Journal of Sensor Science and Technology
Vol. 28, No. 3 (2019) pp. 182-186
http://dx.doi.org/10.5369/JSST.2019.28.3.182
pISSN 1225-5475/eISSN 2093-7563

소수 데이터의 신경망 학습에 의한 카메라 보정

도용태+

Camera Calibration Using Neural Network with a Small Amount of Data

Yongtae Do+

Abstract

When a camera is employed for 3D sensing, accurate camera calibration is vital as it is a prerequisite for the subsequent steps of the sensing process. Camera calibration is usually performed by complex mathematical modeling and geometric analysis. On the other contrary, data learning using an artificial neural network can establish a transformation relation between the 3D space and the 2D camera image without explicit camera modeling. However, a neural network requires a large amount of accurate data for its learning. A significantly large amount of time and work using a precise system setup is needed to collect extensive data accurately in practice. In this study, we propose a two-step neural calibration method that is effective when only a small amount of learning data is available. In the first step, the camera projection transformation matrix is determined using the limited available data. In the second step, the transformation matrix is used for generating a large amount of synthetic data, and the neural network is trained using the generated data. Results of simulation study have shown that the proposed method as valid and effective.

Keywords: Camera calibration, Artificial neural network, Learning, Projection transformation matrix

1. 서 론

시각(vision)은 사람이나 기계에서 가장 중요한 감각기(sensor)이다. 특히 로봇이나 자율 주행 자동차 등 센서 기반의 지능 시스템에서 시각 센서의 역할을 매우 크다. 일반적으로 시각 센서는 카메라의 사용에 의하여 구현된다. 이때 카메라는 3차원 실세계를 2차원의 영상에 대응시키는 기능을 하게 된다. 그 대응 관계의 구체성은 카메라의 특성에 의하여 결정되는데, 보정(calibration)은 카메라의 기하학적 성질을 특징짓는 외부 파라메터(extrinsic parameters)와 광학적 성질을 특징짓는 내부 파라메터(intrinsic parameters)를 주어진 3차원 점들과 이에 대응하는 2차원 영상점들로부터 추정해 내는 작업이 된다 [1,2].

보정은 여타의 센서 계측에서와 마찬가지로 카메라를 활용한 측정 영역에서 오래 전부터 중요한 문제로 다루어져 왔으며, 다양한 기법들이 제안된 바 있다. 기존의 카메라 보정 기법들은 여러 가지 다른 기준에 의하여 분류될 수 있지만, 크게 외형적(explicit) 기법과 내형적(implicit) 기법으로 나눌 수 있다. 전자의 경우 카메라의 광학적, 기하학적 모형(model)을 정의하고, 그 모형을 최적으로 충족시키는 파라메터를 결정하는 수학적 절차를 거치게 된다. 이에 비해 후자는 특별한 모형화 과정 없이 3차원 공간좌표와 2차원 영상좌표 사이의 대응 관계를 규정하는 접근법이다. 외형적 기법은 많은 전통적인 카메라 보정기법들을 비롯하여 현재 널리 사용되는 Tsai의 2단계 기법[2]을 포함한다. 이에 비해, 인공신경회로망 (artificial neural network; ANN) 기반의 학습에 의한 보정은 내형적 기법에 속한다. 기존의 여러 가지 카메라 보정 기법들은 [3,4]를 참조할 수 있다.

최근 들어 인공지능 기술의 발전에 따라 ANN의 활용이 다양한 분야에서 크게 증대되고 있다. ANN은 생물학적 뉴론(neuron)의 연결에 의한 학습(learning)을 공학적으로 구현한 것으로, 여러 가지 모델과 학습법이 있다 [5]. ANN 사용의 가장 큰 장점은 수학적, 혹은 물리적 모형화 과정 없이 주어진 문제를 데이터에 기반한 학습에 의하여 풀 수 있다는데 있다. 따라서 카메라 보정의 문제에 국한해 보면, 어떠한 모형도 완벽하게 실제 카메라 시스템과 일치할 수 없으며 시스템 마다 다른 특성을 가지기 때문에, 특정한 모형을 가정하는 방법보다는 그 시스템의 데이터로부터 학습하는 방법이 더 유연할 수 있고, 특히 정확도도 더 높을 수 있다.

대구대학교 전자전기공학부(School of Electronic & Electrical Engineering, Daegu Unversity)
Gyeongsan-City, Gyeongsangbuk-Do, 38453, Korea
+Corresponding author: ytdo@daegu.ac.kr
(Received : Apr. 30, 2019, Revised : May. 24, 2019, Accepted : May. 28, 2019)

This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License(http://creativecommons.org/licenses/bync/3.0) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

ANN 기반의 학습에 의한 카메라 보정과 관련한 기존의 기법들을 살펴 보면, Woo와 Park[6]은 카메라의 투사 변환을 학습하기 위한 ANN을 구성하였다. 다만 사용한 데이터는 동일 평면(coplanar)으로 제한되었다. 비동일 평면 공간 점들에 대한 스테레오 카메라의 활용을 위한 ANN 적용은 Xiong 등의 연구[7]나 Memon과 Khan의 연구 [8]를 참조할 수 있다. 또한 Chen 등[9]은 GMDH(Group Method of Data Handling) 방법에 의한 네트워크 학습법을 활용한 바 있다. 한편, 카메라 보정에서 정확성을 떨어뜨리는 주요한 요소인 렌즈의 비선형 왜곡 문제를 신경망의 학습을 통하여 해결하고자 한 Chen의 연구[10]도 있다.

ANN을 이용한 학습에 있어 현실적인 문제점 중의 하나는 충분하고 정확한 데이터가 필요하다는 데 있다. 카메라의 보정을 위한 제어점(control point)을 획득하는 작업은 상당한 노력이 필요한 절차로써, 정교한 기계적 혹은 광학적 시스템이 필요하다. 예를 들어 이 문제를 로봇을 사용하여 자동화하기 위한 연구가 있었다 [11]. 특별한 모형 없이 데이터 기반으로 카메라의 기능을 학습하는 경우 데이터의 중요성은 더욱 증대되지만, 주어진 카메라로부터 다수의 데이터를 획득하는 일은 정교한 기계 기구뿐 아니라 많은 시간과 노력을 요구한다.

본 논문에서는 소수의 데이터만으로 ANN을 학습시킬 수 있는 2단계 방법을 제시한다. 우리는 [12]에서 이 방법의 개념을 간략히 제시한 바 있다. 즉, 첫 번째 단계로 카메라 투사 변환 행렬(camera projection transformation matrix)을 결정한다. 이 행렬은 최소한의 데이터만으로 결정될 수 있다. 그리고 두 번째 단계로 투사 변환 행렬을 다수의 가상적인 데이터를 생성하는 데 활용하고, 생성된 데이터는 ANN의 학습에 사용한다.

본 논문의 구성은 다음과 같다. 우선 2장에서 카메라 투사 변환 행렬을 설명하고, 3장에서는 본 논문에서 제안하는 ANN학습 방법을 서술하며, 4 장에서는 시험을 통하여 제안된 방법의 유용성을 입증하고, 5장에서 결론을 내린다.

2. 카메라 투사 변환 행렬

카메라 보정 모형의 기본이 되는 것은 바늘구멍 모형(pinhole model)이다. 바늘구멍 모형은 선형의 변환에 의하여 실현될 수 있다. 이는 단순하고 쉽다는 점에서 중요한 장점을 가지지만, 정확도에 있어서는 현실적으로 제약이 있다.

어떤 3차원 공간 상의 한 점 P는 카메라 영상면의 한 점에 대응되며, 이 때 두 점의 좌표는 각각 3차원 기준 좌표계 {W} 내의 (x, y, z)와 영상 좌표계 상의 (u, v)이다. Fig. 1은 공간 점과 영상 점과의 관계를 나타낸다 [2].

공간 점과 영상 점 사이의 변환은 식 (1)에 의하며, 이 때 f는 초점거리(focal length), (i_o, j_o)는 영상면의 광학적 중심이며, r과 t는 각각 $\{W\}$ 기준좌표계와 $\{C\}$ 카메라 좌표계 사이의 회전행렬과 변위벡터의 요소들이다. 여기서 k는 카메라의 내외부 파라

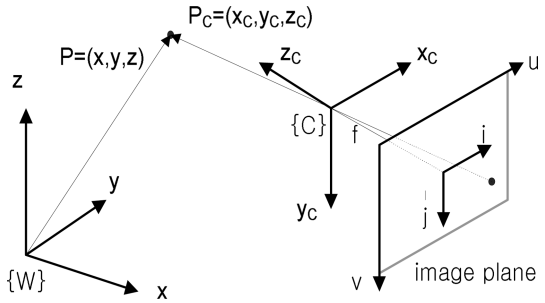

Fig. 1. Pinhole camera model.

메터를 포함하는 (3×4) 카메라 투사 변환 행렬 K의 요소이다. 한편 영상좌표 벡터 $[su, sv, s]$에서 s는 스케일 인자(scale factor)이다.

$$\begin{pmatrix} su \\ sv \\ s \end{pmatrix} = \begin{pmatrix} -f & 0 & i_o \\ 0 & -f & j_o \\ 0 & 0 & 1 \end{pmatrix} \begin{pmatrix} r_{11} & r_{12} & r_{13} & t_1 \\ r_{21} & r_{22} & r_{23} & t_2 \\ r_{31} & r_{32} & r_{33} & t_3 \end{pmatrix} \begin{pmatrix} x \\ y \\ z \\ 1 \end{pmatrix} = \begin{pmatrix} k_{11} & k_{12} & k_{13} & k_{14} \\ k_{21} & k_{22} & k_{23} & k_{24} \\ k_{31} & k_{32} & k_{33} & k_{34} \end{pmatrix} \begin{pmatrix} x \\ y \\ z \\ 1 \end{pmatrix} = KP \tag{1}$$

식 (1)에서, 만약 투사 변환 행렬 K가 규정되면, 어떤 3차원 공간 점 P로부터 이에 대응하는 2차원 영상 점의 좌표가 계산될 수 있음을 알 수 있다. K 행렬의 12개 요소들은 식 (1)을 식 (2)와 같이 전개한 후, 기지의 3차원 점들과 이들의 영상점들에 대하여 최소제곱오차법으로 구할 수 있다.

$$\begin{pmatrix} x & y & z & 1 & 0 & 0 & 0 & 0 & -xu & -yu & -zu & -u \\ 0 & 0 & 0 & 0 & x & y & z & 1 & -xv & -yv & -zv & -v \end{pmatrix} \begin{pmatrix} k_{11} \\ \vdots \\ k_{34} \end{pmatrix} = \begin{pmatrix} 0 \\ 0 \end{pmatrix} \tag{2}$$

3. 신경망 학습에 의한 보정 방법

카메라 투사 변환을 활용하는 2절의 방법은 간단하다는 장점이 있으나, 높은 정확도를 기대하기는 어렵다. 이는 카메라 렌즈의 비선형성이 높은 경우 더욱 심각한 문제가 된다. 이러한 문제에 대한 하나의 해법으로 ANN의 학습이 가능하며, Fig. 2는 이 문제에 대한 직관적인 ANN 구조가 된다. 즉, 3차원 실세계 점의 좌표를 입력으로 하고, 이에 대응하는 2차원 영상 점의 좌표를 출력으로 한다.

간단한 구조를 가지는 Fig. 2의 신경망을 사용할 때는 학습을 위해서 다수의 데이터가 필요한 또 다른 문제가 생긴다. 그리고 다수의 데이터를 정확하게 획득하기 위해서는 일반적으로 정교한 기계 및 광학적 장치가 필요하며, 이를 운용하는 상당한 노

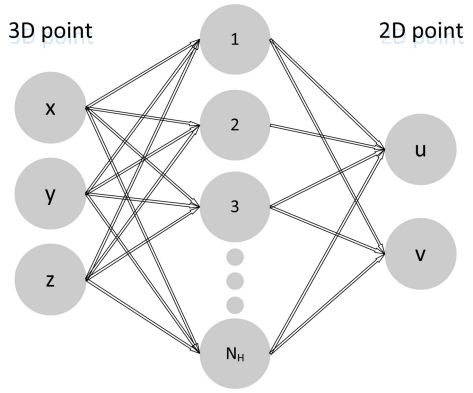

Fig. 2. ANN for learning the projection of a camera.

력과 시간도 요구된다. 기존의 연구에서 이 문제는 흔히 심각하게 다루어 지지 않고 있으나, 현실적으로는 카메라 보정의 절차를 어렵게 하는 중요한 문제들 중의 하나이다. 여기에 착안하여 본 논문에서는 제한된 수의 데이터로도 ANN을 효율적으로 학습하여 카메라를 보정할 수 있는 새로운 접근법을 제시한다.

본 논문에서 제시하는 방법은 크게 두 단계에 의한다. 먼저 첫 번째 단계로써, 주어진 소수의 데이터를 사용하여 식(2)로부터 카메라 투사 변환 행렬 K를 결정한다. 즉, 미지의 행렬 요소들 중 임의의 하나를 1로 두고, N개의 제어점들에 대해서 정리하면 식 (3)을 얻는다. 여기서는 $k_{34}=1$로 가정하였다.

$$\begin{pmatrix} x_1 & y_1 & z_1 & 1 & 0 & 0 & 0 & 0 & -x_1u_1 & -y_1u_1 & -z_1u_1 \\ 0 & 0 & 0 & 0 & x_1 & y_1 & z_1 & 1 & -x_1v_1 & -y_1v_1 & -z_1v_1 \\ & & & & & & \cdots & & & & \\ x_N & y_N & z_N & 1 & 0 & 0 & 0 & 0 & -x_Nu_N & -y_Nu_N & -z_Nu_N \\ 0 & 0 & 0 & 0 & x_N & y_N & z_N & 1 & -x_Nv_N & -y_Nv_N & -z_Nv_N \end{pmatrix} \begin{pmatrix} k_{11} \\ \vdots \\ k_{33} \end{pmatrix} = \begin{pmatrix} u_1 \\ v_1 \\ \cdots \\ u_N \\ v_N \end{pmatrix} \quad (3)$$

이 식에서 미지의 요소가 11개이므로, 이들 값을 결정하는데 필요한 최소의 데이터는 6개이다. 즉, $N \geq 6$가 해를 얻는 조건이므로, 적은 수의 데이터만으로도 행렬 K를 결정할 수 있다.

이제 두 번째 단계로써, 가상적인 3차원 점을 생성한다. 그리고 앞단계에서 결정된 카메라 투사 변환 행렬을 이용하여 가상적인 공간점들에 대응하는 영상점들을 식 (1)에서 계산한다. 이와 같은 방법으로 필요한 만큼 많은 수의 가상적인 데이터를 생성할 수 있다. 다만 이들 데이터는 선형적인 바늘구멍 카메라 모형에 기반하고 있으므로 정확도가 높지는 않다. 그러나 많은 데이터를 원하는 만큼 만들 수 있기 때문에 ANN을 학습하는데 유용하다. Fig. 3은 본 논문에서 제안하는 절차의 개념을 보여 준다.

ANN의 학습에는 여러 가지 다양한 알고리듬이 있다 [5]. 예를 들어 다층의 신경망 학습을 위한 오류역전파 알고리듬 (Error Back-Propagation: EBP)은 대표적인 학습법이다. 그러나 본 논문에서는 Luvenberg-Marquardt (LM) 학습 알고리듬을 사용한다. LM 알고리듬은 기존의 EBP 알고리듬에 비해 매우 빠른 학습 속도를 가진 것으로 알려져 있다 [13].

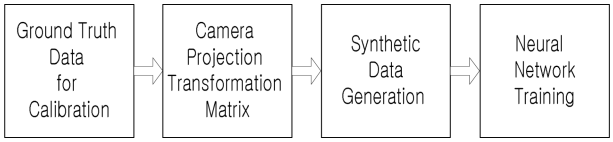

Fig. 3. Proposed neural camera calibration method.

4. 결 과

제안된 방법을 확인하기 위하여 Table 1과 같은 카메라를 가정하였다. 카메라의 영상 해상도는 512×512[pixel]로 가정하였다. Table 2는 영상에 추가된 비선형성과 잡음이다. 영상의 비선형성은 주로 렌즈의 방사 왜곡(radial distortion)에 기인하며 [2] 이는 파라메터 h에 의해 표현되지만, 경우에 따라서는 비방사 왜곡(non-radial distortion)도 무시할 수 없으며 이는 g_1, ..., g_4에 의하여 표현된다. 잡음의 경우에는 정규분포 N(0, pixel_size/12)을 고려하였다.

실험에서 ANN을 학습하기 위하여 사용한 데이터의 개수는 10개이다. Fig. 4는 사용된 학습 데이터의 분포와 영상점 마다의 오차를 보여 준다. 그림에서 원의 반경은 오차의 크기를 나타낸다. 오차가 작아 원을 그릴 수 없는 점들은 주로 영상면의 중앙 근처에 존재하며 오차는 Table 2의 렌즈 왜곡과 잡음에 기인한다.

10개의 데이터로 카메라 투사 변환 행렬을 결정하는 데는 문제가 없으나, ANN을 학습하기에는 매우 부족하다. 먼저 우리는 주어진 10개의 데이터를 사용하여 카메라 투사 변환 행렬을

Table 1. Camera parameters assumed for test.

Parameters	Values
f	25
(i_o, j_o)	(258, 204)
Pixel size	23 μm×23 μm
Rotation(x)	185°
Rotation(y)	-30°
Rotation(z)	15°
Position(x)	5 mm
Position(y)	200 mm
Position(z)	2005 mm

Table 2. Lens distortion and noise parameters.

Parameters	Values
h	0.005
g_1	0.002
g_2	-0.009
g_3	-0.002
g_4	0.009
Noise	$N(0,\ 0.023^2/12)$

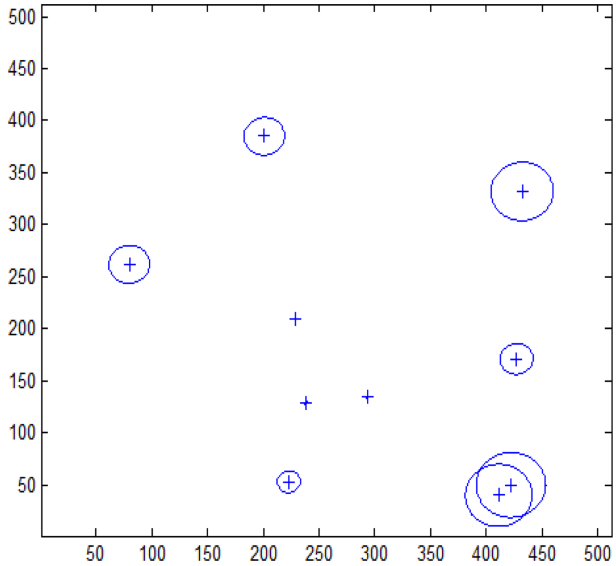

Fig. 4. Calibration points are marked by '+'. They are distorted mainly by the lens and the degree of distortion is represented by the circle size.

결정하였다. 행렬의 결정은 식 (3)으로부터 간단한 절차에 의하지만 높은 정확도를 기대하기는 어렵다.

이제 카메라 투사 변환 행렬을 이용하여 30개의 가상 데이터를 생성하였다. 그리고 그 가상 데이터는 ANN을 학습하는데 활용하였다. ANN의 은닉 뉴런 개수는 학습능력을 결정하는 주요한 요소이다. 우리는 은닉 뉴런의 개수를 다양하게 변화하면서 ANN의 성능을 점검하였으며, 그 결과는 Table 3과 같았다. 이 때 성능 평가의 척도는 투사 변환의 정확도로 식 (4)와 같이 정의하였다.

$$Error = \frac{1}{N}\sum_{n=1}^{N}\sqrt{(u_n - \hat{u}_n)^2 + (v_n - \hat{v}_n)^2} \tag{4}$$

단, N은 데이터의 개수, $(\hat{u}, \hat{v})$은 실제 영상점 (u, v)에 대한 ANN의 추정 좌표이다. 성능 시험을 위해 사용한 점들은 학습용 가상 데이터와는 별도로 총 30개의 실제 데이터이다. 또한 ANN의 초기치 설정이 성능에 영향을 주므로, 동일한 구조의 신경망에 대해서 초기치를 불규칙적으로 5번 다르게 사용하여 얻어진 결과들 중 최선을 선택하였다. 이 실험에서 최고의 성능은 은닉 뉴런의 개수를 5개로 하였을 때 얻어졌는데, 은닉 뉴런의 개수가 더 늘어나면 학습 정확도는 높아지지만 시험 정확도는 낮아졌다. 이는 주어진 데이터의 개수에 비해 망의 구조가 복잡하여 ANN이 주어진 데이터를 학습하기 보다 암기한 결과로 보인다. Luvenberg-Marquardt 알고리듬을 ANN의 학습에 사용하였으며, 학습 epoch의 숫자는 최고 500번으로 한정하였다.

이상의 결과를 카메라 투사 변환 행렬을 사용한 결과 및 단순히 주어진 소수의 데이터로 Fig. 2의 ANN을 학습한 결과와 비교하면 Table 4와 같다. 소수의 데이터만으로 Fig. 2의 ANN을 학습할 때, 초기치와 망의 구조를 달리 하면서 시험한 결과 은닉 뉴런의 개수가 4개일 때 최고의 결과를 얻었으나 그 결과는 비교된 다른 방법들의 결과보다 현저하게 좋지 않았다. 더 좋은 결과는 Eq.(1)에 의하여 카메라 투사 변환 행렬을 이용하였을 때였으나, 가장 좋은 결과는 제안된 바와 같이 다수의 데이터를 가상적으로 생성하고 활용하여 ANN을 학습하는 방법을 사용했을 때 얻어졌다. 제안된 방법으로 학습된 ANN의 학습 데이터에 대한 오차는 Fig. 5에서 원의 반경으로 나타낸 바와 같다.

동일한 실험을 학습 데이터의 개수가 20개일 때로 늘려서 되풀이하였을 때는 Table 5와 같은 결과를 얻었다. 투사 변환 행렬의 정확도가 높아졌으며, 주어진 소수의 데이터만으로 ANN을 학습했을 때의 정확도도 높아졌지만 여전히 선형의 투사 변환 행렬을 사용했을 때 보다 낮았다. 투사 변환 행렬을 이용하여 가상의 데이터를 30개 생성한 후 ANN을 학습하는 방법이 여기서도 가장 좋은 결과를 보였으나, 각 방법들의 정확도 격차는 상당히 좁혀 졌다.

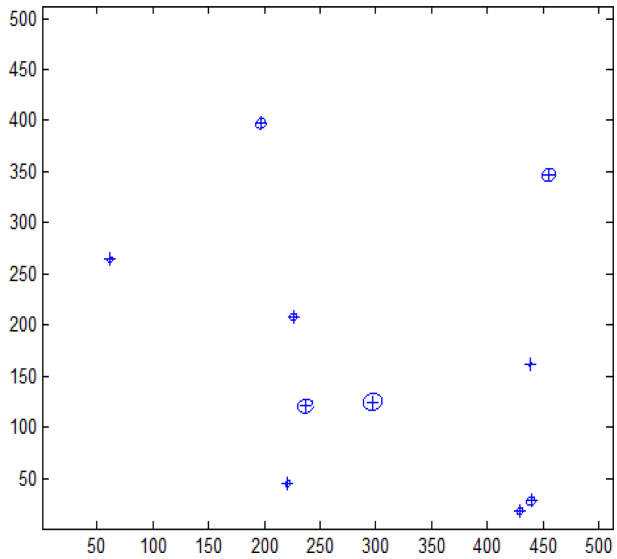

Fig. 5. Error circles by the proposed method for the calibration data.

Table 3. Performance(projection error in [mm]) for different number of hidden nodes

Number of Hidden Nodes	3	4	5	6	7
Training Error	0.109	0.090	0.059	0.033	0.015
Test Error	0.287	0.283	0.267	0.308	0.307

Table 4. Comparative test results [mm]

Methods	Error for Learning data	Error for Test Data
Eq.(1)	0.101	0.388
Fig. 2	0.039	1.039
Proposed	0.059	0.267

Table 5. Test results using more learning data: Twenty data are used here for calibration while ten data are used in the test of Table 4.

Methods	Error for Learning data	Error for Test Data
Eq.(1)	0.340	0.248
Fig. 2	0.037	0.305
Proposed	0.018	0.232

5. 결 론

본 논문에서는 ANN학습에 의하여 카메라를 보정하는 새로운 방법을 제시하였다. 기존의 바늘구멍 카메라 모형을 이용한 보정 기법은 6개 이상의 소수 데이터만으로 실행이 가능하지만 렌즈의 왜곡 등 시스템 비선형성에 의한 낮은 정확도의 문제가 있다. 이에 비해 ANN은 비선형 학습에 의하여 높은 정확도를 얻을 수 있으나 다수의 학습 데이터가 필요하다. 이러한 사실은 본 논문에서 제시한 방법의 토대가 되었다. 즉, 여러 가지 실제적 제약으로 인하여 소수의 데이터만으로 카메라를 보정하여야 하는 경우에 단순히 주어진 데이터를 학습하는 ANN은 쉽게 학습 성과를 달성하지만 시험용 데이터에 대한 일반화 성능(generalization performance)은 매우 낮다. 이는 ANN이 소수의 시험용 데이터를 암기한 결과로 보인다. 이에 비해 여기서 제안한 방법과 같이 다수의 가상 데이터를 카메라 투사 변환 행렬을 활용하여 생성한 후 이를 학습한 ANN은 비교적 좋은 정확도를 보였다. 다만 이러한 방법은 학습 데이터의 개수가 소수일 때 유효하며, 그 숫자가 증대되면 유용성이 낮아짐을 실험을 통하여 확인할 수 있었다. 즉, 제안하는 방법은 학습용 데이터의 숫자가 충분하지 않는 여러 현실적 상황에서의 카메라 보정에서 유용하게 활용될 수 있다.

감사의 글

이 논문은 2016학년도 대구대학교 학술연구비지원에 의한 논문임.

REFERENCES

[1] T. Jadhav, K. Singh, and A. Abhyankar, “Volumetric estimation using 3D reconstruction method for grading of fruits”, *Multimed. Tools Appl*. Vol. 78, No. 2, pp. 1613-1634, 2019.

[2] R. Tsai, “A versatile camera calibration technique for high-accuracy 3D machine vision metrology using off-the-shelf TV cameras and lenses”, *IEEE J. Robot. Autom.*, Vol. 3, No. 4, pp. 323-344, 1987.

[3] L. Song, W. Wu, J. Guo, and X. Li, “Survey on camera calibration technique”, *Proc. IEEE Int. Conf. Intell. Hum. Mach. Syst. Cybern.*, Hangzhou, China, 2013.

[4] Q. Wang, L. Fu, and Z. Liu, “Review on camera calibration”, *Proc. Chin. Control Decis. Conf*., pp. 3354-3358, Xuzhou, China, 2010.

[5] S. Walczak, “Artificial neural networks,” *in Advanced Methodologies and Technologies in Artificial Intelligence, Computer Simulation, and Human-Computer Interaction*, M. Khosrow-Pour, Ed., IGI Global, Hershey, pp. 40-53 2018.

[6] D.-M. Woo and D.-C. Park, “An efficient method for camera calibration using multilayer perceptron type neural network”, *Proc. Int. Conf. Future Comput. Commun.*, pp. 358-362, Kuala Lumpar, Malaysia, 2009.

[7] J. Xiong, J. Xia, X. Xu, and Z. Tian, “A novel method of stereo camera calibration using BP neural network”, *Appl. Mech. Mater*., Vol. 29-32, pp. 2692-2697, 2010.

[8] Q. Memon and S. Khan, “Camera calibration and three-dimensional world reconstruction of stereo-vision using neural networks”, *Int. J. Syst. Sci.*, Vol. 32, No. 9, pp. 1155-1159, 2001.

[9] B. Chen, W. Wang, and Q. Qin, “Stereo vision calibration based on GMDH neural network”, *Appl. Opt*., Vol. 51, No. 7, pp. 841-845, 2012.

[10] X. Chen, H. Fang, Y. Yang, and S. Qin, “The research of camera distortion correction based on neural network”, *Proc. Chin. Control Decis. Conf*., pp. 596-601, Mianyang, China , 2011.

[11] Y. Do, J. Neubert, N. Ferrier, and Y. Hu., “Camera calibration where practical uncertainties exist in camera model and calibration data”, *Proc. IEEE Conf. Mechatron. Mach. Vis. Pract.,* pp. 491-495, Hong Kong, 2001.

[12] Y. Do, “Neural camera calibration using a limited number of data”, *Proc. Korean Sens. Soc. Conf*. Vol. 29, p. 217, Seoul, Korea, 2018.

[13] M.T. Hagan and M. Menhaj, “Training feedforward networks with the Marquardt algorithm”, *IEEE Trans. Neural Netw.*, Vol. 5, No. 6, pp. 989-993, 1994.