

相対的意味論と機械翻訳の応用

村上仁一

鳥取大学 工学部

murakami@tottori-u.ac.jp

1 はじめに

本論文では、語彙の意味を、説明するために、相対的意味表現と、絶対的意味表現について述べる。次に、これらの方法でも、説明できない語彙に対し、2言語を利用した方法をしめす。そして、この方法を利用した翻訳方法について述べる。具体的には、“相対的意味論に基づく変換主導型統計翻訳(TDSMT)”と、“相対的意味論に基づく統計翻訳(RSMT)”の方法について述べる。最後に相対的意味論とNMT(Natural Network Machine Translation)の関係を検討する。

2 語彙の意味と辞書

2.1 辞書学と意味表現

辞書は、現在や過去において、使用された語彙を収集し、その品詞・意味・背景(語源等)・使用法(用例)・派生語・等を解説した書籍である。基本的には、語彙は、他の語彙を利用して、解説する。1つの辞書において、解説文には、出来るだけ統一をとるように収集される。

語彙について何らかの記述をするための言語を、メタ言語と呼ぶ。初めに、語彙とメタ言語が、同一言語の場合の例を示す。そして、語彙の意味を絶対的意味表現と相対的意味表現をもちいて述べる。

2.2 絶対的意味表現

絶対的意味表現とは、単語の語彙の意味を具体的な他の語彙で表現する。この表現方法は、基本的には、理解しやすい。以下は、絶対的意味表現の例である。

青 - 波長 400nm 近辺の光
赤 - 波長 800nm 近辺の光

多くの語彙は、絶対的意味表現で、表現できる。しかし、意味の表現が困難な語彙も多い。以下は、その例である。

右^[1]

- 南を向いたとき、西にあたる方(広辞苑)
- アナログ時計の1時から5時までの表示がある側。(新明解国語辞典)
- この辞書を開いて読むとき、偶数のページのある側(岩波国語辞典)

左

- 南に向かったとき、東にあたる方(旺文社国語辞典)
- アナログ時計の文字盤に向かった時に、七時から十一時までの表示のある側。(新明解国語辞典)
- この辞典を開いて読む時、奇数ページのある側。(岩波国語辞典)

いずれの説明も、曖昧な点が残る。(例えば、“南”とは?) 似た語彙として“上”“下”などがある。

2.3 相対的意味表現

相対的意味表現とは、単語の意味を、お互いに相反する単語で表現する方法である。例を以下に述べる。

右 - 左の反対
左 - 右の反対

絶対的意味表現で困難な語彙は、相対的意味表現で表現可能な場合が多い。しかし、この表現方法は、説明がループするため、“煙を蒔いたような表現”と言って嫌悪する人も多い。

また、語彙の中には、対的意味表現を用いても、説明できない語彙がある。以下は、その例である。

人間

- ひと 人類
- 遺伝的な両親が人間である人
- 考える輩

いずれの説明も、疑問点が残る。このように、“人間”の意味を説明することは、非常に困難である。¹⁾

2.4 2言語を用いた意味表現

単言語では説明するのが困難な語彙は、2言語を利用して表現することが可能な場合がある。例を以下に挙げる。

- “人間”とは“human”である。

以下に、2言語を用いた例を示す。

“右”とは“right”である。

“犬”とは“dog”である。

“動物”とは“animal”である。

しかし、“犬”には別の意味がある。

“犬”とは“spy”である。

このように、2言語をもちても、語彙に複数の意味があるとき、一意に表現できない。

2.5 2言語を用いた相対的意味表現

単言語において、複数の意味があるとき、2言語を用いた意味表現では、1意に表現できない。このような場合、2言語の相対的意味を用いて表現できる。

“aがbならばcはd”

これを“2言語を用いた相対的意味表現”と呼んでいる。

例を以下に示す。

1. “右”が“right”ならば“左”は“left”
2. “犬”が“dog”ならば“猫”は“cat”

1) 個人的には、2番目の説明が好みである。

3. “犬”が“Canis”ならば“猫”は“Felis”
4. “犬”が“spy”ならば“猫”は“sex decoy”

3 2言語を用いた相対的意味表現の辞書(変換テーブル)

3.1 変換テーブルと文法

本研究では、語彙を2言語を用いた相対的意味表現に基づいて、考える。これを以下のように表現する。

- “aがbならばcはd ただしa,b,c,dは単語”

この辞書を“変換テーブル”と呼んでいる。

例を以下に示す。

a:犬 b:dog c:猫 d:cat

a:犬 b:Canidae c:猫 d:Felis

dogとcatは、哺乳類である。Canisは犬科で、Felisは猫科である。この例では、名詞の意味的な階層の情報が変換テーブルに含まれる。

a:彼 b:he c:彼女 d:she

a:彼 b:him c:彼女 d:her

この例では、代名詞の文法が変換テーブルに含まれる。

a:走る b:run c:歩く d:walk

a:走った b:ran c:歩いた d:walked

この例では、時制の文法が変換テーブルに含まれる。

これらの例から、変換テーブルには、文法や属性や意味の情報が含まれることがわかる。なお、文脈に応じた情報も含めることができると、考えている。

3.2 変換テーブルの作成方法

変換テーブルは、手動で作成できる。しかし、自動的に作成する方法がある。その方法の1つに、文パターンを利用して作成する方法がある。作成方法を以下に示す。

1. 学習文1を準備する。
 - 彼は山にいった。
 - He went to mountain.
2. 対訳単語を準備する。

a: 山 b: mountain
3. 文パターンを作成する。
 - 彼はNにいった。
 - He went to N
4. 学習文2を準備する。
 - 彼は海にいった。
 - He went to sea.
5. 学習文1と文パターンと学習文2から、以下の変換テーブルを作成する。

a:山 b: mountain c:海 d: sea

4 相対的意味論を用いた変換主導型機械翻訳(TDSMT)[2]

変換テーブルは、文中の単語の置換可能な辞書として捕らえることができる。したがって、変換テーブルの応用として、機械翻訳がある。以下に相対的意味論を用いた変換主導型機械翻訳(Transfer Driven with Relative Meaning using Statistica Machine Translation 以後TDSMT)の概念を述べる。例として、日英翻訳を考える。

2) なお、“犬”が“spy”ならば“猫”は“Mata Hari”は面白い

4.1 TDSMTの基本概念

基本概念を、以下に述べる。

- AがBならばCはDである。
- A,B,C,Dは文である。
- a,b,c,dは単語もしくは句である。
- 入力文はCで、翻訳文はDになる。

以下に例を示す。

1. 入力文

日英翻訳において、以下の日本語の翻訳を想定する。

C ショウジョウハエは林檎が好きだ
2. 学習文

学習文として 以下の対訳文を想定する。

A 私は林檎が好きだ

BI like an apple
3. 変換テーブル

以下の変換テーブルを想定する。

a: 私 b: I c: ショウジョウハエ d: Fruit flies
4. 変換規則

以下の変換規則を想定する。

Aにaを適用し、Bにbを適用できたならば、Cにcを適用し、Dにdを適用する。
5. 出力文(翻訳文)

以上の結果から以下の出力文(英文)を得る。

 - Fruit flies like an apple

4.2 TDSMTの一般形式

TDSMTでは、以下を基本概念とする。

- AがBならばCはD
 - ただしA,B,C,Dは文
- Cは入力文、Dは出力文
- A対訳学習文の日本語
B対訳学習文の英文
C入力日本語文
D出力の英文(翻訳文)
- aがbならばcはd
 - ただしa,b,c,dは単語もしくは句

a対訳学習文の日本語単語
b対訳学習文の英語単語
c入力日本語単語
d出力の英語単語

以下の変換規則を想定する。

- Aにaを適用し、Bにbを適用できたならば、Cにcを適用し、Dにdを適用できる。

4.3 TDSMTの例

A ツバメは矢のように飛ぶ
B Swallow flies like an arrow
C 時間は矢のように飛ぶ
D Time flies like an arrow

a: ツバメ b: Swallow c: 時間 d: Time

“Time flies like an arrow”の訳として“時蠅、矢を好む”がある。この訳は、非文と考えられる。しかし、なぜ、非文と考えられるのだろうか？通常は、“時蠅”が存在しない

から、非文とする。しかし、存在しないことの証明は、困難である。

相対的意味論の考えかたは、“ツバメは矢のように飛ぶ”があるから、“時間は矢のように飛ぶ”と訳すことができると解釈する。

4.4 TDSMT の動作例

実際の文章に TDSMT を使って翻訳した例を以下に示す。

- A 風が北から南に変わった
- B The wind changed from north to south
- C 信号が青より赤に変わった
- D The signal changed from green to red

使用した変換テーブルを以下に示す。

	a	b	c	d
1	風	wind	信号	signal
2	北	north	青	green
3	から	from	より	from
4	南	south	赤	red

現実の TDSMT の翻訳結果を見ると、それぞれの変換テーブルにおいて、やや奇異に思われる点がある。

1. “信号”と“風”は、あまり類似していると思えない。
2. “青”と“北”は、あまり類似していると思えない。
3. 通常、“より”は“than”と訳される。
4. 通常、“青”は“blue”と訳される。

このように、実際に利用される変換テーブルは、人間の直感と、少し異なる。

4.5 TDSMT の問題

1. 語彙数
一般の単語辞書の見出し語は、約 10 万単語である。したがって、変換テーブルの数は 100 億単語が必要になる。(10 万 × 10 万) この数の、精度の高い変換テーブルを収集することは、困難である。
2. 直感との差
実際に翻訳に利用される変換テーブルは、人間の直感と、少し異なる場合がある 4.4 章。

5 相対的意味論に基づく統計翻訳 (RSMT)

5.1 基本的な考え方

TDSMT は、変換テーブルの数と精度が問題になる。しかし、相対的意味論は、魅力のある考え方である。そこで、この考え方を、文に適用する。そして変換テーブルは使用しない。変換テーブルの代わりに、翻訳確率と類似度を利用する。この翻訳方式を相対的意味論に基づく統計翻訳 Relative Meaning Statistica Machine Translation (以後 RSMT) と呼んでいる。以下に RSMT の基本的な概念を述べる。

- A が B ならば C は D
- ただし A, B, C, D は文
- A 対訳学習文の日本語
- B 対訳学習文の英語
- C 入力日本語
- D 出力英文 (翻訳文)

- A と C は同一言語において類似
- A と B は 2 言語の翻訳において類似
- B と D は同一言語において類似
- C と D は 2 言語の翻訳において類似

以下に例を述べる。

- A 私は林檎が好きだ
- B I like an apple
- C ショウジョウハエは林檎が好きだ
- D Fruit flies like an apple

この例では、以下のように解釈する。

1. “私は林檎が好きだ”と“ショウジョウハエは林檎が好きだ”は類似している。
2. “私は林檎が好きだ”に対する“I like an apple”の翻訳確率は高い。
3. “ショウジョウハエは林檎が好きだ”に対する“Fruit flies like an apple”の翻訳確率は高い。
4. “I like an apple”と“Fruit flies like an apple”は類似している。
5. 以上 4 点を考慮して、“ショウジョウハエは林檎が好きだ”を入力したとき、“Fruit flies like an apple”が翻訳文である。

5.2 実際の RSMT

5.2.1 出力英文

理想的な RSMT において、“D 出力英文”は、生成可能なすべての英文から、選択する。語彙を 10^5 と考えて、1 文は 10 単語で構成されると仮定すると、 $10^{50}((10^5)^{10})$ 文から選択することになる。また、A および B は、大量の対訳学習文から、最適な文を選択する。通常は、 10^6 文あたりが想定できる。

この数字は、現実的には計算不可能である。そこで、あらかじめ、“C 入力日本語”を、“別の機械翻訳”で翻訳し、複数の出力英文を得る。これから“D 出力英文”として、RSMT を動作して A と B を選択する。この“別の機械翻訳”には、NMT や Phrase Based SMT や rule base MT などが可能である。したがって実際の RSMT は、複数の翻訳候補文から、最終的な出力英文 (翻訳文) を選択する形になる。

5.2.2 文の翻訳確率 $Sim(CD_j)$

文 C と文 D_j の文の翻訳確率は、多くの計算方法が考えられる。基本的には、文の翻訳確率とみなせる。例えば NMT の翻訳確率も利用できる。本論文では、線形性を考えて、以下の式を利用している。

$$Sim(C_m D_{jn}) = \frac{\sum_{i=0}^M \sum_{j=0}^N \log_2(\text{Count}(C_m D_{jn}) / (\text{Count}(C_m) \times \text{Count}(D_{jn})))}{\text{Count}(C_m D_{jn})}$$

対訳データベース中において
 C_m と D_{jn} が同時に出現する回数

$\text{Count}(C_m)$ データベース中の C_m の出現回数
 C_m 文 C の m 番目の単語
M 文 C の単語数
 D_{jn} 文 D_j の n 番目の単語
N 文 D_j の単語数

5.2.3 文の類似度 $Sim(CA_i)$

文 C と文 A_i の文の類似度は、多くの計算方法が考えられる。最近では Word2vec を利用した距離尺度が多い。また BLEU を利用した距離尺度も考えられる。本論文では、線形性を考慮して、以下の式を利用している。

$$Sim(CA_i) = \sum_{i=0}^M \text{CountNum}(CA_i) / \text{CountALL}(A_i)$$

$\text{CountNum}(CA_i)$ 文 C と文 A_i が一致する単語数
 $\text{CountALL}A_i$ 文 A_i の単語数
 M 文 A の文数

5.3 RSMT の実働例

以下に RSMT の例を示す。C は入力文で、D は出力文 (翻訳出力) である。

A 信号が青から赤にぱっと変わった。
B The traffic light jumped from green to red .
C 信号が青より赤に変わった。
D The signal changed from green to red .

- $sim(AC) = -1.807355$
- $sim(BD) = -3.321930$
- $trans(CA) = -75.601800$
- $trans(BD) = -1.041353$

5.4 RSMT の長所

RSMT の長所を挙げる。

1. 修正の容易さ

翻訳した場合、その翻訳に近い翻訳文が表示される。そのため、誤った翻訳が出力されても、人手で用意に変更箇所が解る。

A 彼は我を通した。
B He had his own way .
C 彼女は我を通した。
D She had his own way .

正解文は “She had her own way” である。この例文では “his” を “her” に書き換えるのは容易と考えている。

2. N-BEST

RSMT では 1 位候補が間違っているても、2 位候補が正しい場合が多い。例を以下に示す。

C ぶらんこが揺れている。
D₁ The swing is flicking .
A₁ 炎が揺れている。
B₁ The flame is flickering .
D₂ The swing is swining .
A₂ ハンモックが揺れていた。
B₂ The hammock was swinging .

この例では正解が第 2 候補にある。

3. 人手評価と自動評価の差

自動評価では、評価できない良さがある。人手評価では、通常の NMT を超える場合が多い。

5.5 RSMT の問題点

以下に RSMT の問題点を示す。

ある単語と、ある単語が共起する確率が高いとき、この単語を削除することは、困難である。例を以下の述べる。

A 彼は我を通した。
B He had his own way .
C 彼女は我を通した。
D She had his own way .

この例では “我” を “his” と翻訳している。学習データに “我” を “his” の共起の確率が高い場合、この “我” を “her” と翻訳することは困難である。

A 炎が揺れている。
B The flame is flickering .
C ぶらんこが揺れている。
D The swing is flicking .

この例では “ぶらんこ” が “揺れている” を “flicking” と翻訳している。学習データに “揺れている” と “flicking” の共起の確率が高い場合、 “揺れている” と “swinging” と訳することは、困難である。

6 考察 - 相対的意味論と NMT

NMT は、現在、尤も普遍的に使われている翻訳システムである。この翻訳システムを、相対的意味論的に考えると、A と B が複数ある場合の C と D の関係として捕らえることが可能である。NMT の学習データは A,B に相当する。C は入力文で、D は出力文 (翻訳文) である。そして、文の類似確率と翻訳確率は、非線形関数であり、Nural Network で類推している。つまり、5.1 章における、A,B を明示しない翻訳システムである。

例を以下に示す。学習データを 2 文とする。C は入力文で、D は出力文である。

A₁ 彼は山にいった。
B₁ He went to mountain
A₂ 彼女は海にいった
B₂ She went to sea
C 彼は海にいった
D He went to sea

この例では以下のように考える。

“彼は山にいった。” と “He went to mountain”, と “彼女は海にいった” と “She went to sea” が、存在するから、 “彼は海にいった” は “He went to sea” と翻訳できる。

この考え方は、NMT における、別の見識を持てる。

7 まとめ

本論文では、相対的意味論に基づく統計翻訳 (RSMT) の考え方をまとめた。RSMT は、文の相対的意味論を利用している。そして “A が B ならば C は D” を想定している。そして、文の翻訳確率と文の類似度を利用して、出力文 (翻訳文) を選択する。ただし、文の翻訳確率と文の類似度には、多くの計算方法がある。また、相対的意味論は、NMT の別の見方が可能になる。また、多くの分野で、応用が可能である。これらの分野を追求していきたい。

参考文献

- [1] 三浦しをん. 舟を編む. 光文社 ISBN-10 4334927769, 2011.
- [2] 安場裕人, 村上仁一. 相対的意味論に基づく変換主導型統計機械翻訳～未知語の出力. 言語処理学会第 25 回年次大会, No. A5-4, 2019.