

メンター発見アルゴリズムによる 自己実現プラットフォームの研究

大川 倫明^{1,a)} 山口 高康^{1,2,b)}

概要: オンライン・コミュニケーション・サービスが普及し、時間や場所を問わず世界中の人と繋がること
が可能となり、自ら学んで成長できる環境が広がっている。しかし、成長を望む者同士が互いに高め合い、
未来の自己実現を手助けし合える程の相手に巡り合うことは難しい。そのため、今の自分に適したメン
ターを見つけ出す方法論が求められる。本研究では、自己実現を目指す人と交流できる独自 SNS プラット
フォームを構築し、そこに投稿されたテキストや画像からユーザーの特徴量を抽出して、ユーザーが未知の嗜
好領域を持つ人物をメンターとして推薦するアルゴリズムを提案する。研究室のメンバー 8 名に独自 SNS
へ参加してもらい、ユーザーが未知の嗜好領域を持つ人物を推薦する実験を行った。提案手法によれば、加
工した画像を特徴量に加えることで、ユーザーの潜在的な特徴量を抽出でき、さらに未知の嗜好領域のメン
ターを推薦できる可能性があることを明らかにした。

キーワード: 自己実現, メンター発見, マッチングアルゴリズム

Self-actualization Platform Applying Personalized Mentor Discovery Algorithms

TOMOAKI OHKAWA^{1,a)} TAKAYASU YAMAGUCHI^{1,2,b)}

Abstract: With the spread of online communication services, connecting with people worldwide has become more
accessible. As a result, people can learn and grow by themselves. However, finding a mentor who can help with
self-actualization can be difficult. Thus, a methodology to find the “perfect mentors” is required. In this paper, we
created a new social networking platform for self-actualization, which extracts user features from texts and images, to
recommend mentors based on latent preference domains. Our experiment shows that adding expressive interpretations
generated from images would improve the system’s recommendation of mentors based on latent preferences.

Keywords: Self-actualization, mentor discovery, matching algorithm

1. はじめに

新型コロナウイルス感染症の影響で、Zoom や Google Meet のようなオンライン・コミュニケーション・サービスが普及した。時間や場所を問わず世界中の人と繋がること
が可能となり、自ら学んで成長できる環境が広がっている。しかし、成長を望む者同士が互いに高め合い、未来の
自己実現を手助けし合える程の相手に巡り合うことは難し

い。そのため、今の自分に適したメンターを見つけ出す方
法論が求められる。

従来の研究では、適切なレベルや範囲の知識を持った人
たちを集めたコミュニティを形成する研究 [1] や、Twitter
内で共通の関心を持つユーザーを推薦する研究 [2] がある。
これらの研究は、知識レベルや趣味嗜好を考慮したユーザ
を推薦することで、ユーザ体験が向上することが示されて
いるが [3], 一部の研究者は、これがユーザをコンフォート
ゾーンに閉じ込める「フィルターバブル」を生み出すと主
張する [3], [4]。フィルターバブルは、ユーザの未知の嗜好
領域を発見することを妨げ、推薦されるアイテムや人、コ

¹ 秋田県立大学 システム科学技術学部 経営システム工学科

² 情報処理学会

^{a)} tomoaki.ohkawa@cps.akita-pu.ac.jp

^{b)} takayasu@akita-pu.ac.jp

コンテンツなどの多様性を制限してしまう。またこの問題は、「自己実現のための推薦システム」を構築することで克服されると報告されており、このシステムは嗜好を強制するのではなく、ユーザが未知の嗜好領域を深めることを支援するという、より複雑な状況に焦点を当てている [5], [6]. さらに、推薦精度やユーザ体験を最適化するのではなく、ユーザが自分自身の好みや嗜好を発見する重要な過程を支援することを目的としている。

本研究では、自己実現を目指す人と交流できる独自 SNS プラットフォームを構築し、そこに投稿されたテキストだけでなく、加工した画像を特徴量に加え分析をする。テキストからユーザが言語化する特徴量と、画像を加工した際に得たノイズと、ユーザが言語化しない潜在的な特徴量を抽出し、それぞれの特徴量を足し合わせることで、従来にない新たな趣味嗜好の抽出を行う。その抽出された人と似た特徴量をもつ人をメンターとして採用し、マッチングさせることで、フィルターバブル問題を抑制しつつ、ユーザが未知の嗜好領域を発見し、深めることを支援する。本研究の目的は、ユーザの潜在的な特徴量を考慮した未知の嗜好領域を持つメンターを推薦するアルゴリズムについて検討することである。

2. 先行研究

2.1 フィルターバブル問題と自己実現

情報過多な現代において、推薦システムは多方面で利用されており、ユーザに適したアイテムや人、コンテンツなどが推薦されている。しかし、一部の研究者は、このシステムはユーザを「フィルターバブル」の中に閉じ込め、ユーザの視野を狭め、探究心を失わせ、真の嗜好の発達を妨げている可能性がある問題視している [3], [4]. 近年は、推薦システムの有用性を測る指標として、推薦精度以外の新たな指標が提案されている。たとえば、説明性のある推薦や新しい嗜好の抽出方法、ユーザとのインタラクションがユーザの満足度、信頼度などに与える影響について研究している [7], [8]. さらに、多様性やセレンディピティのような指標で推薦を改善する研究がある [9], [10].

自己実現に関する研究としては、「自己実現のための推薦システム」がある [5]. これは、フィルターバブルを引き起こした推薦システムおよびそのユーザの欠点を認識し、これらの欠点を解決するための新しい推薦システム方向性について提案した研究である。この論文の中では、このシステムを活用することにより、ユーザは自分の好みをより理解し、深めることで、人生の決断に自信を持つ可能性があることを述べた。そして、マズローが提唱する自己実現の欲求 [11] を支援し、消費者としての自律性が損なわれることを防げることを明らかにした。また、ユーザの自己実現を支援するために、Top-N 推薦のタスクを応用した研究が

ある [12]. これは、ユーザが好まないであろうアイテムを従来の精度重視の Top-10 リストと組み合わせて推薦する。ユーザが嫌いそうなもの、よくわからないもの、議論を呼びそうなものなどを Top-10 リストとは別に 5 つ推薦する新しい映画推薦システムである。このシステムは、単にシステムが予測した最適なアイテムを推薦せず、ユーザ独自の趣味嗜好の開発を支援することを目的としている。このアプローチによって、ユーザはより多くの選択肢をコントロールできるようになり、その結果、自分の決断により満足することができるようになると主張した。

2.2 メンター発見

2.2.1 SNS での推薦

現在、Twitter や Facebook, Instagram のような SNS (Social Networking Service) は高度な機械学習の技術によって、各ユーザに最適化された投稿や動画、ユーザの推薦をしている。たとえば、Twitter は連絡先にフォローしてないユーザのメールアドレスや電話番号が含まれている場合、その人をフォローするように推薦したり、ユーザがいる都市や国などの位置情報に基づいて推薦する。さらに、ユーザの閲覧履歴やツイートを引用した人を分析し、ユーザの行動に基づいて推薦する [13]. また、Facebook や Instagram は利用者にとって関連性の高い、価値ある推薦をすることを目指している。一人ひとりに合わせたおすすめを個別に提案し、フード、レシピ、本、読書に関するおすすめを表示することもある。さらに、ユーザのおすすめコンテンツについてはガイドラインを設けている。低いおすすめ、不快なおすすめ、未成年者にお酒やタバコ、不適切なおすすめを表示しないようにするために、ガイドラインを運用しセキュリティを高めている [14].

2.2.2 趣味嗜好の抽出

Twitter において膨大な数のユーザからフォローユーザを探し出すためには、自分で Twitter ユーザを検索し、検索結果から自分にあったユーザを選択しなければならない。そのため、共通の関心事の情報を扱うユーザを推薦する研究 [2], [15] や、Twitter において投稿の文章類似度とフォロー関係の相関を分析した研究がある [16]. また、アイコン画像を選択・設定する際に、個人の価値観や思想、嗜好などの影響を受けることを利用し、ユーザの Twitter 上での行動とアイコン画像の因果関係について調査した研究がある [17]. さらに、ユーザが SNS 上で投稿するテキストと画像の投稿に着目し、投稿内容の関係を明らかにした研究がある [18]. この研究によると、画像の投稿は言葉で表現する傾向が小さく、画像で表現する傾向が強いことを示した。

3. 提案手法

3.1 ユースケース

自己実現を目指すユーザに図1のような独自 SNS プラットフォームを使用してもらおう。ユーザは一般的な SNS に投稿するように、テキストと画像の投稿をする。そのデータを基にユーザに適したメンターが推薦され、メンターとマッチングできる。メンターとコミュニケーションをとることで、ユーザは未知の嗜好領域を発見し、深めることができる。



図1 独自プラットフォーム

3.2 分析手法

テキストの分析は、異なる特徴の埋め込みベクトルを生成できる TF-IDF と BERT を用いる。また、画像の分析は、CLIP Reward を用いて画像から英語テキストを生成し、日本語に翻訳をする。

3.2.1 TF-IDF

TF-IDF(Term Frequency-Inverse Document Frequency) とは、各文章中に含まれる各単語が「その文章内でどれほど重要か」を表す尺度である。具体的には、ある文章における、ある単語の出現頻度を表す TF と、逆文章頻度を表す IDF を掛け合わせて、文章を特徴付けるキーワードに着目してベクトル化する手法である。

3.2.2 BERT

BERT(Bidirectional Encoder Representations from Transformers) とは、Transformer[19] で使用された Multi-head attention を 12 層 (あるいは 24 層) 重ねたモデルであり、パラメータ学習は Masked Language Model と Next Sentence Prediction という 2 つのタスクを解くことで、教師なしの枠組みのもとで行われる。BERT の入力の埋め込み表現は、図 2[20] に示すように、トークンの重みと文章内での位置を示す重みを加える。また 2 つの文章を入力する場合には、各トークンがどちらに属するかを示すための重みを加える。このモデルを用いることで、入力文内の文脈に依存した形で単語の埋め込み表現を得ることができる。本研究では、日本語 Wikipedia で学習された東北大学の乾研究室が公開する日本語 BERT モデル [21] を用いて 768 次元の文章の埋め込みベクトルを取得する。

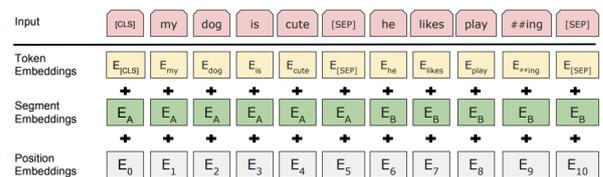


図2 BERT の埋め込みベクトル

3.2.3 CLIP Reward

CLIP(Contrastive Language-Image Pre-training) [22] とは、4 億組の画像と画像を説明するテキストを用いて学習されたモデルであり、画像から英語のテキストを生成することができる。このモデルの画像とテキストの類似度に着目して、より説明性があり、正確な画像キャプションを生成することができるモデルが CLIP Reward[23] である。本研究では、このモデルを用いて画像から英語のテキストを取得する。

3.2.4 コサイン類似度

コサイン類似度とは、ベクトル同士のなす角度の近さを表しており、ベクトル A と B の類似度は数式 (1) のようにあらわされる。出力が 1 に近いほどユーザ間は類似しており、0 に近いほど類似していないことを表す。

$$Similarity(A, B) = \frac{\sum_{i=1}^n A_i B_i}{\sqrt{\sum_{i=1}^n A_i^2} \sqrt{\sum_{i=1}^n B_i^2}} \quad (1)$$

3.3 システム構成

本研究では、ユーザ名、投稿されたテキスト、投稿された画像をデータベースに保管する。保管された画像に関しては、3.2.3 節で述べた CLIP Reward で画像から英語のテキストを取得した後、Google 翻訳 API で日本語に翻訳した画像テキストを特徴量として用いる。この特徴量は、CLIP Reward が説明性のあり、特徴的な英語のテキストを

生成し、Google 翻訳 API が、自然言語処理モデルに解釈可能な翻訳をした時、ユーザの潜在的な特徴量になる。反対に、CLIP Reward が誤った画像の説明をしたり、Google 翻訳 API が誤った翻訳をするとノイズとなり、ユーザが未知の嗜好領域の特徴量になる。この特徴量をテキストと組み合わせ、ユーザの潜在的な特徴量を考慮した未知の嗜好領域を持つメンターを推薦する。また、これはフィルターバブル問題を抑制し、ユーザが未知の嗜好領域を発見し、探索するきっかけを提供し、自己実現を手助けするアルゴリズムであるといえる。

4. 実験

実験では、私が所属する研究室の学生の協力のもと行う。

4.1 実験データ

自分を含めた 8 名の被験者が日常的に独自プラットフォームを利用してもらい、データベースに蓄積された下記のデータを用いて実験を行う。また、図 3 に各ユーザの投稿数の比較を示した。テキストを投稿した人は合計 8 名で画像を投稿した人は合計 5 名であった。

- (1) テキストデータ 159 件
- (2) 画像データ 37 件
- (3) テキストと画像を合わせたデータ 196 件

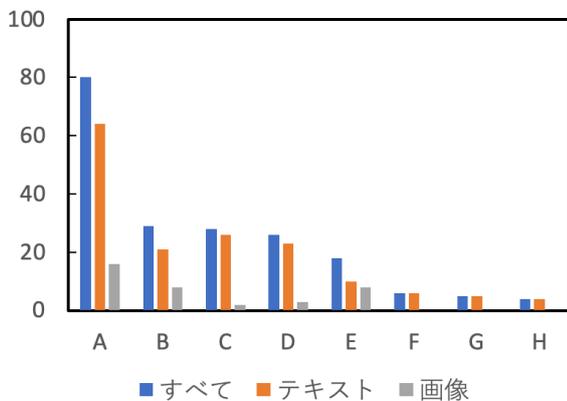


図 3 各ユーザの投稿数の比較

4.2 実験方法

4.2.1 評価指標

コサイン類似度は、1 に近いほどユーザ間は類似しており、0 に近いほど類似していないことを表すため、各ユーザ間の距離の可視化をする際に直感とは反した結果となってしまう。そのため、1 からコサイン類似度を引き、ユーザ間の距離を算出できるモデルを数式 (2) に示した。このモデルを用いて評価する。

$$Distance(A, B) = 1 - \frac{\sum_{i=1}^n A_i B_i}{\sqrt{\sum_{i=1}^n A_i^2} \sqrt{\sum_{i=1}^n B_i^2}} \quad (2)$$

4.2.2 テキストと画像テキストの特徴量の比較

テキストと画像テキストの特徴量を比較し、それぞれの特徴量に嗜好の差異があるか実験する。画像テキストは人工知能 (AI) が生成した文章であるため、特徴量を比較する際は、時系列を考慮しないモデルを用いて比較することが望ましい。本研究では、3.2.1 節で述べた文章中のキーワードに着目する TF-IDF を用いて各ユーザの埋め込みベクトルを生成した後、評価指標を用いて、テキストと画像の特徴量の距離を比較する。実験参加者 8 名のうち、5 名が画像の投稿をしたため、この 5 名のみの各特徴量間の距離と距離の平均を算出し評価する。

4.2.3 メンターの推薦

テキストのみを用いる従来手法 [2], [15] では、フィルターバブル問題が起こりうる可能性があり、未知の嗜好領域を発見し、深められる可能性が低い。そのため、ノイズを含んだ画像テキストを加えることで、従来手法と推薦するメンターが変化するか実験する。3.2 節で述べた各モデルを用いて、ユーザごと埋め込みベクトルを生成し、評価指標で距離を算出した後、距離が一番近い人をメンター候補として採用する。各ユーザに推薦されるメンターをまとめた表を作成する。また、従来手法と提案手法で各ユーザに推薦されるメンターが変化した場合は、「1」変化がない場合は、「0」を表に追記し、推薦するメンターがどの程度変化したか割合を算出する。

4.2.4 推薦精度

実験データ 1, 実験データ 2, 実験データ 3 を用いて、各モデルの推薦精度の差異について実験する。各モデルごと各ユーザの埋め込みベクトルを生成した後、距離を算出する。ユーザ間の距離が大きい人と小さい人を区別できることが望ましいため、距離の最大値、最小値、範囲、分散をそれぞれ算出し、表にまとめる。また、提案手法を用いて、各モデルでユーザ間の距離に特徴があるか可視化する。

5. 評価

4.2.2 節で述べた各ユーザのテキストと画像テキストの特徴量を比較した結果を表 1 に示した。各ユーザのテキストデータと画像テキストデータの距離は 1 に近く、全体としての平均も同様に 1 に近い。

表 1 各ユーザのテキストと画像の投稿の埋め込みベクトル距離

	A	B	C	D	E	平均
距離	1.000	0.989	1.000	0.990	0.987	0.993

4.2.3 節で述べた各モデルを用いて従来手法と提案手法で、メンター候補が変化するか実験した結果を表 2 に示した。TF-IDF を用いた実験では、8 人中 2 人が変化し、割合で 25% 変化した。BERT を用いた実験では、8 人中 6 人が変化し、割合で 75% 変化した。TF-IDF と BERT で推薦するメンターを比べると、TF-IDF ではユーザ A を頻繁にメ

ンターとして推薦しているが、BERTではユーザ A を 1 回も推薦していない。また、各モデルの提案手法を比べると TF-IDF ではユーザ A, BERT ではユーザ B を多く推薦している。4.1 節で示した図 3 を参照するとユーザ A, B の共通点は、投稿数が多いことがわかる。加えて、TF-IDF は投稿数が多いユーザ A, B, C, D, E を推薦する傾向にあり、BERT は投稿数が少ないユーザ G を推薦している。

表 2 各モデル、各特徴量における推薦メンターの変化

		A	B	C	D	E	F	G	H	割合
TF-IDF	従来手法	B	A	A	A	D	C	B	D	
	提案手法	E	A	A	A	A	C	B	D	
	推薦変化	1	0	0	0	1	0	0	0	25%
BERT	従来手法	E	C	D	C	E	B	F	E	
	提案手法	G	E	D	B	B	B	D	C	
	推薦変化	1	1	0	1	1	0	1	1	75%

4.2.4 節で述べた提案手法を用いた各モデルの推薦精度の差異について実験結果を表 3 に示した。TF-IDF を用いた実験では、すべての実験データにおいて最小値、最大値が共に 1 に近く、ユーザ間の距離が近い組はない。また提案手法は、従来手法より範囲が 0.156 から 0.219 に大きくなり、分散が 0.049 から 0.063 へと大きくなった。

BERT を用いた実験では、最小値は 0 に近く、最大値は 0.6 に近い値を出力していることから、ユーザ間の距離が近い組と比較的遠い組がいる。また、提案手法の範囲を参照すると 0.5 となっており、TF-IDF より大きな値を出力している。従来手法と提案手法の分散を比べると、0.027 から 0.063 に大きくなっている。各モデルの画像テキストのみの分散を参照すると、TF-IDF が 0.145 で、BERT が 0.002 であり、大きな差がある。

表 3 最小値、最大値、範囲、分散によるモデル比較

		従来手法			画像テキスト			提案手法		
		最小値	最大値	範囲	分散	最小値	最大値	範囲	分散	
TF-IDF	最小値	0.844	1.000	0.156	0.049	0.681	0.972	0.291	0.145	
	最大値	1.000	1.000	0.156	0.049	0.681	0.972	0.291	0.145	
	範囲	0.156	0.219	0.063	0.063	0.291	0.219	0.063	0.063	
	分散	0.049	0.145	0.063	0.063	0.145	0.063	0.063	0.063	
BERT	最小値	0.088	0.560	0.472	0.027	0.091	0.235	0.144	0.500	
	最大値	0.088	0.560	0.472	0.027	0.091	0.235	0.144	0.500	
	範囲	0.088	0.560	0.472	0.027	0.091	0.235	0.144	0.500	
	分散	0.027	0.002	0.031	0.031	0.002	0.031	0.031	0.031	

提案手法を用いた各モデルのネットワーク図を図 4、図 5 に示した。TF-IDF はユーザ間の全体としてユーザ間の距離が大きく、BERT はユーザ間の距離がユーザ A を除いて小さい。図 4 を参照すると、ユーザ A がネットワークの中心部に位置しており、多くのユーザと距離が近いことがわかる。

6. 考察

4.2.2 節で述べた実験では、各ユーザのテキストと画像テキストの特徴量を比較した。画像キャプション精度につ

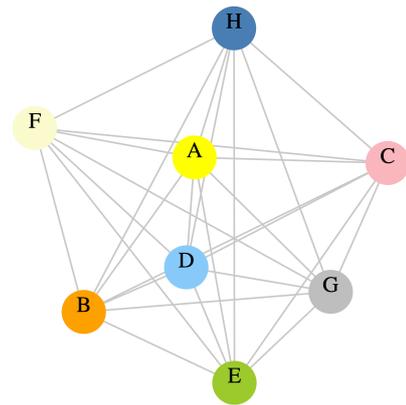


図 4 TF-IDF を用いたネットワーク図 (提案手法)

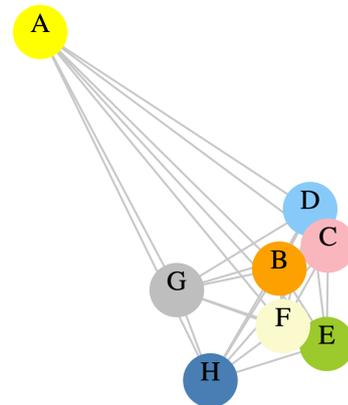


図 5 BERT を用いたネットワーク図 (提案手法)

いては、先行研究で年々精度が向上していると報告していること [23] と 4.2.4 節で述べた画像テキストの分析において BERT より TFIDF の方が推薦精度が高かったことから、画像から単語の抽出は正確にできたと推測できる。そのため、この実験については、画像から単語を正確に抽出できたと仮定して考察する。表 1 からすべてのユーザにおいてテキストと画像テキストの特徴量の距離が遠いことから、テキストと画像の投稿は傾向が違うことがわかる。先行研究では画像の投稿は言葉で表現する傾向が小さく、画像で表現する傾向が強いことが明らかになっている [18] ことから、ユーザが言語化する特徴量と言語化しない潜在的な特徴量を抽出することができたと考えられる。

4.2.3 節で述べた実験では、各モデルを用いて従来手法と提案手法で、メンター候補となる人がどのような変化があるか実験した。表 2 から TF-IDF より BERT の方が推薦するメンターの変化が大きくなった。このことから、BERT を用いる方がユーザが未知の嗜好領域を持つメンターと出会える可能性が高いといえる。また、TF-IDF は、ユーザ A を多くメンターとして推薦した。これは、TF-IDF は投稿数が多いほど密なベクトルを生成し、投稿数が少ないほど疎なベクトルを生成するため、投稿数が多いほど単語の出現確率が高い埋め込みベクトルすなわち、距離が近くな

りやすい埋め込みベクトルを生成したためだと考える。また、BERTはユーザBを多くメンターとして推薦し、投稿数が少ないユーザGも推薦した。これは、投稿数によらず、各ユーザの投稿から密な埋め込みベクトルを生成し、メンターとして推薦するモデルであることを示す。さらに、BERTは、ユーザAを一度も推薦しなかった。BERTは埋め込みベクトルを表現できる文章の最大長が存在し、投稿数が80件のユーザAは正確な埋め込みベクトルを生成できなかったためだと考えられる。

4.2.4節で述べた実験では、実験データ1、実験データ2、実験データ3を用いて、各モデルの推薦精度の評価をした。表3の従来手法と提案手法の分散を比べると、提案手法の方が分散が大きくなった。しかし、BERTに関しては、ユーザAの埋め込みベクトルが正確ではなく、外れ値となり、それが分散を大きくした可能性があるため、BERTに関しては推薦精度が向上したとは言いがたい。また、画像テキストのみを各モデルで比較をすると、TF-IDFは大きな値を出力し、BERTは極めて小さな値を出力した。これは、CLIP Rewardが出力した英語テキストをGoogle翻訳APIで翻訳し、ノイズを含ませたため、時系列を考慮するBERTが正確な埋め込みベクトルを生成できなかったためだと考えられる。それに対し、TF-IDFはノイズを加えた日本語テキストの中から名詞のみを抽出しベクトル化したため、大きな値を出力したと考えられる。このことから、BERTは発生させたノイズを考慮するモデルであり、TF-IDFはノイズを考慮せず、ユーザの潜在的な特徴量のみを抽出できるモデルであるといえる。

提案手法を用いて、各モデルでユーザ間の距離に特徴があるか可視化すると、TF-IDFはユーザ間の距離を遠く出力するモデルの性質があり、BERTはユーザ距離を近く出力する性質があることがわかり、ネットワーク図の中心にいるユーザがメンターとして推薦されやすいことがわかった。

7. おわりに

本研究では、ユーザのテキストと画像の投稿からユーザが言語化する特徴量と言語化しない潜在的な特徴量を抽出できることを明らかにした。また、ノイズを含ませた画像テキストを特徴量として加えることで、推薦するメンターの変化やTF-IDFとBERTのモデルの性質を明らかにした。TF-IDFは、ユーザ間の距離を遠く出力する傾向があり、画像を加工した際に含ませたノイズを考慮せずにベクトルを生成できることがわかった。このことから、TF-IDFはユーザの潜在的な特徴量を考慮して推薦できる。BERTは、投稿数に関係なく、従来手法で推薦するメンターとは違うメンターを推薦できる。また、ユーザ間の距離を近く出力する傾向があり、画像を加工した際に含ませたノイズを考慮してベクトルを生成できることがわかった。このことか

ら、BERTは、ユーザが未知の嗜好領域を持つメンターを推薦し、マッチングさせることで、フィルターバブル問題を抑制する可能性が高いといえる。

今後は、TF-IDFとBERTを組み合わせ、既存の手法と比較することで、ユーザの潜在的な特徴量を考慮した未知の嗜好領域を持つメンターを推薦するアルゴリズムについて再検討する。また、そのアルゴリズムを独自プラットフォームに組み込むことで、ユーザが未知の嗜好領域を発見し、その領域を深めることを支援をしたい。

参考文献

- [1] 直也伊藤, 佑一岡田, 朋子米澤. Twitter上での知識獲得をねらってつながる最適コミュニティの検討. 2019年度情報処理学会関西支部 支部大会 講演論文集, 2020.
- [2] 貴志将考, 大沢英一. twitterにおける共通の関心を持つユーザのレコメンド. 第75回全国大会講演論文集, Vol. 2013, No. 1, pp. 103-104, 2013.
- [3] Bart P. Knijnenburg, Martijn C. Willemsen, Zeno Gantner, Hakan Soncu, and Chris Newell. Explaining the user experience of recommender systems. *User Modeling and User-Adapted Interaction*, Vol. 22, , 2012.
- [4] Paul Resnick, R. Kelly Garrett, Travis Kriplean, Sean A. Munson, and Natalie Jo mini Stroud. Bursting your (filter) bubble : Strategies for promoting diverse exposure. In *Proceedings of the 2013 Conference on Computer Supported Cooperative Work, CSCW* ' 13, , 2013.
- [5] Bart P. Knijnenburg, Saadhika Sivakumar, and Daricia Wilkinson. Recommender systems for self-actualization. In *Proceedings of the 10th ACM Conference on Recommender Systems, RecSys* ' 16, , 2016.
- [6] Daricia Wilkinson, Saadhika Sivakumar, Pratitee Sinha, and Bart P Knijnenburg. Testing a recommender system for self-actualization. In *2nd Workshop on Engineering Computer-Human Interaction in Recommender Systems*, Vol. EnCHIReS 2017, , 2017.
- [7] Nava Tintarev and Judith Masthoff. Evaluating the effectiveness of explanations for recommender systems. *User Modeling and User-Adapted Interaction* 22, Vol. 4-5, , 2012.
- [8] Jingjun David Xu, Izak Benbasat, and Ronald T Cenfetelli. The nature and consequences of trade-off transparency in the context of recommendation agents. *MIS quarterly* 38, Vol. 2, , 2014.
- [9] XavierAmatriain, NealLathia, JosepM.Pujol, Hae-woonKwak, and NuriaOliver. The wisdom of the few: A collaborative filtering approach based on expert opinions from the web. In *Proceedings of the International Conference on Research and Development in Information Retrieval, SIGIR* ' 09, , 2009.
- [10] MarcoDeGemmis, PasqualeLops, GiovanniSemeraro, and CataldoMusto. An investigation on the serendipity problem in recommender systems. *Information Processing and Management* 51, Vol. 5, , 2015.
- [11] Abraham H. Maslow. *The Power of Self-Actualization*. Sounds True, 1992.
- [12] Guo Lijie. Beyond the top-n: Algorithms that generate recommendations for self-actualization. *Proceedings of the 12th ACM Conference on Recommender Systems, Vol. RecSys* '18, , 2018.
- [13] Inc. Twitter. About twitter's account suggestions, 2022. <https://help.twitter.com/>.
- [14] Inc. Meta Platforms. What are recommendations on insta-

- gram?, 2022. <https://help.instagram.com/>.
- [15] 雄介久米, 隆弘打矢, 逸内匠. 興味領域を考慮した twitter ユーザ推薦手法の提案と評価. 研究報告知能システム (ICS), 2015.
 - [16] 祐介渡邊, 浩佐藤, 智弘白川. 文章類似度に基づくユーザーリコメンドシステムの提案. 計測自動制御学会システム・情報部門第 62 回システム工学部会研究会論文集, 2020.
 - [17] 登夢富永, 嘉徳土方, 正吾西田. アイコン画像に注目した twitter 研究の提案. 人工知能学会全国大会論文集, Vol. JSAI2014, pp. 3M4-4in, 2014.
 - [18] 了玉置. Sns 上の画像投稿とテキスト投稿への反応と投稿内容の関係: テキストの内容分析を用いた比較. 商経学叢, 第 67 巻第 1 号, pp. 59-82, 2020.
 - [19] Ashish Vaswani, Noam Shazeer, Niki Parmar, Jakob Uszkoreit, Llion Jones, Aidan N Gomez, Łukasz Kaiser, and Illia Polosukhin. Attention is all you need. *NIPS*, 2017.
 - [20] Jacob Devlin, Ming-Wei Chang, Kenton Lee, and Kristina Toutanova. Bert: pre-training of deep bidirectional transformers for language understanding. *arXiv*, 2018.
 - [21] Tohoku University. Pretrained japanese bert models, 2020. <https://huggingface.co/cl-tohoku/bert-large-japanese>.
 - [22] Alec Radford, Jong Wook Kim, Chris Hallacy, Aditya Ramesh, Gabriel Goh, Sandhini Agarwal, Girish Sastry, Amanda Askell, Pamela Mishkin, Jack Clark, Gretchen Krueger, and Ilya Sutskever. Learning transferable visual models from natural language supervision. *PMLR*, 2021.
 - [23] Jaemin Cho, Seunghyun Yoon, Ajinkya Kale, Franck Derroncourt, Trung Bui, and Mohit Bansal. Fine-grained image captioning with clip reward. *arXiv*, 2022.