

学位論文

安心感を与える抱きつき形状による生体計測システム
およびニューラルネット構成法に関する研究

2023年3月

拓殖大学大学院工学研究科
機械・電子システム工学専攻

G0D2012020

王 超

内容

第1章	序論	1
1.1	本研究の背景	1
1.2	本研究の目的	2
1.3	論文の構成	3
第2章	生体信号計測および機械学習, ニューラルネット	5
2.1	背景	5
2.2	バイタルサイン	10
2.3	バイタルサインセンサ	12
2.4	機械学習・ニューラルネット	17
	第2章の参考文献	24
第3章	バイタルサイン計測を目的とした生体状態評価システムの構成	27
3.1	マイコンによるバイタルサイン計測	27
3.1.1	バイタルデータ計測のためのマイコンとセンサ	27
3.1.2	感情状態の推定	28
3.1.3	実験	28
3.1.4	マイコンによるバイタルサイン計測のまとめ	30
3.2	抱きつき型システム	31
3.2.1	体温	32
3.2.2	呼吸数	33
3.2.3	脈拍	34
3.2.4	実験	36
3.3	まとめ	42
	第3章の参考文献	43
第4章	生体状態評価システムへの機械学習およびニューラルネットの導入	45
4.1	抱きつき型システムへ表情認識の導入	45
4.1.1	表情認識	46
4.1.2	抱きつき型システムへ表情認識の導入のまとめ	49
4.2	表情認識による孤独感軽減ロボットの動作選択	50
4.2.1	孤独感軽減ロボット	50
4.2.2	表情判別による動作選択	51
4.2.3	実験	53
4.2.4	表情認識による孤独感軽減ロボットの動作選択のまとめ	54

4.3 非接触測定の導入.....	55
4.3.1 皮膚反射モデル.....	55
4.3.2 カメラによる非接触脈波推定.....	56
4.3.3 実験.....	58
4.3.4 非接触測定の導入のまとめ.....	60
4.4 まとめ.....	61
第4章の参考文献.....	62
第5章 四元数に拡張したニューラルネットと生体状態評価システムへの応用.....	64
5.1 四元数ニューラルネットによる入力逆推定法.....	65
5.1.1 四元数.....	65
5.1.2 四元数ニューラルネット.....	66
5.1.3 四元数ニューラルネットの入力逆推定.....	67
5.1.4 入力の逆推定法を提案.....	68
5.1.5 実験.....	68
5.1.6 ビット演算問題.....	69
5.1.7 アフィン変換問題.....	74
5.1.8 従来法との比較.....	78
5.1.9 四元数ニューラルネットによる入力逆推定法のまとめ.....	81
5.2 四元数ニューラルネットの生体状態評価システムへの応用.....	82
5.2.1 9軸ジャイロセンサ.....	82
5.2.2 抱きつき型システム.....	83
5.2.3 実験.....	84
5.2.4 四元数ニューラルネットの生体状態評価システムへの応用のまとめ.....	86
5.3 まとめ.....	87
第5章の参考文献.....	88
第6章 結論.....	90
謝辞.....	92
本研究に関連する研究業績一覧.....	93

第1章 序論

1.1 本研究の背景

近年の医療技術の進歩により、医用検査装置の高度化はもちろんのこと、日常計測装置が生活の中で幅広く使用されるようになってきた。日常計測装置では、計測の精度とともに計測の容易さや使用感の良否も重要な要素となる。そこには、計測のための医用電子・情報技術的な側面に加えて、工業デザインや感性工学的な側面が必要となる。

日常的な計測や、身近な医院における小児医療においては、スムーズな診断や治療のために、患児の不安や症状を和らげることが大切である。小児の不安解消のために、抱っこやスキンシップは有効な手段の1つである。そこで、抱っこやスキンシップの有効性に基づく「抱きつき型」の計測システムならば、不安を解消しつつ医療計測を行うことが可能になると考える。

電子技術の進歩により、さまざまなセンサや小型のコンピュータが開発され、手軽に利用できるようになった。そこで、生体信号を計測できるセンサからのデータをマイコン経由で処理することで、計測のためのシステムのプロトタイプを構成し実験を行うことができる。これにより、実際のシステム開発や製品化に先立って、開発するシステムの有効性や可能性を検証することができるようになった。

情報技術の進歩により、機械学習や深層学習による信号判別や画像認識が実用化されるとともに、より身近なものとなった。画像認識の1つの応用として、顔画像から感情を推定する方法が提案された。この方法では、エクマンによる表情と感情の関係に基づいて、顔画像から7種類の感情を推定する。また、画像認識の他の応用として、顔の動画画像から直接医療計測を行うさまざまな方法が研究されている。感情を推定しフィードバックすることや、動画画像から非接触で計測を行うことは、不安を緩和しつつ医療計測をおこなうために有効と考えられる。

機械学習や深層学習は、近年盛んに研究されるとともに、さまざまなモデルや手法が提案・実現されるようになってきた。三次元空間における姿勢や挙動の表現のために、高次元素数である四元数が用いられる場面が増えてきた。生体計測においても、体の動きや姿勢によるデータがしばしば用いられる。そこで、四元数を直接取り扱うことができる機械学習や深層学習法が検討されてきた。四元数に拡張した機械学習法は、本研究で対象とする計測システムにも有効と予測する。

以上のような医療技術、電子技術、情報技術等の背景に注目し、本研究では抱きつくことで生体信号を測定する新たな医療計測システムの研究とともに、不安感の緩和や軽減のために機械学習や深層学習に基づく感情推定や非接触計測を導入した安心感を与えるシステムの研究を行った。

1.2 本研究の目的

本研究では、抱きつくことで安心感を与えつつ生体信号を計測する医療計測システムを開発するためのプロトタイプを作成するとともに、画像認識等の技術によって不安感を緩和する機能を追加することでシステムを拡張すること、そのための機械学習・深層学習法を提案することを目的とした。本研究では以下の3つを目的とする。

- ① バイタルサイン計測を目的とした生体状態評価システムの構成
- ② 生体状態評価システムへの機械学習およびニューラルネットの導入
- ③ 四元数に拡張したニューラルネットと生体状態評価システムへの応用

まずは、バイタルサイン計測を目的とした生体状態評価システムの構成に取り組む。医療の分野において、体温・心拍・血圧・呼吸のバイタルサインは重要であり、ウェアラブルセンサや画像による非接触計測など、さまざまな手法が研究されている。特に小児患者においては、不安や症状を和らげつつ計測する必要がある。その1つの解決法として抱きつき型の生体状態評価システムを提案する。本研究では、マイコンとセンサによる簡便なシステムを構成し、計測の可能性と有効性を検証することを目的とする。

続いて、上記で検討した生体状態評価システムへの機械学習およびニューラルネットの導入に取り組む。近年、機械学習やニューラルネットを用いて、顔の画像等から生体状態や感情を推定する方法が研究されている。本研究では、患者の不安や症状を軽減することを目的として、抱きつき型の生体状態評価システムに対して、表情認識による感情状態の推定法や、顔動画によるバイタル情報の非接触計測法を導入することを提案する。さらに、表情認識による感情推定と、顔動画による心拍推定の可能性と有効性を検証する。

さらに、四元数に拡張したニューラルネットと生体状態評価システムへの応用に取り組む。3次元空間における幾何学演算や姿勢表現に四元数は有効であり、ニューラルネットの四元数への拡張が提案されている。本研究では、3次元空間内における、結果から原因の効率的な推定手法の1つとして、四元数ニューラルネットによる逆問題解法を提案し、その効果を検証する。さらに、四元数ニューラルネットを、抱きつき型生体状態評価システムの姿勢推定に適用し、その有効性を検証する。

個々の具体的な研究背景や目的に関しては、後の章でそれぞれ述べる。

1.3 論文の構成

本論文は6章で構成され、第1章以降の内容は以下のとおりである。

第1章 序論

本研究の背景・目的・論文の構成について概説する。

第2章 生体信号計測および機械学習，ニューラルネット

研究背景として、人口動態と高齢化・少子化の傾向について概観し、小児医療や日常計測の重要性を明らかにした。続いて、本研究で対象とする生体信号、特にバイタルサインを中心にその重要性和応用例について述べ、その測定に使われる方法およびセンサについて解説した。さらに、生体信号や生体状態の解析、推定に関わる機械学習やニューラルネットについてその特徴や原理を解説した。

第3章 バイタルサイン計測を目的とした生体状態評価システムの構成

マイコンとセンサによる生体状態評価システムを構成し精度と有効性を検証した。医療の分野において、体温・心拍・血圧・呼吸のバイタルサインは重要であり、ウェアラブルセンサや画像による非接触計測など、さまざまな手法が研究されている。特に小児患者においては、不安や症状を和らげつつ計測する必要がある、その1つの解決法として抱きつき型の生体状態評価システムを提案した。提案法である抱きつき型生体状態評価システムの有効性を示すために、マイコンとセンサによって4つのバイタルサインである体温、心拍、血圧、呼吸を測定し感情状態を推定するシステムを、簡便なセンサとマイコンで実現した。本システムにおいて、体温はサーミスタによる温度センサ、心拍は光電脈波センサ、血圧はもう1つの光電脈波センサによる脈波伝搬速度(PWV)、呼吸は呼気による温度変化をサーミスタ温度センサで測定することとした。実際にマイコンとセンサによる簡便なシステムを構成し、計測の可能性と有効性を検証した。

第4章 生体状態評価システムへの機械学習およびニューラルネットの導入

前章で提案、検証した生体状態評価システムへの追加機能として、動画による表情認識や心拍測定のための機械学習やニューラルネット手法の検証を行った。近年、機械学習やニューラルネットを用いて、顔の画像等から生体状態や感情を推定する方法が研究されており、患者の不安や症状を軽減することを目的として、抱きつき型の生体状態評価システムに対して、表情認識による感情状態の推定法や、顔動画によるバイタル情報の非接触計測法を導入することを提案した。具体的には、表情認識による感情推定と、顔動画による心拍推定の可能性と有効性を検証した。表情認識による感情状態の推定では、表情から推定した感情を提示して注意を引き不安を和らげることを目的とし、エクマンによる7種類の表情を深層

学習によって学習したモデルを用いて感情推定を行った。実際に Web カメラと LCD ディスプレイを Raspberry Pi マイコンに接続し、感情に合った顔文字を表示するシステムを構成し、有効性を検証した。続いて、表情認識の応用として、表情認識によるロボットの動作選択を提案して有効性の検証を行った。本工学部で開発が行われている孤独感軽減ロボットを想定し、表情認識で推定した感情に基づく動作選択法を導入することを提案した。ラッセルの円環モデルに基づき感情を表す物理量を 2 次元で評価し、感情を中立に誘導することを目的とし動作を選択することとし、仮想空間内で動作するロボットを用いて動作を検証し有効性を示した。さらに、ユーザの快適性と動きの制限を改善するために、抱きつき型生体状態評価システムに非接触計測法を導入することを提案し、顔動画によるバイタル情報の非接触計測法として、顔動画による心拍測定の可能性と有効性を検証した。

第5章 四元数に拡張したニューラルネットと生体状態評価システムへの応用

前章では、不安感の緩和や軽減のために機械学習や深層学習に基づく感情推定や非接触計測を本システムに導入することを提案した。日常計測において、姿勢状態を推定し把握することは重要であり、抱きつき型の計測方法をとる本システムでも有望な検討対象である。一方、3次元空間における幾何学演算や姿勢表現に高次複素数の1つである四元数は有効であり、ニューラルネットの四元数への拡張が提案されている。本章において、まずは四元数ニューラルネットによる3次元空間における逆問題解法を提案しその効果を示した。さらに、四元数ニューラルネットを抱きつき型生体状態評価システムの姿勢推定に適用することを目的とし有効性を検証した。

第6章 結論

本論文の各章で得られた結果を総括した。本研究では、人に安心感を与える計測システムを目指し、抱きつくことで呼吸や心拍、体温、血圧のバイタルサインを測定するシステムの開発を行った。マイコンとセンサを用いた検証モデルで計測実験を行い、抱きつくことでバイタルサインの計測が可能であることを示すことで、本システムの有効性を示した。続いて、不安感の緩和や軽減のために機械学習や深層学習に基づく感情推定や非接触計測をこのシステムに導入することを提案し、計算機実験によって動作を示した。本システムは、安心感を与えるためのさまざまな付加機能を含む総合的なバイタルサイン計測システムに拡張可能であることを示した。さらに、本システムを用いた効率的な姿勢推定や把握を目標とし、空間幾何や3次元姿勢表現に有効とされる四元数を取り入れたニューラルネットについての検討と姿勢推定の可能性を検証した。四元数に拡張したニューラルネットの一手法を提案し、抱きつき型の生体状態評価システムへの応用を計算機実験によって検証した。本研究を通して提案・検証したシステムは、人に安心感を与えつつ生体信号を計測する1つの枠組みとして、医療計測や日常計測に寄与するものと期待される。

第2章 生体信号計測および機械学習, ニューラルネット

2.1 背景

文献によると, 世界人口は 2017 年の 76.4 億人から 2064 年に 90.7 億人でピークを迎え, 2100 年には 87.9 億人に減少すると予測された[1]. 世界の人々は長生きしている. 現在, ほとんどの人が 60 代以上まで生きると見られている. 今後 30 年間で, 世界の人口に占める 60 歳以上の割合は 12% から 22% へとほぼ倍増し, 2050 年には 10 億人から 21 億人になると見込まれている. また, 80 歳以上の高齢者は 2050 年までに 3 倍の 4 億 2,600 万人に達すると予想された. このような人口高齢化のペースは, 過去に比べはるかに速い. 世界のすべての国で, 人口に占める高齢者の数と割合が増加し, この人口動態の変化に対応できるような保健・社会システムを確保するという大きな課題に直面している. 2050 年までに, 世界の 60 歳以上の人口の 3 分の 2 が低中所得国に住むことになる[2].

図 2.1 のように, 今後 30 年間の世界の高齢化人口の変化と分布を視覚化した世界保健機関のデータを示している. これは, 60 歳以上の人口の割合が指数関数的に増加していることがわかった.

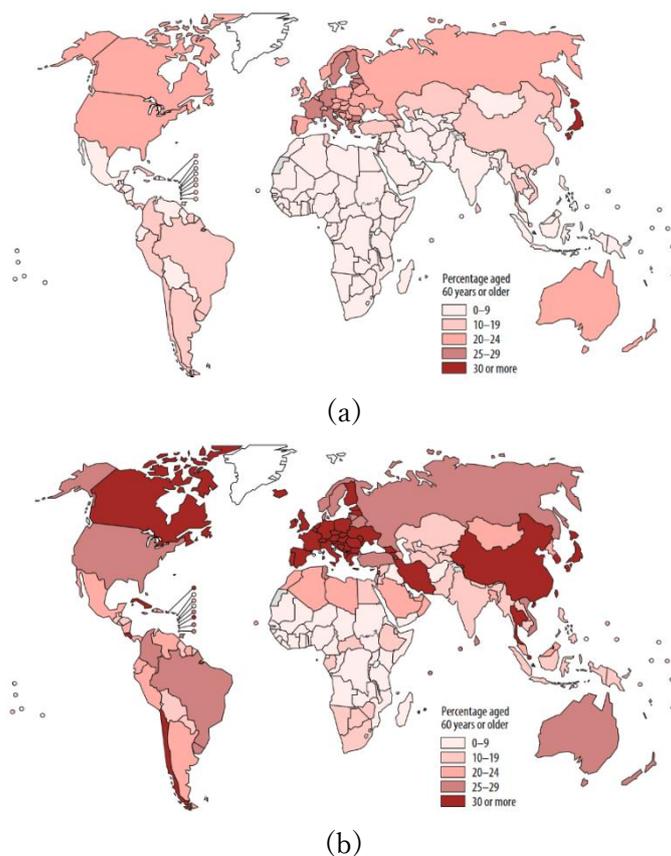


図 2.1 60 歳以上の人口の割合, 国別, (a) 2015 年 (b) 2050 年[1]

日本では、人口は近年横ばいであり、人口減少局面を迎えている。厚生労働省のデータ[3]によると、1995年には、65歳以上の成人が15～64歳人口を上回ることになった。図2.2示すように、2060年には総人口が9000万人を割り込み、この差は時間の経過とともに拡大し続け、高齢化率は40%近い水準になると推計されている。

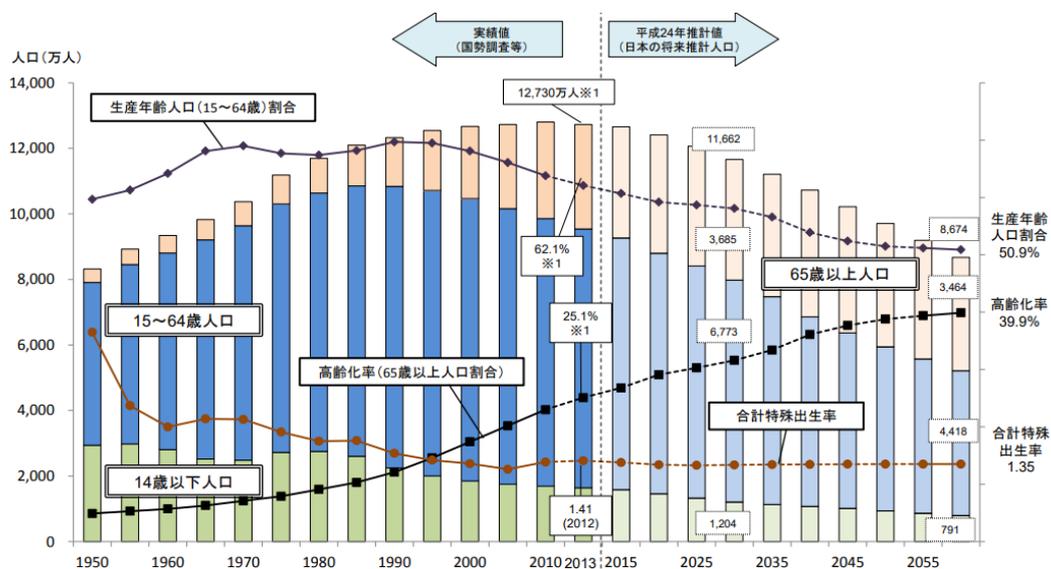


図 2.2. 日本の人口の推移[3]

人口数が増えるほど、そして高齢人口が増えるほど、医療費支出は増加すると予測できる。国民所得水準が向上され、生活環境が改善されることによって、平均寿命が高くなり、老人人口が増えるが、老人人口の増加は慢性病及び各種老人性疾患の増加と係って医療費の増加に影響を与える。

図 2.3 に示すように、日本の医療費の規模をみると、その額は年々増加しており、2019年度には約 44.4 兆円に達している。そのうち、高齢者の医療費は約 17 兆円で、全医療費の 3 分の 1 以上（65 歳以上 38.4%）を占め、その割合は年々増加している。一人当たり年間医療費の特徴を見ると、70 歳以上で 198 万円、70 歳未満で 100 万円と、高齢者の医療費が高いことがわかった[4]。また、国民医療費の国民所得に対する比率をみると、1995 年代に入ってから 10 年間で約 1% ずつ上昇傾向にある。

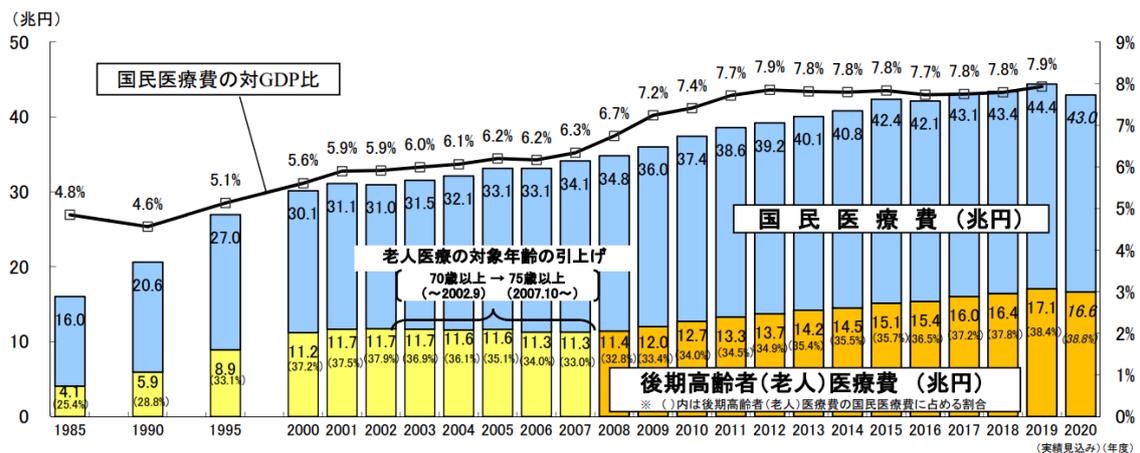
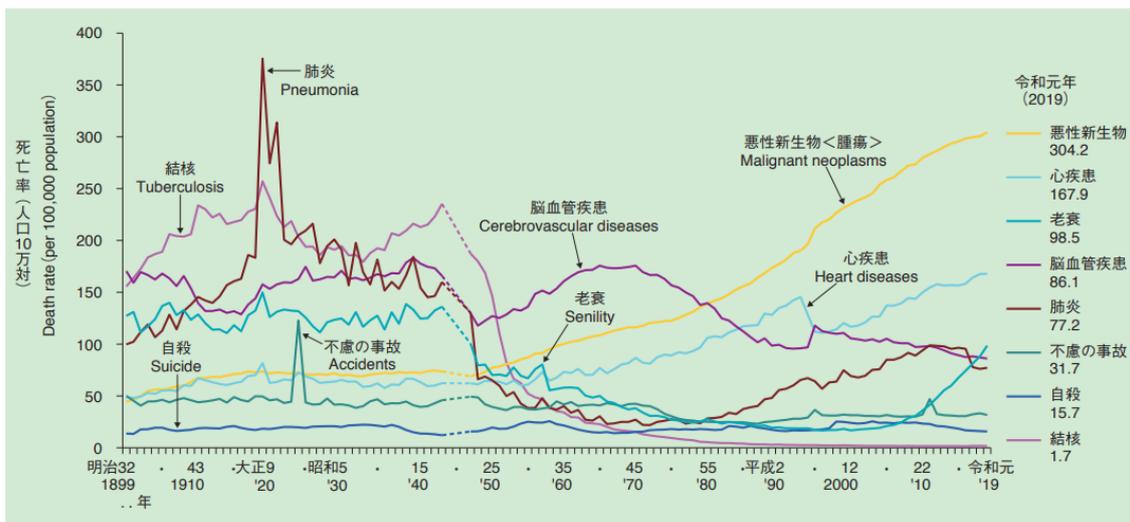


図 2.3 医療費の動向[4]

過去数十年の医療の改善により、先進国の住民は長生きするようになったが、複数の、しばしば複雑な健康状態を抱えている[5]。主な死因別に死亡率の年次推移をみると、1960年以前は感染症の値が高く、その以降は悪性新生物(腫瘍)、心疾患、脳血管疾患が死因順位の第1位から第3位を占めていた。



注：グラフが点線になっている昭和19年～21年(1944年～1946年)は、戦災による資料喪失等資料不備のため、統計が得られていないものである。

図 2.4 主要死因別死亡率の年次推移 1899年～2019年[6]

急性外傷からの生存率も向上しているが、これは重度の障害を持つ人の増加につながっている。現在、継続的なモニタリングを必要とする患者の数は、人口の増加に比例して増加しており、2025年には、高齢者グループの数は約12億人になると予想されている。

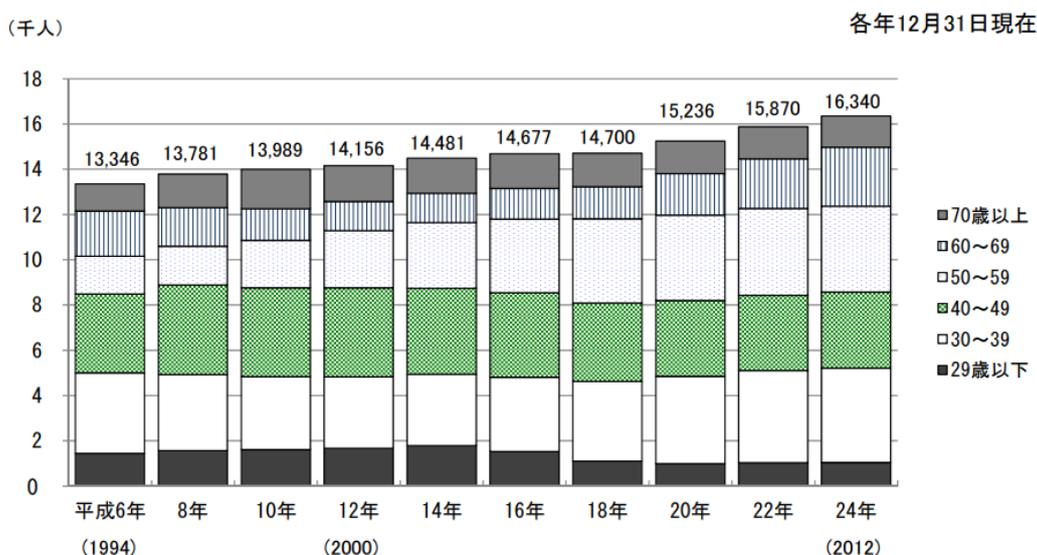
また、日本は世界に先駆けて少産少子の時代に向かって突き進んでいる。その中で、子育て世帯が安心して生活できるためには、良い小児医療の提供が不可欠である。

厚生労働省の小児医療に関するデータによると、図 2.5 に示すように子どもの人口や子育て世帯数は減少しているものの、病院においては受療率が上昇傾向にある。図 2.6、図 2.7 に示すように、小児科医の年齢上昇や他科を主たる診療科としながら小児科も診療する医師の減少等により、小児科診療を行う医療機関に患者が集中する傾向もみられた。さらに、最近では母親の就業の急速な増加により、今後は時間外・夜間・休日診療等のニーズも高まることが見込まれる[7]。

もう一つの大きな社会問題である少子化の中で、医療技術の進歩により乳児死亡率は減少傾向にあるものの、医療的ケアを必要とする児は全国的に増加傾向にあり、新生児集中治療室(NICU)等から退院後、地域で在宅医療を受ける整備が求められている[8]。



図 2.5 子どもの人口と患者数の推移 (a)15歳未満人口の推移, (b)15歳未満の小児患者数(外来) [9]



出所:厚生労働省大臣官房統計情報部 医師・歯科医師・薬剤師調査

図 2.6 小児科医師(主たる)数の年次推移 [9]

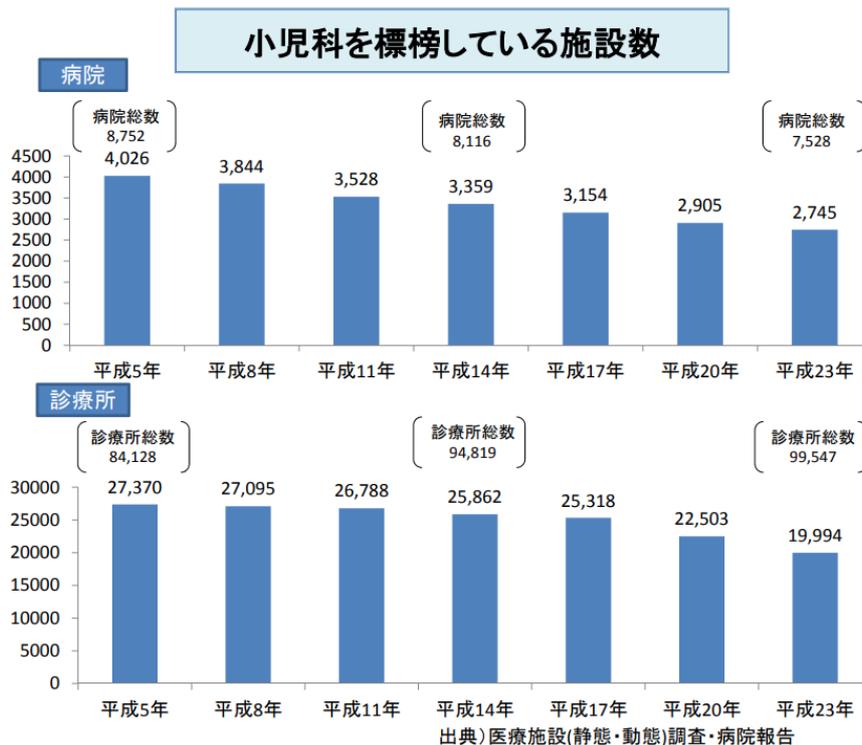


図 2.7 小児科を標榜している施設数 [9]

このような人口動態や小児医療環境の変化は、いくつかの基本的な問題を提起する。

- 複雑な病状を持つ患者の増加にどのように対処すればよいのか？
- 医療機関へのアクセスが悪い地域に住む人々に、どのようにして質の高いケアを提供するか？
- 増え続ける異常徴候を持つ人々にはどうやって未然に発見できるのか？
- 子どもの受療率の増加と小児医療施設の減少にどのように対処すればよいのか？

明らかに、上記の問題を解決しようとすることは非常に困難で複雑である。しかし、この問題は、情報技術および関連分野の最近の進歩を利用することによって、部分的に解決することができる。現在、医療システムの能力を向上させ、その範囲を病院、コミュニティ、遠隔地、および家庭に拡大することを約束するテクノロジーが存在する。また、診断の実施方法や監視方法を変更し、個人の独立性と参加を最大化することもできる。

人口動態の高齢化の進展、医療費の増加、慢性疾患の蔓延、小児医療環境の変化は、現在の医療制度を根本的に変える主要な要因となっている[10]。そのため、医療従事者が費用対効果の高い、迅速な医療サービスを提供できることが期待されている。

2.2 バイタルサイン

バイタルサイン測定は、広く採用されており、臨床ケアに不可欠な要素である。それらには、人の基本的な身体機能を断続的に観察し測定するものである。伝統的に、バイタルサインは血圧、体温、脈拍、呼吸数を含むが、現在では他の多くのパラメータも含まれるようになった。バイタルサインの変化は、患者の異常な生理学的変化を示す最初で早い兆候であり、評価する臨床医に重要な情報源となる。病院内、特に高依存度地域では、臨床的悪化の認識、介入とケアの拡大の必要性をサポートするために、バイタルサインの測定が定期的に行われる。多くの場合、詳細なモニタリングは、患者が病院やクリニックに入院している間のみ行われる。したがって、バイタルサイン監視システムには、表 2.1 に示すように 1 つまたは複数の監視項目が含まれる。

表 2.1 バイタルサイン

心電計 (ECG)	脈拍数 (Heart Rate)
フォトプレチスモグラム (PPG)	心拍変動 (HRV)
体温	呼吸数
血圧	血中酸素飽和度

以下のバイタルサインの紹介は文献[11]による。

● 体温

体温とは、身体内部の温度のことである。心臓や脳など身体の深部の温度を指し、心理学的には、心臓から出てすぐの大動脈の血液の温度を意味する。しかし実際には、身体内部の温度を測ることは難しいため、より身体内部に近い温度が得られ、測定しやすい腋窩、口腔、直腸、鼓膜などの部位の温度を測定し、身体内部の温度として用いられる。水銀温度計や電子温度計で上記部位を測定し、体温データを取得する。通常 5~10 分程度かかる。

● 呼吸

呼吸は血液に酸素を取り込むための重要な機能である。呼吸中枢では血液中の酸素濃度を保つための制御が行われている。呼吸には肺でのガス交換と組織でのガス交換の 2 つがある。呼吸運動は胸郭の変形（拡大・縮小）と横隔膜の移動（収縮・弛緩）によって行われる。呼吸運動に関係する主要な筋肉は肋間筋と横隔膜で呼吸筋と呼ばれる。胸郭の変形は肋骨の移動によって行われ、これを胸式呼吸という。横隔膜の移動による呼吸を腹式呼吸という。一般的に安静状態は腹式呼吸、運動状態は胸式呼吸の割合が大きくなる。これらの動きを観察し、1 分間の呼吸数をカウントすることで呼吸数を求める。

- 脈拍

脈拍とは、心臓の拍動（心拍）によって大動脈に拍出された血液の波動が末梢動脈に伝播されたもので、心拍に伴う動脈内の圧力の変化を体表から感知したものである。心臓は心室内の血液を動脈に向かって押し出す「収縮期」と、次の拍出に備えて心室内に血液をためる「拡張期」を繰り返しており、この過程を「心周期」という。収縮期の最も高い血圧と拡張期の最も低い血圧の差を「脈圧」といい、これが末梢の動脈に伝達して脈拍として触知できる。動脈が体表の近くを通っている部位では、指先で動脈を触れてみることで心拍に応じて血管が脈打つ様子を観察できる。

- 血圧

血圧とは、血管内の血液の有する圧力のことである。一般には動脈の血圧のことで、心臓の収縮期と拡張期の血圧をいい、それぞれ収縮期血圧、拡張期血圧と呼ぶ。単位は水銀柱ミリメートル (mmHg) を使用することがほとんどである。血圧の値が高くなるにしたがいⅠ度からⅢ度までの高血圧に分けられる。また高血圧でない場合は正常域血圧となるが、これも3つの区分に分けられ、一番低い区分（収縮期血圧 120mmHg 未満かつ拡張期血圧 80mmHg 未満）を至適血圧という。一般的に用いられている血圧測定には、水銀血圧計、アネロイド血圧計、電子血圧計がある。水銀血圧計の測定には、上腕にマンシェットを巻き、加圧し、減圧時に、肘前部の上腕動脈に聴診器をあて音を聴き、血圧を判定する。聴診法では、上腕動脈に当てた聴診器の音を聞きながら、最高血圧、最低血圧を決定する。圧を高くしてから、徐々に低下すると、聴診器から音が聞こえてくる（コロトコフ音）。その音が最初に聞こえたときの圧力が最高血圧、音が消えたところの圧が最低血圧である。

しかし、上記のような従来の方法では、測定に時間がかかるだけでなく、個別に測定を行うことも考慮すると、医療資源の有効活用という点で改善の余地があると言える。

2.3 バイタルサインセンサ

近年のセンサ技術や組み込みコンピューティング技術の進歩により、人々のライフスタイルや日常生活に影響を与えることなく、身につけたり家庭環境に組み込んだりできる小型のセンサネットワークが出現しているため、プライマリーケアサービスにおいて、バイタルサインの測定も可能になっている。例えば、乳幼児や小児の評価 [12] や長期疾患を持つ人々の評価において、また地域社会や住宅介護の環境では、バイタルサインの在宅測定はますます高齢化していく人々の健康状態のモニタリングに特に有用となる可能性がある。

さまざまなアプリケーションの開発に伴い、ますます多くのセンサが登場している。最も一般的に使用されるセンサを表 2.2 に示す。いくつかの典型的なセンサを以下に紹介する。

表 2.2 一般的に使用されるセンサ

センサ	機能 信号の種類	サンプリング	周波数	設置場所
加速度センサ	三次元空間の各空間軸で加速度を取得。	連続	高い	非侵襲
カメラピル	ワイヤレス内視鏡技術による消化管の検出。	連続	高い	侵襲
ECG/EEG/EMG センサ	体の表面に配置された 2 つの電極間の電圧差を測定する。	連続	高い	非侵襲
ジャイロスコープ	角運動量保存則に従って、回転物体の角速度を測定する。	連続	高い	非侵襲
湿度センサ	湿度変化による抵抗率と静電容量の変化から湿度を測定する。	離散	低い	非侵襲
血中酸素飽和度 センサ	体の薄い部分を通過する赤色光と赤外線吸収率から血中酸素飽和度を測定する。	連続	高い	非侵襲
圧力センサ	誘電媒体の圧電効果による圧力値を測定する。	連続	高い	非侵襲
温度センサ	材料の物性変化による温度測定する。	離散	低い	非侵襲
視覚センサ	長さ、数、位置、面積など、被写体の特徴を捉える。	連続/離散	高/低	非侵襲
赤外線センサ	焦電効果による温度変化を測定する。	連続/離散	高/低	非侵襲

- PPG (光電式容積脈波記録法)

PPG とは脈拍に伴う動脈容積の変化を光学的に捉えるものである。取得プロセスは、送信機 (光源) と受信機 (光検出器) の位置によって、透過モードと散乱モードで動作することができる。透過モードでは、光源と受光器の位置が皮膚組織の層を挟んで対向するように配置される [13]。光検出器は、光源からの光が組織に吸収された後の残光を検出する。一般的に、この PPG センサは、主に指、足指、耳たぶなど、体の遠位部での PPG 測定に採用されている。指用はパルスオキシメーターなどの医療用途に広く活用されている。一方、耳たぶのバージョンは、バイタルモニタリングに頻繁に利用されている [14]。

さらに、PPG センサの光源の隣には光検出器が配置されており、散乱の原理で動作している。PPG センサの光源に隣接して光検出器が配置され、同じ体表面で反射した光を検出する。そのため、反射原理は、手首、額、食道、頸動脈など、透過原理ではうまく測定できない異なる身体部位での PPG 信号測定に高い自由度を提供する。その結果、長期的なモニタリングのための非侵襲的なウェアラブル技術に実装するのに適している。

PPG 測定システムの基本的なハードウェアコンポーネントは、PPG 信号を抽出する発光ダイオード (LED) と受光ダイオードである。LED は、手首、指先、耳たぶ、または額の皮膚を照らすために、赤色または赤外線を放射する。一方、感光ダイオードは、時間の経過とともに変化する組織の光吸収を監視し、血液量の変動を検出することができる。PPG 信号は、血管内の血流の変動によって生じる信号を記録する。心拍数の変動は、血管内血流 (単位あたり) の変動を引き起こす。光センサが記録する誘導電圧は、血流の変動に対応して変化する。収縮期には、光センサは最大限の光を吸収する。PPG 信号の振幅は、組織の血流および流出変動に比例する。したがって、PPG 信号は、心血管循環系、収縮期および拡張期の心臓活動、末梢微小循環系のネットワーク、および血液レオロジーと血行力学データに関連する生理学的情報を提供する [15]。

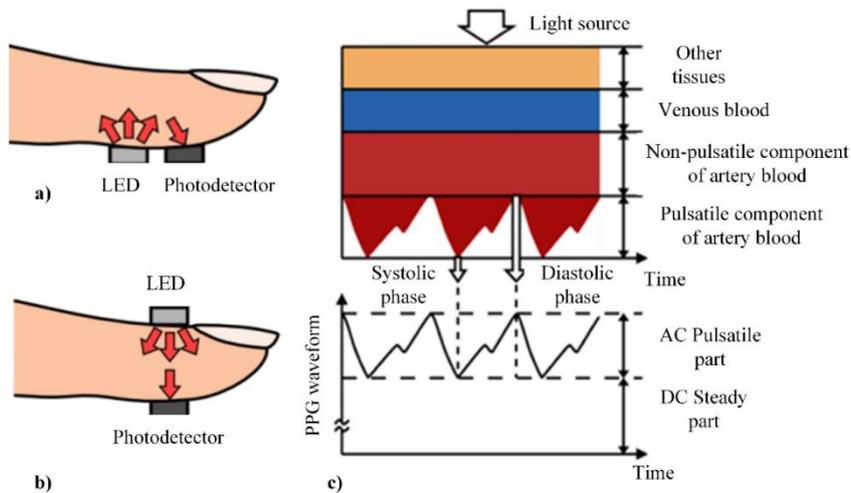


図 2.8 光電式容積脈波 (PPG) の原理 : (a) 散乱モード, (b) 透過モード, (c) PPG 信号の例 [16]

● 加速度センサ

加速度計は、慣性 3 次元座標系でコンポーネントの加速度を測定するために使用されている。それらは、サイズが小さく、比較的 low コストであり、既存のセンサネットワークプラットフォームに統合できる便利さから、人間のエネルギー消費の検出と行動認識において重要な役割を果たしている。

加速度計を利用する目的の 1 つは、人間のエネルギー消費を検出することである。加速度計を人体に装着すると、身体活動の頻度、運動強度、およびその他の情報を取得できる。エネルギー消費は、加速度計が取得した情報に基づいた一連のアルゴリズムによって推測できる。

人間のエネルギー消費量の検出と比較すると、行動認識は、加速度計だけでなく、他の慣性センサを使用して移動の方向と角度、およびその他の行動パラメータを認識するため、はるかに複雑である。さらに、生のセンサデータから活動情報を取得する必要があるため、信号処理プロセスはより複雑になる。一般に、加速度計はジャイロ스코プや磁力計と連携してより正確な測定を実現できる。参照[17]、加速度計のみを利用する EcoIMU と呼ばれる一種の慣性測定ユニット (IMU) が提示されており、線形加速度と角速度を正確に測定できる。一対の 3 軸加速度計で構成され、相対運動追跡から絶対運動追跡まで加速度計の適用範囲を拡大する。

図 2.9 は、大型から小型のウェアラブルデバイスやインプラントデバイスへのコンピュータの進化の一例を示したものである。診断と治療を中心とした従来の病院中心の医療システムから、危険因子の早期発見、診断、治療を重視する個人中心の医療システムへと移行しつつある [17][18]。

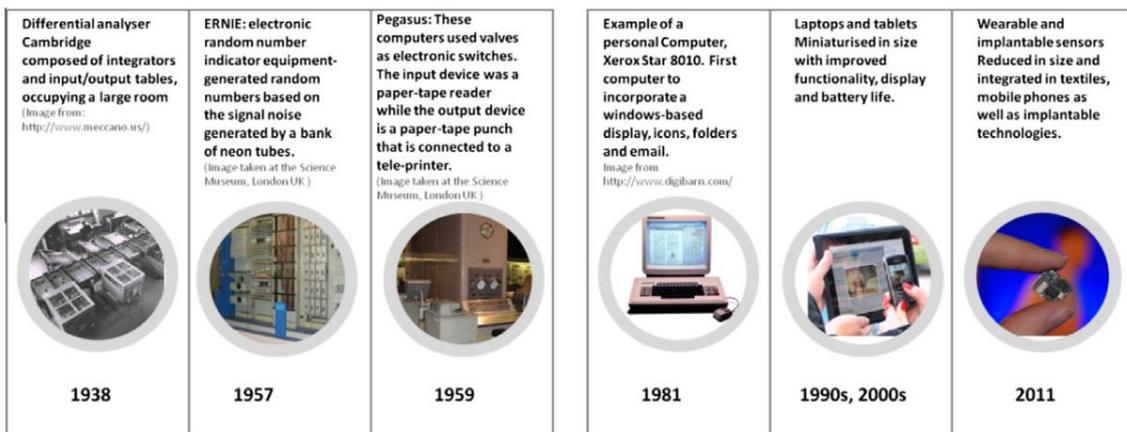


図 2.9 大型コンピュータからウェアラブルデバイスや埋め込み型デバイスまで、時間の経過に伴うコンピュータの進化の例。 [19]

文献 [20] で提案されているリモートシステム概念(図 2.10)によれば、ウェアラブルセンサを使用して生理学的および運動データを収集し、患者の状態モニタリングを可能にする。センサは、関心のある臨床応用に従って展開される。

- 健康とウェルネスのモニタリング

バイタルサイン（心拍数や呼吸数など）を監視するセンサは、たとえば、うっ血性心不全の患者や臨床的介入を受けている慢性閉塞性肺疾患の患者を監視するときにも展開される。

- 在宅リハビリテーション

動きのデータをキャプチャするためのセンサは、たとえば、脳卒中の生存者の在宅リハビリテーション介入の有効性や高齢者の移動支援機器の使用の監視などのアプリケーションに展開される。

- 安全監視

ワイヤレス通信は、患者のデータを携帯電話またはアクセスポイントに送信し、その情報をインターネット経由でリモートセンターに中継するために使用される。緊急事態（転倒など）は、システム全体に実装されたデータ処理によって検出され、アラームメッセージが緊急サービスセンターに送信され、患者に即時の支援を提供する。家族や介護者は、緊急事態が発生した場合に警告を受けるが、患者が薬を服用するなどの支援が必要な場合にも通知される可能性がある。臨床担当者は、患者の状態をリモートで監視し、医療上の決定が必要な場合に警告を受けることができる。

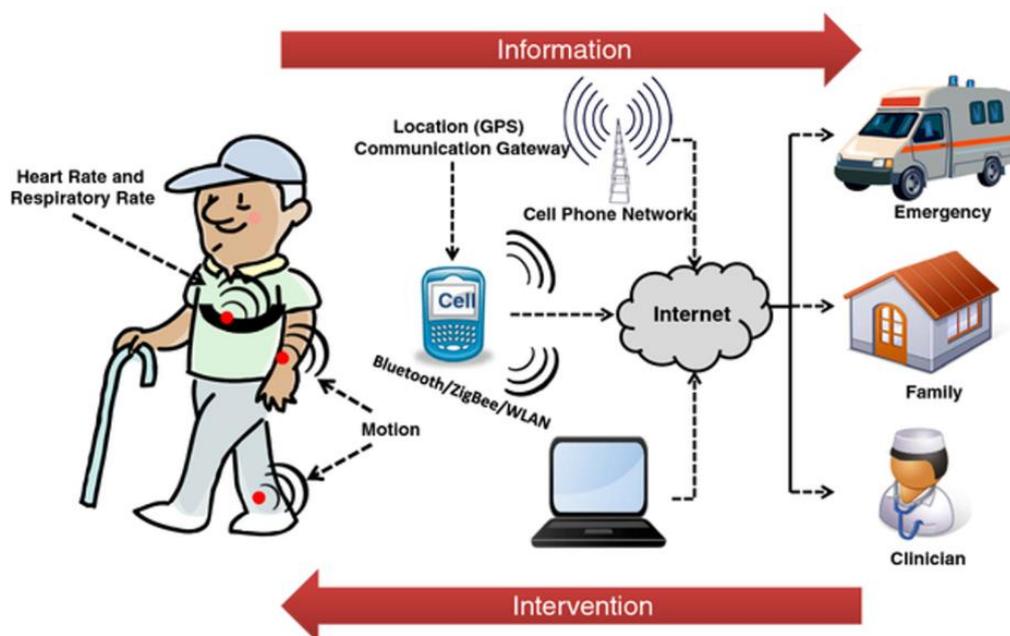


図 2.10 ウェアラブルセンサに基づくリモート健康監視システムの図[20]

バイタルサインの観察は臨床上の意思決定にとって重要だが、その正確さと適時性は改善の余地があると認識されている[21]。バイタルサイン測定における現在の課題の背後には、いくつかの理由がある。

バイタルサインの測定方法には、侵襲性と非侵襲性を含めてさまざまなものがあるが、まず電力や周波数などのセンサ機器の違いにより、データが同期しなくなる。次、文書化の正確性と完全性を含むバイタルサイン測定記録の品質、およびこの情報が臨床記録でどのように表示されるかは、臨床管理の決定に影響を与える可能性がある[22]。最後、バイタルサインを測定するための現在の標準治療法も、患者に不便や不快感を与える可能性がある。非侵襲的な手法の多くは、何らかの形で接触を伴うため、皮膚に炎症を起こすことがある[23]。モニタリング機器は危険をもたらす、患者のケア、移動、および睡眠を妨害する可能性があり、一方、その目立ちやすさは、例えば、重症患者を見舞う人に対して感情的に動揺させる可能性がある[24]。観察過程そのものから生じるストレスや不安も、患者の臨床状態を代表しない誤解を招く測定結果となることがある；例えば、「白衣効果」によって、他の環境では正常な血圧であるにもかかわらず、臨床評価中に血圧測定値が上昇することがある[25]。

また、メンタルヘルスは、個人の生活の質を決定する重要な要素である。生活の質に直接影響を与える可能性があるが、たとえば個人が意思決定プロセスに関与する方法を変更するなど、間接的な影響を与える可能性があり、生涯にわたる潜在的な長期的な影響をもたらす可能性がある[26]。

心理状態が主観的で文化的に制約されているだけでなく[27], [28], これについて懸念する理由があるという意味で、従来の方法論に固有の欠陥をますます認識している。たとえば、人々は自分の行動や経験に関する記憶が乏しく[29], 自分の行動の原因についての洞察力が乏しく[30], 理解できない行動について説明を求められた場合などである。意識せずに作話に従事する。このように、患者と医師の間にコミュニケーションの壁が形成され、治療の効率を低下させる可能性がある。

2.4 機械学習・ニューラルネット

● 機械学習

人工知能とは、コンピュータに人間と同様の知能を実現させる試みであり、1956年のダートマス会議において、ジョン・マッカーシーによって命名された。人工知能は計算機科学の一分野であり、認知科学や心理学、言語学といった学問分野と隣接している。

機械学習は人工知能における1つの分野であり、コンピュータが自動でルールやパターンを学習する方法である。機械学習では、機械学習アルゴリズムによって、事前に定められた方程式やモデルに頼らず、計算的な手法でデータから情報を学ぶ。機械学習は、データに潜む自然なパターンを見つけ出し、そこから洞察を導き、意思決定や未来予測に用いる。

機械学習の種類として、教師データを用いて訓練を行う教師あり学習と、教師データを用いずにモデルの内部演算によって訓練を行う教師なし学習がある。教師あり学習では、既にある入出力データを用いてモデルを訓練し、将来の出力を予測する。教師なし学習では、入力データに内在する隠れたパターンや固有の構造を発見する。

教師あり学習の目的は、不確かさがあっても証拠に基づいて予測を行えるモデルを構築することである。教師あり学習の処理は訓練と予測に分けられ、訓練ではすでにある一連の入力データとそれに対する応答（出力）を用いてモデルを訓練し、予測では新たなデータへの応答を合理的に予測できるようにする。

教師あり学習では、問題の対象によって、分類問題と回帰問題に分けられる。分類問題を解く分類モデルは、入力データを複数のカテゴリーに分類する。典型用途は、画像診断、音声認識、信用度評価などが挙げられる。回帰問題を解く回帰モデルは、連続的な応答を予測する。典型用途は、信号や株価等の時系列予測などが挙げられる。

教師なし学習の目的は、ラベル付けされた応答を持たない一連の入力データから推論を導き出すことである。教師なし学習の例としてクラスタリングがある。クラスタリングでは、探索的データ分析により、データ内の隠れたパターンやグループ構造を発見する。典型用途は、遺伝子分析、市場調査、物体認識などが挙げられる。

機械学習の種類を図2.11に示す。

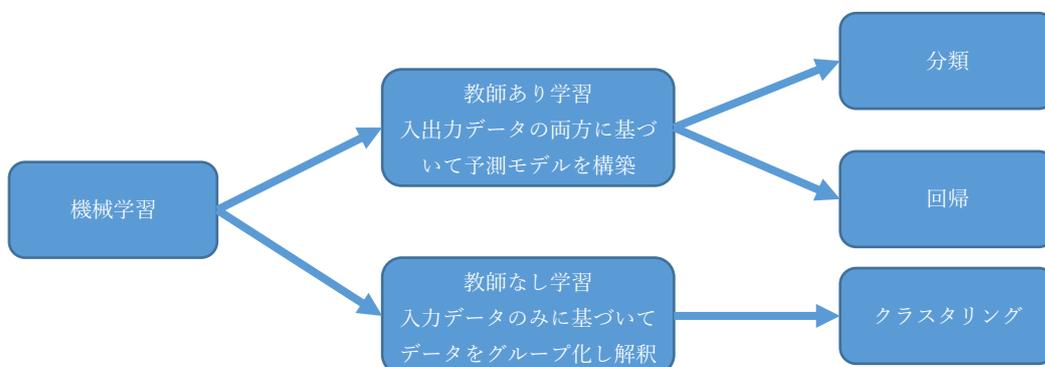
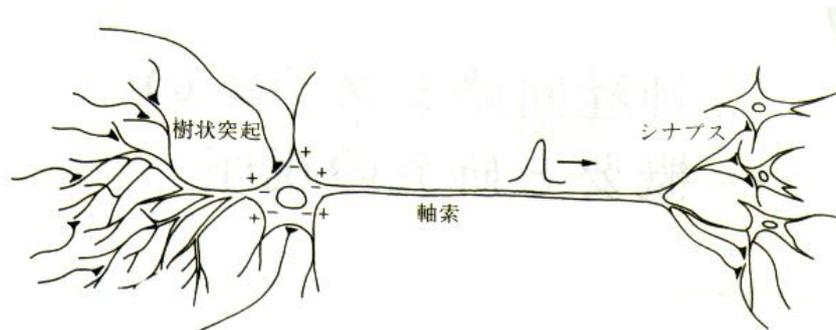


図 2.11 機械学習の種類

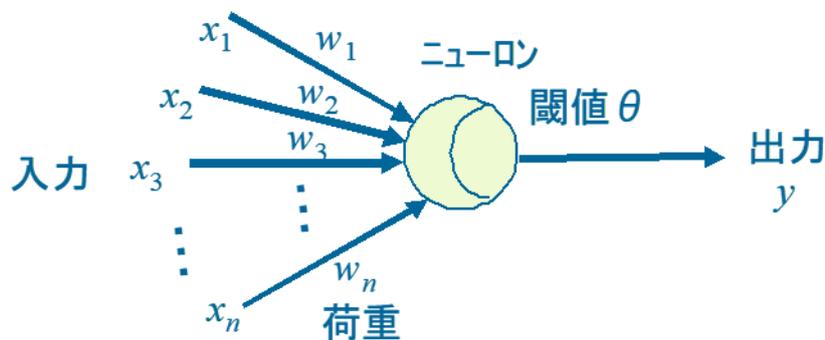
- ニューラルネット

ニューラルネットは機械学習を実現するための一手法であり，神経細胞の処理機構に基づく計算モデルである．ニューラルネットでは神経細胞の動作を抽象化して数理モデル化し，ネットワークとして取り扱う．深層学習は多層構造のニューラルネットを用いた機械学習法の1つであり，大規模なネットワークにより一般に特徴量を自動で抽出できるというメリットがある[31].

神経細胞のモデル化には，目的によって詳細なものから簡略なものまでさまざまな方法がある．例えばホジキン・ハックスレイのモデルは神経細胞の発火の様子を時系列信号として再現する．一方で工学的な使用を目的とした簡略なモデルとして，マカロック・ピッツのモデルからの人工ニューロンモデルは，計算の容易さから単純なニューラルネットから深層学習まで幅広く用いられる．人工ニューロンモデルでは，神経細胞の「シナプスで入力を制御」「他からの入力を集積」「閾値で興奮し情報を出力」という3つの特徴に着目し，「シナプス荷重」「電位加算」「閾値処理」といった手段で動作をモデル化する．生体の神経細胞と人工ニューロンモデルの比較を図 2.12 に示す[32].



(a)



(b)

図 2.12 生体の神経細胞と形式ニューロンモデルの比較[32]

人工ニューロンモデルは、複数の入力と一つの出力を有した計算素子である。各入力には数値が与えられ、与えられた数値はそれぞれの入力ごとに結合荷重(重み)と掛け合わされ、その結果が合算される。さらにこの合計値から閾値を引き算し、この値を適当な伝達関数によって変換した結果の値を、この人工ニューロンの出力とする。伝達関数は用途によってさまざまな関数がいられる。代表的なものとしては、0 または 1 の 2 値出力を与えるステップ関数、0 から 1 までの連続値を出力するシグモイド関数、入力値をそのまま出力するランプ関数がある。また、正規化線形関数 (Rectified Linear Unit: ReLU) と呼ばれる、負の入力に対して 0、正の入力に対してはランプ関数の値を出力する関数が、深層学習などでよく用いられる[31].

- 多層型ニューラルネット

人工ニューロンを層状に並べたモデルは、多層型ニューラルネットや階層型ニューラルネット、層状ニューラルネットなどと呼ばれる。通常が多層ネットワークを、ニューロン素子と荷重によって構成されるシステムとして、入出力間の変換関係に着目して考察する[32]. 多層ネットワークは入力と出力および入出力間の変換関数によって構成され、入力値は荷重との線形和として変換関数の引数となる。入出力関係は、

$$y_i = f\left(\sum_{j=1}^N w_{ij}x_j\right) \quad (2.1)$$

と表すことができる。ここで w_{ij} , x_j , y_i , f はそれぞれ荷重, 入力, 出力, 変換関数である。

入力ベクトル $\mathbf{X} = \{x_j\}$, ($j = 1, \dots, N$) と出力ベクトル $\mathbf{Y} = \{y_i\}$, ($i = 1, \dots, M$) をとる多層ネットワークを考える。学習時は、教師データセット $(\mathbf{X}', \mathbf{Y}')$: $\mathbf{X}' = \{x'_j\}$, ($j = 1, \dots, N$), $\mathbf{Y}' = \{y'_i\}$, ($i = 1, \dots, M$) によって荷重の修正を行う。まず入力層に入力 \mathbf{X}' を与え出力誤差 E を、

$$E = \sum_{i=1}^M (y_i - y'_i)^2 \quad (2.2)$$

により平均 2 乗誤差によって定義する。ここで $\mathbf{Y} = \{y_i\}$, ($i = 1, \dots, M$) は教師入力 \mathbf{X}' を与えたことによる出力である。この誤差は荷重 w_{ij} に関する E の偏微分

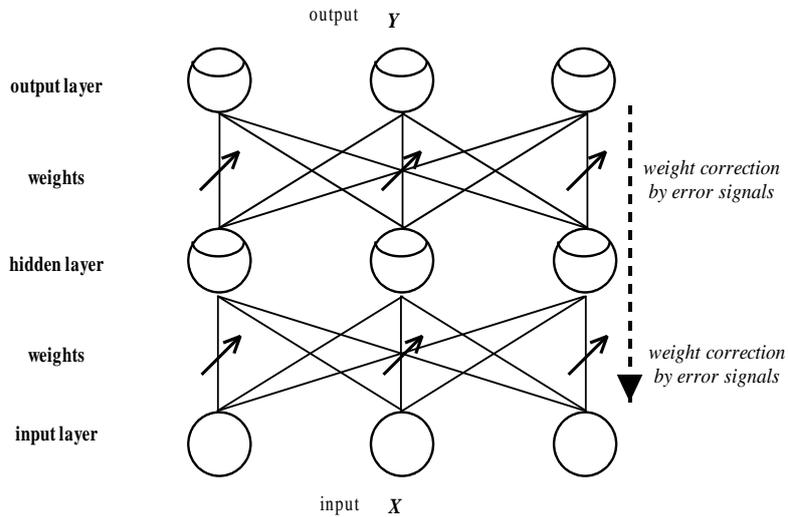
$$\frac{\partial E}{\partial w_{ij}} = -\delta_j y_i \quad (2.3)$$

を与える誤差信号 δ_j の形でネットワークの上層(出力層により近い層)から下層(入力層により近い層)へと伝搬される。この規則を用いると、荷重 w_{ij} は

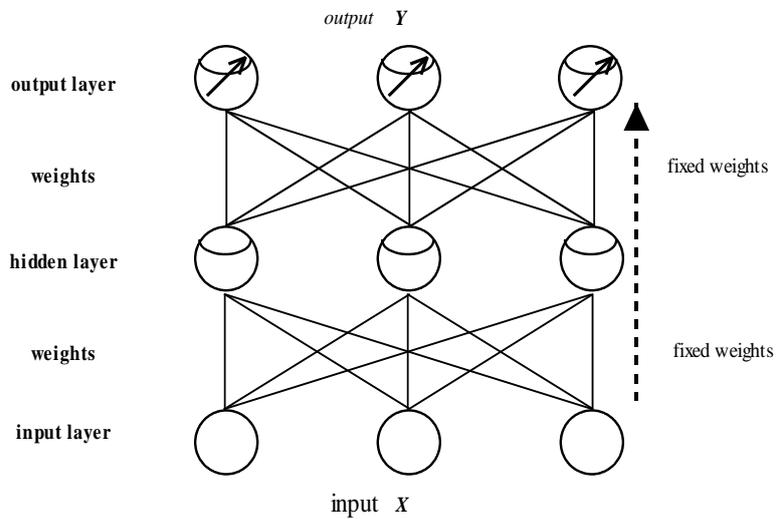
$$w_{ij}(t+1) = w_{ij}(t) + \varepsilon \delta_j y_i \quad (2.4)$$

によって修正される。ここで ε は学習係数である。この規則を繰返し用いることにより、ネットワークは荷重の形で順方向関係を徐々に構築する。

学習の完了したネットワークに対しては、学習によって得た w_{ij} を固定して、実入力ベクトル $\tilde{X} = \{\tilde{x}_j\}$, ($j=1, \Lambda, N$) を与え、それによって得られた出力ベクトル $\tilde{Y} = \{\tilde{y}_i\}$, ($i=1, \Lambda, M$) を解とする。多層ネットワークの学習および推定の動作を図 2.13 に示す。



(a)



(b)

図. 2.13 多層ネットワークの動作概念

(a) 学習動作 (b) 推定動作

- 逆問題解法のための多層ニューラルネットワーク

逆問題とは観測された現象から原因やその現象を起こす内部機構を推定する問題である。順問題が原因から結果を導くのに対し、逆問題は結果から原因を求める、または出力から入力を求めるものを指す[33]。多層ニューラルネットワークを信号の流れの観点から見ると、学習時に順方向関係を構築した上で、実行時にはその順方向関係を用いて順問題を解くものと言える。これに対して、まず結果を与え、学習時に確定した因果関係から原因を逆に推定するネットワークインバージョン[34]の方法によって、逆問題を解くことが可能となる。

通常多層ネットワークは誤差逆伝搬法によって層間荷重に順方向の入出力関係を構成する。通常の誤差逆伝搬法では、出力誤差が荷重の誤りによって生じるという仮定に基づいて荷重の修正を行う。一方、荷重 w_{ij} と入力 x_j の間の双対性に基づき、式(2.5)において、出力誤差が入力の誤りによるものと仮定して、荷重の代わりに入力を修正することが可能である。ここで w_{ij} は層間荷重、 x_j は入力、 y_i は出力、 f は素子の入出力関係を表す関数である。これは、荷重を修正する代わりに、荷重 w_{ij} を固定したまま入力 x_j をデルタ則によって変化させることを意味する。この手法はネットワークインバージョンと呼ばれる。

学習時は、通常ネットワークと同様、前項の式(2.6)~(2.7)によって荷重の修正を行う。推定時は、学習で得られた荷重を固定し、入力層に仮の入力ベクトル $\mathbf{X}^0 = \{x_j^0\}$, ($j = 1, \dots, M$) を与える。そして実出力データ $\tilde{\mathbf{Y}} = \{\tilde{y}_i\}$, ($i = 1, \dots, M$) を用いて入力の修正を行う。まず入力 \mathbf{X}^0 によって生じる出力 $\mathbf{Y} = \{y_i\}$, ($i = 1, \dots, M$) と $\tilde{\mathbf{Y}}$ によって出力誤差 E を

$$E = \sum_{i=1}^M (y_i - \tilde{y}_i)^2 \quad (2.5)$$

のように計算し、この誤差を入力 x_j に関する E の偏微分係数

$$\frac{\partial E}{\partial x_j} = -\delta_j \quad (2.6)$$

を与える誤差信号 δ_j の形でネットワークの上層から下層へと伝搬する。この規則を用いると、入力 x_j は

$$x_j(t+1) = x_j(t) + \eta \delta_j \quad (2.7)$$

によって修正される。ここで η は学習における学習係数に相当する荷重修正係数である。この規則を繰返し用いることにより、学習で構築された順方向関係を逆に用いて、出力から入力を徐々に推定できる。ネットワークインバージョンによる処理での学習動作および推定動作をそれぞれ Fig.2.14(a),(b)に示す。

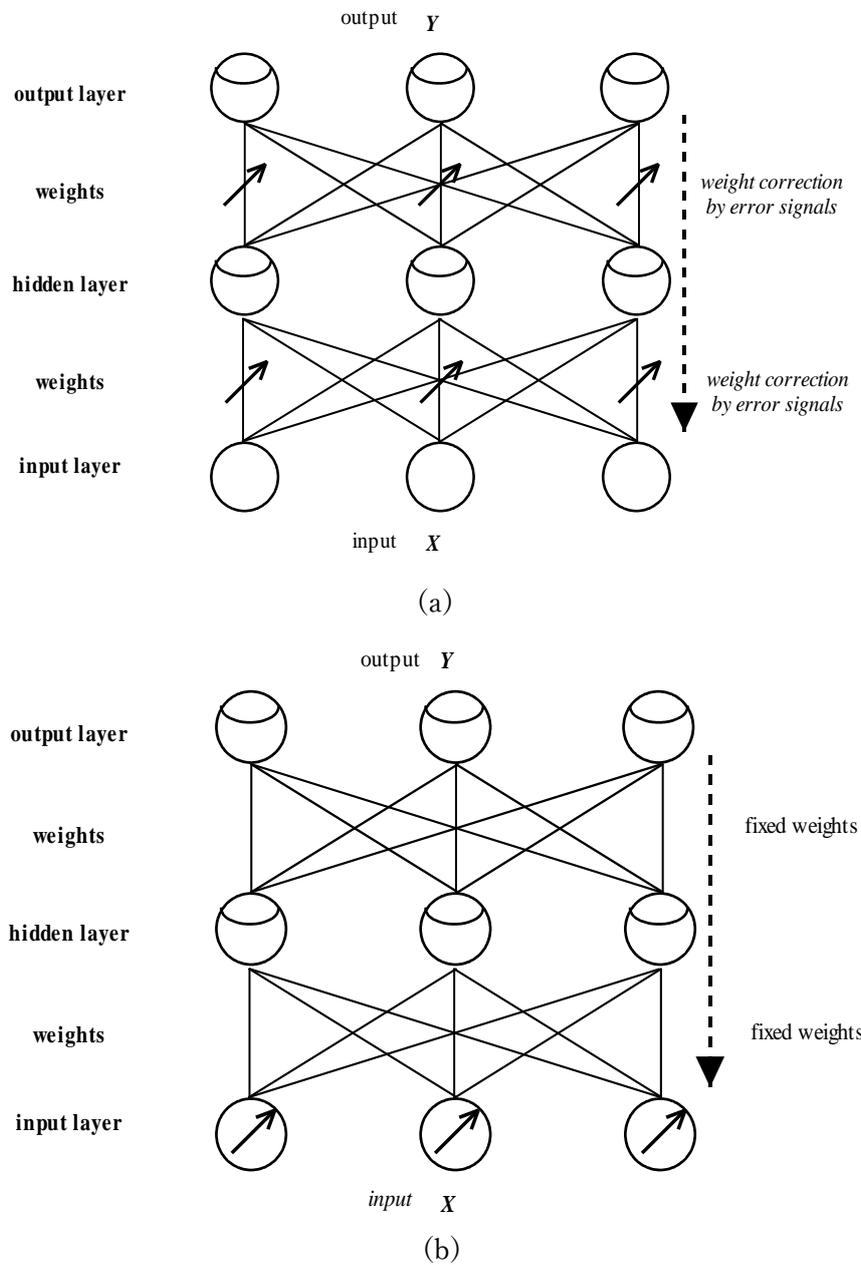


図 2.14 ネットワークインバージョンの動作概念

(a) 学習動作 (b) 逆推定動作

● 深層学習

深層学習またはディープラーニング (Deep Learning) は、大規模かつ複雑化したニューラルネットワーク技術の一種である。深層学習の技術を用いると、ニューラルネットワークを用いて大規模なデータを学習することが可能となる。深層学習は、世界的な画像認識に関する学術的なコンテストである Large Scale Visual Recognition Challenge (ILSVRC) の 2012 年の大会において、ジェフリー・ヒントンらによる AlexNet というシステムによって圧倒的な成績で優勝したことで注目を集め始めた。AlexNet は畳み込みニューラルネットワーク (Convolutional Neural Network: CNN) という種類のモデルで、生物の視覚神経系の構成にヒントを得たニューラルネットワークである。このモデルでは、畳み込み層によって画像フィルタを画像全域にわたって適用し、プーリング層によって画像を局所的に平均化する。畳み込み層とプーリング層を何層も重ねることで、画像の特徴を抽出する。

深層学習が発展してきた主な理由は以下の通りである。

- ・ ハードウェア技術の発展： CPU の高速化やマルチコア化、一般の計算処理に GPU を用いる GPGPU 技術、メモリの大容量化など。
- ・ ビッグデータの利用可能性： インターネットの発展、IoT 技術の進展。
- ・ ニューラルネットワーク学習技術： 出力関数や誤差評価の改善など学習技術の向上。
- ・ ニューラルネットワークの構造： 畳み込みニューラルネットワーク (CNN) や自己符号化器 (AutoEncoder)、長・短期記憶 (Long-Short Term Memory: LSTM)、敵対的生成ネットワーク (Generative Adversarial Network: GAN) など、新しいモデルの提案。

AlexNet の成功により、画像認識の分野を中心に深層学習の研究が進められてきた。深層学習は画像認識だけのための手法ではなく、信号解析や時系列予測、自然言語処理など幅広い分野に適用可能な技術である [31]。

本研究においても、多層ニューラルネットワークに加えて深層学習の手法も用いることとする。

第2章の参考文献

- [1] W. H. Organization, *World Report on Ageing and Health*. World Health Organization, 2015.
- [2] K. KINSELLA and D. R. PHILLIPS, “Global aging: the challenge of success,” *Population Bulletin*, vol. 60, no. 1, pp. 3–40, Mar. 2005.
- [3] “厚生労働省,厚生労働統計一覧 ,人口動態調査.”
- [4] “厚生労働省,医療保険データベース,医療保険に関する基礎資料.” [Online]. Available: <https://www.mhlw.go.jp/bunya/iryohoken/database/>
- [5] S. P. Gulley, E. K. Rasch, and L. Chan, “Ongoing Coverage for Ongoing Care: Access, Utilization, and Out-of-Pocket Spending Among Uninsured Working-Aged Adults with Chronic Health Care Needs,” *Am J Public Health*, vol. 101, no. 2, pp. 368–375, Feb. 2011, doi: 10.2105/AJPH.2010.191569.
- [6] “厚生労働省 , 人口動態統計「報告書」.” [Online]. Available: <https://www.mhlw.go.jp/toukei/list/81-1a.html#link07>
- [7] 野村真美, 田中美穂, and 出口真弓, “小児医療の現状と今後に向けての提言,” 日本医師会総合政策研究機構, Apr. 2016. Accessed: Dec. 12, 2022. [Online]. Available: <https://www.jmari.med.or.jp/result/working/post-781/>
- [8] 中村知夫, “医療的ケア児に対する小児在宅医療の現状と将来像,” *Organ Biology*, vol. 27, no. 1, pp. 21–30, 2019, doi: 10.11378/organbio.27.21.
- [9] 厚生労働省, 小児医療に関するデータ, <https://www.mhlw.go.jp/file/05-Shingikai-12401000-Hokenkyoku-Soumuka/0000096261.pdf>
- [10] X. Teng and Y.-T. Zhang, “[M-health: trends in wearable medical devices],” *Zhongguo Yi Liao Qi Xie Za Zhi*, vol. 30, no. 5, pp. 330–340, Sep. 2006.
- [11] 藤野智子, 三浦英恵, and 村田洋章, 基礎と臨床がつながるバイタルサイン. 学研メディカル秀潤社, 2014.
- [12] “Safe system framework for children at risk of deterioration. Royal College of Paediatrics and Child Health.,” *RCPCH*, 2018. <https://www.rcpch.ac.uk/resources/safe-system-framework-children-risk-deterioration> (accessed Dec. 01, 2022).
- [13] I. Lee, N. Park, H. Lee, C. Hwang, J. H. Kim, and S. Park, “Systematic Review on Human Skin-Compatible Wearable Photoplethysmography Sensors,” *Applied Sciences*, vol. 11, no. 5, Art. no. 5, Jan. 2021, doi: 10.3390/app11052313.
- [14] J. Přibíl, A. Přibílová, and I. Frollo, “Comparative Measurement of the PPG Signal on Different Human Body Positions by Sensors Working in Reflection and Transmission Modes,” *Engineering Proceedings*, vol. 2, no. 1, Art. no. 1, 2020, doi: 10.3390/ecsa-7-08204.

- [15] Y. Liang, Z. Chen, R. Ward, and M. Elgendi, "Hypertension Assessment Using Photoplethysmography: A Risk Stratification Approach," *J Clin Med*, vol. 8, no. 1, p. 12, Dec. 2018, doi: 10.3390/jcm8010012.
- [16] T. Tamura, Y. Maeda, M. Sekine, and M. Yoshida, "Wearable Photoplethysmographic Sensors—Past and Present," *Electronics*, vol. 3, no. 2, pp. 282–302, Apr. 2014, doi: 10.3390/electronics3020282.
- [17] Y.-L. Tsai, T.-T. Tu, H. Bae, and P. H. Chou, "EcoIMU: A Dual Triaxial-Accelerometer Inertial Measurement Unit for Wearable Applications," in *2010 International Conference on Body Sensor Networks*, Singapore, Singapore, Jun. 2010, pp. 207–212. doi: 10.1109/BSN.2010.47.
- [18] J. Qi, P. Yang, A. Waraich, Z. Deng, Y. Zhao, and Y. Yang, "Examining sensor-based physical activity recognition and monitoring for healthcare using Internet of Things: A systematic review," *Journal of Biomedical Informatics*, vol. 87, pp. 138–153, Nov. 2018, doi: 10.1016/j.jbi.2018.09.002.
- [19] L. Atallah, B. Lo, and G.-Z. Yang, "Can pervasive sensing address current challenges in global healthcare?," *Journal of Epidemiology and Global Health*, vol. 2, no. 1, pp. 1–13, Mar. 2012, doi: 10.1016/j.jegh.2011.11.005.
- [20] S. Patel, H. Park, P. Bonato, L. Chan, and M. Rodgers, "A review of wearable sensors and systems with application in rehabilitation," *J NeuroEngineering Rehabil*, vol. 9, no. 1, p. 21, 2012, doi: 10.1186/1743-0003-9-21.
- [21] C. H. V. Leuvan and I. Mitchell, "Missed opportunities? An observational study of vital sign measurements," *Crit Care Resusc*, vol. 10, no. 2, pp. 111–115, Jun. 2008.
- [22] S. J. Wilson *et al.*, "Track and trigger in an emergency department: an observational evaluation study," *Emerg Med J*, vol. 30, no. 3, pp. 186–191, Mar. 2013, doi: 10.1136/emered-2011-200499.
- [23] J. S. Murray, C. Noonan, S. Quigley, and M. A. Q. Curley, "Medical device-related hospital-acquired pressure ulcers in children: an integrative review," *J Pediatr Nurs*, vol. 28, no. 6, pp. 585–595, 2013, doi: 10.1016/j.pedn.2013.05.004.
- [24] J. Hope *et al.*, "A fundamental conflict of care: Nurses' accounts of balancing patients' sleep with taking vital sign observations at night," *J Clin Nurs*, vol. 27, no. 9–10, pp. 1860–1871, May 2018, doi: 10.1111/jocn.14234.
- [25] T. G. Pickering, A. Coats, J. M. Mallion, G. Mancia, and P. Verdecchia, "Blood Pressure Monitoring. Task force V: White-coat hypertension," *Blood Press Monit*, vol. 4, no. 6, pp. 333–341, Dec. 1999, doi: 10.1097/00126097-199912000-00006.
- [26] S. J. Bishop and C. Gagne, "Anxiety, Depression, and Decision Making: A Computational Perspective," *Annual Review of Neuroscience*, vol. 41, no. 1, pp. 371–

- 388, 2018, doi: 10.1146/annurev-neuro-080317-062007.
- [27] J. R. Betancourt, A. R. Green, J. E. Carrillo, and E. R. Park, “Cultural competence and health care disparities: key perspectives and trends,” *Health Aff (Millwood)*, vol. 24, no. 2, pp. 499–505, 2005, doi: 10.1377/hlthaff.24.2.499.
- [28] B. C. Schouten and L. Meeuwesen, “Cultural differences in medical communication: a review of the literature,” *Patient Educ Couns*, vol. 64, no. 1–3, pp. 21–34, Dec. 2006, doi: 10.1016/j.pec.2005.11.014.
- [29] D. E. Stull, N. K. Leidy, B. Parasuraman, and O. Chassany, “Optimal recall periods for patient-reported outcomes: challenges and potential solutions,” *Curr Med Res Opin*, vol. 25, no. 4, pp. 929–942, Apr. 2009, doi: 10.1185/03007990902774765.
- [30] S. Vazire and M. R. Mehl, “Knowing Me, Knowing You: The Accuracy and Unique Predictive Validity of Self-Ratings and Other-Ratings of Daily Behavior,” *Journal of Personality and Social Psychology*, vol. 95, no. 5, pp. 1202–1216, Nov. 2008, doi: 10.1037/a0013314.
- [31] 小高知宏, 「基礎から学ぶ人工知能の教科書」 オーム社, 2019.
- [32] 小杉幸夫, 「神経回路システム—基礎と応用—」 コロナ社, 1995.
- [33] C. W. Groetsch: *Inverse Problems in the Mathematical Sciences*, Informatica International (1993)
- [34] A. Linden and J. Kindermann: *Inversion of Multilayer Nets*, Proc. of the International Joint Conference on Neural Networks, 425/430 (1989)

第3章 バイタルサイン計測を目的とした生体状態評価システムの構成

3.1 マイコンによるバイタルサイン計測

バイタルサインは人間の生命兆候であり、看護や臨床医学の場で重視されている。バイタルサインは、一般には体温・心拍・血圧・呼吸の4つを指す場合が多く、これらを計測し患者の病態を迅速に把握することが必要とされている[1][2]。一方で、バイタルサインは精神や感情状態に応じて変化するため、それらの変化を計測することで感情状態を推定することが試みられている[3]。また、個人の感情状態だけでなく、人と人の間の感情状態の推定の試みも発表されている[4]。

本節では、4つのバイタルサインである体温・心拍・血圧・呼吸を測定し、それらのデータから感情状態を推定することを考える。上記を、簡便なセンサとマイコンを用いたシステムで実現することを目的とする。

3.1.1 バイタルデータ計測のためのマイコンとセンサ

対象は体温と心拍、血圧、呼吸とし、安価で簡便な測定のために、サーミスタによる温度センサと光電脈波センサを用いたシステムを考える。体温についてはサーミスタによる温度センサを用い体表の温度を計測する。心拍については光電脈波センサによる計測で代用し指先の脈波を計測する。血圧は一般にカフ式の血圧計を用いて測定するが多いが、脈波の伝搬速度による計測方法も提案されている[2]。そこで、腕の前腕筋と指先に取り付けた光電脈波センサから脈波伝搬速度を求めることを考える。呼吸については、マスクにサーミスタを取り付け呼気による温度変化により推定する。

体温と呼吸の測定を行う温度センサとして、サーミスタを用いる。サーミスタは温度の変化により抵抗値が変化する素子である。本節では、村田製作所の NTC サーミスタ 10k Ω (NXFT15XH103FA2B050)を用い、抵抗による分圧回路を構成してサーミスタの両端の電圧を Arduino[5]のアナログ入力で計測する。体温はアナログ入力から求めた温度をそのまま用い、呼吸についてはマスクの口の部分に取り付けたサーミスタにより測定した呼気と吸気の温度差により測定する。心拍と血圧の測定は脈波センサにより測定する。本節では、Sparkfun のパルスセンサ(SEN-11574)を用い、センサの出力を Arduino のアナログ入力に計測する。心拍は指先に装着したセンサで得られた脈波で計測し、血圧は前腕筋と指先に装着したセンサで得た脈波により脈波伝搬速度を求めることを考える。

温度センサの分圧回路への入力として Arduino の 5.0[V]出力を用い、脈波センサは 3.3[V]出力を用いる。2つの温度センサと2つの脈波センサを Arduino のアナログ入力 A0～A3 に接続し、それぞれのセンサからの値を計測する。図 3.1 にマイコンとセンサを用い

たバイタルデータ計測の構成を示す。

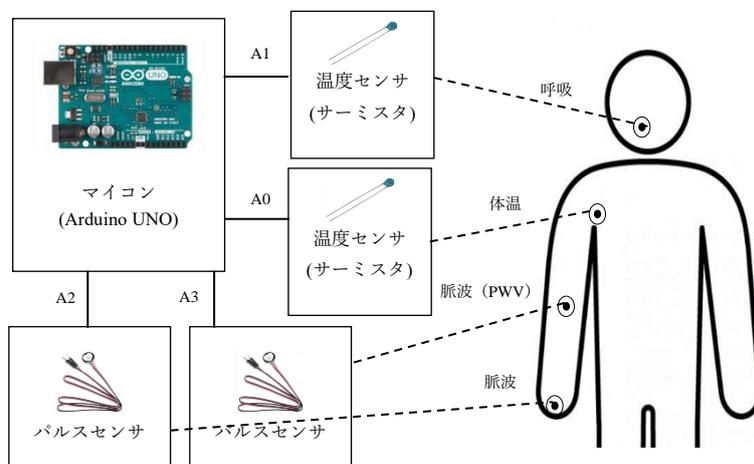


図 3.1 マイコンとセンサを用いた生体データの計測

3.1.2 感情状態の推定

4つのセンサから得られた生体データから、感情状態を推定することを目的に実験を行う。学習には、教師あり機械学習に基づく分類学習法を用いる。本節では分類する状態として、安静状態と作業状態、運動状態の3つを考え学習及び分類を行う。作業状態は、キーボードによるタイピング作業、運動状態は鉄アレイで負荷をかけた腕の上下運動とし、安静状態は何も行わない状態とする。今回の実験ではそれぞれを30秒ずつ継続して行い、その間の波形を計測した。分類学習器には、一定時間内の波形の最大値を学習・分類データとして与えた。

分類学習にはMATLAB[6]の分類学習器を用いた。予測子の数は4、観測値の数は90、クラスの数は3で、応答はそれぞれの状態とした。検定方式は交差検証とし分割数を5とした。分類学習の方法は、決定木、線形判別、線形SVM、最近傍法の4通りとした。

3.1.3 実験

最初に、測定した波形のうち、脈波センサで測定した指先の脈波波形及び、温度センサで測定した呼吸波形のうち、安静状態のものを図3.2に示す。脈波についてはほぼ正確に測定できており、呼吸についても呼気による温度の変化が正しく測定できていることが判る。ただし脈波伝搬速度については、2つの脈波センサ間の距離が短く、サンプリング時間が十分

でないため正確に測定できなかった。今回は 4 つのセンサから得た波形をもとに感情の状態を推定する。

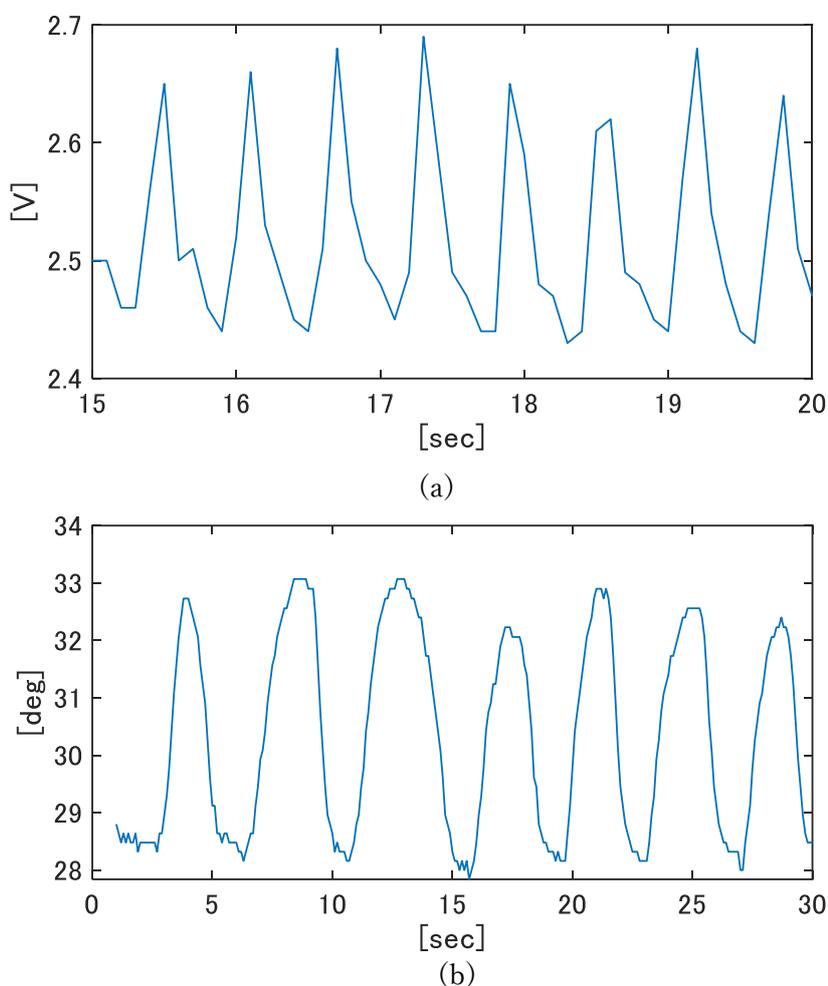


図.3.2 安静時の指先脈波および呼気温度

(a)指先脈波 (b)呼気温度

状態の推定結果として、それぞれの分類法と分類結果の正解率を表 3.1 に、正解率が最も高かった SVM による分類結果の混合行列による評価を表 3.2 に示す。分類法による正解率については、どの方法においてもほぼ 90%前後となったが、中でも SVM を用いた場合に 95.4%と最も高い正解率となった。また SVM による分類結果の混合行列によると、作業状態については 100%の正解率だが、安静状態および運動状態においては不正解が見られた。

結果として、マイコンと安価なセンサによるシステムによるバイタルデータからの感情状態の推定の可能性を示した。

表 3.1 3つの状態の分類結果

分類学習法	正解率
決定木	88.5%
判別分析（線形判別）	92.0%
SVM（線形SVM）	95.4%
最近傍法（KNN）	92.0%

表 3.2 SVMによる分類結果の混同行列による評価

		予測されたクラス		
		安静	作業	運動
真のクラス	安静	97%	3%	0%
	作業	0%	100%	0%
	運動	0%	10%	90%

3.1.4 マイコンによるバイタルサイン計測のまとめ

本節では、4つのバイタルサインである体温・心拍・血圧・呼吸を測定し、感情状態を推定するシステムを、簡便なセンサとマイコンで実現した。体温はサーミスタによる温度センサ、心拍は光電脈波センサ、血圧はもう1つの光電脈波センサによる脈波伝搬速度(PWV)、呼吸は呼気による温度変化をサーミスタ温度センサで測定する方法を採用し計測実験を行った。結果より、マイコンとセンサによる簡便なシステムでも、十分にバイタルサインの測定方法の議論や検討を行うプロトタイプとして用いることが可能であることが示された。本節の結果に基づき、以降ではマイコンとセンサによる構成を基本として研究を進めていくこととする。

3.2 抱きつき型システム

バイタルサインのモニタリングは、日々の健康管理や医療診断に欠かせないものである[7]。定期的な身体モニタリングのために病院を訪れることは不可欠である。しかし、すべてのバイタルサインを1つ1つ検査することは時間を消費し患者の負担を増加させるだけでなく、限りある医療従事者のマンパワーの有効活用の点からも問題がある。また、多くの患者、特に子どもは病院で医師に会うことを非常に緊張し、恐れを感じている。そのため、日常的な診察で患者に不安を与えにくいだけでなく、必要なバイタルサインを一度に正確かつスムーズに測定できるシステムを目指すことが重要である。これらの問題を解消するために、本節では抱きつき型のバイタルサイン測定システムを提案する。抱きつきやすい形状で患者に緊張感を与えず、簡単なバイタルサイン測定で医療支援を行うことを目的とする。バイタルサインとは、体温、呼吸数[8]、心拍数[9]、収縮期血圧（SP）、拡張期血圧（DP）[10]などを指す。近年、バイタルサインを監視するための様々な手法やシステムが開発されている[11][12]。体温については、水銀の熱膨張を利用する方法、サーミスタ方式、赤外線方式などがある。呼吸については、マスクを用いて呼吸流量を測定する方法[13]や、胸部や腹部の周径の変化を単純に捉える方法[9]がある。また、エアバッグやぬいぐるみに圧力センサを接続して測定する方法も提案されている[14]。心拍は、胸部の心電図に電極を接続して測定する方法や、血管の容積変化を波形としてとらえる脈波法によって測定する方法がある。血圧は通常カフを用いて測定するが、カフを用いずに脈波伝播速度で血圧を推定する方法もある[15]。

本節では、患者が抱きつくことで重要な情報を自然に測定するシステムの構成を検討した。重要な情報としては、体温、呼吸、心拍の計測を目指した。マイコンとセンサを用いて簡易なプロトタイプを構築し、3つのバイタルサインを同時に計測することを検討する。

バイタルサインは人間の生命の証であり、看護や臨床医学で重視されている。バイタルサインは、一般に体温、心拍数、血圧、呼吸の4つのパラメータを指し、これらを測定することで患者の状態を迅速に把握することが必要である[16]。本節では、患者が抱きついた状態でバイタルサインを自然に計測するシステムを構築した。迅速な生命情報計測のために、システム構成の形状・デザインから診断・治療時の不安・症状の緩和まで多角的な検討を行う。本節では、抱きつき型の形状として直径約30cmの球体を採用し、各種センサを接続してマイコンのバイタル情報を取得・測定することを検討する。

簡易的なバイタル情報計測システムとして、マイクロコンピュータとセンサを用いた構成を検討した。対象は体温、心拍、呼吸で、安価で簡易に測定できるように赤外線温度センサ、光電脈波センサ、ジャイロセンサを利用した。体温は、赤外線温度センサで体表面の温度を測定した。心拍については、光電脈波センサを用いて指先の脈波を測定した。呼吸については、球体にジャイロセンサを取り付け、呼吸による球体の変位を推定する方法を採用した。図3.3に、マイクロコンピュータとセンサを用いたバイタルデータ計測の構成を示す。

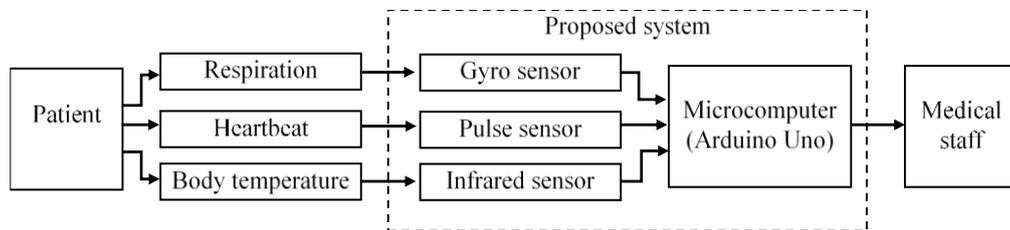
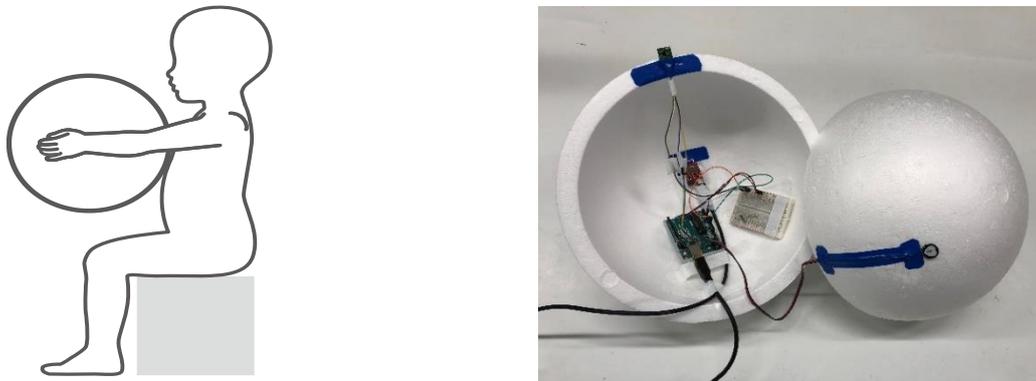


図 3.3 (a) 抱きつき型システムのコンセプト (b) 抱きつき型システムのプロトタイプ
(c) センサ付きマイコンを用いたバイタルサインの計測システム

3.2.1 体温

体温とは、体の温度である。心臓や脳など体の深部の温度を指し、心理的には心臓から出た直後の大動脈の血液の温度を意味する。体内温度を測定することは困難であるため、より体内に近い温度を求め、大動脈、口腔、直腸、鼓膜など測定が容易な部分の温度を測定し、体内温度として活用する。

人体の体温分布から、小児医療を目指す場合、顔の温度を示すオムロン MEMS 非接触温度センサ (D6T-44L06) の非接触測定が有利であると想像された。

そこで、本節では、MEMS 非接触型赤外線温度センサを抱きかかえ型システムに取り付け、生体温度情報を計測し、その基本性能と効果を検証した。被験者が抱っこ型システムを持ち、MEMS 非接触温度センサを顔の方に向け、体温を測定した。また、被験者の顔と MEMS 非接触温度センサの距離は約 20cm であった。

3.2.2 呼吸数

呼吸数 (RR) は、他のバイタルサインと組み合わせて患者の早期警戒スコアを導き出すことができる重要な生理学的測定値である [17].

まず、マスクにサーミスタを取り付け、吐く息と外気の温度差から呼吸を推定する方法を検討した。サーミスタとは、温度変化により抵抗値が変化する素子である。サーミスタと抵抗で回路を構成し [13], Arduino のアナログ入力を用いてサーミスタの電圧を測定した。これにより、呼気の温度差から呼吸を計測できることが確認された。サーミスタを用いた上記の方法は、吐く息から直接呼吸を計測できるため有効であるが、マスクなどに取り付けたサーミスタを口元に当て、吐く息の温度を計測する必要がある。これは、実際の測定に手間がかかるため現実的ではなく、違和感なく自然に測定できる方法の検討が必要である。

本節では、上記の理由から、ジャイロセンサを用いた呼吸計測を抱きつき球体に取り付けを行う方法を紹介し、その効果を検証する。腹部運動による呼吸信号を推定する方法として、加速度センサを用いる方法が提案されている。感度の観点から加速度、ジャイロ、磁気を測定できる安価な 9 軸センサを検討した結果、前述のとおり 3 軸ジャイロセンサを使用することにした。

本節では、抱きつきシステムの動きを 3 軸ジャイロセンサで検出し、腹部の変位として計測することで呼吸を計測した。

利用したジャイロセンサは、SparkFun 社の 9DoF Razor IMU M0 を発泡スチロールの球体の内側に貼り付けた。このセンサは、加速度、ジャイロ、磁気の 3 軸をそれぞれ持つ 9 軸センサであるが、今回は 3 軸のジャイロセンサとして利用した。今回は評価ボードを採用したため、マイコンを介さずに USB ケーブルで直接 PC と接続できるため、実際には球体にセンサを取り付け、USB ケーブルで直接 PC と接続して波形を取得する。

得られた軸の回転角度を g_x , g_y , g_z とし、その絶対値を平均することで腹部の変位を測定した。

$$g_{ave} = \frac{|g_x| + |g_y| + |g_z|}{3} \quad (3.1)$$

ここで、腹部からの垂直方向がジャイロセンサの z 軸、高さ方向が y 軸、左右方向が x 軸方向となるように球体を保持することが基本形となる。この式で絶対値を計算することで、ジャイロセンサの向きに関係なく、腹部の変位を測定することができた。

測定されたジャイロセンサの 3 軸波形を図 3.4(a) に示す。この測定波形から、 Y 軸ジャイロセンサは呼吸動作を反映できると判断できる。しかし、本節では、ボールの抱きつき方向による軸変化から、呼吸数を求めるために、3 軸平均法を採用した。式(3.1)を用いた波形平均を図 3.4(b) に示す。3 軸ジャイロセンサが呼吸数を正確にフィットさせることができることが確認できる。

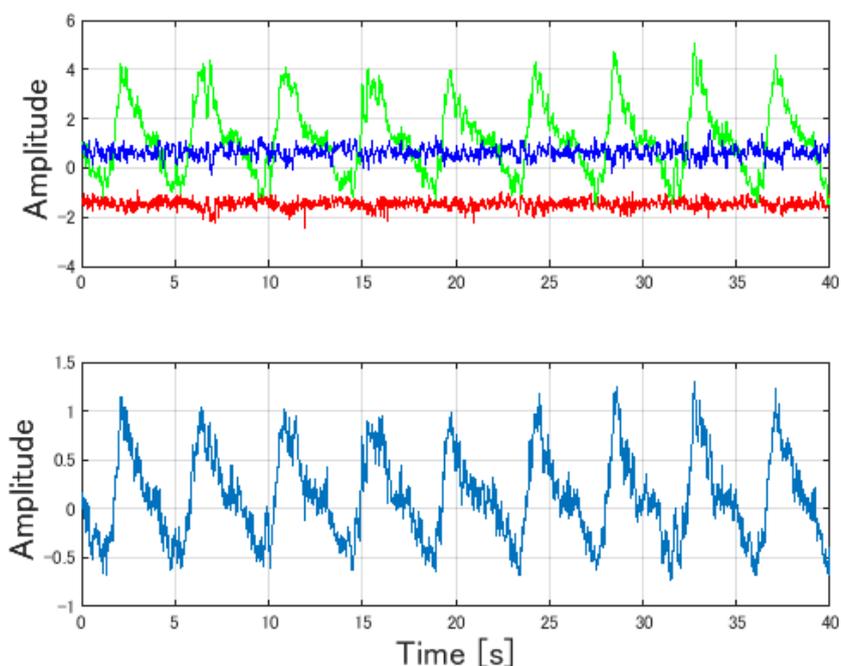


図 3.4 (a) 3 軸ジャイロセンサの x, y, z 軸の値 (b) 式(3.1)より計算された波形

3.2.3 脈拍

光電式容積脈波 (PPG) は、組織、血管、血液の光学的特性と光の相互作用を非侵襲的に利用するもので、心血管系や呼吸器系の物理パラメータを推定するためによく利用される [18]。また、光電式容積脈波 (PPS) は、組織、血管、血液の光学的特性、および、心電図、脈拍、脈拍数などの計測に利用される。心拍数を検出するための非侵襲的な方法としての PPG の採用は、1938 年に Hertzman [19], [20] によって実証され、鉛筆の懐中電灯と心電計に接続した光電池を用いて、血管の脈動による充血と離開を通して心周期を記録した。今日の PPG センサは、Hertzman が紹介した装置と同じ原理を採用しているが、最新の発光ダイオード (LED)、フォトダイオード、マイクロコントローラを用いて小型化されている [18]。

脈拍とは、心拍 (心臓の拍動) によって大動脈に送り出された血液が末梢動脈に伝播する波であり、心拍に伴う動脈の圧力の変化を体表から感知することができる。赤外線や赤色光、あるいは 550nm 前後の緑色の波長の光を生体に照射し、入射光を吸収する性質があるため、フォトダイオードやフォトトランジスタを用いて心臓の脈動に伴って血流量を変化させることができる。血管の容量の変化を時系列で感知することで、脈波信号を測定することがで

きる。指先の脈波を取得するセンサとして、Sparkfun 社のパルスセンサ (SEN-11574) を採用した。脈拍は Arduino マイコンを用いて波形を取得した。

図 3.5 (a) は、本実験で測定した脈波信号の一部を表示したものである。また、この波形は FFT アルゴリズムを用いて算出した周波数スペクトル分布を図 3.5 (b) に示す。

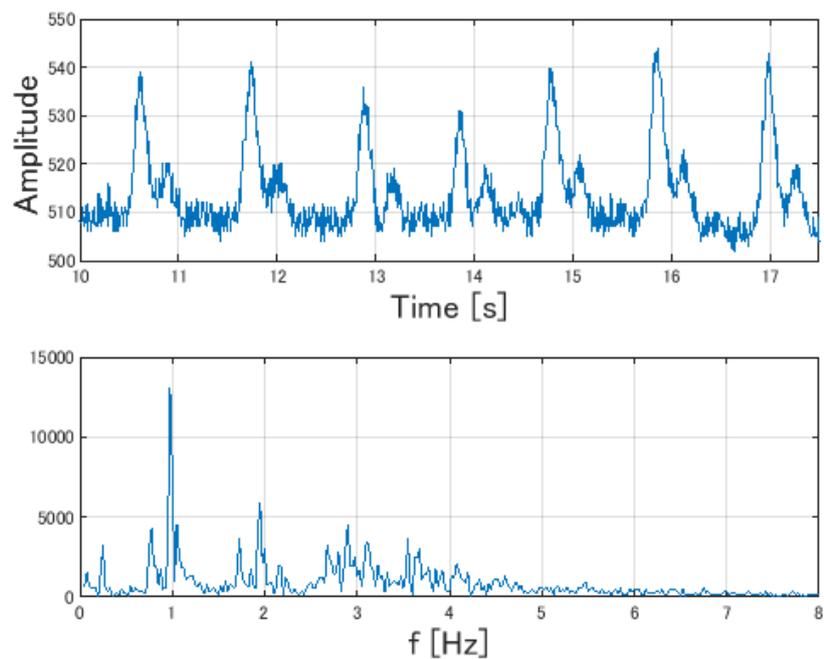


図 3.5 (a) パルス波波形, (b) FFT 後のスペクトル分布

3.2.4 実験

抱きつきシステムを用いて、バイタルサインを測定する実験を行った。赤外線センサ、ジャイロセンサ、脈波センサを利用し、マイクロコンピュータと発泡スチロールの球体を用いて抱きつきシステムを構築した。図 3.3(b)に抱きつき型システムの実験プロトタイプを示す。本実験の目的は、体温、呼吸数、脈拍を同時に計測することが可能かどうかを確認することである。

球体の内側にジャイロセンサを取り付け、呼吸による腹部の変位を身体付近で計測した。3軸のジャイロセンサなので、ズレにも対応できる。脈波センサは球体の胴体から一番遠いところに取り付け、抱きかかえるような指先を当てて脈波を測定している。実際の使用では、脈波センサの位置に指先を誘導する方法が必要である。また、顔の温度を測定するために、球体の上部に赤外線温度センサを取り付けた。赤外線温度センサは4×4のアレイ型なので、視差に対応できる。実際には、16の領域で体温範囲内のものを選択する処理が行われた。マイコンはPCとUSBケーブルで接続し、PC上のデータを取得する。

被験者は成人男性1名。椅子に座り、両手で球体を持ち、赤外線温度センサを顔に向けて体温を測定し、左手の指先を脈波センサに当て、静的な自然呼吸を維持した。体温、呼吸、脈拍を同時に測定し、PC上で波形を取得した。以下は、その結果である。

- 体温

被験者の体温は約 35°Cであった。検証のため、赤外線体温計 T0-300 で測定した体温は 35.2°C、電子体温計 UT-201 で測定した体温は 37.1°Cであった。電子体温計の結果とは差があり、実際の使用には校正が必要となる。

- 呼吸数

最初に、これまで行ってきたサーミスタとの比較を行う。被検者に装着したサーミスタを取り付けたマスクと、ジャイロセンサを取り付けた球体の両方で呼吸の計測を行った。計測波形を図 4 に示す。ここでは、10 秒ほどの無呼吸状態の後に呼吸を開始した。両波形のピークを比較すると、サーミスタとジャイロセンサでは位相がずれており、サーミスタでは呼気時、ジャイロセンサでは吸気時にピークが検出されていることがわかる。ピーク間隔は両者ともほぼ等しく、ジャイロセンサによる腹部変位から呼吸の推定が可能であることを確認した。

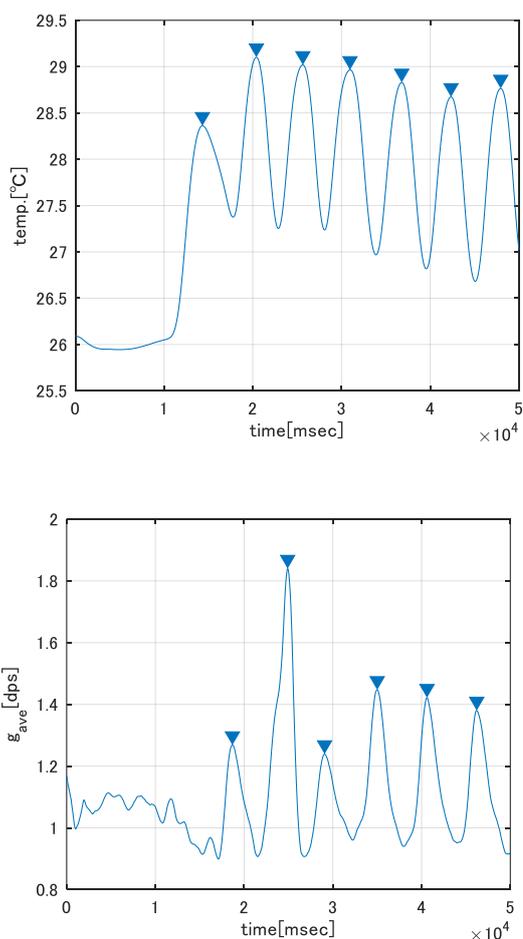


図 3.6 サーミスタとジャイロセンサによる計測の比較

(a) サーミスタ (b) ジャイロセンサ

人間の活動周波数は 0-20 Hz であり，信号エネルギーのほとんどすべてが 3 Hz 以下であることが示されている．この理論に基づき，カットオフ周波数が 0.475 Hz の 3 次バターワース IIR ローパスフィルタを設計した．

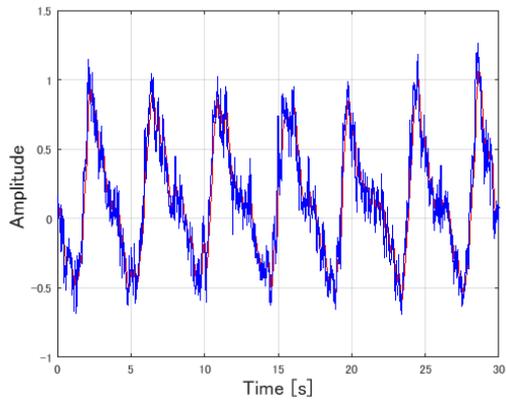
フィルタリング後の波形を図 3.7(b)に示す．しかし，フィルタリングされた波形は遅延が大きく，S/N 比の R 値も大きく低下していることがわかる．

そこで，同じ原波形をフィルタリングするカルマンフィルタを設計し，その結果を図 3.7(a)に図示した．リアルタイム性が高く，遅延も短いことがわかる．

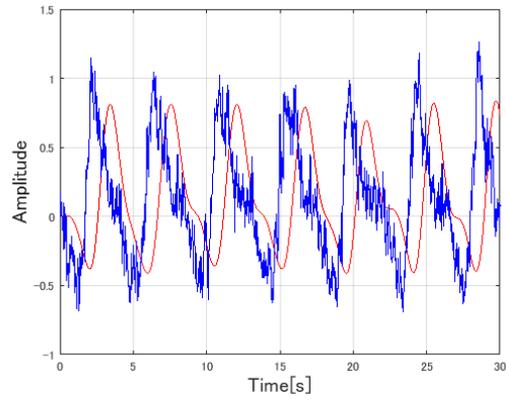
図 3.7 (c) は，カルマンフィルタを用いて呼吸波の時間領域の信号をフィルタリングしたものである．周期的な信号は，30 秒以内に 1~7 までの複数のピークを持つ．

この波形は，呼吸動作を反映しており，最大ピーク A；と最小ピーク B との間の傾きは，呼気過程を反映しており，最小ピーク B と最大ピークとの間の傾きは，呼気過程を反映しており，最小ピーク B と最大ピークとの間の傾きは，呼気過程を反映している．C 間の傾きは吸気過程を反映し，残りのピークに適用される．各最大ピークと次のピークとの間の時間幅の期間を R_c とした．

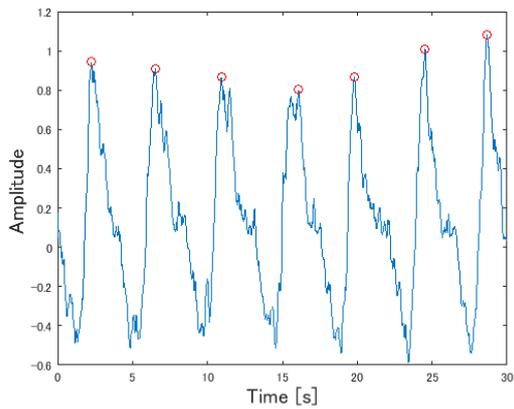
各呼吸周期における周期的な変化を図 3.7(d)に示す．呼吸数は，周期の平均値を算出し，その平均値の期間において 60 で割ることにより算出した．算出された呼吸数は，14 拍／分であった．



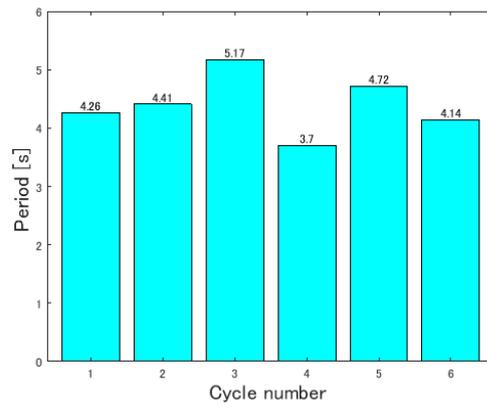
(a)



(b)



(c)



(d)

図 3.7 (a)カルマンフィルタによるフィルタリングした呼吸波 (赤線)
 (b) バターワースフィルタリングによるフィルタリングした呼吸波(赤線)
 (c) 呼吸波の極大点を求める
 (d) 周期にわたる呼吸周期の変化

● 心拍数

脈波のフィルタリングは，呼吸波の抽出と同様である．まず，3次パラメータが 3.55Hz のバターワースフィルタを設計し，原波形をフィルタリングする．図 3.8(b)の赤線はフィルタリングされた波形を表しており，この波形も遅延が大きく，S/N 比 R が不足していることが分かる．

脈波では，細部に至るまで心臓の活動に関する情報が含まれているため，情報の最大限の保持と低遅延のフィルタリングが特に重要である．

図 3.8 (a) において，カルマンフィルタは低遅延で元の脈波波形にフィットすることができ，SN 比の R 値も大きくなっている．

図 3.8(c)は電圧信号のピーク値を定義したものである．図 3.8 (d) に示すように，心拍の周期は各周期でわずかに変化している．7.5 秒で 6 サイクルの平均周期を計算することで，最終的に 1 分間に 58 回の心拍が得られる．

測定された呼吸数は 1 分間に 14 回，心拍数は 1 分間に 58 回であった．これらの結果を比較した結果，実際の値と一致した．これらの結果から，呼吸と脈波が十分に測定できることが確認できた．

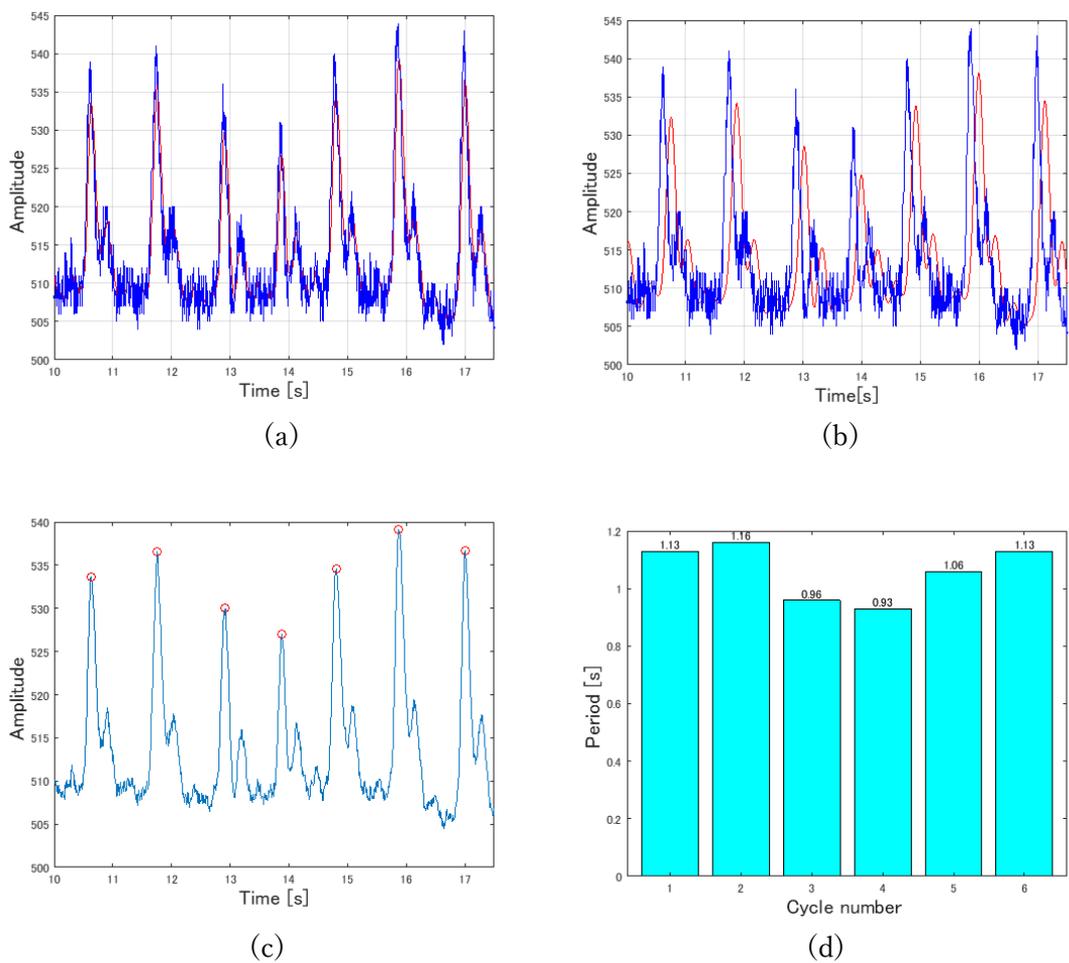


図 3.8 (a)カルマンフィルタによるフィルタリングした脈波 (赤線)
 (b) バターワースフィルタによるリングした脈波 (赤線)
 (c) 脈波の極大点を求める (d) 心拍周期の周期的変化

3.2.4 抱きつき型システムのまとめ

本節では、抱きつき型の生体状態評価システムを提案し、発泡スチロールの球体にマイクロコンピュータと複数のセンサを取り付けた簡易プロトタイプを構築した。体温、呼吸、心拍にそれぞれ赤外線センサ、ジャイロセンサ、光電脈波センサを利用することとし、発泡スチロール球体に取り付けて構成したシステムで計測実験を行った。結果より、それぞれのセンサとマイコンを取り付けた球体によって構成された抱きつき型システムによって、バイタルサインの測定が十分に可能であることが確認された。

3.3 まとめ

本章では、マイコンとセンサによる簡便なシステムによりバイタルデータを計測し、分類学習法を用いて感情状態を推定することを試みた。2つの光電脈波センサと2つのサーミスタ温度センサを用いて、体温・心拍・血圧・呼吸を測定することを目標にシステムを構成し、得られたセンサデータを決定木・線形判別・SVM・最近傍法による分類学習法によって学習・分類した。判別する状態として安静・作業・運動の3状態のデータを計測し、分類を行い良好な結果を得た。

本章では、抱きつき型生命情報計測システムを提案した。発泡スチロールの球体にマイクロコンピュータと複数のセンサを取り付けた簡易プロトタイプを構築した。ここでは、体温、呼吸、心拍にそれぞれ赤外線センサ、ジャイロセンサ、光電脈波センサを利用することにした。RRとHRの実験では、2つのフィルタの効果を比較した。実験では、本研究で活用したセンサフィルタリングにおいて、バターワースフィルタは遅延や歪みが大きいことが証明された。相対的に、アカマンフィルタは遅延が少なく、信号対雑音比(SNR)値が高いという利点があり、良い性能を発揮する。結論として、カルマンフィルタはバターワースフィルタより優れており、これは研究[21]の結論と一致する。このシステムを用いて、バイタルサイン計測実験を行った。その結果、本システムは実現可能であり、バイタルサインを効率的に計測できることがわかった。ただし、この実験は静かで比較的理想的な状況で行われたものである。そのため、次のステップとして、異なる視点を取り入れる方法を評価し、モーションアーチファクトによる影響を考慮し、解決策を開発することが必要である。

以上、本章では、マイコンとセンサによる簡便な計測システムにより、十分にバイタルサインの測定方法の議論や検討を行うプロトタイプとして用いることが可能であることを示した。また、各種センサとマイコンを取り付けた球体によって構成された抱きつき型システムによって、バイタルサインの測定が十分に可能であることを確認した。本章の結果に基づき、以降では球体によって構成される抱きつき型システムのための機能や手法について研究を進めていくこととする。

第3章の参考文献

- [1] 藤野智子, 三浦英恵, and 村田洋章, 基礎と臨床がつながる バイタルサイン. 学研メディカル秀潤社, 2014.
- [2] 小澤利男, 新しい血圧測定と脈波解析マニュアル. メジカルビュー, 2008.
- [3] K. Sharma, C. Castellini, E. L. van den Broek, A. Albu-Schäeffler, and F. Schwenker, “A dataset of continuous affect annotations and physiological signals for emotion analysis,” *Scientific Data*, vol. 6, Oct. 2019, doi: 10.1038/s41597-019-0209-0.
- [4] Y. Hattori, T. Tanaka, Y. Kajiwara, and H. Shimakawa, “Estimation of Intimacy Change in Team Using Vital Signs,” presented at the 2018 Federated Conference on Computer Science and Information Systems, Sep. 2018, pp. 3–10. doi: 10.15439/2018F90.
- [5] 神崎康宏, *Arduino* で計る, 測る, 量る. CQ 出版社, 2012.
- [6] MATLAB ドキュメンテーション, “分類学習器アプリにおける分類モデルの学習.” [Online]. Available: <https://jp.mathworks.com/help/stats/train-classification-models-in-classification-learner-app.html>
- [7] K. Ho *et al.*, “Multi sensor approach to detection of heartbeat and respiratory rate aided by fuzzy logic,” in *International Conference on Fuzzy Systems*, Jul. 2010, pp. 1–6. doi: 10.1109/FUZZY.2010.5584045.
- [8] I. Smith, J. Mackay, N. Fahrid, and D. Kruckeck, “Respiratory rate measurement: a comparison of methods,” *British Journal of Healthcare Assistants*, vol. 5, no. 1, pp. 18–23, Jan. 2011, doi: 10.12968/bjha.2011.5.1.18.
- [9] X. Yang *et al.*, “Textile Fiber Optic Microbend Sensor Used for Heartbeat and Respiration Monitoring,” *IEEE Sensors Journal*, vol. 15, no. 2, pp. 757–761, Feb. 2015, doi: 10.1109/JSEN.2014.2353640.
- [10] P. Ambrosi, B. Kreitmann, and G. Habib, “Home Blood Pressure Monitoring in Heart Transplant Recipients: Comparison with Ambulatory Blood Pressure Monitoring,” *Transplantation*, vol. 97, no. 3, pp. 363–367, Feb. 2014, doi: 10.1097/01.TP.0000435704.55805.f9.
- [11] B. Fernandes, J. A. Afonso, and R. Simões, “Vital signs monitoring and management using mobile devices,” in *6th Iberian Conference on Information Systems and Technologies (CISTI 2011)*, Jun. 2011, pp. 1–6.
- [12] R. A. Z. Daou, E. Aad, F. Nakhle, A. Hayek, and J. Börcsök, “Patient vital signs monitoring via android application,” in *2015 International Conference on Advances in Biomedical Engineering (ICABME)*, Sep. 2015, pp. 166–169. doi: 10.1109/ICABME.2015.7323278.
- [13] W. Chao and T. Ogawa, “Measurement of vital sign data using microcomputer and

- evaluation by machine learning,” *The 14th Japan Society of Sensitive Engineering Spring Conference*, vol. 2p04, pp. 604–605, 2019.
- [14] H. Uratani and M. Oksuga, “Development of Respiration Leading Stuffed Toy Using Airbags for children.,” *The Japanese Journal of Ergonomics*, vol. 51, no. 6, pp. 248–434, 2015.
- [15] M. Kachuee, M. M. Kiani, H. Mohammadzade, and M. Shabany, “Cuff-Less Blood Pressure Estimation Algorithms for Continuous Health-Care Monitoring,” *IEEE Transactions on Biomedical Engineering*, vol. 64, pp. 1–1, Jun. 2016, doi: 10.1109/TBME.2016.2580904.
- [16] M. Elliott and A. Coventry, “Critical care: the eight vital signs of patient monitoring,” *British Journal of Nursing*, vol. 21, no. 10, pp. 621–625, May 2012, doi: 10.12968/bjon.2012.21.10.621.
- [17] L. Tarassenko, D. A. Clifton, M. R. Pinsky, M. T. Hravnak, J. R. Woods, and P. J. Watkinson, “Centile-based early warning scores derived from statistical distributions of vital signs,” *Resuscitation*, vol. 82, no. 8, pp. 1013–1018, Aug. 2011, doi: 10.1016/j.resuscitation.2011.03.006.
- [18] J. Allen, “Photoplethysmography and its application in clinical physiological measurement,” *Physiol. Meas.*, vol. 28, no. 3, pp. R1–R39, Mar. 2007, doi: 10.1088/0967-3334/28/3/R01.
- [19] A. B. Hertzman, “THE BLOOD SUPPLY OF VARIOUS SKIN AREAS AS ESTIMATED BY THE PHOTOELECTRIC PLETHYSMOGRAPH,” *American Journal of Physiology-Legacy Content*, vol. 124, no. 2, pp. 328–340, Oct. 1938, doi: 10.1152/ajplegacy.1938.124.2.328.
- [20] A. B. Hertzman, “Comparative Estimation of Blood Supply of Skin Areas from Photoelectrically Recorded Volume Pulse,” *Experimental Biology and Medicine*, vol. 38, no. 4, pp. 562–564, May 1938, doi: 10.3181/00379727-38-9935P.
- [21] W. Wang, Y. Guo, B. Huang, G. Zhao, B. Liu, and L. Wang, “Analysis of filtering methods for 3D acceleration signals in body sensor network,” in *International Symposium on Bioelectronics and Bioinformatics 2011*, Suzhou, China, Nov. 2011, pp. 263–266. doi: 10.1109/ISBB.2011.6107697.

第4章 生体状態評価システムへの機械学習およびニューラルネットの導入

4.1 抱きつき型システムへ表情認識の導入

医療支援のための抱きつき型システムとして、不安を取り除くための形状設計や、バイタル情報を迅速に測定するためのシステム構成について研究を行ってきた[1]。これまでは、簡単なマイコンとセンサを用いたシステム構成を試みてきた。これまでに、加速度センサやサーモグラフィを用いて、呼吸、心拍、体温などのバイタルサインを計測するシステムを構築し、検証してきた。抱きつき型システムのプロトタイプとして、図4.1に示すような直径約30cmの球体を用いて検討を行ってきた。

人間の表情は感情と関連しており、表情認識により推定された感情に合った情報を提示することで、注目を集め、不安を取り除くことができると考える。本節では、Raspberry PiにWebカメラと液晶キャラクタディスプレイを接続し、患者の表情を認識することで感情に合った感情を表示するシステムを構築する。顔の表情認識にはディープネットワークを使用する。図4.2に、本節で提案する表情認識付きバイタルサイン計測システムのコンセプトを示す。本システムは、抱きかかえることで患者のバイタルサインを測定し、医療スタッフに伝えるとともに、顔の表情を認識するものである。患者自身に感情をフィードバックすることで患者の緊張をほぐし安心感を与えることや、医療スタッフに患者の感情を伝達することを目的とする。



図 4.1 表情認識部を付けた抱きつき型システム

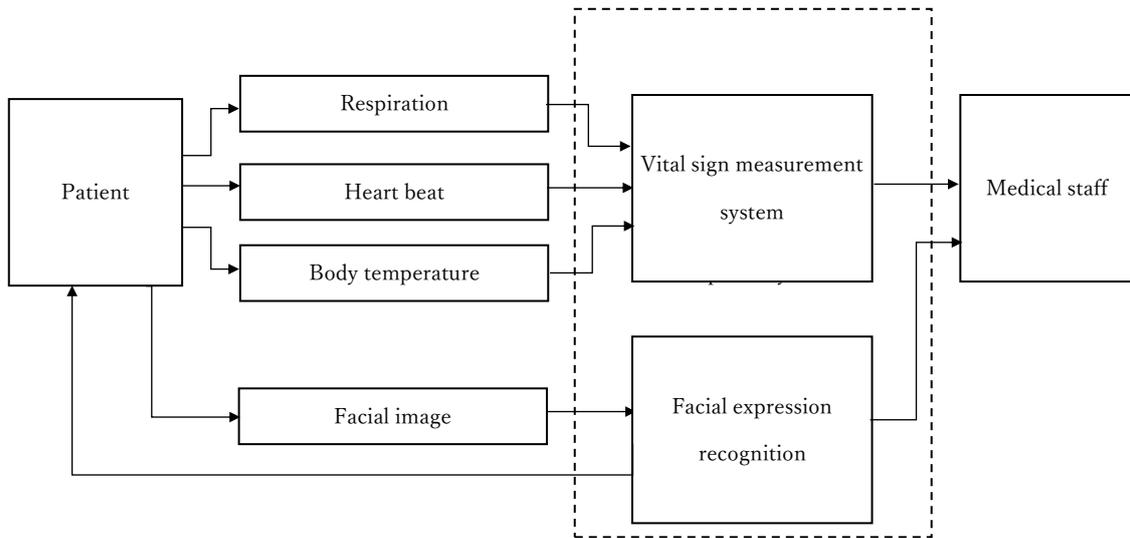


図 4.2 バイタルサイン計測システムへの表情認識導入

4.1.1 表情認識

エクマン[2]は、顔の表情を「驚き」「恐怖」「嫌悪」「怒り」「喜び」「悲しみ」「中立」の7種類に分類した。この分類に基づき、表情画像から感情を推定する方法が検討されている[3]。機械学習により表情と感情の関係を学習する場合、大量の表情データが必要となる。顔の表情データベースとしては、CK+や JAFEE が知られている[4], [5]。本節では、入力層、5つの中間層、出力層からなる完全連結型のディープネットワークを用い、中間層の活性化関数を ReLU、出力層を Softmax とした。画像は 68×68 ピクセルで、エクマンの「驚き」「恐怖」「嫌悪」「怒り」「喜び」「悲しみ」「中立」の7種類である。7つの出力ニューロンは、7つの感情に対応する 0.0 から 1.0 の値を出力する。これをラベルとして、ネットワークを学習し、顔画像を与えて感情を認識させる。

本節では、直径 30cm の発泡スチロールの球体に、画像入力用の Web カメラ、液晶ディスプレイ、表情認識などの処理を行うマイコン Raspberry Pi、モバイルバッテリーを取り付けて構成する。図 4.1 に本システムのプロトタイプを示す。

認識精度を確認するため、Web カメラを取り付けた球体をかざして撮影した顔画像から表情認識を行った。20代の男性被験者3名に対して、「驚き」「恐怖」「嫌悪」「怒り」「幸福」「悲しみ」「中立」の7種類の感情を指定し、それに対応する顔の表情を認識させることができた。実験では、図 4.3 に示す順序で表情を作るよう被験者に指示した。この手順を各被験者につき5回ずつ繰り返し、合計90回の結果を得た。

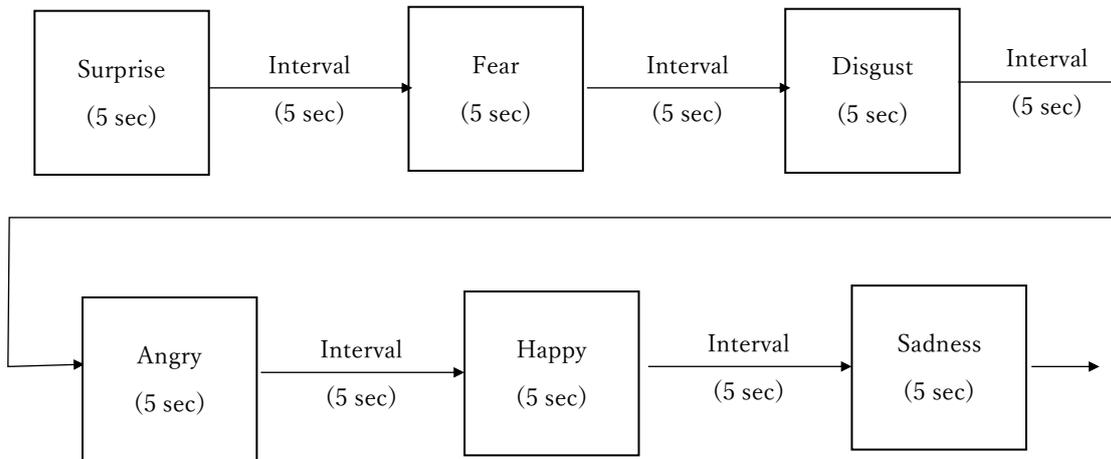


図 4.3 表情認識実験の手順

表 4.1 は、各表情について、3 人の 5 回によるネットワーク出力の平均値を示している。Happy の表情については、Neutral を除き、Happy を表す出力が最大であることがわかる。Surprise についても同様である。Angry, Disgust, Fear, Sadness は最大値ではなく、したがって Happy と Surprise はほぼ正しく認識されていることがわかる。図 4.4 と図 4.5 は、Happy と Surprise について、3 人が 5 回ずつネットワーク出力を行ったものである。

この結果から、個々の認識結果は必ずしも高くはなく、改善が必要である。しかし、医療分野では、Angry, Disgust, Fearなどを細かく区別する必要はなく、例えば、Happyなどが区別できれば十分である。その点からも、この結果は有効であると思われる。精度を上げるためには、学習データの質・量の向上や、学習方法、特にネットワーク構造の研究が可能である。

表 4.1 表情認識における出力の平均値

		Mean output values						
		Angry	Disgust	Fear	Happy	Sadness	Surprise	Neutral
Facial expressions	Angry	0.3818	0.5354	0.2975	0.2723	0.1863	0.2565	0.5038
	Disgust	0.4623	0.3224	0.4047	0.1796	0.4204	0.2778	0.7308
	Fear	0.3327	0.3246	0.3756	0.1868	0.3326	0.3612	0.5810
	Happy	0.2570	0.3339	0.5010	0.5753	0.2069	0.3527	0.5263
	Sadness	0.3219	0.3292	0.5010	0.3827	0.2835	0.2803	0.6421
	Surprise	0.2301	0.1219	0.4159	0.0872	0.3833	0.6127	0.6089

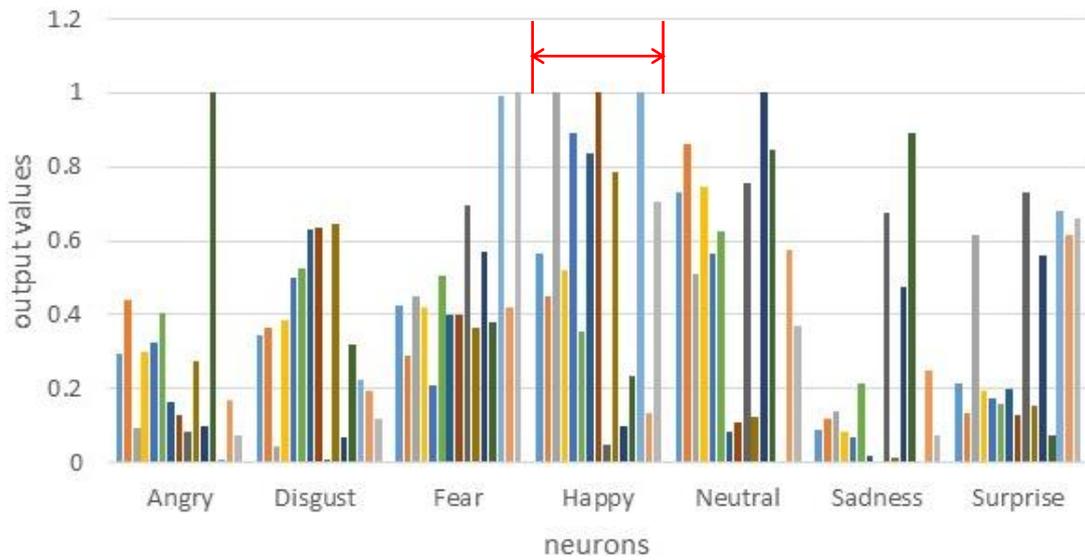


図 4.4 "Happy"の表情に対するネットワーク出力

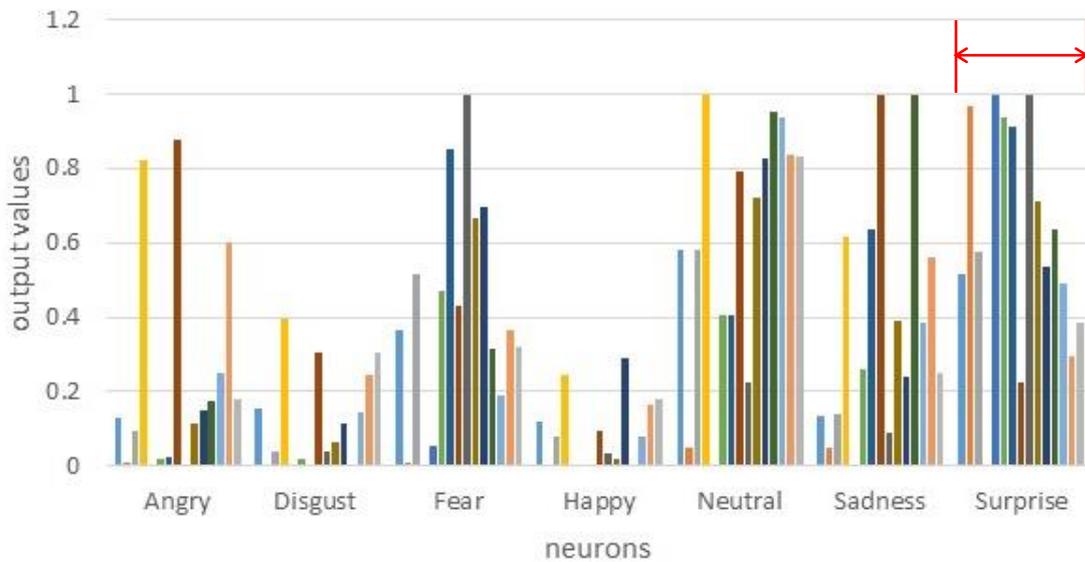


図 4.5 "Surprise"の表情に対するネットワーク出力

4.1.2 抱きつき型システムへ表情認識の導入のまとめ

本節では、抱きつき型システムについて、患者の不安や症状を和らげるために、表情認識の導入を検討した。Web カメラと LCD ディスプレイ、Raspberry Pi を発泡スチロール球体に取り付けたシステムとし、表情認識とフィードバックを抱きつき型システムのみで完結する構成とした。表情認識実験の結果により、抱きつき型システムによって表情認識が実現できることを確認した。課題としては、表情認識精度の向上のための学習データの質・量の向上や学習方法、ネットワーク構造の検討が挙げられる。

本節の結果の意義は、抱きつき型システムによって患者の感情状態を推定し、さらに感情のフィードバックを行う機能を提案し実際に構成したことにある。本節の結果により、抱きつき型システムが単にバイタルサイン計測を行うだけでなく、安心感を与えるシステムへの拡張性の一例が示された。

4.2 表情認識による孤独感軽減ロボットの動作選択

医療・介護施設へのロボット導入が図られ、動物型などのロボットが人間とのコミュニケーションや癒しのツールとして活用されつつある。一方、医療分野では、入院中の小児の孤独感や生活環境が与えるストレスが治療拒否や看護負荷の原因となっている。また、高齢者のリハビリテーションにおいて、リハビリの動機付けややる気を与えることの大切さが指摘されている。そのための孤独感軽減のためのロボットが提案され開発が進められている[6][7]。

人間の表情はさまざまな感情と深い関係があり、表情を分析することで感情を予測できる。表情分析としてエクマンの研究が知られている[8]。近年では、様々な表情のデータベースが公開され[9][10]、さらに深層学習等に基づく分類が発表されており[11][12]、これらを利用することで容易に表情認識が可能である。

本節では、孤独感軽減のためのロボットに、表情認識で推定した感情に基づく動作選択法を導入することを検討する。表情データを学習した深層ネットワークを用い、Web カメラで読み取った表情から感情を予測し、予め用意した動作を予測した感情に合わせて選択することを考える。今回は、孤独感軽減ロボット実機への表情認識の導入の準備として、仮想空間内で動作するロボットを用いてシステムを構成した。

4.2.1 孤独感軽減ロボット

西川らは、ロボットの存在感を与えることによって、誰かがいる、見守られている、応援されているなどの感情を与えることを目的として、孤独感を軽減するためのロボットを開発した[7]。このロボットは、オムニホイールを用いた円形の四輪駆動ロボットをベースとし、その上部に人の呼吸の様子を表すような拡大・縮小の機構を取り付け、これらの振幅と速度により感情を表現することを目的としている。

西川らは「楽しみ」「心配」「嬉しい」「平気」の4つの感情を表すロボットの動きを設定して、その動作に注目する被検者の感情の動きを観測した。その結果として4つの動作と感情の関係を示し、さらに孤独感緩和の効果を示した。このロボットは動作によって心理的な効果を与えているが、対象者の感情の観測やフィードバックは行っていない。そこで、対象者の感情に合わせて動きを効果的に提示するために、何らかのセンサや画像から感情の推定を行うことで、より効果的な動作提示が可能になると考える。

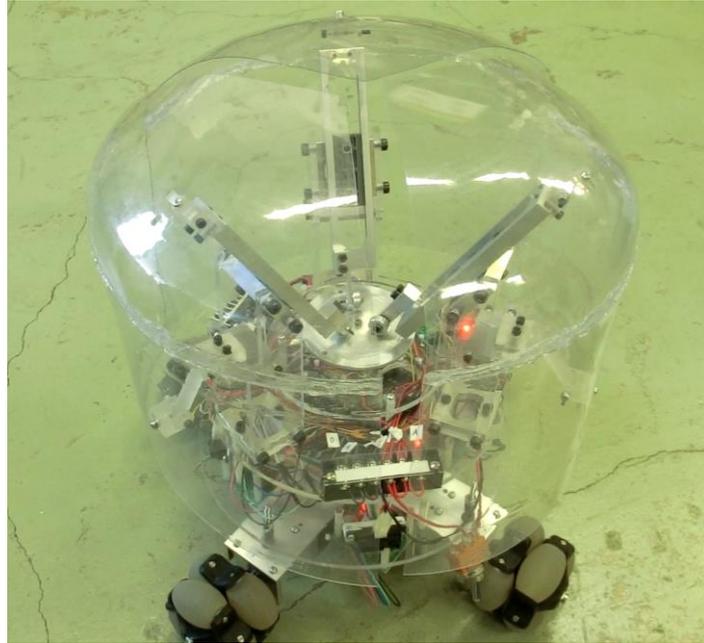


図 4.6 孤独感軽減ロボット

4.2.2 表情判別による動作選択

表情による感情推定として、牧野らはインターネット検索で収集した画像データをもとに、畳み込みニューラルネットを用いて表情判別を行っている[11]。また、AkcoraはCohn-KanadeとJAFEEの画像データを用い、5層の全結合ニューラルネットを用いた表情判別システムを構成している[12]。本節では後者のデータとネットワーク構成による表情判別システムを用いる。

本節では、表情分析による孤独感軽減ロボットの動作選択の実現を目的としてシステムを構成する。表情認識のシステムはAkcora[12]に基づきTensorflowとKerasで構成し、画像中の顔検出にはdlibを用いる。今回は、表情認識による移動ロボットの動作制御を目的とし、孤独感軽減ロボットの実機への導入の前に仮想ロボットによる動作検証を行う。仮想ロボットとしてはChoregraphe上でPepperを動作させる[13]。画像はWebカメラで取り込み、Socket通信で表情認識部から受け取った感情の情報をもとに動作を選択し仮想ロボットを制御する。図4.7に表情認識によるロボット動作選択の流れを示す。

ネットワーク構成は5層の全結合とし、学習データはCohn-KanadeとJAFEEの画像データを用いる[11]。画像は 68×68 を1次元化して 4624×1 に整形する。各データは「驚き」「恐怖」「嫌悪」「怒り」「幸福」「悲しみ」と「中立」の7種類とする。ネットワークは入力4624素子、中間512素子 \times 5層、出力7素子の全結合ネットワークとし、中間層素子

の活性化関数は ReLU, 出力はソフトマックスとする. 学習誤差の推移より, 学習および汎化が十分に行われていることを確認した.

感情の推定結果は, Socket 通信で仮想ロボットへと送られ, 感情に合わせて用意した動作を選択し, 仮想空間上で動作を行う. 感情を表す物理量として Pleasant と Activation の 2次元での評価を図 4.8(a)に示す. これに対して, 表情認識での 7つの感情と, 孤独感軽減ロボットにおける 4つの感情をプロットしたものを図 4.8(b)に示す. 本節では, 感情を中立に誘導することを目的として, 表情認識での感情と孤独感軽減ロボットの感情を原点対称とした組とし, 動作を選択することとした. 対象とするロボット動作を表す軌道を, 図 4.9(a)~(d)に示す.

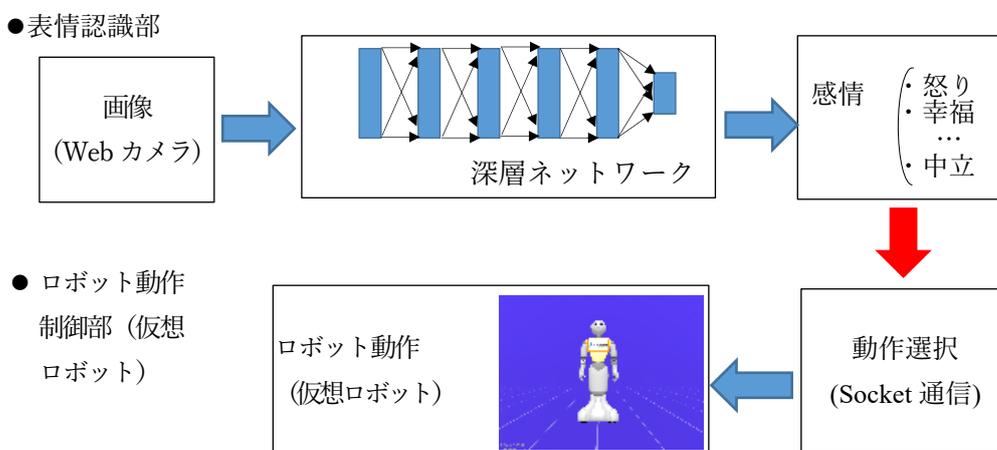


図4.7 表情認識によるロボット動作選択の流れ

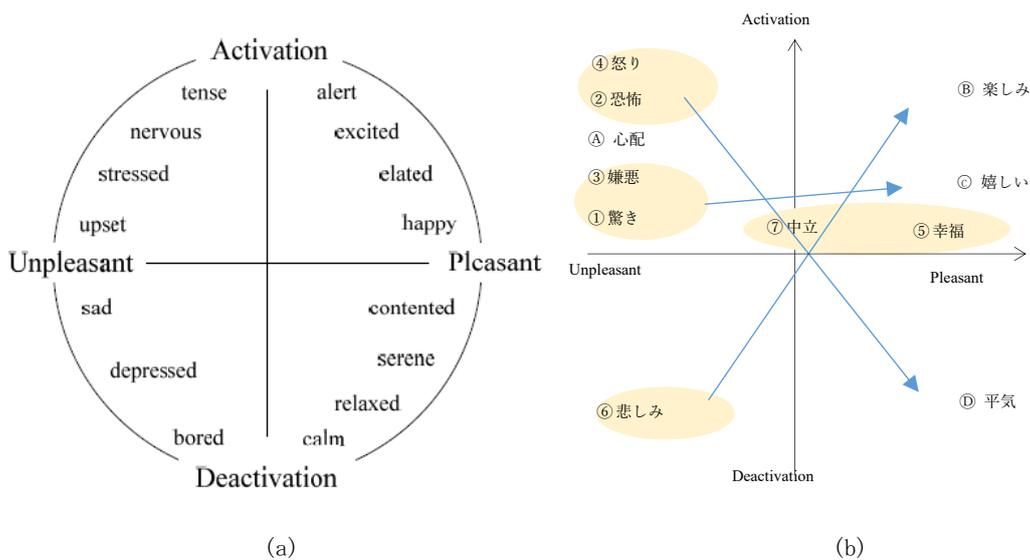


図4.8 感情を表す物理量 (a) 感情と物理量

(b) 表情認識と孤独感軽減ロボットの感情のプロット

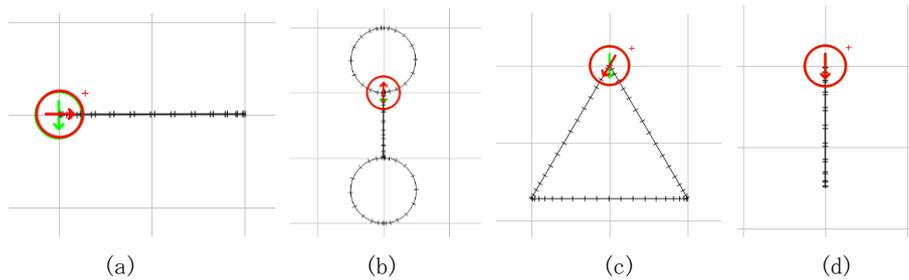


図 4.9 ロボット動作を表す軌道

(a) 心配 (b) 楽しみ (c) 嬉しい (d) 平気

4.2.3 実験

動作検証のために実験を行った。20代男性の被検者8名に、「驚き」「恐怖」「嫌悪」「怒り」「幸福」「悲しみ」「中立」の感情を指定し、それに対応する表情の判別を行った。結果を指定した感情と判別結果の表の形で表1に示す。表の数字は人数を表す。結果によると、「驚き」「嫌悪」「中立」に関しては正しく認識されているが、それ以外は正しく認識されていない。これは被検者の表情が明確でなくやや乏しいと思われること、学習が不十分である可能性などが考えられる。

続いて、被検者8名に仮想ロボットの4つの動作を示し、それらを「Pleasant」と「Active」の2つの指標で順位付けの形で評価させた。その順位の平均を求めた結果を表4.2と図4.10に示す。図4.8(b)と図4.10を比較すると、西川らのロボット動作と、今回設定した仮想ロボットの動作には類似性が見られる。従って今回の仮想ロボットの動作は感情と類似性があり、表情から読み取った感情によって動作選択することで、孤独感軽減効果が上がるものとする。

表4.2 表情の判別結果

		判別（予測）結果						
		驚き	恐怖	嫌悪	怒り	幸福	悲しみ	中立
実際のクラス	驚き	5	0	1	0	0	0	2
	恐怖	1	0	2	1	0	0	4
	嫌悪	1	0	6	0	0	0	1
	怒り	0	0	4	1	0	0	3
	幸福	0	0	5	0	2	0	1
	悲しみ	0	0	6	0	0	0	2
	中立	0	0	2	0	0	0	6

表4.3 ロボット動作の評価

	Pleasant	Active
心配	1.375	1.5
楽しみ	3.125	3.25
嬉しい	3.25	2.5
平気	2.25	2.75

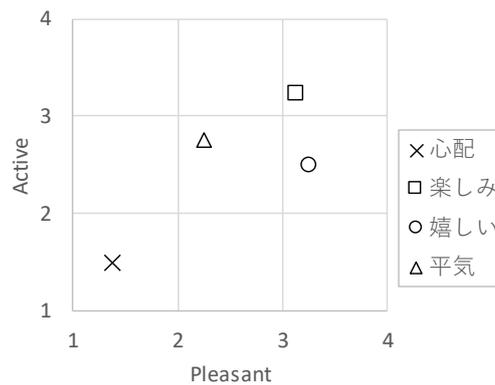


図4.10 ロボット動作の評価

4.2.4 表情認識による孤独感軽減ロボットの動作選択のまとめ

本節では、前節で抱きつき型システムに導入した表情認識の手法の応用として、孤独感軽減のためのロボットの動作選択の導入を提案した。深層ネットワークを用いて表情認識を行い、認識結果を仮想ロボットに送って動作を選択するプログラムを作成し、さらに表情判別の検証と仮想ロボット動作の評価を行った。表情認識による孤独感軽減ロボットの動作選択の問題における今後の課題として、孤独感軽減ロボット実機に接続しての検証、孤独感軽減効果の検証が挙げられる。

本節の結果は、抱きつき型システムの機能拡張における直接の成果ではないが、抱きつき型システムに追加した手法の他の問題への応用可能性と有効性を示したものである。孤独感軽減を目的としたロボットへの応用という意味では、不安感の解消や安心感への寄与を目的とした抱きつき型システムと関連するものとする。

4.3 非接触測定への導入

これまで、球体に取り付けた光電脈波センサを用いて心拍の代わりに指先脈波を測定してきた。しかし、この方法ではセンサの位置を指先に合わせて抱きつく必要があり、少しでもずれると測定の精度が低下するという問題があった。

一方、カメラを用いて脈波を推定する方法がある。例えば、動画像中の顔色の変化から脈波成分を取り出すことで、脈波を測定することが可能である。そこで、抱きつき型システムの球体にカメラを取り付け、顔の動画像から脈波を測定することを考える。これにより、センサと指の位置合わせが不要になるというメリットがある。

4.3.1 皮膚反射モデル

皮膚は、表皮、真皮、および皮下組織からなる多層の不均一な器官である [14]。

カメラで測定された肌には、モーションによって引き起こされる強度/鏡面反射の変化と、パルスによって引き起こされる微妙な色の変化のために、時間の経過とともに変化する特定の色がある。これらの時間変化は、輝度強度レベルに比例する。二色性モデル [15] に基づいて、記録された画像シーケンス内の各皮膚ピクセルの反射は、RGB チャネルの時変関数として次に定義できる。

$$\mathbf{c}_i(t) = I(t) \cdot (\mathbf{v}_s(t) + \mathbf{v}_d(t)) + \mathbf{v}_n(t) \quad (4.1)$$

ここで、 $\mathbf{c}_i(t)$ は i 番目の肌のピクセル強度であり、 $\{R_i(t), G_i(t), B_i(t)\}$ と書き換えることができる。 $I(t)$ は、光源と、光源、皮膚組織、およびカメラ間の距離の変化に依存する輝度強度レベルを示す。 $\mathbf{v}_s(t)$ は、皮膚表面からの反射の鏡面成分を表す。 $\mathbf{v}_d(t)$ は、皮膚組織での光の散乱と吸収によって生じる拡散成分を表す。 $\mathbf{v}_n(t)$ は、カメラセンサの量子化ノイズを表す。

さらに、式(4.1)を拡張して次のように脈拍を抽出することができる。

$$\mathbf{c}_i(t) = I_0 \cdot (1 + i(t)) (\mathbf{u}_s \cdot \mathbf{s}(t) + \mathbf{u}_c \cdot \mathbf{c}_0 + \mathbf{u}_p \cdot \mathbf{p}(t)) + \mathbf{v}_n(t) \quad (4.2)$$

ここで $I_0 \cdot (1 + i(t))$ は、定常部分と時変部分を含む照明を定義される。 $\mathbf{u}_s \cdot \mathbf{s}(t)$ と $\mathbf{u}_p \cdot \mathbf{p}(t)$ は、それぞれ鏡面成分と拡散成分の時変信号である。また、反射信号にはさまざまな定数成分があるため、皮膚反射の色ベクトルは \mathbf{u}_c で表され、 \mathbf{c}_0 は反射強度である。その後、フレームごとに RGB チャネルのスキン ピクセルを空間的に平均化することにより、量子化ノイズが除去される。時変成分は静的成分よりもはるかに小さいため、時変成分の積を除去することで反射モデルを次のように単純化できる。

$$\mathbf{c}_i(t) = I_0 \cdot \mathbf{u}_c \cdot \mathbf{c}_0 \cdot (1 + i(t)) + \mathbf{u}_s \cdot I_0 \cdot \mathbf{s}(t) + \mathbf{u}_p \cdot I_0 \cdot \mathbf{p}(t) \quad (4.3)$$

式(4.3)に関して、非接触心拍数測定のタスクは： $\mathbf{c}_i(t)$ から $\mathbf{p}(t)$ を抽出することである。

4.3.2 カメラによる非接触脈波推定

これまでに、ビデオカメラ等で検出された光電式容積脈波記録法 (PPG) による信号を、心周期中の顔の色の変化を検出することで測定できることがわかった[16][17]. この技術を利用することで、皮膚からの反射光の微妙な変化を利用して生理学的信号を抽出することができ[18], 遠隔生理学的測定分野は過去 10 年間で大きく発展した.

カメラによる非接触脈波測定の処理の流れは以下の通りである. また, 処理の流れを図 4.11 に示す.

- ① カメラで撮影した映像から, 顔の部分を切り出す.
- ② 切り出した部分の各チャンネルの顔反射光の値を計算する.
- ③ 肌の色の変化から, 脈波成分を抽出する.
- ④ 脈波をフィルタに通し, 心拍数を取得する.

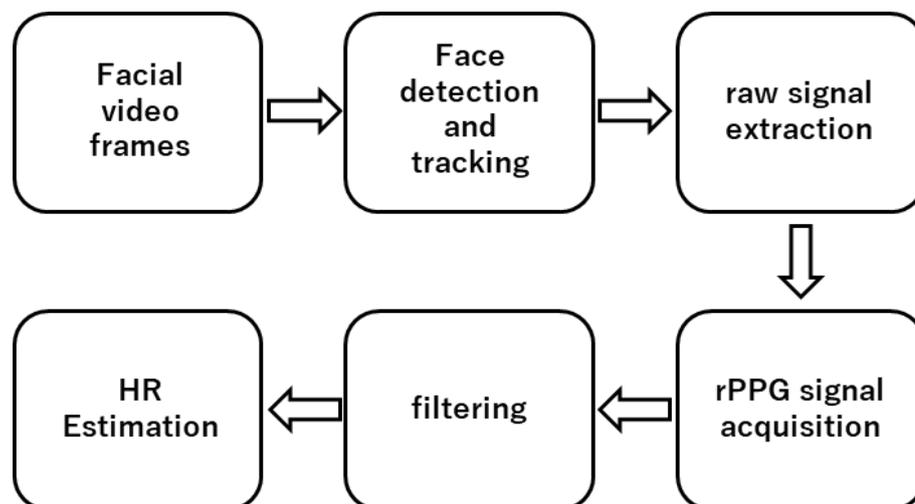


図 4.11 非接触脈波推定の流れ

顔映像から心拍を測定する抱きつき型システムとして、図 4.12 に示すような最上部に Web カメラを取り付けた直径 30 cm の発泡スチロール球体を用意した。顔と Web カメラの距離が近いので、広角型の機種とし視野角 120 度の Buffalo の BSW200MBK を用いた。

本来は Raspberry Pi 等のマイコンを内蔵して、脈波の信号処理を行ってから Wi-Fi で PC にデータを送信することを想定しているが、今回は抱きつき球体に取り付けた Web カメラからの脈波測定動作を確認するために、Web カメラを有線(USB)で PC に接続し、信号処理は PC 上で行った。

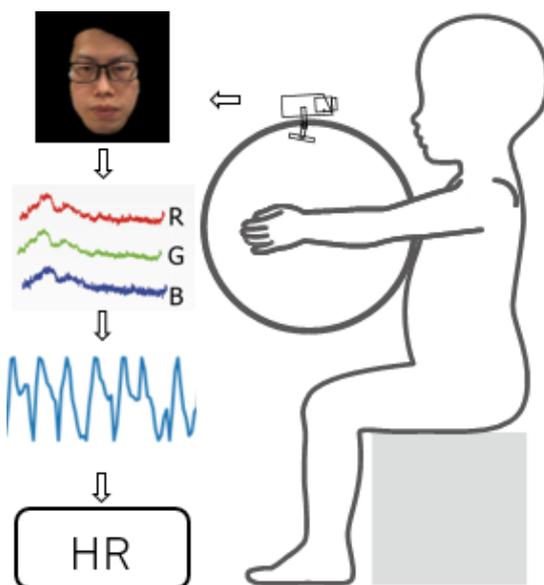


図 4.12 顔映像による心拍推定を導入した抱きつき型システム

4.3.3 実験

顔映像から心拍を測定する抱きつき型システムの動作を確認するために、Web カメラを取り付けた球体の抱きつき球体を用いて実験を行った。被検者は男子大学院生 1 名である。

顔映像からの脈波、心拍数と心拍数の変動の測定結果を図 4.13 と図 4.14 に示す。安静状態で測定し、Web カメラと顔の距離は 20cm である比較のため、携帯型ヘルスマニタ（三栄, Checkme Pro X）で同時に計測を行った。結果によると、顔映像から計測した脈拍数は 56 回/分であり、携帯型ヘルスマニタで計測した脈拍数は 58 回/分でほぼ一致した。

顔と Web カメラの位置関係による、脈拍測定の可・不可を実験で確認した。位置関係としては、顔と Web カメラの距離と、正面から左右の顔と Web カメラの角度、正面から上下の顔と Web カメラの角度とした。

まず、顔と Web カメラの距離を $d[\text{cm}]$ とし、 $d = 5, 10, 20, 30, 40$ として測定したところ、 $d \leq 30$ で測定可能であった。続いて、正面から左右の顔と Web カメラの角度として、正面を 0° とし、距離 30[cm] で右に $\theta = 45^\circ, 60^\circ, 75^\circ, 90^\circ$ としたところ、 $\theta \leq 75^\circ$ で測定可能であった。また、正面から上下の顔と Web カメラの角度としては、上下 75° 以内で測定可能であることを確認した。これらの結果より、顔映像を用いた本システムでの心拍の測定については、抱きつきの体勢にほぼ影響なく可能であると考えられる。

以上より、抱きつき球体上に取り付けた Web カメラによる顔映像から心拍が正しく測定されること、また顔と Web カメラの位置関係に対して問題なく測定が可能であることを確認した。

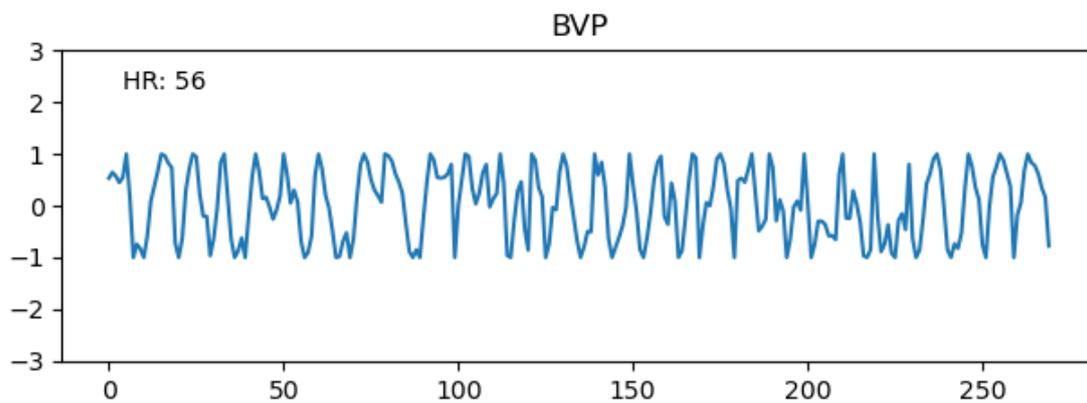


図 4.13 顔映像による脈波

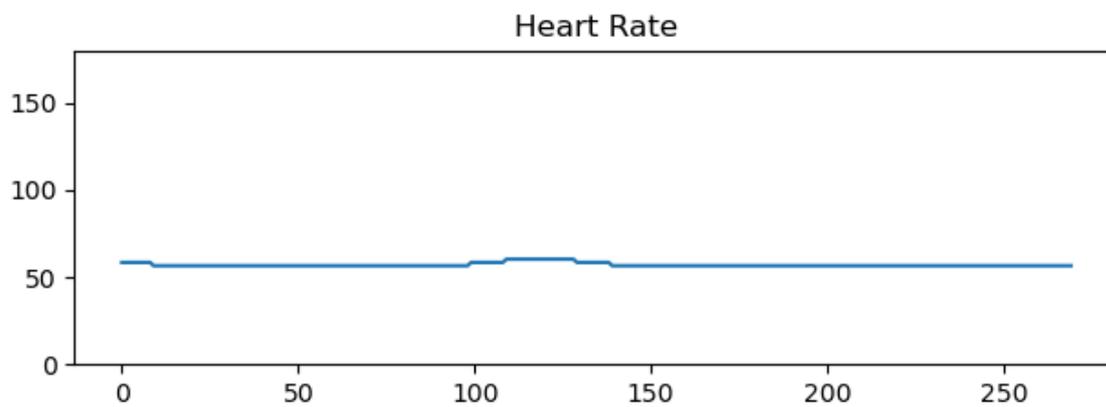


図 4.14 心拍数の変動

4.3.4 非接触測定 of 導入のまとめ

本節では、抱きつき型システムについて、カメラを用いた非接触測定の導入を提案した。具体的には、カメラによる顔の動画像からの脈波の推定を検討した。結果として、抱きつき球体上に取り付けた Web カメラによって撮影した顔画像から脈波の測定が可能であり、非接触で心拍の計測が可能であることを実験によって確認した。

本節の結果の意義は、抱きつき型システムによるバイタルサインの計測のために、患者の負担を軽減する非接触測定の導入の例を示したことにある。本節の結果により、抱きつき型システムによるバイタルサイン計測において、より患者の負担を軽減するシステムへの発展性の一例が示された。

4.4 まとめ

本章では、抱きつき型の生体状態評価システムに安心感を与えるための追加機能を導入することを提案し、システムの構成および実験によって動作や効果を示した。まずは、表情認識による感情推定とフィードバックの導入を提案し、球体に取り付けた Web カメラと LCD ディスプレイおよびマイコンによるシステムを構成し、実験によって表情認識の実現を確認した。続いて表情認識の手法の応用として、孤独感軽減ロボットの動作選択への導入を試みた。仮想空間でのロボットに表情に合わせた動作をさせるシステムを構成し、実験によって有効性を示した。さらに、抱きつき型システムについて、カメラを用いた非接触測定を導入を提案した。具体的には Web カメラからの顔動画像から脈拍を計測する方法を導入し、実験によって心拍の計測が可能であることを示した。

本章の結果の意義は、抱きつき型システムによって患者の感情状態を推定し、さらに感情のフィードバックを行う機能を提案し実際に構成したことや、抱きつき型システムによるバイタルサインの計測のために、患者の負担を軽減する非接触測定を導入の例を示したことにある。本章の結果により、抱きつき型システムによるバイタルサイン計測において、より患者に安心感を与え、負担を軽減するシステムへの発展性の例が示された。

第4章の参考文献

- [1] C. Wang and T. Ogawa, "Measurement of vital information and estimation of emotional state by microcomputer," 14th Japan Society for Kansei Engineering Spring Meeting, p. 2p04, 2019
- [2] P. Ekman and W. V. Friesen, *Unmasking the face: A guide to recognizing emotions from facial clues*. Oxford, England: Prentice-Hall, 1975, pp. xii, 212.
- [3] E. Akcora, "Facial-Expression-Keras." Apr. 04, 2022. Accessed: Dec. 04, 2022. [Online]. Available: <https://github.com/ezgiakcora/Facial-Expression-Keras>
- [4] P. Lucey, J. F. Cohn, T. Kanade, J. Saragih, Z. Ambadar, and I. Matthews, "The Extended Cohn-Kanade Dataset (CK+): A complete dataset for action unit and emotion-specified expression," in 2010 IEEE Computer Society Conference on Computer Vision and Pattern Recognition - Workshops, Jun. 2010, pp. 94–101. doi: 10.1109/CVPRW.2010.5543262
- [5] M. Lyons, M. Kamachi, and J. Gyoba, "Coding Facial Expressions with Gabor Wavelets (IVC Special Issue)," 1998. doi: 10.5281/zenodo.4029679.
- [6] Y. Nishikawa, Y. Kagawa, and A. Okazaki, "Development of Spiral-Movement Robot to Reduce Anxiety Among Pediatric Patients", *Journal of Advanced Computational Intelligence and Intelligent Informatics*, Vol.21 No.4, 2017.
- [7] 西川佳男, 香川美仁他「孤独感軽減のためのロボット開発」計測自動制御学会第18回システムインテグレーション部門講演会論文集, pp.1524-1525, 2017.
- [8] エクマン,フリーゼン,工藤力(訳)「表情分析入門」誠信書房, 1987.
- [9] L. P. Cohn, J. F. Kanade, et. al. "The Extended Cohn-Kanade Dataset (CK+): A complete facial expression dataset for action unit and emotion-specified expression", *Third IEEE Workshop on CVPR for Human Communicative Behavior Analysis*, 2010.
- [10] M. J. Lyons, S. Akamatsu, M. Kamachi, and J. Gyoba, "Coding Facial Expressions with Gabor Wavelets", *3rd IEEE International Conference on Automatic Face and Gesture Recognition*, pp. 200-205, 1998.
- [11] 牧野浩二, 西崎博光「算数&ラズパイから始めるディープ・ラーニング」CQ出版社, pp.133-137, 2018.
- [12] E. Akcora, "Facial-Expression-Keras", <https://github.com/ezgiakcora/Facial-Expression-Keras>.
- [13] 竹田真, 小枝祐基「Pepperスタートブック」SB Creative, 2015.
- [14] A. Krishnaswamy and G. Baranoski, "A Study on Skin Optics," 2004. Accessed: Jan. 20, 2023.
- [15] S. A. Shafer, "Using color to separate reflection components," *Color Research & Application*, vol. 10, no. 4, pp. 210–218, 1985, doi: 10.1002/col.5080100409.
- [16] M.-Z. Poh, D. J. McDuff, and R. W. Picard, "Non-contact, automated cardiac pulse measurements using video imaging and blind source separation," *Opt. Express*, vol. 18, no. 10, p. 10762, 2010.
- [17] W. Verkruyse, L. O. Svaasand, and J. S. Nelson, "Remote plethysmographic imaging using ambient light," *Opt. Express*, vol. 16, no. 26, p. 21434, 2008.

- [18] Y. Sun and N. Thakor, "Photoplethysmography Revisited: From contact to noncontact, From Point to Imaging," *IEEE Trans. Biomed. Eng.*, vol. 63, no. 3, pp. 463–477, 2016.

第5章 四元数に拡張したニューラルネットと生体状態評価システムへの応用

3次元空間における幾何学演算や姿勢表現に四元数は有効であり、ロボット制御やコンピュータグラフィックスなどモデルの姿勢表現にしばしば用いられる。また、ニューラルネットを複素数や四元数に拡張した複素ニューラルネットや四元数ニューラルネットへの拡張が提案されている。生体計測においても、体の動きや姿勢によるデータがしばしば用いられる。四元数に拡張したニューラルネット手法は、本研究で対象とする計測システムにも有効と予測する。

原因から結果を導く順問題に対し、逆問題では与えられた結果から原因を推定する。生体動作評価やロボット制御においても逆問題を解く場面が存在する。そこで、3次元空間での逆問題を適応的に解くために、四元数に拡張されたニューラルネットによる解法は有効と考える。

本章では、3次元空間内における結果から原因の効率的な推定手法の1つとして、四元数ニューラルネットによる逆問題解法を提案し、その効果を検証する。さらに、四元数ニューラルネットを、抱きつき型生体状態評価システムの姿勢推定に適用し、その有効性を検証する。四元数に拡張したニューラルネット法は、本研究で対象とする計測システムにも有効と予測する。

以下では、四元数について概説し、続いて四元数ニューラルネットによる入力逆推定法について述べ、さらに四元数ニューラルネットの生体状態評価システムへの応用について述べる。

5.1 四元数ニューラルネットによる入力逆推定法

5.1.1 四元数

W. R. Hamilton によって発見された四元数は、1つの実部と3つの虚部をもつ高次複素数である。実部を q_0 、虚部を q_1, q_2, q_3 とすると、四元数 \mathbf{q} は、

$$\mathbf{q} = q_0 + q_1i + q_2j + q_3k \quad (5.1)$$

と表される。ここで i, j, k は虚数単位であり、 $i^2 = j^2 = k^2 = ijk = -1$, $ij = -ji = k$, $jk = -kj = i$, $ki = -ik = j$ である。

四元数 $\mathbf{q} = q_0 + q_1i + q_2j + q_3k$, $\mathbf{q}' = q'_0 + q'_1i + q'_2j + q'_3k$ に対し和と差は、

$$\mathbf{q} \pm \mathbf{q}' = (q_0 \pm q'_0) + (q_1 \pm q'_1)i + (q_2 \pm q'_2)j + (q_3 \pm q'_3)k \quad (5.2)$$

となり、四元数 \mathbf{q}, \mathbf{q}' の積 $\mathbf{q} \otimes \mathbf{q}'$ は、

$$\begin{aligned} \mathbf{q} \otimes \mathbf{q}' &= (q_0q'_0 - q_1q'_1 - q_2q'_2 - q_3q'_3) \\ &\quad + (q_0q'_1 + q_1q'_0 + q_2q'_3 - q_3q'_2)i \\ &\quad + (q_0q'_2 + q_2q'_0 + q_3q'_1 - q_1q'_3)j \\ &\quad + (q_0q'_3 + q_3q'_0 + q_1q'_2 - q_2q'_1)k \end{aligned} \quad (5.3)$$

となる。また本研究では、四元数 \mathbf{q}, \mathbf{q}' の要素ごとの積 $\mathbf{q} \odot \mathbf{q}'$ を、

$$\mathbf{q} \odot \mathbf{q}' = q_0q'_0 + q_1q'_1i + q_2q'_2j + q_3q'_3k \quad (5.4)$$

と定義する。

四元数 \mathbf{q} の共役 \mathbf{q}^* は、

$$\mathbf{q}^* = q_0 - q_1i - q_2j - q_3k \quad (5.5)$$

と定義され、ノルム $|\mathbf{q}|$ は、

$$|\mathbf{q}| = \sqrt{q_0^2 + q_1^2 + q_2^2 + q_3^2} \quad (5.6)$$

である。また、 $\mathbf{q} \neq 0$ のとき、 \mathbf{q} の逆数 \mathbf{q}^{-1} は、

$$\mathbf{q}^{-1} = \frac{\mathbf{q}^*}{|\mathbf{q}|^2} \quad (5.7)$$

で求められる。さらに、 $|\mathbf{u}| = 1$ の四元数 \mathbf{u} と、実部が0の四元数 \mathbf{a} とみなしたベクトルを考えた場合、

$$\mathbf{a}' = \mathbf{u} \otimes \mathbf{a} \otimes \mathbf{u}^* \quad (5.8)$$

の演算は、ベクトルの3次元空間での回転を表す[1],[2].

四元数の積の演算は結合則や分配則を満たすが、交換則は満たさない。四元数は、3次元空間における回転や補間の表現に適しており、対象物の姿勢表現などに用いられる。

実部が0かつ虚部のうち少なくとも1つが0でない四元数を純虚四元数といい、3次元空間の表現などに用いられる。本研究では、純虚四元数を対象とする。

5.1.2 四元数ニューラルネット

本研究では、四元数の幾何学演算に基づくニューロンを用いた層状のニューラルネットを対象とする。ニューロンモデルの定義と層状ニューラルネットの学習法は、文献[11]と同様とし、具体的には以下の通りである。

このニューロンにおいて、入力を \mathbf{x}_m 、荷重を \mathbf{w}_{nm} 、閾値を θ_n とし、出力 \mathbf{y}_n を

$$\begin{aligned} \mathbf{s}_n &= \sum_n \frac{\mathbf{w}_{nm} \otimes \mathbf{x}_m \otimes \mathbf{w}_{nm}^*}{|\mathbf{w}_{nm}|} - \theta_n \\ \mathbf{y}_n &= \mathbf{f}(\mathbf{s}_n) \end{aligned} \quad (5.9)$$

とする。ここで \otimes は式(5.3)に示す四元数の積を表し、 \mathbf{s}_n は内部ポテンシャルである。式(5.9)の演算は、他ニューロンの出力値が結合荷重により回転・相似変換を受けるとともに閾値により平行移動されるような幾何学変換に相当する。 \mathbf{f} はニューロンの入出力変換関数で、

$$\begin{aligned} \mathbf{f}(\mathbf{s}) &= f(s_1)i + f(s_2)j + f(s_3)k \\ f(s) &= \frac{1}{1 + e^{-s}} \end{aligned} \quad (5.10)$$

とする。

文献[11]に示される四元数に拡張した誤差逆伝搬学習法を用いて学習を行う。出力層、中間層、入力層をもつ3層のネットワークを考え、それぞれの層のニューロンを $\mathbf{n}, \mathbf{m}, \mathbf{l}$ の記号で区別する。なお、中間層と出力層を上記の幾何学演算に基づくニューロンとする。ネットワークの出力誤差を

$$E = \frac{1}{2} \sum_n |\mathbf{d}_n - \mathbf{y}_n|^2 \quad (5.11)$$

とする。ここで \mathbf{d}_n および \mathbf{y}_n を、それぞれ教師出力とネットワーク出力とする。荷重と閾値のパラメータを \mathbf{p} とし、これらを

$$\begin{aligned} \mathbf{p}^{\text{new}} &= \mathbf{p}^{\text{old}} + \Delta \mathbf{p} \\ \Delta \mathbf{p} &= -\eta \cdot \frac{\partial E}{\partial \mathbf{p}} \end{aligned} \quad (5.12)$$

の式により繰り返し修正する。ここで η は微小係数である。この式に基づき、ニューロンの閾値 θ_n 、 θ_m 、荷重 \mathbf{w}_{nm} 、 \mathbf{w}_{ml} を修正する。修正量は

$$\begin{aligned} \Delta \theta_n &= (\mathbf{y}_n - \mathbf{d}_n) \odot \mathbf{f}'(\mathbf{s}_n) \\ \Delta \mathbf{w}_{nm} &= \frac{1}{|\mathbf{w}_{nm}|} \left(\frac{\Delta \theta_n \cdot (\mathbf{w}_{nm} \otimes \mathbf{y}_m \otimes \mathbf{w}_{nm}^*)}{|\mathbf{w}_{nm}|^2} \mathbf{w}_{nm} - 2\Delta \theta_n \otimes \mathbf{w}_{nm} \otimes \mathbf{y}_m^* \right) \end{aligned} \quad (5.13)$$

$$\begin{aligned}\Delta\theta_m &= \left(\sum_n \frac{\mathbf{w}_{nm}^* \otimes \Delta\theta_n \otimes \mathbf{w}_{nm}}{|\mathbf{w}_{nm}|} \right) \odot \mathbf{f}'(\mathbf{s}_m) \\ \Delta\mathbf{w}_{ml} &= \frac{1}{|\mathbf{w}_{ml}|} \left(\frac{\Delta\theta_m \cdot (\mathbf{w}_{ml} \otimes \mathbf{y}_l \otimes \mathbf{w}_{ml}^*)}{|\mathbf{w}_{ml}|^2} \mathbf{w}_{ml} - 2\Delta\theta_m \otimes \mathbf{w}_{ml} \otimes \mathbf{y}_l^* \right)\end{aligned}\quad (5.14)$$

となる。ここで \odot は式(4)に示す四元数の要素ごとの積を表す。また

$$\mathbf{f}'(\mathbf{s}) = \frac{\partial f(s_1)}{\partial s_1} i + \frac{\partial f(s_2)}{\partial s_2} j + \frac{\partial f(s_3)}{\partial s_3} k \quad (5.15)$$

とする。なお、逆伝搬の計算は、出力ニューロンの閾値 θ_n 、中間—出力ニューロン間の荷重 \mathbf{w}_{nm} 、中間ニューロンの閾値 θ_m 、中間—出力ニューロン間の荷重 \mathbf{w}_{ml} の順に行われる。

5.1.3 四元数ニューラルネットの入力逆推定

原因から結果を導く順問題に対し、与えられた結果から原因を推定する逆問題を考える。通常の層状ニューラルネットでは、入力から出力を求める方向で学習を行い、学習した関係を順方向で用いて入力から出力を求める。これに対し、学習済みニューラルネットに対して出力を提示し、対応する入力を求めることで逆問題を解くことを考える。

層状ニューラルネットでは、出力誤差の原因が荷重によるものとして、誤差を最小化する方向で荷重を修正する。それに対し、荷重の値が正しいと仮定し出力誤差の原因が入力によるものとして、誤差を最小化する方向で入力を修正することができる[16]。この手順により、学習済みのニューラルネットに出力を提示することで、それに対応する入力を推定できる。

前述の方法で学習済みの四元数ニューラルネットに出力を提示し、対応する入力を求める方法を以下に示す。学習済みの3層型四元数ネットワークにおいて、ランダム入力を与えたときの、提示した出力 \mathbf{d}_n とネットワーク出力 \mathbf{y}_n との誤差を式(5.11)同様に計算する。この誤差が入力によるものとして、誤差を入力に逆伝搬して修正を行う。入力 \mathbf{x} を、

$$\begin{aligned}\mathbf{x}^{\text{new}} &= \mathbf{x}^{\text{old}} + \Delta\mathbf{x} \\ \Delta\mathbf{x} &= -\eta \cdot \frac{\partial E}{\partial \mathbf{x}}\end{aligned}\quad (5.16)$$

の式によって繰り返し修正する。 η は微小係数である。 θ_n と θ_m の修正要求 $\Delta\theta_n$ 、 $\Delta\theta_m$ を、

$$\begin{aligned}\Delta\theta_n &= (\mathbf{y}_n - \mathbf{d}_n) \odot \mathbf{f}'(\mathbf{s}_n) \\ \Delta\theta_m &= \left(\sum_n \frac{\mathbf{w}_{nm}^* \otimes \Delta\theta_n \otimes \mathbf{w}_{nm}}{|\mathbf{w}_{nm}|} \right) \odot \mathbf{f}'(\mathbf{s}_m)\end{aligned}\quad (5.17)$$

の式によって求め、出力層から中間層に逆伝搬する。さらに

$$\Delta x_l = \sum_m \frac{\mathbf{w}_{ml}^* \otimes \Delta \theta_m \otimes \mathbf{w}_{ml}}{|\mathbf{w}_{ml}|} \quad (5.18)$$

によって、入力層に逆伝搬されるものとする。なお、式(17)の $\Delta \theta_n$ と $\Delta \theta_m$ は誤差を入力に伝搬するために計算し、ここでは $\Delta \theta_n$ と $\Delta \theta_m$ の修正は行わない。また、入力ニューロンは入力の分配のみで非線形演算を行っていないので、式(5.17)と異なり式(5.18)では右辺への変換関数の微分の、要素ごとの積演算は行わない。

以上の方法によって、学習済みの四元数ニューラルネットに対し出力を提示し、任意の初期入力を繰り返し修正することにより、提示した出力に対応する入力を逆推定することができる。

5.1.4 入力の逆推定法を提案

高次複素数の1つである四元数は、3次元空間での幾何学演算を表現するのに適しており、ロボット制御やコンピュータグラフィックスなどモデルの姿勢表現にしばしば用いられる[1],[2]。また、ニューラルネットを複素数や四元数に拡張した複素ニューラルネット[3],[4]や四元数ニューラルネット[5],[6]、さらにこれらの高次元数を包含するクリフォード代数に拡張したニューラルネット[7]-[9]が提案されている。四元数ニューラルネットでは、単一型[10]や多層型[10-12]、相互結合型[13-15]などさまざまなモデルで検討が行われている。四元数の幾何学演算に基づくニューロンを用いた層状モデルでは、3次元空間でのアフィン変換やカラー画像圧縮の問題で効果が示されている[11],[12]。

学習済み層状ニューラルネットを用いて、出力から入力を逆推定する方法が提案されている[16]。この方法は逆問題[17]の解法などに応用され[18],[19]、複素数や四元数に対応したニューラルネットへの拡張が検討された[20]-[22]。しかし、四元数の幾何学演算に基づくニューロンを用いた層状モデルでの検討は行われていない。幾何学代数としての四元数の特性を生かすためには、四元数の幾何学演算に基づくモデルの使用が必要と考える。そこで本研究では、四元数の幾何学変換に基づくニューロンによる層状ネットワークのための、入力の逆推定法を提案する。提案法による入力の逆推定動作を、簡単なビット演算問題および3次元空間におけるアフィン変換問題によって示す。

5.1.5 実験

提案手法の動作を簡単な問題の計算機実験で確認する。対象とする問題はビット演算問題と、3次元空間でのアフィン変換問題である。

ビット演算問題では、具体的にはビット反転とビットローテートの演算の学習と逆推定を試みる。ビット反転では入力データを反転して出力することを学習し、ビットローテート

では入力をキャリーなしで1ビット分だけ右ローテートを行った出力を学習する。さらに、それぞれの演算で学習済みネットワークに出力を提示して対応する入力を逆推定する。なお文献[11]ではパリティ問題が取り上げられているが、この逆関係は1対多の不良設定問題となり無条件では解くことができない。そのため本研究では不良設定の生じないビット反転とビットローテートの問題を取り上げる。

アフィン変換の問題では、入力されたデータを移動、拡大、回転させて出力することを学習し、学習済みネットワークを用いて対応する入力を逆推定する。これらは文献[11]で取り上げられている問題を逆問題として解くものである。

5.1.6 ビット演算問題

最初に、3ビットのビット反転の問題の実験を行った。3ビットの2進数 $(x_1 x_2 x_3)_2$, $x_1, x_2, x_3 \in \{0, 1\}$ と、これを反転した2進数 $(y_1 y_2 y_3)_2 = (\bar{x}_1 \bar{x}_2 \bar{x}_3)_2$ を考える。ここでは、3ビットのビット反転問題を四元数に拡張し、入力を $x = x_1i + x_2j + x_3k$ ($0 \leq x_m \leq 1$, $m = 1, 2, 3$) とし、出力を $y = y_1i + y_2j + y_3k$, $y_m = 1 - x_m$ ($m = 1, 2, 3$) とする。ただし i, j, k は四元数の虚数単位である。ネットワーク構成とパラメータを表5.1に示す。

学習は入力 $(y_1, y_2, y_3) = (0, 0, 0), (0, 0, 1), \dots, (1, 1, 1)$ とその反転出力の8データの組を用いて行った。学習時の出力誤差の推移を図5.1(a)に示す。誤差の減少により入出力関係が学習されていることを確認した。

学習済み四元数ネットワークを用いて、提示する出力に対する入力の逆推定を試した。逆推定のテストデータとして、 $(y_1, y_2, y_3) = (0, 0, 0), (0, 0, 1), \dots, (1, 1, 1)$ の8データに相当する四元数を10回、計80個の出力として与えた。入力の初期値は四元数 $x_1i + x_2j + x_3k$ の各部を $0 \leq x_1, x_2, x_3, \leq 1$ の範囲の乱数として設定した。与えた80のテストデータに対する逆推定時の出力誤差の推移を図5.1(b)に示す。誤差の減少により出力から入力が修正されていることが確認できる。表5.2に与えた出力と逆推定された入力、正解の入力を示す。逆推定された入力の結果は各データとも10回の平均であるが、逆推定の繰り返し回数を十分多くとったため、ランダムな初期入力からでもデータごとにほぼ同じ値に収束した。また、結果は正解とほぼ一致しており、誤差の原因はネットワーク構成あるいは学習のパラメータによるものと考えられる。以上より、ビット反転問題において学習済みの四元数ネットワークにより、提示された出力に対応する入力が正しく逆推定されていることを確認した。

続いて、3ビットのビットローテートの問題の実験を行った。3ビットの2進数 $(x_1 x_2 x_3)_2$, $x_1, x_2, x_3 \in \{0, 1\}$ と、これを1ビット分だけ右にローテートした2進数 $(y_1 y_2 y_3)_2 =$

$(x_3 x_1 x_2)_2$ を考える．ここでは，3 ビットのビットローテート問題を四元数に拡張し，入力を $\mathbf{x} = x_1i + x_2j + x_3k$, ($0 \leq x_m \leq 1, m = 1,2,3$) とし，出力を $\mathbf{y} = y_1i + y_2j + y_3k$, $y_1 = x_3, y_2 = x_1, y_3 = x_2$ とする．

学習は入力 $(x_1, x_2, x_3) = (0, 0, 0), (0, 0, 1), \dots, (1, 1, 1)$ とそのローテート出力の 8 データを用いて行った．図 5.2(a)に示す学習時の出力誤差の推移より，入出力関係の学習を確認した．

学習済み四元数ネットワークを用いて，ビット反転問題と同様に逆推定を試した．逆推定のテストデータとして 8 データに相当する四元数を 10 回，計 80 個の出力として与えた．入力の初期値は同様の乱数とした．図 5.2(b)の逆推定時の出力誤差の推移より，出力からの入力の修正が確認できる．表 5.3 に与えた出力と逆推定された入力，正解の入力を示す．ビット反転問題の際と同様に，結果は正解とほぼ一致しており，学習済み四元数ネットワークによって，提示された出力からの入力の逆推定を確認した．

以上より，学習済みの四元数ニューラルネットワークを用いた入力の逆推定について，ビット反転とビットローテートの問題を用いて動作を示した．提案法によって，提示された出力に対応する入力の逆推定が可能であることが確認された．

表 5.1 ビット演算問題におけるネットワークパラメータ.

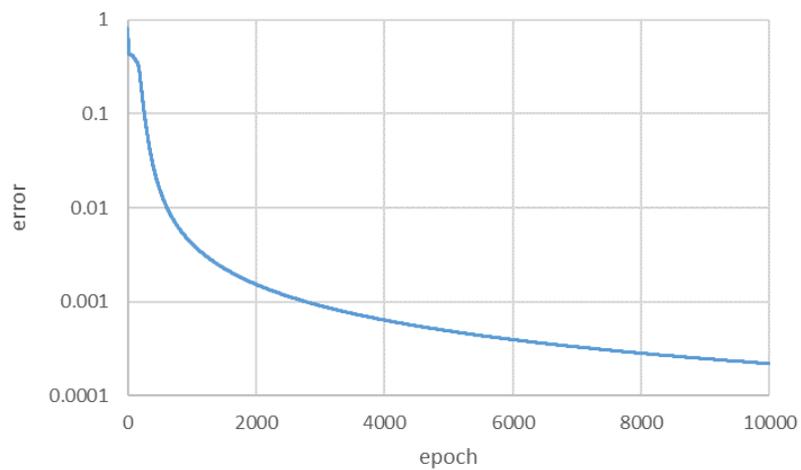
Parameters	Values
Number of input neurons	1
Number of hidden neurons	5
Number of output neurons	1
Forward learning rate η	0.1
Inverse update rate η	0.1
Number of learning epochs	10000
Number of estimation epochs	10000

表 5.2 ビット反転問題の結果

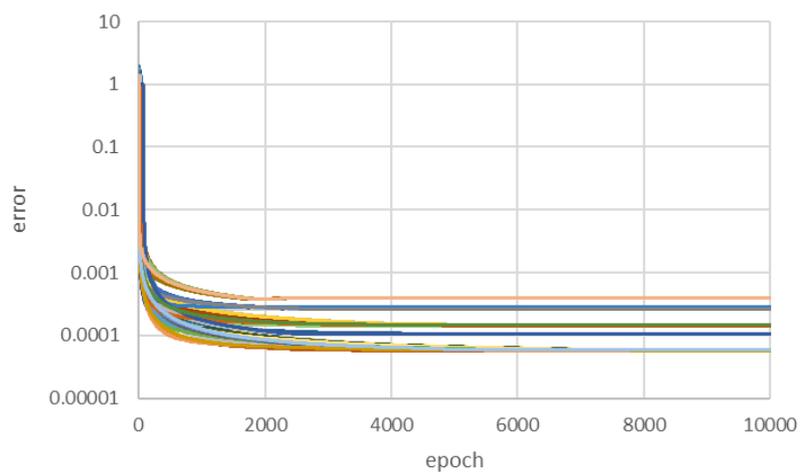
Given output			Estimated input			Correct input		
y_1	y_2	y_3	x_1	x_2	x_3	x_1	x_2	x_3
1	1	1	0.0000	0.0016	0.0132	0	0	0
1	1	0	0.0000	0.0127	0.8595	0	0	1
1	0	1	0.0883	0.9809	0.0000	0	1	0
1	0	0	0.1898	0.9532	1.0000	0	1	1
0	1	1	1.0000	0.0000	0.0000	1	0	0
0	1	0	1.0000	0.0490	0.9410	1	0	1
0	0	1	1.0000	0.9564	0.1531	1	1	0
0	0	0	0.9794	1.0000	1.0000	1	1	1

表 5.3 ビット回転問題の結果.

Given output			Estimated input			Correct input		
y_1	y_2	y_3	x_1	x_2	x_3	x_1	x_2	x_3
0	0	0	0.0000	0.0016	0.0132	0	0	0
1	0	0	0.0000	0.0127	0.8595	0	0	1
0	0	1	0.0883	0.9809	0.0000	0	1	0
1	0	1	0.1898	0.9532	1.0000	0	1	1
0	1	0	1.0000	0.0000	0.0000	1	0	0
1	1	0	1.0000	0.0490	0.9410	1	0	1
0	1	1	1.0000	0.9564	0.1531	1	1	0
1	1	1	0.9794	1.0000	1.0000	1	1	1

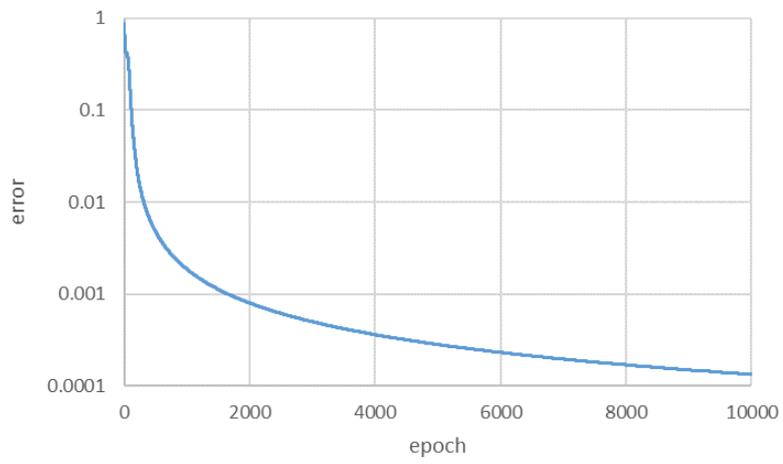


(a)

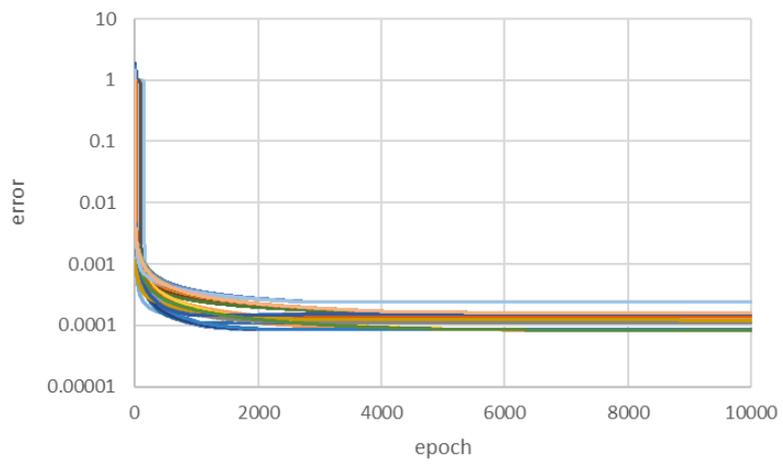


(b)

図 5.1 ビット反転問題における出力誤差の遷移
(a)学習時, (b)逆推定時.



(a)



(b)

図 5.2 ビット回転問題における出力誤差の遷移,
(a)学習時, (b)逆推定時..

5.1.7 アフィン変換問題

3次元空間内での2点間のアフィン変換の問題の実験を行った。3次元空間内の点 (x_1, x_2, x_3) と、これをアフィン変換した点 (y_1, y_2, y_3) を考える。ここでは、3次元空間の座標系を四元数で表現し、入力を $\mathbf{x} = x_1\mathbf{i} + x_2\mathbf{j} + x_3\mathbf{k}$, ($0 \leq x_m \leq 1, m = 1, 2, 3$) とし、

出力を $\mathbf{y} = y_1\mathbf{i} + y_2\mathbf{j} + y_3\mathbf{k}$, ($0 \leq y_m \leq 1, m = 1, 2, 3$) とする。本研究では、アフィン変換として平行移動、拡大縮小、回転の3つを対象とする。ネットワーク構成とパラメータを表5.4に示す。本実験では、3次元空間内の一部の点の変換例によって空間全体の変換関係を学習させることを目的とするため、過学習を防ぐことで汎化能力を保つ必要がある。今回は過学習を防ぐために、学習回数を固定でなく、平均誤差0.01に到達した時点で終了させることとした。

最初に平行移動の実験を行った。図5.3(a)に示すように、 xy 平面と平行に与えた9点の入力と、それらを z 軸負方向に0.3だけ平行移動した点の出力との関係を学習させた。さらに、図5.4(a)に示す立方体の辺上の96点を出力として与え、入力の逆推定を行った。その結果と正解の入力を図5.5(a)に示す。結果の立方体の形状はやや崩れており誤差があるが、正解に近い形状で逆推定が行われていることがわかる。

続いて拡大縮小の実験を行った。図5.3(b)に示すように xyz 空間内の平面上に与えた9点の入力と、それらを x, y, z 各軸方向に2倍に拡大した点の出力との関係を学習させた。逆推定は図5.4(b)に示す立方体の辺上の56点を出力として与えることで行い、図5.5(b)に示す逆推定入力結果を得た。この結果も平行移動と同様にやや誤差があるが正解に近い形状が得られている。

さらに回転移動の実験を行った。図5.3(c)に示すように、 xy 平面上の9点の入力と、 y 軸周りに 30° 回転した点の出力との関係を学習させた。逆推定は図5.4(c)に示す立方体の辺上の56点を出力として与えることで行い、図5.5(c)に示す逆推定入力結果を得た。この結果もこれまで同様にやや誤差があるが正解に近い形状が得られている。

以上より、学習済みの四元数ニューラルネットを用いた入力の逆推定動作について、平行移動、拡大縮小、回転に関するアフィン変換の問題を対象に示した。提案法によって、提示された出力に対応する入力の逆推定が可能であることが確認された。なお、これらの問題では、ネットワークの汎化能力によって、3次元空間内の一部の点の変換例から空間全体の変換関係を学習させることを考えた。そのため、少ない点から汎化能力を低下させずに学習させる必要があった。今回の結果では逆推定結果にやや誤差が生じたが、精度向上のためには、学習点を十分に与えることと、過学習を防ぐことが重要であると考えられる。

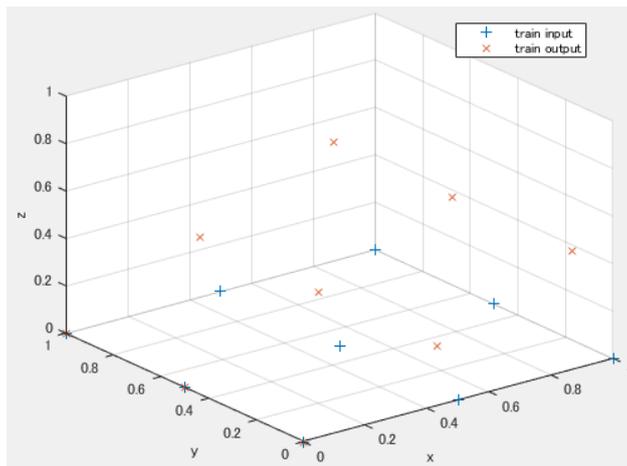
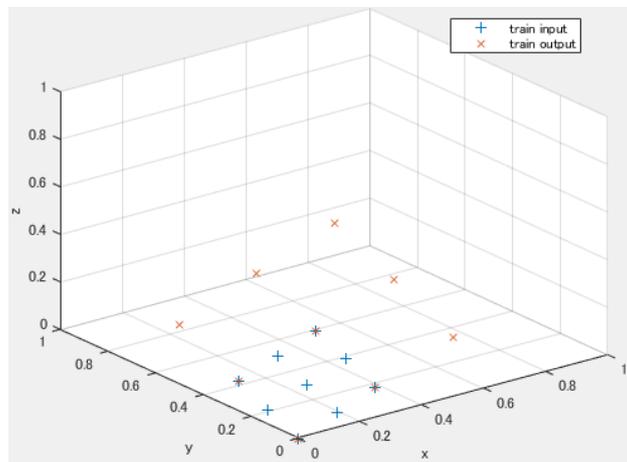
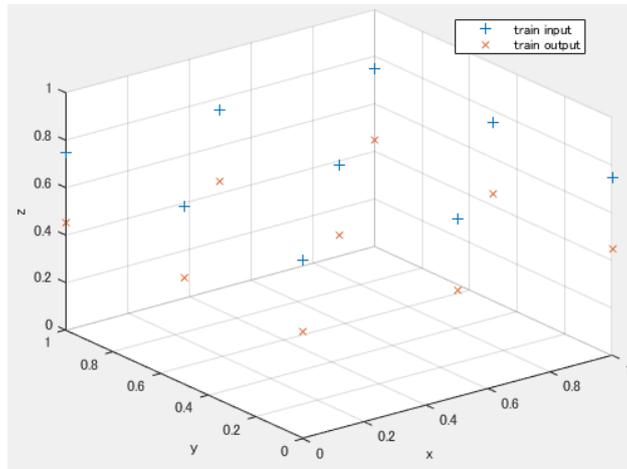


図 5.3 アフィン変換実験の学習パターン
 (a)平行移動, (b)拡張, (c)回転.

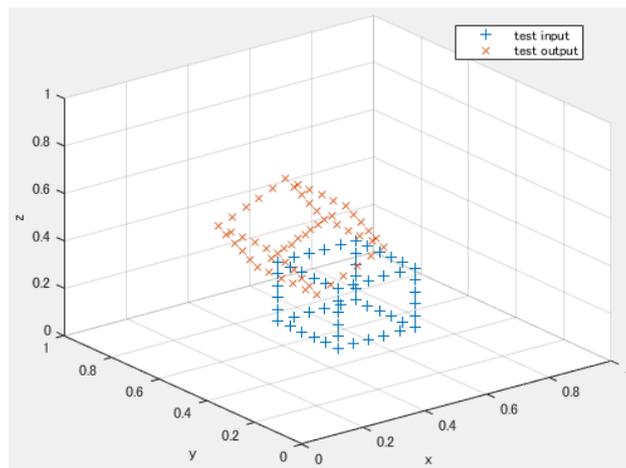
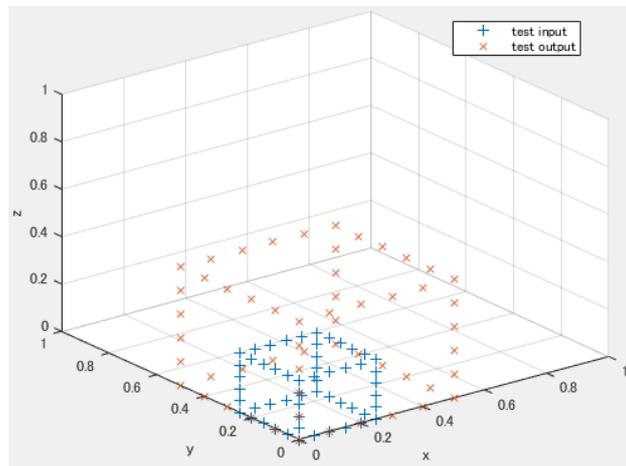
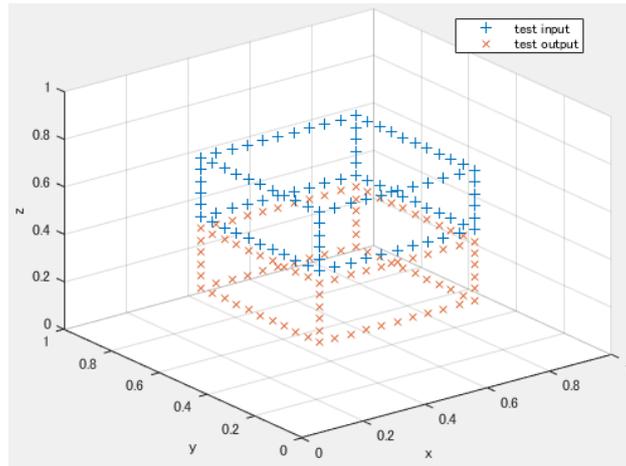


図 5.4 アフィン変換実験のテストパターン。
(a)平行移動, (b)拡張, (c)回転.

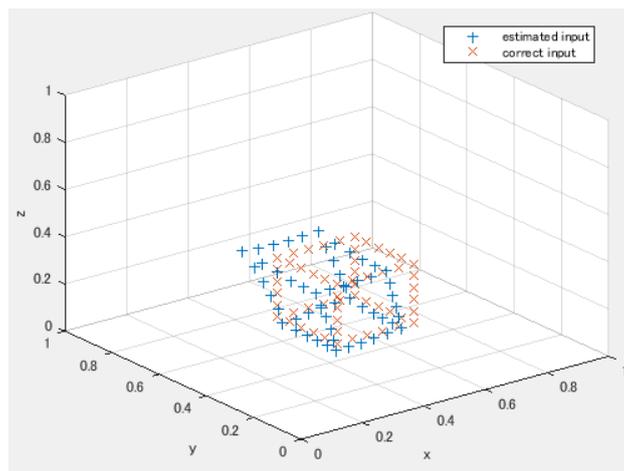
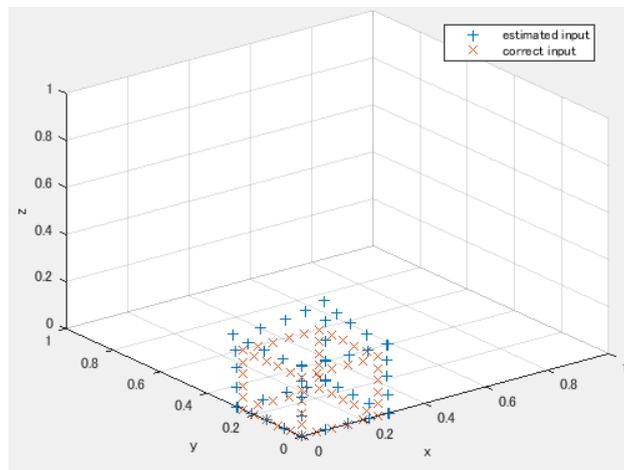
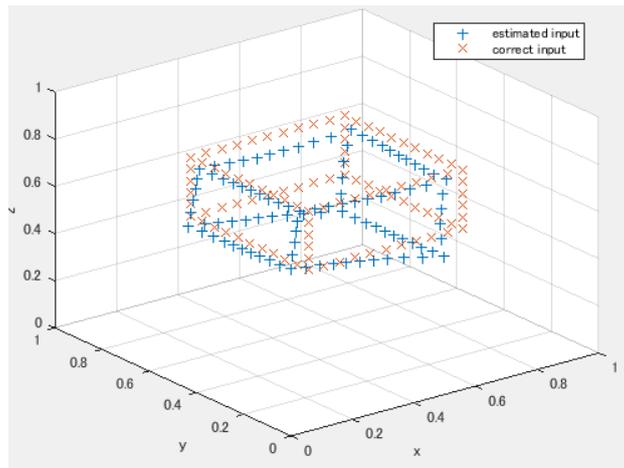


図 5.5 入力 inverse推定結果
 (a) 平行移動, (b) 拡張, (c) 回転.

表 5.4 アフィン変換問題におけるネットワークパラメータ

Parameters	Values
Number of input neurons	1
Number of hidden neurons	5
Number of output neurons	1
Forward learning rate η	0.1
Inverse update rate η	0.1
Mean squared learning error to attain	0.01
Mean squared estimation error to attain	0.0001
Maximum number of learning epochs	50000
Maximum number of estimation epochs	10000

5.1.8 従来法との比較

提案法の効果を確認するために、従来法との比較実験を行った。用いた方法は、実数型ネットワーク[16]と幾何学演算によらない四元数ネットワーク[22]である。実数型ネットワークでは、四元数の3つの虚部の値を3個の実数ニューロンに割り当て、入力・中間・出力層は四元数ネットワークの場合の3倍の素子数とした。幾何学演算によらない四元数ネットワークでは、四元数入力と四元数荷重の積の総和を、式(5.10)の変換関数に直接与える形式とした。対象とした問題は、ビット演算の2つの問題とアフィン変換の3つの問題とした。ネットワークのパラメータは、実数型ネットワークの素子数が3倍であること以外は表5.1,5.4と同じである。なお、提案法の結果は前々節および前節の実験のものである。

学習の状況を確認するために、表5.5にそれぞれの方法および問題における、学習終了時の平均二乗誤差と繰り返し回数を示す。学習終了の条件は、表5.1、5.4に示すように平均二乗誤差と繰り返し回数で設定しており、ビット演算問題とアフィン変換問題で異なるが、ビット演算問題では10000回の繰り返し後に十分に誤差が減少していること、アフィン変換問題では少ない繰り返し回数で誤差0.01を下回っていることがわかる。この結果より、いずれの方法および問題においても学習終了条件を満たし、学習が正しく行われたことが確認できた。

逆推定の結果として、表5.6にそれぞれの問題に対しそれぞれの方法で得た入力逆推定値の、正解値との平均二乗誤差を示す。ビット演算問題では、幾何学演算を用いない四元数ネットワークによるビットローテート問題でやや誤差が生じているが、それ以外では誤差

が小さく、いずれの場合でも高い精度で逆推定が行われていることがわかる。この結果より、今回のビット演算の逆推定では実数型ネットワークでも逆推定できることが確認できた。これは、今回のビット演算問題では四元数による幾何学演算と関係なく、単に与えられた入出力関係の逆関係を用いることで解決できたからと考えられる。ただし、そのような問題に対しても提案法は有効であることが確認できた。

一方、アフィン変換問題の結果では、実数型ネットワークにおいて誤差が大きく、幾何学演算を用いない四元数ネットワークでもやや誤差が生じているのに対し、幾何学演算を用いた四元数ネットワークでは誤差が小さく、高い精度で逆推定が行われていることが確認できる。この問題では、与えられた少ない学習データから未学習データに対する逆推定を行う必要がある。すなわち、学習データの構造に基づく写像関係を学習し、その結果を用いて逆推定を行うことが要求される。結果によると、実数型ネットワークでは与えられた学習データから幾何学的な関係を学習できておらず、未学習データに対して正しく逆推定ができなかったものと予想する。幾何学演算を用いない四元数ネットワークでは、やや誤差が残り不十分ながらも逆推定が行われている。一方で、幾何学演算に基づく四元数ネットワークでは、ビット演算問題の場合と同様に高い精度で逆推定が行われている。この結果は、幾何学演算に基づく四元数ネットワークが、与えられた学習データから幾何学的な関係を学習したことで、未学習データに対しても正しく逆推定を行うことができたものと考えられる。

以上より、幾何学演算に基づく四元数ネットワークは、アフィン変換のように幾何学的な関係の学習が要求される場合に有効であり、特にその結果を逆推定に用いる場合にその効果が表れることを確認した。

表 5.5 各問題, 各ネットワークでの学習完了状況.

problem		real-valued net		quaternion net (non-geometric)		quaternion net (geometric)	
		MSE	epoch	MSE	epoch	MSE	epoch
bitwise operation	bit- inversion	0.000097	10000	0.000120	10000	0.000219	10000
	bit- rotation	0.000094	10000	0.000236	10000	0.000133	10000
affine transformation	translation	0.01	285	0.01	216	0.01	471
	dilatation	0.01	1690	0.01	1417	0.01	1393
	rotation	0.01	437	0.01	282	0.01	365

表 5.6 各問題および各ネットワークの逆推定結果の平均誤差

problem		real-valued net	quaternion net (non-geometric)	quaternion net (geometric)
bitwise operation	bit-inversion	0.0499	0.0258	0.0871
	bit-rotation	0.0534	0.2236	0.0379
affine transformation	translation	0.3162	0.2002	0.0746
	dilatation	0.2138	0.1616	0.0491
	rotation	0.6601	0.2975	0.0679

5.1.9 四元数ニューラルネットによる入力逆推定法のまとめ

本節では、3次元空間内における結果から原因の効率的な推定手法の1つとして、四元数ニューラルネットによる逆問題解法を提案した。その動作を示すために、基礎的な問題としてビット演算問題とアフィン変換問題に適用し逆推定動作と精度を確認した。また効果を確認するために、通常の実数型ニューラルネットと比較し有効性を示した。

本節の結果の意義は、四元数に拡張したニューラルネットの1手法を提案し有効性を示した点にある。本節では基礎的な問題を対象として効果を示したが、3次元空間において定義される各種問題にも適用可能と考える。

5.2 四元数ニューラルネットの生体状態評価システムへの応用

各種センサを用いて、人間や物体の姿勢を評価することができる。動作を表現する物理量には、位置、速度、加速度や角度、角速度、角加速度等があり、多軸センサを用いることで3次元データとして計測できる。そこで、動作を評価したい部位に多軸センサを取り付け、得られた多次元データから、動作の解析や認識・推定が行われる。一方、3次元空間の幾何学の記述に、四元数を用いることができる。本研究では、3軸センサで得られる角速度の計測データで物体の姿勢を四元数で表現し、これらの間の関係を学習・推定することを考える。

近年、四元数に拡張されたニューラルネットが提案され、理論及び応用の両面で検討が進められている。四元数ニューラルネットは四元数入出力間の非線形関係を学習・推定することが可能である。四元数ニューラルネットのモデルとしては、層状モデルやリカレントモデルなどさまざまなものが提案されている。本研究では、角速度の3次元データと3次元姿勢の間の関係を考えるため、層状モデルを使用する。

著者らは、医療支援のための抱きつき型のバイタルサイン計測システムを提案している。このシステムは、球体に複数のセンサを取り付けて生体信号の計測を行う。本研究では、抱きつき球体の姿勢の推定に、四元数ニューラルネットの使用することを検討する。球体に取り付けた3軸角速度センサによって、球体の姿勢を推定する。本研究では、ジャイロセンサのデータからの球体の姿勢の推定に、四元数ニューラルネットを適用することを考え、シミュレーションによって効果を示す。

5.2.1 9軸ジャイロセンサ

動作を表現する物理量として、位置、速度、加速度または角度、角速度、角加速度等がある。動作解析にはこれらを計測できるセンサや方法が必要である。速度・加速度については、それぞれ時間微分・積分の関係にあるので、いずれかが判れば残りは計算で求めることができる。角速度・角加速度についても同様である。さらに位置または角度が判れば、動作の初期位置や基準位置を設定することができる。

本研究では、Switch Science社の9DoF Razor IMU M09軸モーションセンサを用いて、物体の姿勢の学習・推定を行うことを考える。対象とする物理量は角速度とし、3軸センサでデータを計測する。

5.2.2 抱きつき型システム

本研究では、医療支援のための抱きつき型のバイタルサイン計測システムを提案している。このシステムは、球体に複数のセンサを取り付けて生体信号の計測を行う。図 5.6 のように、患者が抱きつく間に自然にバイタル情報を計測する。診断や治療時の不安や症状を和らげるための形状やデザインから、迅速なバイタル情報計測のためのシステム構成までの検討を行っている。抱きつき型の形状として約 30 cm の発泡スチロール球体を用い、センサとマイコンを取り付けてバイタル情報を計測することを検討している。本研究では、抱きつき球体の姿勢の推定の問題を考え、四元数ニューラルネットを使用することを検討する。球体に取り付けた 3 軸角速度センサによって、球体の姿勢を推定する。

本研究で用いるモーションセンサと、抱きつき球体への取り付けの様子を、図 5.7 に示す。

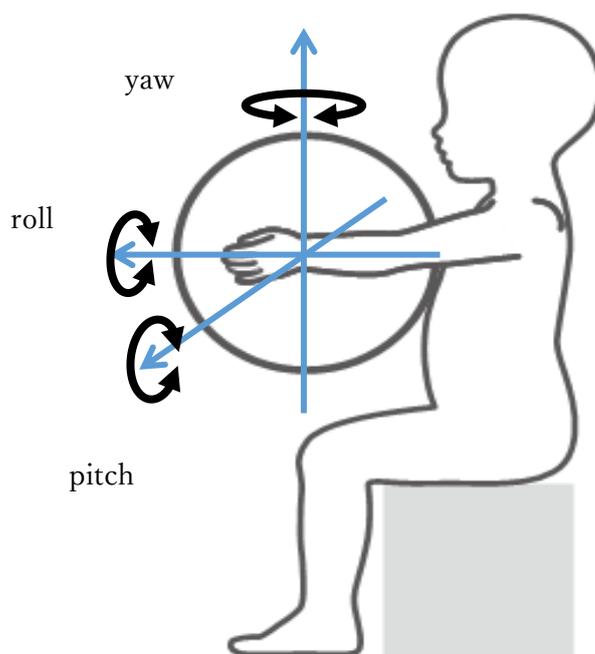


図 5.6 抱きつき型システム

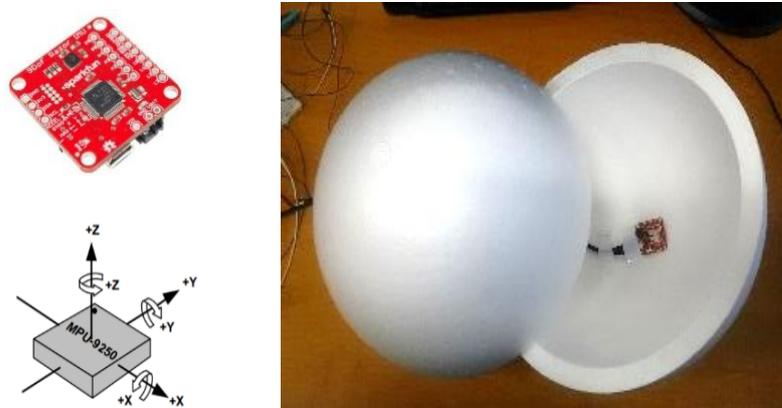
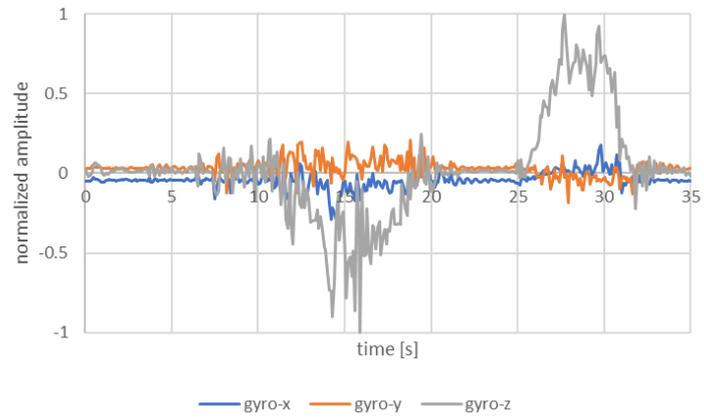


図 5.7 ジャイロセンサと抱きつき型の球体

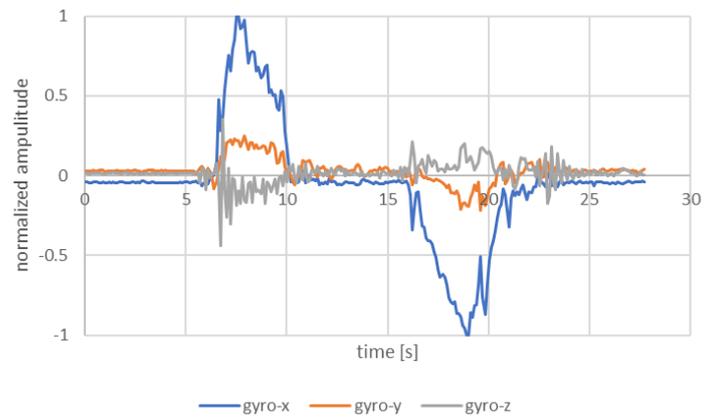
5.2.3 実験

本研究では、ジャイロセンサからのデータをもとに球体の姿勢の推定を行う。球体に取り付けたジャイロセンサによって、球体の角速度を計測し、角速度から姿勢を四元数ニューラルネットで学習・推定することを試みる。

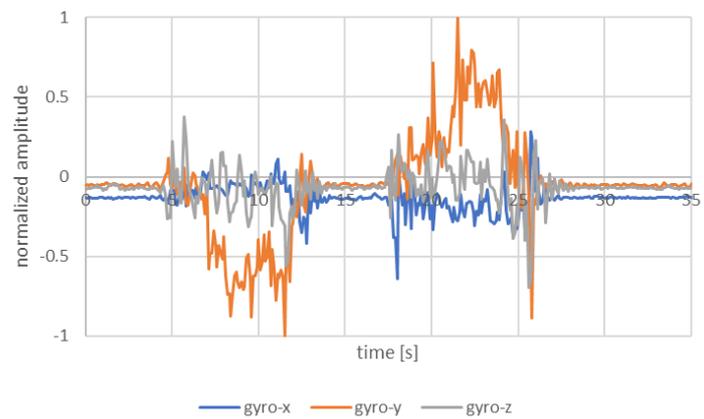
球体を、プラスマイナス 90 度で、ロール、ピッチ、ヨー回転させたときのジャイロセンサの波形を図 5.8 に示す。これらの波形からローパスフィルタでノイズを除去し、ピーク前後 2 秒間隔の計 5 点をサンプリングして入力データとする。学習は計測波形を元に作成した疑似波形を用いて行い、テストにおいては測定した波形から作成した入力データを用いた。



(a)



(b)



(c)

図 5.8 3 種類の回転 (a) ロール, (b) ピッチ, および (c) ヨー

比較のために、実数型ネットワークと四元数ネットワークの両方で学習・推定を行った。パラメータは表 5.7 の通りである。入力は角速度の各 3 軸データを四元数の各部に対応させ、出力は球体の回転による姿勢とした。実験の結果、実数型ネットワークの平均推定誤差は 0.196、四元数ニューラルネットの平均推定誤差 0.162 で、四元数ニューラルネットの方がやや誤差が小さい結果となった。

以上、四元数ニューラルネットによるジャイロセンサからの球体姿勢推定の基本動作を確認した。

表 5.7 ネットワーク パラメータ

Network	Real-valued	Quaternion
Number of input neurons	20	5
Number of hidden neurons	32	8
Number of output neurons	4	1
Learning rate ϵ	0.01	0.01
Number of training epoch	50000	50000

5.2.4 四元数ニューラルネットの生体状態評価システムへの応用のまとめ

本節では、四元数ニューラルネットを、抱きつき型生体状態評価システムの姿勢推定に適用し、その有効性を検証した。抱きつき型システムとして発泡スチロール球体を用い、3 軸モーションセンサからの信号から四元数ニューラルネットにより 3 次元の姿勢を推定する実験を行った。結果として姿勢の推定効果を確認し、実数型ニューラルネットとの比較でも良好な推定結果を得た。

本節の結果の意義は、3 次元空間内における推定に有効な四元数ニューラルネットを、本研究で対象としている抱きつき型システムに応用して効果を示したことにある。本節の結果により、抱きつき型システムによるバイタルサイン計測において、3 次元空間表現に有効な方法の導入例を示し、抱きつき型システムによる推定の改善・進展の可能性を示した。

5.3 まとめ

本章では、3次元空間内における結果から原因の効率的な推定手法の1つとして、四元数ニューラルネットによる逆問題解法を提案し、基礎的な問題としてビット演算問題とアフィン変換問題に適用して有効性を示した。また、四元数ニューラルネットを、抱きつき型生体状態評価システムの姿勢推定に適用し有効性を示した。結果として、提案した四元数ニューラルネットによる逆問題解法の効果を確認するとともに、四元数ニューラルネットによる姿勢の推定効果を確認した。

本章の結果の意義は、四元数に拡張したニューラルネットの1手法を提案し有効性を示した点および、3次元空間内における推定に有効な四元数ニューラルネットを抱きつき型システムに応用して効果を示したことにある。本節の結果により、抱きつき型システムによるバイタルサイン計測において、3次元空間表現に有効な方法が導入可能であることを示し、抱きつき型システムによる推定の改善・進展の可能性を示した。

第5章の参考文献

- [1] 金谷健一: 幾何学と代数系 Geometric Algebra-ハミルトン, グラスマン, クリフォード, 森北出版 (2014)
- [2] 金谷一郎: 3D - CG プログラマーのためのクォータニオン入門 三訂版, 工学社 (2018)
- [3] A. Hirose: Complex-Valued Neural Networks. Springer (2006)
- [4] T. Nitta: Complex-Valued Neural Networks: Utilizing High-Dimensional Parameters. IGI-Global, (2009)
- [5] P. Arena, R. Caponetto, L. Fortuna, G. Muscato and M.G. Xibilia: Quaternionic Multilayer Perceptrons for Chaotic Time Series Prediction, IEICE Transaction on Fundamentals of Electronics, Communications and Computer Sciences E79-A(10) 1682/1688 (1996)
- [6] T. Nitta: An extension of the back-propagation algorithm to quaternions, Proc. of Int'l Conf. on Neural Information Processing, 1, 247/250, (1996)
- [7] 黒江, 新田, E. Hitzer: クリフォード代数の応用-サーベイ-, 計測と制御, 51, (4), (2012)
- [8] Y. Kuroe, S. Tanigawa, and H. Iima, "Models of Hopfield-type Clifford neural networks and their energy functions—Hyperbolic and dual valued networks -,” in Proc. Int. Conf. Neural Information Processing, 560/569 (2011).
- [9] Y. Kuroe: Models of Clifford Recurrent Neural Networks and Their Dynamics.” Proceedings of the 2011 International Joint Conference on Neural Networks, 1035/41, (2011)
- [10] T. Nitta: A Solution to the 4-bit Parity Problem with a Single Quaternary Neuron, Neural Information Processing-Letters and Reviews 5 (2), 33/39 (2004)
- [11] N. Matsui, T. Isokawa, H. Kusamichi, F. Pepera, and H. Nishimura: Quaternion neural network with geometrical operators, Journal of Intelligent and Fuzzy Systems 15, 149/164 (2004)
- [12] H. Kusamichi, T. Isokawa, N. Matsui, Y. Ogawa, and K. Maeda, "A new scheme for color light vision by Quaternion neural network”, In Proceedings of the 2nd Int'l Conf. on Autonomous Robots and Agents, 101/106, (2004)
- [13] T. Isokawa, H. Nishimura, and N. Matsui: Commutative quaternion and multistate Hopfield neural networks, Proc. Int. Joint Conf. Neural Networks 1281/1286 (2010)
- [14] M. Kobayashi: Quaternionic Hopfield neural networks with twinmultistate activation function, Neurocomputing, 267, 304/310, (2017)
- [15] M. Kobayashi: Quaternion-Valued Twin-Multistate Hopfield Neural Networks With Dual Connections, IEEE Transactions On Neural Networks And Learning Systems, 32, (2) (2021)
- [16] A. Linden and J. Kindermann: Inversion of Multilayer Nets, Proc. of the International Joint Conference on Neural Networks, 425/430 (1989)
- [17] C. W. Groetsch: Inverse Problems in the Mathematical Sciences, Informatica International (1993)
- [18] Y. Kosugi and K. Kameyama: Inverse use of BP net in answer-in-weights scheme for arithmetic calculations, Proc. World Congress on Neural Networks, (3), 462/465, (1993)

- [19] 小杉, 植本, 小川 : ネットワークインバージョンにおける動的正則化, 電子情報通信学会論文誌 D-II, J81-D-II, (7), 1639/1646, (1998)
- [20] 小川, 金田 : 複素逆問題の解法のための複素ネットワークインバージョン, 電子情報通信学会論文誌 D-II, J88-D-II, (9), 1954/1962, (2005)
- [21] 小川, 井浦 : 四元数ニューラルネットワークによる逆推定の特徴, 第 3 回コンピューテーショナル・インテリジェンス研究会講演論文集, 109/112 (2013)
- [22] T. Ogawa, “Solution of Inverse Problems Using Multilayer Quaternion Neural Networks”, The 2014 International Conference on Computational Science and Computational Intelligence, (2), 317/318 (2014)
- [23] T. Ogawa and H. Kanada, “Solution for Ill-posed Inverse Kinematics of Robot Arm by Network Inversion”, Journal of Robotics, Article ID 870923, (2010)

第6章 結論

本研究では、抱きつくことで不安感を緩和しつつ生体信号を計測する医療計測システムを開発するためのプロトタイプを作成するとともに、画像認識等の技術によって機能を拡張すること、そのための機械学習・深層学習法を提案し検証を行った。具体的には、バイタルサイン計測を目的とした生体状態評価システムの構成、生体状態評価システムへの機械学習およびニューラルネットの導入、四元数に拡張したニューラルネットと生体状態評価システムへの応用について検証し有効性を示した。本研究で得られた成果を列挙すると以下のようになる。

第2章「生体信号計測および機械学習、ニューラルネット」では、本研究で対象とする生体信号、特にバイタルサインを中心にその重要性和応用例について、社会や医療の状況や問題点から考察し、その測定に使われる方法およびセンサについて比較した。さらに、生体信号や生体状態の解析、推定に関わる機械学習やニューラルネットについてその特徴や原理を示し、本研究で扱うバイタルサイン計測や機械学習・ニューラルネットの詳細を明らかにした。

第3章「バイタルサイン計測を目的とした生体状態評価システムの構成」では、マイコンとセンサによる生体状態評価システムのプロトタイプを構成し、測定可能性と精度を検証することで本システムの有効性を示した。医療の分野において、体温・心拍・血圧・呼吸のバイタルサインは重要であるが、特に小児患者においては、不安や症状を和らげつつ計測する必要がある、その1つの解決法として抱きつき型の生体状態評価システムを提案した。本システムの有効性を示すために、マイコンとセンサによって4つのバイタルサインである体温、心拍、血圧、呼吸を測定し感情状態を推定するシステムを、簡便なセンサとマイコンで実現した。本システムで用いる測定用センサについて検討した結果、体温は非接触型赤外線温度センサ、心拍は光電脈波センサ、血圧はもう1つの光電脈波センサによる脈波伝搬速度(PWV)、呼吸は加速度センサによる腹部変位によって、十分に測定可能であることを実験によって示した。

第4章「生体状態評価システムへの機械学習およびニューラルネットの導入」では、前章で提案、検証した抱きつき型の生体状態評価システムへの追加機能として、動画による表情認識や心拍測定のためのニューラルネット手法の検証を行った。具体的に検証を行った手法は、深層学習による顔画像からの感情推定法の導入と、ロボットの動作決定への表情認識の導入、さらに、顔動画によるバイタル情報の非接触計測法としての顔動画による心拍推定の導入である。まず、表情認識による感情状態の推定では、表情から推定した感情を提示して注意を引き不安を和らげることを目的とし、エクマンによる7種類の表情を深層学習によって学習したモデルを用いて感情推定を行った。実際にWebカメラとLCDディスプレイをRaspberry Piマイコンに接続し、感情に合った表示を行うシステムを構成し、実験によってその動作と認識精度を示した。続いて、関連研究として表情認識によるロボットの動

作選択を提案した。本学工学部で開発が行われている孤独感軽減ロボットを想定し、表情認識で推定した感情に基づく動作選択法を導入した。ラッセルの円環モデルに基づき感情を表す物理量を2次元で評価し、感情を中立に誘導することを目的とし動作を選択することとした。仮想空間内で動作するロボットを用いて動作を示し、表情認識精度と動作によって想起される感情を比較しその類似性を示した。さらに、ユーザの快適性と動きの制限を改善するために、抱きつき型生体状態評価システムに非接触計測法を導入したシステムを構成し、顔動画によるバイタル情報の非接触計測法として、顔動画による心拍測定が十分可能であることを示した。

第5章「四元数に拡張したニューラルネットと生体状態評価システムへの応用」では、四元数に拡張したニューラルネットによる一つの手法を提案し、生体状態評価システムへの導入の有効性を検証した。3次元空間における幾何学演算や姿勢表現に四元数は有効であり、ニューラルネットの四元数への拡張が提案されている。3次元空間内における、結果から原因の効率的な推定手法の1つとして、四元数ニューラルネットによる逆問題解法を提案しその効果を検証した。さらに、四元数ニューラルネットを抱きつき型生体状態評価システムの姿勢推定に適用することを目的とし有効性を検証した。

以上本研究では、人に安心感を与える計測システムを目指し、抱きつくことで呼吸や心拍、体温、血圧のバイタルサインを測定するシステムの開発を行った。バイタルサインの計測を目的とした抱きつき型の生体状態評価システムの構成の検討および実験を行い、さらにこのシステムへの機械学習およびニューラルネットの導入を提案および計算機実験を行った。その結果として、抱きつき型生体状態評価システムはバイタルサイン計測の形態として有効であること、さらに機械学習やニューラルネットによるさまざまな付加機能が追加可能で拡張性や可能性に優れたシステムであることを示した。加えて、四元数に拡張したニューラルネットの一手法を提案し、抱きつき型の生体状態評価システムへの応用の有効性を検証することで、さらなる拡張性や可能性を示した。本研究で提案・検証したシステムは、人に安心感を与えつつ生体信号を計測するものとして、医療計測や日常計測に寄与するものと期待される。

謝辞

この研究を遂行するにあたり、終始暖かくご指導と激励を賜りました拓殖大学工学部電子システム工学科 小川 毅彦教授に深く感謝いたします。

本論文の細部にわたり、大変貴重なご意見、ご助言を戴いた拓殖大学工学部電子システム工学科 長谷川 淳教授、林 誠治教授、何 宜欣准教授、拓殖大学工学部デザイン学科 大島 直樹教授に深くお礼申し上げます。

最後に、これまで私をあたたく応援してくれた両親と兄、妹に心から感謝します。

本研究に関連する研究業績一覧

(雑誌論文)

1. 王超, 小川毅彦, 「幾何学演算子を用いた四元数ニューラルネットのための入力逆推定法」, 計測自動制御学会論文集, Vol.58, No.2, pp.105-111 (2022-2).

(査読付国際会議論文)

2. Wang Chao, Takehiko Ogawa, Ho Yihsin, Jun Hasegawa, Naoki Oshima, "Facial Expression Recognition for Hugging Type Vital Sign Measuring System", The 2020 International Conference on Computational Science and Computational Intelligence (CSCI), pp.1533-1534 (2020-12)
3. Wang Chao, Takehiko Ogawa, Ho Yihsin, Jun Hasegawa, Naoki Oshima, "Development of Hugging Type System for Measuring Vital Signs", The SICE Annual Conference 2021, pp.159-164 (2021-9)
4. Wang Chao, Takehiko Ogawa, Ho Yihsin, Jun Hasegawa, Naoki Oshima, "Introduction of Heart Rate Measurement by Facial Video to Hugging-Type System", The 8th International Conference on Health Informatics & Medical Systems, (HIMS'22), (2022-7)
5. Wang Chao, Takehiko Ogawa, "Posture Estimation of Hugging-Type System by Motion Sensor Using Quaternion Neural Network", The 24th International Conference on Artificial Intelligence, (ICAI'22), (2022-7)

(国内学会発表)

6. 王超, 小川毅彦 「マイコンによるバイタル情報計測と感情状態の推定」第14回日本感性工学会春季大会 2p04, pp.604-605 (2019-3)
7. 王超, 小川毅彦, 何宜欣, 長谷川淳, 大島直樹, 「抱きつき型医療支援システムのための呼吸計測法について」第15回日本感性工学会春季大会 2p04 (2020-3)
8. 小川毅彦, 王超, 何宜欣, 西川佳男, 香川美仁, 林誠治, アルバレスハイメ, 「表情認識による孤独感軽減ロボットの動作選択」第15回日本感性工学会春季大会 1p06 (2020-3)
9. 王超, 小川毅彦, 何宜欣, 長谷川淳, 大島直樹, 「医療支援のための抱きつき型システムへの表情認識の導入」電子情報通信学会総合大会 H-2-20 (2020-3).
10. 王超, 小川毅彦 「四元数ニューラルネットの入力逆推定」計測自動制御学会システム・情報部門講演会 (SSI2020) , GS4-2-4, pp.156-158 (2020-11).
11. 何宜欣, 董成遠, ムハマド バイハキ ビン アブドゥル マナン, 金子侑生, 王超, 小川毅彦, 長谷川淳, 大島直樹 「小児医療支援に向けた移動ロボットの開発」第40回日本ロボット学会学術講演会, RSJ2022AC4J2-04, (2022-09)