

常識を持つコンピュータの実現に向けた
常識的道具判断システムの構築
Construction of Commonsense Implement Judgment System
for Achievement of Computer with Commonsense

宮柳 皓介†
Kousuke Miyayanagi

吉村 枝里子†
Eriko Yoshimura

渡部 広一†
Hirokazu Watabe

河岡 司†
Tsukasa Kawaoka

1. 研究背景

人間と機械が円滑なコミュニケーションを行う為には、機械に人間と同じような常識的な判断のできる仕組みが必要である。そこで、これまでに「時間、場所、知覚・感覚、量、感情、職種」に関して常識的な判断のできるシステムが提案されてきた^{[1][2]}。しかし、これらだけではまだ十分に人間の常識を網羅できていない。そこで、本稿では既に提案されたシステムに加えて、コミュニケーションに必要な常識として、道具に関する常識を提案する。

例えば、「髪を梳きたい」という要望に対し、「櫛」に関する会話を行うためには、「髪を梳くには櫛が必要である」という常識を理解しなければならない。人間は道具を使う状況において、何をするにはどの道具が必要かという知識を持っており、その常識に基づいて行動している。そこで機械に、人間の行動に対して必要な道具を提示する連想機能を持たせることが必要となる。本稿では、道具に関する会話を円滑に行うことを目的として、道具に関する常識を持たせた「常識的道具判断システム」を構築する。

2. 関連技術

常識的道具判断システムを構築する上で、重要となる関連技術について説明する。

2.1 概念ベース^[3]

「概念ベース」は複数の国語辞書や新聞から自立語を抽出して自動構築した、概念を表す語の知識ベースである。概念ベースには現在約12万語の概念が登録されている。

概念は、ある語 A をその語と関連の強いと考えられる語(属性) a_i と重み $w_i (>0)$ の対の集合として定義する(式1)。

$$A = \{(a_1, w_1), (a_2, w_2), \dots, (a_n, w_n)\} \dots (1)$$

2.2 意味的共起関連度計算^[4]

意味的共起関連度計算(以下、共起関連度計算と呼ぶ)は、2つの概念間の強さを定量的に評価するもので、概念 A と概念 B の関連が強いほどそれぞれの概念の意味特徴を表す属性集合内に対象とする語が数多く共出現し、そのことから関連性を判断するという方式である。この方式を用いることにより、概念間の共起情報から「公園-滑り台」「釘-金槌」といった連想により導き出されるような語と語の関係の強さを判断することができる。

2.3 シソーラス^[5]

本シソーラスでは、一般名詞の意味的用法を表す2710個の意味属性(ノード)の上位-下位関係、全体-部分関係が木構造で示されており、約13万語が登録されている。

†同志社大学大学院工学研究科

Graduate School of Engineering, Doshisha University

2.4 Web から構築された大規模格フレーム^[6]

Web から構築された大規模格フレーム(以下、「格フレーム」と呼ぶ)とは、Web 上の約5億文の日本語テキストから自動的に構築され、約9万語の用言から構成された知識ベースである。また、用言とそれがとる各要素の関係を記述したものであり、これにより動詞から関係ある名詞をWeb 上の頻度順に検索することが出来る。

検索の際には用言の用法である格(デ格、へ格 etc)を用いる。表1に用言と格から検索した名詞の例を示す。

表1 用言と格から検索した名詞

用言	格	名詞
切る	デ格	包丁, 鋏, ナイフ...
行く	へ格	学校, 病院, 店...

3. 常識的道具判断システム

常識的道具判断システムの処理は、入力文に対して格フレームを用いて、必要な道具の候補となる語(以下、候補語と呼ぶ)を取得し、シソーラスと共起関連度計算により絞り込まれた候補語を出力するという流れである(図1)。本システムでは、シソーラスに存在するノード「道具」以下に属する全ての語を「道具」と定義する。各処理における流れを次節より述べる。

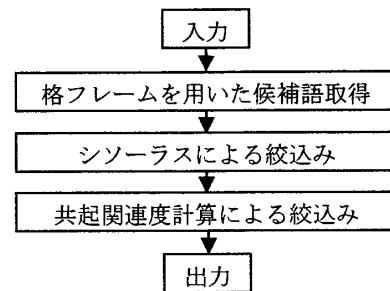


図1 常識的道具判断システムの流れ

3.1 システムの入力形態

入力形態としては、「[名詞](Ex.魚)を[動詞](Ex.釣る)」の形とする。また、「[名詞]を[動詞]」以外の入力文は対象としない。

3.2 候補語の取得方法

「茶釜」^[7]を用いて形態素解析を行い、入力文「[名詞]を[動詞](Ex.紙を切る)」の名詞(Ex.「紙」)の(以下、「入力名詞」と呼ぶ)と動詞(Ex.「切る」)の基本形部分(以下、「入力動詞」と呼ぶ)を抽出する。そして、「茶釜」によって得られた入力動詞に対して格フレームを用い、候補語の獲得を行う。格フレームより取得する際の、用言

の用法は「デ格」を用いる。「デ格」が表す表現には「場所」「原因」「道具」「手段」「材料」などがあり、本手法では「道具」となる語を出力させるため、「デ格」における名詞を候補として獲得する。

3.3 シソーラスによる絞込み

3.2節で取得した候補語は、「場所」「原因」「道具」「手段」「材料」などの可能性がある。そこで、シソーラスを用いることにより「道具」のみに絞り込む。つまり候補語のシソーラスの親ノードに「道具」が無ければ候補語から削除する。

3.4 共起関連度計算による絞込み

3.3節によって「道具」であると判断した候補語と入力名詞とで、2.2節で説明した共起関連度計算を行う。候補語と入力名詞で、共起関連度計算を行った結果、閾値(0.007)以下なら入力文と関連の弱い語として削除する。

3.5 出力

3.2節～3.4節の処理を行い、最終的に残った候補語を、入力文に対して必要な道具として出力する。

4. 常識的道具判断システムの評価

提案したシステムの評価を行う。アンケートを行い一人につき5文の「入力文(3.1節で説明した入力形態)」を列挙してもらい、それによって計26人分の重複を除いた100文の評価用データを得た。

この評価用データに対し、システムによって出力された道具が正しいかどうかを3名の目視によって評価を行う。

評価基準は入力文に対して出力された道具を「常識(○)」「非常識(×)」「非常識ではない(△)」に分けて次のように評価を行った。

「○」: 3人中2人以上が正解

「△」: 3人中1人が正解

「×」: 3人全員が不正解

評価精度は出力全体における「○」と「△」の割合とする。

評価結果は、○: 48.7%、△: 22.7%、×: 28.6%であり、出力数はそれぞれ○: 133語、△: 62語、×: 78語出力された。本システムの精度である「○」、「△」の割合は71.4%であった(図2)。




図2 システムの評価

5. 考察

4節で述べた評価結果より、精度は71.4%であった。100文で195語の正解語が得られた為、1文当たり2語程度の正解語が得られた。しかし、実際には人間が連想する道具が出力されていない入力文は30文あった。候補語の段階

では、人間が連想する語が得られているが、共起関連度で絞る際に削除されているものがある。例として「体を洗う」を挙げる。候補語の段階では「スポンジ、シャワー、風呂・・・」が出力されたが、共起関連度を用いて候補語を絞る際に、削除された。

他の問題点として、候補語の段階で人間が連想する道具が省かれている場合がある。例として「鉛筆を削る」を挙げる。システムに「鉛筆を削る」を入力すると「ナイフ、鋸、刃物、ファイル、鉋」が出力された。「ナイフ、刃物」が出力されており、「鉛筆を削る」のに用いる道具が出力されている。だが、人間が「鉛筆を削る」から主に連想するのは「鉛筆削り」であると考えられる。これは、格フレームのみで候補語を獲得してきているので、道具の候補が少ない。よって人間が連想する道具が省かれている可能性があると考えられる。

また、格フレームから候補を獲得してくる段階で「鉛筆削り」は「削り」となってしまう問題がある。このような「鉛筆」と「削り」に分かれてしまうような複合語は、獲得することができないので、候補語に残すことができない。

今後、上記に挙げた問題を解決するために、候補語を増やす方法と人間が連想する道具を候補語から多く残すことを考案する必要があると考える。

6. おわりに

本稿では、概念ベースと共起関連度計算からなる連想システムを用いることにより、入力文に対して必要な道具を出力する「常識的道具判断システム」の構築と評価を行った。結果、71.4%の精度を得ることが出来た。

今後、人間が連想する道具を候補語から多く残し、より正解語を増加させることにより、精度が良くなると考えられ、より自然なコンピュータ会話に繋がると考えられる。

参考文献

- [1] 土屋誠司, 奥村紀之, 渡部広一, 河岡司: 連想メカニズムを用いた時間判断手法の提案, 自然言語処理, Vol. 12, No. 5, pp. 111-129, 2005.
- [2] 杉本二郎, 渡部広一, 河岡司: 概念ベースを用いた常識場所判断システムの構築, 情報処理学会自然言語処理研究会資料, 2003-NL-153, pp. 81-88, 2003.
- [3] 奥村紀之, 土屋誠司, 渡部広一, 河岡司: 概念間の関連度計算のための大規模概念ベースの構築, 自然言語処理, Vol. 14, No. 5, pp. 41-64, 2007.
- [4] 奥村紀之, 渡部広一, 河岡司: 概念の意味属性と共起情報を用いた関連度計算方式, 自然言語処理, Vol. 13, No. 1, pp. 53-74, 2006.
- [5] 池原悟, 宮崎正弘, 白井論, 横尾昭男, 中岩浩巳, 小倉健太郎, 大山芳史, 林良彦 (編): 日本語語彙体系, 岩波書店, 1997.
- [6] 河原大輔, 黒橋禎夫: 高機能計算環境を用いた Web からの大規模格フレーム構築, 情報処理学会自然言語処理研究会, 2006-NL-171, pp. 67-73, 2006.
- [7] 松本裕治, 北内啓, 山下達雄, 平野善隆, 今一修, 今村友明: 日本語形態素解析システム『茶筌』version1.0 使用説明書, NAIST Technical Report, NAIST-IS-TR97007, 1997.