

Dualformer における教師なし対訳語彙獲得過程の調査

金子航汰 秋葉友良
豊橋技術科学大学

塚田元
愛知産業大学

{kaneko.kota.zw, akiba.tomoyoshi.tk}@tut.jp tsukada@asu.ac.jp

概要

Dualformer は, Transformer を双方向の系列変換に拡張したニューラルアーキテクチャである. 機械翻訳に適用する場合, 例えば英日翻訳と日英翻訳を一つのモデルで実現可能である. また, 単言語データで Dualformer を学習するための補助タスクとして, Online Round-trip Translation(ORT) が提案され, ドメイン適応実験の結果, ターゲットドメインに対する翻訳性能を大幅に改善した. これはパラメータを更新する処理が逆翻訳そのものであり, 実質的にオンラインで IBT を行うのと同等の効果が得られたためであると推測される. IBT に対する優位性を検証するため, IBT を行った単方向モデルと ORT を適用した双方向モデルにて翻訳性能と対訳語彙獲得過程を調査した. 調査の結果, IBT を行った単方向モデルと同様に ORT を適用した双方向モデルは, 翻訳性能が改善されるとともに対訳語彙獲得率が上昇した. また対訳語彙の獲得量, 獲得速度ともに ORT の方が高くなった.

1 はじめに

機械翻訳における双方向学習は, 翻訳方向を一方方向に限定せず, 言語対の両方向 (例: 英語→日本語および日本語→英語) を同時に学習するアーキテクチャである. 特に, 大規模な対訳データが入手困難な低資源言語環境において, 双方向学習は有効な手法として注目されている. このような双方向学習は, その実装レベルの違いから, 大きくモデルレベルとデータレベルのアプローチに分けることができる.

モデルレベル双方向学習の代表例として, Xia らの研究 [1] があり, Chien らはこのアーキテクチャを Dualformer[2] と呼んでいる. Dualformer は, Transformer[3] を双方向の系列変換に拡張したニューラルアーキテクチャである. Dualformer はパラメータを部分的に共有しているため, 双方向翻訳

を一つのモデルで実現可能である. また加藤らは単言語データで Dualformer を学習するための補助タスクとして, Online Round-trip Translation (ORT) を提案している [4].

一方, データレベル双方向学習の代表的手法として, Iterative Back-Translation (IBT) が知られている [5][6]. IBT は, Back-Translation[7] を拡張した手法である. この手法により, 対訳データが限られている状況でも単言語データを効果的に活用できる点が利点である.

先行研究 [4] にて ORT は, ドメイン適応実験の結果, ターゲットドメインに対する翻訳性能を大幅に改善している. これはパラメータを更新する処理が逆翻訳そのものであり, 実質的にオンラインで IBT を行うのと同等の効果が得られたためであると推測されている [4].

こうした ORT と IBT の関連性について, 複数の評価を行うことで調査を行った. 先行研究 [4] では, 翻訳性能として BLEU[8] のみで評価している. 本研究では, それに加えて COMET[9] による翻訳性能と対訳語彙獲得率 [10][11] で評価を行った. 特に対訳語彙獲得率に注目し, 学習ステップごとに計算することで対訳語彙獲得過程を調査した.

2 関連研究

2.1 Dualformer

Dualformer[2] は, Transformer[3] を双方向の系列変換に拡張したニューラルアーキテクチャである. 機械翻訳に適用する場合, 例えば英日翻訳と日英翻訳を一つのモデルで実現可能である. 言語 X から言語 Y へのデコーダと言語 Y から言語 X へのデコーダの二つのデコーダによって構成されている. 以下は, 言語 X から言語 Y への翻訳手順である.

1. デコーダ X にソース文 x を入力する.
2. デコーダ X の Cross Attention を無効化しエン

コーダとして扱う。

3. 2.の結果をデコーダ Y へ入力しデコーダとして処理を行う。

このときのデコーダ X は Transformer のエンコーダ、デコーダ Y は Transformer のデコーダと等価である。逆方向の翻訳を行う場合は、デコーダを入れ替えて同様の処理を行う。

2.2 Online Round-trip Translation (ORT)

Online Round-trip Translation(ORT) は, Dualformer の学習で単言語データを活用する補助タスクである[4]。以下は, ORT の主な処理の手順である。

1. デコーダ X をエンコーダとして, 言語 X の単言語データから得た入力 x をデコーダ Y によって言語 Y へ再帰的に翻訳し, 翻訳結果 \tilde{y} を生成する。
2. デコーダ Y をエンコーダとして翻訳結果 \tilde{y} をデコーダ X によって言語 X に翻訳し, ORT の結果 x' を生成する。
3. 入力した x と ORT の生成結果 x' を比較し損失を計算する。

2.3 Iterative Back-Translation

Iterative Back-Translation(IBT)[5][6] は, Back-Translation[7] を拡張したデータレベルの双方向学習である。以下は, IBT の主な学習手順である,

1. ソースドメインの対訳データ (C_X^S, C_Y^S) を利用し, 言語 X から言語 Y への単方向モデル $(Model_{X \rightarrow Y})$ および言語 Y から言語 X への単方向モデル $(Model_{Y \rightarrow X})$ を作成する。
2. ターゲットドメインの単言語データ言語 X の C_X^T を, $Model_{X \rightarrow Y}$ によって言語 Y へ翻訳し C_Y^T を作成し, (C_X^T, C_Y^T) を疑似対訳データとする。
3. ターゲットドメインの単言語データ言語 y の C_Y^T を, $Model_{Y \rightarrow X}$ によって言語 X へ翻訳し C_X^T を作成し, (C_Y^T, C_X^T) を疑似対訳データとする。
4. 疑似対訳データ (C_X^T, C_Y^T) を利用し, 逆方向のモデル $(Model_{Y \rightarrow X})$ の Fine-tuning を行う。
5. 疑似対訳データ (C_Y^T, C_X^T) を利用し, 逆方向のモデル $(Model_{X \rightarrow Y})$ の Fine-tuning を行う。
6. 2-5 を繰り返し行う。

ORT は IBT に相応する処理を学習時に行っていると考えられる。

2.4 対訳語彙獲得率

対訳語彙獲得率 [10][11][12] は, ターゲットドメインのみに存在する単語がどの程度, 正しく翻訳可能になったかを表す評価指標である。以下は, 対訳語彙獲得率を求める手順である。

1. ソースとターゲットのデータを比較し, ターゲットドメインのみに存在する対訳語彙をリスト化する。
2. 下記の式で計算する。

$$\text{対訳語彙獲得率 (ARABV)} = \frac{\text{正しく翻訳できた対訳語彙の総数}}{\text{全ての対訳語彙の入力延べ数}}$$

3 実験

3.1 データ設定

対訳語彙獲得過程を確認するためにドメイン適応実験を行う。京都フリー翻訳タスクコーパス (KFTT), 約 44 万文ペアをソースドメインの対訳コーパス, アジア学術論文コーパス (ASPEC) 日・英 100 万文ずつをターゲットドメインの単言語データとして用いる。データの前処理として, 日英共通で NFKC 正規化, 英語には Moses を利用し, True-casing を行う。サブワード化には日英ともに語彙数を 16000 に設定した SentencePiece を用いる。

3.2 モデル設定

使用したモデルのアーキテクチャは, Dualformer と Transformer の 2 種類である。

1. ORT を適用した Dualformer を 150000 ステップ学習したモデル
2. IBT によって日英単方向モデルと英日単方向モデルをそれぞれ 30000 ステップずつファインチューニングし, 4 回更新させたモデル

上記のように学習ステップを 150000 ステップになるように統一し, それぞれ 3000 ステップずつチェックポイントを作成した。モデルの学習および翻訳には fairseq を用いた。

3.3 評価指標

作成したモデルにてそれぞれ BLEU, COMET による翻訳性能と対訳語彙獲得率で評価を行った。翻訳性能と対訳語彙獲得率は, それぞれ 3000 ステップご

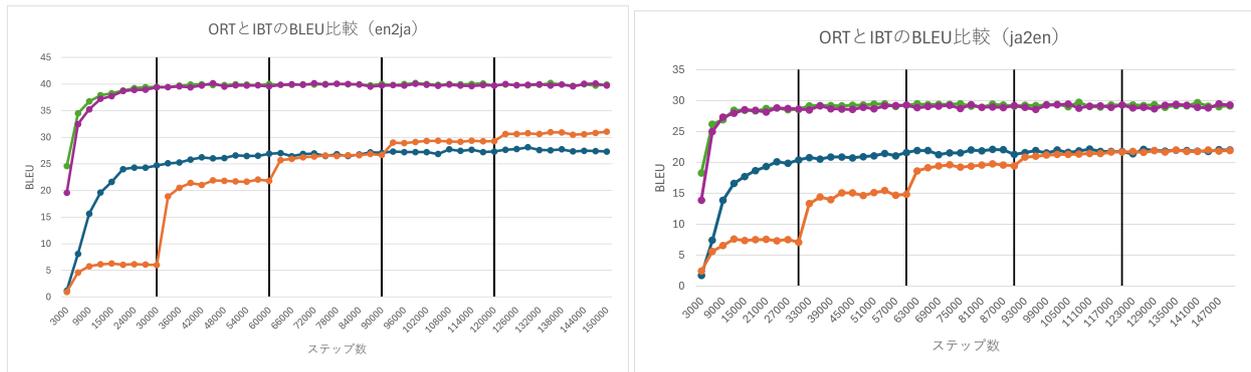


図1 Dualformer-ORT(青)とTransformer-IBT(橙)のBLEU比較

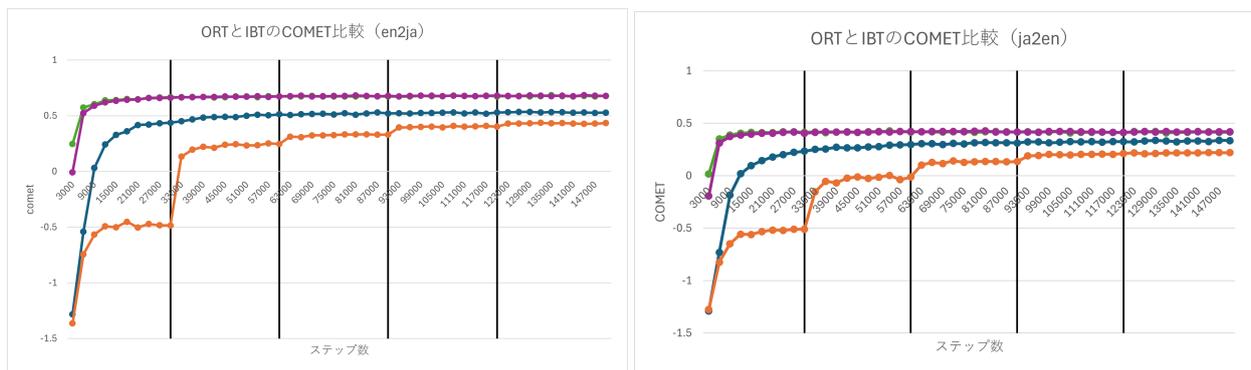


図2 Dualformer-ORT(青)とDualformer-IBT(橙)のCOMET比較

とに作成したチェックポイントごとに計算した。

3.4 結果

図 1-3 に実験結果を示す。全ての図に共有で横軸が学習ステップ、縦軸が各評価指標を示す。黒の縦線が IBT によって新しい疑似対訳データを作成し、モデルを更新したタイミングを表す。またグラフの青線が Dualformer(ORT)、橙線が Trnsformer(IBT) の結果である。

図 1 は評価指標 BLEU での比較、図 2 は評価指標 COMET での比較、である。左図が英語から日本語方向の翻訳、右図が日本語から英語方向の翻訳である。性能上限として、単言語データと同じサイズの ASPEC の対訳データで学習した Transformer と Dualformer の結果を、それぞれグラフの紫線と緑線で示した。

どちらの指標でも性能上限の対訳データで学習した場合は、Transformer と Dualformer で大きな差は見られなかった。単言語データで学習した場合は、Transformer(IBT) と Dualformer(ORT) 共に学習ステップが増えるに連れて、翻訳方向とも安定して上昇している。一方、Transformer(IBT) は、新しい疑似対訳データを作成したタイミングで性能が大き

く向上しグラフが階段状になっているのに対し、Dualformer(ORT) は連続的に性能向上が見られる。学習を 150,000 ステップまで進めた場合を比較すると、BLEU の結果では、英語から日本語への翻訳方向で Transformer(IBT) の方が評価が高くなっている。一方、COMET の結果では、両翻訳方向ともに一貫して、Dualformer(ORT) の方が評価が高くなっており、教師あり学習の結果により近づいている。

図 3 は、対訳語彙獲得率の比較である。どちらのモデルも性能が改善されるとともに、対訳語彙獲得率が上昇している。一方、Dualformer(ORT) は早い段階から獲得率を急激に上昇させている。また、最終的にも Dualformer(ORT) の方が獲得率が高くなっている。

4 考察

ORT を適用した双方向モデル Dualformer と IBT を行った単方向モデルの対訳語彙獲得過程を比較することで、Dualformer は IBT よりも対訳語彙獲得率の獲得率、獲得量がともに高くなっていることが分かった。これは、IBT がデータレベルの双方向学習であるのに対し、ORT がモデルレベルの双方向学習である。そのため ORT では疑似対訳ペアをその都度生

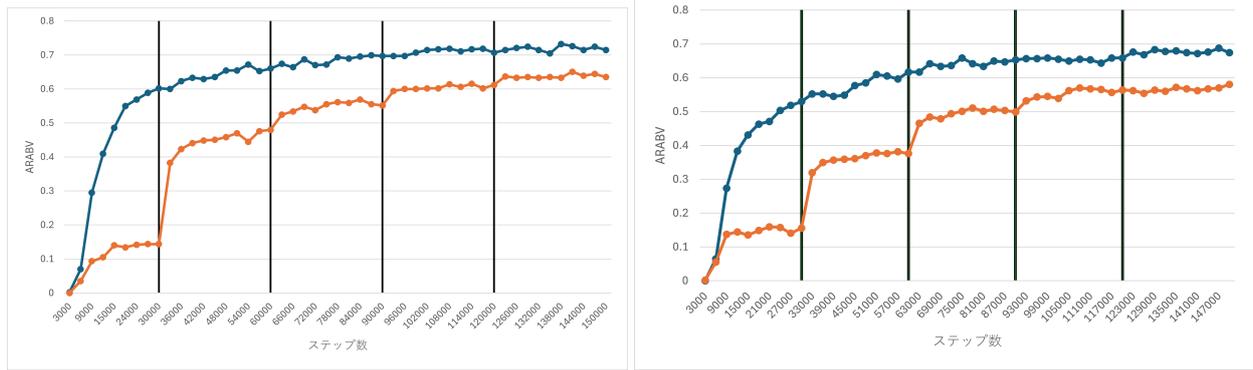


図3 Dualformer-ORT(青)とTransformer-IBT(橙)の対訳語彙獲得率比較

成し、常に最高品質のデータで訓練できるからであると考える。また、Dualformerは2つの翻訳方向でパラメータが共有されているため、片方向の語彙が獲得されればもう片方も自動的に獲得されるためだと考えられる。

5 おわりに

本稿では、ターゲットドメインの単言語データを用いたドメイン適応実験において、TransformerによるIterative Back-Translation(IBT)とDualformerのOnline Round-Trip Translation(ORT)の比較を行った。学習ステップ毎の2つの翻訳性能評価指標と対訳語彙獲得率を調べ、両手法の性質の違いを明らかにした。最終的には、Dualformer(ORT)の方が高い対訳語彙獲得率を示し、その結果COMETで高い翻訳性能を示したと考えられる。

謝辞

本研究はJSPS 科研費 23K11118の助成を受けたものです。

参考文献

[1] Yingce Xia, Xu Tan, Fei Tian, Tao Qin, Nenghai Yu, and Tie-Yan Liu. Model-level dual learning. In Jennifer Dy and Andreas Krause, editors, **Proceedings of the 35th International Conference on Machine Learning**, Vol. 80 of **Proceedings of Machine Learning Research**, pp. 5383–5392. PMLR, 10–15 Jul 2018.

[2] Jen-Tzung Chien and Wei-Hsiang Chang. Dualformer: A unified bidirectional sequence-to-sequence learning. In **ICASSP 2021- 2021 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)**, pp. 7718–7722, 2021.

[3] Ashish Vaswani, Noam Shazeer, Niki Parmar, Jakob Uszkoreit, Llion Jones, Aidan N. Gomez, Łukasz Kaiser, and Illia Plosukhin. Attention is all you need. 2017.

[4] 加藤龍兵, 秋葉友良, 塚田元. ニューラル機械翻訳の

モデルレベル双方向学習における単言語データの活用. 言語処理学会年次大会発表論文集 (Web), Vol.30th, 2025.

[5] Vu Cong Duy Hoang, Philipp Koehn, Gholamreza Haffari, and Trevor Cohn. Iterative back-translation for neural machine translation. In **Proceedings of the 2nd Workshop on Neural Machine Translation and Generation**, pp. 18–24, 2018.

[6] 森田知熙, 秋葉友良, 塚田元. 双方向の逆翻訳を利用したニューラル機械翻訳の教師なし適応の検討. 情報処理学会研究報告 2018-NL-238 (第5回自然言語処理シンポジウム), pp. 1–5, 2018.

[7] Rico Sennrich, Barry Haddow, and Alexandra Birch. Improving neural machine translation models with monolingual data. In Katrin Erk and Noah A. Smith, editors, **Proceedings of the 54th Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers)**, pp. 86–96, Berlin, Germany, August 2016. Association for Computational Linguistics.

[8] Kishore Papineni, Salim Roukos, Todd Ward, and Wei-Jing Zhu. Bleu: A method for automatic evaluation of machine translation. In Pierre Isabelle, Eugene Charniak, and Dekang Lin, editors, **Proceedings of the 40th Annual Meeting of the Association for Computational Linguistics**, pp. 311–318, Philadelphia, Pennsylvania, USA, July 2002. Association for Computational Linguistics.

[9] Ricardo Rei, Craig Stewart, Ana C. Farinha, and Alon Lavie. Comet: A neural framework for mt evaluation. **arXiv preprint arXiv:2009.09025**, 2020. <https://arxiv.org/abs/2009.09025>.

[10] 谷川琢磨, 秋葉友良, 塚田元. 双方向翻訳モデルの相互学習による対訳語彙の教師なし獲得過程の調査. 言語処理学会年次大会発表論文集, Vol.29th, pp. 16–20, 2023.

[11] 谷川琢磨, 秋葉友良, 塚田元. Iterative back-translationは対訳語彙を獲得できるか? 言語処理学会年次大会発表論文集, Vol.28th, pp. 354–359, 2022.

[12] Takuma Tanigawa, Tomoyosi Akiba, and Hajime Tsukada. Analysis on unsupervised acquisition process of bilingual vocabulary through iterative back-translation. In **Proceedings of the 2024 Joint International Conference on Computational Linguistics, Language Resources and Evaluation (LREC-COLING 2024)**, pp. 887–892, Torino, Italia, May 2024. ELRA and ICCL.