

修士論文

高齢者のQOL向上のための生体・活動指標を用いたストレス予測・行動変容システムの提案と評価

松本 敢大

奈良先端科学技術大学院大学

先端科学技術研究科

情報理工学プログラム

主指導教員: 安本 慶一

ユビキタスコンピューティングシステム 研究室 (情報科学領域)

令和5年1月31日提出

本論文は奈良先端科学技術大学院大学先端科学技術研究科に
修士(工学)授与の要件として提出した修士論文である。

松本 敢大

審査委員：

主査 安本 慶一 (情報科学領域 教授)

金谷 重彦 (情報科学領域 教授)

諏訪 博彦 (情報科学領域 准教授)

高齢者のQOL向上のための生体・活動指標を用いたストレス予測・行動変容システムの提案と評価*

松本 敢大

内容梗概

世界的に高齢者の人口比率が急速に高まっており、世界は高齢化社会となっている。そのため、高齢者福祉のための効果的な対策が求められている。高齢者福祉を推進するためには、高齢者自身が日常生活を理解し、健康状態を自ら管理できるような環境をつくり、高齢者のQOLを向上させることが必要である。高齢者のQOLを向上させるためには、高齢者のストレス状態を推定することが不可欠である。ストレス状態は、実施した行動やその時間・ストレス強度によって、毎日・毎時間変化する。しかし、既存の研究の多くは、生体情報や特定の行動（睡眠時間、運動時間・量など）のみを説明変数としてストレス状態を推定しており、日常生活行動すべてを考慮しているわけではない。そのため、家庭での生活を考慮し、ストレスの原因となる日常生活行動の把握と、高齢者自身が自宅での日常生活を理解し、健康状態を自ら管理できるような環境づくりを目標とする。本研究では、朝夕に取得したストレス状況質問票の回答を正解値とし、各家庭内行動時の生体情報および生体的観点と活動的観点を含む新規提案指標を特徴量として、機械学習によるストレス推定モデルを構築する手法と、ストレス推定手法の結果をフィードバックし行動変容を促す健康状態管理システムを提案する。ストレス推定手法は、データセットとして日常生活行動センシングシステムで取得できる日常生活行動データとスマートウォッチで取得できる心拍データ（生体情報）を使用する。特徴量抽出では、心拍データから計算できるストレス指標としてRRIとローレンツプロット面積を使用した。健康状態管理システムは、日常生活の任

*奈良先端科学技術大学院大学 先端科学技術研究科 修士論文, 令和5年1月31日.

意のタイミングで高齢者へ健康状態予測の結果をフィードバックすることで、行動変容を促し自ら健康状態管理を行えるようにすることを要件としている。この要件を実現するために、健康状態管理システムに3つの機能を実装する。(1) ストレス予測機能、(2) 実施済・実施予定の生活行動を入力する機能と予測に用いる特徴量を生成する機能、(3) (1)で予測したストレスをフィードバックする機能を実装した。本研究では、これらの機能を搭載することで行動変容を促す健康状態管理 Web アプリケーションを Flask で開発した。健康状態管理システムにおいて、被験者は悪い予測結果（ストレスが高くなる）がフィードバックされた時は、ストレスの原因となっている行動群を確認し、予測ストレスが低くなるように実施予定の行動を変化させるような行動変容を促す。ストレス推定手法の評価実験として、高齢者5世帯のそれぞれ1ヶ月間のデータを用いて、起床後4時間とアンケート回答前24時間のRRI分散とローレンツプロット面積を特徴量とするベースライン手法1、ベースライン手法1に睡眠時間を特徴量として加えたベースライン手法2、行動ごとのローレンツプロット面積と行動ごとの総時間、そして、新規指標を特徴量として加えた提案手法と比較した。提案手法の平均推定精度は59%となり、ベースライン手法1の52%、ベースライン手法2の55%よりも良好であった。また、開発した健康状態管理システムの有効性を評価するため、12名の被験者に、2日間の予備実験と5日間の本実験の合計7日間の評価実験を行った。評価実験では、5段階のリッカートスケールで体調とアプリの使用感の評価、アノテーションアプリで被験者の行動時間を取得した。結果として、提案システムの使用前と使用後で体調が平均2.08ポイントから1.33ポイントに改善された（低いほど体調は良い）。また、使用前と使用後の入浴時間が1.48倍、食事時間が1.52倍となった。これにより、アプリを使用する事で体調が改善される可能性、行動変容を促す可能性、さらに健康には入浴時間と食事時間が関わる可能性が示唆された。

キーワード

QOL；機械学習；ストレス予測；行動変容

Design and Evaluation of Stress Estimation Method Using Biometric and Activity Indicators and Health Status Management System to Improve QOL of the Elderly*

Kanta Matsumoto

Abstract

The proportion of the elderly population is rapidly increasing worldwide, and the world is becoming an aging society. Therefore, effective measures for the welfare of the elderly are required. In order to promote the welfare of the elderly, it is necessary to create an environment in which the elderly themselves understand their daily lives and can manage their own health conditions, thereby improving their quality of life. To improve the QOL of the elderly, it is essential to estimate their stress state. The stress state changes daily and hourly, depending on the action taken, its duration, and the intensity of the stress. However, most of the existing studies estimate the stress state using only biometric information and specific activities (e.g., sleeping time, duration and amount of exercise) as explanatory variables and do not consider all daily life activities. Therefore, we aim to understand the daily activities that cause stress and to create an environment in which the elderly themselves can understand their daily life at home and manage their own health condition, considering their home life. In this study, we propose a method to construct a stress estimation model by machine learning, using the answers to a stress questionnaire taken in the morning and evening as the

*Master's Thesis, Graduate School of Science and Technology, Nara Institute of Science and Technology, January 31, 2023.

correct answers, biometric information at the time of each household activity, and the newly proposed indices including the biometric and activity perspectives as features. The results of the stress estimation method are fed back to the system to promote behavioral change. The stress estimation method uses daily activity data obtained by a daily activity sensing system and heart rate data (biometric information) obtained by a smartwatch as a data set. For feature extraction, we used RRI and Lorenz plot area as stress indices that can be calculated from the heart rate data. The health condition management system is designed to feed back the results of health condition prediction to the elderly at arbitrary times in their daily lives to promote behavioral change and enable them to manage their health condition on their own. To realize this requirement, three functions are implemented in the health condition management system. (1) a function for predicting stress, (2) a function for inputting the lifestyle activities that have been or will be implemented and a function for generating features for prediction, and (3) a function for feeding back the stress predicted in (1). In this study, we developed a health condition management web application in Flask that promotes behavior change by implementing these functions. When subjects receive feedback from bad predictions (high stress), the system encourages them to check the group of activities causing the stress and to change their activity to lower the predicted stress. As an experiment to evaluate the stress estimation method, we used data from five elderly households for a period of one month, respectively, to examine the following three methods: baseline method 1, which uses the RRI variance and Lorenz plot area for 4 hours after waking and 24 hours before answering the questionnaire as features; baseline method 2, which adds sleep duration to baseline method 1 as a feature; and baseline method 3, which uses the Lorenz plot area for each activity and the RRI variance for the 24-hour period before answering the questionnaire as features. The proposed method was compared to the baseline method 1, which uses the Lorenz plot area and total time per action, and the baseline method 2, which adds a new indicator as a feature. The average estimation accuracy of the proposed method was 59%, which was better than the 52% of the baseline method 1 and 55% of the baseline method 2. To evaluate the effective-

ness of the developed health status management system, an evaluation experiment was conducted with 12 subjects for 7 days (2 days for the preliminary experiment and 5 days for the actual experiment). In the evaluation experiment, the subjects' physical condition and the usability of the application were evaluated on a 5-point Likert scale, and the subjects' action time was obtained by an annotation application. As a result, physical condition improved from an average of 2.08 points to 1.33 points before and after the use of the proposed system (the lower the value, the better the physical condition). Additionally, bathing time and eating times were 1.48 and 1.52 times longer before and after the use of the proposed system, respectively. This suggests that the use of the application may improve physical condition, promote behavioral change, and that bathing time and eating time are related to health.

Keywords:

QOL; Machine learning; Stress prediction; Behavior change

目次

1. 序論	1
2. 関連研究	5
2.1 QOL 推定	5
2.2 ストレス推定	6
2.3 スマートホームにおける家庭内行動の認識	7
2.4 スマートホームにおける健康状態管理	7
2.5 本研究の立ち位置	8
3. 健康状態フィードバックによる行動変容の可能性：要件定義とシステムの設計	9
3.1 ユースケースシナリオ	9
3.2 要件定義	9
4. 家庭内行動データと生体情報を用いたストレス推定モデルと健康状態管理システムの提案	11
4.1 提案手法の目的	11
4.2 提案手法概要	11
4.3 ストレス推定モデル	12
4.3.1 データ収集	12
4.3.2 特徴量抽出	14
4.3.3 ストレス推定	16
4.4 ストレス推定機能を用いた健康状態管理システム	16
4.4.1 健康状態管理システムの概要	16
4.4.2 健康状態管理システムのシステムデザイン	18
4.4.3 システム実装	18
5. 評価実験	21
5.1 ストレス推定モデルの評価実験	21

5.1.1	データセット	21
5.1.2	ストレス推定モデルの概要	21
5.1.3	ストレス認識モデルの詳細	24
5.2	健康状態管理システムの評価実験	28
5.2.1	健康状態管理システム評価実験の概要	28
5.2.2	健康状態管理システム評価実験の詳細	28
6.	結果	34
6.1	ストレス推定モデルの評価結果	34
6.1.1	SMOTE-OverSampler, RandomUnderSampler, Bagging の導 入結果	34
6.1.2	特徴の違いによる効果検証	37
6.1.3	SHAP による分析	41
6.2	行動変容実験の評価結果	43
6.2.1	アンケートによる分析	43
6.2.2	アプリの入力と行動時間による分析	49
6.2.3	平均行動時間による分析	50
6.3	考察	51
6.4	制限	52
7.	結論	53
	謝辞	56
	参考文献	57
	研究業績	65

目 次

1	提案手法の概要	12
2	ローレンツプロット面積の計算方法	13
3	Salon システムの構成要素	14
4	健康状態管理システムの概要	17
5	Web アプリの画面遷移図	20
6	特徴量データの生成フロー	23
7	朝・夜アンケートの集計期間	25
8	健康状態管理システム評価実験の概要	28
9	健康状態管理システム評価実験の詳細な流れ	29
10	アノテーションアプリの概要	31
11	各行動のアノテーションアプリを入力するタイミング	32
12	朝 (MQ) のストレス推定における4つの手法の混同行列	40
13	夜 (NQ) のストレス推定における4つの手法の混同行列	41
14	朝のアンケート (MQ) の SHAP 値によるモデル出力への特徴量の 影響	42
15	夜のアンケート (NQ) の SHAP 値によるモデル出力への特徴量の 影響	43
16	体調を聞くアンケートの結果	44
17	アプリの評価を聞くアンケートの結果	45
18	身体的ストレスのアンケート結果	47
19	精神的ストレスのアンケート結果	48
20	体調予測フィードバックと行動変容のアンケート結果	48
21	体調予測フィードバックと体調のアンケート結果	49
22	アプリの入力結果と実際の行動時間の比較	50
23	予備実験と本実験の行動時間の比較	51

表目次

1	行動ログ	14
2	行動ごとのストレス指標	15
3	被験者 ID1/女性における生体指標	24
4	被験者 ID1/女性における活動指標	24
5	各手法で使用する特徴量	27
6	提案手法 1 に SMOTEOverSampler, RandomUnderSampler, Bagging を導入した結果. 推定値は MQ と NQ の平均値	36
7	5つの手法の推定精度. 推定値は MQ と NQ の平均値	38
8	MQ における 4つの手法の推定精度	39
9	NQ における 4つの手法の推定精度	39
10	アプリの評価と体調のアンケート結果	46
11	アプリの入力結果と実際の行動時間の比較	49
12	予備実験と本実験の行動時間の比較	50

1. 序論

世界的に高齢者の人口比率が急速に高まっており、世界は高齢化社会となっている。高齢化社会は、経済的・社会的に大きなリスクをもたらしている。そのため、高齢者福祉と健康寿命の延伸のための効果的な対策が求められている。高齢者福祉を推進するためには、医療機関での支援だけでなく、高齢者が住み慣れた家で自立した生活を送ることができるよう福祉的な支援をすることが必要である。そのため、高齢者自身が自宅での日常生活を理解し、健康状態を自ら管理できるような環境づくりが不可欠である。このような背景のもと、家庭における行動認識技術に関する研究は数多く行われているが (e.g., 松井 [1])、高齢者が自己健康状態管理のできる環境構築や生活習慣改善のための健康状態モニタリングに関する研究はまだ初期段階にとどまっている。

高齢者の見守りサービスや生活習慣の改善を行うためには、健康状態を表す指標を開発し、その指標が変化する要因を調べる必要がある。健康状態を示す代表的な指標の一つとして、QOL (Quality of Life) が挙げられる。世界的な高齢化の進展に伴い、高齢者の QOL に関する研究が盛んに行われている [2, 3, 4]。世界保健機関 (WHO) では、健康状態の代表的な指標として 100 問のアンケートに基づく WHOQOL-100 [5] を開発している。しかし、このようなアンケート指標を用いた測定方法は、質問項目が多いため、回答者への負担が大きい。そのため、Amenomori らは [6]、スマートフォンやスマートウォッチなどのデバイスから得られるデータから機械学習を用いて各質問項目の回答を予測することで、より少ない負担で HRQOL (Health Related Quality of Life) を測定する研究をおこなっている。この研究では、HRQOL を継続的に測定し、ストレスの兆候を早期に発見して予防することで、心身のストレス状態と強く関連する HRQOL を改善することを目指している。HRQOL に関する研究は、老若男女、病気の有無など様々な状況を対象に行われている [7, 8, 9, 10, 2]。このような、デバイスを用いたストレス推定は、日常生活など様々な場面で応用されている [11, 12, 13]。Natasha ら [12] は、スマートデバイスを用いて、翌日の健康状態、ストレス、幸福度を定量的に測定・推定する手法を提案している。Gjoreski ら [13] は、複数のスマートフォンのデータ (加速度センサー、オーディオレコーダー、GPS, Wi-Fi, 通話記

録, 光センサーなど) を利用した学生のストレスの自動推定手法を提案している. この手法は, 学生のストレスを検出するための機械学習モデルを開発することを目的としている.

しかし, これらの研究では, スマートフォンを使用し, 正確な行動を記録することや, スクリーンタイムなどを測定することが必要である. そのため, デジタル機器に慣れておらず, プライバシー情報の提供に抵抗がありがちな高齢者の特性が考慮されておらず, 高齢者にとって負担の大きいシステムとなっている. また, 高齢者は外出よりも自宅で過ごす時間が長いと考えられるため, 家庭内の日常生活行動センシングデータを用いて健康状態を管理するシステムを開発する必要がある.

本研究では, スマートホームで自動収集できる日常生活行動センシングデータと, スマートウォッチを装着することで自動収集できる生体データを用いることで, 高齢者に負担の少ないストレス推定手法を提案する. さらに, ストレス推定結果をフィードバックすることで, 簡易的に健康状態管理を行うシステムを開発する.

既存のストレス推定モデルでは, 心拍数やスマートフォンの加速度, 運動量などを説明変数として用いている. 本研究では, 家庭内行動とストレスに関係があると考え, 家庭内行動ごとの心拍数を説明変数とする. 本研究では初め, 家庭内行動ごとの心拍数のみを説明変数としたストレス推定モデルを全被験者のデータを用いて学習させたが, データの個人差が大きく, 低い推定精度に留まった. この問題を解決するために, 正規化した生体指標と活動指標を組み合わせ, 新たな指標 (Mixed indicator) を作成した. 新たな指標 (Mixed indicator) では, 活動的観点 (活動指標) と生体観点 (生体指標) を特徴として含む新たな指標を提案している. 活動指標と生体指標を用いる理由は, QOL と身体活動の関係を調べた関連研究や, ウェアラブルデバイスで取得できる生体情報を用いてストレスを検出する研究が多く行われているためである [14, 15, 16, 17]. 最後に, 提案指標を説明変数, 主観的ストレスを尋ねるアンケートを目的変数として, モデルを構築し, 提案するストレス推定手法の評価を行う.

また, 提案するストレス推定手法の有効性を評価するため, 作成したストレス

モデルの推定結果をフィードバックすることで行動変容を促す健康状態管理システムを作成する。健康状態管理システムには 1: ストレス予測機能, 2: 実施済・実施予定の生活行動を入力する機能と予測に用いる特徴量を生成する機能, 3:1 で予測したストレスをフィードバックする機能の 3 つの機能を実装する。提案システムは任意のタイミングで使用され, 翌朝の起床までの行動予定時間を入力することで, 起床時の健康状態予測結果を被験者にフィードバックする。また, 被験者はフィードバック結果に満足しない場合, 再度行動予定時間を入力でき, 満足するまで行動予定を入力しフィードバックを受けることができる。これにより, 被験者は悪い予測結果 (ストレスが高くなる) がフィードバックされた時は, ストレスの原因となっている行動群を確認し, 予測ストレスが低くなるように実施予定の行動を変化させるような行動変容を促す。

提案したストレス推定手法および健康状態管理システムの有効性を評価するために, 二つの実験を行った。一つ目の実験では, 提案するストレス推定手法の有効性を評価するために, 60 歳以上の高齢者 5 世帯から 1 ヶ月間収集した生活データ, 生体データ, ストレス状況質問票 (朝晩の身体的ストレス) からなるデータセット [1] に本手法を適用した。ストレス推定手法の評価として, 2 つのベースライン手法: 起床後 4 時間とアンケート前 24 時間の RRI 分散とローレンツプロット面積 (関連研究 [18, 19] でストレスに対する有効性が検証されている) を特徴量として用いたベースライン手法 1, ベースライン手法 1 に睡眠時間 [11] を特徴量として追加したベースライン手法 2 と, ベースライン手法 2 に各活動のローレンツプロット面積, 各活動の合計時間, 各家庭内行動の Mixed indicator (新規提案指標) を特徴量として追加した提案手法を比較した。その結果, 提案手法の推定精度は平均 59% となり, ベースライン手法 1 の 52%, ベースライン手法 2 の 55% よりも高くなった。

二つ目の実験では, 提案する健康状態管理システムを 12 名の被験者に 2 日間の予備実験と 5 日間の本実験の合計 7 日間使用してもらい評価実験を行った。提案システムの評価として, 実験前と後に 5 段階のリッカートスケールを用いて, 健康状態フィードバックに対する意識調査アンケートを行った。結果として, 体調に関するアンケート結果は, 提案システムの使用前と使用後で平均 2.08 ポイント

から 1.33 ポイントに改善した（低いほど体調は良い）。また，システムの使用前と使用後では入浴時間が 1.48 倍，食事時間が 1.52 倍となった。これにより，アプリを使用する事で体調が改善される可能性，行動変容を促す可能性，さらに健康には入浴時間と食事時間が関わる可能性が示唆された。

2. 関連研究

ここでは、QOL 推定、ストレス推定、健康状態管理、スマートホームにおける家庭内行動の認識、スマートホーム技術を用いた健康状態管理システムに関する関連研究をまとめる。

2.1 QOL 推定

QOL (Quality of Life) は、日常生活における満足度や質を測定するものである。QOL [20] に関する研究は、もともと医療分野で治療後の QOL を議論するための概念として始まったが、現在は医療分野だけでなく、ワークライフバランスや幸福など、生活全般の質に関わる概念としても使われている。特に人間の健康に直接関わる QOL は HRQOL (Health Related Quality of Life) と呼ばれ、身体的状態、心理的状态、社会的相互作用、経済・職業的状态、宗教・精神的状态など様々な領域に分類されて評価されている。WHO (世界保健機関) では、QOL を定量的に評価するために、WHOQOL [5] や Short Form [21] など、様々な指標を開発している。これらの指標は紙の質問紙で評価されているが、WHOQOL-100 [5, 22] は 6 領域 100 項目、SF-36 [21] は 8 領域 36 項目が必要であり、回答するのに大変な負荷がかかるため、日常的に QOL を評価することは難しい。このような背景のもと、QOL と日常生活の関連性を調べたり、QOL の評価をより精度良く、より簡単にする文脈で多くの研究が行われている。Amenomori [6] らは、スマートフォンやスマートウォッチから得られる移動情報や生体情報を用いて HRQOL を継続的に測定する方法を提案し、少ない質問項目とスマートデバイスの情報を用いて HRQOL が推定できることを示している。彼らは、身体的・精神的ストレス状態と強く関連する HRQOL を継続的に測定することで、ストレスの兆候を早期に発見し、予防することで HRQOL の向上を目指している。Prasad ら [23] は、インド在住の高齢者の身体機能を評価し、身体活動レベルおよび QOL との関連を明らかにすることを目的としている。結果として、身体機能と QOL の間には正の相関があり身体活動量と QOL の間にも正の相関があることを明らかにしている。Zapata-Lamana ら [24] は、活動的な高齢者を対象に、身体活動量や QOL を

育む要因が生活満足度の要因となりうるかを評価することを目的としている。その結果、健康度、身体活動量、QOLが、成人における満足度の要因であることが示された。Sellaら [4] は、健康な高齢者のQOL（およびその特定領域）と睡眠の関連性を検証した。結果として、客観的および主観的な睡眠の質特に睡眠に関するネガティブな感情や思い込みが、睡眠効率とともに、健康な高齢者のQOLの評価に影響を与えることが示された。このように、高齢者とQOLは様々な研究対象になっている。

2.2 ストレス推定

デバイスを用いたストレス推定については、様々な場面で多くの研究がなされている。ストレス推定には2つのグループがある。1つ目は、制御された実験室環境で行われる研究である [25, 26]。これらの研究では、研究者がストレスレベルを完全にコントロールできるストレステスト [27] を用いて意図的にストレスを発生させており、80~97%の高いストレス検出精度が報告されている。2つ目は、実生活におけるストレスを分析する研究であり、比較的精度が低いことが報告されている [12, 28, 29, 30]。Asmaら [31] は、ネガティブな心理状態を評価するために Hamilton Depression Rating Scale を提案している。Garciaら [32] は、仕事でのストレス状態を評価するために、Oldenburg Burnout Inventory を提案している。Natashaら [12] は、スマートデバイスを用いて翌日の健康状態、ストレス、幸福感を定量的に測定・推定する手法を提案している。Gjoreskiら [13] は、スマートフォンを用いた学生のストレスの自動検出を提案している。この手法は、学生のストレスを検出するための機械学習モデルを開発することを目的としている。彼らは、加速度センサー、オーディオレコーダー、GPS、Wi-Fi、通話記録、光センサーなど、複数のスマートフォンのデータを利用している。

また、ウェアラブルデバイスで取得できる生体情報を用いて、ストレスの検出を行う研究が数多く行われている [14, 15, 16, 17]。提案された手法は、ECG [33], skin electrical activity [34], RRI [35], electromyography [36] センサー等から収集した生体情報の組み合わせを分析するものである。これらの研究は、機械学習アルゴリズムを用い生体情報を解析し、ストレスの検出や感情の分類を行った。その

結果，環境の違いやデータセットの違いによる影響により，精度は50～90%程度と低い傾向にある．このような課題のもと推定精度を向上させるために，様々なシステムが研究されている．システムの一つとして，スマートウォッチだけでなく，胸部に装着する心拍センサー（WHS-3 など）も利用する研究がある～[37]．しかし，複数のウェアラブルセンサーを使用するシステムは，ユーザーの負担が大きく，日常生活におけるリアルタイムのストレス検出には適していない [38]．そこで本研究では，できるだけ邪魔にならない最小限のデバイスを使用する．

2.3 スマートホームにおける家庭内行動の認識

Georgia Institute of Technology [39], University of Colorado at Boulder [40], Microsoft Research [41]などは，家庭における日常生活行動の認識に関するスマートホームプロジェクトを開始している．MavHome プロジェクトでは，健康データセットの異常検知を行い，スマートホームの異常値やドリフトをチェックしている [42]．このアプローチは，数値ベースの健康状態を記録したデータセットの回帰と相関に基づくものであり，健康状態データセットを用いた実験では，人間のバイタルサインの増加，減少，一定などの時間的な傾向を学習し推定している．このようなスマートホーム内の日常生活行動センシングに関する研究の精度が高まるにつれて，これらの技術を健康支援技術に応用することが一般的になりつつある．しかし，健康状態推定の分野では，スマートフォンや心電図センサーから取得できるデータで推定を行うことが多い．スマートホーム内での健康支援分野の発展を考えると，日常生活行動センシングデータと組み合わせた健康状態の推定は重要な研究領域である．そのため，日常生活行動センシングで取得した家庭内活動と健康状態推定を組み合わせた研究を行う必要がある．

2.4 スマートホームにおける健康状態管理

スマートホームの研究でも，生活空間内の活動を関連させ居住者の幸福度を推定する試みがなされている．Intel Research の Computer-Supported Coordinated Care (CSCC) プロジェクト [43] の目標は，在宅生活を希望する高齢者のケアネッ

トワーク特性とニーズを特定することである。Jakkula ら [44] は、健康状態の傾向を特定し、スマートホームシステムを構築することを目的としている。しかし、スマートホームにおけるストレス推定に関連する既存研究の多くは、被験者の自宅などの一般住宅ではなく、管理されたスマートホームで実施されている。そのため、実際の家庭における現実のストレスを分析・推定する研究はほとんどない。また、上記の関連研究の多くは、使用するセンサデータや特徴量に、被験者の家庭での行動が考慮されていない。そのため、日常生活動作に関する情報がない場合、ストレスの原因となる動作の把握ができず、ストレス状態の改善ができない可能性がある。そのため、家庭での活動に関するデータや生体情報を取り入れることが必要である。

2.5 本研究の立ち位置

このように、従来研究では実際の日常生活行動のデータセットを用いていないことやウェアラブルデバイスの数が多い、使用するセンサデータや特徴量に、被験者の家庭での行動が考慮されていない等の課題がある。本研究では、実際の日常生活行動におけるストレスを分析・推定できるデータセットを用い、最小限のウェアラブルデバイスで取得した生体情報と日常生活行動センシングで取得した家庭内活動データを組み合わせたストレス推定手法と推定結果をフィードバックすることで行動変容を促す健康状態管理システムの提案を行う。本研究では、使用するセンサデータや特徴量に、家庭での生活を考慮し、ストレスの原因となる日常生活行動の把握とそれらを用いた行動変容による高齢者の QOL 向上を目標とする。

3. 健康状態フィードバックによる行動変容の可能性：要件定義とシステムの設計

本研究では、ウェアラブルデバイスで取得した生体情報と日常生活行動センシングシステムで取得した家庭内活動を組み合わせたストレス推定手法の評価を行い、推定結果をフィードバックすることで健康な状態への行動変容を促すシステムを提案する。このセクションでは想定するユースケースと対象、使用する技術と技術課題について述べる。

3.1 ユースケースシナリオ

ユースケースシナリオを以下に示す。

ある高齢者がスマートホームに在住している。このスマートホームでは日常生活行動センシングシステムにより、常にセンシングが行われている。また、高齢者は腕に生体情報を取得可能なスマートウォッチを装着している。これらのデータはスマートホームのサーバーで管理されており、サーバー内ではこれらのデータを用いたストレス推定の機械学習モデルが作成されている。高齢者は起床から通常の生活を行い、任意のタイミングで行動変容システムに起床までの行動予定を入力する。提案システムは、入力された行動予定とセンシングデータを用いて機械学習を行い明日の朝の健康状態を予測し、高齢者へ結果をフィードバックする。悪い結果が出た場合、高齢者は自分の行動予定を反省・見直し、生活の改善のためにスケジュールを変更する。良い結果が出た場合は、高齢者は入力した行動通りに生活をできるよう意識しながら生活を行うことで、健康状態が改善されていく。

3.2 要件定義

ユースケースシナリオを満たすために、本研究では5つの要件を定義する。本研究では、高齢者のQOLを向上させることを目的としているため、“高齢者向けであること（要件1）”、その際に高齢者は低負荷なシステムを求めているため、“

低負荷であること（要件2）”が求められる。また，提案手法はストレスを推定することでQOL向上を目指すため，“ストレス推定ができること（要件3）”が必要不可欠である。

翌朝の健康状態を予測し高齢者へ結果をフィードバックすることで行動変容を目指すためには，“行動スケジュールを入力することで未来のストレスを推定できること（要件4）”が必要である。加えて，自分の行動予定を繰り返し反省・見直すためには，“入力を何度もできること（要件5）”が必要である。次章でこれらの要件を満たす手法およびシステムを提案する。

4. 家庭内行動データと生体情報を用いたストレス推定モデルと健康状態管理システムの提案

4.1 提案手法の目的

本章では、3章で説明した要件を解決するための手法を提案する。高齢者のQOL向上を目的とした高齢者の自主的な健康状態管理システムには、高齢者用に調整された負荷の少ないデータ収集手法とそれらのデータを用いる健康状態推定モデル、これらの技術を使用した健康状態管理システムが必要である。そのために、本研究では機械学習を用いて、その日に行われた日常生活行動ごとのストレス指標の値から、1日の終わり（または翌日の始まり）のストレス状態を推定する手法を提案する。また、提案手法を使用し被験者の行動予定からストレスを推定しフィードバックを行うことで、被験者へ行動変容実験を行うシステムを提案する。

4.2 提案手法概要

提案手法の概要を図1に示す。提案手法は、5つのパートから構成される。第1パートから3パートがストレス推定モデルの作成、第4パートから第5パートが健康状態管理システムの作成である。第1パートは生体情報と行動情報を収集するためのデータ収集パートである。このパートでは、スマートウォッチと日常生活行動センシングシステムを用いて、それぞれ生体データと日常生活行動データを収集する。第2パートは有効な特徴量を生成するために特徴抽出を行う。データ収集パートで収集されたデータから特徴を抽出する。第3パートは、ストレス推定モデルである。ストレス推定モデルは機械学習により構築される。第4パートでは健康状態管理システムの開発を行い、第5パートでは提案システムの健康状態フィードバックによって行動変容促されることで、使用者が健康になる方向への行動変容を行う。詳細は以下のセクションで述べる。

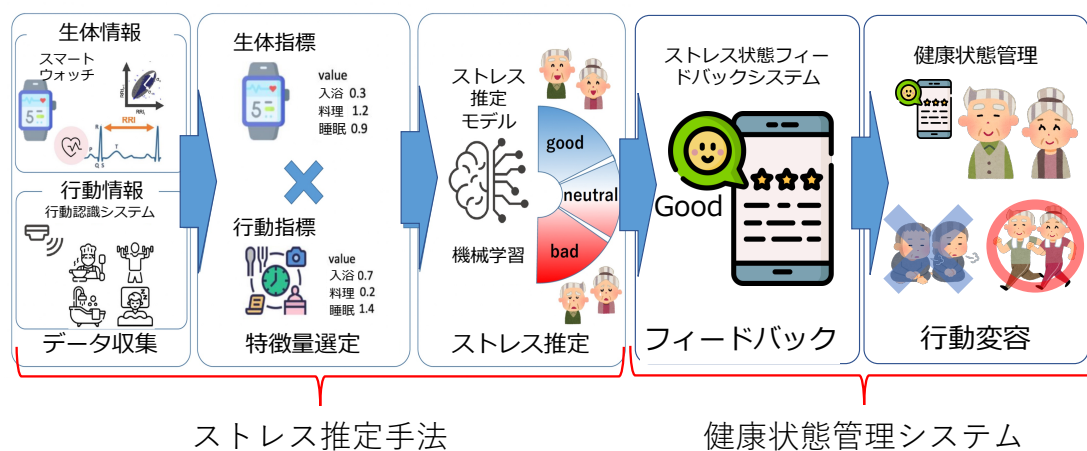


図 1: 提案手法の概要

4.3 ストレス推定モデル

4.3.1 データ収集

ストレス状態は、心拍変動などの生体データを解析することで推定することができる。心拍変動は、スマートウォッチなどのウェアラブル生体センサーで測定することができる。既存の研究では、心拍間隔 (RRI) と RRI の標準偏差がストレス推定に用いられる重要な指標であることが示されている [45, 46]。そこで、心拍変動データから算出できるストレス指標として、RRI 分散とローレンツプロット面積に着目する。豊福ら [18] は、ローレンツプロット (LP) を用いた副交感神経の活性度の簡易推定法を提案した。ローレンツプロットは 2 次元平面上に $(RRI(t), RRI(t+1))$ でプロットされ、 $RRI(t)$ は時間 t における RRI である。図 2 はローレンツプロットの例である。出力楕円の面積は RRI の揺らぎの大きさを表し、副交感神経が活性化したかを判断する手法として利用・評価されている [19, 47, 48]。

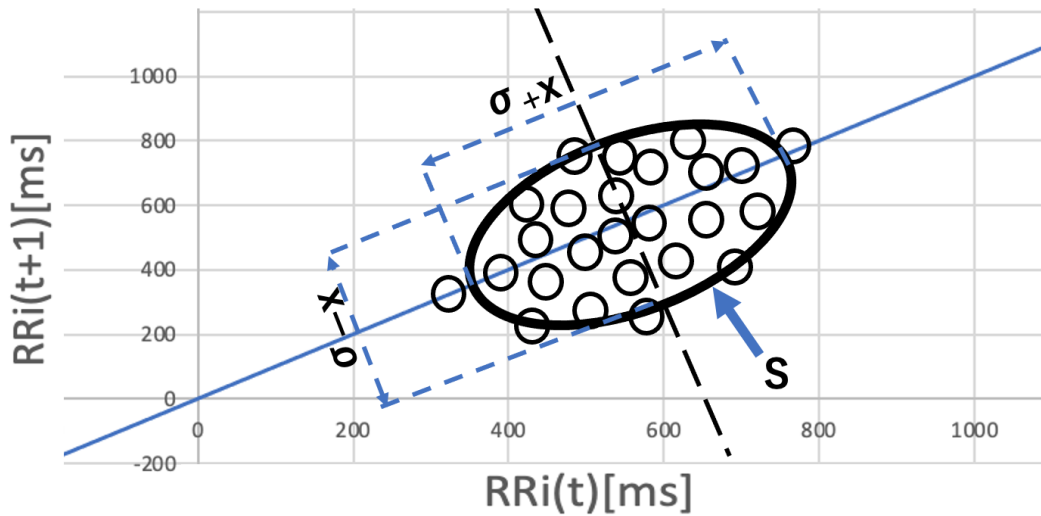


図 2: ローレンツプロット面積の計算方法

心拍数を RRI に変換する式は，式 1 で示される．

$$RRI = \frac{60}{\text{Heartrate} \times 1000} \quad (1)$$

ここで， RRI は心拍間隔 (ms)， Heartrate は 1 分あたりの心拍数である．

プロットされた点を覆う楕円の面積をローレンツプロット面積として，図 2 に示すように計算する．

$y = x$ 軸に，原点 (0,0) からの距離の平均を m ，原点からの標準偏差を $\delta_{\Delta x}$ とすると， $y = -x$ 軸に，原点からの距離の平均を m とする． $y = -x$ 軸において，原点 (0,0) からの標準偏差を $\delta_{(-x)}$ とする．このとき，長軸 $\delta_{\Delta x}$ ，短軸 $\delta_{(-x)}$ の楕円の面積 S は次のように計算される．

$$S = \pi \cdot \delta_{\Delta x} \cdot \delta_{(-x)} \quad (2)$$

ここでは，日常生活行動センシングシステム (SALON [49]: 図 3 など) を用いて，住民の行動を自動的に取得できる環境を想定している．表 1 に日常生活行動センシングシステムの記録例を示す．行動記録の対象は，調理，食事，休息，作業，掃除，洗濯，外出，入浴，睡眠などの主な日常生活行動である．これらの行動記録は，将来的に日常生活行動センシングシステムで記録される予定である．

表 1: 行動ログ

時間	行動
-7:00	睡眠
7:30-8:00	料理
8:00-8:30	食事
8:30-9:00	その他
9:00-18:00	外出
18:00-18:30	料理
18:30-19:30	食事
19:30-21:00	その他
21:00-21:30	入浴
21:30-23:00	その他
23:00-	睡眠



図 3: Salon システムの構成要素

4.3.2 特徴量抽出

提案手法は、心拍データから各行動の RRI 分散とローレンツプロット面積を、4.3.1 章で述べた式 2 で算出する。また、各行動のと RRI 分散とローレンツプロット面積からストレス指標を算出する。最後に、各行動のストレス指標の値を表 2 のように算出し記録する。

表 2: 行動ごとのストレス指標

行動	RRI 分散	ローレンツプロット面積
睡眠	0.8	1.0
料理	0.3	0.5
食事	0.2	0.4
その他	0.3	0.3
外出	0.1	0.3
入浴	0.5	0.7
睡眠	0.9	0.9

ストレスに関して住民は、高ストレスな行動を短時間で行えば低ストレスと感じ、低ストレスな行動を長時間行えば高ストレスと感ずることがある。そのため、ストレスの状態を表すには、時間とストレスの強さを組み合わせた指標が必要になる。そこで、時間の指標として「活動指標」、ストレス強度の指標として「生体指標」を作成する。

活動指標は、各行動の総行動時間をもとに定義する。また、家事の行動時間は性別によって大きく異なる。そこで、性別ごとに指標を正規化する。

活動指標 A_i は次のように定義される。

$$A_{i,s,a} = \frac{Ar_{s,a}}{\sum_{n=1}^N Ar_{s_n,a} \div N} \quad (3)$$

ここで、 Ar は 24 時間における各行動の行動時間比率、 N は被験者数、 s は各被験者、 a は各行動である。

生体指標は、ローレンツプロットの面積をもとに定義される。日本の場合、男性の調理活動に関するローレンツプロット面積は、調理活動をしない人がいるため、低くなる。そこで、男女別に正規化する。そこで、生体指標 B_i を次のように定義する。

$$B_{i,s,a} = \frac{Br_{s,a}}{\sum_{n=1}^N Br_{s_n,a} \div N} \quad (4)$$

ここで、 Br は 24 時間における各行動のローレンツプロット面積の正規化値、 N は被験者数、 s は各被験者、 a は各行動である。

この 2 つの指標を掛け合わせることで、ストレスがかかる時間の長さや強さの両方が含まれる新しい指標 (Mixed indicator) を作成することができる。この *MixedIndicator* を次のように定義する。

$$MixedIndicator(A_i, B_i)_{s,a} = A_{i,s,a} \times B_{i,s,a} \quad (5)$$

ここで、 A_i は活動指標、 B_i は生体指標、 A_r は 24 時間の各行動の行動時間比率、 Br は 24 時間の各行動のローレンツプロット面積比率、 N は被験者数、 s は各被験者、 a は各行動である。

4.3.3 ストレス推定

抽出された特徴量は、居住者のストレスを推定するために使用される。ストレス推定モデルは、機械学習を用いて構築される。モデルの構築に使用する機械学習アルゴリズムは、ランダムフォレスト [50] である。ランダムフォレストは、アンサンブル学習に基づいた機械学習アルゴリズムである。複数の決定木を分類器として用い、分類器による結果を統合することで分類結果を得る。他のアルゴリズムと比較して、特定の対象に対する計算時間が短く、高い性能を持つと言われている。提案手法は、スマートフォンでの処理を想定しているため、高精度かつ処理負荷の低いランダムフォレストを選択する。

4.4 ストレス推定機能を用いた健康状態管理システム

本節ではストレス推定機能を用いた健康状態管理アプリケーションの概要とシステムデザイン、実装について述べる。

4.4.1 健康状態管理システムの概要

健康状態管理システムは、日常生活の任意のタイミングで健康状態管理システムに睡眠までの行動予定を入力後、高齢者へ健康状態予測の結果をフィードバック

クすることで、行動変容を促し高齢者自ら健康状態管理を行える環境作りを目的としている。

図4に健康状態管理システムの概要を示す。健康状態管理システムは以下の3つの機能を含む。

- 特徴量の入力機能
- ストレス推定機能
- フィードバック・出力機能

要件(4) ”行動スケジュールを入力することで未来のストレスを推定できること”を満たすために、特徴量の入力機能とストレス推定機能を実装する。また、健康状態管理システムは自分の行動予定を反省・見直す機能が必要であるため、要件(5) ”入力を何度もできること”を満たすために、フィードバック・出力機能を実装する。

本研究では、これらの機能を搭載した健康状態管理 Web アプリケーションを Python の Web アプリケーションフレームワークである Flask¹で開発する。

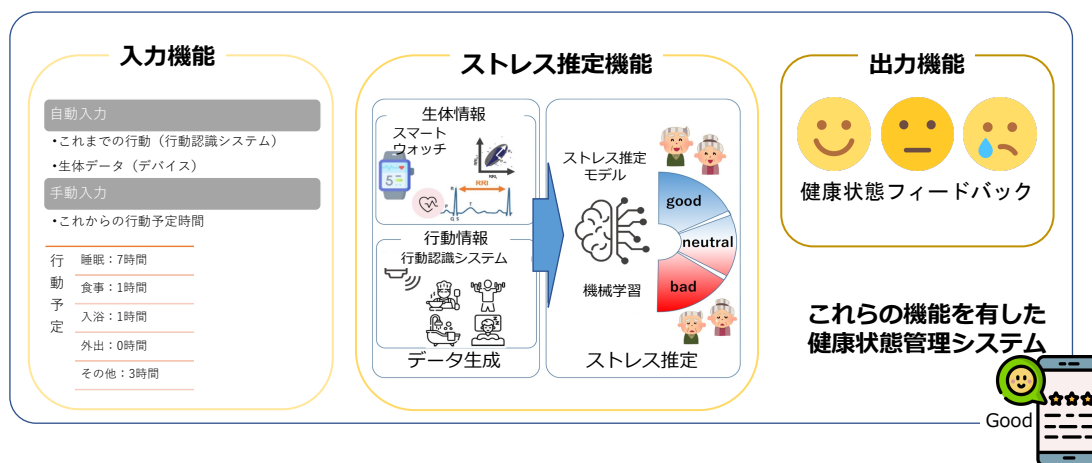


図4: 健康状態管理システムの概要

¹<https://flask.palletsprojects.com> アクセス日:1月30日

4.4.2 健康状態管理システムのシステムデザイン

図4に健康状態管理システムのシステムデザインを示す。健康状態管理システムのフロントエンド部分は2つの要素で構成されている。

- ストレス推定機能を使用するための特徴量を入力する機能
- ストレス推定結果をフィードバックする表示・出力機能

入力機能ではストレス推定機能を使用するための特徴量を入力する。4.3節で示した特徴量のうち、行動時間は被験者がシステムへ入力し、生体情報は全被験者のRRIの平均値をシステムが生成する。ストレス推定結果をフィードバックする表示機能では、体調が良い、悪い、どちらでもないの3種類の体調を文字と図4の画像で表示する。

健康状態管理システムのバックエンド部分は2つの要素で構成されている。

- ストレス推定機能を使用するための特徴量生成機能
- ストレス推定機能

ストレス推定機能を使用するための特徴量を生成する機能では、4.3節で示した式を用いて特徴量を生成する。ストレス推定機能は4.3節で示した手法でストレス推定を行う。

4.4.3 システム実装

図5にFlaskで実装したWebアプリ（提案システム）の画面遷移を示す。被験者はまず1と2で基本情報の入力を行う。1で入力を行う項目は起床時間と入眠時間、そしてこれまでの行動時間である。2では現時刻から睡眠までの残り時間が表示され、その時間を埋めるように今後の行動予定時間を入力していく。入力を完了し送信ボタンを押すと、健康状態の推定結果が得られる。3で被験者は体調フィードバックを確認し、フィードバックが気に入っている場合「この結果に満足し終了するボタン」と気に入らない場合「もう一度予測をするボタン」を選択できる。「この結果に満足し終了するボタン」を押すと2aに遷移し、提案システムは

サーバーに「今後の行動予定時間」の1回目の入力（1と2で入力した内容）と最終の入力を保存する。被験者はシステムの操作を完了する。「もう一度予測をするボタン」を選択すると4に遷移し、起床時間と入眠時間、これまでの行動時間を再入力する。再入力を完了すると5番へ遷移し、健康状態フィードバックを確認して「この結果に満足し終了するボタン」と「もう一度予測をするボタン」を選択でき、被験者は何度でもストレス推定を行うことができる。「この結果に満足し終了するボタン」を押すと5aに遷移し、提案システムは2aと同様に入力内容（5の入力）を保存し、被験者はシステムの操作を完了する。

1. 入眠時間と起床時間とそれまでの行動時間を入力

ID1日付2023年01月14日 17:13:19
 入眠時間 2時 0分 (24時間表記)
 起床時間 8時 0分 (24時間表記)
 睡眠までの残り時間 8時間 42分

この入力してください
 入眠時間 0 分
 起床時間 0 分 (24時間表記)

行動の種類	過去の行動時間	今後の行動時間
睡眠	1時間 0分	6時間 0分
外出	0時間 0分	0時間 0分
料理	0時間 0分	0時間 0分
食事	1時間 30分	0時間 30分
入浴	0時間 0分	0時間 30分
その他	1時間 0分	7時間 42分

IDと入眠起床時間とユーザー名が
 これでいいですか? はい いいえ
 この睡眠時間を入力完了

健康状態を推定

3. 体調のフィードバックを受け取り、もう一度入力するか選択

ID1日付2023年01月14日 17:13:19
 入眠時間 2時 0分 (24時間表記)
 起床時間 8時 0分 (24時間表記)
 睡眠までの残り時間 8時間 42分

この入力してください
 入眠時間 0 分
 起床時間 0 分 (24時間表記)

行動の種類	過去の行動時間	今後の行動時間
睡眠	0時間 0分	6時間 0分
外出	0時間 0分	0時間 0分
料理	0時間 0分	0時間 0分
食事	1時間 30分	0時間 30分
入浴	0時間 0分	0時間 30分
その他	1時間 0分	7時間 42分

この予定は体調が悪くなるでしょうか? はい いいえ
 この健康状態を入力完了

再度入力を行う

4. もう一度寝るまでの行動時間を入力。睡眠時間も変更可能

ID1日付2023年01月14日 17:13:19
 入眠時間 2時 0分 (24時間表記)
 起床時間 8時 0分 (24時間表記)
 睡眠までの残り時間 8時間 42分

この入力してください
 入眠時間 0 分
 起床時間 0 分 (24時間表記)

行動の種類	過去の行動時間	今後の行動時間
睡眠	0時間 0分	6時間 0分
外出	0時間 0分	0時間 0分
料理	0時間 0分	0時間 0分
食事	1時間 30分	0時間 30分
入浴	0時間 0分	0時間 30分
その他	1時間 0分	7時間 42分

この予定は体調が悪くなるでしょうか? はい いいえ
 この予定は

健康状態を推定

5. 体調のフィードバックを受け取り、もう一度入力するか選択

ID1日付2023年01月14日 17:13:19
 入眠時間 2時 0分 (24時間表記)
 起床時間 8時 0分 (24時間表記)
 睡眠までの残り時間 8時間 42分

この入力してください
 入眠時間 0 分
 起床時間 0 分 (24時間表記)

行動の種類	過去の行動時間	今後の行動時間
睡眠	0時間 0分	6時間 0分
外出	0時間 0分	0時間 0分
料理	0時間 0分	0時間 0分
食事	1時間 30分	0時間 30分
入浴	0時間 0分	0時間 30分
その他	1時間 0分	7時間 12分

この予定は体調が悪くなるでしょうか? はい いいえ
 この健康状態を入力完了

2. 寝るまでの行動時間を入力

ID1日付2023年01月14日 17:13:19
 入眠時間 2時 0分 (24時間表記)
 起床時間 8時 0分 (24時間表記)
 睡眠までの残り時間 8時間 42分

行動の種類	過去の行動時間	今後の行動時間
睡眠	0時間 0分	6時間 0分
外出	0時間 0分	0時間 0分
料理	0時間 0分	0時間 0分
食事	1時間 30分	0時間 30分
入浴	0時間 0分	0時間 30分
その他	1時間 0分	7時間 42分

この予定は

2a. 入力、推定結果を確認

ID1日付2023年01月14日 17:13:19
 入眠時間 2時 0分 (24時間表記)
 起床時間 8時 0分 (24時間表記)
 睡眠までの残り時間 8時間 42分

行動の種類	過去の行動時間	今後の行動時間
睡眠	0時間 0分	6時間 0分
外出	0時間 0分	0時間 0分
料理	0時間 0分	0時間 0分
食事	1時間 30分	0時間 30分
入浴	0時間 0分	0時間 30分
その他	1時間 0分	7時間 42分

この予定は体調が悪くなるでしょうか? はい いいえ
 これで今日の入力は終了です。
 入力通りに生活できるよう頑張ってください。

5a. 入力、推定結果を確認

ID1日付2023年01月14日 17:13:19
 入眠時間 2時 0分 (24時間表記)
 起床時間 8時 0分 (24時間表記)
 睡眠までの残り時間 8時間 42分

行動の種類	過去の行動時間	今後の行動時間
睡眠	0時間 0分	6時間 0分
外出	0時間 0分	0時間 0分
料理	0時間 0分	0時間 0分
食事	1時間 30分	0時間 30分
入浴	0時間 0分	0時間 30分
その他	1時間 0分	7時間 12分

この予定は体調が悪くなるでしょうか? はい いいえ
 これで今日の入力は終了です。
 入力通りに生活できるよう頑張ってください。

図 5: Web アプリの画面遷移図

5. 評価実験

5.1 ストレス推定モデルの評価実験

5.1.1 データセット

実験データは、60歳代の単身者1世帯と夫婦4世帯からなる一般高齢者5世帯から収集し、生体情報データ、日常生活行動データ、ストレス状態データからデータセットは構成されている。データセットにはSALONシステム[49]を用いた。SALONシステムでは、スマートウォッチ、最大10個の人感センサー、最大10個の環境センサー、数個のドアセンサー、5個のアノテーションボタン、サーバーからなるシステムを各家にセットし、データセットの期間は、各世帯1ヶ月間とした。生体データとして用いる心拍数データは、Fitbit Alta HRで収集した。Fitbit Alta HRは15秒に1回、心拍数を収集する。

入浴、調理、食事、外出、睡眠、その他という代表的な5つの日常生活行動を使用した。住民は、それぞれの行動を行う場所に設置された図3に示すアノテーションボタンを押すことで、行動の開始と終了を記録した。ストレス状態は、毎日起床後と就寝前に身体的ストレスに関する質問をすることで収集した。回答は5段階のリッカートスケールを用いた。具体的な質問項目は以下の通りである。

MQ (朝の質問): 今朝はすっきり起きれましたか？

NQ (夜の質問): 身体の痛みや不快感による身体的ストレスはありますか？

5.1.2 ストレス推定モデルの概要

図6にストレス推定モデルの概要を示す。4章に示したデータは、以下の流れで説明変数に変換される。Fitbitで取得した生体データはまずRRIに変換され、「RRIの平均」として説明変数になり、「ローレンツプロット面積」を算出する。ローレンツプロット面積は「その日のローレンツプロット面積」と「日常生活行動ごとのローレンツプロット面積」として使用される。日常生活行動センシングシステムで得られた行動データを「行動ごとの行動時間」、「睡眠時間」として使用する。

「睡眠時間」は、「睡眠の行動時間」と同じである。「ローレンツプロット面積」と「行動ごとの行動時間」から、「活動指標」と「生体指標」が生成されそれらの積から Mixed indicator は算出される。

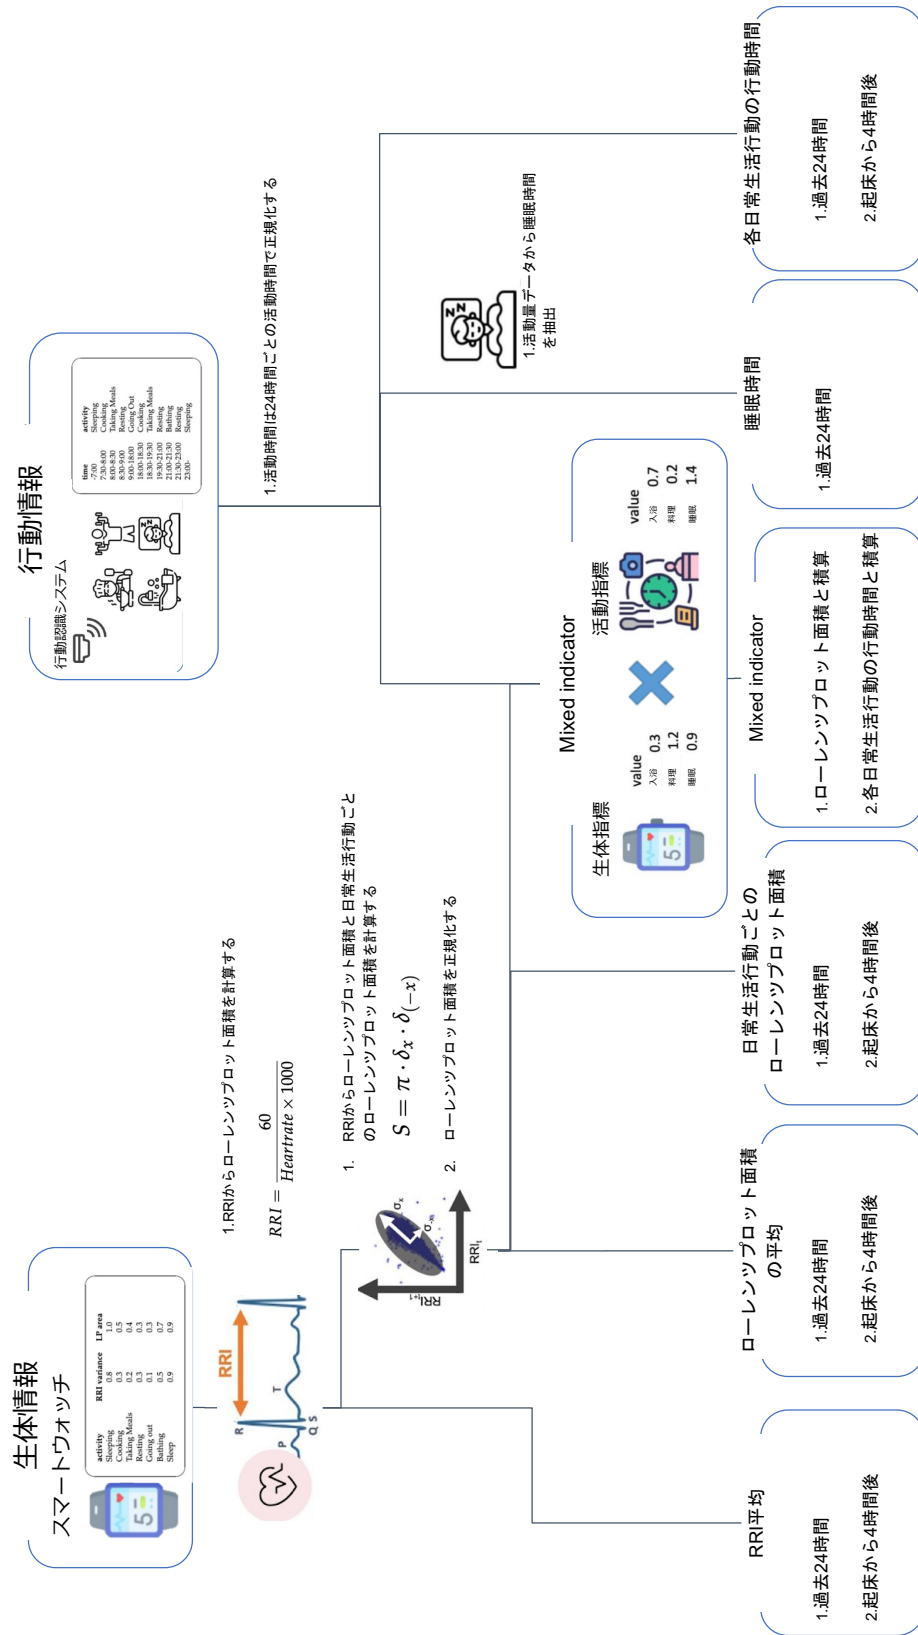


図6: 特微量データの生成フロー

表 3 に式 4 に基づく各行動の生体指標値の一例と，表 4 に式 3 に基づく活動指標の一例を示す。

表 3: 被験者 ID1/女性における生体指標

行動	値
入浴	1.13
料理	1.21
食事	0.67
外出	0.80
睡眠	0.95
その他	1.10

表 4: 被験者 ID1/女性における活動指標

行動	値
入浴	0.40
料理	1.84
食事	0.66
外出	0.71
睡眠	1.11
その他	1.14

5.1.3 ストレス認識モデルの詳細

収集・生成したデータは，ストレス推定モデルの構築に使用される．ストレス推定モデルは，ランダムフォレスト [50] によって構築される．モデル構築の際，5 段階のリッカートスケールの回答を，良い，悪い，どちらでもないの 3 段階に再編成した．また，回答は不均衡データとなっていた．そこで，SMOTE-OverSampler [51]²，RandomUnderSampler³，bagging などの前処理を行うことで不均衡を緩和させた．構築したモデルのパラメータは以下の通りである．RandomForestClassifier は scikit-learn のデフォルト値を用いた．アップサンプリングパラメータは `sampling_strategy=1:100, 2:100, 3:200, k_neighbors=3, random_state=0`．ダウンサンプリングパラメータは `random_state=seed, replacement=True` とした．Bagging を 10 回行い，`random_state=seed` の Seed 値を 1~10 の間で 1 ずつ増やして 10 個のモデルを作成した．予測した 10 個のモデルの出力の最頻値を，最終的なモデルの出

²https://imbalanced-learn.org/stable/references/generated/imblearn.over_sampling.SMOTE.html アクセス日:1 月 30 日

³https://imbalanced-learn.org/stable/references/generated/imblearn.under_sampling.RandomUnderSampler.html アクセス日:1 月 30 日

力とした。図7は、朝と夜の質問の回答を推定するための分析対象期間（特徴量を抽出する時間）である。

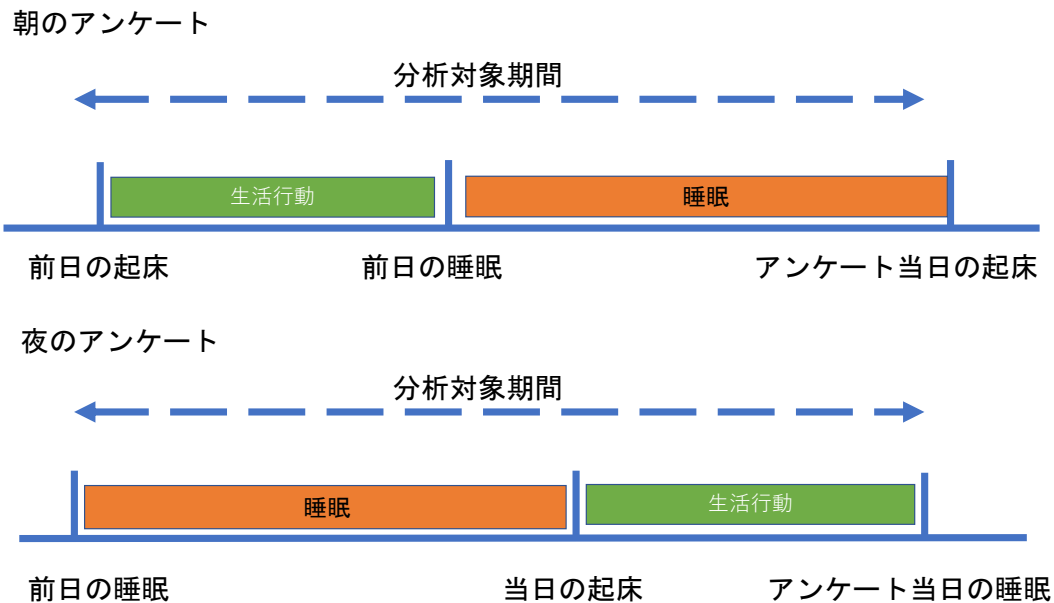


図7: 朝・夜アンケートの集計期間

実験では、ベースライン手法2種類、提案手法2種類のモデルを構築した。表5に各手法で使用する特徴量を示す。ベースライン手法1では、以下の4つの基本特徴量を用いている。

- 24時間のRRIの平均値
- 起床後4時間の平均RRI値
- 24時間のローレンツプロット面積
- 起床後4時間のローレンツプロット面積

ベースライン手法2では、ベースライン手法1の特徴量に[11]で有効性が示された睡眠時間を加えた。提案手法1は、ベースライン手法2の特徴量に、行動ごとのローレンツプロット面積と、起床後4時間の行動ごとのローレンツプロット面

積を追加する。提案手法2は提案手法1の特徴量に、行動ごとの行動時間、起床後4時間の行動ごとの行動時間、Mixed indicatorを追加したものである。このモデルを3分割クロスバリデーション法により検証した。評価指標として Accuracy と F1-measure を用いた。Accuracy と F1-measure はそれぞれ式6と式7で定義される。

$$\text{Accuracy} = \frac{\text{推定対象の正答数}}{\text{推定対象の総数}} \quad (6)$$

$$\text{F1-measure} = \frac{2\text{Recall} \cdot \text{Precision}}{\text{Recall} + \text{Precision}} \quad (7)$$

表 5: 各手法で使用する特徴量

	ベースライン1	ベースライン2	提案手法1	提案手法2
基本特徴量	X	X	X	X
睡眠時間		X	X	X
各行動のローレンツプロット面積			X	X
起床後4時間の各行動のローレンツプロット面積			X	X
各行動ごとの行動時間				X
起床後4時間の各行動ごとの行動時間				X
Mixed indicator と各行動ごとのローレンツプロット面積を積算				X
Mixed indicator と各行動ごとの行動時間を積算				X

5.2 健康状態管理システムの評価実験

5.2.1 健康状態管理システム評価実験の概要

本実験は，被験者に提案システムが予測した健康状態がフィードバックされることにより，認知や反省を促し，「行動変容が行われるか」と「健康状態が改善される可能性があるのか」を検証することを目的とする．実験ではスマートフォンのアノテーションアプリ，Web アプリを使用しながら，スマートウォッチを装着し，合計1週間通常的生活をする．実験はスマートフォンアプリを使用する2日間の予備実験，スマートフォンアプリとWeb アプリを使用する5日間の本実験に分かれている．また，被験者は12人の学生を対象としている．健康状態管理システム評価実験の概要を図8に示す．被験者は1日を通して後述するアノテーションアプリで行動のアノテーションを行う．例として図8には朝ごはん（食事），外出の準備（その他），外出を示している．被験者は夕方に提案システムを使用し，健康状態フィードバックを受け取る．提案システム使用後もアノテーションを行う．



図 8: 健康状態管理システム評価実験の概要

5.2.2 健康状態管理システム評価実験の詳細

実験で被験者は，スマートフォンアプリ，Web アプリを使用しながら，スマートウォッチを装着し，合計1週間の生活をする．被験者は起床時に健康状態やア

プリの評価を聞くアンケートに答える。また、指定された行動を行う場合にアプリ上に表示されるその行動をアノテーションする。指定する行動は、「料理」、「食事」、「外出」、「入浴」、「睡眠」、「その他」の6種類である。まず、2日間スマートウォッチを装着しながらこれらの情報を入力し予備実験は完了する。本実験では予備実験に追加して提案手法である Web アプリを用いる。Web アプリでは帰宅時か夕食時に対象行動の行動時間予定を記入する。入力する内容は入眠時間と起床時間、指定された6種類の行動時間予定を入力する。5日間スマートウォッチを装着しながら、これらの情報を入力し本実験は完了する。データ収集はアノテーションアプリの入力、Web アプリの1回目の入力時、最終確定時に収集しクラウドサーバーに保存される。また、スマートウォッチは装着中、スマートウォッチの会社が用意するサーバー上に保存される。これらの収集したデータは加工され機械学習用のデータとして Web アプリで使用される。

図9に健康状態管理システム評価実験の詳細な流れを示す。また、図のローマ数字 i~v で示される行動は被験者の1日の行動例を示している。

1~2日目 行動変容 **予備実験**


- 1.起床
- 2.起床後の行動をアノテーション
 - i. 料理
 - ii. 食事
 - iii. その他
 - iv. 外出
- 3.20:00までに帰宅
- 4.帰宅後の行動をアノテーション
 - i. 料理
 - ii. 食事
 - iii. その他
 - iv. 入浴
 - v. 睡眠
- 5.睡眠行動の入力により1日終了
- 6.起床
- 7.朝のアンケート(Google Form)

3~7日目 行動変容 **本実験**

- 1.起床
- 2.起床後の行動をアノテーション
 - i. 料理
 - ii. 食事
 - iii. その他
 - iv. 外出
- 3.20:00までに帰宅
- 4.帰宅時、もしくは18:00~19:00にアプリを使用し行動の予定を入力 (Webアプリ)
- 5.帰宅後の行動をアノテーション
 - i. 料理
 - ii. 食事
 - iii. その他
 - iv. 入浴
 - v. 睡眠
- 6.睡眠行動により1日終了
- 7.起床
- 8.朝のアンケート(Google Form)

図9: 健康状態管理システム評価実験の詳細な流れ

図 10 にアノテーションアプリの概要を示す。図 10(a)(b) は、アノテーション画面を表示している。図のように食事のボタンを押すと食事ボタンが点灯し、サーバーへデータが送信され食事時行動のアノテーションが開始される。青く点灯した後、再度食事行動のボタンを押すと青い点灯が消え、行動が終了したことを示す。図 10(c) には、ある被験者が実際にアノテーションした行動が表示されている。



(a) アノテーションアプリ 1

(b) アノテーションアプリ 2



(c) アノテーションされた行動

図 10: アノテーションアプリの概要

各行動のアノテーションアプリを入力するタイミングの定義は表 11 の通りである。

	行動の定義	開始	終了
外出	外出する	玄関から外に出る 直前	玄関から中に入った 直後
睡眠	睡眠をとる	布団に入る 直前	布団から出た 直後
食事	料理を食べる	食べ始める 直前	料理を食べ終わった 直後
入浴/シャワー	浴室で体を洗う	浴室に入る動作を 行う時	浴室から出て体を拭くなどの動作が 終了した時
料理	キッチンで料理する (レンジ調理含む)	料理を始める 直前	料理を終えた 直後
その他	上記5つに一つも 該当しない行動	その作業を開始する 直前	それらの作業を終了した 直後

図 11: 各行動のアノテーションアプリを入力するタイミング

注意：1. 外出行動はどの行動より優先される。(外出中に食事をする場合は外出行動に分類される。) 2. 自宅では、睡眠、食事、入浴、料理、外出の時以外は、その他の行動を常に点灯させる。

被験者は4.4章で示した Web アプリケーションを使用して本実験を行った。Web アプリケーションを使用する目的は健康状態予測結果をフィードバックされることで行動変容が起こるのか、行動変容が起こることで健康状態が改善されるのかを調べるためである。

実験を通して毎朝起床した後に被験者はアンケートを記入した。アンケート項目は以下のとおりで、5段階のリッカートスケールに従い回答を行った。身体的、精神的ストレスは予備実験と本実験の両方、その他の質問は本実験時にアンケートを実施した。

- 身体的ストレスはありますか？

- 精神的なストレスはありますか？
- 昨日行われたアプリの体調予測フィードバックはあなたの体調を良くする方向に働きましたか？(本実験のみ)
- 昨日行われたアプリの体調予測フィードバックはあなたの行動を変えましたか？(本実験のみ)

6. 結果

この章では、はじめにストレス推定モデルの評価結果について述べる。まず、モデルの推定精度を向上させるために行った処理である OverSampler, RandomUnderSampler, Bagging の導入結果について述べる。その後、提案手法の有効性を調べるために行った特徴の違いによる効果検証、特徴量の重要度を検証するための SAHP による分析を行った。行動変容実験では、はじめに、アプリの継続使用によりどのような変化が現れるのかを調べるため、体調とアプリの評価を聞いたアンケートによる分析について述べる。その後、アプリを使用することでどのような行動変容が行われるのかを調べるために、アプリの入力と行動時間による分析、予備実験と本実験での行動時間時間の差を検証するために平均行動時間による分析を行った。

6.1 ストレス推定モデルの評価結果

6.1.1 SMOTE-OverSampler, RandomUnderSampler, Bagging の導入結果

モデル精度を向上させるために、処理をしない手法と4つのデータ処理を行った手法の計5つを比較評価した。処理なし, OverSampler, UnderSampler, UnderSampler with Bagging, Over&UnderSampler with Bagging の4種類のデータ処理方式を適用した。SMOTE-OverSampler と RandomUnderSampler を使用した。Bagging は RandomUnderSampler の random_state の Seed 値を10回変えて10個の推定を行い、その推定値を投票で最も多い値で決定する。

表6に、これら5つの方式を提案手法1に適用した場合の Accuracy と F1-measure を示す。朝 (MQ) と夜 (NQ) の身体ストレス推定値を平均化した平均精度は、それぞれ 0.65, 0.65, 0.46, 0.44, 0.58 となった。

本研究では、高齢者の健康状態を管理することを目的としている。健康状態の管理には、高齢者の身体状態の悪化を早期に発見することが必要であるため、体調不良の日 (少数クラス) の検出が必要と考えられる。表6において、処理なしと OverSampler は高精度であるが、少数クラス (Bad) の F1 値は低い。OverSampler, UnderSampler, Bagging の組み合わせは、Bad クラスに対して、他の手法よりも高

い精度と F1-measure が示された。表 6 では、従来手法 [52] の結果のみを示しているが、他の評価手法でも同様の結果が得られている。そこで、以下の評価実験では、全ての手法に SMOTE-OverSampler, RandomUnderSampler, Bagging を使用する。

表 6: 提案手法 1 に SMOTEOversampler, RandomUnderSampler, Bagging を導入した結果. 推定値は MQ と NQ の平均値

	処理なし	OverSampler	UnderSampler	UnderSampler	UnderSampler and Bagging	Over, UnderSampler and Bagging
Accuracy	0.65	0.65	0.46	0.46	0.44	0.58
F1-measure						
Bad	0.27	0.37	0.41	0.41	0.43	0.47
Neutral	0.24	0.37	0.38	0.38	0.35	0.38
Good	0.76	0.75	0.54	0.54	0.49	0.66

6.1.2 特徴の違いによる効果検証

提案手法を含む4つの評価手法を比較した。その結果は表7に示す通りであり、4つの手法でそれぞれ0.52, 0.55, 0.57, **0.59**という推定精度（値は朝（MQ）と夜（NQ）の身体ストレスアンケートを平均して算出）を達成した。このことから、睡眠時間特徴量の追加（ベースライン2）により、精度がやや向上することが示唆された。行動ごとの生体情報特徴量、および日常生活行動時間と Mixed indicator（提案手法2）は、ベースライン1と比べて精度が大きく向上する。

表 7: 5 つの手法の推定精度. 推定値は MQ と NQ の平均値

	ベースライン1	ベースライン2	提案手法1	提案手法2
MQ: 朝の身体的ストレス	0.49	0.49	0.54	0.56
NQ: 夜の身体的ストレス	0.55	0.57	0.61	0.62
平均	0.52	0.55	0.57	0.59

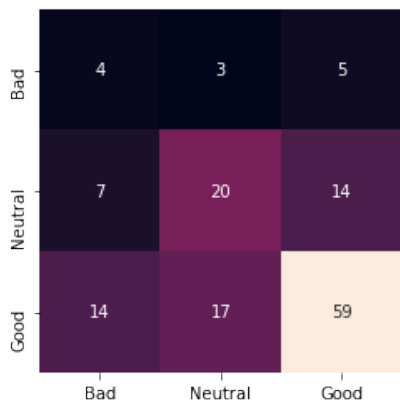
表 8: MQ における 4 つの手法の推定精度

	ベースライン 1	ベースライン 2	提案手法 1	提案手法 2	データ数
Accuracy	0.49	0.53	0.52	0.56	143
Recall					
Bad	0.35	0.05	0.15	0.23	21
Neutral	0.38	0.42	0.39	0.42	36
Good	0.66	0.61	0.67	0.70	83
F1-measure					
Bad	0.36	0.04	0.16	0.45	21
Neutral	0.34	0.38	0.38	0.44	36
Good	0.66	0.64	0.67	0.69	83

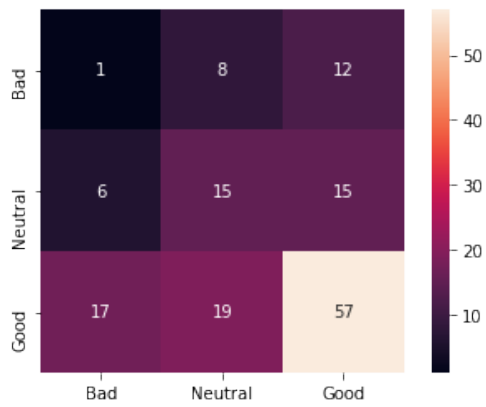
表 9: NQ における 4 つの手法の推定精度

	ベースライン 1	ベースライン 2	提案手法 1	提案手法 2	データ数
Accuracy	0.55	0.57	0.61	0.62	157
Recall					
Bad	0.56	0.54	0.53	0.64	55
Neutral	0.42	0.42	0.58	0.32	19
Good	0.57	0.61	0.67	0.69	83
F1-measure					
Bad	0.56	0.60	0.38	0.67	55
Neutral	0.32	0.31	0.42	0.28	19
Good	0.61	0.65	0.68	0.68	83


より詳細な推定結果を表 8, 表 9 に示す。また, 全ての手法による朝 (MQ) と夜 (NQ) の身体ストレス推定の混同行列をそれぞれ図 12, 図 13 に示す。提案手法 2 の図 13 では, Good の正解数が増加し, Bad と Neutral の正解数も増加している。



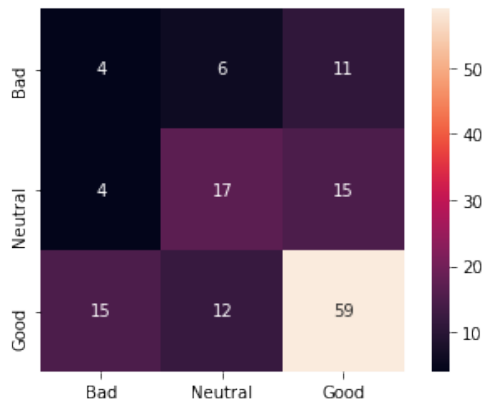
(a) ベースライン 1



(b) ベースライン 2




(c) 提案手法 1



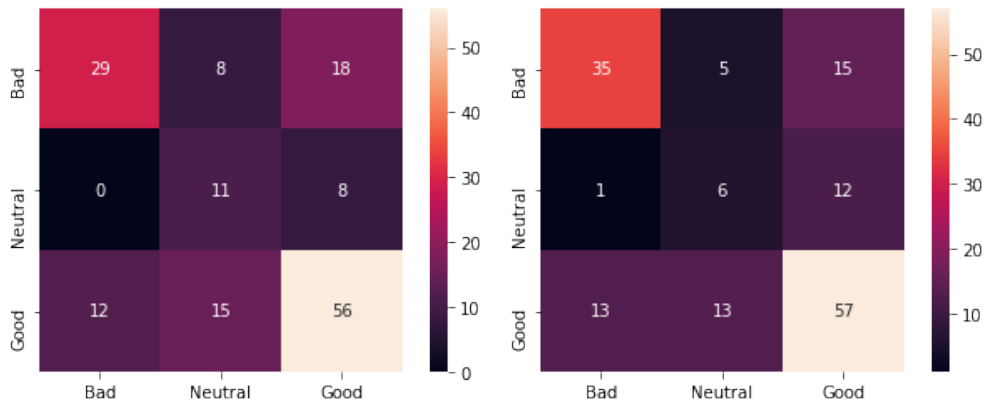
(d) 提案手法 2

図 12: 朝 (MQ) のストレス推定における 4 つの手法の混同行列



(a) ベースライン 1

(b) ベースライン 2



(c) 提案手法 1

(d) 提案手法 2

図 13: 夜 (NQ) のストレス推定における 4 つの手法の混同行列

6.1.3 SHAP による分析

特徴変数が目的変数に与える影響を調べるために、SHAP⁴ の `shap.Explainer` を使用した。図 14 と図 15 は提案手法 2 における `shap.Explainer` の結果である。Mixed indicator に関連する特徴は、寄与度の高い上位 10 位に入っている (30 特徴中)。睡眠は関連研究により重要であることが知られており、実際に睡眠に関

⁴<https://shap.readthedocs.io/en/latest/index.html> アクセス日: 1 月 30 日

連する特徴が上位 10 位以内に入っている。図 14 と 図 15 を見ると、入浴と食事のランクは寄与度が高く、RRI は最も高いことが分かる。これは、入浴は疲労回復に効果があり、食事はストレス解消に効果があると考えられるからである。




図 14: 朝のアンケート (MQ) の SHAP 値によるモデル出力への特徴量の影響

- 縦軸：各機能（寄与度の高い順，トップ 10）
- 横軸：寄与度変数（SHAP 値）の値




図 15: 夜のアンケート（NQ）の SHAP 値によるモデル出力への特徴量の影響

- 縦軸：各機能（寄与度の高い順，トップ10）
- 横軸：寄与度変数（SHAP 値）の値

6.2 行動変容実験の評価結果

6.2.1 アンケートによる分析

図 16 は縦軸に 12 人の被験者の回答の平均値，横軸に経過日数を載せている。1～2 日目が予備実験期間，3～7 日目が本実験期間である。灰色と黄色の折れ線はアプリの評価を聞いているため，3 日目からアンケートを取得している。青と赤の線は身体的・精神的ストレスについてのアンケート結果である。これらはストレスの有無を聞いているため，値が 1（ストレスがない）に近いほど健康である。図 16 における 3 日目と 7 日目を比較すると，体調が良くなっていることがわかる。

図 17 の「昨日行われたアプリの体調予測フィードバックはあなたの体調を良くする方向に働きましたか?」，「昨日行われたアプリの体調予測フィードバックはあなたの行動を変えましたか?」における 3 日目と 7 日目を比較すると，アプリに対する評価が上がっていることがわかる。




図 16: 体調を聞くアンケートの結果




図 17: アプリの評価を聞くアンケートの結果

具体的な値を知るために、表 10 を見ると、身体的ストレスを聞くアンケートにて提案システムの使用前と使用後で 2.00 ポイントから 1.33 ポイントと低い傾向になった。これは、身体的ストレスがほとんどないことを示す。精神的ストレスを聞くアンケートにて提案システムの使用前と使用後で 2.33 ポイントから 1.75 ポイントと低い傾向になった。これは、精神的ストレスがほとんどないことを示す。アプリによる体調の行動変容の質問では、2.42 ポイントから 3.17 ポイントと上昇した（高いほど良い評価）。アプリによる体調の変化の質問では、2.50 ポイントから 3.17 ポイントと上昇した（高いほど良い評価）。そのため、アプリの継続使用により健康状態の改善と健康状態フィードバックによる行動変容の可能性が上昇する事が示唆された。

表 10: アプリの評価と体調のアンケート結果

日数	体の痛みや不快感による 身体的ストレスはありますか？	精神的なストレスは ありますか？	昨日行われたアプリの 体調予測フィードバックは あなたの体調を良くする方向に 働きましたか？	昨日行われたアプリの 体調予測フィードバックは あなたの行動を変えましたか？
1日目	1.42	2.17		
2日目	1.83	2.17		
3日目	2.00	2.33	2.42	2.5
4日目	2.00	2.25	2.75	1.83
5日目	1.83	1.75	2.67	2.75
6日目	1.83	1.83	2.67	2.92
7日目	1.33	1.75	3.17	3.17

図 18, 19, 20, 21 に詳細なアンケート結果を示す。縦軸に回答数, 横軸に経過日数を載せている。




図 18: 身体的ストレスのアンケート結果

精神的なストレスはありますか？




図 19: 精神的ストレスのアンケート結果

昨日の体調予測フィードバックは
あなたの行動を変えましたか？




図 20: 体調予測フィードバックと行動変容のアンケート結果

昨日の体調予測フィードバックはあなたの
体調を良くする方向に働きましたか？




図 21: 体調予測フィードバックと体調のアンケート結果

6.2.2 アプリの入力と行動時間による分析

表 11, 図 22 にアプリの 1 回目と最終の入力, 実際の行動時間を示した. 図 22 では, 緑に 1 回目の入力, 青に最終確定した入力, 黄色に実際の行動時間を示した. 表 11, 図 22 から 1 回目の入力 (緑) と最終の入力 (青) を比較すると, 外出, 食事, 入浴の時間が上昇した. また, 1 回目の入力 (緑), 最終の入力 (青) と行動時間 (黄) を比較すると食事・入浴・その他の時間が増加した.

表 11: アプリの入力結果と実際の行動時間の比較

	外出	料理	食事	入浴	睡眠	その他
1 回目の入力	536	3	37	27	485	350
最終の入力	556	5	37	30	484	326
行動時間	385	5	53	73	450	472




図 22: アプリの入力結果と実際の行動時間の比較

システムの使用前と使用後の入浴時間が1.48倍，食事時間が1.52倍となった。これにより，アプリを使用する事で行動変容を促す可能性，さらに健康には入浴時間と食事時間が関わる可能性が示唆された。

6.2.3 平均行動時間による分析

表 12, 図 23 に予備実験時と本実験時の行動時間の比較を示した。

表 12: 予備実験と本実験の行動時間の比較

	外出	料理	食事	入浴	睡眠	その他
予備実験	5:15:14	0:04:21	0:24:46	0:18:03	7:38:53	10:17:50
本実験	4:12:29	0:01:48	0:36:32	0:27:23	7:16:41	11:24:16




図 23: 予備実験と本実験の行動時間の比較

図 23 では、行動の実施時間の合計を 24 時間とし予備実験と本実験の各行動の行動時間の比較を示した。この比較では 6.2.2 節と同じく、入浴時間と食事時間が約 12 分と約 9 分の増加が見られた。

6.3 考察

6.1.1 節では、ADASYN など他のアップサンプリング手法では精度に大きな変化が見られなかったため、アップサンプリングには SMOTE を使用し、Optuna によるハイパーパラメータ調整はデータ点数が少なくオーバーフィッティングの傾向があったため、実装しなかった。しかし、十分なデータセットが揃えば、ハイパーパラメータ調整は良い効果を発揮すると思われる。

6.1.2 節の表 7 の結果から Mixed indicator は推定精度を上げるために有効であることが示唆された。提案したストレス推定手法で使用したデータセットは、夫婦で構成されており（単身世帯は 1 世帯のみ）、行動にもばらつきがある。そのため、Mixed indicator が男女の個人差や個人間の行動時間差を緩和する働きをし

たと考える。Mixed indicator は、ストレスの状態を表すには、時間とストレスの強さを組み合わせた指標が必要になるという仮説のもと時間の指標として「活動指標」、ストレス強度の指標として「生体指標」から構成されている。そのため、ストレスには時間的な指標と生体的な指標を用いることで精度の向上が行われる。

6.2.1 節の図 16 から、提案システムを使用することで体調が良くなることが示唆された。これは、健康状態フィードバックを受け取ることでアプリ使用者は自分の体調について、認知・反省を行ったためと考える。また、アプリケーションの継続使用により行動変容が起こる可能性が上がった、これはアプリケーションの使用により、自分の行動を反省する習慣が身についたためと考える。そのため、長期間の継続使用や 1 日に複数回の使用をすることで、行動変容の可能性が高くなると考える。

6.1.3 節の結果、入浴時間と食事時間はストレス推定モデルで寄与度が高く、6.2.2 節の図 22 と 6.2.3 節の図 23 から、入浴と食事時間は健康を意識すると行動変容が起こるため、入浴と食事時間は健康状態と関係があることが示唆された。入浴と食事時間が長いという事は、精神的な余裕を示すと考える。そのため、入浴と食事時間は健康に重要な指標と考えられる。

6.4 制限

今回は 6 つの家庭内行動に絞って予測を行った。これは本研究が家事と生体情報と健康状態の関係を調べることを目的としているためである。しかし、健康状態予測に関する関連研究では、運動データやスマートフォンの使用時間などを記録している。そのため、予測精度を高くするためにも、運動量などの新しい特徴量の追加をすることも考慮すべきであると考えられる。

7. 結論

本研究では、朝夕に取得したストレス状況質問票の回答を正解値とし、各家庭内行動時の生体情報、および、生体的観点と活動的観点を含む新規提案指標 (Mixed indicator) を特徴量として、機械学習によるストレス推定モデルを構築する手法と、ストレス推定手法の結果をフィードバックし行動変容を促す健康状態管理システムを提案した。

ストレス推定手法の評価実験として、高齢者世帯 5 世帯の 1ヶ月間のデータを用いて、起床後 4 時間とアンケート回答前 24 時間の RRI 分散とローレンツプロット面積を特徴量とするベースライン手法 1、ベースライン手法 1 に睡眠時間を特徴量として加えたベースライン手法 2、行動ごとのローレンツプロット面積と行動ごとの総時間、そして、新規指標を特徴量として加えた提案手法と比較した。提案手法の平均推定精度は 59% となり、ベースライン手法 1 の 52%、ベースライン手法 2 の 55% よりも高くなった。これにより、生体的観点と活動的観点を含む提案指標がストレス推定にある程度有効であることが分かった。

また、開発した健康状態管理システムの有効性を評価するため、12 名の被験者に、2 日間の予備実験と 5 日間の本実験の合計 7 日間の評価実験を行った。評価実験では、5 段階のリッカートスケールで体調とアプリの評価、アノテーションアプリで被験者の行動時間を取得した。結果として、体調を聞くアンケートにて提案システムの使用前と使用後で平均 2.08 ポイントから 1.33 ポイントへと改善された。1.33 ポイントは体調が、かなり良くなることを示している。また、使用前と使用後の入浴時間が 1.48 倍、食事時間が 1.52 倍となった。これにより、アプリを使用する事で体調が改善される可能性、行動変容を促す可能性、さらに健康には入浴時間と食事時間が関わる可能性が示唆された。

提案したストレス推定手法の平均推定精度 59% は、十分な精度であると言えない。提案したストレス推定手法の推定精度が上がることで、健康状態管理システムのフィードバックの結果がより良くなる事で、行動変容をさらに促す可能性がある。

本研究では、健康状態の推定の推定精度を向上させるために、ウェアラブルセンサーによる心拍データおよび ADL センシングシステムによる行動データのみ

を用いた。使用したウェアラブルセンサーはFitbit Alta HRであり、RRI取得の粒度が粗い（10–15秒毎）ため、心拍変動の急激な変化を得ることができない。そのため、心拍変動の取得頻度をより細かくすることができれば、さらに精度が向上する可能性がある。

また、提案した健康状態管理システムの評価実験は学生を対象に行った。そのため、高齢者への提案システムの有効性を十分に検証しきれていない。そのため、高齢者への健康状態システムの評価実験を行う必要がある。

今後の展望として、提案したストレス推定手法の精度改善のために、行動認識システムで取得する行動の追加と、生体情報の追加が挙げられる。行動の粒度を細かくする事で、入浴や食事以外のストレスに関係する要素がわかる可能性がある。生体情報の追加により、ローレンツプロット面積以外の生体指標の作成ができ、精度が向上する可能性がある。健康状態管理システムでは、更なる行動変容を促すためのナッジ機能の追加と体調が良くなる行動予定の表示などが挙げられる。ナッジ機能の追加では、プッシュ通知にナッジを含んだ表示を行い行動変容を促す研究 [53] がある。そのため、本システムも同様にプッシュ通知などを用いてナッジを行う事で、行動変容をさらに促す。また、体調が良くなる行動予定の表示では、体調が悪くなる結果のフィードバックと合わせて、体調が良くなる行動の表示を行うことで、被験者にどのような行動を行えば良いか示す。これにより、より良い行動変容を促すことができる可能性がある。データ入力については、本研究のデータ取得は行動データをスマートフォンのアノテーションアプリを使用し、正解データをアンケートで取得している。そのため、被験者にデータ入力やアンケートへの回答という負荷を与えてしまっている。そのため、行動データでは関連研究で挙げている SALON システムによる ADL データの自動収集、正解データでは RRI やローレンツプロットの値を正解データとして使用することで、アンケートを用いず、データ入力の自動化を達成できる可能性がある。行動変容の効果はアンケートによる評価を行ったが、行動変容の効果の定量的に測定するためには、実験経済学に基づいた評価が必要である。Arno ら [54] は、ナッジによる成人の食事の選択をより健康的なものに変えることに、成功しているかを調べた。この論文では、ナッジの効果を全体的なカロリー消費の変化によって判断

した。Kimら [55] は、被験者にストレス関連のデータを振り返るフィードバックを提示することにより、行動変容を促すシステムを提案した。この論文の行動変容の計測では、ストレスを軽減させる行動を画面上に表示し、被験者がその行動を行なった回数でナッジの効果を計測した。結果として、ユーザーは「ストレッチ」、「短い Youtube クリップを見る」、「友人にメールを送る」、「スケジュールを整理する」などを例に含む 152 件のユニークな行動を行なった。これらのような評価を行う事で、ナッジ効果の定量化の可能性があると考える。これらの研究は特定の行動の変化や、行動の介入回数などを定量化している。しかし、本研究では全行動の変化を定量化する必要がある。そのため、本研究での行動変容を定量化するための指標は慎重に検討しなければならない。

謝辞

本論文の執筆，および研究を進めるにあたり，様々な方々に御協力を賜りました．ここに謝意を添えて御名前を記させていただきます．

安本慶一 教授には，研究に関する全般的な事柄に対して多大なるご指導・ご助言をいただきました．研究活動の手厚いご支援に感謝の意を表すとともに，心より厚く御礼申しあげます．

金谷重彦 教授には，ご多忙の中，論文審査委員を引き受けてくださった上で，発表の場においては様々なご助言をいただきました．感謝の意を表すとともに，心より厚く御礼申しあげます．

諏訪博彦 准教授には，研究の初期段階からの的確なご指導，およびご指摘をいただきました．特に，国際会議に同行していただき，温かいお言葉や，多くのご助言を賜りました．感謝の意を表すとともに，心より厚く御礼申しあげます．

藤本まなと 准教授には，終始適切なご指導を賜りました．ここに深謝の意を表します．

松田裕貴 助教には，日常的に研究室内の様々なことに対してご助言を賜りました．感謝の意を表すとともに，心より厚く御礼申し上げます．

三宅雅人 准教授には起業部顧問として，厳しくも温かいお言葉をかけていただきました．謹んで感謝申し上げます．

金岡恵 事務補佐員，山内奈緒 事務補佐員には，学会や出張に関する事務処理を始め，研究生生活の様々な場面でご支援いただきましたこと，謹んで感謝申し上げます．

松井智一 先輩には，研究初期から指導をしてくださり，技術的な課題に対するアドバイスや研究生生活の様々な場面でご助言を賜りましたこと，謹んで感謝申し上げます．

また研究や学生生活全般において，的確なアドバイスをくださった三崎先輩，立花先輩や安西先輩を始めとする先輩の皆様，共に研究生生活を過ごしたユビキタスコンピューティングシステム研究室と起業部の同輩，後輩には，公私ともにお世話になりました．心より感謝申しあげます．

参考文献

- [1] Matsui Tomokazu, Misaki Shinya, Sato Yuma, Fujimot Manato, Suwa Hirohiko, and Yausmoto Keiichi. Multi-person daily activity recognition with non-contact sensors based on activity co-occurrence. In *The 13th International Conference on Mobile Computing and Ubiquitous Networking (ICMU 2021)*, pp. 157–164, 2021.
- [2] Margarida Goes, Manuel Lopes, João Marôco, Henrique Oliveira, and César Fonseca. Psychometric properties of the whoqol-bref (pt) in a sample of elderly citizens. *Health and Quality of Life Outcomes*, Vol. 19, No. 1, pp. 1–12, 2021.
- [3] Aung Zaw Zaw Phyto, David A Gonzalez-Chica, Nigel P Stocks, Robyn L Woods, Jane Fisher, Thach Tran, Alice J Owen, Stephanie A Ward, Carlene J Britt, Joanne Ryan, et al. Impact of economic factors, social health and stressful life events on physical health-related quality of life trajectories in older australians. *Quality of Life Research*, Vol. 31, No. 5, pp. 1321–1333, 2022.
- [4] Enrico Sella, Nicola Cellini, and Erika Borella. How elderly people ’ s quality of life relates to their sleep quality and sleep-related beliefs. *Behavioral sleep medicine*, Vol. 20, No. 1, pp. 112–124, 2022.
- [5] The Whoqol Group. The world health organization quality of life assessment (whoqol): development and general psychometric properties. *Social science & medicine*, Vol. 46, No. 12, pp. 1569–1585, 1998.
- [6] Chishu Amenomori, Teruhiro Mizumoto, Hirohiko Suwa, Yutaka Arakawa, and Keiichi Yasumoto. A method for simplified hrqol measurement by smart devices. In *International Conference on Wireless Mobile Communication and Healthcare*, pp. 91–98. Springer, 2017.
- [7] ME Payne, KN Porter Starr, M Orenduff, HS Mulder, SR McDonald, AP Spira, CF Pieper, and CW Bales. Quality of life and mental health in older adults with

- obesity and frailty: associations with a weight loss intervention. *The journal of nutrition, health & aging*, Vol. 22, No. 10, pp. 1259–1265, 2018.
- [8] Jessie N Zurita-Cruz, Leticia Manuel-Apolinar, María Luisa Arellano-Flores, Alejandro Gutierrez-Gonzalez, Alma Gloria Najera-Ahumada, and Nelly Cisneros-Gonzalez. Health and quality of life outcomes impairment of quality of life in type 2 diabetes mellitus: a cross-sectional study. *Health and quality of life outcomes*, Vol. 16, No. 1, pp. 1–7, 2018.
- [9] Wenjun Xie, Xiaoyu Zhang, Jiao Wang, Jinghui Zhang, Jie Liu, Bei Wang, Wei Guan, Huijuan Zhang, Li Xu, Guiying Liu, et al. Evaluation of quality of life and its influencing factors after transplantation of leukemia patients based on sf-36 score: a cohort study. *Quality of Life Research*, Vol. 29, No. 7, pp. 1809–1816, 2020.
- [10] Kathrin Wunsch, Carina Nigg, Claudia Niessner, Steffen CE Schmidt, Doris Oriwol, Anke Hanssen-Doose, Alexander Burchartz, Ana Eichsteller, Simon Kolb, Annette Worth, et al. The impact of covid-19 on the interrelation of physical activity, screen time and health-related quality of life in children and adolescents in germany: results of the motorik-modul study. *Children*, Vol. 8, No. 2, p. 98, 2021.
- [11] Shuichi Fukuda, Yuki Matsuda, Yuri Tani, Yutaka Arakawa, and Keiichi Yasumoto. Predicting depression and anxiety mood by wrist-worn sleep sensor. In *2020 IEEE International Conference on Pervasive Computing and Communications Workshops (PerCom Workshops)*, pp. 1–6, 2020.
- [12] Natasha Jaques, Sara Taylor, Ehimwenma Nosakhare, Akane Sano, and Rosalind Picard. Multi-task learning for predicting health, stress, and happiness. In *NIPS Workshop on Machine Learning for Healthcare*, 2016.
- [13] Martin Gjoreski, Hristijan Gjoreski, Mitja Lutrek, and Matja Gams. Automatic detection of perceived stress in campus students using smartphones. In *2015*

International Conference on Intelligent Environments, pp. 132–135, 2015.

- [14] Alberto de Santos Sierra, Carmen Sánchez Ávila, Javier Guerra Casanova, and Gonzalo Bailador. A stress-detection system based on physiological signals and fuzzy logic. *IEEE Transactions on Industrial Electronics*, Vol. 58, pp. 4857–4865, 2011.
- [15] Elena Smets, Emmanuel Rios Velazquez, Giuseppina Schiavone, Imen Chakroun, EllieD’ Hondt, Walter De Raedt, Jan Cornelis, Olivier Janssens, Sofie Van Hoecke, Stephan Claes ほか. Large-scale wearable data reveal digital phenotypes for daily-life stress detection. *NPJ digital medicine*, Vol. 1, No. 1, pp. 1–10, 2018.
- [16] Jeen Shing Wang, Che Wei Lin, and Ya Ting C. Yang. A k-nearest-neighbor classifier with heart rate variability feature-based transformation algorithm for driving stress recognition. *Neurocomputing*, Vol. 116, pp. 136–143, September 2013.
- [17] Kalliopi Kyriakou, Bernd Resch, Günther Sagl, Andreas Petutschnig, Christian Werner, David Niederseer, Michael Liedlgruber, Frank Wilhelm, Tess Osborne, and Jessica Pykett. Detecting moments of stress from measurements of wearable physiological sensors. *Sensors*, Vol. 19, No. 17, p. 3805, 2019.
- [18] Fumi Toyofuku, Kazuhiko Yamaguchi, and Hiroshi Hagiwara. Simplified method for estimating parasympathetic nerves activity by lorenz plot of ecg rr intervals. *The Japanese Journal of Ergonomics*, Vol. 42, No. Supplement, pp. 512–515, 2006.
- [19] Michael Brennan, Marimuthu Palaniswami, and Peter Kamen. Poincare plot interpretation using a physiological model of hrv based on a network of oscillators. *American Journal of Physiology-Heart and Circulatory Physiology*, Vol. 283, No. 5, pp. H1873–H1886, 2002.

- [20] WHOQoL Group, et al. The development of the world health organization quality of life assessment instrument (the whoqol). In *Quality of life assessment: International perspectives*, pp. 41–57. Springer, 1994.
- [21] John E Ware Jr. Sf-36 health survey update. *Spine*, Vol. 25, No. 24, pp. 3130–3139, 2000.
- [22] Whoqol Group, et al. Development of the world health organization whoqol-bref quality of life assessment. *Psychological medicine*, Vol. 28, No. 3, pp. 551–558, 1998.
- [23] Lekshmi Prasad, Jean Fredrick, and R Aruna. The relationship between physical performance and quality of life and the level of physical activity among the elderly. *Journal of Education and Health Promotion*, Vol. 10, , 2021.
- [24] Rafael Zapata-Lamana, Felipe Poblete-Valderrama, Andres Ledezma-Dames, Patricia Pavón-León, Ana María Leiva, María Trinidad Fuentes-Alvarez, Igor Cigarroa, and María Antonia Parra-Rizo. Health, functional ability, and environmental quality as predictors of life satisfaction in physically active older adults. *Social Sciences*, Vol. 11, No. 6, p. 265, 2022.
- [25] Daniel McDuff, Sarah Gontarek, and Rosalind Picard. Remote measurement of cognitive stress via heart rate variability. In *2014 36th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, pp. 2957–2960. IEEE, 2014.
- [26] Jacqueline Wijsman, Bernard Grundlehner, Hao Liu, Julien Penders, and Hermie Hermens. Wearable physiological sensors reflect mental stress state in office-like situations. In *2013 Humaine Association Conference on Affective Computing and Intelligent Interaction*, pp. 600–605. IEEE, 2013.
- [27] Katarina Dedovic, Robert Renwick, Najmeh Khalili Mahani, Veronika Engert, Sonia J Lupien, and Jens C Pruessner. The montreal imaging stress task: using

functional imaging to investigate the effects of perceiving and processing psychosocial stress in the human brain. *Journal of Psychiatry and Neuroscience*, Vol. 30, No. 5, p. 319, 2005.

- [28] Gerald Bauer and Paul Lukowicz. Can smartphones detect stress-related changes in the behaviour of individuals? In *2012 IEEE international conference on pervasive computing and communications workshops*, pp. 423–426. IEEE, 2012.
- [29] Akane Sano and Rosalind W Picard. Stress recognition using wearable sensors and mobile phones. In *2013 Humaine association conference on affective computing and intelligent interaction*, pp. 671–676. IEEE, 2013.
- [30] Javier Hernandez, Rob R Morris, and Rosalind W Picard. Call center stress recognition with person-specific models. In *International Conference on Affective Computing and Intelligent Interaction*, pp. 125–134. Springer, 2011.
- [31] Asma Ghandeharioun, Szymon Fedor, Lisa Sangermano, Dawn Ionescu, Jonathan Alpert, Chelsea Dale, David Sontag, and Rosalind Picard. Objective assessment of depressive symptoms with machine learning and wearable sensors data. In *2017 Seventh International Conference on Affective Computing and Intelligent Interaction (ACII)*, pp. 325–332. IEEE, 2017.
- [32] Enrique Garcia-Ceja, Venet Osmani, and Oscar Mayora. Automatic stress detection in working environments from smartphones' accelerometer data: a first step. *IEEE journal of biomedical and health informatics*, Vol. 20, No. 4, pp. 1053–1060, 2015.
- [33] Priya Karthikeyan, Murugappan Murugappan, and Sazali Bin Yaacob. Detection of human stress using short-term ecg and hrv signals. *Journal of Mechanics in Medicine and Biology*, Vol. 13, p. 1350038, 2013.
- [34] Cornelia Setz, Bert Arnrich, Johannes Schumm, Roberto La Marca, Gerhard Tröster, and Ulrike Ehlert. Discriminating stress from cognitive load using

- a wearable eda device. *IEEE Transactions on Information Technology in Biomedicine*, Vol. 14, No. 2, pp. 410–417, 2010.
- [35] Tomokazu Matsui, Kosei Onishi, Shinya Misaki, Hirohiko Suwa, Manato Fujimoto, Teruhiro Mizumoto, Wataru Sasaki, Aki Kimura, Kiyoyasu Maruyama, and Keiichi Yasumoto. Analysis of visualized bioindicators related to activities of daily living. In *International Conference on Advanced Information Networking and Applications*, pp. 731–744. Springer, 2021.
- [36] John Cacioppo and Louis Tassinary. Inferring psychological significance from physiological signals. *The American psychologist*, Vol. 45, pp. 16–28, 02 1990.
- [37] Atsushi Miyaji, Tomokazu Matsui, Zhihua Zhang, Hyuckjin Choi, Manato Fujimoto, and Keiichi Yasumoto. Analysis on nursing care activity related stress level for reduction of caregiving workload. In *50th International Conference on Parallel Processing Workshop*, pp. 1–8, 2021.
- [38] Jennifer A Healey and Rosalind W Picard. Detecting stress during real-world driving tasks using physiological sensors. *IEEE Transactions on intelligent transportation systems*, Vol. 6, No. 2, pp. 156–166, 2005.
- [39] Elizabeth D Mynatt, Jim Rowan, Sarah Craighill, and Annie Jacobs. Digital family portraits: supporting peace of mind for extended family members. In *Proceedings of the SIGCHI conference on Human factors in computing systems*, pp. 333–340, 2001.
- [40] Michael C Mozer. 12 lessons from an adaptive home. *Smart environments: Technologies, protocols, and applications*, 2005.
- [41] B Brumitt and JJ Cadiz. Let there be light! comparing interfaces for homes of the future. microsoft research, redmond, wa 98052. Technical report, MSR-TR-2000-92, 2000.

- [42] Gaurav Jain, Diane Cook, and Vikramaditya Jakkula. Monitoring health by detecting drifts and outliers for a smart environment inhabitant. 01 2006.
- [43] Sunny Consolvo, Peter Roessler, Brett E Shelton, Anthony LaMarca, Bill Schilit, and Sara Bly. Technology for care networks of elders. *IEEE pervasive computing*, Vol. 3, No. 2, pp. 22–29, 2004.
- [44] Vikramaditya R Jakkula, Diane J Cook, and Gaurav Jain. Prediction models for a smart home based health care system. In *21st International Conference on Advanced Information Networking and Applications Workshops (AINAW'07)*, Vol. 2, pp. 761–765. IEEE, 2007.
- [45] Hyun Jae Baek, Haet Bit Lee, Jung Soo Kim, Jong Min Choi, Ko Keun Kim, and Kwang Suk Park. Nonintrusive biological signal monitoring in a car to evaluate a driver ' s stress and health state. *Telemedicine and e-Health*, Vol. 15, No. 2, pp. 182–189, 2009.
- [46] Kohei Yamamoto, Kentaroh Toyoda, and Tomoaki Ohtsuki. Spectrogram-based non-contact rri estimation by accurate peak detection algorithm. *IEEE Access*, Vol. 6, pp. 60369–60379, 2018.
- [47] Peter Walter Kamen, Henry Krum, and Andrew Maxwell Tonkin. Poincare plot of heart rate variability allows quantitative display of parasympathetic nervous activity in humans. *Clinical science*, Vol. 91, No. 2, pp. 201–208, 1996.
- [48] Laurent Mourot, Malika Bouhaddi, Stéphane Perrey, Jean-Denis Rouillon, and Jacques Regnard. Quantitative poincare plot analysis of heart rate variability: effect of endurance training. *European journal of applied physiology*, Vol. 91, No. 1, pp. 79–87, 2004.
- [49] T. Matsui, K. Onishi, S. Misaki, M. Fujimoto, H. Suwa, and K. Yasumoto. Salon: Simplified sensing system for activity of daily living in ordinary home. *Sensors*, Vol. 20, No. 17, p. 4895, 2020.

- [50] Leo Breiman. Random forests. *Machine learning*, Vol. 45, No. 1, pp. 5–32, 2001.
- [51] Nitesh V Chawla, Kevin W Bowyer, Lawrence O Hall, and W Philip Kegelmeyer. Smote: synthetic minority over-sampling technique. *Journal of artificial intelligence research*, Vol. 16, pp. 321–357, 2002.
- [52] Kanta Matsumoto, Tomokazu Matsui, Hirohiko Suwa, and Keiichi Yasumoto. Stress prediction using per-activity biometric data to improve qol in the elderly. In *International Conference on Smart Homes and Health Telematics*, pp. 196–208. Springer, Cham, 2022.
- [53] 佑磨佐藤, 智一松井, 優吾中村, 博彦諏訪, 慶一安本. 宅内行動認識モデル最適化のためのナッジを用いたアノテーション行動誘導方法の検討. マルチメディア, 分散協調とモバイルシンポジウム 2021 論文集, Vol. 2021, No. 1, pp. 11–19, 06 2021.
- [54] Anneliese Arno and Steve Thomas. The efficacy of nudge theory strategies in influencing adult dietary behaviour: a systematic review and meta-analysis. *BMC public health*, Vol. 16, No. 1, pp. 1–11, 2016.
- [55] Taewan Kim, Haesoo Kim, Ha Yeon Lee, Hwarang Goh, Shakhboz Abdigap-porov, Mingon Jeong, Hyunsung Cho, Kyungsik Han, Youngtae Noh, Sung-Ju Lee, et al. Prediction for retrospection: Integrating algorithmic stress prediction into personal informatics systems for college students ’ mental health. In *Proceedings of the 2022 CHI Conference on Human Factors in Computing Systems*, pp. 1–20, 2022.

研究業績

学術論文誌

1. Matsumoto, K.; Matsui, T.; Suwa, H.; Yasumoto, K. Stress Estimation Using Biometric and Activity Indicators to Improve QOL of the Elderly. *Sensors* 2023, 23, 535. <https://doi.org/10.3390/s23010535>

国際会議

1. Matsumoto, K., Matsui, T., Suwa, H., Yasumoto, K. (2022). Stress Prediction Using Per-Activity Biometric Data to Improve QOL in the Elderly. In: Aloulou, H., Abdulrazak, B., de Marassé-Enouf, A., Mokhtari, M. (eds) *Participative Urban Health and Healthy Aging in the Age of AI. ICOST 2022. Lecture Notes in Computer Science*, vol 13287. Springer, Cham. https://doi.org/10.1007/978-3-031-09593-1_15

国内会議

1. 松本 敢大, 松井 智一, 諏訪 博彦, 安本 慶一: 高齢者の QOL 向上に向けた生活行動データと心拍情報を使った健康状態予測, マルチメディア, 分散, 協調とモバイル (DICOMO2021) シンポジウム, 2021 年 6 月.