

# 부품 분류 방법에 따른 분류율 비교

\*이영길\*·안성규\*·정성환\*

colorlee@cosmos.changwon.ac.kr \*창원대학교 멀티미디어 연구실

## Comparison of Classification Rate According to Parts Classification Method

Young-gil Lee\*, Sung-Gyu Ahn\* Sung-Hawn Jung\*

\*Dept of Computer Science, Changwon National University

### 요 약

본 논문에서는 다양한 부품에 대한 적당한 분류 방법을 찾기 위해 일반적으로 많이 사용되는 신경망을 이용한 분류 방법과 템플릿 매칭을 이용한 분류 방법을 실험에 사용하였다. 본 연구에서는 부품 분류 방법을 부품의 분류율과 인식에 사용될 수 있는 최대 부품 수를 고려하여 비교 분석하였다. 실험결과 DCT(Discrete Cosine Transform)를 이용한 템플릿 매칭 방법이 다양한 부품을 인식하는데 있어 가장 뛰어난 분류율을 보였다.

## I. 서 론

컴퓨터 하드웨어 기술과 디지털 영상 처리 알고리즘의 발달로 인하여, 현재 컴퓨터 비전 기술이 다양한 분야에 응용 사용되고 있으며, 그 적용 범위 또한 확대되어 가고 있다[1][2].

이러한 컴퓨터 비전은 주로 공장 자동화(Factory Automation)분야에 응용 되고 있다. 그 중에서도 부품 분류는 품질관리 시스템 및 자동 조립 라인에 있어, 대상이 되는 부품의 종류를 인식하고 분류하는 중요한 기초 기술 중의 하나이다[3].

기존의 부품 분류 방법들에는 신경망을 이용한 방법과 템플릿을 사용하는 단순거리척도 방법이 있다.

본 연구에서는 인식률을 비교 분석하기 위해서 신경망을 이용한 방법으로는 단층 신경망을 이용한 방법과 다층 신경망을 이용한 분류 방법을 사용하였으며, 템플릿 매칭을 이용한 방법으로는 통계적 템플릿 매칭기술과 DCT를 이용한 템플릿 매칭기술을 분류에 사용하였다[4][5].

서론에 이어 2장에서는 부품 분류 시스템 구조를 살펴보고, 3장은 본 논문에서 사용한 부품 분류 방법을 설명하겠

다. 4장에서는 부품 분류 방법들의 실험결과를 살펴보고, 5장에서 결론을 맺는다.

## II. 부품 분류 시스템

부품 분류 시스템을 구조는 아래 그림 1과 같다.

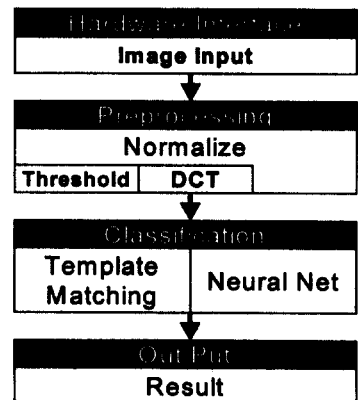


그림 1. 부품 분류 시스템 구조도

부품 분류 시스템의 구성은 부품 영상을 하드웨어 장치로부터 입력 받는 입력단계와 입력된 부품 영상에 대해 정규화 및 이진화, DCT변환 과정을 거치는 전처리 단계, 그리고 전처리 단계를 거쳐서 나온 특징을 이용하여 부품을 인식하고 분류 하는 분류단계로 구성되어 있다.

### III. 부품 인식 및 분류 방법

본 연구에서는 부품 분류 방법을 비교 분석하기 위해 아래와 같이 신경망을 이용하는 두 가지 방법과 템플릿 매칭기법을 이용한 두 가지 방법을 실험에 이용하였다.

#### 3.1 단층 신경망을 이용한 분류

입력된 부품영상을 32×32크기로 정규화하여 단층 신경망의 입력형식에 맞게 이진화 과정을 거쳐 입력 벡터를 생성하였다.

전처리 과정을 거쳐 나온 부품영상을 입력 벡터로 하여 전방향(feedforward) 단층 신경망인 Adaline을 분류에 사용하였다.

입력층을 벡터  $In$  출력층을 벡터  $Out_j$ 로 표현하면 각 층의 연결가중치 행렬은  $W$ 로 표현할 수 있다. 이때 입력층의 내용을 바탕으로 출력 층의 내용을 결정하는 신경망의 전과 과정은 식 1과 같다.

$$\begin{aligned} Act_j &= \sum_{j=1}^N W_{j\mu} \cdot In_{\mu} \\ Out_j &= 1, Act_j \geq 0 \\ Out_j &= -1, Act_j < 0 \end{aligned} \quad (1)$$

이때, 목표 벡터와 신경망의 출력을 비교하여 신경망의 연결 가중치를 수정한다. 목표 벡터를  $T$ 라고 하고 학습률을  $\eta$ 이라고 하면, 가중치를 변경하는 방법은 식 2와 같이 표현된다.

$$W(new)_{\mu} = W(old) + \eta \cdot (T_j - Act_j) \cdot In_{\mu} \quad (2)$$

위의 과정을 여러 번 반복하여 특정 입력 패턴에 대해 원하는 출력을 얻게 된다.

#### 3.2 다층 신경망을 이용한 분류

입력된 부품영상을 32×32크기로 정규화 과정만을 거친 후 전방향 (feedforward) 다층 신경망인 MLP(Multi Layer Perceptron)을 분류에 사용하였다. 입력층을 벡터  $In_{\mu}$ , 출력층을 벡터  $Out_{\mu}$ 로 표현하면 각 층의 연결가중치는 행렬  $W_{\mu}$ 의 꼴로 표현할 수 있다. 이때 입력층의 내용을 바탕으로 하여 출력 층의 내용을 결정하는 신경망의 전과 과정은 식 3과 같다. 이때 식의 Bias값은 1을 사용했다.

$$\begin{aligned} Act_j &= \sum_{j=1}^N W_{j\mu} \cdot In_{\mu} + Bias \\ Out_j &= 1 / (1 + \exp(-Gain \times Act_j)) \end{aligned} \quad (3)$$

목표 벡터와 신경망의 출력을 비교하여 신경망의 연결 가중치를 수정한다. 이때 목표치와 결과치와의 차이 값이 신경망의 오류치가 된다. 이 오류치는 중간 가중치 수정을 위해 목표 벡터를  $T_j$ 라고 할 때 식 4의 방법으로 각 층에 역전파 된다. 역전파된 오류치를 이용하여 최종적으로 가중치를 수정할 때는 학습율을  $\eta$ 이라고 하면 가중치를 변경하는 방법은 식 5로 표현된다. 이때  $dW$  값은 모멘텀 항으로 신경망이 지역 최소점에 빠질 위험을 줄이기 위해 추가된 항이다.

$$\begin{aligned} ErrPrev_j &= Out_j \cdot (1 - Out_j) \cdot (T_j - Act_j) \\ ErrNext_{\mu} &= Out_{\mu} \cdot (1 - Out_{\mu}) \cdot \left( \sum_j W_{j\mu}^t \cdot ErrPrev_j \right) \end{aligned} \quad (4)$$

$$\begin{aligned} E &= \eta \cdot Out_{\mu} \cdot ErrThis \\ W(new)_{\mu} &= W(old)_{\mu} + E + \alpha \cdot dW_{\mu} \\ dW(Updated)_{\mu} &= E \end{aligned} \quad (5)$$

#### 3.3 통계적 템플릿 매칭

입력 부품 영상을 32×32 크기로 정규화한 다음 부품의 분류를 하기 위해 부품 영상의 통계적인 특징으로 평균 및 분산을 이용한다. 그리고 부품의 모양정보를 이용하기 위해서 전처리 과정을 통해 얻어진 32×32의 영상들을 이용하여 템플릿을 구성하게 된다.

샘플 영상의 편집시 입력되는 영상들이 조금씩 왜곡될 수 있으므로, 쉽게 왜곡될 수 있는 몇 가지 형태를 샘플 영상으로 입력 받아서 식 6에 의해 샘플 영상들을 겹친다. 이렇게 구성된 영상은 분류를 위한 템플릿으로 이용된다.

수식 6에서  $I$ 는 대상이 되는 영상의 인덱스 값이며,  $N_I$ 은  $I$ 종류가 가지고 있는 샘플 영상의 개수를 나타낸다.  $S_{kI}$ 은  $I$ 종류의  $k$  번째 샘플 영상을 나타내며,  $Template_I$ 는  $I$ 종류의 템플릿을 나타낸다.

$$Template_I = \frac{1}{N_I} \cdot \sum_{k=1}^{N_I} S_{kI} \quad (6)$$

특정 추출 과정에서 분류 대상이 되는 영상들의 특징 값들이 얻어졌으면, 부품영상을 입력받아서 분류작업을 수행한다.

분류 과정은 먼저 영상의 평균 및 분산값과 얻어 놓은 각 부품 영상의 통계값들과 비교하여, 각 값의 차이가 큰 종류의 부품들을 분류 대상에서 제외시킨다.

다음, 통계값 비교를 통해 제외되고 남은 후보 부품들을 대상으로 각 부품영상의 템플릿과 입력영상을 식 7에서

$E_i$ 로 표현되는 유클리드 거리가 최소가 되는 영상을 찾는다.

이때, 식 7에서 입력 영상은  $IN$ 으로 표현된다.

$$(Template_i - IN)^2 = E_i \quad (7)$$

이러한 계층적인 과정을 통해서 불필요한 유클리드 거리 척도 측정을 수행하지 않으므로 시스템이 보다 효율적으로 수행된다.

### 3.4 주파수 템플릿 매칭

앞의 템플릿 방법은 영상의 왜곡에 약하다는 단점을 가지고 있다. 이러한 단점을 극복하기 위해 DCT에 의한 주파수 분석법을 사용하였다. 입력된 영상을 주파수 분석법에 의해서 특징을 추출하기 위해서 아래 식 8과 같이  $N \times N$  블록으로 분할한다.

$$B_N(a,b) = In_{N_a \times N_b} \quad (8)$$

식 9에서는 분할된 소 블록의 정보를 각 주파수 영역별로 모아서 재구성한다. 이때, 각각의 주파수 영역마다 (원 영상 크기)/ $N$  크기의 주파수 특징 영상이 구성된다.

$$FL_L(a,b) = \sum_{k=0}^L F_N(B(a,b))_{k,L-k} \quad (9)$$

이때 함수  $F$ 는 식 10의 DCT 변환 함수이다.

$$F_N I_{x,y} = \frac{1}{N^2} \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} I_{i,j} \cdot \cos\left(\frac{(2i+1)u\pi}{2N}\right) \cos\left(\frac{(2j+1)v\pi}{2N}\right) \quad (10)$$

이렇게 만들어진 주파수 특징 영상을 최소 제곱 오류 분류 방법에 의해서 부품을 분류 한다.

## IV. 실험결과

부품 분류를 실험하기 위해서 신경망을 이용한 방법에서는 총 10종류 100개의 부품 영상을 사용하였으며, 템플릿 매칭을 이용한 방법에서는 195종류 각 10장씩 1950장을 실험에 이용하였다. 실험에 사용한 부품 영상은 그림 2와 같다.

본 논문에서 제안한 방법은 펜티엄 프로 200에서 Microsoft Visual C++5.0로 실험하였으며, 그 결과는 표 1과 같다.



그림 2. 부품 영상

표 1. 부품 분류 결과

분류방법	Neural Net		Template	
	Adaline	MLP	통계적방법	DCT이용
부품영상	10종류×10장=100장		195종류×10장=1950장	
분류율	81%	100%	84%	97%

본 연구에서 제시한 4가지 방법을 비교 실험한 결과 다층 신경망을 이용한 방법과 DCT를 이용한 템플릿 매칭을 이용한 방법에서 높은 인식률을 보여 주었다. 하지만, 다층 신경망을 사용한 경우 훈련 시 많은 학습시간이 소요되었으며, 입력벡터의 한계로 10개 이상의 부품을 처리하기에는 적당하지 않았다. 그러나, DCT를 이용한 템플릿 매칭 방법은 다양한 부품에 대해서 적용이 가능했으며, 인식률 또한 높게 나왔다.

## V. 결론

본 논문에서는 다양한 부품 영상에 대하여 부품 분류 방법에 따른 인식률을 비교 분석하였다. 실험결과 부품의 종류가 10개 이하일 경우 다층 신경망을 이용한 방법이 뛰어나았으며, 20개 이상의 다양한 부품의 인식에는 DCT 변환을 이용한 템플릿 매칭 방법이 효과적이라는 것을 알 수 있었다.

## 참고논문

- [1] Nello Zuech ed., "Machine Vision : Capabilities for industry", Machine Vision Association of SME,1988.
- [2] K. Hendengren, "Methodology for Automatci image-based inspection of industrial objects", in Advances in Machine Vision, j.Sanz ed., Springer-Verlag, 1988.
- [3] 김상철, "ART2 신경회로망을 이용한 실장 PCB분류 시스템", 석사학위논문, pp.1-29, 1998.
- [4] A. L. Yullie, P. W. Hallinan and D. S. Cohen, "Feature Extraction from Faces using Deformable Templates", Int. ourn of Computer Vision, Vol.8, No2, pp. 99-112, Aug. 1992.
- [5] 이영길, 안성규, 정성환, "주파수 분석을 이용한 부품 분류 시스템 구현", 한국 정보처리 학회 '99 춘계 학술발표 논문집, pp.1329-1331, 1999.