

# 単語属性変換で作成した 疑似負例データを用いた 自動機械翻訳評価

○ 高橋洸丞 (NAIST)  
石橋陽一 (NAIST)  
須藤克仁 (NAIST/JST)  
中村哲 (NAIST)

# BERT [Devlin +, 2018.] を用いた自動評価手法

機械翻訳の共有タスク WMT2018/2020で  
人手評価との高い相関を記録した評価手法

- **BLEURT** [Sellam +, BLEURT: Learning robust metrics for text generation, ACL 2020. ]
- **C-SPEC** [Takahashi +, Automatic machine translation evaluation using source language inputs and cross-lingual language model, ACL 2020. ]
- **COMET** [Rei +, COMET: A neural framework for MT evaluation, EMNLP 2020. ]

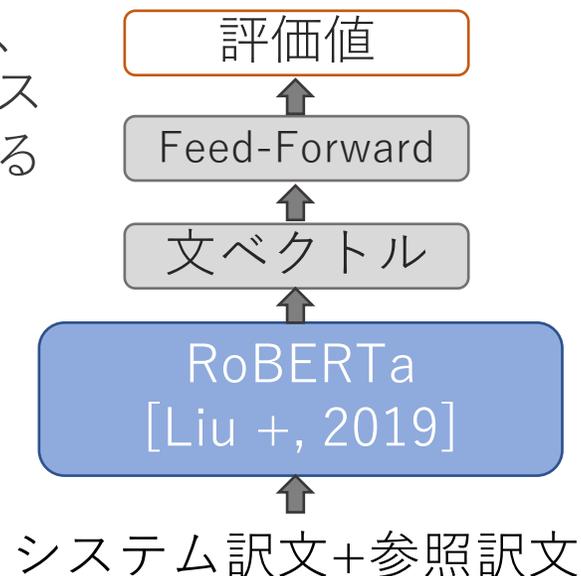
人手評価付きのデータでfine-tuningする必要がある

ノンパラメトリックな手法(BLEU[Papineni+, 2002.]やBERTscore[Zhang +, 2019.] )  
よりも人手評価との相関が高い

# BLEURT・C-SPECの違い

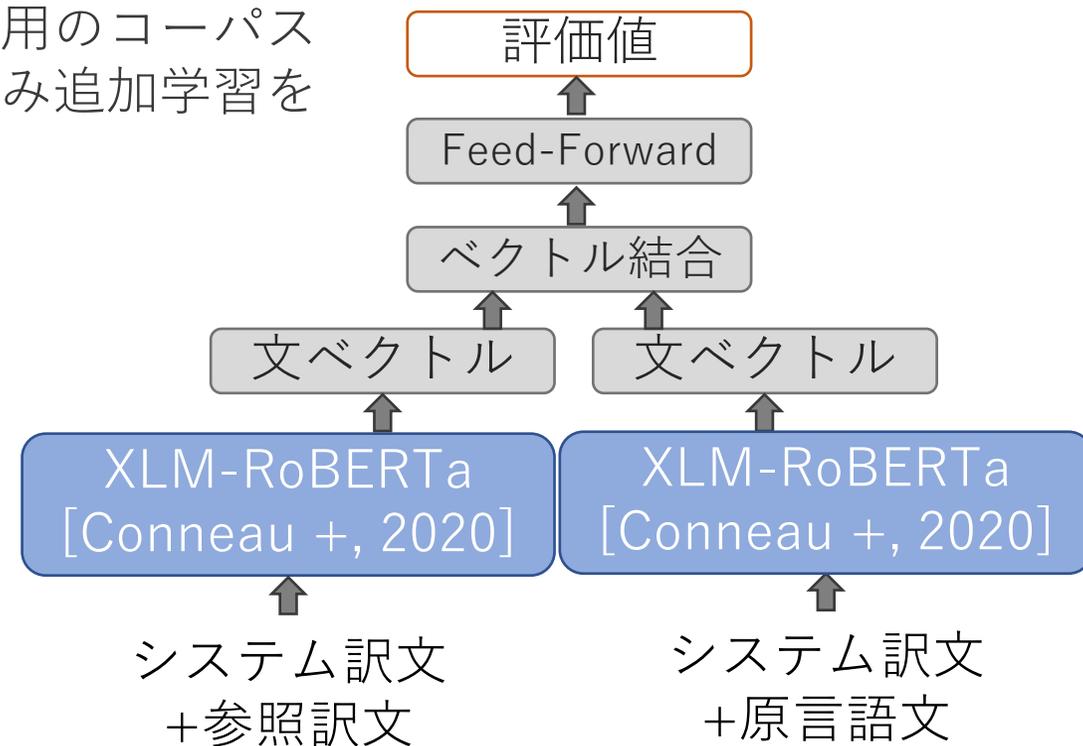
## BLEURT

様々な正負の生成データで学習後、評価用のコーパスで追加学習をする



## C-SPEC

評価用のコーパスでのみ追加学習をする



# BLEURT・C-SPECの評価誤り

WMT17のmetrics shared taskでピアソンの相関係数を大きく低下させた文例

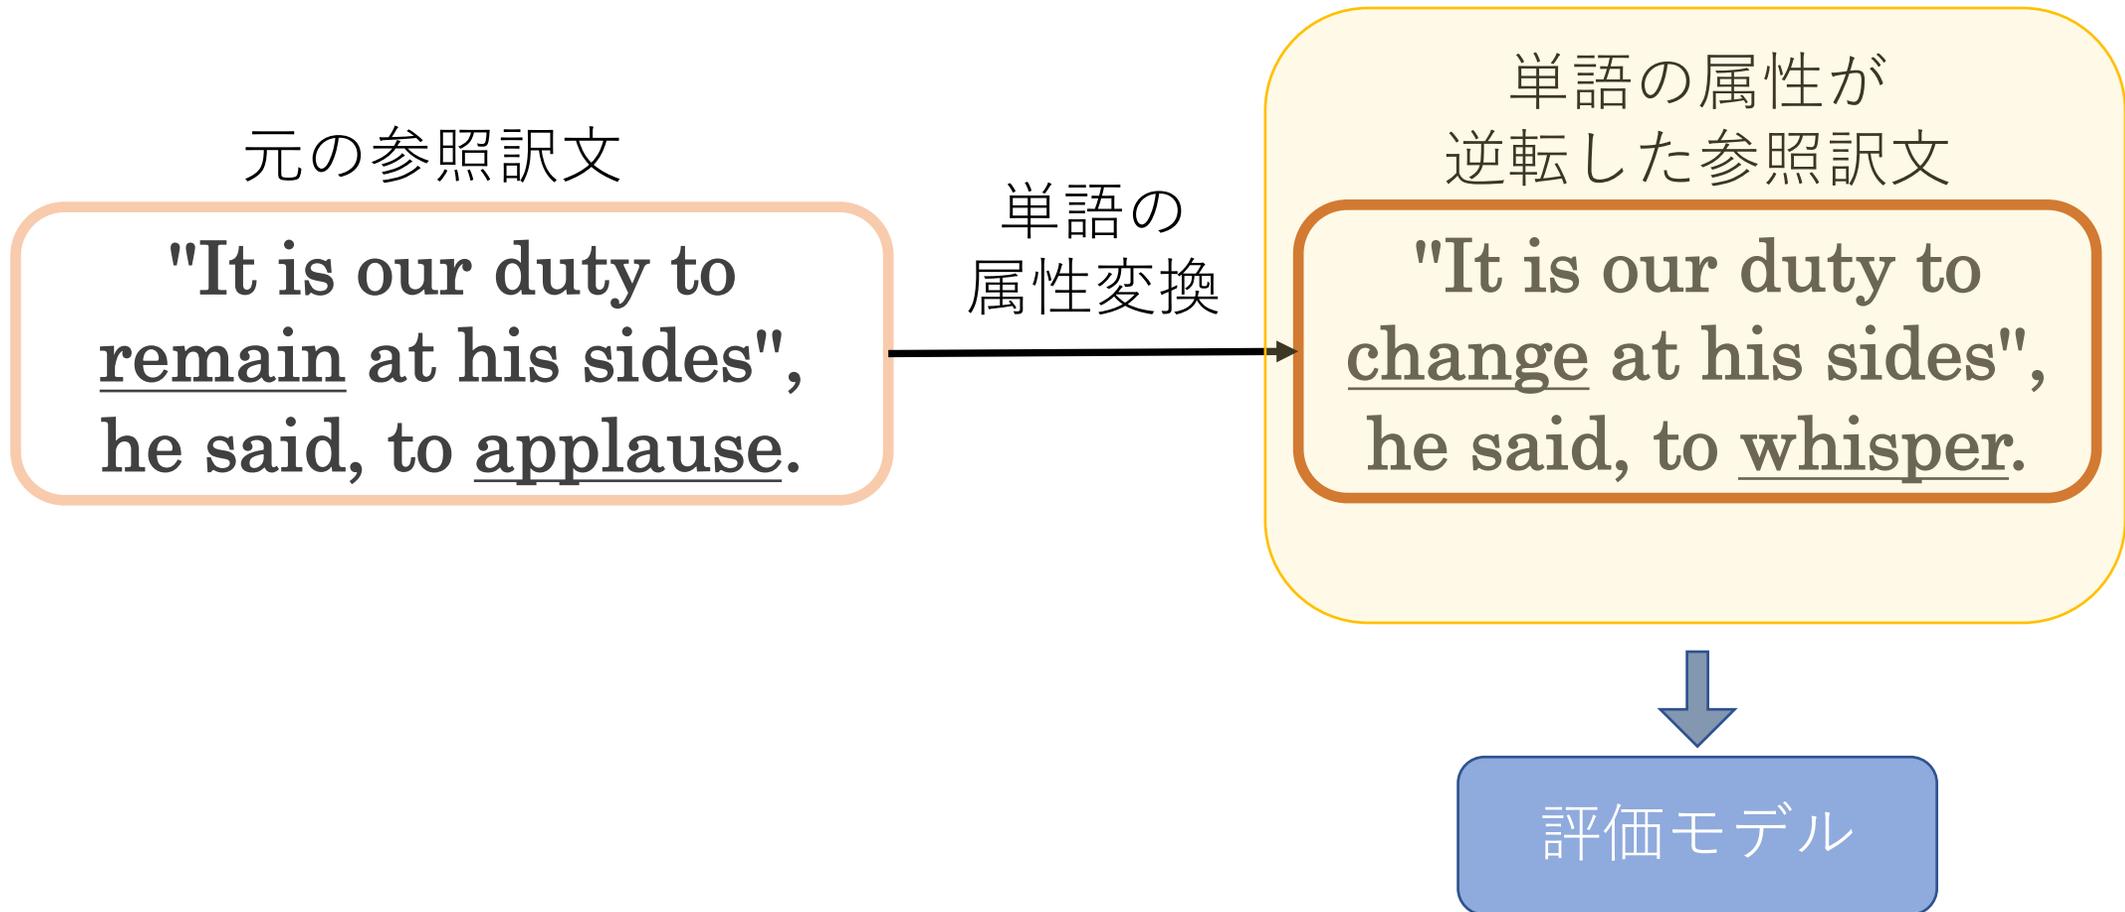
参照訳文	システム訳文	人手評価	BLEURT20	C-SPEC
They want to compete with <u>delivery services</u> .	They want to compete with <u>airlines</u> .	-0.861	-0.344	0.595
I'm glad we <u>got some of these dirty licks caught on tape</u> .	I'm glad we <u>lick some of the dirty things they made</u> .	-1.548	-0.088	-0.405

名詞(固有表現)の誤翻訳由来の評価誤り

述語構造の誤翻訳由来の評価誤り

# 提案手法 (C-SPECpn : C-SPEC fine-tuned on pseudo-negatives)

疑似的な名詞誤りを含むデータで評価モデルの追加学習



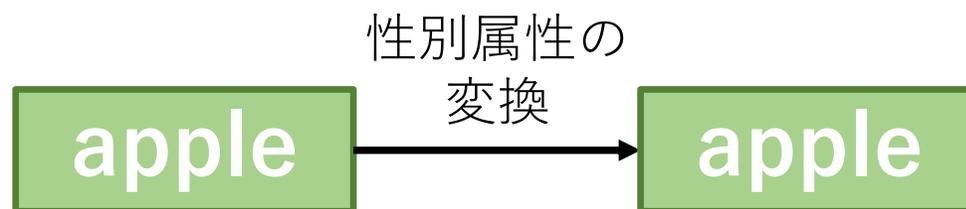
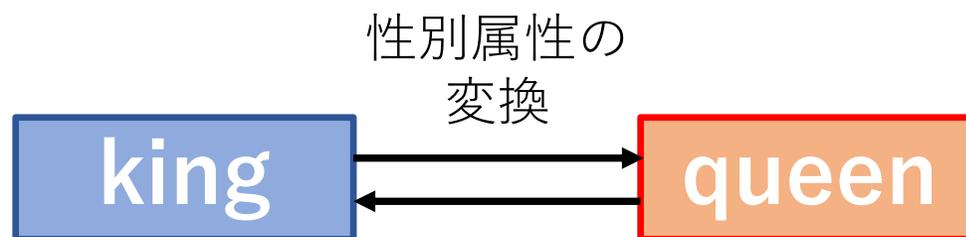
# 疑似負例データの作成

## 鏡面変換に基づく単語属性変換

[Ishibashi +, Reflection-based word attribute transfer, 2020] を参照訳文に適応

### 変換属性

- 性別
- 対義関係



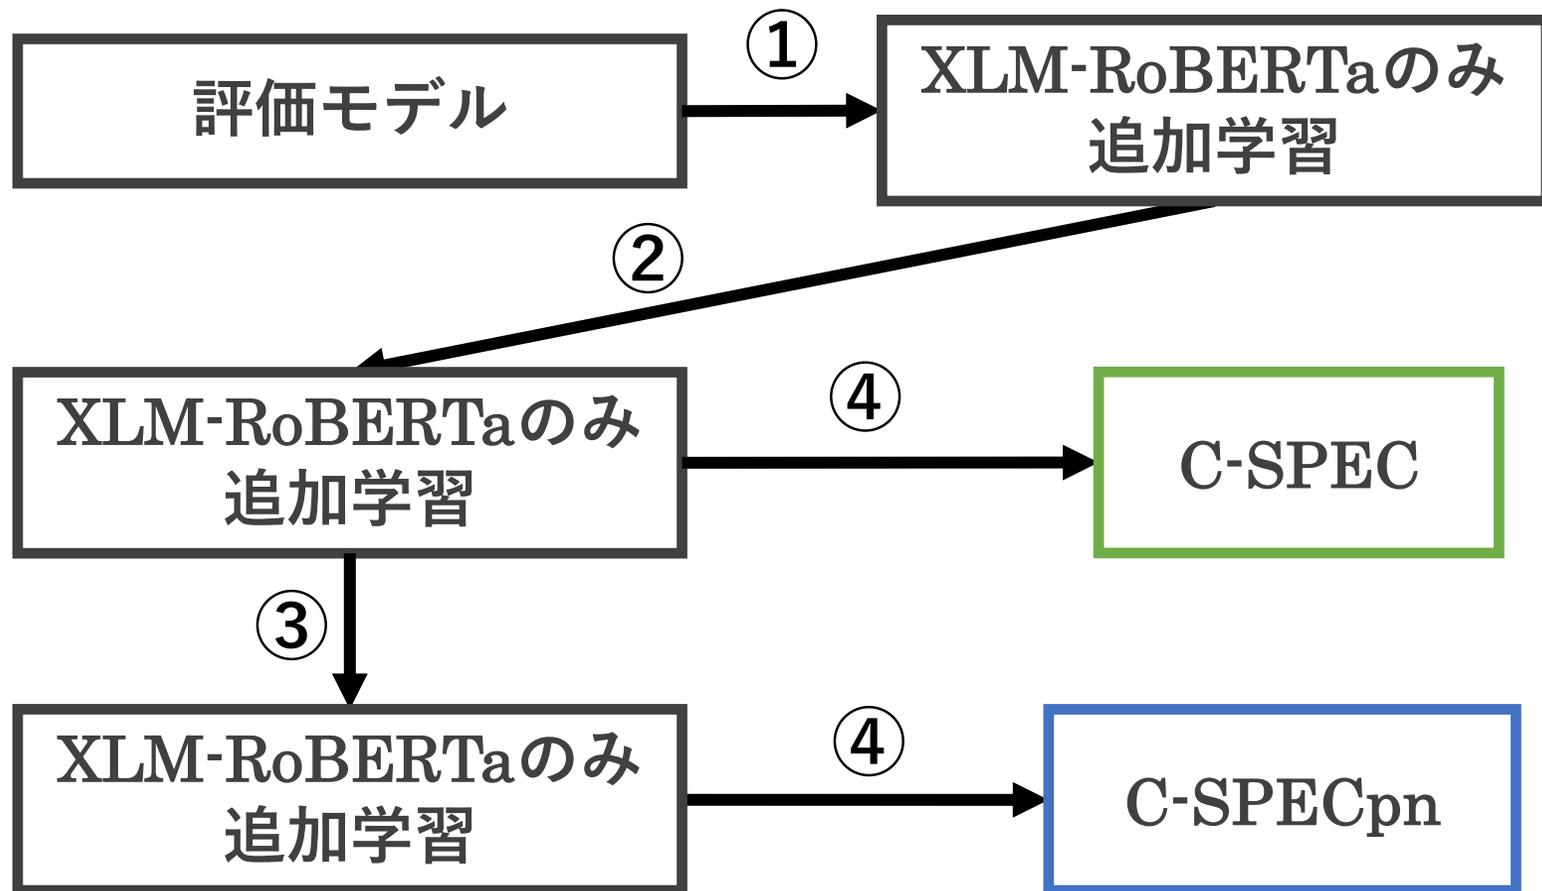
対象の属性を持たない単語は  
変換されない

# 分類タスクとして負例データで学習

評価モデルへの入力

1. システム訳文+原言語文、システム訳文+参照訳文  
(変化なし)
2. 参照訳文+原言語文、参照訳文+参照訳文  
(参照訳文に置き換え)
3. 負例文+原言語文、負例文+参照訳文  
(負例文に置き換え)

# コーパスごとの追加学習



- ①: WMT15-16で訓練
- ②: WMT18-20で訓練
- ③: 疑似負例データで訓練
- ④: WMT20のMQMデータで訓練

# WMT20のMQMデータでの実験結果

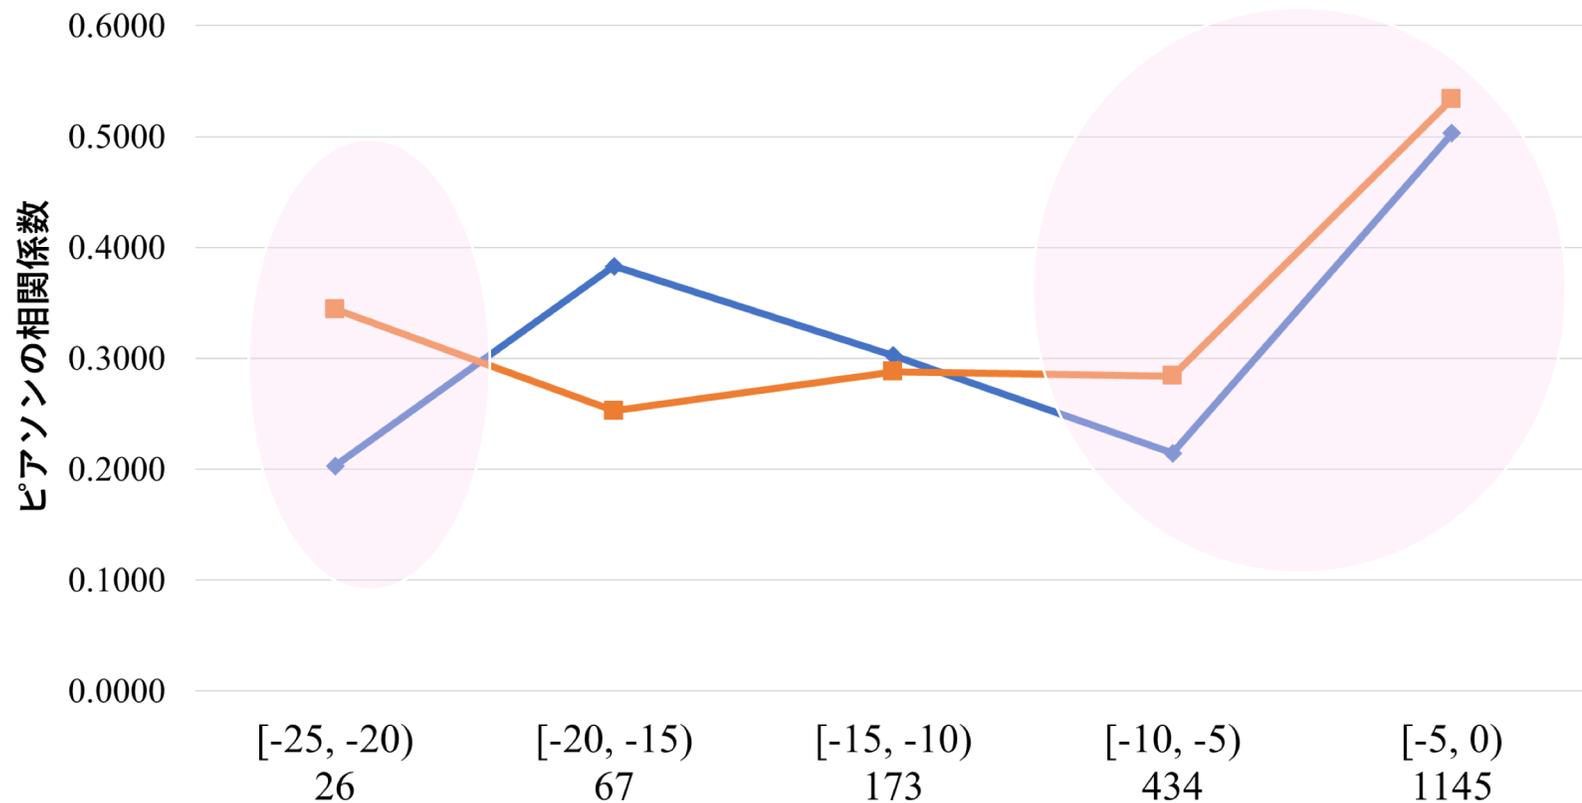
評価モデル	英語->ドイツ語	中国語->英語	2言語対の平均	全ての言語対
ベースライン: C-SPEC	0.612	0.805	0.708	0.813
提案モデル: C-SPECpn	<b>0.619</b>	<b>0.824</b>	<b>0.721</b>	<b>0.829</b>

-NOTE-

人手評価とのピアソンの相関係数で計測  
1.0に数値が近い程、人手評価との相関が高い

負例データで追加訓練することで、**より高い相関が得られた**

# システム訳文の品質による ピアソンの相関係数の差



人手評価が低い値域と  
高い値域において  
ピアソンの相関係数の向上

人手評価の値域と文量

◆C-SPEC

■C-SPECpn

# WMT21 metrics shared taskの結果

## 提案モデル

Metric	Total “wins”	Language Pair			Granularity		Data condition		
		en→de	en→ru	zh→en	sys	seg	news w/o HT	news w/ HT	TED
<b>C-SPECpn</b>	11	4	3	4	6	5	3	5	3
bleurt-20	10	4	5	1	4	6	4	3	3
COMET-MQM_2021	10	3	3	4	3	7	3	2	5
tgt-regEMT	4	1	1	2	3	1	2	1	1
<i>COMET-QE-MQM_2021</i>	3	1	1	1	3			3	
<i>OpenKiwi-MQM</i>	3	2		1	3		1	2	
RoBLEURT*	3			3	1	2	1		2
cushLEPOR(LM)	2	1		1	2		1		1
BERTScore	2	1	1		2		1		1
Prism	2		2		2		1		1
YiSi-1	2		2		2		1		1
MEE2	2	2			2		1		1
BLEU	1	1			1		1		
hLEPOR	1		1		1				1
MTEQA*	1			1	1				1
TER	1			1	1				1
chrF	1			1	1				1

Freitag +, Results of the WMT21 Metrics Shared Task: Evaluating Metrics with Expert-based Human Evaluations on TED and News Domain, WMT 2021 表12より引用

# WMT21のチャレンジセットの事例分析

チャレンジセットでは、

①誤った参照訳文、②ドイツ語の訳出誤り が含まれている

	原言語文	参照訳文	システム訳文	C-SPEC	C-SPECpn
①	希望 <u>水</u> 早点退吧	We hope that <u>the flooding ends soon.</u>	I hope <u>the water will return early.</u>	-1.5684	-0.6392
②	Ihr <u>konntet</u> denken.	You <u>were able to</u> think.	your <u>konntet</u> thinking.	-8.2422	-1.4688

C-SPECpnは参照訳文よりも原言語文との類似度を重要視している

# まとめ

- 単語属性変換を用いた負例データを作成
- 負例データによる追加訓練で評価モデルの  
人手評価との相関が向上
  - 特に、高品質な翻訳文への評価に対してピアソンの相関向上
- 提案モデルのC-SPECpnは、原言語文との類似度により重きをおいた評価をしている