


LangCon 2021



# KLUE: Korean Language Understanding Evaluation

Upstage 문지형

## KLUE Paper Day

KLUE \_ Korean Language Understanding Evaluation

2021.06.01

<https://www.youtube.com/watch?v=0ySceOe7Rws>


- Introduction
- Source Corpora
- Tasks
- Language Models
- Ethical Considerations
- Discussion
- Leaderboard

# 이미 많은 내용이 (심지어 public하게) 공유되었다

Language  
Conference

페이퍼 소개를 또 하자니 중복  
컨텐츠 발표란 내 사전에  
없는데...

처음 공유하는 내용이면서도  
LangCon 취지에 맞고 유익한  
주제는 없을까...



Paper Day에서처럼 페이퍼  
소개를 한다고 하더라도 주어진  
발표 시간은 30분 밖에 없어서  
축박할 것 같다...

1. KLUE Overview
2. KLUE 구축 과정
  1. 태스크 선정 배경
  2. 널리 쓰이는 데이터를 위해
3. Baseline 코드 소개
4. KLUE Leaderboard
5. KLUE 이후의 데이터(에 대한 개인적인 바람)



# KLUE Overview

- 자연어 이해 (NLU) 모델의 평가
  - AI 가 사람의 언어를 얼마나 잘 이해하는지 평가하려면 다양한 과제에서 평가되어야 함
- 자연어 이해 (NLU) 모델 발전의 견인
  - 공정한 자연어 이해 (생성) 모델 비교의 토대
- 기존 한국어 데이터셋의 한계 극복



Name	Type	Format	Eval. Metric	# Classes	Train	Dev	Test	Source	Style
YNAT	문장 주제 분류	Single Sentence Classification	Macro F1	7	45k	9k	9k	뉴스(헤드라인)	문어체
KLUE-STS	문장 유사도	Sentence Pair Regression /Classification	Pearson's r F1	[0,5] 2	11k	0.5k	1k	뉴스, 리뷰, 스마트홈 쿼리	문어체, 구어체
KLUE-NLI	자연어 추론	Sentence Pair Classification	Accuracy	3	25k	3k	3k	뉴스, 리뷰, 위키피디아	문어체, 구어체
KLUE-NER	개체명 인식	Sequence Tagging	Entity-level Macro F1 Character-level Macro F1	6 12	21k	5k	5k	뉴스, 리뷰	문어체, 구어체
KLUE-RE	관계 추출	Single Sentence Classification	Micro F1 AUPRC	29 30	32k	8k	8k	뉴스, 위키피디아	문어체
KLUE-DP	의존 구문 분석	Sequence Tagging	UAC LAC	단어 수 38	10k	2k	2.5k	뉴스, 리뷰	문어체, 구어체
KLUE-MRC	기계 독해	Span Prediction	EM ROUGE-W	2	12k	8k	9k	뉴스, 위키피디아	문어체
WoS	대화 상태 추적	Slot-Value Prediction	JGA Slot Micro F1	(45)	8k	1k	1k	목적형 대화	구어체



# KLUE 구축 과정

LangCon 2021

- **Ranking Criteria**

- NLU 필수 태스크인가?
- 다른 Benchmark 와의 차별성이 있는가?
- 한국어만의 특성이 고려되어야 하는 태스크인가?
- 회사에서 관심있을 법한 태스크인가?
- 연구자에게 관심있을 법한 태스크인가?
- 문제 정의가 견고한가?
- 저작권 이슈가 없는가?
- 구축 난이도는 적당한가? (제한된 시간 내에 프로젝트에 참여한 인력으로 만들 수 있는가?)

# 어떤 태스크를 선정해야 할까?

Language  
Conference

Task	Task format	Ranking criteria								총점	투표인원	평점	
		NLU 필수 task	다른 benchmark 외의 차별성	한국어 특성 고려	industrial needs	academic needs	문제 정의의 solidity	License free	구축 난이도				
		3	2	1	2	2	0.5	0.5	1				
예시	예시									16	4	4.00	
Sem Dialogue State Tracking (Task Oriented Dialog)	지형, 지문									45.5	8	5.69	
Sem Paraphrase	sentence 1   sentence 2   class									31	7	4.43	
Sem Hatespeech Detection	single sentence   hate label (hate, offensive, none)									9.5	4	2.38	
Sem Speech Act Classification	sentence   speech act class									10	4	2.50	
Sem ASR error을 포함한 text의 SLU	sentence   class									24.5	7	3.50	
Sem Open Domain Dialogue Understanding										21	5	4.20	
Sem STS	sentence 1   sentence 2   score (0-5)									14.5	5	2.90	
Sem NLI	sentence 1   sentence 2   class (contradiction, entailment, neutral)									22.5	7	3.21	
Sem Event Detection	sentence   event class									8	3	2.67	
Sem 놀임말 classification	sentence   class									11	7	1.57	
Sem 사투리 classification	sentence   class									13	7	1.86	
Sem Relation Extraction	subject   object   relation   NE tagged single sentence									27	5	5.40	
Sem Intent classification	sentence   class									32	7	4.57	
Sem (Aspect) Sentiment Classification										32	7	4.57	
Sem Sarcasm Detection	sentence   binary class									19	6	3.17	
Sem News classification	sentence   class (news category)									1	2	0.50	
Sem Temporal QA										8	2	4.00	
Sem non-answerable question classification	passage   question   answer (yes/no/I don't know)									14	4	3.50	
Sem Machine Reading Comprehension	지형, 수식									34.5	6	5.75	
Sem Mathematical Reasoning	passage   question   answer									22	6	3.67	
Sem Common Sense QA	sentence 1   relation (cause, result)   multiple choice									27	6	4.50	
Sem extractive summarization										12.5	4	3.13	
Sy Slot filling										11	4	2.75	
Sy Word sense disambiguation										12	5	2.40	
Sy 형태분석(POS tagging)										20.5	5	4.10	
Sy 구문 분석(Dependency Parsing) + 형태분석 분석 결과 포함	Conll 형태 분석 결과와 구문 분석 결과 병기(sejong tags), 아래 예시는 영문 U	1 1 Many 2 won 3 silver 4 and 5 Sue 6 bronze	2 - 0 2 5 2	nssubj root obj cc conj orphan	2 0:root 2:obj E5.1:cc E5.1:subj 2:conj E5.1:dot						33	8	4.13
Sy 어휘의미 분석											8	4	2.00
Sem 상호참조 해결(Coreference resolution)											28	7	4.00
Sy 개체명 분석(NER, Named Entity Recognition)											33	8	4.13
Sy 의미역 분석(Semantic Role Labeling)											2.5	2	1.25
Sy 언어 수용성(Linguistic Acceptability)											10.5	4	2.63
Sy 무형 대용어 복원 (Anaphora resolution)											12	5	2.40

- Hate-speech Detection
- Sarcasm Detection
- SLU (Spoken Language Understanding)
- 높임말/사투리 Classification
- Extractive Summarization
- Temporal QA
- Mathematical Reasoning
- Common Sense QA
- Coreference Resolution
- 무형대용어 복원

...

# 선정된 8개 Task를 어떻게 잘 만들 수 있을까?

- 사용가능한 Source Corpora 탐색 및 수집

담당자	크롤링 완료	크롤링 우선순위	코퍼스
		1	연합뉴스 (뉴스제목)
(진행중)		1	위키트리 (본문)
O	1		wikipedia
O	1		정책브리핑
O	2		네이버 영화 리뷰
O	2		airbnb
O	3		위kipedia
		Generated	ParaKQC
		Generated	ToD
		O	리브레위키
		2	위키문헌
		O	위키책
		2	판결문
변환		2	공유마당 시
			뉴스페퍼민트 (뉴스기사)
			annotate / create
12/12(토)까지 위 코퍼스 크롤링. 화이팅!!!			태깅플랫폼
		3	국립국어원 표준국어대사전
		3	우리말샘
		3	국회 회의록
변환	999		카이스트 북 코퍼스
	999		UD corpus
	999		제타위키
	999		위키백과
	3		네이버 언예 뉴스 리뷰
	3		네이버 쇼핑 리뷰
	999		서울 열린데이터광장
	999		공유민료저작물
	999		공공누리
	999		K-QuAD
			Korean Contemporary Corpus of Written Sentences
		999	코로나 시국의 일기 데이터
		999	책/소설 등
변환	999		korean_parallel_data

- 선정된 태스크에 분배
    - 문어체와 구어체가 섞여있으면 좋은 태스크인가?
      - DP, NER, STS, NLI, RE, SSC
    - 구어체로 구축이 가능한 태스크인가?
      - DP, NER, STS, NLI

## ● 선정된 태스크에 분배

- 문어/구어 Corpora 중에 해당 태스크에 적합한 코퍼스는 무엇인가?
    - 네이버 영화 리뷰: 영화 도메인에 대한 텍스트이기 때문에 영화 감독, 영화명, 배우명 등 공인에 해당하는 인물명과 개체명이 많은 편 → NER
    - 위키트리: CC-BY-SA로 사용가능한 뉴스 코퍼스이지만 뉴스 컨텐츠 퀄리티 이슈가 존재 (click bait 등). 단 문장 단위로 분리하고 random sampling한 경우 문장 자체에 대한 이슈는 적음 → DP, NER, RE, NLI
    - 위키피디아: MRC를 제작하기 위해서는 문단 단위의 텍스트가 꼭 필요 (차별성을 위해 추후 뉴스 코퍼스 추가)

- 선정된 태스크에 분배
    - 수집한 코퍼스의 수량
      - 위키트리: 양이 많았기 때문에 많은 태스크에서 사용 가능
      - 위키피디아/정책브리핑: 퀄리티 대비 양이 적어서 꼭 필요한 태스크에 우선 분배
    - General Domain 에 적합한가?
      - 판결문 X

다다익선

다다익선

충분한 시간과 자금과 사람이 있다면...

# 태스크에 적합한 데이터 수량은 어느 정도인가?

Language  
Conference

- 각 태스크에서 가장 작은 단위의 데이터를 구축할 때 드는 금액은 어느 정도인가?
  - (POS) + DP: ~~겁나~~ 비쌈
- 데이터 구축을 위해 사용가능한 금액은 얼마인가?
- 각 태스크에서 가장 작은 단위의 데이터를 구축할 때 드는 시간은 어느 정도인가?
  - MRC: 요구 조건이 빽세서 은근히 오래 걸림. 지문 독해도 필요
- 데이터 구축에 쓸 수 있는 시간은 어느 정도인가?
- 모델이 태스크를 풀기 위해 필요한 최소 수량은 어느 정도인가?
  - 모델 성능이 안 나오는 이유가 데이터 부족이 아니길

- **YNAT**
  - 본문을 보고 판단되는 predefined 뉴스 카테고리의 매칭 오류를 최소화
- **STS**
  - STS-b 의 구축방식을 최대한 Follow
  - 두 문장이 자연스러운 문장일 때 의미적으로 유사한 문장쌍과 그렇지 않은 문장쌍 pair를 자동으로 매칭시켜서 구축 시간을 단축하고 퀄리티를 향상
- **NLI**
  - 알려진 annotation artifact를 최소화하여 구축하는 것
- **NER/DP**
  - 첫 구어 데이터셋 (Source Corpora 선정에서 만족)
- **RE**
  - 충분한 수량의 데이터셋
    - Distant Supervision 및 NER 모델 사용

- MRC
  - 이미 공개된 한국어 MRC 데이터셋에서 다루지 않았던 질문 유형 추가
  - 알려진 annotation artifact를 최소화하여 구축하는 것
    - 첫 문장에 정답이 있는 경우가 많음
    - multi-hop question 일지라도 한 문장만 보고도 맞출 수 있는 질문인 경우가 많음

- WoS
  - WoZ Setting에서 알려진 구축 방식의 한계를 극복한 방식으로 구축하는 것
    - Self-Dialog: 비용 감축
    - Dropdown menu: 여러 발생 최소화

- 가이드라인의 모호함을 최대한 제거
  - 여러 번의 iteration
- 꼼꼼한 검수
- 제작자의 의도를 명료하게 전달
- 전문 지식이 필요한 경우 annotator 훈련을 충분히 시도




Figure 1: The initial pool of crowdworkers are randomly assigned to one of four protocols and the datasets are collected in parallel.

- 모델이 배워야하는 pattern을 제대로 학습해야 Test 성능이 오를 수 있도록 분리
  - NER: 특정 단어와 label을 연관짓는 모델 X → 문맥 속에서 단어의 entity를 판단하는 모델 O
  - NLI: 가설 문장만 보고 label을 연관짓는 모델 X → 가설 문장과 전체 문장 모두를 보고 그 둘의 관계를 추론하는 모델 O
  - RE: 일반적인 상황에서는 no\_relation 이 많기 때문에 전체 데이터에서 random sampling 하여 추출한 문장들로 test set 구성

- 태스크와 데이터, 그리고 모델 특성의 측면을 다각도로 고려
  - NER
    - entity-level macro F1: Tokenization 의 성능에 따라 점수가 크게 차이가 나는 metric
    - character-level macro F1: Tokenization 성능의 영향을 적게 받는 metric
  - MRC
    - EM: Tokenization 의 성능에 따라 점수가 크게 차이가 나는 metric
    - ROUGE-W:
      - 1) Tokenization 성능의 영향을 적게 받는 metric
      - 2) 우연히 character가 겹치는 단어를 정답으로 잡은 경우에 대해 과도하게 점수를 많이 주지 않는 metric  
(한국의 위인들 / 국한된 범위)
  - DP
    - macro F1: class imbalance 가 심하기 때문



# Baseline 코드 소개

<https://github.com/KLUE-benchmark/KLUE-baseline>



# KLUE Leaderboard

LangCon 2021

# KLUE Leaderboard

Language  
Conference

<https://klue-benchmark.com/>

- Individual Tasks > YNAT > Data > Download Baseline Code > 수정 > 압축 > 제출

The screenshot shows the YNAT competition interface with the 'Data' tab selected. On the left, there's a sidebar with 'Data Download' and several download links:

- Download Baseline Code Link**  
[https://aistages-prod-server-public.s3.amazonaws.com/app/Competitions/000065/data/klue\\_code.tar.gz](https://aistages-prod-server-public.s3.amazonaws.com/app/Competitions/000065/data/klue_code.tar.gz)
- Download Data Link\_KLUE-TC (a.k.a. YNAT)**  
<https://aistages-prod-server-public.s3.amazonaws.com/app/Competitions/000066/data/ynat-v1.tar.gz>
- Download Data Link\_KLUE-STS**  
<https://aistages-prod-server-public.s3.amazonaws.com/app/Competitions/000067/data/klue-sts-v1.tar.gz>
- Download Data Link\_KLUE-NLI**  
<https://aistages-prod-server-public.s3.amazonaws.com/app/Competitions/000068/data/klue-nli-v1.tar.gz>
- Download Data Link\_KLUE-NER**  
<https://aistages-prod-server-public.s3.amazonaws.com/app/Competitions/000069/data/klue-ner-v1.tar.gz>

The screenshot shows a file explorer window displaying the contents of the 'ynat\_code' folder. The folder structure and files are as follows:

Name	Date Modified	Size	Kind
dataloader.py	Jun 25, 2021 11:41 AM	2 KB	Python script
dataset.py	Jun 25, 2021 11:41 AM	511 bytes	Python script
inference.py	Today 11:17 PM	4 KB	Python script
model	Today 10:59 PM	--	Folder
model.py	Jun 25, 2021 11:41 AM	Zero bytes	Python script
requirements.txt	Jun 28, 2021 9:42 AM	89 bytes	Plain Text
utils.py	Jun 25, 2021 11:41 AM	99 bytes	Python script

- Individual Tasks > YNAT > Data > Download Baseline Code > 수정 > 압축 > 제출

**\_uploaded File**

Model Name: My model

Model License: Apache-2.0

Description (Optional): Test code for YNAT

Hyperparameter (Optional):

Key	Value
batch_size	32
learning_rate	0.0001
warmup_ratio	0.1
training_epochs	1
input	input

**New Submission**

Click to find your submission file  
File should be tar.gz

Model Name: My model

Model License: Apache-2.0

Description (Optional): Test code for YNAT

Hyperparameter (Optional):

Key	Value
batch_size	32
learning_rate	0.0001
warmup_ratio	0.1
training_epochs	1
input	input

Uploading... 24%

**Notification**

Submission Success

CONFIRM

- Individual Tasks > YNAT > Data > Download Baseline Code > 수정 > 압축 > 제출

Phase	State	Hyperparameters	JobName	Created_at	Job Log
Inference	Pending	More	In/C66/U337/3	2021-08-02 23:19	More
Rows per page: 5 ▾ 1-1 of 1 < >					
<a href="#">In/C66/U337/3</a>					
<pre> bash: cannot set terminal process group (-1): Inappropriate ioctl for device bash: no job control in this shell 2021-08-02 14:24:09,569 sagemaker-training-toolkit INFO Imported framework sagemaker_pytorch_container.training 2021-08-02 14:24:09,595 sagemaker_pytorch_container.training INFO Block until all host DNS lookups succeed. 2021-08-02 14:24:15,833 sagemaker_pytorch_container.training INFO Invoking user training script. 2021-08-02 14:24:19,545 sagemaker-training-toolkit INFO Invoking user script  Training Env: {     "additional_framework_parameters": {},     "channel_input_dirs": {         "eval": "/opt/ml/input/data/eval",         "model": "/opt/ml/input/data/model"     },     "current_host": "algo-1",     "framework_module": "sagemaker_pytorch_container.training:main",     "hosts": [         "algo-1"     ],     "hyperparameters": {},     "input_config_dir": "/opt/ml/input" } </pre>					

T - 6						
Phase	State	Hyperparameters	JobName	Created_at	Job Log	
Inference	Done	More	In/C66/U337/6	2021-08-03 12:05	More	
Evaluation	Done	More	Ev/C66/U337/6	2021-08-03 12:11	More	
Rows per page: 5 ▾ 1-2 of 2 < >						
<a href="#">Overview</a> <a href="#">Submission</a> <a href="#">My Record</a> <a href="#">Leaderboard</a> <a href="#">Discussion</a>						
Task Record						
Submission ID	Result	F1	Model	Description	Hyperparameters	Final Submission
TC - 6	{"F1": 85.71}	85.71	YNAT test	More	More	Select <input type="checkbox"/>
Rows per page: 5 ▾ 1-1 of 1 < >						



# KLUE 이후의 데이터(에 대한 개인적인 바람)

- 데이터에 대한 모델 점수의 향상이 곧 모델의 성능 향상으로 이어지는 데이터
- Baseline 모델의 점수가 낮아서 점수 향상의 여유가 있는 데이터
- 문제에 대한 접근 방식에 대해 다르게 생각해보게 해주는 데이터
  - e.g., social bias inference
- static benchmark vs. dynamic benchmark

## Dynabench: Rethinking Benchmarking in NLP

Douwe Kiela<sup>†</sup>, Max Bartolo<sup>‡</sup>, Yixin Nie<sup>\*</sup>, Divyansh Kaushik<sup>§</sup>, Atticus Geiger<sup>¶</sup>,

Zhengxuan Wu<sup>¶</sup>, Bertie Vidgen<sup>||</sup>, Grusha Prasad<sup>\*\*</sup>, Amanpreet Singh<sup>†</sup>, Pratik Ringshia<sup>†</sup>,


Zhiyi Ma<sup>†</sup>, Tristan Thrush<sup>†</sup>, Sebastian Riedel<sup>††</sup>, Zeerak Waseem<sup>††</sup>, Pontus Stenetorp<sup>†</sup>,

Robin Jia<sup>†</sup>, Mohit Bansal<sup>\*</sup>, Christopher Potts<sup>¶</sup> and Adina Williams<sup>†</sup>


<sup>†</sup> Facebook AI Research; <sup>‡</sup> UCL; <sup>\*</sup> UNC Chapel Hill; <sup>§</sup> CMU; <sup>¶</sup> Stanford University

<sup>||</sup> Alan Turing Institute; <sup>\*\*</sup> JHU; <sup>††</sup> Simon Fraser University


dynabench@fb.com




LangCon 2021



# Thank you!



LangCon 2021



# Any questions?