

2018 NLP&AI Lab 연구실적



2018 연구실적

❖ 개인 연구

- 식당 예약 및 추천을 위한 한국어 대화 코퍼스 구축 ----- 소아람
- Question Answer ----- 좌희정
- 대화 시스템에서의 자연스러운 대화를 위한 Memory Attention기반 Breakdown Detection ----- 이설화
- An Analysis on AI in CyberSecurity ----- Titi
- 보고서 자동 분석 및 Topic 자동 추출 기술 연구 ----- 허윤아
- Character-Level Feature Extraction with Densely Connected Networks ----- 이찬희
- Structured "Image - Text" Mapping for Bidirectional "Image - Text" Transitions ----- 김규경
- Utilizing Dual Memory Network with Domain Knowledge for Goal-Oriented Dialogues ----- 이동엽
- 개체명 인식(Named Entity Recognition) 시스템 연구 및 개발 ----- 김경민
- Enhanced Sequential Representation Augmented with Utterance-level Attention for Response Selection -- 황태선
- Answer Generation from Span Prediction in MRC Tasks ----- 양기수

2018 연구실적 [과제]

❖ 스마트 시니어세대의 문화향유를 위한 인지반응 맞춤형 UI/UX기술 개발

- 인지반응 분석 시스템 개발 ----- 이설화
- 스마트 시니어 맞춤형 프로파일 관리시스템 고도화 ----- 허윤아
- 스마트 시니어 맞춤형 추천 시스템 개발 ----- 황태선
- 표준안 및 기술 보고서 작성 ----- 소아람

❖ 사용자 중심의 지능형 패션검색 및 맞춤형 코디네이션 제품 개발

- 벡터기반 사용자 선호 패션 프로파일링·코디 및 매칭 기술 개발 ----- 이설화
- 드로잉 자질 추출 기술 ----- 이찬희
- 딥러닝 기반의 패션 상품 유사 이미지 검색 모델 ----- 이동엽

❖ 전통문화 융복합 지원을 위한 지능형 검색 플랫폼 구축

- Meta Learning based Global Relation Extraction ----- 김규경
- 고유명사 개체인식 기술 개발 추가 연구 - 데이터 구축 ----- 김경민

2018 연구실적 [과제]

❖ 머신러닝을 이용한 비정형 위협정보 자동추출 방안 연구 (KISA)

- 비정형 위협정보 자동 인식 및 추출 ----- 이찬희
- 머신러닝을 이용한 문서 자동 요약 ----- 이찬희
- 유사 문서 검색 및 시각화 ----- 이찬희
- Keyword Extraction ----- 허윤아
- 위협정보 개체명 인식 데이터 구축 ----- 김경민
- OCR 프로그램 조사 및 성능 비교 ----- 양기수

❖ 기계학습을 활용한 자연어 질의/응답 인공지능 모델 개발 (현대자동차)

- 기술 동향 보고서 및 기술 개발 전략 보고서 ----- 김규경
- 자동차 법률 응답 대화 시스템 개발 ----- 이동엽

식당 예약 및 추천을 위한 한국어 대화 코퍼스 구축

고려대학교 NLP&AI Lab.

소아람

연구 내용 - 대화 코퍼스 구축

❖ 대화 데이터 수집

- 대화 데이터는 대화 상대에 따라 인간-기계 대화 데이터와 인간-인간 대화 데이터로 구분함
- 본 연구에서는 대화 코퍼스 수집을 위하여 인간-인간의 대화를 수집함
 - 시스템과 사용자 역할로 나누어 각 역할에 알맞게 대화를 나누어 대화를 수집함

연구 내용 - 대화 코퍼스 구축

❖ 대화 수집 가이드라인

- 시스템

- 사용자가 원하는 식당을 알아내기 위하여 고정된 형식의 질문을 함
예) 어느 종류의 식당을 원하시나요?
원하시는 가격대를 말씀해 주세요.
- 사용자가 원하는 식당 추천
- 사용자가 선택한 식당에 대한 정보 제공 및 예약을 위한 대화 진행

연구 내용 - 대화 코퍼스 구축

❖ 대화 수집 가이드라인

- 사용자
 - 원하는 식당에 대한 정보를 얻기 위하여 시스템에 정보를 제공함
 - 다양한 발화를 수집할 수 있도록 최대한 다양한 형식으로 변화를 주어 시스템과 대화
예) 5명, 다섯명, 오인, 5

연구 내용 - 대화 코퍼스 구축

❖ 수집 데이터

수집정보	참 고
위치	이태원 근처, 강남역 주변, 정자역, 판교 등
음식종류	한식, 양식, 중식, 일식, 이탈리아, 베트남, 기타
식당	실제 식당이름
날짜	월, 일, 오늘, 내일, 0요일
시간	00시 ~24시, 저녁, 오후, 점심
인원	0명
가격	1인당 15,000원, 5만원, 4명 10만원
예약도구	앱(app)으로 예약, 전화로 예약
전화번호	02-1234-5678, 031-777-8965
주소	서울시 서초구 서초동 143
주차장 유무	주차 가능 / 불가능
주차 서비스	가능 / 불가능

연구 내용 - 대화 코퍼스 구축

❖ 대화 시나리오

시스템: 어느 지역을 원하시나요?

사용자: 이태원 근처로 추천해줘

시스템: 어느 종류의 식당을 원하시나요?

사용자: 이탈리아 레스토랑이 좋을 것 같아

시스템: 원하시는 가격대를 말씀해 주세요.

사용자: 1인당 15000원~20000원

시스템: 언제 방문할 예정인가요?

사용자: 오늘 저녁 7시쯤 가려고

시스템: 이태원 근처의 당일 예약 가능한 식당은 이탈리아 레스토랑은 비스테까, 피제리아까사, 오레노 입니다.

사용자: 또 다른 식당은?

시스템: 하베스트, 레뒤플라, 라쿠치나, 라코르테 입니다.

사용자: 오레노 예약해줘

시스템: 몇 명인가요?

사용자: 음... 4명 예약해줘

시스템: 오늘 저녁 7시 오레노에 4명 예약하였습니다.

사용자: 또 다른 식당은?

시스템: 하베스트, 레뒤플라, 라쿠치나, 라코르테 입니다.

연구 내용 - 대화 코퍼스 구축

❖ 태깅(tagging)

사용자: [[오늘||날짜]] [[저녁||시간]] [[이태원||위치]] 근처 식당 추천해줘

시스템: 어느 종류의 식당을 원하시나요?

사용자: [[이탈리안||종류]] 레스토랑

시스템: 원하시는 가격대를 말씀해 주세요.

사용자: [[1인당 15000원~20000원||가격]]

시스템: 언제 방문할 예정인가요?

사용자: [[오늘||날짜]] [[저녁 7시||시간]]

시스템: [[이태원||위치]] 근처의 예약 가능한 [[이탈리안||종류]] 레스토랑은 [[비스테까||식당]], [[피제리아까사||식당]], [[오레노||식당]]입니다.

사용자: 또 다른 식당은?

시스템: [[하베스트||식당]], [[레뒤플라||식당]], [[라쿠치나||식당]], [[라코르테||식당]]입니다.

사용자: [[오레노||식당]] 예약해줘

시스템: 몇 명인가요?

사용자: 음... [[4명||인원]] 예약해줘

시스템: [[오늘||날짜]] [[저녁 7시||시간]] [[오레노||식당]]에 [[4명||인원]] 예약하였습니다.

사용자: [[오레노||식당]] 전화번호 알려줘

시스템: [[02-794-0055||전화번호]]입니다.

연구 내용 - 대화 코퍼스 구축

❖ 데이터 통계

차시	Dialogue	slot												
		Slot수 (필수/추가)	위치	음식종류	식당	날짜	시간	인원	가격	예약도구	전화번호	주소	주차장 유무	주차 서비스
1차	192	7	561	374	686	531	530	483	201					
2차	306	12(6/6)	725	645	2242	720	721	581	429	40	244	268	117	21
3차	1390	12(6/6)	1387	2779	1339	1383	1383	1383	1392	1383	1387	1391	1384	1251
4차	210	12(6/6)												
5차	수집 중	12(6/6)												

- 총 2098개의 Dialogue를 수집함
- 사용자 발화 : 24262
- 시스템 발화 : 25757

Question Answer

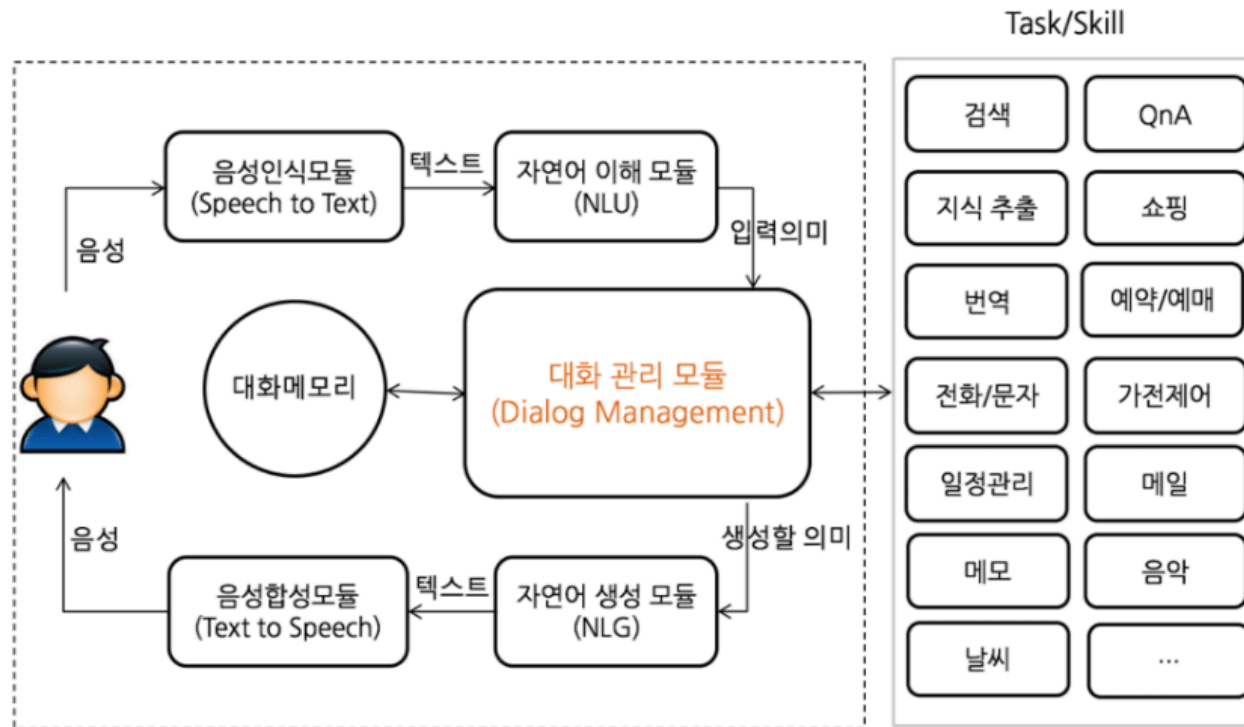
고려대학교 NLP&AI Lab.

좌희정

연구 계획

❖ 연구 내용 : task 지정을 위한 사용자 의도 파악

- Question & Answer 과정에서 사용자의 질문이 어떤 의도인지를 파악하기 위해 slot filling, slot tagging 을 통한 정확한 도메인 찾기



연구 계획

❖ 관련 논문

- Sequential Short-Text Classification with Recurrent and Convolutional Neural Networks
- A joint Model of Intent Determination and Slot Filling for Spoken Language Understanding
- ONENET: Joint Domain, Intent, Slot prediction for Spoken Language Understanding
- Attention-Based Recurrent Neural Network Models for Joint Intent Detection and Slot Filling

대화 시스템에서의 자연스러운 대화를 위한 Memory Attention 기반 Breakdown Detection


고려대학교 NLP&AI Lab.

이설화

연구 내용 - Introduction

❖ 대화시스템에서의 이슈

- 시스템과 사람 간의 자연스러운 대화



연구 내용 - Dialogue Breakdown

- 사람과 시스템 사이의 대화에서 문맥의 흐름이 끊겨 사람이 더 이상 대화 흐름에 참여할 수 없게 되는 상황
- Dialogue Breakdown Detection (Walker et al., 2002)
 - 시스템의 발화가 Dialogue Breakdown을 유발하는지 탐색하는 것 (Martinovsky et al., 2006)

연구 내용 - Dialogue Breakdown

System



"오늘은 축구하기 좋은 날씨네요."

User




"맞아, 그런데 곧 비가 온대."

"일기예보에서 저녁에 비가
온다고 했어요."

"나는 비가 싫어서 저녁에 집에
있을 거야."

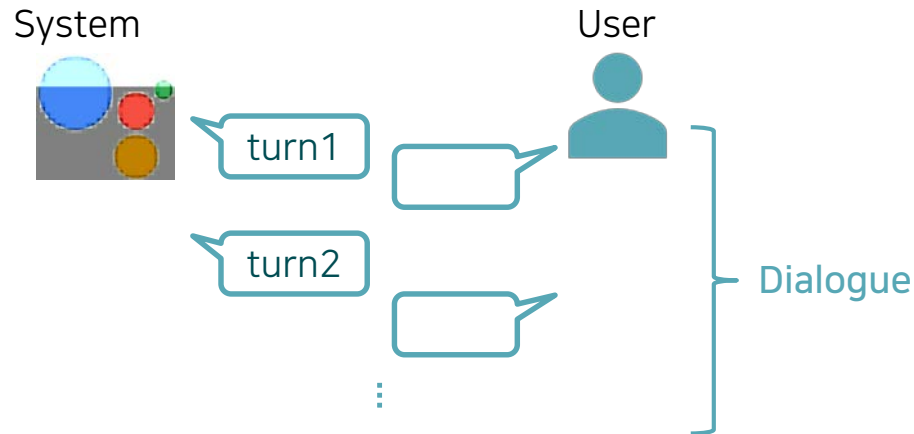
"그러면 저녁에 나가서
축구하면 되겠네요."

"..."




연구 내용 - Motivation (1/2)

- 대화 시스템내에 Breakdown이 발생하는 이유
 - 사람과 시스템이 발화를 여러 번 주고 받는 multi-turn으로 인해 시스템이 사용자의 의도를 잘못 이해
 - 시스템이 대화의 모든 흐름을 파악하기 어려움



연구 내용 - 연구 내용 - Motivation (2/2)

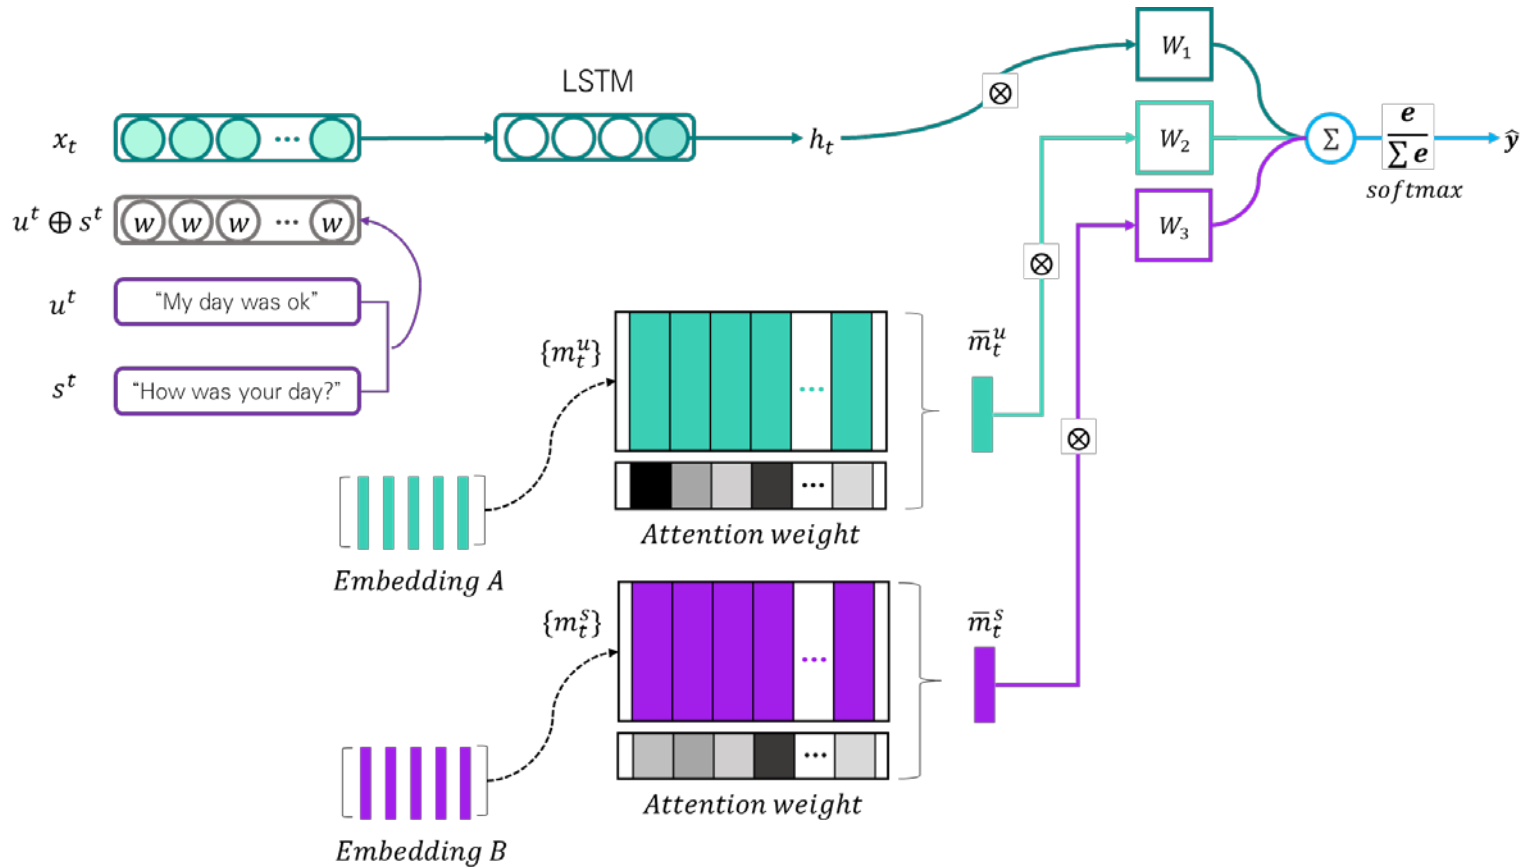
- Breakdown detection을 위한 기존 방법들은 hand-crafted feature들을 이용하거나 단순한 구조의 end-to-end방식을 사용함
 - 대화 시스템 고유의 특성을 반영하지 못함
 - 시스템이 이전 발화들을 기억하게 하면서 그 중 중요한 발화들에 중점을 뒤편보자



연구 내용 - Proposed model

- Temporal Utterance Encoding model
 - End-to-End
 - Memory Attention (memory network based)
- 제안한 모델은 LSTM을 이용하여 대화내에 사용자와 시스템의 발화를 인코딩하고 시스템 발화에 대해 memory network기반의 attention을 적용함

연구 내용 - Proposed model



s^t : system utterance at time step t

u^t : user utterance at time step t

$\{m_t^s\}$: system memory vectors

$\{m_t^u\}$: user memory vectors

연구 내용 - Dataset

- DSTC6(Dialog system technology challenges)
- DBDC3 dataset for training
 - IRIS-100, TKTK-100, CIC-115, YI-100 (English)
 - Dialogue 415개
 - 20 또는 21개의 발화로 구성된 dialogue
 - 각 system utterance에 대해 사람이 세 개의 label (Non breakdown, possibly breakdown, Breakdown) 중 태깅하여 voting
- Evaluation dataset
 - IRIS-50, TKTK-50, CIC-50, YI-50

연구 내용 - Evaluation

- Baseline – CRF(Conditional random field)
- Evaluation metrics
 - Classification-related: Accuracy, precision, recall, f1
 - Distribution-related: JS divergence, Mean squared error
- 비교 모델
 - 제안한 모델 – TU(no memory net), TU+S(system memory), TU+U(user memory), TU+S+U(sys+user memory)
 - KTH – LSTM, SVM
 - PLECO – Memory network
 - RSL17BD - ExtraTreesRegressor

연구 내용 - Experiment results(1/3)

- Classification-based
 - TU+S+U에서 기존 모델보다 뛰어난 성능을 보임

		Model								
		Proposed model				CRF Baseline	Majority Baseline	KTH run2	PLECO run1	RSL17BD run2
		TU	TU+S	TU+U	TU+S+U					
	Accuracy	0.458	0.464	0.467	0.47	0.4285	0.3720	0.4415	0.2950	0.4310
F1	F1(B)	0.5146	0.532	0.533	0.556	0.3543	0.3343	0.2949	0.3636	0.3201
	F1(PB+B)	0.6737	0.6906	0.6679	0.7441	0.76722	0.8927	0.7440	0.8744	0.8400

연구 내용 - Experiment results(2/3)

- Distribution-based
 - 기존 모델의 성능이 더 뛰어났음

		Model								
		Proposed model				CRF Baseline	Majority Baseline	KTH run2	PLECO run1	RSL17BD run2
		TU	TU+S	TU+U	TU+S+U					
JSD	JSD(NB,PB,B)	0.0775	0.0749	0.075	0.0976	0.4409	0.0393	0.0481	0.0714	0.0412
	JSD(NB,PB+B)	0.056	0.0483	0.0478	0.0536	0.2687	0.0237	0.0267	0.0427	0.0256
	JSD(NB+PB,B)	0.0375	0.0388	0.0367	0.06	0.2985	0.0257	0.0262	0.0535	0.0225
MSE	MSE(NB,PB,B)	0.0452	0.0435	0.0432	0.058	0.2185	0.0224	0.0281	0.0415	0.0241
	MSE(NB,PB+B)	0.0651	0.0567	0.0561	0.0622	0.2171	0.0278	0.0315	0.0455	0.0301
	MSE(NB+PB,B)	0.0413	0.0436	0.0413	0.0707	0.2578	0.0264	0.0286	0.0632	0.0246

연구 내용 - Experiment results(3/3)

- Qualitative evaluation
 - Memory attention distribution(TU+S+U)을 이용한 정성적 평가

Role	Utterances	Memory Attention Distribution	
		user memory	system memory
User1	Hello how are you?	0.004	
System1	Hello, I really like movies. how about we talk about movies?		0.063
User2	That sounds good i like movies. what is your favorite movie?	0.0365	
System2	Hello, I really like movies. how about we talk about movies?		0.063
User3	That sounds good i like movies. what is your favorite movie?	0.0365	
System3	Ok. Let me know something you're interested in.		0.178
User4	I would like to talk about movies.	0.0366	
System4	Ok. Let me know something you're interested in.		0.178
User5	I would like to talk about movies.	0.0366	
System5	I like pop music.		0.258
User6	Do you like avril lavigne?	0.849	
System6	I like pop music. (Dialogue break down)		0.258

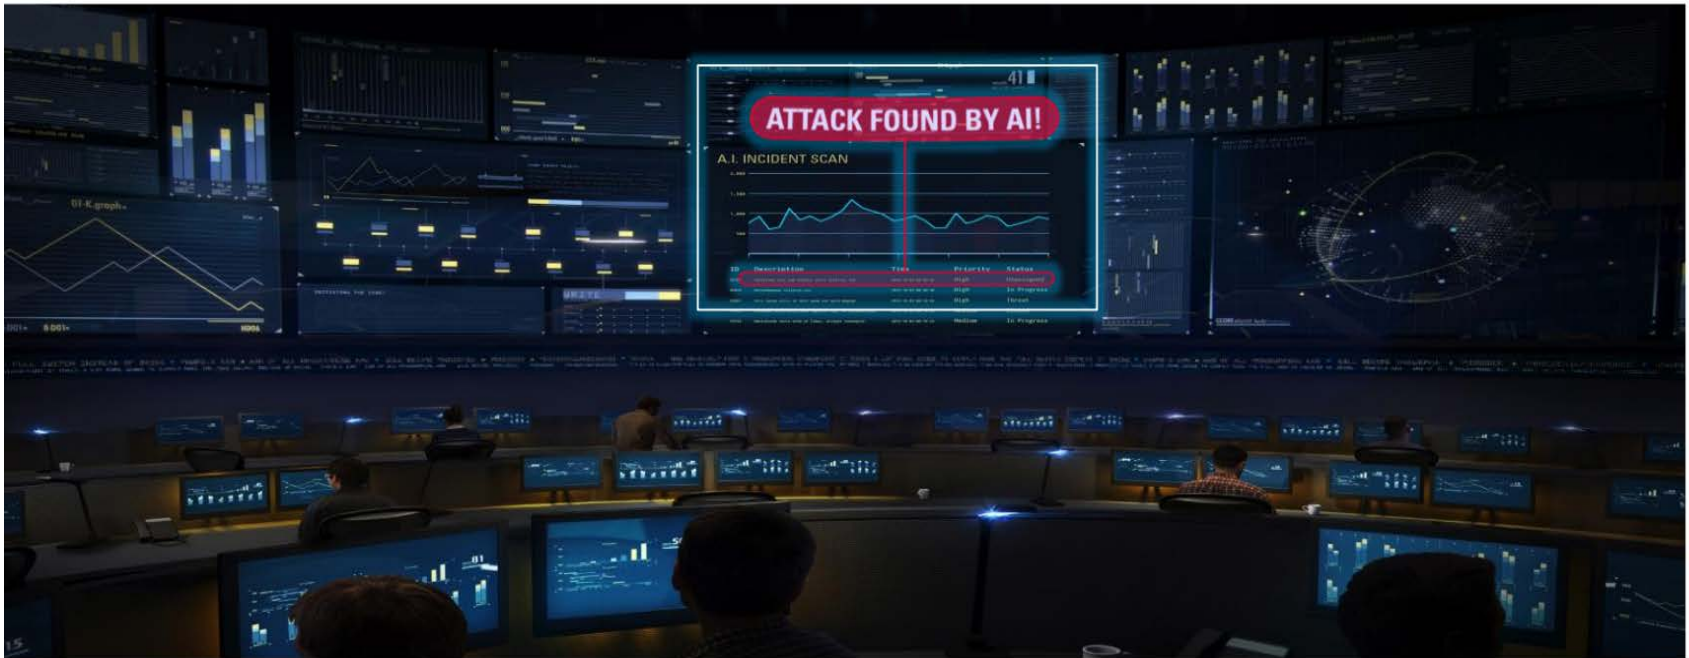
Table 3: Example predictions of user and system memory attention distribution on DBDC3 task.

An Analysis on AI in CyberSecurity

고려대학교 NLP&AI Lab.

Aiyanyo Imatitikua Danielle

연구 내용 - The Ultimate goal



Predictive Protection

연구 내용 - The Ultimate goal

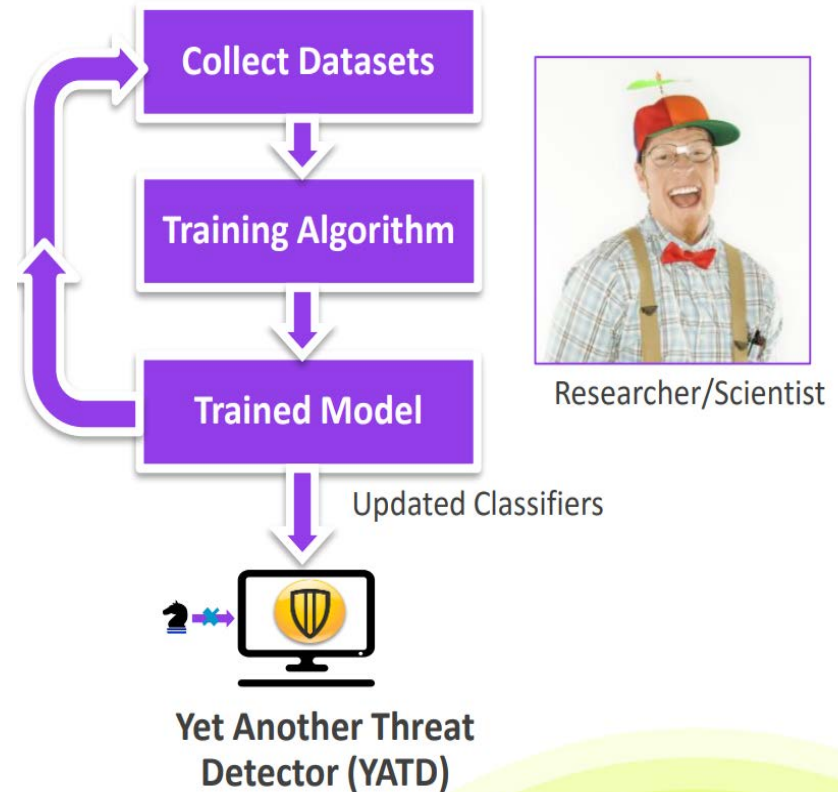
- A system that anticipates attacks and automatically reconfigures for protection.
- Real-time conversation monitoring for
 - Social engineering
 - Cyberbullying
 - Fake news etc
- Threat detection systems that learn to learn

연구 내용 - Powered by Learning

❖ Yet Another Threat Detector

- Data with labels
- Debate about techniques
- Rely on data scientists
 - Feature engineering
 - Updates & tweaks

❖ Primarily by automation



연구 내용 - The Actors

Abundant
Data

Leading
Experts

Features

Techniques

- 9 Trillion rows of security data
- 4.5B queries processed daily from 175M endpoint devices
- 2B emails scanned daily
- 1B previously unseen web requests scanned daily
- Outputs from other systems and products
- Dedicated organization of experts
- World renowned attack investigation team
- Centuries of combined AI experience.
- Static attributes
- Dynamic behaviors
- Reputation
- Relations
- Sequential state
- Ensembling
- Boosting
- Sequential Learning
- Deep Learning
- Automation

연구 내용 - The Tools

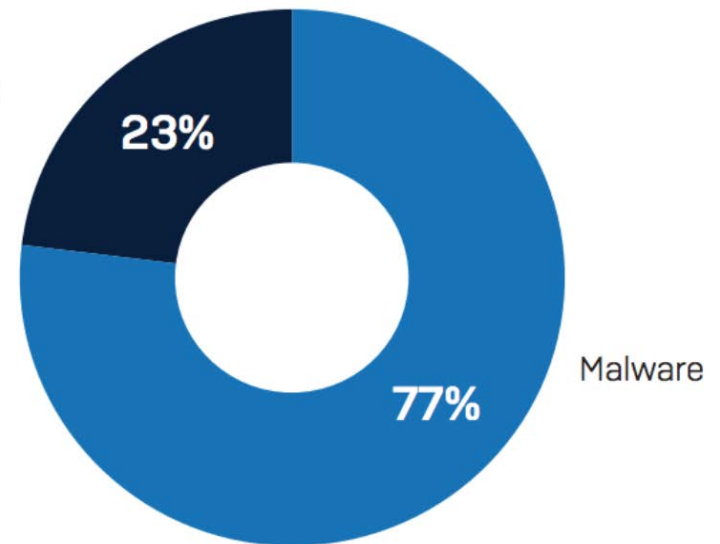
- Supervised or Unsupervised Learning
 - In the field of malware classification many of the techniques used to implement supervised or unsupervised Machine Learning offer significant benefits in terms of accurate and fast classification of malware with very low False Positive rates, but it does require a large training base, extensive data expertise and resources.
 - Supervised: Malware classification, Spam identification, MLSec project on firewall data
 - Unsupervised: DNS analytics, Threat intelligence, Tier 1 analyst automation, User and Entity Behavior Analytics.
- Deep Learning

연구 내용 - The Challenges

- Ransomware Evolution
- AI Expansion
- IOT threats
- Blockchain
- Serverless Apps
- Network traffic data
- Real time scenarios
- Adaptive attacking behavior
- Anomaly detection for cloud servers
- Testing deep learning based intrusion detection

2017 Android Samples Distribution

PUA samples count



연구 내용 - Future Direction

- Reducing training and detection time
- Real world scenarios
- Outlier detection algorithms to take into consideration the evolving nature of threat
- Integrate file specific behavioral detection into endpoint anti-virus systems

보고서 자동 분석 및 Topic 자동 추출 기술 연구

고려대학교 NLP&AI Lab.



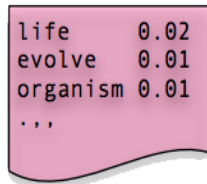

허윤아

연구 목표 - 보고서 Topic 자동 추출

- Topic Modeling이란 문서 집합의 추상적인 “주제”를 발견하기 위한 통계적 모델링임
- 정보화 시대가 도래하면서 매일 생성되는 텍스트는 인간이 직접 처리할 수 있는 양을 크게 넘어서는데, 토픽 모델은 자동적으로 비정형 텍스트의 집합을 이해하기 쉽도록 조직하고 정리하는 데에 쓰일 수 있음
- 실제로 문헌 내에 어떤 주제가 들어있고, 주제 간의 비중이 어떠한지는 문헌 집합 내의 단어 통계를 수학적으로 분석함으로써 알아낼 수 있음
- 또한, 토픽 모델은 원래 개발된 목적인 텍스트 마이닝 분야 이외에도 유전자 정보, 이미지, 네트워크와 같은 자료에서 유의미한 구조를 발견하는 데에도 유용하게 사용되고 있음

연구 내용 - 보고서 Topic 자동 추출

Topics



Documents

Seeking Life's Bare (Genetic) Necessities


COLD SPRING HARBOR, NEW YORK— How many **genes** does an **organism** need to **survive**? Last week at the genome meeting here,* two genome researchers with radically different approaches presented complementary views of the basic genes needed for **life**. One research team, using **computer** analyses to compare known **genomes**, concluded that today's **organisms** can be sustained with just 250 genes, and that the earliest life forms required a mere 128 **genes**. The other researcher mapped genes in a simple parasite and estimated that for this organism, 800 genes are plenty to do the job—but that anything short of 100 wouldn't be enough. Although the numbers don't match precisely, those **predictions** “are not all that far apart,” especially in comparison to the 75,000 **genes** in the human genome, notes Siv Andersson of Uppsala University in Sweden, who arrived at the 800 number. But coming up with a consensus answer may be more than just a **genetic numbers** game, particularly as more and more **genomes** are completely mapped and sequenced. “It may be a way of organizing any newly **sequenced genome**,” explains Arcady Mushegian, a **computational** molecular biologist at the National Center for Biotechnology Information (NCBI) in Bethesda, Maryland. Comparing an

Stripping down. Computer analysis yields an estimate of the minimum modern and ancient genomes.

* Genome Mapping and Sequencing, Cold Spring Harbor, New York, May 8 to 12.

SCIENCE • VOL. 272 • 24 MAY 1996

Topic proportions & assignments



연구 내용 - Latent Dirichlet Allocation(LDA)

- LDA 란?
 - LDA(Latent Dirichlet Allocation) 주어진 문서에 대해서 각 문서는 어떤 주제들이 존재하는지 확률적으로 추출하는 Topic Modeling 기법 중 하나임

[LDA 모델 예시]

- Document 1: I had a peanut butter sandwich for breakfast.
- Document 2: I like to eat almonds, peanuts and walnuts.
- Document 3: My neighbor got a little dog yesterday.
- Document 4: Cats and dogs are mortal enemies.
- Document 5: You mustn't feed peanuts to your dog.



LDA 모델을 통해 문서에서 나타나는 여러 주제를 발견함

[LDA 결과]

- Topic 1: 30% peanuts, 15% almonds, 10% breakfast... (-> food 라고 해석)
- Topic 2: 20% dogs, 10% cats, 5% peanuts... (->동물이라고 해석)

연구 내용 - Latent Dirichlet Allocation(LDA)

- LDA 란?
 - LDA(Latent Dirichlet Allocation) 주어진 문서에 대해서 각 문서는 어떤 주제들이 존재하는지 확률적으로 추출하는 Topic Modeling 기법 중 하나임

[LDA 모델 예시]

- Document 1: I had a peanut butter sandwich for breakfast.
- Document 2: I like to eat almonds, peanuts and walnuts.
- Document 3: My neighbor got a little dog yesterday.
- Document 4: Cats and dogs are mortal enemies.
- Document 5: You mustn't feed peanuts to your dog.

[Topic 결과]

- Document 1 and 2 : 100% Topic 1
- Document 3 and 4 :100% Topic 2
- Document 5 : 70% Topic 1, 30% Topic 2



LDA 모델을 통해 문서에서 나타나는 여러 주제를 발견함

[LDA 결과]

- Topic 1: 30% peanuts, 15% almonds, 10% breakfast... (-> food 라고 해석)
- Topic 2: 20% dogs, 10% cats, 5% peanuts... (->동물이라고 해석)

연구 내용 - Topic Modeling

❖ Procedure

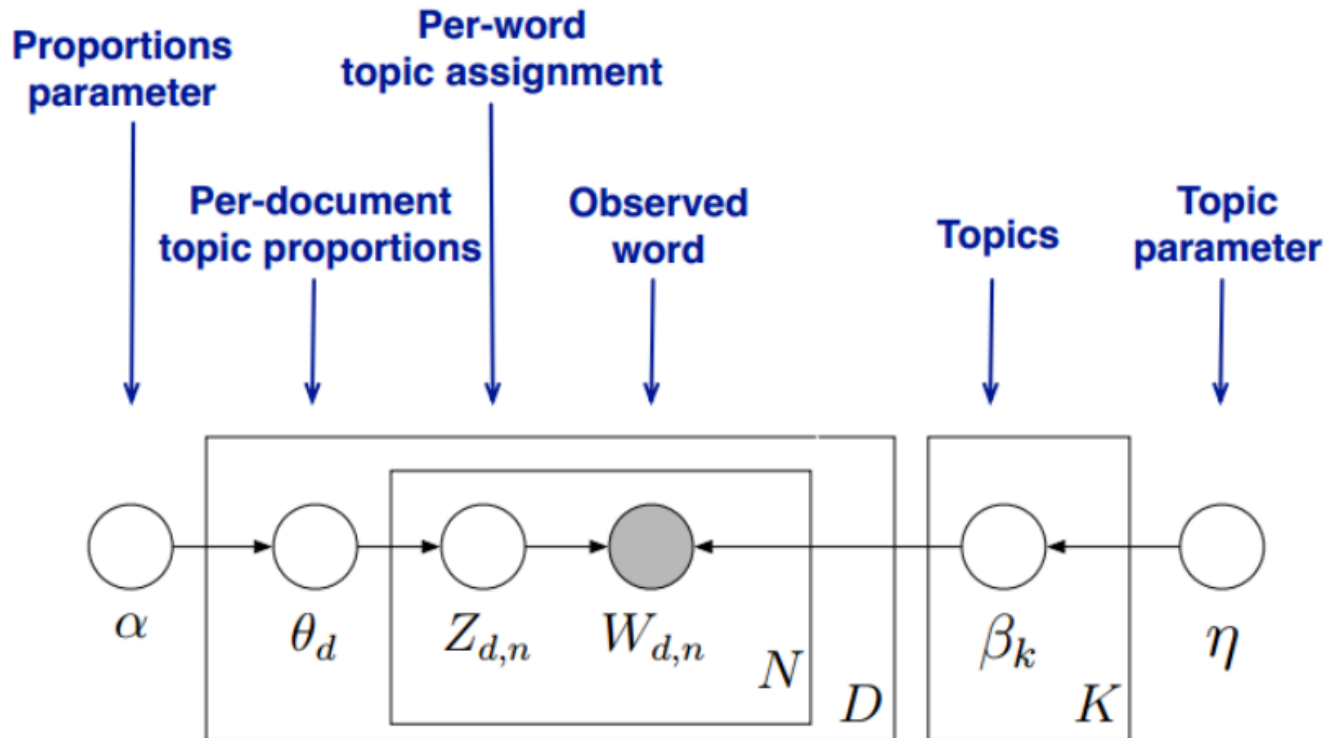
- 전체 문서에 대한 전처리와 Topic 이 될 수 있는 단어 생성을 위해 전처리를 진행함
 - am / is / are / of / a / the / but / ...와 같은 단어는 "주제"에 대한 정보가 없기 때문에 제거함
- 각 문서 내에서 중요하고 효과적인 단어를 구성하여 단어 집합을 생성함
- 실제 문서(d) 에서 각 단어 w 를 통해 연산함
 - $p(\text{topic } t \mid \text{document } d)$: 문서에서 topic(word)이 나온 비율(확률)

	w_1	w_2	w_3	w_n
D1	0	2	1	3
D2	1	4	0	0
D3	0	2	3	1
D_n	1	1	3	0

연구 내용 - Topic Modeling

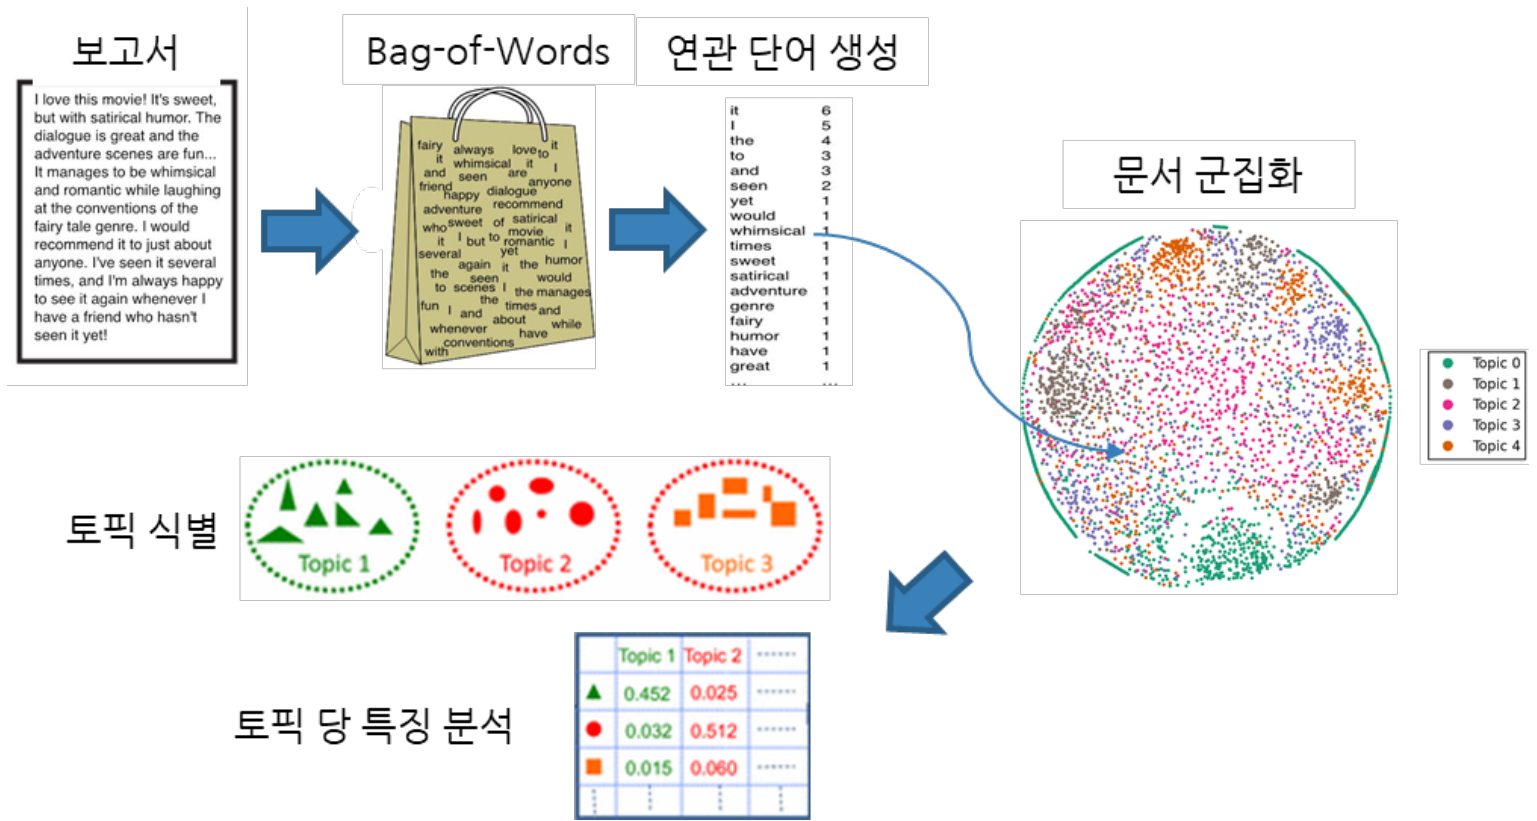
❖ Topic Model Definition

- 목표 : 전체 문서에서 Topic을 추측 또는 추정하는 것



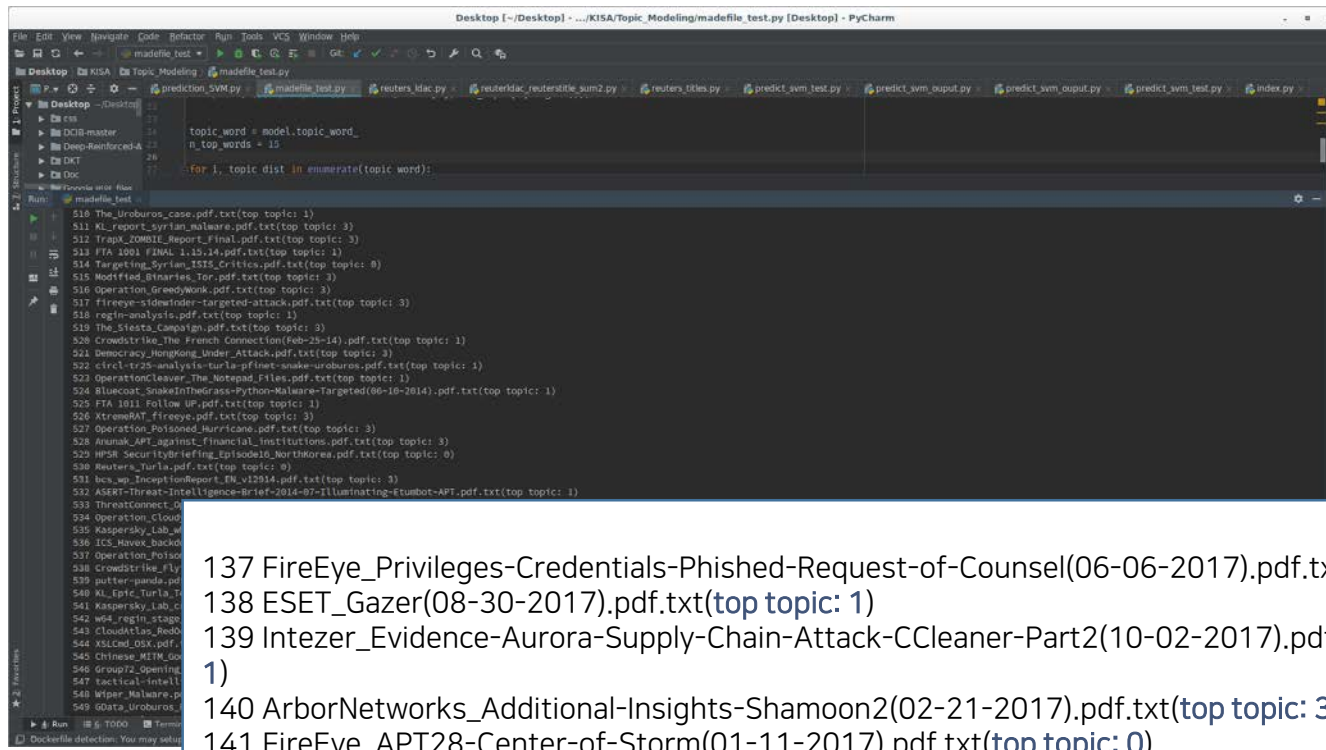
연구 내용 - Topic Modeling

❖ 문서 토픽 자동 추출 시스템 구조도



연구 결과 - Topic Modeling

❖ 각 인텔리전스 보고서마다 토픽 자동 추출



Character-Level Feature Extraction with Densely Connected Networks

고려대학교 NLP&AI Lab.


이찬희

Introduction | Background

- 효과적인 문자 단위 feature를 만들어내는 것은 많은 자연어처리 task에서 매우 중요함
 - Named Entity Recognition (NER), Part-of-Speech (POS) Tagging, Slot tagging 등
- State-of-the-art method들은 어떤 형태로든 문자 단위 feature를 활용함
 - Hand-crafted feature
 - Convolutional Neural Network (CNN) 활용
 - Recurrent Neural Network (RNN) 활용
- 이 중 CNN이나 RNN과 같은 Neural Network을 활용하는 방법은 전문가 지식이나 시간 투자의 필요성이 낮으면서도 탁월한 성능을 보여 각광 받음


Introduction | CNN

- Convolutional Neural Network (CNN)을 이용하여 단어를 구성하는 문자로부터 feature vector 생성
 - Word embedding과 같은 방법으로 각 문자를 character embedding로 변환
 - 단어를 구성하는 문자들의 character embedding에 convolution 적용 후, pooling을 사용하여 단어 벡터 생성
- 단점 - 단어 내 n-gram의 순서와 단어 벡터가 독립적이므로 위치 정보가 손실됨



Introduction | RNN

- Recurrent Neural Network (RNN)을 이용하여 단어를 구성하는 문자로부터 feature vector 생성
 - 단어를 구성하는 문자들의 character embedding에 RNN을 적용하여 단어 벡터 생성
 - Word embedding을 보조하는 역할로 사용, 혹은 word embedding 없이 character RNN만을 사용
- 단점 - 문자를 순차적으로 처리해야 하므로 계산 속도가 느림



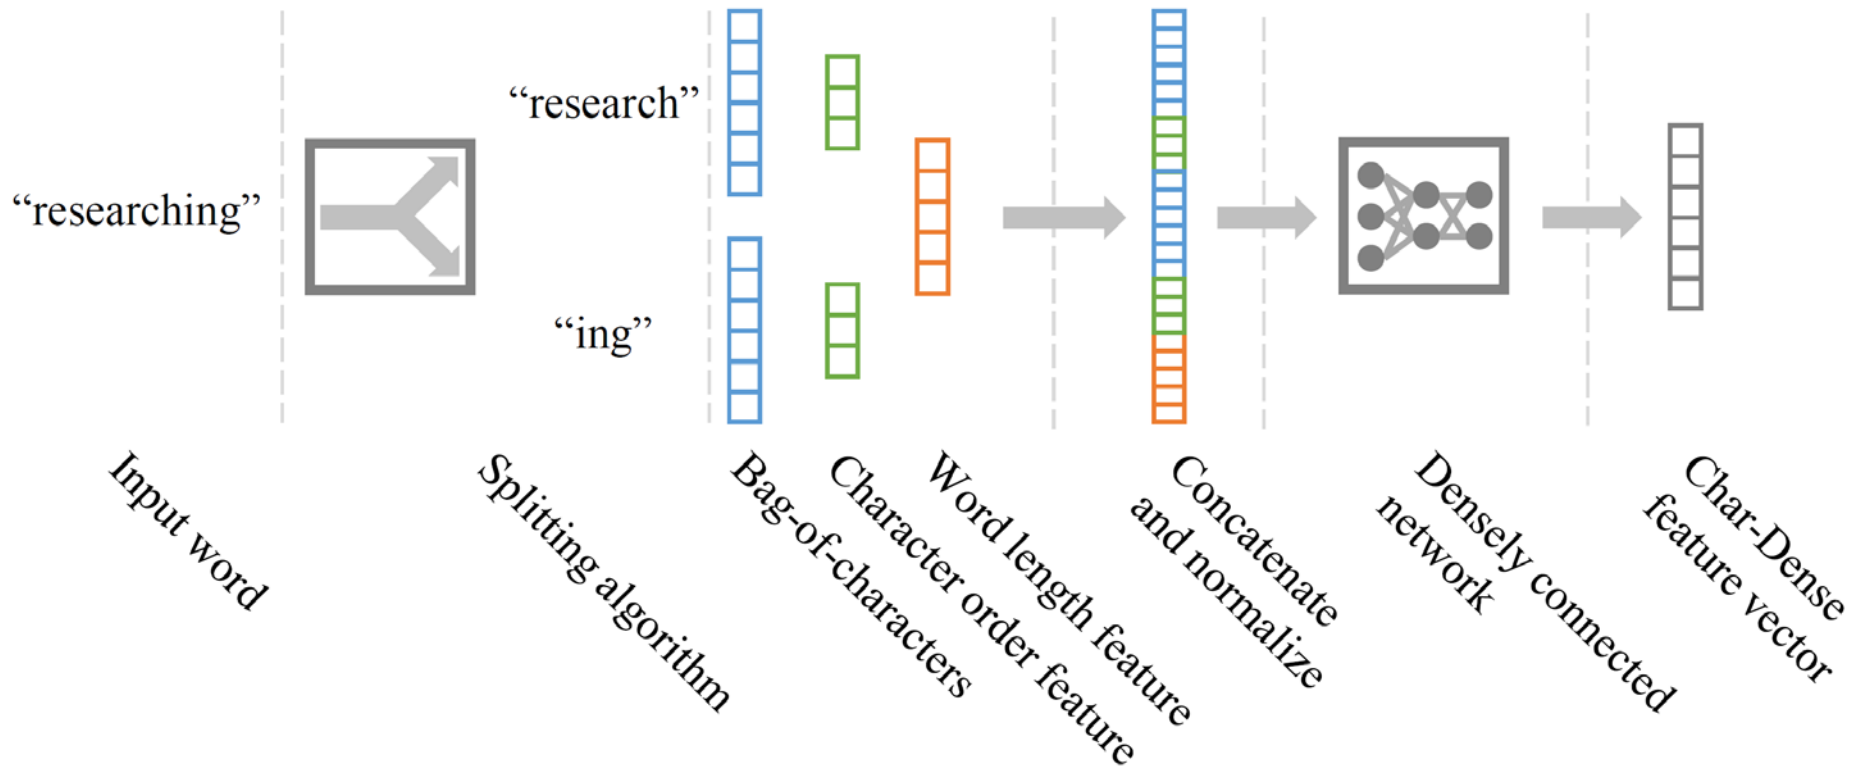
Introduction | Contribution

- Densely connected network (i.e. feed-forward NN, fully-connected NN, multi-layer perceptron)을 이용하여 효과적인 문자 단위 feature를 만들어내는 방법을 제안함
- 제안된 방법의 장점
- Hand-crafted feature나 data 전처리가 필요하지 않음
- RNN/CNN 대비 빠른 계산 속도를 보여주면서 성능도 우수함
- 특정 언어나 task에 국한되지 않음 - 알파벳권에만 존재하는 대소문자 정보나, NER에 많이 활용되는 gazetteer (개체명 사전) 불필요
- Contribution
- 효과적인 동시에 효율적인 문자 단위 feature 생성 방법을 제안함
- 다수의 실험을 통해 제안된 방법이 CNN 및 RNN보다 우수함을 정량적으로 증명함
- 가장 많이 연구된 NLP task들인 NER, POS, Slot tagging에서 state-of-the-art (POS, Slot) 혹은 그에 근접한 (NER) 성능을 보임

Proposed Method | Overview

- 제안된 방법은 Bag-of-Characters (BOC)를 바탕으로 함
- BOC는 문자의 순서 정보가 손실되기 때문에 word collision 현상이 발생함
 - Word collision - 서로 다른 단어가 동일한 vector 표현을 갖는 현상
- 이를 극복하기 위해 단어를 분할하고, 추가적인 feature를 추가
 - 이 때, feature들은 모두 특정 언어/task에 국한되지 않고 자동적으로 추출 가능
- 문자 BOC, 문자 순서 feature, 단어 길이 feature를 concatenate 하여 sparse vector를 생성함
 - 이 sparse vector는 단어마다 유일하고 변하지 않으므로 속도 향상을 위해 캐싱
- Sparse vector를 하나의 hidden layer가 있는 densely connected network의 입력으로 사용해서 dense feature vector를 생성

Proposed Method | Overview



Proposed Method | Splitting Words

- 각 단어는 k 개의 조각으로 분할됨
 - Word collision을 줄이기 위함
- 학습 말뭉치의 n -gram 통계를 활용, 단어가 고빈도 n -gram들로 분할되도록 함
- Byte-pair encoding (BPE) 방법과 유사하지만, BPE는 임의의 개수로 단어를 분할하는 반면 제안된 방법은 단어가 k 개의 조각으로 분할됨을 보장함
 - Concatenation과 Densely Connected Network을 이용하기 때문에 일정한 개수로 분할하는 것이 필수
- 각 단어 조각은 BOC를 이용하여 vector로 변환

Proposed Method | Splitting Words

Algorithm 1: Splitting word into k pieces

Input : word $w = (c_1, c_2, \dots, c_n)$, n-gram statistics C_{ng} , number of pieces k

Output: $S = (s_1, \dots, s_k)$ where $s_1 + s_2 + \dots + s_k = w$

```
1  $S \leftarrow w$ 
2 while  $|S| > k$  do
3   |  $m = \underset{i}{\operatorname{argmax}} C_{ng}(c_i + c_{i+1})$ 
4   |  $S \leftarrow (\dots, s_{m-1}, s_m + s_{m+1}, s_{m+2}, \dots)$ 
5 end
6 while  $|S| < k$  do
7   | Append empty string to  $S$ 
8 end
9 return  $S$ 
```

Proposed Method | Character Order Feature

- BOC로 인해 문자 순서 정보가 손실되므로, 이를 보충할 feature를 추가함
- 디지털로 표현 가능한 모든 문자는 character-set (e.g. UTF-16)으로부터 숫자로 변환될 수 있으며, 이에 따라 문자 간 순서 비교가 가능함
- 길이 n 의 문자열 $T=\{c_1, c_2, \dots, c_n\}$ 로부터 아래 식에 따라 $C_{asc}(T)$ 와 $C_{des}(T)$ 를 계산함
- 각 단어 조각은 $C_{asc}(T) > C_{des}(T)$, $C_{asc}(T) = C_{des}(T)$, $C_{asc}(T) < C_{des}(T)$ 중 하나로 분류되며, 이 정보를 3차원 one-hot vector로 표현함

$$F_{asc}(T, k) = \begin{cases} 1, & \text{if } c_k < c_{k+1} \\ 0, & \text{otherwise} \end{cases}, \quad F_{des}(T, k) = \begin{cases} 1, & \text{if } c_k > c_{k+1} \\ 0, & \text{otherwise} \end{cases}$$

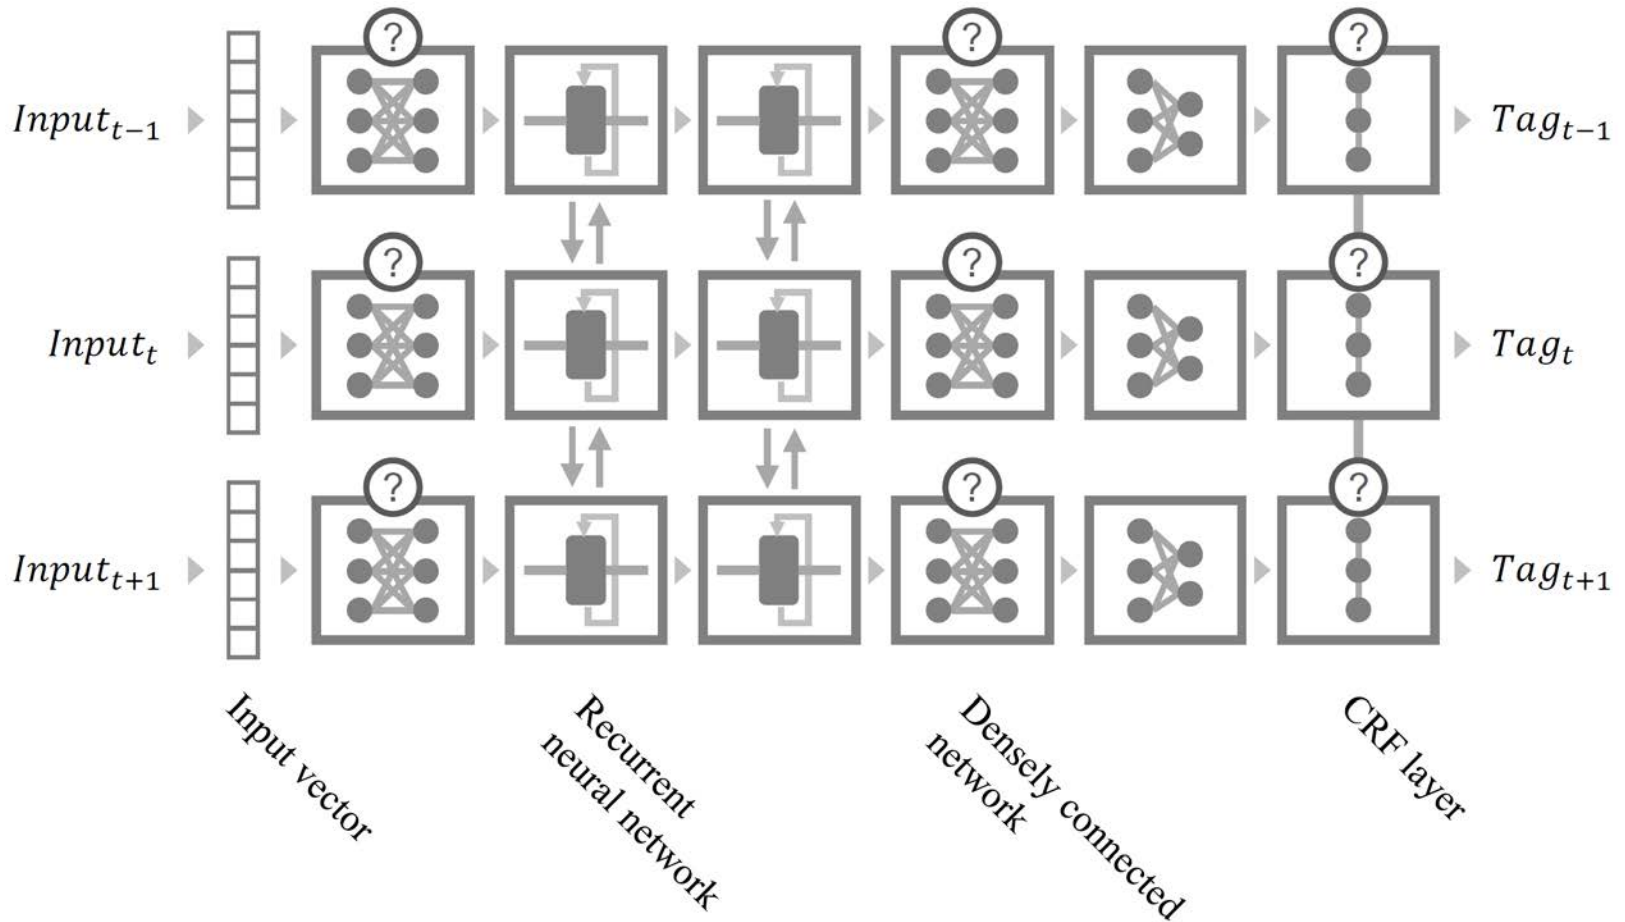
$$C_{asc}(T) = \sum_{k=1}^{n-1} F_{asc}(T, k), \quad C_{des}(T) = \sum_{k=1}^{n-1} F_{des}(T, k)$$

Proposed Method | Word Length Feature

- Word collision의 추가적인 감소를 위해, 각 단어를 구성하는 문자의 수를 feature로 활용
- 0~20의 숫자를 one-hot encoding을 이용하여 vector로 표현하며, 20글자를 초과하는 단어는 20글자로 취급

Experimental Setup | Model

- Sequence tagging은 Bidirectional-LSTM-CRF 모델을 사용함



Experimental Setup | Evaluation

- 제안된 모델을 3개의 task를 통해 정량적으로 검증함
- Slot tagging
 - Airline Travel Information System (ATIS) dataset 사용
 - 84종의 slot label (BIO 적용으로 127종의 class label)
- Part-of-Speech Tagging
 - Wall Street Journal (WSJ) portion of the Penn TreeBank (PTB) dataset 사용
 - 45종의 POS label
- Named Entity Recognition
 - CoNLL-2003 dataset 사용
 - 4종의 entity label (BIO 적용으로 9종의 class label)

Experimental Setup | Baseline Models

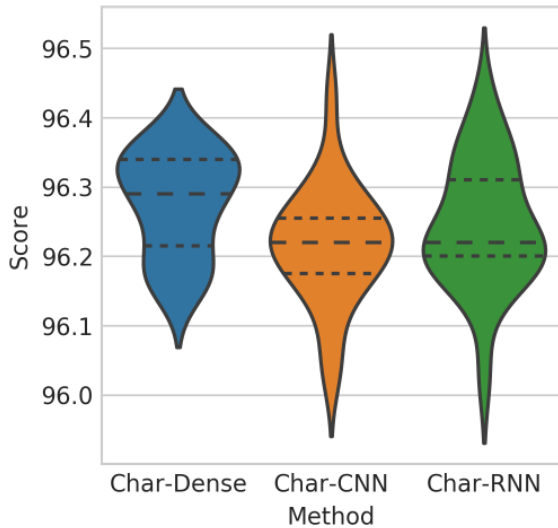
- CNN/RNN을 이용하여 문자 단위 feature를 생성하는 모델을 baseline으로 사용
- 문자 단위 feature 생성 방법 외의 모든 모델 구조는 동일하게 적용
- CRF layer는 모델 구조의 변화에 대해 robust하게 만드는 영향이 있으므로, 모델 간 차이를 확인하기 위해 baseline 실험에서는 CRF 대신 softmax layer 사용

Results and Discussion | Baseline Models

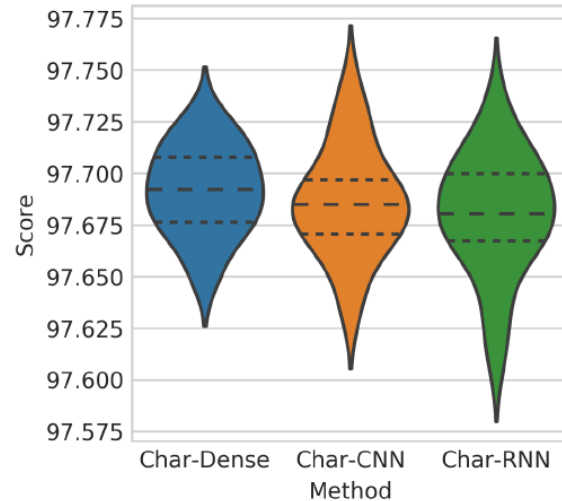
Method	Task		
	Slot	POS	NER
Char-CNN	96.22 (SD 0.08)	97.68 (SD 0.03)	89.08 (SD 0.20)
Char-RNN	96.25 (SD 0.09)	97.68 (SD 0.03)	90.15 (SD 0.14)
Char-Dense (Ours)	96.28 (SD 0.07)	97.69 (SD 0.02)	90.10 (SD 0.13)

- Baseline model들과의 성능 비교. SD=standard deviation

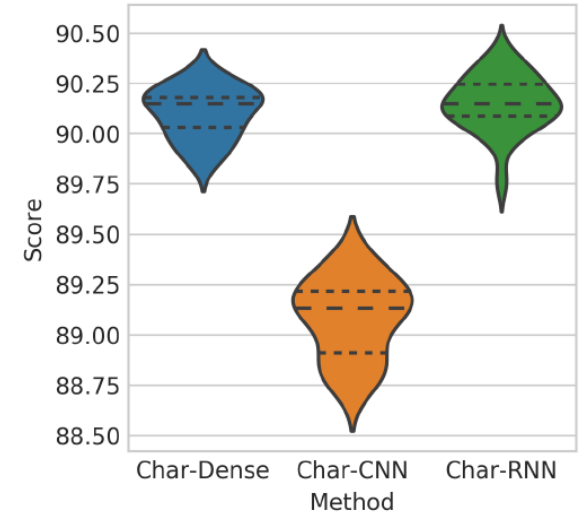
Results and Discussion | Baseline Models



(a) Slot



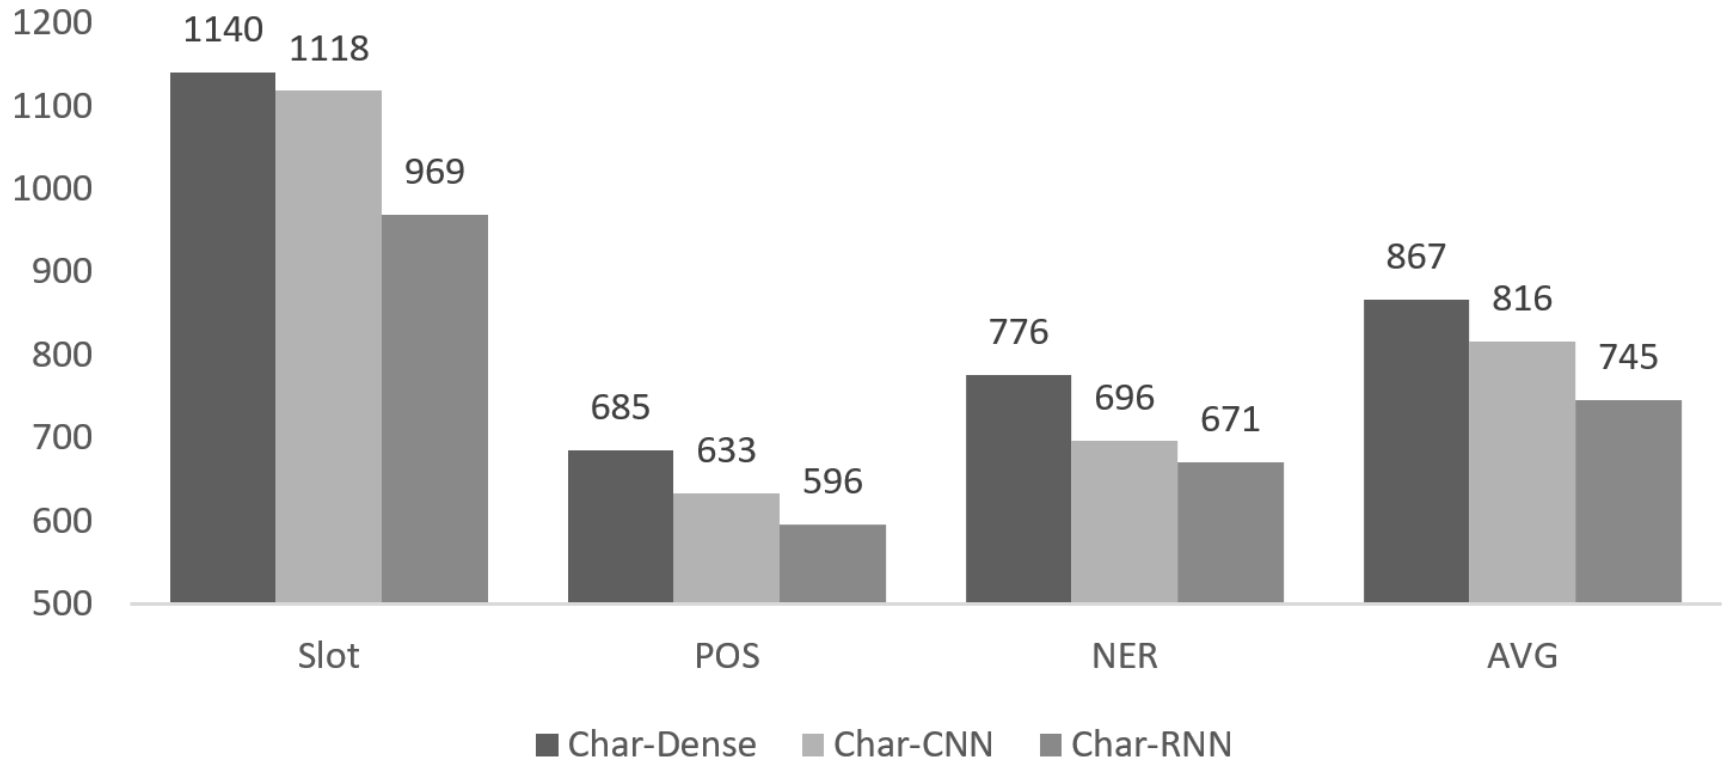
(b) POS



(c) NER

- 성능 분포를 나타낸 violin plot. 점선은 quartile을 나타냄

Results and Discussion | Tagging Speed



- 모델별 tagging 속도 비교. (초당 처리 문장 수)
- 제안된 모델에서 RNN 대비 16.32%, CNN 대비 6.29% 속도 향상이 나타남

Results and Discussion | Comparison

Slot		POS		NER	
Approach	F1	Approach	Acc.	Approach	F1
Mesnil et al. (2015)	94.73	Toutanova et al. (2003)	97.24	Ando and Zhang (2005)	89.31
Yao et al. (2014)	94.85	Manning (2011)	97.32	Collobert et al. (2011)	89.59
Liu and Lane (2015)	94.89	Shen et al. (2007)	97.33	Huang et al. (2015)	90.10
Yao et al. (2014)	95.08	Sun (2014)	97.36	Chiu and Nichols (2015)	90.77
Peng and Yao (2015)	95.25	Moore (2015)	97.36	Ratinov and Roth (2009)	90.80
Vu et al. (2016)	95.56	Hajič et al. (2009)	97.44	Lin and Wu (2009)	90.90
Vu (2016)	95.61	Søgaard (2011)	97.50	Passos et al. (2014)	90.90
Kurata et al. (2016)	95.66	Tsuboi (2014)	97.51	Lample et al. (2016)	90.94
Zhu and Yu (2017)	95.79	Huang et al. (2015)	97.55	Luo et al. (2015)	91.20
Zhai et al. (2017)	95.86	Choi (2016)	97.64	Ma and Hovy (2016)	91.21
Char-Dense w/o CRF (Ours)	96.36	Char-Dense w/o CRF (Ours)	97.73	Char-Dense w/o CRF (Ours)	90.28
Char-Dense w/ CRF (Ours)	96.62	Char-Dense w/ CRF (Ours)	97.65	Char-Dense w/ CRF (Ours)	91.13

Conclusion

- 효과적인 동시에 효율적인 문자 단위 feature 생성 방법을 제안하였음
- 제안된 방법은 parameter initialization의 영향을 CNN/RNN에 비하여 적게 받음
- 제안된 방법은 특정 언어나 task에 국한되지 않으며 generalizability가 우수함

- Future Work
 - 철자 오류에 대한 robustness 실험
 - Machine translation이나 automatic text summarization과 같은 추가적인 자연어처리 task에 적용

Structured “Image – Text” Mapping for Bidirectional “Image – Text” Transitions

고려대학교 NLP&AI Lab.

김규경

연구 소개 - 문제점 및 목표 소개

- Image-Text processing의 문제점:
 - 이미지 → 텍스트의 경우:
 - ▶ 비(非)구조적인 접근으로 인하여 오류 수정 및 학습에 개입하기 힘들
 - 텍스트 → Object의 경우:
 - ▶ 텍스트가 표현하는 대상(이미지)의 속성을 고려하지 않아 당연한 논리적 결과를 인지 못함
- 목표:
 - 구조적인 이미지 - 텍스트 Embedded Map을 구축하여 구조적인 이미지 분석과 대상 속성을 고려하는 Semantic Text Embedding을 가능케 하는 모델의 구축

연구 내용 - 문제점 및 목표 소개

- 이미지 → 텍스트의 경우:구조적인 접근의 부재



Okapi



Deer




Zebra

- 각각 Deer, Zebra, Okapi를 학습하여도 3 동물의 구조적인 공통점과 차이점을 분석 못함.
- 이미지내의 수많은 Feature들을 분석하지 않고 한번에 처리하면서 생기는 결과
- 해당 연구에서는 이러한 Feature들의 구조적인 분석을 거치는 Recognition을 시도함

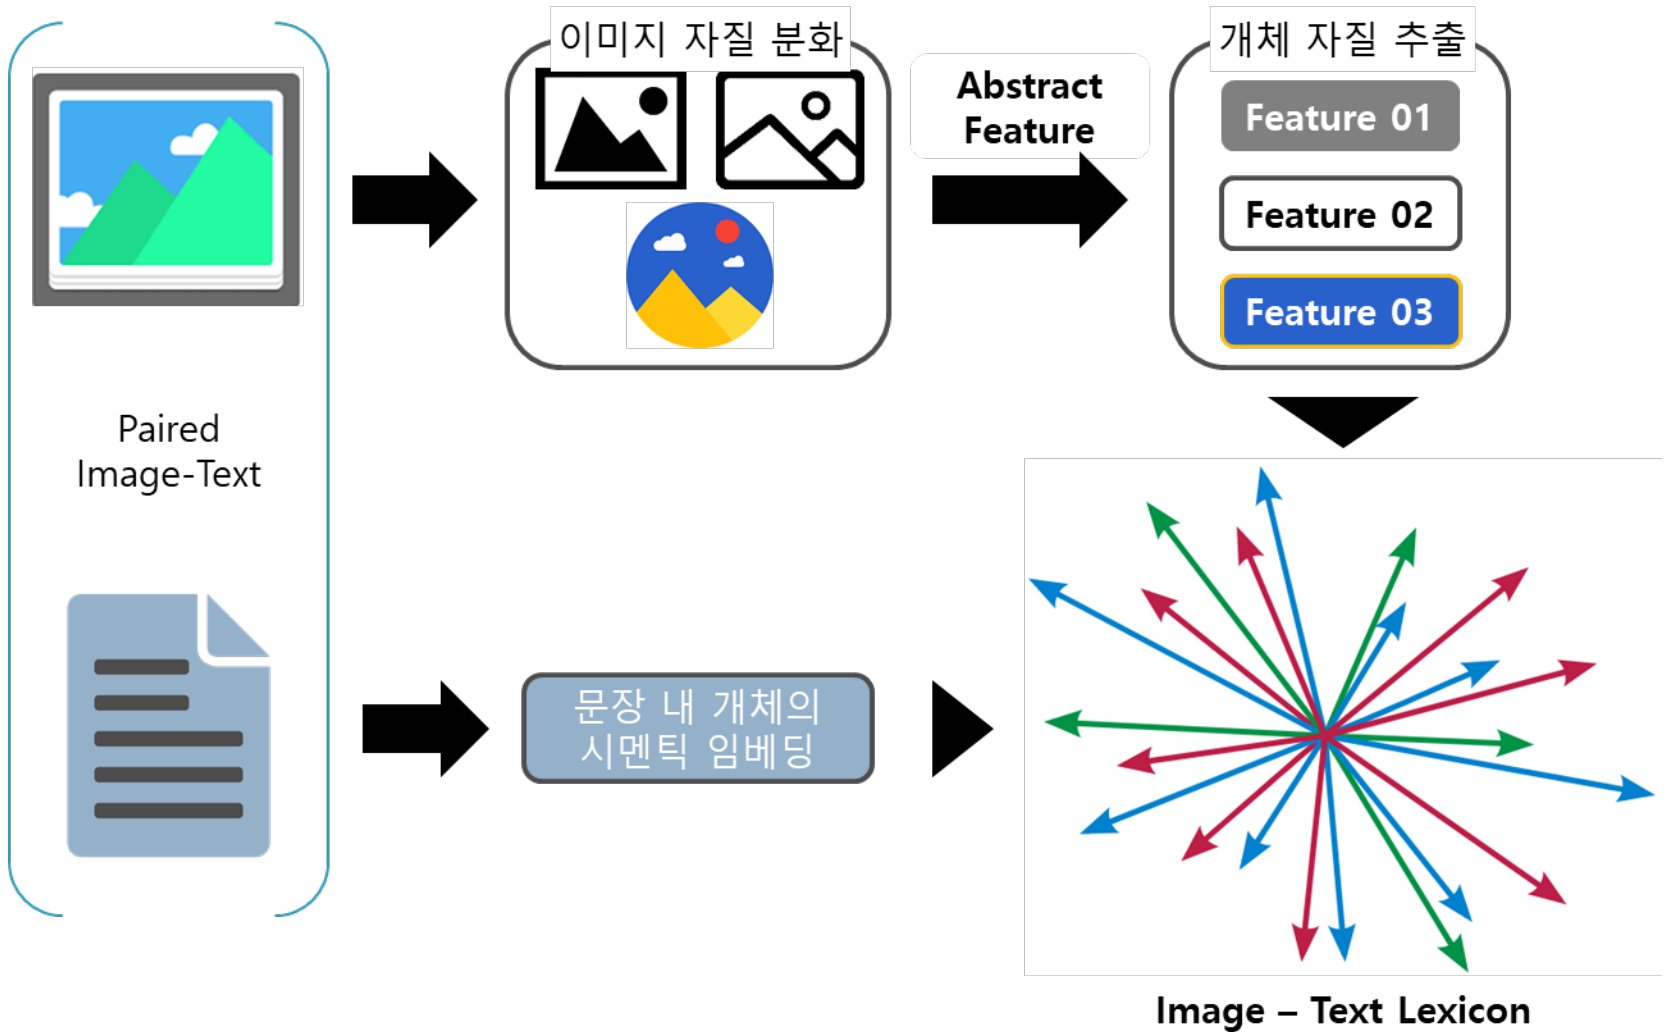
연구 내용 - 문제점 및 목표 소개

- 텍스트의 경우: 언급하는 대상 속성에 대한 이해 결여




- Finger와 Hand가 가지는 두 개체간 공통된 속성을 텍스트 데이터만으로는 알 수 없음
- 이는 이미지 개체로서는 너무나 당연하나, 텍스트에는 해당 속성이 반영이 안돼서 생기는 문제
- 해당 연구에서는 이미지 Feature들을 통해 텍스트에 Object가 가지는 속성을 반영할 수 있게 함

연구 내용 - 모델 개요




연구 내용 - Output



연구 내용 - 모델 설명


- 이미지 자질 분화



RGB channel separation



SURF

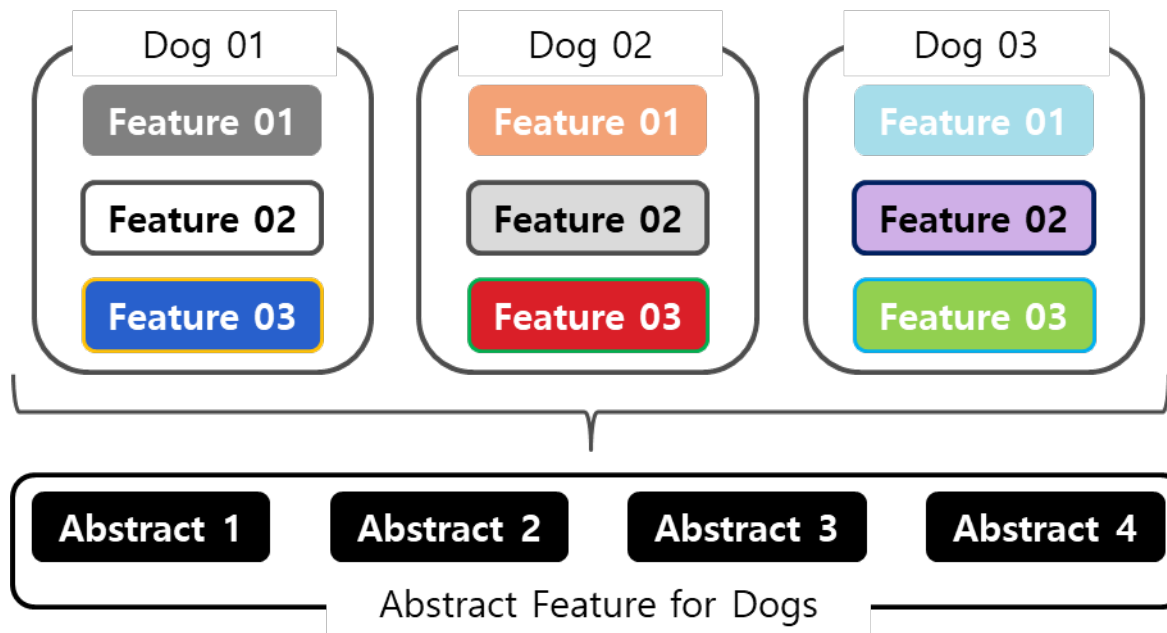


Edge Detection

- 이미지 내의 각 Feature의 특징을 극대화 및 다양화하기 위해 3가지 방법으로 이미지를 처리함
- 처리된 이미지에서 뽑아낸 자질들은 해당 Object의 Feature는 본래의 것보다 단순해짐

연구 내용 - 모델 설명


- 이미지 자질 추출



- Train a classifier that classifies features based on which object it belongs to.
- Based by this trained classifier, construct "Abstract Features" for each class(object)

연구 내용 - 모델 설명

- Aligning with Semantic Embeddings
 - The embeddings are based from BERT embeddings
 - As each paired sentences contains similar contexts, so does the entities within it.
 - Based by this we align the amalgamation of the abstract feature to become like this.
- In other words, the amalgamation is used like a sentences used in BERT



모델 실험 - 모델 실험 설계

- Experiment: Visual Question & Answering
 - A set of images paired with questions which requires visual understanding to answer
 - A fair test for testing both Text-to-Image and Image-to-Text
 - The model itself will be a pre-existing model, but trained with our vector space.

Who is wearing glasses?

man



woman




Where is the child sitting?

fridge



arms




Is the umbrella upside down?

yes



no



How many children are in the bed?

2



1



결론

- Contribution:
 - Constructing a true bidirectional Text-Image semantic space that benefits both Natural Language Processing and Image Processing
 - Binding Text to physical information via Image Features
 - Structural Image Feature Analysis/Processing via Textual information
- Futureworks:
 - As this is only a construction of a shared semantic space...
 - Generating Images via Text description
 - Describing Image features via Text
 - ex) finding common features between 2 images and point out the different ones

Utilizing Dual Memory Network with Domain Knowledge for Goal-Oriented Dialogues

고려대학교 NLP&AI Lab.

이동엽

연구 내용 - 이중 메모리와 도메인 지식을 이용한 목적 지향적 대화 시스템

- 기존 대화 시스템을 구성하는 방식으로는 rule-based와 hand-craft 자질들을 이용한 방법들이 존재하였음
- 최근 딥러닝 모델들을(LSTM, Seq2Seq...) 대화 시스템에 적용하고 있지만, 많은 양의 학습 데이터를 필요로 한다는 한계점이 존재
- 도메인 지식을 대화 시스템에 활용하는 연구가 존재하지만, 해당 연구는 대화의 전체 이력을 고려할 수 없고, hand-craft 자질을 필요로 함
- 본 연구에서는 도메인 지식을 활용하여 시스템 응답 템플릿을 구성하고, 이중 메모리를 통해 대화의 전체 이력을 고려할 수 있는 대화 시스템 모델을 제안함

연구 내용 - 시스템 응답 생성시 도메인 지식 반영

System Action Templates

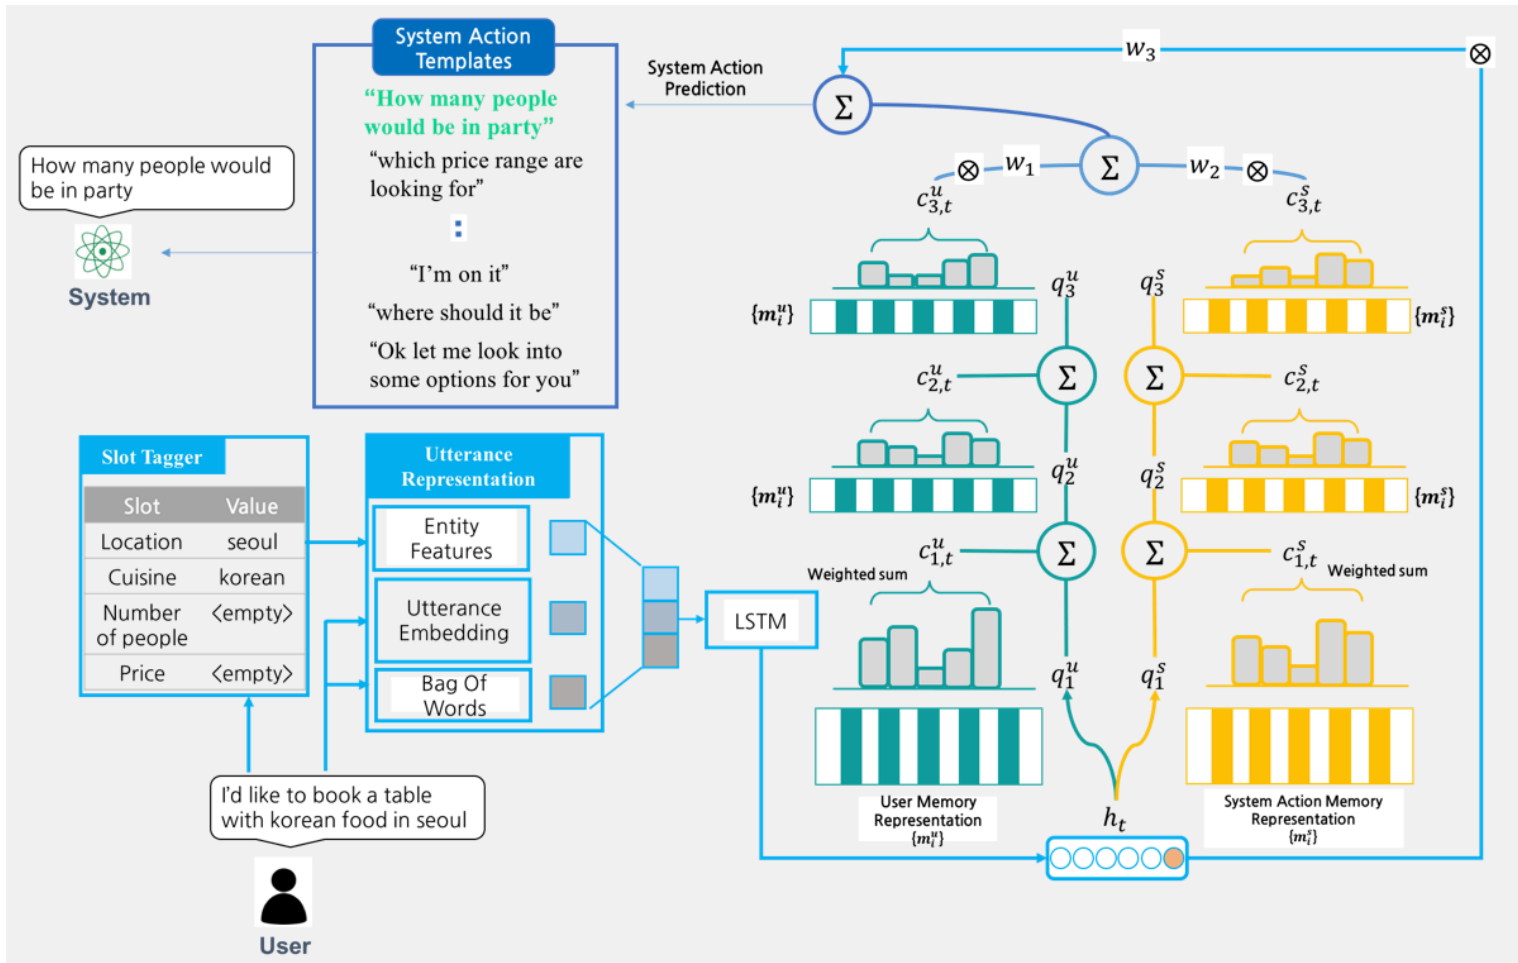
hello what can I help you with today
any preference on a type of cuisine
api_call <price> <number of people>
<cuisine> <location>
great let me do the reservation
here it is <info_address>
here it is <info_phone>
how many people would be in your party
I'm on it
is there anything i can help you with
ok let me look into some options for you
sure is there anything else to update
sure let me find an other option for you
what do you think of this option: <restaurant>
where should it be
which price range are looking for
you're welcome

- 도메인 지식을 반영하여 시스템 응답 액션 템플릿 구성
- 적은 양의 데이터로, 대화 모델의 학습이 가능

연구 내용 - 이중 메모리를 이용한 대화 이력 추적

- 사용자 발화와 시스템 응답 발화 표현(representation)을 구성하고 이를 각각 사용자 발화 메모리, 시스템 응답 메모리로 구성
- 주어진 사용자 발화에 대한 응답 생성시, 이중 메모리에서 어떤 발화에 각각 집중할 지 고려하여 시스템 응답 생성

연구 내용 - 제안 모델 구조도



제안 모델 구조도

연구 내용 - 실험 데이터

Dataset	Task 5	Task 6
Training dialogs	1000	1618
Validation dialogs	1000	500
Test dialogs	1000	1117
Slot label size	4	3
System action templates size	16	58
Vocab size	3747	1229

Table 4: Statistics of the bAbI task datasets.

- End-to-End 방식의 목적 지향적 대화 시스템 모델을 위한 평가로 많이 사용되는 bAbI 데이터를 사용
- 해당 데이터는 식당 예약에 관련한 도메인 데이터임

연구 내용 - Evaluation Matrix

- Evaluation Matrix

- Per-response accuracy = $\frac{(\textit{Number of Correct Utterance})}{(\textit{Total Number of Utterance})}$
- Per-dialogue accuracy = $\frac{(\textit{Number of dialogs(every response is corret)})}{(\textit{Total Number of Dialogue})}$

연구 내용 - 제안 모델 성능

Approach		Task-5(OOV)		Task-6	
		Per-response	Per-dialogue	Per-response	Per-dialogue
(Bordes et al., 2016)		77.7	0.0	41.1	0.0
(Perez and Liu, 2016)		79.4	0.0	48.7	1.4
(Seo et al., 2016)		96.0	-	51.1	-
(Eric and Manning, 2017)		-	-	48.0	1.5
(Williams et al., 2017)		100	100	53.1	1.9
BoW		99.9	98.6	54.9	1.0
UE		99.7	97.3	55.1	0.9
BoW+UE		100	99.3	55.1	1.1
BoW+UE+EF(RB)		100	100	55.8	1.3
BoW+UE+EF(ST)		100	100	55.8	1.4
Proposed Model	UM	100	100	55.5	1.8
	1-hop SM	100	100	55.2	1.5
	UM+SM	100	100	55.9	2.0
	2-hop UM+SM	100	100	55.7	2.1
	3-hop UM+SM	100	100	55.7	2.3

Table 6: Performance results of per-response and per-dialog accuracy on bAbI tasks. Key: BoW = bag-of-words representation; UE = utterance embedding using a word2vec; EF(RB) = entity features representation with rule-based entity names; EF(ST) = entity features representation with slot tagging model (section 3.1); UM = user memory representation; SM = system memory representation. Experiments on memory hop(1 to 3) were based on utterance representation utilizing BoW + UE + EF(ST).

제안 모델 성능

Adversarial Learning for Natural Language Understanding

고려대학교 NLP&AI Lab.

이동엽

연구 내용 - 기존 연구 내용

- 자연어 이해 모델 구성을 위한 방법으로는 CRF, LSTM과 같이 순차열 라벨링을 위한 모델이 많이 이용되고 있음
- 하지만 이러한 모델을 학습하기 위해서는 많은 양의 라벨링 된 데이터를 필요로 함
- 또한 새로운 도메인으로 모델을 확장하고자 할 때, 새로운 도메인에 대한 데이터를 다시 라벨링 해야함 (non-scalable)

연구 내용 - 적대 학습을 이용한 자연어 이해

- Motivations

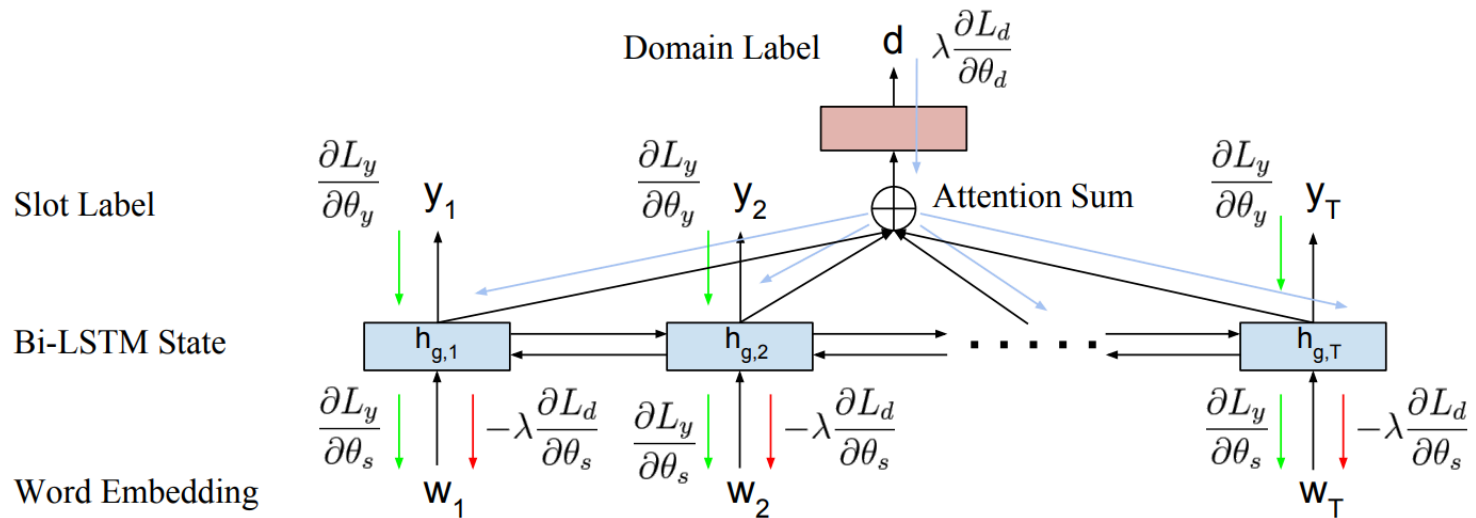
- 새로운 도메인(target)으로 시스템을 확장하고자 할 때, 관련있는 기존 도메인(source)의 데이터를 활용하여 대상 도메인(target)의 모델 성능을 향상
- 적대 학습을 이용하여 두 도메인간의 공유 될 수 있는 자질(shared features)을 학습하고, 이를 대상 도메인을 위한 모델 학습에 이용

- Benefits

- 새로운 도메인을 위한 모델 학습 시, 보다 적은 양의 데이터로 모델의 학습이 가능
- 또한 적은양의 데이터만으로 모델 성능의 향상 가능

연구 내용 - Learning Shared Features

- Negative Gradient 방법을 이용하여 Domain Classification Loss 학습을 방해

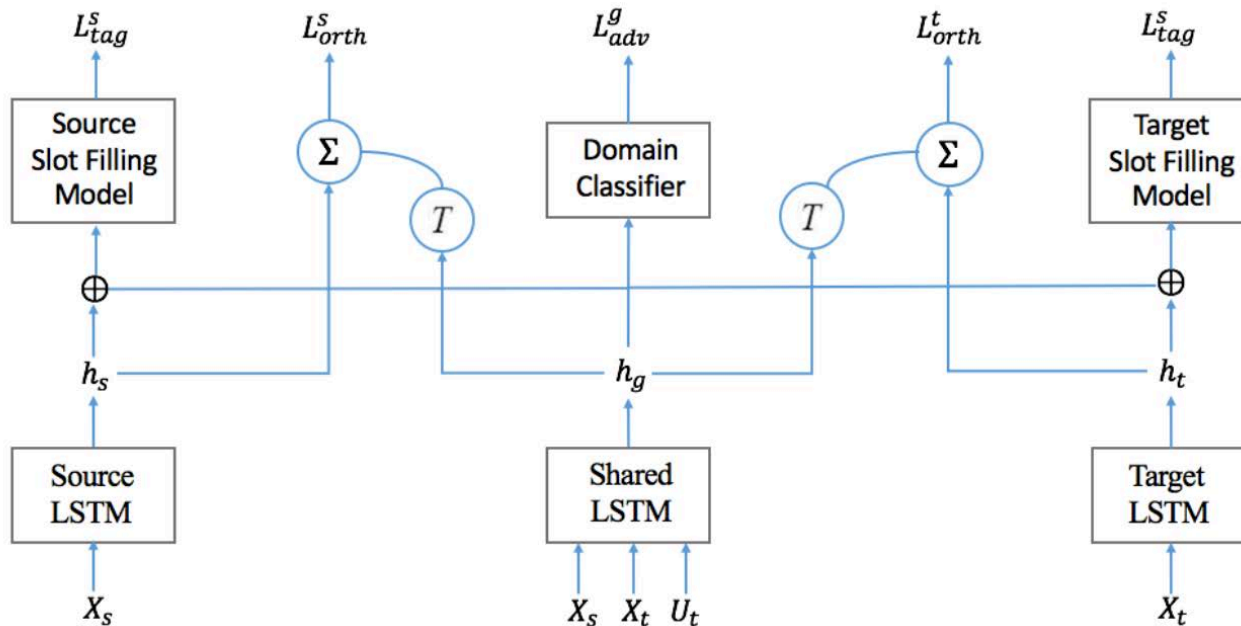


Multi-Domain Adversarial Learning for Slot Filling in Spoken Language Understanding [NIPS 2017]

연구 내용 - Learning Shared Features

- Random Prediction
 - 도메인 라벨값을 랜덤하게 할당하고, 발화로부터 정확하지 않은 도메인 라벨을 예측하도록 함으로써 공유 자질 학습
 - Adversarial Adaptation of Synthetic or Stale Data [ACL 2017]*
- 두 가지의 데이터 전이 (data shift) 문제를 풀기 위해 제안됨
 - Synthetic data => Live user data (deployment shift)
 - Stale data => Current data (temporal shift)

연구 내용 - 제안 모델 구조도



Input representation:

- X_s : Labeled source domain data
- X_t : Labeled target domain data
- U_t : Unlabeled target domain data

Parameters:

- h_s : Source domain-specific features
- h_g : Domain-general features
- h_t : Target domain-specific features

연구 내용 - Adversarial Domain Classification Loss

- Adversarial Domain Classification Loss
 - 도메인 공유 자질을 학습하기 위해 적대 학습 분류기를 학습
 - 적대 학습 방식으로 domain random prediction 방법을 이용
 - h_g 로부터 도메인 d^i 예측시 Source 도메인 50%, Target 도메인 50% 확률로 랜덤하게 예측 => 데이터로부터 해당 데이터의 도메인을 잘 구분하지 못하도록 학습이 진행되기 때문에 도메인 공유 자질이 학습됨
 - $\lambda L_{adv}^g = -\sum \log p(d^i | h_g)$, where λ is coefficient

연구 내용 - Joint Optimization

Input representation:

X_s : Labeled source domain data

X_t : Labeled target domain data

U_t : Unlabeled target domain data

Parameters:

h_s : Source domain-specific features

h_g : Domain-general features

h_t : Target domain-specific features

Each epoch

- 1) Train source slot filling model with X_s based on h_s and h_g
- 2) Train domain classifier with X_s, X_t, U_t based on h_g
- 3) Train target slot filling model with X_t based on h_t and h_g

End of epochs

[알고리즘 1] Joint Optimization을 통한 슬롯 채우기 모델 학습 과정

연구 내용 - 실험 데이터

- 실험 데이터

Datasets	Slot	Train Label/Unlabel	Test	Description
ATIS	127	4978/0	893	Flight reservation
MIT Rest.	17	766/6894	1521	Restaurant reservation

[표 1] 실험 데이터 통계 정보

- Slot Filling 모델 학습을 위해 ATIS(항공 예약)와 MIT Rest.(식당 예약) 데이터를 이용
- 일반적인 도메인 적응 실험 환경에 따라, 라벨링된 Source 도메인 데이터는 충분하고 Target 도메인 데이터는 10%만 라벨링 되어있다고 가정
- Source 도메인 : ATIS, Target 도메인 : MIT Rest.

연구 내용 - 실험 결과

- 실험 결과
 - Slot Filling 모델의 성능 평가를 위해 f1-score metric을 사용
 - TGT는 적대 학습을 적용하지 않은 모델, ADV는 적대 학습을 적용한 모델
 - 실험 결과 $\lambda=0.1$ 일때, 67.12의 f1-score로 가장 높은 성능을 나타냄

Source \ Target		MIT Rest.
ATIS	TGT	66.10
	ADV($\lambda = 1$)	65.32
	ADV($\lambda = 0.1$)	67.12
	ADV($\lambda = 0.01$)	66.41

[표 2] 적대 학습 방법을 적용한 슬롯 채우기 모델 성능

개체명 인식(Named Entity Recognition) 시스템 연구 및 개발

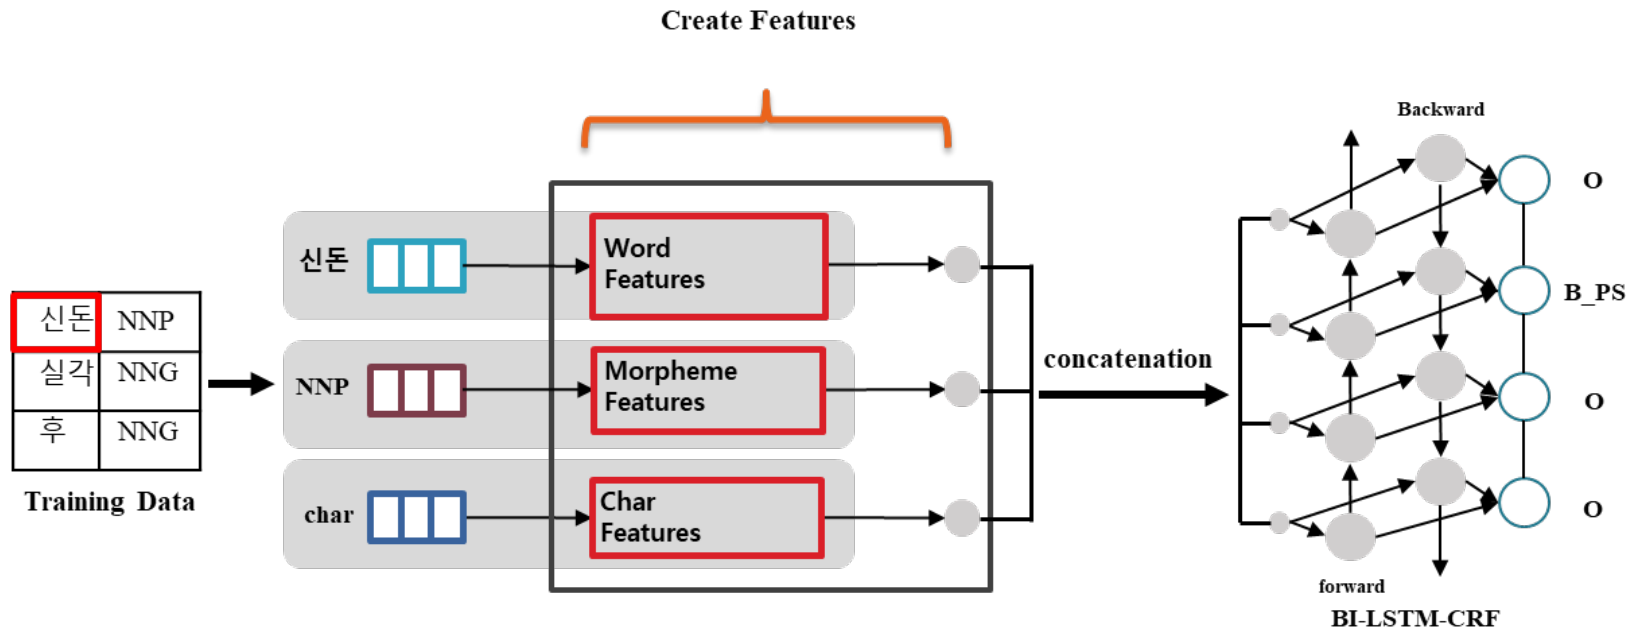
고려대학교 NLP&AI Lab.

김경민

연구 소개 - 개체명 인식

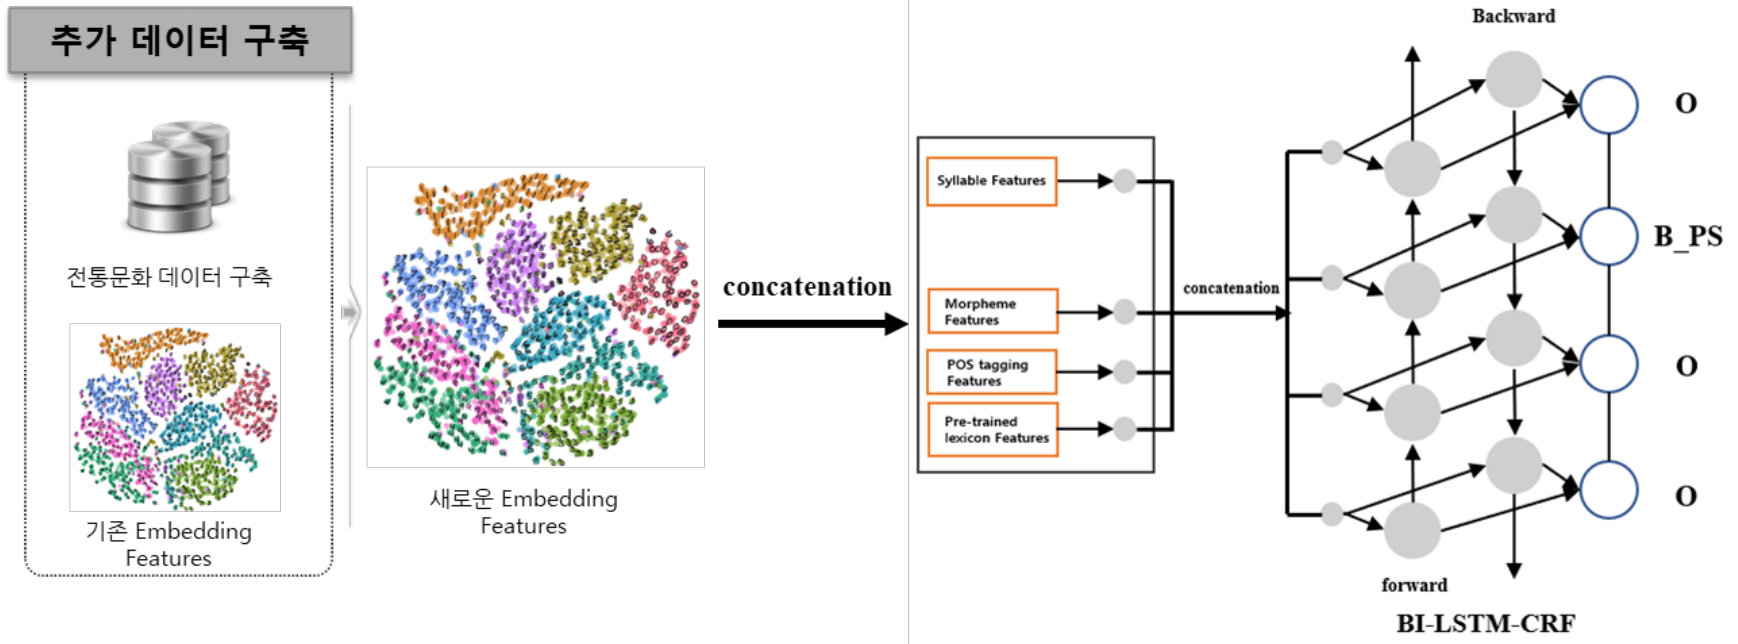
- 목표
 - 기존 영어 혹은 한글 기반 개체명 인식시스템 base model을 기반으로 word, char, morpheme 자질을 활용한 BI-LSTM-CRF 모델 구축
 - 새로운 데이터를 구축하여 기존 입력 데이터에 추가한 모델 학습

연구 소개 - Bi-LSTM-CRF 기반의 개체명 인식 모델



- Word, Morpheme, Char 단위의 각각의 자질을 활용하여 모델 성능을 평가함

연구 소개 - 구축 데이터 기반으로 기존 모델에 추가 학습



- 기존 embedding feature에 구축한 데이터를 추가 입력으로 학습하여 새로운 Embedding Feature를 생성
- 생성된 것을 기존 Bi-LSTM-CNN-CRF 모델의 입력으로 넣어 성능 평가

연구 소개 - 구축 데이터 기반으로 기존 모델에 추가 학습

input> 1597년 정유재란이 일어나자 원군은 삼도수군통제사가 되어 일본 수군과 대전했으나 조선 수군은 다대포·칠천량에서 대패하여 제해권을 상실하였고 원군과 이역기 등의 장수는 전사하였다.

output> <1597년:DT> <정유재란:DT>이 일어나자 원군은 삼도수군통제사가 되어 <일본:LC> 수군과 대전했으나 <조선:DT> 수군은 <다대포·칠천량:LC>에서 대패하여 제해권을 상실하였고 원군과 이역기 등의 장수는 전사하였다.

1597년 DT

정유재란 DT

일본 LC

조선 DT

다대포·칠천량 LC

• 기존 개체명 시스템 결과

"개체명 인식 결과": "<1420년:DT>에 다시 집현전이 설립되었을 때는 10명에서 <1423년:DT> 16인이었다가 <1435년:DT>에는 32인까지 증가되었다. 기능 또한 확대되어 유교주의적 의례, 제도, 문화의 정리 사업인 고제 연구와 편찬 사업이 시작되었다. <조선 문종:OG>이 즉위하면서 집현전이 대간 차출의 본거가 되어 호간고론적인 집단으로 변화였다."

• 새로운 개체명 시스템 결과

개체명 인식 결과:

"<1420년:DT>에 다시 <집현전:OG>이 설립되었을 때는 10명에서 <1423년:DT> 16인이었다가 <1435년:DT>에는 32인까지 증가되었다. 기능 또한 확대되어 유교주의적 의례, 제도, 문화의 정리 사업인 고제 연구와 편찬 사업이 시작되었다. <조선:LC> 문종이 즉위하면서 <집현전:OG>이 대간 차출의 본거가 되어 호간고론적인 집단으로 변화였다."

- 기존에 학습된 모델로 인식 하기 어려웠던 전통문화 텍스트 인식

Enhanced Sequential Representation Augmented with Utterance-level Attention for Response Selection

고려대학교 NLP&AI Lab.

황태선

연구 내용 - Response Selection

- 두 사용자의 Multi-turn 대화에서 마지막에 올 발화 내용을 정답 후보들 중 정답을 예측하는 연구
- Human-computer 대화 시스템은 자연스럽게 일관된 대화를 이끌어 나가는 것을 목표로 함. 특히 검색 기반 대화 시스템에서는 대화 코퍼스 내에서 가장 적합한 응답 검색을 바탕으로 응답
- 정답 이전의 대화를 입력으로 하여 전체 대화가 자연스럽게 이어질 수 있는 정답을 선택
- 대화 내에서 단어, 문장과 같은 중요한 정보와 정답의 관련성을 어떻게 확인할 것인지, 또한 대화 내 발화 간의 관계를 어떻게 모델링 할 지 등에 대한 연구가 필요함

연구 내용 - Multi-turn 대화 내 발화 예측



My skype doesn't start, anyone knows why?

Skype is having an issue; <https://twitter.com/#!/Skype>




So I can only wait?

At this time, that's what I suggest



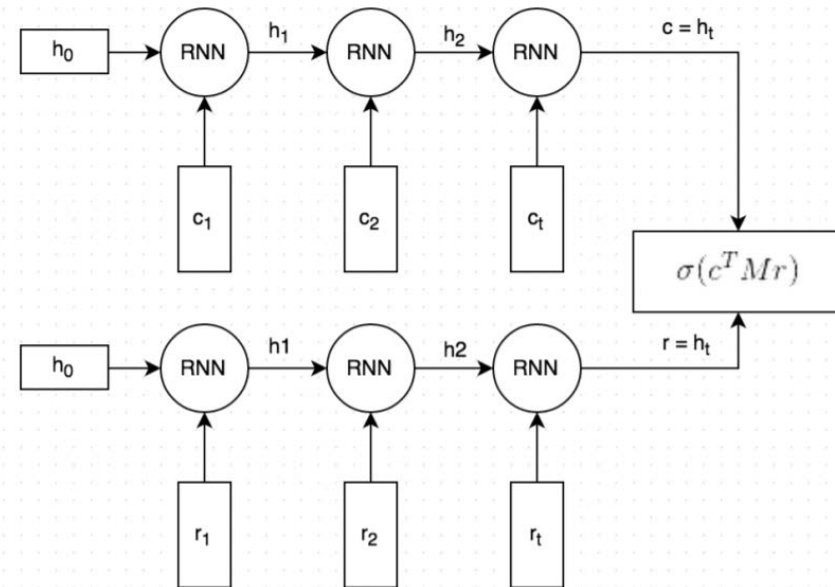
Thanks, better to know that its in progress than missing out. Maybe skype has this problem with Ubuntu because MS bought skype



1. have you tried right shift?
2. there are several apps for data backup, after that do a 64 bit clean install
3. **Don't be silly, it's a cross-platform issue**
- ⋮
99. It is cool, one sec
100. thanks for the link

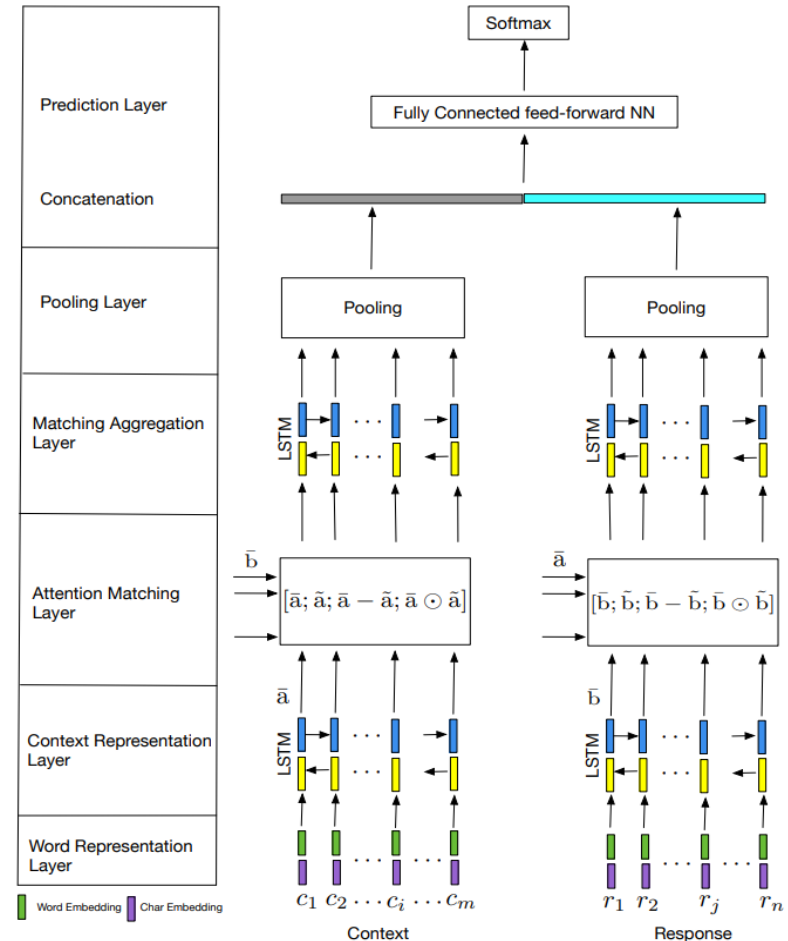
연구 내용 - Dual Encoder w/LSTM [Lowe et al, 2015]

- 두 사용자간 대화 문장(Context)와 각 정답 문장(Response)의 단어들이 RNN 또는 LSTM의 입력으로 들어감
- 양방향 LSTM을 통한 모델의 경우 두 문장의 단어 간 관련성을 반영하지 않기 때문에 문장 간 유사도를 판단하기 어려움
- LSTM을 통한 word-sequence 모델은 대화 발화 turn별로 고려하지 않기 때문에 대화가 길어질 경우 대화의 중간 맥락의 정보 손실이 발생할 수 있음

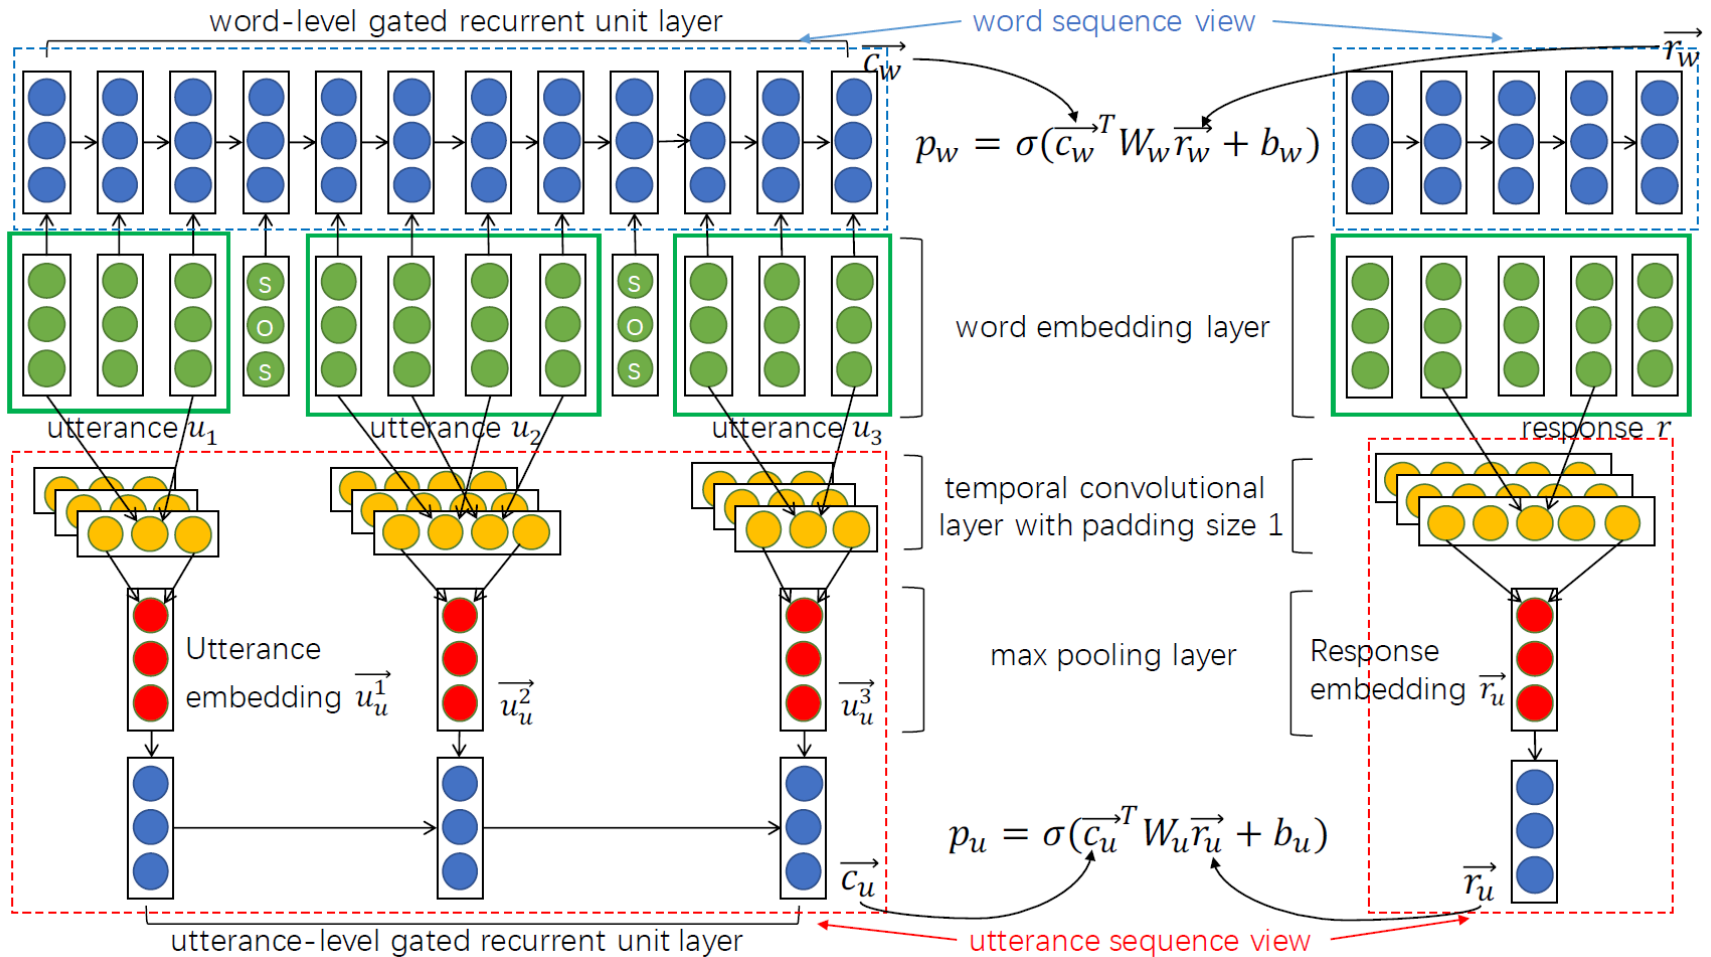


연구 내용 - ESIM [Dong and Huang, 2018]

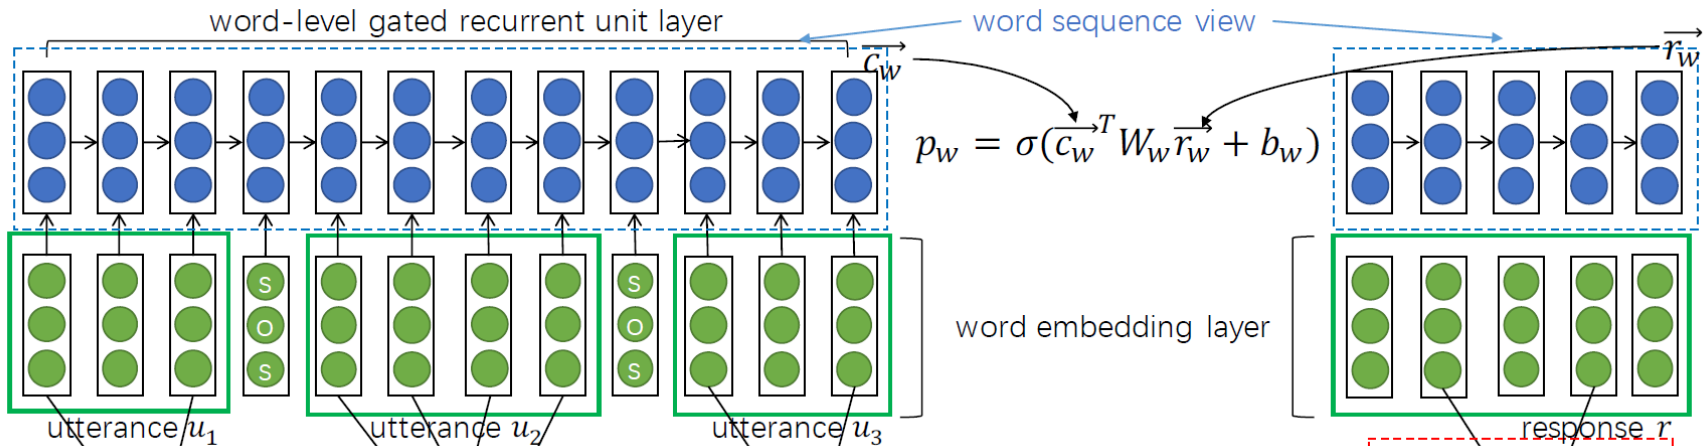
- NLI(Natural Language Inference) task 에서 뛰어난 성능을 보인 ESIM 모델을 Response Selection에서 사용함으로써 대화 및 응답 발화의 관련 정보들을 반영
- ESIM 기반의 모델의 경우, 두 문장의 관련 단어들의 정보를 반영하지만 대화(Dialog Context)가 Utterance(발화) 단위가 아닌 전체 하나의 문장 단위로 들어가게 됨 [대화 내 발화의 구분은 `_eot_`(end of turn) 태그를 사용함]
- 본 모델에서도 대화 발화 turn별로 고려하지 않고 대화 전체를 하나의 입력으로 받기 때문에 대화 또는 각 발화들의 길이가 길어질 경우 정보 손실이 발생할 수 있음



연구 내용 - Multi-view [Zhou et al, 2016]

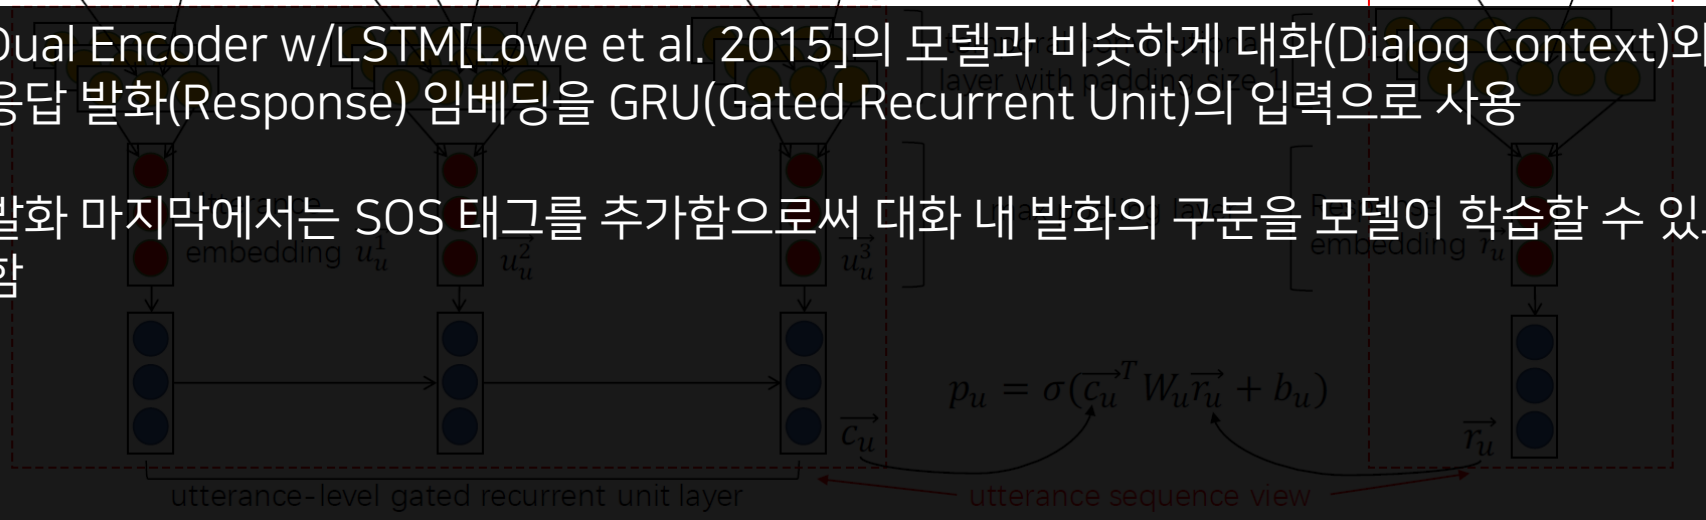


연구 내용 - Multi-view [Zhou et al, 2016]



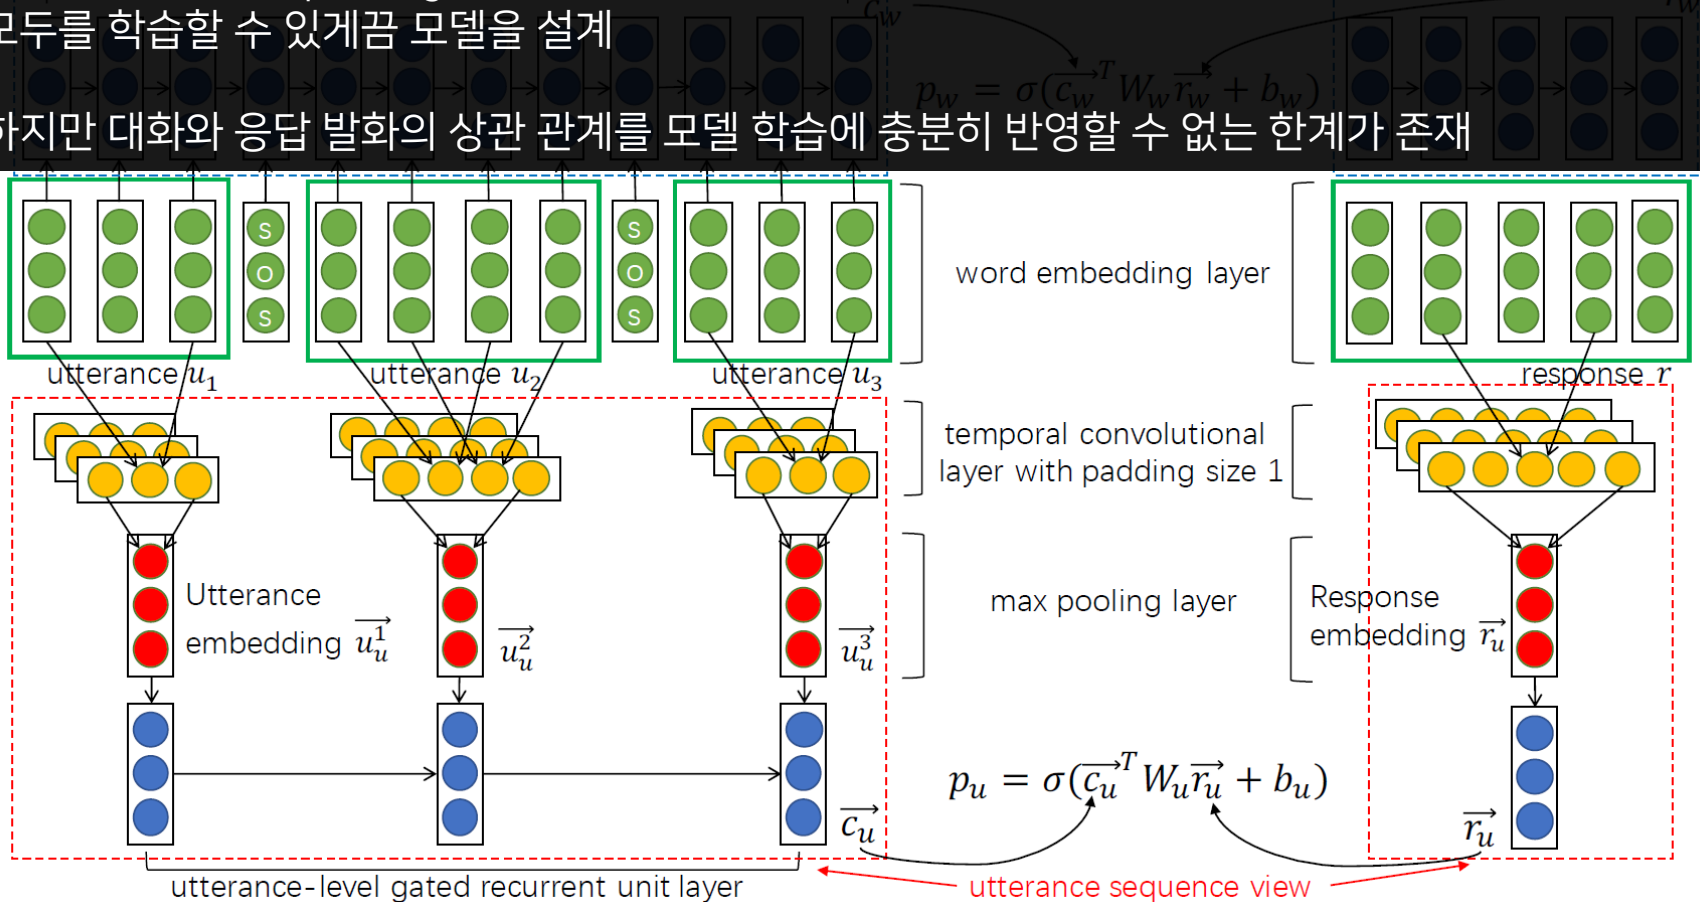
• Dual Encoder w/LSTM[Lowe et al. 2015]의 모델과 비슷하게 대화(Dialog Context)와 응답 발화(Response) 임베딩을 GRU(Gated Recurrent Unit)의 입력으로 사용

• 발화 마지막에서는 SOS 태그를 추가함으로써 대화 내 발화의 구분을 모델이 학습할 수 있도록 함

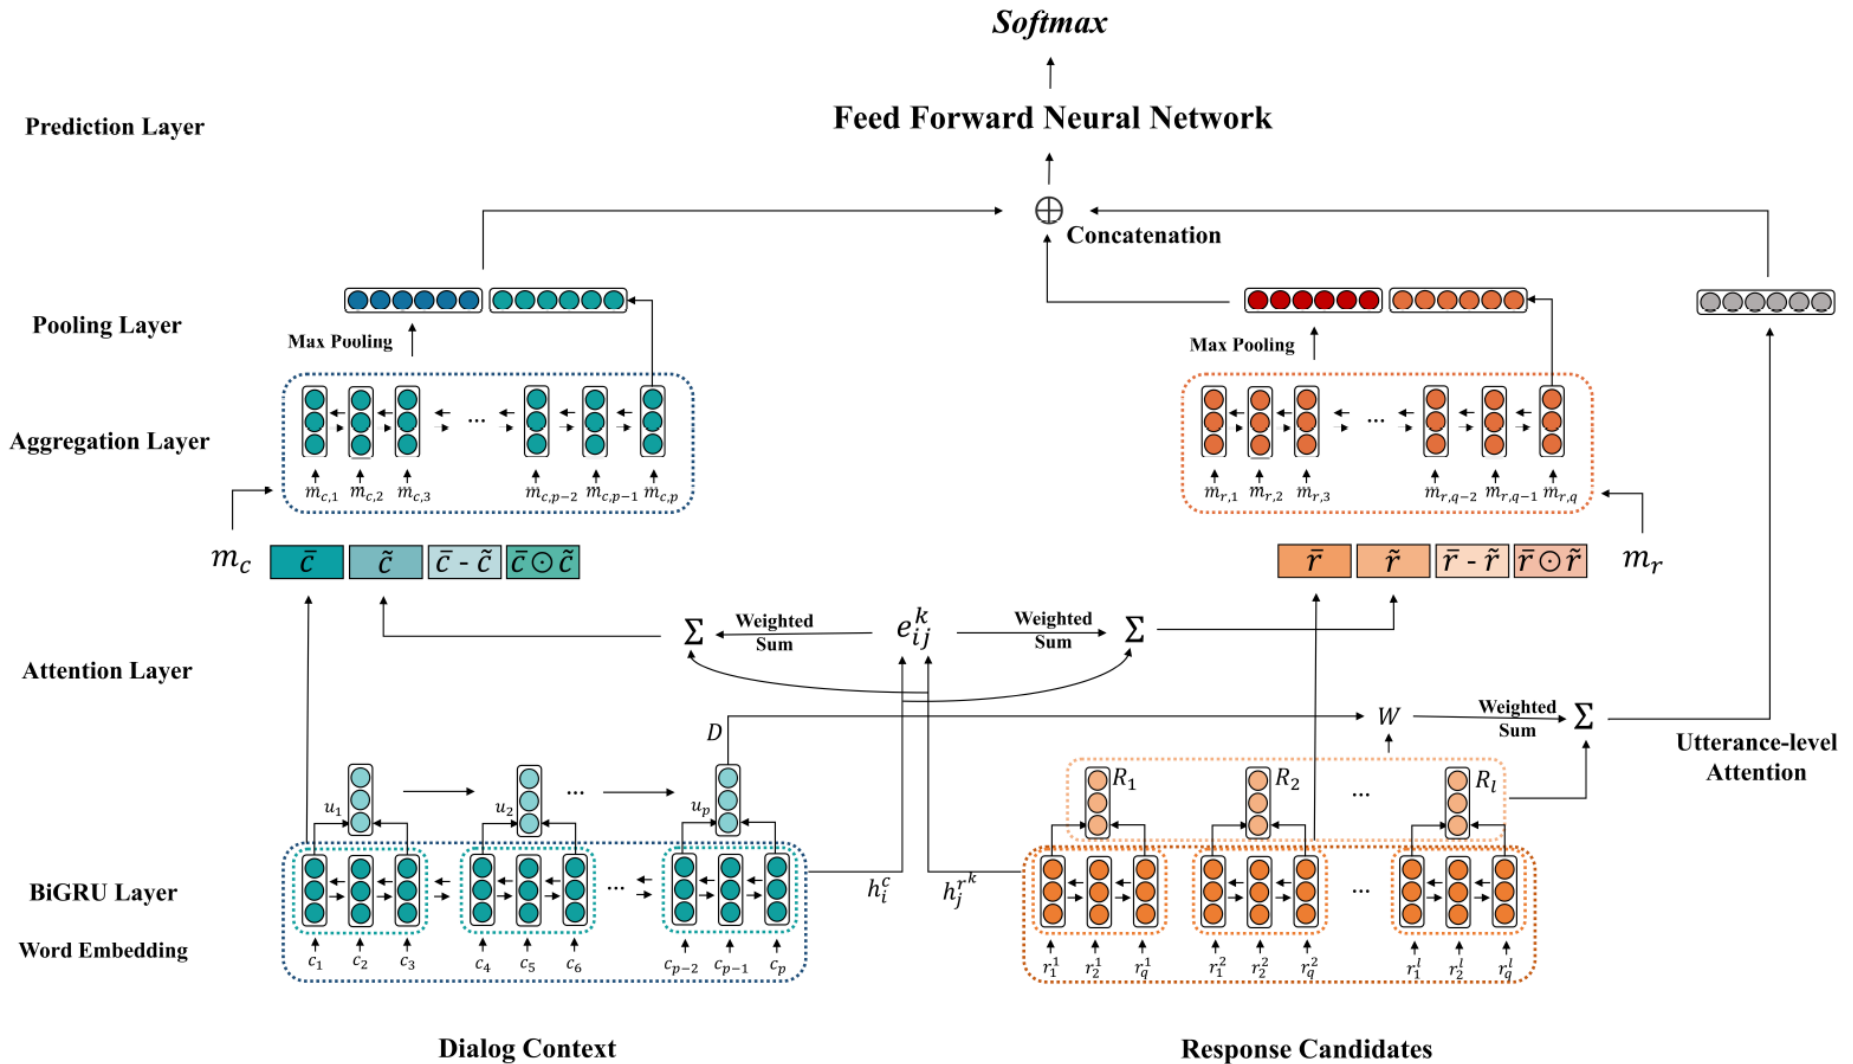


연구 내용 - Multi-view [Zhou et al, 2016]

- 대화 내 발화(Utterance) 단위로 학습을 진행하기 위해서 CNN을 사용하였음. 각 발화의 Convolved feature들을 max pooling하여 GRU의 입력으로 사용. Multi-view 모델에서는 대화의 단어, 발화 단위 모두를 학습할 수 있게끔 모델을 설계
- 하지만 대화와 응답 발화의 상관 관계를 모델 학습에 충분히 반영할 수 없는 한계가 존재



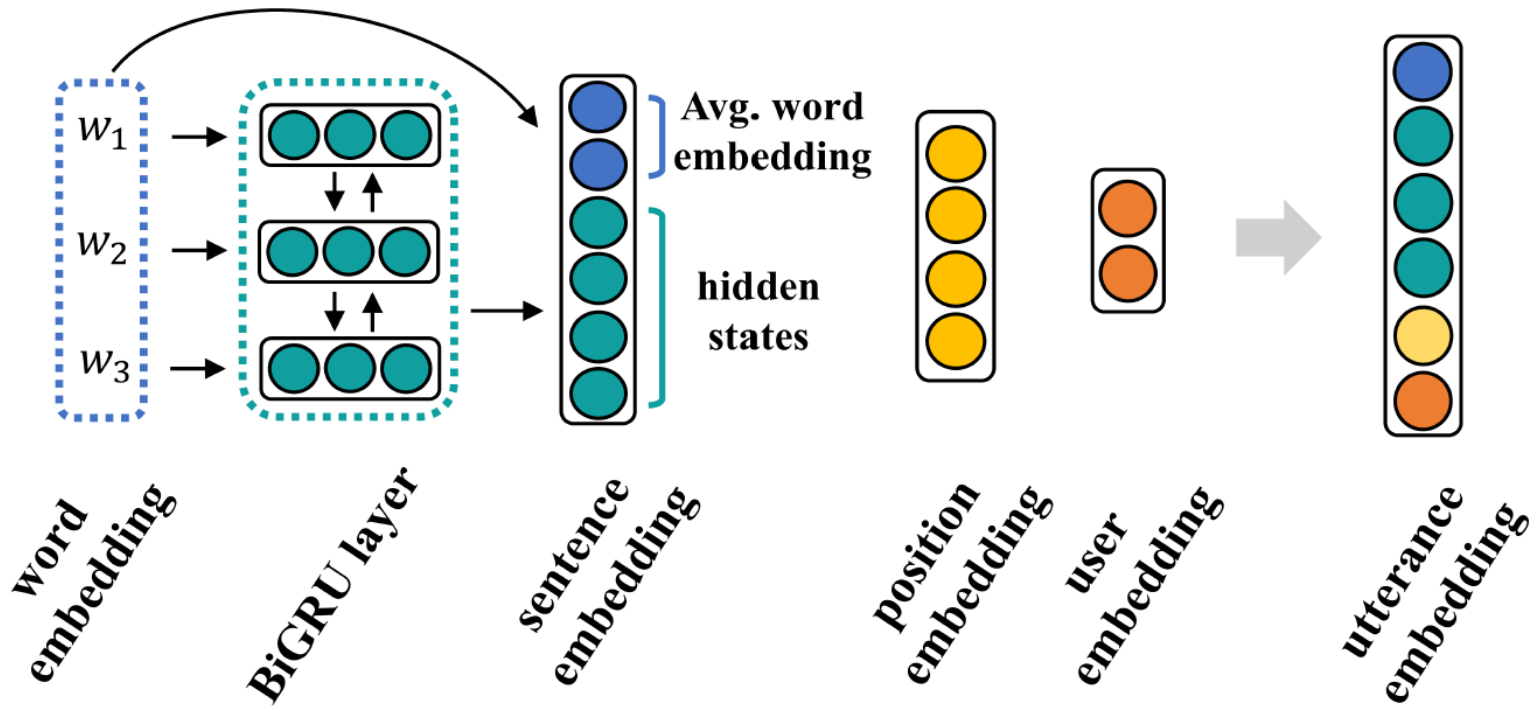
연구 내용 - ESIM w/Utterance-level Attention



연구 내용 - Utterance Representation

- Sentence Embedding
 - 발화 내 단어 임베딩의 평균(Avg. word embeddings)과 bidirectional GRU의 hidden states를 결합하여 이를 발화 문장 임베딩으로 사용
- Position Embedding
 - 대화 내에서 각 발화(utterance)들의 위치 정보는 마지막 발화를 예측하는 데에 중요한 정보로 쓰일 수 있음. 발화의 position 임베딩은 Vaswani et al. (2017)에서 제안했던 방식과 동일하게 생성함
 - 기존 연구에서 position 임베딩을 입력에 더한 것과 달리 본 연구에서는 문장 임베딩과 결합하여 사용함
- User Embedding
 - 두 사용자의 multi-turn 대화 내에서는 각자의 특징 및 대화 목적이 존재함. 각 사용자들을 one-hot encoding으로 벡터화하여 utterance feature로 사용(e.g. advisor:[1,0], student[0,1])

연구 내용 - Utterance Representation



연구 내용 - Experiments

- Datasets
 - Dialog System Technology Challenges 7(DSTC7)
 - Ubuntu IRC (Internet Relay Chat) Dialog Corpus
- Ubuntu 시스템 내에서 발생하는 문제에 대해 질문 및 답변하는 대화 코퍼스
 - Advising (Flex) Dataset
 - 학생이 다음 학기에 어떤 수업을 들을 지 Course Adviser에게 조언을 구하는 대화 데이터
- Task Description
 - Task 1 : 총 100개의 응답 발화 후보 중 1개의 정답을 고르는 것
 - Task 4 : Task 1가 동일하지만, 정답이 없는 경우도 있음(NONE)

연구 내용 - Experiments

Task	Dataset	Ubuntu			Advising		
		#dialogs	#tokens	#Avg. turns per dialog	#dialogs	#tokens	#Avg. turns per dialog
Task 1	Training	100000	221112	5.490	100000	5302	6.985
	Develop.	5000	117853	5.436	500	2433	7.234
	Test1	1000	49788	5.588	500	2494	7.232
	Test2	-	-	-	500	2332	7.166
Task4	Training	100000	220999	5.446	100000	5304	6.985
	Develop.	5000	118229	5.431	500	2415	7.234
	Test1	1000	49772	5.588	500	2466	7.232
	Test2	-	-	-	500	2316	7.166

연구 내용 - Negative Sampling

- 각 대화(Dialog Context)마다 1개의 positive 응답과 99개의 negative 응답들을 포함하는 100개의 정답 후보들이 존재. 하지만 학습 시 매번 100개 중 하나의 적합한 정답을 예측하는 것은 오랜 학습 시간이 소요됨
- 따라서, 정답 후보 내의 negative 응답들을 랜덤하게 샘플링을 진행하여 학습에는 축소된 정답 후보들을 사용함. Negative 샘플의 수의 경우, 10에서부터 30까지 5개 단위로 실험을 진행한 결과 20개를 사용하였을 때 가장 좋은 성능을 보여줌
- 전체 100개를 사용하였을 때보다 축소된 negative 샘플을 사용하였을 때 약 2~3% 좋은 성능을 보여주었으며, 매 epoch 마다 다른 negative 샘플을 사용하였을 때 5~6% 좋은 성능을 보여줌

연구 내용 - Evaluation

- Baselines
 - Dual Encoder w/LSTM(Lowe et al. 2015)
 - 단어 단위에서 대화와 정답 후보들의 sequence 정보만을 사용
 - ESIM(Dong and Huang 2018)
 - Context-aware, response-aware Attention을 사용함으로써 대화와 정답 후보들과의 상관 관계를 반영하여 학습을 진행
- 제안된 모델
 - ESIM + SE
 - Sentence embedding(문장 임베딩)을 생성하여 단어 단위 ESIM 모델과 함께 사용
 - ESIM + SE + PE + UE
 - Utterance embedding(발화 임베딩)을 sentence, position, user에 대한 세 가지 feature로 구성하여 단어 단위 ESIM 모델과 함께 사용

연구 내용 - Experiments

Task 1	Ubuntu						Advising					
	R@1	R@2	R@5	R@10	R@50	MRR	R@1	R@2	R@5	R@10	R@50	MRR
(Lowe et al. 2015)	0.211	0.307	0.446	0.569	0.921	0.320	0.074	0.108	0.210	0.342	0.802	0.162
(Dong and Huang 2018)	0.367	0.452	0.558	0.651	0.917	0.465	0.086	0.156	0.256	0.376	0.834	0.187
ESIM + SE (GloVe)	0.377	0.460	0.568	0.657	0.929	0.473	0.098	0.160	0.294	0.430	0.834	0.204
ESIM + SE + PE + UE (GloVe)	0.384	0.464	0.575	0.662	0.921	0.480	0.112	0.166	0.298	0.438	0.859	0.214
ESIM + SE + PE + UE (ELMo)	0.406	0.493	0.606	0.691	0.928	0.505	0.106	0.160	0.306	0.460	0.858	0.213

(a) Model performance for task 1

Task 4	Ubuntu						Advising					
	R@1	R@2	R@5	R@10	R@50	MRR	R@1	R@2	R@5	R@10	R@50	MRR
(Lowe et al. 2015)	0.215	0.328	0.500	0.622	0.925	0.351	0.162	0.200	0.262	0.346	0.736	0.228
(Dong and Huang 2018)	0.378	0.507	0.634	0.717	0.931	0.500	0.156	0.242	0.400	0.546	0.888	0.278
ESIM + SE (GloVe)	0.386	0.512	0.636	0.722	0.939	0.507	0.170	0.278	0.406	0.536	0.894	0.293
ESIM + SE + PE + UE (GloVe)	0.394	0.515	0.651	0.728	0.941	0.512	0.190	0.272	0.424	0.578	0.908	0.311
ESIM + SE + PE + UE (ELMo)	0.417	0.542	0.662	0.735	0.938	0.533	0.186	0.266	0.386	0.498	0.854	0.291

(b) Model performance for task 4

연구 내용 - Results

Task	Dataset	Submitted Results				Improved Results			
		R@1	R@10	R@50	MRR	R@1	R@10	R@50	MRR
Task 1	Ubuntu	0.471	0.700	0.926	0.5570	-	-	-	-
	Advising case1	0.122	0.474	0.868	0.2337	0.290	0.614	0.898	0.4019
	Advising case2	0.064	0.398	0.800	0.1611	0.106	0.436	0.826	0.2071
Task4	Ubuntu	0.487	0.772	0.936	0.5932	-	-	-	-
	Advising case1	0.224	0.552	0.896	0.3276	0.340	0.782	0.974	0.4926
	Advising case2	0.178	0.470	0.856	0.2703	0.196	0.544	0.898	0.3154

- Batch Shuffling on Advising Dataset
 - 기존 실험에서 Advising 데이터에 대해 학습이 잘 진행되지 않았음
 - Response Selection 데이터 구축 시 하나의 대화에서 turn 별로 데이터 셋을 구축하여 대화 데이터 분포가 일정하지 않아 모델 학습이 진행되지 않는 문제가 발생
 - 총 100,000개의 데이터 셋에 대한 Batch Shuffling을 진행하여 위의 문제를 해결하였음

Answer Generation from Span Prediction in MRC Tasks

고려대학교 NLP&AI Lab.

양기수

연구 내용 - Span Prediction in MRC Tasks

Passage Sentence

In meteorology, precipitation is any product of the condensation of atmospheric water vapor that falls under gravity.

Question

What causes precipitation to fall?

Answer Candidate

gravity

Example of Span Prediction in MRC Task

연구 내용 - Answer Generation Model

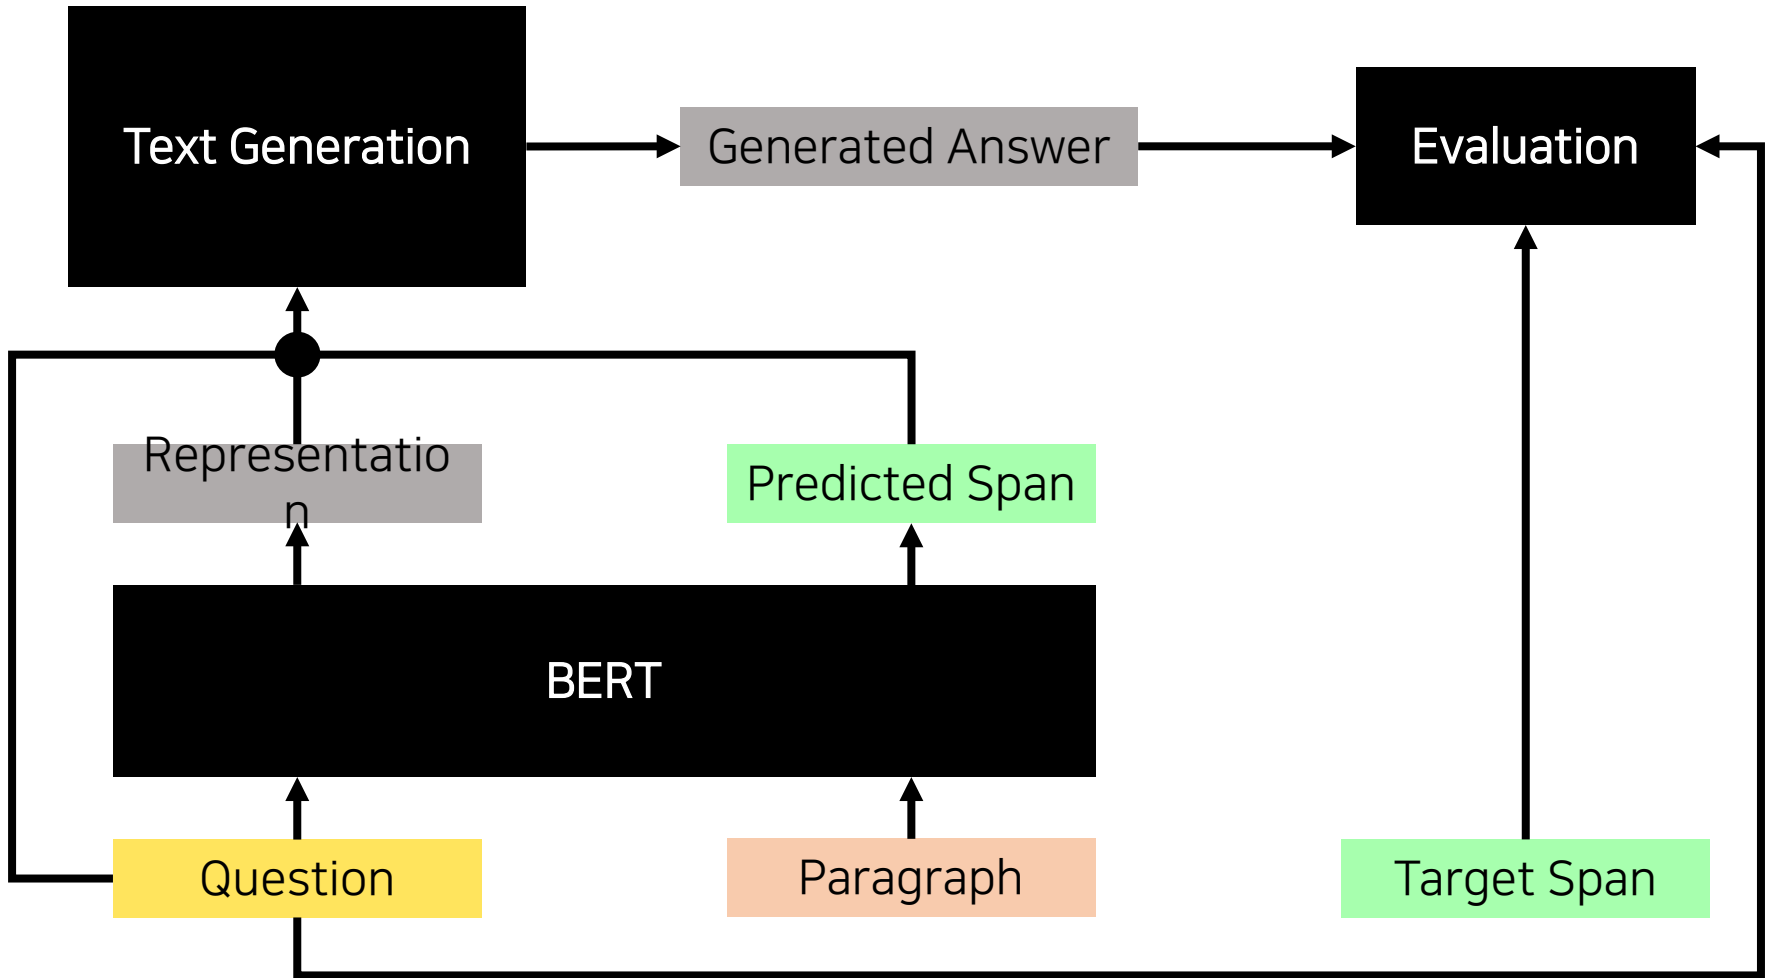


Figure of Answer Generation Model

연구 내용 - Related Works

BERT

1. Inputs: [CLS] + Question + [SEP] + Paragraph
2. Encoding the Inputs through Pre-trained BERT Model
3. Multiple Fine-tuners
 - First of all, train the span prediction fine-tuner, then freeze its variables.
 - Second, train the answer generation fine-tuner
4. Related Experiments
 - Text Classification with Bidirectional Encoder Representations from Transformers(BERT) in a Korean Language Classification Task

s 합성재를 쓰는 대부분의 화가가 건강상의 문제나 불편을 호소하기 때문이다.
n 온 세계의 자주화를 실현하기 위한 투쟁의 지침을 마련해주신 그이께 가장 숭고한 경의를 드린다.
n 버럭더미가 있던 곳에 성토를 하고 꾸린 야외휴식터는 그야말로 한폭의 그림을 방불케 하였다.
s 김민하, 하준호, 김대우의 경쟁 구도는 이미 깨진 지 오래다.
n 모두가 이런 생각으로 그이를 우러르는데 위대한 장군님의 우렁우렁하신 음성이 장내를 울리었다.
n 도, 시, 군당위원회를 비롯하여 모든 당조직들이 철도수송문제를 푸는데 큰 관심을 돌려야 하겠습니다.
s 서울은 인천 유나이티드에서 이석현을 영입했다고 2일 공식 발표했다.
s 누구나 서피스2와 함께 요리를 만들 수 있는 것이다.

연구 내용 - Related Works

Text Generation

1. Decoder
 - Train to generate answers from hidden representation
2. GAN with RL e.g. SeqGAN(2017), LeakGAN(2017), GAN with IRL(2018)
 - Being actively researched, but there is no placeholder for the hidden representation
3. Related Experiments
 - Style Transfer in Korean Text using **Sequence-to-Sequence(S2S)**
 - Image **Generative Adversarial Networks(GAN)** with Densely Connected Layers
 - “Auto Thinking” Game Development based on **Reinforcement Learning(RL)**

그는 하루빨리 관광의 \$UNK\$ 되기 위하여 이악하게 노력하였다. \$END\$
그는 우리의 \$UNK\$ \$UNK\$ 앞장에서 위하여 헌신적으로 노력하였다. \$END\$

Example of Text Generation using Seq2Seq

연구 내용 - Related Works

Evaluation

1. BLEU score → when comparing with an original Question
 - Having a lack when a target text is too short and when similar yet different words are generated.
2. 14 Metrics in 『The Evaluation of Sentence Similarity Measures (2018)』 → with a predicted span

Sentence Similarity Measures
$sim_{jaccard}$
$sim_{overlap}$
$sim_{overlap,IDF}$
$sim_{overlap,phrase}$
$sim_{TF,vector}$
$sim_{TFIDF,vector}$
$sim_{TFIDF,nov}$
$sim_{identity}$
sim_{ssv}
sim_{sem}
$sim_{simsem,IDF}$
sim_{wo}
sim_{ssv+wo}
sim_{sem+wo}

14 Sentence Similarity Measures

Metrics	MLE	SeqGAN	RankGAN	LeakGAN	IRL	Ground Truth
BLEU _F -2	0.798	0.821	0.850*	0.914	0.829	0.836
BLEU _F -3	0.631	0.632	0.672*	0.816	0.662	0.672
BLEU _F -4	0.498	0.511	0.557*	0.699	0.586	0.598
BLEU _F -5	0.434	0.439	0.544*	0.632	0.542	0.557
BLEU _B -2	0.801	0.682	-	0.790	0.868	0.869
BLEU _B -3	0.622	0.542	-	0.605	0.718	0.710
BLEU _B -4	0.551	0.513	-	0.549	0.660	0.649
BLEU _B -5	0.508	0.469	-	0.506	0.609	0.601
BLEU _{HA} -2	0.799	0.745	-	0.847	0.848	0.852
BLEU _{HA} -3	0.626	0.584	-	0.695	0.689	0.690
BLEU _{HA} -4	0.523	0.512	-	0.615	0.621	0.622
BLEU _{HA} -5	0.468	0.454	-	0.562	0.574	0.578

Results on COCO image caption dataset

연구 내용 - Expected Contribution

1. To derive complete sentence through answer generation instead of span prediction
2. To propose multiple fine-tuners of BERT
3. To improve generative models by feeding sentence representation to GAN
4. To generate meaningful text by combining to MRC tasks
5. Answer Data Augmentation (QG is also possible with this model)

스마트 시니어세대의 문화향유를 위한 인지반응 맞춤형 UI/UX 기술 개발

고려대학교 NLP&AI Lab.

- 인지반응 분석 시스템 개발
- 스마트 시니어 맞춤형 프로파일 관리시스템 고도화
- 스마트 시니어 맞춤형 추천 시스템 개발
- 표준안 및 기술 보고서 작성

연구 내용 - 인지반응 분석 시스템 개발

- 인지반응 9종 검사에 따른 시각화 결과 도출



인지반응 해설

당신이 속한 그룹의 인지반응 유형은

['C']

[당신이 속한 그룹에 대한 해설]

당신에게는 폰트 사이즈를 크게 이용하는 것을 추천합니다. 기본 인터페이스보다 심플한 구조를 제공하여 당신의 콘텐츠 이용에 도움을 주는 것이 좋을 것 같습니다. 또한, 동영상 재생속도는 기본 재생속도보다 조금 더 느리게 제공하여 동영상을 인지하고 처리하는데 어려움이 없도록 도와드리겠습니다. 자막 이용시에는 노란 바탕음영에 파란색 글자 또는 초록색 바탕음영에 빨간색 글자 이용하는 것이 좋습니다. 당신에게는 콘텐츠를 보고 기능을 이용하는데 보조기능을 제공하여 해당 콘텐츠를 손조롭게 이용하도록 돕겠습니다.

Smart Senior Cognitive Style

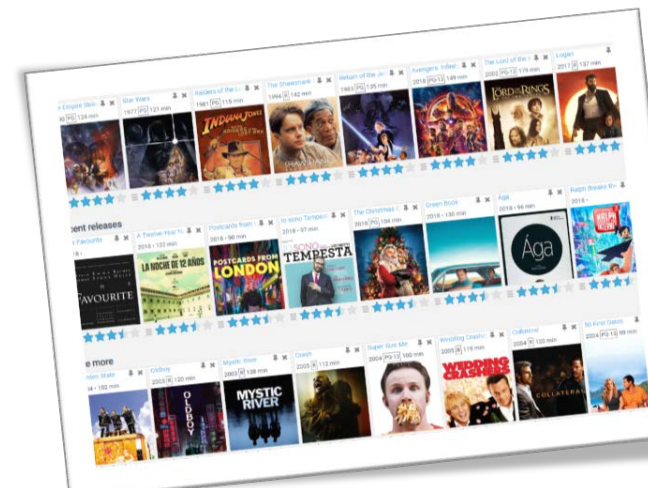


연구 내용 - 스마트 시니어 맞춤형 프로파일 관리시스템 고도화

- 스마트 시니어 맞춤형 프로파일 관리시스템은 통합적인 프로파일 관리를 지원하고, 프로파일 분석을 통해 발생한 데이터는 시니어 맞춤형 디지털 콘텐츠 추천, 시니어 맞춤형 콘텐츠 생성 및 최적화를 위해 개발
- Feature selection을 통해 약 180여개의 인지반응 검사지에서 의미 있는 검사지만 추출하여 검사 시간을 단축하고, 집중도를 향상시킴
- 또한 인지반응 검사지 데이터와 온라인 활동 기반 데이터를 기반으로 classification을 통해 새로운 스마트 시니어가 인지반응 검사를 했을 때 정확한 맞춤형 시스템을 제공할 수 있도록 개발함

연구 내용 - 스마트 시니어 맞춤형 추천 시스템 개발

- Zhang et al. (2017)이 SIGIR에서 발표한 Contractive Auto-encode를 이용한 Collaborative Filtering 모델인 AutoSVD++ 모델을 사용하여 추천 시스템을 개발하였음
- 사용자가 이미 관람한 영화에 대해 1~5 점 사이의 평점을 내리면 추천 모델이 상위 K개의 영화를 사용자에게 추천함. 본 실험에서 사용한 Movielens-latest-small 데이터 셋에 대하여 RMSE 0.887의 성능을 확인
- 데이터 셋에 존재하는 9205개에 해당하는 모든 영화에 대한 포스터 및 줄거리 크롤링을 진행하였으며, 해당 포스터 및 줄거리는 사용자의 인지 능력에 따라 다른 UI/UX로 사용자에게 제공됨



연구 내용 - 표준안 및 기술 보고서 작성

- 1건의 표준이 표준의결 되었으며 기술 보고서 4건 표준 공고됨

구분	제목	현재상태
표준	온라인 콘텐츠 사용자 프로파일 구조	운영위원회 조정
기술 보고서	고령자용 디지털 콘텐츠 서비스 개발을 위한 3D 디지털 콘텐츠 안정성	표준공고
기술 보고서	고령자를 위한 디지털 콘텐츠 서비스 개발을 위한 그래픽 사용자 인터페이스 구성요소 현황	표준공고
기술 보고서	고령자를 위한 동영상 자막 설계 지침	표준공고(예정)
기술 보고서	고령자를 위한 인지반응 측정 방법 및 적용사례	표준공고(예정)

사용자 중심의 지능형 패션 검색 및 맞춤형 코디네이션 제품 개발

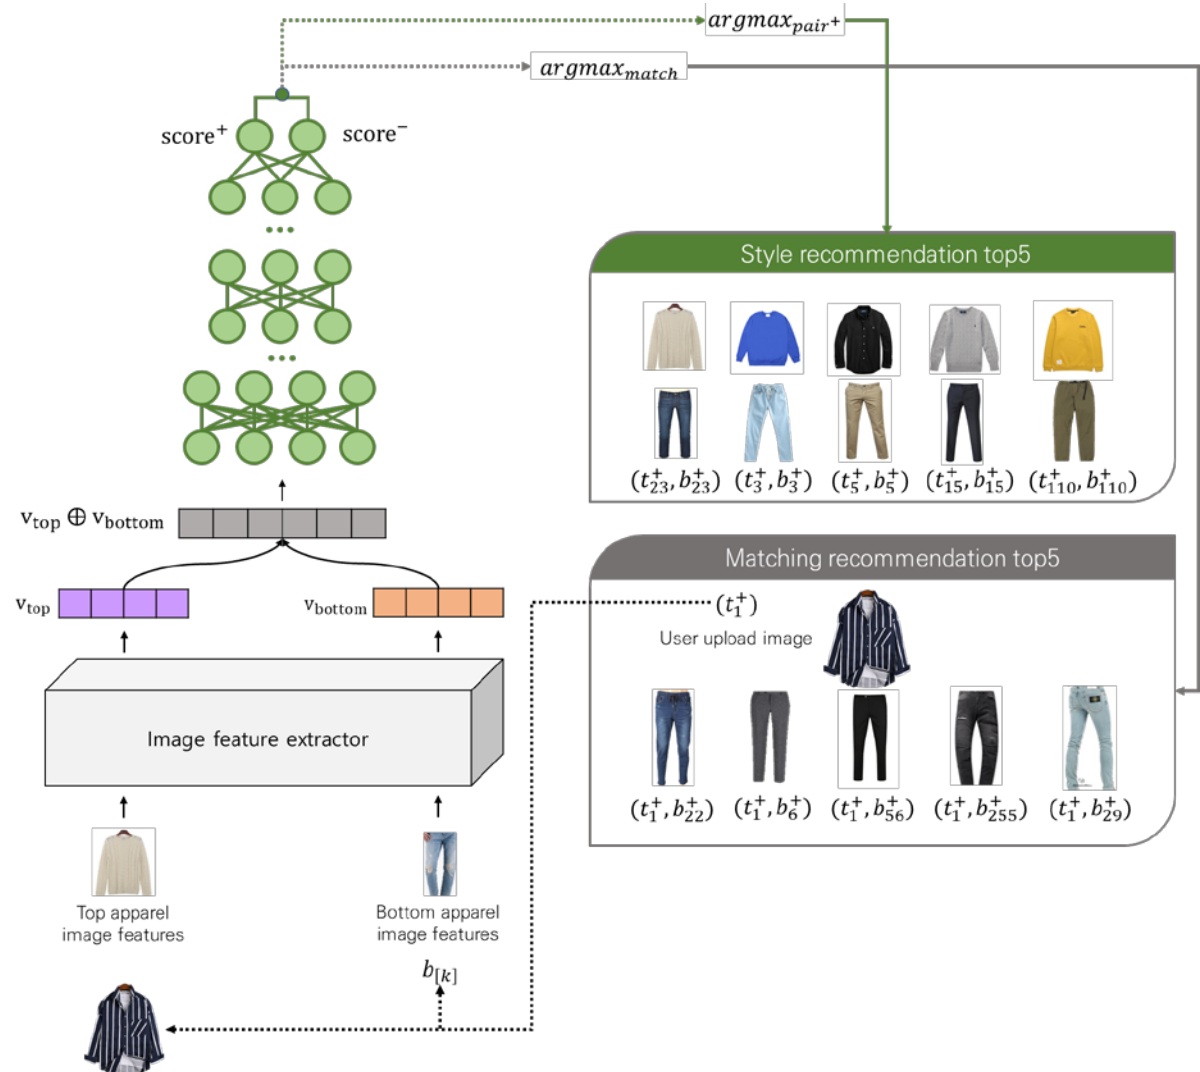
고려대학교 NLP&AI Lab.

- 벡터기반 사용자 선호 패션 프로파일링· 코디 및 매칭 기술 개발
- 드로잉 자질 추출 기술
- 딥러닝 기반의 패션 상품 유사 이미지 검색 모델

연구 내용 - 벡터기반 사용자 선호 패션 프로파일링·코디 및 매칭 기술 개발

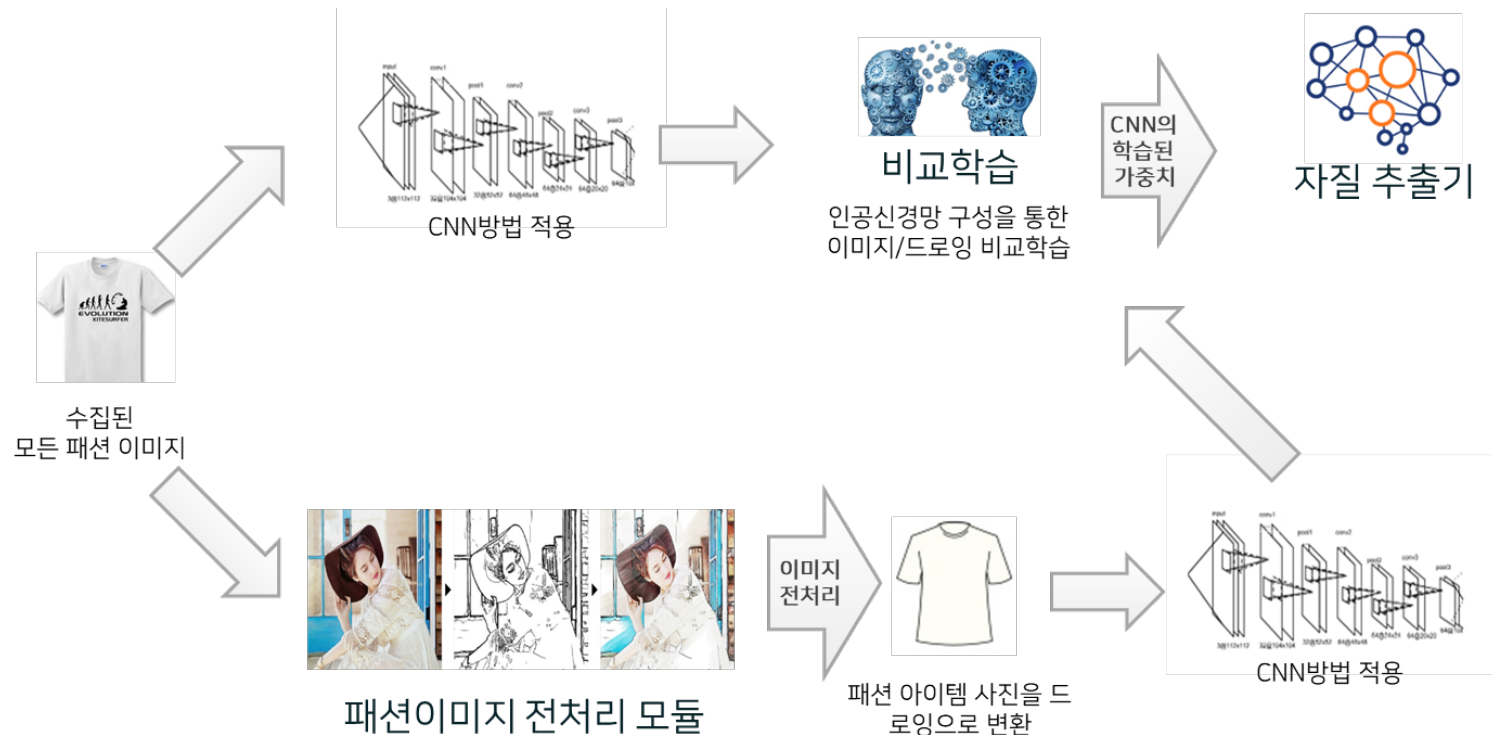
❖ 패션 추천 기술

- 코디 추천
 - 상의 및 하의
 - 계절감
- 매칭 추천
 - 어울리는 하의 추천
 - 어울리는 상의 추천
 - 계절감



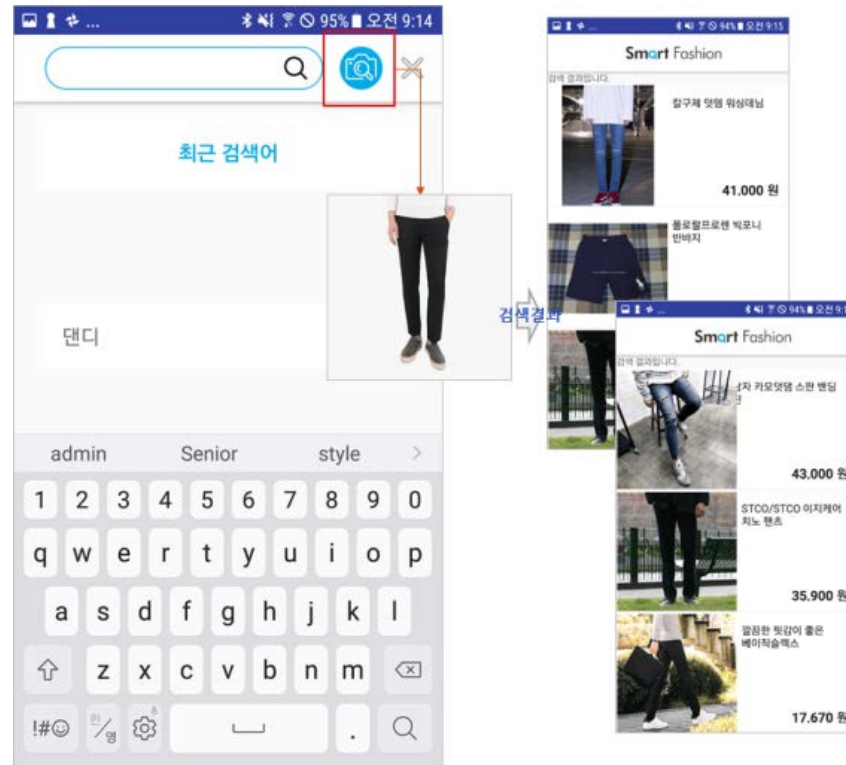
연구 내용 - 드로잉 자질 추출 기술

- CNN & FFNN 방법을 활용하여 드로잉 이미지 자질 추출모듈 개발
 - 패션 아이템 사진들을 이미지 전처리 과정을 통해 드로잉 이미지로 변환시켜 학습 데이터로 사용



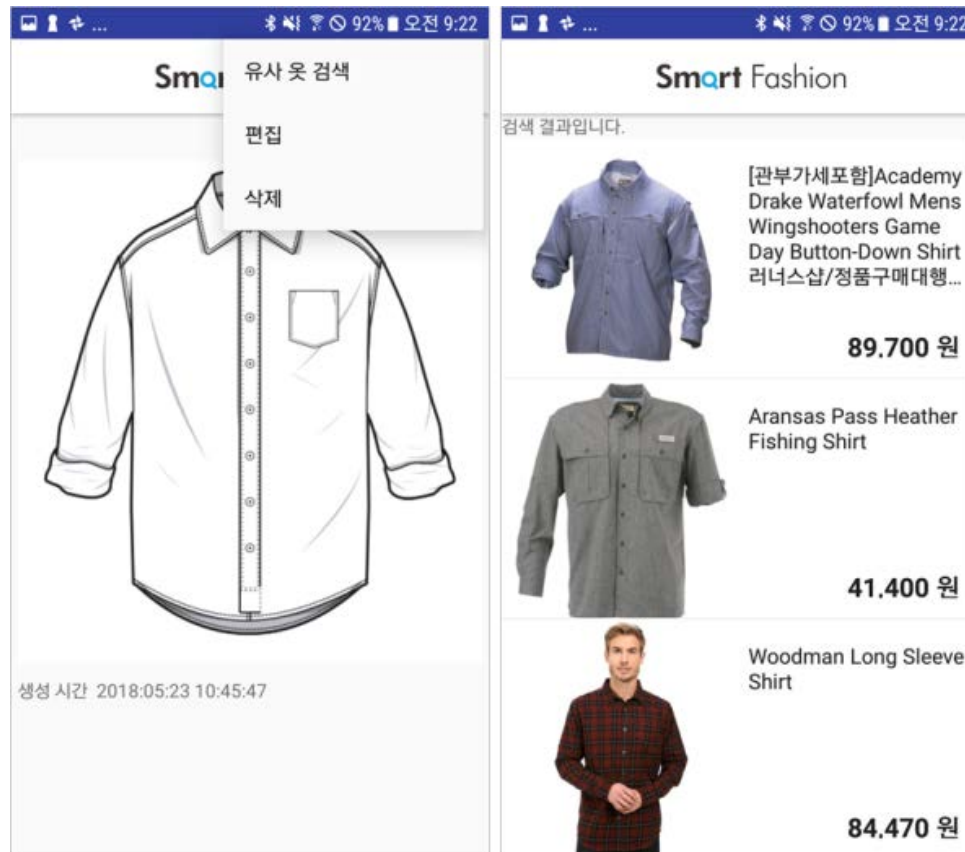
연구 내용 - 딥러닝 기반의 패션 상품 유사 이미지 검색 모델

- CNN 모델을 이용하여 패션 상품 이미지의 자질을 추출한 후 이를 기반으로한 유사 이미지 검색 모델 개발
- 이미지의 유사도는 색, 모양, 패턴 등을 고려하여 결정될 수 있음



연구 내용 - 딥러닝 기반의 패션 상품 유사 이미지 검색 모델

- 패션 상품 드로잉으로부터 업샘플링된 패션 상품 이미지를 이용한 유사 이미지 검색 모델 개발



전통문화 융복합 지원을 위한 지능형 검색 플랫폼 구축

고려대학교 NLP&AI Lab.

- Meta Learning based Global Relation Extraction
- 고유명사 개체인식 기술 개발 추가 연구 - 데이터 구축

Meta Learning based Global Relation Extraction

연구 내용 - 시멘틱 분석 기법

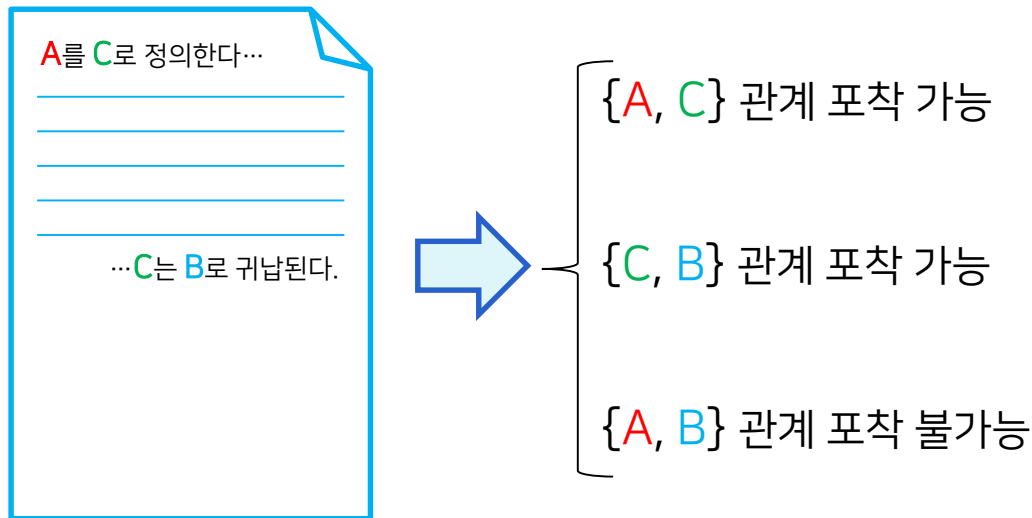
- 시멘틱 분석 기법에 사용될 기술 선정:
 - 문선 내 개체간 시멘틱 분석 기법으로 Relation Extraction을 선택함
- 관계 추출(Relation Extraction)이란?
 - 텍스트 내의 개체간 상호작용들을 고정된 시멘틱 관계 유형으로써 표현하는 것
- 텍스트 내 개체 간 관계 :
 - 텍스트의 의미는 텍스트 내에 개체를 정의하고, 각 개체간의 상호작용을 통해 부여 된다.
 - 이러한 상호작용들은 다양한 형태의 텍스트로 표현되며, 그 방식과 표기는 일정하지 않다.

1446년 9월 세종대왕이 훈민정음을 창제하였다.

{세종대왕, 훈민정음, hasCreated}

연구 내용 - 시멘틱 분석 기법

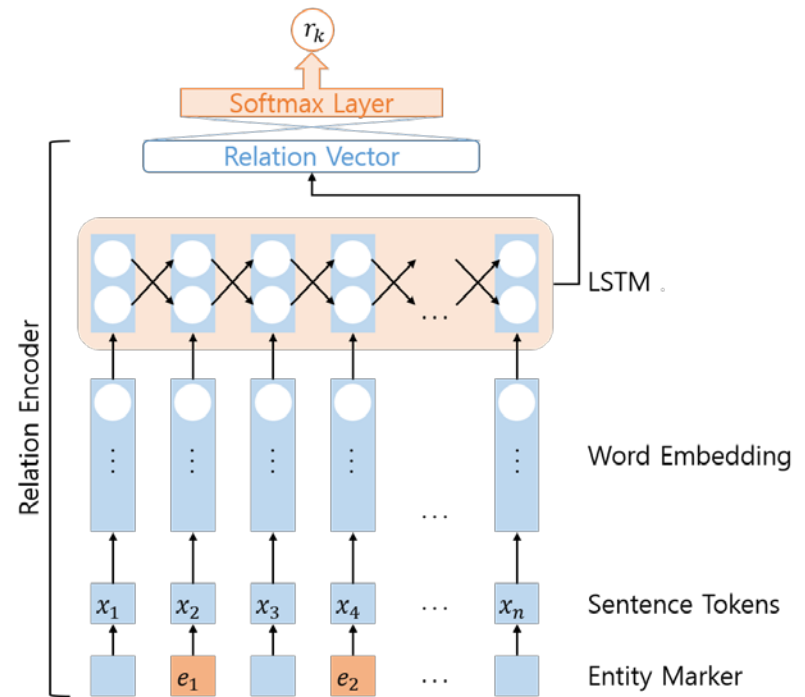
- 문제점
 - 장문의 텍스트를 처리할 경우, 여러 문장에 걸쳐 표현되는 문서 내 개체 간의 관계를 놓친다.
 - 이는 주어 및 목적어의 생략이 잦은 한국어의 경우 이 문제점이 더 크게 두드러진다.



- 위 문제를 해결하기 위하여 외부 메모리를 사용하는 RE 모델을 제시한다.

모델 설명 - Initial Relation Extraction


- 관계 분석 이전 전처리
 - 개체명 인식기를 통한 문서 내 개체 파악함
- 단편적 관계 분석
 - 문서 내에 존재하는 관계를 문장 단위로 분석 및 추출
 - 문장 내에 관계를 정의할 개체 1, 2 (e_1, e_2)을 표시함
 - 문장 x 내의 토큰 x_1, x_2, \dots, x_n 들을 벡터에 임베딩
 - 토큰 임베딩들은 LSTM 신경망을 거쳐 Relation 벡터로 변환됨
 - Relation 벡터를 통하여 (e_1, e_2)간 관계 여부 및 관계 분류를 판별함



모델 설명 - Augmented External Memory

- 문제점
 - 단편적 관계 추출 모델에서 얻어낸 결과들은 그러나 어디까지나 언급 수준의 관계들
 - 여러 문장에 걸쳐져 있는 관계를 가진 개체들을 분석하지 못함
- 외부 메모리 사용
 - 1차적으로 외부 메모리에 텍스트에서 얻어낸 언급 수준의 관계들의 출력벡터를 차례대로 저장하며 문장을 건너뛰는 관계 후보들을 검색함
 - 각 개체 사이에 공유되는 중간 개체들이 있는 관계들을 모두 통합하여 새로운 예측 벡터를 생성
 - 생성된 예측 벡터는 훈련된 메모리 증강 신경망을 통해 개체들 간의 전역 관계들을 정의함

모델 설명 - Augmented External Memory



모델 평가 - Experiments & Results

❖ 평가방법

- 전역적 관계 추출의 정확도를 평가하기 위하여 타 모델들과 함께 문서 단위의 평가 데이터로부터 관계 추출을 실행함
- 단편적 관계 추출과 전역적 관계 추출의 Precision, Recall 그리고 F1 Score을 비교함

	[A]	[B]	[C]	AEMM
Local Precision	0.327	0.341	0.390	0.269
Local Recall	0.315	0.347	0.259	0.307
Local F1 Score	0.321	0.344	0.311	0.287
Global Precision	0.194	0.183	0.198	0.383
Global Recall	0.313	0.332	0.262	0.287
Global F1 score	0.240	0.236	0.226	0.328

결론

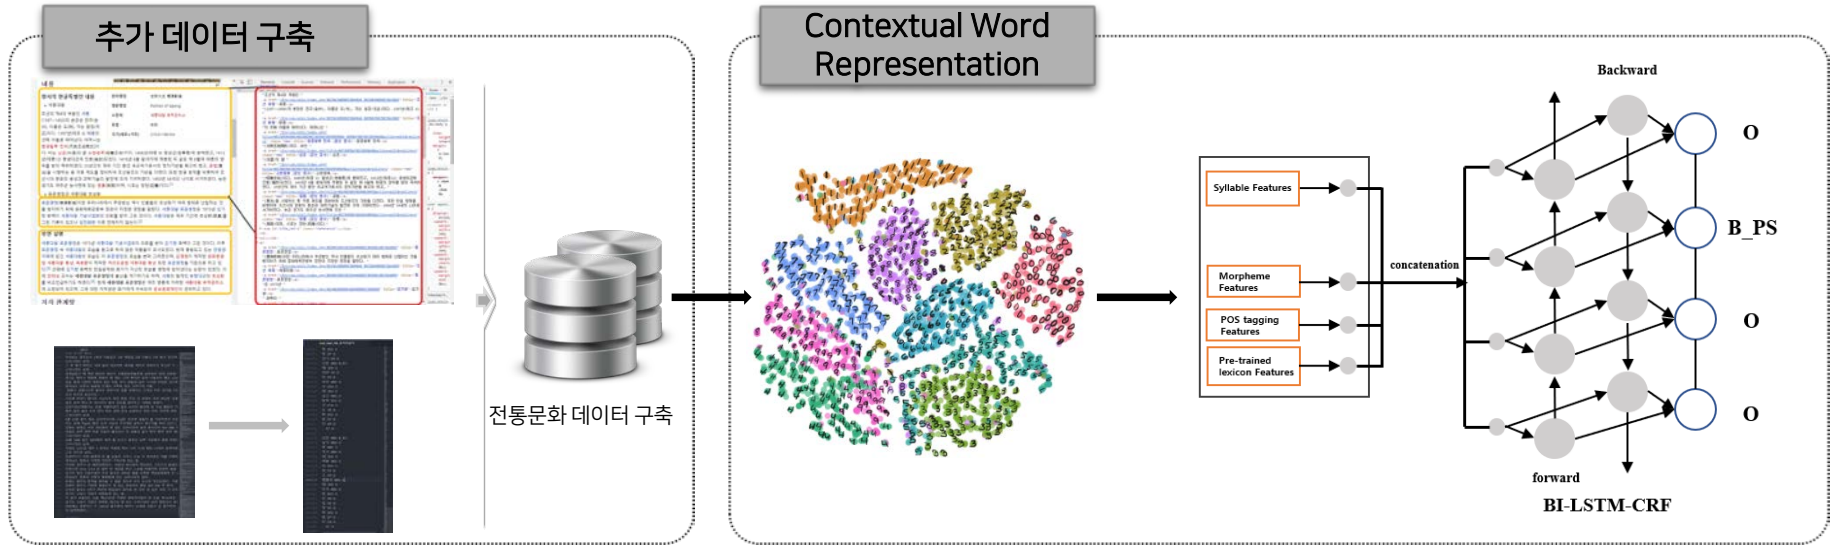
- 모델의 목적
 - 문서 내의 여러 문장을 통해 관계가 형성되는 개체들의 관계도 추출하려고 하는 RE 모델의 개발
 - 문장 내에 주어, 목적어의 생략이 잦은 한글 텍스트에 효과적인 RE 모델의 개발
- Contribution
 - 장문의 텍스트에 대한 심도 깊은 분석을 제시하는 것
 - 자연어로 이루어진 문서에서는 단 하나의 문장 내에서 성립되는 관계보다는 여러 문장에 걸쳐 표현되어지는 관계가 해당 문서 내의 주제를 더 잘 반영함을 반영하는 모델 제시
- Future Improvements:
 - 대량의 데이터를 2가지 형태로 요구하므로 이에 대한 완화
 - 오랜 훈련 시간 단축

고유명사 개체인식 기술 개발 추가 연구 - 데이터 구축

연구 내용 - 전통문화 개체명 인식 시스템 연구

- 개체명 인식기(Named Entity Recognition) 시스템이란?
 - 문장 내에서 고유한 의미를 갖는 명사를 추출하여 인명(PS), 지명(LC), 시간(TI) 등으로 고유명사를 인식하는 시스템
- 2차년도 연구 목표
 - 1차년도에서 부족했던 학습 데이터 추가 구축
 - 기존 모델에 추가 학습하여 자질 보강

연구 내용 - 전통문화 개체명 인식 시스템 연구



입력 문장

↓

형태소 단위
개체명 분석
결과

↓

개체명 인식
결과

↓

태그 결과

Input: 조선 세종은 조선의 제4대 군주이며 언어학자이다. 그의 업적에 대한 존경의 의미를 담은 명칭인 세종대왕으로 자주 일컬어진다. 성은 이, 휘는 도, 본관은 전주, 자는 원정, 아명은 막동이다.

형태소 단위 개체명 분석 결과:
 {"조선": "B_LC", "세종": "B_PS", "은": "O", "의": "O", "제": "O", "4": "O", "대": "O", "군주": "O", "이": "O", "며": "O", "언어학자": "O", "다": "O", "그": "O", "업적": "O", "에": "O", "대하": "O", "는": "O", "존경": "O", "의미": "O", "를": "O", "담": "O", "명칭": "O", "대왕": "O", "으로": "O", "자주": "O", "일컫": "O", "어": "O", "지": "O", "는다": "O", "성": "O", "": "O", "휘": "O", "는": "O", "도": "O", "본관": "O", "전주": "B_LC", "자": "O", "원정": "O", "아명": "O", "막": "O", "동이": "O"}

개체명 인식 결과:
 "<조선 세종:PS>은 <조선:LC>의 제4대 군주이며 언어학자이다. 그의 업적에 대한 존경의 의미를 담은 명칭인 <세종:PS>대왕으로 자주 일컬어진다. 성은 이, 휘는 도, 본관은 <전주:LC>, 자는 원정, 아명은 막동이다."

태그 결과:
 ('조선': 'LC')
 ('세종': 'PS')
 ('전주': 'LC')

연구 내용 - 전통문화 개체명 인식 시스템 연구

- 한국학 중앙연구원 사이트(<http://dh.aks.ac.kr>) 데이터 [정의] 및 [내용] 크롤링

The image shows a screenshot of a web browser displaying a Wikipedia page in Korean about Sejong the Great. The page content is partially highlighted in yellow, and the HTML source code is visible on the right side, with a red box highlighting a specific section of the code.

장서각 한글특별전 내용

한자명칭	世宗大王 標準影幀
영문명칭	Portrait of Sejong
소장처	세종대왕 유적관리소
유형	회화
크기(세로×가로)	210.0×180.0cm

조선의 제4대 국왕인 **세종** (1397~1450)의 본관은 전주(全州), 이름은 도(陶), 자는 원정(元正)이다. 1397년(태조 6) 태종의 셋째 아들로 태어났다. 어머니는 원경왕후 민씨(元敬王后閔氏)이다. 비는 심은(沈溫)의 딸 소헌왕후(昭憲王后)이다. 1408년(태종 8) 중녕군(忠寧君)에 봉해졌고, 1412년(태종 12) 중녕대군에 진봉(進封)되었다. 1418년 6월 왕세자에 책봉된 뒤 같은 해 8월에 태종의 양위를 받아 즉위하였다. 33년간의 재위 기간 동안 유교국가로서의 정치기반을 확고히 했고, **공법**(貢法)을 시행하는 등 각종 제도를 정비하여 조선왕조의 기반을 다졌다. 또한 한글 창제를 비롯하여 조선시대 문화의 융성과 과학기술의 발전에 크게 기여하였다. 1450년 54세의 나이로 서거하였다. 능은 경기도 여주군 능서면에 있는 **영릉**(英陵)이며, 시호는 장헌(莊憲)이다.^[1]

• 표준영정과 세종대왕 조상화

표준영정(標準影幀)이란 우리나라에서 추앙받는 역사 인물들의 초상화가 여러 형태로 남김하는 것을 방지하기 위해 문화체육관광부 장관이 지정한 영정을 말한다. **세종대왕 표준영정**은 1973년 김기창 화백이 세종대왕 기념사업회의 의뢰를 받아 그린 것이다. 세종대왕은 재위 기간에 조상화(朝眞)를 그린 기록이 있으나 **엄진왜란** 이후 전해지지 않는다.^[2]

부연 설명

세종대왕 표준영정은 1973년 세종대왕 기념사업회의 의뢰를 받아 김기창 화백이 그린 것이다. 이후 표준영정 속 세종대왕의 모습을 참고로 하여 많은 작품들이 모사되었다. 현재 통용되고 있는 만원권 지폐에 담긴 세종대왕의 모습도 이 표준영정의 모습을 본떠 그려졌으며, 김영환이 제작한 **광화문광장 세종대왕 동상**, 육동환이 제작한 **여의도공원 세종대왕 동상** 또한 표준영정을 기준으로 하고 있다.^[3] 근래에 김기창 화백의 친필문자와 화가가 자신의 모습을 영정에 담아냈다는 논란이 있었다. 이에 안태성 교수는 세종대왕 표준영정에 불신을 제기하기도 하며, 세종의 형제인 **고령대군의 초상화**를 비교 언급하기도 하였다.^[4] 현재 세종대왕 표준영정은 여주 영릉에 자리한 **세종대왕 유적관리소**에 소장되어 있으며, 그에 대한 저작권은 화가에 귀속되어 **은문화재단**이 관리하고 있다.

HTML Source Code Snippet:

```

<p>
<sup id="cite_ref-1" class="reference">↑</sup>
</p>
</ul>
</ul>
<p>
<a href="/encycvs/wiki/index.php/NFC98448095" title="표준영정">표준영정</a>
("標準影幀)이란 우리나라에서 추앙받는 역사 인물들의 초상화가 여러 형태로 남김하는 것을 방지하기 위해 문화체육관광부 장관이 지정한 영정을 말한다.
"
<a href="/encycvs/wiki/index.php/NFC98448095" title="조선 세종">조선 세종</a>
<a href="/encycvs/wiki/index.php/NFC98448095" title="표준영정">표준영정</a>
"은 1973년
"
<a href="/encycvs/wiki/index.php/NFC98448095" title="김기창">김기창</a>
"
</p>

```

연구 내용 - 전통문화 개체명 인식 시스템 연구

- 고려대학교 형태소 분석기를 사용하여 크롤링 데이터 문장 형태소 분석 및 POS tagging
- 지난 5월, 5명이 한 달간 15만여 건의 태깅 작업 진행
- 이후 추가 데이터 training을 위한 문장 전처리 작업 진행

```

List_D
511 조선 후기의 승려.
512 저서로는 정호보서 1책과 치문집주 3권 백암집 2권 지암기 1책 등이 있으며
513 신라시대의 승려.
520 그 후 해가 바뀌고 여러 일이 지났지만 비석을 세우지 못하다가 후고려 가
521 고려시대의 승려.
522 일찍 장경기 때 백은 탑본의 일부가 국립중앙박물관에 남아있고 현재 잔존한
523 경기도 양주시 회암동 회암사 에 있는 고려 후기의 승려 나용선사 해근 132
524 승탑 앞에 나란히 세워져 있는 석등 역시 승탑과 같은 시기에 조성된 것으로
525 전라남도 순천시 송광면 조계산 서쪽에 있는 신라시대 사찰.
526 평항수 곱항나무로 불리는 송광사의 명물 평항수는 조계산 마루 천지암 뒤
527 조선 전기의 문신이다.
528 시문에 뛰어난 명나라 사신으로 왔던 함림 진감 과 회정부 로써 회담한 내용
529 일본 승려 연년 이 당나라의 불교 성지를 돌아보고 기록한 여행기.
530 입당구법선재행기는 당을 여행하였던 일본 승려의 일의에 찬 구법 활동의 기
531 해의 흥교 불교 도교 정치 외교 법제 민속 궁중비사 친문 자리 언어에 관한
532 고려시대의 승려.
533 6월 29일 병이 매우 심하여지므로 스님은 손으로 일흔칠 을 가리키면서 속근
534 하는 날에 하늘로 뻗은 오색 기운이 무지개와 같아서 영구자를 따라 갔으나
535 강원도 양양군 서면 천림원지 에 있는 신라시대의 승려 흥각선사 814 880 9
536 바라는 전에 재계 비운 찬술자 흥각선사의 성품과 돌아가 후의 영적 업적 내
537 고려시대의 승려.
538 10월 10일 운도 50여명이 영여 를 모시고 팔공산 남쪽 기슭에서 화강 하였
539 고려시대의 승려.
540 지친은 1395년 태조 4 천마산 적멸암 에서 나이 72세 법랍 54세로 입적하였
541 고려 전기의 승려.
542 임종하시기 직전 왕에게 표 를 받들어 고하니 노승 이 뜻하였던 배를 이륙하
543 경상남도 함천군 가야면 지리산에 있는 절.
544 이러한 경지가 곧 해인사매이다. 마음의 바다에서 번뇌라는 가지가지 물결이
545 무용수면 1651 1719 은 얼마 전 세상을 떠난 스승을 떠올리며 천천히 글물
546 선사의 말인 무용수면이 조선 불교의 새로운 틀을 구축한 백암성종에게 쓴
547 경상남도 창원시 의창구 봉림동에 있는 신라시대의 절터.
548 현재는 절터의 흔적을 찾아볼 수 없을 정도로 모두 논으로 개간되었다. 사찰
549 강원도 원주시 지정면 흥법사에 있는 진공대사 증암 869 940 의 탑비.
550 신라의 탑비는 9세기 후반에 확립되어 풍토화 된 귀부 와 높은 비좌 가 갖추
551 경기도 고양시 덕양구 북한동에 있는 절.
552 이 절의 유물로는 보물 제611호로 지정된 원종국사탑비 와 보물 제749호로
553 경기도 고양시 덕양구 북한동 태고사 에 있는 고려시대의 승려 원종국사 보
554 비문에는 원종국사 가 1361년 풍주에서 태어나 13세에 회암사 로 출가하여
555 다 업적하였다.
556
  
```

데이터 4702 문장



```

trad_train_file_루지리관거
140451 하 XSV O
140452 앓 EP O
140453 으나 EM O
140454 신은 NNG B_PS
140455 에 JKB O
140456 의하 VV O
140457 아 EM O
140458 속리 NNP O
140459 사 XSN O
140460 에 JKB O
140461 근교 NNG O
140462 당하 XSV O
140463 기 ETH O
140464 도 JX O
140465 하 XSV O
140466 앓 EP O
140467 다 EM O
140468 . SF O
140469
140470 신은 NNG B_PS
140471 실각 NNG O
140472 후 NNG O
140473 국사 NNG O
140474 에 JKB O
140475 책행 NNG O
140476 뒤 XSV O
140477 앓 EP O
140478 고 EM O
140479 평원사 NNG O
140480 에 JKB O
140481 주석 NNG O
140482 하 XSV O
140483 다 EM O
140484 인 VV O
140485 적 VV O
140486 하 XSV O
140487 앓 EP O
140488 다 EM O
140489 . SF O
140490
  
```

태깅 데이터 15만 개

연구 내용 - 전통문화 개체명 인식 시스템 연구

- 기존 4258 문장 + 4702문장 학습 및 결과

input> 세종이 훈민정음을 처음 창제한 것은 1443년 12월이었다. 이후 세종은 최항(崔恒)· 박팽년(朴彭年)· 신숙주(申叔舟)· 이현로(李賢老)· 이개(李垿)· 강희안(姜希顔) 등에게 명하여 여러 문서들을 훈민정음으로 작성하는 등의 시험 과정을 거쳤다.

output> <세종:PS>이 훈민정음을 처음 창제한 것은 <1443년 12월:DT>이었다. 이후 <세종:PS>은 <최항:PS>·<崔恒:PS>·<박팽년:PS>·<신숙주:PS>(申叔舟)·<이현로(李賢老)::PS>·<이개(李垿)::PS>·<강희안(姜希顔) 등:PS>에게 명하여 여러 문서들을 훈민정음으로 작성하는 등의 시험 과정을 거쳤다.

세종 PS

1443년 12월 DT

세종 PS

최항 PS

崔恒 PS

박팽년 PS

신숙주 PS

이현로(李賢老)· PS

이개(李垿)· PS

강희안(姜希顔) 등 PS

세종(PS), 년도(DT), 그 외 인물(PS) 인식

연구 내용 - 전통문화 개체명 인식 시스템 연구

- 기존 4258 문장 + 4702문장 학습 및 결과

input> 1592년 4월 13일 일본의 침입으로 임진왜란이 발발되었는데, 일본의 대군이 침입해 왔다는 급보가 전라좌수영에 전달된 것은 이틀 뒤였다. 이순신의 휘하 전함대는 4월 29일 수영 앞바다에 총집결하여 매일 작전회의가 열리고 기동연습도 강행하여 완전한 전투태세에 임하게 되고, 이순신은 총지휘관으로 5월 2일 기함에 승선하였다.

output> <1592년:DT> <4월:DT> <13일:DT> <일본:LC>의 침입으로 임진왜란이 발발되었는데, <일본:LC>의 대군이 침입해 왔다는 급보가 <전라좌수영:DT>에 전달된 것은 이틀 뒤였다. <이순신:PS>의 휘하 전함대는 <4월 29일:DT> <수영 앞바다:LC>에 총집결하여 매일 작전회의가 열리고 기동연습도 강행하여 완전한 전투태세에 임하게 되고, <이순신:PS>은 총지휘관으로 <5월 2일:DT> 기함에 승선하였다.

1592년	DT
4월	DT
13일	DT
일본	LC
일본	LC
전라좌수영	DT
이순신	PS
4월 29일	DT
수영 앞바다	LC
이순신	PS
5월 2일	DT

장소(LC), 년도(DT), 그 외 인물(PS) 인식

머신러닝을 이용한 비정형 위협정보 자동추출 방안 연구

고려대학교 NLP&AI Lab.

- 비정형 위협정보 자동 인식 및 추출
- 머신러닝을 이용한 문서 자동 요약
- 유사 문서 검색 및 시각화
- Keyword Extraction
- 위협정보 개체명 인식 데이터 구축
- OCR 프로그램 조사 및 성능 비교

연구 목표

선행 기술 연구



국내·외 비정형 빅데이터 분석 사례 조사

기반 기술 연구



딥러닝 기술을 이용한 비정형 위협정보 자동 인식 및 추출 기술 연구



머신러닝 기반 보고서 자동 분석 및 키워드 추출 기술 연구



머신러닝을 이용한 문서 자동 요약 기술 연구

응용 기술 연구



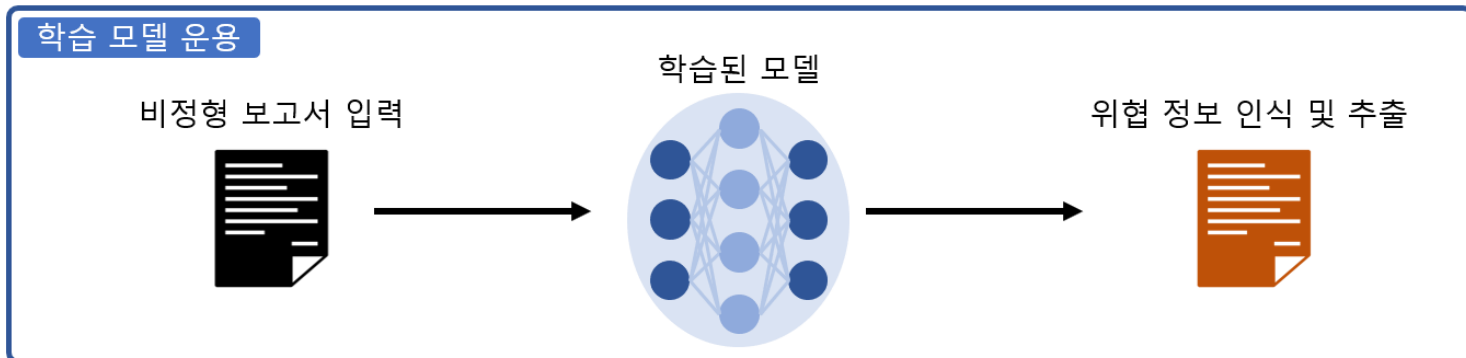
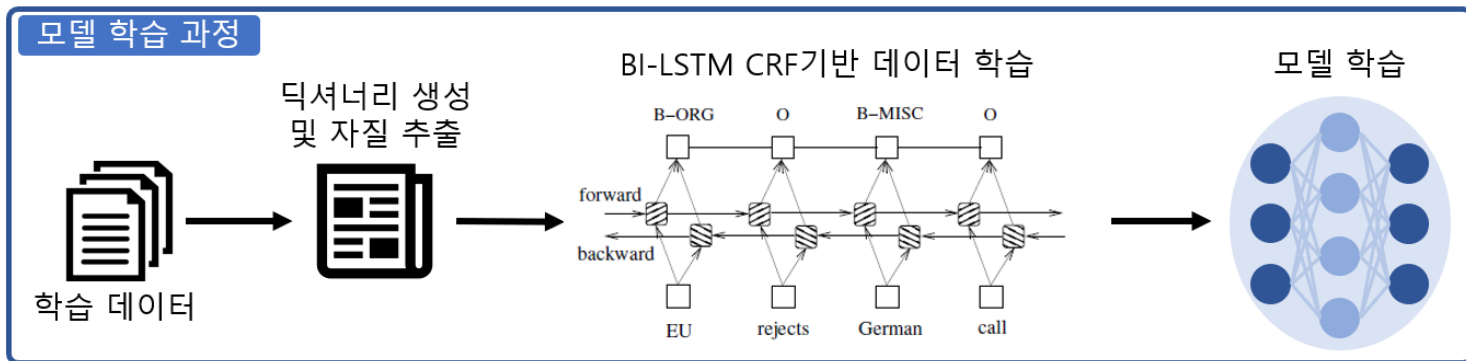
딥러닝을 이용한 문서 토픽 자동 추출 기술 연구



문서 임베딩 벡터 기반 유사 문서 검색 및 시각화 기술 연구

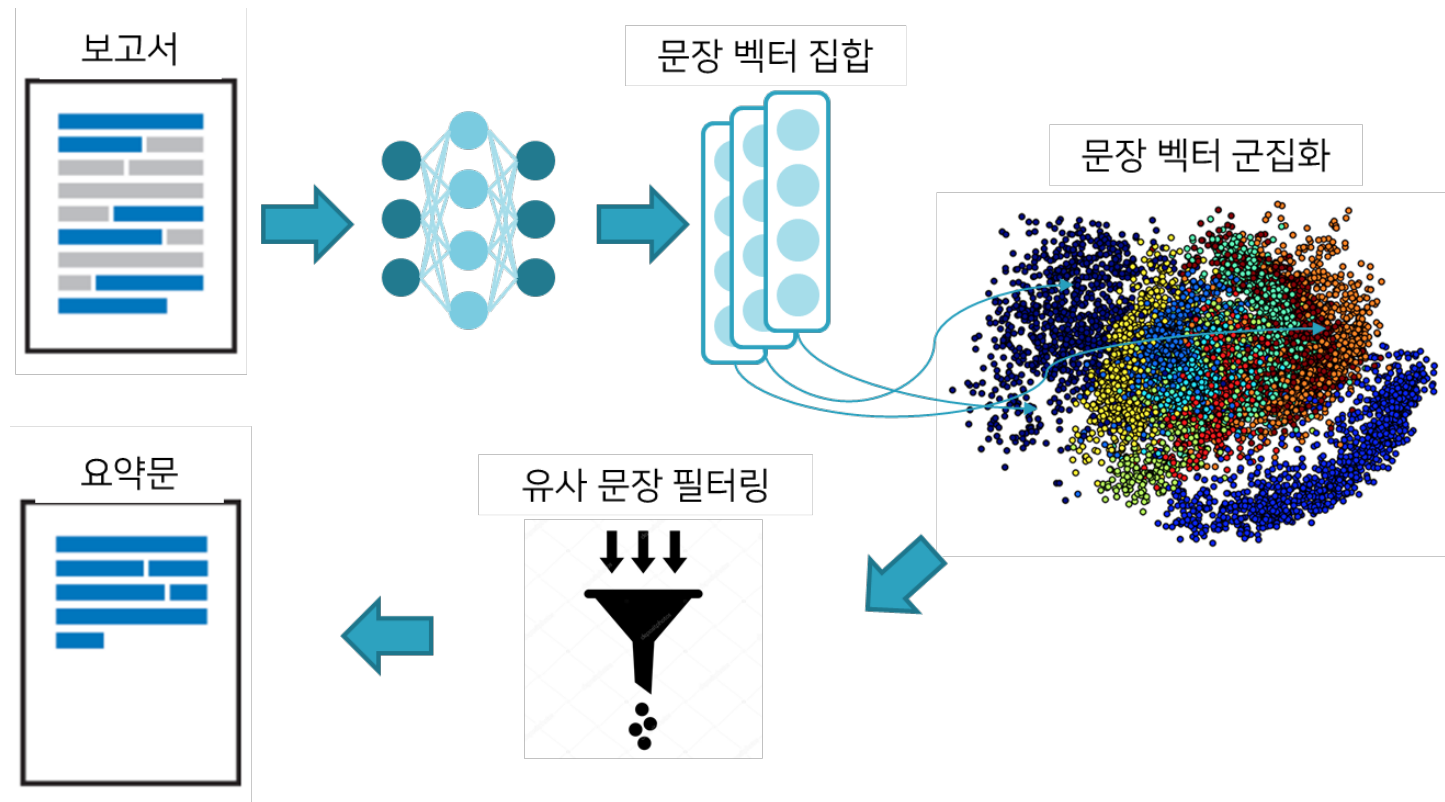
연구 내용 - 비정형 위협정보 자동 인식 및 추출

- BI-LSTM-CRF 기반 모델을 통해 데이터 학습
- 비정형 보고서가 입력될 경우, 학습된 모델을 사용하여 위협정보로 판단되는 개체명 인식 및 추출




연구 내용 - 머신러닝을 이용한 문서 자동 요약

- 보고서로부터 요약문을 자동적으로 생성할 수 있는 기술 연구
- 보고서 검색 시 요약문을 보고서와 함께 효과적으로 제시할 수 있는 방법 연구



연구 내용 - 유사 문서 검색 및 시각화

- 벡터 공간 상에 문서를 임베딩하고, 이 벡터 공간의 차원을 축소하는 기술 연구
- 차원 축소된 벡터 공간을 효과적으로 시각화하고, 이를 이용하여 유사 문서를 검색하는 기술 연구




연구 목표 - Keyword Extraction


- 인텔리전스 보고서가 증가함에 따라 사용자가 원하고자 하는 문서를 짧은 시간 내에 판단하여 찾는 것은 쉽지 않음
- 사용자가 효율적으로 원하는 문서를 찾을 수 있도록 키워드 추출 알고리즘을 이용함



인텔리전스 보고서



키워드 추출 알고리즘



키워드 추출



키워드 검색 용이

연구 내용 - Keyword Extraction

- 키워드 추출 시스템 구조도



연구 결과 - Keyword Extraction

- 각 인텔리전스 보고서 마다 keyword 추출

```
tf = blob.words.count(word) / len(blob.words)
if tf == 0:
    tf = 0.1
return tf

def n_containing(word, preprocess_train_data):
    return sum(1 for blob in preprocess_train_data if word in blob.words)
for l, blob in enumerate(prepro... for word, score in sorted_words...
```

Run: keyword_extraction_original

```
/usr/bin/python3.5 /home/ubuntu-yuna/Desktop/KISA/keyword_extraction/keyword_extraction_original.py
Top words in document 1
Word: shady, TF-IDF: 0.01893
Word: wada, TF-IDF: 0.0097
Word: alperovitch, TF-IDF: 0.00848
Word: mcafee, TF-IDF: 0.00815
Word: e-mail, TF-IDF: 0.00754
Word: says, TF-IDF: 0.00754
Word: olympic, TF-IDF: 0.00689
Word: rat, TF-IDF: 0.00672
Word: cyber-espionage, TF-IDF: 0.00539
Word: spokesman, TF-IDF: 0.00431
Word: wrote, TF-IDF: 0.00431
Word: nonprofits, TF-IDF: 0.00431
Word: anti-doping, TF-IDF: 0.00344
Word: committee, TF-IDF: 0.00344
Word: command-and-control, TF-IDF: 0.00323
Word: vanity, TF-IDF: 0.00323
Word: breaches, TF-IDF: 0.00323
Word: victims, TF-IDF: 0.003
Word: us, TF-IDF: 0.00269
Word: organizations, TF-IDF: 0.00265
Word: committees, TF-IDF: 0.00258
Word: expert, TF-IDF: 0.00258
Word: nations, TF-IDF: 0.00258
Word: singapore, TF-IDF: 0.00258
Word: really, TF-IDF: 0.00258
Word: unprecedented, TF-IDF: 0.00258
Word: western, TF-IDF: 0.00258
Word: he, TF-IDF: 0.00245
Word: agency, TF-IDF: 0.00245
Word: problem, TF-IDF: 0.00235
Top words in document 2
Word: shaze, TF-IDF: 0.05698
Word: kernel, TF-IDF: 0.0106
Word: stuxnet, TF-IDF: 0.00979
Word: driver, TF-IDF: 0.00666
Word: c2, TF-IDF: 0.00645
Word: 24,900, TF-IDF: 0.00538
```

Top words in document 1

- Word: shady, TF-IDF: 0.01893
- Word: wada, TF-IDF: 0.0097
- Word: alperovitch, TF-IDF: 0.00848
- Word: mcafee, TF-IDF: 0.00815
- Word: e-mail, TF-IDF: 0.00754
- Word: says, TF-IDF: 0.00754
- Word: olympic, TF-IDF: 0.00689
- Word: rat, TF-IDF: 0.00672
- Word: cyber-espionage, TF-IDF: 0.00539

-
-
-

연구 결과 - Keyword Extraction

- 각 인텔리전스 보고서 keyword 추출 성능
 - 수작업으로 추출한 키워드와 결과와 비교 시 80%의 정확도를 보임

수작업을 통한 키워드 추출	본 모델을 이용한 키워드 추출
MSPs	Word: apt10
APT10	Word: plugx
Cloud hopper	Word: msp
Threat actor	Word: organisations
Plug X	Word: msps
PWC	Word: chches
BAE	Word: china-based
China based	Word: pwc
Organisation	Word: japanese
Dynmaic-dns	Word: bae

수작업을 통한 키워드 추출	본 모델을 이용한 키워드 추출
Utc+8	Word: dynamic-dns
Chches	Word: utc+8
poison	Word: annex
Japen	Word: hopper
Annex	Word: quasar
Poision ivy	Word: ivy
Attack	Word: 2016
IVY	Word: poison
C2 domain	Word: actor
FYP	Word: fyp

연구 결과 - 위협정보 개체명 인식 데이터 구축

- 오류수정 도구 생성
 - 태그 작업은 사람에 의해 발생된 부분으로 실수가 발생할 수 있음
 - 따라서 오류를 방지하고자 태그확인이 가능한 반자동 도구를 생성하여 배포
 - 오류 파악 도구에서, 도구가 자동적으로 말뭉치를 수정하는 경우는 모호성이 존재하지 않는 경우에 한함
 - 이는 모호성이 있는 상황에서 잘못된 오류 수정으로 인해 말뭉치가 손상되는 것을 방지하기 위함임
 - 모호성이 존재할 가능성이 있는 경우, 도구는 오류를 수정하는 대신 오류가 발생한 파일과 발생 위치를 사용자에게 제시하여 직접적인 수정을 유도함


연구 결과 - 위협정보 개체명 인식 데이터 구축

- 오류수정 도구 생성
 - 태그 작업은 사람에 의해 발생된 부분으로 실수가 발생할 수 있음
 - 따라서 오류를 방지하고자 태그확인이 가능한 반자동 도구를 생성하여 배포
 - 오류 파악 도구에서, 도구가 자동적으로 말뭉치를 수정하는 경우는 모호성이 존재하지 않는 경우에 한함
 - 이는 모호성이 있는 상황에서 잘못된 오류 수정으로 인해 말뭉치가 손상되는 것을 방지하기 위함임
 - 모호성이 존재할 가능성이 있는 경우, 도구는 오류를 수정하는 대신 오류가 발생한 파일과 발생 위치를 사용자에게 제시하여 직접적인 수정을 유도함

연구 내용 - OCR 프로그램 조사 및 성능 비교

- 다양한 형태로 제공되는 OCR 프로그램을 7종으로 추려 2가지 성능 평가를 진행함
- 주어진 문자 이미지를 해당 문자로 정확히 변환하는지, 문자를 포함한 이미지와 문자가 아닌 이미지를 구분할 수 있는지를 측정해 정확도로 표현함
- 하지만 각 프로그램마다 줄 바꿈과 문장 순서 등 출력 형태가 달라 정답 데이터와 예측 데이터의 문자들을 일대일로 비교하기 어려움
- 모든 예측 데이터를 정답 데이터에 맞춰 일일이 병렬 데이터를 구축하는 작업은 확장성이 낮음
- 이에 따라 대안으로서, 정답 데이터에 등장한 문자의 출현 횟수를 사전(dictionary)에 저장한 뒤, 예측 데이터마다 사전을 구축해 정답 데이터 사전과 값 차이의 절대값을 모두 더해 오차를 구함

연구 내용 - OCR 프로그램 조사 및 성능 비교



<그림 4> OCR 성능 비교 결과

기계학습을 활용한 자연어 질의/응답 인공지능 모델 개발


고려대학교 NLP&AI Lab.

- 기술 동향 보고서
- 기술 개발 전략 보고서
- 자동차 법률 응답 대화 시스템

연구 내용 - 기술 동향 보고서 및 기술 개발 전략 보고서

- 과제 배경

- 4차 산업혁명의 핵심 기술인 AI 기술의 선도적 확보를 위해 차세대 업무 지원이 가능한 AI DSS (Decision Support System) 서비스 모델 및 질의응답 모델 개발 연구
- 최신 NLP관련 Top Conference 및 학회지에서 발표된 논문들을 분석함
- Machine Learning, Question & Answering, Natural Language Understanding, MultiModal Approach, Relation Extraction, Transfer Learning, Dialogue State Tracking 분야를 다룸



연구 내용 - 기술 동향 보고서 및 기술 개발 전략 보고서

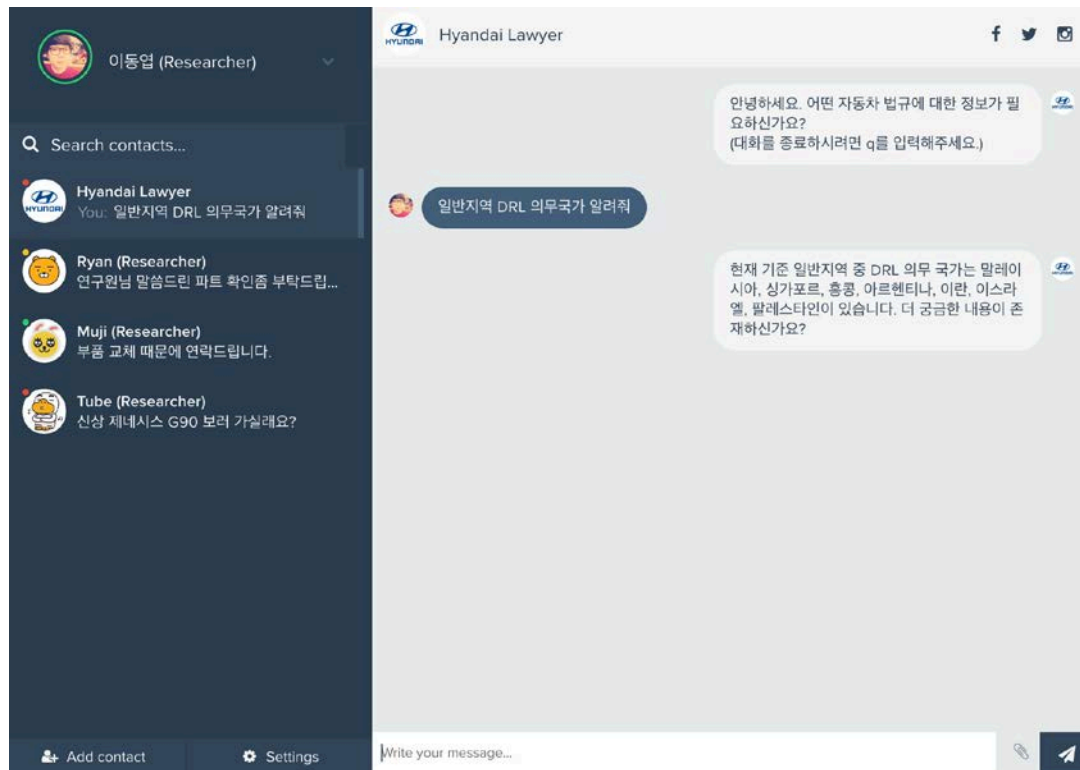
- 분석 및 논문 요약
 - Know What You Don't Know: Unanswerable Questions for SQuAD
 - Large-Scale QA-SRL Parsing
 - Learning to Ask Good Questions: Ranking Clarification Questions using Neural Expected Value of Perfect Information
 - Multi-Relational Question Answering from Narratives: Machine Reading and Reasoning in Simulated Worlds
 - Question Answering on Knowledge Bases and Text using Universal Schema and Memory Networks
 - Attention Is All You Need
 - Learning to Paraphrase for Question Answering
 - Latent Space Embedding for Retrieval in Question-Answer Archives
 - The NarrativeQA Reading Comprehension Challenge
 - Adversarial Adaptation of Synthetic or Stale Data

연구 내용 - 기술 동향 보고서 및 기술 개발 전략 보고서

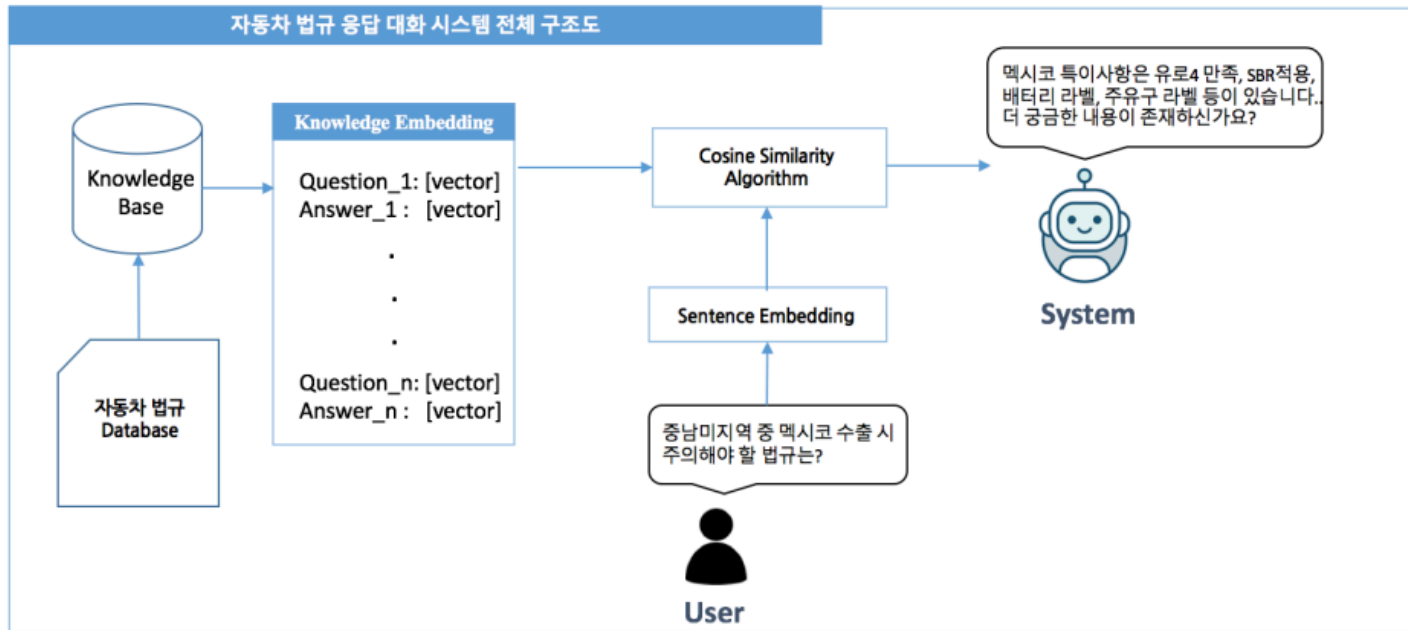
- 분석 및 논문 요약
 - New Transfer Learning Techniques for Disparate Label Sets
 - ONENET: JOINT DOMAIN, INTENT, SLOT PREDICTION FOR SPOKEN LANGUAGE UNDERSTANDING
 - ReadingWikipedia to Answer Open-Domain Questions
 - Never-Ending Learning
 - Visual Relation Extraction via Multi-modal Translation Embedding Based Model
 - Training Classifiers with Natural Language Explanations
 - Zero-Shot Transfer Learning for Event Extraction
 - Cross-Domain Sentiment Classification with Target Domain Specific Information
 - Question-Answer Driven Semantic Role Labeling
 - Zero-Shot Recognition via Semantic Embeddings and Knowledge Graphs
 - Semantic Parsing of Technical Support Questions
 - Adaptive Document Retrieval for Deep Question Answering

연구 내용 - 자동차 법률 응답 대화 시스템

- 자동차에 관련한 법률 지식을 대화 시스템을 통해 연구자들에게 제공해주는 시스템
- 본 시스템을 통해, 연구자들은 자동차 법률 지식에 쉽게 접근할 수 있음



연구 내용 - 자동차 법률 응답 대화 시스템



- 자동차에 관한 법규들을 지식 기반(knowledge base)의 형태로 저장
- 연구자로부터 질문(query)이 들어왔을 때, 구축된 지식을 활용하여 연구자에게 관련된 법규 조항들을 알려줌
- 질문과 구축된 법률 지식 기반과의 유사도를 측정하고, 해당 질문과 가장 유사도가 높은 법률 지식에 대한 답을 전달

연구실적

고려대학교 NLP&AI Lab.

- 논문
- 특허
- 소프트웨어등록
- 시제품

연구 실적 - 논문

❖ 해외 학술지

1. Seolhwa Lee, Dongyub Lee, Danial Hoosyar, Jaechoon Jo, Heuseok Lim, "Integrating Breakdown Detection into Dialogue Systems to Improve Knowledge Management: Encoding Temporal Temporal Utterances with Memory Attention", the journal of information technology and management(ITEM), 2018. (under review)
2. Danial Hooshyar, Seolhwa Lee, Yeongwook Yang, Jaechoon Jo, Heuseok Lim, "SmartSenior: automatic content personalization through semi-supervised learning", Wireless Personal Communications, 2018. (SCIE)
3. Danial Hooshyar, Seolhwa Lee, Yeongwook Yang, Jaechoon Jo, Heuseok Lim, "Long-term effects of adaptive customization support on elderly people", Cognition Technology and Work, 2018. (SSCI/SCIE)

연구 실적 - 논문

❖ 해외 학술대회

1. Aram So, Natasia Wulansari, HeuiSeok Lim, " A study on building corpus for restaurant reservation system " , The 2nd International Conference on Interdisciplinary research on Computer Science, Psychology, and Education (ICICPE), pp. 126-128, 2018.
2. Seolhwa Lee, Heuseok Lim, "A Study on Vector-Based User-Preferred Fashion Matching", The 2st International conference on Interdisciplinary research on Computer Science, Psychology, and Education (ICICPE' 2018), 2018.
3. YunA Hur, Heuseok Lim, "Empirical Evaluation of Traditional Culture Document Classification Systems with TF-IDF/Bag-of-Words Features", The 2nd International Conference on Interdisciplinary research on Computer science, Psychology, and Education(ICICPE), 2018.
4. Chanhee Lee, Youngbum Kim, Dongyub Lee, Heuseok Lim. "Character-Level Feature Extraction with Densely Connected Networks", International Conference on Computational Linguistics (COLING 2018), 2018.08.
5. Andrew Matteson, Chanhee Lee, Young-Bum Kim, HeuiSeok Lim. "Rich Character-Level Information for Korean Morphological Analysis and Part-of-Speech Tagging", International Conference on Computational Linguistics (COLING 2018), 2018.08.

연구 실적 - 논문

❖ 해외 학술대회

6. Chanhee Lee, Heuseok Lim. "Sketch to Image Upsampling using Generative Adversarial Networks for Query by Image Content", International Conference on Interdisciplinary research on Computer Science, Psychology, and Education (ICICPE), 2018.01.
7. Kuekyeng Kim, Hyesung Ji, Heuseok Lim, "Comparisons of multiple approaches in improving Image Caption Generation Models", ICICPE 2018, 2018.02
8. Gyeongmin Kim, Heuseok Lim, "A study of Dataset and User interface for a Restaurant Reservation Dialogue System", International Conference on Interdisciplinary research on Computer Science, Psychology, and Education(ICICPE), 2018.
9. Taesun Whang, Dongyub Lee, Chanhee Lee, Heuseok Lim, "Enhanced Sequential Representation Augmented with Utterance-level Attention for Response Selection", AAIL'2019 Workshop on Dialog System Technology Challenges (DSTC7), 2019. 01.



연구 실적 - 논문

❖ 국내 학술지

1. 이설화, 이찬희, 조재춘, 임희석, " 암묵적 사용자 프로파일링을 통한 딥러닝기반 지능형 선호 패션 추천", 한국융합학회논문지 2018.
2. 김규경, 김경민, 조재춘, 임희석, "전통 문화 데이터를 이용한 메타 러닝 기반 전역 관계 추출", 한국융합학회논문지, 2018.11, vol.9, no.11, pp. 23-28 (6 pages)
3. 김경민, 김규경, 조재춘, 임희석, " 한국 전통문화 말뭉치구축 및 Bi-LSTM-CNN-CRF 기반의 개체명 인식 모델 개발", 한국융합학회, 2016년 추계학술발표대회 논문집, 제 23권, 제 2호, pp. 327-328, 2018.

연구 실적 - 논문

❖ 국내 학술대회

1. 소아람, 이설화, 허윤아, 황태선, 임희석, "맞춤형 UX 설계를 위한 시니어와 주니어 사용자의 생체능력 비교 분석 연구", 한국컴퓨터교육학회 하계 학술발표논문지 제22권 제2호, 2018.
2. 소아람, 박기남, 임희석, "식당예약 및 추천을 위한 한국어 대화 코퍼스 구축 연구", 제30회 한글 및 한국어정보처리 학술대회 논문집, pp. 630-632, 2018.
-  3. 이설화, 소아람, 허윤아, 황태선, 임희석, "고령 사용자를 위한 UI/UX 컴포넌트 매핑 및 시각화 방법", 컴퓨터교육학회 2018 하계학술발표논문집, 제22권, 제2호, pp.85~87, 2018
4. 이설화, 조재춘, 이찬희, 이동엽, 임희석, "사용자 프로파일링을 통한 지능형 선호 패션 추천", 2018 한국패션비즈니스학회, pp.72~73, 2018.
5. 허윤아, 황태선, 소아람, 이설화, 임희석, "고령 사용자 맞춤형 UI/UX 제공을 위한 인지 및 온라인 활동 기반 프로파일링", 컴퓨터교육학회, 하계학술 발표논문집, 제 22권, 제 2호, 2018
6. 허윤아, 김경민, 이찬희, 임희석, "딥러닝 기술을 이용한 비정형 보안 위협정보 자동 탐지 및 추출 기술 연구", 한글 및 한국어 정보처리 학술대회정보처리학회, 2018.
-  7. 이찬희, 조재춘, 이동엽, 이설화, 임희석. "스케치를 이용한 남성 의류 검색", 한국패션비즈니스학회 2018 춘계학술대회 논문집, pp.79-80, 2018.04.
8. 이찬희, 이동엽, 허윤아, 양기수, 임희석. "음절 단위 및 자모 단위의 Byte Pair Encoding 비교 연구", 제30회 한글 및 한국어 정보처리 학술대회 논문집, 2018.

연구 실적 - 논문

❖ 국내 학술대회

9. 김규경, 김경민, 조재춘, 임희석 "문서 내 전역 관계 추출: 생략된 개체의 고려", 제30회 한글 및 한국어 정보처리 학술대회, 2018
10. 이동엽, 황태선, 이찬희, 임희석, "적대 학습을 이용한 자연어 이해", 한글 및 한국어정보처리 학술대회, 2018
11. 이동엽, 이찬희, 이설화, 조재춘, 임희석 "패션 상품 이미지를 이용한 패션 상품 카테고리 자동 분류기 개발" 한국패션비즈니스학회 2018 춘계학술대회 논문집, pp.131-132, 2018.04.
12. 김경민, 허윤아, 김규경, 임희석, " 정보보안 분야의 위협정보 개체명 인식 시스템 개발을 위한 데이터셋 구축", 한글 및 한국어 정보처리학회, 2018.
13. 황태선, 이동엽, 임희석, "Attention 기반의 대화 발화 예측 모델", 제 30회 한글 및 한국어 정보처리 학술 대회, pp 40-43, 2018.
14. 황태선, 이설화, 허윤아, 소아람, 임희석, "시니어 인지 반응 측정 데이터 기반 뉴스 형태 추천 시스템 설계", 한국 컴퓨터 교육학회 하계 학술대회, 제 22권 2호. pp. 143-145. 2018.
15. 양기수, 이동엽, 이찬희, 임희석, "오토인코더와 적대 네트워크를 활용한 한국어 문체 변환", 한국정보과학회, 제30회 한글 및 한국어 정보처리 학술대회 논문집, 2018

연구 실적 - 특허

❖ 특허(국내)

1. 스마트 시니어 인지반응 기반의 모델링 방법 및 장치, 출원 완료 및 등록 진행 중, 이설화
2. 사용자 프로파일링을 이용한 사용자의 선호 패션 추천 방법, 출원 완료, 이설화
3. 스마트 시니어 온라인 활동 기반 프로파일을 이용한 맞춤형 콘텐츠, 출원 완료, 허윤아
4. 한글 문서 내 전역적 관계 추출기, 2018.12.03 출원, 김규경, 김경민, 조재춘
5. 딥 러닝을 이용하여 이미지를 검색하는 단말 장치 및 방법, 이동엽, 임희석
6. 스마트 시니어를 위한 맞춤형 콘텐츠 추천 장치 및 방법, 출원 완료, 황태선

❖ 특허(국외)

1. 스마트 시니어 인지반응 기반의 모델링 방법 및 장치, 출원 완료, 이설화

❖ 기술이전

1. 한국어 개체명 인식 시스템, 이동엽, 임희석

연구 실적 - 시제품 제작, 강연, 수상

❖ 시제품 제작

1. 인지반응 분석 시스템 플랫폼 제작, <http://nlplab.iptime.org:4321/seol2/>
2. 전통문화 관계 추출기 개발 DEMO: <http://nlplab.iptime.org:32277/>
3. 한국어 식당 예약 시스템, <http://nlplab.iptime.org:8886/>
4. 현대 자동차 자동차 법률 상담 시스템, <http://nlplab.iptime.org:8894/>
5. 딥러닝 기반의 패션 상품 유사 이미지 검색 모델, <http://nlplab.iptime.org:8854/>
6. 전통문화 개체명 인식기 개발 DEMO, http://nlplab.iptime.org:32280/ner_demo/index.html

❖ 강연

1. 현대자동차, "Bilingual Word Embedding", 2018. 이설화
2. KT, "Bilingual Word Embedding", 2018. 이설화
3. 현대자동차 Sequence Tagging (Named Entity Recognition) 튜토리얼
4. KT End-to-End Sentence Classification 튜토리얼

연구 실적 - 시제품 제작, 강연, 수상

❖ 수상

1. 국어정보처리 경진대회 (의존 구문 파서), 차다운, 이동엽, 임희석

❖ 국내포럼

1. Samsung AI Forum 2018, Character-Level Feature Extraction with Densely Connected Networks.