

スマートフォンを用いた歩行時心拍数推定法

隅田 麻由¹ 水本 旭洋^{1,2,a)} 安本 慶一¹

受付日 2013年4月2日, 採録日 2013年10月9日

概要: 本論文では, 個人の身体条件に適した負担度でのウォーキングを支援するシステムの実現を目指し, スマートフォンで利用可能な機能のみを用いた心拍数推定法を提案する. 提案手法では, 歩行中の心拍数を推定するために, 機械学習を基に, 加速度や歩行速度などの歩行データから心拍数を予測する心拍数モデルを構築する. 心拍数の突発的な変化に対応するため, モデルの入力として心拍数変化と関連性が高い酸素摂取量に着目する. そして, 加速度および位置情報などのスマートフォンで計測可能なデータから酸素摂取量の変化を正確に推定する方法を新規に提案する. また, 学習データのない様々なユーザーに対して心拍数を推定できるようにするため, 過去の運動習慣を基に分類したユーザーカテゴリごとに心拍数モデルを構築し, パラメータの最適化, 心拍数データの正規化などを適用する. 複数の被験者および歩行ルートについて実際に計測したデータに本手法を適用した結果, 6.37 bpm (拍/分) 以内の平均誤差で心拍数の推定ができること, 提案する酸素摂取量推定法が平均 10 bpm 以上の誤差の軽減に寄与することなどを確認した.

キーワード: 心拍数推定, スマートフォンセンシング, 機械学習, ウォーキング支援

A Method for Estimating Heart Rate during Walking with Smartphone

MAYU SUMIDA¹ TERUHIRO MIZUMOTO^{1,2,a)} KEIICHI YASUMOTO¹

Received: April 2, 2013, Accepted: October 9, 2013

Abstract: In this paper, aiming to realize the support system for walking with appropriate physical load for various individuals, we propose a method to estimate the heart rate during walking only with available functions of a smartphone. For this purpose, we build a heart rate model that predicts the heart rate from walking data including acceleration and walking speed by machine learning. In order to deal with the sudden change of heart rate, we focus attention on oxygen uptake which is closely related to heart rate change and use it as an input of the model. To make this possible, we devise a novel technique to accurately estimate the oxygen uptake from acceleration and location data measured by a smartphone. Moreover, we estimate the heart rate for new users who utilize the system for the first time. For this purpose, we classify all users into some categories by existence of exercise habits, and then build a model for each category after optimizing category-specific parameters and normalizing heart rate data measured. We applied the proposed method to actual walking data on various routes by different persons and confirmed that the method estimates heart rate change with mean error of 6.37 bpm (beat per minute) and the proposed oxygen uptake estimation technique reduces the mean error by more than 10 bpm.

Keywords: heart rate estimation, smartphone sensing, machine learning, walking support

¹ 奈良先端科学技術大学院大学
Nara Institute of Science and Technology, Ikoma, Nara 630-0192, Japan

² 日本学術振興会特別研究員 DC
JSPS Research Fellow DC, Kojimachi Business Center Building, Chiyoda, Tokyo 102-0083, Japan

a) teruhiro-m@is.naist.jp

1. はじめに

ウォーキングは体脂肪の減少, 筋力の増加といった健康増進・維持に効果的であるだけでなく, 特別な器具なしに誰でも手軽に実施できるという利点がある. しかし, 負担の高い無理なウォーキングを続けた場合は, 心臓や関節に

大きな負担がかかり、ウォーキングに対する意欲の低下や継続性の低下につながる。特に高齢者や特定の持病保持者については、負担が高い状態が続くことが危険な場合もある。また一方で、負担の低いウォーキングを続けた場合は、十分な効果が得られない可能性が高い [1]。したがって、継続性の高い効果的なウォーキングのためには、個人の身体条件に応じた適切な負担度でウォーキングを行う必要がある。

MPTrain [2], IM4Sports music system [3] は、ユーザが一定範囲内の心拍数で運動（ウォーキングやジョギングなど）を継続できるよう、必要に応じて適したテンポの音楽を自動再生する。ユーザは、再生される音楽のテンポに自身の歩調を合わせるだけで、自然に効果的なトレーニングを行うことができる。しかし上記のシステムは、心拍数の測定に必要な心拍計の装着が必須である。最近ではSUUNTO社のt6d [4] やPOLAR社のRS100 [5] のような腕時計型のワイヤレス心拍計を用いることで、以前より手軽に運動中の心拍数を測ることができる。しかし、これらの心拍計はデバイスコストが高く、トランスミッタと呼ばれる装置を胸部に直接装着する必要があるため、装着に手間がかかり、ウォーキングの利点である手軽さが損なわれる。したがって、特殊デバイスを用いないシステムが求められる。

スマートフォンを用いた運動中のコンテキスト推定に関する研究として、活動識別 [6], [7] や歩行者の位置推定 [8], [9] などが行われているが、負担度の推定を目的としたものはほとんど存在しない。また、運動強度推定を目的とした研究 [10] では、リアルタイム推定を行っているが、年齢や運動習慣などの個人差を反映した運動強度を推定することはできない。さらに、負担度との関連性が高い心拍数を予測する手法 [11] は存在するが、運動中の心拍数予測は対象としておらず、個人差についても考慮されていない。

本論文では、ウォーキングの利点である「手軽さ」と、ウォーキングに求められる「各個人に適した負担度」の2点に着目したウォーキング支援システムの実現を目指し、スマートフォン搭載機能のみを用いた歩行時における心拍数の推定手法を提案する。提案システムでは、適切な負担度を維持するためのペースコントロールや、無理のないウォーキングのための歩行ルートを選択を可能にすることで、継続性の高い効果的なウォーキング支援を行う。

スマートフォンを用いた心拍数推定には、次に示す3つの課題がある。スマートフォンでは心拍数を直接測定できない（課題1）。また、心拍数は運動強度の変化にともない変化するが、その変化は突発的である（課題2）。加えて、同じ運動強度で歩行する場合でも、心拍数の変化度合い（変化量、変化速度）および大きさは身体条件（運動習慣、年齢など）に応じた違いがある（課題3）。

本論文では、課題1および課題2の解決のため、スマー

トフォンから取得する加速度や歩行速度などの歩行データと、心拍計により計測した実際の心拍数データに機械学習を適用することで、心拍数予測モデルを構築する。心拍数は運動強度の変化に遅れて徐々に変化するという特徴を持つ。この特徴をモデルに取り入れるため、心拍数と同じように変化する性質を持つ酸素摂取量に着目し、酸素摂取量の変化を加速度や位置情報などのスマートフォンで計測可能なデータから正確に推定する方法を新たに考案する。そして、酸素摂取量をモデルの入力パラメータとして使用することで、心拍数の変化を正確に推定できるようにする。また、課題3の解決のため、ユーザをプロフィール（運動習慣や年齢など）に基づいていくつかのカテゴリに分類のうえ、心拍数の変化度合いを反映するパラメータを新たに導入しカテゴリごとに最適化する。さらに、実測した心拍数データを正規化したうえでモデルを構築し、他カテゴリの学習結果も利用して、各カテゴリのユーザの心拍数予測の正確度を高める。

評価実験として、複数の被験者および複数の歩行ルートについて心拍数推定を行った結果、平均で6.37bpmの誤差で心拍数の推定ができること、提案する酸素摂取量の推定法を用いることで、用いない場合に比べ10bpm以上誤差を軽減できることなどを確認した。

2. 負担度を考慮したウォーキング支援システム

提案するウォーキング支援システムの目的と要件、それらを実現する際の課題と解決の基本方針について述べる。

2.1 目的

提案するウォーキング支援システムは、無理なウォーキングによる継続性の低下、もしくは、怪我などの危険性を回避するとともに、効果的なウォーキングの提供を目的とする。そのため提案システムは、主に「適度なウォーキングペースの維持」および「歩行ルートに対する負担度の事前提示」の2つの機能の実現を目指す。前者では、ウォーキング中に適度な負担度を維持できるように、ユーザの負担度の高低に応じて歩行速度の調整を促す。後者では、ウォーキングを行う前に、歩行中に予想される負担度の確認やユーザの身体条件に適した歩行ルートを選択を可能にする。

2.2 負担度の指標

運動中の身体的負担度は、運動強度との関連性が強く、測定の指標にはBorgが定義したRPE（主観的運動強度：Rate of Perceived Exertion）[12], [13] や心拍数がよく用いられる。

RPEは各個人の身体的負担度の測定に用いられ、表1に示す15段階のボルグ・スケール [12] として知られている。RPEと心拍数との間には直線的な相関関係があり、ス

表 1 ボルグ・スケール

Table 1 Borg scale.

RPE	主観的運動強度	RPE	主観的運動強度
20		12	
19	非常にきつい	11	楽である
18		10	
17	かなりきつい	9	かなり楽である
16		8	
15	きつい	7	非常に楽である
14		6	
13	ややきつい		

ケールの数字は心拍数の 1/10 に対応している [13]. これは感覚的な負担度を定量的に測定する際に有効であるが, アンケートなどによる評価が必要であるため, 測定に手間がかかる. そのため, 短い時間間隔での測定には適していない.

上記の問題から, 最近では, 心拍数を負担度の指標とすることが多い. また, 心拍数は短い時間間隔で個人の負担度を測定する際に有効である. 以上より, 本論文では負担度の指標として心拍数を使用する.

2.3 要件

1 章で述べたように, 提案システムでは, ウォーキングの利点である「手軽さ」と, ウォーキングに求められる「各個人に適した負担度」に着目する.

システムのユーザビリティの観点から, 提案システムでは, 特殊デバイスなしに手軽に心拍数を推定できることが望ましい. また, ウォーキング中の心拍数は歩行速度や道の勾配の変化にともない変化するうえに, その変化は突発的である. システムはこのような変化を追跡し柔軟に対応できなければならない. 加えて, 年齢や運動習慣に応じて心拍数の変化には個人差があるため, 個人の身体条件に適した負担度 (心拍数) を提示することが望ましい.

以上のことから, 提案システムの実現には, 下記の要件を満たす必要がある.

- 要件 1: 普及デバイスによる負担度の測定
- 要件 2: ウォーキング中の負担度変化の推定
- 要件 3: 年齢, 性別, 身体能力などの個人差の考慮

2.4 課題と基本方針

前述の要件を実現する際の課題と, その解決方針について以下に述べる.

・要件 1 に対する課題と基本方針

本研究では, 近年急速に普及しているデバイス (普及デバイス) としてスマートフォンに着目し, 搭載されたセンサのみを用いた負担度推定を行うことで, 特殊デバイスの装着にともなう手間やコストなどの負担の軽減, および, 誰でも手軽に利用できるユーザビリティの高いシステムの




図 1 運動習慣の異なる被験者が同ルートと同時にウォーキングした場合の心拍数変化 (被験者 A: 運動習慣なし, 被験者 B: 運動習慣あり)

Fig. 1 Heart rate change when 2 subjects with different sport habit simultaneously walk on a route at similar speed. (A without sport habit, B with sport habit).

実現を目指す. しかし, スマートフォンでは, 負担度との関連性が高い心拍数を直接測定することはできない. したがって, スマートフォンにより取得する歩行データ (加速度, 歩行速度, 勾配, 酸素摂取量などの時系列データ, 詳細は後述) と心拍数の関連付けが必要である. この関連付けは, 歩行データから心拍数を予測する心拍数モデルを構築することで行う. 具体的には, ニューラルネットワークなどの機械学習を使用し, 歩行速度, 勾配などのデータを入力とするモデルを構築する.

・要件 2 に対する課題と基本方針

歩行中の負担度は, 運動強度の変化にともない変化し, 特に歩行速度および勾配の影響を受ける [14].

しかし, 運動強度変化時の心拍数は, 瞬間的に変化するのではなく, ある値に近づくように徐々に変化するという性質を持つ. すなわち, 運動強度の変化直後は, その後の運動強度が一定であっても, しばらくの間, 心拍数は変化し続ける. したがって, 歩行速度および勾配の変化を検出するだけでは, 正確に運動強度と心拍数の関連付けを行うことは難しい.

そこで本研究では, 酸素摂取量に着目し, これを心拍数モデルの入力の 1 つとして使用する. 運動中の心拍数は体内に酸素を供給するために増減することから, 供給される酸素 (すなわち, 酸素摂取量) は心拍数変化の性質とよく似た性質を持ち, 心拍数との関連性も高いと考えられる. ただし, 酸素摂取量についてもスマートフォンでは直接測定できないため, 本研究では推定方式を新たに考案する. 詳細については, 3.2.4 項で述べる.

・要件 3 に対する課題と基本方針

心拍数変化に関する個人差には運動習慣や年齢などが考えられ, これによって, 同じ運動強度でも, 心拍数の変化度合い (変化幅, 反応速度) や心拍数の大きさ (絶対値) に違いが生じる.

例として, 運動習慣の異なる 2 人の被験者が同じルートと同時にウォーキングした際の心拍数変化を図 1 に示す. 運動習慣のある被験者 (被験者 B) の心拍数に比べて, 運




図 2 安静時心拍数の異なる被験者が同ルートと同時にウォーキングした場合の心拍数変化

Fig. 2 Heart rate change when 2 subjects with different heart rate at rest simultaneously walk on a route.

動習慣のない被験者(被験者 A)の心拍数は全体的に高く、上昇幅についても、特に 540s 以降で、より大きいことが分かる。また、変化の仕方は同じでも、心拍数の大きさが異なる場合もある。その様子を図 2 に示す。

本研究では、システムを初めて利用するユーザ(歩行データがモデルの学習に利用されていないユーザ)に対する心拍数推定を可能とするために、複数人の歩行データから構築する心拍数モデルを基に心拍数推定を行う。そのために、「20代、運動習慣あり」、「20代、運動習慣なし」というように、年齢や運動習慣などのプロフィールを基にカテゴリを作成する。そして、同一カテゴリに属するユーザは類似した心拍数変化をするという前提の下、推定に必要なパラメータをカテゴリごとに最適化し、心拍数モデルを構築することで、心拍数変化に関する個人差を考慮する。

2.5 提案システムの設計

本システムは、ユーザビリティの観点から普及デバイスであるスマートフォンのみを利用する。また、ウォーキングを通して運動を行いたいユーザを対象とし、3軸加速度センサおよび GPS センサを搭載したスマートフォン用アプリケーションとしての利用を想定する。

図 3 に提案システムのアーキテクチャを示す。提案システムは、Mobile computing module, Feature extraction module, Prediction module の 3つのモジュールと、各モジュールにおける各構成要素(心拍数モデル、共有データベースなど)から構成される。Mobile computing module はスマートフォンで、残り 2つのモジュールはクラウド上にあるサーバで実行される。

Mobile computing module のユーザ・インタフェース(User Interface)は、ユーザに提供する情報(負担度、心拍数、歩行速度)の表示やユーザ情報(運動習慣、年齢、安静時心拍数、希望する運動時間、出発地点、目的地点)の入力操作を可能にする。また、カテゴリ検出器(Category Detector)はユーザが属するカテゴリの決定を行い、データ収集器(Data Collector)は歩行データの収集を行う。収集したデータは、ウィンドウ幅 W のハーフ・オーバーラップ方式(時間間隔 $[t_i, t_i + W]$ と次の時間間隔 $[t_{i+1}, t_{i+1} + W]$)

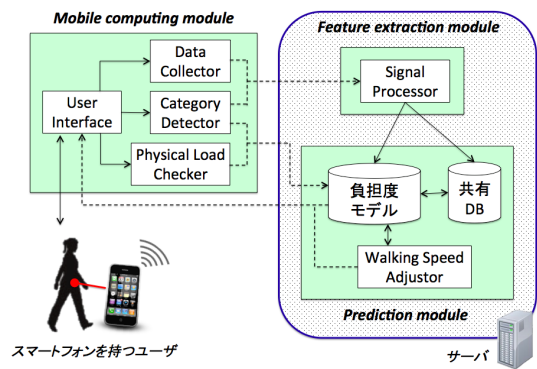


図 3 提案システムのアーキテクチャ(実線は処理の流れもしくはデータの流れを示し、破線はインターネットを介したデータ通信を表す。モジュール間の通信は一定周期で行われる)

Fig. 3 Architecture of proposed system.

がちょうど半分重なるように、すなわち $t_{i+1} = t_i + W/2$ となるように、時間を区切る方式)を用いて、一定時間間隔 W のデータに区切られ、Wi-Fi もしくは 3G 回線によって、一定周期 $W/2$ でサーバに送られる。加えて、負担度検査器(Physical Load Checker)は、ユーザがウォーキング前に歩行ルートに対する負担度を確認するために、歩行ルートの特定や予想される歩行速度の算出などを行う。

Feature extraction module では、信号処理器(Signal Processor)により Mobile computing module から受信したデータの処理を行う。ここでは、受信した一定時間間隔(W)の測定データを基に 3.2 節で述べる方法を用いて、加速度の振幅、歩行速度、酸素摂取量などの予測に必要な特徴量を抽出する。

Prediction module では、抽出した特徴量を用いて心拍数予測を行うとともに、各特徴量および予測結果を共有データベース(共有 DB)に蓄積する。なお、受信するデータに合わせて、一定周期($W/2$)ごとに心拍数を予測するものとする。加えて、歩行速度調整器(Walking Speed Adjustor)により、現在の歩行速度で歩き続けた場合の心拍数変化を予測し、必要に応じて歩行速度の調整を促す。

3. スマートフォンを用いた心拍数推定

提案手法では、歩行データと心拍数の関連付けのために、ニューラルネットワークを用いて心拍数を予測する心拍数モデルを構築する。運動強度の変化直後は、心拍数はある値に向かって徐々に変化するという性質を持つ。提案手法では、運動強度とその継続時間を考慮するために、心拍数変化と同様の性質を持つ酸素摂取量に着目し、心拍数モデルの入力とする。

以下、心拍数モデルの作成手順(歩行データの収集、特徴量の抽出、モデルの構築)それぞれについて述べる。

3.1 スマートフォンによる歩行データの収集

2.4 節で述べたように、心拍数は歩行速度および勾配の

変化にともない変化する。また、トレッドミルを用いて歩行中の加速度を測定した予備実験では、歩行速度によって加速度の振幅に特に違いが見られた。加えて、運動中の心拍数は体内に酸素を補給するために増減することから、心拍数と酸素摂取量の相関は高いといえる。これより、心拍数の予測では、(i)–(iv) 加速度の振幅 (X 軸, Y 軸, Z 軸, 3 軸合成), (v) 歩行速度, (vi) 勾配, (vii) 酸素摂取量を心拍数モデルの入力パラメータ (特徴量) とする。

これらの特徴量を取得するために、スマートフォンに搭載されている加速度センサおよび GPS デバイスを用いて、歩行中の加速度および位置情報を収集する。このような時系列のデータがあれば、加速度データより加速度の振幅および歩行速度の取得が、GPS データ (位置情報) より勾配の取得が可能となり、さらには、歩行速度および勾配から酸素摂取量が算出できる (詳細は後述する)。

3.2 特徴量の抽出

測定した加速度データおよび GPS データから、前節で示した 7 種類の特徴量を以下の方法で抽出する。

3.2.1 加速度の振幅

3 軸加速度センサにより得られた各軸のデータおよび 3 軸合成のデータを使用し、4 種類の振幅を抽出する。

抽出では、予備実験の結果を基に、まず前処理として周波数 0 Hz の直流成分を除去する。そして、各データをハーフ・オーバーラップ方式でウィンドウサイズ W [s] のウィンドウに区切り、ウィンドウごとに平均振幅を算出する。なお、本研究で使用する特徴量はすべて、上記の抽出方法と同様に、ハーフ・オーバーラップ方式で区切ったウィンドウごとに算出するものとする。

3.2.2 歩行速度

歩行速度は、下記の式 (1) および (2) を用いて推定した移動距離を基に算出する。ここで、 S_k [m/s], $Dist_k$ [m], ST_k [歩], G_k [%] は、それぞれ、ウィンドウサイズが W [s] である k 番目のウィンドウにおける歩行速度の水平成分、水平方向の移動距離、歩数、勾配を表す。歩数は、加速度データを用いた歩数推定 [15], [16] を利用する。また、 SL [m/歩] は歩行ルートの総距離 ($Dist_{total}$ [m]) および歩数の総数 (ST_{total} [歩]) から算出する歩幅を表す。

$$S_k = Dist_k / W \quad (1)$$

$$Dist_k = ST_k \cdot SL \cdot \cos(\arctan(G_k/100)) \quad (2)$$

$$SL = Dist_{total} / ST_{total} \quad (3)$$

GPS より取得する位置情報から移動距離を求める方法も考えられるが、GPS は位置推定における誤差が大きいため、慣性センサ (加速度センサ, ジャイロセンサなど) を用いてスタート位置からの相対位置を推定するデッド・レコニング [8], [9] を使用する。




図 4 一定運動強度で運動した場合の酸素摂取量の変化
Fig. 4 Oxygen uptake change with constant physical load.

3.2.3 勾配

道の勾配は、下記に示す式 (4) より算出する。ここで、 G_k [%], $Dist_k$ [m], AD_k [m] は、 k 番目のウィンドウにおける勾配、移動距離、標高差を表す。なお、 AD_k [m] は、各ウィンドウに含まれる L 点の位置情報 (GPS データの計測周期による) のうち、1 点目と L 点目の標高差である。

$$G_k = (AD_k / Dist_k) \times 100 \quad (4)$$

3.2.4 酸素摂取量

本項では、提案手法の鍵となる酸素摂取量の推定方式について詳細を述べる。

酸素摂取量は、各運動強度に対応した値まで瞬間的に増大するのではなく、運動開始後 2–3 分で定常状態へと近づくという性質を持つ。ここで、各運動強度に対応した値とは、運動中に必要となる酸素量 (以下、酸素需要量) を意味する。図 4 に、一定運動強度で運動した場合の酸素摂取量の変化を示す。図 4 において (a) は増加時、(b) は減少時の図であり、 K は酸素需要量を表す。

このとき、 t 秒間における酸素摂取量の増加量 ΔU [ml/kg/min] および減少量 ΔD [ml/kg/min] は、運動に必要なエネルギーを生み出すために必要な酸素量 (酸素需要量) K [ml/kg/min], 酸素需要量に収束するまでの時間を表すパラメータ τ_u (増加時), τ_d (減少時) を用いて次式のように表される [17], [18]。

$$\Delta U = K e^{-\frac{\tau_u}{t}} \quad (5)$$

$$\Delta D = K (1 - e^{-\frac{\tau_d}{t}}) \quad (6)$$

酸素需要量 K [ml/kg/min] はある運動強度における酸素摂取量の理論値と一致すると仮定すると、 K は式 (7)–(10) より計算できる [14]。

$$K = R + H + V \quad (7)$$

$$R_{Oxygen} = 3.5 \quad (8)$$

$$H_{Oxygen} = 0.1 \times speed \quad (9)$$

$$V_{Oxygen} = 1.8 \times speed \times grade \quad (10)$$

ここで、 R_{Oxygen} は安静時の酸素摂取量、 H_{Oxygen} は歩行速度の水平方向成分のみを考慮して算出した酸素摂取量、 V_{Oxygen} は勾配の増加にともない必要となる、歩行速度の垂直方向成分のみを考慮して算出した酸素摂取量である。

酸素需要量および運動時間が分かれば、酸素摂取量の変化量を求めることが可能であるが、ここで課題となるのは、歩行ルートが一定ではなく変化すること、勾配が一定でも、歩行者の意図に反して（同じ速度で歩いていると思っけても）歩行速度はつねに変化することである。したがって本アルゴリズムでは、周期的に一定時間分の酸素需要量を求め、直前の周期における酸素摂取量からの増減に応じて酸素摂取量の変化量を算出する。

酸素摂取量推定処理の基本的な流れを以下に示す。算出の時間間隔を P 、時刻 $t_i = t_0 + i \times P$ ($i = 1, 2, 3 \dots$) における酸素需要量を K_i 、酸素摂取量を V_i とする。このとき、時刻 t_i における酸素摂取量の算出は、次に示す3つのステップで行われる。

- ステップ1：酸素需要量の計算
- ステップ2：変化傾向の決定
- ステップ3：酸素摂取量の変化量の計算

まずステップ1では、一定時間 P ($= t_{i+1} - t_i$) における平均歩行速度および平均勾配から式(7)–(10)を基に酸素需要量 K_i を算出する。そしてステップ2で、求めた K_i と P 秒前の酸素需要量 K_{i-1} を比較し、酸素需要量の変化が「増加」、「減少」、「変化なし」のいずれであるかを決定する。ステップ3では、ステップ2で決定した変化傾向に応じて、下記のように酸素摂取量 V_i を算出する。なお、変化傾向が「変化なし」の場合は、運動強度の変化はないものとし、それまでの変化を継続する。

- $K_i > K_{i-1}$ (増加) の場合

$$\Delta U_i = K_i e^{-\frac{\tau_d}{P}}$$

$$V_i = V_{i-1} + \Delta U_i$$

- $K_i < K_{i-1}$ (減少) の場合

$$\Delta D_i = K_i (1 - e^{-\frac{\tau_d}{P}})$$

$$V_i = V_{i-1} - \Delta D_i$$

- $K_i = K_{i-1}$ (変化なし) の場合
 - P 秒前の変化傾向が「増加」の場合

$$\Delta U_i = K_i (e^{-\frac{\tau_d}{2P}} - e^{-\frac{\tau_d}{P}})$$

$$V_i = V_{i-1} + \Delta U_i$$

- P 秒前の変化傾向が「減少」の場合

$$\Delta D_i = K_i \{ (1 - e^{-\frac{\tau_d}{2P}}) - (1 - e^{-\frac{\tau_d}{P}}) \}$$

$$V_i = V_{i-1} - \Delta D_i$$

以上のステップを繰り返すことで、歩行中の酸素摂取量を計算する。

なお、酸素摂取量の代わりに心拍数を同様の方法で推定し機械学習に入力する特徴量として用いることも考えられる。しかし、酸素摂取量は、数式(5)、(6)により歩行速度お

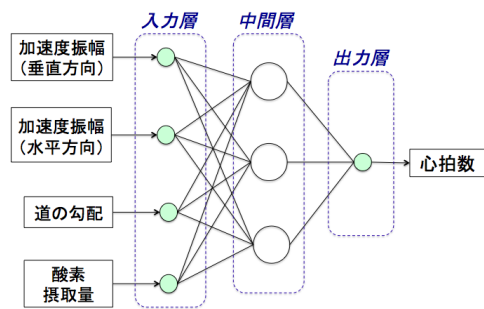


図5 階層型ニューラルネットワーク
Fig. 5 The structure of neural network.

よび勾配から直接算出することができるが、心拍数を歩行速度などから直接算出する方法は、著者らが調べた限りでは提案されていない。よって、提案手法では、酸素摂取量を機械学習に用いる特徴量の1つとして用いることとした。

3.3 機械学習に基づくモデルの構築

3.2節で得られた特徴量から、心拍数を予測するモデルを構築する。

2.4節で述べたように、心拍数モデルを構築する際には、歩行データ(特徴量)と心拍数の関連付けを行う必要がある。前節で述べた特徴量は心拍数変化と強い関連性があるが、各特徴量と心拍数の間には変化の仕方に非線形な関係がある[11]。また、文献[11]が心拍数の推定にニューラルネットワークを用いていることから、非線形な関係の効率良い学習が期待できると考え、ニューラルネットワークを用い、機械学習を測定データに適用することで心拍数モデルを構築する。

モデルの構築には、データマイニングツール WEKA3 [19] を使用する。このツールでは、図5に示すような、入力層、出力層、中間層を持つ階層型ニューラルネットワークが利用できる。ここでの学習は教師あり学習と呼ばれ、学習に必要な教師データ(以下、学習データ)により、あらかじめ、入出力の関係を学習させることで心拍数モデルを構築する。構築したモデルに対し、時刻 t_i から時刻 $t_i + W$ (W はウィンドウサイズ) における加速度や歩行速度などの時系列データ(以下、テストデータ)を与えることで、時刻 $t_i + W$ における心拍数が出力値(予測値)として算出される。

4. 個人差を考慮した心拍数推定

前章で述べた心拍数推定法では、心拍数変化の個人差(心拍数の変化幅、反応速度、絶対値)を酸素摂取量に反映できない。これは、実際のウォーキングでは同じ運動強度でも人によって心拍数の変化の仕方が異なるにもかかわらず、酸素摂取量を歩行速度および勾配のみから推定しているためである。また、心拍数の大きさは特に個人差が強く、心拍数の大きさを酸素摂取量に反映させることは難しい。

そこで、上記課題の解決のため、いくつかのパラメータを新たに導入し、それらの値をプロファイル（運動習慣や年齢など）より作成するカテゴリごとに最適化する。また、学習に使用する心拍数データを正規化することで、心拍数の大きさの違いを取り除く。

4.1 カテゴリの作成

これまでに述べたように、心拍数の変化には個人差がある。特に、運動習慣が大きく影響すると考えられ、予備実験より、同程度の運動習慣を持つ人は類似した心拍数変化を示すことが確認されている。これより、心拍数変化に関する個人差を吸収するには、運動習慣のタイプによって異なる心拍数変化の特徴を考慮する必要がある。

提案手法では、同一カテゴリに属するユーザはよく似た心拍数変化を示すと仮定し、ユーザの運動習慣や年齢などを基にカテゴリを作成する。そして、カテゴリごとに固有のパラメータ値を設定したうえで、モデルの構築を行う。

4.2 酸素摂取量の算出におけるパラメータの設定

酸素摂取量の算出には、いくつかのパラメータが影響している。なかでも、式 (5) および (6) において、 τ_u , τ_d は心拍数の変化のしやすさ（反応速度）、 K は運動強度を反映することから、心拍数変化に関連のあるパラメータであると考えられる。酸素需要量 K の個人差を考慮するため、提案手法では、新たなパラメータ M_s , M_g を導入する。なお、パラメータ M_s および M_g は、酸素需要量の算出時に、式 (9) を M_s 倍、式 (10) を M_g 倍するためのものである。

パラメータ M_s , M_g , τ_u , τ_d の決定手順を以下に示す。ここで用いる方法は非線形最適化と呼ばれており、複数の変数を持つ目標関数の最小値を初期推定値を使って探索する方法である。なお、ここでは1人の被験者について4つのパラメータを決定する手順を示す。また、各被験者はルート A-E の5つのルートにおいて歩行データを収集し（詳細は5.2.1 項）、各被験者の属するカテゴリは決まっているものとする。

(1) 被験者 s がルート r ($r \in \{A, B, C, D, E\}$) を歩いた場合の歩行データを基に、ルート r についてのパラメータ値の組 $P_r = \{M_s, M_g, \tau_u, \tau_d\}$ を求める。

- (a) 各パラメータ (M_s , M_g , τ_u , τ_d) をカテゴリごとに初期化。
- (b) ルート r で測定した心拍数データおよび歩行データを n 個のブロック B_j ($j = 1, \dots, n$) に分割。
- (c) j 番目のブロックに該当する心拍数データより、直線近似により心拍数増減の傾き LH_j を算出。
- (d) j 番目のブロックに該当する歩行データより、歩行速度および勾配を基に酸素摂取量を計算し、直線近似により酸素摂取量増減の傾き LV_j を算出。
- (e) LH_j と LV_j の二乗誤差 SE_j を計算。

(f) 二乗誤差 SE_j を目標関数とし、これを最小化するパラメータ値を探索。

(g) 各ブロックから得られた二乗誤差 SE_j ($j = 1, \dots, n$) のうち、二乗誤差が最小となったパラメータ値 (M_s , M_g , τ_u , τ_d) を P_r とする。

(2) パラメータ値の組 P_r ($r \in \{A, B, C, D, E\}$) より各パラメータの平均値を計算し、これを被験者 s 特有のパラメータ値とする。

なお、カテゴリごとにパラメータ値を設定するために、上記手順により各被験者について適切なパラメータ値を求めたうえで、同カテゴリの被験者から平均値をそれぞれ算出する。

4.3 心拍数の正規化

2.4 節の図 2 で示したように、心拍数の変化幅が同程度であっても、心拍数の大きさが異なる場合がある。これは、心拍数予測時に誤差が生じる原因となる。提案手法では、心拍数の大きさの違いを取り除くために、学習に使用するすべての心拍数データの初期値（開始時心拍数）を 0 にすることで正規化を行う。すなわち、正規化前の心拍数データ Hb_i ($i = 1, 2, 3, \dots$)、正規化後の心拍数データ Ha_i ($i = 1, 2, 3, \dots$)、開始時心拍数 HR_{start} は、下記の関係性を満たす。これより、心拍数の変化のみを考慮することができる。

$$Ha_i = Hb_i - HR_{start}$$

正規化後の心拍数データよりモデルを構築する場合、当然ながら、そのモデルにより得られた予測値は心拍数変化の特徴のみが反映されたものとなる。そこで、予測後の心拍数を開始心拍数で補正することで、各ユーザの本来の心拍数の大きさに変換する。すなわち、補正前の心拍数予測値 Pb_i ($i = 1, 2, 3, \dots$)、補正前の心拍数予測値 Pa_i ($i = 1, 2, 3, \dots$)、開始時心拍数を HR_{start} は、下記の関係性を満たす。なお、開始心拍数は安静時心拍数を用いるものとする。

$$Pa_i = Pb_i + (HR_{start} - Pb_1)$$

5. 心拍数モデルによる心拍数予測誤差の評価

3 章および 4 章で示した提案手法の有用性および心拍数の予測誤差について評価を行うために、18 人の被験者を対象に、評価実験を行った。

5.1 評価目的

評価の目的は、提案手法により構築した心拍数モデルにより得られる予測心拍数が、提案システムで利用する場合に正確であるかどうかを調査することである。そのために評価実験では、一般道で測定したデータから心拍数モデル

を構築し、心拍数の予測誤差を評価する。予測誤差は、歩行中に心拍計を用いて測定した心拍数の実測値とモデルにより得られた心拍数の予測値の平均誤差として算出する。

予備実験として、全被験者に対して座位の状態でも3分間の安静時心拍数を測定した（なお、測定した安静時心拍数は4.3節の開始心拍数 HR_{start} として使用する）。その結果、心拍数は安静時でも周期的に変動し、24秒間（ウィンドウサイズを24秒とするため）における心拍数の平均変化量は7bpmであることを確認した。一方、本実験に際して計測した各歩行ルートにおける心拍数の変動幅は17.25-66.58 [bpm] であり、安静時よりかなり変動幅が大きい。よって、歩行時の心拍数予測誤差は7bpm以内程度が妥当であると考えられる。また、表1のボルグ・スケールでは、隣り合うRPEレベル間の心拍数は10bpmであり、誤差が10bpm以内であれば、推定した負担度が真値と2レベル以上離れることはない。よって、評価では、7bpm以内の誤差を達成することを目標とする。

5.2 評価実験の設定

5.2.1 実験環境

歩行データおよび心拍数データの収集では、異なる運動習慣を持つ18人の被験者（20代、男性15人、女性3人）が腕時計型のワイヤレス心拍計（SUUNTO, t6d）[4]およびスマートフォン（Sony Ericsson, Xperia active）[20]を装着したうえで、異なる5つの歩行ルートを歩行した。

被験者は、心拍計を胸に、スマートフォンを腰（正面、中央）に装着し、加えて、スマートフォン搭載の加速度センサが図6に示す向きになるよう固定した。なお、サンプリング時間は、経験的に、加速度センサを20ミリ秒、心拍計を2秒、GPSセンサを3秒とする。また、図7に各歩行ルートの標高を示す。なお、各ルートの距離は、ルートA, C, Dが1,500m, Bが1,700m, Eが1,100mである。なお、Google Mapsなどで取得可能な標高データは誤差が大きかったため、実験では生駒市が編纂・販売している1/2,500スケールの生駒市全域地図に記載されている正確な標高データを各歩行ルートに沿って抽出し用いた。

5.2.2 カテゴリの作成

実験では、プロフィールとして、心拍数変化に最も影響



図6 使用デバイスと加速度センサの向き

Fig. 6 Usage devices and the acceleration directions.

すると考えられる運動習慣の有無および運動の継続期間のみを考慮し、以下の条件で3つのカテゴリ（カテゴリ1-カテゴリ3）を作成する。なお、ここでの「運動習慣あり」とは、国民健康栄養調査[21]の定義に従い、「週2回、1回30分以上の運動を1年以上継続している状態」を指す。加えて、運動の継続期間が長いとは、8-10年にわたり、週2回、1回30分以上の運動を継続していることを指す。

- カテゴリ1：現在運動習慣なし&過去運動習慣なし
- カテゴリ2：現在運動習慣あり&その継続期間が短い、もしくは、現在運動習慣なし&過去の運動習慣あり
- カテゴリ3：現在運動習慣あり&その継続期間が長い

なお、現在の運動習慣は直近の6カ月を対象としており、カテゴリ2に条件を2つ設定しているのは、予備実験において、これらの条件に合う被験者が同程度の歩行時の心拍数上昇を示したためである。各被験者のカテゴリを決定するために、運動習慣に関するアンケートを行った結果、カテゴリ1に5人、カテゴリ2に11人、カテゴリ3に2人の被験者が分類された。

上記のカテゴリごとの各歩行ルートにおける最小・最大・平均心拍数および変動幅を表2に示す。表から、カテゴリ




図7 歩行ルートの標高

Fig. 7 Gradients of five walking routes.

表2 各歩行ルートにおけるカテゴリごとの心拍数

Table 2 Heart rate for every category on each walking route.

		A	B	C	D	E
カテゴリー1	最小	99.0	106.9	104.7	99.2	105.5
	最大	151.6	148.6	137.4	137.3	127.3
	変動幅	52.5	41.7	32.8	38.1	21.9
	平均	125.1	125.9	119.9	123.9	117.6
カテゴリー2	最小	87.9	96.5	92.7	96.3	100.8
	最大	134.3	131.2	124.6	133.8	122.2
	変動幅	46.4	34.7	31.9	37.6	21.4
	平均	113.0	112.8	108.3	118.4	112.3
カテゴリー3	最小	78.2	87.6	87.2	81.4	80.8
	最大	108.7	113.5	106.3	113.0	99.8
	変動幅	30.5	25.9	19.2	31.6	19.0
	平均	95.4	96.7	96.1	96.0	88.4

1, 2, 3 の順で, 最小, 最大, 平均心拍数が減少しており, 各カテゴリ間にある程度の差異が見られる. また, 心拍数変動幅 (最大 - 最小) は, カテゴリ 1 とカテゴリ 2 の間に大きな違いは見られないが, カテゴリ 2 とカテゴリ 3 を比べると, 後者の方がかなり小さいことが分かる.

5.2.3 心拍数モデルの構築

モデルの構築では, 1 人の被験者があるルート (ルート A-E のいずれか) を歩行した際の実測データ (歩行データおよび心拍数データ) をテストデータとし, 学習データはテストデータを除く実測データの集合とする. 学習データは, 18 人 × 5 ルート - 1 = 89 組の (被験者, ルート) の歩行データとなり, 各組の歩行データは, (歩行時間 ÷ 12 秒) 個のサンプルからなる. 全 90 組のデータが含む合計サンプル数は 7,089, 平均は 78.8 であった. このデータより構築したモデルを RS11 と表記する. 以下に, 心拍数モデルの構築に必要な各パラメータの設定と予測誤差の算出方法について示す.

入力パラメータの選別

入力数が 4 を超えると個人差の影響 (たとえば, 歩き方などの違いが進行方向の加速度に影響する) により, 誤差がわずかに大きくなるということを予備実験により確認した. そこで, 7 種類の入力パラメータのうち個人差の影響を受けにくいものとして, 酸素摂取量 (VO), 勾配 (G), X 軸 (垂直) 方向および Y 軸 (水平) 方向の加速度の振幅 (AX, AY) の 4 つを心拍数モデルの構築で使用する入力パラメータとして選択した. なお, 個人差の影響の受けにくさは, 2 人同時に歩行した際の歩行データについて, 入力パラメータごとに算出する相関係数より決定する.

また, 評価実験では, ウィンドウサイズ W は経験的に 24 秒とする^{*1}. 特徴量の抽出では, 実測データ (加速度データ, 位置データ) をハーフ・オーバーラップでウィンドウに分割するため, 各特徴量は 12 秒ごとの時系列データとなる.

予測誤差の算出方法

構築した心拍数モデルの予測誤差は, 心拍数の予測値と実測値より計算する平均絶対誤差 (MAE: Mean Absolute Error) を基に算出する.

被験者 s ($s \in \{s1, s2, \dots, s18\}$) がルート r ($r \in \{A, B, C, D, E\}$) を歩行した際の実測データをテストデータとした場合, 心拍数モデル m (RS11) より得られた平均絶対誤差 MAE [bpm] は, 式 (11) より算出できる.

ここで, ある歩行ルートに対する歩行時間を Q 秒 (整数), 時刻 t ($t > 0$) での予測心拍数, 実測心拍数をそれぞれ $phr(t)$, $rhr(t)$ とする. 予測心拍数はウィンドウサイズ

W 秒であるウィンドウごとに算出したものであり, 実測心拍数は W 秒間の平均値である. また, 特徴量はハーフ・オーバーラップ方式により計算するため, テストデータはサンプル数 n 個の時系列データである. サンプル数 n は, 式 (12) で表される.

$$Err(s, r, n) = \frac{\sum_{i=0}^{n-1} |phr(\frac{W}{2}i) - rhr(\frac{W}{2}i)|}{n} \quad (11)$$

$$n = \frac{2Q}{W} \quad (12)$$

構築したモデルより得られる予測誤差 $ErrM(m)$ [bpm] は, 式 (13) により計算する. これは, 全被験者および全歩行ルートについて算出する平均誤差である.

$$ErrM(m) = \frac{\sum_{r \in Route} \sum_{s \in Subject} Err(s, r, n)}{|Subject| \times |Route|} \quad (13)$$

ここで, $Subject = \{s1, \dots, s18\}$, $Route = \{A, B, C, D, E\}$ である.

5.3 評価および考察

全被験者および全歩行ルートに対して行った予測結果を, 表 3 に示す. これは, 歩行ルートごと, 被験者ごとの心拍数の予測誤差である.

この表にあるように, 同じ被験者でも歩行ルートによって, もしくは, 同じ歩行ルートでも被験者によって予測誤差は異なるが, 全体で 6.37 bpm の平均誤差で予測することができた.

カテゴリごとの平均に注目すると, カテゴリ 3 が 5.36 bpm と誤差が最も小さく, カテゴリ 1 とカテゴリ 2 はそれぞれ誤差が 6.40 bpm, 6.60 bpm であった. カテゴリ 3 の被験者は心拍数変動が少なく, より正確な心拍数推定が可能であることが分かった.

歩行ルートごとに算出した予測誤差に着目すると, 特に, 歩行ルート A, B, C, E については, 目標予測誤差 7 bpm を下回る結果が得られた. しかしその一方で, 歩行ルート D の予測誤差は比較的大きい結果となった. ルート D は, 他のルートに比べて勾配がより急な道を含むため, 心拍数増加時に個人差が出やすく, その急激な心拍数変化をうまく予測できない場合に予測誤差が大きくなったと考えられる. これは, 勾配が頻繁に変化する歩行ルート, もしくは, 勾配が急な歩行ルートで測定した実測データを学習データに追加することで改善が期待できる.

被験者ごとに算出した予測誤差に着目すると, おおむね, 目標誤差 7 bpm 以下もしくは 7 bpm に近い予測誤差が得られている. ここで, 少ない誤差で心拍数を予測できた場合の結果として, s4 および s13 についての結果を図 8 および図 9 に示す. これらの結果より, 細かい心拍数変動まで予測することはできないが, おおむね, 心拍数変化に追従できていることが分かる.

しかし, なかには推定誤差が大きい場合もある. 表 3 に

*1 心拍計, GPS のサンプリング周期の最小公倍数で, かつ, ハーフ・オーバーラップ方式を用いる場合の最小のウィンドウサイズは 12 秒であるが, 24 秒の方がデッド・レコニングによる歩行速度の推定精度が良かったため.

表 3 様々な歩行ルートに対する心拍数予測結果および複数被験者に対する心拍数予測結果

Table 3 Prediction results (MAE) for all subjects/routes.

被験者 (sub)	カテゴリ	歩行ルート (route)					平均
		A	B	C	D	E	
s1	1	7.13	9.28	4.16	10.89	1.56	6.60
s2	1	15.07	5.24	4.73	16.24	3.00	8.86
s3	1	4.64	5.91	4.00	10.15	8.40	6.62
s4	1	5.41	5.35	7.64	5.05	2.39	5.17
s5	1	3.23	4.42	4.16	4.14	5.42	4.27
カテゴリ 1 平均		7.10	6.04	4.94	9.29	4.15	6.40
s6	2	5.80	2.92	3.05	9.45	3.93	5.03
s7	2	4.44	10.52	4.44	4.83	6.33	6.11
s8	2	12.00	4.84	4.11	13.86	4.56	7.87
s9	2	2.86	3.22	5.17	4.81	7.28	4.67
s10	2	5.11	4.00	8.24	5.95	3.65	5.39
s11	2	6.83	9.63	2.60	10.70	7.96	7.55
s12	2	11.32	7.12	5.66	7.85	6.91	7.77
s13	2	2.86	3.92	4.44	4.71	4.60	4.11
s14	2	3.93	3.19	4.73	18.23	1.43	6.30
s15	2	4.97	4.20	9.70	9.23	14.38	8.50
s16	2	11.46	7.81	8.11	14.32	4.05	9.15
カテゴリ 2 平均		6.51	5.58	5.48	9.45	5.92	6.60
s17	3	8.13	6.87	6.60	4.09	3.35	5.81
s18	3	4.99	9.96	4.58	3.30	1.67	4.90
カテゴリ 3 平均		6.56	8.42	5.59	3.7	2.51	5.36
平均		6.68	6.02	5.34	8.77	5.05	6.37




図 8 心拍数の予測結果 (s4, E)

Fig. 8 Prediction of heart rate change (s4, E).




図 10 心拍数の予測結果 (s14, D)

Fig. 10 Prediction of heart rate change (s14, D).




図 9 心拍数の予測結果 (s13, A)

Fig. 9 Prediction of heart rate change (s13, A).




図 11 心拍数の予測結果 (s2, D)

Fig. 11 Prediction of heart rate change (s2, D).

示す結果を見ると、6人の被験者 (s2, s8, s11, s12, s15, s16) は予測誤差が比較的大きく、目標誤差を上回っている。

表 3 において、最も推定誤差が大きい組 (s14, D) と 2 番目に誤差が大きい (s2, D) の心拍数の推移を、それぞれ、図 10 と図 11 に示す。前者は、歩行開始時の心拍数の上昇をとらえきれず、後者は 300s 以降に心拍数が下がらず高い値に停滞しているのを予測できていない。

被験者によって誤差の大きさや誤差が出やすいルートは異なるが、いずれの被験者についても、予測誤差が大きくなる原因は酸素摂取量の算出にある。酸素摂取量は、歩行速度および移動距離の算出時に生じる誤差に加え、パラメータ τ_u , τ_d , M_s , M_g の値の影響を受ける。たとえば、




図 12 酸素摂取量の効果
Fig. 12 Effectiveness of oxygen uptake.

該当カテゴリの中でも強い負担を感じやすいにもかかわらず、パラメータ M_s , M_g に設定したパラメータ値が適切でなかったために、その特徴が算出時に反映されていない場合には、心拍数の急激な変化を予測することが特に難しくなる。パラメータ M_s , M_g はカテゴリごとに値を設定するため、よりの確かなカテゴリの作成方法について今後の検討が必要であると考えられる。

5.3.1 酸素摂取量の有効性

3.2.4 項で述べた酸素摂取量の有効性について評価を行う。そのために、酸素摂取量を入力に含む場合 (VO あり, 入力: 酸素摂取量 (VO), 勾配 (G), X 軸および Y 軸の加速度振幅 (AX, AY)) とそうでない場合 (VO なし, 入力: 勾配 (G), X 軸および Y 軸の加速度振幅 (AX, AY)) について、心拍数の予測誤差を比較する。

図 12 に、モデル RS11 より得られた予測誤差 $ErrM(RS11)$ [bpm] を示す。ここで、エラーバー (誤差範囲) は標準偏差を表す。VO ありと VO なしの予測誤差を比較するために t 検定 (有意水準 0.05, 以降すべて同じ) を行った結果、有意差が見られた ($p < 0.0001$)。また、VO なしの場合の誤差が 16.71 bpm, ありの場合が 6.37 bpm となり、酸素摂取量をモデルの入力とすることで、10 bpm 以上誤差が軽減されている。よって、酸素摂取量をモデルの入力として用いることは誤差軽減に有効であるといえる。

5.3.2 個人差吸収のカテゴリ化およびパラメータの導入に関する効果

5.2.2 項で作成したカテゴリおよび導入したパラメータの効果について示す。そのために、3 章および 4 章で述べた酸素摂取量の推定に必要なパラメータ (M_s , M_g , τ_u , τ_d) をカテゴリごとに設定する場合とそうでない場合の予測結果を比較する。

- 設定 1: 全カテゴリに同じ値を設定
- 設定 2: τ_u および τ_d のみをカテゴリごとに設定
- 設定 3: M_s および M_g のみをカテゴリごとに設定
- 設定 4: 全パラメータをカテゴリごとに設定

4.2 節で述べた方法を基に決定した各パラメータを、表 4 に示す。3.2.4 項および 4.2 節で述べたように、パラメータ τ_u , τ_d は心拍数の変化しやすさ (反応速度) を、パラメータ M_s , M_g は感じる負担度の強さを表している。表 4 に示す結果では、運動習慣のない人 (カテゴリ 1) ほど負担を強く感じ、心拍数が上がりやすく下がりにくいという特

表 4 各カテゴリにおけるパラメータ値
Table 4 Parameter values for each category.

カテゴリ	M_s	M_g	τ_u	τ_d
1	1.56	1.45	62.22	84.28
2	1.25	1.27	64.94	70.53
3	1.24	1.20	79.77	40.16




図 13 カテゴリごとのパラメータ設定効果
Fig. 13 Effectiveness of parameter for every category.

徴が現れていることが分かる。

図 13 に心拍数の予測結果を示す。これは、モデル RS11 より得られた予測誤差であり、エラーバーは標準偏差を表す。なお、設定 1-設定 4 において、全カテゴリに同じパラメータ値を設定する場合は、 $M_s = 1.16$, $M_g = 1.31$, $\tau_u = 68.98$, $\tau_d = 64.99$ とする。これらの値は、表 4 に示したパラメータ値の平均値である。また、カテゴリごとに異なるパラメータ値を設定する場合は表 4 に従う。

カテゴリ作成の効果についての評価として、設定 1 とその他の設定 (設定 2, 設定 3, 設定 4) との予測誤差をそれぞれ比較する。それぞれの場合について 5.3.1 項と同様に t 検定を行った結果、設定 1 と設定 2 の比較では有意差が見られなかった ($p > 0.2$) が、残りの場合については有意差が見られた (いずれの場合も $p < 0.05$)。

また、4 種類のパラメータ (τ_u , τ_d , M_s , M_g) の導入効果についての評価として、設定 1 と設定 2, 設定 2 と設定 3, 設定 3 と設定 4 の予測誤差をそれぞれ比較する。それぞれの場合について同様に t 検定を行った結果、設定 1 と設定 2 および設定 3 と設定 4 を比較した場合は有意差は見られず (いずれの場合も $p > 0.2$)、設定 2 と設定 3 を比較した場合にのみ有意差が見られた ($p < 0.05$)。

以上より、作成したカテゴリごとにパラメータ値を設定することで、予測誤差の軽減が可能である。特に、パラメータ M_s および M_g をカテゴリごとに設定することが効果的であると考えられる。

一方、図 13 では、パラメータ τ_u , τ_d を導入・設定することの効果が見られなかった。今後、これらのパラメータによりカテゴリごとの心拍数予測誤差を改善できる可能性があるかを詳細に検討する必要がある。

5.3.3 心拍数の正規化の効果

4.3 節で示した心拍数の正規化の効果について評価を行うために、各モデルについて正規化を行う場合と行わない場合の予測誤差を比較する。




図 14 心拍数正規化の効果

Fig. 14 Effectiveness of normalization.

表 5 各モデルより得られる予測誤差

Table 5 MAE of heart rate estimation by different models.

心拍数モデル (model)	RS00	RS01	RS10	RS11
予測誤差 [bpm]	6.87	6.66	6.55	6.37

図 14 に、モデル RS11 より算出した予測誤差 ($ErrM(RS11)$) を示す。ここで、エラーバー (誤差範囲) は標準偏差を表す。正規化を行う場合と行わない場合の予測誤差を比較するために、これまでと同様に t 検定を行った結果、有意差が見られた ($p < 0.01$)。これより、心拍数の正規化は予測誤差を軽減する効果があるといえる。

5.3.4 他のモデルによる評価

RS11 以外のモデルとして、推定したい歩行ルート r およびユーザ s に対し、学習データとして、 r のデータ (他のユーザのも含む) も s のデータもいっさい使用しないモデル RS00、 r のデータ (他のユーザのも含む) は使用しないが s の r 以外のルートに対するデータを学習データに使用するモデル RS01、 s のデータ (全ルート) は使用しないが r の他のユーザのデータは使用するモデル RS10 に対しても評価を行った。予測誤差の結果を表 5 に示す。

表より、ルートに対するデータが存在しない場合 (RS01)、本人データが存在しない場合 (RS10)、どちらも存在しない場合 (RS00) においても、目標誤差である 7 bpm 以内を達成できていることが分かる。特に、モデル RS10 は、歩行データが存在しない新規ユーザに対する歩行時心拍数を、RS11 よりわずか 0.18 bpm 大きい平均 6.55 bpm の誤差で推定でき、また、モデル RS01 は、歩行データが存在しない新規歩行ルートでも、誤差 6.66 bpm で心拍数を推定できることを表している。これらのモデルは、提案手法を実装し普及させるうえで有用であると思われる。

5.4 誤差要因に関する考察

推定した心拍数の誤差は、(1) 酸素摂取量の誤差、(2) モデルの推定誤差から構成される。このうち、(1) に関しては、(1a) 歩行速度、(1b) 各位置での標高データが誤差の要因になりうる。また、モデルの推定誤差は、(2a) 学習データの不足、(2b) 個人差、(2c) その他が要因として考えられる。

(1b) に関して、Google Maps などで取得可能な標高データは誤差が大きかったため、実験では地方自治体が販売する地域地図に記載の正確な標高データを用いることで、標

高の誤差による影響を回避した。(1a) に関して、GPS により計測した時系列位置情報から歩行速度を算出すると、連続する位置の誤差により速度の変化が激しくなること、また、離れた 2 点の GPS 位置情報から平均歩行速度を求める方法では、短い時間間隔での歩行速度の変化が求められないことから、酸素摂取量の変化に反映できないことが予備実験より分かった。以上より、提案手法では 3.2.2 項で述べたデッド・レコニングを基とした歩行速度推定を採用し、短い時間間隔での歩行速度の相対的な変化を求め、酸素摂取量の変化をある程度正確に算出することを可能にしている。しかし、デッド・レコニングによる歩行速度についても誤差は存在する。歩行速度の誤差および心拍数推定に与える影響については、今後評価を行いたい。

(2a) に関しては、現状では 18 人の被験者のそれぞれに対し、5 つの歩行ルートのデータを学習データとして取得しているにすぎず、より学習データを充実させることで、さらにモデルの推定精度を高めることができる可能性がある。今後学習データを増やし、誤差の改善効果に関する評価を行いたい。また、(2b) に関して、提案する個人差の吸収方法の結果である図 13, 14 がそれほど良い効果を示しているとはいえ、提案手法には改善の余地が残っている。特に、5.2.2 項のカテゴリ分けに関しては、運動の種類などによらず、単に運動習慣の有無で分けており、カテゴリの定義に関しては改善の余地がある。一方、男女を分けることに関しては、予備実験の結果から、男女差よりも運動習慣による個人差が大きかったこと、性差によって明確に心拍数に違いが生じるといった既存研究が調べた限り見つからなかったことから、今回は考慮しなかった。

以上述べたように、心拍数の推定誤差に影響を与える複数の要因が存在し、今後各要因が与える影響について調査を進めたい。しかしながら、図 12 に示しているように、提案する酸素摂取量をモデルへの入力とすることで、デッド・レコニングなどの誤差も含めたモデルの推定誤差が 10 bpm 以上、割合では 62% 以上軽減されており、提案手法の効果がある程度示せたと考えている。

6. 関連研究

1 章および 2 章で述べたように、提案システムの実現には、(i) 手軽な負担度の推定、(ii) 負担度の変化推定、(iii) 年齢、運動習慣などの個人差の考慮が必要である。本章では、この 3 点に着目したうえで関連研究について述べる。

6.1 スマートフォンを用いた運動中のコンテキスト推定

スマートフォンは普及デバイスであるうえに、加速度センサや磁気センサ、GPS などのセンサが搭載されており、様々なコンテキストの推定に使用されている。

Khan ら [6]、Sun ら [7] は、スマートフォンに搭載され

た3軸加速度センサのみを用いて活動識別を行っている。これらの研究では、「安静」、「歩行」、「階段の昇降」、「走行」などの運動強度の異なる活動を対象に、約94%の識別精度を達成している。

そのほかにも、歩数推定 [15], [22] や進行方向の推定 [23], さらにこれらに基づく歩行者の位置推定 (デッド・レコニング) [8], [9] など、スマートフォンを用いた研究は数多く存在する。ただし、これらの研究は負担度推定を目的とした研究ではないため、本研究とは異なる。

6.2 心拍数予測に関する研究

心拍数予測を行うことを目的とした研究には、心拍計を装着したうえで一定時間後の心拍数予測を行うもの [2], [3] と、心拍計の装着なしに予測を行うもの [11] に分けられる。

前者は、1章で述べた既存の運動支援システムで用いられている手法であり、再生する音楽のテンポと心拍数を関連付けるモデルを基に、歩行速度の変化にともなう心拍数変化を予測している。ここでは、心拍計により測定する心拍数および歩行速度をモデルの入力として使用するため、入力データの正確さは保証されている。加えて、システムの指示どおりにユーザが歩行速度を変えることが前提であるため、歩行速度の変化量および変化するタイミングは既知である。これより既存手法は、心拍数の予測が比較的容易な環境を想定している。それに対して本研究は、心拍計の装着なしに心拍数を予測することを前提とし、突発的に歩行速度や道の勾配が変化する環境を想定しているため、予測がより困難になる。

後者の手法には、Xiaoら [11] が提案した、ニューラルネットワークを用いた心拍数予測モデルがある。ここでは、3軸加速度センサにおける各軸の加速度および1ステップ前の心拍数予測値を入力として与えており、推定平均誤差5bpmで予測可能という結果が報告されている。しかし、この手法は、各時刻 t_i の心拍数を直前の時刻 t_{i-1} での実測加速度データと予測心拍数をもとに推定しており、心拍数の誤差が時間の経過とともに累積されていくため、歩行時のように心拍数が急激に変化するような場面での使用は難しい。また、この研究では、個人差に関する考慮は特に行われていない。

6.3 運動強度推定に関する研究

運動強度の任意の変化を検出するために、リアルタイムでの運動強度推定に重点を置いた研究がいくつかある。

Tapiaら [10] は、加速度センサと心拍計を併用し、「座位」、「歩行」、「走行」、「階段の昇降」、といった5種類の活動種別の推定およびその運動強度の推定を行っている。ここでは、心拍計の装着が必要であるため、これまで述べてきたように、コストや手間に関する問題がある。また、運動強度の推定では、論文中で定義されている3段階の運動

強度 (低, 中, 高) に分類するだけであるため、定量的な推定は行われず、個人差についても考慮されていない。

6.4 スマートフォンのカメラ画像を用いた心拍数推定

追加のデバイスを使用せずスマートフォンのみで心拍数を推定するアプリケーションが開発されている。Heart Rate Monitor [24] は、スマートフォンのカメラレンズ部に指をかざすことで脈拍を測定することができる。Cardio Buddy [25] はスマートフォンカメラで取得したユーザの表情から心拍数を予測する。しかし、これらのアプリケーションでは、指や顔の映像を正確に取得する必要があるため、歩行中の心拍数の計測は難しい。

7. まとめ

本論文では、スマートフォン搭載センサのみを用いた心拍数推定手法について述べた。

提案手法の評価実験では、複数の被験者および複数の歩行ルートについて心拍数予測を行った結果、本人データや歩行ルートのデータをモデルの学習に使用しない場合でも、7bpm以下の平均誤差で心拍数の推定ができることが分かった。また、提案する酸素摂取量推定手法を適用することで、10bpm以上誤差を軽減できることが分かった。

今後は、より個人差を反映した高精度な推定を可能にするため、ユーザカテゴリの作成方法について詳しく検討するとともに、心拍数特性が異なる被験者 (異なる世代など) を加えた実験や長時間のウォーキングを対象にした実験、歩行速度をコントロールした場合の心拍数予測について評価することを計画している。また、本論文では機械学習モデルとしてニューラルネットワークを用いたが、スマートフォンで予測心拍数を算出できるよう、他のより軽量の学習モデルの使用も検討していきたい。

謝辞 本研究の一部は、JSPS 科研費 25280031 の助成のもと行った。

参考文献

- [1] Laursen, A.H., Kristiansen, O.P., Marott, J.L., Schnohr, P. and Prescott, E.: Intensity versus duration of physical activity: Implications for the metabolic syndrome, A prospective cohort study, *BMJ Open*, Vol.2, No.5 (2012).
- [2] Oliver, N. and Flores-Mangas, F.: MPTrain: A mobile, music and physiology-based personal trainer, *Proc. 8th Conf. on Human-computer Interaction with Mobile Devices and Services (MobileHCI '06)*, pp.21-28 (2006).
- [3] Wijnalda, G., Pauws, S., Vignoli, F. and Stuckenschmidt, H.: A Personalized Music System for Motivation in Sport Performance, *J. IEEE Pervasive Computing*, Vol.4, No.3, pp.26-32 (2005).
- [4] SUUNTO: Heart Rate Monitor, Suunto t6d Black Smoke (online), available from (<http://www.suunto-japan.jp/products/contents/sportscomputer/training/t-6d/SS015843000>) (accessed 2011-08-22).
- [5] POLAR: Basic heart rate and timing (online), available

from (http://www.bigblue.gr.jp/polar/polar_rs/polar_rs100.h-tml) (accessed 2011-08-22).

[6] Khan, A.M., Lee, Y.-K., Lee, S. and Kim, T.-S.: Human Activity Recognition via an Accelerometer-Enabled-Smartphone Using Kernel Discriminant Analysis, *Proc. 5th Int'l Conf. on Future Information Technology (FutureTech 2010)*, pp.1-6 (2010).

[7] Sun, L., Zhang, D., Li, B., Guo, B. and Li, S.: Activity Recognition on an Accelerometer Embedded Mobile Phone with Varying Positions and Orientations, *Proc. 7th Int'l Conf. on Ubiquitous Intelligence and Computing (UIC '10)*, Lecture Notes in Computer Science, Vol.6406, pp.548-562 (2010).

[8] Jin, Y., Toh, H.S., Soh, W.S. and Wong, W.C.: A robust dead-reckoning pedestrian tracking system with low cost sensors, *Proc. IEEE Int'l Conf. on Pervasive Computing and Communications (PerCom 2011)*, pp.220-230 (2011).

[9] Steinhoff, U. and Schiele, B.: Dead reckoning from the pocket - An experimental study, *Proc. IEEE Int'l Conf. on Pervasive Computing and Communications (PerCom 2011)*, pp.162-170 (2010).

[10] Tapia, E.M., Intille, S.S., Haskell, W., Larson, K., Wright, J., King, A. and Friedman, R.: Real-Time Recognition of Physical Activities and Their Intensities Using Wireless Accelerometers and a Heart Rate Monitor, *Proc. 11th IEEE Int'l Symp. on Wearable Computers (ISWC 2007)*, pp.37-40 (2007).

[11] Xiao, F., Chen, Y., Yuchi, M., Ding, M. and Jo, J.: Heart Rate Prediction Model Based on Physical Activities Using Evolutionary Neural Network, *Proc. 4th Int'l Conf. on Genetic and Evolutionary Computing (ICGEC 2010)*, pp.198-201 (2010).

[12] Borg, G.: Psychophysical Scaling with Applications in Physical Work and the Perception of Exertion, *Scand. J. of Work Environ. Health*, Vol.16, No.1, pp.55-58 (1990).

[13] Borg, G.: Perceived Exertion: A Note on "History" and Methods, *ACSM J. Med. Sci. Sports Exerc. (MSSE)*, Vol.5, pp.90-93 (1973).

[14] American College of Sports Medicine: *ACSM's Guidelines for Exercise Testing and Prescription*, 7th edition, Lippincott Williams & Wilkins, Philadelphia (2005).

[15] Shin, S.H., Lee, M.S., Park, C.G. and Hong, H.S.: Pedestrian dead reckoning system with phone location awareness algorithm, *Proc. IEEE/ION Position, Location and Navigation Symp. (PLANS 2010)*, pp.97-101 (2010).

[16] Ying, H., Silex, C., Schnitzer, A., Leonhardt, S. and Schiek, M.: Automatic Step Detection in the Accelerometer Signal, *Proc. 4th Int'l Workshop on Wearable and Implantable Body Sensor Networks (BSN 2007)*, Vol.13, pp.80-85 (2007).

[17] Barstow, T.J. and Mole, P.A.: Linear and Nonlinear Characteristics of Oxygen Uptake Kinetics during Heavy Exercise, *J. Applied Physiology*, Vol.71, No.6, pp.2099-2106 (1991).

[18] 佐川貢一, 石原 正, 猪岡 光, 猪岡英二: 歩行形態の違いを考慮した消費カロリーの無拘束推定, 計測自動制御学会, Vol.183, No.7, pp.1-8 (1999).

[19] WEKA3: Data Mining with Open Source Machine Learning Software in Java, (online), available from (<http://www.cs.waikato.ac.nz/ml/weka>) (accessed 2011-11-29).

[20] SONY: Xperia active (Android Smartphone) (online), available from (<http://www.sonymobile.com/gb/>

products/phones/xpe-ria-active/) (accessed 2012-12-03).

[21] 厚生労働省:平成 22 年国民健康栄養調査 (オンライン), 入手先 (<http://www.mhlw.go.jp/bunya/kenkou/eiyou/dl/h22-houkoku-01.pdf>) (参照 2013-01-10).

[22] Mladenov, M. and Mock, M.: A Step Counter Service for Java-enabled Devices Using a Built-in Accelerometer, *Proc. 1st Int'l Workshop on Context-aware Middleware and Services (CAMS '09) in COMSWARE '09*, pp.1-5 (2009).

[23] Hoseinitatabaei, S.A., Gluhak, A. and Tafazolli, R.: uDirect: A novel Approach for Pervasive Observation of User Direction with Mobile Phones, *Proc. IEEE Int'l Conf. on Pervasive Computing and Communications (PerCom 2011)*, pp.74-83 (2011).

[24] code4food: Heart rate monitor (online), available from (<https://www.quixey.com/app/2207732023/heart-rate-monitor>) (accessed 2013-07-28).

[25] Azumio Inc.: Cardio buddy - Touchless camera heart rate monitor (online), available from (<https://itunes.apple.com/us/app/cardio-buddy-touchless-camera/id554391046?mt=8>) (accessed 2013-07-28).



隅田 麻由

2011 年奈良女子大学理学部情報科学科卒業。2013 年奈良先端科学技術大学院大学情報科学研究科博士前期課程修了。現在、アークレイ株式会社で機器開発に従事。



水本 旭洋 (学生会員)

2009 年近畿大学理工学部卒業。2011 年奈良先端科学技術大学院大学情報科学研究科博士前期課程修了。現在、同研究科博士後期課程在学中。ユビキタスコンピューティングに関する研究に従事。



安本 慶一 (正会員)

1991 年大阪大学基礎工学部情報工学科卒業。1995 年同大学院博士後期課程退学後、滋賀大学経済学部助手。2002 年奈良先端科学技術大学院大学情報科学研究科助教授, 2011 年より同研究科教授。博士 (工学)。モバイルコンピューティング, ユビキタスコンピューティングに関する研究に従事。電子情報通信学会, ACM, IEEE 各会員。