

モノリンガルデータを増加させた場合の統計翻訳の精度調査

善行佑介 *1 村上仁一 *2 徳久雅人 *2

*1 鳥取大学 工学部 知能情報工学科

*2 鳥取大学大学院 工学研究科 情報エレクトロニクス専攻

*1,*2 {s102025, murakami, tokuhisa} @ ike.tottori-u.ac.jp

1 はじめに

統計翻訳は、対訳データから学習する翻訳モデルと、モノリンガルデータから学習する言語モデルを用いて、確率的に翻訳をする。

アラビア語-英語 [1] や、中国語-英語 [2] では数百万文もの多量の対訳データが提供されている。しかし、日本語-英語で提供されている対訳データの量は少ない。したがって、日英翻訳や英日翻訳において多量の対訳データを用いて、精度の高い翻訳モデルを作成することは困難である。

そこで本研究では、データを収集することが容易な、モノリンガルデータを大量に使用して、言語モデルを学習し、日英翻訳と英日翻訳の翻訳精度の向上を目指す。

2 実験方法

ベースラインは辞書から抜き出した単文 (辞書文) [3] を使用する。翻訳モデルの学習には 100,000 文、言語モデルの学習には 100,000 文を用いる。テスト文として辞書文 10,000 文を使用する。デベロップメント文には 1000 文を使用する。実験は日英翻訳と英日翻訳を行う。

2.1 翻訳モデルの学習

翻訳モデルを学習するために、GIZA++[4] を用いる。

2.2 言語モデルの学習

言語モデルを学習するために、SRILM[5] の ngram-count を用いる。N-gram モデルに 5-gram の言語モデルを用いる。

2.3 デコーダのパラメータ

デコーダには mooses[6] を用いる。

2.4 パラメータのチューニング

本実験では 3 種類のコーパスを扱う (第 2.5 節参照)。実験条件を揃えるために、各コーパスごとに同じ mooses のパラメータを使う。

2.5 実験で用いるモノリンガルデータ

本実験では、対訳データの数を固定して、多量のモノリンガルデータをベースラインに加えて翻訳精度の変化を調べる。実験データとして、テスト文と同分野の辞書文と、別分野の特許翻訳文、Wikipedia から抜き出した文 (Wikipedia 文) の 3 種類を使用する。実験で使用するモノリンガルコーパスの内訳を表 1 に示す。

表 1 実験で使用するモノリンガルコーパス

追加コーパス	英語文	日本語文
辞書文	888,443 文	906,324 文
特許翻訳文	3,507,225 文	3,507,231 文
Wikipedia 文	14,679,468 文	12,893,649 文

2.6 評価方法

本実験の評価方法として、人手評価と自動評価を用いる。

2.6.1 人手評価

人手評価は出力文からランダムに 100 文を取りだし、追加コーパスとベースラインの対比較評価を行う。判断基準の例を以下に示す。

ベースライン○	ベースラインの出力文が追加コーパスありの出力文より翻訳品質が優れている
追加○ (辞書文)	辞書文を追加したコーパスの出力文がベースラインの出力文より翻訳品質が優れている
差なし	2 つの出力文の翻訳品質に明確な差がない
同出力	2 つの出力文が完全に同じ

2.6.2 自動評価

自動評価は、BLEU[7], METEOR[8], RIBES[9], TER[10] を用いる。

3 実験結果

3.1 人手評価

日英翻訳における人手評価の結果を表 2 に、英日翻訳における人手評価の結果を表 3 に示す。

表 2 日英翻訳の人手評価

ベースライン○	追加○ (辞書文)	差なし	同出力
12	16	42	30
ベースライン○	追加○ (特許翻訳文)	差なし	同出力
9	11	35	45
ベースライン○	追加○ (Wikipedia 文)	差なし	同出力
13	6	51	30

表3 英日翻訳の人手評価

ベースライン○	追加○ (辞書文)	差なし	同出力
7	14	58	21
ベースライン○	追加○ (特許翻訳文)	差なし	同出力
6	8	54	32
ベースライン○	追加○ (Wikipedia 文)	差なし	同出力
10	13	54	23

人手評価の結果より、辞書文を追加した日英翻訳・英日翻訳では、ベースラインと比べて翻訳精度が向上している。特許翻訳文と Wikipedia 文を追加した日英翻訳・英日翻訳では、翻訳精度に変化がなかった。

3.2 自動評価

日英翻訳の自動評価の結果を表4に、英日翻訳の自動評価の結果を表5に示す。

表4 日英翻訳の自動評価

コーパスの内容	BLEU	METEOR	RIBES	TER
辞書文				
ベースライン	0.1382	0.4552	0.7105	69.511
追加あり	0.1499	0.4641	0.7123	70.004
特許翻訳文				
ベースライン	0.1299	0.4521	0.7051	73.437
追加あり	0.1339	0.4512	0.7056	70.969
Wikipedia 文				
ベースライン	0.1310	0.4540	0.7046	72.719
追加あり	0.1389	0.4536	0.7024	71.893

表5 英日翻訳の自動評価

コーパスの内容	BLEU	RIBES	TER
辞書文			
ベースライン	0.1792	0.7686	65.958
追加あり	0.1860	0.7690	66.637
特許翻訳文			
ベースライン	0.1738	0.7635	68.097
追加あり	0.1741	0.7622	67.415
Wikipedia 文			
ベースライン	0.1792	0.7694	67.028
追加あり	0.1815	0.7644	66.994

自動評価の結果から、辞書文を追加した場合は TER 値を除いて、日英翻訳、英日翻訳ともに翻訳精度が向上している。一方特許翻訳文を追加した場合は、日英翻訳では BLEU 値、RIBES 値、TER 値が、英日翻訳では BLEU 値、TER 値の翻訳精度がわずかに向上している。Wikipedia 文を追加した場合は、BLEU 値と TER 値が日英翻訳・英日翻訳ともに翻訳精度がわずかに向上している。

3.3 実験結果のまとめ

辞書文を追加したときの翻訳精度は、日英翻訳・英日翻訳ともに向上した。特許翻訳文と Wikipedia 文を追加したときの翻訳精度は、日英翻訳・英日翻訳ともにあ

まり向上しなかった。

4 データ量を変化させた実験

4.1 目的

追加実験として、辞書文と Wikipedia 文を使用し、追加する文を FULL のデータから 1/2、1/4 と減らしていき、モノリンガルデータの量と翻訳精度の関係を調べる。

4.2 実験内容

実験環境は第2章と同じである。新たな実験データとして追加するコーパスの 1/2、1/4、1/8 のデータを使用し、辞書文と Wikipedia 文で日英翻訳と英日翻訳を行う。

4.3 実験結果

日英翻訳における辞書文の人手評価の結果を表6に、Wikipedia 文の人手評価の結果を表7に、英日翻訳における辞書文の人手評価の結果を表8に、Wikipedia 文の人手評価の結果を表9に示す。日英翻訳の自動評価 BLEU の結果を図1に、METEOR の結果を図2に、RIBES の結果を図3に、TER の結果を図4に、英日翻訳の自動評価 BLEU の結果を図5に、RIBES の結果を図6に、TER の結果を図7に示す。

表6 辞書文の日英翻訳の人手評価

ベースライン ○	+98,555 文 (+1/8 FULL) ○	差なし	同出力
7	10	36	47
ベースライン ○	+197,110 文 (+1/4 FULL) ○	差なし	同出力
7	12	46	35
ベースライン ○	+394,221 文 (+1/2 FULL) ○	差なし	同出力
12	15	46	27
ベースライン ○	+788,443 文 (+FULL) ○	差なし	同出力
12	16	42	30

表7 Wikipedia 文の日英翻訳の人手評価

ベースライン ○	+1,822,433 文 (+1/8 FULL) ○	差なし	同出力
7	5	49	39
ベースライン ○	+3,644,867 文 (+1/4 FULL) ○	差なし	同出力
8	7	49	36
ベースライン ○	+7,289,734 文 (+1/2 FULL) ○	差なし	同出力
9	7	51	33
ベースライン ○	+14,579,468 文 (+FULL) ○	差なし	同出力
13	6	51	30

人手評価の表において、“+FULL”とは、追加できる最大のモノリンガルデータを、ベースラインのデータに追加した文である。“+1/2 FULL”とは、追加できる最大のモノリンガルデータの 1/2 を、ベースラインのデータ

に追加した文である。“+1/4 FULL”と“+1/8 FULL”も“+1/2 FULL”と同様である。




図1 日英翻訳の BLEU 値の変化




図2 日英翻訳の METEOR 値の変化




図3 日英翻訳の RIBES 値の変化




図4 日英翻訳の TER 値の変化

表8 辞書文の英日翻訳の人手評価

ベースライン ○	+100,790 文 (+1/8 FULL) ○	差なし	同出力
5	5	54	36
ベースライン ○	+201,581 文 (+1/4 FULL) ○	差なし	同出力
6	9	56	29
ベースライン ○	+403,162 文 (+1/2 FULL) ○	差なし	同出力
5	11	58	26
ベースライン ○	+806,324 文 (+FULL) ○	差なし	同出力
7	14	58	21

表9 Wikipedia 文の英日翻訳の人手評価

ベースライン ○	+1,699,206 文 (+1/8 FULL) ○	差なし	同出力
9	12	47	32
ベースライン ○	+3,198,412 文 (+1/4 FULL) ○	差なし	同出力
8	13	50	29
ベースライン ○	+6,396,824 文 (+1/2 FULL) ○	差なし	同出力
10	10	54	26
ベースライン ○	+12,793,649 文 (+FULL) ○	差なし	同出力
10	13	54	23




図5 英日翻訳の BLEU 値の変化




図6 英日翻訳の RIBES 値の変化




図7 英日翻訳の TER 値の変化

実験結果より、人手評価では辞書文の翻訳精度が日英・英日翻訳ともに、比例して向上している。自動評価でも TER 値を除けば、辞書文の翻訳精度が日英・英日翻訳ともに、比例して向上している。

また、分野の違う Wikipedia 文では BLEU 値が日英・英日翻訳ともに、比例して向上している。しかし、その他の自動評価の結果では、ばらつきがある。

5 考察

5.1 分野の依存性

今回の実験では、日英翻訳・英日翻訳で翻訳精度において、同分野のモノリンガルデータを増やすと翻訳精度は向上する。しかし、別分野のモノリンガルデータを追加すると、翻訳精度はあまり向上しなかった。よって、統計翻訳における言語モデルの分野依存性は高い。

5.2 データ量と翻訳精度の関係

辞書文のデータを増やすと人手・自動評価において日英翻訳・英日翻訳の翻訳精度が、増加量と比例して向上している。よって、同分野のモノリンガルデータを収集することは有用であると考えられる。

5.3 人手評価の問題点

今回の実験での人手評価は、出力文 100 文に対して対比較を行ったが、翻訳品質に差のある文は 20 文ほどしかなかった。20 文で翻訳精度の差を評価するには信頼性が低い。よって評価する文数を増やす必要がある。

5.4 自動評価の問題点

統計翻訳における自動評価では、様々な問題が報告されている。松本は、単文を用いて自動評価と人手評価を行い、評価結果に差異が生じたことを報告している [11]。本実験でも自動評価の結果と人手評価の結果に差があった。今後、自動評価に対する方法を調べる必要がある。

6 関連研究

Brants らはアラビア語英語間の統計翻訳において、多量のモノリンガルデータを使用し、統計翻訳を行った [12]。4 種類のモノリンガルデータ、2 つの翻訳手法を用いて、BLEU 値が分野に関係なく向上することを報告した。また、Schwenk は仏英翻訳で、多量のモノリンガルデータを使用し、統計翻訳を行い、BLEU 値が上昇したことを報告している [13]。

本実験でも日英翻訳・英日翻訳での BLEU 値が同分野と別分野で向上している。しかし、他の自動評価の値はばらつきがある。上記の関連研究は、BLEU 値が向上したことのみを報告しており、他の自動評価の値は示されない。これは、BLEU の評価の問題点の 1 つであると考えている。

7 おわりに

本研究では英語-日本語間の単文の統計翻訳において、対訳データと比べて、データを収集することが容易な、モノリンガルデータを増やす実験を行った。

実験の結果、テスト文と同分野のモノリンガルデータを増やすと、日英翻訳・英日翻訳の翻訳精度が向上した。一方別分野のモノリンガルデータでは、日英翻訳・英日翻訳において翻訳精度があまり向上しなかった。

今後は重文複文コーパスや、統計翻訳の別手法での実験を行いたい。

参考文献

- [1] Li et al.: “Parallel Aligned Treebanks at LDC: New Challenges Interfacing Existing Infrastructures”, LREC 2012, pp.1848-1855, 2012.
- [2] Ruiqiang Zhang and Eiichiro Sumita: “Boosting Statistical Machine Translation by Lemmatization and Linear Interpolation”, Proceedings of the ACL 2007, pp.181-184, 2007.
- [3] 村上仁一, 藤波進: “日本語と英語の対訳文対の収集と著作権の考察”, 第一回コーパス日本語学会ワークショップ, pp.119-130, 2012.
- [4] GIZA++, <http://www.fjoch.com/GIZA++.html>
- [5] SRILM, The SRI Language Modeling Toolkit, <http://www.speech.sri.com/projects/srilm/>
- [6] moses, <http://www.statmt.org/moses/>
- [7] Papineni et al.: BLEU, NIST: “a method for automatic evaluation of machine translation”, 40th Annual meeting of the Association for Computational Linguistics, pp.311-318, 2002.
- [8] Banerjee et al.: METEOR: “An Automatic Metric for MT Evaluation with Improved Correlation with Human Judgments”, Proceedings of Workshop on Intrinsic and Extrinsic Evaluation Measures for MT and/or Summarization at the 43th Annual Meeting of the Association of Computational Linguistics (ACL-2005), pp.65-72, 2005.
- [9] 平尾 他: RIBES: “順位相関に基づく翻訳の自動評価法”, 言語処理学会第 17 年次大会発表論文集, pp.1111-1114, 2011.
- [10] Richard Schwartz, Linnea Micciulla, John Makhoul. “A Study of Translation Edit Rate with Targeted Human Annotation”, AMTA, pp.223-231, 2006.
- [11] 松本拓也, 村上仁一, 徳久雅人 “機械翻訳における人手評価と自動評価の考察”, NLP-2012, pp.505-508, 2012
- [12] Thorsten Brants, Ashok C. Popat, Peng Xu, Franz J. Och, and Jeffrey Dean, “Large Language Models in Machine Translation”, EMNLP-2007, pp.858-867, 2007.
- [13] Holger Schwenk, “Investigations on Large-Scale Lightly-Supervised Training for Statistical Machine Translation”, Proceedings of IWSLT 2008, pp.182-189, 2008.