

動画閲覧時の動作特性によるタスクタイプの分類と動画推薦

井出 達郎[†]細部 博史[‡]法政大学情報科学部[†]法政大学情報科学部[‡]

1. はじめに

YouTube は、現存する最大規模で最も洗練された産業推薦システムの 1 つであり、ユーザにとって有用な情報のリソースである。YouTube 上での動画探索において、同じユーザであっても、状態によって心に抱いている目標は異なる。しかし、現状はユーザのその時々状態に関係なく、動画の関連度や過去の視聴履歴から動画が推薦されていると推測される。

Athukorala ら [1]は、Google Scholar のようなインタフェースを有する論文検索エンジンにおいて、調査か探査かの 2 つのタスクタイプを分類し、動作特性として、クエリの長さ、読み取り時間、累積クリック数を利用した。これらを基にしたパラメータによってタスクタイプを判定する分類器を構築した。

本研究では動画閲覧時の動作特性によるタスクタイプの分類とタスクタイプ毎の動画推薦を提案する。動作から読み取れる動的なユーザの目的をタスクタイプとして分類することで、その目的に沿った高次の推薦をすることが狙いである。YouTube を模したモバイルアプリケーション上で暗黙に記録したユーザの動作によるパラメータを基にタスクタイプの判定をして、関連動画表示で動画推薦を行う。

2. 準備

本研究では、決定木の生成に機械学習ソフトウェア Weka [2]を利用する。Weka の有する機械学習アルゴリズムの中で分類学習のアルゴリズムを本研究では利用する。データセットは ARFF 形式という専用の形式で用意し、パラメータとしてクエリの長さ、読み取り時間、スクロール深度、タスクタイプを記述する。決定木を生成するアルゴリズムと検定の種類を選択して実行すると結果を出力する。出力結果からは、分類の精度や決定木の木構造表現を確認することができる。

3. 提案手法

本研究では、ユーザの動作特性から読み取れる動的なユーザの目的をタスクタイプとして分類し、推薦に応用する。タスクタイプは Athukorala らの論文 [1]をもとに定義する。この論文では、論文検索において調査と探査の 2 つのタスクタイプを定義した。本研究では動画探索時

について定義するため、これに周回を加えて以下の 3 つを定める。

- 調査：あらかじめ探す動画が決まっているタスク。ユーザは特定の動画を目標として検索する。
- 探査：探す動画が決まっていないタスク。ユーザは興味や関心から、幅広いコンテンツを検索する。
- 周回：同じようなコンテンツを繰り返し見るタスク。

動作特性とは、瞬間的なユーザの特徴を表す行動のことである。本研究では、以下の 3 つの動作特性を記録し、パラメータとして利用した。

1. クエリの長さ：最初の検索セッションでのクエリに入力した単語数。スペース区切りで数える。
2. 画面スクロール深度：動画リストのビューを上下にスクロールした深さ。
3. 読み取り時間：最初の動画を見始めるまでの時間。

提案手法は主に UI、分類器、推薦の 3 段階からなる。UI は動画閲覧時のユーザの動作を記録するものであり、YouTube クライアントアプリケーションとして実現する。これは YouTube mobile のものほとんど変わらないが、暗黙に動作の記録を行う。これらの動作からパラメータを抽出し、分類器に渡す。分類器はパラメータを受け取ってタスクタイプを判定する。タスクタイプによって動画検索にフィルタを掛ける形で推薦を行う。

3.1. 分類器のパラメータ設定

本研究では、動作特性のパラメータ選定に Weka を用いる。データセットとして本アプリケーション上でタスクを著者の 1 人に課すことで得たデータを利用した。課したタスクは、調査タスク 6 個、探査タスク 6 個、周回タスク 6 個の合計 18 タスクである。調査タスクでは、思いついた特定の動画を探査した。探査タスクでは、カテゴリを決めて探査した。周回タスクでは、日常的に確認している動画群を探査した。このデータセットを入力データとして、機械学習アルゴリズムには C4.5 [3]に基づいた決定木を生成する J48 を選択した。学習データのために交差検証を用いて、生成された決定木は図 1 である。最初のノードでクエリの長さによって分岐し、次のノードでスクロール深度によって分岐する。葉ノードの lookup, exploration, repeat はそれぞれ調査、探査、周回を表す。例えば、クエリの長さが 2 でスクロール深度が 14 であれば調査タスクと判定される。

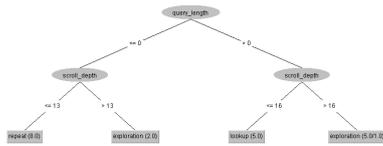


図1 自身の操作記録に基づいたタスクタイプの決定木

3.2. 推薦

分類器によって判定されたタスクタイプによって、検索パラメータを変更する。タスクタイプを探索と判定すると、関連動画表示に興味のあるカテゴリの動画を追加する。調査と判定すると、関連動画に登録チャンネルの新作動画やライブストリーミングを特別に表示せず、動画の関連度の高い順に表示する。周回と判定すると、動画の関連度と関係なしに、関心の高い登録チャンネルの新作動画を関連動画表示に追加する。

4. 実験

この実験の目的は、動作特性によるタスクタイプの動的な分類と推薦の評価をすることである。以下では、分類器が有効なシステムをフルシステムと呼び、分類器を有効にしないシステムのをベースラインシステムと呼ぶ。

参加者は4名で、平均年齢は22.3歳、日常的に何らかの用途でYouTubeを利用している。YouTubeの各タブを疑似的に再現するために、事前アンケートを行った。

4.1. 設計

被験者1人当たり調査タスクを1タスク、探索タスク、周回タスクをそれぞれのフルシステム、ベースラインシステムで行うため4タスク、合計5タスクをこなしてもらう。順序効果避けるためにタスクの順番はバランスをとる。各タスクでシチュエーションを設定する。

調査タスクは実験の2時間前に見てもらった動画を探してもらう。探索タスクは、事前アンケートに興味はあるが知識はあまりない分野をいくつか答えてもらったうえで、適切なものを選択し、自由に調べてもらう。表1はカテゴリと参加者の対応を示す。周回タスクは、日常的に見ている動画群を事前に答えてもらい、いつも通りに利用してもらう。探索タスク2つと周回タスク2つがそれぞれ終わったタイミングで前後のシステムの関連動画表示について質問をする。フルシステムとベースラインシステムで順番を実験者によって変える。

表1 実験用に選んだ検索トピック

| 参加者 | 検索トピック |
|-----|--------|
| 1 | 映画とアニメ |
| 2 | 科学と技術 |
| 3 | 音楽 |
| 4 | 映画とアニメ |

4.2. ユーザの評価

タスク全体を通して、関連動画表示の差異に気付かなかったと答える参加者が多かった。関連動画表示に目的

と全く異なる動画表示が出ていることに気付いたという声があった(参加者3)。これは本来のタスクと異なるタスクで判定されたために、関連動画表示に目的と全く関係のない動画が含まれていたためである。他にも、同じ動画が繰り返し表示されたと答えた参加者もいた(参加者4)。これも推薦として関連動画表示に追加された動画に違和感を覚えたための回答である。

4.3. 分類器の精度

参加者1人当たり5タスクで、4人に取り組んでもらったため、合計20タスクについて精度を計算した。20タスクのうち正しく判定できたのは10タスクで精度は50%であった。このうち、調査タスクは4タスクで、2タスク正しく判定できた(50%)。探索タスクは8タスク中8タスクが正しく判定されたため100%。周回タスクは全体で一度も判定されなかったため0%となった。また、周回タスクの8タスクのうち7タスクが探索タスクと誤って判定された。

5. 議論

実験により、調査タスクと探索タスクについては、一定程度の精度で分類できることが分かった。一方で周回タスクに分類されるようなケースはなかったこと、全体的に探索タスクと判定されることが多かったことから、偏った結果になったといえる。まず考えられる原因は、決定木生成のために用意したデータが著者の1人にタスクを課したもののみであったことである。著者自身にタスクを課して動作を記録した際には、全体的にスクロール深度が小さく、これに対して実験の参加者のスクロール深度は全体的に大きかった。この差は、著者自身の各タスクに対する先入観や実験の参加者数が少ないことによって生まれたように考えられる。この問題に対しては、システムに組み込む決定木を生成するデータを得るために予備実験をする、本実験数を増やす等、データの偏りに配慮する必要がある。

6. おわりに

動的にユーザのタスクタイプを分類するために動作特性によるパラメータを記録し、決定木によって分析した。参考論文[1]のようにスクロール深度を採用せずにブックマークなどで暗黙に検索結果リストを評価する等、評価手法の改良が今後の課題である。

文 献

[1] K. Athukorala, A. Medlar, A. Oulasvirta, G. Jacucci and D. Glowacka, "Beyond Relevance: Adapting Exploration/Exploitation in Information Retrieval," *Proc. ACM IUI*, pp. 359-369, 2016.

[2] I. H. Witten, E. Frank, *Data Mining: Practical Machine Learning Tools and Techniques*, San Francisco: Morgan Kaufmann, 2005.

[3] J. Quinlan, *C4.5: Programs for Machine Learning*, Los Altos, California: Morgan Kaufmann, 1993.