

厚生労働科学研究費補助金

政策科学総合研究事業
(臨床研究等 ICT 基盤構築・人工知能実装研究事業)

保健医療用人工知能の技術革新と国際競争力向上に資する
人材育成に関する研究

(H29-ICT-一般-009)

平成 29 年度 総括・分担研究報告書

研究代表者 奥村 貴史

平成 30 (2018) 年 3 月

目 次

I. 統括研究報告書

保健医療用人工知能の技術革新と国際競争力向上に資する人材育成	3
奥村 貴史 (国立保健医療科学院)	

II. 分担研究報告書

意思決定者の人材育成

医療機関における意思決定者に対する人工知能教育	11
亀田 義人 (千葉大学)	
医療用人工知能の政策関係者を対象とした人工知能教育	22
藤原 幸一 (京都大学)	
医療用人工知能の普及啓発に向けた課題分析	25
木村 眞司 (札幌医科大学)	

研究の多様性を高める人材育成

歯科における人工知能 ― 国内における研究動向と人材育成	31
安藤 雄一 (国立保健医療科学院)	
保健医療福祉行政における人工知能応用に関する研究 国保データベース事業における AI・BI・RPA 活用	37
神谷 達夫・岡本 悦司 (福知山公立大学)	
AI の医療分野への応用による効率化に関する文献調査	51
福田 敬 (国立保健医療科学院)	

研究の生産性を高める人材育成

医療用人工知能の研究開発基盤としての医師学術認証に関する研究	65
中村 素典 (国立情報学研究所)・奥村 貴史 (国立保健医療科学院)	
医療用人工知能の研究協力者育成.....	71
奥村 貴史 (国立保健医療科学院)	

III. 開発教材サンプル^(*)

「人工知能入門―人工知能の社会実装のために」	77
「AI 人材育成 教育カリキュラム案」	111
「医療用人工知能の作り方」	143
「医療用人工知能研究に求められるデータ生成・監査タスクを 海外委託する」	153

(※) 各教材は、今後の検討を通じて絶えず更新・改良するものとし、確定版ではない

I. 統括研究報告書

保健医療用人工知能の技術革新と国際競争力向上に資する 人材育成に関する研究

研究代表者 奥村 貴史

（国立保健医療科学院 研究情報支援研究センター 特命上席主任研究官）

研究要旨

我々は、2009年より国立研究機関として医療用AIの研究に取り組み、また、医療用AIの政策研究に関わってきた。その過程を通じて、本研究分野は、研究人材の欠如よりも、研究プロジェクトを支える人材の欠如により制約を受けることを繰り返し経験してきた。たとえば、医療用AI研究を進めるためには膨大な臨床データに正確な解釈を付与する研究協力者が必要となる。また、臨床研究は、協力する地域や施設において意思決定に関わる長の技術受容度により強く制約を受ける。

そこで本研究では、医療用AI研究を支える3種類の人材を対象にそれぞれ効率的な育成プログラムを策定することで、研究分野の発展に寄与することを目指した。まず、医療用AIの導入意志決定に関わる人材の育成に向けて、医療機関や政策当局の理解促進に資する教材の開発を目指した。また、応用分野を開拓していくため、医療の周辺領域の研究分野におけるAI活用について、参入促進に向けた現況調査を図った。最後に、データ生成や構築システムの評価に関わる、研究の生産性向上に資する人材育成の検討を目指した。上記の達成のため、我々は、研究統括を含む10名3グループの研究班を形成し、平成30年度からの本格的な活動に向けた準備を行った。

現在の我が国の医療用AI政策では、戦略的な研究開発投資が行われていない。医療用人工知能研究に際して、国内の各研究チームはそれぞれ個別に意思決定者への啓発を行うと共に、研究協力者の訓練を行わざるを得ず、非効率な競争を強いられている。研究助成の選択と集中は、研究の多様性を損ない、国際競争力を損なう逆説的な状況を生じている。本研究班は、研究分野の多様化と各研究チームの研究効率の改善を図ると共に、医療用AIに関する政策や臨床応用の医師決定者の啓発を目指している。研究班活動を通じて、今後、医療用人工知能技術に関する国際競争力の向上を図りたい。

研究分担者

安藤 雄一	国立保健医療科学院
福田 敬	国立保健医療科学院
市川 学	国立保健医療科学院
中村 素典	国立情報学研究所
神谷 達夫	福知山公立大学
岡本 悦司	福知山公立大学
木村 眞司	札幌医科大学
亀田 義人	千葉大学
藤原 幸一	京都大学

A. 研究目的

我々は、国立研究機関として医療用 AI の研究に 2009 年より取り組み、また、医療用 AI の政策研究に関わってきた。その過程を通じ、本分野は、研究人材の欠如よりも、研究プロジェクトを支える人材の欠如により制約を受けることを繰り返し経験してきた。たとえば、医療用 AI 研究を進めるためには膨大な臨床データに正確な解釈を付与する研究協力者が必要となる。また、臨床研究は、協力する地域や施設において意思決定に関わる長の技術受容度により強く制約を受ける。

そこで本研究では、医療用 AI 研究を支える 3 種類の人材を対象にそれぞれ効率的な育成プログラムを策定することで、研究分野の発展に寄与することを提案した。まず、医療用 AI の導入意思決定に関わる人材の理解促進に資する情報提供を目指した。次に、応用分野を開拓していくため、従来研究がカバーしていない領域の専門家に研究意義の啓発を図る。最後に、データ生成や構築システムの評価に関わる、研究の生産性に繋がる人材育成を志向した。

これらは従来施策の対象外であり、各研究チームが個別に情報提供などの努力を重

ねてきた。これらの分野に公的な支援を行い、自由に利用しうる教材を提供することにより、各研究チームの研究効率を大幅に増すことが期待される。今年度は、その研究初年度として、予備的調査と次年度の詳細な計画立案を目的とした。

B. 研究方法

研究の遂行に際しては、図 1 に示す構成の研究班を構成した。各研究分担の概要を以下に示す。

医療用 AI の研究開発や導入の意思決定に関与する人材育成

医療用 AI の研究開発に際しては、各医療機関の研究開発への参加や学会レベルでの大規模研究の実現等において、各組織の長や学会幹部の理解が不可欠である。しかしながら、これら意思決定に関与する人材を対象とした教材は存在せず、各プロジェクトの負担となっている。また、我が国では医療機器に対して厳しい品質管理が課されており、医療用 AI にも規制が適用される。しかし、我々の政策研究により、この状況が今後の研究開発競争において米国・中国と比して著しい制約となることが示唆されている。今後、医療用 AI 政策に関わる政府人材を対象とした人材育成が望まれる。

そこで、亀田分担(千葉大学医学部附属病院)は、医療機関における病院長、その候補や支援人材等、人工知能導入に際する意思決定者に向けた教育プログラムの開発を目指した。そのために、千葉大学医学部附属病院が、病院経営に関与する医療人材の養成を目的として展開中の「病院経営スペシャリスト養成プログラム」とのタイアップを図り、検討を進めた。藤原分担(京都大学大学院情報学研究科)では、政策決定に関わる関係者を対象とした、AI 技術についての

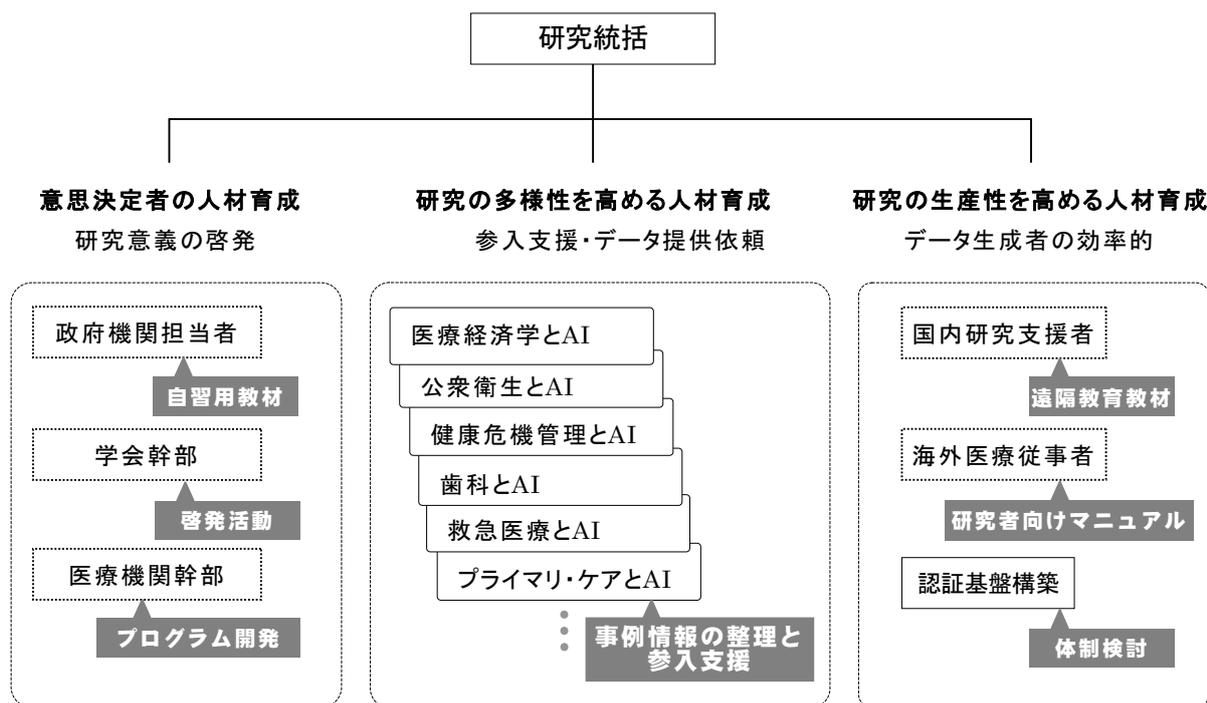


図 1 研究班全体体制

教材開発を目指した。そのために、関係者へのヒアリングを行い、カリキュラム案の策定を試みた。木村分担(札幌医科大学)では、医療用人工知能の普及に向け、医学における各分野の意思決定者を対象とした啓発活動のあり方を検討した。今年度は、インタビューを中心に、そのための課題分析に取り組んだ。

研究の多様性を高める人材育成

医療用 AI に関する研究の多くは既に類似研究の山となっている。国による研究助成もディープラーニングを利用した画像認識研究が多く、研究の多様性が損なわれつつある。とりわけ、画像認識処理には性能限界があるため、その後を見据えた研究の多様化が不可欠である。そこで、様々な医療用 AI に関する事例を検討し、研究の多様化に資する情報提供を検討した。

安藤分担(国立保健医療科学院)では、我

が国の歯科医療における AI 研究の動向について文献サーベイと情報収集を行った。また、その結果を踏まえ、歯科における人材育成の方向性について検討した。神谷・岡本分担(福知山公立大学)は、各種データの取り扱いに膨大な手作業を掛けている保健医療福祉行政において、データの収集・整理・分析に AI 技術を活用しえないか検討を行った。そのために、各地方自治体が進める国民健康保険に関するデータベース関連業務を取り上げ、人工知能を活用した効率化に向けたケーススタディを試みた。福田分担(国立保健医療科学院)では、人工知能による医療の効率化・有効化の評価に向けた検討をおこなった。そのために、今年度は、行政の議論や取組を整理すると共に、医療の効率化・有効化のために取り組まれている事例を整理した。市川分担(国立保健医療科学院)では、災害対応等の健康危機管理における AI の活用について検討を試みた。

研究の生産性を高める人材育成

医療用 AI の研究開発には、学習や評価に要するデータ生成に際して、医療従事者による膨大な単純作業が求められる。しかし、医療従事者等の研究協力者を対象として、「そもそも医療用 AI とは何か」、「なぜ単純作業が必要なのか」を伝達し、広報していく手段が限られている。また、その単純作業を訓練する手法も各チームの努力に負っている。研究協力者を対象として研究の意義を広報し、また、実際の作業を訓練する場を設けることで、医療用 AI の研究効率は大きく向上する。

そこで、奥村分担(国立保健医療科学院)では、医療用 AI 研究への協力者を対象として、研究支援の人材育成を目指した。また、発展途上国の医療従事者の組織化手法の教材化を図った。さらに、中村・奥村分担(国立情報学研究所)では、医療用 AI 研究の生産性を高めるうえでの鍵となる医療用 AI 研究開発基盤と認証システムの確立に向けた検討を行った。

C. 研究結果

研究計画における 3 つのサブテーマそれぞれについて、状況と成果を概説する。

「意思決定者の人材育成」に向けて、亀田分担では、医療機関幹部を対象とした教育において、医療用人工知能に関する教程を組み込むためのプログラム開発を進めた。藤原分担では、政策関係者を対象とした教材の作成を進めた。両者は教材の一部共有も含めて関係が深いもので、共同の分担会議も設定した。議論の結果、この分野の研究開発の発展には、Funding Agency 機能を持った橋渡し支援組織と橋渡し人材の育成が求められることが明らかとなった。木村分担においては、医療系学会指導者を対

象とした啓発活動に向けて、課題の整理に取り組んだ。

「研究の多様性を高める人材育成」においては、安藤分担(歯科と AI)、神谷・岡本分担(公衆衛生と AI)、福田分担(医療経済と AI)において、網羅的なサーベイを進めた。また、研究代表奥村は、「プライマリ・ケアと AI」というテーマでの啓発活動に携わった。市川分担(健康危機管理と AI)においては、健康危機管理への AI 応用の事例検討を進めた。以上のサーベイを通じて、AI のさまざまな医療応用を整理した。今後、集積した情報を活用した啓発活動に繋げたい。

「研究の生産性を高める人材育成」においては、研究代表奥村が、医療用 AI の研究開発に求められるデータ生成作業向けの教材開発を行った。また、海外医療従事者を活用した医療用 AI 研究の効率化について事例報告を整理した。さらに、中村・奥村分担において、医療用 AI 研究の生産性向上に向けて、医師学術認証基盤の実現に向けた検討を進めた。

D. 考察

人工知能分野における人材育成策としては、今まで、機械学習の基礎研究者や機械学習の医療応用に関する研究者が想定されてきた。しかし、この分野の研究人材は、既存の教育機関が積極的に育成しており、文部科学省による「数理及びデータサイエンスに係る教育強化」施策による支援策も既に講じられている。また、既にいくつものオンライン教材が公開されており、自習環境も充実している。研究方法論の教育には絶え間ない更新が求められることから、継続性のない研究班が教材作成を行ったとしても、その後の発展は困難なものと考えられる。

そもそも人材育成には時間が掛かる。そして、我が国では、育成しているうちに社

会情勢が変わりニーズがなくなるような人材育成政策を繰り返してきた。1990年代の大学院重点化は、多量の余剰博士問題を引き起こした。法曹需要の増大を根拠に2004年に創設された法科大学院の志願者数は、現在、ピーク時の1割近くにまで落ち込み、多くの大学院で募集停止が続いている。「21世紀はバイオの時代」と要請され定員が増員されたバイオ系大学院卒者は、人材の過剰とポジションの縮小による過酷な就職状況に喘いでいる。

こうした状況が生じる背景として、そもそも将来の正確な予想は困難だという点が挙げられる。とりわけ、技術革新は非連続的に生じるため、政府が定めるロードマップにしたがって進まない。現在、爆発的に普及したスマートフォンに用いられている技術のうち、政府の研究開発ロードマップに基づいて生まれた成果はほとんどないであろう。技術革新の種がどこにあるかを自薦に予測することは容易でないとすると、政府が定めたロードマップへと合致する一部のチームに過度の選択と集中を図ることは、逆に技術革新を損なうことになる。

以上の立場に立てば、医療用AI政策において、政府は、限られた政策資源を多様なプレーヤによるさまざまな取り組みが実現する自由度の向上に振り向けることが望ましい。研究の多様性を高めるためには、研究分野への参入障壁を低くすると共に、研究開発のコストを下げる施策が求められる。また、市場に任せると「金銭的にペイしない有意義なAI応用」への過少投資が生じる。この問題に対処するためには、医学や医療が抱えるさまざまな問題の中から市場が解決しえないAI応用課題を拾い上げ、インセンティブを設ける仕組みを実現する必要がある。今後、限られた政策資源を効果的に活用していくために、政策決定者を対象とした教材の開発と啓発活動が望まれる。

E. 結論

本研究では、医療用人工知能分野において技術革新と国際競争力向上に資するため、意思決定者の人材育成、研究の多様性を高める人材育成、研究の生産性を高める人材育成に取り組んだ。こうした試みは既存の施策を補う試みと考えられる。初年度である今年度は、年度後半からの研究班設置という背景もあり、まずは研究体制の確立を目指した。

現在の我が国の医療用AI政策では、戦略的な研究開発投資が行われていないことに加えて、薬機法の規制により分野の発展に制約がある。いわば中途半端なアクセルとブレーキが同時に踏まれている状態であり、今後、米国・中国に大きく後れを取る懸念が強い。本研究により研究の多様化と効率化がもたらされることにより、医療用人工知能技術に関する国際競争力の向上を図りたい。

F. 研究発表

1. 論文発表

- 1) Y. Yaguchi, M. Omura, and T. Okumura, "Geometrical mapping of diseases with calculated similarity measure", 2017 IEEE International Conference on Bioinformatics and Biomedicine (BIBM 2017), Nov 2017, pp. 1131-1134.
- 2) H. Tanaka, K. Ueda, S. Watanuki, T. Watari, Y. Tokuda, T. Okumura, "Disease Vocabulary Size as a Surrogate Marker for Physicians' Disease Knowledge Volume", PLOS ONE (submitted).

2. 学会発表

- 1) 奥村貴史, "プライマリ・ケアと人工知能", プライマリ・ケア, 日本プライマリ・ケア連合学会, 2018年3月.

II. 分担研究報告書

医療機関における意思決定者に対する人工知能教育

研究分担者 亀田 義人

（千葉大学医学部附属病院 病院長企画室 特任助教）

研究要旨

本分担研究では医療機関における病院長、その候補や支援人材等、人工知能導入に際する意思決定者に向けた教育プログラムを開発する。今年度においては、種々の関係者からのヒアリングや教育講座の情報収集と再編成を行い、病院執行部向けの教育プログラムの作成を試みた。

その結果、病院管理者や執行部としてAIを活用していく上で重要なポイントとして、以下の項目を抽出した。すなわち、(1) 人工知能とは何か、(2) 人工知能を活用する意義、(3) 人工知能の歴史とトレンド、(4) ディープラーニングの理論的な背景、(5) 医療における人工知能の活用領域、(6) 人工知能の限界と適切な活用、(7) 人工知能を活用した製品の調達について、の7項目となる。

来年度においては、必要な知識や能力を整理することでコンピテンシーの設定を図る。また、病院執行部が広く受講できる様な環境整備及び、試験的講座の実施と受講者からのフィードバックによる教材の質の向上に取り組むたい。

A. 研究目的

本研究班では、医療用人工知能(AI)分野において、技術革新と国際競争力向上に資する人材育成プログラムを開発することを目的としているが、本分担研究では医療機関における病院長、その候補や支援人材等、人工知能導入に際する意思決定者に向けた教育プログラムを開発することを目的とし、もって、AIを搭載した技術への理解と医療機関への研究開発協力への理解と社会実装を推進することを目的とする。

B. 研究方法

今年度、プログラムの開発に際して、以下の3点に取り組んだ。

① AI教育プログラムの現状・情報把握

まず、AI教育の現状やAIに関する情報の把握を目指した。そのために、各民間および国公立やそれに準ずる機関が提供から提供されているオンサイト/オンラインAI教育講座について実際に参加し、必要なりテラシーの取得と抽象化・概念化を行った。また、参加を通じて、AI系情報技術者との関係構築を図った。

② AI研究者・企業のAIシステム開発者へのヒアリング

AIのプログラミング教育提供者、AI研究者や企業のAIシステム開発者へヒアリングを行い、必要なりテラシーやAIを活用するためのコンピテンシー、および、それらの評価方法の開発を試みた。

③ プログラム開発の管理体制の構築

プログラムの開発に際しては、千葉大学医学部附属病院が展開中の「病院経営スペシャリスト養成プログラム」の協力を得た。「病院経営スペシャリスト養成プログラム」は、持続的な病院経営システムを構築できる実践的な医療人材を養成することを目的とした病院経営に関する研修である。これは、平成19年の学校教育法の改正以降実現した大学としての正式な履修証明書を発行する研修となっている。そのために、プログラムの進捗管理及び報告・改善の場として、内外の委員からなるプログラム運営委員会を有している。本研究分担における教育プログラムの開発に際しては、収集した情報をもとに教育プログラムを作成し、その概要を公私立の病院長を外部委員として擁するプログラム運営委員会に諮り、意見を反映する形式にて進めた。

C. 研究結果

東京大学大学院情報工学系研究科が主催する「実データで学ぶ人工知能講座」、公益財団法人医療・病院管理研究協会が主催する「病院管理研修 医療における人工知能とビッグデータの活用と影響」、株式会社ARKが主催する「AIエバンジェリスト養成講座」、株式会社キカガクが主催する「人口知能脱ブラックボックスセミナー」、「ディープラーニングハンズオンセミナー」及び株式会社メドピア主催の「Health 2.0 Asia-Japan 2017」にて、人工知能周辺の知見を収集した。また、人工知能学会理事の千葉大学荒井幸代教授よりヒアリングを行い、病院管理者として人工知能とどのように向き合うべきか等についてまとめた。

病院管理者や執行部としてAIを活用していく上で重要なポイントとして、以下の7点を作業仮説として提示した。

- (1) 人工知能とは何か
- (2) 人工知能を活用する意義
- (3) 人工知能の歴史とトレンド
- (4) ディープラーニングの理論的背景
- (5) 医療における人工知能の活用領域
- (6) 人工知能の限界と適切な活用
- (7) 人工知能を活用した製品の調達

文末に、各トピックの要旨を整理する。

D. 考察

人工知能の社会実装に向けて、病院経営陣が備えるべき知識について整理したが、そもそも各個人の基礎知識にばらつきがある中で、どのような項目を学習するべきか、コンテンツベースの教材作成には限界があると考えられる。医学教育や他分野の教育と同様、コンピテンシーを設定して、その習得に向けて各個人が主体的な学び(Active learning)を行う Outcome based Educationが必要であると考えられる。

E. 結論

今年度においては、種々の関係者からのヒアリング、教育講座の情報収集と再編成を行い、病院執行部向けの教育内容の概要案を作成した。来年度においては、これを更に成熟させ、必要な能力を抽象化しコンピテンシーの設定を図る。また、病院執行部が広く受講できる様な環境整備及び、試験的講座の実施と受講者からのフィードバックによる教材の質の向上に取り組みたい。

F. 研究発表

なし

補遺－医療機関トップを対象とした AI 教育教材要旨

(1) 人口知能とは何か

人工知能の定義の前に、知能に関する統一的な定義を考える必要がある。知能とは、一般的には知的な活動の能力であり、知的な活動には問題解決・推論・学習などの情報処理能力や抽象化、一般化などが一面として挙げられる。

一方、人工知能は、一般に「何らかの知的動作が可能な計算機システム」と言われるが、この「知的動作」にも定義が無い。また、人工知能では知能をシミュレートすることになるが、知能のシミュレーションが知能といえるかという疑問もある。表 1 に示されるとおり、本邦の主要な人工知能研究者においても、人工知能の定義は様々であり、統一的な定義はなされていない。

人工知能の分類の一つに、強い AI、弱い AI という分類があり、前者は汎用型人工知能と呼ばれる。いわゆる人間のような振る舞いをする知的コンピューターであり、設計した時の想定を超えた新たな問題にも対処する。後者は特化型人工知能と呼ばれ、人間が設定した特定の問題(画像の識別等)に対して、主に機械学習を用いて解決する。強い AI の実現は未だ課題が多く、通常活用されるのは後者である。

人工知能の持つ機能は人体の構造・機能になぞらえて、目、耳、言語に例えられる。すなわち、画像認識、音声認識、自然言語処理である。これらの情報を数値化し、機械学習を通じて規則性を見つけ出し、推計あるいは分類した結果として出力するというのが基本的な挙動となっている。

人工知能と機械学習及び、近年注目されるディープラーニングの関係性として、「人工知能⇒機械学習⇒ディープラーニン

中島秀之	公立ほこだて未来大学	人工的につくられた、知能を持つ実態。あるいはそれをつくろうとすることによって知能自体を研究する分野である
武田英明	国立情報学研究所	
西田豊明	京都大学	「知能を持つメカ」ないしは「心を持つメカ」である
溝口理一郎	北陸先端科学技術大学院	人工的につくった知的な振る舞いをするためのもの(システム)である
長尾真	京都大学	人間の頭脳活動を極限までシミュレートするシステムである
堀浩一	東京大学	人工的に作る新しい知能の世界である
浅田稔	大阪大学	知能の定義が明確でないので、人工知能を明確に定義できない
松原仁	公立ほこだて未来大学	究極には人間と区別が付かない人工的な知能のこと
池上高志	東京大学	自然にわれわれがペットや人に接触するような、情動と冗談に満ちた相互作用を、物理法則に関係なく、あるいは逆らって、人工的に作り出せるシステム
山口高平	慶應義塾大学	人の知的な振る舞いを模倣・支援・超越するための構成的システム
栗原聡	電気通信大学	人工的につくられる知能であるが、その知能のレベルは人を超えているものを想像している
山川宏	ドワンゴ人工知能研究所	計算機知能のうちで、人間が直接・間接に設計する場合を人工知能と呼んで良いのではないかと思う
松尾豊	東京大学	人工的につくられた人間のような知能、ないしはそれをつくる技術。人間のように知的であるとは、「気づくことのできる」コンピュータ、つまり、データの中から特徴量を生成し現象をモデル化することのできるコンピュータという意味である

表 1 国内の主な研究者による人工知能の定義
(総務省 平成 28 年度情報通信白書より)

グ」という関係がある。ディープラーニングは機械学習の一手法であり、機械学習は人工知能を構成する一要素であると表現できる。弱い人工知能による問題解決の手法は、現在、二つのアプローチが主流となっている。一つは、回帰問題の解決(結果の推計・推定)であり、もう一つは分類問題の解決(分類)である。

このようなアプローチで人工知能に問題解決をさせる上では、大量の利用可能なデータ、高い計算機能力、機械学習アルゴリズム、3つの要素が重要となる。近年の人工知能ブームには、これらの3要素がそろったことになったことで、研究がなされてきた技術が現実的な問題に適用できるようになった背景がある。

(2) 人工知能を活用する意義

人工知能が注目を集めるようになった社会的な背景には、技術的側面のみならず、人口構造の変化及び産業構造の変化がある。

日本においては、1960年頃から1990年代半ばまで人口の生産年齢割合が高く、人口構造が経済にプラスになる時期があった。これは人口ボーナスと呼ばれ、安い労働力を背景に世界中の仕事を受注する一方で、高齢者割合が低く社会保障にかかる費用が比較的少ない時代であることを活かし、インフラ投資を進めることができた。経済発展に関しては、高度成長期となる時代である。

高度成長期が訪れると富裕層が子供に教育投資し、高学歴化による人件費の上昇と晩婚化・晩産化が進み少子化の傾向が生じる。医療や年金制度が充実するため平均寿命も延び、やがて高齢化社会へと移行する。

人口ボーナス期が終えんを迎え、次に来るのが人口オーナス期である。オーナスとは「重荷・負担」という意味で、人口構造が経済の重荷になる時期である。ボーナス

期に比べ働く人よりも支えられる人が多くなる状況であり、ボーナス期のような人を大量に投入して行うような経済発展の仕方は通用しなくなる。人口オーナス期に生じる典型的な問題は、労働人口が減少すること及び、働く世代が引退世代を支える社会保障制度の維持が困難となることである。高齢化は世界的な課題であるが、日本は特に主要国で最も早く少子高齢化が進行している。ことさら医療に関しては、限られた財源の中著しく増加する高齢者に対してサービスを提供していくことが求められており、生産性の向上が不可欠である。人工知能による産業構造の変化は、ドイツが人工知能含めてIoT(Internet of Things)の社会実装をIndustry 4.0(第4次産業革命)と銘打っており、人工知能の活用による生産性の向上が期待されている。米国では「米国人工知能研究開発戦略」を策定して、各分野の人工知能の実装に関するロードマップを策定しており、中国では新一代人工智能発展計画を立案し、自動運転、都市計画、医療映像、音声認識の4分野に特に力を入れ、百度、アリババグループ、テンセント、科大訊飛(iFLYTEK)の4社を指定して2030年までに世界トップ水準へ向上させ中国を世界の主要な「AIイノベーションセンター」にする事を目指している。このように各国が人工知能の活用を国家戦略に位置づけており、日本でも日本世界最先端IT国家創造宣言・官民データ活用推進基本計画(平成29年5月30日閣議決定)が策定されるなど、国家として取り組んで行くべき事項である事がわかる。

(3) 人工知能の歴史とトレンド

人工知能研究は1950年代から続いているが、現在までに3回のブームが生じてきたとされる。

第1次ブームでは、コンピューターによる「推論」や「探索」が可能となり、特定の問題に対する解決ができるようになった。しかし、複雑な問題の解決が困難な事が明らかとなり、ブームの終焉を迎えた。この頃の技術ですでにパーセプトロンや人工対話システム **ELIZA** などが作られている。

第2次人工知能ブームは、1980年代に生じた。推論に必要な知識を人手を用いて表現し、コンピューターに与えることで、実用的な「エキスパートシステム」(専門分野の知識を取り込んだ上で推論することで、その分野の専門家のように振る舞うプログラム)が実現した。また、エキスパートシステムの他に、入力された知識から確定的な手順の記述なしに結果を推定する「ファジィ」や「ニューロ」コンピューティングが開発された。しかし、コンピューターが十分な情報処理能力を持たない時代であったために、「ファジィ搭載」を謳った商品が市販される程度に留まり、ブームはやがて終焉を迎えた。

第3次人工知能ブームは、2000年代から現在まで続いている。発達したコンピューターの計算能力を活用し、また、大量に集積するようになったビッグデータを用いて、「ディープラーニング」(2006年)などの機械学習アルゴリズムによって様々な実用的課題が解決できるようになったことが背景にある。

こうした技術の多くやプラットフォームは、無料で公開されることが多い一方で、対象となるデータの量と質が課題解決に重要視されている。また、実際の商品・サービスとして社会に浸透するためには、実用化のための開発や社会環境の整備、課題を持つ業界と人工知能技術者間でのすりあわせなどの取組を進めていく必要がある。

(4) ディープラーニングの理論的背景

人工知能を活用する上での得意不得意を知るに当たって、その前提となる理論的背景を知ることは重要である。特に実応用が進んでいるディープラーニングの理論的背景の概要を説明する。

機械学習を利活用する場合、大きく二つの手法が存在する。一つは線形代数を基礎としたもので、もう一つは確率統計学を基礎としたものである。前者には個々で扱うディープラーニングやサポートベクターマシーン(SVM)と呼ばれるパターン認識手法などが含まれ、後者にはマルコフ連鎖モンテカルロ法(MCMC)や隠れマルコフモデル(HMM)などといったものが含まれる。

機械学習を活用して問題解決を図る場合、大まかな流れは以下の通りとなる。

1) 解決したい問題に対して計算モデルを決める

ディープラーニングは、計算モデルとしてはディープニューラルネットワーク(DNN)と呼ばれ、入力層、中間層(隠れ層)、出力層からなる(図1)。中間層を何層置くか、隠れ層のノードをいくつ置くかについてもヒトが設定する必要がある。パラメーター W の値ははじめランダムに設定する。DNNでは、入力 x についてパラメーターが掛けられた結果の値 U に対して、そのまま結果を用いるのでは無く、非線形データにも対応できるように非線形変換が行われる。非線形変換に用いられる関数を活性化関数と呼び、従来はシグモイド関数というものが使われていたが、現在、ReLU 関数というのが一番精度高く結果を出せるといわれており、これを用いる場合が多い。

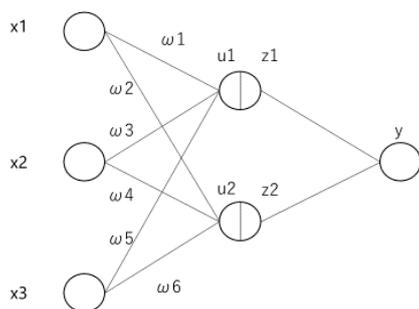


図 1 ニューラルネットワークの例

2) 評価関数(損失関数)を決める

DNN において、評価関数では、回帰問題では通常平均二乗誤差、分類問題ではソフトマックス関数という関数を用い、クロスエントロピー誤差という値を求める。設定したパラメーターを元に評価関数の値を求める事を順伝播という(図 2)。

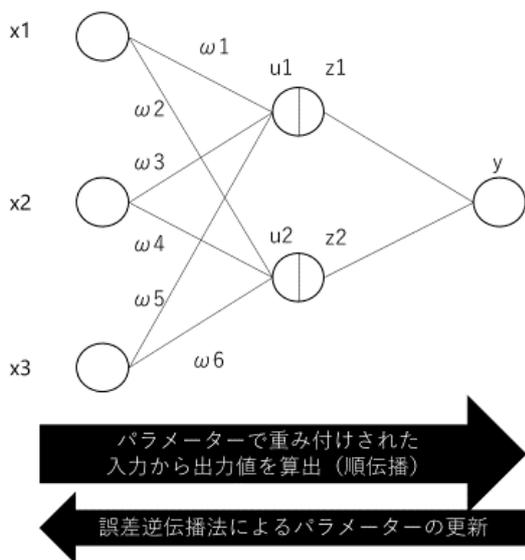


図 2 順伝播と誤差逆伝播

3) 評価関数を最大化もしくは最小化する

評価関数を最小化するために、評価関数をパラメーター W からなる式に整理して、その式を W で偏微分し、その値を元のパラメーター W から引く事により更新する計

算を繰り返す(最急降下法)これを誤差逆伝播法という。

(5) 医療における人工知能の活用領域

医療においても様々な領域で人工知能の活用が期待されている。一つの分類方法として、総務省「ICT の進化が雇用と働き方に及ぼす影響に関する調査研究」では、識別(音声認識、画像認識、動画認識、言語解析)、予測(数値予測、マッチング、意図予測、ニーズ予測)、実効(表現生成、デザイン、行動最適化、作業の自動化)に分類している。これらを医療に照らし合わせることで、AI を活用してどのような事が実現可能か考える手がかりになるかもしれない。

医療における人工知能の活用も多岐荷渡また現在進行形で増え続けているため、枚挙にいとまが無いが、個々では 3 つほど例を挙げる。

1) 医療画像処理

画像処理はディープラーニングが最も特異とする分野の一つである。現在の第 3 次 AI ブームは、Stanford 大学の Fei-Fei Li が教師付画像データ : ImageNet を創設した事から注目を浴び、画像認識で始まった経緯がある。人工知能を画像解析に活用する場合、畳み込みニューラルネットワーク(CNN: Convolutional Neural Network)というモデルを用いることが多い。

画像認識タスクでは、画像データとそのラベルを大量に学習させることによって、未知の画像に対してそれが何であるかのラベルを出すという枠組みで動作する。この技術を活用して、既に放射線領域では脳動脈瘤の高精度な検出に応用されており、そのほかの頭蓋内病変の診断への応用や、胸部 X 線写真から骨の特徴量を削除することにより鎖骨や肋骨が無い画像を提供し、肺

の病変を見やすくする、などの技術が開発されている。東京大学初ベンチャーの□ピクセルは富士フィルムと共同し、人工知能による診断支援を富士フィルムの医療用画像情報システムに搭載していくことを目指している。東芝デジタルソリューションズは千葉大学と共同し、胃がんのリンパ節生検検体に対し、人工知能を用いた術中迅速病理診断の研究を行っている。

十分な量の教師付データがあれば様々な分野に応用が可能であり、病理診断の自動化、内視鏡所見をリアルタイムに解析して、腫瘍らしき所見にアラートを発するシステムや、悪性黒色腫等の皮膚疾患の検出など様々な画像診断技術に人工知能の活用が取り組まれている。

2) がんの Precision Medicine

ゲノム医療において、患者個々人のゲノム情報から、より効果的で安全な治療法を選択する Precision Medicine が行われ始めている。既報の文献や既存の遺伝子・病態・治療に関するデータベースの情報をキュレーションする事により、個々人に最適化された診療について提案する。国立がんセンターは産総研や国内発人工知能ベンチャー企業である Preferred Networks と共同で Precision Medicine に取り組んでいる。

3) その他自然言語処理等の活用

患者の問診内容や身体所見をインプットとして、診断補助に活用する手法や、診療文書の作成補助などの活用方法が考えられる。文脈として理解する必要がある場合は、前後関係を踏まえた分析が可能なモデルが必要であり、主に Recurrent Neural Network が用いられる。

総務省次世代人工知能社会実装ワーキンググループの自然言語処理の医療応用の報告によれば、学会が行ってきた症例データ

ベースの蓄積を活用して、診断支援に取り組むことや、ツイッターのつぶやき内容を自然言語処理で解析し、感染症発生を推定するツールの開発、語彙から将来の認知症の発生を予測する技術など、様々な分野で実用化が図られている。

上記以外にも、人工知能の推計・分類機能が活用できる領域は様々にあると考えられる。人工知能の特徴を理解し、医療現場のどのような課題解決に、どのように人工知能を活用するか考えていく事が社会実装には重要である。

(6) 人工知能の限界と適切な活用

チューリングテスト

チューリングテストという、機械に応答させて人間が応答しているか機械が応答しているか、判断するテストがある。しかし未だ十分に人間らしい反応であるという成果を挙げてはいない。

不完全性定理

「自己言及のパラドックス」いわゆる「クレタ人は嘘つきだとクレタ人は言った」を、ゲーゲルが数学的に証明したもの。完全な人工知能はその完全性を証明できないという矛盾が生じる。外部から条件・定義を設定する必要が生じる。

中国語の部屋

中国語を知っているヒトがコンピューターに対して中国語を入力、別の部屋で中国語を知らないヒトが中国語を記号として認識して、ある記号に対してはこの記号、というように返答すると、見かけ上中国語を理解しているヒトが対応している様に見える。単に記号を操作するだけで知能をシミュレートしており、知能はヒトにも機械にもでっち上げられるというもの。

フレーム問題

現在、人工知能は思考すべき範囲や詳細度の決定を人工知能自身でできない。ある目的を達成使用とする場合、関係ある事項のほか、関係無い事項は無限に存在するため、それを洗い出そうとすると無限に時間を要し停止してしまう。

現在のところ、人工知能に対しヒトが「適切」な範囲を定める必要があり、「範囲を定める問題」の一般的な解決は困難である。

記号接地問題

記号を実世界の意味と結びつけられるかという問題。コンピューターは記号の意味を理解していないので、記号の操作だけで知能を実現できない。例えば、シマ+ウマ=シマウマという様な概念を一般化して獲得する事はできない。

トロツコ問題

トロツコが線路の上を走行しており、岐路が設けられている。線路の先には修理作業中の5名の作業員がおり、そのまま走ると5名が轢かれる。別の岐路の先には1人が作業している。A氏はたまたまトロツコの進行方向を変えるレバーの近くにいる。A氏がとるべき「正しい」行動とはどのようなものか。という問題。人工知能に「正しい」判断をさせる場合、何を持って「正しい」とするか。人工知能にどのような価値判断を与えるべきか、どのようにコンセンサスを得るのか、コンセンサスは得られるのか。

瑕疵があった場合の責任の所在

人工知能を搭載した製品を使用して起きた問題の中で、人工知能の判断が誤っていたために起きた問題の責任は、製品製造者

にあるか、製品使用者にあるか。人工知能が出した解答に従って起きた問題の所在は、どのような場合にどこに置くべきか。

Asilomar AI Principles (2017)

2017年1月、カリフォルニア州アシロマにて行われた、全世界のAIの研究者と経済学、法律、倫理、哲学の専門家が集まり議論された人類にとって有益なAIに関する原則。研究に関する5項目、倫理と価値観に関する13項目、長期的な問題に関する5項目計23項目が挙げられた。

AI ネットワーク社会推進会議報告書 2017

総務省情報通信政策研究所が、平成28年10月から「AI ネットワーク社会推進会議」を開催し、AI ネットワーク化をめぐる社会的・経済的・倫理的・法的な課題について検討を進めている。平成29年7月に報告書が発出され、その中で、国際的な議論のためのAI 開発ガイドライン案が提案された(図3)。

(7) 人工知能を活用した製品の調達

人工知能の用いた製品を開発・実装する場合、図4のような手順が必要になると考えられる。前述の通り、現状人工知能を活用する場合、問題の設定を解決モデルの設定はヒトが行わなければならない。適切なシステム開発のためには、現場の問題意識と、人工知能開発研究者と、ユーザーインターフェース開発ベンダーとの間で、密なコミュニケーションが必要となる。それを理解した上で、対応適任者を専任する必要が出てくる。また、精度向上のためには、利用環境で生まれるデータを学習させ続ける仕組み作りも重要である。

第2章 国際的な議論のためのAI開発ガイドライン案①

目的	基本理念	用語の定義及び対象範囲
<ul style="list-style-type: none"> AIネットワーク化（AIシステムがインターネット等と接続され、AIシステム相互間又はAIシステムと他の種類のシステムとの間のネットワークが形成されるようになること）の進展により、人間及びその社会や経済に多大な便益がもたらされる一方、不透明化等のリスクに対する懸念も存在 オープンな議論を通じ、国際的なコンセンサスを醸成し、非規制的で非拘束的なソフトローたるガイドラインやそのベストプラクティスをステークホルダ間で国際的に共有することが必要 AIネットワーク化の健全な進展を通じたAIシステムの便益の増進とリスクの抑制により、利用者の利益を保護するとともにリスクの波及を抑制し、人間中心の智連社会を実現 	<ul style="list-style-type: none"> 人間がAIネットワークと共生することにより、その恵沢がすべての人によってあまねく享受され、人間の尊厳と個人の自律が尊重される人間中心の社会を実現 非拘束的なソフトローたる指針やそのベストプラクティスをステークホルダ間で国際的に共有 イノベティブでオープンな研究開発と公正な競争、学問の自由や表現の自由といった民主主義社会の価値を尊重するとともに、便益とリスクの適正なバランスを確保 技術的中立性の確保、開発者に過度の負担を課さないよう配慮 不断の見直し、必要に応じた柔軟な改定、広範で柔軟な議論 	<ul style="list-style-type: none"> 「AI」: AIソフト及びAIシステムを総称する概念 ●「AIソフト」: データ・情報・知識の学習等により、利活用の過程を通じて自らの出力やプログラムを変化させる機能を有するソフトウェア（例: 機械学習ソフトウェア） ●「AIシステム」: AIソフトを構成要素として含むシステム（例: AIソフトを実装したロボットやクラウドシステム） ・AIシステムの「開発者」及び「利用者」は以下のとおり定義 ※ただし、「開発者」及び「利用者」は場面に依りて個別に決まる相対的な概念 ●「開発者」: AIシステムの研究開発（AIシステムを利用しながら行う研究開発を含む）を行う者（自らが開発したAIシステムを用いてAIネットワークサービスを他者に提供するプロバイダを含む） ●「利用者」: AIシステムを利用する者（最終利用者（エンドユーザ）のほか、他者が開発したAIネットワークサービスを第三者に提供するプロバイダを含む） ・対象とするAIシステムの範囲→ネットワーク化され得るAIシステム（ネットワークに接続可能なAIシステム） ・対象とする開発者の範囲→一定定義された開発者すべて ・対象とする開発の範囲→閉鎖された空間（実験室、セキュリティが十分に確保されたサンドボックス等）内での開発は対象とせず、ネットワークに接続して行う段階に限定
<p>関係者に期待される役割</p>	<ul style="list-style-type: none"> ・各国政府及び国際機関による多様なステークホルダ間の対話の促進に向けた環境整備 ・開発者、利用者等ステークホルダによる対話やベストプラクティスの共有、AIの便益及びリスクに関する認識の共有 ・標準化団体等による推奨モデルの作成・公表 ・各国政府によるAIの開発者コミュニティの支援、AIに関する研究開発を支援する政策の積極的な推進 	

第2章 国際的な議論のためのAI開発ガイドライン案②（AI開発原則案の解説）

開発原則	開発原則の解説（留意することが期待される事項等）
<p>① 連携の原則 開発者は、AIシステムの相互接続性と相互運用性に留意する。</p>	<ul style="list-style-type: none"> ・相互接続性と相互運用性を確保するため、①有効な関連情報の共有に向けた協力、②国際的な標準や規格への準拠、③データ形式の標準化及びインターフェイスやプロトコルのオープン化への対応、④標準必須特許等のライセンス契約及びその条件についてのオープン・公平な取扱い、などに留意することが望ましい。
<p>② 透明性の原則 開発者は、AIシステムの入出力の検証可能性及び判断結果の説明可能性に留意する。</p>	<ul style="list-style-type: none"> ・採用する技術の特性や用途に照らし合理的な範囲で、AIシステムの入出力の検証可能性及び判断結果の説明可能性に留意することが望ましい。（※アルゴリズム、ソースコード、学習データの関係を想定するものではない。）
<p>③ 制御可能性の原則 開発者は、AIシステムの制御可能性に留意する。</p>	<ul style="list-style-type: none"> ・AIシステムの制御可能性について、あらかじめ検証及び妥当性の確認をするよう努めるとともに、採用する技術の特性に照らし合理的な可能な範囲において、人間や信頼できる他のAIによる監督・対処の実効性に留意することが望ましい。
<p>④ 安全の原則 開発者は、AIシステムがアクチュエータ等を通じて利用者及び第三者の生命・身体・財産に危害を及ぼすことがないよう配慮する。</p>	<ul style="list-style-type: none"> ・AIシステムの安全性について、あらかじめ検証及び妥当性の確認をするよう努めるとともに、AIシステムの本質安全や機能安全に資するよう、開発の過程を通じて、採用する技術との特性に照らし可能な範囲で措置を講ずるよう努めることが望ましい。 ・利用者及び第三者の生命・身体・財産の安全に関する判断を行うAIシステムについては、利用者等ステークホルダに対して設計の趣旨などを説明するよう努めることが望ましい。
<p>⑤ セキュリティの原則 開発者は、AIシステムのセキュリティに留意する。</p>	<ul style="list-style-type: none"> ・AIシステムのセキュリティについて、あらかじめ検証及び妥当性の確認をするよう努めるとともに、開発の過程を通じて、採用する技術の特性に照らし可能な範囲で対策を講ずるよう努めることが望ましい（セキュリティ・バイ・デザイン）。
<p>⑥ プライバシーの原則 開発者は、AIシステムにより利用者及び第三者のプライバシーが侵害されないよう配慮する。</p>	<ul style="list-style-type: none"> ・AIシステムのプライバシー侵害のリスクについて、あらかじめ影響評価を行うよう努めるとともに、開発の過程を通じて、採用する技術の特性に照らし可能な範囲で措置を講ずるよう努めることが望ましい（プライバシー・バイ・デザイン）。
<p>⑦ 倫理の原則 開発者は、AIシステムの開発において、人間の尊厳と個人の自律を尊重する。</p>	<ul style="list-style-type: none"> ・AIシステムの学習データに含まれる偏見などに起因して不当な差別が生じないよう、採用する技術の特性に照らし可能な範囲で所要の措置を講ずるよう努めることが望ましい。 ・国際人権法や国際人道法を踏まえ、AIシステムが人間性の価値を不当に毀損することがないよう留意することが望ましい。
<p>⑧ 利用者支援の原則 開発者は、AIシステムが利用者を支援し、利用者を選択の機会を適切に提供することが可能となるよう配慮する。</p>	<ul style="list-style-type: none"> ・AIシステムの利用者のために、①利用者の判断に資する情報を適時適切に提供し、かつ利用者にとって操作しやすいインターフェイスが利用可能となるよう配慮、②利用者を選択の機会を適時適切に提供する機能が利用可能となるよう配慮、③社会的弱者の利用を容易にするための取組、に留意することが望ましい。
<p>⑨ アカウンタビリティの原則 開発者は、利用者を含むステークホルダに対しアカウンタビリティを果たすよう努める。</p>	<ul style="list-style-type: none"> ・開発原則①～⑧の趣旨に鑑み、利用者等に対しAIシステムの技術的特性について情報提供や説明を行うほか、ステークホルダとの対話を通じた意見聴取や、ステークホルダの積極的な関与を得るよう努めることが望ましい。 ・AIシステムによりサービスを提供するプロバイダなどの情報共有・協力を努めることが望ましい。

図3 総務省によるAI開発ガイドライン案

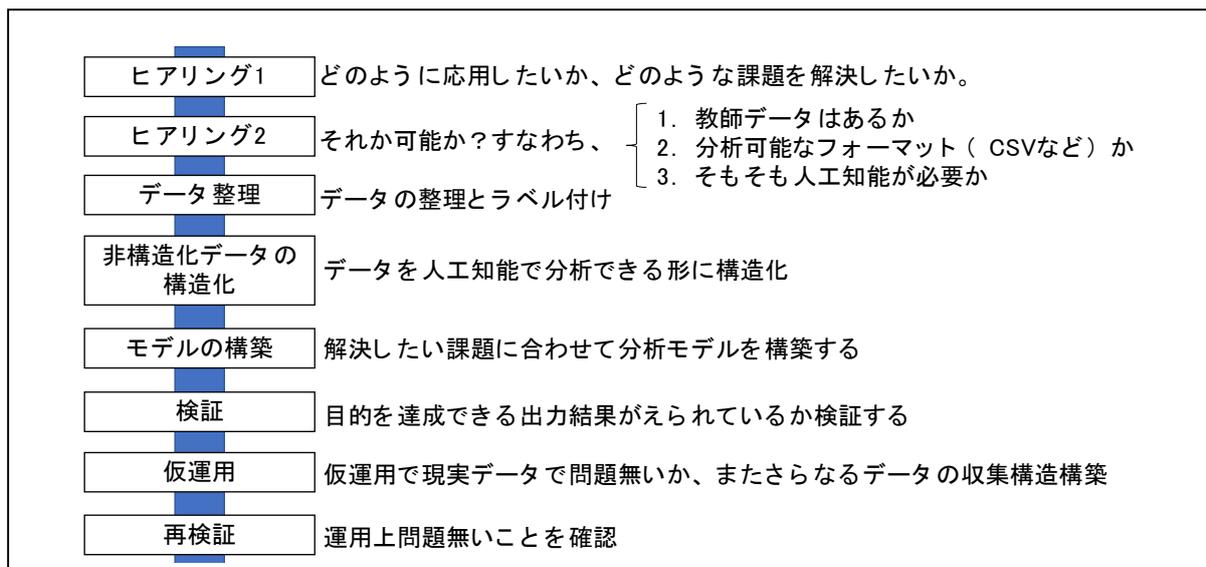


図4 機械学習を含んだ人工知能製品の開発運用フロー例

以上、人工知能の社会実装に向けて得ておくべき基本的知識を記載した。経産省発行のH29年通商白書によれば、日本のイノベーション能力は世界21位、研究開発における産学協業は18位と順位が低く、今後イノベーションの推進に向けて行動していくことが重要と考えられる。

医療用人工知能の政策関係者を対象とした人工知能教育

研究分担者 藤原 幸一

（京都大学大学院情報学研究科 助教）

研究要旨

近年、ビッグデータ解析や人工知能(AI)技術が発展している。医療においても、これらの技術の研究が進んでいるが、実際の医療現場でそれらが活用されているとはいえない。この状況を改善するには、現場の医師が最新の AI 技術について理解することのみならず、情報システムを導入する権限を有する医療機関における意志決定者や、そもそもの政策決定に関わる関係者も、AI 技術についての理解が求められる。

そこで本研究では、意志決定者向けに AI 技術について啓蒙するための教材を開発する。今年度は、まず、医療機関における意志決定者が AI 技術について理解しておくべき事柄を、現場医師、エンジニア、および AI 技術に特化して講義を提供しているベンチャー企業にヒアリングした。その上で、ヒアリング結果に基づいて意志決定者が理解すべき AI 技術について教材のカリキュラム案を策定した。次年度では、本カリキュラムに基づいて実際の教材作成を進める。

A. 研究目的

近年、ビッグデータ解析や人工知能(AI)技術の進展がみられ、医療分野においてもこれら技術の研究開発が進んでいる。たとえば、深層学習を用いた医療画像解析や、自然言語処理に基づいたカルテ解析などの研究が進んでおり、データ解析・AI 活用による医療革新への期待は大きい。しかしながら、研究レベルでは様々な取り組みがなされていても、実際の医療現場でそれらが活用されているとはいえない。今後、研究と医療現場におけるデータ解析・AI 活用への温度差がますます広がるのが懸念される。

この原因として、AI の研究者側において医療についての造詣が深くないことに加え、医療倫理や個人情報保護の観点から

現実の臨床データへのアクセスが容易でないことが挙げられる。また、医療現場側においても、AI 技術への理解不足が挙げられる。そのため現場の医師が、自らの臨床に AI 技術を活用したい、または AI の研究者とコラボレーションをしたいと考えたときに、当該施設内においてスムーズに同意を得るのが難しい場合がある。

これらの状況を改善するには、現場の医師が最新の AI 技術について理解することのみならず、医療 AI を活用した政策を立案する決定者も AI 技術について理解しておく必要がある。

そこで、本研究分担では、特に政策決定者向けに AI 技術について啓蒙するための、教材を開発することを目的とした。

B. 研究方法

研究1年目となる今年度、政策決定者がポリシーを立案するにあたり、現場におけるAI技術の認識について、現場医師3名と議論した。また、医療データを扱った経験のあるエンジニア2名にも、医療データ解析の実態についてヒアリングした。

さらに、AI技術に特化して講義を提供しているベンチャー企業に取材して、現在提供されているカリキュラムについて調査した。

最終的に、これらの結果に基づいて、政策決定者が理解すべきAI技術についての教材のカリキュラム案を策定した。

C. 研究結果

ヒアリングで得られた主な意見を以下に整理する。

【医師】

- 臨床現場の医師がAI技術の種々の詳細を理解し、自らデータの解析までする時間はない旨の意見がある。一方でAIには興味がある医師もあり、情報系の研究者・エンジニアとの協業を望んでいる。
- 手法の概要を理解していないと、そもそもどのようなことがAI技術で実現できるか、またどのようなデータが必要であるかを把握できないため、手法の概要だけでも勉強したい。
- 現状として、AI技術でどこまでできるようになっているのか、今後数年でどのようなことが可能になると考えられるかを知りたい。また、逆にどのようなことはAIでは実現できないのかも知りたい。

【情報系エンジニア】

- とりあえずAIを使いたい、とだけ言われても困るので、アプリケーションを明確にしてほしい。
- 医学知識に乏しいため、データのラベリング、解釈が困難であり、データのクリーニングも含めて、ラベリングと前処理は医療者側をお願いしたい。
- 個人情報保護は当然としても、倫理審査などもあり、他の分野と比べて格段にデータのハンドリングが困難。予め医療データの扱いに特有のノウハウなどを知りたい。
- 発注しようとしているシステムについて、適切な工数・費用の相場観は身につけておいて欲しい。
- 納品の形態(レポートなのか、アルゴリズムなのか、プログラムなのか、それらが実装されたサーバーなのか)についてのイメージを持って欲しい。

【AI技術を講義するベンチャー企業】

- サービス開始以降、受講者数はうなぎ登りで、また受講者の業種も幅広く、AI技術を学びたい、導入したいと考える個人・企業は多い。
- 数学やプログラミングを含めて、技術の詳細を学びたい人も多いが、以外とそもそもAIとは何かについて学びたいと考えている人も多い。
- AIが流行っているからという理由だけで、会社からAI技術について勉強してこいと言われ受講する人もいる。

これらの調査結果に基づいて、カリキュラム案を立案した。カリキュラム立案にあたっては、以下の点を取りわけ考慮した。

- ・ 導入として、すでに医療関係で用いられている AI 技術の実例について紹介すること。
- ・ そもそも現在 AI と呼ばれている技術は、数年前までビッグデータ解析や機械学習と呼ばれていたものであり、本質的な違いはないことを説明した上で、今回の AI ブームのきっかけとなったディープラーニングについても概略に触れること。
- ・ AI にて扱う様々なタスクについて統一的に扱い、どのような問題であれば、既存の方法で対応可能であるかを説明する。また、どのようなことは AI には不向きであるかについても述べる。
- ・ AI 技術を理解するために必要な知識について、個々の詳細には立ち入らないが、整理して伝えること。
- ・ 実際に AI を導入する際のフローを説明すること。特に、費用対効果については丁寧に説明する。

最終的に開発したカリキュラム案を、別添のレポートにまとめた。

D. 考察

これらヒアリング結果より、医師と情報系のエンジニアとがこれまで正しく意思疎通できていないことが明らかとなった。特に、両者が考えているアウトプットが異なっていると、仕様が曖昧となり開発時に手戻りが発生、工数が増大する可能性が考えられる。したがって、政策決定者は政策立案にあたり、両者の溝を埋める、もしくは溝があることを陽に考慮する必要がある。

E. 結論

本研究分担では、医療 AI に係る政策の決定にあたり決定者が理解しておくべき事柄を、現場医師、エンジニア、および AI 技術に特化して講義を提供しているベンチャー企業に取材した。

最終的に、これらの結果に基づいて、ペリシー立案にあたり政策決定者が理解すべき AI 技術についての教材のカリキュラム案を策定した。次年度では、本カリキュラムに基づいて実際の教材作成に進む。

F. 研究発表

1. 論文発表

なし

2. 学会発表

なし

厚生労働科学研究費補助金（政策科学総合研究事業）
分担研究報告書

医療用人工知能の普及啓発に向けた課題分析

研究分担者

木村 眞司

（札幌医科大学医療人育成センター教養教育研究部門）

研究協力者

岩田 啓芳

（独立行政法人 地域医療機能推進機構 城東病院）

研究要旨

医療用人工知能の研究開発に際しては、各医療機関の研究開発への参加や学会レベルでの大規模研究の実現等において、各組織の長や学会幹部の理解が不可欠である。しかしながら、これら意思決定に関与する人材を対象とした医療用人工知能の教材がなく、各プロジェクトの負担となってきた。一方、これらの人材には、一方的な情報提供は必ずしも有効ではなく、むしろ、対話を通じた信頼の醸成や疑問の解消が行動変容に繋がりうる。そこで、本研究分担は、医療用人工知能の普及に向けて、これら各分野の意思決定者を対象とした啓発活動のあり方を検討した。

今年度は、その準備段階として、総合診療の臨床現場における医療用人工知能のニーズや課題のヒアリング調査を試みた。そのために、研究代表が研究開発を行ってきた診断支援システム「PGY-01」を対象として、試験運用経験のある医師と運用経験のない医師にインタビューを行い、診断支援システムの必要性や現場での課題を分析した。

ヒアリングの結果、診断支援システムは、臨床現場において利用されていなかったことが判明した。原因として、診断支援システムの利用導線と提供情報の有用性に課題が見出された。一方、現在の臨床スタイル自体が抱えている各種バイアスに対する懸念と、医療用人工知能に対する医師らの強い期待も明らかとなった。以上の結果から、診断支援システムには、臨床側に相応の需要と期待があることが示唆された。今後、臨床側における診断困難症例に対応するための技術の他に、医療の質を無意識のうちに低減せしめている一般症例に対する支援を通じて、組織幹部を啓発しうる可能性が見出された。

A. 研究目的

臨床診断は医療の現場において欠かせない重要な過程である。これは全国のあらゆる医療機関において、質の程度の差はあれども普遍的に行われている。しかしながら、

臨床診断には時には膨大な情報とその処理が求められ、多くの労力・時間を要する場合がある。そうした際、診断プロセスの複雑さや様々な外的要因から、致命的疾患や緊急を要する疾患の診断ミス・見逃しなどが生じ得る。そこで、臨床診断を支援する

医療用人工知能分野の発展に向け、技術革新と国際競争力向上に資する人材育成が必要となった。

本分野の政策研究を経て、医療用人工知能研究は、研究人材の欠如に加えて研究プロジェクトを支える人材により制約を受けることが明らかになった。たとえば、医療用人工知能研究を進めるためには医療機関の意思決定者に技術が受容される必要がある。しかし、医師決定者に医療用人工知能に関する十分な理解がなければ実現しない。

そこで、本研究分担では医療用人工知能の開発や普及に関わる意思決定者の啓発を目標として掲げた。そのために、今年度では、医療用人工知能の有望な応用である診断支援システムの必要性や現場での課題を分析し、研究教育機関・研修病院の臨床現場における受容と活用の促進に向けた知見の収集を図った。

B. 研究方法

医療用人工知能の研究開発や活用に際した意思決定に関わる人材を対象とした啓発活動を行うため、まず医療用人工知能の運用に関するフィードバックを対面による面接によって収集する。対象として、診断支援システムのプロトタイプである PGY-01(図 1)を試験運用している教育研究病院の担当者、及び PGY-01 の運用経験のない医療用人工知能の潜在的な利用者のない臨床現場の医師を想定した。インタビュー対象者、及び質問内容は以下の通り。

インタビュー対象

1. 診断支援システムのプロトタイプ PGY-01 を試験運用している医療機関の担当者：川崎市立多摩病院 聖マリアンナ医科大学 総合診療内科 土田知也氏

2. 医療用人工知能の潜在的な利用者：筑波大学 地域医療教育学 濱田修平氏

質問内容

- Q1-1:診断 AI(PGY-01)を日常的に用いておられますか？その頻度を教えて下さい。
- Q1-2:診断 AI(PGY-01)を日常的に使用していない場合、その理由を教えてください。
- Q1-3 : PGY-01 の改善点を教えてください。
- Q2: 診断困難時に、診断 AI からどのような支援が得られるとより有益ですか？
- Q2-2:病気をリストアップするだけではなく、何か AI の機能として追加できるか？
- Q3: 医師による診断過程において、陥りがちな過ちは何でしょうか？
- Q4:最近の医学系ニュースで、最も取り入れてみたいと思った技術は何でしょうか？また、その理由を教えてください。

C. 研究結果

1. 川崎市立多摩病院 聖マリアンナ医科大学 総合診療内科 土田知也医師

土田氏は PGY-01 の試験運用を行っている医師であり、医療用人工知能の運用に関するフィードバックを収集した。その結果、PGY-01 は試験運用開始時に試験的に利用してみて以来殆ど利用されていない事実が判明した。その理由として土田氏があげたのが、川崎市立多摩病院では診断システムを利用する必要があるような難解な病気に遭遇するケースが稀であるという点であった。多くのケースで診断システムを利用すること無く診断がつくため、診断システムを利用するルーティンが生まれず、結果として極稀に遭遇する診断困難な事例でもシステムを利用することなく当該領域の専門家に相談して解決していた。

一方で、実務の中で診断システムを利用するケースは無かったものの、試験運用の



図 1 診断困難症例の診断支援システム PGY-01

開始前に実施した特定の疾患を想定したテストでは、想定通りの鑑別を診断システムが出力しており、診断システム鑑別精度については十分な水準にあると認識していた。しかし、Google 検索のような既存の検索システムでも同様の疾患が出力されていたとのことで、この時点で診断システムの必要性に疑問を抱いていたというお話だった。

こうした中で、診断システムの改善点として土田氏が挙げたのは、「スマホなどで簡単に利用できる形態での提供」や「電子カルテ等普段の業務で利用しているツールとの連携」「疾患に関する論文などの文献などを表示する機能の追加」の3点。臨床の現場ですぐに使えるアプリケーションや普段の業務の中で特に意識せず使えるシステムであれば利用頻度は増え、鑑別に合わせて疾患に関する論文なども提示してくれるれば、利便性は高まるというご助言を頂いた。

また、臨床現場からの貴重な意見として「診断困難だからといってすぐに診断つけ

なければならないとは限らない」というご指摘があった。高齢者の多い病院では様々な病態を持った患者が訪れる。その際、診断をつけるための情報が少ないと経過観察によって様子を見るケースが多く、結果として治癒してしまうことも少なくない。そうしたケースもある中で、診断システムを用いて診断を付け、疑いがあるから検査を行なうことは患者の負担を増やしてしまうことに繋がるというご意見を頂いた。

診断困難な事例はどのようなケースで遭遇するのか尋ねたところ、外来を中心に扱う総合診療で月に2-3例見る程度ということだった。後に疾患が判明することもあれば、自然に治癒してしまうケースもあったという。ただ、こう言ったケースで診断システムを利用することは想起されなかった。

医師による診断過程による過ちとして、土田氏は「診断時のバイアス」を挙げた。その上で、こうしたバイアスを無くすために診断システムを利用することは有用ではあるものの、バイアスを無くすために運用

するのであれば、カルテや問診データの読み込みや読影システムへの組み込みによって、医師による診断結果をチェックできる仕組みや得られたデータをそのまま使える機能が必要だろうというご指摘を受けた。

この他に、近年の医学系の技術で興味深いものを伺ったところ、幾つか貴重なご意見を頂けた。例えば、医療用ロボットが看護師や家族の代わりに介護やリハビリのサポートをロボットが行い、患者の歩き方の変化などを医療用ロボットが認識して疑いのある疾患を提示してくれると医療の質は大きく向上する。また、患者の自宅などに各種センサを設置し、患者の体調等を日常的に観察してくれるようなシステムがあれば、そのデータを用いて診断システムが病気の兆候を発見することで「予防医療」に繋げるようなアプローチも可能になるという意見であった。

今回の土田氏へのインタビューでは、試験運用では診断システムをあまり利用しなかったものの医療用人工知能に対する期待感を感じられた。その一方、臨床現場で利用するには様々な課題があるというお考えであり、こうした課題の解決は急務であると言える。

2. 筑波大学地域医療教育学 濱田修平医師

濱田氏は PGY-01 を利用していない臨床現場の医師であり、医療用人工知能の運用経験がないため、今回は質問内容の「Q2」以降、医療用人工知能に対する期待や医療現場の課題について尋ねた。

まず、診断システムに期待するものについては、患者の症状などから可能性の高いものを順に表示し、見逃しやすい疾患などを鑑別に加えてくれると良いということだった。これについては PGY-01 で提供されているが、診断がつけられるようなケースでは「可能性の高いもの」と同時に「可能

性が低く考える必要のないもの」を挙げてくれると良いというご意見も得られた。これにより、考慮する必要のない疾患を想定した検査を省くことができるため、患者の負担を軽減することができる。

医師による診断過程による過ちとしては、土田氏と同様に思い込みバイアスによる見落としや先入観を挙げた。臨床現場では、医師が簡単な検査で見つけられたはずの疾患を見落とすことがある。こうしたケースで、鑑別と合わせて必要な検査などを人工知能が提案してくれることで医師の見落としを防げるかもしれない。また、検査データの分析を人工知能が細かく分析することで、人間が見落としがちな微細な兆候を見逃さなくなる可能性についても言及した。

医療技術について気になるものとしては、マイクロ RNA 分析を挙げていた。マイクロ RNA 分析によって、通常なら発見できないような小さながんを発見できるようになる。これにより、がんの早期発見・早期治療が可能になれば、がんの治療は大きく発展するというお話だった。

濱田氏へのインタビューでは医療用人工知能に対する強い期待が伺えた。診断システムを積極的に利用することで患者の負担を軽減しようという発想も新しい。また、診断システムへの期待は PGY-01 利用目的にマッチしており、潜在的なユーザーとして有意義なヒアリングとなった。

D. 考察

今回のインタビューにより、診断システムの運用に際し幾つか重要な知見を得られた。まず、診断システムの精度に関しては十分と認識していながらも使用されることがなかったこと。原因としては、診断システムを使用する必要のある診断困難な事例の少なさとシステムの使いにくさが挙げられている。しかしながら、診断 AI の活用

目的の中に医師の持つバイアスの除去がある以上、診断システムは医師が必要と感じた時以外にも利用されることが望ましい。人間よるバイアスは診断困難な事例だけではなく、診断がつくケースでも起こり得る。バイアスの存在に医師が気づけるように、常に利用されている状態が理想である。

また、診断困難な事例が少数ながらあったにもかかわらず診断システムが利用されなかった。診断システムを含め、医療に用いられる機器が使いにくい場合、医師がその必要性を強く感じた時にしか使われなくなる。しかし、そのケースが極稀にしか発生せず、代替手段が容易に利用可能な場合、利用すべきケースでも診断システムが利用されにくくなる。今回の試験運用では「診断困難な事例はその分野の専門家に意見を求める」「Google 検索でも同様のことができる」という意見があり、何らかの代替手段が用いられたと推測される。このことから、診断システムが利用しやすい形態で提供される事は診断システムの普及促進において非常に重要な要件となると思われる。利用しやすい形態の例として、今回のインタビューではスマートフォンでの利用のほか、電子カルテとの連携や問診時の音声データ活用などが例示された。小型の情報端末ですぐに利用できる形態、もしくは医師の日常業務の中で収集される情報をそのまま診断システムに活用できる形態で診断システムが提供されることが望ましい。

現行の診断システムでは、診断時のバイアスを除去するために鑑別をより多く挙げる形式をとっていた。しかし、今回のインタビューから臨床現場の医師が患者の負担軽減を強く意識していることが分かった。診断システムに期待するものの中に不要な検査を明確にするために無視出来るケースを提示して欲しいというものもあれば、診断システムの利用を避ける理由に、鑑別を挙げることで検査が増え、患者に対する負

担を増やす事に関する懸念があった。診断システムの現行の目的とは方向性が異なってくるものの、患者の負担を減らすための診断システム利用についても検討の余地がある。

さらに、双方のインタビューで臨床現場における過ちとして診断時のバイアスが挙げられた。これによって、バイアスを除去するための診断システム活用については一定の需要があることが示唆された。しかし、試験運用の現場では、鑑別を挙げるだけでは不十分という意見もあった。疾患に関連する論文の表示や使いやすい形態での提供など、診断システムの活用方法や追加機能についてはさらなる検討を加える必要があるだろう。

これらの結果を受けて、医療用人工知能の普及に向けての医療系学会の意思決定者への啓発活動には、特に以下の点に留意し、理解を得ていく必要があると考えられた。

(1) 医師が「診断 AI を用いよう」と思わないときにこそ、アンカリングバイアスによって抜け落ちが発生することから、そうした事態を避けるうえでもプライマリケアに人工知能が有益たりうること。

(2) そのためには、たとえば、電子カルテに組み込まれることにより医師の診察や記載、検査オーダーや処方を自動的にモニタリングし、必要に応じて警告を発する仕組みが有益であること。

(3) カルテ記載から病名や症状を自動的に抽出する技術、いわゆる医療用自然言語処理の性能向上により、医療用 AI 技術にさらなる発展が実現しうること。

(4) 上記のような仕組みの実現には、技術の研究開発だけでなく、制度面での課題が合わせて克服されなければならない、そのためにも学術団体として働きかけていく必要があること。

E. 結論

医療用人工知能の研究開発に際しては、各医療機関の研究開発への参加や学会レベルでの大規模研究の実現等において、各組織の長や学会幹部の理解が不可欠である。しかしながら、これら意思決定に関与する人材を対象とした医療用人工知能の教材がなく、各プロジェクトの負担となってきた。一方、これらの人材には、一方的な情報提供は必ずしも有効ではなく、むしろ、対話を通じた信頼の醸成や疑問の解消が行動変容に繋がりうる。そこで、本研究分担は、医療用人工知能の普及に向けて、これら各分野の指導者を対象とした啓発活動のあり方を検討した。

今年度は、その準備として、総合診療の臨床現場における医療用人工知能のニーズや課題のヒアリング調査を試みた。本来は、大勢の医師を対象としたグループインタビューが望まれたが、時間的な制約が厳しく、結果的に2名のインタビューに留まった。それでも、現在の総合診療における課題と、医療用人工知能を通じた克服に向けた前向きなフィードバックを得ることが出来た。

また、インタビューを通じて、臨床現場で医療用人工知能の利用を促進していくうえで、いくつかの課題も明らかとなった。まず、診断支援システムが医師の日常業務において自然な流れで利用できない限り活用も進まないという点がある。また、診断支援システムが医師のバイアスを補う方向に働くためには、医師が診断困難を感じる場合だけでなく、医師がなんら困難を感じない症例においても医療用人工知能が診療をモニタし、必要に応じて医師に示唆を与える必要があるものと考えられた。

今後、今年度の検討によって得られた知見を活用することで、各分野の指導者に対する啓発活動の具体化と研究開発の促進に

繋げたい。

F. 研究発表

1. 論文発表

なし

2. 学会発表

なし

歯科における人工知能 — 国内における研究動向と人材育成

研究分担者 安藤雄一

（国立保健医療科学院 研究情報支援研究センター 統括研究官）

研究要旨

医療用 AI の研究プロジェクトを進めるうえで、研究の多様性を高める人材育成が求められている。そこで、わが国の歯科保健医療の分野における人工知能(AI)研究の動向について文献レビューと情報収集を行った。また、その結果を踏まえ、歯科における人材育成の方向性について検討した。

医中誌において論文タイトルに「歯科」が含まれる AI に関連した文献を検索したところ、71 件がヒットした。その内訳をみると歯科学士向けの患者教育用ロボットの開発に関するものが圧倒的に多かった。全般的に研究の進展は低調であり、業界としての関心度合いの目安となる業界誌での扱いも少なかった。しかしながら、ネット検索では、音声認識技術など歯科に应用可能な技術が認められた。

こうした状況を前進させる人材育成に向けた取り組みとして、まずは歯科関係者側に対する AI 教育の適切なプログラムが求められる。また、AI 活用が有用と考えられる課題を見出すと共に、AI 専門家と歯科関係者が相互交流できる機会の構築が有益と考えられた。

A. 研究目的

人工知能(Artificial Intelligence、以下、AI)は、20 世紀半ばに初めてその名称が用いられて以来、ブームと冬の時代を繰り返し、現在、第 3 次ブームを迎えているといわれている 1)。

保健医療の分野では、厚生労働省の懇談会 2)により、人工知能(AI)を利用した病気の診断や医薬品開発の支援、患者の遺伝情報に応じたゲノム医療など 6 分野を重点領域として選定した。しかし、奥村 3)は、こうした状況について、論文作成が進みやすい分野や民間投資がビジネスとして成り立つ分野に限定されがちであり、公益性が高くても論文になりにくかったり収益が望めない分野については過小投資になりがちである点を指摘している。

今後、分野の健全な発展に向けては、現

状の施策の「穴」を補う試みが求められる。そこで、本研究班では、医療用 AI の研究プロジェクトを進めるうえで制約となる三種の人材育成として、①医療用 AI の研究開発や導入の意志決定に関与する人材育成、②研究の多様性を高める人材育成、③研究の生産性を高める人材育成、を目的とした。そのなかで、本分担研究は、②の研究の多様性を高める人材育成の一環として、歯科を対象とした AI 人材の育成を目的とした。

歯科の産業規模を金額的にみると、国民医療費統計 4)における歯科医療費 2 兆 8294 億円に自費診療分 5)が加わった年間 3 兆円余の規模であり、就労者数は歯科医療が供給される主たる場である歯科診療所の勤務者(歯科医師、歯科衛生士、歯科技工士、診療補助者、事務職など)は約 30 万人 6)である。

本研究分担では、まず、こうした状況にある歯科の業界(以下、歯科界と称す)においてなされてきた AI に関する研究・利用について、文献検索とネット検索を行い概観する。そのうえで、簡単な現況調査を行い、歯科界における AI 活用に関する人材育成について考察する。これにより、AI 活用の多様性向上の一端を担う意義が期待される。

B. 研究方法

1. 文献検索

本分担報告では国内の動向を把握することを目的としていることから、医中誌を用い、「歯科」に関する文献で、タイトルまたは要約中に「人工知能」の文言が含まれている文献を検索した。検索式は以下の通りである。

(人工知能/TH or 人工知能/AL)
and 歯科/TI

また、歯科の業界誌における取り上げ方をみると業界としての注目度を大まかに把握できると考え、代表的な歯科業界誌である 5 誌(歯界展望、日本歯科評論、The Quintessence、デンタルダイヤモンド、アポロニア)における掲載状況を確認した。

2. ネット検索

Google を用いて「歯科 AI」ないし「歯科 人工知能」による検索を行った。

3. その他

2018 年 3 月 9 日に開催された歯科と AI に関するシンポジウム、「ソーシャル・スマートデンタルホスピタル キックオフシンポジウム」(図 1) 7)に参加し、当該分野の現状を視察した。

C. 研究結果

1. 文献検索

医中誌における検索式「(人工知能/TH or 人工知能/AL) and 歯科/TI」では計 71 件がヒットし、内容を歯科の分野別に分類したところ、内容的に AI とは言えないものが 7 件あり、残る 65 件の内訳は以下の通りであった。

- ・ロボット(学生教育用の患者ロボット)に関するもの：44 件
- ・画像診断に関するもの：8 件
- ・エキスパートシステム (歯科補綴関連)：4 件
- ・歯科技工 (CAD/CAM) 関連：3 件
- ・AI 全般：2 件
- ・診療録関連：2 件
- ・アポイントシステム：1 件

上述のように、ロボットに関するものが半数以上と圧倒的多数を占めた。これらは大学における歯科学学生への教育に用いる患者ロボットに関するもの 8-11)である。

画像診断に関するものは、大学病院における歯科矯正治療 12)や嚢胞 13)の自動診断に関するものや遺体身元判定を目的とした X 線写真からの歯の自動記録に向けた基礎的研究などであった。

エキスパートシステムに関する文献 14,15)は、いずれも歯科補綴学の分野に関するもので、いずれも第五世代コンピュータ 1)が注目を集めた時期に出されたものであった。

歯科技工については新たなデジタル技術が歯科技工に及ぼす影響に関する解説 16)などであった。

AI 全般に関する文献は、社会の動向を簡潔に述べる短い内容のもの 17,18)であった。

次に、代表的な歯科業界誌 5 誌(歯界展望、日本歯科評論、The Quintessence、デンタルダイヤモンド、アポロニア)のうち、「人工知能」に関する記事があったのは 3 誌(日本歯科評論、The Quintessence、デンタルダイヤモンド)のみで、このうち、The Quintessence、デンタルダイヤモンドでは 10 年以上前の論文のみで、ここ 10 年間で掲載されたのは日本歯科評論 17,18) のみであった。

2. ネット検索

Google で「AI 歯科」と検索すると検索上位を狙って命名した歯科医院などがヒットするため、「人工知能 歯科」で検索したところ、以下のようなサイトがヒットした(上位 20 件)。

- ・ 大阪大学における取り組み (後述)
- ・ 歯科用 CAD プログラム (業者)
- ・ 歯科予約管理システム (業者)
- ・ AI を活用している歯科医院 等々

上記以外では音声入力アプリ開発による衣類採寸業務が効率化したこと 19)を報じるニュースサイトへの Twitter によるレスポンスとして歯科健診における活用可能性を予測・期待する声があった 20)。

また、MR(Mixed Reality : 複合現実)の応用による歯科治療シミュレーションシステムのサイトも注目された 21)。

3. その他

2018 年 3 月 9 日に大阪大学にて行われた「ソーシャル・スマートデンタルホスピタル キックオフシンポジウム」(図 1) 7)において発表された歯科の取り組みは、以下の通りであった。

- ・ 矯正歯科治療における機械学習と臨床への応用

- ・ 人工知能を用いた、口内炎と口腔がんの鑑別診断システムの開発
- ・ データ同化技術を用いた歯の喪失シミュレーション



図 1. 大阪大学歯学部附属病院が主催したシンポジウムのポスター

D. 考察

わが国における歯科の AI 研究について医中誌により文献レビューを行ったところ、我が国で最も早期に開始された歯科の AI 研究は、歯科補綴の分野において義歯の設計に関するエキスパートシステム構築等に関するものであった 1)。この頃は第 5 世代コンピュータがもてはやされた第 2 期 AI ブームの時期であった。その後のわが国における AI 研究は、学生教育用の患者ロボットに関するものが突出して多く、画像診断に関する研究がこれに続いていた。PubMed による世界の動向に関する文献レビュー結果と比較すると、歯科学生向

け患者教育用ロボットに関する研究が多いのは我が国の特徴であり、対外的な評価も高い 22)。他方、研究の幅でみると、我が国の研究は海外の取り組み状況に比べると、分野が比較的限定されてきたといえる。

参考のため PubMed を用い、医中誌の検索式と同様、下記の検索を行った。

((dentistry[ti])or(dental[ti])) and
(artificial intelligence)

その結果、112 件がヒットしたが、内容的には医中誌による検索結果よりも研究の幅は広く、患者教育用ロボットに偏ったものではなかった。医中誌による検索結果と比較すると、医中誌で最も多かったロボットに関するものは PubMed 検索ヒット件数(112)の 1 割強と、過半数を超えていた医中誌に比べると割合が少なかった。医中誌検索でロボットに次いでヒット件数が多かった(a) 画像診断関連、(b) エキスパートシステム、(c) 歯科技工(CAD/CAM)の PubMed 検索におけるヒット件数はいずれも全ヒット件数の 1 割前後であり、画像診断関連と歯科技工(CAD/CAM)では医中誌検索結果と類似していたが、エキスパートシステムでは PubMed 検索におけるヒット割合が高かった。また、全般的にみて PubMed 検索では歯科臨床における診断に関連するものが多かったが、内容的には多様であった。

AI と歯科に関する国内外の文献検索結果を比較すると、歯科学学生教育用患者ロボットの開発に関する研究が多かった我が国に対し、海外での取り組みは多様と言える。PubMed と医中誌では文献の分類基準が同一と考えにくい面があり、今回行ったような単純な検索結果から類推できる内容には限界があるが、それを踏まえても上述した違いは際立っていた。

以上を総括すると、わが国の歯科分野における AI の研究動向の現状は、満足のいくレベルにはほど遠いと言える。歯科界と

しての関心度合いについては、歯科の業界誌における取り扱いが 1 つの目安になるが、扱いそのものが少なく、業界としての関心の低さとみることができる。

一方、歯科分野における AI 活用のニーズについて考えてみると、歯科医院でのニーズは決して低くなく、既に予約システムなど商品化が進んでいるものもあるが、これらは民間市場ベースでの対応が主と考えられるが、学会を中心とした研究ベースでの取り組みの進展も重要と考えられる。

AI の研究開発は、投資金額の規模として公的研究費よりも民間動向に依るところが大きいのが、反面、電化製品のように、ほぼ全面的に民間企業に委ねる性質のものとは必ずしも言えない面も有していると考えられる。もしそうであれば、今後、AI が今後、社会の各層に浸透していく状況を踏まえると、これに対応できる人材育成を行う必要性は意外と高い可能性がある。とくに学会などの公的側面も有している団体の果たす役割としては、その団体の専門領域において AI 活用のメリットを見出すことが重要と考えられる。

とくに歯科の分野においては、AI そのものに詳しい人材は数少ない現状にあると思われるので、まずは AI の基本的なところや他分野での活用例などを学び、周囲に AI 活用が期待できるものがあるかどうかを検討することが肝要であろう。

近年、幼児が歯ブラシを加えたまま転倒した際の事故が問題視されるようになったが、幼児用の柔らかな材質の歯ブラシが開発されたが、これなどは子どもの事故に関するデータベースが構築されたことが契機になったとのことであり 23)、参考にすべきと思われる。

近年、音声認識の技術が進み、衣料の裁断を行う民間企業では採寸した数値を音声入力できるようになり、業務効率が上がったことが NHK のニュースによって報じられたが、このニュースに対して歯科での応用が可能であることを示唆したツイートがある 20)。

歯科における音声入力には既に臨床の場における診療室限定のシステムが販売されているが、歯科健診は診療室だけでなく乳幼児や園児・学童・生徒や成人に対して診療室の外でも様々な形で行われているので、汎用性の高い音声入力が可能になれば多くの歯科医師から歓迎されると思われる。

E. 結論

わが国の歯科保健医療の分野におけるAI研究の動向について文献レビューを行ったところ、歯科学生向けの患者教育用ロボットの開発に関するものが多かった。全般的に、歯科用AI研究の進展は低調であり、業界としての関心度合いも低かった。

この結果を踏まえて、歯科保健医療の分野における人材育成のあり方について検討を行った。今後、AI導入について技術的検討が必要になると思われるが、歯科関係の職種で、これに対応できる人材は希少であり、AIに関して専門性の高い人材の関与が必須となる。そこで、これらAI人材と歯科人材とが研究交流できる機会をどのように設けるかが課題となると考えられる。その一助として、歯科側からの情報発信は不可欠であり、今後、当事者が求めていること、或いは現状をありのまま伝える手段が必要と思われる。

次年度は、学会等の関係者にアプローチし、様々な意見聴取を行い、それをAI技術として実現を図っていくにはどのようにやり方が有用なのかを検討してみたい。

F. 参考文献

- 1) 大野浩. 俯瞰図から見える日本型“AI 人工知能”ビジネスモデル. 日刊工業新聞社. 2017.
- 2) 保健医療分野におけるAI活用推進懇談会 報告書.
<http://www.mhlw.go.jp/stf/shingi2/0000169233.html> (厚生労働省ウェブサイト、2018年5月14日アクセス)
- 3) 奥村貴史. プライマリ・ケアと人工知能. プライマリ・ケア 2018 ; 3(1) : 80-83.
- 4) 結果の概要 平成27年度 国民医療費の概況.
<http://www.mhlw.go.jp/toukei/saikin/hw/k-iryohi/15/dl/kekka.pdf> (厚生労働省ウェブサイト、2018年5月14日アクセス)
- 5) 医療経済実態調査.
<http://www.mhlw.go.jp/bunya/iryohouhoken/database/zenpan/iryookikan01.html> (厚生労働省ウェブサイト、2018年5月16日アクセス)
- 6) 結果の概要4 従事者数の状況 平成26年(2014)医療施設(静態・動態)調査・病院報告の概況.
<http://www.mhlw.go.jp/toukei/saikin/hw/iryosd/14/dl/1-4.pdf>(厚生労働省ウェブサイト、2018年5月14日アクセス)
- 7) ソーシャル・スマートデンタルホスピタル キックオフシンポジウム.
<http://www.osaka-u.ac.jp/ja/news/seminar/2018/03/7659>(大阪大学ウェブサイト、2018年5月14日アクセス)
- 8) 秋山仁志、宇塚 聡、宮下 渉、原 節宏、新田俊彦、三代冬彦、羽村 章. ヒト型患者ロボットシミュレーションシステム(SIMROID)を用いた歯科硬組織修復研修. 日本シミュレーション医療教育学会雑誌 2016 ; 4 : 10-17.
- 9) 高信英明、大久保則男、鈴木健司、三浦宏文、榎 宏太郎、宮崎芳和、丹澤 豪、高本陽一、高西淳夫. 歯科患者ロボットにおける呼気機能と口腔内温湿度. 日本咀嚼学会雑誌 2015 ; 25(1) : 2-7.
- 10) 丹澤 豪、間所 睦、長谷川篤司、高信英明、高西淳夫、榎 宏太郎. ヒューマノイドロボットを応用した歯科偶発症シミュレーション教育. 日本シミュレー

- シオン外科学会誌 2010 ; 18(1) : 1-10.
- 11) 間所 睦、丹澤 豪、榎 宏太郎、高信英明、高西淳夫. 歯科臨床教育用患者ロボットの開発(解説). 日本歯科医学会誌 2010 ; 29 : 37-41.
 - 12) 谷川千尋、石垣光昂、Lee Chonho、竹内優斗、清水優仁、野崎一徳、山城 隆. 矯正歯科治療要否を判定する artificial intelligence(AI)システム. 第 76 回日本矯正歯科学会大会プログラム : 2017.10 : 同抄録集. p.142.
 - 13) Banumathi A., Kannammal A., Arthee R., Raju S., Abhaikumar V. Automated Diagnosis and Severity Measurement of Cysts in Dental X-ray Images Using Neural Network. Biomedical Soft Computing and Human Sciences 2006; 11(1):15-19.
 - 14) 堤 定美. 歯科における人工知能の応用. 日本歯科評論 1986 ; 524 : 203-214.
 - 15) 林 恭平. 歯科領域における人工知能の応用. 第 5 回医療情報学連合大会 : 1985.11 : 同論文集. 523-528.
 - 16) 滝沢琢也. 陸 誠. (連載-歯科技工作業のデジタル化はわれわれをどこに連れて行くのか? 将来残る手作業とは?) 匠の技とデジタルの融合から、さらなる新しいステージへ(第 1 回) 総論 歯科技工の現状とデジタル化. Quintessence of Dental Technology 2017; 42(9): 1452-1463.
 - 17) 須崎 明. 臨床の行方 いまこそ大切にすべきもの 歯科医療におけるイノベーションとソリューション. 日本歯科評論 2017 ; 77(11) : 8-9.
 - 18) 羽村 章. 歯学の行方 学会ニュース・トピックス 社会の変化と未来の歯科医師. 日本歯科評論 2016 : 76(11) : 11-13.
 - 19) 「RECAIUS フィールドボイス」が、株式会社ささげ屋の”衣類採寸業務”に採用. http://www.toshiba-sol.co.jp/news/detail/20171207.htm?_ga=2.196569775.2068685419.1514989353-454912206.1514989353(東芝デジタルソリューションズ ウェブサイト、2018 年 5 月 15 日アクセス)
 - 20) Haruhiko Okumura. https://twitter.com/h_okumura/status/948136760998948864
 - 21) 神崎洋治. MR 技術を医療に応用 世界初の歯科治療 MR シミュレーションシステムの意義としくみ. <https://robotstart.info/2017/04/28/mr-dental.html>(ロボスタ ウェブサイト、2018 年 5 月 15 日アクセス)
 - 22) Khanna S. Artificial intelligence: contemporary applications and future compass. Int Dent J. 2010;60(4):269-272.
 - 23) 西田佳史、北村光司、今井健太、山中 龍. 人工知能とビッグデータを活用した子どもの事故による傷害の予防. チャイルドヘルス 2017 ; 20(4) : 281-285.

G. 研究発表

1. 論文発表

なし

2. 学会発表

なし

保健医療福祉行政における人工知能応用に関する研究

国保データベース事業における AI・BI・RPA 活用

研究分担者 神谷 達夫[†]、岡本 悦司[‡]

([†] 福知山公立大学 地域経営学部 医療福祉経営学科 教授)

([‡] 福知山公立大学 地域経営学部 医療福祉経営学科 教授)

研究要旨

保健医療福祉行政においては、データの収集・整理・分析に膨大な手作業が発生している。近年著しく発展した人工知能(AI)技術の応用による効率化が期待されるが、行政内部の業務は一般に公開されておらず、効率化の検討が進んでいない。

そこで本研究分担では、各地方自治体が関わる国民健康保険に関するデータベース関連業務を取り上げ、ケーススタディとして、人工知能を活用した効率化を検討した。そのために、北近畿の地方自治体における国保データベース(KDB)に関わる介護保険課、健康課、保険医療課等を対象とした業務実態の調査を行った。また、これら業務への応用が可能な AI 関連技術について、動向調査を行ったうえで、適用可能性を検討した。

6自治体を対象とした調査の結果、組織で導入している情報システム上のデータと個別業務で使用している Excel データとが 2重化している問題が明らかとなった。また、手作業による業務効率の改善余地が複数認められた。また、10年間に渡り保存されていたレセプトデータが十分に活用されていない事例が認められた。

AI 関連技術の導入によって、業務効率の改善と各種課題への対応が期待される。ただし、現時点では導入に際したコストが高い。さらなる実態調査と、具体化に向けた作業、システムの低廉化に向けた施策が望まれた。

A. 研究目的

我々は、2016年度より保健医療福祉計画に資するデータウェアハウスの構築とその運用の高度化に関する研究に取り組んできた[1]。その過程を通じて、保健医療福祉に関するデータの収集・整理・分析には膨大な手作業が発生していることが分かった。例えば、各県ごとにまとめられた保健所からの統計データのまとめ方が県ごとに異なっており、それをデータウェア

ハウスとして活用するためには、手動によるデータ整理に膨大な時間を要するといった問題を経験した。

このような問題の解決のためには、AIによる自動化が効果的である。そこで、本研究分担では、自治体における保健医療にかかる情報の有効活用の阻害要因(条例の法的制約、PC活用上の技術的制約、労働力の不足等)を調査し、手動による非効率なデータ処理の問題を AI 技術によって解決できるかを検討した。

実際の研究に際しては、ケーススタディとして、国保データベース(KDB)の関連業務を取り上げ、調査するものとした。KDBは地域包括ケア推進のための有力なツールとして期待されており、国は市町村による積極的な活用を推奨している。現在、団塊世代が全て後期高齢者になる2025年を目指して、要介護状態になっても施設入所せず自宅等で生活し続けられる「地域包括ケア」が市町村の設置する地域包括支援センターを中心に進められている。しかし、KDBは十分に活用されていない実態が先行研究[2]で明らかになっている。KDB普及の阻害要因には、個人情報保護条例の法的制約、PC活用上の技術的制約、労働力の不足等が考えられる。今年度は、この阻害要因を解決するためのAI技術の応用に向けて、北近畿の自治体におけるKDB関連部署の業務実態を調査した。また、これら業務への応用が可能なAI関連技術について、動向調査を行った。

B. 研究方法

自治体における情報の有効活用の阻害要因(条例の法的制約、PC活用上の技術的制約等)は定型的なアンケート調査では把握できず、担当者より直に聞き取ることが不可欠である。そこで、北近畿市町村のKDB活用の実態とその制約要因を訪問することによって実際にデータ処理を担当する職員よりヒアリングすることで明らかにする。さらに、ヒアリングで明らかになった活用状況から、AI技術導入による業務効率化を検討する。

調査対象としては、京都府及び兵庫県北部にまたがる10市4町を想定したが、時間的制約等から6市を訪問し、KDBに関係する部署(主に、国民健康保険、介護保険(後期高齢)そして保健の3部門)の実際に端末を操作している職員から扱うデー

タの内容、業務量等についてヒアリングを実施した。

対象市には事前に研究の趣旨説明書ならびに依頼状(末尾に示す参考資料)を送付し、対象市がヒアリングを受けるのに適任の職員を選択ならびに3課の時間を調整し、ヒアリングをセッティングした。

対象となったのは、主に3課の事務職や保健師であった。課長等の管理職も同席することが多かったが、内容が実務的なものであったためヒアリングの回答は現業に携われる職員が中心となることが多かった。録音は行わず、著者らが理解した範囲で筆記記録した。時間はいずれも2時間弱であった。

現状のAI技術の動向調査に際しては、文献調査、展示会(「医療・介護総合 EXPO」、 「AI業務自動化展」)での調査、セミナー参加(「世界のAI技術」)に拠った。

C. 研究結果

a) ヒアリング調査結果

● A市(約3万人)

A市では、KDB端末は市民・国保課、高齢者支援課に各1台配置されているが、保健推進課には配置されていなかった。また国保課と高齢者支援課とではログオンIDを別となっており、国保課は介護保険レセプトを閲覧できず、高齢者支援課は国保レセプトを閲覧できないように設定されていた。保健推進課にはKDB端末がなく、代わりに両備システムズ社から購入した「健康カルテ」システムを使用し、特定健診もがん検診データも一体的に分析していた。

特筆されるのは、「健康カルテ」の他に FOCUSと呼ばれる医療費分析ソフトを導入している点であり、国民健康保険団体連合会より毎月提供されるレセプトデータ(csv形式で提供されるためA市では「突合

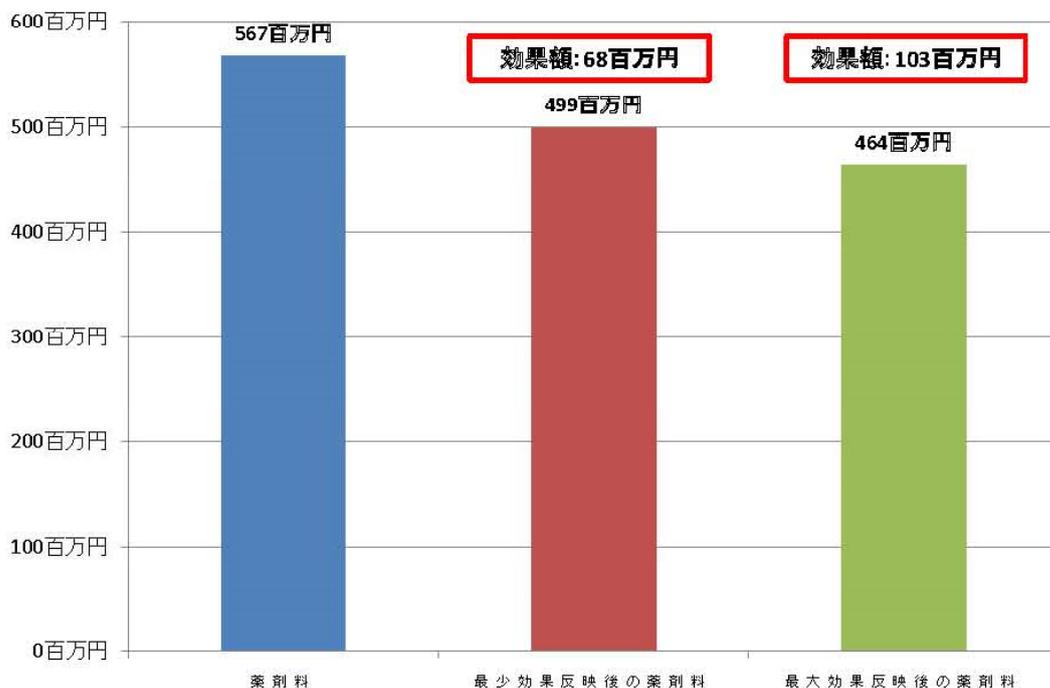


図1 「FOCUS」の出力例

(出所「医療費分析ツール FOCUS」図表 75 ジェネリック医薬品の切り替えによる効果額)

csv」と呼ばれていた。また別名レセ電コード情報とも呼ばれる)を毎月分析している点である。突合 csv の内容は、訪問先の画面上で確認したところ、電子レセプトの内容そのものであり、診療行為や医薬品の内容が全て含まれていた。しかしながら、レセプトデータのかたちは複雑なのでその分析には特別なスキルが必要となる。両備システム社の FOCUS はその分析のためのシステムであり、A 市はそれを使用して、例えば、データヘルス計画のデータを作成していた。図 1 は、A 市が 2016 年 3 月に策定したデータヘルス計画書の一部であり、国保被保険者が現在ブランド品で処方されている薬剤のうちジェネリックのある製品についてジェネリックに切り換えた場合に医療費がどれだけ削減されるか、を推計したものである。こうした高度な分析は、KDB では不可能であり、A 市は KDB を超える情報活用を行っているといえる。

この FOCUS 利用のためには、府国民健康保険団体連合会より送付されてくるレセプトデータの DVD を FOCUS システムにアップロードしなければならない、その作業は国保課職員が直に行っている。ただ、その作業量はわずかで業務負担にはなっていない。

京都府国民健康保険団体連合会は府下市町村に 2009 年 1 月より一貫して DVD にてレセプトデータを提供しているが、その多くは死蔵され活用されておらず、今後の課題といえる。

A 市は FOCUS という分析用ソフトウェアを導入したため、KDB より高度な分析が可能となっており、保健推進課においては KDB 端末がなくても支障ない状況となっていた。ただ、この FOCUS による分析は誰でもできるというのではなく、全ての機能を活用するためには、納入元企業の支援が必要となる。また、A 市以外の京都府で連合会から送られてくる DVD を十分

に活用しきれてはならず、この部分への AI 導入検討は有意義であると考えられる。

一方、A 市では、高額医療費、還付請求、療養費等の手入力、帳票入力、金額のチェックが発生しておりこの分野の AI による効率化も検討事項である。

● B 市（人口 8 万人）

KDB 端末は 3 課全てに一台ずつ配置されているが、閲覧できる範囲は個人情報保護条例を管轄する総務課が決定している。健康づくり課の端末では、KDB の全情報(特定健康診査・保健指導、国保レセプト、介保レセプト)が閲覧可能となっている。2017 年 12 月までは後期高齢者レセプトは閲覧できなかったが保険医療課に依頼して後期高齢者レセプトも現在では閲覧できるようになった。しかしながら、高齢者支援課の端末は後期高齢者のレセプト(そして介護保険レセプト)は閲覧できるものの、国保レセプトは閲覧できないように設定されている(後期高齢者のレセプトは 2015 年度分以降)。このため 65～74 歳の前期高齢者における介護予防の評価において、KDB だけでは困難とのことであった。また、A 市のようなレセ電コード情報の提供も受けていない。

B 市内には地域包括支援センターが 7 つ(うち直営 1、残りは委託)あるが、KDB を地域ケア会議に活用したりはしていない。ただ、担当地域ごとの特性は KDB で出せるのでセンター関係者に提供はしている。7 つの地域包括支援センターの情報は、システムリサーチ社製の管理システムが 2011 年より事実上「電子カルテ」のように使用されており、そのデータは本所において集約されている。ただし、地域包括支援センターが提供するものは、市町村が独自事業として軽度者(要支援者等)を対象に実施される「総合事業」のみであり、管理シス

テムが管理するのもこのデータのみである。通常の要介護者にサービスを提供する通常の介護サービスについては、それぞれの事業者が独自のシステムを使っている。

したがって、地域包括支援センターの情報システムは市が提供する「総合事業」のみであり、医療保険レセプトは参照できない。B 市の地域包括支援センターでは上記のように KDB が活用できないので、投薬内容がどうしても必要な場合には主治医を訪問しての面談を行うことさえある。

保健センターの健康管理システムにおいて、特定健診やがん検診等のデータは保健センター独自の健康管理システムで管理されている。個別検診の結果は、医療機関から紙で提出されるため、担当職員を置いて手入力している。正確を期すため読み合わせも行っており、事務負担は少ない。また、健康管理システムでは、分析のためにクロス集計を出力しているが、この出力は紙出力であるため、さらなる検討のために Excel に手入力により再入力している。この入力の際に打ち間違いが発生し、修正が発生している。

上記のことから、B 市では、情報システム間のデータ移行や帳票の入力を効率化しうる AI 技術の導入が考えられる。

● C 市（約 2 万人）

KDB 端末は関係 3 課全てに配置されている。

介護保険課では KDB を使用するのは個人情報の閲覧より専らデータ集計に使っている。個人を特定する必要のある現金給付、補足給付(介護保険施設における室料、食費は自己負担が原則だが低所得者に対するの給付)そして受給者台帳は、KDB ではなく自治体の情報システムである LGWAN を使用している。LGWAN(Local Government Wide Area Network)は、インタ

ーネットからは独立して設計・運用されている地方自治体を中心とした行政機関専用のネットワークであり、地方公共団体情報システム機構(J-LIS)により運用されている。

地域包括支援センターは市役所内部に設置された直営センター一つのみである。地域ケア会議も開催されているが、通常、ケアマネージャーが自身の担当する要介護者についてのカルテ等を提供して議論されている。

KDB に含まれる投薬情報等を提供することは個人情報条例の制約もありできず、またケアマネージャーから投薬内容を知りたいといった要望はない。

健康課での活用では、特定健康診査・保健指導データは連合会とオンラインで直にやりとりされている。健診は集団と個別があり、集団は兵庫県健康財団に委託されており、健診結果が財団から DVD で提供され、それを連合会にオンラインで提出している。個別健診も公立八鹿病院はじめとして個人診療所でも多くはオンラインで提出している。しかし、データには事務的ミス(ID の間違い等。医学データではない)が含まれており、エラー訂正が必要となり、それが不可欠の作業となっている。

がん検診は ATLAS 社製「健康家族」で管理している。先述の兵庫県健康財団は特定健康診査・保健指導データについては連合会提出用と「健康家族」用の二つの DVD を作っている。件数では財団委託の集団健診が半分以上を占めている。しかし個別健診については全て手入力であり、そのために雇用する職員は1ヵ月3人日程度である。

がん検診の結果は、県保健所を介して県に報告されている(それが健康増進事業報告として e-stat で公表されている)。「健康家族」に入力された内容は管轄する朝来保健所がチェックする。健康増進事業報告は

Excel で提出されているので数字が一致しないと入力できない。

がん検診で大きな作業となるのは、前年度に要精密検査とされた者について、その後の追跡調査をして報告しなければならないことである。健康財団や公立八鹿病院等は要精密検査とされた者について追跡調査も行っている。しかし、その他の要精密検査者については保健師が電話等で問い合わせたりして人海戦術で把握するしかない。乳がん、子宮ガンの検診の案内は、Excel で作った表から差し込み印刷で発行しているが、何十人程度の作業であれば、紙ベースのみでの作業もある。

保険医療課での情報活用といえ、ほとんどレセプト点検や資格管理といったもので、それも KDB ではなく国保総合システムで行っている。他の業務も兼任ではあるが、ベテランの臨時職員が1人おり、この職員の能力が高く多重投薬を見抜く等の実績を上げている。

C 市におけるヒアリング調査で分かったことは、データのチェックなどの事務作業が問題となっているようであったことである。また、がん検診に関しては保健師の努力により要精密検査が把握できていることである。保健師は、事務作業よりも本来業務が重要であるため、あまり多くない手作業であっても、自動化できるような AI システムが望まれる。一方、国保総合システムのデータは活用されているが、その内容を読み取れる人材は限られるため、テキストマイニングなどを用いたエキスパートシステムに有用性があると考えられる。

●D市 (約6万人)

KDB 端末は国保医療課に1台あるのみで、他2課には無く、健康課は国保医療課

のものを共有している(IDも共通なので全データが閲覧可能)。しかし、介護保険課は全くKDBを活用していない。また、後期高齢者レセプトは契約していないため、KDBにこの機能は入っていない。データヘルス計画策定時に契約を検討したが、データを活用しなければ無用であるためということで契約はしなかったとのことである。市内の後期高齢者は約1万1500人であり、うち通院しておらず健診の対象となるのは6700人位で、実際の検診受診者は500人くらいなので不要と判断したようである。

京都府のように国民健康保険団体連合会から市町村に電子レセプトデータの全体を提供する「レセ電コード情報」あるいは「突合csv」等については全く知られていなかった。

国保医療課では、データヘルス計画策定業務をデータホライゾン社に委託したが、その基となったデータはKDBではなく、県国民健康保険団体連合会より直に提供を受けたデータである。兵庫県国民健康保険団体連合会は、2012年度のKDB導入以前から独自のシステムを有しており、現在は従来のシステムとKDBが併存している。

連合会システム端末は、市役所内の専用室内に4~5台あり、専らレセプト点検を委託しているメディケア社の社員がレセプト点検のため使用している。D市に限らず兵庫県では県下全市町村がレセプト点検を外部委託している。レセプト審査による査定率は請求点数の約2%位で、委託費と比較すると収支はほぼ平衡している。

一方、県連合会システムはKDBとは異なりcsvファイルとしてデータを出力できず、独自のデータ分析に活用することができない。

健康課では、特定健診で受診勧奨が必要

と考えられる(たとえば高血圧II, III度, HbA1c>7%, 慢性腎臓病等)者の受診状況、投薬内容、眼科受診の有・無等を把握するためレセプトを活用するがKDBより使いたなれた県独自システムを使う方が普通である。

がん検診の要精密検査者の追跡調査は大がかりな作業であるが、D市の人口規模と人口移動の少なさのため、ほぼ100%把握している。たとえば、胃がんは約3500人の受診者があるが、その7~8%が要精密検査となり、約250人が対象となる。それをそれぞれの地区担当の保健師が電話や問合わせで把握している。

また、肺がんは6500人で約5%が要精密検査となるが把握率は90%以上である。大腸がんでは、要精密検査とされながら便潜血を痔だと思い込んで放置している人が少なくないのは問題と認識している。一方、兵庫県はがん検診受診率が低いので、県は独自に市町村国保に対する調整交付金の算定にがん検診受診率を加味している。

がん検診のデータ管理はATLAS社製「健康家族」を使用しているが、D市で使用しているバージョンは、健康増進事業報告の様式は作れないので専らExcelで処理している(6町合併時に「健康家族」に統一した)。集団検診を委託しているJA、健康財団は最初から健康増進事業報告の様式にあったかたちでCD-ROMで提出している。なお集団検診は75歳未満の国保加入者のみで後期高齢者は医師会に個別検診として委託しており、それらは全て紙報告なので200件くらいを手入力しなければならない。このようにExcelと健康家族に二重に入力しなければならないのは負担である。

介護保険課では、KDBの端末がないので、KDBは全く使われていない。地域包括支援センターは3か所あり、うち1つは

直営であるが、IT活用はまったくない。

地域包括支援センターの業務のひとつは要介護認定であるが、新規申請や変更申請については市が直接訪問調査等を行い、更新申請については、その被保険者担当のケアマネが行っている。

介護保険レセプトデータは県国民健康保険団体連合会より送られてくるのでさくら KCS 社製システムに取りこんで管理している。要介護認定データは厚生労働省の介護保険総合 DB への報告を行っているが、それは「要介護認定ソフト 2009」より直接送信している。

D市のヒアリング調査で分かったことは、データが情報システムと部署独自の Excel との 2 重管理になっていることや、保健師の手作業による管理が存在することである。また、IT 非活用の部門も存在し、AI 等を用いた IT 活用による業務の改善の可能性は大きいと思われる。

●E市（約8万人）

KDB 端末は 3 課に一つずつ配置されているが、閲覧できる範囲は本庁の国保係が課によって異なるように設定している。閲覧範囲は、KDB 導入時に担当課と協議して決定したとのことである。

市民課国保係は全体の権限を握っており、後期高齢者レセプトも含む全データが閲覧可能である。健康増進課国保保健係(特定健診を担当)はレセプトについては集計結果のみ閲覧可能であり、個々のレセプトそのものは非表示となっている。個々のレセプトが必要な場合、本庁に問い合わせることになっている。

高年介護課には端末は有るが「使っていない」とのことで、別システム(県連合会のシステムか)の方をよく使っている。

国の介護保険総合 DB への要介護認定デ

ータの送信は「要介護認定ソフト 2009」より毎月直接 csv ファイルとしてアップロードしている。要介護認定調査票は特記事項等 OCR で読み込めないデータがあり約 25 人の調査員(嘱託)が手入力している。この作業は、外部委託しておらず、10 年前より続けているということであった。

健康増進課の検診業務では、がん検診は集団検診が主で、兵庫県健康財団に委託するのみである。健康財団は、検診結果等をデータ入力して提供する。

特定検診では、個別検診が主体であり、主に医師会委託となっている。データは、医師会がとりまとめて「特定健診データ管理システム(富士通社製)」という KDB とは別個の市役所におかれた端末を使って兵庫県国民健康保険団体連合会に送付している。

健康増進事業報告もデータ管理システムでより送信しているが、兵庫県は健康増進事業報告とは別に「がん検診実施状況調査」も実施しているが、その両者の項目が異なるため、類する作業であるにも関わらず、システムから自動で処理することができず、担当保健師がこの作業を受け持ち、保健師の負担となっている。

E市では、現在のシステムが概ね問題なく動作しているようであるが、OCR で読み込めないデータの手入力や健康増進事業報告とがん検診実施状況調査の作業重複による作業量の増加が AI の利用によって効率化できるのではないかと思われる。

●F市（約8万人）

KDB 端末は保険課と健康増進課(保健福祉センター内)に各 1 台あるが、介護保険担当の高齢者支援課や地域包括支援セン

ターにはない(従って地域包括ケア等には活用されていない)。閲覧可能な範囲は保険課の端末は全て閲覧可能であるが、健康増進課の端末では、レセプト情報が閲覧できないように設定されている。

また後期高齢者分のデータは F 市の KDB には含まれていない。それはデータの提供が受けられないため、個人情報保護条例の制約のためである。ヒアリング中に、F 市の個人情報保護の制約は周辺市町村に比べても厳格という見解があった。ただし、個人情報保護審査会はあくまで市民より開示請求があった場合に開示の可否や範囲を審議する機関であって、市が独自に KDB やレセ電コード情報を分析するにあたって個別に審査会の承認が必要というわけではない、とのことであった。

保険課では、「レセ電コード情報」というレセプトデータ(A 市における突合 csv)は、2009 年 1 月より現在まで府国民健康保険団体連合会より提供されているが、そのまま保存されていて、全く活用されていない。「今年より国保が府に移管されるため、府が市に代わって分析を行ってほしい」という要望が担当者より聞かれた。

医療機関から提出されたレセプトは国民健康保険団体連合会に設置された審査委員会で審査されるが、その内容を再チェックする「レセプト点検」は保険者の業務であり、F 市保険課にも以前レセプト点検担当の「レセプト係」があったが、現在ではレセプト点検も連合会に委託するようになったため、F 市保険課の業務からレセプト関連の業務はなくなった。

健康増進課は、がん検診、特定健診等のデータを両備システム社の「健康カルテ」で管理している。2007 年度に近隣 3 町と合併した際にひとつの町が使用していたことから全市でこの「健康カルテ」を使用

するようになった。当初は V6 だったが現在は V7 を使用している。特定健診では、個別健診は府医師会に委託しており、医師会は健診結果を XML 化してデータ提出する。しかし、大腸がんは年間 2000 件くらいの検査結果を手入力している。この入力には臨時職員をあてている。乳がん(約 1000 件/年)、前立腺がん(約 1300 件/年)も含め OCR 入力を採用しているが、OCR で読み取れない場合に対応が必要である。また、乳がんなどは受診者が比較的若いので OCR に問題は発生しにくい。高齢者を含む検診の場合は OCR で読み取れない場合が多い。OCR の作業には兼任の臨時職員 4~5 名があたる。この時に予防接種の入力と重なると、端末が混雑し、時間を分けて端末を使うなどの配慮が必要となっている。

F 市でも、検診結果の手入力や OCR 入力結果の修正が発生していた。この部分の業務効率改善は、他の分野でも共通するところであり、他の分野で有効なツールの導入も有効であろう。一方、今回の調査で多量のレセプトデータが活用されずに保存されていることが分かった。これらのデータは、有効に活用すると保健医療に対して大きな影響を持つと考えられ、AI 技術等を用いたデータの分析支援などの導入が有効ではないかと思われる。

b) AI 技術の動向調査

自治体へのヒアリング調査と共に、今年度、AI 技術の動向調査を行った。ただし、本研究分担は AI 技術を活用した保健医療行政の改善を主眼としていることから、厳密な AI 技術の現状調査だけではなく、業務の効率化に資する AI の関連技術一般を含めて調査の対象とした。

AI の分類

近年注目されている AI 技術は、機械学習を基盤としたものが中心であるが、AI 技術は、50 年以上前より研究がなされており、さまざまな技術が存在してきた。ここでは、機械学習技術を用いた AI 以外を、従来型 AI と称するものとする(図 2)。

こうした従来型 AI には、推論エンジンやエキスパートシステムが含まれ、一部実用化しているものもある。推論エンジン応用の代表例である Prolog 言語は、現在でも一部の用途で用いられている。また、機械学習型 AI の成果を取り入れたエキスパートシステムも開発されており、機械学習型 AI との連携・融合も盛んになると考えられる。一方、市販製品の中には、こうした従来型の AI に加えて、AI とは呼び難い単純なプログラムに対しても AI と呼称している場合が存在する。AI という用語の乱用は、各種の議論が混乱する原因ともなっていると考えられる。

機械学習型の AI には、統計的機械学習と深層学習が含まれる。

深層学習は、多段のニューラルネットワークを用い、そのニューラルネットワークの係数を機械学習によって決定する。近年の AI ブームは深層学習型の AI によるアプリケーション(主に画像処理分野)の成功がきっかけとなっているため、AI という用語と深層学習を含むと思われるケースが出てきている。しかし、AI 技術の導入の判断する人材を育成する場合には、AI 技術は深層学習のみではないと十分に伝える必要がある。

統計的機械学習は、回帰、分類を統計的に行うものである。このため、使用する手法はデータマイニングと共通するものがあり、近年 AI 技術者とデータサイエンティストが混同されることがある。ただ、回帰系のアルゴリズムにも、ニューラルネット

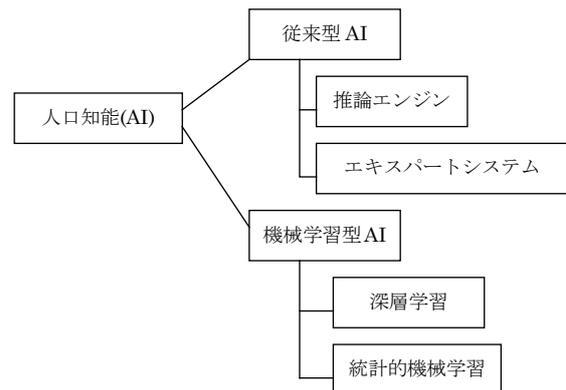


図 2 AI 技術の分類

ワークを用いたものがあり、統計的機械学習であってもニューラルネットワークが全く関係ないわけではない。

統計的機械学習と深層学習とでは、必要とする計算機の能力にも大きな違いがある。深層学習は、統計的機械学習より多くの計算が必要となる。このため、深層学習のためには、GPGPU¹を用いることが多くなっている。調査した展示会(医療・介護総合 EXPO、AI 業務自動化展)では、2 社の AI 用コンピュータが展示されていたが、2 社ともコンピュータゲーム用 GPU を搭載していた。専用ハードウェアも開発されているという報道もあるが、その内容は行列やテンソルが高速に計算できるシストリックアレイであり、GPU や他の計算アクセラレータと大差のないものと考えられる。

深層学習の開発基盤は、現在のところ Google 社の TensorFlow が有力である。ただ、TensorFlow は低水準なライブラリであるため、その上位として Keras が用いられることが多い。

一方、統計的機械学習では、scikit-learn が普及しており、小型のコンピュータでも実行させる例が公表されている。

¹ GPGPU (General-purpose computing on graphics processing units): GPU の演算資源を画像表示以外に用いるもので、行列計算等に応用される。

深層学習においても統計的機械学習においても、プログラミングには Python 言語が用いられている場合が多く、AI の導入を検討する人材を育成する場合、ある程度 Python 等のプログラミング言語の知識に対する理解が必要である。

RPA

近年、業務の効率化のために RPA を導入できないかという議論が増えている。RPA とは、**Robotic Process Automation** を意味しており、コンピュータ上のソフトウェアとして実現されたロボットによる業務自動化の取り組みを指す。

RPA は、一般的に Class1 から Class3 に分類される。この Class 分けには、多少の定義の揺らぎはあるが、大まかに、Class1 は、定型業務を決められた手順通りに実行するアプリケーションソフトウェアの自動実行を実現する。Class2 になると、変化に対応することができ、Class3 になると意思決定の機能を持つとされている。したがって、現在の AI の定義では AI に含まれるのは Class2、3 である。しかし、Class1 であっても有用である場合がある上に、現在の RPA 製品は Class1 に若干の Class2 の機能を加えたものであり、業務の効率化にとっては、Class1 製品も重要な検討項目となる。AI ブームの影響から、低いクラスの RPA を AI の一種であるとして販売する例も見られるため、混同を避ける必要がある。

展示会等で展示されている RPA 製品のなかには、厳密には RDA (Robotic Desktop Automation) と分類されるべき製品が含まれている。厳密な定義のうえでは、RPA は、サーバー上でも実行される自動化ツールを指し、ユーザの操作画面であるデスクトップのみを対象とした自動化は、RDA に分類される。ただし、現行製品においては、RDA であっても RPA として販売されているこ

とから、販売上、両者の差は明確となっていない点に注意を要する。

現在の RPA 製品は、アプリケーションに与える指令をフローチャートで記述するのが主流となっている。一部、プログラミング言語で指示内容を記述できるソフトウェアも存在するが、基本的にプログラミングのできない人を対象にすることが多いことから、フローチャートを利用した RPA 製品が多い理由であると推測される。

低機能な RPA(RDA)製品には、画面上の位置を柔軟に指定できないものがある。その場合、特定の画像を探し出して、その位置からの相対位置で操作する対象の座標を指定するような製品が主流である。

今後、ホワイトカラー業務の自動化・効率化には RPA あるいは RPA 類似のソフトウェアの導入が進むと思われる。この時に、フローチャートによる動作指示が使われる可能性が高いため、AI の導入を検討する人材を育成するためには、フローチャートの教育も必要であろう。

帳票のデータ化

展示会(AI 業務自動化展)では、帳票のデータ化を自動化するシステムの展示があった。本研究での自治体へのヒアリング調査においても、帳票の入力業務が存在した。現在の帳票入力システムは、高価であるため、小規模な用途には向かないが、このようなシステムが安価になれば、保健医療関係の業務の効率が改善されるものと期待される。

ナレッジマネジメントシステム

組織内で作成された文書を自動的に管理するナレッジマネジメントシステムが開発されている。機械学習を用いてテキストマイニングなどが実用化したため、可能となってきたシステムであり、組織の文書

管理には役に立つと考えられる。AI の導入を検討する人材を育成するためには、このナレッジマネジメントシステムのような AI 応用技術の例も知っておく必要があると考えられる。

BI ツール / BI システム

ナレッジマネジメントシステムが主に文書の管理に使われるのに対し、蓄積されたデータをまとめて分析するのが BI (Business Intelligence) ツールである。BI ツールには、AI ではない機能も多く含まれるが、統計的機械学習を活用した分析機能も含まれている。これらの中には、保健医療に対しても有用な機能が存在する。例えば、地域ケア会議に使用するデータの分析を既存の Excel よりも簡単に作成できるようにすれば、保健師の業務を効率化することにつながるであろう。

D. 考察

今回の訪問ヒアリングを通じて、京都府と兵庫県はレセプトデータの電子化については先進県であることが明らかになった。兵庫県では、以前より独自の情報システムを有しており、結果として KDB と県独自システムとの二重構造になっている。システムの統一には費用と時間がかかるため、2つのシステムの連携に RPA の導入が考えられる。

京都府においては、KDB が構築される前の 2009 年頃から府国民健康保険団体連合会より電子レセプトデータ(レセ電コード情報)が市町村に提供されてきた。ただし、このデータの活用はなされておらず、統計的機械学習や BI ツールを用いた分析環境を構築するのは保健医療の発展に資するものである。調査した京都府下の 3 市の状況は以下の通りである。

A 市…レセ電コード情報の提供を受け、ソフトにより分析している

F 市…レセ電コード情報の提供を受け、データが死蔵されている

B 市…レセ電コード情報の提供を受けていない

F 市は 10 年という長期間の貴重なデータを保有しているが活用されていない。レセプトデータは複雑であり、その分析には特殊なスキルもしくはツールが必要となる。

10 年分ものレセプトデータを、たとえば特定健診データと突合することによって分析すれば貴重な知見が得られるであろう。

レセプトデータは膨大であり、三島市(人口約 11 万人)の 5 年間分でも TB 級のサイズとなる。このようなデータの分析には、並列分散処理システムが有効である。

A 市が使用している FOCUS は、有効ではあるが高額である。高額な原因は、販売数が少ないことに加え、運用に販売業者の支援が必要なことにある。また、その他の BI ツールを使うとしても、医療用に修正することと BI ツールが高価であるため、費用的な面で難しいと思われる。KDB に含まれるデータには共通性があるので、BI ツールを共通化することにより低廉化できると思われる。

一方、「国保が府に移管されることより府が分析を代行してほしい」という要望が関係者より聞かれたが、レセプト分析のスキルもしくはソフトがあれば市自らが行うことは不可能ではない。著者の岡本は、国立保健医療科学院において静岡県三島市のレセプトデータを 5 年分程度分析し、特定保健指導の医療費効果の測定等を行った。そうした経験の体系化を通じて、AI 技術を用いた安価な BI ツールの実現と普及が望まれる。

調査対象となった全ての自治体で帳票入力作業が存在した。また、データ入力の手作業が少なからず存在した。場合によっては、データ入力を保健師が担当していることもあり、本来業務への影響が懸念される。多くの部署では、データの整理は業務時間外の仕事となっていた。このような業務に RPA や帳票データ化システム、BI ツール等の導入が有効であろうと思われるが、そのツール類の価格が問題となる。低廉なツールの出現が業務効率化の鍵であると思われる。ただし、現状販売されているシステムは高価であり、小規模な自治体で導入することは難しい。今後、AI 技術の普及が進み、システムの低廉化が望ましい。

E. 結論

本研究分担では、保健医療における AI 技術の応用可能性を検討するため、北近畿市町村の KDB 関連部署のヒアリング調査を実施した。

調査の結果、組織で導入している情報システムと部署や個人単位で使用している Excel データの 2 重化の問題や手作業による業務効率の改善余地が認められた。また、F 市の場合、10 年間に渡るレセプトデータが保存されていたが、このデータが十分に活用されていない結果が明らかとなった。

これらの問題に対して、AI 関連技術は有望な解決策と考えられた。例えば、システム間でのデータ共有や定型的な業務の自動化には RPA が有効である。保健医療行政における各種データの分析には、統計的機械学習などの AI 技術が有効と考えら

れる。また、帳票の入力やデータのチェックにおいても、AI 関連技術は有望な解決策となる。今後、さらなる実態調査と具体化に向けた作業が望まれる。

ただし、現在のシステムは高価であり、小規模な自治体において導入コストを上回るメリットを見出すのはまだ容易でない。今後、関連技術の発展に加えて、低廉化に向けた施策を検討する必要がある。

F. 研究発表

本研究は、平成 29 年度と平成 30 年度の 2 年計画であり、平成 29 年度は研究のための事前調査にあてたため、平成 29 年度は研究発表に至っていない。

G. 参考文献

- [1] 岡本 悦司, 神谷 達夫, 保健医療福祉計画データウェアハウスウェブ上公開に関する研究, 厚生労働科学研究補助金 健康安全・危機管理対策総合研究事業保健医療福祉計画策定のためのデータウェアハウス構築に関する研究, 平成 28 年度 総括・分担研究報告書
- [2] 厚生労働科学研究長寿科学研究開発事業「エビデンスに基づく地域包括ケアシステム構築のための市町村情報活用マニュアル作成と運用に関する研究」平成 26 年度成果報告書. 熊川寿郎(業務主任者), 2015 年 3 月.

参考資料

〇〇〇〇市

国保データベース関係課(国保, 介保, 特定健診等) 御中

保健福祉に関する ICT(特に KDB)活用状況のヒアリング御協力依頼

福知山公立大学北近畿地域連携推進センター(Kita-re)は北近畿市町村のシンクタンク的な研究として今年度, 以下の 2 プロジェクトを推進しています。

センター教員プロジェクト

「北近畿市町村の地域包括ケアへの国保データベース(KDB)活用状況に関する調査」

研究代表者: 岡本悦司

厚生労働科学研究「保健医療分野における A I 開発人材の育成プログラムを策定する研究」

研究分担者: 神谷達夫

国保データベース(KDB), 介護保険総合 DB 等, 市町村の保健福祉に関する情報基盤が急速に整っており, その活用が期待されています。上記 2 研究は, 自治体の ICT 活用を推進するため, 活用状況等について研究者が担当者を訪問して聞き取りをさせていただきたく, 御多忙中恐縮ですが御協力をお願いする次第です。

希望内容

KDB, 介護保険総合 DB ならびに健康増進事業報告(がん検診等)のデータ処理を担当されおられる方と面談し, 活用状況についてヒアリングする(具体的には, 国民健康保険課, 介護保険課そして保健センターのデータ処理担当の方を希望します)

研究成果の公表

北近畿センタープロジェクト・・・プロジェクト報告書として公表

厚生労働科学研究・・・厚生労働科学研究報告書として厚生労働省に提出

〇〇市におかれましては, 〇〇システム社と, KDB から「突合 csv」と呼ばれるレセプト個票データを収集して FOCUS と呼ばれる高度な医療費分析システムをデータヘルスや医療費分析に活用されている, と承っています。北近畿における ICT 活用の先進事例として, 是非担当者よりお話を伺いたく存じます。

近く, 電話又はメールにて連絡をとらせていただきますのでよろしく申し上げます。

福知山公立大学

岡本悦司, 神谷達夫

AIの医療分野への応用による効率化に関する文献調査

研究分担者 福田 敬

（国立保健医療科学院 医療・福祉サービス研究部 部長）

研究要旨

人工知能(AI)の医療分野への応用が医療の効率化・有効化に寄与することが期待されている。そこで本分担研究では、医療用 AI に関する文献調査を通じて、行政の議論や取組を整理し、医療の効率化・有効化のために実用化されている事例・将来的に応用が期待される事例を整理した。

行政の議論や取組については、政府関係機関の議論や取組を取り上げ、実用例については、1) 研究開発、2) 予防、3) 診断、4) 治療、5) ケア、6) 支払請求・保険と、6 種類に分類して整理した。分類した各領域において、AI が医療の効率化・有効化を促進することが可能と考えられることが確認された。

A. 研究目的

人工知能(AI)の医療分野への応用が医療の効率化・有効化に寄与することが期待されている。一方で、そのために求められる医療用 AI 研究に際しては、研究に不可欠となるデータの集積自体にも多くの障害があり、容易なものとは言い難い。

そこで本研究班は、医療用 AI 研究の価値を理解し研究を支える周辺人材の育成と、医療用 AI 研究の応用分野の拡大を通じて、本分野の発展に取り組んできた。

本研究分担は、医療経済学の観点から、とりわけ、医療用 AI が医療経済に与えるインパクトを明らかとすることで、医療用 AI 研究の発展を目指した。そのためには、まずは医療用 AI の研究、議論、利活用の現状や期待を整理する必要がある。そこで今年度は、医療用 AI に関して、行政の議論や取組を整理すると共に、医療の効率化・有効

化のために実用化されている事例・将来的に応用が期待される事例を文献調査した。

B. 研究方法

行政の議論や取組、期待に関しては、インターネット検索(Google)を用い「AI」と「医療」と「報告書」で検索して抽出した。実用化されている事例、将来的に応用が期待される事例に関しては、日本語文献については Google および Google Scholar で、「医療」または「ヘルスケア」と、「AI」または「ビッグデータ」または「機械学習」として検索を行った。英語文献については、Google および Google Scholar において、「medical」または「health care」と、「AI」または「Big Data」または「machine learning」にて検索し、文献収集した。

検索に際して、AI 以外にビッグデータや機械学習といったキーワードを加えた理由

は、近年の AI 分野の躍進がビッグデータと機械学習によって引き起こされたと考えられるためである。

以上の条件により収集した文献から、特に医療や関連業務の効率化や費用への影響、費用対効果といった医療経済的な観点を含むものを抽出し、整理した。

C. 研究結果

前章で述べた方法にて文献を収集し、分類のうえレビューを行った結果を以下に示す。第 1 節では、行政の議論・取組・期待について、行政機関の報告書を取りまとめる。第 2 節では、実用化されている事例・将来的に応用が期待される事例を整理する。

1. 行政の議論・取組・期待

ここでは、内閣府・首相官邸の未来投資会議、人工知能と人間社会に関する懇談会、厚生労働省の保健医療分野における AI 活用推進懇談会、総務省の AI ネットワーク社会推進会議、経済産業省の平成 28 年度我が国におけるデータ駆動型社会に係る基盤整備(医療介護領域における第 4 次産業革命の動向等に関する調査)最終報告書(2017)を取り上げる。

1.1. 未来投資会議[1]

未来投資会議は、内閣府の各大臣と有識者を構成員としており、2016 年 9 月に第 1 回が開催されている。未来投資戦略—Society 5.0 の実現に向けた改革—を打ち出している。「Society 5.0」は、先端技術をあらゆる産業や社会生活に取り入れ、「必要なモノ・サービスを、必要な人に、必要な時に、必要なだけ提供する」ことにより、様々な社会課題を解決する試みである。

Society 5.0 に向けた戦略分野の一つである健康・医療・介護の分野については、新

たに講ずべき具体的施策として、以下のように取り上げられている。

まず、技術革新を最大限活用し、個人・患者本位で、最適な健康管理と診療、自立支援に軸足を置いた介護など、新しい健康・医療・介護システムを構築する。また、オールジャパンでのデータ利活用基盤を構築し、個人の状態に合った効果の高いサービス提供による、健康寿命の延伸と高齢者の自立した生活を実現する。さらに、AI、ロボット等も組み合わせることで現場の生産性を上げながら、高齢化・人口減少下でも質が高く、効率的な健康・医療・介護のサービス提供を可能とするモデルを構築する。こうした仕組みを支えるため、効果的な民間サービスの育成・普及を促すとともに、日本発の優れた医薬品・医療機器等の開発・事業化を進めるとされる。このように、費用対効果も勘案しつつ、基盤構築・制度改革・民間投資促進を一体的に進め、2020 年には新しいシステムを構築し、国民が安心できる医療・介護が 2025 年に国民生活に定着していることを目指している。

1.2. 内閣府 人工知能と人間社会に関する懇談会[2]

本懇談会は、Society 5.0 の実現の鍵である人工知能の研究開発及び利活用を健全に進展させるべく、人工知能と人間社会の関わりについて検討を行うことを目的として、原山優子総合科学技術・イノベーション会議議員を座長として構成されており、第 1 回が 2016 年 5 月に開催されている。人工知能技術と人間社会について、「移動」、「製造」、「個人向けサービス(医療、金融を含む)」および「対話・交流(コミュニケーション)」の 4 つの分野を対象に、倫理的観点、法的観点、経済的観点、社会的観点、教育的観点、研究開発的観点の 6 つの観点から検討をしている。

医療についての検討は以下のものである。まず、倫理的論点からは、人工知能による予測診断が正確になることで消極的な人生になる可能性の他、患者の知る権利、知りたくない権利、医師の伝える義務の再整理の必要性が指摘されている。法的観点からは、個人情報保護の問題やミス責任が医師のみに課せられるのかという問題、医師不在のケースや遠隔診断・治療のケースの法的再検討の必要性の他に、AI技術を用いた人の知的・身体的能力の拡張についての法的制限の必要性について検討されている。経済的論点からは、医療ビジネスが日常的な健康サービスへシフトしていく可能性や、疾病確率が高精度で計算できることで保険が成立しにくくなる可能性が指摘されている。社会的論点からは、AIの新技术により生まれうる格差の問題や社会的コストの配分方法について検討されている。教育的観点からは、AIによる情報について主体的に理解し、自らの意思で判断するリテラシーの必要性が指摘されている。研究開発的観点からは、個人が同定・推定できないような匿名化の方法や本人のみがアクセス可能なプライバシー保護を担保する仕組みの必要性が指摘されている。

1.3. 厚生労働省 保健医療分野における AI 活用推進懇談会[3]

本懇談会は、保健医療分野におけるAIの活用が患者・国民にもたらすメリットを整理するとともに、保健医療分野におけるAIの実用化にあたっての課題を検討した上で、保健医療分野において活用するための対応方策等を策定することを目的として、間野博行国立がん研究センター研究所所長を座長として構成されており、第1回が2017年1月に開催されている。

AIによって、新たな診断方法や治療法の創出、全国どこでも最先端の医療を受けら

れる環境の整備、患者の治療等に専念できるよう、医療・看護従事者の負担軽減の3つを実現するため、AI開発を進めるべき重点領域を6つ選定している。その6つとは、ゲノム医療、画像診断支援、診断・治療支援、医薬品開発、介護認知症、手術支援である。AIの開発を促進する基盤整備とAIの質や安全性を確保するためのルール整備を実施し、全国をカバーした保健医療AIの開発に必要となるビッグデータの収集体制を整備するとともに、AI開発用のクラウド環境も整備・認証する取り組みを行っていくとしている。

1.4. 総務省 AI ネットワーク社会推進会議[4]

本会議は、社会全体におけるAIネットワーク化の推進に向けた社会的・経済的・倫理的・法的課題を総合的に検討することを目的として、須藤修東京大学大学院情報学環教授・東京大学総合教育研究センター長を議長として構成されており、第1回が2016年10月に開催されている。

AIネットワーク化とはAIシステムがインターネットその他の情報通信ネットワークと接続され、AIシステム相互間又はAIシステムと他の種類のシステムとの間のネットワークが形成されるようになることをいう。AIネットワーク化推進に関する国内外の動向や国際的議論のためのAI開発ガイドライン案、様々な分野におけるAIシステムの具体的な利活用の場面(ユースケース)を想定して、AIネットワーク化が社会・経済にもたらすインパクトおよびリスクの評価を行ったうえで、今後の課題を整理している。

また、AI開発ガイドライン案の検討に向けた先行的評価として、AIネットワーク化前の段階にシナリオ上想定される主なユースケースとしては、以下が挙げられている。

- 家庭や介護施設等の様々なセンサーの情報で、健康状態の推定や病気発症の予測
- 患者の症状と過去の症例をマッチングし、該当可能性の高い病名と適切な処置方法提示
- 病歴、遺伝情報等を元に、個人々に応じて自動的にカスタマイズされたサービスの提案

さらに、AI ネットワーク化後の段階にシナリオ上想定されるユースケースの主なものとして、以下が示されている。

- 健康状態の変化に応じて、病院、介護施設などに自動運転車が迅速に搬送
- 医療機関と消防機関等との間において、救急車、病院の受入態勢等についてリアルタイムで調整を行い、搬送及び治療全体のリアルタイムの最適化に向けた提案
- 病院・医師間で必要な医療情報が適切なタイミングで行われ、診察・治療の整合を図る

AI システムを利活用する分野ごとに利用者の視点から評価として、領域横断前の段階にシナリオ上想定されるユースケースとしては、以下がある。

- 持病や病歴、日々の健康状態に合わせて、冷蔵庫・冷凍庫に保管されている食材に応じて、レシピを提案
- ウェアラブル端末からの情報やカメラ画像を元に、健康状態の変化に応じて、病院、介護施設等に自動運転車が迅速に搬送する
- 介護履歴や健康状態を元に、最適な介護プランを提案するとともに、介護ロボットが支援

AI システムを利活用する分野ごとに利用者の視点から評価として、領域横断後の段階にシナリオ上想定されるユースケースとしては、以下がある。

- (医療・介護 + 農林水産 + 小売 + 生活支援)
持病や病歴、日々の健康状態から、健康に良いレシピを提案することに加えて、食材の保管状況に応じて、農林水産事業者や小売業者に自動注文を行い、レシピに合わせて料理ロボットが調理する。また、食材の配送に併せて、生産・流通データ(産地、品種、農薬使用の有無など)が消費者に届くと共に、お薦めの情報がリアルタイムで届く。
- (医療・介護 + 行政 + 金融・保険)
利用者の健康に関する情報(病歴、介護履歴、遺伝情報等)に応じて、関連する行政サービス(手当金・補助等の支援サービス、検診やコミュニティ活動の案内等)の情報を提供し、申請や更新などの手続きを補助。また、利用者の健康に関する情報をもとに、個人々に応じてカスタマイズされた金融サービス(保険等)を提案。

1.5. 経済産業省 平成28年度我が国におけるデータ駆動型社会に係る基盤整備(医療介護領域における第4次産業革命の動向等に関する調査)最終報告書(2017)[5]

本報告書では、海外の技術開発・事業化・法規制等の動向を調査し、我が国の強みや課題を踏まえた上で健康・医療・介護分野のあるべき姿の実現に必要な政策課題を検討している。対象として、IoT/センサー、EHR(Electronic Health Record)基盤、AIによるデータ分析・活用、在宅・遠隔医療、

画像診断、低侵襲医療、人口組織・臓器、創薬の在り方という8つのテーマが選ばれている。アプローチとして、各テーマについて、二次情報調査・インタビューを並行して実施し、現状と進化の方向性を明らかにした上で、課題・政策上の論点を整理している。調査された応用事例については、次節で取り上げる。

2. 実用化されている事例・将来的に応用が期待される事例

大江[6]は、AI技術が医療で活用される可能性のある領域として、医学文献検索、医療画像診断、診療経過や予後予測、治療機器の自動制御などを挙げている。医療分野におけるビッグデータ・ICT・AIの利活用の動向について、とくに創薬については、公益財団法人ヒューマンサイエンス振興財団創薬資源班の報告書[7]でヒアリング調査が行われている。

Tomarのサーベイ[8]では、データマイニングが病院の震源の有効的な管理、病院ランキング、より良い顧客との関係作り、院内感染のコントロール、効果比較研究、患者のケアの質の向上、医療請求の詐欺の減少、ハイリスク患者の認識、健康政策の計画等において役立つと指摘されている。

また、McKinsey[9]は、ビッグデータを活用したヘルスケアシステムの建て直しにより、アメリカでは毎年3,000億ドル以上の新たな価値を獲得する機会があり、その3分の2は国の医療費支出の削減という形であると推計している。

本節では、以下、AIが医療に実用化されている事例・将来的に応用が期待される事例を、医療における研究開発、予防、診断、治療、ケア、支払請求・保険のそれぞれの分野に整理して、紹介する。

2.1. 研究開発

- BERG Interrogative Biology [5]

BERG Healthでは、患者と健常者の検体から大量のゲノム、代謝、脂質・タンパクの構造等の生物学的データを読み込み、個々の患者の服薬した薬剤とその治療結果等の臨床データと合わせて分析している。これによりデータ間の相関から疾患因子を検出し、機序に関する仮説構築に役立てている。これを基に膵臓癌の抗癌剤を開発し、2016年1月より第2相試験の開始に至った。AIによる疾患因子の検出を実際の創薬に役立てた例として先進的な事例であり、従来14年程度を要した創薬プロセスを7年程度に短縮しうると言われている。

- Atomwise [5]

蛋白質のデータバンクから、エボラウイルスと化合物の結晶構造解析結果を抽出し、結合状態に関するQSAR（定量的構造活性相関）を学習するAIを開発している。IBMと共同で行ったエボラ出血熱の研究では、従来の方法では数ヶ月から数年かかるところ、1日もかからずに既存の医薬品7000点がエボラ出血熱の病原体に有効かを調べることができた。

- BenevolentBio [5]

この試みでは、論文等を入力として、疾患ごとに関連する遺伝子や化合物の活性に関する特徴を学習している。そのデータを基に、Janssen社が保有する化合物データと合わせて、有望な化合物が無いかを探索している。

- Numedii [5]

疾患における遺伝子発現パターンデータと、化合物の遺伝子抑制パターンデータを論文から学習し、遺伝子抑制と化合物の構

造的な特徴を抽出している。これにより、既承認薬や製薬企業内の開発中断化合物の中からリポジショニングが期待できる薬物候補、およびその有効性を予測する。最新の臨床データを基に、大手製薬企業の製品・化合物を用いて効率的にリポジショニングが期待できる。

- PrOCTOR [5]

PrOCTOR は、毒性試験を原因として FDA に認可されなかった数百の薬物候補と、承認された薬物のデータを読み込み、各薬物の分子量や標的の特性等、48 の特徴を基に毒性の有無を予測するアルゴリズムを構築している。その結果、FDA 承認された糖尿病薬の有毒性が高いことを予測したところ、実際に当該糖尿病薬の有害事象が報告され、承認が撤回となった事例があった。開発における毒性試験の効率化が期待される。

- Watson for Clinical Trial Matching [5]

患者のうち、治験に参加したことがあるものは全体の 5%程度に留まる。そのため、臨床試験が適切な患者をリクルートすることが出来ず、治験が難航するとともに開発期間の長期化に繋がっていた。そこで、Watson は、公的な治験登録システムや各病院において行った治験の基準とその参加者のデータを入力として、治験への参加基準を機械学習している。これにより、マッチングに必要な情報をカルテから抽出し治験のプロトコルに当てはめることで、適切な治験の候補を提示することが出来る。その際、判断の根拠となるデータや適格性を高めるために変更可能な条件も示すことが出来る。治験のプロトコルは、平均 46 項目あり、患者データ毎に 1 項目ずつ手作業で確認するよりも効率的に臨床試験候補にたどり着くことができる。

- AiCure [5]

AiCure は、スマートフォンのカメラで服薬時の被験者の顔と薬剤を認識することで、服薬行動を動作により確認することができるアプリである。治験実施者は、アプリを通じ、被験者の服薬行動をビデオレビューなしで確認することができる。臨床試験における服薬管理への利用による治験実施者の負担軽減、およびエビデンス取得確度の向上の他、医療機関での導入による治療効果の向上・経過観察の綿密化が見込まれる。

- スパコン「京」によるインシリコ創薬 [10]

AIや分子シミュレーションの技術を駆使したインシリコ創薬において、化合物ライブラリから疾患原因タンパク質と結合する化合物を探索するバーチャルスクリーニング技術や、発見した医薬品化合物候補(リード化合物)に対して活性の向上や副作用抑制を目指して最適化を行うインシリコシミュレーション技術が期待されているが、計算機性能の不足等により困難があった。中津井ら[10]は、スーパーコンピュータ「京」を用いることで、世界最大規模の化合物スクリーニングと、インシリコシミュレーションによる疾患原因タンパク質 - 化合物間の高精度な結合自由エネルギー評価を実現するインシリコ創薬基盤を構築した。インシリコ創薬の研究に、医薬品研究開発プロセスの効率化による研究開発コスト抑制するものとして、期待が寄せられている。

- DPC データによる臨床疫学研究 [11]

DPC (Diagnosis Procedure Combination)データベースは、全国の 1000 以上の施設から収集された入院患者データベースであり、年間 700 万を超える症例数を有する。DPC データは診療報酬明細データベースの一つで

あり、詳細な診療履歴データに加えていくつかの臨床データも含んでいる。このデータベースを用いた臨床研究の成果の一部として、アテローム血栓性脳梗塞患者に対するアルガトロバン療法の効果の推定、彼が成人患者における経静脈栄養と経腸栄養の短期生存率と合併症率の比較、予後熱傷指数の妥当性の検討、という3つの研究が挙げられている。

- Vioxx の副作用発見 [13]

カリフォルニアの Kaiser Permanente は、臨床データと費用データを結びつけて分析することで、医薬品 Vioxx の副作用を発見し、その後の市場から回収させた。

2.2. 予防

- The Hospital for Sick Children [13]

カナダの The Hospital for Sick Children で、ベッドの監視デバイスから得られたバイタルデータを分析することで、院内感染の兆候を従来の方法よりも 24 時間早く検出している。

- The University of Ontario's Institute of Technology [13]

The University of Ontario's Institute of Technology は、IBM と提携して、新生児集中治療室の新生児をモニタリングするプラットフォームである Project Artemis を開発した。これにより、症状が現れる 24 時間前に院内感染の発症を予測することができた。

- The Johns Hopkins School of Medicine [13]

The Johns Hopkins School of Medicine は、Google Flu Trend を利用して、疾病対策予防センターからの警告が出る 1 週間前に、インフルエンザ関連の救急受診を予測した。

- 英国国民保健サービス [13]

英国国民保健サービス(NHS : the United Kingdom's National Health Service)は、全国レベルの研究データベースを構築するために、3年から5年にわたり10万人までのゲノム全体を配列決定する計画を発表した。このデータベースは、臨床医および研究者が癌およびその他のまれな状態の遺伝的原因をよりよく理解する助けとなる。このデータに基づいて、新しい薬剤等を開発することができ、患者はより有効であると思われる標的療法を受けることができると考えられている。

- Aequa Sciences [5]

Cambridge 大学・FN MOTOL 大学病院・Nanjing Drum Tower 病院・Shuguang 病院より収集された患者データを基に、遺伝子検査結果と疾患データを紐付け、疾患毎の遺伝子発現パターンを機械学習している。これにより、各個人の検査結果をもとにアルツハイマー病罹患リスクを予測し、各人に対して健康のために最適なプランを提示する。

2.3. 診断

- コロンビア大学メディカルセンター [12]

脳損傷患者の時系列な生理データを分析することで、各種の合併症が出現してからでなく、その症状が生じる前に適切な対応を実現している。脳動脈瘤からの脳出血患者からは、従来の方法よりも 48 時間早く重篤な合併症を検出するのに役立っている。

- Harvard Medical School と Harvard Pilgrim Health Care [13]

糖尿病と診断された患者の電子カルテを

自動的に解析することにより、1 型糖尿病および 2 型糖尿病の患者を区別できた。このアルゴリズムは、患者に付与された疾病分類コードのみを用いるよりも、患者を効果的に検出することが出来た。

- 臨床診断意思決定支援システム [13]

現在の臨床診断意思決定支援システム (CDSS : Clinical Decision Support Systems) は、患者情報と医学的ガイドラインとを比し、有害な薬物反応などの潜在的な医療過誤を警告する。主要な大都市圏の小児救命救急病院で実施された研究では、CDSS ツールが、副作用やイベントを 2 カ月で 40% 削減した。CDSS は、将来的に、医療画像 (X 線、CT、MRI) の画像診断と画像認識を用いるモジュールや医学文献を自動的にマイニングするモジュールを含めることで、医師に対する助言を自動化し患者ケアを向上させうる。

- 精神神経系疾患診断システム [14]

徳島大学大学院ヘルスバイオサイエンス研究部神経情報医学部門との共同研究で、精神神経系疾患のゲノムレベルのデータを用いた分析によって、うつ病、統合失調症、双極性感情障害等の精神神経系疾患において、良好な識別能力を有する診断システムの構築に成功している。従来では問診による経験的判断でしか診断がつかなかった精神神経系疾患において、エビデンスに基づく診断につながると見込まれている。

- 音声データを用いたうつ病診断 [15]

約 2000 名の被験者を対象として、オンライン調査にてうつ病のスクリーニングに使われている質問票に答えてもらうと共に音声を吹き込んでもらい、機械学習を用いてそのデータを分析した。うつ病の患者は、

脳卒中、心疾患、認知症等さまざまな疾患を発生しやすいことが知られている。うつ病の適切な診断と治療が、うつ病と共に発生しうるうつ病以外の疾患による社会的費用を軽減する可能性がある」と指摘している。

- 心不全検出・分類 [16]

サポートベクターマシン等の機械学習の手法を用いて、心不全の検出や、ディープラーニングを用いた拡張性心不全(HFpEF)や収縮性心不全(HFrEF)等の心不全の病形分類が研究されている。機械学習により、既存の診断および治療支援システムが改善され、コスト削減や結果の向上につながる可能性があることが示されている。

- 医療画像解析のディープラーニングのサーベイ [17], [18]

文献[17]では、脳 MRI にディープラーニングを用いてアルツハイマー病の進行具合を決定するものや、胸部 CT 画像から間質性肺疾患(ILD : Interstitial Lung Diseases)を検出するもの、脳 MRI から HIV 陽性か否か分類するもの等が紹介されている。

その他に、文献[18]は、医療画像解析に関連する主要なディープラーニングの 300 以上の論文をサーベイしている。

- 胎児性アルコール・スペクトラム障害の検出 [19]

胎児性アルコール・スペクトラム障害 (FASD: Fetal Alcohol Spectrum Disorders) に関して、2 次元画像を対象とした顔認識ソフトウェアによる自動的な検知と標準的な手動検査を比較した。その結果、自動化手法がより効率的であることが示され、患者の早期認知が結果の改善を伴う早期介入に繋がるであろうとしている。

- **Imprint [5]**

画面上に表示される画像を見た被験者の目線の動きを用いて、脳の働きを機械学習によって評価している。当初病院で 30 分程度かかっていた診断テストが、在宅で、5 分程度で行えるようになった。また、音声認識による診断とは異なり、言語の異なる各国へのローカライゼーションが不要であることも利点として挙げられている。

- **Enlitic [5]**

CT・MRI 画像等を登録し、ディープラーニングを用いて、悪性腫瘍を検出している。放射線医師よりも 50% 検出力が高く、また手動で 30 分程度かかっていた悪性腫瘍の検出をより早く行えるようになった。現在、オーストラリアで実運用されている。

- **DeepMind for eye [5]**

NHS が管理している大量の眼球スキャン画像を読み込み、失明に繋がる糖尿病性網膜症や加齢黄斑変性等の疾患の兆候を、ディープラーニングによって見出すことを目指して開発が行われている。眼性疾患の確定診断には、従来熟練した医師が複数回スキャンする必要があり時間がかかっていたが、単回のスキャンで迅速に診断することを目指している。

- **DeepMind for radiation therapy [5]**

NHS が管理している CT・MRI 画像を用いることで、癌組織と正常な組織を区別し、放射線照射を計画するシステムを開発している。従来、頭頸部癌の放射線治療における照射対象の計画には 4 時間程度の時間を要していたが、1 時間程度に短縮できることが見込まれている。頭頸部癌は腫瘍部位が複雑であるため、当該疾患の放射線治療

計画技術が確立されれば、他疾患の放射線治療においても応用することができるとしている。

2.4. 治療

- **アメリカの Premier [12]**

アメリカ最大の医療関係機関である Premier には、2700 以上の病院と保健システム、9 万の非急性期治療施設、40 万人の医師の人的ネットワークが含まれる。そのデータベース化により、詳細な比較臨床結果、医療資源の使用率、および取引の費用データを参加者に提供している。これらにより、29,000 人以上の人命が救われ、医療費が約 70 億米ドル削減された。

- **カナダのノースヨーク総合病院 [12]**

ノースヨーク総合病院は、リアルタイム分析を用いて患者アウトカムを改善した。

- **イタリアの Rizzoli Orthopaedic Institute [12]**

遺伝性骨疾患に関してデータ分析をすることで、年間入院患者数の 30% の削減と画像検査数の 60% 超の削減を含む、より効率的で費用対効果の高い治療が実現した。

- **Brigham and Women's Hospital [12]**

手術の成功に不可欠な多数の要因の研究に基づいて、関節置換手術を体系的に標準化した。その結果、より良い治療成績と医療コストの削減に繋がった。

- **ミシガン大学保健システム [12]**

ミシガン大学保健システムは、輸血の管理を標準化し、輸血の必要性を 31%、経費を月 20 万ドル削減した。

- CERによる治療の標準化・最適化 [13]

多くの研究で、医療従事者、地域、患者の医療行為、成果、費用に幅広い変化が存在することが示されている。例えば、Dartmouth Atlas プロジェクトの研究者の中には、プライマリケア医師の中には、同じ診療行為において同僚と比して2倍以上のCT スキャンを施行する医師がいる。比較効果研究(CER: Comparative Effectiveness Research)によって、患者の特性、治療のコストと結果を含む大規模なデータセットを批判的に分析することで、適用する最も臨床的かつ費用対効果の高い治療法を特定するのに役立つ。

- 米国退役軍人局 [12]

米国退役軍人局保健システムは、医療情報技術と遠隔患者監視プログラムの実証に成功した。臨床ガイドラインの遵守やエビデンスベースの薬物治療の割合の上昇において、民間部門より優れた結果を示した。

- 心不全患者のアドヒアランスの予測と再入院の予測[16]

サポートベクターマシン等の機械学習の手法を用いて、心不全患者のアドヒアランスの予測や再入院の予測が行われた。その結果、治療支援システムの改善によるコスト削減を含む、心不全患者の結果を向上させる可能性があることが示されている。

- Faros のプラットフォーム [5]

診療記録から患者の症状、前回の治療方針、治療アウトカムを読み取り、機械学習によって治療方針ごとの期待効果およびコストを評価している。現在、フロリダ州、テネシー州等でメンタルヘルス領域に特化した病院やカウンセリング施設を展開している Centerstone と提携し、アルゴリズムの

精度を向上しており、従来の治療法よりも治療効果を40%向上させ、コストを40%削減している。

- Watson for Oncology [5]

Memorial Sloan Kettering(がんセンター)の医師がスクリーニングした論文等の知識を当初8000時間、その後1年に2000時間学習させた。その結果、構造的・非構造的な患者の診療記録を基に、診断が困難であった癌を識別し、可能な治療オプションを提示しうるまでに至っている。

- Triton システム [5]

手術中に使用した血液の染み込んだガーゼの画像をiPadで撮影することで、機械学習によって画像認識し、出血量・ヘモグロビン量を推計している。iPadという汎用的なモバイル端末を用いて手術中の出血量を推計できる世界初のシステムである。

- 自動縫合ロボット STAR [5]

現在、開発されている手術支援ロボット Smart Tissue Autonomous Robot (STAR)は、AIを搭載し、人間が指定した箇所を自動で縫合する機能を有している。熟練外科医の技術と経験をAIに学習させており、複数のカメラで術野を立体的に捉え、アームの先端に取り付けられた触覚センサーで感触を確かめながらAIが最適な方法を選択して縫合を行う。縫合スピードは現時点で医師の手技に少し劣るものの、施術ミスはより少ない。柔らかい豚の腸を縫合してつなげる実験では、手術全体の60%をSTARが自動的に行い、STARが縫合した箇所は医師と同じくらいの強度で縫合されている。既存の方法よりもミスの少ない低侵襲の治療を早く・低コストで行うことが可能になると期待されている。

- AI 搭載自動採血ロボット Venous Pro [5]

Venous Pro は、赤外線センサーと超音波画像技術を使って、採血を行う静脈の位置を自動で認識し、ロボットにより制御された注射針で採血を行う。現在、開発中であるが、治験や病院での利用により看護師の負担軽減が見込まれる。また、採血を自動化することにより、治験などでの結果を安定化させるとともに、医療従事者の感染症のリスクを低減しうる。

- スマート治療室 [20]

スマート治療室とは、IoT を活用して様々な医療機器をつなぎ、手術の進行や患者の状況を整理してディスプレイに投影することで、医師やスタッフに情報が瞬時に共有されるというコンセプトの手術室である。室内には「戦略デスク」と呼ばれる情報統合表示用高精彩ディスプレイがあり、術中の診断や検査のデータが整理され、統合表示される。また、電気メスも IoT でつながっているため、腫瘍の画像には「どの部分をどれくらい切ったか」という情報がプロットされる。さらに、室外の部屋やほかの医療機関とともに情報を共有することが可能であり、経験豊富な医師によるモニタリングも可能である。このほかにも、スマート治療室では手術の情報を時系列で保存しており、将来的には、よりよい医療の提供につながるものと考えられる。具体的には、ビッグデータの分析によって、手術プロセスとアウトカムの関係性が明確になるなどの効果が期待される。現在、東京女子医科大学と広島大学で試験的に導入されているのみだが、今後、普及していくに従って、医療トラブルの防止や手術精度・安全の向上、ひいては患者の QOL 向上に貢献していくと考えられる。

2.5. ケア

- Suggestic [5]

2 型糖尿病のユーザーが入力した基礎代謝や腸内微生物の有無を含む健康データ、遺伝データに応じて、より適切なレシピや近隣のレストランの料理をチャット形式で推奨する。推奨の根拠は論文やガイドライン、日々の健康データ、推奨に対するユーザーの回答といった複数の入力データを踏まえ、パーソナライズされていく。

- 院内リソース最適化 [5]

Florida Hospital Celebration Health では、収集したデータを分析して病院内の効率化を進めている。具体的には、看護師の動きをトラッキングして、病院内の設備や消耗品の偏り、看護師の負担を分析し、配置や役割分担の改善につなげる等している。

- Dementia Remote Monitoring AI [5]

UCSF Memory and Aging Center の研究者グループは、IoT と機械学習を使った認知症患者の個別継続的な介護を行うためのエコシステムを構築しており、現在費用対効果を測るための臨床試験が行われている。具体的には、生活情報を取得するためのセンサーを患者の自宅各所に配置し、スマートデバイスからも患者の位置や活動情報を取得して、機械学習のアルゴリズムにより患者の生活パターンを学習し、活動の突発的異変・漸次的変化を察知している。患者の QOL を改善するとともに、介護にかかる費用の削減効果が期待されている。認知症患者治療においては、医師の診察の頻度が低い場合に症状が見過ごされ、その後悪化し入院となるケースが多いため、継続的なモニタリングにより入院期間の短縮が図れると考えられている。

- NHS Remote Monitoring Project [5]

認知症患者の自宅の冷蔵庫やカーテンにセンサーを付け、そのセンサーやウェアラブル端末を通じて、患者がいつもの時間に起きて活動しているか、食事をとっているかを機械学習を用いて確認するプロジェクトが実施されている。現在、効果検証中であるが、認知症患者が自立した生活を行う期間を延ばす取組として医療費削減効果が期待されている。また、認知症患者だけでなく、高齢者、視覚障害者に対しても同様のパイロット試験が行われており、介護にかかる費用の削減効果が期待されている

2.6. 請求支払・保険

- チリの医療請求の詐欺濫用検出システム [21]

チリの民間健康保険会社が採用しているデータマイニングに基づく、医療請求の詐欺濫用検出システムを導入した。医療請求は、受療から一定期間内に要求された補助金を承認、修正、または却下といった手続きが少数の医療専門家によって手作業で実施されていた。検出システムは、詐欺濫用の問題に関与する医療請求関連会社、医療従事者、および雇用主のそれぞれに、多層パーセプトロンニューラルネットワークを使用している。詐欺濫用検出システムの導入の結果、毎月約75件の詐欺濫用ケースの検出率を示し、システムなしで検出した場合より6.6ヵ月早く検出するようになった。

- テキサス州メディケイド詐欺・濫用検出システム [22]

テキサス州メディケイド詐欺・濫用検出システムは、データマイニング技術を使用して詐欺や濫用を発見し、1998年には100万ドルを節約した。

- 医療保障の加入者と非加入者の分類モデル [23]

ニューラルネットと決定木を使用して、医療保障の加入者と非加入者を分類するモデルを作成した。分類モデルにより、加入に重要な要因を特定化することで、医療保障格差を縮小させることに使用できる可能性がある。

D. 考察

本研究分担では、行政の議論・取組・期待について、行政機関の報告書を取りまとめ、また、実用化されている事例・将来的に応用が期待される事例を検討した。

内閣府、厚生労働省、総務省、経済産業省等の政府関連機関での議論では、医療分野へのAIの応用により、様々な観点からのメリットが期待されている一方で、AIによる情報を理解し自らの意思で判断するリテラシーが必要といったこれを活用する人材の重要性も指摘されている。

内閣府の人工知能と人間社会に関する懇談会[2]で取り上げられている議論のほかにも、大石[24]は、ビッグデータの活用の際にはデータがすべて電子記録である必要があるため、解析を支える基盤技術として、データ構造化技術、高性能なハードウェア、機械学習アルゴリズム、検索エンジンを要する点を挙げている。また、医療ビッグデータは、情報の性質上個人情報管理には細心の注意を払う必要がある点を指摘している。

AIの医療への応用には課題はあるとはいえ、研究開発、予防、診断、治療、ケア、支払請求・保険の各領域でAIは医療の効率化・有効化を促進することが可能と考えられることが様々な事例で確認できた。限りある資源を用いて、いかに効率的に医療

を発展させていくかは大きな課題であり、AIによって効率化が図れるのであれば将来に向けて期待できる方法である。ただし、AIのシステムやその応用にはさらに投資が必要な部分もあり、追加的な投資に見合う成果が見込まれるかといった費用対効果の観点を検討することも重要であると思われる。

E. 結論

本研究では、医療分野へのAIの応用について、特に医療や関連業務の効率化といった医療経済的な観点から、行政の議論・取組・期待について、行政機関の報告書を取りまとめ、実用化されている事例・将来的に応用が期待される事例を検討した。

AIの医療への応用には課題はあるとはいえ、研究開発(R&D)、予防、診断、治療、ケア、支払請求・保険の各領域でAIは医療の効率化・有効化を促進することが可能と考えられることが確認できた。またこれまでの議論でも、AIにより得られる情報をいかに活用するかといったという観点から、これに関連する人材の重要性も指摘されていた。今後、AIの専門家だけでなく、医療分野でこの応用を正しく推進できる人材の育成が必要である。

F. 研究発表

なし

参考文献

- [1] 首相官邸. 未来投資戦略—Society 5.0の実現に向けた改革—. 2017.
https://www.kantei.go.jp/jp/singi/keizaisai/sei/pdf/miraitousi2017_t.pdf
- [2] 内閣府. 人工知能と人間社会に関する懇談会 報告書. 2017.
<http://www8.cao.go.jp/cstp/tyousakai/ai/>

- [3] 厚生労働省. 保健医療分野における AI 活用推進懇談会 報告書. 2017
<http://www.mhlw.go.jp/stf/shingi/other-kousei.html?tid=408914>
- [4] 総務省. AI ネットワーク社会推進会議 報告書. 2017
http://www.soumu.go.jp/menu_news/s-news/01iicp01_02000067.html
- [5] 経済産業省. 平成 28 年度我が国におけるデータ駆動型社会に係る基盤整備 (医療介護領域における第 4 次産業革命の動向等に関する調査) 最終報告書・事例集. 2017.
http://www.meti.go.jp/meti_lib/report/H28FY/000527.pdf
http://www.meti.go.jp/meti_lib/report/H28FY/000528.pdf
- [6] 大江和彦. これからの医療における AI の活用と課題. 医薬品情報学. 2017; 19 巻; N1-N3
- [7] 公益財団法人ヒューマンサイエンス振興財団創薬資源班. 医療分野におけるビッグデータ並びに ICT・AI の利活用の最新動向—創薬並びに個別化医療・先制医療への貢献の道を探る—. 2017.
http://www.jhsf.or.jp/paper/report/report_201604.pdf
- [8] Divya Tomar. A survey on Data Mining approaches for Healthcare. International Journal of Bio-Science and Bio-Technology 2013; Vol.5, No.5; 241-266.
- [9] McKinsey & Company. Big data: The next frontier for innovation, competition and productivity. 2011.
<https://www.mckinsey.com/business-functions/digital-mckinsey/our-insights/big-data-the-next-frontier-for-innovation>
- [10] 中津井雅彦, 鎌田真由美, 荒木望嗣, 奥野恭史. スパコン「京」によるインシリコ創薬. 日薬理誌. 2017; 149; 281-287.
- [11] 康永秀生. DPC データによる臨床疫学研究の成果と今後の課題. 医療と社会. 2016; 26,1; 7-14.
- [12] IBM. Data-driven healthcare organizations use big data analytics for big gains. 2013.
https://www-03.ibm.com/industries/ca/en/healthcare/documents/Data_driven_healthcare_organizations_use_big_data_analytics_for_big_gains.pdf

- [13]Institute for Health Technology Transformation. Transforming Health Care Through Big Data Strategies for leveraging big data in the health care. 2013.
- [14]石井一夫. 医療におけるビッグデータ利活用ー精神神経系疾患の診断系の開発を中心としてー. 情報処理. 2014; 55, 9; 964-969.
- [15]宗未来, 竹林由武, 関沢洋一, 下地貴明. "声"だけで、うつ病はどこまで診断可能か? ~音声感情認識技術にアンサンブル型機械学習モデルを応用したうつ病スクリーニング機能に関する精度の検証. RIETI. 2016.
- [16]Saqib Ejaz Awan, Ferdous Sohel, Frank Mario Sanfilippo, Mohammed Bennamoun, and Girish Dwivedi. Machine learning in heart failure: Ready for prime time. Current Opinion in Cardiology. 2017; 33, 2; 190-195.
- [17]Kyu-Hwan Jung, Hyunho Park, Woochan Hwang. Deep Learning for Medical Image Analysis: Applications to Computed Tomography and Magnetic Resonance Imaging. Hanyang Medical Reviews. 2017; 37; 61-70.
- [18]A Survey on Deep Learning in Medical Image Analysis. Geert Litjens, Thijs Kooi, Babak Ehteshami Bejnordi, Arnaud Arindra Adiyoso Setio, Francesco Ciompi, Mohsen Ghafoorian, Jeroen A.W.M. van der Laak, Bram van Ginneken, Clara I. Sánchez. Medical Image Analysis. 2017; 42; 60-88.
- [19]Matthew Valentine, Dustin C.J. Bihm, Lior Wolf, H. Eugene Hoyme, Philip A. May, David Buckley, Wendy Kalberg, Omar A. Abdul-Rahman. Computer-Aided Recognition of Facial Attributes for Fetal Alcohol Spectrum Disorders. Pediatrics. 2016; 140, 6.
- [20]横内瑛, 高橋麻理恵, 池田真紀. 医療・介護現場のデジタル化 IoTやAIを活用した医療・介護現場の将来像. 知的資産創造. 2017; 10月号; 12-33.
- [21]Pedro A. Ortega, Cristian J. Figueroa, Gonzalo A. Ruz. A Medical Claim Fraud/Abuse Detection System based on Data Mining: A Case Study in Chile. International Conference on Data Mining. 2006.
- [22]Divya Tomar. A survey on Data Mining approaches for Healthcare. International Journal of Bio-Science and Bio-Technology. 2013; 5, 5; 241-266.
- [23]Dursun Delen, Christie Fuller, Charles McCann, Deepa Ray. Analysis of healthcare coverage: A data mining approach. Expert Systems with Applications. 2009; 36, 2, 1; 995-1003.
- [24]大石健一. 中枢神経画像のビッグデータ解析. 薬剤学. 2017; 77,2; 76-80.

医療用人工知能の研究開発基盤としての 医師学術認証に関する研究

研究分担者

中村 素典

（国立情報学研究所 学術基盤推進部 特任教授）

奥村 貴史

（国立保健医療科学院 研究情報支援研究センター 特命上席主任研究官）

研究要旨

医療用人工知能の開発には医療データを用いた学習と利用者による検証・評価が不可欠である。この学習用データの収集・加工と人工知能による学習および検証・評価の双方において医師の協力が必要であるが、この協力者の確保とデータへのアクセス管理に対して必要なコストが高いことが医療用人工知能の開発における障害となっている。

医師を対象とした学術認証基盤は、この問題への有力な解決策と考えられる。医師学術認証基盤が普及することにより、医師は1つのアカウントで医療用人工知能を含む各種サービスを容易に利用できるようになる。また、医療用 AI 研究者にとっては、協力医師の確保とデータ作成が低コスト化する点で有用性が高い。そこで、本研究分担では、そうした医師学術認証の実現に向けて関係者へのヒアリングと効果的な説明資料の検討を行った。

ヒアリングを通じて、医師学術認証への潜在的なニーズの多さが示唆された。また、説明資料への多くのフィードバックが得られると共に、内容のブラッシュアップを図ることができた。次年度においてもヒアリングを続けると共に、利用者ニーズの更なる確認と広報の充実を図ることが望ましい。

A. 研究目的

人工知能技術の発展に伴い、医療分野への応用が期待されている。しかしながら、人工知能技術の研究開発には膨大な学習データが求められる。とりわけ、医療用人工知能の精度向上には、医師の手による高品質なデータの準備が求められることから、高額な人件費が研究の発展を制約している。また、こうした過程を経て医療用人

工知能の研究開発を進めても、実際の利用促進に際して、何万人という規模に上る医師を対象としたアカウント配布とその管理を行なう必要がある。このような取り組みが重複して行われるようであれば、技術の活用に向けての障害の一つとなることが容易に予想される。

この問題を解決する方法として、公的機関がオンライン上で医師を簡便に認証する共通利用可能な仕組みを整備する手法

実現に向けて

医師学術認証基盤の構築に用いる技術は、どれも国内外にて十分な利用実績のある標準的な技術です。また、このような実現に求められる費用は、それぞれの組織が支出してきた既存予算の組み換えにより賄うことが可能です。最大の課題は、技術予算ではなく、新たな社会基盤を構築する上で、いかに関係機関がコンセンサスを形成するかという点にあります。

そのために、私たちは、このパンフレットを作成し、提案の骨子を説明するとともに、賛同者を募ることにしました。賛同者を募るために、必要に応じて、提案内容そのものも御覧させていただきます。疑問点や検討すべき課題があれば、お気軽にご連絡下さい。また、本企画を、関係する諸機関にぜひご紹介頂ければ幸いです。

プロジェクトロードマップ

医師学術認証基盤を実現するためには、従となるサービスとユーザーを、認証基盤に接続するところからはじめる必要があります。そのために、我々は、ほとんどの新卒医師が参加する「臨床研修マッチング」に活用することを提案しています。これにより、毎年、8000名以上の新規ユーザーが基盤に参加することになり、多くのサービスが開発されるインセンティブとなります。多くのサービスが利用できるようなれば、既卒医師の参加も増えることになるでしょう。

なお、医学部を有する大学のうち、既に半数近くは「学認」参加を果たしています。学認を活用した構成とすることにより、ユーザー数の拡大はさらに有利なものとなります。

初期	発展期	成熟期
ユーザーの増加と開発コスト削減	医師学術認証基盤の普及	AIの発展とユーザーのさらなる増加
06 UMINユーザー増加	06 医師向けサービス充実 05 医療AIの普及促進	02 AIの発展 02 医療用人工知能の利用
04 大学アカウントの利用 07 医療AIの開発促進	01 IDの一本化 03 診療情報変更の簡便化 04 学会員管理の効率化	05 卒業生のキャリア記録 05 ユーザー大増強
	07 ユーザー増加	

提案者について

技術革新が進む人工知能技術の医療応用が期待されています。しかし、医療用人工知能の研究開発にはさまざまな障壁があり、制度的な支援も限定的なものとなっています。そうした課題のひとつが、医療用人工知能の研究開発に関わる人材育成です。

我々の研究班（保健医療用人工知能 技術革新と国際競争力向上に資する人材育成に関する研究班：農村班）は、この問題に取り組み、医療用人工知能研究者と研究者を支える各種周辺人材の育成を目標に研究を続けてきました。その一環として、医療用人工知能の研究開発と普及を支える社会基盤が欠如していることを関係者に啓発する必要性に至り、この企画を開始しました。

研究代表者の所属する国立保健医療科学院は、厚生労働省の所管する国立研究教育機関であり、我が国の公衆衛生に関わる人材育成と学識の探求を目的とした組織です。本提案により、従来の施設に欠けがらであった医療用人工知能の研究開発と普及のコストが低廉化され、医療用情報技術に多様な技術革新がもたらされることを願っています。これは、大規模な技術進歩を促した情報技術の意思を、多くの困難を抱えた我が国の医療と医療現場に役立てていくための基礎となる試みです。

研究代表
国立保健医療科学院 研究情報技術研究センター 農村 賢史
takao@nih.go.jp

医師学術認証基盤 の実現に向けて



平成29～30年度厚生労働科学研究費補助金
医療科学総合研究事業（臨床研究等）基盤構築・人工知能医療研究事業
保健医療用人工知能 技術革新と国際競争力向上に資する人材育成に関する研究班

図1 医師学術認証説明資料(表・裏表紙)

が考えられる。このような「医師学術認証基盤」を利用することで、医師は1つのアカウントで各種サービスを容易に利用できるようになる。研究者は、医師学術認証基盤を通じて協力者の確保と管理を、コストを押さえつつ行えるようになる。

こうした認証基盤は、国立情報学研究所が学術認証基盤「学認」を長年運用してきたことから、技術的には既に完成していると考えられる。しかしながら、実際に医師ユーザーの学術認証を実現するためには、各医師が所属する機関や認証基盤を活用する各活用分野の理解と協力が不可欠となる。そのためには、技術に対する認知と構想に対する賛同を集める必要がある。また、その大前提として、こうした構想が医師や研究者側の潜在的なニーズに合致していることを示す必要がある。

そこで本研究分担では、関係者へのヒアリングを行い、潜在的なニーズ調査を行う。

また、医師学術認証基盤の仕組みとメリットを解説する効果的な説明資料を作成し、ヒアリング結果を元にした継続的な改訂を試みる。

B. 研究方法

医師を対象とした認証技術としては、以前より、政府主導で医師認証基盤の構築が行われてきた。しかしながら、医師認証基盤(HPKI)は、医師が作成する各種書類をオンライン上で安全にやり取りするための公的な電子署名としての利用を目的として設計されている。その結果、信頼性の担保と引き換えに、汎用性や利便性を犠牲とした構成となっている。また、利用に際したHPKIカードの取得に際しては、本人確認書類のほか住民票などが必要とされており、取得までのハードルが高く、普及に多くの時間を要している。

医師学術認証基盤 日本の医療を支える多彩な波及効果が期待される、低コストな情報施策



図 2 医師学術認証説明資料 (見開き)

もし、低コストに配布が可能で、普及率の高い簡易的な医師認証基盤が実現できれば、医師のオンライン認証を通じて、医療用人工知能の研究開発コストを大幅に低廉化できる。さらに、医療用人工知能の普及に要するハードルを一気に下げることが可能となる。こうした特性を有する医師学術認証基盤は、電子認証の有用性の啓発を通じて、より公的な医師認証基盤の普及にも資するものと考えられる。

そこで我々の研究グループでは、国立情報学研究所が運用する「学術認証フェデレーション(学認)」で用いられている ID 連携技術を応用した医師学術認証基盤の構築を構想した。学認は、全国の約 200 の大学等に在籍する学生や教職員を対象とし、既に約 140 万におよぶアカウントを保有している。学認アカウントを利用することにより、1つのアカウントで様々なサービスにログインするシングルサインオンが

実現する。このような情報基盤を医師学術認証にも適用することにより、医師学術認証基盤を低コストに実現しうることが期待される。

そこで、本研究分担では、医師学術認証基盤に関係する諸組織に対してヒアリングを行い、潜在的なニーズについて質的な調査を試みる。また、医師学術認証基盤の説明資料を作成したうえで、ヒアリングに基づいて資料を継続的に改訂し、高品質な説明資料の作成を図る。

C. 研究結果

今年度、医師学術認証に関わりうる関係者を対象として、計 4 件のヒアリングを行った。ヒアリング対象は、医療用人工知能研究に関わる情報系研究者、当該政策に関する有識者となる。なお、本提案自体は、

研究班による構想段階のものであり、客観性や再現性を担保すべき局面にない。また、自由かつ効果的なフィードバックを得ることが優先されたことから、チャタムハウスルールの適用が妥当であると判断し、本報告においては匿名性を保つものとする。

ヒアリングにおいては、それぞれに対し、図1・2に示す説明資料を提示し、非構造化インタビューを行った。フィードバックは、提案内容そのものに対する意見に加えて、説明資料の構成や内容に関するものに及んだ。結果として、医療用人工知能の研究当事者より、こうした研究基盤の整備に対して、研究開発の促進に資するものと前向きな評価が得られた。否定的なコメントとしては、医師認証基盤との重複投資ではないかという指摘に加え、コスト面での課題の指摘が得られた。説明資料に対しては、提案が実現する各種のメリット全てが導入直後に得られるわけでないことから、施策と得られるメリットを時系列のロードマップとして示す必要性等の指摘が得られた。

説明資料の作成に際しては、職業デザイナーとヒアリング対象とのディスカッションを繰り返し、改定を重ねた。説明資料は、配布の利便を考慮しA4見開き式とし、表紙には、「医師」「医学生」「大学」「UMIN（大学病院医療情報ネットワーク）」「研究者」「政府」「学会」と、医師学術認証基盤に関わる主体が連携するイメージを配した。見開きにおいては、医師学術認証基盤を介して、医師や医学生などのユーザーとそれらユーザーが所属する大学組織(Identity Provider: IdP)が、医師用学術サービスを提供する研究者や学会等のサービスプロバイダ(Service Provider: SP)と相互接続する様子を示した。それぞれの構成要素には、各自のメリットを付記してある。そのなかでも、医師と研究者については、医師学術

認証基盤を利用するメリットが大きいことから、大きなスペースを割いて詳述した。また、見開き右下には、IdPやSP等の用語説明コーナーを設けた。さらに、裏表紙において、構想の実現に向けた技術的裏づけや、前述のプロジェクトロードマップを示した。とりわけ、ロードマップでは、医師学術認証基盤の展開を「初期」「発展期」「成熟期」に分け、どの段階で誰にどのようなメリットが生じるかを端的に表現した。

D. 考察

ヒアリングを通じて、医師学術認証基盤は、多くのサービスを簡便に利用できる医師とこうした医師に低コストで繋がる手法が得られる研究者側のメリットが特に大きいことが分かった。また、医師学術認証基盤のアカウントを、新卒医師が行う臨床研修の「研修先病院マッチング」に活用することで、新卒医師を効率的にユーザー化すると共に、有益なサービス提供を実現しうる可能性を確認した。現在、臨床研修先の決定においては、マッチングシステムの利用のためだけに全国医学生にアカウントの配布を行っていることから、その枠組みを有効活用しうることを期待される。

また、医師学術認証基盤のメリットとして、学認のように確立した技術を用いて低コスト、短期間、低リスクに実現できることが上げられる。既存の医師認証基盤であるHPKIは、法的な証拠能力を担保した認証システムであることから、いわばオンラインシステムのための「実印」と言える。しかし、実生活においても、いかに信頼性が高いからとは言え常時実印を利用しているわけではない。宅急便の受け取りや出勤簿といった、高度な証拠能力を要求されない目的には、「認印」を用いることで、日常生活の利便が保たれている。オンライン認

証も、学術目的の簡便なシステムと医療目的の強固なシステムとを用意することにより利便が向上することが期待される。さらに、医師学術認証基盤を通じて獲得したユーザーを、医師認証基盤へと誘導する導線を設けることにより、医師認証基盤自体の発展に繋がることを期待される。

一方、課題として、医師学術認証基盤が医師認証基盤との二重投資を生むのではないかという疑念を生じがちであることには、配慮が求められる。今後、「実印と認印」、「クレジットカードとSUICA(電子マネー)」といった例を用いて、用途に応じて複数の技術が用意され、また、相互に競争が生じ、また相互に補完する関係となることが技術の発展に繋がることを、政策当局に理解して頂く必要がある。また、医師学術認証基盤が低コストであることの理由として、「認証フェデレーション」を利用している点の簡便な説明が望まれる。認証基盤の運用に際し、新たな管理主体が医師ユーザーを管理することには大きなコストが掛かる。一方、認証フェデレーションモデルでは、医師や医学生が所属している医学部や病院が相互連携することにより、所属情報を相互融通する形で認証を実現する。これは、SUICAやPASMO等の交通系電子マネーが相互乗り入れしているイメージで捉えたと分かりやすいが、行政機関にとっては馴染みの薄い考え方であるため、説明に工夫が求められる。

医師学術認証基盤の持つメリットは幅広く、医師や研究者だけでなく、医学部や医学会、行政機関等、多くの関連組織にメリットがもたらされる。説明資料の改訂を重ねることで、より平易な説明を心がけると共に、賛同者を増す試みが欠かせない。

E. 結論

医師学術認証基盤の整備により、研究者

は、多くの医師に医療用人工知能研究のボトルネックとなっていた各種学習データの作成を容易に依頼することが可能となる。また、研究開発した医療用人工知能を、低コストに臨床側に提供することが可能となる。これは、医師ユーザーを確保し、また、管理していくことが困難な小規模な研究グループにおいても、医療用人工知能を安価に全国展開する手段をもたらす。医師学術認証基盤は、このように医療用人工知能の研究開発を促進する効果が期待される。

今年度のヒアリングと資料作成を通じて、こうした提案に対する関係者からのフィードバックを収集することが出来た。認証基盤技術は、全国レベルで展開することによりユーザーが拡大し、また、サービス提供者にとってのメリットが増す。そのため、政策としての実現が望まれるが、フェデレーション型の認証基盤は直感的なものではなく、説明と理解に時間を要する。逆に、一部の医学部や医療機関を対象として、認証基盤を通じた医療用人工知能の研究開発と実運用を実現し、そのモデルをフェデレーションにより拡大する手法も、検討に値するものと考えられた。

今後、ヒアリングを拡大すると共に、医師に対しても意見聴取を進め、提案への賛同を増やしたい。そのためには、今年度策定した説明資料の改定を進め、より効果的な広報を実現する必要がある。

F. 研究発表

1. 論文発表

なし

2. 学会発表

なし

医療用人工知能の研究協力者育成

研究分担者

奥村 貴史

（国立保健医療科学院 研究情報支援研究センター 特命上席主任研究官）

研究要旨

医療用人工知能研究の発展に向けた人材育成に際しては、研究者の育成以上に、研究を支援し多様性を高めるための育成が求められる。そのうち、研究協力者の育成は従来各研究グループが独自に取り組まざるを得ず、研究上の負担となってきた。共同利用できる高品質な教材は、医療用人工知能研究の効率化に繋がる。そこで、医療用 AI の研究開発に求められる研究協力者向けの教材開発を行った。

教材としては、我々が取り組んでいる診断支援システムの研究開発をケーススタディとして取り上げ、その研究用データ生成の過程を記録した。なお、このようなデータを生成する際、国内における医療従事者には数の上で制約があることに加えて単価が高い問題がある。もし、海外の医療従事者を効率的にリクルートすることができれば、医療用人工知能研究の低コスト化に向けてさらに有益な情報提供となる。そこで、実際の作業を海外医療従事者に委託するとともに、その過程を研究者向けの教材として整理した。今年度の取り組みにより、研究協力者向けの人材育成施策として、教材のたたき台を整備することができた。今後、質・量の充実に加えて、活用事例の拡大が望まれる。

A. 研究目的

人工知能研究においては、計算機に対象分野の知識をいかに与えるかという点に多くの労力を要する。医療用人工知能研究においては、この知識の編纂に医療従事者の関与が必要となることから、より多くの時間やコストが求められる。とりわけ、質の高いデータを大量に用意するためには、データ生成に適正のあるモチベーションの高い医療従事者を何名もリクルートする必要がある。

この問題に対して、各研究グループは研究協力者への広報やトレーニングを独自に進めてきた。しかし、単純作業に適性のあ

る医療従事者は少ないうえコストが高く、医療用人工知能研究のボトルネックとなっている。

この問題に対して、医療従事者に対する啓発や研究協力者への基礎トレーニングを、研究チームを超えて共同化することにより、医療用人工知能研究のコストの低廉化と効率化が期待される。そこで本研究分担では、人工知能の研究協力者を主たる対象とした各種教材の開発を目指した。

B. 研究方法

実際の医療用人工知能研究に用いるデータを研究協力者に依頼して生成しつつ、そ

の過程をケーススタディとして教材化した。事例としては、我々が取り組んでいる診断支援システムの研究開発に必要となっていた「診断結果画面に表示する参考文献リストの自動生成」を選び、その研究用データ生成の過程を取り上げた。

また、このようなデータを生成する際、国内における医療従事者には数の上で制約があることに加えて単価が高い。もし、海外の医療従事者を効率的にリクルートすることができれば、医療用人工知能研究の低コスト化に向けて、さらに有益な情報提供となるものと構想した。そこで、データ生成の実作業を海外の医師へと委託し、合わせて教材化した。

C. 研究結果

上記の方針に基づき、教材として、「医療用人工知能の作り方」、「医療用人工知能研究に求められるデータ生成・監査タスクを海外委託する」を作成した。

「医療用人工知能の作り方」では、医療用人工知能研究においてなぜ膨大な単純作業によるデータ生成が求められるかを整理した。また、「医療用人工知能研究に求められるデータ生成・監査タスクを海外委託する」では、海外の作業者が数多く登録しているクラウドソーシングサイト UpWork を利用し、スリランカ在住の医師に医療用人工知能の研究開発に求められるデータ生成を依頼し、教材化した。

それぞれの原稿を別添として示す。これらは現時点でドラフトであり、今後、実際の作業協力者や医師へと供覧し、フィードバックを得ることにより改定を重ね、より品質の向上を図ることを想定している。

D. 考察

今年度は、研究協力者向けの啓発用教材

として、我々が研究を進めてきた診断支援システムに求められるデータ生成を取り上げ整理した。こうした作業は、それぞれの研究に応じて設計する必要がある。しかし、膨大な単純作業が必要となる意義の啓発という点では、ある程度の一般性を有するものと考えられる。

今後の方向性としては、大きく2つ考えられる。まず、コンテンツに対するものとして、関連教材の質と量の充実が望ましい。そのためには、他のチームへのアンケートやヒアリングによるニーズ調査に加えて、協力依頼を行い、教材のバリエーションを増やす等が考えられる。また、たたき台の教材を他の研究者や実際の作業者へと供覧しフィードバックを得ることで、完成度を高めることが望ましい。

もうひとつの方向性として、こうした教材を活用した実際の研究支援が考えられる。たとえば、こうした啓発を継続的に行うことで医療従事者間での露出を高め、研究者と協力者のマッチングを行うようなサービスには、ニーズがあるものと考えられる。研究者側からは、研究費による委託ができればより負担も軽減することから、法人格を有した組織が、研究者側からの対価によってサービスを維持するような試みが有益とも考えられる。また、研究者と研究協力者のマッチングに際しては、本研究班の中村・奥村研究分担で行っている学術認証基盤により、一層の効率化が見込まれる。その方面の施策も発展が望まれる。

E. 結論

医療用人工知能研究の発展に向けた人材育成に際しては、研究者の育成以上に、研究を支援し多様性を高めるための育成が求められる。そのうち、研究協力者の育成は従来各研究グループが独自に取り組まざるを得ず、研究上の負担となってきた。

医療用人工知能研究の効率化に向けて、共同利用できる高品質な教材はニーズがあるものと考えられ、今年度の取り組みにより、そのたたき台を整備することができた。今後、コンテンツの質・量の充実に加えて、活用事例の拡大が望まれる。

F. 研究発表

1. 論文発表

なし

2. 学会発表

なし

III. 開発教材サンプル

厚生労働科学研究費補助金 政策科学総合研究事業
(臨床研究等ICT基盤構築・人工知能実装研究事業)
保健医療用人工知能の技術革新と国際競争力向上に資する人材育成
に関する研究 (H29-ICT-一般-004)

人工知能入門 人工知能の社会実装のために

千葉大学病院病院長企画室
病院経営管理研究センター 特任講師
亀田 義人

1. 人工知能とは何か
2. 人工知能を活用する意義
3. 人工知能の歴史とトレンド
4. ディープラーニングの理論的な背景
5. 医療における人工知能の活用領域
6. 人工知能の限界と適切な活用
7. 人工知能を活用した製品の調達について

1. 人工知能とは何か

2. 人工知能を活用する意義

3. 人工知能の歴史とトレンド

4. ディープラーニングの理論的な背景

5. 医療における人工知能の活用領域

6. 人工知能の限界と適切な活用

7. 人工知能を活用した製品の調達について

そもそも知能とは？  一般的には
知的な活動の能力 をいう。

知的な活動とは？  問題解決・推論・学習などの情報処理能力
抽象化・一般化など

人工知能とは？  一般に、
「何らかの知的動作が可能な計算機システム」

「知的動作」とは？  定義が無い

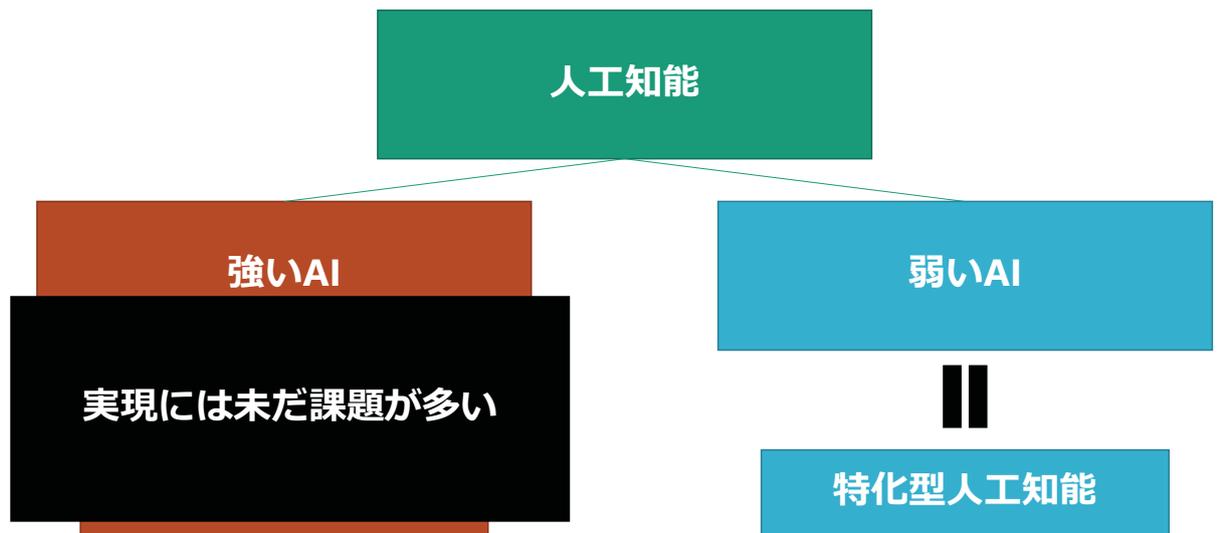
**人工知能では、知能のシミュレーションすることになるが、
知能のシミュレーションが知能といえるか？という疑問**

国内の主な研究者による人工知能の定義

中島秀之	公立はこだて未来大学	人工的につくられた、知能を持つ実態。あるいはそれをつくろうとすることによって知能自体を研究する分野である
武田英明	国立情報学研究所	
西田豊明	京都大学	「知能を持つメカ」ないしは「心を持つメカ」である
溝口理一郎	北陸先端科学技術大学院	人工的につくった知的な振る舞いをするためのもの（システム）である
長尾真		
堀浩一		
浅田稔		
松原仁		
池上高志		
山口高平		
栗原聡	電気通信大学	いるものを想像している
山川宏	ドワンゴ人工知能研究所	計算機知能のうちで、人間が直接・間接に設計する場合を人工知能と呼んで良いのではないかと思う
松尾豊	東京大学	人工的につくられた人間のような知能、ないしはそれをつくる技術。人間のように知的であるとは、「気づくことのできる」コンピュータ、つまり、データの中から特徴量を生成し現象をモデル化することのできるコンピュータという意味である

本邦での業界の第一人者でも人工知能の定義は様々であり、統一的な定義が成されているものではない

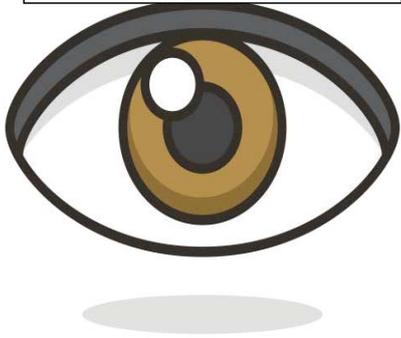
総務省 平成28年度情報通信白書



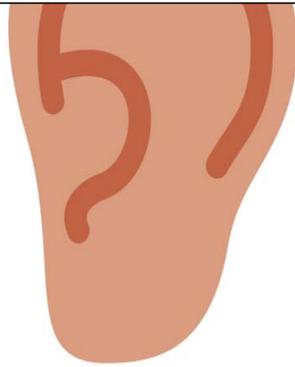
人間のような振る舞いをする知的コンピューターであり、設計した時の想定を超えた新たな問題にも対処する。

人間が設定した特定の問題（画像の識別等）に対して、主に機械学習を用いて解決する。

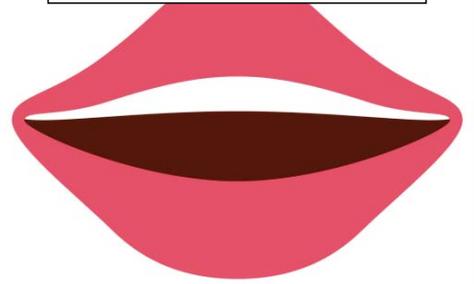
画像認識



音声認識



自然言語処理



人工知能の持つ機能

人工知能と機械学習及び、ディープラーニングの関係性



人工知能の 二つの 理論背景

線形代数

DNNなど

確率統計

ベイズ統計など

DNN: Deep Neural Network

人工知能の 二つの 問題解決 手法

回帰問題の解決

結果の
推計・推定

分類問題の解決

分類

大量の
利用可能
なデータ

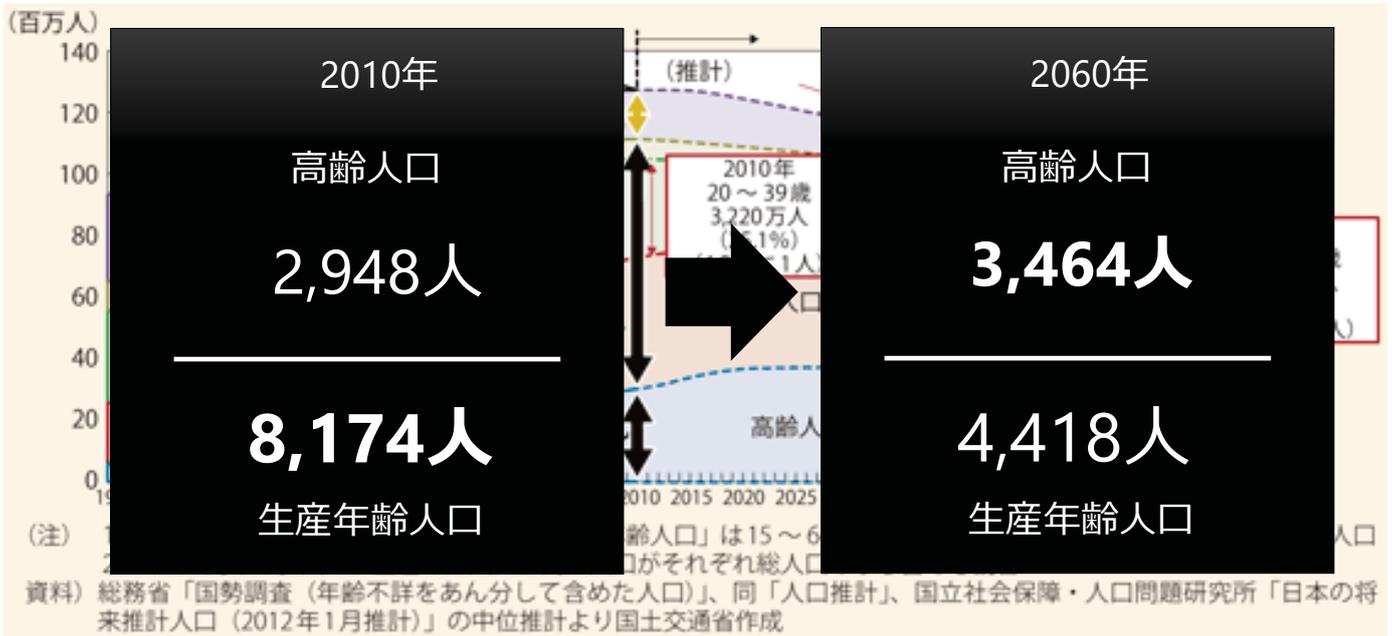
計算機能
力の向上

機械学習
アルゴリズム
の開発

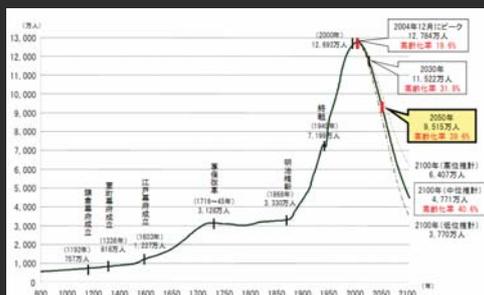
人工知能に問題解決をさせる上で重要な要素

1. 人工知能とは何か
2. 人工知能を活用する意義
3. 人工知能の歴史とトレンド
4. ディープラーニングの理論的な背景
5. 医療における人工知能の活用領域
6. 人工知能の限界と適切な活用
7. 人工知能を活用した製品の調達について

日本の人口及び産業構造の変化



人口ボーナス期と人口オーナス期



人口ボーナス期

総人口に占める「生産年齢人口(15歳～64歳の人口)」比率が圧倒的に多い状態。

安価で豊富な労働力があり、従属人口が少ないため、教育費や社会保障費の負担が少ない状態。

国家予算を経済政策に振り向けやすく、また他国からの投資を呼び込めるので、経済が活性化する。

後半になると高学歴化による人件費上昇と晩婚化・晩産化による少子化していく。

人口ボーナス期で経済発展に成功した後、医療や年金制度が充実して高齢化が進み人口オーナス期に突入する。オーナスとは、「重荷・負担」という意味。

「支えられる人」が「支える人」を上回り、社会保障費などが重い負担となるため、消費や貯蓄、投資が停滞する。

日本は人口オーナス期に突入して長いですが、十分な対策がなされてこなかった。

人口オーナス期

各国で人口知能は国家戦略に位置づけられている

ドイツ	インダストリー4.0
日本	世界最先端IT国家創造宣言
米国	米国人工知能研究開発戦略
中国	新一代人工智能発展計画

世界最先端IT国家創造宣言 目指すべき社会・姿

1. IT利活用の深化により未来に向けて成長する社会
2. ITを利活用したまち・ひと・しごとの活性化による活力ある社会
3. ITを利活用した安全・安心・豊かさが実感できる社会
4. ITを利活用した公共サービスがワンストップで受けられる社



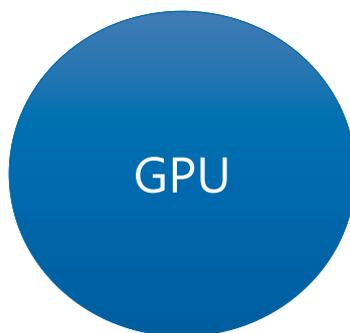
産業革命前後

同様の変革が起きようとしているのかもしれない

1. 人工知能とは何か
2. 人工知能を活用する意義
- 3. 人工知能の歴史とトレンド**
4. ディープラーニングの理論的な背景
5. 医療における人工知能の活用領域
6. 人工知能の限界と適切な活用
7. 人工知能を活用した製品の調達について

人工知能の3回のブーム

第1次	1950年代 ～	コンピューターによる「推論」や「探索」、パーセプトロンや人工対話システムELIZA	複雑な問題の解決が困難
第2次	1980年代 ～	「エキスパートシステム」、「ファジィ」や「ニューロ」コンピューティング	十分な情報処理能力をコンピューターが持たず限定的な能力も持つにとどまり、商用的にも一部「ファジィ」搭載という程度
第3次	2000年代 ～現在まで	「ディープラーニング」（2006年）などの機械学習アルゴリズム	「ビッグデータ」を、この間発達したコンピューターの計算能力（GPU/CPU）を元に、機械学習アルゴリズムを用いることにより様々な課題解決ができるようになった



人工知能に問題解決をさせる上で重要な要素

DATAの標準化・規格化とBIG DATAの活用

- 日本ではまだそのインフラ整備が途上にあるが、様々な領域で電子化が進んでいる
- 海外では例えば米国のNational Library of Medicine内のNational Center for Biotechnology InformationのPubmedなど、標準化された情報の集積化が先行している

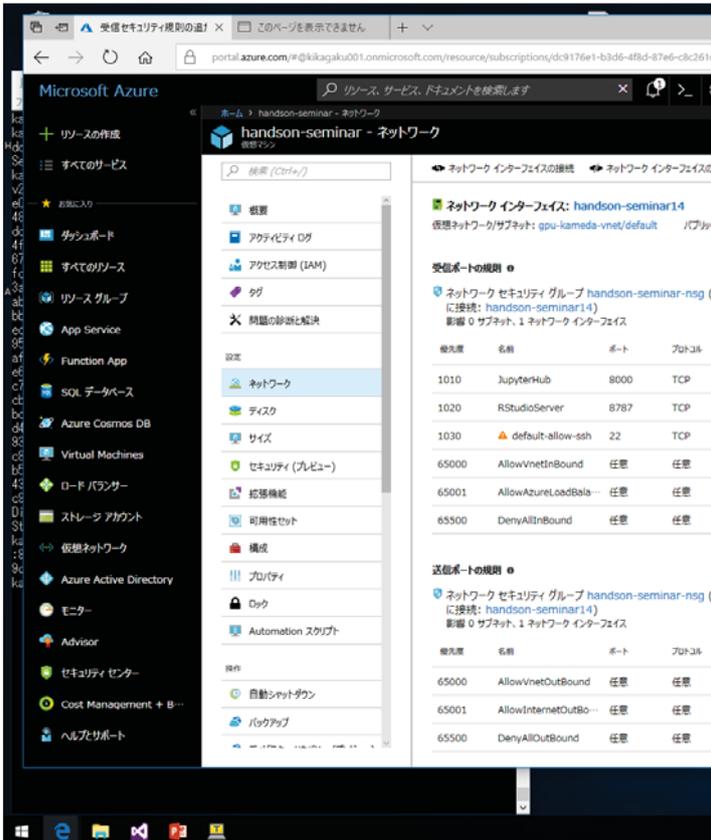
今後はIoT等により標準化された情報の集積と活用も課題



高性能なGPUの登場により演算能力の課題が克服された

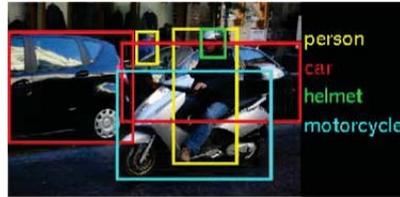
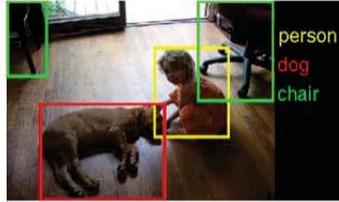
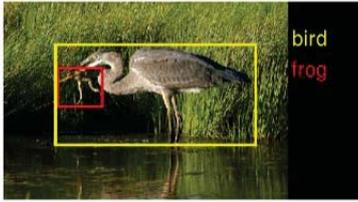
- GPU : Graphics Processing Unite

CPU(Central Precessing Unite)に対して、特に主に画像処理に関して処理能力を高めたもの。CPUが、一つのコア（演算処理を行う部分）が複雑な計算を行う事を念頭に設計されているのに対して、GPUでは単純な計算を多数並列処理させる事を念頭に設計されており、コア数も多い。



クラウドによるGPU利用環境提供サービスの普及

- 自前で大量のGPUを搭載したコンピュータを構築しなくても、クラウド環境でGPU利用環境を提供してくれる有料サービスが普及している。
- 左はMicrosoft Azureの仮想機械に実際にアクセスしているところ



※画像はILSVRC 2013のもの

- 2012年に開催された画像認識コンテスト、Large Scale Visual Recognition Challenge 2012 (ILSVRC2012)において、カナダ・トロント大学のGeoffrey Hintonチームがディープラーニングを用いて、著しく高い精度での画像認識を達成。

<http://www.image-net.org/challenges/LSVRC/2013/>

DEEP LEARNINGの登場

The IEEE SPECTRUM logo is displayed in white on a dark background. Below the logo, there are social media icons for Facebook, Twitter, LinkedIn, and YouTube. At the bottom, there are three navigation links: 'Engineering Topics', 'Special Reports', and 'Blogs', each with a small downward arrow.

Interactive: The Top Programming Languages 2017

Find the programming languages that are most important to you

The Institute of Electrical and Electronics Engineers

<https://spectrum.ieee.org/static/interactive-the-top-programming-languages-2017>

プログラム言語 Pythonの台頭

IEEE spectrumのプログラム言語ランキングにおいて、2016年に3位であったPythonが2017年に遂に1位に上昇。

人口知能・機械学習の利用環境がフリーで整えられ、社会実装の促進に貢献

Language Rank	Types	Spectrum Ranking
1. Python	🌐 🖥️	100.0
2. C	📱 🖥️ 🖨️	99.7
3. Java	🌐 📱 🖥️	99.4
4. C++	📱 🖥️ 🖨️	97.2
5. C#	🌐 📱 🖥️	88.6
6. R	🖥️	88.2
7. JavaScript	🌐 📱	85.4
8. PHP	🌐	81.1
9. Go	🌐 🖥️	75.8
10. Swift	📱 🖥️	75.0
11. Arduino	🖨️	72.4
12. Ruby	🌐 🖥️	72.1
13. Assembly	🖨️	71.8
14. Matlab	🖥️	68.6
15. Scala	🌐 📱	68.1
16. HTML	🌐	67.2

人工知能利活用のための無料プラットフォーム



Documentation Blog Contact Anaconda Cloud [Download](#)

Anaconda Data Science Certification

Objectively Demonstrate Your Data Science Experience

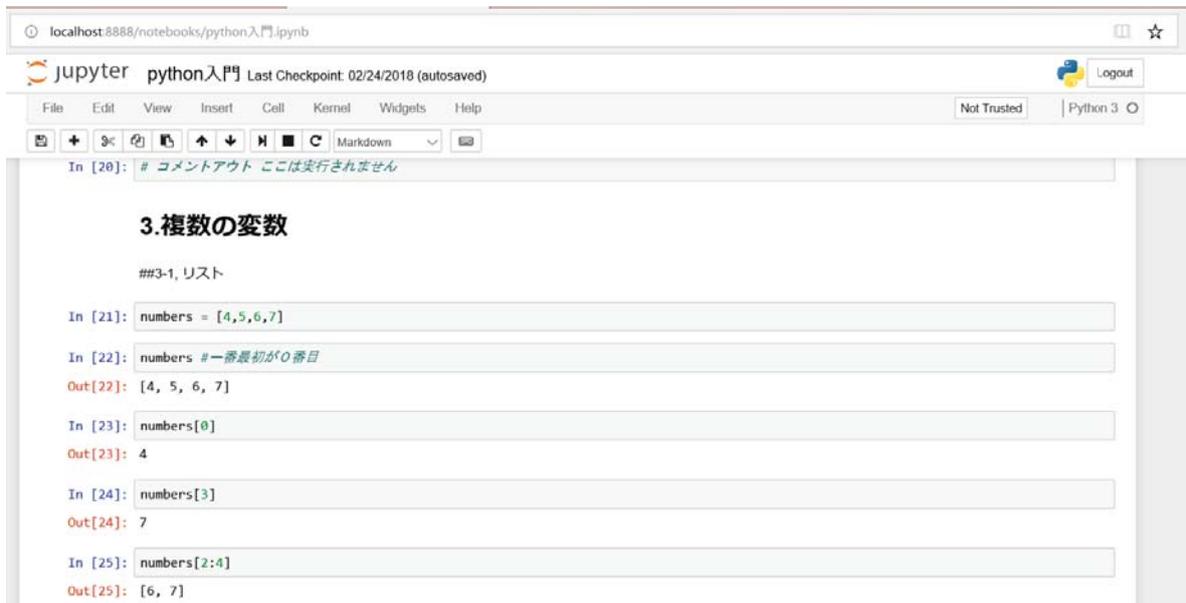
[Learn More](#)

The Most Popular Python Data Science Platform

機械学習やデータ処理が簡単にできるライブラリ※を多数標準装備したPythonのDistribution（利用環境をパッケージ化したもの）も登場

※ある特定の機能を持つプログラムを定型化して、他のプログラムが引用できる状態にしたものを、複数集めてまとめたファイル

ブラウザ上でJupyter notebookというPythonのインターフェースも活用可能



```
In [20]: # コメントアウト ここは実行されません

3.複数の変数

##3-1, リスト

In [21]: numbers = [4,5,6,7]
Out[21]: [4, 5, 6, 7]

In [22]: numbers # 一番最初の番号
Out[22]: [4, 5, 6, 7]

In [23]: numbers[0]
Out[23]: 4

In [24]: numbers[3]
Out[24]: 7

In [25]: numbers[2:4]
Out[25]: [6, 7]
```

代表的なDNN※ライブラリ

※DNN : Deep Neural Network DNNを用いてDeep Learning させる

TensorFlow

googleが開発したDNNライブラリ。googleが実際に使っているライブラリをオープン化している。

<https://www.tensorflow.org/versions/master/tutorials/>

Chainer

国内ベンチャー企業であるPreferred Networksが開発したDNNライブラリ。Preferred NetworksはMicrosoftとの協業や国内各大手企業と提携している。こちらもライブラリをオープン化している。

<https://docs.chainer.org/en/stable/guides/>

1. 人工知能とは何か
2. 人工知能を活用する意義
3. 人工知能の歴史とトレンド
- 4. ディープラーニングの理論的な背景**
5. 医療における人工知能の活用領域
6. 人工知能の限界と適切な活用
7. 人工知能を活用した製品の調達について

人工知能の 二つの 理論背景

線形代数

DNNなど

確率統計

ベイズ統計など

人工知能の3つの学習様式

教師あり学習

教師なし学習

強化学習

人工知能を活用した問題解決の基本的な枠組み

- 1) 解決したい問題に対して計算モデルを決める
- 2) 評価関数（損失関数）を決める
- 3) 評価関数（損失関数）を最大化もしくは最小化する

人口知能を活用した問題解決の基本的な枠組み

重回帰分析を例にとると

1) 解決したい問題に対して計算モデルを決める

⇒回帰式（目的変数を説明変数で計算する式）を設定

$$y = a_1x_1 + a_2x_2 + \dots + a_kx_k + b$$

2) 評価関数（損失関数）を決める

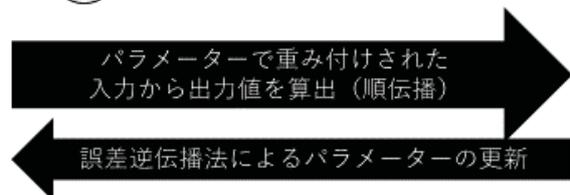
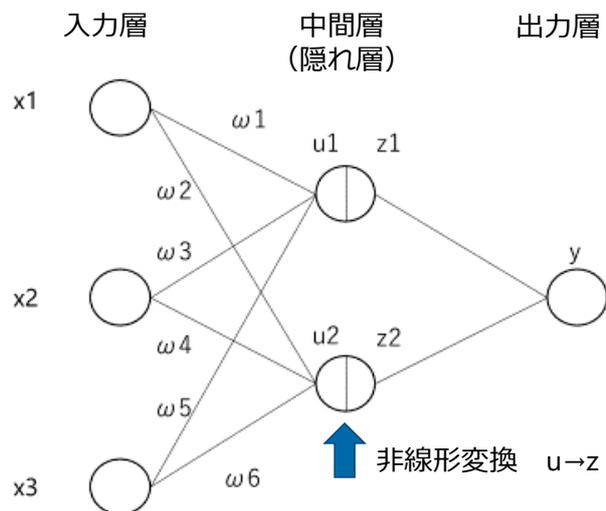
⇒最小二乗法

3) 評価関数（損失関数）を最大化もしくは最小化する

⇒「従属変数の測定値と、独立変数の測定値および回帰式を用いて求めた推定値の差の二乗和誤差」が最小になるように回帰式の係数を求める

シンプルなDNNモデル例

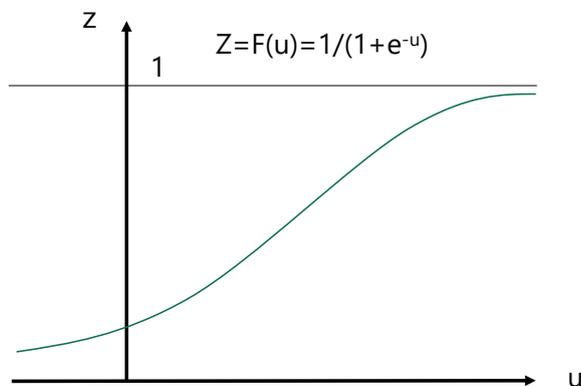
DNNは入力層、中間層（隠れ層）、出力層からなる。中間層を何層置くか、隠れ層のノードをいくつ置くかについてもヒトが設定する必要がある。パラメーターWの値ははじめランダムに設定する。



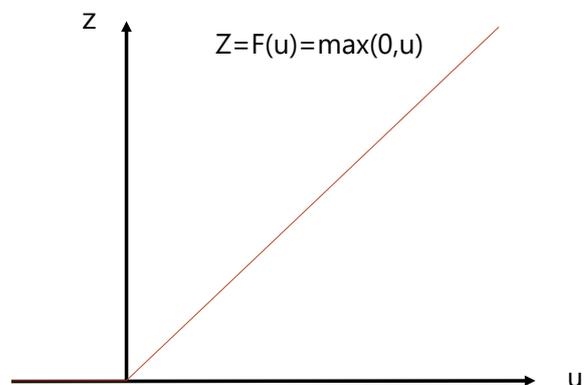
上記は回帰モデル。
分類問題の場合は出力層 y が複数となる。

非線形変換に用いる活性化関数

シグモイド関数



Relu関数



uの負の値は無視、数値の大きさも考慮できる

評価関数（損失関数）を決める

回帰問題のとき

平均二乗誤差

Mean Squared Errorを用いる

$$L=(y-t)^2$$

分類問題のとき

ソフトマックス関数を用いて

クロスエントロピー誤差を求める

(参考)

ソフトマックス関数

$$f(x) = \frac{\exp(x_i)}{\sum_{j=1}^d \exp(x_j)}$$

クロスエントロピー誤差

$$L(hL) = \sum_i (y_i \log hL_i + (1-y_i) \log (1-hL_i))$$

実際はChainerライブラリ等の中に定義されていて
F.softmax_cross_entropy(y,t)等と入力すれば計算してくれる

損失関数を最小化する (+ そのためのパラメータwを求める)

最急降下法

1) ランダムにwの初期値を決める

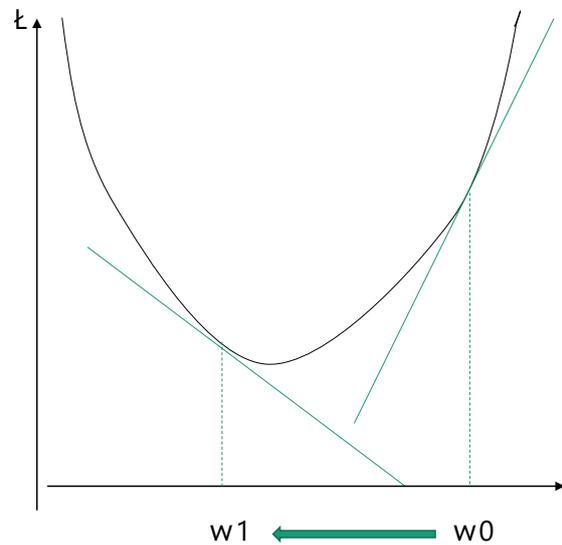
2) 損失関数の微分値 (傾き) を求める

$d/dw(t)$

3) パラメータを更新する

損失関数の微分値を引く

$w \leftarrow w - d/dw(t) (\times \rho : \text{学習係数})$



(参考)

目的別に最適化されたNeural Network

画像認識 ⇒ Convolutional Neural Network

時系列解析 ⇒ Recurrent Neural Network

1. 人工知能とは何か
2. 人工知能を活用する意義
3. 人工知能の歴史とトレンド
4. ディープラーニングの理論的な背景
- 5. 医療における人工知能の活用領域**
6. 人工知能の限界と適切な活用
7. 人工知能を活用した製品の調達について

医療においても様々な領域で人工知能の活用が期待されている

人工知能（AI）の実用化における機能領域

識別	音声認識	予測	数値予測	実効	表現生成
	画像認識		マッチング		デザイン
	動画認識		意図予測		行動最適化
	言語解析		ニーズ予測		作業の自動化

(出典) 総務省「ICTの進化が雇用と働き方に及ぼす影響に関する調査研究」(平成28年)

一つの分類方法として、総務省「ICTの進化が雇用と働き方に及ぼす影響に関する調査研究」において識別、予測、実効に分類している。これらを医療に照らし合わせることで、AIを活用してどのような事が実現可能か考える手がかりになるかもしれない。

医療における人工知能の活用の具体例

既に医療における人工知能の利活用の事例は幅広く存在しており、増え続けているため、すべてを紹介するのは困難となっている。ここでは一部の領域についてピックアップする

- 1) 医療画像処理
- 2) がんのPrecision Medicine
- 3) 自然言語処理等の活用



1) 医療画像処理

画像処理・画像認識は第3次人工知能ブームの火付け役となった領域の一つであり、活用が特に先行している分野である。

画像診断、病理診断や患者の外観からの疾病予測等取り組まれている。

TED Stanford大学Fei Fei Li氏のプレゼンテーション
https://www.ted.com/talks/fei_fei_li_how_we_re_teaching_computers_to_understand_pictures?language=ja

人工知能による脳動脈瘤等の診断支援

富士フィルム 東京大学発ベンチャー「エルピクセル」と提携
－ AI技術を医療画像診断支援に活用 －

2018年4月12日
富士フィルム株式会社

富士フィルム株式会社(社長:助野 健児)は、医療領域の画像解析に強みを持つエルピクセル株式会社(以下:エルピクセル)と医療画像の診断支援に用いられるAI技術に関するパートナーシップについて2018年4月10日に合意しました。今後、エルピクセルが開発する診断支援AI技術を、富士フィルムの医用画像情報システム(以下:PACS)に搭載していくことを目指します。

人工知能を活用した医療画像診断支援技術「EIRL (エイル)」を発表

EIRL | 人工知能(AI) | 医療画像診断支援

2017年11月24日



人工知能を活用した術中迅速病理診断支援

2018年1月31日

東芝デジタルソリューションズと千葉大学フロンティア医工学センター、AIによる胃がんのリンパ節転移巣検出の共同研究を開始

東芝デジタルソリューションズ株式会社

☞ マークの付いたリンクは、別ウィンドウで開きます。

東芝デジタルソリューションズ株式会社(神奈川県川崎市 取締役社長 錦織 弘信 以下、当社)は、国立大学法人千葉大学(千葉県千葉市以下、千葉大学)フロンティア医工学センター 林秀樹教授、医学研究院先端応用外科学 松原久裕教授、医学部診断病理学教室 松嶋博助教授らの研究グループと、AI^{注1}(人工知能)による病理組織画像からの胃がんのリンパ節転移巣検出の共同研究を開始しました。

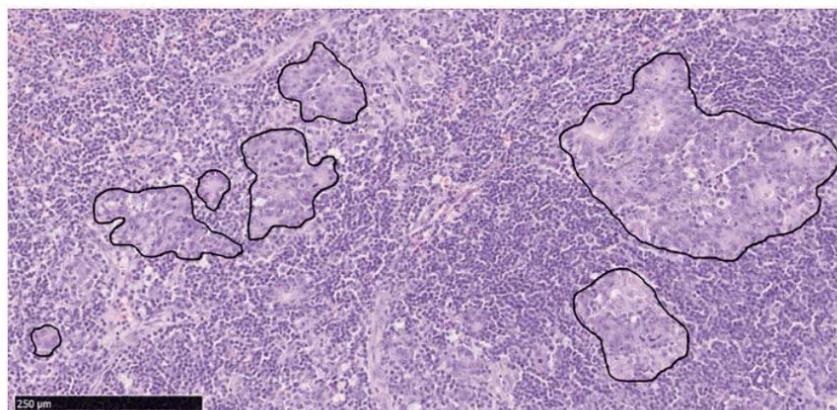
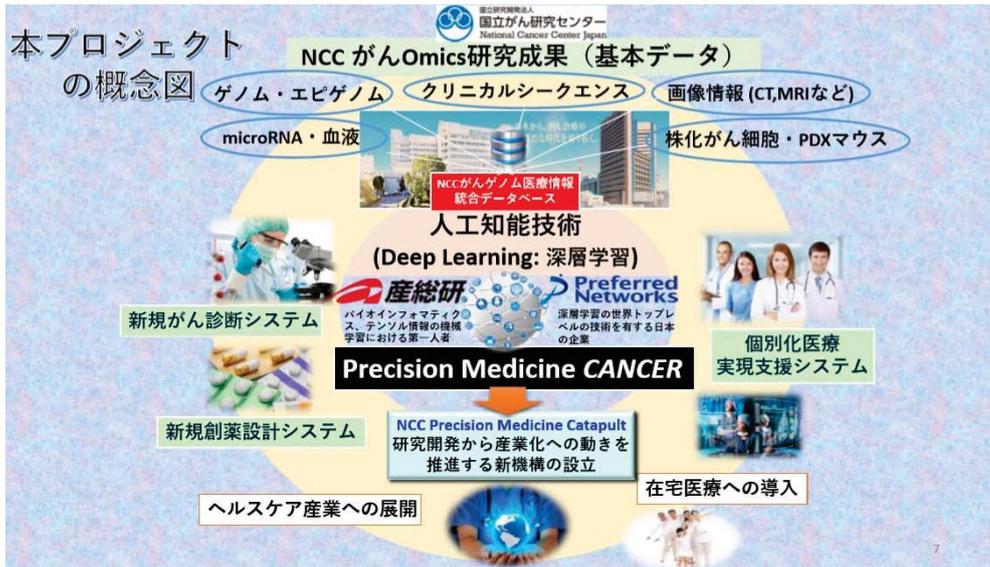


図1 胃がんのリンパ節転移(リンパ節のHE染色組織像:実線で囲まれた部分が転移組織)

2) がんのPrecision Medicine



国立がん研究センター 人工知能を用いた統合的ながん医療システムの開発

https://www.ncc.go.jp/jp/information/pr_release/2016/1129/press_release_20161129_01.pdf

3) 自然言語処理等の活用

総務省 次世代人工知能社会実装WG 自然言語処理の医療応用

NAISTに集まる大規模データ

- 日本内科学会 - 45,000症例
- 日本産科婦科学会 - 25,000症例
- 東京大学医学部附属病院 - 300,000症例
- 自治医科大学 - 100,000症例
- 京都大学医学部附属病院 - 60,000症例
- 東京大学生産技術研究所 - 100,000症例
- 福島県立医科大学
- 東北メディカル・メガバンク

症例検索から診断支援のためのデータへ

症状から症例を検索 | 症状から診断名を推測する

- 稀な症例であっても重要な疾患であり見落としの防止に貢献
- 海外展開時における競争力の確保に寄与

症例報告は日本の学会が長年行ってきた我が国独自の活動
立ち上げた日本の医療AIを挽回する格好のデータベース

医療テキストから医師
疾病 (病名、症状) (言い換え・正規化) の抽出

医療現場の標準化

ICD-R11
悪心及び嘔吐
悪心嘔吐
胃のむかつき
悪心
嘔吐
吐き戻し (吐)
嘔吐

http://www.soumu.go.jp/main_content/000474414.pdf



迅速・網羅的病原体ゲノム解析法の開発及び感染症危機管理体制の構築に資する研究



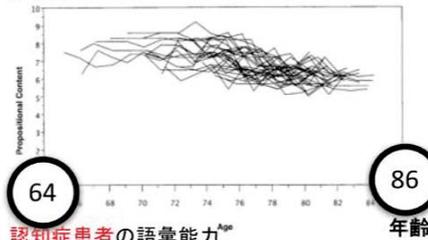
感染症危機管理体制の構築に資する網羅的な診断系を確立
Twitterの“つぶやき”から自然言語処理にて感染症発生を推定するツールを開発し、そのアラートが実際の現場（病院・地研・感染研）で正しい事象を捕捉しているのか否かを検証する。
海外来訪者の増大と東京オリンピック対策を兼ねて、感染研・東京都健康安全研究所との連携を密にし、実地疫学とNGS検査法を軸にネットワーク構築する。

- 黒田誠 (国立感染症研究所)
- 木村博一 (国立感染症研究所)
- 梁明秀 (横浜市立大学大学院)
- 大石和徳 (国立感染症研究所)
- 四宮博人 (愛媛県環境衛生研究所)
- 貞升健志 (東京都健康安全研究所)
- 大場邦弘 (公立昭和病院)
- 荒牧英治 (奈良先端技術大学院大学)

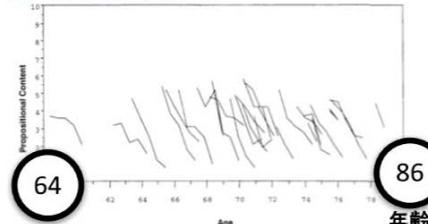
+ BRAIN

Snowdonや Kemperは英語言語にて認知症者の語彙力が発症の30年前からも予測できる可能性を示唆

健常者の語彙能力



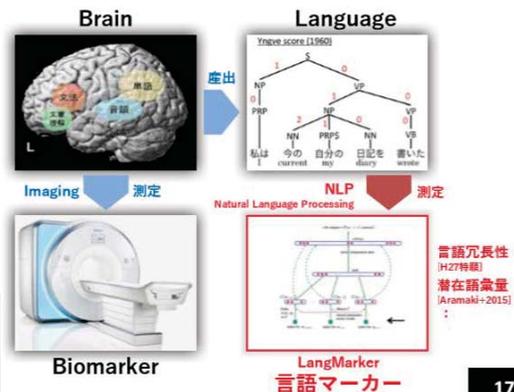
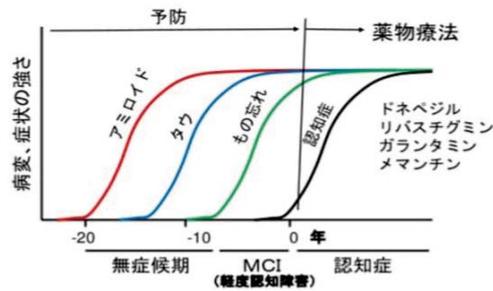
認知症患者の語彙能力



Snowdon, D. A., Kemper, S., Mortimer, J. A., Greiner, L. H., Wekstein, D. R., & Markesbery, W. R. (1996). Linguistic ability in early life and cognitive function and Alzheimer's disease in late life: Findings from the Nun Study. *Journal of the American Medical Association*, 275, 528-532.

個人発話データの利活用

病理的妥当性



1. 人工知能とは何か
2. 人工知能を活用する意義
3. 人工知能の歴史とトレンド
4. ディープラーニングの理論的な背景
5. 医療における人工知能の活用領域
- 6. 人工知能の限界と適切な活用**
7. 人工知能を活用した製品の調達について

人工知能の限界

哲学的・概念的な問題から、技術的・実践倫理的・法的課題まで

- 1) チューリングテスト
- 2) 不完全性定理
- 3) 中国語の部屋
- 4) フレーム問題
- 5) 記号接地問題
- 6) トロッコ問題
- 7) 瑕疵があった場合の責任の所在

1) チューリングテスト

チューリングテストという、機械に応答させて人間が応答しているか機械が応答しているか、判断するテストがある。30%の審査員に人だと判断させれば合格で、2014年に33%にて達成はされたが、未だ十分に人間らしい反応であるという成果を挙げてはいない。

2) 不完全性定理

「自己言及のパラドックス」いわゆる「クレタ人は嘘つきだとクレタ人は言った」を、ゲーゲルが数学的に証明した。完全な人工知能はその完全性を証明できないという矛盾が生じる。外部から条件・定義を設定する必要が生じる。

3) 中国語の部屋

中国語を知っているヒトがコンピュータに対して中国語を入力、別の部屋で中国語を知らないヒトが中国語を記号として認識して、ある記号に対してはこの記号、というように返答すると、見かけ上中国語を理解しているヒトが対応している様に見える。単に記号を操作するだけで知能をシミュレートしており、知能はヒトにも機械にもでっつけられるというもの。

4) フレーム問題

現在、人工知能は思考すべき範囲や詳細度の決定を人工知能自身でできない。ある目的を達成使用とする場合、関係ある事項のほか、関係無い事項は無限に存在するため、それを洗い出そうとすると無限に時間を要し停止してしまう。

現在のところ、人工知能に対しヒトが「適切」な範囲を定める必要があり、「範囲を定める問題」の一般的な解決は困難である。

5) 記号接地問題

記号を実世界の意味と結びつけられるかという問題。コンピュータは記号の意味を理解していないので、記号の操作だけで知能を実現できない。例えば、シマ+ウマ=シマウマという様な概念を一般化して獲得する事はできない。

6) トロツコ問題

トロツコが線路の上を走行しており、岐路が設けられている。線路の先には修理作業中の5名の作業員がおり、そのまま走ると5名が轢かれる。別の岐路の先には1人が作業している。A氏はたまたまトロツコの進行方向を変えるレバーの近くにいる。A氏がとるべき「正しい」行動とはどのようなものか。という問題。人工知能に「正しい」判断をさせる場合、何を持って「正しい」とするか。人工知能にどのような価値判断を与えるべきか、どのようにコンセンサスを得るのか、コンセンサスは得られるのか。

7) 瑕疵があった場合の責任の所在

人工知能を搭載した製品を使用して起きた問題の中で、人工知能の判断が誤っていたために起きた問題の責任は、製品製造者にあるか、製品使用者にあるか。

人工知能が出した解答に従って起きた問題の所在は、どのような場合にどこに置くべきか。

官民 ITS 構想・ロードマップ 2017

ITS (Intelligent Transport Systems : 高度道路交通システム)

【表 1】自動運転レベルの定義 (J3016) の概要⁴

レベル	概要	安全運転に係る監視、対応主体
運転者が全てあるいは一部の運転タスクを実施		
SAE レベル 0 運転自動化なし	・ 運転者が全ての運転タスクを実施	運転者
SAE レベル 1 運転支援	・ システムが前後・左右のいずれかの車両制御に係る運転タスクのサブタスクを実施	運転者
SAE レベル 2 部分運転自動化	・ システムが前後・左右の両方の車両制御に係る運転タスクのサブタスクを実施	運転者
自動運転システムが全ての運転タスクを実施		
SAE レベル 3 条件付運転自動化	・ システムが全ての運転タスクを実施 (限定領域内 [※]) ・ 作動継続が困難な場合の運転者は、システムの介入要求等に対して、適切にตอบสนองすることが期待される	システム (作動継続が困難な場合は運転者)
SAE レベル 4 高度運転自動化	・ システムが全ての運転タスクを実施 (限定領域内 [※]) ・ 作動継続が困難な場合、利用者が応答することは期待されない	システム
SAE レベル 5 完全運転自動化	・ システムが全ての運転タスクを実施 (限定領域内 [※] ではない) ・ 作動継続が困難な場合、利用者 ⁵ が応答することは期待されない	システム

自動運転の分野ではAI活用により生じた責任の所在も議論されている

<高度自動運転の制度整備に係る基本的考え方>

高度自動運転の実現のための制度整備の方針 (大綱) の検討にあたっては、我が国としては、以下の基本的な考え方 (戦略) に基づいて検討を行うものとする。

- i. 中期的視点に立った制度面における国際的リーダーシップの発揮
- ii. 安全性を確保しつつイノベーションが促進されるような制度枠組みの策定
- iii. 社会受容性を前提とつつイノベーションが促進されるような責任関係の明確化

人工知能の適切な活用

Asilomar AI Principles (2017)

2017年1月、カリフォルニア州アシロマにて行われた、全世界のAIの研究者と経済学、法律、倫理、哲学の専門家が集まり議論された人類にとって有益なAIに関する原則。研究に関する5項目、倫理と価値観に関する13項目、長期的な問題に関する5項目計23項目が挙げられた。

AIネットワーク社会推進会議報告書2017

総務省情報通信政策研究所が、平成28年10月から「AIネットワーク社会推進会議」を開催し、AIネットワーク化をめぐる社会的・経済的・倫理的・法的な課題について検討を進めている。平成29年7月に報告書が発出され、その中で、国際的な議論のためのAI開発ガイドライン案が提案された

Asilomar AI Principles (2017)

- Research Issues
- 1) **Research Goal:** The goal of AI research should be to create not undirected intelligence, but beneficial intelligence.
- 2) **Research Funding:** Investments in AI should be accompanied by funding for research on ensuring its beneficial use, including thorny questions in computer science, economics, law, ethics, and social studies, such as:
 - How can we make future AI systems highly robust, so that they do what we want without malfunctioning or getting hacked?
 - How can we grow our prosperity through automation while maintaining people's resources and purpose?
 - How can we update our legal systems to be more fair and efficient, to keep pace with AI, and to manage the risks associated with AI?
 - What set of values should AI be aligned with, and what legal and ethical status should it have?
- 3) **Science-Policy Link:** There should be constructive and healthy exchange between AI researchers and policy-makers.
- 4) **Research Culture:** A culture of cooperation, trust, and transparency should be fostered among researchers and developers of AI.
- 5) **Race Avoidance:** Teams developing AI systems should actively cooperate to avoid corner-cutting on safety standards.

- Ethics and Values
- 6) **Safety:** AI systems should be safe and secure throughout their operational lifetime, and verifiably so where applicable and feasible.
- 7) **Failure Transparency:** If an AI system causes harm, it should be possible to ascertain why.
- 8) **Judicial Transparency:** Any involvement by an autonomous system in judicial decision-making should provide a satisfactory explanation auditable by a competent human authority.
- 9) **Responsibility:** Designers and builders of advanced AI systems are stakeholders in the moral implications of their use, misuse, and actions, with a responsibility and opportunity to shape those implications.
- 10) **Value Alignment:** Highly autonomous AI systems should be designed so that their goals and behaviors can be assured to align with human values throughout their operation.
- 11) **Human Values:** AI systems should be designed and operated so as to be compatible with ideals of human dignity, rights, freedoms, and cultural diversity.
- 12) **Personal Privacy:** People should have the right to access, manage and control the data they generate, given AI systems' power to analyze and utilize that data.

- 13) **Liberty and Privacy:** The application of AI to personal data must not unreasonably curtail people's real or perceived liberty.
- 14) **Shared Benefit:** AI technologies should benefit and empower as many people as possible.
- 15) **Shared Prosperity:** The economic prosperity created by AI should be shared broadly, to benefit all of humanity.
- 16) **Human Control:** Humans should choose how and whether to delegate decisions to AI systems, to accomplish human-chosen objectives.
- 17) **Non-subversion:** The power conferred by control of highly advanced AI systems should respect and improve, rather than subvert, the social and civic processes on which the health of society depends.
- 18) **AI Arms Race:** An arms race in lethal autonomous weapons should be avoided.

- Longer-term Issues
- 19) **Capability Caution:** There being no consensus, we should avoid strong assumptions regarding upper limits on future AI capabilities.
- 20) **Importance:** Advanced AI could represent a profound change in the history of life on Earth, and should be planned for and managed with commensurate care and resources.
- 21) **Risks:** Risks posed by AI systems, especially catastrophic or existential risks, must be subject to planning and mitigation efforts commensurate with their expected impact.
- 22) **Recursive Self-Improvement:** AI systems designed to recursively self-improve or self-replicate in a manner that could lead to rapidly increasing quality or quantity must be subject to strict safety and control measures.
- 23) **Common Good:** Superintelligence should only be developed in the service of widely shared ethical ideals, and for the benefit of all humanity rather than one state or organization.

第2章 国際的な議論のためのAI開発ガイドライン案①

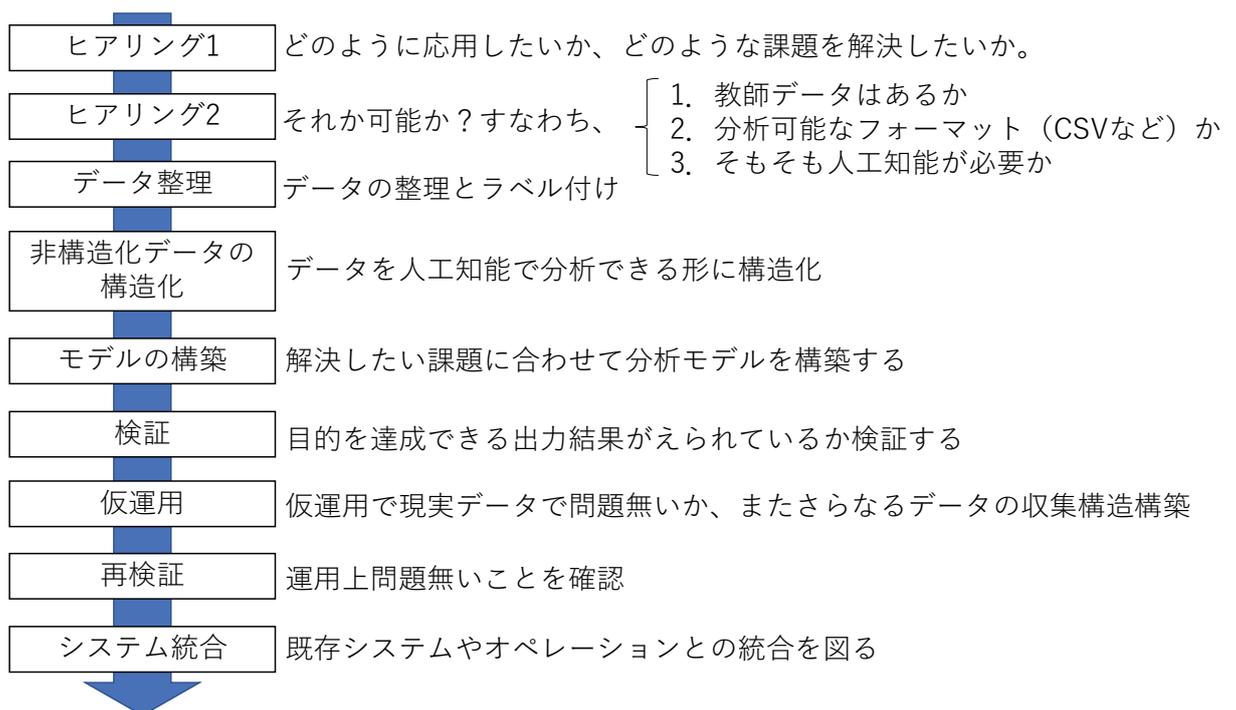
目的	基本理念	用語の定義及び対象範囲
<ul style="list-style-type: none"> AIネットワーク化(AIシステムがインターネット等と接続され、AIシステム相互間又はAIシステムと他の種類のシステムとの間のネットワークが形成されるようになること)の進展により、人間及びその社会や経済に多大な便益がもたらされる一方、不透明化等のリスクに対する懸念も存在 オープンな議論を通じ、国際的なコンセンサスを醸成し、非規制的で非拘束的なソフトローたるガイドラインやそのベストプラクティスをステークホルダ間で国際的に共有することが必要 AIネットワーク化の健全な進展を通じたAIシステムの便益の増進とリスクの抑制により、利用者の利益を保護するとともにリスクの波及を抑制し、人間中心の智連社会を実現 	<ul style="list-style-type: none"> 人間がAIネットワークと共生することにより、その恵沢がすべての人によってあまねく享受され、人間の尊厳と個人の自律が尊重される人間中心の社会を実現 非拘束的なソフトローたる指針やそのベストプラクティスをステークホルダ間で国際的に共有 イノベティブでオープンな研究開発と公正な競争、学問の自由や表現の自由といった民主主義社会の価値を尊重するとともに、便益とリスクの適正なバランスを確保 技術的中立性の確保、開発者に過度の負担を課さないよう配慮 不断の見直し、必要に応じた柔軟な改定、広範で柔軟な議論 	<ul style="list-style-type: none"> 「AI」: AIソフト及びAIシステムを総称する概念 <ul style="list-style-type: none"> ●「AIソフト」: データ・情報・知識の学習等により、利活用の過程を通じて自らの出力やプログラムを変化させる機能を有するソフトウェア(例: 機械学習ソフトウェア) ●「AIシステム」: AIソフトを構成要素として含むシステム(例: AIソフトを実装したロボットやクラウドシステム) AIシステムの「開発者」及び「利用者」は以下のとおり定義 ※ただし、「開発者」及び「利用者」は場面に応じて個別に決まる相対的な概念 <ul style="list-style-type: none"> ●「開発者」: AIシステムの研究開発(AIシステムを利用しながら行う研究開発を含む)を行う者(自らが開発したAIシステムを用いてAIネットワークサービスを他者に提供するプロバイダを含む) ●「利用者」: AIシステムを利用する者(最終利用者(エンドユーザ)のほか、他者が開発したAIネットワークサービスを第三者に提供するプロバイダを含む) 対象とするAIシステムの範囲→ネットワーク化され得るAIシステム(ネットワークに接続可能なAIシステム) 対象とする開発者の範囲→定義された開発者すべて 対象とする開発の範囲→閉鎖された空間(実験室、セキュリティが十分に確保されたサンドボックス等)内での開発は対象とせず、ネットワークに接続して行う段階に限定
関係者に期待される役割	<ul style="list-style-type: none"> 各国政府及び国際機関による多様なステークホルダ間の対話の促進に向けた環境整備 開発者、利用者等ステークホルダによる対話やベストプラクティスの共有、AIの便益及びリスクに関する認識の共有 標準化団体等による推奨モデルの作成・公表 各国政府によるAIの開発者コミュニティの支援、AIに関する研究開発を支援する政策の積極的な推進 	

第2章 国際的な議論のためのAI開発ガイドライン案② (AI開発原則案の解説)

開発原則	開発原則の解説 (留意することが期待される事項等)
① 連携の原則 開発者は、AIシステムの相互接続性と相互運用性に留意する。	・相互接続性と相互運用性を確保するため、①有効な関連情報の共有に向けた協力、②国際的な標準や規格への準拠、③データ形式の標準化及びインターフェイスやプロトコルのオープン化への対応、④標準必須特許等のライセンス契約及びその条件についてのオープン・公平な取扱い、などに留意することが望ましい。
② 透明性の原則 開発者は、AIシステムの入出力の検証可能性及び判断結果の説明可能性に留意する。	・採用する技術の特性や用途に照らし合理的な範囲で、AIシステムの入出力の検証可能性及び判断結果の説明可能性に留意することが望ましい。 (※アルゴリズム、ソースコード、学習データの開示を想定するものではない。)
③ 制御可能性の原則 開発者は、AIシステムの制御可能性に留意する。	・AIシステムの制御可能性について、あらかじめ検証及び妥当性の確認をするよう努めるとともに、採用する技術の特性に照らし合理的な可能な範囲において、人間や信頼できる他のAIによる監督・対処の実効性に留意することが望ましい。
④ 安全の原則 開発者は、AIシステムがアクチュエータ等を通じて利用者及び第三者の生命・身体・財産に危害を及ぼすことがないよう配慮する。	・AIシステムの安全性について、あらかじめ検証及び妥当性の確認をするよう努めるとともに、AIシステムの本質安全や機能安全に資するよう、開発の過程を通じて、採用する技術との特性に照らし可能な範囲で措置を講ずるよう努めることが望ましい。 ・利用者及び第三者の生命・身体・財産の安全に関する判断を行うAIシステムについては、利用者等ステークホルダに対して設計の趣旨などを説明するよう努めることが望ましい。
⑤ セキュリティの原則 開発者は、AIシステムのセキュリティに留意する。	・AIシステムのセキュリティについて、あらかじめ検証及び妥当性の確認をするよう努めるとともに、開発の過程を通じて、採用する技術の特性に照らし可能な範囲で対策を講ずるよう努めることが望ましい(セキュリティ・バイ・デザイン)。
⑥ プライバシーの原則 開発者は、AIシステムにより利用者及び第三者のプライバシーが侵害されないよう配慮する。	・AIシステムのプライバシー侵害のリスクについて、あらかじめ影響評価を行うよう努めるとともに、開発の過程を通じて、採用する技術の特性に照らし可能な範囲で措置を講ずるよう努めることが望ましい(プライバシー・バイ・デザイン)。
⑦ 倫理の原則 開発者は、AIシステムの開発において、人間の尊厳と個人の自律を尊重する。	・AIシステムの学習データに含まれる偏見などに起因して不当な差別が生じないよう、採用する技術の特性に照らし可能な範囲で所要の措置を講ずるよう努めることが望ましい。 ・国際人権法や国際人道法を踏まえ、AIシステムが人間性の価値を不当に毀損することがないよう留意することが望ましい。
⑧ 利用者支援の原則 開発者は、AIシステムが利用者を支援し、利用者を選択の機会を適切に提供することが可能となるよう配慮する。	・AIシステムの利用者のために、①利用者の判断に資する情報を適時適切に提供し、かつ利用者にとって操作しやすいインターフェイスが利用可能となるよう配慮、②利用者を選択の機会を適時適切に提供する機能が利用可能となるよう配慮、③社会的弱者の利用を容易にするための取組、に留意することが望ましい。
⑨ アカウンタビリティの原則 開発者は、利用者を含むステークホルダに対しアカウンタビリティを果たすよう努める。	・開発原則①～⑧の趣旨に鑑み、利用者等に対しAIシステムの技術的的特性について情報提供や説明を行うほか、ステークホルダとの対話を通じた意見聴取や、ステークホルダの積極的な関与を得るよう努めることが望ましい。 ・AIシステムによりサービスを提供するプロバイダなどの情報共有・協力に努めることが望ましい。

1. 人工知能とは何か
2. 人工知能を活用する意義
3. 人工知能の歴史とトレンド
4. ディープラーニングの理論的な背景
5. 医療における人工知能の活用領域
6. 人工知能の限界と適切な活用
7. 人工知能を活用した製品の調達について

機械学習を含んだ人工知能製品の開発運用フロー例



適切なシステム開発のためには、現場の問題意識と、人工知能開発研究者と、ユーザーインターフェース開発ベンダーとの間で、密なコミュニケーションが必要となる。それを理解した上で、対応適任者を専任する必要が出てくる。また、精度向上のためには、利用環境で生まれるデータを学習させ続ける仕組み作りも重要である。

日本はイノベーション能力が低いと評価されている

第Ⅱ-3-2-1-1表 WEF イノベーションランキング 2016-2017年版

	イノベーション ランキング	イノベーション 能力	科学技術 調査機関の質	企業の研究 開発投資	研究開発にお ける産学協業	先進技術に対 する政府調達	科学者・技術者 の対応領域と数	PCT 国際出願 件数
スイス	1	1	1	1	1	28	14	3
イスラエル	2	4	3	3	3	9	8	5
フィンランド	3	6	8	7	2	26	1	4
米国	4	2	5	2	4	11	2	10
ドイツ	5	5	11	5	8	6	16	7
スウェーデン	6	3	7	6	12	23	20	2
オランダ	7	10	4	14	5	21	21	9
日本	8	21	13	4	18	16	3	1
シンガポール	9	20	10	15	7	4	9	13
デンマーク	10	18	16	16	14	53	37	8

備考：PCT 出願とは、特許協力条約に基づいた特許申請。

資料：WEF「The Global Competitiveness Report (2016-2017年版)」から経済産業省作成。

平成29年版通商白書 経済産業省

http://www.meti.go.jp/report/tsuhaku2017/pdf/2017_00-all.pdf

イノベーションに向けて行動して行くことが重要

1. イントロダクション

1-1. AIが医療業界で使われている事例

画像解析が医療の診断にブレイクスルーを起こす

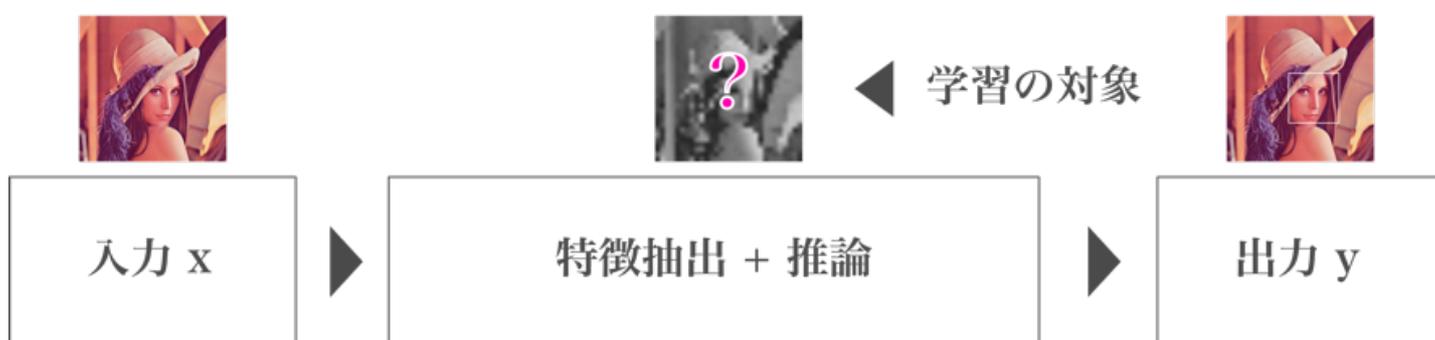
医療業界において、特に目覚ましい発展は**画像**の解析である。2012年以降、**機械学習**の一種である**ディープラーニング**という技術が登場し、それ以来、この画像分野での応用が進展してきている。この後に詳細な紹介を行うが、機械学習という技術では入力となる変数（例えば、画像）と、アクションに対応する教師データ（例えば、発作の有無）を準備することで、その規則性をデータから見つけ出し、再現することが可能になる。

ディープラーニングの登場より前から機械学習による画像の解析もよく行われてきていた。しかし、その際に障害になっていた点として、どのように画像を解析するかが人間の経験と勘により行われており、専門知識が豊富かつプログラミングによる実装ができる優秀なエンジニアがいないと実現できないといった課題があった。要するに「**専門知識**」と「**実装のスキル**」の2点が不可欠であり、コレを満たせない業界では機械学習での問題の解決が困難であったといえる。それがここに来て、ディープラーニングという技術の登場により徐々に変わりつつある。

ディープラーニング以前の機械学習



ディープラーニング以後の機械学習



この違いについて、上図を用いて説明していく。これまでの機械学習では「**特徴抽出**」と呼ばれるある対象とする現象を特定しやすくするために、機械学習の入力データを適切な形に変換する前処理が基本的に必要であった。そして、この前処理には長年の経験で培われた知識が不可欠である。

この流れは自然のように感じるであろうが、みなさんに想像してもらいたい点として、ガンの発作位置を特定しやすいような画像の前処理についてご存じだろうか。当然、知らないはずである。しかし、機械学習によって症状の発作位置を予測する場合は、このような専門的な知識が不可欠であった。

ディープラーニングで画期的であった部分は、この特徴抽出に関して理論上省略できることである。これまでの機械学習は入力、特徴抽出のロジック、教師データとなる出力の3つが必要であったことに対し、ディープラーニングではこの特徴抽出の仕組みをモデル内で表現できているため、入力データと教師データとなる出力の2つのみであれば良い。つまり、医師が病気の位置だけ特定したデータを準備しておけば、どのように病気に特徴抽出すると病気の位置を捉えやすいかといった特徴抽出のロジックを知らずとも、ディープラーニングが学習を行い、病気の位置を見つけ出せるようなシステムが完成する。

もちろん、これは理論上の話であるため、実際の案件になるとデータをしっかりみて、ディープラーニングとは言えど、前処理はある程度行うのであるが、どのような特徴量が適切かが前提知識としてわかっていない業界に置いても適用可能となり、医療に関する専門知識を持たないエンジニアにおいても、医療現場のデータ解析が可能となってきている。

電子カルテの解析も始まっている

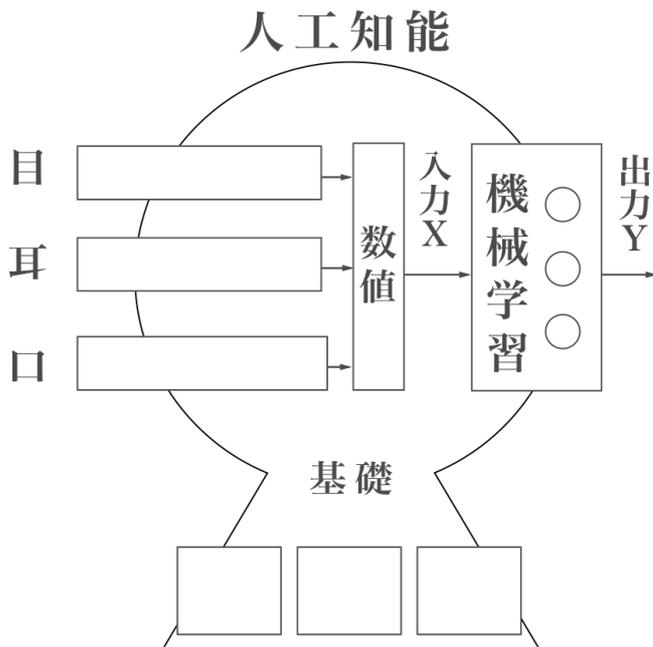
他にもカルテの電子化が進むことに寄って、より多くの文字情報が得られるようになっている。この文字情報を自然言語処理によって解析することで患者に対する有用なフィードバックが得られる可能性がある。また、医師は短時間の診察で候補が無数にある中から症状を判断しなければ行けないケースが多く、少なからず見逃してしまう場合も想定される。そこで、過去の症状を機械学習によって解析し、診断結果のアシストを行うといった研究は多く行われている。この解析には先述した画像や電子カルテのテキスト情報が非常に有用である。

しかし、気をつけなければいけないことも多くある。構想として話は始まっているが、実際に機械学習ベースの解析を導入するには難易度が高いことがある。例えば、カルテが電子化されたとは言え、病院によって記録を残しているフォーマットが統一されていないことが問題である。解析を行おうにもそのフォーマットの違いが吸収できず、結局データを蓄積したは良いが、データの統合を行う際にまた人手を要してしまい、コストが見合わずに開発に進むことはない可能性も高い。こちらの電子カルテデータの統合に関しては**医療言語処理グループ**などで積極的に議論されている。

そのためにも、データの電子化を行う前に気をつけなければいけないことがある。それはどのように使っていくかを念頭に置いて、データのため方を設計しておかなければならない。とりあえずためておくは、結局使えない可能性が低くない。そのためにも、医師はまず機械学習を利用したシステムの発注するために最低限必要なAIのリテラシーを勉強していく必要がある。

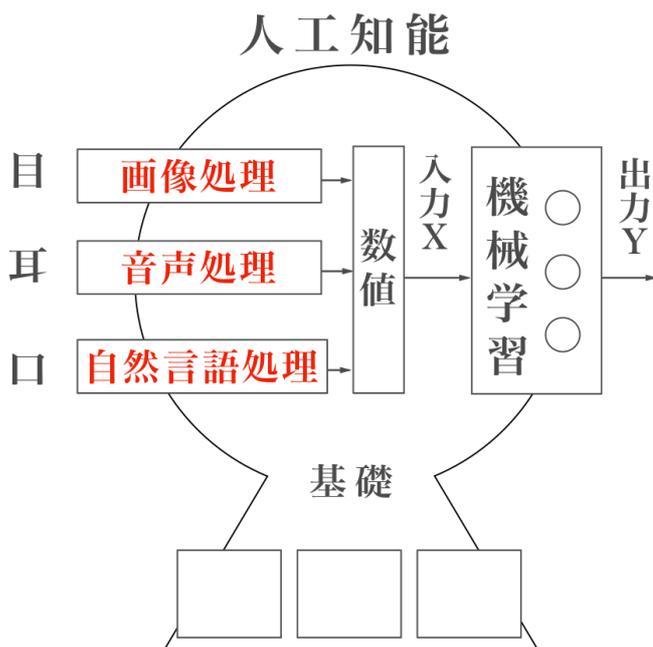
ポイントとしては、どのようなデータから何が導けるのか。具体的にどのようなデータを準備しておかないといけないのか。意味のないデータのため方とはどのようなものか。こういった発注者側のリテラシーを習得することが本講座の目的である。

1-2. AI・機械学習・ディープラーニングとは？



この業界では「AI」「機械学習」「ディープラーニング」といった言葉が飛び交い、どれも同じような意味として用いられるケースが多い。しかし、厳密にはそれぞれに位置づけの違いが存在し、発注する際にどの技術を使用するか把握しておかないと全然違うものができてしまう可能性があるため要注意である。

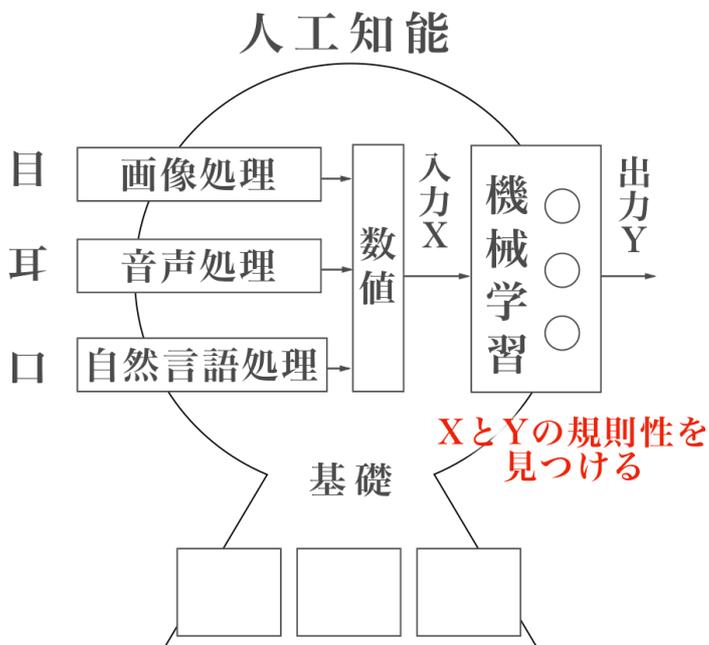
まず、包含関係から説明する。人工知能 (AI; Artificial Intelligence) が一番の大枠であり、そのAIの一部技術として機械学習が存在する。また、その機械学習の一部がディープラーニングである。このような包含関係となっているが、結局、AIと機械学習の違いはわかったであろうか。答えはおそらくNoではないだろうか。それでは、それぞれの位置づけについて下の図を使用しながら解説していく。



人工知能 (AI)

まずはじめに、AIは人間の機能を計算機によって再現したいというモチベーションで開発されており、当然、目や耳、口といった機能を再現できる必要がある。そして、目は「画像」、耳は「音声（時系列）」、口は本来食べ物であるが話すという比喩表現で「言葉（自然言語）」を取り扱える必要がある。そして、まず一番最初にこれらの入力された情報を数値として定量評価できる必要がある。コンピュータはもやとした定性的なものを扱うことはできず、数値としてしか扱うことができない。さらに突き詰めると0と1しか扱うことができないが、このあたりは現代のコンピュータではこの0と1の組み合わせで文字情報や小数点がある実数値など多様な表現が可能となっている。

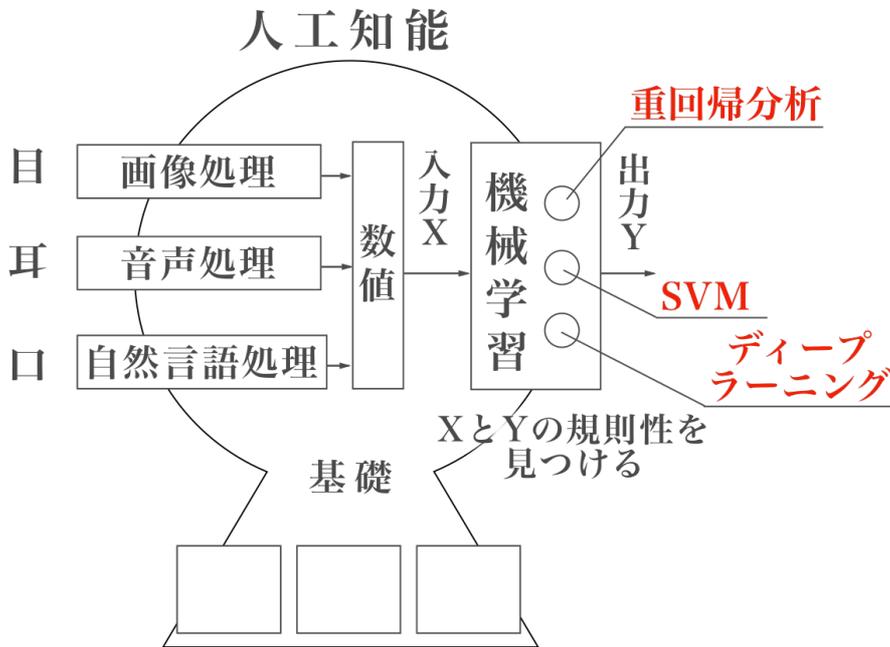
それでは、どのように画像を定量評価するのだろうか。デジタルカメラには相補型金属酸化膜半導体 (CMOS) センサと呼ばれる光の強さを感じとる素子が搭載されており、この素子が明るさを定量評価する。例えば、もし光がとても強ければ100で、光が全くなければ0といったように表現するのである。さらにカラー画像になると、写真としては1枚という印象が有るかもしれないが、Red, Green, Blueの3枚の画像から構成されており、それぞれの色に対する光の強さを定量評価して重ね合わせることでカラー画像をコンピュータ上で再現できるようになっている。次に音声は空気の振動量をマイクによって取得するわけである。そして、定量評価において、一番困難を極めるものが自然言語である。「人工知能」という単語は数値でいうといくらになるのであるだろうか。例えば4文字だから4で良いのであるだろうか。「機械学習」も4文字であり、全く別の言葉が同じ数値になってしまう変換は好ましくなく、これではいけないことがわかる。こちらに関しては、いまだに議論が続いているところであるが、気になった方は「自然言語 特徴量」と調べていただきたい。いろいろな定量評価の方法が議論されているが、最近の問題設定にあったように特徴量に変換することが主流となっており、ここにも特徴量抽出をモデル内に含んでいるディープラーニングの登場によるものが大きい。



機械学習

そして、この特徴量抽出を含めた定量評価を終えると、数値として扱えるため、コンピュータ内では画像や自然言語といった差がなくなる。そして、この数値を入力データとして何かしらのアクションに紐付け

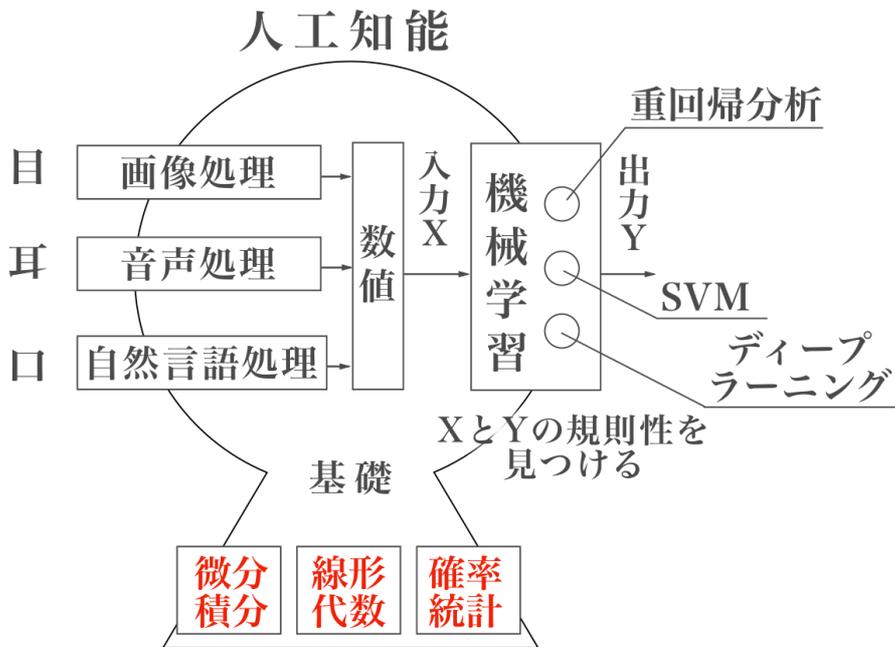
るような関係性を見つける技術が機械学習である。例えば、画像の情報が入力されて、この顔写真の画像は「佐藤さん」、この顔写真は「鈴木さん」といったように、紐付けを行うのである。この時の画像情報を入力変数、名前を出力変数と言い、機械学習ではこの入力と出力の関係性を見つける概念である。厳密には入力データだけのケースもあるが、この説明は後ほどおこなう。これで人工知能の一部として機械学習が位置づけられていることをおわかりいただけたらどうか。



ディープラーニング

機械学習はあくまで概念であり、コンピュータにとっては具体的な指示を出さないと当然、動作しない。そのため、このように「入力と出力の関係性を紐付けて」といったしじではいけないわけである。この時にコンピュータに詳細に指示を出す具体的な手順のことを**アルゴリズム**という。そして、機械学習アルゴリズムの一つがディープラーニングである。そのため、当然別の機械学習アルゴリズムも存在しており、例えば、サポートベクターマシン (SVM) などが有名である。

このように、AIという大きな概念から、その問題を解くために必要なアクションに落としていった際に、機械学習やディープラーニングという技術が存在することがわかる。

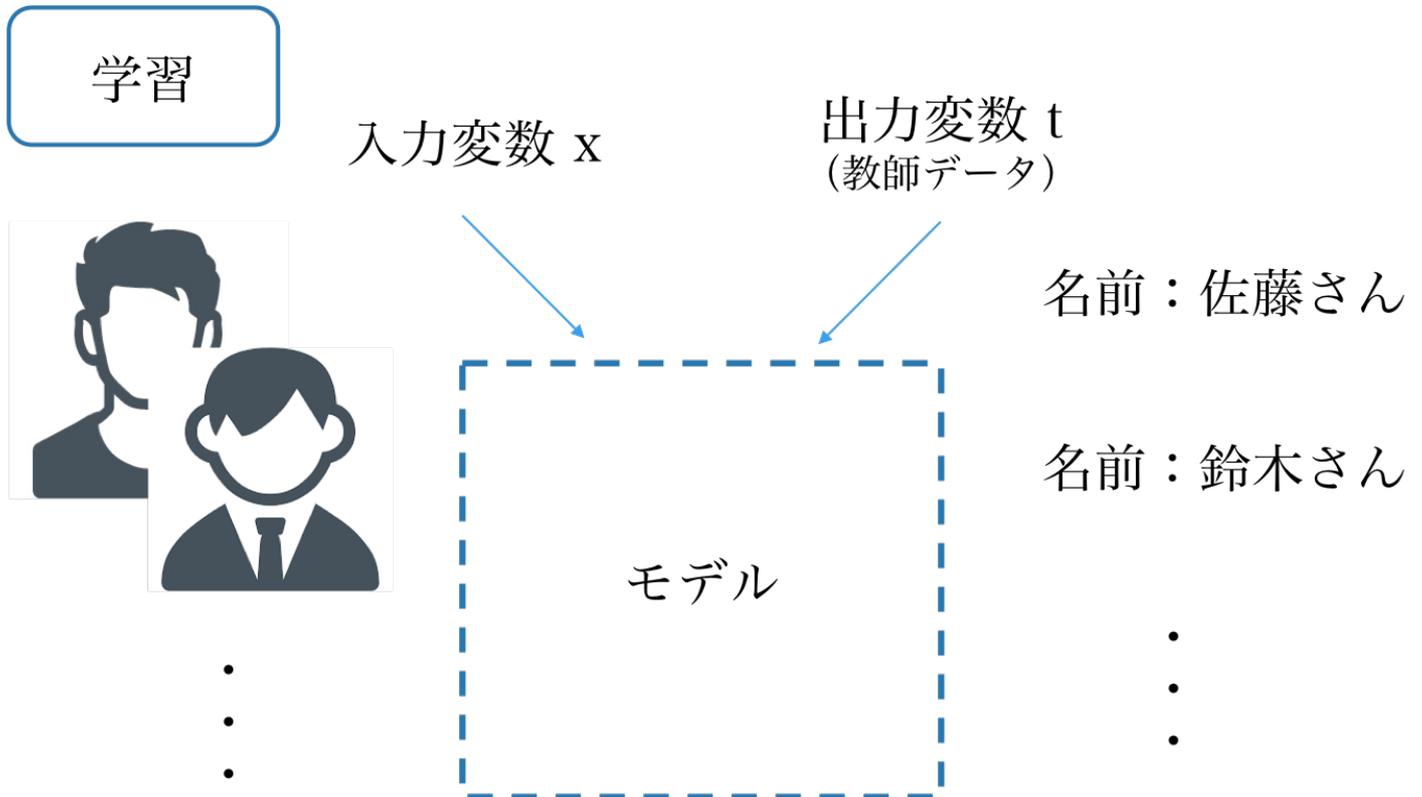


基礎となる数学

そして、この機械学習を勉強するために必要なスキルセットとしては、数学とプログラミングである。数学は基礎として、「微分積分」「線形代数」「確率統計」の3つがある。そして、プログラミングは言語を問わず開発が進んでいるが、そのメインストリームはPythonという言語である。実案件でもPythonによる解析案件が多いと言われている。

1-3. 学習と推論

プロダクトを作成する際によくあるミスを避けるために**学習**と**推論**について、その開発工程とともに説明する。



学習

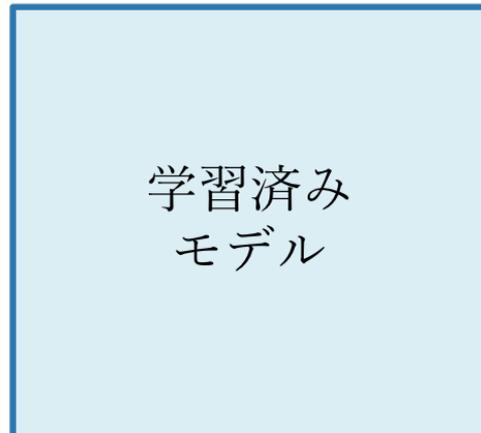
ユーザーの視点では、AIを「使う」といった印象が多いが、実際にはAI、特に機械学習の「**モデルを学習する**」といったフェーズが一番最初に必要となる。例として、顔写真から名前を予測したいという問題設定で考えてみる。

機械学習においては、最初から顔写真をもとに名前が予測できるわけではない。入力とする画像に対して、その名前を1セットで与える必要がある。この時の人間側でラベルを付けて与える出力値を**教師データ**と呼び、文字では t として書かれることが多い (teachの頭文字 t)。そして、この入力と出力の1セットになったデータを元に、機械学習のモデルを学習させる。この学習でうまくいけば、精度良く判別できるようなモデルができ、これを**学習済みモデル**と呼ぶ。

推論



入力変数 x



名前：鈴木さん

出力変数 y
(予測値)

推論

この学習済みモデルを使って予測値を計算することを **推論**と呼ぶ。サービスでユーザーが使用する際は、基本的にこの推論となっている。そのため、「AI=推論」だという誤った認識もあり、開発する際に誤解が生じてしまうため気をつける必要がある。そして、推論によって計算される予測値はよく y で表現される。

よくある間違い

実例を挙げながら学習と推論の違いについてさらに理解を深めていく。例えば、問題設定として、音声データから文字データを書き出すようなシステムを作りたいという依頼があったとする。クライアントの主張としては、過去十数年分のデータが蓄積されている。データの量にもよるが一件問題設定としては、機械学習を使えば実現可能であると考えられる。

しかし、実際に案件が始まってデータを見てみると、音声情報が十数年分蓄積されているが、それに対応した文字の情報が全くないことが発覚する。今回の問題設定を振り返ってみると、音声情報を入力として、出力には文字情報と設定する必要があった。そのため、これでは文字を書き起こすことができない。なぜか分かるだろうか。

入力として音声の情報があり、そしてその出力に対応するところとして、その音声に紐付いた文字の情報がラベル付けされている必要があるが、音声の情報しかなかったのである。

このように機械学習を適用する際には、学習と推論を意識してデータを蓄積しておく必要があり、ただ単に蓄積だけし続けたデータではアクションに紐付いていないため、特に価値を発揮することができない。そのため、機械学習で使用することを念頭にデータベースや問題設定を設計した後にデータを蓄積し、あ

る程度蓄積ができたタイミングでモデルを学習して使っていくことが望ましい流れである。

2. 機械学習概論

2-1. 機械学習の3大トピック

機械学習は大きく3つに分類される。1つ目が**教師あり学習**、2つ目が**教師なし学習**、そして、3つ目が**強化学習**である。この3つの違いを正確に把握しておくことで、依頼する際に教師あり学習か、教師なし学習か、それとも強化学習であるのかを判断できる。

教師あり学習

教師あり学習は、入力となるデータ (X) と出力となるデータ (Y) がセットで揃っており、入力から出力を予測するモデルを作る。たとえば、「駅からの距離や部屋の広さ (入力 X) から家賃 (出力 Y) を予測する」「画像 (X) から男性か女性といった性別 (出力 Y) を識別する」といった問題設定が挙げられる。

教師なし学習

教師なし学習は、入力となるデータ (X) のみで、データの背後に存在する本質的な構造を抽出する。「顧客データ (入力 X) を似ている属性ごとに分ける」「大量のデータ (入力 X) の中から情報として密度の高い部分のみ抽出する」といった問題設定が挙げられる。

強化学習

強化学習はある環境内におけるエージェントが、現在の状態を観測し、取るべき行動を決定する。一言で説明するなら身近なお掃除ロボットを考えていただきたい。実際には全く始めデータがない状態の中、つまり部屋の床に置かれているかもわからず、かつ部屋の広さや家具の配置情報も全くわからない状態の中でスタートする。そして、動きながら部屋の情報を収集し、そのデータに基づいて、部屋を最短で掃除できるように行動を決定していく。

3つの違い

教師あり学習では、最初から人間側で入力 X と出力 Y についてデータが準備されており、こちらを元にその X と Y の規則性を見つける。それに対し、教師なし学習では、入力 X しか情報が与えられておらず、その中でその入力 X にはどのようなデータの構造になっているかを考えていく。そして、強化学習では入力も出力も与えられていない中で、自ら動きながらデータを収集し、そしてそのデータをもとにモデルを構築していく。

ビジネス活用を視野に入れた場合

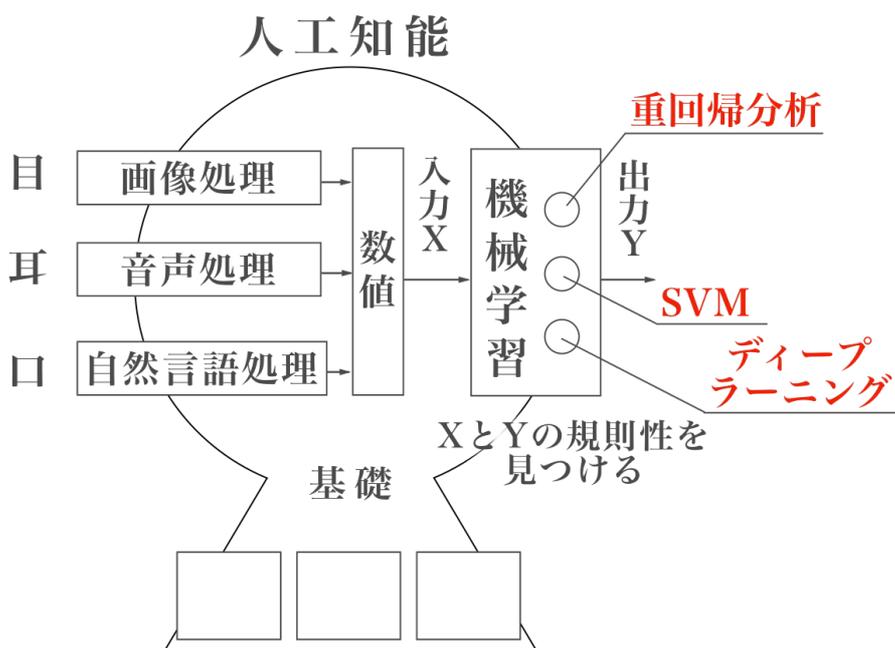
ビジネスの現場において、効果を発揮できるのは教師あり学習が多い。もちろん、教師なし学習や強化学習に関しても、研究開発で使用されているケースは多々あるが、最終的な納品を考えると教師あり学習で

ないと難しいことがわかる。

納品する際には、最終的に何パーセントの精度が確保できているかといった結果を当然把握する必要がある。教師なし学習の場合は、実際には教師となるデータがないため、「検証」が難しくなる。そのため、最終的にモデルは作ったものの、結局何パーセントぐらいの精度が出るかは、現場に投入してみるまで分からない。そうなると実際にどのぐらいの精度が出るかわからないものはリスクが高く、導入するための意思決定ができない。

それに対して、教師あり学習では手持ちのデータを、学習に使用する**訓練データ**と検証のみで使用する**検証データ**に分割することで、未知のデータに対する結果を模して検証を行うことができる。もちろん検証データも過去のデータではあるため、未来に対する結果を保証するものではないが、この結果があるとならば信頼性が大きく違ってくる。そのため、発注者側としては教師あり学習として発注することが望ましいと言える。

2-2. 機械学習アルゴリズム



教師あり、学習教師なし学習、強化学習についての概略を学んだため、それぞれに対して、さらに具体的な手法まで深掘りする。

教師あり学習：回帰と分類

教師あり学習はまず大きく分けて、**回帰**と**分類**に分かれる。

回帰では出力の値が数値となる。もう少し厳密に言うと、**連続値**を予測するのが回帰である。例えば、家賃の値や株価の値と言った連続値を予測するという問題設定である。有名な手法としては、**重回帰分析**や**ロジスティック回帰**、**ニューラルネットワーク**がある。

それに対して、分類では**カテゴリ**を予測する。例えば、赤ワイン・白ワイン・ロゼと言った3カテゴリの分類であったり、男性・女性のように、予め決められたカテゴリのどこに属するかを決定する問題設定である。有名な手法としては、**決定木**や**ニューラルネットワーク**がある。

教師なし学習：クラスタリングと次元削減

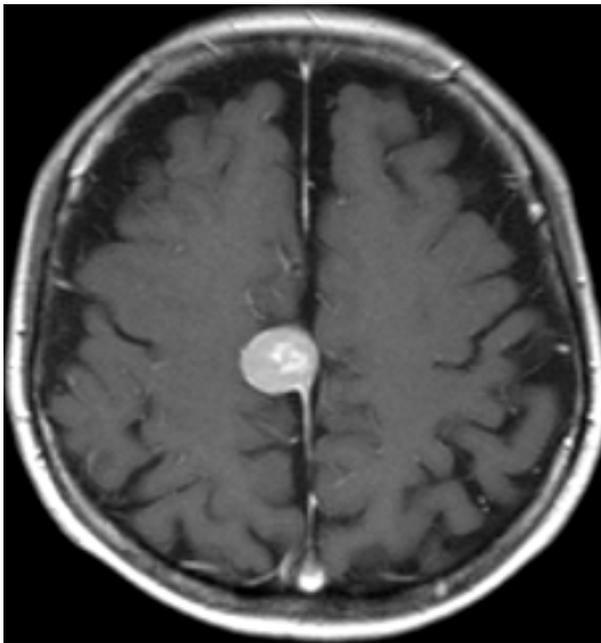
次に教師なし学習では、**クラスタリング**と**次元削減**が有名である。

クラスタリング (Clustering) では、データ間の距離が近いところもの同士で分けるといったことが行われる。これは一件、教師あり学習の分類 (Classification) に似ているが、異なるものである。なぜなら、分類は教師あり学習であるため、どのカテゴリに属するかという教師データがあらかじめ与えられており、クラスタリングは、結局この人が男性なのか女性なのかといったデータは存在しない。そのため、基本的には人間の事前知識と照らし合わせながら解決策として導入していくことで、現場で活用できる。有名な手法としては、**k-近傍法**などがある。

そして、**次元削減**では、入力変数の数が大きい場合に、変数の数を圧縮する。例えば、与えられたデータが100次元、つまり列の数が100個あったときに、全てのデータを使用することが望ましいとは限らない。少し技術的な話になるが、**多重共線性**と呼ばれる入力変数同士が強い相関を持つことで、予測に悪影響をもたらすといった問題が知られている。そのため、入力変数同士が相関を持たないように、次元を減らす（つまり次元削減）を行うことで、予測精度の向上に寄与することがある。そのため、教師あり学習の前処理として、この次元削減が用いられる場合も多く、有名な手法だと**主成分分析**などがある。

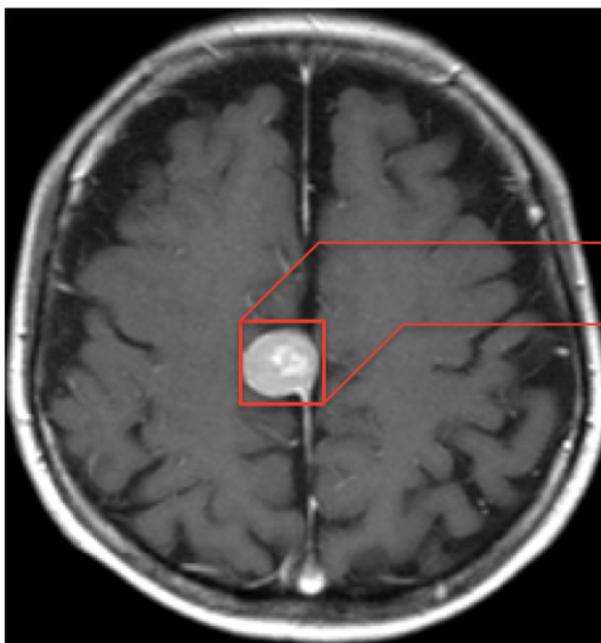
強化学習に関しては、最近**DQN**と呼ばれる**深層強化学習**、つまり、ディープラーニングと強化学習を組み合わせた手法がよく取り上げられる。AlphaGoが囲碁で人間に勝利した時に使われていた手法である。このDQNと呼ばれる手法の中でも使われているが、主に**Q学習**と呼ばれる手法が有名である。

2-3. 演習課題



実際に機械学習の位置付けを把握できたところで、演習問題を行う。今回はMRIの画像データから、腫瘍位置を機械学習アルゴリズムによって見つけたいというシステムを構築する。

あなたの手元には上記のようなMRI画像があり、教師データとしてどのようなデータを準備することが必要となるかを問題設定から考えてほしい。ヒントとしては最終的にどのような情報が欲しいのかである。



それでは、答え合わせをおこなう。まず画像の中から抽出したい情報として、「腫瘍がどこにあるのか」である。

これは2つの手法が組み合わさって実現できる。まず1つ目が腫瘍か否かを問わず、物体を検出する手法

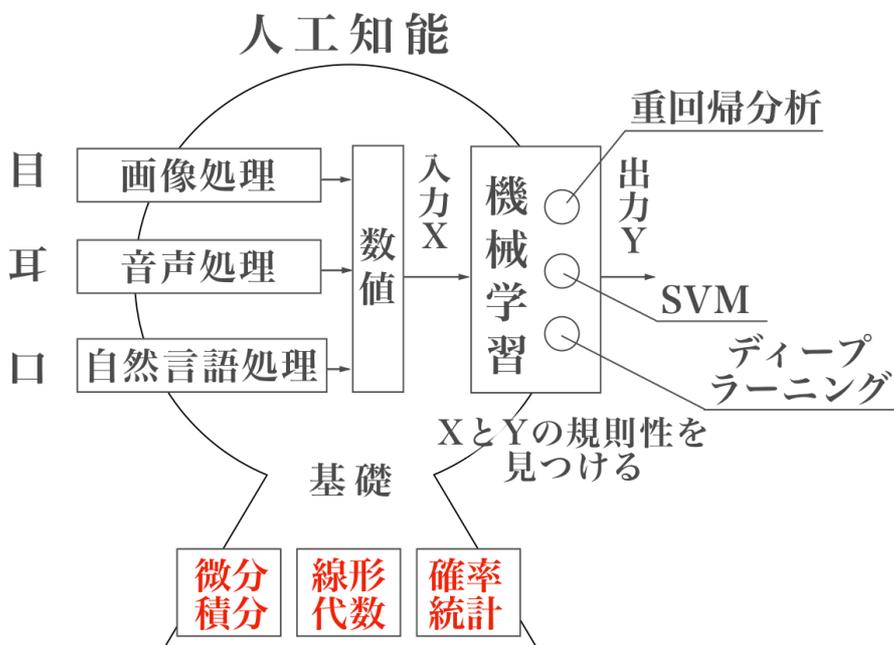
である。そして、その検出された物体が腫瘍であるか否かといった2カテゴリの分類となる。

これを実現するためには、教師データとして、腫瘍の箇所の**座標情報**が必要となる。単に腫瘍の有無だけでなく、どの位置に腫瘍があるのかまで教師データとして与える必要がある。そのため、上記の画像がその答えとなる。

画像系はよく畳み込みニューラルネットワーク（CNN; Convolutional Neural Network）が使用されるケースが多く、今回のような領域まで特定する場合は、R-CNN（Region with CNN）がよく使用される。つまり、あなたが発注をかけたいときには、R-CNNで検討したいと告げ、さらには、どこに腫瘍があるのかの座標情報を教師データとしてつけておいたという情報を渡すことができれば、あとは機械学習エンジニアが腫瘍を発見できるようなモデルを作成してくれる。

3. 機械学習の周辺技術

3-1. 機械学習に必要な数学

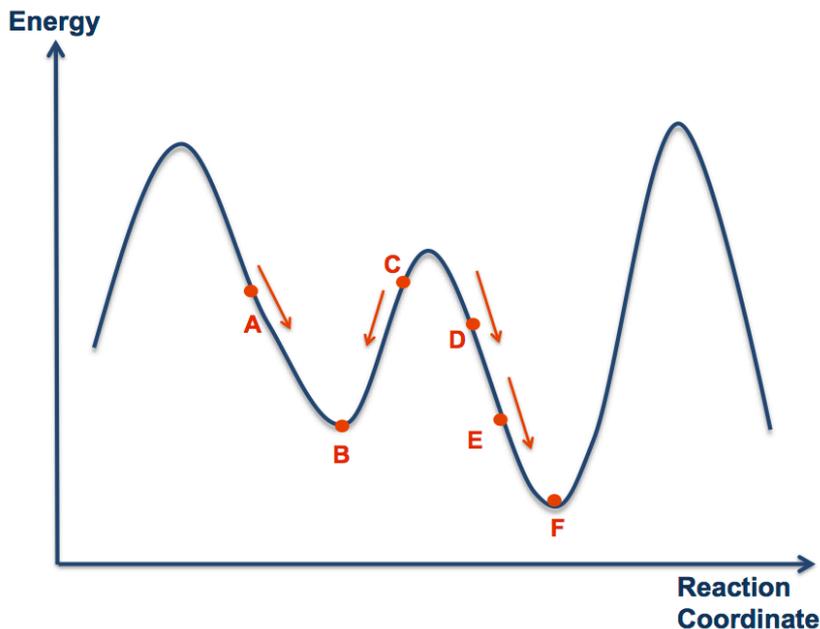


先述したとおり、機械学習に必要な数学は「微分積分」「線形代数」「確率統計」の大きくわけて3つがある。この3つが機械学習を使用していく上で必要不可欠といえる。しかし、最初から全てを習得することは難しく、特に発注側の立場であれば、議論をする際に抑えておくべき用語とそれらの数学が使用される用途だけ把握しておけば最初のステップとしては良い。

微分積分

まず微分積分であるが、高校の時はセットで習うことに対し、機械学習では微分と積分は別々の用途に使用される。

微分は**傾きを求める**といったことが使用用途のゴールとなる。そして、この傾きを使うことによってどのような恩恵を預かることができるのか出たところがポイントとなる。



上記の図で解説を行う。各点において傾きを求めることで、関数がどの地点で最小値を持つのかを把握できるようになる。機械学習の中では、評価関数や損失関数といって、実際のデータとの誤差を小さくしたいという問題設定が多く登場し、その際にこの誤差を最小化できる手段がとても有用である。そこに使用される技術に微分が適用されているわけである。

積分は**ベイズ統計**と呼ばれる難易度が高い機械学習の手法で登場し、主に時系列データなどのある区間に関する**面積**を計算するというように使用される。

線形代数

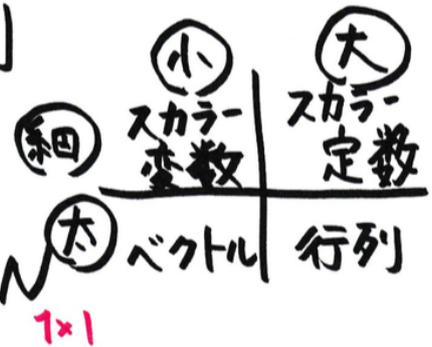
機械学習を勉強する際に最も重要だと言われるのが、**線形代数**である。

線形代数を大学の一般教養で勉強する際には、線形空間や補空間など、難しい用語がたくさん出てくるが、まず発注者側として開発側とすり合わせを行う際に絶対に抑えておくべき用語は**スカラー**、**ベクトル**、**行列**である。発注者サイドは、この用語が理解できていないと議論している際に難しい話をしているのか容易な話であるのかもわからなくなってしまう。

◎ スカラー, ベクトル, 行列

○ スカラー

x, y, z, M, N



○ ベクトル

$$x = \begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix} \quad 3 \times 1$$

$$y = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_N \end{bmatrix} \quad N \times 1$$

○ 行列 (マトリックス)

$$(\times) X = \begin{bmatrix} x_{11} & x_{12} \\ x_{21} & x_{22} \\ x_{31} & x_{32} \end{bmatrix}$$

$$x^T = [x_1 \ x_2 \ x_3]$$

転置
サイズ
3 × 2
行 列

上記の画像で説明する通り、スカラーは1つの文字を表しており、それらを複数まとめたものがベクトル、そのベクトルをさらに行と列の方向に拡張したものが行列である。機械学習では、データの数が多いため、スカラーだけでは表現しきれず、これらの情報をまとめてベクトルや行列という形にすることで、非常にスッキリとした議論を行うことができるのである。これが線形代数を学ぶ大きな目的である。特にわざわざ難しい計算をしようとするわけではなく、情報をうまく整理して扱うための学問として線形代数が用いられている。

確率統計

機械学習といえばまず確率統計が必要という印象が強いかもしれないが、意外にも初歩的な機械学習では確率統計の知識がそれほど大きくは必要ない。

線形代数をベースとした機械学習では、平均、分散、標準偏差、そして正規分布といった初歩的な確率統計の基礎を抑えておくだけで議論に参加できる。

そして、ベイズ統計と言われるさらに難しいな手法を勉強する際には、確率密度関数であったり、そこから派生していく難しい数式が必要不可欠となる。こちらは、開発側が把握しておけば良いため、発注者側としてはそれほどの深掘りは一旦必要ない。

3-2. プログラミングと環境開発

ソフトウェア

- OS (Operating System)



- プログラミング言語



- フレームワーク



- API



機械学習は数学だけではなく、**プログラミング**の知識が必須となる。また、プログラミングを行うに伴って、**OS**、**プログラミング言語**、**フレームワーク (ライブラリ)**、**API**といったソフトウェアに関するその周辺知識に関して必要となっている。さらに最近では、大量のデータが入手できるようになったため、その大量のデータを処理するためにも、自前のコンピュータではなく、別の計算機で処理させることも一般的になってきました。そのため、計算機 (ハードウェア) に関する周辺知識も必要となっている。

OS (Operating System)

OSとは、その概念の説明よりも、WindowsやOS X、Linuxといった具体的な名称を聞くとわかりやすいと思う。ハードウェアの制御とユーザーが使用するアプリケーションのベースを取り持つ役割の部分である。このOSごとに解析環境の設定が大きく異なり、ユーザー間の環境の差や、ローカル (手元の計算機) とリモート (手元以外の計算機) によるOSの差によって、環境構築に非常に手間がかかることが多々ある。最近では、**Docker**と呼ばれるサービスの登場により、OS間の差を埋めることができるようになり、ローカルで構築していた環境を、そのままリモートへと手軽に移植できるようになっている。機械学習領域では、**Ubuntu**と呼ばれるLinuxディストリビューションの一種がよく使用される。特に問題がなければ、依頼する際には、UbuntuをOSとして指定しておくが良い。

プログラミング言語

機械学習でよく使用されるプログラミング言語としては、**Python**がある。それ以外にも**R**言語や

MATLAB、**JAVA** といった言語も存在するが、多くの解析案件ではPythonがよく使用されるため、特に問題がなければPythonを発注する際のプログラミング言語として使用すると良い。Pythonが好まれる理由としては、もともとアプリケーション向けの言語として開発されているため、単なる解析だけでなく、システム統合すると言った際にもシームレスに行うことができる。また、Pythonを使用した機械学習のコミュニティが非常に盛り上がり、その結果Pythonのプログラミングに関するリファレンスがインターネット上で多く存在する。これは、初心者でも勉強する敷居が低くなっていることを意味しており、これから採用する際の育成も容易であることにも繋がる。どのプログラミング言語を使用するかという事は一番最初に決定する必要があり、最終的に**人の採用**であったりとか**引き継ぎの容易さ**といった観点まで考慮することが大事である。

ハードウェア

- オンプレミス

自社内など購入して保有するサーバー

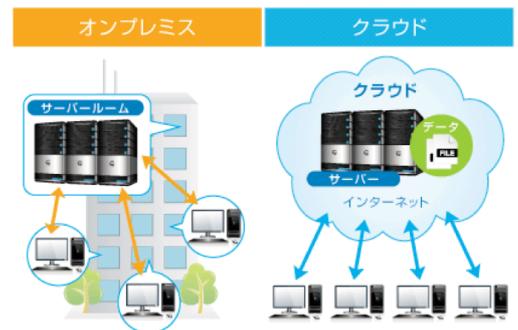
- 大規模運用であれば**コストメリット**あり
- スケールするために**初期費用**がかかる

- クラウド

時間単位などでレンタルするサーバー

- **リソースの変動**を吸収できる
- **メンテナンスコスト**を抑えられる

- IaaS, PaaS, SaaS



画像：[オンプレミスか？クラウドか？](#)

解析環境

また見落とされがちになっている点としてプログラミングを行う以上は開発環境解析する環境の構築を行う必要がある。最近では、簡単にインストールできるようなソフトウェアも増えてきたため、ローカルでの解析環境の構築はそこまで難しくはない。

しかし、ディープラーニングの登場やビッグデータ解析によって、非常にリッチな環境が解析において必要となる場面が多くなってきた。そのために、**クラウド**や**オンプレミス**を問わず、リモート上の計算機を使用することの重要性が増している。

Pythonでは、Jupyter Notebookと呼ばれる環境で解析を行う人が増えており、こちらではWebブラウザが解析環境となる。そのため、このWebブラウザベースの仕組みによって、ローカルで解析を行う場合も、リモートの環境を使用して解析を行う場合にもほとんど差異を意識することなく解析を行うことができる。

最近ではDockerで開発環境を丸ごとコピーして、他の人に渡せるため、ソースコードの共有だけでなく、開発環境の共有も併せて行うことが一般的になっている。こういった解析の環境に関しても最終的にどのように引き継ぐのか、そしてその環境が今後使えるのかと言った観点が重要である。納品される際に、学習済みモデルだけは納品してもらおうといったケースでなく、今後も解析を続ける場合、その解析環境についても自前で使えるように発注する必要が出てくる。この際にクラウドを選択するのかオンプレミスを選択するのかデータ周辺環境についても知識がないと、開発側の思い通りとなってしまうため、事前にこの流れを把握しておくことが重要である。

3-3. 機械学習がよく使われる領域

画像

近年、画像データの解析に関して非常に盛り上がっている。画像データは単純に入力変数として使用する際には縦かける横、さらにカラー画像の場合は CHANNEL という部分も追加されて、非常に多くの画素数になる。例えば、縦が100ピクセル、横が300ピクセルのカラー画像の場合、100かける300かける3チャンネルで合計9万ピクセルとなる。単純な機械学習の入力変数として扱う場合入力変数の数が90000となる。実際には1枚の画像であるため90000の入力変数という問題設定にするとモデルの学習が非常に難しくなってしまう。

ここでパラメータの数を減らすということが非常に大きな問題である、この解決策として、**畳み込みニューラルネットワーク (CNN)** が登場している。これは古くからあった画像処理のフィルタという概念をパラメータとして適用することでパラメータの数を減らし、かつ画像としての特性もうまく考慮しながら学習させることが可能になっている。CNNはディープラーニングの一種であり、医療画像に関してもこのCNNによって多くのブレークスルーが起こっている。

時系列

時系列に関しては、前のデータによる影響をうまく表現するために、これもディープラーニングの一種だが、**リカレントニューラルネットワーク (RNN; Recurrent Neural Network)** が提案されている。従来から時系列向けのニューラルネットワークもあったが、最近ではこちらに置き換えられるケースが非常に多くなり、時系列解析のスタンダードとなっている。また、画像と時系列を組み合わせることで、動画としての処理も可能である。

自然言語

そして最後が自然言語である。こちらはテキストを扱うような場合である。冒頭で紹介した通り、自然言語の処理に関しては、単語が数値で言えばいくらなのかといった定量評価が非常に難しく、こちらに関しても特徴量を選択できるようなニューラルネットワークがとても活躍している。

また、覚えておいていただきたい点として、自然言語データは現場に導入する際の難易度が高い場合がある。それは、文章の生成といった問題設定の時に起こるため、例を交えて紹介する。文章生成の際に、「私は機械学習を勉強しています。」という情報が正解だったとする。このときに、機械学習アルゴリズムで予測した結果が「機械学習を私は勉強しています。」であった際に、人間であれば概ね合っていると判断できるが、機械側では順番が異なっているため、不正解であると判断してしまう。この問題に関して、機械学習側での正解の判断と人間側の正解の判断が異なってしまう。正解率が低いように見えた際にもこのような問題で語順が違うだけであるのか、選ぶ単語も間違っているのかといったところの検証が必要となり、こちらは人間が手動で行う以外、適切に判断できるものがない場合が多い。

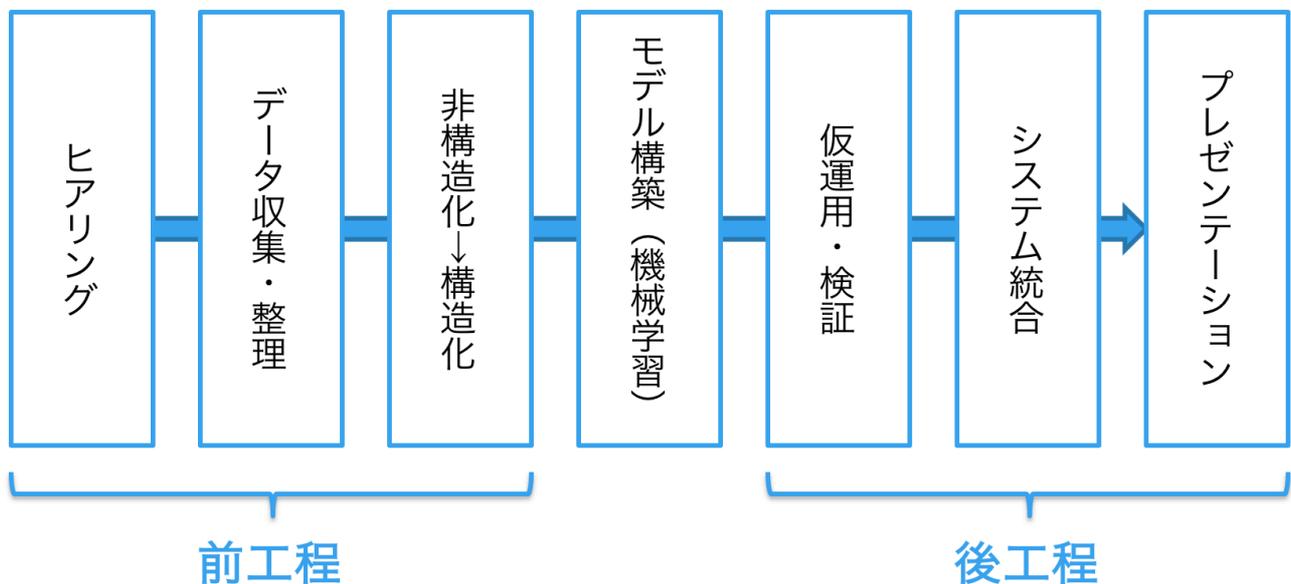
ビジネスへの応用

4-1. ビジネスフロー

機械学習案件が扱うべきスコープ

機械学習を実際に実践する際のビジネスフローについて紹介していく。機械学習を始めたばかりの初心者は、モデル構築と呼ばれる数学とプログラミングを使った箇所についての仕事のみがフォーカスが当たりがちである。つまり、入力と出力（教師）データをクライアントから受け取り、それに対して、その入力と出力をうまく紐づけるようなモデルを作るということである。

しかし、実案件のスコープはモデル構築だけでなく、以下の図の通り、遥かにそれよりも広いのである。



大まかな流れ

一番最初にどのようなビジネスを行っているかと言ったビジネスアンダースタANDINGを行うヒアリングの作業が必要となる。そしてそのビジネスを成功させるために必要なデータの収集それから整理について作業を行うことになる。

これらのデータは最初から数値化されているケースは少なく、文章といったものや画像をとといったものに関して非構造化データから構造化データへ変換する必要がある。

その後、この構造化されたデータをもとにモデル構築を行う。このモデル構築の部分に機械学習を使用する。例えばディープラーニングや、簡単な方法では重回帰分析など、最もその問題に適した手法をエンジニアが選択して適用する。

そして実際に次の日からうまくいくのか、次のデータからうまくいくのかということに関して保証を求められるケースが多くあるため、まずは仮の運用を行いながら検証作業を行っていくことをしばしば行う。

その仮運用の後、うまく実装ができていればシステムをとの統合を行っていく。

また最終的にどのようなシステムであるかについてのプレゼンテーションやドキュメンテーションの作業が必要である。

それでは、続いて各工程について、落とし穴も踏まえて紹介する。

ヒアリング

まずヒアリングの作業だが、この時に大事なことは、最終的なシステムの統合を視野に入れながらヒアリングをすることである。クライアントは「AIを使いたい」というような曖昧な段階で相談をする。その際に相談を受ける側としては、相談内容を実現するためには、どのように構造化をする必要があるか、どのようなデータが必要であるか、どのような問題設定が必要であるか、最終的にシステムに統合する際にはどの程度の精度が必要であるか、システムの統合する際にはどのような技術選定を行うべきか、といった言葉で具体的に案件として仕様を固める必要がある。

更にこのヒアリングの段階で各工程を細かく、どのような落とし穴があるかも含めて分解し、どの程度の期間がかかるのかといったことを検討する必要がある。大きく時間がかかるポイントとしてはデータ収集や、そのデータ収集の前に存在する、解析環境構築といったところがある。そのため、どのようなデータが既に入手可能であるのか、そのデータはクライアントの環境でしか使えないのかそれともデータとして自分たちの環境で解析できるのか、クライアント側でしかデータが使えない場合はどのように解析環境構築すればいいか、といったことまで、実際のフローに結びつくようにしっかりとヒアリングする必要がある。

ここに関しては、遅かれ早かれ行う必要があるが、最初にざっくりとした要件だけを決めて進めてしまうことも少なからずあり、最終的に想定していた時間内に終わらないと言ったことでクライアントの期待値と異なってしまいうケースも多く存在する。そのため丁寧にヒアリングを行い、どのようなデータの扱い方、フローになるかもしっかりと固めておく必要がある。

他方発注側では、この受注者サイドの事情を把握しながらどのようなデータを出すことができるか、そして教師データとして紐付いているか、自分たちのデータがクライアント先に渡すことができるのか、そのためには秘密保持契約書との契約書の準備であったり上長の許可また医療であれば倫理審査頭を通す必要があるためデータを共有する際のフローを依頼する前に把握しておくことで、受注者再度とすり合わせる際に無駄な時間を過ごすことを減らすことができる。

ヒアリングの際に非常に重要なこととして、最終的な程度であったりデータの量からできるできないと言った判断を下すことをあらかじめよくなっていくことも大事だが、実現できるがやらないといった判断を下すことも非常に重要である。

これは開発コストに対して得られるパフォーマンスが低い場合に、できるけれどもやらないと言った判断

を下すことである。例としては、事務作業に関して自動化したいといった場合である。機械学習を使って毎日同じように繰り返している事務作業を自動運用したいというとき、多くの場合かけた開発費用に対して、例えば0.5人月の工数を削減できたとしても、一人当たり20万円の人件費の半分だとすると、月間10万円程度のコスト削減にしかない。

これに加え基本的にAIで精度100%を保持することは困難であり、人間のチェックが必要となるため、0.5人月程度のチェックの工数が必要となる。

これに対して開発費用は少なくとも500万円、通常は数千万円といった規模になる。この人件費10万円では、開発費にかけた金額を回収するのに長い期間が必要になり、また機械学習のモデルでは、最終的に出来上がったモデルをずっと使い続けるのではなく、適宜メンテナンスが必要となるため、運用コストとして毎月数万円から数十万円かかるケースもある。

そのため、この10万円しかコスト削減できないケースにおいては開発を行うメリットは非常に少ない、もしくは赤字になってしまうことが想定される。費用対効果については、最初の段階でしっかりと検討する必要がある。

データ収集・整理

次にデータ収集整理に関してである。前述の通り、まずどのようなデータが必要であるかということヒアリングの段階で固めておく。これはどのようなデータが使用可能であるのかと言った発注者側からの提案に基づいて、受注者側でどのように使用していくかを検討していく。

そのため、発注を行う際にはどのようなデータが使用可能であるのかということ先を先に明確にする必要がある。この際使えるデータなら何でも出していい訳ではなく、ある程度を構造化する目処が立っているものである必要がある。完璧に構造化できている必要はないが、例えば紙データでしか残っていないであるとか、メールに書いてあるやり取りをデータとするようなケースは、実際に機械学習をかける際に紙の情報から文字情報を書き起こしたり、メールの文章から必要な文章だけを抜き出したりといった、人間側の前処理の工数が非常に多く発生する。

こちらに関しても、時間とお金をかければ対応可能ではあるが、開発期間が非常に長くなり、コストもかなり大きくなる。かけた時間に対して思ったような期待値が得られないようなケースも多々あるため、初めてのプロジェクトに関しては、既にデータが構造化できる目処がある情報を使用することを推奨する。

データ収集の際には、ファイルとして受け渡しできるのが一番楽なケースである。この際には、入力変数となるものと教師データとなるものを準備する。例えば画像の場合は、フォルダごとに教師データの情報のフォルダごとに画像が分かれているとベストである。

また医療の画像と異常検知において注意しなければいけないことが、データ収集の段階で一つ存在する。それは異常のデータが非常に少ないという問題である。基本的には正常状態であるため、異常のデータを集めることは困難であることはあるが、教師あり学習において異常と正常を分類するためには、異常のデータも正常のデータと同等の量が必要となる。

もちろんデータ解析側でうまく処理を行ってデータの水増しを行うこともできるが、理想的には正常デー

タと同等量の異常データが必要となる。逆にいえば、異常データの量に合わせて正常データを間引くため、異常のデータがどれだけ集まっているかによって機械学習に使用できるデータの量というものが決まる。

またこの際に、そのデータをどのように受け渡すのか、その際に必要な契約書は何か、環境はどのようなものが必要かというところはしっかりと押さえておく必要がある。データ解析を行う側としては、クラウドを使用することが最も手軽であり、大きなリソースを使う際にもリスクが少ないため、クラウドを使用することは可能か検討するのが良い。その際にこういった要件であればクラウドを使用できるか、もしくはオンプレミス以外の解析は不可能かというところを事前に把握しておく。

非構造化->構造化

非構造化から構造化に関しては、エンジニア側の作業である。文章といったデータをいかに定量的に評価をするか、そしてエクセルのカラムのように、行と列に置き換えてデータを格納するような形式に変換していく。そのため、この構造化データを作成することを前提としてデータを準備する必要がある。

モデル構築（機械学習）

モデル構築は受注者サイドの作業となるため、発注者側で特にどのモデルを使用してほしいというような依頼を行うことはないが、例えばディープラーニングを使用してほしいなど要件が最初からあれば把握しておく必要がある。

また発注する際には、業者によって画像が得意な業者、自然言語が得意な業者、時系列が得意な業者といったように得意領域が異なるため、実績のある企業を選ぶとよい。実績はホームページで過去にどのような案件を行ったのかというところを見れば確認可能である。

このモデル構築の最終的なゴールは、与えられたデータを訓練と検証データに分け、その検証データに対する予測値や精度がどの程度になるかを検証することである。そのため納品物としては、この段階ではレポートとなる。このレポートの段階で、発注者側が納得すれば、次の仮運用やシステム統合に移行していく。

発注先の選定基準としては、すでに類似案件を経験しているかが重要である。すでに経験があれば、前処理等のノウハウたまっていたり、すでに構築されている別の案件で構築されている学習済みモデルが使用できる場合がある。別案件であったとしても、類似案件の学習済みモデルをベースにチューニングすることで、準備できるデータの量が少なくても、良い精度が出せる場合が多くある。これを転移学習といい、ディープラーニングではファインチューニングという技術に応用している。そのため、経験的にも実装的にも、類似案件の経験があるかは重要な選択基準となるのである。

仮運用・検証

モデル構築が上手くいった場合でも、あくまでそれは訓練データに対する精度であるため、実際に運用した際の結果とは異なってくるケースが多くある。あくまで訓練データは過去のデータであるためである。そのためモデル構築後も、どの程度の結果が出るのかを仮運用しながら検証していく必要がある。

特に知識のない発注者側の場合、検証というところのモデル構築の際の検証データに関する検証をさすことで納得するが、実際に解析を進めてみると検証データというものはデータ解析側で何パーセント選択をするのかと言ったことを恣意的に決めることができ、良い結果が出るような検証データの選び方をしているケースも少なからず存在する。そのため本当に運用フェーズでうまくいくとは限らず、実際に適用してみることが重要となり、これが仮運用をしながらの検証ということである。

ここで仮運用しながら検証を行うと、過去のデータに対する予測値を計算していた仕組みとは異なり、定期的に予測値を計算すると言った仕組みや、誰でも使えるようにアプリケーションに落とし込んでいく工程が発生する。これに関してはデータ解析とはまた異なるアプリケーションを作っていくような技術が必要となるため、ここで大きな費用が発生する。そのため仮運用を始めてからでは費用対効果が合わないケースも多々あるため、モデル構築の段階でレポート納品としてまずマイルストーン置いておくことを推奨する。仮運用を行いながら、もしうまくいかないケースであればモデル構築を再度見直していく。

システム統合

仮運用がうまくいった際には、開発したものを既存のシステムに統合する工程がある。既存のシステムがない場合は新しくウェブアプリケーションを作るということもある。

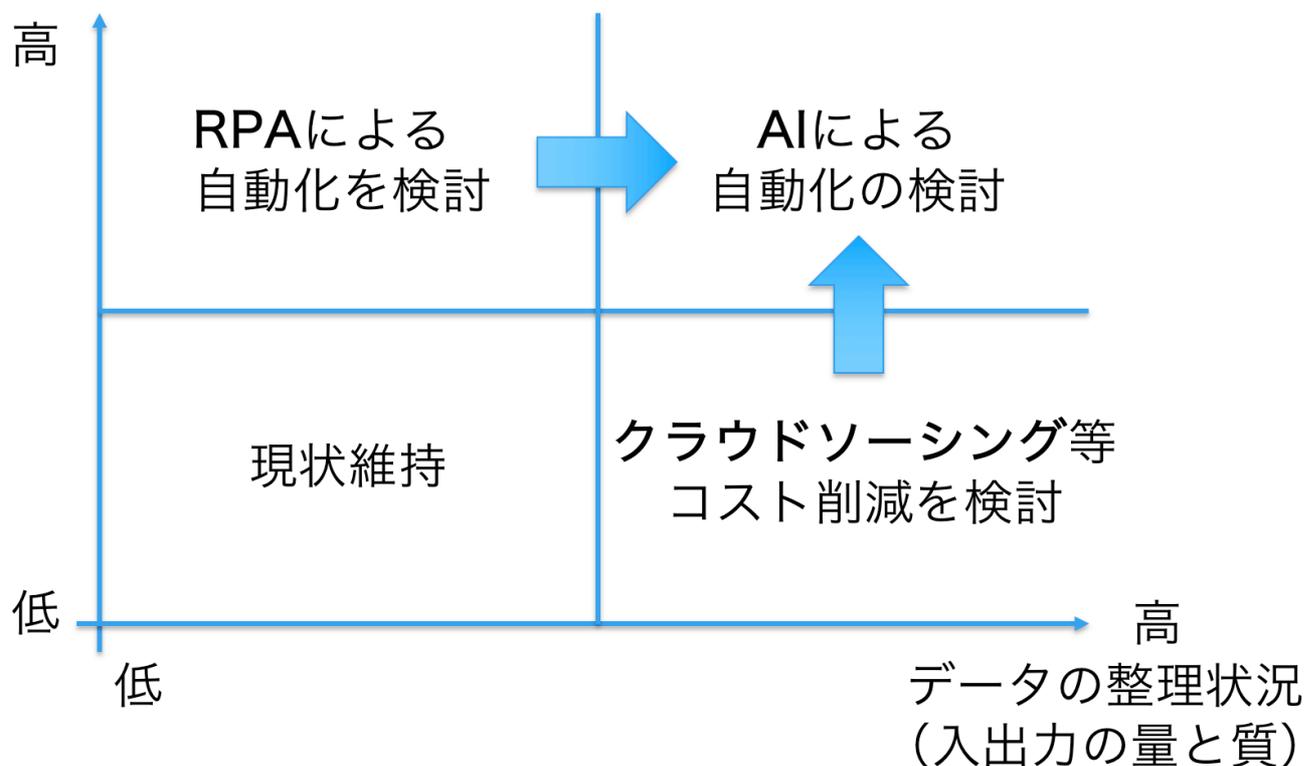
この際に、発注者側としては既存のシステムがどういう仕組みで作られているのか、どの業者によって作られているのかを考えておく必要がある。特に医療系ではベンダーが限られており、自前で作ったシステムを他の医師が使えるように統合するということは容易ではない。

またPMDAと言った審査を通すことが必要になることもあり、最終的にシステムに統合できるのかを把握した上でプロジェクトを開始しなければならない。

4-2. 使うべき案件の切り分け方

費用対効果とデータの整理状況から、使うべき案件の切り分け方について4象限に分けて紹介する。

費用対効果



この4象限に分ける際には、2つの軸が存在する。1つ目はデータの整理状況、そしてもう1つは費用対効果である。

データの整理状況が低く、費用対効果も低いケース

例えば事務作業のような違うフォーマットがたくさん出てきて、そして開発しても開発費運用費に比べてパフォーマンスが出ないようなケースに関しては、今のままは現状維持をすることが最も良い選択である。

データは整理されているが、費用対効果は低いケース

それに対して費用対効果は高くないが、データの量が多くなってきたケース、たくさんの事務作業が発生したようなケースに関しては、まずクラウドソーシングと活用してコストの削減を行うことが必要となる。そしてその際には、最終的に機械学習に使用できるように入力 (X) と教師データ (T) に関して1セットでとっておくと良い。そうすることによってデータがたくさん溜まっていき、最終的にAIによる自動化の検討を行うことができる。

データの整理状況は低いが、費用対効果は高いケース

次に費用対効果に関して考えていくと、データがあまりないが費用対効果が高くそしてロジックがある程度確定しているというようなケースがある。これに関しては **RPA（ロボティックプロセスオートメーション）** の検討が最も良い選択である。RPAは単純に人間の行っていた作業をプログラミングし、それを再現していくというようなものである。RPAに関する開発を行う企業も多く出現しており、ロジックさえある程度確定していれば、費用対効果も高いため開発コストに見合うような結果を得ることができる。

そしてこのRPAを実施していく中で、ある程度ロジックを言語化することが難しいことが多々出てくる。その際には機械学習を用いてそのロジックをデータ駆動で見つけ出していくといたことが望ましい。

例えば Web のフォームに関してどこが名前の卵なのか、どこがメールアドレスの卵なのかといったところは、ある程度をロジックで判断できるが、Webのフォームのデザインが異なっているケースでは、そこに関しては画像データ駆動の機械学習を挟んで行く方が精度良くばらつきに対応できたりするケースがある。

このようにRPAを使用しながら、適宜必要な箇所は機械学習に落とし込んでいくといったことによって、費用対効果も高く、そしてデータの整理状況も徐々に高くなっていくようなシステムを作っていくことができる。そのため、まず機械学習、AIによって案件をクリアしてほしいと言ったような依頼を出すのではなく、データの整理状況と費用対効果の状況を見ながら、クラウドソーシングを活用していくのか、それともRPAによって自動化を行っていくのか、そしてそれが最終的にどのようにAIによって自動化を検討できるのか、ここまで踏まえた議論を最初に行っておく必要がある。

ステップ1としてクラウドソーシングもしくはRPAによる自動化を検討、そして次のステップではAIによって自動化を検討していく。このようにマイルストーン置いていくことで、開発側としても焦らずに開発でき、そして発注者側としても、効果を短期間で得ることができるといったような関係性を築き上げることができる。

4-3. 外注と内製化

案件を進めていく上で、開発を外注して行うのか、それとも自社内で開発して内製化していくのか最初の選択がある。外注と内製化のそれぞれに関するメリット、デメリットを考えていく。

外注

まず外注のメリットとしては、データ解析を行う人を確保する必要がないことである。AI人材は不足していると言われており、採用が難しいといった問題がある。そのため、開発しようにもまず人手の確保が優先であり、開発しようにも採用できずに始められないといった問題が生じる。そのため、このような人材の確保が必要とならない場合、案件の企画さえ固めてしまえば、外注先を見つけることができれば、即時に開始することが出来る。

一方、デメリットとしては、開発されている機械学習やシステムの仕組みに関して把握できていないため、修正が必要な場合にも依頼を行わなければいけないというメンテナンス性の問題がある。また、開発後の契約期間が切れてしまうと修正することが困難となり、**技術的負債**が残る。この技術的負債は発注者側にとって大きなデメリットになる。

内製化

内製化を行うメリット・デメリットは、外注のメリット・デメリットの反対である。開発を行う際の修正が比較的容易であり、その分の開発できる人材が必要となるため、案件を開始する前にまず人材の採用が不可欠となる。また、人材を採用した後も育成ができる環境が必要となる。エンジニアは技術に対する向上心が高いため、技術的なチャレンジが少ないと転職する傾向にあり、そのためにも育成を行っていくシステムが必要である。

最初から採用や育成ができる環境を作り上げることは容易ではない。そのため、データ解析の案件を行う際は、まず最初に費用対効果がでるのかといったところの検証を外注して行う。そして必要であれば、その案件を引き継げるような人材を時間をかけて確保しながら育成していく。最終的にはその人材に案件の詳細を把握してもらうという流れが望ましいと言える。

医療用人工知能の作り方

～研究開発の中心となるデータ作成の実際～

2018年3月23日

概要

機械学習を用いた人工知能の開発において、学習データは必要不可欠なものとなってきた。しかし、この学習データの生成には人間による作業が必要不可欠であり、学習データの種類によってはその作業に高度な専門的な知識を要求する。そんな中、医療用データを用いて学習を行なう医療用人工知能では、学習データの生成に医師の協力が必要となることがある。しかし、このデータ生成には膨大な単純作業が含まれ、多くの医師がそういった作業を忌避する傾向にある。こうした状況は医療用人工知能の開発を遅らせる大きな原因となり得るが、こうした作業に関して医師の理解を得られれば、医療用人工知能の実用化に向けた大きな一歩となる。

1. 人工知能と機械学習

近年、人工知能技術が急激に進歩し、あらゆる領域で話題になっている。顔認識技術がスマートフォンなどのセキュリティ分野に応用され、記者の代わりに記事を書くようになり、症状から疾患を提示して医師の手助けをするようになってきた。人間の知能を再現するという人工知能の試みは長い年月を経てようやく形になりつつある。こうした人工知能の成長を支えているのがディープラーニングを始めとする機械学習だ。

従来は人工知能の認識・判断・行動に関わるあらゆるルールを人間が自ら教えていた。しかし、人間が直接教えられることには限界があり、特に人間が意識的に行なうことのない感覚的なタスクである画像認識や音声認識などの領域では長らく壁にぶつかっていた。それがディープラーニングによって壊れた。

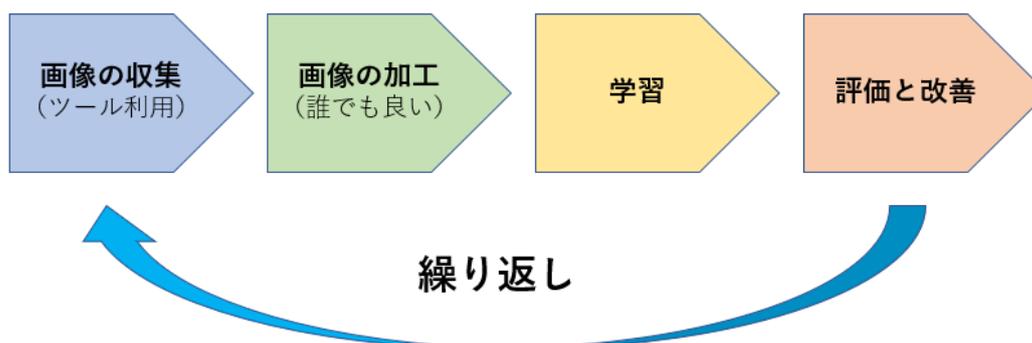
大きく進歩した人工知能による認識能力によって、人工知能は改めて注目を集めるようになり、様々な応用に期待がかかるようになってきた。その一方、人工知能がどのように学習し、成長しているのかについてはよく理解されていない。まずは画像認識システムの学習プロセスに焦点を当ててみた。

2. 画像認識を行なう人工知能の開発

人工知能の開発と一口に言っても様々なアプローチがあり、人工知能の目的と目的達成の手法、使われる技術によって開発方法は全く異なっている。今回はその中でも、社会に大きなインパクトを与えた画像認識システムにおける画像の学習プロセスについて簡単に紹介する。

学習プロセスは大きく「データの収集」「データの加工」「加工済みデータでの学習」「性

能評価と改善」の4つに分けられている。最終段階の評価で満足の行く結果が出ればプロセスは終了するが、出なければアルゴリズムや学習方法に改善を加え、必要に応じて新たにデータ収集・加工・学習・評価を繰り返す。では、各プロセスで何が行われているのかを細かく見ていこう。



<データの収集>

まずは学習させたい対象の画像を収集する。人間の顔であれば人間の顔を、犬の画像であれば犬の画像を集めることになる。ここで収集される画像の枚数は時に数千万に及ぶこともある。しかし、同じ人間の画像であっても角度・背景・光によって見え方が異なるように、全く同じ物体の画像であっても、バリエーションに富んでいることが望ましい。

この時に問題になるのが「どこからそんなに沢山の画像を集めてくるか」だろう。一昔前であれば、この段階で画像が集められず人工知能の性能は頭打ちになっていたところだが、今ならインターネットがある。キーワードで検索すれば大量の画像がヒットする上に、動画を使えば1つの動画から同じ対象の角度の違う画像を複数枚入手できるため、「人間や動物の画像」であればさほど学習用データの収集には困らない。

<データの加工>

こうして得られたデータはそのまま学習に使うことはできない。データを集める際に人間が一枚一枚選んでいた場合は別だが、通常はより多くのデータを一度に収集できるようにするためにデータ収集用のプログラムを作り、そのプログラムにデータを集めさせる。そのプログラムはあくまで「キーワードで得られた画像を全て収集する」もしくは「特定のキーワードで検索した動画の中からランダムに画像を抽出する」などのタスクを行なう

だけのものであり、全く関連性の無い画像も多数混ざっている。

そのため、収集した画像は人間が目で見分けていかなければならない。人間の顔を認識させたいのであれば、人間の顔が含まれている画像に「人間の顔」と付け、犬を識別したいのであれば犬が含まれている画像に「犬」と付ける。この作業は人間の顔や犬を識別出来る人間なら誰でも出来る極めて単純な作業だ。それを1人で何千何万と行なうため、ここでも効率化のためにプログラムを組む。例えば、犬を識別するために、画像と一緒に「犬である」「犬ではない」と書かれたボタンが表示され、クリックすると次が表示されるようなプログラムを作れば、人間が行う作業は画像を見てマウスやキーボードを押すだけになる。

<データでの学習>

退屈な作業が終わると今度はそれを使って人工知能に学習をさせることになる。この際、ラベルの付け方は非常に重要になる。例えば、「犬である」「犬ではない」というシンプルなラベルしか貼っていないのであれば、人工知能が学習するのは犬か犬ではないかだけで、犬の種類までは識別しない。

学習時間は画像の枚数・アルゴリズム・コンピューターの性能にもよるが、学習プロセスの全体の中でそれほどの割合にはならない。場合によっては一瞬である。「学習」は重要なプロセスであることは間違いないが、手間と時間がかかるのはそれ以外のプロセスだ。

<性能評価と改善>

学習が終わった後に行なうのは性能評価だ。学習用のデータとは別に作っておいたテスト用のデータを使って検証する。人工知能は学習を経て「犬だと思った画像」「犬ではないと思った画像」を出力する。こうして出力されたデータを人間がチェックする。

良い結果が出ても、悪い結果が出ても、評価プロセスは非常に重要だ。良くなった原因、悪くなった原因を突き止め、アルゴリズムにさらなる改良を加えていく。アルゴリズムではなく、学習データに問題がある場合には、次に収集する画像データの集め方やラベルの付け方について改善していかなければならない。

ここで画像認識システムの学習プロセスは終了する。しかし前述の通り、必要に応じて何度も何度も繰り返される。作り始めたばかりのシステムであれば、繰り返す回数は1回や2回ではなく、場合によっては何十回と繰り返すことになる。これは途方もない作業だ。

3. 医療用人工知能で同じことができるのか

前述の画像認識システムのプロセスは、画像・文字・音声などの認識タスクを行なう人工知能の多くで共通している。この学習プロセスをきちんと回すことができれば、一定水準の認識タスクを実行できる人工知能が完成する。

ただ、一見簡単そうに見える学習プロセスにも大きな問題がある。学習に必要なデータが膨大なのだ。データはインターネットから適当に拾ってくるだけでは不十分で、ラベルを付けるなど学習用に加工しなければならない。前述の画像認識システムのように「犬」を識別するだけの作業であれば、それほど難しくはない。犬が何なんなのか認識できるなら小中学生だって構わないし、日本以外にもいくらでも依頼できる相手が存在する。クラウドソーシングサービスなどの発達で人材も集めやすくなっており、こうした画像認識システムの開発はスムーズに進み、実際に高性能な人工知能が多数登場している。

しかし、認識すべき情報の「答え」が分かる人間が少ない場合には厄介だ。例えば、肺のレントゲン写真を見てその「答え」となる疾患を当てることができる人間は医師など医療の専門家だけだ。有名大学の医学生だって経験不足なら難しいだろう。経験豊富な医師をこうした単純作業に大量に確保すること容易ではない。さらに、問題は人手や費用が集めにくいだけに留まらない。疾患があるかないかの判別は犬がいるかいないかという判別に比べて遥かに難解で、画像によってははっきりと断定できない「疑いがある」レベルにとどまるものもあるだろう。つまり、ラベル付の判定基準ですら簡単には決まらないのだ。

人工知能の学習は、基本的には学習に用いる情報の認識・理解に高度な専門知識が必要なケースになるほど難しくなる。医療用人工知能の場合は学習に使うデータが個人情報に関わるケースも少なくないため、インターネットで何でも集まる時代にデータを集めることにすら苦労する。苦労して収集したデータもそのままでは使えないため医師の協力を仰ぐことになる。

そこで具体的に、どのような作業が行われるのかについて説明していく。

4. 文献のリファレンスを表示する医療用人工知能の開発

医療用人工知能にも様々な種類が存在する。中でも注目を集めているのが診断支援を行なう人工知能である。今までは医師にしか識別することができなかった様々な疾患を、画像を含む各種検査データや症状から自動で判別してくれるようになったのだ。これだけでも十分優れているのだが、もしこうした診断支援システムが疾患に関連する文献のリファレンスを上げてくれたらどれほど医師の仕事が楽になるだろう。

そこで、診断支援システムに文献のリファレンスを表示する機能を追加するとしよう。そのためには疾患別のリファレンスリストが必要となるが、これを人力で整理するのは難しい。そこで文献を確認し、自動で整理してくれる分類用の人工知能を作ることにする。

膨大な医学文献を適切に分類するための膨大なルールを人間の手で入力していくことは現実的ではないため、機械学習を用いて人工知能に自ら学ばせる必要がある。その学習プロセスは前述の画像認識システムの学習プロセスと殆ど変わらない。ただ、各プロセスで必要となる作業が微妙に異なる。



※学習プロセス自体は画像の学習と変わらない

<データの収集>

ここで行なうのは文献データの収集だ。画像認識システムの学習と同様に、これも自動で行なう。ただし、検索時のキーワードは疾患名であったり医学用語であったり、より専門性の高いものとなる。また、今回はインターネットを使った文献の収集であるため、実際に収集するのはウェブページのURLとなる。URLにはWikipediaから公的機関の医療サイトまで含まれており、情報の形態は多岐に渡る。

＜データの加工＞

データを収集した後は、URL の先を確認し、医療用の文献として表示する価値があるかをチェックすることになる。この時点では、キーワードでヒットした URL が集められているだけであり、疾患の名前が入っているだけで無意味な URL もあれば、疾患とは全く無関係の URL も存在する。

分類用の人工知能には、まずこうした無価値な文献を可能な限り取り除いて貰う必要がある。価値のある文献かどうかの確認は専門知識を持った人間にしかできないため、ここでは医師に依頼する。しかし、医師に依頼するからといって実質的な作業内容が複雑になるわけではない。やることは単純で、URL リストに含まれている文献を1つ1つ確認し、価値があるか無いかのラベルをひたすら付けていくだけだ。

＜データでの学習＞

加工データが完成したら、そのデータを使って価値のあるデータだけを出力するように学習させる。この際、価値のあるデータだけではなく不要なデータも同時に入力することが重要だ。インターネット上に存在する文献には無数の種類があり、価値ある文献に似た無価値な文献も存在する。こうしたものも可能な限り正しく分類してもらわなければならない。

＜性能評価と改善＞

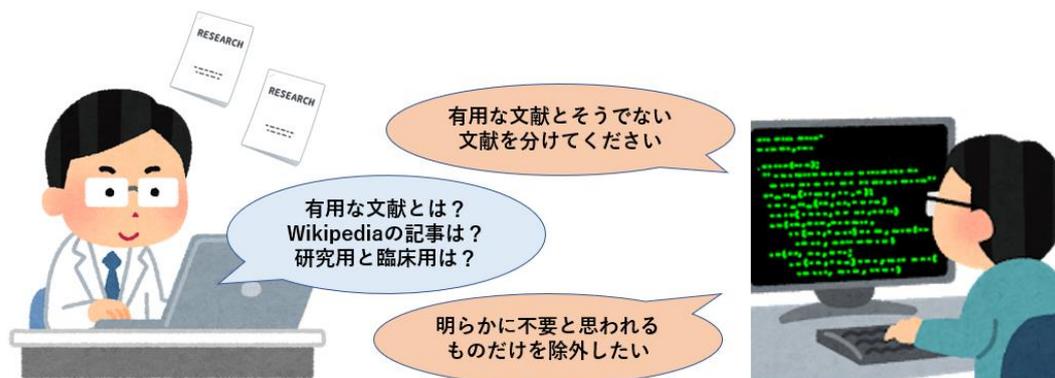
学習完了後、改めて文献を分類させ評価する。価値あるデータが出ていれば良いのだが、そう簡単にはいかない。価値のあるデータとして主力されたものの中に含まれる無価値なデータがなぜ含まれたのかを分析し、アルゴリズムの改善やデータの収集・加工の改善に生かして行かなければならない。その上で、収集・加工・学習・評価を繰り返していく。

5. 医師による医学文献のチェック作業 –ガイドラインの策定–

全体としてのプロセスは画像認識システムの学習とさほど変わらないことは分かって頂けたらう。しかし、問題は「データの加工」の工程にある。分類用人工知能に出力してもらいたいのは「医師がリファレンスとして読む文献として価値のあるもの」であり、その答えを知っているのは医師だけだ。医学的な知識がない人間には頼めない。そこで医師に頼んで文献が使えるか使えないかのラベル付け作業をしてもらうことになる。

そこでまず、医師は大量の URL リストを渡され「有用な文献とそうでない文献を分けてください」と依頼される。ところがすぐに、このケースで言う「有用な文献って何だ」という話になる。つまり、判定基準に関する情報が不足しているのだ。ラベル付けのガイドラインの策定が必要になる。画像認識システムの学習のように「犬である」「犬ではない」という話であれば簡単だが、医療に関わるデータの分類はそう簡単な話ではない。

例えば、「Wikipedia などのサイトでは、医学的に有用な情報はあるものの信頼できるとは言えない文献がある。これは価値があるといえるのか?」「研究領域では価値があるものの、臨床現場では価値のない論文はどうなるのか?」などの疑問が生まれる。こうした疑問に対し、人工知能の開発者は「明らかに不要と思われるものだけを除外したい。そのため、そうした文献は価値があると判定して欲しい」という回答を返す。



最初に URL を数件チェックしただけでもこれぐらいの質疑応答が行われる。こうしたやり取りを経てようやく暫定的なガイドラインが作られるのだ。素人であれば「研究領域で価値のあるもの」と「臨床現場で価値のあるもの」の区別はつかない。今回のケースでは両方共価値があるとされたが、臨床現場だけで利用するものであれば区別する必要があったらう。

6. 医師による医学文献のチェック作業 – ラベル付け作業 –

暫定的なガイドラインが完成してようやく実作業に入る。ただ、膨大な URL を1つ1つ開いてチェックするのではどれだけ時間がかかるか分からない。そのため、画像認識システムの学習時と同様に、チェック作業を効率化するツールが作られる事が多い。今回のケースでは、URL をいちいち開くのは手間なので、リンク先のキャプチャー画像と一緒にラベル選択のボタンが表示されるツールが作成された。これによって医師は URL を開く必要がなくなり、少なくともキャプチャー画像のみで判断できるレベルのデータであれば簡単に分類できるようになった。



単純作業が続く

しかし、ツールを用いたとしても単純作業がひたすら続くことには変わらない。医療関係者向けの公的機関のサイトで、内容的にも明らかに価値があるだろうと見ただけで判断できるケースもあれば、リンク先に飛び、文献をしっかりと読まなければならないケースもあるため、集中力の必要な作業が続く。さらに、その過程で先に作成した暫定的なガイドラインでは対応できない問題にも遭遇する。

例えば、「疾患をまとめた便利なリストが含まれているケース」「医学的に価値があるが、そもそも動物に関する疾患であるケース」「医学的な文献だけど情報不足なケース」「英語で書かれていない文献」などである。これらの文献は状況によっては価値を持つ文献であり、一概に無価値と分類するのは避けたい。そこで、人工知能の開発者はラベル付けのガイドラインを改定し、「リスト」「ミスマッチ」「情報不足」「非英語」「その他」などのラベルを追加した。

それに合わせてツールを修正し、合わせてツールの使い勝手についても医師のフィードバックを受け、ツールについてもより効率的に作業できるように改善していく。こうしたやり取りを繰り返しながらガイドラインを確定することで、ようやく安定して作業が進むようになる。

7. 医療用人工知能の完成に一步近づいた

分類用の人工知能はこうして分けられた文献を使って「価値がある文献」が何なのか学習していく。医学生なら、分類された文献を何件か読めば「価値がある」とされる基準を理解できるかもしれないが、人工知能ではそうはいかない。何千何万もの文献を読みながら、少しずつ学習していく。また、何千何万もの文献の中に大量に「実は価値のない文献」が混ざっていると学習効率が落ちてしまうため、データの質は重要だ。単純作業だからと十分な知識のない人間に頼むと、せっかく集めたデータが無駄になる。人工知能の性能向上において、このデータ加工は非常に重要な作業である。

データ加工を終え、データを使って学習させ、評価と改善が終われば医療用人工知能が完成するかというとそうは行かない。評価の内容次第では新たに文献を集めて同じ工程を繰り返す必要がある。そうして何とか分類用の人工知能が価値ある文献を見つけ出してくれるようになったとしても、これは診断支援システムに搭載する追加機能であるため、実際にどのように表示するのか、表示する順番はどう選定するのか、関連のある文献をどう絞り込むのかなど、問題は山積している。

診断支援システムが鑑別と合わせて文献を表示し、それが医師の業務に役立つようなレベルに達するまでの道のりはまだまだ遠い。しかし、医療用人工知能が現場で使えるようになり、患者に治療に役立つようになるためには、この長い道のりを少しずつ進んでいかなければならない。

8. まとめ

機械学習を用いた人工知能の開発において、学習用データは必要不可欠である。しかし、学習用データの作成過程で人間の手が必要になり、それが膨大な単純作業であることはあまり認識されていない。また、学習に用いるデータによってデータの加工作業を行う人間に求められるスキルが違い、それによってこの単純作業の担い手が限られ、人工知能の開発に大きな影響を与えることも知られていない。

医療用人工知能の学習では、医師によるデータ加工が必要であるにも関わらずこの作業の重要性が正しく理解されておらず、協力者を得ることが難しくなっている。データの加工作業自体は非常に単調ではあるものの、こうした地道な作業が医療用人工知能の実用化には必要不可欠であり、そのためには医師の協力が不可欠である点が理解頂ければ幸いである。

**医療用人工知能研究に求められる
データ生成・監査タスクを海外委託する**

2018年2月14日

サマリー

医療用人工知能の学習データの作成には、時間とコストがかかる。そこで、今回、インターネットを活用して軽作業を委託する「クラウドソーシング」を通じて、海外の医療従事者に作業を委託する試みを行った。

試行では、利用者の多いクラウドソーシングサイトである UpWork 社を利用し、スリランカ在住の医師に、自動的に生成した文献データの医学的な監査作業を委託した。委託管理のシステムが確立されているため、実際の作業において、応募・作業・決済はスムーズに進んだ。また、作業履歴も、遠隔で確認することができた。結果的に、研究利用するうえで十分な品質のデータが完成した。また、国内医師を雇用することと比べて、5分の1程度のコストで監査作業を行うことが出来た。作業へのヒアリングにより、作業側にとっても大きなストレスなく作業を行えることが確認できた。

クラウドソーシングを利用した作業委託は応用範囲が広い。今後、医療用人工知能の研究開発への有効活用が期待される。

海外に作業を委託する理由

人工知能の研究開発が活発化している。人工知能と一口に言っても様々なモデルがあるが、中でも近年目覚ましい成果を上げているのが機械学習によって能力を向上させていくタイプの人工知能だ。この種の人工知能では多かれ少なかれデータが必要になるため、データをどのように集め、学習させ、検証するかが人工知能研究の鍵になってくる。ただし、人工知能研究に必要となるデータの作成には、人間が関与せざるをえない部分が少なからず存在する。これは殆どの場合、膨大な単純作業であり、人手と時間がかかる作業だ。

これは医療用人工知能研究でも変わらない。プログラムが出力したデータが医学的に正しいか、有用であるかはその領域に関する知識と経験の豊富な人間が判断するしかなく、信頼のおける医療従事者が必要不可欠だ。しかし、国内の医療従事者の人件費は高く、一般的な人工知能研究と比してもデータ生成にかかるコストがより高額となってしまふ。この状況は、日本の医療用人工知能研究の研究コストを増加させる。

また、医師は、精神的な集中を要求される膨大な単純作業を好まず、研究協力者の確保にも難渋する。一部の医療用人工知能研究では、実際、この協力者の確保に困難があり研究が停滞してきた側面がある。

もし、海外の医療従事者を効率的にリクルートし、データ生成業務を委託することが出来れば、この人件費の問題と研究協力者の確保の問題が解決する可能性がある。とりわけ、データ作成の多くは単純作業であることから、コミュニケーションにハードルがある海外医療従事者へと作業を委託する事も現実的となる可能性がある。

近年、クラウドソーシングサービスが発達したことで、海外の単純作業者を探すことも容易になっている。作業ジャンルを問わないクラウドサービスとしては

「UpWork」「Freelancer.com」、特定の作業に特化したサービスとしては「Amazon Mechanical Turk」などが知られており、世界中で広く使われている。

作業側も、オンラインのクラウドソーシングサイトを用いることで、自国の賃金よりも高い報酬で作業ができることも多く、多くの医師やエンジニアが海外の作業を受注している。そこで、こうしたサービスを利用することで、安価に医療用人工知能研究のデータ生成ができないか、検証を試みた。

委託内容と作業手順

今回、クラウドサービスで委託する業務として「医療に関するウェブページの内容検証作業」を取り上げた。ここで検証するウェブページは、医療関係のウェブサイトの中から有用と考えられるものをアルゴリズムが自動的に選んだ結果となっている。具体的な検証作業としては、ウェブサイトの名称や URL などが含まれている一覧ファイルに対し、作業者は各 URL の内容を確認し、それが特定の疾患に関する医学的に有用なウェブサイトかどうかを判断する。

66687	Partial epilepsy with pericentral spikes	omim_607221_0 omim_607221	0	74769	20141006	google	http://www.ncbi.nlm.nih.gov/pubmed/20183	OK	abstract
6218	Familial primary cryofibrinogenemia	omim_123540_0 omim_123540	0	34473	20141006	google	http://en.wikipedia.org/wiki/Cryofibrinogenemia	OK	wikipedia
127	Achard syndrome	omim_100700_0 omim_100700	0	36468	20141006	google	http://www.rhdiagnosis.com/achard_sy	OK	textbook
7775	Dyslexia	omim_127700_2 omim_127700	2	74426	20141006	google	http://en.wikipedia.org/wiki/Reading_disability	OK	wikipedia
37398	Enterocolitis	omim_226150_0 omim_226150	0	26845	20160501	google	https://www.nlm.nih.gov/medlineplus/ency/	OK	textbook
26999	Seborrheic keratosis	omim_182000_0 omim_182000	0	32977	20141006	google	http://www.mayoclinic.org/diseases-conditions	OK	textbook
9000	Spontaneous thrombosis with factor V excess	omim_134400_1 omim_134400	1	34619	20141006	google	http://www.mayoclinic.org/diseases-conditions	OK	textbook
31477	Total intestinal aganglionosis	omim_202550_0 omim_202550	0	53039	20141006	google	http://www.uptodate.com/contents/congenital	OK	textbook
1135	Internal anal sphincter myopathy	omim_105565_0 omim_105565	0	76291	20141006	google	http://www.ncbi.nlm.nih.gov/pubmed/19935	OK	abstract
17984	Multiple exostoses with spastic tetraparesis	omim_158345_0 omim_158345	0	76368	20160504	bing	http://www.ncbi.nlm.nih.gov/pubmed/85637	OK	abstract
75031	Megarbane-Jalkh syndrome	omim_612785_1 omim_612785	1	75213	20141006	google	http://www.ncbi.nlm.nih.gov/pubmed/19012	OK	abstract
45046	Ophthalmoplegic neuromuscular disorder	omim_258470_0 omim_258470	0	74823	20141006	google	http://www.ncbi.nlm.nih.gov/pubmed/16003	OK	abstract
61582	Juvenile recurrent parotitis	omim_603588_0 omim_603588	0	72178	20141006	google	http://www.ncbi.nlm.nih.gov/pubmed/17407	OK	abstract
60242	Pseudoacromegaly with severe insulin resist	omim_602511_0 omim_602511	0	140586	20141006	google	http://en.wikipedia.org/wiki/Acromegaly	OK	wikipedia
42732	Progressive lymphoid system deterioration	omim_247630_0 omim_247630	0	133500	20141006	google	http://en.wikipedia.org/wiki/Central_nervous	OK	wikipedia
58925	Sebacous nevus syndrome and Hemimeg	omim_601359_0 omim_601359	0	74486	20141006	google	http://www.ncbi.nlm.nih.gov/pubmed/76254	OK	abstract
73479	Hunter-MacDonald syndrome	omim_611962_0 omim_611962	0	37333	20141006	google	http://rare-diseases.info.nih.gov/gard/2751/	OK	unknown
40888	Male hypogonadism	omim_241100_0 omim_241100	0	54933	20141006	google	http://www.uptodate.com/contents/testoster	OK	textbook
55054	Paine syndrome	omim_311400_0 omim_311400	0	210081	20141006	google	http://en.wikipedia.org/wiki/Payne_Syndrome	OK	wikipedia
15106	Atopic IgE responsiveness	omim_147050_0 omim_147050	0	36871	20141006	google	http://en.wikibooks.org/wiki/Handbook_of_I	OK	wikipedia
20174	Voluntary nystagmus	omim_164170_0 omim_164170	0	23439	20141006	google	http://www.rhdiagnosis.com/medical/volu	OK	textbook
60688	Apraxia of eyelid opening	omim_603119_0 omim_603119	0	45651	20141006	google	http://eyewiki.aao.org/Blepharospasm	OK	wikipedia
15639	Keloid formation	omim_148100_0 omim_148100	0	73421	20141006	google	http://www.ncbi.nlm.nih.gov/pubmed/94945	OK	abstract
66298	Peripheral arterial occlusive disease	omim_606787_0 omim_606787	0	104095	20141006	google	http://www.aafp.org/atp/2004/0201/p525.ht	OK	unknown
75143	Giachelli syndrome	omim_612917_1 omim_612917	1	46853	20141006	google	http://en.wikibooks.org/wiki/Handbook_of_I	OK	wikipedia
52286	Calvarial hyperostosis	omim_302030_0 omim_302030	0	25791	20141006	google	http://www.rhdiagnosis.com/medical/calv	OK	textbook
18454	Hartung type myoclonic epilepsy	omim_159600_0 omim_159600	0	101705	20141006	google	http://en.wikipedia.org/wiki/Chorea_gravida	OK	wikipedia
11238	Giant platelet syndrome with thrombocyte	omim_137560_0 omim_137560	0	76351	20141006	google	http://www.ncbi.nlm.nih.gov/pubmed/14601	OK	abstract
49010	Tardive dyskinesia	omim_272620_0 omim_272620	0	34991	20141006	google	http://www.nytimes.com/health/guides/disea	OK	textbook
19724	Nevus flammeus of nape of neck	omim_163100_0 omim_163100	0	66081	20141006	google	http://en.wikipedia.org/wiki/Nevus_flammeus	OK	wikipedia
39879	Normal-pressure hydrocephalus	omim_236690_0 omim_236690	0	59966	20141006	google	http://www.uptodate.com/contents/normal-pr	OK	textbook
46778	Infantile polymyoclonus	omim_263550_0 omim_263550	0	78851	20141006	google	http://en.wikipedia.org/wiki/Opsoclonus_my	OK	wikipedia
47685	Retinal telangiectasia and hypogammaglob	omim_267900_0 omim_267900	0	56125	20141006	google	http://en.wikipedia.org/wiki/Macular_telangi	OK	wikipedia

(ウェブサイトの名称・URL・疾患名などが含まれる一覧ファイル)

この一覧データは、今後他の目的に利用されるだけでなく、明らかに病気と無関係のデータや有用性の低いデータを指摘することで、アルゴリズムの性能向上に役立てることができる。このため、データの判定作業が必要となる。

リストに含まれるウェブサイトの種類は多岐に渡る。公的機関の情報提供サイトや医学論文の概要を含むサイトもあれば、ニュースの記事や製薬会社のホームページなども含まれている。こうした理由から、作業者は専門知識を有する医師が望ましい。

判定作業自体は極めてシンプルである。病名と URL が含まれるリストを渡された作業者は URL を 1 つ 1 つ確認しながら、有用なサイトには「Useful」とラベルを付ける。そうでないサイトには「Non medical」「Mismatch」「Poor」「List」「Other」「Garbage」「Non-English」のいずれかのラベルをつける。この場合、「Useful」以外は不適切なサイトとして扱われる。

作業委託に使ったツール

この作業には時間がかかるため、Google スプレッドシートのスクリプトを活用し、作業効率の向上が図られている。具体的には、リストの中で判定に必要となる「病名」「URL」「ウェブサイトのサムネイル」「ラベル（選択肢）」のみが画面表示される。作業者がサムネイルだけで判断できる場合はラベルをクリックして先に進み、判断が難しい場合に URL をクリックして詳細を確認する。マウスのみでの作業も可能であり、100 個の URL を 20-30 分程度で判定できる Google スプレッドシートのスクリプトを用意した。

このツールを実現するために「判定に利用するウェブサイトのサムネイル作成」「URL リストの分割」「Google スプレッドシートの作成」「スプレッドシートへのスクリプトの埋め込み」等の環境整備を別途行った。作業者が判定作業を行った後、「データのダウンロード」と「集計」を行って結果を出力する体制も整えた。

246925: McLeod neuroacanthocytosis syndrome

<http://rarediseases.info.nih.gov/gard/10731/mcleod-neuroacanthocytosis-syndrome/resources/1>

(ラベルとサムネイルが表示されている判定画面)

クラウドサービス上で作業者を募集する

(今回利用したクラウドサービス「UpWork」のホームページ)

今回、作業者を探すのに使ったクラウドサービスは「UpWork」だ。oDeskとして2003年にサービスをスタートさせたUpWorkは、2017年の時点で全世界180カ国1400万人がユーザー登録しており、クラウドサービスとしては世界トップレベルの規模を誇る。雇用者側が負担する手数料は支払額の2.75%、作業者側は報酬に応じて5%-20%の手数料が取られる。高額報酬になるほど手数料が減る形となっている。

会員登録の段階ではクレジットカード情報などは不要で、必要な情報を入力したらすぐに仕事を作成して募集をかけることができる。一般募集はせずにワーカーを検索して直接依頼する事も可能だ。また、ユーザー登録せずにワーカーを探することもできる。このように、利用の敷居を下げるための多くの工夫がこらされている。ただし、ユーザー登録をしなければコンタクトを取ることはできず、プロジェクトを作成しての募集もできない。

Freelancer Preferences

Do you want freelancers to find and apply to your job?

- Freelancers using Upwork.com and public search engines can find this job.
- Only Upwork users can find this job.
- Only freelancers I have invited can find this job.

Do you have freelancers in mind that you would like to invite?

Preferred Qualifications

Specify the qualifications you're looking for in a successful application. Freelancers may still apply if they do not meet your preferences, but they will be clearly notified that they are at a disadvantage.

[Hide Qualifications](#)

Freelancer Type

Job Success Score

Rising Talent

Hours Billed on Upwork

Location

English Level (self-assigned)

Group

Screening Questions

(UpWork の求人票情報作成画面。ワーカーのレーティングなどを絞りこめる)

求人票を作成するために入力可能な情報は多岐に渡るが、業務内容の説明さえ記入すれば、とりあえずの求人はできる。ただし、時給制かプロジェクト単位の支払いになるかは最初の段階で決めておく必要がある。業務内容を説明する項目では必要なスキルなども記載するが、UpWork 内での実績やレーティングを指定して絞り込むことも可能だ。また、応募の際にワーカーが答える質問事項なども用意できるため、スキルの有無や実績についての質問を用意しておけば、応募者の選定が楽になる。

求人票の提示段階では支払い方法の登録などは不要だが、ワーカーと実際に契約する際には、支払いに必要な情報を登録する必要がある。方法はクレジットカードの他に Paypal があり、クレジットカードの場合は一時的に数ドル程度事前課金（デ

ポジット) される。この課金は、承認後に返金される。クレジットカードの課金が素早く確認できない場合には承認にやや時間がかかるため、早めに対応しておくことが望ましい。

応募者の確認と契約まで

The screenshot displays the UpWork interface for reviewing proposals. At the top, there are navigation tabs: 'VIEW JOB POST', 'INVITE FREELANCERS', 'REVIEW PROPOSALS (15)', and 'HIRE (1)'. Below this, there are sub-tabs: 'ALL PROPOSALS (15)', 'SHORTLISTED (0)', 'MESSAGED (0)', and 'ARCHIVED (3)'. A modal window titled 'Invite a coworker to help you hire' is open, showing a search box and an 'Invite Coworkers' button. Below the modal, there are search filters and sorting options. The main content area displays three proposal cards for 'Psychiatry writer', 'Writer, editor, translator', and 'Pharmacist', each with a 'Best Match' badge, hourly rate, and location.

(応募者の一覧画面。UpWork における平均時給や実績などが表示される)

今回の委託では、医療分野の専門知識を持つワーカーを募集した。その結果、1週間で10名前後、3週間で18名(辞退3名)の応募者が来た。新規案件はユーザーに参照されやすいため、募集直後が最も応募者が増える。応募者に対してこの段階でメッセージのやり取りなどを行うことが可能で、応募時に用意した質問への回答を深掘りし、実績の詳細情報や医療従事者としての証明書の提示を求めることもできる。

今回の応募者を見てみると、職種は医師・薬剤師・研究者・医学生・ライターなど多岐に渡っていた。医師だけでも5名おり、この他に実績の豊富な医療の専門家と思しきワーカーは6-7名いた。つまり、半数以上が作業に適した医療関係者だったことになる。ただ、あくまでプロフィールや質問への回答から確認できるものだけであり、これだけでは信頼できるワーカーかどうかは分からない。

また、募集してきたワーカーのUpWorkにおける平均時給は時給10ドルから65ドルと幅広いが、これは現在の職業の他に応募者が居住する地域にも大きな影響を受けているため、平均時給が高いからといってスキルのあるワーカーだとは限らない。むしろ、先進国の医師で時給が50ドル前後だった場合には却って注意が必要かもしれない。

Writing and editing a medical case report

APRIL 2015

Report

Technical Writing english-proofreading, editing, content-writing, medical-writing

The client had a partly written case report on a patient with a lichenoid drug eruption. He needed help in modifying the document with regard to content editing, text formatting and proofreading. He also wanted the conclusion and the abstract of the case report written within a word limit.

I rearranged... [more](#)

[Case report - A patient with a lichenoid drug eruption.pdf \(252.54 KB\)](#)

(UpWork上で確認できるワーカーの実績に関する資料)

直接メッセージを送って実績を証明できるものを提示してもらうこともできる。また、UpWork上で今までの仕事の実績やフィードバックを確認することも可能だ。過去の仕事の内容や成果物が提示されているケースもあるため、過去に同様の仕事をこなし、評価されているのであれば判断材料となる。

しかし、あくまで「本物の医師」に作業を依頼したいという場合には「UpWork上での実績」だけでは不十分だ。日本や米国（州ごと）など医師データベースを提

供している国ならそれを使用できるが、途上国のようにそうしたシステムが無い場合やそもそも相手がデータベースに登録していない場合には医師免許や学位証明書で確認する必要がある。

また、過去の実績や所属病院のウェブサイトを用いた存在確認という手もある。所属病院の医師リストと病院のドメインが入ったメールで本人確認すれば良い。スキルの確認方法は求人票の質問の他、Skype でのインタビュー、小規模のプロジェクトによる試雇などが考えられる。

採用した作業者と賃金について



(委託したワーカーのプロフィール画面)

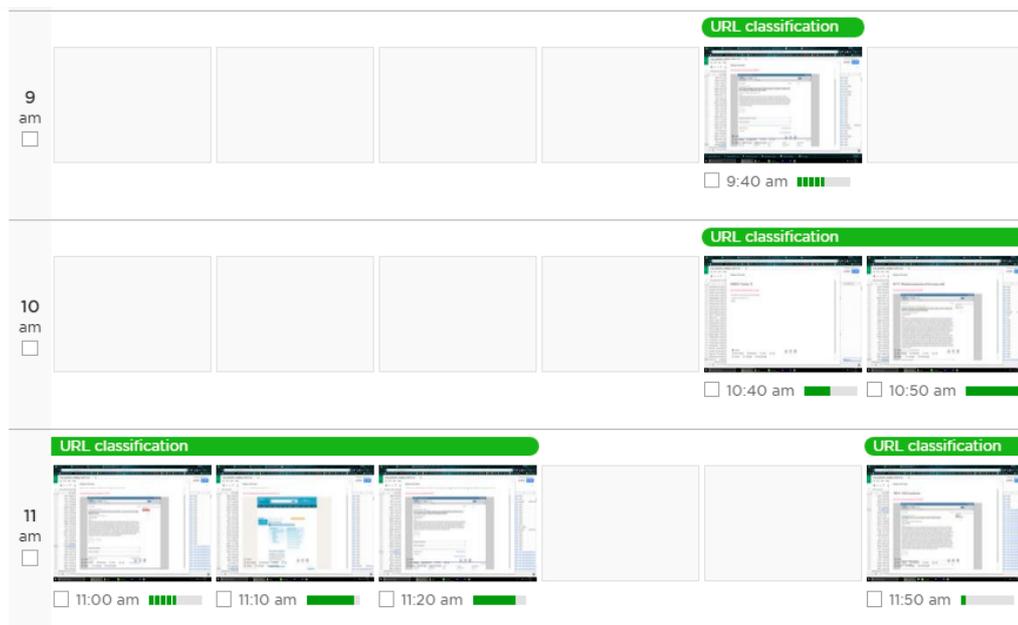
今回はスリランカの医師に A 氏に依頼することにした。A 氏はスリランカ最大の大学であるコロンボ大学を卒業し、国の研究機関での勤務経験がある。UpWork 上の実績も豊富であり、論文の著者名でも確認できた。念のために学位証明書の提示を依頼すると、快く証明書を送ってくれた。

TIME & PAYMENTS	MESSAGES & FILES	WORK DIARY	TERMS & SETTINGS
Rate and Limits			
Rate			\$20.00 /hr
Weekly Limit			30 hrs/week
Manual Time			Manual time allowed
Start Date			January 11, 2018
View history of contract changes			

(UpWork の契約内容画面。時給や上限などが確認できる)

契約を結ぶ前に金額などの条件についてワーカーと交渉するのだが、A 氏の UpWork における平均時給は 20 ドル。この時給額をそのまま提示したところあっさり契約が成立した。

また、合わせて「Weekly Limit」として週あたりの最大労働時間を設定することができるので、予算オーバーは避けられる。UpWork では、ワーカーの活動ログを測定するアプリを提供しており、アプリを使っての労働時間の計測もできる。自動の時間管理の結果を、ワーカーと依頼者双方の合意のもとに修正することもできるようになっている。



(UpWork で確認できる活動ログ。スクリーンショットと活動頻度が表示される)

活動ログ機能を用いれば、作業中に定期的に撮影されたスクリーンショット画像やキーボードとマウスの使用頻度が UpWork 上に保存される。この画面だけでも記録としては十分だが、より細かく確認したければ 1 分おきに記録されたキーボードとマウスの使用状況を見ることができる。

TIME (UTC)	KEYBOARD	MOUSE
2:41:44 pm	22	1
2:42:44 pm	15	11
2:43:44 pm	16	4
2:44:44 pm	17	10
2:45:44 pm	15	26
2:46:44 pm	22	8
2:47:44 pm	23	11
2:48:44 pm	13	6
2:49:44 pm	10	20
2:50:44 pm	37	21
2:51:44 pm	13	15
2:52:08 pm	6	1

(マウスとキーボードの使用ログ)

かなり細かくワーカー側の労働状況を確認することができるため、少なくとも PC 上で作業するタスクを依頼する場合には、労働時間をサバ読んで請求されることはなさそうだ。もちろん、スクリーンショットや活動ログを見て作業をしていないと判断できる場合にはこちらで作業時間を調整することができる。

DESCRIPTION / MEMO	AMOUNT
- 10:30 hrs @ \$20.00/hr - 01/22/2018 - 01/28/2018	210.00
TOTAL AMOUNT:	\$210.00

Invoice created via **Upwork**

(UpWork より発行される請求書)

作業ログを元に週毎に UpWork から請求が行われる。請求書は以上の様な形態となっており、この金額に UpWork 手数料 (2.75%) を足した金額が週毎に UpWork 経由で請求される。登録された決済方法で自動的に決済されるため、活動ログのチェックはそれまでに済ませる必要がある。

また、契約途中での金額変更やボーナスの支払いも可能なシステムになっており、タスクの状況が変化すれば同意の上で時給を変更することができる。また、予想以上の成果を挙げてくれた場合には、追加報酬を支払うことで次の仕事に繋げることもできるだろう。

委託の結果、時間あたりの作業量とコスト感

TIME & PAYMENTS		MESSAGES & FILES	WORK DIARY	TERMS & SETTINGS	...				
Last 24hrs	This week	Last week	Since start						
3:50 hrs	9:10 hrs	7:10 hrs	35:30 hrs						
<small>Last worked 10 hours ago</small>	<small>Of 30hr limit</small>	<small>\$143.33 Paid Dispute</small>	<small>\$526.67 Paid</small>						
Timesheet this Week									
MON 2/12	TUE 2/13	WED 2/14	THU 2/15	FRI 2/16	SAT 2/17	SUN 2/18	HOURS	RATE	AMOUNT
5:20	3:50	—					9:10	\$20.00/hr	\$183.33
All Timesheets and Other Payments								Last 30 days: \$526.67	
DATE	DESCRIPTION	CHARGE	INVOICE						
Feb 12	Invoice for 02/05/2018-02/11/2018 - 7:10 hrs @ \$20.00/hr	\$143.33							
Feb 5	Invoice for 01/29/2018-02/04/2018 - 4:30 hrs @ \$20.00/hr	\$90.00							
Jan 29	Invoice for 01/22/2018-01/28/2018 - 10:30 hrs @ \$20.00/hr	\$210.00							
Jan 22	Invoice for 01/15/2018-01/21/2018 - 1:50 hrs @ \$20.00/hr	\$36.67							
Jan 15	Invoice for 01/08/2018-01/14/2018 - 2:20 hrs @ \$20.00/hr	\$46.67							

(全体及び曜日毎の労働時間と週毎の支払額)

最終的な作業時間はおよそ 35 時間で、支払額は約 700 ドル程度となった。完了した判定作業は約 7000 件。作業初期に発生した判定基準の変更による再判定や別件で

行ったヒアリングなども作業時間に含まれているため、それらを除いた概算で「1時間あたり約 300 件」の作業効率となった。

作業に慣れる前はもう少し時間がかかっていたが、最終的にはこの作業速度で落ち着いている。判定作業の品質も申し分ないものであった。作業に際しては、作業の効率化に資する意見なども出して頂き、環境そのものを改善しながら進めることができた。

仮にこの作業を日本の医師に依頼した場合、日本の医師の時給はおよそ 1 万円前後とされているため、同じ作業を依頼した場合は 5 倍のコストがかかることになる。

また、医師を時給 20 ドルで働かせることに不安を覚えるかもしれない。しかし、スリランカの医師の月収は 600-700 ドルの水準であり、これは日本の医師の 20 分の 1 だ。それを踏まえれば、20 ドルという時給は高額な部類に入る。事実、今回の支払だけでも月収に匹敵する収入になる。

スリランカ以外にも同じ賃金レベルの国は数多く存在するため、最適な作業者を見つけられさえすれば、より大規模な判定作業を行なうとしても同じようなコスト感で作業ができる可能性がある。

作業者の反応

コストパフォーマンスの極めて高い作業委託となり、委託側としては満足のいく契約になったが、作業側はどう感じているのだろうか。こうした委託が作業者にとって大きな負担となる場合、より大規模且つ長期間に渡って作業をする場合に問題になる。そのため、A 氏に今回の案件に関連して簡単なヒアリングを行ったところ、以下のような返答が得られた。

Q「今回の賃金には満足していますか？」

A「ええ、当時の平均時給でしたので十分に満足しています。」

Q「作業についてどのような印象を持ちましたか？またやりたいと思いましたが？」

A「今回の作業は私の医学的な知識をフルに使い真剣に情報を評価するもので、退屈どころか興味深いものでした。コンピューターだけで作業ができましたし、作業時間も自由です。気持ちよく作業できましたので、こういった仕事はまたやりたいですね。」

Q「クラウドサービスを通じて作業をしたい医師や医療関係者は多いと思いますか？」

A「途上国では給料も少ないので、副業をしている医師は多いです。私の回りにもUpWorkで作業をしたいと考えている医師は何人かいますが、競争が激しいので最初の仕事を見つけるに苦労していますね。」

Q「UpWork以外でこうした作業を委託する作業者をどうやって見つければ良いと思いますか？」

A「同僚や知人を辿って探すことになるのではないのでしょうか。UpWork以外にも作業者を見つける方法はたくさんあると思いますが、先進国のクライアントにとってUpWorkは安価に雇用できる途上国のワーカーを探す魅力的な場になると思います。」

Q「UpWorkで仕事を見つける時にどのような問題がありますか？」

A「興味深いタスクが中々見つからないことですね。提示額が低すぎるケースも多いです。あと、一番の問題は他の応募者との競争が激しいことですね。応募しても中々採用されません。ただ、最近は定期的に招待されるようになったので特に困っていませんが。」

まとめ

結果、委託者としては国内水準の 5 分の 1 という想定以上に安い費用で作業を委託できた。作業側も満足の行く賃金で作業できたようで、双方にとってメリットのある作業委託になったといえる。海外の作業側とのコミュニケーションは殆ど UpWork のシステム上で行ったが、契約・作業・支払いまでのプロセスは非常にスムーズに進んだ。実作業における作業プロセスが確立していれば、人員を増やしたとしても特に大きな問題はなさそうだ。

また、UpWork のシステムでは UpWork 上で作業した実績しか参照できないため、実績のある作業側に依頼が集中するようだ。委託する側としても実績のないワーカーには依頼しにくい。結果として最初の 1 件までのハードルが高くなり、潜在的なワーカーが仕事をもらえていない事もヒアリングから明らかとなった。こうしたワーカーの中から十分なスキルのある人材を見つけ出すことも重要だろう。

プロフィールやメッセージのやり取りを通じて実績やスキルの確認は可能であり、手間を惜しまず UpWork 上で実績の少ないユーザーとメッセージのやりとりをしてスキルの確認をすれば、有望なワーカーを多く見つけることもできそうだ。

一旦信頼できるワーカーを見つけられれば同僚を紹介して貰う形でワーカーを増やすこともできる。大規模な作業の前に小規模な作業を委託し手順を確立した上で、ワーカーを紹介してもらう形で作業側を増やせば、より大きなプロジェクトにも応用できるだろう。

今回の作業はデータの検証作業だったが、遠隔で作業が可能なシンプルなタスクであれば医療用人工知能のデータ検証以外のタスクにも応用はできる。もちろん、医療分野の他にも各種専門家にタスクを依頼するような作業には有用だろう。特に人工知能研究ではデータ生成関連の単純作業が多いため、応用範囲は幅広い。賃金についても、国内と海外の賃金格差の大きな職種ほどクラウドソーシングを使った海外業務委託のメリットは大きい。

今回の委託によって、研究中のアルゴリズムの精度が概算で現状 87%程度あることが確認できた。今回作成したデータによって再度学習させることにより、さらなる性能向上が期待される。クラウドソーシングが人工知能の研究開発に大きなインパクトを有することがご理解頂けることを願っている。

