

楽 WALK : スマートフォンを用いた歩行時心拍数推定システム

RAKUWALK : heart rate prediction system during walking with smartphone

隅田 麻由¹ 水本 旭洋^{1,2} 安本 慶一¹

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

概要 :

ウォーキングは、健康維持・増進に効果的な運動である。しかし、負担の高い無理なウォーキングは逆効果であり、効果的かつ継続的にウォーキングを実施するには、個人の身体能力に応じた歩行ルートを選択が必要である。歩行中の身体的負担度は心拍数から推定可能であるが、心拍計などの特殊デバイスの装着は手間がかかる。本研究では、消費カロリーや歩行時間の制約を満たし、かつ、ユーザにとって負担度が最小となる歩行ルートを推薦するナビゲーションシステム、楽 WALK 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身体的負担度の推定法を提案する。提案手法では、個々人の負担度および負担度の変化を推定するために、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負担度モデルを作成する。実際のウォーキングで計測したデータに本手法を適用した結果、提案手法により平均絶対誤差 11bpm 以内で心拍数の推定ができることが分かった。

Abstract: Walking is effective exercise for maintaining and promoting healthy life, but high perceived exertion during walking may be counterproductive. For effective and continuous walking, it is necessary to select a walking route suitable for individual physical ability. Though perceived exertion during walking can be estimated by heart rate, it is costly for a user to equip with a special device such as a heart rate monitor. In this paper, aiming to realize a health-conscious walking navigation system that recommends a walking route with minimal perceived exertion satisfying constraints of calorie consumption and walking hours, we propose a system called RAKUWALK which estimates perceived exertion during walking with only available functions of a smartphone. For this purpose, we build a perceived exertion model which predicts the heart rate from walking data including acceleration and walking speed based on machine learning. We applied the proposed method to actual walking data and confirmed that the method estimates the heart rate within 11bpm.

1. はじめに

生活習慣病の予防には、運動の継続が重要である。特に、誰でも気軽に行うことができるウォーキングが近年注目されており、健康づくりのための運動指針 2006[1] では、1 日 1 万歩ウォーキングが推奨されている。しかし、自分の体力にあったルートを選択しなければ、心臓や関節に負担がかかり、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。

関連研究として、心拍計および加速度センサによる運動強度推定 [2][3] や心拍数予測 [4] を行う手法は存在するが、負担度の推定を目的としたものは存在しない。また既存ナビゲーションシステムでは、個人の身体能力を考慮したルートを検索することはできない。

本研究では、消費カロリーや歩行時間の制約を満たし、かつ、ユーザにとって負担度が最小となる歩行ルートを推薦するナビゲーションシステム、楽 WALK の実現を目指し、様々な歩行ルートに対する負担度推定手法を提案する。負担度の推定には、次に示す 3 つの課題が挙げられる。負担

度は心拍数より算出可能であるが、心拍計の装着に手間がかかり (課題 1)、身体能力に応じて同じ運動量でも負担度には個人差がある (課題 2)。また、様々な歩行ルートに対する負担度の推定には大量のデータが必要であり、収集のコストが高い (課題 3)。そこで、課題 1 および課題 2 の解決のため、年齢や性別などの属性により作成したカテゴリごとに、負担度モデルを作成する。負担度モデルとしては、スマートフォンから取得する加速度の振幅や周波数、歩行速度や道の勾配などのデータと、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。加えて、課題 3 の解決のため、ユーザ参加型センシング [12] によりデータを収集および共有し、歩行ルート検索時に負担度を推定できるようにする。

提案手法の評価では、負担度モデルに与える入力項目の検討および推定精度の評価を行う。ここでは、実際に一般道で測定したデータから作成した負担度モデルを用意し、前回の実験 [5] で入力として有用性が確認できた酸素摂取量について、一般道での実験における有用性を評価する。更に、実測値とモデルより得られた予測値を比較することで、予測誤差および負担度の推定精度を算出するとともに、高い精度が得られる入力パラメタの組み合わせを求める。また、求めた入力パラメタの組み合わせを用いることで、歩行ルートに関わりなく平均絶対誤差 11bpm 以内での心拍数の推定が

¹ 奈良先端科学技術大学院大学
Nara Institute Science and Technology

² 日本学術振興会特別研究員 DC
JSPS Research Fellow DC

可能なことが分かった。

2. 関連研究

2.1 節で述べるように、負担度は心拍数と強い関連性があり、また心拍数は運動強度によって変動することが分かっている。したがって本研究では、歩行中の運動強度と心拍数を関連付けることで、歩行中に感じる負担度を推定する。そのためには、歩行ルートに対する個々人の運動強度の推定および運動強度の変化の推定が必要である。

2.1 身体的負担度に関する知見

個人の身体的負担度の測定には、Borg が定義した RPE (主観的運動強度) [6] がよく用いられ、これは表 1 に示す 15 段階のボルグ・スケール [14] 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、スケールの数字は心拍数の 1/10 に対応している [7]。よって、これは主観的な運動強度を数値化する際に有効であり、心拍数と負担度の関連付けが可能となる。

表 1 ボルグ・スケール

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		

2.2 運動強度推定に関する研究

Oscar ら [2], Tapia ら [3] は、加速度センサと心拍計を併用し、「ウォーキング」や「ジョギング」などといった活動種別の推定 [2][3] およびその運動強度の推定 [3] を行っている。心拍数を特徴量とすることで推定精度が向上していることから、運動強度の推定には心拍数の利用が有用であると考えられる。

最近では SUUNTO 社の t6d[8] や POLAR 社の RS100[9] のような腕時計型のワイヤレス心拍計を用いることで、手軽に運動中の心拍数を測定できる。しかしこのような心拍計は、トランスミッター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、煩わしい。加えて、デバイスコストが高いという問題もある。上記で挙げた既存研究は、複数の特殊デバイスの装着が必要であることから、手間やコストの問題が発生すると考えられる。

2.3 心拍数予測に関する研究

Feng ら [4] は、ニューラルネットワークを用いた心拍数予測モデルを提案している。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。これよりニューラルネットワークは運動強度と心拍数の関連付けの手段として利用で

きると考えられるが、Feng らは心拍数変動が少ない日常生活を対象としているため、ここで考案されているモデルは、本研究に必要な運動中の心拍数予測には使用できない。

2.4 既存のナビゲーションシステム

既存のナビゲーションシステムとして、ソニーの徒歩ナビゲーション NAV-U[10] や、NAVITIME 社の自転車用ルート検索サービス [11] が提供されている。これらのシステムでは、比較的負担の少ないルートを検索できるが、道の勾配を基準としており、個人の身体能力を考慮したルートを検索することはできない。そのため、坂道が少ないルートを選択した場合でも、人によっては負担を感じる事が考えられ、身体に無理な負担がかかる可能性がある。

2.5 本研究の位置付け

既存研究では、運動強度の推定や心拍数の予測が行われているが、運動中の負担度推定を目的とした研究は存在しない。更に 2.2 節で示した Tapia ら [3] の研究では、数分間の運動を対象とした運動強度推定を行っているため、運動強度の変化は考慮されておらず、歩行ルートと運動強度の関連付けも行われていない。また、既存のナビゲーションシステムにおいても、個人の身体能力を考慮したルートを検索できるシステムは存在しない。

これより本研究では、スマートフォン搭載センサのみを用いた負担度推定手法を提案し、個々人の運動強度の推定および運動強度の変化の推定を行う。そしてこの手法に基づき、ユーザにとって負担が最小となる歩行ルートを推薦するナビゲーションシステムを提案する。

3. 負担度を考慮した歩行ナビゲーション

3.1 目的

本研究で提案する負担度を考慮したナビゲーションシステム (以下、楽 WALK) 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ことを目的とする。そのため提案システムでは、歩行ルート検索時に、負担の少ない推薦歩行ルートとそのルートに対する負担度を提示する。またウォーキング中には、システムによって負担が高いと判断された場合のみ警告を表示し、ユーザに歩行速度の調整を行ってもらう。これにより、ユーザが推薦歩行ルート以外のルートを歩行する際にも、提案システムを利用することができる。

3.2 要件と基本方針

楽 WALK には、ユーザに提示する負担度の信頼性が必要となる。信頼性を向上させるためには、様々な歩行ルートに対する負担度や歩行データなどの大量なデータが必要であり、特殊デバイスを使用しない低コストかつ手軽なデータ収集法が求められる。更に、勾配のみを考慮した負担度ではなく、年齢や性別、運動習慣など個人の身体条件に適した負担度を提示することが望ましい。また、ウォーキング




図 1 楽 WALK の概要

中に警告を表示するためには、負担度の変化を推定する必要がある。歩行中の負担度は、歩行速度や勾配、運動強度とその継続時間によって変化すると考えられ、例えば、負担度が高くなるような急な上り坂を歩いたとしても、その後平坦な道をしばらく歩けば、負担度は徐々に低くなっていく。このような連続的な負担度の変化まで推定するためには、瞬間的な歩行速度や勾配の変化に加えて、運動の継続時間も考慮した負担度の推定を行う必要がある。

以上のことから、提案システムを実現するには、下記の要件を満たす必要がある。

- (1) 普及デバイスによる負担度の測定
- (2) ウォーキング中の負担度変化の推定
- (3) 様々なルートにおける歩行データの効率良い収集
- (4) 年齢、性別、身体能力などの個人差の考慮

これらの要件を満たすための基本方針について述べる。要件 (1) については、近年普及している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伴う手間やコストなどの負担を軽減する。要件 (2) については、歩行データ (加速度、歩行速度、勾配、位置などの時系列データ、詳細は後述) から負担度と関連性の強い心拍数を予測する負担度モデルを作成する。これは後述するように、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作成する。更に、歩行速度や勾配の情報を基に算出する酸素摂取量を入力に加え、運動強度の変化と運動の継続時間を考慮する。要件 (3) については、ユーザ参加型センシング (Participatory Sensing) [12] によるデータ収集を行う。ここでは、スマートフォン用のデータ収集アプリをユーザに配布し、広範囲における歩行データを効率良く収集する。収集データをサーバ上のデータベースで共有することで、ユーザが初めて歩行するルートに対しても負担度の推定が可能となる。またデータが増えるにつれ、システムが提示する負担度の信頼性が向上すると考えられる。要件 (4) については、「20 代男性、運動習慣有り」、「30 代女性、運動習慣無し」というように、年齢や性別などの属性によりカテゴリを作成する。同一カテゴリに属するユーザは同程度の負担を感じるという前提の下、カテゴリ毎に歩行データの収集や負担度モデルの作成を行うことで、負担度に関する個人差を考慮する。

3.3 提案システムの設計

以上の節で述べた目的および要件をふまえ、楽 WALK の概要について述べる。本システムは、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 1 に、楽 WALK の概要図を示す。本システムは、クラウド上に置かれている共有データベースおよびサーバ、そしてユーザが装着するスマートフォンから構成される。

共有データベースには、加速度センサおよび GPS センサにより測定するユーザの歩行データが蓄積される。ここで歩行データとは、加速度の振幅および周波数、歩行速度、勾配、位置情報を指す。加えて、共有データベースには、推定した心拍数および負担度も蓄積する。年齢や性別などの属性により分類されるカテゴリごとにデータを蓄積することで、様々なユーザに対する歩行データを共有する。

本システムの歩行ナビゲーションは、スマートフォン内のアプリケーションを介して行う。まずユーザは、希望する運動時間および消費カロリー、プロフィールの入力、加えて、マップ上で出発地点および到着地点の選択を行う (図 1 (1))。そして入力されたプロフィールからユーザが属するカテゴリを決定し、共有データベースに蓄積されている該当カテゴリのデータを基に、推薦歩行ルートの決定、更に、図 2 に示すように、スマートフォンの画面にルートと負担度の表示を行う (図 1 (2) ~ (5))。推薦歩行ルートの決定方法については、3.4 節で述べる。

ユーザのウォーキング開始後、スマートフォンにより取得された歩行データは、定期的にクラウド上にアップロードされる (図 1 (2))。サーバ上では、負担度モデルにこのデータを与えることで心拍数および負担度の推定を行い、ユーザに無理な負担がないかどうかを確認する (図 1 (3))。ユーザの歩行速度が適切でない場合には、「もう少しゆっくり歩いてください」や「やや早めに歩いてください」などの歩行速度に関するアドバイスを提示する (図 1 (3) ~ (5))。ウォーキング中または終了時に、ユーザの主観的な負担度もしくは心拍数データ (心拍計を装着していた場合のみ) をアップロードしても良い。このデータは、ユーザの歩行データと共に共有データベースに蓄積される。ユー



図 2 歩行ルート推薦画面の例

表 2 心拍数と負担度評価の関係

レベル	主観的評価	心拍数 (bpm)
1	負担を感じない	60~99
2	やや負担を感じる	100~119
3	負担は感じるが、運動の継続は可能	120~139
4	歩行速度（運動強度）の低下が必要	140~169
5	休憩が必要	170~200

ザビリティを保つという観点から、主観的負担度の評価もしくは心拍数データの提供は必須ではなく、各ユーザーの意志に委ねる。

3.4 推薦歩行ルート決定方法

以下に示す推薦歩行ルート決定アルゴリズムを用いて、ユーザーが希望する運動時間および消費カロリーを満たし、かつ、ユーザーにとって負担が最小の歩行ルートを推薦する。

手順 1：カテゴリ決定 ユーザーが入力したプロフィール情報により、ユーザーのカテゴリを決定する。

手順 2：候補ルートの選択 ユーザーがマップ上で選択した出発地点および到着地点の情報を基に、一定距離（2m/秒×運動時間など）以内の候補となる歩行ルートを全て見つけ出し、これらを候補ルート群とする。

手順 3：歩行速度の算出 候補ルート群に属する各ルートに対し、歩行速度の算出を行う。ここでは、各ルートの距離をユーザーの希望する運動時間で除算することで歩行速度を求める。ただしユーザーが一定速度で歩行するとは限らないため、ルートの勾配を考慮し、勾配に応じて時間を傾斜配分する。勾配は与えられているものとする。

手順 4：消費カロリーの計算 手順 3 で計算した歩行速度および勾配を基に、ACSM (American College of Sports Medicine) により定義された下記の算出式 [13] を用いて、各ルートに対する消費カロリーを求める。

$$C = VO_2 * 5.01$$

$$VO_2 = R + H + V$$

$$R = 3.5$$

$$H = 0.1 * speed$$

$$V = 1.8 * speed * grade$$

ここで、 C [kcal] は消費カロリーを表し、これは酸素摂取量 VO_2 [ml/Kg/min] から算出できる。 VO_2 は、安静時の酸素摂取量 R 、歩行速度に基づく水平方向の酸素摂取量 H 、勾配の増加に伴い必要となる垂直方向の酸素摂取量 V から求められる。また、 $speed$ [m/min]、 $grade$ [%] はそれぞれ、手順 3 で求めた歩行速度、勾配を表す。

手順 5：心拍数および負担度の推定 各ルートに対し、4章で述べる手法を使用して、歩行時の心拍数および負担度を推定する。ここでは、共有データベース内の該当カテゴリにおいて、同一ルートの歩行データを基に心拍数推定を行い、負担度とその時間変化について推定する。そして、表 2 のように負担度を設定し、レベル 4（歩行速度（運動強度）の低下が必要）および 5（休憩が必要）の状態になる場合には、歩行速度を調整した上で、再度、負担度の推定を行う。なお、表 2 は、表 1 のボルグ・スケール [14] および ACSM が定めた運動強度分類表 [13] を基に作成する。ACSM より中程度の運動が薦められている [13] ことから、ここでは表 2 のレベル 4 以上を危険レベルとする。

手順 6：推薦歩行ルートの決定 候補ルート群に属するルートの中から、下記条件を満たすものを推薦歩行ルートとする。推薦ルートが複数ある場合は、ランダムに最大 3

つのルートを選び、表示する。

- (1) 手順 4 で求めた消費カロリーが、ユーザーの希望する消費カロリー以上である
- (2) 手順 5 で推定した負担度について、表 2 の 4（歩行速度（運動強度）の低下が必要）および 5（休憩が必要）の状態になる合計時間が最小である

4. スマートフォンによる身体的負担度の推定

提案手法では、スマートフォンから取得する歩行データから心拍数を予測する負担度モデルを作成する。ここでは、2.1 節で述べたボルグ・スケールに着目し、心拍数から負担度を定量的に評価できるという仮定の下、歩行データを基に心拍数予測を行う。そして、予測した心拍数を表 2 にあてはめることで、負担度を推定する。

加速度の振幅と心拍数の間には、変化の仕方に非線形的な関係が見られる [4]。したがって本研究では、入力である歩行データと心拍数の非線形な対応関係を再現するニューラルネットワークを用い、心拍数の予測を行う。負担度モデルの作成は、(a) スマートフォンによる歩行データの取得、ニューラルネットワークに与える入力に関する処理を行うための (b) 特徴量の抽出、(c) 学習データによるモデルの作成、という 3 つのフェーズに分けられる。以下の節で (a) ~ (c) について述べる。

4.1 (a) スマートフォンによる歩行データの収集

心拍数の予測には、(i) 加速度の振幅および周波数、(ii) 歩行速度、(iii) 勾配、(iv) 酸素摂取量を入力パラメータとして使用する。

トレッドミルを用いて歩行中の加速度を測定した実験では、歩行速度や勾配によって加速度の振幅、周波数に違いが見られた。また 3.4 節で示したカロリー消費量の算出式より、心拍数の増減と相関が高い酸素摂取量が歩行速度および勾配から算出できることが分かる。これより、心拍数の変化に関連のあるデータとして、上記 (i) ~ (iv) の入力パラメータを考える。

本研究では、これらの入力パラメータ（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 センサを用いて、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、加速度データから加速度の振幅および周波数、歩行速度を、位置情報から勾配を取得することができ、更には、歩行速度および勾配から酸素摂取量が算出できる。

4.2 (b) 特徴量の抽出

収集した加速度データおよび位置情報から、加速度の振幅および周波数、歩行速度、勾配を算出する。更に、歩行速度および勾配から算出した酸素摂取量を入力として与え、運動強度とその継続時間を考慮した負担度の推定を行う。

4.2.1 加速度の振幅および周波数の抽出

ここでは、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する。予備実験の結果を基に、前処理として周波数0Hzの直流成分を除去した各データを、ハーフ・オーバーラップ方式で一定時間のウィンドウに区切り、ウィンドウごとに平均振幅およびパワースペクトルにおいてエネルギーが最大となる周波数（以下、周波数ピーク）を抽出する。ウィンドウサイズは、使用センサのサンプリング時間の都合上600点の倍数にする必要があるため、ここでは経験的に1200点に設定した、

4.2.2 歩行速度の算出

歩行速度は、加速度データを用いた歩数推定を利用し、歩数推定により得られた歩数およびユーザの歩幅から移動距離を求めることで算出する。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[15]を使用する。

歩行速度の算出には、次に示す式を用いる。

$$Speed = (Dist/Time) * 3.6 \quad (1)$$

$$Dist = Step * Stride_length \quad (2)$$

$$Stride_length = Height - 1 \quad (3)$$

ここで、 $Speed[km/h]$ は歩行速度、 $Dist[m]$ は移動時間 $Time[s]$ における移動距離を表す。また、移動距離 $Dist[m]$ は、式(2)に示すように移動時間 $Time[s]$ における歩数 $Step[歩]$ と歩幅 $Stride_length[m/歩]$ から算出する。歩幅はユーザの身長 $Height[m]$ を基に、式(3)より算出する。

歩数推定は、Yingらが提案した推定アルゴリズム[16]を参考にする。このアルゴリズムでは、波形の絶対値が閾値未満になるタイミング（以下、クロスポイント）を検出することで歩数推定を行う。Yingらは閾値を0と設定しているが、これでは停止時の検出が難しいため、本研究では、経験的に加速度の分散を3倍したものを閾値とする。

図3に、加速度データから検出したクロスポイントを赤丸で示す。閾値を通過するポイントを検出しているため、クロスポイント数の $\frac{1}{4}$ が歩数であると考えられる。また、図3に示した波形は、Yingらの提案アルゴリズムに従い、Z軸の加速度データに対し、平滑化フィルタおよび導関数を求めるための微分関数を適応したものである。

4.2.3 勾配の算出

道の勾配は、次に示す式により算出する。

$$Degree = 100 * AltDiff / Dist$$

ここで、 $Degree[\%]$ は勾配、 $Dist[m]$ は移動距離を表す。これは、4.2.2節で述べた式(1)により算出した値を使用す




図3 クロスポイントの検出

る。また $AltDiff[m]$ は、3秒おきにGPSで取得する2点間の標高差を表す。これは、Google Maps API version3によって取得する。

4.2.4 酸素摂取量の算出

酸素摂取量は心拍数と高い相関関係があり、これら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。また歩行状態から安静状態になる場合も同様に、瞬間的に変化するのではなく、徐々に減少する[17]。

一定強度の運動を行った場合、酸素摂取量の増加量 $U[ml/kg/min]$ および減少量 $D[ml/kg/min]$ 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（以下、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 T 、時刻 $t[s]$ を用いて次式のように表される[17]。

$$U = Ke^{-\frac{T}{t}} \quad (4)$$

$$D = K(1 - e^{-\frac{T}{t}}) \quad (5)$$

本研究では、3.4節の手順4で示したACSMの消費カロリー算出式を用いて、一定時間 $P[s]$ における平均歩行速度および平均勾配から酸素摂取量 $V_{now}[ml/kg/min]$ を算出する。 V_{now} が P 秒前の値 $V_{pre}[ml/kg/min]$ と比較して増加した場合には、 $K = V_{now}$ として上記の式(4)を用いて増加量を計算する。逆に V_{pre} と比較して減少した場合には、 $K = V_{now}$ として上記の式(5)を用いて減少量を計算する。 $V_{now} = V_{pre}$ の場合には運動強度に変化がないものと考え、 P 秒前の状態が増加傾向であれば $K = V_{now}$ として上記の式(4)を、減少傾向であれば $K = V_{now}$ として上記の式(5)を用いて変化量を計算する。パラメータ値は、経験的に、 $T = 53$ 、 $P = 24$ とする。

4.3 (c) 学習データによるモデルの作成

負担度モデルの作成には、データマイニングツールWEKA3[18]を使用する。このツールでは、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、予め、入出力の関係を学習させることで負担度モデルを作成する。作成したモデルに対し、ある時刻 t_0 から現在時刻 t_n 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、これより算出された時刻 t_0 から時刻 t_n までの心拍数が出力値（予測値）となる。実際に使用したデータについては、次章で述べる。

5. 負担度モデルによる推定精度の評価

5.1 目的と方法

評価の目的は、4章で述べた負担度モデルを用いて予測した心拍数および負担度が、提案システムを利用する場合に十分正確であるか調査することである。

これまでに我々は、トレッドミルを用いて測定したデータを用いて、ニューラルネットワークに与える有用な入力についての検討を行い、酸素摂取量の有効性を確認した [5]。本稿ではこの結果をふまえ、一般道で測定したデータから負担度モデルを作成し、一般道における酸素摂取量の有効性についての評価 (評価 1) および負担度の推定精度の評価 (評価 2) を行う。

評価 1 では、酸素摂取量を入力に含む場合と含まない場合の予測結果を比較することで、その有効性について検討する。入力には、各軸の加速度データおよび 3 軸合成の加速度データから抽出する振幅 (AX, AY, AZ, A) および周波数ピーク (FX, FY, FZ, F), 歩行速度 (S), 勾配 (G), 酸素摂取量 (VO) の計 11 種類の特徴量を考える。

評価 2 では、表 2 において心拍数が 20bpm 増加すると負担度が最大で 2 レベル高くなってしまふことから、平均絶対誤差 10bpm を目指し、負担度の誤検出を 1 レベル以下に抑えることを目標とする。また、提案システムの実用の観点から、負担度が低い場合に高いと判定される誤検出 (false positive) よりも負担度が高い場合に低いと判定される誤検出 (false negative) を抑える必要があると考えられる。これより本稿では、false positive の出現率 (FP (%)) および false negative の出現率 (FN (%)) を算出する。

5.2 実験環境

実験では、腕時計型のワイヤレス心拍計 (SUUNTO, t6d) を腕に装着し、腰 (正面, 中央) にスマートフォン (Sony Ericsson, Xperia active) を装着した。スマートフォンは、搭載されている加速度センサが図 4 に示す向きになるよう固定した。またサンプリング間隔は、加速度センサを 20 ミリ秒、心拍計を 2 秒、GPS センサを 3 秒とし、被験者を 1 人 (20 代, 女性) とした。

5.3 負担度モデル作成に使用するデータ

一般道におけるデータ測定では、異なる 5 つの歩行ルート歩いた。図 5 に、各ルートの標高および距離を示す。




図 4 加速度センサの向き

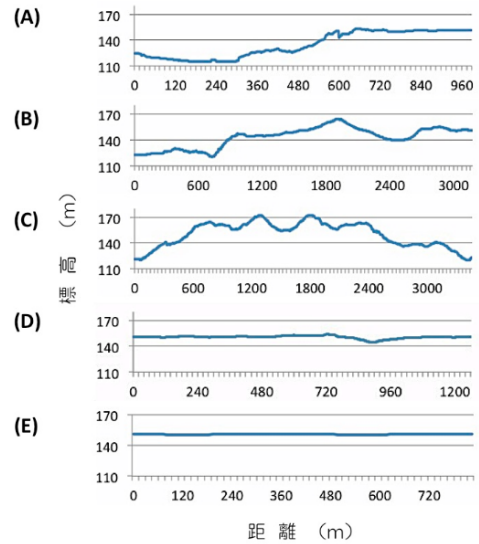


図 5 測定を行った歩行ルートの標高および距離

図 5 にあるように、(A) ~ (C) は高低差の大きい道、(D) および (E) は高低差の小さい道であり、歩行時間は (A), (E) が 20 分、(C), (D) が 40 分、(E) が 7 分である。実験では、5 種類のデータのうち 1 つをテストデータ、残りを学習データとして使用する。

5.4 評価および考察

5.4.1 酸素摂取量の有効性についての検討

5.1 節で挙げた 11 種類の入力項目のうち、入力数が 6 以下となる全組み合わせ (1485 通り) について、負担度モデルを作成し、心拍数予測を行った。テストデータには (A) ~ (E) をそれぞれ使用し、入力ごとに実測値と予測値の相関係数および平均絶対誤差を求めた。

ここで、一般道における酸素摂取量の有用性を評価するために、酸素摂取量を入力に含む場合 (VO あり) と含まない場合 (VO なし) について、最大相関係数、最小平均絶対誤差、入力を、表 3、表 4 にそれぞれ示す。このとき、routeA~routeE は、それぞれ (A) ~ (E) をテストデータとして実験した結果である。

表 3、表 4 から、相関係数が 0.75-0.90 (VO あり), 0.55-0.79 (VO なし), 心拍数の平均絶対誤差が 4.75-11.78bpm (VO あり), 6.83-8.41bpm (VO なし) の推定ができた。これは、目標である誤差 10bpm 以内を概ね満たしている。

テストケースごとに「VO あり」および「VO なし」の結果を比較すると、相関係数は、routeD を除いて「VO あり」の方が相関が高い結果となった。一方、平均絶対誤差は、routeD および routeE では「VO あり」が、残りのテストケースについては「VO なし」が、誤差が少ない結果となった。これより、routeA~routeC では酸素摂取量の有効性が見られたが、routeD~routeE では有効性が認められなかった。

また、入力に着目すると、「VO あり」の routeA~routeC については、歩行速度もしくは勾配を入力に含むことで誤差が小さくなっている。一方、「VO なし」では、振幅および周波数に加えて、routeA~routeC は歩行速度および勾配

表 3 最大相関係数および最小平均絶対誤差 (VO あり)

テストケース	相関係数		平均絶対誤差 (bpm)	
	最大値	入力	最小値	入力
routeA	0.90	AY, VO	4.75	FZ, S, VO
routeB	0.83	F, FX, A, AX, VO	8.78	FZ, A, AX, AY, S, VO
routeC	0.77	FZ, VO	8.45	F, FY, D, VO
routeD	0.44	FX, FZ, D, S, VO	6.49	F, FY, A, AY, D, VO
routeE	0.75	FX, FZ, AY, AZ, VO	11.78	F, FX, FZ, AX, VO

表 4 最大相関係数および最小平均絶対誤差 (VO なし)

テスト	相関係数		平均絶対誤差 (bpm)	
	最大値	入力	最小値	入力
routeA	0.79	FX, FY, AY, D, S	6.83	F, FX, FY, AX, D, S
routeB	0.75	FX, A, D, S	8.41	FY, FZ, AX, AZ, D, S
routeC	0.60	F, FY, AZ, D	8.93	FX, FY, FZ, D, S
routeD	0.55	FZ, AX, AZ, S	3.02	F, FZ, AZ, S
routeE	0.55	FX, A, AX, S	9.40	FX, FY, FZ, A, AZ, D

が、routeD～routeE は歩行速度が有効に働くことが分かる。

上記のように、テストケースによって酸素摂取量の有効性に違いが現れたのは、歩行ルートの高低差の違いが原因であると考えられる。routeA～routeC のように高低差が大きい場合は、勾配や歩行速度の変化に伴い心拍数が大きく変動し、その特徴を勾配および歩行速度から算出する酸素摂取量によって再現できるため、その有効性が現れた。しかし、routeD～routeE のように高低差が小さい場合は、勾配の変化が少ないために酸素摂取量による推定効果が低い。

また、入力に関しては、routeA～routeC では歩行速度および勾配が、routeD～routeE では歩行速度が有用であることから、歩行速度や勾配が心拍数変化に大きく影響することが分かる。

正確な推定には歩行速度および勾配が重要であるが、現時点では、高低差が小さい所における勾配 (ならびに酸素摂取量) の誤差が大きい。また、デッドレコニングによる歩行速度推定には誤差が含まれる。精度を上げるには、勾配および歩行速度の正確な計測法、または、入力を歩行ルートによって変える (例えば、勾配を削除) 方法が必要である。

5.4.2 評価 2 : 心拍数および負担度の推定精度

評価 1 では、歩行ルートの高低差やテストケースによって有用な入力が変わることが分かった。しかし、楽 WALK における心拍数予測においては、予測に使用する入力を予め決定しておく必要がある。そこで評価 2 では、高低差の大きい場合と小さい場合それぞれについて最適な入力を決定し、負担度の推定精度を評価する。

まず、高低差の大きい場合 (routeA～routeC)、小さい場合 (routeD～routeE) に分け、それぞれに対し最適な入力の決定を行った。前者の場合については、routeA, routeB, routeC のそれぞれに対し、評価 1 で示した 1485 通りの入力ごとに平均絶対誤差を求めて平均をとり、平均値が最小となる入力パラメタの組合せを最適な入力とした。後者の場合についても、同様に最適な入力を求めた。その結果、最適な入力は、高低差の大きい場合は、周波数 (F, FY)、

表 5 心拍数の予測結果および負担度の推定率

(routeA～routeC の入力：周波数, 歩行速度, 勾配, 酸素摂取量
routeD～routeE の入力：周波数, 振幅, 歩行速度)

テストケース	相関係数	平均絶対誤差 (bpm)	NE(%)	FP(%)	FN(%)
routeA	0.81	7.23	66.65	27.17	6.18
routeB	0.69	10.31	45.68	54.32	0.00
routeC	0.68	8.83	51.17	30.99	17.84
routeD	0.38	4.55	88.42	5.26	6.32
routeE	0.20	9.91	75.76	0.00	24.24

歩行速度 (S)、勾配 (D)、酸素摂取量 (VO)、高低差の小さい場合は周波数 (FX, FY, FZ)、振幅 (AZ)、歩行速度 (S) となった。

ここで、前者の入力を routeA～routeC に適応した場合、後者の入力を routeD～routeE に適応した場合の心拍数の予測結果と負担度の推定率を表 5 に示す。負担度の推定率は、表 2 に示す負担度を用いて、負担度を正しく推定した割合 (NE)、実際よりも負担度を高く推定した割合 (FP)、低く推定した割合 (FN) をそれぞれ計算した。表 5 より、全てのテストケースで心拍数の目標誤差を概ね満たすことができた。また、高低差の小さい場合に特に高い正答率が得られ、全体的に FN の発生率が小さい結果となった。

更に、高低差が大きい場合の推定例として、routeA の心拍数の予測結果および負担度の分類表を表 6 および図 6 に、高低差が小さい場合の推定例として、routeD の心拍数の予測結果および負担度の分類表をそれぞれ表 7 および図 7 に示す。

分類表は、行方向を実測値の負担度、列方向を予測値の負担度とする。そして表の各欄の値は、対応する負担度 (実測レベル, 予測レベル) に分類された数の全体に対する割合を表わし、表の全ての欄の値を合計すると 100%となる。テストデータのサンプル数は routeA が 81 個、routeD が 95 個 (12 秒おきのサンプル)、更に、routeA は負担度のレベル 3 以上、routeD はレベル 5 に該当するデータは含まない。また、分類表において、NE は対角成分の和、FP は上三角成分の和、FN は下三角成分の和として計算する。

表 5 および表 6 より、routeA では、負担度の誤推定は最大 2 レベル、正答率 67%、負担度 1 レベル以内での正答率は 98.76%という結果が得られた。これより、歩行中に負担が変化する場合でも、ある程度正しく負担度を推定できることが分かる。また、この場合の FN の発生率は、6.18%であった。

表 5 および表 7 より、routeD では、負担度の誤推定を 1 レベル以内に抑えることができ、推定正答率およそ 88%という結果を得ることができた。更に、FN の割合も 6.32%と少なく、歩行ナビゲーションに十分利用できる精度が得られたと言える。

6. まとめ

本稿では、スマートフォン搭載センサのみを用いた負担

表 6 負担度分類表 (高低差が大きい場合)

		予 測 レ ベ ル				
		1	2	3	4	5
実	1	7.40	2.47	1.24	0.00	0.00
測	2	1.24	40.74	8.64	0.00	0.00
レ	3	0.00	4.94	17.28	14.82	0.00
ベ	4	0.00	0.00	0.00	1.23	0.00
ル	5	0.00	0.00	0.00	0.00	0.00

表 7 負担度分類表 (高低差が小さい場合)

		予 測 レ ベ ル				
		1	2	3	4	5
実	1	2.10	4.21	0.00	0.00	0.00
測	2	6.32	86.32	1.05	0.00	0.00
レ	3	0.00	0.00	0.00	0.00	0.00
ベ	4	0.00	0.00	0.00	0.00	0.00
ル	5	0.00	0.00	0.00	0.00	0.00




図 6 高低差が大きい場合の結果
(入力: 周波数, 歩行速度, 勾配, 酸素摂取量)




図 7 高低差が小さい場合の結果 (入力: 周波数, 振幅, 歩行速度)

度推定手法と, その手法に基づいた, 個人の身体能力に応じた歩行ルートを紹介する楽 WALK について述べた. 負担度モデルの評価実験では, 歩行ルート的高低差によって有用な入力が変わることが分かり, 学習により得られた入力パラメタの組合せにより, 歩行ルートに関わりなく 11bpm 以下の平均絶対誤差で心拍数の推定が可能となった.

今後は, 歩行速度および勾配の算出における誤差を改善すると共に, ルート的高低差に応じた最適な入力についても更に検討を進めたい. また, 今回は被験者 1 人のデータを使用したが, 複数の被験者から収集したデータを使用した実験にも取り組みたい.

参考文献

[1] 運動所要量・運動指針の策定検討会: 健康づくりのための運動指針 2006~生活習慣病予防のために~, エクササイズガ

イド 2006: 厚生労働省, <http://www.mhlw.go.jp/bunya/kenkou/undou01/pdf/data.pdf>: (参照 2012-7-10).

[2] Lara, Ö. D., Pérez, A. J., Labrador, M. A. and Posada, J. D.: Centinela: A human activity recognition system based on acceleration and vital sign data, *Journal on Pervasive and Mobile Computing* (2011).

[3] Tapia, E. M., Intille, S. S., Haskell, H. 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. of 11th International Symposium on Wearable Computers (ISWC2007)*, pp. 37-40 (2007).

[4] Xiao, F., Chen, Y., Yuchi, M., Ding, M. and Jo, J.: Heart Rate Prediction Model Based on Physical Activities Using Evolutionary Neural Network, *Fourth International Conference on Genetic and Evolutionary Computing*, pp. 198-201 (2010).

[5] 隅田麻由, 今津真也, 水本旭洋, 安本慶一: 健康指向歩行ナビゲーションのためのスマートフォンによる身体的負担度の推定, 情報処理学会研究報告, Vol. 2012-MBL-62, No. 27, pp. 1-8 (2012).

[6] Borg, G.: Psychophysical scaling with applications in physical work and the perception of exertion, *Scandinavian Journal of Work Environment Health*, Vol. 16 (SUPPL 1), pp. 55-58 (1990).

[7] Borg, G.: Psychophysical scaling with applications in physical work and the perception of exertion, *Med. Sci. Sports Exerc*, Vol. 5, No. 2, pp. 90-93 (1973).

[8] SUUNTO, : スポーツコンピューター TRAINING t6d, <http://www.suunto-japan.jp/products/list/sportscomputer/training/t6d>: (参照 2011-08-22).

[9] POLAR, : ハートレートモニター RS100, http://www.polar.co.jp/ja/products/get_active/running/multisport/RS100/: (参照 2011-08-22).

[10] SONY, : ポータブルナビゲーション NAV-U, <http://www.sony.jp/nav-u/contents/>: (参照 2011-11-29).

[11] NAVITIME, : 自転車ルート検索, <http://www.navitime.co.jp/bicycle/>: (参照 2011-06-12).

[12] Goldman, J., Shilton, K., Burke, J., Estrin, D., Hansen, M., Ramanathan, N., Reddy, S., Samanta, V. and Srivastava, M.: Participatory Sensing: A citizen-powered approach to illuminating the patterns that shape our world, *Foresight & Governance Project, White Paper* (2009).

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

[14] 小野寺孝一, 宮下充正: 全身持久性運動における主観的強度と客観的強度の対応性: Rating of perceived exertion の観点から, 体育学研究, Vol. 21, No. 4, pp. 191-203 (1976).

[15] Montemerli, M., Becker, J., Bhat, S., Dahlkamp, H., Dologov, D., Ettinger, S. and Haehnel, D.: Junior: the stanford entry in the urban challenge, *J Field Robot* 25(9):569-597 C (2008).

[16] Ying, H., Silex, C., Schnitzer, A. and S. Leonhardt, M. S.: Automatic Step Detection in the Accelerometer Signal, *4th International Workshop on Wearable and Implantable Body Sensor Networks, Springer Berlin Heidelberg* (2007).

[17] 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, No. 183-7 (1999).

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