



ウェアラブル活動量推定デバイスの高精度化および低消費電力化に関する研究

中西, 基文

(Degree)

博士 (工学)

(Date of Degree)

2018-09-25

(Date of Publication)

2019-09-01

(Resource Type)

doctoral thesis

(Report Number)

甲第7309号

(URL)

<https://hdl.handle.net/20.500.14094/D1007309>

※ 当コンテンツは神戸大学の学術成果です。無断複製・不正使用等を禁じます。著作権法で認められている範囲内で、適切にご利用ください。



博士論文

ウェアラブル活動量推定デバイスの 高精度化および低消費電力化 に関する研究

平成30年7月

神戸大学大学院システム情報学研究科

中西 基文

内容梗概

近年、生活習慣病の予防とともに健康寿命の延伸に対する取り組みが重要視されるようになってきている。生活習慣病予防と健康寿命の延伸に対して身体活動の増加が特に効果的であることはよく知られている。そのためには、日常生活における身体活動を正確に把握することが重要となる。身体活動の把握として、その頻度(Frequency)、強度(Intensity)、時間(Time)、種類(Type)の FITT と呼ばれる 4 指標の記録が重要であり、生活習慣改善に向けた指導で広く利用されている。それらのデータは日常生活の中で長期的かつ連続して計測すること、なにより正確に計測することが求められている。正確で、長期間の連続した身体活動データは、生活習慣病を予防し、健康寿命の延伸を促進するためのより良い健康指導・生活指導の提供につながるため、それが実現できるウェアラブルデバイスが強く求められている。

身体活動を記録するための数多くのウェアラブルデバイスが開発、報告されており、特に身に着けるタイプのウェアラブルウェアラブルデバイスに注目が集まっている。それらのウェアラブルデバイスの多くは加速度センサを用いて FITT を推定している。しかしながら、現在広く利用されているウェアラブルデバイスには以下の 3 点の課題がある。

第 1 の課題はエネルギー消費量を正確に推定できない行動があることである。例えば階段上りがその行動に当たる。階段上りはエネルギー消費量が非常に大きく歩行時の 2 倍程度あるのに対して、加速度信号は小さく歩行時と同程度となる。そのため加速度のみでは正確にエネルギー消費量を推定することができない。

第 2 の課題として長時間の連続使用に向けたウェアラブルデバイスの小型化である。長期間の連続した記録のためには装着が容易かつ日常生活を妨げないように、できる限り小型・軽量のウェアラブルデバイスであることが望ましい。ウェアラブルデバイスは身に着けることを前提として小型軽量を重視した設計のため、その目的には非常に適していると考えられる。ウェアラブルデバイスの小型・軽量化ためには必要となる部品点数削減と電池サイズを小さくすることが効果的な手段である。しかしながら、単純にその手段を取り入れるだけでは、FITT の正確な記録に必要な機能が失われる、ウェアラブルデバイスの駆動時

間が短くなってしまふという課題が発生する。

第3の課題が長時間連続動作を可能とする低消費電力化である。現状のウェアラブルウェアラブルデバイスの連続駆動時間は約2週間程度であり長期間動作とは言えない。低消費電力化が進むことで電池交換、充電といった煩わしい行為を長期間必要とせずに連続使用が可能となる。加えてウェアラブルデバイスに使用する電池サイズも小型化することができるため、低消費電力化は第2の課題の解決にも重要な役割を果たす。本来の目的である長期間の連続した FITT の正確な記録を可能とするためにも、低消費電力化技術は強く求められている。

そこで本研究ではこれら3点の課題を解決する事を目的とし身体活動量としてのエネルギー消費量と運動・行動種類を高精度に推定するアルゴリズムの開発とそのアルゴリズムを活用したウェアラブルデバイスの小型化技術と長期間の連続動作を実現させることを目標とし低消費電力化に関する研究を行った。本論文は全7章で構成され、第1章は序論である。

第2章では、ウェアラブルデバイスが抱える課題について述べる。ウェアラブルデバイスは健康増進を目的として広く普及した。しかしながら、現状では上述の通り消費エネルギー量の推定精度、ウェアラブルデバイスの小型化、そして低消費電力化という3点の課題がある。本章ではそれらの詳細について述べる。

第3章では、従来正しく推定ができていなかった階段上り時におけるエネルギー消費量をより正しく推定するためのアルゴリズムを提案する。そのアルゴリズム開発のために42名の被験者による臨床試験を実施した。その結果をもとに新たな行動分類アルゴリズムとエネルギー消費量の指標の一つである METs(Metabolic Equivalents)推定モデルを開発した。そのアルゴリズムは *leave-one-out cross validation* を用いて最適モデルを決定、その推定精度を検証した。結果、その最適モデルでは階段上りにおいては従来の推定アルゴリズムに対して絶対誤差(MAPE)で約84%の精度向上が確認できた。

第4章は、ウェアラブルデバイスの小型化に向けた SoC(System-on-Chip)の開発に取り組む。ウェアラブルデバイスの小型化には回路を構成する部品点数の削減と電池サイズの縮小が効果的である。そこで本章では、第3章で提案したアルゴリズムが動作する SoC の開発を行うことで部品点数の削減を行った。加えて、加速度信号に対するフィルタリング処理を実行できるハードウェアを SoC 内部に集積することで、CPU コアのアクティブ率削減を実現した。試作した SoC, 加速度センサ(KX022; Kionix, Inc.), NFC 通信 IC, および CR1220 バッテリーを備えた身体活動モニタリングが可能なアプリケーションボードを開発。そのサイズは 23×21 mm であり、小型のウェアラブルデバイスを開発した。本章ではシミュレーションにより、開発された SoC による消費電力削減効果を検証した。その結果、信号処理をすべてソフトウェアで実行した場合の消費電流が $42.6 \mu\text{A}$ であるのに対し、SoC 内部に実装されたハードウェアを利用した場合には $25.9 \mu\text{A}$ での動作が可能となり、約 39 % の電力削減効果が確認できた。

第5章では第4章にて提案した SoC を用いて、サンプリングレートの段階的適応制御 (SACS)による低消費電力技術の開発を行った。これは加速度センサのサンプリングレートを行動分類に応じて適応的に変化させることで低消費電力を実現する技術である。本章では、提案方法による消費電力の削減効果と、エネルギー消費量推定精度について検証した。実使用を想定したシミュレーション結果では、提案するウェアラブルデバイスは $11.3 \mu\text{A}$ で動作し、第4章の結果である $25.9 \mu\text{A}$ に対して、約 56 %の電力削減効果が確認できた。加えてサンプリングレートの変更頻度が高い場合でもエネルギー消費量推定精度においても、サンプリングレート固定(Fixed)に対する RMSE(Root Mean Square Error)で 0.14 METs 程度と SACS を用いる事による誤差は非常に小さなものであることが確認できた。

第6章では、重力加速度を考慮した行動分類とサンプリングレートの適応的直接制御方式(DACS)を開発した。第5章では SACS を利用することによる低消費電力化効果を評価した。本章では、重力加速度の影響を考慮した行動分類方法の高精度化と、行動分類に応じてサンプリングレートを特定の周波数へと直接的に変化させる DACS を提案した。DACS を用いることで、実測の METs 値に対する絶対誤差は、Fixed に比べて 0.1METs 以下であり、差はないことが臨床試験からも確認された。加速度センサのアクティブレートも第5章で述べた実使用を想定したシミュレーションにより、SACS に対して、加速度センサの

アクティブレートを約 23 %削減することができた。これは、システムが約 $9.8 \mu\text{A}$ での動作が期待できる結果であった。

最後に第 7 章において本論文の結論を述べる。従来のアルゴリズムでは推定が困難であった特定の行動における推定精度向上を実現するアルゴリズムの開発ができた。また、そのアルゴリズムを実装する SoC の開発、小型化と低消費電力化に向けた新規回路を搭載した。試作したチップサイズは $5 \text{ mm} \times 4 \text{ mm}$ と非常に小型であり、身体活動モニタリングが可能なアプリケーションボードも $21 \text{ mm} \times 23 \text{ mm}$ であり、非常に小型なウェアラブルデバイスを実現できた。消費電力も人の活動時における消費エネルギーの推定精度を維持しつつ、 $11.3 \mu\text{A}$ での動作を実現した。これは 40 mAh の Li-ion 電池を使用した場合、約 147 日間の連続動作が可能となり、一般的なウェアラブルデバイスの 7 日間に対して約 20 倍の長寿命化が達成できた。加えて、重力加速度を考慮した行動分類とサンプリングレートの適応的直接制御方式を採用することで、システム全体で、約 $9.8 \mu\text{A}$ での動作が期待できる結果を示せた。

本論文では、現状のウェアラブルデバイスが抱えている課題である推定精度の向上とウェアラブルデバイスの小型化と長期間の連続動作の両立を可能とする低消費電力技術の開発を通じて、ウェアラブル応用可能な活動量推定デバイスの高精度化および低消費電力化技術を確立できた。

目次

第 1 章 序論	1 1
1.1 本研究の背景.....	1 1
1.2 研究目的及び本論文の構成.....	1 3
第 2 章 ウェアラブルデバイスの現状と課題	1 5
2.1 ウェアラブルデバイスの現状.....	1 5
2.2 ウェアラブルデバイスの課題.....	1 7
第 3 章 ウェアラブルデバイス向け METs 推定アルゴリズムの高精度化	2 0
3.1 緒言.....	2 0
3.2 運動強度と行動種類について.....	2 0
3.2.1 運動強度について.....	2 0
3.2.2 生活活動の行動分類.....	2 2
3.3 運動強度推定アルゴリズムの課題と先行研究例.....	2 4
3.4 心拍と加速度を併用した METs 推定アルゴリズムの提案.....	2 7
3.4.1 3 軸加速度信号に対する信号処理.....	2 7
3.4.2 R-R Interval に関する信号処理.....	2 8
3.4.3 身体活動分類のためのアルゴリズム.....	2 8
3.4.4 運動強度としての METs 推定方法.....	2 9
3.5 アルゴリズム開発に向けた臨床試験.....	3 0
3.5.1 臨床試験概要.....	3 0
3.5.2 被験者に関する情報.....	3 1
3.5.3 臨床試験プロトコル.....	3 1
3.5.4 臨床試験における計測結果.....	3 3
3.6 提案決定木を用いた行動分類結果.....	3 4
3.6.1 MIG, HIG を分類するための %HRR 閾値の決定.....	3 4

3.6.2	行動分類結果	3 5
3.6.3	誤差原因に関する分析	3 5
3.7	METs 推定精度評価	3 6
3.7.1	leave-one-out cross-validation を用いた各モデル間の比較	3 6
3.7.2	最適モデルを用いた精度評価	3 7
3.7.3	提案アルゴリズムと他の推定アルゴリズムとの比較結果	4 1
3.7.4	METs 推定精度に関する分析	4 2
3.8	結言	4 3
第4章 ウェアラブルデバイスの低消費電力化と小型化のための System-on-Chip (SoC)の		
	開発	4 4
4.1	諸言	4 4
4.2	ウェアラブルデバイスにおける小型化と低消費電力化の現状と課題	4 4
4.2.1	ウェアラブルデバイスの小型化に向けた取り組み	4 4
4.2.2	小型化と低消費電力化へのアプローチ	4 5
4.3	生体信号計測に適した低消費電力 SoC の開発	4 6
4.3.1	低消費電力化に向けた不揮発性メモリ, バッファメモリの実装	4 7
4.3.2	デジタルフィルタ処理のハードウェア化	4 8
4.3.3	サンプリングレートの変更への対応	4 9
4.4	試作 SoC を用いた低消費電力効果に関する検証	5 0
4.4.1	試作 SoC	5 0
4.4.2	提案 SoC の消費電力のシミュレーションによる評価	5 2
4.5	結言	5 4
第5章 アダプティブサンプリングによる 低消費電力技術の開発		
	5 5	
5.1	緒言	5 5
5.2	低消費電力化技術の重要性とその取り組み	5 5
5.3	アダプティブサンプリングを用いた行動分類と METs 推定アルゴリズム	5 6

5.4	提案アルゴリズムによる METs 推定精度の評価.....	5 7
5.4.1	臨床試験プロトコル	5 7
5.4.2	臨床試験の提案アルゴリズム適用結果	5 9
5.5	提案アルゴリズムを用いた場合の消費電流のシミュレーション評価	6 1
5.6	結言	6 4
第 6 章	重力加速度の影響を考慮したサンプリングレートの制御方式の開発	6 5
6.1	諸言	6 5
6.2	重力加速度を考慮した行動分類アルゴリズム	6 5
6.3	サンプリングレート制御方式の開発.....	6 8
6.4	臨床試験による METs 推定精度への影響の検証.....	7 0
6.4.1	臨床試験プロトコル	7 0
6.4.2	周波数制御方法変更による影響の検証	7 1
6.5	アクティブ率による低消費電力化の検証	7 3
6.6	結言	7 5
第 7 章	結論.....	7 6
謝辞	7 8
著者の研究業績目録	8 0
参考文献	8 2

目次

☒ 1-1 Relationship of each generation and the medical expenses of 2015 in Japan.....	1 1
☒ 1-2 Annual trend of national medical expenses and the ratio of gross domestic product(GDP) and medical expences.....	1 2
☒ 1-3 Relationship between problems and chapters in this thesis	1 4
☒ 2-1 Wearable device market size prediction (national total).....	1 5
☒ 2-2 the usage example of Patch Sensor Zio Patch (iRhythm Technologies, Inc, San ...	1 7
☒ 3-1 the experiment of experiments with Dugrus bag	2 1
☒ 3-2 The comparison of acceleration signals of each axis in walking and stair ascent	2 5
☒ 3-3 Proposed decision tree for this study	2 9
☒ 3-4 (a)臨床試験風景. (b)HealthPatchMD と HJA-750C の取り付け位 (c)HealthPatch MD (d)HJA-750C.	3 0
☒ 3-5 (a)the relationship between METs and ACC _{fil} (b)the relationship between METs and %HRR	3 3
☒ 3-6 The relationship between classification accuracy of MIG and HIG and %HRR.....	3 5
☒ 3-7 METs and error rates of eight activities obtained using the proposed model and the algorithm reported earlier	3 9
☒ 3-8 Relation between error and the result of classification.....	4 0
☒ 4-1 Block diagram of the SoC.....	4 6
☒ 4-2 The example of active state and sleep state	4 7
☒ 4-3 The influence of changing sampling rate.....	5 0
☒ 4-4 Test chip micrograph.	5 0
☒ 4-5 Application board of the proposed sensor.....	5 1
☒ 4-6 Current consumption of proposed CPU.....	5 3
☒ 4-7 the comparison between software processing and proposed SoC.....	5 4
☒ 5-1 Flow chart of PA classification, METs estimation and deciding sampling rate.....	5 6
☒ 5-2 Result of measurement and processed results using proposed algorithm during experimental tests.....	5 9
☒ 5-3 Total current consumption during experimental tests	6 2

☒ 5-4 Simulation result of proposed system in daily usage.....	6 3
☒ 6-1 The decision tree of physical activity classification group.....	6 5
☒ 6-2 (a)机拭きにおける姿勢 (b)歩行時.....	6 6
☒ 6-3 The acceleration signals and filtered signals of each axes in cleaning desk and normal walking.....	6 7
☒ 6-4 the relation between RFU and METs.....	6 8
☒ 6-5 RMS errors compared with 32-Hz fixed F S.....	6 9
☒ 6-6 The Decision tree for adaptive sampling rate.....	7 0
☒ 6-7 Example of <i>ACCfil</i> calculated from measured accelerations: (a) Sequence 1 and (b) Sequence 2.....	7 2
☒ 6-8 The Root Mean Square Error for HJA-750C.....	7 3
☒ 6-9 the average sampling frequency for daily usage.....	7 4

表目次

表 3-1 the numbers of sensors and features for using each algorithm	2 3
表 3-2 physical activity groups in this study.....	2 4
表 3-3 List of features for each proposed model.....	3 0
表 3-4 Physical characteristics of subjects ($N = 42$)	3 1
表 3-5 The eight locomotive activities performed in this paper.....	3 2
表 3-6 %HRR and measured METs with each activity.....	3 3
表 3-7 Statistical results of measurement indices	3 4
表 3-8 Results of group classification using the proposed decision tree.....	3 5
表 3-9 Mean absolute percentage errors (MAPE) of respective estimated results [%].....	3 7
表 3-10 Statistical results of estimation with using all data	3 9
表 3-11 MAPE and MPE for eight activities	4 0
表 3-12 Mean absolute percentage error compared with other algorithms	4 1
表 3-13 Mean percentage error (MPE) with other algorithms	4 2
表 4-1 The Active rate of each function block.....	4 8
表 4-2 Test chip specifications.....	5 1
表 4-3 Current consumption of software processing and hardware.....	5 2
表 5-1 The battery life of major monitoring PAI devices	5 5
表 5-2 Physical activity list and time of experimental test	5 8
表 5-3 Threshold for Physical Activity classification	5 8
表 5-4 Adjustment Coefficient Value for experimental test	5 9
表 5-5 Root Mean Square Error of ACCfil and estimation METs	6 1
表 5-6 Results for all subjects on experimental tests	6 2
表 5-7 Spent time of PA for simulation of daily usage	6 3
表 6-1 Practiced physical activities and classified group	7 0
表 6-2 List of activities in each test sequence.....	7 1
表 6-3 Usage rate of each sampling rate.....	7 4
表 6-4 the average of sampling frequency for daily usage	7 4

第1章 序論

1.1 本研究の背景

近年、生活習慣病の予防だけでなく、健康寿命の延伸が社会的に強く求められている。健康寿命とは健康上の問題で日常生活が制限されることなく生活できる期間のことを指し、この期間が長ければながいほど本人の QOL も高く、医療費削減が期待できる。図 1-1 は厚生労働省より発表された平成 26 年度の医療費の年齢別統計結果[1]をもとに作成したものである。表中の数字は各世代における医療費(単位：兆円)を表しており、医療費の総額が 40 兆 8071 億円のうち、65 歳以上が約 24 兆円(58.6%)を占めている。また、図 1-2 は同結果をもとに 1955 年から 2015 年までの医療費の推移を表しており、年々増加の一途をたどっている。今後さらに高齢化進むことを鑑みると医療費の増大は進み、国内総生産(GDP)に対する割合も大きくなっていく。健康寿命を延伸することと、生活習慣病の予防を進めることは年代にかかわらず、医療費削減に大きく貢献する。この 2 つに取り組むことは社会的に大きな意義を持つ。




図 1-1 Relationship of each generation and the medical expenses of 2015 in Japan

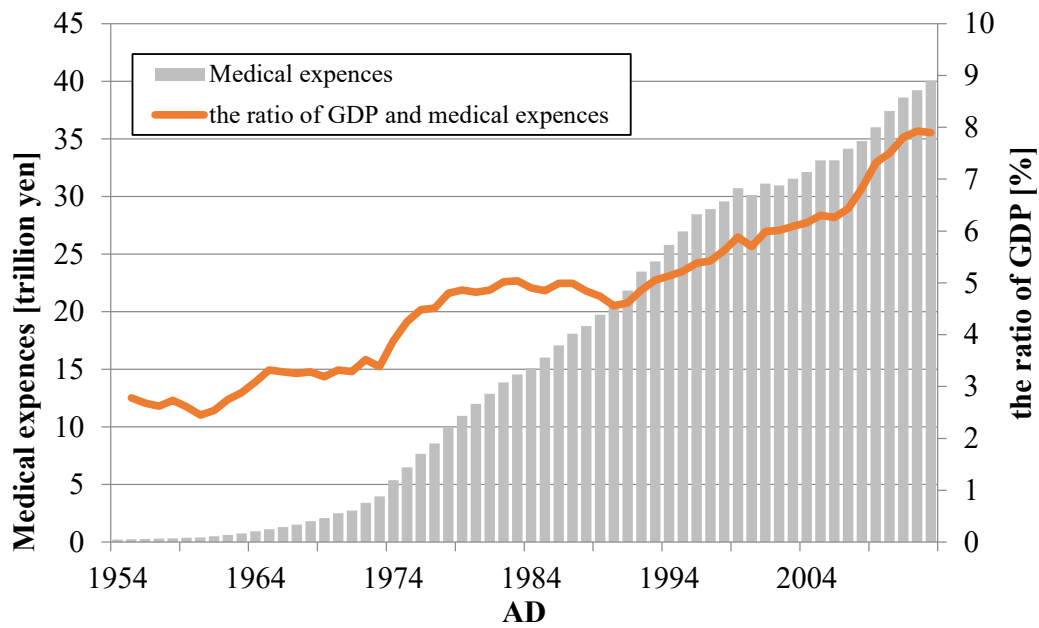


図 1-2 Annual trend of national medical expenses and the ratio of gross domestic product(GDP) and medical expenses

生活習慣病の予防と健康寿命の延伸の手段として生活習慣の改善, 特に身体活動の増加が非常に効果的であることはよく知られている. 身体活動としては FITT といわれる以下の 4 指標が重要とされ, それらの指標の記録を行いその結果に基づいて生活習慣の管理と改善に向けた健康指導が行われることが一般的である.

頻度 (Frequency)	週や月などの一定期間内に行う運動の回数
強度 (Intensity)	心拍数や酸素摂取量を基にした METs (Metabolic Equivalents) がその指標として一般的に利用されている.
時間 (Time)	運動を継続している時間
種類 (Type)	運動の種類, 家事活動や歩行活動, スポーツなど

こうした身体活動は長期間にわたり記録されることが必要である. Coleman らによって長期間記録された歩数の変化は, 健康状態の変化に起因する指標として定量化できることが報告されている[2]. つまり正確な長期間の身体活動データ(FITT)を正確に把握, 記録することは生活習慣の改善と今後の健康リスクの予測を可能にすることにつ

ながら。また、そのデータを活用することで対象者一人一人に合わせた健康指導のパーソナライズ化が可能となり、それによる指導効果の向上も可能になる。その実現のためにも、FITTの4指標を正しくかつ長期的に連続して計測・記録ができるウェアラブルデバイスは社会的に強く求められている。

最近ではその要求を満たすために身に付けやすい小型・軽量でデザイン性も高いウェアラブルデバイスに注目が集まっており、数多く報告されている[3][4][5][6]。これらのウェアラブルデバイスの多くがその身体活動の推定に加速度センサを用いており、その信号の強弱からFITTを推定している。しかしながら、その方式では特定の行動下における運動強度が正しく測定できないという既知の課題があり、その改善も強く求められている。また、ウェアラブルデバイスはその小型軽量という特性上、バッテリーサイズを小さくすることが求められる。バッテリーサイズが小さくなった結果として電池寿命が短くなり、電池交換・充電の頻度が高くなる。その行為の煩雑さによりウェアラブルデバイスの使用を中断してしまう傾向がある。使用中断を避け、連続的で長期間のデータを計測するためにもウェアラブルデバイスの電池寿命の長寿命化が求められ、その効果的な対策としての低消費電力化が強く求められている。

1.2 研究目的及び本論文の構成

本論文では1.1節で述べた背景をもとに、ウェアラブル応用可能なMETs (Metabolic Equivalents)の推定精度の向上とその推定を行うウェアラブルデバイスの小型化と低消費電力化を目的とする。

図1-3は本論文で取り上げるウェアラブルデバイスが抱える3つの課題と各章との対応を示している。本論文の各章について概略を以下にまとめる。本論文では各章毎に現在のアルゴリズムが持つ課題、低消費電力に向けた具体的な方法を明らかにし、目的達成するための改善提案を行う。

- 第 1 章 本研究に関する技術的背景, 技術動向及び本論文の研究内容について記述する.
- 第 2 章 ウェアラブルデバイスにおける現状とその課題について記述する
- 第 3 章 本論文にて新たに開発提案する心拍と加速度併用した METs 推定アルゴリズムについて記述する
- 第 4 章 第 3 章で提案するアルゴリズムが動作する System-on-Chip(SoC)の開発について記述する
- 第 5 章 サンプリングレートの適応的段階制御を用いて実現する低消費電力技術の開発について記述する
- 第 6 章 重力加速度の影響を考慮した分類方法とサンプリングレートの適応的直接制御方法について記述する.
- 第 7 章 本論文の結論をまとめる

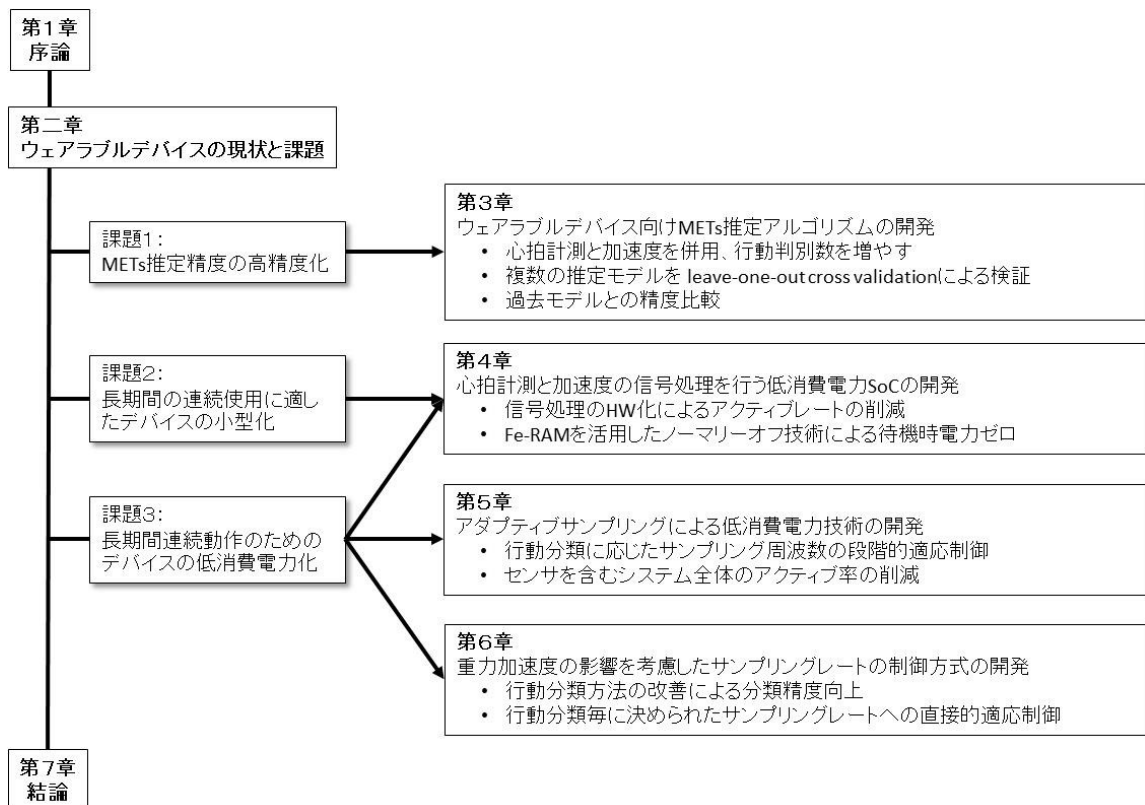


図 1-3 Relationship between problems and chapters in this thesis

第2章 ウェアラブルデバイスの現状と課題

第1章で述べたように、近年ウェアラブルデバイスに対する注目が集まっておりその目的も多岐にわたってきている。本章ではそのウェアラブルデバイスの現状をまとめ、それが抱える課題について述べる。

2.1 ウェアラブルデバイスの現状

ウェアラブルデバイスとは、身体や衣服に装着して利用するデバイスの総称である。本論文では主に血圧値、心拍数、歩行数、エネルギー消費量、睡眠の質といった生活活動、身体活動を計測、記録するウェアラブルデバイスを主に扱う。現在、ウェアラブルデバイスの市場規模は拡大、今後もその傾向は継続される見込みである。総務省の情報通信白書平成28年度版にて報告されているウェアラブルデバイスの市場規模予測(各国合計)を図2-1に示す((出典)矢野経済研究所「ウェアラブルデバイス世界市場に関する調査(2016年)」)[7]。その市場規模は、全世界で2015年で約7,100万台、2020年までには約3億2,300万台まで増加すると予測されている。




図 2-1 Wearable device market size prediction (national total)

このように市場として成長した大きな要因は2つある。一つはウェアラブルデバイスの小型化・軽量化が進み装着時の負担や忌避感が軽減したことにより気軽に使用できることになった点。もう一点は、健康志向への高まりから自身の運動習慣を知りたいという要求が高まり、ウェアラブルデバイスの使用者が増加したことがあげられる。特に小型・軽量化によるデザイン性も高い商品群[3][4][5][6]が数多く発売され若年層における使用率が高くなったことが大きな要因だと考えられる。また、ここ数年ではAppleWatch[8]や、Galaxy Gear S2[9]といったSmartWatchにも身体活動を記録する機能が組み込まれている。日常的に装着しやすいウェアラブルデバイスの開発・発売と、グローバルにおける健康意識の高まりから、ウェアラブルデバイスの市場規模は拡大し続けている。

従来、ウェアラブルデバイスは、日常生活での運動を記録、個人で活用することが主な用途であった。しかし、近年ではそうした個人利用以外の用途も増えてきている。例えば、ウェアラブルデバイスから得られる身体活動の情報を記録、管理することで、使用者の健康リスクを定量化させる用途である。得られた情報をもとに、リスクを定量化し、そのリスクの大小によって保険料へのインセンティブを与えるなどのサービスが試みられている。他の用途としては、地方自治体が住民に歩数計を配布し、地域の健康増進を目的とした試みが開始されている。このように、個人用途だけでなく様々な健康増進サービスのためにウェアラブルデバイスが利用され、広く普及している。

こうした用途で、特に重要なのが身体活動としてのFITTの推定精度である。健康リスクを判断するために、ウェアラブルデバイスにより記録された身体活動の情報が活用されるため、その推定精度は高い精度が求められる。特に臨床研究用途ではその要望が強い。そうした用途に向けて高精度な推定が可能なウェアラブルデバイスとしてHJA-750C(オムロンヘルスケア株式会社,京都)[10]がある。このデバイスに用いられているアルゴリズムはその精度の高さから運動生理学系の論文内で活動量の指標として広く用いられている[11][12][13]。このウェアラブルデバイスで記録された結果をもとに疾患と身体活動の関係を解明、今後の健康リスク低減のための方法が報告されつつある。現段階では特定用途向けとしての利用にとどまっているが、その利用用途は上述のサービスの拡大とともに拡大していくと考えられる。

医療向けのモニタリングデバイスとして、近年ではパッチ型ウェアラブルデバイスの開発も進んでいる[14][15]。パッチ型とは図2-2のように粘着性の電極を用いて肌に

直接ウェアラブルデバイスを張り付けるタイプのウェアラブルデバイスを指す。このウェアラブルデバイスでは、心拍数や心電波形といった心疾患イベントを予防するために非常に重要なデータを身体活動の記録とともに連続して記録することができる。




図 2-2 the usage example of Patch Sensor Zio Patch (iRhythm Technologies, Inc, San Francisco, Calif)[14]

2.2 ウェアラブルデバイスの課題

前節で述べたように、ウェアラブルデバイスは従来の個人用途だけでなく、そのウェアラブルデバイスを用いて記録されたデータを利用した健康指導サービスの提供なども始まっている。そうした使用用途が拡大していくにつれて、現状のウェアラブルデバイスに対する3つの課題が明らかになってきた。以下にその3つの課題を示す。

1. METs 推定精度の高精度化
2. 長期間の連続使用に適したウェアラブルデバイスの小型化
3. 長期間連続動作のためのウェアラブルデバイスの低消費電力化

一つ目の課題は METs 推定精度の高精度化である。前節で述べたようにウェアラブルデバイスの使用用途が多岐に広がっているが、それら全ては身体活動を計測する機能が基本となる。そのため、その身体活動すべてを正しく計測することが非常に重要である。ウェアラブルデバイスにおける身体活動の計測とは主に運動強度と運動種類をセンサを用いて推定し、運動頻度、時間は計測された運動強度と種類が時系列で記録された結果から判断することが一般的である。現在のウェアラブルデバイスは運動強度と種類の推定には一般的に加速度センサを用いている。これは運動強度の強弱

と体の動きとしての加速度信号の強弱に強い相関があることを利用している。運動強度の指標としては、METs が一般的に広く利用されている。加速度を利用している種々のウェアラブルデバイスがそれぞれの運動強度を推定するアルゴリズムを持っており、David R らがそのアルゴリズムの特徴について報告している[15]。またこれらのウェアラブルデバイスの測定精度に関する比較結果も報告されている[16]。しかしながらこうした加速度センサを用いた推定には、ある種類の活動ではその運動強度が正しく推定できないという大きな課題がある。例えば階段上りのような活動がそれに該当する。階段上り時の運動強度は非常に大きく、歩行時の2倍程度となっている。しかしながらその加速度信号は歩行時のそれと同様の大きさであるため、その運動強度は実際よりも低く推定されてしまう。同様の理由で自転車や筋力トレーニングも正しく推定することが難しい。こうした推定が難しい活動があることは大きな課題であり、種々の活動における METs 推定の高精度化が重要である。

2つ目の課題は、長期間の連続使用に適したウェアラブルデバイスの小型化である。ウェアラブルデバイスはその特徴から小型化と軽量化が進んできた。しかしながら、長期間にわたり連続使用するためにはまだ不十分であると考えられる。長期間の連続使用を行うためには、装着感を無くし日常生活の中で自然に使用できるようにしなければならない。そのためにはデザイン・形状の自由度を高くすることが求められ、そのためにはウェアラブルデバイス内部に組み込まれている基板サイズと電池サイズの小型化が必要となる。単純に電池サイズを変更し、ウェアラブルデバイスの小型化を実現しようとする、電池容量の低下によるウェアラブルデバイスの電池寿命の低下を招く。したがって、限られたウェアラブルデバイスのサイズにおいて電池サイズを大きくするためには、電子部品や基板を小さくする方法が求められる。

3つ目の課題は長期間連続動作のための低消費電力化である。ウェアラブルデバイスによって計測される身体活動は長期間でかつ連続した記録であることが望まれている。現状のウェアラブルデバイスの電池寿命は約7日間程度であり、その都度電池交換や充電行為が発生する。その行為が頻繁になるとその煩雑さからウェアラブルデバイスの使用を中断してしまう可能性が高くなり、これは継続的な記録に対して大きな問題となる。加えて、充電時間中はウェアラブルデバイスによる身体活動の測定ができなくなるため、連続した計測ができなくなる。電池交換式の場合には、その電池寿命は長いものの、電池の廃棄量が増加するといった環境面での問題が発生する。また、

2 つ目の課題と関わる部分だが、ウェアラブルデバイスの低消費電力化はウェアラブルデバイスの小型化に大きく寄与する。低消費電力化が実現できると、同じ電池寿命でも電池容量を小さくすることができ、ウェアラブルデバイスもそれに合わせて小型にすることができる。したがって、低消費電力化はウェアラブルデバイスの小型化と電池寿命の長期化を両立させるための非常に重要な技術である。

これら 3 つの課題に関してはそれぞれに対する研究報告は数多くなされている。しかし METs 推定アルゴリズムは高精度化だけを目的とする研究例が多く消費電力を考慮せずに精度のみを追及をしている研究例が多い。したがって、ウェアラブルデバイス用途としてウェアラブルデバイスの小型化、低消費電力化までを想定した推定システムにはなっておらず、社会的な要求に対して不十分であると考ええる。長期的かつ、連続した記録を行うことを目的にするウェアラブルデバイスとしては上述の課題すべてを考慮したアルゴリズムと活動量推定を行うウェアラブルデバイスのシステム設計を包括的に行っていく必要がある。

第3章

ウェアラブルデバイス向け

METs 推定アルゴリズムの高精度化

3.1 緒言

本章では、第1の課題である METs (Metabolic Equivalents)推定の高精度化に向けた新たな推定アルゴリズムを提案する。METs 推定が困難である行動の高精度化に向けては心拍センサと加速度センサを併用することで推定する行動分類数を増加，それぞれに適した METs 推定式を用いることで実現する。提案するアルゴリズムはウェアラブルデバイスで利用することを前提とし，消費電力の増大をできる限り抑えることを考慮したアルゴリズムについて述べる。

3.2 節では運動強度と行動種類について記述する。

3.3 節ではアルゴリズムの課題とそれに対する先行研究例を記述する

3.4 節では本論文で提案する推定アルゴリズムについて詳細を説明する。

3.5 節ではアルゴリズムを開発するために実施した臨床試験について記述する。

最後に 3.6 節，3.7 節で実際にアルゴリズムを用いた場合の運動種類，運動強度の推定結果とそれぞれについての誤差原因の分析について記述する

3.2 運動強度と行動種類について

3.2.1 運動強度について

本アルゴリズムでは運動強度として METs を推定するアルゴリズムを提案する。

1 MET とは，安静状態 1 分における消費エネルギー量として定義されており，それは酸素消費量を用いた以下の式(3.1)で表される。運動時における METs はこの安静状態

の何倍に相当するかを表す値として利用される。

$$1 \text{ METs} = \frac{3.5 \text{ ml}}{(\text{体重}(\text{kg}) \cdot \text{安静時間}(\text{分}))} \quad (3.1)$$

この METs という指標は健康増進に向けた運動強度の指標としても広く利用されており、「健康づくりのための身体活動基準 2013」(厚生労働省, 2013 年)[17] , 米国の団体の American College of Sports Medicine (ACSM)が制定するガイドライン[18]でもこの METs を利用している。

正確な METs 推定を行うには、ダグラスバッグを用いて収集した運動時の酸素消費量(VO_2)と二酸化炭素排出量(VCO_2)から推定を行う方法が一般的である。収集したそれらの情報を用いて以下の式(3.2)に示す Weir の公式[19]により安静時と運動時におけるエネルギー消費量 (EE : Energy Expenditures) [kcal]を推定する。その安静時の EE を 1METs として、運動時の EE が安静時の何倍に相当するかを計算することで、運動時の METs が得られる。

$$\text{消費エネルギー(EE) [kcal]} = 3.9 \times \text{VO}_2 \text{ [L]} + 1.1 \times \text{VCO}_2 \text{ [L]} \quad (3.2)$$

ダグラスバッグを用いた呼気ガスの収集の様子を以下の図に示す。



(a)安静時測定



(b)歩行時測定

図 3-1 the experiment of experiments with Dugrus bag

このように、ダグラスバッグを用いた EE 測定からの METs 推定は正確である反面、非常に煩雑でかつ測定装置も高価なものになる。そのため、日常的な測定には適さない。

そこで、もっと簡便で、日常的な METs 推定を行うために利用されているのが、加

速度センサなど慣性センサを利用したアルゴリズムである。これに関しては過去から非常に多くの研究成果が報告[20]-[24]されており、一般的に広く利用されている。現在のウェアラブルデバイスはこれらの報告と同様に加速度などの慣性センサからの情報から METs を含む EE の推定を行っている。その研究成果の中の一つにオムロンヘルスケアによって開発されたアルゴリズムがある[25][26]。それは運動量、生活習慣などの評価を行う臨床研究現場で広く利用されている。

3.2.2 生活活動の行動分類

近年、運動強度の推定や行動分類の精度を向上させるとともに、行動分類数を増やすために複数のセンサを利用し、サポートベクターマシン (SVM) などの機械学習を利用する方法が広く使用されている。これらの研究では詳細な行動分類ができるようなアルゴリズムが報告されている。例えば、Liu, S らが開発した SVM を利用したアルゴリズムは PC 操作や速度違いの歩行を含む 13 種類の行動をそれぞれ高い精度での分類が可能となっている。これらの研究成果はその分類数、推定精度ともに高い成果を示している。しかしながら、これらのアルゴリズムにおいては使用するセンサ及びアルゴリズムに利用する特徴量の数は増加する傾向にある。以下の表 3-1 にそれぞれのアルゴリズムで使用するセンサの数と特徴量の数を示す。

表 3-1 the numbers of sensors and features for using each algorithm

Author	Ref	Algorithm	sensors	the number of features
Božidara Cvetković	[27]	SVM	two accelerometers Heart rate Skin temperature	30 to 40
Mitja Luštrek	[28]	SVM, C4.5, Random Forest, Naïve Bayes Random Forest	two accelerometers	8
Hristijan Gjoreski	[29]	Multiple Contexts Ensemble	two accelerometers	128
Shaopen Liu	[30]	SVM	two accelerometers ventilation sensor	63
Che-Wei Lin	[31]	Neural-Network k-Based	accelerometer electrocardiogram	21

これらのアルゴリズムでは取り付けるセンサの多さから日常的な装着には適さないものが多い。また、多くの計算を行うため計算量が増大、その処理に必要となる消費電力は高くなる。そのため、本論文で目的としているシステムの低消費電力化には適さない方法であると判断する。

一方で前項で述べた「健康づくりのための身体活動基準2013」[17]では行動の種類を細かく規定せず、運動強度のみを基準とした行動として以下のように定められている。

<18～64歳の身体活動（生活活動・運動）の基準>

強度が3 METs以上の身体活動を23 METs・h/week行う。具体的には、歩行又はそれと同等以上の強度の身体活動を毎日60分行う。

(引用：健康づくりのための身体活動基準2013)

健康増進・生活改善を目的とした場合の行動種類は上記のように運動強度を基準として分類することが重要であり、細かな行動種別までは求められていない。本章におけ

る目的はウェアラブルデバイス向けの METs 推定精度の向上であり，細かな行動分類ではない．そのため，行動分類としては以下の表 3-2 ような 4 分類で十分だと判断した．ガイドラインでは 3 METs 以上の行動とのみの記載だが，目的である推定精度向上のために 歩行活動(Locomotive)をその強度で 2 種類に分類した．

表 3-2 physical activity groups in this study

Classification Group	METs	Example
Sedentary ¹	<1.0	Sitting, Operating PC
Household ²	> 1.0 (not locomotive)	Vacuming, wash dishes
Middle Intensity Group (MIG)	3.0 < 6.0	Walk (70m/min)
Locomotive High Intensity Group (HIG)	< 6.0	Stair ascent, Jogging

1 : Sedentary とはほぼ動きのない安静状態のこと

2 : Household とは家事活動のことで歩行ではない 1METs 以上の行動を指す

3.3 運動強度推定アルゴリズムの課題と先行研究例

運動強度推定アルゴリズムにおける大きな課題とは，第 2.2 章で述べた通り特定の活動時におけるエネルギー消費量 (EE) の推定精度が低いことである．これは単一の加速度センサのみで推定を行うことが原因である．加速度信号としては小さな動きであるにも関わらず，高い EE を有する活動においてその推定精度が低下，実際の消費量よりも低く推定される傾向にある．こうした活動時の METs 推定精度の向上は非常に重要で，解決すべき課題であると考え

本章ではそれらの行動における改善のアプローチとしてまず階段上り (stair ascent) に着目した．以前の研究において，階段上りにおける呼気ガスから得られる実測の METs に対する誤差は-60.6%であった[26]．他にも，Crouter らも．Freedson MET 方程式を使用する 1 つのデバイス (Actigraph Model 7164; Actigraph LLC, Pensacola, FL) における誤差について報告している．その結果によると，階段上り，階段降り活動における

推定誤差は -38.3% であると報告[32]しており、その誤差はまだ大きいと言わざるを得ない。

先行研究[26]からも、この問題に取り組むために単一の加速度センサのみで解決させることが難しいことがわかっている。以下の図に階段上り時と歩行時における加速度波形を示す。各軸ともに、階段上り時と歩行時の加速度の振幅やその形状が近似しており、加速度信号だけではその分類が難しい。この加速度信号から多くの特徴量を導出し、機械学習などの手法を利用すればその判別が可能となるが、それは3.2.2でも述べた通り、本論文の目的には適さないと考える。

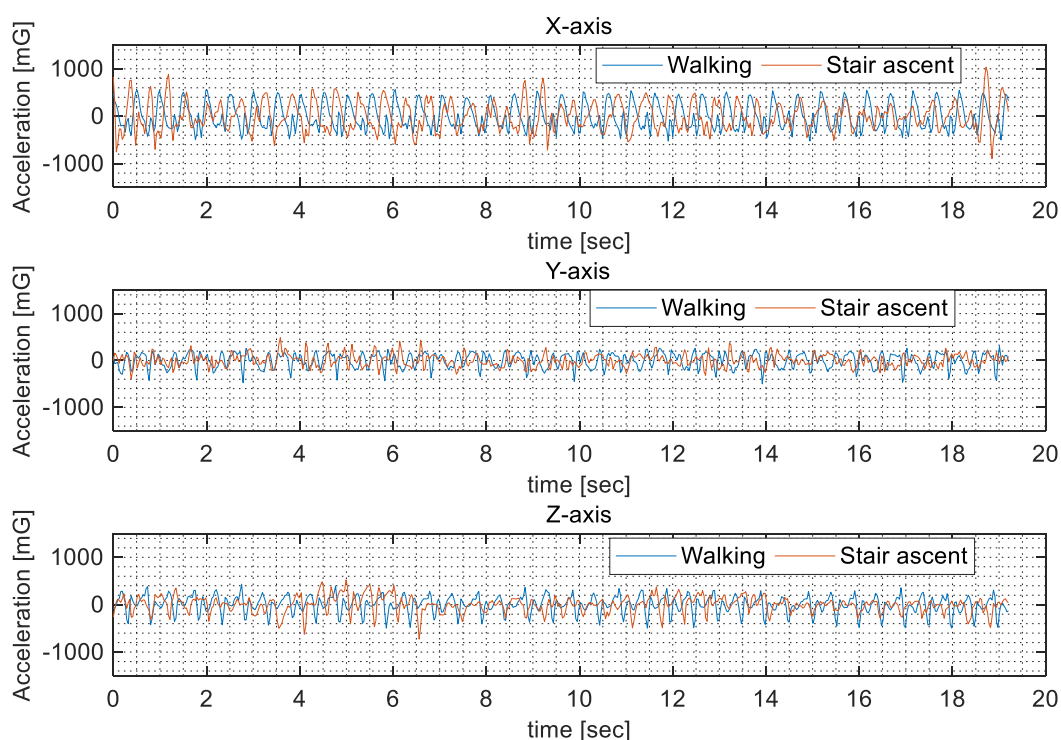


図 3-2 The comparison of acceleration signals of each axis in walking and stair ascent

そこで、階段上りにおける推定精度向上を目的として加速度だけではなく、複数のセンサを組み合わせる方法が提案されてきた[32]-[39]。それらの組み合わせでは以下の2つの方法が頻繁に使用されている。

まず第1の方法は、気圧センサを使用する方法である。そのアルゴリズムは Ohtaki や M. Voleno などによって報告されている[35][36][37]。気圧センサを使用し、高度の変化を測定する。その情報と加速度センサから得られる人の動作の強度を併用した消

費エネルギー量の推定方法を提案している．これによって，階段上昇などの高度の変化がある活動時におけるの精度向上が達成できる．しかし，一般的に気圧センサは消費電力が高くなる傾向があり，高度の変化がない，その他の推定が難しい行動，例えば自転車などの場合には，改善効果が期待できないため本研究の目的には適さない．

第2の方法は，Crouter [38] と Li [39]によって報告されているように，心拍数と加速度を併用した方法である．運動強度と心拍数との間には強い相関があることが分かっている．加速度信号だけでなく，心拍を同時に利用するようなアルゴリズムによって精度の向上が達成されている．この方法であれば気圧センサを用いた場合とは異なり，階段上り以外の行動時における推定精度の向上も十分に期待できる．しかし，現在報告されている結果は階段上昇時における運動強度を正確に推定するにはまだ不十分な結果であることも分かっている．例えば Crouter らが報告している誤差は-20.5 %であり，実使用上まだ不十分な精度であり，まだ改善が必要である[32]．

本章で提案する高精度を実現するためのアルゴリズムは，本論文の目的に合致する加速度と心拍を併用する方法を採用する．その理由は以下の2点である

- ・ 心拍測定が超低消費電力で実現できる
- ・ 心拍数を運動強度と同時に計測できることによるメリットが非常に多い

和泉らは，非常に低消費電力(6.14 μA)で R-R interval (RRI) 測定を可能にするシステムオンチップ (SoC) を開発した[40]．また，他のグループでも，心拍数を測定するための低消費電力 SoC の開発例が報告されている[41]-[44]．これらの研究により，心拍は非常に低消費で測定でき，高精度化を実現するための消費電力の増加を最小限に抑えられ，システム全体を低消費電力化したいという本論文の目的と合致する．

加えて，心拍数は，健康状態に関する重要な生体情報を提供することができる．その情報は運動強度の推定だけでなく，幅広い目的における貴重な情報となる．したがって，ウェアラブルデバイスへの心拍センサの追加は，本研究の目的である高精度化だけでなく，生体計測における非常に重要な情報の計測も可能となる．それらの理由から本章では心拍数と加速度を併用したアルゴリズムの開発を行った．

3.4

心拍と加速度を併用した METs 推定アルゴリズムの提案

本章では精度向上のための METs 推定アルゴリズムについて述べる。本論文では、シンプルな構成ではあるものの、METs 推定精度向上が十分期待できる決定木による行動分類と多重回帰モデルを用いた推定方法を提案する。

本論文で提案するアルゴリズムは、先行研究として報告されている我々のアルゴリズムから以下の2つの大きな改善点を加えた。

- ・ 歩行活動 (Locomotive) を前節で述べたように Middle Intensity Group (MIG) と High Intensity Group (Group) と細分化する
- ・ 行動分類と運動強度を推定するための多重回帰モデルに使用される特徴量を増加させる

行動分類と METs 推定には以下に示す3つの指標を用いる。

フィルタリング処理後の3軸合成加速度	: ACC_{fil}
フィルタリング前後での合成加速度の比率	: RUF
Percentage Heart Rate Resered	: %HRR

以下の説では、それら3つの指標を得るための、信号処理方法、行動分類アルゴリズム、そして、METs 推定のための多重回帰モデルについて説明する。

3.4.1 3軸加速度信号に対する信号処理

加速度センサによって得られた三軸それぞれの加速度は、従来研究[25][26]と同じ方法で信号処理が行われる。まず初めに、3軸加速度計からの信号は0.7 Hzのカットオフ周波数を有するハイパスフィルタによる処理を各軸に対して行う。これは信号内に重畳している重力加速度成分を除去するためである。

フィルタリング処理行っていない加速度信号と、ハイパスフィルタを用いてフィルタリングされた加速度信号それぞれで、3軸の合成加速度を計算した。計算されたそれぞれの値の比率を以下の式(3.3)のように計算し Ratio Unfiltered synthetic acceleration and Filtered synthetic acceleration (RFU)を求めた。この RFU は次節で示す決定木にあるように、家事活動と歩行活動の分類に利用した。ACC_{fil}はフィルタリングされた信号の合成加速度の平均値として定義される。

$$RUF = \frac{\text{フィルタリングしていない合成加速度}}{\text{フィルタリング処理後の合成加速度}} \quad (3.3)$$

3.4.2 R-R Interval に関する信号処理

今回、心拍数に基づく指標として、percentage Heart Rate Reserve (%HRR) を用いることとした。これは、安静時心拍数を 0%、最大心拍数を 100%と設定し、運動中の心拍数がどの程度になるのかを数値化する方法である。この%HRR は以下の式(3.3)で定義される[45]。

$$\%HRR = \frac{HR_{act} - HR_{rest}}{HR_{max} - HR_{rest}} \times 100 \quad (3.4)$$

活動中の心拍数 (HR_{act}) は、活動中の心拍数の平均値を表す。休息時の心拍数 (HR_{rest}) は、本章では7分間の安静座位時における平均心拍数の平均値として定義した。また、最大心拍数 (HR_{max}) は、以下に示す Karvonen の式を用いて設定された。

$$HR_{max} = 220 - Age \quad (3.5)$$

3.4.3 身体活動分類のためのアルゴリズム

第1の改善である行動分類数を増加させたアルゴリズムについて、本節では説明する。今回新たに提案するアルゴリズムは、従来、歩行活動として1グループであった

ものを運動強度に応じた Middle Intensity Group (MIG), High Intensity Group (HIG)の2種類に細分化する。本章にて提案するアルゴリズムは、先行研究で報告されているアルゴリズムをベースとして、その決定木に新たな分岐を追加することで実現させた。従来の決定木[26]では、上述の表 3-2 に示す、Sedentary, Household, Locomotive の3種類に分類している。

本章にて提案する分類数増加のアルゴリズムについて、我々は先行研究として%HRR を用いての運動強度の分類の可能性について評価した[46]。結果、ジョギング、階段上りといった6METs以上の高強度の運動と6METs以下の行動を%HRRを用いることで分類できることが確認できた。その結果をもとに、本章では%HRRを用いた分類方法を提案、その決定木を以下の図 3-3 に示す。




図 3-3 Proposed decision tree for this study

3.4.4 運動強度としての METs 推定方法

第2の改善は、運動強度推定のための多重回帰モデルにおいて使用される特徴量を増加させることである。本章では、分類数増加のために使用した%HRRだけでなく、他の身体的特徴もMETs推定のために利用することを検討した。本論文ではその多重回帰モデルをSPSS Statistics 24(SPSS24; IBM Corp., Armonk, NY)を用いて計算した。本論文では5種類の異なる多重回帰モデルを提案する。多重回帰モデルに用いた特徴量が推定結果へ与える影響を検証するために、モデル作成には強制入力法を採用した。表1は、提案されたモデルのそれぞれで使用される特徴量を示す。

表 3-3 List of features for each proposed model

Model	Features
Prop. 01	ACC_{fit}
Prop. 02	%HRR
Prop. 03	ACC_{fit} , %HRR
Prop. 04	ACC_{fit} , %HRR, BMI
Prop. 05	ACC_{fit} , %HRR, weight
Previous	ACC_{fit}

提案された5種類のモデルにおける METs 推定精度は、leave-one-out cross validation によって生成された推定 METs 値の平均絶対誤差率 (MAPE) に基づいて比較した。このプロセスでは、被験者1名を検証データとして定義、他の被験者のデータはトレーニングデータとして重回帰モデル作成に利用する。このプロセスを全被験者にて繰り返し、その推定誤差結果の MAPE を算出し、目的に合った最適モデルを決定する。

3.5 アルゴリズム開発に向けた臨床試験

本章では、今回提案するアルゴリズムの開発のために行った臨床試験について説明する。

3.5.1 臨床試験概要

本章で提案された行動分類のための決定木と METs 推定のための多重回帰モデルを開発、評価するために42名のボランティアによる臨床試験を実施した。この臨床試験では、被験者の呼気ガスを用いて測定された METs、三軸の加速度信号、および RRI を記録した。以下の図に測定状況の一例を示す。




図 3-4 (a)臨床試験風景. (b)HealthPatchMD と HJA-750C の取り付け位
(c)HealthPatch MD (d)HJA-750C.

3.5.2 被験者に関する情報

本章で述べる臨床試験はヘルシンキ宣言[47]に示されたガイドラインに従って、日本の国立健康・栄養研究所（NIHN）で実施された。この実験には、合計 42 人のボランティアが参加、被験者を含むすべてのプロトコルは、NIHN の倫理委員会およびオムロンヘルスケア株式会社によって承認されたものであった。今回の試験では各世代、および性別からおよそ 5 人づつ抽出されるように被験者を選択した。すべての被験者は体重および身長を測定し、各被験者の BMI を算出した。被験者の年齢、性別、身長、体重、および BMI 分布を表 3-4 に示す。本研究に関連する目的および手順に関する詳細は、測定前に被験者に説明されすべての被験者から事前に書面によるインフォームドコンセントがなされた。

表 3-4 Physical characteristics of subjects (N = 42)

	Generation	N	Age[years]	Height[cm]	Weight[kg]	BMI[kg/m ²]
			Avg. (SD)	Avg. (SD)	Avg. (SD)	Avg. (SD)
Male	20-30	6	26.2 (3.1)	169.0 (7.2)	66.3 (10.6)	23.1 (2.0)
	30-40	4	36.3 (2.8)	171.1 (3.1)	65.6 (15.2)	22.3 (4.4)
	40-50	6	43.2 (3.9)	173.1 (6.2)	73.1 (12.1)	24.4 (3.6)
	50-60	5	52.2 (1.8)	171.5 (2.3)	68.4 (13.1)	23.2 (3.9)
Female	20-30	5	23.0 (2.3)	157.3 (4.5)	49.1 (5.1)	19.8 (1.5)
	30-40	6	32.5 (3.4)	163.1 (11.0)	59.0 (14.9)	22.0 (4.2)
	40-50	5	43.0 (4.2)	155.9(5.7)	52.8 (17.1)	21.6 (6.4)
	50-60	5	52.8 (1.3)	158.1 (2.2)	59.4 (8.0)	23.8 (3.2)

3.5.3 臨床試験プロトコル

この研究では、実施した様々な身体活動の 3 軸加速度、RRI、および消費エネルギーの記録を行った。記録のため被験者は、HealthPatch MD（Vital Connect Inc., San Jose, Ca）を胸部に取り付け、23 の異なる活動（座位での安静を含む）中における 3 軸加速度および RRI を記録を行った。この記録された RRI は HealthPatchMD の機能を用いて得られた値である。本研究で用いる %HRR の計算に利用する心拍数(BPM)は、この RRI から変換された値を用いた。この HealthPatch MD は、24 時間モニタリング用に開発

された測定装置であり肌に直接貼り付けて使用する。この装置の測定精度については、すでに報告[48]されており、本試験に用いることは問題がないと判断した。各被験者のウエストには活動量計 (HJA-750C;オムロンヘルスケア株式会社, 京都, 日本) を取り付けた。HJA-750C には本論文のアルゴリズムのベースとなっているアルゴリズムが実装されている。先行研究を用いた場合の推定 METs として利用するために HealthPatch と同時計測を行いその値を記録した。図 3-4(b)にこれらのデバイスの取り付け位置を示す。

23 種類の異なる行動中, 被験者はマスクが取り付けられ, 呼吸に伴うガスは取り付けられたダグラスバッグに集められた。式(3.2)にある Weir の公式を用いて, 各行動における消費エネルギー量(kcal)を計算し, 安静時の消費エネルギー量との比較から METs へと換算された。この呼気ガスから得られた METs は本章における METs の基準値として誤差評価に利用する。計測されたのは 23 種類の行動ではあったが, 本章では, 階段上りを含む歩行活動中の推定精度向上が目的であったため, 実施した行動のうち, 階段昇降, 歩行 (3 速), 歩行 (2 パターン), およびジョギングの歩行活動に分類される 8 つの行動についての評価を実施した。その 8 種の行動についての実施時間, およびその速度を以下の表 3-5 に示す。

表 3-5 The eight locomotive activities performed in this paper

Activity	Speed	time [min]
Stair descent	Self-selected	2.5
Stair ascent	Self-selected	2
Slow walking	55 m/min	5
Normal walking	70 m/min	5
Brisk walking	100 m/min	5
Normal walking with load (3kg)	70 m/min	5
Slow walking with load (5kg)	55 m/min	5
Jogging	130 m/min	4

3.5.4 臨床試験における計測結果

以下の表 3-6 に各活動の METs および%HRR の平均および標準偏差 (SD) を示す。表中の N が各行動において正しく測定できた被験者数をあらわしている。42 名の被験者のうちの 2 人は、いずれの活動中も測定できなかったため結果から除外している。測定不能であったデータは解析対象から除外した。

表 3-6 %HRR and measured METs with each activity

	Activity	N	HRR[%]		METs	
			Avg.	SD	Avg.	SD
MIG	Stair descent	36	15.45	7.11	2.73	0.39
	Slow walking (55 m/min)	33	18.81	9.10	3.35	0.54
	Normal walking (70 m/min)	29	23.37	9.14	3.75	0.50
	Brisk walking (100 m/min)	30	34.16	11.87	5.12	0.88
	Slow walking with Load (5 kg)	33	27.01	9.50	4.03	0.46
	Normal walking with Load (3 kg)	29	26.92	9.99	4.24	0.65
HIG	Stair ascent	30	51.22	8.52	7.42	0.87
	Jogging (130 m/min)	23	67.34	15.37	9.50	1.64

次に 8 種の行動における ACC_{fil} と %HRR の分布を以下の図 3-5 に示す。また、表 3-7 に METs, ACC_{fil} および %HRR の統計量を記す。




図 3-5 (a) the relationship between METs and ACC_{fil}

(b) the relationship between METs and %HRR

表 3-7 Statistical results of measurement indices

Index	MIG		HIG	
	Avg.	SD	Avg.	SD
ACC _{fil} [mG]	294.1	89.6	545.8	367.9
%HRR [%]	23.96	11.20	58.2	14.3
METs	3.83	0.95	8.3	1.6

図中にある r_{HACC} は、HIG における ACC_{fil} と MET の相関係数であり、 r_{MACC} は MIG の相関係数である。HIG、MIG ともに 0.68 と強い相関を示していることが確認できた。

図 3-5(b) は HRR と MET の関係を示したものである。図中の r_{HHR} は HIG における %HRR と METs の間の相関係数であり、 r_{MHR} は MIG における相関係数である。MIG については $r = 0.756$ と高い相関を持っていることが確認できた、しかしながら、HIG においては $r = 0.573$ と MIG に比べて低い値となっている。

3.6 提案決定木を用いた行動分類結果

本章では、新たに提案した決定木を用いた行動分類の推定結果について述べ、その誤差原因について検討する。

3.6.1 MIG, HIG を分類するための%HRR 閾値の決定

本節では、歩行活動を%HRRによってMIGとHIGに分類するための閾値の決定方法について述べる。まず得られたデータから、MIGとHIGの分類精度が最も高い%HRRの値を探索した。以下の図3-6は、%HRRと、MIGおよびHIGの分類精度との関係を示す。その結果、図中に矢印で示された点がMIG,HIGともに分類精度が最大となる箇所であり、その%HRRは40.15%であることが分かった。これは、ACSMガイドラインにおける軽度(Light)と中程度(Moderate)の境界値(%HRR=40%)に非常に近い値であった。このため、本論文では試験データから得られた40.15%ではなく、閾値に一般性を持たせるためにもガイドラインに従って%HRR=40%を使用することを決定した。

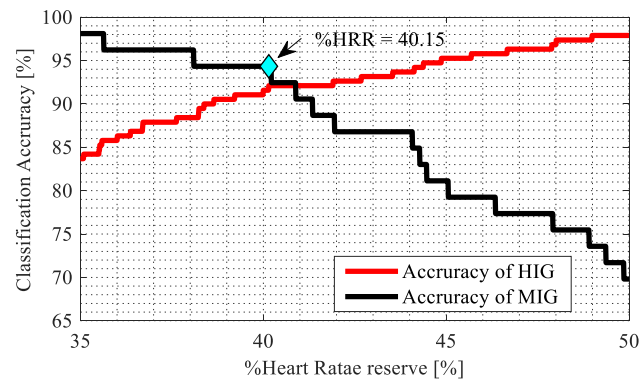


図 3-6 The relationship between classification accuracy of MIG and HIG and %HRR

3.6.2 行動分類結果

各活動の分類結果を表 3-8 に示す。MIG と定義された活動のうち、91.6%が正しく分類された。MIG の中では早歩き (brisk walking)の推定精度が 76.7%と、最も推定精度が低い結果となった。HIG として定義された階段上昇とジョギングは、94.3%は正しく分類されていたが、5.7%は MIG に誤分類される結果であった。

表 3-8 Results of group classification using the proposed decision tree

	Percentage of Classified Result	
	classified as MIG [%]	classified as HIG [%]
MIG	91.6	8.4
Stair descent	100.0	0.0
Slow walking(55m/min)	100.0	0.0
Normal walking(70m/min)	96.6	3.4
Brisk walking(100m/min)	76.7	23.3
Slow walking with Load(5 kg)	87.9	12.1
Normal walking with Load(3 kg)	86.2	13.8
HIG	5.7	94.3
Stair ascent	6.7	93.3
Jogging(130m/min)	4.3	95.7

3.6.3 誤差原因に関する分析

本節では誤分類の原因について検討する。表 3-8 に記載されているように分類精度は MIG と HIG の両方で平均 91%以上であり、実使用上問題ないレベルである。しか

し、早歩き(*Brisk walk*)における分類精度は他の活動と比較して低い結果であった(76.7%)。これは誤分類された被験者の%HRR 傾向が、正しく分類された群とは異なることが原因である。

誤分類された被験者の身体情報を確認すると、誤分類された7人中5人が女性であることが分かった。今回の試験では被験者の男性/女性比が50%になるよう調整したにも関わらず、このような偏りが確認された。被験者の性別が%HRR に強い影響を与えることが考えられる。これらの影響を排除するための一つの提案として、最大心拍数の計算式の変更が挙げられる。Whyte らは、性別と年齢、運動習慣を考慮した以下の式(3.6)ような最大心拍数の推定式を提案している[49]。

$$HR_{\max}(\textit{SedentaryFemale}) = 221 - 1.09 \cdot \textit{Age} \quad (3.6)$$

本研究においては、運動習慣に関するデータがないため上記の推定式を利用した推定は行えていない。しかしながら、こうした性別、年齢、運動習慣を考慮した最大心拍数の推定式を採用することにより、%HRR の値の改善をによる分類精度の向上が期待できる。

3.7 METs 推定精度評価

本節では、提案された5つの多重回帰モデルを用いて得られたMETs 推定結果の比較を行う。その中の最適モデルについて他のアルゴリズムとの比較検討を実施した。

3.7.1 leave-one-out cross-validation を用いた各モデル間の比較

本節では、提案した5つの多重回帰モデルについて、leave-one-out cross-validation を用いて比較検討を行った。各モデルで利用している特徴量は本章3.4.4節、表3-3で示されている。以下の表3-9に各提案モデルにおけるMAPEの平均値を示す。参考として同時計測を行ったHJA-750Cの結果も示す。HJA-750Cは加速度のみを使用、MIGとHIGを1つの歩行活動グループとして扱う、従来の推定アルゴリズムを使用した結果である。結果は、提案モデルProp.03, 04, 05においてはすべての行動において大きな差はない。一方で、Prop.01, Prop.02におけるMAPEは、他の3つのモデルに比べて大きくなり、階段上昇では3つのモデルよりもそれぞれ数%大きい結果であった。

表 3-9 Mean absolute percentage errors (MAPE) of respective estimated results [%]

Activity	Proposed multiple-regression-models					HJA-750C	
	Prop. 01	Prop. 02	Prop. 03	Prop. 04	Prop. 05	N	
Stair descent	31.6	22.9	21.6	22.0	22.3	36	28.6
Slow walking (55 m/min)	12.1	11.1	8.8	9.0	8.8	33	13.2
Normal walking (70 m/min)	13.6	11.5	12.1	12.6	12.4	29	11.9
Brisk walking (100 m/min)	18.7	17.9	15.9	17.4	16.8	30	11.8
Slow walking with load (5 kg)	18.6	15.8	16.2	17.0	16.4	33	15.8
Normal walking with load (3 kg)	17.5	17.0	16.7	17.7	16.9	29	10.5
Stair ascent	11.7	13.5	10.0	10.5	10.5	27	58.7
Jogging (130 m/min)	13.5	14.7	12.8	12.4	11.8	23	11.4
MIG	19.0	16.2	15.3	16.1	15.7	189	15.8
HIG	12.4	13.8	11.1	11.1	10.8	50	36.9

推定が困難である階段上りを含む HIG に関する結果に着目する。Prop. 05 の MAPE が 10.8%あり、最も推定誤差が低いモデルであった。しかしながら、その差はわずか 0.3%であり、無視できるほど小さい。階段上昇の結果に注目すると、Prop. 03 の結果 (10.0%) が最もいい結果であった。Prop.03 モデルと従来モデル(HJA-750C)の階段上昇時における MAPE は、それぞれ 10.0%と 58.7%であり、大幅な改善効果を示した。

これらの結果に基づいて、本研究では最適モデルとして Prop.03 を採用する。Prop. 03, 04, 05 における MAPE の差は、階段上昇時にわずか 0.5%、HIG では 0.3%であることと、特徴量が 3 つのモデル中最も少ない 2 個であり、本研究の目的に最適なモデルであると判断した。

3.7.2 最適モデルを用いた精度評価

3.7.1 で提示された結果に基づいて、本研究では最適モデルとして Prop.03 を採用した。目的である階段上昇時の推定精度が最も高かったことと、使用する特徴量が加速度と心拍だけであり最も少なく、非常に簡便な推定モデルであるためである。

最適モデルを利用した場合の METs 推定誤差評価のために、すべての測定データを

トレーニングデータとして使用し、重回帰モデルを再計算した。再計算された推定式を以下の式(3.7)と式(3.8)にそれぞれ示す。

$$MIG : METs_{est} = 0.0043 \cdot ACC_{fil} + 0.047 \cdot \%HRR + 1.4238 \quad (3.7)$$

$$HIG : METs_{est} = 0.0024 \cdot ACC_{fil} + 0.029 \cdot \%HRR + 5.3113 \quad (3.8)$$

図 3-7 は、式(3.7)と式(3.8)を用いて得られた推定誤差と METs の関係と従来のモデルで得られた結果をそれぞれ示す。図 3-7(a)はMIGにおける提案モデルの結果を示し、図 3-7(c)は HIG における結果を示している。図 3-7(b)は MIG における従来アルゴリズム(HJA-750C)の結果を、図 3-7(d)は従来アルゴリズムの HIG における結果を示している。図中の実線は MIG および HIG の平均値を示し、破線は、誤差の 95%予測間隔 (Prediction Interval) を表している。表 7 には得られた推定誤差の統計的な解析結果を示す。

提案された最適モデルを用いた MIG の結果は、その平均の 95%信頼区間(Confidential Interval)が 0.07~0.31 とわずかなバイアス誤差を有している。しかし、METs と推定誤差における相関係数は $r = 0.005$ であり比例誤差は存在しない結果であることが確認された。次に HIG モデルについて確認する。その平均値の 95%信頼区間は -0.48 から 0.21 でありバイアス誤差は見られない。しかしながら、METs と推定誤差における相関係数が $r = -0.543$ と、比例誤差が存在する結果となった。

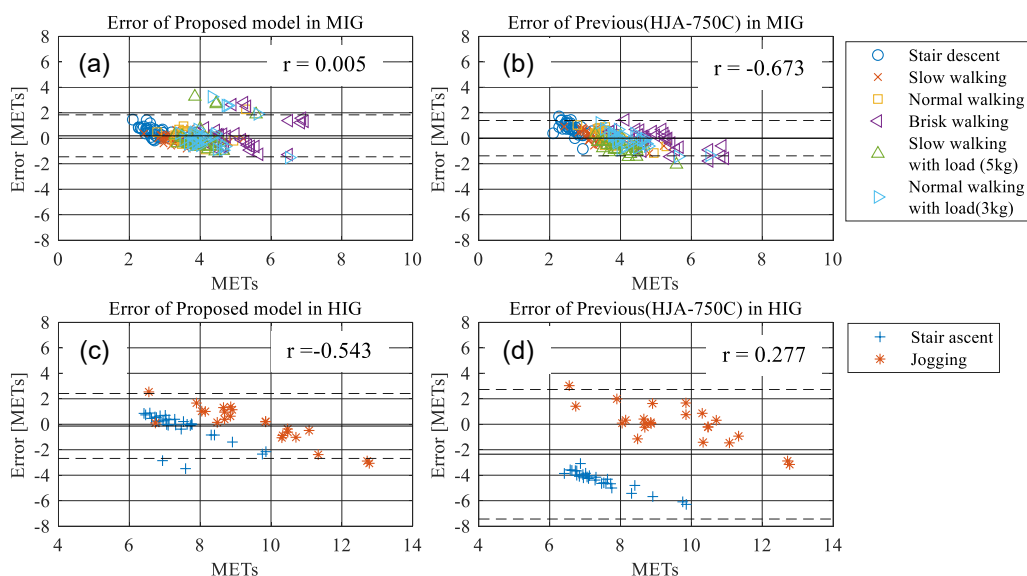


図 3-7 METs and error rates of eight activities obtained using the proposed model and the algorithm reported earlier

表 3-10 Statistical results of estimation with using all data

	MIG		HIG	
	Proposed	Previous	Proposed	Previous
Average	0.19	0.01	-0.14	-2.35
Upper confidence Interval of the average (95%)	0.31	0.11	0.21	-1.64
Lower confidence Interval of the average (95%)	0.07	-0.09	-0.48	-3.06
Upper Prediction Interval (95%)	1.84	1.40	2.41	2.73
Lower Prediction Interval (95%)	-1.46	-1.38	-2.68	-7.44

また、精度比較のために、以前のモデルと提案されたモデルを使用した場合の Mean Absolute Percentage Error (MAPE)と Mean Percentage Error (MPE)を算出、その結果を表 3-11 にまとめた。階段上昇における MAPE は 9.61%であり、MPE は-2.24%であった。一方で以前のモデル (HJA-750C) の METs の MAPE および MPE は、それぞれ 58.70% および-58.70%という結果であった。したがって、本章で提案されたモデルは、以前のモデル(HJA-750C)よりもそれぞれ推定誤差を約 84%、96%も改善できた。また、同じく HIG の行動であるジョギングの結果は従来のものと提案モデルはほぼ同じ値であり、精度低下は認められなかった。

表 3-11 MAPE and MPE for eight activities

Activity	MAPE[%]		MPE[%]	
	Prop.	Prev.	Prop.	Prev.
Stair descent	21.22	28.56	20.02	26.63
Slow walking	8.19	13.2	-0.04	5.06
Normal walking	11.48	11.88	2.65	3.94
Brisk walking	15.59	11.79	4.27	-2.15
Slow walking with load (5 kg)	15.82	15.84	1.44	-15
Normal walking with load(3 kg)	16.23	7.47	4.31	-1.87
Stair ascent	9.61	58.70	-2.24	-58.70
Jogging	11.66	11.41	2.1	2.47
MIG	14.88	15.31	5.77	3.32
HIG	10.50	36.95	-0.36	-30.56

加えて本研究では分類結果に基づいた推定誤差分布をについて評価した。以下の図 3-8 にその分布を示す。図中の直線は正しく分類できている群の平均を示し、破線はその群の 95%予想区間を示している。MIG で正しく分類されている群の 95%予測区間は、-1.04 から 1.03 MET であるが、HIG のそれは-2.32 から 2.28 MET である。

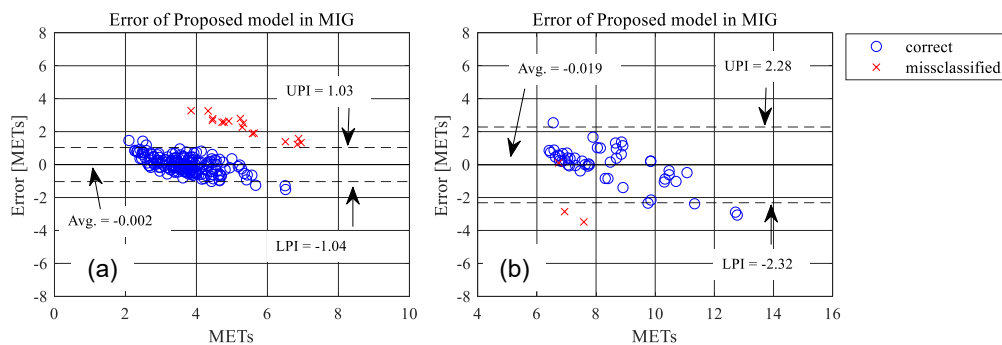


図 3-8 Relation between error and the result of classification.

本研究では、推定誤差と分類結果の関係を確認した。図 3-8 に示すように、MIG における 2 MET 以上の誤差はすべて誤分類した結果であった。仮に、この誤分類を排除した場合、95%予測区間は-1.04~1.03 となり、HJA-750C (-1.38~1.40) で得られた予測区間よりも優れた結果となる。したがって、3.6.3 で述べた誤分類を減らす取り組みを行うことで、さらなる推定精度向上が期待できる。

3.7.3 提案アルゴリズムと他の推定アルゴリズムとの比較結果

本章では、歩行やジョギングなどの行動における METs 推定精度として MAPE を他のアルゴリズムと比較した。比較に利用したアルゴリズムは、本章で提案したアルゴリズムと同じ分類木を利用した機械学習を用いたものを選択した。その結果を以下の表に示す。推定に利用しているデータ・行動などは異なるものの、提案アルゴリズムと機械学習を用いたアルゴリズムとの間に MAPE における明確な差はないことが確認できた。

表 3-12 Mean absolute percentage error compared with other algorithms

Author	Algorithm	Ref	Number of features	Activity	MAPE [%]
Proposed	Classification tree Multi-regression model		2	6 different walks, jogging, stair	13.9
Mitja Luštrek	REPTree	[28]	8 (Accelerometer)	running	12.6 ^{*1}
Hristijan Gjoreski	Random forest Multiple Contexts Ensemble	[29]	128 (Accelerometer)	Walk, running	15.7

*1 This value was calculated as the MAPE to the mean value of METs at two different speeds

また、以下の表 3-13 には本章で着目した METs 推定が困難な行動である階段上昇/下降における他のアルゴリズムを用いて得られた結果と比較した結果を示す。提案されたモデルは Wang の方法を除いて、他の推定方法に対してその精度向上が達成できていることを示している。

表 3-13 Mean percentage error (MPE) with other algorithms

Algorithm	Ref	Features	Activity	MPE [%]
Proposed model	--	Accelerometer, %HRR	stair ascent /descent	9.90
ActiGraph New 2 -regression model	[32]	count	stair ascent /descent	-11.76
Actiheart combined activity and HR algorithm	[38]	count, HR	stair ascent /descent	-20.51
Proposed model	--	Accelerometer, %HRR	stair ascent	-2.25
Matteo Voleno	[36]	Accelerometer, barometer	stair ascent	6.6
Jinging Wang	[51]	21 features(form accelerometer and barometer)	stair ascent	-1.96

3.7.4 METs 推定精度に関する分析

提案モデルと従来モデルの比較結果について詳細を確認する。図 3-7 と表 3-11 に示された結果から、提案されたモデルが推定精度に関して以前のモデルよりも大幅に改善されていることは明らかである。次に、本研究で着目した階段上りにおける結果に着目する。従来モデルを利用した場合、その誤差はすべて-3.0 METs 未満とかなり過少評価をとなっていた。一方で本研究で提案したモデルの誤差はそのほとんどが±2.0 METs 以内となっており METs 推定の高精度化を達成することができた。

提案アルゴリズムを用いて得られた結果と、他の推定アルゴリズムを用いて得られた結果[28][29][32][36][38][51]と比較した結果について確認する。表 3-12 は、歩行やジョギングなどの歩行活動における比較結果である。推定精度の指標である MAPE は Hristijan Gjoreski ら [29]の報告例に対しては MAPE で 1.8%小さい結果であった。一方で Mitja Luštrek ら[28]の結果は提案手法が MAPE で 1.3%大きい結果であった。しかしながら、同じジョギングだけで比較した場合、提案手法の MAPE は 11.66%であり提案手法のほうが小さい結果であった。これらの結果から、提案アルゴリズムは非常にシンプルな構成にも関わらず、機械学習を用いたものと同程度の精度であることが確認できた。次に、本章で着目した階段のぼり行動における推定精度について比較した結果について述べる。表 3-13 は、階段昇降と下降の推定結果を組み合わせたものを示している。他のアルゴリズムとの比較においても提案アルゴリズムが大きなな

改善が認められる。Actiheart の加速度と心拍を組み合わせたアルゴリズムの結果と比較して、約 10%精度が向上した。したがって、提案モデルは、提案モデルと同じ加速度と心拍数を併用した他のアルゴリズムよりも推定精度向上が確認できた。

さらに、表 3-13 では階段上昇の MPE について加速度計と気圧計を使用する他のアルゴリズムと比較した。M. Voleno ら[36]によって報告された結果は 6.6%であったが、我々のモデルの MPE は-2.25%と小さな値となっている。一方で、J.Wang らによって報告されたアルゴリズム[51]は、我々のモデルよりわずかに優れており、その差は約 0.3%である。表 3-6 によれば、階段上昇中の METs は約 7METs であり、0.3%の差は約 0.02 METs に相当する。この結果から我々のモデルと J.Wang[51]のアルゴリズムとの間に重大な誤差は存在しないと考えられる。

以上の結果から、本章にて提案されたアルゴリズムは非常にシンプルな構成であるにも関わらず他のアルゴリズムに対して階段上昇時における METs 推定精度の向上が達成できた。

3.8 結言

我々は、身体活動強度データとしての METs、特に階段上昇を含む日常生活における高強度活動の間における METs を推定することができるアルゴリズムを提案した。本章におけるこの結果は、2つの大きな改善によって実現できた。%HRR を使用した、新たな決定木を使用して歩行活動を 2つのグループに分類しました。さらに、5つの多重回帰モデルを提案、leave-one-out cross validation に基づいて、本発明の目的に最も適した多重回帰モデルを決定した。その結果、本章にて提案したモデルは従来モデルの MAPE よりも 26.45%小さく、約 72%改善していることが確認された。以前に使用されたモデル (HJA-750C) と比較して、階段上昇の MAPE で 84%減少した。これらの結果から、提案アルゴリズムは、階段上昇などの推定が困難な活動を含む、日常生活の METs 推定精度を向上させることができた。

第4章 ウェアラブルデバイスの低消費電力化 と小型化のための System-on-Chip (SoC)の開発

4.1 諸言

本章では、課題であるウェアラブルデバイスの小型化と低消費電力化を実現するために、第3章で提案されたアルゴリズムが実装が可能な System-on-Chip (SoC) の開発を行う。

4.2 節では小型化と消費電力に関する現状の課題について記述する。

4.3 節では本章で新たに開発した SoC について説明する。

最後に、4.4 節では、SoC を用いた場合の消費電力に関する評価結果を記述する。

4.2 ウェアラブルデバイスにおける小型化と低消費電力化 の現状と課題

4.2.1 ウェアラブルデバイスの小型化に向けた取り組み

ウェアラブルデバイスの取り組むべき課題として長期間の連続使用に向けたウェアラブルデバイスの小型化が挙げられる。序論でも述べた通り、効果的な生活習慣の改善のためには、長期間の連続した運動習慣、FITT の記録が望ましい。そのためには装着が容易かつ日常生活における活動を妨げないように、できる限り小型・軽量のウェアラブルデバイスであることが求められる。ウェアラブルデバイスの小型・軽量化するためには、それを構成する部品点数の削減と使用される電池サイズを小さくすることが効果的な手段である。

こうした課題に対する取り組みとして、近年 SoC による周辺機能のチップへの集積

化が盛んにおこなわれるようになった。SoCとは、計算処理をおこなうCPUと従来であれば回路上別部品となっていたBLE通信機能などの周辺機能を1chipに集約したものを示す。例えば、Nordic社[52]やQualcomm社[53]が、スマートフォンやIoT(Internet of Things)機器用として無線通信だけでなく種々の機能を組み込んだSoCを発表している。こうしたSoCを利用することで、同じ機能を維持しつつ部品点数を削減が可能となり、ウェアラブルデバイスの小型化が実現される。

4.2.2 小型化と低消費電力化へのアプローチ

小型化に向けたアプローチとして、ウェアラブルデバイス向けの低消費電力SoCの開発を行った。そのSoCは、先行研究で報告された、ノーマリーオフ技術を使用した低電力の心拍数モニタリングSoC[40]を改良したものである。このSoCは不揮発性メモリ集積し、電源供給がなされていない環境でも命令やデータを保持し続けることができる。そのため、待機状態の消費電流はゼロとなりシステムの低消費電力化に大きく貢献する。本章では、第3章で提案されたアルゴリズムが実装、動作できかつ、ウェアラブルデバイスの低消費電力化に貢献するSoCを開発した。以下の章で本章で開発したSoCに対する詳細を記述する

4.3 生体信号計測に適した低消費電力 SoC の開発

以下の図 4-1 に開発した活動量推定用 SoC のブロック図を示す。第 3 章で提案されたアルゴリズムを実現するための回路要素が実装されている。すなわち心拍センサ、SoC 外部にある加速度センサとのインタフェース、Non-volatile CPU (NV-CM0)、発振器、タイマブロック、そして今回新たに開発、追加された IIR フィルタ回路、合成加速度計算回路、Data buffer SRAM が集積されている。これによりこの SoC は、METs 推定と行動分類機能を低消費電力で実行する。

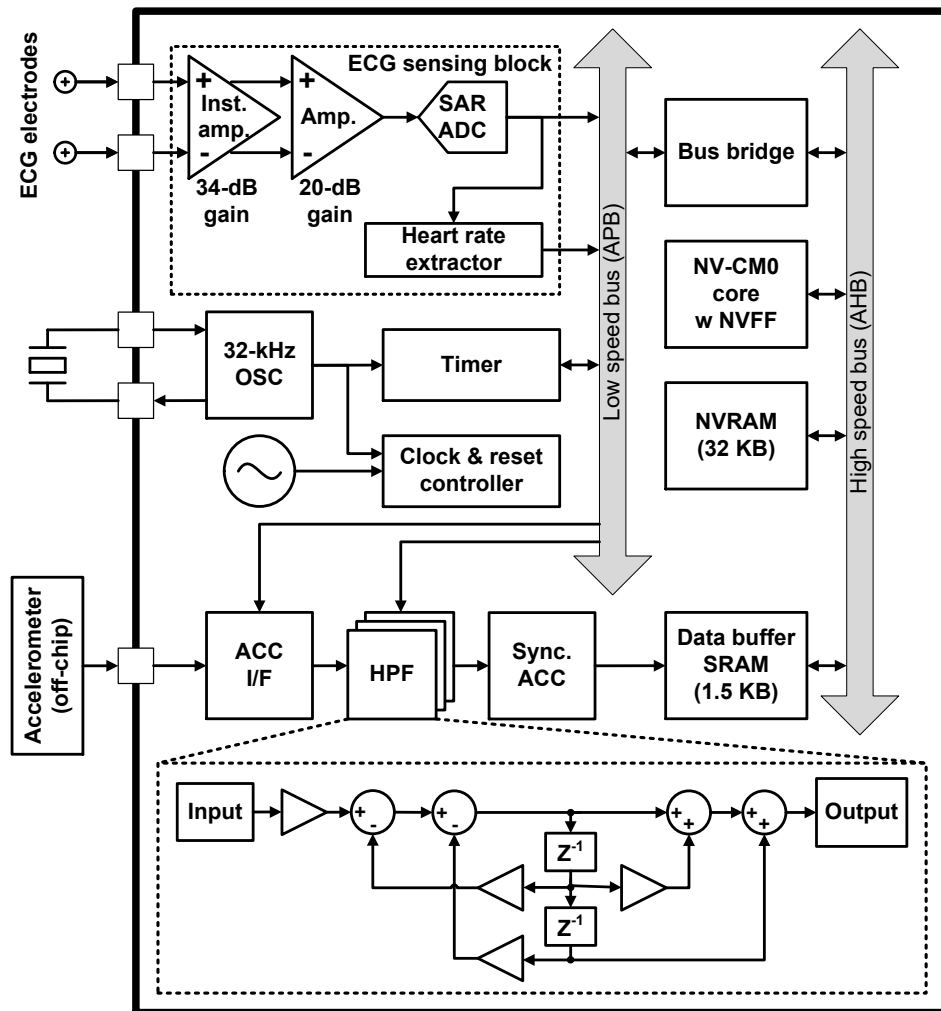


図 4-1 Block diagram of the SoC

4.3.1 低消費電力化に向けた不揮発性メモリ，バッファメモリの実装

本研究で開発した SoC は強誘電体メモリ (FeRAM) を利用した不揮発性フリップフロップからなる不揮発性 CPU と不揮発性 RAM を処理部に持つ。それら不揮発性の処理部は電源供給がされていない場合でも、保存されていたデータを保持し続ける。したがって、CPU や RAM を使用しない待機状態(Sleep)において、電源供給を断つことが可能となり、その間の消費電流をゼロにすることができる。したがって以下の図 4-2 中に示される待機時間(T_{sleep})が長いと消費電力がゼロの時間が増加、結果としてシステムの低消費電力化が期待できる。本章 4.2.2 節でも述べたように、生体信号は一般的に CPU の動作周波数に比べて非常に低いものとなる(CPU 24MHz, 生体活動 : 0.1~10Hz)。そのため、不揮発性 CPU と不揮発性 RAM 利用は CPU の Active Rate を低くすることが容易であり、生体信号モニタリングウェアラブルデバイスの低消費電力化に非常に効果的なアプローチである。

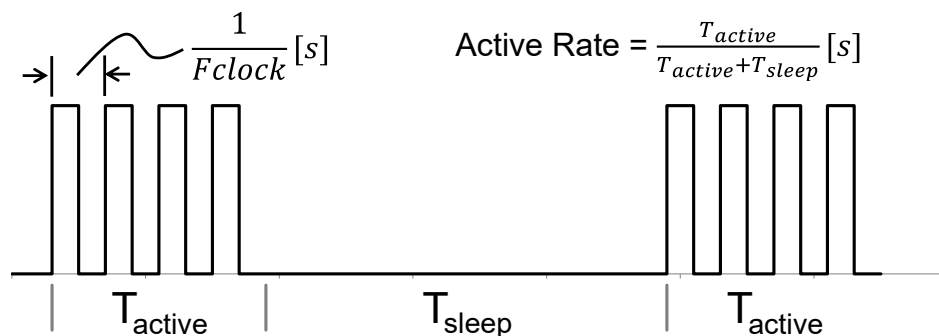


図 4-2 The example of active state and sleep state

加えて、今回開発する SoC には、センサからのデータを保存するためのデータバッファ用 SRAM を実装する。この SRAM は NV-CM0 を経由することなくセンサからの信号などの保存ができるように、内部のデータパス、制御回路を設計した。その結果、METs 推定、行動分類などを実行する NV-CM0 はセンサのサンプリングレートからは独立した動作が可能になり、アクティブレートを削減できる。

表 4-1 に、本研究で開発した SoC 上の各機能ブロックの Active rate を示している。チップ内部の ECG sensing Block にある Analog to Digital Convertor (ADC) と CPU は、本研究で開発した SoC に実装されている不揮発性の処理部、バッファメモリを利用することで、それらのアクティブレートは、それぞれ 0.1% および 2.14% に抑えられた。通

常この機能ブロックは消費電力が高い傾向にあり、低いアクティブレートを実現できたことで、SoCの低消費電力化に大きく寄与する。

表 4-1 The Active rate of each function block

Function Block		Power; Clock contoller	Clock Frequency [Hz]	Active Rat [%]
Clock				
Timer		Always on	32k	100
Power controller				
ECG sensing block	AFE	Always on	-	100
	ADC	Clock gating	24k	2.14
	HRE*1	Clock gating	32k	100
Accelerometer	I/F	Clock gating	32k	64.7
	Filter	Clock gating	32	100
Buffer SRAM		Clock gating	write 32k read 24M	write 0.1 read 0.00014
NV-CM0		Power gatig	24M	0.10
NVRAM		(Normally Off)		

4.3.2 デジタルフィルタ処理のハードウェア化

不揮発メモリの集積に加えて、SoCのアクティブレートを低くするために、デジタルフィルタ処理を行うハードウェアのSoC内部への実装を検討した。デジタルフィルタ処理には、ハイパスフィルタと合成加速度の計算という処理が含まれる。先行研究として和泉らが報告する心拍測定用SoC[40]では、これらの信号処理はソフトウェアで処理を行う必要があった。そのためサンプリングレートと同じサイクルでCPUによって処理されなければならなかった。そのため、余剰な動作が多く、アクティブレートが高くなる要因であった。アクティブレートを下げ、低消費電力化を実現するためにもフィルタ処理部のハードウェア化を行った。

本研究は加速度信号に対するフィルタリングと合成加速度の計算処理を行う回路を開発し、SoC内部に実装した。今回実装されたフィルタ回路は、入出力信号のタイマー制御により、単一のフィルタ回路にも関わらず3軸それぞれの加速度信号のフィル

タリング処理が可能なものとした。これによってチップ内部におけるフィルタリング回路部分の面積を最小限に抑えることができる。

4.3.3 サンプリングレートの変更への対応

開発したフィルタリング処理部は、加速度センサのサンプリングレートの変化にも対応できるように、サンプリングレートに従ってフィルタ内部の各係数を変更することを可能とするように設計された。加えて、この処理部は動的にサンプリングレートを変化させることを想定して設計されている。すなわち生体活動の動きに合わせてサンプリングレートを変化させる。

サンプリングレートを変化させた直後はフィルタ内部の2つの遅延値 (Z^{-1}) にサンプリングレート変化前の値が格納されている。したがって、サンプリングレートの変更直後には、その変更前の遅延値の影響を大きく受け、フィルタリング後の信号に大きな誤差が発生する。以下の図 4-3 にフィルタに一定信号 (0Hz) を入力し、サンプリングレートを変化させた場合の出力波形を示す。変化前のサンプリングレート (BSR : Base Sampling Rate) からその半分の 50%BSR に変更した場合、変更直後に大きなオーバーシュートが発生し、その後約 2.2 秒間程度の安定時間が必要となる。

この影響を最小限に抑えるために、サンプリングレートが変更されたときにフィルタ内部の遅延値 (Z^{-1}) に対して、変更後のサンプリングレートに応じた調整係数を乗ずる。その乗算を可能にするフィルタ回路を設計した。この調整係数とこのフィルタ回路を用いたフィルタ処理後の出力波形を図 4-3 に示す。これにより、フィルタ後の出力波形においてサンプリングレートを変化させた影響は認められない。




図 4-3 The influence of changing sampling rate

4.4 試作 SoC を用いた低消費電力効果に関する検証

4.4.1 試作 SoC

本研究で提案されたシステムの性能を実証するために、強誘電体キャパシタプロセスを用いた 130nm CMOS プロセスで上記 SoC を試作した。図 4-4 および表 4-2 に、チップ写真およびその仕様を示す。

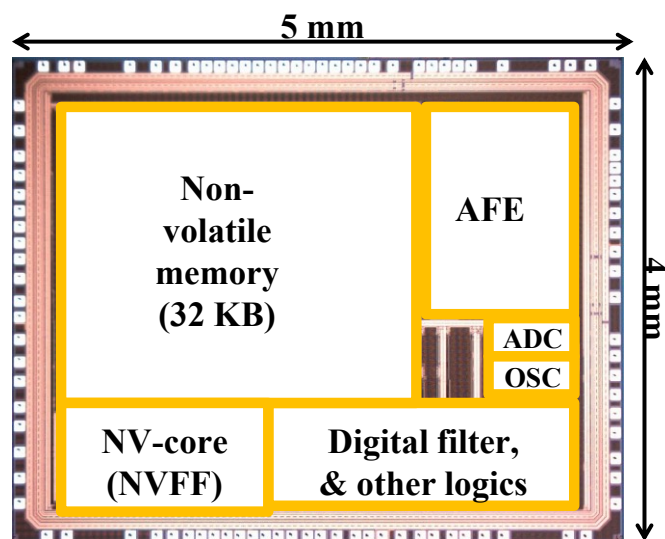


図 4-4 Test chip micrograph.

表 4-2 Test chip specifications

Technology	0.13 μm CMOS	
Supply voltage	1.5 V (AFE, ADC, Logic, Mem.)	
	3.3 V (32.768-kHz OSC, I/O)	
Chip area	$4 \times 5 \text{ mm}^2$	
Frequency	24 MHz (for processor)	
	32 kHz (for other blocks)	
Processor	32-bit Cortex M0 (with NVFF)	
On chip memory	32-KByte 6T-4C NVRAM	
AFE	Gain	54 dB
	Bandwidth	700 Hz
	CMRR	73 dB
ADC	Resolution	8 bit
	Current	0.23 μA @128 S/s, 1.0 μA @1 kS/s

さらにこの SoC を用いてアプリケーションボードを試作した。図 4-5 に本研究で提案された SoC, 加速度センサ(KX022; Kionix, Inc.), NFC 通信 IC, および CR1220 バッテリーを備えたアプリケーションボードを示す。アプリケーションボードのサイズは $23 \times 21 \text{ mm}$ と小さなサイズで実現できた。




図 4-5 Application board of the proposed sensor

4.4.2 提案 SoC の消費電力のシミュレーションによる評価

試作 SoC による電力削減効果を評価するために、試作チップ 10 個の消費電流を実測した。実測時にはサンプリングレートを 32Hz として SoC 内部の ECG sensing Block, ACC I/F 部を除くデジタル部における消費電流を計測した。その結果を以下の表 4-3 に示す。表 4-3 中の Software は加速度にかかわる信号処理をすべて NV-CM0 core で実行した場合の消費電流を示している。表 4-3 中の Processing w/ HW は今回提案したフィルタ回路、および Data bufferSRAM を利用した場合の結果を示す。提案ハードウェアを利用することで消費電流は 85.51%削減できた。

表 4-3 Current consumption of software processing and hardware

	SW [μ A]	Processing w/ HW [μ A]	Current Reduction Ratio [%]
Avg.	19.63	2.85	85.51
Chip.01	20.09	2.53	87.43
Chip.02	19.86	2.96	85.11
Chip.03	19.54	2.72	86.10
Chip.04	19.07	2.41	87.35
Chip.05	19.43	2.26	88.34
Chip.06	19.44	2.77	85.75
Chip.07	18.91	2.76	85.39
Chip.08	19.69	3.12	84.17
Chip.09	20.39	4.19	79.42
Chip.10	19.87	2.78	86.01

次に、サンプリングレートを変更した場合の消費電流についても評価した。サンプリングレート 32Hz を本 SoC における基本サンプリングレート(BSR)として定義し、その半分のサンプリングレート(50%BSR)で動作させた場合の消費電流を測定した。その結果を以下の図 4-6 に示す。SoC 内部のフィルタ回路と Data buffer SRAM を利用した場合の結果である Processig w/ HW ではサンプリングレートを低下させた場合でも消

費電流は BSR と 50%BSR で同程度となっている。これは本章 4.3 節で提案されている 2 つの新たな専用回路構成により CPU の負荷を抑制できたため、CPU のアクティブレートがサンプリングレートに依存しない設計が実現できたためである。

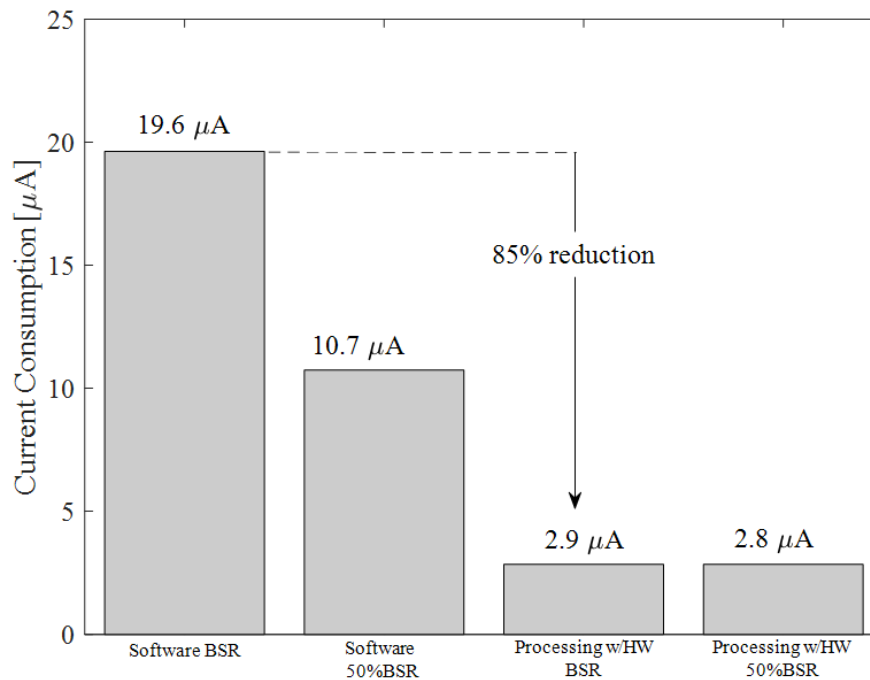


図 4-6 Current consumption of Filetr, memory and CPU

最後に、実使用時のことを想定し、METs 推定システムとして SoC 内部にある ECG sensing Block(Hear Rate)と外部の加速度センサ(Acceleration)の消費電流を加え、ウェアラブルデバイス全体の消費電流をシミュレーション用いて評価した結果を以下の図 4-7 に示す。図中の MCU+MEM は、信号処理ハードウェア、メモリ、および MCU であり SoC 内部のデジタル部の消費電流を示す。Heart Rate は、SoC 内部の ECG sensing block(図 4 1 を参照)の電流消費量を示し、Acceleration は SoC に接続される加速度センサ(KX022)の消費電流を示している。




図 4-7 the comparison with current consumption of wearable device using processing with software and processing with HW

4.5 結言

ウェアラブルデバイスの小型化と低消費電力を実現するための SoC の開発を行った。試作したチップは $4 \times 5 \text{ mm}$ のサイズであり、それを使用したアプリケーションボードは $23 \times 21 \text{ mm}$ で実現でき、ウェアラブルデバイスの小型化ができた。加えて、提案 SoC はフィルタリング処理のハードウェア化、不揮発性メモリの採用などにより、 $2.9 \mu\text{A}$ での動作を達成した。これは従来の信号処理をすべてソフトウェアで行った場合に対して約 85% の削減効果をしめし、ウェアラブルデバイスの低消費電力化に大きく貢献できる SoC の開発ができた。また、本章では METs 推定システムとしての消費電流についても評価した。その結果、加速度信号に対するフィルタリング処理をすべて NV-CM0 上のソフトウェアで実行した場合の消費電流が $42.6 \mu\text{A}$ であるのに対し、SoC 内部に実装されたハードウェアを利用した場合には $25.9 \mu\text{A}$ での動作が可能となり、約 39% の電力削減できた。

第5章 アダプティブサンプリングによる 低消費電力技術の開発

5.1 緒言

本章では、第4章にて開発した SoC を用いたシステムの低消費電力化技術について述べる。

5.2 節では低消費電力技術の重要性とそのアプローチについて説明する。

5.3 節ではアダプティブサンプリングを実現するための方法について説明する。

最後に、5.4 節では、第3章で試作した SoC を用いて本章にて提案する方法での消費電流について評価結果を示す。

5.2 低消費電力化技術の重要性とその取り組み

第2章で述べた通り、ウェアラブルデバイスが抱える課題の一つに長期間の記録の実現に向けての低消費電力化が挙げられる。以下の表に現在発売されている運動習慣をモニタリングするための主要なウェアラブルデバイスの電池寿命について記す。

表 5-1 The battery life of major monitoring PAI devices

battery type	Li-ion (~50 mAh)			SR48W×3 (75 mAh×3)	CR2032 (220 mAh)
	Model	FitBit Charge2[3]	FitBit Flex 2[54]	Jawbone UP4[5]	Misfit RAY[4]
Battery-life	5 days	5 days	7 days	6 months	2 months

このように、Li-ion 電池を使用しているウェアラブルデバイスは一般的に 7 日程度の電池寿命となっている。一方で CR2032 などのコイン型リチウム電池を利用しているものは数か月と比較的長い。しかしながら、コイン電池は使用後は廃棄が必要になることから環境リスクが高いという問題がある。したがって、再充電により繰り返し

利用できる Li-ion 電池を使用することが望ましいが、その場合電池寿命が大きな課題となる。ウェアラブルデバイスの小型化のためにも電池容量の大容量化はできない。したがって、ウェアラブルデバイスの小型化とウェアラブルデバイスの長寿命化を両立させるためにも、システムの低消費電力技術が強く求められている。

5.3 アダプティブサンプリングを用いた行動分類と

METs 推定アルゴリズム

運動習慣を記録するための活動量推定を実行するウェアラブルデバイスの低消費電力化の最も効果的なアプローチはシステム全体のアクティブレートを削減することである。第4章では、信号処理を行う専用回路の集積を行うことでCPUのアクティブレートの低減を実現した。本章では、加速度センサのアクティブレートを下げることによるウェアラブルデバイス全体の低消費電力化方法を提案する。

本節で新たに提案する方法とは、行動の種類に応じて加速度信号のサンプリングレートを適応的に変化させる方法である。以下の図 5-1 に本章で提案する決定木を示す。

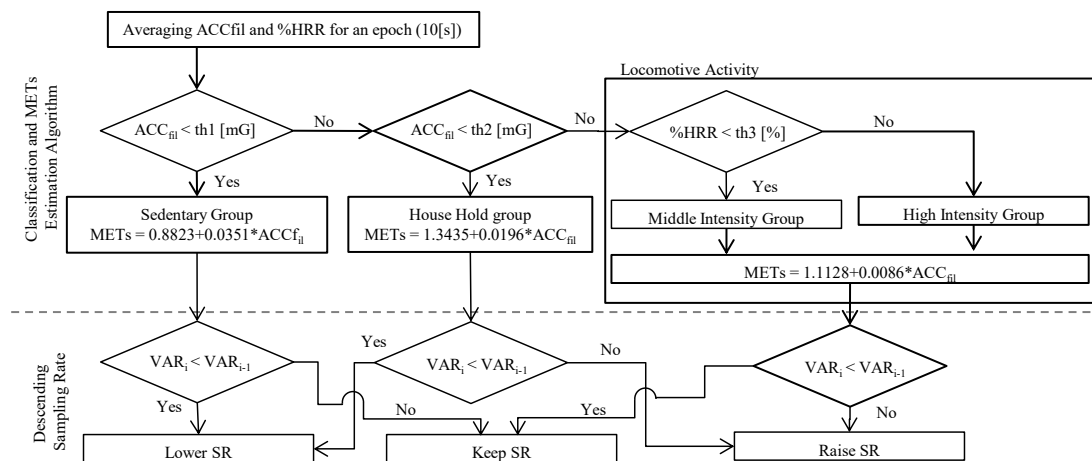


図 5-1 Flow chart of PA classification, METs estimation and deciding sampling rate.

図 5-1 に示されたアルゴリズムのうち、上部が行動分類を実施するアルゴリズム部となる。これは塚原らによる先行研究で提示されたアルゴリズム[56][57]に第3章で述べた%HRRによる行動分類を追加したものである。

第3章で取り上げたような従来の推定システムでは行動の種類によらず、一定のサンプリングレートを使用する[26]。その場合、必ずサンプリングレートに合わせてシステムが動作する。そのため、必要以上にシステム動作が発生している可能性が高い。デスクワークのような行動は加速度の変化も少ないため、低いサンプリングレートでも ACC_{fit} に与える影響が小さい可能性が高い。そこで、本研究では、行動分類と得られた加速度の変化から、サンプリングレートを段階的適応制御(Stepwise Adaptive Controlled Sampling rate, SACS)することで、システム動作を抑制することを考えた。

このアルゴリズムはリアルタイム処理が前提のため行動分類と METs 推定の処理、およびサンプリングレートの決定の処理は一定区間(epoch)ごとに実行される。本研究では、その epoch を 10 sec と定義した。

各 epoch におけるサンプリングレートを決定するために、合成加速度の分散値(VAR)を利用する。VAR が高い行動はその epoch 間での加速度の変化も大きく、高いサンプリングレートで計測すべき行動であると判断できるためである。

図 5-1 に示された決定木に従いサンプリングレートを決定し、それを次の epoch 間で適用する。歩行活動中におけるサンプリングレートを基本サンプリングレートとし、base sampling rate (BSR) として定義する。提案されたサンプリングレートの変化は、その BSR のサンプリングレートの 50%、25%、そして 12.5%から選択される。

5.4 提案アルゴリズムによる METs 推定精度の評価

5.3 節で述べたアダプティブサンプリングを利用することで、加速度センサのアクティビティを下げるができる。本節ではそのサンプリングレートの段階的制御が METs 推定精度へ与える影響を評価する。

5.4.1 臨床試験プロトコル

本研究にて提案されたアルゴリズムの推定精度に対する影響を評価するために、人を対象とした臨床試験を実施した。臨床試験では、8名の成人男性に協力いただいた。本試験はヘルシンキ宣言[47]に示されたガイドラインに従って実施され、本試験の目的および手順に関する詳細は、測定前にすべての被験者に説明され、同意が得られたのちに試験を実施した。

被験者は、Health Patch MD (Vital Connect Inc., San Jose, Ca) を用いて、安静座位状態を含む6つの異なる活動を実施、その活動中の加速度と R-R Interval の計測と記録を行った。本試験は、実施した6つの活動を2つのシーケンスに分けて実施した。以下の表 5-2 に各シーケンスで実施した活動とその動作時間を示す。各活動の間には約1.5分以上の休息時間を設けた。その休息時間には場所を変更するための歩行も含まれている。本試験で実施した活動は Sedetary と Household と Middle Intensity Group (MIG), High Intensity Group (HIG)に分類された。以下の表 5-2 中は各活動がどの行動種類に該当するかを示す。シーケンス 1 は日常生活でのオフィスワークをイメージした行動で構成され、シーケンス 2 はすべて歩行活動で構成されている。

表 5-2 Physical activity list and time of experimental test

	Activity	Physical Activity Group	time [min]
Sequence 1	Sitting (activity as rest)	Sedentary	10
	Operating PC	Sedentary	3
	Cleaning desks	Household	1.5
	Moving Load	Household	1.5
	Stair Ascent	High Intensity Group	1.2
Sequence 2	Walking	Middle Intensity Group	3
	Jogging	High Intensity Group	3

以下の表 5-3 に本試験における行動分類を行うために決定木で使用した閾値を示す。ACC_{fil}の2つの閾値(th1, th2)は、アダプティブサンプリングを検討した先行研究で用いられた閾値と同じ値を利用している[57]。また、%HRR の閾値(th3)は、本試験において分類精度が最も高くなるように決定された。

表 5-3 Threshold for Physical Activity classification

th1 [mG]	th2 [mG]	th3 [%]
29.9	152.6	46

本試験では MIG, HIG の歩行活動中の加速度センサのサンプリングレートを 31.25 Hz (サンプリング時間 32 ms) に設定し、それを Base Sampling Rate (BSR) と定義した。以下の表 5-4 に、第3章の 4.3.3 節で説明された BSR からサンプリングレートを変更した際の影響を低減するための調整係数値を示す。この値をフィルタ内部の遅れ要素

に乗ずることで、サンプリングによる計測波形への影響を最小化する。

表 5-4 Adjustment Coefficient Value for experimental test

Sampling Rate	BSR	Next Sampling Rate [Hz]			
		BSR	50%BSR	25%BSR	12.5%BSR
BSR	1	0.248	0.060	0.016	
50%BSR	4.034	1	0.241	0.063	
25%BSR	16.773	4.157	1	0.261	
12.5%BSR	64.155	15.902	3.825	1	

5.4.2 臨床試験の提案アルゴリズム適用結果

図 5-2 において、サンプリングレートの段階的適応制御(SACS)による処理結果の一例を示す(Prop.). %HRR, ACC_{fil} , 行動分類結果(PA Classification), 加速度センサのサンプリングレートが図 5-2 に示されている. 図中には, 比較のために固定サンプリング(BSR)で処理を行った場合の結果(Prev.)も示した.

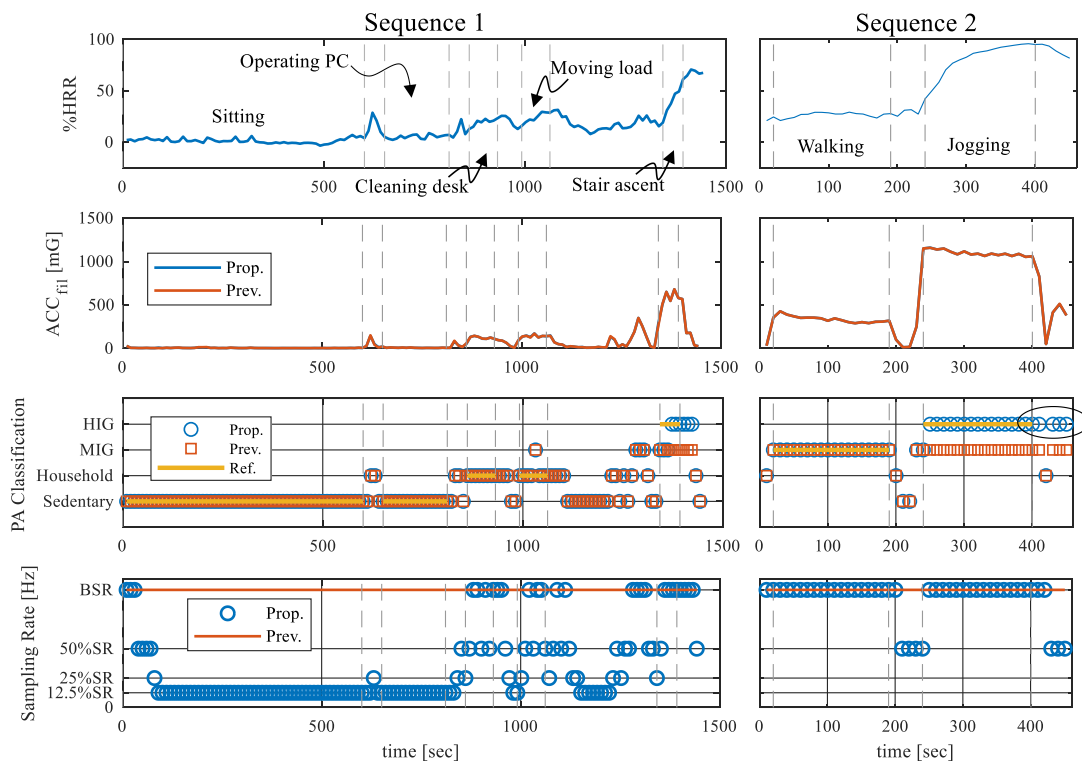


図 5-2 Result of measurement and processed results using proposed algorithm during experimental tests.

図中に示されているすべての行動において、加速度波形の差はほとんど見られずに一致している。Sitting や Operating PC といった Sedentary に分類される行動において、提案アルゴリズムではサンプリングレートが 12.5%BSR にまで低下、その後行動種別が変更となるタイミングでサンプリングレートが上昇していることが確認できる。また、BSR 固定での処理と比較を行った結果として、以下の表 5-5 に固定 BSR による処理を行う従来のアルゴリズム[26]による処理結果に対する提案アルゴリズムの Root Square Mean Error (RMSE)と MeanAbsolute Error (MAE)を示す。RMSE は以下で与えられる式(5.1)で計算された。式中の N は測定したシーケンス内にある epoch の数を示している。

$$\text{RMSE} = \sqrt{\frac{\sum^N (\text{提案アルゴリズムの結果} - \text{BSR 固定の結果})}{N}} \quad (5.1)$$

表 5-5 より、全被験者 8 名の ACC_{fil} における RMSE はシーケンス 1 において最大値が 11.19 mG、平均値は 4.86 mG であった。シーケンス 2 においては、RMSE の最大値は 9.75 mG であり、平均値は 4.92 mG であった。METs における RMSE は、シーケンス 1 における最大値が 0.22 METs、シーケンス 2 における最大値は 0.09METs であった。シーケンス 1, 2 それぞれの平均値は 0.14 METs と 0.04 METs であった。MAE については、シーケンス 1 における最大値が 0.06 METs、シーケンス 2 における最大値は 0.02MET s であった。シーケンス 1 とシーケンス 2 における MAE の平均値はそれぞれ 0.05 METs と 0.01 METs と非常に小さい値であった。これらの結果から実使用上、十分低い値であり、推定精度に対するサンプリングレートを段階的適応制御した影響はないと判断する。

表 5-5 Root Mean Square Error of ACCfil and estimation METs
and Mean Absolute Error of estimation METs

	RMSE of ACC [mG]		RMSE of estimated METs [METs]		MAE of estimated METs [METs]	
	Seq.1	Seq.2	Seq.1	Seq.2	Seq.1	Seq.2
	Sub.01	6.32	2.46	0.07	0.02	0.04
Sub.02	3.08	3.52	0.22	0.03	0.06	0.01
Sub.03	2.78	0.81	0.05	0.01	0.03	0.00
Sub.04	11.19	7.84	0.19	0.07	0.05	0.02
Sub.05	5.95	1.05	0.17	0.02	0.06	0.00
Sub.06	3.66	9.67	0.07	0.09	0.04	0.02
Sub.07	4.17	4.28	0.18	0.04	0.06	0.01
Sub.08	1.69	9.75	0.15	0.08	0.03	0.02
Average	4.86	4.92	0.14	0.04	0.05	0.01
Standard deviations	3.00	3.68	0.06	0.03	0.01	0.01

5.5 提案アルゴリズムを用いた場合の消費電流のシミュレーション評価

5.4 節では、METs 推定精度に大きな影響がないことが確認された。本節では、シミュレーションによって、ウェアラブルデバイスの低消費電力化について評価する。

前節で得られた 8 名の被験者の臨床試験結果に基づき、SACS を用いた場合の消費電流をシミュレーションにて求めた。その消費電流は各シーケンス毎に求められ、各シーケンス間における平均消費電流を以下の図 5-3 に示す。図中の MCU + MEM は、信号処理ハードウェア、メモリ、および MCU であり SoC 内部のデジタル部の消費電流を示す。Heart Rate は、SoC 内部の ECG sensing block(図 4-1 を参照)の電流消費量を示し、Acceleration は SoC に接続される加速度センサ(KX022)の消費電流を示している。また、8 名の被験者それぞれの SACS を用いた場合の平均電流(Prop.)と、従来の固定サンプリングレート(Fixed)での処理に対する割合を以下の表 5-6 に示す。

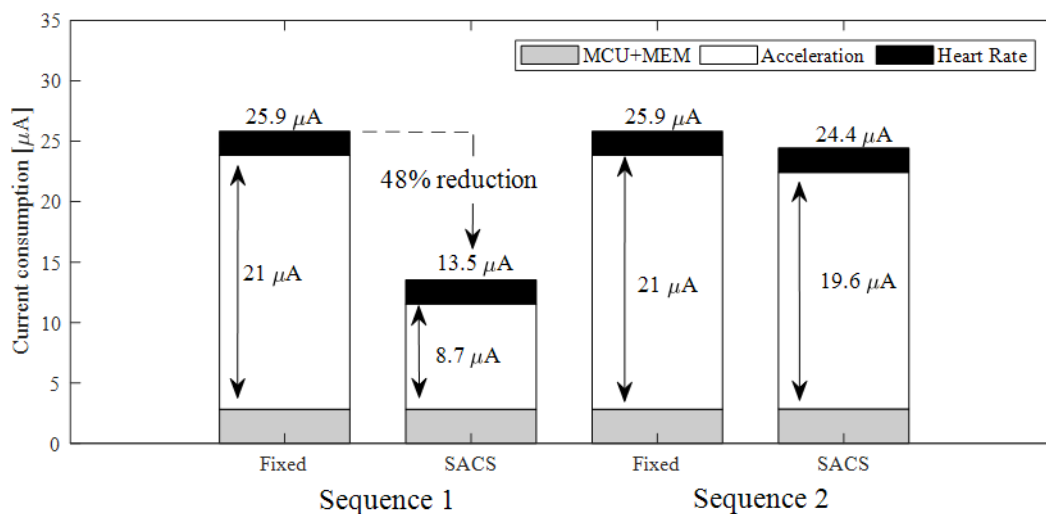


図 5-3 Total current consumption during experimental tests

表 5-6 Results for all subjects on experimental tests

	Seq.01		Sequence2	
	SACS[μA]	ratio of Fixed[%]	SACS [μA]	ratio of Fixed[%]
Sub.01	13.2	51.0	25.2	97.1
Sub.02	13.7	52.9	24.6	95.0
Sub.03	14.1	54.5	24.6	95.0
Sub.04	13.5	52.0	24.0	92.7
Sub.05	12.7	48.9	24.5	94.5
Sub.06	13.7	53.0	23.8	91.7
Sub.07	13.2	51.1	24.2	93.4
Sub.08	14.2	54.8	24.7	95.2
Average	13.5	52.3	24.4	94.3

図 5-3 に示すように、シーケンス 1 および 2 において、本研究で開発した SACS を用いると、Fixed に対してシーケンス 1 では 52.3%、シーケンス 2 では 94.3%の消費電流を達成した。

特に削減効果の大きいシーケンス 1 に注目する。シーケンス 1 では、安静状態に分類される時間がシーケンス内の大部分を占めている。そのため、加速度センサのアクティビティ率が低減、加速度センサの消費電流を $8.7 \mu\text{A}$ へと抑制できた。

本研究で提案、開発したアルゴリズムと SoC を日常生活を想定した場合の消費電流量についてもシミュレーションにて評価した。日常生活における運動の強度とその一日のうちに占める割合について、Healy らの報告結果[58]を利用した。Healy らは、168 人の被験者について運動強度毎の測定時間の結果を報告した。以下の表 5-7 は各行動

と装着時間におけるその行動が占める割合、その時間を示している。本研究では wake-time を Healy らの報告から 15 時間として定義、各行動における時間を求めた。図 5-4 に日常生活で使用した場合のシミュレーション結果を示す。本研究では Vigorous - moderate では歩行活動に該当するとして、該当時間における加速度センサのサンプリングレートを 32Hz としそれを基準サンプリングレート(BSR)と定義した。Light activity の期間では、SACS を用いると、12.5%BSR から 50%BSR の間で変化すると考える。そのため、この時間における加速度センサのサンプリングレートは 25% BSR (8Hz) と設定した。Sedentary 状態は提案アルゴリズムを用いた場合の最低レートである 12.5%BSR (4Hz) であると仮定しシミュレーションを行った。

表 5-7 Spent time of PA for simulation of daily usage

Activity	Explanation	Ratio for wake time [%]	Hours of Activity [h]
Moderate-Vigorous	>3.0METs	4	0.6
Light activity	<3.0METs	39	5.85
Sedentary	Sitting etc...	57	8.55

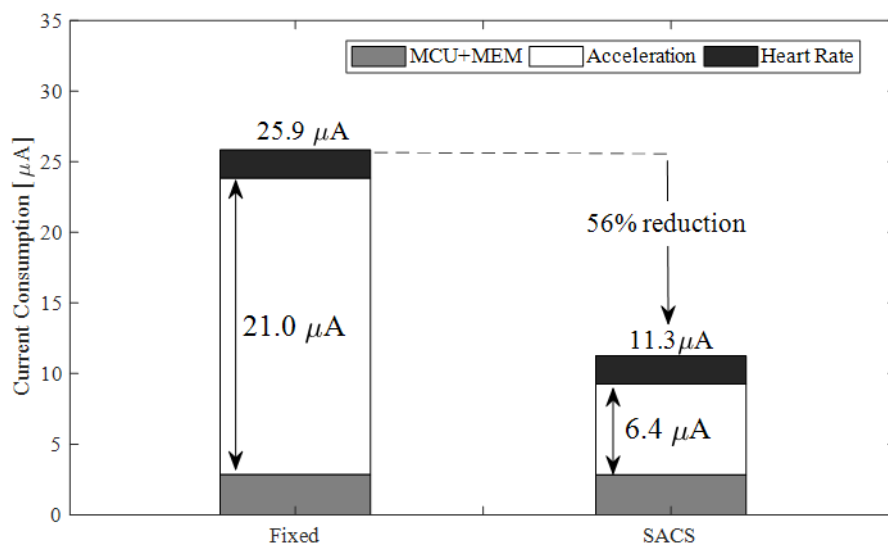


図 5-4 Simulation result of proposed system in daily usage.

従来のサンプリングレートの固定制御(Fixed)では、25.9 μA という結果であった。本研究で提案された SACS を利用することで、その消費電流は 11.3 μA を達成する、これは従来のアルゴリズムに対して約 56%の電力削減効果を示す。これはウェアラブル

ルデバイスで一般的に利用される充電電池である Li-ion 電池の電池容量を 40 mAh とした場合、提案されたシステムは約 144 日間連続して動作することが可能なシステムであることを示す結果であった。

5.6 結言

本章ではサンプリングレートの段階的適応制御と、第 4 章で開発された SoC を組み合わせた低消費電力技術を開発した。サンプリングレートの段階的適応制御(SACS)を用いた場合の推定精度については周波数を固定している場合に対して RMSE で約 0.2 METs であり、推定精度への影響はないことが確認できた。消費電流に関しても、実使用を想定した消費電流について評価、システムとして $11.3 \mu\text{A}$ での動作が可能であり、従来のサンプリングレートの固定制御を行っているものに対して約 56%の消費電流削減を達成した。

第6章

重力加速度の影響を考慮したサンプリングレートの制御方式の開発

6.1 諸言

本研究では、行動分類時に重力加速度の影響を考慮した方法を取り入れた新しいサンプリングレート制御方式を開発する

6.2 節では重力加速度を考慮した行動分類方法について記述する。

6.3 節では新たに提案するサンプリングレートの直接的適応制御方法を記述する。

6.4 節では提案方法の METs 推定精度への影響を検証する。

最後に 6.5 節では低消費電力効果についてアクティブレートをもとに検証した結果を述べる

6.2 重力加速度を考慮した行動分類アルゴリズム

本章で使用する行動分類アルゴリズムは、第3章で述べたアルゴリズムをベースとしている。以下の図 6-1 にその行動分類アルゴリズムの決定木を示す。これは第3章 3.4.3 節内で示されたアルゴリズムのうち、第3章で新たに提案した歩行活動の細分化を行わない決定木である[26]。本章では歩行活動とそれ以外の活動を高精度に分類できるこの方式を採用した。本章ではその方法について説明する。




図 6-1 The decision tree of physical activity classification group

歩行活動とそれ以外を分離する指標として、フィルタリング前後の値の比率(RUF : the ratio unfiltered synthestic acceleration and filtered synthestic acceleration)を使用する。これはフィルタリングを行っていない加速度信号の合成加速度とフィルタリングを行った合成加速度の比率になる。この指標は、第3章の式(3.3)で求められる。これは歩行時とそれ以外の活動時における姿勢の違いから重力加速度成分のセンサ出力への影響が変化するため、その関係を利用している。以下の図6-2に机拭き(Cleaning desk)の活動時と通常速度での歩行(Normal walking)時の姿勢を示す。図中の緑の線は下半身の軸を示し、赤の線は上半身の軸を示している。




図 6-2 (a)机拭きにおける姿勢 (b)歩行時

図6-2(a)の机拭きに代表されるように歩行時以外の行動では大きな姿勢の変化を伴う行動である。その姿勢の変化に合わせて各軸での出力が重力加速度の影響を受けた出力となる。一方で、(b)にあるように歩行時には姿勢の変化がない。重力加速度の影響は一方向のみとなる。そのため歩行時における加速度波形の出力は歩行による加速度変化そのものとなる。

大島らの先行研究[25]において、歩行時以外の活動における重力加速度の影響を除去するため、0.7Hzのカットオフ周波数をもつハイパスフィルタが提案されている。以下の図6-3に机拭きと歩行時における加速度信号の波形を示す。図中の青色の実線がフィルタリング前の信号を、橙色の破線がフィルタリング処理後の信号を示している。

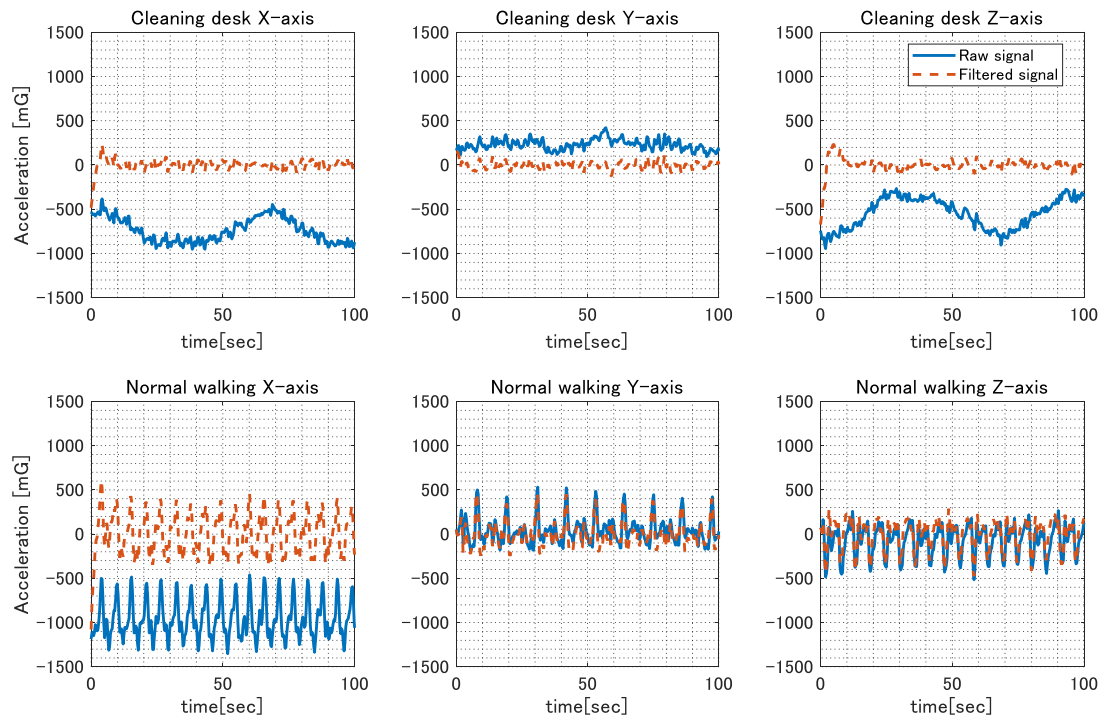


図 6-3 The acceleration signals and filtered signals of each axes in cleaning desk and normal walking

図 6-3 にあるように、机拭き(Cleaning desk)に関してはフィルタ処理を行うと、各軸に現れていた重力加速度の影響が排除され、フィルタ後の加速度信号の振幅が小さくなる。一方で歩行(Normal walk)に関してはフィルタ処理を行っても加速度信号の形状、その大きさには影響がない。したがって、このフィルタ処理前後における加速度信号の比率に大きな差を用いる事で、歩行とそれ以外の行動の分離を行うことができる。

以下に歩行活動とそれ以外の行動時における RUF と METs の関係を示す。歩行活動である Locomotive の集団は RFU=1 付近に集中、生活活動である Household は RFU が 2 以上のところに広く分布していることが確認できる。そのため、第 5 章で使用したような合成加速度の値のみを用いて歩行とそれ以外の行動を分類するものに対して、この比率を用いることでより高精度に歩行活動を他の活動と分類することができる。高精度に分類することが可能になると、より無駄のないサンプリングレートの制御が可能となる。




図 6-4 the relation between RFU and METs

6.3 サンプリングレート制御方式の開発

サンプリングレートの段階的適応制御(SACS)では、サンプリングレートを Base Sampling Rate(BSR)である 32 Hz から 50%, 25%, 12.5%と 4 レベルに段階的に変化させていた。本研究ではこの段階的な変化を不要とし、各活動に応じたサンプリングレートに直接的に変化させることを提案する。以下の図 6-5 は、第 3 章内の臨床試験で記録された 12 の行動における 42 名の被験者の結果を用いて、RUF と ACC_{fi} を 16Hz, 8Hz, 4Hz それぞれで計算、BSR である 32Hz での結果に対する Root Mean Square Error のグラフを示す。16Hz, 8Hz, 4Hz はそれぞれ 32Hz の結果からダウンサンプリングして得られた結果を利用している。

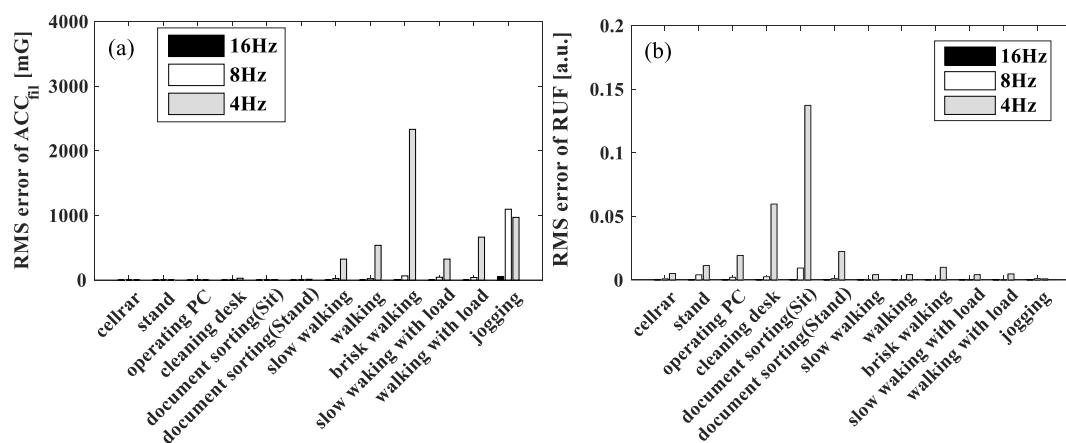


図 6-5 RMS errors compared with 32-Hz fixed FS

RUF についてその影響について評価する. Household に分類される cleaning desk, document sorting sit and stand は 4 Hz や 8 Hz といった低いサンプリングレートで処理を行った場合, RUF の誤差が高くなる傾向がみられた. しかし図 6-1 の決定木から, 分類精度に与える影響はないと判断できる.

次に, ACC_{fil} の結果について確認する. Locomotive に分類される walking (slow, Normal, brisk), walking with Load (slow, Normal), Jogging においては 4 Hz サンプリングではその誤差が大きい. したがって, 本章では歩行活動におけるサンプリングレートは従来と同じ 32 Hz での処理を採用した.

Sedentary と Household においては 4 Hz でのサンプリングが図 6-5 で示された結果から可能であると判断, システムの低消費電力化のために, 4 Hz を採用し, 歩行活動は従来通り 32 Hz での処理を行うとした. 図 6-6 に, サンプリングレートを決定するための決定木を示す. まず, 推定処理区間である epoch ごとに行動分類結果と METs 推定は計算される. EstGroup(n)は, 各区間におけるグループ分類の結果として定義され, Group(n-1), Group(n-2)はそれぞれ 1 epoch 前, 2 epoch 前における行動分類結果を示す. 連続する 3 つの epoch がすべて同じグループに分類される場合, サンプリングレートは Locomotive の場合は 32Hz, Sedentary と household の場合は 4Hz へと変更される.




図 6-6 The Decision tree for adaptive sampling rate

6.4 臨床試験による METs 推定精度への影響の検証

本章で提案したアダプティブサンプリングを用いた行動分類と METs 推定アルゴリズムについて、その精度に対する影響を評価するために、臨床試験を行った。以下ではその試験プロトコル、検証結果について記述する。

6.4.1 臨床試験プロトコル

本章における精度検証のために、第3章で実施した臨床試験の結果を利用した。その測定は、ヘルシンキ宣言[47]のガイドラインに従って行われ、本試験における全ての手順は、国立健康・栄養研究所およびオムロンヘルスケア株式会社の倫理委員会によって承認されたものである。本試験では、実施した23の行動のうち、日常生活に行いやすい行動として12種類の行動を抽出し、その結果を利用した。以下の表 6-1 に本試験で抽出した12種類の行動を示す。

表 6-1 Practiced physical activities and classisified group

Sedentary	Standing, cellular (mobile phone usage), operating a PC
Household	Sorting documents while sitting and standing and cleaning the desk
Locomotive	Walking [slow (55 m/min), normal (70 m/min), brisk (100 m/min)], slow walking with load (5 kg), normal walking with load (3 kg), jogging

本研究では、評価のために、表 6-1 に示す12種類の活動を以下の表 6-2 に示すように2つのシーケンスに分けた。表中のNは測定された被験者数を示す。HealthPatch MDを用いて測定される三軸の加速度信号は、31.25Hzのサンプリングレートに固定され各シーケンスの間連続して記録された。

表 6-2 List of activities in each test sequence

Order	Sequence 1 (N = 31)		Sequence 2 (N = 33)	
	Activity	time [min]	Activity	time [min]
1	Standing	8	Slow walking	5
	Rest	1.5-2	Rest	1.5-2
2	Cellular	7	Normal walking	5
	Rest	1.5-2	Rest	1.5-2
2	Operation of PC	7	Brisk walking	5
	Rest	1.5-2	Rest	1.5-2
4	Sorting documents while sitting	5	Normal walking with load	5
	Rest	1.5-2	Rest	1.5-2
	Sorting documents while standing	5	Slow walking with load	5
5	Rest	1.5-2	Rest	1.5-2
	Cleaning desk	5	Jogging	4

こうして試験で得られた信号に対して、図 6-1 の行動分類アルゴリズムと図 6-6 のサンプリングレートを決定するためのアルゴリズム、そして METs 推定処理を行った。その処理は、MATLAB 2015b (The Math Works Inc.) を用いてオフラインにて行われた。Sedentary と Household の活動で利用される 4 Hz の加速度信号は測定時に記録された 32 Hz の加速度信号からダウンサンプリング処理によって得られた。

6.4.2 周波数制御方法変更による影響の検証

以下に本章にて提案したサンプリングレートの適応的直接制御(Adaptive Direct Controled Sampling rate, ADCS)を用いた結果(Prop.), サンプリングレートの適応的段階制御(SACS)を用いた結果(Prev.), サンプリングレートの固定制御(Fixed)を用いた場合での ACC_{fil} の比較を示す。図 6-7(a) は、シーケンス 1 の測定加速度から算出した結果を示している。提案手法で得られた ACC_{fil} の波形は、Fixed で得られたものとほぼ同じである。図 6-7 (b) は、シーケンス 2 で測定された加速度から計算された結果を示している。提案された方法によって得られた ACC_{fil} は、歩行の開始間隔ごとに小さな誤

差を含んでいることがわかる。これは、歩行活動中または決定木によってサンプリングレートが変化した際に発生しており、歩行活動が 4 Hz のサンプリングレートで処理されたときに発生している。

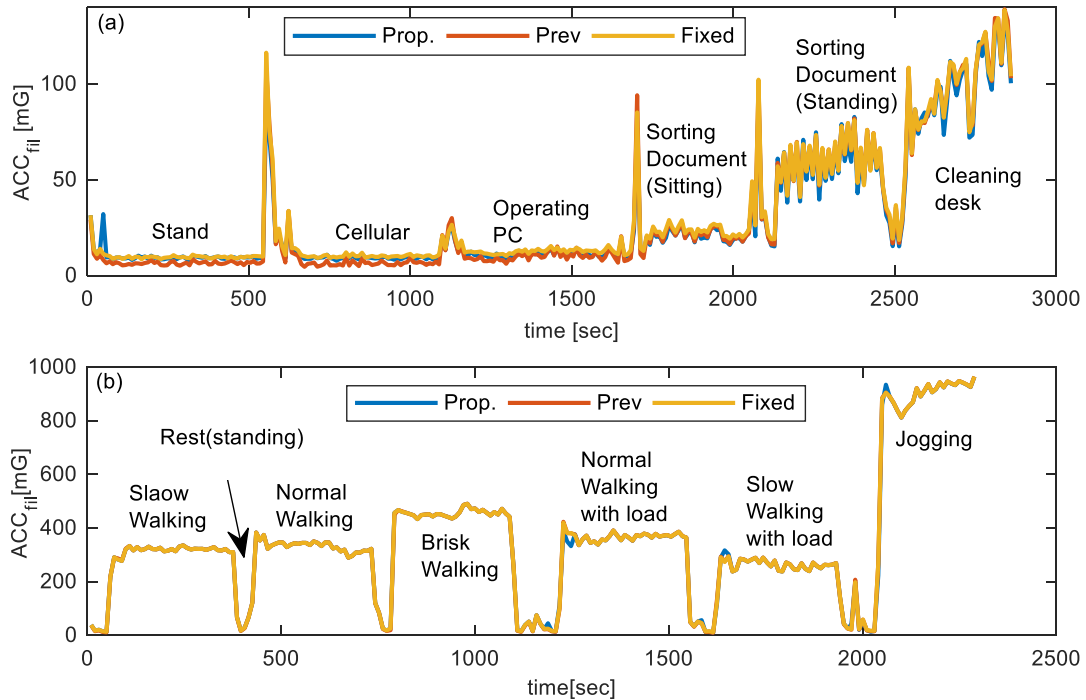


図 6-7 Example of ACC_{fil} calculated from measured accelerations:

(a) Sequence 1 and (b) Sequence 2.

以下の図 6-8 に呼気ガスを用いて測定された METs の基準値に対する、各手法の推定 METs の RMSE(Root Mean Square Error)を示す。DACS を用いた結果(Prop.) と SACS を用いた結果(Prev.), そして Fixed での結果を比較したが、どの行動においても、DACS と Fixed で動作させた場合の結果に大きな差はない。




図 6-8 The Root Mean Square Error for HJA-750C

6.5 アクティブ率による低消費電力化の検証

最後に、DACS を用いた場合の消費電力評価のために、加速度センサのアクティブレートによる評価を行った。第 4 章、第 5 章での結果からわかるように、システムの消費電流は加速度センサの消費電流が支配的になるため、センサのアクティブレートを評価することでシステム全体の評価が行えると判断した。下の表 6-3 に今回のシーケンス 1, 2 における各動作周波数の使用率、加速度センサのアクティブレートとしての平均サンプリングレートとダグラスバックを用いて得られた METs に対する推定 METs との絶対誤差の平均値を示す。

生活活動が多く含まれるシーケンス 1 については、DACS を用いた場合のアクティブレートは 4.5Hz であり、Fixed の 32Hz と比較して約 86%削減、SACS の結果(11.4Hz)と比較しても約 60%削減した。DACS を用いた場合の METs 推定誤差は 0.3 METs 程度であり、それは Fixed の結果と比較しても差はない。

表 6-3 Usage rate of each sampling rate.

		Usage rate [%]				Avg. sampling rate	MAE [METs]
		32-Hz	16-Hz	8-Hz	4-Hz		
Sequence 1	DACS	1.8	--	--	98.2	4.5	0.25
	SACS	15.2	20.6	17.1	47.1	11.4	0.23
	Fixed	100	--	--	--	32	0.28
Sequence 2	DACS	89	--	--	11	28.9	0.65
	SACS	82.6	11.6	5.3	0.5	28.7	0.66
	Fixed	100	--	--	--	32	0.65

また、実使用を想定した低消費電力効果についても検証した。第5章にて提示した日常生活での活動時間(表 5-7)をもとにシステムの平均サンプリングレートを計算した。その結果を以下のに示す。

表 6-4 the average of sampling frequency for daily usage

	Sampling rate setting			Avg. Sampling Frequency [Hz]
	Moderate-Vigorous	Light activity	Sedentary	
Prev	32	8	4	6.68
Prop.	32	4	4	5.12

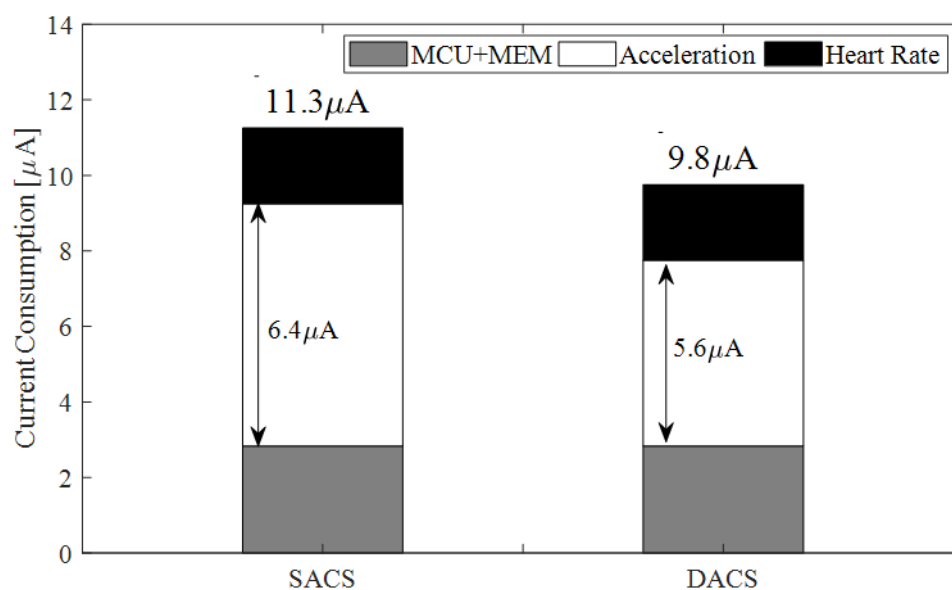


図 6-9 the average sampling frequency for daily usage

DACSはSACSに対して、加速度センサのアクティブレートを約23%の削減できる。SACSを用いた場合のウェアラブルデバイス全体の消費電流の $11.3\ \mu\text{A}$ のうち、加速度センサは約 $6.4\ \mu\text{A}$ を占める。本章の提案を採用するととによって、加速度センサのアクティブレートが低下、結果システム全体としての消費電流が約 $9.8\ \mu\text{A}$ を達成できることが十分期待できる。

6.6 結言

本章では重力加速度を考慮した行動分類と、それに伴ったサンプリングレート制御方式を開発した。生活活動を模した行動群においては、サンプリングレートの段階的適応制御(SACS)に対して、アクティブレートで約60%の削減効果を示した。また、実使用を想定した場合では、加速度センサのアクティブレートを約23%削減することができ、約 $9.8\ \mu\text{A}$ でのシステム動作が見込める制御方式DACCSを開発できた。DACCSは周波数を制御しない場合に比べて、絶対誤差において0.02METs以下であり精度低下を引き起こすものではないことも確認できた。

第7章 結論

本章では本論文の結論を述べる.

第3章 ウェアラブルデバイス向け METs 推定アルゴリズムの開発

身体活動強度データとしての METs, 特に階段上昇を含む日常生活における高強度活動の間における METs を推定することができるアルゴリズムを提案した. その結果, 本章にて提案したモデルは従来モデルの階段上りを含む高強度運動()において, MAPE が 26.5%も小さく, 約 72%改善していることが確認された. また, 階段上昇においては, MAPE で 49.9%小さく, 約 84%改善した. 第3章では階段上昇などの推定が困難な活動を含む, 日常生活の METs 推定精度を向上させるアルゴリズムを開発できた.

第4章 ウェアラブルデバイスの低消費電力化と小型化のための System-on-Chip (SoC)の開発

ウェアラブルデバイスの小型化と低消費電力を実現するための SoC の開発を行った. 試作したチップは 4×5 mm のサイズであり, それを使用したアプリケーションボードは 23×21 mm で実現でき, ウェアラブルデバイスの小型化ができた. 加えて, 提案 SoC はフィルタリング処理のハードウェア化, 不揮発性メモリの採用などにより, $2.9 \mu A$ での動作を達成した. これは従来の信号処理をすべてソフトウェアで行った場合に対して約 85%の削減, ウェアラブルデバイスの低消費電力化に大きく貢献できる SoC の開発ができた. また, ウェアラブルデバイス全体を想定した消費電流についても評価した. その結果, 加速度信号にかかわる信号処理をすべてソフトウェアで実行した場合の消費電流が $42.6 \mu A$ であるのに対し, SoC 内部に実装されたハードウェアを利用した場合には $25.9 \mu A$ での動作が可能となり, 約 39%の電力削減効果が確認できた.

第5章 アダプティブサンプリングによる低消費電力技術の開発

サンプリングレートの適応的段階制御(SACS)と, 第4章で開発した SoC を組み合わせた低消費電力技術を開発した. SACS を用いた場合の推定精度については周波数を固定している場合に対して RMSE で 0.2 METs であり, 推定精度への影響はない. 消費電流に関しても, 実使用を想定した場合について評価し, システムとして約 $11.3 \mu A$

での動作が可能であり、従来のサンプリングレートを固定で処理しているものに対して約 56%の改善効果であることが確認できた。

第6章 重力加速度の影響を考慮したサンプリングレート制御方式の開発

重力加速度を考慮した行動分類と、それに伴ったサンプリングレートの直接的適応制御(DACS)を開発した。生活活動を模した行動群においては、SACSに対して、約60%の削減効果を示した。また、実使用を想定した場合では、加速度センサのアクティブレートを約23%削減することができ、約9.8 μA でのウェアラブルデバイスの動作が見込める新たな制御方式を開発した。DACsを用いた場合は周波数を固定制御する場合に比べて、絶対誤差において0.02 METs以下であり精度低下はなかった。

本論文では、現状のウェアラブルデバイスが抱えている課題である推定精度の向上とウェアラブルデバイスの小型化と長期間の連続動作の両立を可能とする低消費電力技術の開発を通じて、ウェアラブル応用可能な活動量推定デバイスの高精度化および低消費電力化技術を確立できた。

謝辞

本論文は、筆者が神戸大学大学院情報科学専攻プロセッサアーキテクチャ研究室において行った研究成果をまとめたものである。

本研究室への参加のきっかけを与えていただき、また4年間にわたる研究室生活において企業での豊富な経験に裏付けられた懇到なご指導を賜りました、神戸大学大学院システム情報学研究科教授 吉本雅彦先生に、心から感謝いたします。

研究活動において様々な鋭いご指摘、貴重なご意見を頂きました神戸大学大学院システム情報学研究科准教授 川口博先生に深く感謝いたします。

本論文及び本研究に対して貴重なご助言を賜った神戸大学大学院システム情報学研究科教授 永田真先生、神戸大学大学院システム情報学研究科教授 太田 能先生、神戸大学大学院システム情報学研究科教授 熊本悦子先生、大学大学院システム情報学研究科准教授 三浦 典之先生に深く感謝の意を表します。

入学時より在学中、様々な場面において豊富な知識による鋭い指摘、懇切な助言・ご指導を頂きました、神戸大学大学院システム情報学研究科助教 和泉慎太郎先生に心から感謝いたします。

本研究へのきっかけと貴重な経験を与えていただき、また4年間にわたる研究室生活において豊富な経験に裏付けられた、鋭い指摘・ご助言をいただきましたオムロンヘルスケア株式会社 執行役員常務 田中孝英様、専門職 志賀利一様に深く感謝します。

本研究内で試作したチップの開発・試作におき多大なるご協力をいただきましたローム株式会社、藤森 義一様、木村 博光様、渕上 貴明様、丸山 恭二様に心より感謝をいたします。

本論文内におけるアルゴリズム開発、臨床試験において豊富な経験をもとにご助言くださりました、国立栄養研究所 田中茂穂室長、安藤貴文博士、中江健司博士、薄井千代子博士、青山友子博士に深く感謝いたします。

また、同じWINEプロジェクトに所属し、多大なるご協力をいただきました、中井陽三郎氏、正木何奈氏、児玉泰佑氏、松永大地氏、塚原美緒氏、中村亮太氏、永里祐樹氏、岡野孝昭氏、勝浦巧氏に深く感謝いたします。

国際学会発表の際に英語のプレゼンテーションの指導をしていただいた月野光先生に深く感謝の意を表します。

博士後期課程在学中、未熟な私にご助力くださった梅木洋平氏、松川豪氏、森陽紀氏に心から感謝いたします。

本論文の第4章でのLSIチップ試作はNEDO、および科研費を通じて、ローム株式会社の協力で行われたものです。

本研究は、ここで名前を挙げるができなかった大学や企業など他にも多くの方々のご指導、ご協力のもとに完遂されたものであり、ここに謹んで感謝の意を表します。

最後に私をここまで育ててくださいました両親と私を支えてくださった妻に心より感謝を致します。

著者の研究業績目録

A. 学会誌論文 (筆頭論文, 査読有)

1. Motofumi Nakanishi, Shintaro Izumi, Sho Nagayoshi, Hiroshi Kawaguchi, Masahiko Yoshimoto, Toshikazu Shiga, Takafumi Ando, Satoshi Nakae, Chiyoko Usui, Tomoko Aoyama and Shigeho Tanaka, “Estimating Metabolic Equivalents during Activities in Daily Life using Acceleration and Heart Rate for Wearable Devices”, BioMedical Engineering OnLine, (投稿中)
2. M. Nakanishi, S. Izumi, M. Tsukahara, H. Kawaguchi, H. Kimura, K. Marumoto, T. Fuchikami, Y. Fujimori, M. Yoshimoto, "A 11.3- μ A Physical Activity Monitoring System Using Acceleration and Heart Rate," IEICE Trans. Electron., Vol.E101-C, No.4, pp.233-242, Apr. 2018

B. 国際会議(筆頭論文, 査読有)

1. Motofumi Nakanishi, Shintaro Izumi, Mio Tsukahara, Hiroshi Kawaguchi, Masahiko Yoshimoto, “A Metabolic Equivalents Estimation Algorithm using Triaxial Accelerometer and Adaptive Sampling for Wearable Devices” The 1st IEEE Life Sciences Conference, Sydney, Australia, 13-15 Dec 2017
2. Motofumi Nakanishi, Shintaro Izumi, Sho Nagayoshi, Hironori Sato, Hiroshi Kawaguchi, Masahiko Yoshimoto, Takafumi Ando, Satoshi Nakae, Chiyoko Usui, Tomoko Aoyama, Shigeho Tanaka, “Physical Activity Group Classification Algorithm using Triaxial Acceleration and Heart Rate,” 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society(EMBC), pp.510-513 , Aug.2015.

C. 本研究に関するその他の学会論文(共著)

D. 本研究に関するその他の国際会議(共著)

1. Mio Tsukahara, Shintaro Izumi, Motofumi Nakanishi, Hiroshi Kawaguchi, Hiromitsu Kimura, Kyoji Marumoto, Takaaki Fuchikami, Yoshikazu Fujimori, and Masahiko Yoshimoto, “A 19- μ A Metabolic Equivalents Monitoring SoC Using Adaptive Sampling,”

IEEE Asia and South Pacific Design Automation Conference (ASP-DAC) University LSI Design Contest, pp. 37-38, Jan. 2017.

2. Mio Tsukahara, Shintaro Izumi, Motofumi Nakanishi, Hiroshi Kawaguchi, Hiromitsu Kimura, Kyoji Marumoto, Takaaki Fuchikami, Yoshikazu Fujimori, and Masahiko Yoshimoto, “A 15-uA Metabolic Equivalent Monitoring System using Adaptive Acceleration Sampling and Normally Off Computing,” IEEE International Conference on Electronics, Circuits, and Systems (ICECS), pp.61-64, Dec. 2016.
3. Mio Tsukahara, Motofumi Nakanishi, Shintaro Izumi, Yozaburo Nakai, Hiroshi Kawaguchi, and Masahiko Yoshimoto, “Low-Power Metabolic Equivalent Estimation Algorithm Using Adaptive Acceleration Sampling,” 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society(EMBC), Aug. 2016.

E. 本研究に関するその他の発表(査読無)

参考文献

- [1] 厚生労働省ホームページ, 平成 27 年度 国民医療費の概況, 厚生労働省,
<http://www.mhlw.go.jp/toukei/saikin/hw/k-iryohi/15/index.html>
- [2] Coleman, K.L.; Smith, D.G.; Bone, D.A.; Joseph, A.W.; del Agulia, M.A. Step activity monitor: long term, continuous recording of ambulatory function. *J. Rehabil. Res. Dev.* 1999, 36, 8–18. doi:10.1515/bmt-2017-0104
- [3] Fitbit Charge 2, <https://www.fitbit.com/charge2>
- [4] Misfit RAY, <http://jp.misfit.com/products/ray/>
- [5] JAWBONE UP4, <https://jawbone.com/fitness-tracker/up4><https://jawbone.com/>
- [6] Silmee W10,
https://product.tdk.com/info/ja/products/biosensor/biosensor/silmee_w10/index.html
- [7] 総務省ホームページ, 情報通信白書平成 28 年度版, 総務省
<http://www.soumu.go.jp/johotsusintokei/whitepaper/ja/h28/html/nc131410.html>
- [8] Apple watch series 3, <https://www.apple.com/jp/watch/>
- [9] Galaxy Gear S2, <http://www.samsung.com/global/galaxy/gear-s2/>
- [10] HJA-750C, <http://www.healthcare.omron.co.jp/product/hja/hja-750c.html>
- [11] Kurebayashi, Yusuke, and Junichi Otaki. "Association between altered physical activity and neurocognitive function among people with schizophrenia: A minimum 6-months' follow-up study." *Comprehensive Psychiatry* (2017).
- [12] 笹井浩行, 引原有輝, 岡崎勘造, 中田由夫, 大河原一憲, "加速度計による活動量評価と身体活動増進介入への活用." *RESEACH EXERCISE EPIDEMIOLOGY —運動疫学研究* (2015): 17-1
- [13] Kurebayashi, Yusuke, and Junichi Otaki. "Correlations between physical activity and neurocognitive domain functions in patients with schizophrenia: a cross-sectional study." *BMC psychiatry* 17.1 (2017): 4
- [14] Barrett, Paddy M., et al. "Comparison of 24-hour Holter monitoring with 14-day novel adhesive patch electrocardiographic monitoring." *The American journal of medicine* 127.1 (2014): 95-e11

- [15] Bassett Jr, David R., Ann V. Rowlands, and Stewart G. Trost. "Calibration and validation of wearable monitors." *Medicine and science in sports and exercise* 44.1 Suppl 1 (2012): S32.
- [16] Murakami, Haruka, et al. "Accuracy of wearable devices for estimating total energy expenditure: comparison with metabolic chamber and doubly labeled water method." *JAMA internal medicine* 176.5 (2016): 702-703.
- [17] 厚生労働省ホームページ, 健康づくりのための身体活動基準2013」及び「健康づくりのための身体活動指針（アクティブガイド）」について, <http://www.mhlw.go.jp/stf/houdou/2r9852000002xple.html>
- [18] American College of Sports Medicine, General principles of exercise prescription. In *ACSM Guidelines for Exercise Testing and Prescription*, Tenth ed., Baltimore: Philadelphia, 2017, pp. 143–179. 1609139550
- [19] Weir, J.B. New methods for calculating metabolic rate with special reference to protein metabolism. *J. Physiol.* 1949, 109, 1–9.
- [20] Khan, A.M.; Lee, Y.-K.; Lee, S.Y.; Kim, T.-S. A triaxial accelerometer-based physical-activity recognition via augmented-signal features and a hierarchical recognizer. *IEEE Trans. Inf. Technol. in Biomed.* 2010, 14(5), 1166–1172. doi:10.1109/titb.2010.2051955
- [21] Bassett, D.R.; Ainsworth, B.E.; Swartz, A.M.; Strath, S.J.; O'Brien, W.L.; King, G.A. Validity of four motion sensors in measuring moderate intensity physical activity. *Med. Sci. Sports Exerc.* 2000, 32, S471–S480. doi: 10.1097/00005768-200009001-00006
- [22] Matthews, C.E. Calibration of accelerometer output for adults. *Med. Sci. Sports Exerc.* 2005, 37, S512–S522.
- [23] Welk, G.J.; Blair, S.N.; Wood, K.; Thompson, R.N. A comparative evaluation of three accelerometry-based physical activity monitors. *Med. Sci. Sports Exerc.* 2000, 32, S489–S497. doi: 10.1249/01.mss.0000185659.11982.3d
- [24] DeGonzalo, R.; Celks, P.; Renevey, P.; Dasen, S.; Solà, J.; Bertschi, M.; Lemay, M. Physical activity profiling: activity-specific step counting and energy expenditure models using 3D wrist acceleration. in *Proc. IEEE Eng. Med. Biol. Soc.*, in Milan, Italy, Aug. 2015, pp. 8091–8094. doi: 10.1109/embc.2015.7320271

- [25] Oshima, Y.; Kawaguchi, K.; Tanaka, S.; Ohkawara, K.; Hikiyama, Y.; Ishikawa-Takata, K.; Tabata, I. Classifying household and locomotive activities using a triaxial accelerometer. *Gait Posture* 2010, 31, 370–374. doi: 10.1016/j.gaitpost.2010.01.005
- [26] Ohkawara, K.; Oshima, Y.; Hikiyama, Y.; Ishikawa-Takata, K.; Tabata, I.; Tanaka, S. Real-time estimation of daily physical activity intensity by a triaxial accelerometer and a gravity-removal classification algorithm. *Br. J. Nutr.* 2011, 105, 1681–1691.
- [27] Cvetković, B.; Milić, R.; Luštrek, M. Estimating energy expenditure with multiple models using different wearable sensors. *IEEE J. Biomed. Health Informatics*. 2016, 20(4), 1081–108. doi: doi.org/10.1109/jbhi.2015.2432911
- [28] Luštrek, M.; Cvetković, B.; Kozina, S. Energy expenditure estimation with wearable accelerometers. *IEEE International Symposium Circuits and Systems (ISCAS)*, Seoul, South Korea, 20-23 May. 2012, pp. 5–8. doi: 10.1109/iscas.2012.6271906
- [29] Gjoreski, H.; Kaluža, B.; Gams, M.; Milić, R.; Luštrek, M. Context-based ensemble method for human energy expenditure estimation. *Appl. Soft Comput.* 2015, 37, 960–970. doi: 10.1016/j.asoc.2015.05.001
- [30] Liu, S.; Gao, R. X.; John, D.; Staudenmayer, J. W.; Freedson, P.S. Multisensor data fusion for physical activity assessment. *IEEE Trans. Biomed. Engineer.* 2012, 59, 687–696. doi: 10.1109/tbme.2011.2178070
- [31] Lin, C. W.; Yang, Y. T. C.; Wang, J. S.; Yang, Y. C. A wearable sensor module with a neural-network-based activity classification algorithm for daily energy expenditure estimation. *IEEE Trans. Inform. Tech. Biomed.* 2012, 16, 991–998. doi: 10.1109/titb.2012.2206602
- [32] Crouter, S.E.; Clowers, K.G.; Bassett, D.R. Jr. A novel method for using accelerometer data to predict energy expenditure, *J. Appl. Physiol.* 2006, 100, 1324–1331. doi: 10.1152/jappphysiol.00818.2005
- [33] Raj, A.; Subramanya, A.; Fox, D.; Bilmes, J. Rao-Blackwellized particle filters for recognizing activities and spatial context from wearable sensors. *Experimental Robotics*. Springer Berlin/Heidelberg. 2008, pp. 211-221. doi: 10.1007/978-3-540-77457-0_20
- [34] Minnen, D.; Westeyn, T.; Ashbrook, D.; Presti, P.; Starner, T. Recognizing soldier activities in the field. *4th International Workshop on Wearable and Implantable Body*

- Sensor Networks. Springer Berlin Heidelberg. 2007, pp. 236–241.
- [35] Ohtaki, Y.; Susumago, M.; Suzuki, A.; Sagawa, K.; Nagatomi, R.; Inooka, H. Automatic classification of ambulatory movements and evaluation of energy consumptions utilizing accelerometers and a barometer. *Microsyst. Technol.* 2005, 11, 1034–1040. doi: 10.1007/s00542-005-0502-z
- [36] Volen, M.; Redmond, S.J.; Cerutti, S.; Lovell, N.H. Energy expenditure estimation using triaxial accelerometry and barometric pressure measurement. 32nd Annual International Conf. of the IEEE EMBS, Buenos Aires, Argentina, 31 August–6 September, 2010, pp. 5185–5188. doi: 10.1109/iembs.2010.5626271
- [37] Yamazaki, T.; Gen-no, N.; H.; Kamijo, Y.; Okazaki, K.; Masuki, S.; Nose, H. A new device to estimate VO₂ during incline walking by accelerometry and barometry. *Med. Sci. Sports Exerc.* 2009, 41(12), 2213–2219. doi: 10.1249/MSS.0b013e3181a9c452
- [38] Crouter, S.E.; Churilla, J.R.; Basset, D.R. Jr. Accuracy of the Actiheart for the assessment of energy expenditure in adults. *Eur. J. Clin. Nutr.* 2008, 62, 704–711. doi: 10.1038/sj.ejcn.1602766
- [39] Li, R.; Deurenberg, P.; Hautvast, J. G. A critical evaluation of heart rate monitoring to assess energy expenditure in individuals. *Am. J. Clin. Nutr.* 1993, 58, 602–607.
- [40] Izumi, S.; Yamashita, K.; Nakano, M.; Yoshimoto, S.; Nakagawa, T.; Nakai, Y.; Kawaguchi, H.; Kimura, H.; Marumoto, K.; Fuchigami, T.; Fujimori, Y.; Nakajima, H.; Shiga, T.; Yoshimoto, M. Normally off ECG SoC With non-volatile MCU and noise tolerant heartbeat detector. *IEEE Trans. Biomed. Circuits Syst.* 2015, 9, 641–651. doi: 10.1109/tbcas.2015.2452906
- [41] Zhang, X.; Lian, Y. A 300-mV 220-nW event-driven ADC with real-time QRS detection for wearable ECG sensors. *IEEE Trans. Biomed. Circuits Syst.* 2015, 8, 834–843. doi: 10.1109/tbcas.2013.2296942
- [42] Jain, S.K.; Bhaumik, B. An ultra low power ECG signal processor design for cardiovascular disease detection. in Proc. IEEE Eng. Med. Biol. Soc., in Milan, Italy, 25–29 Aug. 2015, pp. 8091–8094. doi: 10.1109/embc.2015.7318497
- [43] H. Kim, R. F. Yazicioglu, T. Torfs, P. Merken, H. J. Yoo, and C. V. Hoof, “A low Power ECG Signal Processor for Ambulatory Arrhythmia Monitoring System,” *VLSI Circuits*

- (VLSIC) 2012 Symposium on IEEE, pp.19–20, June 2012
- [44] Hsu, S-Y.; Ho, Y.; Tseng, Y.; Lin, T-Y.; Chang, P-Y.; Lee, J-W.; Hsiao, J-H.; Chuang, S-M.; Yang, T-Z.; Liu, P-C.; Yang, T-F.; Chen, R-J.; Su, C.; and Lee, C-Y. “A Sub-100 μ W Multi-Functional Cardiac Signal Processor for Mobile Healthcare Applications,” VLSI Circuits (VLSIC), 2012 Symposium on. IEEE, pp.156–157, June 2012.
- [45] Carvalho, V.O.; Guimarães GV, Bocchi EA. The relationship between heart rate reserve and oxygen uptake reserve in heart failure patients on optimized and non-optimized beta-blocker therapy. *Clinics*, 2008, 63, 725–730. doi: 10.1590/s1807-59322008000600003
- [46] Nakanishi, M.; Izumi, S.; Nagayoshi, S.; Sato, H.; Kawaguchi, H.; Yoshimoto, M.; Ando, T.; Nakae, A.; Usui, C.; Aoyama, T.; Tanaka, S. Physical activity group classification algorithm using triaxial acceleration and heart rate. in Proc. IEEE Eng. Med. Biol. Soc., Milan, Italy, 25-29 Aug. 2015, pp. 510–513. doi: 10.1109/embc.2015.7318411
- [47] “WORLD MEDICAL ASSOCIATION DECLARATION OF HELSINKI Ethical Principles for Medical Research Involving Human Subjects” Adopted by the 18th WMA General Assembly, Helsinki, Finland, June 1964,
- [48] Chan, A.M.; Selvaraj, N.; Ferdosi, N.; Narasimhan, R. Wireless patch sensor for remote monitoring of heart rate, respiration, activity and falls. In Proc. IEEE Eng Med. Biol. Soc. Osaka, Japan, 3-7 July. 2013, pp. 6115–6118. doi: 10.1109/embc.2013.6610948
- [49] American College of Sports Medicine, Benefits and risks associated with physical activity. In ACSM Guidelines for Exercise Testing and Prescription, Tenth ed., Baltimore: Philadelphia, 2017, pp. 1–21, 1609139550
- [50] Whyte, G.P.; George, K.; Shave, R.; Middleton, N.; Nevill, A.M. Training induced changes in maximum heart rate. *Int. J. Sports Med.* 2008, 29, 129–133. doi: 10.1055/s-2007-965783
- [51] Wang, J.; Redmond, S.J.; Voleno, M.; Narayanan, M.R.; Wang, N.; Cerutti, S.; Lovell, N.H. Energy expenditure estimation during normal ambulation using triaxial accelerometry and barometric pressure. *Physiol. Meas.* 2012, 33, 1811–1830.

- [52] <http://www.nordicsemi.com/eng/Products>
- [53] <https://www.qualcomm.com/products/snapdragon>
- [54] <https://www.fitbit.com/us/flex2>
- [55] <https://www.healthcare.omron.co.jp/medical/products/HJA-750C/index.html>
- [56] M. Tsukahara, M. Nakanishi, S. Izumi, H. Kawaguchi, and M. Yoshimoto, “Low-power metabolic equivalents estimation algorithm using adaptive acceleration sampling,” Proc. of IEEE EMBC, pp.1878–1881, Aug. 2016.
- [57] M. Tsukahara, S. Izumi, M. Nakanishi, H. Kawaguchi, M. Yoshimoto, H. Kimura, K. Marumoto, T. Fuchikami, and Y. Fujimori, “A 15-[μ A] metabolic equivalents monitoring system using adaptive acceleration sampling and normally off computing,” Proc. of IEEE ICECS, pp.61–64, 2016.
- [58] G. N. Healy, D. W. Dunstan, J. Salmon, E. Cerin, J. E. Shaw, P. Z. Zimmet, and N. Owen, “Breaks in sedentary time,” Diabetes Care, vol.31, no.4, pp.661–666, Apr 2008.

神戸大学博士論文「ウェアラブル活動量推定デバイスの高精度化および低消費電力化に関する研究」全 88 頁 提出日 2018 年 7 月 13 日 本博士論文が神戸大学機関リポジトリ **Kernel** にて掲載される場合、掲載登録日（公開日）はリポジトリの該当 ページ上に掲載されます。© 著者氏名 本論文の内容の一部あるいは全部を無断で複製・転載・翻訳することを禁じます。