

社会の欲求レベルの可視化に関する研究

道用大介、山崎友彰

第1部

社会的痕跡の収集と AI を用いた定量化

道用大介

緒言

1-1. はじめに

人類は歴史の中で、洞窟の壁面、石、木、紙、磁気テープ等、当時使えたメディア（媒体）にその時代の“痕跡”を残してきた。洞窟に描かれた壁画、石碑、文書（もんじょ・ぶんしょ）、日記、SNS、新聞・雑誌・インターネット記事などは全て、社会に残された痕跡であり、これらの痕跡は、年月が経てば、それらが残された時代を理解するための貴重な資料となる。例えば、戦時中の日記や新聞記事という痕跡からは「この期間には戦争があり、食糧が不足していたため、国民の生活は苦しかった」というような時代の定性的な理解ができ、現在の価値観からではあるが、当時の人々の心情を想像することもできる。特に戦争のような大きな社会的事象が起きた場合は、残される痕跡はその大きな社会的事象に関する内容が多くなり、時間が経てば、入手し易い事象の痕跡によって、その時代は印象付けられ、時代を語る際に代表的な出来事として語られる。そして、そこから得られる定性的な情報は代表的な事柄に大きな影響を受け、戦争、食糧不足という印象的な単語があれば、安全や食糧が確保されない環境におかれた人々の心情も自然と当時の代表的な心情として想像されるようになる。このことは、2002年にノーベル経済学賞を受賞した心理学者・行動経済学者のダニエル・カーネマン（Daniel Kahneman）が、エイモス・トベルスキー（Amos Tversky）との1970年代初頭の研究で提案した、思い出し易さや入手のし易さが判断に影響される「利用可能性ヒューリスティック」（Availability Heuristic）^[1] という概念や、典型的・代表的な事項に判断が影響される「代表性ヒューリスティック」（Representativeness Heuristic）^[2] という概念、心理学の分野で古くから知

られる一部の印象が全体の評価に影響するハロー効果（Halo Effect）^[3]などの研究成果からも自明なことである。しかし、当然のことながら、人々の生活の中には、日々の小さな幸せをもたらす出来事や、各々の夢に向けた取り組みなど、大きな社会的事象に隠れた代表的ではない出来事も多く存在し、そこから得られる人々の心情を知るためには、さらなる痕跡を探ることになる。社会に残された痕跡の多くは離散的なのである。

日本国内では、2020年初頭から新型コロナウイルス感染症の感染拡大がはじまり、緊急事態宣言や自粛要請により人々の生活は変化を強いられた。2022年の時点において未だその影響は残っている。コロナ禍初期の2020年4月は多くの人々は、「新型コロナウイルスに感染したくない」、「自分や大切な人々の命を守りたい」という欲求が大半を占めていたように感じられる。その一方で、感染拡大の最前線で自分の生活を犠牲にしながらか働く医療従事者・エッセンシャルワーカーの人々の力になりたいという欲求や、自分が取り組んでいるスポーツの大会をなんとか実現したいなど、安全や安心に関する欲求以外も存在した。また、変化という点では新型コロナウイルスに対する恐怖は感染者の増減によって左右されながら、徐々に薄らいでいったように感じられる。このような、その時代を生きた人々が感じていた状態や変化も社会の中の痕跡を迎えれば理解できるはずである。後に「皆、コロナの恐怖に怯えていただろう」「コロナの時代は自粛ばかりで辛かっただろう」「医療従事者の方々は身を粉にして働いてくれたが、辛かっただろう」「いろんなイベントが中止になって子供たちがかわいそう」というような代表的で定性的な理解だけにとどめず、その時代に、人々がどれくらい安全を求めていたか、どれくらい前向きだったか、など定量的な理解は可能なのであろうか、また、それはどのように表現し、どのように閲覧できるようにすることが望ましいのだろうか。本研究の問題意識の起点はコロナ禍に限らず、代表的ではないものも含めた価値観や心情を定量的かつ、継続的に理解しようとするにはどうすればいいのであろうか、という点である。

1-2. 本研究の目的

本研究の目的は社会に残された痕跡をもとに、人々の価値観や心情を定量的に表現する方法を検討し、それらを継続的に更新、表示するシステムを開発することとする。

2. 研究対象と分析方法

本章では、本研究で対象とする痕跡と分析方法について検討する。

2-1. 対象の検討

我々人間の価値観や心情は、記述するにはあまりにも複雑で多様である。社会に残された痕跡を定期的集めて、連続的な定量データとして扱うことを考えると、単純でわかり易いものに変換・分類が必要である。また、それらの分類のもととなる痕跡は、ある程度の集合性とある程度の離散性を持ったものであることが望ましい。その理由は、時代の振り返りのように集合的に記録されたものは、先に述べたように代表的なことに左右されてしまう一方で、個人の日記のような離散的な記録は、個別の状況が記録されているというメリットがあるが、定期的かつ継続的に残されているか不明であるため、情報の収集サイクルの中で母数に大きな差が生じたり、残された痕跡が特定の年代に集中したりする可能性があるためである。2022年8月にNHKで放送された「1942 大日本帝国の分岐点」では表現の自由が制約された時代に国やメディアが伝えなかった内容に関して、エゴ・ドキュメントをテキストデータとして捉えて、定量的、定性的な分析がされたが、このような分析は期間を区切って、戦争に焦点を当てた分析であるため可能であったと考えられる。

また、定量的、継続的に分析できる仕組みを作るには、利用する痕跡はデジタルデータであることが望ましく、インターネット上の痕跡が適している。インターネットが普及した社会では、それ以前の社会に比べて、人々の活動に関する多くの痕跡がデジタルデータとして残るようになってきた。例えば、ソーシャル・ネットワーキング・システム（SNS）上では友人との気軽な会話や個人の考え、想い、日々の生活の記録などが写真や動画とともに残されており、公開設定によっては誰でも閲覧することができる。インターネット上の掲示板には、政治、スポーツ、芸能など様々なトピックに関して匿名で自らの意見や感想が書き込まれている。新聞などのマスメディアはWeb版への置き換えが進んでおり、以前は代金を支払って購入していた情報の一部が無料で閲覧できるようになり、インターネット上に残されている。インターネットは今や社会インフラとなり、誰でもアクセスできるメディアであるとともに、存在する場所まで物理的に出向いたり、取り寄せたりする必要がないため、長い歴史の中で、人類がこれまで残してきた“痕跡”とは収集、閲覧の容易さという点で群を抜いている。そこで、本研究では、インターネッ

ト上に残された痕跡を利用することとする。

インターネット上の痕跡としては、近年は SNS が膨大な情報を有しており、離散的かつ集合的である。これらの全データを利用できる環境にあれば、非常に有益な痕跡となりうる。しかし、主要な SNS サイトは、自動化されたソフトウェアを利用してデータを無断で取得することを規約違反としている。Twitter は自社で公開している無料 API の利用によって情報収集できるものの、その量に制限がある上、仕様の変更も度々生じ、有料の API の利用には多額の費用がかかる。（ただし研究者は Standard API で利用できる量の 20 倍のツイートに無償アクセスできる）このような制限が設けられるのは、個人情報情報の観点に加えて、SNS 上の痕跡はマーケティングデータとして高い商業的利用価値があるためと考えられる。以上のように、SNS 上のデータに関しては利用方法が運営会社の方針に左右され、継続的にデータを収集できるかが不明であることから、本研究では対象外とした。

一方で、新聞の Web 版は離散的な出来事を集めることによって、ある程度の集合性をもった情報を形成し、さらには定期的、長期的な情報発信により継続性・連続性も持ち合わせているため、本研究の問題意識を解決する痕跡として適していると考えられる。Web 版以前の内容も有料ではあるが、コーパスとして利用できるため、過去に遡って分析を行う場合も同じ新聞社を利用することによって、整合性を確保できると考えられる。

また、前出のダニエル・カーネマンは、バイアスとヒューリスティックの概念が多様な分野で活用されている事例の説明として、著書であるファスト & スロー（原題：Thinking, Fast and Slow）で次のように述べている^[4]。

たとえば政策の研究者によれば、一般市民にとっては明らかなある種の問題がそれ以外の人に無視される現象は、利用可能性ヒューリスティックで説明できるという。人間は記憶から容易に呼び出せる問題を相対的に重要だと評価する傾向があるが、この呼び出しやすさは、メディアに取り上げられるかどうかで決まってしまうことが多い。ひんばんに報道される事柄は、他のことが消え失せたあとまで記憶に残る。その一方で、メディアが報道しようとするのは、一般市民が現在興味を持っているだろうと彼らが判断した事柄である。

つまり、新聞のようなマスメディアはエゴ・ドキュメントのように個人の記録ほどではないが、読者である一般市民が興味を持っていると思われる事柄を取り上げ、それらの事柄は人々に大きな影響を与えている。マスメディアは一般市民に影響を与え、一般市民はマスメディアに影響を与えると考えると、言論統制が行われていなければ、マスメディアで取り上げられる内容は、社会の状況を反映したものといえる。

以上の理由から、本研究では新聞の Web 版の記事のテキストデータを分析することとした。対象とする記事は、機械的に分析しやすい構造となっていた朝日新聞の Web 版である朝日新聞デジタル内の社会 (national)、経済 (business)、政治 (politics)、国際 (international)、IT・科学 (tech_science)、文化・芸能 (culture)、スポーツ (sports)、環境・エネルギー (eco)、ライフ (life) の各カテゴリーの記事一覧ページに記載されている全記事の無料で閲覧可能な部分と、地域 (area) カテゴリーの中の各都道府県の新着記事一覧に記載されている全記事の無料で閲覧可能な部分とした。括弧内は各カテゴリーの URL 上のディレクトリ名である。

2-2. 分析方法の検討

本研究は、人々の価値観や心情を定量的かつ継続的に分析することを目的としているが、継続的に分析するということは時系列で分析することである。時系列での分析は、一般的に横軸は時間、縦軸は割合や件数などの集計値としたグラフを使用するが、記述することすら難しい価値観や心情は集計値との相性が悪い。過去には岩井^[5]や杉崎^[6]が、価値観の定量分析として、ランダムに抽出した日付の新聞社会紙面の記事をマズローの5つの基本的欲求^[7](生理的欲求、安全の欲求、所属と愛の欲求、承認の欲求、自己実現の欲求)に分類し、分類された各欲求レベルの紙面面積の合計から価値観の変化を定量的に推定する分析を試みた。マズローの理論は、複雑で多様な行動の動機づけを5つの基本的欲求に単純化し、批判はあるものの発表から50年以上経った今もなお多くの場面で利用されている。受け入れやすさや後述するような段階性や優先性があることを考慮するとマズローの基本的欲求を分類ラベルとして利用することは合理的であると考えられる。そこで、本研究でも岩井らの方法を踏襲し、Web版の新聞記事をマズローの基本的欲求の5分類に分類し、定量化の糸口とする。そこで、ここまで「価値観や心情」と述べてき

た人間の内的な判断基準や思いは、以後、欲求として考えることとする。

集計の方法に関しては、新聞紙面という資源の上限がある媒体の中で、対象の欲求が占める面積の割合を算出し、5つの欲求の割合を表現するという、岩井らのアイディアはわかりやすいものであった。その一方で、集計に手間がかかり、日々のデータを分析することは現実的ではなく、継続的な分析には向いていない。また、紙媒体の新聞紙面は面積の制約があるが、Web版の記事では、それぞれの記事にページが存在し、紙媒体で用いた面積という概念は適切ではない。そこで、本研究では、各欲求の割合は、面積から求めるのではなく、対象日の各欲求に分類された記事数を同じく対象日の1日の記事の総数で除することで求めることとした。

対象とする記事は1日あたり200件前後あり、毎日、これら全ての記事を人間の手を介して5つの基本的欲求に分類することは現実的ではないため、分類はAI(Artificial Intelligence)を使って行うこととする。AIに関する一般論は山崎による第2部 AI 技術の概要に委ねるが、大量のテキストデータ処理では自然言語処理(NLP: Natural Language Processing)とよばれるAIを用いる。なお、記事一覧ページには他のカテゴリーの記事一覧にも掲載されている重複する記事が存在するが、それらが重複カウントされないようにURLによって重複を防ぐようなデータ処理をすることとした。

2-3. マズローの欲求段階説の概観

本節では、マズローの理論に関して、本研究に関連する内容を概観する。

動因の不可分性と基本的欲求

マズローは次のように、様々な動因や欲求は分離することができないため、詳細なリストを作成することはできないとしており、無意識的な基本的欲求こそが動機づけ理論の唯一の健全な分類の基礎であるとしている^[8]。

我々は、動因あるいは欲求について原子論的リストを作ることはきっぱりあきらめなければならない。第一に、さまざまな動因を均一なものとして、例えば強さや現れる確率を均一なものとして扱ってしまうことになる。これは、ある一つの願望が意識されるその他の優勢な願望がどの程度充足されたかによるという点からしても、正しくない。さまざまな

動因の現れる確率には大変な差異があるのである。

第二に、そのようにリスト化することは、それぞれの動因が互いに他から分離していることを意味してしまう。もちろん、いかなる状態でも分離した動因というものはないのである。

第三に、そのように動因をリスト化することは、通常、行動をもとに作られるので、動因の力動的性質すなわち、意識されたものと無意識のものとは異なっていることや、またある特定の願望が実際には他のいくつかの願望を表わす水路のような役割を果たしていることなどの事実を全く無視することになる。

(中略)

たとえば人が食物を欲しそれを得るために適切な行動をとり、かんで食べるという過程にしても、実際に求めているのは食べ物というよりむしろ安全さなのかもしれない。また、性的欲求、求愛行動、性行為という一連のプロセスにしても、実際には性的満足よりむしろ自尊心を求めているのかもしれない。内観により意識される動因や、動機づけられた行動や、またはっきりした個別的目标対象や効果でさえ、いずれも、人間の動機づけ生活を力動的に分類しようとする場合の健全な基礎とはなりえないのである。このように論理的に排除していくことによって、動機づけ理論の唯一の健全な分類の基礎として、無意識的な基本目標または欲求に到達するのである。

基本的欲求とは生理的欲求、安全の欲求、所属と愛の欲求、承認の欲求、自己実現の欲求であり、これらの満足により満たされる感情的な諸現象は下記のようなものである^[9]。

基本的欲求満足により規定される諸現象

A 意欲的なもの—感情的なもの

1. 身体的に十分満たしたという感情—食物、性、睡眠など —と、その副産物として—安寧、健康、精力、幸福、身体的満足
2. 安全、平和、補償、保護、危険や脅威のなさなどの感情
3. 所属、グループの一員である、グループの目標や功績を同一視している、受容されている、自分のいるべき位置があるなどの感情、愛

し愛されている、愛に値する、愛の同一視などの感情

4. 自己信頼、自己尊重、自尊心、自信、自己信任などの感情、能力、達成、有能、成功、自我の強さ、尊敬に値する、威信、リーダーシップ、独立などの感情
5. これら(1-4)の欲求がすべて満たされたとしても、人は、自分に適していることをしていないかぎり、すぐに(いつもではないにしても)新しい不満が生じ落ち着かなくなってくる
6. 自己実現、自己成就などの感情、自分の素質と可能性のより完全な発達と結実の感情、その結果として生じる成長、成熟、健康、自律の感情、満たされた好奇心、よりいっそう学び知ろうとする感情・・・(以後、省略)・・・

欲求の段階性と優先性

マズローの理論の大きな特徴の一つは、欲求の段階性と優先性に関する言及があることであり、それまでの動機づけ理論に関して、批判的に次のように述べられている^[10]。

これまで動機づけ理論を構築してきた人達は、次のような事実のどちらにも然るべき注意を払わなかった。すなわち第一に、人間というものは、相対的にあるいは一段階ずつ階段を踏んでしか満足しないものであり、第二にいろいろな欲求間には一種の優先序列の階層が存在するという事実である。

ここで注意したいのは、一つの欲求が完全に満たされないと次の欲求が現れないというアルゴリズム的なものではなく、以下のように相対的な満足度によって次の欲求は現れるとされている点である^[11]。

これまで理論的に論じてきたところでは、これら5つの欲求は、一つの欲求が満たされると次の欲求が現れるというような関係あるかのような印象を与えたかもしれない。これは一つの欲求は、次の欲求が現れる間に100%満たされなければならないかのような誤った印象を与えることになる恐れがある。・・・(中略)・・・

優勢な欲求が満たされた後に新しい欲求が現れるということについて述べると、この現れは突然一足とびの現象ではなくて、無からゆっくりと徐々に現れてくるのである。たとえば優勢な欲求 A が 10% しか満たされないと、欲求 B は全く目に見えないであろう。ところが、この欲求 A が 25% 満たされると欲求 B は 5% 出現し、欲求 A が 75% 満たされると、欲求 B は 50% 現れるという具合である。

2-4. 欲求レベルと分類衝突

前節で引用したように、マズローの理論では動因や欲求の原始的リストを作ることはできず、生理的欲求、安全の欲求、所属と愛の欲求、承認の欲求、自己実現の欲求の基本的欲求こそが、動機づけ理論の唯一の健全な分類の基礎であるとし、これらの基本的欲求には段階性と優先性が存在するとしている。岩井らはマズローの基本的欲求の段階性と優先性の考え方を引用し、次のように欲求レベルという考え方を定義した^[5]。

その人の行動を一番強く動機づけている欲求、すなわち最優先で持っている欲求

この定義では新聞記事に取り上げられている人々が最優先で持っている欲求を基本的欲求に分類しているが、前述したようにマスメディアは読者である一般市民が興味を持っていると思われる事柄を取り上げ、人々はそれらに影響を受ける。記事に取り上げられている人々の欲求レベルに着目するのか、読者が記事を読んで、どのように感じるかに着目するのか、という議論は必要であろう。表現を簡便にするために、記事に取り上げられている主体に着目する場合を A、読者がどう感じるかに着目する場合を B とし、1つの記事の分類の際に A-B 間で異なる分類になることを A-B 間の分類衝突とよぶことにする。その他、記事に複数の主体が取り上げられている場合に A-A 間の分類衝突も考えられ、読者の間でも捉え方が異なると B-B 間の分類衝突も起きる。

自己実現の欲求に関しては、特に A-B 間の分類衝突が発生しやすいと考えられる。なぜなら、自己実現の欲求は、新聞記事によって自己実現の欲求を満たされたり、欠乏したりすることはない。他の 4 つの欲求が欠乏欲求であ

るのに対して、自己実現の欲求は成長欲求であり、欠乏感を埋めるものではなく、自分の内側から溢れ出てくる豊かさから生じる欲求であるからである。自己実現の欲求以外にも、A-B間の分類衝突は頻繁に生じる。例えば、犯罪という事実の背後には犯罪を犯した者が存在し、多くの場合は被害者も存在する。犯罪の記事は、犯罪を犯した者の何かしらの欲求レベルを示すとともに、被害者の安全や安定的な状態を侵され安全の欲求の欠乏を表しているとも解釈できる。一部の読者にとっては恐怖や治安に対する不安を感じ、そのような状態から解放されたい欲求が出現することも考えられる。このように、犯罪の記事に関しては、犯罪を犯した者が安全の欲求に動機づけられている場合を除き、A-A間、A-B間の分類衝突が起きる。高校野球の記事では、取り上げられた選手たちの承認や自己実現の欲求を示すとともに、読者は地域の代表の目標や功績を同一視し、所属と愛の欲求の充足を得ている場合もある。この場合、A-B間の分類衝突が起きている。生理的欲求や安全の欲求に関する問題を解決するための支援では、支援を行う側は、より高次の欲求に動機づけられており、A-A間の分類衝突が起きる。対象とした朝日デジタルの会員数は400万人を超えており、読者の状況や捉え方は予測が困難であることから、B-B間の分類衝突はさらに複雑であると考えられる。

以上のように、分類衝突は頻繁に発生する現象であり、分類する上での優先順位が必要である。Bに着目することは難しいため、本研究では、岩井と同様にA（記事に取り上げられている主体）の行動を最も強く動機づけている欲求を欲求レベルと定義し、分類することとし、主体が複数存在する場合は、より焦点を当てられている主体の欲求レベルを採用することとする。

3. システム開発

本章では、欲求レベルの可視化を実現するために開発した3つのシステムについて説明する。

3-1. システムの概要

本研究で開発したシステムは、図 1-1 に示すように、情報収集と分類・集計を司るシステム（以後 ICCAS とよぶ：Information Collection, Classification, Aggregation System）、機械学習を司るシステム（以後 MLS とよぶ：Machin Learning System）、Web 上での時系列データ表示を司るシステム（以後 WVS とよぶ：Web Visualization System）の3つである。

ICCAS は Web 上の記事の URL をデータベースに保存する。保存された URL の一部には、MLS での学習用の教師データとして、後に分類者が Web ページを閲覧して分類した欲求レベルが紐づけされる。MLS は作成された教師データを用いて、新聞記事を5つの欲求レベルに分類するための学習を行う。学習後に作成されたモデルファイルを ICCAS にインポートすることで、ICCAS は日々、Web 上の記事を自動的に分類し、各欲求レベルの割合の7日間の移動平均が WVS に集計値として送信される。このプロセスによって、再学習以外は人間の手を離れて、毎日、自動的に更新され、その結果を WVS を介して Web 上で閲覧することができる。

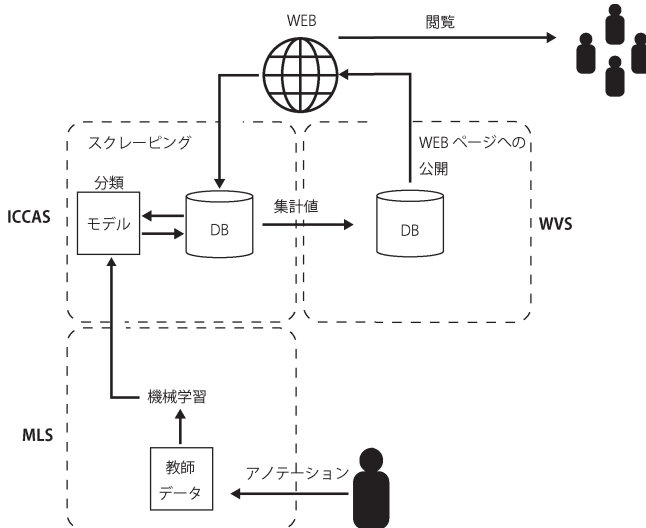


図 1-1 システム概要

3-2. ICCAS

ICCAS の開発言語は Python3.8、URL を保存するデータベースは MySQL5.0 である。Web スクレイピングという Web 上の情報を自動収集する技術の利用には、Selenium ライブラリを使用した。分類には Facebook AI Research が公開（初回リリース：2015 年）した自然言語処理ライブラリ fastText^[12] を使用した。fastText は、対象となる単語の周辺語の共起確率を計算してベクトル化することで単語分散表現を学習する自然言語処理ライブラリで、単語のベクトル化やテキスト分類を行う際に用いられる^[13]。fastText の前身となったアルゴリズムとして word2Vec が存在するが、fastText は単語分散表現の学習速度が速く、また、Subword model^[14] による活用語や未知語のベクトル化にも対応している。fastText の利用方法は「単語表現学習 (Word representation learning)」と「文章分類 (Text classification)」の 2 通りがあり、単語表現学習では単語を学習させて、似ている単語などを抽出し、分散表現によって king - man + woman = queen などの分析が可能である。文章分類では「__label__」のプレフィックスをつけた分類で文章を学習させることで、文章分類ができる。どちらの機能も、学習させる文章は語の区切りに空白を挿入した、分かち書きした文章が必要となる。ICCAS では分かち書きした文章の作成に形態素解析のライブラリで実装が容易である Janome を使用した。

ICCAS による URL の収集は 8 時間の間隔を空けて、継続的かつ自動的に行われ、記事の URL と分類結果がデータベースに 1 レコードとして登録される。ここでの分類結果は MLS での学習結果が反映されたモデルファイルを利用して分類されたものである。

記事の URL の収集は 2020 年 1 月 10 日から開始したが、途中、スクレイピング対象の Web ページの仕様変更に対応するためのシステム変更などの理由で、十分な数の記事 URL を収集できなかった期間があるため、1 日の収集件数が 100 件に満たなかった日のデータは集計対象としないこととした。2020 年 1 月 10 日から 2022 年 11 月 30 日の 1056 日中、集計対象外となっている日数は、76 日であった。

3-3. MLS

MLS の開発言語は Python3.8 を用い、学習のための自然言語処理には

ICCAS と同様に fastText、Web の閲覧には Selenium ライブラリを使用した。学習の際は、保存された URL の記事のカテゴリ、タイトル、内容（無料で取得できる部分のみ）と、あらかじめ保存してある分類結果と合わせて教師データとして利用した。記事の内容はデータベースに保存されない。

学習は生理的欲求、安全の欲求、所属と愛の欲求、承認の欲求、自己実現の欲求の 5 種類のラベルを付与した 2333 件の教師データを使って行なった。作成した教師データは 8 割の確率で訓練用データに、2 割の確率でテスト用データに振り分けられるようにした。なお、教師データへの 5 種類の分類ラベルの付与は分類者が手動で行なった。

また、社会で起こる新たな出来事を反映させるために定期的に教師データを増やし、再学習を行い、ICCAS で使用するモデルのアップデートを行った。

再学習を行なった後に ICCAS に採用するモデルは、epoch 数を 80 から 110 まで設定し、最も精度が高かったモデルとした。epoch 数とは同じデータを何回繰り返して学習するかの数であり、一般的に epoch 数が少なすぎると学習が進まず、epoch 数を多くし過ぎると学習データにだけ適応した学習ばかりが過剰に進んでしまい、未知のデータに対して推定する性能が下がる過学習の状態になってしまう。

3-4. WVS

WVS の開発言語は Python3.8、JavaScript、HTML、データベースは MariaDB10.5 を使用した。WEB フレームワークには Flask ライブラリを使用し、グラフ描画には Chart.js ライブラリを用いた。WEB サーバーの負荷を軽減するために、ICCAS からは集計された値のみが WVS に送られ、WVS のデータベースに保存される。WEB ページからは WVS のデータベースの値が参照されて、図 1-2 のような欲求レベルの変化のグラフが描画される。WVS には ICCAS から毎日自動的にデータが送信されるため、描画されるデータはその時点での最新のものとなる。




図 1-2 WVS の表示例

3-5. 検証

図 1-3 は epoch 数を 5 から 300 まで変動させた際の精度を示したグラフである。今回使用した教師データでは epoch 数が 100 を超えると精度は 74% 前後でほぼ安定していた。この中で最も精度が高かったモデルが、テストデータで間違った予測をした結果の内訳を表 1-1 に示す。誤答の傾向は大きく分けて 2 つである。1 つは、対象とした期間の多くの記事で、安全の欲求に関するだけでなく、新型コロナウイルスの影響について述べられているため、記事の長さが長くなるにつれて、安全の欲求についても書かれているかのように捉えられる記事である。もう 1 つは、新聞記事内に主体が 2 つ以上存在する、2-4 で述べた A-A 間の分類衝突である。例えば、新型コロナウイルスの感染拡大により困っている人々に寄付や寄贈によって支援するという




図 1-3 epoch 数と精度

表 1-1 間違え

		予測					計
		生理	安全	所属愛	承認	自己実	
教師	生理	0	2	0	1	1	4
	安全	1	0	5	8	16	30
	所属愛	0	6	0	8	21	35
	承認	0	18	5	0	9	32
	自己実	2	6	7	5	0	20
		3	32	17	22	47	121

表 1-2 正答時と誤答時の平均予測確率

正答時	確率	誤答時	確率
生理	0.94	生理	0.67
安全	0.97	安全	0.68
所属愛	0.93	所属愛	0.71
承認	0.93	承認	0.71
自己実	0.96	自己実	0.73

記事では、支援を受ける人々は安全の欲求によって動機づけられ、支援する方は所属と愛の欲求、もしくは自己実現の欲求によって動機づけられていると考えられる。このように、どちらに分類するか、人間でも判断に迷うような記事も多数あり、教師データと予測結果が異なったほとんどの記事は、上記2つのような記事であったが、曖昧さを含む自然言語の分類において、74%前後の精度は許容できる範囲であると考えられる。

集計結果における精度を向上させたいければ、予測確率によるフィルタリングも考えられる。fasttextでは予測の際に予測確率が示されるが、表1-2に示すようにテストデータでの正答時と誤答時に平均予測確率に差があるため、予測確率に閾値を設けて、閾値に達しないデータは集計しなければ、集計においては予測精度が高いデータだけが残る。

しかし、フィルタリングの閾値を予測確率0.8にして集計を行うと、残存するデータが図1-4に示すように70%程度と少なくなってしまう。そのため、本報では74%の精度は推移の傾向としては大きな影響を与えないと考え、閾値を設けず、全データを使用して、以後の分析を行うこととした。




図 1-4 閾値を設けた場合のデータ残存率

4. 欲求レベルの時系列分析

本章では、開発した欲求レベルの可視化システムを用いて、欲求レベルの推移に関する分析を行う。なお、以後の新型コロナウイルス感染症による1日の新規感染者数や死亡者数は厚生労働省のオープンデータ^[15]を使用した。

4-1 代表的な事柄：安全の欲求の割合に関して

まずは、この時代に代表される“新型コロナウイルス感染拡大”という事柄が安全の欲求与えた影響に関して分析する。本報での新型コロナウイルスとは、2019年12月以降、中華人民共和国湖北省武漢市で原因不明の肺炎患者から検出された新種のコロナウイルスを指し、2020年2月11日に世界保健機関（WHO）によって「COVID-19 (coronavirus disease 2019)」と定められたものである。

第5波以降は新規感染者数が大幅に増加するため、まずは第1～4波の時期にあたる2020年1月10日から2021年6月30日までの新型コロナウイルスの新規感染者数と欲求レベルの変化の関係を図1-5に示す。安全の欲求の割合は、日本で新型コロナウイルス感染拡大の第1波が始まった2020年4月上旬から中旬の期間が最大となっており、以後、全体的には下降傾向にある。第2波の2020年7～10月の期間では、若干の上下はあるものの、第1波ほどの顕著な上昇は見られず、第3波の2020年10月～2021年2月の期間ではそれまでの下降傾向が一旦止まり、上昇が見られた。その後の第4波での、安全の欲求の割合は第3波とほぼ同等であった。

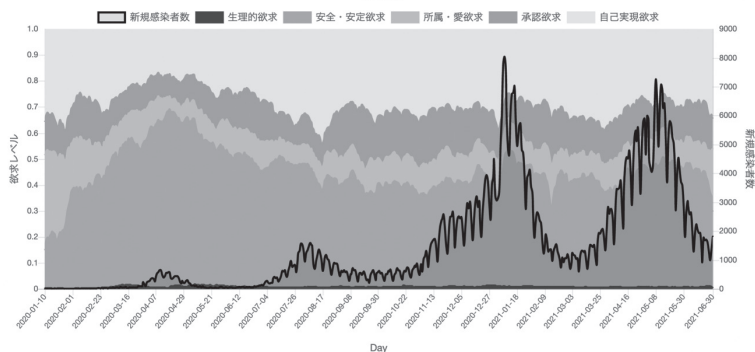


図 1-5 新規感染者数と欲求レベルの変化（第1～4波）

安全の欲求の割合が最も高くなった第1波に関して、詳細を分析するために、第1波前から1回目の緊急事態宣言解除までの主な出来事を表1-3に示す。2019年12月に中国の武漢で原因不明の肺炎患者から新型コロナウイルスが見つかり、2020年1月16日に国内で初の感染者が確認されたが、その時点では安全の欲求の割合はまだ高くなかった。安全の欲求の割合が、急激に増加し始めたのは2020年1月下旬以降である。1月26日に中国武漢に在留している日本人のうち、希望者をチャーター機で帰国させる方針が発表され、中国で起きていることが、いよいよ日本国内にも関係することとして捉えられ始めたことがうかがえる。また、1月20日に横浜港を出港していた大型クルーズ船ダイヤモンド・プリンセス号に新型コロナウイルスに罹患している乗客がいたことが判明し、2月1日に那覇港から横浜港に引き返し、検疫が実施された。連日のように感染者の数が発表され、その数が増えていくにつれて、安全の欲求の割合も上昇していった。2月中旬には安全の欲求の割合の上昇は一旦落ち着ついたが、ダイヤモンド・プリンセス号で感染が確認されず症状のない者の下船がはじまり、乗客の日本人2名が死亡した前後で再度ゆるやかに上昇が始まり、2月下旬に再び急上昇し始めるまでの約2週間は比較的ゆるやかな上昇が続いた。安全の欲求の割合が、再度、急上昇し始めた2月28日は、前日に全国の小学校、中学校、高校に臨時休校が要請され、新型コロナウイルスが、単なる未知の恐怖対象ではなく、実際に、多くの国民の生活に影響を及ぼし始めた時期といえる。この時期に安全の欲求の割合は50%を超え、3月下旬に一旦上昇は落ち着くものの、東京都で新規感染者

数が初めて100名を超えた4月4日以降は、ピークに達する4月中旬まで激な上昇が続いた。その後は、時期による上下はあるものの、第3波初期の11月上旬まで下降傾向が続いた。

表 1-3 第1波前後の主な出来事

年月日	出来事
2020/1/16	新型コロナウイルスの国内初の感染者が確認される
2020/1/26	中国武漢に在留している日本人で、希望する人を全員、帰国させる方針を発表
2020/1/29	中国武漢現地邦人の帰国希望者の政府のチャーター機第1陣が羽田空港に到着。体調不良を訴えた者は入院し、症状のない者は政府の用意したバスで国立国際医療研究センターに移動し、改めて検査を行い、陰性が確認されるまで自宅や千葉県勝浦市のホテルで待機すること、症状の無い2人が帰国後の検査に同意しなかったことなどが報道される。
2020/2/1	2020/1/20に横浜港を出港したダイヤモンドプリンセス号の乗客で1/25に香港で下船した乗客が新型コロナウイルスに罹患していたことが確認された。那覇港で船員乗客に対して検疫を実施。
2020/2/3	ダイヤモンドプリンセス号の船員乗客に対して横浜港にて再度検疫を実施
2020/2/5	ダイヤモンドプリンセス号の乗客乗員のうち10人から新型コロナウイルスの感染が確認されたと発表
2020/2/6	ダイヤモンドプリンセス号で新たに10人の新型コロナウイルスの感染者が確認されたと発表
2020/2/7	ダイヤモンドプリンセス号で新たに41人の新型コロナウイルスの感染者が確認されたと発表
2020/2/10	ダイヤモンドプリンセス号で新たに60人以上の新型コロナウイルスの感染者が確認されたと発表
2020/2/19	ダイヤモンドプリンセス号の乗客のうち、ウイルス検査で感染が確認されず、症状のない者の下船が始まる。
2020/2/20	ダイヤモンドプリンセス号の乗客の日本人2人が死亡したと発表
2020/2/21	WHOによって、新型コロナウイルス感染症の正式名称がCOVID-19 (coronavirus disease 2019) と定められた。
2020/2/27	全国の小中高に臨時休校を要請
2020/2/28	北海道が独自の緊急事態宣言
2020/3/11	世界保健機関 (WHO) がパンデミックを宣言
2020/3/25	東京都で週末の不要不急の外出自粛要請
2020/4/4	東京都で初めて1日の新規感染者数が100人を超える
2020/4/7	東京、神奈川、埼玉、千葉、大阪、兵庫、福岡の7都府県を対象緊急事態宣言発出
2020/4/16	緊急事態宣言を全国に拡大 北海道、茨城、東京、神奈川、埼玉、千葉、石川、愛知、岐阜、大阪、京都、兵庫、福岡を特定警戒都道府県に指定
2020/4/18	全国の感染者が累計1万人突破
2020/5/14	北海道、東京、神奈川、千葉、埼玉、大阪、京都、兵庫以外の39県で緊急事態宣言解除
2020/5/25	全国で緊急事態宣言解除

安全の欲求の割合に関して、特筆すべきは、新規感染者で比較すると、第2波の最大値（1597名）は第1波の最大値（644名）の2倍以上あるにもかかわらず、第2波では第1波ほど安全の欲求の割合が増加しなかったことである。この時点で、新規感染者数では安全の欲求があまり反応しなくなったといえる。図1-6は欲求レベルの変化に新型コロナウイルスによる日毎の死亡者数を重ね合わせたグラフである。第1波と第2波では死亡者の最大値はほぼ同じであることがわかる（第1波25名、第2波19名）。安全の欲求が再び上昇し始めた11月上旬は新型コロナウイルスによる死亡者数が第1波の最大値（25名）を超え始めた時期である。この結果は、人々の安全の欲求に反応する閾値が感染から死亡に引き上げられたことを示唆している。その後、2回目の緊急事態宣言が2021年1月8日に発令された直後に、安全の欲求の割合が、この時期の上昇のピークを迎えた。3月には第4波が始まり、4月25日に東京都など4都府県に3回目の緊急事態宣言が発令されたが、新規感染者数や死亡者数が5月18日の数値を除いて第3波と大きな差がなかったため、安全の欲求の割合も第3波の期間とほぼ同水準であった。

ここまでは、新型コロナウイルスの第1～4波の時期にあたる2020年1月10日から2021年6月30日のデータに関して分析してきたが、新規感染者数が急激に増加した第5波以降も含めた、2020年1月10日から2022年10月30日までの欲求レベルと新規感染者数の関係を図1-7、死亡者数との関係を図1-8に示す。第4波後の2021年7月から8月にかけて一時的に急激に自己実現の欲求の割合が上昇し、安全の欲求の割合が下降しているが、この時期は2020年に開催されるはずであった、東京オリンピックが1年延期されて開

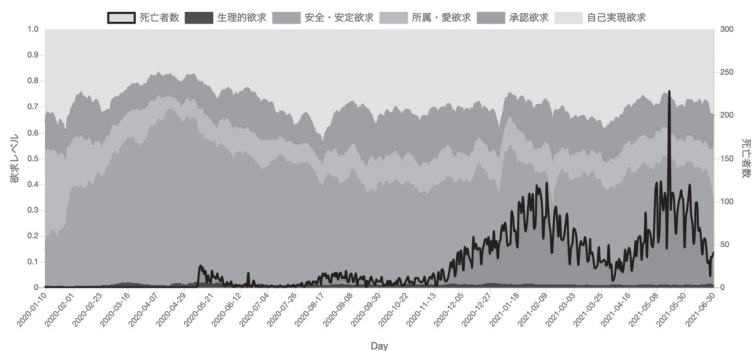


図1-6 死亡者と欲求レベルの変化（第1～4波）




図 1-7 新規感染者数と欲求レベルの変化（第 1～7 波）

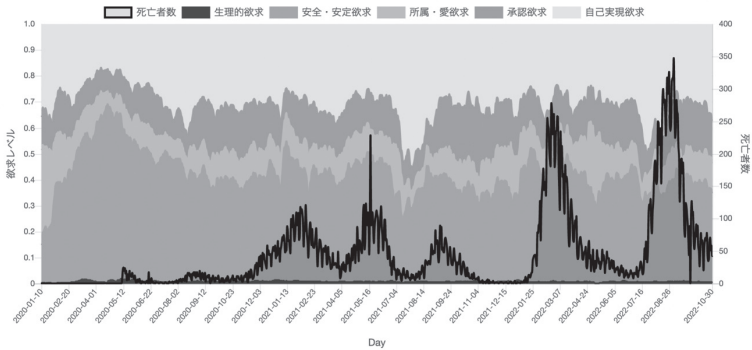


図 1-8 死亡者と欲求レベルの変化（第 1～7 波）

催された時期である。東京オリンピック開催中から新規感染者は増加傾向にあり、第 5 波の新規感染者数はピークで 2 万 5 千人を超える数値であるにもかかわらず、死亡者数の最大値は第 4 波よりも少ないこと、オリンピックにより世の中の雰囲気が変わったことなどが影響してか、オリンピック終了後の安全の欲求の水準はオリンピック前よりも低い水準となっていた。2022 年 1 月からの第 6 波では新規感染者数が、これまでの最大値の 4 倍にあたる 10 万人を超え、死亡者数も急激に増加した（その後、新型コロナウイルスによる死亡者数が過去最多となった）ためか、安全の欲求の割合は一時的に急上昇した。しかし、その後 3 週間で急下降している。2 月中旬以降、安全の欲求は再び第 6 波の最大値程度に急上昇したが、この上昇に関しては、死亡者数が過去最多を記録したことも影響しているが、ロシアがウクライナに侵攻したことが主な要因であった。日本と領土問題を抱えるロシアが、他国に侵攻

しことは日本人にとっては安全を脅かす脅威であったと考えられる。その後、安全の欲求の割合は、その後すぐに下降し始め、2022年4月には第6波前の水準に戻った。第7波では新規感染者の数が最大で26万人となったが、安全の欲求の割合は第6波のレベルには達さず、むしろ夏の時期でスポーツの大会などが多く、自己実現の欲求の上昇に伴い、安全の欲求の割合は下降した。

4-2 代表的ではない事柄

ここまでは、この時代に代表される“新型コロナウイルス感染拡大”という事柄による、安全の欲求の割合の推移に着目してきたが、ここからは、本研究の問題意識の起点である、代表的ではないものも含めた欲求レベルの推移に着目する。図 1-9 は 2020 年 1 月 1 日から 2022 年 12 月 8 日までの安全の欲求以外の 4 つの欲求レベルの割合の変化、表 1-4 は各欲求レベル相関関係

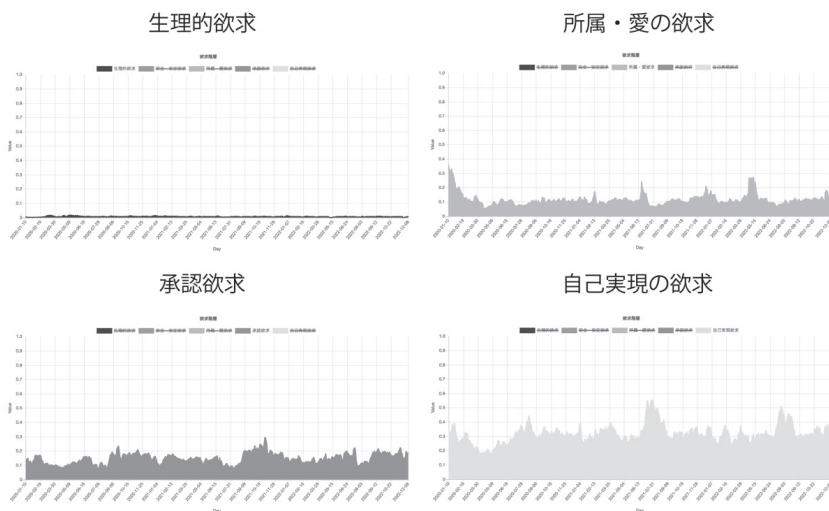


図 1-9 安全の欲求以外の欲求レベルの変化

表 1-4 欲求間の相関関係

	生理	安全	所属・愛	承認	自己実現
生理	1				
安全	0.456	1			
所属・愛	-0.377	-0.491	1		
承認	-0.026	-0.406	0.084	1	
自己実現	-0.345	-0.702	-0.07	-0.129	1

である。安全の欲求以外では、高次の欲求ほど割合が高い傾向にあった。生理的欲求の割合はほとんどの日で1%未満であり、新聞記事において生理的欲求が取り扱われることはほぼなかった。現代の日本では、飢餓はほとんど存在せず、性的な欲求も新聞記事で語られることはほとんどないためであると考えられる。ただし、第1波の際は、需要の急激な減少や休業要請などで職を失い、食べることもできない状況の増加によって、生理的欲求の割合は増えていた。表 1-4 に示すように欲求間の相関関係でも生理的欲求と安全の欲求の間には正の相関関係 ($r=0.456$) が認められた。

所属と愛の欲求は、基本的に年末年始やゴールデンウィークなどに増える傾向がある。ただし、2020年度は人の行動が制限されていたり、様々な行動を自粛するムードであったためか、季節による顕著な変動は見られなかった。また、安全の欲求との間には負の相関関係 ($r=-0.491$) が認められた。2021年6月下旬から7月上旬にかけては所属と愛の欲求が一時的に急上昇しているが、この期間は、安全の欲求の割合が急激に下降した時期と自己実現の欲求の割合が急激に上昇し始めた時期の間の期間であったことは非常に興味深い。

承認の欲求は、今回観測した期間では季節変動などは見られなかったが、2021年のオリンピック以降は、オリンピック前と比べて高くなっていた。安全の欲求との相関関係は全ての欲求の中で最も弱かった ($r=-0.406$)。

自己実現の欲求の割合は、オリンピックや高校野球、各種全国大会などのイベントが集中する夏休み期間に上昇するという季節変動がみられるが、今回観測した期間では、表 1-4 に示したように、安全の欲求と間に強い負の相関関係 ($r=-0.702$) が認められた。所属と愛の欲求、承認の欲求も安全の欲求との間に負の相関が認められたが、自己実現の欲求と安全の欲求の負の相関関係が最も強かった。つまり、新型コロナウイルスの感染拡大による、安全の欲求の割合の上昇に、最も影響を受けたのは自己実現の欲求といえる。この事実は、「欲求は高次になるほど弱く、変わりやすく、抑制されやすい」^[16] というマズローの主張が定量的に証明されたともいえる。

本報で取り上げた期間は、おそらく後々は「新型コロナウイルスが猛威を振った時代」というに語られるであろう。しかし、安全の欲求の割合がピークに達した2020年4月においても、より高次の欲求が存在していたことは、これまで示してきた。人々は新型コロナウイルスの脅威から身を守りたいとい

う欲求と向き合いながら、他の人々と繋がりたい（所属したい）と思い、共通の話題を持つことで地域などのグループの一員であることを感じ、同じグループの人々に感謝した。また、それぞれの居場所で達成や成功、信頼、尊重を望み、さらには、好奇心や自己成就、自分の素質と可能性のより完全な発達と結実のために行動している。その一例として、安全の欲求が高かった2020年3月下旬から5月までの、所属と愛の欲求、承認の欲求、自己実現の欲求に関する記事タイトルの一例を示す。

以下、朝日新聞デジタルより

所属と愛の欲求

- 2020-03-26 | 浦安の修了式、ディズニーの贈り物 「子どもに笑顔を」
- 2020-04-01 | 社長と2m、自宅でもスーツ…コロナで様変わりの入社式
- 2020-04-01 | コロナに負けず、被爆者が「オンライン証言会」
- 2020-04-05 | 宴会自粛、今こそオンライン飲み会を
- 2020-04-11 | 稚内にも群衆 魚価高く港に活気
- 2020-04-15 | フリースクール、教室からオンラインに
- 2020-04-19 | 舞鶴公園の藤、まもなく満開
- 2020-04-21 | オンライン授業で新しい学び 四日市工高の専攻科
- 2020-04-25 | 岡山) 医療関係者にエールを！ 岡山各地で始まる
- 2020-04-25 | 医療関係者を応援 ライトアップや拍手
- 2020-04-26 | 日本一まずい？臭い？油みたい？クセ強い新潟の温泉たち
- 2020-04-27 | 高校生の挑戦、オンラインで支援 雲南・幸雲南塾
- 2020-05-05 | 高卒の内定99・2% 過去6番目の高さ
- 2020-05-06 | 富山大生がオンライン新歓 200人余参加
- 2020-05-08 | 1カ月遅れの始業式 竹田市の小中学校
- 2020-05-08 | 学校、各地で再開 岩手大はオンライン授業
- 2020-05-14 | オンライン昼食会で仲良しに 鈴鹿高の新入生
- 2020-05-15 | 広がるオンライン授業 先生は試行錯誤
- 2020-05-21 | 雪解けの山腹に白い馬 さあ田植えシーズン
- 2020-05-24 | 待ちに待ってた入学式 久留米の市立小46校
- 2020-05-28 | 「茨城どうなってんだ」逃亡クジャク、パンにつられ御用

承認の欲求

- 2020-03-25 | 東邦銀トップ13年ぶり交代 佐藤専務が新頭取に
- 2020-03-25 | 労使対立の佐野SA売店、運営会社変更へ 4月から
- 2020-03-30 | 関電に「極端な内向き文化」 問題山積み、改善へ高い壁
- 2020-04-01 | (宮崎) 都城「かかし亭」の弁当、グランプリで金賞受賞
- 2020-04-02 | iPS 備蓄、京大から独立 公益財団法人で実用化進める
- 2020-04-04 | 「日本一リッチな村」20年ぶりの政権交代 驚きの公約
- 2020-04-09 | (山口) 笠戸ひらめPRへ 下松市がレシピ冊子
- 2020-04-11 | 酒造りの白糖、発酵させてラスクやかきんとんに
- 2020-04-14 | ロボットやAI使うスマート農業 西条で実証実験
- 2020-04-18 | 人気のかんきつ類、カラマンダリン 収穫に大忙し
- 2020-04-16 | おしゃれなコンポストが人気 におい抑え虫わかず
- 2020-04-16 | 食べやすさと味にこだわる介護食 主食からデザートまで
- 2020-04-23 | シャープのマスク、抽選販売に変更 27日にサイト再開
- 2020-04-27 | 送料いりません コロナ拡大で出版社直販サービス
- 2020-04-29 | 「未来コンビニ」木頭にオープン 地区内初
- 2020-04-28 | 燃料電池「エネファーム」お得感アップも普及これから
- 2020-04-28 | (和歌山) 摘み立て新茶 一服いかがが 白浜・川添茶
- 2020-05-01 | (熊本) 「隠れ家」イタリアン、弁当に活路

自己実現の欲求

- 2020-03-25 | 大丈夫、できる！できる！パラメタリスト、前向き合言葉
- 2020-03-25 | 国こだわらぬ「地球市民」キップ・A・ケイツさん
- 2020-04-03 | 特許取ったのは小学4年生 絡まないハンガー考案
- 2020-04-03 | 絵文字、やさしい文 障害ある人たちも読書楽しめるように
- 2020-04-05 | 比の子どもたちにランドセル 中津の住職呼びかけ
- 2020-04-06 | 刀鍛冶人生「終活」楽しむ 刀匠・河内國平さん
- 2020-04-07 | 「障害者アート」を越えて アール・ブリュットの6人展
- 2020-04-13 | 久保建「毎試合多く学んでいる」
- 2020-04-14 | やりたいこと見つけようぜ 「ルフィ」から休校中の君へ
- 2020-04-17 | サッカーの長友、500万円寄付
- 2020-04-17 | MLB選手、400万食超寄付へ

- 2020-04-22 | 古典の名品×現代作家 新たな魅力を「蔵出し」
2020-04-22 | 3D プリンターでフェースシールド自作 小学生が寄
2020-04-24 | MISIA が褒めた少年の歌声 夢紡ぐ場「希望の学校」
2020-04-24 | 金大がフェースシールド作り 病院に無料提供 石川
2020-04-26 | コロナに向き合う人々 マスク作りや新作和菓子
2020-04-30 | 2人の「かっこいい」追求し20年 ラブ・サイケデリコ
がベスト盤
2020-05-04 | 最前線で闘うあなたに 豪州で「優しさのパンデミック」
2020-05-08 | 困難を乗り越える力とは ジャーナリスト・増田明美さん
2020-05-11 | 「ほんとうにつらい」全日本吹奏楽コンなど中止
2020-05-13 | 神奈川) 鎌倉の飲食店有志が病院に弁当配達開始

安全の欲求の割合がピークを迎えた後には、困っている人々への寄付や、個人防護具の寄贈、コロナの時代に対応するための商品開発、人とのつながりが急激になくなった状況でのサポートやコミュニティの継続など、コロナ前にはなかった、安全欲求を解消するためのより高次の欲求が現れはじめたこともわかる。

5. 結言

本研究では、代表的ではないものも含めた価値観や心情を定量的かつ、その変化を継続的に理解することを問題意識の起点として、3つのシステムを開発し、それらを連携されることで、社会の欲求レベルの継続的な可視化を可能にした。

開発したシステムを用いて、コロナ禍での欲求レベルの推移を分析した結果、安全の欲求の急激な上昇と緩やかな下降の様子を確認し、新型コロナウイルスの新規感染者数や死亡者数との比較によって、安全の欲求に反応する閾値が、より安全を脅かす事象に変化していることが確認できた。また、コロナ禍の安全の欲求の割合の上昇によって最も影響を受けたのは、自己実現の欲求であった。

安全の欲求の割合がピークを迎えた後には、困っている人々への寄付や、個人防護具の寄贈、コロナの時代に対応するための商品開発、人とのつながりが急激になくなった状況でのサポートやコミュニティの継続など、コロナ

前にはなかった、安全欲求を解消するためのより高次の欲求が現れた。安全の欲求の割合が落ち着き始めた頃からは、所属・愛の欲求や自己実現の欲求の割合に季節性が確認された。季節性に関しては、一時的な現象の可能性もあるため、継続的な観察が必要である。

今後の課題としては、予測精度向上と、本研究でデータを収集し始めた2020年1月10日以前のデータも加えた、長期的な欲求レベルの推移を分析できるようにすることである。Web版の記事の一覧リストは毎日書き換えられるため、以前の内容はコーパス利用の検討が必要である。

参考文献

- [1] Tversky, A., & Kahneman, D. (1973). Availability: A heuristic for judging frequency and probability. *Cognitive psychology*, 5(2), 207-232
- [2] Kahneman, D., & Tversky, A. (1972). Subjective probability: A judgment of representativeness. *Cognitive psychology*, 3(3), 430-454.
- [3] Thorndike, E. L. (1920). A constant error in psychological ratings. *Journal of applied psychology*, 4(1), 25.
- [4] Daniel Kahneman (2012) *Thinking, Fast and Slow*. 村井章子 (訳: 2014) *ファスト&スロー (上)*, 早川書房, P23
- [5] 岩井祐治 (1995). 新聞社会面にみる日本人の価値意識の変化に関する研究, 慶應義塾大学大学院理工学研究科修士論文.
- [6] 杉崎真美 (1995). マズローの理論に基づく社会的価値構造モデルの提案, 慶應義塾大学大学院理工学研究科修士論文.
- [7] Maslow, A. H. (1981). *Motivation and personality*. Prabhat Prakashan. 小口忠彦 (訳: 1987) *人間性の心理学*, 産能大出版部, P56-72
- [8] Maslow, A. H. (1981). *Motivation and personality*. Prabhat Prakashan. 小口忠彦 (訳: 1987) *人間性の心理学*, 産能大出版部, P40-43
- [9] Maslow, A. H. (1981). *Motivation and personality*. Prabhat Prakashan. 小口忠彦 (訳: 1987) *人間性の心理学*, 産能大出版部, P111-112
- [10] Maslow, A. H. (1981). *Motivation and personality*. Prabhat Prakashan. 小口忠彦 (訳: 1987) *人間性の心理学*, 産能大出版部, P40
- [11] Maslow, A. H. (1981). *Motivation and personality*. Prabhat Prakashan. 小口忠彦 (訳: 1987) *人間性の心理学*, 産能大出版部, P83

- [12] Bojanowski, P., Grave, E., Joulin, A., & Mikolov, T. (2017). Enriching word vectors with subword information. Transactions of the association for computational linguistics, 5, 135-146.
- [13] Joulin, A., Grave, E., Bojanowski, P., & Mikolov, T. (2016). Bag of tricks for efficient text classification. arXiv preprint arXiv:1607.01759.
- [14] Mikolov, T., Sutskever, I., Chen, K., Corrado, G. S., & Dean, J. (2013). Distributed representations of words and phrases and their compositionality. Advances in neural information processing systems, 26. (分散表現)
- [15] 厚生労働省データからわかる - 新型コロナウイルス感染症情報 - (<https://covid19.mhlw.go.jp/>)
- [16] Maslow, A. H. (1981). Motivation and personality. Prabhat Prakashan. 小口忠彦 (訳: 1987) 人間性の心理学, 産能大出版部, P154

第2部

AI技術の概要

山崎友彰

1. AIについて

本研究は、AIや人工知能という言葉で表されることの多くなったディープラーニングの技術を利用したものである。この技術はさまざまな分野で使用されるようになっていて、少し前まで見かけることの多かった「AIとは何か」という疑問も、最近は投げかけられることが少なくなってきたように思える。技術レベルは実用化できるまでに高まってきたと言えるだろう。既に多くの資料で人工知能の成り立ちなどは読むことができるが、この技術が定着するにつれて“IT”や“自動化”という文脈で用いられている様子もある。そこで、第2部においては、その成り立ちや現在の利用状況等を簡単に説明することを目的とする。

2006年ごろに始まったと言われる第三次人工知能ブームは現在も続いている。それまでは、人が加工しながら重要と思われる情報をデータから特定し、それをコンピューターが理解できる形に変換する、というプロセスを経て、実用可能となるレベルの人工知能を生み出していた。こうして生み出された人工知能は、当時エキスパートシステムと呼ばれるほど、専門家のような高いレベルで振る舞うことのできるプログラムであったが、膨大な情報を人手でインプットする必要があるため、その実用範囲は特定の領域に限定された。思っていたレベルには到達できないという落胆が原因となり、前回の人工知能ブームは終わりを迎えることとなった。この人手の作業を大幅に削減することを可能にしたのが、現在まで続く三回目のAI技術の急速な発展である。データを（基本的には）そのまま加工せずにコンピューターにインプットするだけで、人がさまざまな経験を通して獲得する情報をコンピューターが自ら特定していく技術である。ディープラーニングという手法の登場によって、これが可能となった。

ディープラーニングと呼ばれるこの技術は、2012年のILSVRCという画像認識の世界大会で優勝したチームが発表したことで知られている。2010年から始まったこの大会では、それまで統計的なモデルが高成績を取っていた。

しかし、2012年の大会を境に、ディープラーニングを用いたモデルがデファクトスタンダードになった。その後も大会が開催されるごとに、精度は塗り替えられていったが、2015年の優勝チームによって作成されたモデルが、初めて人間の精度を超えたとされたことから、メディアにも大きく取り上げられ急速に広まった。ディープラーニングを用いたモデルの複雑さを示す指標のひとつに、モデルを構成する層の数がある。2014年大会までは優勝チームが作成したモデルの層の数は20程度であったが、2015年大会の優勝チームが発表したモデルは最大152層で構築されていて、まさにディープラーニングや深層学習という名前に相応しいモデルの誕生であった。

その後の発展は目覚ましいものがある。第三次人工知能ブームにおけるベースとなった画像分類と呼ばれるタスクにおいては、モデルの精度が限界近くまで高まった印象もあるが、この技術はその後さまざまなタスクへの適用に広がっていった。そうしたタスクの中のいくつかを紹介する。

2. 画像分類

このタスクは、たとえば「犬」「猫」「馬」のいずれかに画像を分類するというものである。大量に用意した犬と猫、馬の画像を用いてモデルを学習させることで、その学習で用いた画像以外についても、「犬」「猫」「馬」のいずれかへの分類を正しく予測させるタスクである。学習と予測という二つのフェーズはどのタスクにおいても共通している手順となる。

ディープラーニング以前の方法では、人が画像を確認し、犬の特徴、猫の特徴、馬の特徴を見出す作業が必要であった。たとえば、犬と猫と馬において、目の縦横比はそれぞれ異なるといった特徴や、耳の形が異なるといった特徴、現れる模様が異なる、体の各部位の大きさの比率が異なる等である。そして、それらの特徴を画像から数値として抽出するアルゴリズムと、得られた各特徴の数値を用いて総合的に分類の判断を行うアルゴリズムを構築することになる。上で述べたように、人が特徴を見つけなければならないことと、それを抽出するアルゴリズム、総合的に分類を判断するアルゴリズムを構築しなければならないことは、精度の面においても、負担の面においても、実用化を阻む大きな要因のひとつに挙げられていた。

ディープラーニングにおいては、これらをコンピューターが担っている。「犬」「猫」「馬」の画像を予め作成したモデルにインプットすることで、高い

精度で分類できるようにモデルが自ら学習していく。どのような特徴であれば良いのか、その特徴からどのように判断すれば良いのかについて、少しずつ学習していく。コンピューターへのインプットの方法はさまざまであるが、簡単な例で言えば、「犬」という名前のフォルダに犬の画像を保存しておき、「猫」という名前のフォルダに猫の画像を保存しておき、「馬」という名前のフォルダに馬の画像を保存しておく方法がある。これはラベル付けと呼ばれる作業になる。モデルに学習させるための準備はこの程度の作業となるため、人工知能を生み出すための負担は大きく削減されることになった。

当然ではあるが、それら3つの画像を分類せずに混在させた状態でモデルにインプットしたとしても、それらの画像から自然と三つに分類するように学習したり、猫の中でもさらに細かい品種で分類するように学習したりしていくことはない。人間であれば大量の犬の画像を見ていれば、自然とそれらの中での違いに気づき、犬種について分類する知見を得たり、そもそも犬種という概念が存在することに気付いたりするものであるが、そのようなことは現時点のディープラーニングでは起こらない。ラベル付けという作業を通して、コンピューターに正解を与えなければ学習が進むことはない。しかし、正解を正しく与えていれば、その学習能力は非常に高く、それぞれの画像に写っているのが体の一部であったり顔だけであったり、それぞれの画像で背景が大きく異なっていたりしても、高い精度で分類するように学習していく。




図 2-1 1000 個のカテゴリに分類する AlexNet と呼ばれるモデルのアーキテクチャ (ImageNet classification with deep convolutional neural networks より引用)

3. オートエンコーダー

ディープラーニングが誕生するより前に手法として提唱されていた自己符号化器と呼ばれるこのタスクにも、ディープラーニングが利用されている。

オートエンコーダーでは、モデルを通してデータを圧縮し、その後復元する処理を行う。そして、元のデータが復元できるようにモデルを学習させる。データの圧縮によって、情報が欠落することになるため、元のデータを復元するためには、元のデータが持つ重要度の高い情報を選択して抽出できるように圧縮しておかなければならない。言い換えれば、元のデータを復元することができたモデルは、重要度の高い情報の抽出を行うことができているため、精度の高い次元削減、または特徴抽出を実現していることにもなる。

製造現場でオートエンコーダーが利用される際は、異常検知を目的とすることが多い。学習のフェーズでは、正常な製品の画像だけを用いて学習させ、正常な製品の画像が持つ重要度の高い情報を抽出することを目指す。予測のフェーズでは、実際に製造された製品の画像をモデルに入力する。正常な製品であれば、学習のフェーズで用いた画像と似ているため、入力した画像と同じ画像が出力されるが、欠点などが存在する異常な製品の画像であれば、学習のフェーズで用いた画像とは異なるため、うまく復元することができず、入力画像と出力画像に差が生じる。この差を数値化して閾値と比較することで、異常な製品が製造されたことを検知でき、またその差を画像の形で出力することで、異常のある箇所も特定することが可能になるというアプローチである。

不良品が数多く生じる場合は、上の画像分類によって正常と異常を振り分けることも可能であるが、不良品の発生頻度が少ない場合も実際には多く、そうした場合はモデルの学習に必要な異常画像を十分に用意することができず、画像分類タスクでは対応することが難しい。オートエンコーダーであれば、学習のフェーズで必要となる画像は正常画像だけで良いため、異常画像を用意することが難しい製造現場でも利用することが可能となる。

4. 物体検出

このタスクでは、画像のどこに何が映っているのかを明らかにすることが求められる。画像分類とは異なり、対象物の位置も明確にする必要がある。さらに、一枚の画像に含まれている複数の物体を対象にすることも画像分類とは異なる点である。

商業施設等の入口に設置されることも多くなったが、入場者の体温をディスプレイで表示するシステムなどでも使われている仕組みである。測定した

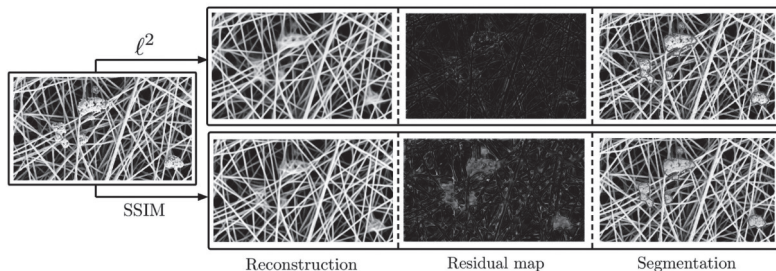


図 2-2 実際の製品の画像とオートエンコーダーに入力して得た画像との差から異常個所を表示するイメージ (Improving Unsupervised Defect Segmentation by Applying Structural Similarity To Autoencoders より引用)

体温とともに、人の顔を四角で囲んで表示させていることが多いが、これは物体検出によって推定された対象物の位置を示す枠で、バウンディングボックスと呼ばれている。映像から抽出した画像に対して、フレームごとに対象物を検知させている。このタスクにおいても、ディープラーニングが用いられている。

これまでの二つのタスクと異なる点として、学習させる基になる画像に対して、アノテーションと呼ばれる作業が必要になる。画像のどこに何が映っているのかを答えさせるため、正解データにおいても、画像のどこに何が映っているのかを示さなければならない。検出させたい物体を枠で囲んでいくこの作業を一般的にアノテーションと呼んでいる。この作業を簡単にするためのツールも数多く存在するため、これらを利用してアノテーションをしていくことになるが、画像が多くなると負荷の高い作業になる。アノテーションを専門に行う会社もあり、外部委託の検討も必要になる作業である。

このタスクは製造現場における異常の検知や部品の検出などに利用されることが多い。それ以外にも、徐々に実用段階へと入ってきている自動運転において利用されることも多い。自動車に搭載されたカメラで撮影し、その画像に映っている標識や障害物、歩行者をモデルによって認識させ、それに基づいて状況に対応した適切な操作を判断して自動車の運転を自動制御している。

5. セマンティックセグメンテーション

このタスクでは、物体検出と同様に、画像のどこに何が映っているのかを明らかにすることが求められる。物体検出と異なるのは、画像の全てのピク



図 2-3 様々な画像をもとに物体検出を行ったイメージ (You Only Look Once: Unified, Real-Time Object Detection より引用)

セルに対して、ピクセルごとに分類する点にある。バウンディングボックスなどで囲んで表示させるのではなく、ピクセルごとに色で分類を表示させるため、不規則な形状の対象物を表示させることに向いている。

学習させるための準備として、このタスクにおいてもアノテーションが必要になる。検出したい物体に色を塗るようにマスクする作業である。ピクセルごとに正解を示す作業であるため、枠で囲むアノテーションに比べると、アノテーションにはある程度の精度が求められる。学習に必要な画像枚数の準備において、やはり負荷の高い作業が必要となる。

製造現場における異常検知に、このタスクも幅広く使われている。特に外観に現れる傷やヒビ等の検出に利用されることが多い印象がある。

全てのタスクに共通している点ではあるが、物体検知やセマンティックセグメンテーションにおいても、高精度なモデルがいくつか提案されている。これらのモデルを利用することが実用レベルにおいては一般的である。したがって、モデルの基本的な構造自体を各製造現場で検討する必要性は低く、実用段階において求められるのは学習に適合したアノテーション画像を十分に用意することとなる。

6. 少ラベル学習

これまで述べてきた通り、どのタスクにおいても学習に用いる画像等を十分に用意することが最低限必要な作業となる。そして、アノテーション等の作業を含めて十分な画像枚数が用意できれば、実用可能なレベルの精度を発揮することが可能と言える。しかし、ディープラーニングに存在する課題は



図 2-4 様々な画像をもとにセマンティックセグメンテーションを行ったイメージ
(Encoder-Decoder with Atrous Separable Convolution for Semantic Image Segmentation より引用)

さまざまにある。そのひとつは、十分な画像枚数を用意できない場合の精度向上である。製造現場を対象に考えれば、良品と不良品について AI を用いて自動で分類したいものの、不良品の発生頻度が低いため、不良品画像を良品画像のように十分に用意することができないといった状況である。長く取り組まれてきた課題でもあるが、この課題解決に向けてさまざまな手法が近年提案されていて、その効果が期待されている。

6-1. 自己教師あり学習

少ラベル学習の有効な手段のひとつとして自己教師あり学習が挙げられる。上で述べたオートエンコーダーも自己教師あり学習のひとつである。この自己教師あり学習についての説明から始める。ここまで述べてきたタスクには、基本的に教師あり学習が用いられていて、上で述べた通り、ラベル付けやアノテーションを通して作成された教師信号である正解データを、画像データと合わせて学習のフェーズでモデルへ与えることになる。これを教師あり学習と呼ぶ。教師なし学習では、画像などのデータを学習のフェーズでモデルに入力するが、正解は与えない。主成分分析やアソシエーション分析、クラスターリングがこれにあたる。ここで述べる自己教師あり学習では、画像データとともに正解をモデルへ与えるはするものの、一般的な教師あり学習とは異なり、人手によるラベル付け等で正解を与えることはしない。様々な手法が提案されているが、比較的シンプルな手法のひとつとして、回転させた画像をモデルに入力するというものがある。その際の回転角はランダムにし、正解データとしてその回転角をモデルに与える。回転角を答えさせるこの学習

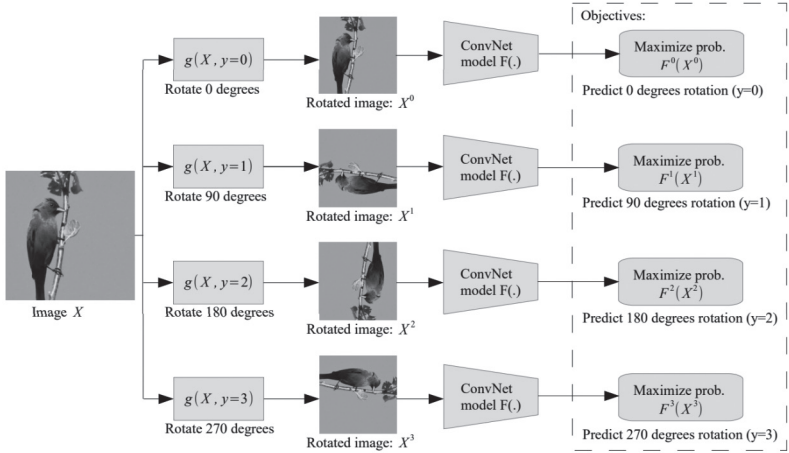


図 2-5 回転角を答えるように学習していくイメージ (Unsupervised Representation Learning By Predicting Image Rotations Segmentation より引用)

を重ね、画像の回転された角度をモデルが精度良く答えるようになれば、人が無意識に捉えている画像の特徴を、モデルも正確に捉えられるようになったと判断する手法である。モデルが自ら作った正解データ（回転角）で学習しているようにも考えられるため、自己教師あり学習と呼ばれている。良品のみをこの学習に用いることで、良品の回転角については正確に答えることができるが、学習に用いなかった不良品については正確に画像の特徴を捉えることができず、正確な回転角を答えられないことが予想される。予測のフェーズでモデルが答える回転角の不正確具合で、良品と不良品を分類することができるという考え方になる。

他の自己教師あり学習には、画像をいくつかのパッチに分けランダムに並べ替えたものをモデルに入力し、元の画像を正解として与える手法や、グレースケールに変換した上で色付け問題を解く手法などがある。いずれにしても、人手によるラベル付け等でモデルに正解を与えるのではなく、モデル自らが学習のフェーズで作る正解を答えられるように学習していく手法である。

6-2. 対照学習

対照学習も基本的なアプローチは同じである。対照学習における代表的な手法について、SimCLR、SwAV、BYOL、SimSiam の構造を下に示す。

どの構造においても、データを圧縮してそこから特徴データを抽出するエ

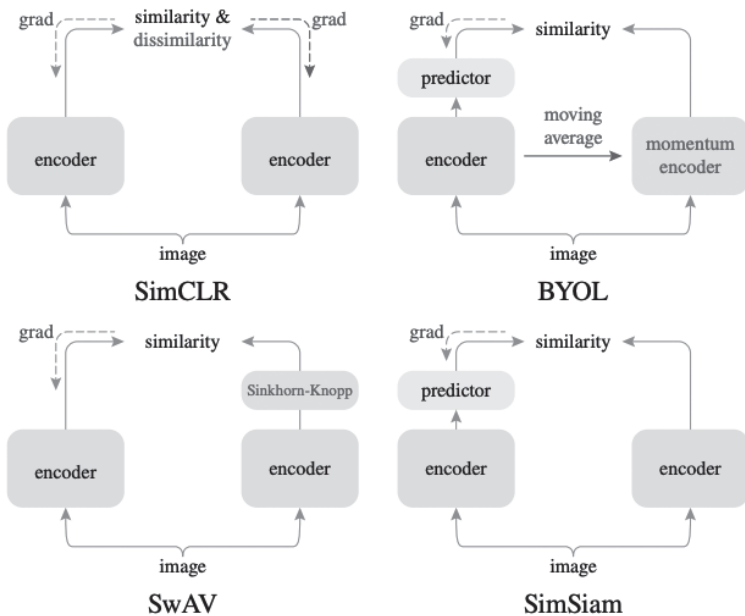


図 2-6 対照学習における代表的ないくつかの構造 (Exploring simple siamese representation learning より引用)

ンコーダーと、変換した画像の特徴データを抽出するエンコーダーの二つが共通的に用いられている。上で述べたオートエンコーダーで使われるエンコーダーと意味合いは同じである。オートエンコーダーでは、この後、デコーダーを用いて圧縮されたデータから元のデータを復元させている。対照学習におけるエンコーダーには、画像分類のタスクで一般的に使われることの多いモデルのひとつである ResNet がよく用いられる。元の画像から抽出した特徴データと変換した画像から抽出した特徴データの類似度を計算し、二つの特徴データが同じものとなるように、類似度を高めるようにモデルが学習していくことになる。エンコーダーによって抽出した二つの特徴データを単純に用いると、どのような画像データであっても同じ特徴データを出力するように学習してしまう崩壊と呼ばれる現象が生じてしまうため、この崩壊等が起きることなく適切に学習が進むよう様々工夫がなされた結果、上の図で示すようにいくつかの構造が提案されている。

こうしたモデルを学習させることで、画像の特徴をよく捉えられるモデル

を構築することができる。そして、この学習の後に画像分類等の目的のタスクに合わせて追加的に学習させることで、少ない画像枚数であっても精度の高いモデルを構築することが可能になると期待されている。

6-3. 半教師あり学習

上で述べた追加学習は第三次人工知能ブームの初期からその有効性が確認されている方法で、Fine-tuning や転移学習と呼ばれている。一般的には、大規模な画像データセットである ImageNet などでも学習したモデルの一部を用いて、各課題で用意した画像データを用いて追加学習する方法がよく見られる。ImageNet データセットには、学習用のデータとして 120 万枚を超える画像が含まれていて、1000 個のカテゴリーに分けられたラベルがそれぞれに付けられている。

半教師あり学習もこの追加学習を利用した手法である。学習方法の名前から分かる通り、ラベル付けされた画像とラベルなし画像の両方を用いて学習する方法を半教師あり学習と呼んでいる。ラベルがない画像については、擬ラベルを与える。ラベル A からラベル C の 3 つに分類するモデルは、 $[0.2, 0.7, 0.1]$ といったデータ構造で予測結果を出力する。この場合、0.7 が最大値となるため、モデルが予測する分類ラベルは B ということになる。仮に正解がラベル B であれば、 $[0.0, 1.0, 0.0]$ と出力するほど精度が高いモデルであると判断できる。これは one-hot 形式のラベルとも呼ばれている。半教師あり学習では、ラベルなし画像についての予測結果が one-hot 形式になるように（正解ラベルが分からない状態のまま）学習させる。また、各画像に対して、左




図 2-7 半教師あり学習の基本的アプローチ (Simplifying Semi-Supervised Learning with Consistency and Confidence より引用)

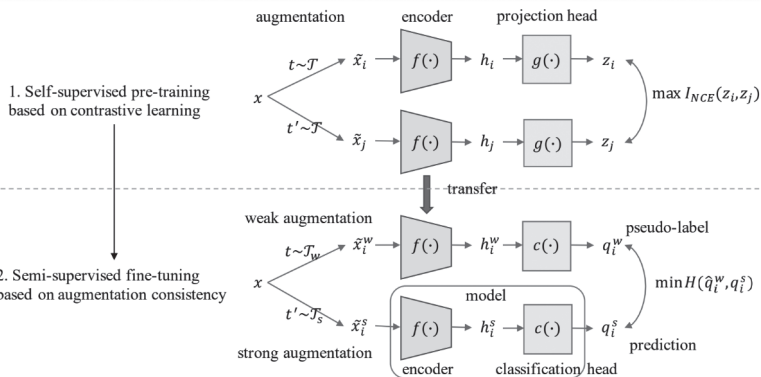


図 2-8 対照学習と半教師あり学習を組み合わせたアプローチ (SelfMatch: Combining Contrastive Self-Supervision and Consistency for Semi-Supervised Learning より引用)

右反転等の弱い変換を行った画像に対する予測結果と、コントラスト変換等の強い変換を行った画像に対する予測結果が同じ値になるように学習させる。この学習方法を、ラベルあり画像を用いた通常画像分類の学習と組み合わせることで、予測精度を向上させる手法が半教師あり学習である。

6-4. 類似問題での学習の流用

上で述べた半教師あり学習を類似問題に利用する手法も存在する。例えば、新製品の外観検査で良品と不良品に分類するモデルを利用することを考えた場合、特に量産化の前段階では様々な欠点が現れる不良品の画像データを十分に用意することは難しい。しかし、従来製品の外観検査において良品と不良品の画像データが十分にストックされていて、製品の外観における特性に大きな違いがなければ、従来製品における良品と不良品の分類が類似問題となる。まず、従来製品を対象にラベル付けのされた画像データを用いて画像分類のモデルを構築する。そして、追加学習としてラベルなし画像データを用いて半教師あり学習を行うアプローチになる。

他にも、ラベルなし画像データを用いて自己教師あり学習を行い、その後ラベル付けされた画像データを加えて半教師あり学習方法を行う提案もされている。

人工知能という名前が付く由来のひとつに、これらのディープラーニングで使われているそれぞれのモデルが、脳の神経回路の一部を模したニューラルネットワークという数理モデルを基本単位としていることが挙げられる。

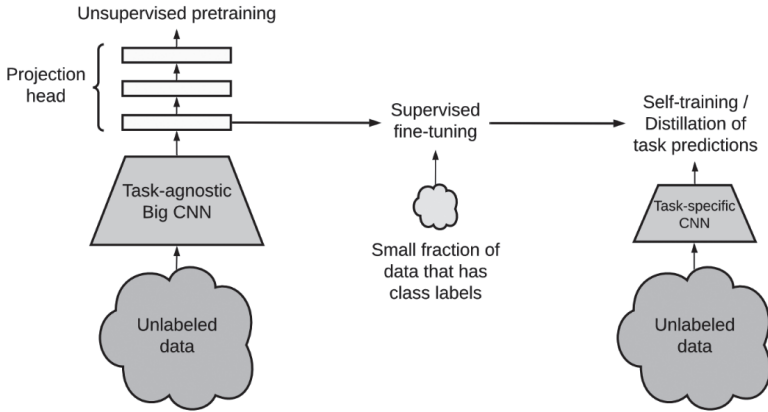


図 2-9 自己教師あり学習と半教師あり学習を組み合わせたアプローチ (Big Self-Supervised Models are Strong Semi-Supervised Learners より引用)

また、画像分類等の分野で時に人を超えるほどの非常に高い予測精度を發揮する技術のひとつに畳み込みニューラルネットワークがある。このネットワークも視覚野のニューロンの応答特性に類似していると言われている。こうした第三次人工知能ブーム初期の技術は、人工知能という名前の由来となるに相応しいものであったが、近年提案されている多くの手法は、人の学習過程等とは明らかに異なるプロセスを有することが特徴として挙げられる。

7. 自然言語処理とは

人が日常で話す言語を自然言語と呼ぶが、この自然言語をコンピューターが理解できるようにデジタルへ変換した上で、人の作業をコンピューターが代わりに行ったり、補助したりする技術全般を自然言語処理と呼んでいる。インターネットを介した様々なサービスが急速に発展してきた近年では、デジタル化されたテキストデータは膨大な量で蓄積されていることもあって、現在の環境は画像データと同じく AI に学習させるための最低条件を満たしている。画像分類等の発展と同じく、自然言語処理においても AI は様々な領域で大いに発展し、実際に身の回りでも幅広い分野で利用され始めている。以降はこの自然減処理分野における AI の発展について簡単に説明する。

7-1. 自然言語処理のタスク

自然言語処理のタスクは様々にある。代表的なものとしては、文章を品詞や活用形を加えた状態で単語に分ける形態素解析や、ある単語が文章の中に現れる確率を示す言語モデル、文章から地名や人名などの固有名詞を抽出する固有表現抽出、文章同士の類似度を表す類似度比較、与えられた条件のもと自動で文章を作成するタスク、文章を校正するタスク、文章をいくつかのカテゴリーに分類するタスクなどがある。本論文の第1章で取り扱ったタスクは、この文章分類にあたる。

7-2. 自然言語処理における近年のトピック

自然言語処理の分野における近年のトピックを一言で表せば、トランスフォーマーモデルを用いた基盤モデルの開発・利用となる。トランスフォーマーモデルは、Attention や自己注意機構と呼ばれる仕組みが用いられていて、エンコーダーとデコーダーから成る機械翻訳モデルである。

トランスフォーマーは様々な特徴を持っているが、Attention と呼ばれる自己注意機構があるために、モデルが持つ暗黙的なデータに対する仮定を表す帰納バイアスが弱いことが大きな特徴のひとつとされている。画像分類モデルであれば、近くのピクセル同士の関係性で何らかの特徴を表すことができる、という仮定のもとでモデルが組まれている。帰納バイアスとしては比較的強いと言える。こうした仮定が成り立つデータに対しては構築されたモデルは高い精度を発揮する。学習に用いるデータ数が比較的少なくても効果的なモデルを構築することもできる。一方、こうした仮定が成り立たなければ、どれだけデータ数を増やしても効果的なモデルとはならない。この状況をブレイクスルーしたモデルがトランスフォーマーである。トランスフォーマーは帰納バイアスが弱いため、これまで以上にあらゆるデータに対して、その特徴を正確に掴むことができると言われている。このトランスフォーマーは画像の分野にも利用され始めていて、Vision Transformer^[11] と呼ばれるモデルも登場した。これまでは ImageNet データセットが有する 120 万枚程度の画像データを利用していましたが、帰納バイアスが弱い Vision Transformer では、3 億データのデータセットを利用することで、これまでのモデルの精度を超えることも発表されている。

近年、この効果の高いトランスフォーマーを基盤モデルとして利用してい

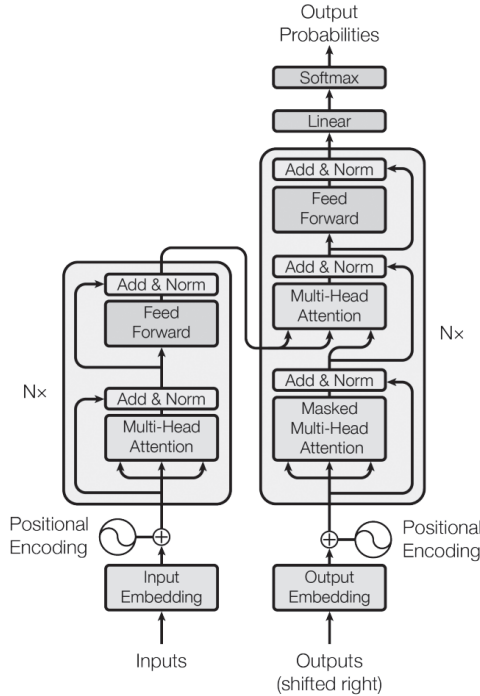


図 2-10 トランスフォーマーモデルの構造(左がエンコーダーで右がデコーダーになる。実際には灰色のブロックが 6 個重なる) (Attention is All you Need より引用)

る。基盤モデルとは、ラベルなしデータを利用して自己教師あり学習を実施し、さまざまなタスクに応じてカスタマイズすることができるモデルのことを表す。自然言語処理の分野で開発された基盤モデルのひとつが BERT^[12]である。

BERT は 2018 年に Google が発表した手法で、さまざまな言語タスクにおいてそれまでのモデルの性能を大きく上回る性能を示し、人間を超えたと言われるほどのブレークスルーを起こした。それまでは文章を単一方向からのみ処理するモデルであったが、Attention の仕組みを利用することで、離れた位置にある単語間の関係も適切に抽出することができる。文脈を考えたうえで単語の意味を適切に表現することを可能としている。

基盤モデルである BERT は大量の文章データを利用して、事前学習と呼ばれる自己教師あり学習を行い、その学習済みモデルをさまざまなタスクに合わせて追加学習させる。事前学習には大量の文章データが必要になるが、一

System	MNLI-(m/mm) 392k	QQP 363k	QNLI 108k	SST-2 67k	CoLA 8.5k	STS-B 5.7k	MRPC 3.5k	RTE 2.5k	Average
Pre-OpenAI SOTA	80.6/80.1	66.1	82.3	93.2	35.0	81.0	86.0	61.7	74.0
BiLSTM+ELMo+Attn	76.4/76.1	64.8	79.8	90.4	36.0	73.3	84.9	56.8	71.0
OpenAI GPT	82.1/81.4	70.3	87.4	91.3	45.4	80.0	82.3	56.0	75.1
BERT _{BASE}	84.6/83.4	71.2	90.5	93.5	52.1	85.8	88.9	66.4	79.6
BERT _{LARGE}	86.7/85.9	72.1	92.7	94.9	60.5	86.5	89.3	70.1	82.1

図 2-11 従来モデルを上回る各タスクにおける BERT の精度（この表は 8 つのタスクにおける精度を表している。それぞれは、MNLI：2 つの文が含意 / 矛盾 / 中立に分類する、QQP：2 つの質問文の意味が同一であるか分類する、QNLI：質問に対して、正しい回答が含まれている文であるかを判定する、SST-2：映画レビューの感情分析、CoLA：文が文法的に正しいかどうかを判定する、STS-B：2 つの文の類似度を 5 段階で判定する、MRPC：ニュースの 2 つの文の類似度を判定する、RTE：2 つの文の含意関係を判定する、というタスクになる）(BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding より引用)

度学習をしてしまえば、その学習済みモデルはさまざまなタスクに利用することができ、事前学習で用いるデータに比べてはるかに少量の文章データであっても高い精度を実現することができる。日本語の文章で事前学習された BERT はいくつか公開されていて、それらを利用することが一般的である。たとえば、東北大学の研究グループが公開しているモデルは、日本語の Wikipedia のすべての記事を利用して事前学習された BERT のモデルとなっている。

2018 年に発表された BERT は、2019 年には日本語圏を含めた検索エンジンで採用されたことが発表されている。そこでは「2019 brazil traveler to use need a visa」という文章で検索をかけた場合が例として説明された。従来はこの文章中の「to」の意味を正確に掴むことができず、ブラジルに旅行する米国人に関する記事が多く表示されていたが、BERT によって文章の構造を正しく理解し、文脈を読み取り、必要な記事を表示できるようになったと言われている。

検索エンジンに留まらず、こうした技術は自動翻訳やスマートスピーカー、対話型のチャットボット、かな文字変換予測など適用範囲は広く、実社会への応用段階へ進めて行くことが今後益々期待されている。

参考文献・参考資料

- Krizhevsky, A., Sutskever, I., & Hinton, G. (2012). ImageNet classification with deep convolutional neural networks. *Neural Information Processing Systems*, 25.
- Bergmann, P., Lowe, S., Fauser, M., Sattlegger, D., & Steger, C. (2018). Im-

- proving Unsupervised Defect Segmentation By Applying Structural Similarity To Autoencoders. arXiv preprint arxiv:1807.02011.
- Redmon, J., Divvala, S., Cirshick, R., & Farhadi, A. (2015). You Only Look Once: Unified, Real-Time Object Detection. 2016 IEEE Conference on Computer Vision and Pattern Recognition, 779-788.
- Chen, L., Zhu, Y., Papandreou, G., Schroff, F., & Adam, H. (2018) Encoder-Decoder with Atrous Separable Convolution for Semantic Image Segmentation. European Conference on Computer Vision, 833-851.
- Gidaris, S., Singh, P., & Komodakis, N. (2018). Unsupervised Representation Learning By Predicting Image Rotations. The International Conference on Learning Representations, arXiv preprint arXiv:1803.07728.
- Chen, X., & He, K. (2021). Exploring simple siamese representation learning. Conference on Computer Vision and Pattern Recognition, 15750-15758.
- Sohn, K., Berthelot, D., Li, C., Zhang, Z., Carlini, N., Cubuk, E., Kurakin, A., Zhang, H., & Raffel, C. (2020). Simplifying Semi-Supervised Learning with Consistency and Confidence. 34th Conference on Neural Information Processing Systems.
- Kim, B., Choo, J., Kwon, Y., Joe, S., Min, S., & Gwon, Y. (2021). SelfMatch: Combining Contrastive Self-Supervision and Consistency for Semi-Supervised Learning. Neural Information Processing Systems 2020 workshop.
- Chen, T., Kornblith, S., Swersky, K., Nerouzi, M., & Hinton, G. (2020). Big Self-Supervised Models are Strong Semi-Supervised Learners. 34th Conference on Neural Information Processing Systems.
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A., Kaiser, L., & Polosukhin, I. (2017). Attention is All you Need. Advances in Neural Information Processing Systems.
- Dosovitskiy, A., Beyer, L., Kolesnikov, A., Weissenborn, D., Zhai, X., Unterthiner, T., Dehghani, M., Minderer, M., Heigold, G., Gelly, S., Uszkoreit, J., & Houlsby, N. (2020). An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale. arXiv preprint arXiv:2010.11929.
- Devlin, J., Chang, M., Lee, K., & Toutanova, K. (2019). BERT: Pre-training of

Deep Bidirectional Transformers for Language Understanding. NAA-CL-HLT.