

# 신경회로망을 이용한 측정 점으로부터 특징형상 인식

전용태\*, 박세형\*

## Geometric Feature Recognition Directly from Scanned Points using Artificial Neural Networks

Yongtae Jun\* and Sehyung Park\*

### ABSTRACT

Reverse engineering (RE) is a process to create computer aided design (CAD) models from the scanned data of an existing part acquired using 3D position scanners. This paper proposes a novel methodology of extracting geometric features directly from a set of 3D scanned points, which utilizes the concepts of feature-based technology and artificial neural networks (ANNs). The use of ANN has enabled the development of a flexible feature-based RE application that can be trained to deal with various features. The following four main tasks were mainly investigated and implemented: (1) Data reduction; (2) edge detection; (3) ANN-based feature recognition; (4) feature extraction. This approach was validated with a variety of real industrial components. The test results show that the developed feature-based RE application proved to be suitable for reconstructing prismatic features such as block, pocket, step, slot, hole, and boss, which are very common and crucial in mechanical engineering products.

**Key Words :** Reverse Engineering (역 공학), Feature (특징형상), Artificial Neural Networks (신경회로망)

### 1. 서론

실제 산업현장에서 도면정보가 존재하지 않은 물품을 재 생산해야 하는 경우가 자주 발생한다. 물품의 외관을 측정하여 얻어진 측정 데이터로부터 물품의 CAD 정보를 생성하여 물품을 재 생산(reconstruction)하는 과정을 역공학(reverse engineering)이라 한다. 특히, 역공학은 다음 상황들에 필수 불가결한 기술이다 [1,2].

- 초기 물품 설계시 CAD 시스템을 사용하지 않았을 때;
- 재 생산되어야 될 물품의 CAD 정보가 손실 또는 훼손되었을 때;
- 물품의 형상이 제조 단계에서 수정되어 처음

CAD 정보와 다르게 되었을 때;

- 협력업체에서 공급되던 물품이 더 이상 공급되지 못할 때;
- 문화재 또는 인체와 같이 애초에 CAD 정보가 없는 형상을 재 구성할 때.

위와 같은 상황에서 작업자는 삼차원 측정기를 이용하여 물품의 외관을 측정한 후, 얻어진 측정데이터로부터 적절한 CAD 모델을 구성한 다음에 최종적으로 원 형상과 똑 같은 복제품(replica)을 만들게 된다.

특징형상(feature)은 생산품의 중요한 공학적인 의미를 내포하고 물품의 생산 과정과 직접적으로 관련되어 있으므로 공정설계 또는 가공정보 산출에 필수적인 정보를 제공한다. 특징형상에 관한

\* 한국과학기술연구원 CAD/CAM 연구센터

기존의 연구<sup>[1,3,4]</sup>는 block, pocket, step, slot, hole 과 boss 와 같이 공학적인 기본 형상들을 특징형상이라 정의하여 각주형 물품을 설계/가공하는 기본 요소 (instances)로서 이용하였다. 특징형상은 기하학적으로 의미 있는 몇 개의 매개변수로 표현될 수 있다. 예를 들어, 원통 특징형상은 길이, 중심좌표, 방향 (orientation) 벡터, 윗면과 아랫 면의 반지름으로 표현된다.

측정 점으로부터 직접 특징형상을 인식하면 다음과 같은 장점들을 갖게 된다<sup>[11]</sup>.

- 상용화된 특징형상 기반 모델러 (feature-based modeler) 와 직접적인 데이터 호환이 가능하므로 추출된 특징형상 정보를 공정설계, 조립해석, 강도해석, 또는 가공정보 산출에 적용할 수 있다.
- 재 구성된 특징형상으로부터 원 CAD 모델과 가공된 모델의 차수를 비교하여 가공 공정을 보정 (calibration) 하기가 수월하다<sup>[2,5]</sup>.
- 역공학 공정을 자동화할 수 있는 토대를 마련할 수 있다<sup>[3]</sup>.

3 차원 측정 장비를 통해 입력 받은 데이터에는 원천적으로 노이즈 (noise) 를 수반하며, 초기 측정 점들의 공간상의 연결 관계를 나타내주는 위상정보를 알지 못하는 상태이다. 이러한 불 완전한 측정 데이터로부터 특징형상을 추출하기 위해서 본 연구에서는 신경회로망을 이용하였다.

신경회로망의 대표적인 특징은 다음과 같다:

- 복잡한 입력 데이터의 패턴 (pattern) 특성을 찾아낼 수 있다.
- 입력데이터가 불 완전하거나 노이즈가 포함되어도 출력 값을 적절하게 추론할 수 있다.
- 일단 학습이 된 회로망은 계산과정이 병렬적으로 수행되므로 계산 속도가 아주 빠르다.

기존의 순차적인 (procedural) 알고리즘은 문제를 풀기위한 명령문과 변수 값이 단계적으로 수행되고 결정된다. 그러나, 신경회로망은 학습 (training) 을 통하여 문제를 풀 수 있는 능력이 배양되며 문제를 병렬 처리하여 해결한다. 따라서, 신경 회로망은 기존의 순차적 계산방법으로는 풀기 어려운 복잡한 입력 값들의 패턴을 구하는 문제에 적용시킬 수 있다.

## 2. 관련연구

지금까지의 RE 기술은 주로 자유곡면 형상에 집중적으로 적용되어 왔다<sup>[6,7]</sup>. 최근 들어 각주 형상 (prismatic shape) 을 갖는 물품에도 역공학 기술을 적용하려는 관심이 고조되어 측정데이터로부터 직접적으로 3D 솔리드 (solid) 모델을 생성하려는 시도가 있었지만 그 결과는 아직 미미한 실정이다<sup>[1,8,10]</sup>.

2 차원 정보로부터 3 차원 CAD 모델을 구성하는 연구는 오래 전부터 수행되어서 2 차원 도면으로부터 3 차원 CAD 모델을 구성할 수 있는 알고리즘들이 제안되었다. Ballard, D.<sup>[9]</sup> 은 생산품의 수직 2 차원 영상을 (orthographic views) 로부터 특정 형상을 인식하는 시스템을 제안하였으며, Motavalli, S.<sup>[10]</sup> 은 스테레오 매칭 (stereo matching) 기법을 이용한 자동 3 차원 모델링 기법을 발표하였다. Thompson, W.<sup>[11]</sup> 등은 가공 특징형상을 기본 형상 (primitive) 으로 하는 RE 시스템 (feature-based RE system) 을 제안하였지만 제안된 시스템은 사용자의 interaction 에 크게 의존하고 있다.

특징형상 인식을 위해 신경회로망 기법을 이용한 연구들은 다음과 같다. Prabhakar, S.<sup>[11]</sup> 등은 B-rep 모델에 처음으로 신경회로망을 도입하였는데, 신경회로망의 입력데이터로서 adjacency matrix 를 이용하였다. Gu, P.<sup>[12]</sup> 는 신경회로망을 도입하여 형상의 일부분이 훼손된 자유곡면 물품을 복원하였는데, 수학식으로부터 추출된 점들을 채택하여 학습정보로 이용하였다. Nezis<sup>[13]</sup> 등은 일련의 휴리스틱 (heuristics) 을 신경회로망과 결합시켜 복합 (compound) 특징형상을 기본 특징형상들로 분해하여 인식하였다.

## 3. 방법론

그림 1 은 본 연구에서 제안한 전체적인 방법론을 보여준다. 먼저 적절한 측정계획에 의하여 물체를 측정한 뒤, 얻어진 측정 점들을 개발된 시스템에 다운로드 한다. 각각의 측정 점들은 서로의 위상정보가 없는 상태이므로 측정 점들과 측정 점으로부터 인식될 특징형상 사이의 관계를 얻기 위해 에지 (edge) 점들을 찾아낸다. 또한, 초기 측정 데이터들은 필요 이상으로 조밀하게 측정되기 때문에 시스템 효율을 위해서 전체 데이터 크기를

줄이는 것이 바람직하다. 본 연구에서도 중첩되어 있는 측정 점들을 주어진 공차한도 (tolerance) 내에서 제거하는 샘플링 (sampling) 작업을 하도록 하였다.

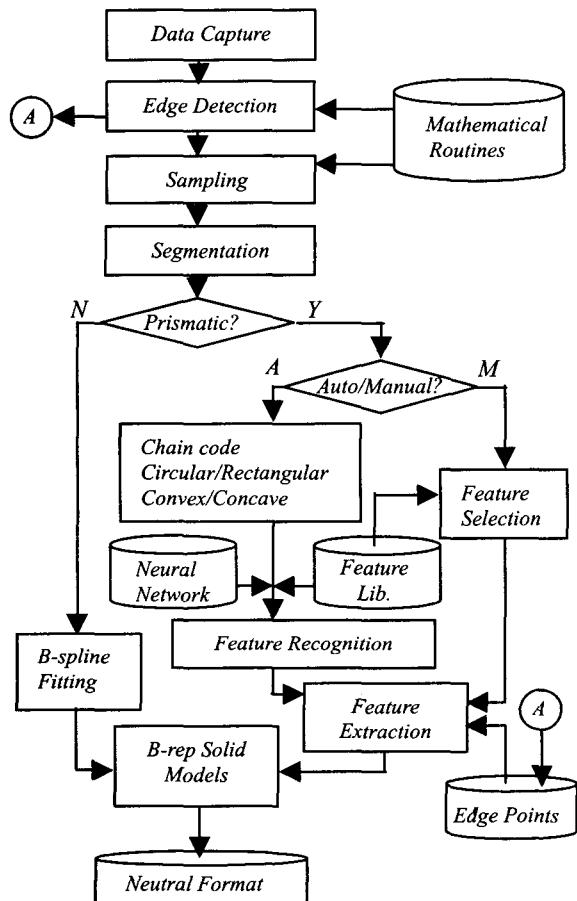
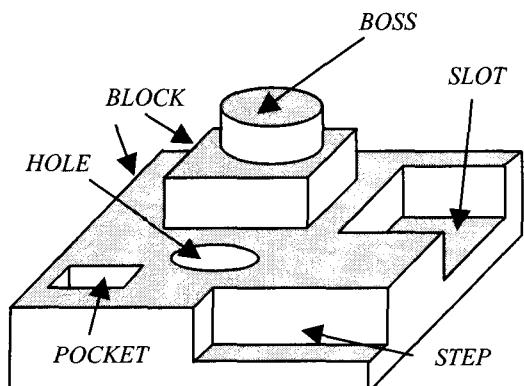
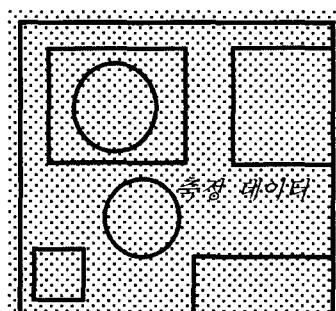


Fig. 1 Research Methodology for the proposed system

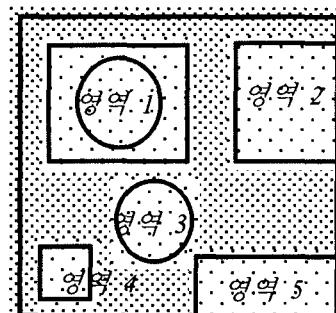
물품 내의 각각의 특징형상은 해당되는 측정 점들과 일대일 대응될 수 있도록 개별 영역 (region)으로 분류하는 것이 좋은데 이는 한 개의 영역이 한 개의 특징형상으로 대응되면 특징형상을 인식하는 과정이 상대적으로 수월해지기 때문이다. 이와 같이, 초기 측정 데이터들을 특징형상에 따라 개별 영역으로 분류하는 작업을 세그멘테이션 (segmentation) 이라 한다. 예를 들어, 그림 2 (a) 와 같은 형상을 갖는 물품의 초기 측정 데이터가 그림 2 (b) 와 같은 때 세그멘테이션 작업이 적절히 수행된 결과가 그림 2 (c) 에 나타나 있다.



(a) 3D view of an example part



(b) before segmentation



(c) after segmentation

Fig. 2 Segmentation process

현재까지 세그멘테이션 작업은 사용자가 수동으로 수행하고 있는데, 이는 자동화하기에는 시간이 아주 오래 소요되며 측정 점에 포함된 노이즈를 적절히 처리할 수 없기 때문이다. 세그멘테이션 과정을 자동으로 처리하는 연구는 본 연구팀에 의해 현재 진행되고 있다.

각각의 세그멘테이션 작업이 완료되면 영역

내의 형상 속성정보가 계산되어진다. 계산된 속성 정보는 신경회로망에 입력되고 신경회로망은 자동적으로 특징형상의 종류를 출력하게 된다. 인식된 특징형상의 길이, 폭, 높이, 지름 등의 치수 값들은 측정 점들의 위치정보로부터 추출된다.

#### 4. 측정 점 전 처리 과정 (Pre-processing)

##### 4.1 Edge detection

애지 점은 영역 사이들의 경계이거나 한 개의 특징형상 내의 예리한 불연속 점들을 말한다. 이러한 애지 점들의 정보로부터 특징형상이 인식되고 추출되기 때문에 애지 점 인식은 본 연구에서 매우 중요한 과정이다. 애지 점은 크게 sharp 애지와 smooth 애지로 구분될 수 있다. Sharp 애지는 불연속 접선 벡터의 유무를 추적하여 찾을 수 있으며 smooth 애지는 곡률 (curvature)의 변화율을 조사하여 구할 수 있다<sup>[2]</sup>.

##### 4.2 측정 점 샘플링 (Sampling)

측정 점의 수가 필요 이상으로 조밀하면 시스템 효율이 저하되므로 측정데이터 양을 적절히 줄여야 한다.

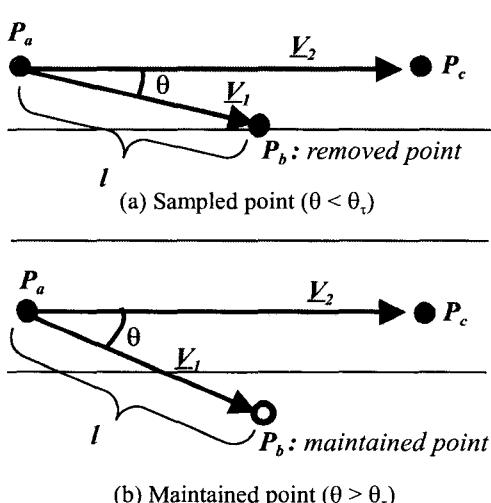


Fig. 3 Point reduction by vector sampling method

본 연구에서는 vector sampling method 와 sampling by rate 라는 두 가지 방법을 구현하여 측정 점을 제거하였다. Vector sampling 알고리즘은 다

음과 같다. 그림 3 과 같이, 측정 데이터 내에 연속된 세 점 ( $P_a, P_b, P_c$ ) 이 존재할 때 세 점으로부터 두 개의 방향 벡터  $V_1 = P_b - P_a$  와  $V_2 = P_c - P_a$  를 구한 후, 두 방향 벡터의 사잇각 ( $\theta$ ) 이 기준각도 ( $\theta_r$ ) 보다 작을 경우 가운데 점 ( $P_b$ ) 를 제거한다. 이와 동시에 두 점 ( $P_a$  와  $P_b$ ) 사이의 거리 ( $l = |P_a - P_b|$ ) 도 감안하여 만약 현재 고려중인 점  $P_b$  와 마지막으로 제거하지 않고 보존된 점  $P_{pp}$  사이의 거리 ( $l = |P_b - P_{pp}|$ ) 가 기준거리 ( $\delta$ ) 보다 클 경우에는 고려중인 점  $P_b$  를 제거하지 않고 보존하게 된다.

Sampling by rate 알고리즘은  $\alpha$  를 사용자 입력 정수 값 (users-input integer values) 이라 할 때 측정점의 순번이  $\alpha$  의 배수 (multiple of  $\alpha$ ) 인 모든 점을 제거하는 것으로 측정 점이 높게 중첩되어 있을 때 효율적이다. 단, 이 경우에도 애지 점들은 제거되지 않도록 하였다.

#### 5. 측정 점의 영역화 (Segmentation)

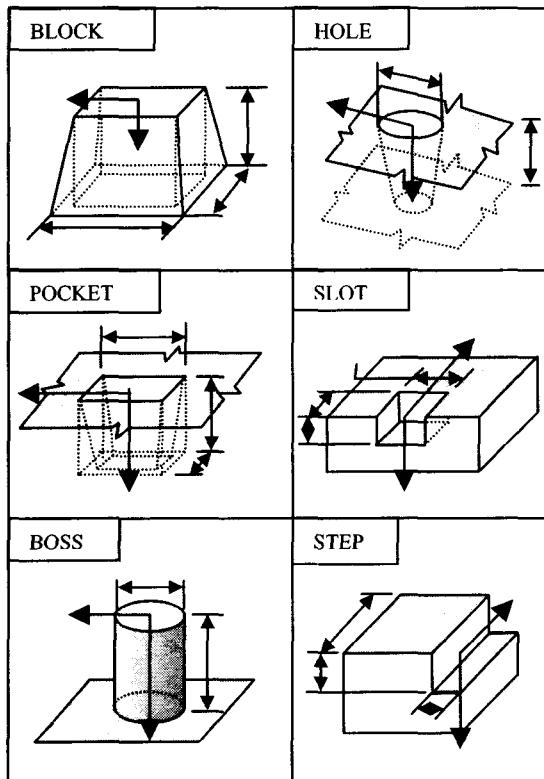
일반적으로 물품은 몇 개의 독립된 기본형상으로 구성된다. 따라서, 물품을 재 구성하기 위해서는 측정 데이터를 기본형상에 따라 구별하면 편리하다. 이러한 세그멘테이션 과정은 측정 데이터로부터 특징형상을 추출하는데 매우 중요하며, 현재는 역공학 작업자가 측정 데이터를 직접 눈으로 확인하며 마우스를 이용하여 세그멘테이션 작업을 수행하고 있다. 세그멘테이션 작업이 모두 끝나면, 작업자가 선택한 각각의 영역내의 측정 데이터들로부터 개별 특징 형상들이 추출된다. 따라서, 세그멘테이션은 모든 측정 점들이 빠짐 없이 선택될 때까지 수행되는데 물체의 복잡도에 따라 용이 할 수도 있고 아주 복잡할 수도 있다.

#### 6. 신경회로망에 의한 특징형상 인식

각주형 물품은 대개 몇 개의 특징형상으로 구성되어 있다. 특징형상은 물품의 공학적 의미를 내포하므로, 물품을 몇 개의 중요한 특징 형상들로 표현할 수 있다면 물품을 생산하기가 수월해 진다<sup>[1, 2]</sup>. 또한, CAD 와 CAM 의 통합을 위해서는 특징형상 기반 기술이 효과적이라 할 수 있으며, 이미 몇 개의 상용화된 시스템들이 활용되고 있다<sup>[14, 15]</sup>. 지금까지의 형상 인식을 위한 연구는 ‘CAD

모델로부터 형상 인식' 이였는데 주로 저장된 B-rep 모델의 꼭지점, 에지, 면의 관계들로부터 수행된다. 측정 점으로부터 직접 형상 인식을 하는 연구는 지금까지 많이 수행되지 않고 있다.

Table 1 Generic feature taxonomy



### 6.1 Feature Library (FL)

FL은 해당 응용분야에서 다루는 모든 특정 형상들을 포함해야 하는데 본 연구에서는 STEP에 분류되어 있는 volume feature taxonomy<sup>[3]</sup>를 근간으로 하는 특징형상들로부터 FL를 구성하였다. 본 FL은 표 1과 같이 pocket, slot, hole, step, boss, block와 같이 6개의 2.5D 기본 특징형상으로 구성되어 있으며 필요에 따라 특징형상을 새롭게 추가할 수 있도록 하였다.

### 6.2 신경회로망 기초

신경 회로망의 알고리즘은 생물의 신경 전달 원리와 유사하여 학습에 의해서 지식을 습득한다. 그림 4와 같이 신경회로망 내의 뉴우런들은 서로

복잡하게 연결되어 있어서 물체의 패턴을 인식하는 복잡한 계산 과정에 이용할 수 있다. 학습과정에서는 신경회로망은 원하는 출력 값을 얻을 수 있을 때 까지 뉴우런 사이의 연결 강도 (weight) 들을 조절한다. 따라서, 신경회로망은 충분한 학습 데이터만이 필요하므로 명확한 룰 (clear-cut rules)이 필요한 기존의 인공지능 알고리즘과는 다른 방식으로 문제를 해결한다.

### 6.3 신경회로망의 구조

본 연구에서는 그림 4와 같이 세 개의 층(layer)으로 구성된 가장 일반적인 형태의 신경회로망을 이용하였으며, 9개의 뉴우런으로 구성된 입력 층, 15개의 뉴우런으로 구성된 은닉 층과 6개의 뉴우런으로 만들어진 출력 층으로 구성되어 있다.

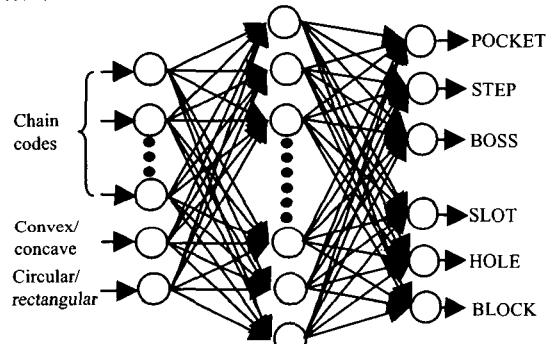


Fig. 4 Neural network structure

입력 층의 뉴우런의 개수는 신경회로망에 입력될 입력 데이터의 수와 동일하다. 본 신경회로망의 입력 데이터는 체인코드, 볼록/오목, 원형/사각형과 같이 3개의 측정 데이터의 기하학적 속성들로 구성된다. 체인코드는 7개의 매개변수로 구성되며 나머지 2개의 입력 데이터는 각각 한 개의 매개변수로 구성되는데 이 들은 측정 점들로부터 자동으로 추출이 되어 신경회로망에 입력되어 진다<sup>[2]</sup>. 은닉 층의 뉴우런의 개수는 처음에 가능한 적게 책정한 뒤 신경회로망이 수렴할 때까지 개수를 늘려서 결정하였다. 두 개의 은닉 층을 갖는 신경회로망도 테스트 하였으나 한 개의 은닉 층을 갖을 때와 차이가 거의 없었으며 오히려 한 개를 포함할 때 보다 학습시간이 10% 정도 지연되어 본 연구에서는 한 개의 은닉 층만을 갖도록 하였다. 출력 층의 뉴우런 수는 다루고자 하는 특

정 형상의 개수와 같도록 하였다.

#### 6.4 신경회로망 학습 과정

본 신경회로망은 학습율  $\eta = 0.9$ , 모우멘텀  $\mu = 0.5$ , 바이어스 = 1.0, 그리고 수렴율 (error tolerance)  $\epsilon = 0.0001$  의 조건으로 학습 되었다. 초기 연결 강도는 -0.25 와 0.25 사이의 임의 값을 갖게 하였는데, 초기 값이 너무 작은 값을 갖게 되면 학습 시간이 늘어나 신경회로망이 최적의 해로 수렴하지 않고, 반면에 아주 큰 값을 갖게 되면 연결강도는 불 안정할 수도 있기 때문이다. 연결강도 값은 모든 학습 데이터가 신경회로망에 한 개씩 입력되면서 알맞은 값으로 수렴된다. 표 2 는 본 회로망 학습 데이터의 한 예를 보여준다.

Table 2 A training pattern (one epoch)

	Chain Codes							(A)	(B)	(C)
	1	2	3	4	5	6	7			
Pocket	4	5	4	3	2	1	2	-1	1	1000000
Step	2	1	2	3	2	1	2	-1	2	010000
Slot	4	5	4	3	2	1	2	-1	2	001000
Boss	2	1	2	3	4	5	4	1	-1	000100
Hole	4	5	4	3	2	1	2	-1	-1	000010
Block	2	1	2	3	4	5	4	1	1	000001

(A) : Convex/Concave attribute

(B) : Circular/Rectangular attribute

(C) : Desired Output

첫 번째 행에 있는 데이터는 pocket 특징형상을 위한 학습 데이터이며, 다음 행은 step 형상을 위한 데이터이다. 이와 같이, 한 개의 행에 있는 값들은 한 개의 특징형상을 위한 학습 데이터이다. 또한, 15 개의 열 (column)로 구성된 배열이 학습 데이터 한 개를 구성한다. 예를 들어, pocket 형상을 학습하기 위해서는, 학습 패턴 '4 5 4 3 2 1 2 -1 1' 과 원하는 출력 값 '1 0 0 0 0 0 0' 가 신경망에 입력된다. 즉, 위 학습 데이터는 7 개의 chain code (4 5 4 3 2 1 2) 를 나타내며 오목 (-1) 하고 사각형 이면서 폐쇄된 성질 (1) 을 갖고 있는 형상은 포켓임을 학습시킨다. 첫 번째 chain code '4' 는 입력 층의 첫 번째 뉴런  $X_1$  에 입력된다 (i.e.,  $X_1 = 4$ ). 같은 방법으로, 다른 모든 chain code 값들도 순서대로 뉴런에 입력 ( $X_2 = 5, \dots, X_7 = 2$ ) 되며,

볼록/오목 변수와 원형/사각 변수 값도 각각  $X_8$  와  $X_9$  에 주어진다.

위의 모든 학습 패턴을 입력한 후에, 출력 층의 6 개의 뉴우런에 발생되는 실제 출력 값을 목표 값 (desired output) 과 개별 비교하여 오차를 계산한다. 이러한 오차 값을 감소 시키는 방향으로 연결강도를 변화 시킨다. 따라서, 최종적으로 실제 출력 값이 목표 값 (1 0 0 0 0 0) 과 같은 값을 가질 때까지 계속 변화 시켜야 한다. 위와 같은 종류의 학습 데이터를 충분히 많이 준비하여 신경회로망을 학습시킨다. 충분히 학습된 신경회로망 만이 모든 특정 형상들을 정확히 인식할 수 있기 때문이다. 본 연구에서 사용된 신경회로망은 제공된 모든 학습 데이터에 대하여 70,000 번의 반복수행 (iteration) 끝에 수렴되었다. 그림 5 는 본 회로망이 학습 되는 과정을 보여 주는데 학습 오차는 초기 약 30,000 번의 반복수행 중에 급속히 감소하면서 수렴되며 변화율도 그에 따라서 감소함을 알 수 있다.

The error and iteration No.

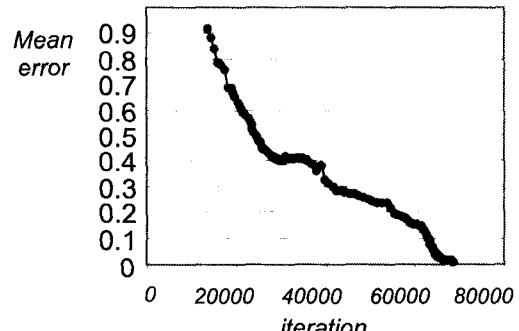


Fig. 5 The learning rate

본 신경회로망은 사전에 학습된 학습정보를 이용하여 선택된 측정 점들이 나타내는 특정 형상의 종류를 계산하여 출력시키게 된다. 즉, 출력 층의 최대 출력 값을 갖는 뉴런의 종류가 인식되는 특징형상을 나타낸다.

#### 6.5 특징형상 크기 추출

주어진 측정 점으로부터 특징형상이 인식되면 인식된 특징형상의 크기, 방향, 위치를 추출해야 한다. 본 연구에서는 원통, 구, 평면 등의 크기를 추출하는데 널리 이용되고 있는 maximum-

likelihood estimation (MLE) 알고리즘<sup>[16]</sup> 을 이용하였으며, 원의 중심과 반지름을 추출하는 알고리즘은 Landau 가 제안한 반복 수행법<sup>[17]</sup> 을 적용하였다.

## 7. 실행 예

개발된 시스템은 C++ 와 OpenGL 그래픽 라이브러리를 이용하여 구현되었으며, 형상모델 표현을 위해서 API (application program interface) 커널 (kernel) 이 직접 개발되었다. 본 시스템을 테스트하기 위하여 그림 6 과 같이 hole, boss, slot, free form surface 와 두 개의 pocket 으로 구성된 물품이 선택되어 테스트되었다.

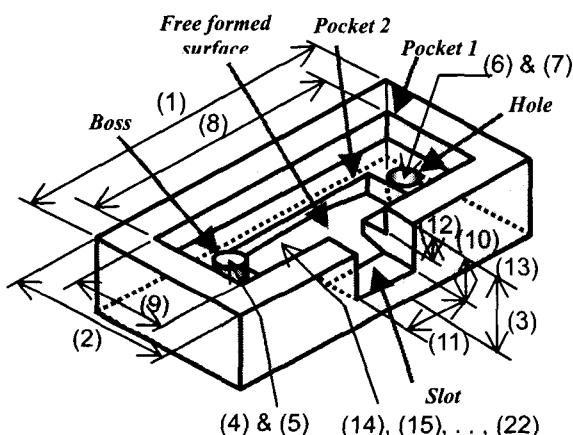


Fig. 6 Example of a part model

선택된 물품의 특징 형상들은 서로 복합적으로 연결되어 있는데 hole, boss 와 두 번째 pocket 은 첫 번째 pocket 특징형상 위에 놓여 있으며 slot 은 두 개의 pocket 면에 존재 한다. 또한, 두 번째 pocket 의 바닥면은 자유곡면 형상을 갖는다. 따라서, 선택된 물품은 개발된 시스템의 성능을 테스트 할 수 있는 적절한 특징 형상들로 구성되어 있으며 크기는 100 mm × 50 mm × 24 mm 이다.

### 7.1 초기 측정 점 정제

물품의 측정을 위하여 싸이클론 (cyclone) 측정기<sup>[18]</sup> 가 사용되었다. 싸이클론의 일반 측정오차는 ± 50 미크론이지만 실제적으로 측정되는 물체의 형상에 따라 조금씩 달라질 수 있다.

그림 7 은 측정 점들을 보여주는데, 총 33,000

개의 측정 점이 래스터 스캔 방식 (raster scan mode) 으로 얻어 졌다. 시스템의 효율을 위해서 그림 8 과 같이, 최소거리 0.9 mm, angle tolerance 30°, 그리고 sampling rate 가 2 인 샘플링 조건으로 측정 점의 수를 18,624 개로 줄였으며, 샘플링 작업과 동시에 에지 검출 모듈을 구동 시켜 그림 9 와 같이 에지 점들을 검출하였다.

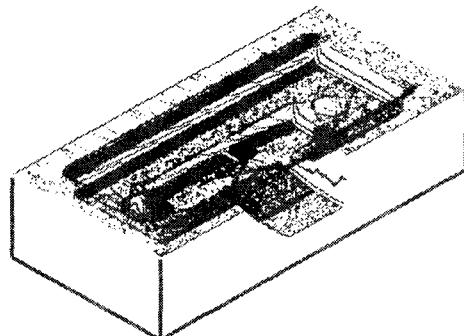


Fig. 7 The cloud of scanned data for the test part

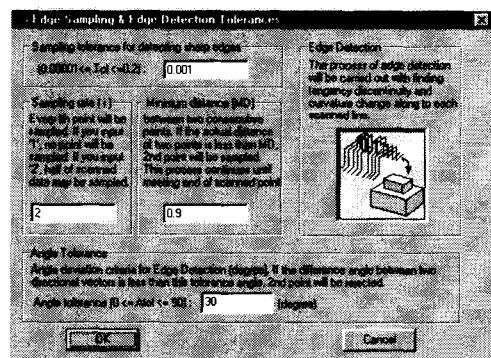


Fig. 8 Sampling dialogue box

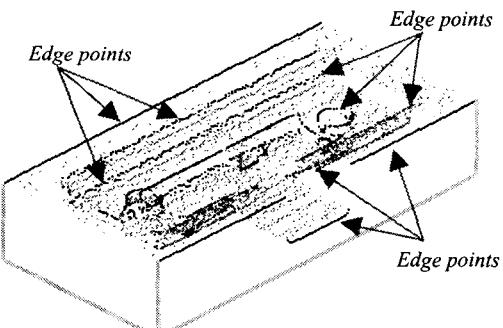


Fig. 9 Data reduction and edge detection

## 7.2 특징형상 인식 및 복제품 가공

전체 측정 점을 적절한 영역으로 영역화 시켜서 영역화 된 각각의 측정 점들로부터 기하학적 속성정보들을 추출하였다. 얻어진 속성정보들을 신경 회로망에 입력시켜서 특징형상이 인식 되도록 하였는데, 구현된 MLE 모듈과 검출된 에지 점들로부터 특징형상의 크기, 방향, 위치가 추출되었다. 본 실험 예를 통하여 인식된 특징형상 모델이 그림 10 과 같으며 그림 11 은 추출된 특징형상 모델 정보로부터 NC 가공된 복제품을 보여준다.

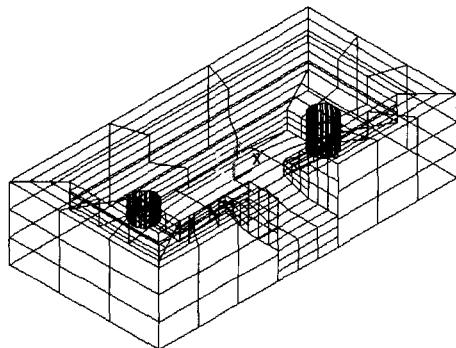


Fig. 10 Feature extraction

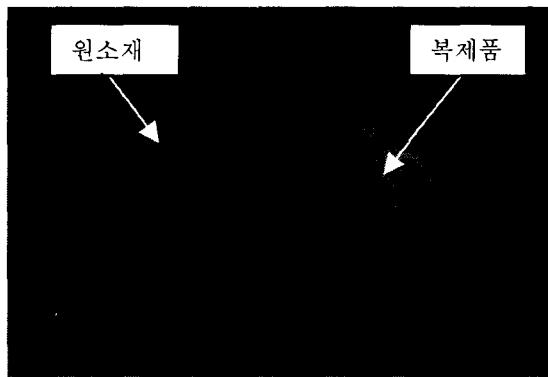


Fig. 11 The duplicated test part

표 3 은 원 소재와 역 공학으로 만들어진 복제품의 형상크기를 비교한 결과를 보여준다. 표로부터 복제품의 크기가 원 소재보다 다소 작게 만들어 졌음을 알 수 있는데, 이는 에지 부분의 측정오차가 주요한 원인으로 작용한 것으로 판단된다. 실제적으로 물체의 에지 부분을 정확히 측정하는 것은 불 가능하기 때문이다. 또한, 측정기의

정밀도, 모델링 근사 오차, 가공 오차 등도 정밀도에 큰 영향을 끼친 것으로 판단된다(평균 오차 값: 0.8 mm). 원소재와 복제품을 비교한 부위 (1), (2), ..., (22) 는 그림 6 과 같다.

Table 3 Error analysis results

비교점	원소재 (mm)	복제품 (mm)	오차 (mm)
전체	(1)길이	100.871	99.776
	(2)폭	50.160	49.339
	(3)높이	23.762	23.054
보스	(4)중심 (x,y,z)	20.29, 24.95, -7.60	20.43, 25.12, -7.61
	(5)직경	8.026	7.938
	(6)중심 (x,y,z)	79.99, 25.25, -7.58	79.82, 25.08, -7.62
홀	(7)직경	8.019	8.103
	(8)길이	79.811	80.341
	(9)폭	28.557	29.859
포켓	(10)높이	7.85	7.32
	(11)길이	18.36	18.70
	(12)폭	20.211	19.689
슬롯	(13)높이	14.436	15.219
	(14)	25.12, 17.97, -14.87	25.31, 18.22, -14.94
	.....(22)		

## 8. 토의 및 결론

측정 데이터로부터 직접 특징형상을 인식할 수 있는 새로운 시스템이 개발되었다. 개발된 시스템은 신경 회로망을 이용하기 때문에 여러 종류의 특징형상을 새롭게 추가할 수 있는 유연성을 갖추고 있다. 신경 회로망의 입력 값은 측정 데이터의 기하학적 속성정보이며 영역화 된 측정 점들로부터 자동적으로 추출된다. 본 시스템은 추출되는 특징형상의 크기나 방향을 사용자가 수정할 수 있도록 하여 사용자의 설계지식을 수용할 수 있도록 하였다.

현재 FL 는 pocket, slot, hole, step, boss, 그리고

block 특징형상으로 이루어져 있는데 필요에 따라 특징형상의 종류를 확장할 수 있다. 본 시스템은 인식하고자 하는 특징 형상의 단면 곡선을 표현하기 위해 7 자릿수로 구성된 체인코드를 채택하였다. 체인코드의 자릿수는 인식하고자 하는 특징형상의 복잡성에 따라 증가 시킬 수 있다. 그러나, 체인코드의 자릿수의 증가는 신경 회로망의 입력 충과 출력 충의 뉴우런 개수를 증가 시키며 은닉 충의 뉴우런의 수도 증가 시켜야 될 가능성이 크므로 학습 시간도 증가 될 것이다.

제시된 방법의 완전 실용화를 위해서는 정밀도 향상을 위한 알고리즘 개선, 측정 점을 자동으로 세그멘테이션 할 수 있는 알고리즘 개발, 복합 특징형상과 chamfers, fillets, round, tap 등의 2 차 특징형상을 위한 추가 연구가 요구 된다.

### 참고문헌

1. W. B Thompson, J. C. Owen and H. James, "Feature-Based Reverse Engineering of Mechanical Parts," University of Utah, Department of Computer Science, Technical Report UUCS-95-010, November 6, 1995.
2. Yongtae Jun, "A feature-based reverse engineering system using artificial neural networks," PhD Thesis, School of Engineering, University of Warwick, Coventry, UK, 1999.
3. Jami J. Shah and Martti Mantyla, Parametric and Feature-based CAD/CAM (Concepts, Techniques, and Applications), John Wiley & Sons, Inc., 1995.
4. P. K. Jain and Sharvan Kumar, "Automatic feature extraction in PRIZCAPP," International Journal of Computer Integrated Manufacturing, Vol. 11, No. 6, pp. 500 – 512, 1998.
5. Pramod N Chivate and Andrei G Jablokow, "Solid-model generation from measured point data," Computer-Aided Design, Vol. 25, No. 9, pp. 587-599, 1993.
6. B Sarkar and C-H Menq, "Smooth - surface approximation and Reverse Engineering," Computer - Aided Design, Vol. 23, No. 9, pp. 623 – 628, 1991.
7. J-Y Lai and C-Y Lu, "Reverse Engineering of composite sculptured surfaces," International Journal of Advanced Manufacturing Technology, Vol. 12, pp. 180 – 189, 1996.
8. Saeid Motavalli and Rafie Shamsaasef, "Object-oriented modelling of a feature-based reverse engineering system," International Journal of Computer Integrated Manufacturing, Vol. 9, No. 5, pp. 354-368, 1996.
9. Ballard, D. H., "Generalising the Hough transform to detect arbitrary shapes," Pattern Recognition, Vol. 13, pp. 111 – 119, 1996.
10. Saeid Motavalli and Jorge Valenzuela, "A system for reverse engineering of prismatic parts using orthographic images," International Journal of Computer Integrated Manufacturing, Vol. 11, No. 2, pp. 103 – 110, 1998.
11. S. Prebhakar and M. R. Henderson, "Automatic form-feature recognition using neural-network-based techniques on boundary representations of solid models," Computer-Aided Design, Vol. 24, No. 7, pp. 381-393, 1992.
12. P. Gu and X. Yan, "Neural network approach to the reconstruction of freeform surfaces for reverse engineering," Computer-Aided Design, Vol. 27, No. 1, pp. 59-64, 1995.
13. K. Nezis and G. Vosniakos, "Recognising 2.5D shape features using a neural network and heuristics," Computer-Aided Design, Vol. 29, No. 7, pp. 523-539, 1997.
14. Chandra R. Devireddy and Kalyan Ghosh, "Feature-based modelling and neural networks-based CAPP for integrated manufacturing," International Journal of Computer Integrated Manufacturing, Vol. 12, No. 1, pp. 61-74, 1999.
15. H. K. Tonshoff, J. C. Aurich and N. D'Agostino, "A unified approach to free-form and regular feature modelling," Annals of the CIRP, Vol. 14, No. 1, pp. 125-128, 1996.
16. R.M. Bolle and D.B. Cooper, "On optimally pieces of information, with application to estimating 3D complex-object position from range data," IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 8, No. 5, pp. 619-638, 1986.
17. U.M. Landau, "Estimation of a circular arc center and its radius," Computer Vision, Graphics, and Image Processing, Vol. 38, pp. 317-326, 1987.
18. Renishaw, Brochure on Scanning System, 1998.