

독립 성분 특징을 적용한 신경망을 이용한 효율적이고 안정적인 손 검출

Effective and reliable Hand Detection Using Neural Network with ICA features

이승준*, 고한석**
Seungjoon Lee*, Hanseok Ko**

Abstract - In this paper we propose an effective and reliable hand detection method using neural network with ICA(Independent Component Analysis) Features. Many algorithms of hand detection have been proposed yet. Among them, ICA is the one of the interesting topics in image processing. ICA can not only separate mixed signals but also efficiently extract low-dimensional features in signals. ICA features are able to represent the characteristic of the images well. The object of this paper is to use effectively ICA that has above advantage. That is, by the proper number of Independent component the arithmetic speed is faster and by normalization of ICA feature the performance of detection is more reliable. For this, we adopt the algorithm, the Proportion of variance, which select the ICA feature by comparing the ratio of variance of ICA feature. By this method, we can extract the feature that is good at classifying hand and non-hand. Our experimental results show that by using ICA features, we obtained a better performance in hand detection than by only training NN on the image. And we can use hand detection system effectively and reliably by our proposal.

Key Words : ICA(Independent Component Analysis), NN(Neural Network)

1. 장 서 론

의사소통에는 여러 가지 방법이 있다. 그 중 사람의 제스처는 표현력이 뛰어나고, 일상생활에서 빈번하게 사용된다. 따라서 제스처는 인간과 컴퓨터간의 통신에 도움을 줄 수 있다[1]. 최근 몇 년 사이에 영상 기반의 제스처 인식에 관한 연구가 광범위하게 이루어져 왔다. 그 연구들의 목적은 수화의 인식, 흡-네트워크의 제어, 가상현실 등으로의 적용이다. 그러나 제스처 인식의 과정 중에는 여러 가지 어려움이 있다. 그 중 하나의 문제가 복잡하고, 다양한 환경에서 제스처 인식의 주체, 즉 손을 정확하게 검출하는 것이다. 손만이 존재하는 단일한 영상에서는 피부색 같은 간단한 특징이나 손의 모델링을 통해 손을 검출할 수 있다. 그러나 복잡한 환경, 특히 손과 비슷한 특징을 갖는 후보들이 다수 존재한다면, 손을 정확하게 검출할 수 없다. 이를 극복하기 위해 그 동안 다양한 방법이 제안되어왔다.

본 논문에서 우리는 독립 성분의 특징과 융합된 신경망을 이용한 손 검출 방법을 제안하였다. 독립 분석(ICA)은 영상 처리 분야뿐만 아니라 여러 분야에서 흥미 있는 주제중의 하나이다. ICA는 혼합된 신호를 잘 분리할 수 있을 뿐만 아니라 신호에서 저 차원의 특징들을 효율적으로 추출할 수 있다. 영상에서 추출한 독립 요소 특징들은 그 영상의 특징을 잘 나타낸다. 본 논문의 목적은 이러한 장점을 갖고 있는

ICA를 효율적으로 사용하는 데에 있다. 즉, 적절한 독립 요소의 개수의 사용을 통해 연산 속도를 빠르게 하고, ICA 내부에서 사용하는 함수에 따라 나오는 데이터의 변이성에 대한 안정성을 높이는 것이다. 우리는 이를 위해 간단한 알고리즘을 제안하였고, 그 알고리즘의 성능 검증을 위해 다양한 실험을 하였다. 이렇게 추출된 독립 요소 특징들은 신경망[2]을 이용하여 훈련되고, 효과적으로 검출에 이용된다.

본 논문의 전체적인 개요는 다음과 같다. 첫 번째로 독립 요소의 특징과 융합된 신경망에 대해 설명하고, 두 번째로 독립 요소의 개수를 줄이는 알고리즘에 대해 설명하고, 세 번째로 함수별로 나온 값에 weight를 주는 방법에 대해 설명할 것이다. 그 다음으로 각각의 알고리즘에 대한 실험 방법, 과정 및 실험 결과에 대해 설명할 것이고, 마지막으로 결과를 바탕으로 결론을 낼 것이다.

2. 장 독립 성분 특징 추출

2.1 독립 성분 분석(ICA)

우리는 독립 요소 특징 추출 알고리즘으로 FastICA[3]를 사용하였다.

관측된 데이터($\mathbf{X} = (x_1, \dots, x_n)^T$)는 통계적으로 독립인 요소들($\mathbf{s} = (s_1, \dots, s_n)^T$)의 선형 변환으로 나타낼 수 있다. 다음의 선형 조합을 가정하자.

$$\mathbf{x} = \mathbf{As} \quad (1)$$

여기서 \mathbf{A} 는 조합 행렬이다. 위 식에서 우리가 알고 있는 값은 \mathbf{x} 뿐이다. 보통, ICA를 데이터에 적용하기 전에 하면

저자 소개

* : 고려대학교 전자컴퓨터공학과 석사과정

** : 고려대학교 전자컴퓨터공학과 정교수

유용한 전처리 기법들이 있다. 그 중 주로 사용하는 기법이 Whitening이다. Whitening은 고차항의 정보를 다루는데 유용하다.

$$Z = Vx = (VA)s \quad (2)$$

여기서 V 는 Whitening 행렬이다. 위 식에서 선형 변환 VA 는 직교 행렬로 바뀐다. 따라서, 우리가 구해야 할 것은 $y = Wz$ 가 녹립 요소를 잘 예측하게 하는 직교 행렬 W 를 구하는 것이다. 이상적인 결과는 W 가 조합 행렬 A 의 역행렬이 되는 것이다.

$$A = W^{-1} \rightarrow y \approx s \quad (3)$$

고차항의 정보를 활용하는 방법에는 여러 가지가 있다. 그 중 원론적이며 적관적인 접근 방법은 중앙 극한 이론에서 출발한 최대 비가우스성의 선형 조합을 찾는 것이다. 비가우스인 임의의 변수의 합은 원래 가우스 성질을 갖는 변수보다 가우시안 분포에 더 비슷해진다. 따라서, 만약 관측된 변수들

의 선형 조합 $y = \sum_i w_i z_i$ 를 취한다면, 선형 조합이 녹립 요소들 중의 하나와 같다면 그것은 최대한으로 비가우스의 성질을 갖고 있을 것이다.

녹립 요소를 구하는 과정은 다음과 같다.

1. n 개의 벡터 w_1, \dots, w_n 를 고려하자. 녹립 요소의 개수(m)를 정하고, n 을 1로 놓는다.
2. 임의로 w_n 의 초기값을 설정한다.
3. $w_n \leftarrow E\{zg(w_n^T z)\} - E\{g'(w_n^T z)\}w_n$ (4)

여기서 $g()$ 는 비선형성을 갖는 함수이다.

$$g(y) = \begin{cases} \tanh(ay) \\ y \exp(-y^2/2) \\ y^3 \end{cases} \quad (5)$$

4. 다음의 직교화 과정을 수행

$$w_n \leftarrow w_n - \sum_{i=1}^{n-1} (w_n^T w_i) w_i \quad (6)$$

5. w_n 을 정규화함

$$w_n \leftarrow w_n / \|w_n\| \quad (7)$$

6. w_n 이 수렴하지 않으면, 다시 3번 과정으로 돌아간다.
7. $n \leftarrow n+1$, $n < m$ 이면 다시 2번 과정으로 돌아간다.

그림 1은 ICA를 통해 구한 손의 녹립 성분의 특징을 나타낸다.

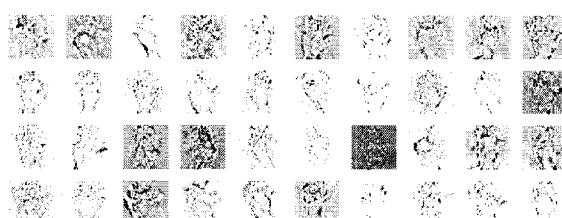


그림 1. 손의 녹립 성분의 특징 영상

2.2 적절한 녹립 성분 특징의 선택

이번 절의 목표는 추출된 녹립 요소 특징들 중에서 자동적으로 가장 좋은 특징들만을 추출하는 것이다. PCA의 경우 좋은 특징의 기준이 eigenvalue의 variance이다. 그러나 ICA의 경우 이미 사전에 녹립 요소의 개수가 정해져 있고, 구해진 값의 크기가 기준이 될 수 없기 때문에 적합한 특징을 선택할 수 없다. 여기서, 우리는 손과 손이 아닌 영상에 대한 구별 성능이 좋은 녹립 성분 특징을 추출하기 위해, 다음의 Proportion of variance 방법을 사용하였다.

$$r_m = \frac{\sigma_{between,m}}{\sigma_{within,m}} = \frac{\sum_{k=1}^K (\bar{f}_m(k) - \bar{\bar{f}}_m)^2}{\sum_{k=1}^K \sum_{l=1}^L (f_m(k,l) - \bar{f}_m(k))^2} \quad (8)$$

여기서,

$$\bar{f}_m(k) = \frac{1}{L} \sum_{l=1}^L f_m(k,l) \quad (9)$$

$$\bar{\bar{f}}_m = \frac{1}{KL} \sum_{k=1}^K \sum_{l=1}^L f_m(k,l) \quad (10)$$

여기서 k 는 클래스를 나타내고, m 은 녹립 요소 특징, l 은 영상을 나타낸다. 여기서 구한 r_m 의 값이 크면 클수록 구별 성능이 뛰어나다.

2.3 함수에 따라 다른 녹립 성분 특징의 정규화

녹립 성분 특징의 추출에서 우리가 사용한 FastICA 알고리즘은 negentropy를 이용한다. 이 과정에서 우리는 식 (5)에 나와 있는 함수들을 이용하게 된다. 그러나 실험을 해보면 각각의 함수별로 나오는 손 검출 성능이 다르다. 이를 보완하기 위해 우리는 각각의 함수별로 구해진 녹립 성분의 특징 값에 가중치를 주어 하나의 값으로 정규화하는 방법을 생각하였다.

$$f_{m,new}(k,l) = \frac{P_1}{P_1 + P_2} f_{m,1}(k,l) + \frac{P_2}{P_1 + P_2} f_{m,2}(k,l) \quad (11)$$

여기서 P_1, P_2 는 각각의 함수별 r_m 의 평균이다.

3. 장 실험 및 결과

손 검출을 위해서는 우선 손과 손이 아닌 영상에 대해서 훈련이 필요하다. 훈련 영상의 개수는 손 영상 304개와 손이 아닌 영상 557개를 사용하였다. 더 나은 검출 성능을 위해서는 보다 많은 훈련 영상이 필요하며, 특히, 손이 아닌 영상은 손과 구별하기 위해 더 많은 양을 필요로 한다. 실험은 3가지 이슈에 대해 수행 하였다. 첫 번째로, 같은 훈련 영상과 테스트 영상에 대해서 일반적인 신경망을 사용했을 때와 본 논문에서 제안한 녹립 요소 특징과 융합된 신경망을 사용했을 때의 검출 성능을 비교하였다. 그 다음으로 제안한 알고리즘의 연산량을 줄이기 위해서[4], 추출한 녹립 성분의 개수를 식 (8)에 의해 줄인 후 첫 번째 실험에서 나온 결과와 비교하였다. 마지막으로, 제안한 알고리즘의 안정성을 높이기

위해서 적용한 실험의 결과와 첫 번째 실험에서 나온 결과를 비교하였다.

그림 2는 사용한 손의 훈련 영상을 나타낸다.

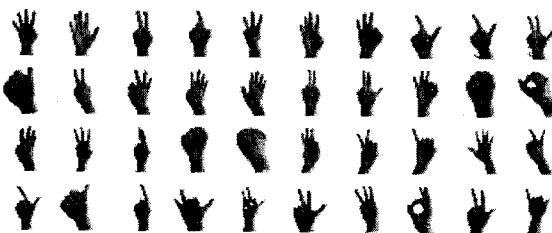


그림 2. 손 훈련 영상

표 1은 일반적인 신경망과 녹립 요소 특징과 융합된 신경망을 사용했을 때의 검출 실험 결과를 나타내고 있다. 2가지의 test 영상에 대해서 검출 실험을 하였다. 표에서 나타난 결과에서 알 수 있듯이, 녹립 요소 특징을 사용했을 때 검출 성능이 더 향상됨을 볼 수 있다.

표 1. 일반적인 신경망 Vs. 녹립성분을 사용한 신경망

검출 성능	Test 영상 I	Test 영상 II
일반적인 신경망	87.7%	89.5%
녹립 요소를 사용한 신경망	93.2%	94.6%

표 2는 표 1의 결과를 바탕으로 제안한 알고리즘의 성능 향상을 위한 실험의 결과를 나타내고 있다. 역시 실험 1과 같이 2가지의 test 영상에 대해서 검출 실험을 하였다. 결과에서 알 수 있듯이 사용하는 녹립 성분 특징의 개수를 줄여도 검출 성능에 큰 차이가 없음을 알 수 있었다.

표 2. 녹립 성분의 개수 별 검출 성능

검출 성능	Test 영상 I	Test 영상 II
녹립 성분을 전부 사용	93.2%	94.6%
녹립 성분을 부분 사용	93.2%	94.3%

표 3은 표 1의 결과를 바탕으로 제안한 알고리즘의 성능 향상을 위한 실험의 결과를 나타내고 있다. 역시 실험 1과 같이 2가지의 test 영상에 대해서 검출 실험을 하였다. 결과에서 알 수 있듯이 정규화된 녹립 성분 특징의 검출 성능이 비슷하거나 더 잘 나옴을 알 수 있었다.

표 3. 정규화된 녹립 성분의 검출 성능

검출 성능	Test 영상 I	Test 영상 II
실험을 통한 최적의 녹립성분	93.2%	94.6%
정규화된 녹립 성분	94.1%	94.6%

4. 장 결론

본 논문에서는 ICA feature를 적용한 신경망을 이용한 손 검출 방법을 제안하였다. 손을 검출하는 데에 있어서 성능의 판단은 검출률과 검출 속도에 의해 결정된다. 제안한 방법은 기존의 일반적인 신경망을 사용한 방법보다 더 나은 검출 성능을 보였다. 또한, 전체적인 연산량을 줄이기 위해서, 효율적인 손 검출을 위한 방법으로 Proportion of variance를 이용하여 손과 손이 아닌 영상을 잘 구별할 수 있는 ICA feature를 만을 추출하여 검출에 이용하는 방법을 제안하였다. 이 방법은 앞에서 제안한 방법에 비해 검출 성능이 떨어지지 않으면서도, 연산 속도는 더 빠라지는 결과를 보였다. 또한, 손 검출의 안정적인 성능을 위해 Proportion of variance의 결과를 이용한 ICA feature의 정규화 과정을 제안하였다. 이 방법은 기존의 g 함수에 따라 다른 결과가 나오는 문제점을 보완하여 항상 최적의 성능을 나타내게 하였다.

따라서, 본 논문이 제안하는 방법은 기존의 영상 전체를 이용한 손 검출 시스템에 비해 빠르고, 효율적이고 안정된 결과를 나타내었다.

참 고 문 헌

- [1] Vladimir I. Pavlovic, Rajeev Sharma and Thomas S. Huang, "Visual Interpretation of Hand Gestures for Human-Computer Interaction: A Review", 1997 IEEE.
- [2] Richard O. Duda, Peter E.hart and David G. Stork, "Pattern Classification, 2nd ed.", A Wiley-Interscience Publication, John Wiley & Sons, Inc..
- [3] Aapo Hyvärinen, Juha Karhunen and Erkki Oja, "Independent Component Analysis", A Wiley-Interscience Publication, John Wiley & Sons, Inc..
- [4] H.K. Ekenel , B. Sankur, "Feature selection in the independent component subspace for face recognition", Pattern Recognition Letters(2004)