

ミュージカル映画を対象とした 感性計量による映画推薦システムの実現 —映画鑑賞で用いられる意味空間の世界—

飯島 萌子[†] 清木 康[‡] 佐々木 史織[‡]

[†]慶應義塾大学環境情報学部 〒252-0805 神奈川県藤沢市遠藤 5322

[‡]慶應義塾大学政策・メディア研究科 〒252-0805 神奈川県藤沢市遠藤 5322

E-mail: † {t16046mi,kiyoki,sashiori}@sfc.keio.ac.jp

あらまし ひととは個々の映画について、個人に特有の感性を用いてあらゆる事象を認識している。本方式は、ひとが映画を好むポイントに着目し、意味の数学モデルを利用して映画に関する感性空間を定義する。本方式は、生成した感性空間は絵画に関しても適合すると仮定し、同空間上に映画と絵画を射影して感性的距離を計量する。本方式は、映画関連キーワードを用いた検索と、絵画を用いた検索を組み合わせたシステムである。本方式では、個々の感性に添った最適なミュージカル映画を推薦することで、感性を切り口にした新しいユーザーエクスペリエンス (UX) を提供する。

キーワード 感性計量, 意味の数学モデル, 空間データベース, 情報推薦, 検索システム

第1章 はじめに

1.1. 研究のきっかけ

激動の 2010 年代に最も輝いた米国株は、動画配信サービスを手掛ける米ネットフリックスらしい。日本経済新聞が米主要 500 社の株価騰落率を算出したところ、2009 年度末比で 41.8 倍と、上昇率首位になった。

[1]

ネットフリックスは定額制見放題の動画配信サービスで、パーソナライズされたレコメンド機能を有する。アルゴリズムは、利用者がどの作品をどこまで再生したか、といった分析を繰り返し、個人の好みにあった動画を推薦する。[2]

レコメンド機能は、利用者が次に見る作品を悩むことなく見つけられるようにサポートしてくれる点で、見たいものははっきりしていないときに特に便利なサービスである。

そもそも、ネットフリックスで視聴されている作品の 80%以上がレコメンド機能を通じて選ばれている [3]ことから、利用者は次に見る作品を探すときに「これが見たい」とはっきり自覚していないことの方が多いと考えられる。

一方で、既存の映画検索サービスは、利用者が次に見たい作品をはっきり自覚していることを前提に作られている。

本研究は、「これが見たい」とはっきり自覚していない利用者を対象とする映画検索サービスが必要だ、と考えたことから始まった。

1.2. 研究の目的

パーソナライズされたレコメンド機能をつくる上

で悩まされるのが、利用者の嗜好の不安定さである。

感性は個人に特有の概念であり、人的経験や知的経験、対象への思考の深さによって複雑に形づくられる。

ネットフリックスを始めとする協調フィルタリングのレコメンド機能は、利用者の視聴履歴をもとに、一人ひとりの嗜好を判断する。つまり、このレコメンド機能のベースにあるのは、利用者の嗜好は視聴傾向に基づいて推測できるという考えだ。

しかしながら、視聴履歴が似ているからといって、映画に対する嗜好が似ているとは限らない。

本研究は、別の手法、すなわち利用者の気分を反映させることで、一人ひとりの感性に添った映画を推薦する。

1.3. 本論文の構成

本論文の構成は以下の通りである。

まず、第 2 章で本研究の概要について述べ、第 3 章で従来の映画検索方法について述べる。第 4 章では本研究における基盤技術について、第 5 章では本研究の基本構成について述べる。第 6 章では構成したシステムの実験と評価実験、及び考察を行い、第 7 章では今後の課題を含めた、本研究のまとめを行う。

第2章 本研究の概要

2.1. 本研究の概要

本研究は、ひとがミュージカル映画を好むポイントに着目し、意味の数学モデル [4]を利用して映画に関する感性空間を定義する。本研究は、生成した感性空間は絵画に関しても適合すると仮定し、同空間上に映画と絵画を射影して感性的距離を計量する。本研究は、

映画関連キーワードを用いた検索と、絵画を用いた検索を合成させることにより、はっきりとした理由や目的を持たないユーザーがその場の気分で映画を見つけられるように支援する。

2.2. 本研究の独創性

本研究の独創性は、どんな映画を見たいのかがよくわからないユーザーのために、多様性のある推薦を行うことである。すなわち、利用者が好むであろう、未知の映画を探してくる等、利用者の関心を広げるような推薦を行う。

元よりレコメンド機能は、情報過多の状況に対処するため、利用者にとって有用な情報を見つけ出す技法として考案された。レコメンド機能は、利用者が関心のあるアイテムを推薦するから有用なのである。

またレコメンド機能には、利用者が関心のあることに加えて、目新しさ[5]が要求されることが指摘されている。目新しさとは、わかりきったものでないことを意味する。

目新しさは主観的な指標であるため、定量的に評価することが難しい。本研究は、映画と絵画を同じ特徴ベクトルで表現することで意外性が間接的に高まると仮定し、生成した感性空間上で映画と絵画の感性的距離を計量する。

2.3. 従来方式に対する優位性

映画検索システムは現在、映画関連キーワードを用いた検索方法が主流である。

言葉は、感情や思想を音声または文字によって抽象するが、その際に、他の不要な性質を排除する作用捨象をも伴う[6][7]。要するに言葉による検索は、利用者に対して、次に見たい映画を仔細にわたって心の中に思い描いておくことを要求する。従来方式は、利用者が求める映画を正確に見つけ出せるので、利用者にとって既知のアイテムを推薦したいときに適している。

しかしながら、利用者の動機が備忘録 (reminder) や類似品 (more like this) よりも新規アイテム (new items) や視野を広げる (broaden my horizon) であるほど、利用者は未知のアイテムの推薦を望んでいる [8]。

協調フィルタリングの推薦手法は、映画の趣味が似ている知り合いに面白い映画を教えてもらう「ロコミ」の過程を自動化する方法で、多様性の高い推薦ができるとされている。ただし協調フィルタリングの場合、アイテムの性質が特徴ベクトルに存在しない限り、内容ベースでの適切な推薦はできないのである。[5]

2.4. 期待する成果

本方式は、利用者がシステムに対して行なった行動に基づいて推薦を行うもので、そのアルゴリズムはシステム運用側が設計した感性空間上で成り立っている。本方式は、ミュージカル映画に対して似た価値基準(特

徴ベクトル)を持つユーザーに対象者を限定することで、多様性のある推薦が内容ベースで実現できると考えた。

第3章 映画検索方法と代表的なサイト

ここでは、映画検索のためのウェブサイトやアプリケーションについて、現在代表的なものを取り上げる。

3.1. IMDb

IMDb[9] (Internet Movie Database) は、映画やTV番組、俳優などに関する情報のオンラインデータベースである。IMDbに登録されたデータは、2019年12月時点で総計3.6億アイテムを超えている。

IMDb.com, Inc.は、1990年にローンチして、1998年にAmazon.comの傘下に入った。

利用者は、映画関連キーワード(作品名や役者、会社名など)を用いて映画を検索できる。利用者は検索結果から任意の作品を選択すると、その作品の詳細情報にアクセスできる。詳細情報には、例えば映画の公開年や出演キャスト、関連画像やIMDbユーザーによる10点評価などがある。

3.2. Prime Video

Prime Video[10] (Amazon Prime Video) は、Amazonが展開する定額制見放題の動画配信サービスである。

次に見る映画を探すとき、利用者は映画関連キーワードを用いて映画を検索したり、過去の視聴履歴に基づいて推薦された映画リストから任意の映画を選択したり、「最近追加された映画」など非個人化推薦された映画リストから任意の映画を選択したりする。

任意の映画を選択すると、利用者はその映画に関する詳細情報に加えて、「この作品をご覧になったお客様は次の作品もご覧になっています」といった推薦を受ける。なおAmazonのレコメンド機能を支えているのは、作品間の類似度を利用した協調フィルタリングである。

3.3. Filmarks

Filmarks[11]は、株式会社つみきが運営する、国内最大級の映画レビューサービスである。

Filmarksは、映画の感想をシェアして楽しむコミュニケーションツールとしての傾向が強い。利用者はフォローしているユーザーの映画レビューをチェックしながら気になる映画を探すことが多く、また「試写会」など非個人化推薦された映画リストから気になる映画を見つけたり、或いは映画関連キーワード(「映画賞」、「製作国」や「#タグ」など独特なものが多い)から映画を探したりできる。

第4章 基盤技術

4.1. 口コミ情報

本研究は、Filmmarks[11]に投稿された映画レビューを 口コミ情報として使用した。本研究は、2019年2月16日の時点で「ミュージカルのおすすめ映画」上位20作品を対象に、各映画250件ずつ、合計5,000件の 口コミ情報を取得した。なお 口コミ情報は投稿日時の新しいものから収集した。以下の図1は取得したデータの例である。

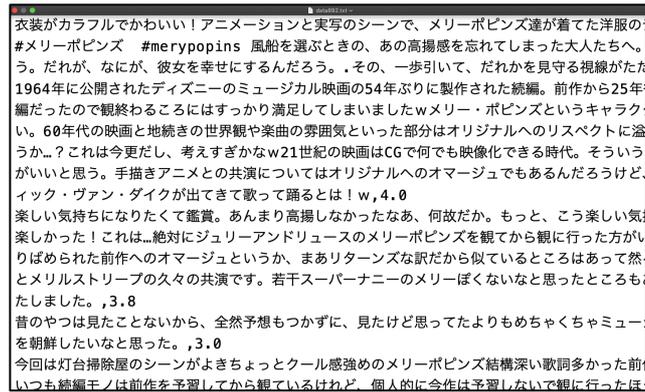


図1 取得データの例

4.2. 自作コーパス

本研究では、映画レビューとして意味のある形容詞を独自に170語選定し、それらをまとめたコーパスを作成した。

以下の表1は自作したコーパスの例である。

あたらしい 儂い
かつこいい 古い

表1 コーパス

本研究は、4.1.で取得した5,000件の 口コミ情報から1,000件を無造作に抜き出し、コーパスに基づいて意味のある形容詞だけを抽出した。本研究は、形態素解析にMeCab[12]を利用した。

4.3. 形態素解析ツール (MeCab)

形態素解析 (Morphological Analysis) は、自然言語処理分野で事前処理として用いられることが多く、単語の品詞情報をもとに文章を形態素に分解できる。

MeCabは京都大学情報学研究科と日本電信電話株式会社コミュニケーション科学基礎研究所の共同研究ユニットプロジェクトを通じて開発されたオープンソースの形態素解析エンジンである。

4.4. キーワード抽出方法 (TF-IDF)

TF-IDFは文書内に出現する単語の重要度を算出する統計的手法の一つで、TF値とIDF値を掛け合わせて求められる。TFでは文書内の出現回数が多い単語ほど重要だとされるのに対して、IDFでは他の文書に出現していない単語ほど重要だとされる。

$$tfidf(t_i, d_j) = tf(t_i, d_j) * idf(t_i)$$

TF (Term Frequency, 単語出現頻度) は、文書 d_j における単語 t_i の出現回数を、文書 d_j における全単語の出現回数の和で割ったものである。

$$tf(t_i, d_j) = \frac{f(t_i, d_j)}{\sum_{t_k \in d_j} f(t_k, d_j)}$$

IDF (Inverse Document Frequency, 逆文書頻度) は、総文書数 N における単語 t_i を含む文書数 $df(t_i)$ の逆数の対数をとったものである。

$$idf(t_i) = \log \frac{N}{df(t_i)}$$

4.5. キーワード抽出方法 (実践)

本研究は、4.2.で抽出された形容詞を対象に統計的手法 (TF-IDF) を用いて 口コミ情報の特徴を分析した。

以下の表2は、①TF-IDF、②表記揺れの修正、③類義語の統合の3つの作業を経て得られた形容詞49個を、TF-IDFの値の大きい順に並べたものである。

1	かわいい	26	おかしい
2	楽しい	27	気持ち良い
3	おもしろい	28	熱い
4	力強い	29	素晴らしい
5	美しい	30	羨ましい
6	かつこいい	31	重い
7	うまい	32	軽い
8	明るい	33	恐ろしい
9	凄い	34	めでたし
10	懐かしい	35	人間らしい
11	嬉しい	36	心地よい
12	深い	37	憎たらしい
13	長い	38	興味深い
14	難しい	39	惜しい
15	辛い	40	見やすい
16	優しい	41	儂い
17	切ない	42	苦しい
18	新しい	43	おいしい
19	細かい	44	愛らしい
20	悲しい	45	酷い
21	怖い	46	激しい
22	物足りない	47	くだらない
23	古い	48	短い
24	温かい	49	清々しい
25	暗い		

表2 口コミ情報の特徴

4.6. 感性空間の構築

そもそも形容詞[14]とは、そのものの性質・状態・属性などを表す言葉である。

本研究は、4.5.で得られた形容詞がミュージカル映画のどの要素を形容したものかに注目し、その対象となる事物を推定した。これは、本当に大事なことは言葉にせず、あえてその周辺を三十一文字に込める歌人[15]に、相通じるところがある。

本研究は 4.5.の 49 個の形容詞を概念的に写像して、形容される対象物を独自に 8 つ定めた。本研究は、映画の特徴を意味的に重複しない最小単位 8 個で分類できると仮定して、ミュージカル映画の感性空間を下表の 8 次元空間で設計した。なおこれらの次元は概念的に直交する。

	次元名 (英語)	次元名 (日本語)
1	SONG	うた
2	STORY	ものがたり
3	ANIME	アニメ
4	DANCE	ダンス
5	HAPPY	幸せ
6	LAUGH	笑い
7	CRY	悲しさ
8	NOSTALGIA	郷愁

表 3 感性空間を構成する 8 次元

4.7. 絵画データ

本研究は、絵画を用いた検索を行うにあたり、シカゴ美術館公式ウェブサイト[13]からパブリックドメインライセンスの名画 28 枚を JPEG ファイル形式でダウンロードした。これらの画像は、クレジット表記なしで無料ダウンロードできる、クリエイティブ・コモンズ 0 (CC0) ライセンスを取得する。

4.8. ベクトル空間による内積計量

本研究は、感性空間上に射影した映画と絵画の感性的距離を計量するのに内積計算を用いた。

映画 a_n のベクトルは以下のように表される。映画 a_n は特徴ベクトルを含むと 1、含まなければ 0 という値からなるベクトルである。ベクトルの成分が 8 つなのは、感性空間を構成する次元数が 8 つだからである。

$$\vec{a}_n = (a_1, a_2, \dots, a_8)$$

同様に、絵画 b_n のベクトルは以下のように表され、特徴ベクトルを含むと 1、含まなければ 0 という値を持つ。

$$\vec{b}_n = (b_1, b_2, \dots, b_8)$$

これら \vec{a}_n と \vec{b}_n の内積の計算は、以下の式で実現できる。

$$\vec{a}_n * \vec{b}_n = a_1 b_1 + a_2 b_2 + \dots + a_8 b_8$$

本方式は、より正確な感性的距離を計量するために、利用者の感性 c_n を絵画 b_n に加算してから、映画 a_n と乗算する。利用者の感性 c_n は、利用者がウェブアプリケーション上で入力した内容に基づくベクトルである。利用者が各特徴ベクトルに価値を見出すならば 1、そうでないならば 0 という値をとる。

$$\vec{c}_n = (c_1, c_2, \dots, c_8)$$

\vec{a}_n と $\vec{b}_n + \vec{c}_n$ の内積計算は、以下の式で実現できる。

$$\vec{a}_n * (\vec{b}_n + \vec{c}_n) = a_1(b_1 + c_1) + a_2(b_2 + c_2) + \dots + a_8(b_8 + c_8)$$

絵画 b_n に利用者の感性 c_n を加算するのは、利用者にとって重要な価値基準が不本意に除外されることを防ぐためである。これは 2.2.に述べた通り、推薦結果の意外性を高めるため、利用者には各絵画の持つ特徴ベクトルの値を知らせないことを踏まえている。

4.9. トレンディ度

本システムは、利用者の世間の評価に対する価値観を尋ねることで、感性的適合度と一般的適合度の混合の割合を、利用者が調節できるようにした。

トレンディ度 u_t は、利用者が世間の評価 t を参考にした場合は 0.1、気にしない場合は 0 の値をとる。

$$u_t = \begin{cases} 0.1 \\ 0 \end{cases}$$

IMDb の 10 点評価[9]を m_s とすると、各映画の評価点 s は 0.0 以上 10.0 以下の値をとる。

$$m_s = \begin{cases} 0.0 \\ 0.1 \\ \dots \\ 9.9 \\ 10.0 \end{cases}$$

以下の式は、利用者のトレンディ度と IMDb の 10 点評価を掛け合わせたもので、利用者が世間の評価を気にしない場合は 0 を出力し、利用者が世間の評価を参考にした場合は 0.0 以上 1.0 以下の値を出力する。

$$v_{t,s} = u_t m_s$$

4.10. メンタルヘルスケア

本システムは、ウェブアプリケーション上でアンケートを行い、利用者にとって精神的疲労の少ない映画を推薦する。

本研究は、利用者の映画鑑賞後の気分に着目し、逆算方式のメンタルヘルスクエアを試みる。具体的には、利用者の映画鑑賞後の気分を u_m とし、 $m = 1$ は「落ち込みたくない」とき、 $m = 0$ は「特に気にしない」ときである。

$$u_m = \begin{cases} 1 \\ 0 \end{cases}$$

映画のコンテンツを m_c とすると、 c は軽い映画のときに 1、重い映画のときに -1 の値をとる。

$$m_c = \begin{cases} 1 \\ -1 \end{cases}$$

以下の式は、利用者の映画鑑賞後の気分 m と映画のコンテンツ c を掛け合わせたものである。

$$v_{m,c} = u_m m_c$$

本システムは、 $v_{m,c} \geq 0$ をメンタルヘルスクエアの基準とし、この基準を満たす映画をメンタルヘルスクエアされた作品として推薦する。

第 5 章 基本構成

5.1. システムの基本構成

本システムは、下記の図 2 に示すように、3 つのメカニズム（センシング、プロセッシング、アクチュエーション）で構成される。

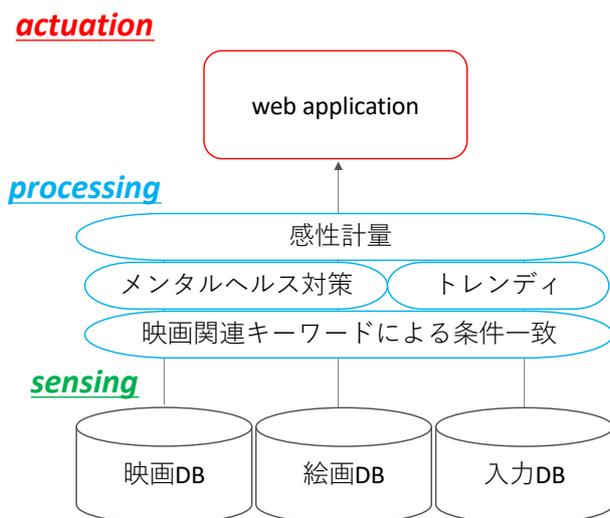


図 2 システム構成図（推薦結果出力時）

センシングでは、データがデータベースに蓄積される。本システムは、映画データベースや絵画データベースに関しては、システム運用側にデータ登録の権限を与える。一方、入力データベースに関しては、利用

者の行動がウェブアプリケーションを介して自動的に登録されるようにした。

プロセッシングでは、4.8. ~ 4.10.の各種演算や、映画関連キーワードを用いた条件一致を組み合わせる。実際のデータ検索クエリは以下ようになる。なお各データベースの構成要素は 5.3. ~ 5.5.で述べる。

```
SELECT 省略
FROM
movie as m, record1 as r1, record2 as r2, gallery as g
WHERE r1.id = (select max(r1.id) from r1)
AND r2.id = (select max(r2.id) from r2)
AND r1.pic = g.pic
AND (映画の上映時間) <= (利用者の持ち時間)
AND (映画の製作年) >= (利用者の設定した値)
AND (4.10.のメンタルヘルスクエア)
ORDER BY
(4.8.の内積計量)+(4.9.のトレンドイ度) DESC LIMIT 5
```

アクチュエーションでは、ウェブアプリケーションを作成した。

5.2. ウェブアプリケーションの構成

本ウェブアプリケーションは、大きく 3 つの機能を持つ。3 つの機能とは、想起、入力、推薦である。

本ウェブアプリケーションは PHP を用いて作成し、MySQL データベースと連動させた。

5.3. 映画 DB の構成要素

映画データは、以下のようにデータベースに登録される。

DB NAME: MOVIE	
COLUMN NAME	NOTE
PID	INT AUTO_INCREMENT
TITLE	VARCHAR
HOURL	INTEGER (単位: 分)
PRODUCTION_YEAR	INTEGER (西暦)
IMDB	FLOAT (10 点評価)
E_SONG	If applicable 1, otherwise 0
E_STORY	If applicable 1, otherwise 0
E_ANIME	If applicable 1, otherwise 0
E_DANCE	If applicable 1, otherwise 0
E_HAPPY	If applicable 1, otherwise 0
E_LAUGH	If applicable 1, otherwise 0
E_CRY	If applicable 1, otherwise 0
E_NOSTALGIA	If applicable 1, otherwise 0
STARRING	VARCHAR (主演俳優)
ELEMENT	VARCHAR (#タグ)
MENTAL_PREPARATION	If yes -1, otherwise 1

本方式では、特徴量の多い映画ばかり推薦されることを防ぐため、各映画は E_〇〇と続く 8 つの次元に関して、必ず 3 つの次元の要素を持つとする。映画が各次元の要素を持つときは 1 を、持たないときは 0 を入力する。

5.4. 絵画 DB の構成要素

絵画データは、以下のようにデータベースに登録さ

れる。

DB NAME: GALLERY	
COLUMN NAME	NOTE
PID	INT AUTO_INCREMENT
TITLE	VARCHAR
E_SONG	If applicable 1, otherwise 0
E_STORY	If applicable 1, otherwise 0
E_ANIME	If applicable 1, otherwise 0
E_DANCE	If applicable 1, otherwise 0
E_HAPPY	If applicable 1, otherwise 0
E_LAUGH	If applicable 1, otherwise 0
E_CRY	If applicable 1, otherwise 0
E_NOSTALGIA	If applicable 1, otherwise 0

同様に、各絵画も E_〇〇と続く 8 つの次元に関して、必ず 3 つの次元の要素を持つとする。

5.5. 入力 DB の構成要素

利用者がウェブアプリケーション上で行う行動は、以下のようにデータベースに登録される。

DB NAME: RECORD1	
COLUMN NAME	NOTE
PID	INT AUTO_INCREMENT
PIC	VARCHAR

DB NAME: RECORD2	
COLUMN NAME	NOTE
PID	INT AUTO_INCREMENT
FIRSTNAME	VARCHAR
MENTAL_PREPARATION	If yes 0, otherwise 1
ALLOTTED_TIME	INTEGER (単位：分)
FILMED_AFTER	INTEGER (西暦)
PUBLIC_EVALUATION	If needed 0.1, otherwise 0
E_SONG	If applicable 1, otherwise 0
E_STORY	If applicable 1, otherwise 0
E_ANIME	If applicable 1, otherwise 0
E_DANCE	If applicable 1, otherwise 0
E_HAPPY	If applicable 1, otherwise 0
E_LAUGH	If applicable 1, otherwise 0
E_CRY	If applicable 1, otherwise 0
E_NOSTALGIA	If applicable 1, otherwise 0

ここでは、利用者は E_〇〇と続く 8 つの次元に関して、無制限に次元の要素を持てるとする。

第 6 章 実験と評価

6.1. アプリケーションの概説

(ア) 絵画選択

本アプリケーションのギャラリーページは、利用者を絵画により喚起される感性の世界に導く。利用者は、絵画のイメージが次に見たい映画のイメージに最も近いものを、1 枚選択する。

(イ) アンケート入力

ここでは、アンケート調査を実施する。図 3 は実際の入力画面のようすである。

(ウ) 推薦

レコメンド機能の推薦が利用者に受け入れられるには、推薦結果が客観的であること、且つ、そのこと

が利用者にわかりやすく伝わる必要がある[5]。

本研究は、推薦の透明性を高めるため、利用者が入力したデータと関連づけることで、推薦を導いた根拠を明示した。

6.2. 実験



本実験の被験者は、システム設計者である筆者とミュージカル映画の好みが似ている女性 4 人である。

(ア) 被験者 A の実験結果

被験者 A は、絵画選択の場面で下のトマス・コールの絵画[16] を選択した。図 3 はアンケートの結果である。

被験者 A

ご希望の鑑賞時間をお選びください。

130分以内

ご希望の映画製作年度をお選びください。

1960年度以降製作

映画鑑賞後の気分について

どんより落ち込むのはいやだ

気にしない

映画に対する世間一般の評価について

参考にしたい

気にしない

ミュージカル映画に期待することをお選びください。

一緒に歌いたくなっちゃう映画

期待する それほど期待しない

深く考えさせられる映画

期待する それほど期待しない

アニメが登場する映画

期待する それほど期待しない

一緒に踊りたくなっちゃう映画

期待する それほど期待しない

ほっこりする映画

期待する それほど期待しない

アハハと笑える映画

期待する それほど期待しない

必ず泣ける映画

期待する それほど期待しない

郷愁に浸れる映画

期待する それほど期待しない

検索

図 3 入力例 1

推薦結果は以下の図 4 のようになった。

皆さんにオススメのミュージカル映画はこちらです。

picture	映画	主演	#タグ
上映時間(分)	製作年	一般的評価度	感性的適合度
	La La Land	Ryan Gosling, Emma Stone	#歌いたくなる #考えさせられる
126	2017	8	3.8000001192029
	Les Parapluies De Cherbourg	Catherine Deneuve, Nino Castelnuovo	#歌いたくなる #泣ける
91	1963	7.8	3.7800000306963923
	Moulin Rouge!	Nicole Kidman, Ewan McGregor	#歌いたくなる #考えさせられる
128	2001	7.6	3.760000001788139
	High School Musical	Zac Efron, Vanessa Hudgens	#歌いたくなる #考えさせられる
98	2006	5.3	3.530000026971102



Mamma Mia: Here We Go Again Lily James, Amanda Seyfried #歌いたくなる #ほっこり

114	2018	6.7	2.6699999909102914
-----	------	-----	--------------------

次へ

図 4 推薦結果 1

推薦結果は、1960 年度以降に製作された映画のうち、上映時間が 130 分以内の中から、感性的適合度 (4.8.の内積と 4.9.のトレンドィ度を加算して算出) の高い順に表示された。一般的評価度は、IMDb による各映画の 10 点評価の数値である。図 3 の被験者 A が「ミュージカル映画に期待すること」と図 4 の各映画の「#タグ」を照らし合わせると、推薦結果は、被験者 A の回答を確かに反映していると確認できる。なお映画のイメージ画像の URL は、上から順に、参考文献[17]~[21]に記載した。

(イ) 評価実験

本研究では、本システムが推薦した映画 5 本について被験者にアンケートを行った。アンケートは Google フォームを利用して作成した。

質問内容は以下の通りである。回答方式は、各質問に対してどれか 1 つだけ選択肢を選ぶ、選択式を採用した。回答結果は、6.3.の図 7 に掲載した。

推薦の意外性	実際に見てみたいですか？
あり	はい
なし	いいえ
その他	鑑賞済
	その他

なお推薦の意外性で「その他」を選択して「映画の内容が分からないため推薦が意外なのか分からない」という趣旨の回答をした被験者がいたが、利用者に新しい情報を与えられた点で多様性のある推薦ができたと判断し、本研究ではこの回答を「(推薦の意外性)あり」としてカウントした。

最後に、被験者によるコメントを一部掲載する。

タイトルも知らなかったミュージカル映画を推薦してもらえ、嬉しかったです。
 ざっくばらんに推薦されたので、年代だとこれー、歌い出したくなる映画だとこれー的な何か説明があると、回答した感を得られて嬉しいです。

6.3. 考察

下の図 7 は、選択肢の選択回数を映画数の 5 で割ったパーセンテージである。否定的な回答内容に関して

は、図の見易さを考慮して、パーセンテージに負の符号をつけた。例えば、被験者 A は「(推薦の意外性)なし」を 4 回選択しているの、 $\frac{4}{5} = 80$ すなわち -80% という具合である。

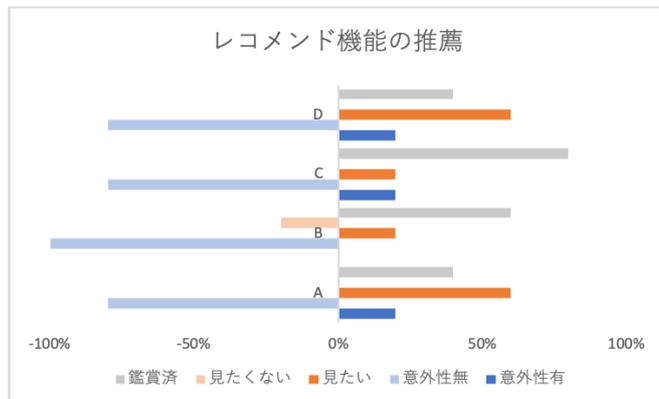


図 5 評価実験

図 7 からわかるのは、4 人全員がほぼ全ての推薦に対して意外性を感じていないことだ。しかしながら、推薦された映画が既に鑑賞済みであるパーセンテージと、推薦された映画を実際に見てみたいと回答したパーセンテージを合わせると、被験者 A から被験者 D の順に 100%, 80%, 100%, 100% となる。つまり本システムは、被験者にとって既知の映画を推薦してしまったため、推薦の意外性は低くなってしまったが、被験者の好みに添った映画の推薦はできていたと考えられる。

第 7 章 本研究のまとめ

本研究は、「これが見たい」とはっきり自覚していない利用者を対象とする、個人化された映画検索サービスを感性計量に基づいて実装した。

本システムの目的である推薦の多様性は、被験者が既に鑑賞済みの映画を多く推薦してしまったため、あまり確かめられなかった。一方、推薦された映画を「実際に見てみたいですか?」という問いに対して「いいえ」と答えたパーセンテージは 1 人を除いて 0% であったことや、推薦された映画が既に鑑賞済みであることが多く見受けられたことから、本システムは利用者の嗜好を反映させた映画推薦を概ね達成できたと考えられる。

また本システムは、被験者からのコメントで推薦の透明性を指摘されているように、未だ UX 向上の余地を持つため、今後も改善を必要とする。

参考文献

[1] 『日経新聞』2019 年 12 月 31 日「Netflix 独走、10 年で 4000% 高 2010 年代の米株首位」(筆・宮本岳則)
<https://www.nikkei.com/article/DGXMZO53999870R>

31C19A2000000/
 [2] Netflix のレコメンド機能のご利用方法
<https://help.netflix.com/ja/node/100639,2020/01/10> 現在
 [3] Brent Smith and Greg Linden, “Two Decades of Recommender Systems at Amazon.com”, IEEE Internet Computing, 2017.
 [4] Kiyoki, Y. Kitagawa, T. and Hayama, T. (1994) “A metadatabase system for semantic image search by a mathematical model of meaning”, ACM SIGMOD Record, vol.23, no.4, 1994, pp.34-41.
 [5] 神島敏弘, (2007) “推薦システムのアルゴリズム”, 人工知能学会誌, vol.22, No.6, pp.826-837.
 [6] 「言葉」. 『スーパー大辞林』. 三省堂, 2013
 [7] 「抽象」. 『スーパー大辞林』. 三省堂, 2013
 [8] K. Swearingen and R. Sinha. Beyond algorithms: An HCI perspective on recommender systems. In SIGIR Workshop on Recommender Systems, 2001.
 [9] PRESS ROOM
<https://www.imdb.com/pressroom/stats/,2020/01/10> 現在
 [10] <https://www.amazon.co.jp,2020/01/10> 現在
 [11] <https://filmarks.com,2020/01/10> 現在
 [12] MeCab: Yet Another Part-of-Speech and Morphological Analysis
<http://taku910.github.io/mecab/,2020/01/10> 現在
 [13] <https://www.artic.edu,2020/01/10> 現在
 [14] 「形容詞」. 『スーパー大辞林』. 三省堂, 2013
 [15] コンテキストデザインとは, 渡邊康太郎
<https://note.mu/waternavy/n/nba719b704057,2020/01/10> 現在
 [16] Thomas Cole. *Distant View of Niagara Falls*, 1830, CC0 Public Domain Designation
 [17] <https://www.imdb.com/title/tt3783958/mediaviewer/rm3967749632,2020/01/10> 現在
 [18] <https://www.imdb.com/title/tt0058450/mediaviewer/rm3746038528,2020/01/10> 現在
 [19] <https://www.imdb.com/title/tt0203009/mediaviewer/rm2687256832,2020/01/10> 現在
 [20] <https://www.imdb.com/title/tt0475293/mediaviewer/rm1663174400,2020/01/10> 現在
 [21] <https://www.imdb.com/title/tt6911608/mediaviewer/rm2479967488,2020/01/10> 現在
 [22] 小森優佳, (2013) “年代別地勢図を用いた歴史書籍と事象の検索・統合・可視化システムの実現”