

Abstract

[動機] ニューラル機械翻訳における, **訳抜け問題**, **重複訳問題を翻訳モデルに出力長を与えることで解決**

[手法] 要約文生成で適用された位置エンコーディングに基づく出力長制御を翻訳タスクに適用

[結果] 学習時に与えるトークン長に幅を与える方がBLEUスコアが上がった訳抜け・重複訳が解決した文と, 逆に発生してしまった文が見受けられた

提案手法

[先行研究]

位置エンコーディングを用いた出力長制御 [Takase+, NAACL-HLT 2019]

- **LDPE** - 文の終端までの差に応じた位置
- **LRPE** - 文の終端までの比率に応じた位置

この二つの式をTransformerモデルに適用
文字数単位での出力長制御が可能

[本研究]

• LRPE, LDPEを翻訳に適用

- 本研究ではLRPE,LDPEにトークン長を与える
- 入力文からトークン長を予測し, 正しいトークン長を与えると訳抜け, 重複訳が解決するのではないかと?
- このアプローチの有効性を検証するため, 正解トークン長に基づく出力長制御を行った
- 学習時に出力長制約に幅(±0.2)を持たせた長さを与えた場合も検証した

$$PE_{(pos,2i)} = \sin\left(\frac{pos}{10000^{2i/d}}\right)$$

$$PE_{(pos,2i+1)} = \cos\left(\frac{pos}{10000^{2i/d}}\right)$$

$$LRPE_{(pos,2i)} = \sin\left(\frac{pos}{len^{2i/d}}\right)$$

$$LRPE_{(pos,2i+1)} = \cos\left(\frac{pos}{len^{2i/d}}\right)$$

$$LRPE_{(pos,2i)} = \sin\left(\frac{len-pos}{10000^{2i/d}}\right)$$

$$LRPE_{(pos,2i+1)} = \cos\left(\frac{len-pos}{10000^{2i/d}}\right)$$

実験結果

[実験条件]

コーパス : ASPEC(1,000,000/1790/1812) トークナイズ : SentencePiece ポキャプラリサイズ : 16,000
ハイパーパラメータ : エンコーダ・デコーダ層数 2, その他は(Vaswani et al., 2017)

[実験結果] 重複訳が発生した例

ref	3相相関イメージセンサー(three-phase correlation image sensor:3PCIS)を使った実時間の位相スタンプ・レンジファインダー(phase-stamp range finder:PSRF)を提案する。
baseline	3相相関イメージセンサー(3PCIS)を用いたリアルタイム位相スタンプ距離計(RT-PSRF)を提案した 【25】
LDPE	三次元位相相関イメージセンサー(3PCIS)を用いた実時間位相スタンプレンジファインダー(RT-PSRF)を提案し,その動作作理と特徴,特徴,特徴,特徴,特徴などを紹介した。 【44】
LRPE	3相相関イメージセンサー(3PCIS)を用いた実時間位相スタンプ距離計(RT-PSRF)を提案し,その原理,原理,原理,原理,原理,および原理,原理,特性について述べた。 【45】
LRPE ± 0.2	3相相関イメージセンサー(3PCIS)を用いた実時間位相スタンプレンジファインダー(RT-PSRF)を提案し,その有効性を検証するために,3相相関イメージセンサー(3PCIS)を用いた。 【45】

LDPE,LRPEと比べ,出力トークン数がほぼ同じだがLRPE ± 0.2は重複訳の回数が少ない

翻訳時ではなく,学習時に与える長さに"揺らぎ"を与えるとBLEUが上がった

モデル	学習時 len	BLEU	分散
ベースライン		41.21	22.312
LRPE	tgt_len	39.79	0.167
	tgt_len ± 0~2	41.56	3.986
LDPE	tgt_len	39.32	0.001
	tgt_len ± 0~2	40.30	2.236

出力長制御の精度を検証

$$\frac{1}{n} \sum_{i=1}^n |ref_i - mt_i|^2$$

分散が小さいことから出力長制御ができているとわかる。
LDPEの方が精度が良い

[考察]

ベースラインに比べ, 提案手法が正しいトークン長を得た時, 訳抜け・重複訳が解決している例は多く見受けられた
原言語文に含まれていないフレーズを翻訳するとき, ベースラインは短く出力することで翻訳文の精度を維持するが, 提案手法では長さがすでに与えられているため, 重複訳をするという問題も発生したと考えられる。