

# 레이저 반사광을 이용한 미세 표면 거칠기 측정 알고리즘에 관한 연구

최규종<sup>†</sup> · 김화영\* · 안중환\*\*  
(2007년 11월 9일 접수, 2008년 3월 8일 심사완료)

## Study on Algorithm of Micro Surface Roughness Measurement Using Laser Reflectance Light

Gyu-Jong Choi, Hwa-Young Kim and Jung-Hwan Ahn

**Key Words :** Micro surface roughness(미세 표면 거칠기), Laser reflectance light(레이저 반사광), Weighting function(가중 함수), Neural network (신경 회로망)

### Abstract

Reflected light can be decomposed into specular and diffuse components according to the light reflectance theory and experiments. The specular component appears in smooth surfaces mainly, while the diffuse one is visible in rough surfaces mostly. Therefore, each component can be used in forming their correlations to a surface roughness. However, they cannot represent the whole surface roughness seamlessly, because each formulation is merely validated in their available surface roughness regions. To solve this problem, new approaches to properly blend two light components in all regions are proposed in this paper. First is the weighting function method that a blending zone and rate can be flexibly adjusted, and second is the neural network method based on the learning from the measurement data. Simulations based on the light reflectance theory were conducted to examine its performance, and then experiments conducted to prove the enhancement of the measurement accuracy and reliability through the whole surface roughness regions.

### 기호설명

- $A$  : 반사면의 넓이
- $g$  : 광학 거칠기
- $\lambda$  : 광원의 파장
- $R_{2\sigma}$  : 광원까지의 반사 거리
- $v$  : 반사 방향
- $\mu$  : 투과율(permeability)
- $\epsilon$  : 유전율(permittivity)
- $f$  : 렌즈의 초점 거리

### 1. 서론

반사광은 표면의 거칠기 정보를 포함하고 있으므로 이를 이용한 거칠기 측정에 관한 연구가 오래 전부터 진행되어 왔다. 특히 표면의 반사광을 활용한 광학식 표면 거칠기 측정법은 인프로세서(in-process) 계측에 있어서 큰 장점이 있는 것으로 밝혀졌다.<sup>(1,2)</sup>

일반적으로 반사광은 정반사 성분에 해당하는 광 강도와 난반사 성분에 해당하는 광 분포도로 구분될 수 있다. 그리고 매끈한 면에서는 정반사 성분이 지배적이고, 상대적으로 거친 면에서는 난반사 성분이 지배적이다. 따라서 각 성분을 개별적으로 측정하여 매끈한 면[0.01~ 0.10  $\mu m$ ]과 거친

<sup>†</sup> 책임저자, 회원, 부산대학교 정밀정형 및 금형가공 연구소, E-mail : websignr@pknu.ac.kr  
TEL : (051)510-3087 FAX : (051)581-3087

\* 부산대학교 기계공학부

\*\* 부산대학교 기계공학부

면[0.18~ 0.30 μm]의 표면 거칠기에 관한 상관 관계식을 유도할 수 있다.<sup>(3)</sup> 그러나 두 가지 성분은 매끈한 면, 거친 면 그리고 두 성분이 혼합되어 있는 중간단계 면[0.10~ 0.18 μm]에서 혼합된 비율이 서로 다르기 때문에 각각의 상관 관계식을 통계적 해석을 통해 유도하더라도 전 구간[0.01~ 0.30 μm]에 대한 표면의 거칠기를 정확히 추정하기는 어렵다. 이로 인해 단일 상관 관계식을 이용하여 측정영역을 전구간으로 확장하기 어렵다.

따라서 본 논문에서는 이러한 문제점을 해결하기 위해 정반사 성분과 난반사 성분을 적절한 비율로 블렌딩(blending)할 수 있는 두 가지 방법을 제시하였다. 먼저, 블렌딩구간(blending zone)과 블렌딩비율(blending rate)을 유연성 있게 조절할 수 있는 가중 함수(weighting function)를 이용하는 방법을 제시하였다. 그리고 학습(learning)을 통해 블렌딩비율을 조절하는 신경회로망(neural network) 방법을 제시하였다. 제시된 두 가지 방법을 실제 시편에 적용하여 그 결과를 비교 분석하였다.

## 2. 광 반사 모델 및 실험장치

### 2.1 광 반사 모델

Beckmann과 Spizzichino는 표면에서 빛이 반사되는 현상을 전자기와 이론의 기본적인 개념을 바탕으로 규명하였다.<sup>(4)</sup>

먼저, 표면의 형상을 공간 상에서 높이  $h$ 에 대한 확률 함수로 정의하고, 그 분포는 평균값 0, 표준 편차  $\sigma_h$ , 상관거리  $T$ 인 정규분포를 이룬다고 가정하였다. 그리고 반사 광량은 Fig. 1 과 같이 정의되는 표면의 한점  $Q$ 에 대해 전기장 크기  $E_{o1}$ , 진행 방향  $e_1$ , 전파 벡터  $k_1$  및 진동수  $\omega$  를 지니는 평면파가 입사각  $\theta_i$ 로 입사하여  $(\theta_r, \phi_r)$ 의 방향으로 산란될 경우 그 평균적인 반사 광량은 식 (1)과 같다.

$$\langle E_2 E_2 \rangle = \frac{E_{o1}^2 A^2 \cos^2 \theta_i}{\lambda^2 R_{o2}^2} e^{-g} \left[ \rho_o^2 + \frac{\pi T^2 D^2}{A} \sum_{m=1}^{\infty} \frac{g^m}{m!m} e^{-v_x^2 T^2 / 4m} \right] \quad (1)$$

여기서

$$\rho_o = \text{sinc}(v_x X) \text{sinc}(v_y Y) \quad (2)$$

$$g = \left( 2\pi \frac{\sigma_h}{\lambda} (\cos \theta_i + \cos \theta_r) \right)^2 \quad (3)$$




Fig. 1 Reflection model of plane wave incident on a rough surface<sup>(4)</sup>

$$D = \left( \frac{1 + \cos \theta_i \cos \theta_r - \sin \theta_i \sin \theta_r \cos \phi_r}{\cos \theta_i (\cos \theta_i + \cos \theta_r)} \right) \quad (4)$$

$$v_{xy} = \sqrt{v_x^2 + v_y^2} \quad (5)$$

반사 광량은 식 (1)과 같이 정반사 성분 ( $\rho_o^2$ ) 과 난반사 성분 ( $\sum g^m e^r$ ) 이 합해진 형태로 표현된다.  $\rho_o$ 는 식 (2)와 같이  $x$ 와  $y$ 축의 sinc 함수를 곱한 형태이므로 정반사 방향을 제외한 모든 산란 방향에 대해 거의 0에 가깝다. 광학 거칠기(optical roughness)  $g$ 는 식 (3)과 같이 표면의 거친 정도를 나타내는  $\sigma_h / \lambda$ 의 제곱에 비례하므로 경면일수록 0에 가깝다. Nayar는 식 (1)의 광 반사 모델로부터 임의의 광학계를 가정하여 광 강도  $L_r$ 을 식 (6)과 같이 재정의 하였다.<sup>(5)</sup>

$$L_r = \sqrt{\frac{\mu}{\epsilon}} \frac{E_{o1}^2 \cos^2 \theta_i}{2\lambda^2} e^{-g} \left( \left( \frac{z}{f} \right)^2 \frac{dA_{im} \cos \gamma}{\cos^2 \theta_r} \rho_o^2 + \frac{\pi T^2 D^2}{\cos \theta_r} \sum_{m=1}^{\infty} \frac{g^m}{m!m} e^{-v_x^2 T^2 / 4m} \right) \quad (6)$$


이와 같은 광반사 모델을 이용하여 광분산 지도를 근사적으로 모델링할 수 있고, 그 결과 광 강도의 크기와 확산 정도를 측정하여 표면의 평균 거칠기 정보를 얻을 수 있다.<sup>(6)</sup>

**Table 1** Specification of HV7131D CMOS image sensor

Pixel resolution	642×482
Pixel size	8×8 μm <sup>2</sup>
Format	VGA
Sensitivity	2.5V/lux·sec

**Table 2** Specification of LT052 Laser diode

Optical power output	35mW max.
Wavelength	650nm band
Operating current	110mA max.

**Fig. 2** Experiment device for surface roughness measurement

## 2.2 실험 장치

Fig. 2는 MPU가 C8051F130로 구성된 실험장치를 나타낸다. 그리고 실험장치의 핵심 요소인 영상 센서와 레이저 다이오드의 사양을 Table 1과 2에 나타내었다. 실험에서 사용된 시편들은 SKD11, 초경(Super alloy), 실리콘 웨이퍼(Silicon wafer)이며, 이러한 시편들에 대해 Mitutoyo사의 휴대형 측정식 표면 거칠기 측정 장치인 SJ-301의 측정 결과를 기준 거칠기값으로 사용하였다.

## 3. 반사광 성분 분해

반사광은 크게 정반사 성분과 난반사 성분으로 나눌 수 있다. 전자는 매끈한 표면에서 차지하는 비율이 높으며, 영상센서의 좁은 영역에서 집중적으로 나타난다. 반면에 후자는 상대적으로 거친 표면에서 차지하는 비율이 높으며, 비교적 낮은 광 강도를 가지고 고르게 퍼져 나타난다.

따라서 Beckmann의 광 반사 모델을 이용하여 확인한 결과 식 (7)과 같이 매끈한 면의 거칠기 ( $R_{q,smooth}$ )는 포화 회피 광 강도<sup>(3)</sup>의 크기( $E_{o1}$ )에 대한 함수로 근사 시킬 수 있고, 거친 면의 거칠기 ( $R_{q,rough}$ )는 식 (8)과 같이 광 강도 분포의 표준 편차( $\sigma$ )에 대한 함수로 근사 시킬 수 있음을 확인할 수 있다.<sup>(2,3)</sup>

$$R_{q,smooth} = a_1 E_{o1} + b_1 \quad (7)$$

$$R_{q,rough} = a_2 \sigma + b_2 \quad (8)$$

여기서,  $a_1$ 과  $b_1$ ,  $a_2$ 와  $b_2$ 는 가상으로 생성된 시편들과 식 (1)과 같은 Beckmann의 광 반사 모델을 이용하여 추정하였다. 실제 실험에서는 각각의 파라미터들이 시편의 종류에 따라 조금씩 차이를 보이고 있기 때문에 평균적인 값을 구하여 적용하였다. Fig. 3은 식 (7)과 (8)을 이용하여 계산된 두 표면 거칠기들과 가상으로 생성된 시편의 표준편차  $\sigma_n$ 와 광원의 파장  $\lambda$ 를 이용하여 계산된 광학 거칠기(optical roughness)를 서로 비교한 그래프이다. 계산된 표면 거칠기값이 광학 거칠기값과 유사할수록 유효한 것으로 보았을때,  $R_{q,smooth}$ 를 구하는 식 (7)은 매끈한 표면에서 유효하고,  $R_{q,rough}$ 를 구하는 식 (8)은 상대적으로 거친 표면에서 유효하다는 것으로 분석할 수 있다. 그리고 중간 단계의 표면에서는 두 성분이 서로 교차하여 정확한 거칠기 측정이 어려운 천이구간(transition zone)이 발생하는 것을 볼 수 있다. 따라서 측정 영역을 전 영역으로 확장하기 위해 이러한 구간에서 두 반사 성분들을 적절히 블렌딩(blending)하여 거칠기를 추정할 수 있는 방법이 필요하다.

## 4. 블렌딩 알고리즘

Fig. 3과 같이 두 성분의 에너지가 10~90%범위로 존재하는 구간을 천이구간(transition zone)으로 정의한다.<sup>(1)</sup> 이러한 구간에서 정확한 표면 거칠기를 추정하기 위해 각 성분들을 블렌딩하는 두 가지 방법을 제시하여 실험하였다. 먼저, 천이구간에서는 두 거칠기 성분들을 적절히 블렌딩하고 나머지 구간에서는 유효한 거칠기값만을 유지하는 가중 함수(weighting function)를 이용하는 방법을 제시하였다. 다음으로 두 거칠기 성분들과 기준 거칠기값들로 학습된 신경회로망(neural network)을 이용하여 블렌딩하는 방법을 제시하였으며, 실험을 통해 두 방법에 대한 결과를 비교 분석하였다.




Fig. 3 Variation of  $R_{q,smooth}$  and  $R_{q,rough}$  versus roughness<sup>(3)</sup>

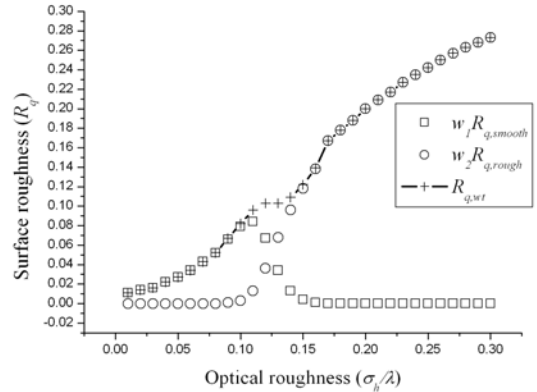
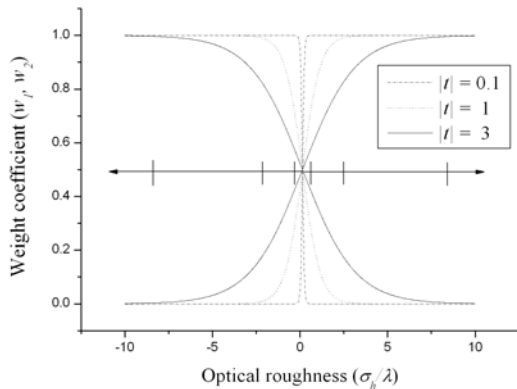



Fig. 5 Blending result of  $R_{q,smooth}$  and  $R_{q,rough}$  using weighting functions (simulation)



(a) Versus  $t$  ( $n = m = 1$ )



(b) Versus  $n, m$  ( $t = 3$ )

Fig. 4 Variations of weighting function  $w_1, w_2$  ( $r_c = 0$ )

4.1 가중 함수를 이용한 블렌딩

광학 거칠기(optical roughness)  $r$ 에서 천이구간이  $[r_0, r_1]$ 으로 주어질 때, 이러한 구간 내에서 두 성분을 블렌딩하기 위한 가중 함수를 식 (9)와 같은 tanh 함수를 이용하여 구성하였다. 여기서  $n, m$ 은 각 성분들의 블렌딩 비율을 조절하는 파라메타이

며, 블렌딩구간을 결정짓는 파라메타  $t$ 와 블렌딩구간의 중심위치  $r_c$ 는 식 (10)과 같이 표현하였다. 이때 설정된 천이구간을 포함하도록  $t$ 를 변화시키면서 블렌딩구간을 조절하였을 때 분모를 6으로 하였을 때 가장 적절하였다. 이와 같은 파라메타들을 이용하여 블렌딩구간과 비율을 유연성 있게 조절할 수 있다는 것을 Fig. 4에 나타내었다.

$$w_1(r) = 1 - \left( \frac{1}{2} \left( \tanh \left( \frac{-r + r_c}{t} \right) + 1 \right) \right)^n \tag{9}$$

$$w_2(r) = 1 - \left( \frac{1}{2} \left( \tanh \left( \frac{r - r_c}{t} \right) + 1 \right) \right)^m$$

여기서,

$$t = \frac{r_0 - r_1}{6}, \quad r_c = \frac{r_0 + r_1}{2} \tag{10}$$

따라서 식 (9)의 가중 함수들이 적용된 식 (11)과 같은 단일 상관 관계식을 이용하여 전 구간에 대한 표면 거칠기  $R_{q,wt}$ 을 구할 수 있다.

$$R_{q,wt} = w_1 R_{q,smooth} + w_2 R_{q,rough} \tag{11}$$

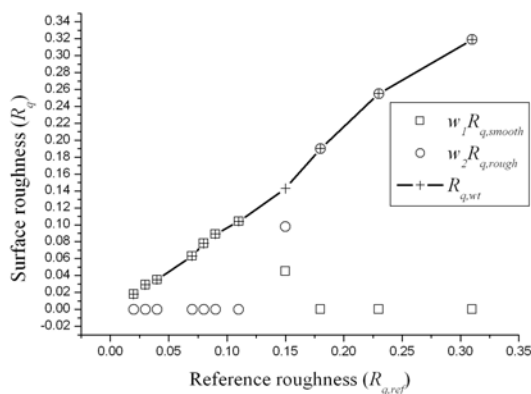
Fig. 5는  $n = 1.1, m = 0.9$ 로 설정된 가중 함수를 이용하여 Fig. 3에 나타난 거칠기 성분들을 블렌딩한 결과를 보여준다. 블렌딩구간에서 부드럽게 결합되었지만 각 성분들의 기울기가 서로 달라서 변곡점이 나타난 것을 볼 수 있다.

이와 같은 방법을 실제 시편(specimen)인 SKD11, 초경(Super alloy), 그리고 실리콘 웨이퍼(Silicon

wafer)에 적용하였다. 먼저, Mitutoyo 사의 접촉식 표면 거칠기 측정기인 SJ-301 을 이용하여 각 시편에 대한 측정 결과를 기준 거칠기값  $R_{q,ref}$  으로 정하였다. 그리고 각 시편에서  $E_{oi}$  과  $\sigma$  값을 측정하여 매끈한 면과 거친 면의 표면 거칠기  $R_{q,smooth}$  와  $R_{q,rough}$  를 각각 구하였다. 식 (7)과 (8)에서 모든 시편에 적용할 수 있는 파라메타들을 정확히 구하기 힘들기 때문에 평균값을 사용하였다. Table 5, 6, 7 은 각 시편에 대해  $R_{q,smooth}$  와  $R_{q,rough}$  , 그리고 각각에 대해 가중 함수를 적용하여 추정된 거칠기  $R_{q,wt}$  를 나타내었다. 이때 파라메타  $t$  는 -0.012,  $r_c$  는 0.145 이며, 블렌딩 차수  $m$  과  $n$  을 1.5 로 조절하였을 때 결과가 가장 좋았다. 세 가지 시편 중 SKD11 에 대한 블렌딩 결과를 Fig. 6 에 나타내었으며, 시물레이션 결과인 Fig. 5 와 유사한 것을 확인할 수 있다. 그러나 식 (7)과 (8)의 파라메타들을 정확하게 구할 수 없기 때문에 천이구간 내에서 특히 많은 오차가 발생한 것을 볼 수 있다.

**Table 3** Neural network parameters

Type	Feed-forward
Training data(input data)	$R_{q,smooth}$ , $R_{q,rough}$
Training data(output data)	$R_{q,ref}$
Bias	Used
Activation function(hidden layer)	Log-sigmoid
Activation function(output layer)	Pure linear
Epoch	100000
Training method	Gradient decent
Learning rate	0.01



**Fig. 6** Blending result of  $R_{q,smooth}$  and  $R_{q,rough}$  in SKD11 using weighting functions


4.2 신경회로망을 이용한 블렌딩  
매끈한 면의 거칠기( $R_{q,smooth}$ )와 거친 면의 거칠기( $R_{q,rough}$ )는 표면의 거칠기와 상관관계를 가지고 있다는 것을 3 장에서 설명하였다. 따라서 함수 근사(function approximation)에 적합한 방법으로 알려져 있는 신경회로망<sup>(7)</sup>의 학습을 통해 두 거칠기 성분을 입력으로 하고 거칠기를 출력하는 식 (11) 과 같은 상관관계를 모델링할 수 있다. 이와 같은 방법은 실제 측정 데이터를 이용 하기 때문에 천이구간에서의 비선형적인 혼합비율을 고려하여 모델링할 수 있다. 또한, 신경회로망의 자유도를 증가시키므로써 입력에 대한 출력 오차를 사용자가 원하는 범위로 설계할 수 있다.

그러나 주어진 문제에 대해 최적의 신경회로망 구조를 구성할 수 있는 이론적인 방법을 찾기는 힘들다. 따라서 본 논문에서는 초기 신경회로망의 구조를 가중 함수를 이용한 방법에서 사용되었던 식 (11)을 근거로 하여 한 개의 은닉층(hidden layer)과 4 개의 뉴런(neuron)으로 초기화 하였다. 여기서 신경회로망의 구조는 Table 3 과 같은 파라메타들로 구성된다. 이와 같은 초기 신경회로망의 구조에서 시작하여 은닉층의 수를 단계적으로 증가시키면서 출력 오차범위(error range)가 최소화 되는 뉴런의 개수를 각 층별로 결정하였다. 다음은 신경회로망의 구조를 결정하기 위한 과정을 구체적으로 서술한 것이며, 새롭게 추가되는 은닉층의 초기 뉴런의 개수는 4 개로 설정하여 최대 12 개까지로 제한하였다.

*Step 1* : 신경회로망의 구조 초기화

*Step 2* : 학습 후 출력 오차범위 계산

*Step 3* : 최소 오차범위 존재 여부 확인



**Fig. 7** Blending result of  $R_{q,smooth}$  and  $R_{q,rough}$  in SKD11 using neural network

**Table 4** Comparison of output error ranges according to the number of hidden layer and its neuron (unit :  $\mu m$ )

Number of neuron	1 <sup>st</sup> hidden (min, max)	2 <sup>nd</sup> hidden (min, max)	3 <sup>rd</sup> hidden (min, max)	4 <sup>th</sup> hidden (min, max)
4	(-0.030, 0.028)	(-0.024, 0.016)	(-0.039, 0.042)	(-0.021, 0.023)
6	(-0.020, 0.049)	(-0.023, 0.013)	(-0.015, 0.012)	(-0.012, 0.015)
7	(-0.018, 0.014)	(-0.020, 0.015)	(-0.011, 0.010)	(-0.020, 0.036)
8	(-0.013, 0.014)	(-0.015, 0.014)	(-0.014, 0.018)	(-0.038, 0.020)
9	(-0.018, 0.025)	(-0.014, 0.012)	(-0.017, 0.020)	(-0.024, 0.022)
10	(-0.021, 0.026)	(-0.040, 0.025)	(-0.038, 0.020)	(-0.025, 0.024)
12	(-0.028, 0.030)	(-0.024, 0.021)	(-0.051, 0.060)	(-0.068, 0.031)
Determined number	<b>8</b>	<b>9</b>	<b>7</b>	<b>6</b>

**Table 5** Experimental results of SKD11

$R_{q,ref}$	$E_{o1}$	$\sigma$	$R_{q,smooth}$	$R_{q,rough}$	$R_{q,mt}$	$R_{q,NN}$
0.02	39.14	12.50	0.02	0.08	0.018	0.019
0.03	39.31	11.37	0.03	0.07	0.029	0.027
0.04	39.41	11.38	0.04	0.07	0.035	0.041
0.07	39.85	12.88	0.06	0.08	0.063	0.067
0.08	40.09	14.56	0.08	0.09	0.078	0.082
0.09	40.27	15.01	0.09	0.10	0.089	0.089
0.11	40.50	16.43	0.10	0.11	0.106	0.113
0.15	40.59	18.04	0.11	0.12	0.138	0.149
0.18	40.77	28.76	0.12	0.19	0.190	0.180
0.23	40.89	38.32	0.13	0.26	0.255	0.230
0.31	40.96	47.66	0.13	0.32	0.319	0.310

**Table 6** Experimental results of Super alloy

$R_{q,ref}$	$E_{o1}$	$\sigma$	$R_{q,smooth}$	$R_{q,rough}$	$R_{q,mt}$	$R_{q,NN}$
0.04	39.55	11.38	0.04	0.07	0.044	0.041
0.07	39.81	12.88	0.06	0.08	0.060	0.067
0.10	40.32	18.44	0.09	0.12	0.136	0.101
0.15	40.60	20.03	0.11	0.13	0.137	0.150
0.18	40.79	26.53	0.12	0.17	0.175	0.180
0.28	40.93	43.30	0.13	0.29	0.289	0.280

Step 4 :

존재하면 → Step 5 로 이동

존재하지 않으면

→ 뉴런 수를 1 만큼 증가 후 Step 2 로 이동

Step 5 :

원하는 오차범위이면 → 종료

원하는 오차범위가 아니면

→ 은닉층 수를 1 만큼 증가 후 Step 2 로 이동

이와 같은 알고리즘을 이용하여 계산된 오차 범위를 Table 4 에 나타내었다. Table 4 는 은닉층의 수와 그것의 뉴런 수에 따른 신경회로망의 출력 오차 범위를 나타낸다. 본 논문에서는 단일 MPU 에서 구현하는 것을 목표로 하기 때문에 과도한 은

**Table 7** Experimental results of Silicon-wafer

$R_{q,ref}$	$E_{o1}$	$\sigma$	$R_{q,smooth}$	$R_{q,rough}$	$R_{q,mt}$	$R_{q,NN}$
0.02	39.18	7.91	0.02	0.05	0.020	0.023
0.04	39.52	9.26	0.04	0.06	0.042	0.040
0.06	39.93	11.19	0.07	0.07	0.068	0.067
0.08	40.15	11.43	0.08	0.07	0.082	0.076
0.09	40.30	13.85	0.09	0.09	0.091	0.093
0.10	40.36	14.46	0.10	0.09	0.095	0.102
0.11	40.50	15.53	0.10	0.10	0.104	0.103
0.15	40.76	17.19	0.12	0.11	0.127	0.150
0.18	40.82	26.38	0.12	0.17	0.174	0.180
0.20	40.91	29.54	0.13	0.20	0.195	0.200
0.25	41.12	36.71	0.14	0.24	0.244	0.250
0.30	40.24	47.46	0.15	0.32	0.317	0.300

**Table 8** Comparison of roughness error rates (unit : % )

$R_{q,ref}$	SKD11		Super alloy		Silicon wafer	
	$R_{q,mt}$	$R_{q,NN}$	$R_{q,mt}$	$R_{q,NN}$	$R_{q,mt}$	$R_{q,NN}$
0.02	10.0	5.0	-	-	0	15.0
0.03	3.3	10.0	-	-	-	-
0.04	12.5	2.5	10.0	2.5	5.0	0
0.06	-	-	-	-	13.3	11.7
0.07	10.0	4.3	14.3	4.3	-	-
0.08	2.5	2.5	-	-	2.5	5.0
0.09	1.1	1.1	-	-	1.1	3.3
0.10	-	-	36.0	1.0	5.0	2.0
0.11	3.6	2.7	-	-	5.5	6.4
0.15	8.0	0.7	8.7	0	15.3	0
0.18	5.6	0	2.8	0	3.3	0
0.20	-	-	-	-	2.5	0
0.23	10.9	0	-	-	-	-
0.25	-	-	-	-	2.4	0
0.28	-	-	3.2	0	-	-
0.30	-	-	-	-	5.7	0
0.31	2.9	0	-	-	-	-

닉층의 수는 계산 복잡도(computational complexity)를 증가 시켜 구현이 힘들 수가 있다. 따라서 은닉층의

수를 최대 4 개로 제한하였다. Table 4 와 계산속도 그리고 오차범위를 고려하여 3 개의 은닉층과 그것들의 뉴런의 개수가 각각 8 개, 9 개, 7 개로 이루어진 구조를 최종 선택하였다. 그리고 결정된 구조의 출력 오차범위를 줄이기 위해 재 학습을 시켰다. 여기서, 신경회로망의 초기 가중치(weight value)의 설정에 따라 출력오차 범위에 대한 약간의 차이는 발생할 수 있고, 주어진 문제를 해결할 수 있는 다른 구조가 존재할 수도 있다. 그러나 이러한 방법은 비록 많은 학습시간을 요구하지만 신경회로망의 구조를 선택하기 위한 체계적이고 합리적인 방법이 될 수 있다. Fig. 7 은 Table 4 를 통해 결정된 신경회로망을 이용하여 계산한 SKD11 의 거칠기  $R_{q,NV}$  를 기준 거칠기  $R_{q,ref}$  와 비교한 그래프를 나타낸다. 가중치 함수를 이용한 결과인 Fig. 6 과 비교하였을 때 기준 거칠기에 대해 선형적인 결과를 나타냄을 알 수 있다.

## 5. 실험 결과 분석

본 논문에서는 평균 거칠기를 추정하기 힘든 천이구간에서 정/난반사 성분을 블렌딩 하기 위한 두 가지 방법을 이용하여 실험하여 그 결과를 Table 5, 6, 7 에 나타내었다. 이러한 데이터를 이용하여 기준 거칠기들에 대한 오차율들을 Table 8 에 각각 나타내었다. 천이구간에서 블렌딩 결과를 비교해볼 때 가중 함수를 이용한 방법에 비해 신경회로망을 이용한 방법이 훨씬 적은 오차율을 보이고 있다. 이것은 전자의 방법은 천이구간 내에서 각 성분에 대한 부정확한 계수들의 사용과 비선형적인 혼합비율을 고려하지 않고 특정 함수를 일괄적으로 사용하였기 때문에 오차가 다소 크게 발생하였다고 볼 수 있다. 그러나 후자의 방법은 실제 측정 데이터를 이용하여 학습을 통해 추정하였기 때문에 암시적(implicitly)으로 혼합비율을 고려했다고 볼 수 있다. 따라서 모든 구간에 대해 거의 정확한 평균 거칠기를 추정할 수 있으며, 정밀도를 10 nm 를 기준으로 했을 때 상용 제품과 거의 동일한 성능을 나타낸다.

## 6. 결 론

레이저 반사광을 이용한 거칠기 측정에 있어서 정반사 성분과 난반사 성분을 전 측정구간에 대해 적절히 블렌딩할 수 있는 방법들을 제시하여 실험한 결과, 다음과 같은 결론을 얻었다.

(1) 제시된 블렌딩 방법들을 통해 두 가지 반사

성분들에 대한 표면 거칠기 계산식을 전 구간에 대한 단일 상관관계의 형태로 표현 할 수 있다.

(2) tanh 함수를 이용하여 블렌딩구간과 각 성분의 블렌딩 비율을 유연하게 조절할 수 있는 가중 함수를 정의할 수 있다.

(3) 실제 측정된 데이터를 이용하여 학습한 신경회로망은 천이구간 내에서 비선형적인 혼합비율을 적절하게 조절할 수 있다.

(4) 특히, 신경회로망을 이용한 방법은 상용 접촉식 표면 거칠기 제품의 측정 결과와 비교했을 때 측정 오차를  $\pm 10nm$  범위로 유지할 수 있다.

## 후 기

이 논문은 2007 년도 부산대학교 박사후연수과정 지원사업에 의하여 연구되었음.

## 참고문헌

- (1) Satoru Takahashi, Takahashi Miyoshi, Yasuhiro Takaya and Yasufumi Tatsuno, 2002, "Study on In-Process Measurement of Silicon Wafer Surface Defects by Laser Scattered Defect Pattern (2<sup>nd</sup> Report) – Fast Defect Measurement Method Method Using LSDP," *Japan Society of Precision Engineering*, Vol. 68, No. 7, pp. 1431~1435.
- (2) Hiroshi Harad, Hideki Nakajima, Teruo Yamaguchi and Atsuhiko Noda, 2002, "Optical Sensing of Surface Roughness for Polishing Robot (3<sup>rd</sup> Report)," *Japan Society of Precision Engineering*, Vol. 68, No. 11, pp. 962~966.
- (3) Seo, Y. H., Kim, J. N. and Ahn, J. H., 2004, "Estimation of Specular Light Power by Adjusting Incident Laser Power for Measuring Mirror-Like Surface Roughness," *Journal of the Korean Society of Precision Engineering*, Vol. 21, No. 6, pp. 94~101.
- (4) Beckmann, P. and Spizzichino, A., 1963, "The Scattering of Electromagnetic Waves from Rough Surfaces," Pergamon press, Oxford.
- (5) Nayar, Shree K., Ikeuchi, Katsushi, Kanade and Takeo, 1991, "Surface Reflection: Physical and Geometrical Perspectives," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 13, No. 7, pp. 611~634.
- (6) Seo, Y. H. and Ahn, J. H., 2004, "Microscopic Surface Estimation Through Light Distribution Analysis of Reflected Laser Beam," *The 30<sup>th</sup> Annual Conference of the IEEE Industrial Electronics Society*, Vol. 2, pp. 1924~1928.
- (7) Draelos, T. and Hush, D., 1996, "A Constructive Neural Network Algorithm for Function Approximation," *Neural Networks, IEEE International Conference on*, Vol. 1, pp. 50~55.