

特別研究報告

題目

ゆらぎ学習により推定したストレス状態に基づくウェルビーイング
空間制御手法の実装と評価

指導教員

村田 正幸 教授

報告者

原 啓太

令和 5 年 2 月 7 日

大阪大学 基礎工学部 情報科学科

ゆらぎ学習により推定したストレス状態に基づくウェルビーイング空間制御手法の実装と評価

原 啓太

内容梗概

昨今の「働き方改革」で見受けられるように我々を取り巻く労働環境は見直されつつある。長時間労働が是正され、個人のワークライフバランスに寄り添った働き方が推奨されているが、限界生産性向上による労働時間の短縮は、単位時間当たりで見れば労働者のストレスを高める可能性があり、かえって個人がストレスなく伸び伸びと過ごしている状態(ウェルビーイング)を損ねてしまう可能性がある。一般に、精神的に負荷のかかる状態においては、ある種の生体反応が現れることが知られており、ウェアラブルセンサーを用いることにより得られる生体情報から精神的な負荷状態を推定することが可能である。本報告の目標は、個々人がストレスなく活動できる空間を実現することであり、そのために、ウェアラブルセンサーによって個人から取得した生体情報に基づき、その人の心理的状态を推定し、その推定結果に応じて空調機器を制御して精神的負荷を和らげるための空間(ウェルビーイング空間)を提供する。

生体情報を用いた心理状態の推定には、ノイズの含まれる観測情報から意思決定を行う脳の認知機構をモデル化したゆらぎ学習を用いる。このモデルは、脳の中で行われる意思決定を、アトラクターを持つダイナミクスモデルにより表現したものであり、このアトラクターに前述の心理的状态の候補を対応付けている。一定の周期で生体情報を観測し、観測を行うごとに意思決定変数をベイズ推定により更新する。推定の結果、ストレス状態と判断された場合、心理状態を改善するように空間に介入する。

このような生体情報に基づくリアルタイムな制御が実現できることを示すため、部屋の温湿度に対するストレス/非ストレス状態を推定して制御を行う実験を行った。温湿度が異なる2つの部屋にてデータを収集しゆらぎ学習を行い、その後入力されたデータがどちらの部屋で取得されたものかを推定した。推定の結果82.5%精度で正しく判別することができた。空間への介入では前述の推定結果に基づきウェルビーイング空間を保つようアクチュエーターを制御できた。制御までの平均時間は20.3秒であった。

主な用語

ウェルビーイング、リアルタイムセンシング、マルチモーダル統合処理、ゆらぎ学習、Bayesian Attractor Model, ベイズ推定、アトラクター、生体情報、空間制御

目次

1	はじめに	6
2	関連研究	8
2.1	生体情報と心理状態の関係	8
2.2	ゆらぎ学習によるストレス状態の推定	8
2.2.1	ゆらぎ学習	8
2.2.2	ベイジアンアトラクターモデル	9
2.2.3	ゆらぎ学習を用いたストレス状態の推定	10
3	ウェルビーイング空間制御手法の実装	12
3.1	ストレス状態の推定	12
3.1.1	生体情報とその取得	12
3.1.2	ゆらぎ学習を用いたストレス状態の推定	14
3.2	アクチュエーターの制御	14
4	実験と評価	17
4.1	ストレス状態の推定	17
4.1.1	生体情報の取得	17
4.1.2	ゆらぎ学習を用いたストレス状態の推定	19
4.1.3	マルチモーダル統合処理	21
4.2	アクチュエーターの制御	21
4.3	考察と課題	22
5	おわりに	24
	謝辞	25
	参考文献	26

目 次

1	ウェルビーイング制御手法	12
2	E4 リストバンド ([1] より引用)	13
3	E4 リストバンド装着図	13
4	E4 streaming server ([2] より引用)	13
5	アシストサーキュレーター ([3] より引用)	15
6	動作例 (風量弱)	15
7	動作例 (風量強)	15
8	実装したシステムの概要	16
9	部屋 1 での生体情報	17
10	部屋 2 での生体情報	18
11	実験用のサンプルデータ	18
12	皮膚電位に関する確信度およびゆらぎ学習での出力	20
13	皮膚温度に関する確信度およびゆらぎ学習での出力	20
14	統合後の出力	21
15	推定結果の出力と平均の推移	22

表 目 次

1	BAM 変数説明	11
2	マルチモーダル統合処理変数説明	11
3	アシストサーキュレーター制御方針	16
4	ゆらぎ学習実行時の変数	19
5	推定結果の正答率	21
6	閾値ごとの推移を検知するまでの時間と誤検知回数	23

1 はじめに

近年、少子高齢化に伴う生産年齢人口の減少や、育児や介護との両立など働く方のニーズの多様化から私たちを取り巻く労働環境は見直されつつある。「働き方改革」で見られるように、長時間労働が是正され、また、新型コロナウイルスの流布を受け、在宅ワークなどの、個人のワークライフバランスに寄り添った働き方が推奨されている。文献 [4] では生産性の向上という課題に対し、適切な労働環境を提供するという手法を取っている。眠気を感じている労働者に対し風や光を当てるなどして眠気を覚まし、生産性を向上させることができたことが報告された。しかし、労働時間の短縮および効率化は位時間当たりで見れば労働者のストレスを高める可能性もある。

近年は人々の労働形態が多様化しており、その中で、心身と社会的な健康が維持されていること（ウェルビーイング）に特に注目が集まっている。文献 [5] によると、テレワークが個人の幸福度や生産性に繋がると判断できたのは月 10 時間から月 30 時間の間の限られたテレワークでの労働のみであった。労働時間の短縮がなされていく中で、生産性を上げつつ個人のウェルビーイングにも配慮した働き方についてはいまだ検討の余地があるとされている。個人のウェルビーイングを定量的に評価する必要があるが、ストレスと関連が高いメンタルヘルス分野においても、うつ状態やうつ病などのメンタルヘルス不調についての評価方法は開発されているのに対し、その前段階での評価法は確立していない。

ストレス状態の推定において皮膚電位活動や皮膚温度、脈波といった生体情報を用いて個々人のストレス状態の推定が可能であると報告されている [6]。しかし、生体譲歩が取得可能なリストバンド型のデバイスなどから得られる生体情報にはノイズが多く含まれる。我々の研究グループではゆらぎ学習と呼ばれる、ノイズが含まれる観測情報から意思決定を行う脳の認知の仕組みを応用した機械学習手法を提案しており、様々な応用に成功している [7]。ゆらぎ学習における観測と意思決定は Bayesian Attractor Model (BAM) [8] に基づいており、このモデルでは、観測情報に対する意思決定状態を表現したものであり、意思決定の結果を確信度付きで出力する。すなわち、観測情報にノイズが含まれていても、意思決定の結果が出力され、出力結果に対する信頼度は、確信度という尺度で表現される。また、人がストレスを感じている状態をリアルタイムに推定する技術も研究している。その一つに、ウェアラブルセンサーを用いて生体情報を取得し、ゆらぎ学習に基づく状態の推定によってその人が現在ストレス状態であるのか否かを判断することが可能であることが報告された [9]。この論文では、複数の生体情報でゆらぎ学習を行い、それぞれで得られた確信度を統合するマルチモーダル統合処理を行った。この手法により、有用でない生体情報を事前に除外することができ、個々人の快適に感じる環境に合わせたストレス状態の推定が可能となっている。

本報告では、文献 [9] の手法をもとに個々人のストレス状態の推定を行い、その推定結果

に応じて個々人が快適に過ごすことができるウェルビーイング空間を保つための空間制御手法の実装と評価を行う。ストレス状態の判別に用いるための生体情報は、ウェアラブルセンサーの一つである、スマートリストバンドを用いてリアルタイムに取得する。取得した生体情報をもとにゆらぎ学習、マルチモーダル統合処理をおこなうことにより個々人に合わせた心理状態の推定をする。その結果、ストレス状態にありウェルビーイングが損なわれていると推定された場合、ストレス状態の原因を取り除く、あるいは改善されるよう空間に制御を加える。この推定、制御をリアルタイムに行うことにより個々人がストレスを感じることなく活動できる、ウェルビーイング空間を保つための制御手法の実現を目指す。

2 関連研究

2.1 生体情報と心理状態の関係

論文 [6] では生体情報と心理状態の関係を明らかにするため、一般公開データセットである WESAD を公開している。このマルチモーダルデータセットは、15 人の被験者の手首と胸部に装着されたデバイスから記録された血流量脈波 (BVP)、心電図 (ECG)、皮膚電気活動 (EDA)、筋電図、呼吸 (RESP)、皮膚温度 (TEMP)、3 軸加速度計 (ACC) と、3 つの異なる感情状態 (ニュートラル、ストレス、アミューズメント) の感情状態に関する自己報告値が含まれている。それらのデータを元とした大量の特徴量 (生理信号や動作信号から抽出) と一般的な機械学習手法 (決定木、ランダムフォレスト、AdaBoost、線形判別分析、 k 近傍法) によりベンチマークを作成している。

データ収集には、胸部装着型と手首装着型、それぞれ RespiBAN Professional と Empatica E4 を使用している。RespiBAN 自体には ACC と RESP を測定するセンサーが搭載されており、最大 4 つのモダリティを追加することのできるハブとして機能する。すべての記録は 700Hz でサンプリングされている。RESP は呼吸誘導型プレチスモグラフセンサーを介して記録され、ECG データは、標準的な 3 ポイント ECG で記録されている。EDA 信号は被験者ができるだけ自由に動けるように、また、腹部は汗腺が密集しているため、EDA 測定に適していることから、腹直筋付近に配置されている。また、TEMP センサーは胸骨付近に配置されている。EMG データは、背骨の両側の僧帽筋上部で記録されている。Empatica E4 に関しては、すべての被験者は利き手でない側の手に装着し BVP (64Hz)、EDA (4Hz)、TEMP (4Hz)、ACC (32Hz) を記録する。これらの情報を用いた 3 クラス (平常、ストレス、興奮) あるいは、2 クラス (ストレス、非ストレス) の推定問題では、ともに高水準の推定結果を得ることができ、複数の生体情報から心理状態を推定することが可能であることが示されている。

2.2 ゆらぎ学習によるストレス状態の推定

2.2.1 ゆらぎ学習

我々の研究グループでは、後述するベイジアンアトラクターモデル (BAM) に基づく意思決定を行う機械学習手法をゆらぎ学習として提案しており、これまでに様々な応用に成功している [7]。

人間の脳は複雑な認知、タスクを同時に行なうことができる。この脳の秘密は人間の脳を含む全ての生体システムに存在する「ゆらぎ」に存在すると考えられている。生体システムではノイズを除去するのではなくノイズを利用することで、高い自由度を持つことができ

る。実際に脳の活動を測定すると、次の行動を決める安静時と呼ばれる状態で様々な状態に対する選択肢のゆらぎが起こっている。これは、脳が次に取りうる選択肢の候補のアトラクターを用意している状態と考えられる。これらの候補を行き来した後、状況に適したアトラクターの選択が確率的に行われる。環境が変化するたびにシステムの状態はアトラクターを移り変わる。このような脳の確率的な振る舞いはBAMからモデル化することができる。

文献 [7] ではこのゆらぎのコンセプトに基づき、ノイズが含まれる観測情報におけるアトラクターを活用した主要な研究結果がまとめられている。文献では、今後、深層学習の性能向上には計算能力上の限界があると予想しており、ゆらぎ学習のような計算負荷の低い手法にも流れが向かうと予想している。脳が実際に確率的に機能しているかどうかはまだ十分に解明されていないもののその不確実性を扱う能力は動的に変化するシステムにおいて、シンプルで効率的な制御機構を開発するためのインスピレーションとして活用することができることが主張されている。

2.2.2 ベイジアンアトラクターモデル

論文 [8] では、意思決定のタスクを、観測した情報を元に複数の選択肢から一つを選ぶ問題とし、意思決定が行われるまでの過程をベイズ推定により定式化した確率的な枠組みを提案している。脳の中で行われる意思決定のモデル化のために、意思決定を表す変数およびその変数がアトラクターを持つダイナミクスモデルを定義して、このアトラクターに前述の選択肢の一つ一つを対応付けている。

脳は時間をかけて感覚情報を蓄積し、十分な情報が集まった時点で意思決定をしているというのが一般的な見解である。しかし、この蓄積メカニズムが具体的にどのように作動するかについては、重要かつ未解決の問題である。例えば、感覚処理には進行中の意思決定に関するフィードバックがあり、そのモデル化や、人がどのように自分の意思決定に対する確信度を計算するかモデル化が、その一例である。さらに、現在の意思決定モデルでは、通常、単一の意思決定のみを考慮し、その意思決定がなされた時点でモデリングを停止してしまう問題がある。BAMは、これらの課題を解決するモデルとして提案されたものである。

BAMでは、一定の周期で情報を観測し、観測を行うごとに脳内の意思決定変数をベイズ推定により更新する。推定した意思決定変数が、どのアトラクターに近いのか、どの程度近いのかを表す値を確信度 (confidence) と定義する。BAMでは外部からの刺激を入力としたベイズ推定により、観測対象が事前に用意した選択肢のどれに該当するのかを判断 (意思決定) する。BAMは意思決定の状態 z_t を保持し、外部からの入力 x_t を受けることで状態 z_t を更新する。ベイズ推定において状態 z_t は一点として扱われるのではなく、観測や脳の状態の曖昧さ、不確実さを反映した確率分布 $P(z_t)$ で表現される。選択肢の個数 (n) に応じ

た数だけ、 z の存在する状態空間の中に安定点 (アトラクター) Φ_1, \dots, Φ_n を用意し、 z_t が Φ_i に十分近づいたとき、 i 番目の選択肢を取るという意思決定を行う。 z_t は確率的に表現されているため、 $z_t = \Phi_i$ である確率密度 (確信度) を導出し、確信度を用いた意思決定がなされる。

次に、状態の更新と意思決定の詳細について説明する。状態の更新は、入力 x_t を得たときに、意思決定状態 z_t の事後分布 $P(z_t|x_t)$ をベイズ推定により求めることで行う。 x_t と z_t には、次の生成モデルが仮定されている。

$$z_t - z_{t-\Delta t} = \Delta t f(z_{t-\Delta t}) + \sqrt{\Delta t} W_t \quad (1)$$

$$x_t = M\sigma(z_t) + V_t \quad (2)$$

ここで、 $f(z)$ はアトラクターモデルの一つであるホップフィールドダイナミクスを表し、このダイナミクスは複数のアトラクターを持つ。 n をベイジアンアトラクターモデルに用意する選択肢の数とするとき、 f が n 個のアトラクター Φ_1, \dots, Φ_n を持つように設計する。 M は各選択肢に対応した観測値を並べた行列であり、 $M = [\mu_1, \dots, \mu_n]$ である。 σ は値域が 0 から 1 である多次元シグモイド関数である。 W_t, V_t はノイズ項であり、それぞれ $W_t \sim \mathcal{N}(0, \frac{q}{\Delta t} I)$, $V_t \sim \mathcal{N}(0, r^2 I)$ である。 \mathcal{N} は正規分布であり、それぞれにおける標準偏差は q, r である。これらによって生成モデルにおけるダイナミクスと観測のノイズが定まるため、 q はダイナミクスの不確かさ、 r は観測の不確かさと呼ばれる。また、 I は単位行列である。

前述の生成モデルをベイズの定理により逆方向に推定することで、意思決定のモデルが得られる。生成モデルの非線形性を考慮して Unscented Kalman Filter (UKF) を用いて近似計算を行う。この状態推定によって得られるのは z_t の事後確率分布 $P(z_t|x_t)$ である。そのため脳の内部状態がどのアトラクターに近いのかは確率密度 $P(z_t = \Phi_i|\mathbf{x})$ の大きさに基づき判定される。

2.2.3 ゆらぎ学習を用いたストレス状態の推定

論文 [9] ではゆらぎ学習を用いたリアルタイムなストレス推定手法を提案している。この手法ではマルチモーダル統合処理をゆらぎ学習に組み合わせており、複数の生体情報において観測される特徴量を、モダリティごとに準備した BAM への入力として用いており、生体情報ごとに得られる確信度を統合する。各生体情報 k での確信度は確信度ベクトル $F_k = P(z_t^k|x_0^k : t)$ で表され、確信度が閾値以下であれば除外し、有用でない生体情報が推定結果に影響を与える可能性を排除している。有用であると判断された生体情報の確信を式 (3) によって統合する。 $modality$ は各生体情報を表し、 w_i は i 番目の生体情報の重み、 \bar{F}_i は正規化された生体

表 1: BAM 変数説明

z_t	意思決定の状態
x_t	外部からの入力
$P(z_t)$	z に対する確率分布
n	選択肢の個数
Φ_1	選択肢 i に対応するアトラクター
$f(z)$	ホップフィールドダイナミクス
M	各選択肢に対応した観測値を並べた行列
σ	値域が 0 から 1 である多次元シグモイド関数
M	各選択肢に対応した観測値を並べた行列
W_t	ノイズ項 $W_t \sim \mathcal{N}(0, \frac{q^2}{\Delta t} I)$
V_t	ノイズ項 $V_t \sim \mathcal{N}(0, r^2 I)$
\mathcal{N}	正規分布
q, r	標準偏差
I	単位行列

情報 i の確信度ベクトルを表す。

$$F = \sum_{i \in \text{modality}} \frac{W_i \bar{F}_i}{\sum_i w_i} \quad (3)$$

十分なデータの得られた 22 名の被験者の生体データを用いた実験を行い、ストレス状態とストレスではない（ベースライン）状態の推定を行った結果、単一の生体情報では判別不可能であった状態推定が、マルチモーダル統合処理により判別できることが示されている。本報告ではこの手法を実装し、実際にリアルタイムにストレス状態の推定を行うことができることを示すとともに、その結果を用いて即時にアクチュエータを制御できることを示す。

表 2: マルチモーダル統合処理変数説明

k	各生体情報
F_k	確信度ベクトル
modality	各生体情報
w_i	i 番目の生体情報の重み
\bar{F}_i	正規化された生体情報 i の確信度ベクトル

3 ウェルビーイング空間制御手法の実装

ウェルビーイングは主観的な指標であり、個人個人によって異なるものである。そこで本研究では、生体センサーを用いて様々な生体情報をセンシングし、得られた生体情報から人の心理的な状態を推定する手法を用いることとする [9]。推定結果をもとに、アクチュエーターを制御することで空間に介入し、ストレス状態を和らげるように空間を制御し、個々人が不快感を覚えることなくのびのびと活動できるウェルビーイング空間の実現を図る。本研究では先行研究に基づき心理状態の推定をおこない、ウェルビーイング空間が保たれるよう推定結果からアクチュエーターを制御する、図1のようなウェルビーイング空間制御手法の実装及び動作検証を行う。

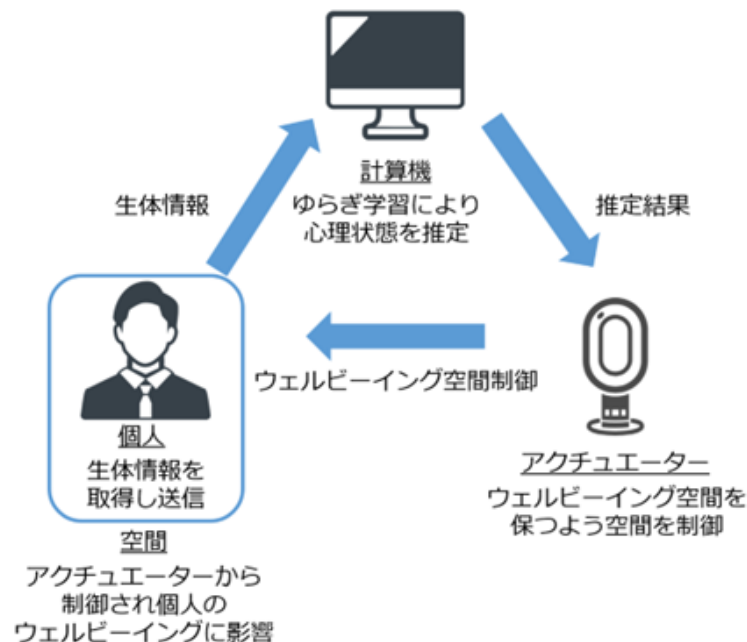


図 1: ウェルビーイング制御手法

3.1 ストレス状態の推定

生体情報のリアルタイムな取得、および、先行研究 [9] に基づく個々人のストレス状態の推定を行う。

3.1.1 生体情報とその取得

本研究では Empatica 社製の E4 リストバンド (図 2) を用いて生体情報を取得する。E4 リストバンドでは 3 軸加速度 (ACC), 血液量パルス (BVP), 電気皮膚反応 (GSR), 心拍間

隔 (IBI), 皮膚温度 (TMP) の生体情報が取得可能である。

E4 リストバンドから得られる生体情報を、ゆらぎ学習を行う計算機に中継するために、Empatica 社が提供するストリーミングサーバーを構築する。本報告においてはノート型計算機にストリーミングサーバーソフトウェアをインストールし、Bluetooth により E4 リストバンドと接続する。図 4 に示すように、ストリーミングサーバーは複数の E4 リストバンドからの生体情報の取得、ネットワークを介したデータの送信を行う機能を持つ。また、データはリストバンドにも蓄積され、通信が一時的に途絶えた場合には、再接続した際に、送ることができていなかったデータを再送信できる機能を持つ。リストバンドとストリーミングサーバーとの通信は非同期的に行われるため、個々人に対してデータを集め、分析を行うことができる。



図 2: E4 リストバンド ([1] より引用)



図 3: E4 リストバンド装着図




図 4: E4 streaming server ([2] より引用)

3.1.2 ゆらぎ学習を用いたストレス状態の推定

ゆらぎ学習を用いたストレス状態の推定は、前述のストリーミングサーバー上で行う。ゆらぎ学習によるストレス推定プログラムとストリーミングサーバーソフトウェアとは TCP を用いたソケット通信により相互に通信を行う。あらかじめストリーミングサーバーに対して、取得する生体データの種別を指定することで、ストリーミング情報としてソケットに生体データが届く。

ゆらぎ学習は少ないサンプル数からも学習を行うことが可能であるという特徴がある。本報告ではストレス/非ストレス状態の判別を行うために、人が快適と感じた空間で取得した生体情報、人が不快と感じた空間で取得した生体情報（皮膚温度、電気皮膚反応を利用）の 2 種類のデータセットを作成した。このデータセットをアトラクターへの学習用と、ストレス推定のテスト用に分割して評価を行う。

3.2 アクチュエーターの制御

ウェルビーイングを保つためのアクチュエーターの制御として、人の五感を対象とした様々なアプローチが考えられる。例えば、強いストレスを検知した際に休憩を促す音楽を流す、本人の好む香りをアロマディフューザーによって空間に広げることで、ストレスの改善を図ることができると考えられる。本報告における実験では、室内の温度と湿度を変化させた際に感じる不快感をストレスと捉え、提案したシステムによって、そのストレスの検出を行うこと、それによるアクチュエーターのリアルタイムな制御が可能であることを示す。

本報告では、アクチュエーターとしてダイキン社のアシストサーキュレーターを用いる。図 6、図 7 に示すような送風調整機能に加え、風向の調整が可能となっている。アシストサーキュレーターは Linux 搭載の小型計算機とシリアル通信を介して接続されており、この計算機を介してアシストサーキュレーターに制御信号を送ることができる。本報告における実装では、前述の通り、ストリーミングサーバーが動作する機器上でゆらぎ学習によるストレス状態の推定を行うため、アクチュエーターの制御もこの機器が行う。



図 5: アシストサーキュレーター ([3] より引用)




図 6: 動作例 (風量弱)



図 7: 動作例 (風量強)

前述のゆらぎ学習にて推定した被験者のストレス/非ストレス状態に基づいてアシストサーキュレーターを制御する。ゆらぎ学習では認識結果を確信度という値によって出力する。ゆらぎ学習が利用している BAM の特性上確信度は急激には変動しない。ただし本報告においては、確信度そのものを制御に使用するのではなく、確信度の高い側の状態を出力として現

在から過去にわたって一定期間中にストレスと判定された回数が閾値を上回った、または下回ったタイミングにアクチュエーターを動作させることとする。この閾値を変更することで、誤った制御が行われる頻度、リアルタイム性を調節できると考えられる。アトラクター0とアトラクター1で表される状態1、状態2においてストレス状態を状態1、非ストレス状態を状態2とすると、アシストサーキュレーターへの動作指針を表3のように定める。今

表 3: アシストサーキュレーター制御方針

	平均 > 閾値	平均 ≤ 閾値
行う制御	通常の空間制御	ストレスを減らす空間制御

回の実験環境のように、ストレス状態を作り出す要因が温度の高さであるとき、ストレスを減らす空間制御とは送風を強めることに対応すると考えられる。また、通常の空間制御とは弱い送風、もしくは停止に対応すると考えられる。送風によるストレス状態の改善は多々報告されており [10,11]、ストレスの要因が温度以外の場合でも有効となる可能性がある。

以上に基づく実装したシステム全体を図8に示す。

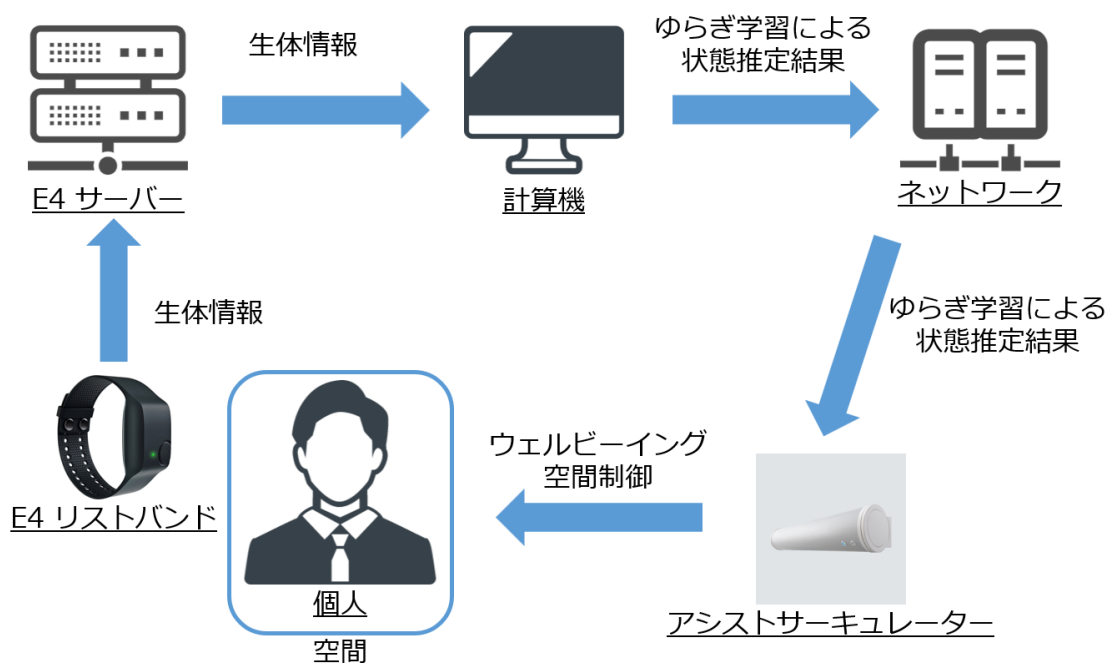


図 8: 実装したシステムの概要

4 実験と評価

提案した手法の評価を行う。1名の男性被験者から生体情報を取得した。2つの異なる環境の部屋を用意し、E4 リストバンドを用い生体情報を取得した。また、そのデータを用い推定したストレス/非ストレス状態をもとに、アクチュエーターの制御が行えたかを確認した。

4.1 ストレス状態の推定

4.1.1 生体情報の取得

データの取得を行った2つの部屋は以下のような環境になっている。

- 部屋1 (ストレス状態) : 室温 26 °C、湿度 70%
- 部屋2 (非ストレス状態) : 室温 23 °C、加湿なし

それぞれの部屋で約2分間リストバンドを装着し生体情報を取得した。取得したデータは図9、図10に示したものであり、このデータをもとに学習、および推定、制御を行う。各生体情報の100サンプルを用いて事前学習を行い、実験では事前学習で利用したデータ以外の部分を用いた。ストレス状態の推定に用いるデータは、図11のように、それぞれの部屋で計測したデータを100個ずつ交互に並べ替えて入力した。




図 9: 部屋1での生体情報




図 10: 部屋 2 での生体情報




図 11: 実験用のサンプルデータ

4.1.2 ゆらぎ学習を用いたストレス状態の推定

はじめに、事前学習用のデータから特徴量を抽出しアトラクターに記憶させる。これはそれぞれ部屋1（ストレス状態）、部屋2（非ストレス状態）で計測した特徴量に対応する。事前学習の終了後、11で示した生体情報を入力することで、ゆらぎ学習は、その生体情報が事前学習で作成したアトラクターどちらに相当するかを推定し、確信度を出力する。推定の結果としては、前述の通り空間制御に用いるためのストレス状態か非ストレス状態を表す値（アトラクターのインデックス）を出力し、出力が0であれば部屋1、1であれば部屋2にいたときのストレス状態として推定された、ということになる。推定結果は皮膚電位活動を用いた際に、図12のようになり、皮膚温度を用いた際に図13のようになった。図に記載したラベルは、表4に示した通りであり、部屋の切り替わりの時点で、入力する生体情報に対して得られる確信度、およびストレス状態の出力結果が変化していることが確認できる。

表 4: ゆらぎ学習実行時の変数

confidence	現在の状態が作成したアトラクターに相当するかの確信度 値が大きいほど確信度が高いことを示す
confidence_room1	現在の状態が部屋1に相当する状態であるかどうかの確信度
confidence_room2	現在の状態が部屋2に相当する状態であるかどうかの確信度
output	最も高い確信度のアトラクターの番号 '0'が部屋1に相当し、'1'が部屋2に相当する




図 12: 皮膚電位に関する確信度およびゆらぎ学習での出力




図 13: 皮膚温度に関する確信度およびゆらぎ学習での出力

4.1.3 マルチモーダル統合処理

2.2.3 節で述べた方法を用い、各生体情報での結果を統合し、状態の判定を出した。統合後の結果は図 14 のようになった。また、入力したデータにおける本来の状態（部屋 1、部屋 2）と得られた出力（'0', '1'）が一致しているかの正答率を用いてこの結果を用いて制御を行うことの妥当性を評価した。正答率は表 5 のようになった。全区間での平均正答率は 82.5% であり、このストレス状態の推定結果に基づき制御を行っても大きな誤制御を起こすことがないことが予想される。




図 14: 統合後の出力

表 5: 推定結果の正答率

	0-199	200-399	400-599	600-799	800-999	1000-1199	全区間合計
正答率	87.5%	84.5%	78.5%	82.0%	80.5%	82.0%	82.5%

4.2 アクチュエーターの制御

3.2 節で述べた方針に基づきアクチュエーターを制御する。本実験では部屋 1 が高温多湿で人がストレスを感じる状態、部屋 2 を人が心地よいと感じるウェルビーイング空間として

いる。そのため、現在の状態が部屋1であると推定された場合空間に介入をする。介入のタイミングは20個の推定結果（20秒相当）の平均を常に取り、状態が部屋1にいるためにストレスが生じている判断した際に機器を制御し風を強め、状態が部屋2にいるためにストレスが発生していないと判断したタイミングで機器の風量を戻す制御を行った。推定結果とその平均の推移を図15に示す。なお、初期状態は制御が必要ない快適な部屋2であり、出力は1となることが期待される。平均値をとることにより区間400-500のような出力が細かく変化している区間において、機器の制御が頻繁に生じることが避けられる。閾値を0.7、0.5、0.3とした際に、実際に制御を行った時点、実際に入力の状態が切り替わった時点から制御を行ったタイミングまでの遅延は表6のようになった。ストレス状態を検知するまでの平均検知時間は閾値を0.5としたとき20.3秒となった。制御における通信時間は平均10ms程度であり、これは検知時間に影響を与えることはなかった。比較対象として別の閾値(0.3, 0.7)でも検証したところ、閾値が低いほどストレス状態に対応するアトラクター1から非ストレス状態を表すアトラクター2への推移の検知が早くなり、一方で閾値を0.7に設定すると図15の区間400-500の間にある変動の影響を受けることがなかった。




図 15: 推定結果の出力と平均の推移

4.3 考察と課題

実験と評価から考察されることを以下に記す。

表 6: 閾値ごとの推移を検知するまでの時間と誤検知回数

閾値	非ストレス 平均検知時間	ストレス状態 平均検知時間	ストレス状態 誤検知回数	非ストレス状態 誤検知回数
0.3	13.1	22.3	2	0
0.5	17.2	20.3	1	0
0.7	21.2	19.7	0	0

取得した生体情報に関して 取得した2つの生体情報で、部屋1、部屋2にいる被験者の状態を推定することができていた。図11からわかるように、皮膚温度では2つの状態が区別しやすい生体情報であったことが分かる。このことは使用しているE4リストバンドが脇の下などで計測する体幹温度ではなく、皮膚温度を計測するものであり、外気温の影響を受けやすくなっていることが考えられる。個々人の心理状態に対応させるために生体情報を取得しているため、外的要因である室温が直接影響を与えるのは好ましくない可能性がある。制御の妥当性を示すためにも、この問題に対しては正答の判定を入力したデータがどちらのものか、ではなく個々人のストレス/非ストレスに対しての正答率をみる必要があると考えられる。

アクチュエーターの制御に関して 閾値を低く設定すれば非ストレス状態の検知が早くなるが、一方誤った制御を行う可能性が高くなる。閾値を高くすることで、ストレス状態の推定結果の変動により誤って非ストレス状態を検出し、結果サーキュレーターの風量を弱めてしまうという状況に比べると、閾値を低く設定する方が非ストレス状態となる空間を作り出せるため、低い閾値の方が適していると思われる。しかし、これらの程度は個々人や環境に合わせて設定されるべきである。

今回は実験的に20データ(20秒相当)ごとに平均を取る方法を採用したが、この期間を短くすればストレス状態の推定結果に対して制御が実施されるまでの時間は短縮される。しかし、今回の実験においてはそれぞれの部屋での生体データを交互に入力したために、推定された状態は定期的に推移する結果となったが、実際の利用シーンを考えると、状態の推移に細かな変動が含まれる場合も考えられる。このような場合、平均を算出する期間を短くすればするほど平均値は不安定になる。このように平均を算出する期間もまた、個々人や環境に合わせて設定されるべきである。

5 おわりに

個々人のストレス状態の推定を行い、その推定結果に応じてウェルビーイング空間を保つための制御手法の実装と評価を行った。ウェアラブルセンサーによって個人から取得した生体情報に基づき、その人の心理的状态を推定し、リアルタイムに個々人のウェルビーイングを改善するよう空間を制御する手法を実装することができた。

生体情報に基づくリアルタイムな制御が実現できることを示すため、部屋の温湿度に対するストレス/非ストレス状態を推定して制御を行う実験を行った。温湿度が異なる2つの部屋にて生体情報を取得しゆらぎ学習を行い、その後入力されたデータがどちらの部屋で取得されたのかを推定した。82.5%の精度で正しく判別することができた。空間への介入では前述の推定結果に基づきウェルビーイング空間を保つようアクチュエーターを制御し平均20.3秒で空間に制御を加えることができた。

本報告での実験では2つの状態の部屋のデータを交互に入力したが、現実では徐々に生体情報が変化する。今後はそのようなに対する動作の検証を行う。また、制御の結果を受けての生体情報の変化を観察し、また制御を行う自動的に個人のウェルビーイングを保つプラットフォームの実装を目指す。

謝辞

本報告をするにあたり、ご多忙の中丁寧にご指導、ご教授いただきました、大阪大学大学院情報科学研究科の村田正幸教授に心より深く感謝を申し上げます。ならびに、本報告を進めるにあたり、大阪大学大学院情報科学研究科の小南大智助教には、方針や進捗の確認、論文執筆指導など手厚くご指導していただきました。心より感謝申し上げます。また、平素よりご指導いただきました、大阪大学大学院情報科学研究科の荒川伸一准教授、大下裕一准教授に心より感謝申し上げます。最後に、日々の学生生活を支えてくださった家族、友人、村田研究室の皆様に感謝の意を表し、謝辞とさせていただきます。

参考文献

- [1] “e4 wristband”, <https://www.empatica.com/en-int/research/e4/>. (Accessed on 02/09/2023).
- [2] “E4 wristband for Developers”, <https://developer.empatica.com>. (Accessed on 12/21/2022).
- [3] “DAIKIN assist-circulator”, <https://www.ac.daikin.co.jp//assist-circulator>. (Accessed on 02/07/2023).
- [4] 向後卓磨, 辻川剛範, 木内幸浩, 西野淳, 橋本哲: “浅い眠気モデル予測制御によるオフィスでの生産性向上の実証”, IEICE Conferences Archives The Institute of Electronics, Information and Communication Engineers (2019).
- [5] 峰滝和典: “テレワークや仕事の柔軟性が就業者の幸福度・生活満足度・仕事と家庭の両立ストレス・生産性にもたらす影響についての実証研究” 日本情報経営学会, pp. 105–108 (2020).
- [6] P. Schmidt, A. Reiss, R. Duerichen, C. Marberger and K. Van Laerhoven: “Introducing wesad, a multimodal dataset for wearable stress and affect detection”, Proceedings of the 20th ACM international conference on multimodal interaction, pp. 400–408 (2018).
- [7] M. Murata and K. Leibnitz: “Fluctuation-Induced Network Control and Learning: Applying the Yuragi Principle of Brain and Biological Systems”, Springer (2021).
- [8] S. Bitzer, J. Bruineberg and S. J. Kiebel: “A Bayesian attractor model for perceptual decision making”, PLoS Computational Biology, **11**, 8, p. e1004442 (2015).
- [9] R. Yoshida: “Stress detection from biological information by Yuragi learning and multimodal Integration”, Master’s thesis, Graduate School of Information Science and Technology, Osaka University (2023).
- [10] 佐藤英樹, 赤林伸一, 坂口淳, 桑原亮一: “通風時の室内における快適性評価手法に関する基礎的研究”, 日本建築学会環境系論文集, **75**, 647, pp. 59–66 (2010).

- [11] 久保博子, 磯田憲生, 日向麻由美, 井上雄二: “夏期における室内変動気流の温熱的快適性に関する研究: その 1 風向変化の影響について”, 空気調和・衛生工学会大会 学術講演論文集 平成 13 年, pp. 1305–1308 (2001).