

修士論文

トピックモデルと感情推定を活用した ネガティブ感情軽減のための 音楽推薦システムの提案

Proposal of a music recommendation system to reduce negative
emotions using topic models and emotion estimation

富山県立大学大学院 工学研究科 電子・情報工学専攻

2355020 水上和秀

指導教員 António Oliveira Nzinga René 講師

提出令和7年(2025年)2月

目 次

図一覧	ii
表一覧	iii
記号一覧	iv
第1章 はじめに	1
§ 1.1 本研究の背景	1
§ 1.2 本研究の目的	2
§ 1.3 本論文の概要	3
第2章 音楽と感情に基づく推薦システムのアプローチ	4
§ 2.1 音楽および他分野における推薦システム	4
§ 2.2 音楽が感情・心理に与える影響	8
§ 2.3 感情分析の手法及び研究事例	12
第3章 理論の説明	15
§ 3.1 テキストからの感情分析	15
§ 3.2 画像からの感情分析	19
§ 3.3 クラスタリング手法によるトピック検索	23
第4章 提案手法	28
§ 4.1 楽曲特徴量の取得の流れ	28
§ 4.2 ガイド付き LDA を用いたプレイリストの作成	28
§ 4.3 提案システムの概要	28
第5章 数値実験並びに考察	30
§ 5.1 数値実験の概要	30
§ 5.2 実験結果と考察	30
第6章 おわりに	31
謝辞	32
参考文献	33

図一覧

2.1	レコメンドシステムのイメージ	5
2.2	協調フィルタリングとコンテンツベースフィルタリング	5
2.3	音楽療法の種類	9
2.4	情報推薦システムの分類	9
3.1	BERT の流れ	16
3.2	BERT の入力部分	16
3.3	deepface で利用できる顔検出の種類	20
3.4	3D アライメント [30]	20
3.5	モデル [30]	21
3.6	LDA におけるグラフィカルモデル	25
3.7	3D アライメント [30]	25

表一覽

2.1 協調フィルタリングとコンテンツベースフィルタリングの比較 [1]	6
2.2 各感情分析の比較 [22]	13

記号一覧

以下に本論文において用いられる用語と記号の対応表を示す.

用語	記号
j 人目の使用者の名前	ϵ_j
j 人目の身長	α_j
j 人目の体重	β_j
j 人目の基礎代謝量 (下限)	B_j^L
j 人目基礎代謝量 (上限)	B_j^H
j 人目のアレルギー情報	x_j
j 人の有する生活習慣病	z_j
対象の日数	D
レシピの数	R
食材の数	Q
栄養素の数	N
データベース上の食材数	S
データベース上の食材番号	$d : 1, 2, 3, \dots, S$
日の番号	$k : 1, 2, 3, \dots, 3D$
栄養素の番号	$l : 1, 2, 3, \dots, N$
材料の番号	$m : 1, 2, 3, \dots, Q$
レシピの番号	$i : 1, 2, 3, \dots, R$
i 番目のレシピの名前	y_i
i 番目のレシピの献立フラグ	r_{ki}
i 番目のレシピの主菜フラグ	σ_i
i 番目のレシピの調理時間	T_i
i 番目のレシピの摂取カロリー	C_i
i 番目のレシピの調理コスト	G_i
i 番目のレシピの m 番目の材料の名前	q_{im}
i 番目のレシピの m 番目の材料量	e_{im}
i 番目のレシピの l 番目の栄養素の名前	n_{il}
i 番目のレシピの l 番目の栄養素の量	f_{il}
d 番目の食材名	Z_d
d 番目の食材の販売単位	W_d
d 番目の食材の値段	M_d

はじめに

§ 1.1 本研究の背景

現代社会において、個人の幸福感や健康は感情のバランスに大きく依存しているとされる。ポジティブな感情は幸福感の向上やストレスの緩和、自尊心の向上に寄与する一方で、ネガティブな感情が強まると心理的な問題を引き起こす可能性が高まる。特に、ネガティブ感情が過剰になる場合、うつ病や不安障害といった心理的健康問題のリスクが高まり、日常生活や社会生活におけるパフォーマンスや満足度の低下を招くと考えられている。このような背景から、ネガティブ感情を適切に管理し、ポジティブ感情を高める手法の開発が重要視されている。

そのような感情管理の手段の一つとして、音楽が注目されている。音楽はテンポ、リズム、歌詞などの構成要素を通じて、感情に直接的に影響を与える力を持つ。たとえば、テンポの速い楽曲は活力やエネルギーの向上に寄与し、穏やかなリズムを持つ楽曲はリラクゼーションを促進するといった効果が確認されている。また、歌詞のテーマやメッセージが個人の心情や状況に共鳴することで、感情的な浄化作用や共感を引き起こすことも明らかになっている。これまでの研究において、音楽を聴くことがネガティブ感情の軽減や幸福感の向上に寄与することが示されている。

一方で、現在普及している音楽推薦システムにはいくつかの課題が存在する。Spotify や Apple Music などの音楽ストリーミングサービスは、主にユーザーの過去の視聴履歴やジャンルの嗜好に基づいて楽曲を推薦している。これらのシステムは効率的にパーソナライズされた音楽体験を提供しているものの、ユーザーの現在の感情状態やその変化を考慮する設計には至っていない。たとえば、ユーザーがネガティブ感情を抱えている状況で、リラクゼーションや気分転換を目的とした楽曲を適切に推薦できる仕組みは十分に確立されていない。このような制約は、感情状態に応じた音楽推薦システムの必要性を浮き彫りにしている。

§ 1.2 本研究の目的

本研究では、ユーザーの現在の感情状態をリアルタイムで推定し、その状態に応じた音楽を推薦するシステムの構築を目指す。このシステムは、DeepFaceを用いた顔認証技術によって感情値（ポジティブ・ネガティブ）の推定を行い、BERTによる歌詞の感情分析を活用して楽曲の感情価を評価する。また、Spotify APIを用いて取得した楽曲の特徴量（テンポ、エネルギー、アコースティック性など）を基に、ネガティブ感情を軽減し、ポジティブ感情を引き出す楽曲を包括的に推薦する仕組みを提案する。このアプローチにより、従来のシステムでは対応しきれなかった感情管理の課題に対する新たな解決策を提示し、音楽を通じて個人の幸福感を向上させることを目的とする。

§ 1.3 本論文の概要

本論文は次のように構成される。

第1章 本研究の背景と目的について説明する。背景ではを述べる。目的ではを述べる。

第2章 音楽による心理・感情への効果について、推薦システムの事例について述べる。また、感情分析の事例について述べる。

第3章 本研究で用いる BERT 及び DeepFace、LDA によるトピック分析について述べる。

第4章 本研究の提案手法について述べる。

第5章 提案手法における精度の検証を目的として行った数値実験について、その概要と結果を示す。

第6章 本研究で述べている提案手法をまとめて説明する。また、今後の課題について述べる。

音楽と感情に基づく推薦システムのアプローチ

§ 2.1 音楽および他分野における推薦システム

近年、ソーシャルメディアの発展やスマートフォンなどのICT機器の普及により、多くの人々がインターネットに触れる機会が増えている。その中でも、YouTube¹をはじめとする動画配信サイトや、Amazon²をはじめとするEC (Electronic Commerce: 電子商取引) サイトなどを利用する機会が増加している。これらのサービスでは、動画や商品を閲覧している際に、関連性の高い別の動画や商品を提示されることが一般的である。このような技術は「情報推薦システム」と呼ばれ、現在その重要性が高まっている。また、レコメンドシステムのイメージを図2.1に示す。

推薦システムにはいくつかの手法が存在し、主に情報推薦における嗜好の予測方法としてルールベース、コンテンツ（内容）ベースフィルタリング、協調フィルタリング、ハイブリッド法の4つに分けることができる。いかにそれぞれの手法について述べ、その後、他分野及び音楽分野における情報推薦の事例、その課題について紹介する。また、表2.1はコンテンツベースフィルタリングと協調フィルタリングの比較を示す表である。

ルールベース推薦

ルールベース推薦とは、システムの運営者があらかじめ「特定の行動をとった人や特定の属性を持つ人に対してどのような商品や情報を提供するか」というルールを設定し、そのルールにしたがってレコメンドを行う手法である。例えば、パスタを購入しようとしている人にチーズやソースを推薦するように、利用者の行動や嗜好を予測して適切だと思われるルールを設定する。この手法は比較的低コストで容易に実装可能であり、透明性が高いという利点がある。運営者が設定したルールに基づいて商品を推薦するだけなので、推薦の結果を簡単に説明できる。しかし、あらかじめ設定したルールに依存するため、利用者の多様なニーズや嗜好を細かく反映することが難しいという欠点がある。また、利用者の行動パターンが変化した場合に対応するには、ルールを手動で更新する必要があるため、運用コストが高くなる可能性がある。

コンテンツベースフィルタリング

コンテンツベースフィルタリングは、アイテム（利用者に推薦する対象やコンテンツ）の特徴量を使用し、利用者の嗜好に近いアイテムを推薦する手法である。例えば、映

¹<https://www.youtube.com>

²<https://www.amazon.co.jp>

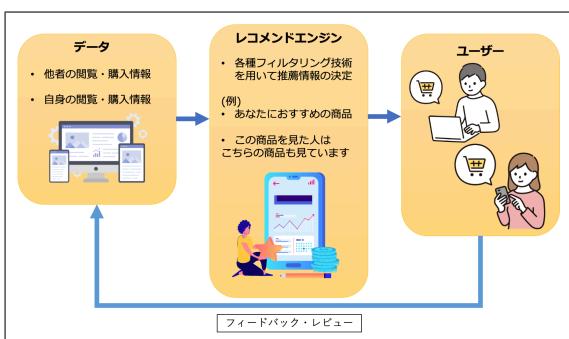


図 2.1: レコメンドシステムのイメージ



図 2.2: 協調フィルタリングとコンテンツベースフィルタリング

画を推薦するシステムを考えてみる。この場合、利用者が「アクション映画」や「サスペンス」といったジャンルを検索すると、システムはそれらの特徴量を分析し、ジャンルやテーマが類似する映画を選び出して推薦する。また、過去に視聴した映画のデータを基に、類似した内容や雰囲気の映画を提案することも可能である。この手法は、利用者の過去の嗜好に基づき、個人に特化した精度の高い推薦ができるという利点がある。利用者が以前に好んだアイテムと特徴の類似度を計算しアイテムを優先的に推薦するため、個々の利用者に特化した推薦が可能である。一方、この手法は過去の嗜好に基づいて推薦を行うため、利用者に同じようなアイテムが繰り返し推薦され、新しいアイテムの発見が難しいという欠点がある。コンテンツベースフィルタリングには、利用者が自分の好むものを直接指定する「直接指定コンテンツベースフィルタリング」と、利用者の嗜好データからプロファイルを作成し、アイテムデータベースと比較することで嗜好を測る「間接指定コンテンツベースフィルタリング」が存在する。

協調フィルタリング

協調フィルタリングは、システム使用前に利用者の嗜好データを収集し、それを基に利用者の好みや傾向（例えば、どのアイテムが好まれ、どれが嫌われるか）を分析する手法である。この手法では、嗜好が類似している利用者同士が、共通して好むアイテムや嫌うアイテムがあると仮定し、似たような嗜好を持つユーザを見つけ出す。その後、そのユーザが好むと思われるアイテムを推薦する。

協調フィルタリングは大きく分けてユーザベース協調フィルタリングとアイテムベース協調フィルタリングの二つに分類される。ユーザベース協調フィルタリングとは似た嗜好を持つ他のユーザを見つけ、そのユーザが高く評価したアイテムを推薦する手法のことであり、アイテムベース協調フィルタリングとはアイテム同士の類似性に基づき、ユーザが過去に好んだアイテムに似たアイテムを推薦手法のことである。これら手法は他の利用者の行動データを活用するため、利用者の過去の評価や行動に基づいて適切な推薦ができるという特徴がある。しかし、協調フィルタリングはシステムに新規ユーザや新規アイテムが追加された場合に過去のデータがないため推薦することが難しくなるという「コールドスタート問題」やユーザとアイテムの評価データが非常に少ないためにユーザー間の類似性を正確に算出できず推薦精度が低下してしまう「スペース性問題」などの課題がある。こ

表 2.1: 協調フィルタリングとコンテンツベースフィルタリングの比較 [1]

分類	協調フィルタリング	コンテンツベースフィルタリング
多様性	○	×
ドメイン知識	○	×
スタートアップ問題	×	△
利用者数	×	○
被覆率	×	○
類似アイテム	×	○
少数派の利用者	×	○

これらの問題を解決するために、コンテンツベースフィルタリングやハイブリッドフィルタリングと組み合わせて使われることが多い。

ハイブリッドフィルタリング

ハイブリッドフィルタリングとは、コンテンツベースフィルタリングと協調フィルタリングを組み合わせた手法である。コンテンツベースフィルタリングは推薦がパターン化されやすく、協調フィルタリングは、新規ユーザや新規アイテムに対して機能しにくいといった欠点があるが、ハイブリッドフィルタリングはそれらの欠点が補われ、幅広いユーザに適切な推薦を行うことができる。

推薦システムは、現在、様々な分野で活用されており、その適用事例も増えている。例えば、EC サイトの分野では商品の推薦、教育分野では学習コンテンツの提示、利用者のニーズや好みに応じた提案を行う仕組みが使われている。こうした他分野での具体的な推薦システムの事例について紹介し、その後、音楽分野における推薦システムの事例を紹介する。

他分野での推薦システムの事例

1. Amazon の推薦システムの事例

Amazon の推薦システムは、協調フィルタリング、コンテンツベースフィルタリング、機械学習を組み合わせて推薦を行っている。協調フィルタリングでは、過去のユーザの行動を分析し、他のユーザの行動と類似したアイテムを推薦している。コンテンツベースフィルタリングでは、商品を購入した人に対して、商品の特徴や属性（ジャンル、ブランドなど）を分析し、類似した商品を推薦している。また、機械学習により、履歴データでモデルをトレーニングすることで予測精度を向上させている [2]。

2. Coursera における推薦システムの事例

Coursera は、オンライン学習プラットフォームで、世界中の大学や企業と提携し、専門的なコースや専門職の資格を提供しているサイトである。Coursera は学習者の過去の履歴や興味に基づき、関連するコースを推薦している。ユーザのプロファイル情報（学習分野、スキルレベル、過去に受講したコースなど）を元に、次に学ぶべきコースを予測している。また、機械学習を利用して、ユーザに合わせた最適なコースを提案することで、学習体験の向上を図っている。[3]

音楽分野でのシステムの事例

1. YouTubeMusic での推薦システムの事例

YouTube Music では、Transformer モデルを活用して音楽推薦を行っている。Transformer モデルは、言語翻訳や分類タスクに使用されていた自然言語処理技術であり、ユーザの音楽の視聴、スキップ、いいねなどの行動を分析している。さらに、既存のランキングモデルと Transformer を組み合わせることで、現在のユーザの行動と過去のリスニング履歴を反映したランキングを学習している。この方法により、ユーザのスキップ率が減少し、音楽を聴く時間が増加する結果が得られ、ユーザの満足度が向上している [4]。

2. Spotify での推薦システムの事例

Spotify では、協調フィルタリング、自然言語処理、音声解析の技術を組み合わせて個人に合った音楽を推薦している。Spotify はユーザのプレイリスト、再生履歴、楽曲への「いいね」などの行動データを分析し、似たような嗜好を持つユーザが気に入った楽曲を推薦している。また、楽曲のテンポ、音程、音量などの音楽的特徴を分析し、類似した特徴を持つ楽曲を識別し、推薦に活用している。さらに、アーティストや楽曲に関連する記事、レビュー、ブログ投稿などのテキストデータを収集・分析し、楽曲がどのように言及されているかを理解し、ユーザーの関心に合った曲を推薦している [5]。

このように、音楽分野及び他分野では推薦システムが活用されている。また、ユーザ一人ひとりの嗜好性に合ったコンテンツを推薦する手法は、すべてのユーザに同じコンテンツを推薦する手法に比べて次の 2 つの効果が期待される。

購買・利用促進

ユーザが興味を持ちやすい商品やサービスを推薦することで、購入率や利用率を向上させることができる。YouTube の推薦システムの研究によると、協調フィルタリングに基づいた推薦システムを YouTube に適用した結果、視聴回数による人気ランキングを表示した場合と比較し視聴数の増加やクリック率の向上が確認され、満足度も向上したとされている [6]。

多様性と満足度の向上

推薦システムを利用することによって、新しいアイテムやジャンルを知ることができ、それにより満足度を高めることができている。ある研究によると、推薦システムはユーザに関連性の高い情報を提示することで、新しい商品やジャンルを発見でき、より充実した体験を得ることができるとされている。また、推薦システムの多様性と正確性にはユーザの満足度に対する相互作用効果があり、これは、ユーザが探していたものと関連性が高く、かつ新しい商品を推薦することで、よりユーザの満足度が向上することが示されている [7]。

推薦システムを導入することによってさまざまな効果があり、多くの分野で使用されている。しかし、既存の推薦システムは、主に過去のユーザデータや他のユーザの行動履歴に

基づいてアイテムを推薦することが多い。これらのシステムは過去のデータに大きく依存しており、リアルタイムで変化するユーザの感情や心理状態を十分に反映できていない。そこで本研究ではユーザの感情状態を考慮し、その感情に合った特徴量を持つ音楽の推薦を行う。本研究のシステムは、従来の感情を考慮しない推薦システムと比較し、ユーザの心理的満足度や体験価値を大幅に向上させる可能性があり、ネガティブ感情を緩和しポジティブ感情を促進する音楽の影響を活用することで、メンタルヘルスの向上にも寄与することが期待される。

§ 2.2 音楽が感情・心理に与える影響

現在の社会は、ストレスの多い社会といわれており、そのような中で、リラクゼーションに関する関心が高まっている。その方法の一つとして音楽があげられる。音楽は古くから、人々の心や体に癒しを与える手段として親しまれており、その音楽が持つ感情調整の効果を活用した治療法が、近年さらに広がりをみせている。その代表的なものが音楽療法である。音楽療法とは、音楽を用いて心身の健康を促進し、治療やリハビリテーションに役立てる療法のことである。音楽のリズム、歌詞、テンポなどが感情や身体的な状態に影響を与える力を活かし、感情的、精神的、身体的な問題を改善することを目的としている [8]。

音楽療法は、主に「能動的音楽療法」と「受動的音楽療法」に分類される。それぞれのイメージを図2.3に示す。能動的音楽療法は、音楽を自分で演奏したり歌ったりすることを通じて、感情や身体の表現を促す手法である。患者が音楽を作り出す過程で、自己表現や創造性を発揮でき、感情の解放や心理的な安定を得ることができる。この方法は、特に心的外傷を抱えた患者やストレスを感じている人々に効果的とされており、音楽を演奏することで、感情の整理が進み、身体的な緊張も緩和されることが多い。

一方、受動的音楽療法は、音楽を聞くことによってリラクゼーションや心理的な回復を促進する方法である。音楽を聞くことによって、リラックスや集中を促し、感情のバランスを整えることができる。受動的音楽療法は、身体的なリラックスを促進し、精神的な安定を得るために広く活用されている [9]。

本研究では受動的音楽療法の観点から、ユーザのネガティブな感情の強度に基づいて音楽を推薦するシステムを提案する。ユーザの感情状態に対応した音楽を推薦することで、効果的に気分の向上を図る。以下に、音楽を聞くことによる生理的・心理的影響を述べたのち、本研究で考慮する音楽の特徴量とそれによる感情の影響を述べる。

音楽は人間の感情や心理状況に大きな影響を与えることが音楽心理学の研究において広く示されている。音楽が人間心理に与える影響には、生理的な反応から心理的な効果まで、さまざまな側面がある。

集中力と記憶力の向上

音楽を聞くことにより、認知能力を向上させることができることが研究によって示されている。特に、バックグラウンドミュージックは認知能力を強化することが示されている。高齢者を対象にした研究では、明るい音楽が処理速度を向上させ、穏やかな音楽が記憶力を改善する効果があることが示された。また、学生を対象にした研究では、クラシック音楽を聴きながら勉強することで、記憶保持力が高まり、試験の成績が向上したという結果が報告されている。[10]



図 2.3: 音楽療法の種類



図 2.4: 情報推薦システムの分類

ストレスの軽減

音楽を聴くことは、ストレスホルモンであるコルチゾールの値が減少するだけでなく、心拍数や血圧を調整することがわかっている。手術前の患者を対象とした研究では、音楽を聴くことでコルチゾールレベルが低下し、リラックス効果が確認された。日常生活でのストレスにおいても、リラックスできる音楽を聞くことがストレス軽減に貢献するとされている [11]。

気分の向上

音楽を聴くことにより、不安を和らげ、気分を向上させることができる。明るくポジティブなメロディーや歌詞は、幸福感や満足感を促進し、気分を向上させる効果がある。アップテンポの音楽やポジティブな歌詞を聴くことで、セロトニンやドーパミンなどの「幸福ホルモン」が分泌される [12]

音楽の感情的効果はいくつかの特徴量に影響される。主な特徴量として、テンポ、曲調(メジャー、マイナーなど)、エネルギー、アコースティック性、そして歌詞の内容が挙げられる。

テンポにおける感情的効果

テンポは1分間の拍数(BPM)で測定される。テンポは、その違い(早いテンポ、遅いテンポ)によって感情に影響を与える。120BPM以上の速いテンポの曲は喜びや興奮、活気を喚起され、60~120BPMの中程度のテンポは安定感と穏やかな気分に誘導し、リラックスしながら集中力を保てる状態をもたらす。また、60BPM以下の遅いテンポの曲は副交感神経を活性化させ、深いリラクゼーションを促進させる。このような効果は脳の活動にも影響され、早いテンポでは側頭葉の活性化が強まり、遅いテンポでは心拍数や血圧の低下がみられる。また、中程度のテンポの音楽は、特に聴覚皮質や感情記憶に関連する脳領域を活性化し、強い感情的覚醒をもたらすとされる [13]。

曲調における感情的効果

音楽の曲調(メジャー・マイナー)によって感情に影響を与えることがいくつかの研究によって示されている。軽度のネガティブ感情を抱える人々に対しては、長調(メジャーキー)な曲が感情を改善し、ポジティブな感情を喚起することが示されている。例えば、メジャー調や高テンポの音楽が、リラックス効果やエネルギーの向上をもたらすとされる [14]。

らし、ネガティブな感情を軽減することが確認されている。長調の音楽は、聴衆に活力を与え、心理的なストレスを緩和する効果が期待される。

一方で、深刻な悲しみやうつ病状態のような極度にネガティブな感情を抱えている場合、長調よりも短調の方がより効果的に穏やかでリラックスできる音楽を提供することができる。一般的に、長調の音楽は明るく快活な印象を与え、ポジティブな感情を喚起しやすく、短調の音楽は、より内省的で落ち着いた雰囲気を持ち、感情を穏やかに整える効果があるとされている特に、深刻な悲しみやうつ病のような状況では、過度にポジティブな音楽が逆に感情の圧迫感や不安感を引き起こす可能性があるため、感情の急激な変化を避けるためにも、リラックスできる短調の音楽が適していると考えられる [14]。

また、他の研究によれば、短調の音楽は心理的な安定感を高め、過度の感情的な変化を防ぐ効果があるとされている。具体的には、短調の音楽が聴く人の心を落ち着かせ、心拍数や呼吸数を安定させることができることが示されており、これにより、リラクゼーションやストレス軽減が促進されるとされている。また、悲しみや絶望感といった強いネガティブ感情に直面した人々に対しては、短調の音楽が感情の調整をスムーズに行い、無理なく心を落ち着ける助けとなる [15]。

エネルギーにおける感情的効果

エネルギーは音楽が持つ「活力」や「力強さ」を示す指標であり、音楽のリズム、音量、テンポなどに関連している。高エネルギーの音楽は、活気に満ちたリズムとメロディーによってリスナーの気分を明るくし、エネルギーッシュな感情を引き起こす。これにより、喜び、興奮、活力といった感情を感じやすくなり、ポジティブな心情を促進する。一方、低エネルギーの音楽は、リズムが遅く、メロディーやハーモニーが穏やかで、音量も控えめである。低エネルギーの音楽は、心拍数を下げ、リラックス効果を高めるため、ストレスや緊張を緩和する効果がある。

アコースティック性における感情的効果

アコースティック性とは、曲がどれだけ自然な楽器の音、または生音に近いかを示す指標のことである。アコースティック性が高い音楽は、ギター、ピアノ、弦楽器、ドラムなど、生楽器を主体とした音が使用されており、自然で心地よい音色であることが特徴である。また、多くの研究において、アコースティック性が高い音楽が感情のバランスをとる助けになることが示されている。例えば、アコースティック性の高い音楽がストレスホルモンであるコルチゾールの分泌を減少させ、心理的な安定感を高める効果があることが示されている [16]。また、armonyによる研究でも、アコースティック性が高い音楽が感情の調整に有効であることが確認されている。これらの研究からも、アコースティック音楽が心理的な安定や感情の調整に有効であることが示唆されている [17]。特に、アコースティック性の高い音楽はリラクゼーション効果が高く、心拍数や血圧の低下を促すため、ネガティブな感情が強い状態にある場合に聴くことでリラックスを促し、気分が改善されることが期待される。一方で、アコースティック性が低い音楽は、エレクトロニック音楽やシンセサイザーを多く使用した音楽を指し、リズムやビートが強調され、感情に強い影響を与える。このような音楽は、活力や興奮を促進し、身体的にも精神的にもエネルギーを増加させる効果がある。特

に、ネガティブな感情が少ない人は、アコースティック性が低い音楽のエネルギーを受け入れやすく、ポジティブな感情を高めることができる。逆に、ネガティブ度合いが高い人には、アコースティック性が低い音楽を聞くことはあまり効果的ではないとされている。特に、心の状態が不安定である場合、このような音楽は感情をさらに乱す可能性があり、リラックスや心理的な安定を促進するには適していない。

歌詞における感情的効果

曲の歌詞は、感情に影響を与えることが示されており、その影響の度合いは感情値により異なる。ポジティブな歌詞の音楽を聞くことにより、ネガティブな感情を軽減する効果について、多くの研究が示している。例えば、Juslin & Smith, Jの研究では、ポジティブな感情を表現する歌詞（「愛」「幸せ」など）が幸福感や満足感を引き起こし、心の状態を改善することを示している [18]。歌詞の感情的な内容が感情に与える影響は大きく、ポジティブな感情を持つ歌詞は、気分を向上させ、ストレスや不安を軽減する効果があることが示されている。

一方、ネガティブな歌詞は共感を与えることもあるが、特に感情的に不安定な状態にある人々には、より感情を不安定にしてしまう可能性がある。Soleymani et al. の研究によると、ネガティブな歌詞は共感を誘発する一方で、過度にネガティブな感情を抱える人々にとって、感情をさらに深める結果となり得ることを示唆している [19]。

ここまで、音楽の特徴量が感情に与える影響について述べてきたが、音楽の効果は、その時に聴く人の現在の感情状態に大きく依存する。音楽による気分の変化について、同質の原理（Iso-principle）という考え方方が提唱されている [20]。

同質の原理

同質の原理とは、人が自分の感情状態に似た特徴を持つ音楽を選び、その音楽を聞くことで感情を安定させる効果を持つ原理である。例えば、ネガティブな感情を抱えている場合には、その感情に同調するような音楽を聞くことで、感情的な一致感が生まれ、リラクゼーションや感情の調整が進むとされる。

同質の原理は、ネガティブな感情状態にある場合には、ポジティブな音楽よりもネガティブな感情に同調する音楽が効果的であることを示唆している。例えば、深い悲しみや落ち込みを感じている人が、明るく活発な音楽を聞いても、その音楽が感情的に異質に感じられることがある。この場合、感情的に明るい音楽は逆に不快に感じ、気分転換の効果が薄れる可能性がある。逆に、悲しい気分を持っている場合、暗い音楽を聞くことで感情的な一致感が生まれ、その後にポジティブな感情に移行する助けになると考えられる。

同質の原理は、音楽推薦による気分誘導にとって重要な概念である。ネガティブな感情を持つユーザに対して、無理にポジティブな音楽を薦めるのではなく、感情的に一致する音楽を選ぶことで、感情の調整が促され、最終的にポジティブな感情への移行をサポートすることができる。このように、感情の強さや状態に合わせた音楽推薦を行うことで、効果的に感情の調整を行うことが可能になる。

本研究では同質の原理に基づき、ユーザのネガティブ度合に応じた音楽の推薦を行う。具体的には、ネガティブ強度が強い場合には感情的に一致する特徴量を持つ音楽を推薦することで、ユーザが自分の感情と調和し、リラックスや心の安定を促進できるようにする。

また、ネガティブ度合が中程度または低い場合には、少しポジティブな特徴量を持つ音楽を選択し、少しずつ気分を高めるような音楽を推薦する。これにより、最終的に気分の向上をサポートする。

§ 2.3 感情分析の手法及び研究事例

感情分析とは自然言語処理の分野の一つであり、データから人々の感情的な状態や意図を抽出し、それを定量的・定性的に分析する技術のことである。感情分析の対象は、テキストや音声、映像、生体情報などがある。各感情分析の比較を表2.2に示す。分析テキストによる分析では文章に含まれている単語や表現を分析することで、書き手の感情分析する。音声による感情分析では声の抑揚や声の大きさを分析することで話し手の感情を分析する。人間の感情表現は非言語による部分が大きいため、音声分析では、テキストでは読み取れない情報を読み取れることがある。また、映像による分析では顔の表情や顔の筋肉の動きを分析することで対象の感情を分析する。映像による分析では音声に頼らずに感情をとらえるため、視線やジェスチャーなどの言葉を使わない感情表現を分析することができる。生体による分析では脳波や脈拍などの生体データを分析する。生体反応は無意識的に起こるため、生体による分析は感情を客観的に分析することができる。

感情分析の手法は大きく分けて「ルールベースによる手法」、「機械学習による手法」、「深層学習による手法」3つのアプローチがある[21]。以下にそれぞれの手法の概要及び特徴について説明する。

1. ルールベースによる手法

ルールベースによる手法は、前持つて定義された一連のルールを用いて感情を分析する手法である。ルールの定義自体は、基本的に人間が手動で行う。特徴としては、比較的簡単に実装できる一方、複雑な感情表現や大規模データへの対応が難しいという欠点がある。

テキストにおけるルールベースによる手法は、感情極性辞書を用いて感情を分析する。感情極性辞書とは、単語に対して感情のスコア（「良い:0.999995、悪い:-1など」）が割り振られた辞書であり、この辞書をもとにテキスト全体の感情スコアを集計し感情を推定する。日本語の感情分析で使われる感情極性辞書は単語感情極性対応表[23]と日本語感情極性辞書がある[24]。

音声データでは、音響特徴（例：ピッチ、テンポ、音量）に基づく閾値ルールを用いる。例えば、高音量で急なテンポ変化が「怒り」を示し、低音量で緩やかなテンポが「悲しみ」を示すといったルールを構築し、抽出された音声特徴とルールに基づいて感情カテゴリを分類する[25]。

画像データ、特に顔画像においては、眉や口角の位置といった表情特徴に基づくルールを設定する。有名な画像の感情分析におけるルールとして、Facial Action Coding System (FACS)に基づくルール方式がある。FACSには、顔の筋肉の動きを定義し、それらの組み合わせで特定の感情を表現するというものである。例えば、喜びは口角の上昇と頬の上がりを伴う表情であり、これらの筋肉の動きを観察することによって「喜び」と識別できる。また、怒りは眉が下がり、中央に寄るとともに、唇が強く閉じられるという特徴を示し、これをもとに「怒り」の感情を分類することができる[26]。

表 2.2: 各感情分析の比較 [22]

感情分析の種類		分析対象	読み取れる感情	活用例
音声	声の抑揚 声の大きさ		平穏 幸福 怒り 悲しみ 恐怖	電話口での怒りの感情から対応方法を判断
テキスト	単語		喜び 悲しみ 怒り おそれ 驚き 嫌悪	口コミから「ネガティブ」「ポジティブ」に分類して集計、商品改善に活かす
画像	顔の表情		怒り 驚き 嫌悪 おそれ 喜び 悲しみ	ドライバーの感情を表情で判定、あおり運転や居眠り運転などを未然に回避
生体情報	脳波 脈拍 発汗		快・不快 覚醒度合い 怒り 喜び 悲しみ	授業中の生徒の脈拍から集中度をチェックし、生徒の状態に合わせて授業を実施

生体データでは、脳波測定や心拍センサにより取得できた特徴量に対して閾値を設定する。例えば、ストレス状態の場合はコルチゾールの値を、リラックスしている場合はオキシトシンの数値や心拍の変動をもとに感情を数値化する [27]。

ルールベースの手法は、感情分析における簡易的なアプローチとして、基本的でわかりやすい特徴を基にしているが、画像データや音声データにおける多様で複雑な表現には限界があり、機械学習や深層学習などのより高度な手法と組み合わせて使用されることが多い。

2. 機械学習による手法

機械学習による手法は、データからパターンや規則を学習し、未知のデータに対して予測を行う教師あり学習を用いた手法である。教師あり学習とは、入力データとその対応する正解ラベル（教師データ）がペアで与えられ、分類器が入力データの特徴と正解ラベルの関連性を学び、未見のデータに対しても正しい予測を行えるように訓練される手法である。

機械学習による手法においては、まずデータから適切な特徴量を抽出し、それを分析器に入力して分析を行う。特徴量とは、データが持つ重要な情報を数値やベクトル形式で表現したものである。例えば、テキストデータであれば、TF-IDF や Bag of Words などの方法を使用して単語の頻度を特徴量として抽出し、感情分析やトピック分類を行う。

画像データの場合、Haar-Like 特徴量を用いて画像における明暗差の集合を特徴量として抽出し、顔認識や物体分類、感情の表情分析を行う。

音声データにおいては、声の高さや速さ、周波数、強度などを特徴量とする。声の周波数、強度はフーリエ変換を用いることにより波長へ変換され特徴量として抽出される [25]。

また、生体データでは、デルタ波、シータ波、アルファ波などの周波数帯域別のパワーや心拍数などの特徴量を使用する。特徴量抽出には脳波測定機器や心拍センサなどを用いる。

これらの特徴量を基に、SVM（サポートベクターマシン）やランダムフォレスト、k-NN（k 近傍法）などの機械学習アルゴリズムを使用して感情分析が行われる。これらのアルゴリズムは、与えられた特徴量と対応する感情ラベルを学習し、新たなデータに対して感情を予測するために用いられる。

SVM

サポートベクターマシン (Support Vector Machine:SVM) は、異なるクラスを分けるための最適な境界（決定境界）を見つけ、データの分類を行う。この決定境界は、クラス間のマージンを最大化するように設計されており、データがどのクラスに属するかを予測するために使用される。

ランダムフォレスト

ランダムフォレスト (Random Forest:RF) は、多数の決定木を組み合わせて分類を行

う手法で、個々の決定木の予測を集約することで高い予測精度を実現する。複数の木を使うため、過学習を防ぐことができ、特に複雑なデータに有効である。

k-近傍法

k-近傍法 (k-nearest neighbor algorithm:K-NN)、データポイントを特徴量に基づいて他のデータポイントと比較し、最も近いk個のデータのラベルを基に予測を行うシンプルなアルゴリズムである。感情分析では、特徴量に基づいて感情ラベルを決定するために使用される。

感情分析の場合、この教師あり学習を活用して、感情ラベル（例えば、ネガティブ、ニュートラルなどの2値クラスラベルや喜び、驚き、悲しみ、怒り、恐怖、嫌悪などの多クラスラベルなど）が付与された大量のデータを使ってモデルを訓練し、入力データを各ラベルに分類する。

3. 深層学習による手法

深層学習による手法は、人工神経ネットワークを基盤にした手法で、特に大規模なデータセットを使って非常に高精度な感情分析を実現する方法である。従来の機械学習手法と比較して、深層学習は特徴量抽出とモデル学習を同時に行う能力があり、これにより手作業で特徴量を設計する必要がなくなる。また、深層学習は複雑で非線形な関係を学習することができ、テキスト、音声、画像、そして生体データにおいて高い性能を発揮する。

深層学習による感情分析には、主に以下の3つのアーキテクチャが使用される。

RNN,LSTM

RNN(Recurrent Neural Network)は、音声などの時系列データや文章など、順序が重要なデータを扱うために設計されたニューラルネットワークである。従来のニューラルネットワークでは、入力データの長さが固定である必要があったが、RNNは各時点の出力を次の時点の入力にフィードバックする構造を持つため、データ間の時系列的な依存関係を捉えることが可能である。ただし、長い時系列データにおいては、情報が時間の経過とともに失われる「勾配消失問題」が生じるという欠点がある。

LSTM(Long Short Term Memory)は、RNNを改良したものであり、RNNが長期的に情報を保持できない問題を解消している。LSTMは不要な過去の情報を削除する忘却ゲート、与えられた情報の重要性を記憶する入力ゲート、記憶された情報のうち必要な部分だけを外部に伝える出力ゲートという3つのゲートを備えることにより、長期的な依存関係を学習している。

CNN

CNN(Convolutional Neural Network)は、畳み込みを使用するニューラルネットワークであり、画像や音声などに適用可能である。畳み込みとは、入力データに対してフィルター（カーネル）を適用する処理である。フィルターは、データの局所的な領域（例えば、画像の小さな部分や音声の一部）に対してスライドし、その領域内の特徴を抽出する。畳み込み操作は、入力データとフィルターを重ね合わせ、出力を生成する。この操作によって、フィルターは画像のエッジや音声の特定の音の特徴を捉え、ネットワークが重要なパターンを学習できるようにする。

Transformer

近年、翻訳などの入力文章を別の文章で出力するというモデルは、Attention を用いたエンコーダー、デコーダ形式の RNN が主流であった。しかし RNN や LSTM は逐次的に単語を処理しているため、訓練時に並列処理ができないという欠点があった。それに対し Transformer は、RNN や CNN を用いず Attention のみを用いている。Transformer は、再帰も疊み込みも一切行わないので並列化が容易であり、他のタスクにも汎用性が高いという特徴がある。

機械学習と深層学習の主な違いは、特徴量の抽出方法とモデル学習のアプローチにある。機械学習では、データから有用な特徴量を手作業で設計・抽出し、それらの特徴量を基にモデルを訓練する。一方、深層学習では、特徴量の抽出とモデル学習が一体となって行われ、データから直接重要な特徴を自動的に学習する。

感情分析の応用事例

理論の説明

§ 3.1 テキストからの感情分析

BERT の技術的説明を書く。

BERT

BERT は、Google が提案した自然言語処理モデルの一つであり、Transformer の Encoder 部分を基盤とし、Attention メカニズムを用いて単語間の関係性をモデル化している。BERT による処理の流れを図 3.1 に示す。BERT は双方向の Transformer アーキテクチャを持っていることが最大の特徴であり、文脈を考慮して単語の意味を理解することができる。また、BERT は、テキスト内の単語の位置情報を学習することができるため、単語の順序を考慮した文脈理解が可能である。これにより、文書分類、質問応答、言語翻訳など、様々な自然言語処理タスクに応用されている。BERT は、大規模なコーパスから事前に学習されたモデルであり、学習済みのモデルを転移学習することで、より小規模なデータセットでも高い精度で処理することができる。

BERT のモデルである Transformer はベクトル化された文章を入力とし、Attention を多数並列に配置した Multi-Head Attention が用いて分析を行っている。

BERT における入力部分

言語を用いたタスクを解く際には、モデルが言語を扱えるように数値化する必要がある。BERT では、まず MeCab を使用して文を単語に分割し、その後 WordPiece を用いて単語をさらにトークンに分割する。BERT の日本語モデルでは、32,000 個のトークンが定義されており、各トークンには固有の ID が割り振られている。BERT への入力時には、このトークン ID が使用される。トークン ID に変換されたデータは、BERT モデルに入力される前に、Input の先頭に [CLS] トークンを、文の終わりに [SEP] トークンを追加しする。そして、以下の 3 種類の埋め込みを加えることで、モデルに適した数値ベクトルとして表現される。また、BERT の入力部分を図 3.2 に示す。

1. トークンの埋め込み

トークンごとに、事前学習された埋め込み行列 $\mathbf{E} \in \mathbb{R}^{|V| \times d}$ を用いてベクトル表現に変換する。ここで、 $|V|$ は語彙サイズ、 d は埋め込みベクトルの次元である。各トークン ID t_i に対応する埋め込みベクトル \mathbf{e}_i は次のように定義される。 \mathbf{e}_i は、語彙内のトークンの意味的な特徴を学習した固定長ベクトルである。

$$\mathbf{e}_i = \mathbf{E}[t_i] \quad (3.1)$$

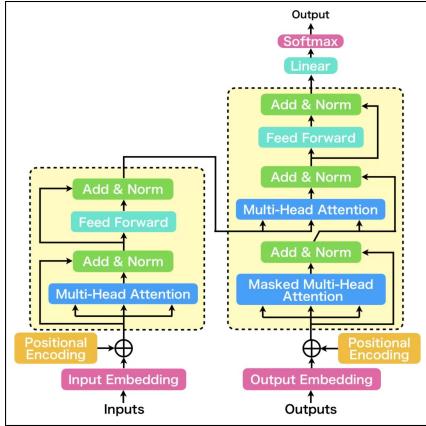


図 3.1: BERT の流れ

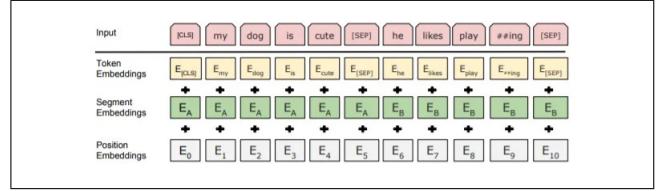


図 3.2: BERT の入力部分

2. 位置埋め込み

トークン埋め込みを行っただけでは入力の順序に関する情報を持たないため、文章を正しく扱えない。そのため、トークン列内での順序情報をモデルに追加するため、位置埋め込みを加える。位置埋め込み行列は $\mathbf{P} \in \mathbb{R}^{n \times d}$ として定義され、各位置 i に対応するベクトル \mathbf{p}_i は次のように計算される。ここで、 pos はトークンの位置 (0, 1, 2, ...) 、 i は埋め込み次元のインデックスである。これにより、固定長の埋め込みベクトルを用いながら、トークンの相対的な順序や距離をモデルが学習可能となる。

$$\mathbf{p}_{(pos, 2i)} = \sin \left(\frac{pos}{10000^{\frac{2i+1}{d_{model}}}} \right), \quad \mathbf{p}_{(pos, 2i+1)} = \cos \left(\frac{pos}{10000^{\frac{2i}{d_{model}}}} \right) \quad (3.2)$$

3. セグメント埋め込み

BERT では、1つの入力が單一文か複数文かを区別するために、セグメント埋め込みを使用する。各トークンには、対応するセグメント ID s_i (文1なら 0、文2なら 1) が割り振られ、埋め込みベクトルは以下のように計算される。

$$\mathbf{s}_i = \mathbf{S}[s_i] \quad (3.3)$$

ここで、 $\mathbf{S} \in \mathbb{R}^{2 \times d}$ はセグメント埋め込み行列であり、 s_i が 0 または 1 に応じて適切なベクトルが選択される。

4. 埋め込みベクトルの統合

最終的に、トークン埋め込み、位置埋め込み、セグメント埋め込みを加算して、モデルに入力するベクトル \mathbf{x}_i を生成する。

$$\mathbf{x}_i = \mathbf{e}_i + \mathbf{p}_i + \mathbf{s}_i \quad (3.4)$$

これにより、各トークンには、その意味 (トークン埋め込み)、位置 (位置埋め込み)、文区別 (セグメント埋め込み) の情報が含まれるベクトルが追加される。

Attention

Attention は、入力の各トークンが他のすべてのトークンにどれだけ関連しているかを学習するメカニズムであり、この機構は、一般的に自己注意 (Self-Attention) として知られている。Self-Attention では、各トークンの埋め込みベクトルを Query、Key、および Value という 3 つのベクトルに変換し、その相関関係を計算して、重み付けされた値を集約する。Query、Key、および Value は入力単語 \mathbf{x}_i にそれぞれの重み W_Q 、 W_K 、 W_V を用いて以下の式で定式化される。

$$\mathbf{Q}_i = W_Q \cdot \mathbf{x}_i, \quad \mathbf{K}_i = W_K \cdot \mathbf{x}_i, \quad \mathbf{V}_i = W_V \cdot \mathbf{x}_i \quad (3.5)$$

また、3 つの相関関係は各トークンのクエリとキーとの内積を計算することで求めることができます。

$$score(Q_i, K_j) = \frac{\mathbf{Q}_i \mathbf{K}_j^T}{\sqrt{d_k}} \quad (3.6)$$

ここで、 d_k は Query と key の次元数である。得られた式にソフトマックス関数を適応し、 V_i を付加重することによって Attention を求めることができる。

$$Attention(Q, K, V) = \text{softmax}\left(\frac{\mathbf{Q} \mathbf{K}^T}{\sqrt{d_k}}\right) \mathbf{V} \quad (3.7)$$

Multi-Head Attention

Attention は一つの計算を逐次的に行っているため、1 つの視点からしか文脈を読み取ることができない。これに対し、Multi-Head Attention は複数の Attention を並列に連結して出力を得る。これにより、情報の多様な側面を同時に捉えることができる。Multi-Head Attention は以下の式で定式化される。

$$Multi-HeadAttention(Q, K, V) = \text{Concat}(\text{head}_1, \text{head}_2, \dots, \text{head}_h)W_o \quad (3.8)$$

$$\text{where } \text{head}_i = \text{Attention}(QW_i^Q, KW_i^K, VW_i^V) \quad (3.9)$$

Feed-Forward Neural Network(FFNN)

Transformer の Encoder と Decoder の最後の層にあるサブレイヤーである。FFNN は、入力データをより高次元の表現に変換するために使用され、モデル内で非線形な変換を行う。

FFNN は全結合層 W_1 、活性化関数 (ReLU)、全結合層 W_2 の 3 つの層で構成される。

第 1 層 (全結合層)

Multi-Head Attention から入力ベクトルを受け取り、高次元の中間層（通常は 2048 次元など）に変換する。高次元に変換することで、モデルが学習する表現空間が広がり、より複雑で多様な関数を学習することができる。

第 2 層 (ReLU 活性化関数)

第 1 層の出力に非線形活性化関数である ReLU を適用する。これにより、非線形性を導入し、モデルがより複雑な関数を学習できるようにする。

第3層（全結合層）

高次元の中間層を、元の入力と同じ次元に戻す。この層は、元の入力次元数に戻すことによって、最終的な出力を得る役割がある

FFNNは入力された情報を高次元で表現し、非線形活性化関数を経て、最終的に入力次元に戻すことで、モデルが表現できる情報の範囲を広げることができる。Attention層は文全体の位置関係を学習するのに優れているが、各トークンの詳細な特徴量を捉えることに欠けている。FFNNによって各トークンが持つ情報量を増やすことができ、入力された特徴量から複雑な関係性を学習することができる [28]。FFNNを通過した後、最終層では学習されたベクトルが出力される。このベクトルを用い、感情分析などをの様々タスクへ応用させる。

モデルの学習方法

BERTは、事前学習を行うことで、一般的な言語の文脈を理解する。ここでは、BERTは大規模なテキストコーパス（Wikipedia や BooksCorpus など）を使って、自己教師あり学習を行います。事前学習では、主に2つのタスクが用いられる。

事前学習

事前学習では、BERTは Masked Language Modeling (MLM) と Next Sentence Prediction (NSP) という2つのタスクを使ってモデルを訓練する。MLMでは、入力文の中でランダムに選ばれた単語を「[MASK]」トークンで置き換え、モデルにその単語を予測させる。MLMにおいて、Multi-Head Attentionは文脈を双方向的に考慮し、マスクされた単語を予測する。NSPでは、2つの文が連続しているかどうかを予測する。このタスクによって、BERTは文間の関係を理解し、文章全体の構造を把握できるようになる。例えば、文Aと文Bが連続している場合は「1」を、連続していない場合は「0」を予測する。

ファインチューニング

事前学習後、BERTは特定のタスクにファインチューニングされる。ファインチューニングとは、事前学習で得られた重みをベースに、特定のタスク（感情分析や質問応答）に最適化する工程である。

最終層の出力と感情予測

最後の層で出力する特徴量は解くタスクによって異なる。感情分析においては、BERTの最終層から [CLS] トークンの特徴量を使用する。[CLS] は文章全体の埋め込みベクトルであり、文全体の特徴を含んだベクトルである。出力されたベクトルを、全結合層に入力し、シグモイド関数を用いることで各クラスのスコアを0~1の範囲に正規化され、感情スコアとして出力される [29]。

本研究では、BERTを用いて歌詞の感情値(0~1の連続値)を分析する。また、その分析結果を楽曲の感情値とし、楽曲の特徴量として加える。

§ 3.2 画像からの感情分析

ユーザの感情を分析する技術として、顔認証技術を用いた手法がある。顔認証とは、顔の特徴を解析して、特定の人物を識別したり、感情を推定したりする技術のことである。顔認証は、物理的な特徴（目、鼻、口、顔の輪郭など）をもとに、個人を識別するために使用されることが多いが、感情分析では顔の表情に基づいて感情を推定する。本研究ではDeepFaceを用い、カメラ映像からユーザの6つの感情極性（「怒り」「悲しみ」「喜び」「驚き」「恐れ」「嫌悪」）を検出する。そして、それぞれのスコアをもとにユーザのネガティブ強度を算出する。以下より、DeepfaceのモデルおよびDeepFaceの感情分析の流れを説明する。

DeepFace

DeepFaceは、Facebookが開発したディープラーニングモデルであり、9層の畠み込みニューラルネットワーク（CNN）を基盤を使用して顔の識別を行っている。また、モデルの学習の際にfacebookの大量の画像データを学習させることにより、人と同等レベルの認識精度を実現した [30]。

Deepfaceは「顔検出」、「3Dアライメント」、「顔特徴の抽出」、「パラメータの学習」の4つの工程により感情分析を行うことができる。

1. 顔検出

顔検出は入力映像から顔を検出する処理である。顔検出では、画像内の顔の位置と大きさを特定し、検出された顔をトリミングして次の処理（顔特徴抽出や感情推定）を行う。DeepFaceでは複数の既存の顔検出モデルを選択することができ（図3.3）、「Haarカスケード分類器」と「MTCNN（Multi-task Cascaded Convolutional Networks）」が一般的に使われる [31]。

2.3Dアライメント

顔検出によって得られた顔部分は、位置や角度によってバラバラな場合がある。このバラバラになった顔を正面に向くように補正する処理を顔アライメントという。従来の2Dアライメントでは、顔が回転している場合や非正面向きの場合に十分な補正ができないという課題があった。この課題を解決するため、DeepFaceでは3Dアライメント技術を導入している [31]。3Dアライメントの例を図3.7に示す。3Dアライメントでは、まず顔画像内から67個の特徴点を検出する（図3.7.(c)）。平均的な顔の3Dモデル（図3.7.(d)）を使用し、画像内の特徴量と対応付けを行う（3.7.(f)）。対応付けを行った3Dモデルをアフィン変換を行い、2D平面に投影する（3.7.(g)）。アフィン変換とは、画像の拡大縮小、回転、平行移動などを行列を使って座標を変換することである [32]。この処理によって顔認識や感情分析がより高精度に行うことができる。

3. 特徴量の抽出

ここでは、DeepFaceの9層の畠み込みニューラルネットワークを用いて、前工程の処理で抽出した顔の画像から高次元の特徴ベクトルを抽出する工程である。

DeepFaceは入力層、畠み込み層（C1）、マックスプーリング層（M2）、畠み込み層（C3）、ローカル接続層（L4、L5、L6）、全結合層（F7、F8）の9層で構成されている [33]。

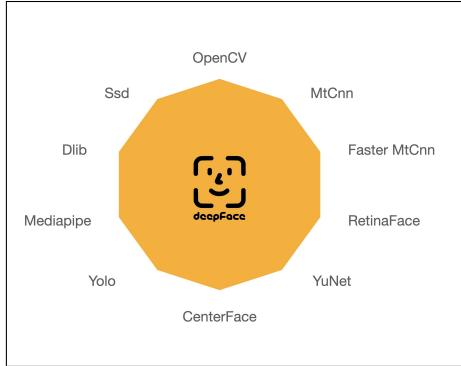


図 3.3: deepface で利用できる顔検出の種類

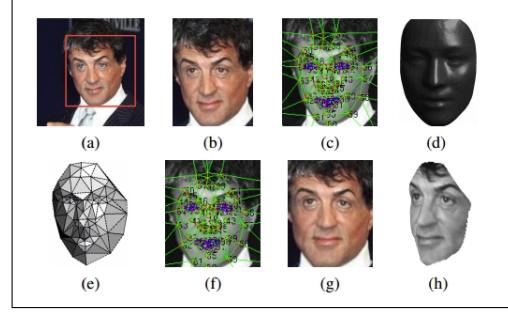


図 3.4: 3D アライメント [30]

入力層

入力層は、顔画像が読み込まれる層である。入力は、3D アライメントで抽出した正面化された顔画像である。入力の際、顔画像のサイズを 152×152 ピクセルに固定され、RGB 画像として 3 チャンネルのデータとして入力される。入力画像を X とすると以下のようにあらわされる。

$$X \in \mathbb{R}^{152 \times 152 \times 3} \quad (3.10)$$

畳み込み層 (C1、C3)

畳み込み層は、入力画像から局所的な特徴を抽出する処理を行う層である。畳み込み層では、入力画像に対してフィルタ (カーネル) をスライドさせながら畳み込み演算を適応し、特徴マップを作成する。畳み込み層 l の出力 (フィルタ k の位置 (i, j) の値) を $F_{i,j,k}^{(l)}$ 、畳み込み層 l のフィルタ k の重みを $W_{m,n,c,k}^{(l)}$ 、前層の出力 (または入力画像) におけるピクセル値を $I_{i+m,j+n,c}^{(l-1)}$ 、フィルタ k に対応するバイアス項を $b_k^{(l)}$ 、活性化関数を $\sigma(x)$ とすると畳み込み演算は以下のようであらわされる。

$$F_{i,j,k}^{(l)} = \sigma \left(\sum_{c=1}^C \sum_{m=1}^H \sum_{n=1}^W W_{m,n,c,k}^{(l)} \cdot I_{i+m,j+n,c}^{(l-1)} + b_k^{(l)} \right) \quad (3.11)$$

C1 層は、RGB 画像 (サイズ $152 \times 152 \times 3$) に適用される最初の畳み込み層である。フィルタサイズは 11×11 、フィルタ数は 32 である。ここでは、 $152 \times 152 \times 3$ の画像に対して 11×11 サイズの 32 個のフィルタをそれぞれ 1 ピクセルごとにスライドさせ、32 個の異なる特徴量を抽出している。また、畳み込み処理を行ったとき、入力画像のサイズを W 、フィルタのサイズを K 、パディングサイズを P (画像の境界に追加するピクセルの数)、ストライド (フィルターが画像上を移動するステップ数) を S 、出力サイズを H_{out} は以下の式で求められる [35]。

$$H = \frac{W - K + 2P}{S} + 1 \quad (3.12)$$

式 (3.12) により、C1 層では 142×142 の 32 個の異なる特徴マップが出力される [34]。畳み込み層によって得られた出力は活性化関数が適応される。DeepFace では ReLU が用いられている。ReLU は、入力が正の値であればそのまま出力し、負の値に対しては 0 を出

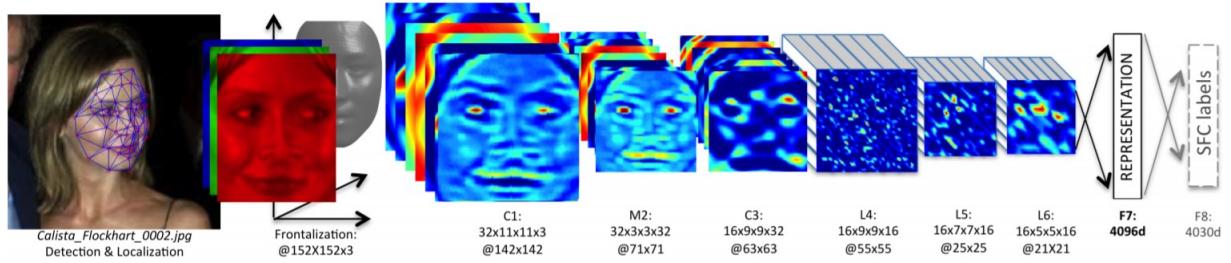


図 3.5: モデル [30]

力する非線形活性化関数である。これにより、ネットワークが複雑な特徴を学習できるようにし、勾配消失問題を避け、計算効率を向上させる。

マックスプーリング層 (M2)

マックスプーリング層は C1 層からの出力に対してプーリング操作を行う層である。プーリングは、特徴マップのサイズを縮小する操作であり、計算コストを削減しながら、空間的な情報を効率よく保持するために使用される。M2 層では、主にマックスプーリングという手法が用いられる。マックスプーリングとは、特徴マップを一定のサイズの領域でスライドさせ、その領域内の最大値を選び出して特徴マップを縮小する手法である。

プーリングサイズは 3×3 、ストライドは 2 である。ここでは、C1 層からの特徴マップ $142 \times 142 \times 32$ を 3×3 の領域でスライドさせ、各領域内の最大値を選択することで、出力の特徴マップのサイズを縮小する。縮小サイズは式 (3.12) により $71 \times 71 \times 32$ に縮小する。

畳み込み層 (C3)

C3 層は、C1 層から得られた特徴マップ適用される畳み込み層である。フィルタサイズは 9×9 、フィルター数は 16 である。これを入力特徴マップ (サイズ $71 \times 71 \times 32$) に対して局所的な特徴を抽出する。縮小サイズは式 (3.12) により $63 \times 63 \times 16$ となる。これにより、前の層で得られた特徴をさらに複雑なパターンに変換する。

ローカル結合層 (L4、L5、L6)

ローカル結合層は各入力位置に対して異なるセットのフィルタを適応する層である。畳み込み層は、全ての位置で同じフィルタを適用するが、ローカル結合層では、位置に対応するフィルタ重みがその位置固有のものになる。出力特徴マップの位置 (i, j) とチャネル k における値を $h_{i,j,k}$ 、入力特徴マップの位置 $(i+m, j+n)$ とチャネル c における値を $X_{i+m,j+n,c}$ 、各空間位置 (i, j) に固有のフィルタ重みを $W_{i,j,m,n,c,k}$ 、各空間位置 (i, j) に固有のバイアス項を $b_{i,j,k}$ 、フィルタの高さと幅を H_f, W_f 、入力特徴マップのチャンネル数をとすると以下の式で求められる。

$$h_{i,j,k} = \sum_{m=1}^{H_f} \sum_{n=1}^{W_f} \sum_{c=1}^C X_{i+m,j+n,c} \cdot W_{i,j,m,n,c,k} + b_{i,j,k} \quad (3.13)$$

L4 のフィルタは 9×9 であり出力の特徴マップのサイズは縮小サイズは式 (3.12) により 55×55 となる。また、L5 のフィルタは 7×7 であり、出力の特徴マップのサイズは縮小サイズは式 (3.12) により 25×25 となる。L6 のフィルタは 5×5 であり、縮小サイズは式 (3.12) により 21×21 となる。

全結合層 (F7、F8)

全結合層は特徴抽出後のデータを一つの固定長ベクトルに変換する層である。これにより、次のタスク (分類タスクや識別タスク) に適した形に変換される。F7 層は、C1～L6 層を通じて抽出された高次元の特徴を統合し、顔画像を表現する 4096 次元の特徴ベクトルを生成する層である。このベクトルは、入力画像の識別に必要な情報を凝縮したものであり、次の F8 層の分類や顔画像間の類似度計算に利用される。F7 層の出力ノード i の値を z_i 、L6 層からの入力ノード j の値を h_j 、入力ノード j と出力ノード i を結ぶ重みを $W_{j,i}$ 、出力ノード i に対応するバイアスを b_i 、L6 層の出力をフラット化した入力ノードの総数を N とする以下のようにあらわされる。

$$z_i = \sum_{j=1}^N h_j \cdot W_{j,i} + b_i \quad (3.14)$$

出力は 4096 次元のベクトルであり、このベクトルは、成分ごとの最大値正規化と L2 正規化法を用いて 0～1 の値に正規化される。これによりモデルの過学習を防ぐことができ、精度を高めることができる。

F8 層は 7 層の出力をもとに 7 つのカテゴリ (怒り、嫌悪、恐怖、幸せ、悲しみ、驚き、中立) のいずれかに分類する層である。7 層で出力された 4096 次元のベクトルを入力とし、各感情に対するスコアを求め、softmax 関数により確率に変換している。F7 層からの特徴ベクトルの成分 i を z_i 、F7 層の出力ノード i と感情カテゴリ k を結ぶ重みを $W_{i,k}$ 、感情カテゴリ k に対応するバイアスを b_k 、感情カテゴリのインデックスを k とした時、感情カテゴリ k に対応するスコアを O_k は以下のように表される

$$o_k = \sum_{i=1}^{4096} z_i \cdot W_{i,k} + b_k \quad (3.15)$$

各感情のスコア o_k を感情の確率 p_k に変換するため、ソフトマックス関数を適応する。確率 p_k が最も高いカテゴリ k が、感情分析の最終的な出力となる。

$$p_k = \frac{\exp(o_k)}{\sum_{j=1}^7 \exp o_j} \quad (3.16)$$

4. パラメータの学習

感情分析のパラメータの学習には、クロスエントロピー損失を使用する。クロスエントロピー損失とは、モデルの予測値と正解ラベルとの間の誤差を定量化する関数のことであり、この関数を最小化することによりモデルの予測精度を向上させている。正解の確率分布を y_k とするとクロスエントロピー損失関数 L は以下で求められる。

$$L = - \sum_{k=1}^7 y_k \log(p_k) \quad (3.17)$$

以上のように、DeepFace により、顔映像から顔を検出し、9 層の CNN によって顔を 4098 次元の特徴ベクトルに変換され、それをもとに各感情の確率を出力している。本研究では、DeepFace を用い、カメラ映像によりユーザの各感情確率を感情スコアとして、ネガティブ強度を算出する。また、ネガティブ強度に応じた楽曲を提示し、ネガティブ強度の推移を計測する。

§ 3.3 クラスタリング手法によるトピック検索

クラスタリング手法と流れについて説明する

本研究では、ガイド付き LDA を用い歌詞を任意のトピックごとにクラスタリングを行う。また、クラスタリング結果のプレイリストを作成し、ユーザが選択する。

クラスタリング

クラスタリングとは、与えられたデータをデータ間の類似度に基づいていくつかのクラスタに振り分ける教師なし学習の手法のひとつである。教師なし学習とは、正解データを必要しない機械学習であり、データセットの中に存在するパターンを発見する手法である。正解データとは、ある原意データに対する結果に相当するデータである。機械学習の分野では、今までに様々なクラスタリング手法が提案されており、その研究は現在も続いている。代表的なクラスタリングを以下に述べる。

階層型クラスタリング

階層型クラスタリングとは、データセット内の観測値を構造組織化するクラスタリング手法のことである。データ全体の中で最も類似度が高い、もしくは最も類似度が低いデータ同士をひとつづつグループ化していく、全てのデータがグループに属すまでそれを繰り返す手法のことである。代表的な手法として群平均法やウォード法などがある

分割型クラスタリング

分割型クラスタリングは、データセットを複数のクラスタに分割するクラスタリング手法である。この手法では、データが異なるクラスタに属するように分割され、各クラスターはほかのクラスとは異なる特徴や属性を持つ。代表的な手法には K-means がある。

探索型クラスタリング

データセットにおける潜在的な構造やパターンを発見するために使用されるクラスタリング手法である。このアプローチは、事前にクラスター数やパターンが明確にわかっていない場合に有用であり、データの自然な分布や関係性を探索的に明らかにする。

確率モデル型クラスタリング

データセットのクラスタ構造を確率モデルを用いてモデリングするクラスタリング手法である。データが生成されるプロセスを確率分布としてとらえ、それに基づいてクラスタリングを行う。

このように、クラスタリングは、データの類似性に基づいてグループ化を行う手法であり、主に階層型、分割型、確率モデル型に分類される。本研究では、歌詞データを確率モデル型クラスタリングの一種である LDA を用いて分析する。

LDA(Latent Dirichlet Allocation)

LDA (Latent Dirichlet Allocation、潜在ディリクレ分配法) は、文書の潜在的なトピック構造を発見するための確率的生成モデルである [36]。LDA は、文章がどのように生成されるかを仮定し、文書中に出現する単語の頻度からそのトピックを推定する手法である。LDA の生成モデルは、以下の過程を経て文章が生成されると仮定する。

トピックの分布

各文章 d_i は、いくつかのトピックから成り立っていると仮定する。例えば、ニュース記事では、『政治』『経済』『スポーツ』などのトピックが含まれ、それぞれのトピックが文書に対してどれくらい関係しているかを示す分布が存在する。それらのトピックは、ディリクレ分布から得られると仮定する。

単語の分布

各トピック k は、そのトピックに関連する特定の単語の頻度分布を持っていると仮定する。たとえば、「スポーツ」のトピックでは「試合」「選手」「チーム」などの単語が頻繁に現れる。トピックごとの単語分布もディリクレ分布から生成される。

単語の生成

各文書の単語は、まずその単語が関連するトピックを確率的に選び、そのトピックに基づく単語分布からサンプリングされて生成される。たとえば、「試合」という単語が文書内で出現した場合、それが「スポーツ」トピックから生成される確率が高いと推測される。

例えば、文書 d のトピック分布が $\theta = [0.6, 0.3, 0.1]$ (政治: 60 %、経済: 30 %、スポーツ: 10 %) であり、トピック『政治』の単語分布 ϕ が $\phi = [0.2, 0.5, 0.3]$ (選挙: 20 %、政策: 50 %、国会: 30 %) であると仮定する。この場合、文書内で『政策』という単語が生成される確率は、トピック『政治』の確率と単語『政策』の確率の積として計算される。

LDA ではディリクレ分布を用いて確率分布 (トピック分布、単語分布) を生成し、それらをもとに多項分布を使い、単語やトピックを生成する。そして、実際の文書中の単語の頻度をもとに、各文書のトピック分布やトピックごとの単語分布を逆推定し、文章のクラスタリングを行う。文章作成のプロセスは以下の流れで行われている。

1. トピック分布の作成

文章 d に対応するトピック分布 θ はディリクレ分布からサンプリングされる。ディリクレ分布とは各要素が確率値をとる (非負であり和が 1 となる) K 次元ベクトルに対する分布である。具体的には、以下の条件を満たす確率分布 K 次元の確率ベクトル $\theta = (\theta_1, \theta_2, \dots, \theta_K)$ を生成する。

$$\theta_k \geq 0 \quad (3.18)$$

$$\sum_{k=1}^K \theta_k = 1 \quad (3.19)$$

また、トピック分布のディリクレ分布のハイパーパラメータを $\alpha = (\alpha_1, \alpha_2, \dots, \alpha_K)$ 、ディリクレ分布の確率密度関数 (PDF) は次のように表される



図 3.6: LDA におけるグラフィカルモデル



図 3.7: 3D アライメント [30]

$$p(\mathbf{x} \mid \alpha) = \frac{1}{B(\alpha)} \prod_{k=1}^K x_k^{\alpha_k-1} \quad (3.20)$$

ここで $B(\alpha)$ はベータ関数であり、ディリクレ分布を確率分布（確率の合計が 1 になる分布）として正規化する定数である。ガンマ関数を $\Gamma(x)$ としたとき、ベータ関数は以下のようにあらわされる。

$$B(\alpha) = \frac{\prod_{k=1}^K \Gamma(\alpha_k)}{\Gamma\left(\sum_{k=1}^K \alpha_k\right)} \quad (3.21)$$

LDA における処理の流れ

多項分布

$$P(x_1, x_2, \dots, x_V \mid n, p_1, p_2, \dots, p_V) = \frac{n!}{x_1! x_2! \dots x_V!} \prod_{i=1}^V p_i^{x_i} \quad (3.22)$$

各記号の意味:

- V : カテゴリの数（語彙サイズなど）
- n : 試行回数（文書内の単語数など）
- x_i : カテゴリ i の出現回数
- p_i : カテゴリ i が選ばれる確率 ($\sum_{i=1}^V p_i = 1$ を満たす)

ガイド付き LDA (Guided Latent Dirichlet Allocation)

LDA の生成モデル

ディリクレ分布の確率密度関数 (PDF) は次のように表されます：

$$P(\theta|\alpha) = \frac{1}{B(\alpha)} \prod_{k=1}^K \theta_k^{\alpha_k-1}$$

ここで使われている各要素は次の通りです。

1. 確率ベクトル θ

$\theta = (\theta_1, \theta_2, \dots, \theta_K)$ は、**確率ベクトル**です。これは、 K 個のトピックの割合を表すベクトルです。各 θ_k は、文書内のトピック k の割合（確率）を示します。すべての θ_k の和は 1 になります。例えば、 $\theta = (0.2, 0.5, 0.3)$ は、文書の中でトピック 1 が 20%、トピック 2 が 50%、トピック 3 が 30% の割合で存在していることを意味します。

2. パラメータ α

$\alpha = (\alpha_1, \alpha_2, \dots, \alpha_K)$ はディリクレ分布の**パラメータ**で、 K 個のトピックごとの「偏り」を制御します。各 α_k は、トピック k がどれだけ「重要」または「頻繁に出現するか」を決定します。例えば、 α_k が大きいと、トピック k の確率が均等に近くなる傾向があり、逆に小さいとそのトピックに偏りが出ます。

3. 正規化定数 $B(\alpha)$

$B(\alpha)$ は、ディリクレ分布を確率分布として正規化するための定数です。ディリクレ分布は多次元の確率分布なので、確率ベクトルが 1 になるように全体を調整する必要があります。この定数は次のように計算されます：

$$B(\alpha) = \frac{\prod_{k=1}^K \Gamma(\alpha_k)}{\Gamma\left(\sum_{k=1}^K \alpha_k\right)}$$

ここで、 $\Gamma(x)$ は**ガンマ関数**です。これは、ベータ関数を高次元に拡張したもので、分布を正しく正規化する役割を果たします。

ガンマ関数は、数値を入力すると特定の計算結果を返す特殊な関数です。これは、ベータ関数（2 次元の確率分布の正規化に使われる関数）を多次元に拡張したものです。

直感的に言うと、ガンマ関数は「ある数値がどれくらい大きいか」を調整するための関数です。ディリクレ分布の場合、この関数を使って確率ベクトルの合計が 1 になるように調整するために必要な数値を計算します。これを使うことで、ディリクレ分布が適切に正規化されます。

4. $\prod_{k=1}^K \theta_k^{\alpha_k-1}$

この部分は、**確率ベクトル** $\theta = (\theta_1, \theta_2, \dots, \theta_K)$ の各要素（トピックの確率）が、ディリクレ分布のパラメータ α_k に基づいて生成されることを意味します。具体的には、 α_k が大きいほど、 θ_k は 1 に近い値になりやすく、 α_k が小さいほど、 θ_k は 0 に近い値になりやすくなります。

まとめ

ディリクレ分布の確率密度関数全体は、「確率ベクトル θ がどれだけ可能性を持っているか」を評価しています。この評価には、次の 3 つの重要な要素が関わっています：

1. **確率ベクトル θ **: これは、各トピックが文書内でどのくらいの割合で出現するかを示します。
2. **パラメータ α **: これは、どのトピックが重要か、あるいは出現頻度が高いかを調整します。大きい値の α_k はトピックが均等に分布する傾向を強調し、小さい値は偏りを強調します。
3. **正規化定数 $B(\alpha)$ **: これは、確率の合計が 1 になるように分布を調整する役割を果たします。

ディリクレ分布は、特定のトピックの割合がどのように分布するかを確率的にモデル化するために使用されます。LDA では、このディリクレ分布を使って、各文書がどのようにトピックに分布しているかを推定します。

提案手法

§ 4.1 楽曲特徴量の取得の流れ

§ 4.2 ガイド付き LDA を用いたプレイリストの作成

§ 4.3 提案システムの概要

数値実験並びに考察

§ 5.1 数値実験の概要

§ 5.2 実験結果と考察

おわりに

謝辞

本研究を遂行するにあたり、多大なご指導と終始懇切丁寧なご鞭撻を賜った富山県立大学工学部電子・情報工学科情報基盤工学講座のAntónio Oliveira Nzinga René講師、奥原浩之教授に深甚な謝意を表します。最後になりましたが、多大な協力をしていただいた研究室の同輩諸氏に感謝致します。

2025年2月

水上和秀

参考文献

- [1] 神嶌 敏弘, “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, 2007, <https://www.kamishima.net/archive/recsysdoc.pdf>
- [2] Baeldung. (n.d.). How Does the Amazon Recommendation System Work? 2025年1月7日閲覧, <https://www.baeldung.com/cs/amazon-recommendation-system#:~:text=1.-,Overview,characteristics%20to%20deliver%20tailored%20suggestions>
- [3] Coursera. (n.d.). Coursera: Learn new skills with online courses from top universities. 2025年1月7日閲覧、<https://www.coursera.org>
- [4] Quantum Zeitgeist. (2023). YouTube Music boosts user satisfaction with AI-powered transformers. 2025年1月7日閲覧, from <https://quantumzeitgeist.com/youtube-music-boosts-user-satisfaction-with-ai-powered-transformers/>
- [5] Artist Push. (n.d.). How does Spotify algorithm work for artists? 2025年1月7日閲覧, <https://artistpush.me/blogs/news/how-does-spotify-algorithm-work-for-artists>
- [6] Zhou, R., Khemmarat, S., & Gao, L. (2010). The impact of YouTube recommendation system on video views. In *Proceedings of the 10th ACM SIGCOMM conference on Internet measurement* (IMC '10) (pp. 404–410). Association for Computing Machinery. <https://doi.org/10.1145/1879141.1879193>
- [7] He, X., Liu, Q., & Jung, S. (2024). The Impact of Recommendation System on User Satisfaction: A Moderated Mediation Approach. *Journal of Theoretical and Applied Electronic Commerce Research*, 19(1), 448-466. 2025年1月7日閲覧 <https://doi.org/10.3390/jtaer19010024>
- [8] 公益財団法人長寿科学振興財団. (n.d.). 音楽療法. 2025年1月7日閲覧, <https://www.tyojyu.or.jp/net/byouki/ninchishou/music.html>
- [9] 日本精神神経学会 田町三田こころみクリニック. (n.d.). うつや不安を和らげる音楽療法の効果とは?. 2025年1月7日閲覧, <https://cocoromi-mental.jp/cocoromims/other/selfcare/music/>
- [10] Gold, B. P., Frank, M. J., Bogert, B., & Brattico, E. (2013). Pleasurable music affects reinforcement learning according to the listener. *Frontiers in Psychology*, 4, 541. 2025年1月7日閲覧
- [11] Tervaniemi, M., Makkonen, T., & Nie, P. (2021). Psychological and physiological signatures of music listening in different listening environments—An exploratory study. *Brain Sciences*, 11(5), 593. 2025年1月7日閲覧
- [12] CLRN. (n.d.). Does music make you happy? 2025年1月7日閲覧, <https://www.clrn.org/does-music-make-you-happy/>

- [13] Bernardi, L., Porta, C., & Sleight, P. (2006). Cardiovascular, cerebrovascular, and respiratory changes induced by different types of music in musicians and non-musicians: The importance of silence. *Heart*, 92(4), 445–452. 2025年1月7日閲覧
- [14] Parncutt, R. (2013). Major-minor tonality, Schenkerian prolongation, and emotion: A commentary on Huron and Davis (2012). *Empirical Musicology Review*, 7(3-4), 118–137.
- [15] Carraturo, G., Pando-Naude, V., Costa, M., Vuust, P., Bonetti, L., & Brattico, E. (2024). The major-minor mode dichotomy in music perception. *Physics of Life Reviews*, 52, 80–106. <https://doi.org/10.1016/j.plrev.2024.02.003>
- [16] Daws, L. (2019). Emotional responses to acoustic music: A study of instrumental and vocal stimuli. Oxford Academic. 2025年1月7日閲覧
- [17] Harmony & Healing. (n.d.). How music can reduce stress and improve mental health. 2025年1月7日閲覧, <https://www.harmonyandhealing.org/how-music-can-reduce-stress/>
- [18] Smith, J., & Brown, A. (2022). The impact of positive music lyrics on emotional wellbeing. CORE. 2025年1月7日閲覧
- [19] Russo, J., & Thompson, A. (2024). The effect of song lyrics on the emotional and physiological response to music. *Journal of Music and Emotion*, 32(4), 214–229. 2025年1月7日閲覧
- [20] Altschuler, I. M. (1954). The past, present, and future of musical therapy. In *Music Therapy* (pp. 24–35). Philosophical Library.
- [21] Thematic. (n.d.). Sentiment analysis. GetThematic. 2025年1月8日閲覧, <https://getthematic.com/sentiment-analysis>
- [22] Cotra、感情分析とは？初心者にもわかりやすく解説！顧客対応の活用例も紹介、2025年1月8日閲覧, <https://www.transcosmos-cotra.jp/sentiment-analysis>
- [23] 高村大也, 乾孝司, 奥村学ぶ, ”スピニモデルによる単語の感情極性抽出”, 情報処理学会論文誌ジャーナル, Vol.47 No.02, pp.627-637, 2016
- [24] 東北大学 乾・鈴木研究室：日本語評価極性辞書, 2025年1月8日閲覧 <http://www.cl.ecei.tohoku.ac.jp/index.php?Open%20Resources%2FJapanese%20Sentiment%20Polarity%20Dictionary>
- [25] G. H. Mohmad Dar and R. Delhibabu, ”Speech Databases, Speech Features, and Classifiers in Speech Emotion Recognition: A Review,” in IEEE Access, vol. 12, pp. 151122-151152, 2024,

- [26] Ekman, P. (n.d.). Facial Action Coding System (FACS). Paul Ekman Group. 2025 年 1 月 8 日閲覧, 2025, from <https://www.paulekman.com>
- [27] 満倉靖恵 (2020). 脳波によるリアルタイム感性計測とその応用——実社会における感 情・感性を用いる試みの広がり——. IEICE Fundamentals Review, 13(3), 180-186.
- [28] AI 総合研究所、Transformer とは？モデルの概要や BERT との違いをわかりや すく解説、2025 年 1 月 8 日閲覧、<https://www.ai-souken.com/article/transformer-overview#position-wise-feed-forward-network%E5%B1%A4>
- [29] 長澤 尚武, 萩原 将文、”文脈を考慮した単語の感情推定”、日本感性工学会論文誌、Vol. 23 (2023), No. 2 pp. 87-96
- [30] Y. Taigman, M. Yang, M. Ranzato and L. Wolf, ”DeepFace: Closing the Gap to Human-Level Performance in Face Verification,” in 2014 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Columbus, OH, USA, 2014, pp. 1701-1708,
- [31] Unite AI, “DeepFace for Advanced Facial Recognition”, <https://www.unite.ai/deepface-for-advanced-facial-recognition/>, 閲覧日 2023.1.7.
- [32] イメージングソリューション, “アフィン変換 (平行移動、拡大縮小、回転、スキー行 列) ”, <https://imagingsolution.net/imaging/affine-transformation/>, 閲覧日 2023.1.7.
- [33] Sefik Ilkin Serengil, “Face Recognition with Facebook DeepFace in Keras”, <https://sefiks.com/2020/02/17/face-recognition-with-facebook-deepface-in-keras/>, 閲 覧日 2023.1.7.
- [34] 楽しみながら学ぶ機械学習 / 自然言語処理入門, 【入門者向け】畳み込 み演算と転置畳み込み演算を理解する”, 閲覧日 2023.1.7.、<https://data-analytics.fun/2021/11/23/understanding-convolution/>,
- [35] 楽しみながら学ぶ機械学習 / 自然言語処理入門、【入門者向け】畳み込 み演算と転置畳み込み演算を理解する、閲覧日 2023.1.7.、<https://data-analytics.fun/2021/11/23/understanding-convolution/>
- [36] David M. Blei, Andrew Y. Ng and Michael I. Jordan “Latent Dirichlet Allocation ” 2003