

【AAMT/Japio特許翻訳研究会活動報告】

特許機械翻訳の課題解決に向けた 機械翻訳技術解説

須藤 克仁

AAMT/Japio特許翻訳研究会 副委員長
(奈良先端科学技術大学院大学)

- 本発表は研究会メンバーによる下記解説論文を紹介するものです

- 共著者の皆様をはじめ、当研究会関係者に御礼申し上げます

今村賢治、越前谷博、江原暉将、後藤功雄、須藤克仁、
園尾聡、綱川隆司、中澤敏明、二宮崇、王向莉

「特許機械翻訳の課題解決に向けた機械翻訳技術解説」

自然言語処理 29巻 3号 pp. 925-985 (2022)

<https://doi.org/10.5715/jnlp.29.925> (オープンアクセス)

© The association for Natural Language Processing

※ 当該論文は[クリエイティブ・コモンズ 表示 4.0 国際 \(CC BY 4.0\)](https://creativecommons.org/licenses/by/4.0/)で公開されています。
本発表に含まれる論文内容の複製はこのライセンスに基づくものです。

発表の構成（≡論文の構成）

1. はじめに：解説論文の背景
2. 訳抜け・過剰訳への対策
3. 用語訳の統一
4. 長文対策
5. 低リソース言語対策
6. 評価
7. 翻訳の高速化・省メモリ化
8. おわりに：まとめ

1. はじめに ～本解説論文（技術調査）の背景

特許機械翻訳研究の動向

- 特許領域における機械翻訳の積極活用
 - 知財庁 (JPO, WIPO, USPTO, EPO, ...)
 - 各種機械翻訳サービスと民間での活用
- 特許機械翻訳に関する学術研究
 - 2008-2013: NTCIR PATMT/PatentMT
 - 日本国内の統計的機械翻訳研究における中心的な役割を果たす
 - 2016-: WAT – JPO Patent Corpus
 - ニューラル機械翻訳への移行期に活用される
 - 以後は一般分野の対訳コーパスが充実し特許データの利用は減少
- 本解説論文では特許機械翻訳の諸課題の現状と今後を議論

2. 訳抜け・過剰訳への対策

訳抜け・過剰訳への様々な対策

7

- ネットワーク内で入力情報の参照度合いを管理
- 逆翻訳等で訳抜けを予測する仕組みの導入
- 語彙表現の工夫
 - 未知語や低頻度語が訳抜け・過剰訳の原因となることが多いため
- 出力長制御のモデル化
- 強化学習による訳抜け・過剰訳の抑制
- 繰り返しの抑制機構
- 訓練データのクリーニングとノイズ対策

3. 用語訳の統一

用語集や語彙制約の導入

9

- 対訳用語集に基づく後編集
 - 用語集定義の「避けるべき用語」を「仕様すべき用語」に置換
 - 同カテゴリの高頻度な用語に置換して翻訳し辞書情報で書き戻す
- 対訳辞書を活用するニューラル機械翻訳機構
 - 辞書中の訳語に対してスコア加点するモデル
 - 語彙制約つき探索
- 学習データへの語彙制約の適用
- 文脈を考慮した翻訳モデル
 - 前の数文の情報を参照する、過去の訳語をキャッシュする、...

4. 長文対策

長文に対する精度低下への対策

11

- 初期の改善：アテンション（注意）機構
 - 「全部覚えてから訳す」から「任意の入力時点を参照可能」に
 - 文分割
 - 長い文を短い単位に分割して翻訳した後、結合する
 - ニューラル機械翻訳以降あまり進展がない
 - 依存（係り受け）構造を制約にした翻訳モデル学習
 - Transformerモデルの位置情報表現の工夫
- ※ 一般には学習時に長文が除外されることも多く注意が必要

5. 低リソース言語対策

(比較的) 単純な方式

13

- カスケード翻訳：別の言語を経由した翻訳
 - 直接対訳の不足を経由言語（ピボット言語）のリソースで補う
 - 英語をピボットとすることが多いが、英→西→カタルーニャ語の研究も
- 学習データの拡張：機械翻訳によるデータの「水増し」
 - 目的言語の文章を原言語に翻訳（逆翻訳）
 - 目的言語側の表現は自然なので言語モデルの面では有効

- 転移学習
 - 別の言語対で作成されたモデルを所望の言語対で追加学習
 - 原言語、目的言語のいずれかを入れ替える
- 多言語モデル
 - 複数の原言語・目的言語の翻訳を単一モデルで行う
 - 副次的に低リソース言語の翻訳性能が向上する例も
- 事前訓練モデル
 - 大量のデータで学習することにより様々なタスクで有効
 - 単言語エンコーダモデル (BERT)
 - 多言語エンコーダ／デコーダモデル (mBART)

6. 評価

- 段階評価
 - 忠実さと流暢さ、容認性
- 相対評価
 - 一対比較、ランキング
- 絶対評価
 - 直接評価（100点満点の点数評価）
- より系統的な評価
 - 多元品質評価尺度 (MQM)、JTF翻訳品質評価ガイドライン
 - 仕様に基づく体系、誤りの種別、深刻さによる重み付けスコア化

- 表層ベース自動評価
 - BLEU、NIST、METEOR、TER、IMPACT、RIBES ... 単語レベル
 - chrF、chrF++ ... 文字レベル
- モデルベース自動評価（汎用モデルをそのまま応用）
 - BERTScore: BERTにより文類似度を計算
 - WE_WPI、MoverScore: 最適輸送を利用
- モデルベース自動評価（汎用モデルを評価にチューニング）
 - RUSE、BERT Regressor、BLEURT、C-SPEC、COMET

- NTCIR-9/10における特許審査評価 (2011, 2013)
 - 拒絶理由として用いられた既存発明の文書を機械翻訳し、拒絶判定根拠が得られるかを実務経験者が判定
- 特許庁「特許文献機械翻訳の品質評価手順」(2014)
 - 忠実さ・流暢さの段階評価 + 重要技術用語の訳質評価
 - 誤りフィードバックのためのチェックリスト
 - 重要情報：技術的要素とそれらの相互関係
 - 国際ワークショップ WAT における JPO Adequacy として利用

7. 翻訳の高速化・省メモリ化

- モデルの小規模化
 - ニューラルネットワークのレイヤー数やベクトル次元数を減らす
- サブワード（単語より短い処理単位）
 - 単語間の共通箇所や活用語尾等を整理、語彙サイズ削減、効率化
- パラメータ共有
 - 同じ処理機構を再利用し、パラメータを増やさずに複雑な計算
- 自己アテンション（注意）機構の高速化 ... 本来は長さの二乗
 - 注意可能範囲の制限、関数の簡略化
- 非自己回帰デコーダ
 - 先頭から順に予測、ではなく出力全体を並列予測

- 知識蒸留（teacher-student approachとも）
 - 小規模モデルに大規模モデルの出力を真似させるよう学習
- 探索空間の削減
 - ビームサーチのビーム幅を小さくし探索を簡略化・高速化
- 出力語彙の動的選択
 - 訳語予測時点の生成候補数を削減し計算量を削減
- ミニバッチ構成法の工夫
 - 同時に処理する文長を揃え、学習時の計算効率を最大化

- 浮動小数点精度の削減：GPU向け
 - 単精度 (32bit) から 半精度 (16bit) に、計算効率も大きく向上
- 量子化：CPU向け
 - 行列乗算時に8ビット整数を利用
- CやC++による実装とメモリ管理
- 計算結果のキャッシュと再利用
- 翻訳コストを競う共通タスクも存在

8. おわりに

- 特許機械翻訳に関わる6つの課題に関する技術を解説
- 利用可能な技術は多く存在するが、実際に特許を対象に検証されている研究は少ない
 - 現在の多くの機械翻訳が共通ベンチマークデータに基づく
- 有望な要素技術は多く存在する
 - タスク間の知見共有と、特許機械翻訳への実用的展開が重要
 - 脱稿後も次々に新しい技術が発表
- 特許文書は特殊な外れ値ではなく、産業上重要な応用先

- 研究会の知見集約と課題整理を目的に実施
 - 2019年12月 Japioとの議論により企画開始
 - 2020年4月 各課題毎のサブグループに分かれ調査執筆開始
(以後研究会定例会合にて進捗報告)
 - 2021年3月 研究会年度報告書にて調査内容報告 (中間)
 - 2022年3月 研究会年度報告書にて調査内容報告 (ほぼ最終)
 - 2022年5月 「自然言語処理」解説論文として投稿
 - 2022年6月 採録決定
 - 2022年9月 出版 (オープンアクセス)
 - 2023年3月 研究会年度報告書にて活動最終報告予定

謝辞と書誌情報（再掲）

26

- 論文共著者の皆様、当研究会関係者に御礼申し上げます
- 内容の詳細は論文をご参照ください

今村賢治、越前谷博、江原暉将、後藤功雄、須藤克仁、
園尾聡、綱川隆司、中澤敏明、二宮崇、王向莉

「特許機械翻訳の課題解決に向けた機械翻訳技術解説」

自然言語処理 29巻 3号 pp. 925-985 (2022)

<https://doi.org/10.5715/jnlp.29.925>（オープンアクセス）

© The association for Natural Language Processing

※ 当該論文は[クリエイティブ・コモンズ 表示 4.0 国際 \(CC BY 4.0\)](https://creativecommons.org/licenses/by/4.0/)で公開されています。