

修士論文

タイトルはここ

english title

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 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 関連研究	4
§ 2.1 音楽が感情・心理に与える影響	4
§ 2.2 音楽および他分野における推薦システム	8
§ 2.3 感情分析による研究事例	11
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 LDA におけるトピック検索について	21
第4章 提案手法	24
§ 4.1 楽曲特徴量の取得の流れ	24
§ 4.2 ガイド付き LDA を用いたプレイリストの作成	24
§ 4.3 提案システムの概要	24
第5章 数値実験並びに考察	26
§ 5.1 数値実験の概要	26
§ 5.2 実験結果と考察	26
第6章 おわりに	27
謝辞	28
参考文献	29

図一覧

2.1	音楽療法の種類	5
2.2	情報推薦システムの分類	5
2.3	レコメンドシステムのイメージ	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	3D アライメント	20
3.4	特徴量取得の流れ	20
3.5	モデル	21

表一覽

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態で、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 関連研究について述べる。

第3章 本研究で用いる

第4章 本研究の提案手法について述べる

第5章

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。

関連研究

§ 2.1 音楽が感情・心理に与える影響

ストレスを解消する方法として、音楽療法がある。

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 [1]。

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。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、音楽を聴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 [2]。

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、音楽を聴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

音楽を聴くことにより、認知能力を向上させ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。[3]

ストレスの軽減



図 2.1: 音楽療法の種類

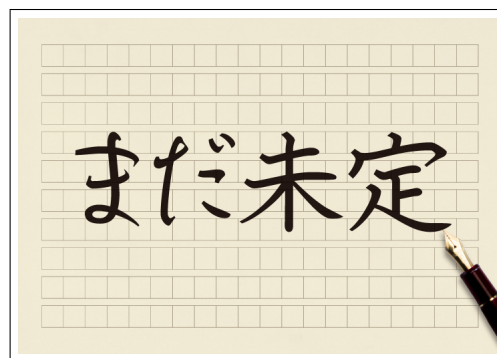


図 2.2: 情報推薦システムの分類

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、リラクゼーション効果が確認された。日常生活でのストレスにおいても、リラクゼーション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 [4]。

感情の調整

音楽の感情的効果はいくつ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を提供し、リラクゼーション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 [5]。

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、リラクゼーション効果やエネルギーの向上をもたらし、ネガティブな感情を軽減することが確認されている [6]。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クゼーションできる音楽を提供するこ

とができる。一般的に、長調（メジャーキー）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い一方、短調（マイナーキー）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【Juslin & Sloboda, 2010】。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。

また、Thoma et al. (2013) の研究によれば、短調の音楽は聴衆の心理的な安定感を高め、過度の感情的な変動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。

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

音楽のアコースティック性は感情や心理状態に影響を与えることが示されている。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を使用されており、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、Thoma et al. (2013) の研究では、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。また、Saarikallio et al. (2013) 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。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

を聴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聴くことにより、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 & Sloboda (2010) 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、リスナーに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。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. (2013) 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は、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。

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) という考え方が提唱されている。

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、その音楽を聴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聴くことで、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聴いても、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、暗い音楽を聴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ーに対して、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、ユーザー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、ユーザー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。

§ 2.2 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、情報推薦システムによりユーザーは膨大な選択肢の中から適切な情報や商品を効率的に発見できるようになり、現代の情報過多の時代において重要な役割を果たしている。レコメンドシステムのイメージを図 2.3 に示す。

推薦システムの目的

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。

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

¹<https://www.youtube.com>

²<https://www.amazon.co.jp>

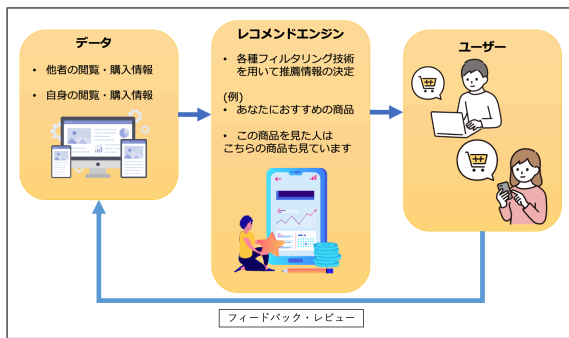


図 2.3: レコメンドシステムのイメージ

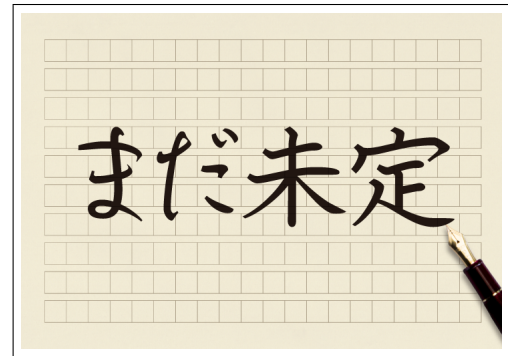


図 2.4: 情報推薦システムの分類

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ーを見つけ出します。その後、そのユーザー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ー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。ユーザー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ーを見つけ、そのユーザー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、ユーザー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ー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」やユーザー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「スパース性問題」などの課題がある。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、新規ユーザー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、幅広いユーザー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

1

2. Coursera における推薦推薦システムの事例

2

音楽分野分野での推薦システムの事例

他分野での事例を書く

1. YoutubeMusic での推薦システムの事例

い

2. AppleMusic における推薦システムの事例

あ

本研究への関連性

他分野での事例を書く

§ 2.3 感情分析による研究事例

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、生体情報などがあげられる。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ので、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できる。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。

テキストによる感情分析の手法は大きく分けて「感情辞書による手法」、「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。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. 感情辞書による手法

感情辞書による手法は感情極性辞書を用いて、単語やフレーズに割り与えられたポジティブまたはネガティブスコアを集計することでテキストの感情を推定する手法である。感情極性辞書を用いた感情推定の流れを説明する。まず、対象となる文章を形態素解析と係り受け解析により単語に分割する。次に、分割した単語を感情極性辞書に基づいてポジティブまたはネガティブに振り分ける。最後に、各単語の情報を集計し、文章全体の感情を推定する。

形態素解析とは、文章を言語において意味を持つ最小単位(形態素)に細分化することである。形態素解析で文章を形態素に分割し、係り受け解析により各形態素の係り先を決定する。日本語の感情分析で使われる感情極性辞書は以下の二つがあげられる

・ 単語感情極性対応表

単語感情極性対応表は、東京工業大学の高村教授が公開した、スピンモデル (SPIN Model) を用いて作成された感情辞書である。スピンモデルとは物理学のスピン理論を応用し、単語の感情極性を文脈に基づいて推定する手法である。単語が同じ文脈で共起する場合、それらの単語は同じ感情極性を持つと仮定し、語彙ネットワークを構築する。このネットワークを用いて、単語同士の感情的な関係性を計算し、感情極性を決定している。

・ 日本語感情極性辞書

日本語感情極性辞書は、東北大学の乾研究室が公開した極性辞書であり、約 8,500 の名詞および複合名詞に感情極性情報を人手で付与している。名詞の評価極性は、評価・感情、状態、行為などを基準に決定されている。

感情辞書による手法では、感情辞書があれば比較的容易に導入可能であり、また、解釈がシンプルであり、直感的に理解しやすいという利点がある。一方、文脈を考慮できない

め、単語単体では誤った感情判定を行ってしまう場合がある。また、未知語に対応できず、比喩や曖昧表現に対して精度が落ちてしまうという問題がある。

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、未知のデータを予測する教師あり学習を用いた手法である。教師あり学習とは、正解のデータが用意されており、正しい出力ができるように入力データの特徴やルールを学習していく手法のことである。感情分析の場合、感情ラベル(ネガティブか、ポジティブかなど)が付与されたデータを学習させ、対象の文章が持つ感情を分類する。

機械学習手法を用いた感情分析では、

step1. データ収集及び前処理

感情分析を行うためには分析対象となるテキストを収集することが必要である。分析対象によって異なるが、一般的にはSNSの投稿やレビューサイトのデータ、アンケートデータなどが用いられる。また、収集したテキストデータは、このままでは機械学習のモデルに適用できないため、「テキストクリーニング」、「トークン化」、「ストップワードの除去」、「正規化」などの前処理を行う。テキストクリーニングでは、不要な記号や特殊文字、URLなどを削除し、データのノイズを取り除く。トークン化ではテキストを単語単位で分割し、モデルが処理可能な形に変換する。日本語の場合、文章に対して形態素解析を行い、文章を単語ごとに分解することが一般的である。ストップワードの除去では、意味を持たない単語を除去する。日本語の場合、助詞である「は」「の」「に」などを除去するが多い。

また、この段階で、モデルの学習に利用する正解データも収集する。感情分析においての正解データは、「ポジティブ」、「ネガティブ」などの感情ラベルを付けたデータセットを収集する。データセットは、既存のデータセットを用いるか、独自にデータを収集し、活用する

step2. 特徴量の抽出

特徴量抽出では、テキストデータを数値に変換する処理を行う。トークン化によって得られた単語や文節を数値的な形式に変換し、機械学習モデルで利用できる特徴量に変換する。これにより、機械学習アルゴリズムがテキストデータの情報を計算で扱えるようになる。テキストを数値化する手法として、「Bag of Words (BoW)」、「TF-IDF」、「Word2Vec」がある。BoWは文書内の単語の出現頻度を数え、それをベクトル形式に変換する手法である。BoWはシンプルで実装が容易である。しかし、単語の出現頻度のみを考慮するため、文書内の単語の順序や重要度、文法構造は考慮されない。TF-IDFは、単語が特定の文書内でどれだけ重要であるかを考慮した手法である。TF-IDFでは、単語の文書内での出現頻度を表す「TF (Term Frequency)」と、単語がどれだけ多くの文書で使われているかを逆数で示す「IDF (Inverse Document Frequency)」を掛け合わせた値を計算する。これにより、「です」や「ます」などの頻出するが重要ではない単語の影響を減らすことができる。しかし、全文書に対してIDFを計算する必要があるため、大量のデータを扱う際には計算コストが高くなるという課題がある。BoWとTF-IDFは、単語の意味的な関係を考慮できない一方、Word2Vecは単語間の意味的な関係性を反映した数値ベクトルを作成する。Word2Vec

ではCBOW (Continuous Bag of Words) を用いてCBOWは、文脈情報を利用して中心の単語を予測であり、中心単語の周囲にある複数の単語を入力として、それらを平均化することで文脈の情報を集約し、その情報を元に中心単語を推定する。CBOWは計算量が比較的少なく、効率的に学習を進めることができたため、データ量が比較的少ない場合や、迅速なモデル構築が必要な場合に有効である。ただし、文脈全体を一度に平均化してしまうため、単語間の詳細な関係性を捉えるのが難しい。

step3. モデルの学習

この段階では、特徴量抽出の過程で数値化された文章及び正解データを用いて、モデルの学習を行う。学習は、モデルが予測を行い、その予測と実際の正解データとの誤差を最小化するように繰り返し行われる。以下に具体的な学習の流れを説明する。

まず、学習プロセスが始まる前に、モデルのパラメータはランダムに初期化される。次に、ベクトル化されたテキストデータを入力として与える。モデルは、テキストデータのベクトル値を特徴量として予測を行う。この時、予測値を \hat{y} 、入力データを X 、モデルのパラメータを W (重み) および b (バイアス) としたとき、予測値は次のように計算される

$$\hat{y} = \sigma(WX + b) \quad (2.1)$$

ここで、 $W \in \mathbb{R}^d$ は重みベクトル、 b はバイアス、 σ はシグモイド関数であり、以下の式で定義される

$$\sigma(z) = \frac{1}{1 + e^{-z}} \quad (2.2)$$

次に、モデルが予測した値 \hat{y} と実際の正解データ y との間の誤差を測るために、損失関数 $L(y, \hat{y})$ を使用する。感情分析における2クラス分類 (ネガティブ、ポジティブ) の場合、損失関数はクロスエントロピーとして以下のように表される。

$$L(y, \hat{y}) = -[y \log(\hat{y}) + (1 - y) \log(1 - \hat{y})] \quad (2.3)$$

次に、損失関数を最小化するために、パラメータ W および b を更新する必要がある。そのためには、損失関数 $L(y, \hat{y})$ をそれぞれのパラメータで微分し、勾配 ∇_W および ∇_b を計算する。勾配降下法に基づくパラメータ更新式は次のように表される

$$W := W - \eta \cdot \nabla_W L(y, \hat{y}) \quad (2.4)$$

$$b := b - \eta \cdot \nabla_b L(y, \hat{y}) \quad (2.5)$$

ここで、 η は学習率であり、パラメータの更新幅を調整する。

この更新を訓練データに対して繰り返し行い、損失関数の値を最小化していく。

step4. モデルの評価

この段階では、学習に使用しなかったデータを用い、モデルが新しいデータに対してどの程度正確に予測できるかを検証する。性能の評価には、主な評価指標として「精度」、「適合率」、「再現率」、「F1スコア」が用いられることが多い。精度とはモデルの全予測に対す

る正しい予測の割合であり、適合率はモデルが正と予測した中で実際に正だった割合のことであり、再現率は実際に正だった中でモデルが正と予測できた割合のことであり、F1スコアは適合率と再現率の調和平均をとった値である。以上の指標を用いることでモデルの強みや弱みを分析することができる。たとえば、適合率が高く再現率が低い場合、モデルは慎重すぎる傾向があるといえる。

step5. 感情の予測

この段階では、ベクトル化された文章データを、作成したモデルに適応し、結果を予測する。感情分析の場合、感情スコア（0から1の間の連続値とし、1に近いほどポジティブ、0に近いほどネガティブ）として感情の強さや確信度を出力する。

例えば、ポジティブな文章に対しては高いスコア（1に近い値）を予測し、ネガティブな文章に対しては低いスコア（0に近い値）を予測する。このようにして得られた予測結果は、感情分析の目的に応じて様々な方法で解釈され、評価される。

3. 深層学習による手法

深層学習 (Deep Learning) は、人工ニューラルネットワークを用いた学習手法で、ニューラルネットワークを多構造に用いることで、大量のデータを使って特徴量の抽出や感情分類を行うことが可能となる。従来の機械学習手法に比べて、文脈を考慮した高度な理解が可能となっている。

深層学習にはさまざまなモデルがあり、画像認識に適した CNN(Convolutional Neural Network) や自然言語処理に適した Transformer、生成モデルに適した GAN(Generative Adversarial Network) など、それぞれ特定のタスクに適応するモデルが存在する。自然言語処理や時系列データの分析においては、文脈や時間的な依存関係を考慮することが重要であり、これを実現するためのモデルとして RNN やその改良版が広く用いられている。

• RNN

RNN(Recurrent Neural Network) は、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

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。

顔画像を用いた感情分析の手法

顔画像を用いた感情分析の手法は、テキストによる感情分析とは異なる手法があり、以下の3つの手法が一般的に使われている。

1. 特徴ベースによる手法

特徴ベースによる手法は、顔画像から特徴を抽出して感情を分類する手法である。

3. 機械学習による手法

3. 深層学習による手法

感情分析は

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??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。

結果として、多くの NLP タスクで従来手法を上回る精度を達成しており、BERT は分散表現と転移学習において大きな進展をもたらした。

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 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、再帰も畳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。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

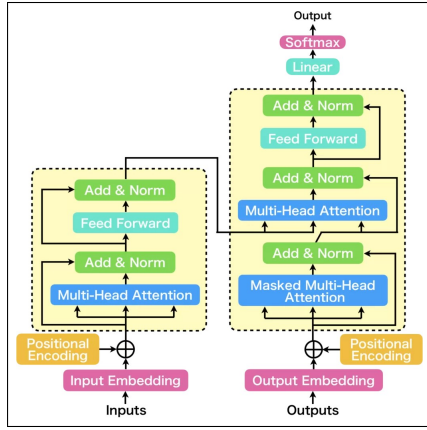


図 3.1: BERT の流れ

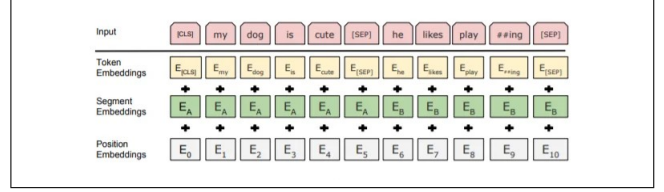


図 3.2: BERT の入力部分

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、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。

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。

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

このベクトル \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。

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くなる可能性がある。そのため、トークン列内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

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

$$\mathbf{p}_{(pos, 2i+1)} = \cos \left(\frac{pos}{10000^{\frac{2i}{d_{model}}}} \right) \quad (3.3)$$

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。

3. セグメント埋め込み

BERT では、1つの入力が単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。

$$\mathbf{s}_i = \mathbf{S}[s_i] \quad (3.4)$$

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。

$$\mathbf{x}_i = \mathbf{e}_i + \mathbf{p}_i + \mathbf{s}_i \quad (3.5)$$

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。

$$\mathbf{Q}_i = W_Q \cdot \mathbf{x}_i, \quad \mathbf{K}_i = W_K \cdot \mathbf{x}_i, \quad \mathbf{V}_i = W_V \cdot \mathbf{x}_i \quad (3.6)$$

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る。

$$\text{score}(Q_i, K_j) = \frac{\mathbf{Q}_i \mathbf{K}_j^T}{\sqrt{d_k}} \quad (3.7)$$

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。

$$\text{Attention}(Q, K, V) = \text{softmax}\left(\frac{\mathbf{Q}\mathbf{K}^T}{\sqrt{d_k}}\right)\mathbf{V} \quad (3.8)$$

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。

$$\text{Multi-HeadAttention}(Q, K, V) = \text{Concat}(\text{head}_1, \text{head}_2, \dots, \text{head}_h)W_o \quad (3.9)$$

$$\text{where } \text{head}_i = \text{Attention}(QW_i^Q, KW_i^K, VW_i^V) \quad (3.10)$$

モデルの学習方法

- **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。Multi-Head Attention は、文全体の意味的および構文的な関係を理解し、正しい予測を行うための情報を集約する。

- **ファインチューニング**

ファインチューニングをする

§ 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 を用いて、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 層の畳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 [8]。

Deepface は「顔検出」、「3D アライメント」、「顔特徴の抽出」、「感情分析モデルの学習」、「感情分析の推定」の 5 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）を行うため。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、「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 [9]。

Haar カスケード分類器

Haar カスケード分類器は OpenCV が提供している画像処理ライブラリであり、Haar 特徴量を使用し、カスケード分類器を用いて画像内の顔の部分进行特定する。カスケード分類器とは複数の分類器を組み合わせた分類器であり、分類器のうち一つでも不正解であると判断した場合に不正解であるように分類器を調整した分類器のことである [10]。Haar 特徴量は、画像の明暗の変化を捉える特徴量で、顔認識においては顔の特定の明暗（例えば、目の周りが明るく、目の下が暗いなど）を特徴量としてとらえる。処理速度が速く、リアルタイムの顔検出に適している一方、照明や顔の角度の影響を受けやすく、精度が低くなることがある [11]。

MTCNN

MTCNN は顔検出のために設計されたディープラーニングモデルである。MTCNN は最初に全体的な顔の領域を検出する P-Net(Proposal Network) と、P-Net で生成された候補領域を入力として、各候補領域に対して顔か非顔かの二値分類を行う R-Net(Refine Network)、R-Net で生成された顔領域を入力として、顔か非顔かの二値分類と同時に、顔のランドマーク（顔の輪郭、目、鼻、口などの位置）検出を行う O-Net(Output Network) の 3 つのステージから構成されるカスケード型の構造となっており、これにより顔検出と顔のランドマーク（目、鼻、口など）の検出を同時に行うことが可能と

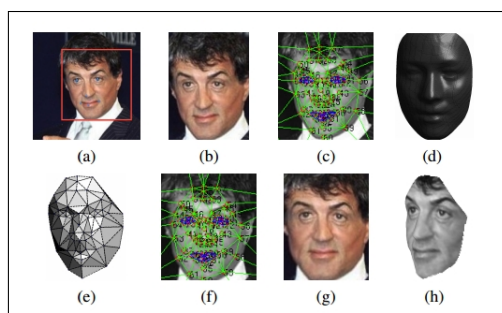


図 3.3: 3D アライメント

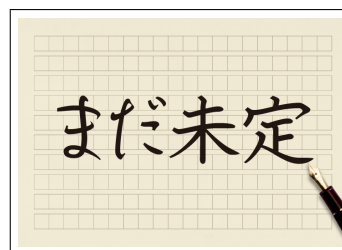


図 3.4: 特徴量取得の流れ

なる [12]。MTCNN は他の顔検出精度が高く、顔の向きや光の影響を受けにくいですが、複数段階の処理を行うため、画像サイズが大きかったり、画像内に検出すべき顔の数が多かったりすると処理速度が遅くなる。

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 [9]。3D アライメントの例を図 3.3 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 3.3.(c))。平均的な顔の 3D モデル (図 3.3.(d)) を使用し、画像内の特徴量と対応付けを行う (3.3.(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 (3.3.(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 (アフィン変換)。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 層の畳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。

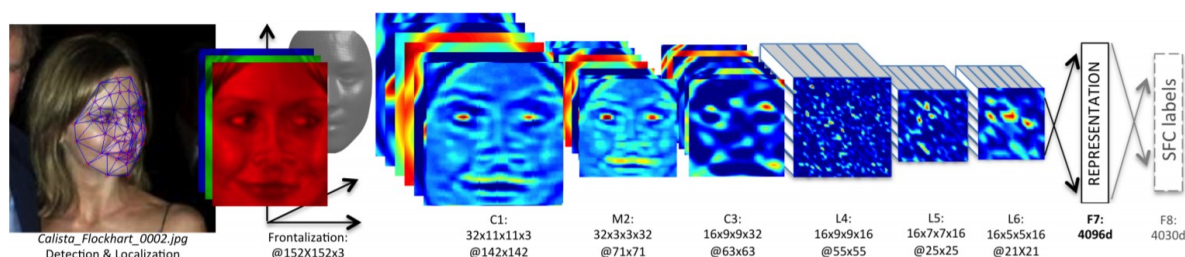


図 3.5: モデル

DeepFace は以下の 9 層で構成されており、

§ 3.3 LDA におけるトピック検索について

クラスタリング手法と流れについて説明する

クラスタリング手法

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ー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、いま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き、全てのデータがグループに属するまでそれを繰り返す手法のことである

< 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ー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ー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。代表的な手法には以下に述べる 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。

K-means

K-means 法は、分割型クラスタリング手法の一つであり、特に大規模なデータセットにおいて効率的にクラスタを形成できるという利点がある。この手法は、データをあらかじめ指定した数 K のクラスターに分けるため、各データ点をその最も近いクラスター中心に割り当て、クラスター中心を繰り返し更新することで収束する。

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] 公益財団法人長寿科学振興財団, “音楽療法”,
<https://www.tyojyu.or.jp/net/byouki/ninchishou/music.html>, 閲覧日 2023.1.7
- [2] 日本精神神経学会 田町三田こころみクリニック, “うつや不安を和らげる音楽療法の効果とは?”,
<https://cocoromi-mental.jp/cocoromi-ms/other/selfcare/music/>, 閲覧日 2023.1.7
- [3] Gold BP, Frank MJ, Bogert B, Brattico E. Pleasurable music affects reinforcement learning according to the listener. *Front Psychol.* 2013 Aug 21;4:541. , 閲覧日 2023.1.7
- [4] Tervaniemi M, Makkonen T, Nie P. Psychological and Physiological Signatures of Music Listening in Different Listening Environments-An Exploratory Study. *Brain Sci.* 2021 May 3;11(5):593. , 閲覧日 2023.1.7
- [5] Bernardi L, Porta C, Sleight P. Cardiovascular, cerebrovascular, and respiratory changes induced by different types of music in musicians and non-musicians: the importance of silence. *Heart.* 2006 Apr;92(4):445-52. , 閲覧日 2023.1.7
- [6] Soleymani, M., Caro, M.N., Schmidt, E.M., & Yang, Y. The MediaEval Brave New Task: Emotion in Music. *MediaEval Benchmarking Initiative for Multimedia Evaluation.* 2013
- [7] Juslin, Patrik N., *Handbook of Music and Emotion: Theory, Research, Applications* (Oxford, 2010; online edn, Oxford Academic, 22 Mar. 2012),
- [8] 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,
- [9] Unite AI, “DeepFace for Advanced Facial Recognition”,
<https://www.unite.ai/deepface-for-advanced-facial-recognition/>, 閲覧日 2023.1.7.
- [10] OpenCV, “Haar Feature-based Cascade Classifier for Object Detection”,
http://opencv.jp/opencv-2svn/py/objdetect_cascade_classification.html, 閲覧日 2023.1.7.
- [11] OpenCV, “Haar Cascades を使った顔検出”, https://labs.eecs.tottori-u.ac.jp/sd/Member/oyamada/OpenCV/html/py_tutorials/py_objdetect/py_face_detection/py_face_detection.html, 閲覧日 2023.1.7.
- [12] K. Zhang, Z. Zhang, Z. Li and Y. Qiao, ”Joint Face Detection and Alignment Using Multitask Cascaded Convolutional Networks,” in *IEEE Signal Processing Letters*, vol. 23, no. 10, pp. 1499-1503, Oct. 2016,

- [13] 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、スキュー行列) ”, <https://imaging-solution.net/imaging/affine-transformation/>, 閲覧日 2023.1.7.