

2 E-4

外電経済ニュースの英日機械翻訳

加藤 直人*

鎌田 雅子**

相沢 輝昭*

* NHK放送技術研究所

** (株) 漢字情報サービス

1. はじめに

毎日大量に入ってくる外電に対応するために、機械翻訳のニーズが高まっている。外電で送られてくるニュースは政治、経済、スポーツ等多岐にわたっており、使われる語や言い回しも様々である。経済ニュースに関してみると、

- ・特殊な文型を持っている。
- ・高品質の翻訳を得るために特別な日本語訳が必要である。

等の特徴がある。これらは機械翻訳にとって困難な問題であり、実際に翻訳率も低い。(我々の翻訳システムの場合、約20%である。)しかし、これらの特徴を分析して利用すれば翻訳率の向上が期待できる。

本稿では、外電の経済ニュースに的を絞り、その特徴を利用した、外電経済ニュース英日機械翻訳システムについて述べる。

2. 経済ニュース翻訳システム概要

AP電は一日350ほどのニュースが入電し、経済ニュースはそのうち50ほどである。各ニュースには必ずタイトルがついており、そのニュースの特徴を表している。なかでも表ニュースでは例えば「ゴルフの結果」、「株の取引価格」など、経済ニュースでは「金価格」、「日本市場」など、毎日固定したタイトルが使われる。したがって、タイトルによって自動的に表ニュースや経済ニュースを選別することができる。

図1に外電経済ニュース翻訳システムの処理の流れを示す。

本システムでは始めにタイトルによって、表ニュース、経済ニュース、一般ニュースの3種類にニュースを分類する。表ニュースは表翻訳ルーチンに進み、英単語を日本語に一対一に単純に置き換える処理のみが行なわれる。(今回は、表ニュースの中でも経済に関係するものしか扱わなかった。)一般ニュースは従来からの機械翻訳システムで処理される。

English to Japanese machine translation system
for economic news of AP wire service
Naoto KATOH*, Masako KAMATA**
and Teruaki AIZAWA**
*NHK Science and Technical Research Laboratories
**Kanji Information Service Co., Ltd.

経済ニュースに関しては以下で説明する3つの処理を行ない、いずれかの処理で翻訳された場合には、結果を出力し以降の処理を中止する。

処理1は、主に数量表現や時間表現のみが変化するような定型文を翻訳の対象とおり、形容詞や副詞などが1つでも付加されたような文は翻訳できない。そこで処理2では若干の柔軟性を持たせるために、定型文に完全に一致しない場合でも翻訳できるよう文法や辞書を作成した。これらいずれの処理でも翻訳されなかった文は、処理3で一般の文を処理する過程と全く同じ翻訳が行なわれる。

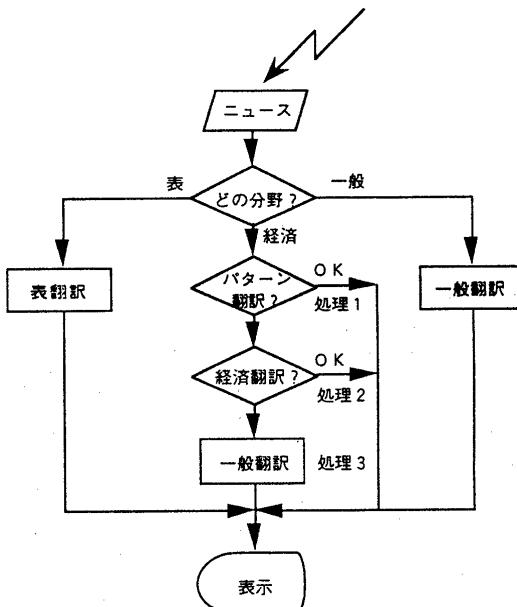


図1 外電経済ニュース英日機械翻訳システム

3. 各翻訳処理

各処理における諸元を表1に示す。

3. 1 処理1の諸元

経済ニュースには定型文が非常に多く、このような英文はその日本語の訳文を与えておき、単純に数量表現や時間表現等の変化部分のみを置き換えるだけで翻訳できる¹⁾。そこで、出現頻度が高い経済ニュース文のうち上位400文に対して日本語訳を入手で与え、定型パターンの英語テンプレートと日本語テンプレートを自動的に作成した。テンプレートの数を増やすればカバーできる文の数も増える。

その例の一部を図 2 に示す。

☆入力 (英文とその日本語訳)	
英文	
"Earlier, in Hong Kong, gold closed at 419.85 dollars an ounce, up from 417.65 dollars"	
日本語訳 「それより先香港では、金は417.65ドルから上昇し、1オンス419.85ドルで引けた」	
★出力 (英語テンプレートと日本語テンプレート)	
S→PAT1 REG PAT2 UNTEXP PAT3 UPDW PAT4 MUNTEXP PAT1→Earlier , in 「」 REG→Hong Kong 「香港」 PAT2→, gold closed at 「」 UNTEXP→419.85 dollars an ounce 「1オンス419.85ドル」 PAT3→, 「」 UPDW→up 「上昇」 PAT4→from 「」 MUNTEXP→417.65 dollars 「417.65ドル」	

図 2 テンプレート作成例

テンプレートを作成する際に、単純に数字のみを置き換えずに、数量表現を変数にしたのには

- ・原文とは異なる数量表現でも翻訳できるようになる。
- ・数字のみにすると、同じ数字が1つの英文中に2度出現した場合、どの数字がどの日本語訳に対応するか曖昧になる。

という理由による。

3. 2 処理 2 の諸元²⁾

ここで使用する文法ルールと辞書は、'91年4月23日～25日のA P電3日分（約450文が含まれている）を用いて作成した。経済ニュース用に文法ルールと辞書をチューニングするために使った、この3日分のデータを、以下では学習データと呼ぶ。解析できる文の種類を少なくすることによりルール数を少なくすることができ、またルール上で前置詞句の係り先もかなり特定できたので、構文的曖昧性を抑えることができた。しかし、システムの制約上、このすべての文を翻訳することができるよう文法ルールや辞書を作成できたわけではない。また、従来の文法ルールでは正確に構文解析できる文でも、経済用文法ルールで誤って解析されるという問題も生まれてくるであろう。

3. 3 処理 3 の諸元

処理 3 は従来の翻訳システムである。辞書は、処理 2 で使用した経済専門辞書の名詞のみを含む大規模のものを用い、文法ルールも一般的のものである。一般文も処理 3 と同様に処理される。

表 1 各翻訳処理の諸元

	翻訳方式	文法	辞書	処理速度
処理 1	解析：パターンマッチング 生成：代入	対訳パターン 約400 局所解析用 約60	1,400 (局所解析用) 1,900 (対訳データ)	5秒／文
処理 2	トランスファー方式	約500	基本語 57,000 経済語 31,000	10秒／文
処理 3	トランスファー方式	約2,500	基本語 57,000 専門語 111,000	20秒／文

4. 評価

学習データと非学習データ ('91年3月7日のA P電、約160文) に対する処理別処理率と翻訳率を表 2 に示す。ここで評価にはMuプロジェクトの方法を用い、評価値上位2つを正解とした。

表 2 処理過程別処理率と翻訳率 (単位 %)

	処理 1	処理 2	処理 3	TOTAL
学習	処理率 29.1	61.3	9.6	100
	翻訳率 100	70.1	10.2	73.0
未学習	処理率 31.2	57.5	11.3	100
	翻訳率 100	58.7	22.2	66.3

学習データでは約30%の文が処理 1 で翻訳され、約60%の文が処理 2 で翻訳されている。翻訳率は処理 1 では当然のことながら 100%，処理 2 では約 70% である。全体の翻訳率は約 73% と高い。

学習データでも非学習データでも各処理における処理率はほとんど同じである。非学習データでは学習データに比べると処理 2 の翻訳率が 10% 低くなっているのに伴い、全体の翻訳率も約 10% 下がっているものの、従来の翻訳率に比べ格段に向上している。処理 3 に残った文は非常に長いものが多かった。

5. おわりに

外電経済ニュースの機械翻訳について述べた。経済ニュースは特有な文型を持っている場合が多く、その特徴を使うことによって従来より翻訳率が格段に上がった。

今後はスポーツニュース、一般のニュースも同様な方法が適用できないかどうかを検討し、外電ニュースの翻訳率向上をめざす。

[参考文献]

- 1) 加藤、浦谷「定型パターンを含むニュース文の抽出とその英日機械翻訳」情報処理学会第44回全国大会(1992)
- 2) 相沢、鎌田「A P電経済ニュースの英語解析用文法」情報処理学会第45回全国大会(1992)