

# 認知科学に基づくユーザーの偶然性希求行動予測モデルの構築

鷲見優一郎<sup>†</sup> 中西 亮輔<sup>†</sup> 光田 英司<sup>†</sup> 二宮 由樹<sup>††</sup> 曾根悠太郎<sup>††</sup>  
三輪 和久<sup>††</sup>

<sup>†</sup> トヨタ自動車株式会社 未来創生センター 〒471-8572 愛知県豊田市トヨタ町1番地

<sup>††</sup> 名古屋大学大学院 情報学研究科 〒464-8603 愛知県名古屋市千種区不老町

E-mail: <sup>†</sup> {yuichiro\_sumi, ryosuke\_nakanishi, eiji\_mitsuda}@mail.toyota.co.jp,

<sup>††</sup> {ninomiya.yuki.t1, miwa.kazuhisa.m6}@f.mail.nagoya-u.ac.jp, sone.yutaro.n2@s.mail.nagoya-u.ac.jp

**あらまし** 近年、推薦システム分野において、セレンディピティが注目されている。認知科学の先行研究では、ユーザーの「偶然性希求行動」（偶然が起りやすい場を作ろうとする行動）に注目し、その時々々の偶然性希求行動に応じて、推薦システムが提供する偶然の度合いを調整する重要性が指摘されている。本研究では、一般的な推薦システムでの実現を目指し、偶然性希求行動を検索クエリから予測するモデルを提案する。その際、偶然性希求行動に影響を与える因子も検索クエリから予測し、中間変数として導入することでモデルの解釈性を高めた。段階的な予測は一般に予測性能の低下を招くが、本モデルは検索クエリから直接予測するモデルよりも高い予測性能を示した。その要因についても考察する。

**キーワード** 推薦システム, セレンディピティ, ユーザ理解

## 1 はじめに

近年、推薦システムにおいて、類似したアイテムが繰り返し推薦されてしまう「過剰最適化 [1]」が問題視されている。過剰最適化は、ユーザー満足度の低下につながり得るだけでなく [2]、ユーザーが自身とは異なる価値観に触れる機会を失う「フィルターバブル [3]」状態を招く可能性が指摘されている。

これらの問題を解決するため、近年セレンディピティが注目されている [4]。セレンディピティのある推薦は、ユーザー満足度や購買意向と相関があることが示されている [5]。従来研究の多くは、セレンディピティを推薦アイテムが持つ属性として捉え、条件として新規性、関連性、意外性を定義し、ユーザーの行動履歴やフィードバックからそれらを抽出・制御するアルゴリズムの設計に注力してきた [2]。

一方、記事推薦システムにおける大規模フィールド調査 [6] では、こうしたアイテム属性に基づく定義だけでは、多くのセレンディピティ事例の取りこぼしがあると報告されている。このことは、セレンディピティのある推薦システムの設計において、アイテム属性や行動履歴などの客観指標のみを重視する推薦手法には限界があり、ユーザーの心理特性や心理状態などに関連する主観指標を考慮する必要性を示唆している。

認知科学分野において、オンラインショッピングの利用場面を想定し、ユーザーが偶然性をどのように捉え、どの程度求めるのかに関する心理学実験が報告されている。従来研究 [7], [8] では、ユーザーの「偶然性希求行動」—ユーザーが偶然性を期待して行う（方略的）行動—に着目し、それに影響を与える心理的および状況要因が特定されている。さらに、その時々々の偶然性希求行動に応じて、推薦システムが提供する偶然の度合いを調整することの重要性も指摘されている。

しかし、ユーザーの偶然性希求行動とその影響因子の取得は、現状ではアンケート以外の方法では困難である。ユーザーエクスペリエンス (UX) を損なわないためには、推薦システムの一般的な利用過程で自然に得られるデータから予測する方法が求められる。また、機械学習モデル等による予測結果に基づいてユーザーへの情報提供を行う場合、モデルの解釈性が高いと有用である。解釈性の高いモデルにより、サービス提供者がなぜそのような予測結果となったのかを理解し、提供情報の内容の検討が可能となることが期待される。

以上より、本研究では偶然性希求行動を検索クエリから予測するモデルを提案する。提案手法では、偶然性希求行動に影響を与える因子も検索クエリから予測し、中間変数として導入することでモデルの解釈性を高める。このように解釈性向上を目的とした段階的予測を行う偶然性希求行動予測モデルと、検索クエリから直接予測するモデルの予測性能を比較し、有効性を検証する。

## 2 関連研究

### 2.1 「Beyond-Accuracy」の推薦システム

推薦システムは、オンラインショッピングサイトやニュースサイトなどで広く利用されている。これまで、推薦システムは、Recall@ $k$  のような、推薦リスト上位  $k$  件のうちに含まれる正解数に基づいて算出される指標などを用いて、ユーザーの行動履歴をできるだけ再現することを主眼に設計・評価されてきた。その結果、行動履歴に関連するアイテムを過度に推薦し、「過剰最適化」を招き得ることが指摘されている [1], [9]。この課題を解決するため、推薦リストの予測性能だけでなく、推薦の多様性や公平性などの指標を加えてシステムを評価する枠組みである「Beyond-Accuracy」が注目されている。多様性のある推薦

は、UX を豊かにし、ユーザーの視野を広げるのに寄与するとされている [10]。さらに、公平性のある推薦では、高齢者など特定の属性を有するユーザー群において性能が低下する、あるいは人気の低いアイテムが推薦されにくいといった偏りを防ぎ、より公正なユーザー体験の実現に寄与するとされている [11]。セレンディピティは、Beyond-Accuracy 指標の 1 つとして提案されており [4]、ユーザーが自力では発見しにくかった、興味対象を見つける手助けになると主張されている [12]。

推薦システム分野では、セレンディピティを推薦アイテムが備える属性として捉え、新規性、関連性、意外性のいずれか 1 つ、またはそれらの組み合わせとする定義が広く用いられてきた [2], [13]。新規性は、一般にユーザーに依存しない指標とされ、推薦時点で広く未知である可能性や想定外の程度を表し、評価数などから推定される人気度の低さに基づき算出される [14]。関連性は、ユーザーの興味・関心への適合度を表し、嗜好の予測値としてスコア化されることが多い [15]。意外性は、ユーザーが普段消費するアイテムとの非類似性や、予期していなかったアイテムを消費した際の満足度など、複数の観点から定義される。例えば、過去履歴に含まれるアイテムおよびそれらの類似アイテムから成る集合と、推薦候補アイテムとの距離に基づき算出する定義がある [16]。

しかし、これらの指標のうちどれがセレンディピティに不可欠であるか、また各指標をどのように測定すべきかについては、理論や手法が未だ確立されていない [6]。加えて、記事推薦を対象とした大規模フィールド調査では、これらの指標と、ユーザーが感じるセレンディピティとの間に乖離が存在することを報告している [6]。このことは、アイテム属性に加え、ユーザーの状況や主観に関わる要素を考慮した指標が必要であることを示唆する。

## 2.2 セレンディピティにおけるユーザーの心理的要因

認知科学を用いた研究 [7] では、オンラインショッピングの場面でユーザーがどの程度偶然性を求めるか、および、その傾向に影響を与える心理的要因に着目している。どの程度偶然性を求めて行動するかは「ユーザーが偶然の出会いを期待して行う (方略的) 行動」を意味する、偶然性希求行動で表される [7]。この指標が高いユーザーは、セレンディピティを強く求めていると考えられる。これまで偶然性希求行動に影響を与える心理的要因と製品属性として、それぞれ目標具体性と快楽次元が報告されている [8]。目標具体性は、ユーザーが検索時に「欲しい商品」をどの程度具体的に想起しているかを示す指標である。例えば車の購入を目的とした検索において、特定の車種名まで具体的に想起している場合は目標具体性が高く、コンパクトカーなどの大まかなカテゴリのみを想起している場合は目標具体性が低い。快楽次元とは、製品 (またはブランド) に対する消費者態度を構成する次元の一つであり、使用経験に伴う感覚的・情緒的反応に基づく快楽的な評価を表す概念である。測定には快楽尺度を用いる [17]。

実験の結果、目標具体性が高いほど偶然性希求行動が低くなり、探索対象の快楽次元が高いほど偶然性希求行動が高くなる

傾向が報告されている。一方で、ユーザーの目標具体性が低いほど、快楽次元が偶然性希求行動に与える影響がより大きくなることも確認されており、これらの変数は偶然性希求行動と密接に関連していることが報告されている。

## 3 提案手法

提案モデルの全体像を図 1 に示す。本研究では、実サービスでの利用を想定し、入力には検索クエリのみとする。提案モデルでは、モデルの解釈性を向上させるため、中間変数として、文献 [7], [8] により偶然性希求行動に影響することが確認されている、目標具体性と快楽次元 (2.2 節参照)、および、目標具体性の予測に有効と考えられる検索目標と検索クエリ間の関係性を表す「上位下位関係」および「属性関係」(4.1 節参照)を導入する。




図 1 提案モデルの全体像

### 3.1 中間変数予測

目標具体性の予測では、入力特徴量として検索クエリ、上位下位関係ラベル、属性関係ラベルを用いる。このとき、検索クエリのベクトルと各関係ラベルの予測値を連結して 1 つのベクトルを作成し、予測に用いる。具体的には、検索クエリは事前学習済み言語モデルでベクトル化し、上位下位関係ラベルと属性関係ラベルは、その検索クエリのベクトルのみで学習されたモデルの予測値を利用する。

快楽次元の予測に用いる入力特徴量は、関係ラベルの予測と同様に、検索クエリのベクトルのみである。全ての予測モデルは教師あり学習手法を用いて学習させる。

### 3.2 偶然性希求行動予測

偶然性希求行動の予測モデルは、図 1 で示す通り、検索クエリの埋め込みベクトル、目標具体性の予測値、快楽次元の予測値を入力特徴量として、教師あり学習手法を用いて学習させる。入力特徴量は、検索クエリのベクトルに対して、目標具体性と快楽次元の予測値を連結して作成する。

## 4 実験

### 4.1 データセット

本実験では、クラウドソーシング [8] により収集された 2,200 件の検索クエリデータを用いた (参加者は成人 200 名。平均年齢 42.1 歳, SD = 8.86, 女性 93 名, 男性 107 名)。このうち、検索クエリとして成立していない 4 件 (入力なし、または「なし」と入力) を除外し、2,196 件を提案手法の学習・検証・

テストに用いた。各検索クエリには、15種の関連情報が含まれており、本研究では以下に示すような検索クエリと3種類の関連情報を利用した。

**検索クエリ**：参加者に「あなたが今実際にオンラインショッピングを利用して購入したいと思っている製品を思い浮かべてください。」と質問し、想起した製品を検索するために入力するクエリを記述させた。

**快楽次元**：快楽尺度 [17] [18] を用いて、参加者が想起した製品に対する態度（快楽次元）を測定した。快楽尺度は意味的差異尺度であり、5組の形容詞対を7件法（例：「1：非常に面白くない」－「7：非常に面白い」）で評価させた。

**目標具体性**：参加者が想起した製品（質問文中では“X”として提示）について、「あなたが1つ目の製品“X”を思い浮かべたとき、買いたいものは具体的に決まっていたか？」と質問し、5件法（「1：全く決まっていなかった」－「5：非常に決まっていた」）で回答を得た。

**偶然性希求行動**：参加者に「これから、先ほどあなたが入力した検索語による検索結果に、どの程度「偶然性」を取り入れるかを設定していただきます。スライダーを用いて0から100まで、段階的に偶然性が高くなっていきます、あなたはどの程度、検索結果に偶然性を持たせたいですか？」と質問し、回答させた。

さらに本研究では、参加者から直接収集したデータに対して、訓練された第三者がアノテーションした上位下位関係ラベルおよび属性関係ラベルも用いた。各ラベルの定義は以下の通りである [19]。

- 上位下位関係ラベル：検索目標と検索クエリの関係性が概念的に上下関係であることを示す。具体的には、「単語Aが単語Bの上位語 (Hypernym) である」は、「B is a (kind of) A」が成立することに等しい。「単語Bが単語Aの下位語 (Hyponym) である」を考える場合も同様である。なお、「スポーツカー」などの複合名詞の場合も同様に、上位語もしくは下位語に相当すれば、上位下位関係とみなした。
- 属性関係ラベル：検索クエリが検索目標の属性（性質、特徴、構成要素など）に相当することを示す。例えば、検索目標が「車」、検索クエリが「車 カッコいい」である場合、「カッコいい」という単語が属性関係に該当する。

## 4.2 前処理

**検索クエリ**：日本語事前学習済みのBERT [20] (tohoku-nlp/bert-base-japanese) [21] およびRoBERTa [22] (nlp-waseda/roberta-base-japanese) [23] を用いて、クエリの埋め込みベクトルを取得した。具体的には、言語モデルによりクエリ中の各単語をそれぞれベクトル化し、pooling手法を利用することで、検索クエリ全体を表すベクトルを算出した。pooling手法には、[24]で高い性能が報告されている、CLS poolingとMean poolingを採用した。各pooling手法の詳細は次の通り [25], [26]。

**CLS** BERTの事前学習時に、次文予測に用いられる、[CLS]トークンの埋め込みを検索クエリ全体の埋め込みとして用

いる。RoBERTaの場合、[CLS]トークンが存在しないため、代替として、文頭トークンである<s>トークンの埋め込みを用いる。

**Mean** クエリ中の各単語の埋め込みベクトルを要素ごとに平均することにより、検索クエリ全体の埋め込みを算出する。本研究で扱うサンプルサイズは、2,196件であり、クラス数に依存して1クラスあたりのサンプル数が小さくなり、学習が困難になる。そこで、快楽次元、目標具体性、偶然性希求行動は、学習時にクラス間のサンプル数が均衡するように二値化を行い、1クラスあたりのサンプル数を確保した。詳細は以下の通りである。

**快楽次元・目標具体性**：快楽次元と目標具体性は、それぞれ7件法と5件法で参加者の回答を取得している。二値化するためにそれぞれの頻度分布を確認したところ、全2,196件のサンプルにおいて、快楽次元では、4以下の値が48.7% (1,070件)と4より大きい値が51.3% (1,126件)であり、目標具体性では、2以下の値が48.4% (1,062件)と2より大きい値が51.6% (1,134件)である。これらの統計量に基づいて、本研究では、快楽次元の4以下の値を「低」、4より大きい値を「高」とし、また目標具体性の2以下の値を「低」、2より大きい値を「高」と定義した。

**偶然性希求行動**：0から100の整数値で取得された回答を、回答値が55以下を「低」、56以上を「高」として二値化した。各クラスの割合は、「低」が50.6% (1,111件)と「高」が49.4% (1,085件)である。

本データ取得は、名古屋大学倫理審査委員会およびトヨタ自動車株式会社の倫理審査 (2024TMC246) において厳正な審査を受け、倫理的配慮が適切に確保されたうえで実施した。

## 4.3 実験設定

本研究では、3章で述べた提案手法の有効性を検証するため、ベースライン手法と比較する。中間変数の導入による段階的な予測に対して、ベースライン手法では、検索クエリから直接、偶然性希求行動を予測した。

提案手法の学習は、3章で述べた通りに実行した。それぞれの予測モデルには、全てLightGBM [27]を用いて、二値分類問題として学習した。LightGBMは、表形式データを入力とする二値分類タスクで広く用いられ、高い予測性能と計算効率が報告されているため、採用した。中間変数を用いて学習する予測モデルでは、陽性ラベルの予測確率を用いており、入力特徴量の該当要素は0から1の間の実数値である。また、モデルのハイパーパラメータはOptuna [28]によりチューニングした。二値分類問題であることを考慮して、性能指標には、二重交差エントロピーを使用した。

ハイパーパラメータチューニングとモデルの性能評価は、二重交差検証 [29], [30]により実施した。本検証法は、汎化性能とモデル選択の評価を厳密に行うため、外側と内側の検証ループを組合せ、二重に交差検証を行う手法である。本研究では、外側・内側ともに $K=5$ のStratified K-Fold Cross Validationを用い、クラス比率を維持した分割を行った。具体的な学習・

評価フローを次に示す。

1. 全データを外側の交差検証用に 5 個のセットに分割した。各セットは、1 つを外側テスト用セット、残りを外側学習用セットとした。外側テスト用セットは最終的な性能評価のみに使い、モデル選択には用いない
2. 外側学習用セットをさらに 5 個のセットに分割し、内側検証用セットと、内側学習用セットを作成した。内側ループでは、候補となるハイパーパラメータ群に対して性能指標（二値交差エントロピー）を算出し、Optuna により最適なハイパーパラメータを選択した
3. 内側ループで選択されたハイパーパラメータを用いて、外側学習セット全体でモデルを再学習した
4. 外側テストセットに対して予測を行い、各評価指標のスコアを算出した。これを外側ループの各分割で繰り返すことで、モデルの予測性能を評価した。

#### 4.4 実験結果

モデルの性能は、Accuracy, Precision, Recall, F1-score を用いて評価し、それぞれについて 5-Fold の平均値と標準偏差を算出した。結果を表 1 に示す。表中の括弧内は標準偏差、太字は同一言語モデルおよび Pooling 手法内でベースラインと提案手法を比較した際の、各指標の最良値を示す。

まず、表 1 の太字で示すように、各条件に対してベースライン手法と提案手法を比較すると、提案手法が優れていることがわかる。具体的には、4 つの評価指標、2 つの言語モデル、2 つの Pooling 手法の組合せによる 16 ( $4 \times 2 \times 2$ ) 通りの比較のうち、14 通りで提案手法が優位な結果である。また、全ての評価指標において、最良値を示したのは、CLS pooling と RoBERTa モデルを用いた提案手法 (Accuracy=0.598, Precision=0.593, Recall=0.594, F1-Score=0.593) であった。このことから、中間変数の予測値を導入した段階的予測が、予測性能の向上に寄与することが確認された。

## 5 考 察

### 5.1 モデル構造

提案手法はベースライン手法と比較して性能が向上しており、この結果は、本研究で導入した中間変数が偶然性希求行動の予測に有用であることを示している。段階的なモデル構造の有用性は、複雑な推論を中間ステップへ分解することで推論を助けるという観点で、大規模言語モデルにおけるプロンプトエンジニアリング手法の 1 つである Chain-of-Thought [31] 研究の主張と類似している。実際、本研究でも事前学習済みの大規模言語モデルを用いており、段階的な推論フローが有効に働いた可能性がある。

一方で、提案手法では中間変数に真値ではなく予測値を用いた。そのため、中間変数の予測性能が後段の予測性能を制約し得る。提案手法の限界性能を確認するため、中間変数に真値を与える条件に変更し、同様に実験した。実験結果を表 2 に示す。真値を用いた場合は予測値を用いた場合に比べて Accuracy,

Precision, F1-Score では約 1%, Recall では 2% の改善にとどまった。つまり、中間変数が予測値であっても提案手法は限界性能に近い水準の性能を示していると解釈できる。

次に、その理由を検討するため、中間変数そのものの予測性能を確認する。提案手法において最良の結果を示した条件 (CLS pooling を用いた RoBERTa) における Accuracy を表 3 に示す。本実験では、クラス分布の偏りが小さいため、チャンスレベル (50%) との比較が直観的である Accuracy を用いた。目標具体性および快楽次元はいずれも 65% を下回り、二値分類問題として十分な予測性能とは言い難い。にもかかわらず、偶然性希求行動予測における、中間変数に予測値を用いた場合と真値を用いた場合との性能差は 1.1% 程度にとどまる。このことは、提案手法の限界性能に近い性能は、中間変数の予測性能そのものよりも、段階的予測を行うモデル構造に起因している可能性を示唆している。

### 5.2 言語モデルと pooling 手法

表 1 より、提案手法における F1-Score の最良値は、Mean pooling を用いた BERT で 0.577, CLS pooling を用いた RoBERTa で 0.593 であり、RoBERTa を用いた条件の方が高い性能を示した。このことは、RoBERTa が BERT と同一構造でありながらも、Next Sentence Prediction の除去や動的マスキング等で事前学習レシピを最適化している点と整合的である。すなわち、検索クエリのような短い入力に対してもロバストな表現を得やすい性質が、提案手法の性能に有利に働いた可能性がある。

次に Pooling 手法の影響を確認する。表 1 より、Pooling 手法以外の条件を同一にして比較したとき (例えば、BERT を用いたベースライン)、一貫性を確認できなかった (RoBERTa を用いた提案手法では CLS が良く、それ以外の条件では Meanの方が優れていた)。Mean pooling は、ベクトルの単純な要素平均による情報圧縮手法であるため、検索クエリの長さに依存せず安定した情報の集約が可能であるが、重要語も非重要語も等しく集約する。一方で、CLS pooling は、次文予測のためにトークンがもつ意味単位で情報を圧縮する手法であり、Mean pooling と比較して、短文における重要語を強調して集約する。検索クエリのような短文において、CLS pooling が優位でなかったのは、検索クエリの質が低かったことが考えられる。例えば、商品名が「ベビー綿棒」で、検索クエリが「抗菌」のみ、となっているサンプルがあり、ユーザーの意図を正しく反映する検索クエリを取得できていないことが示唆される。

### 5.3 解釈性

本研究では、検索クエリから偶然性希求行動を予測するにあたり、解釈性の向上を目的として中間変数を導入したモデルを提案した。そこで、提案手法で学習したモデルが、実際にどの特徴量に基づいて予測しているのかを分析し、解釈性の観点から妥当性を検討する。解釈性の検証には、Shapley Additive Explanations (SHAP) [32] による、特徴量が予測値へ与える寄与度 (SHAP 値) を用いる。SHAP 値は、一般的に、絶対

表 1 偶然性希求行動の予測結果

言語モデル	Pooling	手法	Accuracy	Precision	Recall	F1-Score
BERT	CLS	ベースライン	0.528 (0.025)	0.523 (0.025)	0.545 (0.008)	0.533 (0.016)
		提案手法	<b>0.536 (0.027)</b>	<b>0.530 (0.027)</b>	<b>0.547 (0.023)</b>	<b>0.538 (0.024)</b>
	Mean	ベースライン	0.567 (0.024)	0.562 (0.025)	0.571 (0.031)	0.566 (0.023)
		提案手法	<b>0.572 (0.025)</b>	<b>0.564 (0.025)</b>	<b>0.592 (0.025)</b>	<b>0.577 (0.022)</b>
RoBERTa	CLS	ベースライン	0.554 (0.013)	0.547 (0.013)	0.569 (0.008)	0.558 (0.009)
		提案手法	<b>0.598 (0.025)</b>	<b>0.593 (0.025)</b>	<b>0.594 (0.036)</b>	<b>0.593 (0.027)</b>
	Mean	ベースライン	0.563 (0.032)	0.554 (0.030)	<b>0.587 (0.035)</b>	<b>0.570 (0.032)</b>
		提案手法	<b>0.566 (0.027)</b>	<b>0.560 (0.028)</b>	0.575 (0.034)	0.567 (0.026)

表 2 提案手法における中間変数の条件を変えた際の偶然性希求行動の予測結果

言語モデル	Pooling	中間変数	Accuracy	Precision	Recall	F1-Score
BERT	CLS	予測値	0.536 (0.027)	0.530 (0.027)	0.547 (0.023)	0.538 (0.024)
		真値	<b>0.593 (0.027)</b>	<b>0.585 (0.027)</b>	<b>0.609 (0.037)</b>	<b>0.596 (0.029)</b>
	Mean	予測値	0.572 (0.025)	0.564 (0.025)	0.592 (0.025)	0.577 (0.022)
		真値	<b>0.602 (0.025)</b>	<b>0.595 (0.027)</b>	<b>0.614 (0.037)</b>	<b>0.604 (0.025)</b>
RoBERTa	CLS	予測値	0.598 (0.025)	0.593 (0.025)	0.594 (0.036)	0.593 (0.027)
		真値	<b>0.609 (0.024)</b>	<b>0.604 (0.026)</b>	<b>0.610 (0.029)</b>	<b>0.607 (0.022)</b>
	Mean	予測値	0.566 (0.027)	0.560 (0.028)	0.575 (0.034)	0.567 (0.026)
		真値	<b>0.595 (0.023)</b>	<b>0.590 (0.022)</b>	<b>0.592 (0.033)</b>	<b>0.591 (0.025)</b>

表 3 RoBERTa かつ CLS pooling 条件における中間変数の Accuracy

目標具体性	快樂次元
0.636 (0.016)	0.641 (0.017)

値が大きいほど予測値への影響が大きいことを意味する。

全サンプルに対して特徴量（770 次元）ごとに SHAP 値を算出し、その絶対値を平均した値を算出した。図 2 に、その値が大きい上位 10 個の特徴量を降順に示す。ここで、数字で表記された特徴量は、検索クエリベクトルにおける該当次元番号である。

まず、中間変数のうち目標具体性（図中、purpose）は予測への影響が最も大きく、2 番目に大きい特徴量（図中、714；検索クエリベクトルの 714 番目の要素）と比較して、約 4 倍の影響度であった。一方で、もう 1 つの中間変数である快樂変数は、上位 10 個に含まれず、影響度は全体の 513 位であった。つまり、提案手法は、偶然性希求行動を主に目標具体性で説明するモデルと言える。この傾向は、[7] の結果とも整合する。

## 6 おわりに

本研究では、偶然性希求行動を検索クエリから予測する解釈性の高いモデルを提案した。提案モデルは、検索クエリのみを入力とし、目標具体性と快樂次元を中間変数とする、人の思考過程に基づくモデル構造である。検索クエリから直接予測を行うベースラインと比較して、多くの条件において評価指標の 4 項目すべてで同等または優れた性能を示した。この結果は、中間変数の導入がもたらした効果によるものであると考えられる。5.1 節の考察で示した通り、中間変数を組み込み、段階的に予測を行うモデル構造は、大規模言語モデル分野におけるプロン




図 2 RoBERTa (CLS) を用いた提案手法における Shapley 値の Summary Plot（縦軸中の数字はベクトルの要素番号）

プトエンジニアリング手法と類似した推論フローを有しており、その構造自体が中間変数の予測性能よりも重要であることが確認された。

今後の展望は 2 つある。1 つは被験者実験の実施である。本研究では、オンラインショッピングを想定した仮想的な設定のもとでアンケートを通じて収集されたデータを使用した。今後は、実サービスへの応用を見据え、提案手法による予測結果に基づいて実験的に推薦システムを制御し、使用時における行動データやユーザー満足度により効果を検証する必要がある。

2 つ目は学習データの拡充と質向上である。今回使用した約 2,200 件のデータは、アンケートにより、検索クエリと同時に検索対象も取得したが、その際、両者の対応関係が不明瞭で（例えば、検索対象に「ベビー綿棒」と記し、検索クエリには「抗菌」のみを記すなど）、実験意図の理解が十分でない可能性があるサンプルも含まれていた。今後はデータ量を増やすと共

に、不適切なサンプルを除去する前処理を行い、より信頼性の高いデータを用いて学習することで、予測性能のさらなる向上を図る。

## 文 献

- [1] Panagiotis Adamopoulos and Alexander Tuzhilin. On over-specialization and concentration bias of recommendations. *Proceedings of the 8th ACM Conference on Recommender systems*, pp. 153–160, 10 2014.
- [2] Denis Kotkov, Shuaiqiang Wang, and Jari Veijalainen. A survey of serendipity in recommender systems. *Knowledge-Based Systems*, Vol. 111, pp. 180–192, 2016.
- [3] Tien T. Nguyen, Pik-Mai Hui, F. Maxwell Harper, Loren Terveen, and Joseph A. Konstan. Exploring the filter bubble: the effect of using recommender systems on content diversity. In *Proceedings of the 23rd International Conference on World Wide Web, WWW '14*, p. 677–686, New York, NY, USA, 2014. Association for Computing Machinery.
- [4] Mouzhi Ge, Carla Delgado-Battenfeld, and Dietmar Jannach. Beyond accuracy: evaluating recommender systems by coverage and serendipity. In *Proceedings of the Fourth ACM Conference on Recommender Systems, RecSys '10*, p. 257–260, New York, NY, USA, 2010. Association for Computing Machinery.
- [5] Li Chen, Yonghua Yang, Ningxia Wang, Keping Yang, and Quan Yuan. How serendipity improves user satisfaction with recommendations? a large-scale user evaluation. In *The World Wide Web Conference, WWW '19*, p. 240–250, New York, NY, USA, 2019. Association for Computing Machinery.
- [6] Denis Kotkov, Alan Medlar, Triin Kask, and Dorota Glowacka. The dark matter of serendipity in recommender systems. In *Proceedings of the 2024 Conference on Human Information Interaction and Retrieval, CHIIR '24*, p. 108–118, New York, NY, USA, 2024. Association for Computing Machinery.
- [7] Yuki Ninomiya, Yutaro Sone, Kazuhisa Miwa, Yuichiro Sumi, Ryosuke Nakanishi, Eiji Mitsuda, Koji Sato, and Tadashi Odashima. Determinants of users' chance-seeking behavior in search-based recommendation. In *Proceedings of the Nineteenth ACM Conference on Recommender Systems, RecSys '25*, p. 564–569, New York, NY, USA, 2025. Association for Computing Machinery.
- [8] 曾根悠太郎, 二宮由樹, 三輪和久, 鷺見優一郎, 中西亮輔, 光田英司, 佐藤浩司, 小田島正. 製品の快楽・功利次元と偶然性希求行動の関連. 2025年度日本認知科学会第42回大会, 2025.
- [9] Zeinab Abbassi, Sihem Amer-Yahia, Laks V.S. Lakshmanan, Sergei Vassilvitskii, and Cong Yu. Getting recommender systems to think outside the box. In *Proceedings of the Third ACM Conference on Recommender Systems, RecSys '09*, p. 285–288, New York, NY, USA, 2009. Association for Computing Machinery.
- [10] Pablo Castells, Neil J. Hurley, and Saul Vargas. *Novelty and Diversity in Recommender Systems*, pp. 881–918. Springer US, Boston, MA, 2015.
- [11] Yifan Wang, Weizhi Ma, Min Zhang, Yiqun Liu, and Shaoping Ma. A survey on the fairness of recommender systems. *ACM Trans. Inf. Syst.*, Vol. 41, No. 3, February 2023.
- [12] Jonathan L. Herlocker, Joseph A. Konstan, Loren G. Terveen, and John T. Riedl. Evaluating collaborative filtering recommender systems. *ACM Trans. Inf. Syst.*, Vol. 22, No. 1, p. 5–53, January 2004.
- [13] Denis Kotkov, Joseph A. Konstan, Qian Zhao, and Jari Veijalainen. Investigating serendipity in recommender systems based on real user feedback. In *Proceedings of the 33rd Annual ACM Symposium on Applied Computing, SAC '18*, p. 1341–1350, New York, NY, USA, 2018. Association for Computing Machinery.
- [14] Marius Kaminskis and Derek Bridge. Diversity, serendipity, novelty, and coverage: A survey and empirical analysis of beyond-accuracy objectives in recommender systems. *ACM Trans. Interact. Intell. Syst.*, Vol. 7, No. 1, December 2016.
- [15] Michael D. Ekstrand, John T. Riedl, and Joseph A. Konstan. Collaborative filtering recommender systems. *Foundations and Trends® in Human-Computer Interaction*, Vol. 4, No. 2, pp. 81–173, 2011.
- [16] Panagiotis Adamopoulos and Alexander Tuzhilin. On unexpectedness in recommender systems: Or how to better expect the unexpected. *ACM Trans. Intell. Syst. Technol.*, Vol. 5, No. 4, December 2014.
- [17] Kevin E. Voss, Eric R. Spangenberg, and Bianca Grohmann. Measuring the hedonic and utilitarian dimensions of consumer attitude. *Journal of Marketing Research*, Vol. 40, No. 3, pp. 310–320, 2003.
- [18] 岡田庄生, 西川英彦. 消費者の功利主義的・快楽主義的モノづくり動機と, 製品成果・公開. マーケティングジャーナル, Vol. 39, No. 1, pp. 75–87, 2019.
- [19] 中西亮輔, 鈴木結友, 鷺見優一郎, 光田英司, 二宮由樹, 曾根悠太郎, 三輪和久. プロンプト最適化を用いた検索クエリと検索目標の関係性アノテーション. 第266回自然言語処理研究発表会, 2025.
- [20] Jacob Devlin, Ming-Wei Chang, Kenton Lee, and Kristina Toutanova. BERT: Pre-training of deep bidirectional transformers for language understanding. In Jill Burstein, Christy Doran, and Thamar Solorio, editors, *Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, Volume 1 (Long and Short Papers)*, pp. 4171–4186, Minneapolis, Minnesota, June 2019. Association for Computational Linguistics.
- [21] 東北大学自然言語処理研究グループ. tohoku-nlp/bert-base-japanese, 2020. <https://huggingface.co/tohoku-nlp/bert-base-japanese> [アクセス日: (2025年10月20日)].
- [22] Yinhan Liu, Myle Ott, Naman Goyal, Jingfei Du, Mandar Joshi, Danqi Chen, Omer Levy, Mike Lewis, Luke Zettlemoyer, and Veselin Stoyanov. Roberta: A robustly optimized bert pretraining approach, 2019.
- [23] 早稲田大学河原研究室. nlp-waseda/roberta-base-japanese, 2022. <https://huggingface.co/nlp-waseda/roberta-base-japanese> [アクセス日: (2025年10月20日)].
- [24] Nils Reimers and Iryna Gurevych. Sentence-bert: Sentence embeddings using siamese bert-networks. *CoRR*, Vol. abs/1908.10084, , 2019.
- [25] 塚越駿, 笹野遼平, 武田浩一. 定義文を用いた文理め込み構成法. 言語処理学会第27回年次大会発表論文集, 2021.
- [26] 原知正, 栗田宙人, 横井祥, 乾健太郎. 平均プーリングによる文理め込みの再検討: 平均は点群の要約として十分か? 言語処理学会第30回年次大会発表論文集, 2024.
- [27] Guolin Ke, Qi Meng, Thomas Finley, Taifeng Wang, Wei Chen, Weidong Ma, Qiwei Ye, and Tie-Yan Liu. Lightgbm: a highly efficient gradient boosting decision tree. In *Proceedings of the 31st International Conference on Neural Information Processing Systems, NIPS'17*, p. 3149–3157, Red Hook, NY, USA, 2017. Curran Associates Inc.
- [28] Takuya Akiba, Shotaro Sano, Toshihiko Yanase, Takeru Ohta, and Masanori Koyama. Optuna: A next-generation hyperparameter optimization framework. In *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 2019.
- [29] Sudhir Varma and Richard Simon. Bias in error estimation when using cross-validation for model selection. *BMC bioinformatics*, Vol. 7, No. 1, p. 91, 2006.
- [30] Gavin C Cawley and Nicola LC Talbot. On over-fitting in model selection and subsequent selection bias in perfor-

mance evaluation. *The Journal of Machine Learning Research*, Vol. 11, pp. 2079–2107, 2010.

- [31] Jason Wei, Xuezhi Wang, Dale Schuurmans, Maarten Bosma, Fei Xia, Ed Chi, Quoc V Le, Denny Zhou, et al. Chain-of-thought prompting elicits reasoning in large language models. *Advances in neural information processing systems*, Vol. 35, pp. 24824–24837, 2022.
- [32] Scott M. Lundberg and Su-In Lee. A unified approach to interpreting model predictions. In *Proceedings of the 31st International Conference on Neural Information Processing Systems, NIPS'17*, p. 4768–4777, Red Hook, NY, USA, 2017. Curran Associates Inc.

## 付 録

### 1 中間変数予測結果

快樂次元の予測結果を表 A.1 に、上位下位および属性関係ラベルの予測結果を表 A.2 に、目標具体性の予測結果を表 A.3 示す。

表 A.1 快樂次元の予測結果

言語モデル	Pooling	Accuracy	Precision	Recall	F1-Score
BERT	CLS	0.619 (0.011)	0.634 (0.017)	0.611 (0.031)	0.622 (0.014)
	Mean	0.637 (0.011)	0.650(0.013)	<b>0.655 (0.032)</b>	<b>0.657 (0.018)</b>
RoBERTa	CLS	0.641 (0.017)	0.653 (0.019)	0.641 (0.011)	0.647 (0.014)
	Mean	<b>0.653 (0.032)</b>	<b>0.665 (0.029)</b>	0.647 (0.043)	0.656 (0.035)

表 A.2 上位下位/属性関係ラベルの予測結果

	言語モデル	Pooling	Accuracy	Precision	Recall	F1-Score
上位下位	BERT	CLS	0.634 (0.062)	0.328 (0.043)	0.414 (0.134)	0.344 (0.059)
		Mean	0.638 (0.055)	0.337 (0.042)	0.444 (0.124)	0.367 (0.051)
	RoBERTa	CLS	0.623 (0.060)	0.332 (0.045)	<b>0.475 (0.146)</b>	0.371 (0.054)
		Mean	<b>0.657 (0.056)</b>	<b>0.363 (0.058)</b>	0.444 (0.140)	<b>0.375 (0.065)</b>
属性	BERT	CLS	0.885 (0.011)	<b>0.970 (0.007)</b>	0.899 (0.010)	0.933 (0.007)
		Mean	0.895 (0.013)	0.966 (0.005)	0.915 (0.015)	0.940 (0.008)
	RoBERTa	CLS	<b>0.920 (0.013)</b>	0.969 (0.006)	<b>0.940 (0.014)</b>	<b>0.954 (0.008)</b>
		Mean	0.903 (0.006)	0.966 (0.012)	0.925 (0.007)	0.945 (0.004)

表 A.3 目標具体性の予測結果

	言語モデル	Pooling	Accuracy	Precision	Recall	F1-Score
提案手法	BERT	CLS	0.619 (0.015)	0.643 (0.019)	0.592 (0.047)	0.615 (0.026)
		Mean	<b>0.637 (0.011)</b>	<b>0.657 (0.026)</b>	0.628 (0.038)	0.641 (0.011)
	RoBERTa	CLS	0.636 (0.016)	0.649 (0.020)	<b>0.647 (0.026)</b>	<b>0.647 (0.015)</b>
		Mean	0.617 (0.010)	0.637 (0.010)	0.599 (0.033)	0.617 (0.018)
中間変数が真値	BERT	CLS	0.613 (0.017)	0.635 (0.018)	0.591 (0.044)	0.611 (0.026)
		Mean	<b>0.643 (0.018)</b>	<b>0.659 (0.025)</b>	<b>0.642 (0.011)</b>	<b>0.650 (0.011)</b>
	RoBERTa	CLS	0.622 (0.012)	0.644 (0.018)	0.601 (0.024)	0.622 (0.011)
		Mean	0.625 (0.012)	0.644 (0.015)	0.615 (0.035)	0.628 (0.018)
ベースライン	BERT	CLS	0.616 (0.019)	0.638 (0.020)	0.594 (0.039)	0.615 (0.025)
		Mean	<b>0.638 (0.022)</b>	<b>0.661 (0.025)</b>	0.617 (0.030)	0.638 (0.022)
	RoBERTa	CLS	0.624 (0.024)	0.643 (0.027)	0.615 (0.023)	0.628 (0.022)
		Mean	0.637 (0.017)	0.656 (0.018)	<b>0.624 (0.029)</b>	<b>0.640 (0.019)</b>