



(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2025-0085282
(43) 공개일자 2025년06월12일

- | | |
|---|---|
| <p>(51) 국제특허분류(Int. Cl.)
G06N 3/0475 (2023.01) G06F 40/284 (2020.01)
G06N 3/048 (2023.01)</p> <p>(52) CPC특허분류
G06N 3/0475 (2023.01)
G06F 40/284 (2020.01)</p> <p>(21) 출원번호 10-2023-0174403
(22) 출원일자 2023년12월05일
심사청구일자 2023년12월05일</p> | <p>(71) 출원인
경희대학교 산학협력단
경기도 용인시 기흥구 덕영대로 1732 (서천동, 경희대학교 국제캠퍼스내)</p> <p>(72) 발명자
박성배
서울특별시 송파구 오금로 396, 1402호 (가락동, 에스케이허브파크)</p> <p>김소연
경기도 화성시 동탄대로24가길 30, 134동 303호 (영천동, 동탄 파크 한양수자인)
(뒷면에 계속)</p> <p>(74) 대리인
유미특허법인</p> |
|---|---|

전체 청구항 수 : 총 14 항

(54) 발명의 명칭 시퀀스 생성에 특화된 초점 손실을 사용한 응답 생성 모델 학습 장치 및 그 방법

(57) 요약

시퀀스 생성에 특화된 초점 손실을 사용한 응답 생성 모델 학습 장치 및 그 방법이 개시된다. 이 장치는 시퀀스 생성에 기반한 응답 생성 모델을 학습하는 장치이다. 이 장치는 문장 내 대상 토큰의 위치를 확인하는 위치 확인부 및 위치 확인부에 의해 확인된 대상 토큰의 위치를 사용하여 위치 초점 손실 또는 적응형 위치 초점 손실을 산출하는 손실 산출부를 포함한다. 또한, 이 장치는 손실 산출부에 의해 산출된 위치 초점 손실 또는 적응형 위치 초점 손실을 사용하여 응답 생성 모델에 대한 학습을 수행하는 학습 수행부를 더 포함한다. 여기서, 위치 초점 손실은 대상 토큰의 위치에 따라 초점 손실 또는 반초점 손실로서 작용하는 손실 함수이고, 적응형 위치 초점 손실은 응답 생성 모델의 교차 엔트로피 손실에 학습 데이터의 입력으로 추정된 출력의 역을 반영한 손실 함수이다.

대표도 - 도4

100



(52) CPC특허분류

G06N 3/048 (2023.01)

(72) 발명자

이준범

경기도 화성시 동탄대로24가길 30, 134동 303호 (영천동, 동탄 파크 한양수자인)

박규민

경기도 용인시 기흥구 서천동로43번길 11-11, 204호 (서천동)

이 발명을 지원한 국가연구개발사업

과제고유번호	1711179316
과제번호	RS-2022-00155911
부처명	과학기술정보통신부
과제관리(전문)기관명	정보통신기획평가원
연구사업명	인공지능융합혁신인재양성(R&D)
연구과제명	인공지능융합혁신인재양성(경희대학교)
기 여 율	1/2
과제수행기관명	경희대학교산학협력단
연구기간	2023.01.01 ~ 2023.12.31

이 발명을 지원한 국가연구개발사업

과제고유번호	1711198845
과제번호	IITP-2023-RS-2023-00258649
부처명	과학기술정보통신부
과제관리(전문)기관명	정보통신기획평가원
연구사업명	정보통신방송혁신인재양성
연구과제명	거대 AI 서비스 지원 클라우드 컨티뉴엄 핵심 기술개발
기 여 율	1/2
과제수행기관명	경희대학교산학협력단
연구기간	2023.07.01 ~ 2023.12.31

명세서

청구범위

청구항 1

시퀀스 생성에 기반한 응답 생성 모델을 학습하는 장치로서,
문장 내 대상 토큰의 위치를 확인하는 위치 확인부,
상기 위치 확인부에 의해 확인된 대상 토큰의 위치를 사용하여 위치 초점 손실 또는 적응형 위치 초점 손실을 산출하는 손실 산출부, 그리고
상기 손실 산출부에 의해 산출된 위치 초점 손실 또는 적응형 위치 초점 손실을 사용하여 상기 응답 생성 모델에 대한 학습을 수행하는 학습 수행부를 포함하며,
상기 위치 초점 손실은 상기 대상 토큰의 위치에 따라 초점 손실(focal loss) 또는 반초점 손실(anti-focal loss)로서 작용하는 손실 함수이고,
상기 적응형 위치 초점 손실은 상기 응답 생성 모델의 교차 엔트로피 손실에 학습 데이터의 입력으로 추정된 출력의 역을 반영한 손실 함수인,
응답 생성 모델 학습 장치.

청구항 2

제1항에 있어서,
상기 대상 토큰의 위치는 상기 응답 생성 모델의 입력으로 주어진 문장에 대한 토큰화(tokenize) 이후의 결과에 속하는 토큰의 위치를 나타내는,
응답 생성 모델 학습 장치.

청구항 3

제1항에 있어서,
상기 위치 초점 손실 및 상기 적응형 위치 초점 손실은 상기 대상 토큰의 위치에 따른 관련성과 다양성 사이의 중요도를 중재하는 위치 함수에 따라 결정되는,
응답 생성 모델 학습 장치.

청구항 4

제3항에 있어서,
상기 위치 함수는 상기 대상 토큰의 위치에 대한 선형 단조 증가 함수, 쌍곡탄젠트형 단조 증가 함수 및 역쌍곡탄젠트형 단조 증가 함수 중 하나이거나, 또는
상기 위치 함수는 상기 대상 토큰의 위치에 대한 선형 단조 감소 함수, 쌍곡탄젠트형 단조 감소 함수 및 역쌍곡탄젠트형 단조 감소 함수 중 하나인,
응답 생성 모델 학습 장치.

청구항 5

제3항에 있어서,
상기 위치 함수의 값 범위는 -1과 1 사이인 미분 함수의 값 범위이며,

상기 위치 초점 손실은,
상기 위치 함수가 -1의 값에 가까워질수록 상기 초점 손실로서 작용하는,
응답 생성 모델 학습 장치.

청구항 6

제5항에 있어서,
상기 위치 초점 손실은,
상기 위치 함수가 1의 값에 가까워질수록 상기 반초점 손실로서 작용하는,
응답 생성 모델 학습 장치.

청구항 7

제5항에 있어서,
상기 위치 초점 손실은,
상기 위치 함수가 0인 경우 상기 교차 엔트로피 손실과 동일하게 작용하는,
응답 생성 모델 학습 장치.

청구항 8

시퀀스 생성에 기반한 응답 생성 모델을 학습하는 방법으로서,
문장 내 대상 토큰의 위치를 확인하는 단계,
상기 대상 토큰의 위치를 사용하여 위치 초점 손실 또는 적응형 위치 초점 손실을 산출하는 단계, 그리고
상기 위치 초점 손실 또는 상기 적응형 위치 초점 손실을 사용하여 상기 응답 생성 모델에 대한 학습을 수행하
는 단계
를 포함하며,
상기 위치 초점 손실은 상기 대상 토큰의 위치에 따라 초점 손실 또는 반초점 손실로서 작용하는 손실
함수이고,
상기 적응형 위치 초점 손실은 상기 응답 생성 모델의 교차 엔트로피 손실에 학습 데이터의 입력으로 추정된 출
력의 역을 반영한 손실 함수인,
응답 생성 모델 학습 방법.

청구항 9

제8항에 있어서,
상기 대상 토큰의 위치는 상기 응답 생성 모델의 입력으로 주어진 문장에 대한 토큰화 이후의 결과에 속하는 토큰
의 위치를 나타내는,
응답 생성 모델 학습 방법.

청구항 10

제8항에 있어서,
상기 위치 초점 손실 및 상기 적응형 위치 초점 손실은 상기 대상 토큰의 위치에 따른 관련성과 다양성 사이의
중요도를 중재하는 위치 함수에 따라 결정되는,
응답 생성 모델 학습 방법.

청구항 11

제10항에 있어서,

상기 위치 함수는 상기 대상 토큰의 위치에 대한 선형 단조 증가 함수, 쌍곡탄젠트형 단조 증가 함수 및 역쌍곡탄젠트형 단조 증가 함수 중 하나이거나, 또는

상기 위치 함수는 상기 대상 토큰의 위치에 대한 선형 단조 감소 함수, 쌍곡탄젠트형 단조 감소 함수 및 역쌍곡탄젠트형 단조 감소 함수 중 하나인,

응답 생성 모델 학습 방법.

청구항 12

제10항에 있어서,

상기 위치 함수의 값 범위는 -1과 1 사이인 미분 함수의 값 범위이며,

상기 위치 초점 손실은,

상기 위치 함수가 -1의 값에 가까워질수록 상기 초점 손실로서 작용하는,

응답 생성 모델 학습 방법.

청구항 13

제12항에 있어서,

상기 위치 초점 손실은,

상기 위치 함수가 1의 값에 가까워질수록 상기 반초점 손실로서 작용하는,

응답 생성 모델 학습 방법.

청구항 14

제12항에 있어서,

상기 위치 초점 손실은,

상기 위치 함수가 0인 경우 상기 교차 엔트로피 손실과 동일하게 작용하는,

응답 생성 모델 학습 방법.

발명의 설명

기술 분야

[0001] 본 발명은 시퀀스 생성에 특화된 초점 손실을 사용한 응답 생성 모델 학습 장치 및 그 방법에 관한 것이다.

배경 기술

[0002] 교차 엔트로피 손실은 응답 생성을 포함한 다양한 애플리케이션에서 자동 회귀 언어 모델을 훈련하는 데 효과적인 것으로 입증되었다.

[0003] 그러나, 이는 모델이 자주 사용되는 단어를 선호하도록 강제한다. 결과적으로, 이를 응답 생성에 적용하면 응답 생성기는 응답 생성 시 빈도가 낮은 단어를 피하게 된다.

[0004] 이로 인해, 교차 엔트로피 손실은 응답 생성에서 과도한 일반 응답의 두드러진 원인으로 지적된다.

[0005] 따라서, 다양하고 관련성이 있는 응답 생성을 위한 보다 효율적인 방법이 요구된다.

발명의 내용

해결하려는 과제

[0006] 본 발명이 해결하고자 하는 과제는 예측 신뢰도에 관계없이 관련성과 다양성의 균형을 맞추는 응답을 생성하는

응답 생성 모델 학습 장치 및 그 방법을 제공하는 것이다.

과제의 해결 수단

- [0007] 상기한 바와 같은 본 발명의 과제를 달성하고, 후술하는 본 발명의 특징적인 효과를 실현하기 위한, 본 발명의 특징적인 구성은 하기와 같다.
- [0008] 본 발명의 일 측면에 따르면, 응답 생성 모델 학습 장치가 제공되며, 이 장치는,
- [0009] 시퀀스 생성에 기반한 응답 생성 모델을 학습하는 장치로서, 문장 내 대상 토큰의 위치를 확인하는 위치 확인부, 상기 위치 확인부에 의해 확인된 대상 토큰의 위치를 사용하여 위치 초점 손실 또는 적응형 위치 초점 손실을 산출하는 손실 산출부, 그리고 상기 손실 산출부에 의해 산출된 위치 초점 손실 또는 적응형 위치 초점 손실을 사용하여 상기 응답 생성 모델에 대한 학습을 수행하는 학습 수행부를 포함하며, 상기 위치 초점 손실은 상기 대상 토큰의 위치에 따라 초점 손실(focal loss) 또는 반초점 손실(anti-focal loss)로서 작용하는 손실 함수이고, 상기 적응형 위치 초점 손실은 상기 응답 생성 모델의 교차 엔트로피 손실에 학습 데이터의 입력으로 추정된 출력의 역을 반영한 손실 함수이다.
- [0010] 여기서, 상기 대상 토큰의 위치는 상기 응답 생성 모델의 입력으로 주어진 문장에 대한 토큰화(tokenize) 이후의 결과에 속하는 토큰의 위치를 나타낸다.
- [0011] 또한, 상기 위치 초점 손실 및 상기 적응형 위치 초점 손실은 상기 대상 토큰의 위치에 따른 관련성과 다양성 사이의 중요도를 중재하는 위치 함수에 따라 결정된다.
- [0012] 또한, 상기 위치 함수는 상기 대상 토큰의 위치에 대한 선형 단조 증가 함수, 쌍곡탄젠트형 단조 증가 함수 및 역쌍곡탄젠트형 단조 증가 함수 중 하나이거나, 또는 상기 위치 함수는 상기 대상 토큰의 위치에 대한 선형 단조 감소 함수, 쌍곡탄젠트형 단조 감소 함수 및 역쌍곡탄젠트형 단조 감소 함수 중 하나이다.
- [0013] 또한, 상기 위치 함수의 값 범위는 -1과 1 사이인 미분 함수의 값 범위이며, 상기 위치 초점 손실은, 상기 위치 함수가 -1의 값에 가까워질수록 상기 초점 손실로서 작용하거나, 또는 상기 위치 함수가 1의 값에 가까워질수록 상기 반초점 손실로서 작용하거나, 또는 상기 위치 함수가 0인 경우 상기 교차 엔트로피 손실과 동일하게 작용한다.
- [0014] 본 발명의 다른 측면에 따르면, 응답 생성 모델 학습 방법이 제공되며, 이 방법은,
- [0015] 시퀀스 생성에 기반한 응답 생성 모델을 학습하는 방법으로서, 문장 내 대상 토큰의 위치를 확인하는 단계, 상기 대상 토큰의 위치를 사용하여 위치 초점 손실 또는 적응형 위치 초점 손실을 산출하는 단계, 그리고 상기 위치 초점 손실 또는 상기 적응형 위치 초점 손실을 사용하여 상기 응답 생성 모델에 대한 학습을 수행하는 단계를 포함하며, 상기 위치 초점 손실은 상기 대상 토큰의 위치에 따라 초점 손실 또는 반초점 손실로서 작용하는 손실 함수이고, 상기 적응형 위치 초점 손실은 상기 응답 생성 모델의 교차 엔트로피 손실에 학습 데이터의 입력으로 추정된 출력의 역을 반영한 손실 함수이다.

발명의 효과

- [0016] 본 발명에 따르면, 예측 신뢰도에 관계없이 관련성과 다양성의 균형을 맞추는 응답을 생성할 수 있다.
- [0017] 이로 인해, 일반적인 답변 생성을 회피하고 관련있고 다양한 응답을 생성함으로써 사용자로 하여금 흥미를 유지할 수 있게 할 수 있다.

도면의 간단한 설명

- [0018] 도 1은 일반적인 시퀀스 투 시퀀스 모델의 개략적인 기능 구조도이다.
- 도 2는 본 발명의 실시예에 따른 위치 초점 손실과 다른 손실들 사이의 위치 함수에 따른 동작 비교를 나타낸 도면이다.
- 도 3은 본 발명의 실시예에 따른 위치 함수에 대한 후보 함수를 개략적으로 나타낸 도면이다.
- 도 4는 본 발명의 실시예에 따른 응답 생성 모델 학습 방법의 개략적인 흐름도이다.
- 도 5는 본 발명의 실시예에 따른 응답 생성 모델 학습 장치의 개략적인 구성을 도시한 도면이다.

발명을 실시하기 위한 구체적인 내용

- [0019] 아래에서는 첨부한 도면을 참고로 하여 본 발명의 실시예에 대하여 본 발명이 속하는 기술 분야에서 통상의 지식을 가진 자가 용이하게 실시할 수 있도록 상세히 설명한다. 그러나 본 발명은 여러 가지 상이한 형태로 구현될 수 있으며 여기에서 설명하는 실시예에 한정되지 않는다. 그리고 도면에서 본 발명을 명확하게 설명하기 위해서 설명과 관계없는 부분은 생략하였으며, 명세서 전체를 통하여 유사한 부분에 대해서는 유사한 도면 부호를 붙였다.
- [0020] 명세서 전체에서, 어떤 부분이 어떤 구성요소를 "포함"한다고 할 때, 이는 특별히 반대되는 기재가 없는 한 다른 구성요소를 제외하는 것이 아니라 다른 구성요소를 더 포함할 수 있는 것을 의미한다. 또한, 명세서에 기재된 "...부", "...기", "모듈" 등의 용어는 적어도 하나의 기능이나 동작을 처리하는 단위를 의미하며, 이는 하드웨어나 소프트웨어 또는 하드웨어 및 소프트웨어의 연관성으로 구현될 수 있다.
- [0021] 본 발명에서 설명하는 장치들은 적어도 하나의 프로세서, 메모리 장치, 통신 장치 등을 포함하는 하드웨어로 구성되고, 지정된 장소에 하드웨어와 연관성되어 실행되는 프로그램이 저장된다. 하드웨어는 본 발명의 방법을 실행할 수 있는 구성과 성능을 가진다. 프로그램은 도면들을 참고로 설명한 본 발명의 동작 방법을 구현한 명령어(instructions)를 포함하고, 프로세서와 메모리 장치 등의 하드웨어와 결합하여 본 발명을 실행한다.
- [0022] 도 1은 본 발명이 적용되는 시퀀스 투 시퀀스 모델의 개략적인 기능 구조도이다.
- [0023] 도 1에 도시된 바와 같이, 시퀀스 투 시퀀스(sequence-to-sequence) 모델은 인코더(10)로 입력되는 입력 시퀀스(예를 들어, "I am a student")를 컨텍스트(20)를 통해 출력 시퀀스(예를 들어, "나는 학생입니다")로 변환하여 디코더(30)를 통해 출력하는 모델이다.
- [0024] 응답 생성기에서는 미리 훈련된 변환기(transformer)를 전술한 시퀀스 투 시퀀스 모델로 채택하고 교차 엔트로피 손실을 목적 함수로 채택하는 것이 일반적이다.
- [0025] V 를 응답 생성을 위한 어휘로 설정하고, $Y = \langle y_1, \dots, y_n \rangle$ 및 $P = \langle p_1, \dots, p_n \rangle$ 를 각각 출력 토큰에 대한 참(true, 정답) 분포 및 모델 분포라고 가정하면, 여기서 $|V| = n$ 이며, 이는 응답 생성기에 의한 출력 토큰은 V 의 n 개의 가능한 토큰 중 하나이고, 또한 Y 는 원핫(one-hot) 표현이다.
- [0026] 이 경우, 교차 엔트로피 손실 L_{CEL} 은 다음의 [수학식 1]과 같이 정의될 수 있다.
- [0027] [수학식 1]
- $$L_{CEL}(P, Y) = - \sum_{i=1}^n y_i \log(p_i)$$
- [0028]
- [0029] 여기서, y_i 는 학습 데이터의 i 번째 정답이고, p_i 는 학습 데이터의 입력으로 추정된 i 번째 출력을 나타낸다.
- [0030] 전술한 y_i 중에서 하나만, 즉 y_i 만 1이고, 나머지는 0이다. 따라서, 전술한 [수학식 1]은 다음의 [수학식 2]와 같이 재정의될 수 있다.
- [0031] [수학식 2]
- $$L_{CEL}(P, Y) = - \log(p_i)$$
- [0032]
- [0033] 이러한 교차 엔트로피 손실(L_{CEL})은 신뢰도가 낮은 예측을 강조하지만, 그러나 여전히 $p_i \gg 0.5$ 인 쉬운 샘플의 효과를 과장한다.
- [0034] 한편, 초점 손실(focal loss)은 객체 검출에서 데이터 불균형을 완화하기 위해 설계된 손실이다. 이는 모델이 작지만 잘못된 영역을 무시하지 않도록 유도하는 변조 요소를 도입하여 문제를 해결한다.
- [0035] 그러나, 이러한 초점 손실은 초점 손실에 의해 과도하게 페널티를 받는 낮은 신뢰도 예측이 오히려 시퀀스 수준 검색을 손상시키기 때문에, 빔 탐색을 사용하는 자동 회귀 모델에 적합하지 않다는 것이 잘 알려져 있다.
- [0036] 결과적으로, 응답 생성기가 초점 손실로 훈련되면, 관련성은 있지만 덜 다양한 응답을 생성하게 된다.

- [0037] 모든 p_t 에 대한 신뢰도가 낮은 예측의 효과를 강조하기 위해, 초점 손실은 변조 인자 $(1 - p_t)^\gamma$ 를 도입한다. 즉, 초점 손실 L_{FL} 은 다음의 [수학식 3]과 같이 정의될 수 있다.
- [0038] [수학식 3]
- $$L_{FL}(P, Y) = -(1 - p_t)^\gamma \log(p_t)$$
- [0039]
- [0040] 여기서 $\gamma > 0$ 이다.
- [0041] 전술한 [수학식 3]에서 $(1 - p_t)$ 와 γ 는 모두 양수이므로, 초점 손실(L_{FL})은 항상 교차 엔트로피 손실(L_{CEL})보다 작음을 알 수 있다.
- [0042] 그러나, 교차 엔트로피 손실에 대한 초점 손실에 의한 손실 감소는 낮은 p_t 에서는 작고, 높은 p_t 에서는 크다. 즉, 초점 손실은 p_t 가 높은 예측에 더 민감함을 알 수 있다. 결과적으로, 응답 생성 모델은 골든 토큰을 선호할 수 있다.
- [0043] 전술한 초점 손실은 신뢰도가 낮은 예측에 큰 페널티를 적용하여 출력 분포의 엔트로피를 낮춘다. 낮은 엔트로피는 일반적으로 분류 작업에서 모델의 성공적인 훈련을 의미하지만, 빔 탐색을 기반으로 하는 자동 회귀 모델에서 모델 예측에 대한 높은 신뢰도를 의미하기도 한다. 모델은 빔 탐색을 통한 추론 중에 높은 신뢰도의 예측을 선호하므로, 제한된 토큰으로 구성된 높은 확률의 응답이 생성된다.
- [0044] 한편, 전술한 바와 같이, 응답 생성기가 초점 손실로 훈련되면, 관련성은 있지만 덜 다양한 응답을 생성하게 되므로, 이러한 문제에 대한 해결책으로, 모델이 예측을 과신하지 않도록 하는 반초점 손실(anti-focal loss)이 제안된다.
- [0045] 반초점 손실은 신뢰도가 낮은 예측에 더 적은 페널티를 부과하여 이러한 문제를 해결한다. 즉, 반초점 손실 L_{AFL} 은 다음의 [수학식 4]와 같이 정의될 수 있다.
- [0046] [수학식 4]
- $$L_{AFL}(P, Y) = -(1 + \alpha \cdot p_t)^\gamma \log(p_t)$$
- [0047]
- [0048] 여기서 α 는 낮은 확률로 예측을 더 강조하기 위한 양의 스케일링 인자($\alpha > 0$)이다. 즉, 모델이 반초점 손실로 훈련되는 경우, 모델에 의한 출력 엔트로피는 초점 손실로 훈련된 모델의 출력 엔트로피보다 더 클 것이다. 따라서, 다양한 토큰을 선택할 가능성이 높아짐을 알 수 있다.
- [0049] 그러나, 전술한 반초점 손실은 높은 신뢰도와 낮은 신뢰도 예측 간의 차이를 줄이기 때문에, 모델 예측이 과신할 가능성이 적다.
- [0050] 결과적으로, 모델의 반응은 더욱 다양해졌지만 관련성은 낮아졌음을 알 수 있다. 결과적으로, 관련성과 다양성은 모두 응답 생성에서 중요한 특징이지만, 초점 손실과 반초점 손실은 모두 특징 중 하나를 놓치고 있다.
- [0051] 따라서, 관련성과 다양성 사이의 균형을 유지하기 위해 초점 손실과 반초점 손실과는 다른 손실이 제공되어야 한다.
- [0052] 이하, 본 발명의 실시예에 따라 일반적인 답변 생성을 회피하기 위한 시퀀스 생성에 특화된 위치 초점 손실 및 적응형 위치 초점 손실에 대해 설명한다.
- [0053] 먼저, 위치 초점 손실에 대해 설명한다.
- [0054] 응답 생성에 대한 대부분의 손실은 대상 토큰의 상대적 위치에 의존하지 않는다. 그러나, 응답의 관련성과 다양성 사이에는 트레이드오프가 있기 때문에, 토큰의 위치가 손실로 고려되지 않는 한 응답의 높은 관련성과 다양성을 달성하기는 어렵다.
- [0055] 위치 초점 손실은 응답을 생성할 때 모든 토큰 위치에서 다양성과 관련하여 관련성의 상대적 중요성을 고려한다. 즉, P , Y 외에 대상 토큰의 위치인 t 라는 추가 파라미터가 사용된다. 그러면, 전술한 [수학식 3]에

서 정의된 초점 손실을 바탕으로 위치 초점 손실(L_{PFL})이 다음의 [수학식 5]와 같이 정의될 수 있다.

[0056] [수학식 5]

$$L_{PFL}(P, Y, t) = -(1 + \alpha M(t) \cdot p_t)^\gamma \log(p_t)$$

[0058] 여기서, 위치 함수인 $M(t)$ 는 토큰 위치(t)에 따른 관련성과 다양성 사이의 중요도를 중재하는 함수이다.

[0059] $M(t)$ 는 값 범위가 -1과 1 사이인 모든 미분 함수일 수 있다.

[0060] $M(t) = -1$ 이면, $L_{PFL} = -(1 - \alpha \cdot p_t)^\gamma \log(p_t) = L_{FL}$ 이다. 즉, 음의 $M(t)$ 는 전술한 [수학식 3]에서의 초점 손실처럼 동작함을 알 수 있다.

[0061] 마찬가지로, $M(t) = 1$ 이면, $L_{PFL} = -(1 + \alpha \cdot p_t)^\gamma \log(p_t) = L_{AFL}$ 이다. 즉, 양의 $M(t)$ 는 전술한 [수학식 4]에서의 반초점 손실처럼 동작함을 알 수 있다.

[0062] 첨부한 도 2는 위치 초점 손실('PFL'로 표시됨)이 교차 엔트로피 손실('CEL'로 표시됨), 초점 손실('FL'로 표시됨) 및 반초점 손실('AFL'로 표시됨)과 비교하여 어떻게 동작하는지를 보여준다.

[0063] 도 2의 (a)를 참조하면, $M(t)$ 가 -0.9인 경우, 위치 초점 손실은 초점 손실보다 약간 높으며, 이는 초점 손실과 거의 유사하지만 $M(t) = -0.9 > -1.0$ 이므로 다양성의 영향이 줄어든다는 것을 의미한다.

[0064] 반대로, 도 2의 (c)를 참조하면, $M(t) = 0.9$ 인 경우, 위치 초점 손실은 반초점 손실보다 약간 낮으며, 이는 반초점 손실과 유사하지만 $M(t) = 0.9 < 1.0$ 이므로 다양성의 효과가 약화된 것을 의미한다.

[0065] 마지막으로, 도 2의 (b)를 참조하면, $M(t) = 0$ 인 경우, 위치 초점 손실은 교차 엔트로피 손실과 정확히 일치함을 나타낸다.

[0066] 이와 같이, 본 발명의 실시예에 따른 위치 초점 손실이 적용되는 경우, 모델은 대상 토큰의 위치에 따라 관련성 또는 다양성을 유연하게 강조할 수 있다.

[0067] 한편, $0.5 < p_t < 1$ 인 예측을 가정한다. 아직 $p_t \neq 1$ 이므로, 올바른 예측이라 하더라도 위치 초점 손실(L_{PFL}) 계산에 미치는 영향은 크다.

[0068] 결과적으로, 위치 초점 손실(L_{PFL})에는 두 가지 단점이 있다. 하나는, $0 \ll M(t) < 1$ 일 때 손실이 작아야 함에도 불구하고 p_t 가 크면 올바른 예측의 손실이 크다는 것이다. 다른 하나는, $M(t)$ 가 클 때 위치 초점 손실(L_{PFL})과 초점 손실(L_{FL})사이의 불일치도 크다는 것이다.

[0069] 예를 들어, 도 2의 (c)를 참조하면, $p_t = 0.6$ 일 때, 위치 초점 손실(PFL, 빨간색 곡선)과 초점 손실(FL, 주황색 곡선) 사이의 간격이 매우 크다. 결과적으로, 전체 응답에 대한 손실을 계산할 때, 위치 초점 손실(L_{PFL})은 음수 $M(t)$ 를 무시하는 경향이 있으며, 이로 인해 위치 초점 손실(L_{PFL})은 그들의 균형을 맞추는 대신에 관련성보다 다양성을 선호하게 된다.

[0070] 이러한 문제에 대한 해결수단으로, 본 발명의 실시예에서는 전술한 [수학식 2]에 따른 교차 엔트로피 손실에 p_t 의 역을 반영하는 적응형 위치 초점 손실을 제공한다. 즉, 적응형 위치 초점 손실은 p_t 에 반비례하는 계수를 전술한 [수학식 2]에 따른 교차 엔트로피 손실에 덧붙이는 것을 지칭한다. 이러한 적응형 위치 초점 손실(L_{APFL})은 다음의 [수학식 6]과 같이 정의될 수 있다.

[0071] [수학식 6]

$$L_{APFL}(P, Y, t) = -\left(\frac{1}{p_t + \beta}\right)^{\frac{M(t)}{2}} \log(p_t)$$

[0073] 여기서, $0 < \beta \leq 0.5$ 는 p_t 의 유효 범위를 결정하는 하이퍼파라미터이다.

[0074] $L_{APFL} \propto \frac{1}{p_t}$ 이므로 정확한 예측을 위해 손실이 작아진다.

[0075] $p_t = 1 - \beta$ 이면, $\frac{1}{p_t + \beta} = \frac{1}{1 - \beta + \beta} = 1$ 이다. 따라서, 적응형 위치 초점 손실(L_{APFL})은 교차 엔트로피 손실(L_{CEL})과 동일하다.

[0076] $\frac{1}{p_t + \beta}$ 의 상한은 $\frac{1}{1 + \beta}$ 이다. $\beta \leq 0.5$ 이므로, $\sqrt{\frac{1}{1 + \beta}} \approx 1$ 이어서 무시될 수 있다. 따라서, $p_t > 1 - \beta$ 인 경우에도, 적응형 위치 초점 손실(L_{APFL})은 교차 엔트로피 손실(L_{CEL})과 유사하다.

[0077] 결과적으로, $0 \leq p_t < 1 - \beta$ 인 경우에는 $\frac{1}{p_t + \beta}$ 는 손실 계산에 반영되지만, $1 - \beta \leq p_t \leq 1$ 인 경우에는 그렇지 않다.

[0078] 첨부한 도 3은 전술한 위치 함수 $M(t)$ 에 대한 후보 함수를 개략적으로 나타낸 도면이다.

[0079] 단조롭게 증가하는 함수는 응답 생성기가 초기 위치에서 골든 토큰을 학습한 다음 이후 위치에서 더 다양한 토큰을 학습할 수 있게 한다. 즉, 그들은 작은 t 에 대해 작은 값을 갖고 큰 t 에 대해 큰 값을 갖는다. 그들에 대한 근거는 의미론적으로 사용자 쿼리에 따라 정확한 토큰으로 시작함으로써 좋은 응답이 생성될 수 있다는 것이다.

[0080] 본 발명의 실시예에서 사용되는 단조 증가 함수는 다음의 [수학식 7]과 같이 나타낼 수 있다.

[0081] [수학식 7]

[0082] 선형 함수 :
$$M_{linc}(t) = \frac{1}{l-1}(2t - l - 1)$$

[0083] 쌍곡탄젠트형 함수 :
$$M_{tanhinc}(t) = \tanh\left(\delta t - \frac{l+1}{2}\right)$$

[0084] 역쌍곡탄젠트형 함수 :
$$M_{itanhinc}(t) = \tanh^{-1}\left(\frac{2}{l+\epsilon}\left(t - \frac{l+1}{2}\right)\right)$$

[0085] 여기서, l 은 응답 길이이고, δ 는 가파른 정도를 조정하는 하이퍼파라미터이며, ϵ 는 $M(t)$ 가 무한대로 가는 것을 방지하는 매우 작은 숫자이다.

[0086] 전술한 쌍곡탄젠트형 함수($M_{tanhinc}(t)$) 및 역쌍곡탄젠트형 함수($M_{itanhinc}(t)$)는 선형 함수($M_{linc}(t)$)보다 관련성이나 다양성의 영향을 받는 토큰의 개수를 더 적게 또는 더 많이 만든다.

[0087] 또한, $M(t)$ 에 대해 단조 감소 함수도 가능하며, 이러한 함수는 다음의 [수학식 8]과 같이 나타낼 수 있다.

[0088] [수학식 8]

[0089] 선형 함수 :
$$M_{ldec}(t) = -\frac{1}{l-1}(2t - l - 1)$$

[0090] 쌍곡탄젠트형 함수 :
$$M_{tanhdec}(t) = -\tanh\left(\delta t - \frac{l+1}{2}\right)$$

[0091] 역쌍곡탄젠트형 함수 :
$$M_{itanhdec}(t) = -\tanh^{-1}\left(\frac{2}{l+\epsilon}\left(t - \frac{l+1}{2}\right)\right)$$

[0092] 전술한 함수들은 응답의 초기 위치에서 관련성보다 다양성에 더 많은 중요성을 부과하지만, 생성이 진행됨에 따라 관련성이 더 중요해진다.

[0093] 이하, 본 발명의 실시예에 따른 위치 초점 함수와 적응형 위치 초점 함수에 대한 평가를 위한 실험 설정에 대해 설명한다.

[0094] 개방형 도메인 응답 생성을 위한 세 가지 벤치마크 데이터 세트가 손실의 평가에 사용되며, DailyDialog, Cornell Movie-Dialogs Corpus 및 Ubuntu Dialogue Corpus이다. 모든 데이터 세트는 다중 턴 대화(multi-turn dialogue)로 구성되므로, 대화는 실험을 위해 단일 턴 대화로 변환된다.

[0095] DailyDialog 및 Ubuntu Dialogue Corpus는 훈련, 검증 및 테스트 세트의 사전 정의된 분할을 가진다. 반면에, Cornell Movie-Dialogs Corpus는 이러한 정보가 없어 랜덤 셔플링 후 0.9:0.05:0.05 비율로 분할된다.

[0096] 다음의 [표 1]은 실험을 위한 전처리 후 데이터 세트에 대한 간단한 통계를 요약한 것이다.

[0097] [표 1]

	Daily	Cornell	Ubuntu
훈련 인스턴스 개수	64,934	144,448	1,730,883
검증 인스턴스 개수	6,069	18,056	37,239
테스트 인스턴스 개수	5,740	18,056	36,237
평균 쿼리 길이	13.59	11.28	20.11
평균 응답 길이	14.19	11.63	15.18
어휘 크기	20,704	36,626	44,365

[0098]

[0099] [표 1]을 참조하면, DailyDialog, Cornell Movie-Dialogs 및 Ubuntu Dialogue Corpus의 평균 쿼리 길이는 13.59, 11.28 및 20.11이고, 평균 응답 길이는 14.19, 11.63 및 15.18이다. 고유 토큰의 개수(어휘 크기)는 각각 20,704, 36,626, 44,365이다.

[0100] BART(Bidirectional and Auto-Regressive Transformers)와 T5는 많은 시퀀스 투 시퀀스 작업에서 좋은 성능을 보여주었기 때문에 본 발명의 실시예에 따른 손실의 성능을 조사하기 위한 기본 응답 생성기로 채택되었다. facebook/bart-large는 BART의 구현으로 사용되고, t5/base는 T5의 구현으로 사용되었다. 따라서, 모든 설정은 bart-large 및 t5/base의 설정을 따른다.

[0101] 훈련 및 검증 세트의 배치 크기는 48이고 학습 속도는 $2e^{-5}$ 이다. AdamW 최적화기는 $\beta_1 = 0.9$, $\beta_2 = 0.999$ 및 $\epsilon = 1e-8$ 를 사용하도록 채택되었다. 손실에 대한 파라미터는 $\alpha = 1$, $\beta = 0.5$, $\gamma = 1$ 이고, $M(t)$ 에 대한 손실의 파라미터는 $\delta = 1$ 및 $\epsilon = 0.1$ 이다.

[0102] 응답 생성 성능은 관련성과 다양성이라는 두 가지 측면에서 측정된다.

[0103] 관련성을 측정하기 위해 BLEU(Bilingual Evaluation Understudy)-1, BLEU-2 및 Coherence(Coh)가 채택되었으며, Distinct 및 저-빈도 토큰 비율(LF)은 다양성을 측정하는 데 사용된다. Coh는 코사인 유사성을 통해 쿼리와 생성된 응답 사이의 시맨틱 거리를 계산하므로, 쿼리에 대한 응답의 관련성을 측정한다. Distinct는 생성된 전체 n-gram 중 고유한 n-gram의 비율이고, dist-3과 dist-4가 실제로 사용된다. LF는 생성된 모든 토큰 중에서 빈도가 낮은 토큰의 비율을 측정하며, 여기서 낮은 빈도의 임계값은 공정한 비교를 위해 100으로 설정된다.

[0104] 전술한 설정에 따른 실험 결과는 다음과 같다.

[0105] 다음의 [표 2]는 어느 $M(t)$ 가 Cornell 데이터 세트에서 BART를 사용하여 위치 초점 손실(L_{PFL}) 및 적응형 위치 초점 손실(L_{APFL})에 대해 최고의 성능을 달성하는 지를 보여준다.

[0106] [표 2]

	$M(t)$	관련성		다양성	
		BLEU-1	BLEU-2	Dist-3	Dist-4
L_{PFL}	M_{tinc}	22.91	3.35	24.73	32.03
	$M_{tanhinc}$	22.77	3.14	24.05	31.21
	$M_{itanhinc}$	23.23	3.31	23.13	30.16
	M_{tdec}	21.12	2.25	24.43	31.54
	$M_{tanhdec}$	22.77	3.23	21.75	31.68
	$M_{itanhdec}$	22.64	3.25	25.49	33.06
L_{APFL}	M_{tinc}	23.32	3.40	24.42	31.86
	$M_{tanhinc}$	23.96	3.63	26.95	35.18
	$M_{itanhinc}$	23.96	3.32	26.69	34.41
	M_{tdec}	23.04	3.46	24.25	31.30
	$M_{tanhdec}$	23.12	3.38	23.32	30.21
	$M_{itanhdec}$	22.92	3.38	25.58	33.23

[0107]

[0108] 전술한 [표 2]에서 주목해야 할 두 가지 사항이 있다. 하나는, 적응형 위치 초점 손실(L_{APFL})의 쌍곡탄젠트형 단조 증가 함수($M_{tanhinc}$)가 가장 높은 BLEU와 Dist를 보고하고 있는 것이고, 다른 하나는, 위치 함수 $M(t)$ 유형에 관계없이 적응형 위치 초점 손실(L_{APFL})이 위치 초점 손실(L_{PFL})보다 우수하다는 것이다.

[0109] 적응형 위치 초점 손실(L_{APFL})보다 위치 초점 손실(L_{PFL})의 성능이 낮은 것은 두 가지 단점 때문이다. 첫 번째 단점은, 올바른 예측을 위한 손실이 위치 초점 손실(L_{PFL})에서 너무 높게 측정된다는 점이며, 두 번째 단점은, 위치 초점 손실(L_{PFL})이 음의 $M(t)$ 값에 대한 손실을 무시하는 경향이 있다는 것이다. 이로 인해, 위치 초점 손실(L_{PFL})에 의한 관련있는 반응보다 다양한 반응이 선호되며, 이는 적응형 위치 초점 손실(L_{APFL})보다 선형 단조 증가 함수(M_{tinc}), 선형 단조 감소 함수(M_{tdec}) 및 쌍곡탄젠트형 단조 증가 함수($M_{tanhdec}$)에 대한 다양성이 더 높아진다. 따라서, 쌍곡탄젠트형 단조 증가 함수($M_{tanhinc}$) 및 적응형 위치 초점 손실(L_{APFL})이 모든 실험에서 사용된다.

[0110] 다음의 [표 3]에서는 기본 응답 생성기로서 BART와 T5를 비교한다.

[0111] [표 3]

모델	관련성		다양성	
	BLEU-1	BLEU-2	Dist-3	Dist-4
BART	23.29	3.63	26.94	35.18
T5-RG	22.15	2.16	25.32	34.15
T5-QA	22.66	2.37	25.17	33.30
T5-S	23.07	2.55	26.72	35.15

[0112]

[0113] [표 3]을 참조하면, 두 모델의 성능은 쌍곡탄젠트형 단조 증가 함수($M_{tanhinc}$) 및 적응형 위치 초점 손실(L_{APFL})로 훈련된 후 측정된다.

[0114] T5는 프롬프트로 사전 훈련되었으므로, 특정 작업에 맞게 미세 조정하려면 적절한 프롬프트 설정도 필요하다. 그러나, T5는 응답 생성 프롬프트로 사전 훈련되지 않았다. 따라서, T5의 성능은 다양한 프롬프트에 대해 측정된다. 사용되는 프롬프트는 응답 생성을 위한 새로운 프롬프트와 질의 답변 및 요약에 대한 두 개의 기존 프롬프트이다.

[0115] 전술한 [표 3]에서, T5-RG, T5-QA, T5-S는 T5가 실제로 사용하는 프롬프트로 구분된다. [표 3]에 따르면, BART는 T5 프롬프트 유형에 관계없이 관련성과 다양성 모두에서 T5보다 성능이 뛰어나다. 이는 T5가 사전 훈련을 위한 작업 중심 전략을 가지고 있지만 응답 생성은 T5 사전 훈련을 위한 작업에 포함되지 않기 때문이다. 따라서, BART가 모든 실험에 대한 응답 생성을 위한 모델로 사용된다.

[0116] 다음의 [표 4]는 응답 생성을 위한 손실 계산에 있어 위치 정보의 효율성을 입증한다.

[0117] [표 4]

메트릭	관련성			다양성		
	BLEU-1	BLEU-2	Coh.	Dist-3	Dist-4	LF
Cornell Movie-Dialogs Corpus						
CEL	22.78	3.34	0.62	24.88	32.51	13.44
FL	23.50	3.54	0.65	24.43	31.80	13.65
AFL	22.74	3.33	0.63	26.43	34.13	14.59
PFL	23.33	3.31	0.63	23.13	30.16	13.29
APFL	23.96	3.63	0.66	26.95	35.18	14.24
DailyDialog						
CEL	28.60	8.33	0.59	39.66	53.46	26.68
FL	28.94	8.54	0.64	39.68	53.66	26.66
AFL	28.71	8.25	0.59	40.41	54.33	27.05
PFL	28.87	8.51	0.63	40.08	54.03	26.78
APFL	28.95	8.83	0.64	43.43	58.87	28.87
Ubuntu Dialogue Corpus						
CEL	16.59	3.05	0.50	20.13	30.16	12.15
FL	16.63	3.04	0.54	20.09	31.01	12.22
AFL	16.43	2.96	0.52	21.54	33.29	12.96
PFL	16.79	3.06	0.54	20.14	30.52	12.16
APFL	16.99	3.10	0.55	21.69	32.87	12.90

[0118]

[0119]

전술한 [표 4]를 참조하면, 모든 데이터 세트에서, 초점 손실(FL)의 강도는 관련성에 있으며, 반초점 손실(AFL)은 더 높은 다양성을 달성한다. 초점 손실(FL)은 교차 엔트로피 손실(CEL), 반초점 손실(AFL)보다 높은 관련성을 가지지만, 교차 엔트로피 손실(CEL)과도 유사하거나 낮은 다양성을 보인다. 특히, Cornell Movie-Dialogs Corpus 및 DailyDialog에서, 그의 BLEU 및 Coh가 위치 초점 손실(PFL)의 것보다 높으며, Ubuntu Dialogue Corpus의 위치 초점 손실(PFL)의 것과 경쟁한다. 이는 초점 손실(FL)이 신뢰도가 낮은 예측에 과도한 패널티를 할당하기 때문이다. 반면에, 반초점 손실(AFL)의 관련성은 교차 엔트로피 손실(CEL)의 것보다 다양성이 높음에도 불구하고 교차 엔트로피 손실(CEL)의 관련성보다 낮다.

[0120]

전술한 [표 4]는 위치 초점 손실(PFL)의 뚜렷한 한계를 보여준다. Cornell Movie-Dialogs Corpus에서, 위치 초점 손실(PFL)은 BLEU-2에서 3.31로 표시되며, 이는 교차 엔트로피 손실(CEL)보다 0.03 낮다. 동시에, Dist-3, Dist-4 및 LF는 각각 23.13, 30.16, 13.29로 교차 엔트로피 손실(CEL)보다 1.75, 1.35, 및 0.15 낮다. 이는 위치 초점 손실(PFL)이 올바른 예측에 대해 높은 손실을 제공하므로 모델이 최적으로 훈련될 수 없기 때문이다. 결과적으로, 위치 초점 손실(PFL)은 교차 초점 손실(CEL)보다 낮은 성능을 보인다.

[0121]

DailyDialog에서, 위치 초점 손실(PFL)의 관련성 성능은 BLEU-1의 28.87, BLEU-2의 8.51, 및 Coh의 0.63이다. 이러한 성능은 교차 엔트로피 손실(CEL)의 것보다 높지만 초점 손실(FL)의 것보다는 낮다. 반면에, Dist-3, Dist-4 및 LF는 각각 0.08, 54.03, 26.78로 교차 엔트로피 손실(CEL)과 초점 손실(FL)의 것보다 높다. 이는 PFL의 $M(t)$ 가 양수일 때 $M(t)$ 가 음수일 때보다 항상 더 큰 손실을 가지기 때문이다. 이는 음의 $M(t)$ 를 쉽게 무시하게 만든다. 결과적으로, 위치 초점 손실(PFL)은 관련성보다 다양성을 선호하므로, 초점 손실(FL)보다 관련성은 낮지만 다양성은 높다.

[0122]

Ubuntu Dialogue Corpus에서, 위치 초점 손실(PFL)은 교차 엔트로피 손실(CEL) 및 초점 손실(FL)보다 더 높은 관련성과 다양성을 보여준다. 하지만, 성능은 아직 적응형 위치 초점 손실(APFL)의 성능보다 낮다. 이는 위치 초점 손실(PFL)에 의한 모델이 최적으로 훈련되지 않았음을 의미한다.

[0123]

전술한 [표 4]의 마지막 참고 사항은 본 발명의 실시예에 따른 적응형 위치 초점 손실(APFL)이 모든 데이터 세트의 모든 메트릭에 대해 모든 경쟁자보다 성능이 뛰어나다는 것이다.

[0124]

전술한 바와 같이, 초점 손실(FL)은 교차 엔트로피 손실(CEL)과 유사한 다양성을 보이지만, 높은 관련성을 보이며, 반초점 손실(AFL)은 교차 엔트로피 손실(CEL)과 유사한 관련성을 보이지만, 높은 다양성을 보인다.

[0125]

초점 손실(FL)과 반초점 손실(AFL)의 장점을 모두 활용하는 적응형 위치 초점 손실(APFL)은 Cornell Movie-Dialogs 코퍼스에서 각각 BLEU-1, BLEU-2, Coh의 23.96, 3.63, 0.66을 달성한다. 이러한 성능은 교차 엔트로피 손실(CEL)의 성능보다 1.18, 0.29, 0.04 더 높다. 실제로, 적응형 위치 초점 손실(APFL)은 모든 손실 중에서 관련성이 가장 좋다.

[0126]

또한, 적응형 위치 초점 손실(APFL)은 각각 Dist-3, Dist-4, LF의 26.95, 35.18, 14.24로 교차 엔트로피 손실(CEL)에 비해 2.08, 2.53, 0.60 높게 나타났다. 적응형 위치 초점 손실(APFL)은 초점 손실(FL), 반초점 손실(AFL), 위치 초점 손실(PFL) 및 교차 엔트로피 손실(CEL)보다 성능이 뛰어나다. 즉, 다양성 속에서도 최고라는 것이다. 비슷한 관찰이 다른 두 데이터 세트에서도 발견되었다.

- [0127] 이러한 결과는 적응형 위치 초점 손실(APFL)이 각 토큰 위치에서 적절한 전략을 취함으로써 관련성과 다양성 사이의 트레이드오프를 최소화하고 위치 초점 손실(PFL)의 문제를 충분히 해결한다는 것을 의미한다.
- [0128] 이하에서는 전술한 설명을 참조하여 본 발명의 실시예에 따른 응답 생성 모델 학습 장치에 대해 설명한다.
- [0129] 도 4는 본 발명의 실시예에 따른 응답 생성 모델 학습 장치의 개략적인 블록 구성도이다.
- [0130] 도 4에 도시된 바와 같이, 본 발명의 실시예에 따른 응답 생성 모델 학습 장치(100)는 위치 확인부(110), 손실 산출부(120) 및 학습 수행부(130)를 포함한다.
- [0131] 위치 확인부(110)는 대상 토큰의 위치를 확인한다. 여기서, 대상 토큰의 위치는 응답 생성 모델의 입력으로 주어진 문장에 대한 토큰화(tokenize) 이후 토큰화된 결과에 속하는 토큰의 위치를 나타낸다. 전술한 도 1에서의 예를 들면, "I am a student"가 토큰화된 후 토큰화된 결과가 예를 들어 [I, am, a, stud, #ent]라고 하면, 해당 결과에서 토큰 'I'의 위치는 1이고, 'am'의 위치는 2이며, 'a'의 위치는 3이고, 'stud'의 위치는 4이며, '#ent'의 위치는 5가 된다.
- [0132] 손실 산출부(120)는 위치 확인부(110)에 의해 확인된 대상 토큰의 위치를 사용하여 위치 초점 손실 또는 적응형 위치 초점 손실을 산출한다. 여기서, 위치 초점 손실은 전술한 [수학식 5]에 따라 산출될 수 있고, 적응형 위치 초점 손실은 전술한 [수학식 6]에 따라 산출될 수 있으므로, 여기에서는 구체적인 설명을 생략한다.
- [0133] 학습 수행부(130)는 손실 산출부(120)에 의해 산출된 초점 손실 또는 적응형 위치 초점 손실을 사용하여 응답 생성 모델에 대한 학습을 수행한다.
- [0134] 다음, 본 발명의 실시예에 따른 응답 생성 모델 학습 방법에 대해 설명한다.
- [0135] 도 5는 본 발명의 실시예에 따른 응답 생성 모델 학습 방법의 개략적인 흐름도이다. 도 5에 도시된 본 발명의 실시예에 따른 응답 생성 모델 학습 방법은 전술한 도 4를 참조하여 설명한 응답 생성 모델 학습 장치(100)에 의해 수행될 수 있다.
- [0136] 도 5를 참조하면, 먼저, 위치 확인부(110)는 대상 토큰의 위치를 확인한다(S110). 여기서, 대상 토큰의 위치는 응답 생성 모델의 입력으로 주어진 문장에 대한 토큰화 이후 토큰화된 결과에 속하는 토큰의 위치를 나타낸다.
- [0137] 다음, 손실 산출부(120)는 상기 단계 S110에서 확인된 대상 토큰의 위치를 사용하여 위치 초점 손실 또는 적응형 위치 초점 손실을 산출한다(S120). 여기서, 위치 초점 손실은 전술한 [수학식 5]에 따라 산출될 수 있고, 적응형 위치 초점 손실은 전술한 [수학식 6]에 따라 산출될 수 있다.
- [0138] 그 후, 학습 수행부(130)는 상기 단계 S120에서 산출된 초점 손실 또는 적응형 위치 초점 손실을 사용하여 응답 생성 모델에 대한 학습을 수행한다(S130).
- [0139] 다음, 본 발명의 다른 실시예에 따른 응답 생성 모델 학습 장치에 대해 설명한다.
- [0140] 도 6은 본 발명의 다른 실시예에 따른 응답 생성 모델 학습 장치(200)의 개략적인 구성을 도시한 도면이다.
- [0141] 도 6에 도시된 바와 같이, 본 발명의 실시예에 따른 응답 생성 모델 학습 장치(200)는 적어도 하나의 프로세서(210), 메모리(220), 통신기(230), 입출력기(240) 및 통신 버스(250)를 포함한다.
- [0142] 프로세서(210)는 범용 CPU(Central Processing Unit), 마이크로프로세서, ASIC(Application-Specific Integrated Circuit), 또는 본 출원의 해결수단에서 프로그램 실행을 제어하기 위한 하나 이상의 집적 회로일 수 있다.
- [0143] 메모리(220)는 본 발명의 실시예에 따른 응답 생성 모델 학습을 위한 정보를 저장한다.
- [0144] 구체적으로, 메모리(220)는 코드의 집합을 저장하도록 추가로 구성되고, 그 코드는 다음과 같은 프로세스를 실행하기 위해 프로세서(210)를 제어하는 데 사용된다. 이러한 프로세스는, 대상 토큰의 위치를 확인하는 프로세스, 확인된 대상 토큰의 위치를 사용하여 위치 초점 손실 또는 적응형 위치 초점 손실을 산출하는 프로세스, 산출된 초점 손실 또는 적응형 위치 초점 손실을 사용하여 응답 생성 모델에 대한 학습을 수행하는 프로세스 등을 포함한다. 여기서, 위치 초점 손실은 전술한 [수학식 5]에 따라 산출될 수 있고, 적응형 위치 초점 손실은 전술한 [수학식 6]에 따라 산출될 수 있으므로, 여기에서는 구체적인 설명을 생략한다.
- [0145] 메모리(220)는 ROM(Read-Only Memory) 또는 명령을 저장할 수 있는 다른 유형의 정적 저장 장치, 또는 RAM(Random Access Memory) 또는 정보 및 명령을 저장할 수 있는 다른 유형의 동적 저장 장치일 수 있거나, 또

는 EEPROM(Electrically Erasable Programmable Read-Only Memory), CD-ROM(Compact Disc Read-Only Memory) 또는 다른 콤팩트 디스크 저장 장치 또는 광 디스크 저장 장치(압축 광 디스크, 레이저 디스크, 광 디스크, 디지털 다용도 디스크, 블루레이 디스크 등을 포함함), 자기 디스크 저장 매체 또는 다른 자기 저장 장치, 또는 명령 또는 데이터 구조의 형태로 예상 프로그램 코드를 운반하거나 저장할 수 있으면서 컴퓨터에 의해 액세스될 수 있는 임의의 다른 매체일 수 있으며, 이것은 제한되지 않는다. 메모리(220)는 독립적으로 존재할 수 있으며, 통신 버스(250)에 의해 프로세서(210)에 연결된다.

[0146] 통신기(230)는 외부의 다른 장치와 유무선 통신을 수행하며, 다양한 유선 또는 무선 통신 기술로 구현될 수 있다. 예를 들어, 통신기(230)는 인터넷과 연결되어 서비스를 제공하는 경우 인터넷에서 정보 전송을 위한 표준 프로토콜인 TCP/IP를 따를 수 있다.

[0147] 입출력기(240)는 구체적으로는 입력 장치(241)와 출력 장치(242)로 구성되며, 입력 장치(241)는 프로세서(210)와 통신하고, 복수의 방식으로 사용자의 입력을 수신할 수 있다. 예를 들어, 입력 장치(241)는 마우스, 키보드, 터치 스크린 또는 센싱 장치일 수 있다. 출력 장치(242)는 프로세서(210)와 통신하고, 복수의 방식으로 정보를 디스플레이하거나 음성을 출력할 수 있다. 예를 들어, 출력 장치(242)는 LCD(Liquid Crystal Display), LED(Light Emitting Diode) 디스플레이, OLED(Organic Light Emitting Diode) 디스플레이, 스피커 등일 수 있다.

[0148] 통신 버스(250)는 단어 의미의 모호성 해소를 위한 의미 유지 문장 혼합 장치(200)의 모든 컴포넌트들, 즉 프로세서(210), 메모리(220), 통신기(230) 및 입출력기(240)를 결합하도록 구성된다.


[0149] 본 발명의 실시예에서 사용되는 구성요소 또는 “~부”는 메모리 상의 소정 영역에서 수행되는 태스크, 클래스, 서브 루틴, 프로세스, 오브젝트, 실행 쓰레드, 프로그램과 같은 소프트웨어(software)나, FPGA(field-programmable gate array)나 ASIC(application-specific integrated circuit)과 같은 하드웨어(hardware)로 구현될 수 있으며, 또한 상기 소프트웨어 및 하드웨어의 조합으로 이루어질 수도 있다. 상기 구성요소 또는 ‘~부’ 등은 컴퓨터로 판독 가능한 저장 매체에 포함되어 있을 수도 있고, 복수의 컴퓨터에 그 일부가 분산되어 분포될 수도 있다.

[0150] 이상에서 설명한 본 발명의 실시예는 장치 및 방법을 통해서만 구현이 되는 것은 아니며, 본 발명의 실시예의 구성에 대응하는 기능을 실현하는 프로그램 또는 그 프로그램이 기록된 기록 매체를 통해 구현될 수도 있다.


[0151] 이상에서 본 발명의 실시예에 대하여 상세하게 설명하였지만 본 발명의 권리범위는 이에 한정되는 것은 아니고 다음의 청구범위에서 정의하고 있는 본 발명의 기본 개념을 이용한 당업자의 여러 변형 및 개량 형태 또한 본 발명의 권리범위에 속하는 것이다.

도면

도면1




도면2




도면3

$M(t)$	M_{inc}	M_{tanhinc}	M_{tanhinc}
정의	$\frac{2t-1}{1-1}$	$\tanh(\delta t - \frac{1+1}{2})$	$\tanh^{-1}(\frac{2}{1+\epsilon}(t - \frac{1+1}{2}))$
형상			
$M(t)$	M_{dec}	M_{tanhdec}	M_{tanhdec}
정의	$\frac{1-2t+1}{1-1}$	$-\tanh(\delta t - \frac{1+1}{2})$	$-\tanh^{-1}(\frac{2}{1+\epsilon}(t - \frac{1+1}{2}))$
형상			

도면4



도면5



도면6

