

## 日本語における筆者の性格推定のための言語的特徴の調査

那須川 哲哉† 上條 浩一† 山本 眞大§ 北村 英哉‡

†日本アイ・ビー・エム株式会社 東京基礎研究所

§慶應義塾大学 理工学研究科 ‡関西大学 社会学部

### 1. はじめに

ソーシャルメディアをはじめとした多様なテキストの分析的な活用に対する世の中の関心が高まっている。書き手の性格を把握できればテキスト活用の可能性を広げられるだろうという期待から、筆者の性格を推定する取組みが近年増えてきている。しかし、その多くは英語のテキストを対象としており、日本語を対象としたものはまだ少ない。我々は、インターネット上で日本語による性格診断アンケート<sup>1</sup>を実施し、その回答者のツイート进行分析することで、テキスト上の特徴と性格との関連を分析し、筆者の性格推定にどのような特徴が使えるかを調査した。本稿では、その調査の概要と調査結果を示す。

### 2. 関連研究

テキストの内容とその筆者の性格に関連性が見出せるという研究報告を背景に、テキストを分析して筆者の性格を推定しようとする取組みが増えてきている[1]。下記5要素からなるBig Five Model[2]のように標準的に用いられる性格評価尺度が存在し、2013年にはShared Task[3]も開催され、より効果的な手法の検討が進んでいる。

- Openness to experience  
独創的・好奇心が強い vs. 着実・警戒心が強い
- Conscientiousness  
手際が良い・まめな人 vs. 楽天的・不注意
- Extraversion  
社交的・エネルギー vs. 孤独志向・控えめ
- Agreeableness  
人当たり良い・温情あり vs. 冷たい・不親切
- Neuroticism  
繊細・神経質 vs. 情緒安定・自信家

しかし、その取組みには英語のテキストを対象としたものが多い。日本語を対象とした取組みは、出始めているものの、まだ数が少ない。テキストと性格の関連性には言語や文化による違いが現れてくる可能性があることを考えると、研究の余地はまだ大きいと感じられる。

日本語を対象とした取組みとして、藤倉ら[4]は、音声対話やツイートの特徴がBig Fiveの各要素の分

類に結びつくことを示し、岡本ら[5]は、ツイートの特徴がエゴグラム[6]の5つの分類の推定に寄与することを示している。これらの取組みにおいては、形態素解析で得られた単語を素性として用いているが、英語のテキストを対象としたShared Taskの結果[3]からは、多様性の高い単語レベルの素性を使うボトムアップのアプローチよりも、LIWC (Linguistic Inquiry and Word Count) [7]のようにカテゴリ化された素性を用いるトップダウンのアプローチの方が現状では精度が良いという知見が得られている。日本語でも同様の結果が得られる可能性があり、日本語におけるトップダウンのアプローチの取組みとして、奥村ら[8]は、感情判断システムを用いて、テキスト中の感情関連表現から推定される9つの感情とBig Fiveとの相関を示しているが、対象が9つの感情に限定されている。そこで、我々は、より広範なカテゴリを対象としたLIWCをベースにし、日本語のどのようなカテゴリの表現がどのような性格と関連を示すかを調査した。

### 3. 性格診断データの収集

ツイートとその筆者の性格の関連付けを実現するために、Twitterへの一定量(150ツイート)以上の書き込みを行った筆者を対象に、性格診断のアンケートを実施した。アンケートは、英語、スペイン語で既に実施されているが、言語の利用形態、国民性、文化等が異なり、それらをそのまま利用することができないため、日本語のアンケートを新たに実施した<sup>2</sup>。アンケートは、Personality(個性), Needs(欲求), およびValues(価値観)の計22の性格プロフィール

(図1)に関する計119の質問からなる(図2)。アンケート回答者は各質問に対して該当レベルを5段階で回答するようになっており、その結果を元に、各性格のプロファイルスコアを算出し、回答者へ性格診断結果を提示するようにした(図3)。性格プロフィールとしては、Big Fiveに加え、Kevin FordのUniversal Needs Map に沿ったNeeds(欲求)分析[9]とSchwartzの価値概説(Schwartz Value Survey)に沿ったValues(価値観)分析[10]の結果も対象とした(図1)。

アンケートと同時に、各筆者のツイートデータを取得し、プロフィールスコアと共に、匿名化された形で厳重に保管、分析対象データとして活用した。

<sup>1</sup> <https://pisurveytwitter.mybluemix.net/language>

<sup>2</sup> <https://www.facebook.com/IBMJapan/posts/892316044157506>

性格プロフィール	
大分類	小分類
Big5 (個性)	Openness, Conscientiousness, Extraversion, Agreeableness, Neuroticism (5)
Values (価値観)	Excitement, Harmony, Curiosity, Ideal, Closeness, Self-expression, Liberty, Love, Practicality, Stability, Challenge, Structure (12)
Needs (欲求)	Self-transcendence, Conservation, Hedonism, Self-enhancement, Open to change (5)

図1: 性格プロフィールの分類

	全く当てはまらない	当てはまらない	どちらでもない	当てはまる	とても当てはまる
1. 人生を楽しんでいる	○	○	○	○	○
2. 他人にあまり興味がない	○	○	○	○	○
3. 権威を恐らない	○	○	○	○	○
4. ストレスに強い	○	○	○	○	○
5. 読書が多い	○	○	○	○	○
6. たくさんしゃべるタイプではない	○	○	○	○	○
7. 人と接することに興味がある	○	○	○	○	○
8. 自分の持っているものを近くに置く	○	○	○	○	○

図2: アンケート例

#### Big 5 個性




図3: アンケートの結果表示されるプロフィールスコア例

## 4. LIWC 日本語化

日本語のどのような表現がどのような性格と関連を示すかを調査するにあたり、英語などで実績のある LIWC をベースに日本語表現のカテゴリ化を行った[11]。

基本的には、LIWC2001 で辞書化されている 68 カテゴリのうち、日本語にない Article、及び Non fluencies と区別の困難な Fillers を除く 66 のカテゴリに対応する日本語表現を定義し、IBM Watson Explorer Advanced Edition Analytical Components V11.0 (以下 WEX と略記)[12]の言語処理機能を利用して、テキスト中の各表現の出現を特定する仕組みを実装した。Preposition に関しては助詞を対応させた。

また、心理学的知見から、日本人の性格と関連する可能性があると考えられるカテゴリとして、Event (「祭り」や「花火」など)、Relax (「温泉」や「癒し」など)、Move (「電車」や「通勤」など)、Position change (「転職」や「異動」など)、Reading (「読む」や「本」など) という 5 つのカテゴリの追加を行った。

さらに、LIWC のカテゴリの一部を下記のように細分化した 8 カテゴリも追加した。

- Total 1<sup>st</sup> person のサブセットとして
  - Watashi (「私」や「あたし」など)
  - Boku (「僕」や「ぼく」など)
- Causation のサブセットとして
  - Good causation (「おかげ」や「成果」など)
  - Bad causation (「せい」や「原因」など)

- Communication のサブセットとして
  - Drinking party (「飲み会」や「忘年会」など)
- Friends のサブセットとして
  - Lover (「彼氏」や「恋人」など)
- Family のサブセットとして
  - Children (「子供」や「娘」など)
- Time のサブセットとして
  - On time (「遅い」や「遅刻」など)

結果的に全 79 のカテゴリを定義し、各カテゴリに該当する表現をテキスト中で特定できるようにした。

## 5. テキスト上の特徴と性格との関連分析

3章で述べた方法により、312名(n=312)分の有効なアンケート結果を収集し、以下の方法でツイートデータと性格との関連性を分析した。

まず、筆者  $j$  の全ツイートデータ中に含まれる、LIWC のカテゴリ  $cat_i (i=1, \dots, 79)$  に該当する単語数をカウント後、1文字数当り出現数  $a_{ij}$  に換算し、出現ベクトル  $\mathbf{a}_i = (a_{i1}, \dots, a_{in})$  を求めた。さらに、 $j$  のアンケート時の性格プロフィール  $c_{kj} (k=1, \dots, 22)$  に対するスコアを  $s_{kj} (0 \leq s_{kj} \leq 1)$  とし、各  $k$  に対するスコアベクトル  $\mathbf{s}_k = (s_{k1}, \dots, s_{kn})$  を求めた。そして、各  $\mathbf{a}_i$  と  $\mathbf{s}_k$  間のピアソンの積率相関係数、および p 値を計算した。次に、性格プロフィール  $c_{kj}$  の推定に、どのカテゴリ  $cat_i$  が効果があるかを検証するため、単回帰分析を行い、10-分割交差検証により、実測値と推定値の Mean Absolute Error (MAE) を測定した。さらに、各  $c_{kj}$  に対して、複数のカテゴリを用いた重回帰分析も行い、同様に MAE を測定した。表 1 に、Big5、Needs、Values より各々 2 つずつ選んだプロフィールに対する実測スコアの平均値と標準偏差、表 2 に、表 1 と同じプロフィールに対して相関の高い 18 のカテゴリとの相関 (r)、および単回帰、重回帰における MAE を示す。また、表 3 に、同じプロフィールに対して、重回帰分析を行った際、MAE を最小にするカテゴリを、効果の大きい順 (1 つ以上で MAE を最小にする順) に並べ、それらの相関と、利用したカテゴリの数を示す。さらに、表 4 に、プロフィール推定に効果のあるカテゴリの上位ランキングを、単回帰でベースラインより MAE を小さくしたプロフィールの数で示す。

表 2, 3 より、Harmony と Hedonism を除き、表中のカテゴリの 7 割以上のカテゴリで、単独で、学習データの平均値を推定値とするベースラインよりもプロフィール推定に効果があること、および、重回帰で推定を行

表1: 実測スコアの平均と標準偏差

	Big5		Needs		Values	
	Extraversion	Neuroticism	Liberty	Harmony	Openness to change	Hedonism
ave	0.5108	0.4147	0.5862	0.7556	0.7113	0.7684
sd	0.1725	0.1767	0.1519	0.1138	0.1595	0.1814

表 2: Correlation (左) - 性格プロフィールとカテゴリとの相関(r)。太字は  $p < 0.05$ , 斜字太字は  $p < 0.01$  の相関  
 MAE (右) -  $p < 0.1$  のカテゴリを用い、単回帰、重回帰、およびベースライン(学習データの平均値を推定値とするもの)  
 における推測値と実測値の Mean Absolute Error。空欄は、単回帰によりベースラインより効果のないもの

Category	Correlation						MAE					
	Big5		Needs		Values		Big5		Needs		Values	
	Extraversion	Neuroticism	Liberty	Harmony	Openness to change	Hedonism	Extraversion	Neuroticism	Liberty	Harmony	Openness to change	Hedonism
1st person singular	0.106	<b>-0.168</b>	-0.028	<b>0.112</b>	0.003	0.090	0.1363	0.1444		0.0878		
Total 1st person	0.106	<b>-0.164</b>	-0.027	<b>0.115</b>	0.001	0.085	0.1363	0.1446		0.0877		
Negations	<b>-0.167</b>	<b>-0.208</b>	<b>-0.229</b>	0.049	<b>-0.177</b>	0.009	0.1368	0.1421	0.1179		0.1260	
Prepositions	<b>-0.200</b>	<b>-0.199</b>	-0.071	0.101	-0.102	0.094	0.1356	0.1432		0.0878	0.1274	
Affect	-0.046	<b>-0.249</b>	<b>-0.173</b>	<b>0.116</b>	<b>-0.119</b>	-0.030		0.1418	0.1183	0.0877	0.1272	
Optimism	-0.021	-0.063	<b>-0.153</b>	0.038	<b>-0.160</b>	-0.151			0.1191		0.1277	0.1449
Anxiety	<b>-0.182</b>	<b>-0.252</b>	<b>-0.192</b>	0.085	<b>-0.139</b>	-0.031	0.1370	0.1409	0.1186		0.1275	
Sadness	-0.109	<b>-0.204</b>	<b>-0.172</b>	0.106	<b>-0.120</b>	-0.066	0.1377	0.1432	0.1185	0.0880	0.1266	
Cognition	-0.108	-0.149	-0.148	0.008	-0.097	0.010	0.1376	0.1451	0.1177		0.1277	
Causation	<b>-0.124</b>	-0.101	-0.187	-0.062	<b>-0.139</b>	0.000	0.1373	0.1460	0.1187		0.1268	
Bad causation	<b>-0.202</b>	-0.111	-0.193	-0.040	<b>-0.111</b>	-0.003	0.1357	0.1457	0.1184		0.1274	
Insight	-0.059	-0.096	<b>-0.145</b>	0.018	-0.051	0.013		0.1466	0.1181			
Inhibition	<b>-0.111</b>	-0.014	<b>-0.125</b>	-0.077	-0.096	<b>-0.111</b>	0.1367		0.1191		0.1283	0.1467
Sensation perception	-0.090	<b>-0.189</b>	<b>-0.203</b>	0.098	<b>-0.127</b>	0.080		0.1431	0.1166	0.0876	0.1273	
Seeing	<b>-0.161</b>	<b>-0.138</b>	<b>-0.203</b>	0.090	<b>-0.116</b>	0.095	0.1373	0.1441	0.1159		0.1276	0.1454
Past	0.005	-0.045	<b>-0.170</b>	0.009	<b>-0.155</b>	0.058			0.1184		0.1262	
Job	<b>0.228</b>	0.071	0.103	-0.084	<b>0.143</b>	-0.003	0.1336		0.1194		0.1262	
Leisure	-0.036	-0.085	-0.021	0.060	-0.045	<b>-0.113</b>						0.1452
<b>MAE comparison</b>												
MAE (multiple regression)							0.1280	0.1384	0.1119	0.0869	0.1212	0.1364
MAE (baseline)							0.1379	0.1469	0.1198	0.0882	0.1289	0.1474

表 3: 重回帰分析において利用されるカテゴリのリスト (Category, 上から効果の大きい順)、およびそれらのプロフィールとの相関(r)。Count ( $p < 0.1$ ) は、単回帰でベースラインより MAE を小さくするカテゴリ数、Count (multiple regression) は重回帰で利用されたカテゴリ数 (共に  $p < 0.1$  のカテゴリのみ採用)

Profile	Big5		Needs				Values					
	Extraversion		Neuroticism		Liberty		Harmony		Openness to change		Hedonism	
	Category	r	Category	r	Category	r	Category	r	Category	r	Category	r
Job	<b>0.228</b>	Anxiety	<b>-0.252</b>	Seeing	<b>-0.203</b>	Numbers	<b>0.149</b>	Time	<b>-0.153</b>	Leisure	<b>-0.113</b>	
Bad causation	<b>-0.202</b>	Positive feelings	<b>-0.144</b>	Job	0.103	Affect	<b>0.116</b>	Job	<b>0.143</b>	Lover	<b>0.157</b>	
Communication	0.100	Refs to others	-0.100	Past	<b>-0.170</b>			Past	<b>-0.155</b>	Negative affect	<b>-0.117</b>	
Eating	<b>0.139</b>	Prepositions	<b>-0.199</b>	Inhibition	<b>-0.125</b>			Inhibition	-0.096	Seeing	0.095	
Seeing	<b>-0.161</b>	Affect	<b>-0.249</b>	Sleeping	<b>-0.148</b>			Touching	-0.100	Optimism	<b>-0.151</b>	
Negations	<b>-0.167</b>	Anger	<b>-0.168</b>	Motion	-0.106			Motion	<b>-0.110</b>	TV movies	<b>-0.145</b>	
Numbers	<b>-0.114</b>			Humans	<b>-0.147</b>			Causation	<b>-0.139</b>	All pronouns	<b>0.119</b>	
Cognition	-0.108											
Inhibition	<b>-0.111</b>											
Assents	<b>0.155</b>											
Sadness	-0.109											
Count ( $p < 0.1$ )	19		35		29		10		24		13	
Count (multiple regression)	11		6		7		2		7		7	

表 4: プロファイル推定に効果のあるカテゴリ  
Count は、22 プロファイル中ベースラインより  
MAE を小さくしたプロファイル数

Count	Category
14	Causation
12	Anxiety, Bad causation
11	Cognition, Total 1st person
10	1st person singular, Insight, Inhibition, Negations

うことにより、単回帰の場合と比べ、MAE が 7%前後減少しており、さらに効果があることが確認された。また、相関の絶対値が大きく、p 値が小さいものが、プロファイル推定に効果があることも確認できた。表 3 より、Neuroticism に関しては、単回帰でプロファイル推定に有効なカテゴリが 35 あるのに対し、重回帰では 6 つのカテゴリのみで MAE の最小値を出力する。これは、表 2 からも確認できるように、Anxiety との相関が-0.252 と大きく、さらに p 値も  $3.21 \times 10^{-6}$  と非常に小さくプロファイル推定の効果が大きく、それ以外のカテゴリの追加の効果がなかったため、と推測される。Harmony においては、重回帰での推定においてもベースラインより MAE が 1.5%の減少にとどまっているが、これは、重回帰分析で利用可能なカテゴリが 2 個と少なく、p 値が最小で相関が最大の Number でも  $p=0.0077$  であり、プロファイル推定が難しいことが原因と推測される。さらに、表 4 からは、Causation (原因)、Anxiety (心配) がプロファイル推定に特に有効なカテゴリであることが確認された。1つ以上のプロファイルで単回帰分析で MAE をベースラインより小さくするカテゴリ数、および重回帰分析で MAE を最小にする際に利用されるカテゴリ数は、各々 76 (96.2%) と 57 (72.2%) であった。

## 6. おわりに

LIWC をベースに日本語表現をカテゴリ化したところ、全般的には、7 割以上の多くのカテゴリが何らかの性格との関連性を示しているという結果が得られた。特に「(～の)せい」「結果」「(～の)おかげ」といった表現で何らかの原因に言及している Causation のカテゴリが様々な性格との関連性が高かった。また、「困る」「つらい」「悩む」といった表現からなる Anxiety のカテゴリが、Big Five の Neuroticism と相関が高いといった知見が得られた。

紙数の都合上、表 2 表 3 に全データを記載することができなかったが、LIWC2001 では定義されていない日本語特有のカテゴリとして、「癒し」などに言及した Relax カテゴリが Big Five の Openness to experience と、「転職」などの Position change カテゴリが Big Five の Agreeableness と関連しているといった結果も得られた。LIWC のカテゴリの細分化に関しては、Causation よりも Bad causation、Friends よりも Lover の方が性格推定効

果が高いという結果が得られた。

今後は、各カテゴリに含まれる表現の整備を進めたり、英語やスペイン語などの他言語において、こういったカテゴリとの性格の相関が異なるかどうかを調査したりしつつ、性格診断サービスなどのアプリケーションの検討・実装を進めていく予定である。

## 謝辞

性格診断データの収集にあたって多くの方々のご協力をいただきました。ここに記して深謝いたします。

IBM © Watson Explorer Advanced Edition Analytical Components V11.0 は International Business Machines Corporation の米国およびその他の国における商標。

## 参考文献

- [1] Mairesse, F., Walker, M.A., Mehl, M.R., and Moore, R.K., Using Linguistic Cues for the Automatic Recognition of Personality in Conversation and Text. In Journal of Artificial intelligence Research, 30: 457-500, 2007.
- [2] McCrae, R. R. and John, O.P. An introduction to the five-factor model and its applications. Journal of Personality, 60(2), 175-215, 1992.
- [3] Fabio Celli, Fabio Pianesi, David Stillwell, and Michal Kosinski, "Workshop on Computational Personality Recognition: Shared Task", AAI Technical Report WS-13-01, 2013.
- [4] 藤倉将平, 小川義人, 菊池英明. 音声対話および Twitter におけるユーザのパーソナリティ自動推定, 言語処理学会第 19 回年次大会予稿集, pp.900-903, 2013.
- [5] 岡本拓馬, 松本和幸, 吉田稔, 北研二. ナイーブベイズ法を用いた Twitter による性格推定, 言語処理学会第 20 回年次大会予稿集, pp.1123-1125, 2014.
- [6] ジョン・M. デュセイ, エゴグラム—ひと目でわかる性格の自己診断, 創元社, 2000.
- [7] James W Pennebaker et al. Linguistic inquiry and word count: Liwc 2001. Mahway: Lawrence Erlbaum Associates, Vol. 71, pp. 1-21, 2001.
- [8] 奥村紀之, 金丸裕亮, 奥村学, 感情判断と Big Five を用いたブログ著者の性格推定に関する調査, 第 29 回人工知能学会全国大会, 4J1-5, 2015.
- [9] Yang, H., and Li, Y. Identifying user needs from social media. IBM Research Report, RJ10513 (ALM1309-013), 2013.
- [10] Ryan L. Boyd1, Steven R. Wilson, James W. Pennebaker1, Michal Kosinski, David J. Stillwell, and Rada Mihalcea, Values in Words: Using Language to Evaluate and Understand Personal Values, Proceedings of the Ninth International AAI Conference on Web and Social Media, p.31-40, 2015.
- [11] 山本真大, 那須川哲哉, 上條浩一, 北村英哉, LIWC2001 手作業翻訳の方針と半自動翻訳手法の提案, 言語処理学会第 22 回年次大会予稿集, 2016.
- [12] Wei-Dong Zhu, et al. IBM Watson Content Analytics: Discovering Actionable Insight from Your Content. An IBM Redbooks publication. ISBN-10:0738439428. 2014.