
차세대 멀티미디어 통신을 위한 후각정보 측정데이터의 독립성분분석

권기현* · 최형진** · 황성호* · 주상렬***

Independent Component Analysis Applied on Odor Sensing Measurement Data for
Multimedia Communication

Kihyeon Kwon* · Hyungjin Choi** · Sung-Ho Hwang* · Sang-Yeol Joo***

이 논문은 2007년도 강원대학교 학술연구비를 지원받았음

요약

후각 정보의 실감성을 높일 수 있는 멀티미디어 통신 시스템에서 후각정보 전달을 위한 오더(odor) 센싱 시스템 및 관련 신호 처리 기술 개발은 차세대 멀티미디어 산업을 위한 핵심 과제로 떠오르고 있다. 오더 센싱 시스템의 성능 측정에 전통적으로 많이 사용된 방법은 주성분분석(PCA)이다. PCA는 분산에 기반한 도구로서 많은 경우 잘 동작한다. 그러나 오더 센싱 측정 데이터에 대해서는 의미 있는 값을 표시하는 것에 한계가 있다. 이 논문은 독립성분분석(ICA)을 사용하여 오더 센싱 데이터를 분석하는 방법을 설명한다. PCA와 ICA의 차이를 실질적인 측정데이터를 사용하여 비교하도록 한다. 실험을 통해 ICA가 개선된 변별력으로 센서의 경향 분석, 차원축소, 보다 적합한 데이터 표현 등에 있어 PCA보다 나은 결과를 도출함을 보인다.

ABSTRACT

Odor sensing system that is electronic nose device and its signal processing technique has potential to become a critical service for the people who require tangibility of sense of smell in the multimedia communication. PCA(Principal Component Analysis) have been used for dimensionality reduction and visualization of multivariate measurement data. PCA is good for estimating importance value by variance of data but, have some limitation for getting meaningful representation from odor sensing system. This paper explain about how to analyze the data of odor sensing system by ICA(Independent Component Analysis). We show that ICA can give better result like sensor drift analysis, dimensionality reduction and data representation by improved discrimination.

키워드

Multimedia Communication, Odor Sensing System, Independent Component Analysis, Gas Sensor Array

* 강원대학교 공학대학 전자정보통신공학부
** 강원대학교 IT대학 컴퓨터과학과(교신저자)
*** 강원대학교 자연과학대학 정보통계학과

접수일자 2009. 05. 21
심사완료일자 2009. 06. 23

I. 서 론

디지털 비디오/오디오, 컴퓨터 애니메이션, 그래픽 등의 다양한 정보를 자연스럽게 통합할 수 있는 기술의 발전은 통신, 방송, 가전 분야에서 사용자의 몰입감을 증대시키려는 노력으로 이어져 왔다. 특히, 후각 정보의 실감성을 높일 수 있는 가스 센서어레이 시스템 즉, 전자코(Electronic nose) 장치 및 관련 신호 처리 기술 개발은 차세대 멀티미디어 산업을 위한 핵심 과제로 떠오르고 있다.

가스 센서 어레이 시스템의 개발과 함께 주성분분석(PCA)은 측정 데이터를 분석하는 표준 다변량 통계도구로 사용되어 왔다[1]. PCA(Principal Component Analysis)의 주목적은 패턴인식을 위한 전처리, 차원축소, 다변량 데이터의 차원을 축소하는 것이다. PCA가 많은 응용에 적합하기는 하지만, 어떤 경우에는 측정도구의 내재한 정보까지 완전히 얻어내지는 못한다. 경우에 따라서는 측정 실험에 있어서 가스센서어레이 시스템이 다양한 측정 샘플들에서 효과적인 분별력을 제공하지 못하는 경우도 있다. 이러한 문제점은 단지 측정도구 하드웨어 성질에만 관계된 것은 아니다. 예로, 가스 센서의 낮은 선택력(selectivity)과 감도(sensitivity) 또는 센서 경향 등도 고려해야 한다. 독립성분분석(ICA)은 다변량 통계도구로, 지난 수년간 뉴럴네트워크, 신호처리, BSS(Blind Source Separation) 같은 연구 분야에서 상당한 관심을 불러왔다[2]. 독립성분이나 정보소스를 추출하기 위해 사용되는 방법에는 알려지지 않은 소스가 선형적으로 혼합된 형태의 측정된 데이터가 주어지게 된다.

ICA(Independent Component Analysis)의 주요 목표는 데이터의 확률밀도로부터 고차통계를 사용하여 가능한 독립적인 원 신호를 만드는 동등한 체계를 찾는 것이다. 최근에 ICA의 다양한 성공적인 응용이 생의학신호처리, 이미지압축, 금융데이터분석 등에서 나타나고 있다.

이 논문에서는 ICA가 PCA와 비교하여 볼 때, 알코올 측정 데이터에 대해 개선된 차원축소 방법을 제공하고 성분(component)의 의미 있는 해석이 가능함을 제시한다.

PCA와 ICA 모두 선형변환을 제공한다는 점에서는 유사하나, 각 방법이 변환을 수행할 때 사용하는 정보는 서로 다르다. ICA를 이해하기 위해 2장에서 ICA에 대해 설명한다. 가스 센서 어레이 측정 데이터에 ICA를 사용

할 때 생기는 실질적인 어려움 문제들을 해결하는 전략을 3장에서 설명한다. 이어서, 상용 가스센서어레이 시스템에서 취득한 알코올 데이터에 대해 ICA와 PCA로 분석하는 내용을 4장에서 다루고 결론을 맺는다.

II. ICA 및 PCA

이 절에서는 ICA의 기본 개념을 살펴보도록 한다[3].

2.1. ICA 정의 및 PCA

노이즈프리 ICA모델은 Comon [4]와 Hyvärinen & Oja [5]의 논문에 기반하고 있다.

통계적으로 독립적인 소스($s_1, s_2, \dots, s_m, \dots, s_M$)가 선형시스템을 통해 혼합되어 관찰된 것이 N개($x_1, x_2, \dots, x_n, \dots, x_N$) 있다고 가정하면 식(1)과 같이 표현 할 수 있다.

$$x_n = a_{n1}s_1 + \dots + a_{nm}s_m + \dots + a_{nM}s_M \quad (1)$$

$$n = 1, 2, \dots, N$$

혼합치 x_n 과 소스 s_m 은 랜덤변수라는 가정 하에 혼합된 관찰치는 계수 A_{nm} 에 의해 특성이 부여된다. 행렬을 사용하면 편한데, $X = [x_1, x_2, \dots, x_N]^T$, $s = [s_1, s_2, \dots, s_M]^T$ 로 표현할 수 있으므로, 식(1)의 선형시스템은 식(2)이 된다.

$$x = As \quad (2)$$

A 는 믹싱체계 A_{nm} 을 가지는 $N \times M$ 스칼라 행렬이다. 이 통계적인 모델을 노이즈프리 ICA모델이라고 한다[6]. A 의 역행렬이 s 에 대한 추정치가 된다. 언믹싱(Unmixing) 행렬 W 는 식(3)과 같다.

$$u = Wx = WAs \approx s \quad (3)$$

u 는 S 의 추정치이고 W 는 A^{-1} 의 추정치이다. 이 행렬들을 사용하여 원본 소스의 값을 구하게 된다.

PCA에서 주성분은 각 주성분의 분산에 따라 정렬되고, 해당 고유값을 통해 계산된다. 이것은 독립성분의 경우 가능하지 않은데, 독립성분의 분산 모두 알 수 없기 때문이다. 실제로, PCA는 ICA의 전처리 단계에서 자주 사용되어 성분의 정렬, 성분의 수를 추정하는데 사용된다.

2.2. ICA 알고리즘

ICA 응용 환경이 다양하기 때문에, 여러 가지 알고리즘이 제안되었다. 가장 고전적이고 잘 알려진 ICA 방법은 뉴럴네트워크, 고차통계, 상호정보최소화에 기반을 두고 있다.

- 1) 정보최대화 알고리즘: Bell과 Sejnowski는 정보이론 프레임워크를 통해 ICA에 접근했다. 1995년에 Bell과 Sejnowski는 적응형 학습알고리즘을 제안했는데, 이는 인공 뉴럴 프로세서를 통해 전달되는 정보의 흐름을 최대화 하는 것에 기반을 두고 있다[7].
- 2) 고정점 알고리즘: 고정점 알고리즘은 그라디언트 디스턴트 방법보다 더 빠르게 처리하도록 수정된 뉴런 방법을 사용하여 독립성분을 추정한다[8]. 고정점 알고리즘은 deflation 방법과 symmetric 방법 두개의 카테고리로 나누어져 있다[9]. deflation 방법은 한번에 하나의 독립성분을 추정한다. 반면, 대칭방법은 가중치갱신을 위한 수정된 규칙을 사용하여 모든 독립성분을 동시에 분리하는 것이 가능하게 하는 방법이다.
- 3) JADE (Joint Approximate Diagonalization of Eigenmatrices): 일반적인 ICA 알고리즘은 독립소스의 분산추정기능을 필요로 한다. 그러나 이전의 두 방법과는 달리 JADE는 데이터 변환의 최적화를 하지 않는다.

III. 가스 센서 어레이 측정데이터

3.1. 가스 데이터에 ICA 적용

PCA의 단순성은 다변량 데이터의 분석도구로 인기가 있는 주된 이유가 되며, 가우시안분포를 따르는 데이터셋에 대해 데이터 프로젝션에 대한 방향을 제공하여 적절한 분해가 가능하게 한다. 그러나 가스센서어레이

데이터는 비가우시안인 경우가 많다. 데이터가 여러 가지 타입의 샘플의 반복되는 측정을 가지고 있고, 각 측정 샘플타입에 대한 클러스터를 형성한다고 가정하자. 한 클러스터 내에서 하나의 측정이 가우시안결합분포를 따를 수는 있을 것이다. 그러나 모든 클러스터를 포함하는 분포에서는 데이터의 다양한 구조 때문에 가우시안 결합분포가 되기는 쉽지 않을 것이다. 그러므로 PCA는 가스센서어레이측정데이터에 대한 적절한 분석도구가 되지 못하는데, 데이터마다 분포가 달라질 것이기 때문이다.

대체로 보면, ICA는 PCA의 확장, 일반화 방법이라고 볼 수 있다. 이유는, PCA가 사용하는 이차정보 대신, ICA는 데이터의 고차정보를 사용하고 있기 때문이다. 따라서 비가우시안 분포 데이터에 대해서는 ICA가 보다 의미 있는 결과를 제공한다고 볼 수 있고 개선된 성능을 보이게 된다.

3.2. 가스센서어레이 데이터 구성

가스센서어레이에서 측정값 매트릭스 d 의 행(rows)은 측정샘플 또는 매트릭스오브젝트, 열(column)은 센서 또는 매트릭스변수를 의미한다.

가스센서어레이가 N센서와 K샘플로 구성되어 있다고 보고, 데이터 매트릭스는 $K \times N$ 차원을 가지게 된다. ICA 적용 전에 PCA를 사용하여 차원을 줄임으로서 d 의 중복정보를 제거하는 것은 좋은 방법이다. 이렇게 함으로써 매트릭스 d 는 새로운 데이터매트릭스 $K \times M$ 차원의 xt 로 변환되어진다. 새 매트릭스는 M주성분에 대한 PCA행렬 값을 가진다. 이후 작업을 위해서 데이터매트릭스 xt 는 전치되어, $M \times K$ 행렬 x 가 된다. 여기에서 행렬 $rows$ 는 주성분을 의미하고 컬럼은 샘플측정을 의미한다. 궁극적으로, 이 매트릭스 x 가 ICA모델 식(2)에 적용된다. 이제, 목표는 언막싱 체계 $W = A^{-1}$ 을 찾고, M 을 추정하기 위해 식(3)의 소스 u 를 찾는 것이다.

3.3. PCA 전처리

PCA를 이용한 전처리에는 매트릭스 d 에 대해 백색화 (whitening) 및 차원축차(dimensionality reduction)를 하게 된다. 데이터매트릭스 x 에 평균이 0인 백색화과정을 통한 컴포넌트는 분산이 모두 같다는 것을 의미하다[7]. 추정을 더 단순화하기 위해 식(2)에서 혼합매트릭스는 정

방이라는 가정이 필요하다. 즉, 독립컴포넌트의 수는 관측되는 신호의 수와 일치한다는 말이다. 이 가정은 때로 완화될 수 있지만, 정방흔합매트릭스의 경우 주성분의 수(row)는 소스의 수와 같다. PCA에서 주성분의 수를 선택하는 것으로 소스의 수와 같다는 것으로 볼 수도 있다. 일반적으로, 분산에 크게 기여하지 못하는 주성분은 제거되어야 한다. 따라서 ICA에서 추출되어야 하는 소스의 수는 차원 축차 후 남은 주성분의 수와 일치하는 것이 바람직하다.

3.4. ICA 모델 검증

PCA 고유치로부터 얻어진 분산은 많은 경우에 주요 소스의 수를 추정하는데 많이 쓰인다. PCA가 주요지침을 제공하지만, 소스의 정확한 수는 여전히 결정되기 어렵다. ICA가 분산 구조를 사용하는 것이 아니기 때문이다. 독립 소스의 실제 수는 주성분의 수와 다를 수 있다. 때문에 ICA 모델은 검증(validation) 작업이 필요하게 된다.

모델검증(model validation)은 모든 유형의 다변량 데이터 분석에서 필수작업이고, PCA의 경우 좋은 방법이 많이 있지만, 예로, 교차검증(cross-validation) [10]. 그러나 ICA의 경우 추출되어지는 독립성분의 분산을 모른다는 것이고, 두 번째 이유는 ICA에서 추출되는 성분의 순서가 PCA처럼 알지 못한다는 것이다. 즉, 입력 소스의 수를 정확히 모를 때, 안정적인 ICA모델의 독립성분의 수를 결정하는 것이 쉬운 문제가 아니다.

회귀모델(regression models)에서 신뢰도는 각 컴포넌트에서 유의 변수의 수에 따라 달라진다고 한다[11], [12]. 교차검증에 관련된 절차로 modified jack-knifing [11]이 다변량모델의 불확실성을 추정하는데 적용될 수 있다. 이 방법이 ICA에서 추출된 컴포넌트에서 중요 컴포넌트나 변수의 탐색을 잘 수행하는 것으로 알려져 있다[13].

각 추정된 컴포넌트의 불확실성은 식(4)에 의해 구해 진다[14].

$$\sigma^2(u_m) = \left(\sum_{n=1}^N (u_m - u_{m(-n)})^2 \right) \left(\frac{N-1}{N} \right) \quad (4)$$

M (소스의 수; 독립성분의 수) = 1, 2, ..., M 이고 $n = 1, 2, \dots, N$ (식(1)의 관측치의 수)이다.

$\sigma^2(u_m)$ 은 추정된 불확실성 또는 컴포넌트 u_m 의 각 변수의 분산이다. u_m 은 모든 N 관측치에 대한 컴포넌트 m 의 추정치이다. $u_{m(-n)}$ 은 n 을 뺀 모든 혼합에 대한 컴포넌트 m 추정치이다.

u_m 과 $\sigma^2(u_m)$ 은 추정된 각 컴포넌트의 모든 변수 값에 대한 t-검증의 유의수준에 따라 달라지며, 각 변수의 신뢰구간에서 사용되기도 한다. 즉, 많은 수의 중요하지 않은 변수는 ICA 추정에서 빠지게 된다.

3.5. 독립성분 정렬

독립성분에서 컴포넌트의 추출 순서는 중요하지 않다. 이유는, 다른 컴포넌트 보다 더 중요한 컴포넌트라고 보기 어렵기 때문이다. 그러나 식(4)의 검증 스킴을 위해 컴포넌트가 정렬되는 것이 필요하다.

ICA에서 추출된 컴포넌트를 PCA에서 계산된 컴포넌트와의 상관관계를 가지고 정렬한다. 이 방법으로 정렬하면, ICA와 PCA 방법은 충분히 비교될 수 있다.

3.6. 알고리즘 선택

응용에 따라 적절한 ICA 알고리즘을 선택하는 것이 중요하다.

Infomax 방법은 음성에 주로 사용되며 소스가 sub-gaussian 또는 super-gaussian 분포와 거리가 멀 때 성능이 크게 저하된다[15]. FastICA 방법은 매우 유연성 있고 가장 정확도가 높은 방법이다. 사용자가 데이터셋에 따라 득점 함수를 선택(파라미터 조정 가능)할 수 있고, 속도가 빠르다.

랜덤 초기 조건에 따라서, 같은 문제에 여러 번 적용 했을 때도 추출되는 독립성분의 순서가 달라진다. 즉, 정렬이 필요하다. 대부분의 분포에서 잘 작동하지만, 소스 분포가 가우시안에 매우 가까운 경우 수렴하지 않는 문제가 발생하기도 한다. JADE는 파라메타 조정을 허용하지 않는다. 항상 수렴한다. 추출순서는 항상 동일하다. 에너지에 따른 컴포넌트 정렬을 내재하고 있기 때문이다. 그러나 JADE는 계산이 많으므로 데이터 차원이 작은 경우에 국한된다.

본 논문에서는 FastICA 방법을 사용하여 가스 센서 어레이 측정데이터에서 개선된 성능을 보이도록 한다.

IV. ICA 사용 가스센서어레이 데이터 분석

사용한 가스센서어레이 데이터는 12개 센서를 사용하여 4가지 알코올 용액에 대해 각각 400회식 측정한 것이다[16]. FastICA 알고리즘으로 디플레이션(deflation) 방법을 사용하고 득점함수로는 $g(u) = u^3$ 을 사용하였다.

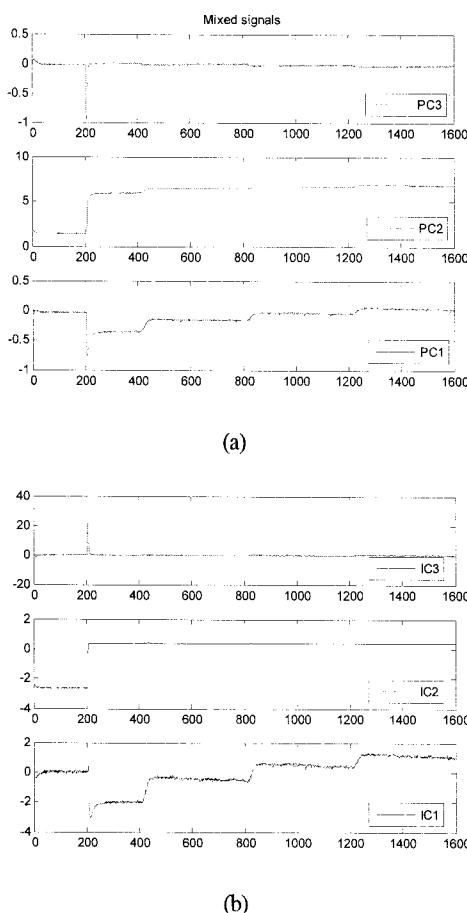


그림 1. 주성분과 독립성분 비교

- (a) 주성분 1, 2, 3 (x축: 측정샘플수, y축: 측정값)
- (b) 독립성분 1, 2, 3 (x축: 측정샘플수, y축: 측정값)

Fig. 1 Comparison of PC(Principal Component) and IC(Independent Component)

- (a) PC 1, 2, 3 (x axis: sample #, y axis: value)
- (b) IC 1, 2, 3 (x axis: sample #, y axis: value)

4.1. PCA & ICA 적용

1) PCA를 통한 차원축소

12개 센서에서 측정한 데이터에서 PCA를 통해 구한 제 1, 2, 3 주성분의 고유치는 99.33%, 0.597%, 0.07%로 전체 분산의 99.6%가 된다. 2개의 주성분만으로도 분산을 표현할 수 있으나 ICA와의 비교를 위해 3번째 주성분 까지 사용한다.

2) PCA & ICA의 라인플롯

PCA를 통해 추출된 주성분과 1, 2, 3과 ICA를 통해 구한 독립성분 1, 2, 3을 플롯으로 나타내었다. PCA 주성분 1과 ICA 독립성분 1의 경우 패턴이 일치하나, PCA 주성분 2, 3과 ICA 독립성분 2, 3을 비교해보면 주성분이 독립성분에 비해 안정되지 않은 결과를 보여주고 있다. 독립성분 2, 3을 살펴보면 센서 드리프트가 거의 없거나 있어도 매우 작은 것을 알 수 있다. 이것은 센서 드리프트가 독립성분 2, 3에서 거의 완전히 잡혔다는 것을 의미한다.

3) PCA & ICA의 PDF

PCA는 가우시안 특성에 기인하고 ICA는 비가우시안 특성에 기인한다. 그림 2-(b)의 좌측 PDF를 살펴보면, PCA에 비해 가우시안 분포를 덜 따른다는 것을 알 수 있다. 이것은 PCA는 초기에 데이터가 가우시안이라고 가정했기 때문이다. 이것으로, PCA는 특정 데이터 세트에서 진정한 소스 분리를 반영할 수는 없다는 것을 알 수 있다.

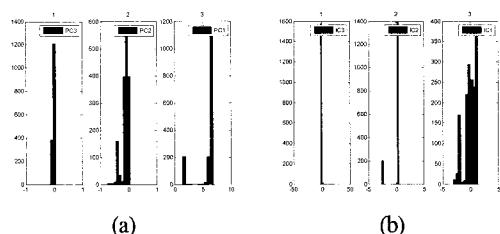


그림 2. 주성분과 독립성분 pdf 비교

- (a) 그림 1-(a) pdf (b) 그림 1-(b) pdf
- (x axis: value, y axis: sample #)

Fig. 2 Comparison of PDF of PC and IC

- (a) Fig. 1-(a) pdf (b) Fig. 1-(b) pdf

4) PCA & ICA의 플롯

그림 1의 PCA와 ICA의 성분을 플롯으로 나타낸 것이다. 십자(+)로 표시한 부분은 4가지 측정 용액의 분산 중심에 십자(+)와 원을 그려 나타낸 것이다.

그림 3의 (a)와 (b)를 보면 제 1 성분의 값이 다른 성분에 비해 과도하게 커서 다른 성분에 대한 영역이 잘 나타나지 못했으나 플롯을 확대해보면 독립성분의 경우 클러스터링이 더 잘 되어 있는 것을 알 수 있다. 제 1 성분에 만 분산의 중심과 원이 표시되었다. 그림 3의 (c)와 (d), (e)와 (f)의 경우에는 독립성분의 경우 클러스터링이 더 잘 되어 있는 것을 알 수 있다.

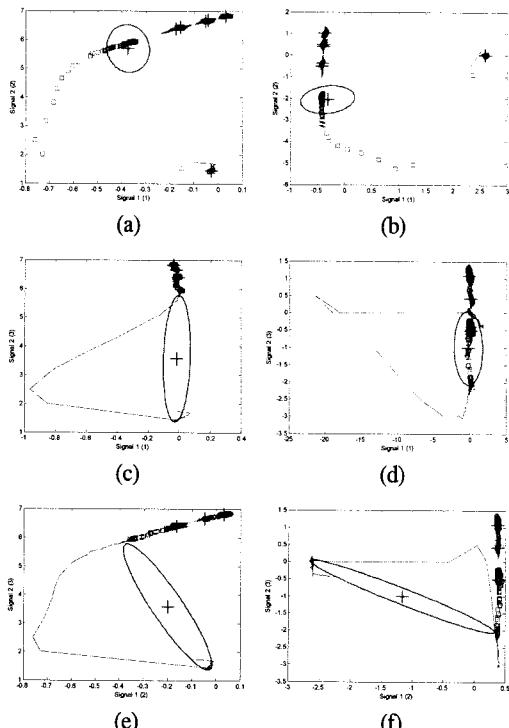


그림 3. 주성분과 독립성분 플롯

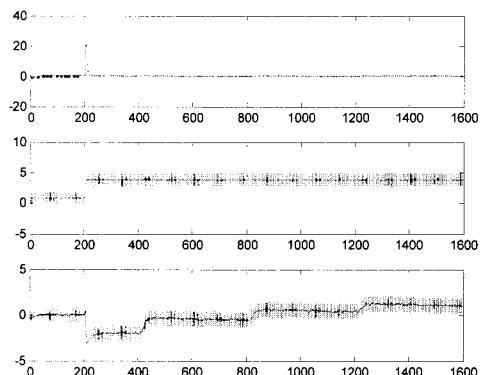
- (a) 그림 1-(a)의 주성분 1, 2 플롯 (b) 그림 1-(b)의 독립성분 1, 2 플롯 (c) PC 1, 3 플롯 (d) IC 1, 3 플롯 (e) PC 2, 3 플롯 (f) IC 2, 3 플롯

Fig. 3 The Plot of PC and IC

- (a) Plot of PC 1, 2 in Fig. 1-(a) (b) Plot of IC 1, 2 in Fig. 1-(b) (c) Plot of PC 1, 3 (d) Plot of IC 1, 3 (e) Plot of PC 2, 3 (f) Plot of IC 2, 3

4.2. 독립성분 검증

ICA 추출 컴포넌트는 식(4)에서 설명한 검증 방법에 의해 검증될 수 있다. 그림 4는 추출된 독립성분에 식(4)의 방법을 사용하여 구한 각 변수의 표준편차를 2배하여 그린 것이다. 즉, 전체 알코올 측정 데이터를 사용해서 구한 독립성분에서 매 단계(12단계) 센서를 하나씩 뺀 데이터에서 구한 독립성분간의 표준편차를 구한 것이다. $u_m(-n)$ 에 대한 추정된 각 컴포넌트의 모든 변수 값에 대해 t-검증(유의수준 0.05%)을 통해 구한 컴포넌트의 신뢰도는 독립성분 1, 2에 대해서는 100%(1600)이며 독립성분 3의 경우 98.5%(1576)로 매우 우수한 것을 알 수 있었다. 이는 알코올의 특성에서 기인한 것으로 판단된다.



(x축: 측정샘플수, y축: 측정값)

그림 4. 독립성분의 검증 플롯

(x axis: sample #, y axis: value)

Fig. 4 Cross Validation of Independent Component

V. 결론 및 향후연구

본 논문에서는 ICA와 PCA를 이용한 가스센서어레이 측정데이터 분석을 수행하였다. 측정한 알코올 측정데이터는 PCA의 군집도에 기인한다는 것을 알 수 있었다. 그리고 ICA가 PCA에 비해 센서드리프트가 적음을 알 수 있었다. 알코올 측정 데이터에서 ICA가 PCA에 비해 개선된 결과를 보여줬다.

데이터가 비가우시안 특성을 보이는 경우 PCA의 능력은 한계점이 있으며 따라서, ICA로 추가적인 처리를

하는 것이 필요해진다. 여기에서, PCA는 ICA 전에 데이터에 대한 백색화 및 차원축소를 위한 전처리 방법으로 사용되게 된다.

ICA 분야의 항후 연구로는 보다 진보된 전처리 작업을 통해 ICA를 가스센서 배열측정데이터에 사용하는데 보다 쉽게 적용할 수 있을 것이다.

감사의 글

본 연구는 2007년도 강원대학교 학술연구비의 지원에 의하여 이루어진 연구로서, 관계부처에 감사드립니다.

참고문헌

- [1] M. Kendall, Multivariate Analysis. London, U.K.: Charles Griffin, 1975.
- [2] A. Hyvärinen and E. Oja, "Survey on independent component analysis," Neural Comput. Surveys, vol. 2, pp. 94 - 128, 1999.
- [3] A. Hyvärinen, J. Karhunen, and E. Oja, Independent Component Analysis. New York: Wiley, 2001.
- [4] P. Comon, "Independent component analysis - A new concept?", Signal Process., vol. 36, pp. 287 - 314, 1994.
- [5] A. Hyvärinen and E. Oja, "Independent component analysis: Algorithms and applications," Neural Networks, vol. 13, no. 4 - 5, pp. 411 - 430, 2000.
- [6] C. Jutten and J. Herault, "Blind separation of sources, Part I: An adaptive algorithm based on neuromimetic architecture," Signal Process., vol. 24, pp. 1 - 10, 1991.
- [7] A. J. Bell and T. J. Sejnowski, "An information-maximization approach to blind separation and blind deconvolution," Neural Comput., vol. 7, pp. 1129 - 1159, 1995.
- [8] T. Cover and J. Thomas, Elements of Information Theory. New York: Wiley, 1991, vol. 1.
- [9] A. Hyvärinen, "Fast and robust fixed-point algorithms for independent component analysis," IEEE Trans. Neural Networks, vol. 10, no. 3, pp. 626 - 634, 1999.
- [10] J. E. Jackson, A User's Guide to Principal Components. New York: Wiley, 1991.
- [11] H. Martens and M. Martens, "Modified jack-knife estimation of parameter uncertainty in bilinear modeling by partial least squares regression (pls)," Food Qual. Preference, vol. 11, no. 1 - 2, pp. 5 - 16, 2000.
- [12] F. Westad and H. Martens, "Variable selection in near infrared spectroscopy based on significance testing in partial least squares regression," J. Near Infrared Spectrosc., vol. 8, pp. 117 - 124, 2001.
- [13] F. Westad and M. Kermit, "Cross validation and uncertainty estimates in independent component analysis," Anal. Chim. Acta, 2003, submitted for publication.
- [14] B. Efron, The Jack Knife, The Bootstrap and Other Resampling Plans. Philadelphia, PA: SIAM Society for Industrial & Applied Mathematics, 1982.
- [15] Y. Li, D. Powers, and J. Peach, Comparison of Blind Source Separation Algorithms. Singapore: World Scientific, 2001, pp. 18 - 23.
- [16] 변형기, 이준섭, 김정도, "필드 스크린을 위한 휴대용 전자코 시스템의 구현," 한국센서학회 vol. 13 no. 1, pp.41~46, 2004.

저자소개



권기현(Kihyeon Kwon)

1995년 강원대학교 컴퓨터과학과
졸업(이학석사)
2000년 강원대학교 컴퓨터과학과
졸업(이학박사)

1996년 ~ 2002년 동원대학 인터넷정보과 교수
2002년 ~ 현재 강원대학교 공학대학 전자정보통신
공학부 교수

※ 관심분야 : Odor 센싱 시스템, 분산네트워크



최형진(Hyungjin Choi)

1982년 영남대학교 물리학과

(이학사)

1987년 일본동경공업대학
정보공학과(공학석사)

1990년 일본동경공업대학 정보공학과(공학박사)

1990년~91년 ETRI 선임연구원

1991년~현재 강원대학교 컴퓨터과학과 교수

※관심분야: 인공지능, 화상처리, 패턴인식



황성호(Sung-ho Hwang)

1991년 성균관대학교 전자공학과
(공학사)

1993년 성균관대학교 대학원
전자공학과(공학석사)

1996년 성균관대학교 대학원 전자공학과(공학박사)

1997년~현재 강원대학교 공학대학 전자정보통신
공학부 교수

※관심분야: MANET, WSN, 네트워크설계



주상렬(Sang-Yeol Joo)

1978년 강원대학교 수학교육학과
(학사)

1981년 고려대학교 수학과(석사)

1984년 고려대학교 수학과(박사)

1998년~1999년 미국 슬리퍼리대학 교환교수

1982년~현재 강원대학교 정보통계학과 교수

※관심분야: 확률, 신뢰성 및 퍼지정보론