

博士論文

高齢者に向けた
スマート生活支援デバイスに関する研究

高橋 雄太

2021年3月17日

奈良先端科学技術大学院大学
情報科学研究科

本論文は奈良先端科学技術大学院大学情報科学研究科に
博士(工学) 授与の要件として提出した博士論文である。

高橋 雄太

審査委員：

安本 慶一 教授	(主指導教員)
松本 健一 教授	(副指導教員)
荒川 豊 客員教授	(副指導教員)
諏訪 博彦 特任准教授	(副指導教員)

高齢者に向けた スマート生活支援デバイスに関する研究*

高橋 雄太

内容梗概

サイバー空間とフィジカル空間を高度な技術によって融合させたシステムを用いることで社会課題を解決し生活の質を向上させた人間中心の社会 Society 5.0 に向けて新たなスマートデバイスが開発されている。しかしながら、既存のスマートデバイスは高齢者にとって煩わしさがあり、インタフェースも最適化されておらず十分な生活の支援が期待できない。本研究では、今まで通りの生活を送りながら自然に使えることを目指し、高齢者が抱える問題に特化した二つのスマートデバイスを開発した。日頃から常に支援を行えるようそれぞれのデバイスは屋外と屋内の二つの生活空間に対応している。屋外においてはリハビリテーションの支援を行う。効果的なりハビリテーションを行うには歩行能力を正確に知る必要があるが、測定には時間的・身体的な負担が大きい。そこで杖にセンサを取り付け、日々の杖の使用の仕方から歩行能力を推定できるのではないかと考えた。杖の加速度・角速度データから一歩一歩杖を突く動作切り出すアルゴリズムを考案し、その区間の特徴から歩行距離を推定する重回帰モデルを構築した。歩行の区間と歩行距離を推定することで歩行能力の指標となる歩行速度も推定でき、リハビリテーションに役立てることができる。高齢者、片麻痺患者、健常者を含む 16 名に協力いただいた実験の結果、95.6%の精度で歩行を検出するとともに 88.1%の精度で歩行距離を推定可能であることを明らかにした。屋内においては家電操作の支援を行う。テレビ、エアコン、照明など様々な家電が一般家庭内に普及しているが同時にリモコンの数も増え、管理や操作を覚える苦勞が増えてくる。この問

*奈良先端科学技術大学院大学 情報科学研究科 博士論文, 2021 年 3 月 17 日.

題を解決するには全ての家電を操作できるデバイスを用意することだが、既存のスマートフォンやスマートスピーカーは高齢者にとって易しいユーザインタフェースとは言えない。そこで一般的なリモコンに似た形状のスマートリモコンを開発した。リモコンの先端にはカメラが付いており、リモコンを向けると画像認識によって操作したい家電を認識する。認識には畳み込みニューラルネットワークを用いたモデルを使用し、汎用的な学習モデルを家電の画像でファインチューニングしている。家電の操作インタフェースはボタンであるため、利用者は操作したい家電にリモコンを向け、ボタンを押すだけで直感的に操作できる。評価実験の結果、5種類の家電を3カ所の位置から81.1%の精度で認識でき、認識時間が約2秒かかることを明らかにした。

キーワード

高齢者, サイバーフィジカルシステム, スマートデバイス, リハビリテーション, 家電

A Study on Life Support Smart Devices for the Elderly*

Yuta Takahashi

Abstract

New smart devices are being developed toward a human-centered society called Society 5.0, which solves social problems and improves the quality of life by using systems that fuse cyber and physical space with advanced technology. However, existing smart devices are cumbersome for the elderly and their interfaces are not optimized and are not expected to adequately support life of the elderly. Therefore, we developed two smart devices designed to be used naturally and to solve the problems of elderly people while they spend their daily lives as usual. The developed two devices are compatible with two living spaces, outdoor and indoor, respectively, to provide constant daily support. In the case of the outdoors, the device provides rehabilitation support. For effective rehabilitation, it is necessary to know the gait ability accurately, but the measurement is time-consuming and labourious for elderly people. Therefore, we attached a sensor to the cane to investigate if it would be possible to estimate the walking ability of a person based on his/her daily use of the cane. We devised an algorithm to cut out a step-by-step walking motion from acceleration and angular velocity data and constructed a multiple regression model to estimate the walking distance from the features of the section. By estimating the section of walking and walking distance, the walking speed, which is an indicator of walking ability and useful information

*Doctoral Dissertation, Graduate School of Information Science, Nara Institute of Science and Technology, March 17, 2021.

for rehabilitation, can be estimated. An experiment with 16 people including elderly people, hemiplegics, and healthy people showed that the walking distance could be detected with 95.6% accuracy and estimated with 88.1% accuracy. In the case of indoors, the device provides support for the operation of home appliances. While various home appliances such as televisions, air conditioners, and lights are becoming more and more common in our homes, the number of remote controls is also increasing, bringing a burden to learn how to operate them and manage them. The solution to the problem is to have a device that can operate all home appliances, but existing devices such as smartphones and smart speakers are not always an easy user interface for the elderly. Therefore, we developed a smart remote control that has the similar shape as an ordinary remote control. A camera is attached to the tip of the remote control, and when the user points the target appliance with it, it recognizes the appliance by image recognition. We constructed a model based on the convolutional neural network for recognition and fine-tuned a general model with images of consumer electronics. Since the operation interface of the home appliances is a button, users can operate the home appliances intuitively by only pointing the remote control at the home appliance and pressing a button. Experimental results showed that five different home appliances can be recognized from three locations with 81.1% accuracy and the recognition time was about 2 seconds.

Keywords:

Elderly, Cyber Physical System, Smart Device, Rehabilitation, Home Appliance

目次

1. 序論	1
2. 歩行能力を診断するスマート杖	5
2.1 はじめに	5
2.2 日常の歩行センシングによるリハビリ支援	7
2.3 杖装着型センサデバイス	9
2.3.1 センサデバイスの要件	10
2.3.2 杖に装着するセンサデバイス	11
2.4 杖の動作に基づく歩行動作検出	12
2.4.1 歩行データの収集実験	14
2.4.2 歩行時の加速度の特徴	14
2.4.3 歩行動作検出アルゴリズム	19
2.4.4 歩行距離推定のための相関分析	24
2.5 提案手法の評価	26
2.5.1 歩行動作の検出精度	27
2.5.2 歩行距離の推定	28
2.6 関連研究	32
2.7 考察	33
2.8 まとめ	34
3. 直感的に家電選択可能なスマートリモコン	35
3.1 はじめに	35
3.2 システム設計	37
3.2.1 動作の流れ	38
3.2.2 Control ユニット	39
3.2.3 Deep learning ユニット	39
3.3 性能の評価	40
3.3.1 セッティング	40

3.3.2	学習の結果	41
3.3.3	家電の認識精度	42
3.3.4	家電の認識時間	43
3.3.5	家電の操作時間	44
3.4	関連研究	47
3.5	考察	49
3.6	まとめ	50
4.	結論	52
	参考文献	54

目次

1	日常の歩行動作センシングの流れ	8
2	製作したプロトタイプの杖装着型センサデバイス	11
3	センサデバイスを装着した杖	13
4	杖を使用した歩行動作	14
5	歩行データ収集実験の様子	15
6	各実験協力者の歩行時の加速度の変化	16
7	杖を突きながら歩行したときの加速度データ	18
8	歩行検出のパラメータ	20
9	振り上げ動作検出フローチャート (state 0)	21
10	振り下げ動作検出フローチャート (state 1)	22
11	インパクト検出フローチャート (state 2)	23
12	決定係数が0.30以上のパラメータと距離の相関関係 (赤: 健常者, 緑: 片麻痺患者)	25
13	パラメータの数と歩行距離推定精度の関係	30
14	システムの全体	38
15	Control ユニット	39
16	ファインチューニングでの CNN の構造	41
17	実験環境	42
18	学習中の精度と損失値	43
19	認識時間の分布 (n=750)	45
20	ユーザテストでの家電操作時間	46

表目次

1	各パラメータの平均値と標準偏差	21
2	1回の歩行動作から抽出したパラメータ	24
3	歩行動作の検出結果	28
4	歩行距離推定の結果	31

5	3 地点からの家電の認識精度	44
---	--------------------------	----

1. 序論

様々な種類の電子計算機が開発され一般的にも普及したことで我々の生活は少しずつ変化し始めている。高い演算能力を持った電子計算機は複雑な処理を短時間で終わらせ、これまでにない価値のあるサービスを提供できるようになった。インターネットを介することで物理的なサーバの存在を気にすることなくサービスを受けられるようになり、クラスターで構成された仮想化環境によって拡張性、可用性、信頼性が高まったクラウドコンピューティングという概念も普及している。小さな電子計算機は、電波網が整備されたことによりどこにいてもインターネット上のサービスにアクセスできるようになった。特に小さい電子計算機は計算機そのものの存在を気にすることなく生活空間に導入でき、生活で使用する「モノ」に実装されることも増えてきた。この概念をIoT(Internet of Things)と呼び、身に着けることが可能なデバイスはウェアラブルデバイスと呼ばれる。小さな計算機は物理的な人やモノの情報を収集するのに優れ、インターネット上にある仮想空間と現実空間を繋ぐインターフェースとして活用される。仮想空間をサイバー空間、物理空間をフィジカル空間として、二つの空間で構成されたシステムはサイバーフィジカルシステム(CPS)と呼ばれる。CPSにより社会課題を解決し生活の質を向上させた人間中心の社会 Society5.0 が科学技術基本計画の第5期にて内閣府から提唱され、普及と発展が期待されている [1]。

超高齢化社会を抱える日本においては高齢者へのCPSの適応について考えていかなければならない。高齢者の人口比率が年々増え続けていることから、今後の社会を支える基板として高齢者の活躍が期待されている。多くの高齢者が健康的に活発的にあり続けるには高齢者が持つ課題をCPSによって解決していくことが重要となる。歩行や階段の上り下りへの苦勞、文字が読みにくくなったなど高齢者特有の課題は多く存在するが基本的には老化による身体能力の低下が原因である。そのため、CPSは健康状態の維持・改善、身体能力の低下の補助を目的としたシステムが基本となる。具体的な例としては、ウェアラブルデバイスで心拍、活動量、位置情報をセンシングする健康モニタリングシステムや介護が必要な人の自立を支援・補助するロボット、ショッピングモールや駅構内の案内をするデジタルサイネージ、無人で運転可能な次世代運転システムが挙げられる。

このようなシステムが実用化されることで既存のシステムが効率化され人員を削減できるようになり，結果として社会全体の生産性を向上できる．そして，個人としては快適で活力のある生活が過ごせるようになる．

CPSは一般的なICTシステムに比べて物理空間をシステムの構成要素に入れている点が特徴的である．電波網が整備されたことで誰しもがインターネットにいつでもアクセスできるようになり，スマートフォンやタブレットのようなスマートデバイスによって物理空間の情報を収集できるようになった．スマートデバイスの他の例としては，腕輪型のスマートウォッチ，眼鏡型のスマートグラスがあり，身に着けられることからウェアラブルデバイスとも呼ばれる．スマートスピーカはマイクとスピーカを内蔵したデバイスで音声対話によって情報の検索や家電操作を行える．スマートデバイスはセンサが内蔵されており，画像，生体情報，動作のような物理空間の情報をセンシングでき，ネットワークを介してサーバに送信できる．そして，サーバ側でデータを分析することで知見や価値を創出でき，利用者にフィードバックすることで生活に役立てることができる．スマートデバイスは物理空間と仮想空間のインターフェースデバイスとしての役割を担っており，CPSを設計する上では重要となっている．システムの目的によっては専用のスマートデバイスを開発することも必要となる．

スマートデバイスのような情報機器は新しいサービスを受けられる反面，高価であったり利点がわかりにくかったり或使用するまでの敷居が高い．高齢者においては3つの理由から敷居がさらに高くなっていると考えられる．1つ目は操作インターフェースが高齢者にとって適していないことである．皮膚の乾燥や触り方の問題でタッチパネルの操作が困難であったり，液晶画面が小さくてよく見えない，音声対話では音が聞き取れないなどの身体的な理由から円滑な操作が難しい．2つ目は利用の敷居が高いことである．敷居が高い理由として操作を覚えるのが大変であったり，知識が不十分なことから装置の設定ができなかったり或使用に際し不安を感じる高齢者が多い [2]．3つ目はそもそもデバイスの必要性を感じないことである．情報機器に慣れ親しんでいない高齢者にとってはスマートデバイスの必要性を感じられず利用の検討に至らない．このような観点から高齢者へスマートデバイスを普及するにはいくつかの障害があり，CPSの利活用による生産性・

生活の質の向上の恩恵を受けられないことが問題となる。

既存のスマートデバイスは高齢者が抱える身体的な問題へのアプローチが不十分であり、高齢者を対象としたCPSを構築するには高齢者の性質に合わせてスマートデバイスを設計する必要がある。上記に挙げた3つの理由に対応させ本研究では設計コンセプトとして、

1. 高齢者に配慮したユーザビリティ
2. 生活空間へ自然に導入できる
3. 高齢者が抱える問題を解決し、生活を支援するサービスを提供

を提案する。高齢者でも扱えるインターフェースにすることで操作性によるストレスを減らし、操作を覚える手続きを極限まで無くすことで使用の不安を取り除き、高齢者が抱える生活の悩みに着目することでサービスの必要性を高める。このコンセプトを元にスマートデバイスを設計すれば高齢者が使いたくなるようなシステムが実現できると考えた。日常生活で常にスマートデバイスの恩恵を受けてもらうために本研究ではデバイスの利用箇所として屋外と屋内に分け、それぞれの生活空間で動作するスマートデバイスを一から開発することにした。

屋外においてはリハビリテーションの支援を行う。効果的なリハビリテーションを行うには歩行能力を精確に知る必要があるが、測定には時間的・身体的な負担が大きい。そこで杖にセンサを取り付け、日々の杖の使用の仕方から歩行能力を推定できるのではないかと考えた。杖の加速度・角速度データから一歩一歩杖を突く動作切り出すアルゴリズムを考案し、その区間の特徴から歩行距離を推定する重回帰モデルを構築した。歩行の区間と歩行距離を推定することで歩行能力の指標となる歩行速度も推定でき、リハビリテーションに役立てることができる。高齢者、片麻痺患者、健常者を含む16名に協力いただいた実験の結果、95.6%の精度で歩行を検出するとともに88.1%の精度で歩行距離を推定可能であることを明らかにした。

屋内においては家電操作の支援を行う。テレビ、エアコン、照明など様々な家電が一般家庭内に普及しているが同時にリモコンの数も増え、管理が面倒になり操作を覚える苦勞が増えてくる。この問題を解決するには全ての家電を操作でき

るデバイスを用意することだが、既存のスマートフォンやスマートスピーカは高齢者にとって易しいユーザインタフェースとは言えない。そこで一般的なりモコンと同じ形状のスマートリモコンを開発した。リモコンの先端にはカメラが付いており、リモコンを向けると画像認識によって家電を認識し操作できる。認識には畳み込みニューラルネットワークを用いたモデルを使用し、汎用的な学習モデルを家電の画像でファインチューニングしている。家電の操作インタフェースは物理的なボタンであるため、利用者は操作したい家電にリモコンを向け、ボタンを押すだけで直感的に操作できる。評価実験の結果、5種類の家電を3カ所の位置から81.1%の精度で認識でき、認識時間が約2秒かかることを明らかにした。

本論文は4つの章から構成される。本章では研究に至るまでの社会的背景と高齢者が利用する場合の既存のスマートデバイスが問題点と設計コンセプトについて述べた。2章ではリハビリテーション支援を目的としたスマート杖に関する研究、3章では家電操作支援を目的としたスマートリモコンについて述べる。4章では研究の全体をまとめつつ課題や今後の展望について述べる。

2. 歩行能力を診断するスマート杖

2.1 はじめに

リハビリテーション（以下、リハビリ）において、歩行能力を評価することは、高齢者や片麻痺患者のようなリハビリ患者の容体を把握するとともに、訓練やアドバイスの指針を決めるために重要である。また、リハビリによる効果を評価することは、方針の正しさやリハビリ患者の回復を把握するために必要である。超高齢化社会の到来により、今後、維持期リハビリが必要な患者が増えることが予測される。維持期リハビリは、リハビリにおいて運動器やADL（Activities Daily of Living）の維持と向上を行うフェーズであり、リハビリ患者は通所か訪問によって支援を受ける。しかしながら、維持期リハビリでは、通院時に比べ、人員不足が原因で個別のリハビリの計画や対応が十分に行えていないことが問題としてあげられている [3]。これにより、歩行能力やリハビリの効果の評価が十分に行えず、結果として、ADLの低下を引き起こしてしまう。歩行能力が低下することは、日常生活において交通事故や転倒を引き起こしてしまう大きな要因となり、最悪の場合では死につながることもある。

リハビリ患者の歩容は、医師や理学療法士のようなリハビリ支援者による目視での観察で、安定性、前進能力、柔軟性に基づいて評価される [4]。この評価方法は経験や勘に基づく主観的な評価であるため、近年では装置を用いた歩行の定量的な評価手法が提案されている [5]。

一方、歩容だけではなく、歩行の実用性についての評価も行われている。歩行の実用性とは、日常生活を送るのに必要な歩行能力のことであり、長時間の歩行や日常生活において必要な歩行速度も評価の対象となる。評価の方法としては、10m歩行テスト [6, 7]、6分間歩行テスト [6]、TUG（Timed Up and Go） [7, 8]、SWWT（Stops walking when talking） [9]、FAC（Functional Ambulation Categories） [10]、実用的歩行能力分類 [6] などがある。これら評価方法によって、歩行の耐久性・速度、バランス、認知能力の評価が可能であるが、テストにおける被歩行評価者の転倒のリスク、人手不足によるリハビリ支援者の業務の負担の増大、環境構築が難しいなどの理由によりテストを定期的に行うことは簡単ではない。

近年では、センサ技術の発展により人の行動を常時センシングすることが容易となっている。そこでリハビリ患者の日常の歩行をセンシング・評価することで歩行の実用性を評価するデバイスとシステムの開発を進めている。日常の歩行をロギングするツールとして、万歩計が使用されてきたが、保持するデータが少なく歩行状態の詳細な分析が行えない。そのため、センシングにより詳細な歩行データを収集し、分析することで、多角的な歩行の評価が期待できる。歩行の実用性を評価するうえで一番の問題となるのはテストに時間がかかることであり、日常の歩行をセンシングすることでリハビリ支援者・患者両方の負担を減らすことができる。また、リハビリ患者の歩行能力を把握することができ、効果的なりハビリ支援につなげることができる。

歩行のセンシングを行う際にはスマートフォンがよく使用されている。スマートフォンのほとんどに加速度・ジャイロセンサが搭載されており、高性能な演算能力を持っているため、歩行の検出と分析が容易である。しかし、本研究でスマートフォンを使用するのは難しいと考えている。理由として、これまでリハビリに特化した介護施設と協力し、リハビリ患者の行動を名札型センサデバイスにより認識することで、リハビリ患者の1日の活動を記録する業務の負担を減らす研究を行ってきた [11, 12]。この研究過程において、リハビリ患者がスマートフォンを所持することがほとんどないことが分かっている。さらに、スマートフォンは移動中に常時所持しているとは限らず、また、所持する位置も人によって異なるためセンサデータの処理が難しい。そのため、本研究も同様にスマートフォン以外のデバイスを用いてセンシングを行うこととする。

スマートフォン以外のセンサデバイスを利用するとして、次にセンサデバイスの装着位置が重要となる。

まず、腰、メガネなどにセンサデバイスを装着することが考えられるが、長期的に使用することを考えると非接触型であるセンサデバイスの方がリハビリ患者への負担が少ない。靴やインソールなどの足回りにセンサを取り付けセンシングする例はすでいくつかある [13, 14, 15] が、実用性が低いと考える。理由としては、靴にセンサを装着した場合、外部のものとの接触や振動よりデバイスが外れる可能性が高いこと、インソール型のセンサデバイスの場合、充電のようなメン

テナンスコストが高いこと、両方においては、センサデバイスが両足分必要となり高コストになることや片足が動かない患者の歩行量のセンシングが難しいことが挙げられる。

そこで我々は福祉器具である杖にセンサデバイスを取り付けることを考えた。移動手段として歩行を用いているリハビリ患者は日常の移動において杖を使用することが多く、要介護者の69.6%が杖を所有している [16]。杖の使用者は歩行が不安定なため、杖なしで歩行可能な人に比べると歩行評価の重要性が高い。杖にセンサデバイスを取り付ければ、人体へは非接触であるため、デバイスの圧迫感がなく利用者への負担が少ない。また、身体の動きや足の運び方ではなく、杖の運び方のみをセンシングするため、片麻痺患者などの非対称な歩行を行う人の歩行の検出が容易となる。さらに、センサデバイスを組み込み型ではなく装着型にすることで、1点杖、4点杖、松葉杖などの様々な種類の杖にも適用でき、汎用性が高く、杖を使用するすべての人に利用してもらうことができる。

本研究の目標は、杖にセンサデバイスを取り付けて日常の歩行動作のセンシングを行い、リハビリ患者の歩行の実用性を評価するシステムを構築することである。杖に装着したセンサデバイスで歩行をセンシングするには、歩行状態を検出するアルゴリズムが必要となる。そして、歩行の実用性を評価するには、歩行速度を計測する必要があり、歩行速度の算出には歩行距離を計測できなければならない。本研究では、リハビリ施設で実際のリハビリ患者の歩行データを収集・分析し、センサデバイス内で歩行動作を検出できるアルゴリズムを構築した。そして、歩行距離を推定する重回帰モデルを構築し、歩行動作の検出精度と歩行距離の推定精度の評価を行った。その結果、歩行動作の検出率は95.6%で、歩行距離の推定精度は88.1%となった。この結果から、杖に装着したセンサデバイスにより歩行動作を十分な精度で認識できることを示した。

2.2 日常の歩行センシングによるリハビリ支援

本研究では、日常の歩行をセンシングし、分析することでリハビリ患者の歩行の実用性を把握し、リハビリ支援に役立てることを目標としている。図1に提案する歩行センシングの流れを示す。

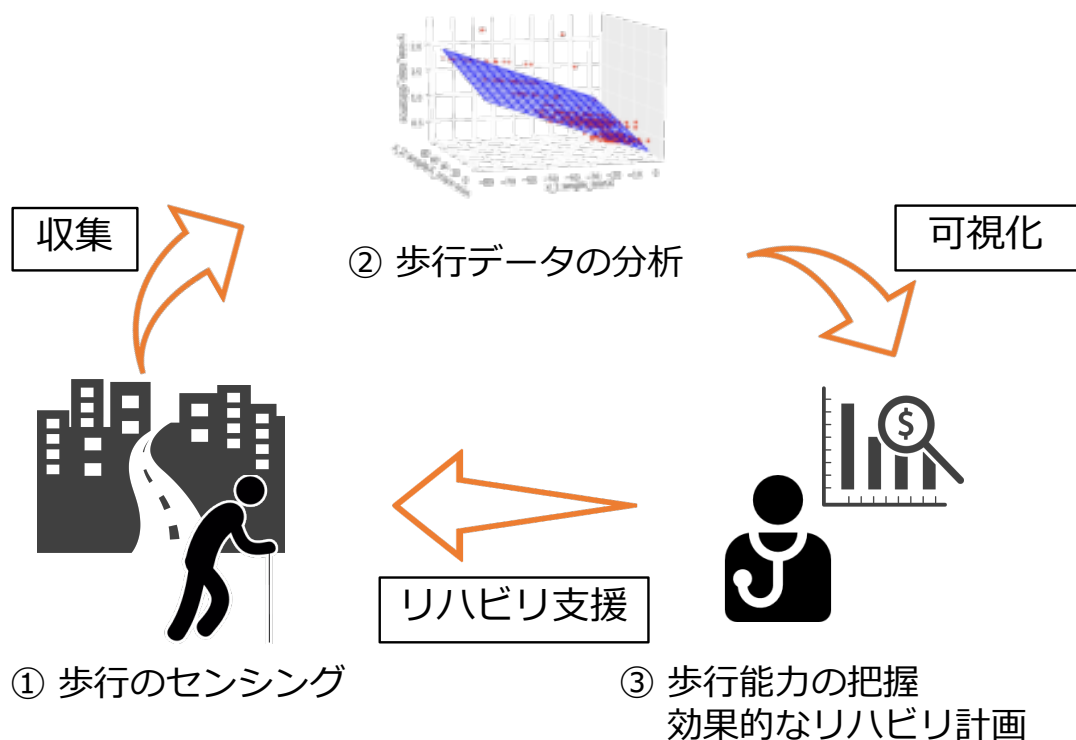


図 1 日常の歩行動作センシングの流れ

① 歩行のセンシングでは、杖に装着したセンサデバイスによって日常の歩行動作のセンシングを行い、センサデータのロギングを行う。ロギングする歩行データは、データ容量の圧迫やデータの抽出の時間の増加を避けるため、ローデータではなく、杖の一突きごとの動作データから得られる抽出パラメータのみとする。ここでの抽出パラメータとは、杖を振り上げる時間・杖を振り下げる時間・杖を振り上げる角度・杖を振り下げる角度・杖を接地したときのインパクトの強さなどを指す。そして、日常の歩行で収集した歩行データをデバイスの利用者が家に帰宅したり、通院のために福祉施設を訪れたりしたときに、デバイスからロギングした歩行データの収集を行い、サーバに集約する。主な利用者である高齢者のスマートフォンの所持率は高くなく、リハビリ患者はスマートフォンをほとんど所持しないため、スマートフォンがなくてもデータの収集ができるこのような仕組みを取り入れている。また、近年ではセンサデバイスを 3G や LTE などのセル

ラ網へ接続できるが、電力消費が大きいことや利用コストが高いことから本研究では使用しない。

② 収集した歩行データを分析し、リハビリ支援者へ提供するデータを算出する。収集した歩行データというのは、杖を突いた度に得られるパラメータのデータ列であるため、歩行を評価するには、包括的な分析をする必要がある。分析して得られるデータとしては、杖の使用の有無、杖が地面から離れてからもう1度着くまでの時間、歩行距離、歩行速度、継続歩行距離、継続歩行時間があげられる。これらのデータを過去のデータと比較しつつ、可視化を行いリハビリ支援者に提供する。

③ 医師や理学療法士が評価結果を参考に利用者の日常の歩行状態を把握し、リハビリ支援に活用する。分析したデータから歩行能力がどの程度あるのか、歩行能力が回復、維持、悪化しているのか、悪化している場合はどのような能力が下がっているのかを知ることができる。そして、結果をリハビリ計画に組み込むことで効率的なリハビリ支援につなげることができる。また、利用者に歩行評価の結果をフィードバックすることでリハビリのモチベーション維持につなげることができると思う。

本章では、① 歩行のセンシングと② 歩行データの分析に注力し、センシングに必要なデバイスの要件の定義とデバイスの開発、センシングに必要な歩行検出アルゴリズムを考案し、歩行データの分析として、歩行の実用性の指標を算出できる歩行距離について評価を行う。

2.3 杖装着型センサデバイス

本節では、日常歩行センシングを実現するために必要なセンサデバイスの要件と開発したプロトタイプของセンサデバイス、本研究で使用したセンサデバイスについて述べる。本研究のアプローチとして、杖にセンサデバイスを取り付けることでリハビリ患者の歩行のセンシングを試みる。既存の歩行のセンシングを行うデバイスとして、スマートフォン、リストバンド型デバイス、靴型デバイスがあるが、デバイスを杖に装着するだけでよいため管理がしやすく、人体に非接触であるためデバイスを取り付けていることの圧迫感が少なく、実用性の面において

杖でのセンシングは優位であると考える。さらに、片麻痺患者のような非対称な歩行においても身体の動きではなく、杖の動きをセンシングするため、ロバストなセンシングが期待できる。

高齢者向けのスマートデバイスとしてのコンセプトと照らし合わせると、(1) 電源以外の操作インターフェースがなくユーザビリティが高い、(2) デバイスを杖に装着するだけでよく導入の敷居が低い、(3) 高齢者が抱える身体の健康という問題に対してリハビリ支援という形でサービスを提供する、というように対応しており、高齢者にとって利用しやすく実用性の高いスマートデバイスとして設計している。

2.3.1 センサデバイスの要件

日常歩行センシングに必要なセンサデバイスとして、まず、杖に取り付け可能な大きさであり、センシングに必要な加速度・ジャイロセンサが実装されている必要がある。また、歩行中はセンサを動作させる必要があり、電力の消耗が激しい。そのため、使い切りの電池ではなく、充電可能なバッテリー駆動で動作する必要がある。そして、センシングした杖の振り上げ・振り下げ時の時間・角度・インパクトの強さや杖の接地時のインパクトの強さなどの歩行のパラメータをローカルでロギングするための記憶領域が必要であり、ロギングした歩行データを手軽にアップロードするための無線通信機能が必要である。これらをまとめると本デバイスに必要な要件は以下となる。

- <要件1> 杖に装着可能な大きさ
- <要件2> 加速度・ジャイロセンサを有する
- <要件3> バッテリーで動作し、充電可能
- <要件4> センシングしたデータをロギング可能
- <要件5> 無線通信機能を有する




図 2 製作したプロトタイプの杖装着型センサデバイス

2.3.2 杖に装着するセンサデバイス

まず，上記の要件を満たす杖に装着するプロトタイプのセンサデバイスの開発を行った．図2に開発したセンサデバイスを示す．本デバイスを検証したところ，micro SD カードへのセンサデータの書き込みに時間がかかり，10Hz を超えたサンプリング周波数でのデータのロギングが難しいことが判明した．杖の歩行データは，杖を突くインパクトが非常に重要であるが，10Hz ではインパクトの検出が難しい．さらに，杖への装着が可能ではあるがデバイスが杖から横にはみ出しており，実用の面では十分な大きさとはいえない．このような理由から，他のセンサを使用した新たなデバイスの開発が必要となった．

プロトタイプでの問題点を解決でき，リハビリ支援を実現するための新たなセンサデバイスとして，筆者らが開発した SenStick[17] を使用することとした．SenStick は小型のセンサデバイスで，8つのセンサ（加速度，ジャイロ，地磁気，温度，湿度，気圧，光，赤外線）と 32MB の大容量フラッシュメモリを搭載している．本デバイスは，デバイスの要件をすべて満たしている．デバイスの大きさ

は、50mm × 10mm × 5mm と小型であり、杖の幅より小さい。大容量フラッシュメモリを搭載しているため、センサのサンプリング周波数を最大 100Hz に設定できる。無線通信機能としては、BLE (Bluetooth Low Energy) を使用できる。また、ファームウェアを書き換えることができるため、用途にあった機能の開発が可能である。

図 3 に杖に装着した様子を示す。SenStick を装着するためのケースを 3D プリントで印刷し、マジックテープで杖に装着している。デバイスを杖の下部に取り付けると物体への接触や衝撃によりデバイスが外れたり、破損したりする可能性があるため、実用面を考慮してデバイスの装着位置は持ち手の近くである上部付近とした。センサは加速度とジャイロを使用し、加速度のレンジを 4G、ジャイロのレンジを 500rad/sec とした。事前調査で、サンプリング周波数が 20Hz 程度であると歩行評価に必要なパラメータを検出できないことが多かったため、サンプリング周波数は 50Hz に設定した。本研究の実験では、上記の設定の SenStick を装着した一点杖で行う。

2.4 杖の動作に基づく歩行動作検出

歩行から杖の一突きごとの歩行評価用パラメータを算出するために、センサ装着杖により歩行動作を検出する方法を検討した。杖を突く動作を含んだデータを検出し、切り分けられれば一つの動作ごとにデータを分析できるようになる。検出する歩行動作は図 4 に示すように杖が接地した状態から杖を振り上げて、杖を振り下げる動作を経過して杖を床に突くインパクトまでの区間である。センサデータから特定波形を検出する手法として、DTW (Dynamic Time Warping) をストリーム処理に適応した SPRING[18] や隠れマルコフモデルを用いた手法 [19] があるが、センシングさせながらこのような処理をするのは演算量が多く電力消費量も増えてしまいデバイスに求められるスペックが高くなる。そのため単純なルールベースで歩行を検出をすることにした。ルールベースのアルゴリズムであれば処理能力が低いチップであってもリアルタイムにセンサデータを処理することが容易である。歩行の検出処理を後に回した場合、センシングした生データを無線通信を介して取得する必要があるが、BLE では転送速度が遅いため実用性が下がっ




図 3 センサデバイスを装着した杖

てしまう。リアルタイムに歩行を検知し、歩行に関する特徴量を抽出して記録しておくことで、ロギングする歩行データのデータ量を削減でき、データ転送にかかる時間を減らし、ハードウェアのコストを下げるができる。本章では、まずはじめに単純なルールベースを構築するために必要な歩行時のセンサデータを収集した実験について述べ、その後、収集したセンサデータの歩行時の特徴的なパターンについて説明し、ルールベースに用いるパラメータを算出して構築した歩行動作の検出アルゴリズムについて述べる。そして、検出した歩行動作から得られるパラメータで、歩行距離を推定する重回帰モデルの構築を行う。




図 4 杖を使用した歩行動作

2.4.1 歩行データの収集実験

リハビリ施設の協力のもと，図5に示すように歩行データの収集の実験を行った．実験では7mの歩行路をセンサデバイスを取り付けた杖を突きながら歩行した際のセンサデータを収集した．実験協力者は70歳以上の高齢者5名，40代の下肢装具使用者1名，施設のスタッフ2名の計8名であった．下肢装具の使用者は装具ありの場合と装具なしの場合で歩行データを収集した．歩行データの収集は2日に分けて行い，各実験協力者の身体の状態に合わせて，歩行路を移動する回数を1回～4回の任意の回数にした．

また，歩行データの収集の際，適切な歩行姿勢をとるために理学療法士のスタッフに杖の高さを各実験協力者の腰の高さに合わせてもらった．収集した歩行データの数は合計415歩となった．


2.4.2 歩行時の加速度の特徴

実験で収集した高齢者，下肢装具使用者，施設スタッフの歩行データの10秒間の3軸加速度センサ値の合成加速度の変化を図6に示す．施設スタッフのような健常者は杖が必要なリハビリ患者ではないが，杖を利用する人は様々であり，多くの人に対応するため，本研究では健常者のデータも解析に取り入れることにしている．図6中において，矩形で薄く塗りつぶした部分は杖を突きながら歩いたときの歩行動作区間を表している．各実験協力者によって合成加速度のピーク値，歩数などの違いが見受けられるが，歩行時の合成加速度の変化は各実験協力者と




図 5 歩行データ収集実験の様子


もに似た傾向にあることが図 6 から分かる．加速度センサの値に特徴的なパターンを確認できたため，歩行動作の検出には 3 軸加速度センサ a_x , a_y , a_z を用いることにした．本節では杖を突きながら歩行したときの 3 軸加速度センサ a_x , a_y , a_z の特徴的な変化パターンについて説明する．



(a) 高齢者



(b) 下肢装具使用者



(c) 施設スタッフ

図 6 各実験協力者の歩行時の加速度の変化

図 7 に杖を突きながら歩行したときの合成加速度 $|a|$ と合成加速度の差分 $|\Delta a|$ の変化を表すグラフを示す. この合成加速度 $|a|$ は 3 軸加速度 a_x , a_y , a_z から式

(1) を用いて算出し、合成加速度の差分 $|\Delta a|$ は3軸加速度 a_x , a_y , a_z の現在の値 $a_{(x,t)}$ と1つ前の値 $a_{(x,t-1)}$ の差分を式 (2), (3), (4) で求め、その差分から式 (5) を用いて二乗和の平方根で算出している。図7(a), (b)において、色で塗りつぶしている部分が歩行動作の区間であり、青で塗りつぶした部分が杖を振り上げている区間、緑で塗りつぶした部分が杖を振り下ろしている区間、赤で塗りつぶした部分は杖を床に突いたインパクトの区間である。なお、塗りつぶしていない部分は杖を突いて歩行していない区間である。図7(a)から確認できるように、杖を突いていない区間の合成加速度 $|a|$ は変化が少なく、おおよそ1Gの値になり、杖の振り上げ動作区間は合成加速度 $|a|$ が増加し、振り下げ動作区間は合成加速度 $|a|$ が減少、そして、インパクトによって合成加速度 $|a|$ が急激に増加する変化をしている。また、図7(a)の3歩目は他の2歩と比べて、インパクト時の合成加速度 $|a|$ の急激な増加が見られない。このようなインパクトが出ないケースはときどき発生するが、図7(b)に示す合成加速度の差分 $|\Delta a|$ では大きく変化しているため合成加速度 $|a|$ でインパクトが出なくても、合成加速度の差分 $|\Delta a|$ では表れる。

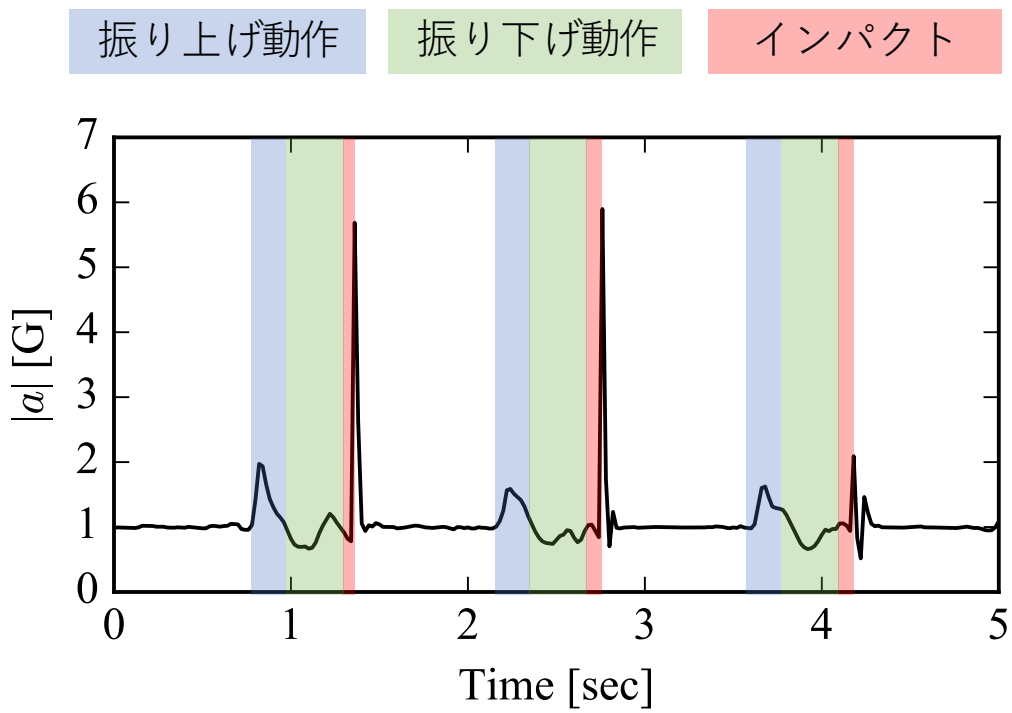
$$|a| = \sqrt{a_x^2 + a_y^2 + a_z^2} \quad (1)$$

$$\Delta a_x = (a_{(x,t)} - a_{(x,t-1)}) \quad (2)$$


$$\Delta a_y = (a_{(y,t)} - a_{(y,t-1)}) \quad (3)$$

$$\Delta a_z = (a_{(z,t)} - a_{(z,t-1)}) \quad (4)$$

$$|\Delta a| = \sqrt{\Delta a_x^2 + \Delta a_y^2 + \Delta a_z^2} \quad (5)$$



(a) 合成加速度 $|a|$ の変化



(b) 合成加速度の差分 $|\Delta a|$ の変化

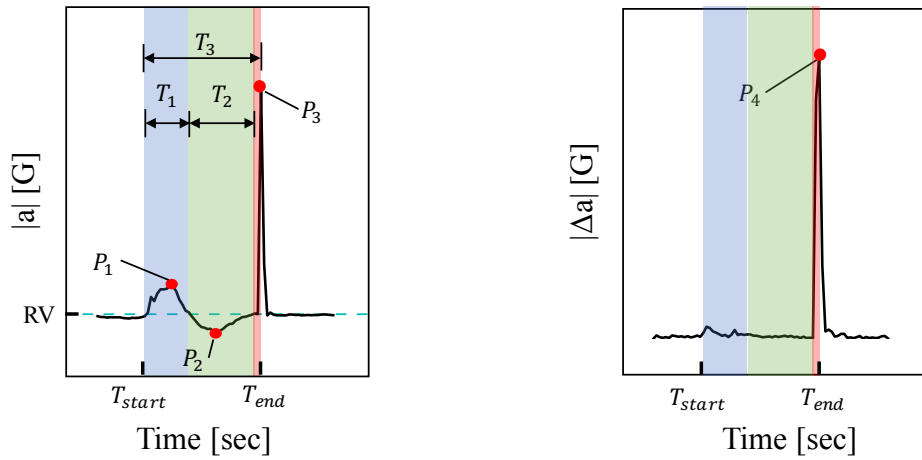
図 7 杖を突きながら歩行したときの加速度データ

2.4.3 歩行動作検出アルゴリズム

歩行動作検出アルゴリズムには大きく3つのパートがある。1つ目は杖の振り上げ動作検出アルゴリズム、2つ目は杖の振り下げ動作検出アルゴリズム、3つ目は杖を床に突いたことによるインパクト検出アルゴリズムである。本節では、各アルゴリズムで用いるパラメータおよび閾値について説明した後、各アルゴリズムの詳細な流れを述べる。

各アルゴリズムで用いるパラメータを図8に示し、各パラメータについて述べる。図8(a)のグラフは1歩分の合成加速度 $|a|$ の変化であり、(b)は合成加速度の差分 $|\Delta a|$ の変化である。パラメータは図8に示しているように T_1 、 T_2 、 T_3 、 P_1 、 P_2 、 P_3 、 P_4 の7つである。 T_1 は杖の振り上げ動作中の時間、 T_2 は杖の振り下げ動作中の時間、 T_3 は歩行動作中の時間、 P_1 は振り上げ動作による合成加速度 $|a|$ のピーク値、 P_2 は振り下げ動作による合成加速度 $|a|$ のピーク値、 P_3 は杖を接地したインパクトによる合成加速度 $|a|$ のピーク値、 P_4 は杖が接地したインパクトによる合成加速度の差分 $|\Delta a|$ のピーク値である。次に、歩行動作検出アルゴリズムで構築するルールベースに用いる閾値について説明する。閾値は先程のパラメータに対応する T_{1,max_th} 、 T_{1,min_th} 、 T_{2,max_th} 、 T_{2,min_th} 、 $T_{3,th}$ 、 $P_{1,th}$ 、 $P_{2,th}$ 、 $P_{3,th}$ 、 $P_{4,th}$ と歩行していない区間から歩行動作区間になったことを検知するための閾値 RV_{th} である。 RV_{th} 以外の閾値はリハビリ施設で収集した歩行データから歩行動作を手動で切り取って得た各パラメータの平均値と標準偏差から決定し、 $T_{1,min_th} = 0.115$ 、 $T_{1,max_th} = 0.534$ 、 $T_{2,min_th} = 0.176$ 、 $T_{2,max_th} = 0.843$ 、 $T_{3,th} = 1.280$ 、 $P_{1,th} = 1.107$ 、 $P_{2,th} = 0.876$ 、 $P_{3,th} = 2.38$ 、 $P_{4,th} = 0.398$ とした。そして、閾値 RV_{th} は歩行していない区間の合成加速度 $|a|$ の平均値と標準偏差から決定し、 $RV_{th} = 1.013$ とした。表1に算出したパラメータの平均値と標準偏差を示す。

歩行動作検出アルゴリズムである振り上げ動作、振り下げ動作、インパクト検出の各アルゴリズムのフローチャートを図9、図10、図11に示し、それぞれの流れについて以下の各項で詳細に述べる。ここで、 T_1 、 T_2 、 T_3 、 P_1 、 P_2 、 P_3 、 P_4 は先ほど述べたパラメータを示し、 T_{1,max_th} 、 T_{1,min_th} 、 T_{2,max_th} 、 T_{2,min_th} 、 $T_{3,th}$ 、 $P_{1,th}$ 、 $P_{2,th}$ 、 $P_{3,th}$ 、 $P_{4,th}$ は各パラメータの閾値を示す。また、 T_{start} は歩行動作



(a) $|a|$ のパラメータ

(b) $|\Delta a|$ のパラメータ

図 8 歩行検出のパラメータ

の開始時刻, T_{end} は歩行動作の終了時刻, state は現在の歩行状態を表し, state 0 の場合は振り上げ動作の検知中, state 1 の状態は振り上げ動作が終わって振り下げ動作の検知中, state 2 のときは杖を床についたときのインパクトを検出している状態であることを示す.

歩行動作の検出には, まずはじめに歩行開始時の杖の振り上げ動作を検出する. 図9に示すように state が 0 の状態から始まり, 合成加速度 $|a|$ が基準値 RV_{th} を超えた場合, 歩行動作の開始時刻として T_{start} を保持し, 時間 T_1 を計測しつつ, T_1 が閾値 T_{1,max_th} 以下の間はピーク値 P_1 を検出し続ける. もし, T_1 が閾値 T_{1,max_th} を超えた場合, 振り上げ動作による合成加速度 $|a|$ の変化ではなかったと判断して T_{start} を破棄して, 再び振り上げ動作の検出を始める. また, 時間 T_1 とピーク値 P_1 がともに閾値 T_{1,min_th} , $P_{1,th}$ 以上であった場合は振り上げ動作が行われたと判断して state を 1 とする.

表 1 各パラメータの平均値と標準偏差

Parameter	Mean	SD
T_1	0.255	0.140
T_2	0.399	0.111
T_3	0.800	0.240
P_1	1.495	0.194
P_2	0.748	0.128
P_3	3.745	1.382
P_4	3.655	1.629
RV	1.008	0.002

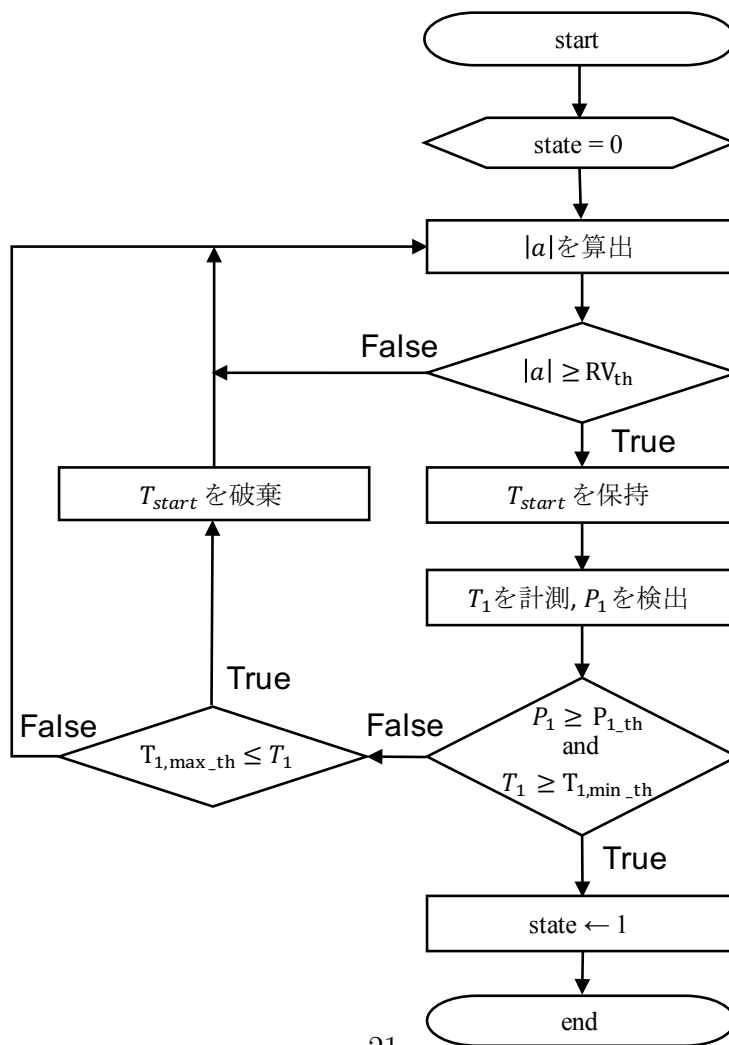


図 9 振り上げ動作検出フローチャート (state 0)

杖の振り上げ動作の検出後、杖の振り下げ動作を検出するため、図10に示すように state が1の状態であるときに合成加速度 $|a|$ が基準値 RV_{th} を下回った場合、時間 T_2 の計測およびピーク値 P_2 を検出する。このとき、時間 T_2 が閾値 T_{2,max_th} を超えた場合は、振り下げ動作による合成加速度 $|a|$ の変化ではなかったと判断して、state を0にして再び振り上げ動作の検出をやり直す。また、ピーク値 P_2 が閾値 $P_{2,th}$ 以下、または時間 T_2 が閾値 T_{2,min_th} 以上かつ T_{2,max_th} 以下となった場合は振り下げ動作が行われたと判断して state を2とする。

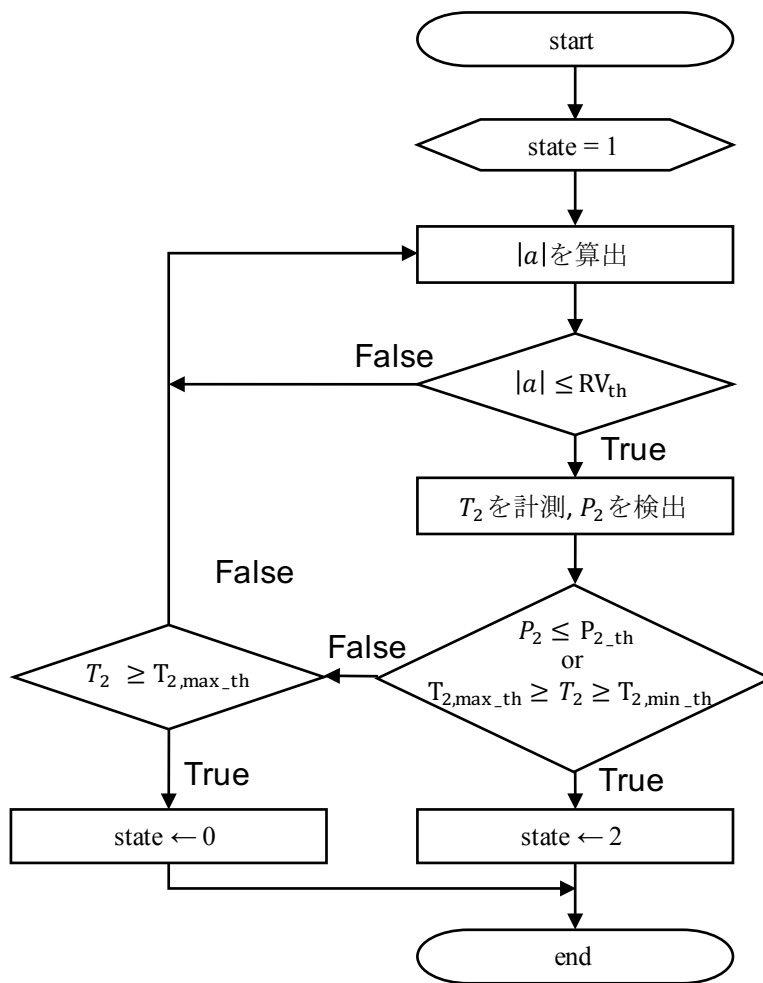


図10 振り下げ動作検出フローチャート (state 1)

杖が地面に突いたときのインパクトを検出するために、図11に示すように state

の状態が2のときに、合成加速度 $|a|$ と合成加速度の差分 $|\Delta a|$ を算出し、時間 T_3 を計測して時間 T_3 が $T_{3,th}$ を超えない限り、ピーク値 P_3, P_4 を検出し続ける。ピーク値 P_3, P_4 が閾値 $P_{3,th}, P_{4,th}$ 以上にならず、時間 T_3 が $T_{3,th}$ を超えた場合は杖を突く動作がなかったと判断し、state を 0 にして、再度振り上げ動作の検出からやり直す。対して、ピーク値 P_3, P_4 が閾値 $P_{3,th}, P_{4,th}$ 以上になった場合、杖が接地したことによるインパクトと判断して、 T_{end} を計測後、 T_{start} から T_{end} までを歩行動作区間として検出する。

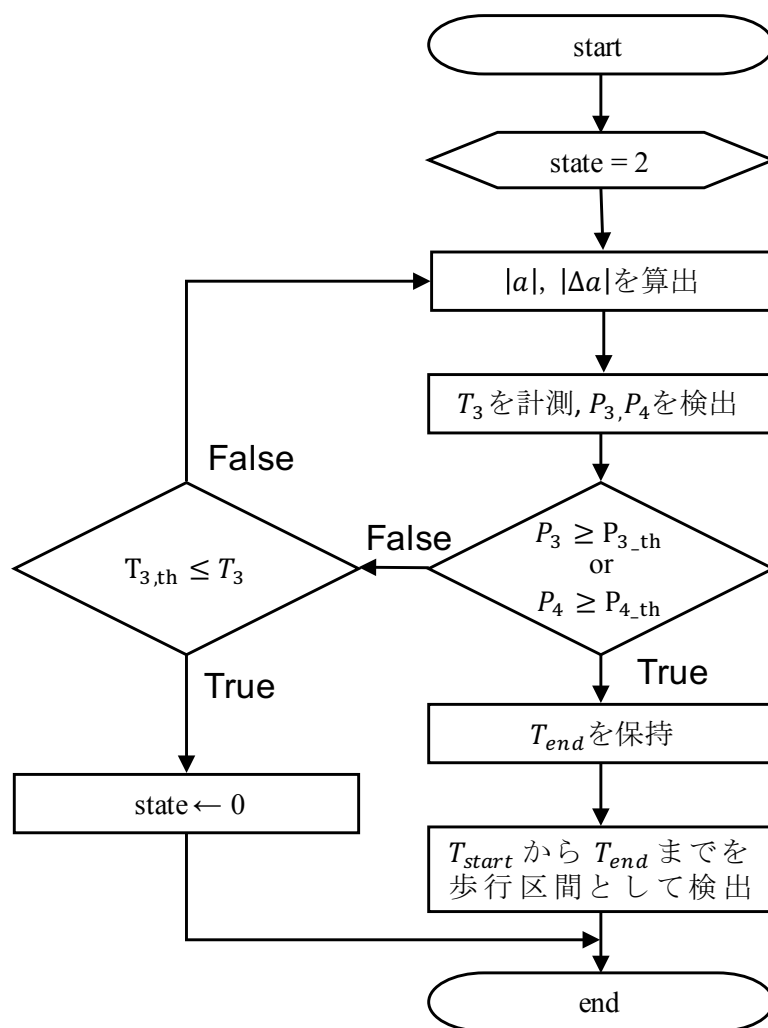


図 11 インパクト検出フローチャート (state 2)

表 2 1 回の歩行動作から抽出したパラメータ

Parameter	Description
p_1	T_3 の時間
p_2	T_1 の時間
p_3	P_1 の値
p_4	T_2 の始めから杖を突くまでの時間
p_5	P_1 の点までの加速度の総和
p_6	T_2 の時間
p_7	P_2 の値
p_8	T_2 のときの合成加速度の総和
p_9	P_3 の値
p_{10}	P_4 の値
p_{11-13}	角度の最大値 (x, y, z)
p_{14-16}	角度の最小値 (x, y, z)
p_{17-19}	角度の最大値と最小値の差 (x, y, z)
p_{20-22}	P_1 のときの角度 (x, y, z)
p_{23-25}	P_2 のときの角度 (x, y, z)
p_{26-28}	P_3 のときの角度 (x, y, z)

2.4.4 歩行距離推定のための相関分析

歩行能力を評価するにあたって、歩行速度は重要な評価項目である。実用的な歩行能力として、信号を渡り切るのに必要な 1m/sec [20] が歩行速度の判断基準となっている。さらに、歩行速度から転倒リスクの予測 [21] を行うことができ、歩行速度が 1m/sec 以下であれば、下肢の障害、死亡、入院のリスクが高いことも分かっている [22]。杖を突いたときの歩行距離と移動時間が分かれば、歩行速度を取得できる。そのため、本研究では杖をセンシングしたデータを用いて歩行距離の推定を行う。歩行距離の推定には、2.4.3 節で提案した歩行動作の検出アルゴリズムにリアルタイムで抽出できるパラメータを用いる。

1 回の歩行動作のデータからパラメータを 28 種類抽出した。1 回の歩行動作と

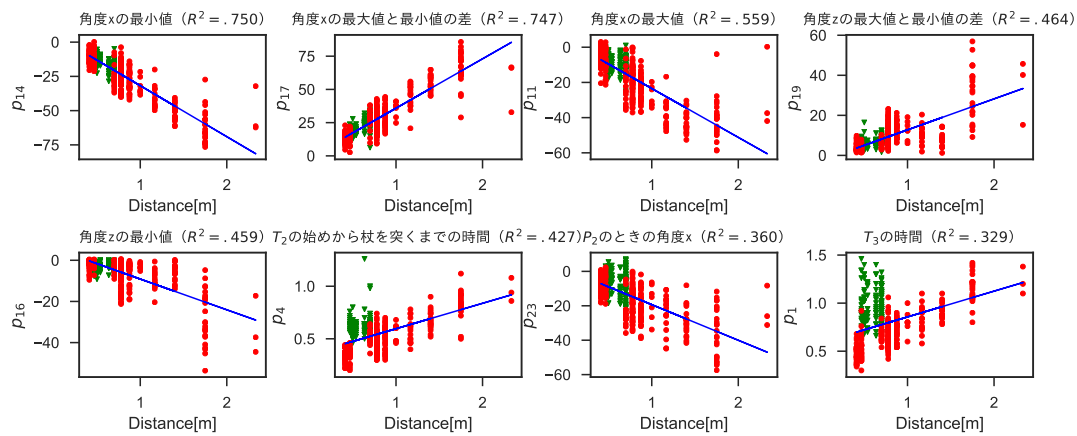


図 12 決定係数が 0.30 以上のパラメータと距離の相関関係（赤：健常者，緑：片麻痺患者）

は、1 回杖を突いて歩行する動作のことを指す。表 2 に今回抽出したパラメータを示す。パラメータの種別を大きく分けると、加速度に関するもの、角度に関するもの、時間に関するものに分かれる。パラメータの角度は、杖の歩行動作の開始地点を 3 軸とも 0 とし、ジャイロの値を積分することで算出している。加速度の単位は G、角度の単位は degree である。これらのパラメータと歩行距離の相関分析を行った。分析に用いたデータは 2.4.1 節で収集したりハビリ施設のデータを使用し、歩行距離は歩行路の距離（7m）を杖を突いた回数で割った距離を使用した。すべてのパラメータに対してピアソンの相関係数 R を求め、決定係数 R^2 が 0.30 以上、かつ、優位水準 0.05 を満たす 8 個のパラメータを図 12 にまとめた。

特徴として、x 軸の角度、z 軸の角度、杖を突く時間に関するパラメータが歩行距離に相関していた¹。特に、x 軸の角度と相関が高い傾向にあり、 p_{14} は決定係数が 0.75 となっている。これは歩行距離が短ければ x 軸へ杖を振る角度が小さくなり、歩行距離が長くなると x 軸へ杖を振る角度も大きくなるという相関関係を表している。また、z 軸の角度や歩行時間に関するパラメータにもある程度の相関が見られた。z 軸の角度については、歩行距離が短いと変化が少なく、歩行距離が長いと杖運びが進行しながら外側から内側へ弧を描くような動きとなり、こ

¹センサデバイスの 3 軸方向は図 3 に定義している。

の動きが z 軸の角度に反映されていると考える。歩行時間に関しては、歩行距離が短ければ時間も短く、歩行距離が長ければ長いという単純な関係性がある。

次に、片麻痺患者のデータと高齢者を含む健常者のデータのパラメータの差を確認するため、健常者のデータを赤、片麻痺患者のデータを緑でプロットした。角度 x 、角度 z に関する p_{14} 、 p_{17} 、 p_{11} 、 p_{19} 、 p_{16} 、 p_{23} の6個のパラメータでは、どちらも相関関係を示している。時間に関する p_4 、 p_1 のパラメータに関しては、片麻痺患者のデータは健常者のデータの上方向にプロットされている。これは、健常者に比べ片麻痺患者はとても慎重に歩行するため、歩行に時間を要するためである。しかし、時間を除くパラメータは片麻痺患者の歩行特性に影響されておらず、相関の特性を示していることから、相関関係を用いて片麻痺患者も歩行距離推定が可能であると考えられる。

歩行距離の推定は、相関分析の結果をもとに重回帰モデルの構築を行う。実際に使用するパラメータについては、後述する2.5.2項で選択を行い、歩行距離推定に使用する。

2.5 提案手法の評価

提案手法の有効性を示すために評価実験を行った。本実験では、実験協力者に室内の直線の歩行路で杖での歩行を行うよう指示した。歩行の仕方に関しては、指定せず自由に歩行してもらった。そして、10回杖を突いた時点で停止させ、その歩行距離を測定した。これを各実験協力者ごとに2回行った。実験協力者は杖を使用していない20代前半の健常者8名である。2.4.2節で述べたように杖の使い方のパターンは高齢者、片麻痺患者、健常者ともに同じであり、かつ、健常者は2点歩行²のような一般的な杖の使い方を知らない可能性が高く、自由な杖の使い方をすることが期待できるため、ロバスト性の検証に有効であると考え、健常者のデータも評価に用いた。本実験で収集した歩行データを用いて、まず、構築した杖の歩行動作検出アルゴリズムの評価を行った。そして、リハビリ施設の実験データと本実験で収集したデータを用いて、歩行距離の推定手法の検証と評価を行った。

²杖を突きながら杖と逆側の足を同時に出し、次に杖側の足を出して進む歩き方

2.5.1 歩行動作の検出精度

2.4.3節で述べたアルゴリズムを用いて歩行動作の区間を検出し、その精度を検証する。歩行動作の区間の定義は、図7で青緑赤で塗りつぶした部分のように杖の振り上げ動作、杖の振り下げ動作、地面に杖を突いたときのインパクトが含まれている区間とする。

まず、2.4.1節の実験のデータに対して、歩行検出アルゴリズムを適用し、評価を行った。高齢者と片麻痺患者を含むリハビリ患者での検出精度は88.9%（377回中339回検出）、杖を利用しているリハビリ患者では98.4%（182歩中179歩検出）、杖を利用していないリハビリ患者では82.1%（195歩中160歩検出）という結果になった。全体での精度は90%を下回っており十分に高いといえないが、杖を利用しているリハビリ患者の精度は十分に高く、スマートフォンの歩行検出アプリでの歩数の精度である約94%[23]を上回っている。そして、杖を利用していないリハビリ患者においては、杖を利用しているリハビリ患者に比べ、82.1%と低い精度となってしまった。精度が低い原因として、杖を利用しないリハビリ患者は一般的な杖の使い方を知らないため、杖を突くタイミングや振り方が大きく異なることで歩行検知アルゴリズムの条件を満たさなかったのが原因であった。しかしながら、この結果から杖を使用しているユーザに対しては高い精度で歩行検出が可能であることが示された。

次に、実験で収集した160歩分の歩行データに歩行動作の検出アルゴリズムを適用し、健常者のデータを用いて評価を行った。表3に歩行動作の検出結果を示す。歩行の検出の欄は歩行検出の場合○、未検出の場合×で示している。

歩行動作の検出数は160歩中153歩、未検出数は7歩であった。検出精度は95.56%であり、杖を使用しない人においても、歩行動作の基準精度となる94%以上の精度で検出できている。歩行動作を検出できなかった原因を調べたところ、「杖の振り上げ動作中に杖が床に接触したこと」や「振り下げ動作途中でインパクトを誤検出したこと」のような想定していない外乱が原因となっていた。しかし、どちらの被験者においても、もう片方の歩行データにおいてはすべて検出できていることから、被験者起因の誤検出ではないことが分かる。このことから、外乱には影響がありつつも、杖を利用していない人に対しても本アルゴリズムに

表 3 歩行動作の検出結果

実験協力者	回数	歩行の検出	検出数 (未検出数)
A	1	oooooooooxx	9 (1)
	2	ooooooooooo	10 (0)
B	1	ooooooooooo	10 (0)
	2	ooooooooooo	10 (0)
C	1	ooooooooooo	10 (0)
	2	oooooxooooo	9 (1)
D	1	ooooooooooo	10 (0)
	2	ooooooooooo	10 (0)
E	1	ooooooooooo	10 (0)
	2	ooooooooooo	10 (0)
F	1	ooooooooooo	10 (0)
	2	oooooxoxoxo	7 (3)
G	1	ooooooooooo	10 (0)
	2	ooooooooooo	10 (0)
H	1	oooxxooooo	8 (2)
	2	ooooooooooo	10 (0)

より十分な精度で歩行の検知が可能であることを示せた。

2.5.2 歩行距離の推定

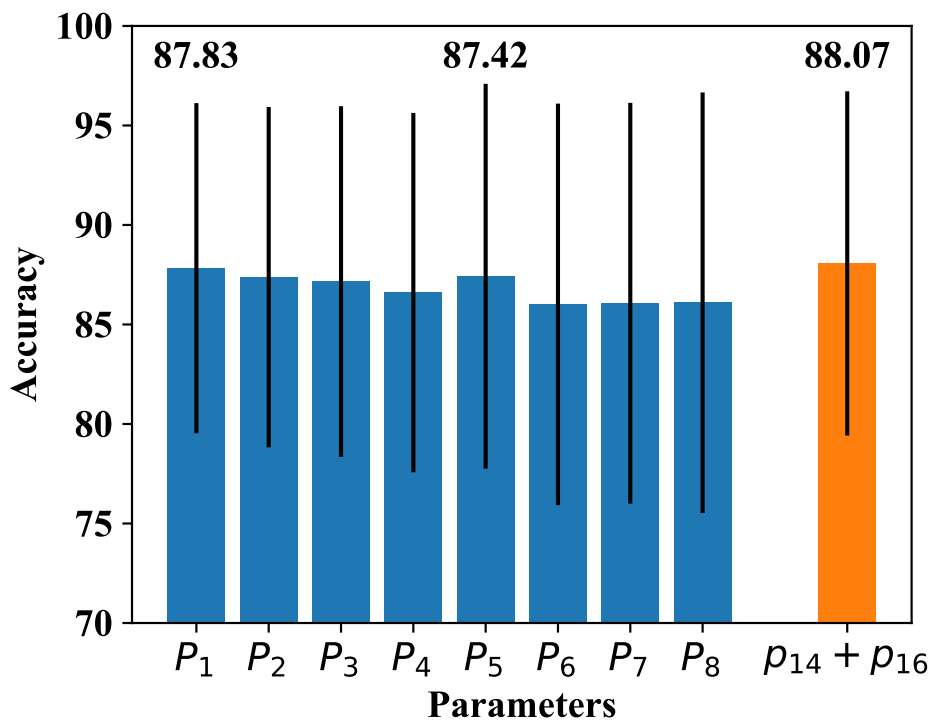
リハビリ施設での実験と追加実験で収集した歩行データを用いて歩行距離の推定について検証・評価を行った。歩行距離の推定モデルには重回帰モデルを使用した。そして、相関分析で得られたパラメータに対し、最小二乗法でモデルのフィッティングを行い、モデルを構築した。評価を行う際には、汎用性を示すため Leave-One-Person-Out Cross-validation によりモデルと推定精度の評価を行った。まず、重回帰モデルで使用するパラメータについて推定精度の結果から検証

し、モデルに使用するパラメータを選択した。そして、選択されたパラメータを用い、歩行距離の推定精度を評価した。

2.4.4 節で分析した 8 個のパラメータを用いて歩行距離推定モデルの構築を行う。モデルの推定精度をより高めるため、パラメータの選択を行った。まず、相関係数が高い順からパラメータを追加していき、推定精度の変化を確認した。図 13 にパラメータと歩行距離の推定精度の関係をまとめた。グラフを見ると、パラメータが 1 つの場合 (P_1) では、精度が 87.83% であるのに対し、パラメータが増えるにつれて精度が少しずつ下がっていることが分かる。しかし、 P_5 において、微小ではあるものの 86.6% から 87.4% と 0.8% 推定精度が向上している。 P_4 と P_5 のパラメータの違いは、 p_{16} (角度 z の最小値) が追加されていることである。そこで、元々の推定精度のベースとなる p_{14} ($=P_1$) と p_{16} を使用してモデルの構築を行ったところ、推定精度が 88.07% にまで向上した。 p_{14} は x 軸の角度に関するパラメータであったのに対し、 p_{16} は z 軸の角度と異なるセンサデータのパラメータであるため、モデルの表現力が増し、精度が向上したと考えられる。

この結果から、本研究では、 p_{14} と p_{16} を歩行推定に使用するパラメータとする。重回帰式は以下ようになる。

$$d = b_0 + b_1 p_{14} + b_2 p_{16} \quad (6)$$



$$P_1 = p_{14}, P_2 = p_{14} + p_{17}, P_3 = p_{14} + p_{17} + p_{11}$$

$$P_4 = p_{14} + p_{17} + p_{11} + p_{19}$$

$$P_5 = p_{14} + p_{17} + p_{11} + p_{19} + p_{16}$$

$$P_6 = p_{14} + p_{17} + p_{11} + p_{19} + p_{16} + p_4$$

$$P_7 = p_{14} + p_{17} + p_{11} + p_{19} + p_{16} + p_4 + p_{23}$$

$$P_8 = p_{14} + p_{17} + p_{11} + p_{19} + p_{16} + p_4 + p_{23} + p_1$$

図 13 パラメータの数と歩行距離推定精度の関係

前項で選択したパラメータを使用した重回帰モデルを用いて、歩行距離の推定を行った。評価では、杖の歩行動作の検出がすべて行えたと仮定し、杖の一突きごとのパラメータをプログラムにより抽出して歩行距離を推定している。表 4 に評価結果を示す。

表 4 歩行距離推定の結果

実験協力者	区分	歩行距離 [m]	推定距離 [m]	精度 [%]
A	若年層	27.51	24.93	90.62
B	若年層	25.47	20.33	79.84
C	若年層	35.54	33.55	94.41
D	若年層	42.98	41.72	97.06
E	若年層	19.60	19.77	99.13
F	若年層	30.03	22.18	73.84
G	若年層	23.00	18.02	78.33
H	若年層	37.05	32.30	87.18
I	中年層	21.00	22.41	93.30
J	中年層	28.00	28.47	98.31
K	高齢層	56.00	72.62	70.32
L	高齢層	56.00	64.86	84.19
M	高齢層	28.00	25.70	91.78
N	高齢層	7.00	6.48	92.55
O	高齢層	49.00	46.85	95.61
P	中年層	56.00	59.10	94.46
P'	中年層	28.00	34.11	78.18

P : 片麻痺患者 (装具あり), P' : 片麻痺患者 (装具なし)

歩行距離の推定精度は、平均が88.06%、標準偏差が8.64%、最大が99.13%、最小が70.32%であった。

リハビリにおいて実用歩行能力の指標としての歩行速度 1.0m/sec が代表的であり、歩行速度が1.0m/sec 以下であれば実用歩行能力が低い [20] とされる。そして、EWGSOP (European Working Group on Sarcopenia in Older People) が定義したサルコペニア判断手法 [24] では、歩行速度 0.8m/sec が閾値と使用されて

いる。0.8m/sec以下の歩行速度であり、かつ、筋量が低い場合は、高齢化にともなう身体能力や筋量の低下の症状であるサルコペニアと診断される。このことから、歩行速度が0.8m/secのユーザを1.0m/sec以上と誤推定しない推定精度が求められる。歩行検知の時間を正確に測れるとすると、速度の誤差となるのは移動距離となるため、本システムでは誤差+25%以内の推定精度が必要となる。全体の評価結果は誤差は約12%であることから必要な推定精度は満たすことができている。

しかしながら、個人ごとの推定結果を見ると、個人差があり、実験協力者D, E, Jの精度は97%以上あるのに対し、実験協力者F, Kの精度は75%を下回っている。実験協力者Fにおいては「歩きの動作が杖と連動しておらず、杖を振り上げた状態で数歩歩く」歩き方をしており、前に杖を振る量が大きい割には実際に移動距離が少なく、推定結果の距離が長くなっていると考えられる。また、杖を振り上げた状態で数歩歩いた場合では、杖を振り上げながら移動しているため、推定結果の距離が短くなっていると考えられる。このような歩き方は一般的な2点歩行とは異なっていた。2名とも杖を利用していない。このことから歩行距離推定において、特殊な杖歩行をするユーザの精度が低くなることがわかる。そのため、本システムを利用する場合は一般的な杖での歩行の仕方を事前に教授する必要がある。

2.6 関連研究

センサを使用して歩行やリハビリ訓練の評価をする研究が行われている。センサの位置としては、脚 [25]、靴 [26, 27]、腰 [5, 28]、腕 [29] や室内に設置したカメラ [30] を使用している研究があり、主に加速度やジャイロのセンサが使用されている。これらの研究では、歩行のパターンや対称性、訓練の運動量の評価を行っている。杖のような福祉器具にセンサをつけ、評価を行う研究はほとんどない。また、リハビリ支援のような室内での使用や専用の環境での測定を想定しており、外界を含む日常の歩行や動きのセンシングには取り組んでいない。

センサを装着した杖という観点では、WuらはSmartCaneというセンサを組み込んだ杖の開発している [31]。SmartCaneの持ち手と地面との接触部に圧力セン

サが組み込まれており、センサデバイス本体には3軸の加速度・ジャイロセンサが搭載されている。このデバイスを使用した転倒検知の手法の提案 [32] も行っている。二宮らは、加速度、心拍センサ、GPSを組み込んだ次世代スマート杖を開発している [33]。しかしながら、このようなセンサ埋め込み型杖はコストが高く、普及が難しいとともに歩行の検出のアルゴリズムや歩行距離推定には取り組んでいない。

スポーツやリハビリ、健康の支援、PDR (Pedestrian Dead Reckoning) の精度向上を目的として、センサを用いた歩行距離の推定が行われている。Shih ら [34] はスマートフォンの3軸加速度センサとジャイロセンサを用いて、加速度の水平成分の二重積分から、腰の位置で 97.35%、胸ポケットでは 96.14%の精度で歩行距離の推定を行っている。Alvarez [13] らは、靴に二軸の加速度センサを取り付け、加速度の垂直成分の二重積分を用いることで、片足のセンサのみでは 90%、両足での場合は 97%の精度で歩行距離の推定を行っている。Wang ら [14] はくるぶしに加速度センサを取り付け、歩行速度と周期を推定し、線形回帰モデルから 95%の精度で歩行距離を推定している。Truong ら [15] はインソールに加速度センサを取り付け、合成加速度の二重積分から、16mの実験では 95.2%、89mの実験では 96.9%の精度で歩行距離を推定している。しかしながら、本研究のような杖に装着したデバイスによる歩行距離推定はこれまでに行われておらず、また、距離推定の条件が厳しいことや実用面が考慮されていないなどの相違点がある。

2.7 考察

本節では、開発した杖装着型センサデバイスの改善点、デバイスを応用した例を考察し述べる。

歩行距離推定の手法を決定する際、実験で得られたデータの相関分析から角加速度の特徴量と距離に相関が見られたため、線形回帰である重回帰モデルでの歩行距離推定を行った。しかし、今後さらにデータを収集し分析した結果、データの多様性が見られれば非線形なデータの回帰予測が可能なモデルである SVR (Support Vector Regression) や回帰木、ニューラルネットワークのような機械学習の手法を適用する必要があると考える。また、杖の突き方に個人特有のパターンがあり、

似たような杖の突き方をする人同士でクラスタに分けることができれば，クラスタごとにモデルを構築することでさらなる精度の向上が見込まれる。

センサデータを分析することで提案手法により高い精度で歩行距離推定が行えたが，他の用途にも活用できることが期待される．例えば，間違った杖の使い方をしている場合は，足腰の負担を軽減できず，つまづいたときの転倒を防げない可能性がある．杖の使い方を評価できれば正しい杖を具体的に提案でき，利用者の安全性を高めることができる．また，転倒の検知ができれば緊急時を判断でき即座に救護を呼べるシステムを実現できるだろう．

杖にセンサデバイスを装着するという概念を一般化すると靴，シルバーカー，自転車のような外出を補助するモノにも適用できる．デバイス化したりセンサを取り付けることで杖と同様にデバイスの存在を気にせず屋外での活動量や移動距離をセンシングできる．それぞれのスマートデバイスの結果が共有されれば詳細な活動量を推定可能で，より効果的なりハビリテーション支援や健康管理に役立てられる．

2.8 まとめ

本章では，リハビリ支援を目的とした日常の歩行動作のセンシングによる歩行評価システムを実現するために杖にセンサデバイスを取り付け，歩行動作の検出アルゴリズムと歩行距離の推定モデルの構築を行った．歩行動作の検出アルゴリズムと歩行距離の推定モデルのパラメータはリハビリ施設で収集した歩行データから決定し，杖を使用しない健常者に対して適用したところ，歩行動作の検出率は95.1%で，歩行距離の推定精度は88.1%であった．本研究によって杖の動き方から使用者の歩行距離の推定が可能であることを明らかにした．サルコペニア患者を健常者と誤推定しない精度として75%以上の精度が求められるが，提案手法では歩行距離を十分な精度で推定できている．

3. 直感的に家電選択可能なスマートリモコン

3.1 はじめに

高度な機能を持つ多種多様な家電機器（家電）が普及したことによって生活の質が向上し快適に生活できるようになった。家電への操作インターフェースとしては物理的なボタンが用意されており、遠隔から操作したい場合は製品に付属した赤外線リモコンを使用するのが一般的である。しかし、一つの家電につき一つのリモコンが付属するため、家電を購入すればするほど赤外線リモコンの数が増えてくる。利用者はそれぞれのリモコンの形状を覚え、位置を適切に管理する必要があり、使い方も覚えなくてはならない。日本のテレビのリモコンは50種類以上ボタンがあるのが一般的で、エアコンも20種類程度ある。ボタンの数が増えたとリモコンのボタンは小さくなり、リモコン本体を見ながらでないと精確な操作が難しくなった。遠隔で操作できるという利点はあるが、リモコンの数の多さや機能の複雑さによって不便さを招いている。

この問題を解決する方法は家電の操作インターフェースを統一することである。利用者が管理するリモコンはそのインターフェースのみとなり、管理が楽になる。購入している家電が多い家庭ほど負荷を大きく下げることができる。一般的な家電はリモコンの赤外線信号によって操作される。リモコンには様々な赤外線信号を記憶され、ボタンが押されると対応する信号を赤外線送信機から送信する。そのため、正規のリモコンでなくても赤外線信号を記録すれば他のデバイスでも代替可能である。複数の家電の操作内容と赤外線信号を記憶したデバイス [35, 36, 37, 38] も登場しており、このようなデバイスを利用することが問題を解決するシンプルなアプローチと言える。家電を操作する際はスマートフォンで専用のアプリを立ち上げ、操作したい家電を選び、操作したい内容を選択することでホームネットワークを通じてデバイスにリクエストを送られ、デバイスから対応した赤外線信号が送信されることで家電が操作される。もし記憶していない赤外線信号があったとしてもデバイス自身に受信機がついていれば、後から学習することも可能である。もう一つのアプローチとしてホームネットワークやインターネットに接続された家電を使うことが挙げられる [39, 40, 41]。このような家電を

情報家電と呼び、ネットワークを介してスマートフォンやウェブアプリケーションによって操作できる。

上記のような製品の登場によって一つのインターフェースで複数の家電を操作できる環境が整いつつある。しかし、インターフェースが統一されたことにより操作したい家電を選ぶ必要が生じる。沢山の家電の中から簡単に短時間で直感的に操作したい家電を選択する手法が重要となってくる。

典型的な家電選択方法 [42, 43, 44, 45] は、特殊なアタッチメントを家電に取り付け、デバイスでそのアタッチメントを認識することである。具体的には赤外線 LED [42]、赤外線トランスミッタ [43]、QR コード [45] が挙げられる。操作デバイスをこのようなアタッチメントに近接させ認識することで家電を選択できる。この手法の利点は確実に認識できることであるが、全ての家電にアタッチメントをつける手間がかかり、かつ、操作デバイスをアタッチメントに近づけるといった動作が必要になり家電の選択に時間がかかる。

アタッチメントを使用せずに家電を選択する手法として、音声認識 [46, 47]、画像認識 [47, 48, 49] が挙げられる。音声認識の場合、「一階のテレビを ON にして」、「リビングルームのエアコンを 26 度に設定して」のように発声することで操作できるが、長い操作のフレーズを覚える必要があり、上手く認識されなかったり間違った場合は操作をし直すのにも時間がかかる。利点としては声の届く範囲であればハンズフリーで操作でき、暗闇の中でも問題なく動作することである。画像認識の場合、利用者はカメラが付いたデバイスで操作したい家電に向けてだけで直感的に選択できる。このようなことができるスマートデバイスの候補としては、スマートフォンやスマートグラスが挙げられる。

スマートフォンにはカメラとインターネット通信が備わっており、普及率から誰しもが利用できる。しかしながら、高齢者にとってはただでさえスマートフォンは高機能でありアプリをインストールしても使いこなせるのか疑問が残る。使いこなせたとしても家電を操作しようとする度にアプリを立ち上げる必要もあり、操作時間がかかるとともにユーザビリティが悪い。デバイスとして機能を切り分けた方が日常において利用しやすく、スマートフォンを使い慣れていなかったり、小さな液晶画面を見るのが苦手な高齢者においては物理ボタンのあるデバイスの

方が操作しやすく実用性が高いと考える。さらにスマートフォンでは赤外線で作るレガシーな家電に対応できない点も問題となる。

スマートグラスは眼鏡型のウェアラブルデバイスで内向のカメラが瞳孔を撮影し、外向きのカメラから利用者がどの位置を見ているのか限定でき、視線によって家電を選択可能である。しかし、スマートグラスを常時装着して生活することはまだ浸透しておらず、家電を操作するためにわざわざ装着するのは効率的ではない。結果として、導入の面でも操作を覚える面においても手に持つタイプのリモコンの形状をしたデバイスが最も実用的という結論に至った。

リモコン型のデバイスは DeepRemote と命名し、画像処理からネットワーク通信を含むシステムを開発した。DeepRemote は近年発展した深層学習による画像認識を活用している。深層学習の技術を使用することで、ロバスト性があり高い認識精度で家電を認識・選択できる。DeepRemote の先端にはカメラが実装されており、操作対象の家電にデバイスを向けて認識すれば家電選択が完了となる。そして利用者は4つの物理的なボタンで簡単に家電を操作できる。さらに赤外線信号の送受信機器と Wi-Fi が実装されており、赤外線家電と情報家電どちらも操作できる。評価実験をした結果、DeepRemote は5種類の家電を3方向から81.1%の精度で家電を認識できることを確認し、認識がスムーズに行えた場合は約5秒で操作できることも確認した。

3.2 システム設計

DeepRemote は深層学習を用いて複数の家電を認識し、操作できるスマートリモコンである。画像の特徴から家電を選択するため提案するシステムでは家電に特殊なアタッチメントを付けずに動作でき、家電とデバイスの距離や方向が異なってもロバストに認識できる。

図14にシステム全体を示す。システムは Deep learning ユニットと Control ユニットから構成される。Deep learning ユニットでは深層学習による画像の学習と生成したモデルによる画像認識が行われる。Control ユニットでは実際にユーザが家電を操作する物理的なユーザインターフェースを提供しており、先端に実装

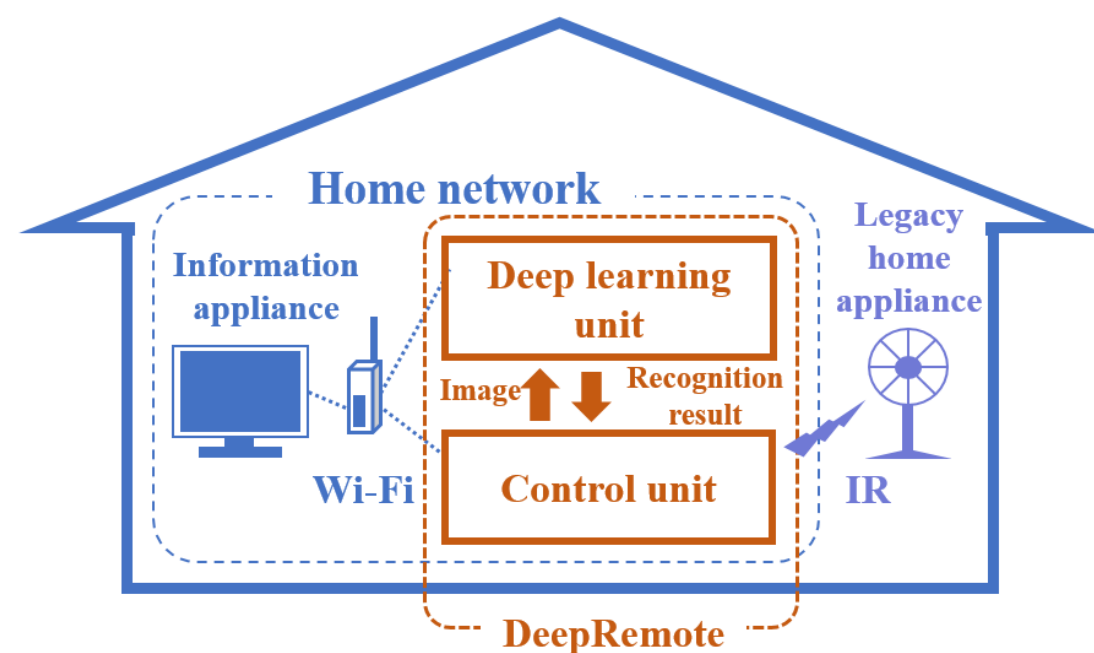


図 14 システムの全体

されたカメラで家電を撮影し Deep learning ユニットで認識する。二つのユニットはホームネットワークで常時接続され、画像や認識結果の通信が行われる。

Deep learning ユニットのサーバ部分を家に置くのは導入コストを高めており最適とは言えない。現実的なシステムとするなら外部の共用サーバでモデルを学習し、デバイス内部で認識するのが理想である。ただ、家電の画像とは言えプライバシーを含むデータではあるため、外部に画像データを送信しないホームサーバを軸としたシステムの方が好ましい。そのため、本システムはホームサーバを設置する前提で設計している。

3.2.1 動作の流れ

はじめに利用者は Control ユニットを持ち、操作したい家電に向け、認識ボタンを押す。ボタンが押されると Control ユニットに実装されたカメラで画像が撮影され、Wi-Fi を通して Deep learning ユニットに画像が送信される。予め生成されたモデルで送信された画像は認識され、認識結果のみがネットワークを通じて




図 15 Control ユニット

Control ユニットへ送られる．認識した結果はユーザに音声でのフィードバックで通知される．家電を認識した後，システムはその家電を操作できる状態に変わり，Control ユニットの四つのボタンで操作できるようになる．四つのボタンのうちの一つに電源ボタンが割り振られ，その他のボタンは家電特有の操作コマンドが割り振られる．システムが家電を認識した後でも認識ボタンは利用可能で，他の家電を操作する場合は再度認識させることで操作可能になる．

3.2.2 Control ユニット

図 15 に Control ユニットを示す．Control ユニットはオンボードコンピュータ，バッテリー，カメラ，赤外線送受信機，スピーカ，4つのボタンで構成され，GPIO もしくは USB で接続されている．リモコンの外装は 3D プリンタで出力している．オンボードコンピュータには Wi-Fi モジュールが実装された Raspberry Pi 3 を使用し，Control ユニットの正面にカメラが設置され， 640×480 の画像を撮影する．

3.2.3 Deep learning ユニット

画像認識の処理の負荷は大きく，処理するコンピュータには高い演算能力が求められる．提案システムにおいて Control ユニットの演算能力は低いこともあり，

画像認識の処理はホームネットワークに接続されたサーバ上で行われる。ネットワークを構築には ROS[50] を用い、Deep learning ユニットと Control ユニットとの通信を担う。

画像認識を行うモデルとして VGG16[51] を選定した。VGG16 は畳み込みニューラルネットワーク (CNN) で構成され ImageNet[52] という巨大な画像データセットで学習されたものを用いる。13 ユニットの畳み込み層と 3 ユニットの全結合層から構成されており、出力層は 1000 ユニットとなっている。画像を入力することで 1000 クラスのどれかに分類される。元々の出力クラスとして扇風機やテレビは含まれているが、ボトルのような不必要なクラスも多く含まれている。そのため、ファインチューニングによってモデルを更新し家電認識に特化させる。ファインチューニング [53] は CNN のモデルを学習させるときに用いる手法の一つで、全結合層のみの設定を変更し、浅い層のパラメータには手を加えず深い層のパラメータのみを再学習させる。学習にかかる時間を削減でき、学習に必要なデータセットも減らせることが利点となる。

図 16 にファインチューニングにより学習させるモデルの構造を示す。モデルの構造において最後の畳み込み層と全結合層が再学習されるため、認識のクラス数を最後の全結合層に再設定している。

3.3 性能の評価

3.3.1 セッティング

大学内のスマートホーム施設のリビングルームにおいて実験環境を準備した。図 17 に実験環境のレイアウトを示す。実験では 5 種類の家電、空気清浄機 (Air purifier)、オーディオプレイヤー (Audio player)、テレビ (TV)、エアコン (Air conditioner)、扇風機 (Fan) を使用する。空気清浄機、テレビ、エアコンは情報家電であり、ホームネットワークを通じて操作できる。オーディオプレイヤーと扇風機は赤外線信号で操作され、信号と操作コマンドは予め Control ユニットに記録した。Deep learning ユニットには core i7 の CPU が載ったノート PC を使用し Control ユニットから送られてきた画像を認識する。一般家庭ではハイエンド

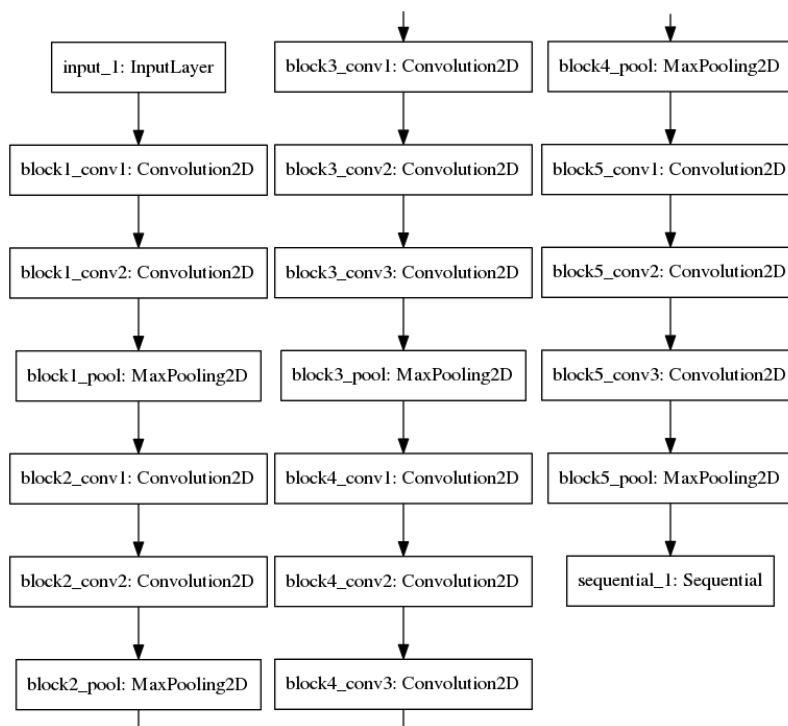


図 16 ファインチューニングでの CNN の構造

な PC を用意できるとは限らないため GPU が載っていない PC を使用した。

学習用の画像として図 17 における P1, P2, P3 の位置から家電をそれぞれ 20 枚撮影し、合計 300 枚の画像を学習させた。ファインチューニングでの学習を想定しており、一からモデルを構築する場合に比べて画像の数は比較的に少ない。なお、家電の電源は OFF の状態で撮影している。

3.3.2 学習の結果

5 クラス 300 枚の画像を用いてモデルをファインチューニングにより学習させた。図 18 に学習中の精度と損失値の推移を示す。最適化アルゴリズムには確率的勾配降下 (SDG) を、損失関数にはカテゴリクロスエントロピーを設定し、エポック数は 200 とした。図に示すように、反復回数 (エポック数) が増えるほど精度が上がり、損失が減少することを確認した。この学習では約 100 目のエポック数で

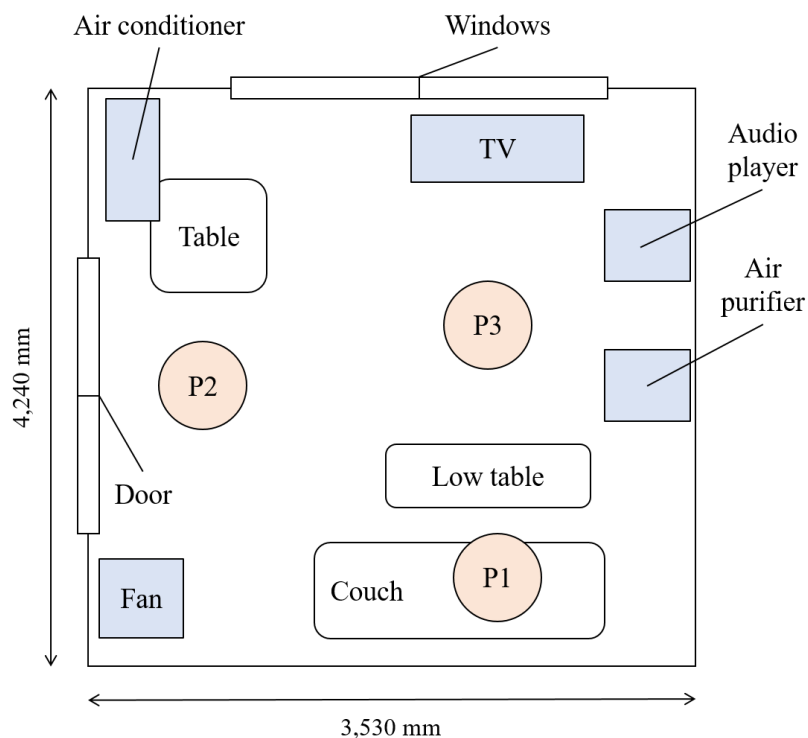


図 17 実験環境

精度が 1.0 付近に到達しており，学習は成功しているといえる．学習にかかった時間は Core i5 の PC で約一時間半であった．

3.3.3 家電の認識精度

モデルの認識性能を評価するため，実験環境で全ての家電の画像を 3 地点からそれぞれ 50 枚撮影した．表 5 に全ての家電と位置の認識精度（F 値）をまとめている．精度はそれぞれの位置で異なり，最も高い平均精度は P2 の 90.45% であった．全ての平均をとると精度は 81.07% となる．結果を精査すると家電の背景が認識結果に影響していることもわかった．P1 において空気清浄機，オーディオプレイヤー，テレビの精度は 8~9 割と高い一方，扇風機とエアコンは 7 割を切り低い精度となっている．原因として，どちらも背景に黒色のドアが映り込むことがしばしばあり，判別する特徴として用いる家電の背景画像の情報が混同されてしまっ

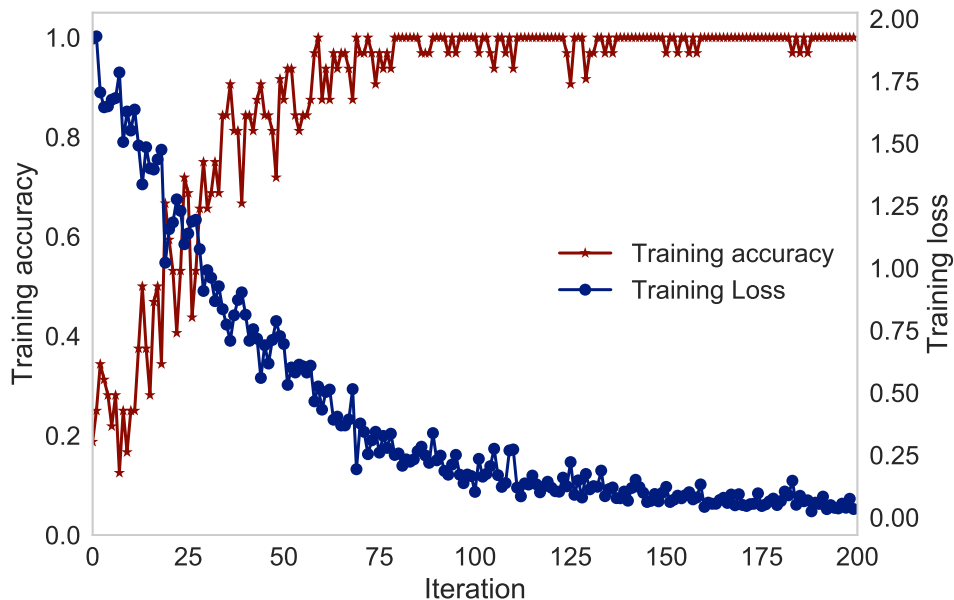


図 18 学習中の精度と損失値

ただと考える。次に他の操作位置に比べて P3 からの認識精度は低くなっていた。P3 は撮影地点から空気清浄機，オーディオプレイヤー，テレビへ距離が近く，画像から家電がはみ出していることもあった。さらにエアコンと扇風機への距離は他の地点よりも遠い。撮影された家電の画像が小さい点と大きい点の二つの条件が重なり，適切な画像特徴量を抽出できずに認識精度が低くなったと考える。

3.3.4 家電の認識時間

Control ユニットの認識ボタンを押してから認識結果が帰ってくるまでの時間を測定した。図 19 に認識時間の分布を示す。平均認識時間は 1.95 秒，最小時間は 1.72 秒，最大時間は 3.07 秒であった。認識時間が遅くなる原因として通信での遅延が大きく，レスポンス時間のばらつきを生んでいた。人間工学におけるシステムの応答時間の限界として 1.0 秒以内であれば人は遅延に気付き，10.0 秒以内が注意を保つ限界と知られている [54]。本システムの応答時間は 1.0 秒を超えて

表 5 3 地点からの家電の認識精度

	Appliance	Precision [%]	Recall [%]	F-measure [%]
P1	Air purifier	100.00	68.00	80.95
	Audio player	83.33	90.00	86.54
	TV	96.15	100.00	98.04
	Air conditioner	57.47	100.00	72.99
	Fan	86.96	40.00	54.80
	Average	84.78	79.60	78.66
P2	Air purifier	81.63	80.00	80.81
	Audio player	100.00	98.00	98.99
	TV	92.59	100.00	96.15
	Air conditioner	79.25	84.00	81.55
	Fan	100.00	90.00	94.74
	Average	90.69	90.40	90.45
P3	Air purifier	76.36	84.00	80.00
	Audio player	100.00	58.00	73.42
	TV	71.43	80.00	75.47
	Air conditioner	53.17	84.00	65.12
	Fan	100.00	62.00	76.54
	Average	80.19	73.60	74.11

いるものの 10.0 秒からは離れているため実用的な応答時間の範囲内であると考え
る。また、Web システムの要件として応答時間を 3 秒とすることが通例としてあ
り、その面からも実用的な範囲内であると言える。GPU がない PC マシンであっ
ても深層学習モデルでの画像認識を 2 秒程度で完了できることを明らかにした。

3.3.5 家電の操作時間

提案システムでの家電の操作時間を評価するためにユーザのテストを行った。
正規の家電のリモコン (Original) を操作時間の比較対象として採用した。空気清

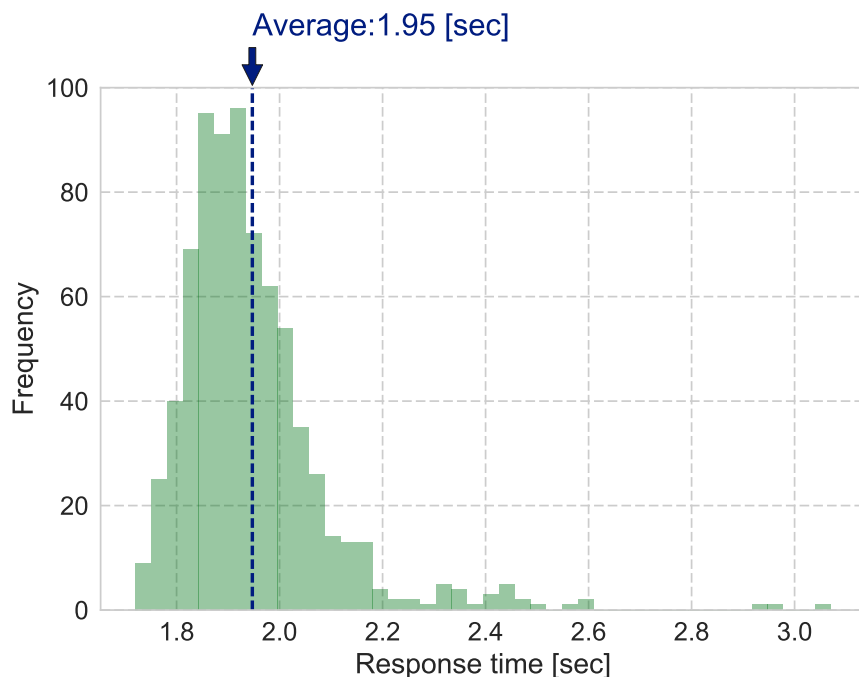


図 19 認識時間の分布 (n=750)

浄機にはリモコンがついていなかったため、他の4種類の家電でのみ実験を行う。このユーザテストでは、家電の電源をONにするまでの時間を計測する。家電ごとに電源をONにする時間を計測するテストと全ての家電の電源をONにするまでの時間を計測するテストを行った。全てのテストはリモコンを持った状態からスタートする。実験協力者の位置は図17におけるP1で固定し、実験協力者の前にある低い机に全てのリモコンを置いた。実験に参加したのは20代男性で、計5名の方に協力いただいた。

図20に実験の結果を示す。縦の棒は平均の操作時間、縦の線は標準偏差を表している。家電の電源をONにするテストでは、エアコンと扇風機の操作時間が他に比べて長く標準偏差が大きくなった。画像認識がうまくいかなかった場合は認識が成功するまでやり直したため時間が多くかかっている。操作の時間に関して、画像認識が成功したときは約5秒で操作を完了でき、失敗した場合は10秒を超える結果となった。正規のリモコンで操作すると概ね2秒で操作を完了できるが、DeepRemoteとの差は3秒程度であり大きく劣っていないと考える。表5の

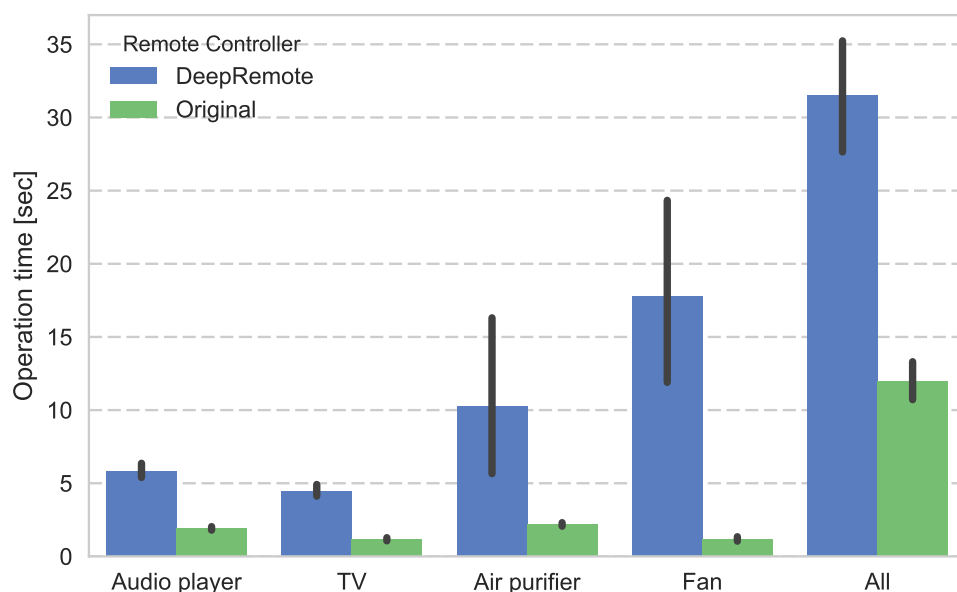


図 20 ユーザテストでの家電操作時間

結果からも 85%以上の認識精度があれば認識の失敗がほぼなく実用的に利用できることがわかった。全ての家電の電源を続けて ON にするテストの結果では、正規のリモコンに比べて DeepRemote は 10 秒以上の差が開いた。

それぞれの家電を ON にする時間の合計は DeepRemote で 33.6 秒、正規のリモコンでは 7.7 秒、次に全ての家電を ON にする時間は DeepRemote で 31.5 秒と 2.1 秒短くなり、正規のリモコンでは 11.7 秒と 3.0 秒長くなっていた。割合で比較すると全ての家電を連続で ON にする場合 DeepRemote は正規のリモコンより 32.3%効率的になっていた。このことから DeepRemote は複数の家電を連続で操作する状況においてはリモコンの持ち替えが発生しないため正規のリモコンよりも優れているといえる。家を出る時・帰った時に全ての家電の電源を消したり、入れたりすることからこのパフォーマンスは現実でも役に立つと考える。

3.4 関連研究

複数のリモコンを一つのインターフェースに統一する方法として、様々な赤外線信号を記憶したリモコンを使う方法と情報家電を使う方法がある。大半の家電が赤外線信号で操作できることから、赤外線信号での操作を統一するためのフレームワークやシステムが開発されている。NakamuraらはSOA(service-oriented architecture)をコンセプトとした赤外線操作可能な家電をネットワークへ接続するためのフレームワーク [35] を提案している。赤外線信号を学習可能でホームネットワークに接続することのできるコントローラデバイスとしてIRKit[36]とeRemote[37]がある。利用者はこれらのコントローラからネットワークを介して遠隔で家電を操作できる。HUIS[38]は電子ペーパーが実装された赤外線リモコンで、専用のソフトウェアと用意された画像を用いて利用者は操作インターフェースを自由にデザインできる。情報家電はECHONET[39], UPnP (Universal Plug and Play) [40], SEP2.0[55]のような標準通信プロトコルで操作できるインターネットに接続可能な家電である。加え、家電間の通信のインフラとして高速PLC (power line communication) 技術も利用可能だ。既に情報家電を利用した家電操作システム [39, 40, 41]が開発されている。Kiyokawarらは3D空間内でのインタラクションで情報家電を操作するフレームワークUbiREMOTE[41]を開発した。家電操作プロトコルとしてUPnPを使用しており、ユーザは現実空間と対応した仮想的な空間内の家電を操作することで現実の家電も同じように操作できる。このようなプロトコルを統一するだけでは沢山の家電がある場合、家電を選択する手続きが加わり操作に時間がかかってしまう。

アタッチメントを元々ある家電に取り付けることで簡単に目標の家電を選択できるようになる。NeßelrathらはWiiリモコンのジェスチャで家電を選択するシステム [42] を実装し評価している。このシステムでは家電に取り付けられた赤外線LEDが特定のパターンの信号で発光し、その信号をWiiリモコン側で受信し解析することで家電を選択できる。TsukadalarはUbi-Finger[43]という指にはめるタイプのデバイスを開発した。Ubi-Fingerはジェスチャで家電を操作でき、デバイスの先端にある赤外線の送信機を家電に取り付けた赤外線受信機に近づけることで家電を選択できる。Ujimalarは家電にプロジェクタと深度カメラを取り付

けることで、ユーザ自身の体がディスプレイとなり、両腕を使ったジェスチャで家電を操作できるシステム U-Remo[44] を提案している。Ullah ら家電に貼り付けられた QR コードを読み取ることで家電を選択できる Remote-touch[45] を開発した。Komeda らは高精度な室内位置推定システム化でのリモコン [56] を提案している。このシステムはコントローラの向いている方向から対象の家電を特定できる。これらの方法では高精度かつ直感的に家電を選択できるが、全ての家電にアタッチメントを取り付けたり、特殊な環境を用意する必要があり汎用的とは言えない。

特殊なアタッチメントを必要としない家電選択手法もいくつか提案されている。Pan らが開発した GeeAir[46] は音声認識で家電を選択し、赤外線信号で操作できる。Xiao らは家電特有の電磁放射線のノイズパターンから家電を特定する手法 [57] を提案している。Kong らはスマートグラスとコンテキスト情報に基づいて家電を選択する手法 [47] を提案している。この手法ではスマートグラスから撮影された画像と、Wi-Fi フィンガープリント、音、照度などのコンテキスト情報から対象の家電を予測できる。なお、画像から特徴量を抽出する手法として畳み込みニューラルネットワークを使用している。これらの方法では特別なアタッチメントを家電に付ける必要はないが、操作が直感的でなかったり、似ている家電を区別するのが難しかったり、ウェアラブルデバイスを必要としたりと何らかの制限が設けられてしまう。そして、赤外線信号とネットワーク通信両方に対応しているシステムはほとんどない。

Hase らの研究 [48] が最も著者の研究に似ており、家電の画像を深層学習での画像認識で特定している。しかしながら、大量の画像で学習している (1 万枚)、実際の操作環境で精度と操作のパフォーマンスを評価していない、赤外線信号での操作のみに対応している、という三点において異なっている。著者の手法では転移学習によって学習する画像を減らすことに成功し、認識精度や操作にかかる時間の評価も行っている。

3.5 考察

本節では、システムの課題と改善点、デバイスを他の用に応用した例を考察し述べる。

ハードウェア部分について、テレビやエアコンなど多機能な家電のリモコンには20~50種類のボタンがあり、本デバイスで全てのボタンを再現するのは困難である。開発した段階でボタンは5つあるが家電操作に対応するには不十分な数であった。家電を操作するために必要な最低限のボタン数を明確にし、液晶パネルなどの内部状態を目視できる機能を追加することで操作性を改良したいと考えている。デバイス自体の大きさもよりコンパクトに収めたい。

現段階では家電画像の撮影、家電と操作コマンドの対応付け、画像の学習が事前の準備として必要となっており、導入の敷居としては高い状態である。今回の研究で着目したのは操作をより快適にするための家電の選択手法であり、より便利なデバイスとするには導入部分を簡易にする必要がある。家電と操作コマンドを対応付けさせる手続きはどんな家電でも操作可能というシステムの性質上除くことができないが、画像を学習させるための事前撮影は減らすことが可能であると考えている。実験では一つの家電に対し60枚の画像を学習させていたが、画像が5枚程度であれば事前準備のコストが大幅に低くなる。最終的には画像の学習なしで認識できることが理想的であり、そのためには家電の認識に特化した専用の認識モデルを構築する必要がある。

ファインチューニングだけでは学習した画像が少ない場合依存性が高く、認識精度が安定しないことが考えられる。プライバシーとの兼ね合いも考える必要があるが、様々な家電画像が集まる仕組みが構築できれば汎用的な認識モデルを構築でき、そのモデルを元にファインチューニングすることで認識精度を向上することが期待できる。また、ニューラルネットワークの勾配を共有するフェデレーションラーニング [58] というフレームワークを導入することでプライバシーの配慮をしつつシステムの利用者同士でモデルを更新可能で認識精度を改善できる。

新製品が出た際は、システムの管理者が該当する家電のコマンドを設定することで、全ユーザも設定できるようになる。個人で家電と操作コマンドを設定することも可能だが煩雑であり可能なら避けたい。認識に関してはフェデレーショ

ンラーニングを採用することで新製品を買った他の利用者が学習したモデルのパラメータを利用でき、新製品であっても少ないデータの学習、もしくは、学習無しで認識できると考えている。

扇風機やロボット掃除機のように使用する場所が変わる家電も存在する。本質的には家電に対して操作する距離と角度が変化するだけであり、操作する位置が変わっても認識可能な現状のシステムでも十分対応できると考えている。唯一変化する部分は家電の背景で、現段階では家電の認識に背景の特徴量が影響している可能性が高い。精度とロバスト性を高めるには認識する画像の前処理が必要となる。画像内のオブジェクトを認識し切り出すことが可能なセマンティックセグメンテーション [59] を用いることで家電と背景を切り分けられる。家電部分の画像のみで学習・認識するようなモデルを構築できれば、背景の影響を無くすことができる。さらにシステムの運営が家電部分の画像を提供するようになれば学習に必要な画像を極力減らしつつ高い精度で認識ができる可能性がある。

家電の画像を分析することで、亀裂や劣化のような外的な物理的な破損を検知できる可能性がある。背景の画像も分析することで配線の状態やホコリが溜まり具合を判断できる可能性がある。もし危険な状態で家電を使用していれば利用者に警告し、新しい製品を勧めたり掃除を促したりする機能を実現できる。また、家電の操作履歴を収集可能であるため利用者の生活パターンを分析でき、生活習慣を是正するような機能や、家電の ON/OFF の状態を把握できているため節電を補助するような機能、温度センサ・ダストセンサを内蔵することで快適な空調を自動的にコントロールする機能のような新しい価値を提供できると考えている。

3.6 まとめ

本章では深層学習に基づく画像認識で直感的な家電操作ができるリモコン Deep-Remote を提案した。DeepRemote は家電を操作する物理的なインターフェース Control ユニットと家電の画像を認識するネットワーク上の Deep learning ユニットから構成されている。性能を評価したところ 300 枚の画像でファインチューニングした VGG16 モデルを用いて 81.1% の精度で家電を認識できる。これは 1.23

回での認識回数で操作可能なことを意味する。また，GPU 無しの PC で約 2 秒の認識時間で動作し，認識がうまくできた場合は電源を ON にする操作に 5 秒かかった。より認識精度が向上し，インターフェースが改善されれば十分に実用的なデバイスになると考えている。しかしながら，認識がうまくいかなかった場合は操作に 10 秒以上かかってしまうことも明らかとなった。

4. 結論

本研究では、高齢者にとって導入と使用が用意なスマート生活支援デバイスのコンセプトとして、(1) 高齢者に配慮したユーザビリティ、(2) 生活空間へ自然に導入できる、(3) 高齢者が抱える問題を解決し、生活を支援するサービスを提供、を提案し屋外と屋内の生活空間に対応するスマートデバイスを二種類開発した。屋外ではリハビリテーション支援のスマート杖、屋内では家電操作支援のスマートリモコンとそれぞれのデバイスは屋外と屋内の二つの生活空間に対応している。

スマート杖は効果的なリハビリテーション支援のため日々の杖の使用の仕方から歩行能力を推定することを目的として開発された。杖のセンサデータから一歩一歩杖を突く動作切り出すアルゴリズムを考案し、その区間の特徴から歩行距離を推定する重回帰モデルを構築した。歩行の区間と歩行距離を推定することで歩行能力の指標となる歩行速度も推定でき、リハビリテーションに役立てることができる。リハビリテーション施設で高齢者、片麻痺患者、健常者を含む16名に協力いただいた実験の結果、95.6%の精度で歩行を検出するとともに88.1%の精度で歩行距離を推定可能であることを明らかにし、十分実用的な性能を持っていることを確認した。

スマートリモコンは、全てのリモコンを一つにまとめることで管理や操作を覚える手間を減らし、快適に生活が送れることを目的として開発した。一般的なリモコンと同じ形状をしたインターフェースにしたことで生活に自然と導入できる。リモコンの先端にはカメラが付いており、家電に向けることで操作したい家電を認識する。認識には畳み込みニューラルネットワークを用いたモデルVGG16を使用し、汎用的な学習モデルを家電の画像でファインチューニングすることで事前準備のコストを減らしている。家電の操作インターフェースはボタンであるため、利用者は操作したい家電にリモコンを向け、ボタンを押すだけで直感的に操作できる。評価実験の結果、5種類の家電を3カ所の位置から81.1%の精度で認識できた。また、GPU無しのPCで約2秒の認識時間で動作し、認識がうまくできた場合は電源をONにする操作に5秒かかった。

高齢者に向けたスマートデバイスの研究は少なく特に設計の段階が重要となっ

てくる。生活への導入が容易であること、高齢者の身体的・精神的な性質を考慮したインターフェース、高齢者が抱えるような課題を支援すること、と汎用的なデバイスに比べて配慮する点が多いが高齢者に利用してもらうにはシステムの設計が重要であると考え。開発したスマートデバイスは可能な限り高齢者に配慮し、十分に実用的な使用に耐えうる性能を確認できた。しかし、実際の生活に導入できてはならず実利用における効果の検証までは至らなかった。高齢化問題を抱える日本のような国や人生100年時代のような生活・経済が変わりつつある2021年において高齢者を対象としたCPSの研究開発は重要度が高くなっている。今後、本研究で得られた知見が社会に役に立てることを期待する。

参考文献

- [1] 内閣府. 第5期科学技術基本計画, 2016.
- [2] 総務省. 平成19年高度齢者・障害者のict利活用の評価及び普及に関する調査研究報告書, 2007.
- [3] 川北慎一郎. リハビリテーション医療の流れ. 恵寿総合病院医学雑誌, Vol. 1, pp. 1-3, 2012.
- [4] 佐藤房郎. 臨床における歩行分析 (第37回日本理学療法士協会全国研修会 (山形) 専門領域研究部会「理学療法基礎系」). 理学療法学, Vol. 30, No. 4, pp. 249-253, 2003.
- [5] 小林哲平, 三宅美博, 和田義明, 松原正明. 加速度センサを用いた運動学的歩行分析システム. 計測自動制御学会論文集, Vol. 42, No. 5, pp. 567-576, 2006.
- [6] 藤井智, 松葉貴司, 田邊侑佳, 山下智子. 脳卒中後片麻痺者の機能評価と屋外歩行能力の獲得状況. 理学療法学 Supplement, Vol. 2014, p. 1099, 2015.
- [7] 妹尾浩一, 橋立博幸. 障害者支援施設に入所した維持期脳卒中片麻痺者の歩行機能に対する長期的なリハビリテーションの介入効果. 理学療法学 Supplement, Vol. 2013, p. 93, 2014.
- [8] Anne Shumway-Cook, Sandy Brauer, and Marjorie Woollacott. Predicting the probability for falls in community-dwelling older adults using the timed up & go test. *Physical therapy*, Vol. 80, No. 9, p. 896, 2000.
- [9] Lillemor Lundin-Olsson, Lars Nyberg, and Yngve Gustafson. “stops walking when talking” as a predictor of falls in elderly people. *The Lancet*, Vol. 349, No. 9052, p. 617, 1997.
- [10] Jan Mehrholz, Katja Wagner, Katja Rutte, Daniel Meißner, and Marcus Pohl. Predictive validity and responsiveness of the functional ambulation

category in hemiparetic patients after stroke. *Archives of Physical Medicine and Rehabilitation*, Vol. 88, No. 10, pp. 1314–1319, 2007.

- [11] Kiyooki Komai, Manato Fujimoto, Yutaka Arakawa, Hirohiko Suwa, Yukitoshi Kashimoto, and Keiichi Yasumoto. Beacon-based multi-person activity monitoring system for day care center. In *IEEE International Conference on Pervasive Computing and Communication Workshops (PerCom Workshops)*, pp. 1–6.
- [12] Yukitoshi Kashimoto, Tatsuya Morita, Manato Fujimoto, Yutaka Arakawa, Hirohiko Suwa, and Keiichi Yasumoto. Sensing activities and locations of senior citizens toward automatic daycare report generation. In *IEEE 31st International Conference on Advanced Information Networking and Applications (AINA)*, pp. 174–181, 2017.
- [13] Juan C Alvarez, Rafael C González, Diego Alvarez, Antonio M López, and Javier Rodríguez-Uría. Multisensor approach to walking distance estimation with foot inertial sensing. In *29th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBS 2007)*., pp. 5719–5722, 2007.
- [14] Jeen-Shing Wang, Che-Wei Lin, Ya-Ting C Yang, and Yu-Jen Ho. Walking pattern classification and walking distance estimation algorithms using gait phase information. *IEEE Trans. Biomedical Engineering*, Vol. 59, No. 10, pp. 2884–2892, 2012.
- [15] Phuc Huu Truong, Jinwook Lee, Ae-Ran Kwon, and Gu-Min Jeong. Stride counting in human walking and walking distance estimation using insole sensors. *Sensors*, Vol. 16, No. 6, p. 823, 2016.
- [16] 水野映子. 要介護者の福祉用具入手・利用の現状と課題. 第一生命経済研究所 Life Design Report, 2003.

- [17] Yugo Nakamura, Yutaka Arakawa, Takuya Kanehira, Masashi Fujiwara, and Keiichi Yasumoto. Senstick: Comprehensive sensing platform with an ultra tiny all-in-one sensor board for iot research. *Journal of Sensors*, Vol. 2017, , 2017.
- [18] Yasushi Sakurai, Christos Faloutsos, and Masashi Yamamuro. Stream monitoring under the time warping distance. In *IEEE 23rd International Conference on Data Engineering (ICDE 2007)*, pp. 1046–1055, 2007.
- [19] Disheng Yang, Jian Tang, Yang Huang, Chao Xu, Jinyang Li, Liang Hu, Guobin Shen, Chieh-Jan Mike Liang, and Hengchang Liu. Tennismaster: An imu-based online serve performance evaluation system. In *Proc. 8th Augmented Human International Conference(AH '17)*, pp. 17:1–17:8, 2017.
- [20] 高橋精一郎, 鳥井田峰子, 田山久美. 歩行評価基準の一考察: 横断歩道の実地調査より. *理学療法学*, Vol. 16, No. 4, pp. 261–266, 1989.
- [21] Lien Quach, Andrew M Galica, Richard N Jones, Elizabeth Procter-Gray, Brad Manor, Marian T Hannan, and Lewis A Lipsitz. The nonlinear relationship between gait speed and falls: the maintenance of balance, independent living, intellect, and zest in the elderly of boston study. *Journal of the American Geriatrics Society*, Vol. 59, No. 6, pp. 1069–1073, 2011.
- [22] Matteo Cesari, Stephen B Kritchevsky, Brenda WHJ Penninx, Barbara J Nicklas, Eleanor M Simonsick, Anne B Newman, Frances A Tylavsky, Jennifer S Brach, Suzanne Satterfield, Douglas C Bauer, et al. Prognostic value of usual gait speed in well-functioning older people—results from the health, aging and body composition study. *Journal of the American Geriatrics Society*, Vol. 53, No. 10, pp. 1675–1680, 2005.
- [23] M A Case, H A Burwick, K G Volpp, and M S Patel. Accuracy of smartphone applications and wearable devices for tracking physical activity data. *JAMA*, Vol. 313, No. 6, pp. 625–626, 2015.

- [24] 厚生労働科学研究補助金高齢者における加齢性筋肉減弱現象（サルコペニア）に関する予防対策確立のための包括的研究研究班. サルコペニア：定義と診断に関する欧州関連学会のコンセンサス—高齢者のサルコペニアに関する欧州ワーキンググループの報告—の監訳. 日本老年医学会雑誌, Vol. 49, No. 6, pp. 788–805, 2012.
- [25] Oonagh Giggins, Daniel Kelly, and Brian Caulfield. Evaluating rehabilitation exercise performance using a single inertial measurement unit. In *7th International Conference on Pervasive Computing Technologies for Healthcare (PervasiveHealth)*, pp. 49–56, 2013.
- [26] Kamiar Aminian, Farzin Dadashi, Benoit Mariani, Constanze Lenoble-Hoskovec, Brigitte Santos-Eggimann, and Christophe J Büla. Gait analysis using shoe-worn inertial sensors: How is foot clearance related to walking speed? In *Proc. 2014 ACM International Joint Conference on Pervasive and Ubiquitous Computing*, pp. 481–485, 2014.
- [27] Octavian Postolache, Mario Ribeiro, Pedro Silva Girão, JM Dias Pereira, and Gabriela Postolache. Unobtrusive sensing for gait rehabilitation assessment. In *Proc. 8th International Conference on Pervasive Computing Technologies for Healthcare*, pp. 386–389, 2014.
- [28] Craig O’Neil, Mark D Dunlop, and Andrew Kerr. Supporting sit-to-stand rehabilitation using smartphone sensors and arduino haptic feedback modules. In *Proc. 17th International Conference on Human-Computer Interaction with Mobile Devices and Services Adjunct*, pp. 811–818, 2015.
- [29] Simon Holland, Rachel L Wright, Alan Wing, Thomas Crevoisier, Oliver Hödl, and Maxime Canelli. A gait rehabilitation pilot study using tactile cueing following hemiparetic stroke. In *Proc. 8th International Conference on Pervasive Computing Technologies for Healthcare*, pp. 402–405, 2014.

- [30] Michael Uelschen and Heinz-Josef Eikerling. A mobile sensor system for gait analysis supporting the assessment of rehabilitation measures. In *Proc. 6th ACM Conference on Bioinformatics, Computational Biology and Health Informatics*, pp. 96–105, 2015.
- [31] Winston Wu, Lawrence Au, Brett Jordan, Thanos Stathopoulos, Maxim Batalin, William Kaiser, Alireza Vahdatpour, Majid Sarrafzadeh, Meika Fang, and Joshua Chodosh. The smartcane system: An assistive device for geriatrics. In *Proc. ICST 3rd International Conference on Body Area Networks(BodyNets '08)*, pp. 2:1–2:4. ICST, 2008.
- [32] Mars Lan, Ani Nahapetian, Alireza Vahdatpour, Lawrence Au, William Kaiser, and Majid Sarrafzadeh. Smartfall: An automatic fall detection system based on subsequence matching for the smartcane. In *Proceedings of the 4th International Conference on Body Area Networks(BodyNets '09)*, pp. 8:1–8:8. ICST, 2009.
- [33] 二宮淳一, 村山一徳, 山岡鉄也. 新しいモビリティ社会に向けた次世代ユビキタス端末：次世代杖（特集スマートモビリティ）－（パーソナルなモビリティ）. *Fujitsu*, Vol. 65, No. 4, pp. 7–12, 2014.
- [34] Wen-Yuah Shih, Liang-Yu Chen, and Kun-Chan Lan. Estimating walking distance with a smart phone. In *2012 5th International Symposium on Parallel Architectures, Algorithms and Programming (PAAP)*, pp. 166–171, 2012.
- [35] Masahide Nakamura, Akihiro Tanaka, Hiroshi Igaki, Haruaki Tamada, and Kenichi Matsumoto. Adapting legacy home appliances to home network systems using web services. In *Web Services, 2006. ICWS'06. International Conference on*, pp. 849–858. IEEE, 2006.
- [36] "irkit - open source wifi connected infrared remote controller" [online]. Available: <http://getirkit.com/en>.

- [37] "eremote" [online]. Available: <http://linkjapan.co.jp/product/eremote>.
- [38] "huis remote controller" [online]. Available: <http://huis.jp>.
- [39] Shohei Saito, Norihiro Ishikawa, and Yosuke Tsuchiya. Development of echonet lite-compliant home appliances control system using pucc protocols from smart devices. In *Computer Software and Applications Conference (COMPSAC), 2015 IEEE 39th Annual*, Vol. 3, pp. 200–204. IEEE, 2015.
- [40] Dong-Sung Kim, Jae-Min Lee, Wook Hyun Kwon, and In Kwan Yuh. Design and implementation of home network systems using upnp middleware for networked appliances. *IEEE Transactions on Consumer Electronics*, Vol. 48, No. 4, pp. 963–972, 2002.
- [41] Kohta Kiyokawa, Shinya Yamamoto, Naoki Shibata, Keiichi Yasumoto, and Minoru Ito. Ubiremote: framework for remotely controlling networked appliances through interaction with 3d virtual space. In *Proceedings of the first annual ACM SIGMM conference on Multimedia systems*, pp. 271–280. ACM, 2010.
- [42] Robert Neßelrath, Chensheng Lu, Christian H Schulz, Jochen Frey, and Jan Alexandersson. A gesture based system for context-sensitive interaction with smart homes. In *Ambient Assisted Living*, pp. 209–219. Springer, 2011.
- [43] KOJI Tsukada and Michiaki Yasumura. Ubi-finger: A simple gesture input device for mobile and ubiquitous environment. *Journal of Asian Information, Science and Life (AISL)*, Vol. 2, No. 2, pp. 111–120, 2004.
- [44] Kaori Ujima, Azusa Kadomura, and Itiro Sii. U-remo: projection-assisted gesture control for home electronics. In *Proceedings of the extended abstracts of the 32nd annual ACM conference on Human factors in computing systems*, pp. 1609–1614. ACM, 2014.

- [45] Ahmed Mohammad Ullah, Md Rashedul Islam, Sayeda Farzana Aktar, and SK Alamgir Hossain. Remote-touch: Augmented reality based marker tracking for smart home control. In *Computer and Information Technology (IC-CIT), 2012 15th International Conference on*, pp. 473–477. IEEE, 2012.
- [46] Gang Pan, Jiahui Wu, Daqing Zhang, Zhaohui Wu, Yingchun Yang, and Shijian Li. Geeair: a universal multimodal remote control device for home appliances. *Personal and Ubiquitous Computing*, Vol. 14, No. 8, pp. 723–735, 2010.
- [47] Quan Kong, Takuya Maekawa, Taiki Miyanishi, and Takayuki Suyama. Selecting home appliances with smart glass based on contextual information. In *Proceedings of the 2016 ACM International Joint Conference on Pervasive and Ubiquitous Computing, UbiComp '16*, pp. 97–108, New York, NY, USA, 2016. ACM.
- [48] Tomohiro Hase and Takaya Sakao. Integrated remote controller distinguishing home appliances by deep learning. In *Consumer Electronics, 2016 IEEE 5th Global Conference on*, pp. 1–3. IEEE, 2016.
- [49] Kaifei Chen, Jonathan Fürst, John Kolb, Hyung-Sin Kim, Xin Jin, David E. Culler, and Randy H. Katz. Snaplink: Fast and accurate vision-based appliance control in large commercial buildings. *Proc. ACM Interact. Mob. Wearable Ubiquitous Technol.*, Vol. 1, No. 4, January 2018.
- [50] Morgan Quigley, Ken Conley, Brian Gerkey, Josh Faust, Tully Foote, Jeremy Leibs, Rob Wheeler, and Andrew Y Ng. Ros: an open-source robot operating system. In *ICRA workshop on open source software*, Vol. 3, p. 5. Kobe, 2009.
- [51] Karen Simonyan and Andrew Zisserman. Very deep convolutional networks for large-scale image recognition. *CoRR*, Vol. abs/1409.1556, , 2014.
- [52] Jia Deng, Wei Dong, Richard Socher, Li-Jia Li, Kai Li, and Li Fei-Fei. Imagenet: A large-scale hierarchical image database. In *Computer Vision*

- and Pattern Recognition, 2009. CVPR 2009. IEEE Conference on*, pp. 248–255. IEEE, 2009.
- [53] Pulkit Agrawal, Ross B. Girshick, and Jitendra Malik. Analyzing the performance of multilayer neural networks for object recognition. *CoRR*, Vol. abs/1407.1610, , 2014.
- [54] George A. Miller. Psychology and information. *American Documentation*, Vol. 19, No. 3, pp. 286–289, 1968.
- [55] ZigBee Alliance. Smart energy profile 2.0. *Draft 0.9, Public Application Profile*, 2010.
- [56] Jun Komeda, Yutaka Arakawa, Morihiko Tamai, and Keiichi Yasumoto. Intuitive appliance control system based on a high-accuracy indoor positioning system. In *Ubiquitous Intelligence and Computing, 2014 IEEE 11th Intl Conf on and IEEE 11th Intl Conf on and Autonomic and Trusted Computing, and IEEE 14th Intl Conf on Scalable Computing and Communications and Its Associated Workshops (UTC-ATC-ScalCom)*, pp. 134–139. IEEE, 2014.
- [57] Robert Xiao, Gierad Laput, Yang Zhang, and Chris Harrison. Deus em machina: On-touch contextual functionality for smart iot appliances. In *Proceedings of the 2017 CHI Conference on Human Factors in Computing Systems*, CHI '17, pp. 4000–4008, New York, NY, USA, 2017. ACM.
- [58] Qiang Yang, Yang Liu, Tianjian Chen, and Yongxin Tong. Federated machine learning: Concept and applications. *CoRR*, Vol. abs/1902.04885, , 2019.
- [59] Simon Jégou, Michal Drozdal, David Vazquez, Adriana Romero, and Yoshua Bengio. The one hundred layers tiramisu: Fully convolutional densenets for semantic segmentation, 2017.