

腕装着型センサによる飲水量推定法の提案

濱谷 尚志^{1,a)} Moustafa Elhamshary¹ 内山 彰¹ 東野 輝夫¹

概要:

人体の約60%を占める水分の摂取量と排出量のバランスを維持することは生命活動維持において重要である。本研究では日常生活で容易に装着可能な腕装着型センサを用いた飲水量の推定手法を提案する。腕の複雑な動きから飲水に関連するモーションおよび飲水中の細かいモーションを認識するため、本手法では時間的な認識スケールの異なる二種類の分類器(マクロ行動分類器・マイクロ行動分類器)を組み合わせる。さらに飲水中の細かいモーションにおける慣性センサの計測値を用いて飲水量推定モデルを構築し、毎回の飲水量を推定する。評価のため合計16人の学生から約22時間のマクロ行動、合計950回以上の飲水におけるデータを収集した結果、提案手法により日常生活における代表的な行動の中から適合率72.6%、再現率73.5%で飲水行動を認識可能であり、さらに実際に飲水を行っている区間を適合率92.8%、再現率97.0%の精度で認識できることが分かった。また、飲水中の腕方向および親指方向の加速度の積分値を説明変数とした線形回帰モデルにより、毎回の飲水量を平均誤差1.5[g]、標準偏差29.5[g]で推定できることを確認した。

1. はじめに

水は人体の約60%を占めている。体内の水分は呼吸や皮膚からの蒸散、発汗などにより時々刻々と失われ、脱水が進行するとめまい・頭痛・認知機能障害などの症状を生じることが知られている[1]。ヒトの一日の水分喪失量のめやすは2500mlとも言われており[2]、食事による水分摂取以外に1200mlの水分を飲水によって摂取することが望ましい。通常、人体は脱水が進行すると口渇感を感知するため、それに応じて水分を補給することが可能である。一方、高齢者や子どもは水分の不足に気づきにくいいため、自動で体内水分量を把握することが重要である。他にも、飲酒量を自動かつリアルタイムでモニタリングすることは、アルコールの飲み過ぎの防止などに役立つ。

しかしながら、一日の飲水量を把握するためには飲水の度に体積を計量したり、ペットボトル・コップなどの容器単位で計数する必要があり日常生活において管理しきれない事態が生じうる。この問題を解決するため、Trago Cap[3]、Hydrate Spark[4]などの飲水量をセンシング可能なボトル型デバイスが市販されている。これにより、ボトルを使用している間は自動的に飲水量を把握することができる一方で、常にそのボトルを使用しなければならない制約を伴う。

一方、人が装着したセンサを用いて利用者の日常生活における様々な行動を認識する研究も数多くなされている。腕装着型センサを用いた食事中の行動認識[5]や、薬瓶を

開ける動作や取り出す動作の認識[6]など、健康管理分野での活用が期待されている。先行研究[7]では、腕に装着した高精度なモーションセンサ、および肩と腕に装着した一対の磁気センサを用い、機械学習アルゴリズムにより飲水時の細かいモーションや容器内の水分量の推定を実現している。また、喉に装着したマイクより取得した嚙下音に基づき飲水量を推定する取り組みもなされている[8]。

これらの手法に対し、本研究では日常生活においてセンサ装着の負担を最小限にし、利用者の生活を妨げることなく一日の飲水量を継続的にトラッキングすることを目的とする。その実現のため、多くの人が身につける腕時計に着目し、ウェアラブルセンサの先駆けとして普及しつつあるスマートウォッチ内蔵センサのみを用いて飲水量を推定する手法を提案する。提案方式では、身体の中でも特に動きが激しい腕の慣性センサの計測値に対し、行動認識の時間的なスケールの異なる二種の分類器を組み合わせ、飲水行動とそれに伴う細かいモーションを認識する。この方式により飲水と推定される区間に対してのみ飲水量推定アルゴリズムを適用し、高精度な飲水量推定を目指す。さらに、900回を超える飲水データの分析に基づき飲水量の推定に有用な特徴量の検討を行った結果、腕方向および親指方向の加速度の積分値が有効であることが明らかになった。これらの指標を説明変数とした線形回帰モデルの構築により、多様な飲水パターンにおける飲水量の推定を実現する。

提案手法の評価のため、合計16人の学生から約22時間のマクロ行動、969回の飲水におけるデータを収集した結果、日常生活における代表的な行動の中から適合率72.6%、再現率73.5%で飲水行動を認識可能であり、さらに実際に

¹ 大阪大学 大学院情報科学研究科
Graduate School of Information Science & Technology, Osaka University

^{a)} h-takasi@ist.osaka-u.ac.jp

飲水を行っている区間を適合率 92.8%、再現率 97.0%の精度で認識できることが分かった。また、飲水中の腕方向および親指方向の加速度の積分値を説明変数とした線形回帰モデルにより、毎回の飲水量を平均誤差 1.5[g]、標準偏差 29.5[g] で推定できることを確認した。以上の提案手法を用いて 172 本のペットボトルでの飲水においてボトルごとの合計飲水量の推定を行った結果、平均誤差 7.3[g]、標準偏差 152.9[g] で推定が可能であり、おおむねボトルの容量の ±30%以内の誤差で合計飲水量を推定できることを確認した。

2. 関連研究

2.1 腕装着型センサを用いた行動認識

近年、日常生活においてスマートフォンやスマートウォッチに内蔵される慣性センサを用いた行動認識が盛んに行われている。中でも、食事の認識や薬の摂取など、健康管理を目的とした研究が多くなされている。食事時の行動認識においても、食事時間 [5], [9] や咀嚼 [10], 食事内容 [11] など、推定の対象は幅広い。薬の摂取の推定 [6] では、薬瓶を開ける動作、掌に取り出す動作を認識することで、決められた時間に服用しているかを記録できる。こういった行動では決まったモーションを日常的に繰り返すため、その際に生じる慣性センサの波形を収集し、機械学習アルゴリズムを用いて行動を認識することが主流である。近年では隠れマルコフモデル (HMM) や条件付き確率場 (CRF) など、特徴量間の時系列的な依存関係を考慮した高度なモデルを用いた手法も数多く提案されており、行動認識において高い性能を示すことが分かってきている。本研究においても、HMM よりも高い性能が報告されている CRF を用いて飲水行動を二段階のスケールで認識する。

2.2 CRF を用いた行動分類

CRF は人の行動認識 [12], [13] の他、文意の認識 [14] や人の移動パターンの認識 [15] などに用いられており、その応用は幅広い。CRF では観測に基づき隠れ状態の系列をラベリングする。この際、各状態 (ラベル) は近傍のラベルに依存するというマルコフ性を仮定している。この特性により、例えば食事であれば (1) 食器を使う (2) 料理を口に運ぶ (3) 噛むといった細かいモーション間の時系列的な依存関係をモデル化し、従来の特徴量 (=観測値) のみに基づく機械学習アルゴリズムよりも高精度に行動を認識できることが報告されている。一方で、この特性より、細かい時間幅での行動認識を行う場合に大局的なラベル間の関係を考慮することが困難になる。本研究ではこの解決のため、時間的なスケールの異なる二種類の CRF を用い、大局的な行動認識による飲水行動全体の検出および飲水行動中における細かいモーションの認識を組み合わせた手法を

提案する。

2.3 飲水量の推定

水分摂取は血液の循環や新陳代謝などの身体の基幹機能を支えており、人体の生命維持における最重要行為の一つである。特に健康管理の重要な高齢者介護の現場において水分摂取量は血圧や体温と同様に管理されるべき項目であるにも関わらず、自動記録されるに至っていない [8]。また、運動時は発汗が盛んになり全身から水分が失われる。過剰な脱水は判断力の低下や持久力の低下をまねき、体温の上昇による熱中症の他、判断力の低下による怪我のリスクも増加する [2]。こういった問題に対し、飲水量を自動的に記録する製品開発や研究が行われている。

飲水に使われるボトルに着目した製品として、Trago Cap[3], Hidrate Spark[4] などが販売されている。これらの製品はボトルに内蔵した機器により容器内の飲料量を把握することで毎回の飲水時に摂取した量を記録できる。また、加速度センサ装着ボトルを用いた飲水行動の認識および飲水量の推定手法 [16] が提案されている。これらの製品や研究では、水分摂取の道具であるボトルにセンサを設置することで高精度かつユーザの負担なく飲水量を推定することが可能であるが、特殊なボトルを使用しなければならない制約を伴う。

一方、画像処理技術を用いて飲水を認識する手法 [17] も提案されている。これにより、飲水時の特徴的な姿勢を高精度に認識可能であることが示されているが、飲水量自体の推定には至っていない。また、ユーザ装着のセンサから飲水量を推定する手法として、山田らは喉装着型マイクを用いた嚙下音に基づく飲水量推定手法 [8] を提案している。嚙下音の継続時間の他、音響特徴量として MFCC を用いることで個人差の小さい飲水量の推定を実現している。喉装着型のマイクは拘束性は低いものの、日常生活での使用は一般的ではなく、利用者にとって一日中装着するハードルが高い。

さらに拘束性のより小さい手法として、腕に装着したモーションセンサ、および肩と腕に装着した一対の磁気センサを用い、機械学習アルゴリズムにより飲水時の細かいモーションや容器内の水分量を推定する手法が提案されている [7]。この手法では飲水行動によって生じる腕の慣性センサの重力加速度の成分について、加速度成分が大きく変化する区間を腕の上げ下げ、その間の区間を飲水中として学習する。さらに、容器内の残存水分量によってわずかに異なる飲水姿勢を肩と腕の一対の磁気センサを用いて推定し、姿勢に基づき容器内の水分量を認識する。手法では容器内の水分量推定モデルの構築のため、容器を 100%、50%および 10%未満の 3 通りの量の水で満たし、実際に水を飲むのではなく、唇を濡らす動作を行いデータ収集を

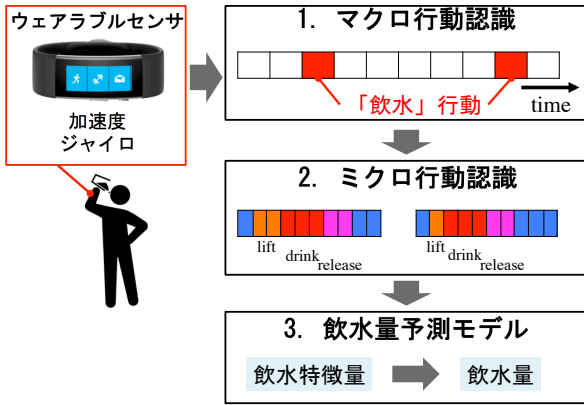


図 1 提案手法の概要

行っている。したがって、実際の飲水量の推定での性能は明らかになっていない。この手法に対し、本研究では (1) 14 名の参加者が実際に飲水を実施し収集したデータの分析に基づき飲水量自体の推定手法を提案し、飲水量の推定誤差を評価している点、および (2) 肩と腕に装着する一対の磁気センサを用いず、腕装着型デバイス内蔵の慣性センサのみで飲水量の推定を完結させている点が異なる。

3. 提案手法

3.1 概要

提案手法の概要を図 1 に示す。本研究では利用者が日常生活において慣性センサ搭載のウェアラブルデバイスを腕に装着しているものと想定する。慣性センサからは 3 軸の加速度および角速度が得られるものとする。収集した値はペアリングしたスマートフォンに送信され、以下の処理により飲水量の推定を行う。

飲水量の推定のため、(1) 幅の広いスライディングウィンドウを用い抽出した特徴量に基づくマクロスケールの行動認識、(2) 幅の狭いスライディングウィンドウを用い抽出した特徴量に基づくミクロスケールの行動認識、(3) ミクロスケールの行動認識結果から得られた飲水特徴量に基づく飲水量の推定の処理を順に実施する。二種の異なる時間スケールでの行動認識を実施することで、人の行動の大局的な依存関係 (例: 机に座ってから食事を始める) および局所的な依存関係 (例: 食器を持ち食事を口に運んだあと飲む) の両方を考慮し、飲水行動全体と、その中で容器を持ち上げる、飲むといった細かいモーションの両方を正しく認識することを目指している。

本手法を適用するための条件として、必ずセンサを装着した腕で飲水行動を実施することが求められる。この条件は Amit らの手法 [7] と同様であるが、飲水をどちらの腕で行うかは人によってほぼ決まっており、装着すべき腕を決定することは容易であると考えられる。なぜなら、飲水時にどちらの腕で容器を持つか、蓋を開けるかといった動作のくせは自然と身につく、無意識に実施されるからである。

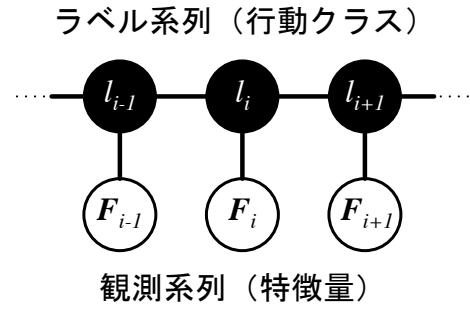


図 2 Linear Chain-CRF

3.2 飲水行動認識アルゴリズム

3.2.1 マクロ行動認識

マクロスケールでの行動認識のため、三軸加速度と三軸角速度の合計 6 つのセンサー値の系列に対し、スライディングウィンドウ W_{macro} を適用し特徴量ベクトル \mathbf{F}_{macro} を抽出する。この際、スライディングウィンドウを $O_{macro}\%$ ずつ重ねながら抽出を行う。多様な特徴量を用いて分類器を構築することで、訓練データに対する当てはまりが良くなる一方で、特徴量の次元数の増大は過学習の原因となるため、重要な特徴量のみを用いて分類器を構築し汎化性能を得ることが重要である。特徴量の候補、および選定方法は 4.2 節で述べる。特徴量 \mathbf{F}_{macro} における行動のラベル L_{macro} は、スライディングウィンドウ W_{macro} 内の各サンプルに付与されたラベルの最頻項目を用いる。これらの特徴量 \mathbf{F} と状態におけるラベル L の組を訓練データとし、提案手法では CRF を用いて入力 \mathbf{F} が与えられたときのラベル L の分布 $p(L|\mathbf{F})$ をモデル化する。

図 2 のように CRF によるモデル化では各サイトにおけるラベルの分布と近傍サイト間のラベルの交互作用をモデル化する。モデル化のため、各サイト i のラベル分布を表現する単項ポテンシャル関数 ϕ_i 、およびサイト i, j 間の相互作用を表現する二項間ポテンシャル関数 ψ_{ij} を用い、条件付確率分布 $p(L|\mathbf{F})$ を次式のように表す。

$$p(L|\mathbf{F}) = \frac{1}{Z(\mathbf{F})} \prod_{i \in S} \phi_i(l_i|\mathbf{F}) \prod_{i \in S} \prod_{j \in N_i} \psi_{ij}(l_i, l_j|\mathbf{F}), \quad (1)$$

$$Z(\mathbf{F}) = \sum_L \left\{ \prod_{i \in S} \phi_i(l_i|\mathbf{F}) \prod_{i \in S} \prod_{j \in N_i} \psi_{ij}(l_i, l_j|\mathbf{F}) \right\}. \quad (2)$$

ここで、 $Z(\mathbf{F})$ は正規化のための関数であり、 S, N_i, l_i, L はそれぞれすべてのサイトの集合、サイト i の近傍サイトの集合、サイト i のラベル、およびラベルの系列 $L = \{l_i\}_{i \in S}$ を表す。本研究では鎖状の Chain CRF モデルを用いるため、サイト i の近傍サイトは $i-1$ および $i+1$ となる。本研究ではこの CRF において、各サイト i におけるラベル l_i に割り当てられるマクロ行動のクラス \mathcal{L}_{macro} として、飲水 (drink) の他、日常生活の主な行動として移動 (move)、立つ (stand)、座る (sit)、横になる (lie)、デスクワーク (work)、食事 (eat) およびその他 (other) の計 7 クラスを定義し、合

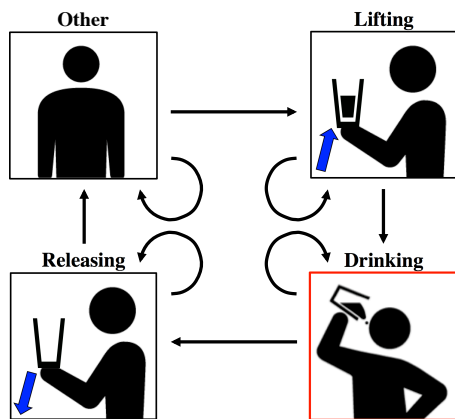


図 3 飲水中のモーション

計 8 種のラベルを用意する。これらのクラスのうち、drink と認識されたウィンドウについてのみ次節で述べるマクロスケール行動分類器に適用し飲水量推定の対象とする。

以上の CRF の構築には python のライブラリである PyStruct[18] を使い、モデルの学習には Block-Coordinate Frank-Wolfe アルゴリズム [19] を用いた。また、学習前にすべての特徴量に標準化 (standardization) を実施し、平均が 0、分散が 1 となる分布に従うように特徴量をスケールリングする。

3.2.2 ミクロ行動認識

ミクロ行動認識においても、マクロ行動認識と同様にスライディングウィンドウ W_{micro} 、重なり率 O_{micro} 、特徴量 F_{micro} 、ラベル L_{micro} のもとで CRF によりモーション間の依存関係をモデル化する。モデル化も 3.2.1 小節と同様に行う。飲水行動 (drink) 中の認識すべきミクロ行動を図 3 に示す。実際に飲水している期間を drinking とし、その前後で容器を持ち上げる動き (lifting) および降ろす動き (releasing) を認識する。さらに、飲水前後に生じるこれら以外の動きを other とし、合計 4 種類の行動を CRF のラベル L_{micro} とする。モデルの学習も 3.2.1 小節と同様に実施する。提案手法では、以上のモデルにより drinking と認識された区間を推定された飲水実施区間とし、この区間における加速度の計測値を用いて後述の飲水量推定を実施する。

3.3 飲水量の推定方式

飲水量推定方式の検討のため、実際に 14 人の被験者から収集した 969 回の飲水について、慣性センサのミクロ行動のラベル付データを収集し分析を行った。その結果を図 4 から 8 に示す。図 4 は各被験者の毎回の飲水量の箱ひげ図を示しており、毎回の飲水量平均に個人差が存在することが分かる。また、全員分の飲水における飲水継続時間と飲水量の関係を図 5 に示す。

この結果から、飲水継続時間と飲水量には全体として正の相関 ($R = 0.65$) が観察され、先行研究 [8] と同様の傾




図 4 被験者ごとの飲水量平均




図 5 飲水時間と飲水量




図 6 飲水時間と飲水量の回帰直線におけるパラメータ




図 7 飲水中の y 軸加速度平均と飲水量

向がみられた。また、各被験者の飲水時間と飲水量の回帰分析における直線の傾きと切片を図 6 に示す。この結果より、回帰直線の傾きおよび切片に大きな個人差が存在し、飲水行動には人によって異なる癖が存在することが分か

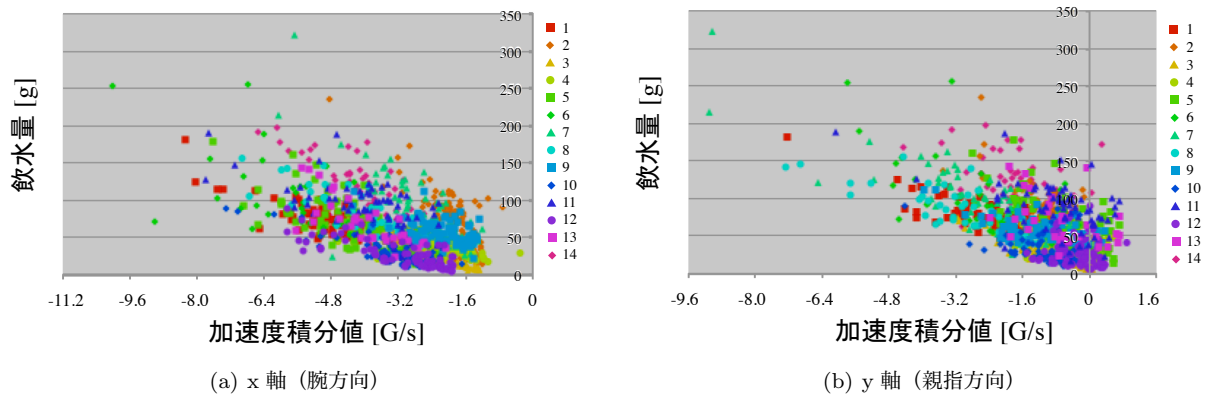


図 8 加速度の積分値と飲水量

る。本論文では、図 6 の結果に基づき、切片が大きい正の値を取るカテゴリ 1 (被験者 9,4,11), 切片が小さい負の値を取るカテゴリ 2 (被験者 1,8,7,12,6), および切片が大きい負の値を取るカテゴリ 3 (被験者 13,10,2,5,14,3) の 3 グループに被験者を分け、それぞれのグループで飲水量推定モデルを構築する。

モデル構築のために、飲水中の姿勢を示す指標として飲水中 (drinking モーション中) の重力加速度の成分を観察した。特に、飲水時は腕を持ち上げることで、親指方向の軸 (y 軸) で計測される重力成分に大きな変化が表れると考えられる。図 7 は飲水中の y 軸加速度平均と飲水量を示しており、ほとんどの場合において重力加速度成分が負 (腕が水平より上向き) になるときに飲水が実施されていることを示している。一方で、平均加速度と飲水量の相関は弱い ($R = 0.42$)。この原因は、容器内の水を飲み干す際などは腕を高く上げるなど、飲水時の姿勢が必ずしも飲水量と比例しないことによると考えられる。そこで、加速度の平均ではなく積分値を用い、飲水区間における姿勢と時間の両方を考慮する。図 8 に x 軸成分と y 軸成分の加速度の積分値と飲水量の関係を示す。これらの結果から、x 軸 (腕方向) 成分と y 軸 (親指方向) 成分の両方において飲水量と負の相関 ($R = 0.56, R = 0.61$) が見られ、飲水量の推定に有用であると考えられる。

以上の分析に基づき、提案手法では加速度 (x 軸, y 軸) の積分値 $\{I_{a_x}, I_{a_y}\}$ を説明変数とした飲水量 M の線形回帰モデル

$$M = a_1 * I_{a_x} + a_2 * I_{a_y} + b \quad (3)$$

を構築し飲水量の推定を行う。具体的なモデルの構築方法、および性能については 4 章で述べる。

4. 性能評価

4.1 データセット

本研究では学生 16 名を対象にスマートフォンとリストバンド型デバイス Microsoft Band 2 [20] を配布し、Android アプリケーションを用いて日常生活における慣性センサ



(a) マクロ行動 (8 種) (b) ミクロ行動 (4 種) と重量

図 9 データ収集アプリケーション

のラベル付データの収集を行った。アプリケーションは Bluetooth 通信によりデバイスから慣性センサ値を読み出し保存する。その際、図 9 に示す二種類のアプリケーションを提供し、8 種類のマクロ行動ラベル、ならびに 4 種類のミクロ行動ラベルと飲水量 (飲水前後の容器の重量) の計測値を入力するよう依頼した。データの収集にあたってはアルバイトとして、もしくは飲料を提供することで依頼し、容器の重量の計測のために 1g 単位で計量可能なデジタルスケールを配布した。Microsoft Band 2 は図 10 のように利き腕に装着した。なお、被験者のうち 2 名は左利きであり、yz 軸成分の計測値が反転するため、収集したデータにおいて yz 軸成分の計測値に正負反転の処理を施した。

マクロ行動データ収集のために 9 人の被験者より表 1 に示す合計約 22 時間のデータを収集した。被験者は普段の生活の中でセンサを装着し、行動を切り替える際にラベル付けを行った。同様に 14 人の被験者にのべ 969 回の飲水を実施してもらい、飲水行動におけるラベル付きのミクロ行動データを収集した。収集したデータの詳細を図 4 および表 2 に示す。

なお、本研究では日常生活やスポーツにおける手法の適

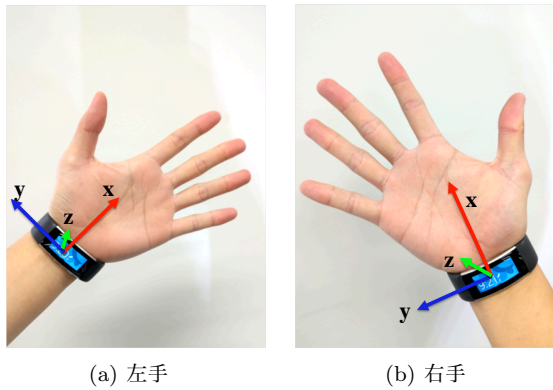


図 10 センサの装着

表 1 マクロ行動データセット

項目	のべ時間 [min.]
drink	64
move	185
stand	207
sit	203
lie	165
work	199
eat	179
other	122
合計	1325

表 2 ミクロ行動データセット

被験者 ID	飲水回数	平均飲水時間 ± 標準偏差 [sec.]
1	76	6.90 ± 1.45
2	108	3.02 ± 0.84
3	79	4.01 ± 0.87
4	90	3.20 ± 0.96
5	77	5.61 ± 1.34
6	36	8.55 ± 2.31
7	62	5.22 ± 1.99
8	39	7.10 ± 1.93
9	86	3.74 ± 1.01
10	91	4.64 ± 1.22
11	67	5.47 ± 1.66
12	74	3.94 ± 1.14
13	32	5.87 ± 1.45
14	52	6.23 ± 1.32
平均飲水時間		4.86 ± 1.98

用を想定しており、最も一般的な飲水方法であると考えられるペットボトル飲料を用いてデータ収集を行い、摂取した飲料は市販の飲料水またはお茶とした。

4.2 パラメータの決定

本節ではモデルの認識性能に影響する種々のパラメータの決定方法について述べる。調整すべきパラメータは分類機に用いる特徴量と特徴量抽出のためのウィンドウに関するパラメータであり、これらを交互に最適化することを繰り返し収束させることで両方のパラメータの最適化を実施する。

4.2.1 分類に用いる特徴量

特徴量の候補を表 3 に示す。表に示す通り、スライディン

表 3 特徴量の候補

項目	説明	総数
平均 (<i>avg</i>)	ウィンドウ内の平均	6
標準偏差 (<i>dev</i>)	ウィンドウ内の標準偏差	6
相関 (<i>corr</i>)	ウィンドウ内の 2 系統の相関	15
<i>manipulation</i>	加速度と角速度の組み合わせ [5]	1

表 4 最適な特徴量

モデル	分類器	特徴量
CRF	マクロ行動	$avg(a_x), avg(a_y), avg(a_z), avg(g_x), avg(g_y), avg(g_z), dev(a_x), dev(a_y), dev(a_z), dev(g_x), dev(g_y), dev(g_z), corr(a_x, a_y), corr(a_x, g_x), corr(a_y, a_z), corr(a_y, g_x), corr(a_y, g_y), corr(a_z, g_x), corr(a_z, g_y), corr(a_z, g_z), corr(g_x, g_z), corr(g_y, g_z), manipulation$
	ミクロ行動	$avg(a_x), avg(a_y), dev(a_y), dev(a_z), dev(g_y), corr(a_x, a_y), corr(a_x, g_x), corr(a_x, g_z), corr(a_y, a_z), corr(a_y, g_x), corr(a_y, g_y), corr(a_z, g_y), corr(a_z, g_z), corr(g_x, g_y), corr(g_x, g_z), corr(g_y, g_z), manipulation$
KNN	マクロ行動	$avg(a_x), avg(a_y), avg(a_z), avg(g_x), avg(g_y), avg(g_z), dev(a_y), dev(a_z), dev(g_x), dev(g_y), corr(a_x, a_y), corr(a_x, a_z), corr(a_x, g_x), corr(a_x, g_z), corr(a_y, g_x), corr(a_y, g_z), corr(a_z, g_y), corr(g_x, g_y), corr(g_y, g_z), manipulation$
	ミクロ行動	$avg(a_x), avg(a_y), avg(a_z), avg(g_y), avg(g_z), dev(a_x), dev(a_y), dev(a_z), dev(g_x), dev(g_y), dev(g_z), corr(a_x, a_y), corr(a_y, a_z), corr(a_y, g_x), corr(a_y, g_z)$

表 5 スライディングウィンドウ用パラメータの探索範囲

パラメータ	候補値
W_{macro} [sec.]	4.0, 5.0, 6.0, 7.0, 8.0
O_{macro} [%]	0, 25, 50
W_{micro} [sec.]	0.5, 1.0
O_{micro} [%]	0, 25, 50

グウィンドウ内の慣性センサの 6 種の値のそれぞれに対し平均 (*avg*) と標準偏差 (*dev*) を求め、6 軸の計測値の 15 通りのペアについて相関係数 (*corr*) を求める。さらに、食事内の行動認識のための特徴量として文献 [5] で提案されている加速度と角速度を組み合わせた動きの指標 *manipulation* を用いる。これらの特徴量について、特徴量選択方式は変数減少法 (backward selection method[21]) を用いた。全ての特徴量を用いるモデルから分類に最も寄与しない特徴量を 1 個ずつ取り除くことを繰り返し、最も良い結果を得られる特徴量の組を選択する。モデルの汎化性能の検証のため、マクロ・ミクロ両方のデータセットにおいて 5 分割交差検定を実施し特徴量選択を行った結果、表 4 に示す特徴量が最適であることが分かった。以降の性能評価ではこれらの特徴量を用いる。

4.2.2 スライディングウィンドウ

スライディングウィンドウのパラメータ候補を表 5 に示す。表 2 の結果より、飲水行動のおおよその平均実施時間を元にマクロ行動分類器におけるウィンドウサイズを設定した。ミクロ行動認識のウィンドウは小さいほど細かい時間単位で認識できるため、後述の飲水量推定において精度が期待できる一方で、行動認識のための情報量が減少し認識が困難になる可能性がある。そこで、本研究では 0.5 秒および 1 秒をウィンドウの候補とする。両分類器におけるウィンド




図 11 マクロ行動 (drink) の認識精度比較




図 12 ミクロ行動 (drinking) の認識精度比較

表 6 マクロ行動認識における混同行列

	drink	move	stand	sit	lie	work	eat	other	適合率	再現率
drink	415	6	3	25	16	23	71	6	72.6%	73.5%
move	14	1144	72	15	14	14	11	122	72.2%	81.4%
stand	4	66	1306	9	12	37	73	52	75.9%	83.8%
sit	43	51	139	554	202	357	118	62	43.3%	36.3%
lie	20	57	80	155	566	190	36	143	49.6%	45.4%
work	30	149	58	359	198	646	52	5	43.2%	43.2%
eat	23	5	4	23	26	35	1168	67	71.0%	86.5%
other	23	107	58	139	107	192	117	161	26.1%	17.8%

表 7 ミクロ行動認識 (CRF) における混同行列

	other	lifting	drinking	releasing	適合率	再現率
other	7218	1321	52	1639	73.2%	70.5%
lifting	1185	12262	818	268	87.3%	84.4%
drinking	3	326	18284	236	92.8%	97.0%
releasing	1459	131	551	15302	87.7%	87.7%

表 8 ミクロ行動認識 (KNN) における混同行列

	other	lifting	drinking	releasing	適合率	再現率
other	6886	1142	114	2098	66.1%	67.2%
lifting	1403	8545	709	3876	64.5%	58.8%
drinking	30	326	18307	186	93.6%	97.1%
releasing	2092	3235	438	11678	65.5%	66.9%

ウの重複率については、0%、25%および50%の3種類を用意する。以上のパラメータに対し、網羅的に5分割交差検定を実施し最適なパラメータを探索するプロセスを4.2.1節の探索と交互に行なった結果、最終的に最適なパラメータ組は $\{W_{macro}, O_{macro}, W_{micro}, O_{micro}\} = \{8.0, 0, 1.0, 0\}$ であることが分かった。しかしながら、 W_{micro}, O_{micro} については最良の組と最悪の組の性能差が0.5%程度と性能差がほとんど確認できなかったため、時間的分解能が最も高くなる $\{W_{micro}, O_{micro}\} = \{0.5, 50\}$ を以降の評価で用いる。

4.3 行動認識の評価結果

4.1節のデータセット、および4.2節のパラメータ設定を用いそれぞれのデータセットで行動認識の性能評価を行った。以降では評価指標として適合率、再現率およびこれらを組み合わせたF値を用いる。比較手法として、クラス分類でよく用いられるk近傍法(KNN)を用いる。KNNでは最適パラメータkの探索のためCRFと同様に5分割交差検定を実施し、マクロ行動認識では $k = 9$ 、ミクロ行動認識では $k = 13$ が最適であることが分かった。さらに、KNNにおいてもCRFと同様に4.2節で述べた特徴量選択・パラメータ探索を実施し、最適なウィンドウパラメータは $\{W_{macro}, O_{macro}, W_{micro}, O_{micro}\} = \{8.0, 0, 0.5, 50\}$ であり、各行動認識における最適な特徴量は表4に示す特徴量であることが分かった。

4.3.1 マクロ行動認識結果

合計1325分のマクロ行動に対し、5分割交差検定を実施しKNNと提案手法(CRF)のそれぞれの分類器を用いて飲水(drink)クラスの認識を行った結果を図11に示す。この結果より、適合率、再現率の両方において提案手法が優れていることが分かる。この理由として、単に慣性センサの

値から得られた特徴量だけを比較するKNNに対し、CRFでは特徴量だけでなく前後のラベルとの整合性も考慮できるため、座って水を飲む、仕事に水を飲む(sit→drink, work→drink)のような時系列的な遷移条件を考慮することができたものと考えられる。

さらに、提案手法における各マクロ行動クラスの混同行列を表6に示す。この結果より、drink, move, stand, eatの各クラスにおいてはいずれも70%以上の適合率および再現率で認識できていることが分かる。一方で、sit, lie, workの3クラスについては、相互に誤認識が多数発生しており、適合率、再現率ともに50%を下回っている。この理由として、腕や体を動かさず drink, eat, move や手を鉛直方向に垂らす stand といったクラスは、他のクラスと比較して加速度や角速度に差が顕著に生じる一方で、sit, lie, work といった机上や床であまり腕を動かさないクラスについては加速度や角速度の差が小さく、行動認識がより困難になったからであると考えられる。また、other は全クラスの中で最も認識率が低く、適合率26.1%、再現率17.8%となっている。これは、other として収集されたデータが自転車、電車、車、エレベーターなど、身体の動きを伴う場合やそうでない場合など多様な状況を含んでいることに起因する。しかしながら、提案手法では drink 以外の区間を全てミクロ行動認識の対象から除外するため、sit, lie, work, other の認識精度が低いことはあまり問題にならないといえる。

4.3.2 ミクロ行動認識結果

マクロ行動と同様に969回の飲水行動データセットに対し5分割交差検定によりミクロ行動認識性能の評価を行っ

表 9 飲水量推定モデルのパラメータ

カテゴリー	a_1	a_2	b	サンプル数
1	-15.863	-8.314	9.209	243
2	-6.194	-18.779	8.918	287
3	-11.817	-17.145	6.321	439
共通	-9.615	-13.763	14.849	969

た結果を図 12 に示す。結果より、KNN および提案手法によるマイクロ行動の認識精度はほぼ同等であることが分かる。マクロ行動分類器と比較して KNN による認識精度が高い理由として、969 回の飲水データセット、および特徴量検出のウィンドウサイズが 0.5 秒であることより、より多くの特徴量サンプルが得られたことが考えられる。

また、提案手法における各マイクロ行動クラスの混同行列を表 7 に示す。この結果より、drinking の認識は適合率 92.8%、再現率 97.0% とおおむね正しく行われており、他のクラスでは drinking と比較して精度が低下していることが分かる。この理由として、lifting, releasing の各クラスでは大きな腕の動きを伴うため加速度や角速度がノイズを伴いやすいことや、other はペットボトルの蓋を開けるなど、複雑な動きを含むサンプルが含まれていたことが挙げられる。

一方、KNN における各マイクロ行動クラスの混同行列を表 8 に示す。結果より、drinking における認識精度は CRF よりも高いものの、CRF と比較して lifting と releasing の誤認識が増加していることが分かる。すなわち、drinking における加速度および角速度の特徴量は他のクラスに対し大きく異なる一方で、lifting, releasing における特徴量の差は比較的微小であり、KNN による認識が難しいことを示している。これに対し、CRF では lifting→drinking→releasing という遷移ルールを学習したことにより lifting と releasing の相互の誤認識は極めて少なく、CRF の有用性が示されている。

以上の結果に対し、本手法では飲水量の推定のために drinking の区間における x 軸加速度および y 軸加速度の積分値を用いるため、KNN・CRF のいずれのモデルを適用しても同等の精度が期待できるといえる。両モデルにおいて drinking の適合率・再現率が 90% を超えていることから、飲水量の推定モデルへ入力される特徴量はおおむね期待どおりの値が入力されているものと考えられる。

4.4 飲水量の推定結果

3.3 節で述べた飲水量推定方式について、実際に収集した 969 回の飲水データにおけるカテゴリー 1,2,3 のそれぞれに対し 5 分割交差検定を実施し線形回帰モデルを構築した。同時に、カテゴリーを分けず全員のデータに対し共通のモデルも構築した。モデルの式 (3) に対し、実際に得られたパラメータを表 9 に示す。

以上のモデルを用い、4.3.2 節のマイクロ行動認識結果で




図 13 飲水量推定結果 (共通モデル)




図 14 飲水量推定結果 (カテゴリー別モデル)

drinking と認識された区間において得られた x 軸加速度の積分値 I_{a_x} および y 軸加速度の積分値 I_{a_y} を入力として飲水量 M の推定を行った結果を図 13 および図 14 に示す。図 13 は共通のモデルを用いて飲水量を推定した結果を示しており、平均誤差は 1.5[g]、二乗平均平方根誤差は 29.5[g] である。さらに図 14 は各カテゴリー別のモデルにおける飲水量の誤差を示しており、平均誤差は 1.3[g]、二乗平均平方根誤差は 28.3[g] である。これらの結果では平均誤差に大きな差は見られないものの、実測値が小さい場合、すなわち飲水時間が短い場合において共通モデルでは切片の影響が強くなり、カテゴリー別のモデルと比較して飲水量を実際より多く推定する傾向がある (図 13 左下)。これに対し、カテゴリー別のモデルでは飲水時間が短い場合において共通モデルよりも推定精度が向上していることが分かった (図 14 左下)。カテゴリーを分けても推定精度があまり向上しない原因として、図 8 で示すように加速度の積分値と飲水量の分布にばらつきが存在し、飲水量を高精度にモ




図 15 ボトル毎の飲水量推定誤差の分布

デル化することが困難であることが挙げられる。

さらに、実験で 14 人が飲んだ合計 172 本のペットボトルのそれぞれで得られたデータセットごとに提案手法による飲水量推定を実施し得られた各ボトル毎の合計推定誤差の分布を図 15 に示す。ペットボトルの容量は飲料の種類によって異なるが、全て 500[ml] から 600[ml] までのボトルを用いた。この結果より、合計飲水量の平均推定誤差は 7.3[g] であり、標準偏差は 152.9[g] である。すなわち、おおむねボトルの容量の $\pm 30\%$ 程度の誤差で各ボトルでの飲水量を推定できているといえる。一方、誤差が非常に大きいサンプルも存在している。誤差が最大 (981[g]) のサンプルでは、被験者が一本のペットボトルで 28 回の飲水を実施していたため毎回の飲水量および飲水時間が短く、現在の飲水量推定モデルでは少量の飲水時に飲水量を多めに推定しやすいことから毎回の推定誤差が蓄積したためこのような結果が得られている。この問題への対策として、少量の飲水時の推定精度を向上させるために飲水継続時間に応じて複数の線形回帰モデルを構築し使い分けられることを検討している。

5. ケーススタディ：居酒屋での食事

実環境で提案手法を用いて生活における飲水量を推定するシナリオとして、居酒屋での食事の飲水量の推定を行う。この理由として、普通の食事と比較して居酒屋での食事時間は長く、かつ飲水回数が多いことから、多くのデータが採取可能であることが挙げられる。居酒屋での食事中に提案手法を用いて飲水量を推定することで、飲み過ぎの防止やアルコール摂取量に対し適切な水分補給を実施することによる二日酔いの防止などに活用できると考えられる。なお、本論文では飲料を摂取することを飲水と呼ぶこととし、飲酒も飲水に含まれるものとする。

データ収集のため、男女 2 名の居酒屋での約 3 時間の食事において、Microsoft Band 2 を装着しセンサデータを集積すると同時に食事風景の動画撮影を実施した。撮影した映像の一例を図 16 に示す。飲水量の把握のため図中のように上皿はかりをテーブルに設置し、飲料を常にはかりに



図 16 実験風景

表 10 収集データの詳細

被験者	飲水回数	合計飲水量	飲料種類
1	40	710 [g]	サワー・果実酒・温茶・果汁飲料
2	27	1220 [g]	酎ハイ・ハイボール・冷茶・冷茶・温茶・果汁飲料

表 11 行動認識モデル別の飲水量推定結果

被験者	飲水量推定結果 (真値との誤差) [g]	
	CRF	KNN
1	2007 (+1297)	4694 (+3984)
2	422 (-798)	880 (-340)

置くことで目盛りの位置、すなわち重量の変化の真値を得た。アナログのはかりを用いることで、電子はかりのように意識的に計測する必要がなく、普通の食事と同様に無意識な飲水動作データを取得できている。毎回の飲水量の取得のため、食後に被験者自身が映像を見返しながらかり目盛りの遷移を読み取りデータ化を行った。

ラベル付けの結果得られたデータの詳細を表 10 に示す。以上のデータセットに対し、4 章で収集した 2 つのデータセットを用いて構築したマクロ行動分類器、ミクロ行動分類器および飲水量推定モデルを用いて提案手法により飲水量の推定を行う。

各被験者に対し CRF および KNN の 2 通りの行動認識モデルを用いて飲水量を推定した結果を表 11 に示す。この結果より、いずれの行動認識モデル、被験者においても飲水量の平均誤差が大きく、居酒屋での食事における正確な飲水量の推定が困難であることが分かる。この原因として、マクロ行動認識による drink の誤検出および検出漏れが考えられる。表 6 のマクロ行動認識モデルの混同行列においても、sit, eat などは drink として誤検出されやすいことが分かっており、居酒屋での食事において、drink 以外のほとんどの時間は sit, eat を実施していたため、実験時間の経過に伴って誤検出が増加したものと考えられる。

この検証のため、映像を見返しながらかり目盛りのラベル付けを行いマクロ行動の認識性能を確認したところ、CRF のモデルにおける被験者 1 の適合率は 26.0%、再現率は 51.0%、被験者 2 の適合率は 46.2%、再現

率は26.1%であり、KNNのモデルにおける被験者1の適合率は17.8%、再現率は45.1%、被験者2の適合率は43.6%、再現率は73.9%であることが分かった。いずれのモデルにおいても被験者1の適合率が低くなっており、実際に飲水を行っていない区間についても数多く飲水量推定の対象としたことで実際よりも飲水量を多く見積もってしまったものと考えられる。特に、被験者1は実験の後半、食事を終えて頬杖をついていた期間が長時間存在し、この区間をdrinkと誤って検出してしまったものと考えられる。一方、被験者2は適合率が45%前後であり、誤検出が半分以上存在するにも関わらず全体の推定誤差はマイナスとなっている。この結果は、マクロ行動認識によりdrinkと誤検出した区間に対して、必ずしもミクロ行動認識よりdrinkingを抽出するわけではないことを示している。例えばおしぼりで口を拭くといった動作はdrinkと酷似しているが、動作は一瞬で実施されることが多く、全体として見るとdrinkと誤認識しがちであるが、drinkingとして抽出される区間は微小である。

さらに、他の原因として、容器による飲水量推定モデルへの影響が考えられる。本研究ではペットボトルを用いて収集した飲水行動データを用いてマクロ行動認識、ミクロ行動認識および飲水量推定のためのモデルを構築しているが、本実験ではペットボトルではなくグラスやジョッキ、湯呑みを用いて飲水を行っていたため、これらのモデルが上手く作用しなかった可能性がある。具体的には、ペットボトルは飲み口が小さくこぼれにくいいため、腕をより高く上げて飲む傾向があることに對し、コップやジョッキは飲み口が広く、腕を上げすぎると飲料がこぼれるため腕をより低くしながらゆっくり飲む傾向が存在する。この結果、それぞれの容器での飲水中に得られる加速度の特徴量が想定と異なってしまった可能性がある。

以上のように、本実験により飲水と酷似した行動の認識、および容器による飲水モーションの差異の考慮が今後必要であることが明らかになった。これらの実現のため、慣性センサの計測値に加え、ロケーションや時間帯といった外部情報を用いることを検討している。具体的には、位置情報からユーザの使い得る容器を絞り込むことで容器別の行動認識モデル、飲水量推定モデルを適用できる可能性がある。例えば、居酒屋ではジョッキやグラスなどを利用し、レストランではコップを利用するといった情報を活用できると考えている。さらに、日常生活において使うコップやボトルは同じことが多いと考えられるため、容器種別の動的な推定や事前のキャリブレーションにより、容器別の行動認識モデルおよび飲水量推定モデルを適用できると考えている。

6. まとめと今後の課題

本研究では日常生活で継続的に装着可能なスマートウォッチに着目し、二種類の時間スケールの異なる行動認識モデルを併用し飲水量を推定する手法を提案した。実際に14人の969回の飲水データセットに対して平均誤差1.5[g]、二乗平均平方根29.5[g]の精度で毎回の飲水を推定できることを明らかにした。さらに、提案手法により172本のペットボトルでの飲水における各ボトルごとの合計飲水量の推定において、平均誤差7.3[g]、標準偏差152.9[g]で推定できることを確認し、おおむねボトルの容量の±30%以内の誤差で合計飲水量を推定できることを確認した。今後の課題として、食事中、スポーツ中など多様なシナリオにおける飲水データの収集、およびコップや水筒など様々な容器における飲水量推定方式を検討する必要がある。

本研究の今後の展望として、夏季の熱中症予防のために本手法を応用することを検討している。熱中症予防のためには身体の脱水の度合いを知ることが重要であり、そのために水分の排出量と摂取量を推定することが有効である。その実現のため、本論文で提案した飲水量の推定手法と横田らの衣服内蔵の湿度センサを用いた簡易発汗量推定手法[22]を組み合わせ、腕装着型センサおよび湿度センサを用いて簡便かつリアルタイムに脱水度を推定する枠組みを検討する。さらに、脱水量の推定に加え、熱中症の主要因である身体深部の体温(深部体温)を推定する著者らの先行研究[23]と組み合わせ、深部体温の上昇度と脱水の進行度の両方の観点より熱中症警告を生じ熱中症を予防する枠組みを検討する。

謝辞 本研究はJSPS 科研費26220001,17J04131の助成を受けたものです。

参考文献

- [1] Adan, A.: Cognitive performance and dehydration, *Journal of the American College of Nutrition*, Vol. 31, No. 2, pp. 71–78 (2012).
- [2] 井上芳光, 近藤徳彦(編): 体温II 体温調節システムとその適応, NAP Limited (2010).
- [3] TRAGO: Trago Cap. <https://trago.co/pages/trago-cap>.
- [4] Hidrate: Hidrate Spark. <http://hidratespark.com/>.
- [5] Dong, Y., Scisco, J., Wilson, M., Muth, E. and Hoover, A.: Detecting periods of eating during free-living by tracking wrist motion, *IEEE journal of biomedical and health informatics*, Vol. 18, No. 4, pp. 1253–1260 (2014).
- [6] Kalantarian, H., Alshurafa, N. and Sarrafzadeh, M.: Detection of gestures associated with medication adherence using smartwatch-based inertial sensors, *IEEE Sensors Journal*, Vol. 16, No. 4, pp. 1054–1061 (2016).
- [7] Amft, O., Bannach, D., Pirkl, G., Kreil, M. and Lukowicz, P.: Towards wearable sensing-based assessment of fluid intake, *Pervasive Computing and Communications Workshops (PERCOM Workshops), 2010 8th IEEE In-*

- ternational Conference on, IEEE, pp. 298–303 (2010). (2015).
- [8] 小林悠一, 山田侑太郎, 西村雅史, 峰野博史, 飯田一朗: 嚥下音を用いた水分摂取量推定手法の研究, *情報処理学会論文誌*, Vol. 57, No. 2, pp. 532–542 (2016).
- [9] Thomaz, E., Essa, I. and Abowd, G. D.: A practical approach for recognizing eating moments with wrist-mounted inertial sensing, *Proceedings of the 2015 ACM International Joint Conference on Pervasive and Ubiquitous Computing*, ACM, pp. 1029–1040 (2015).
- [10] Ramos-Garcia, R. I., Muth, E. R., Gowdy, J. N. and Hoover, A. W.: Improving the recognition of eating gestures using intergesture sequential dependencies, *IEEE journal of biomedical and health informatics*, Vol. 19, No. 3, pp. 825–831 (2015).
- [11] Mirtchouk, M., Merck, C. and Kleinberg, S.: Automated estimation of food type and amount consumed from body-worn audio and motion sensors, *Proceedings of the 2016 ACM International Joint Conference on Pervasive and Ubiquitous Computing*, ACM, pp. 451–462 (2016).
- [12] Zhan, K., Faux, S. and Ramos, F.: Multi-scale conditional random fields for first-person activity recognition, *Pervasive Computing and Communications (PerCom), 2014 IEEE International Conference on*, IEEE, pp. 51–59 (2014).
- [13] Vail, D. L., Veloso, M. M. and Lafferty, J. D.: Conditional random fields for activity recognition, *Proceedings of the 6th international joint conference on Autonomous agents and multiagent systems*, ACM, p. 235 (2007).
- [14] Peng, F. and McCallum, A.: Information extraction from research papers using conditional random fields, *Information processing and management*, Vol. 42, No. 4, pp. 963–979 (2006).
- [15] Gu, W., Jin, M., Zhou, Z., Spanos, C. J. and Zhang, L.: MetroEye: Smart Tracking Your Metro Trips Underground, *Proceedings of the 13th International Conference on Mobile and Ubiquitous Systems: Computing, Networking and Services*, ACM, pp. 84–93 (2016).
- [16] Dong, B., Gallant, R. and Biswas, S.: A self-monitoring water bottle for tracking liquid intake, *Healthcare Innovation Conference (HIC), 2014 IEEE*, IEEE, pp. 311–314 (2014).
- [17] Chua, J.-L., Chang, Y. C., Jaward, M. H., Parkkinen, J. and Wong, K.-S.: Vision-based hand grasping posture recognition in drinking activity, *Intelligent Signal Processing and Communication Systems (ISPACS), 2014 International Symposium on*, IEEE, pp. 185–190 (2014).
- [18] Andreas Mueller.: PyStruct - Structured Learning in Python. <https://pystruct.github.io/>.
- [19] Lacoste-Julien, S., Jaggi, M., Schmidt, M. and Pletscher, P.: Block-coordinate Frank-Wolfe optimization for structural SVMs, *arXiv preprint arXiv:1207.4747* (2012).
- [20] Microsoft: Microsoft Band — Official Site. <https://www.microsoft.com/microsoft-band/en-us>.
- [21] Guyon, I. and Elisseeff, A.: An introduction to variable and feature selection, *Journal of machine learning research*, Vol. 3, No. Mar, pp. 1157–1182 (2003).
- [22] 横田知樹, 近藤亮磨, 岩井将行: 湿度センサを用いた簡易的な発汗センシング手法の実験と評価, *マルチメディア, 分散協調とモバイルシンポジウム 2016 論文集*, Vol. 2016, pp. 853–857 (2016).
- [23] 濱谷尚志, 内山彰, 東野輝夫: ウェアラブルセンサと生体温熱モデルを用いた暑熱環境下での深部体温推定の一手法, *情報処理学会論文誌*, Vol. 56, No. 10, pp. 2033–2043