

単語分散表現を用いた性格特性用語の構造抽出

鶴田健介 久野雅樹

電気通信大学大学院情報理工学研究科

t2230095@edu.cc.uec.ac.jp, hisano@uec.ac.jp

概要

性格の心理学的研究におけるビッグファイブとは、人間の性格が5つの主要な特性因子によって表されるという考え方で今日、性格構造のモデルとして有力なものである。本研究では、自然言語処理を活用し性格特性用語をビッグファイブに基づいて分類することを目的とする。日本語と英語の性格特性用語を単語分散表現に変換し、ロジスティック回帰による分類を行ったところ、性格特性用語のビッグファイブの構造が抽出された。ただし日本語と英語とで、また分散表現で用いたコーパスの間で因子の分類性能には差異が認められた。

1 はじめに

人間の性格を表現する言葉は大量にある。これらの言葉がどんな構造を持つのかは、大きな心理学的課題として様々な研究が行われてきた。その結果近年では、人間の性格はビッグファイブという5因子の構造を持つということが分かってきている。これら5つの因子は、

- 外向性 (E: Extroversion)
- 協調性 (A: Agreeableness)
- 勤勉性 (C: Conscientiousness)
- 情緒安定性 (N: Neuroticism)
- 知性 (O: Openness to Experience)

と呼ばれている。

ビッグファイブに基づいた性格特性用語の収集や構造理解については、英語圏では Oliver P. John [1] や Robert R. McCrae らによる研究 [2][3]、日本では和田ら [4] や村上 [5] による研究など、長年にわたり試みられている。しかしそれらは研究者の主観によって語彙が選択されていたり、質問紙法による性格テストの結果から得られた主観に基づく情報を因子分析によって整理されていたりすることが多い。

本研究では、自然言語処理の手法によってより客

観的な手法を用いて性格特性用語の構造推定を行い、性格概念を構造化することを目的とする。単語の構造分析方法の一つとして単語分散表現という手法が挙げられる。これは単語を数百次元程度のベクトル空間上の点として表現する手法である。この分散表現をもとに、ロジスティック回帰による単語の分類を行った。

2 関連研究

関連する研究として、日本語の性格特性用語の構造に関する研究を3点紹介する。

2.1 岩田らの研究

岩田らの研究 [6] では、性格辞書の候補となる単語を英語の性格形容詞から収集し、大規模な質問紙調査をもとに回帰分析によって単語ごとのビッグファイブの重みを計算して性格辞書を作成した。

2.2 和田らの研究

和田らの研究 [4] では、因子分析を用いて性格特性用語を分類し、日本語版 Adjective Check List に用いられる性格特性用語を整備した。英語版の性格検査である Adjective Check List から収集した性格特性用語を5因子モデルに分類したのち、質問紙の回答結果から因子分析を行なった。この結果から英語の性格特性用語で確認されていたビッグファイブ説が、日本語の性格特性用語に対しても確認された。

2.3 村上の研究

村上の研究 [5] では、広辞苑から収集した性格特性用語を用いた質問紙調査のデータに対し因子分析を行うことで、日本語におけるビッグファイブの構造を確認した。ビッグファイブ因子は外向性、協調性、勤勉性、情緒安定性、知性の5つとし、ビッグファイブ因子は英語圏での研究結果と細部で異なっているとしている。

3 分析手法

3.1 分析準備

日本語の単語分散表現の学習データには、Wikipedia の dump データと、青空文庫に掲載されている作品のうち新字新仮名の作品データの2種類を使用し、それぞれのデータで学習を実施した。形態素解析には MeCab を使用し、システム辞書として JUMAN 辞書を、ユーザー辞書として村上の性格特性用語の中でナ形容詞に当たる 15 語を追加した辞書を使用した。

3.2 単語分散表現の学習

Word2Vec の Skip-gram モデルを使い、Gensim を用いて日本語の単語分散表現の学習を行った。形態素解析によって分かち書きされたデータを一行につき一文になるよう整形し Text8Corpus クラスを用いて読み込みを行った。ここで分散表現の次元数は 100 次元、ウィンドウサイズを 5 に設定した状態で学習を実施した。単語分散表現はコーパス内での出現回数が 5 回以上の単語にのみ付与されるように設定した。

英語の単語分散表現としては、Wikipedia のデータで学習した公開済みの fastText と、GoogleNews を用いて学習した公開済みの分散表現を使用した。

3.3 分析対象とする性格特性用語

日本語の性格特性用語としては、村上宣寛の著書に掲載されている 317 語の性格特性用語のリスト [7] を使用した。このうち Wikipedia コーパスに出現した 150 語と青空文庫コーパスに出現した 140 語をそれぞれ本研究の分析の対象とした。

また英語の性格特性用語としては、Oliver P. John らのリスト [8] を使用した。このうち Wikipedia で学習させた fastText のボキャブラリーに存在した 102 語と、GoogleNews で学習した公開済み分散表現のボキャブラリーに存在した 92 語をそれぞれ本研究の分析の対象とした。

分析に使用した日本語と英語の性格特性用語について、ビッグファイブ因子ごとの単語数の内訳は表 1 のようになった。

表 1 分散表現ごとの性格特性用語の単語数

分散表現	E	A	C	N	O
Wikipedia (日本語)	30	26	42	33	19
青空文庫 (日本語)	21	29	40	30	20
Wikipedia (英語)	21	28	18	17	18
GoogleNews (英語)	20	24	18	14	16

表 2 性格特性用語の例

ビッグファイブ因子	日本語	英語
E(外向性)	内気な	shy
A(協調性)	勝手な	cold
C(勤勉性)	親切な	careless
N(情緒安定性)	愉快な	nervous
O(知性)	軽率な	clever

3.4 性格特性用語の分類

日本語および英語の性格特性用語に対して、単語分散表現を入力としたロジスティック回帰による分類を実行した。分析対象のビッグファイブ因子を正解ラベル、その他のビッグファイブ因子を不正解ラベルとした 2 クラス分類を行った。またデータの偏りに対応するため、オーバーサンプリングを行い、正解ラベルと不正解ラベルの数を同数にそろえうえて分析を実施した。本研究の分析ではオーバーサンプリングを実行しない場合についても分析を行ったが、詳細は割愛する。

4 結果と考察

4.1 日本語における性格特性用語

4.1.1 日本語の性格特性用語の分類結果

Wikipedia および青空文庫で学習させた単語分散表現を対象とした場合の、ビッグファイブ因子ごとの分類結果は表 3、表 4 のようになった。それぞれの値は 5 回実行した時の平均値である。

表 3 日本語・Wikipedia における分類結果

評価方法	E	A	C	N	O
正解率	0.549	0.597	0.650	0.760	0.656
精度	0.569	0.680	0.909	0.775	0.684
再現率	0.384	0.350	0.331	0.731	0.575
F1 値	0.456	0.457	0.484	0.751	0.623

表4 日本語・青空文庫における分類結果

評価方法	E	A	C	N	O
正解率	0.736	0.755	0.673	0.600	0.639
精度	0.733	0.721	0.780	0.680	0.681
再現率	0.734	0.803	0.480	0.356	0.517
F1 値	0.735	0.771	0.591	0.467	0.587

表5 英語・Wikipediaにおける分類結果

評価方法	E	A	C	N	O
正解率	0.909	0.717	0.824	0.735	0.882
精度	0.935	0.933	0.844	0.944	0.906
再現率	0.879	0.467	0.794	0.500	0.853
F1 値	0.906	0.622	0.818	0.654	0.879

表6 英語・GoogleNewsにおける分類結果

評価方法	E	A	C	N	O
正解率	0.662	0.822	0.857	0.729	0.816
精度	0.761	0.905	0.927	0.962	0.865
再現率	0.469	0.718	0.773	0.477	0.748
F1 値	0.577	0.799	0.842	0.631	0.802

4.1.2 考察

日本語の Wikipedia を学習データとした単語分散表現を使用した場合の分類性能は F1 値が 0.46~0.75 となった。また因子ごとで見ると N についての分類性能が 0.75 と最高値になり、E および A の分類性能が 0.46 程度と最低値になった。

青空文庫を学習データとした分散表現を使用した場合の分類性能は、F1 値が 0.47~0.77 となった。さらに実際の予測結果を見ると、A と O は同じ因子として判断されるケースが多いことが確認できた。また因子ごとで見ると、A の分類性能が最高値の 0.77 となり、N についての分類性能が 0.47 と最低値となった。

これらのことから、全体としてはビッグファイブの分類がある程度できたものと考えられるが、2つの単語分散表現の間で構造にずれがあると言える。この分析結果については、単語分散表現の学習量や学習データの種類が分類性能に大きな影響を与えていると考えられる。Wiki コーパスの傾向として、メジャーな単語の出現回数が極端に多く、一般的でない単語や文学的な語彙はあまり使われていないという特徴がある。一方で青空文庫コーパスには文学的な語彙が多く出現している。性格特性用語のリストの中には一般的には使用されにくい用語もいくつか存在しており、これらの単語の影響によって分類性能に差が生じていると思われる。

また、オーバーサンプリングを実行しない場合は分類性能が低下した。学習データが 140 語と少なくデータの偏りも大きいため、うまく学習できていないと考えられる。

4.2 英語における性格特性用語

4.2.1 英語の性格特性用語の分類結果

それぞれの分散表現を用いて同様に分析を実行したところ結果は表 5、表 6 のようになった。

4.2.2 考察

Wikipedia から学習した場合の英語の性格特性用語の分類結果では、F1 値が 0.62~0.91 となった。各因子の結果を見ると E の分類性能が 0.91 と最高値となった。次いで O および C の分類性能がそれぞれ 0.88、0.82 となり、共に 0.80 以上の値となった。また A の分類性能は最低値の 0.62 となった。

一方 GoogleNews から学習した場合の英語の性格特性用語の分類結果では、F1 値が 0.58~0.84 となった。各因子の分類結果を見ると C の分類性能が最高値の 0.84 となり、次いで O と A の分類性能が 0.80 となっており高めである。一方で E の分類性能は 0.58 と最低の値になった。

これらのことから、全体としてビッグファイブの分類がかなりの程度できたと言える。また E と A の分類性能には 2つの分散表現の間で違いが見られたものの、そのほかの因子については、C と O の分類性能が高く N の分類性能が低いという傾向は一致している。

日本語と比較した場合、分類性能の高低で共通するパターンが見られるとは言い難い。一方で英語の分類性能のほうが高い結果が出ており、2つの英語の分散表現である程度同じ傾向がみられるため、日本語におけるビッグファイブの構造に比べて英語におけるビッグファイブの構造がより明確に得られていると考えられる。

日本語と英語の分類性能に差があることについては、単語分散表現の学習に用いたデータの量や種類の違いによる影響が考えられる。英語の分析で使用した公開済みの分散表現の学習データと比較すると、日本語の単語分散表現の学習データはサイズが

小さい。そのため、日本語の分散表現の学習が不十分だったと考えられる。

このほかには、複合語や単語の表記ゆれの扱い方が日本語と英語で異なることも、分類性能の違いに影響していると考えられる。日本語の分散表現では「きれいだ」「きれいな」のように単語の末尾表現ごとに別の単語として学習されてしまう。これによって日本語の分散表現では十分に学習できていなかった可能性が考えられる。

5 おわりに

5.1 結論

日本語の Wikipedia を学習データとした単語分散表現を使用した場合の分類性能は F1 値が 0.46~0.75 となった。また因子ごとで見ると N についての分類性能が最高値になり、E および A の分類性能が最低値となった。一方で、青空文庫を学習データとした単語分散表現を使用した場合の性格特性用語の 2 クラス分類の結果は、F1 値が 0.47~0.77 となり、因子ごとで見ると、E の分類性能が最高値となり、N の分類性能が最低値となった。

英語の Wikipedia を学習データとした単語分散表現を使用した場合の分類性能は、F1 値が 0.62~0.91 となり、因子ごとに見ると E の分類性能が最大値になり、次いで C と O の分類性能が 0.80 以上の値となった。A の分類性能が最低値となった。一方で GoogleNews を学習データとした場合の分類性能は、F1 値が 0.58~0.84 となった。各因子の分類結果では C の分類性能が最高値、次いで O と A の分類性能が高く、E の分類性能が最低値となった。

これらのことから、それぞれの言語で単語分散表現からビッグファイブの分類がある程度できた。しかし 2 つの日本語の単語分散表現の間にはずれがあると言えるため、分散表現の学習データに大きく影響されていると考えられる。一方で 2 つの英語の単語分散表現にはビッグファイブの分類性能の高低に共通した傾向が見られている。さらに日本語と比べて英語の分類性能のほうが高い結果が得られているため、ビッグファイブの構造は英語のほうが明確であると考えられる。

5.2 課題

本研究で使用した性格特性用語の問題点として、性格特性用語の数が少ないことが挙げられる。本研

究ではオーバーサンプリングによってデータの偏りを補ったが、生成されるデータによって性能が変化してしまう。そのため複数の性格特性用語のリストを使うなど、データ数に対する対策が必要である。

また日本語の性格特性用語には、末尾表現がリストによってばらばらであるという問題点も存在する。村上や和田らのリストでは性格特性用語を形容詞として扱っているのに対し、橋本や小塩らの研究 [9][10] では形容詞の語幹を使った単語ベースで分析を行っている。そのため末尾の表記ゆれや複合語に対応できる分散表現を使用する必要がある。

参考文献

- [1] Oliver P. John. The 'Big Five' factor taxonomy : Dimensions of personality in the natural language and in questionnaires. In **Handbook of Personality: Theory and Research**, pp. 66–100. Guilford Press, 1990.
- [2] Ralph L. Piedmont, Robert R. McCrae, and Jr Paul T. Costa. Adjective check list scales and the five-factor model. **Journal of Personality and Social Psychology**, Vol. 60, No. 4, pp. 630–637, 1991.
- [3] Robert R. McCrae and Jr Paul T. Costa. Validation of the five factor model of personality across instruments and observers. **Journal of Personality and Social Psychology**, Vol. 52, No. 1, pp. 81–90, 1987.
- [4] 和田さゆり. 性格特性用語を用いた bigfive 尺度の作成. **心理学研究**, Vol. 67, No. 1, pp. 61–67, 1996.
- [5] 村上宣寛. 日本語におけるビッグ・ファイブとその心理測定的条件. **性格心理学研究**, Vol. 11, No. 2, pp. 70–85, 2003.
- [6] Ritsuko Iwata, Daisuke Kawahara, Takatsune Kumada, and Sadao Kurohashi. Development of a Japanese Personality Dictionary based on Psychological Methods. **Proceedings of the 12th Conference on Language Resources and Evaluation**, pp. 3103–3108, 2020.
- [7] 村上宣寛, 村上千恵子. 主要 5 因子性格検査ハンドブック三訂版: 性格測定的基础から主要 5 因子の世界へ. 筑摩書房, 2017.
- [8] Oliver P. John, Richard W. Robins, and Lawrence A. Perwin. Paradigm shift to the integrative Big Five trait taxonomy: History, measurement, and conceptual Issues. In **Handbook of Personality: Theory and Research**, pp. 114–158. Guilford Press, 3 edition, 2008.
- [9] 橋本泰央, 小塩真司. 辞書研究に基づく対人特性用語の構造の検討. **パーソナリティ研究**, Vol. 28, No. 1, pp. 16–27, 2019.
- [10] 橋本泰央. 辞書的アプローチによる対人特性語の選定. **早稲田大学大学院文学研究科紀要**, Vol. 63, pp. 39–54, 2018.