

# 신경회로망을 이용한 가공면 영상의 거칠기 분류

김광래\*, 사승윤\*\*

## The Classification of Roughness for Machined Surface Image using Neural Network

Kwang-Lae Kim\*, Seung-Yoon Sa\*\*

### Abstract

Surface roughness is one of the most important parameters to estimate quality of products. As this reason, so many studies were carried out through various attempts that were contact or non-contact using computer vision. Even though these efforts, there were few good results in this research. However, texture analysis is making a important role to solve these problems in various fields including universe, aviation, living thing and fibers.

In this study, feature value of co-occurrence matrix was calculated by statistic method and roughness value of worked surface was classified of it. Experiment was carried out using input vector of neural network with characteristic value of texture calculated from worked surface image. It's found that recognition rate of 74% was obtained when adapting texture features. In order to enhance recognition rate, combination type in characteristic value of texture was changed into input vector. As a result, high recognition rate of 92.6% was obtained through these processes.

**Key Words :** Texture Feature(텍스쳐특징), Position Operator(위치연산자), Pixel Pair(픽셀쌍) Quantization(정량화), Intensity Gradient(광강도차), Recognition Rate(인식률)

### Nomenclature

- d : Pixel distance  
P : Position operator  
 $W_{ij}$  : Weight of each hidden unit  
 $w_i$  : Weight of each input unit

$y_k$  : Sigmoid function

$z_j$  : Output of j-th node

$\alpha$  : Learning rate

$\delta$  : Error information term

$\theta$  : Pixel direction

\* : 인덕대학 기계과  
\*\* : 숭실대 시간강사

## 1. 서 론

최근 전자산업의 발전과 공작기계의 기능 향상은 초정밀 가공기술에 대한 관심을 증가시켰다. 연삭과 같이 고정밀도가 요구되는 가공의 경우 공작물의 표면품위는 제품의 가치를 결정하는 중요한 요소이다. 그러나 생산공정의 자동화를 추구하는 현대산업사회는 가공상태의 실시간 감시에 목표를 두고 있는 실정이다. 따라서 비접촉방식의 여러 가지 센서를 이용한 많은 연구들이 시도되고 있다. 이중에서 컴퓨터비젼을 이용한 방법은 여러 분야에서 많이 사용되었다.

컴퓨터비젼의 연구는 가공물의 형상이나 치수보다는 공구의 상태를 파악하는 연구가 주로 행하여 졌으나 특히 가공물의 표면정도를 측정한 연구는 많지 않다. 그 이유는 고정밀도가 요구되는 경우 비전시스템은 주변환경에 대한 민감한 반응과 관찰영역이 좁다는 단점으로 실시간 계측에 많은 어려움을 초래한다. Ramana와 Ramamoorthy는 기계 가공에 의해 얻어진 가공표면을 텍스쳐(texture)해석 방법을 사용하여 가공표면의 특징을 분류하였다<sup>(1)</sup>. 그러나 이 연구에서는 동일한 가공방법으로 같은 형태의 텍스처를 가진 가공물의 경우 거칠기의 변화를 알아내기에는 미흡한 점이 있다. Haralick등은 co-occurrence행렬로부터 텍스처 정보를 추출하기 위해 에너지, 엔트로피, 모멘트, 동질성 등의 2차 특징의 다양성을 제안하였으며, 그 이후에도 여러 연구자들에 의해 통상 이용되었다<sup>(2)</sup>.

Connors와 Harlow는 위의 텍스처 특징들이 사실상 중요한 정보를 포함하지 않는다는 것을 보고하였다. 그 이유는 특징들이 co-occurrence 행렬로부터 추출되었을 때 중요한 텍스처 정보의 손실이 발생한다는 사실을 제시하였으며, 특히 디지털 영상으로부터 co-occurrence행렬까지에서 나타난다. 따라서 시각적으로 구분되는 픽셀쌍(pixel pair)은 알 수 없다는 사실을 보고하였다<sup>(3)</sup>. 또한, Muhamade등은 텍스처패턴의 분류를 위하여 Haralick이 제안한 여섯가지의 텍스처 특징을 Brodatz의 텍스처를 이용한 신경회로망 분류기를 제안하였다<sup>(4)</sup>.

본 연구에서는 가공면의 가공정도를 나타내기 위하여 표면 거칠기 변화에 따른 텍스처 정보를 추출하고, 신경회로망 분류기의 분류성능을 조사하였다. 이를 특징값의 인식률을 분석하여 온라인 측정에 적용할 수 있는 토대를 구축하고자 한다.

## 2. 가공면 텍스처 특징 추출

### 2.1 텍스처 특징

영상처리분야에서 텍스처는 상호관련된 요소들로 구성되어 있는 물체표면의 조직구조를 나타내는 것으로 주어진 영역에서 픽셀의 구조적관계를 특성화하여 영상내의 부드러움, 거칠기 등과 같은 특징을 나타낸다.

본 연구에서는 확률적방법을 이용하여 가공표면의 정도를 나타내려 한다. 이러한 방법은 서로 이웃한 픽셀들 사이의 광강도차(intensity gradient)의 빈도수를 조사함으로써 정량화 할 수 있다. 따라서 영상내에서 픽셀의 위치에 따른 광강도의 차를 나타내기 위해 위치연산자(position operator)  $P$ 는 방향  $\theta$  와 각 방향에서 픽셀간의 거리  $d$ 의 함수로써 다음과 같이 정의한다.

$$\begin{aligned} P(i, j, \theta) = & No. \{ ((k, l), (m, n)) \in (L_H \times L_V), \\ & m - k = d, n - l = 0, \\ & I(k, l) = i, I(m, n) = j \} \end{aligned} \quad (1)$$

여기서,  $(L_H \times L_V)$ 는 영상의 크기이며,  $(k, l), (m, n)$ 은 픽셀쌍의 좌표를 나타낸다. 또한  $I$ 는 영상의 임의의 위치에서의 픽셀의 광강도값이며,  $No.$ 는 발생빈도수를 나타낸다.

연산자에 의해 각 방향에 대한 픽셀간의 광강도차에 따른 빈도수를 계산하여 확률변수화한 co-occurrence행렬(이하 G-행렬)은 다음과 같다.

$$G = \begin{bmatrix} g_{00} & g_{01} & L & g_{0(k-1)} \\ g_{10} & g_{11} & L & g_{1(k-1)} \\ M & M & O & M \\ g_{(k-1)0} & \cdot & L & g_{(k-1)(k-1)} \end{bmatrix} \quad (2)$$

식(2)의 행렬요소  $g_{ij}$ 는 위치연산자  $P$ 에 의해 구한 각 픽셀쌍의 요소를 각각 전체 발생빈도수의 총합으로 나눈값이다. 이와 같이 구한 식(2)의 행렬로부터 다음과 같은 텍스처 특징을 구할 수 있다<sup>(5)</sup>.

① 관성(inertia)

$$G_I = \sum_{i=0}^{k-1} \sum_{j=0}^{k-1} (i - j)^2 g_{ij} \quad (3)$$

② 역모멘트(inverse difference moment)

$$G_{INV} = \sum_{i=0}^{k-1} \sum_{j=0}^{k-1} \frac{g_{ij}}{(k - j)^2} \quad (4)$$

③ 자기상관(autocorrelation)

$$G_A = \frac{\left\{ \sum_{i=0}^{k-1} \sum_{j=0}^{k-1} (ijg_{ij}) - \bar{m}_i \bar{m}_j \right\}}{\sigma_i \sigma_j} \quad (5)$$

④ 엔트로피(entropy)

$$G_{EN} = \sum_{i=0}^{k-1} \sum_{j=0}^{k-1} g_{ij} \log_2 g_{ij} \quad (6)$$

⑤ 동질성(uniformity)

$$G_U = \sum_{i=0}^{k-1} \sum_{j=0}^{k-1} g_{ij}^2 \quad (7)$$

⑥ 국부동질성(local homogeneity)

$$G_{LH} = \sum_i \sum_j \frac{g_{ij}}{1 + (i-j)^2} \quad (8)$$

## 2.2 신경회로망의 학습알고리즘

본 연구에서 사용한 신경회로망의 구조는 Fig. 1에 나타낸바와 같이 입력층, 중간층, 출력층으로 구성하였다. 입력층은 6개의 노드(node)로 구성하였으며, 중간층은 노드수의 변화를 알아보기 위하여 변화시켰으며, 출력층의 노드는 6개로 구성하였다. 입력층의 각 노드는 중간층으로 연결되어 입력층의 출력과 가중치(weight)를 곱한 값의 총합을 입력하여 전달함수를 거쳐 출력층으로 출력한다.

전달함수는 식(9)와 같이 시그모이드(sigmoid)함수를 사용하였다.

$$y_k = f(y_{(in)k}) = \frac{1}{1 + \exp(-f(y_{(in)k}))} \quad (9)$$

여기서,  $y_{(in)k} = W_{0k} + \sum_{j=1}^n z_j w_{jk}$ 이며,  $y_{(in)k}$ 는 노드  $j$ 의 입력의 총합과 bias

항  $W_{0k}$ 의 합이며,  $z_j$ 는 노드  $j$ 의 출력,  $w_{jk}$ 는 노드  $j$ 에서  $k$ 까지의 가중치이다. 따라서 식(10)과 같이 출력  $y_k$ 와 원하는 출력  $T_k$ 간의 오차를 최소로 하는 방향으로 식(11)과 같이 가중치를 변화시킨다.

$$E = \frac{1}{2} (T_k - y_k)^2 \quad (10)$$

$$\Delta w_{jk} = \alpha \delta_k z_j \quad (11)$$

단,  $\delta_k = (T_k - y_k) f'(y_{(in)k})$ 이며, 또한 bias항도 오차를

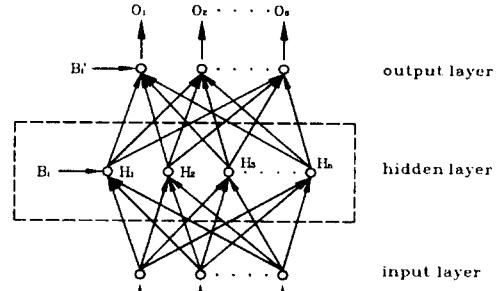


Fig. 1 A neural classifier with a single hidden layer

최소로 하는 방향으로 다음과 같이 변화시킨다.

$$\Delta W_{0k} = \alpha \delta_k \quad (12)$$

따라서 변화된 가중치  $w_{jk}(new)$  와  $W_{0k}(new)$ 는 식(13)과 같다.

$$\begin{aligned} w_{jk}(new) &= w_{jk}(old) + \Delta w_{jk} \\ W_{0k}(new) &= W_{0k}(old) + \Delta W_{0k} \end{aligned} \quad (13)$$

## 3. 실험

### 3.1 실험장치

가공면의 영상획득 및 텍스쳐 해석을 위한 실험장치는 Fig. 2와 같이 구성하였다. 관찰대상은 비교용 표면거칠기 표준시험편을 선정하였고, 이들의 표면을 관찰하기 위해 대물렌즈( $\times 25$ )를 사용하여 CCD카메라로 영상을 획득할 수 있도록 하였다. 획득된 영상은 DT3155 영상처리보드를 통하여 1프레임의 영상을 저장하여 PC에서 처리하도록 구성하였다. 광원으로는 할로겐 램프를 사용하였으며, 미소이송장치로 최적의 초점을 맞출 수 있도록 하였다.

### 3.2 실험방법

비교용 표면거칠기 표준시험편의 연삭가공면으로부터  $0.8\mu m$ ,  $1.6\mu m$ ,  $3.2\mu m$ ,  $6.3\mu m$ ,  $12.5\mu m$ ,  $25\mu m$ 의 6가지 거칠기 값을 대상으로 선정하였다. 표준시험편의 표면영상의 텍스쳐 해석을 위하여 획득된 256그레이 영상을 64그레이 영상으로 정량화(quantization)하였으며, 영상전체에 대하여 G-행렬을 구함으로써 2절에 나타낸 6가지의 텍스쳐 특징을 추출하게 된다. 이때 추출된 텍스쳐 특징을 신경회로망의 입력벡터로 사용하여 거칠기 값에 따른 신경회로

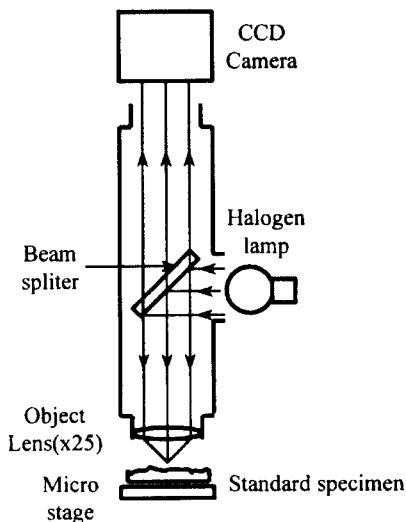


Fig. 2 Schematic diagram of experimental setup

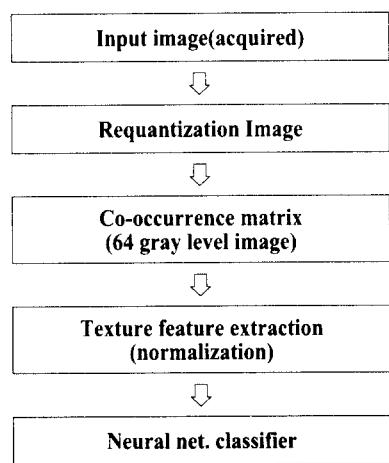


Fig. 3 Structure of the texture classifier

방의 분류특성을 조사한다.

Fig. 3은 본 연구에서 수행한 텍스쳐 해석과정을 나타내는 구조도이다.

## 4. 결과 및 고찰

### 4.1 텍스쳐 특징 추출

비교용 표면거칠기 표준시험편으로부터 얻은 6단계의 영상으로부터 표면의 텍스쳐 특징을 추출하였다. Fig. 4는

표준시험편으로부터 여섯개의 거칠기 값에 따른 영상을 나타낸 것이다.

거칠기 값이 적은 표면의 영상일수록 빛의 반사정도에 따른 명암대비가 완만하게 나타난다. 한편 거칠기 값이 큰 표면의 영상에서는 부분적으로 빛을 반사시키는 부분이 많이 나타나며, 명암대비가 뚜렷함을 알 수 있다. 이러한 부분들이 텍스쳐 해석에서 각 표면간의 차이를 나타내 줄 수 있는 중요한 요인으로 작용하게 된다. Fig. 4의 각 영상으로부터 G-행렬을 구하였다. 행렬의 요소들은 픽셀간 거리  $d=1$ , 방향  $\theta = 0^\circ$ 으로 설정하여 계산하였다. 이러한 조건은 영상에서 픽셀간 거리보다는 방향에 영향을 받는 것으로 보고된 연구의 실험결과를 바탕으로 선정하였다<sup>[6]</sup>. Fig. 4의 영상에서 가공방향은 수직방향으로 형성되어 있어, 수평방향으로의 광강도 변화가 더 크게 나타나 있는 점을 고려한다면 가공면의 거칠기를 잘 나타낼 수 있다. 따라서 계산된 G-행렬의 행렬요소들의 값을 Fig. 5에 나타내었다.

Fig. 5는 입력영상을 64그레이 레벨로 정량화한 영상으로부터 계산된 행렬을 다시  $512 \times 512$ 의 64 그레이 레벨로 표현한 것으로써 가로와 세로는 그레이레벨 값을 나타내며, 값의 크기는 픽셀쌍의 발생확률을 나타낸다. 따라서 여섯 가지의 거칠기 변화에 따른 영상에서 거칠기가 작은  $0.8\mu\text{m}$ 의 경우는 행렬요소의 값들이 중앙부에 집중되어 있으며,  $25\mu\text{m}$ 의 영상은 전체적으로 넓게 분포되어 있음을 관찰할 수 있다.

이는 거칠기 값이  $25\mu\text{m}$ 의 경우가  $0.8\mu\text{m}$ 에 비하여 픽셀간의 광강도차가 크게 나타나는 픽셀쌍의 발생빈도가 많다는 것을 나타낸다. 따라서 작은 거칠기 값을 가지는 표면의 영상일수록 픽셀간의 광강도 값의 차는 작아 일정 영역에 집중된다. 또한 큰 거칠기 값을 가지는 영상일수록 넓게 분포되며 주로 행렬의 대각선상에 집중된다. 또한 G-행렬로부터 2절의 여섯 가지의 텍스쳐 특징값을 추출하여 가공면 거칠기의 분류를 위한 입력벡터로 사용했다.

### 4.2 입력데이터와 학습알고리즘

본 연구에서 가공면의 거칠기 변화를 분류하기 위하여 신경회로망을 이용하였다. 텍스쳐의 특징값을 입력데이터로 사용하였으며, 6개의 텍스쳐 집합들의 판별은 역전파 학습알고리즘을 이용하여 학습하였다.

실험에 사용된 신경회로망은 입력층, 중간층, 출력층인 3개의 층으로 구성하였다. 입력층은 여섯 단계의 거칠기값을 고려하여 6개의 노드로 구성하였고, 중간층의 노드수를

변화할 수 있도록 하였다. 출력층은 분류하고자 하는 6단계의 가공면의 거칠기 값과 같은 노드수로 구성하였다.

Table 1은 입력층의 입력패턴과 이에 따른 출력층과의 관계를 나타낸 것이다. 입력층에서 각 노드는 중간층에서의 각각의 단독 노드와 연결된다. 같은 방법으로 중간층에서의 각 노드는 출력에서의 각각의 단독 노드에 연결된다. 또한 각 노드간의 모든 연결은 학습이 완전하게 끝날

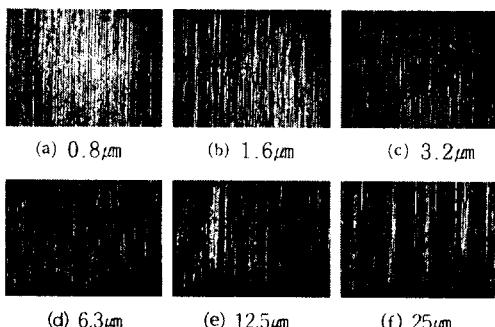


Fig. 4 Standard specimen image

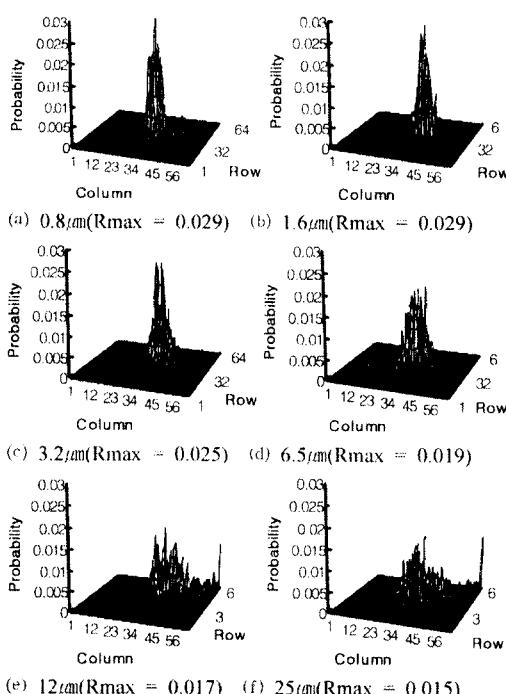


Fig. 5 3-D plot of co-occurrence matrix

때까지 가중치를 변화시켰다. 따라서 텍스쳐분류를 위한 신경회로망은 실험을 통하여 선정하였다. 입력데이터의 학습은 역전과 학습알고리즘을 이용하여 학습하였다. 일반적으로 학습의 종료시기를 선정하는 방법은 오차가 0인 점과 오차의 변화량이 없는 경우로 분류할 수 있다.

본 연구에서는 후자의 방법으로 학습의 종료시점은 학습과정에서 iteration수가 어느 정도 증가하여도 변화가 없는 점을 종료시기로 선정하여 학습하였다. 일반적으로 학습률(learning rate)은 증가할수록 학습속도가 빨라지는 장점은 있으나 반대로 인식률의 감소를 가져올 수 있다. 따라서 본 연구에서는 학습률을 0.2로 선정하였다. 또한 각 표면거칠기에 대하여 24개의 영상을 획득하여 이중 16개의 영상은 학습에 사용하였으며, 8개는 특정 분류 실험에 사용하였다.

중간층 노드수는 Fig. 6에 나타낸바와 같이 입력패턴 수를 48개와 96개의 두가지 경우로 실험하여 결정하였다. 이때 48개의 입력패턴을 사용한 경우의 중간층 노드수가 20개일 때 99.2%의 학습률을 나타냈다. 한편 96개의 입력패턴을 이용한 경우는 중간층 노드수가 31개일 때 99.5%의 학습율을 나타냈다. 따라서 중간층의 노드수는

Table 1 Relation of input node and output node

Input node	Output node
Inertia	100000
Inverse moment	010000
Autocorrelation	001000
Entropy	000100
Uniformity	000010
Local homogeneity	000001

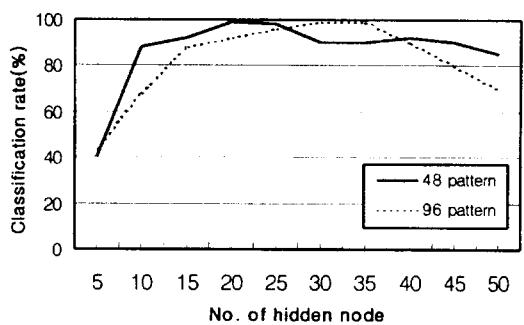


Fig. 6 Classification rate vs. number of hidden nodes for two different training volumes

31개로 하였고 하나의 텍스쳐 특징에 대하여 학습에 사용된 입력패턴의 수는 96개를 사용하였다.

#### 4.3 신경회로망을 이용한 텍스쳐 특징 분류

Fig. 7은 앞선 실험에 의해 선정된 신경회로망을 이용하여 표면거칠기 표준시험편의 분류 결과를 나타낸 그래프이다.  $25\mu\text{m}$ 의 표면을 제외하고는 대체적으로 낮은 분류율을 나타냈다. 이러한 이유는 Fig. 8에 나타낸 바와 같이 거칠기 값이 작은 0.8, 1.6,  $3.2\mu\text{m}$ 의 경우  $0.8\mu\text{m}$ 의 표면이  $1.6\mu\text{m}$ ,  $3.2\mu\text{m}$ 의 표면으로 잘못 인식되는 경우가 각각 25%, 12.5%로 나타났다.  $16\mu\text{m}$ 의 경우도 0.8,  $3.2\mu\text{m}$ 의 표면으로 잘못 인식된 경우가 18.7%와 12.5%로 나타났다. 그러나 거칠기 값이 큰 6.3, 12.5,  $25\mu\text{m}$ 의 경우는 오차가 각각 18.7, 25, 6.3%정도로 거칠기 값이 작은 0.8, 1.6,  $3.2\mu\text{m}$ 의 표면보다 적게 나타났다. 이러한 이유는 거칠기 값이 적은 영역에서는 거칠기 값간의 차가 작아 큰 거칠기 값을 가지는 표면에 비하여 상대적으로 작은 분류율을 나타냈다. 따라서 전체 분류율은 약74%로 낮게 나타났다.

#### 4.4 제안된 방법에 의한 패턴분류

표면거칠기 표준시험편의 거칠기 분류를 위하여 신경회로망을 이용한 분류결과가 74%의 낮은 분류를 나타낸 것을 보완하기 위하여 본 연구에서는 텍스쳐 특징의 분석을 토대로 새로운 방법을 제안한다. 텍스쳐의 6가지의 특징을 분석해보면 역모멘트, 동질성, 국부동질성 등은 거칠기 값의 증가에 따라서 감소 경향을 보이며, 관성, 자기상관, 엔트로피는 증가경향을 갖는다.

이러한 텍스쳐 특징들의 경향이 신경회로망을 이용한 표면거칠기 분류에 있어서 오차의 원인으로 작용된다고 판단된다. 따라서 이들 6가지의 텍스쳐 특징 중에서 어떤 특징이 표면거칠기 분류에 적합한 특징인가를 실험하였다.

따라서 신경회로망의 구성을 다음과 같이 구성하였다. 입력층 노드를 5개의 층으로 구성하고 출력층은 6개로 구성하였다. 또한 중간층의 수는 학습률을 고려하여 26개로 선정하였다. 따라서 Table 2와 같은 분류 결과를 얻었다. Table 2에서 보는 바와 같이 입력패턴으로 관성을 제외한 나머지 5개의 패턴을 사용한 경우에는 65%로 낮은 분류율을 나타냈으며, 반대로 역모멘트를 제외한 5개의 패턴을 입력으로 사용한 경우에는 92.6%로 가장 높은 값을 나타냈다. 이러한 이유는 역모멘트의 경우 텍스쳐 특징을 계산할 때 G-행렬의 주대각 성분이 포함되지 않기 때문이며, 표면거칠기가 적은 표면의 경우 이러한 영향이 거칠기의

분류에 오차로 작용할 수 있는 것으로 판단된다. 따라서 역모멘트를 제외한 나머지 5개의 패턴을 입력패턴으로 사용하였으며, 입력패턴 수는 총 80개의 데이터가 사용되었다. 이에 따른 분류결과를 Fig. 9와 같이 나타내었다.

#### 4.5 고찰

가공면 영상의 텍스쳐특징을 이용하여 표면거칠기에 따른 6가지의 가공면을 분류하였다. 텍스쳐특징은 가공면영상으로부터 구한 G-행렬로부터 6가지의 특징값을 구하였으며, 이를 입력벡터로 사용하여 가공면 거칠기에 따른 패턴을 분류하였다.

신경회로망은 패턴의 분류를 위하여 이용하였으며, 역전과 학습알고리즘을 이용하여 학습하였다. 사용된 입력벡터는 각 거칠기 값에 따라 시험편으로부터 랜덤하게 32개의 영상을 획득하였으며, 이중 16개의 영상은 학습을 위해 사용하였고, 나머지 16개의 영상은 패턴분류에 사용하였다. 패턴 분류실험에서 중간층 노드수의 변화에 따른 인식률을 조사한 결과를 토대로 노드수 31로 정하였으며 실험결과 테

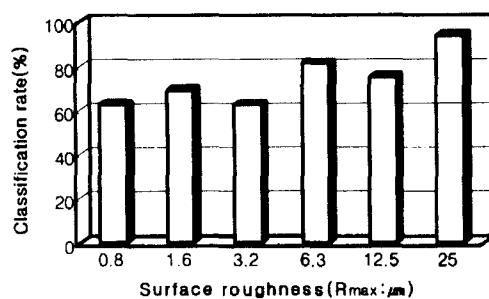


Fig. 7 Classification rate of surface roughness

	25s				3	15
Output pattern	12s				1	<b>12</b>
	6.3s		3	<b>13</b>	1	
	3.2s	2	2	<b>10</b>	2	
	1.6s	4	<b>11</b>	3		
	0.8s	<b>10</b>	3			
	0.8s	1.6s	3.2s	6.3s	12s	25s

Fig. 8 Classification rate of Input pattern

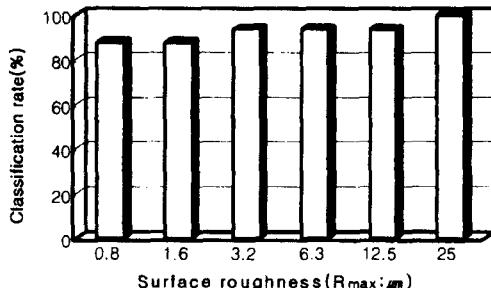


Fig. 9 Classification rate of surface roughness for proposed method

Table 2 The performance of selected texture feature

Combination texture features	Classification rate (%)
$G_{INV}, G_A, G_{EN}, G_U, G_{LH}$	65.0
$G_p, G_A, G_{EN}, G_U, G_{LH}$	92.6
$G_p, G_{INV}, G_{EN}, G_U, G_{LH}$	87.0
$G_p, G_{INV}, G_A, G_U, G_{LH}$	69.8
$G_p, G_{INV}, G_A, G_{EN}, G_{LH}$	80.3
$G_p, G_{INV}, G_A, G_{EN}, G_U$	81.6
$G_{LH}$ : local homogeneity	$G_p$ : inertia
$G_A$ : autocorrelation	$G_{EN}$ : entropy
$G_{INV}$ : inverse moment	$G_U$ : uniformity

스트 패턴의 분류율은 74%로 낮게 나타났다. 따라서 인식률을 높이기 위하여 조합된 형태의 입력벡터를 사용하여 실험하였으며, 이 경우 역모멘트를 제외한 5개의 특징값을 입력패턴으로 사용한 경우가 약 94%로 높은 분류율을 나타냈다. 이러한 이유는 역모멘트 특징이 G-행렬상의 주대각성분을 계산에 고려하지 않는 점에 기인한 것으로 판단된다.

## 5. 결 론

이상과 같이 가공면 거칠기에 따른 텍스쳐 특징을 이용한 신경회로망의 분류를 통하여 다음과 같은 결론을 얻을 수 있었다.

- (1) 여섯가지의 거칠기값을 대상으로 영상을 획득하였고, 계산된 G-행렬로부터 여섯가지의 텍스쳐 특징을 신경망의 입력벡터로 사용하였다,
- (2) 신경망의 중간층의 노드수는 변화할 수 있도록 구성하였으며, 인식률은 노드수 31개의 경우가 가장

큰 값을 나타냈으나, 텍스쳐 특징값들은 전체 74%의 낮은 분류율을 나타냈다.

- (3) 인식률을 높이기 위하여 텍스쳐 특징간의 조합된 형태의 특징값을 사용하였으며, 그 결과 자역모멘트를 제외한 5개의 특징을 이용한 경우가 약 93%의 분류율을 나타냈다.
- (4) 가공면 영상의 텍스쳐 특징을 이용한 표면거칠기 분류는 가능하며, 아울러 측정시스템의 구성과 계산시간을 감소시킬수 있는 알고리즘의 보완이 이루어진다면 온라인계측이 가능하다.

## 후 기

본 연구는 인덕대학 연구비지원에 의하여 연구되었음.

## 참 고 문 헌

- (1) Beyerer, J. and Leon, F. P., "Detection of defect in groove textures of honed surface," Int. J. Mach. Tools Manufact., Vol. 37, No. 3, pp. 371~389, 1997.
- (2) Ramana, K. V. and Ramamoorthy, B., "Statistical methods to compare the textures of machined surface," Pattern Recognition, Vol. 29, No. 9, pp. 1447~1459, 1996.
- (3) Haralick, R. M., "Statistical and structural approach to texture," Proc. IEEE, 67, pp. 786~804, 1979.
- (4) Connors, R. and Harlow, C., "A theoretical comparison of texture algorithms," IEEE Trans. PAMI, PAMI-2, pp. 204~222, 1980.
- (5) Muhamade, A. F. and Deravi, F., "Co-occurrence based features for automatic texture classification using neural network," Neural Net. and Stochastic Methods in Image and Signal Processing, Vol. 1766, pp. 489~496, 1992.
- (6) 사승윤, 이명재, 김광래, 유봉환, "광 강도변화를 이용한 가공면 영상의 텍스쳐 특징 분석," 한국공작기계학회 춘계학술대회 논문집, pp. 316~322, 1998.