

概要

本研究は対義語に対して、教師あり機械学習を用いることにより、対義語の置き換え可否の判定を行うことを目指す。

対義語とは、意味が反対になっている語や意味が対称になっている語のことである。対義語には、文中のある単語を対義語に置き換える場合、対義語に沿うように文の内容を逆にしても対義語に置き換えができないものもある。例えば「足す」と「引く」という対義語の組では、「A から B を引く」とはいうが、「A から B を足す」とはいわない。これは格が変化しているからである。本研究では置き換え可能の定義は、文中のある単語 X の対義語に沿うように文を知識的な内容だけ逆に変更した時（直前直後の付属語、係り受け関係にある文中の格助詞は変更しない）、単語 X を対義語に置き換える場合、置き換え可能であると定義する。荻原ら [1] は、分類語彙表に反対語（ここでは対義語と同様に扱う）情報を付与、またその際、置き換え可否の情報を付与している。しかし、この作業は人手で行っており置き換え可否の情報付与に関しては例文を示していない。実際に置き換えてみないと判断がつかないことも多い。よって、例文を示さずに対義語対に置き換えの可否の情報を付与することは、正確性に欠ける。また、赤江ら [2] は EDR 電子化辞書から得られた類義語を利用し、機械学習を用いた類義語の使い分けの研究を行った。ある対義語間での機械学習の性能が高く、より正確に使い分けを行っていた場合は、その対義語の組は機械学習で性能が高くなるほど使い方の違いが明瞭な対義語対とわかる。使い方の違いが明瞭だと対義語対は置き換え不可能だと考えられる。対して、ある対義語間での機械学習の性能が低い場合は、正確に使い分けができず、その対義語対は機械学習で判断ができないほど使い方の違いが不明瞭な対義語対とわかる。よって使い方の違いが不明瞭なので、その対義語対は置き換え可能であると考えられる。この考え方を用いて機械学習の性能を用いて対義語対の置き換え可否の判定を行う。このような実験を荻原らの研究から獲得した対義語の組を対象に行う。対義語対の使い分けした結果を、例文を示した対義語対の置き換え可否を判定する被験者実験の結果と比較する。本研究の成果は 2 つある。1 つ目は、想定していた通り、機械学習の性能が高ければ置き換え可能であり、機械学習の

性能が低ければ置き換え不可能であるという，機械学習の性能と対義語対の置き換え可否に逆の相関があることが確認できた．2つ目は，それぞれの対義語における有用な知見や対義語対の置き換え可否に関する知見などを獲得した．例えば，慣用的な表現が多く使われていると置き換え可能の値が高くなることがわかった．また，逆の相関が得られなかった原因もわかった．この研究の成果は日本語学習者向けの対義語学習教材作成に利用できる．

目次

第1章	はじめに	1
第2章	先行研究	3
2.1	『分類語彙表』に対する反対語情報付与	3
2.2	教師あり機械学習を用いた類義語の使い分けに関する知識獲得	4
第3章	問題設定と提案手法	6
3.1	問題設定	6
3.2	提案手法	7
3.3	最大エントロピー法	7
3.4	素性	8
第4章	実験	10
4.1	実験データ	10
4.2	実験方法	15
4.3	使い分けの実験結果	16
4.4	被験者実験	24
第5章	考察	27
5.1	被験者実験と機械学習の性能の傾向が一致した対義語対の考察	27
5.1.1	分類分けが高で置き換え可の値が低かったもの	27
5.1.2	分類分けが低で置き換え可の値が高かったもの	33
5.2	被験者実験と機械学習の性能の傾向が一致しなかった対義語対の考察	38
5.2.1	分類分けが高だが置き換え可の値が高かったもの	39
5.2.2	分類分けが低だが置き換え可の値が低かったもの	41
5.2.3	分類分けが中だが置き換え可の値が高かったもの	46
5.2.4	分類分けが中だが置き換え可の値が低かったもの	47

表 目 次

3.1	類義語の判別に用いる素性	9
4.1	実験を行った名詞の対義語の組	11
4.2	実験を行った動詞の対義語の組	12
4.3	実験を行った形容詞の対義語の組	13
4.4	実験を行った副詞の対義語の組	14
4.5	被験者実験を行った対義語の組	14
4.6	被験者実験の例	15
4.7	対義語の分類結果	16
4.8	名詞の対義語対の結果 1	17
4.9	名詞の対義語対の結果 2	18
4.10	動詞の対義語対の結果 1	19
4.11	動詞の対義語対の結果 2	20
4.12	形容詞の対義語対の結果 1	21
4.13	形容詞の対義語対の結果 2	22
4.14	副詞の対義語対の結果	23
4.15	被験者実験の結果 1	24
4.16	被験者実験の結果 2	24
4.17	被験者実験の結果 3	25
5.1	機械学習の性能「潜在」「顕在」)	28
5.2	機械学習が参考にした素性(「潜在」「顕在」)	28
5.3	機械学習の性能「引っ掛かる」「だます」)	29
5.4	機械学習が参考にした素性(「引っ掛かる」「だます」)	29
5.5	機械学習の性能「迎える」「送る」)	30
5.6	機械学習が参考にした素性(「迎える」「送る」)	30
5.7	機械学習の性能「うっすら」「はっきり」)	31

5.8	機械学習が参考にした素性(「うっすら」「はっきり」)	31
5.9	機械学習の性能「正室」「側室」)	33
5.10	機械学習が参考にした素性(「正室」「側室」)	33
5.11	機械学習の性能「勝つ」「負ける」)	34
5.12	機械学習が参考にした素性(「勝つ」「負ける」)	34
5.13	機械学習の性能「少ない」「多い」)	35
5.14	機械学習が参考にした素性(「少ない」「多い」)	35
5.15	機械学習の性能「ぐずぐず」「はきはき」)	36
5.16	機械学習が参考にした素性(「ぐずぐず」「はきはき」)	36
5.17	機械学習の性能「誇る」「恥じる」)	39
5.18	機械学習が参考にした性能(「誇る」「恥じる」)	39
5.19	機械学習の性能「鋭い」「鈍い」)	40
5.20	機械学習が参考にした性能(「鋭い」「鈍い」)	40
5.21	機械学習の性能「沸かす」「冷やす」)	42
5.22	機械学習が参考にした素性(「沸かす」「冷やす」)	42
5.23	機械学習の性能「憎い」「いとしい」)	43
5.24	機械学習が参考にした素性(「憎い」「いとしい」)	43
5.25	機械学習の性能「まだ」「もう」)	44
5.26	機械学習が参考にした素性(「まだ」「もう」)	44
5.27	機械学習の性能「格下げ」「格上げ」)	46
5.28	機械学習が参考にした素性(「格上げ」「格下げ」)	46
5.29	機械学習の性能「着信」「発信」)	47
5.30	機械学習が参考にした素性(「着信」「発信」)	48
5.31	機械学習の性能「固い」「柔らかい」)	49
5.32	機械学習が参考にした素性(「固い」「柔らかい」)	49
5.33	機械学習の性能「はっきり」「ぼんやり」)	50
5.34	機械学習が参考にした素性(「はっきり」「ぼんやり」)	50

第1章 はじめに

対義語とは、意味が反対になっている語や意味が対称になっている語のことである。対義語には、文中のある単語を対義語に置き換える場合、対義語に沿うように文の内容を逆にしても対義語に置き換えができないものもある。例えば「引く」と「足す」で「A から B を引く」とはいうが、「A から B を足す」とはいわない。これは格が変化しているからである。本研究では置き換え可能の定義は、文中のある単語 X の対義語に沿うように文を知識的な内容だけ逆に変更した時（直前直後の付属語、係り受け関係にある文中の格助詞は変更しない）、単語 X を対義語に置き換えられる場合、置き換え可能であると定義する。また、対義語に関する研究では、荻原ら [1] が、分類語彙表に対義語情報を付与、その際、置き換え可否の情報を付与している。しかし、この作業は人手で行っており置き換え可否の情報付与に関しては例文を示していない。実際に置き換えてみないと判断がつかないものも多い。よって、例文を示さずに対義語対に置き換えの可否の情報を付与することは、正確性に欠ける。また、赤江ら [2] は EDR 電子化辞書から得られた類義語を利用し、機械学習を用いた類義語の使い分けを行った。対義語対の機械学習を用いた使い分けの性能が良いと機械でも使い分けれるほど対義語対の使い方の違いが明瞭であると考えられる。使い方の違いが明瞭ということは対義語対は置き換え不可能であると考えられる。対して、ある対義語間での機械学習の性能が低い場合は、正確に使い分けができず、その対義語対は機械学習で判断ができないほど使い方の違いが不明瞭な対義語対とわかる。よって使い方の違いが不明瞭なので、その対義語対は置き換え可能であると考えられる。この考え方をを用い、本研究では、赤江らと同様の手法で機械学習を用いて対義語の使い分けを行い、対義語対の置き換えの可否を判定する。

本研究では、機械学習の性能や素性が対義語対の使い分けに役立つと考え、機械学習を用いて対義語対の使い分けを行い、その結果を用いて対義語対の置き換え可否を判定する。本研究の成果は、人手で行っていた作業を自動化し、また日本語学習者の対義語学習などに利用できると考える。

本研究では、荻原らの研究 [1] で、20 人の被験者の内置き換え 17 人以上が対義語で

あると判断したものを利用する。

荻原らの研究 [1] で、置き換えの可否については判定してあるが、置き換えの可否を判定する際に例文を提示せずに行っている。実際に置き換えてみないと判断がつかないことも多い。よって、例文を提示せずに置き換え可否の判定をすることは、正確性に欠ける。よって、機械学習を行った対義語対の一部から例文を明示し被験者実験を行い、その結果を機械学習の性能と比較する。機械学習の性能と例文を提示し行った被験者実験の結果を比較し、機械学習の性能と被験者実験の結果に逆の相関があることを確認することを目的とする。

本研究の主な主張点を以下に整理する。

- 想定していた通り、機械学習の性能と例文を明示した被験者実験の結果を比較し名詞や動詞では機械学習の性能と対義語対の置き換えの可否は逆の相関があることを確認した。
- 機械学習の性能と対義語対の置き換えの可否の間に逆の相関関係が得られた対義語の機械学習の素性を分析することにより、それぞれの対義語における有用な知見や対義語対の置き換え可否に関する知見を獲得した。

本論文の構成は以下の通りである。第2章では、本研究に関連する研究としてどのような研究が行われてきたかを記述し、その研究と本研究との関連を説明する。第3章では、本研究が扱う問題の設定とそれを解決するために提案した手法について説明を行う。第4章では、本研究が行った機械学習の実験についての説明と、被験者実験についての説明と、それら2つの結果を比較した結果について記述する。第5章では、第4章の結果から素性分析による考察を行う。第6章ではまとめを行う。

第2章 先行研究

本章では、先行研究について記述する。2.1 節では、荻原ら [1] が行った分類語彙表に対義語情報を付与をした研究について記述する。2.2 節では、赤江 [2] が行った類義語に対する機械学習を用いた使い分けの研究について記述する。

2.1 『分類語彙表』に対する反対語情報付与

荻原らは、『分類語彙表増補改訂版』(国立国語研究所 2004) (以下、分類語彙表) 中の反対語(この論文では対義語と同様に扱う)を枚挙し、対義語情報を整備した [1]。分類語彙表は「語を意味によって分類・整理したシソーラス(類義語集)」で、意味の区切り行を入れて 101,070 件からなる。意味の区切り行というのは、例えば既婚なら「体-活動-行為-身上」というように意味ごとに区切ったものである。語句に対して、5 桁の数字からなる分類番号、2 桁以下の数字からなる段落番号、2 桁以下の数字からなる小段落番号、2 桁以下の数字からなる語番号が付与されている。分類語彙表の分類では、類義語だけでなく、反対語・対義語なども同じカテゴリに分類される。「体-自然-生物-生物」なら「有性」「無性(むせい)」や「体-活動-言語-名」なら「同性」「異性」などが、反対語に相当する。しかしながら「同性」「異性」に関しては、どちらも「両性」というカテゴリーに属していることもあり、反対語か否かの判定は作業者により揺れる。何を反対語としてとらえるかは、人によって異なる。例えば二律関係だけでなく、三律関係を反対語としてとらえる人もいる。また反対語の中にも、文脈によって置き換え不可なものもある。このような情報を評価するために、分類語彙表から反対語対候補を収集し、「反対語としての認識」「置き換えの可否」についてクラウドソーシングを用いた調査による分布情報を付与する。クラウドソーシングは Yahoo!クラウドソーシングを用い、1 語対あたり 20 人の作業者に判断を依頼した。作業者は、「対義語・反対語でない」「対義語・反対語であるが、置き換え不可」・「対義語・反対語であり、置き換え可」の 3 択のいずれかを選択する。「対義語・反対語であるが、置き換え不可」の例として、格が変化する(AにBを)「加算する」、(AからBを)「減

算する」を呈示した。「対義語・反対語であり、置き換え可」の例として、「北」、「南」、「暑い」、「寒い」を呈示した。

荻原らの研究の成果として、「体-関係-空間-内外」「体-関係-空間-方向・方角」など1次元的な軸が仮定できるものは、対義語であり、かつ、置き換え可である割合が高く、「用-関係-作用増減・補充」「用-関係-作用-作用・変化」などは、対義語と認定される割合が高い一方、格標示が変化する可能性があり、置き換え不可であるものが増えていくということなどが分かった。また、何を対義語としてとらえるかは人によって異なるため、対義語か否かの二律背反的な定義は困難であることが伺えた。

この先行研究は、対義語情報を分類語彙表に付与しその際に置き換えの可否の情報も付与しているが、置き換え可否に関しては、例文を提示していないので実際に置き換えながら格の変化の確認や、言い回しの確認ができないため正確性にかけてと考えられる。

2.2 教師あり機械学習を用いた類義語の使い分けに関する知識獲得

赤江らは、EDR 電子化辞書から得られる類義語を利用し、機械学習による類義語の使い分けの研究を行った [2]。

赤江らは類義語の使い分けのために機械学習を使用し、複数の類義語対について、どの程度使い分けが必要か、またどのような場合に使い分けが必要かなどを新たに示した。

赤江らは、使い方の分かる類語例解辞典 [3] および「擬音語・擬態語」使い分け帳 [4] から人手で選んだ類義語を利用した。

獲得した類義語対ごとに類義語の使い分けの実験を行った。入力文は、1991年～1995年、2011年～2015年の毎日新聞から獲得した、類義語対のいずれかの語を含む文である。評価は10分割のクロスバリデーションで行った。機械学習の再現率の高さごとに名詞の類義語対を、高・中・低に分類し、機械学習における素性(学習に用いる情報のこと)を分析することで類義語の使い分けに重要な情報を把握した。

赤江らの研究の成果として、機械学習を用いたの類義語の使い分けの手法自体が類義語の使い分けに有効であることを示した。更に、機械学習での性能に基づき使い分けが必要な名詞の類義語対とそれほど必要でない名詞の類義語対を明らかにした。また、実際に素性を分析した。使い分けに役立つ情報を明らかにし、どのような場合に使

い分けの必要があるかを明らかにした。使い分けが必要な名詞の類義語対として「貯金」と「貯蓄」、「メダル」と「賞碑」、使い分けが必要でない類義語対として「省エネ」と「省エネルギー」、「上期」と「上半期」があった。

第3章 問題設定と提案手法

本章では、本研究で扱う問題と提案手法の説明を記述する。3.1節では、本研究で扱う問題設定について記述している。3.2節では、提案手法の大まかな流れについて記述し、3.3節では、本研究で使用する機械学習法である最大エントロピー法についての説明を記述している。3.4節では、機械学習で使用する素性について記述している。

3.1 問題設定

使い分けたい対義語の組 A,B があるとする。語 A と語 B のことを対象語と呼ぶ。対象語のいずれかを含む文を収集する。収集した文において対象語を削除し、対象語があった箇所に対象語のうちどの語が存在したかを推定する。その結果を用い置き換えの可否を判定することが、本研究で扱う問題である。その文に元々あった方の語を選択できれば、正しく対義語を使い分けることができ、置き換えのできない対義語だと考える。逆に、元々あった方の語を選択できなければ、正しく対義語を使い分けることができず、置き換えのできる対義語だと考える。具体的な例として、対義語の組「賛成」「反対」を例に以下に示す。

第三号被保険者制度は不公平という意見に 賛成 です。
自由化を前提にした農業の新政策による新たな農民の選別切り捨てに 反対 する。

このように対象語を含んだ文を収集する。次にこれらの文から対象語を削除する。

第三号被保険者制度は不公平という意見に X です。
自由化を前提にした農業の新政策による新たな農民の選別切り捨てに X する。

X とした箇所に対象語のうちどちらが存在したかを機械学習で推定する。

3.2 提案手法

本研究では、教師あり機械学習を利用して、対象語のうちどの語が文中にあったのかを推定し、その結果を用い置き換えの可否を判定する。対象語のいずれかを含む文を学習データとして用いる。その文が含む対象語をその文の分類先として、機械学習を用いて学習を行う。教師あり機械学習には最大エントロピー法を利用する。再現率の高さごとに結果を高（90%以上）と中（80%以上90%未満）と低（80%未満）の3つに分類し、高が置き換えしにくいもの、低が置き換えしやすいもの、中がそれらの中間として、置き換え可否の判定を行う。

分類に再現率を用いるのは、再現率は機械学習が実験データのうちどれだけ正解を認識したかという指標であるためである。

3.3 最大エントロピー法

本研究では、教師あり機械学習法に、最大エントロピー法を使用する。

最大エントロピー法とは、あらかじめ設定しておいた素性 $f_i (1 \leq j \leq k)$ の集合を F とするとき、式 (3.1) を満足しながらエントロピーを意味する式 (3.2) を最大にするときの確率分布 $p(a, b)$ を求め、その確率分布にしたがって求まる各分類の確率のうち、もっとも大きい確率値を持つ分類を求める分類とする方法である [5, 6, 7, 8]。

$$\sum_{a \in A, b \in B} p(a, b) g_j(a, b) = \sum_{a \in A, b \in B} a(a, b) g_j(a, b) \quad (3.1)$$

for $\forall f_j (1 \leq j \leq k)$

$$H(p) = - \sum_{a \in A, b \in B} p(a, b) \log(p(a, b)) \quad (3.2)$$

ただし、 A, B は分類と文脈の集合を意味し、 $g_i(a, b)$ は文脈 b に素性 f_i があつてなおかつ分類が a の場合 1 となり、それ以外で 0 となる関数を意味する。また、 (a, b) は、既知データでの (a, b) の出現の割合を意味する。

式 (3.1) は、確率 p と出力と素性の組の出現を意味する関数 g をかけることで出力と素性の組の頻度の期待値を求めることになっており、右辺の既知データにおける期待値と、左辺の求める確率分布に基づいて計算される期待値が等しいことを制約とし

て，エントロピー最大化 (確率分布の平滑化) を行って，出力と文脈の確率分布を求めるものとなっている．

3.4 素性

文献 [2] を参考にし，機械学習の素性には表 3.1 のものを用いる．これらの素性を，対象語が含まれる文から取り出す．表 3.1 中に記述されている分類語彙表の番号とは，分類語彙表によって与えられた語ごとの意味を表す 10 桁の番号である．類義語の使い分けでは，文中に存在する語から使い分けに関する情報が得られると考え，素性 1 を設定する．その中でも対象語の前後の語に重要な情報があると考え 素性 2, 3 を設定する．また，対象語の存在する文構造にも情報があると考え，対象語の存在する文節の付属語，対象語の存在する文節に係る文節，対象語の存在する文節に係る文節の自立語と付属語をそれらの語彙情報とともに素性として設定する (素性 4-45) ．

表 3.1: 類義語の判別に用いる素性

番号	素性の説明
素性 1	文中の名詞
素性 2	対象語の前後 3 語
素性 3	2 の分類語彙表の番号 7,5,4,3,2,1 桁
素性 4	対象語が含まれる文節の自立語
素性 5	4 の品詞
素性 6	4 の分類語彙表の番号 7,5,4,3,2,1 桁
素性 7	対象語が含まれる文節の最初の自立語
素性 8	7 の品詞
素性 9	7 の分類語彙表の番号 7,5,4,3,2,1 桁
素性 10	対象語が含まれる文節の最後の自立語
素性 11	10 の品詞
素性 12	10 の分類語彙表の番号 7,5,4,3,2,1 桁
素性 13	対象語が含まれる文節の付属語
素性 14	13 の品詞
素性 15	13 の分類語彙表の番号 7,5,4,3,2,1 桁
素性 16	対象語が含まれる文節の最初の付属語
素性 17	16 の品詞
素性 18	16 の分類語彙表の番号 7,5,4,3,2,1 桁
素性 19	対象語が含まれる文節の最後の付属語
素性 20	19 の品詞
素性 21	19 の分類語彙表の番号 7,5,4,3,2,1 桁
素性 22	対象語が含まれる文節に係る文節の自立語
素性 23	22 の品詞
素性 24	22 の分類語彙表の番号 7,5,4,3,2,1 桁
素性 25	対象語が含まれる文節に係る文節の付属語
素性 26	25 の品詞
素性 27	25 の分類語彙表の番号 7,5,4,3,2,1 桁
素性 28	対象語が含まれる文節に係る文節の最初の自立語
素性 29	28 の品詞
素性 30	28 の分類語彙表の番号 7,5,4,3,2,1 桁
素性 31	対象語が含まれる文節に係る文節の最後の自立語
素性 32	31 の品詞
素性 33	31 の分類語彙表の番号 7,5,4,3,2,1 桁
素性 34	対象語が含まれる文節に係る文節の最初の付属語
素性 35	34 の品詞
素性 36	34 の分類語彙表の番号 7,5,4,3,2,1 桁
素性 37	対象語が含まれる文節に係る文節の最後の付属語
素性 38	37 の品詞
素性 39	37 の分類語彙表の番号 7,5,4,3,2,1 桁
素性 40	対象語が含まれる文節に係る文節の自立語
素性 41	40 の品詞
素性 42	40 の分類語彙表の番号 7,5,4,3,2,1 桁
素性 43	対象語が含まれる文節に係る文節の付属語
素性 44	43 の品詞
素性 45	43 の分類語彙表の番号 7,5,4,3,2,1 桁
素性 46	対象語が含まれる文節に係る文節の最初の自立語
素性 47	46 の品詞
素性 48	46 の分類語彙表の番号 7,5,4,3,2,1 桁
素性 49	対象語が含まれる文節に係る文節の最後の自立語
素性 50	49 の品詞
素性 51	49 の分類語彙表の番号 7,5,4,3,2,1 桁
素性 52	対象語が含まれる文節に係る文節の最初の付属語
素性 53	52 の品詞
素性 54	52 の分類語彙表の番号 7,5,4,3,2,1 桁
素性 55	対象語の類義語対が含まれる文節に係る文節の最後の付属語
素性 56	55 の品詞
素性 57	55 の分類語彙表の番号 7,5,4,3,2,1 桁

第4章 実験

本章では，本研究で実験を行った対義語の組を 4.1 節で説明し，本研究が行った実験方法を 4.2 節で説明し，実験結果を 4.3 節に示し，被験者実験の結果と使い分けの実験の比較を 4.4 節に示す．

4.1 実験データ

本研究では，荻原らの研究 [1] の研究でまとめられた対義語データベースから被験者実験で 20 人中 17 人以上が対義語であると判断されたものを利用する．名詞，動詞，形容詞，副詞の対義語対の中から新聞記事の中に両方の対義語が 50 回以上出現したものをランダムに 50 対を抽出し，実験を行う．また副詞と形容詞に関しては条件を満たすものが副詞が 8 対，形容詞が 46 対であったので 8 対と 46 対で実験を行う．表 4.1 から表 4.4 に実験を行った対義語の組を示す．1991 年から 1995 年，2011 年から 2015 年の毎日新聞から対義語の組のいずれかの語を含む文を獲得した．データ数は学習に偏りを少なくするため対義語の組内で同数にして実験を行った．また「白っぽい」「黒っぽい」などの複合語は機械学習の際に一つの単語と認識されないので実験対象から外している．

被験者実験は，機械学習により求めた 2 つの対義語の正解率の低い方の性能をもとに対義語対を 3 種類（高 90 % 以上，中 80 % 以上 90 % 未満，低 80 % 未満）に分類し，その 3 種類から，4 つの品詞（名詞，動詞，形容詞，副詞）ごとに 3 組ずつランダムに抽出し，合計 36 対（ $3 \times 4 \times 3$ ）で実験を行う．副詞の低に分類されたものと形容詞の高に分類されたものは 2 種類しかなかったので，34 対で実験を行った．表 4.5 に被験者実験を行った対義語の組を示す．

表 4.1: 実験を行った名詞の対義語の組

1	「増産」 「減産」
2	「充電」 「放電」
3	「勝訴」 「敗訴」
4	「白地」 「黒地」
5	「増税」 「減税」
6	「楽勝」 「辛勝」
7	「先輩」 「後輩」
8	「賛成」 「反対」
9	「一方」 「両方」
10	「当番」 「非番」
11	「悲劇」 「喜劇」
12	「和風」 「洋風」
13	「開場」 「閉場」
14	「着衣」 「脱衣」
15	「立春」 「立秋」
16	「洋裁」 「和裁」
17	「プロ」 「アマ」
18	「定数」 「変数」
19	「積」 「商」
20	「結成」 「解散」
21	「公設」 「私設」
22	「水平」 「垂直」
23	「格上げ」 「格下げ」
24	「ノンフィクション」 「フィクション」
25	「古参」 「新参」
26	「師匠」 「門弟」
27	「正室」 「側室」
28	「入社」 「退社」
29	「モノクロ」 「カラー」
30	「安眠」 「不眠」
31	「男声」 「女声」
32	「肉食」 「菜食」
33	「多弁」 「寡黙」
34	「得点」 「失点」
35	「出撃」 「迎撃」
36	「夏場」 「冬場」
37	「朗報」 「悲報」
38	「有線」 「ワイヤレス」
39	「女手」 「男手」
40	「拘禁」 「釈放」
41	「発信」 「着信」
42	「顕在」 「潜在」
43	「文語」 「口語」
44	「プラス」 「マイナス」
45	「前払い」 「後払い」
46	「是認」 「否認」
47	「実像」 「虚像」
48	「内示」 「公示」
49	「増量」 「減量」
50	「肥沃」 「不毛」

表 4.2: 実験を行った動詞の対義語の組

1	「誇る」「恥じる」
2	「増える」「減る」
3	「勝つ」「負ける」
4	「会う」「別れる」
5	「禁じる」「許す」
6	「だます」「引っ掛かる」
7	「出会う」「別れる」
8	「上げる」「落とす」
9	「迎える」「送る」
10	「伸ばす」「曲げる」
11	「突き当たる」「通り抜ける」
12	「冷やす」「沸かす」
13	「眠る」「目覚める」
14	「溶ける」「固まる」
15	「ささやく」「叫ぶ」
16	「見える」「隠れる」
17	「憎む」「慈しむ」
18	「増す」「減る」
19	「やる」「もらう」
20	「温まる」「冷える」
21	「温める」「冷やす」
22	「褒める」「しかる」
23	「引き上げる」「引き下げる」
24	「進む」「遅れる」
25	「くつつく」「離れる」
26	「締める」「緩める」
27	「攻める」「防ぐ」
28	「取り付ける」「取り外す」
29	「貸す」「借りる」
30	「開く」「閉まる」
31	「忘れる」「思い出す」
32	「つなぐ」「断ち切る」
33	「出迎える」「見送る」
34	「近寄る」「遠のく」
35	「詰まる」「通り抜ける」
36	「付き合う」「別れる」
37	「くつつける」「放す」
38	「足りる」「欠ける」
39	「乗る」「降りる」
40	「押す」「引く」
41	「尋ねる」「答える」
42	「問う」「答える」
43	「開ける」「閉める」
44	「預ける」「返す」
45	「上げる」「下げる」
46	「見上げる」「見下ろす」
47	「付ける」「離す」
48	「浮く」「沈む」
49	「上げる」「下ろす」
50	「早める」「遅らせる」

表 4.3: 実験を行った形容詞の対義語の組

1	「長い」「短い」
2	「うまい」「まずい」
3	「難しい」「やすい」
4	「大きい」「小さい」
5	「太い」「細い」
6	「堅い」「軟らかい」
7	「難しい」「易しい」
8	「固い」「柔らかい」
9	「明るい」「暗い」
10	「甘い」「厳しい」
11	「蒸し暑い」「涼しい」
12	「多い」「少ない」
13	「目新しい」「古めかしい」
14	「おいしい」「まずい」
15	「素早い」「のろい」
16	「ふさわしい」「そぐわない」
17	「白い」「黒い」
18	「広い」「狭い」
19	「濃い」「薄い」
20	「暑い」「寒い」
21	「硬い」「軟らかい」
22	「美しい」「醜い」
23	「手ぬるい」「手厳しい」
24	「熱い」「冷たい」
25	「鋭い」「鈍い」
26	「男らしい」「女らしい」
27	「心強い」「心もとない」
28	「暖かい」「冷たい」
29	「心強い」「心細い」
30	「疎い」「詳しい」
31	「高い」「安い」
32	「遠い」「近い」
33	「憎い」「かわいい」
34	「固い」「軟らかい」
35	「重い」「軽い」
36	「深い」「浅い」
37	「速い」「遅い」
38	「硬い」「柔らかい」
39	「憎い」「いとしい」
40	「よい」「悪い」
41	「新しい」「古い」
42	「強い」「弱い」
43	「高い」「低い」
44	「おもしろい」「つまらない」
45	「難しい」「たやすい」
46	「厚い」「薄い」

表 4.4: 実験を行った副詞の対義語の組

1	「はっきり」「うっすら」
2	「どっさり」「ちょっぴり」
3	「はっきり」「ぼんやり」
4	「はきはき」「ぐずぐず」
5	「うっかり」「わざと」
6	「まだ」「もう」
7	「たくさん」「少し」
8	「あっさり」「こってり」

表 4.5: 被験者実験を行った対義語の組

1	「肥沃」「不毛」
2	「潜在」「顕在」
3	「是認」「否認」
4	「格上げ」「格下げ」
5	「入社」「退社」
6	「喜劇」「悲劇」
7	「カラー」「モノクロ」
8	「フィクション」「ノンフィクション」
9	「正室」「側室」
10	「引かかる」「だます」
11	「誇る」「恥じる」
12	「迎える」「送る」
13	「尋ねる」「答える」
14	「くつつく」「離れる」
15	「眠る」「目覚める」
16	「叫ぶ」「ささやく」
17	「勝つ」「負ける」
18	「沸かす」「冷やす」
19	「難しい」「やすい」
20	「鋭い」「鈍い」
21	「熱い」「冷たい」
22	「深い」「浅い」
23	「そぐわない」「ふさわしい」
24	「速い」「遅い」
25	「憎い」「いとしい」
26	「少ない」「多い」
27	「うっすら」「はっきり」
28	「あっさり」「こってり」
29	「少し」「たくさん」
30	「はっきり」「ぼんやり」
31	「わざと」「うっかり」
32	「ちょっぴり」「どっさり」
33	「はきはき」「ぐずぐず」
34	「まだ」「もう」

4.2 実験方法

獲得した対義語組について，対義語の組ごとに対義語の使い分けの実験を行う．入力文は，1991年から1995年，2011年から2015年の毎日新聞から獲得した，対義語の組のいずれかの語を含む文である．評価は10分割のクロスバリデーションで行う．再現率ごとに，高中低の3種類に分類する．高が90%以上，中が80%以上90%未満，低が80%未満である．再現率が高のものは置き換えがしにくいもの，低のものは置き換えがしやすいもの，中のものはそれらの中間であるとする．

被験者実験についての説明をする．まず，対義語対の使い分けの実験を行う．機械学習で使用した文から対義語対ごとに10文ランダムに抽出し被験者に対義語の使い分けを行わせる．その際，被験者は対義語対のどちらかを選ぶのではなく対義語対のどちらかもしくは判断不可の3択の中から選ばせる．

次に，対義語対の置き換え可否の判断の実験を行う．被験者に使い分けの際，選ばなかった単語（対義語）を文章にあてはめさせる．その対義語に沿うように文を知識的な内容だけ逆に変更した時（直前直後の付属語，係り受け関係にある文中の格助詞は変更しない），対義語に置き換えれる場合，置き換え可（Y）を，置き換えできない場合は置き換え不可（N）を選択させる．また，使い分けの際，判断不可を選んだ場合は使い方の違いがないということなので置き換え可（Y）を選ばせる．また，使い分けの選択が間違っていた場合は間違えるほど使い方の違いがないということなので置き換えできると判断し，集計する際置き換え不可を選択していても置き換え可として集計する．実際の例文を表4.6に示す．左の（）内が使い分けの実験の際に使う対義語対で，右の（Y-N）が対義語対の置き換え可否の実験に使うものである．

表 4.6: 被験者実験の例

「少し-たくさん」	
(少し-たくさん-判断不可)	(Y-N)
でも早く1桁に入ることが目標」と悔し涙をぬぐった	
世界の(少し-たくさん-判断不可)(Y-N)の苦しみを自分は理解している	
チョコやあめが(少し-たくさん-判断不可)(Y-N)入っているパックを買って、小分けにしたもの	
具が(少し-たくさん-判断不可)(Y-N)詰まり、かけるだけでごちそうになるキューピーの「具のソース」	
職員が(少し-たくさん-判断不可)(Y-N)流された	
さまざまな改革は選手やコーチに戸惑いを与えながらも(少し-たくさん-判断不可)(Y-N)ずつ浸透中	
嫌がらない事を確認しながら(少し-たくさん-判断不可)(Y-N)ずつ時間を延ばしていく	
私は駅から(少し-たくさん-判断不可)(Y-N)離れ、料金もやや高いが、間違いなく置けるところを探し当てた	
うどんをゆでた後、水洗いし、丼に入れ、醤油を(少し-たくさん-判断不可)(Y-N)入れて食べます	
競争相手は増えたが、(少し-たくさん-判断不可)(Y-N)の人が研究を進め、この分野が発展するのはうれしい	

4.3 使い分けの実験結果

機械学習の再現率の高さごとに対義語の組を分類したものを表 4.7 に示す．それぞれの対義語ごとの結果を名詞は表 4.8 と表 4.9，動詞は表 4.10 と表 4.11，形容詞は表 4.12 と表 4.13，副詞は表 4.14 に示す．

表 4.7: 対義語の分類結果

	高	中	低
名詞	12	18	20
動詞	9	22	19
形容詞	2	21	23
副詞	3	3	2

表 4.8: 名詞の対義語対の結果 1

対義語	再現率	データ数
増産	79.32%	977
減産	79.84%	977
充電	80.50%	159
放電	78.62%	159
勝訴	69.20%	1000
敗訴	67.80%	1000
黒地	66.03%	156
白地	69.23%	156
減税	87.90%	1000
増税	86.60%	1000
楽勝	86.15%	325
辛勝	88.31%	325
後輩	67.90%	1000
先輩	66.90%	1000
賛成	81.70%	1000
反対	84.50%	1000
一方	96.00%	1000
両方	97.60%	1000
当番	81.21%	149
非番	87.92%	149
悲劇	86.50%	1000
喜劇	84.20%	1000
洋風	66.30%	365
和風	64.38%	365
閉場	86.78%	121
開場	91.74%	121
着衣	97.74%	177
脱衣	93.79%	177
立秋	73.53%	68
立春	60.29%	68
和裁	61.29%	62
洋裁	72.58%	62
アマ	87.10%	1000
プロ	86.70%	1000
変数	88.24%	51
定数	80.39%	51
商	92.19%	461
積	92.41%	461
解散	91.90%	1000
結成	91.30%	1000
公設	75.47%	375
私設	79.20%	375
垂直	99.30%	1000
水平	99.70%	1000
格下げ	88.20%	839
格上げ	89.99%	839
ノンフィクション	78.72%	545
フィクション	85.14%	545
新参	83.82%	136
古参	83.09%	136

表 4.9: 名詞の対義語対の結果 2

対義語	再現率	データ数
門弟	61.67%	60
師匠	65.00%	60
側室	69.03%	113
正室	69.03%	113
入社	85.90%	1000
退社	90.00%	1000
モノクロ	84.21%	608
カラー	78.62%	608
安眠	81.11%	90
不眠	82.22%	90
男声	57.14%	84
女声	58.33%	84
菜食	84.62%	91
肉食	80.22%	91
寡黙	92.86%	84
多弁	98.81%	84
得点	89.80%	1000
失点	86.90%	1000
迎撃	92.28%	518
出撃	93.82%	518
夏場	68.49%	952
冬場	70.48%	952
悲報	85.77%	239
朗報	78.24%	239
ワイヤレス	95.73%	117
有線	83.76%	117
女手	77.94%	68
男手	69.12%	68
拘禁	82.35%	238
釈放	84.87%	238
着信	91.38%	232
発信	86.21%	232
顕在	98.36%	611
潜在	97.87%	611
文語	63.30%	109
口語	59.63%	109
プラス	81.80%	1000
マイナス	83.40%	1000
前払い	77.92%	154
後払い	79.87%	154
否認	93.13%	364
是認	96.15%	364
虚像	74.31%	144
実像	77.78%	144
公示	94.79%	461
内示	91.32%	461
減量	99.26%	136
増量	94.85%	136
不毛	100.00%	64
肥沃	100.00%	64

表 4.10: 動詞の対義語対の結果 1

対義語	再現率	データ数
恥じる	93.01%	143
誇る	93.01%	143
増える	63.50%	1000
減る	63.30%	1000
負ける	77.80%	1000
勝つ	78.30%	1000
別れる	78.72%	296
会う	79.39%	296
許す	91.40%	1000
禁じる	91.70%	1000
だます	93.75%	64
引っ掛かる	93.75%	64
出会う	82.43%	296
別れる	79.73%	296
落とす	80.40%	1000
上げる	84.00%	1000
送る	91.50%	1000
迎える	93.10%	1000
伸ばす	77.42%	186
曲げる	79.57%	186
通り抜ける	89.74%	78
突き当たる	85.90%	78
冷やす	80.36%	112
沸かす	79.46%	112
目覚める	83.40%	247
眠る	83.40%	247
固まる	79.55%	176
溶ける	76.70%	176
ささやく	66.88%	154
叫ぶ	72.08%	154
隠れる	82.99%	294
見える	81.29%	294
憎む	73.12%	93
慈しむ	76.34%	93
減る	90.00%	1000
増す	88.70%	1000
やる	97.80%	1000
もらう	93.80%	1000
冷える	73.72%	137
温まる	75.18%	137
温める	81.35%	370
冷やす	82.43%	370
褒める	73.76%	141
しかる	73.05%	141
引き下げる	75.60%	1000
引き上げる	74.30%	1000
遅れる	84.90%	1000
進む	84.80%	1000
離れる	85.71%	112
くつつく	95.54%	112

表 4.11: 動詞の対義語対の結果 2

対義語	再現率	データ数
締める	85.50%	262
緩める	86.26%	262
攻める	95.10%	1000
防ぐ	94.40%	1000
取り外す	79.05%	105
取り付ける	84.76%	105
貸す	75.56%	622
借りる	76.53%	622
閉まる	89.60%	125
開く	89.60%	125
思い出す	87.70%	1000
忘れる	84.80%	1000
つなぐ	91.44%	444
断ち切る	90.32%	444
出迎える	87.50%	168
見送る	86.90%	168
遠のく	85.29%	68
近寄る	88.24%	68
詰まる	89.41%	85
通り抜ける	84.71%	85
別れる	74.32%	296
付き合う	71.96%	296
くっつける	62.96%	54
放す	74.07%	54
欠ける	93.94%	297
足りる	94.95%	297
乗る	86.46%	820
降りる	88.66%	820
押す	88.30%	1000
引く	89.50%	1000
尋ねる	90.90%	1000
答える	89.70%	1000
問う	92.50%	1000
答える	95.90%	1000
閉める	78.09%	283
開ける	78.09%	283
預ける	85.84%	565
返す	84.42%	565
下げる	79.90%	1000
上げる	82.10%	1000
見下ろす	83.01%	465
見上げる	83.44%	465
離す	85.11%	188
付ける	80.32%	188
浮く	84.80%	454
沈む	85.24%	454
下ろす	88.06%	620
上げる	89.03%	620
遅らせる	67.93%	474
早める	66.67%	474

表 4.12: 形容詞の対義語対の結果 1

対義語	再現率	データ数
長い	74.70%	1000
短い	76.20%	1000
まずい	80.60%	1000
うまい	81.10%	1000
難しい	92.80%	1000
やすい	95.20%	1000
大きい	78.40%	1000
小さい	77.10%	1000
細い	75.40%	1000
太い	74.40%	1000
堅い	85.43%	405
軟らかい	89.63%	405
易しい	73.68%	95
難しい	74.74%	95
柔らかい	89.83%	787
固い	87.04%	787
明るい	75.40%	1000
暗い	74.40%	1000
厳しい	84.90%	1000
甘い	81.70%	1000
涼しい	82.35%	170
蒸し暑い	80.59%	170
多い	73.50%	1000
少ない	74.80%	1000
ふさわしい	86.42%	383
そぐわない	89.56%	383
古めかしい	80.72%	83
目新しい	75.90%	83
心強い	81.22%	229
心もとない	78.17%	229
まずい	82.30%	1000
おいしい	83.80%	1000
黒い	68.00%	1000
白い	66.20%	1000
狭い	71.30%	1000
広い	72.60%	1000
濃い	84.10%	1000
薄い	82.80%	1000
暑い	71.70%	1000
寒い	70.90%	1000
軟らかい	78.52%	405
硬い	70.86%	405
美しい	73.85%	195
醜い	72.82%	195
手ぬるい	90.91%	55
手厳しい	85.45%	55
冷たい	83.10%	1000
熱い	81.50%	1000
鈍い	91.82%	746
鋭い	91.69%	746

表 4.13: 形容詞の対義語対の結果 2

対義語	再現率	データ数
女らしい	73.77%	61
男らしい	62.30%	61
いとしい	79.38%	97
憎い	73.20%	97
暖かい	81.84%	914
冷たい	83.81%	914
心強い	76.32%	114
心細い	78.95%	114
詳しい	86.25%	80
疎い	83.75%	80
高い	84.40%	1000
安い	89.40%	1000
近い	88.80%	1000
遠い	91.80%	1000
かわいい	74.66%	146
憎い	69.18%	146
軟らかい	86.91%	405
固い	82.47%	405
軽い	76.30%	1000
重い	78.90%	1000
浅い	88.00%	1000
深い	87.40%	1000
速い	80.10%	1000
遅い	79.40%	1000
柔らかい	78.91%	787
硬い	77.00%	787
のろい	85.96%	57
素早い	92.98%	57
悪い	85.30%	1000
よい	80.00%	1000
新しい	77.80%	1000
古い	76.40%	1000
強い	80.90%	1000
弱い	82.50%	1000
高い	65.90%	1000
低い	66.50%	1000
おもしろい	71.57%	626
つまらない	69.01%	626
たやすい	83.65%	104
難しい	86.54%	104
薄い	83.10%	1000
厚い	84.60%	1000

表 4.14: 副詞の対義語対の結果

対義語	再現率	データ数
うっすら	94.21%	397
はっきり	92.70%	397
ちょっぴり	83.17%	101
どっさり	84.16%	101
ぼんやり	88.01%	567
はっきり	82.19%	567
ぐずぐず	66.00%	50
はきはき	74.00%	50
うっかり	89.89%	475
わざと	94.32%	475
もう	80.00%	1000
まだ	79.90%	1000
たくさん	92.70%	1000
少し	94.80%	1000
こってり	100.00%	65
あっさり	98.46%	65

使い分けの実験の結果，表 4.7 より，名詞は格が変化しないので，文法的な使われ方の差がないと考えられ低が多くなることが予想された．予想どおり低が多く高が少ないという結果になった．動詞は格が変わることがあるので高が多くなると予想されたが，高がもっとも少なく中と低に多く分布した．形容詞は文法的な使われ方の差がないと考えられ低が多くなることが予想された．予想通り，低が少なく続いて中が多いという結果となった．副詞は実験対象の対義語対も少なく，あまり傾向が把握できない．

4.4 被験者実験

3人の被験者実験の結果を表 4.15 と表 4.16 と表 4.17 に示す．表 4.15 と表 4.17 中の数値は置き換え可であると判断された回数である．また，表 4.15 の副詞の低と形容詞の高は実験した対義語対の数が3個ではなく2個なので数値を1.5倍している．表 4.16 は表 4.15 の結果を， $3(\text{分類ごとに実験した対義語対の数}) \times 10(1\text{組の対義語対の問題数}) \times 3(\text{被験者の人数})$ の90で割り，割合にしたものである．

表 4.15: 被験者実験の結果 1

	名詞	動詞	形容詞	副詞	合計
高	39	31	64.5	48	182.5
中	57	38	64	41	200
低	82	65	78	61.5	286.5

表 4.16: 被験者実験の結果 2

	名詞	動詞	形容詞	副詞	合計
高	0.43	0.34	0.72	0.53	0.49
中	0.63	0.42	0.71	0.46	0.57
低	0.91	0.72	0.87	0.68	0.81

表 4.17: 被験者実験の結果 3

品詞	対義語対	分類分け	置き換え可
名詞	「潜在」「顕在」	高	7
	「是認」「否認」		16
	「肥沃」「不毛」		16
動詞	「引っ掛かる」「だます」		4
	「迎える」「送る」		4
	「誇る」「恥じる」		23
形容詞	「鋭い」「鈍い」		22
	「難しい」「やすい」		21
副詞	「少し」「たくさん」		16
	「あっさり」「こってり」		21
	「うっすら」「はっきり」		11
名詞	「発信」「着信」		中
	「退社」「入社」	22	
	「格上げ」「格下げ」	28	
動詞	「尋ねる」「答える」	17	
	「くつつく」「離れる」	12	
	「眠る」「目覚める」	9	
形容詞	「固い」「柔らかい」	16	
	「そぐわない」「ふさわしい」	25	
	「熱い」「冷たい」	23	
副詞	「はっきり」「ぼんやり」	12	
	「わざと」「うっかり」	15	
	「ちょっぴり」「どっさり」	14	
名詞	「実像」「虚像」	低	27
	「カラー」「モノクロ」		25
	「正室」「側室」		30
動詞	「勝つ」「負ける」		28
	「叫ぶ」「ささやく」		23
	「沸かす」「冷やす」		14
形容詞	「美しい」「醜い」		26
	「少ない」「多い」		30
	「憎い」「いとしい」		22
副詞	「まだ」「もう」		20
	「ぐずぐず」「はきはき」		21

表 4.15 と表 4.16 より，被験者実験と機械学習の性能を比較した結果，全体としては高と低は概ね機械学習の性能と対義語対の置き換えの可否に逆の相関がある．また，名詞と動詞に関しては高から低に近づくほど置き換え可の数値が上がり，機械学習の性能と対義語対の置き換え可否に逆の相関がある．しかし，形容詞と副詞に関しては高と低は機械学習の性能と対義語対の置き換え可否に逆の相関があると言えるが，中が高より低くなっている．

第5章 考察

本章では、考察を記述する。5.1節では、被験者実験と機械学習の性能の傾向が一致した対義語対の考察について記述する。5.2節では、被験者実験と機械学習の性能の傾向が一致しなかった対義語対の考察について記述する。

5.1 被験者実験と機械学習の性能の傾向が一致した対義語対の考察

機械学習の性能が低いと対義語対は置き換え可能であると考えられ、機械学習の性能が高いと対義語対は置き換え不可能であると考えられる。本節では、素性分析を行い、被験者実験と機械学習の性能の傾向が一致した対義語対の考察を行う。

また、正規化 α 値が高かった素性の例も表に示す。機械学習が判定を行う際に参考にした素性とその素性の正規化 値を示す。正規化 値とは、最大エントロピー法で求まる 値を全分類先での合計が1となるように正規化した値である。各素性の、分類先ごとに与えられた正規化 値が高いほど、その分類先であることを推定するのに重要な素性であることを意味する。例えば、ある素性 S のある分類先 A に対する正規化 値が X とすると、その素性 S のみで分類を行った場合、分類先 A と推定する確率が X となることを意味する。

5.1.1 分類分けが高で置き換え可の値が低かったもの

ここでは分類分けが高で置き換え可の値が低かったものとして、「潜在」「顕在」と「引っ掛かる」「だます」と「迎える」「送る」と「うっすら」「はっきり」に関して考察する。

まず、「潜在」「顕在」に関して考察する。「潜在」「顕在」は置き換え可と判断された割合は0.23(7/30)である。表5.1に機械学習の性能を示す。表5.2に機械学習が参考にした素性を示す。

表 5.1: 機械学習の性能 (「潜在」「顕在」)

	データ数	再現率
潜在	611	98.36%
顕在	611	97.87%

表 5.2: 機械学習が参考にした素性 (「潜在」「顕在」)

潜在		顕在	
素性	正規化 α 値	素性	正規化 α 値
素性 5:対象語の含まれる文節の自立語の品詞が名詞	0.63	素性 2:化(直後)	0.75
素性 2:的(直後)	0.57	素性 1:憲法	0.57
素性 2:「(直前)	0.57	素性 1:条約	0.56
素性 1:EU	0.56	素性 1:冷戦	0.55
素性 2:対象語が文頭	0.55	素性 1:潜在	0.55

有用な素性としては、「潜在」は、「的」が直後にくることや、直後に名詞がきて複合語を作る(「潜在力」など)用法をすることがあった。以下に例を示す。

- その 潜在 力への期待が強いわけですが、そのひとつ環日本海経済圏構想がさかんに言われるようになりましたね
- すべての政治家が、潜在 的にはだれでも大統領になれるのに対し、前、元大統領だけは絶対になれない

また、文頭や会話文の文頭でよく使われることなどがあった。「顕在」は「化」が直後にくることや、「潜在」と共起しやすいことなどがあった。以下に例を示す。

- 暴力性を 顕在 化させる青年
- 経産相は「新たな視点と工夫で潜在力を 顕在 化させるヒントをもらった」と強調した

「潜在」の場合は顕在とは共起しやすい素性はみられなかった。また、両方に共通することだが「潜在」は「EU」、「顕在」は「憲法」、「条約」、「冷戦」など政治に関わる素性が多くみられた。これは、新聞から文を抽出していることも原因の一つと考えられる。

置き換え可の値が低い理由としては、「顕在」は「顕在化」という慣用的な表現がよく使われ、「潜在」は「潜在的」という慣用的な表現や、「顕在」では使えないが、直後

に名詞が来て複合語を作る用法がよく使われていたため置き換え可の値が低くなったと考えられる。

次に、「引っ掛かる」「だます」に関して考察する。「引っ掛かる」「だます」は置き換え可と判断された割合は0.13(4/30)である。表 5.3 に機械学習の性能を示す。表 5.4 に機械学習が参考にした素性を示す。

表 5.3: 機械学習の性能 (「引っ掛かる」「だます」)

	データ数	再現率
引っ掛かる	64	93.75%
だます	64	93.75%

表 5.4: 機械学習が参考にした素性 (「引っ掛かる」「だます」)

引っ掛かる		だます	
素性	正規化 α 値	素性	正規化 α 値
素性 1:に (直前)	0.75	素性 2:を (直前)	0.63
素性 2:対象語が文末	0.54	素性 1:人	0.55

有用な素性としては、「引っ掛かる」は、「に」が直前に来ることや、「引っ掛かる」が文末に来ることが多く見られた。以下に例を示す。

- だから高学歴なのにオウムなんかに引っ掛かると教育に危機感を示す
- 新・新党「結党宣言」案の中に引っ掛かる一文がある

また新聞から獲得したデータの中に「だます」の対義語として捉えられる例がほとんど見られなかった。「だます」は「を」が直前にくることや、「人」と共起しやすいことなどがあった。以下に例を示す。

- 「キツネは、外国人にとっては人を だます イメージがあるが、日本では神様の使いだ、と説明する」と助言した
- 卑しい顔にならず、私利私欲なく難解な文学論を語りながら、平然と人を だます

データ数が少なく「引っ掛かる」「だます」ともに格助詞の使い方以外の素性はあまり得られなかった。置き換え可の値が低い理由としては、「引っ掛かる」は「に引っ掛か

る」という使い方をし、「だます」は「をだます」という使い方をするので文法上の使い方の違いがはっきりしているため置き換え可の値が低くなったと考えられる。また、「引っ掛かる」の場合、言語の多義性により「だます」の対義語としてではなく、「(物事に)引っ掛かる」という意味で使われている文が多かったことも原因と考えられる。

次に「迎える」「送る」に関して考察する。「迎える」「送る」は置き換え可と判断された割合は0.40(13/30)である。表 5.5 に機械学習の性能を示す。表 5.6 に機械学習が参考にした素性を示す。

表 5.5: 機械学習の性能 (「迎える」「送る」)

	データ数	再現率
送る	1000	91.50%
迎える	1000	93.10%

表 5.6: 機械学習が参考にした素性 (「迎える」「送る」)

迎える		送る	
素性	正規化 α 値	素性	正規化 α 値
素性 1:周年	0.74	素性:日々	0.69
素性 1:日	0.67	素性 1:毎日	0.60
素性 1:年	0.64	素性 1:感謝	0.59
素性 1:死	0.64	素性 1:郵便	0.58
素性 1:開幕	0.59	素性 1:コメ	0.57

有用な素性としては「迎える」は「日」「死」「開幕」など、特定のタイミングもしくは「周年」「年」といった長い期間のはじめを「迎える」という用法が見られた。以下に例を示す。

- どんな死を迎える かも、医療ケアの一部と考えられています
- 阪神は今季、球団創立 60 周年を 迎える

「送る」は「日々」「毎日」など連続した期間を「送る」という表現や「感謝」「郵便」「コメ」といった郵送に関するものが多く見られた。以下に例を示す。

- そのために、主人の写真を前にして、ない頭をあれやこれやとひねって、毎日を大切に 送る ことにした

- 問題はどのような形でコメを 送る か

置き換え可の値が低くなった理由としては、「迎える」「送る」はともに期間や時間に関係する語を目的語とすることが多いが、それぞれ「日々を送る」や「死を迎える」といった、慣用的な表現があるためだと考えられる。また、「送る」の場合は多義性により、郵送などに関する意味だとその文中での対義語は「受け取る」や「受信する」などの単語であることもあり置き換え可の値が低くなったと考えられる。

次に「うっすら」「はっきり」に関して考察する。「うっすら」「はっきり」は置き換え可と判断された割合は0.37(11/30)である。表 5.7 に機械学習の性能を示す。表 5.8 に機械学習が参考にした素性を示す。

表 5.7: 機械学習の性能 (「うっすら」「はっきり」)

	データ数	再現率
うっすら	397	94.21%
はっきり	397	92.70%

表 5.8: 機械学習が参考にした素性 (「うっすら」「はっきり」)

うっすら		はっきり	
素性	正規化 α 値	素性	正規化 α 値
素性 1:程度	0.65	素性:問題	0.64
素性 1:朝	0.64	素性 1:姿勢	0.63
素性 46:対象語が含まれる文節に係る文節の最初の自立語が「見える」	0.60	素性 1:結果	0.61
素性 1:涙	0.59	素性 1:けじめ	0.60
素性 1:雪	0.59	素性 40:対象語が含まれる文節に係る文節の自立語が「する」	0.60

有用な素性としては、「うっすら」は「程度」「朝」「涙」などの単語と共起しやすいことが見られた。また、「うっすら」が文頭に来ることがよく見られた。以下に例文を示す。

- 今月 2 3 日に本社の一部で先行導入したところ、オフィスの明るさは人の顔が うっすら 見える程度に

- 東日本大震災の被災地・岩手県沿岸部は、18日夜から降り出した雪が19日朝になっても残り、うっすらと白く染まった
- うっすらと涙がにじんでいるのに気づいたが、込み合う車内で涙をぬぐうことはできなかった

また、「うっすら見える」という表現や「うっすらと見える」という表現が多く見られた。「はっきり」は「問題」「姿勢」「結果」「けじめ」などの単語と共起しやすいことが見られた。以下に例文を示す。

- 失業問題は景気循環だけでは解決できないことが はっきりした
- その姿勢に今季に懸ける気持ちが はっきりと表れている
- どういう結果が出るかは来年の歌曲の年において はっきりするだろう
- はっきりとしたけじめを求める

また、「はっきりする」という表現が多く見られた。置き換え可の値が低くなった理由としては、「うっすら」は「涙」や「雪」、表5.8では挙げられていないが、「汗」や「雲」や「あかり」などのような単語とともに使われ、「はっきり」は「はっきりする」という慣用的な表現がとてもよく使われており、ともに慣用的な表現がよく使われているため置き換え可の値が低くなったと考えられる。

分類分けが高で置き換え可の値が低かったものとして「潜在」「顕在」と「引っ掛かる」「だます」と「迎える」「送る」と「うっすら」「はっきり」を考察した。その結果、分類分けが低で置き換え可の値が高かったものの特徴として、以下のようなものが見られた。

- 慣用的な表現が多い、もしくは特定の慣用的な表現がよく使われる
- 多義性がある
- 格の変化が起こる
- 有用な素性が多く得られる

5.1.2 分類分けが低で置き換え可の値が高かったもの

ここでは分類分けが低で置き換え可の値が高かったものとして、「正室」「側室」と「勝つ」「負ける」と「少ない」「多い」と「ぐずぐず」「はきはき」に関して考察する。

まず、「正室」「側室」に関して考察する。「正室」「側室」は置き換え可と判断された割合は1(30/30)である。表 5.9 に機械学習の性能を示す。表 5.10 に機械学習が参考にした素性を示す。

表 5.9: 機械学習の性能 (「正室」「側室」)

	データ数	再現率
正室	113	69.03%
側室	113	69.03%

表 5.10: 機械学習が参考にした素性 (「正室」「側室」)

正室		側室	
素性	正規化 α 値	素性	正規化 α 値
素性 1:側室	0.69	素性 1:正室	0.59
素性 1:北政所	0.60	素性 1:阿茶局	0.54
素性 1:濃姫	0.54	素性 1:常盤	0.54

有用な素性としては、「正室」は「北政所」「濃姫」など、「正室」であった人物の素性が多く見られた。また、「側室」と共起しやすいことも見られた。また、「側室」の場合も「正室」と共起しやすい。以下に例文を示す。

- テレビ朝日系の連続ドラマ「信長のシェフ」に信長の 正室・濃姫役で出演中
- 本展では、狩野派作とされる秀吉の 正室・おねと側室・淀殿の肖像画を両脇に配す

「側室」も「正室」と同様に「阿茶局」「常盤」など「側室」であった人物の素性が多く見られた選挙に関わるものも多く見られた。以下に例文を示す。

- 同協議会は9日、清盛の 側室 になる常盤御前役の武井咲さんの衣装を展示するなど内容をリニューアルして、てこ入れを図り、「ドラマはこれからが佳境」と期待をつないでいる

- 2016年に放送されるNHK大河ドラマ「真田丸」で、徳川家康の最愛の側室、阿茶局を演じる

置き換え可の値が高くなった理由は、「正室」「側室」はともに慣用的な表現があまりなく、格の変化なども起こらず、多義性がないことだと考えられる。機械学習の性能が低い原因は、「正室」「側室」はともに妻という関係性を表す言葉なので使い方の違いがほとんど無く、有用な素性があまり得られなかったことが原因と考えられる。

次に、「勝つ」「負ける」に関して考察する。「勝つ」「負ける」は置き換え可と判断された割合は0.93(28/30)である。表5.11に機械学習の性能を示す。表5.12に機械学習が参考にした素性を示す。

表 5.11: 機械学習の性能(「勝つ」「負ける」)

	データ数	再現率
勝つ	1000	78.30%
負ける	1000	77.80%

表 5.12: 機械学習が参考にした素性(「勝つ」「負ける」)

勝つ		負ける	
素性	正規化 α 値	素性	正規化 α 値
素性 1:目標	0.76	素性 1:戦争	0.80
素性 1:自信	0.74	素性 1:政治	0.70
素性 1:力	0.71	素性 1:党	0.66
素性 1:記録	0.67	素性 1:政府	0.65
素性 1:引き分け	0.66	素性 1:与党	0.64

有用な素性としては、「勝つ」は「目標」「自身」「力」「記録」など、「勝利」から連想されるようなものが多く見られた。また、「勝つか」「引き分け」るか」という表現が多く見られた。この表現が多く見られたのは新聞に、リーグ戦の優勝や勝ち抜けを決めたりすることが掲載されているためだと考えられる。以下に例文を示す。

- 日本はオーストラリアに勝つか引き分けるかで、5大会連続5回目のW杯本大会出場が決まる
- 勝に勝つ、自分に活前日に大会コース記録に並ぶ65をマークした15歳の高校1年生に、ツアー2勝の21歳が対抗心を燃やした

「負ける」は「政治」「党」「政府」「与党」など選挙に関わるものが多く見られた。また「戦争」という素性も見られた。これは新聞に掲載されている、戦争に関する記事は日本が第二次世界大戦に負けたことに関する記事が多いことが原因だと考えられる。以下に例文を示す。

- 日本が負けることは、戦争を始めたときからもう分かっていたから
- 自民党が非自民勢力に負けるだろうという政治状況(への認識)を有権者が持っていたと思うし、私も持っていた

置き換え可の値が高くなった理由は、「勝つ」「負ける」ともに慣用的な表現があまりなく、格の変化なども起こらず、多義性がないことだと考えられる。機械学習の性能が低い原因は、「勝つ」「負ける」ともによく使われる言葉なので、「勝つ」「負ける」が出現する文章内容の種類が多いことが原因だと考えられる。

次に「少ない」「多い」に関して考察する。「少ない」「多い」は置き換え可と判断された割合は1(30/30)である。表 5.13 に機械学習の性能を示す。表 5.14 に機械学習が参考にした素性を示す。

表 5.13: 機械学習の性能(「少ない」「多い」)

	データ数	再現率
少ない	1000	74.80%
多い	1000	73.50%

表 5.14: 機械学習が参考にした素性(「少ない」「多い」)

少ない		多い	
素性	正規化 α 値	素性	正規化 α 値
素性 1:情報	0.73	素性 1:医療	0.71
素性 1:要因	0.68	素性 1:建設	0.65
素性 1:選挙	0.63	素性 1:雨	0.64
素性 1:テレビ	0.62	素性 1:トラブル	0.64
素性 1:農業	0.68	素性 1:反対	0.63

素性としては、「少ない」は「情報」「要因」「選挙」「テレビ」「農業」などが見られた。しかし、素性に共通点などは見られなかった。以下に例文を示す。

- 農業を再開した人が少ない中、遠藤アキエさん（75）が野菜をどっさり持ち込んだ
- なかでも後発で、系列局数の少ないテレビ東京に対しては露骨だ

「多い」は「医療」「建設」「雨」「トラブル」「反対」などが見られたが、こちらも共通点などは見られなかった。以下に例文を示す。

- 人数の多い組織が小さいグループをつぶしたり、メンバーへのいじめなどのトラブルが増えている
- （経営の）規模や周囲の状況によって変わらなければならないのに、手間とか、支障があるとか、反対する人が多い

置き換え可の値が高くなった理由は、「少ない」「多い」ともに慣用的な表現があまりなく、格の変化なども起こらず、多義性がないことだと考えられる。また、「少ない」「多い」は程度を表す言葉なので使い方の違いも少なく置き換え可の値が高くなったと考えられる。も機械学習の性能が低い原因は、「少ない」「多い」ともによく使われる言葉なので、「少ない」「多い」出現する文章内容の種類が多いことが原因だと考えられる。また、「勝つ」「負ける」より機械学習の性能が低いため、より広く使われていると考えられる。

次に「ぐずぐず」「はきはき」に関して考察する。「ぐずぐず」「はきはき」は置き換え可と判断された割合は0.7(21/30)である。表 5.15 に機械学習の性能を示す。表 5.16 に機械学習が参考にした素性を示す。

表 5.15: 機械学習の性能（「ぐずぐず」「はきはき」）

	データ数	再現率
ぐずぐず	50	66.00%
はきはき	50	74.00%

表 5.16: 機械学習が参考にした素性（「ぐずぐず」「はきはき」）

ぐずぐず		はきはき	
素性	正規化 α 値	素性	正規化 α 値
素性 1: 結局	0.55	素性 1: 人	0.61
素性 1: 空模様	0.53	素性 1: 口調	0.56

素性としては、「ぐずぐず」は「結局」「空模様」などが見られた。「ぐずぐずした空模様」という慣用的な表現があった。以下に例文を示す。

- あの時の自民党は、政権の不人気を恐れて選挙を先延ばしして反転の機会をうかがったが、結局、ぐずぐずした姿勢とみられて国民の幻滅を招き、選挙での大敗に至った
- 1日中 ぐずぐずした空模様って言うもんな

「はきはき」は「人」「口調」などが見られた。「はきはきした口調」という慣用的な表現があった。以下に例文を示す。

- 画面は替わり、一転 はきはきした口調で話す同じ教諭の映像が流れた
- 私は阪神を担当したことがないので、人となりもよく知らなかったのだが、はきはき自分の言葉で話す選手だとわかった

置き換え可の値が高くなった理由は、「ぐずぐず」「はきはき」ともに慣用的な表現があまりなく、格の変化なども起こらず、多義性がないことだと考えられる。機械学習の性能が低い原因は、データ数が少なく、「ぐずぐず」「はきはき」ともに格の変化が起こらないからだと考えられる。データ数が多ければ、少しは慣用的な表現があるので、分類分けで中に分類される程度に正解率があがると考えられる。

分類分けが低で置き換え可の値が高かったものとして「正室」「側室」と「勝つ」「負ける」と「少ない」「多い」と「ぐずぐず」「はきはき」を考察した。その結果、分類分けが低で置き換え可の値が高かったものの特徴として、以下のようなものが見られた。

- 慣用的な表現が少ない、もしくはあまり使われない
- 多義性が少ない
- 格の変化が起こりにくい
- 出現する文章内容の種類が多い

被験者実験と機械学習の性能の傾向が一致した対義語対の考察をした結果、次のようなことがわかった。

一つ目是对義語対に慣用的な表現が少ない、もしくはあまり使われない場合、置き換え可の値が高くなることである。また、その際、慣用的な表現は機械学習の有用な

素性になるので、慣用的な表現が少ない、もしくはあまり使われない場合は機械学習の性能が低くなる。二つ目は対義語対のどちらかの単語に多義性が少ない場合、置き換え可の値が高くなることである。また、その際、多義性により文中のある単語 X の対義語 Y が文中に出現した時、Y はその文中では X の対義語ではなかった場合、X が出現する文や Y が X の対義語として出現する時の文と大幅に違うので機械学習でも簡単に判断できる。よってそのような文が少なくなると機械学習の性能が低くなる。三つ目は対義語対の格の変化が起こりにくい場合、置き換え可の値が高くなることである。また、その際、格の変化という重要な素性が得られないため、機械学習の性能は低くなる。

これらのことは逆のことも言える。一つ目は、対義語対に慣用的な表現が多い、もしくはよく使われている場合置き換え可の値が低くなり、有用な素性が多く得られるので機械学習の性能が高くなる。二つ目は対義語対のどちらかの単語に多義性が多い場合、多義性により簡単に判断できる場合が多くなり、機械学習の性能が高くなる。三つ目は格の変化が起こりやすい場合、格のが特徴的であることを機械がよく学習し、機械学習の性能が高くなる。

また、出現する文章内容の種類が多いと学習しなければならない情報が多くなり、機械学習の性能が落ちる。このことは置き換え可否とは関係がないと考えられる。

「少ない」「多い」ともによく使われる言葉なので、「少ない」「多い」出現する文章内容の種類が多いことが原因だと考えられる。また、「勝つ」「負ける」より機械学習の性能が低いいため、より広く使われていると考えられる。

5.2 被験者実験と機械学習の性能の傾向が一致しなかった対義語対の考察

機械学習の性能が低いと対義語対は置き換え可能であると考えられ、機械学習の性能が高いと対義語対は置き換え不可能であると考えられる。本節では、素性分析を行い、被験者実験と機械学習の性能の傾向が一致しなかった対義語対の考察を行う。

また、正規化 α 値が高かった素性の例も表に示す。

5.2.1 分類分けが高だが置き換え可の値が高かったもの

ここでは分類分けが高だが置き換え可の値が高かったものとして、置き換え可の値が特に高かった「誇る」「恥じる」と「鋭い」「鈍い」に関して考察する。まず、「誇る」「恥じる」に関して考察する。「誇る」「恥じる」は置き換え可と判断された割合は0.77(23/30)である。表 5.17 に機械学習の性能を示す。表 5.18 に機械学習が参考にした素性を示す。

表 5.17: 機械学習の性能(「誇る」「恥じる」)

	データ数	再現率
誇る	143	93.01%
恥じる	143	93.01%

表 5.18: 機械学習が参考にした性能(「誇る」「恥じる」)

誇る		恥じる	
素性	正規化 α 値	素性	正規化 α 値
素性 1: 1	0.63	素性 1:こと	0.60
素性 1: 2	0.59	素性 1:自分	0.59
素性 2: 対象語が文末	0.57	素性 23:対象語を修飾する節内の最初の単語の品詞が形容詞	0.58
素性 1:世界	0.56	素性 26:対象語を修飾する節内の単語の品詞が形容詞	0.57
素性 1:優勝	0.54	素性 1:不明	0.53

有用な素性としては、「誇る」は「1」「2」などのような数字が多く見られた。これは順位や数値を誇るものとして多いからである。また、「誇る」が文末にきやすいことや、「世界」「優勝」などが見られた。以下に例文を示す。

- 「沖縄美(ちゅ)ら海水族館」(沖縄県)に続き全国2位の集客数を誇る
- デンマークと並んで世界一の水準を誇る

「恥じる」は「恥じること」や「不明を恥じる」といった慣用的な表現や、「自分の…を恥じる」といった表現や、「(形容動詞の名詞に変化したもの)を恥じる」といった用法が多く見られた。以下に例文を示す。

- また価格の安さに喜んだ自分のうかつさを恥じるとともに、当事者の苦悩はいかばかりかと、心が痛んできた
- 自らの軽率さに恥じる一瞬があった

置き換え可の値が高くなってしまった原因は、「誇る」「恥じる」はともに慣用的な用法が少なく、且つ文法的な使い方の違いがあまりなく置き換え可の値が高くなったからだと考えられる。文法的な使い方の違いがあまりないにも関わらず機械学習の性能が高いのは、有用な素性を多く得られたからだと考えられる。「誇る」「恥じる」は置き換え可能ではあるが使われ方に傾向がある。例えば、「誇る」の場合、誇るものとして順位や数値などとともに共起しやすいことや、「誇る」で文が終わることなどである、「恥じる」の場合、「自分の…を恥じる」といった表現や「(形容動詞の名詞に変化したもの)を恥じる」といった用法などである。これは日本語学習に役立つ知見である。

次に「鋭い」「鈍い」について考察する。「鋭い」「鈍い」は置き換え可と判断された割合は0.73(22/30)である。表 5.19 に機械学習の性能を示す。表 5.20 に機械学習が参考にした素性を示す。

表 5.19: 機械学習の性能 (「鋭い」「鈍い」)

	データ数	再現率
鋭い	746	91.70%
鈍い	746	91.81%

表 5.20: 機械学習が参考にした性能 (「鋭い」「鈍い」)

鋭い		鈍い	
素性	正規化 α 値	素性	正規化 α 値
素性 1:打球	0.62	素性 1:音	0.70
素性 1:切れ味	0.59	素性 1:消費	0.63
素性 1:攻め	0.57	素性 1:景気	0.62
素性 1:子供	0.56	素性 1:円	0.62
素性 1:視線	0.54	素性 1:ゴロ	0.60

有用な素性としては、「鋭い」は「打球」「切れ味」「攻め」「子供」「視線」など共起しやすい単語が見られた。以下に例文を示す。

- 打の中心でもある中村隼はフリー打撃でも 鋭い 打球を左翼方向へ
- 近づいた記者に 鋭い 視線が一斉に注がれる

鈍いは「消費」「景気」「円」など経済に関わることが多くみられた。以下に例文を示す。

- 国内では株高の恩恵を受ける高所得者層の消費は堅調なものの、中間所得層の消費は 鈍い
- 国内景気の回復ペースが 鈍い ことは、長銀の芳しくない財務内容をさらに圧迫する可能性がある」と指摘している

近年日本の経済状況が良くないことが原因だと考えられる。また、「音」「ゴロ」など共起しやすい単語が見られた。置き換え可の値が高くなってしまった原因は、「鋭い」「鈍い」はともに慣用的な用法が少なく、且つ文法的な使い方の違いがあまりなく置き換え可の値が高くなったからだと考えられる。また、「鋭い」「鈍い」は程度を表す言葉なので使い方の違いも少なく置き換え可の値が高くなったと考えられる。文法的な使い方の違いがあまりないにも関わらず機械学習の性能が高いのは、「鋭い」「鈍い」ともに正規化 値の高い素性が多く得られたことが原因だと考えられる。有用な素性であげたもの以外だと、「鋭い」だと「目」「振り」「指摘」「パス」などがあり、「鈍い」だと「痛み」「回復」「反応」「政府」などがある。

分類分けが高で置き換え可の値が高かったものとして「誇る」「恥じる」と「鋭い」「鈍い」を考察した。その結果、分類分けが高だが置き換え可の値が高かったものの特徴として、以下のようなものが見られた。

- 慣用的な表現が少ない、もしくはあまり使われない
- 格の変化が起こりにくい
- 正規化 値の高い素性が多く得られている
- それぞれの対義語の使い方に傾向がある

5.2.2 分類分けが低だが置き換え可の値が低かったもの

ここでは分類分けが低だが置き換え可の値が低かったものとして、置き換え可の値が低かった「沸かす」「冷やす」と「まだ」「もう」と「憎い」「いとしい」に関して考察する。

まず「沸かす」「冷やす」に関して考察する。「沸かす」「冷やす」は置き換え可と判断された割合は0.47(14/30)である。表 5.21 に機械学習の性能を示す。表 5.22 に機械学習が参考にした素性を示す。

表 5.21: 機械学習の性能 (「沸かす」「冷やす」)

	データ数	再現率
沸かす	112	80.36%
冷やす	112	79.46%

表 5.22: 機械学習が参考にした素性 (「沸かす」「冷やす」)

沸かす		冷やす	
素性	正規化 α 値	素性	正規化 α 値
素性 1:湯	0.63	素性 1:海水	0.57
素性 1:ガス	0.59	素性 1:プール	0.56
素性 1:風呂	0.59	素性 1:燃料	0.56
素性 1:まき	0.57	素性 1:ビール	0.56
素性 1:給湯	0.55	素性 1:冷却	0.56

有用な素性としては「沸かす」が「湯」「ガス」「風呂」「まき」「給湯」などお湯に関係するものなどが多く見られた。以下に例文を示す。

- ガスふる釜の場合、四二度に沸かすまでに約四十二分
- 大気中の熱を集めてお湯を沸かす 家庭用ヒートポンプ給湯器の愛称

「冷やす」では「ビール」などよく冷やすものや、「海水」「プール」「燃料」「冷却」など原発に関するものが見られた。これは使用している新聞が2011年～2015年のものを含んでいるため東日本大震災における原発事故を新聞で多く扱ったことに起因すると考えられる。以下に例文を示す。

- 燃料棒の溶融が深刻な原子炉や使用済み核燃料プールを冷やすため、1～3号機の原子炉には1日約400トンの水を注入、燃料プールにはこれまでに計約6500トンが注入された
- 津波による停電でプールの水を冷やす 海水ポンプが動かなくなっているのに加え、爆発で水温計が故障したため水温が測定できなくなっている

原発に関する素性が多いのは、取得できた文数が112文と少なく、さらに、新聞からデータを収集しているため、文の内容が偏ってしまったためだと考えられる。

置き換え可の値が低くなってしまった原因としては、「沸かす」の場合の対義語は概ね「冷やす」になるのだが、「冷やす」の場合、など、文中の意味によっては「温める」などが対義語になることが多くあった。以下に例文を示す。

- この麦茶、昔から体を 冷やす 働きがあるといわれてきた
- 特に「I」の冷却、つまりケガをした患部を 冷やす のが大事だという

よって、置き換え不可能となることが多くなったと考えられる。また、再現率が79.46%とほぼ中に分類される値であることも原因であると考えられる。

次に「憎い」「いとしい」に関して考察する。「憎い」「いとしい」は置き換え可と判断された割合は0.67(20/30)である。表??に機械学習の性能を示す。表5.24に機械学習が参考にした素性を示す。

表 5.23: 機械学習の性能(「憎い」「いとしい」)

	データ数	再現率
憎い	97	63.92%
いとしい	97	75.26%

表 5.24: 機械学習が参考にした素性(「憎い」「いとしい」)

憎い		いとしい	
素性	正規化 α 値	素性	正規化 α 値
素性 2:が(直前)	0.57	素性 1:娘	0.60
素性 1:犯人	0.56	素性 41:対象語が含まれる文節に係る文節の自立語の品詞が名詞	0.59

データ数が少なかったのであまり有用な素性が得られなかった。有用な素性としては、「憎い」は直前に「が」が来て「...が憎い」という表現や「犯人」などが見られた。

- 長さを変えるあたりが 憎い

- 犯人については、光子さんは「憎い」と一言

「もう」に関しては、直後に名詞が来て「いとしい...」という表現や「娘」などが見られた。以下に例文を示す。

- いとしい人からののがきが舞い込んだように、娘は目を輝かせた
- 娘との思い出は数えきれないほどあるが、あの時ほどわが子を いとしい と思ったことはない

などがあつた。「...が憎い」や「いとしい...」という表現は対義語に置き換えても問題無い。よって、この2つの表現はそれぞれの対義語対の使われやすい表現ではあるが慣用的な表現ではない。

置き換え可の値が低くなってしまった原因としては、多義性により、「憎い」の文中内での対義語が「いとしい」ではなく「好ましい」と判断されたものがあつたため置き換え可の値が低くなつたと考えられる。使い方に関しては、よく使われる慣用的な表現もなく、文法的な使い方の違いもなかつた。

次に「まだ」「もう」に関して考察する。「まだ」「もう」は置き換え可と判断された割合は0.67(20/30)である。表 5.25 に機械学習の性能を示す。表 5.26 に機械学習が参考にした素性を示す。

表 5.25: 機械学習の性能(「まだ」「もう」)

	データ数	再現率
まだ	1000	80.00%
もう	1000	79.90%

表 5.26: 機械学習が参考にした素性(「まだ」「もう」)

まだ		もう	
素性	正規化 α 値	素性	正規化 α 値
素性 1:者	0.72	素性 2:一	0.75
素性 1:日本	0.71	素性 2:1	0.70
素性 1:段階	0.70	素性 1:最後	0.69
素性 1:団	0.70	素性 2:対象語が文頭	0.64
素性 1:はず	0.68	素性 1:たくさん	0.68

「まだ」に関しては有用な素性が得られなかった．以下に例文を示す．

- 北陸の人たちの優しさ、風景の美しさといった、まだ気付かれていない日本のよさに、ね
- 一方では、ロシア側には「まだ日本側の提案を子細に検討する段階ではない」という思いが強い

「もう」に関しては直後に「1」と「一」が来ることが非常に多かった。「もう1回」, 「もう一度」といった表現が多く見られた．直後に来るものだと、「たくさん」も「もうたくさん」という表現でよく使われていた．また，文頭で使われることが多かった．以下に例文を示す．

- もう 漁業だけでは生きていけない家庭が大半だ
- もう 1人の主要人物が、東京のギャラリーオーナー、香魚子（あゆこ）だ

などがあった．この場合でも「1」と「一」が直後にくる表現が多く見られた．

置き換え可の値が低くなってしまった原因としては，もうの直後に「1」と「一」が見られる慣用的な表現が多く見られたためと考えられる．また，こちらも「沸かす」「冷やす」と同様に再現率が0.79とほぼ中に分類される値であることも原因であると考えられる．

分類分けが高で置き換え可の値が高かったものとして「沸かす」「冷やす」と「憎い」「いしい」と「まだ」「もう」を考察した．その結果，分類分けが低だが置き換え可の値が低かったものの特徴として，以下のようなものが見られた．

- 慣用的な表現が多い，もしくはよく使われる慣用的な表現がある
- どちらかの単語に多義性がある
- 出現する文章内容の種類が多い
- 正規化 値の高い素性があまり得られていない

5.2.3 分類分けが中だが置き換え可の値が高かったもの

ここでは、分類分けが中だが置き換え可の値が高かったものとして、最も置き換え可の値が高かった「格下げ」「格上げ」に関して考察する。「格上げ」「格下げ」は置き換え可と判断された割合は 0.93(28/30) である。表 5.27 に機械学習の性能を示す。表 5.28 に機械学習が参考にした素性を示す。

表 5.27: 機械学習の性能(「格下げ」「格上げ」)

	データ数	再現率
格下げ	839	88.20%
格上げ	839	89.99%

表 5.28: 機械学習が参考にした素性(「格上げ」「格下げ」)

格下げ		格上げ	
素性	正規化 α 値	素性	正規化 α 値
素性 1:国債	0.80	素性 1:国連	0.65
素性 1:銀行	0.69	素性 1:会談	0.62
素性 1:金融	0.67	素性 1:国際	0.60
素性 1:危機	0.62	素性 1:加盟	0.60
素性 1:悪化	0.61	素性 1:交渉	0.60

有用な素性としては「格下げ」は「国債」「銀行」「金融」などお金に関するものが多く見られた。以下に例文を示す。

- 世界市場の混乱不可避米国債の 格下げ で世界の金融市場の混乱は避けられそうにない
- スペインは不動産バブルの崩壊や欧州各国の国債価格下落などで銀行の財務内容が悪化しており、格下げ は銀行の資金調達をさらに難しくしそうだ

また、「危機」「悪化」などマイナスイメージのある言葉も多く見られた。「格上げ」は「国連」「会談」「国際」「加盟」「交渉」など政治に関するもの特に、国連に関わってくるものが多く見られた。以下に例を示す。

- パレスチナは米政権の反対を押し切り、昨年 11 月、国連で地位 格上げ に成功するなど、イスラエルに揺さぶりをかけ続けている

- 国際的には「国家」と認められていないが、これまでのオブザーバー資格から格上げされ、195番目の「加盟国」の地位を得た

などがあつた。「格下げ」ならお金に関するものばかりが見られ、「格上げ」なら国連に関するものばかりが見られた。

置き換え可の値が高くなってしまった原因としては、慣用的な表現があまりなく、さらに文法的な使い方の違いがあまりないので、置き換え可の値が高くなったためと考えられる。文法的な使い方の違いがあまりないのに機械学習の性能がよいのは、使われている文章が「格上げ」「格下げ」ともに特徴的であり、そのことを多く学習したことが原因だと考えられる。特徴的な文章を多く学習したのは、「格上げ」「格下げ」が元々使われる場面が限定される単語なことと、新聞からデータを取得しているので収集する文章に偏りが出たことが原因だと考えられる。

5.2.4 分類分けが中だが置き換え可の値が低かったもの

ここでは、分類分けが中だが置き換え可の値が高かったものとして、最も置き換え可の値が低かった「発信」「着信」に関して考察する。また、形容詞と副詞の中に分類されたものは置き換え可否と機械学習の性能の逆の相関が得られなかったので「固い」「柔らかい」と「はっきり」「ぼんやり」も考察する。「発信」「着信」は置き換え可と判断された割合は0.23(7/30)である。まず、「発信」「着信」について考察する。表5.29に機械学習の性能を示す。表5.30に機械学習が参考にした素性を示す。

表 5.29: 機械学習の性能(「着信」「発信」)

	データ数	再現率
着信	232	91.38%
発信	232	86.21%

表 5.30: 機械学習が参考にした素性 (「着信」「発信」)

着信		発信	
素性	正規化 α 値	素性	正規化 α 値
素性 1:電話	0.80	素性 1:情報	0.64
素性 1:携帯	0.71	素性 1:こと	0.62
素性 1:番号	0.68	素性 1:もの	0.58
素性 1:メール	0.62	素性 1:国際	0.56
素性 1:拒否	0.56	素性 1:日本	0.56

有用な素性としては「着信」は「電話」「携帯」「番号」「メール」「拒否」など携帯に関するものが多く見られた。以下に例を示す。

- 友子さんが好きだった曲で、荻原さんが携帯電話の着信音にも使っている
- 昼夜を問わず突発ニュースのチェックやメールの着信音にビクビクする毎日

「発信」は「情報」「こと」「もの」など、何を発信するかということについてのものや「国際」「日本」など世界に関するものなどが見られた。以下に例を示す。

- 今年は「日本はアジアの一員として、アジア情勢を世界に向けて発信する義務がある」(船山真チーフプロデューサー)という発想から、アジアハイウエーと取り組むことになった
- 仙台会合は、日本の復興の現状を世界へ発信し、同時に震災の教訓を国際社会で共有、途上国で防災意識を根付かせようと開かれた

などがあった。

中に分類されたにも関わらず置き換え可の値が低くなってしまった原因としては、両方ともある程度有用な素性が得られて機械学習の性能がある程度高くなったが、だが、「着信」は受動的なもので「発信」は能動的なものであるため、慣用的な表現が多くなった。例えば「着信」なら「着信拒否」や「着信履歴」などがあり、「発信」なら「発信力」や「発信者」などがある。よって、置き換え可の値が低くなってしまったと考えられる。

次に「固い」「柔らかい」について考察する。「固い」「柔らかい」は置き換え可と判断された割合は0.53(16/30)である。表 5.31 に機械学習の性能を示す。表??に機械学習が参考にした素性を示す。

表 5.31: 機械学習の性能 (「固い」「柔らかい」)

	データ数	再現率
固い	787	82.19%
柔らかい	787	88.01%

表 5.32: 機械学習が参考にした素性 (「固い」「柔らかい」)

固い		柔らかい	
素性	正規化 α 値	素性	正規化 α 値
素性 1:地盤	0.71	素性 1:体	0.70
素性 2:絆(直後)	0.66	素性 1:音	0.66
素性 1:握手	0.65	素性 1:物腰	0.64
素性 1:決意	0.63	素性 1:声	0.61
素性 1:結束	0.62	素性 1:色	0.60

有用な素性としては「固い」は「地盤」「絆(直後)」「決意」「結束」などの単語と共起することが見られた。「固い地盤」という表現は「地盤」という単語が「土地」の意味ではなく、「勢力」の意味で使われる際は慣用的な表現である。また、「固い握手」という慣用的な表現も見られた。以下に例を示す。

- 遠く離れてはいても、絆は限りなく 固い
- 固い 地盤をもつ神風氏は民主支持層の約 9 割を固めるが、無党派層への浸透が課題

「柔らかい」は「体」「音」「物腰」「声」「色」などの単語と共起することが見られた。以下に例を示す。

- ピッチを一步出れば物腰は 柔らかい
- 音量は小さいけれど、繊細でとても 柔らかい 音

置き換え可能の値が低くなった原因は、多義性により「柔らかい」は「柔らかい声」「柔らかい物腰」などの表現の場合「柔らかい」の対義語は「硬い」になり、置き換えできないと判断されることがあったからだと考えられる。また、「固い」に関しては「固い地盤」や「固い握手」といった慣用的な表現が見られたことも原因だと考えられる。

次に、「はっきり」「ぼんやり」について考察する。「はっきり」「ぼんやり」は置き換え可と判断された割合は0.40(12/30)である。表 5.33 に機械学習の性能を示す。表 5.34 に機械学習が参考にした素性を示す。

表 5.33: 機械学習の性能 (「はっきり」「ぼんやり」)

	データ数	再現率
はっきり	567	82.19%
ぼんやり	567	88.01%

表 5.34: 機械学習が参考にした素性 (「はっきり」「ぼんやり」)

はっきり		ぼんやり	
素性	正規化 α 値	素性	正規化 α 値
素性 1:形	0.78	素性 2:する (直後)	0.72
素性 1:生徒	0.69	素性 1:全体	0.70
素性 1:言葉	0.69	素性 52:対象語が含まれる文節が修飾する文節の最後の自立語が「いる」	0.62
素性 1:会見	0.65	素性 52:対象語が含まれる文節が修飾する文節の最初の付属語が「ようだ」	0.67
素性 1:大学	0.65	素性 1:時間	0.66

有用な素性としては「はっきり」は「形」「生徒」「言葉」「会見」「大学」などの単語と共起することが見られた。以下に例を示す。

- 暗い部分も光の形が はっきり している
- 原発ゼロへの思いをにじませながらも、はっきり とした言葉はない

「ぼんやり」は「全体」「時間」などの単語と共起することが見られた。また、「(人などが)ぼんやりする」「ぼんやり...いる」「ぼんやり...ような」という表現が見られた。以下に例を示す。

- 社務所の入り口にしばらく座って ぼんやり する
- 何となくその岸が ぼんやり と見えたような気もした

- 僕はその様子を ぼんやり 見ていた

置き換え可能の値が低くなった原因は、「(人などが) ぼんやりする」という慣用的な表現が多く使われていることが原因だと考えられる。また、「(物事が) はっきりする」という慣用的な表現がおおく使われていることも原因だと考えられる。

分類分けが中だが置き換え可の値が低かったものとして、置き換え可の値が低かった「発信」「着信」と「固い」「柔らかい」と「はっきり」「ぼんやり」の考察をおこなった。置き換え可能が低くなった理由としては以下のようなものが見られた。

- 慣用的な表現が多い，もしくは，よく使われる
- 多義性がある

被験者実験と機械学習の性能の傾向が一致しなかった対義語対の考察をした結果，それぞれの対義語対で傾向が一致しなかった原因はわかったが，全体として傾向などはつかめなかった。また，機械学習の性能が89%や79%に近いものは一概に相関が得られなかったと判断するべきではないと考えられる。高中低の分類ではなく機械学習の性能ごとに置き換え可否の値と比較する考察も重要であると考えられる。

第6章 おわりに

本研究では機械学習を用いて対義語の使い分けを行い、その結果を用い対義語対の置き換え可否の判定を行った。本研究の成果は2つある。

第1の成果として、想定していた通り、機械学習の性能が高ければ置き換え可能であり、機械学習の性能が低ければ置き換え不可能であるという、機械学習の性能と置き換え可否に逆の相関があることが確認できた。

第2の成果として、機械学習の性能と被験者実験の置き換え可否の傾向が一致したものや一致しなかったものを機械学習の素性を分析した。その結果、それぞれの対義語における有用な知見を獲得した。例えば、「潜在」は他の名詞と組み合わせて「潜在力」や「潜在意識」などの複合語を作ることなどがわかった。また、機械学習の性能と置き換え可否の被験者実験を比較した結果置き換え可の値が高くなる条件と置き換え可の値が低くなる条件がわかった。置き換え可の値が高くなる条件を以下に示す。

- 慣用的な表現が多い、もしくは特定の慣用的な表現がよく使われる
- 多義性がある
- 格の変化が起こる

また、置き換え可の値が低くなる条件を以下に示す。

- 慣用的な表現が少ない、もしくは特定の慣用的な表現がよくあまり使われない
- 多義性少ない
- 格の変化が起りにくい

謝辞

また，研究の進め方や本論文の書き方など，細部にわたる御指導を頂きました，鳥取大学工学部知能情報工学科自然言語処理研究室の村田真樹教授に心から御礼申し上げます．また，本研究を進めるにあたり，御指導，御助言を頂きました，村上仁一准教授に心から御礼申し上げます．その他様々な場面で御助言を頂いた自然言語処理研究室の皆様には感謝の意を表します．

参考文献

- [1] 荻原亜彩美, 森山菜々美, 浅原正幸, 加藤祥, 山崎誠. 『分類語彙表』に対する反対語情報. 言語処理学会第 25 回年次大会, 2018.
- [2] 赤江涼太. 機械学習を用いた同義語の使い分けに関する知識獲得. 卒業論文, 鳥取大学工学部知能情報工学科, 2017.
- [3] 小学館辞典編集部. 使い方の分かる類語例解辞典. 小学館, 1994.
- [4] 山口仲美, 佐藤有紀. 「擬音語・擬態語」使い分け帳. 山海堂, 2006.
- [5] Eric Sven Ristad. Maximum entropy modeling for natural language. In *ACL/EACL Tutorial Program, Madrid*, 1997.
- [6] 村田真樹, 内山将夫, 内元清貴, 馬青, 井佐原均. 種々の機械学習手法を用いた多義解消実験. 電子情報通信学会言語理解とコミュニケーション研究会, pp. 7–14, 2001.
- [7] Masao Utiyama. Maximum entropy modeling packagen: <http://www.nict.go.jp/x/x161/members/mutiyama/software.htmlmaxent>. 2006.
- [8] Masaki Murata, Kiyotaka Uchimoto, Masao Utiyama, Qing Ma, Ryo Nishimura, Yasuhiko Watanabe, Kouichi Doi, and Kentaro Torisawa. Using the maximum entropy method for natural language processing: Category estimation, feature extraction, and error correction. Vol. 2, pp. 272–279, 2010.