

誤り理由を考慮したニューラル文法誤り訂正

小山田 創哲 *1*2*3 兼村 厚範 *2 石井 信 *3*4
Sotetsu Koyamada Atsunori Kanemura Shin Ishii

*1株式会社リクルートテクノロジーズ
Recruit Technologies Co., Ltd.

*2産業技術総合研究所 *3京都大学 大学院情報学研究科
National Institute of Advanced Industrial Science and Technology (AIST) Graduate School of Informatics, Kyoto University

*4ATR 脳情報通信総合研究所
ATR Brain Information Communication Research Laboratory Group

Neural machine translation (NMT) methods with an attention mechanism are promising for automated grammatical error correction compared to other statistical machine translation methods. However, current NMT-based grammatical error correction models have at least two issues: (i) it is difficult to identify why error corrections are made, i.e., correction models are black boxes and (ii) the attention of each correction does not depend on error types. To resolve these difficulties, we propose a multi-attention based neural grammatical error correction model, which utilizes an appropriate attention for error correction. We evaluated our proposed model and the baseline single-attention model with the CoNLL-2014 shared task dataset, and found that $F_{0.5}$ scores are comparable.

1. はじめに

文法誤り訂正の主要なアプローチの一つは統計的機械翻訳 (statistical machine translation; SMT) に基づくものである。文法誤り訂正を、誤りのある文から、正しい文への翻訳だと考えれば、SMT の手法は文法誤り訂正でも活用が可能である。一方、SMT の分野では近年、ニューラルネットワークを用いた encoder-decoder 型のニューラル機械翻訳 (neural machine translation; NMT) が成功を取っており [5, 1], その自然な流れとして、文法誤り訂正でも NMT を用いた手法 (ニューラル文法誤り訂正法) が提案され始めている [7, 8].

ニューラル文法誤り訂正は有望であるが、単に訂正案の文を出力するだけに留まり、誤り訂正の理由が必ずしも自明でなく“ブラックボックス”性が高いという実用上の問題がある。

そこで本研究では、根拠とする誤り訂正の理由も隠れ変数として同時に推定し、誤り理由に応じて適応的な attention を活用するニューラル文法誤り訂正モデルを提案する。また、誤り理由のアノテーション付きのデータは収集コストが高ことから、それらを半教師有りで学習する学習則を提案する。

2. 提案手法

文法誤りの理由を陽に推定すると共に、誤り理由に応じた適切な attention を用いるニューラル文法誤り訂正モデルを提案する。提案手法の概略を図 1 に示す。

2.1 誤り訂正理由に応じた attention

t' 番目のトークン $y_{t'}$ の誤り訂正の際、修正前の文における t 番目のトークン x_t にどれだけ着目して修正すべきかは、その誤りの理由に依存するため、 $(x_t, y_{t'})$ の関連度合いの指標には、想定する誤り理由の個数 (M とする) に応じた M 個のスカラ値 ($\alpha_{t,t'}^1, \dots, \alpha_{t,t'}^M$) を M 個の attention として考える。

また、 $(x_t, y_{t'})$ に対する適切な attention を、この誤り理由に応じた attention の重み付き線形和によって求める:

$$\alpha_{t,t'} = \sum_{m=1}^M z_{t,t'}^m \alpha_{t,t'}^m \quad (1)$$

ここで、 $z_{t,t'}^m$ は文法誤りの理由の推定値を表すパラメータで、 $z_{t,t'}^m \in [0, 1]$ かつ $\sum_{m=1}^M z_{t,t'}^m = 1$ とする。これによって、 $\alpha_{t,t'}$ は、適切な誤り理由の推定値 $z_{t,t'}^m$ が与えられていれば、それに応じた attention $\alpha_{t,t'}^m$ を活用できる。

誤り理由の推定値 $z_{t,t'} = (z_{t,t'}^1, \dots, z_{t,t'}^M)$ も、入力系列とそれまでの出力系列から推定される。これによって、

1. 推定時においても (推定された) 誤り理由に応じた適切な attention の活用が可能となり、
2. 文法誤り訂正時に、学習者に対して推定された誤り理由のフィードバックが可能となる。

2.2 半教師有り学習に対応した学習則

提案モデルは誤り訂正理由を隠れ変数 $z_{t'}$ とした生成モデルと捉えられ、[4] で提案された生成モデルにおける半教師有り学習手法と同じ考え方で $z_{t'}$ について半教師有り学習ができる。すなわち、 $z_{t'}$ の教師データが得られない場合、

1. まず、現在のパラメータに基づいて $z_{t'}$ を推定し、
2. 推定された $z_{t'}$ に基づいた誤差によりパラメータを更新する。

3. 数値実験

3.1 データセット

モデルの学習と評価に用いたデータセットは CoNLL-2014 データセット [3], CoNLL-2013 データセット [2], Lang-8 データセット [6] の 3 つである。

CoNLL-2014 データセット [3] のテストデータにおいて誤り

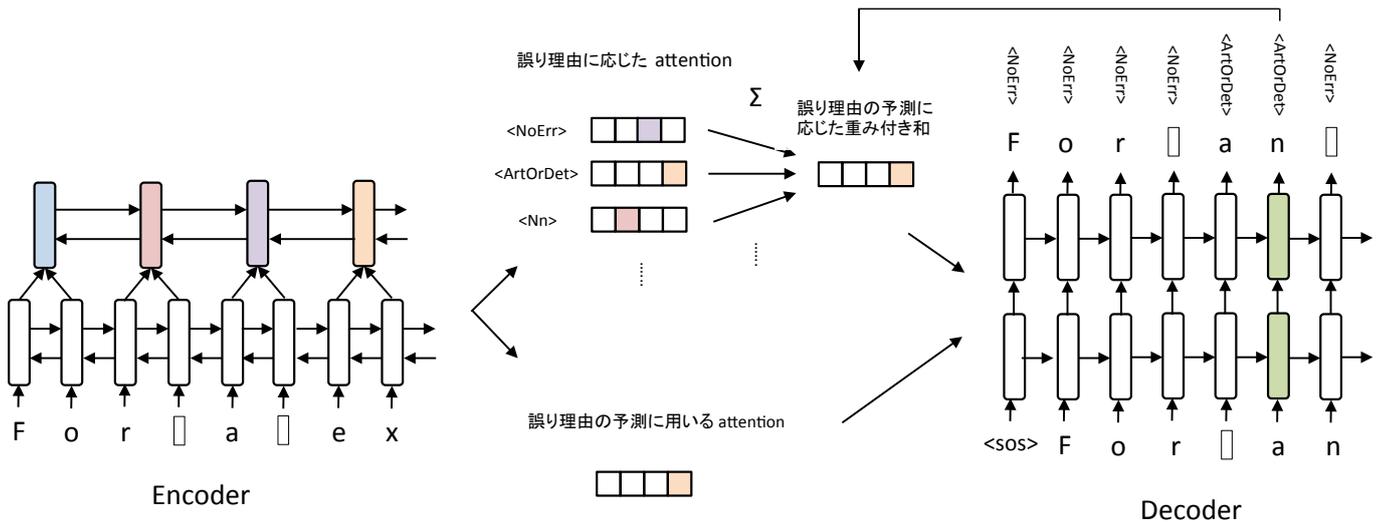


図 1: 誤り理由に適応的なアテンション: 誤り理由に応じた複数のアテンションを学習し, 誤り理由に応じて適応的に選択することで適切なアテンションを生成する.

表 1: Precision/Recall/ $F_{0.5}$ (M^2) スコアの比較

Model	Precision	Recall	M^2
通常の attention	42.23	15.36	31.29
提案手法の attention	42.91	15.80	31.95

訂正と誤り理由推定の評価を行った. モデルの完全な教師有り学習に必要な, 誤り文 x , 修正文 y , 及び誤り理由を示す系列 z には, それぞれ CoNLL-2014 データセットの誤り文, 修正文, 及び人手でラベリングされた誤りカテゴリを用いた.

今回, 誤りカテゴリのうち, トレーニングデータにおける誤りの数の多い順に 9 クラスと, その他の誤りを示す 10 個の誤り理由を, 誤り推定の学習の対象とし学習を行った.

ニューラル文法誤り訂正のモデルの学習には, CoNLL-2014 データセットのトレーニングデータのサンプルサイズは十分であるとは言えないため, [7] と同じく, Lang-8 データセット [6] の誤り文, 修正文のペアもトレーニングデータとして利用し, 半教師有り学習を行った.

CoNLL-2013 データセット [2] は, 先行研究に倣い, テストデータをバリデーション用のデータセットとして利用した.

3.2 数値実験の結果

[7] のモデルをベースに, 提案手法である誤り理由に応じた attention を用いた場合と, 通常の attention を用いた場合の Precision/Recall/ $F_{0.5}$ (M^2) スコアをそれぞれ比較を行った (図 1). 提案手法の M^2 スコアが遜色ないことを確認した.

4. おわりに

本研究では, ニューラル文法誤り訂正において, その訂正の理由 (根拠) が必ずしも自明でないという問題点に対し, その誤り理由も同時に隠れ変数として推定し, 誤り理由に応じた適切な attention を用いるモデルを提案した.

参考文献

- [1] D. Bahdanau, K. Cho, and Y. Bengio. Neural machine translation by jointly learning to align and translate. In *Proceedings of International Conference on Learning Representations (ICLR)*, 2015.
- [2] H. T. Ng, S. M. Wu, Y. Wu, C. Hadiwinoto, and J. Tetreault. The CoNLL-2013 shared task on grammatical error correction. In *Proceedings of Conference on Computational Natural Language Learning: Shared Task (CoNLL)*, 2013.
- [3] H. T. Ng, S. M. Wu, T. Briscoe, C. Hadiwinoto, R. H. Susanto, and C. Bryant. The CoNLL-2014 shared task on grammatical error correction. In *Proceedings of Conference on Computational Natural Language Learning: Shared Task (CoNLL)*, 2014.
- [4] K. Nigam, A. K. McCallum, S. Thrun, and T. Mitchell. Text classification from labeled and unlabeled documents using EM. *Machine Learning*, 39(2-3):103-134, 2000.
- [5] I. Sutskever, O. Vinyals, and Q. V. Le. Sequence to sequence learning with neural networks. In *Advances in Neural Information Processing Systems (NIPS)*, 2014.
- [6] T. Tajiri, M. Komachi, and Y. Matsumoto. Tense and aspect error correction for ESL learners using global context. In *Proceedings of Association for Computational Linguistics: Short Papers (ACL)*, 2012.
- [7] Z. Xie, A. Avati, N. Arivazhagan, D. Jurafsky, and A. Y. Ng. Neural language correction with character-based attention. *arXiv:1603.09727 [cs.CL]*, 2016.
- [8] Z. Yuan and T. Briscoe. Grammatical error correction using neural machine translation. In *Proceedings of Annual Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies (NAACL-HLT)*, pages 380-386, 2016.