

語彙的対応関係の一般化に基づく 言い換え知識の拡張

藤田 篤

Pierre Isabelle




情報通信研究機構

National Research Council Canada


今日の話題

■ 与えられた言い換え知識の自動拡張

- 言い換え知識: 言い換え関係にある表現の対の集合
- 提案手法
 - 関係ありそうな語の対の抽象化



- 大規模単言語コーパスからの具体例の抽出



● 実験結果

- 規模: コーパスの規模によるが100倍のオーダーは達成可能
- 精度: ナイーブな使い方でも従来手法と同程度以上

背景と動機

言い換え:概ね同じ意味内容を表す言語表現

■ 語や語の列

The roof **looks like** a prehistoric lizard's spine.

The roof **resembles** a prehistoric lizard's spine.

■ 節内の構造変換

Employment **showed a sharp decrease**.

Employment **decreased sharply**.

The car **collided with** the bicycle.

The car **and** the bicycle **collided**.

■ 複数の節にまたがる構造変換


It was his best suit **that** John wore to the dance last night.

John wore his best suit to the dance last night.


言い換え(生成)に必要な知識

■ とくに言い換え知識

- 言い換え関係にある表現の集合(一般に対)の集合
 - 何らかの文脈で同義かつ置き換え可能
- 一般に文よりも小さなテキスト断片
 - 表層表現 (構造情報を含む場合も)



■ パターン, テンプレート



言い換え知識の自動獲得の研究動向

■ 獲得元

- (シソーラス)
- 単言語(シングル)コーパス
- 単言語パラレルコーパス
- 単言語コンパラブルコーパス
- 異言語パラレルコーパス (対訳コーパス)

■ 手がかり

- 周辺文脈 [Harris, 54][Lin+, 01]
- 共通の翻訳 [Barzilay+, 01][Bannard+, 05][Callison-Burch, 08]
- 概念, トピック, 用語 [Shinyama+, 02][Hashimoto+, 11]

単言語シングル + 分布仮説

■ 分布仮説 [Harris, 54]

- “類似する文脈でよく使われる表現は似た意味を持つ”
 - 文脈素性: 左右の隣接 n-gram, 構造上の隣接要素
- e.g., “Tezgüno” [Pantel+, 02]
 - wine, cognac, whiskey と似ている → アルコール飲料

A bottle of **tezgüno** is on the table

Everyone likes **tezgüno**

Tezgüno makes you drunk

We make **tezgüno** out of corn

- 同義とは限らない: e.g., 反義語, 上位下位語




異言語パラレル + アライメント

■ 翻訳を意味表現として用いる [Bannard+, 05]

- 分布仮説における「文脈」よりも信頼できる
 - 多義性の問題は残る
- 対訳コーパスから自動的に獲得可能
 - 単語アライメント + 対訳句対の抽出
- 対訳コーパス << 単言語コーパス

自動的に学習したフレーズテーブル

health issue		problème de santé
health problem		problème de santé
regional issue		problème régional
regional problem		problème régional



単言語コンパラブル + アライメント

■ 複数の語釈文の対応付け

- 複数の辞書における語釈文 [Murata+, 04]
- Webから得た定義文 [Hashimoto+, 11][Yan+, 13]
- コンパラブルコーパス << シングルコーパス

Osteoporosis

a disease that decreases the quantity of bone and makes bones fragile

a disease that reduces bone mass and increases the risk of bone fracture



decreases the quantity of bone

reduces bone mass

makes bones fragile

increases the risk of bone fracture

カバレッジと精度の両立が課題

■ 単言語コーパス + 分布仮説

- Pro. 大規模コーパス → 高カバレッジ
- Con. 周辺文脈の類似性は弱い手がかかり → 低精度
 - e.g., 反義語, 上位下位語も似た文脈で使われる

■ パラレル/コンパラブルコーパス + アラインメント

- Pro. 文単位と同義性/類義性 → 高精度
- Con. 規模に限られる → 低カバレッジ

品質を保ったまま知識を拡張する


与えられた言い換え知識の拡張

■ タスクの定義


- 入力: 高品質な言い換え知識
- 出力: 新たな言い換え知識

■ 提案手法

- 関係ありそうな語の対の抽象化



- 大規模単言語コーパスからの具体例の抽出



手続き



S_{Seed} : 種となる言い換え表現対の集合

airports in Europe $\Leftrightarrow$ European airports
amendment of regulation $\Leftrightarrow$ amending regulation
should be noted that $\Leftrightarrow$ is worth noting that

↓ Step 1. 言い換えパターンの獲得
言い換えパターン

$X:\phi$ in $Y:\phi \Leftrightarrow Y:an\ X:\phi$
 $X:ment\ of\ Y:\phi \Leftrightarrow X:ing\ Y:\phi$
should be $X:ed$ that $\Leftrightarrow$ is worth $X:ing$ that

↓ Step 2. 新規言い換え表現対の収集

S_{LV} : 新規言い換え表現対の集合


cohesion in Europe $\Leftrightarrow$ European cohesion
democracy in Europe $\Leftrightarrow$ European democracy
increase in Haiti $\Leftrightarrow$ Haitian increase
transportation in suburb $\Leftrightarrow$ suburban transportation
economy in Uruguay $\Leftrightarrow$ Uruguayan economy
amendment of documents $\Leftrightarrow$ amending documents
amendment of protocol $\Leftrightarrow$ amending protocol
investment of resources $\Leftrightarrow$ investing resources
recruitment of engineers $\Leftrightarrow$ recruiting engineers
should be highlighted that $\Leftrightarrow$ is worth highlighting that
should be reiterated that $\Leftrightarrow$ is worth reiterating that
should be stated that $\Leftrightarrow$ is worth stating that

Step 1. 言い換えパターンの獲得

■ 種となる(高品質な)言い換え表現対の集合 (S_{Seed})

→ 言い換えパターンの集合

- 両辺において対応関係にある語を変数化
- 作業仮説: 言い換え表現対の各辺にあり、
同じ語幹を持つ語の対は、特定の(意味的な)関係を持つ



対応関係のある語の同定

■ 語幹を厳密には同定せず，文字ベースの候補生成

- (“**th**at”, “**th**is”) → (“**X**:at”, “**X**:is”) / “**th**”
- (“oblig**e**”, “forc**e**”) → (“oblig:**X**”, “forc:**X**”) / “**e**”
- (“**amend**ment”, “**amend**ing”) → (“**X**:ment”, “**X**:ing”) / “**amend**”
- (“unc**clear**”, “**clear**”) → (“un:**X**”, “φ:**X**”) / “**clear**”

■ 接辞パターン候補のフィルタリング

- 長さ k 以上の語幹 n 種類に対して観察された接辞パターン候補のみを残す [Gaussier, 99]
 - k : 共通部分の最小文字数 (5)
 - n : 語幹の種類 (2)

自動的に同定した語対の例



$X:\phi$ in $Y:\phi$ $\longleftrightarrow$ $Y:\text{an } X:\phi$

- (“Haiti”, “Haitian”), (“Tibet”, “Tibetan”),
 (“Uruguay”, “Uruguayan”), (“Chicago”, “Chicagoan”),
 (“Elizabeth”, “Elizabethan”), (“suburb”, “suburban”)



$X:\text{ment of } Y:\phi$ $\longleftrightarrow$ $X:\text{ing } Y:\phi$

- (“development”, “developing”), (“treatment”, “treating”),
 (“payment”, “paying”), (“employment”, “employing”),
 (“investment”, “investing”)




$X:\text{able } Y:\phi$ $\longleftrightarrow$ $Y:\phi$ which can be $X:\text{ed}$

- (“adjustable”, “adjusted”), (“reportable”, “reported”),
 (“playable”, “played”), (“diversifiable”, “diversified”),
 (“recordable”, “recorded”)

Step 2. 新規言い換え表現対の収集

- 言い換えパターンの集合 + 単言語コーパス
→ 新規言い換え表現対の集合 (S_{LV})
 - 各パターンの両辺にマッチする表現を抽出
 - 両表現の存在性を重要視
 - 各対の信頼性を文脈類似度で定量化



信頼性: 表現の存在性と表現対の類似性

- 表現の存在性: コーパス中に一定回数出現
- 表現対の類似性: 文脈類似度
 - 文脈素性: 隣接する左右トークンn-gram [Marton+, 09]
 - cf. bag-of-words: 安価だがノイジー
 - cf. 依存構造上の隣接要素: 正確だが高価

There have been many approaches to compute the similarity between words based on their distribution in a corpus.



to between


- ベクトルの比較: コサイン類似度, Jaccard係数, etc.

先行研究 (1)


■ 表現の外側に変数を制約として付加

- 元の表層表現のスコアリングのために変数を付加
[Lin+, 01][Ravichandran+, 02][Szpektor+, 04]

- Similarity(“find a solution to”, “solve”)
=def GeoMean(Similarity(X_1 , X_2), Similarity(Y_1 , Y_2))



- 両者が置換可能な条件を特定 [Callison-Burch, 08][Zhao+, 09]
 - “create equal” が右側のNPを含まないVPで,
そのNPがその右側の複数形の名詞句(NNS)を含まないならば,
“creating equal” に置換可能




- 集合拡張の諸手法も対象の外側の抽象化 (≡ 文脈類似度)

先行研究 (2)

■ 人間による帰納 [Jacquemin, 99][Fujita+, 07]

- 言い換えにおける派生語間の関係に着目
- 高コスト，言語依存
 - 関数の実体となる辞書も人間が編纂



提案手法の特徴

■ 全自動・教師なし

- ごく少数のパラメタ (カバレッジと精度のバランス)

■ 種々の語彙的対応関係をカバー

- 派生語
- 語形変化 (e.g., 数, 性, 格)
- 異表記 (e.g., -nize/-nise)

■ 単言語コーパスが大きいほどレバレッジが効く

- 対訳コーパスを大きくするよりも安価

英語の言い換え知識獲得実験 規模・精度

Step 0. 種となる言い換え知識の獲得

- 異言語パラレルコーパス(対訳コーパス)
→ 種となる(高品質な)言い換え表現対の集合 (S_{Seed})
 - Bilingual pivoting [Bannard+, 05]



- 各種クリーニング [Fujita+, 12]

- ストップリスト
- 言い換え確率

$$p(e_2|e_1) = \sum_{f \in tr(e_1) \cap tr(e_2)} p(e_2|f)p(f|e_1)$$

データ

コーパス (2種類の設定)

- Europarl (En-Fr)
 - 対訳: Europarl (v7) 2.0M文/55.7Mトークン (en)
 - 単言語: WMT News Crawl (2011-2013) 52.0M文/1.20Bトークン
- NTCIR (En-Ja)
 - 対訳: NTCIR 特許翻訳コーパス 3.2M文/107Mトークン (en)
 - 単言語: NTCIR 2006-2007年分 39.9M文/1.36Bトークン

使用したツール

■ トーカナイザ

- En, Fr: Mosesdecoder (RELEASE-2.1.1) の tokenizer.perl
- Ja: MeCab (0.996)の分かち書き



■ 単語アラインメント: SyMGIZA++

- IBM-2 単語アラインメント

■ フレーズテーブルの学習: Mosesdecoder

- Diag-grow-final
- フレーズ長の上限: 8
- Significance pruning [Johnson+, 07]

新たに獲得できた言い換え表現対の数




■ 顕著に大規模な言い換え知識を構築可能

- 対訳コーパスが大きいほど
 - 獲得できる言い換え表現対が多い (P_{Seed} , P_{LV} ともに)
 - コーパスのサイズ比が小さいためレバレッジは小さい
 - Europarlの1/16以下を用いた設定では異なる振る舞い
- 単言語コーパスはもっとある → さらなる大規模化も可能

掘り当てたのは本当に金か?

■ 人間による精度の評価: 文脈における置換テスト

- intrinsicにしたいが
- 言い換え生成 (ナイーブな置換+LM) [Callison-Burch, 08]



- プロトコル [Fujita, 13]
 - 同じ箇所に対する複数の言い換え候補を同時に見ながら
 - 2つの基準で
 - まず文法性の評価 (5段階)
 - 次に意味の等価性の評価 (6段階)
 - 各々決定木に従って

評価対象データ

候補生成

- WMT 2011-2013 “newstest” data (10,050文)
 - 制約: 10-30 words (5,850文)
- Europarl 設定の P_{Seed} (0.97M対) と P_{LV} (63.8M対)
- 89k箇所に対する1.0M件の言い換え事例

スコアリング


- 5-gram LMを用いて各箇所に対するベスト3を選択

サンプリング

- 重複のない語句200件 (言い換え文対600件)
 - P_{Seed} 由来: 66件
 - P_{LV} 由来: 534件


文法性の評価

- 評価対象: 言い換え後の文のみ
- 評価者3名のKappa値
 - 5段階: 0.51 - 0.56 (moderate)
 - 2段階: 0.64 - 0.79 (substantial)



意味の等価性の評価

- 評価対象: 言い換え前の文と言い換え後の文の対
- 評価者3名のKappa値
 - 6段階: 0.27 - 0.35 (fair)
 - 2段階: 0.48 - 0.53 (moderate)



評価結果

■ 精度: 3人の評価者, 2段階評価の多数派に基づく

	文数	文法性	意味の等価性	両方
S_{Seed}	66	0.85	0.91	0.76
S_{LV}	534	0.74	0.78	0.59
合計	600	0.75	0.79	0.61

- S_{Seed} 由来の言い換えの精度は十分に高い
 - クリーニングの効果 [Fujita+, 12; 13]
- S_{LV} 由来の言い換えも従来手法と同等以上
 - state-of-the-artにおける値 [Callison-Burch, 08]
 - 評価者, データが異なるので参考まで
 - Europarl (10言語-En) + CCG + LM
 - 文法性 0.68, 意味の等価性 0.62, 両方 0.55

主なエラーの原因

■ フレーズ全体のカテゴリ交替

評価対象

considered sufficiently

sufficient consideration

原文

The safety issue was **considered sufficiently** serious for all affected parties to be informed.

言い換え文

The safety issue was **sufficient consideration** serious for all affected parties to be informed.

■ 数や冠詞などの Agreement 誤り

評価対象

potential buyers

a potential buyer

原文

... there are tons of **potential buyers** of military weapons.

言い換え文


... there are tons of **a potential buyer** of military weapons.

■ 言い換え認識の応用タスクでは有用


まとめ

■ 与えられた言い換え知識の自動拡張

- 言い換え知識: 言い換え関係にある表現の対の集合
- 提案手法
 - 関係ありそうな語の対の抽象化



- 大規模単言語コーパスからの具体例の抽出



● 実験結果

- 規模: コーパスの規模によるが100倍のオーダーは達成可能
- 精度: ナイーブな使い方でも従来手法と同程度以上