creative commons

COMMONS DEED

저작자표시-비영리-변경금지 2.0 대한민국

이용자는 아래의 조건을 따르는 경우에 한하여 자유롭게

- 이 저작물을 복제, 배포, 전송, 전시, 공연 및 방송할 수 있습니다.

다음과 같은 조건을 따라야 합니다:

저작자표시. 귀하는 원저작자를 표시하여야 합니다.

비영리. 귀하는 이 저작물을 영리 목적으로 이용할 수 없습니다.

변경금지. 귀하는 이 저작물을 개작, 변형 또는 가공할 수 없습니다.

- 귀하는, 이 저작물의 재이용이나 배포의 경우, 이 저작물에 적용된 이용허락조건을 명확하게 나타내어야 합니다.
- 저작권자로부터 별도의 허가를 받으면 이러한 조건들은 적용되지 않습니다.

저작권법에 따른 이용자의 권리는 위의 내용에 의하여 영향을 받지 않습니다.

이것은 이용허락규약(Legal Code)을 이해하기 쉽게 요약한 것입니다.

Disclaimer

dCollection

이학석사 학위논문

모바일 로봇의 물체 파지 인식을 위한 셀프 라벨링 온라인 학습

Self-Labeling Online Learning

for Mobile Robot Grasping

2022년 2월

서울대학교 대학원

협동과정 뇌과학전공

유 영 재

모바일 로봇의 물체 파지 인식을 위한 셀프 라벨링 온라인 학습

Self-Labeling Online Learning

for Mobile Robot Grasping

지도 교수 장 병 탁

이 논문을 이학석사 학위논문으로 제출함
2022년 2월

서울대학교 대학원
협동과정 뇌과학전공
유 영 재

유영재의 이학석사 학위논문을 인준함
2022년 2월

위 원 장 _____ 이 인 아 _____ (인)

부위원장 _____ 장 병 탁 _____ (인)

위 원 _____ 김 현 진 _____ (인)

초 록

동적인 환경에서 물체 파지를 정확하고 견고하게 하는 것은 모바일 조작 로봇이 성공적으로 과업을 수행하는데 필수적이다. 과거 암 로봇의 조작 연구에선 파지 인식을 위해 촉각 센서나 시각 센서를 사용하여 이를 해결하고자 했다. 하지만 이동형 로봇은 변화하는 환경에서 움직임으로 인해 노이즈가 발생함을 고려해야 한다. 최근 파지 인식 연구는 학습 기반 알고리즘에 의존하고 있다. 학습 기반 방법은 데이터를 수집하고 라벨을 입력하는데 많은 시간과 노력이 필요한 제한이 있다. 따라서 본 논문은 로봇의 파지인식학습을 위해, 스스로 라벨링을 수행하며 온라인 학습하는 과정을 자동화하는 종단간(end-to-end) 방법을 제시한다. 셀프 라벨링은 로봇이 물체가 파지 후 사라졌는지 여부를 카메라를 통한 물체 인식으로 확인하여 수행한다. 파지 인식은 멀티모달 파지 인식 네트워크를 통해 학습되며, 이때 입력 데이터는 카메라와 그리퍼의 여러 센서를 통해 얻은 데이터를 활용한다. 제안한 방법을 검증하기 위해 실내 거실 환경에서 정리정돈 과업을 수행하는 실험을 설계하였다. HSR 로봇을 활용해 11개의 물체를 정리 정돈하는 두가지 비교실험을 진행하였고, 파지 인식 네트워크를 사용한 실험이 사용하지 않은 실험대비 파지 실패가 3회, 5회 발생했을 때 과업 수행 시간에서 각각 10.7%와 14.7%의 향상을 보여 제안한 방법의 효율성을 입증하였다.

주요어 : 모바일 홈 로봇, 셀프 라벨링, 온라인 학습, 물체 파지 탐지
학 번 : 2020-21841

목 차

제 1 장 서 론 1
제 1 절 파지 인식 연구의 필요성 및 연구 동향 1
제 2 절 데이터 라벨링의 자동화 필요성 및 방안 제시 3
제 3 절 연구의 내용 4

제 2 장 배경 연구 6
제 1 절 물체 파지 인식 6
제 2 절 온라인 학습 6
제 3 절 자기지도 학습과 셀프 라벨링 7

제 3 장 셀프 라벨링을 통한 파지 인식 온라인 학습 8
제 1 절 로봇을 이용한 셀프 라벨링 8
제 2 절 메모리 기반 온라인 학습 11
제 3 절 파지 인식 네트워크 12

제 4 장 실험 설정 13
제 1 절 로봇 플랫폼 13
제 2 절 파지 작업을 위한 물체 목록 15
제 3 절 RGB-D 카메라 기반 거리 계산 18
제 4 절 실험 방법 20

제 5 장 실험 결과 22
제 1 절 온라인 학습을 통한 파지 인식 네트워크 학습 22
제 2 절 파지 인식 네트워크 사용에 따른 성능 비교 25

제 6 장 고찰 및 결론 28
제 1 절 연구의 정리 28
제 2 절 연구의 고찰 29

참고문헌 31

Abstract 38

표 목차

[표 1] 실험에 사용한 HSR python package.....14

[표 2] 물체 파지 작업을 위한 물체 목록.....16

[표 3] 파지 인식 네트워크의 보편성 검증 물체 목록.....17

그림 목차

[그림 1] 이동형 조작 로봇의 멀티모달 물체 파지 인식 2

[그림 2] 인지행동 모델 모형 3

[그림 3] 물체 파지 인식을 위한 셀프 라벨링 온라인 학습 프레임 워크 개요 5

[그림 4] 셀프 라벨링 온라인 학습 프레임 워크 순서도 9

[그림 5] 멀티모달 파지 인식 네트워크 구조도.....12

[그림 6] HSR 로봇과 실험에 사용한 센서 위치.....13

[그림 7] RGB-D 카메라와 물체 간 배치도 19

[그림 8] 실험 내 파지가 실패한 경우 22

[그림 9] 파지 인식 그래프 학습 시 훈련 및 검증 loss 그래프 23

[그림 10] 온라인 학습의 진행 소요 시간 추이 24

[그림 11] 파지 인식 네트워크 사용 여부에 따른 비교 실험 결과 그래프.....26

[그림 12] 비교 실험 내 파지 실패 시 시간 차이가 발생하는 상황.....27

식 목차

[식 1] RGB-D 카메라와 물체 간 거리 계산 공식 18

알고리즘 목차

[알고리즘 1] 물체 파지 인식을 위한 셀프 라벨링 온라인 학습 프레임워크 개요 10

[알고리즘 2] 성공과 횟수를 조절하는 규칙을 반영한 실험의 알고리즘 21

제 1 장 서 론

제 1 절 파지 인식 연구의 필요성 및 동향

최근 로보틱스와 인공지능 기술의 발전으로 인간의 간단한 업무를 로봇이 대체하는 시도(A. S. Morgan et al, 2020)가 증가하고 있다. 서비스 로봇 분야는 고정된 키오스크와 같은 기계가 정보를 제공하는 것부터 (A. Ghorbani et al., 2009), 자율주행을 수행하는 로봇이 공항, 식당, 박물관 등의 여러 장소에서 작업의 도움을 주기까지 빠르게 성장하고 있다 (D. Zhu et al., 2021). 이러한 서비스 로봇은 팔이 탑재되어 이동 및 조작이 복합적으로 필요한 AI 기반의 고차원 서비스(Y. Kim et al., 2018; B.Wang et al., 2020; J. Yuan et al., 2019) 를 가까운 장래에 제공할 것으로 기대되고 있다.

로봇 팔이 실용적으로 사용되기 위해 필수적으로 필요한 능력은 파지 여부를 감지하는 것이다(Y. Zhang et al., 2018). 파지 여부 감지란 로봇이 현재 물체 파지를 성공적으로 파지하고 있는지 실패하였는지 스스로 인식하는 이진분류 문제이다. 파지 실패는 파지 시도 시 물체 인식기가 정확한 위치 탐지를 실패할 때 발생할 수 있고, 또한 파지 성공 후 로봇의 주행 시 장애물과의 충돌로 물체 떨어뜨림이 발생할 수도 있다. 만약 이와 같은 파지 실패를 인식하지 못한다면, 로봇은 물체 없이 과업을 진행하는 실수가 발생한다.

일부 선행 연구에서는 파지 여부 판단을 위해 촉각 센서 혹은 카메라를 이용하였다 (J. Li et al., 2018; J. W. James et al, 2018; S. Cui et al., 2020). 이들은 사용 가능한 인식을 수행할 수 있지만 실제 모바일 로봇의 서비스에서 사용하기엔 2가지 이유에서 실용성이 떨어진다. 먼저, 모든 로봇 팔이 달린 로봇에 촉각 센서가 탑재되어 있진 않다. 또한 실시간 이미지 스트림을 분석하기엔 실제 환경은 배경이 계속 변화하며 로봇이 다룰 물체 또한 시각적으로 다양하고 복잡하다 (M. Zhao et al.,

2020; M. Siam et al., 2019).

최근 이를 멀티모달 센서를 이용해 상보적으로 인식하는 학습기반 모델이 연구되고 있다 (L. Wellhausen et al., 2020; O. Mees et al., 2016; T. Bhattacharjee et al., 2018; A. Nguyen et al., 2020; D. Vaufreydaz et al., 2016). 인간의 뇌 또한 인식 및 의사결정을 할 때 주변 환경에 자연 감각들이 동적이고 멀티모달하게 반응하는 특성(J. Holler et al., 2019)이 있는데, 이에 착안한 것이다. 본 연구의 선행연구 (Y. J. Yoo et al., 2021) 에선 RGB 카메라, Depth 카메라, 마이크, 힘-토크 센서를 사용해 동적인 환경에서 강인한 과실 인지를 위한 오토 인코더 기반의 이상탐지 방법을 제안했다. 사람의 경우 물체를 떨어뜨릴 때 단순 시각정보만이 아닌, 시각, 청각, 무게감각 등을 복합적으로 고려하여 판단하는데 이러한 특성을 고려해 설계하였다.

본 논문에선 멀티모달 센서 데이터를 이용하는 지도학습 기반의 파지 인식 네트워크를 제안하고자 한다. 그림 1과 같이 카메라와 그리퍼 등에 탑재된 다중 센서로부터 데이터를 얻어 동적인 환경 변화에서 물체 파지를 강건하게 탐지하는 파지 인식 네트워크를 제시하고자 한다.

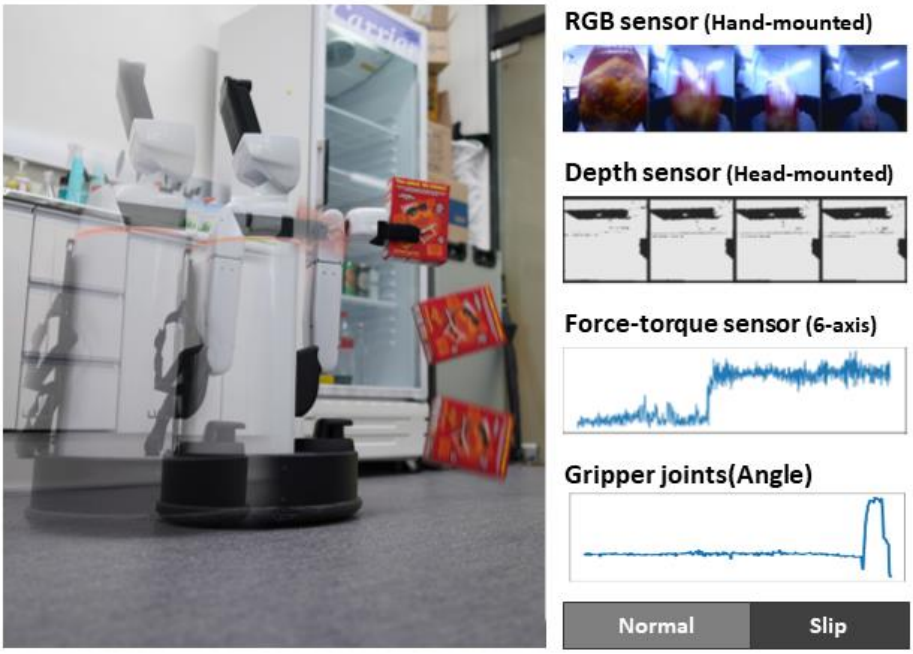

[그림 1] 이동형 조작 로봇의 멀티모달 물체 파지 인식

제 2 절 데이터 라벨링의 자동화 필요성 및 방안 제시

이러한 학습 기반 인식 모델은 사전에 학습된 환경에선 높은 성능을 보이지만 새로운 환경에 직면할 땐 다시 데이터를 수집하고 라벨링하는 과정이 불가피하다 (L. Pinto et al., 2016). 데이터를 수집하고 라벨링하는 과정은 사람의 직접적인 시간과 노력이 소요되기에 많은 비용을 필요로 한다 (E. E. Aksoy et al., 2020; P. Dube et al., 2019; B. Wang et al., 2020). 하지만 인간의 경우 새로운 환경에서 보다 적응적으로 학습한다. 그림 2과 같이 인지행동모델에 의하면 인간은 환경적 변화를 다양한 감각기관을 통해 인식하고 신체의 작동기를 통해 적절한 행동을 환경에 반영한다 (J. M. Fuster, 2005; R. Sun et al., 2010). 간단한 예로 타인이 나를 부르는 소리를 인식해 그 방향으로 고개를 돌리는 것과 같다. 이는 조건에 따라 행동을 결정하고, 행동은 다시 새로운 환경을 형성하는 순환적 상호작용을 갖는데, 이 과정에서 기억 및 경험이 축적된다. 이처럼 환경의 변화를 통해 행동을 이해하고 더 나아가 기억 및 경험을 축적해 학습하는 인간의 인지행동모델과 유사한 학습을 로봇을 통해 설계해 보고자 했다.

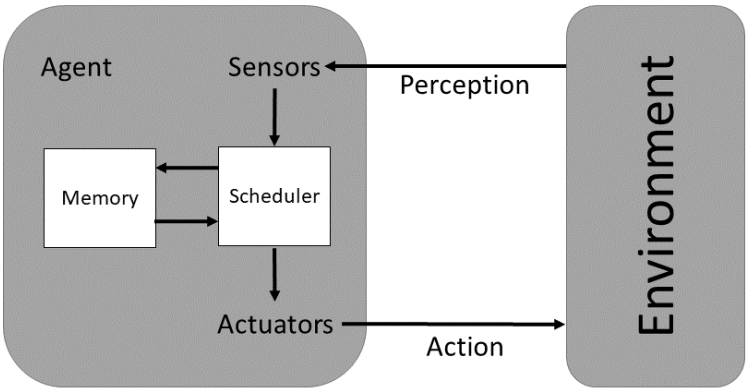

[그림 2] 인지행동 모델 모형

이를 구현하기 위해 로봇의 행동 메커니즘을 유기적인 파이프라인으로 설계하여 로봇이 환경의 변화를 통해 스스로 라벨을 반자동적으로 판단할 수 있는 셀프 라벨링을 설계하였다. 셀프 라벨링은 사람의 직접적 개입이 최소화하며 데이터를 바로 학습에 사용하기에, 데이터 작업을 위한 많은 비용 소모를 줄이는데 기여할 수 있다 (J. Z□rn et al., 2021).

온라인 학습(W. Luo et al., 2018)은 인간의 노동을 줄일 수 있는 또 다른 접근법이다. 기술적으로 로봇은 움직이는 컴퓨터이기에, 데이터 수집 및 모델 학습이 가능하다. 로봇의 온라인 학습은 실시간으로 새로운 환경의 데이터를 수집하여 자가 적응을 가능하게 한다. 또한 온라인 학습 시 데이터를 사용 후 저장할 필요가 없어 메모리 자원의 효율을 향상시킬 수 있다. 셀프 라벨링과 온라인 학습을 결합하면 로봇이 실험을 수행하는 동안 데이터를 모으고, 전처리하며 라벨을 설정한 뒤 학습 데이터로 사용하여 실시간으로 모델을 지도 학습하는 것이 가능하다.

제 2 절 연구의 내용

본 논문에선 시각, 무게, 그리퍼의 관절 값 등의 센서를 통합한 멀티모달 데이터를 통해 동적인 환경 변화에서 물체 파지를 강건하게 탐지하는 파지 인식 네트워크를 제시한다. 파지 인식 네트워크를 지도학습 하기 위해 그림 3과 같이 셀프 라벨링과 온라인 러닝을 모두 활용하는 종단간 학습 방법을 제시한다. 셀프 라벨링은 카메라를 이용한 물체 인식을 감독(supervision)으로 사용해 파지 시도 후 물체의 사라짐 여부에 따라 파지성공 여부를 체크해 1 또는 0의 값을 할당하여 라벨링을 수행한다. 이 방법은 라벨링 과정을 로봇이 픽앤플레이스(pick-and-place) 과업을 수행하는 동안 자동화한다. 온라인 학습은 지속적인 종단간 학습을 수행하기 위한 과정으로 다중 센서

데이터를 모델에 입력하여 실시간 학습한다. 이때, 학습 데이터의 클래스 불균형을 막기 위해 데이터를 축적 후 무작위 배치할 수 있는 큐 기반 메모리를 사용한다. 학습 후 작업 수행 시간의 향상에 파지 인식 네트워크가 얼마나 기여하는지 보이기 위해 비교실험으로 실내 운반 서비스 실험을 설계하여 모델의 효용성을 검증한다.

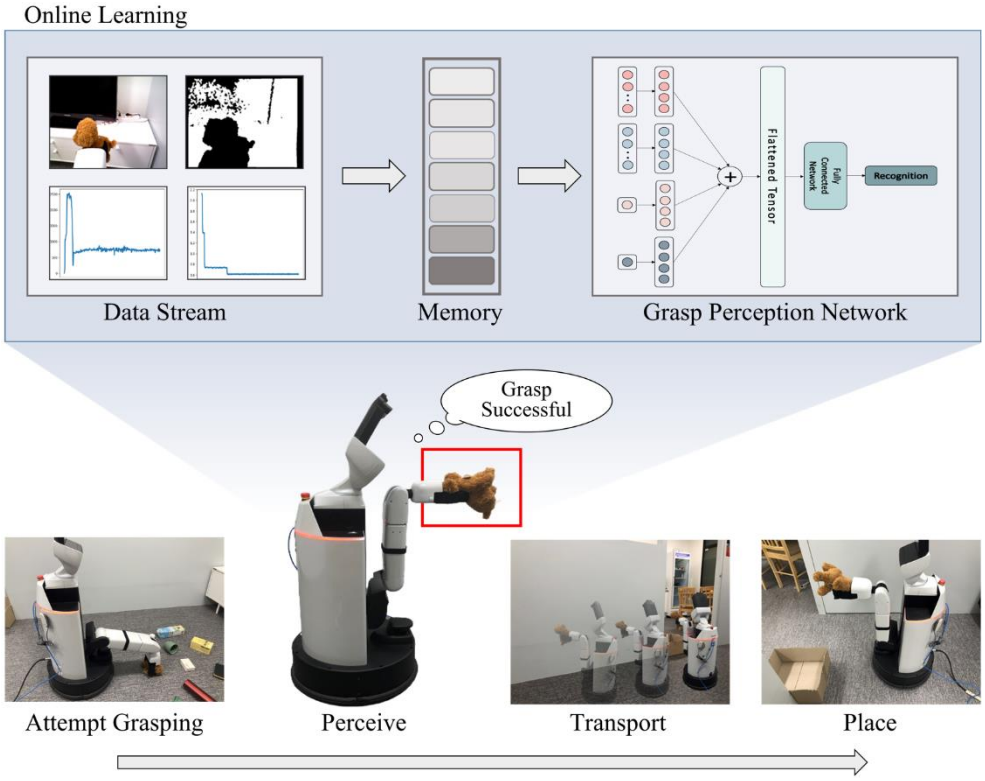

[그림 3] 물체 파지 인식을 위한 셀프 라벨링 온라인 학습 프레임워크 개요: 이동형 조작 로봇이 물체 파지를 시도하고 파지 여부를 셀프 라벨링으로 인식한 뒤, 물체를 운송한다. 이 때 물체를 운송하는 동안 온라인 학습으로 물체 파지여부를 탐지하는 학습이 수행된다.

제 2 장 배경 연구

제 1 절 물체 파지 인식

파지 인식은 로봇의 조작 연구에서 업무 능력을 향상시키는데 중요한 문제이다. 물체 파지 인식이 실패하면 파지 실패 시 이를 알아차리지 못해, 빈 손으로 배달 업무를 수행하는 실수를 초래할 수 있다. 최근 인공지능의 발전으로 머신 러닝 기반의 파지 인식 연구가 시도되고 있다 (Y. Zhang et al., 2018). 센서를 이용한 가장 일반적인 파지 인식법은 촉각센서를 사용하는 것이다. Li의 연구팀 (J. Li et al., 2018) 은 촉각 센서와 카메라 간에 상호 보완적인 탐지를 수행하여 파지 인식에 높은 성능을 보였다. James의 연구팀(J. W. James et al., 2018) 은 Support Vector Machine (SVM)을 탐지 모델로 사용하고 생체모방 촉각 센서인 TacTip을 사용하여 빠르고 견고한 파지 인식을 가능하게 하였다. Zhang의 연구팀 (H. Zhang et al., 2017) 은 RGB 이미지 센서만으로 물체 파지 상태를 성공적으로 추론하는 모델을 선보이기도 했다.

제 2 절 온라인 학습

온라인 학습은 빠르게 변화하는 환경에서 로봇이 실시간 데이터를 받아 자가 적응하는 방법 중 하나이다. Losing의 연구팀 (V. Losing et al., 2015) 은 모바일 로봇으로 장애물을 탐지해 내는 모델을 온라인 학습을 이용하여 구현하였다. 이는 또한 학습 후 데이터를 사용하지 않기에 메모리 자원 효율을 향상시킬 수 있었다. 해당 방법의 검증을 위해 Losing의 연구팀은 응용 시나리오를 설계하여 실시간 상호적

학습을 보였다. 온라인 학습은 학습 초기에 단기적으로 클래스가 한쪽으로 편향되어 불균형을 이룰 경우 과적합(overfitting)이 발생할 우려가 있다. 이에 대한 방안으로 Malialis의 연구팀 (K. Malialis et al., 2018) 은 대기열 기반 리샘플링을 제안하였다. 방법의 핵심 아이디어는 각 클래스 별 데이터를 별도의 대기열에 쌓아 두어 학습 데이터 셋에 선택적으로 포함하는 것이다. 대기열 기반 리샘플링은 학습 속도와 품질 면에서 기존 방식 대비 최고 수준의 결과를 보였다.

제 3 절 자기지도 학습과 셀프 라벨링

지도 학습은 높은 성능의 모델을 구현하는데 유리하지만 수많은 학습데이터에 라벨이 필요하다는 제한사항이 있다 (H. AlQuabeh et al., 2021). 라벨링 작업에 필요한 시간과 노력을 줄이고자 최근 자기지도 학습 (P. Sermanet et al., 2018; H. Alwassel et al., 2020) 과 셀프 라벨링 (M. D. Bah et al., 2018; C. Sandoval al., 2021) 이 방안으로 연구되고 있다. Tung의 연구팀 (H.-Y. F. Tung et al., 2017) 은 RGB 비디오에서 사람의 3D 모양과 골격 외형을 추론하는 자기지도 학습기반 신경망 모델을 제안하였다. 테스트 시 자기지도 손실을 통해 매개변수를 조정하여 순수 감독 학습 기반 최적화 방법보다 높은 수준의 3D 재구성 정확도를 달성했다.

셀프 라벨링은 라벨링 문제를 해결할 수 있는 또다른 접근법이다. De Gregorio의 연구팀 (D. D. Gregorio et al., 2020) 은 로봇을 이용해 가상의 학습 데이터를 생성하는 파이프라인을 제시했다. 이 시스템은 2D 카메라를 이동시키는 반 자동적 방법으로 대규모의 라벨 된 데이터를 최소한의 사람 개입으로 만들 수 있었다.

제 3 장 파지 인식 학습을 위한 셀프 라벨링 온라인 학습

제 1 절 로봇을 이용한 셀프 라벨링

셀프 라벨링은 로봇이 학습 시 데이터의 라벨을 스스로 결정하기 위한 과정이다. 셀프 라벨링의 핵심 아이디어는 카메라를 통한 물체 인식을 감독(supervision)으로 사용해 파지 시도 후 물체의 사라짐 여부에 따라 파지성공 여부를 체크해 라벨을 1 또는 0의 값을 할당하여 결정하는 것이다. 이는 학습 시 파지를 잘 했는지 여부를 스스로 결정하기 위한 과정이며 실시간으로 파지 여부를 연속적으로 인식하는 것과는 다르게 한 번의 파지 시도당 한번 만 이루어진다. 로봇을 이용한 셀프 라벨링 온라인 학습의 파이프 라인은 그림 4와 같다. 이 중, 셀프 라벨링은 왼쪽의 분홍색 박스에 해당되며, 이에 대한 자세한 과정은 알고리즘 1과 같다. 사용한 HSR API의 자세한 설명은 4장 1절의 표 1에 수록하였다. 먼저 시작 위치 P_0에서 RGB-D 카메라로 i번째 파지 시도를 위한 대상 물체 o_i를 탐지한다. 로봇은 RGB-D 카메라를 통해 물체와의 거리를 계산해 물체 파지를 시도한다. 그리고 P_0로 다시 돌아와 o_i를 바닥에서 다시 체크하여 파지 상태를 확인한다. 만약 o_i가 기존 위치에서 발견되지 않으면, 파지가 성공한 것으로 라벨 y_i를 1로 적용한다. o_i가 기존 위치에 발견되면 파지가 실패한 것으로 y_i를 0으로 적용한다. y_i 가 결정되면, 온라인 학습 시작을 위해 스케줄러에 시작 신호 S_{on}을 보낸다. 그리고 물체를 배치할 위치인 P_1으로 로봇이 이동하고 동시에 온라인 학습을 진행한다. 로봇이 물체 배치를 완료하면 다시 P_0로 돌아와 다음 대상 물체 o_{i+1}을 파지할 준비를 한다. 위와 같은 과정을 모든 물체에 대해 동일하게 반복한다.

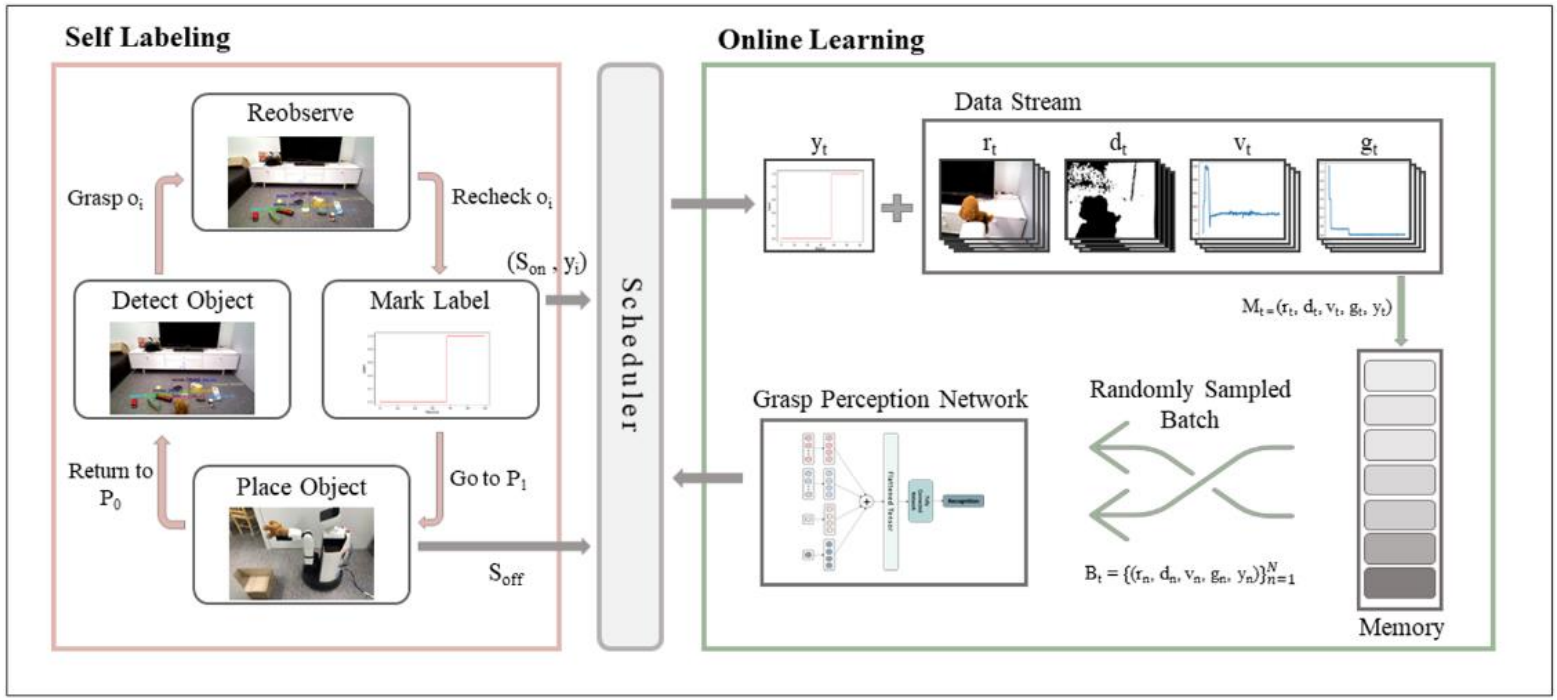

[그림 4] 셀프 라벨링 온라인 학습 프레임 워크 순서도: 크게 셀프 라벨링과 온라인 학습으로 나뉜다. 셀프 라벨링은 물체 파지 성공여부를 확인하여 라벨을 결정한다. 온라인 학습은 실시간 데이터를 받아 파지 인식 네트워크를 학습한다.

알고리즘 1: HSR을 이용한 셀프 라벨링 알고리즘

```
Initialization of joint position
while (searchTargetObject() >0) do
    omni_base.go_abs(start position P0)
    ObjectName, PositionInfo ← searchTargetObject()
    posX ← PositionInfo.z * sin(π/2 – head-joint) –
            PositionInfo.y * cos(π/2 – head-joint)
    omni_base.go_rel(posX, PositionInfo.x, 0)
    whole_body.move_to_joint_positions(joints to pick-up)
    gripper.apply_force(1.0)
    whole_body.move_to_joint_positions(joints to transport)
    omni_base.go_abs(start position P0)
    SuccessGrab ← RecheckTargetObject(ObjectName)
    Scheduler(Son, SuccessGrab)
    omni_base.go_abs(start position P1)
    whole_body.move_to_joint_positions(place the object)
    Scheduler(Soff)
    gripper.command(1.0)
```

제 2 절 메모리 기반 온라인 학습

셀프 라벨링을 통해 라벨 y_i를 파악한 후 스케줄러가 y_i와 S_{on}을 받으면, 온라인 학습을 시작하며 그 과정은 그림 4의 초록색 박스와 같다. 실시간으로 받은 로봇의 각 센서 데이터와 y_i를 메모리 M에 축적한다. M은 여러 물체에 대한 파지 실패와 성공 모두를 저장할 만큼 충분한 크기이며, 큐(Queue)와 같은 선입 선출(FIFO) 구조를 갖는다. 시간 t에 M에 축적된 데이터 M_t는 RGB 이미지 r_t, 심도 이미지 d_t, 힘-토크 센서 값 v_t, 그리퍼의 관절 값 g_t, 그리고 라벨 y_t가 포함된다. r_t와 d_t는 메모리에 넣기 전에 저장공간의 효율과 학습 시 시간 효율을 위해 32 x 32 크기로 재조정한다. M에 데이터가 입력되면, M에서 데이터는 무작위 추출되어 배치 B_t를 이룬다. 이때 $B_t = \{(r_n, d_n, v_n, g_n, y_n)\}_{n=1}^{N}$ 이며 N은 배치 크기(batch size) 이다. 메모리를 사용하지 않고 배치를 실시간 센서 데이터만을 받아 구성하면 온라인 학습 시 편향된 라벨로 학습되는데, 메모리 사용은 이와 같은 편향된 학습을 방지할 수 있다. B_t는 파지 인식 네트워크의 학습데이터로 사용된다. 위의 과정은 o_i가 P_1으로 배치를 완료하기 전까지 반복된다. 배치가 완료되면 스케줄러는 종결 신호 S_{off}를 받아 온라인 학습을 일시정지하고 대기 상태가 된다.

제 3 절 파지 인식 네트워크

파지 인식 네트워크 구조는 그림 5과 같다. 네트워크는 RGB 이미지, 심도 이미지, 힘-토크 센서 데이터, 그리퍼 관절들의 값으로 4가지 종류의 센서 데이터를 통해 학습한다. 각 데이터는 모두 이산 데이터 이기에 주파수가 달라도 동일 시간에 스냅샷 값을 얻기 용이하다. 원시 데이터는 크기와 차원이 다른 이성분(heterogenous) 데이터이기에 정규화와 차원 동기화가 필요하다. 먼저 모든 센서 데이터 값을 0에서 1사이의 값으로 정규화 시킨다. 그리고 같은 크기와 차원으로 만들기 위해, 그림 5과 같은 컨볼루션 연산을 거쳐 크기 및 차원을 재조정해준다. 재조정된 데이터를 1차원(flattened) 텐서로 결합된 뒤, 완전 연결 네트워크(fully connected network)의 입력으로 사용한다. 네트워크의 출력으론 파지 성공 여부가 이항 분류된다. 학습 시, 네트워크는 컨볼루션 계층과 완전 연결 네트워크를 모두 포함하여 훈련된다.

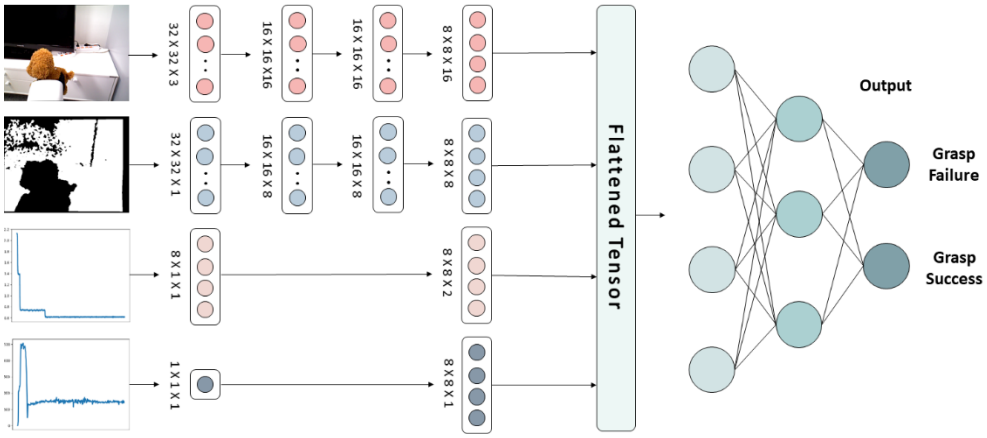

[그림 5] 멀티모달 파지 인식 네트워크 구조도

제 4 장 실험 설정

제 1 절 로봇 플랫폼

실험에 사용한 로봇은 Toyota 사에서 제작한 Human Support Robot(HSR) (T. Yamamoto et al., 2018) 이다. HSR은 실내환경에서 인간에게 유용한 도움을 주기 위해 제작되었다. 전 방향성 이동이 가능하며, 그리퍼가 탑재된 팔로 조작이 가능하다. 실험에 사용한 센서는 그림 6와 같다. 로봇의 머리에 탑재된 RGB-D 카메라는 Xtion Pro live이며 손목에 달린 힘-토크 센서는 DynPick WDF 65M200-3이다.

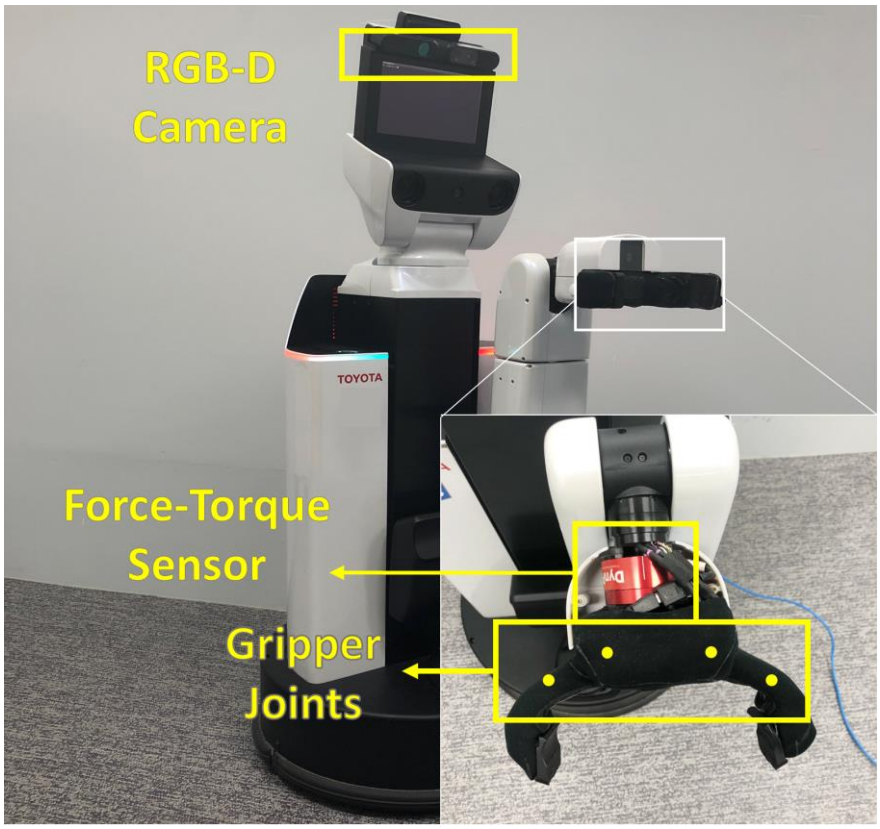

[그림 6] HSR 로봇과 실험에 사용한 센서 위치

소프트웨어 개발은 제공된 ROS와 Python API를 이용하였으며 사용한 주요 API는 표 1과 같다.

[표 1] 실험에 사용한 HSR python package

omni_base.go_abs(x, y, direction, timeout) - 사전에 파악된 지도 내의 절대좌표(*x, y*) 및 목표 방향(*direction*)으로 이동. *timeout* 시간 내 이동 못할 시 오류를 발생
omni_base.go_rel(x, y, direction, timeout) - HSR의 base 를 기준으로 (*x, y*) 거리 및 목표 방향(*direction*)으로 상대적 이동. *timeout* 시간 내 이동 못할 시 오류를 발생
gripper.apply_force(force) - *force* 만큼 그리퍼에 힘을 가함
gripper.command(radian_value) - *radian_value* 만큼 벌어진 각도로 그리퍼 이동
whole_body.move_to_joint_positions({joint_name: radian_value}) - 이름이 *joint_name* 인 관절의 각도를 *radian_value* 가 되도록 회전

제 2 절 파지 작업을 위한 물체 목록

실험에 사용한 물체 목록은 표 2과 표 3와 같다. 표 2은 온라인 학습과 비교 실험을 위한 물체 목록이다. 표 3는 학습된 파지 인식 네트워크의 보편성을 검증하기 위한 물체 목록이다. 물체들은 다음의 조건을 고려하여 선택하였다. 첫째로, HSR은 실내 서비스를 위해 설계된 로봇이기에 실내 일상생활에서 보편적으로 쓰이는 물체로 선정한다. 둘째, HSR의 그리퍼 최대 폭이 13.5cm임을 감안하여 물체는 10cm이내의 폭이 있어야 한다. 셋째, 물체 파지 학습 시 물체의 특수한 특징(feature)에 과적합 하지 않고 보편적인 특징을 학습하기 위해 크기, 무게, 재질 등이 통일되지 않도록 다양한 물체를 선정한다. 마지막으로, YOLOv3 (J. Redmon et al., 2018) 기반 물체 탐지기가 정확히 탐지할 수 있도록 물체의 표면이 명확해야 한다.

[표 2] **물체 파지 작업을 위한 물체 목록:** 파지 인식 네트워크 학습을 위해서 사용하며, 비교 실험 시에도 사용한다.

Object	Photo	Weight	Size	Material
Teddy bear		106g	Large	Fabric
Sponge		14g	Medium	Sponge
Juice pack		34g	Large	Carton
Cup		112g	Medium	Silicone
Tumbler		248g	Large	Metal
Toy car		79g	Small	Plastic
Bottle		311g	Large	Plastic
Soap box		119g	Small	Paper
Vitamin bottle		100g	Small	Plastic
Tennis ball		58g	Small	Felt
Tea box		62g	Medium	Paper

[표 3] 파지 인식 네트워크의 보편성 검증 물체 목록

Object	Photo	Weight	Size	Material
Aluminum can		18g	Medium	Metal
Board eraser		8g	Small	Styrofoam
Mouse		64g	Small	Plastic

제 3 절 RGB-D 카메라 기반 거리 계산

물체를 3D 공간에서 파지하기 위해, 대상 물체와 로봇 간에 3차원 거리를 명확히 계산하는 것이 필요하다. 실험에 사용한 RGB-D 카메라 Xtion Pro live를 이용하면 공간의 3차원 거리 정보인 pointcloud 데이터를 사용할 수 있다. pointcloud 데이터를 로봇의 좌표 시스템에 맞게 변환해주면 로봇이 물체 파지를 위해 이동할 거리 산출이 가능하다. 로봇 머리에 탑재된 RGB-D 카메라와 목표 물체 간의 거리 계산을 도식화한 배치도는 그림 7와 같다. 먼저 RGB-D 카메라와 목표 물체까지 떨어진 3차원 거리를 $D = (d_x, d_y, d_z)$ 라 하자. 투영된 RGB 이미지에서 물체 탐지기가 먼저 목표 물체의 중앙점 좌표 $C = (c_x, c_y)$ 를 찾는다. C 를 이용해 pointcloud 데이터에서 목표 물체까지의 거리인 (pc_x, pc_y, pc_z)를 얻는다. 이 (pc_x, pc_y, pc_z)를 이용해 아래 식과 같이 $D = (d_x, d_y, d_z)$를 구할 수 있다.

$$\sin(\alpha - \beta) = \frac{d_x}{d}$$
$$d_x = pc_z \sin\alpha - pc_y \cos\alpha$$
$$d_y = pc_x$$
$$d_z = pc_z \cos\alpha + pc_y \sin\alpha$$

[식 1] RGB-D 카메라와 물체 간 거리 계산 공식

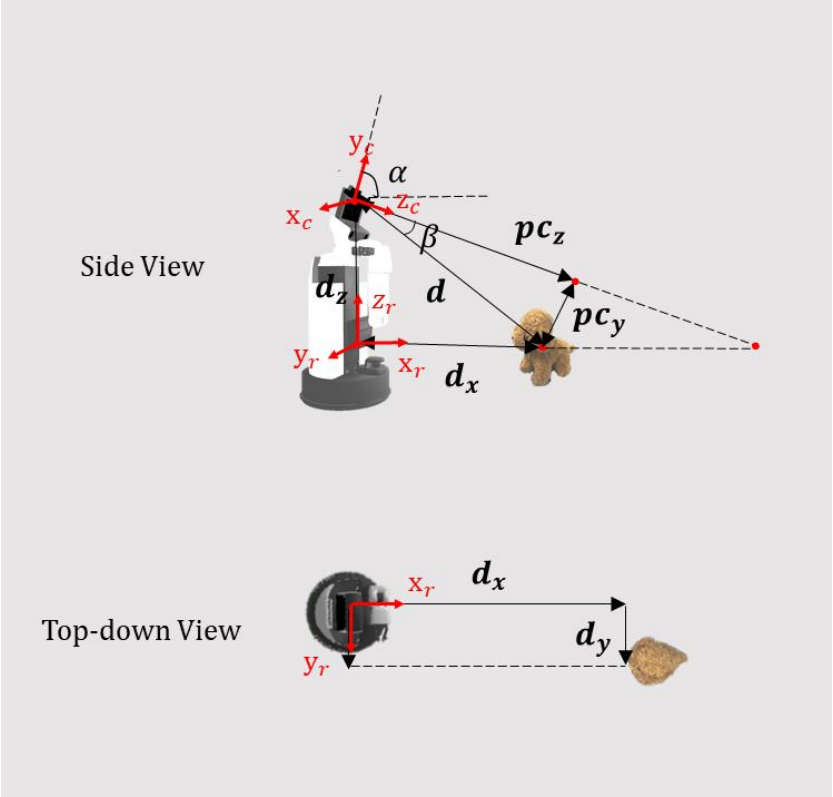

[그림 7] RGB-D 카메라와 물체 간 배치도

제 4 절 실험 방법

파지 인식을 위한 셀프 라벨링 온라인 학습을 진행하기 위해 실험을 설계하였다. 먼저, 선정한 물체들을 실내 거실과 유사한 실험실 바닥에 흩어지게 배치한다. 다음 물체를 파지 할 후보 물체를 물체 탐지기를 통해 탐색한다. 각 물체까지의 거리는 pointcloud 데이터를 사용해 계산하고 가장 작은 pc_z값을 갖는 물체를 목표 물체로 선정한다. 일부 물체는 가로 또는 세로 폭이 HSR이 파지할 수 있는 최대 길이를 초과하므로, 가로 또는 세로 폭 중 좁은 면을 파악하여 파지 방향으로 결정한다.

대상 물체까지의 이동 거리 및 파지 방향을 계산해도 현실의 다양한 변수로 인해 파지 성공은 항상 보장될 순 없다. 학습 시 파지 성공과 실패를 균형 있게 학습하기 위해, 성공 횟수와 실패 횟수가 동일하게 유지되어야 한다. 이를 보장하기 위해, 성공과 실패 횟수를 조절하는 실험의 규칙을 설계하였으며 알고리즘 2와 같다. 만약 파지 실패 횟수가 성공 횟수보다 많다면, 해당 시행은 온라인 학습을 생략한다. 또한 성공 횟수가 파지 실패 횟수보다 많다면, 강제로 파지 실패를 만들기 위해 로봇은 다음 시행에서 의도적으로 허공에 파지를 한 뒤 P_1으로 이동하여 실패 횟수를 보장한다. 이 규칙으로 성공과 실패 횟수는 반드시 균형을 이루게 된다.

알고리즘 2: 성공과 실패 횟수를 조절 규칙을 추가한 알고리즘

```
SuccessCount ← 0
FailureCount ← 0
while (searchTargetObject() >0) do
    Initialization of joint position
    omni_base.go_abs(start position P0)
    if (FailureCount > SuccessCount) then
        ObjectName, PositionInfo ← searchTargetObject()
        posX ← PositionInfo.z * sin(π/2 – head-joint) –
                PositionInfo.y * cos(π/2 – head-joint)
        omni_base.go_rel(posX, PositionInfo.x, 0)
        whole_body.move_to_joint_positions(joints to pick-up)
        gripper.apply_force(1.0)
        whole_body.move_to_joint_positions(joints to transport)
        omni_base.go_abs(start position P0)
        SuccessGrab ← RecheckTargetObject(ObjectName)
        if (SuccessGrab = TRUE) then
            SuccessCount ← SuccessCount + 1
        else if(FailureCount <= SuccessCount) then
            FailureCount ← FailureCount + 1
    else
        gripper.apply_force(1.0)
        FailureCount ← FailureCount + 1
    if (FailureCount < SuccessCount + 2) then
        Scheduler(Son, SuccessGrab)
    omni_base.go_abs(start position P1)
    whole_body.move_to_joint_positions(place the object)
    Scheduler(Soff)
    Gripper.command(1.0)
```

제 5 장 실험 결과

제 1 절 온라인 학습을 통한 파지 인식 네트워크 학습

파지 인식 네트워크 학습을 위한 셀프 라벨링 온라인 학습 실험에서, 대부분의 파지 시도는 성공했지만 드문 경우 실패가 발생했다. 이는 주로 그림 8과 같이 목표 물체가 다른 물체와 인접하여 그리퍼의 운동 경로가 방해되거나 파지가 견고하지 못해 미끄러지는 경우였다. 이 때 실패 물체를 재차 파지 시도하자 목표 물체 주변이 조금씩 밀리며 그리퍼가 접근할 여유 공간이 생겼고, 결국 파지를 성공했다.

[그림 8] 실험 내 파지가 실패한 경우: 목표 물체인 Bottle이 Cup과 인접하여 파지 시 두 물체를 겹쳐 잡게 되었고, 견고하지 못한 파지로 인해 물체를 들어올릴 때 미끄러지며 파지에 실패하였다

그림 9은 파지 인식 네트워크 학습 시의 훈련 손실(train loss)과 검증 손실(validation loss)을 보여준다. 학습 손실 그래프는 Epoch 81 부근에 크게 증가하는데, 이는 학습 데이터의 라벨이 그 이전엔 편향되어 있었기 때문이다. 3장 4절에서 언급한 바와 같이, 성공 횟수와 실패 횟수는 온라인 학습 시 과적합을 막기 위해 균형 있게 유지되어야 한다. 로봇이 첫번째 파지를 성공한 뒤, 메모리에는 일시적으로 성공한 데이터만 편향되어 쌓인다. 이로 인해 파지 인식 네트워크가 성공 시행의 데이터에 과적합된다. 하지만 우리가 설계한 균형 규칙으로 인해 두번째 시행에선 반드시 파지를 실패하게 되어 두번째 온라인 학습 시엔 배치에 두 라벨의 데이터가 모두 포함된다. 따라서 훈련 손실 값은 순간 증가하게 되고, 검증 손실 값은 빠르게 감소한다. 그 후, 라벨은 무작위 추출 시 균형을 이루며 두 손실 값 모두 천천히 감소한다.

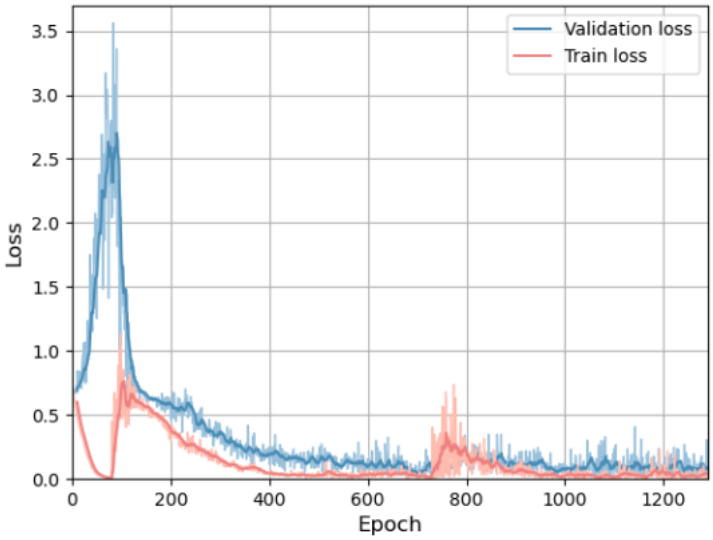

[그림 9] 파지 인식 네트워크 학습 시 훈련 및 검증 loss 그래프

그림 10는 온라인 학습 시작 후, 매 Epoch 시까지 소요된 시간 추이 그래프 이다. 먼저 온라인 학습과 셀프 라벨링이 번갈아 가며 진행되기에 셀프 라벨링 시 소요한 시간만큼 그래프가 끊어진 계단모양의 형태를 띈다. 또한 파지가 성공한 후 학습데이터의 균형을 위해 파지 실패를 강제한 뒤 온라인 학습을 수행하는 경우, 셀프 라벨링을 수행하지 않아 시간의 차가 적게 발생하였다.

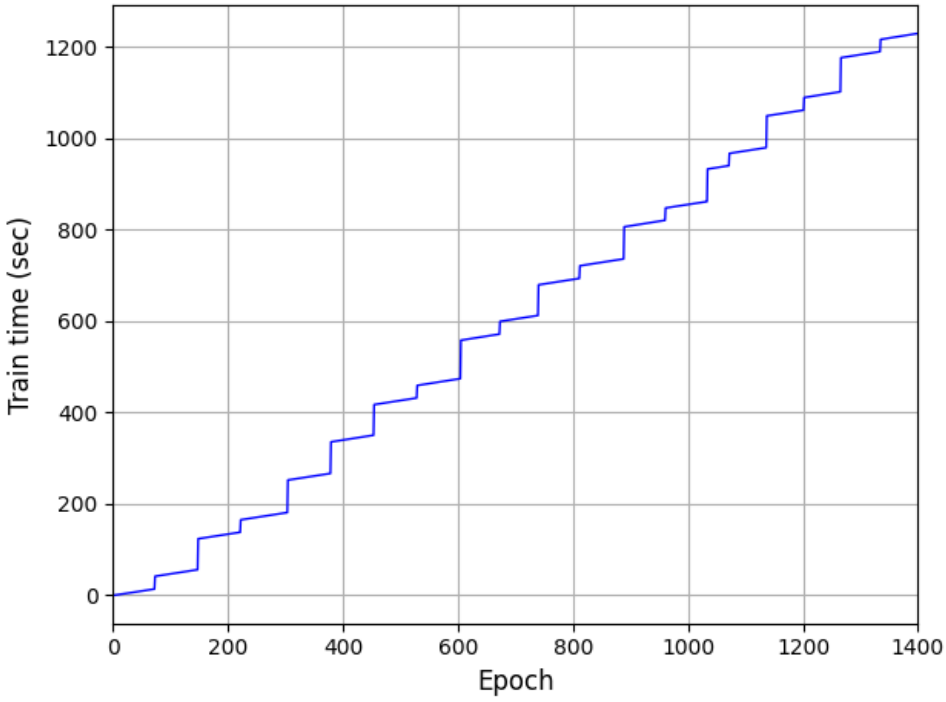

[그림 10] 온라인 학습의 진행 소요 시간 추이: 모든 물건에 대해 온라인 학습을 진행한 총 요소시간은 1230초였다

학습이 끝나고 파지 인식 네트워크는 표 1의 모든 물체에 대해 파지를 성공적으로 인식했다. 또한 네트워크의 보편성을 검증하기 위해 표 2의 검증 물체에 대해 실험한 결과 대개 모든 물체에 대해 파지 인식을 성공하였다. 하지만 board eraser를 종종 파지 인식하는데 실패하였다. 이는 board eraser가 작고 가벼우며, 바닥과 유사한 색을 가져 환경의 변화를 명확히 구분하기 어렵기 때문으로 추측한다.

제 2 절 파지 인식 네트워크 사용에 따른 성능 비교

파지 인식 네트워크를 사용하여 실내 운송 서비스에서 작업 성능이 얼마나 향상되었는지 보이기 위해 비교 실험을 설계했다. 실험은 표 1의 11개 물체를 바닥에 흩어지게 배치한 뒤, 로봇이 파지하여 정해진 위치 P_1으로 옮기는 작업을 수행한다. 로봇의 작업 성능은 모든 물체를 P_1으로 옮기는데 드는 총 시간을 측정하여 평가한다. 파지 인식 네트워크의 사용 여부는 실험의 독립 변수로, 한 실험은 학습된 파지 인식 네트워크를 사용한 데모이고, 대조 실험은 네트워크를 사용하지 않고 항상 파지 성공을 가정한 방법을 사용한다. 학습된 네트워크를 사용한 실험에서는, 모델이 물체 파지를 성공한 경우 바로 P_1으로 이동한다. 하지만 파지 실패를 인식한 경우 로봇은 다시 시작 지점인 P_0로 돌아와 물체를 재 탐색한다. 파지 인식 네트워크를 사용하지 않은 대조 실험은 항상 파지를 성공한 것으로 가정하고 모든 파지 시도 후 P_1으로 이동한다.

비교 실험의 결과는 그림 11과 같다. 두 그래프 모두 처음엔 유사한 속도로 증가한다. 하지만 파지 실패가 일어날 때마다 두 데모 간 시간 격차가 벌어진다. 이는 그림 12의 파지 인식 네트워크를 사용하지 않은 오른쪽 실험과 같이 로봇이 파지 실패를 인지하지 못하여 빈 손으로 이동하는 시간 낭비가 발생하기 때문이다. 반대로 파지인식 네트워크를 사용한 그림 12의 왼쪽 실험은 이러한 낭비되는 시간을 단축하여 다음 목표 물체를 곧바로 탐색한다. 결과적으로, 실험의 총 소요 시간 격차는 그림 11에서 각각 (a) 107초, (b) 150초로, 파지 인식 네트워크를 사용한 데모가 두 경우 모두 높은 성능을 보였다. 성능 향상율은 각각 (a) 10.7%, (b) 14.3%로 파지 실패 횟수가 증가함에 따라 더 높은 성능 향상을 보였다. 만약 물체 파지 후 운반해야 하는 목표 지점이 더 멀수록, 그리고 목표 물체의 개수가 많을수록 파지 인식 네트워크를 사용하는 것이 더 큰 성능 향상에 기여할 것이다.

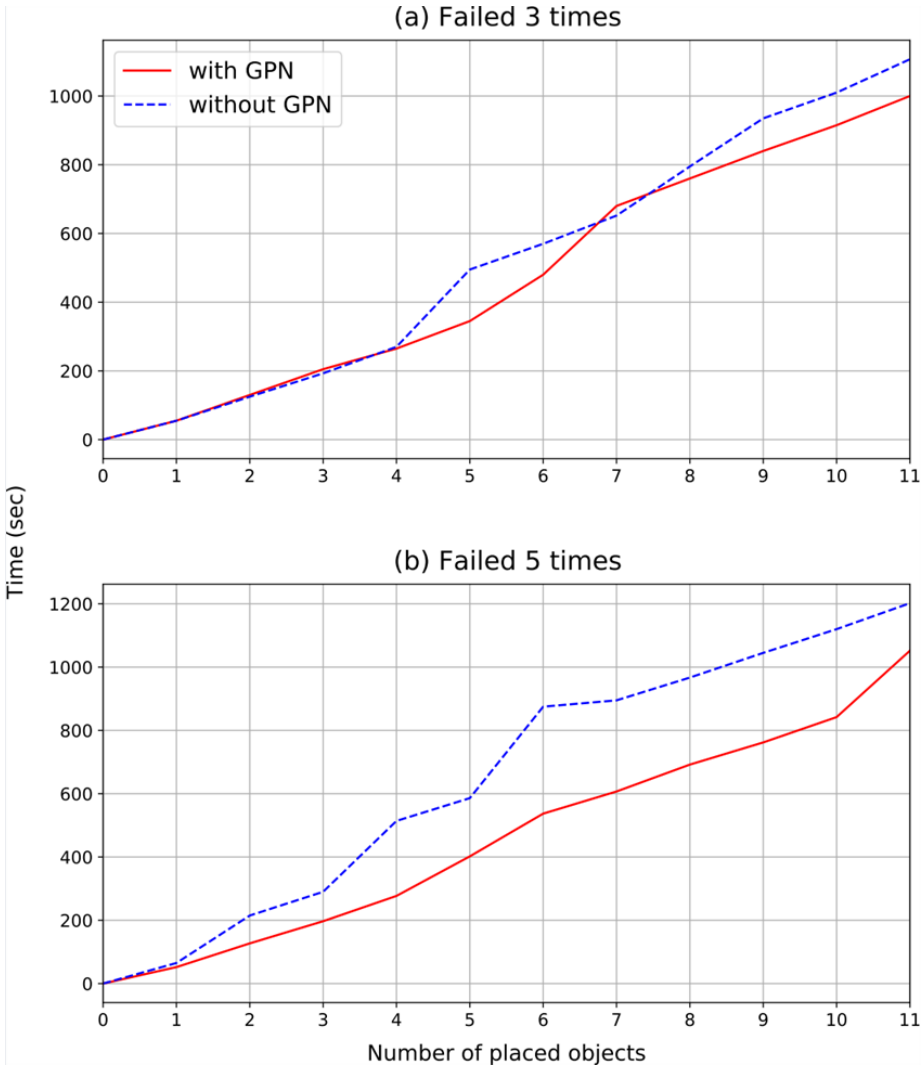

[그림 11] 파지 인식 네트워크 사용 여부에 따른 비교 실험 결과 그래프: 물체 파지 수행 중 실패한 횟수가 (a)는 3회, (b)는 5회이다. 물체 파지 실패가 더 많이 발생할 때 수행 시간의 차이가 더욱 명확히 발생했다.

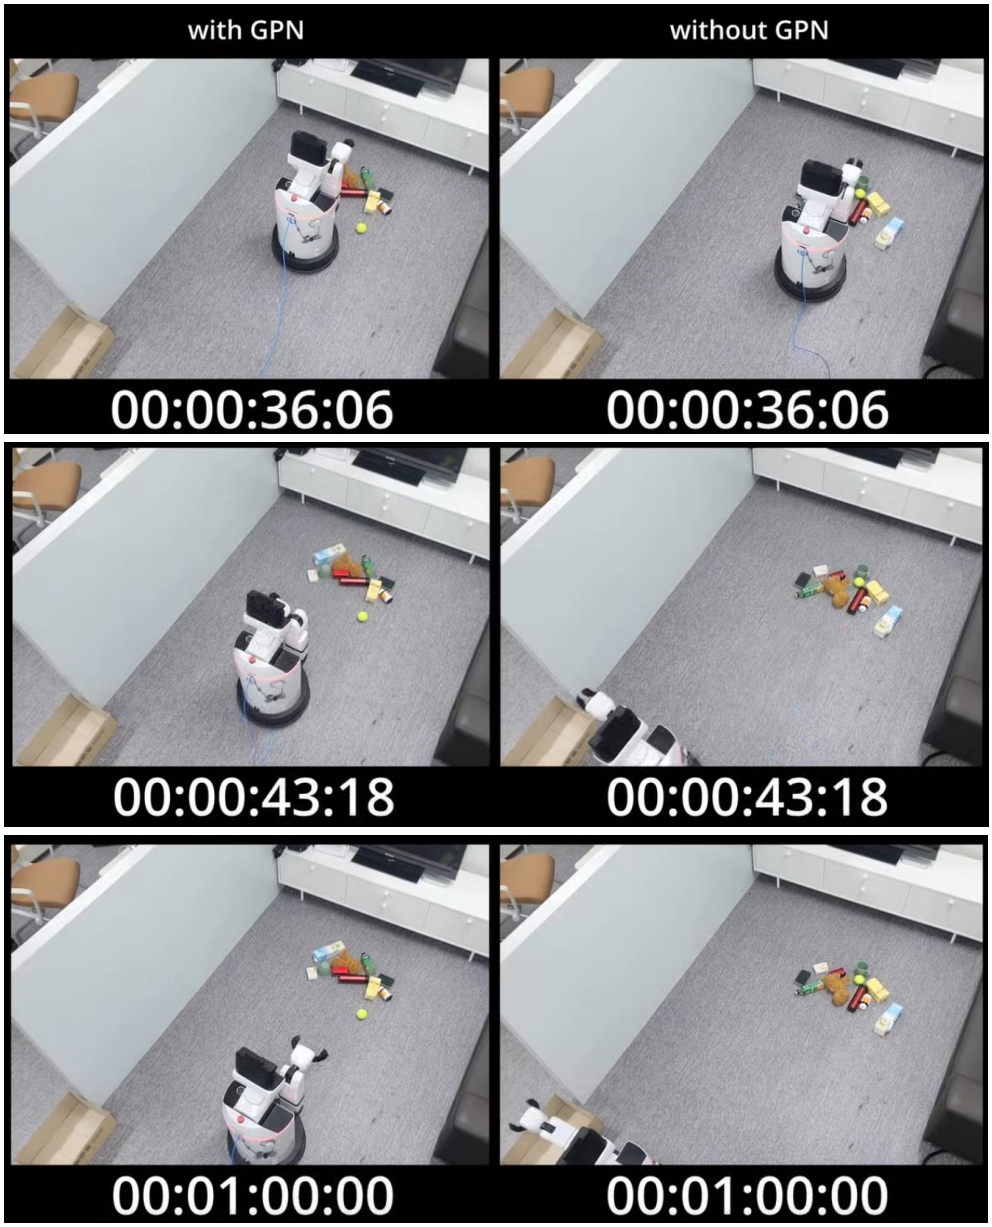

[그림 12] 비교 실험 내 파지 실패 시 시간 차이가 발생하는 상황: 약 36초에 파지 인식 네트워크를 사용한 경우와 사용하지 않은 경우 모두 파지 실패가 일어났을 때의 상황이다. 이때 파지 실패 후, 파지 인식 네트워크를 사용하여 파지 실패를 인식한 경우 바로 다음 목표 물체 탐지를 시도한다. 하지만 파지 인식 네트워크를 사용하지 않은 실험에선 파지 실패 후에도 운반을 시도하며 불필요한 시간을 소모하고 있다.

제 6 장 고찰 및 결론

제 1 절 연구의 정리

본 논문에선, 이동형 조작 로봇이 동적인 환경에서 물체 파지를 견고하게 수행하기 위한 멀티모달 파지 인식 네트워크를 제안하고, 이를 학습할 때 사람의 개입을 최소화하기 위한 셀프 라벨링 온라인 학습을 제안하였다. 셀프 라벨링은 물체 탐지를 감독으로 사용하여 스스로 라벨을 결정하였고, 온라인 학습은 큐 기반 메모리를 사용해 무작위 추출을 하여 모델을 실시간 학습하였다. 강건한 인식을 위해 파지 인식 네트워크는 4개 종류의 센서 데이터를 상호보완적으로 사용하여 학습하였고 다양한 물체에 높은 인식 성능을 보였다. 제시한 셀프 라벨링 온라인 학습 프레임워크를 검증하기 위해, 실제 가정 환경에서 실생활 물체를 파지 한 뒤 옮기는 실험을 설계하였다. 또한 파지 인식 네트워크의 효율성을 검증하기 위해, 파지 인식 네트워크를 사용한 실험과 대조 실험을 설계해 그 작업 성능을 측정하였다. 실험 결과 파지 인식 네트워크가 물체 파지 실패 시 시간을 단축하는데 기여하였고, 파지 실패가 많이 발생할 때 효율이 극대화됨을 확인했다.

제 2 절 연구의 고찰

본 연구는 가상 환경이 아닌 실세계에서 로봇을 활용해 스스로 파지 인식을 학습하는 프레임워크를 설계하여 제시했다. 실제 로봇을 통해 실시간 학습하는 연구가 최근 다양한 과업에서 시도되고 있다. Alex의 연구 팀 (A. Mitrevski et al., 2020) 에선, 이동형 조작 로봇이 물체를 알맞게 파지 하기 위해 이동해야 할 (x, y, z) 좌표를 경험에 기반해 조정하는 프레임워크를 제시했다. 해당 방법을 사용한 물체 끌기 실험에서 학습 이전 14%의 성공률에서 학습 이후 76%의 성공률로 향상됨을 보였다. 하지만 모델의 학습 과정에서 라벨 작업엔 사람의 개입이 필요한 한계가 있는데, 본 논문의 연구에선 사람의 개입 없이 종단간 학습이 가능하다. 물론 A. Mitrevski et al. 의 연구에선 연속형 변수 (x, y, z) 를 추론하는데 반해, 파지 성공 여부는 0과 1의 이진 분류를 수행하기에 비교적 쉬운 수준의 판단이 요구된다.

그리고 파지 인식 네트워크의 설계 시 마이크와 같은 청각 센서의 데이터를 사용하지 못한 한계가 존재한다. 초기 설계 시, 마이크 데이터를 사용하고자 했으나 온라인 학습의 실시간 데이터 스트림 시 한계 사항이 있었다. 파지 인식 네트워크의 입력으로 사용하는 RGB 이미지, Depth 이미지, 힘-토크 센서 값, 그리퍼의 관절 값 등은 모두 이산형(Discrete) 데이터이기에 순간의 스냅샷이 가능하지만, 소리 데이터는 주파수가 필요한 순차(Sequential) 데이터인 특성의 차이가 있다. 따라서 소리데이터는 고정된 주기를 통한 시간 동기화를 거친 뒤, Mel-Frequency Cepstral Coefficient (MFCC) (L. Muda et al., 2010) 와 같은 전처리가 추가적으로 필요하다. 하지만 이와 같은 추가적인 처리과정은 데이터 수집 시 지연을 유발하여 데이터 수집과 전처리 및 모델 학습이 동시에 이루어지는 온라인 학습에 적절치 않다 판단하여 마이크 사용은 제외하게 되었다.

본 논문에선 가정한 환경적 제한은 다음과 같다. 먼저 사전에 학습한 물체에 대해서만 탐지가 가능한 탐지기를 사용하였다. 이는 처음

보는 물체에 대해서는 탐지하지 못하는 한계점이 있다. 이는 Yolo v3 와 같은 물체 탐지기가 물체의 이름이 학습 시 필요로 한 지도학습 기반의 모델이기 때문이다. 최근 이를 확장시키기 위해 처음 보는 물체에 대해서도 라벨은 모르나, 독립적인 물체로 이미지 분할(Image segmentation) 하는 연구가 제시되고 있다 (Y. Xiang et al., 2020). 이와 같은 처음보는 물체 탐지 시 그 라벨은 파악하기 어렵기에 셀프 라벨링 시 파지 성공 여부를 물체 라벨 탐지의 변화를 통해 판단하는 논리의 수정이 필요하다. 이는 시야내 물체의 갯수 변화 및 위치 정보 변화에 따라 셀프 라벨링을 하도록 수정할 수 있다.

또한 목표 물체 탐지 및 운송 시 P_0, P_1 같은 사전에 정의된 고정된 위치에서 수행되었다. 하지만 보다 넓은 공간에서 다양한 물체군으로 실험을 확장한다면 물체 및 운송 지점을 유동적으로 탐지하는 네비게이션 연구가 함께 진행되어야 한다. 예를 들어 현재 운송할 물체는 P_0에서 탐지 시 시야 내에 없을 경우 운송이 불가하다. 하지만 주행 가능한 공간을 돌아다니며 목표 물체를 탐색하면 (A.C. Hern□ndez et al., 2016) 보다 확장성 있는 연구가 가능할 것이다.

참고 문헌

[1] A. Ghorbani, S. Shiry, and A. Nodehi, “Using genetic algorithm for a mobile robot path planning,” in International Conference on Future Computer and Communication, 2009, pp. 164-166.

[2] Y. Kim, J. Jang, and S. Yun, “End-to-end deep learning for autonomous navigation of mobile robot,” in IEEE International Conference on Consumer Electronics (ICCE), 2018.

[3] B. Wang, Z. Liu, Q. Li, and A. Prorok, “Mobile robot path planning in dynamic environments through globally guided reinforcement learning,” IEEE Robotics and Automation Letters, vol. 5, no. 4, pp.6932-6939, 2020.

[4] J. Yuan, H. Wang, C. Lin, D. Liu, and D. Yu, “A novel gru-rnn network model for dynamic path planning of mobile robot,” IEEE Access, vol. 7, pp. 15 140-15 151, 2019.

[5] L. Wellhausen, R. Ranftl, and M. Hutter, “Safe robot navigation via multi-modal anomaly detection,” IEEE Robotics and Automation Letters, vol. 5, no. 2, pp. 1326-1333, 2020.

[6] O. Mees, A. Eitel, and W. Burgard, “Choosing smartly: Adaptive multimodal fusion for object detection in changing environments,” in IEEE/RSJ International Conference on Intelligent Robots and Systems(IROS), 2016, pp. 151-156.

[7] T. Bhattacharjee, H. M. Clever, J. Wade, and C. C. Kemp, “Multimodal tactile perception of objects in a real home,” IEEE Robotics

and Automation Letters, vol. 3, no. 3, pp. 2523–2530.

[8] A. Nguyen, N. Nguyen, K. Tran, E. Tjiputra, and Q. D. Tran, "Autonomous navigation in complex environments with deep multimodal fusion network," in IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), 2020, pp. 5824–5830.

[9] E. E. Aksoy, S. Baci, and S. Cavdar, "Salsanet: Fast road and vehicle segmentation in lidar point clouds for autonomous driving," in IEEE Intelligent Vehicles Symposium (IV), 2020, pp. 926–932.

[10] P. Dube, B. Bhattacharjee, S. Huo, P. Watson, B. Belgodere, and J. R. Kender, "Automatic labeling of data for transfer learning," in IEEE/CVF Conference on Computer Vision and Pattern Recognition(CVPR), 2019, pp. 122–129.

[11] Y. Zhang, Z. Kan, Y. A. Tse, Y. Yang, and M. Y. Wang, "Fingervision tactile sensor design and slip detection using convolutional lstm network," arXiv preprint arXiv:1810.02653, 2018.

[12] J. Li, S. Dong, and E. Adelson, "Slip detection with combined tactile and visual information," in International Conference on Robotics and Automation (ICRA), 2018, pp. 7772–7777.

[13] J. W. James, N. Pestell, and N. F. Lepora, "Slip detection with a biomimetic tactile sensor," IEEE Robotics and Automation Letters, vol. 3, no. 4, pp. 3340–3346, 2018.

[14] H. Zhang, X. Lan, X. Zhou, J. Wang, and N. Zheng, "Vision−based robotic grasp success determination with convolutional neural

network," in IEEE 7th Annual International Conference on CYBER Technology in Automation, Control, and Intelligent Systems (CYBER), 2017, pp. 31–36.

[15] V. Losing, B. Hammer, and H. Wersing, "Interactive online learning for obstacle classification on a mobile robot," in International Joint Conference on Neural Networks (IJCNN), 2015.

[16] K. Malialis, C. Panayiotou, and M. M. Polycarpou, "Queue−based resampling for online class imbalance learning," 2018.

[17] P. Sermanet, C. Lynch, Y. Chebotar, J. Hsu, E. Jang, S. Schaal, S. Levine, and G. Brain, Time−contrastive networks: Self−supervised learning from video," in IEEE International Conference on Robotics and Automation (ICRA), 2018, pp. 1134–1141.

[18] H. Alwassel, D. Mahajan, B. Korbar, L. Torresani, B. Ghanem, and D. Tran, "Self−supervised learning by cross−modal audio−video clustering," in Advances in Neural Information Processing Systems 33 (NeurIPS), 2020.

[19] M. D. Bah, A. Hafiane, and R. Canals, "Deep learning with unsupervised data labeling for weed detection in line crops in uav images," Remote Sensing, vol. 10, no. 11, 2018.

[20] C. Sandoval, E. Pirogova, and M. Lech, "Adversarial learning approach to unsupervised labeling offine art paintings," IEEE Access, vol.9, pp. 81 969–81 985, 2021.

[21] H.−Y. F. Tung, H.−W. Tung, E. Yumer, and K. Fragkiadaki, "Self−

supervised learning of motion capture," arXiv preprint arXiv:1712.01337, 2017.

[22] D. D. Gregorio, A. Tonioni, G. Palli, and L. D. Stefano, "Semiautomatic labeling for deep learning in robotics," IEEE Transactions on Automation Science and Engineering, vol. 17, no. 2, pp. 611–620, 2020.

[23] T. Yamamoto, K. Terada, A. Ochiai, F. Saito, Y. Asahara, and K. Murase, "Development of the research platform of a domestic mobile manipulator utilized for international competition and fieldtest," in International Conference on Intelligent Robots and Systems (IROS), 2018, pp. 7675–7682.

[24] J. Redmon and A. Farhadi, "Yolov3: An incremental improvement," arXiv preprint arXiv:1804.02767, 2018.

[25] D. Zhu, H. Seki, T. Tsuji and T. Hiramitsu, "Mechanism and Design of Tableware Tidying-up Robot for Self-Service Restaurant," 2021 IEEE International Conference on Mechatronics and Automation (ICMA), 2021, pp. 825-830.

[26] A.S. Morgan, K. Hang, W.G. Bircher, F. M. Alladkani, A. Gandhi , B. Calli ,and A. M. Dollar, "Benchmarking Cluttered Robot Pick-and-Place Manipulation With the Box and Blocks Test," in IEEE Robotics and Automation Letters, vol. 5, no. 2, pp. 454-461, 2020.

[27] S. Cui, R. Wang, J. Wei, F. Li and S. Wang, "Grasp State Assessment of Deformable Objects Using Visual-Tactile Fusion Perception," 2020 IEEE International Conference on Robotics and Automation (ICRA), 2020, pp. 538-544.

[28] Y. Zhang, Z. Kan, Y.A. Tse, Y. Yang, M.Y. Wang, “FingerVision Tactile Sensor Design and Slip Detection Using Convolutional LSTM Network”, arXiv preprint arXiv:1810.02653, 2018.

[29] M. Zhao, H. Lu, S. Yang and F. Guo, "The Experience-Memory Q-Learning Algorithm for Robot Path Planning in Unknown Environment," in IEEE Access, vol. 8, pp. 47824-47844, 2020.

[30] M. Siam, C. Jiang, S. Lu, L. Petrich, M. Gamal, M. Elhoseiny, and M. Jagersand "Video Object Segmentation using Teacher-Student Adaptation in a Human Robot Interaction (HRI) Setting," 2019 International Conference on Robotics and Automation (ICRA), 2019, pp. 50-56.

[31] D. Vaufreydaz, W. Johal, and C. Combe, “Starting engagement detection towards a companion robot using multimodal features”, Robotics and Autonomous Systems, Volume 75, Part A, 2016, Pages 4-16.

[32] J. Holler and S. C. Levinson, “Multimodal Language Processing in Human Communication””, Trends in Cognitive Sciences, Volume 23, Issue 8, 2019, Pages 639-652.

[33] L. Pinto and A. Gupta, "Supersizing self-supervision: Learning to grasp from 50K tries and 700 robot hours," 2016 IEEE International Conference on Robotics and Automation (ICRA), 2016, pp. 3406-3413.

[34] R. Sun and N. Wilson, “Motivational Processes Within the

Perception–Action Cycle", Perception−Action Cycle, pp 449−472, 2010.

[35] J. Zürn, W. Burgard and A. Valada, "Self−Supervised Visual Terrain Classification From Unsupervised Acoustic Feature Learning," in IEEE Transactions on Robotics, vol. 37, no. 2, pp. 466−481, 2021.

[36] W. Luo and K. Sycara, "Adaptive Sampling and Online Learning in Multi−Robot Sensor Coverage with Mixture of Gaussian Processes," 2018 IEEE International Conference on Robotics and Automation (ICRA), 2018, pp. 6359−6364.

[37] H. AlQuabeh, A. Bawazeer, A. Alhashmi, "Investigating a Baseline Of Self Supervised Learning Towards Reducing Labeling Costs For Image Classification", arXiv preprint arXiv:2108.07464, 2021.

[38] A. Mitrevski, P. G. Plöger and G. Lakemeyer, "Representation and Experience−Based Learning of Explainable Models for Robot Action Execution," 2020 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), 2020, pp. 5641−5647.

[39] L. Muda, M. Begam and I. Elamvazuthi, "Voice Recognition Algorithms using Mel Frequency Cepstral Coefficient (MFCC) and Dynamic Time Warping (DTW) Techniques", Journal of Computing, Volume 2, Issue 3, 2010.

[40] Y. Xiang, C. Xie, A. Mousavian, D. Fox, "Learning RGB−D Feature Embeddings for Unseen Object Instance Segmentation", arXiv preprint arXiv:2007.15157, 2020.

[41] A.C. Hernández, C. Gómez, J. Crespo and R. Barber, “Object Detection Applied to Indoor Environments for Mobile Robot Navigation”, Sensors 16, no. 8: 1180, 2016.

[42] Multimodal Anomaly Detection Based on Deep Auto-Encoder for Object Slip Perception of Mobile Manipulation Robots, Y.-J. Yoo, C.-Y. Lee, B.-T. Zhang, In Proceedings of the 2021 IEEE International Conference on Robotics and Automation (ICRA 2021), June 2021.

[43] J. M. Fuster, Cortex and mind: Unifying cognition. Oxford university press, 2005.

Abstract

Self-Labeling Online Learning for Mobile Robot Grasping

Youngjae Yoo

Interdisciplinary Program in Neuroscience

The Graduate School

Seoul National University

In this paper, we proposed a new grasp perception method for mobile manipulation robot that utilizes both self-labeling and online learning. Self-labeling is implemented by using object detection as supervision, and online learning was achieved by training the model with a randomly sampled batch from a queue-based memory. For robust perception, the GPN model is trained by processing four types of sensory data, and shows high accuracy in performance with various objects. To demonstrate our self-labeling online learning framework, we designed a pick-and-place experiment in a real-world environment with everyday objects. We verified the effectiveness of the GPN by a comparative experiment that measured the task performance by comparing time within two demos: one using the GPN-trained model, and the other using a simple logical method. As a result, it was confirmed that using the GPN does contribute in saving time for picking and placing the objects, especially if more failures occur, or the time spent in delivering the objects increases.

Keywords : Mobile home robot, Self-labeling, Online learning, Object grasp perception

Student Number : 2020-21841