

Deep Learning을 사용한 백색광 주사 간섭계의 높이 측정 방법

백상현[†], 황원준^{**}

Measurement Method of Height of White Light Scanning Interferometer using Deep Learning

Sang Hyune Baek[†], Wonjun Hwang^{**}

ABSTRACT

In this paper, we propose a measurement method for height of white light scanning interferometer using deep learning. In order to measure the fine surface shape, a three-dimensional surface shape measurement technique is required. A typical example is a white light scanning interferometer. In order to calculate the surface shape from the measurement image of the white light scanning interferometer, the height of each pixel must be calculated. In this paper, we propose a neural network for height calculation and use virtual data generation method to train this neural network. The accuracy was measured by inputting 57 actual data to the neural network which had completed the learning. We propose two new functions for accuracy measurement. We have analyzed the cases where there are many errors among the accuracy calculation values, and it is confirmed that there are many errors when there is no interference fringe or outside the learned range. We confirmed that the proposed neural network works correctly in most cases. We expect better results if we improve the way we generate learning data.

Key words: White-light Scanning Interferometry, Deep Learning, BRNNs, LSTM

1. 서 론

광학렌즈, 반도체, 평판 디스플레이 등의 여러 산업 분야에서 물체의 표면 형상이 수 μm ~수십 μm 높이에 불과한 다양한 제품들이 제조되고 있어, 이 제품들의 표면을 정밀하게 측정하고자 하는 요구가 같이 증대 되고 있다. 이러한 미세 형상을 측정하는 삼차원 표면 형상 측정기술에는 여러 가지 방법이 있는데, 그 중 백색광 간섭계(White-Light Interferometry) [1] 는 빛의 간섭 효과를 이용해 비접촉식으로

물체의 표면형상을 빠르게 측정할 수 있어 많은 분야에서 사용되고 있다. 백색광 간섭계는 간섭 무늬를 획득하는 방식에 따라 다시 몇 가지로 나누어지는데 이중 가장 대표적인 방법은 PZT [2]나 모터를 이용해 간섭무늬를 얻는 백색광 주사 간섭계(White-light Scanning Interferometry)이다. 백색광 주사 간섭계는 연속적으로 높이를 변경하면서 획득한 이미지에서 개별 이미지 픽셀의 밝기 변화를 추출하고, 이 픽셀의 밝기가 보강 간섭이나 상쇄 간섭에 의해 가장 크게 변화되는 지점을 찾아 개별 픽셀의 높이를

* Corresponding Author : WonJun Hwang, Address: (16499) 206, World cup-ro, Yeongtong-gu, Suwon, Gyeonggi-do, Korea, TEL : +82-31-219-2632, FAX : +82-31-219-1621, E-mail : wjhwang@ajou.ac.kr

Receipt date : Jul. 10, 2018, Approval date : Jul. 26, 2018
[†] Dept. of Computer Eng., Graduate School, Ajou University (E-mail : shbaek@gmail.com)

^{**} Dept. of Computer Eng., Graduate School, Ajou University

* This research was supported by Basic Science Research Program through the National Research Foundation of Korea (NRF) funded by the Ministry of Education, Science and Technology (NRF-2017R1D1A1B03031560)

결정하여 물체의 형상을 측정하는 방법이다. 간섭에 의한 밝기 변화로부터 높이를 찾는 방법으로는 대표적으로 FFT와 Inverse FFT를 이용하는 방법 [3]이 있으며, 이 외에도 계산 속도나 측정 정밀도를 개선하기 위한 여러 방법들이 연구 되어 사용되고 있다.

본 연구에서는 신경망을 사용해 간섭 무늬로부터 물체 표면의 높이를 측정하는 방법과 이 신경망을 학습하기 위해 실제 데이터가 아닌 가상 데이터를 사용하는 방법을 제안하였다. 실제 측정된 데이터를 Squared-envelope function Estimation by Sampling Theory (SEST) [4] 알고리즘으로 계산하여 형상을 측정된 결과와 신경망에 의하여 예측된 형상을 비교하였으며, 오차가 발생한 신호에 대한 원인을 분석하였다.

2. 기존 연구

2.1 백색광 주사 간섭계

물체의 형상을 찾기 위한 백색광 주사 간섭계는 일반적으로 Fig. 1 [5]과 같은 구조를 가지고 있다. Fig. 1에서 광원을 출발한 빛은 중앙의 빔 스플리터 (Beam Splitter)에서 2개로 나뉘어져 하나는 기준 거울 (Reference mirror)에서 반사되고 다른 하나는 물체에서 반사되어 다시 하나로 합쳐지게 된다. 이때 기준 거울까지의 거리 l 과 물체까지의 거리 $p(x,y)$ 의




Fig. 1. White Light Scanning Interferometer Diagram [5].

차이에 의해 빛의 위상 차이가 발생하는데, 2개의 빛이 동일한 위상을 가진 경우 빛이 더욱 강해지는 보강간섭이 일어나고 정반대의 위상을 가진 경우에는 더욱 어두워지는 상쇄 간섭이 일어난다[6].

기준 거울을 PZT나 모터 등을 사용해 이동시키면 거리 l 이 변하기 때문에 두 빛의 위상 차이가 연속적으로 발생하여 보강 및 상쇄 간섭의 모양이 변화된다. Fig. 1에서 거리 l 을 변경 시키면서 일정 거리 간격으로 이미지를 획득하면 여러 개의 순차적인 이미지를 얻을 수 있으며, 이 중 한 픽셀인 $p(x,y)$ 지점에서 빛의 밝기 변화를 그려보면 Fig. 2와 같다. Fig. 2에서 x 축은 이미지를 획득한 일련 번호이고, y 축은 밝기 값으로 0~255의 값을 가진다. 영상의 초점이 안 맞는 지점에서는 밝기 변화가 없으면, 영상의 초점이 맞는 중앙부에서는 2개 빛의 보강 및 상쇄 간섭에 의해 밝기의 변화가 나타난다. 이 신호에서 Fig. 2의 붉은 색으로 그려진 선과 같은 외형선 (Envelope)을 구한 후 이 외형선의 정점을 구하면, 이 정점의 위치가 해당 픽셀 $p(x,y)$ 지점의 높이이다. 이미지 전체 픽셀에 대해 동일한 작업을 반복하면 물체의 표면 형상을 얻을 수 있다. 외형선의 정점을 찾는 대표적인 방법으로는 FFT와 Inverse FFT를 이용하는 방법이 있으며 이 외에 여러 방법이 있는데 본 연구에서는 FFT와 Inverse FFT를 사용하는 방법과 Squared-envelope function Estimation by Sampling Theory(SEST) 알고리즘을 사용하는 방법에 대해 검토하였다.

2.1 FFT와 Inverse FFT를 사용한 측정 방법 [3, 7]

Fig. 3는 FFT를 사용한 정점 추출 측정 방법을 보여준다. 연속적으로 획득된 이미지의 $p(x,y)$ 위치에서 기록된 밝기 변화는 Fig. 3(a)와 같다. 이 신호를 Fourier Transform(FFT) 적용시켜 주파수축으로 변환시키면 신호는 Fig. 3(b)와 같은 형태를 갖게 된다. Fig. 3(b) 신호에 대역 필터를 적용하여 주 신호 외에 DC와 잡음 성분 등을 제거하면 Fig. 3(c)와 같은 신호를 얻게 된다. Fig. 3(c)의 신호를 다시 Inverse FFT를 시키면 Fig. 3(d)와 같은 깨끗한 신호를 얻게 되며, 이 신호의 정점 위치를 찾으면 $p(x,y)$ 의 높이를 알 수 있다. FFT와 Inverse FFT를 사용하는 방법은 높은 정밀도에 비해 계산에 많은 시간이 걸려 빠른 속도를 요구하는 분야에서는 적용이 어려운 단

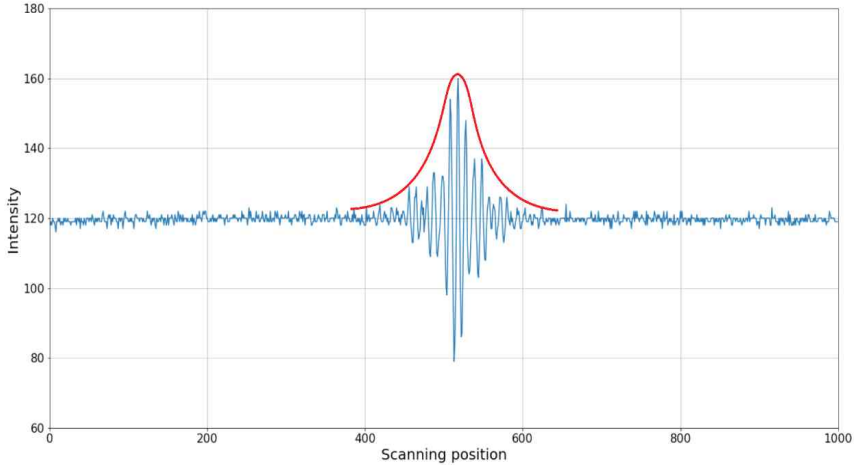


Fig. 2. Intensity of $p(x, y)$. Red line is envelope of signal.




Fig. 3. (a) Recorded intensity (b) spectrum of Fourier transform (c) filtering out DC and negative frequencies and centralizing (d) extracted coherence envelope by inverse Fourier Transform [7]

점이 있다.

2.2 Squared-envelope function Estimation by Sampling Theory(SEST) 알고리즘을 사용한 측정방법 [4,5]

SEST 알고리즘은 샘플링 이론을 바탕으로 squared-envelope 함수를 신호에 적용해, 적은 샘플 데이터를 가지고도 신호의 정점을 계산할 수 있다. SEST 알고리즘은 FFT와 Inverse FFT를 사용한 방법에 비해 정밀도는 떨어지나 간섭 무늬 신호의 정점을 빠른 속도로 계산 할 수 있는 장점이 있다. 식 (1)~(3)은 SEST 알고리즘을 사용해 정점을 구하는 식이다. 식

(1)~(3)에서 n 은 이미지를 획득한 순번이고, N 은 이미지의 총 개수이다. Z_n 은 n 번째 위치임을 의미하며, $g(Z_n)$ 은 n 번째 이미지의 밝기이다. 식 (1)에서 \hat{C} 은 전체 신호의 평균 밝기이며, 식 (2)에서 f_n 은 밝기 데이터에서 평균 밝기를 뺀 데이터이다. 식 (3)에서 r_N 은 SEST 알고리즘으로 계산된 결과 값이며, r_N 값이 최대가 되는 Z_j 가 정점의 위치이다.

$$\hat{C} = \frac{1}{N} \sum_{n=0}^{N-1} g(Z_n) \tag{1}$$

$$f_n = g(Z_n) - \hat{C} \tag{2}$$

$$r_N(Z_j) = (f_j)^2 + \frac{4}{\pi^2} \left\{ \sum_{n=-\lfloor \frac{j+1}{2} \rfloor}^{\lfloor \frac{N-j-2}{2} \rfloor} \frac{f_{j+2n+1}}{2n+1} \right\}^2 \tag{3}$$

SEST 알고리즘을 계산할 때 측정 중 광원의 밝기가 변하거나, 물체의 특성에 의해 밝기가 변하는 것과 같이 특수한 경우에는 단순히 식 (1)~(3)을 적용하였을 때 올바른 값을 찾지 못하게 된다. Fig. 4(a)의 경우 찾고자 하는 정점의 값은 500 근처여야 하는데 SEST 알고리즘을 적용하였을 때는 정상적으로 찾지 못하고 1,000 가까운 값을 제시한다. 이를 해결하기 위해서는 단순히 신호의 평균값을 구하지 않고, DC나 AC 성분을 모두 제거한 후 SEST 알고리즘을 적용하는 것이 필요하다. Fig. 4(b)는 Fig. 4(a)의 신호에 High Pass Filter (HPF) 를 적용한 후의 결과 신호이며, 이 신호에 SEST 알고리즘을 적용한 결과 Fig. 4(b)에서 노랑색 선으로 표시된 정상적인 위치를 찾았다.

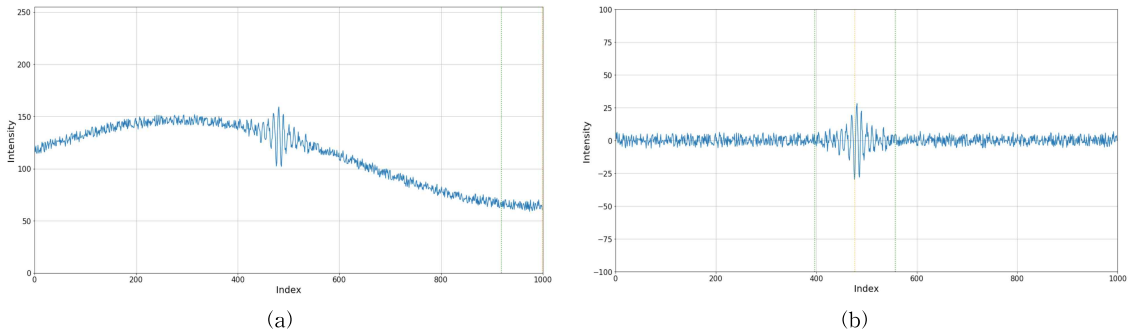


Fig. 4. Intensity (a) Original (b) after High-Pass Filtering.

3. 제안 방법

본 연구에서는 Tensorflow [8]를 기반으로 신호의 최대 위치를 찾아내는 신경망을 구성하였다 [9, 10, 11]. Fig. 5는 제안된 전체 신경망의 구성이다. 신경망에 입력되는 데이터는 30um 간격으로 1,000회 획득된 이미지로부터 추출되며, 이미지의 한 픽셀 $p(x,y)$ 지점의 밝기 값들이다. 이 신호를 Bidirectional Recurrent Neural Networks(BRNNs)에 입력하였다 [12]. BRNNs는 전방향 상태와 후방향 상태의 2개 Hidden layer로 구성되어 있는데 Hidden layer들은 Long Short Term Memory(LSTM) [13]로 구성하였다.

Fig. 6 [13]은 LSTM의 구조 예인데, 현재 입력 데이터 X_t 와 과거 출력 데이터 h_{t-1} 2개를 입력 받아

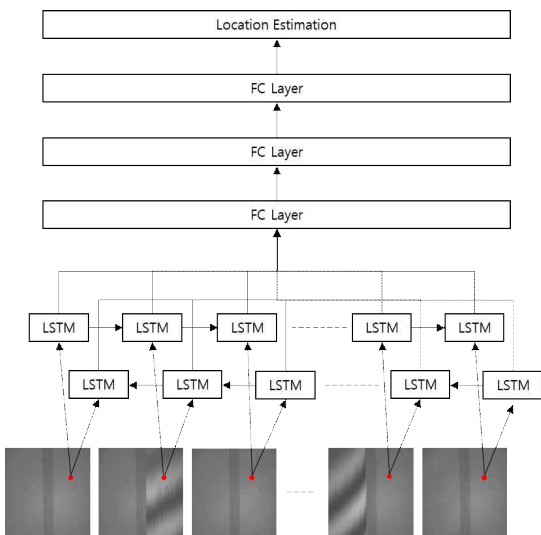


Fig. 5. Architecture of the proposed Network.

출력 h_t 을 내보낸다. 따라서 $t-1$ 시점의 출력 신호 h_{t-1} 이 t 시점의 출력 신호 h_t 에 영향을 주게 되어 과거의 값을 기억하는 효과가 나타나며, 이 특성에 의해 시간적으로 연속성이 있는 데이터를 처리하는데 적합하다.

BRNNs의 출력은 3개의 Fully-Connected(FC) layer을 거쳐 신호의 정점 위치를 예측한다. 구성된 신경망은 가상으로 생성한 신호를 사용해 학습을 시켰으며, 학습이 끝난 신경망에 실제 측정된 신호를 입력해 신경망의 동작을 검증하였다. 실제 측정 신호의 정점은 HPF를 적용한 후 SEST 알고리즘을 사용해 구하였으면, 이 계산 값과 신경망의 예측 값을 비교, 분석하였다.

4. 실험

4.1 샘플

본 연구에 사용한 데이터는 Fig. 7과 같은 샘플로부터 측정되었으며, 샘플은 백색의 세라믹 재질의 물체이고 표면은 평평하게 가공되어 있다. 샘플은 5개의 조각으로 구분되어 있어 각 조각 별로 높이가 다르게 가공되었으며, 각각의 높이 차이는 Fig. 7 하단




Fig. 6. The repeating module in an LSTM contains four interacting layers.




Fig. 7. Sample (Ceramic with thickness variation).

에 표시된 바와 같이 1, 2, 5, 10 μm이다. Fig. 7에서 붉은 색으로 표시된 원은 측정지점을 의미하며 상하 각각 9개씩 모두 18곳을 측정하였다. 측정 지점을 약간씩 변경해 가며 총 3회를 측정하였으며, 그 중 1회는 조명의 밝기를 변경하였다.

측정 지점별로 거리를 변경하면서 1,000회 이미지를 획득 하였으며, 획득한 이미지 간의 높이 차이는 30 μm였다. 각 이미지는 720 × 720 pixel 해상도를 가지고 있는 8 bit 그레이 스케일(Gray Scale) 이미지다. 생성된 이미지 데이터는 총 18 point × 3회 = 54개였으며, 이 밖에 신호에 예외가 많이 포함된 3개의 데이터를 추가하여 모두 57개의 데이터였다.

4.2 학습용 데이터

학습용 데이터는 실제 데이터가 아닌 가상으로 생성한 데이터를 사용하였다. 57개의 측정 데이터 중 임의의 한 개를 선택한 후 이 중 1개의 신호를 선택하여 이 신호를 기준으로 가상 데이터를 생성하였다. 가상 데이터 생성에 사용한 기준 신호는 Fig. 2와 같다. 기준 데이터에서 정점의 위치, 파형의 크기, 파형 전체의 DC 및 AC 레벨, 잡음의 크기를 변경하여 10,240개의 가상 신호를 생성하였다. 각각의 가상 신호 생성 시에 변형량은 Table 1을 기준으로 무작위로 선택하였으며, 이때 정점의 위치가 너무 작거나

Table 1. Variation of Raw Signal

Value	Range
Peak Location	81 ~ 920
Peak to Peak	30% ~ 120%
DC bias (gray level)	-50 ~ 50
AC bias (gray level)	50 * sin(angle): angle(0° ~ 300°)
Noise (gray level)	-5 ~ 5

커서 신호가 잘리는 것을 막기 위해 정점의 위치는 81 ~ 920 범위로 제한하였다. 또한 변형된 파형이 0 ~ 255 사이의 밝기 범위를 벗어나 너무 크거나 작은 경우에도 가상 데이터에서 제외하였다. 생성된 가상 신호는 HPF를 적용한 후 SEST 알고리즘을 적용하여 정점의 위치를 결정하였다.

4.3 검증용 데이터

검증용 데이터는 4.1항의 샘플에서 측정된 54개의 데이터와 타 샘플에서 측정된 3개의 데이터 모두 57개를 사용하였다. 획득한 이미지의 해상도가 720 × 720 pixel 이어서 가로, 세로 20 pixel 간격으로 측정점을 선택하여 가로 35개 × 세로 35개, 총 1,225개를 선택하였다. 각 측정 점에서 추출된 신호에 HPF를 적용한 후 SEST 알고리즘을 적용해 정점의 위치를 계산하였으며, 총 신호의 개수는 57 × 1,225 = 69,825 개였다. 학습 중 사용한 검증용 데이터는 57개 세트 중 임의로 1개를 선택하였으며 모든 학습이 끝난 후에는 57개 데이터 전체에 대해 정확도를 검증하였다.

4.4 신경망

본 연구에 사용된 신경망의 상세한 구조는 Table 2와 같다. 일반적인 경우 LSTM에 입력되는 신호의 Time Step은 신호의 길이와 동일하게 되는데 [9, 10], 본 연구에서는 1,000개의 값을 인접한 2개씩 묶어 모두 500개의 Time step을 가지도록 변경하여 사용하였다. Time Step을 1,000으로 사용하는 경우 학습을 위해 사용하는 미니 배치(batch)의 크기에 제한이 있어 학습 시간이 길어지는 문제가 있었다. 이를 개선하기 위해 입력을 여러 크기로 변경하면서 학습 시간

Table 2. Network architecture of the proposed method

Layer Name	Layer Description
Input	Input = 4 (gray level)
BRNNs	Time step=250, Input=4, output=512 Forward LSTM State=256, tanh Backward LSTM State=256, tanh
FC layer 1	Nodes = 1,024, tanh
Dropout	0.5
FC layer 2	Nodes = 1,024, linear
Dropout	0.5
FC layer 3	Nodes = 1, elu

Table 3. Accuracy function

Accuracy 1	Accuracy 2
P[i] : prediction values G[i] : ground truth values N : Size of G L : Cut level	P[i] : prediction values G[i] : ground truth values D[i] : difference N : Size of G L : 0.95
1. Count = 0 2. For i=0 to N-1 3. If absolute(P[i] - G[i]) < L 4. Count += 1 5. End For 6. Result = Count / N	1. For i=0 to N-1 2. D[i] = absolute(P[i] - G[i]) 3. End For 4. Sort of D (Ascending order) 5. Result = D[N * L]

및 성능을 비교한 결과 현재 구조에서는 Time Step을 500개로 만드는 것이 가장 좋은 결과를 보였다. Time Step을 1,000으로 사용한 경우에는 오히려 성능이 높지 않았으며 이는 많은 LSTM 모듈을 통과하면서 계산 중간에 값의 일부가 소실되어 버리는 Vanishing Gradients 문제 [14]가 일부 발생한 것으로 판단되며 향후 더 많은 시도가 필요할 것으로 생각된다. BRNNs의 출력은 FC 층에 연결하였는데 FC 층은 모두 3개로 구성하였으며, 이중 마지막 FC 층은 노드 1개로 구성하여 앞에 층의 모든 결과 값을 모은 후 정점의 위치를 출력하도록 하였다.

4.5 손실 함수, 정확도 함수 및 최적화 알고리즘

신경망 학습 시 손실 함수는 Mean Square Error (MSE)를 사용하였으며, 정확도 함수는 2가지를 정의하여 사용하였다. 정확도 함수를 정의하기 위해 먼저 SEST 알고리즘에 의한 계산 값과 신경망의 예측 값의 차이를 오차로 정의하였다. 정확도 함수 1은 한 개 데이터의 전체 신호 중 오차가 허용되는 범위 내에 들어온 신호의 비율로 정의하였다. 오차의 허용 범위는 30단계로 하였으며 이는 전체 1,000단계의 3%에 해당하는 값이다. 정확도 함수 2는 데이터 내의 신호 전체의 오차를 오름차순으로 정렬 한 후 95%에 해당하는 1,164번째 값의 오차로 정의하였다. 학습이 반복되어 정확도가 올라가면 정확도 함수 1의 경우 1에 가까운 값을 가지게 되고, 정확도 함수 2의 경우에는 오차가 줄어들어 0에 접근하게 된다. Table 3에 사용된 정확도 함수를 기술하였다. 최적화 알고리즘은 Adam 알고리즘을 사용하였으며, 학습 중 사용되는 초기 학습 값(learning rate)은 손실 값

이 줄어들어 따라 줄어 나갔다. 초기 학습 값은 Table 4와 같이 적용하였다.

Table 4 Learning rate by loss

loss	Learning Rate
loss >= 10000	0.001
1000 <= loss < 10000	0.003
300 <= loss < 1000	0.001
100 <= loss < 300	0.0005
loss < 100	0.0001

4.6 실험 결과

학습은 모두 200 이폭(epoch)를 진행하였으며, 학습이 진행됨에 따라 손실 값은 Fig. 8(a)와 같이 줄어들었다. Fig. 8(b)는 정확도 함수 1의 결과이고, Fig. 8(c)는 정확도 함수 2의 결과이다.

학습이 끝난 신경망에 검증용 데이터 57개를 적용해 정확도를 확인하였다. Fig. 9(a)는 데이터 별로 정확도 함수 1의 결과이며 Fig. 9(b)는 정확도 함수 2의 결과이다. 전체 데이터의 절반 정도에서 좋은 결과를 보이고 있으나 1T-2, 12T-1~12B-3, 23T-1~23B-3, 34T-1~34B-3, 45T-1~45B-3, S1, S3, S4는 오차가 크게 나타났다.

4.7 오차 분석

오차가 크게 발생한 데이터는 1T-2, 12T-1~12B-3, 23T-1~23B-3, 34T-1~34B-3, 45T-1~45B-3, S1, S3, S4 였다. 각 데이터의 오차를 분석한 결과 크게 2가지 경우로 발생 원인을 나눌 수 있었다.

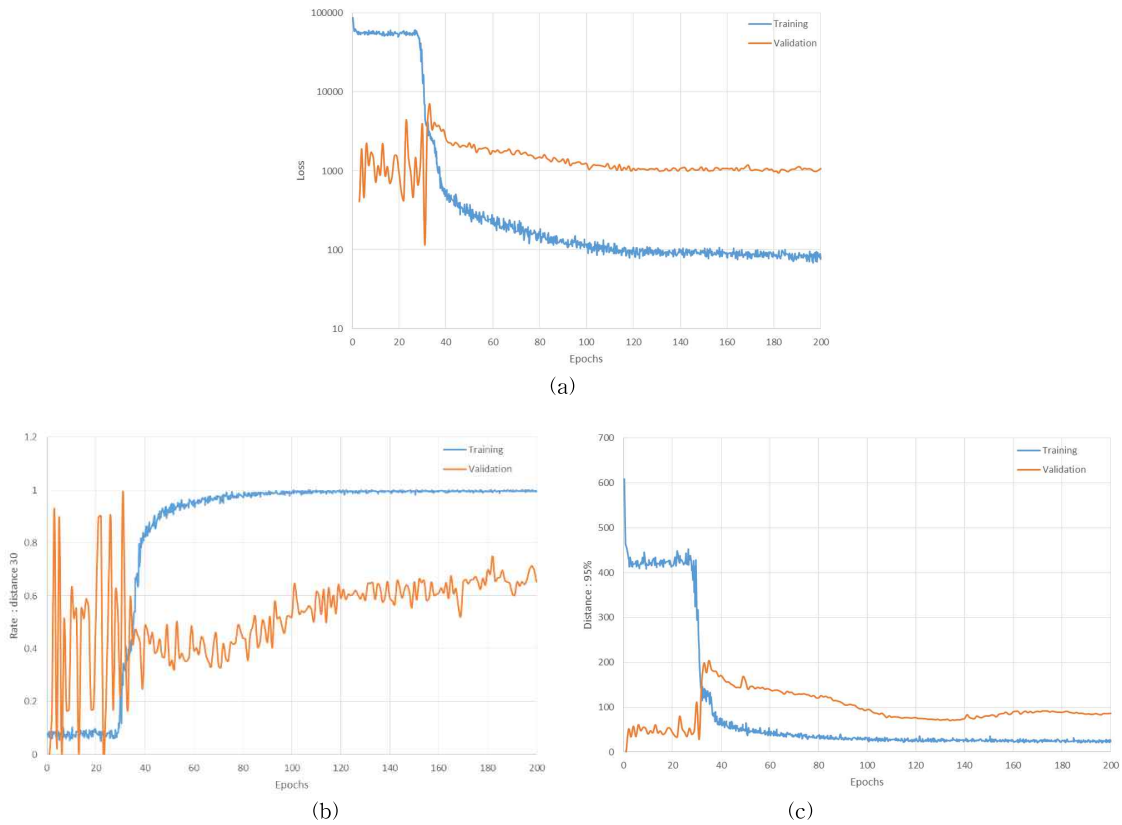


Fig. 8. Training graph (a) losses (b) accuracy 1 (c) accuracy 2.

하나는 신호가 학습 범위를 벗어난 경우로 1T-2, S3, S4가 이에 해당한다. 다른 하나는 신호 상에 간섭 무늬에 의한 변화가 없는 것으로 12T-1~12B-3, 23T-1~23B-3, 34T-1~34B-3, 45T-1~45B-3, S1가 이에 해당한다.

Fig. 10, Fig. 11, Fig. 12는 학습 범위를 벗어난 경우의 데이터 별 표면 형상과 신호의 예를 보여준다. 각 그림에서 (a)는 SEST 알고리즘을 사용해 계산한 표면 형상이며, (b)는 신경망으로 예측한 형상이다. (c)는 오차가 발생한 신호들의 예이다. Fig. 10는 1T-2의 데이터인데 실제 데이터는 정점의 위치가 950 정도로 높은 쪽으로 치우쳐 있다. 그러나 학습 데이터에서는 신호가 왜곡되는 경우를 피하기 위해 정점의 위치를 81~920으로 제한하였다. 따라서 신경망은 학습의 결과 정점의 위치를 920쪽으로 낮추려는 경향을 보였으며 이로 인해 실제 정점의 위치와 차이가 발생하게 되었다. Fig. 11은 S3 데이터인데 실제 신호의 크기는 20 정도인 것에 반해 학습 데이

터에서는 신호의 크기를 기준 신호의 30~120%로 정하여 기준 신호가 80 일때 24~96 사이로 제한되고 있다. 이 차이로 인해 신경망의 예측 값에 오차가 발생하게 되었다. Fig. 12은 S4 데이터인데 신호가 밝아 밝기 값의 최대치가 250 가까이 되었다. 학습 데이터에서는 신호의 왜곡을 막기 위해 밝기의 최대치를 200 이하로 제한하고 있는데 실제 신호가 이를 벗어나자 신경망의 예측 값에 오차가 발생하게 되었다. 결론적으로 학습 데이터를 생성할 때 Table 1의 조건을 준수하였는데 이 3개 데이터의 경우 학습한 범위를 벗어나고 있다. 따라서 학습 데이터를 생성할 때 현재 보다 넓은 범위로 가상 데이터를 생성한다면 이 문제를 해결 할 수 있을 것으로 판단된다.

Fig. 13, Fig. 14는 간섭 무늬가 없는 경우의 표면 형상과 신호의 예를 보여준다. Fig. 13은 12T-1 데이터인데 물체의 표면 형상이 불연속 면을 가지고 있음을 볼 수 있다. 그리고 불연속 면에서는 신호가 정상적으로 측정 및 계산이 되지 않고 있다. 마찬가지로

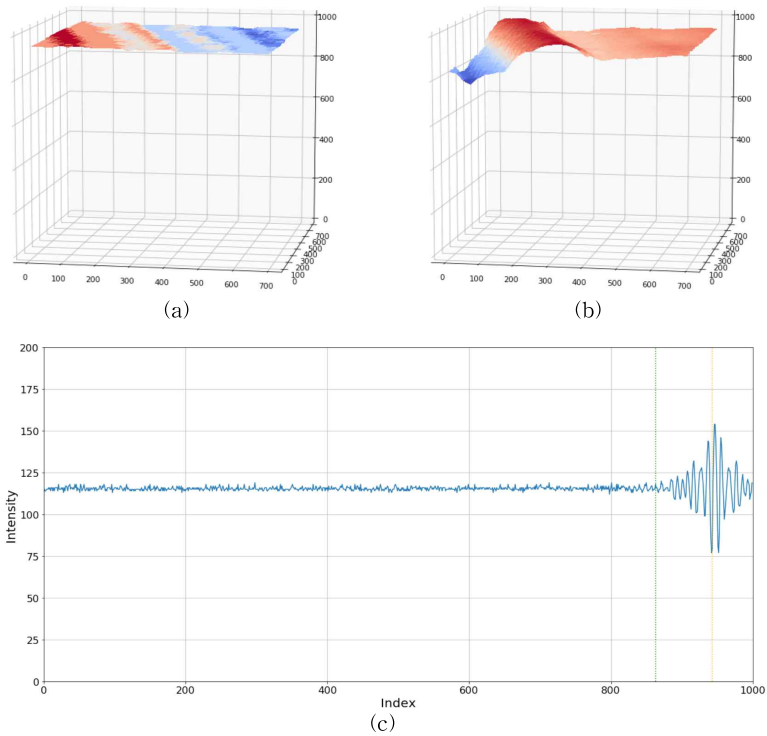


Fig. 10. 1T-2 has high peak position (a) 3D profile of SEST (b) 3D profile of prediction (c) recorded intensity.

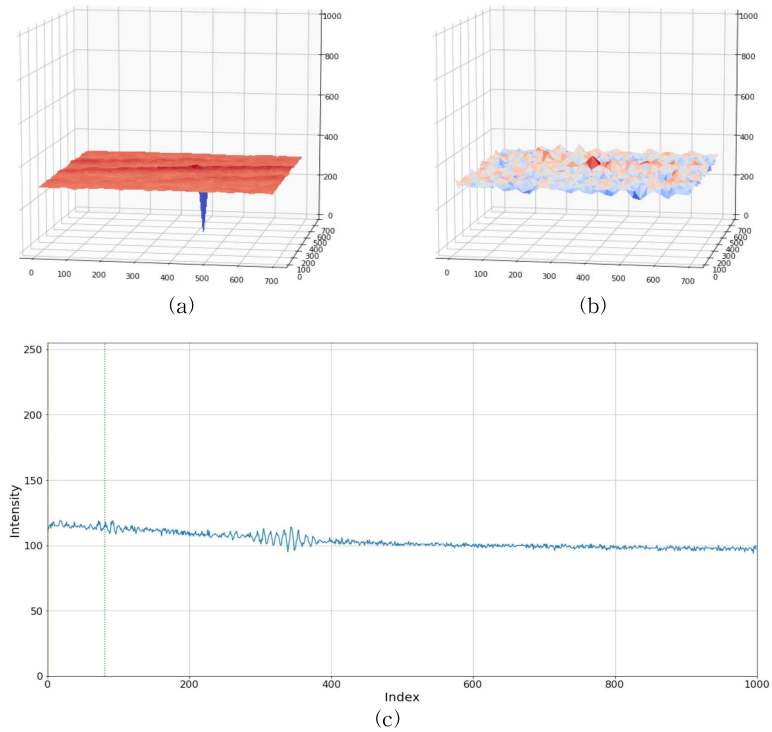


Fig. 11. S3 has small amplitude (a) 3D profile of SEST (b) 3D profile of prediction (c) recorded intensity.

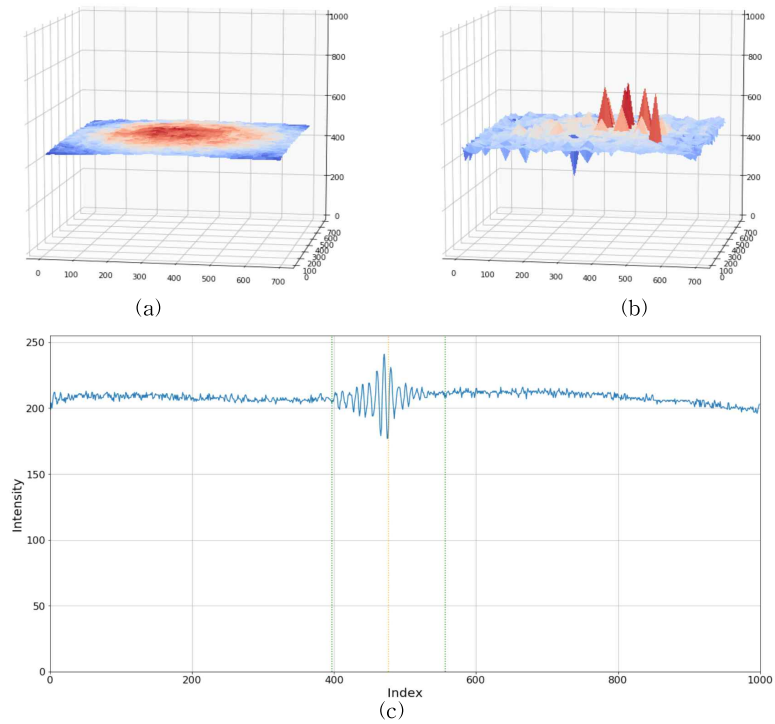


Fig. 12. S4 has a high gray level (a) 3D profile of SEST (b) 3D profile of prediction (c) recorded intensity.

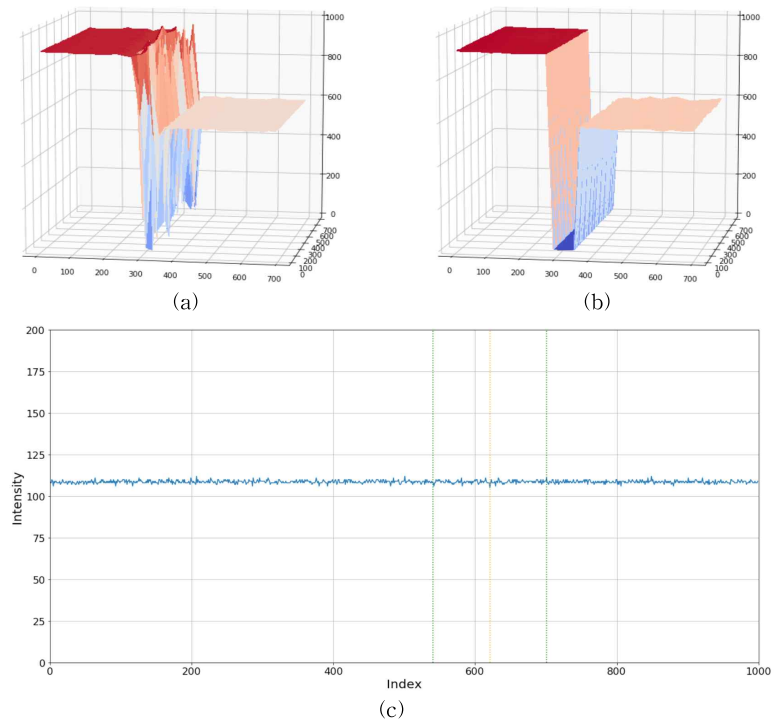


Fig. 13. 12T-1 has a step (a) 3D profile of SEST (b) 3D profile of prediction (c) recorded intensity.

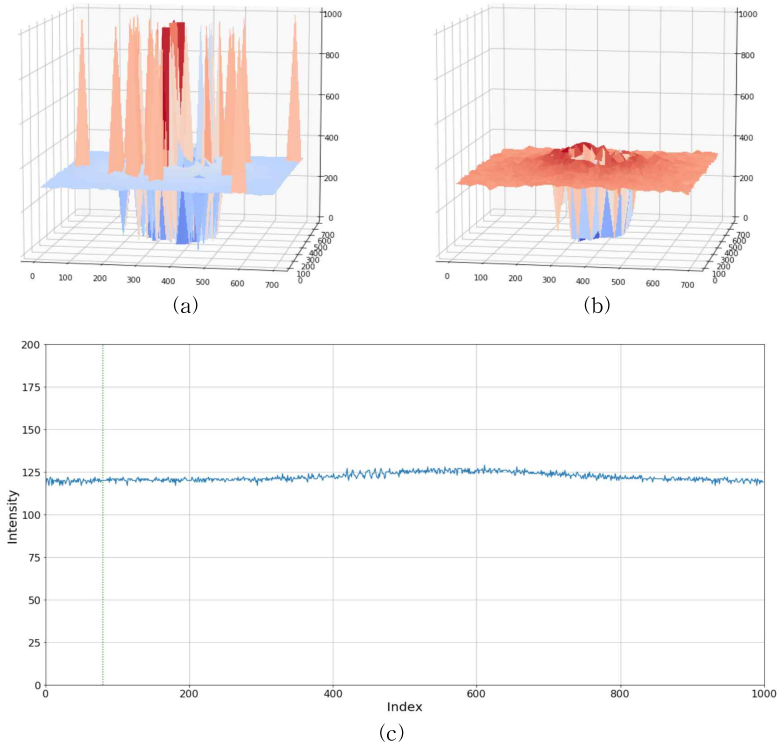


Fig. 14. S1 has a hole in the center (a) 3D profile of SEST (b) 3D profile of prediction (c) recorded intensity.

생성하였으며, 이러한 가상 데이터로 학습된 신경망이 실제 데이터를 측정하는데 사용할 수 있음을 확인하였다. 또한 제한한 신경망의 정확도를 판별하기 위해 새로운 정확도 함수를 2가지 정의하였으며, 이를 실제 데이터 검증에 사용하여 신경망의 정확도를 판별하는데 적합함을 확인하였다. SEST 알고리즘을 적용해 측정된 표면 형상과 제한한 신경망을 사용해 측정된 표면 형상을 비교하여 신경망을 사용해 표면 형상을 측정하는 것이 가능함을 확인하였다. 마지막으로 표면 형상에 차이가 있는 부분을 비교 분석하였으며, 이 결과 간섭 무늬 신호가 없거나, 간섭 무늬 신호가 신경망이 학습한 범위 밖인 경우 두 방법간에 차이가 많이 발생함을 확인하였다. 이 중 신호가 없는 경우와 같은 비정상적인 경우 SEST 알고리즘은 결과를 예측하기 어려운데 반해 신경망은 어느 정도 제한된 범위 내로 값을 출력해 별도의 후 처리 없이도 잡음에 더 강한 결과를 보여 준다.

본 연구를 통해 백색광 주사 간섭계의 신호를 예측하는데 BRNNs와 LSTM을 사용하는 것이 적절함을 확인하였고, 신호를 예측하는 데 가상 데이터를

사용한 방법이 가능함을 확인하였다. 향후 학습 데이터 생성 방법을 보완 한다면 더욱 향상된 결과를 얻을 것으로 기대된다.

REFERENCE

[1] P. Flournoy, R. McClure, and G. Wyntjes, "White-Light Interferometric Thickness Gauge," *Applied Optics*, Vol. 11, No. 9, pp. 1907-1915, 1972.

[2] Piezoelectricity, <https://en.wikipedia.org/wiki/Piezoelectricity> (accessed Jun., 27, 2018).

[3] P.d. Groot and L. Deck, "Three-dimensional Imaging by Sub-nyquist Sampling of White-light Interferograms," *Optics Letters*, Vol. 18, No. 17, pp. 1462-1464, 1993.

[4] A. Hirabayashi, H. Ogawa, and K. Kitagawa, "Fast Surface Profiler by White-light Interferometry by Use of a New Algorithm Based on Sampling Theory," *Applied Optics*, Vol.

41, No. 23, pp. 4876-4883, 2002.

[5] K.W. Ko, J.H. Sim, and M.Y. Kim, "A High-Speed White-Light Scanning Interferometer for Bump Inspection of Semiconductor Manufacture," *Journal of the Korean Society for Precision Engineering*, Vol. 30, No. 7, pp. 702-708, 2013.

[6] Wave Interference, https://en.wikipedia.org/wiki/Wave_interference (accessed Jul., 2, 2018).

[7] L. Mingzhou, *Development of Fringe Analysis Techniques in White Light Interferometry for Micro-Component Measurement*, Doctor's Thesis of National University of Singapore, 2008.

[8] Tensorflow, <https://www.tensorflow.org> (accessed Jun., 29, 2018).

[9] W. Hwang and S.C. Lim, "Inferring Interaction Force from Visual Information without Using Physical Force Sensors," *Sensors*, Vol. 17, No. 11, pp. 2455-2469, 2017.


[10] TensorFlow 1.3 Experiment with Long Short Term Memory (and Gated Recurrent Unit) Recurrent Neural Networks for Sine Prediction, [https://github.com/sunsided/tensorflow-lstm-sin](https://github.com/sunsided/tensorflow- lstm-sin) (accessed Jun., 29, 2018).

[11] V.P. Than, T.B. Nguyen, and S.T. Chung, "Accurate Human Localization for Automatic Labelling of Human from Fisheye Images," *Journal of Korea Multimedia Society*, Vol. 20, No. 5, pp. 769-781, 2017.

[12] M. Schuster and K.K. Paliwal, "Bidirectional Recurrent Neural Networks," *IEEE Transactions on Signal Processing*, Vol. 45, No. 11, pp. 2673-2681, 1997.

[13] Understanding LSTM Networks, <http://colah.github.io/posts/2015-08-Understanding-LSTMs> (accessed Jul., 3, 2018).

[14] R. Grosse, Lecture 15: Exploding and Vanishing Gradients, Computer Science, University of Toronto, 2017.



백 상 현

1990년 아주대학교 전자공학과
학사 졸업
1992년 아주대학교 전자공학과
석사 졸업
1999년 아주대학교 컴퓨터공학과
박사 수료



황 원 준

1999년 고려대학교 전자공학과
학사 졸업
2001년 고려대학교 전자공학과
석사 졸업
2016년 KAIST 전기 및 전자공
학부 박사 졸업

2001년 2월 ~ 2016년 8월 삼성종합기술원 전문연구원
2016년 9월 아주대학교 소프트웨어학부 조교수