

博士学位論文

データ駆動型社会における
病院の在り方に関する研究

2022年9月

兵庫県立大学大学院 応用情報科学研究科

応用情報科学専攻

岸 本 和 昌

要約

本論文は、医学と医療は高度化および複雑化するなかで、病院は医療現場の安全性の担保と医療の質の向上という社会的な要求に応えつつ医療サービスを提供しなければならぬため、複雑化した病院の業務を合理化または自動化できる可能性を模索すべく、データ駆動型社会における病院の在り方を検討した。そのために、病院・病院情報システムなどのこれまでの展開と現状について分析した上で、データ駆動型病院情報システムを検討し、データ駆動志向がもたらす病院の在り方について今後の方策について論じたものである。

医学とは人の心身の健康を維持もしくは増進させ、病気を治すまたは癒すための学問であり、加えて医学の実践あるいは社会適用として医療が発展してきた。我が国では西洋医療の導入によって近代的な病院が始まり、歴史を踏まえると病院とは医学を実践する医療を社会的に適用させた場である。近代的な医療サービスの提供は診療報酬を始めとした医療制度によって始まったが、社会保障ばかりに国費を投入することができなくなり、医療費抑制への方向転換することとなった。

しかし、医学の発展による治療機器・検査機器の機能向上や情報技術の適用のみならず、社会が求める医療サービスのあり方の変化に伴い、多くの歪み生まれつつある。特に、医療に対する安全性の担保や、診療録を中心とした記録の保全等については、医療従事者に対して過大な負荷をかけることとなり、また安全を担保するための多くの金銭的なコストが要求される。ところが、医療費の増大は国家の財政負担になっているという現状において、潤沢なりソースを医療サービスに投入することは現実的ではない。

一方、医療以外の社会に目を向けてみると、社会に対して情報技術を適用することで様々な問題解決が期待されている。特に、膨大なデータから知識を抽出したり、IoT (Internet of Things) などを中心とした様々な技術適用によってデータ駆動型の社会を構築し、我々の生活を大きく変革することが期待されている。今後は膨大なデータに基づいて開発された AI (Artificial Intelligence) などの技術によって、様々な知的活動がコンピュータシステムによって行われる可能性がある。しかし、病院における診療現場という観点からは、治療機器、検査機器、病院情報システム等の導入が進みつつあるものの、これらの導入が「病院の業務を効率化する」ことに貢献できているかということについては、甚だ疑念が残る。実際の医療現場においても、例えば高度な医療機器を導入した場合、当然これらの操作は煩雑であり、また多くの知識を必要とする場合が多く、また患者の安全を広く注意する必要があるため、結果として医療従事者の負担は増加する一方である。よって、今後の持続的な医療サービスの提供のあり方を検討するにあたり、データ駆動型の病院について深く検討することは、極めて重要であるといえる。

よって、本論文においては、これまでほとんど検討されてこなかったデータ駆動型社会の観点から、新たな病院のあり方、とりわけ病院情報システムのあり方について検討する。その中でも、1. データ駆動志向のための IoT やセンサデータを用いたデータ収集および機

機械学習の利用による安全性の担保について、2. 蓄積されたデータおよび機械学習を用いたデータ駆動志向の業務の合理化について検討する。そこで、1.に対して、病院情報システムと接続されていない、または接続できない医療機器に対してアラーム音から医療機器のアラート状況の収集および自動認識を検討し、アラーム音から医療機器のアラート状況の自動認識することによって、データ駆動型病院情報システムに詳細なデータの収集が可能となることが明らかとなった。これによってアラート状況の通知システムに応用することで安全性の担保に繋がると考えられる。次に 2.に対して、看護記録から危険行動の自動監査を検討し、ごく少数の漏れが発生する可能性はあるものの、再現率が高いことから危険行動の自動抽出に対して実際に医療現場での適用を具体的に考えられるものであった。したがって、蓄積されたデータである看護記録から自然言語処理技術および深層学習を用いて看護業務の合理化ができる可能性が明らかとなった。

本論文において、データ駆動型病院情報システムに必要となるデータの収集とデータの蓄積・利用について検討した。これらの検討から、病院は IoT 技術によって収集したデータから AI で抽出した情報を医療従事者に提供することによって、データ駆動志向で複雑化した病院の業務を合理化できることが明らかとなった。したがって、包括的な医療サービスを提供しつつ、医療現場の安全性の担保と医療の質の向上が社会的に求められるなかで、医療従事者の負担の増加を抑えつつ病院機能は高度化できると考えられる。これは今後のデータ駆動型社会を医療に適用した際に起こる病院の在り方に対して確かな指針を与えるものと思われる。

目次

第1章	序論	1
第2章	病院	4
2.1	医療システム	4
2.1.1	イギリスを始めとした欧州の医療システム	4
2.1.2	アメリカの医療システム	5
2.1.3	日本の医療システム	7
2.2	医療制度	9
2.2.1	イギリスの税方式	9
2.2.2	日本の社会保険方式	10
2.2.3	アメリカの民間保険方式	13
2.3	日本の病院の歴史	15
2.3.1	明治から敗戦まで	15
2.3.2	敗戦後から GHQ による改革	17
2.3.3	GHQ 撤退後	18
2.3.4	病床規制と機能分化	21
2.4	病院の課題	24
第3章	病院情報システム	26
3.1	病院情報システムの概要	26
3.2	病院情報システムの発展の歴史	26
3.3	電子カルテ	28
3.3.1	電子カルテの普及	28
3.3.2	診療記録	29
3.3.3	看護記録	31
3.4	医療機器管理システム	32
3.4.1	現代の医療における医療機器	32
3.4.2	医療機器を取り巻く法規制	33
3.4.3	医療機器管理システムの概要	35
3.5	医療機器と病院情報システムの連携	36
3.6	病院情報システムの現状と課題	38
第4章	Artificial Intelligence	40
4.1	AI の歴史	40
4.1.1	AI 第一世代	40
4.1.2	AI 第二世代	41
4.1.3	AI 第三世代	43

4.2	知能とは	44
4.3	AI の分類	45
4.4	IoT とビッグデータ	46
4.4.1	IoT デバイスの普及	46
4.4.2	ビッグデータ	50
4.5	ニューラルネットワーク	51
4.5.1	単純パーセプトロン	52
4.5.2	多層パーセプトロン	53
4.6	深層学習	63
4.6.1	多層化における問題	63
4.6.2	畳み込みニューラルネットワーク	64
4.6.3	リカレントニューラルネットワーク	66
4.6.4	Transformer	70
4.7	AI の医療への適用	76
第 5 章	AI の病院への適用	78
5.1	本邦における医療に AI を適用する試み	78
5.2	データ駆動型社会	81
5.3	AI がもたらす次の病院の在り方	82
第 6 章	病棟における医療機器のアラーム音の収集および自動識別	84
6.1	背景	84
6.2	目的	85
6.3	対象機器	85
6.4	方法	87
6.4.1	アラーム音識別システム	88
6.4.1.1	入力	88
6.4.1.2	特徴抽出	89
6.4.1.3	アラーム音識別モデル	90
6.4.2	モデル学習	90
6.5	シミュレーション実験	91
6.5.1	シミュレーションデータセット	91
6.5.2	識別結果	91
6.5.3	評価指標	92
6.6	結果	92
6.7	考察	94
6.7.1	特徴抽出における CFB	94
6.7.2	アラーム音識別システム	94

6.8	まとめ.....	95
第7章	看護記録からの危険行動の自動監査.....	96
7.1	背景.....	96
7.2	目的.....	97
7.3	方法.....	97
7.3.1	対象データ.....	98
7.3.2	BERT	99
7.3.3	判別実験.....	99
7.3.3.1	前処理.....	99
7.3.3.2	判別器.....	100
7.3.3.3	学習及び判別器の性能評価.....	101
7.4	結果.....	102
7.5	考察.....	103
7.6	まとめ.....	105
第8章	おわりに.....	106
謝辞	108
参考文献	109

図目次

図 1: イギリスの診療構造	5
図 2: アメリカの診療構造	6
図 3: 日本の診療構造	8
図 4: 社会保障制度	10
図 5: 平成 26 年度診療報酬改定による病床機能	24
図 6: 電子カルテの普及状況	29
図 7: 医療機器管理システムの概略	36
図 8: 医療機器と電子カルテの連携モデル	37
図 10: 中国語の部屋	45
図 11: IoT の適応分類	47
図 12: 世界の IoT デバイス数の推移及び予測	49
図 13: 分野・産業別の世界の IoT デバイス数及び成長率予測	49
図 14: ビッグデータを構成する各種データ	51
図 15: ニューロン 2 個のモデル	52
図 16: 3 層のニューラルネットワーク	54
図 17: バックプロパゲーションの概要	56
図 18: 合成関数の例	56
図 19: 連鎖律による出力側から偏微分する流れ	57
図 20: 順伝播と逆伝播	57
図 21: 勾配降下法 の概念図	58
図 22: 局所最適解と大域的最適解	61
図 23: 訓練データとバッチ	62
図 24: シグモイドと ReLU の微分	63
図 25: CNN2 層の畳み込みとプーリング	65
図 26: RNN の順伝播 (実線) と逆伝播 (破線)	66
図 27: RNN の構造	67
図 28: LSTM ブロックの構造	68
図 29: GRU ブロックの構造	69
図 30: Attention の Encoder-decoder モデル	70
図 31: Scaled Dot-product Attention の構造	72
図 32: Multi-head Attention の概要	73
図 32: Transformer の構造	74
図 34: MYCIN のシステムフロー	76
図 35: AI ホスピタルの概要	80

図 36: データ駆動型社会の概念図	81
図 37: 録音環境	86
図 38: 実験概要	88
図 39: カスタムフィルタバンク	89
図 40: CFB のパワースペクトログラム	90
図 41: 特徴抽出	90
図 42: CFB における SNR 0dB の混同行列.....	93
図 43: SOAP 記載による診療記録	98
図 44: 提案モデルのアーキテクチャ	100
図 45: 実験フローの概念図	101

表目次

表 1: アメリカにおける活動中の医師数 (2002 年)	6
表 2: 病院と診療所の年代別医師数 (2019 年)	7
表 3: 開設者別にみた施設数と病床数 (2019 年)	8
表 4: 公的医療保険に関する動き	11
表 5: 日本の医療保険制度	12
表 6: OECD 加盟国の保険医療費の一部	14
表 7: 明治～戦中までの病院数の推移	16
表 8: 戦後からの病院数の推移	20
表 9: 病床機能における医療機能区分	23
表 10: 日本の医療 IT 化の歴史	28
表 11: 看護記録の様式	32
表 12: 医療機器のクラス分類	35
表 13: データヘルス改革推進計画	78
表 14: 録音条件	86
表 15: アラーム音の詳細	87
表 16: micro-F と AUC による MFB と CFB の比較	93
表 17: アンダーサンプリングごとの言語モデルによる評価比較	103

第1章 序論

情報科学は通信技術の発展とともに近代的学知として誕生した。情報を伝える手段として人類は言語を体得し、文字に起こすことで情報の記録と伝達が始まった。これは4万年前の洞窟絵画から始まり、紀元後は105年の紙の発明、1450年の活版印刷術の発明、1876年の電話の発明など、情報の取得・記録・伝達を長い年月をかけた技術革新が可能とした。そして通信技術の発展とともに情報を客観的に捉える概念をクロード・シャノン (C. E. Shannon) らが展開したことにより情報理論は発展した。情報理論は計算機のためのコンピュータに情報量の概念を加えることによって、情報処理マシンとして現代のコンピュータの基礎が生み出された[1]。1950年のコンピュータの発明以降、インターネット、World Wide Web, スマートフォン等のITの技術革新から、我々の暮らす社会はコンピュータとインターネットの情報通信インフラが大きな役割を果たす情報社会となっている。

情報科学によって医学にもたらされた貢献として、画期的であったものとして医用画像がある。アナログデータであるX線診断から始まり、1951年の高橋トモグラフィによってフィルムによる回転横断像を得ることに成功したが不明瞭な断層像であった。コンピュータの進歩により1972年にX線CTが登場し、実用的な人体の二次元横断画像を得ることに成功した。これは人体を透過したX線ビームをフィルムの代わりにX線検出器で受け、デジタルデータのX線吸収値 (CT値) に変換することにより、コンピュータ処理によって二次元横断像を再構成する。具体的には、コンピュータによってラドン変換やフーリエ変換といった演算を実用的な速度で可能とし、診断に利用できる横断像を描出できるようになった。また磁気による核磁気共鳴現象は物性研究などに利用されていたが、1970年代から医学への応用が始まった。水素原子は測定感度が高く、人体は水素原子から構成される水分子が豊富に存在するため、MRIは水分子から放出される核磁気共鳴信号の空間分布を取得する。1980年頃からハードウェアとソフトウェアの開発が飛躍的に進歩したことによって、MRIは人体の水分子の空間分布を画像化することで横断面情報を取得できるようになった。したがって、情報科学の適用によってフィルムからデジタルの横断像に発展したことで、臨床的価値を有する情報と成ることを可能とした[2]。他にバイオインフォマティクスにおいては、膨大なゲノムデータを解析して病気のメカニズムを明らかにすることや、タンパク質の形や動きを詳しく調べて治療薬を開発するといった事などが研究されている。これらの研究は、生命現象をコンピュータ上でシミュレートし、アルゴリズムを適用することによって、膨大なデータから情報を抽出することが試みられている。

医学の社会的な適用は医療であり、医療の実践の場である病院において、支払基金への報酬請求を始めとした医療制度による複雑化した病院業務の効率化のために情報科学が貢献した。病院の中でコンピュータが業務の支援に使われ始めたのは、1960年代からであり、患者ごとの医療費の請求処理を行う部分で医事会計システムに入力することにより、請求

額の計算、請求書の発行が自動化された[3]。続いて検査部門では複数の自動分析装置を統合的に制御する検査部門システムが構築され、検査部門システムと医事会計システムが連携したオーダーエントリシステムが導入された。その後、医療制度による診療記録の記載状況等を定期的に把握する必要性といった背景から電子カルテおよび、これらのシステムを統合する病院情報システムが構築された。また他の部門も業務支援システムの導入が進んでおり、医療従事者は様々な場面でデータを入力することが一般化し、診療データやレポートデータのみならず、様々なデータが病院情報システムに蓄積され続けている。

しかし、実際の医療現場の現状は、これまで述べてきた医学の発展による治療機器・検査機器の機能向上や情報技術の適用のみならず、社会が求める医療サービスのあり方の変化に伴い、多くの歪み生まれつつある。特に、医療に対する安全性の担保や、診療録を中心とした記録の保全等については、医療従事者に対して過大な負荷をかけることとなり、また安全を担保するための多くの金銭的なコストが要求される。ところが、医療費の増大は国家の財政負担になっているという現状において、潤沢なりソースを医療サービスに投入することは現実的ではない。

一方、医療以外の社会に目を向けてみると、社会に対して情報技術を適用することで様々な問題解決が期待されている。特に、膨大なデータから知識を抽出したり、IoT (Internet of Things) などを中心とした様々な技術適用によってデータ駆動型の社会を構築し[4]、我々の生活を大きく変革することが期待されている。例えば、自動運転技術は人の移動を根本的に変革する可能性があり、また動画配信技術などによるテレワーク環境の普及は、我々の働き方に対して大きな影響を与えている。今後は膨大なデータに基づいて開発された AI (Artificial Intelligence) などの技術によって、様々な知的活動がコンピュータシステムによって行われる可能性がある。しかし、病院における診療現場という観点からは、治療機器、検査機器、病院情報システム等の導入が進みつつあるものの、これらの導入が「病院の業務を効率化する」ことに貢献できているかということについては、甚だ疑念が残る。実際の医療現場においても、例えば高度な医療機器を導入した場合、当然これらの操作は煩雑であり、また多くの知識を必要とする場合が多く、また患者の安全を広く注意する必要がある。結果として医療従事者の負担は増加する一方である。よって、今後の持続的な医療サービスの提供のあり方を検討するにあたり、データ駆動型の病院について深く検討することは、極めて重要であるといえる。

よって、本論文においては、これまでほとんど検討されてこなかったデータ駆動型社会の観点から、新たな病院のあり方、とりわけ病院情報システムのあり方について検討する。具体的には、第2章、第3章、第4章においてこれまで病院と病院情報システムを踏まえた上で、データ駆動志向で必要となる AI について論じる。第5章ではデータ駆動型病院情報システムにおける AI の適用について論じる。データ駆動型病院情報システムを検討するにあたって、データ駆動型社会の概念からデータの収集とデータの蓄積・利用から検討す

る。第 6 章では、IoT やセンサデータを用いたデータ収集および機械学習の利用による安全性の担保について、病棟における医療機器のアラーム音の収集および自動識別を検討する。第 7 章では蓄積されたデータおよび機械学習を用いた業務の合理化について、看護師が記載した看護記録からの危険行動の自動監査を検討する。最後に第 8 章で結論を述べる。

第2章 病院

文明開化した明治時代から西洋医療の導入によって近代的な病院が始まり，敗戦とGHQの介入により現在の病院たる医療システムと制度が構築された．本章では，2.1節で世界と日本の医療システムについて，2.2節で世界と日本の医療制度について，2.3節で日本の病院の歴史について，2.4節で前節を踏まえた病院の課題について述べる．

2.1 医療システム

国によって医療システムの構造に差異があり，診療所と病院の役割，概念，機能が国によって異なる．本節では各国の病院と診療所，プライマリケアとセカンダリケア，診療構造について2.1.1項でイギリスを始めとした欧州の医療システム，2.1.2項でアメリカの医療システム，2.1.3項で日本の医療システムについて述べる．

ここでまず，プライマリケアとセカンダリケアの定義であるが，特にプライマリケアの概念は幅広い使われ方をしている．プライマリケアとセカンダリケアはどちらも機能領域に関する概念であり，医療の発展により医療システムのなかで高度かつ専門分化した先端的な領域が現れてきた．この領域がセカンダリケアであり，この領域を差し引いた領域がプライマリケアと呼ばれる．

プライマリケアは医療の入り口であり，細分化された専門的な診療科の集まりであるセカンダリケアに患者を適切に配分する機能を担う．患者は多くの場合，自身の症状から何の標榜科を受診するのが適切かは判断できないため，これを指示する機能が求められる．次に，特定の医師がかかりつけ医として，住民の健康を管理する統合的な機能も担う．日常的に患者と接することで，各患者にふさわしい診療や生活習慣の制御をすることが期待される．また専門領域をセカンダリケアとすれば，このセカンダリケア以外をプライマリケアが機能を担うことになり，幅広い領域を包括的にプライマリケアがカバーしているといえる．

2.1.1 イギリスを始めとした欧州の医療システム

医師・医療施設・患者の3つの要素を構造化したものを「診療構造」といい，この診療構造はプライマリケア，セカンダリケアから診療構造ダイアグラムで医療システムを表現することができる．

イギリスの医師には専門医と一般医という明確な区別がある．一般医がプライマリケアを担当し，専門医は一般医からの照会に基づいて患者に専門的なセカンダリケアを提供し

ている。そして明確に棲み分けが図られている。イギリスでは医師のキャリアパスが一般医と専門医で異なり、5年の医学校の後、1年の研修が行われるが、この期間が終了するまでに一般医か専門医かを選択することとなる。そしてセカンダリケアに必要な臨床能力を身につけないプライマリケアに特化した一般医と、身につける専門医が生まれ、能力上に差異のある医師が養成される。

次に、プライマリケアとセカンダリケアの2つの機能領域は、病院と診療所に2つの医療施設によって医療提供がカバーされることになる(図1)。矢印は患者の受療パターンを示し、一般医が診てプライマリケアで済む場合、そして専門的な治療が必要と判断すれば、患者はしかるべき病院の専門診療科へと送られる。そして病院における専門医の治療が完了すると、診療の責任は再び一般医に返されることになる。

イギリスにおいては、一般医と専門医で二分された医療システムをとるが、医師と医療施設との関係性は他国では少し異なる場合がある。フランスでは、病院外来部門が一般医によって担当される場合と、ドイツでは専門医が診療所を開業する場合とがある。




図 1: イギリスの診療構造[5]

2.1.2 アメリカの医療システム

アメリカの医療システムは、イギリスの一般医と専門医で分離しているのではなく、プライマリケアとセカンダリケアの全体を、専門医のみでカバーしている。

アメリカでは、かかりつけ医機能や医療の入り口としての役割に内科医、家庭医、小児科医はイギリスのような一般医を系譜としているが、他の専門医と同様に近医の病院と施設利用に関する契約を交わし、病院医療に従事し、必要であれば手術も行うという点で、イギリスの一般医より専門的な診療に従事する医師として存在している。

医学生は卒後にレジデンシーとよばれる卒後研修プログラムを経て、専門医の資格を授

与される。このレジデンシーを終えると、大半の医師は診療所を開業する専門医となる。診療活動中に従事する医師は全体の 89.3%を占め、フルタイムで大学病院やその他の教育病院を中心に病院スタッフとして従事する医師は 10.7%のみである（表 1）。開業医は、自分にかかりつけている患者に病院での治療が必要と判断したときは、患者を連携病院に転院させた上で、その病院においても患者に対する主治医としての責任を継続し治療を行う。そこでは、病院との契約に基づいて手術室などの施設を利用するとともに、レジデントを養成する病院であれば教育も行う[6]。

患者の受診パターンはイギリスのように、概ね診療所を医療の入り口とし、高度な治療が必要であれば病院に移る経路を辿ることになるが、患者の診療の主たる責任はイギリスのように一般医と専門医に引き継がれるのではなく、一貫してかかりつけ医である専門医が担っている（図 2）。

表 1: アメリカにおける活動中の医師数（2002 年） [6]

総計	719,431 人
診療所開業医	516,246 人
レジデント, インターン	96,937 人
フルタイムの病院スタッフ	61,641 人
診療以外の活動に従事	44,607 人
診療活動に従事する医師（レジデント, インターンを除く）に占める開業医の割合	89.3%
同フルタイムの病院スタッフの割合	10.7%




図 2: アメリカの診療構造[5]

2.1.3 日本の医療システム

日本の医療システムはアメリカと同様に専門医がプライマリケアとセカンダリケアの両方を担っている。名称としては病院に雇用される勤務医と、自身が診療所や病院を開設して運営する開業医があるが、これは就業形態の違いであって臨床能力においてイギリスの一般医と専門医に見られるような差はない。臨床能力のあり方は卒後におけるキャリアに依存しており、卒後に入局する医局によって診療科目の専門性が異なってくる。この医局制度の人事パターンによって、最終的に開業する医師の大部分が残りの勤務医と同様に、10年以上病院での勤務に従事している（表 2）。このため長期に渡ってセカンダリケアに適合的な臨床経験の蓄積を続けていることになり、専門医のみによってプライマリケアとセカンダリケアの両方に対応する構造になっている[7,8]。

日本の医療法では有床病床 20 床以上が「病院」で、これ未満を「診療所」と呼び、病院は開業医によって施設数の 71.0%、病床数の 57.1%を担っている（表 3）。また診療所は開業医が施設数の 82.5%、病床数が 93.6%を担っている[9]。

無床診療所から大規模病院まで多彩な施設が分布するため、病院と診療所の機能的な区別が曖昧で、20 床を区切りに病院と診療所を分けているが便宜的な意味が大きい。実際に、診療所がセカンダリケアを行っているのに対して、病院も大きな外来部門を抱えてプライマリケアを行っている（図 3）。

表 2: 病院と診療所の年代別医師数（2019 年） [9]

	医療施設 の従事者	病院の開 設者又は 法人の代 表者	病院の勤 務者	医育機関 附属の病 院の勤務 者	診療所の 開設者又 は法人の 代表者	診療所の 勤務者
29 歳以下	29,605	29,171	-	18,788	22	185
30～39	66,495	59,965	60	35,692	1,104	3,439
40～49	69,862	49,079	515	35,204	9,347	8,958
50～59	70,610	38,247	1,147	30,881	21,101	7,926
60～69	56,194	22,282	1,852	18,266	25,133	5,601
70 歳以上	34,444	9,383	1,609	7,677	15,002	6,018

日本の受療パターンは多様であり、医療の入り口として診療所でも病院でも構わない。その後、より高度なセカンダリケアが必要な場合も、診療所に入院する場合もあれば、より大きな病院に転院する場合もある。

表 3: 開設者別にみた施設数と病床数 (2019年) [9]

	施設数	構成割合 (%)	病床数	構成割合 (%)
病院	8,300	100.0	1,529,215	100.0
国	322	3.9	126,423	8.3
公的医療機関	1,202	14.5	311,724	20.4
社会保険関係団体	51	0.6	15,523	1.0
その他	831	10.0	203,284	13.3
開業医 (医療法人, 個人)	5,894	71.0	872,261	57.1
一般診療所	102,616	100.0	90,825	100.0
国	537	0.5	2,175	2.4
公的医療機関	3,522	3.4	2,419	2.7
社会保険関係団体	450	0.4	0	-
その他	13,441	13.1	1,192	1.3
開業医 (医療法人, 個人)	84,666	82.5	85,039	93.6

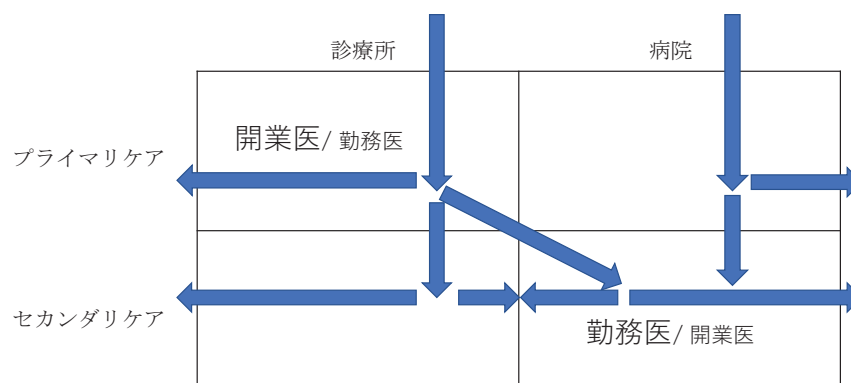


図 3: 日本の診療構造[5]

2.2 医療制度

本節では、2.2.1 項でイギリスの医療制度、2.2.2 項で日本の医療制度、2.2.3 項でアメリカの医療制度について述べる。

世界の医療制度は、一般に財源とサービスの提供という面から 3 つのタイプに大別される。1 つは「税方式」であり、税金を財源として、広く国民一般にはほぼ無料で医療サービスを提供する制度であり、代表的な国はイギリスをはじめとした北欧諸国等である。2 つめが「社会保険方式」であり、国民の多くが医療保険に加入し、その保険料を医療費の財源としている国である。医療機関は開業が自由で、国民による医療機関の選択も自由なのが一般的であり、表的な国は、日本、ドイツ、フランス等である。3 つめが「民間保険方式」でアメリカの医療である。公的な医療保障制度は、高齢者等を対象とする制度と生活保護受給者を対象とする制度の 2 つだけで、国民一般に対する公的医療保障制度はなく、多くの国民は民間保険に加入する。被用者の場合は、企業が保険料を負担して、従業員に民間保険を提供する事が多い[10]。

日本は社会保険方式をとっており、国民皆保険を国民の義務とし、医療に対して国民はフリーアクセス（医療機関・医師の選択の自由）であり、医師は開業の自由があり、他国とは違い民間医療機関が中心となって医療提供体制を支えている。

2.2.1 イギリスの税方式

イギリスでは外国人も含めイギリス国内に住所を持つ人は近くの診療所に登録する。病气やけがをしたときは、登録をした診療所で診察をしてもらうが、登録をしていない診療所や病院に直接行っても日本のように受け付けてもらえない。これは診療所の医師が一般医としてプライマリケアを担って医療の入り口として機能し、セカンダリケアの病院の専門医が高度な医療、専門的な医療を担当することで、機能分担、役割分担をしているからである。したがって住民は、いきなり病院に行くのではなく、まず診療所に行くことを求められる。

このようにイギリスでは、患者にとってフリーアクセスが認められておらず、診療所開設も自由にできるわけではない。加えて病院はすべて国営病院で、病院で働く専門医はすべて公務員であり、国から給料を受けて病院で診療を行う。次に診療所医師の報酬は、基本的に登録をした住民 1 人当たり年いくらかという診療報酬を国から受け取り、その額は日本のように診療内容によって変わるわけではない。そうして患者は、基本的に税金で医療が賄われているため窓口負担がなく、日本のような公的な医療保険制はない。このようなイギリスの医療制度は「National Health Service : NHS」と呼ばれる。

税金を財源にしており、国によって全国各地に計画的に整備されている。このため病院

や診療所が都市部に集中して農村部には不足するということがないため、どこに住んでいても、地元で医療を受けられるようになっている。また病院機能を分担しているため、特定の病院に病気の種類や重さにかかわらず患者が集中することがない。

一方で、税金を財源としているため、国がどれだけ医療に税金をあてるかで、結果的に病院の設備や人件費が変動してしまう。第二次世界大戦後の不況に際しては、診療所の医師から紹介された患者が、病院への入院を何カ月も待たされるということが普通になってしまったという事態を経験している。また、医師や看護師の給料も引き上げできず、そのために医療関係者のストライキが頻発する、といったことも起こった。

2.2.2 日本の社会保険方式

日本の国民皆保険制度は1958年（昭和33年）の国民健康保険法改正により制定され、1961年（昭和36年）に実施された。全ての国民が文化的社会の成員たるに値する生活を営むことができるようにすることを目的に「社会保障制度」が整備され、人々の生活を生涯にわたって支える（図4）。1961年度以降、国民健康保険制度の制度創設後の歴史を振り返ると制度の根幹は維持しつつも、数度の大きな改正がなされた[11]。これに伴い従来の国保老人、社保老人とも後期高齢者医療制度に移行し、現在は国保世帯、被用者保険世帯ともに74歳以下の被保険者で構成されている（表4）。

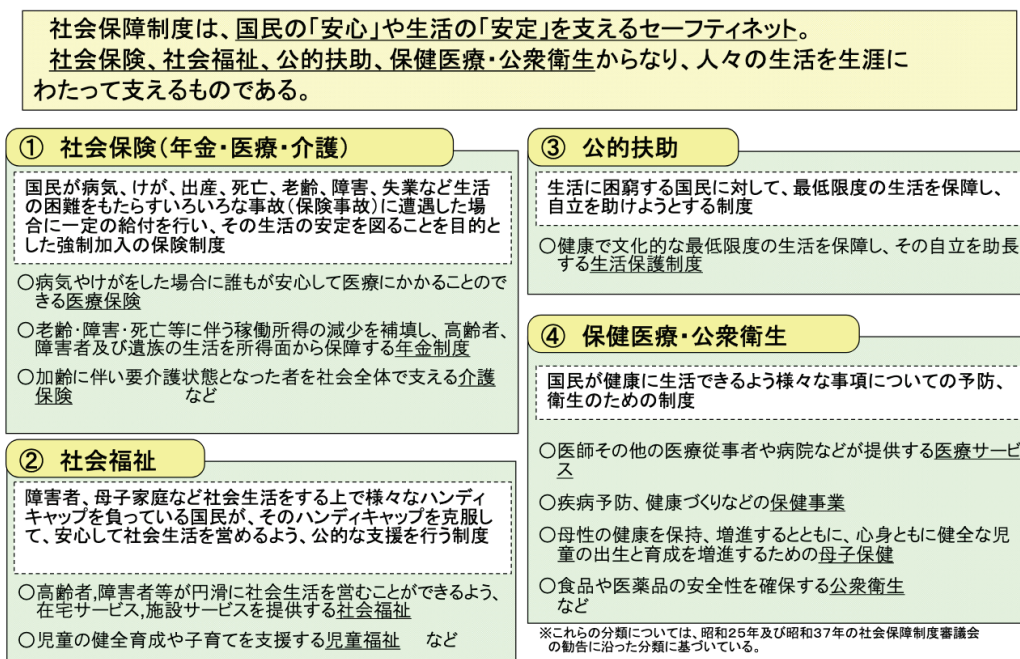


図4: 社会保障制度[12]

表 4: 公的医療保険に関する動き[11]

大正	1922 年	(旧) 健康保険法
昭和	1938 年	(旧) 国民健康保険法
	1958 年	国民健康保険法の制定
	1961 年	国民皆保険の実現
	1973 年	70 歳以上の医療費が無料に (自己負担ゼロ)
	1983 年	老人保健法の施行
	1984 年	職域保険 (被用者保険) 本人の自己負担 1 割
平成	1997 年	同自己負担 2 割
	2003 年	同自己負担 3 割
	2008 年	後期高齢者医療制度始まる
	2015 年	医療保険制度改革法が成立 (国民健康保険への財政支援の拡充, 入院時の食事代の段階的引き上げ, 紹介状なしの大病院受診時の定額負担の導入などが盛り込まれた)
	2018 年	国民健康保険の財政運営が, 市町村から都道府県単位に変更

この社会保障制度は, 「社会保険」「社会福祉」「公的扶助」「保健医療・公衆衛生」からなり, 「医療保険」は「社会保険」の 1 つに位置付けられる[13]. 医療保険制度に関する法律として, 被用者を対象とした健康保険法, 船員を対象とした船員保険法, 国家公務員共済組合法, 地方公務員等共済組合法, 私立学校教職員共済組合法がある. また自営業者や無職を対象とした国民健康保険法がある. さらに, 75 歳以上の方を対象にした後期高齢者医療制度などがある (表 5).

これらいずれかの公的医療保険に日本国民全員が加入し, 病気やけがで医療が必要になった際に, 保険に加入する被保険者が出し合ったお金から医療費の一部が支払われる制度である.

表 5: 日本の医療保険制度[13]

制度		被保険者	保険者	給付内容
健康保険	健康保険組合	健康保険組合がある事務所の勤務社	健康保険組合	業務外の病気・けが・出産・死亡
	全国健康保険協会	上記以外の事業者の勤務者	全国健康保険協会	業務外の病気・けが・出産・死亡
	船員保険	船員	全国健康保険協会	業務外の病気・けが・出産・死亡
	共済保険	国家公務員・地方公務員・私学の教職員	各共済組合	病気・けが・出産・死亡
国民健康保険 (地域保健)	国民健康保険	健康保険（職域保険）に加入している勤労者以外の住民	市区町村	病気・けが
	国民健康保険組合	同業者組合の組合員	国民健康保険組合	病気・けが
退職者医療制度		職域保険の定年退職者で65歳未満の人	市区町村	病気・けが
後期高齢者医療制度		75歳以上の人および65歳以上で一定の障害を状態にある人	後期高齢者医療広域連合（都道府県単位）	病気・けが

2.2.3 アメリカの民間保険方式

アメリカで公的医療制度としては、高齢者および障害者を対象とする「メディケア」と生活保護受給者を対象とする「メディケイド」、その他に特定の子供が加入できる児童医療保険プログラム（CHIP：Children's Health Insurance Program）、受給資格のある退役軍人に対して医療を提供する退役軍人省の医療プログラムなどが存在する。それ以外の国民は民間保険に加入する。自営業者等は自分で民間保険に加入し、企業の従業員は企業が保険料を負担して従業員に提供する民間保険に加入する。また、2015年に定められた医療保険制度改革法（ACA：Patient Protection and Affordable Care Act、通称「オバマケア」）によって、従業員が50人以上在籍する企業には医療保険の提供が義務付けられたため、保険加入者のほとんどが企業を通じて保険プランに加入している[14]。

2008年時点でみると、65歳以上の人はだいたいメディケアで保障されているが、65歳未満の人は、60%は事業主提供の保険、6%が民間保険に個人加入、17%がメディケア・メディケイドに加入、17%が無保険者である。

アメリカの医療は世界最高の医療水準を誇り、医者や看護師等の医学教育についても、その水準の高さには定評がある。これは、アメリカの医療制度が自由競争を基本としていることが大きい。税方式や社会保障方式のように国から一律の報酬ではなく、質の高い医療には、高い対価が支払われるからこそ、医師の競争があり、医学は発達するためである。公的医療保険制度による一律の官僚的規制は、そうした競争とそれによる資源の効率的配分を阻害するからだめだ、というのがアメリカの考え方である。

アメリカの医療費はとて高く、国民1人当たり医療費でも、医療費の対GDP比でも、アメリカは世界的に高い（表6）。加えてアメリカでは被用者については、事業主が医療保険を提供するため公的制度は必要ないという発想がある。このため、公的医療保障制度は高齢者と貧困者に対して用意すれば良いという発想があった[15]。しかし、バイデン政権はヘルスケア改革に取り組むと明言しており、改革のポイントとして高騰する医療費を抑えること、保険の選択肢を増やすこと、仕組みをより単純で分かりやすくすることなどとしている。

表 6: OECD 加盟国の保険医療費の一部

国名	総医療費の対 GDP 比 (%)		一人当たり医療費 (ドル)	
		順位		順位
アメリカ	16.9	1	10,586	1
スイス	12.2	2	7,317	2
ドイツ	11.2	3	5,986	4
フランス	11.2	4	4,965	12
スウェーデン	11.0	5	5,447	5
日本	10.9	6	4,766	15
カナダ	10.7	7	4,974	11
デンマーク	10.5	8	5,299	7
ベルギー	10.4	9	4,944	13
オーストリア	10.3	10	5,395	6
ノルウェー	10.2	11	6,187	3
オランダ	9.9	12	5,288	8
イギリス	9.8	13	4,070	18
ニュージーランド	9.3	14	3,923	19
オーストラリア	9.3	15	5,005	10
ポルトガル	9.1	16	2,861	24
フィンランド	9.1	17	4,236	17
チリ	8.9	18	2,182	31
スペイン	8.9	19	3,323	21
イタリア	8.8	20	3,428	20

2.3 日本の病院の歴史

病院の歴史は、明治時代、第二次世界大戦後の敗戦、GHQによる改革、GHQ撤退後、少子高齢社会の到来がターニングポイントとなる。本節では、2.3.1項で明治から第二次世界大戦後の敗戦までの歴史、2.3.2項で敗戦後からGHQによる改革の歴史、2.3.3項でGHQ撤退後の歴史、2.3.4項で近年の病床規制と機能分化について述べる。

2.3.1 明治から敗戦まで

明治維新までの医療は、医師が患者宅に往診し、その場で薬を調剤して処方する方式であったため、外来や入院はなかった。このため、病院という患者を入院して治療する施設は江戸の小石川養生所と長崎養生所以外になかった。しかし明治維新後、新政府は国の方針として西洋医学を採用し、外国に頼らず独自に病院や病院システムを構築していった[16]。

明治時代から戦中までの病院数の推移を表7に示す[7]。明治元年から、各地で軍事病院の開設が始まり、明治4年の廃藩置県まで各藩は競うようにして藩立病院を開設していった。その後、藩は消滅するが一部は私立病院として存続し、公立病院が新設されていった。これらの病院は長崎養生所をモデルが多く取られており、主要病院は医学校に併設され医師の臨床教育のための施設であった。このため明治初期の公立病院の多くは医学校を併設していたが、明治10年の西南の役終結後に政府の財政が逼迫することとなった。これに対して、地方財政の危機を回避するために府県立医学校を全面的に廃止する方針となり、明治21年の勅令で公費による運営が不可能となったため廃止または民間への払い下げが行われた。このため私立病院を主体にして整備がなされていき、大正時代に入ると官立の病院数が増えるが、昭和に入ると再び私立病院数が増え、日本では医療提供の中核を民間病院・民間診療所が担っていくことになる。つまり世界において病院とは公的病院が大半であるのに対して、日本は民間病院で個人開業医の診療所から発展した小規模病院が病院医療の担うという医療提供体制となった。また当時の病院には施設基準はなく、各府県が独自に認可基準を定めており、明治24年4月に「私立病院並ニ産院設立規則」が施行され、「患者または産婦を10人以上入院せしめる施設」が「病院」または「産院」、これに該当しない施設が「診療所」と区分され、施設基準の始まりとなった[17,18]。

表 7：明治～戦中までの病院数の推移[7]

年次	病院	国立	公的	その他	一般診療所
1877 (明治 10) 年	159	12	112	35	
1882 (15)	626	(330)		296	
1892 (25)	576	(198)		378	
1897 (30)	624	3	156	465	
1902 (35)	746	4	151	591	
1907 (40)	807	5	101	691	
1926 (大正 15)	3,429	(1,680)		1,749	
1930 (昭和 5)	3,716	(1,683)		2,033	
1935 (10)	4,625	(1,814)		2,811	35,772
1940 (15)	4,732	(1,647)		3,085	36,416
1945 (20)	645	(297)		348	6,607

第二次世界大戦終了までの間は、国立病院は帝国大学附属病院、官立大学附属病院、海軍病院、陸軍病院という特定患者に対する病院、または伝染病、結核、精神病などの特殊な疾病に対する専門病院で、一般病院はほぼ無かった。一般病院はというと、診療を行う医師が自分の医療機関の経営を行う民間病院で、しかも個人の医師によって提供されていた。このときの経営は、現在の保険診療ではなく、患者が直接支払う治療費によって運営されていた。

大正 11 年に健康保険法が成立し、昭和 2 年に労働者の疾病と労災への保険給付が全面実施された。しかし、第一次大戦の後に続く戦後恐慌、関東大震災（大正 12 年）、金融恐慌（昭和 2 年）、世界恐慌（昭和 4 年）という経済恐慌によって国民の貧困化が進んだことで日本赤十字社と済生会の病院建設が急がれた。昭和 6 年に満州事変、昭和 12 年に日中戦争が起こった時代では、アジア・南洋への国家進出を支えるための人口膨張政策と健民健兵政策を主軸とした医療政策がとられた。特徴としては、結核病床の増設、軍医療施設の整備、国民医療法制定、日本医療団の展開が挙げられる。

連なる恐慌によって人口増加率低下、栄養不良による結核死亡率増加、母子保健水準の低下、乳児死亡率増加、徴兵検査甲種不合格者激増という人的資源の悪化が起こった。開

業医は疾病の治療を中心として医療提供をおこなっていたため、軍部の求める予防医学や健康増強には応えられていなかった。このため、軍部が日本の予防医学を重要課題として挙げ、無医村などの地域医療格差の是正や国民の健康保持、体力増進、体位向上が医療政策の課題となった。軍部の兵士増加要請によって昭和13年に「厚生省」が開設され、保健衛生行政を担当することとなった。そして、低所得者を対象とする市立病院や職域病院が創設され、昭和13年には国民健康保険が成立した。当時の病院規模は官公立病院の平均病床数25床、私立は34床と少なかった。

医療に対する国の関与が大きくなっていき、医師会を国策協力機関に改組する方針がとられ、第二次世界大戦中の昭和17年に特殊法人「日本医療団」が設立された。日本医療団は各道府県の主な病院を強制買収して、多数の病院、診療所、産院を全国規模で開設し、都市と農村間の医療機関配置格差の是正を図ろうとしたが、戦争と昭和20年8月の敗戦によって目的は果たせなかった。

2.3.2 敗戦後からGHQによる改革

敗戦後の医療提供体制は混乱し、急激なインフレーションで保険診療は機能しなくなった。なぜなら、保険者支払い分の医療費を後日に回収できても、診療に使用した医薬品は医療費回収までに価値が高騰するため、同じ数量の医薬品が補充できなくなったからである[16]。

GHQ (General Head Quarters) が日本を占領統治することになり、保健・衛生面では公衆衛生、社会保障の概念を取り入れていくことになった。GHQで社会保障を担当したのは公衆衛生福祉局局長のクロード・F・サムス准将で軍医であった。サムスは戦後から今日までの医療・福祉・公衆衛生制度の基礎を創ることとなり、疾病予防、治療、社会福祉、社会保障の4分野のバランスを保ちつつ、アメリカの制度をモデルとして保健・医療の近代化改革を行った。これはドイツに習って明治から築いてきた医療制度をアメリカ型医療制度に変更させることであった。しかし、日本の医療提供体制はアメリカ型の公営病院を軸とするものではなく、自由開業制や患者の医師選択の自由は尊重された。

GHQは軍や財閥、地主にはメスを入れたが、官僚組織には殆どメスを入れなかったため、厚生省は解散されずに残り、新たに衛生局、医療局、社会局ができた。サムスが試みた医療制度改革は、大学での医師育成(6年制)、ドイツ語の医学教育から英語教育への変更、卒後インターン制度導入、医師国家試験制度導入、最前線の衛生行政機関としての保健所を配置、医薬分業構想、看護婦の医師指示受姿勢から患者看護姿勢への意識改革、診療所の病床廃止、厚生省の改革など多項目に渡った。その後、昭和23年に国の医療制度を定める「医療法」「医師法」「歯科医師法」「薬剤師法」「保健婦助産婦看護婦法(保助看護法)」が制定された。結果として、日本は昭和27年までのGHQによる占領期の7年間の

間に世界中で最も近代的な保健福祉法典を有する国となった。

このとき、サムスは大学レベルの卒業生は一流の医師として大病院に就職して都市に留まることから、地方に配置する医師用に安価な教育で医師を育成するために医専があったと解釈したとされる。この医専から輩出される医師は二流の医療を提供しており、経済的利益を重視し、学会出席などの自己研鑽を怠っており、医療の質の向上を行っていなかった。病院は病棟が10床程度の自分の病院に入院させ、設備を欠く病院で自分の能力以上の手術処置をおこなっていたとされ、結果として多くの患者が亡くなっていた。このような医師の存在から、医専の廃校、医師資格国家試験導入、インターン制度導入、病院規模の最低基準の引き上げに向かわせることとなった。昭和23年に「医療法」が施行され、医療施設に対する人員や設備内容の最低基準が定められ、病院の収容患者10人以上から20人以上に引き上げられ、19床以下の零細小規模病院は有床診療所となった。

2.3.3 GHQ 撤退後

GHQ が撤退した後、GHQ が目指す改革が全て継承されたとは言い切れない。例として、病院経営マネジメントの知識取得・能力開発への努力はなくなり、経営・法律・会計知識に乏しい医師が自分の経営経験と勘を頼りに病院を運営するという事が始まった。自由開業制のもと病院と病床が増えるなか、看護師が不足しているにも関わらず労働環境改善は無視された。医師のインターン制度も目的の卒後研修は骨抜きにされ、大学病院はインターン研修生を無給の労働者として酷使した。後に看護師やインターン研修生が、病院ストライキや学園紛争によって、病院の理不尽な行いを世間に訴える事態にまで至る。

昭和23年の「医療法」制定から、都道府県および市町村が事業者になる「公立病院」には、設置費用への国庫補助を可能とする規定が設けられ、昭和26年には日本赤十字社、済生会、厚生農業協同組合連合会といった公立病院以外の公的医療機関へも国庫補助の対象が広がった。これらの病院も公的病院として扱われるが、事業主は民間医療機関である。このため、民間病院の中に、国庫補助を貰いつつ非課税の病院と、国庫補助もなく納税義務を負う病院の2種類が存在することとなり、日本の民間病院における二重構造が生まれ今日に至る。また、自由開業制に対して改変はなかったことから、病院整備は国や地域全体を俯瞰した計画のもと秩序立って行われず、市場原理主義のもとに各医療機関が独自の判断で設備投資を行ったため、やがて国公立病院の濫立が問題視されるようになった。このため昭和37年の医療法改正で、国公立病院に対して病床規制が導入されたが、民間病院は病床規制の対象外であった。

昭和33年に国民健康保険法が制定され、昭和36年に国民皆医療保険制度が発足した。国民の誰もが医療に接することが可能となり、医療提供側の病院や診療所は保険診療費部分の回収を気にすること無く医療を提供できるようになり、資金繰りは安定した。これに

に伴い、自由診療と保険診療を併せた混合診療は禁止されたことから、自由診療を行う医療機関は消滅した。このときの診療報酬請求は出来高制であったことから、個々の医療機関は保険適用範囲内で「医業収益極大化行動」をとるようになり国民医療費は増加していったが、これによって医療機関の成長と発展に寄与することとなった。

当時は無医町村など医療機関が不足している地域があり、病院の整備を医療金融公庫の貸付を通じて民間病院に行わせたが、病院数の増加よりも病床数の増加の方がはるかに高かった。欧州では公的機関が国内の医療施設の整備を行っているが、日本では国公立病院は病床規制がなされたため、民間病院が施設数の 7 割を占めることになった。戦後からの病院数の推移を表 8 に示す[7]。

GHQ が導入したインターン制度は昭和 43 年に廃止され、医学部卒後の国家試験に合格すれば医師になれたが、医師は不足し全国に多くの無医町村があった。昭和 48 年に田中角栄首相は無医大県の解消を掲げ、医科大学と医学部を設置することで医師不足の解消を図った。当時は、個人の医師が自宅併設の診療所を開設して往診も行き、やがて通院患者が増えて入院用ベッドを設置するようになる。そして病床数が 20 床を超えると診療所は病院に昇格していった。このため、どの病院にも外来部門が存在しており、入院患者は診療所や他病院からの紹介ではなく、自院の外来部門でスクリーニングして上層階の病棟へトスアップして病床を埋める方式をどの病院もとるようになった。したがって、日本の病院の外来部門は病院経営上、自院の病床を埋めるための重要な部門となり、地域全体として医療機能は特定化されなかった。病院が目標とするモデルとして、多くの標榜科を持ち、多くの外来患者を集める「総合病院」が理想とされた。このため、医大を卒業する医師は母校の許可病床 100 床以上で主要な診療科をもつ医学部附属病院を理想のモデルとして、総合病院を発展させる際の目標にした。加えて、当時の高度経済成長期時代は総合的で大規模であることが社会での成功と信用を表すステータスであったことにも起因した。ここに日本と欧米の病院機能の大きな違いが生まれることになり、欧米では病院は基本的に入院施設であり、外来部門を持たない病院が多いなか、日本ではすべての病院が大きな外来部門を持っている経緯である。

表 8: 戦後からの病院数の推移[7]

年次	病院	国立	公立	その他	一般診療所
1950 (昭和 25)	3,408	383	572	2,453	43,827
1955 (30)	5,119	425	1,337	3,357	51,349
1960 (35)	6,094	452	1,442	4,200	59,008
1965 (40)	7,047	448	1,466	5,133	64,524
1970 (45)	7,974	444	1,388	6,142	68,997
1975 (50)	8,294	439	1,366	6,489	73,114
1980 (55)	9,055	453	1,369	7,233	77,611
1985 (60)	9,608	411	1,369	7,828	78,927
1990 (平成 2)	10,096	399	1,371	8,326	80,852
1995 (7)	9,606	388	1,372	7,846	87,069
1996 (8)	9,490	387	1,368	7,735	87,909
1997 (9)	9,413	380	1,369	7,664	89,292
1998 (10)	9,333	375	1,369	7,589	90,556
1999 (11)	9,286	370	1,368	7,548	91,500
2000 (12)	9,266	359	1,373	7,534	92,824
2001 (13)	9,239	349	1,375	7,515	94,019
2002 (14)	9,187	336	1,377	7,474	94,819
2003 (15)	9,122	323	1,382	7,417	96,050
2004 (16)	9,077	304	1,377	7,396	97,051
2005 (17)	9,026	294	1,362	7,370	97,442
2006 (18)	8,943	292	1,351	7,300	98,609
2007 (19)	8,862	291	1,325	7,246	99,532
2008 (20)	8,794	276	1,320	7,198	99,083
2009 (21)	8,739	275	1,296	7,168	99,635

2.3.4 病床規制と機能分化

昭和 44 年に全国規模で老人の医療費自己負担分無料化が進展し、昭和 47 年には 2 県を除いて老人医療費が無料化された。このような状況から政府は、昭和 48 年に 70 歳以上（寝たきり等の場合は 65 歳以上）の医療費自己負担の実質無料化、国民健康保険被扶養者の自己負担額を 5 割から 3 割へ引き下げ、一定額を超える自己負担額を支給する高額療養費制度導入、年金給付水準の大幅引き上げなどの社会保障政策を実施した。この老人医療費無料化政策によって、老人も医療提供側も経済的負担を気にせず治療が行えるようになり、生活水準、栄養状態の向上から日本人の平均寿命は伸長し、老人の絶対数は増加していった。また診療報酬は出来高制で薬価差益も大きかったため、医業収益と医業利益は増加した。加えて、病院経営面では老人の入院患者は好ましく、全国の老人病院数とその病床は増加し、国民医療費は増大し自治体や保険者に財政面での課題が顕在化した。昭和 57 年に制定された「老人保健法」によって市町村が保険者かつ運営主体となり、この制度で一部患者負担が導入され、老人の医療費自己負担の実質無料化は若干後退した。

昭和 61 年以降、病院から自宅への橋渡しとして老人保健施設が創設された。平成 2 年には老人保健法が改正され、デイサービス、ショートステイ、ホームヘルプが推進され、医療法人をはじめとする病院が事業者になれた。自治体からの手厚い補助金等から老健施設は少ない自己資金で開設が可能であり、医師や看護師の人員配置も病院に比べて緩く、病院の運営上から近くに老健施設があることは好ましかったことから、病床過剰地域の民間病院は老健施設を病院に併設して事業展開を図っていった。平成 4 年の第二次医療法改正では病床区分での「その他の病床」の中に「療養型病床群」という区分が現れ、平均在院日数の長い慢性期の高齢者は療養型病床群に入院するようになった。平成 12 年の第四次医療法改正によって「療養病床」に変更された。昭和から平成にかけて高齢者人口の絶対数と比率は増加し高齢社会となり、そして少子高齢化に伴って疾病構造は変化した。長期療養を必要とする患者の増加から高齢者医療費は増加し、高齢者の自己負担率の変更、対象年齢の引き上げを図り、後に「老人保健制度」は「後期高齢者医療制度」へと改められた。

医師の自由開業制によって、病床数の量的確保は昭和 60 年頃に達成したと判断されたが、地域偏在と病院機能の分担は不明確であったため、第一次医療法改正にて「医療計画」が導入された。医療計画は都道府県ごとに医療を提携する体制の確保に関する計画を策定し、体系だった地域の医療体制を目指した。定める事項としては以下の 7 項目である。

1. 医療圏（医療計画の単位となる区域）
2. 基準病床数算定
3. 地域支援病院整備目標
4. 医療関係施設相互の機能の分担及び業務の連携（設備、器械・器具の共同利用など）
5. 休日診療，夜間診療等の救急医療確保
6. 医師，歯科医師，薬剤師，看護師等の医療従事者の確保
7. その他の医療提供体制の確保

この医療計画に沿って公立病院，民間病院の整備を進めていくこととなり，自由開業制を踏まえつつも知事は制約を課すことが可能となった。病床数に関しては，都道府県内で区分された二次医療圏と都道府県単位で区分された三次医療圏に必要な病床数を設定し，必要病床数を上回っている二次医療圏は過剰病床地域とされた。過剰病床地域における病院開設や増床には，都道府県医療審議会の意見を聞いた上で，知事が勧告を行えることとなった。これにより，特に都市部のほとんどは病床過剰地域となったため，都市部の病床数の増加には歯止めがかかり，また病床規制によって病院数の増加も止まった。

病床の区分として，昭和23年の医療法制定時は「精神病床」「伝染病床」「結核病床」を独立させ，それ以外は「その他の病床」として区分した。その後，平均寿命の伸長と高齢化により疾病構造が変化したことから，老人保健法によって「その他の病床」のなかに「特例許可老人病棟」が置かれた。次に第二次医療法改正時に「療養型病院群」の区分が現れ，そして「療養病床」が創られ，療養病床では医師・看護師の人数は手薄になるが，介護職員の配置を厚くすることとなった。このため現在は，「精神病床」「感染症病床」「結核病床」「療養病床」「一般病床」の5つの区分に分けられている。

次に本格的な少子高齢社会を見据えて，医療資源を効果的かつ効率的に活用するために一般病床についてさらなる機能分化が図られている。これは，一般病床は診療報酬の入院基本料が4つに区分されており，入院患者：看護師が7：1，10：1，13：1，15：1でより看護師の割合が多いほど高度な医療，良質な医療を行っている病床として診療報酬点数が高い。結果として，7：1の看護が2万床と見込まれて開始したが，病院の合理的な経営判断から7：1が他の割合より多くなり33万床近くにまで急増した。そこで急性期から亜急性期，回復期，療養，在宅に至るまでの流れを構築するため，一般病床について機能分化を進めていくこととなった。地域において，それぞれの医療機関の一般病床が担っている医療機能を「高度急性期」，「急性期」，「回復期」，「慢性期」に分け，高度急性期の病床が最

も多いのではなく、地域全体として必要な医療機能がバランスよく提供される体制を構築していくこととなった（表 9）。これは看護師配置によって病床を区分して医療政策を行ってきた従来の考えから、地域のニーズに応じて病院が自主的に効果的な医療提供ができるような、医療機能による区分をすることとなった（図 5）。他に在宅医療を推進しており、住み慣れた地域や自宅で医療提供を継続することで、生活環境の変化が精神的・肉体的な負担につながりやすい患者を対象に療養生活を支えることができる。または治癒が期待できない疾患や障害のために、何らかの介護が必要な患者とその家族を居宅で支えることができる。こうして、費用がかかるとされる病院での医療提供を居宅にシフトさせることによって医療費の抑制が期待されている。

表 9: 病床機能における医療機能区分

医療機能の名称	医療機能の内容
高度急性期機能 (15～16日程度)	急性期の患者に対し、状態の早期安定化に向けて、診療密度が特に高い医療を提供する機能
急性期機能 (9日程度)	急性期の患者に対し、状態の早期安定化に向けて、医療を提供する機能
回復期機能 (60日程度)	急性期を経過した患者への在宅復帰に向けた医療やリハビリテーションを提供する機能。特に、急性期を経過した脳血管疾患や大腿骨頸部骨折等の患者に対し、ADLの向上や在宅復帰を目的としたリハビリテーションを集中的に提供する機能（回復期リハビリテーション機能）。
慢性期機能 (135日程度)	<ul style="list-style-type: none"> ・長期にわたり療養が必要な患者を入院させる機能 ・長期にわたり療養が必要な重度の障害者（重度の意識障害者を含む）、筋ジストロフィー患者又は難病患者等を入院させる機能

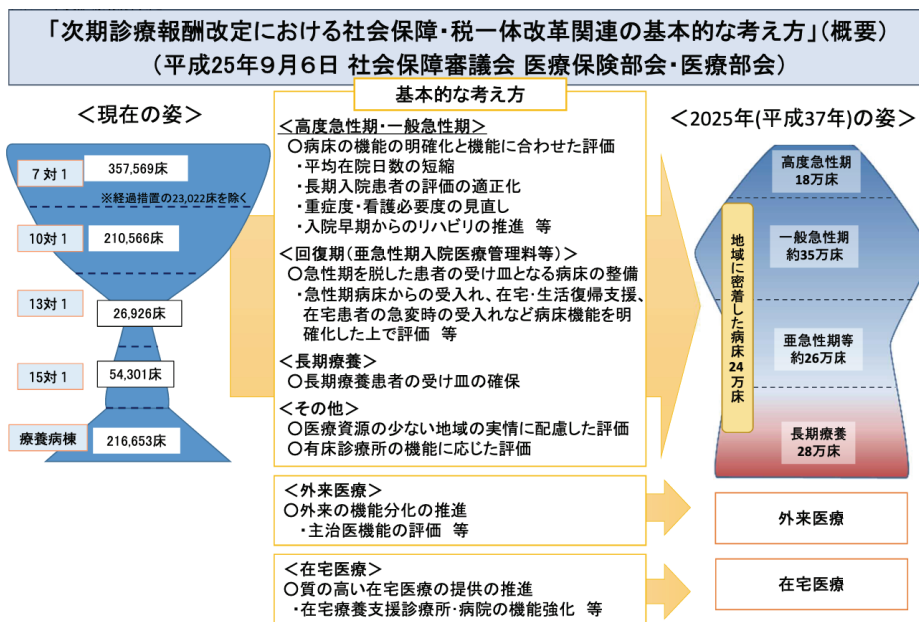


図 5: 平成 26 年度診療報酬改定による病床機能[19]

2.4 病院の課題

戦後、自由開業制に対して改変はなかったことから市場原理主義のもとに各医療機関が独自の判断で設備投資を行ったため、国公立病院が濫立した。昭和 36 年に国民皆医療保険制度が発足し、保険適用範囲内で「医業収益極大化行動」をとるようになり国民医療費は増加、さらに昭和 48 年に 70 歳以上（寝たきり等の場合は 65 歳以上）の医療費自己負担の実質無料化、国民健康保険被扶養者の自己負担額を 5 割から 3 割へ引き下げなどの社会保障政策を実施し医療費は高騰した。そして日本の経済成長が終焉したことによって、社会保障ばかりに国費を投入することができなくなり、オイルショックを契機に医療費抑制への方向転換することとなった。加えて昭和から平成にかけて高齢者人口の絶対数と比率は増加し高齢社会となり、少子高齢化に伴って疾病構造は変化した。疾病構造の変化により増加した生活習慣病は完治が困難で多額の治療費を必要とする場合も多く、医療費増大の要因の一つとなっている。

日本の医療提供体制と医療保険制度は国民皆保険制度が施行されて以来、何とか破綻せずに機能しているが、新薬やロボット手術を始めとした新しい治療で医療は高度化し続けている。一方で医療費増大の一途を辿るなかで医療提供体制を維持するために医療機関の機能分化が求められており、在宅医療にも病院は対応していく必要がある。つまり病院は患者に対して病気を治療するだけでなく、包括的な医療サービスを提供するために高度化しなければならない。このなかで医療現場の安全性の担保と、医療事故から患者の安全を守るという医療の質の向上が社会的に求められるため、医療従事者の負担は増大する一方

である。もっとも、病院の医療従事者は既に業務の膨大化と煩雑化によって多忙であり、慢性的に超過勤務が多い。医師や看護師は労働時間が長く、患者への対応以外に多くの時間がとられる。特に看護師は患者への対応以上に患者の情報収集や記録にかかる時間の方が長く、就業時間の前や後といった時間外にまで行わざるを得ない。このような多忙で疲弊し易い環境下で、患者安全の確保と医療の質を担保することは困難である。しかしながら、看護師は慢性的に不足しており人的資源の追加投入は困難かつ、病院経営にとって人件費が負担となるため容易ではない。

したがって、高度化および複雑化する医療と社会的使命の変化に対応した医療サービスを提供するためには、病院はもはやこれまでの運用では維持できないと思われる。この解決策のひとつとして、ICT の利用による病院情報システムの利用が期待されている。よって、次章では病院情報システムの概要について述べ、現状および問題点を論じる。

第3章 病院情報システム

病院情報システムは、医事会計システムの構築に始まり診療情報を伝達・共有し病院の業務を支援する為に電子カルテシステムや多くの部門システムが開発され医療機関で利用されている。本章では、3.1 節で病院情報システムの概要について、3.2 節で病院情報システムの歴史を述べる。そして、3.3 節で電子カルテについて、3.4 節で医療機器管理システムについて、3.5 節で医療機器と病院情報システムの連携について述べる。最後に3.6 節で病院情報システムの現状と課題について述べる。

3.1 病院情報システムの概要

病院には、外来、病棟以外に、検査部、薬剤部、放射線部など多くの部門が存在し、多くの職種の職員がそれぞれに役割を担う。これらの職種が連携して患者の診療にあたることにより病院として機能するが、職員が連携するためには必要な情報を伝達し合い、診療情報を共有しなければならない。従来は紙で情報の伝達、蓄積を行ってきたが、情報技術の発達により、部門を結んで病院の業務を支援するコンピュータシステムが使われるようになってきた。この診療情報を伝達・共有し、病院の業務を支援するコンピュータシステム全体を病院情報システム (Hospital Information System: HIS) と言う。

病院情報システムの発達とともに医療機器の IT 化による自動記録が進んでいる。まず初期に、放射線診断装置の放射線画像を管理する画像保存システム (Picture Archiving and Communication Systems: PACS) が普及していった。その後、電子カルテの普及とともに、患者の検温表を自動記録するため、バイタルサイン (血圧・脈拍数・呼吸数・体温) 等を測定する患者監視装置が病院情報システムと連携できるようになっている。今後さらに、看護師の業務量負担軽減の観点から、他の医療機器についても連携の拡大が行われつつある。

3.2 病院情報システムの発展の歴史

病院の中でコンピュータが業務支援で使われ始めたのは、1960 年代からであり、患者ごとの医療費の請求処理を行う医事会計の部分であった (表 10)。医事会計処理のためには、患者に行われた医療行為の情報を収集し、医療保険制度等の複雑なルールに基づいて請求するために膨大な事務処理と請求計算の迅速性が求められるため、医事会計システムの大規模コンピュータが使用されるようになった。医事職員が処方箋や検査依頼用紙の控えなどの用紙から、実施された診療行為をシステムに入力することにより、請求額の計算、請求書の発行が自動化された[3]。

1970年代からは、特に検査部門では機械化が進められ、自動分析装置により大量の検査をこなす体制を整えることが求められた。その後、複数の自動分析装置を統合的に制御する検査部門システムが構築された。また、診療行為に関する情報は、診察室や病棟で発生する。当時は、医師が処方箋や検査の依頼用紙を記載し、薬剤部、検査部へ用紙が搬送され、同時に、複写用紙が医事会計部門に搬送されることにより情報が伝達されていた。この用紙に基づき結果の報告用紙を作成していた。そして、自動分析装置を利用する検査では、患者情報などを入力し、結果報告書がプリント出力されていた。この運用では、これらの用紙を受ける中央診療部門で用紙に記載された内容を転記で入力し、さらに医事会計部門でも医事会計システムにデータを入力することになる。この重複作業をなくし、情報伝達を効率化するために構築されたのがオーダエントリシステムであり、1980年代から大規模病院を中心に導入されていった。

1990年代は、グラフィカルユーザーインターフェース（GUI）のシステムが一般的となり、これまで大型コンピュータを中心とした構成から、サーバ機を用いた構成に変わり、端末にはクライアント機となるパーソナルコンピュータが利用されるようになった。その後、対象範囲も急速に広がり、用紙で情報伝達していた部分が、コンピュータシステムに置き換えられていった。また、部門システムについても、各部門にそれぞれの業務を支援するシステムが導入されていった。

1999年に厚生省から診療録などを電子媒体で保存することを認める通知が出され、2000年代には、紙の診療録をコンピュータシステムで管理する電子カルテシステムが開発されるようになった。また、フィルムを媒体としてきた放射線画像についても、2008年に国が「電子画像管理加算」を新設し請求できるようになったことから、レントゲンフィルムを画像データで保存する PACS が普及した[20]。

その後、オーダリングシステム、電子カルテシステムなどを統合する病院情報システムが大規模病院を中心に普及してきている[3]。

表 10: 日本の医療 IT 化の歴史

1960 年代	電子計算機の一般化により，医事業務における診療報酬請求計算の電子化も始まる．
1970 年代	医事会計の時間短縮と効率化のためのレセプトコンピュータの開発．臨床検査部門や薬剤部門，放射線部門などの中の医療機器の情報化が始まる．
1980 年代	部門システムやオーダーリングシステムの開発．大規模病院の部門内の情報システム化や医事会計システムなどが普及．
1990 年代	電子カルテシステムの開発．遠隔医療などのシステムが活発化．計算機技術としてはクライアント・サーバ技術が登場し，インターネット技術と共に定着する．
2000 年代以降	地域連携システムの開発．「保健医療分野の情報化グランドデザイン」の公表．レセプトのオンライン請求の義務化．電子画像管理加算という PACS の普及促進のための点数が新設され，フィルムレスの流れが進む．

3.3 電子カルテ

電子カルテは，様々な医療情報を電子情報として一括してデータベースに記録するシステムである．本節では，3.3.1 項で現在の電子カルテの普及状況について，3.3.2 項で診療記録の種類と取り巻く法律について，3.3.3 項で看護記録の概要を述べる．

3.3.1 電子カルテの普及

従来，医師・歯科医師が診療録を紙のカルテとして記入していたが，電子的なシステムに置き換え，電子情報として一括してカルテをデータベースに記録するシステムである．1999 年に診療録等の電子媒体による保存が認められ，2001 年 12 月の e-Japan 構想の一環として厚生労働省が策定した「保健医療分野の情報化にむけてのグランドデザイン」において，「2006 年度までに全国の 400 床以上の病院および全診療所の 6 割以上に電子カルテシステムの普及を図ること」が目標として始まった．その後，2002 年に診療録等の電子媒体による外部保存が認められた．ただし 2017 年時点で 400 床以上の病院においても普及率 85.4%に達した．普及率の経時変化を図 6 に示す[21]．

電子カルテシステム

	一般病院 (※1)	病床規模別			一般診療所 (※2)
		400床以上	200～399床	200床未満	
平成20年	14.2% (1,092/7,714)	38.8% (279/720)	22.7% (313/1,380)	8.9% (500/5,614)	14.7% (14,602/99,083)
平成23年 (※3)	21.9% (1,620/7,410)	57.3% (401/700)	33.4% (440/1,317)	14.4% (779/5,393)	21.2% (20,797/98,004)
平成26年	34.2% (2,542/7,426)	77.5% (550/710)	50.9% (682/1,340)	24.4% (1,310/5,376)	35.0% (35,178/100,461)
平成29年	46.7% (3,432/7,353)	85.4% (603/706)	64.9% (864/1,332)	37.0% (1,965/5,315)	41.6% (42,167/101,471)

オーダーリングシステム

	一般病院 (※1)	病床規模別		
		400床以上	200～399床	200床未満
平成20年	31.7% (2,448/7,714)	82.4% (593/720)	54.0% (745/1,380)	19.8% (1,110/5,614)
平成23年 (※3)	39.3% (2,913/7,410)	86.6% (606/700)	62.8% (827/1,317)	27.4% (1,480/5,393)
平成26年	47.7% (3,539/7,426)	89.7% (637/710)	70.6% (946/1,340)	36.4% (1,956/5,376)
平成29年	55.6% (4,088/7,353)	91.4% (645/706)	76.7% (1,021/1,332)	45.6% (2,422/5,315)

【注 釈】

(※1) 一般病院とは、病院のうち、精神科病床のみを有する病院及び結核病床のみを有する病院を除いたものをいう。
 (※2) 一般診療所とは、診療所のうち歯科医療のみを行う診療所を除いたものをいう。
 (※3) 平成23年は、宮城県の石巻医療圏、気仙沼医療圏及び福島県全域を除いた数値である。

図 6：電子カルテの普及状況[21]

実際のカルテには、様々な医療情報が収録される。カルテとして最も重要な情報に保険診療用1号用紙があり、患者名、生年月日、住所、保険関連情報、病名と転帰、既往症、主要症状経過、処方、手術、処置が収録される。その他に画像、波形データ、紹介状、指導内容書、説明書、同意書、看護記録、手術記録などがある。このようなすべての医療情報を電子化したものが電子カルテである。

3.3.2 診療記録

医療機関に、医師・看護師だけでなく検査技師、薬剤師など多岐にわたる職種の職員がそれぞれの役割を担っており、このような職種が密に連携して患者の診療にあたっている。職員同士が連携し診療を行うために、必要な情報を伝達し診療情報を共有する必要がある。診療記録は医師・看護師・理学療法士など診療に関わる医療関係者が実施した診療内容を記録したものである[22]。

厚生労働省の「診療情報の提供等に関する指針」において、診療記録と、「診療録、処方箋、手術記録、看護記録、検査所見記録、エックス線写真、紹介状、退院した患者に係る入院期間中の診療経過の要約はその他の診療の過程で患者の身体状況、病状、治療等について作成、記録又保存された書類、画像等の記録」と定義されている[23]。

法律によって医療関係者が作成・保存を義務付けられている諸記録として、以下が挙げ

られる[24].

1. 医師法第 24 条に規定されている診療録
2. 歯科医師法第 23 条に規定されている診療録
3. 保健師助産師看護師法（昭和 23 年法律第 203 号）第 42 条に規定されている助産録
4. 医療法（昭和 23 年法律第 205 号）第 46 条第 2 項に規定されている財産目録，同法第 51 条の 2 第 1 項に規定されている事業報告書等，監事の監査報告書及び定款又は寄附行為，同条第 2 項に規定されている書類及び公認会計士等の監査報告書並びに同法第 54 条の 7 において読み替えて準用する会社法（平成 17 年法律第 86 号）第 684 条第 1 項に規定されている社会医療法人債原簿及び同法第 731 条第 2 項に規定されている議事録
5. 医療法第 21 条，第 22 条及び第 22 条の 2 に規定されている診療に関する諸記録及び同法第 22 条及び第 22 条の 2 に規定されている病院の管理及び運営に関する諸記録
6. 診療放射線技師法（昭和 26 年法律第 226 号）第 28 条に規定されている照射録
7. 歯科技工士法（昭和 30 年法律第 168 号）第 19 条に規定されている指示書
8. 薬剤師法（昭和 35 年法律第 146 号）第 27 条に規定されている調剤済みの処方せん
9. 薬剤師法第 28 条に規定されている調剤録
10. 外国医師等が行う臨床修練に係る医師法第十七条等の特例等に関する法律（昭和 62 年法律第 29 号）第 11 条に規定されている診療録
11. 救急救命士法（平成 3 年法律第 36 号）第 46 条に規定されている救急救命処置録
12. 医療法施行規則（昭和 23 年厚生省令第 50 号）第 30 条の 23 第 1 項及び第 2 項に規定されている帳簿
13. 保険医療機関及び保険医療養担当規則（昭和 32 年厚生省令第 15 号）第 9 条に規定されている診療録等
14. 保険薬局及び保険薬剤師療養担当規則（昭和 32 年厚生省令第 16 号）第 6 条に規定されている調剤済みの処方せん及び調剤録
15. 臨床検査技師等に関する法律施行規則（昭和 33 年厚生省令第 24 号）第 12 条の

3に規定されている書類

16. 歯科衛生士法施行規則（平成元年厚生省令第46号）第18条に規定されている歯科衛生士の業務記録
17. 高齢者の医療の確保に関する法律の規定による療養の給付の取扱い及び担当に関する基準（昭58年厚生省告示第14号）第9条に規定されている診療録等
18. 高齢者の医療の確保に関する法律の規定による療養の給付の取扱い及び担当に関する基準第28条に規定されている調剤済みの処方せん及び調剤録

3.3.3 看護記録

診療記録のうち、看護師が記載する記録は看護記録と呼ばれるが、看護記録は上記の法律によって記録が義務付けられる訳ではない。必ずしも看護記録の記載は法律上必要とされないが、診療情報開示の考え方が国民に浸透したことに伴い、看護記録の開示を求められることが多くなっている。また、医療事故発生時等において、看護記録の記載内容から事実を確認されることがある。さらに、診療報酬算定の根拠等において看護記録が重要視されている[25]。

看護記録の目的は、「看護実践を証明する」こと、「看護実践の継続性と一貫性を担保する」こと、「看護実践の評価及び質の向上を図る」こととされる[25]。

1. 看護実践を証明する
看護実践の一連の過程を記録することにより、専門的な判断をもとに行われた看護実践を明示する。
2. 看護実践の継続性と一貫性を担保する
看護職の間で、看護記録を通じて看護実践の内容を共有することにより、継続性と一貫性のある看護実践を提供する。
3. 看護実践の評価及び質の向上を図る
看護記録に書かれた看護実践を振り返り、評価することで、次により質の高い看護実践を提供することにつながる。また、看護研究等で看護記録に書かれた看護実践の内容を蓄積、分析し、新しい知見を得ることで、より質の高い看護実践の提供につながる。

これらのことから、看護記録の様式には、基礎情報（データベース）、看護計画、経過記録、要約（サマリー）等があり、以下の内容が記載されている（表11）。

表 11: 看護記録の様式[25]

様式	内容
基礎情報 (データベース)	看護を必要とする人の病歴や現在の治療, 使用薬剤, アレルギー, さらに, 身体的, 精神的, 社会的, スピリチュアルな側面の情報等を記載したものである.
看護計画	看護を必要とする人の健康問題と期待する成果, 期待する成果を得るための個別的な看護実践の計画を記載したものである.
経過記録	看護を必要とする人の意向や訴え, 健康問題, 治療・処置, 看護実践等の経過を記載したものである.
要約 (サマリー)	看護を必要とする人の健康問題の経過, 情報を要約したものである.

3.4 医療機器管理システム

医療機器管理システムは, 病院内の医療機器を保守管理する目的で利用されている. 近年, 医療機器の高度化・増加に伴い, 法整備と共に開発されてきた経緯がある. 本節では, 3.4.1 項で現在の医療における医療機器について, 3.4.2 項で医療機器を取り巻く法規制について, 3.4.3 項で医療機器管理システムの概要を述べる.

3.4.1 現代の医療における医療機器

古来より人の目で診断し人の手で治療を行ってきた医療は, 聴診器やメスといった「医療用の道具」の発明により「新しい目・手」を得ることができ, 診断・治療技術のさらなる進歩・発展を遂げるようになった. そして, 19 世紀末から 20 世紀初頭にかけて, ドイツの物理学者レントゲンにより X 線装置, ロシアの物理学者コロトコフにより血圧計, オランダの生理学者アイントーフエンにより心電計が開発され, 医療の世界に「医療用の機械」, いわゆる医療機器が使用されるようになりその重要性が認識されるようになった. 20 世紀に入ると機器開発の基盤となる機械・電気電子など工学分野の著しい発達に支えられて多種多様な医療機器が開発され, 今や治療のみならず臨床検査・放射線検査および治療・生体計測など多岐に渡る分野にて日常的に使用されるようになった. そして, 医療機器の導入はこれらの分野のさらなる進歩・発展をもたらし, そこから得られた知見が医療機器の更なる発展を促すことになり, これらの相互の発展が結果として医療そのものの発展と高度化に繋がることとなった[26].

実際の臨床現場における医療の遂行にも医療機器は多く用いられており, その中でも機

器を利用した検査による早期での病気発見や生命維持管理装置による救急患者や重症患者の治療のように、医療機器なくしては分からない・救えないといった医療場面も多くなっている。また、近年は医療分野の情報化に伴い、遠隔地における医療行為の手段としてネットワークを介した医療機器の遠隔操作による治療や医療情報のデータベース管理と複数の医療機関における情報共有など、ネットワークやほかの様々な情報技術と医療機器の結び付きが強くなっている。

このように、現代医療における医療技術の発展は医学と工学の領域を融合した医用工学の発達によるものであり、研究開発され高度化する多くの医療機器が、安全かつ効果的な医療の遂行に多大な貢献をしている。特に、医療機器の果たす役割は検査、診断から治療、リハビリ、そして情報技術の活用など多様化し、医療機器は現代医療を支える上で必要不可欠な存在となっている。

3.4.2 医療機器を取り巻く法規制

医療機器は 3.4.1 項で記述した歴史からも急激に高度化・多様化しており、安全確保するため法律によって厳格に定義・規制される。関連する法律を 2 つ以下に述べる。

(1) 医療法

医療機関における医療機器の安全確保に係る対策については、医療法で規定される。医療法第 6 条 10 項では「病院、診療所または助産所の管理者は、厚生労働省令で定めるところにより、医療の安全を確保するための指針の策定、従業者に対する研修の実施その他の当該病院、診療所または助産所における医療の安全を確保するための措置を講じなければならない」としている[27]。つまりここでは、病院などの医療機関に対し医療の安全確保のための指針を策定すること、従業員に対する研修を実施することなどの安全確保のための措置を講じることを義務付けている。さらに、この規定を受け、医療法施行規則では病院などの医療機関において医療の安全管理のための体制確保を求め、医療機器については「医療機器の安全管理のための体制確保に係る措置」を講じなければならないと規定している[28]。これには、「医療機器の安全対策のための責任者（医療機器安全管理責任者）の配置」、「従業者に対する医療機器の安全使用のための研修の実施」、「医療機器の保守点検に関する計画の策定および保守点検の実施」、「医療機器の安全使用のために必要となる情報の収集その他の医療機器の安全使用を目的とした改善のための方策の実施」の 4 項目が義務付けられている。これにより、医療機器の安全使用と管理体制の整備が法令に明記され、医療機関は安全な医療機器を提供することが責務となった。また、この詳細事項については、平成 19 年 3 月 30 日厚生労働省医政局指導課長・研究開発課長通知「医療機器に

係る安全管理のための体制の確保に係る運営上の留意点について」により示されている[29]。この中で、特に医療機器の使用に当たっては医療機器製造販売業者が作成した添付文書などの記載に従って実施するよう指導されており、そのため医療機器安全管理責任者に添付文書などの医療機器の安全使用・保守点検などに関する情報を整理し、その管理を行う事を求めている。

(2) 医薬品，医療機器等の品質，有効性及び安全性の確保等に関する法律

我が国における医療機器は、「医薬品，医療機器等の品質，有効性及び安全性の確保等に関する法律」に規定されている。2014年11月25日の薬事法改定に伴い、従来の薬事法から「医薬品，医療機器等の品質，有効性及び安全性の確保等に関する法律」（以下、医薬品医療機器等法）と改称された[30]。医療機器・体外診断用医薬品の特性を踏まえた改定で、医療機器の承認許可の迅速化，合理化を進め，開発促進を図ることを改正目的としている。

医薬品医療機器等法第2条4項によると「人若しくは動物の疾病の診断，治療若しくは予防に使用されること，または人若しくは動物の身体の構造若しくは機能に影響を及ぼすことが目的とされている機械器具など」とされており[30]，平成17年までは医療で用いられる用具や機械はすべて「医療用具」とされたが，同年4月1日の薬事法改正によって「医療機器」と総称されるようになった[31]。現在，医薬品医療機器等法によって医療機器として指定される機器はその使用用途，使用部位，使用方法，構造，材質などから病院用機器・診断用機器・手術用機器・処置用機器・歯科用機器・簡易医療機器に分けられる。加えて，その機器が人の生命・健康におよぼすリスクの大きさに応じてクラス分類がある。表12にその分類と不具合発生時のリスクの大きさ，対象医療機器を示す。さらに，この中でもクラス分類に関わらず保守点検・修理・その他の管理に必要な専門的知識・技術を必要とする医療機器を「特定保守管理医療機器」として指定しており，コンタクトレンズや自動体外式除細動器（Automated External Defibrillator: AED）などがこれにあたる。現在，医薬品医療機器等法で指定される医療機器の総数は非常に多く，特定保守管理医療機器に指定されるだけでも約1000種にも上る。また，医薬品医療機器等法第63条2項では医療機器製造販売業者に医療機器の有効性・安全性の確保，適正使用・管理のために必要な情報が記載された添付文書を医療機器ごとに提供しなければならないと定めている。添付文書に記載される事項は，「使用方法，取扱上の注意事項（禁忌・禁止事項を含む）」，「保守点検に関する事項」，「省令に定める事項」と様式の統一化が図られている。また，独立行政法人医薬品医療機器総合機構（Pharmaceutical and Medical Devices Agency: PMDA）が電子登録によるデータベース化を推進している。

さらに，医薬品医療機器等法第77条の4では医療機器による危害の防止および副作用な

どを厚生労働大臣に報告すること義務付けている。製造販売業者などは、医療機器の使用によって保健衛生上の危害が発生し、また拡大の恐れがあることを知ったときは、これを防止するために廃棄、回収、販売の停止、情報の提供などの措置を講じなければならないと定めている。また、医療機器の副作用（不具合）などに起因するものと疑われる疾病、傷害または死亡の発生または感染症の発生その他、医療機器の有効性および安全性に関する事項を知ったときは、その旨を報告しなければならないとされる。

表 12：医療機器のクラス分類

クラス分類	リスクの大きさ	対象医療機器
クラスⅠ (一般医療機器)	不具合が生じた場合、人体へのリスクが極めて低い	メス、ピンセット、医療用不織布、手術用照明器など
クラスⅡ (管理医療機器)	不具合が生じた場合、人体へのリスクが比較的低い	MRI、X線撮影装置、超音波診断装置、汎用心電計など
クラスⅢ (高度管理医療機器)	不具合が生じた場合、人体へのリスクが比較的高い	人工透析装置、人工呼吸器、バルーンカテーテルなど
クラスⅣ (高度管理医療機器)	患者への侵襲性が高く、不具合が生じた場合、生命の危険に直結するおそれ	ペースメーカー、人工心臓弁、ステントなど

3.4.3 医療機器管理システムの概要

近年の法改正により医療機器の安全確保が強化され医療機関の責任の所在が明確化された。そして医療機器管理の必要性が増大するにあたり、医療機器管理を支援するシステムが様々に開発された[32]。

従来、各病棟や部門ごとに医療機器は保守点検などの管理がなされ、病院内でばらばらに分散管理されていた。しかし、医療機器と管理者の接点が少なく管理が不十分になることが危惧されるため、医療機器管理部門（MEセンター）から各部門に対して医療機器の貸出・返却を行う中央管理が主流になった。これにより保有台数の適正化や始業前点検による機器安全の向上、機器情報の一元化による適正管理などを図っている。また、情報管理を徹底した上で、集中治療室など使用頻度の高い部門に対しては、一部定数配置を行う中央分散併用管理法をとる施設もある。そこで情報管理を支援するために医療機器管理システムが発達してきた。

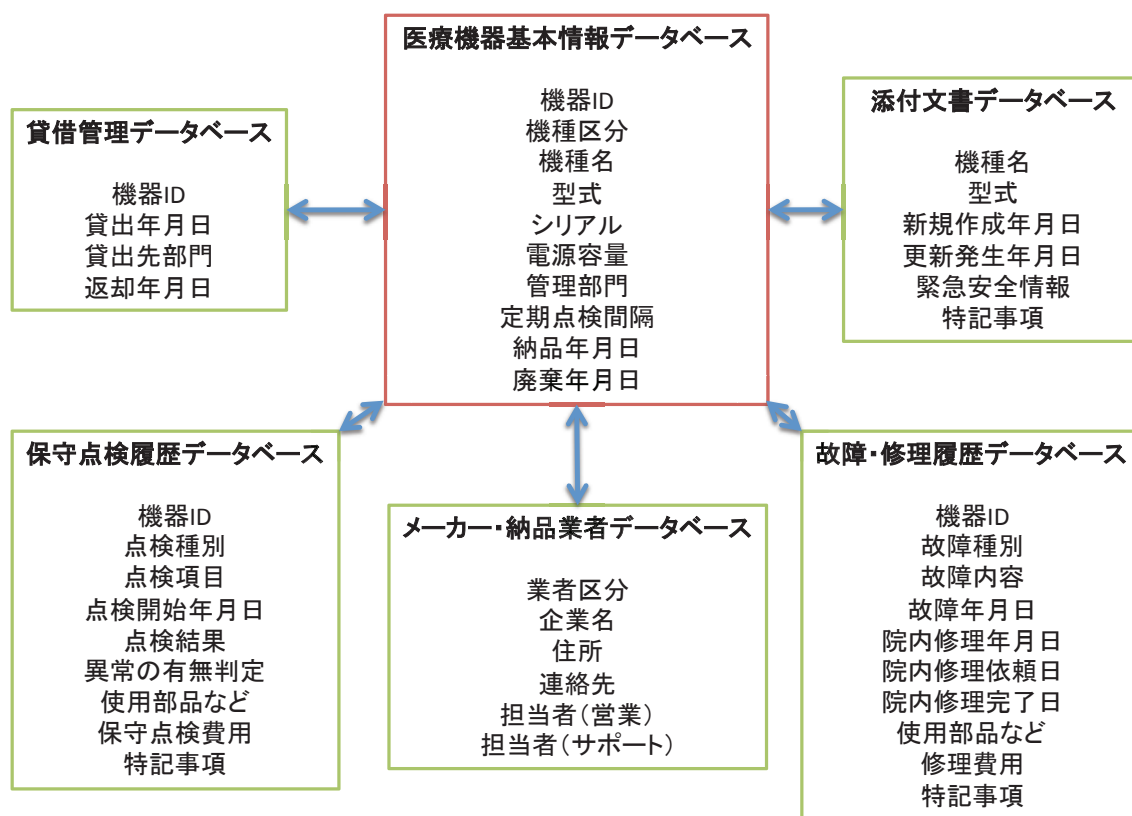


図 7：医療機器管理システムの概略

従来の医療機器情報管理は手書帳簿や表計算ソフトを利用していたが、医療機器は断続的に永年使用され、個々の情報は膨大で機種や保有台数も年々増加し、従来法では十分な管理が困難となり、医療機器管理システムが多数開発された。また、医療機器安全管理責任者の配置が義務付けられたため、医療機器の保守管理は努力目標から義務へと移行し、保守計画の策定や規定項目の記録保存が義務化された。これを支援するために、医療機器管理システムは機器基本情報を中心として、貸借所在、保守点検情報の管理など機器管理部門全体を支援するシステムとなる[33]。医療機器管理システムの概念図を図 7 に示す。

3.5 医療機器と病院情報システムの連携

紙カルテから電子カルテに移行した際、患者監視モニター等で計測した心拍数や血圧などのバイタルサインを、電子カルテに転記入力して熱計表を作成していたが、入力する手間が職員に負担としてかかっていた。さらに勤務時間内に入力できない場合には、あらかじめメモに記載した計測値を、勤務時間外に後追いで入力する場合もある。このため、ネットワークを介して医療機器と電子カルテが連携して自動記録できる体制をとる病院が増加している。

現在、医療機器はゲートウェイサーバを介して電子カルテサーバに自動記録する。ゲートウェイサーバは電子カルテサーバより入院（移動）情報・患者基本情報を取得し、職員がクライアント端末から患者と医療機器またはベッドを指定して名寄せを行う。またゲートウェイサーバから電子カルテへの送信間隔・パラメータの種類を患者ごとに設定することにより、重症度に合わせて細やかに記録できる。ゲートウェイサーバを介した電子カルテと医療機器の連携モデルを図8に示す[34].

一方で、医療機器は患者を計測した診療データ（バイタルサインなど）以外にも、機器内部のセンサ情報やエラー情報などのプリミティブなログデータを蓄積しており、それは患者に使用されていない場合にも随時蓄積している。しかし、医療機器を取り扱う部門システムとして唯一の医療機器管理システムは、機器台帳、保守管理、貸借所在などを目的として開発・運用された。このため、電子カルテと連携する機能は、使用患者登録を行いアライバイ管理ができる機能に留まっており、医療機器のログデータを保存できるデータベースとしては発展していない[35].

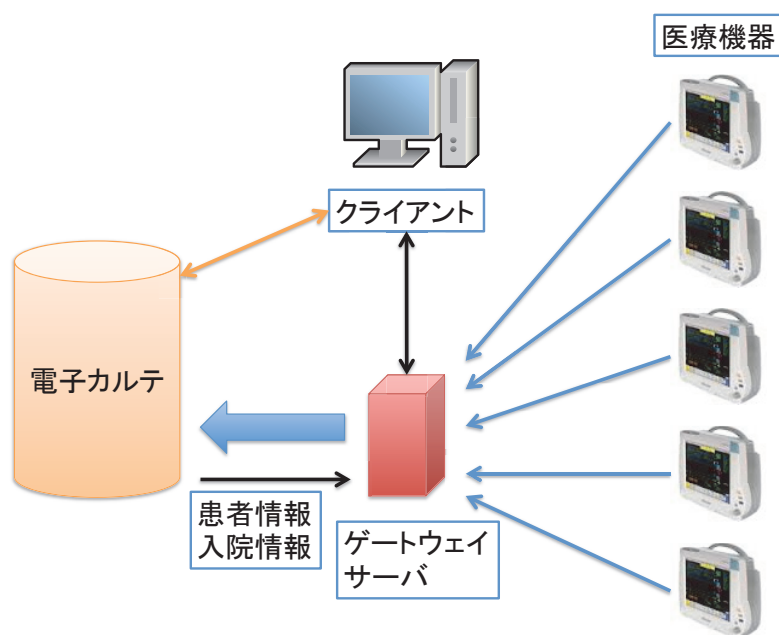


図8：医療機器と電子カルテの連携モデル

3.6 病院情報システムの現状と課題

オーダーリングシステム，電子カルテ，これらを統合する病院情報システムによってペーパーレス化が図られ，他の医療従事者に即時に共有でき，過去分を容易に検索できるようになった．また部門ごとに業務支援システムの導入が進んでおり，医療従事者は様々な場面でデータを入力することが一般化している．

日本の医療システムは，欧米のプライマリケアは診療所，セカンダリケアは病院といった明快な区分と比べて多様である．この現状を是正するために，診療所でかかりつけ医を持たせて医療の窓口とし，病院へは紹介で来院することが勧められている．さらに，日本の病院は病床機能によって分化し，医療機関の役割分担が政策として勧められている．これは患者がかかりつけ医を医療の窓口として，急性期病院から回復期リハビリテーション病院，療養期病院，そして在宅医療でかかりつけ医に還るといった医療体制モデルである．しかし，この多段に医療機関をまたぐ医療体制を敷くにあたって，医療機関の患者の情報共有は医療機関毎に要約された簡易な情報となって伝達される．したがって，すべての情報が共有されているわけではないため，医療機関ごとに診療情報が分散していることになる．この問題に対して，EHR（Electric Health Record）の導入に向けた試みがなされている[36]．EHRは個人のあらゆる診療情報を生涯にわたって電子媒体に記録し，その情報を各医療機関の間で共有・活用する仕組みである．電子カルテに含まれる診断に関する情報以外に検査情報（採血結果，検査画像等），患者の背景・基礎情報（既往歴，血圧，体重等），レセプト情報（診療行為，薬剤等）が含まれている．これによって患者の診療情報が横断的に収集されビッグデータと成り，匿名性を担保した上で医学の研究に利活用されることが期待できる．

データの利活用は一次利用と二次利用に分類されることが多い．医療情報の一次利用とは，患者の治療において取得される医療情報をその患者の治療に係わる医療従事者が利用して，その患者のために使うことを言う．これらの情報は病院経営における診療請求，及び医師が診断，医療従事者が業務を遂行する上で記録を参照するために利用されており，情報の蓄積は着実に進んでいる．しかしながら，2017年の経済協力開発機構（OECD）によると世界の電子医療記録の準備状況と日本を比較した場合，いずれにおいても最も低い評価となっている[37]．

一方，医療情報の二次利用とは直接にはその患者の治療には関わりがない利用のことを指す．これまで病院は蓄積した情報に溢れているが，二次利用できていないのが現状である．これは，患者に直接のメリットがなく利用するには，内容を明示したうえでの患者同意が前提となっていたため研究や開発が進まなかった．しかし，2022年4月の個人情報保護法改正と同年6月6日の倫理指針ガイダンスが改定されたことによって，「学術研究機関等」（大学病院など）に当てはまらない医療機関であっても，既存試料・情報を用いた医

学研究などで研究対象者からインフォームド・コンセントや適切な同意を受けるのが困難な場合は、オプトアウト（研究に関する所定事項を公表・通知し、研究対象者が拒否できる機会を保障すること）を実施すれば個人情報法を順守できることが確認された[38–40]。これらから、病院情報システムに蓄積したデータの二次利用によって、医療従事者の業務や患者に有用となるシステム開発が期待できる。よって、次章ではAIを始めとするIoTとビッグデータから知識の抽出に用いる深層学習について論じる。

第4章 Artificial Intelligence

2013年の第三次AIブーム以降、による様々なヒトに変わる自動化のための課題解決に注目が集まっている。医療分野においてはAIによる医師の診断支援システム（Clinical Decision Support System: CDSS）の実現に向けて盛んに研究が行われている。本章では、4.1節でAIの歴史について、4.2節で知能について、4.3節でAIの様々な分類について、4.4節でAIを有効活用するためのIoTとビッグデータ、4.5節で深層学習の基礎理論となるニューラルネットワークについて、4.6節で深層学習に用いられる応用技術について、4.7節でAIの医療への適用について述べる。

4.1 AIの歴史

現在、第三次AIブームの到来によって盛んに研究が行われている。本節では、4.1.1項でAI第一世代について、4.1.2項でAI第二世代について、4.1.3項でAI第三世代の歴史について述べる。

4.1.1 AI第一世代

19世紀末にサンティアゴ・ラモン・カハール（S. R. Cajal）によって脳神経系がニューロンと呼ばれる神経細胞が多数結合したネットワークであることが示され、そこで行われている情報処理に関しては、1940年代にウォーレン・スタージス・マカロック（W. S. McCulloch）とウォルター・ピッツ（W. Pitts）が、多入力・一出力のしきい素子として機能するニューロンのネットワークによって、任意の論理演算を計算できることが研究の嚆矢とされている。加えて、1949年頃にドナルド・ヘブ（D. Hebb）がシナプスと呼ばれるニューロンの結合部位の信号伝達効率を、それが結合している前後の神経細胞の発火に応じた一定のルールで増減させることで、条件反射のような学習が行えることを示した[41]。

AIの原点となるのは、1956年夏、米国ニューハンプシャー州ダートマス大学に10人の研究者が会合をもったダートマス会議である。その10人は、ジョン・マッカーシー（J. McCarthy）、マーヴィン・ミンスキー（M. Minsky）、クロード・シャノン（C. E. Shannon）、ナサニエル・ロチェスター（N. Rochester）、トレンチャード・モア（T. More）、アーサー・サミュエル（A. Samuel）、オリバー・セルフリッジ（O. Selfridge）、レイ・ソロモノフ（R. Solomonoff）、アレン・ニューウェル（A. Newell）、ハーバート・サイモン（H. Simon）であり、コンピュータ知的な能力を獲得させるにはどうすればよいか議論した。ここで初めて「AI（Artificial Intelligence）」すなわち人工知能という言葉が世に現れた。当時のコンピュータに関する基礎理論はオートマトン理論であったが、これとは独立に計算機科学の分野でAIという新しい分野が芽吹いた。

ミンスキーは1961年に論文「Steps Toward Artificial Intelligence」を発表し、AIで検討すべき課題として、探索、パターン認識、学習、問題解決、プランニングを挙げた。次にニューウェルとサイモンは人間の問題解決過程のモデルとしてGPS (General Problem Solver) を提案し、その後のプランニングの問題に発展していった。1970年頃までのAI研究の初期は、ゲーム・パズルのプログラミング、プランニング、定理証明などのテーマが挙げられる。この頃は「人間はある一般的な能力を持っており、これにより人間の知的な行動が引き起こされる」と考えられ、「コンピュータを知的にするには、状況に応じて動作する判断能力を与える必要がある」とし「この能力は問題によらない一般的なものである」という考えであった。この一般的な能力が「知能」とされていたが、チェスやパズルなどの比較的単純化された世界の中で解くトイ問題であり、実世界で適用できるかは不確定であった[42]。

脳の仕組みを再現することによって、脳のように動作する「ニューラルネットワーク」を人工的に作ろうとし、1957年にフランク・ローゼンブラット (F. Rosenblatt) のパーセプトロンというモデルが脚光を浴びた[43]。このパーセプトロン (単純パーセプトロン) のプログラムを使うと、コンピュータがデータを自動的に学習していく事が可能となるため期待が集まったが、「線形分離可能なデータにしか用いることができない」などの問題から研究は収束していった。当時は脳の仕組みを再現するには脳の知見が不十分であり、理論とアルゴリズムの研究が進められることとなった。

4.1.2 AI 第二世代

1965年にエドワード・ファイゲンバウム (Edward A. Feigenbaum) がDENDRALという、入力として構造が未知の化学物質の分子式と質量スペクトルを与え、出力として化学構造を推定するシステムの研究に着手した。この開発の目標は、専門家の高い知識を必要とする分野で、実際に役に立つ問題を解決することだった。結果としてDENDRALは大学院生と同程度の推定能力をもつことが確認され、「エキスパートシステム」の第1号とされている。

このエキスパートシステムは、様々な専門知識のデータベースを作り、専門家 (エキスパート) の頭脳をコンピュータに代替させようとする試みであり、このシステムを使うことによって誰でも専門家並みの仕事ができることが期待された。

一方で、エキスパートシステムはたとえ用途を限定したとしても、実用に耐える規模のプログラムを構築しようとする、規模が大きくなるにつれて探索数が爆発的に増大する、数万という知識を適切に維持管理する仕組み、入力した知識以上のことはできず、例外に対応させようと思えばいつまでも知識を書き終えることができない、等の問題に突き当たることとなった[44]。

ニューラルネットワークはというと、1970年代を通じてパーセプトロンが抱える問題を解決するモデルや、その数理的基礎理論が次々に発表された。連想記憶モデル、情報処理機構の自己組織による形成、神経情報地図の形成、神経場の興奮パターン力学、統計神経力学などが研究された。この地道な研究により、脳が行っていると考えられる「記憶」「学習」といった仕組みの解明を助け、ニューラルネットワークによって「記憶」と「学習」をコンピュータ上で再現する試みの基礎ができた。

これらのことからエキスパートシステムから次第に、学習の仕組みを実現したニューラルネットワークへ期待が移っていった。1969年にパーセプトロンの限界が指摘されたことにより停滞していたが、1986年にデイヴィッド・ラメルハート (David E. Rumelhart) らが、誤り訂正型学習の課題を3層のネットワークで誤差逆伝播法 (error back propagation) による学習手法を定式化しブレークスルーを与えた。さらにジョン・ホップフィールド (J. Hopfield) が NP 完全問題の近似解法にニューラルネットを利用して成功を収め、ジェフリー・ヒント (G. Hinton) らによるボルツマンマシンなど様々なニューラルネットワークを用いた並列分散処理の研究が「コネクショニズム」などの名前で盛んになった。

第二次 AI ブームの成果として、人間の顔を認識する「顔認証技術」、指紋から人物を特定する「指紋認証技術」、人間のように話す「音声合成技術」などが実現され、人間の労働を代替する「AI」が期待されるようになった。しかし、これらの技術は研究室の外で実運用の技術実証を行おうとすると、環境の変化からくる想定外の外乱に遭遇すると、途端に精度が悪くなるという頑健性が問題となり、簡単には社会に適用できなかった。一方でニューラルネットワークはというと、誤差逆伝播法による学習は以下の問題点があった。

- ① 局所最適解に収束し、大域的最適解への収束が保証されていない。
- ② 学習結果が結合の重みの初期値などに依存する。
- ③ 学習の途中で進みが遅くなることがある。
- ④ 中間層が増えると、伝播される誤差の情報が失われていくため、層の多いネットワークの学習が困難。

そうして1990年代半ばに、ウラジミール・ヴァプニック (V. Vapnik) らによって欠点の少ない機械学習手法であるサポートベクターマシンが提案されたことなどもあり、ニューラルネットの工学的応用は下火となり、併せてAIブームが去る事となった[41]。

4.1.3 AI 第三世代

2013年以降に第三次AIブームが到来した。そこで第二次AIブームの頑健性の問題に対する対処として、以下が挙げられる。

- ① 環境の変化を起こさないようにする
- ② 環境の変化に対してシステム自らが対処する
- ③ 環境の変化をすべて予測する

①の問題に対しては、工業などの環境の変化が極めて少ない場所で働く産業ロボットが例として挙げられる。②の問題に対してはロボット掃除機のように「ぶつかったら避ける」のように、環境との相互作用を通して適応的に振る舞う仕組みが実現した。③の問題に対しては、後述の機械学習技術を基にしたデータサイエンス手法で解決が図られている。

第二次ブーム以降もパターン認識分野における基盤技術は進歩し、なかでもインターネットにWebページができたことで大量のテキストを収集し分析することが可能となり、自然言語処理領域が飛躍的に進展した。近年、インターネットやSNSといった通信技術の発達により多くの情報を収集することが可能となったほか、位置情報や加速度などのセンサーデータを持つスマートフォンの爆発的な普及により、ヒト単位での行動履歴を始めとしたライフログ、写真や動画といったデータの取得が容易になった。こうした背景から膨大な構造化データ、非構造化データを収集できるようになった。加えて計算機の性能も向上していったことで、これまで理論上で語られていた知見も複雑な試行ができる環境が整い機械学習への期待が高まった。

コンピュータにおける学習とは、その根幹は「分ける」という問題解決に帰着する。つまり、YesかNo、TrueかFalse、猫か猫でないか、これらの判断はすべて「イエス・ノー問題」であり、機械学習は分け方を自動的に習得することである。そこで何を基に分けるかどうかは機械学習の精度に関わる肝であり、ヒトが変数を決めてモデル化することを行っていた。この変数のことを「特徴量」と呼び、何を選ぶかで予測、分類、回帰、分析の精度は大きく変化する。ヒトの場合、同じ作業を何度も繰り返す中で適切な特徴量を決めるコツを掴むことで、さまざまな特徴量を無意識のうちに導き出している。しかし従来の機械学習アルゴリズムでは自発的に何が特徴量なのかを構成することはできず、どの特徴量に注目して、特徴量を選択して、分けるかは人間が考えていた。

そうした中、2012年に画像物体認識コンテスト（ImageNet Large Scale Visual Recognition Challenge: ILSVRC）において深層学習（ディープラーニング）を用いた手法により、トロント大学のヒントングループ（チーム名 Super Vision）が圧倒的に勝利したことから始まった[45]。データをもとにコンピュータがみずから特徴量をつくりだす機械学習の方法であり、「表現学習」のひとつとされる深層学習によって画像認識の精度向

上が図られた。これを契機として、コンピュータが自動的に特徴量を探し出せることが可能となり、「人間の知能はコンピュータで再現できる」という仮説の証明に向けて現在も研究が進展している。

4.2 知能とは

コンピュータは人間の知能の中でも「論理的な演算」を可能にするが、厳密に記述されたアルゴリズムがなければ動作しないが、厳密に記述されていればどんな論理演算でも実行できる。次に人間の脳の神経細胞を模したとされる「ニューラルネットワーク」は、あくまで人間が与えたデータを「分類」することを目的にしており、人間のように精神を宿した「知能」とは言えない[46]。AI が目指す人間の知能と、盛んに研究開発されている自動翻訳の思考実験を例に知能について述べる。

「チューリングテスト」と呼ぶ試験では、テストを行う判定者が 2 台の画面を前にして、それぞれの画面と会話する。1 台の画面には人間の受け答えの結果を表示し、もう 1 台の画面には人間らしい反応を返すプログラムの結果を表示させる。判定者はどんな質問をしても良いこととし、判定者が人間とコンピュータを確実に区別できなかった場合に、このコンピュータはテストに合格したとする。しかしテストに合格しても「知能を持つ」とは直接的には言えない。これは「中国語の部屋」という思考実験によって反論されている[47]。

ある部屋に、アルファベットしか理解できないイギリス人を配置する。この部屋には紙切れ 1 枚しか受け渡しができない穴があり、隣の部屋と繋がっているとする。そこに、イギリス人が居る隣の部屋から、中国語で書かれた質問文が送られてくるとする。次にイギリス人はこの質問文の記述はまったく理解できないが、イギリス人の居る部屋にはある質問文がきた場合にどのように記述して回答するかをすべて記したマニュアルが置いてあるとする。このマニュアルを見ながらであれば回答を記述することができるため、意味不明な中国語の質問がきても回答を記述して返すことができる[48]。この行為においてイギリス人は質問文を読解して意味を理解し回答しているわけではない。イギリス人はマニュアルどおりに意味も分からず回答しており、何も知的行為を行っているわけではなく、作業を実施しているだけである（図 9）。

以上のチューリングテストと中国語の部屋から、ニューラルネットワークにおける「分類」は、ときに人間ができないような複雑な「分類」をしてくれるものの、そこには「知能」を宿しているわけではなく、複雑な論理演算によって構築された分類器・識別器で翻訳しているに過ぎない。

このため「知能」の視点から AI には 2 つの定義があり、「弱い AI」と「強い AI」と呼

ばれる。この2つの違いは、「人間のように自分の意志で何かを判断する」というような精神を宿す有無で分けられる。弱いAIは「人間の知能の代わりに一部を行う機械」であり、現在の深層学習をはじめとする機械学習はアルゴリズムから学習を行っているため世間的にAIまたは人工知能と呼ばれるが、精神を宿しているわけではない。このため、現在開発が進んでいるAIはすべて「弱いAI」であり、精神を宿す「強いAI」ははまだ開発されていない。




図 9: 中国語の部屋

4.3 AI の分類

知能の視点から定義される強いAIと弱いAIの他に、AIは特化型と汎用型に分類される。

特化型は特定の専門分野でのみ能力を発揮できるAIであり、囲碁などのボードゲームの対戦ができるAIや、法律や医療、故障診断などの専門分野における自動判定に特化したものがある。これらは限定した系において人間の能力を超える判断能力を発揮しており、例えば囲碁においてプロの棋士でも敵わない強さを誇るようになっている。

一方で汎用型は、人間のように幅広い対象に対して推論や判断が行えるものであり、設計時の想定を超えた未知の多様な問題を解決できる汎用性のあるAIのことである。映画や書籍に出てくる空想の人型アンドロイドなどは、汎用的なAIを搭載したロボットだと言える。深層学習の発展により膨大なデータから知識や特徴を自動的に獲得することが可能になったが、これまで実現されているAIはタスクのドメインごとに人が設計しており、自律的に様々なタスクを解決できるまでは至っていない。

しかしながら、汎用型AIの実現に向けて多様なモダリティのデータから得られる知識を

再利用性が高い部品として整理するためのグラフ表現やオントロジーとの対応に関する研究や、様々な膨大なデータから得られた知識の転用を行う転移学習といった研究がすすんでいる。また人が設計するアーキテクチャを自動生成するアーキテクチャ探索の研究も試みられている[41].

4.4 IoT とビッグデータ

IoT (Internet of Things) はモノのインターネットとも呼ばれ、世の中のあらゆる事象をデータとして取得できるようになりつつあり、これら大量のデータのことをビッグデータと称される。このビッグデータから新たな価値や知識を導き出すためには、人の手に余るため AI で自動的に特徴を抽出する必要がある、また AI には大量の学習データが必要となるため、ビッグデータと AI は相互に関連し合っている。

4.4.1 IoT デバイスの普及

1993 年にインターネットの商用利用が開始されて以降、個人用パソコンの普及も相まって急速に広がった。2001 年から「いつでも、どこでも、何でも、誰でも」ネットワークに繋がるユビキタスネットワーク社会の構想が総務省より提案され、その後は様々な「モノ」がセンサーと無線通信を介してインターネットの一部を構成する IoT というキーワードで表現されるようになった。

IoT とデータ転送技術であるセンサネットワークについて以下に述べる。

(1) IoT

“モノ” のインターネット (Internet of Things: IoT) とは従来は主にパソコンやサーバ、プリンタ等の IT 関連機器が接続されていたインターネットにそれ以外の様々な“モノ”を接続する技術の総称である。

テレビやデジタルカメラ、デジタルビデオカメラ等のデジタル情報家電をインターネットに接続する流れは既に始まっている。さらに、デジタル化された映像、音楽、音声、写真、文字情報を、インターネットを介して伝達される機会がますます増えており、あらゆる“モノ”がコミュニケーションをするための情報伝送路に変化しつつある。IoT の概念図を図 10 に示す。様々なモノ、機械、人間の行動や自然現象は膨大な情報を生成しており、大きく以下の 3 つに分類できる[49].

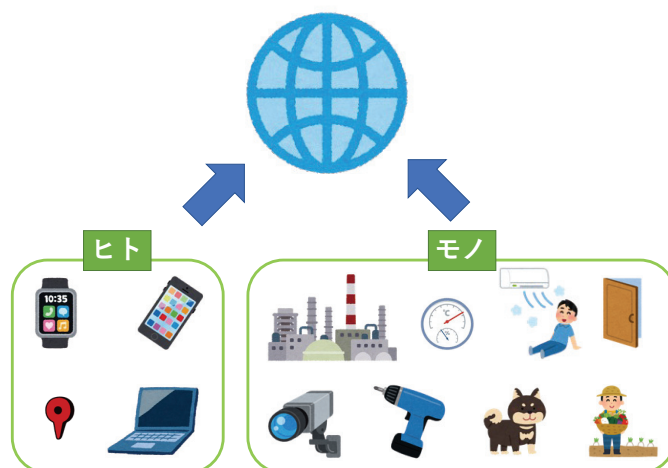


図 10 : IoT の適応分類

- ヒト
パソコン，スマートフォン，タブレット，ウェアラブルデバイスなど
- 機械
監視カメラ，体重計，自動洗濯機，工場作業機械など
- その他のモノ
ドアの開閉，ドアの施錠，ペットの行動，観葉植物の土壌の水分量など

これらの情報を収集して可視化することができれば様々な問題が解決できる。見ることや聞くこと触ることができている情報はもちろんだが、それらができない情報もセンサにより数値化され収集可能となる。

IoT におけるセンサの実用例を以下に挙げる。

- 環境モニタ … 温度，湿度，気圧，照度，騒音，その他
- モーションモニタ … 衝撃，振動，傾斜，転倒，落下，移動，その他
- ロケーションモニタ … 存在検知，近接検知，通過検知
- ドアの開閉・施錠状態など

(2) センサネットワーク

センサネットワークとは、センサノードを相互に接続することにより多地点のセンシング情報を収集し、利活用するためのシステム、あるいはその通信路としてのネットワークである。センサノードは、センサ・マイクロプロセッサ・通信デバイス・電源で構成され

ており、各々のセンサノードが自律的にネットワークを構成し、基地局を必要とせずセンシングしたデータを伝える。さらに、ネットワークの拡張性をもたせるため、要所に通信及び計算処理能力の高いノードを置くことで、階層的なネットワーク構造として構築することも可能である[50].

センサネットワークを構成するセンサノードは一般に以下の3種類がある。

- コーディネータ
ルータの機能に加え、ネットワーク全体を管理する機能を持つノード
- ルータ
センサの機能に加え、データの中継する機能を持つノード
- エンドデバイス
センサの機能のみを持ち、自らが観測したデータを送信するノード

そして、センサネットワークには、センサノードの繋がり方である接続トポロジとして主に以下の3つがある。

- スター型トポロジ
コーディネータを中心に、コーディネータと各ノードが1対1で通信を行う。
- メッシュ型トポロジ
近接するノードとは直接通信を行い、自分の通信範囲外にあるノードとは近接するノードを経由するマルチホップ通信を用いて通信を行う。
- クラスタツリー型トポロジ
スター型トポロジにさらに階層的な要素を加えた接続トポロジ。

IoT デバイス数は年々増加しており、2023年には2016年の約2倍になると予測されている(図11)。加えて通信機能を備えたIoT デバイス数は医療分野においても年々増加しており、他分野に比べてデバイス総数は少ないものの、成長率予測は医療分野が最も高い(図12)。




図 11: 世界の IoT デバイス数の推移及び予測[51]




図 12: 分野・産業別の世界の IoT デバイス数及び成長率予測[51]

4.4.2 ビッグデータ

インターネットやセンサネットワークの普及により、ネットワークに接続できる端末が多様化し、社会に急激に浸透し、こうした端末から様々なデータを高頻度で収集することが容易となってきている。ビッグデータでは、こうした大量のデータから新たな価値を導き出すことが求められる。

ビッグデータは人間では全体を把握することが困難な巨大なデータ群のことを指し、その特性を表す 3 つのキーワードから「3 つの V」と呼ばれる[52]。以下にビッグデータの特性について挙げる。

(1) Volume

Volume は、膨大なデータ量を表す。Google や Twitter などのインターネットサービスや、センサネットワークの普及により、処理対象となるデータ量が急激に増え続けている。そのデータ量は、テラバイトからペタバイト、そしてエクサバイトのオーダーになる。

(2) Velocity

Velocity は、データの発生頻度が非常に高くなることを表す。インターネットサービスのアクセスログのほか、センサ上からも高頻度でデータが生成され蓄積されており、これらのデータをリアルタイムに処理し、対応することが求められる。

(3) Variety

Variety は、データの多様化を表す。テキストや音声、写真などの画像や、動画など様々な構造化されていない複雑なデータがある。また、変化の激しいインターネットサービスでは、機能の追加・削除などにより、データ構造が変化していく。

また、ビッグデータは活用範囲が幅広いため、あらゆる分野または業界での利活用が期待されている。この具体的に構成するデータの種類と内容を図 13 に示す[53]。



図 13：ビッグデータを構成する各種データ [53]

4.5 ニューラルネットワーク

人間の脳はニューロンと呼ばれる神経細胞によって構成され、大脳皮質では約 140 億ものニューロンが巨大なネットワークを形成している。このニューロンの中で情報を伝達することにより、人間は物事を認識し、情報処理を行っている。

ニューロン間では、電気信号により情報伝達が行われ、ニューロンが他のニューロンから入力を受け取ると、自身の中で電気を加算し、ある閾値を超えると（発火）次のニューロンに電気信号を伝達しネットワークを駆け巡る。各ニューロン間での結合の強さは異なっているため、どのニューロンがどれくらいの電気信号を受け取るかによって、ネットワーク全体での電気信号の伝わり方が変わる。この違いによって人間は異なるパターンを認識している。これを模したアルゴリズムがニューラルネットワークである。

本節では、4.5.1 項で脳の神経をモデルとした単純パーセプトロンについて、4.5.2 項で深層学習の基礎となった多層パーセプトロンを例に深層学習の基礎理論について述べる。

4.5.1 単純パーセプトロン

あるニューロンが、2つのニューロンから電気信号を受け取った場合を想定する。注意点として以下が挙げられる[54].

- 2つのニューロンのどちらかがどれくらいの電気信号を受け取るか
- 閾値はどれくらいにすべきか
- 閾値を超えたときにどれくらいの電気信号を送るか

以上を踏まえ、入力信号の変数を x_1, x_2 とする。また各ニューロン間で結合の強さは異なるため、実際に伝わる電気信号が異なるため、この結合の強さを重み w_1, w_2 としてモデル化すると、以下が電気信号の総量は「 $w_1x_1 + w_2x_2$ 」と表せる (図 14).




図 14: ニューロン 2 個のモデル

また、電気信号を受け取ったニューロンが発火して、次のニューロンに受け渡すかどうかは閾値 θ で発火条件を決めることができるため、以下の式で表せる。

$$y = \begin{cases} 1 & (w_1x_1 + w_2x_2 \geq \theta) \\ 0 & (w_1x_1 + w_2x_2 < \theta) \end{cases}$$

以上を入力 n 個に拡張して一般化すると、以下の式で表すことができる。

$$y = \begin{cases} 1 & (w_1x_1 + w_2x_2 + \dots + w_nx_n \geq \theta) \\ 0 & (w_1x_1 + w_2x_2 + \dots + w_nx_n < \theta) \end{cases}$$

ここで、関数 $f(x)$ と考えると以下になり 0 か 1 の 2 値に変換され、これをステップ関数と呼ぶ。

$$f(x) = \begin{cases} 1 & (x \geq \theta) \\ 0 & (x < \theta) \end{cases}$$

ネットワーク出力 y は、

$$y = f(w_1x_1 + w_2x_2 + \dots + w_nx_n - \theta)$$

と書き直すことができる。次いで、ベクトルの内積を用いて表し $b = -\theta$ とすると以下の式で表すことができる。 w^T はベクトル w の転置を意味している。

$$x = \begin{pmatrix} x_1 \\ \vdots \\ x_n \end{pmatrix}, w = \begin{pmatrix} w_1 \\ \vdots \\ w_n \end{pmatrix}$$

$$y = f(w^T x + b)$$

ニューロンの出力を式で表されるニューラルネットワークのモデルをパーセプトロン (perceptron) またはノード (node) とよび、最も簡単な形をしたこのモデルを単純パーセプトロン (simple perceptron) と呼ぶ。またここで定義した w を重みベクトル、 b をバイアスと言う。加えて、このニューロンの出力における関数 $f(x)$ は、単純パーセプトロンでは出力値が 0 か 1 のステップ関数であり、このようなニューロンの線形結合後の非線形変換を行う関数のことを活性化関数 (activation function) と呼ぶ。

実際にパラメータを求める場合、適当な値で試し、これにより得られる出力 (予測値) と正解データとの誤差から、試す値を修正する事を繰り返す。この方法を「誤り訂正学習法」という。

正解の出力を t とすると重みとバイアスの差分と更新式は以下となる。

$$\Delta w = (y - t)x$$

$$\Delta b = (y - t)$$

$$w^{(k+1)} = w^k - \Delta w$$

$$b^{(k+1)} = b^k - \Delta b$$

この更新式を用いて、 $\Delta w = 0$ かつ $\Delta b = 0$ となるまで演算を繰り返す。ただし、正しく分類できない学習の場合は誤差が 0 とならないため、一定回数以上の更新を計算した時点で演算を終了する必要がある。

4.5.2 多層パーセプトロン

パーセプトロンを多段に結合したネットワークを多層パーセプトロン (multi-layer perceptron: MLP) と呼び、入力を受け取る層を入力層 (input layer)、出力する層を出力層 (output layer)、多段にすることで追加された入力層と出力層の間を中間層 (intermediate layer) または隠れ層 (hidden layer) と呼ばれる。すべてのノードは互いに結合する構造をしており、全結合型ニューラルネットワーク (fully-connected) とも呼ばれ、もっとも単純な深層学習である (図 15)。




図 15: 3層のニューラルネットワーク

この 3 層の MLP では、入力層～中間層における出力の式は重み W 、バイアス b 、活性化関数 f とすると、

$$h = f(Wx + b)$$

となり、ここで得られた h が出力層に伝播するため、中間層～出力層では、重み V 、バイアス c 、活性化関数 g とすると、

$$y = g(Vh + c)$$

となる。

ニューラルネットワークでは、1 つ前の層から線形変換を適用した結果を受け取り、そこへさらに非線形変換を適用（活性化関数 f と g ）した値を出力する。非線形変換を行うのは、入出力間が線形な関係であればよく近似することができるが、入出力間が非線形な関係の場合にうまく近似することができないからである。このためニューラルネットワークの各層で、線形変換後に活性化関数で非線形変換を行い、ネットワーク全体としても非線形性を持つようにしている。

単純パーセプトロンでは、重みベクトルとバイアスベクトルで線形変換後にステップ関数で非線形変換を行い、ニューロンの発火を 0 か 1 の 2 値で表現していた。このため、線形変換した値が 0 か 1 を判定する微妙な場合、どちらかに割り振られる事によって微妙だった情報が失われることになる。この問題を解決するために、出力値を 0～1 の確率として出力できればよく、活性化関数にシグモイド関数などの微分可能な関数が用いられる。この微分可能な関数を用いる必要があることについては、後述のバックプロパゲーションに関係する。

(1) 誤差の算出

学習のために誤差を算出する必要がある。上記のように出力を確率的に扱うため、ニューロンが発火する場合を $C = 1$ 、しない場合を $C = 0$ の確率変数とし、ニューロンが発火する確率は

$$p(C = 1|x) = \sigma(w^T x + b)$$

と表せ、確率の和が1となるので、ニューロンが発火しない確率は

$$p(C = 0|x) = 1 - p(C = 1|x)$$

となる。 C は0か1しか取り得ないので、 $y := \sigma(w^T x + b)$ とすると、

$$p(C = t|x) = y^t(1 - y)^{1-t}$$

とまとめることができる（ただし、 $t \in \{0, 1\}$ ）。これにより、 N 個の入力データ x_n およびそれぞれに対応する正解の出力データ t_n が与えられたとき、ネットワークのパラメータである重み w およびバイアス b を最尤推定するための尤度関数は下式のように表せる。

$$\begin{aligned} L(w, b) &= \prod_{n=1}^N p(C = t_n|x_n) \\ &= \prod_{n=1}^N y_n^{t_n}(1 - y_n)^{1-t_n} \end{aligned}$$

この尤度関数を最大化するようにパラメータを調整することで学習ができているということになる。このような関数が最大・最小となる状態を求める問題のことを「最適化問題」と呼ぶ。

関数の最大・最小を求める場合は微分で導出できるため、各パラメータの偏微分（勾配）をすることになる。そこで計算を簡単にするために尤度関数の対数をとって全体の和を表し、符号を入れ替えると、以下の一般的な最適化問題の形となる。

$$\begin{aligned} E(w, b) &:= -\log L(w, b) \\ &= -\sum_{n=1}^N \{t_n \log y_n + (1 - t_n) \log(1 - y_n)\} \end{aligned}$$

この式を「交差エントロピー誤差関数（cross-entropy error function）」と呼び、この関数を最小化することが最適化することになる。この関数 E のことを、「誤差関数」または「損失関数」と呼ぶ。

(2) バックプロパゲーションと勾配降下法

複数の層からなるニューラルネットワークに入力と出力があり、各パラメータが目的に対して調整されることでネットワーク自体が学習する。入力から出力の方向に計算が進むことを順伝播といい、出力値と正解データから誤差を算出する。次は出力から入力の方へデータを遡るように逆伝播して、ネットワークの各層のパラメータを調整するが、このアルゴリズムを誤差逆伝播法（バックプロパゲーション: **back propagation**）という（図 16）。この順伝播と逆伝播を繰り返して各パラメータを調整することで、ネットワークは次第に適切な出力が得られるようになる[55]。

バックプロパゲーションに必要な理論として、連結した複数の関数（合成関数）の微分は、それを構成する各関数の微分の積に分解できるという連鎖律（chain rule）がある。

3 層のニューラルネットワークとして、入力 x から関数 $p = P(x)$ 、関数 $q = Q(a)$ 、関数 $y = R(q)$ の 3 つの関数によって順伝播で出力 $y = F(x)$ が構成される場合、以下の計算グラフで表される（図 17）。

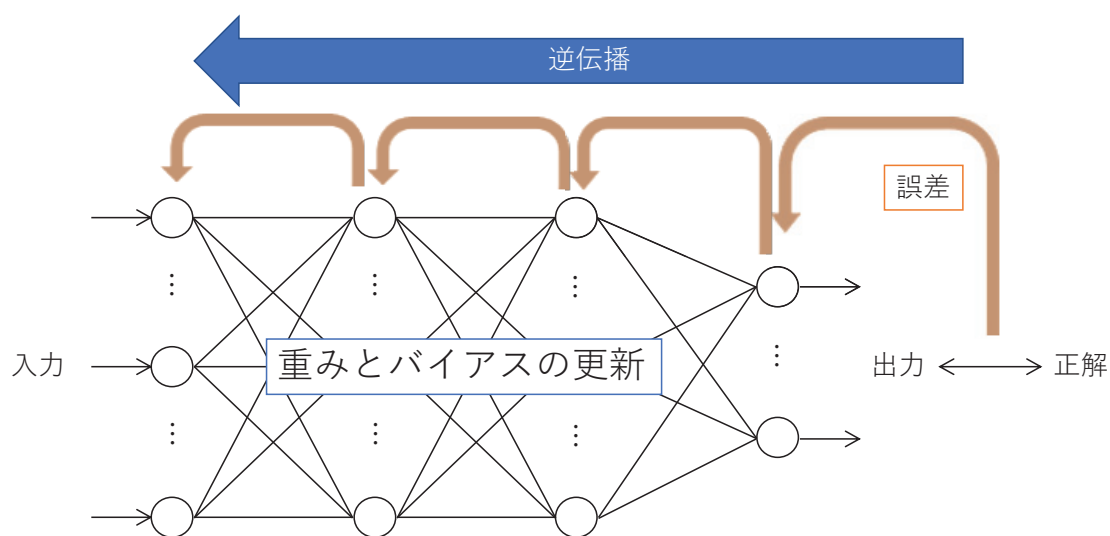


図 16: バックプロパゲーションの概要




図 17: 合成関数の例

x に関する y の微分は,

$$\frac{dy}{dx} = \frac{dy}{dy} \frac{dy}{dq} \frac{dq}{dp} \frac{dp}{dx}$$

と分解でき、 $\frac{dy}{dy} = 1$ となる.

これをバックプロパゲーションに適用して、出力方向から入力方向へ順に計算するように表すと以下になる (図 18).

順伝播と逆伝播の間には、明確な対応関係があり、順伝播時の変数 p は、逆伝播時の微分 dy/dp に対応する (図 19). 同様に q と dy/dq が対応し、 x と dy/dx が対応する. また、関数にも対応関係があることが分かる. 例えば関数 Q の逆伝播は $Q'(p)$ に対応し、 P は $P'(x)$ に対応する. また逆伝播の計算をする場合には、 $R'(q)$ を計算するにあたって、変数 q が必要となるため、逆伝播の計算に先んじてまずは順伝播を計算し、次いで逆伝播の計算をすることになる[56]. この方法を応用して、誤差関数 E から各層の重み w とバイアス b の修正を行う.

$$\frac{dy}{dx} = \left(\left(\frac{dy}{dy} \frac{dy}{dq} \right) \frac{dq}{dp} \right) \frac{dp}{dx}$$

$$\frac{dy}{dy} \frac{dy}{dq} = \frac{dy}{dq}$$

$$\frac{dy}{dq} \frac{dq}{dp} = \frac{dy}{dp}$$

$$\frac{dy}{dp} \frac{dp}{dx} = \frac{dy}{dx}$$

図 18: 連鎖律による出力側から偏微分する流れ




図 19: 順伝播と逆伝播




図 20: 勾配降下法の概念図

バックプロパゲーションでは、「勾配降下法」によりパラメータの修正量が決定される (図 20)。横軸 w が重み, 縦軸 E が誤差であり, 誤差 E を重み w で偏微分したものが誤差の勾配として算出できる。このような誤差の曲線・形状を知ることはできないため, 勾配に応じて少しずつパラメータを変化させ, 誤差が小さくなるように反復学習を繰り返す。したがって, ニューラルネットワークのすべての重みとバイアスを更新するためには, まずは誤差に基づいた勾配を求める必要がある。

ここで誤差から重みの勾配は, 変数 u に対する誤差 E の重み w による偏微分を考え, 連鎖律を適用すると次の式に分解できる。

$$\frac{\partial E}{\partial w_i} = \frac{\partial E}{\partial u} \frac{\partial u}{\partial w_i}$$

まず, 右辺の $\partial E/\partial u$ を δ に置き換え, これも連鎖律で分解すると以下で表せる。

$$\begin{aligned} \delta &= \frac{\partial E}{\partial u} \\ &= \frac{\partial E}{\partial y} \frac{\partial y}{\partial u} \end{aligned}$$

$\partial E/\partial y$ は, 出力層の場合には誤差関数の y による偏微分になり, 中間層では下層からの逆伝播で算出することができる。また $\partial y/\partial u$ は活性化関数を偏微分して得ることができる。

次に $\partial u / \partial w_i$ は、活性化関数 u の重み w による偏微分であることから以下で表せる。

$$\begin{aligned}\frac{\partial u}{\partial w_i} &= \frac{\partial(\sum_{k=1}^m x_k w_k + b)}{\partial w_i} \\ &= \frac{\partial}{\partial w_i}(x_1 w_1 + x_2 w_2 + \cdots + x_i w_i + \cdots + x_m w_m + b) \\ &= x_i\end{aligned}$$

以上から、 $\partial E / \partial w_i$ を δ と x_i で置き換えると、重み w の勾配は以下となる。

$$\begin{aligned}\delta &= \frac{\partial E}{\partial u} \\ &= \frac{\partial E}{\partial y} \frac{\partial y}{\partial u} \\ \frac{\partial E}{\partial w_i} &= x_i \delta\end{aligned}$$

バイアスの勾配は、 u を b で偏微分すると 1 になるため、上記と同様に以下として導ける。

$$\frac{\partial E}{\partial b} = \delta$$

ここまでで、出力層から中間層までの勾配を求めることができた。

最後に入力 x_i の勾配を求める。入力の勾配はニューロン数を n 個、 k を層内の各ニューロンとすると以下で表せる。

$$\begin{aligned}\frac{\partial E}{\partial x_i} &= \sum_{k=1}^n \frac{\partial E}{\partial u_k} \frac{\partial u_k}{\partial x_i} \\ &= \sum_{k=1}^n w_{ik} \delta_k\end{aligned}$$

これらの式から誤差関数 E における重み w とバイアス b の勾配が得られたことによって、各パラメータの修正量を与える更新式を定義することができる。

交差エントロピー誤差関数 E におけるパラメータは w, b であるため、勾配降下法で与えられる式は次となる。

$$\begin{aligned}w^{(k+1)} &= w^{(k)} - \eta \frac{\partial E(w, b)}{\partial w} \\ b^{(k+1)} &= b^{(k)} - \eta \frac{\partial E(w, b)}{\partial b}\end{aligned}$$

$\eta (> 0)$ は学習率 (learning rate) とよばれる定数で、学習の速度を決定する。元のパラ

メータから学習率 η と勾配を乗じた値の差を、新たなパラメータとして更新することになる。こうして、あるパラメータ値で予測誤差が発生したならば、その誤差をフィードバックしてパラメータ値を更新すれば、より最適なパラメータ値に近づいていくことができる。

活性化関数にシグモイド関数を用いた場合の各パラメータの勾配を求めると次のように導出できる。

$$\begin{aligned}\frac{\partial E(w, b)}{\partial w} &= \sum_{n=1}^N \frac{\partial E_n}{\partial y_n} \frac{\partial y_n}{\partial w} \\ &= - \sum_{n=1}^N \left(\frac{t_n}{y_n} - \frac{1-t_n}{1-y_n} \right) \frac{\partial y_n}{\partial w}\end{aligned}$$

ここでシグモイド関数の微分 $\sigma'(x) = \sigma(x)(1 - \sigma(x))$ を用いると、

$$\begin{aligned}&= - \sum_{n=1}^N \left(\frac{t_n}{y_n} - \frac{1-t_n}{1-y_n} \right) y_n(1-y_n) x_n \\ &= - \sum_{n=1}^N \{t_n(1-y_n) - y_n(1-t_n)\} x_n \\ &= - \sum_{n=1}^N (t_n - y_n) x_n\end{aligned}$$

バイアス b も同様に導出できる。

$$\frac{\partial E(w, b)}{\partial b} = - \sum_{n=1}^N (t_n - y_n)$$

よって、

$$\begin{aligned}w^{(k+1)} &= w^{(k)} - \eta \sum_{n=1}^N (y_n - t_n) x_n \\ b^{(k+1)} &= b^{(k)} - \eta \sum_{n=1}^N (y_n - t_n)\end{aligned}$$

これらの式は、誤り訂正学習法と同様に、予測値と正解データとの誤差 $(y_n - t_n)$ を用いてパラメータを更新することになる。

(3) 確率的勾配降下法

勾配降下法を用いることで理論的に学習できることは証明されたが、実際問題として重み w とバイアス b を更新するのに、 N 個すべてのデータに対する和を求める必要がある。これは N が巨大になったときに、一度にデータをオンメモリに載せきれなくなる問題が生じる。この問題を解決するための手法として「確率的勾配降下法 (Stochastic Gradient Descent: SGD)」がとられる。勾配降下法では全データ数の和を求めてからパラメータを更新するのにに対し、確率的勾配降下法ではデータを 1 つずつランダムに選んでパラメータを更新する。

$$w^{(k+1)} = w^{(k)} - \eta(y_n - t_n)x_n$$
$$b^{(k+1)} = b^{(k)} - \eta(y_n - t_n)$$

こうすることで、勾配降下法でパラメータを 1 回更新するのと同じ計算量でパラメータを N 回更新できるので効率よく最適な解を探索することができる。ただし N 回で学習が終わることは稀であるため、 N 個のデータ全体に対して反復学習する必要があり、この反復回数をエポック (epoch) と言う。このエポックごとにデータをまたはシャッフルして反復学習することで、学習に偏りが生じにくくなり、より最適な解が得やすくなる。

しかし実際の曲線は複雑で、もっとも E が小さい区間である大域的最適解と、そうではない局所最適解がしばしば存在する (図 21)。このため小さい学習率では更新が小さいため局所最適解に陥りやすく、大きい学習率ではなかなか学習が収束しなくなる。このため、最初は学習率を大きくとって大域的最適解であろう曲線に達してから、次に学習率を小さくして学習が収束しやすくなるように、学習率を可変させること (Warmup) が行われる。




図 21: 局所最適解と大域的最適解

(4) ミニバッチ勾配降下法

通常の勾配降下法を「バッチ勾配降下法」とよび、確率的勾配降下法とバッチ勾配降下法の間的手法として「ミニバッチ勾配降下法」がある。これは N 個のデータを分割して学習する手法で、コンピュータ上では並列計算ができるようになり、効率よく処理がおこなえる (図 22)。

ミニバッチ勾配降下法は、分割した学習 (訓練) データと正解データのペアの塊 (バッチ) を作成し、このバッチのデータ量をバッチサイズと呼ぶ。バッチ内で学習データを使用して重み w とバイアス b の更新が行われ、 N 個の訓練データを小さなミニバッチに分割し、バッチごとに学習する。つまり、訓練データが 1000 個でバッチサイズを 50 個と設定した場合、20 個のバッチに分割され、1 エポックあたり 20 回の更新が行われることになる。

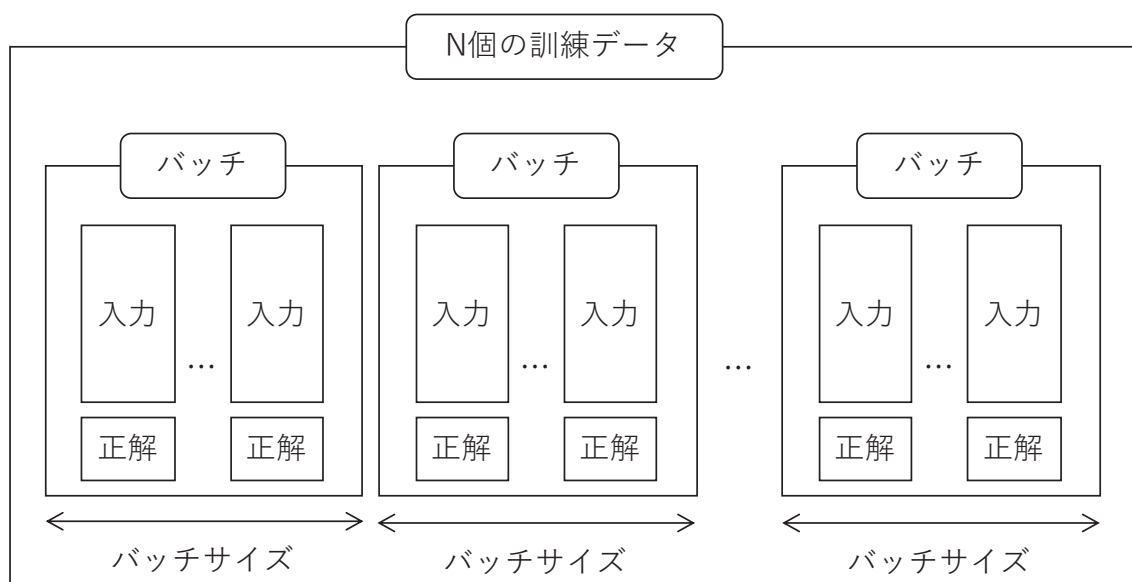


図 22: 訓練データとバッチ

4.6 深層学習

多層パーセプトロンによって入力層と出力層の間に中間層を加えることで、非線形分類ができるようになった。各ニューロンが発火するかどうかのパターンの組み合わせによって分類するので、ニューロンの総数を増やすことで、より複雑なパターンを分類できるようになるはずである。ニューロンを増やす方針として、①層内のニューロンを増やす、②層を増やす、というアプローチが考えられる。特に②のアプローチで深い層を持つネットワークをディープニューラルネットワーク (Deep Neural Network: DNN) といい、この学習手法をディープラーニング (deep learning) または深層学習と呼ぶ。

4.6.1 多層化における問題

中間層を増やす、つまり深くする事によって表現・分類できるパターンは多くなり予測精度があがるはずである。しかし、実際には単純に中間層を増やすだけでは予測精度が上がらず、学習がうまく進まないことがある。

(1) 勾配消失問題

勾配消失問題 (vanishing gradient) とは、バックプロパゲーションの演算で勾配が消えてしまう問題のことをいう。バックプロパゲーション時の連鎖律による偏微分で、層を経る度に勾配が小さくなるためである。活性化関数を偏微分することを繰り返すが、例えばシグモイド関数を微分すると $0 \sim 0.25$ の値になり、層を深くするほど入力層までに小さな値になってしまう。この問題を回避するためには「微分しても値が小さくならない活性化関数」を用いる対策が考えられる。このため従来の中間層にはシグモイド関数が使われていたが、現在は正規化線形関数 (ReLU: rectified linear unit) が多用されている[57]。ReLU は入力値が負であれば 0 を出力し、正であれば入力値をそのまま出力する関数である。このため、シグモイドは入力が大きくなるほど曲線の傾き (勾配) が小さくなるが、ReLU は一定という特徴がある (図 23)。




図 23: シグモイドと ReLU の微分

(2) オーバーフィッティング問題

勾配消失問題に加え、訓練データに過剰に適合しすぎるオーバーフィッティング (overfitting) あるいは「過学習」または「過剰適合」と呼び、与えた訓練データに過剰に近似してしまうことである。訓練データには限りがあるため、ニューロンの数が増えることで複雑なパターンを表現できる一方で、学習はうまく進んだように見えても、訓練データのみを複雑に表現してしまい、未知のデータを与えたときに精度が得られなくなり、実運用した場合に汎化性能が得られず頑健性 (ロバスト: robust) でなくなる。単純に誤差 E を最小化するようにパラメータを更新すると過学習する可能性が高くなる。この対策として、訓練データを多くする、または過学習に陥る前に学習を打ち切る方法がとられる。

訓練データを多くする方法としては、収集するサンプルを増やすか、データを生成して水増しする。この水増しの事をデータオーグメンテーション (data augmentation) と呼ぶ。画像分野ではサンプルデータを幾何学的な操作、色空間の操作、マスク処理などをする[58]。音響分野ではスペクトログラムとして時間・周波数空間の画像として扱うため時間方向のシフト、ノイズの重畳、時間方向・周波数方向のマスク処理などがある。自然言語では、同義語の置換、別の言語に翻訳してから元に戻す、ランダムな同義語の挿入・移動・削除がある[59]。

過学習に陥る前に早期に学習を打ち切るとことをアーリーストッピング (early stopping) という。そこで学習中の過学習の判定方法であるが、一般的に訓練データとは別に学習に用いない検証データを用意し、エポックごとに訓練データと識別器・分類器にとって未知のデータである検証データを推定しての正解率 (accuracy) と損失 (loss) を算出する。この得られた訓練データと検証データの正解率もしくは損失の乖離が認められれば過学習が起こっていると判断する。アーリーストッピングでは検証データの正解率もしくは損失の最小値から任意のエポック数を経た後に、最小値の更新がなければ学習を打ち切る。次に検証データの正解率もしくは損失が最小値の時の学習モデルを採用する。

4.6.2 畳み込みニューラルネットワーク

畳み込みニューラルネットワーク (Convolutional Neural Network: CNN) とは画像データを入力として高い認識性能を獲得しているモデルで、ヒトが持つ視覚野の神経細胞の働きを模倣している。

視覚野の単純型細胞 (S細胞) は画像の濃淡パターン (特徴) を検出し、複雑型細胞 (C細胞) は空間的な位置のずれを吸収し同一の特徴とみなしている。この S 細胞の働きを畳み込み層、C細胞をプーリング層で模倣する。

(1) 畳み込み層 (convolutional layer)

畳み込み層は、フィルタを用いて画像の特徴を抽出する。フィルタを画像の左上から順番に重ねて、画像とフィルタの値を乗じた総和を算出し、特徴マップという新たな二次元データを生成する。これはヒトの視覚野が持つ局所受容野に対応し、ヒトは認識対象がずれても認識できるが、コンピュータは別の画像と判断してしまうことを、フィルターを重ねて畳み込むことで解決しようとするものである。

このフィルタをカーネル (kernel) または **sliding window** と呼び、畳み込み層のニューロンを意味する。カーネルのサイズは 3×3 , 5×5 , 3×5 など任意に設定する。加えて、指定したフィルタの枚数だけ特徴マップを生成することができ、フィルタの値は一般的に正規分布から取り出されるランダムな値で演算する。また、順番にフィルタをずらす移動量をストライド (stride) と呼び、ストライドを大きくすれば生成する特徴マップのサイズは小さくなる。

(2) プーリング層 (pooling layer)

プーリング層は、ダウンサンプリングと呼ばれ、特徴マップのサイズを最大値 (max pooling) か平均値 (average pooling) で小さくする。max pooling はカーネル内の最大値を特徴として抽出するため、畳み込み層と同じく画像の位置ずれに対して頑健性を持つ。

例としてモノクロ画像 32×32 pixel を、カーネルサイズが 5×5 、プーリング 2×2 とし、1層目のフィルタを 8 枚、2層目のフィルタを 16 枚とした 2 層の CNN モデルを図 24 に示す。




図 24: CNN2 層の畳み込みとプーリング

畳み込み層でフィルタの枚数を増やして奥行方向に次元を追加し、次段のプーリング層でニューロンを 1/4 に削減する。次に 2 層目の畳み込み層でフィルタを 2 倍に増やし、またプーリング層でニューロンを 1/4 に削減する。畳み込みとプーリングの組み合わせで 1 つの CNN とすると、プーリングでニューロンを 1/4 まで減らすため、フィルタでニューロンを 2 倍とし、結果として CNN1 層でニューロンを 1/2 ずつ減らしながら効率よく特徴抽出を行っている。

4.6.3 リカレントニューラルネットワーク

リカレントニューラルネットワークとは、中間層がループする構造をとる再帰型ニューラルネットワーク (Recurrent neural network: RNN) である。自分自身へループさせることで、前の時刻の中間層の影響を受けることができ、RNN は過去の記憶を用いて判断することを可能としている。このため、音声や文章、動画などの時系列データを扱うことに適している[55]。

RNN もバックプロパゲーションにより学習できるが、誤差の伝播の仕方が通常とは異なる。誤差は過去に遡っていくが、出力層からの誤差の勾配と次の時刻からの中間層の誤差の勾配を加算して重みとバイアスを更新することになる (図 25)。




図 25: RNN の順伝播 (実線) と逆伝播 (破線)

(1) simple RNN

単純な RNN は後述の LSTM と GRU と区別するために simple RNN とも呼ばれる。RNN 層は、この時刻の入力の重みの行列積に、前の時刻の出力と重みの行列積、およびバイアスを加算し、活性化関数で処理する (図 26)。

RNN は時系列方向に深いネットワーク構造をとるため、何層にもわたって誤差を伝播させると勾配が消失もしくは発散 (勾配爆発) するという問題がある。勾配爆発に対しては勾配クリッピングという勾配の大きさに制限をかけることで抑制する [60]。

勾配クリッピングでは、勾配の L2 ノルムが閾値 (threshold) より大きい場合、以下のアルゴリズムにより勾配全体が一定以上に大きくならないように抑制する。

```

$$g \leftarrow \text{勾配}$$

$$\text{if } \|g\| \geq \text{threshold} \text{ then}$$

$$g \leftarrow \frac{\text{threshold}}{\|g\|} g$$

$$\text{end if}$$

```

これらのことから RNN は短期の記憶を保持できるが、長期の記憶を保持することが難しい。この問題を解決するために次の LSTM と GRU が考案された。

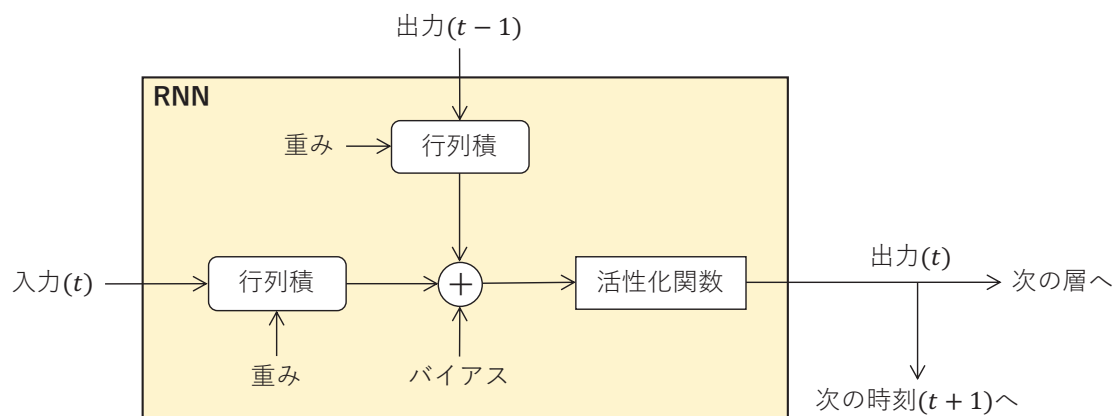


図 26: RNN の構造

(2) LSTM

simple RNN は長期の因果関係の学習が難しいという問題点があったが、それを克服したネットワークが 1997 年に発表された LSTM (Long short-term memory) である[61]. LSTM はこれまでニューロンとして扱ってきた部分を、入力ゲート・出力ゲートと CEC (Constant Error Carousel) と呼ばれる仕組みを導入した LSTM ブロックにすることで、長期の記憶と短期の記憶も共に保持することができる (図 27).

誤差を留ませるためのニューロンを CEC と呼び、CEC は受け取った値をそのまま過去の値として保持し、次の時刻に伝える. また逆伝播において勾配が消失せず、時間を遡っても誤差は留まるため、長期依存性も実現できるようになった. しかし、時間依存性のある信号のときは重みを大きくし、依存性のない信号のときは重みを小さくしなければならないが、ニューロンが同じ重みで繋がっている限り、両者はお互いに打ち消し合う重みの更新となってしまう. これを「入力重み衝突」と呼び、出力でも同じことが起こり「出力重み衝突」と呼ばれる. この問題を解決するためには入力ゲートでは、時間依存性のある信号を受け取ったとき「のみ」活性化する必要がある. 必要なタイミングでのみ信号を伝播し、それ以外は遮断しておくためのゲートの存在を取り入れなくてはならない. そこで入力ゲートと出力ゲートでは、0~1 の値を取るシグモイド関数と入出力の積で制御するよって、過去の情報が必要になったタイミングでのみゲート開けることで長期依存性も効率的に学習できるようになった.

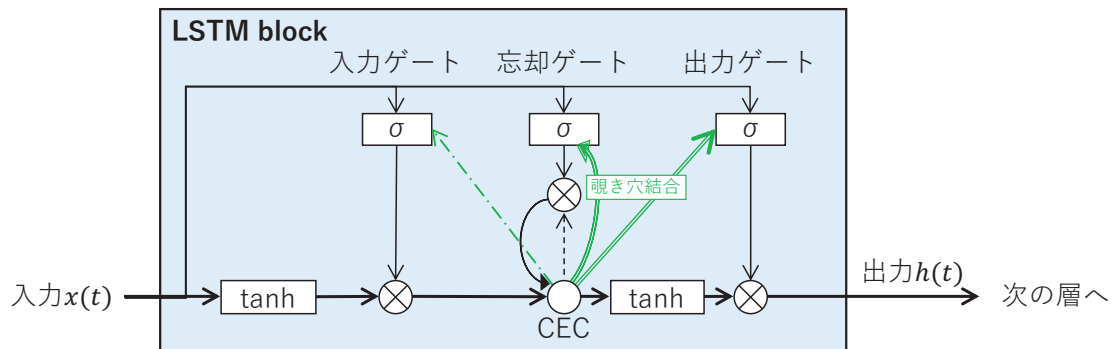


図 27: LSTM ブロックの構造

次に LSTM を改良し、「忘却ゲート」が導入された[62]。これは時系列データ内でパターンが大きく変わる場合、内部記憶の CEC の値が素早く変化しないという問題があった。このため、過去の情報が必要なくなったタイミングで記憶を消すための制御が必要であり、忘却ゲートを追加することで実現している。他のゲートと同じくシグモイド関数を CEC にかけることで忘れ去る機能を果たす。

最後の「覗き穴結合」が導入された[63]。3 つのゲートは時刻 t の入力と $x(t)$ と時刻 $t-1$ の出力 $h(t-1)$ に制御されているため、CEC に保持された過去の情報をどのタイミングで伝播させるかはあくまで LSTM ブロックの入出力に依存している。これによって、仮に入力ゲートがずっと閉じていると、他のゲートは CEC の状態を見ることができないため、解決方法として覗き穴結合が導入された。

(3) GRU

GRU (Gated recurrent unit) は LSTM を改良したもので、2014 年に Cho らにより考案された[64]。LSTM と比べて記憶する CEC がなく、より一般化された構成となっているため、計算量が少なく場合によっては LSTM より良い性能を発揮することもある。

GRU では入力ゲートと忘却ゲートは「更新ゲート」に統合され、CEC と出力ゲートが無い代わりに「リセットゲート」と呼ぶ過去から引き継がれたデータを取捨選択するためのゲートが導入された (図 28)。リセットゲートは過去から引き継がれる値にリセットゲートの値をかけることで、過去の記憶をどの程度取り入れるかをシグモイド関数で調整する[55]。次に新しい記憶である入力 $x(t)$ は LSTM と同じく \tanh 関数を活性化関数とし、リセットゲートと前の記憶である $h(t-1)$ の積をとって、過去の記憶が取捨選択されたうえで新しい記憶として形成する。最後に更新ゲートでは、 $x(t)$ に更新ゲートの値をかけ、過去の記憶として更新ゲートの値から 1 で減じ、 $h(t-1)$ をかけた後に $x(t)$ を加算する。これより、新しい記憶と過去の記憶の割合が調整され、この時刻の出力となる。

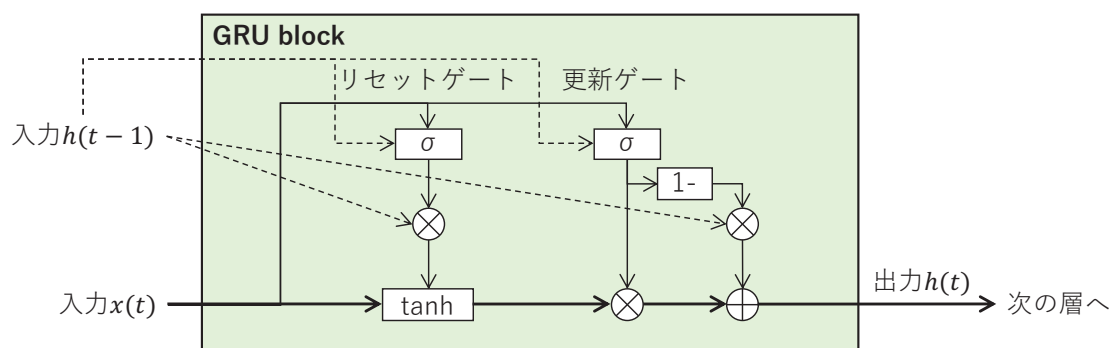


図 28: GRU ブロックの構造

4.6.4 Transformer

これまで説明してきたモデルは、入力層は多数のニューロンから成り、出力層では認識・分類といった少数のニューロンへと減ずるエンコーダ (Encoder) について述べてきた。画像生成や機械翻訳といったタスクでは、エンコーダの後に画像となるピクセル数または翻訳後の文章まで段階的にニューロンを増やすデコーダ (Decoder) を連結し、エンコーダが入力系列の時間依存関係を、デコーダが出力系列のコンテキスト情報をそれぞれ扱う。このようなモデルを Encoder-decoder モデルまたは Sequence-to-sequence (Seq2Seq, S2S) と呼ばれ RNN の LSTM で開発された[65]。しかし、従来の RNN は自然言語処理の機械翻訳で比較的短い文章であれば上手くいったが、長い文章の翻訳が困難だった。これはエンコーダの最後は 1 つにまとめられ、固定された大きさのベクトルとしてデコーダに引き渡されるため、柔軟に表現できないためである。そこで考案されたのが Attention 機構である[66]。

この Attention 機構を応用し RNN を用いず時系列データ処理を実現した Attention, Attention を応用し機械翻訳などに適用される Transformer について述べる。

(1) Attention 機構

Attention 機構のアイデアは、出力する単語にとって重要な入力単語のみを注視して潜在表現を抽出するというものである。まず単語を推定する際に「this」「is」「a」「pen」「.」に分けたトークンをそれぞれエンコーダに対して Attention weight α をかけて加算する。次に出力された「これ」をデコーダの RNN に入力して次の単語を推定するが、この際に再度重みを計算して重み付け足し合わせを行う。図 29 に Attention 機構を導入した Encoder-decoder モデルの概要を示す[67]。

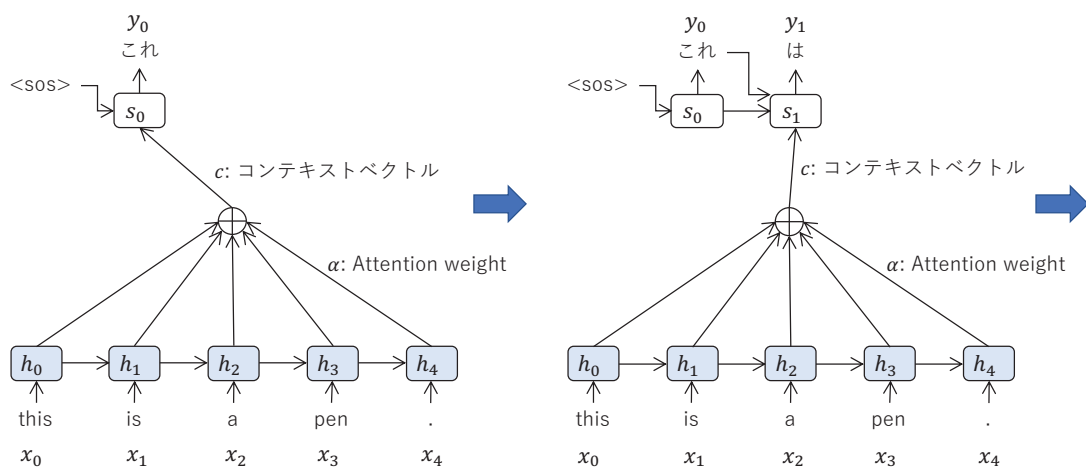


図 29: Attention の Encoder-decoder モデル

最初にエンコーダの処理は RNN で構成され次の式で表す.

$$h_t = \text{Encoder}(x_t) = \text{RNN}(x_t, h_{t-1})$$

次に, Attention weight を用いてフレームごとの潜在特徴量の重み付けの総和であるコンテキストベクトル c_i を計算する. コンテキストベクトル c_i は i 番目のトークンを推定するための潜在特徴量で, $\alpha_{i,t}$ は i 番目のトークンを推定するために用い, フレーム t ごとの Attention weight である.

$$c_i = \sum_t \alpha_{i,t} h_t$$

最後にデコードは RNN と出力層で構成され次の式で表す.

$$s_i = \text{RNN}\{\text{concatenate}(c_i, \text{embed}(y_{i-1})), s_{i-1}\}$$

s_i はデコーダの RNN の隠れ層の値, y_{i-1} はすでに推定された 1 つ前のトークンである. $\text{embed}(y_{i-1})$ はトークンをベクトル化した値を表す. この c_i と $\text{embed}(y_{i-1})$ を連結 (concatenate) し, RNN の出力を線形層と softmax 関数で, i 番目のトークン y_i を推定する.

$$y_i \sim \text{softmax}(\text{Linear}(s_i))$$

こうして, 最初にデコード側の初期ベクトルとエンコードが出力した各トークンの特徴量の内積を計算し, これが Attention のためのスコアになる. 次にこれら各トークンのスコアを softmax 関数で総和が 1 になるように正規化し, これが入力系列のどこに注目するかを表す. この得られた softmax 関数の値をエンコードした後の各特徴ベクトルにかけて総和をとることで, 注目すべき特徴ベクトルが出る. この Attention weight と RNN の出力をもとにトークンを導出する. 次の単語は, 1 つ前に推定したトークンと入力の各トークンの特徴量の内積を計算し, 同様に推定を繰り返していくことで Attention 機構によって RNN のみと比べて離れたトークンとの関連性を保持しやすくなっている.

(2) Query-Key-Value を用いた Attention

前述した Seq2Seq では Attention 機構を組み込んだ RNN が用いられていたが, Attention で入力に Query, Key, Value の 3 つを入力することで RNN を代替する[68]. RNN は内部に再帰計算を含むため, 前の時刻を計算しないと次の計算ができないことにより, GPU を用いた並列演算において GPU の性能を使いきることが難しかった. しかし Attention は再帰計算がなくすべてテンソル演算で表現されるため, GPU の高速な並列演算処理が可能となる (図 30).

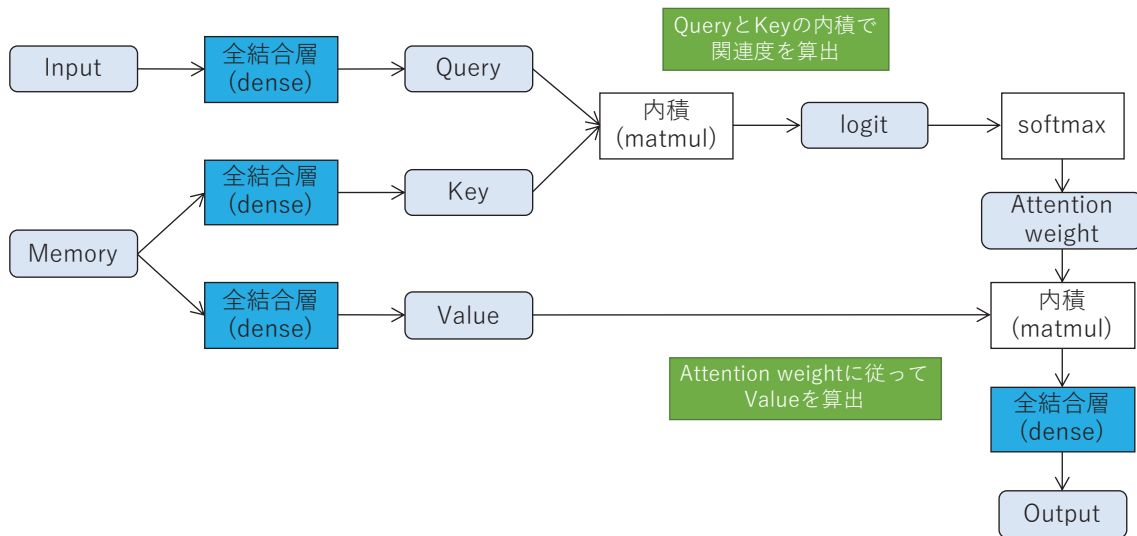


図 30: Scaled Dot-product Attention の構造

モデルの中心にあるのは Attention 機構であるため、元データ (Memory) と検索対象の入力 (Input) の関連度から Attention weight を算出し、value との内積で出力する構造をとる。

まず、入力の Input と Memory の 2 つに分けられ、それぞれ全結合層に入力し Query, Key, Value に割り付ける。Query は検索をかけたいものになり、Key はこの検索をかけるときに、Memory 内のトークンと検索をかける Query がどの程度近いのかを測るための索引のような働きをする。この Key の索引を参考に、対応する適切な Value を出力する。

次に Query と Key の内積 (matrix multiply: matmul) と logit 関数から、Query と Key の関連度を算出する。これは Dot-product Attention と呼ばれる手法である。また関連度の値が大きいと logit 関数の値は急激に増大するため、Query の大きさを次元 (depth) に従って小さくする、この手法を Scaled Dot-product と言い、この手法を適用した Attention を「Scaled Dot-Product Attention」と呼ぶ。この関連度は softmax 関数で各トークンの関連度の割合を同じままに総和が 1 となるように、0 から 1 に収め正規化を図る。

$$Attention\ weight = softmax\left(\frac{qk^T}{\sqrt{depth_{Query}}}\right)$$

この 0 から 1 の範囲に収められた値が Attention weight になり、Memory のどのトークンに注意を向けるかの重みをつけることになる。Query と Key のベクトルが似ていれば、Attention weight は大きくなり、そうでなければ小さくなる。

Attention には大きく以下の 2 つがある。

① Input と Memory に全く同じデータを入力する Self-Attention

文法の構造または単語同士の関係性を得るために使われる。

② Input と Memory に異なるデータを入力する Source-Target-Attention

後述の Transformer でエンコーダの出力とデコードの入力からの流れで合流する箇所に用いられる。

(3) Multi-head Attention

Multi-head Attention は小さな複数の Scaled Dot-Product Attention を並列化して結合した層である[68]。並列化する Attention の数を head と呼び、head の数だけ Query, Key, Value を分割してそれぞれの Scaled Dot-Product Attention に入力し、出力を結合させる (図 31)。

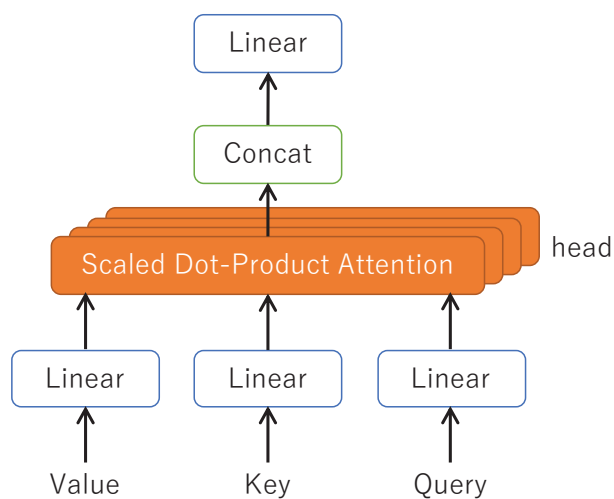


図 31: Multi-head Attention の概要[68]

(4) Transformer

機械翻訳などの Transformer, 自然言語処理の BERT やその他多くの 2021 年現在の SoTA (State of The Art) となっている自然言語処理のモデルは Attention ベースのモデルである (図 32). Transformer は RNN を用いず Self-Attention と Target-Source-Attention のみで再帰計算なく構築しているため, 高効率な GPU による並列計算を可能としている.

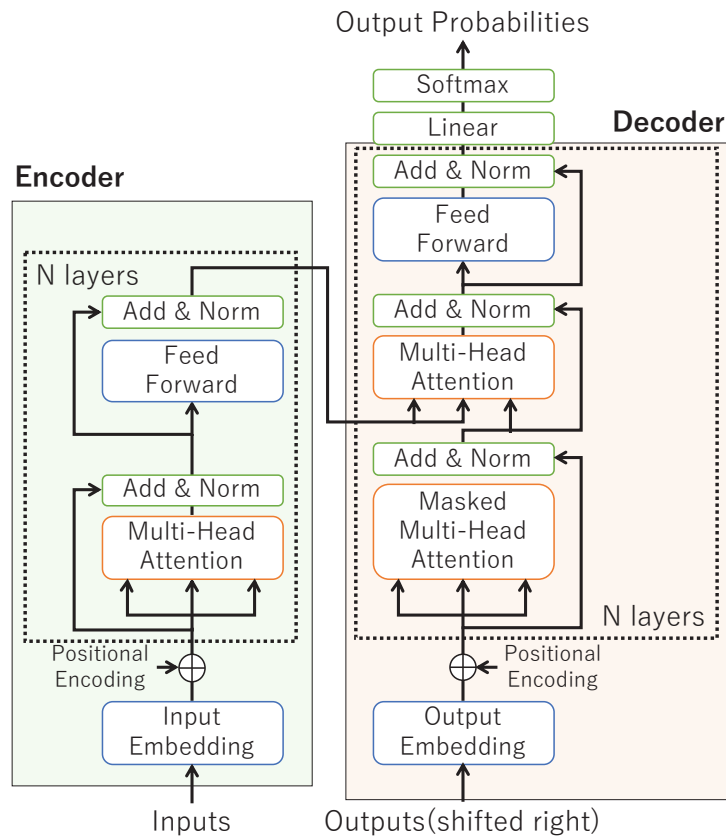


図 32: Transformer の構造[69]

エンコーダの構造として以下の手順で演算する[69].

- ① Embedding 層によって入力文章を 512 次元のベクトルに圧縮
- ② Positional Encoder 層によって位置情報を付加
- ③ Multi-Head Attention 層で Self-Attention を計算し, データ内照応関係を付加
- ④ 各種正規化 (Normalization) を適用

⑤ Point-wise 順伝播ネットワーク (PPFN) で活性化関数を適用

⑥ 各種 Normalization を適用

③～⑥を 6 層繰り返す.

デコーダの構造として以下の手順で演算する.

① Embedding レイヤによって入力文章を 512 次元のベクトルに圧縮

② Positional Encoder 層によって位置情報を付加

③ Masked Multi-Head Attention で Self-Attention を計算し, データ内照応関係を付加

④ 各種 Normalization を適用

⑤ ここまでの出力を Query に, エンコーダの出力を Key と Value にして Multi-Head Attention で Attention を計算し, 異なる時系列データの照応関係情報を獲得

⑥ 各種 Normalization を適用

⑦ PPFN で変換

⑧ 各種 Normalization を適用

③～⑧を 6 層繰り返す.

Transformer は自然言語処理の BERT, GPT-2 などのベースのモデルであり, その性能と RNN を用いないアーキテクチャからパラダイムシフトとなった. このアーキテクチャは自然言語処理だけでなく, 画像認識に応用した Vision Transformer (ViT) や音声認識では Conformer が開発された[70,71].

4.7 AIの医療への適用

これまでのAIの医療への適用としてAI第二世代にあたるMYCINが挙げられる。医学部出身のエドワード・ショートリッフェ（Edward H. Shortliffe）が中心となって開発され、血液感染症と骨髄炎の診断と治療法を支援した。このMYCINはプロダクションルールに確信度が付加されており、不確かな知識も表現でき、システムが行った推論に対する説明機能も有している（図33）。しかし、知識の記述を増やすにつれ、他のルールとの整合性を維持するなどのメンテナンスが困難になった[72]。

MYCINは推論に対する説明機能を有していた。しかし、深層学習モデルは内部のニューラルネットワークにおけるニューロンの多さのため、結果が示された際の判断根拠となる因子の特定が困難である。このためモデルの判断根拠はブラックボックスとなり、AIが出力する結論の根拠についての説明を文脈に必要な形で得ることが出来ない。特に診断において医師は、医学的な知識体系から因果関係や人体構造に関する情報から演繹的に判断を下すため、AIで得られた結果を演繹的な推論で理解することは困難である。加えて、診断結果を患者に説明する場合に、患者が納得できるように判断や意思決定のプロセスを説明する必要がある。また、AIの判断が誤っていた場合、適用結果に責任を負うのは使用側の医療従事者であるため、説明性を付与するためには、現在のAIに加えて医学的知識による推論結果を組み合わせたAIが求められる[73]。現在、推論結果に貢献した部分を可視化するという手法はGrad-CAMやAttention機構を応用したAttention mapなどによって実現している[70,74]。また、説明できるAIを開発する研究も試みられている[75]。

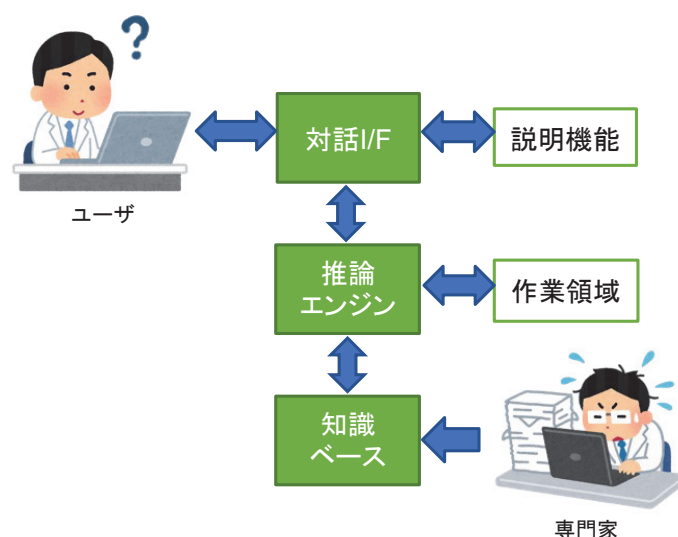


図 33: MYCIN のシステムフロー

一方で、2018年にアメリカ医師会（AMA）は「医療における拡張知能」という声明を出した[76]。これはAMAがAIについて言及した最初の文書であるとされ、AIの位置づけについて述べられている。AMAはAI（Artificial Intelligence）としてではなく、拡張機能（Augmented Intelligence）として位置付け、AIが医療において求められること・可能なことは「医療の自動化」ではなく、医師である人間の動作・判断の支援、人間の知能の拡張にこそ重点があるからだとしている。これは、医師の存在自体は置き換えられず、医師とAIとの連携でよりよいケアが達成できるとしている。

この上で以下の5つの提案がなされている。

1. 医療におけるデジタル技術の導入が患者にも医師にも利益が大きいものであること
2. 医療AIの開発から実践までの諸段階はそれらを用いる医師の視点が組み込まれるべきこと
3. 医療AIが「再現性」「説明可能性」を備え、また新たな「弱者」を生み出すものではないこと
4. AIの可能性と限界に関する医師・医学生・患者への教育の充実
5. AI使用による諸問題の把握・監督体制の整備

これらのことから、医療に適用するAIは「人間あるいはそれ以上の知能をもった」、相当程度に特定の機能に特化し、機序の明晰性を備え、医師や看護師等の医療従事者を支援することによって業務を最適化するAIが求められている。一方で、昨今のICTでは、IoT技術によって社会のあらゆるデータからAIを用いてデータ駆動で社会を動かすデータ駆動型社会が現実のものとなりつつある。よって次章ではAIの病院への適用について論じる。

第5章 AIの病院への適用

深層学習によってビッグデータから自動的に学習できるようになったことからAI開発が盛んに行われており、併せてIoT技術の発展からあらゆるデータの取得と蓄積が試みられ、データ駆動型社会の到来が期待されている。一方で、医療分野においてはAIによる医師の診断支援システム（Clinical Decision Support System: CDSS）の実現に向けて盛んに研究が行われている。

本章では、データ駆動型社会の到来に対して病院の在り方について論じる。5.1節で本邦における医療にAIを適用する試みについて、5.2節でデータ駆動型社会について、最後に5.3節でAIがもたらす次の病院の在り方について述べる。

5.1 本邦における医療にAIを適用する試み

深層学習によるパラダイムシフトといえる第三次AIブームから医療分野への期待は大きい。2017年に厚生労働省がデータヘルス改革推進計画を発表し、健康・医療・介護システムの構築について8つのサービスが述べられている（表13）。ここでは医療・介護の提供だけでなく、予防推進による国民の健康維持・増進を図ること、がんゲノム情報の解析によって革新的な医薬品などの開発を推進すること、さらにはAIの活用なども含まれている[77]。

表 13: データヘルス改革推進計画[77]

データヘルス改革の基礎構築	・被保険者番号の個人単位化 ・オンライン資格確認システムの導入
最適な保健医療サービスの提供	①保健医療記録の共有 ②救急時医療情報共有
保健・医療・介護のビッグデータの連結・活用, PHR	③健康スコアリング ④データヘルス分析関連サービス ⑤乳幼児期・学童期の健康情報・PHR
科学的介護の実現	⑥科学的介護のデータ
がんゲノム情報の活用など	⑦がんゲノム・AI
審査支払い機関の強化	⑧医療保険情報に関わるデータ分析などに関する業務を追加

2018 年度の内閣府戦略的イノベーション創造プログラム (SIP) 第 2 期において、医療分野における Society5.0 の実現に向けた課題として「AI ホスピタルによる高度診断・治療システム」研究が採択された。これは AI, IoT, ビッグデータの技術を活用して医療の効率化や医療従事者の負担軽減などを旨とした技術・サービスの開発を行う一連のプロジェクトであり、様々なサブテーマから成る「AI ホスピタルシステム」を開発・構築・社会実装することにより、高度で先進的な医療サービスを提供する。その結果として医療機関における効率化を図り、医師や看護師等の医療従事者の抜本的な負担の軽減を実現することを目標としている[78]。そこで AI ホスピタルを実現するために、医療・製薬など医療に関わる業界共通の基盤になる医療 AI プラットフォームの構築が始まっている。医療 AI プラットフォームという共通基盤ができれば、今まで各病院が持っていた医療情報を 1 つの場所に集めて AI が分析・提案が行え、研究開発においても各病院から集められた医療情報を活用した新たな技術開発が容易に行うことが期待されている[79]。AI ホスピタルプロジェクトでは検査データや医用画像の他に患者個人の情報として、環境センサ、ウェアラブル端末、バイタルセンサ、位置センサの取得が考慮されている(図 34)。

現在、AI を適用する焦点は病院における医療に置かれているが、保健・医療・介護のビッグデータや PHR のデータ基盤が整うことによって、予防医療や在宅医療・介護医療の AI 開発がさらに促進されると考えられる。したがって、医療を施す場は病院だけに限らず、在宅や個人の生活にまで領域が広がると考えられる。

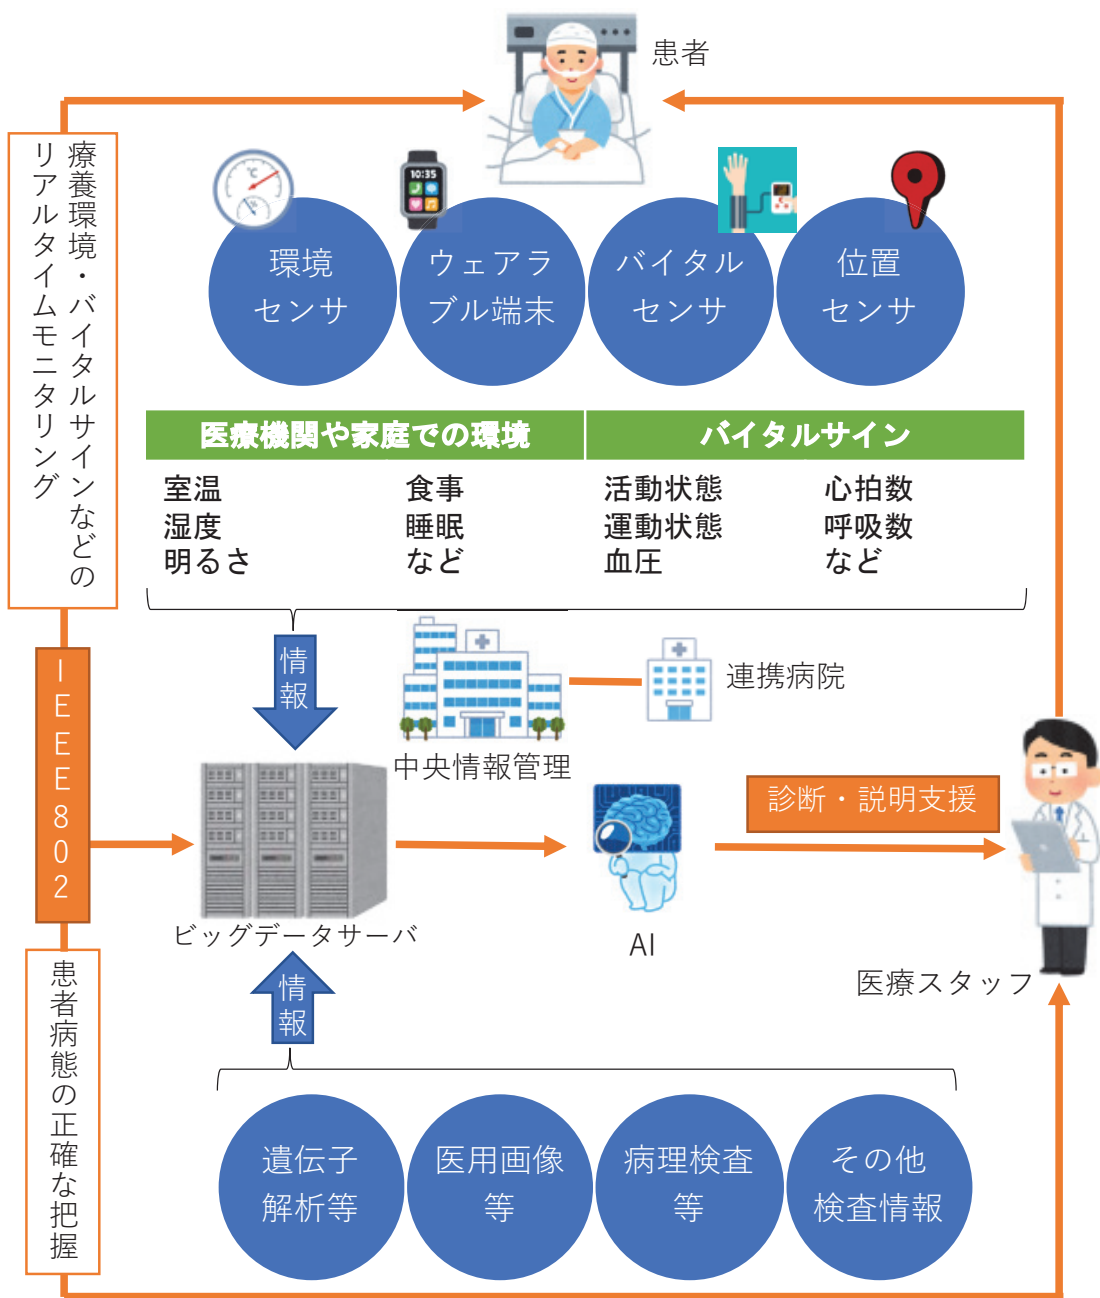


図 34: AI ホスピタルの概要[78]

5.2 データ駆動型社会

狩猟社会（Society 1.0）、農耕社会（Society 2.0）、工業社会（Society 3.0）、情報社会（Society 4.0）に続く新たな社会として Society 5.0 が提唱されており、この社会の実現を支える仕組みの1つとして、データ活用に基づくデータ駆動型社会の実現が謳われている。

2018年に閣議決定された未来投資戦略2018では、Society 5.0と共に2015年に経済産業省が公表したサイバーフィジカルシステム（Cyber Physical System: CPS）が重要課題として掲げられた[4,80]。CPSによるデータ駆動型社会は、IoT・ビッグデータ・AI等のITの技術革新によって、製造プロセス、モビリティ、流通、スマートハウス、医療・健康、インフラ・産業保安、行政等の様々な分野において実世界から得られたデータを取得し、サイバー空間で大規模データ処理技術等を駆使して分析・解析を行い、情報や知識に変換した結果を再び実世界にフィードバックする。これが社会のあらゆる領域に実装されることによって、社会的価値を生み出していく社会の実現を目指している（図35）。

このデータ駆動型社会とは、IoTが様々な産業社会に適用され、デジタル化された情報が、知識へと変換されて現実世界に適用されることによって、データが付加価値を獲得して現実世界を動かす社会である。つまり、ビッグデータから抽出した情報や知識を人にフィードバックし、意思決定を支援することを通して社会を動かす。または人が介在することなしにデータが自動で社会を動かすことである。

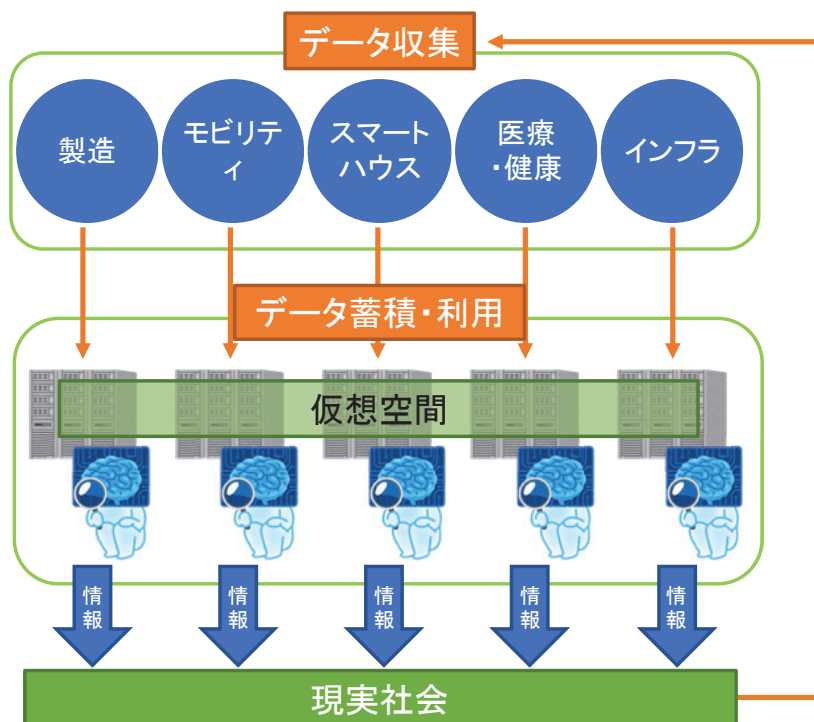


図 35: データ駆動型社会の概念図

5.3 AIがもたらす次の病院の在り方

医学と医療が高度化および複雑化しつつ、病院は在宅医療にも対応して患者に包括的な医療サービスを提供しなければならない。このなかで医療現場の安全性の担保と、医療の質の向上が社会的に求められるため、医療従事者の負担は増大する一方である。このため、病院の業務を効率化し病院機能を高度化するためには、病院情報システムは高度化しなければならない。

世界における病院情報システムの取り組みとしてスマートホスピタルがある。オーダーリングシステムから始まった病院の ICT 化は、紙ベースのシステムと患者ファイルを EHR に転送することを目的として最初に導入された。その後、2007年にケア、健康、コストの3つの概念から、コストを削減しながらケアと健康の改善に重点が置かれた[81]。こうして医療社会での EHR の受け入れが増えるにつれ、大量の臨床データと医事データが蓄積された。その結果として臨床研究が改善され、管理者の意思決定が改善されていった[82]。この流れから、「デジタル」という呼称は次第に「スマート」に置き換えられ、スマートホスピタルを開発するための多くの調査研究と運用プロジェクトが実施されていった[83]。スマートホスピタルとは動的にデジタル化された環境下で、患者や医療従事者を含めたすべての個人に最大かつリアルタイムにメリットを提供する事ができる病院であり、AI の利用は不可欠だと考えられている。スマートホスピタルの実現のためには新しい技術と機器に加えて、臨床及び管理プロセスの作成と最適化が必要とされる。様々な情報を接続して取得したビッグデータを利活用することで、ケアの質を高め、コストパフォーマンスを効率化する報告が挙げられている[84]。またスマートホスピタルはこの効率を最大化し、ケアの質を高め、既存のプロセスを改善することによって患者満足度を高めるサービスを提供できるとされる[85-87]。世界保健機関（WHO）によると2020年から10年間で、スキル不足の医療従事者である1800万人以上に対処することになると言われている。これは限られたスペースと人材の中で、長時間、高ストレスな労働を強いることになり、医療従事者の数を増やすことは日々増加する医療サービスの要求を満たすには持続可能な選択肢ではないとされる[22,23]。一方、スマートホスピタルは、業務負担の軽減と患者の健康管理の向上により、需要の増加に対応したより良いケアを提供できるとともに、現在の非効率性を是正することが期待できるとされる[88]。

病院情報システムが医療現場の安全性の担保と医療の質の向上を図るための高度化は、スマートホスピタルの概念を基にデータ駆動志向を加えることによって達成できると考えられる。すなわち診療データの一次利用に留まっていた病院情報システムから、病院情報システムがデータ駆動志向で動的に支援を行うデータ駆動型病院情報システムを実現させることである。

AI が支援する分野としては、これまでに蓄積された診療データや、ゲノムデータおよび

医療従事者が様々なシステムに日々入力したデータ等を用いることで、帰納的な医学的知見を得ることができる可能性があるため、医学の診断や治療に関して多くの AI の開発や研究が進められている。一方で、医療現場の安全性の担保と、医療の質の向上が社会的に求められるなかで、医療従事者の業務を効率化するためには、IoT、センシング技術およびデータの蓄積と利用によって、複雑化した病院の業務を合理化または自動化できる可能性があるが、データ駆動志向の病院における在り方は検討できていない。よって、データ駆動型社会における病院の在り方を検討することを目的として、データ駆動型病院情報システムを検討するにあたって、データ駆動志向のためのデータの収集とデータの蓄積および利用を検討する。

第 6 章では、IoT やセンサデータを用いたデータ収集および機械学習の利用による安全性の担保について、自動的に医療機器の異常状態を通知することで安全性を向上できる可能性がある。このため、病院情報システムと接続されていない、または接続できない医療機器に対してアラーム音から医療機器のアラート状況の収集および自動認識を検討する。

第 7 章では蓄積されたデータおよび機械学習を用いた業務の合理化について、看護師は患者の機微を捉えて看護記録に叙述的に記載しているため、患者が直近に起こすであろう行動を予測することによって適切な患者管理が行える可能性がある。このため、看護記録における「患者の危険行動」について、深層学習を用いて自動監査が可能か検討する。

第6章 病棟における医療機器のアラーム音の収集および自動識別

医療機器のアラームは間接的に患者の異常状態を捕捉している場合がある。病院情報システムと接続されていない医療機器または接続できない医療機器に対してアラーム音から医療機器のアラート状況を自動認識し、患者を管理する看護師に通知することで看護業務の最適化を図れる可能性がある。本章では医療機器のアラーム音から機種のアラート状態を自動検出する識別器を検討する。

6.1 背景

医療機器は聴覚アラーム信号（以下、アラーム音）で医療従事者に対して異常状態を知らせているが、医療従事者は遠方や夜間の見回りのために個室で鳴るアラーム音に気付けないことがある。2010年から2015年の間において日本医療機能評価機構にインシデントとアクシデントの報告が173例挙がっており、うち23例はアラームが鳴っているにもかかわらず気付かなかった事例であった[89]。報告内容から業務環境の要因としては「施設の構造上、死角が多く患者の病室に入ると外の音が聞こえにくかった」「ナースステーションから遠い部屋でアラーム音は届かなかった」「ICUの一番奥の個室なので聞こえにくかった」「アラーム音が記録室内では聞こえない構造になっていた」等が指摘されている。

一方で、生体情報モニタはネットワーク化され多くの病院で病院情報システムに接続されており、他の医療機器についてもネットワーク化が盛んに試みられている。具体的には、シリンジポンプや輸液ポンプなどが内蔵の無線LANによって病院情報システムに接続して作動状況を通信できるものが普及しつつある。ほかにも医療機器の外部出力端子にドングルを接続して無線化する提案がされている[90,91]。しかし現状は、外部出力端子を有する機器においてゲートウェイの設置などデータ取得環境構築のコストと接続の煩雑さから、病院情報システムとの連動が広く普及していない。また、未だに外部出力端子がなく病院情報システムとの接続が困難な機器も少なくない。したがって病室でアラーム音を自動検知することができれば、より安全な医療を提供できる。

医療機器の異常時に鳴るアラーム音を検出できれば効果的ではあるが、病院情報システムに取り込んで活用するためには機種を識別する必要がある。従来、音認識はテンプレートマッチング、隠れマルコフモデル (hidden Markov model: HMM)、混合ガウス分布 (gaussian mixture model: GMM) の順で導入された。現在は、深層学習を用いて混在した様々な環境音に対して多ラベルを付与した重複音の認識の研究が試みられ、高精度な予測ができるようになった[92,93]。正弦波信号であるアラーム音の識別においても、ピーク周波数の検出 (Spectral peak picking 法) より GMMの方がノイズに対してロバストであることが報告され、機械学習に基づく提案がなされている[94–97]。また、組み込みシグ

ルボードコンピュータとモバイル向け機械学習モデルの性能向上により、エッジデバイスによる音声認識も試みられている[98]。これらから、患者ベッドサイドに設置したエッジデバイスを用いて、アラーム音から医療機器の異常状態を認識することにより、外部出力のない医療機器も含めて簡易に病院情報システムと連動できる[94]。しかし、患者ベッドサイド環境では、患者の異常と連動して複数の医療機器からアラーム音が重複して鳴る場合があるが、重複アラーム音の識別に関する検討はなされていない。

6.2 目的

本研究では、モノラルマイクロフォンを用いて、鳴動する医療機器の重複したアラーム音から、機種を識別を可能とする方法を提案する。具体的には、アラーム音の特徴抽出に、周波数成分にバンドパスフィルタを配列したアラーム音を対象としたフィルタバンクを適用する。次に識別器には、音響識別するにあたって深層ニューラルネットワークに基づく手法が主流となっており、畳み込みニューラルネットワークや画像認識で高い性能を示す機械学習モデルを利用した手法を用いる[92,93,97]。特に今回は、重複アラーム音の識別を行うために、単一のアラーム音から合成した重複アラーム音の学習データセットを用いて深層学習した識別器を構築する。その後、病棟の環境音（以下、環境音）を合成した重複アラーム音の評価データセットから機器の鳴動を識別し、通知システムとして臨床応用可能か検討する。

6.3 対象機器

病院の一般病棟における医療機器の使用数が多い人工呼吸器装着患者を想定し、識別するアラーム音は、輸液ポンプ（Infusion pump）、シリンジポンプ（Syringe pump）の閉塞アラーム、カフ圧コントローラ（Cuff controller）の低圧アラーム、人工呼吸器（Ventilator）の低換気量アラームの4機種とした。実機を作動させてマイクロフォンで静音下にて録音し、同時にA特性の騒音計で音圧を測定した（表14）。音源とマイクロフォンの離隔距離はベッドサイドで用いる場合の距離とした（図36）。録音したアラーム音はピーク周波数のコントラストが明瞭な横縞のスペクトログラムで、輸液ポンプと人工呼吸器はパルス音、カフ圧コントローラは単一のバースト音、シリンジポンプは持続する一定のバースト音であった（表15）。

表 14: 録音条件

	Model	MM-MCU05BK (SANWA SUPPLY INC.)
Microphone	Frequency response	2Hz~20kHz
	Output impedance	2.2k Ω
	Directivity	Omnidirectional
	Modulation	Linear PCM
	Channel	Monaural
Data format	Sampling frequency	48kHz
	Quantization bit rate	16bit

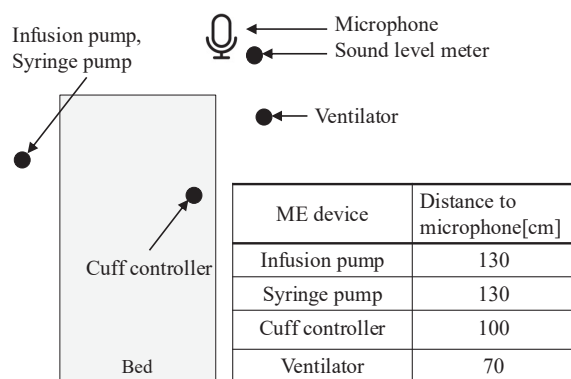


図 36: 録音環境

表 15: アラーム音の詳細

Source device	Manufacturer/ Model	Peak frequencies (Hz)	Signal duration	Sound setting	Sound level (dB)
Infusion pump	JMS/ OT-818G	844, 1707, 2578, 3409, 4266, 5118, 5953, 7688	0.13s 5times ^a	6	81.0
Cuff controller	Murata/ Smart Cuff	2344, 4688, 7031, 9375, 11700, 14041, 18725	0.5s	None	60.0
Syringe pump	Terumo/ TE-351	3984, 12000, 15984	constant	b-2	75.6
Ventilator	Drager/ SAVINA	984, 1969, 2953, 3938, 5906, 7902, 8889 / 780, 1547, 3141, 5484, 6281, 7054, 9406 ^b	0.16s 5times ^a	100%	84.0

^a The number to repeat in one event.

^b The symbol of slash separates the two tones.

6.4 方法

重複アラーム音から機種を識別する識別器を提案する。提案するアラーム音識別システムは図 37 に示すように、入力、特徴抽出、アラーム音識別モデルから成り立つ。入力では対象機器から識別するクラス名を設定する。特徴抽出では収集した音響情報から識別器に入力する特徴量を抽出する。アラーム音識別モデルでは識別器の機械学習モデルを設計する。これらから成り立つシステムによって重複アラーム音から機種を識別することが実現できる。最後にモデル学習では環境音に対してロバストな方法を適用する。

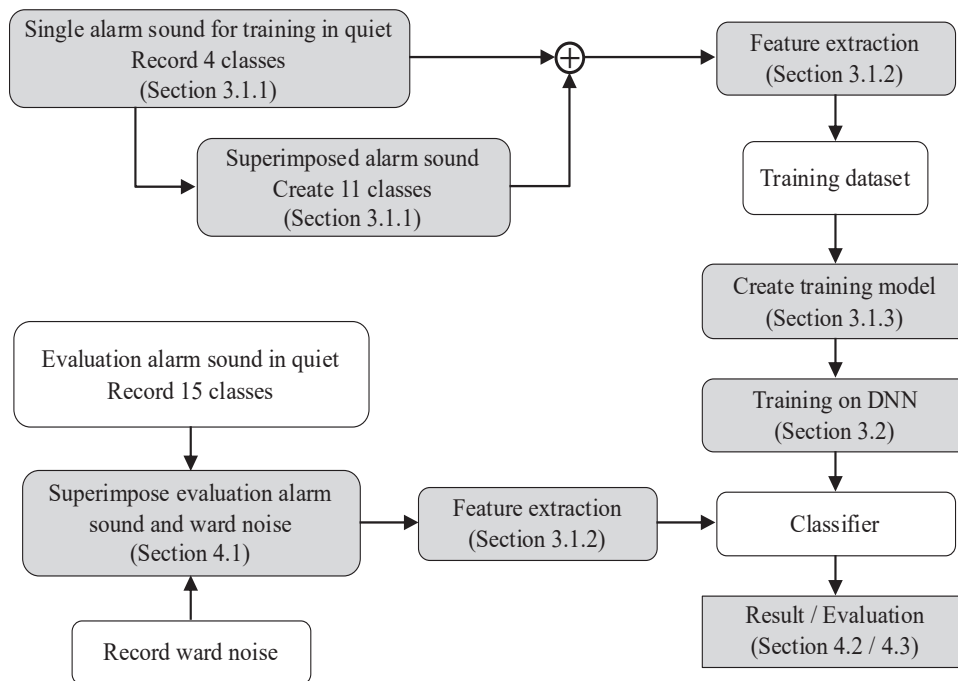


図 37: 実験概要

6.4.1 アラーム音識別システム

ベッドサイドで使用する医療機器の重複アラーム音の識別システムを構築する。識別器に入力する特徴量の抽出にあたり、対象機器の周波数スペクトルから得られた情報を基に、フィルタバンクを適用する。

音響識別の多くはスペクトルにメルフィルタバンク（以下、MFB）をかけたログメルスペクトログラムかメル周波数ケプストラム（MFCC）が用いられる[99]。近年、深層学習ではログメルスペクトログラムを用いて認識結果の向上が報告されている[100,101]。ここで仮説として、識別対象機器の周波数スペクトルから得られたピーク周波数を基にしたフィルタバンクであれば、アラーム音に対してより特徴を捉えやすく認識結果が向上する可能性がある。

6.4.1.1 入力

重複アラーム音を識別するにあたり、クラス数は 4 機種の有無によるすべての組み合わせから 15 クラスと、環境音クラス（以下、other）を含めた合計 16 クラスとした。以後、ラベルの略称については輸液ポンプ（以下、Inf）、シリンジポンプ（以下、Syr）、カフ圧コントローラ（以下、Cuff）、人工呼吸器（以下、Vent）とする。

6.4.1.2 特徴抽出

識別器に入力するにあたり，音響データから特徴量を抽出した．入力した音響データを短時間フーリエ変換（Short Time Fourier Transform, STFT）で時間-周波数空間のパワースペクトログラムに変換した[99]．フーリエ変換で切り出すサンプル数は 1024 サンプル，ホップサイズを 256 サンプルとし，窓関数はハニング窓関数を用いた．次にプリエンファシス処理で高域成分を強調し，後述のフィルタバンクを適用した．

比較対照となる識別器のフィルタバンクとして MFB を用いた．MFB は人の周波数知覚特性を考慮したメル尺度を基に，三角形のバンドパスフィルタを重ねながら並べたフィルタである．バンドパスフィルタのチャンネル数は識別対象機器のピーク周波数と同じ 32 個として作成した．

一方で，仮説に挙げた識別対象機器のピーク周波数を基にフィルタバンクを作成する．MFB を基に，三角波の頂点である中心周波数を対象機器の n 番目のピーク周波数とし，三角波の底辺を $n - 1, n + 1$ 番目のピーク周波数として配列したカスタムフィルタバンク（以下，CFB）を作成した（図 38）．

これらフィルタバンクを実験毎にパワースペクトログラムに乗じた後に対数化した．最後に，ホップサイズだけずらして 200ms まで繰り返して結合し， 38×511 のパワースペクトログラムを特徴量とした（図 39）．特徴抽出方法のフロー図を図 40 に示す．




図 38: カスタムフィルタバンク




図 39: CFB のパワースペクトログラム

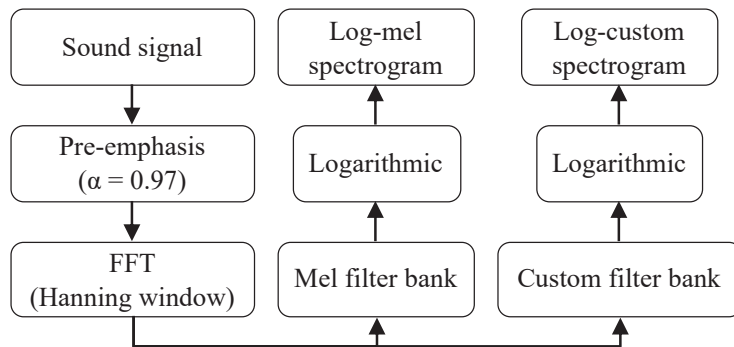


図 40: 特徴抽出

6.4.1.3 アラーム音識別モデル

識別モデルはベッドサイドに設置するエッジデバイスを想定し、軽量の深層ニューラルネットワークモデルである MobileNetV3 small を用いた[102]. 環境構築としてプログラミング言語はPython 3.7, 深層学習ライブラリはKeras 2.4.0 (バックエンドはTensorflow 2.3.1), 音響解析ライブラリは Librosa 0.8.0 を用いた. 次にネットワーク設計は MobileNetV3 small の出力層を 16 クラス, 活性化関数を softmax 関数として 16 個の予測値の合計が 1.0 となるようにした.

6.4.2 モデル学習

学習データセットは, 識別器の過学習を防ぎつつシミュレーション実験でロバストな性能を持たせるために, データ拡張処理 (Data augmentation) を適用した.

学習データセットに用いる 2~4 機種 of 重複アラーム音は, 録音した 4 機種 of 単一アラーム

ム音からサウンド編集ソフトウェア Audacity で重畳して作成した。重畳方法としてはアラーム音の発音開始に揃えて重なった部分のみを学習データに採用した。これらをフレーム長 200ms で切り出し、wav ファイルとして 20 サンプルずつ用意した。other クラス（環境音）は駆動音が大きい人工呼吸器のアラーム音間の雑音と録音環境下の背景雑音を 20 サンプルずつ加えた。Data augmentation としてホワイトノイズを信号対雑音比（以下、SNR）30dB から 0dB の範囲で 1dB ずつ重ねたデータを加え、これにより 30 倍にサンプルを増した[103]。その後 MFB と CFB を用いて、それぞれ 9600 サンプルのログスペクトログラムから成るテストデータセットを用意した。

学習には最適化アルゴリズムに Adam，損失関数は交差エントロピーとした[104]。さらに学習時にジェネレータを組み込み，学習サンプルに周波数方向と時間方向に対して，ランダムにマスク処理を行う SpecAugment を適用した[105]。最後に 5 分割交差検証，エポック数 100 で学習済みモデルを作成し，学習曲線から過学習に陥っていないことを確認した。

6.5 シミュレーション実験

アラーム音識別システムに対して特徴抽出で提案した仮説である，CFB を用いた識別器は MFB を用いた識別器より優れていることをシミュレーション実験で検証する。これについてシミュレーションデータセットを用いて，後述の識別結果と評価指標から検証した。

6.5.1 シミュレーションデータセット

静音下で 4 機種の実機でアラーム音を鳴らし合わせ，すべての組み合わせの重複アラーム音を録音した。アノテーションは Audacity を用いて目視でラベル付けを行った。次に病棟のベッドサイドで環境音を録音し，重複アラーム音に SNR 30, 20, 10, 0dB で重畳させてシミュレーションデータとした。この環境音には会話，足音，戸棚の開閉音，口腔内吸引が含まれている。その後，フレーム長 200ms，50ms 間隔で読み込み，MFB と CFB で特徴抽出し 2 種類のデータセットを作成した。最後に，アラーム音の長さや発音間隔の違いから各クラスに偏りが生じるために，不均衡なサンプル数となる。このため層別化ランダムアンダーサンプリング処理を加えて，各クラスを同じサンプル数にした。

6.5.2 識別結果

入力されたデータから識別器は 16 クラスの合計予測値が 1.0 となるように出力され，この 16 クラスから最大値のクラスを識別結果として出力した。なお，シミュレーションデー

タセットはアンダーサンプリングしているため、スムージングなど時系列の判定処理 (Post processing) は行わなかった。したがって、1 フレーム毎に識別したセグメントベースの結果から、後述の各指標で総合評価を行った。

6.5.3 評価指標

評価指標として、識別結果のクラス名から多クラス分類の混同行列を作成した[106]。識別結果とクラスが合致すると **Positive**、正解クラス以外の場合を **Negative** と判定し、各クラスの **Recall** と **Precision** は混同行列から次のように算出した。この **Recall** と **Precision** から各クラスの **macro-F** 値を次のように算出した。

システムの評価としてマイクロ平均をとった **micro-F** 値と、特定の閾値を決めずに識別しているため **ROC** 曲線 (**Receiver Operating Characteristic Curve**) から **AUC** (**Area Under Curve**) で検討する。なお多クラス分類におけるマイクロ平均では **Recall**, **Precision**, **F** 値は同じ値になる。

6.6 結果

MFB を用いた識別器と **CFB** を用いた識別器の識別結果を表 16 に示す。総合評価として **micro-F** 値と **AUC** を算出し、**CFB** を用いることで **micro-F** 値は最大 4.4 ポイント、**AUC** は最大 0.006 ポイント高いことが確認できた。次に、**CFB** を用いた **SNR 0dB** の識別結果を図 41 の混同行列に示す。各クラス 107 サンプルから 5 つの学習済みモデルでそれぞれ識別するため、各 535 個の識別結果となった。**Recall** において単アラームでは **4.Vent** が 74%であったものが、2 機種になることで **9.Cuff,Vent** クラスが 57%、3 機種になることで **14.Inf,Syr,Vent** クラスが 56%、4 機種で 39%であった。共通点として人工呼吸器である **Vent** が含まれるラベルの **Recall** は低い傾向であった。混同行列において誤認識して入ったクラスは、1 機種で **0.other** クラス、2 機種で **3.Syr** クラスと **4.Vent** クラス、3 機種で **10.Syr,Vent** クラス、4 機種で **10.Syr,Vent** クラスと **14.Inf,Syr,Vent** クラスであった。アラーム音識別システムの評価として、クラス別において **AUC 0.90** 以上であった。

これらから、どの **SNR** においても **CFB** の **micro-F** 値と **AUC** は **MFB** より高かったため、**CFB** が優れていることの仮説が検証された。加えて **AUC** からアラーム音識別システムが機種を識別できた。

表 16: micro-F と AUC による MFB と CFB の比較

SNR	MFB(Baseline)		CFB	
	micro-F (%) mean (SD) *	AUC mean (SD)	micro-F (%) mean (SD) *	AUC mean (SD)
No word noise	71.4 (0.972)	0.964 (0.00206)	75.1 (0.840)	0.968 (0.00125)
30	71.3 (1.02)	0.964 (0.00210)	75.1 (0.962)	0.969 (0.00106)
20	71.6 (1.00)	0.964 (0.00164)	75.4 (0.975)	0.969 (0.00116)
10	72.3 (0.839)	0.965 (0.00121)	75.9 (1.00)	0.969 (0.00109)
0	68.2 (1.46)	0.956 (0.00279)	72.7 (1.20)	0.963 (0.00106)

*mean (SD) is the mean and standard deviation of model trained 5 times

True label																Precision	Recall	macro F	AUC	
	0.other	1.Inf	2.Cuff	3.Syr	4.Vent	5.Inf,Cuff	6.Inf,Syr	7.Inf,Vent	8.Cuff,Syr	9.Cuff,Vent	10.Syr,Vent	11.Inf,Cuff,Syr	12.Inf,Cuff,Vent	13.Cuff,Syr,Vent	14.Inf,Syr,Vent	15.Inf,Cuff,Syr,Vent				
0.other	329	41	24	121	4	1	2	4	3	0	1	2	2	0	0	1	76%	61%	68%	0.971
1.Inf	7	483	5	7	0	21	3	9	0	0	0	0	0	0	0	0	83%	90%	86%	0.988
2.Cuff	43	0	432	13	2	27	0	0	16	0	0	0	0	2	0	0	87%	81%	84%	0.984
3.Syr	0	0	0	492	0	0	12	0	25	0	4	2	0	0	0	0	48%	92%	63%	0.974
4.Vent	46	3	1	19	397	0	0	15	0	2	48	0	2	2	0	0	61%	74%	67%	0.966
5.Inf,Cuff	0	36	27	1	0	461	1	1	4	0	0	0	4	0	0	0	90%	86%	88%	0.992
6.Inf,Syr	0	0	0	80	0	0	411	0	5	0	0	35	0	0	4	0	80%	77%	78%	0.954
7.Inf,Vent	4	20	0	5	79	0	0	393	0	0	9	0	22	0	3	0	73%	73%	73%	0.977
8.Cuff,Syr	0	0	0	81	0	0	0	0	444	0	3	5	0	2	0	0	72%	83%	77%	0.978
9.Cuff,Vent	2	0	3	1	129	0	0	0	1	303	5	0	43	48	0	0	85%	57%	68%	0.967
10.Syr,Vent	0	0	0	94	0	0	0	0	0	0	440	0	0	1	0	0	49%	82%	61%	0.962
11.Inf,Cuff,Syr	0	0	1	14	0	0	41	0	95	0	0	381	0	0	2	1	89%	71%	79%	0.932
12.Inf,Cuff,Vent	0	1	1	0	38	1	0	116	0	53	0	0	323	2	0	0	82%	60%	69%	0.972
13.Cuff,Syr,Vent	0	0	0	41	0	0	0	0	21	0	134	0	0	335	3	1	79%	63%	70%	0.949
14.Inf,Syr,Vent	0	0	0	31	0	0	45	0	0	0	148	0	0	0	302	9	62%	56%	59%	0.939
15.Inf,Cuff,Syr,Vent	0	0	0	17	0	0	0	0	0	0	107	3	0	32	170	206	94%	39%	55%	0.913

図 41: CFB における SNR 0dB の混同行列

(Precision, Recall, macro F は 70%以上に網掛け)

6.7 考察

本研究では、大量の人工的な雑音データを用いて識別器の構築を行い、病院雑音下での重複アラーム音に対する評価を行った。

6.7.1 特徴抽出における CFB

表 16 より、CFB を用いることで従来の MFB より micro-F 値は 3.6~4.5 ポイントの精度向上が得られ、すべての SNR において優位であった。特に SNR 0dB の CFB は MFB の各 SNR の結果よりも高く、ロバストであることが確認された。病棟において操作ミスを未然に防ぐ観点から機種統一が図られ、既知の限定した機器を使用することが想定される。本システムは教師あり機械学習であり、既知の音源を対象としているため CFB は有効と考えられる。加えて CFB はアラーム音の周波数のみを抽出しているのではなく、他の周波数帯域も残しているため、識別対象を患者行動などの音源に拡張できると考えられる。

6.7.2 アラーム音識別システム

1 機種のみや複数機種が鳴っている状況から、できる限り見落としなく病院情報システムへと通知するシステムであることが望まれる。一方で、実臨床での通知システムを想定するにあたり、いくつかのアラーム音が鳴っている状況にも関わらず 0.other クラス（環境音）と識別することが問題となる。このため臨床応用への評価において Recall と混同行列から、0.other クラスの誤識別が重要と考えられる。特に人工呼吸器は生命維持管理装置であることから低換気アラーム等を見逃すとインシデントに繋がりがかねないため、Recall 100%で確実に拾い上げる必要がある。

今回、図 41 より 9.Cuff,Vent クラス、12.Inf,Cuff,Vent クラスから 15.Inf,Cuff,Syr,Vent クラス以外は Recall が 70%以上であった。加えて混同行列から、誤識別していたものは 4 機種に対して 3 機種、3 機種に対して 2 機種など、鳴っている機種のうち一部を欠いて誤識別する傾向がみられ、鳴っていない機種を判別する結果はほとんどなかった。一方で、混同行列のすべての値から 0.other クラスに誤識別していた割合は、8025 個（0.other は除く）の入力のうち 102 個が誤っており 1.3%であったことから、的確な識別はなされていないがアラート状況の検出としては高い性能を示したと考えられる。

クラス別の誤識別では、2.Cuff クラスが 8.0%と 4.Vent クラスが 8.6%であった。カフ圧コントローラ（Cuff）はスペクトログラムから他機種に比べて音圧が小さい事に起因していると考えられる。また人工呼吸器（Vent）は常に圧縮空気を作るブローの駆動音と間欠的な換気の排出音が含まれる。誤認識したスペクトログラムから環境音下に作動音が重畳した場合に 0.other クラスと誤識別していた。これは学習時の 0.other クラスに作動音を含

めていたため誤認識したと考えられる。ほかに 0.other クラスの Precision が 76% で、主に 3.Sry クラスを多く誤識別していた。加えて、13.Cuff,Syr,Vent から 15.Inf,Cuff,Syr,Vent クラスは 10.Syr,Vent クラスを多く誤識別しており、シリンジポンプ (Syr) が識別されやすい傾向であった。これはシリンジポンプのピーク周波数が他機種に比べて 3 つと特徴が少ないが、一定に鳴り続けるため特徴抽出されやすい事が原因と考えられる。

これらのことから、システムの AUC は 0.9 以上で検出しているが、アラーム音と雑音を高い性能で区別できた。機種 of 識別性能においては改良の余地は残るが、通知システムとして可能性が示された。

本評価実験ではアンダーサンプリングしたシミュレーションデータセットであるため、時系列に基づく Post processing を行っていない。今後はスムージングなどの Post processing についても考慮する必要がある。また、今回は 4 種類の識別システムでクラスは multi-label 法で検討した[93]。識別数が増えるとクラス数が指数関数的に増えるため、今後は combined single-label 法を用いて検討する。

6.8 まとめ

医療従事者がアラーム音を気付くことができないと、医療事故に繋がる可能性がある。病室でアラーム音を自動検知するために、録音した単一アラーム音から合成した重複アラーム音を用いて深層ニューラルネットワークによる識別器を作成した。結果として、重複アラーム音における識別性能はシミュレーション実験において従来の MFB より CFB が優位に識別できた。加えて、混同行列の結果から環境音の誤識別率が低かったことから、臨床応用できる可能性がある。

したがって、病院情報システムと接続されていない、または接続できない医療機器に対してアラーム音から医療機器のアラート状況の自動認識することによって、データ駆動型病院情報システムに詳細なデータの収集が可能となる。これによってアラート状況の通知システムに応用することで安全性の担保に繋がると考えられる。

第7章 看護記録からの危険行動の自動監査

看護師は患者の機微を捉えて看護記録に叙述的に記載している。このことから患者の行動を予測できる可能性があり、これを予測することができれば看護記録の監査業務の負荷を軽減できる可能性がある。本章では、自然言語処理技術および深層学習を用いて叙述的に記載された看護記録から危険行動について自動監査を検討する。

7.1 背景

病院情報システムの普及に伴い、多くの病院でいわゆる診療記録についても電子的に記録する電子カルテシステムの普及が進みつつある。電子カルテシステムの普及によって診療記録・看護記録は即時に共有されるようになり、多職種での情報共有に基づいた医療サービスの質の向上が期待されている。特に、「看護記録」については、日本看護協会の看護業務基準における定義として「看護実践の一連の過程を記録したものであり、この記録は看護師の思考と行為を示すもの」とされており、自身が実践したことや患者の個別性にあわせたケア内容や手順、治療やケア実施時とその後の反応などの看護実践の結果について詳細に記載する[107]。そのため看護記録は患者の状態や経過を把握することに用いられており、患者管理に関わる医療従事者にとって重要である。しかし、看護記録そのものの多くは叙述的に記載されており、記録内容そのものを確認または監査するためには、基本的には人間の目で閲覧する必要がある。特に、監査については患者に提供された治療やケアの効果を分析・評価する際だけでなく、転院時の看護サマリー（看護要約）の記載、必要度の評価および監査、転倒転落などリスクの分析・評価、看護記録の監査などがあり、これらの監査業務は看護サービスの質の担保に対しても極めて重要であると考えられている[108]。

看護記録の監査は、看護記録と看護の質向上を目的に施設内で設定した記録の記載基準に則って看護実践の一連の過程が記録されているか、その記録は質・量ともに十分であるかを監査することとある[25]。基本的には各施設で基準を決定し、その内容を監査することが求められるが、一方で監査自体のあり方については監査票の作成方法や、監査者の育成方法などの多くが検討されている[109,110]。その他にも、例えば医療・看護必要度の評価において、看護師が入力すべきチェック項目と実際のカルテ記載などが対応しているかを監査する必要がある場合もある[111]。特に、医療・看護必要度評価における「患者の危険行動」については、2018年までは、医療・看護必要度の患者状態の把握であるB項目における評価項目の1つであり、この項目チェックに対して看護記録における「根拠となる記録」が求められてきた[112]。そのため、看護記録の監査が必要となり、看護師や医事の担当者の膨大な労力が割かれてきた[113]。一方で、実際に「患者の危険行動」が見受けら

れるにも関わらず、医療・看護必要度のチェックを行っていない場合、各患者の入院料や施設基準値に影響があるため、実際の病院収入の減収に繋がることが懸念される。すなわち、医療制度側の立場や病院経営の立場においても、看護記録の内容について、正確に監査することが重要であるといえる[112]。

一方で、自然言語処理や機械学習技術の発展により、フリーテキストのような叙述的なデータについても人間のようなタスクをこなすことが可能になりつつある。そのため、我々の研究チームでは、フリーテキストで記載された診療記録に対して、自動的な監査を行う研究を進めてきた[114]。例えば、我々はこれまで診療情報管理士のカルテ監査業務、特にインフォームド・コンセントの内容が適切かどうかを自動的に判断することを目的とし、出現単語に基づくベクトル空間モデルを構築し、サポートベクターマシンを用いて教師あり学習に基づく判別器を構築した。その結果、監査上「記載の質」に問題があると考えられるかどうかの判定においては、F1-value が 0.75 程度の性能であった[114]。しかし、2018年に発表された Bidirectional Encoder Representations from Transformers (BERT) 技術[115]は、いくつかの自然言語処理タスクにおいて最高の成績をおさめており、BERTを用いた自然言語処理研究が進んでいる。また、BERT 自体は膨大なテキストデータによって事前学習を行い、その上でタスクの目的に合致したデータによってファインチューニングを行う仕組みである。これまでは、事前学習のデータとして Wikipedia 等のウェブ上のコーパスが利用されてきたが、日本語の医療データに特化した事前学習したモデルが利用可能になった。これらのことから、看護記録に対して BERT モデルを適用し判別器を構築することで、実際に監査業務を軽減できる可能性がある。

7.2 目的

本研究では、自然言語で記載された看護記録から、自然言語処理技術および機械学習技術を用いて自動監査を行うことを試みる。具体的には、医療・看護必要度においても監査の対象となった危険行動のうち、「チューブ類の自己抜去」について、看護記録においてこれらの記述を自動的に判別可能かについて検証し、監査業務の軽減がどれくらい可能かについて検討する。

7.3 方法

看護記録における「患者の危険行動あるいは放置すれば危険行動に至る」について、BERT を用いて自動的に"判別"可能かについて検討した。本研究における判別対象の危険行動とは、医療・看護必要度 B 項目における「治療・検査中のチューブ類・点滴ルート等の自己抜去、転倒・転落、自傷行為」のうち、「チューブ類・点滴ルート等の自己抜去」

とした。具体的に評価する患者の状態とは、血管内に挿入するライン、気道内へ挿入するチューブ、栄養チューブ、尿道カテーテル、各種ドレーン類、硬膜外カテーテルなどを意識的、無意識的にかかわらず患者自身が抜去する、またはしようとする状態の患者に関する記載があるかどうかについて、BERT モデルを用いて自動監査を行うことが可能かを検証した。

7.3.1 対象データ

本研究は、大阪府内にある急性期病院 A における、看護師が記録した経過記録を対象とする。A 病院では、電子カルテシステムが導入されており、経過記録自体は SOAP 形式で記載されており、2018 年 3 月に看護師・助産師が記録した経過記録は、465,803 レコードであった。患者の危険行動については、SOAP 記載においては O 欄に記載されている。看護記録の SOAP データの実際を図 42 に示す。図 1 の場合、O 欄の上段は選択式の観察項目から自動転記される記録であり、下段は看護師が入力した文章の記録となる。今回、O 欄におけるオーダ実施情報、観察項目の自動転記、定型文を使用した記載、数値や単語のみのレコードを除いた 37,953 レコードを対象とした。

これらの 37,953 レコードに対して、実際に A 病院にて危険行動に関する記載が含まれているかについて、筆頭著者が看護必要度評価における研修に基づいて客観的に判定をおこなったデータを用いた。その結果、231 レコードが危険行動のうち自己抜去を示唆すると考えられた。これらのデータは個人が特定できないように加工した。

2018-03-02 16:45 入院 看護師 [redacted]	
S	そんなん知らん。
O	チューブ管理異常: +トラブルあり
	本人のもとを訪室するとEDチューブがベッドに全て抜けきって抜け落ちてるところを発見する。呼吸音異常なし。抜いたのか問うと上記発言あり。
A	EDチューブ自己抜去
P	本人に説明し終日モン装着していただく

Total 5 records

図 42: SOAP 記載による診療記録

7.3.2 BERT

BERT は Attention で構成される Encoder-Decoder モデルである Transformer の Multi-Head Attention を用いて双方向に学習を行う深層学習である[115]. BERT は Masked Language Model と Next Sentence Prediction の 2 つのタスクを, 大規模なコーパスで事前学習することで汎用言語モデルを構築する. Masked Language Model はランダムに選んだトークンをマスクし, マスクされたトークンを周りの文脈から予測する. Next Sentence Prediction はある 2 つの文を入力し連続する文か否かを判定する. その後, ファインチューニングによって目的のタスクに応じて最適化を図る. ファインチューニングとは, 事前学習されたモデルをタスクに応じた出力層に変更し, 事前学習で獲得した重みを初期値として, 目的タスクの教師データでモデルを再度学習する. このようにパラメータを最適化することで, 汎化性能をより向上させることが期待できる[115]. これらから自然言語処理の複数のタスクで高い性能を獲得している.

7.3.3 判別実験

本研究では, 東北大学が公開している一般分野のコーパスである Wikipedia 日本語版で事前学習を行った bert-base-japanese-v2 (以下, tohoku-BERT) を比較対照とし, 東京大学の医療 AI 開発学講座が公開している約 1 億 2000 万行のカルテ記録で事前学習を行った UTH-BERT-BASE-512-WWM (以下, UTH-BERT) を適用した[116].

7.3.3.1 前処理

先述した 37,953 レコードの看護記録データに対して, まず全角化, 空白の削除, 改行コードの削除を行った. テキストの分割処理に形態素解析エンジン MeCab[117]を用い, tohoku-BERT はシステム辞書に UniDic2.1.2, UTH-BERT はシステム辞書に NEologd[118–120], ユーザー辞書に万病辞書 (MANBYO_202106) [121]を適用してトークン化した. ここで BERT モデルに入力できる最大長は 512 トークンであるため, 最大長を超えるテキストは head+tail 法を適用し, 文頭から 128 トークン, 文末から 382 トークンを選出した[122]. 次に BERT は学習時に特殊トークンである [CLS], [SEP], [UNK], [PAD]を利用する. トークン化した文頭に [CLS], 文末に [SEP], 人名は不明を意味する [UNK]に置換した. トークン化されたテキストは, テキスト毎にトークン数が異なるが, 学習モデルの入力長が最大トークン以下のテキストは, [SEP]の後に [PAD]で埋めて入力長を整えた.

7.3.3.2 判別器

本研究の BERT モデルは 12 層の Multi Head Attention, 768 次元の中間層, 12 個の Attention Head から構成される. 本研究のタスクは 2 値分類であるため, ファインチューニングするにあたり tohoku-BERT は transformers ライブラリを用いてノード数 1 の出力層を追加した. UTH-BERT は NSP-Dense 層までを取得し, 出力層を追加した (図 43). これら BERT モデルの出力層は活性化関数 sigmoid を用いた全結合層とし, 0 から 1 の推定値を出力することとした.

環境構築としてハードウェア環境は, CPU Intel Core i7-6900K 3.20GHz, メモリ 96GB, GPU は GeForce RTX 3090 を 2 枚搭載したコンピュータを用いた. プログラミング言語は Python 3.8, 深層学習ライブラリは Keras 2.6.0 (バックエンドは Tensorflow 2.6.1), Keras BERT 0.8.0 を用いた.

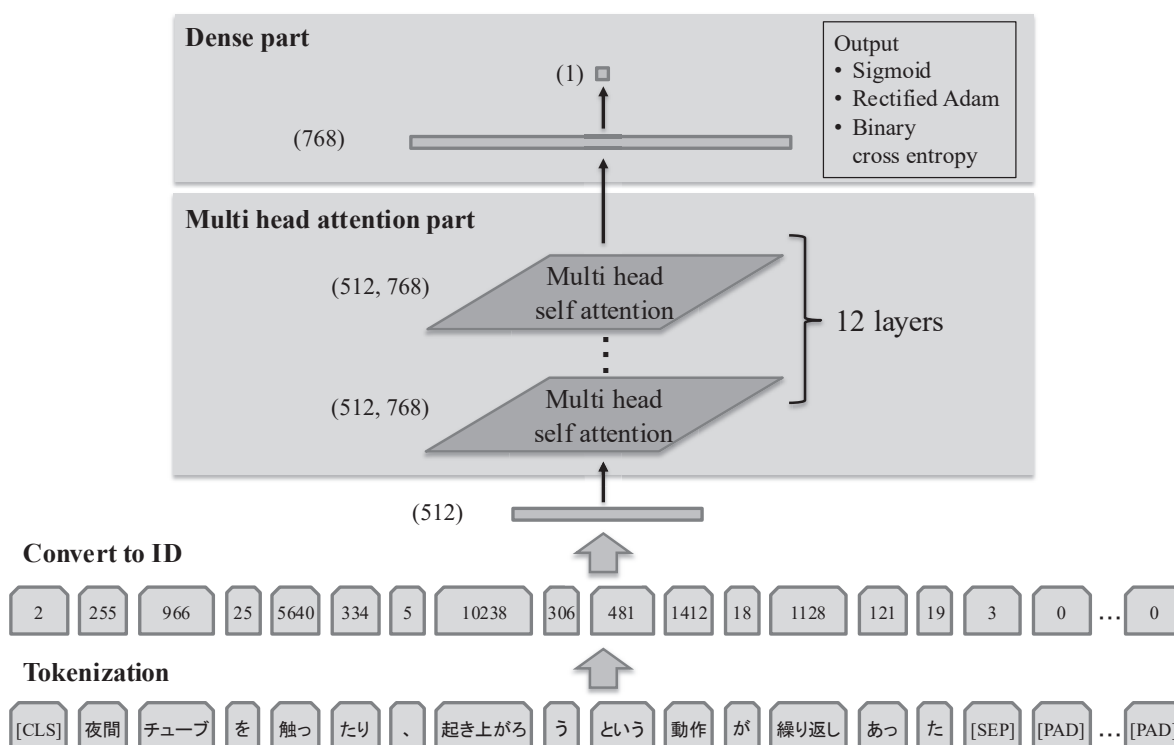


図 43: 提案モデルのアーキテクチャ

7.3.3.3 学習及び判別器の性能評価

本データセットは不均衡データであり，これらのデータを用いて構築する判別器の一般性の担保が重要となる．そのため，交差検証およびアンダーサンプリングを用いてできる限り一般性を担保する方法を検討した．概念図を図 44 に示す．

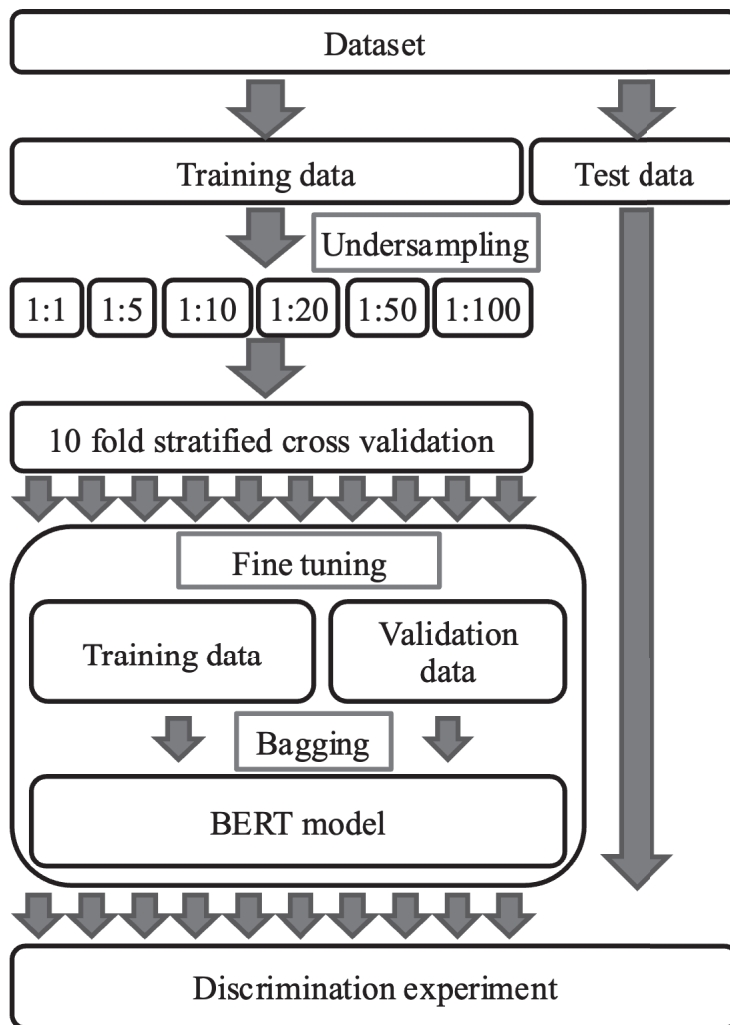


図 44: 実験フローの概念図

まず、①学習データと評価データを 4:1 {30,362 レコード (正例 185 レコード) : 7,591 レコード (正例 46 レコード)} で層化分割を行った。BERT における学習モデルの構築においてファインチューニングを行うには、学習データを訓練データと検証データに分けて学習を進める必要がある。また、学習データについては、判別器の一般性の担保、および頑強性を期待してアンダーサンプリングを行った。具体的には②任意の割合 (1:1, 1:5, 1:10, 1:10, 1:20, 1:50, 1:100) で分割した。この各分割の割合のデータを用いて BERT によってファインチューニングを行うが、この分割においてもデータの偏りによる判別性能にばらつきが出る可能性があるため、ファインチューニングのための訓練データおよび検証データについては、③層化 10 分割交差検証によって訓練データセットおよび検証データセットを作成した。よって、本実験では、任意の割合 (1:1, 1:5, 1:10, 1:10, 1:20, 1:50, 1:100) ごとに 10 個の判別器が作成され、評価することになる。

BERT による学習については、損失関数に `binary cross entropy loss`、最適化関数は `Rectified Adam` を適用し、`learning rate` 2.0×10^{-5} とした[123]。学習時のバッチサイズ 16、エポック数 20 とし、`validation loss` を監視した `Early stopping` で過剰適合を防ぐようにした[124]。判別器の判定結果はモデルから出力される推定値を閾値 0.5 でブール値に変換することとした。なおバッチサイズに基づいて分けられたミニバッチについては、正例データと負例データの割合を 1:1 とするためにバギング処理を行った[125]。バギング処理によって、正例データと負例データを偏らずに利用したファインチューニングができることを期待できる。

判別結果については、①の評価データ 7,591 レコードを用いて、②に示す任意の割合ごとに判別した 10 回について、評価指標として適合率 (`Precision`)、再現率 (`Recall`)、F1 (`F1 score`) を用いた。最後に交差検証で得られたそれぞれの指標を、相加平均して評価した。加えて判別器は看護記録を抽出して監査支援を想定するため、総合評価は高い再現率が求められる。

7.4 結果

方法で述べたアンダーサンプリングの正例・負例割合 (1:1, 1:5, 1:10, 1:10, 1:20, 1:50, 1:100) に対応した結果を、以下の表 17 に示す。比較対照の `tohoku-BERT` は `UTH-BERT` と同様に高い再現率であった。しかし、適合率は各アンダーサンプリングにおいて 0.092 から 0.144 の差であったため、F1 は `UTH-BERT` の方が 0.115 から 0.135 高く、`UTH-BERT` の 1:100 が 0.713 で最も高値であった。アンダーサンプリングの割合を指数的に増加させると適合率も向上し、かつ再現率は高値を保っていたため、結果として F1 も向上した。

表 17: アンダーサンプリングごとの言語モデルによる評価比較

Positive examples	166	166	166	166	166	166	
Negative examples	166	830	1660	3320	8300	16600	
Negative / examples	1	5	10	20	50	100	
tohoku-BERT	Accuracy	0.874	0.967	0.976	0.983	0.987	0.990
	Precision	0.066	0.179	0.220	0.291	0.373	0.428
	Recall	0.920	0.971	0.971	0.966	0.960	0.956
	F1	0.120	0.298	0.355	0.441	0.521	0.578
UTH-BERT	Accuracy	0.972	0.984	0.989	0.990	0.994	0.995
	Precision	0.173	0.271	0.347	0.391	0.501	0.572
	Recall	0.939	0.969	0.968	0.968	0.954	0.952
	F1	0.291	0.423	0.511	0.556	0.655	0.713

7.5 考察

今回対象とした、看護記録における「患者の危険行動」について、特に「治療・検査中のチューブ類・点滴ルート等の自己抜去」に関連する記述に対して、一般分野のコーパスで事前学習した BERT モデルと医療テキストで事前学習した BERT モデルを用いて教師あり学習を利用した判別実験を行った。また、判別性能の一般性、および頑強性を検証するために、交差検証を前提とした上で、BERT モデルにおけるファインチューニングにおけるバギングの適用を検討した。特に、アンダーサンプリングの割合がどのように判別性能に影響を与えるのかについて、検証を行った。

結果は、UTH-BERT は tohoku-BERT より適合率が高い事により F1 も高かった。本実験の看護記録も医療テキストであるため、ドメイン特化の BERT モデルが判別性能に寄与したと考えられる。またアンダーサンプリングの正例・負例割合 (1:1, 1:5, 1:10, 1:10, 1:20, 1:50, 1:100) によって、UTH-BERT における F1 は 0.291 (正例 : 負例 = 1:1) から、0.713 (正例 : 負例 = 1:100) に至るまで大きな変化が見られたが、各正例・負例割合における 10 回の学習結果に基づく判定においてばらつきはほとんど見られず、一般性のある結果が得られたと言える。

そもそもの本研究の動機としては、監査担当看護師の膨大な手間を減らしたいというも

のであった。今回の監査においては、背景で述べたとおりに 2 つの観点があり、1 つ目は「医療・看護必要度評価において、危険行動があるとチェックがされていた場合、根拠となる記載があるか」であり、2 つ目は「危険行動と判定できる看護記録があるにも関わらず、医療・看護必要度評価に反映されていない記載はないか」である。これらは、両方ともに医療・看護必要度の評価制度の根幹をなすものであり、また各病院においては診療報酬に大きく影響する。例えば、前者の場合については根拠がないのに危険行動にチェックが入っているということで、故意に重症患者を多く評価していると審査されかねず、後者は実際に危険行動を伴う重症患者を診療しているにも関わらず、チェックができていないということで、病院の減収につながっている可能性が高い。

本研究の結果は、正例・負例割合が 1:100 の UTH-BERT を用いた学習モデルでは、F1 0.713 という性能もさることながら、再現率 0.952、適合率 0.572 と再現率が高かった。本研究で対象としたデータで考えると、本来監査すべきカルテ記載は 37,953 レコードであり、その中に存在する危険行動を記載した 231 レコードを抽出するタスクである。これまでは全数 (37,953 レコード) をチェックする必要があったが、今回の判別器の再現率と適合率から 384 レコードが監査対象として抽出され、その中には 220 レコードの危険行動が記載されたレコードが含まれる。すなわち、危険行動を記載した 231 レコードから判別された 220 レコードを減じた 11 レコード (正例の 4.7%) の見逃しが起こりうることになる。

今回構築した判別器を用いて実際に監査担当看護師が監査を行う場合は、看護師が危険行動ありとした患者の診療録と、判別器が自己抜去ありと判定したレコードの和集合が監査対象となる。その場合、看護師のチェックで陽性 (危険行動あり) かつ判別器で陽性 (自己抜去あり) の患者は確認を省いてよく、看護師のチェックが陽性かつ判別器が陰性のレコードは誤判定疑い、看護師のチェックが陰性で判別器が陽性のレコードは見落とし疑いとして監査することになる。すなわち、今回構築した判別器を用いて監査担当看護師が監査する場合、判別器が抽出した 384 レコードと看護師が危険行動ありとしたレコードを監査するだけでよく、手間が大きく削減できることが期待される。

具体的な判定の結果をしてみると、「人工呼吸器装着中、多数デバイス挿入中。両上肢抑制帯、抑制ミトンを外すと手を顔の方に持っていく様子あり。」「挿管チューブの違和感訴えられ手をごそごそされる。」といったように、表現が曖昧でヒトでも判別しづらいと考えられるような記述を危険行動として認識できていなかった反面、「ルート類を気にせず身まわりの作業をしている」「Aライン・末梢・胃管・バルン挿入中。指示動作あいまいであり、チューブ類の認識なし。」といった、直接的に危険行動と理解できるものについても含まれていた。また、1:100 のアンダーサンプリングにおいて、上記のように正例を負例と判断した偽陰性となった記述は 44 レコード (テストデータにおける正例は全部で 46 レコード) であることを考えると、学習データに含まれる正例データによって抽出できる危険行動の記述が異なっている可能性がある。そのため、より頑強な判別器を構築

するためにも、より多くの危険行動の記述を示す正例データを収集する必要があると考えられる。

本研究の限界として、医療・看護必要度 B 項目危険行動における「治療・検査中のチューブ類・点滴ルート等の自己抜去」のみを検討し、「転倒・転落，自傷行為」は扱っていないためさらなる検討が必要である。また、不均衡データであり正例が極端に少ないため多施設で正例データを取る必要がある。これらを踏まえた上で、作成した判別器を実際に病院情報システム上に実装することで、危険行動の記載があった場合に担当者に通知するシステムの構築を検討したいと考えている。

7.6 まとめ

看護記録は診療情報の一つとして多職種に渡る重要な情報源であるため、看護記録が正確に記載されていることは非常に重要であり、多くの病院では看護記録の監査を行っている。看護記録における「患者の危険行動」について、BERT および深層学習を用いて自動的に抽出可能かについて検討した。結果として、作成した判別器の再現率は 0.952 であり、F1 は 0.713 であった。看護記録の監査業務はチェック漏れも含めたすべての記録を監査することは膨大な手間がかかる。この判別器を用いることによって、ごく少数の監査漏れが発生する可能性はあるものの、再現率が高いことから危険行動における監査業務に対して実際に医療現場での適用を具体的に考えられるものであった。

したがって、深層学習に基づく本判別器は蓄積された看護記録から情報を抽出することによって、これまで実行できなかった全レコードの監査に対する実行可能性を示し、看護業務を合理化できる可能性が明らかとなった。

第8章 おわりに

医学とは人の心身の健康を維持もしくは増進させ、病気を治すまたは癒すための学問であり、加えて医学の実践あるいは社会適用として医療が発展してきた。我が国では文明開化した明治時代から西洋医療の導入によって近代的な病院が始まり、歴史を踏まえると病院とは医学を実践する医療を社会的に適用させた場であると述べた。近代的な医療サービスの提供は敗戦と GHQ の介入により診療報酬を始めとした医療制度によって始まった。しかし、日本の経済成長が終焉したことによって、社会保障ばかりに国費を投入することができなくなり、オイルショックを契機に医療費抑制への方向転換することとなった。

現在、日本の医療提供体制と医療保険制度は、国民皆保険制度が施行されて以来、何とか破綻せずに機能しているが、診断・治療技術が常に高度化および複雑化する医療と社会的使命の変化に対応した包括的な医療サービスを提供するためには、病院はもはやこれまでの運用では維持が困難である。

これまで、病院は支払基金への報酬請求を始めとした医療制度による複雑化した病院の業務を効率化するために、オーダリングシステム、電子カルテ、部門ごとの業務支援システムを統合する病院情報システムが導入された。これによって、病院の業務の軽減を目的として情報伝達の自動化と診療記録の検索性の向上が図られ、医療従事者は様々な場面でデータを入力することが一般化した。それでも、医療従事者は業務の膨大化と煩雑化によって多忙であるため、業務をさらに効率化しなければ医療の安全と質を担保しつつ高度化し続ける医療に対応できない。このためには、病院の業務を効率化するために病院情報システムが高度化する事によって、病院機能を高度化しなければならない。

一方で、深層学習によって AI は大規模なデータから特徴を学習する事が可能となったが、推論結果の因果関係を説明することが困難であるため、診断や治療といった医療の自動化を目的とした利用はできない。しかし、高度化する医療と社会的使命の変化に対応した医療サービスを提供するためには、複雑化した病院の業務を合理化または自動化するにあたって AI の支援は不可欠と考えられる。また IoT 技術の発展から様々なデータを蓄積するビッグデータが生まれ、データ駆動型社会が現実のものとなりつつあり、病院においてはスマートホスピタルという概念から IoT 技術と AI による業務の最適化が試みられている。従って、病院情報システムが医療現場の安全性の担保と医療の質の向上を図るための高度化は、スマートホスピタルの概念を基にデータ駆動志向を加えることによって、データ駆動志向で動的に AI が支援を行うデータ駆動型病院情報システムで達成できると考えられる。これまでのスマートホスピタルの概念においては、医学的な診療データやゲノムデータ等を用いることで、帰納的な医学的知見を得ることに主眼が置かれており、医療現場の安全性の担保と、医療の質の向上が社会的に求められるなかで、データ駆動志向を踏ま

えた病院の業務の効率化についてはあまり検討できていなかった。

よって本論文では、データ駆動型社会における病院の在り方を検討することを目的として、データ駆動型病院情報システムを検討した。その中でも、1. データ駆動志向のためのIoT やセンサデータを用いたデータ収集および機械学習の利用による安全性の担保について、2. 蓄積されたデータおよび機械学習を用いたデータ駆動志向の業務の合理化について検討した。そこで、1.に対する検討として、自動的に医療機器の異常状態を通知することで安全性を向上できる可能性がある。このために、病院情報システムと接続されていない、または接続できない医療機器に対してアラーム音から医療機器のアラート状況の収集および自動認識を検討した。結果として、アラーム音から医療機器のアラート状況の自動認識することによって、データ駆動型病院情報システムに詳細なデータの収集が可能となることが明らかとなった。これによってアラート状況の通知システムに応用することで安全性の担保に繋がると考えられる。次に2.に対する検討として、看護師は患者の機微を捉えて看護記録に叙述的に記載しているため、看護記録から患者行動を予測すること看護記録の監査業務の負荷を軽減できる可能性がある。結果として、深層学習に基づく判別器を用いることによって、ごく少数の漏れが発生する可能性はあるものの、再現率が高いことから危険行動の自動抽出に対して実際に医療現場での適用を具体的に考えられるものであった。したがって、蓄積されたデータである看護記録から自然言語処理技術および深層学習を用いることで、これまで実行できなかった全レコードの監査に対する実行可能性を示し、看護業務を合理化できる可能性が明らかとなった。

本論文において、病院・医療制度・医療システムのこれまでの変遷を踏まえ、現状の病院情報システムとAIから、データ駆動型病院情報システムに必要となるデータの収集とデータの蓄積・利用について検討した。これらの検討から、病院はIoT 技術によって収集したデータからAIで抽出した情報を医療従事者に提供することによって、データ駆動志向で複雑化した病院の業務を合理化できることが明らかとなった。したがって、包括的な医療サービスを提供しつつ、医療現場の安全性の担保と医療の質の向上が社会的に求められるなかで、医療従事者の負担の増加を抑えつつ病院機能は高度化できると考えられる。これは今後のデータ駆動型社会を医療に適用した際に起こる病院の在り方に対して確かな指針を与えるものと思われる。

謝辞

本研究の機会を与えてくださり，終始熱心なご指導ご鞭撻を賜りました兵庫県立大学大学院応用情報科学研究科の竹村匡正教授に，心より厚くお礼申し上げます．また，本論文をまとめるにあたり，ご助言をいただくとともにご指導いただきました，水野（松本）由子教授並びに原口亮教授に，深く御礼申し上げます．

機械学習手法，深層学習のネットワーク設計，ならびに貴重な御意見を頂きました近畿大学情報学部の杉山治准教授と京都大学大学院医学研究科の小島諒介講師に深く感謝いたします．

看護記録について，監査業務の実態，ならびに貴重なご助言をいただきました大阪警察病院看護部の阪本恭子様にも厚くお礼を申し上げます．

本研究の遂行にあたってご協力を承りました兵庫県立大学大学院応用情報科学研究科の諸先生方，竹村研究室の皆様に，心より感謝いたします．本当にありがとうございました．

最後に，神戸市立西神戸医療センター臨床工学室の皆様に医療機器の利用に御協力を頂き貴重なデータを得ることでできました．また多大なるご助言もいただき心より御礼申し上げます．

参考文献

- [1] 高岡詠子: シャノンの情報理論入門 —価値ある情報を高速に、正確に送る— [Internet]. 講談社. Available from:
<https://elib.maruzen.co.jp/elib/html/BookDetail/Id/3000028196/ISBN:978-4-06-257795-3>
- [2] 大澤忠: 内科診断学を変えた画像技術. 日本内科学会雑誌. **91**(1), pp.163–167, 2002.
- [3] 日本医療情報学会医療情報技師育成部会: 医療情報 医療情報システム編, 第6版. 篠原出版新社, 2020. ISBN:978-4-86705-801-5
- [4] 経済産業省: 中間取りまとめ～CPSによるデータ駆動型社会の到来を見据えた変革～ [Internet]. [accessed 2022 Jul 10]. Available from:
https://www.meti.go.jp/shingikai/sankoshin/shomu_ryutsu/joho_keizai/20150521_report.html
- [5] 猪飼周平: 病院の世紀の理論. 東京: 有斐閣, 2010. ISBN:978-4-641-17359-0
- [6] U.S. Department of Health and Human Services: Health, United States, 2005 with Chartbook on Trends in the Health of Americans. p.344.
- [7] 厚生労働省: 医療施設の動向. 厚生労働白書, p.41.
- [8] 厚生労働省: 平成30年（2018年）医師・歯科医師・薬剤師調査の概況 [Internet]. [accessed 2022 Apr 30]. Available from: <https://www.mhlw.go.jp/toukei/saikin/hw/ishi/18/>
- [9] 厚生労働省: 令和元(2019)年医療施設（動態）調査・病院報告の概況 [Internet]. [accessed 2022 Apr 30]. Available from: <https://www.mhlw.go.jp/toukei/saikin/hw/iryosd/19/>
- [10] 厚生労働協会: 地域の医療と介護を知るために—わかりやすい医療と介護の制度・政策— 第2回 日本の医療制度はイギリスやアメリカと違う?. 厚生指標. **63**(8), pp.41–44, 2016.
- [11] 日本医師会: 国民皆保険制度の歴史 [Internet]. 国民皆保険制度の歴史 | 世界に誇れる日本の医療保険制度 | 日本医師会. [accessed 2022 Apr 30]. Available from:
<https://www.med.or.jp/people/info/kaifo/history/>
- [12] 厚生労働省: 社会保障とは何か [Internet]. [accessed 2022 Aug 10]. Available from:
https://www.mhlw.go.jp/stf/newpage_21479.html

- [13] 厚生労働省: 戦後社会保障制度史 [Internet]. [accessed 2022 Apr 30]. Available from:
<https://www.mhlw.go.jp/seisaku/21.html>
- [14] 日本貿易振興機構: 米国における医療保険制度の概要 [Internet]. 米国における医療保険制度の概要 (2021年6月) 調査レポート - 国・地域別に見る. 2021 [accessed 2022 Apr 30]. Available from: <https://www.jetro.go.jp/world/reports/2021/01/01168598c658e4b0.html>
- [15] 厚生労働省: 医療保障制度に関する国際関係資料について [Internet]. [accessed 2022 Apr 30]. Available from:
https://www.mhlw.go.jp/stf/seisakunitsuite/bunya/kenkou_iryuu/iryuuhoken/iryuuhoken11/index.html
- [16] 福永肇: 日本病院史. 東京: Pilar Press, 2014. ISBN:978-4-86194-073-6
- [17] 今村栄一: 病院管理の理論と実際. 東京: 医学書院, 1968.
- [18] 菅谷章: 日本の病院: その歩みと問題点. 東京: 中央公論社, 1981. ISBN:4-12-100600-3
- [19] 厚生労働省: 平成26年度診療報酬改定について [Internet]. [accessed 2022 Aug 10]. Available from: <https://www.mhlw.go.jp/stf/seisakunitsuite/bunya/0000032996.html>
- [20] 野末睦, 中村恵二: 改革・改善のための戦略デザイン 病院DX. 秀和システム, 2021.
- [21] 厚生労働省: 医療分野の情報化の現状 [Internet]. [accessed 2022 Apr 30]. Available from:
https://www.mhlw.go.jp/stf/seisakunitsuite/bunya/kenkou_iryuu/iryuu/johoka/index.html
- [22] 黒田知宏: 記録情報の管理 [Internet]. 電子情報通信学会知識ベース | 4編 医療情報システム. 2011. [accessed 2022 Apr 30]. Available from: https://www.ieice-hbkb.org/portal/doc_495.html
- [23] 厚生労働省: 診療情報の提供等に関する指針 [Internet]. 2004. [accessed 2022 Apr 30]. Available from: <https://www.mhlw.go.jp/shingi/2004/06/s0623-15m.html>
- [24] 厚生労働省: 診療録等の保存を行う場所について〔医療法〕 [Internet]. 医政発第329003号保発第329001号Mar 29, 2002. Available from:
https://www.mhlw.go.jp/web/t_doc?dataId=00ta6739&dataType=1&pageNo=1
- [25] 日本看護協会: 看護記録に関する指針 [Internet]. 港北出版印刷株式会社, 2018. [accessed 2022 Apr 30]. Available from:
https://www.nurse.or.jp/home/publication/pdf/guideline/nursing_record.pdf

- [26] 久保田博南: 医療機器の歴史: 最先端技術のルーツを探る. 真興交易医書出版部, 2003. ISBN:978-4-88003-702-8
- [27] 医療法 [Internet]. 第205号Jul 30, 1948. Available from: https://www.mhlw.go.jp/web/t_doc?dataId=80090000&dataType=0&pageNo=1
- [28] 厚生省: 医療法施行規則 [Internet]. 厚生省令第50号Nov 5, 1948. Available from: https://www.mhlw.go.jp/web/t_doc?dataId=80092000&dataType=0&pageNo=1
- [29] 厚生労働省: 医療機器に係る安全管理のための体制確保に係る運用上の留意点について [Internet]. 医政指発第0330001号医政研発第0330018号Mar 30, 2007. Available from: <http://hcea.umin.ac.jp/files/pdf/070330unyoutuuti.pdf>
- [30] 医薬品、医療機器等の品質、有効性及び安全性の確保等に関する法律 [Internet]. 法律第145号1960. Available from: <https://elaws.e-gov.go.jp/document?lawid=335AC0000000145>
- [31] 薬事医療法制研究会: 早わかり改正薬事法のポイント: 医薬品医療機器等法・医薬品ネット販売関連法のすべてがわかる. じほう, 2014. ISBN:978-4-8407-4555-0
- [32] 西謙一: 医療機器管理ソフトの現状と標準化の必要性. 医科器械学 Jpn J Med Instrum 日本医療機器学会. **77**(7), pp.408–415, 2007.
- [33] 酒井順哉: 手術部におけるITを用いた医療機器保守管理. Clin Eng. **20**(2), pp.120–124, 2009.
- [34] ダンクネット: バイタルデータ送信システムACSYS-Gateway [Internet]. バイタルデータ送信システム ACSYS-Gatew 株式会社ダンクネット-重症部門システムのエキスパート. [accessed 2022 Apr 30]. Available from: <https://www.danknet.co.jp/product/acsysgateway/>
- [35] 多賀谷正志, 川本俊治, 石崎光理, 市川峻介, 半田宏樹, 入船竜史, 小田洋介, 原和信, 阪田光彦, 焼廣益秀, 泉谷裕則: 使用患者登録機能を有する医療機器管理システムの導入効果. 医療情報学. **33**(3), pp.171–179, 2013.
- [36] 吉原博幸: 千年カルテプロジェクト: 本格的日本版ehrと医療データの2次利用に向けて. 情報管理. **60**(11), pp.767–778, 2018.
- [37] Oderkirk J: Readiness of electronic health record systems to contribute to national health information and research [Internet]. Paris: OECD2017 Dec. Available from: <https://www.oecd-ilibrary.org/social-issues-migration-health/readiness-of-electronic-health->

record-systems-to-contribute-to-national-health-information-and-research_9e296bf3-en

- [38] 原祐一: 医療情報のデジタル化における現状と課題 — 日本における経緯と国際比較 — | 日本医師会総合政策研究機構 [Internet]. 2022. [accessed 2022 Jul 10]. Available from: <https://www.jmari.med.or.jp/result/report/post-3397/>
- [39] 文部科学省, 厚生労働省, 経済産業省: 人を対象とする生命科学・医学系研究に関する倫理指針 [Internet]. [accessed 2022 Jul 10]. Available from: <https://www.mhlw.go.jp/content/000909926.pdf>
- [40] 文部科学省, 厚生労働省, 経済産業省: 人を対象とする生命科学・医学系研究に関する倫理指針ガイダンス [Internet]. [accessed 2022 Jul 10]. Available from: <https://www.mhlw.go.jp/content/000946358.pdf>
- [41] 中島秀之, 浅田稔, 橋田浩一, 松原仁, 山川宏, 栗原聡, 松尾豊: AI事典 [Internet], 第3版. 近代科学社, 2019. Available from: <https://books.google.co.jp/books?id=rkvCDwAAQBAJISBN:978-4-7649-0604-4>
- [42] 馬場口登, 山田誠二: 人工知能の基礎 [Internet], 第2版. オーム社, 2015. Available from: <https://books.google.co.jp/books?id=7vtXjwEACAAJISBN:978-4-274-83207-9>
- [43] Rosenblatt F: The perceptron: A probabilistic model for information storage and organization in the brain. *Psychol Rev*, US: American Psychological Association. **65**(6), pp.386–408, 1958.
- [44] 松尾豊: ディープラーニングで日本のモノづくりは復権する [Internet]. ダイヤモンド社, 2018. Available from: <https://books.google.co.jp/books?id=GhJNDwAAQBAJ>
- [45] Krizhevsky A, Sutskever I, Hinton GE: ImageNet classification with deep convolutional neural networks. *Commun ACM*. **60**(6), pp.84–90, 2017.
- [46] 松田雄馬: 人工知能の哲学: 生命から紐解く知能の謎. 東海大学出版部, 2017. ISBN:978-4-486-02141-4
- [47] 福島邦彦, 大串健吾, 斎藤秀昭: 視聴覚情報処理. 森北出版, 2001. ISBN:978-4-627-80691-7
- [48] 西森秀稔: スピングラス理論と情報統計力学. 岩波書店, 1999. ISBN:978-4-00-007414-8
- [49] モノワイヤレス: IoTとは? [Internet]. [accessed 2022 Jul 10]. Available from: https://www.mono-wireless.com/jp/tech/Internet_of_Things.html

- [50] 電子情報通信学会: 知識の森4群5編3章センサーネットワーク [Internet]. [accessed 2022 Jul 10]. Available from: https://www.ieice-hbkb.org/portal/doc_485.html
- [51] 総務省: 令和3年版 情報通信白書 | IoTデバイスの急速な普及 [Internet]. [accessed 2021 Dec 29]. Available from: <https://www.soumu.go.jp/johotsusintokei/whitepaper/ja/r03/html/nd105220.html>
- [52] 太田洋, 本橋信也, 河野達也, 鶴見利章: NOSQLの基礎知識 [Internet]. 東京: リックテレコム, 2012. Available from: <https://m.kulib.kyoto-u.ac.jp/webopac/BB04291425ISBN:978-4-89797-887-1>
- [53] 総務省: ビッグデータとは何か [Internet]. [accessed 2022 Jul 10]. Available from: <https://www.soumu.go.jp/johotsusintokei/whitepaper/ja/h24/html/nc121410.html>
- [54] 巢籠悠輔: 詳解ディープラーニング第2版, 第2版. マイナビ出版, 2019.
- [55] 我妻幸長: はじめてのディープラーニング2: Pythonで実装する再帰型ニューラルネットワーク, VAE, GAN. Sbクリエイティブ, 2020. ISBN:978-4-8156-0558-2
- [56] 斎藤康毅: ゼロから作るDeep Learning 3 -フレームワーク編. オライリージャパン, 2020. ISBN:978-4-87311-906-9
- [57] LeCun Y, Bengio Y, Hinton G: Deep learning. Nature Nature Publishing Group. **521**(7553), pp.436–444, 2015.
- [58] Shorten C, Khoshgoftaar TM: A survey on Image Data Augmentation for Deep Learning. J Big Data. **6**(1), p.60, 2019.
- [59] Wei J, Zou K: EDA: Easy Data Augmentation Techniques for Boosting Performance on Text Classification Tasks. ArXiv190111196 Cs [Internet], 2019. [accessed 2022 Apr 30]. Available from: <http://arxiv.org/abs/1901.11196>
- [60] Pascanu R, Mikolov T, Bengio Y: On the difficulty of training recurrent neural networks. In: Dasgupta S, McAllester D, editors. Proc 30th Int Conf Mach Learn [Internet], Atlanta, Georgia, USA: PMLR, pp.1310–1318, 2013. Available from: <https://proceedings.mlr.press/v28/pascanu13.html>
- [61] Hochreiter S, Schmidhuber J: Long Short-Term Memory. Neural Comput. **9**(8), pp.1735–1780, 1997.

- [62] Gers FA, Schmidhuber J, Cummins F: Learning to Forget: Continual Prediction with LSTM. *Neural Comput.* **12**(10), pp.2451–2471, 2000.
- [63] Gers FA, Schmidhuber J: Recurrent nets that time and count. *Proc IEEE-INNS-ENNS Int Jt Conf Neural Netw IJCNN 2000 Neural Comput New Chall Perspect New Millenn*, pp.189–194 vol.3, 2000.
- [64] Cho K, van Merriënboer B, Gulcehre C, Bahdanau D, Bougares F, Schwenk H, Bengio Y: Learning Phrase Representations using RNN Encoder-Decoder for Statistical Machine Translation. *ArXiv14061078 Cs Stat [Internet]*, 2014. [accessed 2021 Dec 4]. Available from: <http://arxiv.org/abs/1406.1078>
- [65] Sutskever I, Vinyals O, Le QV: Sequence to Sequence Learning with Neural Networks. In: Ghahramani Z, Welling M, Cortes C, Lawrence N, Weinberger KQ, editors. *Adv Neural Inf Process Syst [Internet]* Curran Associates, Inc. 2014. Available from: <https://proceedings.neurips.cc/paper/2014/file/a14ac55a4f27472c5d894ec1c3c743d2-Paper.pdf>
- [66] Bahdanau D, Cho K, Bengio Y: Neural Machine Translation by Jointly Learning to Align and Translate. *ArXiv14090473 Cs Stat [Internet]*, 2016. [accessed 2021 Dec 4]. Available from: <http://arxiv.org/abs/1409.0473>
- [67] 高島遼一: Pythonで学ぶ音声認識 機械学習実践シリーズ [Internet]. インプレス, 2021. Available from: <https://books.google.co.jp/books?id=WhwuEAAAQBAJISBN:978-4-295-01138-5>
- [68] Vaswani A, Shazeer N, Parmar N, Uszkoreit J, Jones L, Gomez AN, Kaiser Ł, Polosukhin I: Attention is All you Need. *Neural Inf Process Syst*, pp.6000–6010, 2017.
- [69] DeepSquare: 自然言語処理の必須知識 Transformer を徹底解説！ [Internet]. 2020. [accessed 2022 May 2]. Available from: <https://deepsquare.jp/2020/07/transformer/>
- [70] Dosovitskiy A, Beyer L, Kolesnikov A, Weissenborn D, Zhai X, Unterthiner T, Dehghani M, Minderer M, Heigold G, Gelly S, Uszkoreit J, Houshy N: An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale. *ArXiv201011929 Cs [Internet]*, 2020. [accessed 2022 May 2]. Available from: <http://arxiv.org/abs/2010.11929>
- [71] Gulati A, Qin J, Chiu C-C, Parmar N, Zhang Y, Yu J, Han W, Wang S, Zhang Z, Wu Y, Pang R: Conformer: Convolution-augmented Transformer for Speech Recognition. *Interspeech*

- 2020 [Internet]ISCA , pp.5036–5040, 2020. [accessed 2022 May 2]. Available from:
https://www.isca-speech.org/archive/interspeech_2020/gulati20_interspeech.html
- [72] 大江和彦: これからの医療における AI の活用と課題. 医薬品情報学一般社団法人 日本医薬品情報学会. **19**(3), pp.1-3, 2017.
- [73] 日本医師会 生命倫理懇談会: 「医療 AI の加速度的な進展をふまえた 生命倫理の問題」について [Internet]. 2022 Mar. Available from: https://www.med.or.jp/dl-med/teireikaiken/20220309_3.pdf
- [74] Selvaraju RR, Cogswell M, Das A, Vedantam R, Parikh D, Batra D: Grad-CAM: Visual Explanations From Deep Networks via Gradient-Based Localization. IEEE , pp.618–626, 2017. [accessed 2022 Jul 6]. Available from:
https://openaccess.thecvf.com/content_iccv_2017/html/Selvaraju_Grad-CAM_Visual_Explanations_ICCV_2017_paper.html
- [75] Gunning D, Aha D: DARPA’s Explainable Artificial Intelligence (XAI) Program. AI Mag. **40**(2), pp.44–58, 2019.
- [76] AMA: Augmented Intelligence in Health Care H-480.940 [Internet]. 2018. [accessed 2022 Jul 6]. Available from: <https://policysearch.ama-assn.org/policyfinder/detail/augmented%20intelligence?uri=%2FAMADoc%2FHOD.xml-H-480.940.xml>
- [77] 厚生労働省: 「国民の健康確保のためのビッグデータ活用推進に関するデータヘルス改革推進計画・工程表」及び「支払基金業務効率化・高度化計画・工程表」について [Internet]. [accessed 2022 Jul 4]. Available from:
<https://www.mhlw.go.jp/stf/seisakunitsuite/bunya/0000170011.html>
- [78] 内閣府: 戦略的イノベーション創造プログラム (SIP) [Internet]. [accessed 2022 Apr 30]. Available from: <https://www8.cao.go.jp/cstp/gaiyo/sip/>
- [79] ドクタービジョン: 内閣府が掲げる「AIホスピタル」プロジェクトとは? [Internet]. [accessed 2022 Jul 4]. Available from: <https://www.doctor-vision.com/column/2021/08/ai-hospital.php>
- [80] 首相官邸: 未来投資戦略2018— 「Society 5.0」 「データ駆動型社会」 への変革— [Internet]. 2018. [accessed 2022 Jul 10]. Available from:
http://www.kantei.go.jp/jp/singi/keizaisaisei/pdf/miraitousi2018_zentai.pdf

- [81] Berwick DM, Nolan TW, Whittington J: The Triple Aim: Care, Health, And Cost. *Health Aff (Millwood)* Health Affairs. **27**(3), pp.759–769, 2008.
- [82] Nordo AH, Levaux HP, Becnel LB, Galvez J, Rao P, Stem K, Prakash E, Kush RD: Use of EHRs data for clinical research: Historical progress and current applications. *Learn Health Syst.* **3**(1), p.e10076, 2019.
- [83] Ilyashenko O, Ilin I, Kurapeev D: Smart Hospital concept and its implementation capabilities based on the incentive extension. *SHS Web Conf*EDP Sciences. **44**, p.40, 2018.
- [84] Moro Visconti R, Morea D: Healthcare Digitalization and Pay-For-Performance Incentives in Smart Hospital Project Financing. *Int J Environ Res Public Health*Multidisciplinary Digital Publishing Institute. **17**(7), pp.2318, 2020.
- [85] Holzinger A, Röcker C, Ziefle M: From Smart Health to Smart Hospitals. In: Holzinger A, Röcker C, Ziefle M, editors. *Smart Health Open Probl Future Chall* [Internet], Cham: Springer International Publishing , pp.1–20, 2015. [accessed 2022 Jul 5]. Available from: https://doi.org/10.1007/978-3-319-16226-3_1
- [86] Moro Visconti R, Martiniello L: Smart Hospitals and Patient-Centered Governance [Internet]. Rochester, NY, 2019. [accessed 2022 Jul 5]. Available from: <https://papers.ssrn.com/abstract=3357473>
- [87] Garg N: Technology in Healthcare: Vision of Smart Hospitals [Internet]. *Handb Res Eng Bus Healthc Appl Data Sci Anal*. IGI Global , pp.346–362, 2021. [accessed 2022 Jul 5]. Available from: <https://www.igi-global.com/chapter/technology-in-healthcare/www.igi-global.com/chapter/technology-in-healthcare/264316>
- [88] Fischer GS, Righi R da R, Ramos G de O, Costa CA da, Rodrigues JJPC: EIHealth: Using Internet of Things and data prediction for elastic management of human resources in smart hospitals. *Eng Appl Artif Intell.* **87**, pp.103285, 2020.
- [89] 石川雅彦, 斉藤奈緒美: 医療機器のアラームに関わるインシデント・アクシデント事例からみる再発防止の検討. *医療機器学.* **87**(3), pp.285–291, 2017.
- [90] 讃岐美智義: 輸液ポンプの自動制御システム (特集 ICUにおける自動制御システムの現況と未来). *ICUとCCU Jpn J Intensive Care Med* 集中治療医学医学図書出版. **44**(3), pp.117–122, 2020.

- [91] 吉岡淳, 石山智之, 斎藤大樹, 長澤智一, 松田智美, 保科政美, 土谷順彦: 通信機器およびスマートデバイスを用いた人工呼吸器遠隔監視システムの開発と検証試験. 医療機器学. **88**(4), pp.449–457, 2018.
- [92] Cakir E, Heittola T, Huttunen H, Virtanen T: Polyphonic sound event detection using multi label deep neural networks. 2015 Int Jt Conf Neural Netw IJCNN , pp.1–7, 2015.
- [93] Cakir E, Heittola T, Huttunen H, Virtanen T: Multi-label vs. combined single-label sound event detection with deep neural networks. 2015 23rd Eur Signal Process Conf EUSIPCO , pp.2551–2555, 2015.
- [94] 高岡京平, 實近威雄, 白石優旗, 竹田史章: ニューラルネットワークによる酸素濃縮器を対象としたアラーム音識別システム. システム制御情報学会 研究発表講演会講演論文集 , pp.213–213, 2006.
- [95] Jančovič P, Köküer M: Detection of sinusoidal signals in noise by probabilistic modelling of the spectral magnitude shape and phase continuity. 2011 IEEE Int Conf Acoust Speech Signal Process ICASSP , pp.517–520, 2011.
- [96] Raboshchuk G, Nadeu C, Jančovič P, Lilja AP, Köküer M, Muñoz Mahamud B, Riverola De Veciana A: A Knowledge-Based Approach to Automatic Detection of Equipment Alarm Sounds in a Neonatal Intensive Care Unit Environment. IEEE J Transl Eng Health Med. **6**, pp.1–10, 2018.
- [97] Shiraishi Y, Takeda T, Shitara A: Alarm Sound Classification System in Smartphones for the Deaf and Hard-of-Hearing Using Deep Neural Networks. ACHI 2020 Thirteen Int Conf Adv Comput-Hum Interact , pp.30–33, 2020.
- [98] Cerutti G, Andri R, Cavigelli L, Farella E, Magno M, Benini L: Sound event detection with binary neural networks on tightly power-constrained IoT devices. Proc ACMIEEE Int Symp Low Power Electron Des [Internet], New York, NY, USA: Association for Computing Machinery , pp.19–24, 2020. [accessed 2022 May 1]. Available from: <https://doi.org/10.1145/3370748.3406588>
- [99] Purwins H, Li B, Virtanen T, Schlüter J, Chang S, Sainath T: Deep Learning for Audio Signal Processing. IEEE J Sel Top Signal Process. **13**(2), pp.206–219, 2019.
- [100] Li J, Dai W, Metze F, Qu S, Das S: A comparison of Deep Learning methods for environmental sound detection. 2017 IEEE Int Conf Acoust Speech Signal Process ICASSP ,

pp.126–130, 2017.

- [101] Mushtaq Z, Su S-F: Environmental sound classification using a regularized deep convolutional neural network with data augmentation. *Appl Acoust.* **167**, p.107389, 2020.
- [102] Howard A, Sandler M, Chu G, Chen L-C, Chen B, Tan M, Wang W, Zhu Y, Pang R, Vasudevan V, Le QV, Adam H: Searching for MobileNetV3. *IEEE*, pp.1314–1324, 2019. [accessed 2021 May 28]. Available from: https://openaccess.thecvf.com/content_ICCV_2019/html/Howard_Searching_for_MobileNetV3_ICCV_2019_paper.html
- [103] Salamon J, Bello JP: Deep Convolutional Neural Networks and Data Augmentation for Environmental Sound Classification. *IEEE Signal Process Lett.* **24**(3), pp.279–283, 2017.
- [104] Kingma DP, Ba J: Adam: A Method for Stochastic Optimization. *ArXiv14126980 Cs [Internet]*, 2017. [accessed 2021 Jun 7]. Available from: <http://arxiv.org/abs/1412.6980>
- [105] Park DS, Chan W, Zhang Y, Chiu C-C, Zoph B, Cubuk ED, Le QV: SpecAugment: A Simple Data Augmentation Method for Automatic Speech Recognition. *Interspeech 2019*, pp.2613–2617, 2019.
- [106] Mesáros A, Heittola T, Virtanen T: Metrics for Polyphonic Sound Event Detection. *Appl SciMultidisciplinary Digital Publishing Institute.* **6**(6), p.162, 2016.
- [107] 日本看護協会: 看護業務基準2016年改定版 [Internet]. 株式会社ナチュラル, 2016. [accessed 2022 Jul 1]. Available from: <https://www.nurse.or.jp/nursing/practice/kijyun/pdf/kijyun2016.pdf>
- [108] 村松洋, 渡部勇, 大崎千恵子, 小塚和人: 看護記録のテキストマイニング. *情報処理学会論文誌データベース (TOD) 情報処理学会.* **3**(3), pp.112–122, 2010.
- [109] 川端香織, 後藤浩美, 都築有紀, 田岡典子, 初崎和美: 看護記録の充実を目指して. *日本農村医学会学術総会抄録集.* **54**, pp.163–163, 2005.
- [110] 松田智子, 酒瀬川ルミ子, 北渡瀬郁恵, 田畑幸子, 福島悦子, 吉中平次: 周手術期看護記録監査方法の変更による記録者意識の変化: 他者評価にスタッフの導入を試みて. *日本手術医学会誌 J Jpn Assoc Oper Room Technol日本手術医学会.* **30**(1), pp.71–74, 2009.
- [111] 鈴木美恵子, 滝島紀子: 看護必要度評価の根拠となる看護記録の実態と今後の課題. 川

- 崎市立看護短期大学紀要. **18**(1), pp.51–57, 2013.
- [112] 久松桂子: 急性期患者の特性に着目した「重症度, 医療・看護必要度」に関する研究の系統的レビュー. 国際医療福祉大学学会誌. **23**(1), pp.62–73, 2018.
- [113] 村瀬美直子: 看護必要度導入期における評価者研修の重要性. 日本農村医学会学術総会抄録集. **58**, p.193, 2009.
- [114] 山田ひとみ, 竹村匡正, 岡本和也, 黒田知宏, 桑田成規: インフォームド・コンセント記載を対象とした診療録監査システムの検討. 診療情報管理. **29**(1), pp.53–61, 2017.
- [115] Devlin J, Chang M-W, Lee K, Toutanova K: BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding. Proc 2019 Conf North Am Chapter Assoc Comput Linguist Hum Lang Technol Vol 1 Long Short Pap [Internet], Minneapolis, Minnesota: Association for Computational Linguistics, pp.4171–4186, 2019. [accessed 2022 Mar 10]. Available from: <https://aclanthology.org/N19-1423>
- [116] Kawazoe Y, Shibata D, Shinohara E, Aramaki E, Ohe K: A clinical specific BERT developed with huge size of Japanese clinical narrative [Internet]. 2020. [accessed 2021 Oct 11]. Available from: <https://www.medrxiv.org/content/10.1101/2020.07.07.20148585v1>
- [117] Kudo T: Applying Conditional Random Fields to Japanese Morphological Analysis. Proc 2004 Conf Empir Methods Nat Lang Process EMNLP-2004, pp.230–237, 2004.
- [118] Sato T: Neologism dictionary based on the language resources on the Web for Mecab [Internet]. 2015. [accessed 2021 Nov 17]. Available from: <https://github.com/neologd/mecab-ipadic-neologd>
- [119] 佐藤敏紀, 奥村学, 橋本泰一: 単語分かち書き用辞書生成システム NEologd の運用 — 文書分類を例にして —. 自然言語処理研究会研究報告情報処理学会, pp.NL-229-15, 2016.
- [120] 佐藤敏紀, 奥村学, 橋本泰一: 単語分かち書き辞書 mecab-ipadic-NEologd の実装と情報検索における効果的な使用方法の検討. 言語処理学会第23回年次大会(NLP2017)言語処理学会, pp.NLP2017-B6-1, 2017.
- [121] Ito K, Nagai H, Okahisa T, Wakamiya S, Iwao T, Aramaki E: J-MeDic: A Japanese Disease Name Dictionary based on Real Clinical Usage. Proc Elev Int Conf Lang Resour Eval LREC 2018 [Internet], Miyazaki, Japan: European Language Resources Association (ELRA), 2018.

[accessed 2021 Oct 12]. Available from: <https://aclanthology.org/L18-1375>

[122] Sun C, Qiu X, Xu Y, Huang X: How to Fine-Tune BERT for Text Classification? In: Sun M, Huang X, Ji H, Liu Z, Liu Y, editors. *Chin Comput Linguist*, Cham: Springer International Publishing , pp.194–206, 2019.

[123] Liu L, Jiang H, He P, Chen W, Liu X, Gao J, Han J: On the Variance of the Adaptive Learning Rate and Beyond. *ICLR*, 2019. [accessed 2022 Mar 21]. Available from: <https://openreview.net/forum?id=rkgz2aEKDr>

[124] Mosbach M, Andriushchenko M, Klakow D: On the Stability of Fine-tuning BERT: Misconceptions, Explanations, and Strong Baselines. *ICLR*, 2020. [accessed 2022 Mar 21]. Available from: https://openreview.net/forum?id=nzpLWnVAyah&utm_campaign=NLP%20News&utm_medium=email&utm_source=Revue%20newsletter

[125] Yan Y, Chen M, Shyu M-L, Chen S-C: Deep Learning for Imbalanced Multimedia Data Classification. 2015 IEEE Int Symp Multimed ISM [Internet], Miami, FL, USA: IEEE , pp.483–488, 2015. [accessed 2021 Oct 28]. Available from: <http://ieeexplore.ieee.org/document/7442383/>

Research on the State of Hospitals for the Data Driven Society

Kazumasa KISHIMOTO

Medicine and medical care are becoming more advanced and complex with the advancement of science. The workload on medical staff continues to increase as hospitals must satisfy society's demands for ensuring medical safety and improving the quality of care. Therefore, hospital information systems must become more advanced and complex to improve the efficiency of hospital operations, and to advance hospital functions. Currently, artificial Intelligence (AI) development and research are actively conducted because of its potential to obtain inductive medical knowledge by using medical and genomic data. On the other hand, the accumulation and use of IoT data and medical data has the potential to streamline or automate increasingly complex hospital operations, but the state of the data-driven oriented hospital has not been examined. Therefore, this paper discusses a data-driven hospital information system with the purpose of examining the state of hospitals in a data-driven society.

First, regarding the use of data collection and machine learning with IoT and sensor data for data-driven orientation to ensure safety, this study examined a classifier that detects the status of medical devices from alarm sounds. As a result, a classifier using deep learning was shown to have applicability as a notification system. Next, regarding the use of accumulated data and machine learning to streamline operations, this study examined the automated audit of risk behaviors from nursing records. As a result, the classifier showed a high recall rate and clinical applicability, although a very small number of leaks occurred.

It is clear that hospitals can streamline their increasingly complex operations by providing medical staff with data-driven information extracted by AI from data collected by the IoT. Therefore, as society demands safety and quality improvement in medical care, I thought that the workload of medical staff could be reduced and hospital functions could be advanced.

学位論文と基礎となる学術論文目録

学術論文誌（査読あり）

- [1] 岸本和昌, 竹村匡正, 杉山治, 小島諒介, 八上全弘, 南部雅幸, 藤井清孝, 黒田知宏: 深層ニューラルネットワークを用いた重複アラーム音識別システムの検討. 生体医工学. **60(1)**, pp.8-15, 2022.
- [2] 阪本恭子, 岸本和昌, 山本剛, 竹村匡正: BERT を用いた看護記録における自動監査の試み: カルテ記載における自己抜去を対象として. 生体医工学(採択済み).

International Conference Papers

- [1] Kazumasa K, Takashi N, Kenichirou F, Tadamasa T: Investigation of integrating a variety of medical devices data into medical information system. IEEE, USA, 2016.
- [2] Kazumasa K, Takashi N, Kenta H, Tadamasa T: Construction of push notification system handling medical device log data. IEEE, USA, 2018.

国内学会，研究会発表

- [1] 岸本和昌, 押川千穂, 中井隆史, 竹村匡正: 電子カルテシステムにおける医療機器ログデータの取り扱いに関する検討. 第 36 回医療情報学連合大会論文集, 千葉県, pp.302-303, 2016.
- [2] 岸本和昌, 押川千穂, 糸川雅子, 中井隆史, 竹村匡正: 医療機器ログデータを用いたプッシュ通知システムの構築. 第 36 回医療情報学連合大会論文集, 大阪府, p.340, 2017.
- [3] 岸本和昌, 中井隆史, 堀健太, 糸川雅子, 押川千穂, 竹村匡正: 医療機器データを用いたプッシュ通知システムの検討. 第 38 回医療情報学連合大会論文集, 福岡県, p.374, 2018.
- [4] 岸本和昌, 井上宗紀, 竹村匡正: エッジデバイスを用いた深層学習によるアラーム音検知システムの検討. 第 40 回医療情報学連合大会論文集, 静岡県, pp.529-530, 2020.
- [5] 岸本和昌, 竹村匡正, 杉山治, 小島諒介, 八上全弘, 南部雅幸, 藤井清孝, 黒田知宏: 深層ニューラルネットワークを用いた重複アラーム音識別システムの検討. 生体医工学シンポジウム 2021, 富山県, 2021.
- [6] 清水充子, 岸本和昌, 中井隆史, 山下晃平, 佐藤瑞月, 梶田朝佳, 竹村匡正: 化合物の類似性を用いた医薬品グループ予測. 第 41 回医療情報学連合大会論文集, 愛知県, pp.795-796, 2021.

- [7] 岸本和昌, 竹村匡正, 杉山治, 小島諒介, 山本豪志朗, 黒田知宏: エッジデバイス上における医療機器アラーム音分類器の実行可能性の検討. 第 66 回システム制御情報学会研究発表講演会, 京都府, 2022.

その他の学術論文目録

学術論文誌 (査読あり)

- [1] 垣内優芳, 岸本和昌, 加藤博史, 田中利明, 桜井稔泰: 早期離床時における自動カフ圧計の使用有無によるカフ圧変動差: 症例報告. 日本理学療法学会大会(Web). **53**, pp.2-20, 2019.

International Conference Papers

- [1] Kiyotaka F, Kazumasa K, Munenori I: Study of Evaluation Method on Electromagnetic Environment for Safe Introduction of Wandering Sensing Systems Operable in Medical Field. 2020 14th International Symposium on Medical Information Communication Technology (ISMICT), p.1, 2020.

国内学会, 研究会発表

- [1] 岸本和昌: 関節鏡用電気メスにおけるアクティブ電極の経時的変化について. 日本手術医学会誌, 東京都, p.151, 2017.
- [2] 石橋一馬, 岸本和昌: Filemaker Pro を用いた医療機器管理ソフトとの連携. 日本臨床工学技士会誌, 東京都, p.256, 2018.
- [3] 岸本和昌: 当院の内視鏡手術における手術室臨床工学技士の業務. 日本手術医学会誌, 東京都, 2018.
- [4] 中本皓太, 岸本和昌, 藤井清孝, 桜井稔泰: 自動カフ圧コントローラ Smart Cuff の性能評価. 日本集中治療医学会学術集会, pp.60-66, 2019.
- [5] 市之瀬透, 吉田一貴, 岸本和昌, 高橋篤志, 吉田哲也, 正木昭次: 兵庫県臨床工学技士会における手術ワーキンググループの活動報告. 日本臨床工学技士会誌, 東京都, p.235, 2019.
- [6] 岸本和昌: 強アルカリフリー炭酸ガス吸収剤の比較. 日本手術医学会誌, 東京都, p.180, 2019.

- [7] 藤井清孝, 井上宗紀, 中本皓太, 岸本和昌: 医療機器/電子カルテ連携推進に伴う新たなトラブル事例. 病院設備. **61(5)**, p.146, 2019.
- [8] 岸本和昌, 上崎勝生, 高橋祐一, 藤井清孝: 当院における電気メス用対極板の安全運用の検討. 第 26 回近畿臨床工学会, 京都府, 2019.
- [9] 島田尚哉, 加藤博史, 中村拓生, 三井友成, 岸本和昌, 橋本圭司, 吉田哲也, 松島寛和: 医工連携による酸素ボンベ残時間計算タイマーの開発と商品化への取り組み. 医療の質・安全学会誌, p.491, 2019.
- [10] 堤貴彦, 森由希子, 杉山治, 山本豪志朗, 齊藤健一, 岸本和昌, 倉田真宏, 大鶴繁, 黒田知宏: 振動台実験装置を用いた地震時の手術台の安全性の検証. 第 66 回システム制御情報学会研究発表講演会, 京都府, 2022.