

機械翻訳システムの評価

3W-1

—品質向上にむけて—
田中康仁
兵庫大学

E-mail: yasuhito@humans-kc.hydro-dai.ac.jp

〔0〕はじめに

機械翻訳システムは、多くのコンピュータ企業やソフトウェア会社で作成されている。しかし、これらの品質はさまざまである。また、これについての評価方法、評価方針は決まっていない。これらについて色々と検討する必要がある。このことについて考えてみる。

〔1〕評価の方法について

評価については色々な方法がある。幾つかのものを次に示す。

- (1) 機械翻訳システムを対象に、A, B, Cのランクを付けるための評価
- (2) 機械翻訳システムの利用と使わない方法での費用の分析による評価
- (3) 品質向上のために各機械翻訳システムにはどのような問題点があるか、大量のデータによるテストにより問題点を明確にする。どのような改善をすれば品質が向上するかを評価する。

(4) その他

等の方法がある。

ここでは(3)の方法を基にして考えてみる。しかし、この方法は問題点の指摘であるため、開発者にとってあまり良い気持ちを持ってない。

しかし、問題点を明確にすることが、品質向上に結びつくことを理解していただきたい。

〔2〕機械翻訳システム用評価データ

機械翻訳システムを評価するにあたって重要な点はどのような評価データを集めるかということである。ここでは日本電子化辞書株式会社（EDR）の英文コーパスを用いることにした。この英文コーパスはタグ付けされているが、このタグを取り除いた文を用いた。これを単語数別に分類する。単語数別文の数は次の通りである。

| 単語数 | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 |
|-------|-------|-------|-------|---------|-------|-------|-------|-------|-------|
| 文の数 | 0 | 19 | 460 | 1,889 | 5,030 | 6,798 | 7,791 | 8,416 | 8,698 |
| | 10 | 11 | 12 | 13 | 14 | 15 | 16 | 17 | 18 |
| 9,114 | 9,018 | 9,176 | 9,050 | 8,815 | 8,446 | 8,245 | 7,466 | 6,559 | 5,283 |
| | 19 | 20 | 21 | 22 | 23 | 24 | 25 | 26 | 27 |
| 3,645 | 562 | 464 | 321 | 235 | 142 | 77 | 46 | 23 | 12 |
| | 28 | 29 | 30 | 31 | 32 | 33 | 合計 | | |
| 2 | 0 | 0 | 1 | 125,803 | | | | | |

このコーパスの中で？（疑問符）と！（感嘆符）の付いている文の数を単語数別に調べると次のようになる。

| 単語数 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 |
|------|---|----|-----|-----|-------|-------|-----|-----|-----|-----|
| ？の文数 | 0 | 50 | 314 | 872 | 1,105 | 1,092 | 965 | 811 | 566 | 475 |
| ！の文数 | 1 | 20 | 29 | 45 | 34 | 34 | 17 | 23 | 19 | 16 |

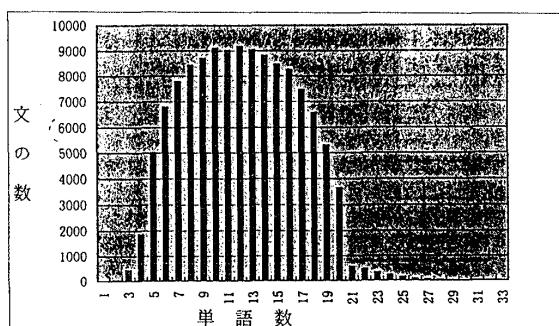
Evaluation Method for Machine Translation System.

— quality up —
Yasuhito Tanaka
Hyogo University

| 12 | 13 | 14 | 15 | 16 | 17 | 18 | 19 | 20 | 21 | 22 |
|-----|-----|-----|-----|-----|----|----|----|----|----|----|
| 322 | 251 | 206 | 156 | 101 | 72 | 71 | 42 | 38 | 5 | 3 |
| 10 | 21 | 7 | 5 | 6 | 2 | 1 | 4 | 1 | 0 | 0 |

| 23 | 24 | 25 | 26 | 27 | 28 | 29 | 30 | 33 | 合計 |
|----|----|----|----|----|----|----|----|----|-------|
| 0 | 0 | 2 | 1 | 0 | 0 | 0 | 0 | 0 | 7,652 |
| 1 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 296 |

疑問文は6単語のものが最も多く、全体的に他の文と比べ短い。感嘆文も5単語のものが最多である。



EDRの英文コーパスを分析した結果、次のような特徴がある。

| | |
|------------|--------------|
| 文の総数 | 125,670文 |
| 最長の文 | 33単語の文 1文 |
| 最短の文 | 2単語の文 19文 |
| 平均単語数 | 12.22単語 |
| 単語数の中央値 | 12単語 |
| 疑問文の数（？の数） | 7,652文 6.09% |
| 感嘆文の数（！の数） | 296文 0.23% |

また単語数が20以上になると急に少なくなっている。さらにEDRコーパスには次の特徴がある。

- (1) 新聞の文に比べ人称代名詞が主語になる文が多い。
- (2) 疑問文、感嘆文の数が多い。
- (3) 単語数が20単語以内のもので99%を占めている。
- (4) 単語数が20以上がきわめて少くなっているのは、EDRコーパス作成時の何らか操作を行ったと思われる。

〔3〕評価の具体的方法について

- (1) ソフトウェアとしての安定性

機械翻訳システムはコンピュータ上で動くソフトウェアである。このためどのようなデータに対しても、ソフトウェアが何の応答もなく終了するということは避けなければならない。

A社のシステムでは、ある特定のデータを処理させると、ソフトウェアが何の応答もなく終了していた。しかし、A社は直ちに新しい版（バージョン）を出してしまい、今では問題なく処理す

るシステムになっている。

(2) 問題点だけの収集

B社のシステムは構文解析、その他の処理で処理不能となると、一定の記号列を表示し、訳語の単語列を表示する処理を行い、次の文の処理に移ってしまった。このため大量のデータを処理してみると、多量の誤りが出現した。そこでEDRの英文コーパスの7単語以内の約2万文の処理中に1,226文見つかった。これらを開発者に送ったところ、次のような返信を得た。

1) EDRの英文コーパスの中に英文字の誤り、編集上の誤りがあった。これは筆者の問題点であった。

2) 省略形 例えは、you'reのようなものについての対応が不十分であることが判明した。また、文の一部が省略されているものもある。これについては対応されていない。

Yes, I certainly will (do). do の省略

3) 一部の文法上の欠点があることが、開発者によって認められた。倒置文に対して弱いということである。

例 Behind every cultural image exists those taboos.

以上のこととは開発者が誤った処理によるデータを検討すれば、ただちに判明するものであった。これは誤った処理を約1,200文集めたからである。約5%の文が処理できていない。誤って処理したデータを分析する中で、一文毎の個別の問題か、それらの中にある共通の問題であるかが判明した。

(3) 訳文の理解度による評価

機械翻訳システムでは「理解度」による評価と「忠実度」による評価がある。ここでは理解度により評価方法を行ってみた。

評価に用いた英文はEDRの英文コーパスを採用し、単語数が2~7のものを用いた。採点は英語の教員が行った。

評価結果 C社の英日翻訳システム

| | 5 | 4 | 3 | 2 | 1 | 合計 | 平均値 |
|-------|--------|-------|-------|------|------|--------|------|
| 2 単語文 | 15 | 1 | 1 | 1 | 1 | 19 | 4.47 |
| 3 単語文 | 336 | 97 | 16 | 11 | 0 | 460 | 4.65 |
| 4 単語文 | 1,369 | 336 | 157 | 25 | 2 | 1,889 | 4.61 |
| 5 単語文 | 3,655 | 808 | 510 | 53 | 4 | 5,030 | 4.60 |
| 6 単語文 | 4,742 | 1,379 | 595 | 81 | 1 | 6,798 | 4.58 |
| 7 単語文 | 4,471 | 2,331 | 870 | 118 | 1 | 7,791 | 4.43 |
| 合計 | 14,588 | 4,952 | 2,149 | 289 | 9 | 21,987 | 4.53 |
| % | 66.35 | 22.52 | 9.77 | 1.31 | 0.04 | 100% | |

評点の高いものが良い結果を示す。

このC社はEDRプロジェクトで中心的役割をはたした会社である。単語数が少ない文であるためか、非常に良い翻訳結果が得られた。しかし、単語数が多くなると少しづつ平均値が下がっている。

この方法では、翻訳結果の良い文と悪い結果の文を分けることがなされるので、悪い結果を集め分析

することにより、改良方法がわかる。個々の文固有の問題点、知識データの不足、文法体系、文解釈等の問題であるかを判別することができる。C社以外の数社について試したところ、C社より平均点で約1点程度低いことがわかった。この1点の差は大きな差である。今後の改良を期待する。

A社、B社、C社とも、この論文を作成した時点から版(バージョン)が更新され少しづつ良くなっている。このような実験を行うと、このデータについては改良がなされるため、さらに新しいテストデータを準備しなければならない。

最近では大量のWWWが作られているのでこの英文を集め、単語数別に整理し、同一の文はまとめ、頻度をつけてテストデータとして利用することもできる。

筆者の友人もWWWから242MBのデータを集めてくれた。これは参考になるものである。

[4] おわりに

機械翻訳システム(英→日)のテストを行い評価を行った。大量の英文データを単語数別に分析し、整理し、単語数の少ないものから順次テストするという方法を考えついた。これにより機械翻訳システム(英→日)の品質の向上をはかる一つの方法ができた。

さらに色々な方法を考えてみたい。これら試行から、大量の日英対訳付コーパスを作成しなければならないこともわかった。また、市販されているCD-ROMを機械翻訳のテストに利用するのも一つの方法である。

[5] 参考文献

- (1) 安田賀計 らくらく使えるビジネス文書1,230文例 CD-ROM 日本経済新聞社
- (2) 田久保浩平、橋本光憲 英文ビジネスレター文例大辞典 CD-ROM 日本経済新聞社 15,000文
- (3) 塩澤 正、スコット シェフェルバイン インターネット英語表現辞典 三修社 1998年1月
- (4) 新編英和活用大辞典(自然な英文を書くための38万例) CD-ROM版 研究社 1996年
- (5) 社 日本電子工業振興協会 「自然言語処理システムの動向に関する調査報告書」 平成9年4月
- (6) 牧野武則 評価技術 「機械翻訳」 Bit別冊 共立出版 1988年9月
- (7) 長尾 真 「機械翻訳はどこまで可能か」 岩波出版 1986年6月

[6] データについて

英文データは日本電子化辞書の英文コーパスを利用した。

日本電子化辞書のプロジェクトに参加した企業がEDR英文コーパスをあまり利用していない。翻訳システムにもっと活用してほしいものである。

EDRコーパスには日本語のコーパスもある。これを日英機械翻訳システムに利用すべきである。