

Fast abstractive summarization with Reinforce-Selected Sentence Rewriting

An Extraction-Abstraction Hybrid Approach for Summarization

1. 개요

• 인간의 요약 방식에 기반한 하이브리드 요약 모델 제안

Extract

the oxford university women 's boat race team were rescued from the thames by the royal national lifeboat institution (rnli) on wednesday after being overcome by choppy waters . crew members from the chiswick rnli station came to the assistance of the oxford crew and their cox , who were training for the boat race which - along with the men 's race - takes place on saturday , april 11 . after the rowers were returned safely to putney , the sunken eight was recovered and returned to oxford 's base . the royal national lifeboat institution come to the assistance of the oxford university women 's team . the oxford crew were training on the thames for the boat race which takes place on saturday , april 11 . the rnli revealed the conditions were caused by strong wind against the tide creating three successive waves that poured over the boat 's riggers , ' creating an influx of water that could not be managed by the craft 's bilge pump ' . in a statement rnli helmsman ian owen said : ' while we have rescued quite a number of rowers over the years , this is the first time i 've been involved in helping such a prestigious team . ' the weather can be unpredictable on the thames , and the oxford university team dealt with the situation as safely and calmly as possible . we wish them all the best for their upcoming race . ' chiswick and tower stations are the busiest in the country , and the rnli has saved over 3,600 people since the service began in 2002 . the rnli alternative boat race fundraising event on april 10 takes place the day before the bny mellon boat race on the same famous stretch of river . for more information , please visit : rnli.org / boatrace .



Rewrite

the oxford university women 's boat race team were rescued from the thames by the royal national lifeboat institution (rnli) on wednesday after being overcome by choppy waters .

crew members from the chiswick rnli station came to the assistance of the oxford crew and their cox , who were training for the boat race which - along with the men 's race - takes place on saturday , april 11 .

after the rowers were returned safely to putney , the sunken eight was recovered and returned to oxford 's base .

the royal national lifeboat institution come to the assistance of the oxford university women 's team .



the oxford university women 's boat race team were rescued from the thames by the royal national lifeboat institution .

crew members were training for the boat race which takes place on saturday .

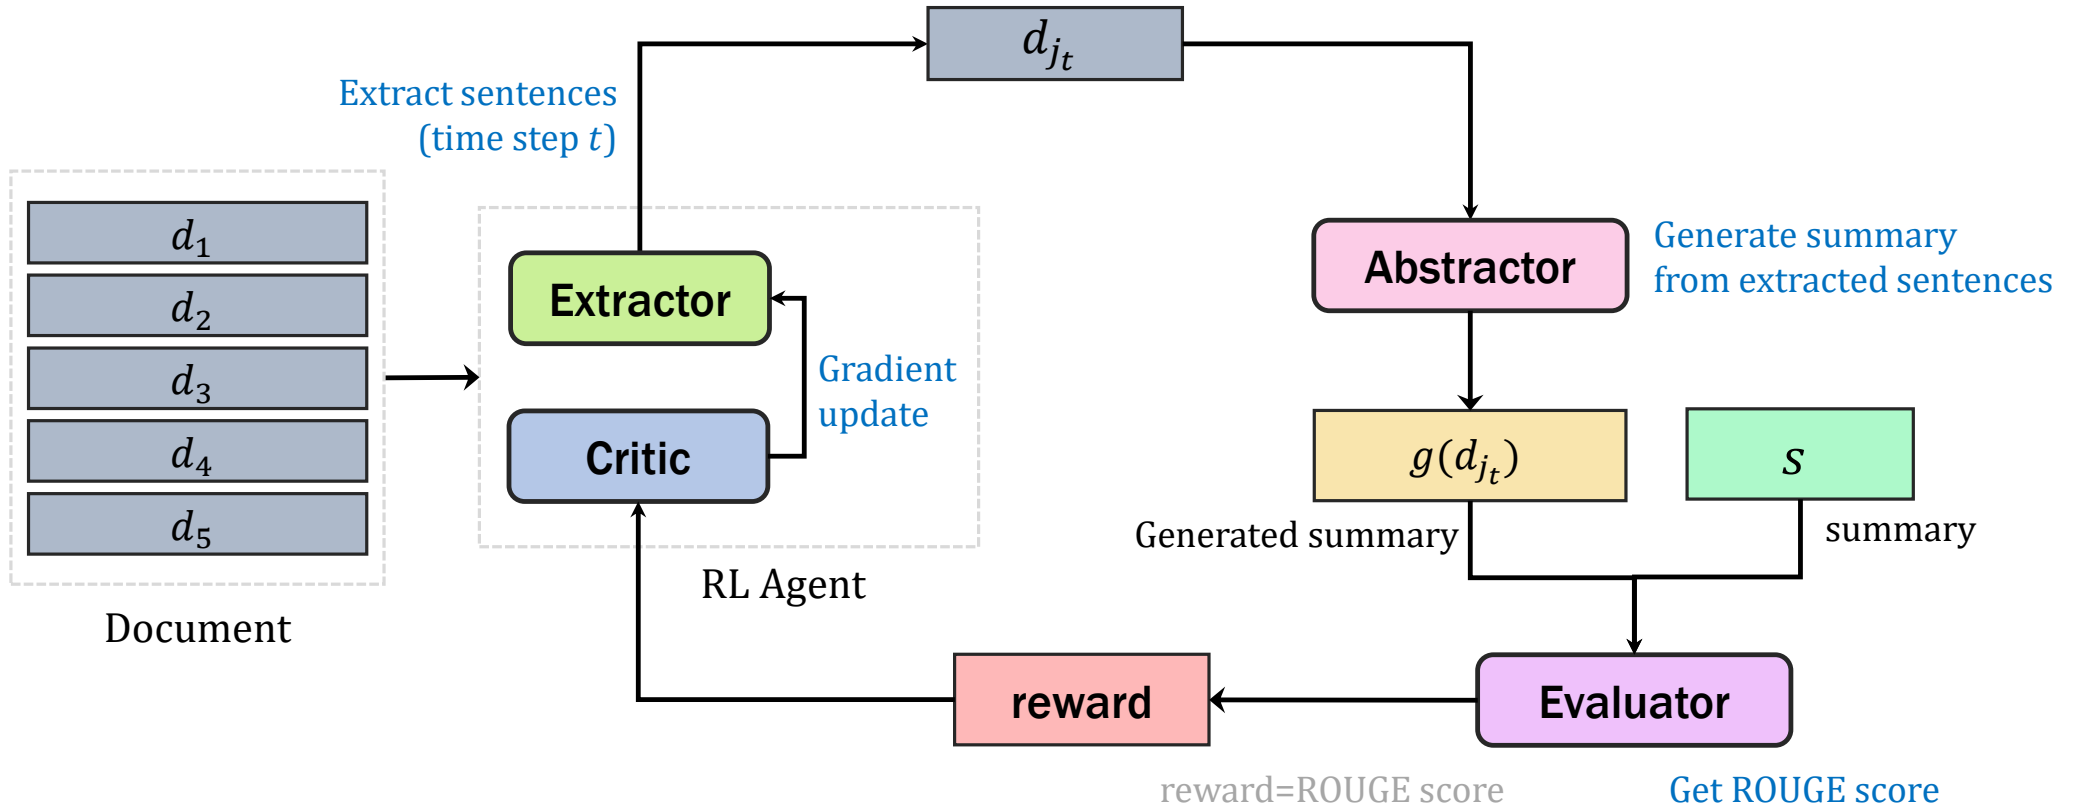
the rowers were returned to oxford 's base .

the royal national lifeboat institution come to the assistance of the oxford university women 's team .

2. 모델 프레임워크

- The Framework

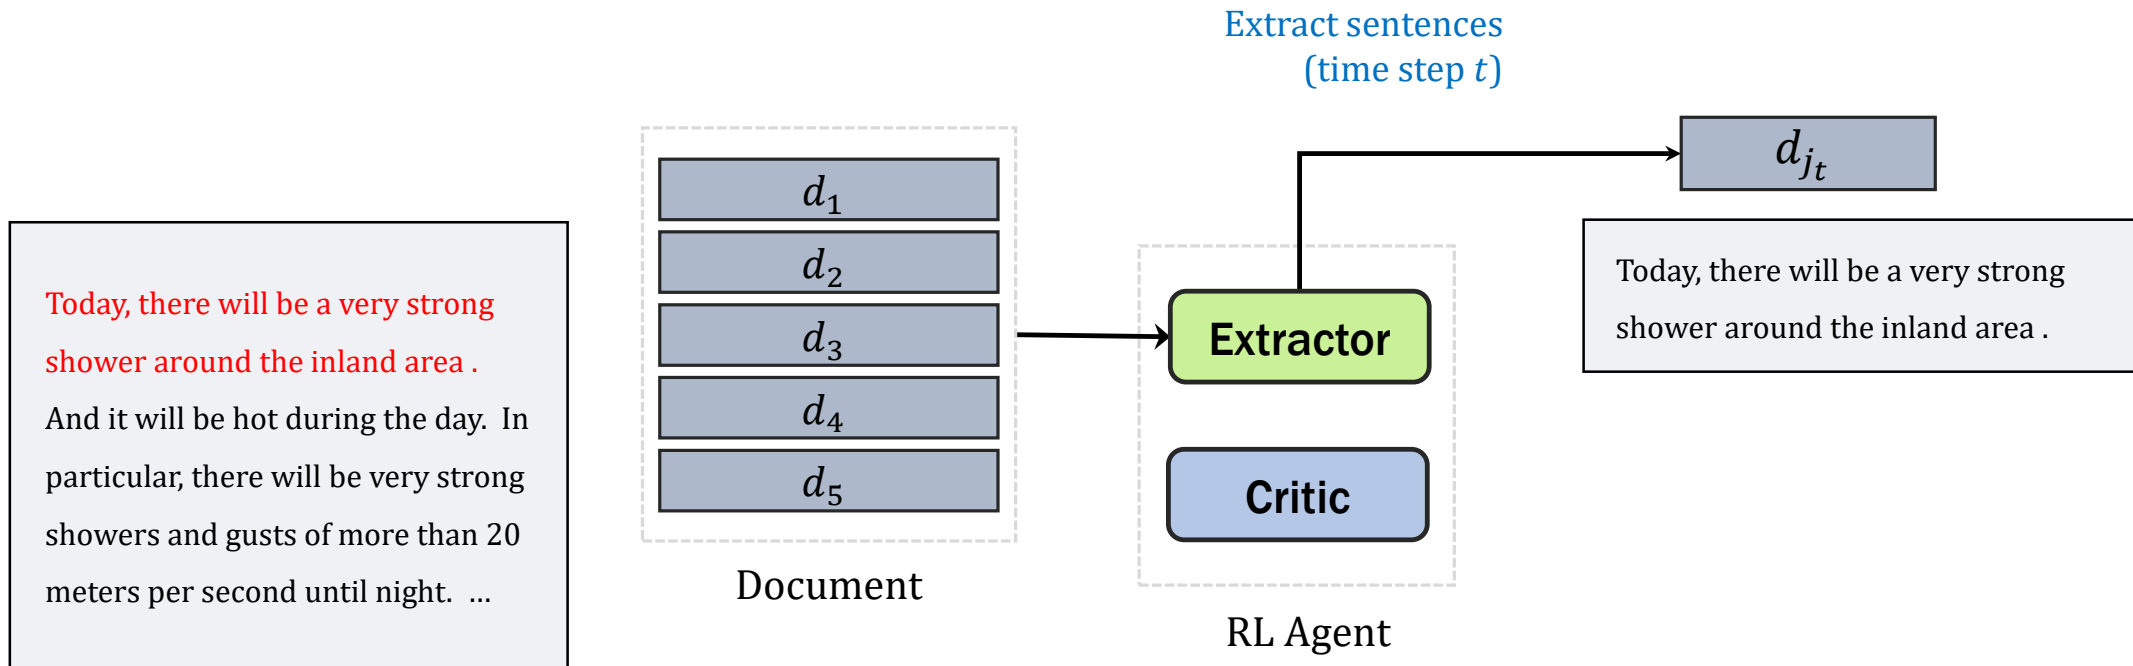
강화 학습 (Reinforcement-learning, RL)을 통해 Extractor와 Abstractor를 연결한 종단 간 (end-to-end) 학습이 가능함



2. 모델 프레임워크

- The Framework

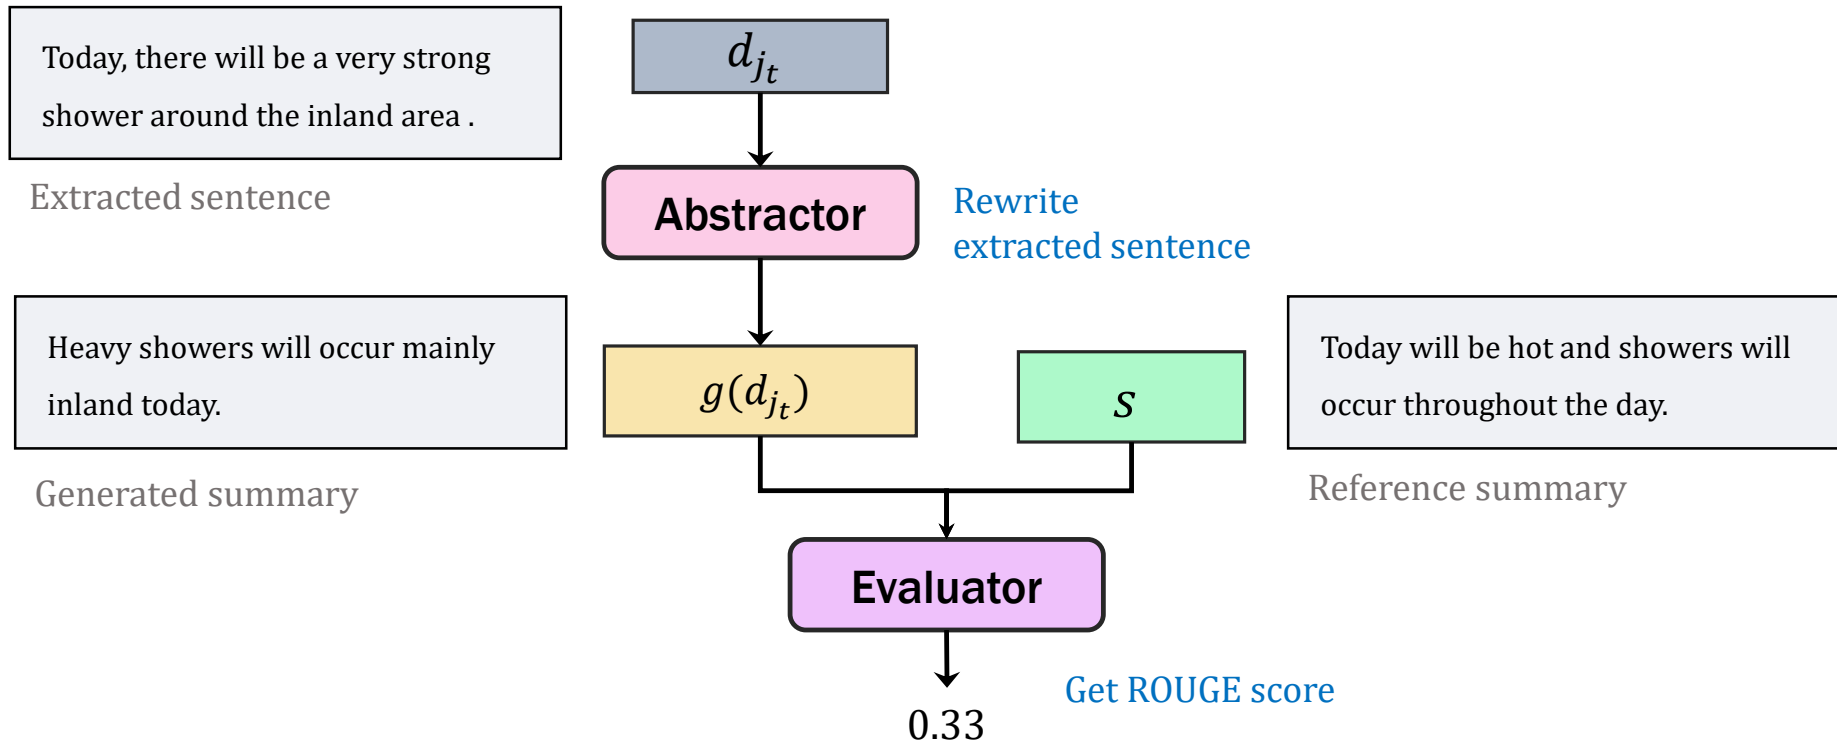
(1) 입력 문서로부터 핵심 문장 추출



2. 모델 프레임워크

- The Framework

(2) 추출된 문장을 재작성 (Rewrite)하여 생성된 요약문과 정답 요약문 비교

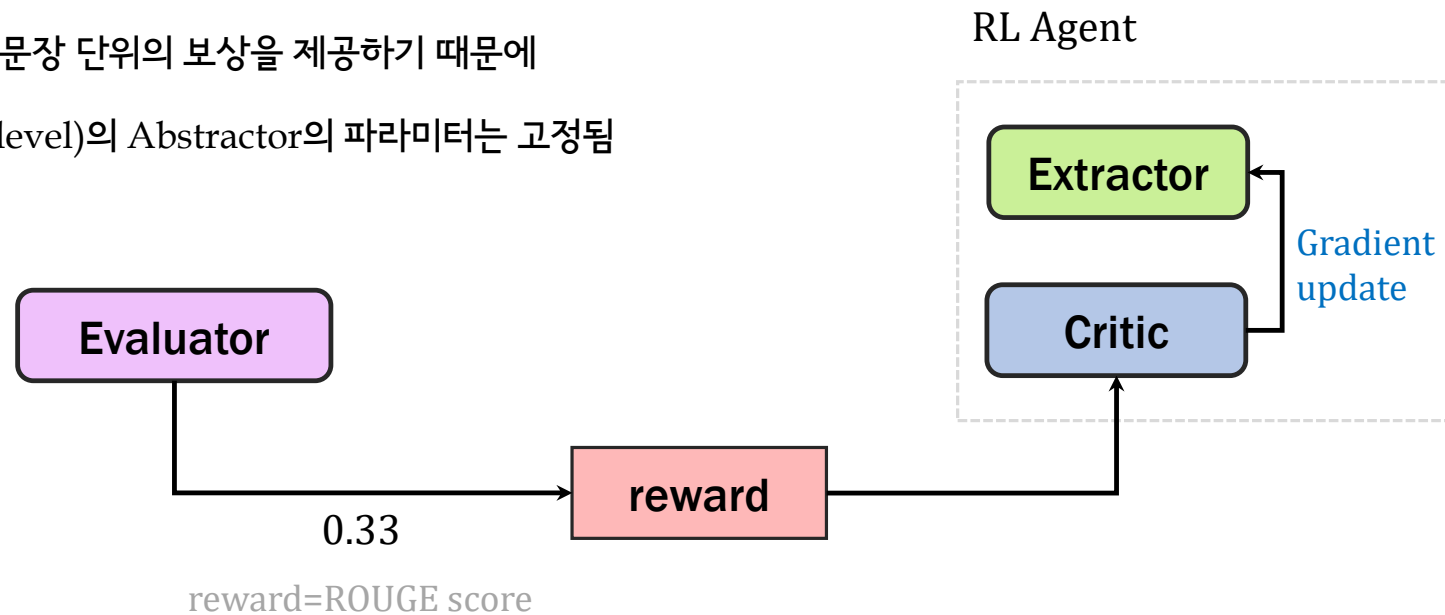


2. 모델 프레임워크

- The Framework

(3) ROUGE score을 바탕으로 Extractor 파라미터 갱신

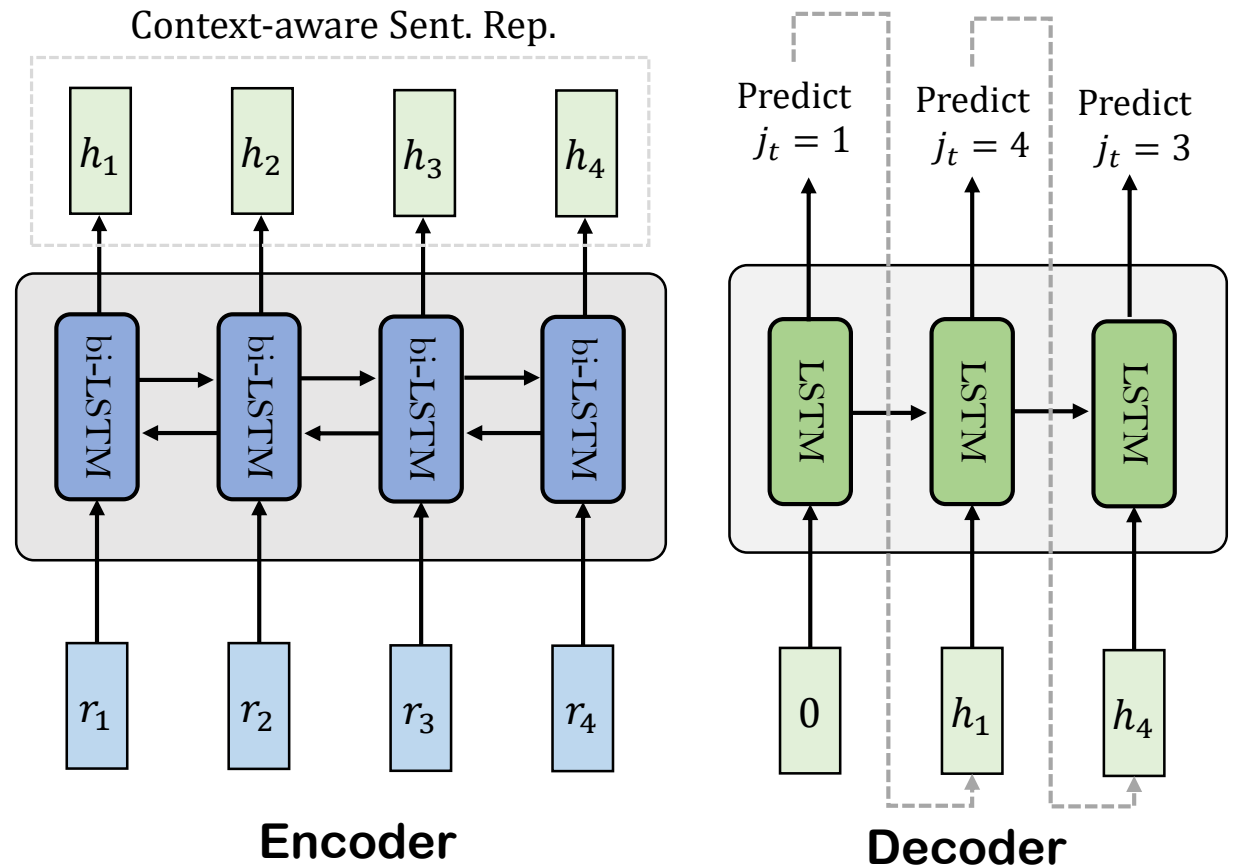
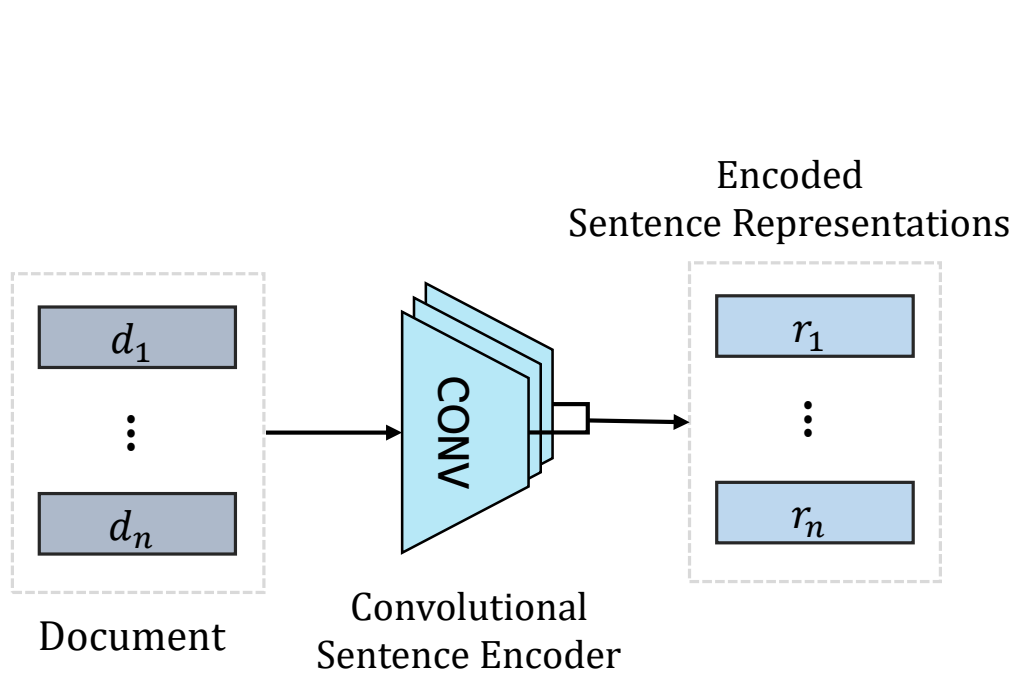
Extractor는 문장 단위 (Sentence-level)로 추출하며,
제안 방식의 RL은 문장 단위의 보상을 제공하기 때문에
단어 단위 (Word-level)의 Abstractor의 파라미터는 고정됨



3. 모델 구조

- Extractor

Pointer Network* 모델 사용

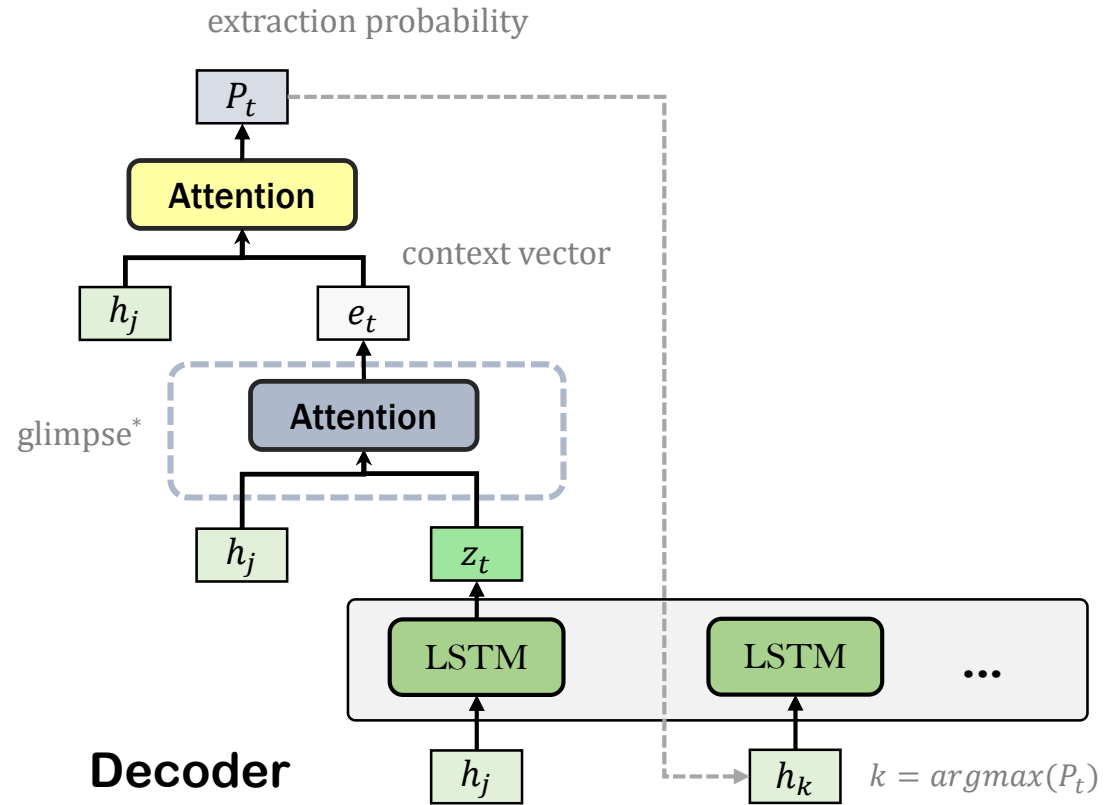
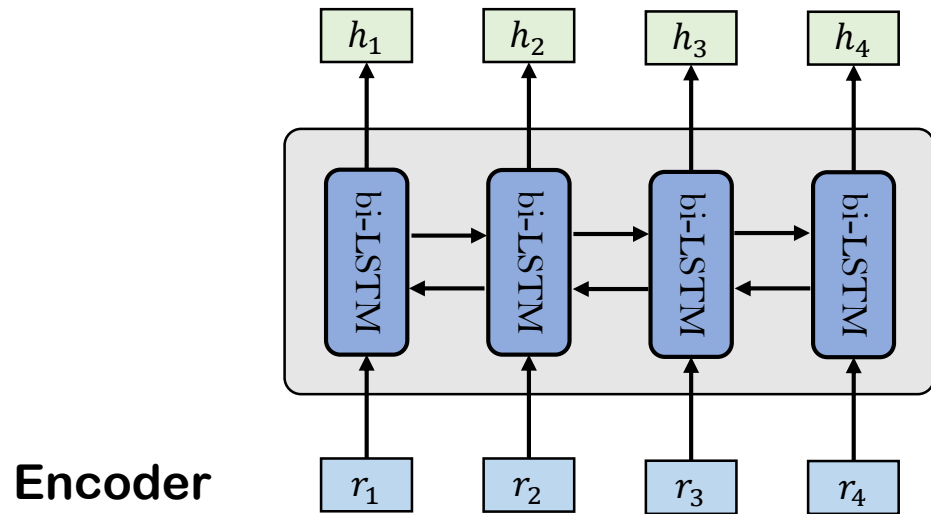


* Vinyals, Oriol, Meire Fortunato, and Navdeep Jaitly. "Pointer Networks." *Advances in Neural Information Processing Systems* 28 (2015): 2692-2700.

3. 모델 구조

- Extractor

“pointing” 전에 Attention을 수행하는 glimpse*을 추가하여
2번의 Attention mechanism 사용



* Vinyals, Oriol, Samy Bengio, and Manjunath Kudlur. "Order matters: Sequence to sequence for sets." in The 4th International Conference on Learning Representations, San Juan, Puerto Rico, May 2016,

3. 모델 구조

- Extractor

Glimpse Operation

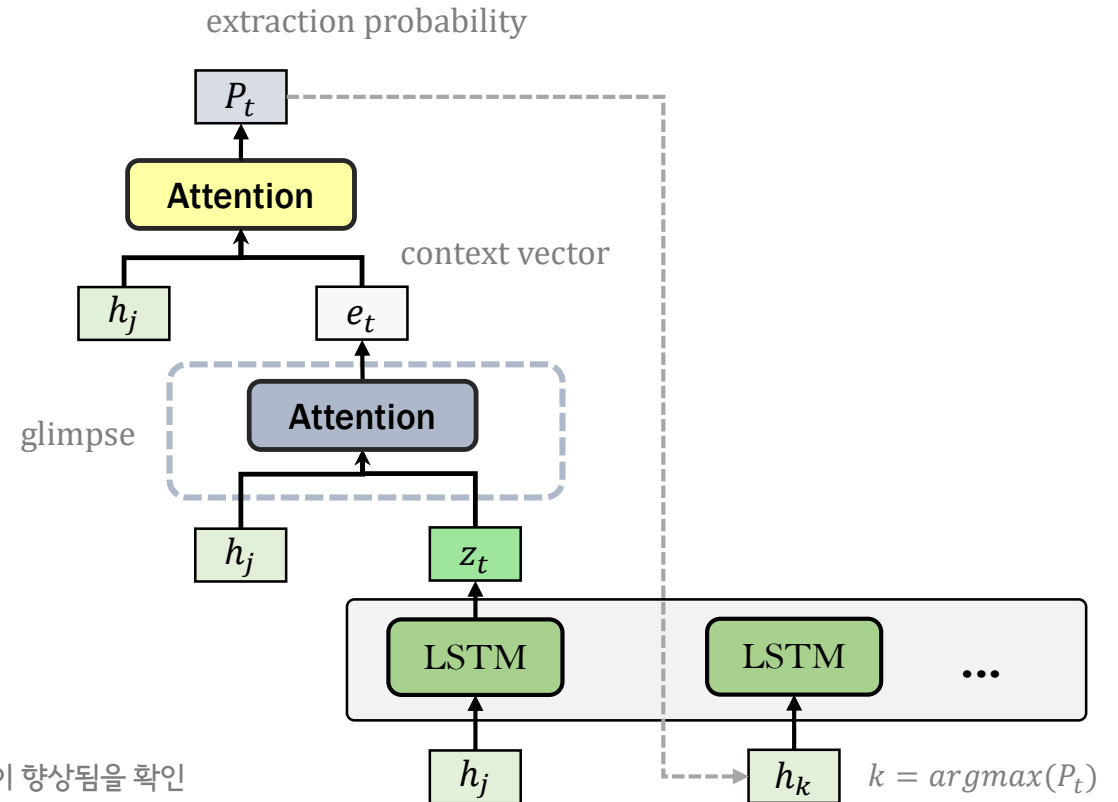
: Extra Attention step

디코더 입력 h_j 와 출력 z_t 에 Attention을 수행

2번의 Attention을 통해 context-aware 벡터 h_j 에 집중하기 때문에,
문서 내 모든 문장들을 효율적으로 분류할 수 있다

Length N glimpses	Ptr-Net		$P = 0$ step		$P = 1$ step		$P = 5$ steps	
	0	1	0	1	0	1	0	1
$N = 5$	81%	90%	65%	84%	84%	92%	88%	94%
$N = 10$	8%	28%	7%	30%	14%	44%	17%	57%
$N = 15$	0%	4%	1%	2%	0%	5%	2%	4%

* Vinyals et al.의 연구에서, 정렬 문제(sorting)에 대해 glimpse를 추가한 모델의 성능이 향상됨을 확인



3. 모델 구조

- Extractor

Decoder의 문장 추출 과정

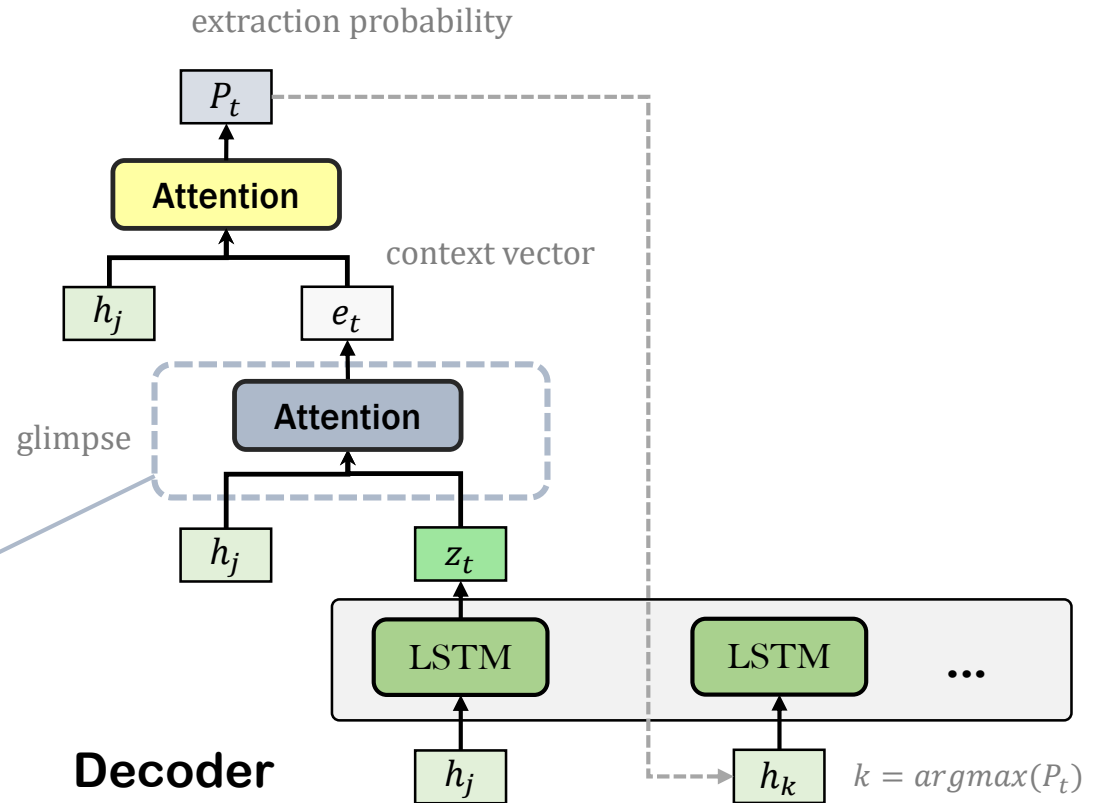
디코더 입력 h_j 와 출력 z_t 에 Attention을 수행

$$a_j^t = \mathbf{v}_g^T \tanh(\mathbf{W}_{g1}h_j + \mathbf{W}_{g2}z_t)$$

$$a^t = \text{softmax}(a^t)$$

$$e^t = \sum_j a_j^t \mathbf{W}_{g1}h_j$$

h_j 와 z_t 의 Attention Value



3. 모델 구조

- Extractor

Decoder의 문장 추출 과정

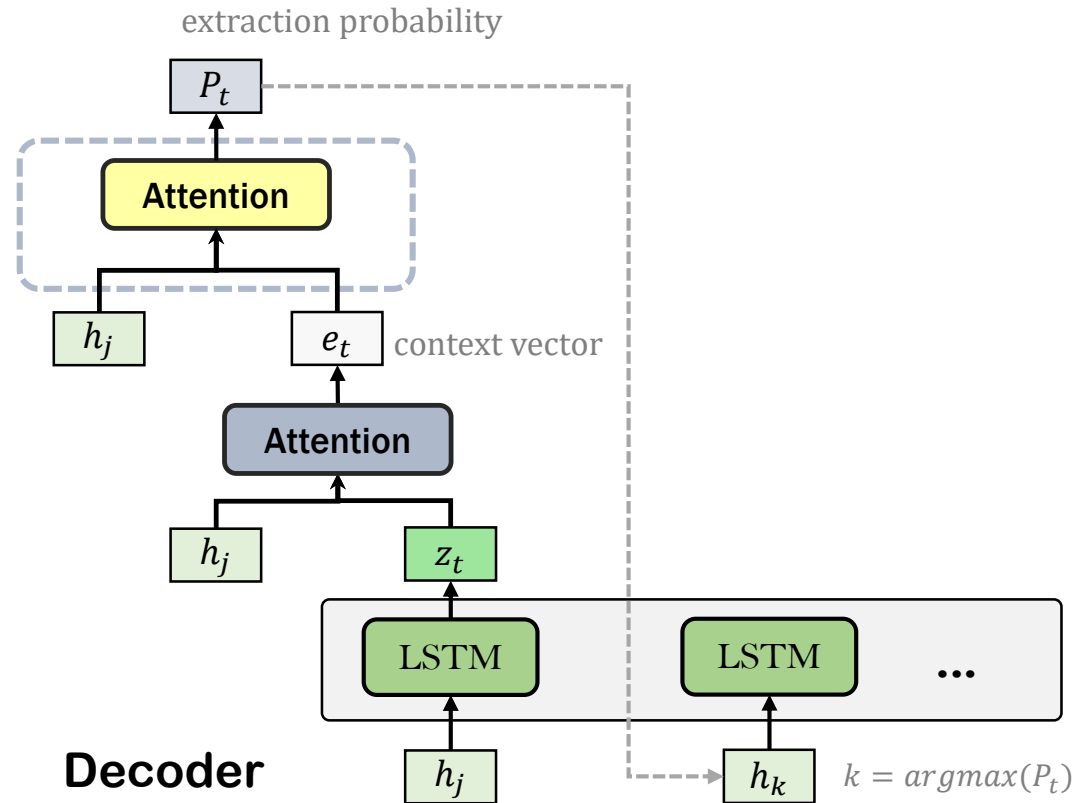
time step t 에서 j 번째 문장에 대한
Attention Score

$$u_j^t = \begin{cases} \mathbf{v}_g^T \tanh(\mathbf{W}_{p1}h_j + \mathbf{W}_{p2}e_t) & \text{if } j_t \neq j_k \\ -\infty & \forall k < t \end{cases}$$

이전 time step에서 추출한 문장 배제

$$P(j_t | j_1, \dots, j_{t-1}) = \text{softmax}(u^t)$$

Document 내 j 번째 문장에 대한 추출 확률 분포



3. 모델 구조

- Abstractor

기본 Encoder-Decoder 구조의 Seq2Seq 모델

* h 와 s 는 각각 encoder와 decoder의 출력을 의미

$$e_i^t = v^T \tanh(W_h h_i + W_s s_t + b_{\text{attn}})$$

$$a^t = \text{softmax}(e^t)$$

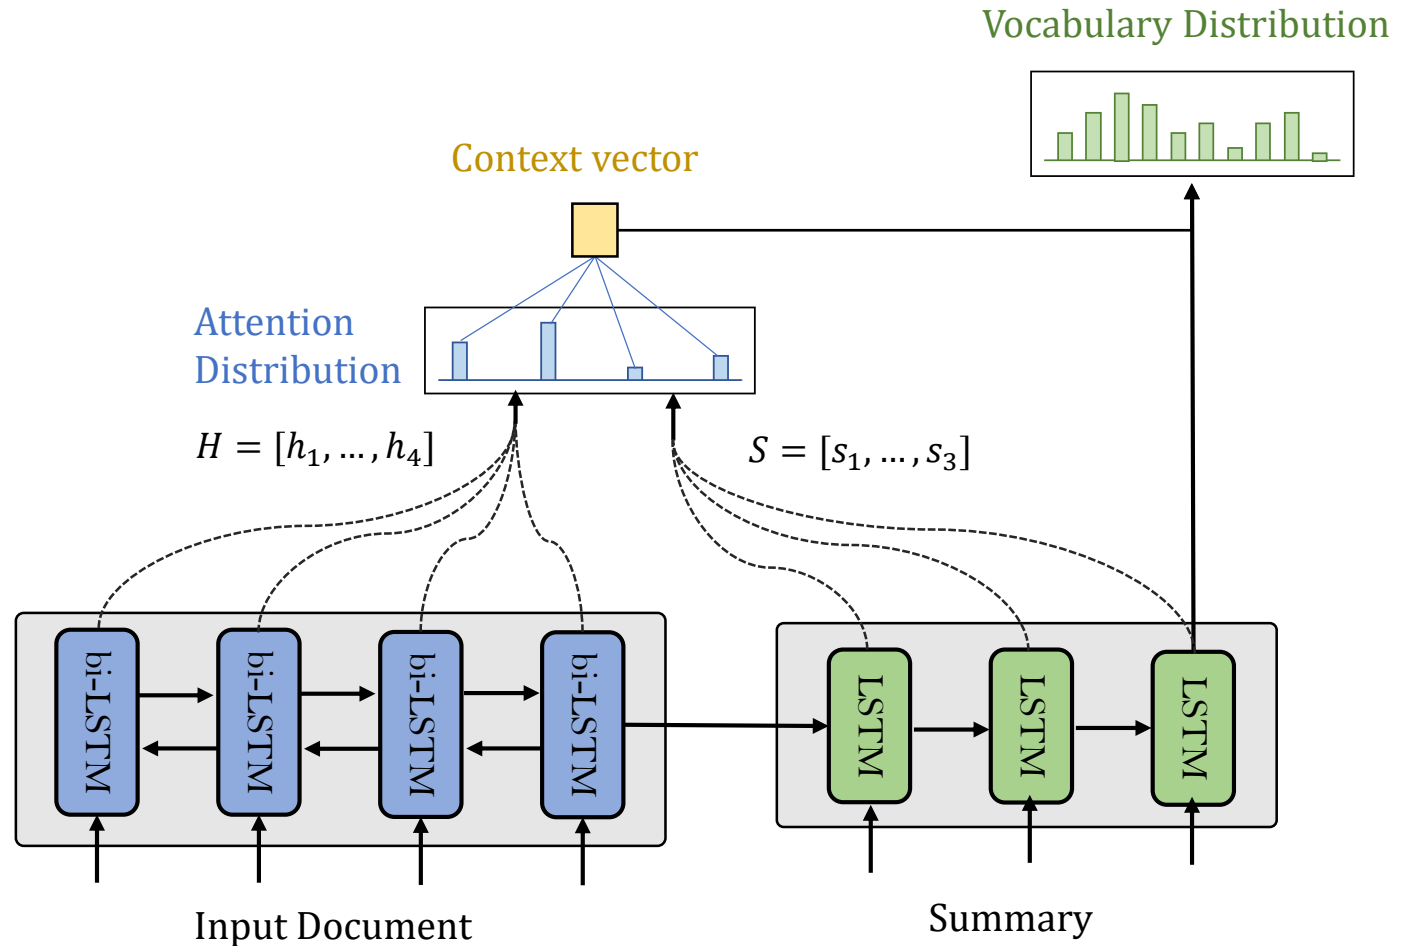
Attention Distribution

$$h_t^* = \sum_i a_i^t h_i$$

Context vector

$$P_{\text{vocab}} = \text{softmax}(V'(V[s_t, h_t^*] + b) + b')$$

Vocabulary Distribution



3. 모델 구조

- Abstractor

Pointer-generator Network

OOV(Out-Of-Vocabulary) 문제를 해결하기 위해
Seq2Seq 모델에 Copy mechanism 추가

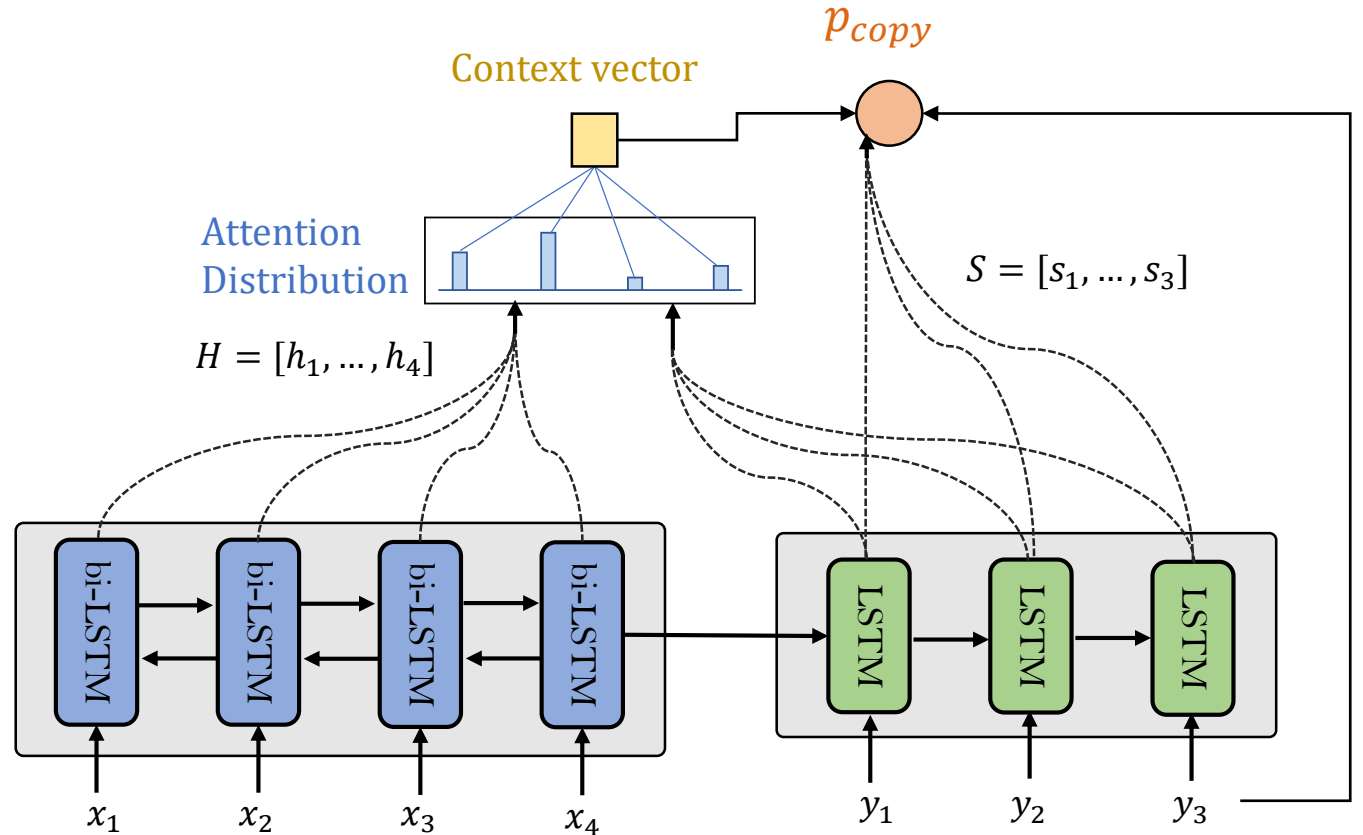
: 입력 문장에 나타난 어휘에 대해 출현 확률을 높일 수 있다

$$P_{copy} = \sigma(v_h^\top h_t^* + v_s^\top s_t + v_y^\top y_t + b)$$

Context vector

Decoder state

Embedded decoder input



3. 모델 구조

- Abstractor

Pointer-generator Network

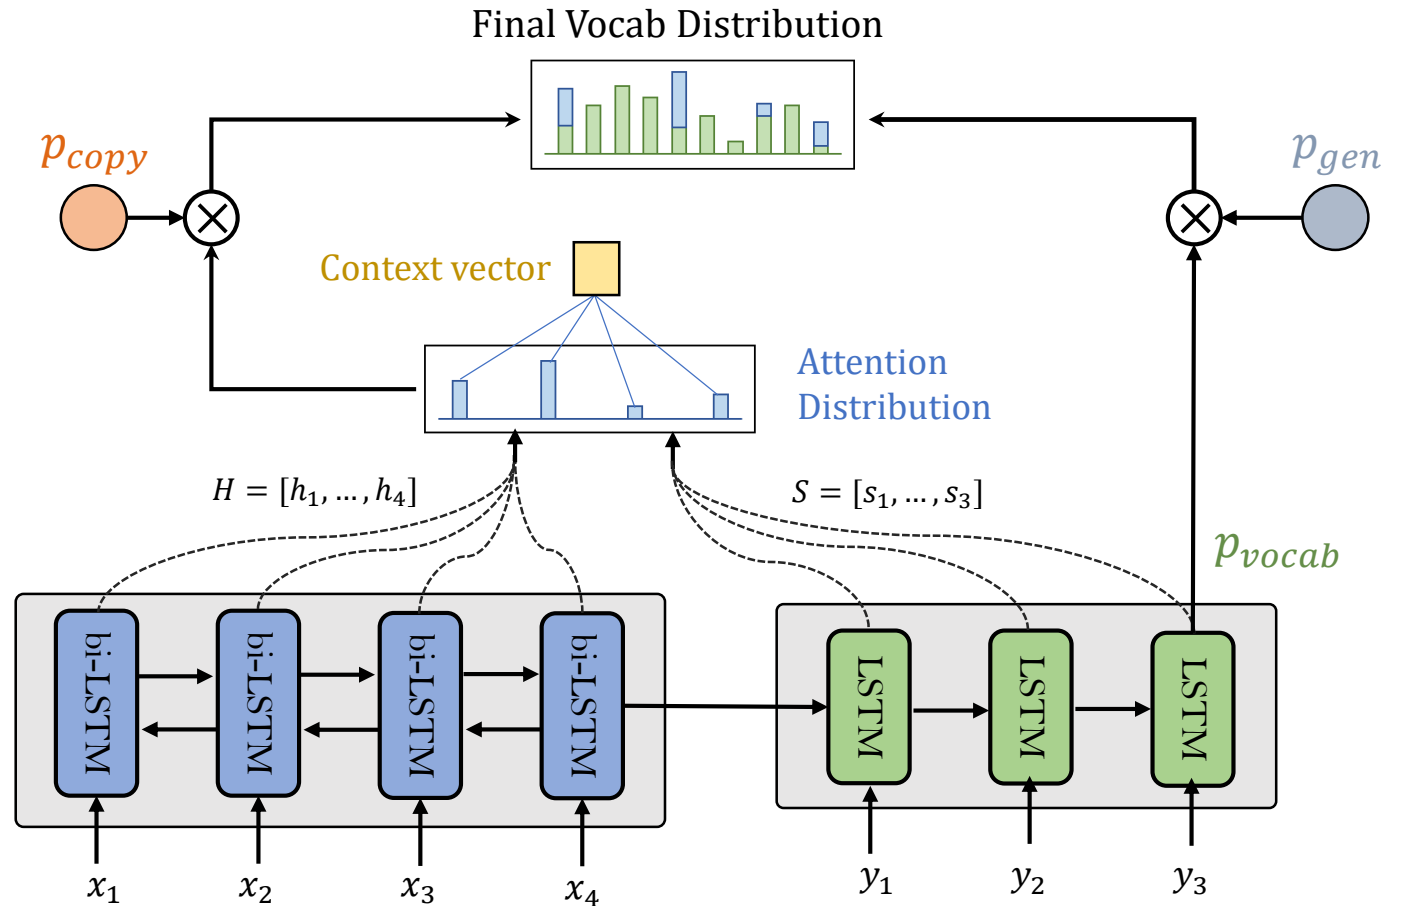
OOV(Out-Of-Vocabulary) 문제를 해결하기 위해
Seq2Seq 모델에 Copy mechanism 추가

: 입력 문장에 나타난 어휘에 대해 출현 확률을 높일 수 있다

$$P_{gen} = 1 - P_{copy}$$

$$P_{final\ vocab} = a^t P_{copy} + P_{gen} P_{vocab}$$

Attention Distribution



4. 모델 훈련

- Training

본 연구에서는 각각 사전 학습된 Extractor, Abstractor를 사용하며, 강화 학습을 통해 두 모델을 연결함

이 때, Extractor가 너무 많은 문장을 추출하는 것을 방지하기 위해, **중지 행동(Stop Action)** 추가

$$\boxed{V_{EOE}} \quad * \text{ EOE : End of Extraction}$$

문장 추출을 계속할지 판단하기 위한 **종료 보상(terminal reward)** 추가

종료 보상을 최대화하기 위해 관련 없는 문장이 추출되지 않도록 학습

Terminal Reward

문장 추출 종료를 학습하기 위한 보상

$$\text{ROUGE-1}_{F_1}([\{g(d_{j_t})\}_t], [\{s_t\}_t])$$

Intermediate Reward

Extractor에 의해 추출한 문장에 대한 문장 단위 보상

$$\text{ROUGE-L}_{F_1}(g(d_{j_t}), s_t)$$

4. 모델 훈련

- Reinforcement Learning

생성된 요약문 $g(d_{j_t})$ 과 정답 요약문 s_t 의 ROUGE-L 점수를 문장 단위 보상 (Sentence-level reward)으로 사용

$$r(t + 1) = \text{ROUGE-L}_{F_1}(g(d_{j_t}), s_t)$$

$r(t)$ time step t 의 보상 (reward)

$$c_t = (D, d_{j_{t-1}})$$

c_t time step t 의 상태 (state), 주어진 Document D 와 추출된 문장 d_{j_t} 로 구성

$$\pi_{\theta_a, \omega}(c_t, j) = P(j)$$

j_t 행동 (action), time step t 에 추출된 문장 번호

$\pi_{\theta_a, \omega}(c_t, j)$ 정책 (policy), c_t 상태일 때, j 행동을 취할 확률

θ_a, ω 는 Encoder와 Decoder의 훈련 파라미터

4. 모델 훈련

- Reinforcement Learning

REINFORCE 알고리즘

: 하나의 에피소드가 끝난 후, 누적 보상 R_t 를 계산하여 파라미터를 갱신하는 방법

$$J(\theta) = \mathbb{E}_{\pi_{\theta}}[r]$$

Policy gradient) 목적 함수 $J(\theta_a, \omega)$ 의 경사를 통해 파라미터 탐색

$$\nabla_{\theta} J(\theta) = \mathbb{E}_{\pi_{\theta}}[\nabla_{\theta} \log \pi_{\theta}(c, j) Q^{\pi}(c, j)]$$

$$= \mathbb{E}_{\pi_{\theta}}[\nabla_{\theta} \log \pi_{\theta}(c, j) R_t]$$

$$J(\theta_a, \omega)$$

Objective function

목적 함수 $J(\theta_a, \omega)$ 을 최대화 하는 θ_a, ω 를 탐색

$$Q^{\pi_{\theta}}(c_t, j_t)$$

Q-value function

주어진 상태 c_t 에서 행동 j_t 를 취했을 경우 얻을 수 있는 누적 보상 R_t

$$V^{\pi_{\theta}}(c_t)$$

state-value function

주어진 상태 c_t 에서 얻을 수 있는 누적 보상 R_t

에피소드(episode)의 반환 값인 누적 보상 R_t 는

많은 확률 변수(Random Variable)의 합으로 계산되기 때문에, 높은 분산 값을 가짐

4. 모델 훈련

- Reinforcement Learning

Actor-Critic

: 본 연구에서는 REINFORCE 알고리즘의 단점을 보완하기 위해 Advantage function $A^{\pi_{\theta}}(c, j)$ 을 사용
특정 상태에서, 임의의 행동에 따른 누적 보상 값 $V^{\pi_{\theta}}(c)$ 을 통해 분산을 낮춤

$$A^{\pi_{\theta}}(c, j) = Q^{\pi_{\theta}}(c, j) - V^{\pi_{\theta}}(c)$$

$V^{\pi_{\theta}}$ 를 추정할 critic network 추가

$$\nabla_{\theta_a, \omega} J(\theta_a, \omega)$$

$$= \mathbb{E}[\nabla_{\theta_a, \omega} \log \pi_{\theta_a}(c, j) A^{\pi_{\theta}}(c, j)]$$

$$A^{\pi_{\theta}}(c, j)$$

Advantage function

주어진 상태 c_t 에서 행동 j_t 를 취하는 것이 얼마나 좋은지 측정

$$A^{\pi_{\theta}}(c, j) = \mathbb{E}[r(c, j) - r(c)]$$

5. 관련 연구-ASAE

- Abstractive Summarization after Extraction(ASAE)*

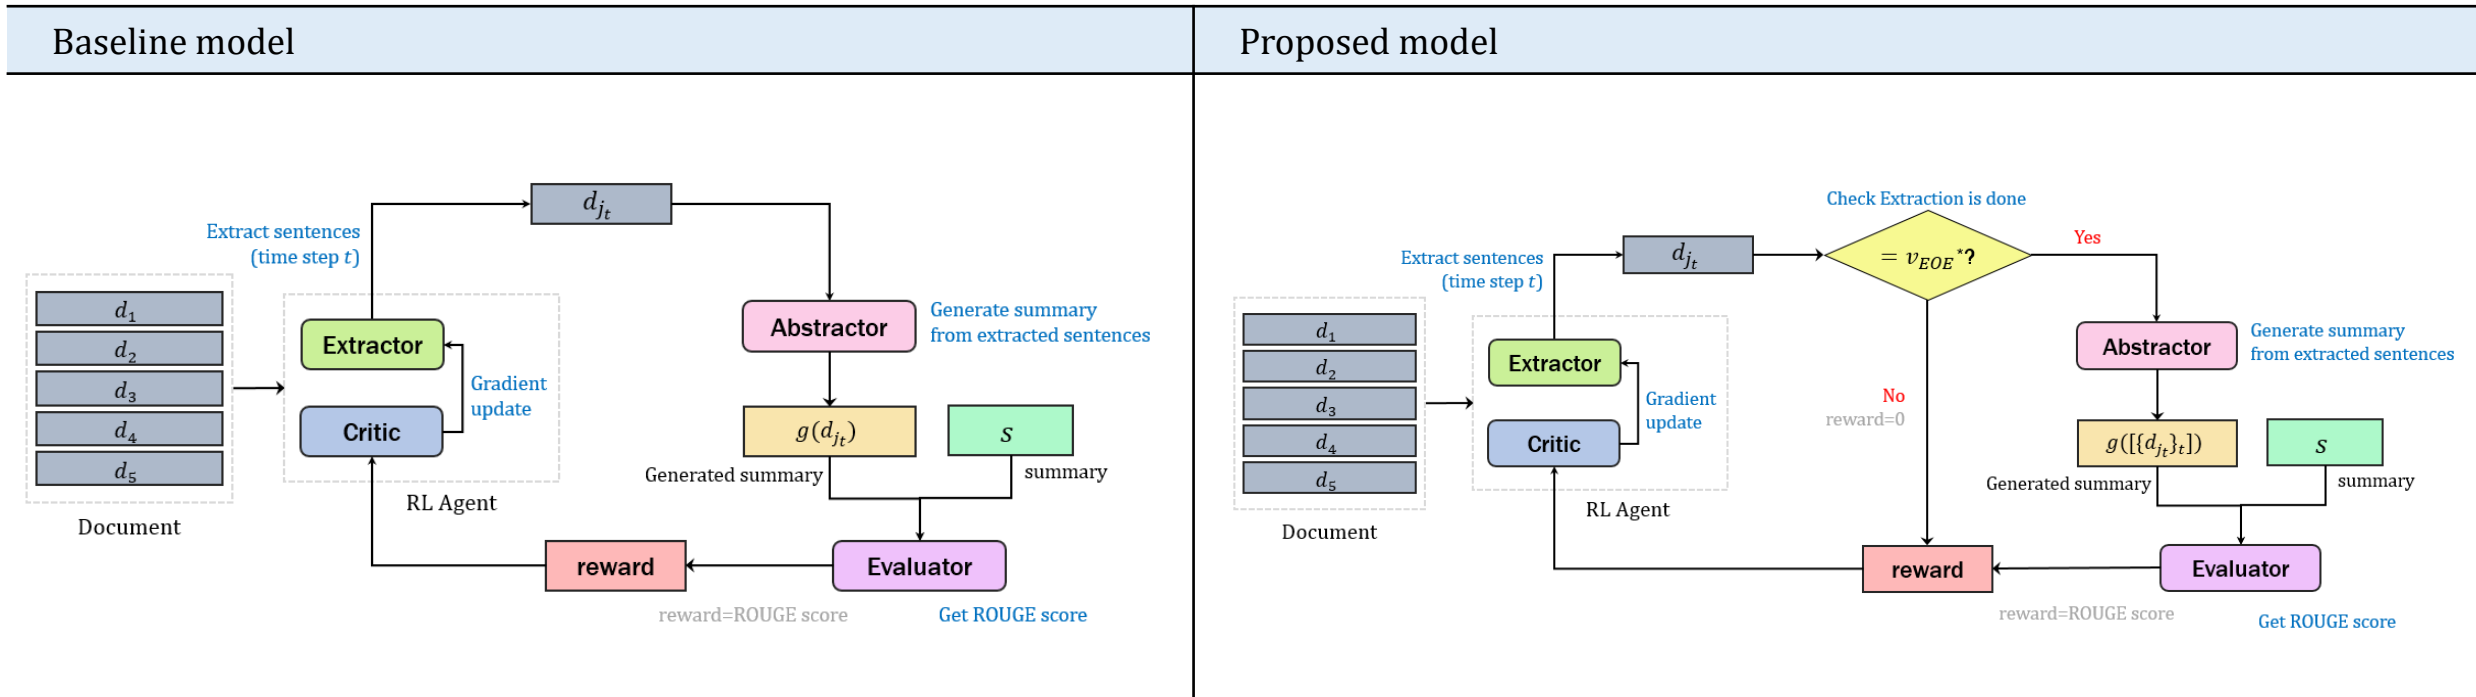
기존 모델	Contribution
입력 문서에서 핵심 문장들을 추출하고, 추출된 문장마다 각각 추상 요약 수행	입력 문서에 대한 추출 요약이 끝난 후, 추출된 문장들에 추상 요약 수행
Encoder-Decoder 구조의 모델을 통한 추상 요약 시, 단어 반복 문제 발생	coverage mechanism 추가
영어로 구성된 CNN/Daily Mail dataset 사용	중국어로 구성된 NLPC 2017 Task 3 dataset 사용

* Huang, Si, et al. "An Extraction-Abstraction Hybrid Approach for Long Document Summarization." 2019 6th International Conference on Behavioral, Economic and Socio-Cultural Computing (BESC). IEEE, 2019.

5. 관련 연구-ASAE

- 기존 모델과 프레임워크 비교

원본 텍스트로부터 추출된 각 문장은 전체적인 맥락을 담기보다 편향적인 정보를 담기 때문에 관련 연구는 은 문장 추출이 끝난 후, 추출된 문장들을 바탕으로 요약을 생성한다.

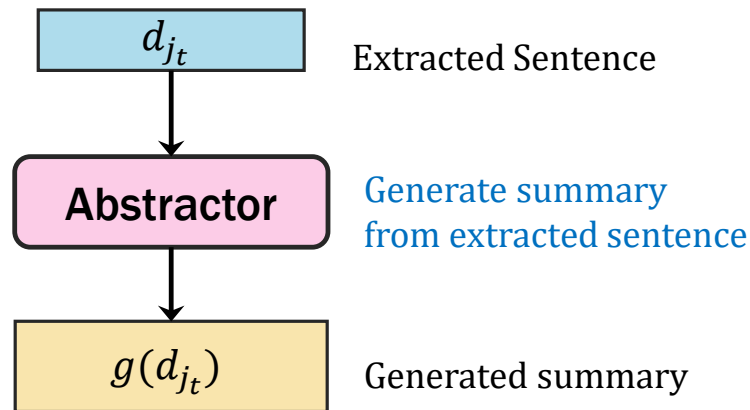


5. 관련 연구-ASAE


• ASAE의 추상 요약

추출된 하나의 문장은 전체적인 맥락이 아닌 **편향적인 정보**를 담을 가능성이 높음

→ 문장 마다 추상 요약을 수행하지 않고, 추출된 문장들에 추상 요약 수행
추출된 문장들의 상호 연관성을 기반으로 요약문 생성



기존 모델의 추상 요약



ASAE 모델의 추상 요약

5. 관련 연구-ASAE

- ASAE의 추상 요약

Coverage mechanism

- 관련 연구에서는 같은 단어가 반복적으로 등장하는 **반복 문제 (repetition problem)**를 해결하기 위해, 이를 추가함
- c^t 는 이전 time step $t - 1$ 까지의 Attention score 합계

$$\text{Coverage vector } c^t = \sum_{r=0}^{t-1} a^r \text{ Attention score}$$

- 이전에 높은 Attention score 를 받은 단어에 패널티를 부여하고자, loss에 coverage loss를 더함

$$covloss_t = \sum_i \min(a_i^t, c_i^t)$$

$$loss_t = -\log P(\omega_t^*) + \lambda covloss_t$$

* $P(\omega_t^*)$: target word ω_t^* 의 등장 확률