

MTRNN을 이용한 한국어 대화 모델 생성

신창욱^o, 차정원

창원대학교

{papower1, jcha}@changwon.ac.kr

Korean Dialogue Modeling using MTRNN

Chang-Uk Shin^o, Jeong-Won Cha

Changwon National University

요약

본 논문에서는 Multi-layer sequence-to-sequence 구조를 이용해 한국어 대화 시스템을 개발하였다. sequence-to-sequence는 RNN 혹은 그 변형 네트워크에 데이터를 입력하고, 입력이 완료된 후의 은닉층의 embedding에 기반해 출력열을 생성한다. 우리는 sequence-to-sequence로 입력된 발화에 대해 출력 발화를 내어주는 대화 모델을 학습하였고, 그 성능을 측정하였다. RNN에 대해서는 약 80만 발화를, MTRNN에 대해서는 5만 발화를 학습하고 평가하였다. 모델의 결과로 나타난 발화들을 정리하고 분석하였다.

주제어: sequence-to-sequence, 대화 모델, LSTM, MTRNN

1. 서론

대화 시스템은 대화의 기록을 유지하며, 입력된 사용자의 발화에 대해 적절한 응답을 내어주는 시스템이다.

대화 시스템에서 가장 중요한 모듈은 주어진 대화 기록과 입력된 사용자의 발화에 대하여 시스템의 출력 발화를 결정하는 모듈이라고 볼 수 있다. 우리는 그것을 대화 모델이라 부른다.

sequence-to-sequence 등의 end-to-end 구조를 이용하여 자연언어처리의 문제를 해결하려는 시도가 종종 있어왔다. 대화 시스템에서는 사용자의 발화 처리, 대화 기록 관리, 시스템 발화 생성을 하나의 모델로 수행하는 방식이 이에 해당한다. 이러한 end-to-end 시스템은 기존에 연구된 다단계 시스템에 비해 연구자의 노력과 시간이 적게 소요됨에도 불구하고 높은 성능을 보여주고 있어 여러 분야에서 시도되고 있다.

우리는 sequence-to-sequence 구조로 한국어 대화 모델을 학습하고 그 결과를 분석하였다. 특히, Recurrent unit으로 LSTM과 MTRNN을 비교하여 분석하였다.

2. 관련 연구

여러 연구자들이 end-to-end 구조로 자연어처리 문제들을 해결하기 위해 연구를 진행한 바 있다. sequence-to-sequence 구조는 순서를 갖는 데이터를 입력하여 입력열 전체에 대한 표현을 획득하고, 그것에 기반하여 출력열을 생성하는 구조를 취하고 있다. 이 방식이 기존 자연어처리 분야의 여러 문제에 적용하기 적합하여, 형태소 분석 등 여러 분야에 적용되었다.

[1, 2, 3]에서는 sequence-to-sequence 구조를 이용해 형태소 분석 및 품사 태깅을 시도한 바 있다. 음절 단위, 또는 어절 단위로 인코딩된 입력을 sequence-to-sequence 모델에 입력하고, 그 출력을 형태소 분석 및 품사 부착의 결과물로서 사용한다.

[4]에서는 sequence-to-sequence 구조로 구구조 구문 분석을 수행하였다. 형태소 분석된 입력 문장을 음절 또는 형태소 단위로 입력받아, 구구조 구문분석 결과를 토 큰 단위로 출력하도록 학습하였다.

대화 시스템과 모델링에서 관련된 이전 연구로, 많은 양의 발화 입-출력 쌍을 수집하고 입력되는 발화에 매치된 출력 발화는 내어주는 방식의 연구가 진행되었다. [5]에서는 TF-IDF와 단어 임베딩을 대화 매치에 사용해 MRR 93.9%를 달성하였다.

3. 제안 방법

우리는 Multi-layer sequence-to-sequence 구조를 이용해 대화 모델을 학습하였다. Recurrent Unit으로 LSTM[6]과 MTRNN[7]의 변형을 학습하였고, 그 결과를 비교하였다.

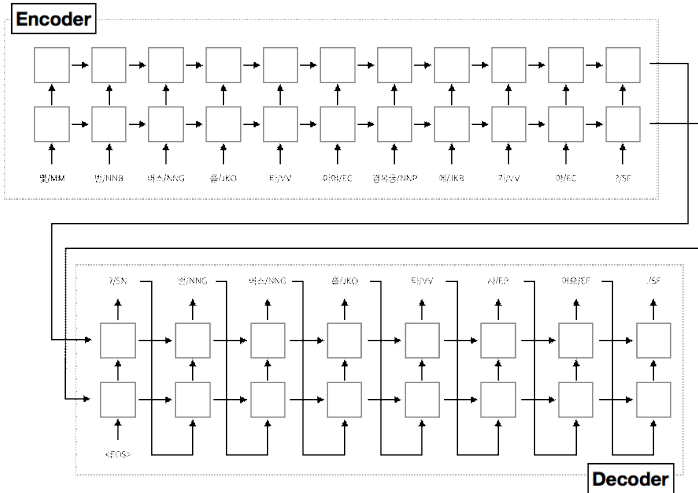
[그림 1]은 sequence-to-sequence의 구조를 설명한다. 그림에서 입력열을 분산 표현으로 생성하는 단계를 encode, 그것을 수행하는 네트워크를 encoder라 칭한다. encoder는 매 입력이 주어질 때마다 다음 식으로 RNN variant의 hidden state를 업데이트 한다.

$$h_t = f(h_{t-1}, x_t) \tag{1}$$

식1에서 f는 non-linear activation 함수이다. 마지막 토큰까지 입력이 완료되었을 때의 hidden state를 sequence 전체에 대한 분산 표현으로 간주한다. 그리고 해당 분산 표현을 최초의 state로 하는 decoder를 동작시켜 출력 시퀀스를 생성한다.

$$h_t = f(h_t, y_{t-1}) \tag{2}$$

위 식2는 decoder에서의 매 타임 스텝 t에서 이전 스텝의 hidden state h_t 와 출력 y_{t-1} 로 이번 타임 스텝의 hidden state를 생성함을 이야기한다. [그림 1]에서도



[그림 1] multi-layer sequence-to-sequence

이전의 출력 토큰이 다음 스텝의 입력으로 취해지는 것을 확인할 수 있다.

sequence-to-sequence는 여러 RNN variant로 구성할 수 있는데, 본 논문에서는 그 중 LSTM과 MTRNN으로 실험을 진행하였다.

LSTM은 RNN에서 발생하는 그라디언트 소실(vanishing gradient) 문제를 해결한 변형으로 여러 문제에서 RNN 대신에 주로 사용되고 있다. RNN에서는 하나의 state를 관리하는 반면, LSTM은 세 개의 gate를 이용해 두 개의 state를 관리하고 있다. 그 첫 번째는 아래 식의 c이고 cell state라 불리운다. 두 번째 state는 아래의 h이고 hidden state이다. 식의 \odot 는 Hadamard product이다.

$$f_t = \sigma(W_{xh_f}x_t + W_{hh_f}h_{t-1} + b_{h_f}) \quad (3)$$


$$i_t = \sigma(W_{xh_i}x_t + W_{hh_i}h_{t-1} + b_{h_i}) \quad (4)$$

$$o_t = \sigma(W_{xh_o}x_t + W_{hh_o}h_{t-1} + b_{h_o}) \quad (5)$$

$$g_t = \tanh(W_{xh_g}x_t + W_{hh_g}h_{t-1} + b_{h_g}) \quad (6)$$

$$c_t = f_t \odot c_{t-1} + i_t \odot g_t \quad (7)$$

$$h_t = \tanh(c_t) \odot o_t \quad (8)$$



[그림 2] LSTM 구조

MTRNN은 Recurrent Node의 상태 업데이트 식을 새로이 정의하고, 그것을 파라미터 τ 로 조절할 수 있도록 하였다. 같은 층의 노드를 그룹화하고, 그룹마다 τ 를 달리 설정하여 특정 그룹은 빠르게, 특정 그룹은 느리게 업데이트되도록 설정하였다.

우리는 MTRNN τ 를 층 내에 그룹에 설정하지 않고, 2개의 층에 각각 다른 τ 를 설정하여 변형을 시도하였다. 이렇게

하면 층마다 다른 state representation을 갖게 될 것이다.

$$u_{i,t+1} = (1 - \frac{1}{\tau_i})u_{i,t} + \frac{1}{\tau_i} \left[\sum_{k \in N} w_{jk} x_{k,t} \right] \quad (9)$$

위 식9에서 τ 를 layer마다 달리 설정해 줌으로써 multi-layer에서 multiple time-scale을 작성할 수 있다. 식에서 w 는 weight matrix, x 는 입력 혹은 이전 layer의 state, N 은 입력 차원 혹은 이전 layer의 노드의 수, $u_{i,t}$ 는 시간 t 에서 i 번째 layer의 state이다.

4. 실험

4. 1. 실험 설정

sequence-to-sequence로 대화 모델링을 수행한다. 어떤 사용자의 입력에 대하여, 그것의 응답에 해당하는 발화 출력을 목표로 설정한다. 평가로는 평가 데이터셋의 입력 발화를 시스템에 입력하고, 그 출력물을 평가 데이터셋의 출력 발화와 비교하여 성능을 도출한다.

학습에 사용한 코퍼스는 직접 작성하였고, 일상 대화 도메인의 코퍼스이다. 코퍼스에 대한 정보는 [표 1]에 정리하였다. 하나의 입력 발화에 대해 여러 출력 발화가 부착되어 있는 형태이다.

[표 1] 학습 코퍼스의 통계 정보

구분	수량	단위
입력 발화 수	146,276	발화
출력 발화 수	1,123,902	발화
입력 발화 내 발화당 형태소 수	4.50	형태소/발화
출력 발화 내 발화당 형태소 수	9.42	형태소/발화

코퍼스가 하나의 입력 발화에 대해 여러 출력 발화가 부착된 코퍼스이므로, 전처리 과정이 다소 필요하다. 우리는 먼저 여러 출력 발화를 갖는 입력 발화에 대하여, 각 하나씩의 출력 발화를 갖도록 분리하였다. 그리고 이렇게 생성된 총 112만 발화쌍을 80%의 학습 코퍼스와 20%의 평가 코퍼스로 나누었다.

평가는 번역 등의 연구에서 주로 사용되는 BLEU 스코어[8]를 사용하였다. 정답으로 주어진 출력 발화들을 번역에서의 정답과 같다고 보고, 모델의 결과를 평가하는 방식이다.

실험은 가장 적합한 파라미터를 알아내기 위하여 learning rate 등을 수정하며 진행하였고, 그 결과를 4. 2. 실험 결과 및 분석에 기술한다.

4. 2. 실험 결과 및 분석

모든 실험에서 hidden unit는 512, embedding size는 256을 사용하였고, layer는 2로 설정, dropout과 attention을 적용하였다. optimizer로 adam을 사용하였다.

첫 번째 실험은 LSTM으로 진행하였다. learning rate는 0.00001로 설정하였고, 학습 발화 89만 9천여 발화로 학습, 22만여 발화로 평가를 수행하였다.

두 번째 실험은 sequence-to-sequence의 Recurrent Node를 LSTM 대신 위에서 설명한 MTRNN의 변형으로 설정한 실험이다. learning rate는 0.0001로 설정하였고, τ 는 첫 번째 레이어에 2, 두 번째 레이어에 3을 설정하였다. 5만 개의 발화로 학습, 5만 개의 발화로 평가를 수행하였다. 첫 번째 실험과 학습 및 평가 발화 수에 차이가 있다.

세 번째 실험은 두 번째 실험에서 τ 를 3, 4로 수정한 실험이다. 두 번째 실험과 τ 설정에만 차이가 있고 다른 설정은 같다.

[표 2] 대화 모델의 실험별 성능

실험	cell type	BLEU1	BLEU2	BLEU3	BLEU4
1	LSTM	0.452	0.278	0.212	0.189
2	MTRNN variant	0.464	0.328	0.248	0.205
3	MTRNN variant	0.479	0.341	0.263	0.220

우리의 설정에서 하나의 입력 발화가 여러 출력 발화에 매치되는 경우가 있다. 우리는 이에 대한 분석을 수행하고자, 평가 코퍼스에서 몇 개의 샘플을 추출해 [표 6]에 정리하였다. 실제 학습은 형태소 품사가 부착된 형태소 단위이지만, 편의를 위해 원문을 복원하여 기술하였다.

[표 3] 대화 모델의 입력 발화에 대한 출력 샘플

입력발화	그래 미안한걸
정답 출력발화 (총 40발화)	내가 더 미안해
	미안하다면 다야? 마음 상했다고~
	나도 미안해~
모델 출력 발화	나도 미안하지~
입력발화	너 사귀는 사람 있어?
정답 출력 발화 (총 35발화)	난 화려한 싱글이야!!
	당연히 있지~
	놀리는 것이오?
모델 출력 발화	난 화려한 싱글이야?
입력발화	철수야 식구중에 언니 있니?
정답 출력 발화 (총 28발화)	없어... 하지만 누나 한 명 있었으면 좋겠다...
	누나 없당... 쏘로지~
	아니 없어. 혼자야
모델 출력 발화	당연한 A형이야?

위 두 예제는 적절히 잘 모델링 된 것으로 볼 수 있다. 첫 번째 예제 ‘그래 미안한걸’은 학습 코퍼스에서 유사한 발화 ‘진짜 미안했어’, ‘그래 미안해요’ 등이 학습되어서 효과를 발휘한 것으로 판단된다. 두 번째 예제는 더욱 확실하게 중첩되는 학습 데이터가 있었다. ‘철수야 너 사귀는 사람 있어?’, ‘철수야 사귀는 사람 있어?’ 등이다.

마지막 예제는 모델이 적절한 답변을 내어주지 못한 경우이다. 혈액형을 묻는 예제 발화쌍으로 ‘철수야 혈액형 뭐야?’ / ‘자상한 A형이야~’가 있었다. 그리고 언니가

있는지 묻는 발화에 대해서는 ‘당연한’으로 시작하는 발화가 없었다. 우리의 실험에서 ‘당연/XR’과 ‘자상/XR’의 임베딩이 유사하고, 이 중에서 잘못 선택한 것이 뒤까지 영향을 미쳐 이러한 결과가 발생한 것이다.

5. 결론

높은 성능과 응용력을 갖춘 대화 모델링 기법을 목표로 많은 연구가 진행되고 있다. 우리는 sequence-to-sequence 구조에 Recurrent unit으로 LSTM과 MTRNN을 비교실험하고, 그 결과를 기술하였다. 우리의 실험에서는 학습 발화와 평가 발화에 수의 차이가 있지만 MTRNN이 LSTM에 비해 높은 성능을 보였다.

대화를 모델링하기 위한 연구가 계속 진행되고 있다. 우리의 이번 연구는 대화 모델링을 end-to-end로 수행할 수 있음을 보였다. 학습 후 측정된 성능은 BLEU4 0.161 ~ 0.220의 성능을 보였다. Attention 메커니즘과 MTRNN을 적용하였음에도 낮은 성능을 보여, 대화 모델링을 end-to-end로 수행하기 위해서는 심도 깊은 연구가 진행되어야 할 것으로 보인다.

사 사

이 논문은 2017년도 정부(교육부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업임 (No. 2017R1D1A1B03033534).

참 고 문 헌

- [1] 정의석, 박전규, seq2seq 주의집중 모델을 이용한 형태소 분석 및 품사 태깅, 한글 및 한국어 정보처리 학술대회 논문집, 2016.
- [2] 이건일, 이의현, 이종혁, Sequence-to-sequence 기반 한국어 형태소 분석 및 품사 태깅, 정보과학회논문지, 44권 1호, 57-62, 2017.
- [3] 박건우, 이현구, 김학수, Sequence-to-Sequence 기반 다중 발화 후보를 이용한 형태소 분석기, 한국컴퓨터종합학술대회 논문집, 648-650, 2017.
- [4] 황현선, 이창기, Sequence-to-sequence 모델을 이용한 한국어 구구조 구문 분석, 한글 및 한국어 정보처리 학술대회 논문집, 2016.
- [5] 이호경, 배경만, 고영중, 격투과 워드 임베딩을 활용한 유사도 기반 대화 모델링, 한글 및 한국어 정보처리 학술대회 논문집, 2016.
- [6] Sepp Hochreiter, Jurgen Schmidhuber, LONG SHORT-TERM MEMORY, Neural Computation, 9(8), 1735-1780, 1997.
- [7] Yuichi Yamashita, Jun Tani, Emergence of Functional Hierarchy in a Multiple Timescale Neural Network Model: A Humanoid Robot Experiment, PLoS Computational Biology, 2007.
- [8] Kishore Papineni et al, BLEU: a Method for Automatic Evaluation of Machine Translation, Association for Computational Linguistics, 311-318, 2002.