

MOSFC-Gradient Ascent를 이용한 엔트로피 최대화의 성능향상

김영섭*, 이영주*, 이광석**, 허강인*

요약

본 논문은 음원분리를 수행하기 위한 방법으로 기존의 독립성분분석 방법 중 하나인 엔트로피 최대화 방법에서 빠른 수렴과 분리결과의 정확성 확보를 위해 기존 학습 방법인 Gradient Ascent 알고리즘을 개선한 MOSFC-Gradient Ascent(Multiple Objects Searching and Fast Converging Gradient Ascent) 방법을 제안한다. 제안된 방법은 엔트로피가 지속적으로 증가하면 학습상수 또한 증가시킴으로써 빠른 수렴 특성을 가지며, 또한 랜덤한 서로 다른 시작 값으로 구성된 여러 개의 분리행렬을 탐색객체로 정의하고 병렬적으로 최적의 분리행렬을 찾음으로써 혼합된 신호의 수가 증가하더라도 수렴속도의 저하 없이 높은 분리 성능을 유지하는 방법이다.

Performance Improvement of Entropy Maximization using MOSFC-Gradient Ascent

Young-Sub Kim*, Young-Joo Lee*, Kwang-Seok Lee**, Kang-In Hur*

ABSTRACT

In this paper, we propose the method of MOSFC-Gradient Ascent improving the Gradient Ascent algorithm. This method obtains fast convergence and accuracy of separate results in Entropy maximization method being one among the existing ICA(Independent Component Analysis) with the method for performing the sound source separation. If Entropy is steadily increased, the proposed method will have characteristic of fast convergence through increase of learning constant. Also it will define as search object of several demixing matrix made in random other start value. As searching optimal demixing matrixs in parallel, the proposed method is retained on high demixing performance without decrease of convergence speed even though number of mixed signals is increased.

Key Words : Information Maximization, Entropy, Gradient Ascent, ICA

* 동아대학교 전자공학과(yskim770202@gmail.com)

** 국립경남과학기술대학교 전자공학과

· 제1저자(First Author) : 김영섭 · 교신저자(Correspondent Author) : 허강인

· 접수일(2013년 3월 14일), 수정일(1차 : 2013년 4월 9일), 게재확정일(2013년 4월 15일)

1. 서 론

최근 HMI(Human Machine Interface), 토론장에서
의 데이터 기록 및 유지, 그리고 공공장소에서 모발
일 기기를 이용한 사용자 음성 질의 기반 정보 시
스템(교통정보검색 및 주가 시세 정보 검색)등 음성
신호를 적용한 시스템의 증가와 다양한 환경에서의
적용으로 인해 잡음에 대한 강인성 확보가 중요하
게 부각되고 있다. 특히 사람들이 밀집된 지역에서
옆 사람의 비정상적 신호가 혼합된 경우 음성인식
시스템을 적용하기 위해서는 음성의 명료성 향상을
위해 음원분리 기술의 연구가 필수적이다[1].

본 논문은 음원분리를 수행하기 위한 기존의 독
립성분분석(ICA)[2] 방법 중의 하나인 엔트로피 최
대화(Infomax : Information Maximization)[3][4] 방법
의 성능개선에 관한 연구이다. Infomax는 비선형
활성함수를 통과한 매핑된 신호 \mathbf{Y} 의 엔트로피를
최대화하는 분리행렬 \mathbf{W} 을 최적화하기 위해
Gradient Ascent 학습 알고리즘을 사용한다. 그러나
Gradient Ascent 학습 알고리즘은 반복적 처리방법
을 이용하므로 시간적 비용 문제를 포함하고 또한
최대 함수값을 찾는 것이 아니라, 분리행렬 \mathbf{W} 의
초기값에 의존한 가장 근접한 지역 최대값을 찾으
므로 일정한 성능을 유지하기 위한 개선이 필요하
다. 따라서 본 논문은 Infomax방법에서 사용하는
학습 알고리즘의 빠른 수렴과 결과의 정확성을 향
상시키기 위한 두 가지 방법을 제안하고 실험을
통하여 제안된 방법의 성능을 평가한다.

II. 독립성분분석

독립성분분석은 암묵신호분리를 수행하기 위한
방법 중의 하나이며, 신호원들이 모두 독립적이라
는 가정아래 각각의 독립된 신호를 찾아내는 방법

이다. <그림 1>은 독립된 신호들의 결합, 분리 과
정을 나타낸다.

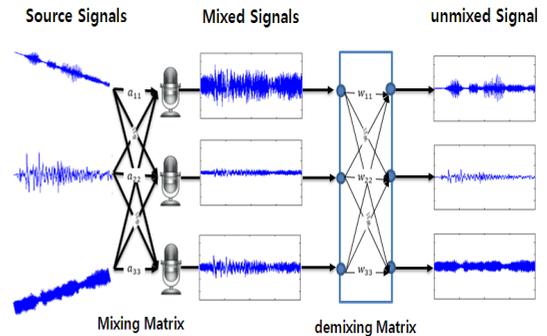


그림 1. 독립성분분석 모델
Fig 1. Model of ICA

N 개의 독립적인 신호들을 s_1, s_2, \dots, s_N 라 하고,
이들이 a_{ij} 에 의해 선형 조합으로 만들어진 N 개의
신호들을 x_1, x_2, \dots, x_N 이라할 때 이들의 관계는 식
(1)과 같이 표현할 수 있다.

$$x_i = \sum_{j=1}^N a_{ij} s_j \quad (1)$$

여기서 x_i 와 s_j 들을 각각 벡터로 나타내고 a_{ij} 을
 i 행, j 열로 갖는 $N \times N$ 정방행렬을 \mathbf{A} 라 하면 식
(1)은 식 (2)과 같이 벡터, 행렬식으로 쓸 수 있다.

$$\mathbf{x} = \mathbf{A}\mathbf{s} \quad (2)$$

여기서 독립성분분석은 원 신호 \mathbf{s} 와 혼합행렬
(Mixing Matrix) \mathbf{A} 에 대한 어떠한 정보도 없는 상
태에서 관찰된 신호 \mathbf{x} 만을 가지고 식 (3)을 만족하
는 \mathbf{A} 의 역행렬인 분리행렬(demixing matrix) \mathbf{W} 을
추정해서 독립된 신호 \mathbf{y} 을 얻는 방법이다[2].

$$\mathbf{y} = \mathbf{W}\mathbf{x} \quad (3)$$

분리행렬 \mathbf{W} 을 추정하는 방법은 신호의 비정규성
(nongaussianity)이 높을수록, 즉 가우시안 분포로부

터 멀어질수록 그 신호는 소스 신호에 가까워지기 때문에 비정규성을 측정하는 방법을 사용한다[2]. 이것은 중심극한정리와 관련이 있으며 이 정리에 의하면 iid(independent and identically distributed)인 확률변수(random variable)들이 무한히 더해진 합은 가우시안 분포를 이룬다는 것이다. 다시 말해 독립 관계에 있는 두 변수를 더하게 되면 그 합은 원래의 변수보다 더 가우시안에 가깝게 되는 것이다. 따라서 비정규성을 측정하는 방법에 따라 독립성분분석은 첨도(kurtosis) 최대화[5], 상호 정보(mutual information) 최소화[6], 네겐트로피(negentropy) 최소화[7], 엔트로피(entropy) 최대화[3][4]을 이용하는 방법 등으로 나눌 수 있으며, 이 중 본 논문에서는 엔트로피 최대화 방법을 이용하였다.

한 이 후 내용에서 Y, y 는 단일변량 \mathbf{Y}, \mathbf{y} 는 다변량을 나타낸다.

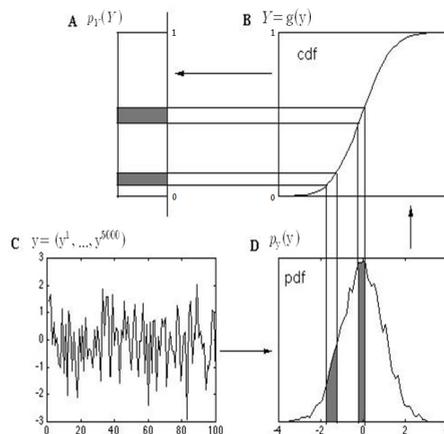


그림 2. 정보최대화를 위한 개념도
Fig 2. Conceptual diagram for information maximization[4]

III. 엔트로피를 이용한 Infomax

엔트로피 최대화방법은 식 (3)의 추정된 신호 \mathbf{y} 가 원 신호 \mathbf{s} 에 대한 누적분포함수를 모사하는 비선형 활성화함수 $\mathbf{Y}=\mathbf{g}(\mathbf{y})$ 을 통과할 때, 출력된 신호 \mathbf{Y} 가 균등 분포(uniform distribution)를 이루게 하여 결합 엔트로피를 최대화함으로써 상호 독립적인 신호를 획득하는 방법이다. <그림 2>는 추정된 신호 $\mathbf{y}=(y^1, \dots, y^{5000})$ (C)의 가우시안 확률밀도 함수 $p_y(y)$ (D)가 비선형 활성화함수 (B)를 통과함으로써 매핑된 신호 \mathbf{Y} 의 확률밀도 함수 $p_Y(Y)$ 가 균등 분포 (A)가 되는 과정을 보여준다.

정보이론에서의 엔트로피 정의를 이용하면 비선형 활성화함수 $\mathbf{Y}=\mathbf{g}(\mathbf{y})$ 을 통해 변환된 신호 \mathbf{Y} 의 엔트로피는 식 (4)로 표현할 수 있다.

$$H(Y) = -\frac{1}{N} \sum_{t=1}^N \ln p_Y(Y^t) \quad (4)$$

여기서 위첨자 t 는 임의의 시간을 나타내며, 또

<그림 2>에서 보여준 것과 같이 매핑된 신호의 확률밀도함수 $p_Y(Y)$ 는 추정된 신호 \mathbf{y} 의 확률밀도함수 $p_y(y)$ 와 관련된다. 이는 <그림 2>(D)의 음영부분의 x 축 간격을 Δy 라 하고, 그에 해당하는 (A)의 간격을 ΔY 라고 할 때 식 (5)을 얻을 수 있게 한다.

$$p_Y(Y^t) \Delta Y = p_y(y^t) \Delta y \quad (5)$$

식 (5)을 $p_Y(Y)$ 에 관하여 정리하고, $\Delta y \rightarrow 0$ 로 접근하면 식 (5)은 식 (6)으로 나타낼 수 있다.

$$p_Y(Y^t) = \frac{p_y(y^t)}{\left| \frac{dY}{dy} \right|} \quad (6)$$

여기서 분모의 절댓치는, 만약 dY/dy 가 단조감소하면 음수값을 가지므로 단조증가와 단조감소 함수 모두를 고려하기 위한 것이다.

그리고 $\mathbf{Y}=\mathbf{g}(\mathbf{y})$ 에서 활성화함수는 소스 신호형태

에 대한 누적분포함수이므로 $g'(y) = dY/dy$ 로 나타낼 수 있다. 따라서 $g'(y)$ 는 소스 신호의 확률밀도 함수 $p_s(y)$ 이며, 이 결과를 식 (6)에 대입하면, 식 (7)을 얻는다.

$$p_Y(Y^t) = \frac{p_y(y^t)}{p_s(y^t)} \quad (7)$$

식 (7)을 식 (4)에 대입하면, 소스 신호와 추출된 신호의 확률밀도함수의 관점에서 엔트로피에 대한 단일변량 표현 식 (8)을 얻을 수 있으며, 식 (8)을 해결하기 위해서는, 추정된 신호의 확률밀도함수 $p_y(y)$ 에 대한 표현이 필요하다.

$$H(Y) = -\frac{1}{N} \sum_t \ln \frac{p_y(y^t)}{p_s(y^t)} \quad (8)$$

이 표현은 식 (6)의 관계에 대한 추론을 통해 얻을 수 있다. 또한 단일변량에 대한 모델은 하나의 확률변수 이상이 있는 일반적 경우로 확장될 수 있고, 따라서 추정된 신호 $\mathbf{y} = \mathbf{W}\mathbf{x}$ 의 다변량 확률밀도함수 $p_y(\mathbf{y})$ 는 식 (9)과 같다.

$$p_y(\mathbf{y}) = \frac{p_x(\mathbf{x})}{\left| \frac{\partial \mathbf{y}}{\partial \mathbf{x}} \right|} \quad (9)$$

여기서 식 (9)의 분모는 야코비안(Jacobian) J 로 표현될 수 있다. 그리고 야코비안 J 와 분리행렬 \mathbf{W} 의 행렬식은 식 (10)과 같다.

$$J = |\mathbf{J}| = |\mathbf{W}| \quad (10)$$

그러므로 추정된 신호의 확률밀도함수 $p_y(\mathbf{y})$ 는 식 (11)로 나타낼 수 있다.

$$p_y(\mathbf{y}) = \frac{p_x(\mathbf{x})}{|\mathbf{W}|} \quad (11)$$

식 (11)의 추정된 신호의 확률밀도함수에 대한 표현을 식 (8)의 변환된 신호 Y 에 대한 엔트로피

의 표현에 대입하고, 이것을 다변량 표현으로 나타내면 식 (12)을 얻는다.

$$H(\mathbf{Y}) = -\frac{1}{N} \sum_{t=1}^N \ln \left(\frac{p_x(\mathbf{x}^t)}{|\mathbf{W}| p_s(\mathbf{y}^t)} \right) \quad (12)$$

로그의 특성과 합에 대한 연산자를 분배하면 식 (12)은 식 (13)으로 나타낼 수 있다.

$$H(\mathbf{Y}) = -\frac{1}{N} \sum_{t=1}^N \ln p_x(\mathbf{x}^t) + \frac{1}{N} \sum_{t=1}^N \ln p_s(\mathbf{y}^t) + \ln |\mathbf{W}| \quad (13)$$

식 (13)의 첫 번째 항은 입력 신호 \mathbf{x} 의 엔트로피 $H(\mathbf{X})$ 이다. 그러나 엔트로피 $H(\mathbf{Y})$ 을 최대화하는 분리 행렬 \mathbf{W} 는 엔트로피 $H(\mathbf{X})$ 에 영향을 받지 않기 때문에, $H(\mathbf{X})$ 는 식 (13)으로부터 무시될 수 있다. 따라서 식 (13)은 식 (14)과 같이 나타낼 수 있다.

$$h(\mathbf{Y}) = \frac{1}{N} \sum_{t=1}^N \ln p_s(\mathbf{y}^t) + \ln |\mathbf{W}| \quad (14)$$

식 (14)은 단일 변량의 합으로 식 (15)과 같이 수정될 수 있다.

$$h(\mathbf{Y}) = \frac{1}{N} \sum_{i=1}^M \sum_{t=1}^N \ln p_s(y_i^t) + \ln |\mathbf{W}| \quad (15)$$

식 (15)을 최대화하는 분리행렬 \mathbf{W} 는 \mathbf{Y} 의 엔트로피를 최대화한다. 따라서 \mathbf{Y} 의 행들이 독립이라는 것을 암시하고, 이때 \mathbf{y} 의 행들 또한 독립이다. 그리고 그것은 \mathbf{W} 가 소스 신호를 분리하는 행렬이라는 것을 의미한다. 식 (15)은 Infomax 방법에 사용된 기본식이다.

IV. Infomax 학습방법

현재 엔트로피를 위한 표현이 식 (15)과 같이 유

도되었기 때문에 변환된 신호 \mathbf{Y} 의 엔트로피를 구할 수 있다. Infomax의 목적은 \mathbf{Y} 의 엔트로피를 최대화하는 분리행렬 \mathbf{W} 을 찾는 것이거나, 또는 동일하게 $h(\mathbf{Y})$ 을 최대화하는 것이다. 따라서 분리행렬 \mathbf{W} 을 최적화하기 위해 비교사 학습방법인 Gradient Ascent 알고리즘을 사용한다.

Gradient Ascent 알고리즘은 엔트로피의 기울기 ∇h 을 위한 표현을 요구하며, 기울기는 엔트로피 $h(\mathbf{Y})$ 을 분리행렬 \mathbf{W} 로 편미분함으로써 구할 수 있다. 그러나 먼저 편미분을 수행하기 전 계산의 단순화를 위해 식 (15)에서 시간샘플의 합 연산을 기대치 연산으로 수정하고, 분리행렬 \mathbf{W} 의 단일성분에 대한 계산을 먼저 수행한 다음 모든 성분으로 확장하도록 한다. 따라서 엔트로피의 기울기에 대한 표현은 식 (16)과 같이 나타낼 수 있다.

$$\frac{\partial h}{\partial W_{ij}} = E \left\{ \sum_{i=1}^M \frac{\partial \ln g'(y_i)}{\partial W_{ij}} \right\} + \frac{\partial \ln |\mathbf{W}|}{\partial W_{ij}} \quad (16)$$

식 (16)은 두 개의 항으로 구성되며, 첫 번째 항의 편미분은 체인룰(Chain Rule)을 이용하여 식 (17)과 같이 계산될 수 있다.

$$\frac{\partial \ln g'(y_i)}{\partial W_{ij}} = \frac{g''(y_i)}{g'(y_i)} x_j \quad (17)$$

여기서 식 (17)의 $g''(y_i)/g'(y_i)$ 는 표기의 편의성을 위해 식 (18)로 정의한다.

$$\psi(y_i) = \frac{g''(y_i)}{g'(y_i)} \quad (18)$$

다음으로, 두 번째 항의 편미분 결과는 식 (19)과 같다.

$$\frac{\partial \ln |\mathbf{W}|}{\partial W_{ij}} = [\mathbf{W}^{-T}]_{ij} \quad (19)$$

편미분의 결과를 식 (16)에 대입한 엔트로피의 기울기 ∇h 는 식 (20)과 같다.

$$\frac{\partial h}{\partial W_{ij}} = E \left\{ \sum_{i=1}^M \psi(y_i) x_j \right\} + [\mathbf{W}^{-T}]_{ij} \quad (20)$$

식 (20)은 분리행렬 \mathbf{W} 의 단일성분에 대한 계산이다. 그러므로 이것을 모든 성분으로 확장하면, 엔트로피의 기울기 ∇h 에 대한 표현은 식 (21)과 같이 나타낼 수 있다.

$$\nabla h = \mathbf{W}^{-T} + E\{\psi(\mathbf{y})\mathbf{x}^T\} \quad (21)$$

신호가 에르고딕 신호라고 가정하면 결과는 식 (22)과 같다.

$$\nabla h = \mathbf{W}^{-T} + \frac{1}{N} \sum_{t=1}^N \psi(\mathbf{y}^t) [\mathbf{x}^t]^T \quad (22)$$

다음은 엔트로피를 최대화하기 위해 분리행렬 \mathbf{W} 을 최적화하는 비교사 학습규칙이 필요하다. 이것은 식 (23)과 같은 Gradient Ascent 학습 알고리즘을 사용한다.

$$\mathbf{W}_{\text{new}} = \mathbf{W}_{\text{old}} + \eta \nabla h \quad (23)$$

여기서 η 는 학습 상수이며, ∇h 가 지역 최대값에 도달할 때까지 반복적으로 수행된다.

식 (22)의 ∇h 을 식 (23)에 대입하면 식 (24)과 같이 엔트로피를 최대화하기 위한 분리행렬 \mathbf{W} 을 최적화하는 표현을 얻을 수 있다.

$$\mathbf{W}_{\text{new}} = \mathbf{W}_{\text{old}} + \eta \left(\mathbf{W}_{\text{old}}^{-T} + \frac{1}{N} \sum_{t=1}^N \psi(\mathbf{y}^t) [\mathbf{x}^t]^T \right) \quad (24)$$

식 (24)에서 $\psi(\mathbf{y}^t)$ 는 활성화함수 $g(y)$ 와 관련되며, 활성화함수가 소스 신호의 누적분포함수 형태가 되어야만 출력된 신호 \mathbf{Y} 가 균등분포를 이루게 되므로, 결합엔트로피를 최대화할 수 있다. 음성신호의 경우에는 확률분포 형태가 super-gaussian인 특성을 이용하여 hyperbolic tangent 함수를 활성화함수로 많이 사용한다. 따라서 $g''(y_i)/g'(y_i)$ 는 식 (25)과 같다.

$$\Psi(\mathbf{y}) = \frac{g''(\mathbf{y})}{g'(\mathbf{y})} = -2 \tanh(\mathbf{y}) \quad (25)$$

식 (25)을 식 (24)에 대입하면 분리행렬 \mathbf{W} 을 최적화하는 표현은 결국 식 (26)으로 나타낼 수 있다.

$$\mathbf{W}_{new} = \mathbf{W}_{old} + \eta \left(\mathbf{W}_{old}^T + \frac{1}{N} \sum_{t=1}^N -2 \tanh(\mathbf{y}^t) [\mathbf{x}^t]^T \right) \quad (26)$$

V. 개선된 학습방법

본 논문은 Infomax방법에서 사용하는 학습 알고리즘(Gradient Ascent)의 빠른 수렴과 결과의 정확성을 향상시키기 위한 두 가지 방법을 제안한다.

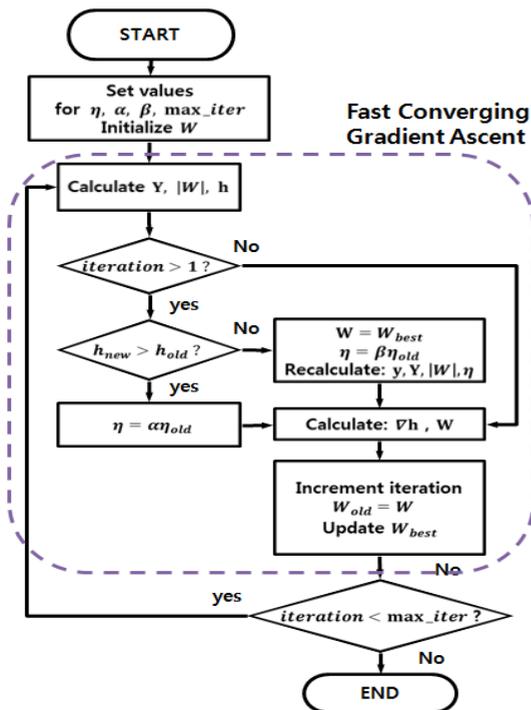


그림 3. 고속수렴을 위한 방법
Fig 3. Fast Converging Gradient Ascent

제안하는 방법(1) : <그림 3>의 고속수렴을 위한 방법의 흐름도와 같이 엔트로피 $h(\mathbf{Y})$ 가 감소하지 않고 계속적으로 증가하면 증가하는 방향으로 일정한 학습상수를 취하는 것이 아니라 학습상수 η 의 크기를 조금씩 증가시키는 방법이다. 만약 엔트로피 $h(\mathbf{Y})$ 가 감소하면, 알고리즘은 최대값을 놓쳤다고 가정하고 이전에 탐색한 \mathbf{W} 중 엔트로피가 최대값을 갖는 \mathbf{W}_{best} 의 위치로 귀환하여 작은 학습상수에서부터 다시 점차적으로 증가하는 학습상수를 취하는 것이다.

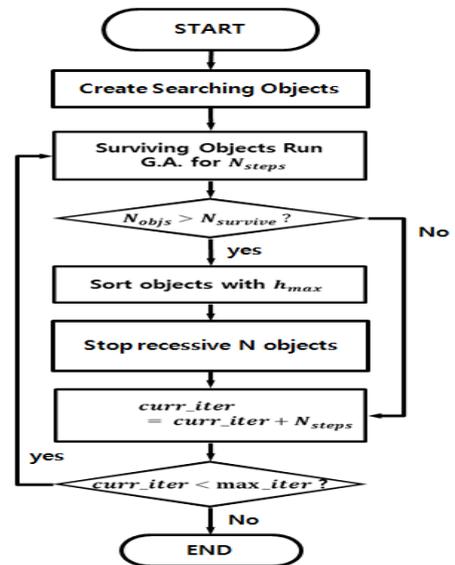


그림 4. 다중 탐색 객체를 이용한 방법
Fig 4. Multiple Objects Searching Gradient Ascent

제안하는 방법(2) : Infomax방법은 엔트로피를 최대화함으로써 추출된 신호를 찾기 때문에 전역 최대값을 찾아야 한다. 그러나 Gradient Ascent 알고리즘은 \mathbf{W} 에 가장 근접한 지역 최대값을 찾는 방법이다. 또한 이것은 4개 이상의 혼합된 신호 분리에서는 전역 최대값을 찾을 확률이 현저하게 줄어든다. 따라서 전역 최대값을 알아내는 더 높은 확률을 얻기 위한 방법으로 본 연구에서는 랜덤한

서로 다른 시작 값으로 구성된 분리행렬 \mathbf{W}^k , ($k=1, \dots, N$)을 탐색객체로 정의하고 병렬적으로 최대 엔트로피를 갖는 최적의 \mathbf{W}_{opt} 을 찾는 방법이다. 뿐만 아니라 객체의 수와 반복 횟수에 따른 연산량과 시간 비용을 줄이기 위해 일정주기마다 엔트로피의 값을 평가하여 낮은 엔트로피를 탐색한 객체 \mathbf{W}^k 에 대해서는 탐색을 중지 시키는 MOSFC-Gradient Ascent(Multiple Objects Searching and Fast Converging Gradient Ascent) 방법을 제안한다. <그림 4>는 다중 탐색 객체를 이용한 방법이며 <그림 3>의 Fast Converging Gradient Ascent부분을 <그림 4>의 Surviving Objects Run G. A. 부분에 적용하면 다중 탐색객체와 고속수렴 모두를 적용한 Gradient Ascent방법을 사용할 수 있다.

VI. 실험 및 성능평가

<그림 5>는 기존 Infomax알고리즘의 엔트로피 수렴 성능과 제안방법 1의 고속수렴 방법이 적용된 엔트로피의 수렴 곡선을 보여준다.

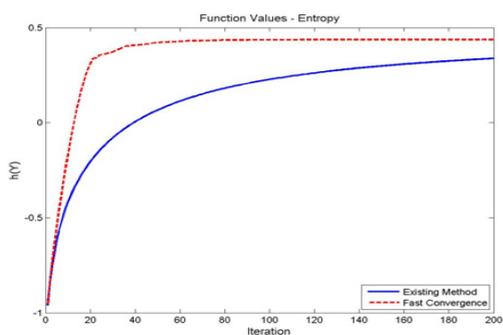


그림 5. 고속 수렴을 이용한 방법
Fig 5. Fast Converging Gradient Ascent (M=2)

최대 반복횟수에 도달할 때 까지 천천히 수렴한다. 그러나 제안된 방법은 반복횟수가 60회 정도에서 수렴에 진입하며, 동일한 최대 반복횟수에서 기존 알고리즘보다 더 높은 $h(\mathbf{Y})$ 값을 얻을 수 있음을 엔트로피의 수렴곡선을 통해 확인할 수 있다.

<그림 6>는 반복횟수 증가에 따른 계산비용과 음원분리 결과의 정확성을 위해 제안된 MOSFC-Gradient Ascent알고리즘을 5개의 혼합된 음성신호에 적용한 엔트로피의 수렴곡선이다. 실험을 위한 설정값은 <표 1>과 같이 32개의 탐색객체를 사용하였으며, 기존 방법에 대해서는 분리에 실패했으나 제안된 방법을 이용한 실험에서는 5개의 소스 신호 모두를 효과적으로 분리함을 확인할 수 있었다.

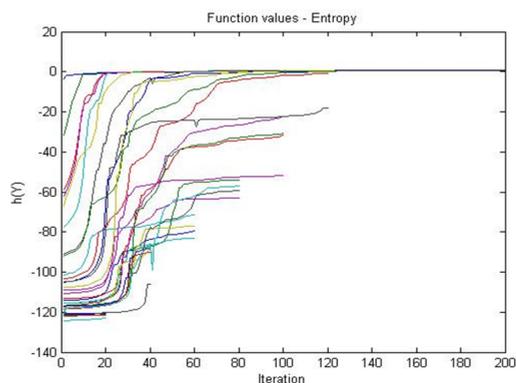


그림 6. 다중 탐색 객체와 고속수렴을 이용한 방법
Fig 6. Multiple Objects Searching and Fast Converging Gradient Ascent (M=5)

표 1. 탐색객체에 대한 설정값
Table 1. Configuration Values for Searching Objects

탐색객체 평가 주기 : N_{steps}	20
탐색객체 수 : N_{objs}	32
탈락하는 탐색객체 수 : N_{stop}	4
최종 생존 탐색객체 수 : $N_{survive}$	8

기존 방법은 $h(\mathbf{Y})$ 가 완만한 곡선을 이루면서

VII. 결 론

본 연구는 음원분리를 수행하기 위한 방법으로 기존의 독립성분분석 방법 중 하나인 엔트로피 최대화 방법에 대하여 빠른 수렴과 분리결과의 정확성 확보를 위해 기존 학습 알고리즘을 개선한 MOSFC-Gradient Ascent 방법을 제안하고 실험을 통하여 확인하였다. 제안된 방법으로 음원분리를 수행할 경우 혼합된 음원의 수가 증가하더라도 수렴속도의 저하 없이 높은 분리 성능을 유지하는 것을 확인할 수 있었다.

참고문헌

- [1] J. M. Valin, S. Yamamoto, J. Rouat, F. Michaud, K. Nakadai, H. G. Okuno, "Robust Recognition of Simultaneous Speech by a Mobile Robot," Robotics, IEEE Transactions on, Vol. 23, Issue 4, pp.742-752, 2007
- [2] A. Hyvärinen and E. Oja, "Independent Component Analysis : Algorithms and Applications," Neural Networks, Vol. 13, No.4-5, pp.411-430, 2000.
- [3] A. J. Bell and T. J. Sejnowski, "An information-maximization approach to blind separation and blind deconvolution," Neural Computation, vol.7, no. 6, pp.1129-1159, 1995.
- [4] J. V. Stone, *Independent Component Analysis : A Tutorial Introduction*, Massachusetts Institute of Technology, Massachusetts, 2004.
- [5] J. P. LeBlanc and P. L. De Leon, "Speech Separation by Kurtosis Maximization," Proc. ICASSP, Vol. 2, pp. 1029-1032, 1998.
- [6] S. Amari, A. Cichocki and H. H. Yang, "A New Learning Algorithm for Blind Signal Separation," Advances in Neural Information Processing Systems, MIT Press, pp. 757-763. 1996.
- [7] A. Hyvärinen, "Fast and Robust Fixed-Point Algorithms for Independent Component Analysis," IEEE Transactions on Neural Networks, vol. 10, no. 3, pp. 626-634, May, 1999.

감사의 글

본 논문은 동아대학교 학술연구비 지원에 의하여 연구되었음.

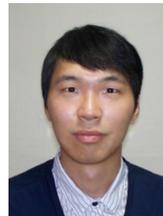
저자소개



김영섭(Young-Sub Kim)

2005년 동명정보대학교 컴퓨터공학과 (공학사)
2007년 동아대학교 대학원 전자공학과 (공학석사)

2009년~현재 동아대학교 대학원 전자공학과(박사과정)
※ 관심분야 : 음성/영상신호처리, 패턴인식



이영주(Young-Joo Lee)

2007년 동아대학교 전기전자컴퓨터 공학부 전자전공(공학사)
2010년 동아대학교 대학원 전자공학과 (공학석사)

2010년~현재 동아대학교 대학원 전자공학과(박사과정)
※ 관심분야 : 음성/영상신호처리, 임베디드 시스템



이광석(Gwang-Seok Lee)

1983년 동아대학교 전자공학과(공학사)
1985년 동아대학교 대학원 전자공학과 (공학석사)
1992년 동아대학교 대학원 전자공학과 (공학박사)

1995년~현재 국립경남과학기술대학교 전자공학과 교수
※ 관심분야 : 음성신호처리, Biometrics, 지능화 기술



허강인(Kang-In Hur)

1989년~1998년 일본 쓰쿠바대학 객원연구원
1992년~1993년 일본 도요하시대학 객원연구원

1984년~현재 동아대학교 전자공학과 교수
※ 관심분야 : 음성/영상신호처리, 패턴인식