



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](#)

공학석사 학위논문

자기조직화 신경망을 이용한
지속적이고 능동적인 로봇 학습 기법

**Continual Active Robot Learning using
Self-organizing Neural Network**

2021년 2월

서울대학교 대학원
컴퓨터공학부

황 인 준

자기조직화 신경망을 이용한
지속적이고 능동적인 로봇 학습 기법

Continual Active Robot Learning using
Self-organizing Neural Network

지도교수 장 병 탁

이 논문을 공학석사 학위논문으로 제출함

2020년 10월

서울대학교 대학원

컴퓨터공학부

황 인 준

황인준의 석사 학위논문을 인준함

2020년 12월

위 원 장 _____ 염 현 영 (인)

부 위 원 장 _____ 장 병 탁 (인)

위 원 _____ 엄 현 상 (인)



초 록

이 논문에서는 인공지능 로봇이 실제 환경에 적응하면서 주변에서 접하는 대상의 개념을 지속적이고 능동적으로 학습하는 방법을 제안한다. 최근 딥러닝이 비약적으로 발전하면서 인공지능 가전, 스피커 등이 개발되고 있으나, 이런 제품 대부분은 일괄적으로 학습된 음성 인식이나 얼굴 인식 같은 기능을 이용하기 때문에 개별 동작 환경이 학습 환경과 다르다면 성능이 크게 저하될 수 있다. 또한, 여기에 활용되는 딥러닝 모델은 대량의 데이터로 오랜 시간 학습시켜야 하고 입력 순서에 따라 파괴적 망각이 나타날 수 있다는 한계가 있다. 인공지능 로봇은 새로 감지한 소수의 데이터를 계속 학습해 나가는 것이 필요하며, 이 연구에서는 이를 위해 사람의 학습 방식을 모사하는 데 초점을 맞추었다. 자기조직화 신경망, 온라인 준지도 능동 학습을 비롯하여 사람의 학습 방식을 모사한 기존 머신러닝 기법을 모델 구조와 학습 기제 측면에서 분석하고 이들의 장점을 종합할 수 있는 새로운 모델인 CARLSON을 개발했다.

CARLSON은 로봇이 관측한 물체 이미지를 입력받아 물체 개념을 학습하며, 새로운 데이터를 기존 개념과 대조하면서 지식을 확장해 나가는 자기조직화 신경망 구조로 되어 있다. 물체 이미지는 차원이 높고 잡음을 포함하므로, 효율적이고 안정적인 학습을 위하여 이미지에서 핵심적인 표상을 우선 추출하도록 했다. 표상 추출은 모델의 인코더(encoder) 부분이 수행하며, 이는 표상을 이미지로 복원하는 디코더(decoder)와 함께 훈련된다. 인코더에서 추출된 표상들은 상호 유사도에 따라 여러 개념으로 나뉘고 각 개념은 대표 표상을 가지는 하나의 노드(node)로 군집화된다. 군집화 과정의 노드 추가와 조정은 적응 공명 이론(Grossberg 1987)에서처럼 하향식 예측과 상향식 활성화를 통해 이루어진다. 인코더와 디코더를 포함한 전체 모델은 데이터가 입력될 때마다 학습하며, 표지 전파 기법을 통해 유사한 노드 간에 정보를 전달하고 불확실한 개념에 대해서는 능동적 질의를 통해 정보를 보충함으로써 데이터가 적고 정답 표지가 드물 때도 효과적으로 학습할 수 있다.

이 연구에서는 실제 로봇에서 모델의 성능을 검증하기 위하여 휴머노이드 로봇인 NAO로 연속적인 물체 이미지를 수집하고 시각 객체 인식 실험을 수행했다. CARLSON은 일반적인 딥러닝 모델인 합성곱 신경망(CNN)보다 확연히 높은 분류 정확도를 보였으며, 데이터 수와 표지가 적고 각 데이터를 한 번씩만 학습할 수 있는 제약하에서도 안정적으로 동작하는 것을 검증할 수 있었다. 추가로 잘 알려진 숫자 및 물체 인식 데이터셋인 MNIST, SVHN, Fashion-MNIST, CIFAR-10에서 온라인 준지도 학습 시나리오를 설정하고 모델을 시험했으며, 마찬가지로 CARLSON이 CNN보다 높은 성능을 보이는 것을 확인했다.

주요어: 지속 학습, 능동 학습, 인공지능 로봇, 자기조직화 신경망,
온라인 학습, 준지도 학습

학번: 2019-23288

목 차

초 록	i
목 차	iii
표 차례	v
그림 차례	vi
제 1장 서 론	1
제 2장 사람의 학습 방식을 모사한 머신러닝	5
2.1. 자기조직화 신경망	5
2.1.1. 승자 독식과 k-평균 군집화	6
2.1.2. 자기조직화 지도	6
2.1.3. 뉴럴 가스 네트워크	7
2.2. 효율적인 학습 기제	9
2.2.1. 데이터가 적을 때의 학습 방법	9
2.2.2. 표지가 적을 때의 학습 방법	11
2.3. 적응 공명 이론을 통한 지속 학습	12
제 3장 지속적 능동 학습 자기조직화 신경망	15
3.1. 표상 추출과 데이터 재생성	15
3.2. 가우시안 군집화와 노드 간 정보 전달	16
3.2.1. 개념 생성과 조정	17
3.2.2. 군집 특성을 활용한 인코더 학습	18
3.2.3. 노드 간 표지 정보 전파	21
3.3. 데이터 생성을 통한 능동 학습	22
3.4. CARLSON 학습 및 추론	23
제 4장 일반화된 CARLSON 모델	25
4.1. 유기적 개념 형성	26
4.1.1. 명시적 개념 조정	27

4.1.2. 개념 병합 및 세분화	27
4.2. 계층적 표상화	28
4.3. 능동적 데이터 질의	29
제 5장 시각 객체 인식 실험	31
5.1. 시각 객체 데이터셋	31
5.1.1. 로봇을 이용한 데이터 수집	31
5.1.2. 숫자 및 물체 인식 데이터셋	33
5.2. 온라인 준지도 학습 실험	33
5.2.1. 모델 구현 상세	33
5.2.2. 실험 설정	34
5.2.3. 실험 결과 및 논의	35
제 6장 결 론	36
참고 문헌	37
Abstract	43

표 차례

[표 1] NAO로 수집한 데이터 명세	32
[표 2] 시각 객체 분류 온라인 준지도 학습 결과	35

그림 차례


[그림 1] 인공지능 로봇의 환경 상호 작용 모식도	2
[그림 2] 자기조직화 신경망 학습 예시	8
[그림 3] MPART 모델 구조도(Kim, Hwang, Lee et al. 2020)	14
[그림 4] ARLET 모델 구조도(Choi, Hwang, and Zhang 2020)	14
[그림 5] 일반화된 CARLSON 구조도	25
[그림 6] NAO를 이용한 데이터 수집 환경	32

제 1장

서론

인공지능은 딥러닝 연구가 본격화된 2010년 초부터 대용량 데이터 구축, 고속 처리 하드웨어의 개발과 함께 급속도로 성장해 왔다. 최근에는 실세계 상호 작용을 통해 다양한 환경에 적응할 수 있는 지능 에이전트 혹은 로봇에 관한 연구와 개발이 확대되는 추세이다. 산업에서도 개인화된 인공지능 서비스에 대한 수요가 늘고 있으며 실제로 인공지능이 탑재된 가전과 스피커 등이 출시되었다(López 2017). 하지만 현재의 제품들은 대부분 음성 인식이나 얼굴 인식 같은 정해진 기능만 수행할 수 있으며, 여기에 사용되는 머신러닝 모델은 미리 모아 둔 데이터로 학습시키므로 실사용 환경이 학습 환경과 다르다면 성능이 크게 저하되기도 한다. 제품 업데이트를 통해 새로운 기능이 추가되거나 성능이 향상되기도 하지만 이 역시 단말 각각에 특화된 것이 아니라 일괄적으로 개발 및 배포된다. 이런 제품과 달리 인공지능 로봇은 맥락에 따라 사용자의 명령을 이해하고 물건을 가져오거나 도구를 조작하는 등 다양한 맞춤형 서비스를 제공하기 위해 스스로 환경과 상호 작용하고 경험을 통해 지식을 축적해야 한다. 학습 환경이 계속 변화하기 때문에 미리 수집된 데이터 대신 실시간으로 입력되는 데이터에 지속적으로 적응하는 것도 필요하다(Wang et al. 2017; Park et al. 2018; 그림 2). 이 같은 조건은 사람이 일상에서 학습할 때도 흔히 적용되므로 사람의 학습 방식을 로봇에 적용하면 효율적이고 안정적인 학습을 기대할 수 있다.

사람은 경험한 적 없는 낯선 장소에서 처음 보는 대상을 접했을 때 그 대상을 잠시 살펴보는 것만으로 특성을 파악하고 개념을 쉽게 습득할 수 있으며, 이를 통해 새로운 환경에 유연하고 빠르게 적응할 수 있다. 또한, 새 개념을 배웠다고 해서 기존의 지식을 잊어버리는 것이 아니라 기존 개념을 확장하거나 세분화하면서 지속적으로 학습한다. 사람이 정



[그림 2] 인공지능 로봇의 환경 상호 작용 모식도. 로봇이 변화하는 환경에 적응하고 서비스를 제공하기 위해서는 행동이나 대화를 통해 얻은 다양한 센서 정보를 처리하고 환경에 대한 지식을 지속적으로 학습하는 것이 요구된다.

보를 처리하는 원리가 아직 완전히 파악되지 않는 않지만, 뇌과학, 심리학, 경제학, 인지과학을 비롯한 다양한 분야의 연구를 통해 뇌의 구조와 기능, 감각 정보의 처리 순서, 지각과 행동에 관련된 법칙 같은 중요 사실들이 밝혀졌다. 인공지능도 이러한 발견에 기반을 두고 있으며, 인공지능 시스템은 뇌를 모사한 인공 신경망 모델을 갖추고 머신러닝을 통해 스스로 성능을 개선한다. 음성 인식, 물체 인식 같은 현실 문제를 해결하려면 데이터의 복잡한 패턴까지 파악할 수 있어야 하므로 모델의 처리 단계와 파라미터 개수를 늘린 딥러닝 기법이 활발하게 연구되고 있다 (Krizhevsky 2012; Schmidhuber 2015; He 2016).

딥러닝을 이용한 인공지능 시스템은 시각적 물체 인식이나 음성 인식, 이미지 생성, 시계열 값 예측같이 입력에 대한 결과가 명확하게 정해져 있는 구체적인 과제에서는 사람 수준 이상의 높은 성능을 보이기도 한다. 딥러닝 기법은 일반적으로 선형 변환이나 합성곱(convolution) 연산 등을 조합하여 다수의 파라미터를 가지는 심층 모델을 설정하고 이를 대량의 데이터로 훈련한다. 훈련 시 데이터 각각에 대해 기대하는 결과를 정답 표지(ground-truth label)로 함께 사용하여 완전 지도 학습(fully-supervised learning)하는 경우도 흔하다. 또한, 정확도와 안정성을 높이기 위하여 하나의 데이터셋을 랜덤한 순서로 수십 번 이상 학습하는데, 이 같은 방식은 앞서 언급한 사람의 효율적인 학습 방식과는 거리가 있다. 게다가 복잡한 모델을 학습시키려면 데이터 가공과 파라미터 갱신을 빠르게 처리할 수 있는 고성능 컴퓨팅 장치가 있어야 하고 양질의 데이터와

정답 표지를 수집하는 데도 많은 시간과 인력이 필요하므로 실세계 문제에 바로 적용하기 어렵다는 단점도 있다.

인공지능 로봇처럼 변화하는 환경에 적응해야 하는 시스템은 가공되지 않은 소량의 데이터를 실시간으로 학습해야 하며 정답 표지도 항상 얻을 수 있는 것이 아니므로 데이터 및 표지 효율성이 높은 머신러닝 기법을 사용해야 한다. 데이터가 적을 때는 학습 대상 데이터와 비슷한 환경에서 수집되고 가공된 별도 데이터셋을 이용하여 모델을 일부 미리 학습시킨 후에 대상 데이터가 입력되었을 때 빠르게 적응할 수 있도록 하는 전이 학습 혹은 메타 학습을 고려할 수 있다. 그러나 이 방법을 적용하려면 입력될 데이터를 예측하여 그와 비슷한 데이터를 준비해야 하며, 실제 데이터가 이와 다르다면 미리 학습한 효과가 크게 낮아진다는 한계가 있다. 따라서 로봇 학습에서처럼 모델이 접하게 될 데이터를 알기 어려울 때는 별도 데이터 없이도 입력되는 데이터를 즉시 학습하는 온라인 학습 기법이 적절하다고 볼 수 있다. 데이터 자체의 양과는 별개로 정답 표지가 적다면 약지도, 준지도, 혹은 비지도 학습을 사용할 수 있다. 또한, 학습 도중에 표지를 추가로 획득할 수 있는 상황이라면 개념 형성에 중요하다고 판단되는 데이터의 정답을 질의하는 능동 학습을 사용하는 것도 가능하다. 효과적인 로봇 학습을 위해서는 언급한 기법들을 종합적으로 적용해야 하고 학습에 적절한 모델 구조 개발도 필요하다.

이 연구에서는 인공지능 로봇의 지속적이고 능동적인 물체 개념 학습을 위한 자기조직화 신경망 CARLSON을 제안한다. 이 모델은 적응 공명 이론(Grossberg 1987)을 기본 구조로 하여 파괴적 망각이 없이 지속 학습(continual learning)을 할 수 있으며, 개념을 가우시안 노드(Gaussian node)로 군집화하고 노드 사이의 정보 전달을 통해 부족한 데이터나 표지에도 강건하게 대응할 수 있다. 잡음의 영향을 줄이고 군집화의 성능을 높이기 위해 이미지 데이터에서 핵심적인 특징만 추출하여 표상화하며, 확실하지 않은 개념에 대해서는 표본 추출과 데이터 생성을 통해 사람에게 정답을 묻고 개념을 조정하는 능동 학습도 수행한다. 군집 병합과 분할 과정을 추가하거나 계층적인 표상화를 수행하고 능동 학습 기법

을 다양화하는 방식으로 모델을 확장하는 것도 가능하다. CARLSON은 동작 효율성을 고려하여 구현되었으며, 모델 성능 확인을 위하여 실제 로봇인 NAO로 이미지를 수집하고 시각 객체 인식 실험을 수행했다. 추가 검증을 위해 잘 알려진 숫자 및 물체 인식 데이터셋에 대해서도 온라인 준지도 학습 시나리오를 설정하고 기존 머신러닝 모델인 합성곱 신경망과 비교했으며, 이를 통해 CARLSON이 기존 방법보다 안정적인 지속 학습 성능을 보이는 것을 확인할 수 있었다.

이 논문의 구성은 다음과 같다. 2장에서는 사람의 정보 처리 과정을 살펴보고 사람의 학습 방식을 모사한 기존의 머신러닝 기법을 분석한다. 3장에서는 로봇이 시각 객체를 학습할 수 있도록 구현한 CARLSON 모델에 관해 상술하며, 이를 이론적으로 일반화한 모델을 4장에서 다룬다. 5장에서는 구체적인 실험 환경과 데이터셋을 제시하고 구현된 모델을 온라인 준지도 학습 시나리오에서 실험한 결과에 대해서 논의하며, 6장에서는 전체를 요약하고 연구의 발전 방향을 제시한다.

제 2장

사람의 학습 방식을 모사한 머신러닝

사람이 정보를 처리하고 학습하는 원리는 뇌과학, 심리학, 인지과학 등 여러 학문 분야에서 꾸준히 연구되었다. 뇌에 관한 실험을 통해서 눈이나 귀 같은 감각 기관으로 받아들이는 자극이 시각, 청각 피질처럼 구분된 영역에서 처리된다는 점이 밝혀졌다. 감각 자극은 뇌의 여러 부분을 추가로 거치면서 점차 지각(perceive)되는데, 세부적인 정보의 유형에 따라 다른 경로(pathway)로 처리되기도 한다(Schiller 1986; Alain et al. 2001). 시각을 통해 물체를 인식하거나 청각을 통해 말의 의미를 해석하는 수준의 인지(cognition)가 이루어질 때는 자극의 국소적 패턴부터 통합된 정보까지를 차례로 인식하는 상향식(bottom-up) 처리, 그리고 고차 개념부터 역으로 자극의 패턴을 해석해 나가는 하향식(top-down) 예측이 복합적으로 작용한다. 뇌 영역에 따른 기능 분배와 양방향 정보 처리는 효율적이고 지속적인 학습의 핵심 원리인데, 이 장에서는 이를 모사한 머신러닝 구조인 자기조직화 신경망에 대해 분석하며, 실세계에서처럼 데이터와 정답 표지가 적을 때 모델을 훈련하는 방법들을 살펴본다.

2.1. 자기조직화 신경망

머신러닝 모델 중 다층 퍼셉트론(multilayer perceptron)이나 합성곱 신경망(convolutional neural network)이 파라미터를 이용하여 입력 데이터를 해석하고 처리하는 부분에 대한 일반화를 진행한다. 자기조직화 신경망은 데이터 자체를 명시적인 대표 노드(representative node)로 일반화시킨다(Seiffert and Jain 2002). 노드는 주변의 데이터를 대표하는 대푯값을 가지고 있으며, 대푯값은 일반적으로 입력 데이터와 같은 차원의 벡터로 표현된다. 데이터가 입력되면 그와 비슷한 대푯값을 가지는 노드들이 활성화되고 일련의 연산을 통해 이들의 대푯값을 갱신함으로써 전체 노드

가 대표하는 데이터 분포가 입력된 데이터 분포와 잘 맞도록 조정한다. 여기에는 경쟁식 학습(Rumelhart and Zipser 1985) 원리가 적용되어, 대푯값과 입력 데이터의 유사도가 절대적 기준 혹은 상대적 기준을 넘는 일부 노드에서만 활성화와 조정이 일어난다. 자기조직화 신경망은 정답 표지 없이도 학습과 추론을 할 수 있고 기존 개념과 새로운 개념을 비교하면서 발전한다는 점에서 사람의 학습과 비슷한 특성을 보이며, 데이터를 효과적으로 표현할 수 있도록 노드의 형태나 활성화 및 조정 방법을 달리한 신경망 모델이 다수 제시되었다.

2.1.1. 승자 독식과 k-평균 군집화

전체 노드 중 입력에 대한 유사도가 가장 높은 하나의 노드만 선택하는 것을 승자 독식(winner-take-all) 전략이라고 한다. K-평균 군집화(k-means clustering)가 하나의 예시로, 이 방식에서는 전체 데이터가 정해진 개수의 군집, 즉 노드로 표현된다고 가정한다(MacQueen 1967). 입력과 대푯값의 유사도는 벡터 사이의 유클리드(Euclidean) 거리나 코사인(cosine) 거리 등을 이용하여 정의하며, 모델 학습 시에는 각각의 입력 데이터를 거리가 가장 가까운 승자 노드로 분류한 다음, 각 노드의 대푯값을 그 노드에 속하는 데이터들의 평균으로 치환하는 과정을 반복한다(그림 2a). 모든 노드의 대푯값이 수렴할 때까지 같은 데이터를 반복적으로 학습하며, 최종 결과 노드를 사용하면 새로운 데이터를 분류할 수 있다. 단순한 승자 독식 전략은 이처럼 작동 방식이 직관적이고 구현이 간단하다는 장점이 있지만, 승자 노드 외에는 입력 데이터에 전혀 반응하지 않는다는 문제가 있다. 이를 보완하기 위해서는 유사도가 높은 노드를 모두 업데이트할 수 있는 기법을 추가로 사용해야 한다.

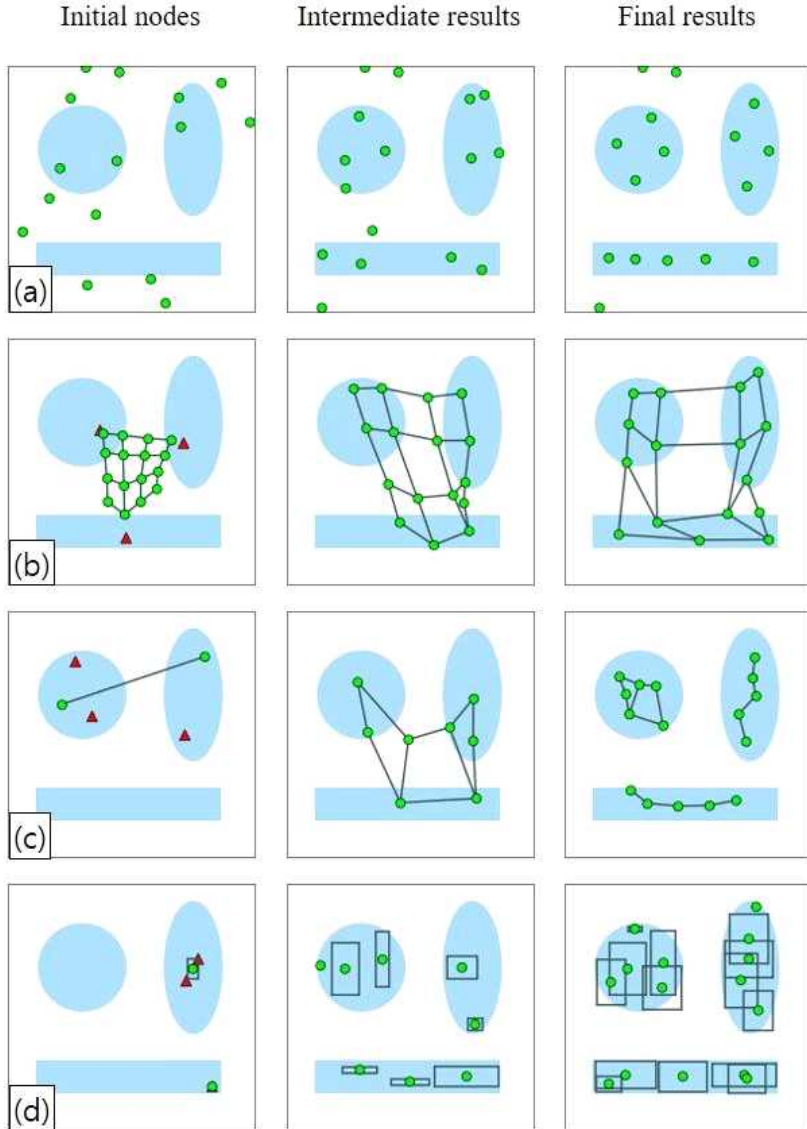
2.1.2. 자기조직화 지도

하나의 입력에 대해 여러 노드를 활성화하고 이들을 모두 업데이트하는 방식이 승자 독식 전략과 함께 널리 사용되며, 이를 응용한 가장 대표적인 구조는 자기조직화 지도(Self-organizing Map, SOM; Kohonen

1982)이다. SOM은 입력 데이터 분포를 대표하는 노드들이 공간상에서 하나 이상의 격자 구조를 이룬다고 가정하며, 거리가 가까운 노드들은 연결되어 있다고 보고 업데이트 정보를 공유하도록 한다. 입력에 대한 승자 노드는 k -평균 군집화에서처럼 대푯값과 입력의 벡터 거리가 가장 가까운 것으로 선택한다. 승자 노드의 대푯값은 입력과의 거리를 줄이는 방향으로 조정하며, 연결된 주변 노드 역시 같은 방향으로 각각의 대푯값을 조정하는데, 조정 정도는 승자 노드와의 거리에 따라 차등적으로 정해진다. 학습이 완료되면 데이터가 밀집된 지역에 많은 노드가 몰려 있고 데이터가 드문 곳에는 노드가 적은 형태를 띠게 된다(그림 2b). 하지만 SOM은 초기에 설정한 격자 형태를 크게 벗어나는 데이터에 대해서는 제대로 대응하지 못하며, 입력 순서에 따라 전체 노드가 한 방향으로 몰리면 파괴적 망각이 일어날 수 있다.

2.1.3. 뉴럴 가스 네트워크

SOM의 단점을 해결하기 위한 제안된 뉴럴 가스(Neural Gas, NG) 계열의 모델들은 SOM의 고정된 노드 연결 상태를 동적으로 변화시킬 수 있도록 개선한 것이다. 초기 모델인 NG (Martinetz and Schulten 1991)는 SOM과 비슷하게 노드 활성화와 조정을 하지만, 노드 간 연결을 미리 정해 두지 않고 공동으로 활성화된 노드 사이에 생성하며, 각 연결의 최근 활성화 시각을 기록하여 일정 시간 동안 활성화되지 않은 연결은 삭제한다. NG를 발전시킨 GNG (Fritzke 1995)는 초기 노드를 두 개로 줄이는 대신 노드마다 입력에 대한 예측 오차를 기록하고 오차가 일정 수준 이상으로 커지면 새로운 노드를 추가하도록 하여 자유도를 높였다(그림 2c). SOINN (Shen and Hasegawa 2006)은 노드 활성화 횟수를 추가로 기록하고 두 수준의 계층적 표상 공간에서 번갈아 가며 군집화를 진행하여 잡음에 강인하게 했으며, 이를 확장한 A-SOINN (Shen et al. 2011)은 준지도 능동 학습을 통해 표지가 적을 때도 안정적으로 데이터를 분류할 수 있도록 했다. 그러나 이런 모델들은 여러 단계의 동작을 결정하는 다수의 고정 파라미터를 미리 정해야 한다는 한계를 가지고 있다.



[그림 3] 자기조직화 신경망 학습 예시. 음영은 입력 데이터 분포, 삼각형(▲)은 초기 입력, 원(●)은 노드를 나타낸다. (a) K-평균 군집화 (b) 자기조직화 지도(SOM) (c) 뉴럴 가스(NG) 네트워크 (d) 적응 공명 이론(ART) 모델의 초기, 학습 중, 최종 노드 분포.

2.2. 효율적인 학습 기제

학습에 사용할 수 있는 데이터와 정답 표지의 수가 적고, 데이터 저장에 대한 제한 때문에 같은 데이터에 여러 번 접근하는 것이 불가능하다면 딥러닝에서 흔히 사용하는 배치 학습(batch learning)은 적용하기 어렵다. 이런 경우에는 주어지는 데이터의 내재적인 정보를 최대한 활용하고 데이터의 유용성을 판단하여 효율적으로 학습하는 방식이 필요하다. 여기서는 이러한 학습 방식을 데이터가 적을 때와 표지가 적을 때로 나누어 살펴보고 기존 기법의 장단점을 분석한다.

2.2.1. 데이터가 적을 때의 학습 방법

입력될 학습 대상 데이터와 유사하면서 이미 다량 수집되고 가공된 사전 준비 데이터를 활용하면 모델이 입력 데이터를 더 효율적으로 학습할 수 있다. 전이 학습(transfer learning)은 사전 준비 데이터로 모델을 사전 학습(pre-train)시킨 뒤에 대상 데이터에 맞도록 파라미터를 수정하는 방법이다(Fei-Fei 2006; Pan and Yang 2009). 딥러닝 모델을 이용한 전이 학습에서는 사전 학습 후에 입력부에 가까운 층의 파라미터를 일부 유지한 상태로 대상 데이터를 학습시킨다(Yosinski et al. 2014). 이를 통해 초반 모델 층에서 사전 준비 데이터와 대상 데이터가 공통으로 지나는 특징이 안정적으로 추출되며, 후반 층에서는 파라미터 조정을 통해 대상 데이터에 특화된 성질을 학습할 수 있다. 사전 준비 데이터와 학습 대상 데이터를 서로 다른 도메인(domain)으로 보고 이들 사이의 관계를 학습하는 도메인 적응(domain adaptation) 방식으로 학습할 수도 있으며, 이때는 사전 준비 도메인에서 분류 성능을 높이면서 두 도메인의 데이터 표상이 비슷해지는 방향으로 모델을 훈련함으로써 결과적으로 대상 데이터에서도 높은 분류 성능을 얻을 수 있도록 한다(Ben-David et al. 2010).

메타 학습(meta learning)은 사전 준비 데이터를 이용하여 모델이 적은 양의 학습 대상 데이터에 빠르게 적응하는 데 필요한 기능을 발달시키는 기법이다. 메타 학습이 효과적으로 적용되는 대표적인 문제는 퓨샷 분류(few-shot classification)로, 학습 과정에서 접하지 못했던 범주의 표지

데이터 예시가 소수(few-shot) 주어질 때 이와 같은 범주의 미표지 (unlabeled) 데이터를 분류해 내는 것이 목적이다. 이 문제에서는 다량의 사전 준비 데이터를 사용하더라도 분류하고자 하는 범주에 관한 정보는 얻을 수 없다. 따라서 일반적인 분류 모델을 학습시키는 대신에 데이터의 내재적 특징을 추출하거나 데이터 간의 유사도를 추정하는 방식으로 미표지 데이터가 어느 표지 데이터와 가장 가까운지 찾는다. 사전 준비 데이터를 이용하여 데이터의 특징적인 부분들이 이루는 패턴을 모델링하거나(Fei-Fei, Fergus, and Perona 2006), 데이터 간의 유사도를 거리로 나타내 학습하는 거리 학습(metric learning; Koch et al. 2015), 데이터를 그래프의 노드로 표현하고 이들 사이의 연결성을 학습하는 그래프 학습(graph learning; Kim et al. 2019) 방법 등이 이용된다. 학습의 효율을 높이기 위해서, 사전 준비 데이터에서 일부 데이터만 추출하고 퓨샷 학습 상황을 설정하여 분류기를 학습시키는 시행을 반복하는 일화적 훈련(episodic training; Vinyals et al. 2016)이 주로 이루어진다.

전이 학습과 메타 학습에서 사용되는 사전 준비 데이터를 마련하기 위해서는 학습 대상 데이터의 특징을 먼저 예측해야 한다. 그러나 로봇 학습 시에는 환경과 데이터 수집 조건이 변하기 때문에 이를 예측하는 것이 어려우며, 로봇이 앞으로 접할 데이터와 비슷하면서 이미 잘 가공된 데이터를 찾는 일도 쉽지 않다. 따라서 이 연구에서는 사전 준비 데이터 없이도 적은 입력 데이터만으로 학습을 수행하는 온라인 학습(online learning)에 초점을 맞춘다. 온라인 학습은 데이터가 입력되는 즉시 파라미터를 업데이트하는 방식으로, 한 번에 입력되는 데이터가 소량이어도 학습이 가능하다(Hoi et al. 2018). 배치 학습도 배치 크기를 작게 설정한다면 일종의 온라인 학습으로 볼 수 있지만, 파라미터 업데이트의 안정성이 떨어지고 학습률(learning rate)에 따라 학습이 오래 걸리거나 망각이 심해진다는 문제가 있다. 일반적으로 온라인 학습은 안정적인 학습을 위해 지속 학습을 동반한 점증 학습(incremental learning) 형태로 활용된다(He et al. 2011; Lee et al. 2017).

2.2.2. 표지가 적을 때의 학습 방법

학습 데이터에 정확한 정답 표지를 일일이 부여하는 것은 전문성과 시간이 많이 요구되는 작업이다. 이 때문에 일부 상황에서는 데이터 표지가 정확하지 않거나 누락된 조건에서 학습을 수행해야 한다. 잘못된 표지가 입력되거나 정답 표지 대신 이를 유추하는 단서만 주어지는 상태에서의 학습은 약지도 학습(weakly supervised learning)에 해당한다. 표지가 전혀 없다면 비지도 학습(unsupervised learning)을 수행해야 하며, 이때는 보통 데이터 간의 유사성이나 연관성을 예측하는 것을 목적으로 하여 데이터의 내재적인 특징을 최대한 포착하고 유용한 정보를 추출하도록 학습된다. 비지도 학습을 하는 구조에는 자기조직화 신경망 대부분이 포함된다. 일부 데이터만 표지되어 있고 나머지에는 표지가 없을 때는 준지도 학습(semi-supervised learning) 기법이 사용되며, 이때는 적게나마 주어지는 표지 정보를 최대한 활용하기 위하여 모델 내부 표상 간 표지 전파(label propagation)를 적용하거나 스스로 예측한 표지를 정답으로 삼아 학습하는 자기 훈련(self-training) 등이 이용된다(Zhu and Ghahramani 2002; Zou et al. 2019).

모델이 학습하는 도중에 추가적인 표지 정보를 얻을 수 있는 상황에는 능동 학습(active learning)을 사용한다. 능동 학습은 모델이 사람처럼 정답을 알고 있는 존재에게 간헐적으로 질문하여 획득한 정답을 학습하는 방식이다(Zhang 1994, Settles 2012). 데이터가 소량이어도 표지를 전부 질의하는 것은 사실상 불가능하므로 정보이론에 근거하여 중요한 데이터만 선택하여 질의한다. 데이터의 중요도는 해당 데이터를 학습한다고 가정했을 때 모델의 예측력이 향상될 정도의 기댓값으로 정하며, 이는 현재 모델로 데이터의 표지를 예측했을 때 그 결과의 확신(confidence), 마진(margin), 엔트로피(entropy) 등의 지표로 정의할 수 있다. 능동 학습은 질의를 통해 얻은 표지를 이용하여 완전 지도 학습(supervised learning) 혹은 준지도 학습과 함께 사용된다. 이 논문에서 다루는 로봇 학습 상황에서는 데이터 표지가 일부 주어지고 추가 표지도 얻을 수 있으므로 준지도 능동 학습 기법을 적용한다.

2.3. 적응 공명 이론을 통한 지속 학습

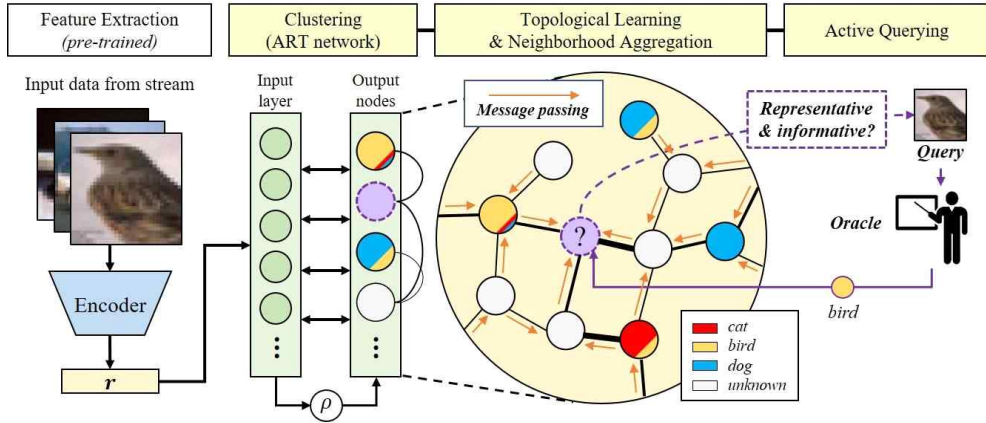
적응 공명 이론(Adaptive Resonance Theory, ART; Grossberg 1987)은 사람 뇌 정보 처리에 관한 이론으로, 다양한 자기조직화 신경망이 여기에 기반을 두고 개발되었다. ART 모델은 SOM이나 NG을 비롯한 다른 자기조직화 신경망처럼 입력 데이터에 가장 잘 맞는 노드를 먼저 찾는데, 여기에 더해 대푯값과 입력 사이의 적합도를 계산하고 경계값(vigilance parameter)과 비교하여 선택된 노드가 정말 입력을 대표할 만한지 판단하는 과정이 있다. 즉 노드를 기준으로 입력에 대해 하향식으로 예측한 결과와 입력을 기준으로 노드를 상향식으로 활성화한 결과가 공명을 이룰 때만 입력된 데이터가 기존 개념에 부합한다고 해석하며, 이를 통해 잡음에 강건하게 군집화할 수 있다. 적합한 노드가 없을 때는 새로운 노드를 추가하므로 망각이 없는 지속 학습(continual learning)이 가능하다. 또한, 입력이 들어올 때마다 노드를 업데이트하므로 온라인 학습 특성 역시 가진다. ART 모델은 기본적으로 비지도로 학습되며, 구현에 따라 완전 지도 혹은 준지도 학습 및 능동 학습도 가능하다.

초기 ART 모델인 ART 1 (Grossberg 1987)은 전체 노드에 대해 대푯값과 입력의 일치도를 먼저 계산하여 승자 노드를 찾고 그에 대한 적합도를 검사한다. 적합도가 경계값을 넘으면 해당 노드가 최종 승자가 되지만, 그렇지 않으면 일치도가 다음으로 높은 노드를 승자 노드로 취급하고 적합도를 검사하는 과정을 반복한다. 이런 과정은 처리 시간이 오래 걸린다는 단점이 있는데, 이를 개선한 Fuzzy ART는 모든 노드에 대한 일치도 T 와 적합도 V 를 한 번의 절차에서 계산하여 속도를 높였다 (Carpenter, Grossberg, and Rosen 1991). 입력 벡터가 \mathbf{x} , 노드 대푯값이 \mathbf{v} 일 때 T 와 V 는 수식 1과 같이 계산되며, 여기서 연산자 \wedge 는 두 벡터의 원소 단위 최솟값으로 구성된 벡터를 찾는 퍼지 연산자(fuzzy operator), $\|\cdot\|_1$ 는 벡터 원소들의 절댓값 합인 L1 norm를 의미하고, 상수인 선택 파라미터 α 를 통해 노드 선택을 조정할 수 있다.

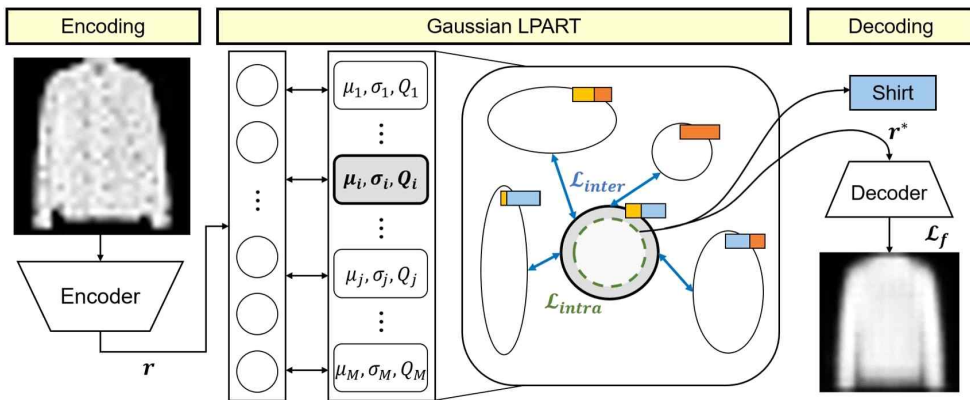
$$T(\mathbf{x}, \mathbf{v}) = \frac{\|\mathbf{x} \wedge \mathbf{v}\|_1}{\alpha + \|\mathbf{v}\|_1}, \quad V(\mathbf{x}, \mathbf{v}) = \frac{\|\mathbf{x} \wedge \mathbf{v}\|_1}{\|\mathbf{x}\|_1} \quad (1)$$

Fuzzy ART를 응용한 모델로는 완전 지도 학습을 가정하고 표지 정보를 저장하면서 군집화를 수행하는 Fuzzy ARTMAP (Carpenter et al. 1992), 군집 형태를 가우시안 분포로 가정한 Gaussian ART (Williamson 1996), 군집화 네트워크 계층을 추가한 TopoART (Tscherepanow 2010) 등이 있다. 또 다른 응용인 LPART (Kim, Hwang, Kang et al. 2020)는 준지도 학습을 위해 노드에 표지 분포(label density)를 추가하고 이를 전파(propagate)하도록 했다. 이를 확장한 MPART (Kim, Hwang, Lee et al. 2020)는 노드 간에 명시적인 연결을 추가하여 전체를 그래프로 간주하고 메시지 패싱(message passing)을 통한 표지 전파가 이루어지도록 했다(그림 4). 또한, 노드의 표지 불확실도를 정의하고 이를 이용해 표지를 질의하는 능동 학습을 적용하여 학습 효율성을 높였다.

자기조직화 신경망에서 고차원 데이터를 가공 없이 군집화하게 되면 잡음에 취약해지므로 저차원으로 표상화하는 과정이 필요한데, LPART나 MPART를 비롯한 대부분의 ART 모델은 입력을 그대로 받아들여 군집화할 뿐, 데이터를 직접 표상화하지는 않는다. 따라서 이런 모델은 별도의 표상 추출기를 훈련하여 사용해야 한다는 단점이 있다. ARLET (Choi, Hwang, and Zhang 2020)은 ART 구조와 표상 추출기를 한꺼번에 학습하는 방식으로 이 문제를 개선한 모델이다(그림 5). 이 모델은 인코더(encoder)를 통해 표상을 추출하고 ART 방식을 거쳐 가우시안 노드로 군집화하며, 노드의 특성에 따라 인코더를 다시 학습시키는 방식으로 작동한다. 이때 노드가 나타내는 분포 특성에 관한 목적 함수와 노드 간 거리로 정의되는 목적 함수를 최소화함으로써 표지가 같은 노드끼리 더 잘 모일 수 있도록 한다. ARLET은 이를 통해 MNIST, CIFAR-10 등의 시각 객체 분류 데이터셋에서 안정적인 온라인 준지도 지속 학습 성능을 보였다. 이 논문에서 제안하는 CARLSON은 ARLET에 기반을 두고 있으며, MPART에서와 같이 표지 불확실도에 따른 능동적인 질의 과정을 추가하는 한편, 모델을 이론적으로 일반화하고 실제 로봇에 적용해 검증함으로써 실세계 문제를 해결할 수 있도록 발전시켰다.



[그림 4] MPART 모델 구조도(Kim, Hwang, Lee et al. 2020). FuzzyART를 기본으로 하여 데이터 표상을 군집화하며, 메시지 패싱을 통한 준지도 학습이 가능하다. 또한, 노드의 표지 불확실도에 따라 표지를 질의하는 능동 학습을 적용했다.



[그림 5] ARLET 모델 구조도(Choi, Hwang, and Zhang 2020). 가우시안 군집을 형성하고 표지를 전파하는 Gaussian LPART가 중심이 되며, 데이터에서 표상을 추출하는 인코더와 표상을 데이터 차원으로 복원하는 디코더를 Gaussian LPART와 함께 중단 학습하여 새로운 입력에 대한 유연한 적용이 가능하다.

제 3장

지속적 능동 학습 자기조직화 신경망

이 논문에서 제안하는 자기조직화 신경망 모델 CARLSON은 지속적이고 능동적인 로봇 학습을 위하여 데이터 군집화를 통해 개념을 형성하고 능동적 질의를 이용하여 부족한 정보를 스스로 보완한다. 구체적으로는 로봇이 물체를 연속으로 관찰하면서 획득한 시각 데이터와 그에 대해 간헐적으로 주어지는 물체 범주 표지를 온라인으로 학습하고, 능동 학습 시에는 표지가 불확실한 개념을 선택하여 이미지를 생성하고 그 표지를 사람에게 물어본다. 입력 데이터가 픽셀 단위의 이미지이므로 입력의 차원을 낮춤으로써 잡음을 제거하고 핵심적인 특징만 남기는 표상 추출을 수행하며, ART 모델을 활용하여 표상을 군집화하는 형태를 취한다. 각각의 군집은 개별적인 개념으로 볼 수 있는데, 학습이 이루어지면서 대상의 개념 형성에 핵심이 되는 특징이 변할 수 있으므로 군집화와 표상 추출 능력을 함께 발달시키는 종단 학습(end-to-end training)을 적용했다. CARLSON의 구성 요소는 다음 절에서부터 상세하게 다룬다.

3.1. 표상 추출과 데이터 재생성

데이터 표상 추출은 합성곱 신경망 구조로 된 인코더(encoder) E 가 수행한다. 입력 데이터 X 는 높이 h , 너비 w 인 RGB 이미지로, 각 원소가 0 이상 1 이하이고 크기 $h \times w \times 3$ 인 3차원 실수 행렬로 표현된다. 인코딩 결과는 k 차원 표상 벡터 \mathbf{r} 이 되며, 이후 자기조직화 신경망에 의해 군집화된다. 추출된 표상이 데이터의 핵심 특성을 포함해야 하므로 오토인코딩(autoencoding) 구조를 사용하여 인코더를 학습시킨다. 즉 인코더에서 추출된 표상 \mathbf{r} 로부터 이미지 \hat{X} 를 만들어 내는 디코더(decoder) D 를 사용하여, 재생성 이미지가 원본과 가까워지도록 훈련함으로써 \mathbf{r} 이 이미

지의 주요 특징을 보존하도록 유도한다. 인코더와 디코더는 원본과 재생성 이미지의 이진 교차 엔트로피(binary cross-entropy, BCE)로 정의된 재생성 목적 함수 L_{rec} 를 최소화하는 방향으로 함께 학습된다.

$$\begin{aligned} L_{rec} &= BCE(X, \hat{X}) = BCE(X, D(E(X))) \\ &= \sum_{i=1}^h \sum_{j=1}^w \sum_{c=1}^3 \left(-X_{ijc} \log(\hat{X}_{ijc}) - (1 - X_{ijc}) \log(1 - \hat{X}_{ijc}) \right) \end{aligned} \quad (2)$$

재생성 목적 함수는 여러 데이터 사이의 관계를 포함하지는 않으므로 비슷한 데이터라도 표상이 가깝다는 보장이 없다. 표상 공간에서 유사한 데이터 표상끼리 군집을 형성하도록 하려면 표상 간 거리에 대한 제약이 필요하며, 이를 위해 추가로 설정한 인코더 학습 목적 함수는 3.2 절에서 군집화와 함께 다룬다.

3.2. 가우시안 군집화와 노드 간 정보 전달

군집화는 군집에 대한 가정에 따라 결과가 다르게 나타난다. 이 연구에서는 실세계 데이터를 설명하는 데 적합하고 수학적 특성이 잘 알려져서 구현과 확장이 용이한 가우시안(Gaussian) 분포를 활용했다. 즉 물체 이미지의 표상 분포가 여러 가우시안 분포의 혼합으로 표현된다고 가정하고 각각의 군집이 가우시안 분포를 나타내도록 모델링한다. 군집은 다른 자기조직화 신경망에서와 마찬가지로 대푯값을 가지는 노드로 표현되며, 대푯값은 입력 표상 \mathbf{r} 과 같은 k 차원의 평균 벡터 $\boldsymbol{\mu}$ 와 각 차원 간의 공분산 행렬 $\boldsymbol{\Sigma}$ 로 이루어진다. 이때 표상의 서로 다른 차원끼리는 독립된 특성을 나타낸다고 가정하여 공분산을 0으로 하고 $\boldsymbol{\Sigma}$ 는 대각 원소만을 벡터로 나타낸 $\boldsymbol{\sigma}^2$ 로 대체한다. 노드가 나타내는 분포 $p(\cdot | \boldsymbol{\mu}, \boldsymbol{\sigma}^2)$ 는 k 차원 가우시안 $N(\boldsymbol{\mu}, \boldsymbol{\sigma}^2)$ 으로, 벡터 \mathbf{x} 에서의 확률 밀도는 수식 3과 같다. 이를 이용한 노드 생성과 조정은 ART 방식으로 이루어진다.

$$p(\mathbf{x} | \boldsymbol{\mu}, \boldsymbol{\sigma}^2) = (2\pi)^{-\frac{k}{2}} \left(\prod_{i=1}^k \sigma_i \right)^{-1} \exp \left(-\frac{1}{2} \sum_{i=1}^k \left(\frac{\mu_i - x_i}{\sigma_i} \right)^2 \right) \quad (3)$$

3.2.1. 개념 생성과 조정

학습 전 모델에는 노드가 전혀 없으며, 데이터 입력에 따라 노드가 생성 및 조정된다. 최초 데이터 표상이 입력되면 새로운 노드가 생성되는데 Gaussian ART에서처럼 평균은 입력 표상과 같은 벡터로, 분산은 모든 원소가 0.25인 벡터로 설정한다. 두 번째 입력부터는 기존에 있던 노드와의 적합도 및 일치도에 따라 승자 노드를 선택하고 업데이트한다. 적합도가 경계값 상수 ρ 이상인 노드는 입력에 적합하다고 보고 활성화(activate)한다. 활성 노드 중 일치도가 가장 높은 것이 승자 노드가 되며, 만일 모든 노드의 적합도가 경계값보다 낮다면 새로운 종류의 데이터가 입력된 것으로 보고 노드를 생성한다. 생성 시에는 최초 노드처럼 평균을 입력과 같게 하고 분산을 모든 원소가 0.25인 벡터로 한다. 최초 생성을 포함하여 노드가 생성될 때는 노드의 활성화도 a 를 1로 설정하고 이후 입력에 대해 노드가 승자로 선택될 때마다 활성화도를 1씩 높인다.

입력 표상 벡터가 \mathbf{r} 일 때 노드 하나의 대푯값 $(\boldsymbol{\mu}, \boldsymbol{\sigma}^2)$ 에 대한 적합도 $F(\mathbf{r}, \boldsymbol{\mu}, \boldsymbol{\sigma}^2)$ 는 노드가 대표하는 분포 $p(\cdot | \boldsymbol{\mu}, \boldsymbol{\sigma}^2)$ 에 따른 \mathbf{r} 의 우도(likelihood)를 이용하여 정의한다. 일치도 $C(\mathbf{r}, \boldsymbol{\mu}, \boldsymbol{\sigma}^2)$ 는 $p(\cdot | \boldsymbol{\mu}, \boldsymbol{\sigma}^2)$ 에 따른 \mathbf{r} 의 사후 확률(posterior probability)에 비례한다. 사후 확률을 정확하게 계산하려면 대푯값과 표상의 선형 확률(prior probability)이 필요하다. 대푯값 선형 확률은 해당 노드가 전체 노드 중 차지하는 비중, 즉 활성화도 a 로 표현할 수 있다. 표상 선형 확률은 모든 노드에 대해 같으므로 일치도를 비교할 때는 무시할 수 있다. 가우시안 분포 식을 사용한 적합도와 일치도는 수식 4와 같이 계산된다.

$$F(\mathbf{r}, \boldsymbol{\mu}, \boldsymbol{\sigma}^2) = (2\pi)^{\frac{k}{2}} \left(\prod_{i=1}^k \sigma_i \right) p(\mathbf{r} | \boldsymbol{\mu}, \boldsymbol{\sigma}^2) = \exp \left(-\frac{1}{2} \sum_{i=1}^k \left(\frac{\mu_i - r_i}{\sigma_i} \right)^2 \right) \quad (4)$$

$$C(\mathbf{r}, \boldsymbol{\mu}, \boldsymbol{\sigma}^2) = (2\pi)^{\frac{k}{2}} p(\boldsymbol{\mu}, \boldsymbol{\sigma}^2 | \mathbf{r}) p(\mathbf{r}) = a \left(\prod_{i=1}^k \sigma_i \right)^{-1} F(\mathbf{r}, \boldsymbol{\mu}, \boldsymbol{\sigma}^2)$$

입력에 대해 기존 노드가 승자가 된다면 활성화도를 높이는 것 외에도 해당 노드의 대푯값을 조정하여 입력을 더 잘 표현하도록 한다. 증가한

활성도 $a^{(new)}$ 는 원래 활성도 a 에 1을 더한 값이고, 대푯값인 평균과 분산 업데이트는 표본 평균과 분산 업데이트를 따른다. 평균과 분산의 d 번째 원소에 대한 업데이트는 다음 수식과 같다.

$$\begin{aligned}\mu_d^{(new)} &= \frac{a\mu_d + r_d}{a^{(new)}} \\ (\sigma_d^{(new)})^2 &= \frac{a\sigma_d^2 + (\mu_d^{(new)} - r_d)^2}{a^{(new)}}\end{aligned}\quad (5)$$

데이터와 함께 표지가 입력된다면 이는 노드에 분포 형태로 축적된다. 편의상 표지는 1 이상의 정수이고 모델이 접하는 표지는 중복을 제외했을 때 1부터 차례로 증가한다고 가정한다. 각 노드는 표지 분포 벡터 \mathbf{q} 를 가지며, \mathbf{q} 의 차원은 현재까지 모델에 입력된 표지 종류 수와 같도록 계속 증가한다. 단, 준지도 학습 상황에서 첫 표지가 입력되기 전까지는 모든 노드의 표지 분포를 원소가 없는 벡터(null)로 설정한다. 모델이 학습의 특정 시점까지 입력받은 표지가 m 개였을 때, 새로운 표지인 $m+1$ 이 입력되면 모든 노드의 표지 분포에 새로운 차원을 추가하고 그 값을 0으로 한다. 즉 원래 표지 분포가 $\mathbf{q}=(q_1, \dots, q_m)$ 이었다면 새로운 표지 입력 후의 분포는 $\mathbf{q}^{(new)}=(q_1, \dots, q_m, 0)$ 이 된다. 입력에 대해 승자 노드가 존재할 때, 표지 y 와 함께 입력되었다면 승자 노드의 표지 분포 중 그 표지에 해당하는 원소 q_y 를 1 증가시킨다. 표지가 없었다면 표지 분포는 그대로 둔다. 적합한 노드가 없어서 새로운 노드가 생성된다면 우선 표지 분포를 m 차원 영벡터로 설정하고, 표지가 입력되었을 때만 그에 해당하는 원소를 1로 한다. 표지 분포는 합이 1이 아닐 수 있으므로 확률 분포는 아니지만, 노드가 나타내는 데이터의 표지가 무엇인지 판단하는 척도로 사용할 수 있다.

3.2.2. 군집 특성을 활용한 인코더 학습

생성과 조정을 통해 형성된 노드는 비슷한 표상을 군집화하기는 하지만 군집에 대한 제약이 없기 때문에 학습이 지속되면 적은 수의 군집

이 너무 넓은 표상 공간에 걸치게 되거나, 반대로 입력 개수에 비해 너무 많은 군집이 생성되어 사실상 대표성을 잃어버리게 될 수 있다. CARLSON에서는 이를 방지하기 위해 군집의 형태에 대한 목적 함수를 설정하고 이를 최소화하도록 했다. 자기조직화 신경망만으로는 표상 자체를 조정할 수 없으므로 ARLET에서와 같이 인코더를 업데이트하는 방식을 취한다(Choi, Hwang, and Zhang 2020). 우선 군집이 적절한 크기를 유지하면서도 여러 표상을 포함하게 하도록 노드가 나타내는 가우시안 분포 $N(\boldsymbol{\mu}, \boldsymbol{\sigma}^2)$ 를 원소 간 독립인 표준정규분포 $N(\mathbf{0}, \mathbf{1})$ 에 가깝게 했다. 발산 학습 목적 함수 L_{div} 를 두 분포 사이의 Kullback-Leibler 발산(KLD)으로 설정하여 데이터가 전체적으로 비슷한 위치로 표상화되면서 각 군집의 분산이 너무 커지거나 작아지지 않도록 했다.

$$L_{div} = KLD(N(\boldsymbol{\mu}, \boldsymbol{\sigma}^2) \| N(\mathbf{0}, \mathbf{1})) = -\frac{1}{2} \sum_{i=1}^k (1 + \log(\sigma_i^2) - \mu_i^2 - \sigma_i^2) \quad (6)$$

군집 크기와 위치에 대한 제약 외에도, 하나의 군집에 범주가 같은 표상끼리만 모이도록 유도하는 수단이 필요하다. 이를 위해 ARLET과 같은 군집 간 목적 함수 L_{inter} 와 군집 내 목적 함수 L_{intra} 를 설정하여 인코더를 훈련한다. 입력 표상 \mathbf{r} 에 의해 활성화된 노드 집합을 $A(\mathbf{r})$ 이라 했을 때 L_{inter} 는 $A(\mathbf{r})$ 에 속하는 노드 간의 범주 동일성과 거리에 따라 정의된다. 노드 i 와 j 의 범주 동일성은 표지 분포 \mathbf{q}_i 와 \mathbf{q}_j 의 유사도로 판단하는데, 각 표지 분포를 원소 합으로 나누어 표지 확률 분포 P_i, P_j 로 정규화한 후 이들의 Jensen-Shannon 발산(JSD)을 계산하여 구한다. 발산 값이 상수 θ_{inter} 보다 작다면 두 노드는 같은 범주의 데이터를 대표하는 것으로 간주하여 범주 동일성 $S(i, j)$ 을 +1로 하고, 그렇지 않다면 -1로 설정한다. 다만 표지가 입력된 적이 없어서 두 표지 분포 모두 빈 벡터(null)이거나 둘 중 하나라도 영벡터라면 정규화가 불가하므로 $S(i, j)$ 을 0으로 정의한다. 현재까지 m 개의 표지가 입력되었을 때 빈 벡터나 영벡터가 아닌 표지 분포를 가지는 두 노드 i 와 j 의 범주 동일성 $S(i, j)$ 는 다음 수식으로 계산할 수 있다.

$$JSD(P_i \| P_j) = \sum_{y=1}^m \frac{1}{2} \left\{ P_{i,y} \log \left(\frac{P_{i,y}}{P_{j,y}} \right) + P_{j,y} \log \left(\frac{P_{j,y}}{P_{i,y}} \right) \right\} \quad (7)$$

$$S(i,j) = \begin{cases} +1 & \text{if } JSD(P_i \| P_j) < \theta_{inter} \\ -1 & \text{o.w.} \end{cases} \quad (8)$$

노드 대푯값 거리는 평균 μ_i 과 μ_j 의 L2 거리로 정의하며, 두 노드의 범주가 동일할 때는 이를 최소화하고 다를 때는 최대화하도록 노드 간 목적 함수를 설정한다. 목적 함수를 거리 자체 혹은 그 역수로 두면 목적 함수 최소화를 통해 거리 조정을 유도할 수 있으며, 이에 따라 정의된 L_{inter} 는 다음과 같다. 수식에서 $A(\mathbf{r})^2$ 은 $A(\mathbf{r})$ 의 원소 쌍 집합이다.

$$L_{inter} = \sum_{(i,j) \in A(\mathbf{r})^2} S(i,j) \cdot \|\mu_i - \mu_j\|_2 \quad (9)$$

다른 목적 함수인 군집 내 목적 함수는 하나의 노드에 되도록 하나의 범주의 물체 표상만 포함되도록 하는 역할을 한다. 노드가 대표하는 범주의 다양성은 표지 분포의 엔트로피(entropy)를 이용하여 정의하는데, 이때 수식 7에서처럼 정규화한 확률 분포를 사용한다. 노드 i 의 범주 다양성 $U(i)$ 은 엔트로피 $H(P_i)$ 가 상수 θ_{intra} 보다 크면 +1, 작으면 -1로 정의된다. 노드 간 범주 동일성과 마찬가지로 표지 분포가 빈 벡터 혹은 영벡터라면 범주 다양성은 0으로 정의한다.

$$H(P_i) = \sum_{y=1}^m -P_{i,y} \log(P_{i,y}) \quad (10)$$

$$U(i) = \begin{cases} +1 & \text{if } H(P_i) > \theta_{intra} \\ -1 & \text{o.w.} \end{cases} \quad (11)$$

노드 범주 다양성이 클 때는 분산을 키움으로써 그 노드에 속했던 데이터가 다음 군집화 시에 여러 군집으로 분할될 수 있도록 한다. 반대로 노드에 한 범주의 데이터만 속할 때는 분산을 줄여서 다른 군집과 확실하게 분리되도록 유도한다. 군집 내 목적 함수 L_{intra} 역시 노드 분산

의 크기 자체를 이용하여 정의할 수 있으며, 범주 다양성에 의해 부호를 결정하고 합친 형태로 다음 수식과 같이 나타난다.

$$L_{intra} = \sum_{i \in A(\mathbf{r})} -U(i) \cdot \|\sigma_i\|_2^2 \quad (12)$$

상기한 세 목적 함수 L_{div} , L_{inter} , L_{intra} 와 수식 6에서 정의한 재생성 목적 함수 L_{rec} 까지 모두 고려한 인코더의 최종 학습 목적 함수 L 은 수식 13으로 계산된다. λ_{inter} 와 λ_{intra} 는 L_{inter} 와 L_{intra} 의 상대적 중요도를 결정하는 상수이다.

$$L = L_{rec} + L_{div} + \lambda_{inter} L_{inter} + \lambda_{intra} L_{intra} \quad (13)$$

L 의 첫 번째와 두 번째 항은 널리 사용되는 생성 모델인 변분 오토 인코더(Variational Autoencoder, VAE; Kingma and Welling 2014)의 목적 함수와 일맥상통한다. VAE는 데이터 표상을 평균과 분산으로 나누어 인코딩하고, 데이터의 주변 우도(marginal likelihood)을 최대화하는 과정에서 변분 추론(variational inference)을 통해 결과적으로 재생성 목적 함수 및 발산 목적 함수를 최소화하게 된다. 따라서 CARLSON은 균집화가 잘 되도록 VAE를 확장한 형태로도 볼 수 있다.

3.2.3. 노드 간 표지 정보 전파

학습 시 주어지는 소수의 표지를 충분히 활용하려면 표지를 입력받지 못한 노드에도 정보를 전달해야 한다. 이를 위해서 LPART나 ARLET에서처럼 활성화된 노드 간에 표지 분포를 일정 비율에 따라 전파하는 표지 전파(label propagation) 방식을 사용한다. 구체적인 기법은 LPART에서 제안한 방법(Kim, Hwang, Kang et al. 2020)을 따른다.

표지 전파는 표상이 입력되었을 때 승자 노드에 대한 대푯값과 표지 분포를 업데이트한 직후 수행한다. 활성화된 노드 중 표지 정보가 부족한 것이 전파를 받는 대상이 되며, 해당 노드가 다수라면 순차적으로 전파를 수행한다. 표지 정보량을 표지 분포 \mathbf{q} 의 원소 합 $sum(\mathbf{q})$ 으로 정의하고 이 값이 1보다 작을 때 전파 대상으로 선정하여, 표지가 있는 데이

터에 대해 한 번도 승자로 선택되지 않은 노드가 표지를 전파받도록 했다. 입력 표상 \mathbf{r} 에 대해 이러한 조건을 만족하는 노드의 집합을 $B(\mathbf{r})$ 이라고 하면 $B(\mathbf{r}) = \{i \mid i \in A(\mathbf{r}) \wedge \text{sum}(\mathbf{q}_i) < 1\}$ 이 된다. $B(\mathbf{r})$ 에 속한 노드 i 의 새로운 표지 분포 $\mathbf{q}_i^{(new)}$ 는 원래 값 \mathbf{q}_i 와 $A(\mathbf{r})$ 소속 노드들의 표지 분포 평균값을 전파율 δ 로 가중 평균하여 구하는데, 전파 후에도 정보량을 1보다 작게 유지하기 위해 전체를 표지 종류 수 m 으로 나눈다. 노드의 표지 분포에 대한 업데이트는 다음 수식과 같다.

$$\mathbf{q}_i^{(new)} = \left(\delta \times \frac{\sum_{j \in A(\mathbf{r}) - \{i\}} \mathbf{q}_j}{\sum_{j \in A(\mathbf{r}) - \{i\}} \text{sum}(\mathbf{q}_j)} + (1 - \delta) \times \frac{\mathbf{q}_i}{\text{sum}(\mathbf{q}_i)} \right) \times \frac{1}{m} \quad (14)$$

3.3. 데이터 생성을 통한 능동 학습

CARLSON이 학습할 때 다양한 표지를 입력받았다면 표지 전파를 통해서 충분한 정보를 전달할 수 있다. 그러나 특정 표지를 전혀 학습하지 못했거나 절대적인 개수가 부족한 경우에는 신뢰도가 낮은 결과가 나올 수밖에 없다. 로봇 학습에서는 학습 데이터에 대한 정답 표지를 사용자에게 물어볼 기회가 있으므로 이 같은 문제를 어느 정도 극복할 수 있다. CARLSON은 일정 주기 τ 마다 유용성이 가장 높은 데이터의 표지를 사람에게 능동적으로 질의한다.

질의를 위한 데이터는 현재까지 학습을 위해 사용한 데이터 가운데서 선택하는 것이 가장 직관적이다. 그러나 로봇이 획득하는 데이터는 시간에 따라 끝없이 축적되므로 하나의 단말에 모두 저장하기 어려울 수 있으며, 어떤 데이터가 중요할지는 학습 상태에 따라 변하므로 선택적 저장도 쉽지 않다. 또한, 사용자와 상호 작용하면서 서비스를 제공하는 로봇의 특성상 개인 정보 보호를 위해 데이터 저장이 불가할 수도 있다. 입력 데이터를 저장하지 않고도 질의 데이터를 얻기 위해서는 디코더를 이용한 생성이 필수적이다. 생성에 사용할 표상은 현재까지 형성된 개념 중 가장 불확실한 것에서 추출하며, 이를 통해 표지를 학습한 후에 전체적인 개념 불확실도가 가장 많이 감소할 수 있도록 했다. 개념 불확실도

는 수식 10에서 구한 노드의 표지 분포 엔트로피 $H(P)$ 로 정의하며, 표상 추출을 위한 노드 j_{query} 는 전체 노드 중에서 엔트로피가 가장 큰 것으로 선택한다. 선택된 노드에서는 평균과 분산에 따라 표상 \mathbf{s}_{query} 를 가우시안 표본 추출한다.

$$j_{query} = \operatorname{argmax}_i H(P_i), \quad \mathbf{s}_{query} \sim N(\boldsymbol{\mu}_{j_{query}}, \sigma_{j_{query}}^2) \quad (15)$$

\mathbf{s}_{query} 는 디코더를 통해 입력 데이터와 같은 차원의 데이터로 재생성되고, 모델은 그 데이터의 표지를 사용자에게 질의한다. 질의를 통해 표지 y_{query} 를 얻으면 이를 j_{query} 의 표지 분포에 더한다. 데이터 표지 획득 과정을 Q 로 나타내면 능동 학습은 수식 16으로 나타낼 수 있다.

$$y_{query} = Q(D(\mathbf{s}_{query})), \quad q_{j_{query}, y_{query}}^{(new)} = q_{j_{query}, y_{query}} + 1 \quad (16)$$

3.4. CARLSON 학습 및 추론

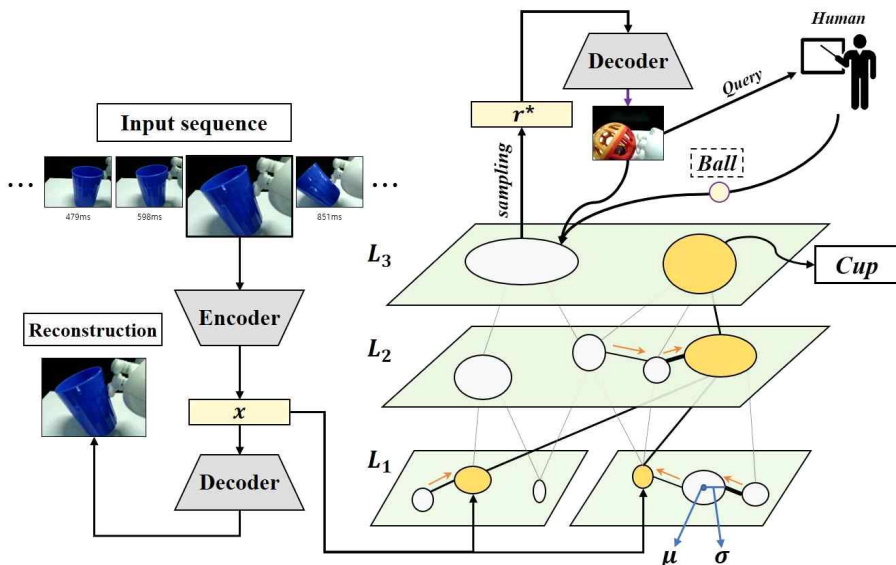
CARLSON 학습은 수식 13에서 계산한 목적 함수 L 을 최소화하는 방향으로 이루어지며, 노드의 평균을 구하는 과정에서 축적된 표상을 이용하여 목적 함수의 미분 값을 구하고 인코더와 디코더의 파라미터를 업데이트한다. 인코더와 디코더 업데이트는 군집화와 표지 전과 후에 수행하여 다음 입력 데이터부터는 갱신된 인코더로 표상화된다. CARLSON의 전체 학습 절차는 알고리즘 1과 같다. 학습을 마친 모델로 새로운 데이터의 표지를 추론할 때는 학습 시와 마찬가지로 데이터를 인코딩한 후에 승자 노드를 찾는데, 이때는 활성화된 노드가 없다면 전체 노드 중 일치도가 가장 높은 노드를 승자로 간주한다. 승자 노드의 표지 분포에서 가장 큰 값을 가지는 표지를 추론 결과로 하며, 만일 해당 표지 분포가 빈 벡터나 영벡터이면 모델이 접했던 표지 중 하나를 임의로 출력한다. 추론 대상 데이터가 다수라면 이들을 배치(batch)로 취급하여 인코딩하고 승자 노드 탐색에서 공통된 부분을 한 번에 계산하는 방식으로 효율적인 추론을 할 수 있다.

[알고리즘 1] 지속적 능동 학습 자기조직화 신경망(CARLSON).

- 1: 노드 집합 $N \leftarrow \phi$ 및 번호 $n \leftarrow 0$, 표지 종류 $m \leftarrow 0$.
 - 2: 시간 $t \leftarrow 0$.
 - 3: 각 입력 (X, y) 에 대해 명령 4~30 수행. // 빈 표지: 0
 - 4: $t \leftarrow t + 1$.
 - 5: $y > m$ 이면 $m \leftarrow m + 1$, N 의 각 노드 \mathbf{q} 차원 1 증가.
 - 6: 표상 $\mathbf{r} \leftarrow E(X)$. // E : 인코더
 - 7: 재생성 목적 함수 $L_{rec} \leftarrow BCE(X, D(\mathbf{r}))$. // D : 디코더
 - 8: N 의 각 노드에 대해 적합도 $F(\mathbf{r}, \boldsymbol{\mu}, \boldsymbol{\sigma}^2)$ 계산. // 수식 4
 - 9: 활성 노드 집합 $A(\mathbf{r}) \leftarrow \{i \mid i \in N \wedge F(\mathbf{r}, \boldsymbol{\mu}_i, \boldsymbol{\sigma}_i^2) \geq \rho\}$. // ρ : 경계값
 - 10: $A(\mathbf{r}) = \phi$ 이면 명령 11~15 수행:
 - 11: $n \leftarrow n + 1$, 새로운 노드 $i = n$ 을 N 에 추가.
 - 12: $\mu_{i,k} \leftarrow r_k$, $\sigma_{i,k}^2 \leftarrow 0.25$ ($k = 1, \dots, \dim(\mathbf{r})$), $a_i \leftarrow 1$.
 - 13: y 에 따라 \mathbf{q}_i 설정. // 3.2.1절
 - 14: 발산 목적 함수 L_{div} 계산. // 수식 6
 - 15: $L_{inter} \leftarrow 0$, $L_{intra} \leftarrow 0$.
 - 16: 그 외에는 명령 17~25 수행:
 - 17: $A(\mathbf{r})$ 의 각 노드에 대해 일치도 $C(\mathbf{r}, \boldsymbol{\mu}, \boldsymbol{\sigma}^2)$ 계산. // 수식 4
 - 18: 승자 노드 $w \leftarrow \operatorname{argmax}_{i \in A(\mathbf{r})} C(\mathbf{r}, \boldsymbol{\mu}_i, \boldsymbol{\sigma}_i^2)$.
 - 19: $\boldsymbol{\mu}_w$ 와 $\boldsymbol{\sigma}_w^2$ 을 업데이트, $a_w \leftarrow a_w + 1$. // 수식 7
 - 20: $y > 0$ 이면 $q_{w,y} \leftarrow q_{w,y} + 1$.
 - 21: $B(\mathbf{r}) \leftarrow \{i \mid i \in A(\mathbf{r}) \wedge \operatorname{sum}(\mathbf{q}_i) < 1\}$.
 - 22: $B(\mathbf{r})$ 의 각 노드에 대해 표지 전파 수행. // 수식 14
 - 23: 발산 목적 함수 L_{div} 계산. // 수식 6
 - 24: 노드 간 목적 함수 L_{inter} 계산. // 수식 9
 - 25: 노드 내 목적 함수 L_{intra} 계산. // 수식 12
 - 26: 최종 목적 함수 L 계산 및 최적화(모델 업데이트). // 수식 13
 - 27: $t \% \tau = 0$ 이면 명령 28~30을 수행:
 - 28: N 의 각 노드에 대한 표지 엔트로피 $H(P)$ 계산. // 수식 10
 - 29: $j \leftarrow \operatorname{argmax}_i H(P_i)$, 표상 $\mathbf{s} \sim N(\boldsymbol{\mu}_j, \boldsymbol{\sigma}_j^2)$ 추출.
 - 30: $D(\mathbf{s})$ 의 표지를 질의한 결과로 \mathbf{q}_j 업데이트.
-

제 4장 일반화된 CARLSON 모델

CARLSON은 인코더와 자기조직화 신경망을 동시에 학습시킴으로써 개념을 나타내는 가우시안 노드를 생성하고 표상을 조정하여 변화하는 입력에 효과적으로 적응할 수 있다. 3장에서 다른 모델의 각 구성 요소는 가정을 완화하고 기능을 추가하는 방식으로 다양하게 확장될 수 있다. 이 장에서는 CARLSON의 개념 형성 과정과 능동 학습을 이론적으로 일반화한 모델을 제시하며, 이를 위한 명시적인 개념 조정, 계층적 표상화, 그리고 데이터 저장을 활용한 능동 학습 기법을 다룬다. 확장된 모델의 전체 구조는 그림 5에 나타나 있다.



[그림 6] 일반화된 CARLSON 구조도. 모델에 데이터가 입력되면 인코더를 이용하여 표상화하고 낮은 계층부터 차례로 군집화한다. 최종 계층에서는 추론과 능동적 질의가 이루어진다.

4.1. 유기적 개념 형성

노드 활성 여부를 판단하는 경계값은 노드가 대표하는 개념의 포괄성 정도로 볼 수 있는데, 모델 학습이 이루어짐에 따라 개념이 지속적으로 변하는 것을 반영하여 시간에 따른 변수로 일반화할 수 있다. 시간 t 에 따른 적합도 경계값 $\rho(t)$ 는 t 와 음의 상관관계를 보이며, 이는 학습이 이루어지면서 개념이 점차 분화되어 노드가 작아지는 것에 기인한다. 초기 경계값을 ρ 로 하고 시간에 따라 지수적으로 감쇠하는 경계값 $\rho(t)$ 는 감쇠 정도를 결정하는 양의 상수 τ_ρ 를 이용하여 수식 17과 같이 나타낼 수 있으며, CARLSON은 τ_ρ 가 ∞ 인 것으로 볼 수 있다.

$$\rho(t) = \rho \cdot \exp(-t/\tau_\rho) \quad (\tau_\rho > 0) \quad (17)$$

CARLSON에서 입력에 따른 노드 업데이트는 동작의 효율상 승자 독식을 기본으로 했지만, 적합도와 일치도가 높은 다수의 노드를 업데이트하는 것도 가능하다. 적합도 F 와 일치도 C 에 대해 두 노드 i, j 에서의 값 차이(절댓값)를 수식 18와 같이 Δ_F 와 Δ_C 로 표기하고 이를 이용해 노드 업데이트를 기술할 수 있다.

$$\begin{aligned} \Delta_F(\mathbf{r}, i, j) &:= |F(\mathbf{r}, \boldsymbol{\mu}_i, \sigma_i^2) - F(\mathbf{r}, \boldsymbol{\mu}_j, \sigma_j^2)| \\ \Delta_C(\mathbf{r}, i, j) &:= |C(\mathbf{r}, \boldsymbol{\mu}_i, \sigma_i^2) - C(\mathbf{r}, \boldsymbol{\mu}_j, \sigma_j^2)| \end{aligned} \quad (18)$$

입력 \mathbf{r} 에 대해 활성화된 노드 i 의 활성화도 a_i 는 승자 노드 w 와의 적합도 및 일치도 차이에 따라 수식 19와 같이 바뀐다. 여기서 α_F 와 α_C 는 0 이상의 상수이며, CARLSON은 두 값을 모두 ∞ 로 설정한 것과 같다. 단, Δ_F 나 Δ_C 가 0이면 α_F 또는 α_C 를 곱한 결과도 0으로 한다. 활성화도 변화량을 Δa_i 로 표기하면 노드 평균과 분산 업데이트는 수식 20과 같다.

$$a_i^{(new)} = a_i + \Delta a_i = a_i + \exp(-\alpha_F \Delta_F(\mathbf{r}, w, i) - \alpha_C \Delta_C(\mathbf{r}, w, i)) \quad (19)$$

$$\mu_{i,d}^{(new)} = \frac{a_i \mu_{i,d} + \Delta a_i r_d}{a_i^{(new)}}, \quad (\sigma_{i,d}^{(new)})^2 = \frac{a_i \sigma_{i,d}^2 + \Delta a_i (\mu_{i,d}^{(new)} - r_d)^2}{a_i^{(new)}} \quad (20)$$

4.1.1. 명시적 개념 조정

CARLSON에서는 새로운 개념을 학습하더라도 기존 개념은 인코더 업데이트를 통해 간접적으로만 조정하는데, 이 과정은 더욱 명시적으로 바꿀 수 있다. 개념 조정은 새로 추가된 노드와 유사한 기존 노드들에서 표상을 표본 추출하여 다시 군집화하는 방식으로 이루어진다. 새 노드 i 와 기존 노드 j 의 노드 유사도는 j 를 기준으로 i 의 평균에 대한 적합도 $F(\mu_i, \mu_j, \sigma_j^2)$ 로 계산하는데, μ_i 가 입력 표상 \mathbf{r} 과 같으므로 노드 유사도는 입력에 대한 적합도 $F(\mathbf{r}, \mu_j, \sigma_j^2)$ 와 같다. 적합도가 시간에 따른 변수 $\xi(t)$ 이상이면 노드가 유사하다고 보고 표상을 추출한다. 데이터가 밀집한 부분에서 더 많은 표상을 추출하는 것이 자연스러우므로 노드 활성도가 높을수록 추출하는 표상의 수는 많아진다. 전체 표상의 수는 $v(t)$ 로 제한하며, 추출한 표상을 군집화하는 것은 모델이 새로운 입력을 받아 업데이트를 수행하는 것과 같은 방식으로 이루어진다.

4.1.2. 개념 병합 및 세분화

같은 입력에 대해 활성화된 노드 중 특히 비슷한 것들은 사실상 같은 개념을 대표하는 것으로 보고 합칠 수 있다. CARLSON에서는 노드 간 목적 함수를 최소화함으로써 노드 병합을 유도했는데, 개념 조정에서 처럼 표본 추출과 재군집화를 통해 이를 명시적으로 수행할 수 있다. 병합 여부는 노드 범주 동일성 S 로 판단할 수 있는데, 이때 S 의 값을 결정하는 기준은 시간에 따라 감소하는 변수 $\theta_{inter}(t)$ 로 설정한다. 두 노드의 동일성이 1이라면 두 노드에서 활성도에 따라 표상을 표본 추출하여 다시 군집화하는 방식으로 노드를 병합한다.

이와 반대로 하나의 노드가 둘 이상의 개념을 표현하는 것으로 판단될 때는 노드를 나눈다. 노드 병합과 마찬가지로 이 과정은 CARLSON에서 노드 내 목적 함수 최소화를 통해 간접적으로 이루어졌던 부분이다. 범주 다양성 U 가 1인 노드가 분할 대상이며, U 의 계산 기준은 시간에 따라 증가하는 $\theta_{intra}(t)$ 로 재정의하여 사용한다. 표지가 거의 입력되지

많은 노드는 표지 엔트로피 H 가 높아서 U 가 1이 될 가능성이 큰데, 이런 노드를 전부 분할하는 것은 비효율적이므로 표지 정보량 $sum(\mathbf{q})$ 가 상수 ζ 보다 큰 노드만 분할 대상으로 한다. 노드 분할 역시 표본 추출한 표상을 다시 군집화하는 방식으로 이루어진다.

4.2. 계층적 표상화

자기조직화 신경망은 일반적으로 하나의 표상 공간에 모든 노드를 배치하고 표상을 여기에 맞도록 군집화한다. 이 과정을 거쳐 공통된 특성을 가지는 데이터들이 하나의 군집으로 축약되기는 하나, 데이터 각각의 고유한 속성이 군집화에 여전히 많은 영향을 미칠 수 있다. 예를 들어 로봇이 한 색깔의 물체 여러 개를 관측하고 이에 대한 대표적인 표상을 만들어 냈다고 할 때, 같은 종류지만 색깔이 다른 물체를 보게 되면 색깔의 차이로 인해서 다른 군집으로 분류할 수도 있다. 즉 같은 종류의 물체도 세부 속성에 따라 여러 군집으로 나뉠 수 있으며, 이는 공통된 하나의 개념을 학습한 결과라고 보기는 어렵다. 역으로, 일부 속성을 무시한 채 물체 표상을 하나의 군집으로 모으면 여러 물체 개념이 섞여서 과하게 일반화되는 경향이 나타날 수 있다. 이런 문제를 해결하는 데는 단계적으로 여러 속성을 추출하여 군집화하고 다시 이 속성들의 조합으로 상위 군집을 만들어 내는 계층적 표상화를 사용할 수 있다.

계층적 표상화에서는 딥러닝과 마찬가지로 입력부에 가까운 하위 표상 공간은 단순한 속성을 포착하고 층을 거듭할수록 고차원적인 개념을 형성하게 된다. 표상 계층은 이론적으로 얼마든지 많이 만들 수 있으나, 계층이 많아질수록 업데이트 시간이 오래 소요되고 여러 계층에서 중복된 정보가 추출될 가능성이 커진다. 따라서 계층의 수는 데이터 복잡도에 따라 적절히 조절해야 하며, 필요에 따라 CARLSON처럼 하나만으론 하는 것도 가능하다. 하위 계층에서는 표상의 일부 원소만 이용하여 군집화하며, 상위로 갈수록 더 많은 원소를 고려하도록 한다. 상위 계층의 노드는 하위 계층의 노드보다 일반화되어 있으므로 더 많은 표상을 포함할 수 있도록 적합도 경계값을 포함한 기준 상수들을 조정한다.

계층 l 에서 군집화에 사용하는 표상 원소는 표상과 같은 k 차원의 이진 벡터 \mathbf{m}_l 로 나타낼 수 있는데, $m_{l,d}$ 는 표상의 d 번째 원소를 사용한다면 1로, 아니라면 0으로 설정한다. 적합도와 일치도 등을 계산할 때 표상과 노드 대푯값에 \mathbf{m}_l 을 원소 단위로 곱한 형태로 사용하여 $m_{l,d}$ 가 0인 원소들이 군집화에 영향을 주지 않도록 한다. 단, 대푯값 업데이트 시에는 표상의 모든 원소를 사용한다. 상위 계층 $l+1$ 에서 군집화할 때는 하위 계층 l 에서 사용한 원소 전부를 고려하고 추가 원소도 사용할 수 있다. 즉 \mathbf{m}_{l+1} 은 \mathbf{m}_l 에서 0인 일부 원소를 1로 변경한 것과 같다. 최종 계층에서는 모든 원소를 고려하므로 \mathbf{m} 은 모든 원소가 1인 벡터가 된다. 개념 생성은 하위 계층부터 차례대로 이루어지며, 첫 계층에서는 입력 표상을 그대로 사용하고 두 번째 계층부터는 직전 계층에서 형성된 노드 대푯값을 입력으로 삼아 군집화한다. 이러한 계층적 표상화는 단일 계층 표상화보다 입력 잡음에 더 강건하게 동작한다는 장점이 있다.

4.3. 능동적 데이터 질의

미표지된 데이터가 입력될 때 즉각적 질의를 통해 정답을 알게 된다면 불확실한 정보에 의한 오류가 누적될 위험이 적다. 사람과 실시간으로 상호 작용하면서 물체 개념을 학습하는 상황에는 이런 형태의 질의가 가능한데, 사람이 데이터 표지를 유추하고 답하는 데도 상당한 시간이 걸린다는 점을 고려하여 중요도가 높은 데이터의 표지만 물어본다. 데이터 중요도는 승자 노드의 표지 엔트로피 H 로 정의하고 이 값이 시간에 따른 변수 $l(t)$ 이상인 데이터를 질의 대상으로 선정한다. 표지는 $T(t)$ 시간 간격으로 사람에게 물어보는데, 질문 주기 $T(t)$ 는 학습 초기에 짧게 하여 초기 개념을 확실하게 정립하도록 하고 학습이 이루어짐에 따라 점차 늘려서 로봇을 가르치는 사람의 부담을 줄이도록 한다. 즉각적인 질의는 항상 가능한 것이 아니므로 질의가 불가능할 때는 중요 데이터를 저장해두었다가 가능할 때 물어보는 방식도 적용할 수 있다.

데이터 저장 방식은 즉각적 질의와 같은 기준으로 데이터를 선택하지만 이를 비지도로 우선 학습하고 별도 메모리에 저장해둔다. 사람에게

질의할 수 있는 때가 되면 모아 두었던 데이터 표지를 한꺼번에 물어본다. 학습에 따라 모델이 변하면 데이터 중요도 판단 기준이 달라지므로 예전에 저장했던 데이터가 중요하지 않게 될 수도 있으며, 따라서 저장 시점과 질의 시점이 멀수록 능동 학습의 효율이 낮아진다. 질의하는 데이터 개수도 일정 범위로 제한해야 하므로 유한한 큐(queue) 구조의 메모리를 사용하여 오래된 데이터를 삭제하도록 한다.

CARLSON에서 사용했던 데이터 생성 방식은 표상 추출을 위한 노드 선택에 더 많은 요소를 고려하는 방향으로 일반화할 수 있다. 학습 초기에는 개념의 세분화가 잘 이루어지지 않으므로 표지 엔트로피가 높으면서 다른 노드와 가까운 노드를 선택하는 것이 유용하지만, 학습이 어느 정도 진행되면 이미 일부 개념에 대해서는 익숙한 상태이므로 기존 지식과 확연히 다른, 즉 다른 노드로부터의 거리가 먼 노드에 관한 정보를 얻는 것이 효과적이다. 표상을 추출할 노드는 중요도 I 가 가장 높은 것으로 결정하며, I 는 활성화도 a 와 표지 엔트로피 H , 주변 노드와의 유사도 F 및 시간 t 의 조합으로 수식 21과 같이 정의된다. 수식에서 τ_u 는 시간 상수이고 η_1 과 η_2 는 각 요소의 기여도를 조절하는 상수이며, CARLSON은 τ_u, η_1, η_2 가 모두 0인 모델이다.

$$I(i) = H(P_i) \frac{1 + \eta_1 a_i}{\exp(\eta_2 (t - \tau_u) \sum_{j \neq i} F(\boldsymbol{\mu}_i, \boldsymbol{\mu}_j, \sigma_j^2)^2)} \quad (21)$$

선택된 노드에서는 가우시안 표본 추출을 통해 표상을 구하고 이를 디코딩하여 질의 데이터를 얻는다. 생성된 데이터는 질의 시점에 모델에 가장 유용하기는 하나, 생성 결과가 실세계 입력과 달라서 적당한 표지를 찾기가 힘들 우려가 있다. 따라서 상황에 따라 즉각적 질의, 데이터 저장 방식, 데이터 생성 방식을 복합적으로 사용하여 안정적으로 능동 학습할 수 있도록 한다.

제 5장

시각 객체 인식 실험

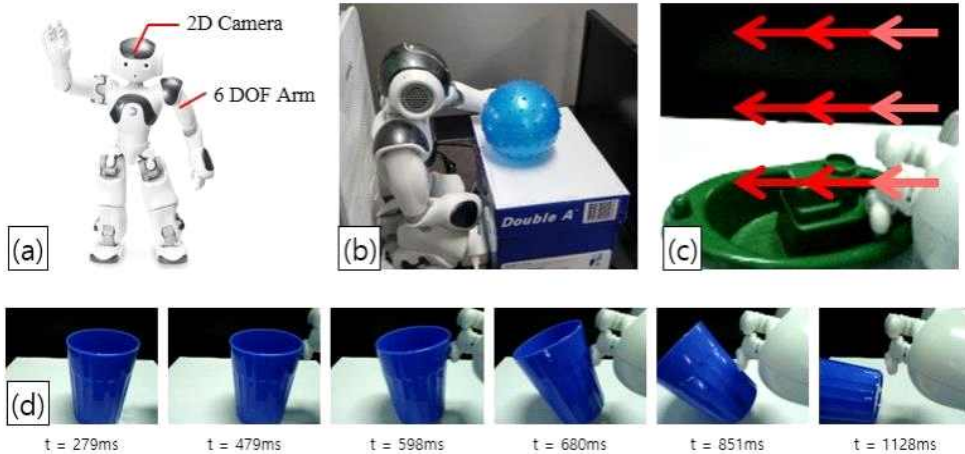
CARLSON의 학습 성능을 확인하기 위하여 실제 로봇이 관측한 시각 객체를 분류하는 실험을 진행했다. 데이터는 휴머노이드 로봇인 NAO를 이용하여 수집한 연속적인 물체 이미지로, 로봇이 실사용 환경에서 동작하는 상황을 모사하고자 모델이 데이터와 표지를 제한적으로 받도록 했다. 로봇 데이터 외의 데이터셋에서도 학습과 추론을 통해 분류 정확도를 측정함으로써 모델의 범용성을 확인했다.

5.1. 시각 객체 데이터셋

5.1.1. 로봇을 이용한 데이터 수집

실험에 이용한 NAO는 57cm 정도 높이로 사지를 가지고 있으며, 머리에 초당 최대 20장 속도로 촬영이 가능한 2D 카메라가 상하로 있고 음성 입력부, 출력부 및 촉각 센서가 탑재돼 있다(Gouaillier et al. 2009; 그림 7a). 목 관절은 좌우와 상하로 움직일 수 있고 양팔은 어깨, 팔꿈치, 손을 포함해 팔마다 자유도 6으로 움직일 수 있으며, 각 관절의 각도는 0.0015라디안(radian) 단위로 조정된다. NAO는 이동이나 물체 조작보다는 감정 표현과 대화 같은 상호 작용에 특화된 로봇이지만, 짧은 거리를 이동하거나 가벼운 물체를 옮기는 동작 등은 가능하다.

데이터 수집 시에는 NAO가 팔로 물체를 밀면서 카메라로 그 변화를 관측하도록 했으며, 연속적으로 입력되는 이미지와 센서로 측정한 팔의 각도 및 수집 시간을 기록했다. 물체는 NAO가 안전하게 밀 수 있도록 적당한 크기와 질량을 가진 장난감들로 선정했으며 형태와 색상을 다양하게 했다. NAO는 왼팔이나 오른팔로 물체를 미는데, 팔은 정해진 세 가지 중 하나의 위치에서 시작하여 높이를 유지한 채 몸체 바깥에서 안



[그림 7] NAO를 이용한 데이터 수집 환경. (a) NAO 로봇의 모습 (b) 물체 조작 실험 환경 (c) 3가지 팔 높이와 3가지 속도로 구성된 물체 조작 행동 도식화 (d) 시간에 따른 연속적 데이터 예시.

[표 1] NAO로 수집한 데이터 명세. 총 18,084건의 데이터를 수집했으며 후처리를 통해 7,864건을 선택하여 실험에 사용했다.

분류	이름	명세	유형 (값 범위)
데이터	이미지	20가지 물체 RGB 이미지	120×160×3 실수 행렬 (0.0~1.0)
정답 표지	물체 형태	8가지 물체 형태(Ball, Boat, Bus, Cup, Shoe, Car, Rattle, Dice) 중 하나	정수(0~7)
	물체 색상	5가지 물체 색상(Red, Green, Blue, Yellow, Purple) 중 하나	정수(0~4)
메타 데이터	행동 ID	3가지 팔 높이(-0.35, -0.1, 0.15)와 3가지 팔 속도(0.03, 0.06, 0.1)의 조합 중 하나	정수(0~8)
	팔 ID	오른팔(0) 혹은 왼팔(1) 중 하나	정수(0~1)
	시간	이미지 획득 시 행동 시작으로부터 소요된 시간(ms)	정수(0 이상)
	머리 각도	머리의 좌우(HeadYaw) 및 상하(HeadPitch) 각도 센서 측정치(radian)	2×1 실수 벡터 (-2.0~2.0)
	팔 각도	움직이는 팔의 6개 관절(ShoulderPitch, ShoulderRoll, ElbowYaw, ElbowRoll, WristYaw, Hand)에 대한 각도 센서 측정치(radian)	6×1 실수 벡터 (-2.0~2.0)

쪽으로 움직인다. 팔의 속력은 모터 최대 속력의 0.03배, 0.06배 혹은 0.1 배 중 하나로 설정하여 물체 하나당 총 18가지의 밀기 시행을 통해 데이터를 모았다. 팔을 움직이면서 NAO의 상부 카메라를 사용하여 QQVGA 규격(가로 160픽셀, 세로 120픽셀)으로 초당 최대 10프레임의 RGB 형태의 컬러 이미지를 수집했으며, 밀기 시행 한 번에 수집된 이미지 개수는 18장에서 90장까지였으나 데이터 균형을 위해 시행마다 최대 30장을 선택하여 학습과 추론에 사용했다. 선택된 이미지의 총 개수는 7,864장이고 그중 5,327장을 학습 데이터로 사용했다. 각각의 이미지에 대해서 물체 범주와 색깔은 수동으로 표지했다. 데이터를 수집한 환경과 물체 데이터 예시는 그림 7에 나타나 있으며, 전체 물체 목록을 비롯한 데이터 명세는 표 1과 같다. 수집한 데이터셋은 NAO 데이터셋으로 명명한다.

5.1.2. 숫자 및 물체 인식 데이터셋

시각 객체 분류는 머신러닝 분야에서 오랜 기간 연구된 주제이며, 이와 관련해 개발된 모델의 성능을 평가하기 위한 데이터셋도 다수 공개되어 있다. 대표적으로 숫자 분류 데이터셋 MNIST (LeCun, Cortes, and Burges 2010) 및 SVHN (Netzer et al. 2011), 의상 분류 데이터셋 Fashion-MNIST (Xiao, Rasul, and Vollgraf 2017), 사물 인식 데이터셋 CIFAR-10 (Krizhevsky and Hinton 2009) 등이 있다. 상기 데이터셋은 하나의 물체에 대한 이미지를 연속적으로 수집한 NAO 데이터셋과 달리 범주에 따른 데이터 유사성이 없다. 따라서 로봇 학습 조건에 부합하지는 않지만 여러 연구에서의 실험을 통해 유효성이 검증되었다고 볼 수 있으므로 적절한 제약하에서 분류 실험을 진행했다.

5.2. 온라인 준지도 학습 실험

5.2.1. 모델 구현 상세

CARLSON의 인코더는 네 개의 2차원 합성곱 층으로 이루어져 있으며, 각 층의 출력은 배치 정규화(Ioffe and Szegedy 2015)와 ReLU 활성화 함수를 차례로 거친다. 합성곱 결과는 두 개의 완전 연결 층을 통해 벡터로

표상화된다. 디코더는 인코더와 반대로 표상을 입력받아 두 개의 완전 연결 층을 거친 뒤에 역 합성곱(transposed convolution)을 포함한 네 개 층에서 합성곱 연산을 수행한다. 인코더와 디코더 파라미터 업데이트에는 Adam 최적화(Kingma and Ba 2015)를 적용하였고, 학습률은 0.001, 정규화 상수는 0.0005로 통일했다. 가우시안 군집화의 경계값 ρ 는 0.003으로 두었고 표지 동일성과 불확실성 판단 기준인 θ_{inter} 와 θ_{intra} 는 각각 15, 0.3으로 설정했다. 목적 함수 계산에서 사용되는 λ_{inter} , λ_{intra} 는 모두 1이고 표지 전과 비율 δ 는 0.5로 했다.

인코더와 디코더를 중단 학습하는 대신 군집화에 앞서 사전 학습(pre-train)한 모델로도 실험했으며, 이때는 VAE에서와 같은 방법으로 표상의 평균과 분산 벡터를 구하고 재생성 목적 함수와 발산 목적 함수를 최소화하도록 학습이 이루어진다. 또한, 딥러닝 모델과의 성능 비교를 위해 CARLSON 인코더와 같은 구조를 가지는 합성곱 신경망(CNN)을 별도로 구현했다. CNN은 완전 연결 층과 softmax 연산을 추가로 이용하여 표지 확률을 구하고 CARLSON에서와 같은 방식으로 최적화한다.

5.2.2. 실험 설정

실험에서는 인공지능 로봇이 획득하는 데이터를 즉시 학습하는 온라인 학습을 가정한다. 실사용 환경에서도 물체를 연속으로 관찰하게 되므로 학습과 추론 시 같은 범주의 데이터가 30개씩 연속으로 주어지도록 했다. 다만 하나의 이미지는 한 번씩만 입력되고 입력된 데이터는 저장할 수 없도록 했다. 준지도 학습 상황도 설정하여 정답 표지는 전체 데이터 중 10%, 5% 또는 1%에 대해서만 제공하며, 추가적인 표지 획득은 없는 상태로 실험한다. 이때 준지도 설정을 제외한 온라인 학습 자체의 난이도를 가늠하기 위하여 표지를 전부 제공한 상태에서 CNN 학습과 추론도 진행했다. 실험은 모델과 데이터셋, 설정마다 10회씩 진행했으며, 각 시행에서 모델을 새롭게 학습시키고 분류 정확도를 측정하여 이들의 평균과 표준편차를 구했다.

5.2.3. 실험 결과 및 논의

실험 결과는 표 2에 나타나 있다. NAO 데이터셋에서는 CARLSON이 CNN과 비교해 월등히 높은 성능을 보이며, 심지어 표지를 100% 사용하여 학습한 CNN보다도 정확도가 높다. 인코더와 디코더의 사전 학습 여부는 성능에 거의 영향을 주지 않는 것으로 나타났다. 주어지는 데이터 개수와 표지 수를 고려하면 절대적인 분류 성능도 상당히 안정적이라고 평가할 수 있다. 다른 데이터셋에서도 거의 모든 경우에 CARLSON이 CNN보다 높은 성능을 보였으며, MNIST와 Fashion-MNIST에서는 표지 100%를 사용했을 때와 비슷한 정확도를 보였다. 또 다른 주목할 만한 부분은 CARLSON의 표준편차가 훨씬 낮다는 점으로, 이상의 결과를 종합하면 CARLSON이 CNN보다 데이터 입력 순서나 표지의 영향을 덜 받으며, 따라서 로봇 학습 환경에 더 적합하다고 볼 수 있다.

[표 2] 시각 객체 분류 온라인 준지도 학습 결과. 10회씩 실험하여 분류 정확도의 평균과 표준편차(괄호)를 구했다(단위: %).

데이터셋	표지 비율	CNN (100%)	CNN	CARLSON (사전 학습)	CARLSON
NAO	1%	27.8 (12.7)	22.6 (3.7)	37.8 (4.4)	36.3 (4.4)
	5%		26.8 (6.1)	41.5 (3.3)	44.9 (5.6)
	10%		29.2 (9.7)	42.8 (2.4)	45.0 (4.0)
MNIST	1%	85.5 (10.4)	34.3 (14.3)	78.8 (1.6)	76.5 (1.0)
	5%		66.2 (13.1)	81.9 (1.4)	80.2 (1.0)
	10%		71.0 (11.8)	82.2 (0.8)	86.6 (0.6)
SVHN	1%	41.9 (8.7)	16.6 (3.6)	16.0 (0.8)	17.3 (1.1)
	5%		20.7 (3.2)	19.2 (0.9)	20.5 (0.8)
	10%		22.7 (8.1)	21.0 (0.9)	22.3 (0.9)
Fashion-MNIST	1%	72.7 (7.6)	41.9 (8.9)	67.8 (1.0)	66.1 (0.7)
	5%		52.0 (7.4)	70.4 (0.4)	69.2 (0.6)
	10%		58.0 (10.6)	71.6 (0.7)	70.8 (0.7)
CIFAR-10	1%	31.7 (3.8)	13.1 (2.1)	16.6 (1.5)	17.1 (0.7)
	5%		14.8 (2.9)	20.4 (0.5)	19.2 (0.9)
	10%		18.0 (3.0)	21.2 (0.6)	22.1 (0.5)

제 6장

결론

이 논문에서는 인공지능 로봇이 새로운 환경에서 접하는 대상의 개념을 효율적이고 지속적으로 학습할 수 있도록 하는 모델 CARLSON을 제안했다. CARLSON은 사람의 학습 방식을 모사한 자기조직화 신경망 구조를 기본으로 하고 온라인 준지도 능동 학습을 수행함으로써 적은 데이터와 표지만으로도 물체 개념을 학습할 수 있다. 시각 객체를 분류하는 구체적인 과제를 수행하기 위해서 데이터에서 표상을 추출하는 인코더와 디코더를 구성하고 가우시안 군집화를 통해 개념을 형성하도록 했으며, 전체 구조를 중단 학습하여 새로운 입력에 더욱 유연하게 적응하도록 모델을 구현했다. 또한, 개념의 병합이나 분리 기법, 계층적 표상화, 데이터 저장을 통한 능동적 질의 방식을 추가한 확장 모델도 제시했다. 구현한 모델의 성능을 검증하기 위해 휴머노이드 로봇 NAO로 물체 이미지 데이터셋을 수집하여 시각 객체 분류 실험을 진행했고 CARLSON이 물체 개념을 효과적으로 지속 학습할 수 있다는 것을 확인했다.

향후에는 CARLSON을 이용하여 물체 개념과 로봇의 행동을 연관시켜서 학습하는 방향으로 연구를 확장할 수 있다. NAO 데이터셋을 수집할 때처럼 로봇이 물체를 조작하면서 일어나는 연속적인 변화를 기록하면 정적인 센서 관측만으로는 파악할 수 없는 물체의 물리적 성질이나 행위 유도성(affordance)과 관련된 정보를 획득하는 것이 가능하다. 로봇 팔의 위치, 손 모양, 팔을 움직이는 속도와 궤적 등을 행동 표상으로 나타내고 특정 행동에 따라 물체 이미지 표상이 어떻게 변하는지 예측하도록 모델을 개선하면 로봇이 물체의 물리적 속성을 학습하여 효율적으로 조작하도록 할 수 있을 것이다. 여기에 능동 학습을 적용하여 다음에 학습할 데이터를 얻기 위한 행동을 스스로 결정하게 한다면 인공지능 로봇의 능동성과 자율성이 더욱 높아질 것으로 기대한다.

참고 문헌

- Alain, Claude, Stephen R. Arnott, Stephanie Hevenor, Simon Graham, and Cheryl L. Grady. "What and where in the human auditory system." *Proceedings of the National Academy of Sciences* 98, no.21 (2001): 12301-12306.
- Anagnostopoulos, Georgios C., and Michael Georgiopoulos. "Ellipsoid ART and ARTMAP for incremental clustering and classification." *Proceedings of the International Joint Conference on Neural Networks* 2 (2001): 1221-1226.
- Ben-David, Shai, John Blitzer, Koby Crammer, Alex Kulesza, Fernando Pereira, and Jennifer W. Vaughan. "A theory of learning from different domains." *Machine learning* 79, no. 1-2 (2010): 151-175.
- Breazeal, Cynthia. Apparatus and methods for providing a persistent companion device. U.S. Patent 10,391,636, filed March 13, 2014, and issued August 27, 2019.
- Brown, Tom B., Benjamin Mann, Nick Ryder, Melanie Subbiah, Jared Kaplan, Prafulla Dhariwal, Arvind Neelakantan, et al. "Language models are few-shot learners." *arXiv preprint arXiv:2005.14165* (2020).
- Carpenter, Gail A., Stephen Grossberg, and David B. Rosen. "Fuzzy ART: Fast stable learning and categorization of analog patterns by an adaptive resonance system." *Neural Networks* 4, no. 6 (1991): 759-771.
- Carpenter, Gail A., Stephen Grossberg, Natalya Markuzon, John H. Reynolds, and David B. Rosen. "Fuzzy ARTMAP: A Neural Network Architecture for Incremental Supervised Learning of Analog Multidimensional Maps." *IEEE Transactions on Neural Networks* 3, no. 5 (1992): 698-713.
- Choi, Won-Seok, Injune Hwang, and Byoung-Tak Zhang. "ARLET: Adaptive Representation Learning with End-to-end Training." *NeurIPS 2020 Workshop on BabyMind* (2020).
- Fei-Fei, Li. "Knowledge transfer in learning to recognize visual object

- classes.” *Proceedings of the International Conference on Development and Learning* (2006).
- Fei-Fei, Li, Rob Fergus. and Pietro Perona. “One-Shot learning of object categories.” *IEEE Transactions on Pattern Analysis and Machine Intelligence* 28, no. 4 (2006): 594-611.
- Finn, Chelsea, Aravind Rajeswaran, Sham Kakade, and Sergey Levine. “Online Meta-Learning.” *arXiv preprint arXiv:1902.08438* (2019).
- Frank, Thomas, Karl-Friedrich Kraiss, and Torsten Kuhlen. “Comparative analysis of fuzzy ART and ART-2A network clustering performance.” *IEEE Transactions on Neural Networks* 9, no. 3 (1998): 544-559.
- Fritzke, Bernd. “A Growing Neural Gas Network Learns Topologies.” *Advances in Neural Information Processing Systems* 7 (1995): 625-632.
- Gouaillier, David, Vincent Hugel, Pierre Blazevic, Chris Kilner, Jérôme Monceaux, Pascal Lafourcade, Brice Marnier, Julien Serre, and Bruno Maisonnier. “Mechatronic design of NAO humanoid.” *2009 IEEE International Conference on Robotics and Automation* (2009).
- Grossberg, Stephen. Competitive learning: “From interactive activation to adaptive resonance.” *Cognitive Science* 11, no. 1 (1987): 23-63.
- He, Haibo, Sheng Chen, Kang Li, and Xin Xu. “Incremental learning from stream data.” *IEEE Transactions on Neural Networks* 22, no. 12-1 (2011): 1901-1914.
- He, Kaiming, Xiangyu Zhang, Shaoqing Ren, and Jian Sun. “Deep residual learning for image recognition.” *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (2016).
- Hebb, Donald O. *The Organization of Behavior: A Neuropsychological Theory*. New York: Wiley, 1949.
- Hoi, Steven C. H., Doyen Sahoo, Jing Lu, and Peilin Zhao. “Online Learning: A Comprehensive Survey.” *arXiv preprint arXiv:1802.02871* (2018).
- Ioffe, Sergey, and Christian Szegedy. “Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift.”

- Proceedings of the 32nd International Conference on Machine Learning* (2015):448-456.
- Kandel, Eric R., James H. Schwartz, Thomas M. Jessell, Steven A. Siegelbaum, and A. J. Hudspeth. *Principles of Neural Science*. 5th ed. New York: McGraw-Hill, 2012.
- Kim, Jongmin, Taesup Kim, Sungwoong Kim, and Chang D. Yoo. “Edge-Labeling Graph Neural Network for Few-shot Learning.” *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (2019):11-20.
- Kim, Taehyeong, Injune Hwang, Gi-Cheon Kang, Won-Seok Choi, Hyunseo Kim, and Byoung-Tak Zhang. “Label Propagation Adaptive Resonance Theory for Semi-Supervised Continuous Learning.” *2020 IEEE International Conference on Acoustics, Speech and Signal Processing* (2020): 4012-4016.
- Kim, Taehyeong, Injune Hwang, Hyundo Lee, Hyunseo Kim, Won-Seok Choi, and Byoung-Tak Zhang. “Message Passing Adaptive Resonance Theory for Online Active Semi-supervised Learning.” *arXiv preprint arXiv:2012.01227* (2020).
- Kingma, Diederik P., and Max Welling. “Auto-Encoding Variational Bayes.” *2nd International Conference on Learning Representations, Conference Track Proceedings* (2014).
- Kingma, Diederik P., and Jimmy Ba. “Adam: A Method for Stochastic Optimization.” *3rd International Conference on Learning Representations, Conference Track Proceedings* (2015).
- Koch, Gregory, Richard Zemel, and Ruslan Salakhutdinov. “Siamese Neural Networks for One-shot Image Recognition.” *ICML Deep Learning Workshop* (2015).
- Kohonen, Teuvo. “Self-Organized Formation of Topologically Correct Feature Maps.” *Biological Cybernetics* 43, no. 1 (1982): 59-69.
- Krizhevsky, Alex, and Geoffrey Hinton. “Learning Multiple Layers of Features from Tiny Images.” *Tech Report* (2009).
- Krizhevsky, Alex, Ilya Sutskever, and Geoffrey E. Hinton. “ImageNet classi-

- fication with deep convolutional neural networks.” *Advances in Neural Information Processing Systems* 25 (2012): 1097–1105.
- LeCun, Yann, Corinna Cortes, and Christopher J. C. Burges. (2010). “The MNIST Handwritten Digit Database.” Accessed December 30, 2020. <http://yann.lecun.com/exdb/mnist/>.
- Lee, Chung-Yeon, Hyundo Lee, Injune Hwang, and Byoung-Tak Zhang. “Visual Perception Framework for an Intelligent Mobile Robot.” *2020 17th International Conference on Ubiquitous Robots* (2020): 612-616.
- Lee, Sang-Woo, Jin-Hwa Kim, Jaehyun Jun, Jung-Woo Ha, and Byoung-Tak Zhang. (2017). “Overcoming Catastrophic Forgetting by Incremental Moment Matching.” *Advances in Neural Information Processing Systems* 30 (2017): 4653–4663.
- López, Gustavo, Luis Quesada, and Luis A. Guerrero. “Alexa vs. Siri vs. Cortana vs. Google Assistant: A Comparison of Speech-Based Natural User Interfaces.” *Advances in Human Factors and Systems Interaction* (2017): 241-250.
- MacQueen, James. B. “Some Methods for classification and Analysis of Multivariate Observations.” *Proceedings of Fifth Berkeley Symposium on Mathematical Statistics and Probability* 1 (1967): 281–297.
- Martinetz, Thomas and Klaus Schulten. “A "neural gas" network learns topologies.” *Artificial Neural Networks* (1991): 397–402.
- Meier, Benjamin B., Ismail Elezi, Mohammadreza Amirian, Oliver Dürr, and Thilo Stadelmann. “Learning neural models for end-to-end clustering.” *IAPR Workshop on Artificial Neural Networks in Pattern Recognition* (2018): 126–138.
- Netzer, Yuval, Tao Wang, Adam Coates, Alessandro Bissacco, Bo Wu, and Andrew Y. Ng. “Reading Digits in Natural Images with Unsupervised Feature Learning.” *NIPS 2011 Workshop on Deep Learning and Unsupervised Feature Learning* (2011).
- Pan, Sinno J., and Qiang Yang. “A survey on transfer learning.” *IEEE Transactions on Knowledge and Data Engineering* 22, no. 10 (2009): 1345-1359.

- Park, Kyung-Wha, Jin-Young Choi, Beom-Jin Lee, Chung-Yeon Lee, Injune Hwang, and Byoung-Tak Zhang. "VLAS: A Vision-Language-Action Integrated System for Mobile Social Service Robots." *Federated AI for Robotics Workshop* (2018).
- Rumelhart, David E., and David Zipser. "Feature Discovery by Competitive Learning." *Cognitive Science* 9, no. 1 (1985): 75-112.
- Schiller, Peter H. "The central visual system." *Vision Research* 26, no. 9 (1986): 1351-1386.
- Schmidhuber, Jürgen. "Deep learning in neural networks: An overview." *Neural Networks* 61 (2015): 85-117.
- Seiffert, Udo, and Lakhmi C. Jain, eds. *Self-Organizing Neural Networks: Recent Advances and Applications*. Physica, 2002.
- Settles, Burr. *Active Learning*. Morgan & Claypool Publishers, 2012.
- Shen, Furao, and Osamu Hasegawa. "An incremental network for on-line unsupervised classification and topology learning." *Neural Networks* 19, no. 1 (2006): 90-106.
- Shen, Furao, Hui Yu, Keisuke Sakurai, and Osamu Hasegawa. "An incremental online semi-supervised active learning algorithm based on self-organizing incremental neural network." *Neural Computing and Applications* 20, no. 7 (2011): 1061-1074.
- SoftBank Robotics. "Aldebaran 2.8.6.23e documentation." SoftBank Robotics Documentation. Accessed December 30, 2020.
<http://doc.aldebaran.com/2-8/index.html>.
- Teney, Damien, and Anton van den Hengel. "Actively Seeking and Learning from Live Data." *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (2019).
- Tscherepanow, Marko. "TopoART: A Topology Learning Hierarchical ART Network." *Proceedings of the 20th International Conference on Artificial Neural Networks* (2010): 157-167.
- Vigdor, Boaz, and Boaz Lerner. "The Bayesian ARTMAP." *IEEE Transactions on Neural Networks* 18, no. 6 (2007): 1628-1644.

- Vinyals, Oriol, Charles Blundell, Timothy Lillicrap, Koray Kavukcuoglu, and Daan Wierstra. "Matching Networks for One Shot Learning." *Advances in Neural Information Processing Systems* 29 (2016):3630-3638.
- Wang, Tick S., Zoltan-Csaba Marton, Manuel Brucker, and Rudolph Triebel. "How Robots Learn to Classify New Objects Trained from Small Data Sets." *Proceedings of the 1st Annual Conference on Robot Learning* (2017): 408-417.
- Williamson, James R. "Gaussian ARTMAP: A Neural Network for Fast Incremental Learning of Noisy Multidimensional Maps." *Neural Networks* 9, no. 5 (1996): 881-897.
- Xiao, Han, Kashif Rasul, and Roland Vollgraf. "Fashion-MNIST: a Novel Image Dataset for Benchmarking Machine Learning Algorithms." *arXiv preprint arXiv:1708.07747* (2017).
- Yang, Bo, Xiao Fu, Nicholas D. Sidiropoulos, and Mingyi Hong. "Towards K-means-friendly spaces: Simultaneous deep learning and clustering." *Proceedings of the 34th International Conference on Machine Learning* (2017): 5888-5901.
- Yao, Huaxiu, Ying Wei, Junzhou Huang, and Zhenhui Li. "Hierarchically Structured Meta-learning." *Proceedings of the 36th International Conference on Machine Learning* (2019): 7045-7054.
- Yosinski, Jason, Jeff Clune, Yoshua Bengio, and Hod Lipson. "How transferable are features in deep neural networks?" *Advances in Neural Information Processing Systems* 27 (2014): 3320-3328.
- Zhang, Byoung-Tak. "Accelerated Learning by Active Example Selection." *International Journal of Neural Systems* 5, no. 1 (1994): 67-75.
- Zhu, Xiaojin and Zoubin Ghahramani. "Learning from Labeled and Unlabeled Data with Label Propagation." *Tech Report* (2002).
- Zou, Yang, Zhiding Xiao, Feng Liu, X., B.V.K. Vijaya Kumar, and Jinsong Wang. "Confidence Regularized Self-Training." *Proceedings of the IEEE International Conference on Computer Vision* (2019).

Abstract

Continual Active Robot Learning using Self-organizing Neural Network

Injune Hwang

Department of Computer Science and Engineering

The Graduate School

Seoul National University

In this thesis, a continual and active machine learning method is proposed to make artificial intelligence (AI) robots adapt to real environments and form concepts of nearby objects. Recent advances in the field of AI have led to the development of smart home appliances or AI speakers, but most of these products may suffer performance degradation in actual use. This is because they use functions such as voice or face recognition without adjusting them to the individual operation environments. The deep learning techniques used for these functions need to be trained repeatedly with big data for a long time, and they have a risk of catastrophic forgetting when encountering increasingly diverse objects. Meanwhile, AI robots need to continuously learn skills and concepts from a relatively small number of newly acquired data. Since humans are the most well-known agents that learn this way, imitating human learning would be one of the most effective ways to achieve the desired robot learning. The proposed model, CARLSON, integrates the strengths of the previous human-like machine learning methods.

CARLSON is a self-organizing neural network that can expand the knowledge by comparing the incoming object image to the learned concepts. In order to increase the efficiency and stability of learning, the model first reduces the size and noise of high-dimensional input images by extracting informative features, or representations, from them. The feature extraction is carried out by an encoder which is jointly trained with a decoder that reconstructs images from representations. CARLSON divides the representations into groups in such a way that each group represents a single kind of objects, or an individual concept. The groups are implemented as nodes with means and variances that are created or adjusted by considering both top-down prediction and bottom-up activation as in Adaptive Resonance Theory (Grossberg 1987). The whole model including the encoder and decoder is trained in an end-to-end manner, and updated upon every new input. Using a label propagation method, CARLSON makes the similar nodes share information so that it can infer the object categories even when the labels are provided rarely. It can also actively ask a human operator about uncertain concepts to further make up for insufficient information.

To evaluate the model, a visual object dataset was constructed by collecting images with a humanoid robot NAO, and was used for object recognition experiments. CARLSON clearly outperformed a convolutional neural network (CNN) model and showed a stable performance even when the labels were given rarely and each data could be accessed only once during training. It also performed better than CNN in online semi-supervised recognition tasks using well-known digit and object classification datasets: MNIST, SVHN, Fashion-MNIST, and CIFAR-10.

Keywords: Continual learning, active learning, AI robot, self-organizing neural network, online learning, semi-supervised learning

Student Number: 2019-23288