

【査読論文】

主観的ウェルビーイングの推論と観点感情分析のための自然言語処理人工知能エンジンの開発及び有効性検証

保井 俊之 (武蔵野大学 ウェルビーイング学部・叡啓大学 ソーシャルシステムデザイン学部 教授)

星野 政明 (クウジット株式会社、現所属：株式会社 AmaterZ)

宮島 靖 (クウジット株式会社)

末吉 隆彦 (クウジット株式会社)

要約

本研究は自然言語処理の人工知能 (AI) を用いて、複雑な日本語構文により書かれた自由記述テキストを読み込み、書き手の主観的ウェルビーイング (SWB) の度合いを推論するエンジンを開発し、その有効性を検証した。BERT に代表される機械学習の手法により、テキストを文書ベクトルに変換する機能に着目し、書き込まれた言葉の SWB との関連を特定するため、モダリティ分析及び観点感情分析を行った。これらの分析により、SWB と強く関連する書き手の意図を表す言葉及び感情対象語等を抽出し得ることを示し、SWB 度の高低と関連づいている名詞または固有表現を自由記述から抽出する AI 推論エンジンの基盤を構築した。

1. 背景と目的

エビデンスベースの政策決定 (Evidence-Based Policy Making; EBPM) 及び政策評価の目標として、主観的ウェルビーイング (Subjective Well-Being; SWB) を掲げる国際機関及び政府が 2010 年代以降、増加している。例えば、OECD Learning Compass 2030 (OECD 2013) では、教育は学生の個人的及び集団的ウェルビーイングを支援するものであるとしている。また、日本政府の予算編成の大綱であるいわゆる骨太の方針では、ウェルビーイングを重要業績指標とする政府計画の策定が 2021 年以降、規定されている (内閣府 2021)。

公共政策の領域においては、リアルタイムの政策エビデンス検知の重要性が増しており、特にコロナ禍への政策対応を背景に、その必要性が急務であると認識されている (Gallego & Font 2020, Wang et al. 2020)。しかし、リアルタイ

ムで収集可能なデータの制約が桎梏となっており（森川 2020）、政策決定における即時性の確保が課題となっている。

SWB は、リアルタイムでの検知が望ましい政策指標である（Diener et al. 2018, Bellet & Frijter 2019 for WHR 2019）。しかし、SWB は即時入手のニーズが高いにもかかわらず、即時入手の制約性が最も大きい指標の一つである。この課題に対応するため、リアルタイムでの政策エビデンス入手のプラットフォームとなる SWB の即時推論 AI の開発が喫緊の課題となっている。

以上のようなウェルビーイングに関する公共政策領域における EBPM の課題を背景に、本研究は、自然言語処理の AI が、複雑な日本語構文により書かれた自由記述テキストを読み込み、書き手の SWB の度合いを推論するエンジンを開発し、その有効性を検証することを目的とする。開発に当たっては、Bidirectional Encoder Representations from Transformers（BERT）等の機械学習手法により、テキストを文書ベクトルに変換する機能に着目し、書き込まれた言葉の SWB との関連を特定するため、モダリティ分析及び観点感情分析を行う。なお文書ベクトルとは、BERT に代表される自然言語処理モデルにより自由記述テキストを数値化した多次元の数値列を指し、機械学習アルゴリズムが SWB と SWB との関連を解析可能にする変換を表現したベクトルである。モダリティ分析（Nuyts & van der Auwera, 2016）は、述語構造分析により、回答者のモダリティを推定する分析方法である。モダリティとは、文中に表現されている状態に対する話者の態度を表す意味範疇を指す。一方、観点感情分析（Aspect-Based Sentiment Analysis; ABSA, Pontiki et al., 2014）は、ポジティブ感情及びネガティブ感情の対象になる名詞または固有表現を識別する分析方法である。

2. SWB 推論 AI の開発

（1）SWB 推論 AI の概要

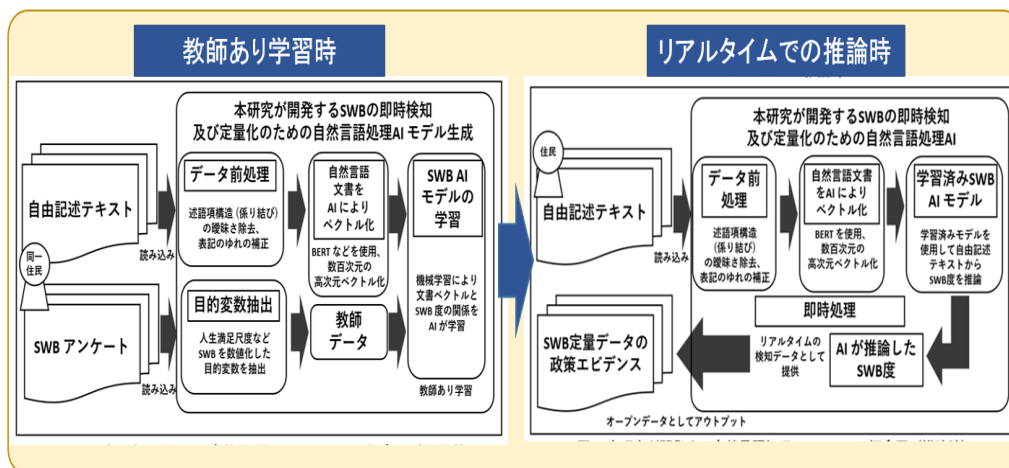
本研究では、大規模言語モデル（Large Language Model; LLM）に基づく BERT を活用し、SWB 推論 AI エンジンを構築した。構築した AI エンジンのシステム概要を（図 1）に示す。

本エンジンは、教師あり学習時とリアルタイムでの推論時の 2 つのフェーズ

で動作し、それぞれ異なるデータ処理手順を持つ。

まず教師あり学習時には、SWB に関連する自由記述テキストを解析し、機械学習モデルの学習データとして利用する。具体的には SWB 尺度に関連づけられた 140 文字程度の短文データを収集し、教師データとして準備する。次に、日本語 BERT を活用し、これらの自由記述テキストを 768 次元のベクトルに変換する。このベクトル化されたデータを用い、収集データの 8 割を訓練データとして本 AI エンジンが実装する機械学習アルゴリズムに適用し、SWB 推論 AI エンジンの教師あり学習を実施する。機械学習による予測モデルの作成には、マイクロソフトが開発した決定木応用のアルゴリズムである Light Gradient Boosting Machine (Light GBM) ¹⁾ を用いる。学習後、残りの 2 割のデータを検証データとして用い、モデルの精度を評価し、最適化を進める。この一連のプロセスを通じて、自由記述テキストから SWB を推論するための予測モデルを構築する。

SWB のリアルタイム推論時には、学習済みの SWB 推論 AI エンジンを活用し、新たに入力された自由記述データをもとに即時推論を行う。まずユーザーが記述した自由記述テキストをシステムに入力し、日本語 BERT を用いて 768 次元の高次元ベクトルに変換し、変換されたベクトルデータを学習済みの Light GBM モデルに入力し、SWB 度を推論する。推論結果はリアルタイムで出力され、政策決定への活用や個人向けフィードバックの提供が可能となる。これにより、SWB の即時推論を実現し、リアルタイムでの政策エビデンス入手や個人のウェルビーイング評価を支援することができる。



(図1) SWB 推論 AI エンジンのシステム概要図


(2) SWB 推論のためのデータ収集

この SWB 推論 AI エンジンが学習する SWB 尺度については、カントリルのはしご (Cantril 1965)、人生満足尺度 (Satisfaction With Life Scale; SWLS, Diener et al., 1985)、幸福の 4 因子 (前野 2013)、及びポジティブ・ネガティブ感情尺度 (Positive and Negative Affect Schedule; PANAS, 日本版; 佐藤・安田 2001) を用いた。そして、これらの尺度に関連づけられた 140 文字程度の短文の 2,000 データを収集した。データについては、調査会社を通じウェブ方式で日本在住の 2,000 名を対象に、SWB の状態の自由記述及び SWB 度に関するアンケートによる収集を 2023 年 9 月 20 ~ 25 日の間に行った。内訳は男性 1,000 名及び女性 1,000 名で、20 歳台から 60 歳台以上まで年齢別に、さらに在住地は日本の 8 地域に、均等に割り付けた。


そして収集したデータのうち 8 割を用い、この推論 AI エンジンの教師あり学習を実施した。さらに、収集データの 2 割を有効性確認に使用し、AI が読み込んだ自由記述テキストを 768 次元の高次元 BERT ベクトルに置換できることを確認した。そして執筆者らは、これらの 8 割のデータを使用して教師あり学習から導かれた SWB 度データ、及び残り 2 割の有効性検証のために使用したデータから導かれた SWB 度データを比較し、教師あり機械学習により推論された回答者の SWB 度とアンケート調査から分析される SWB 度データの誤差を集計し、モデルの有効性を検証した。




(図2) 度数分布 (カントリルのはしご)



(図3) 度数分布 (人生満足尺度)



(図4) 度数分布 (幸せ4因子)



(図5) 度数分布 (日本版PANAS, ポジティブ感情-ネガティブ感情のネットベース)

(3) SWB 度数分布

収集されたデータの SWB 度数分布図を、図 2（カントリルのはしご）、図 3（SWLS）、図 4（幸せ 4 因子）及び図 5（PANAS）に示す。なお図 2（カントリルのはしご）については、日本人の分布に特徴的とされる二項分布（高橋 2018）となっている。²⁾

3. 分析の手法

分析の手法については、まず、推論 AI の基盤となる因果関係の仮説を立て、SWB 尺度とベクトル化された自由記述との関連を特定するため、相関分析を行った。さらに推論モデルの精度を、SWB に関連する自由記述の書き手としてより感応度が高いと期待される回答者の SWB 上位 25% 層及び下位 25% 層について、適合率及び再現率等を分析した。この SWB 上位 25% 及び下位 25% 層の分類については、分類に使用する SWB 尺度は、後述する 4. (1) の相関分析の結果を参照しつつ、カントリルのはしごを用いた。


さらに述語構造分析によりデータ回答者のモダリティ、すなわち文中に表現されている状態に対する話者の態度を表す意味範疇を推定する分析方法であるモダリティ分析 (Nuyts & van der Auwera, 2016) を行った。そしてポジティブ感情及びネガティブ感情の対象になる名詞または固有表現を識別する分析方法である ABSA (Pontiki et al., 2014) を実施した。なお、モダリティ分析については、SWB に関する話者の態度が端的に表れる意味範疇を特定することが重要であるため、SWB に関連する自由記述の書き手として最も感応度が高いと期待される回答者の SWB 上位 10% 層及び下位 10% 層を対象に実施した。また ABSA については、推論モデルの精度検証と同様に、SWB 上位 25% 層及び下位 25% 層を対象に実施した。

4. 分析の結果

(1) 相関分析

回答者から収集した 4 つの SWB 尺度に関するデータについて、尺度間の相関分析を実施した。まず、シャピロウィルク検定により、p 値はすべて $p < 0.01$ となり、正規分布に従う母集団からサンプリングされたという帰無仮説を棄却

し、すべての SWB 尺度の正規性はないことを確認した。さらに相関分析ですべて 0.5 以上の相関がある（図 6）ことを確認し、無相関検定（スピアマン）により、 $p < 0.01$ であり、相関がないという帰無仮説を棄却し、すべての SWB 尺度の組み合わせで、相関があることを確認した。



（図6）SWB尺度間の相関分析の結果

（2）推論モデルの適合率及び再現率

SWB 上位 25% 層及び下位 25% 層の回答者の SWB 尺度（カントリルのはしご）の回答の理由に対する推論の適合率を検証したところ、SWB 上位 25% 層で 92%、下位 25% 層で 88% となった（表 1）。なお他の SWB 尺度では、有効な適合率及び再現率を持つ推論モデルは構築されなかった。

（表1）推論モデルの正解率等

	適合率	再現率	F1値	データ数
SWB 上位 25%層	92%	87%	89%	100
SWB 下位 25%層	88%	92%	90%	100

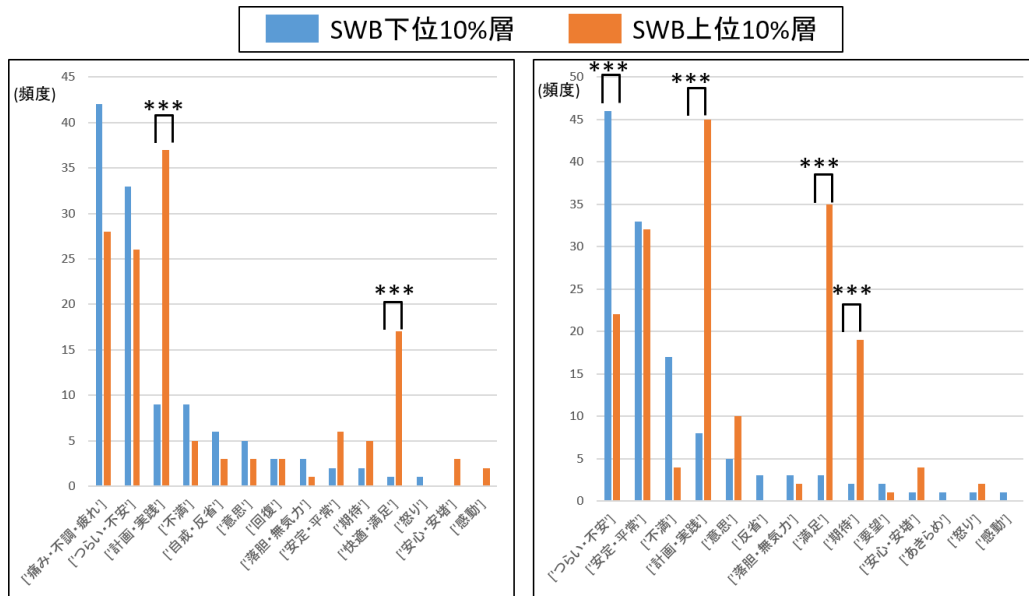
（3）モダリティ分析

モダリティ分析の結果、SWB 上位 10% 層に属する回答者は、統計的に有意に高いモダリティを示し、身体的状態に関して「計画・実践」および「快適・満足」が高く、精神的状態においては「計画・実践」、「満足」、「期待」が顕著であった。さらに、社会的状態に関しても「平穏」および「満足」のモダリティが、統計的に有意に高い傾向を示した。また、これらの回答者の記述には、具体的な言葉が多用される傾向が見られた。

他方で、SWB 下位 10% 層に属する回答者は、精神的状態において「つらい・不安」、社会的状態において「フラストレーション」および「家計不安」といっ


たモダリティが統計的に有意に高かった。また、これらの回答者の記述には、抽象的な言葉が多く用いられる傾向が認められた。

SWLS による SWB 上位 10% 層及び下位 10% 層のモダリティの比較について、身体的状態のモダリティ（図 7）、精神的状態のモダリティ（図 8）、並びに社会的状態のモダリティ（図 9）をそれぞれ示す。



（図7）SWLSによるSWB上位10%層と下位10%層の身体的状態のモダリティ

（図8）SWLSによるSWB上位10%層と下位10%層の精神的状態のモダリティ



（図9）SWLSによるSWB上位10%層と下位10%層の社会的状態のモダリティ

(4) ABSA の実施

ABSA を実施した。その実施に際しては、読み込んだ文が表わす感情だけではなく、その感情対象 (sentiment target) は何かをも抽出するために、BERT の意味的特徴量に加えて対象語を同定する系列学習モデル Conditional Random Field (CRF) を組合わせた BERT-CRF (五井野・濱上 2021) を実装して使用した。これにより、抽出された感情対象語等がポジティブあるいはネガティブな感情に関連づけられているかが、分析可能となる。ポジティブ感情及びネガティブ感情は、心理的ウェルビーイングのうちのヘドニック・ウェルビーイングすなわち短期的なウェルビーイングの主要な構成概念である (Steptoe et al. 2015)。

また、カントリルのはしごの尺度に関連づけられた自由記述データのうち、SWB が上位 25% 層および下位 25% 層に属する回答者のデータを用い、教師あり学習を行った上で、ABSA による推論モデルを構築した。その結果、SWB 上位 25% 層及び下位 25% 層の回答者が SWB 尺度 (カントリルのはしご) において示した回答の理由に対する推論の適合率 (全体平均 (Micro-F1 値)) は 71% であり、部分一致も含めると 77% であった (表 2)。

(表2)BERT-CRFによる推論モデルの正解率等


感情ターゲット	適合率	再現率	F1値	データ数
ポジティブ	74%	68%	70%	164
ネガティブ	70%	71%	71%	307
全体平均 (Micro-F1値)	71%	70%	71%	471

(注)部分一致も正解とすると、全体平均 (MicroF1値) は適合率 77%, 再現率 75%, F1 値 76% になる。


(5) SWB に関連する感情対象語の抽出

ABSA の結果から、全データにおける感情対象語の抽出を行った。感情対象語とは、特定の評価や感情が向けられる対象となる名詞または名詞句を指し、本分析において出現頻度が最上位 3 位となったのは「生活」「家族」及び「お金」であった。また、ポジティブな感情と関連づけられる割合が「生活」とともに最上位の感情対象語として「家族」及び「子供」が挙げられ、特に「ペット」はほぼもっぱらポジティブな感情と関連づけられる傾向が見られた。一方、ネガティブな感情と関連づけられる割合が最上位の感情対象語としては「生活」とともに「お金」及び「仕事」が示された (図 10)。

次に、50歳以上と50歳未満の回答者における感情対象語の出現回数の比較を行った。その結果、「仕事」は50歳以上ではポジティブな感情出現とネガティブな感情出現の頻度比で、ポジティブな感情の出現頻度がネガティブな感情のその2倍を超えたのに対し、50歳未満では逆に、同出現頻度比で、ネガティブな感情の出現頻度がポジティブな感情のその2倍を超えた。全体的な傾向としては、全データを対象とした分析結果と大きな差異は見られな




(図10)ABSA 全データの感情対象語




(図11)ABSAの感情対象語 50歳以上と50歳未満の対比

かったが、年齢層ごとの特徴として、50歳以上では「健康」及び「孫」が同頻度比で、ポジティブな感情の出現頻度がネガティブな感情のその2倍を超え、一方で50歳未満では「時間」「夫」及び「心」が同頻度比で、ポジティブな感情の出現頻度がネガティブな感情のその2倍を超えることが確認された(図11)。

さらに SWB 上位 25% 層の回答者における感情対象語の抽出を行った。その結果、感情対象語として出現頻度が最上位 3 位となったのは「家族」「子供」及び「生活」であった。特に「家族」及び「子供」は、ほぼポジティブな感情と関連づけられる傾向が顕著に認められた(図 12)。他方で、SWB 下位 25% の回答者における感情対象語の抽出を行ったところ、感情



(図12)ABSA SWB上位25%層の感情対象語




(図13)ABSA SWB下位25%層の感情対象語

対象語として出現頻度が最上位 3 位となったのは「お金」「生活」及び「仕事」であり、特に「お金」及び「仕事」は、ほぼネガティブな感情と関連づけられる傾向が顕著に認められた(図 13)。

なおこの分析では、感情語及び批評語の使用傾向を明確に把握するため、出現頻度がゼロに近い語の影響を排除し、統計的に有意な傾向を分析する目的で、感情対象語としての出現回数が一定程度あると判断される出現頻度 5 回以上の語のみを抽出した。

(6) SWB に関連する感情語及び批評語の抽出

SWB の上位 25% 層及び下位 25% 層のデータにおいて、感情語 (Sentiment Words) 及び批評語 (Opinion Words) を抽出し、出現頻度の傾向を分析した。



(図14) ABSA 感情語及び批評語 SWB上位25%層と下位25%層の対比

感情語とは、個人の感情や評価を表現する語句であり、形容詞・副詞・動詞などが含まれる（例：「素晴らしい」「悪い」「好き」「最悪」）。他方、批評語は特定の対象やアспектに対する評価や意見を示す語句であり、感情語が含まれることもある。（例：「(画質が) 良い」「(電池持ちが) 悪い」「(動作が) 遅い」「(色が) 嫌い」）。

分析の結果、SWB 上位 25% 層において感情語および批評語として上位の頻度で出現したのは、「幸せ」「健康」「楽しく」及び「感謝」などであり、特に「幸せ」は肯定形（例：「幸せだ」「幸せを感じる」）として使用される傾向が強かった。他方、SWB 下位 25% 層では、「幸せ」「不安」「ストレス」及び「いない」などが上位の頻度で出現し、特に「幸せ」は否定形（例：「幸せではない」「幸せでない」）として表現されることが多かった（図 14）。

この分析においても、感情語及び批評語の使用傾向を明確に把握するため、出現頻度がゼロに近い語の影響を排除し、統計的に有意な傾向を分析する目的で、感情語または批評語としての出現回数が一定程度あると判断される出現頻度 5 回以上の語のみを抽出した。

5. 考察

本研究では、ABSA 用いた分析により、自由記述テキストにおける特定の語が回答者のポジティブおよびネガティブな感情と関連づけられることが明らか

になった。特に、感情対象語に着目した結果、ポジティブに関連づく頻度がネガティブに関連づく頻度の2倍超となった語として「家族」「子供」及び「ペット」が抽出され、ネガティブに関連づく割合が高い語として「お金」及び「仕事」が確認された。

さらに、「仕事」に関しては年齢層による違いが見られ、50歳以上の回答者ではポジティブに関連づく頻度がネガティブに関連づく頻度の2倍超となった一方、50歳未満ではネガティブに関連づく頻度がポジティブに関連づく頻度の2倍超になった。また50歳以上では「健康」及び「孫」、50歳未満では「時間」「夫」及び「心」が、それぞれポジティブに関連づく頻度がネガティブに関連づく頻度の2倍超であることが明らかとなった。特にSWB上位25%層の回答者において、「家族」及び「子供」がポジティブな感情と強く結びつく傾向が確認された。

ABSAによるポジティブな感情対象語の抽出の結果は、家族との交流 (Diener & Seligman 2002)、子供との関わり (Nelson et al. 2013)、及びペットの存在 (McConnell et al. 2011) が高いSWBと相関するという先行研究と整合的である。先行研究は、感謝を示し、喜びを表出しながら健やかな生活を送ることは、高いSWBと相関する (Emmons & McCullough 2003) ことを明らかにしている。これらの語がSWB上位25%層の回答者において、感情語および批評語によって表現されていたことは先行研究と整合的である。

他方で、ABSAによるネガティブな感情対象語の抽出の結果は、「お金」 (Sweet et al. 2013) や「仕事」 (Kivimäki & Kawachi 2015) に関する問題が低いSWBと相関するという先行研究と一致する結果が得られた。特にSWB下位25%層の回答者において、「お金」及び「仕事」がネガティブな感情と強く関連づく傾向が確認された。先行研究は、不安やストレスを示し、欠如を認知することが低いSWBと相関する (Bonanno 2004) ことを明らかにしている。これらの語がSWB下位25%層の回答者において、感情語および批評語によって表現されていたことは同じく先行研究と整合的である。

また、感情語及び批評語の使用傾向を分析した結果、SWB上位25%層の回答者では「幸せ (肯定形)」「健康」「楽しく」及び「感謝」の出現頻度が上位となったのに対し、SWB下位25%層の回答者では「幸せ (否定形)」「不安」「ス

トレス」及び「いない」の出現頻度が上位であることが明らかになった。

以上の結果から、ポジティブな感情対象語の使用は高い SWB と、ネガティブな感情対象語の使用は低い SWB と、それぞれ関連しており、これらの語がどのような感情語や批評語とともに用いられるかによって、SWB の高低がテキストデータから推論できる可能性が示唆された。

これにより、SWB の高低と関連づく名詞や固有表現を自由記述から抽出する AI 推論エンジンの基盤を構築し、エビデンスベースの社会政策や福祉施策の設計に貢献する可能性が示唆された。

6. 結論と今後の研究課題

(1) 結論

本研究は、自然言語処理の AI による文脈を考慮した文書ベクトル化機能及び推論機能により、書かれた自由記述テキストの構文から、書き手の SWB の度合いを推論するエンジンの開発を行った。機械学習により AI エンジンが回答者の SWB を、SWB 上位 25% 層及び下位 25% 層では 9 割程度の適合率及び再現率で推論できることを明らかにし、その有効性を示した。

次に、モダリティ分析により、SWB 上位 10% 層では、計画・実践、快適、満足、期待及び平穏が具体的な表現で、SWB 下位 10% 層では、つらい・不安、フラストレーション及び家計不安が抽象的な表現で、それぞれ回答者の意図として書かれる傾向があることがわかった。

さらに ABSA により、感情対象語について、ポジティブ感情に関連づく割合が上位だったのは「家族」「子供」及び「ペット」、またネガティブ感情に関連づく割合が上位の感情対象語は「お金」及び「仕事」であり、SWB 上位 25% 層は特に「家族」及び「子供」がポジティブ感情に関連づき、SWB 下位 25% 層は特に「お金」及び「仕事」がネガティブ感情に関連づく傾向にあることが示された。そして、感情語及び批評語については、SWB 上位 25% 層では「幸せ（肯定形）」「健康」「楽しく」及び「感謝」、SWB 下位 25% 層では「幸せ（否定形）」「不安」「ストレス」及び「いない」の出現頻度が上位にあることがわかった。

（２）今後の研究課題

今後の研究課題は三つある。

第一に、ウェルビーイング推論エンジンの精度をさらに向上させ、SWB 中位層においても適合性および再現性を確保できるようにすることである。第二に、モダリティ分析および ABSA の精度をさらに向上させることであり、特に ABSA においては、ロングテールに該当する同義語や表記の異なる出現語を統合し、ポジティブ感情またはネガティブ感情の判定が可能となるようにすることである。第三に、対象語のポジティブ感情及びネガティブ感情の重みを算出する方法の開発も今後の研究課題である。

謝辞

本研究は JSPS 科研費（JSPS KAKENHI JP22K04601）、JST 共創の場形成支援プログラム（JPMJPF2111）、及び公益財団法人三菱 UFJ 信託奨学財団研究助成（2024 年度）の支援を受けている。記して謝意を表す。

注釈

- 1 マイクロソフトが開発した決定木応用のアルゴリズム Light GBM (<https://lightgbm.readthedocs.io/>, ライセンスは MIT License) を用い、機械学習アルゴリズムによる予測モデルを作成する。
- 2 図 3（人生満足尺度）、図 4（幸せ 4 因子）及び図 5（日本版 PANAS）に見るように、これらの度数分布は中央値当たりの度数が突出しており、回答がすべて中央値に偏った恣意的な回答のデータである可能性を排除できていない可能性がある。他方で、SWB 上位 25% 及び下位 25% 層の抽出に当たり、使用した尺度はこれらの尺度ではない、図 2 に度数分布が示されているカントリルのはしごである。さらにカントリルのはしごを使用して、SWB 上位 25% 及び下位 25% 層の抽出を行った際には、SWB 上位 25% 層はカントリルのはしごの 7～10 点、SWB 下位 25% 層はカントリルのはしごの 1～4 点にそれぞれ概ね対応しており、中央値の回答の連打など、恣意的な回答の可能性を排除しきれない回答が含まれている可能性のある中央値付近（5～6 点）は、このデータの分析対象から排除されて

いる。したがって、回答データの信頼性に影響を及ぼす可能性はほぼないと判断し、恣意的な回答の可能性を排除しきれない回答をデータから取り除くなどの措置はとっていない。

参考文献

- Bellet, C., & Frijters, P. (2019). “Chapter 6: Big data and well-being”, In *World Happiness Report 2019*, <https://worldhappiness.report/ed/2019/big-data-and-well-being/> (最終閲覧 2025 年 3 月 22 日)
- Bonanno, G. A. (2004). “Loss, trauma, and human resilience: Have we underestimated the human capacity to thrive after extremely aversive events?”, *American Psychologist*, vol. 59, No.1, pp.20–28. <https://doi.org/10.1037/0003-066X.59.1.20>
- Cantril, H. (1965). *The Pattern of Human Concerns*, New Brunswick, NJ: Rutgers University Press.
- Diener, E., Emmons, R.A., Larsen, R.J., Griffin, S. (1985). “The Satisfaction with Life Scale”, *Journal of Personality Assessment*, vol. 49, No. 1, pp.71–75.
- Diener, E., & Seligman, M. E. P. (2002). “Very happy people”, *Psychological Science*, vol.13, No.1, pp.81–84.
- Diener, E., Oishi, S. & Tay, L. (2018). “Advances in subjective well-being research”, *Nature Human Behavior*, Vol.2, pp.253–260. <https://doi.org/10.1038/s41562-018-0307-6>
- Emmons, R. A., & McCullough, M. E. (2003). “Counting blessings versus burdens: An experimental investigation of gratitude and subjective well-being in daily life”, *Journal of Personality and Social Psychology*, vol.84, No.2, pp.377–389.
- Gallego, I., & Font, X. (2020). “Changes in air passenger demand as a result of the COVID-19 crisis: using Big Data to inform tourism policy”, *Journal of Sustainable Tourism*, vol.29, No.9, pp.1470–1489, <https://doi.org/10.1080/09669582.2020.1773476>
- Kivimäki, M., & Kawachi, I. (2015). “Work stress and subjective well-being:

- Epidemiological evidence and public health implications”, In E. Diener, S. Oishi, & L. Tay (Eds.), *The Oxford Handbook of Well - Being*, pp.397–412, Oxford: Oxford University Press.
- McConnell, A. R., Brown, C. M., Shoda, T. M., Stayton, L. E., & Martin, C. E. (2011). “Friends with benefits: On the positive consequences of pet ownership”, *Journal of Personality and Social Psychology*, vol.101, No.6, pp.1239–1252.
- Nelson, G., Kushlev, K., & Lyubomirsky, S. (2013). “The more, the merrier? Parenthood and well - being”, *Journal of Personality and Social Psychology*, vol.105, No.5, pp.832–851.
- Nuyts, J., van der Auwara, J. (eds.) (2016). *The Oxford Handbook of Modality and Mood*, Oxford, UK: Oxford University Press.
- OECD (2013). *OECD Learning Compass 2030*, OECD Website, <https://www.oecd.org/education/2030-project/teaching-and-learning/learning/learning-compass-2030/> (最終閲覧 2025 年 3 月 22 日)
- Pontiki, M., Galanis, D., Papageorgiou, H., Manandhar, S., & Androutsopoulos, I. (2014). “SemEval-2014 Task 4: Aspect Based Sentiment Analysis”, *Proceedings of the 8th International Workshop on Semantic Evaluation (SemEval 2014)*, pp. 27–35, <https://doi.org/10.3115/v1/S14-2004>.
- Sweet, E., Nandi, A., Adam, E. K., & McDade, T. W. (2013). “The high cost of debt: Household financial debt and its impact on mental and physical health”, *Social Science & Medicine*, vol.91, pp.94–100.
- Stephoe, A., Deaton, A., Stone, A.A.(2015). “Subjective wellbeing, health, and ageing”, *Lancet*, 2015 Feb Vol.14, No.385(9968), pp.640-648. doi: 10.1016/S0140-6736(13)61489-0. Epub 2014 Nov 6. PMID: 25468152; PMCID: PMC4339610.
- Wang, C., Pan, R., Wan, X., Tan, Y., Xu, L., McIntyre, R.S., Choo, F.N., Tran, B., Ho, R., Sharma, V.K., Ho, C. (2020). “A longitudinal study on the mental health of general population during the COVID-19 epidemic in China”, *Brain, Behavior and immunity*, Vol.87, July 2020, pp.40-48, <https://doi.org/10.1016/j.bbi.2020.07.041>.

[org/10.1016/j.bbi.2020.04.028](https://doi.org/10.1016/j.bbi.2020.04.028)

- 五井野琢也, 濱上知樹 (2021). 「BERT を用いた医療文書からの固有表現抽出」
計測自動制御学会『第 48 回知能システムシンポジウム』2021 年 3 月 8-9 日,
オンライン開催, オンライン予稿集, B3-2.
- 佐藤徳, 安田朝子 (2001). 「日本語版 PANAS の作成」『性格心理学研究』Vol. 9,
p,139.
- 高橋義明 (2018). 「日本の幸福度の低さにおける文化の影響: 理想の幸福度によ
る検証」『行動経済学』第 11 巻大会特別号 (2018) 第 12 回大会プロシード
ィングス, pp.13-18.
- 内閣府 (2021). 「経済財政運営と改革の基本方針 2021 日本の未来を拓く 4 つの
原動力〜グリーン、デジタル、活力ある地方創り、少子化対策〜」(骨太
方針 2021), 2021 年 6 月 8 日閣議決定, [https://www5.cao.go.jp/
keizaishimon/kaigi/cabinet/2021/2021_basicpolicies_ja.pdf](https://www5.cao.go.jp/keizaishimon/kaigi/cabinet/2021/2021_basicpolicies_ja.pdf),
(最終閲覧 2025 年 3 月 22 日).
- 前野隆司 (2013). 『幸せのメカニズム: 実践・幸福学入門』講談社現代新書.
- 森川 正之 (2020). 「コロナ危機下の在宅勤務の生産性: 就労者へのサーベイに
よる分析」(報告書 No. 20-J-034), 独立行政法人 経済産業研究所.