Point Cloud 기반의 Neural Network를 이용한 그리퍼의 최적 파지점 추출 알고리즘 연구

Optimal Gripping Point Extraction Algorithm for Gripper Using Point Cloud Data Based Neural Network

정 동 교[®], 김 동 언[®], 이 승 현[®], 이 장 명*[®]

(Dongkyo Jeong¹, Dongeon Kim¹, Seunghyeon Lee¹, and Jang-Myung Lee^{1,*})

¹Department of Electrical and Computer Engineering Pusan National University

Abstract: In this paper, the optimal griping point learning is conducted through the neural network with the input of point cloud data. The SG-DNN (Stable Grasping-Deep Neural Network) algorithm, which was applied only to the shapes classified as the "original type", is extended to the real object and additionally composed of cost functions. Through this, a study was conducted to extract the optimal point for stable griping. Griping objects were simplified and limited to 10 types of shapes in the SG-DNN algorithm, and 4 cost functions were designed accordingly in order to extract the optimal griping point. However, when applying the method for an actual object, there was a limitation in deriving the optimal griping point. The content of the text uses a sample extracted from coordinate points through the point cloud data of a real object as the input of the neural network model. In comparison to the conventional method, a learning data set including dense surface area coordinates is constructed, leading to the extraction of a precise gripping point. The cost function was supplemented with cost functions for height, width, and rotation, and was designed to fit the actual object while including the cost function for the mass center according to the material and the gripper depth. The performance of the algorithm was verified by griping experiments involving real objects.

Keywords: point cloud, SG-DNN, neural network, cost function, griping method

I. 서론

로봇은 사람이 해야 할 일을 대체할 수 있고, 사람보다 효율적으로 반복적인 일을 처리할 수 있는 장점이 있기에 널리 사용되고 있다. 최근에는 다양한 분야에 로봇이 적용 되어 정교하고 복잡한 일을 수행할 수 있도록 로봇의 지능 화가 로봇 개발에 있어 중요한 요소로 대두되고 있다.

EOAT (End of Arm Tooling)는 사람의 팔을 본떠서 만든 로봇 매니퓰레이터의 끝단에 부착하는 장치로써 사람의 손 과 같은 그리퍼, 부속 센서 및 자동화 장치 등을 말한다. 최근 협동 로봇의 사용량이 증가함에 따라 다양한 환경에 서 이를 필요로 하게 되어, 그 사용 목적에 맞는 EOAT 장 비가 많이 개발되고 있다. 특히 그리퍼의 경우 Pick & Place 작업, Bin Picking 작업을 포함한 다수의 작업에서 파지를 수행하는 중요한 장치이다.

그리퍼를 사용하여 물체를 파지 및 이송하는 작업을 수 행할 때 물체가 흔들리거나, 떨어지지 않는 것을 안정적인 파지라고 한다. 안정적인 파지를 수행하기 위한 많은 방법 이 제시 및 논의되고 있고, 그 중에서 Dex-net, QT-Opt, Grasp-GAN 방법은 딥 러닝을 이용하여 파지 기법에 관한 연구를 진행하였다[1-5]. 또한, 파지 작업 시에 대 상체의 형상이 불확실한 경우에 파지를 진행하는 연구와 Neuroevolution 기 법을 적용한 파지 방법, 그리고 접촉력을 추정할 수 있도록 Tactile sensor를 개발하고 이를 통해서 파지하는 연구가 진 행되었다[6-8].

본 논문에서는 딥러닝을 이용하여 최적 파지점을 추출하는 방법에 대하여 연구한다[9,10]. 최적 파지점은 앞서 언급한 안정적인 파지와 마찬가지로 물체를 그리퍼로 들어 올 렸을 때 회전이나 놓침이 발생하지 않는 위치를 말한다. 물체 상에서 최적의 파지 점에 해당하는 좌표 값을 추출하도록 인공신경망을 구성하고, 인공신경망의 학습에 있어 Point Cloud Data를 사용한다. 본 연구의 알고리즘은 최적 파지점을 연구했던 SG-DNN (Stable Grasping-Deep Neural Network) 알고리즘의 가치 함수(Cost function) 요소에 실제 물체의 회전을 고려한 가치 함수를 보완 및 추가 구성하여 연구를 진행한다[11,12].

*Corresponding Author

Manuscript received June 24, 2020; revised August 11, 2020; accepted November 25, 2020 정동교: 부산대학교 전자공학과 대학원생(dongkyo1696@pusan.ac.kr, ORCiD[®] 0000-0002-1132-2772) 김동언: 부산대학교 전자공학과 대학원생(dongeon1696@pusan.ac.kr, ORCiD[®] 0000-0002-1674-1263) 이승현: 부산대학교 전자공학과 대학원생(seunghyeon1696@pusan.ac.kr, ORCiD[®] 0000-0002-8181-9637) 이장명: 부산대학교 전자공학과 교수(jmlee@pusan.ac.kr, ORCiD[®] 0000-0003-4290-8087) ※ 본 연구는 산업통상자원부의 산업핵심기술개발사업의 지원을 받아 수행된 연구결과임(No.10073147). 본문의 2장에서는 연구에 사용되었던 그리퍼 시스템에 관해 설명하고, 3장에서는 실제 물체에서 최적 파지점을 추 출하는 알고리즘에 관해 설명한다. 4장에서는 파지 대상 체 에 Neural Network 학습을 적용한 과정을 설명하고, 5장에 서는 실제 실험을 시행 후 알고리즘의 성능을 확인하며, 6 장에서는 결론으로 마무리를 한다.

Ⅱ. 그리퍼 시스템

1. 그리퍼 구성

본 논문에서는 2 Finger 형태의 그리퍼를 통해서 파지 작업을 실시한다. 로봇 매니퓰레이터의 끝단에 부착하는 그 리퍼는 최대 5 kg의 물체를 파지할 수 있고, 파지 가능한 최대 폭은 110 mm이며, 파지 가능한 깊이는 최대 90 mm 까지 사용이 가능하다. 물체를 파지하는 힘은 0.35N으로 제 한하여 파지 위치에 따른 안정성에 연구의 초점을 맞추어 진행하였고, 최적 파지 실험에 있어서 그리퍼 작업의 최대 범위 이내의 물체만을 대상으로 한다.

2. 그리퍼 파지 방향

그리퍼를 통한 파지 작업은 수직적인 파지나 수평적인 파지 방법의 하나를 사용한다.

그림 1(a)와 같은 수직적인 파지 방법은 원뿔, 반원 등 물체의 높이 중심점보다 질량 중심점이 Z축 상에서 아래에 형성되는 물체를 파지할 때 사용한다. 반면에 (b)와 같은 수평적인 파지 방법은 원기둥, 직육면체 등 물체의 높이 중 심점과 질량 중심점이 Z축 상에서 동일한 위치의 물체를 파지할 때 사용한다.

III. SG-DNN 2.0

1. SG-DNN 2.0 시스템

SG-DNN 2.0 (Stable Grasping-Deep Neural Network 2.0) 알 고리즘은 실제 물체의 최적 파지 점을 추출하는 것을 목적 으로 하는 알고리즘이다. 그에 대한 Block Diagram은 다음 그림 2와 같이 구성한다.

SG-DNN 2.0 알고리즘은 RGB-Depth 카메라로부터 물체 를 인식하는 것에서 시작된다. 이때, 영상처리를 통하여 물 체의 외곽선을 인식하고, 깊이 측정을 통하여 x, y, z축의 좌표를 추출하게 되며, 이로부터 Point Cloud Data를 생성하 게 된다. 또한 YOLO(You Only Look Once) v2라는 CNN 알 고리즘을 통하여 물체의 종류에 대한 클래스 값을 출력한 다. 이때 YOLO v2로 출력된 클래스 값과 비전 센서의 영



그림 1. (a) 수직적인 파지, (b) 수평적인 파지. Fig. 1. (a) Vertical Grip, (b) Horizontal Grip.



그림 2. SG-DNN 2.0 알고리즘. Fig. 2. SG-DNN 2.0 Algorithm.

상처리를 통해 인식되는 정보가 동일한 물체에 대한 Point Cloud의 sampling data 값을 SG-DNN 2.0에 입력으로 전달 한다.

즉, Point Cloud Data의 좌표 값이 Neural Network에 입력 되며 설정된 가치 함수에 따라 최적 파지점이 출력된다. 물 체와 그리퍼 특성을 고려한 가치 함수를 구성하였고, 실제 물체에 대한 학습 시 적용이 용이하도록 구성을 하여 Neural Network 학습을 진행한다. 학습으로 추출된 최적 파지점은 좌표로 출력되고, 이를 실제 물체에 적용하여 그리퍼를 통 한 파지를 수행한다[17,18].

2. Point Cloud Data for SG-DNN 2.0

Point Cloud Data는 3차원 좌표계 상에서의 데이터 집합 으로, 실제 물체의 표면에서 측정된 좌표 점의 그룹으로 사 용된다. 주로 실제 물체의 3차원 정보를 가상환경에서 활용 할 수 있는 기술로 활용되고, Depth Sensor, 3D Reconstruction 방법들을 이용하여 생성할 수 있다[13-15].

본 연구에서는 Point Cloud Data를 입력으로 하여 최적의 파지 점을 추출하도록 학습한다. 파지하고자 하는 물체를 3 차원의 Point Cloud Data로 Data Set을 구축한다.

Point Cloud Data 생성은 Rendering 과정을 통해서 물체 의 폭, 깊이, 높이를 고려하여 실제 물체와 동일한 표면적 을 갖도록 다음의 작업을 진행한다. 먼저, 3DS MAX tool을 사용하여 model의 rendering을 생성 후 MATLAB에서 물체 의 축과 원점을 맞춰주는 과정을 통하여 Point Cloud Data 를 생성을 하였다. 이 방법은 앞서 언급한 Depth Sensor,



그림 3. 물병의 Point Cloud Data. Fig. 3. Point Cloud Data of Bottle.

3D Reconstruction 방법들의 결과물에 비해서 배경, 주변 물 체의 반영 등 불필요한 정보가 없고 제작이 용이하다는 장 점이 있다.

그림 3은 물병의 외형에 기반한 Point Cloud Data를 구성 한 것이다. Point Cloud Data를 Neural Network 학습의 입력 으로 사용하기 위해 Sampling을 실시한다. Sampling은 물체 형태를 동일하게 구성하고, 표면을 이루는 각 좌표는 다른 점들의 조합으로 구성하여 물체별로 10,000~14,000개의 data 로 실시하였다. 이때 더 낮은 data의 수로 sampling 한다면 물체의 입체적 형상을 반영하지 못할 수 있기에, 표면의 좌 표에 따라 안정성이 중요한 본 연구에서는 충분한 개수의 data로 sampling을 실시한다. 이를 통해서 다양한 학습용 데 이터를 획득하는 방법으로 sampling이 사용되었다. 이렇게 Sampling 된 Point Cloud Data를 Neural Network의 입력으로 하여 학습을 진행한다.

3. Neural Network for SG-DNN 2.0

Neural Network는 Input layer, Hidden layer, Output layer 로 구성되어 내부 파라미터 학습을 통해서 입력 값을 처 리하여 원하는 데이터로 출력한다. Neural Network 학습 과정은 Gradient Descent 방식을 통해서 loss가 낮아지는 방 향으로 파라미터를 업데이트하는데, 이때 loss는 설정한 가치 함수에 의해 계산된다. 따라서 가치 함수 구성은 학 습시키고자 하는 특징을 가치 함수 요소로 반영해서 구성 해야 한다.

Neural Network 학습은 Sampling 된 Point Cloud Data 수 (n)와 x, y, z 좌표 3개를 곱한 값을 입력으로 하고 256 크 기의 Hidden layer 4개를 학습을 거쳐 최적의 파지점에 해 당하는 값을 출력한다.

4. SG-DNN 2.0의 가치 함수

가치 함수는 출력 값과 실제 물체의 기준 값을 비교하여 loss를 출력하는 함수이다. 그림 4에서 가치 함수는 Neural Network 학습 과정을 통해 예상으로 출력된 $\mathcal{U}(\widehat{P}_i)$ 과 물체 가 가지고 있는 기준이 되는 좌표 값(P_i) 간의 loss가 적은 값을 MSE방법을 통하여 찾도록 한다.

$$C_{total}(\vec{P}_i) - C_{total}(\vec{P}_i) = loss \tag{1}$$

식 (1)은 Neural Network를 거쳐 출력된 최적 파지 점으 로 예측한 값과 물체가 가지고 있는 기준 좌표 간의 차이 를 가치 함수를 사용하여 나타낸다. 여기서 C_{total}은 가치 함수의 총합을 의미하며 다음과 같이 구해진다.

$$C_{total} = C_h + C_w + C_r + C_t + C_d \tag{2}$$

식 (2)는 가치 함수의 총합(C_{total})으로 가치 함수 요소들 의 함을 의미하고, 이는 SG-DNN에서 제시했던 기하적인 특징과 실제 물체 파지 시 회전을 고려한 가치 함수 요소 를 추가 구성하였다. 가치 함수 요소는 높이 (C_h) , 폭 (C_w) , 회전 (C_r) , 재질의 질량중심 (C_t) , 그리퍼 깊이에 관한 가치 함수(C₄)인 5가지로 구성된다[11,12].

가치 함수는 확률밀도함수의 형태를 사용한다. 각각의 가치 함수 요소는 개별 물체의 특성에 맞는 기하적인 라벨 값, 즉 x, y, z축에 해당하는 가로, 세로, 높이 값을 갖는다. 이러한 가치 함수의 특성을 고려하여, 개별 가치 함수가 갖 는 요소의 최적 값을 평균으로 하는 확률밀도 함수를 사용 하여 라벨을 도출하였다. 라벨은 최적 파지점의 기준으로 사용되며 좌표쌍으로 구성된다. 이렇게 생성된 라벨은 MSE 방법으로 train에 의해 생성된 값과의 loss가 최소일 때를 기준으로 최적의 파지점을 도출한다. 가치 함수에서 최적의 평균값을 기준으로 양쪽으로 cost가 상승되는 형태로 표현 하여, 모든 좌표 값에 대해 cost를 가지게끔 하도록 구성하 였다. 따라서 가치 함수 총합은 가장 낮은 cost값일수록 최 적의 평균값에 유사하도록 한다.

아래는 세부적인 개별 가치 함수들의 설정에 관한 내용 이다.



Fig. 4. System of Neural Network.

$$C_{x}(x) = -\frac{1}{\sqrt{2\pi}\sigma_{x}}e^{-\frac{(x-m)^{2}}{2\sigma_{x}^{2}}}$$
(3)

$$\sigma_x = \sqrt{\frac{1}{n} \sum_{i=1}^{n} (x_i - m)^2}$$
(4)

식 (3)은 가치 함수로써 x는 각 가치 함수 요소의 입력 변수, m은 물체에 따른 가치 함수 요소의 최적 값을 의미 한다. 식 (4)은 가치 함수의 표준 편차 값으로써 가치 함수 요소의 입력 값과 최적 값에 따라 사용한다.

가치 함수에 사용되는 물체의 좌표 좌, 우측 파지 점은 다음과 같이 표현한다.

$$P_{L} = [P_{L,x}, P_{L,y}, P_{L,z}]$$
(5-a)

$$P_{R} = [P_{R,x}, P_{R,y}, P_{R,z}]$$
(5-b)

4.1. 높이에 관한 가치 함수

높이에 관한 가치 함수는 물체에 생성되는 두 좌표의 높 이 값이 비슷하게 입력 값으로 형성되어야 한다. 또한 물체 에 따라 안정적인 파지에 적합한 최적 값은 다르게 위치한다.

그림 5와 같이 com 타입을 포함한 파지접점에 기울기가 존재하는 경우에 있어서 수직 방향에서 물체를 파지할 때 높이의 중심점(P_g)을 파지할 경우, 물체를 놓치게 된다. 따 라서 물체 파지 시 무게 중심점보다 아래 위치에 파지를 해야 한다. 이때 그리퍼의 기하학적 특성을 고려하여 지면 과 충돌하지 않는 점을 고려하여, 물체의 질량 중심점(P_m) 아래 5 mm에 위치한 점(P_b)에서 최적 값을 갖는다고 설정 한다.

$$h = \frac{P_{L,z} + P_{R,z}}{2} \tag{6}$$

$$m = P_b \tag{7}$$

$$C_{h}(h) = -\frac{1}{\sqrt{2\pi}\sigma_{h}}e^{-\frac{(h-m)^{2}}{2\sigma_{h}^{2}}}$$
(8)



그림 5. 수직 방향 물체 파지(높이). Fig. 5. Grip of Vertical objects (Height).



그림 6. 수평 방향 물체 파지(높이). Fig. 6. Grip of Horizontal objects (Height).

여기서 식 (6)은 높이에 대한 입력 값이고, 식 (7)은 물체의 높이 최적 값을 설명할 때, 이를 식 (8)에 대입하여 높이에 관한 가치 함수를 구한다. 수평 방향에서의 물체를 파지하 는 경우에서는 다음과 같다.

그림 6과 같이 수평 방향에서 파지하는 물체는 높이 중 심점과 질량 중심점이 동일한 위치에 형성된다. 따라서 회 전을 방지하는 것을 고려하여 질량 중심점을 최적 값으로 설정하여 파지한다. 수평 방향의 파지에 대한 입력 값, 최 적 값, 가치 함수는 식 (6)~(8)과 동일하게 사용한다. 4.2. 폭에 관한 가치 함수

그리퍼의 폭과 물체의 최대 폭을 고려한 계산을 통해 가 치 함수를 구한다. 본 연구에서 사용하는 그리퍼의 폭 범위 는 0~110mm까지 사용이 가능하지만, 최적으로 파지 기능 을 할 수 있는 범위는 10~80 mm이다. 따라서 80 mm 이 내의 폭을 가진 물체를 파지하도록 한다. 여기서 최적 값 m 의 경우 물체 별 질량 중심점 위치의 폭을 최적 값으로 설 정한다.

$$w = \sqrt{(P_{L,x} - P_{R,x})^2 + (P_{L,y} - P_{R,y})^2 + (P_{L,z} - P_{R,z})^2} \quad (9)$$

$$C_w(w) = -\frac{1}{\sqrt{2\pi}\sigma_w} e^{-\frac{(w-m)^2}{2\sigma_w^2}} \quad (10)$$

식 (9)의 폭에 대한 입력 값과 물체 별 질량 중심점의 폭을 식 (10)에 대입하여 폭에 관한 가치 함수를 구한다. 4.3. 회전에 관한 가치 함수

물체에 생성되는 두 좌표 점의 X축 좌표 $P_{L,x}$, $P_{R,x}$ 가 차이가 난 상태로 그리퍼 파지를 할 경우 물체는 수평적인 회전이 발생한다. 마찬가지로 Z축 좌표 $P_{L,z}$, $P_{R,z}$ 가 차이 가 난 상태로 파지를 할 경우 물체는 수직적인 회전이 발 생한다. 이에 대하여 회전이 발생하지 않도록 각 축의 좌표 점 차이를 최소화해야 하고, 가치 함수는 회전하지 않는 위 치에 근사할 수 있도록 설정한다.

$$r = |P_{L,x} - P_{R,x}| + |P_{L,z} - P_{R,z}|$$
(11)

$$C_{r}(r) = -\frac{1}{\sqrt{2\pi}\sigma_{r}}e^{-\frac{(r-m)^{2}}{2\sigma_{r}^{2}}}$$
(12)

식 (11)의 입력 값은 폭과 높이의 차이 값을 고려하여 설정하고, 최적 값 m은 좌표 값의 차이가 0일 때 회전이 발생하지 않기에 0을 설정한다. 이를 식 (12)에 대입하여 회전에 관한 가치 함수를 구한다.

4.4. 재질에 따른 질량 중심의 가치 함수

물체를 구성하는 재질이 두 가지 이상으로 구성된 경우, 최적 파지점을 구함에 있어서 그리퍼로 파지할 때 Y축 기 준 회전을 고려한다. 물체의 외형을 기반으로 X축 상 중심 점을 파지할 경우, 물체는 재질이 같지 않고 무게가 다르기 에 무거운 쪽으로 회전이 발생한다.

이를 물체에 모멘트가 발생하였다고 한다. 따라서 안정 적인 파지를 함에서는 모멘트 합이 0이 되는 구간을 파지 해야 회전이 발생하지 않는다. 본 연구는 다음과 같이 물체 를 나눠서 모멘트가 0이 되는 위치의 가치 함수를 찾도록 계산한다.

그림 7에서 물체는 좌, 우측으로 나눠서 계산한다. 이때 사용된 용어는 다음과 같다.

L₁, L₂는 좌, 우측 물체의 길이

P_{m1}, P_{m2}는 좌, 우측 물체의 질량 중심점

 m_1g, m_2g 는 좌, 우측 물체에 작용하는 중력

c는 동일한 축 선상의 임의의 점

질량 중심점 P_{m1}, P_{m2} 사이에 c가 위치한 경우를 계산해 보면 m_1g 로 형성된 모멘트와 m_2g 로 형성된 모멘트가 서 로 반대 방향으로 작용한다. 식 (13) 이외의 범위로 입력 값이 형성될 경우 모멘트 계산에서 한쪽으로만 모멘트가 작용한다. 따라서 본 연구에서는 0이 되는 구간만 고려하여 범위는 다음과 같다.

$$\frac{1}{x_1} < \frac{P_{L,x} + P_{R,x}}{2} < L_1 + \overline{x_2}$$
(13)

식 (13)은 모멘트가 발생하지 않는 임의의 점 주변에서 가치 함수 계산을 할 수 있도록 입력 값 범위를 지정했다. 이때 모멘트 계산을 하면 다음과 같다.

$$T = rF \tag{14}$$

식 (14)의 경우 모멘트는 힘과 거리에 비례하는 식이고, 이를 그림 7의 설명에 맞춰주면 다음과 같다.



그림 7. 재질이 다른 물체에 대한 예시.

Fig. 7. Example of objects with different materials.

$$\sum T = -m_1 g l_1 + m_2 g l_2 \tag{15}$$

$$t = -m_1 g((\frac{P_{L,x} + P_{R,x}}{2}) - \overline{x_1}) + m_2 g(L_1 + \overline{x_2} - (\frac{P_{L,x} + P_{R,x}}{2}))$$
(16)

$$C_{t}(t) = -\frac{1}{\sqrt{2\pi}\sigma_{t}}e^{-\frac{(t-m)^{2}}{2\sigma_{t}^{2}}}$$
(17)

식 (15)은 물체 전체의 모멘트를 계산한 식이다. 식 (16)은 모멘트 합이 0인 부분에 근사한 값을 입력 값으로 구성하였 고, 식 (17)에 입력 값과 최적 값을 넣어 재질에 따른 질량 중 심의 가치 함수를 구성하였다. 최적 값 m은 회전이 발생하지 않는 모멘트 합이 0인 점을 고려하여 0으로 설정한다.

4.5. 깊이의 함수

그리퍼의 깊이가 물체의 질량 중심점까지 거리에 비해 짧아서 도달하지 못할 경우가 존재할 수 있다. 이때 그리퍼 의 파지 가능 범위를 고려하여 좌표 점이 생성될 수 있도 록 범위를 지정하고, 파지 가능 범위를 벗어난 위치에서 좌 표 점이 생성될 경우 가치 함수의 cost 값을 높게 부여하여 최적의 좌표 값에 부합하지 않다고 설정한다.

그림 8은 수평 방향으로 그리퍼 파지를 실시할 때의 경 우로서 가치 함수를 구하면 다음과 같다.

$$d = \frac{P_{L,x} + P_{R,x}}{2}$$
(18)

$$m = P_m \tag{19}$$

$$C_d(d) = -\frac{1}{\sqrt{2\pi}\sigma_d} e^{-\frac{(d-m)^2}{2\sigma_d^2}}$$
(20)

식 (18)의 입력 값은 질량 중심점을 벗어나지 않는 범위 에서 입력 값이 생성되는 경우를 말한다. 식 (19)의 최적 값 m은 질량 중심점 위치에서 최적 값이 형성된다고 설정 하고, 이를 식 (20)에 대입하여 그리퍼 깊이에 관한 가치 함수를 구한다.



그림 8. 수평 방향물체 파지(깊이).

Fig. 8. Grip of Horizontal objects (Depth).



그림 9. 수직 방향 물체 파지(깊이). Fig. 9. Grip of Vertical objects (Depth).

만일 입력 값의 x 좌표 값이 $d > P_m$ 범위에 생성되어 그 리퍼 파지 범위를 벗어날 경우*d* 값은 2*d*로 설정하여 높은 cost가 나오도록 가치 함수를 계산한다.

그림 9와 같이 수직 방향을 고려할 경우 입력 값은 Z축 좌표가 되고 다음과 같이 가치 함수를 구한다.

$$d = \frac{P_{L,z} + P_{R,z}}{2}$$
(21)

식 (21)의 입력 값은 질량 중심점을 벗어나지 않는 범위 에서 입력 값을 설명하고, 최적 값과 가치 함수는 식 (19) ~ (20)과 동일하게 사용한다.

만일 입력 값의 z 좌표 값이 $d < P_m$ 범위에 생성되어 그 리퍼 파지 범위를 벗어날 경우 d값은 2d로 설정하여 높은 cost가 나오도록 가치 함수를 계산한다.

IV. SG-DNN 2.0 Neural Network 적용

파지 대상 체는 물병, 드라이버, 원뿔, 원기둥 4가지 물 체를 선정하였다. 원뿔과 원기둥은 도형의 최적 파지점을 추출하기 위해 선정함으로써 SG-DNN과 성능을 비교하기 위해 사용하였다. 물병과 드라이버는 도형으로 쉽게 도식화 가능하여 선정하였다.

표 1의 파지 대상 체를 Point Cloud Data 변환 후 물체당 10.000개~14.000개의 Sampling을 실행하여 Neural Network 학습 과정에 입력 값으로 사용하였다. 2,000번 학습을 시킨 후 Test Set으로 출력된 값 중 물체 별 loss가 가장 낮은 10 개의 좌표 값을 표 2~표 5에 나타냈다. 추출된 파지 점의 경우에 loss가 적은 좌표 점일수록 안정적인 파지 점에 가 까운 최적점이 도출되었다. 이는 물체별로 갖는 질량중심점 에 가까운 z축의 좌표와 왼쪽과 오른쪽 파지 점에서 x축과 z축의 동일한 정도로 인한 회전의 발생, 그리고 이형 이상 의 재질로 구성된 물체의 경우 재질의 차이에 의한 무게중 심점을 고려한 중심점에 따라서 안정성이 차이 나고, 불안 정한 점일수록 loss가 크게 도출되었다.

학습에 있어서 Optimizer는 Adam을 사용하고 Framework 는 Tensor flow를 사용하여 구현하여 학습을 진행하였다.

V. 실험

丑	1.	파지 대상 체.
Table	1.	Grip Objects.

	Shape	Point Cloud Data	Size(mm)	
원뿔			폭 : 70 높이 : 80 깊이 : 70	
원기둥			폭 : 65 높이 : 140 깊이 : 65	
드라 이버		B B B B B B B B B B B B B B B B B B B	폭 : 215 높이 : 40 깊이 : 40	
물병	The second s		폭 : 70 높이 : 200 깊이 : 70	



그림 10. 드라이버의 최적 파지점 표시. Fig. 10. Display optimal gripping point of screwdriver.

RTX 2080, RAM 16GB 사양의 PC와 Intel realsense D145 의 RGB-Depth 카메라를 사용하였다. Software의 경우 Matlab과 3D Max 프로그램을 활용하였고, 그리퍼의 경우 ROBOTIS 사의 RH-P12-RN의 그리퍼를 사용하였다. 실험은 4장에서 Neural Network for SG-DNN 2.0의 Test Set 2.000번 학습으로 나온 loss 값 중 무작위한 100개의 좌표 쌍을 사용



- 그림 11. 드라이버 파지 실험.
- Fig. 11. Screwdriver gripping experiment.



그림 12. 물병의 최적 파지점 표시.

Fig. 12. Display optimal gripping point of bottle.



그림 13. 물병 파지 실험. Fig. 13. Bottle gripping experiment.

하여 파지 성공률을 확인한다. 좌표 쌍을 Matlab 환경에서 Point Cloud Data에 표시를 시킨 뒤 실제 물체로 적용하도 록 한다. 물체를 파지했을 때, 흔들림이나 놓침 없이 파지 한 높이로부터 수직으로 200 mm만큼 들어 올린 후 10초간 상태를 유지하고 목적지로 이동 시 낙하가 발생하지 않으 면 성공으로 한다. 물체의 최적 파지 점 간의 정확도를 비 교하기 위해 SG-DNN과 동일한 그리퍼 환경에서 성공률을 비교한다.

파지 성공률이 질량 중심점을 기준으로 파지한 PSO 알 고리즘[16]보다 성공률이 낮은 경우, 개별 가치 함수들을 조정하여 안정적인 파지점들을 갱신하였다. 갱신된 파지점 들을 통해서 반복적인 실험을 진행하였고, 이를 통해 최적 의 파지점들을 도출한 결과는 다음의 표 2~5와 같다.

표 2. 원기둥의 loss 별 최저 10개 좌표.

Table 2. At least 10 coordinates loss of cylinder.

$P_{L,x}$	$P_{L,y}$	$P_{L,z}$	$P_{R,x}$	$P_{R,y}$	$P_{R,z}$	loss
33.970	-30.888	100.542	33.936	29.734	101.014	3.695
36.143	-28.424	100.562	34.951	31.354	100.182	3.896
34.549	-30.66	102.401	36.073	29.622	99.621	3.998
31.361	-30.788	101.384	34.071	30.036	100.088	4.844
36.164	-32.583	38.617	36.184	30.116	99.389	4.942
36.698	-29.258	102.309	33.850	30.721	99.623	4.945
32.343	-26.266	102.131	34.974	30.473	100.505	5.333
37.154	-32.161	100.467	35.767	31.209	100.643	5.559
34.857	-32.939	100.235	35.247	29.098	98.676	5.577
36.233	-34.397	100.652	34.153	30.208	99.887	5.618

표 3. 원뿔의 loss 별 최저 10개 좌표.

Table 3. At least 10 coordinates loss of cone.

$P_{L,x}$	$P_{L,y}$	$P_{L,z}$	$P_{R,x}$	$P_{R,y}$	$P_{R,z}$	loss
37.197	-31.696	20.548	35.477	25.119	19.245	3.642
32.322	-29.975	20.684	35.523	25.364	19.043	4.084
36.656	-32.209	21.981	34.174	24.931	20.280	4.163
34.534	-32.449	22.422	35.415	25.679	20.409	4.279
34.797	-29.323	19.027	33.427	24.566	20.689	4.337
32.211	-31.951	17.947	35.533	24.770	20.485	4.549
32.719	-26.843	19.618	35.154	24.311	19.492	4.668
36.681	-31.406	20.152	35.062	25.686	18.502	4.914
32.466	-27.435	17.374	34.277	24.723	19.608	5.210
36.612	-31.699	21.176	36.069	24.776	18.795	5.265

표 4. 드라이버의 loss 별 최저 10개 좌표.

Table 4. At least 10 coordinates loss of screwdriver.

$P_{L,x}$	$P_{L,y}$	$P_{L,z}$	$P_{R,x}$	$P_{R,y}$	$P_{R,z}$	loss
136.707	3.666	49.588	137.477	-4.289	48.574	3.245
138.506	1.315	51.301	137.377	-3.263	49.906	3.294
136.704	1.566	48.228	137.620	-3.059	49.417	3.740
135.316	4.360	52.619	137.048	-3.243	50.808	3.990
135.723	0.752	47.471	137.426	-3.999	50.169	4.386
137.21	2.351	50.835	136.680	-2.225	48.955	4.598
135.079	0.602	48.491	137.511	-4.281	49.724	4.667
136.577	-0.263	50.406	137.304	-3.871	49.218	4.684
135.751	4.204	50.354	137.542	-4.597	51.480	4.913
138.005	2.197	54.439	137.210	-3.396	50.363	4.980

표 5. 물병의 loss 별 최저 10개 좌표.

Table 5	5 At	least 10	coordinates	loss	of bottle
I GOIC S	·. 111	rease re	coordination	1000	or oour

$P_{L,x}$	$P_{L,y}$	$P_{L,z}$	$P_{R,x}$	$P_{R,y}$	$P_{R,z}$	loss
33.970	-30.888	100.542	33.936	29.734	101.014	3.695
36.143	-28.424	100.562	34.951	31.354	100.182	3.896
34.549	-30.66	102.401	36.073	29.622	99.621	3.998
31.361	-30.788	101.384	34.071	30.036	100.088	4.844
36.164	-32.583	38.617	36.184	30.116	99.389	4.942
36.698	-29.258	102.309	33.850	30.721	99.623	4.945
32.343	-26.266	102.131	34.974	30.473	100.505	5.333
37.154	-32.161	100.467	35.767	31.209	100.643	5.559
34.857	-32.939	100.235	35.247	29.098	98.676	5.577
36.233	-34.397	100.652	34.153	30.208	99.887	5.618

표 6. 파지 성공률 비교.

Table 6. Comparison of Griping Success Rate.

Algorithm	PSO	SG-DNN	SG-DNN 2.0
원뿔	75 %	75 %	77 %
원기둥	85 %	86 %	87 %
드라이버	55 %	55 %	78 %
물병	83 %	84%	85 %

표 6 파지 실험 결과에 따르면 SG-DNN 2.0 알고리즘을 사용한 방법은 SG-DNN 알고리즘과 PSO 알고리즘보다 실 제 물체의 파지 안정성에 대한 성공률이 높은 것을 확인할 수 있었다. 이는 PSO 알고리즘의 경우, 전역 최적 위치 파 티클로 설정된 질량 중심의 값으로 최적 파지점이 형성되 며, 이에 따라서 다른 변수들을 고려하지 못한 값이 도출되 었다[16]. SG-DNN의 경우 좌표 쌍을 맞춰준 상태에서 입력 을 넣었지만, 회전에 대하여 Z축 좌표만을 고려하였다. 그 로 인해 X축 좌표의 차이를 보정 받지 못하여 드라이버의 파지 시에 특히 회전이 발생하는 경우가 많았고 이에 따라 성공률이 낮았다. 그에 반해 SG-DNN 2.0의 경우 가치 함수 구성 자체에서 실제 물체의 X축과 Z축 모두에서 회전이 발생하는 것을 고려하였기에 성공률이 높았다고 판단된다. 또한 같은 형태를 보이지만 무게가 다른 원기둥과 물병을 파지하는 경우에 무거운 원기동이 파지 점에 따른 안정성 에 영향을 더 받는 것을 확인할 수 있다.

그림 14~그림 17은 SG-DNN 2.0 알고리즘을 파지 실험 에서 사용된 loss 범위에 따른 성공률을 나타낸 것이다. 그 래프를 확인한 결과 SG-DNN 2.0 알고리즘을 통해 추출된 loss는 성공률과 비례하는 것을 확인할 수 있었다. 파지 대 상 체 4가지 모두 loss 범위가 낮은 경우 성공률이 높았고, loss 범위가 높은 경우 성공률이 낮았다. 그러나 2.000개의 좌표 중 100개의 좌표를 Sampling 하여 파지 실험을 하였고, 적은 표본 수로 loss 범위가 낮을 때 그래프의 낙차가 커졌다.

VI. 결론

본 논문에서는 그리퍼를 이용하여 물체를 파지 시에 안 정적인 작업을 수행할 수 있도록 최적의 파지점을 찾는 연 구를 진행하였다. 파지 물체 별 3차원 정보를 사용할 수 있



그림 14. 원뿔의 loss 범위에 따른 성공률.

Fig. 14. Success rate according to the cone loss range.





Fig. 15. Success rate according to the cylinder loss range.



그림 16. 드라이버의 loss 범위에 따른 성공률.





그림 17. 물병의 loss 범위에 따른 성공률.

Fig. 17. Success rate according to the bottle loss range.

도록 Point Cloud Data를 추출 후 Neural Network 학습 과정 에 사용하였고, 실제 물체를 파지할 때 고려할 사항에 맞춰 가치 함수의 요소를 구성하였다. Point Cloud Data에서 다양 한 데이터를 사용하도록 Sampling을 실시 후 학습을 진행 하였고, 물체 별 loss가 가장 낮은 상위 10가지 좌표를 파지 실험에 사용하였다. 또한 최적의 파지 점 실험을 위해서 사 용하는 그리퍼의 힘은 최소한을 사용하여 실험 결과가 힘 에 영향을 받지 않도록 하였다. 비교 대상은 SG-DNN 알고 리즘을 사용하여 물체를 파지할 때 회전이나 놓침이 발생 하지 않는지를 확인하였다. 그 결과 실제 물체를 파지할 때 회전과 놓침이 자주 발생한 SG-DNN 알고리즘과 PSO 알고 리즘과는 달리 SG-DNN 2.0 알고리즘은 물체가 회전되지 않는 파지점을 찾음으로써 성공률의 차이가 존재하였다.

추후 연구로는 물체의 파지 시 마찰력과 최적의 파지 힘 을 고려한 안정적인 파지 점 도출에 대한 학습을 진행할 예정이다.

REFERENCES

- J. Mahelr, J. Liang, S. Niyaz, M. Laskey, R. Doan, X. Liu, J. -A. Ojea, and K. Glodberg, "Dex-net 2.0: Deep learning to plan robust Grips with synthetic point clouds and analytic Grip metrics," arXiv preprint arXiv:1703.09312, 2017.
- [2] C.-Bodnar, A.-Li, K.-Hausman, P.-Pastor, and M.-Kalakrishnan "Quantile qt-opt for risk-aware vision-based robotic grasping," arXiv preprint arXiv:1910.02787, 2019.
- [3] K.-Bousmalis, A.-Irpan, P.-Wohlhart, Y.-Bai, M.-Kelcey, M.-Kalakrishna, D.-Laura, I.-Julian, P.-Peter, K.-Konolige, L.-Sergey, and V.-Vincent, "Using simulation and domain adaptation to improve efficiency of deep robotic Griping," *IEEE International Conference on Robotics and Automation* (ICRA), pp. 4243-4250, 2018.
- [4] H.-J. Cho, J.-B. Song, Y.-B. Park, and I.-H. Seo, "Object recognition and grasping based on artificial intelligence," *Korea Robotics Society*, vol. 16, no. 1, pp. 39-49, 2019.
- [5] F.-J. Chu, R.-Xu, and P.-A. Vela, "Real-world Multiobject, MultiGrip Detection," *IEEE Robotics and Automation Letters*, vol. 3, no. 4, pp. 3355-3362, 2018.
- [6] M.-Li, K.-Hang, D.-Kragic, and A.-Billard, "Dexterous Griping under shape uncertainty," *Robotics and Autonomous Systems*, vol. 75, pp. 352-364, 2016.
- [7] P.-C. Huang, J.-Lehman, K.-A. Mok, R.-Miikkulainen, and L.-Sentis, "Griping novel objects with a dexterous robotic hand through neuroevolution," *IEEE Symposium on Computational Intelligence in Control and Automation (CICA)*, pp. 1-8, 2014.
- [8] D.-Guo, F.-Sun, B.-Fang, C.-Yang, and N.-Xi, "Robotic Griping using visual and tactile sensing," *Information Sciences*, vol. 417, pp. 274-286, 2017.
- [9] S.-Levine, P.-Pastor, A.-Krizhevsky, J.-Ibraz, and D.-Quillen, "Learning hand-eye coordination for robotic Griping with deep learning and large-scale data collection," *The Interna-*

tional Journal of Robotics Research, vol. 37, pp. 421-436, 2018.

- [10] D.-Rao, Q.-Le, T.-Phoka, M.-Quigley, A.-Sudsang, and A. -Y. Andrew, "Griping novel objects with depth segmentation," *IEEE/RSJ International Conference on Intelligent Robots and Systems*, pp. 2578-2585, 2010.
- [11] K.-S. Kim, D.-K. Kim, J.-H. Park, and J.-M. Lee, "Artificial Neural Network for Stable Robotic Griping," *Journal of Korea Robotics Society*, vol. 14, no. 2, pp. 094-103, 2019.
- [12] D.-K. Kim, A.-Li, and J.-M. Lee, "Stable robotic grasping of multiple objects using deep neural networks," *Robotica*, pp. 1-14, doi:10.1017/S0263574720000703, 2020.
- [13] A.-T. Pas and R.-Platt, "Using geometry to detect Grip poses in 3d point clouds," *Springer, In Robotics Research*, pp. 307-324, 2018.
- [14] H.-Liang, X.-Ma, S.-Li, M.-Görner, S.-Tang, B.-Fang, F.-Sun, and J.-Zhang, "PointNetGPD: Detecting Grip Configurations from Point Sets," *IEEE International Conference on Robotics and Automation (ICRA)*, pp. 3629-3635, 2019.
- [15] F.-Ikhwantri, N.-Habibie, A.-R. Syulistyo, and W.-Jatmiko, "Learning semantic segmentation score in weakly supervised convolutional neural network," *IEEE International Conference on Computers, Communications, and Systems* (ICCCS), pp. 19-25, 2015.
- [16] A. Engelbrecht, "Particle swarm optimization," 2012 IEEE Congress on Evolutionary Computation (WCCI), Brisbane, ALD, Australia pp. 1-8, 2012.
- [17] H.-J. Park, B.-H. Ahn, J.-M. Baek, D.-G. Le, C.-W. Kim, S.-B. Joo, O.-W. Gwon, M.-Y. Kim, and J.-H. Seo, "Selection of grasping target and control system of robotic prosthetic hand using images and deep learning," *Journal of Institute of Control, Robotics and Systems (in Korean)*, vol. 25, no. 9, pp. 312-317, 2020.
- [18] D.-Y. Kim, G.-H. Sim, and G.-H. Lee, "Object detection by combining two different CNN algorithms and robotic grasping control," *Journal of Institute of Control, Robotics and Systems (in Korean)*, vol. 25, no. 9, pp. 811-817, 2019.



정 동 교

2016년 동의대학교 조선해양공학과 졸 업. 2020년 부산대학교 대학원 전기전자 컴퓨터공학과 공학석사. 관심분야는 딥 러닝, 인공지능, 비주얼 서보잉.



김 동 언

2015년 인제대학교 전자지능로봇공학과 졸업. 2017년 부산대학교 대학원 전기전 자컴퓨터공학과 공학석사. 2020년 동 대 학원 전기전자컴퓨터공학과 공학박사. 관심분야는 지능제어, 머신러닝, 마이크 로프로세서응용.



이 승 현

2018년 동아대학교 메카트로닉스공학과 졸업. 2020년~현재 부산대학교 대학원 전기전자공학부 석사과정 재학 중. 관심 분야는 인공지능, 비주얼 서보잉.



이 장 명

1980년 서울대학교 전자공학과 졸업. 1982년 동 대학원 공학석사. 1990년 USC (미국 남가주대학교) 공학박사. 1992년~ 현재 부산대학교 전자공학과 교수. 관심 분야는 특수환경 Navigation and Localization, 지능로봇 시스템 설계 및 제어, 마이크로프로세서 응용.