

AQM 프레임워크를 위한 생성적 분류 모델과 변별적 분류 모델의 비교

허유정^o, 이상우, 장병탁

서울대학교 컴퓨터공학부

{yjheo,slee,btzhang}@bi.snu.ac.kr

Comparison of Generative Classification Model and Discriminative Classification Model for AQM framework

Yu-Jung Heo^o, Sang-Woo Lee, Byoung-Tak Zhang

School of Computer Science & Engineering, Seoul National University

요 약

목표 지향적 대화(Goal-oriented Dialogue)는 구체적이며 특정한 목표를 달성하기 위하여 질문자와 답변자가 묻고 답하는 대화를 지칭한다. 목표 지향적 대화 시스템의 일환으로 최근 Answerer in Questioner's Mind (AQM) 프레임워크가 제안되었다. AQM 프레임워크는 학습 데이터에서 정보 이득(information gain)을 최대화 하는 질문을 선택하는 방식으로, 보다 효율적인 질문을 도출하여 목표 지향적 대화 시스템의 능력을 높인다. 기존 AQM 연구에서는 도출된 질의응답 바탕으로 목표를 맞추는 Guesser 모델에 대해, Naïve Bayes 기반의 생성적 분류 모델(generative classification model)을 사용하였다. 본 논문에서는 목표 지향적 대화 문제 중 하나인 GuessWhat?! 에 대해 기존의 AQM 프레임워크의 생성적 분류 모델과 변별적 모델(discriminative model)을 적용한 경우를 비교하고, 변별적 모델 사용의 장점을 논증하며, 가능한 변별적 모델의 예시에 대하여 논의한다.

1. 서 론

목표 지향적 대화(goal-oriented dialog)는 특정한 목표를 달성하기 위하여 질문자와 답변자가 묻고 답하는 대화를 지칭한다. 일반적으로 목표 지향적 대화 시스템은 자유 대화(chit-chat dialog) 시스템과 비교되어, 보다 더 밀접한 산업적 수요와 관련을 가진다고 여겨진다.

구체적으로 목표 지향적 대화 시스템에는 질문자가 알아내야 하는 구체적인 목표 혹은 정답이 있다. 예를 들어, 카페에서 커피를 주문하는 상황을 생각해 보자. 해당 상황에서는 종업원이 질문자, 손님이 답변자가 되며, 손님은 종업원에게 주문을 하고, 종업원은 손님이 원하는 음료의 리스트 및 수량 등을 정확하게 알아내야 한다. 또 다른 예로, 콜 센터 응대 시스템에서는 상담원이 질문자, 사용자가 답변자에 해당한다. 해당 상황에서 상담원의 목표는 사용자의 상황을 정확히 파악하고 그에 대한 해결책을 제시하는 것이다.

자유 대화 시스템에는 Recurrent Neural Network(순환 신경망, RNN)을 기반으로 입력 문장이 들어오면 상응하는 문장을 출력하는 seq2seq 모델을 활용하여 다양한 연구가 진행되었고, 주목할만한 성과를 보였다[1]. 해당 방법론은 목표 지향적 대화 시스템에 또한 적용되었으나, 도메인에 대한 사전 지식과 목표 지향적인 문맥의 고려가 부족하여 상대적으로 제한적인

결과를 보였다[2].

더 나아가, 깊은 지도 학습[3]과 깊은 강화학습[4]을 목표 지향적 대화 시스템에 적용, RNN 기반의 모델을 종단간 학습으로 최적화하려는 시도가 있었다. 하지만, 질문을 생성하는 질문자 에이전트를 만들기 위해서 이전의 질의응답을 바탕으로 최적의 질문을 생성하는 복잡한 구조의 RNN을 학습해야 한다. 복잡한 구조의 RNN을 학습하는 것은 매우 어려운 문제로 여겨지며, 이에 다소 제한적인 성공을 거두었다.

Answerer in Questioner's Mind(AQM) 프레임워크는 복잡한 RNN을 학습시키는 대신, 학습 데이터에서 정보 이득을 최대화하는 효율적인 질문을 찾는 방식으로 문제를 우회하여, 기존 딥러닝 기반의 방법론보다 좋은 성능을 보고하였다[5]. AQM은 단순한 기계학습 모델과 수식을 사용하는 것을 특징으로 가지며, 특별히 질문과 답변을 종합하여 목표를 맞추는 Guesser 모델에 대하여 naïve Bayes 기반의 생성적 모델을 사용하는 것을 가정한다.

본 논문에서는 목표 지향적 대화 문제 중 하나인 GuessWhat?!에 대해 기존의 AQM 프레임워크의 생성적 분류 모델과 변별적 모델을 적용한 경우를 비교하고, 변별적 모델 사용의 장점을 논증한다. 또한 가능한 변별적 모델의 예시에 대하여 논의한다.

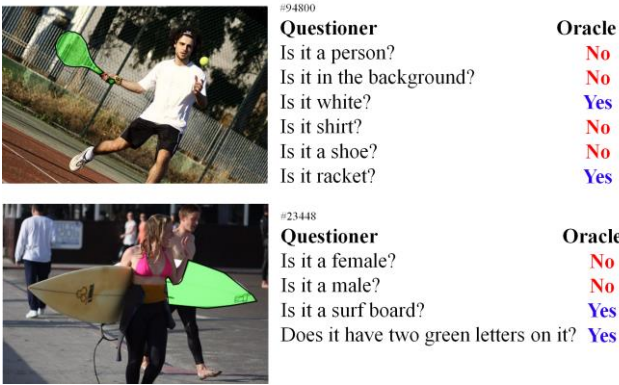


그림 1. GuessWhat?! 데이터의 예시

2. GuessWhat?!

GuessWhat?!은 이미지를 중심으로 수행하는 목표 지향적 대화 게임의 일종으로, 질문자와 답변자가 함께 수행하는 이미지 스무고개 게임으로 생각할 수 있다. 질문자는 이미지에 숨겨진 정답 물체인지를 알지 못하며, 물체를 맞추기 위해 Yes-No 질문을 생성한다. 답변자는 정답 물체를 알고 있으며, 질문자의 질문에 대하여 [예, 아니오, 잘 모르겠음] 중 하나로 대답한다. 질문자는 질문을 하는 동안에는 정답이 될 수 있는 후보 물체를 알지 못하지만, 답을 알게 되었다고 생각되어 정답을 맞추겠다고 선언하였을 때, 물체들의 후보를 알게 되며 질문자는 후보 중 가장 그럴듯한 물체를 답으로 선택해야 한다.

GuessWhat?! 데이터(그림 1)는 약 150,000 게임으로 구성되어 있으며, 각 게임은 하나의 이미지와 여러 개의 질문-답변쌍으로 구성되어 있다. 데이터를 기반으로 인공지능 질문자 에이전트와 인공지능 답변자 에이전트를 같이 학습하고, 두 인공지능 에이전트가 성공적인 게임을 수행하게 하는 것이 본 게임의 목표이다.

3. Answerer in Questioner's Mind (AQM) 프레임워크

AQM은 질문을 생성하고, 목표를 맞추는 질문자 에이전트를 모델링 하고자 한다. 즉, 목표를 맞추기 위해 질문을 던지는 Question Generator와 이전 질의응답을 바탕으로 목표를 맞추는 Guesser가 우리의 관심사이다. 우리는 목표, t번째 질문, t번째 답변 세트를 C, Q_t, A_t 로, 각 인스턴스를 C, q_t, a_t 를 정의한다. 그림 2는 GuessWhat?! 문제에 적용한 정의의 예이다.

3.1 Question Generator

Question Generator는 정보 이득을 최대화 하는 효율적인 정답을 추출한다. 정보 이득에 대한 상세 수식은 수식은 아래 식 (1)과 같다. 질문자는 답변을 생성하는 RNN을 학습하는 대신, 답변자의 모델 $p(a_t | c, q_t, a_{1:t-1}, q_{1:t-1})$ 을 학습한다.



그림 2. GuessWhat?! 데이터에 대한 AQM 프레임워크의 용어 정의

$$I[C, A_t; q_t, a_{1:t-1}, q_{1:t-1}] = \sum_{a_t} \sum_c p(c | a_{1:t-1}, q_{1:t-1}) \cdot p(a_t | c, q_t, a_{1:t-1}, q_{1:t-1}) \ln \frac{p(a_t | c, q_t, a_{1:t-1}, q_{1:t-1})}{p(a_t | q_t, a_{1:t-1}, q_{1:t-1})} \quad (1)$$

3.1 Guesser

t개의 질의응답 $(a_{1:t}, q_{1:t})$ 이 주어졌을 때 목표를 맞추기 위해 정답 c의 확률을 구하는 Guesser 모델이 필요하다. AQM에서는 Guesser 모델로, 식 (2)의 생성적 모델을 정의한다.

$$p(c | a_{1:t}, q_{1:t}) \propto p(c) \prod_j p(a_j | c, q_j, a_{1:j-1}, q_{1:j-1}) \quad (2)$$

$$p(a_t | c, q_t, a_{1:t-1}, q_{1:t-1}) \propto p(a_t | c, q_t) \quad (3)$$

식 (2)의 $p(a_t | c, q_t, a_{1:t-1}, q_{1:t-1})$ 를 근사하는 것이 어렵기 때문에, AQM의 실제 실험에서는 식 (3)과 같은 근사식을 사용하였고, 최종적으로 AQM의 Guesser 모델은 naïve Bayes와 같다. 하지만, naïve Bayes 혹은 일반적인 생성적 모델은 데이터가 많이 주어졌을 때, 변별적 모델보다 성능이 좋지 않다는 것이 알려져 있다[6].

4. GuessWhat?! 실험 결과

질문자가 답변자의 답변자 모델을 온전히 모사하였을 때, AQM 프레임워크는 세 번의 질문만에 59.40%의 성능을 내어, Hierarchical Recurrent Encoder-Decoder(HRED)를 사용한 깊은 감독학습 모델[3]의 성능 46.8%과 깊은 감독학습과 강화학습을 함께 적용한 모델[4]의 성능 52.3%과 비교하여 좋은 성능을 보였다.

하지만, AQM에서 사용된 Guesser 모델은 분류 문제 관점에서 보면 naïve Bayes의 일종이라고 볼 수 있다.

Model	test accuracy
Baseline [5]	0.160
변별적 모델 (LSTM) [3]	0.613
생성적 모델 (naïve Bayes)	0.5595
Human performance [4]	0.844

표 1. GuessWhat?! 테스트 데이터(사람의 질의 응답)의 정확도에 대한 성능

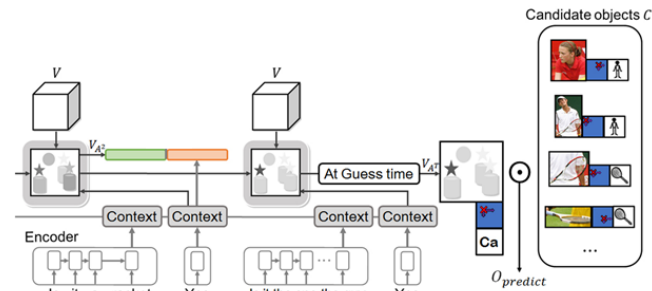


그림 3. AQM 프레임 워크에 적용 가능한 변별적 분류 모델의 예

우리는 AQM에서 사용된 Guesser의 naïve Bayes 모델을 GuessWhat?!의 테스트 데이터, 즉 사람의 질의응답 데이터에 적용하여 55.95%의 성능을 얻었다. 같은 세팅에서 Guesser 모델로 RNN 기반의 LSTM(Long Short-Term Memory) 모델을 적용한 경우 61.3%의 성능을 얻었다(표 1). 본 실험에서 도출된 결과를 통해 AQM의 주된 성능 향상의 요인이 Guesser 모델이 아닌 Question Generator 모델에서 기인했음을 추론할 수 있다. 즉, Guesser model을 생성적 모델을 보다 견고한 변별적 모델로 변경한다면, AQM의 추가적인 성능 향상에 기여할 수 있을 것이다

5. 변별적 실험 모델의 후보

우리는 Guesser 모델을 보다 견고하게 디자인하여 AQM의 성능을 추가로 증가시킬 수 있을 것이라고 생각한다. 이전 연구[3,4]에서 사용하였던 LSTM(Long Short-Term Memory) 기반의 모델 혹은 Hierarchical Recurrent Encoder-Decoder(HRED) 기반의 모델이 그 예가 될 수 있다.

하지만, 더 나아가 우리는 Spatio-Temporal Attention을 LSTM 혹은 HRED 모델에 적용시키는 기법을 고안하고 있다. Attention Memory는 질의응답에 대해 주어진 이미지에 존재하는 목표 물체에 주의를 가하도록 학습된다. 이는 실제 이미지 특정 부분인 목표 물체에 대해 주의를 기울임으로서, 기존의 LSTM 혹은 HRED 모델의 은닉 변수들의 학습에 시각적 접지 효과를 주는 것으로 이해할 수 있다. 고안하고 있는 변별적 분류 모델의 예는 그림 3과 같다.

이 논문은 2017년도 정부(과학기술정보통신부)의 재원으로 정보통신기술진흥센터(R0126-16-1072-SW스타랩, 2017-0-01772-VTT), 한국산업기술평가관리원(10060086-RISF)과 한국연구재단(R0126-16-1072-GENKO)의 지원을 받았음.

참고 문헌

- [1] Oriol Vinyals and Quoc Le, "A Neural Conversation Model," *ICML deep learning workshop*, 2015.
- [2] Antoine Bordes, Y-Lan Boureau, and Jason Weston, "Learning end-to-end goal-oriented dialog," In *ICLR*, 2017.
- [3] Ham de vries et al., "GuessWhat?! Visual Object Discovery through Multi-modal Dialogue," In *CVPR*, 2017.
- [4] Florian Strub et al., "End-to-end optimization of goal-driven and visually grounded dialogue systems," *arXiv*, 2017.
- [5] Sang-Woo Lee et al., "Answerer in Questioner's Mind for Goal-Oriented Visual Dialogue," *ACML workshop*, 2017.
- [6] Andrew Y. Ng and Michael I. Jordan, "On discriminative vs. generative classifiers: A comparison of logistic regression and naïve Bayes," In *NIPS*, 2002.