

人とモノへの装着型センサを用いた行動計測によるメンタルワークロード推定  
～床拭き掃除のケース～

Mental workload estimation based on behavior monitoring  
using sensors attached on person and object : A case of floor mopping

志田原 萌美† 早川 侑花† 辻 愛里‡ 藤波 香織†‡  
Moemi SHIDAHARA Yuka HAYAKAWA Airi TSUJI Kaori FUJINAMI

## 1 はじめに

医療現場 [1] や自動車の運転時 [2] に、ヒューマンエラーに起因する事故が多く発生している。作業中の情報はワーキングメモリに保持される [2]。ワーキングメモリは一度に保持できる情報量や保持時間に制限があることから負荷がかかりやすく、過負荷時は処理能力が低下する [3]。このときワーキングメモリにかかる負荷を認知負荷 [4]、認知負荷量をメンタルワークロード (MWL) [5] と呼ぶ。篠原ら [3] は日常的に作業者の認知資源量を推定することでエラーを防ぐべきだと述べており、Haapalainen ら [6] は、MWL 推定について、日常生活行動への適用のためにリアルタイムかつ客観的な推定を行うことの重要性を述べている。

本研究では、日常行動時のウェアラブルセンサによる行動計測から、MWL の定量的な推定を目的とする。着目する日常行動の要件として、a) 器具を用い、器具にセンサを装着可能、b) 全体的な身体動作を伴うこと、c) 開始から終了までに一定の時間を要すること、と定義する。以上を満たす日常行動として、フローリングワイパー (ワイパー) を用いた床掃除 (床掃除) を対象とする。床掃除時の加速度・角速度データ (行動データ) 収集を行うと共に、質問紙による主観的な MWL の測定を行う。行動データから算出される特徴量を説明変数、MWL の主観評価値を目的変数とする回帰モデルを構築し、MWL の定量的な推定手法を提案する。

## 2 関連研究

### 2.1 センシングによる人の内在状態推定

MWL を含めた、人の内在状態を推定する研究では、質問紙等を用いた主観の評価によって内在状態の推定を行っている [7]。しかし、主観の評価は個人の主観に左右されるため、個人差を生みやすく、回答者が誤った判断による回答を行う可能性も排除できない。質問紙による自己評価において、実直な自己評価でなく社会的に望まれる回答を行う場合がある [8]。また、実験後の質問紙では、記憶保持に認知資源を割くことが作業負荷の増加につながることやリアルタイムな評価が困難であるという問題がある [9]。そこで、内在状態の客観的な指標として、脈波等の生体信号や身体動作計測により得られる行動データといった、定量的に計測可能な値を用いることが有効だと考えられる。

† 東京農工大学 大学院 生物システム応用科学府 生物機能システム科学専攻、

Department of Bio-Functions and Systems Science, Tokyo University of Agriculture and Technology

‡ 東京農工大学 大学院 工学研究院 先端情報科学部門、Division of Advanced Information Technology and Computer Science, Tokyo University of Agriculture and Technology

清水ら [10] は脳波や脈拍などの生体信号を用いて自動車ドライバーの感情計測を行い、安静時と比べて走行時の方が感情推定精度が低下することを明らかにした。白崎ら [11] は心電、脈拍、呼吸、皮膚電位を計測する 4 つの生体センサを用いて感情の快・不快・覚醒度の識別を試み、識別が妥当であることを示した。

このように、センサによって収集した数値と主観的評価の関係性を明らかにすることで内在状態が推定できる可能性がある。こうした定量的なデータを用いた推定は客観的な評価が可能であり、MWL 推定においても有効であると考えられる。

### 2.2 MWL 推定に関する研究

#### 2.2.1 主観的指標を用いた推定

MWL の主観的評価の方法として NASA-Task Load Index (NASA-TLX) [7] が知られている。NASA-TLX は米国航空宇宙局で開発された評価指標 [12] である。一対比較法によってそれぞれの尺度の重要度を評価し、尺度ごとの評価点に重みをかけて平均したものを加重平均ワークロードスコアとする。芳賀ら [7] は NASA-TLX の下位尺度を I) 精神的な欲求、II) 身体的な欲求、III) 時間的切迫感、IV) 課題の遂行、V) 努力、VI) 葛藤水準、とした訳語を用い、日本語版 NASA-TLX を作成した。また、この作成した主観的指標の有効性を検討するため、円周トラッキング課題を実施し、評価指標の MWL 推定における有効性を明らかにした。

#### 2.2.2 行動的指標を用いた推定

行動的指標とは作業成績等を MWL の程度とみなす指標であり、二重課題法が多く用いられている [12]。渥美ら [13] は歩行タスクと 2 種類の提示媒体を用いた暗算課題を用い、マルチタスク下でタスクの作業成績による認知負荷の評価を行った。その結果、提示媒体により主観的指標による認知負荷の程度が異なることを明らかにした。さらに、聴覚的な刺激の提示は視覚的な提示に比べ、負荷が大きいことを主張している。また、芳賀ら [7] は、視覚探索課題、暗算課題、トラッキング課題の 3 課題を用い、日本語版 NASA-TLX を用いて定性評価を行った。その結果、課題の作業困難度による MWL の程度の識別が可能であることを示した。このように行動的指標を用いた MWL 推定では、二重課題法や課題全体の負荷を変化させる手法が妥当であると考えられる。

#### 2.2.3 客観的指標を用いた推定

客観的指標を用いた MWL の推定方法として、脳波 [14] や心電図 [15] 等の生体信号を用いた推定が多く行われている [16]。しかし、生体信号を用いた研究では、センシングを行うための専用の機器や機器を有した空間を利用するという制約が課されることから、日常生活への適用が困難である [6]。梶原ら [3] は、歩行時の加速度データを用い、歩行の自動化の程度から認知負荷推定を

行った。その結果、認知負荷が中程度の場合は歩行の自動化が行われる一方で、高程度の場合は歩行の自動化に失敗することを明らかにした。この研究から、客観的指標を用いた MWL 推定が有効であることが示唆された。

### 3 MWL 推定システム

図1にシステムの概要を示す。3軸加速度センサ(ATR-Promotions社のTSND151[17])と慣性計測装置(IMU)内蔵イヤホン型デバイス(eSense[18])を用いて、床掃除中の頭部、手首、ワイパーの柄の加速度・角速度データ(行動データ)を取得する。行動データは加速度・角速度の各3軸と3軸合成加速度の計7次元のデータを含む。収集する行動データに対してウィンドウへの分割、スライディングウィンドウの処理を行い、ウィンドウ内のデータから算出される特徴量を回帰モデルの説明変数とする。特徴量は、時間領域から10種類(平均、標準偏差、最大値、最小値、範囲、分散、中央値、歪度、尖度、平均絶対偏差)の特徴量と、周波数領域から4種類(ピーク周波数、ピーク周波数のパワースペクトル密度、エネルギー、エントロピー)の計14種類を設定した。ウィンドウサイズ(WS)や特徴量は後述するパラメータを用い評価実験にて回帰性能の比較を行う。また、回帰モデルの目的変数にはNASA-TLXの加重平均ワークロードスコアと篠田ら[19]が簡易精神疲労尺度に用いた4項目(精神負担、単調感、注意力の低下、心的飽和)の計5つのMWL指標を用いる。

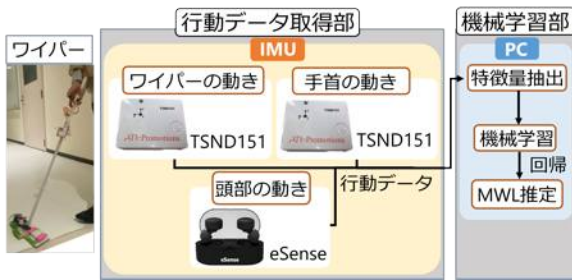


図1 MWL 推定システム概要

## 4 データ収集実験

### 4.1 実施内容

床拭き掃除中のMWL推定モデル構築のためのデータ収集を20代の12名(男性:6名,女性:6名)を対象として実施した。実験手順を図2に示す。床に書かれた縦線に沿って掃除範囲を満遍なく掃除するタスクを、後述の作業困難度ごとに5回ずつ行わせた。順序効果を相殺するため、被験者間の課題の順序を6通りに入れ替えて実験を実施した。また、センシングデバイスを用いた床掃除への慣れのために練習時間を設け、ルートの確認や掃除方法の確認を行った。各作業後にNASA-TLXと精神疲労尺度の質問紙に回答させた。NASA-TLXスコアを構成する6つの項目について0から100の値で回答を取得し、精神疲労尺度は、簡易精神疲労尺度に用いた4項目(精神負担、単調感、注意力の低下、心的飽和)について0から100の値で回答を取得した。

### 4.2 作業困難度の設定

目的変数とするMWLの主観評価値にばらつきを持たせるため、実験時のサブタスクとして記憶探索課題を用い、表1のような3段階の作業困難度を設定した。記憶探索課題の作業成績取得のために、ジョイスティック

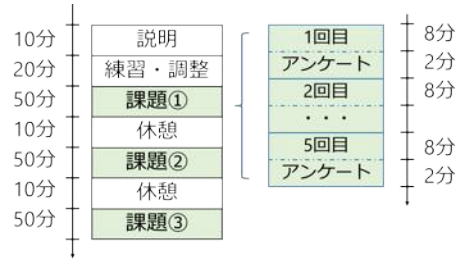


図2 データ収集の手順

表1 課題設定

作業困難度	タスク内容
低	床掃除のみ
中	床掃除+記憶探索課題(難易度低)
高	床掃除+記憶探索課題(難易度高)

(ELEGOO社のJoystick Module[20])をワイパーに装着した。作業成績による検証は行わず、実験時の被験者のタスクに対するモチベーション維持のために用いた。記憶探索課題は6種類の音源で構成し、難易度低では1つの音源を、難易度高では2つの音源を記憶させた。記憶した音が聴こえたら、ワイパーの柄に装着したジョイスティックを右に傾け、それ以外の音が聴こえたら左に傾けるよう指示した。

### 4.3 実験環境

実験環境を図3に示す。掃除範囲は1)模造紙、2)模造紙を敷いた段ボール、3)ポスター、の3種類の素材を設定し、3部屋を掃除する想定で掃除範囲を区別した。1)、2)、3)の所要時間がそれぞれ1分、1分、30秒程度であった。そこで、データ量確保のため参加者に依らず5分以上の実験時間を確保できるように、掃除順序を1)→2)→3)→2)→1)→1)とした。実験時の様子を図4に示す。作業中の行動データ取得とデータ処理用の動画取得のため、参加者の手首にバンド、頭部にイヤホン、ウェアラブルカメラを装着させた。

### 4.4 実験結果

1タスクあたり平均1時間7分39秒のデータを収集した。収集したデータに対し、実時間とタイムスタンプの一致と後述するターンの処理のためにアノテーションを行った。

## 5 推定モデルの評価

### 5.1 推定手法の概要

本研究におけるMWL推定手法の概要を図5に示す。まず、実験で得られた行動データに後述するターンのデータの処理を施し、ウィンドウサイズ(WS)単位ごとに区切る。WS内のデータを用いて特徴量を計算する。その後、機械学習による推定(回帰)モデル構築を行う。本稿では機械学習アルゴリズムによる精度の差異について検証を行うため、他のアルゴリズムを用いたモデルの構築も行った。詳細は後述する。また、モデルの構築では使用するセンサの部位、特徴量、WSをパラメータとし、パラメータの組み合わせによる精度の差異を交差検証により評価する。

### 5.2 パラメータ

使用するセンサの部位、特徴量、WSをモデル構築時のパラメータとし、パラメータの組み合わせによる精度




図3 実験環境

比較を行う。使用するセンサの部位は頭部、手首、ワイパーの3部位とした。特徴量は全ての特徴量を使用(all)、加速度由来のみ使用(acc)、角速度由来のみ使用(gyro)、時間領域のみ使用(time)、周波数領域のみ使用(freq)、の5条件とした。また、WSは実験で扱う行動を基準に定めるべき[21]であり、本研究で注目すべき行動単位は1歩ごと、もしくは掃除範囲の端でのターンごとであると考えた。観察の結果、1歩は1.2秒以内に収まり、1ターンごとの間隔は4.8秒以内に収まること分かったため、1.2秒と4.8秒に中間として2.4秒を加えた3条件をWSとした。以上のパラメータを用い回帰性能を比較する。

### 5.3 評価指標

各モデルを絶対平均誤差 (Mean Absolute Error ; MAE) を用いて評価する。MAEは回帰問題において、予測値と実測値の差の絶対値の平均を表す指標である。MAEは以下の式で表される。

$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (1)$$

ここで、 $y_i$ は実測値、 $\hat{y}_i$ は予測値、 $n$ はデータ量を表す。MAEが0に近いほど精度が高いといえ、本研究で構築したモデルのMAEは0~100の値を取りうる。

### 5.4 機械学習アルゴリズムによる精度の違い

モデル構築において、検証データと訓練データに同一人物のデータのみを含むモデル(個人特化型モデル)の精度が最高となると考えた。行動データによるMWL推定における精度の上限を調査するため、個人特化型モデルの精度検証を行った。より高い精度でMWLを推定可能な機械学習アルゴリズムを明らかにするため、LightGBM (LGBM)、Random Forest (RF)、多変量線形回帰 (MLR)、サポートベクター回帰 (SVR) の4アルゴリズムを用いて個人特化型モデルを構築し、精度比較を行った。



図4 実験時の様子




図5 推定手法の概要

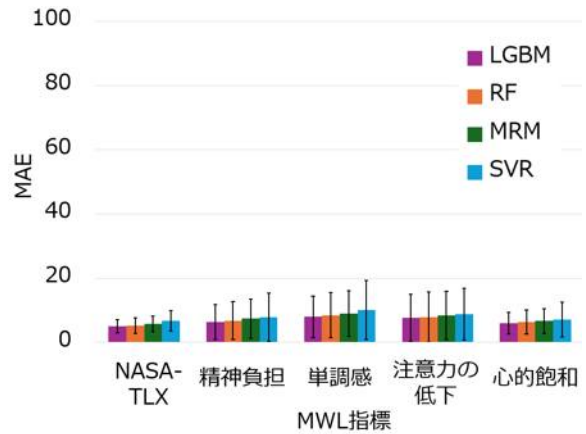


図6 機械学習アルゴリズムによる個人特化型モデルの精度の差異

検証結果を図6に示す。図6より、LGBMやRFを用いたモデルの精度が他のアルゴリズムを用いたモデルよりも高くなった。よって、MWL推定モデルにおいてLGBMによるモデル構築が適していると考え、以降の検証はLGBMを用いて行う。

### 5.5 利用シナリオごとの精度の違い

訓練データと検証データの分布について3つのシナリオを想定している。訓練データに同様の傾向をもつデータのみを含んでいる場合を個人特化型モデル、訓練データに検証データと同様の傾向をもつデータが一部分に含まれている場合を全員モデル、訓練データと検証データのデータ分布が異なる場合を汎用モデルとする。各シナリオごとに検証を行うため、3種類のモデルを構築した。また、この作成したモデルの概要を図7に示す。個人特化型のモデルは訓練データに1被験者のデータのみ、全員モデルは全12人の被験者データを含む。この2つのモデルは10分割交差検証により検証した。加えて、全12人の被験者データの内、訓練データと検証データに同一被験者のデータを含めない分割を行う1人抜き交差検証を行った。本稿では、この評価により検証したモデルを汎用モデルと呼ぶ。

LGBMを用い、利用シナリオによる精度の違いを検証した。検証結果を表2に示す。3つのモデルの内、目的




図7 構築するモデルの種類

表 2 利用シナリオごとの精度の違い

目的変数	評価シナリオの種類	MAE の最小値
NASA-TLX	個人特化型モデル	5.0
	全員モデル	10.3
	汎用モデル	21.3
精神負担	個人特化型モデル	6.4
	全員モデル	13.9
	汎用モデル	20.7
単調感	個人特化型モデル	8.0
	全員モデル	12.9
	汎用モデル	16.6
注意力の低下	個人特化型モデル	6.0
	全員モデル	16.8
	汎用モデル	31.0
心的飽和	個人特化型モデル	7.6
	全員モデル	16.5
	汎用モデル	33.0

変数によらず個人特化型モデルの精度が最も高かった。各モデルについて、MWL 推定に寄与する条件を明らかにするため、モデルを構築するパラメータについて述べる。個人特化型モデルを構成するパラメータについて表 3 に示す。表 3 の MAE は全 12 の被験者モデルの内、精度が最高となったモデル（最良モデル）の MAE の平均値を示し、センサ部位、WS、特徴量は MWL 指標ごとに最良モデルを構成するパラメータを調査し、最頻となったパラメータを示す。MWL 推定の精度が高いモデル

表 3 個人特化型モデルの各最良モデルにおける MAE の平均値と最頻パラメータ

目的変数	センサ部位	WS[s]	特徴量	MAE
NASA-TLX	手首	1.2	all	5.0
精神負担	頭部	1.2	all	6.4
単調感	手首	1.2	all	8.0
注意力の低下	手首	1.2	all	6.0
心的飽和	手首	1.2	all	7.6

ルはセンサ部位は手首、WS は 1.2 秒、特徴量は all のパラメータを用いたモデルが多いことが分かった。

次に、全員モデルについて、MWL 推定精度が最高となったモデル（最良モデル）の MAE とモデルを構成する条件を表 4 に示す。表 4 より、最良モデルにおいて、目的変数によらず WS は 1.2 秒、特徴量は all のパラメータを含んでいることが分かった。また、センサ部位は頭部、もしくは手首が最良モデルの条件となった。汎用モデルについて、最良モデルの MAE とモデルを構成する条件を表 5 に示す。表 5 より、目的変数によって最良モデルを構築するパラメータが異なることが分かった。しかし、汎用モデルについては、モデルを構築する条件による MAE の差異が他の 2 モデルに比べて小さい傾向があった。目的変数に依らず差異は小さく、MAE の標準偏差は 5 以下となった。

表 4 全員モデルの最良モデル

目的変数	センサ部位	WS[s]	特徴量	MAE
NASA-TLX	手首	1.2	all	10.3
精神負担	手首	1.2	all	13.9
単調感	頭部	1.2	all	16.8
注意力の低下	頭部	1.2	all	16.5
心的飽和	手首	1.2	all	12.9

表 5 汎用モデルの最良モデル

目的変数	センサ部位	WS[s]	特徴量	MAE
NASA-TLX	柄	4.8	gyro	33.0
精神負担	頭部	1.2	gyro	20.7
単調感	柄	2.4	all	33.3
注意力の低下	手首	1.2	all	36.3
心的飽和	手首	1.2	gyro	20.0

## 5.6 作業者行動を考慮した場合の精度の違い

データ収集実験で掃除範囲の端でのターンの方法について被験者に指示を行わなかったため、ターン時の被験者の動きは特に個人差が大きい可能性がある。よって、ターンに基づく動作を削除し、データ処理の有無による精度の差異について検証を行った。ターン処理において 3 人の被験者にデータの欠損が生じたため、計 9 被験者のデータを用いて検証を行った。ターンの定義を図 8 に示す。図 8 の緑色部はターンによって身体が傾く箇所を示し、ターンの姿勢部とし、橙色部は掃除範囲の端でのターン箇所を示し、ターン部とする。ターンに基づく姿勢の変化はターンの姿勢部とターン部で生じると考え、ターンに基づく動作時のデータの削除をおこなった。

検証結果を図 9 に示す。図 9 はターンの処理の有無による精度比較の結果を示す。目的変数によらずターンの処理を行ったほうが MWL 推定モデルの精度が高くなることが分かった。

## 6 考察

### 6.1 利用シナリオの違いと精度の差異について

3 モデルの精度比較を行った結果、個人特化型モデルの精度が最高であったことから、MWL 推定において 1 個人のデータに特化したモデルの精度が向上する傾向があると考えられる。個人特化型モデルについて目的変数によらず、MWL 推定モデルの MAE が最大で 8.0 であったことから、高精度で MWL 推定が可能であることがわかった。一方で、精度が最低であった汎用モデルについても心的飽和の推定の場合、MAE が 20.0 となっており、行動データによる MWL 推定の妥当性が窺える。

### 6.2 MWL 推定に寄与する条件について

まず、センサ部位について、個人特化型モデルでは手首、全員モデルでは手首や頭部を用いたモデルが最良となった。汎用モデルにおいて、パラメータによる精度の差が小さかったことを考慮すると、MWL 推定において手首のセンサが推定に寄与する可能性が高い。

手首の行動データはスマートウォッチ等、腕時計型端末によりセンシングが可能である場合が多い。その場合、すでに普及している端末での MWL 推定が可能である。よって、MWL 推定システムを日常生活へ自然に導入できるため、手首のデータを用いたモデルの精度が高いことは実用可能性が高いと考えられる。次に、特徴量

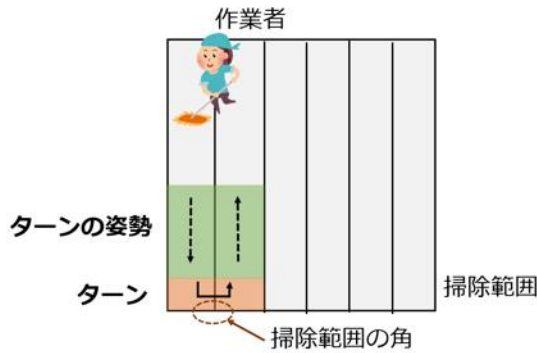


図 8 ターンに基づく作業者行動の定義

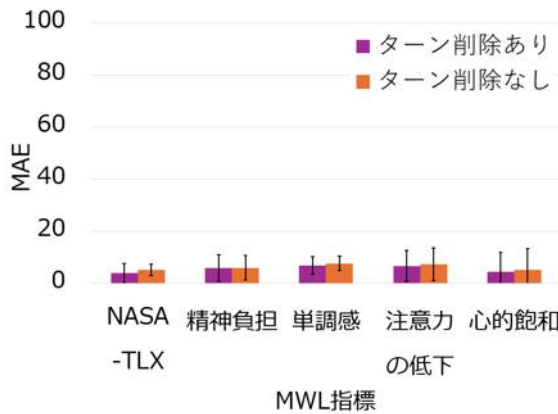


図 9 LGBM を用いたターン処理の有無による精度検証

について、モデルの種類に依らず all を用いた最良モデルが多かった。all を用いた場合、他の特徴量パラメータに比べデータ量が多くなる。そのため、データ量が多いほど MWL 推定のモデルの精度が向上する可能性が窺えた。最後に WS について、個人特化型モデルと全員モデルでは 1.2 秒、汎用モデルでは 1.2 秒や 4.8 秒の最良モデルが多かった。1.2 秒は掃除範囲での端でのターンに着目した WS であり、行動特徴をふまえた WS の精度が向上する可能性が窺えた。また、1.2 秒は今回の検証において設定した WS の内、最小の値であり、モデル構築時のデータ量が最大であった。

以上より、MWL 推定モデルを構築するパラメータにおいて、データ量が多いほど推定精度が向上する可能性が窺えた。今後はデータ量による精度の違いについても検証を行う必要がある。

### 6.3 作業者行動の考慮について

ターンのデータ処理を行うことで、機械学習アルゴリズムによらず MWL 推定精度の向上が見られた。このことから、直進のみのデータを用いた場合に MWL 推定精度が向上する可能性がある。今後は特徴量重要度の検証により、MWL 推定に寄与する特徴量を明らかにし、ターン処理の必要性について詳細な検討を行う。ターンの削除を行う場合、システムへの応用時にはデータ収集時に作業者行動の識別が必要となる。よってターン部かどうかの識別可能性についても検討する。

## 7 おわりに

本研究では、日常行動時のウェアラブルセンサによる行動計測による MWL の定量的な推定を目的とした。日常行動時の行動データと質問紙による MWL の主観評価

を収集し、収集データを用いた回帰モデルの構築、評価を行った。モデルの精度評価により LGBM を用いたモデルの精度が高いこと、個人特化型モデルの精度が高いことがわかった。このことから、シナリオとして、1 人分のデータを収集できた場合、そのデータから LGBM を用いた回帰モデルを作成することで、MWL 推定が高精度で可能となることが分かった。また、汎用モデルによる心的飽和の推定で MAE が 20.0 に留まることが分かった。このことから MWL 推定において、行動データを用いることはシステムへの実用可能性が高いことがわかった。

MWL 推定に寄与する条件の検証では、直線時のデータを抽出するとモデルの推定精度が向上することが分かったため、一直線に歩く動作が MWL 推定に適している可能性が窺えた。システムへの実用を考えると、直線時のデータであるかどうかの識別可能となることで MWL 推定の精度が向上する可能性がある。また、手首のデータを用いたモデルの精度が他の部位のデータを用いたモデルよりも MWL 推定精度が向上したことから、既に普及しているスマートウォッチ等の装着型デバイスにより日常生活での自然なセンシングの可能性が窺えた。特徴量と WS の検証では、データ量が多いほど MWL 推定の精度が高いことが分かったため、今後はデータ量と精度の相関について検証する必要がある。

また、本研究では、日常行動の内、床掃除に着目してモデルの構築を行ったが、頭部データのみの利用を考えると、他の行動についても適用できる可能性がある。床掃除のように行動に方向を伴い、頭部単体を動かす等頭部に独立した動きを伴わない行動であれば、頭部データによる MWL 推定が可能であると考えられる。今後は他の日常行動での適用についても MWL 推定の妥当性について検討する必要がある。

### 参考文献

- 古幡. “医療システムにおけるヒューマン・エラー” 人間工学, Vol.17, No.4, pp.167-174(1981).
- 田久保. “交通事故データによる運転者のヒューマンエラーと心的負荷の一考察” 国際交通安全学会誌, Vol.30, No.3, pp. 299-308(2005).
- 篠原 他. “日常生活における注意経験と主観的メンタルワークロードの個人差” 人間工学, Vol.43, No.4, pp. 201-211(2007).
- 山岡 他. “ハード・ソフトウェアデザインの人間工学講義, 第 2 章” 株式会社武蔵野美術大学出版局 (2002).
- 徳田 他. “サッカー型眼球運動から運転者のメンタルワークロードを推定する研究” 第 54 回自動制御連合講演会論文集, p.63(2011)
- E.Haapalainen et al. “Psycho-physiological measures for assessing cognitive load” In *Proc. UbiComp'12*, p.30(2010)
- 芳賀 他. “日本語版 NASA-TLX によるメンタルワークロード測定 各種室内実験課題の困難度に対するワークロード得点の感度” 人間工学, Vol.32, No.2, pp. 71-79(1996)
- Fernández-Ballesteros, R. et al. “Self-report measures” Evidence-based outcome research: A practical guide to conducting randomized controlled trials for psychosocial interventions, pp. 95-122(2008)
- T.Kosch et al. “Workload-aware systems and interfaces for cognitive augmentation” arXiv preprint arXiv:2010.07703(2020)
- 清水 他. “深層学習を用いた心電位によるドライバー感情推定” 自動車技術会論文集, Vol.50, No.2, pp.505-

- 510(2019)
- [11] 白崎 他. “音楽動画視聴時における生体センシングによる感情推定の精度評価” In IEICE Conferences Archives. The Institute of Electronics, Information and Communication Engineers(2019)
- [12] 芳賀. “MWL の理論と測定, 第 2 章” 日本出版サービス株式会社 (2001)
- [13] 渥美 他. “心身マルチタスク状況下における認知タスク負荷評価の検討” 第 31 回人工知能学会全国大会論文集第 31 回 (2017)
- [14] D.Conway et al. “The effect of stress on cognitive load measurement.” In Human-Computer Interaction-INTERACT 2013, Part IV 14, pp. 659-666(2013).
- [15] 宮治 他. “生体情報を利用した AdaBoost によるドライバ認知負荷状態の検知.” 情報処理学会論文誌, Vol.50, No.1, pp.171-180(2009)
- [16] F.Kawsar. “Earables for personal-scale behavior analytics” *IEEE Pervasive Computing*, Vol.30, No.3, pp. 83-89(2018)
- [17] ATR-Promotions. “小型無線多機能センサ「TSND151」” <https://www.atr-p.com/products/sensor.html> (Accessed on 06/04/2024).
- [18] F.Kawsar. “Earables for personal-scale behavior analytics” *IEEE Pervasive Computing*, Vol.17, No.3, pp. 83-89(2018)
- [19] 篠田 他. “二重課題法によるメンタルワークロード要因の心理生理的評価” 人間工学, Vol.34, No.1, pp. 37-44(1998)
- [20] ELEGOO. “Elegoo uno r3 project the most complete starter kit tutorial - elegoo official” <https://www.elegoo.com/en-jp/blogs/arduino-projects/elegoo-uno-r3-project-the-most-complete-starter-kit-tutorial>(Accessed on 06/07/2024).
- [21] F.Chen et al. “Multimodal behavior and interaction as indicators of cognitive load” *ACM Trans Intell Syst Technol*, Vol.2, No.4, pp. 1-36(2013)
- [22] Apple. “Apple Vision Pro が登場 — Apple が開発した初の空間コンピュータ” <https://www.apple.com/jp/newsroom/2023/06/introducing-apple-vision-pro/>(Accessed on 06/08/2024).
- [23] 梶原. “加速度センサによる working rythm の測定と脳にかかる認知負荷の推定” 生体情報計測による感情の可視化技術. 株式会社技術情報協会 (2020)