

## 실시간 약통 분류를 위한 계층적 신경회로망

# Hierarchical Neural Network for Real-time Medicine-bottle Classification

김정준\* · 김태훈\* · 류강수\*\* · 이대식\*\*\* · 이종학\*\*\*\* · 박길흠†  
Jung-Joon Kim\*, Tae-Hun Kim\*, Gang-Soo Ryu\*\*, Dae-Sik Lee\*\*\*, Jong-Hak Lee\*\*\*\*, Kil-Houm Park\*†

\*경북대학교 IT대학 전자공학부

\*\*구미대학교 정보통신과

\*\*\*대구대학교 전자전기공학부

\*\*\*\*대구가톨릭대학교 IT공학부

† School of Electrical Engineering and Computer Science, Kyungpook National University

### 요 약

의약품 자동 포장하는 시스템에서는 캐니스터(Canister)에 해당 약을 정확히 보충할 수 있는 해당 약통과 캐니스터와의 일치 여부를 판단하는 정합 알고리즘이 필수적이다. 본 논문에서는 약화사고 방지를 위해 많은 종류의 약통을 분류하기 위한 분류 성능뿐만 아니라 실시간으로 처리할 수 있는 상·하 계층으로 구성된 계층적 신경회로망을 제안한다. 먼저 약통 정보를 나타내는 라벨 영상으로부터 다수의 저 차원 특징 벡터를 추출한다. 추출된 특징 벡터를 사용하여 하위계층의 다층 퍼셉트론(MLP, Multi-layer Perceptron) 신경회로망을 학습한다. 다음으로 학습된 MLP의 중간층 출력을 입력으로 사용하여 상위계층의 MLP를 학습한다. 100개의 약통에 대해 좌우 30도까지 회전한 영상에 대해 제안한 계층적 신경회로망의 분류 성능 시험과 실시간 연산처리 성능의 우수함을 보였다.

**키워드** : 약통 분류, 약화, 계층적 신경회로망, 다층 퍼셉트론

### Abstract

In The matching algorithm for automatic packaging of drugs is essential to determine whether the canister can exactly refill the suitable medicine. In this paper, we propose a hierarchical neural network with the upper and lower layers which can perform real-time processing and classification of many types of medicine bottles to prevent accidental medicine disaster. A few number of low-dimensional feature vector are extracted from the label images presenting medicine-bottle information. By using the extracted feature vectors, the lower layer of MLP(Multi-layer Perceptron) neural networks is learned. Then, the output of the learned middle layer of the MLP is used as the input to the upper layer of the MLP learning. The proposed hierarchical neural network shows good classification performance and real-time operation in the test of up to 30 degrees rotated to the left and right images of 100 different medicine bottles.

**Key Words** : Real-time Medicine-bottle Classification, Accidental medicine disaster, Hierarchical neural network, Multi-layer Perceptron

## 1. 서 론

접수일자: 2013년 3월 31일

심사(수정)일자: 2013년 4월 7일

게재확정일자 : 2013년 5월 3일

† Corresponding author

This is an Open-Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/3.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

의약품은 생명과 절대적인 관계가 있으므로 환자가 약을 지급받는 과정에서 일어날 수 있는 약화사고를 방지하는 것은 매우 중요하다. 약화사고의 원인은 약사가 약을 수동으로 조제할 때 주로 발생하기 때문에 약화사고를 방지하기 위해서 전자동 정제분류 포장시스템을 많이 사용하고 있다. 그러나 이 시스템은 의약품을 자동으로 포장하는 시스템으로서 정해진 캐니스터(canister)에 해당 약이 아닌 다른 약이 보충된다면 대형 약화사고가 일어난다. 따라서 정해진 캐니스터에 해당 약이 정확히 보충될 수 있도록 하는 장치가 필요하다. 이 장치에는 캐니스터와 해당 약의 약통과의 일치 여부를 판단할 수 있는 정합(matching) 알고리즘이

필수적이다.

기존의 약통 분류 방법으로는 김 등이 제안한 SURF 기반의 분류 방법이 있다[1]. 이는 분류 성능 면에서는 우수하나, 약통 수가 늘어난다면 많은 계산 량으로 인해 실시간 처리가 어렵다. 일반적으로 약통 영상은 획득하는 과정에서 조명의 변화와 회전 변화, 크기변화, 그리고 위치변화 등의 기하학적 변화 등에 따라 매우 다양하게 변한다. 따라서 조명 변화와 약통의 기하학적 변화를 갖는 약통 영상에 대해서는 그 성능이 저하된다. 사람은 환경 변화를 이미 학습된 경험으로부터 판단할 수 있어 그러한 변화에도 매우 잘 적응한다. 따라서 인간의 뇌 정보처리 방식을 이용하는 신경회로망은 정합에 기반을 두어 약통을 분류하는데 적합한 방법임을 알 수 있다. 특히 전자동 정제분류 포장시스템은 대부분 정해진 약통만을 사용하기 때문에 모든 약통을 학습에 참여시킨다면 그 분류 성능은 탁월할 것이다. 또한 신경회로망은 새로운 특징을 추가하거나 약통 종류의 추가에 대해 학습이 용이한 장점이 있다.

수많은 약통을 분류하기 위해서는 약통의 라벨 영상을 입력 특징으로 사용하는 것이 바람직하다. 그러나 라벨 영상은 많은 화소로 구성되어 고차의 입력 벡터를 형성하게 된다. 이에 따라 분류기의 규모가 방대해지면 계산 량이 많아지고 학습이 어려워질 수 있다. 따라서 신경회로망을 이용한 이상적인 약통 분류기는 가능하면 입력 특징 벡터의 차원을 줄이면서 높은 분류 성능을 갖도록 해야 한다. 이를 위해서는 고 차원의 입력 특징 벡터 차원을 몇 개의 저 차원의 입력 특징 벡터 차원 군으로 나누고, 이를 소규모 신경회로망으로 학습시킨 후 통합할 방법이 요구되고 있다[2-4].

본 연구의 대상인 약통 영상은 3 가지 주요 특징들을 갖는다. 1) 획득된 약통 영상은 회전 변화가 많이 일어난다. 2) 전자동 정제 분류 포장 시스템에서는 정해진 약통만을 사용한다. 3) 분류에 사용할 특징은 약통의 라벨영역이고 변별력을 갖기 위해서는 많은 화소 수가 필요하다. 신경 회로망은 회전변화가 많은 특징에 대해서는 학습과정에서 회전을 고려하면 되고, 정해진 약통만을 사용하는 특징에 대해서는 모든 약통을 학습에 참여시킨다면 그 분류 성능은 탁월할 것이다. 그러나 라벨영역의 변별력을 위하여 요구되는 많은 화소의 필요성 특징에 대해 살펴보면, 이를 신경회로망의 입력 벡터로 사용하면 신경회로망의 규모가 방대해짐을 알 수 있다. 이는 많은 계산 량으로 인해 실시간 처리가 어려워 질 수 있음을 말한다.

따라서 본 논문에서는 저 차원 벡터를 입력으로 하는 소수의 소규모 신경회로망을 사용하고 이들을 통합하는 상·하계층으로 구성된 계층적 신경회로망을 제안한다. 먼저 약통 정보를 나타내는 고 차원의 라벨 영상으로 부터 다수의 저 차원 특징 벡터를 추출한다. 여기서 저 차원 특징 벡터들은 라벨 영상으로부터 decimation 과정을 반복 적용하여 얻는다. 추출된 특징 벡터들을 사용하여 하위계층의 MLP들을 학습한다. 다음으로 신경회로망의 중간층 출력이 새로운 특징 추출기로 사용될 수 있는 성질을 이용하여 학습된 다층 퍼셉트론(MLP, Multi-layer Perceptron)의 중간층 출력을 입력으로 사용하여 상위계층의 MLP를 학습한다[5]. 제안한 계층적 신경회로망은 여러 개의 소규모 MLP들을 사용한 신경회로망으로 입력 벡터의 차원을 줄여줌으로서 학습, 분류, 그리고 약통 추가 등의 과정에서 상당한 이점을 갖는다. 제안한 계층적 신경회로망의 곱셈 연산수를 기반을 둔 연산 처리 성능과 실시간 분류율 성능을 확인하였다.

## 2. 신경회로망을 이용한 약통 분류기

### 2.1 자동 정제분류 포장시스템

의약품을 자동으로 포장하는 시스템으로서 정해진 캐니스터에 해당 약이 정확히 보충되어 질수 있도록 정해진 캐니스터와 해당 약의 약통과의 일치 여부를 판단할 수 있는 정합 알고리즘이 필수적이다. 그림 1은 자동 정제분류 포장시스템의 약통분류 과정을 나타낸 것으로 약품 자동인식 시스템 장치가 그 중심에 있다. 캐니스터의 고유 약통번호 인식을 통한 데이터베이스 영상과 보충하려는 약통영상과의 일치 여부를 판단하여 약통에 약을 보충하는 약품 인식시스템이다. 기존의 김 등이 제안한 SURF 기반의 분류 방법[1] 분류 성능 면에서는 우수하나, 약통 수가 늘어나면 엄청난 계산 량으로 인해 실시간 처리가 어려운 한계가 있다.

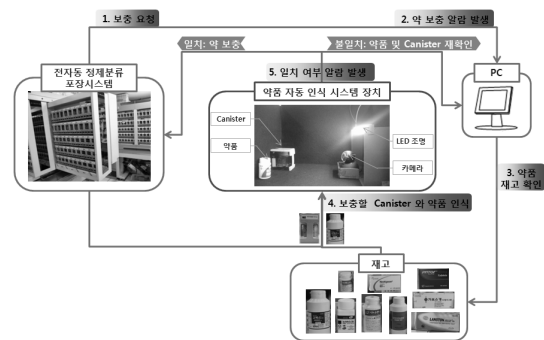


그림 1. 약통 분류 과정

Fig. 1. Procedure of Medicine-bottle Classification.

### 2.2 다층 퍼셉트론 신경회로망

입력층과 출력층으로만 구성된 단층 퍼셉트론(Single-layer Perceptron)과는 다르게 다층 퍼셉트론(MLP)에서는 중간층을 가지고 있다. MLP는 중간층을 가짐에 따라 평면 공간에서 임의의 패턴을 분리시킬 수 있다[5]. MLP에서 중간층은 다수 개 둘 수 있지만, 중간층이 하나인 MLP는 그림 2에서 나타난 것과 같다. 그림 2에서  $i, j, k$ 는 각각 입력층, 중간층 및 출력층을 나타내며,  $W^1$ 은 입력층과 중간층 사이의 가중치 행렬,  $W^2$ 는 중간층과 출력층 사이의 가중치 행렬을 나타낸다.

그림 2에서  $X$ 는 입력 특징 벡터로서  $p$  차원,  $h$ 는 중간층 출력 벡터로서  $q$  차원, 그리고  $O$ 는 출력층 출력 벡터로서  $r$ 차원을 가진다. 입력층과 중간층 사이의 가중치는 중간층의 각 노드에서의 가중치 벡터  $W_j^1, j=1,2,\dots,q$  로서 표현할 수 있다. 따라서  $W^1$ 은  $p \times q$ 차원이 되며, 중간층의 가중치 벡터들 및 입력층과의 강도 성분에 의해 나타낸다. 중간층과 출력층 사이의 가중치는 출력층의 각 노드에서의 벡터  $W_j^2, j=1,2,\dots,r$  로서 표현할 수 있다. 따라서 중간층과 출력층 사이의 가중치 행렬  $W^2$ 는  $q \times r$ 차원으로 구성되며,  $W^1$ 과 같은 표현 방법에 따라 출력층의 각 노드에 대한 가중치 벡터들 및 중간층과 출력층 사이의 연결 강도 성분에 의해 나타낼 수 있다.

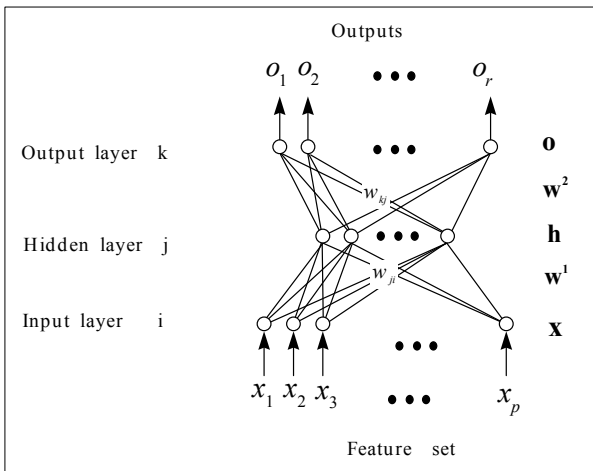


그림 2. 하나의 중간층을 가지는 다층 퍼셉트론의 구조  
 Fig. 2. An Architecture of Multi-layer Perceptron with One Hidden Layer.

**2.3 계층적 신경회로망을 이용한 약통 분류기**

수많은 종류의 약통을 분류하는데 그림 2와 같은 하나의 MLP를 이용할 경우는 입력 특징 벡터의 차원이 너무 커 분류 성능을 보장할 수 없다. 이는 학습 및 분류 과정에서 시간이 오래 걸릴 뿐만 아니라, 분류에 실패할 수도 있다. 따라서 이와 같이 신경회로망으로 고차원의 입력 특징벡터를 갖는 대상을 분류하기 위해서는 입력에 사용되는 특징 벡터의 차원을 줄이는 것이 매우 중요하다.

본 논문에서는 저 차원 벡터를 입력으로 하는 소수의 소규모 신경회로망을 사용하고 이들을 통합하는 상·하 계층으로 구성된 계층적 신경회로망을 제안한다. 먼저 입력 벡터의 추출은 다음의 3 단계로 이루어진다[1].

단계 1: 약통 영상으로부터 이진화, 모폴로지 연산 등을 이용하여 최외곽 사각형(MBR, Minimum Boundary Rectangle)을 그림 3과 같이 검출한다.

단계 2: MBR 영역에서 정규화된 라벨 영상을 그림 4(a)와 같이 추출한다.

단계 3: Decimation 과정을 반복 적용하여 다중 해상도 영상, 즉 다수의 저 차원 특징 벡터  $X$ 를 그림 4(b), 그림 4(c), 그리고 그림 4(d)와 같이 추출한다.

먼저 약통 영상으로부터 라벨 영상을 얻기 위해서 약통 영상으로부터 최외곽 사각형(MBR, Minimum Boundary Rectangle)을 검출한다. MBR을 추출하기 위해 획득된 약통 칼라 영상을 이진화 문턱치를 이용하여 흑백 영상으로 만든다. 다음으로 모폴로지 연산과 윤곽선 검출 알고리즘을 적용하여 약통 영역에 대해 윤곽선을 검출한다. 윤곽선 중에서 가장 길이가 긴 윤곽선을 사용하여 MBR을 검출한다. 다음으로 MBR 영역에서 라벨 영상을 추출한다. 라벨 영상은 약통마다 그 크기가 다르므로 정해진 크기로 정규화 한다. 정규화된  $256 \times 256$  라벨 영상은 65,536개의 화소수로 이루어져 있기 때문에, 고 차원 입력 벡터가 된다. 따라서 decimation 과정을 반복 적용하여 다수의 저 차원 특징 벡터를 추출한다. 그리고 약통의 회전 변화를 고려해 학습에 사용될 좌우 5도 간격으로 30도 회전된 약통의 라벨 영상들에 대해서도 마찬가지로 과정을 적용한다.

그림 5는 약통 분류를 위해 제안한 계층적 신경회로망을 나타낸다. 추출된 입력 특징 벡터  $X$  들을 사용하여 하위계층의  $MLP(MLP_L)$ 들을 학습한다. 여기서 하위계층의




그림 3. 약통영상 MBR 영역 검출: (a) 약통영상 (b) 모폴로지 영상 (c) 윤곽선 검출영상  
 Fig. 3. MBR Region Extraction of Medicine-bottle Image: (a) RGB Medicien-bottle Image (b) Morphology Image (c) Extracted Contour Image.




그림 4. Decimation된 영상 (a) 정규화된 라벨 영상 (b) 10x10 (c) 30x30 (d) 50x50  
 Fig. 4. Decimation Image (a) Normalized Label Image (b) 10x10 (c) 30x30 (d) 50x50.

$MLP_L$ 들의 구조는 하나의 중간층을 갖는 다층 퍼셉트론 구조인 그림 2의 구조를 이용한다. 그림 5에서  $MLP_{L1}, MLP_{L2}, \dots, MLP_{LN}$ 는 각각 저 차원 입력 벡터  $X_1, X_2, \dots, X_N$ 에 대한 다층 퍼셉트론 신경회로망이다. 다음으로 학습된 MLP의 중간층 출력 벡터  $h$ 를 입력 벡터로 사용하여 상위 계층의  $MLP(MLP_H)$ 를 학습한다. 여기서  $MLP_H$ 의 구조도 그림 2의 구조를 이용한다.

$MLP_L$ 의 중간층 출력 벡터  $h$ 는 입력 특징 벡터에 비해 보다 높은 변별력을 갖는다. 이를 바탕으로 서로 다른 변별력을 갖는  $MLP_L$ 의 중간층 출력들을 통합하여  $MLP_H$ 의 입력으로 사용함으로써 더욱 높은 변별력을 갖도록 한다[6]. 또한 제안한 계층적 신경회로망은 저 차원의 입력 특징 벡터를 사용하여 학습 및 분류 과정에서의 연산수를 획기적으로 줄인다. 예를 들어 약통의 회전 변화를 고려해 좌우 회전된

총  $M$ 개 영상에 대해 고 차원 입력 벡터  $X$ 의 차원이  $N \times N = N^2$ 이고, 하위계층  $MLP_L$ 를 3개 사용할 경우 ( $X_1, X_2, X_3$ 의 차원이 각각  $\frac{N}{25} \times \frac{N}{25} = \frac{N^2}{625}, \frac{N}{20} \times \frac{N}{20} = \frac{N^2}{400}, \frac{N}{15} \times \frac{N}{15} = \frac{N^2}{225}$  이라고 할 때) 학습에 필요한 곱셈 연산 횟수를 살펴본다. 먼저 그림 2의 단일 MLP를 사용하고, 중간층 노드 개수를 입력 노드의 25%인  $\frac{N^2}{4}$ 개로 할 경우, 출력 노드 당 학습에 필요한 곱셈 연산이 아래의 식(1)과 같이  $0.25MN^4$  번 일어난다.

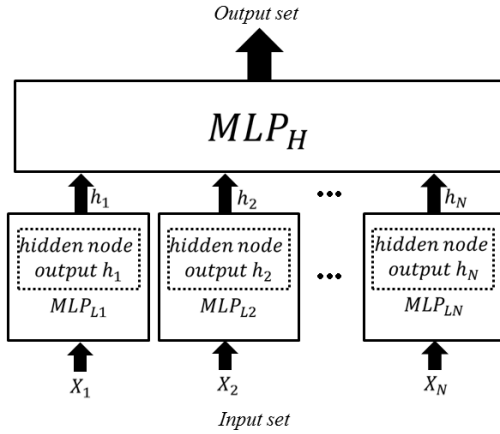


그림 5. 실시간 약통분류를 위한 계층적 신경회로망  
Fig. 5. Hierarchical Neural Network for Real-time Medicine-bottle Classification.

$$\begin{aligned} & \text{입력벡터차원} \times \text{중간노드수} \times \text{회전영상수} \\ &= N^2 \times \frac{N^2}{4} \times M = \frac{MN^4}{4} \end{aligned} \quad (1)$$

한편 제안한 계층적 신경 회로망에서는  $MLP_{L1}, MLP_{L2}, MLP_{L3}$ 의 중간층 노드 개수가 입력 노드의 25%인 각각  $\frac{N^2}{2500}, \frac{N^2}{1600}, \frac{N^2}{900}$ 개로 할 경우 출력 노드 당 학습에 필요한 곱셈 연산은 각  $MLP_L$ 에서 합인 아래의 식(2)와 같다.

$$\begin{aligned} & \sum_{i=1}^3 MLP_{Li}(\text{입력벡터차원} \times \text{중간노드수}) \times \text{회전영상수} \\ &= \left( \frac{N^2}{625} \times \frac{N^2}{2500} + \frac{N^2}{400} \times \frac{N^2}{1600} + \frac{N^2}{225} \times \frac{N^2}{900} \right) M \\ &\approx 0.00000714MN^4 = 7.14 \times 10^{-6} \end{aligned} \quad (2)$$

그리고  $MLP_H$ 의 입력 노드는 각  $MLP_L$ 의 중간층 노드들의 합인  $0.002136N^2$ 개 입력 노드의 25%인  $0.000534N^2$ 개로 할 경우 출력 노드 당 학습에 필요한 곱셈 연산은  $MLP_H$ 에서  $0.00000114MN^4$ 번 일어난다. 따라서 제안한 계층적 신경 회로망은 단일 MLP에 비해 곱셈 연산수를 아래의 식 (3)과 같이 약 99.9% 이상을 줄일 수 있다.

이러한 저 차원 입력 특징벡터를 적용한 계층적 신경회

로망은 학습 및 분류 과정에서의 학습 및 연산수를 획기적으로 줄임으로써 실시간 자동 정제분류 포장 시스템의 성능을 보장해 줄 수 있다.

$$\begin{aligned} & \frac{MLP_L \text{의 연산수} + MLP_H \text{의 연산수}}{\text{단일 MLP의 연산수}} \\ &= \frac{7.14 \times 10^{-6} MN^4 + 1.14 \times 10^{-6} MN^4}{0.25MN^4} \quad (3) \\ &\approx 0.00003312 = 3.312 \times 10^{-5} \end{aligned}$$

### 3. 시험 및 검토

시험에서는 5개의 대형 약국에서 수집한 약통 100종을 대상으로 하였고, 이들 모두를 학습 약통으로 사용하였다. 모든 약통을 학습에 사용한 이유는 전자동 정제 분류 포장 시스템은 대부분 정해진 약통만을 사용하기 때문이다. 만약에 새로운 약통이 추가될 경우는 그 약통에 대해서 추가적인 학습을 하여야 한다. 저차원 영상은 256x256의 영상을 decimation한 10x10, 30x30, 50x50의 3 가지 해상도 영상들을 사용하였다. 제안한 계층적 신경 회로망의 성능은 분류율과 연산수로 평가하였다. 그리고 약통의 회전 변화를 고려해 좌우 5도 간격으로 30도 회전된 총 13개 영상에 대해 학습을 하였다. 또한 중간층 노드 개수를 입력 노드의 25%로 하였다. 각 MLP에 대한 학습은 역전파법을 사용하였으며 이때 관성항은 0.7로 하였다. 학습에 사용한 입력 벡터는 그레이 영상에 대해 최대값을 1로 정규화하여 사용하였다.

먼저 그림 2의 단일 MLP를 사용할 경우에 분류율은 100% 였지만, 출력 노드 당 학습하는데 필요한 곱셈 연산이 약  $1.4 \times 10^{10}$ 번 일어나고, 출력 노드 당 분류에 필요한 곱셈 연산이  $1.1 \times 10^9$ 번 일어난다. 표 1은 저 차원 입력 벡터들에 따른  $MLP_L$ 의 출력 노드 당 학습하는데 필요한 곱셈 연산수를 나타낸다. 여기서 3개의  $MLP_L$ 의 학습은 모두 500회 이내의 반복 학습 횟수로서 완료되었다. 표 2는 저 차원 입력 벡터들에 따른  $MLP_L$ 의 분류율과 출력 노드 당 분류에 필요한 곱셈 연산수를 나타낸다. 표 1과 표 2로부터, 하위 계층의 MLP인  $MLP_L$ 에서의 학습 및 분류 과정의 곱셈 연산 회수가 하나의 MLP에서의 학습 및 분류 과정의 곱셈 연산 회수에 비해 극단적으로 적음을 알 수 있으나, 분류 성능은 입력 벡터의 변별력이 떨어짐에 따라 저하됨을 알 수 있다. 하지만 저차원 벡터의 차원이 높아질수록 분류 성능이 개선됨을 알 수 있고, 이는 영상 해상도가 높아짐에 따라 입력 벡터가 보다 높은 변별력을 가짐을 의미한다. 또한 분류에 실패한 약통을 확인한 결과 학습에 참여하지 않은 회전 영상들이 많았다.

표 3은 제안한 계층적 신경 회로망의 분류율과 출력 노드 당 분류에 필요한 곱셈 연산수를 나타낸다. 여기서 학습은 70회 이내의 반복 학습 횟수로서 완료되었다. 이는  $MLP_L$ 의 중간층 출력들이 높은 변별력을 갖고 상호 보완적인 작용을 한다는 것을 나타낸다. 표 3으로부터 제안한 계층적 신경 회로망의 학습 및 분류 과정의 곱셈 연산 회수가 하나의 MLP에서의 학습 및 분류 과정의 곱셈 연산 회수에

비해 엄청나게 적음을 알 수 있고, 분류도 완벽히 할 수 있음을 알 수 있다. 특히 학습에 참여하지 않은 회전 영상들에 대해서도 완벽히 분류함을 확인하였다.

표 1. 저 차원 입력 벡터들에 따른  $MLP_L$ 의 출력 노드 당 학습에 필요한 곱셈 연산수

Table 1. Number of Multiplication Operations for Learning per Output Node for Low Dimension Input Vectors.

입력벡터 차원	$10 \times 10$ ( $MLP_{L1}$ )	$30 \times 30$ ( $MLP_{L2}$ )	$50 \times 50$ ( $MLP_{L3}$ )	합계
$MLP_L$ 의 곱셈연산수	32,500	2,632,500	20,312,500	22,977,500

표 2. 저 차원 입력 벡터들에 따른  $MLP_L$ 의 분류율과 출력 노드 당 분류에 필요한 곱셈 연산수

Table 2. Classification Rate of  $MLP_L$  and Number of Multiplication Operations for Classification per Output Node for Low Dimension Input Vectors.

크기(pixel×pixel)	분류율(%)	출력 노드 당 곱셈연산수
$10 \times 10$ ( $MLP_{L1}$ )	67%(67/100)	2,500
$30 \times 30$ ( $MLP_{L2}$ )	82%(82/100)	202,500
$50 \times 50$ ( $MLP_{L3}$ )	88%(88/100)	1,562,500

표 3. 계층적 신경 회로망의 분류율과 출력 노드 당 분류에 필요한 곱셈 연산수

Table 3. Classification Rate and Number of Multiplication Operations for Learning and Classification per Output Node of Hierarchical Neural Network.

분류율(%)	출력 노드 당 학습의 곱셈 연산수	출력 노드 당 분류의 곱셈 연산수
100%(100/100)	25,468,625	1,959,125

#### 4. 결 론

본 논문에서는 약화 방지를 위해 많은 종류의 약통을 실시간으로 분류할 수 있는 신경회로망을 제안하였다. 약통 영상은 회전 변화가 많이 일어나고, 전자동 정제 분류 포장 시스템에서는 정해진 약통만을 사용하고, 분류에 사용할 입력 특징은 약통의 많은 화소 수로 구성된 라벨영상이다. 이로부터 적은 화소 수로 구성된 저 차원 벡터를 입력으로 하는 소수의 소규모 신경회로망을 사용하고 이들을 통합하는 상·하 계층으로 구성된 계층적 신경회로망을 이용하였다. 시험 결과 제안한 신경 회로망이 연산량 측면에서는 실시간

처리가 가능하고, 분류 성능도 우수함을 알 수 있었다.

본 논문에서는 100개의 약통을 대상으로 5도 간격의 좌우 30도 회전으로 제한하였지만 향후 약통의 종류가 늘어나고 회전의 범위가 확대되더라도 제안한 2단계 방식이 유용하게 적용될 수 있을 것으로 예상된다. 그러나 본 논문에서 출력 노드 값의 최고치에 의한 분류에서 100%를 보였지만, 출력노드의 값들의 차이가 아주 작은 경우도 있음에 따라 약화 사고 방지를 보장하기 위해 향후 신뢰도 지수 도입을 고려해야 할 필요가 있을 것이다.

#### References

- [1] Kim, T. H., Kim, G. S., Song, Y. C., Ryu, G. S., Choi, B. J., and Park K. H., "A Color-based Medicine Bottle Classification Method Robust to Illumination Variations," *Journal of Korean Institute of Intelligent Systems*, vol. 23, no. 1, pp. 57-64, 2013.
- [2] C. Y. Suen and Y. S. Huang, "Multi-expert systems for pattern recognition," *Proc. of the second Pacific Rim International Conference on Artificial Intelligence*, Seoul, pp. 15-20, Sept. 1992.
- [3] S. Lee and S. N. Srihari, "A theory of classifier combination: the neural network approach," *Document Analysis and Recognition, 1995., Proceedings of the Third International Conference on.* vol. 1, pp. 42-45, Aug. 1995.
- [4] R. A. Jacobs and M. I. Jordan "Learning piecewise control strategies in a modular neural network architecture", *Systems, Man and Cybernetics, IEEE Transactions on*, vol. 23, no. 2, pp. 337-345, 1993.
- [5] I. C. Jou, S. S. You and L. W. Chang, "Analysis of Hidden Nodes for Multi-layer Perceptron Neural Networks," *Pattern Recognition*, vol. 27, no. 6, pp. 859-864, 1994.
- [6] G. S. Ryu and S. I. Chien, "An integrated classifier of modularized neural networks: A case study on handwritten numerals recognition," *International Symposium on Artificial Neural Networks*, Taiwan Hsinchu, pp. D3-07~D3-12, Dec. 1995.

저 자 소 개



**김정준(Jungjoon Kim)**

1981년 : 경북대학교 전자공학과 공학사  
1983년 : 한국과학기술원 전자공학 공학석사  
1997년 : 루이지애나주립대, 미국 공학박사  
1984년~2011년 : (주)케이티 상무  
2012년~현재 : 경북대학교 전자공학부 부 교수

관심분야 : 신호처리, 임베디드 devices, IT Convergence  
Phone : +82-53-950-5524  
E-mail : jungkim7@ee.knu.ac.kr



**김태훈(Tae-Hun Kim)**

한국지능시스템학회 논문지,  
제21권 제5호 참조



**류강수(Gang-Soo Ryu)**

한국지능시스템학회 논문지,  
제21권 제2호 참조



**이대식(Dae-Sik Lee)**

1982년 : 경북대학교 전자공학과 공학사  
1984년 : 한국과학기술원 전기 및 전자공학과 석사  
1991년 : 한국과학기술원 전기 및 전자공학과 박사  
1994년~현재 : 대구대학교 전자전기공학부 교수

관심분야 : 전력전자 응용, 지능제어  
Phone : +82-53-850-6624  
E-mail : dslee@daegu.ac.kr



**이종학(Jong-Hak Lee)**

1982년 : 경북대학교 전자공학과 공학사  
1984년 : 한국과학기술원 전산학과 석사  
1997년 : 한국과학기술원 전산학과 박사  
1984년~1987년 : 금성통신(주) 부설연구소  
1987년~1998년 : 한국통신 연구개발본부  
1998년~현재 : 대구가톨릭대학교 IT공학부 교수

관심분야 : 다차원 화일구조, 데이터베이스, 보안  
Phone : +82-53-850-2746  
E-mail : jhlee11@cu.ac.kr



**박길흠(Kil-Houm Park)**

한국지능시스템학회 논문지,  
제21권 제5호 참조