

영한 번역투 완화

그것 팀 되다 (NLP)
강현구, 박경원, 김민규,
정유민, 심현보

What is Translationese?

최근 LLM의 발전으로 고품질 기계 번역이 가능해졌지만, 여전히 번역투(translationese) 문제는 해결되지 않은 채 남아 있음.

번역투란

외국어 문장 구조나 표현이 그대로 옮겨져 자연스럽지 않은 문장을 의미
한국어 번역문에서 영어 어순, 표현이 그대로 반영된
어색한 문장들이 자주 발생함.

목표

“번역투” 문장을 자연스러운 한국어 스타일로 변환하는
Style Transfer Model을 구축하고자 함.

영어식 표현	설명
-에 의하여	어떤 이가 행한 행위의 뜻으로 쓴 영문을 잘못 번역한 표현을 모방 - 예시: 외부 요인 에 의해
-부터(로부터, 으로부터)	출처 또는 기원을 나타내는 전치사 from구를 직역한 표현 - 예시: 발신자 로부터
-쓰던, -았(었)던, -였던	영어의 과거완료형을 흉내낸 말 - 예시: 콘솔에서 발급받 았던
가진다, 갖는다	have 또는 take를 직역투로 번역한 표현 - 예시: 특징을 가집니다
-어(아)진다	사물이 주어인 수동태 문장을 우리말로 직역한 번역 투 표현 - 예시: 나누 어진다
-들	영어의 명사 복수형을 그대로 번역한 표현 - 예시: 다양한 기능 들 * 국어에서는 명사 그 자체를 복수라고 분명히 드러내야 할 때가 아니면 복수형을 쓰지 않음
-에 관한, -에 대한	‘about’을 대한, 대하여, 관해, 관하여 등으로 번역하여 일반 문장에서 그대로 고착된 표현 - 예시: 필수 여부 에 대해

어드벤처타임

BEST 정말 웃겨서 살 수가 없습니다. 맵소사, 이와 같은 드립은 어디서 오는 것입니까? 혹여 가보로 내려옵니까? 나의 공중제비를 멈추게 하십시오! 당신과 같은 사람들 때문에 삶이 굉장히 재미있습니다. 그러한 드립은 비밀리에 보관하지 말고, 재빨리 내용물을 꺼내주십시오. 세상에 이런 드립이 다 있겠습니까? 드립학원의 연줄이 평균 이상입니까? 완전한 드립머신이 틀림 없습니다. 두부, 흥부, 형부 모두 파열시키고 말았습니다. 나의 배꼽을 보상해 내십시오! 이것은 살인 드립입니다! 호흠이 곤란합니다! 제발 목숨을 살려주십시오!

2019-07-03 10:27 신고

👍 1407

👎 60

Text Style Transfer

문장의 내용은 유지하면서 표현 방식 (스타일)만 바꾸는 자연어 처리 기술

	Source Style	Target Style
Impolite → Polite:	Shut up! the video is starting!	Please be quiet , the video will begin shortly.
Negative → Positive:	The food is tasteless .	The food is delicious .
Informal → Formal:	The kid is freaking out .	That child is distressed .

Table 1: TST examples regarding sentiment, polarity, and formality.

(예시)

Translationese
→ **Natural**

번역투에 관한 연구를 통해 이 발표 자료는 우리 팀에 의해 제작되었다.
우리 팀은 번역투를 연구하여 이 발표 자료를 제작하였다.

Solution & Model Choice

	Source	Target
Ex. 1		
Ex. 2		
Ex. 3		
Ex. 4		

Parallel Data

Source	Target
	

Non-parallel Data


Parallel data: 한국어 문장과 같은 의미의 번역투 한국어 문장이 동시에 존재하는 데이터 세팅

하지만 **한영 번역투는 No parallel data!!!**

→ pseudo-parallel dataset 제작해 parallel data에서 적용 가능한 학습 기법을 사용!

Solution & Model Choice

(pseudo-parallel data)




CE Loss

$$L_{sup} = - \sum_{j=1}^N \sum_{i=1}^V Y_i^j \log(\mathbf{H}_i^j)$$

Dataset

Main Goal: 어떻게 번역투 (translationese)가 포함된 데이터 셋을 구현할 수 있을 것인가?

Back Translation 기법을 사용하자!



100만행을 추려 CSV형태로 재가공한 Hugging face의 데이터셋

AI-Hub에 등재되어있는 영-한 병렬 데이터



meta의 NLLB-200을 사용하여 번역품질이 떨어지는 Translationese(번역투) column을 형성!



Translationese

당연하다, 그것은 가능하다, 하지만 나는 증명사진이 필요합니다.


Search this dataset	
ko string · lengths  2→262 97.8%	en string · lengths  2→502 97.4%
들을 조사하여 그것의 내용과 특징을 검토하려고 한다.	prior research on the size of cities conducted in...
박 회장은 기업들이 심사 이전 단계부터 사업을 벌일 수 있게 보완하거나, 여러 부처에 걸친 복합 사업 모델도 신속...	Chairman Park suggested that companies should be able to do business from the pre-screening stage...
당연히 가능하죠, 그런데 증명사진이 필요합니다.	Of course, it's possible, but I need an ID photo.

※ Translationese 데이터를 구축하는 과정에서 사용된 두 가지 모델



NLLB – No Language Left Behind

Meta에서 개발한 **초대형 다국어 번역 모델**로,
총 200개 이상의 언어를 상호 간에 번역할 수 있도록 설계됨
(NLLB-200 Distilled 600M 사용)



데이터 필터링 과정

1. ko행과 translationese 사이의 BERTScore F1 값이 0.9 이상인 행만 유지,
의미가 보존된 행만을 남기고자 함
2. 한글, 알파벳, 특수문자, 공백, 숫자를 제외한 다른 문자를 포함한 행을 삭제


번역투는 잘 드러나지만 **너무 많은 행이 삭제**되는 문제가 발생

EN	KO	Translationese
After the each mission, we will make a very bitter penalty juice that is good for the body but not tasty for the mouth.	저희가 매 미션이 끝나면 몸에는 좋지만 입에는 아주 쓴 벌칙 주스를 만들 건데요.	각 임무 후에 우리는 매우 쓴 벌금주스를 만들 것입니다. 그것은 몸에 좋지만 입에 맛이 없습니다.

NLLB를 한국어 데이터로 파인 튜닝한
NLLB-Finetuned-en2ko 모델을 사용하여
Translationese 데이터를 추가적으로 생성

도합 **50만행 정도의 KO – Translationese pseudo-parallel data** 형성

Solution & Model Choice



Evaluation Metric

A successful style-transferred output not only needs to demonstrate the correct target style; but also, due to the uncontrollability of neural networks, we need to verify that it preserves the original semantics, and maintains natural language fluency. Therefore, the commonly used practice of evaluation considers the following three criteria: (1) transferred style strength, (2) semantic preservation, and (3) fluency.

즉, 성공적인 Text Style Transfer (번역투 완화)는
한국어 원문의 1) 스타일을 지키면서, 2) 의미를 보존해야 하며 3) 유창 (문장 구성)해야 함!

Table 4

Overview of evaluation methods for each criterion.

Criterion	Automatic Evaluation	Human Evaluation
Overall	BLEU with gold references	Rating or ranking
- Transferred Style Strength	Accuracy by a separately trained style classifier	Rating or ranking
- Semantic Preservation	BLEU/ROUGE/etc. with (modified) inputs	Rating or ranking
- Fluency	Perplexity by a separately trained language model	Rating or ranking

적용

의미: **BERTScore**

유창성: **Perplexity, TTR**

각 메트릭 평가 시 참고 지표.

Evaluation Metric

Quantitative

BERTScore: ((Ko)BERT 기준) 의미를 얼마나 보존하는지

- 1) 높은 BERTScore: 번역투와 완화 텍스트 간의 의미가 같음
- 2) Dataset Filtering 단계에서도 사용
: 생성 번역투 텍스트의 품질이 낮다면 BERTScore가 낮을 것.

Perplexity: 학습 데이터에 비해 얼마나 어색한지

주어진 정답 텍스트를 얼마나 '확실하게' 예측하는지를 다루는 불확실성과 관련된 지표

높은 Perplexity: 번역투 텍스트에 가깝게 번역할 수록 그 차이가 크게 나타나 얻을 수 있는 수치로 예상됨

Qualitative

Type-Token Ratio (TTR): 전체 단어 수 대비 어휘 다양성

어휘력에 대한 간접지표로, 사용한 어휘의 다양성을 다룸

번역투의 경우: 모든 문장 내 동일/유사 단어의 번역에 대해 일관된 해석을 내놓으므로 낮을 것으로 예상됨

다만, 영한 번역투 유형에 따라 TTR이 높아질 수도, 낮아질 수도 있음

※ 영한 번역투 타입별 예상 평가 지표 변화 추이

번역투 타입	BERTScore	Perplexity	TTR
직역	↔ (의미 보존)	↑	↔/↑
대명사			
- 대명사 남발	↔	↑	↓
- “우리” 일반화	↔	↑	↓
- “~의 그것”	↔/↓ (어색)	↑	↓
영문법식 문장부호 사용	↔	↑	↔
불필요한 구문 직역			
- 문장 사이 표현	↔	↑	↓
- 강조용 표현	↔	↑	↓
- “You know” 직역	↔	↑	↓
피동 표현	↔	↑	↔
시제			
- 현재진행형 과다	↔	↑	↓
- “~할 것이다” 직역	↔	↑/↔	↔
A, B 그리고/또는 C	↔	↑	↔
아무도 ~하지 않는다	↔	↑	↔
만약 ~다면	↔	↑	↓

가설: 번역투에 가까울수록 Perplexity가 높고, TTR이 낮을 것이다. 또한 스타일에 관계없이 BERTScore는 높아야 한다.


(그러나, TTR은 일부 케이스(패러프레이징 / 동의어 과다 치환 / 직역)에서 일시적으로 높아질 수 있어, MATTR (Moving Average TTR)로 대체)

수치적 결과

YAICON 6th
영한 번역투 완화

Quantitative Results

KE-T5-base



5 epoch까지는 안정적으로 감소하는 양상을 보이고 있음



2 epoch을 추가한 경우 전체적으로 감소하나 진동하는 모습을 보임

Quantitative Results

mt5-base

Epoch	Training Loss	Validation Loss
1	1.966100	1.740007
2	1.904100	1.688509
3	1.870100	1.653518
4	1.809600	1.634902
5	1.801200	1.627118

mt5-small

Epoch	Training Loss	Validation Loss
1	2.303300	1.908256
2	2.118600	1.809754
3	2.058400	1.779874

Quantitative Results

KE-T5-base

KoBERT-score

```
# ko vs. mitigated
similarities = get_similarity_batch(reference_texts, mitigated_texts)
```

```
print(f"KoBERT avg similarity: {np.mean(similarities):.4f}")
print(f"KoBERT max similarity: {np.max(similarities):.4f}")
print(f"KoBERT min similarity: {np.min(similarities):.4f}")
```

```
KoBERT avg similarity: 0.8123
KoBERT max similarity: 0.9786
KoBERT min similarity: 0.4497
```

```
# ko vs. translated_ko
similarities = get_similarity_batch(test_dataset_sample['ko'], test_dataset_sample['ko_translationese'])
```

```
print(f"KoBERT avg similarity: {np.mean(similarities):.4f}")
print(f"KoBERT max similarity: {np.max(similarities):.4f}")
print(f"KoBERT min similarity: {np.min(similarities):.4f}")
```

```
KoBERT avg similarity: 0.8696
KoBERT max similarity: 1.0000
KoBERT min similarity: 0.5580
```

가설: 스타일에 무관하게 유지되어야 한다.
결과: 값이 소폭 상승하였으나,
비슷한 수준을 보이고 있다.

Quantitative Results

mt5-base

Kobertscore F1
0.768200
0.833900
0.835800
0.835600
0.835900

mt5-small

Kobertscore F1
0.743600
0.750500
0.751300

두 모델의 경우에도 KoBERTScore 자체는
유지되어야 할 것으로 기대되나,

epoch에 따라 상승하는 양상을 보여주고 있음.

Quantitative Results

Perplexity

KE-T5-base

mt5-base

mt5-small

```
# ko vs. mitigated
import math
if "eval_loss" in final_metrics:
    ppl = math.exp(final_metrics["eval_loss"])
    print(f"Perplexity: {ppl:.4f}")
```

Perplexity: 1.3640

Perplexity

11.885900

10.045200

9.758100

9.722900

9.569600

Perplexity

15.181800

13.199600

12.842000

KE-T5-base 모델의 perplexity가 가장 낮게 나온 것으로 보아
번역투가 가장 완화된 결과를 보여줄 것으로 예상해볼 수 있음

Quantitative Results

MATTR

Average MATTR of Translationese Texts: 0.9941

MATTR이 모두 소폭 상승한 것으로 보아
모든 모델에서 번역투 완화가 성공적으로
이루어질 것을 예측해 볼 수 있음

KE-T5-base

mt5-base

mt5-small

```
total_mattr_mitigated = 0
for sent in generated_texts:
    total_mattr_mitigated += mattr(sent, window_size=50)

average_mattr_mitigated = total_mattr_mitigated / len(generated_texts)
print(f"Average MATTR of Mitigated Texts: {average_mattr_mitigated:.4f}")
```

Average MATTR of Mitigated Texts: 0.9977

Mattr

0.996600

0.996000

0.995800

0.996100

0.996000

Mattr

0.996700

0.996700

0.996600

정성적 결과 비교

YAICON 6th
영한 번역투 완화

Qualitative Results

KE-T5-base

예시
번역투 문장: 고모는 두 명을 아들을 가지고 있다.
완화된 문장: 고모는 두 아들을 두고 있습니다.

예시
번역투 문장: 그 아이들은 보육원에 의해 보호되었다.
완화된 문장: 아이들이 보육원 내에서 보호를 받았다.

예시
번역투 문장: 학생들은 공부함에 있어서 불편함이 없었다.
완화된 문장: 학생들은 공부하는 데 불편이 없었다.

예시
번역투 문장: 다음 물음에 대해 답하십시오.
완화된 문장: 다음 질문에 답해주세요.

예시
번역투 문장: 성공하기 위해서는 열심히 노력하지 않으면 안 된다.
완화된 문장: 성공하기 위해서는 노력을 다해야 합니다.

mt5-base

입력 5: 고모는 두 명을 아들을 가지고 있다.
완화 5: 고모는 두 명의 아들을 가지고 있습니다.

입력 2: 그 아이들은 보육원에 의해 보호되었다.
완화 2: 그 아이들은 보육원에 의해 보호되었습니다.

입력 7: 학생들은 공부함에 있어서 불편함이 없었다.
완화 7: 학생들은 공부하기에 불편함이 없었습니다.

입력 4: 다음 물음에 대해 답하십시오.
완화 4: 다음 물음에 대해 회신해 주십시오.

입력 8: 성공하기 위해서는 열심히 노력하지 않으면 안 된다.
완화 8: 성공하기 위해서는 열심히 노력하지 않으면 안 됩니다.

mt5-small

입력 5: 고모는 두 명을 아들을 가지고 있다.
완화 5: 고모는 두 명의 아들을 가지고 있습니다.

입력 2: 그 아이들은 보육원에 의해 보호되었다.
완화 2: 그 아이들은 보육원에 의해 보호되었습니다.

입력 7: 학생들은 공부함에 있어서 불편함이 없었다.
완화 7: 학생들은 공부함에 있어서 불편함이 없었습니다.

입력 4: 다음 물음에 대해 답하십시오.
완화 4: 다음 물음에 대해 답변해 주십시오.

입력 8: 성공하기 위해서는 열심히 노력하지 않으면 안 된다.
완화 8: 성공하기 위해서는 열심히 노력하지 않으면 안 됩니다.

핵심 문장: 고모는 두 명을 아들을 가지고 있다.

KE-T5-base가 가장 자연스러운 한국어 표현을 나타내고 있음을 확인할 수 있음

근거 1. 두 명을 아들을 → 두 아들을 (목적어 오번역 및 지나친 수식어 해소)

근거 2. 가지고 있다 → 두고 있습니다 (have에서 비롯된 표현 완화)

Qualitative Results

KE-T5-base

번역투 문장: 그들은 그들의 친구들과 함께 시간을 보내는 것을 즐긴다.
완화된 문장: 그들이 친구와 함께 시간 보내는 것을 즐겨요.

번역투 문장: 그는 내 말에 동의하지 않는 것처럼 보였다.
완화된 문장: 그가 자신의 발언에 동의하지 않은 것처럼 보이네요.

mt5-base

입력 2: 그들은 그들의 친구들과 함께 시간을 보내는 것을 즐긴다.
완화 2: 그들은 친구들과 함께 시간을 보내는 것을 즐깁니다.

입력 10: 그는 내 말에 동의하지 않는 것처럼 보였다.
완화 10: 그는 내 말에 동의하지 않는 것처럼 보였습니다.

mt5-small

입력 2: 그들은 그들의 친구들과 함께 시간을 보내는 것을 즐긴다.
완화 2: 그들은 친구들과 함께 시간을 보내는 것을 즐깁니다.

입력 10: 그는 내 말에 동의하지 않는 것처럼 보였다.
완화 10: 그는 내 말에 동의하지 않는 것처럼 보였습니다.

단, KE-T5-base가 가장 자연스러운 어투를 구사하는 동시에 의미가 바뀌어버린 문장이 포함되어 있음

예) 결과: 그가 자신의 발언에 동의하지 않는 것처럼 보이네요.
원래 의도: 그가 나의 발언에 동의하지 않는 것 같네요.
→ 발언의 주체가 와전

반면, mt5-base와 mt5-small은 전반적으로 비슷한 결과를 보이고 있으며,
여전히 직역한 말투를 담고 있지만 의미가 와전된 문장은 없는 것으로 보임.

Qualitative Results

UV 보호 기능을 가지고 있습니다. 400nm 까지의 모든 유해한 파란색 빛을 100% 필터링합니다.
하지만 착용하기에 매우 편리합니다.

KE-T5-base

UV 보호 기능이 있어 400nm의 모든 유해한 파란색 빛을 100% 필터링하지만 착용하기 매우 편리합니다.

→ ~~까지의 의미가 ~~의로 오역됨

mt5-base

입력: UV 보호 기능을 가지고 있습니다. 400nm까지의 모든 유해한 파란색 빛을 100% 필터링합니다. 하지만 착용하기에 매우 편리합니다.
출력: 모든 유해한 파란색 빛을 100% 필터링하여 착용하기에 매우 편리합니다.

→ 파장과 관련된 중요 정보가 소실됨

mt5-small

입력: UV 보호 기능을 가지고 있습니다. 400nm까지의 모든 유해한 파란색 빛을 100% 필터링합니다. 하지만 착용하기에 매우 편리합니다.
출력: UV 보호 기능은 400nm까지의 모든 유해한 파란색 빛을 100% 필터링하고 착용하기에 매우 편리합니다.

→ 보호기능이 있다는 의미가 보호 기능 자체에 대한 설명으로 바뀜

한계점과 제언

YAICON 6th
영한 번역투 완화


Limitations

1. 원문 데이터 자체에 만연한 번역투 (대부분의 인식 차원)
2. NLLB-Finetuned-en2ko의 경우 너무 좋은 성능으로 결과 자체에 번역투 미포함 다수 존재
3. 번역투의 특징을 추출하기에는 불충분한 데이터셋 크기 (~ 473K)
 - Data augmentation을 활용한 Representation Learning 가능성
4. CE Loss만으로는 구별하기 어려운 번역투 - 자연스러운 번역 문장 간 미세한 차이
 - 추가 loss 도입을 통한 발전된 style transfer를 유도


Future Work

1. Data augmentation


(a)



(b)



2. 추가 Loss 도입: classifier-guided loss, reconstruction loss, cycle loss



Text Style Transfer를 통한 영어의 Formality를 바꾸는 연구로,
Loss 추가 고려 가능!

감사합니다!

그것팀되다 일동

제 발표를 끝까지 청취해 주신 여러분, 이 얼마나 황송하고도 감개무량한 일입니까?
내 심장이 과열되어 고마움이 증기처럼 분출되고 있습니다! 나의 감격의 눈물을 수습해 주십시오!
진심으로, 전자파를 넘는 감사를 송출합니다. 당신의 은혜, 압도적으로 과다합니다!
저의 진동하는 성대를 당신의 고막에 관통시켜 주신 그 은혜, 평생 잊지 않겠습니다! 이 감사를 어디에 표현해야 합니까?
전자 기기로는 부족합니다! 직접 공중제비로 전하러 가겠습니다!

2019-07-03 10:27 | 신고

 1407

 60