

패턴인식을 위한 일반화된 이차신경망 구현

論文

51D-10-2

An Implementation of Generalized Second-Order Neural Networks for Pattern Recognition

李鳳奎* · 梁요한**
(Bongkyu Lee · Yohan Yang)

Abstract - For most of pattern recognition applications, it is required to correctly recognize patterns even if they have translation variations. In this paper, to achieve the goal of translation invariant pattern recognition, we propose a new generalized translation invariant second-order neural network using a constraint on the weights. The weight constraint is implemented using generalized translation invariant features which are accumulated sums of pixel combinations. Simulation results will be given to demonstrate that the proposed second-order neural network has the generalized translation invariant property.

Key Words : translation invariant, generalization, second-order neural network, weight constraint, pixel combination

1. 서 론

인간 시각 시스템의 중요한 특징 중 하나는 인식대상을 전체 입력 이미지에서의 위치에 무관하게 인식하는 능력이 있다는 것이다[1]. 따라서 인간의 시각을 대신하여 많은 응용분야에 사용되기 위해 구현되는 인공시각시스템 또한 인간과 같이 위치에 무관하게 대상을 인식하는 능력을 가져야 하며, 이런 능력은 학습과정을 통해 기계에게 부여되는 것이 일반적이다. 따라서 고려할 수 있는 모든 변형을 학습할 수 있는 충분한 양의 학습데이터를 사용할 수 있다면, 기계에 인간의 시각 특성을 부여하는 것이 어렵지 않을 것이다. 그러나 현실적으로 이런 이상적인 학습 데이터를 획득하는 것은 불가능하다. 또한 획득되었다 하더라도 이런 방대한 데이터를 학습하는데는 예측할 수 없는 많은 시간이 소요되기 때문에 학습이 불가능하게 된다. 위치변형만 고려하여도 인식대상이 입력이미지의 어디에 존재하는지를 사전에 파악할 수 없기 때문에 위치무관 인식시스템을 위해서는 방대한 데이터를 학습해야 한다. 또한 이런 방대한 학습데이터가 모든 위치변형을 고려한 것인지를 알 수 없기 때문에 100%의 인식율을 기대할 수 없다. 따라서 효과적인 위치불변 시각시스템을 구현하기 위해서는 위치변형을 정확히 정의하고 이에 적합한 학습/인식 모델을 구현하는 것이 필수적이다. 일반적으로 패턴인식에서 나타나는 위치변형은 4가지의 유형으로 구분할 수 있다. 이런 4가지유형의 변형은 구조적 텍스처나 각막표피 (corneal endothelium)와 같은 이미지를 처리할 때 볼 수 있다(그림 1).

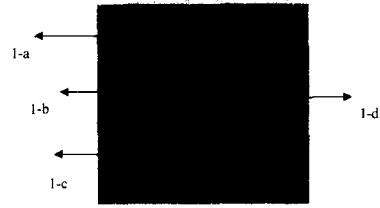


그림 1 다양한 위치변형 패턴
Fig. 1 Various translated patterns

인간의 경우는 그림1의 1-a, 1-b, 1-c, 1-d를 모두 같은 패턴을 표현하는 것임을 쉽게 알 수 있으나, 인공시각을 4가지 유형의 변형에 대해 일반화시키는 것은 쉬운 작업이 아니다. 이것은 아직까지 4가지 유형의 변형을 모두 소화할 수 있는 모델이 구현되지 않은 것으로 쉽게 증명이 된다.

현재까지의 위치에 무관한 인공시각 모델에 대해서 알아보고 그 문제점을 지적하면 다음과 같다. 가장 널리 사용된 초기의 위치에 무관한 인공시각 모델은 2 단계 처리 과정으로 구성되었다[2,3,4,5]. 먼저, 다양한 처리기법을 이용하여 인식 대상들에서 불변 특징을 추출하는 전처리 과정을 거친다. 다음 단계는 이를 추출 특징을 분류할 수 있게 학습된 인식기에 특징을 적용하여 실제 분류작업을 하는 것이다. 그러나 이런 접근 방법은 시스템 구성이 복잡하고 특정한 전처리 기법을 선택해야 하는 어려움 등의 문제점이 있다. 따라서 최근의 위치에 무관한 인식 모델은 2단계를 단일 단계로 통합한 시스템을 선호하는데, 신경망 방법이 그 대표적인 예이다.

신경망을 이용한 위치에 무관한 인식모델로서 가장 먼저 제안된 방법이 앞에서 언급한 변형된 패턴 모두를 학습 데이터로 제시하는 방법이다. 이 방법은 위치변형 뿐 아니라 다른 많은 기하학적 변형에 대해서도 처리가 가능하다는 일

* 終身會員 : 濟州大學數 電算統計學科 副教授 · 工博

** 準會員 : 濟州大學數 電算統計學科

接受日字 : 2002年 4月 19日

最終完了 : 2002年 7月 30日

반성을 가지고 있다. 그러나 위치에 무관한 특성을 신경망에 학습시키는데 필요한 대규모의 데이터로 인하여 많은 학습시간을 요구하면서도 충분한 성능을 낼 수 없기 때문에 실제 응용에 사용하기에는 부적절한 방법이다. 더욱이 학습에 사용할 이상적인 학습 데이터 집합을 수집하는 것이 현실적으로 불가능하기 때문에 실제로는 불변 특징을 추출하여 신경망을 학습시키는 2단계 방법을 이용하는 것이 보통이다[6].

다른 형태의 신경망 기반 접근 방법으로는 특정 불변을 위한 개개의 신경망 구조를 재 정의함으로써 변형을 신경망 구조 자체에 흡수시키는 방법이 있다. Neocognitron[7,8,9]은 이런 접근 방법을 사용하여 위치에 무관한 인식 능력을 가지도록 한 대표적인 신경망이다. 이 모델은 계층적 자기구성(self-organizing) 신경망으로 이미지의 위치 변형에 무관하게 패턴을 인식할 수 있다. 그러나, 모델을 구성하는 노드의 수가 학습되어질 패턴의 수에 비례하여 증가하기 때문에 학습 속도가 매우 느린 단점이 있으며, 다른 연구자들에 의해서 위치변형에 대한 해결이 명확히 정의되지 않았음이 증명되는 등 많은 문제점을 보이고 있는 것도 사실이다.

Neocognitron과 같은 접근 방법을 사용하지만 구조가 다른 불변 인식용 신경망 모델이 Widrow[10]에 의해 제안되었는데 이 모델은 퍼셉트론 형태의 계층적인(layered) 신경망을 전처리 형태로 이용하는 방식을 사용하였다. 또한 이 방법은 일반화가 가능하다는 장점과 이해하기 쉽다는 장점을 가지고 있는 관계로 다른 연구자들이 계층적인 신경망을 이용한 불변 패턴 인식을 연구하는 계기가 되었다. 그 예로는 다음과 같은 연구 결과가 나타나 있다. Khotanzad[11]와 Yegnaarayana[12]는 퍼셉트론(perceptron)과 디지털 필터를 사용한 방법을 제안하였고, Hasegawa[13]는 국부적인 불변 상호연결을 가지는 정방향(feedforward) 다차원 신경망을 제안하였다. Lin[14]은 2개의 연결된 다차원 신경망으로 구성되는 2단계 신경망 시스템을 제안하였다. Minnix[15]는 동적인 임계치 방식(dynamic thresholding mechanism)과 위치 불변 변환 그리고 변형된 Neocognitron으로 구성된 계층 신경망(layered network)을 제안하였다. 이렇듯 계층적인 신경망을 이용한 방법은 많은 다양한 연구 결과를 보이고 있지만 이 방법 역시 많은 학습 시간이 소요되는 단점을 극복하지 못하였기 때문에 사용에 제한을 받았다.

Neocognitron, 계층신경망 방법 외에 불변 패턴 인식에 사용된 방법은 Carpenter와 Grossberg의 ART 모델을[16] 응용한 것들이 있다. Srinivasa[17]는 훈련되지 않은 패턴에 대한 인식에 ART1 모델을 채택했고, Fukumi[18]는 a CONE model을 개발하여 동전인식을 수행하였다. 그러나 ART 모델을 기반으로 한 방법은 Neocognitron이나 계층적 네트워크 등 다른 신경망 모델에 비해서 학습과정이나 메커니즘을 명확히 구명할 수 없어 실제 구현하는데 많은 어려움이 있다는 단점을 때문에 일반적으로 사용하기에는 제약이 따른다. 이런 단점을 보완하기 위해 Srinivasa[19]는 3층 구조의 ART1을 제안하였으나, 이 모델 역시 기본 모델의 단점을 그대로 가지고 있어 단점을 일부 수정한 것에 불과하다.

이렇게 지금까지 연구된 신경망 방법들의 단점을 보완하기 위해 최근에 제안된 방법이 고차신경망을 이용하는 것이다. 고차신경망은 입력 패턴의 기하학적인 구조를 신경망의 구조에 직접 구현이 가능하기 때문에 불변 특성을 지닌 신

경망의 구조를 쉽게 구현할 수 있다. 또한 일반화된 학습 규칙을 이용할 수 있기 때문에 패턴인식에 사용이 효과적이다 [20,21,22]. 그러나 이런 장점에도 불구하고 다른 접근 방법과는 달리 최근까지 고차신경망을 이용한 불변 패턴 인식에 대한 연구가 활발하지 못했던 이유는 고차신경망은 입력 노드의 수가 대상 패턴의 크기에 기하급수적으로 증가하기 때문에 구현이 어려운 단점이 있다. 만약 패턴 차원이 N 이고, 차수가 R 인 고차신경망의 경우, 입력노드 수는 $O(N^R)$ 이 된다는 것이다. 이 문제점을 해결하면 고차신경망은 다른 방법보다 효과적으로 불변 패턴인식에 사용될 수 있기 때문에 많은 연구자들이 노드 수를 줄인 고차신경망을 이용한 불변 패턴 인식 시스템을 연구하였고 그 결과 노드 수를 줄인 고차신경망을 이용한 시스템에 대한 다양한 결과를 보였다. Coarse coding 기법을 이용하여 노드 수를 줄이는 구현 방법이 Spirkovska[21,22] 등에 의해서 제안하였고, 기하학적 특징 추출 방법으로 이 문제를 해결한 연구 결과도 발표되었다 [23,24,25].

그러나 이런 신경망 기반의 불변 패턴인식 시스템에 대한 많은 선행 연구 결과에도 불구하고, 그림 1에 나타나는 모든 형태의 위치변형을 해결하는 일반화된 위치불변 시스템은 아직 구현되지 못하고 있는 것이 현실이다. 그 이유는 현재 까지의 모든 위치불변 인식 모델은 주어진 문제영역에서 발생이 가능한 제한된 변형만을 고려하여 모델의 구조를 구현하였기 때문이다. 예를 들면 일반적인 정형화된 문자인식 등과 같은 영역에서는 그림 1-(a,c,d) 등의 wrap-translation(패턴이 특정 축을 중심으로 교차하는 변형)은 일어나지 않기 때문에 이런 변형은 고려치 않는다. 그러나 이런 가정은 인식대상이 달라지면 타당성을 잃어버리게 되고 결과적으로 치명적인 오인식의 원인이 되는 것이다. 즉, 인식 대상에 따라서 그림 1에서 표현한 것과 같이 4가지 유형의 위치변형 중 어느 것이 나타날지를 미리 예측하는 것은 불가능하기 때문에 잘 정의된 불변 패턴 인식 모델은 일반화된 인식 능력이 필수적이다. 그러나 특정 변형 도메인에 무관한 신경망의 구조를 일반화시키는 것은 근본적으로 구현이 매우 어렵기 때문에 아직까지 만족할 연구 결과가 나타나지 못하는 것이 현실이다.

본 논문에서는 이런 신경망 기반 시스템에서 해결하기 가장 어려운 문제 중 하나인 일반화된 불변 시스템의 구현을 다루고자 한다. 일반화 대상은 그림 1에서 보는 바와 같이 패턴 인식에서 고려할 수 있는 4가지 유형의 위치변형에 대해서 일반화된 모델이다. 제안된 신경망은 고차신경망의 일종인 이차신경망의 구조에 가중치 제약(weight constraints)을 준 새로운 모델로써, 기존 방법에 비해서 1) 4가지 변형을 모두 흡수하는 일반화된 불변 특성, 2) 입력된 이미지와 같은 차원의 입력노드 수(size limited)를 가지는 특성이 있다. 이런 특성을 만족하는 가중치 제약을 구현하기 위해서 본 논문에서는 이차특징이라는 패턴의 기하학적인 특성을 사용한다. 제안된 방법의 타당성을 보이기 위해 실행한 시뮬레이션 결과, 제안된 모델이 일반화 된 위치불변 특성을 가짐을 알 수 있었다.

본 논문의 구성은 다음과 같다. 2장에서는 먼저 일반적인 이차신경망에 대해서 소개하고 이를 바탕으로 제안된 모델을 구성하는 가중치 제약을 유도한다. 3장에서는 2장에서

구해진 모델의 타당성을 실험데이터를 통한 시뮬레이션으로 검증하고 분석한다.

2. 일반화된 위치 불변 이차신경망

2.1 이차신경망의 기본 개요

일반적인 고차신경망의 노드 i 에 대한 출력 y_i 는 다음과 같이 주어진다. 여기서 Θ 는 비선형 함수, h_i 는 노드(node) i 의 입력, W 는 가중치 행렬이고 x 는 입력 노드의 값을 의미한다.

$$y_i = \Theta(h_i) = \Theta\left(\sum_j W_{ij}x_j + \sum_j \sum_k W_{ijk}x_jx_k + \sum_j \sum_k \sum_l W_{ijkl}x_jx_kx_l + \dots\right) \quad (1)$$

위의 고차신경망 식 (1)에서 이차항(2번째 항)만을 고려한 것이 이차신경망이고 그 출력을 다음과 같이 표현할 수 있다.

$$y_i = \Theta(h_i) = \Theta\left(\sum_j \sum_k W_{ijk}x_jx_k\right) \quad (2)$$

식(2)는 위치에 불변하는 이차신경망의 정보처리 형태를 보여준다. 두 입력 노드 x_j, x_k 에 들어온 입력 데이터들은 곱연산(product)을 통해 처리된 후, 가중치와 결합된다. 이런 과정들은 모든 입력쌍에 적용되는데 이들 각 쌍의 결과들의 합이 출력 노드로 전달된다. 이때 이 가중치에 대한 제약조건을 부여하는 방법에 따라서 여러 가지 불변 특성을 얻을 수 있는 것이다[20].

(1), (2)에서 나타난 고차신경망(혹은 이차신경망)의 경우는 일반적으로 불변특성을 신경망의 구조에 포함시킬 수 있는 장점이 있다. 그러나 입력 노드의 수가 입력의 크기에 대해서 기하급수적으로 증가하는 문제점 때문에 구현에 어려움이 많다. $m \times n$ 크기의 이미지에 대해서 차수가 R 인 고차신경망을 적용한다면 입력노드의 수가 $O((m \times n)^R)$ 로 증가한다. 24×24 이미지에 대해서 이차신경망을 적용할 경우 필요한 입력노드 수는 331,776개이다. 이런 문제점 때문에 고차신경망을 실제 응용에 적용할 수 있도록 구현하는데 지금까지 많은 제약이 있었다. 다행히 최근 여러 연구자들에 의해서 이 문제점을 해결하는 방법이 다수 제시되었기 때문에 현재는 효과적인 구현이 가능해졌다. Spirkovska [21,22]등은 이 문제를 입력이미지를 적은 픽셀 수로 표현하여 축소함으로써 해결하였다. 이 축소방법은 실제 이미지를 구성하는 픽셀 수를 줄이는 접근 방식인데, 실제 이차 및 삼차신경망의 구현에 적용하여 실험하였다. 그러나 이방법의 경우 복잡한 패턴에는 적용이 힘들다는 단점이 있다. 이들 외에도 입력 픽셀의 각 쌍을 결합하고 그 결합들의 합을 이용한 SOP(Summation Of Products) 특징을 입력패턴으로부터 추출하여 이를 MLP(Multilayer Perceptron)에 적용시키는 방법을 통해 입력 노드를 줄이는 방법이 연구되어졌다 [23,24,25,26]. 이 방법을 사용하면 이차신경망을 픽셀간의 결합특징과 MLP를 이용하여 구현할 수 있으며, 입력노드의 기하급수적인 증가 문제도 해결할 수 있다(그림 2). 본 논문에서 제안하는 신경망도 이 방법을 이용하여 구현한다.

이런 노력에도 불구하고 아직 일반화된 능력을 가진 모델의 구현은 이루지 못하고 있다. 이에 본 논문에서는 그림 2의 형태를 가지는 일반화된 모델을 제시한다.

다음 장에서는 지금까지 구현되지 못한 일반화된 위치불변을 위한 픽셀간의 결합 방법을 가중치 제약을 통해 설명하고 이를 바탕으로 구현 알고리즘을 제시한다.

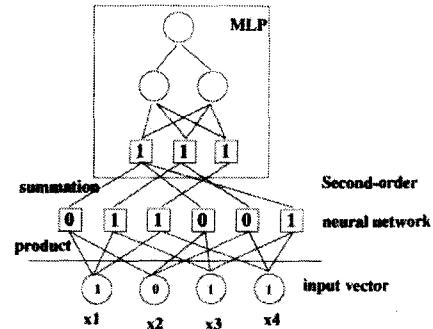


그림 2 MLP와 SOP를 이용한 이차신경망 구현

Fig. 2 A second-order neural network implemented using MLP and SOP.

2.2 일반화된 변형 불변 이차신경망

이장에서는 패턴인식에서 나타나는 4가지 유형의 위치변형에 불변성을 가지는 일반화된 신경망을 구현하는 방법을 제안한다. 제안된 구현 방법은 먼저 모든 위치변형에 대한 불변성을 신경망의 구조에 구현하기 위해 필요한 가중치 제약을 설정한 후, 이 제약을 실제 구현하는데 필요한 알고리즘을 제시한다. 일반적으로 4가지 유형의 변형은 2차원 패턴에서 발생하는 것인지만 자세한 설명을 위해 우선 1차원 패턴에서 기본 개념을 설명한 후 이를 바탕으로 2차원 이미지에 대한 방법을 제시한다.

크기가 n 인 일차원 입력 벡터 X 의 j, k 번째 구성 요소로 이루어진 (x_j, x_k) ($j < k$)에 대해서 두 요소간의 거리 관계는 $|k-j|$ 로 나타낼 수 있다. 만약 이 두 요소 x_j, x_k 가 각기 p 만큼 오른쪽으로 동일하게 위치이동을 할 경우 두 요소간의 거리 관계는 이동하지 않은 경우와 같이 $|k-j|$ 로 나타낼 수 있다. 따라서 두 요소는 같은 거리관계를 보이며, 위치에 무관한 인식을 위해서는 (x_{j+p}, x_{k+p}) 와 (x_j, x_k) 는 같은 쌍으로 인식해야 할 것이다. 따라서 요소 j, k 와 출력노드 i 간의 가중치 W_{ijk} 는 다음과 같은 관계를 만족해야 한다.

$$W_{ijk} = W_{i(j+p)(k+p)} = W_{i(j+p)((k+p)\%n)} \quad (3)$$

수식 (3)에서 마지막 항은 wrap-translation인 경우이며, 사용된 '%'는 나머지 연산을 의미한다. 여기에서 원소 (x_j, x_k) 쌍의 위치관계에 대응하는 2가지 종류의 픽셀간의 거리 관계를 정의할 수 있다. 먼저 $W_{i(j+p)(k+p)}$ 에서 *inner distance* ($k-j$)를 정의할 수 있다. 그리고 $W_{i(j+p)((k+p)\%n)}$ 에서 또 하나의 거리관계 *outer distance* ($n+j-k$)를 구할

수 있다(그림 3-F). wrap을 고려한 1차원 상에서의 위치불변을 위해서는 이 2가지 거리 관계를 가지는 픽셀들을 모두 (x_j, x_k)와 같은 것으로 인식해야 한다. 이런 가중치 제약조건은 입력요소 간의 상관관계를 추출하는 방법을 사용하여 신경망에 구현이 가능하다. 일차원 패턴에서의 2가지 거리에 관련된 상관관계를 입력요소들로부터 추출하는데 필요한 것이 *distance window*이다. 이것은 요소 두 x_i 에서 같은 상관관계를 가지는 x_k 로 고려해야 할 요소를 찾는 실제 입력패턴과 같은 크기의 창으로써, 한 원소 씩 오른쪽으로 이동하면서 거리관계를 계산한다. 그림 3-F에서 보듯이 현재의 x_i 에서는 자신의 window내에 있는 모든 요소들과 거리 관계를 계산해야 하는 것이다. 이렇게 계산된 누적 거리값은 같은 거리 관계를 가지는 요소 쌍들의 합으로 표현되며, 이를 이차특징(Second-Order Features)이라 한다[24,26].

위에서 설명한 일차원의 경우를 확장하면 이차원 이미지에 적용이 된다. 크기가 $m \times n$ 인 입력 이미지 B 에 대해서 일차원에서 적용한 *distance window*를 확장하여 4가지 종류의 모든 위치변형을 소화하기 위해서는 $m \times n$ 크기의 이차원 *window*가 필요하다 (그림 3-G). 이 *window*를 이용하여 *window*내의 모든 요소(픽셀)와 맨 위쪽 모서리 픽셀간의 행과 열을 모두 고려한 2차원 거리관계를 추출하여 일차원의 경우처럼 누적한 결과를 사용하면 모든 위치변형을 소화하는 일반화 된 신경망을 얻을 수 있으며 이때 얻어지는 같은 거리 요소의 누적 값을 일반화된 이차특징 (Generalized Second-Order Features)라 할 수 있다. 그림 4에서 2차원 패턴에 대해서 행과 열을 고려한 거리관계의 누적값을 구하는 실제적인 알고리즘을 보였다. 이 알고리즘을 입력되는 이차원 패턴에 적용하는 신경망은 임의의 위치변형에 대해서도 무관한 특성을 가질 수 있는 것이다.

3. 시뮬레이션을 통한 실험

컴퓨터 시뮬레이션을 통해 제안된 특징을 사용한 이차신경망의 타당성에 대해서 알아본다. 실험에 사용된 데이터는 4가지 종류의 비행기 패턴을 이용하였다. 본 논문의 목적을 보다 잘 이해하기 위해서는 텍스처(texture)패턴과 실제 4가지 변형이 모두 발생할 수 있는 대상을 선정하고 이를 이용하여 실험을 하는 것이 나은 방법일 것이다. 또한 비행기 패턴과 같은 데이터는 실제 상황에서 수집할 경우 wrap-translation이 발생하는 경우를 찾는 것은 어렵다. 그럼에도 불구하고 비행기 패턴을 이용한 실험을 고려하는 것은 다음과 같은 이유에 기인한다. 첫째는 실제 원형의 모양이 비교적 잘 파악되는 것을 이용한 실험 결과가 논문을 읽는 연구자들에게 제안된 일반화된 이차신경망 모델의 유효성을 보다 잘 보여줄 수 있을 것이기 때문이다. 즉 원형을 잘 알 수 있기 때문에 원형에서 얻을 수 있는 여러 유형의 변형들을 비교적 쉽게 알 수 있어 시뮬레이션의 정확성을 읽은 사람으로 하여금 쉽게 파악 할 수 있도록 하기 위한 것이다. 또한 본 실험에서 사용하는 비행기 이미지의 경우 불변패턴 인식에서 많이 사용되어 온 데이터이기 때문에, 실험 결과의 객관성을 보여줄 수 있다는 부가적인 효과도 기대할 수 있을 것이다.

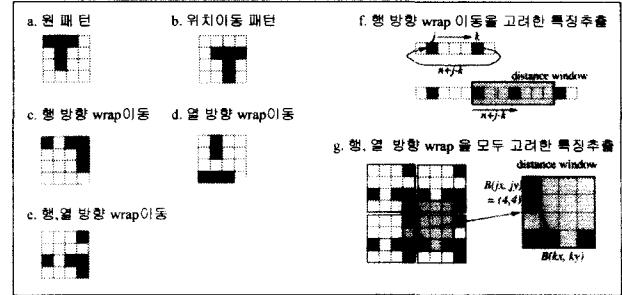


그림 3 다양한 위치변형과 일반화된 위치불변 추출

Fig. 3 Various translational variances and generalized invariant feature extraction

Algorithm: Extract-feature

```

1: for each position  $(j_x, j_y)$  in an image  $B$  do
2:   for  $l_x = 0$  to  $m-1$  do
3:     for  $l_y = 0$  to  $n-1$  do
4:       if  $(l_x, l_y)$  is not  $(0,0)$  then
5:          $k_x = (j_x, j_y) \text{ mod } m$ 
6:          $k_y = (j_x, j_y) \text{ mod } n$ 
7:          $\text{Second}(l_x, l_y) = \text{Second}(l_x, l_y) + B(j_x, j_y) \times B(k_x, k_y)$ 
8:       fi
9:     od
10:   od
11: od

```

그림 4 이차특징 추출 알고리즘

Fig. 4 The algorithm for extracting second-order features.

실험데이터는 스캐너로 입력받은 그레이 영상(0~255 레벨의 명도값을 가짐)으로 각 비행기 이미지의 크기는 16×16 의 크기이다 (그림 5-a 참조). 그림 5-a에 나타난 4가지 원형데이터는 신경망의 학습에 사용한다. 학습이 된 신경망에 대한 인식 실험을 위해 준비된 테스터 데이터는 원형데이터에 인위적인 위치변형을 가하여 만들어진다. 각 원형 데이터에 대해서 임의로 특정 픽셀 수(wrap이 되는 경우 포함)만큼 행과 열 방향으로 위치변형을 가하여 패턴 당 40개 (총 160개) 테스트 데이터를 구성하였다. 그림 5-b에서는 원형 데이터를 행방향, 열방향, 행렬방향으로 변형한 예를 보여준다.

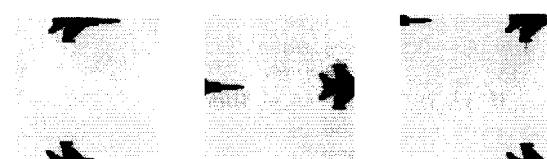
본 논문에서의 실험에 대한 또 한가지의 기존 실험과 다른 점은 제안된 방법과의 성능비교를 위한 다른 시스템을 고려하지 않는다는 것이다. 그 이유는 실험의 목적이 제안된 방법의 타당성을 검증하기 위한 것으로 성능비교는 큰 의미가 없으며, 또한 비교대상이 될 수 있는 시스템은 현재 까지 구현/제안되지 않고 있기 때문에 비교자체가 불가능하기 때문이다.

실제 구현되는 이차신경망 모델은 3계층(입력, 출력, 은닉)을 가지며 역전파 학습을 이용하는 표준의 MLP형태이다. 그러나 구현 모델이 일반적인 일차의 MLP과 다른 점은 입력노드에 들어오는 입력이 그림 4의 알고리즘에 의해서 추출되어지는 일반화된 이차특징이라는 것이다. [20,26] 등에서 이미 이런 전처리된 특징을 사용하는 MLP를 고차신경망으로 정의하였고 실제 이런 방법을 통해 구현된 고차신경망으로 정의하였고 실제 이런 방법을 통해 구현된 고차신경망으로

좋은 불변특성을 지니고 있는 것은 많은 연구를 통해 알려져 있으며 본 논문에서도 1장에서 이미 MLP를 이용한 고차신경망 방식을 이용함을 언급하였기 때문에 구현에서 MLP를 이차신경망으로 표현한다. 구현된 이차신경망의 세부적인 노드 수, 학습방법 그리고 학습에 필요한 파라미터는 표 1에 정리하였다.



(a) 실험용 데이터 원형
(a) Prototypes of experimental data



(b) 테스트 데이터 예
(b) An example of test data

그림 5 실험용 데이터 원형 및 테스트 데이터 예

Fig. 5 Data used in the experiments

표 1에서 보는 것과 같이 입력노드의 수는 256개이다 (16×16). 출력 노드의 수는 인식대상 이미지 카테고리의 수(4개)를 나타낸다. 은닉 노드의 수와 학습율은 여러 개를 임의로 선택하여 학습시킨 결과 중에서 학습시간 및 PSS(Pattern Sum of Square)가 가장 좋은 것을 선택하였다. 구현된 신경망의 동작원리는 다음과 같다. 먼저 입력된 이미지에 대해서 그림 4에 나타난 알고리즘을 통해 일반화된 이차특징을 추출한다. 그리고 나서 이 추출된 특징을 입력노드에 받아 실제 인식을 처리한다. 구현된 신경망은 미리 원래 모양의 패턴을 통해 학습이 완료되어 있기 때문에 위치변형이 발생한 입력패턴일지라도 추출된 특징이 같게 나타나는 학습되어진 패턴으로 분류함으로써, 4가지 유형의 위치변형에 무관하게 올바른 인식 결과를 산출하게 되는 것이다. 표 2는 실제 실험결과를 보여주고 있다. 표에서 볼 수 있듯이 제안한 이차신경망은 wrap-translation을 포함한 어떠한 위치변화에도 무관하게 패턴을 잘 인식함을 알 수 있다.

표 1 구현 신경망의 상세구조

Table 1 Configurations of the implemented network.

파라미터	입력노드 수	은닉노드 수	출력노드 수	학습율
값	256	3	4	0.254

활성함수	학습방법	학습완료횟수	에러 한계
sigmoid	역전파학습	212	0.03

표 2 실험결과(인식율)

Table 2 Recognition results+

패턴 종류	테스트 패턴 수	인식수	오인식 수
패턴 1	40	40	0
패턴 2	40	40	0
패턴 3	40	40	0
패턴 4	40	40	0

이런 우수한 인식결과(100%)를 얻은 것은 다른 여러 결과 [20,21,22,23,24,25,26]에서의 경우와 마찬가지 일차의 신경망에서는 볼 수 없는 고차신경망의 우수한 분류 능력에 기인 한다. 즉, 고차신경망의 경우는 학습을 통해 얻어진 불변성을 자체의 구조에 포함시키기는 능력이 있기 때문에 변형에 무관하게 입력을 잘 분류할 수 있는 것이다. 그러나 이런 고차신경망의 경우도 입력 이미지에 노이즈가 있는 경우에는 위와 같은 100% 인식결과를 얻기는 어려울 것임은 예상할 수 있다. 이것은 특정 불변특성을 포함하고 있는 고차신경망일지라도 다른 변형을 포함하기 위해서는 부가적인 학습이나 가중치 제약이 필요하다는 것을 보인다. 예를 들면 노이즈가 있는 위치변형된 패턴인 경우는 두가지의 복합적인 변형이 함께 포함되기 때문에 정확한 인식을 보장할 수 없는 것이다. 그러나 이 경우에도 일반적으로 고차신경망은 일차신경망보다는 인식율이 좋음이 여러 연구결과를 통해 증명되었다[20,21,26]. 따라서 잘 정의된 불변특성 고차신경망은 일차의 신경망을 통해 얻기 어려운 불변특성이외에도 다른 부가적인 특성을 얻을 수 있다. 본 논문에서는 비록 노이즈가 들어가는 경우는 제외시켰지만 다음의 2가지 사실을 바탕으로 본 실험이 유효함을 보일 수 있다. 먼저 본 실험은 그 대상이 제안된 신경망의 일반화된 위치변형의 확인이다. 즉 기타의 다른 변형을 고려치 않는 것이다. 따라서 다른 변형에 대해서는 향후에 보다 연구를 할 수 있는 것이고, 이번 실험에서는 이를 다른 변형에 따른 상황은 불필요한 것이다. 두 번째로는 만약 노이즈 같은 변형이 있을 경우에는 제안된 시스템의 전처리 과정으로 저대역 필터와 같이 노이즈를 제거 할 수 있는 기존의 방법을 그대로 이용할 수 있다는 것이다. 그렇게 되면 제안된 신경망의 일반화된 위치불변 특성을 다양한 응용에 처리 가능할 것이다. 이런 근거를 바탕으로 제안된 시스템에 대한 본 실험은 그 타당성을 확보할 수 있을 것이다.

4. 결 론

본 논문은 신경망 모델을 이용한 패턴인식 연구에서 중요한 비중을 차지하지만 실제 구현이 어려운 문제중 하나인 일반화된 신경망의 구조를 다루었다. 여러 가지의 일반화 능력 중에서, 본 논문에서는 특히 패턴인식에서 자주 나타나는 기하학적 변형의 한 부류인 위치이동에 무관한 특성에 대해서 일반성을 가지는 이차신경망의 구현에 초점을 맞추었다. 제안된 방법은 4가지 종류의 위치이동 변화를 모두 수용할 수 있는 새로운 신경망 모델의 구현을 위한 가중치 제약조건, 제약조건의 구현, 신경망의 구조 등을 설명하였다. 제안된 방법은 기존의 MLP구조를 이용한 구현방법[20,24,

25,26]을 사용하면서도 일차신경망에는 없는 불변특징을 구현할 수 있어 추가적인 자원의 할당 없이 불변인식에 효과적으로 사용이 가능하다. 제안된 방법의 장점은 다음과 같이 요약할 수 있다.

1. 단순한 구조이기 때문에 구현이 쉽다.
2. 패턴의 종류에 무관하게 적용이 가능.
3. 그림 4의 알고리즘은 두 픽셀 간의 상관관계만 고려.
4. $m \times n$ 입력 이미지에 대해서 입력노드 수도 $m \times n$

참 고 문 헌

- [1] S.E. Palmer, "Reference Frames in the perception of shape and orientation," *Object Perception*, pp. 121-163, 1989.
- [2] R. L. Kashyap, R. Chellappa, "Stochastic models for closed boundary analysis: representation and reconstruction," *IEEE Trans. on Information Theory*, vol. 27, pp. 627-637, 1981.
- [3] T.R. Crimmins, "A complete set of Fourier descriptors for two-dimensional shapes," *IEEE Trans. on System, Man and Cybernetics*, vol. 12, pp. 848-855, 1982.
- [4] G.P.R. Saravayudu, I.K. Sethi, "Walsh descriptor for polygonal curves," *Pattern Recognition*, vol. 16, pp. 848-855, 1983.
- [5] S. O. Belkasim, M. Shridhar, M. Ahmadi, "Pattern recognition with moment invariants: a comparative study and new results," *Pattern Recognition*, vol. 24, pp. 1117-1138, 1991.
- [6] H. Wechsler, G.L. Zimmerman, "2-D invariant object recognition using distributed associative memory," *IEEE Trans. on PAMI*, vol. 10, pp. 811-821, 1988.
- [7] K. Fukushima, "Neocognitron: A hierarchical neural network capable of visual pattern recognition," *Neural Networks*, vol. 1, pp. 119-130, 1988.
- [8] K. Fukushima, "Analysis of the process of visual recognition by the Neocognitron," *Neural Networks*, vol. 2, pp. 413-420, 1989.
- [9] E. Barnard, D. Casasent, "Shift invariance and the Neocognitron," *Neural Networks*, vol. 3, pp. 403-410, 1990.
- [10] B. Widrow, R.G. Winter, R.A. Baxter, "Layered neural nets for pattern recognition," *ASSP*, vol. 36, pp. 1109-1118, 1988.
- [11] A. Khotanzad, J.H. Lu, "Classification of invariant image representations using a neural network," *ASSP*, vol. 38, pp. 1028-1038, 1990.
- [12] B. Yegnanarayana, A. Ravichandran, "A two stage neural network for translation, rotation and size invariant pattern recognition," *Proc. of ICASSP91*, 1991.
- [13] A. Hasegawa, K. Itoh, Y. Ichioka, "Generalization of shift invariant neural networks: Image processing of corneal endothelium," *Neural Networks*, vol. 9, pp. 345-356, 1996.
- [14] W. G. Lin, S.S. Wang, "A new neural model for invariant pattern recognition," *Neural Networks*, vol. 9, pp. 899-913, 1996.
- [15] J. I. Minix, S. Eugene, R.M. Inigo, "A multilayered self-organizing artificial neural network for invariant pattern recognition," *IEEE Trans. on Knowledge and Data Engineering*, vol. 4, pp. 162-167, 1992.
- [16] G. A. Carpenter, S. Grossberg, "Invariant pattern recognition and recall by an attentive self-organizing ART architecture in a non-stationary world," *Proc. ICNN87*, 1987.
- [17] N. Srinivasa, M. Jouaneh, "A Neural network model for invariant pattern recognition," *IEEE trans. on Signal Processing*, vol. 40, pp. 1595-1599, 1992.
- [18] M. Fukumi, S. Omatsu, F. Takada, T. Kosaka, "Rotation invariant neural pattern recognition system with application to coin recognition," *IEEE Trans. on Neural Networks*, vol. 3, pp. 272-279, 1992.
- [19] N. Srinivasa, M. Jouaneh, "An invariant pattern recognition machine using a modified ART architecture," *IEEE Trans. on System, Man and Cybernetics*, vol. 23, pp. 1432-1437, 1993.
- [20] C.L. Giles, T. Maxwell, "Learning, invariance, and generalization in high-order neural networks," *Applied Optics*, vol. 26, pp. 2972-2978, 1987.
- [21] L. Spirkovska, M. B. Reid, "Position, scale and rotation invariant object recognition using higher-order neural networks," *Pattern Recognition*, vol. 25, no. 9 pp. 957-985, 1992.
- [22] L. Spirkovska, M. B. Reid, "Coarse-coded higher-order neural networks for PSRI object recognition," *IEEE Trans. on Neural Networks*, vol. 4, no. 2 pp. 276-283, 1993.
- [23] B.K. Lee, H.H Lee, D.K. Kim, Y. Cho, H.Y. Hwang, "Reduction of input nodes for shift invariant second-order neural networks using PCA," *Proc. of ICANN94*, vol. 2, pp. 1029-1032, 1994.
- [24] B. Lee, S. Cho, Y. Cho, "Translation, scale and rotation invariant pattern recognition using PCA and reduced second-order neural network," *Int. Journal of Neural, Parallel and Scientific Computation*, vol. 3, no. 3, pp. 417-429, 1995.
- [25] H.Y. Kwon, B.C. Kim, H.Y. Hwang, "Rotation and scale invariant pattern recognition using complex log mapping and augmented second-order neural network," *IEE Electronics Letters*, vol. 29, no. 7, pp. 620-621, 1992.
- [26] W.A.C. Schmidt, J.P. Davis, "Pattern recognition properties of various feature spaces for higher order neural networks," *IEEE Trans. on PAMI*, vol. 15, no. 8, pp. 795-801, 1993.

저 자 소 개



이 봉 규 (李 鳳 奎)

제주대학교 전산통계학과 부교수
Tel : (064)754-3593
e_mail : bklee@venus1.cheju.ac.kr



양 요 한 (梁 級 漢)

제주대학교 전산통계 석사과정
(주)바이오인포마이너 개발팀장
Tel : (064) 702-1832
e_mail : yangkun7@bioinformer.com