적응 콤 필터링을 이용한 이동 통신 환경에서의 강인한 음성 인식

박정식(KAIST), 정규준(KAIST), 오영환(KAIST)

<차 례>

<Abstract>

Robust Speech Recognition using Adaptive Comb Filtering in Mobile Communication Environment

Jeong-Sik Park, Gue-Jun Jung, Yung-Hwan Oh

In this paper, we employ the adaptive comb filtering for effective noise reduction in mobile communication environment. Adaptive comb filtering is a well-known method for noise reduction, but requires correct pitch period and must be applied just in voiced speech frames. To satisfy these requirements we use two kinds of information extracted from speech packets, one of which is the pitch period information measured precisely by a speech coder and the other is the frame rate information related to a decision on speech or silence frame. Experiments on speech recognition system confirm the efficiency of this method. Feature parameters employing this method give superior performance in noise environment to those extracted directly from output speech.

* Keywords: robust speech recognition, adaptive comb filtering, mobile communication environment, speech coder, QCELP

1. 서 론

음성 인식 기술은 현재 전화망 뿐 아니라 유선 통신망에 이르기까지 응용 범위가 확대되고 있으며 특히 첨단 정보망 구축에 원동력이 될 무선 통신 환경으로 영역을 넓혀 가고 있다. 본 논문은 무선 통신의 한 범주라 할 수 있는 이동 단말기 상에서의 음성 인식 성능을 향상시키기 위한 방법을 다룬다. 특히 단말기 사용자들의 이동성에 의한 여러 잡음 환경에 대해 강인한 인식 성능을 유지할 수 있는 방법을 제안하고자 한다.

이동 통신 환경에서의 음성 인식에 대한 연구는 특징 파라미터를 추출하는 전처리부의 설계 방법에 따라 음성 코덱의 출력 음성으로부터 특징 파라미터를 추출하는 방법, 코덱의 부호화기에서 인식 파라미터를 추출하여 그것을 코딩 및 인식에 이용하는 방법, 그리고 음성 코딩에 사용되는 파라미터를 패킷에서 추출하여 특징 파라미터로 사용하는 방법으로 나뉜다. 이 중 두 번째 방법은 인식률은 좋으나 합성음의 음질 저하가 문제되며 처리량이 제한된 단말기에서 특징 파라미터를 추출하므로 PC 기반의 음성 인식 기술을 적용하는데 한계가 있다. 또한 첫 번째 방법은 구현이 용이하나 세 번째 방법보다 인식 성능이 좋지 않다는 연구 결과가 있었다[1]. 따라서 이동 통신 환경에서의 음성 인식 연구는 세 번째 방법, 즉 패킷에서 추출한 특징 파라미터를 대상으로 수행되어 왔다. 하지만 15dB 이하의 잡음 음성에 대해 인식 실험을 수행한 결과 세 번째 방법보다는 첫 번째 방법의 인식률이 높았으며, 이는 음성 코덱의 영향임을 확인하였다[2].

본 논문에서는 이처럼 출력 음성에서 특징 파라미터를 추출하는 경우 출력 음성에 포함된 잡음을 제거하기 위해 적응 콤 필터링(Adaptive Comb Filtering)을 이용하는 방법을 제안한다. 2장에서 잡음 환경에서 음성 코덱이 인식 성능에 미치는 영향을 살펴보고 3장에서 적응 콤 필터링을 이용하여 출력 음성에 포함된 잡음을 제거하는 과정에 대해 설명한다. 4장에서 실험 결과를 제시하며 5장에서 결론을 맺는다.

2. 잡음 환경에서 음성 코덱의 영향

출력 음성과 패킷에서 추출한 특징 파라미터의 성능을 비교한 기존 연구의 실험 환경은 배경 잡음이 첨가되지 않은 깨끗한 실험실 환경이었으며 패킷에서 추출한 특징 파라미터의 성능이 더 좋은 결과를 나타냈다[1]. 그러나 동일한 실험 조건에서 배경 잡음이 첨가된 음성을 대상으로 인식 실험을 수행한 결과 기존의 연구와 달리 출력 음성에서 추출한 파라미터가 더 좋은 성능을 보였으며 SNR이 높을수록 성능 차이는 더욱 두드러졌다[2]. 이와 같은 결과는 실험에 사용한 QCELP

(Qualcomm Code-Excited Linear Predictive) 음성 코덱의 영향과 관련이 있다.

<그림 1>은 백색 잡음이 첨가된 입력 음성과 출력 음성의 파형을 비교한 것으로 디코딩 후 비음성 구간의 에너지가 상당히 감소되었음을 확인할 수 있다. <그림 2>는 음성 구간의 에너지 변화 여부를 확인하기 위해 동일한 음성의 음성 구간과 비음성 구간에 해당하는 프레임의 스펙트럼을 분석한 것으로, 비음성 프레임의 경우 디코딩 후 전 주파수 대역의 에너지가 감소되었지만 음성 프레임은 에너지의 변화가 거의 없었다.

두 그림으로부터 잡음 환경에서 출력 음성에서 추출한 파라미터의 성능이 높은 이유를 설명할 수 있다. 일반적으로 음성에 잡음이 첨가되면 음성 구간의 검출이 어렵다. 그러나 코덱을 통과한 출력 음성의 경우 비음성 구간의 에너지 감소로 인해 음성 구간의 검출이 용이해지며 이는 인식 성능 향상의 중요한 요인이 된다.

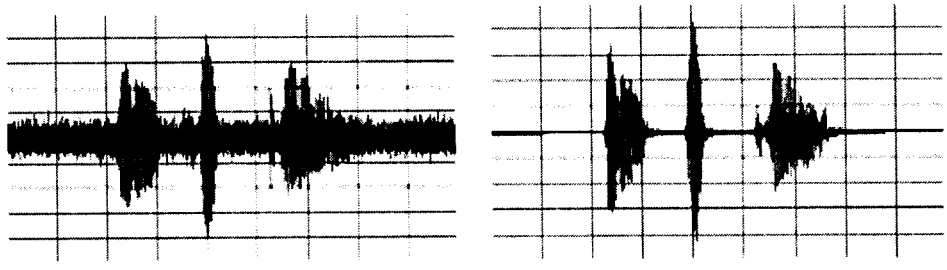

(a) 입력 음성 (b) 출력 음성

<그림 1> 음성 코덱의 영향 (백색 잡음, SNR 5dB)

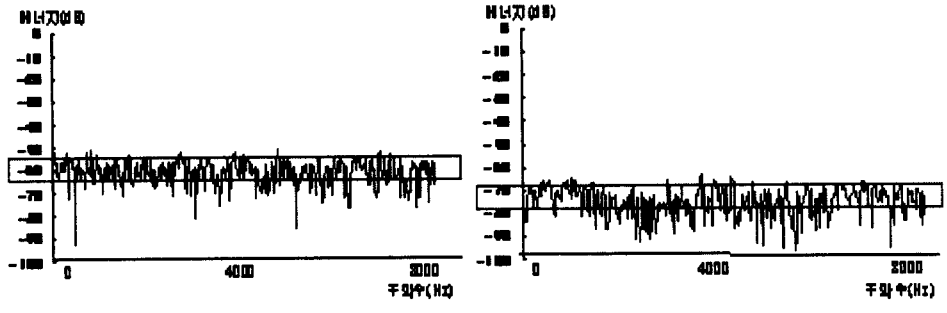

(a) 입력 음성 (b) 출력 음성

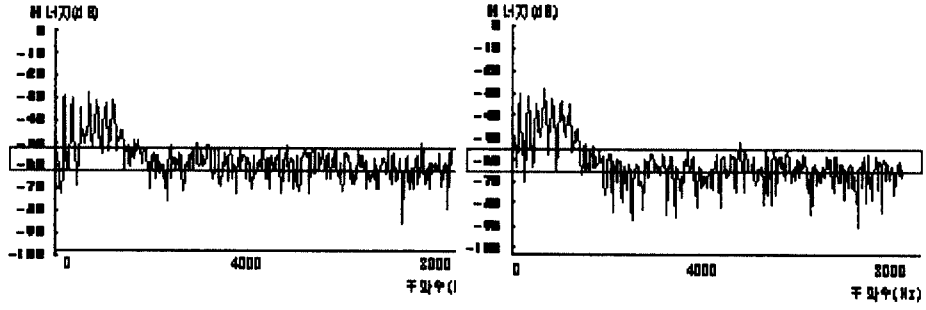

(a) 입력 음성 (b) 출력 음성

<그림 2> 음성(上)/비음성(下) 프레임의 스펙트럼

3. 적응 콤 필터링을 이용한 효과적인 잡음 제거

앞서 살펴본 바와 같이 음성 코덱은 비음성 구간의 에너지를 감소시키며 이로 인해 출력 음성에서 추출한 파라미터의 성능이 향상된다. 이와 같은 상황에서 출력 음성의 음성 구간에 여전히 존재하는 잡음 성분을 제거함으로써 인식 성능을 더욱 향상시킬 수 있을 것이다. 이를 위해 본 연구에서는 적응 콤 필터링(Adaptive Comb Filtering)을 음성 구간의 잡음 제거에 이용하고자 한다.

3.1. 적응 콤 필터링을 이용한 출력 음성의 잡음 제거

스펙트럼 사상, 잡음 차감법과 같은 대부분의 음질 개선 기법은 입력 신호에서 비음성 구간을 검출한 후 잡음 성분을 추정하고 그 결과를 음성 구간의 잡음 처리에 이용한다. 그러나 디코딩 후 생성된 출력 음성의 비음성 구간은 코덱의 영향으로 에너지가 감소된 상태이기 때문에 정확한 잡음 추정이 불가능하며 음성 구간의 잡음을 제거하는데 한계가 있다. 따라서 출력 음성의 잡음 제거를 위해서는 비음성 구간의 잡음 추정 없이 음성 구간의 잡음을 제거할 수 있는 음질 개선 기법을 적용해야 한다. 콤 필터링은 이러한 특성을 지닌 음질 개선 기법으로 음성 구간에서 측정한 기본 주파수(또는 피치 주기)를 이용하여 잡음 성분을 제거하기 때문에 비음성 구간의 잡음 추정이 필요 없다[3].

<그림 3>은 콤 필터링의 원리를 주파수 영역에서 표현한 것이다. 잡음 음성의 경우 <그림 3-a>와 같이 고조파와 고조파 사이에 잡음 성분이 존재한다. 이 때, 음성의 기본 주파수(F0)와 동일한 주파수 응답을 갖는 콤 필터(<그림 3-b>)를 적용하

면 <그림 3-c>와 같이 잡음 성분이 제거된 스펙트럼을 얻을 수 있다. 그런데 시간에 따라 변화하는 기본 주파수를 정확하게 반영하지 않고 콤 필터링을 수행하면 필터링 후 음성 신호의 왜곡이 발생할 우려가 있다. Frazier에 의해 제안된 적응 콤 필터링은 기본 주파수를 정확히 반영함으로써 음성 신호의 왜곡을 최소화하는 콤 필터링의 개선된 형태이다[4, 5].

<그림 4>는 본 논문에서 제안한 잡음 제거 과정을 나타낸 것으로, 음성 코덱 통과 후 생성된 출력 음성의 음성 구간에 적응 콤 필터링을 적용한 후 특징 파라미터를 추출하는 과정이다. 다음 절에서 이 과정에 대해 자세히 살펴보도록 한다.

<그림 3-a> 잡음 음성의 스펙트럼

<그림 3-b> 콤 필터의 주파수 응답 형태

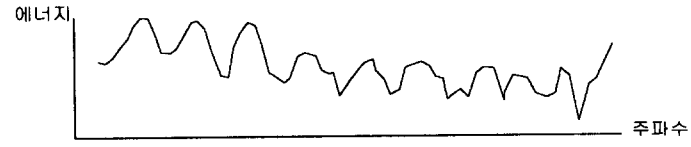

<그림 3-c> 필터링 후의 스펙트럼

<그림 3> 콤 필터링의 원리

3.2. 유성음 프레임의 선별

적응 콤 필터링은 피치 주기를 갖는 음성 구간에 대해서만 적용될 수 있으므로 음성 프레임을 선별해야 한다. 이 과정에서 프레임의 전송률 정보를 패킷에서

추출하여 이용하였다. QCELP 코덱은 각 프레임의 speech activity를 측정하여 전송률을 결정하는데 activity가 작은 비음성 구간은 전송률이 1 kbps로 결정되는 특성이 있다[6]. 따라서 전송률이 1 kbps인 프레임[1]은 비음성 구간으로 간주하여 처리하였다.

음성 구간은 유성음과 무성음으로 이루어지는데 비주기성이 강한 무성음 구간에 대해 필터링을 수행하면 무성음의 신호 성분이 제거될 우려가 있다. 따라서 음성 구간 중 유성음 프레임만을 선별하는 과정이 필요하다. 본 연구에서는 이를 위해 자기상관계수(autocorrelation coefficient)를 이용한 유/무성음 분별 방법을 사용하였다[7].

유성음 프레임에 대해 필터링을 수행하면 잡음 성분이 제거되어 프레임의 전체 에너지가 감소한다. 따라서 필터링이 적용되지 않는 비음성 또는 무성음 구간은 상대적으로 큰 에너지를 갖게 되므로 부적절하게 강조될 수 있다. 이러한 문제를 해결하기 위해 비음성과 무성음 프레임에 대해 간단한 감쇠 처리를 하였다.

3.3. 적응 콤 필터링 처리

앞의 과정을 통해 선별된 유성음 프레임에 대해 적응 콤 필터링을 적용한다. 필터링을 효과적으로 수행하기 위해서는 각 프레임의 정확한 피치 주기가 요구된다. 켑스트럼 기반 또는 LPC 기반의 피치 측정 방법 등 피치 주기를 측정하는 다양한 방법들이 존재하지만 정확한 피치 주기를 측정하는 것은 쉽지 않으며 잡음 음성의 경우는 더욱 어렵다. 이와 같은 제약을 해결하기 위해 본 연구에서는 음성 코덱에서 측정된 피치 주기를 음성 패킷에서 추출하여 직접 이용하였다. QCELP 음성 코덱은 프레임마다 피치 주기가 최다 네 차례 갱신될 정도로 음성의 피치 주기를 정확히 측정한다. 특히 패킷에서 추출한 피치 주기는 복호화기에서 출력 음성의 합성에 이용하는 정보로서 출력 음성에 정확히 부합하는 피치 주기이기 때문에 피치 측정이 어려운 잡음 음성에 대해서도 필터링을 효과적으로 수행할 수 있다. 콤 필터링을 위한 피치 측정 과정을 생략할 수 있다는 점은 계산량 감소 측면에서 유용하다.

---

1) 전송률이 1 kbps인 프레임을 보통 'Rate 1/8' 프레임이라고도 한다.

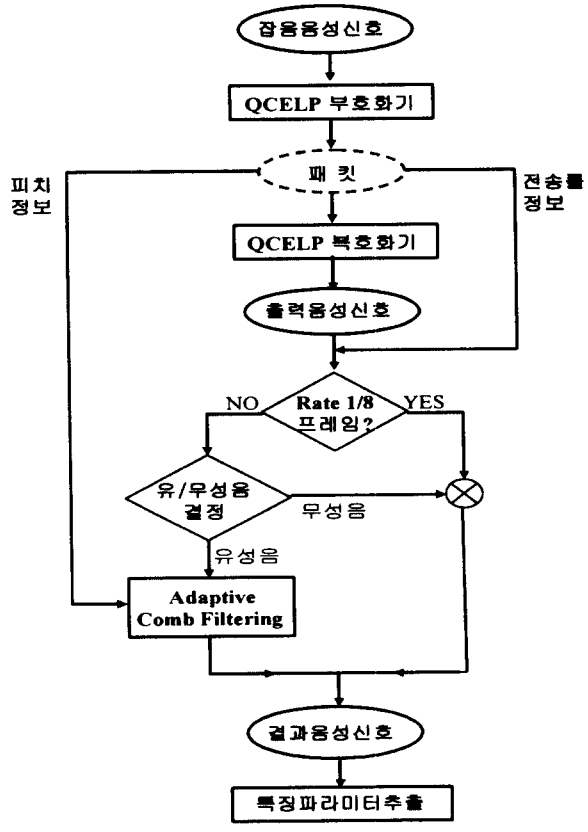

<그림 4> 제안한 잡음 제거 과정

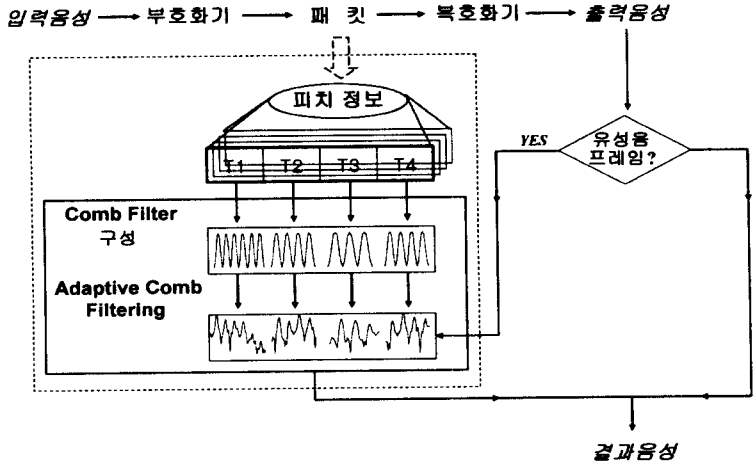

<그림 5> 유성음 프레임의 필터링 처리

<그림 5>는 유성음 프레임에 대해 필터링을 처리하는 과정을 나타낸 것이다. QCELP에서는 각 프레임의 전송률에 따라 피치 주기의 갱신 횟수가 다르기 때문에 부프레임 단위로 필터링을 수행했다. 위 그림의 경우 전송률이 8 kbps인 프레임으로 피치 주기가 네 차례 갱신되기 때문에 네 개의 부프레임에 대해 각각의 피치 주기(T1-T4)를 이용하여 콤 필터를 구성하고 부프레임 별로 콤 필터를 적용하여 필터링을 수행한다.

4. 실험 및 결과

4.1. 실험 환경

제안한 방법의 유효성을 검증하기 위해 연속 HMM을 이용한 50 단어 규모의 고립 단어 인식 실험을 수행하였다. 적응 콤 필터링을 적용한 후 추출한 파라미터 외에 출력 음성에서 추출한 파라미터와 기존의 음질 개선 기법 중 가장 잘 알려진 스펙트럼 차감법(Spectral Subtract)을 적용한 후 추출한 파라미터를 성능 비교의 목적으로 사용하였다(<그림 6>참조). 실험에 사용한 DB는 한국어 낭독 음성 PBW (Phonetically Balanced Word) DB이며, 학습 데이터로는 20명의 화자가 두 차례씩 발성한 2000개의 발화를, 실험 데이터로는 10명의 화자가 두 차례씩 발성한 1000개의 발화를 사용하였다[8]. HTK를 이용하여 추출한 39차 MFCC 파라미터를 특징 파라미터로 사용하였으며 13차 MFCC, 차분, 가속 MFCC로 구성하였다. 잡음 환경을 고려하기 위해 실험 데이터에 첨가한 배경 잡음은 NoiseX-92에 포함된 백색 잡음과 군중 잡음, 공장 잡음이며, 실험실 환경(clean speech) 및 SNR 15dB, 10dB, 5dB, 0dB 각각의 잡음 환경에 대하여 인식 성능을 비교하였다[9].

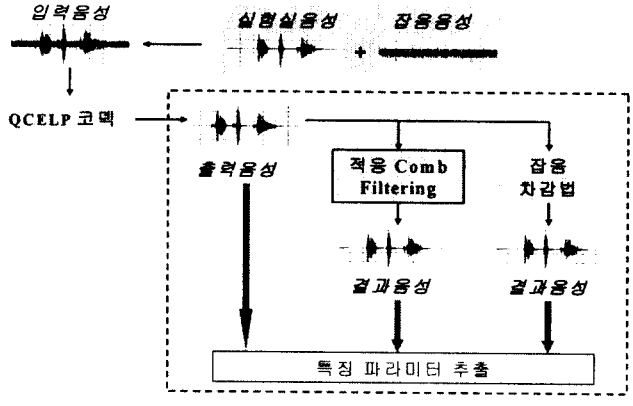

<그림 6> 실험에 사용한 특징 파라미터

4.2. 실험 결과

각 실험에 대한 인식 성능 결과는 <표 1, 2, 3>과 같다. 실험실 환경과 SNR 15dB의 잡음 환경에서는 제안한 방법으로 추출한 파라미터의 성능이 낮았지만, SNR 10dB 이하의 잡음 환경에서는 다른 파라미터에 비해 성능이 크게 향상되었으며 잡음 정도가 심해질수록 성능 차이가 두드러졌다. 또한 기존의 잡음 차감법이 적용된 파라미터의 성능은 출력 음성에서 추출한 파라미터보다는 향상되었지만 제안한 방법으로 추출한 파라미터의 성능에는 미치지 못했다. 이와 같은 결과는 적응 콤 필터링을 통해 음성 구간의 잡음이 효과적으로 제거되었음을 의미한다.

<표 1> 각 파라미터 간 성능 비교 (백색 잡음) (단위 : %)

SNR	∞(clean)	15dB	10dB	5dB	0dB
출력음성	99.4	89.2	70.4	40.6	13.1
잡음차감법	99.3	90.9	72.1	42.4	14.3
제안한방법	96.5	87.7	77.3	48.3	25.7

<표 2> 각 파라미터 간 성능 비교 (군중 잡음)

SNR	∞(clean)	15dB	10dB	5dB	0dB
출력음성	99.4	96.7	89.2	60.6	16.2
잡음차감법	99.3	96.4	90.3	60.4	16.0
제안한방법	96.5	96.2	92.2	83.4	35.3

<표 3> 각 파라미터 간 성능 비교 (공장 잡음)

SNR	∞(clean)	15dB	10dB	5dB	0dB
출력음성	99.4	97.0	85.3	55.3	14.3
잡음차감법	99.3	95.2	83.6	53.2	15.0
제안한방법	96.5	95.0	92.2	80.0	37.7

5. 결 론

본 논문에서는 음성 코덱의 출력 음성에 대해 적응 콤 필터링을 적용함으로써 음성에 포함된 잡음을 제거하는 방법을 제안하였다. 출력 음성에는 비음성 구간의 에너지가 감소되어 잡음 성분을 추정하는데 한계가 있는데 음성 구간의 피치 주기를 이용하는 콤 필터링을 적용하여 잡음을 효과적으로 제거할 수 있었다. 이 방법은 코덱에서 제공되는 정보를 이용함으로써 피치 추출 등의 과정을 생략할 수 있으며 정확한 피치 정보를 통해 콤 필터링을 보다 효과적으로 수행할 수 있다는 장점을 갖는다.

QCELP 코덱에서 생성된 출력 음성을 사용하여 SNR 15dB 이하의 여러 종류의 잡음 환경에서 인식 실험을 수행한 결과, 제안한 방법으로 추출한 파라미터의 성능 향상을 확인할 수 있었다. 그러나 실험실 환경에서는 다른 파라미터에 비해 낮은 성능을 보였는데 그 이유는 필터링에 의한 음성 신호의 왜곡 때문이다. 이를 해결하기 위해 왜곡을 최소화하는 개선된 적응 콤 필터링을 연구해야 할 필요가 있다.

참 고 문 헌

[1] Hong-Kook K., "Bitstream-based feature extraction for wireless speech recognition", *Proc. of International Conference on ASSP*, Vol. 3, pp.1607-1610, 2000.

[2] 박정식, 정규준, 오영환, "Adaptive Comb Filtering을 이용한 이동 통신 환경에서의 강인한 음성 인식", *2002년 한국음향학회 추계학술발표대회 논문집*, 21권, 2(s)호, pp.35-38, 2002.

[3] V. C. Shields Jr., "Separation of added speech signals by digital comb filtering", S. M. thesis, M.I.T., Cambridge, 1970.

[4] R. H. Frazier, "An adaptive filtering approach toward speech enhancement", S. M. thesis, M.I.T., Cambridge, 1975.

[5] R. H. Frazier, S. Samsam, "Enhancement of speech by adaptive filtering", *in Proc. IEEE Int. Conf. on ASSP, Philadelphia. PA, Apr.12-14*, pp.251-253, 1976.

[6] W. Gardner, "QCELP: A variable rate speech coder for CDMA digital cellular", *Speech and audio coding for wireless and network applications*, pp.77-84, Boston: Kluwer Academic Pub., 1993.

[7] B. S. Atal, L. R. Rabiner, "A pattern recognition approach to voiced-unvoiced-silence classification with applications to speech recognition", *IEEE Trans. Acoust., Speech, Signal Processing*, Vol. 24, pp.201-212, 1976, June.

[8] 이용주, "음성언어코퍼스", *정보과학회지*, 16권, 2호, pp.41-48, 1998.

[9] A. P. Varga, H. J. M Steenken et al., "The NOISEX-92 study on the effect of additive noise on automatic speech recognition", Technical Report, DRA Speech Research Unit, 1992.

접수일자: 2003년 05월 21일
게재결정: 2003년 06월 12일

▶ 박정식(Jeong-Sik Park)
주소: 대전시 유성구 구성동 373-1
소속: 한국과학기술원 전자전산학과 전산학전공
전화: 042) 869-5556
E-mail: parkjs@kaist.ac.kr

▶ 정규준(Gue-Jun Jung)
주소: 대전시 유성구 구성동 373-1
소속: 한국과학기술원 전자전산학과 전산학전공
전화: 042) 869-3556
E-mail: sylph@speech.kaist.ac.kr

▶ 오영환(Yung-Hwan Oh)
주소: 대전시 유성구 구성동 373-1
소속: 한국과학기술원 전자전산학과 전산학전공
전화: 042) 869-3516
E-mail: yhoh@speech.kaist.ac.kr