

변이음 HMM을 이용한 고립단어 인식

Isolated Word Recognition Using Allophone Unit Hidden Markov Model.

이 강 성*, 김 순 협*

(Gang Sung Lee, Soon Hyob Kim)

요 약

본 논문에서는 변이음 단위의 Hidden Markov Model (HMM)을 이용하여 고립단어를 인식하는 방법을 논한다. 변이음 단위로 HMM을 구성하여 변이음 사전을 만들고, 이 변이음 사전을 이용하여 단어 사전을 구성한다. 변이음 HMM을 이용하여 단어를 구성하려면 변이음 간의 천이확률이 계산되어야 하므로 본 연구에서는 변이음 간의 천이 확률의 영향을 측정하여 그 변이음으로 이루어지는 범의의 단어별 적용없이 적은 수의 적용 데이터로 단어모델을 구성 인식하는 것을 설명한다. 비교를 위하여 단어인식 HMM으로 인식 실험을 한 결과, 변이음 단위 HMM이 적은 기억 용량과 적은 데이터의 훈련으로 단어단위 HMM 이상인 인식율을 얻을 수 있음을 보였다.

ABSTRACT

In this paper, we discuss the method of recognizing allophone unit isolated words using hidden Markov model(HMM). Frist we constructed allophone lexicon by extracting allophones from training data and by training allophone HMMs. And then to recognize isolated words using allophone HMMs, it is necessary to construct word dictionary which contains information of allophone sequence and inter-allophone transition probability. Allophone sequences are represented by allophone HMMs. To see the effects of inter-allophone transition probability and to determine optimal probabilities, we performend some experiments. And we showed that small number of traing data and simple train procedure is needed to train word HMMs of allophon sequences and that not less performance than word unit HMM is obtained.

I. 서 론

음성 신호의 처리는 변이음 단위의 단위 스펙트럼으로 표현된다. 이 정보를 해석하기 위해서는 이단

스펙트럼과 시간에 따른 그 변화를 추적해야 하는 기술이 필요하다. 이러한 기술은 패턴 정합 방법인 DTW와 통계적 모델링 방법인 HMM, Neural Net 등으로 발전되어 왔다. 이들 중에 현재 음성 인식에서 가장 일반적인 접근방법은 통계적 모델링 방법이며 그 중에서도 Hidden Markov Model(HMM)은 가장 성공적인 학습기술로 잘 알려져 있다. HMM

*광운대학교 전자계산기공과과

은 다른 모델에 비해 안정되고 간결하게 음성을 모델링 하는 것이 가능하며 인식용 하는 효율적인 maximum-likelihood 알고리즘이 존재한다⁽¹²⁾. 그래서 고립 단어 인식 작업에 많이 적용되어 왔는데, 기존의 단어인식 모델들은 단어단위 HMM을 구성하여 사용하여 왔다⁽¹³⁾.

단어 단위 HMM을 이용하여 고립단어를 인식하려면 단어수가 증가함에 따라 기억 용량이 크게 증가하며 수가된 단어의 학습시간과 노력이 많이 들게 된다. 따라서 부단어 단위로 인식하는 것이 기억용량 및 학습량, 학습시간을 줄일 수 있는 보다 적절한 방법이라 하겠다. 일반적으로 많이 사용되는 부단어에는 음소, 변이음, phone등이 있다. 이 중에서 음소단위는 음향적인 변화 패턴이 다양하게 전개되는 논리적인 단위로써 하나의 HMM에 작용시키기가 어렵고 phone 단위는 가장 세밀한 단위가긴 하지만 종류가 너무 다양하고 추출하기 어려운 점이 있으므로 본 연구에서는 변이음 단위 HMM을 인식 기본 단위로 선정하였다. 본 연구에서는 변이음 단위 HMM을 기본 단위로 구성하여 기억 용량도 적게 필요로 하며 학습 시간과 노력도 훨씬 적게 들게 하는 화자 종속 고립단어 인식 시스템을 구성하는 것을 목적으로 한다.

변이음 HMM을 이용한 고립단어 학습 및 인식 절차를 그림 1에 보인다. 대상어는 낱어의 9개 도명곡이 도명으로 조합 가능한 15개의 단어를 선정하였다. 먼저 9개 도명으로 부터 변이음을 선정, 추출하여 변이음 HMM을 작성한다. 그리고 이들 변이음을 모아 변이음 사전을 구성한다. 그리고 대상어휘에 대하여 이들 변이음으로 구성되는 단어사전을 구성한다. 이 단어사전은 변이음에 대한 코드와 변이음간의 전이확률로 구성된다. 단어사전이 구성되면 학습 데이터로 단어사전 내의 변이음 간 전이확률을 학습시켜 단어사전을 완성한다. 시험 데이터와 단어노출을 비교하기 위하여 Viterbi 알고리즘을 사용한다.

변이음 치이확률의 영향을 알기 위하여 변이음 간 전이확률을 고정시켜 인식실험을 한다. 또 인식 성능을 비교하기 위하여 단어단위 HMM으로 인식실험을 한다.

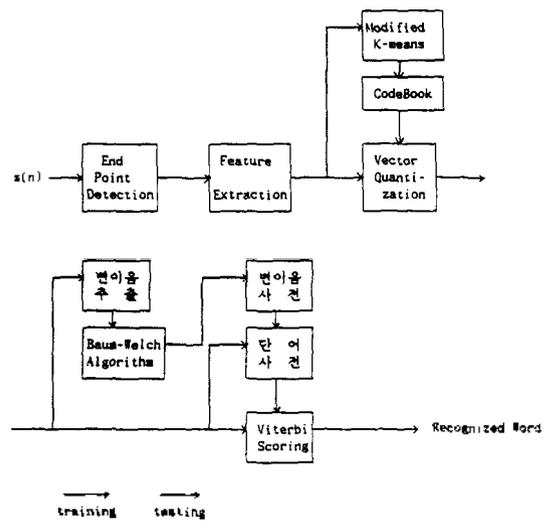


그림 1. 고립단어 학습 및 인식 절차 구성도
Fig. 1. Schematic diagram for training and recognition

II. 변이음 HMM을 이용한 고립단어 인식

1. 음성분석

본 연구에서는 시작점, 끝점 검출을 peak to-peak 값으로 검출하는 Rabiner등의 끝점 검출 방법을 사용하였다. 시작점 및 끝점은 정보의 손실없이 음절 구간과 앞뒤의 묵음 구간을 다 포함하도록 이루어지게 선정하였다.

음성 파형은 3.1KHz의 차단 주파수를 갖는 저역 여파기(LPF)를 통과하여 8KHz로 샘플링 되었다. 4 샘플은 12비트로 양자화되었다. 선형예측코딩(LPC) 분석은 단어의 전체 프레임에 대하여 수행되었다. LPC 분석은 16ms의 프레임으로 하고, 8ms씩 이동하면서 10차로 분석되었다. 음성의 각 16ms는 pre-emphasis 1 (0.95z⁻¹) Hamming window를 사용하여 처리되었다. 근해전 LPC 계수는 16차의 LPC cepstrum 계수로 변환되어 본 연구에서 사용하는 기본 특징 벡터로 사용된다.

2. 벡터 양자화(Vector Quantization)

HMM은 연속 확률 밀도함수를 갖는 HMM으로 인식 방법도 갖는 HMM으로 이루어진다. 그 중에서 이산 확률 밀도함수를 갖는 HMM은, 다른 HMM이 연속 HMM에 비해 인식률이 우수하다.

않으며⁶⁾, 계산량이 적고 처리하기가 간단하기 때문에 많이 사용되고 있다. VQ는 다차원 공간의 데이터를 유한개의 집단으로 구분하여 유한개의 심볼로 그들 그룹을 나타내는 기법으로서, 이산 HMM을 위해서 사용하는데 VQ 코드 북을 구성하는 방법에는 1) 단어마다 각각의 코드 북을 두는 방법, 2) 전체적으로 하나의 코드 북을 두는 방법이 있다. 그런데 1)의 방법인 단어마다 코드북을 두는 방법은 단어가 증가됨에 따라, 또한 코드 북 크기가 증가함에 따라 코드 북 검색 시간이 크게 증가하며, 단어마다 각각의 코드 북을 작성하는 것과 방법 2)와 같이 전체적으로 하나의 코드북을 작성한 것에는 인식 성능의 차이가 거의 없으므로⁶⁾, 본 연구에서는 이산 HMM을 위해 전체적으로 하나의 VQ 코드 북을 작성한다. 코드 북의 크기는 64로 설정했으며, VQ 코드 북 설계방법으로는 Modified K-means(MKM) 알고리즘을 사용했다⁷⁾.

벡터 양자화 과정에서, 코드북을 작성하기 위해서 또는 코드북의 코드워드와 입력 벡터의 유사도를 측정하기 위해서 거리계산이 필요한데 본 연구에서는 다음의 식을 사용하였다⁸⁾⁹⁾.

$$d(x, y) = w(C_{x0} - C_{y0}) + \sum_{i=1}^p (C_{xi} - C_{yi}) \quad (1)$$

여기서, x와 y는 두 개의 켈스트럼 벡터를 나타내고 w는 하중함수이며, Ci 는 LPC cepstrum 계수를 나타낸다. 차수 p는 앞절에서 설명한 비와 같이 10이다.

위 식(1)에서 w는 0.04로 설정하여, 에너지 값이 다른 계수 값보다 훨씬 크기 때문에 에너지에 비해 계수의 중요성이 덜해지기 문해결 최소화시켰다.

3. Hidden Markov Model¹⁰⁾¹¹⁾

HMM을 수식으로 나타내면 모델 M은

$$M = (\Pi, A, B)$$

가 된다. 여기서 Π 는 초기 상태 분포 벡터로써

$$\Pi = (\pi_1, \pi_2, \dots, \pi_N)$$

이고 여기서 N은 상태수이며, 상태 천이 행렬 A는

$$A = [a_{ij}], 1 \leq i \leq N, 1 \leq j \leq N$$

로 a_{ij} 는 상태 i에서 상태 j로 넘어갈 확률이며, B는

$$B = [b_{jk}], 1 \leq j \leq N, 1 \leq k \leq M$$

로 b_{jk} 는 현재상태 q_j 에서 관측 심볼 v_k 가 나타날 확률이다.

관측열 O가 주어지고 모델 M이 주어졌을 때 관측열 O가 모델 M에 의해 나타날 수 있는 확률은 일반적으로 잘 알려진 Forward-Backward 알고리즘으로 구할 수 있으나 본 실험에서는 Viterbi 알고리즘을 사용한다.

또한 모델의 파라미터를 개선하는 것은 Baum-Welch 알고리즘을 사용한다. 다음에 한개의 단어 학습에 의한 A, B 파라미터 재 추정식을 보인다.

$$a_{ij} = \frac{\sum_{t=1}^T \alpha_t(i) a_{ij} b_j(o_{t+1}) \beta_{t+1}(j)}{\sum_{t=1}^T \alpha_t(i) \beta_t(i)} \quad (2)$$

$$b_{ij} = \frac{\sum_{t=1}^T \alpha_t(i) \beta_t(j)}{\sum_{t=1}^T \alpha_t(i) \beta_t(i)} \quad (3)$$

그러나 식(2)를 일반적으로 그냥 사용하지는 않고 복수개의 학습 단어에 의해 전체적으로 파라미터를 재추정하는 아래의 식이 사용된다¹⁰⁾.

$$a_{ij} = \frac{\sum_{t=1}^K \sum_{l=1}^L \alpha_t^k(i) a_{ij} b_l(o_{t+1}) \beta_{t+1}^k(j)}{\sum_{t=1}^K \sum_{l=1}^L \alpha_t^k(i) \beta_t^k(i)} \quad (4)$$

$$b_{ij} = \frac{\sum_{t=1}^K \sum_{l=1}^L \alpha_t^k(i) \beta_t^k(j)}{\sum_{t=1}^K \sum_{l=1}^L \alpha_t^k(i) \beta_t^k(i)} \quad (5)$$

를 재구성해야 한다. 본 연구에서도 Levinson

Rabiner 와 Sondhi가 사용한 scaling 기법을 사용하였으나¹⁰⁾ 복수개 단어의 재 추정식에 오류가 있으므로 아래에 다시 정리하여 둔다¹¹⁾.

$$a_u = \frac{\sum_{k=1}^K P_k \sum_{i=1}^{T-1} \alpha_i^k(i) a_u b_i(o_{t+1}) \beta_{t+1}^k(j)}{\sum_{k=1}^K P_k \sum_{i=1}^{T-1} \alpha_i^k(i) \beta_{t+1}^k(i) / c_t} \quad (6)$$

$$b_u = \frac{\sum_{k=1}^K P_k \sum_{i=1}^T \alpha_i^k(i) \beta_i^k(i) / c_t^{(k)}}{\sum_{k=1}^K P_k \sum_{i=1}^T \alpha_i^k(i) \beta_i^k(i) / c_t^{(k)}} \quad (7)$$

여기서 $\alpha_i(i)$ 와 $\beta_i(i)$ 는 다음의 Forward-Backward 알고리즘에 의해 구해진다.

$$\alpha_{t+1}(j) = [\sum_{i=1}^N \alpha_t(i) a_{ij}] b_j(o_{t+1}) \quad 1 \leq t < T-1 \quad (8)$$

$$\beta_t(i) = \sum_{j=1}^N a_{ij} b_j(o_{t+1}) \beta_{t+1}(j) \quad T-1 \geq t \geq 1 \quad (9)$$

$\alpha_t(i)$ 가 계산되면 scaling 계수 c_t 로 $\alpha_t(i)$ 가 곱해져서 $\sum_{i=1}^N c_t \alpha_t(i) = 1$ 이 되도록 한다.

$$c_t = [\sum_{i=1}^N \alpha_t(i)]^{-1} \quad (10)$$

또한 각 $\beta_t(i)$ 로 c_t 가 곱해져서 scaling 된다. 또한

$$P_k = \sum_{i=1}^T c_t \quad (11)$$

이다.

4. 변이음 사전 및 단어 사전 구성

실험에 사용된 2음절 단어는 표 1과 표 2에 각각 나타낸다. 표 1은 남한의 도명 9개에 대한 목록이며 표 2는 표 1의 앞 음절과 뒷 음절을 결합시켜 만든 목록이다. 본 연구의 기본적인 실험은 표 1의 단어를 기초로 하여 행하여졌다. 단어는 남성 1인이 표 1의 단어를 12번, 표 2의 단어를 5번씩 발성하였다. 12회 발성한 표 1의 단어중 앞의 5회의 전체 데이터는 64개의 코드워드를 갖는 VQ 코드북 작성을 위해 사용되었다. 그리고 나서 이 5회에 데이터 중에서는 다음의 변이음들을 변이음당 약 8~15개 씩을

hand-segmentation 방법으로 D/A를 통해 확인을 거쳐 추출되었다. 추출된 변이음의 종류와 변이음 HMM의 상태를 표 3에 보인다.

변이음 들중 「u」는 「uk」를 한번에 합쳐 놓은 형태로서 /r/ 다음에 중성 /r/으로 마칠 경우는 언제나 공백을 /r/와 같이 생각함으로 묵음 구간까지 합하여 하나의 변이음으로 취급하였다.

추출된 변이음들은 앞절에서 기술한 바와 같이 10차의 LPC cepstrum으로 변환되어 변이음 HMM을 통하여 학습된다. 그림 2에 본 연구에서 이용한 변이음 HMM을 나타낸다.

표 1. 남한의 도명
Table 1. Province names of South Korea

번호	단어	발음
1	경기	[kyæŋgi]
2	강원	[kaŋwæn]
3	충북	[čunbuk]
4	충남	[čunnam]
5	경북	[kyænbuk]
6	경남	[kyænam]
7	전북	[čænbuk]
8	전남	[čænam]
8	제주	[čæcu]

표 2. 도명으로 조합된 단어
Table 2. Words composed by porvince names

번호	단어	발음
1	경원	[kyænwæn]
2	경주	[kyæŋcu]
3	강기	[kaŋgi]
4	강북	[kaŋbuk]
5	강남	[kaŋnam]
6	강주	[kaŋcu]
7	충기	[čunggi]
8	충원	[čunwæn]
9	충주	[čunču]
10	전기	[čæŋgi]
11	전원	[čænwæn]
12	전주	[čæŋcu]
13	제원	[čæwæn]
14	제북	[čæbuk]
15	제남	[čænam]

표 3. 변이음 종류 및 상태 수

Table 3. Types and number of states of allophone HMM

변이음	상태수	변이음	상태수
k	2	l	3
u	2	a	3
c	3	wə	4
m	2	u	4
n	2	u ¹	4
b	2	ə	3
v	3	e	3
c ^v (유성화)	3	silence	2
yə	3		

단어 모델은 단어를 구성하는 변이음들을 순서대로 나열하고 그 변이음 간의 천이확률을 정함에 의해 완성된다. 그림 3에서 보듯이 단어모델은 언제나 시작 변이음 HMM s로 시작해서 끝 변이음 HMM e로 마치게 되는데, 이 두개의 HMM은 묵음 HMM이다. 앞서 기술했듯이 시작점과 끝점을 잡을 때 묵음이 앞뒤에 포함되도록 충분히 잡았으므로 시작과 끝 변이음으로 묵음을 두는 것이 타당하다. 또한 이렇게 함으로 시작점과 끝점 검출이 정확하지 않아도 되는 장점을 갖는다.

III. 실험 및 고찰

본 연구에서는 변이음 HMM을 이용한 단어인식의 유용성을 검증하기 위하여 4가지의 실험을 하였다. 실험 1에서 3까지는 표 1의 음성자료에 관한 실험이며, 실험 4는 표 2의 음성 자료이다.

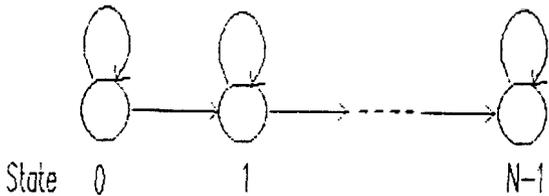


그림 2. 변이음 HMM
Fig. 2. Allophone HMM

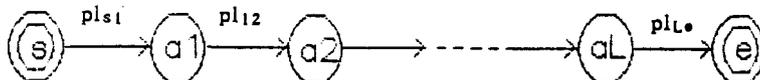
추출된 변이음들은 Baum-Welch의 재추정 알고리즘을 반복하여 사용함으로 변이음 HMM을 학습시켰다. 변이음 HMM의 상태수 (N)은 변이음의 종류에 따라서 2~4개로 설정하였다. 학습이 완성되면 이들 변이음 HMM을 한 곳에 모아 변이음 사전을 구성한다.

변이음 HMM을 이용한 단어모델은 그림 3에 나타난다.

1. 단어 HMM을 이용한 인식 실험

변이음 HMM을 이용한 고립단어 인식의 성능과 비교하기 위하여 단어단위의 HMM을 이용하여 표 1의 9개 단어에 대한 인식 실험을 하였다. 단어 HMM의 학습을 위해 표 1의 내용을 12회 발성한 것 중 5회를 사용하였다. 상태 수는 모두 10개로 하여 인식실험을 하였다. 총 9개 단어를 12회 반복한 108개 데이터 중에서 107개를 올바르게 인식하여 인식률 99.07%를 기록하였다.

오인식된 단어는 12회째 발성한 경남으로서 총남으로 인식되었다.



- ai 변이음 HMM
- s 시작 변이음 HMM
- e 끝 변이음 HMM
- pl 변이음 간의 천이 확률

그림 3. 변이음 HMM을 이용한 단어모델
Fig. 3. Word model constructed by allophone HMM

2 변이음 천이 확률을 고정시켰을 때의 인식 실험
 변이음 사전에서 변이음 HMM을 연결하여 단어를
 인식하기 위해서는 변이음 간의 천이 확률이 필요하다.
 이번 실험에서는 변이음간 천이 확률과 인식률과의
 관계를 알아보기 위하여 단어사전의 단어를 학습
 시키지 않고 전체 변이음간의 천이확률을 0.1에서
 0.9까지 0.1씩 증가시키면서 실험을 하였다. 실험
 결과를 그림 4에 나타내었다.

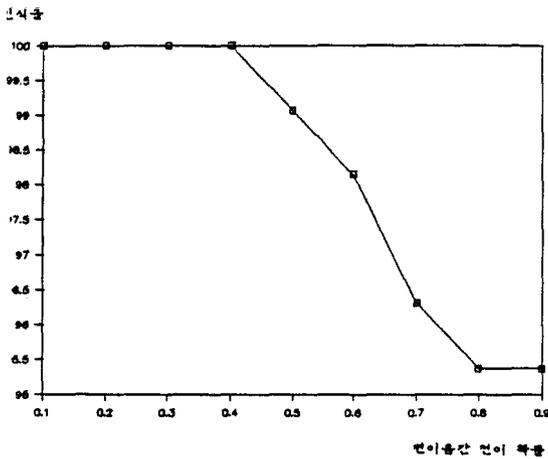


그림 4. 변이음간 천이 확률에 따른 인식률
 Fig. 4. Recognition score according to transition probability between allophones.

변이음 간 천이 확률은 0.1에서 0.4일 때는 인식률이 100%, 0.5일 때는 99.07%, 0.6일 때는 98.25%, 0.7일 때는 96.30%, 그리고 0.8일 때는 95.37%가 되어 천이 확률이 0.1에서 0.4일 때 가장 좋은 성능을 내고, 확률이 증가함에 따라 인식률이 나빠진다는 것을 알 수 있다.

3. 변이음 천이 확률을 학습시켰을 때의 인식 실험

단어 HMM으로 고립단어를 인식하기 위해서는 많은 양의 학습 데이터, 학습시간, 그리고 기억 용량을 필요로 하지만 음소 또는 변이음등의 부 단어 단위로 인식 모델을 설계했을 때는 부 단어들의 모임으로 단순히 기술 할 수 있으므로 기억용량이 적게 들고 학습시도 부 단어간의 천이 확률만 계산하면 되므로 데이터 일이나 시간이 적게 걸리게 된다.

이번 실험에서는 변이음 HMM으로 구성된 단어사전의 변이음간 천이 확률 파라미터를 단 2회의 학습 데이터로 천이 확률을 조정된 후에 인식실험을 행하였다. 인식률은 100%로 108개 단어를 모두 인식하였다.

4. 새로운 단어의 인식 실험

이번 인식실험은 표 2에 기술된 단어에 대한 인식 실험으로 표 1의 단어에서 추출되어 구성된 변이음 HMM을 이용하여 단어 사전을 구성하였다. 새로운 단어에 대한 실험은 2가지분 하였다. 첫번째는 학습 없이 변이음간 천이확률을 실험 2에서 얻어진 실험 결과를 토대로 하여 0.25로 고정시켜 인식 실험을 하였고 두번째로는 표 2의 단어를 5회 발생한 것 중 2회로 변이음 천이확률을 학습시켜 인식실험을 하였다. 첫번째 실험에서는 총 75개 데이터중 3개가 오인식되어 96%의 인식률을 기록하였으며 두번째 실험에서는 2개를 오인식하여 97.33%의 인식률을 나타내었다.

5. 고 찰

이상의 실험은 변이음 HMM을 이용한 고립단어 인식 성능을 평가하기 위하여 수행하였다. 첫번째 실험은 단어단위 HMM을 이용하여 99.07%의 인식률을 나타내어, 두번째 실험의 변이음간 천이확률을 고정시켰을 때의 최고 인식률 100%, 세번째 실험의 천이확률을 학습시켰을 때의 인식률 100%와 비교했을 때 변이음의 부 단어 단위 HMM을 이용한 고립단어 인식이 비당위를 보였다. 여기서 나타난 것 보다 변이음 단위가 더 좋은 성능을 나타낸 이유는 상태 수가 변이음 단위에 더 많기 때문인 것으로 해석되며, 상태 수를 단어단위와 같이 해도 인식성능에 차이가 거의 없을 것으로 고찰된다.

IV. 결 론

고립단어를 인식하기 위하여 변이음 단위 HMM을 이용하였다. 대상 어휘는 남한의 9개 도명과 1명으로 조립가능한 15개의 단어를 선정하여 실험하였

다. 실험결과 단어단위 인식 성능과 변이음 HMM을 이용한 고립단어 인식 성능이 99.07%와 100%로 거의 유사한 결과를 내었으며, 또한 변이음 HMM을 이용하여 단어를 인식할 때의 변이음 간의 전이 확률은 0.1에서 0.4일 때가 가장 좋은 인식률을 내는 것을 알 수 있었다. 또한 전혀 훈련되지 않는 15개의 새로운 단어에 대해서도 변이음 전이확률을 고정시켰을 때 96%, 전이확률 학습을 시켰을 때 97.33%의 인식률을 얻어 변이음 단위 HMM을 이용한 고립단어 인식의 타당성을 입증하였다.

參 考 文 獻

1. W.J. Yang, J.C. Lee, Y.C. Chang and H.C. Wang, "Hidden Markov Model for Mandarin Lexical Tone Recognition", IEEE Trans. on Acoust., Speech, Signal Processing, Vol. ASSP-36, No. 7, July, 1988.
2. 大河内正明, "マルコフモデルによる 音聲認識", 日本電子情報通信學會誌, 4/ '87.
3. L.R. Rabiner, S.E. Levinson and M.M. Sondhi, "On the Application of Vector Quantization and Hidden Markov Models to Speaker-Independent, Isolated Word Recognition", Bell System Technical Journal, Vol. 62, No. 4, April 1983.
4. B.H. Juang, L.R. Rabiner, "Mixture Autoregressive Hidden Markov Model for Speech Signals", IEEE Trans. on Acoust., Speech, Signal Processing, Vol. ASSP-33, No. 6, Dec. 1985.
5. L.F. Lamel, L.R. Rabiner, A.E. Rosenberg and J.G. Wilpon, "An Improved Endpoint Detector for Isolated Word Recognition", IEEE Trans. on Acoust., Speech, and Signal Processing, Vol. ASSP-29, No. 4, Aug. 1981.
6. E. Frangoulis, "Vector Quantization of the Continuous Distributions of an HMM Speech Recognizer based on Mixtures of Continuous Distributions", Proc. ICA SSP 89.
7. J.G. Wilpon and L.R. Rabiner, "A Modified K-means Clustering Algorithm for Use in Isolated Word Recognition", IEEE Trans. on Acoust., Speech, and Signal Processing, Vol. ASSP-33, No. 3, June 1985.
8. A.H. Gray, and J.D. Marker, "Distance Measures for Speech Processing", IEEE Trans. on Acoust., Speech, and Signal Processing, Vol. ASSP-24 No. Oct. 1976.
9. Shikano, K., Kohda, M., "On the LPC Distance Measures for Vowel Recognition in Continuous Utterances", Institute of Electrical and Communication Engineers of Japan, Trans. on D, J63-D(5), May, 1980.
10. S.E. Levinson, L.R. Rabiner and M.M. Sondhi, "An Introduction to the Application of the Theory of Probabilistic Functions of a Markov Process to Automatic Speech Recognition", Bell System Technical Journal, Vol. 63, No. 4, April, 1983.
11. L.R. Rabiner and B.H. Juang, "An Introduction to Hidden Markov Models", IEEE ASSP Magazine, Jan. 1986.

▲이강성 제10권 1호 참조

▲김순형 제10권 1호 참조