

# 중소 제조업을 위한 HTM 기반의 부품 이미지 인식 시스템의 개발

배 선 갑<sup>+</sup> · 이 대 한<sup>\*\*</sup> · 조 건 화<sup>+</sup> · 남 해 보<sup>\*\*\*</sup> ·  
성 기 원<sup>\*\*\*\*</sup> · 배 종 민<sup>\*\*\*\*\*</sup> · 강 현 석<sup>\*\*\*\*\*</sup>

## 요 약

소량으로 다품종을 생산하는 소규모 공장에서 적은 비용으로 쉽게 부품의 양·불량을 판별하는 시스템의 개발이 절실히 요구된다. 이러한 시스템의 개발을 위하여 다양한 환경에서도 물체를 인식할 수 있는 사람의 인식 능력과 같은 기능이 필요하다. 인간의 고등 지능은 대부분 두뇌의 신피질(neocortex)에서 비롯된다. 최근 이 신피질의 동작 원리를 컴퓨터에 접목시키는 연구 중의 하나가 Jeff Hopkins가 제안한 HTM 이론이다. 본 논문은 이 HTM 이론을 적용하여 소량 다품종 부품 생산 현장에서 부품의 이미지를 인식하여 양·불량을 판별하는 시스템인 PRESM(Parts image REcognition System for small scale Manufacturing industry)를 개발하였다. 개발 결과를 현장에 적용해 본 결과 실제 환경에서 부품의 양·불량 판별이 우수한 것으로 확인되었다.

키워드 : 부품 이미지 인식, HTM, 신피질

## Development of an HTM-Based Parts Image Recognition System for Small Scale Manufacturing Industry

Bae Sun-Gap<sup>+</sup> · Lee Dae-Han<sup>\*\*</sup> · Diao Jian-Hua<sup>+</sup> · Nan Hai-Bao<sup>\*\*\*</sup> ·  
Sung Ki-Won<sup>\*\*\*\*</sup> · Bae Jong-Min<sup>\*\*\*\*\*</sup> · Kang Hyun-Syug<sup>\*\*\*\*\*</sup>

## ABSTRACT

It is necessary to develop a system of judging whether or not the parts are defective easily at low cost, especially in a small scale factory which manufactures a large variety of products in small amounts. To develop such system, we require to recognize objects using human's cognitive ability under various circumstances. Human's high intelligence originates mostly from neocortex of human brain. The HTM theory, which is proposed by Jeff Hopkins, is one of the recent researches to model the operation principle of neocortex. In this paper we developed PRESM (Parts image REcognition System for small scale Manufacturing industry) system based on the HTM theory to judge badness of manufactured products. As a result of application to the real field of workplace environments we identified the superiority of our recognition system.

Keywords : Parts Image Recognition, HTM, Neocortex

### 1. 서 론

정보·영상기술의 발전은 제조 공장에서 품질 개선과 이를 통한 생산성 향상에 많은 기여를 해왔다. 그러나 하나의 프레스로 여러 가지 부품들을 생산하는 소규모의 공장에서

는 양·불량품을 대부분 사람이 판별한다. 이 경우 반복되는 작업으로 집중력이 부족해져 불량을 감지하지 못하는 경우가 있어 품질관리의 신뢰성이 심각한 영향을 받는다. 뿐만 아니라 대규모 공장보다 각 부품마다 양·불량품을 판별하는 시스템을 설치 운영하기는 비용과 복잡성으로 인해 매우 어려운 실정이다. 그래서 보다 빠르고 정확하게 양·불량품을 판정하면서도 비용이 적게 들도록, 다양한 부품에 쉽고 빠르게 적용할 수 있는 시스템의 개발이 절실히 요구된다.

기존에 제안된 디자인 규칙 기반 특성 비교법에 기반한 영상처리를 통한 부품 검사 시스템[1]은 특정 부품 하나를

\* 준 회 원 : 경상대학교 컴퓨터학과 박사과정  
\*\* 준 회 원 : 경상대학교 컴퓨터학과 석사  
\*\*\* 준 회 원 : 경상대학교 컴퓨터학과 석사과정  
\*\*\*\* 정 회 원 : 창원대학교 산업시스템공학과 겸임교수  
\*\*\*\*\* 종신회원 : 경상대학교 컴퓨터과학부 교수  
\*\*\*\*\* 종신회원 : 경상대학교 컴퓨터과학부 교수(교신저자)  
논문접수 : 2009년 2월 4일  
수정일 : 1차 2009년 3월 31일, 2차 2009년 4월 30일, 3차 2009년 5월 25일  
심사완료 : 2009년 5월 26일

목표로 개발되어, 해당 부품에 맞게 복잡한 프로그램으로 구성되어 있다. 하지만 소량 다품종을 생산하는 소규모 공장에서는 생산 부품이 바뀔 때마다 신속하게 그 부품에 맞게 이러한 장비를 설치하는 것이 비용 때문에 거의 불가능한 일이다. 이러한 소규모 단위 공장에서는 작은 비용 부담으로 효과적으로 양·불량품을 판별하는 시스템이 되기 위해서는 필요할 때마다 생산 제품의 이미지를 학습하여 실시간으로 인식하여 판별하는 기능이 필요하다. 그런데 이러한 기능의 인식 시스템이 되기 위해서는 다양한 가변 환경에서도 사람이 인식할 때와 같은 수준의 인식률이 요구되며, 제품이 바뀔 때마다 쉽게 그 제품에 적용될 수 있어야 한다. 따라서 인간 두뇌의 이미지 인식 기능에 비견할 수 있는 적합한 기술이 필요하다.

인간의 이미지 인식 능력은 주로 인간 두뇌의 외부를 둘러싸고 있는 얇은 막인 신피질(neocortex)의 기능에서 비롯된다. 그동안 신피질의 동작 원리를 흉내 내는 시스템을 개발하려는 노력이 많이 이루어져 왔다[2]. 그 중 신피질의 동작 기제에 좀 더 가까운 것이 최근 Jeff Hopkins가 제안한 계층형 시간적 메모리(Hierarchical Temporal Memory(HTM)) 이론이다.

HTM 이론[3]은 인간 두뇌를 구성하는 뉴런들과 시냅스들이 계층적으로 시간적 메모리 구조를 갖고 있다고 보는 이론으로, 인간 두뇌의 해부학과 심리적 동작 실험 결과를 분석해 흉내내어 만들어졌다. 이는 기존 인공신경망 이론보다 노드의 역할이 좀 더 복잡한 연산을 수행하는 방법을 사용하며, 실세계에 대한 시공간적인 패턴을 계층적으로 기억한다. 이러한 HTM 이론을 기반으로 최근 Numenta라는 회사에서 지능 시뮬레이션 엔진으로 NuPIC을 개발하였다. 이 NuPIC은 현재 다양한 인식 분야에 활발하게 활용되고 있으며, 계속적으로 기능이 발전되고 있다[4].

본 논문은 이 HTM 기술을 이용하여 부품의 양·불량을 판정하는 중소 제조업을 위한 부품 이미지 인식 시스템인 PRESM(Parts image REcognition System for small scale Manufacture industry)을 개발하였다. 우리는 PRESM의 개발을 위해 공장에서 생산된 양품과 불량품을 다양한 환경에서 이미지를 촬영해 그룹화 하고, 적절한 HTM 네트워크 구조를 결정한 후, 이미지들로 훈련시켜 적합한 파라미터를 설정하는 방법을 사용하였다. 그리고 개발한 이 시스템을 실제 현장에서 테스트해 보았다. 즉, 여러 방향으로 회전(rotation) 또는 이동(shift) 등이 있는 새로운 부품 이미지 데이터들에 대해 추론하여 인식하는 실험을 수행하였다. 또한, 하나의 생산라인에서 다른 종류의 제품이 생산되는 것을 가정하여 새로운 제품의 이미지 데이터들에 대해 학습, 추론하여 인식하는 실험을 수행하였다. 그 결과 이러한 영향들과 생산되는 제품 종류의 변화가 있는 실제 상황에서도 인식 능력이 우수한 것으로 확인되었다.

논문의 구성은 다음과 같다. 2장에서 관련 연구를 기술하고, 3장에서는 우리가 개발한 PRESM의 개념을 설명한다. 4장에서는 이의 구현을 보이고 그 결과를 실제 환경에 적용

해 분석한다. 5장에서는 관련된 기존 연구들과 비교한다. 마지막 6장에서는 결론과 향후 과제를 논한다.

## 2. 관련 연구

산업 분야에서 비전검사 시스템에 많이 사용해 온 방법은 모델 기반의 자동화 검사 기법인 형판 매칭 방법과 디자인 규칙 기반 기법이 있다. 형판 매칭 검사 기법은 영상 차감법, 또는 상관계수를 사용하는 화소-대-화소 방법이며, 디자인 규칙 기반(rule base) 기법은 입력 물체로부터 특성을 추출하고 이상적인 참조 모델을 서술하는 규칙들에 비교하는 방법이다[1]. 이는 모든 규칙들이 만족되면 입력 물체는 무결점으로 간주되는 것으로 각 부품마다 특성을 비교하기 위해 입력 객체의 경계선, 모양의 구석과 같은 객체의 특성을 추출하고, 이미 저장되어 있는 모델의 특성과 비교함으로써 결점의 유무를 판별하게 되는데, 이는 매칭 알고리즘이 복잡하고 입력 영상의 잡음에 민감하며 메모리 낭비의 문제와 수행 속도가 느리다는 단점이 있다. 따라서 여러 부품을 검사하기 위해서는 각 부품마다 알고리즘을 새로 구성해야 되는 번거로움과 복잡함이 있어서 여러 종류의 제품에 적용하기에 부적합하다.

그리고 추론과 인식의 방법으로 인공신경망(Artificial Neural Network), 최근접 분류기(Nearest Neighbor Classifier), SVM(Support Vector Machines) 등이 이용되어 왔다[8]. 그러나 인공신경망은 상호 연결된 뉴런에 의해 연산 기억, 필터, 변환, 분류, 최적화 등의 기능을 수행할 수 있지만 자료가 가지는 시계열 모형의 특징을 기억 구조로서 인공신경망의 학습구조에 도입한 연구는 매우 드물고, 네트워크 학습을 위해서는 많은 시간이 필요하며, 이런 일련의 학습 과정은 새로운 자료가 추가되면 전체 과정을 모두 다시 수행해야 하는 단점을 가지고 있다[9]. 최근접 분류기는 입력 벡터가 주어지면 유사도 함수에 기반하여 참조 집합에서 입력 벡터와 가장 유사한 K개의 벡터를 선택한다. 이 K개의 벡터 이웃들의 레이블과 유사도 값의 분포에 따라 입력 벡터의 클래스를 결정하게 된다. 이는 일반적으로 인식할 대상의 수가 적을 경우 잘 분류되나 인식할 대상의 수가 많아지면 클래스간 특징들의 유사도가 증가하여 인식에 어려움이 따른다[10]. SVM은 선형 분리 가능한 샘플들에 대하여 클래스간의 거리가 최대가 되도록 함으로써 비교적 우수한 성능을 나타낸다. 하지만 영상의 다양성과 복잡성 등의 특징을 효과적으로 인식할 수 있는 방법에 대한 개발이 요구된다[11]. 따라서 본 논문에서는 이들이 가지고 있는 문제점을 해결하기 위하여 부품의 양·불량을 판정하는데 새로운 HTM 이론을 적용하였다.

HTM 이론은 기존의 경험적 탐색을 기본으로 하는 인공 지능(AI)이나 단순 뉴런들의 연결로 보는 인공신경망(ANN)과는 달리, HTM 이론에서는 시스템을 일정한 공통 연산을 수행하는 메모리 노드들을 계층 네트워크(hierarchy network)로 구성한다[4,5]. 이때, 네트워크의 기본 단위인 노드(node)

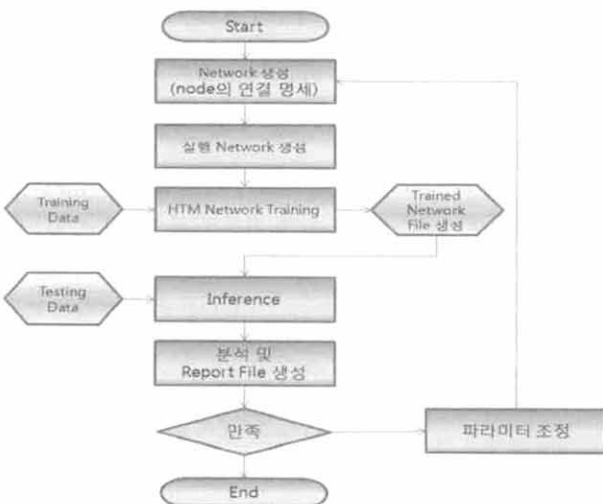
는 6개 층으로 이루어진 신피질(neocortex)의 기본 단위인 신피질 칼럼(neocortex column)에 해당하는 것으로 본다. 이렇게 구성된 HTM 네트워크는 실세계의 시공간적 패턴 정보(특히, 시간 정보)를 이용해 효율적으로 지능적 판단을 할 수 있게 한다. 또한, HTM은 일종의 메모리 시스템으로 HTM에서는 프로그램 되지 않으며 문제마다 다른 알고리즘을 수행하는 것이 아니라 문제를 해결하는 방법을 학습한다. 그리고 학습 과정에서 감각 신호의 특성들 사이의 시공간적 관계성이 계층적 메모리 구조에 형성된다. 이를 위해 외부 감각 데이터에 자신을 노출시키는 방법으로 훈련을 하게 되며, 모델링된 방식의 레벨을 통해 학습된 정보를 저장한다. 학습이 끝나면 새로운 패턴을 인식하게 된다. 보다 상세한 것은 [3,4,5]를 참조하기 바란다.

### 3. HTM 기반의 부품 이미지 인식 시스템

이 장에서는 우리가 개발한 중소기업을 위한 HTM 기반의 부품 이미지 인식 시스템 PRESM(Parts image REcognition System for small scale Manufacture industry)의 개념을 설명한다.

#### 3.1 시스템의 수행 구조

HTM 기술을 이용한 부품 이미지 인식 시스템의 개발은 (그림 1)과 같이 Numenta 사에서 추천하는 절차[5]에 몇 가지를 추가하는 방법을 통해 이루어 졌다. 그림에서 보는 것과 같이 우선 노드 생성과 노드의 연결을 통해 네트워크를 형성한 후 실행 네트워크 생성, HTM 엔진에 학습시킬 훈련 데이터는 사전에 수집된 데이터를 활용하며 HTM 네트워크는 이들을 이용하여 훈련시킨다. 훈련(학습과 추론 기능 이용) 과정을 거친 네트워크 파일이 형성되면 새롭게 인식하고자 하는 테스트 데이터를 입력 데이터로 받아서 인식하고 이를 바탕으로 분석하여 적절한 동작을 수행하



(그림 1) 부품 이미지 인식 시스템의 수행 구조

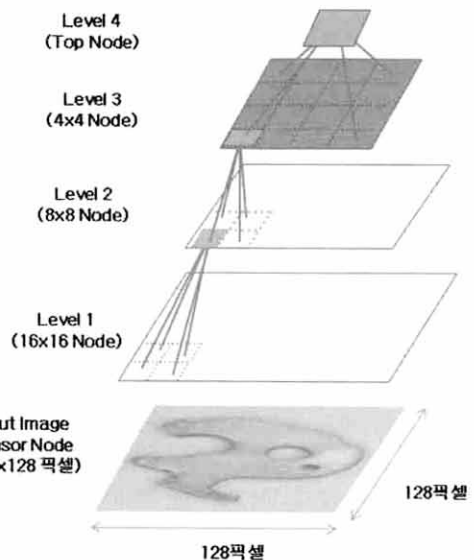
게 된다. 그런데 좋은 HTM 응용이 되기 위해서는 이러한 새로운 데이터의 다양한 인식 실험을 바탕으로 HTM 네트워크의 인식 성능 향상을 위해 여러 가지 파라미터 조정 작업을 거쳐야 한다. 우리는 이를 위해 조정된 HTM 네트워크가 만족한 레벨에 이를 때까지 파라미터를 조정하고 실험을 반복하는 방법을 추가하였다.

#### 3.2 HTM 네트워크 구성

우리는 PRESM을 위해 부품의 한 면을 인식하는 HTM 네트워크를 (그림 2)와 같이 구성하였다. 우리는 이 네트워크 구성으로 앞면 네트워크와 뒷면 네트워크를 구축하여 통합해 PRESM을 완성하였다. 두 개의 네트워크를 구축한 것은 앞면과 뒷면이 확연히 구분되면서 앞면은 정상인데 뒷면이 불량인 경우와 그 반대인 경우가 있기 때문이다. 그리고 각 네트워크는 총 4개의 레벨로 구성하였다. 여기서 각 노드는 하나의 사각형으로 표현되어 있다. 가장 아래의 센서 노드는 이미지 센서로서 외부의 데이터를 입력받게 되고, Zeta1 노드[4,5]들로 구성된 가장 아래 레벨 1로 입력된다.

네트워크에서 가장 높은 레벨의 노드는 한 개로 이루어져 있으며, 이는 Zeta1 노드와 유사하지만 외부로 출력을 보내는 효과(effector) 노드와 연결시키기 위해 특수 기능을 담당하는 Zeta1Top 노드[4,5]가 된다. 이렇게 하여 HTM 네트워크는 레벨 별로 1개, 16개, 64개, 256개의 노드로 구성하였다. 센서 노드를 통해 들어오는 입력 이미지의 크기는 128x128 픽셀로 이루어져 있다. 이는 레벨 1의 16x16개 노드 각각에 64(8x8) 픽셀로 반영되어 사상(mapping)하게 하였다.

높은 레벨에서의 각 노드는 낮은 레벨의 여러 노드들로부터 입력을 받게 된다. (그림 2)의 레벨 2의 노드는 레벨 1의 4(2x2)개의 결과들로부터 입력을 받는 것을 나타낸 것이다. 이렇게 자식 노드들의 결과를 입력으로 받아들이는 과정을



(그림 2) HTM 네트워크의 구성

거치면 가장 높은 레벨에서의 노드는 전체 이미지 영역을 한 번에 인식하게 된다.

3.3 학습과 추론

HTM 네트워크의 동작은 크게 학습과 추론 단계로 이루어진다[5]. 학습은 HTM 네트워크에서 레벨(level) 별로 이루어진다. 각 레벨의 노드들은 입력되는 패턴들에 대하여 공간적으로 상대적인 위치와 시간적으로 동시발생(coincidence)의 행렬을 생성하고 이를 정량화한다. 그리고 이들 패턴들을 그룹 지음으로써 학습을 완료한다. 레벨별로 학습이 완료되면 입력 데이터들에 대해 추론하는 추론(inference) 단계로 이행된다. 추론 단계에서는 입력 패턴에 대하여 학습 단계에서 학습한 동시발생의 그룹들에 대한 믿음 분포를 발생시킨다. 이렇게 하여 네트워크의 모든 노드들이 전체적으로 학습이 완료된 HTM 네트워크가 완성된다. 이제 이를 이용하여 새로운 입력 데이터들에 대하여 인식(recognition)하게 된다. 인식과정은 최상위 레벨의 추론 과정으로 다른 레벨과 다르게 카테고리 센서(category sensor)로부터 제품들의 범주(category)를 입력받아 추론에 이용한다. 즉, 새롭게 입력된 제품 이미지 패턴을 범주(category)들에 대하여 확률분포를 발생시켜 확률적으로 높은 범주에 사상(mapping)시킨다. 이로써 제품을 인식하여 구분 짓게 된다. 제품들의 범주에는 양품과 불량품의 종류를 모두 포함하고 있어서 양품과 불량품을 종류별 구분이 가능하다.

3.4 파라미터 결정

HTM 네트워크가 최대의 정확도를 얻기 위해 우리는 여러 가지 파라미터들 중 먼저 최대 거리와 시그마 파라미터 값을 조정하여 실험하였다.

최대거리(max distance)는 하나의 기준 센서로부터 원본 이미지와 비교 대상인 입력 이미지의 벡터 사이의 유클리디안(Euclidean) 거리의 최대값이다. 이는 학습하는 동안에 입력된 데이터 벡터들이 한 기준점에서 최대 거리 값을 설정하면 입력되는 이미지 센스의 벡터들의 거리를 각각 계산하여 이것과 비교하게 된다. 최대 거리의 값보다 작을 경우 같은 동시발생으로 취급하고, 이 최대거리 보다 클 경우에 새로운 동시발생으로 취급한다. 따라서 최대 거리를 크게 설정해 줄 경우, 속도는 빠르지만 정확한 비교는 어렵다. 대신 최대 거리를 작게 설정할수록 학습 속도는 느리지만 좀더 정확한 비교를 할 수 있다. 뚜렷이 구분이 되는 이미지를 인식하는 응용에서는 비교적 최대 거리 값이 커야 높은 정확도를 나타낸다. 반면에 미세한 차이를 보이는 이미지를 구별해 내는 응용에서는 최대거리 값이 작아야 된다.

시그마(sigma)는 추론 과정에서 필요한 파라미터로서 동시발생 사건의 정규 분포의 표준편차이다. 이는 동시에 발생하는 경우의 수의 범위를 지정한다. 이 값이 작은 것은 동시발생 사건이 밀집되어 있음을 의미하며, 큰 값은 넓게 분포함을 뜻한다. 대개 추론시 잡음이 많은 이미지일 경우는 이 값을 크게 설정하고, 깨끗한 이미지일 경우는 이 값을

작게 설정하면 정확도가 높게 나타난다.

우리가 추론 과정에서 사용한 이미지 데이터는 미세한 차이로 불량품이 판정되는 이미지로서 주위 환경에 의해 잡음도 있는 이미지이다. 따라서 정확도를 높이기 위해 적당한 시그마를 설정하는 것이 중요하다. 또한, 우리는 훈련 데이터의 수가 정확도에 미치는 영향을 알아보기 위해 양품 대 불량품의 비율을 다르게 하여 실험하였다. 그 결과들은 다음 4장에서 보다 상세하게 알아본다.

3.5 훈련 데이터와 테스트 데이터

PRESM의 훈련에 사용한 데이터는 두 종류의 부품에 대하여 양품의 앞·뒷면 이미지와 불량품을 종류별로 수집하여 앞·뒷면의 이미지를 카메라로 찍어서 만들었다. 그 이미지는 128×128 픽셀 크기의 그레이스케일의 bmp 포맷이다. 이 시스템의 인식 정확도를 확인하기 위하여 여러 방향의 회전과 위치 변화를 시켜 새롭게 촬영한 이미지를 테스트 데이터로 사용하였다.

이는 제품이 (그림 3)와 같은 부품 제조 라인의 컨베이어 벨트 위에서 연속적으로 나오는 제품의 이미지를 실시간으로 촬영하여 128 × 128 픽셀로 잘라(crop)낸 것이다. 아래 (그림 4)은 이러한 데이터들의 실제 예들이다.



(a) 카메라 (b) 컨베이어 벨트 (c) 전체 설비

(그림 3) 부품 제조 라인

4. 구현 결과 및 분석

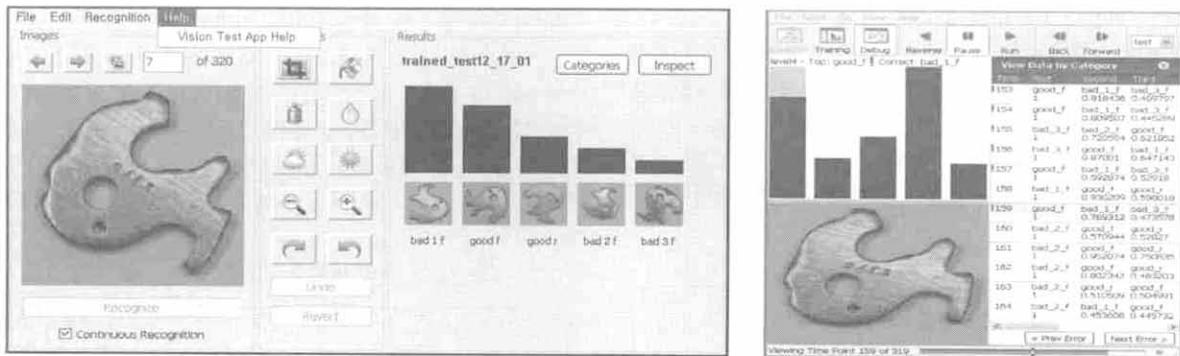
이 장에서는 개발된 PRESM의 구현 결과를 보이고, 그것의 여러 가지 실험 결과와 분석에 대하여 설명한다. (그림 4)의 제품 유형 1에 대해서 실험을 수행한 결과이다.

4.1 구현 결과

개발된 PRESM의 구현 환경은 크게 3가지로 이루어져 있다. Windows XP를 기본 운영 체제로 구성하였고, HTM 엔진인 NuPIC 1.6.1과 Vitamin D 툴킷[6]을 이용하였으며, Python 2.5 언어를 사용하였다. (그림 5)은 PRESM의 인식 결과 화면이다. 오른쪽 그림은 입력된 테스트 이미지 데이터에 대해 학습된 이미지의 추론 결과를 그래프로 나타내며, 왼쪽 그림은 오류를 검정하는 과정으로 파라미터를 수정한 후 추론결과를 보이는 화면이다. 추론 결과가 막대그래프로 표현되어 인식물을 쉽게 확인할 수 있다.

			제품 유형 1 이미지	제품 유형 2 이미지
훈련 데이터	양품	앞면		
		뒷면		
	불량품	앞면 (3종류)		
		뒷면 (3종류)		
테스트 데이터	양품	앞면		
		뒷면		
	불량품	앞면 (3종류)		
		뒷면 (3종류)		

(그림 4) 훈련 및 테스트 데이터의 실제 예



(그림 5) PRESM 학습 결과 화면

4.2 최대거리 변화에 따른 실험 결과

최대거리 파라미터를 변경하여 가장 최적의 수치를 찾아 보았다. 이 실험을 위해 훈련 데이터로 먼저 훈련한 후에 테스트 데이터를 양품의 앞·뒷면(good\_f, good\_r), 불량품의 앞면 세 종류(Bad\_1\_f, Bad\_2\_f, Bad\_3\_f)를 사용하여 최대거리 파라미터를 변경시키면서 실험하였다. 최대거리의 값의 폭을 적게 변화시키는 실험을 수행하였다. 이는 불량품과 양품이 미세하게 차이가 나므로 최대거리의 값이 작을 때 정확도가 높을 것이라는 가정에서였다. 그 결과는 <표 1>에 나타나 있다.

최대거리 값을 변화시키면서 실험해 본 결과, 위 <표 1>

<표 1> 최대거리 변화에 따른 정확도 (단위 : %)

maxdistance	Bad_1_f	Bad_2_f	Bad_3_f	Good_f	Good_r	Average
1200	29.0	95.0	30.0	93.0	99.0	69.2
1300	37.0	97.0	39.0	90.0	100	72.6
1400	36.0	96.0	39.0	92.0	99.0	72.4
1500	44.0	96.0	31.0	95.0	99.0	73.0
1600	48.0	96.0	37.0	90.0	97.0	73.6
1700	33.0	97.0	33.0	92.0	100	71.0
1800	34.0	92.0	32.0	94.0	100	70.4
1900	37.0	94.0	31.0	88.0	100	70.0
2000	36.0	94.0	31.0	88.0	100	69.8



에서 보는 바와 같이 최대거리가 1,600일 때 평균적으로 정확도가 가장 높은 것으로 나타났다.

4.3 시그마 값에 따른 실험 결과

우리는 최대거리를 가장 정확도가 높은 1,600으로 적용하여, 시그마 값을 변화시켜 가면서 실험을 수행하였다. 그 결과를 <표 2>에 나타내었다.

위의 결과에 의하면 시그마 값이 100일 때 평균적으로 가장 높은 정확도를 보였다.

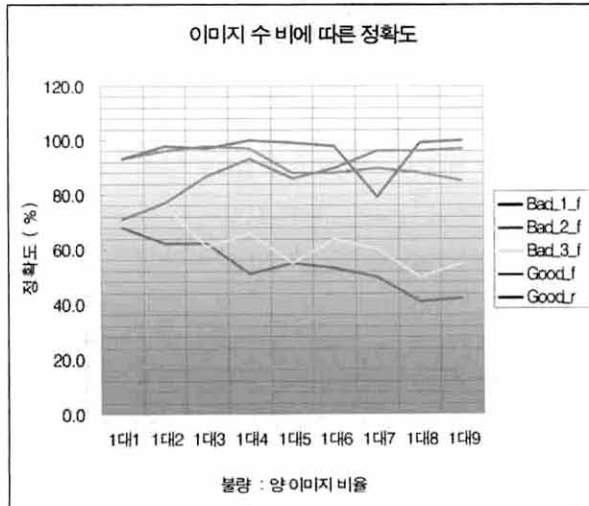
<표 2> 시그마 값에 따른 정확도 (단위 : %)

Sigma Category	20	30	40	50	60	70	80	90	100	110	120	130
bad_1_f	32.0	38.0	53.0	39.0	45.0	59.0	49.0	51.0	53.0	51.0	52.0	53.0
bad_2_f	90.0	98.0	98.0	96.0	97.0	97.0	97.0	97.0	94.0	88.0	94.0	93.0
bad_3_f	29.0	45.0	45.0	54.0	65.0	61.0	69.0	66.0	68.0	72.0	67.0	64.0
good_f	82.0	91.0	91.0	93.0	90.0	91.0	91.0	93.0	94.0	95.0	95.0	94.0
good_r	90.0	96.0	97.0	97.0	99.0	97.0	98.0	100	99.0	100	100	100
Average	64.6	73.6	76.8	75.8	79.2	81.0	80.8	81.4	81.6	81.2	81.6	80.8

4.4 이미지 수의 비에 따른 실험 결과

학습의 의미를 보면 많이 보고 많이 배운 것일수록 정확도가 높은 것처럼 두뇌의 학습 원리를 기계로 한 HTML 엔진은 "학습에 사용된 이미지의 수가 많으면 정확도가 높을 것이다."라는 가정에서 불량품의 비율을 1(이미지 개수로는 60개)로 하고 양품의 비율을 높여가면서 실험을 수행하였다. 그 결과는 다음 (그림 6)과 같다.

일반적으로 공장에서 제품이 생산될 때 양품이 많이 생산되고, 불량품이 적게 생산된다. 하지만 양품을 불량품으로 판정할 가능성이 있다. 이런 경우에 양품을 불량품으로 판정하는 경우가 많아짐으로써 기계의 가동을 자주 정지시키는 일이 발생할 수 있다. 따라서 양품의 판정은 거의 100%



(그림 6) 이미지 수 비에 따른 정확도

에 가깝게 만들 필요가 있다. 이에 대한 실험 결과 양품 대 불량품의 비율이 1 : 4 정도가 적합한 것으로 판단된다. 이 비율은 양품의 정확도를 높일 뿐만 아니라 다른 불량품의 정확도도 높였다.

4.5 두 개의 네트워크 실험 결과

우리는 양·불량을 판정하는 정확도를 높이기 위하여 앞에서 밝힌 것과 같이 앞면과 뒷면의 두 가지 HTML 네트워크를 구성하였다. 그래서 두 네트워크 각각에 대해 실험을 수행하였다. 그리고 그 결과를 조합하여 양·불량을 판정하는 판정식을 만들었다. 이 판정식으로 판정한 결과의 정확도를 <표 3>에 나타내었다.

최종적으로 정리하면 PRESM에 대해 가장 정확도가 높은 파라미터는 최대거리의 수치가 1,600인 경우에 전체적으로 정확도가 높았으며, 시그마 수치 중에 100인 경우가 가장 정확도가 높았다. 그리고 양품과 불량품의 비율은 4 : 1 정도로 하는 것이 정확한 판정을 하는데 유리했다. 이렇게 하여 전체적으로 각 카테고리별로 정확도가 약간 낮은 것이 있었으나, 양·불량 판정은 두 개의 네트워크로 판정한 것을 조합하는 식에 의하여 판정한 결과로 90% 이상의 정확도를 보였다. 실제 현장에서는 두세 번 이상 계속해서 불량 이 일어났을 때 프레스를 점검하는 등의 대처를 할 수 있기 때문에, 이러한 시스템의 성능 결과만으로도 큰 효과를 볼 수 있어 매우 유용한 시스템임이 확인되었다. 그러나 Bad\_1\_f, Bad\_3\_r과 같이 외형이 사람의 눈으로 구분이 어려운 것은 정확도가 56%, 68% 정도로 낮아 이에 대한 보완의 여지가 있음을 확인하였다. 이것은 향후 과제로 남긴다.

그리고 하나의 프레스에서 다른 종류의 제품이 생산 될 경우를 가정하여 (그림 4)의 제품 유형 2의 이미지에 대한 실험을 제품 유형 1과 동일한 방법으로 학습과 추론 과정을 거쳐 인식하는 방법으로 양·불량 판정을 하는 실험을 수행하였다. 이의 결과 또한 제품 유형 1과 비슷한 결과를 얻었다.

<표 3> 두 개의 네트워크 판정식과 그 결과 정확도

판정식	카테고리	한 개의 네트워크로 판정	두 개의 네트워크로 판정
양품 판정 식 : Lf : 앞면 Network, Lr : 뒷면 Network 결과 값 if (Lf=Good_f And Lr=Good_f) or (Lf =Good_r and Lr=Good_r) then Good else Bad  불량품 판정 식 : if (Lf =Good_f And Lr=Bad_*) then 뒷면 불량 else if (Lf =Bad_* and Lr=Good_r) then 앞면 불량 else 앞,뒷면 모두 불량	Bad_1_f	58.00%	56.00%
	Bad_1_r	91.00%	91.00%
	Bad_2_f	97.00%	99.00%
	Bad_2_r	96.25%	99.38%
	Bad_3_f	58.00%	68.00%
	Bad_3_r	90.00%	91.88%
	Good_f	92.00%	92.00%
	Good_r	98.68%	98.68%

〈표 4〉 기존 시스템과 비교

	PRESM	자동 너트 검사 장비[1]
설치 및 운용 용이성	사용자가 시스템을 학습시켜 사용함	특정 부품에 맞게 전문가가 설치해야 됨
프로그램 방법 및 설치	부품의 종류에 관계없이 사용 가능	특정 부품에 맞는 프로그램 작성
여러 종류의 부품 사용	그대로 사용 가능	새롭게 시스템 설계를 해야 됨
부품의 종류 변화에 따른 추가 비용	추가 비용이 없음	새로운 프로그램 비용 부담
처리 속도	부품에 관계없이 양·불량 판정 시간은 약 400ms	부품의 종류에 따라 달라짐

5. 기존 연구와의 비교

지금까지 다양한 기법을 바탕으로 다양한 응용에 적용한 (번호판, 얼굴, 너트 장비 등) 이미지 인식 시스템들이 있었으나[1, 8, 9, 10, 11, 12], 생산 현장에서 부품 이미지를 인식하여 양·불량품을 판단하는 이미지 인식 시스템은 “자동 너트 검사 장비”[1] 외에는 찾아보기 힘들다. 그런데 [1]의 경우도 특정 부품에 적용할 수 있는 방법으로, 실제 중소기업의 가변 환경에서 사용할 수 있기 위해서는 실시간으로 소량 다품종 부품을 인식할 수 있는 기능이 필요하다. 우리는 이러한 기능을 갖도록 하기 위해서 HTM 기술을 적용한 부품 이미지 인식 시스템을 개발하였다. 여기서는 개발한 PRESM 시스템을 적용성과 효율성의 측면에서 “자동 너트 검사 장비”[1]와 비교해 본다. 우선 우리 시스템은 “자동 너트 검사 장비”에 비해 생산되는 부품의 종류가 바뀌는 순간 제품의 이미지를 수집, 학습, 추론하는 과정을 통해 바로 적용이 가능하여, 다품종 소량 생산의 소규모 공장의 중소기업의 가변 환경에서 보다 적응력이 좋다. 그리고 부품 교체시도 거의 추가 비용이 들지 않으며, 설치된 시스템을 변화 없이 그대로 사용 가능하다. 또한, 일반 PC에 카메라를 부착하여 사용하기 때문에 설치비용이 저렴하며, 사용자가 상황에 맞게 파라미터를 임의로 조정하여 정확도를 높일 수 있도록 하여 효율적으로 시스템을 운용할 수 있다. 뿐만 아니라 학습 후에는 부품에 대한 양·불량 판단이 네트워크를 통해 아래에서 위로 몇 단계(우리의 시스템에서는 3단계)의 레벨로 전파되어 추론이 이루어지기 때문에 매우 빠르게 가능하여 실시간 현장에서 활용할 수 있다. 요약하여 아래 <표 4>에 간단하게 정리해 보았다.

6. 결론 및 향후 과제

지금까지 우리는 HTM 기반의 부품 이미지 인식 시스템(PRESM)의 개발을 보이고 실제 데이터를 이용한 실험 결과를 분석하였다.

소규모 제조업 공장에서는 생산되는 여러 가지 부품에 대해 적합하고 쉽게 주문형으로 부품의 양·불량 판단이 가능한 시스템의 개발이 필요하다. 이러한 공장 환경에서의 부품 이미지 인식은 여러 종류의 부품들에 대해 다양하게 왜곡된 데이터에 대해서도 강건하면서도 인식률이 높아야 한다. 이를 위해서 우리는 인간의 지능 즉, 신피질(neocortex)

의 작동 기제를 흉내 낸 HTM 기술을 이용하여 적절한 HTM 네트워크를 구성하고, 인식률에 영향을 미칠 수 있는 각종 파라미터 값들을 실험을 통해 조절하여 적합한 시스템을 개발하였다. 개발된 PRESM은 가변적인 이미지가 흔히 입력되는 실제 현장 환경에 적용한 결과 인식의 정확도가 높게 나타났다. 그리고 각 공장마다 생산되는 부품의 이미지를 종류별로 수집하여 각각에 대하여 학습, 훈련, 추론을 거쳐 인식하므로 각 공장별로, 생산 부품이 다르더라도 이에 적합한 시스템으로 쉽게 개발을 할 수 있었다. 따라서 이 시스템은 소규모로 여러 종류의 부품을 생산하는 공장의 작업장에서 동일한 시스템을 사용할 수 있어서 생산되는 부품의 종류에 바뀌어도 추가 비용이 들지 않는다. 뿐만 아니라 사용자가 상황에 맞게 파라미터를 임의로 조정하여 정확도를 높일 수 있도록 하여 효율적으로 시스템을 운용할 수 있다.

향후 더 많은 데이터 수집 및 실험으로 다양한 부품 이미지들의 인식에 대한 정확도를 높이는 작업이 필요하며, 일반 사용자가 보다 쉽게 주문형으로 부품 이미지 인식 시스템을 구축해 활용할 수 있도록 하는 사용자 학습 시스템의 개발도 필요하다. 또한, 소리나 온도 센스에서 보내온 정보를 본 HTM 기반의 이미지 인식 시스템에 접목하는 연구가 이루어 질 경우 더욱 정확도가 높은 인식 시스템이 될 것으로 기대된다.

참 고 문 헌

- [1] 이상학, 서명호, 정태충, “이미지 프로세싱을 이용한 자동 너트 검사 장비 개발”, 정보처리학회논문지A, 제11-A권 제4호, pp.235-242, 2004, 4.
- [2] Jeff Hawkins, ‘OnIntelligence’, New York, Henry Holt, 2005.
- [3] Jeff Hawkins, Dileep George, “Hierarchical Temporal Memory”, Numenta, Inc., March, 2007.
- [4] Numenta Inc., “Numenta Platform for Intelligent Computing”, June, 2008.
- [5] Dileep George and Bobby Jaros, “The HTM Learning Algorithms”, Numenta Inc., March, 2007.
- [6] Vitamin D, Inc., “Vitamin D Toolkit Reference Guide”, June, 2008.
- [7] Y. Ke, and R. Sukthankar, “PCA-SIFT: A More Distinctive Representation for Local Image Descriptors,” IEEE CVPR,

Vol. 2, pp.506-513, 2004.

- [8] 장경식, "얼굴의 특성을 반영하는 휴리스틱 평가함수를 이용한 얼굴 특징 검출", 정보처리학회논문지B, 제8-B권 제2호, pp.183-184, 2001, 4.
- [9] 방걸원, 강대욱, 조완현, "킬러정보와 오류역전과 알고리즘을 이용한 교통표지판 인식", 정보처리학회논문지D, 제14-D권 제7호, pp.809-818, 2007, 12.
- [10] 유승훈, 김덕환, 이석룡, 정진완, 김상희, "윤곽선 이미지 피라미드와 관심영역 검출을 이용한 SIFT 기반 이미지 유사성 검색", 한국정보과학회논문지, 데이터베이스 제35권 제4호, pp.345-355, 2008, 8.
- [11] 장승주, 신병철, "ACL 알고리즘을 이용한 자동차 번호판 영역 추출에 대한 연구", 정보처리학회논문지D, 제9-D권 제6호, pp.1113-1118, 2002, 12.
- [12] 권혁봉, 권동진, 장인동, 윤영복, 안재형, "YCbCr 색공간에서 피부색과 윤곽선 정보를 이용한 얼굴영역 검출", 한국멀티미디어학회논문지, 제7권 제1호, pp.27-34, 2004, 1.
- [13] 송근원, "얼굴인식 기술 및 동향", 한국멀티미디어학회지, 제7권 제2호, pp.1-8, 2003, 6. 전자공학회논문지, 제43권 CI편 제3호, pp.30-38, 2006, 5.



### 배 선 갑

e-mail : bsgap@hanmail.net  
 1987년 경북대학교 물리학과(학사)  
 2004년 경상대학교 컴퓨터과학과(석사)  
 2006년~현 재 경상대학교 컴퓨터과학과 박사과정  
 관심분야: 패턴인식, 지능시스템, 내장형 데이터베이스



### 이 대 한

e-mail : neokshacker@nate.com  
 2004년 경상대학교 컴퓨터과학과(학사)  
 2007년~현 재 경상대학교 컴퓨터과학과(석사)  
 관심분야: XML, 데이터베이스 통합, 기계학습



### 조 건 화

e-mail : diaoxiaoxiao@hotmail.com  
 2004년 중국 안산과학대학 컴퓨터과학과(학사)  
 2006년 경상대학교 컴퓨터과학과(석사)  
 2006년~현 재 경상대학교 컴퓨터과학과 박사과정

관심분야: Intelligence, Embedded DB, XML, MPEG-7



### 남 해 보

e-mail : nanhaibao666@hotmail.com  
 2007년 중국 길림북화대학 컴퓨터과학과(학사)  
 2007년~현 재 경상대학교 컴퓨터과학과 석사과정  
 관심분야: Intelligence, Image Processing, Patten Design, JSP



### 성 기 원

e-mail : sungkw@tisys.co.kr, union25@nate.com  
 1996년 창원대학교 산업공학과(학사)  
 1998년 창원대학교 산업공학과(공학석사)  
 2001년 창원대학교 산업공학과 박사 이수  
 1995년~1995년 KIMM 연구소 위촉연구원  
 1998년~1999년 창원대학교 산업기술연구소 전임연구원  
 1998년~2001년 창원대학교 산업공학과 시간강사  
 1999년~2004년 (주)현세시스템 컨설팅 팀장  
 2004년~현 재 (주)TIS SI사업팀 팀장  
 2006년~현 재 창원대학교 산업시스템공학과 겸임교수  
 관심분야: 인공지능, ERP, SCM, CALS, ILS 등



### 배 종 민

e-mail : jmbae@gnu.ac.kr  
 1980년 서울대학교 수학교육과(학사)  
 1983년 서울대학교 계산통계학과(석사)  
 1985년 서울대학교 계산통계학과(박사)  
 1982년~1984년 한국전자통신연구소 연구원  
 1997년~1998년 Virginia Tech. 객원연구원  
 1984년~현 재 경상대학교 컴퓨터과학부 교수  
 관심분야: XML, 데이터베이스 통합, 기계학습



### 강 현 석

e-mail : hskang@gnu.ac.kr  
 1981년 동국대학교 전자계산학과(학사)  
 1983년 서울대학교 전산학과(석사)  
 1989년 서울대학교 전산학과(박사)  
 1981년~1984년 2월 한국전자통신연구원 연구원  
 1984년~1993년 2월 전북대학교 전임강사, 부교수, 교수  
 1993년~현 재 경상대학교 컴퓨터과학부 교수, 컴퓨터정보통신 연구소 연구원  
 관심분야: 멀티미디어, 내장형 데이터베이스, 지능시스템