

ストレス予測による経路推薦に向けた歩行環境および生体信号の群衆データ分析

北林 宏樹[†] 大西 恒彰[†] 張 信鵬[†] 浅野 泰仁^{††} 吉川 正俊^{††}

[†] 京都大学情報学研究科 〒606-8501 京都府京都市左京区吉田本町

^{††} 京都大学情報学研究科 〒606-8501 京都府京都市左京区吉田本町

E-mail: †{kitabayashi,onishi,xinpeng,zhang}@db.soc.i.kyoto-u.ac.jp, ††{asano,yoshikawa}@i.kyoto-u.ac.jp

あらまし 近年、人々の健康に対する意識が高まってきている。健康を促進するための代表的な運動として歩行がある。しかし、高齢者や歩行が困難な障害者の中では積極的に外出しようとする人は必ずしも多くない。本研究は、高齢者等が歩行する機会の不足によって健康を損なわないために、歩行での外出を促進することを目的としている。そのためには、各歩行者が歩行時に感じるストレスを削減することが有効であると考え、本稿では、各歩行者の歩行環境や生体情報によるストレス予測を利用した経路推薦の実現を将来的な目標とし、その第一段階としてストレス予測に関する研究を行った。ストレス予測においては、過去に記録された個人の歩行環境・生体信号データと個人以外の群衆から集めた歩行環境・生体信号データを分析するという手法を提案する。歩行環境データとは路面状況や勾配、道の狭さなどであり、生体信号データとは心拍数・心拍変動である。本稿では歩行者が感じるストレスをなるべく小さくする経路推薦に向けて、歩行環境および生体信号データを記録・分析し、ストレスを予測した予備実験について述べる。

キーワード ビッグデータ, データマイニング, 生体信号

1. はじめに

近年、人々の健康に対する意識の高まりに伴い、ヘルスケアに関する研究が盛んに行われている。健康を維持増進するためには、運動が有効である。時間を選ばず、かつ誰でも手軽にできて特別な器具を用いなくても良い運動として、歩行がある。歩行は定期的に行えば健康維持・増進に有効であるが、歩行環境によっては、特に高齢者や障害者など体の弱い人にとっては身体的負担やストレスの原因になってしまう可能性がある。例えば、健常者には困難とは感じられない道の勾配であっても負担になる場合もあり、また狭い道や混雑した道では健常者が感じる以上に歩きにくさを感じる可能性もある。また、一人で外出するのが精神的に億劫と感じる場合もあるだろう。したがって各歩行者が外出するときに、身体的負担及びストレスを適切に抑えた経路を推薦することは、高齢者や障害者の歩行促進ひいては健康維持に役立つと考えられる。歩行環境にも混雑状況などのように地図や標高等の情報だけでは捉えられないものがあり、またその影響も個人の現在の身体の状態によって変わりうる。そのため、個人の過去の歩行時に記録された生体信号データおよびその歩行環境データと、その個人がこれから歩く道を過去に歩行した群衆の歩行環境・生体信号データから、上記のような経路推薦を行うのが目的となる。身体的負担やストレスの評価には様々な方法があるが、心拍数を用いた方法が簡便である。身体的負担がどの程度かかっているかということは、

心拍数の高さに関連している。心拍数が平均的な値の場合は程よい負担となるが、著しく心拍数が高くなった場合は負担が過度にかかっているとと言える。また、ストレスの程度については、R-R interval(心拍発生の間隔)から呼吸変動であるHF(Hi Frequency)と血圧変動であるLF(Low Frequency)を求めることで得られるHFとLFの比(LF/HF)を、その指標として用いることができる[1]。したがって、心拍数の予測ができれば、身体的負担やストレスを予測することができることになる。Sumidaら[2]は、スマートフォンから取得可能な歩行時の加速度データを用いて歩行者の心拍数を予測し、例えばその値が著しく高かった場合、身体的疲労度が高いと判断して歩行速度を下げた方が良いといったアドバイスを自動で提供するシステムを開発している。Sumidaら[2]の研究では、心拍数の予測モデルとして、加速度と勾配およびそれらから算出される酸素摂取量を入力とし、心拍数を出力とするニューラルネットワークを用いている。また、酸素摂取量の算出には運動習慣の有無などに起因するパラメータを機械学習によって決定している。彼らの実験結果では、予測値と実測値の平均的な誤差は7bpm(beat per minute)程度であったと報告されている。

Sumidaらのモデルで負担の要因となっているのは主に勾配であるが、ストレスの原因としては、このモデルで使われていない、上で述べたような混雑状況など勾配以外の歩行環境によるものが大きいと考えられる。そこで本研究では、歩行時のストレスを低減させる経路の推薦という将来的な目的を達成す

るための第一段階として、歩行環境の影響を考慮したストレスすなわち心拍数の予測に取り組んだ。具体的には、京都市内において歩行環境が異なるいくつかのルートにおいて、歩行者の心拍数・心拍変動からなる生体信号データと、勾配・道の混雑度・歩行者が一人で歩いているか二人で歩いているかなどの歩行環境データを採取し、Sumida らのモデルを追実験することで、勾配以外の歩行環境が心拍数およびストレスにどの程度影響を与えているかを検証した。

2. 関連研究

心拍数を予測するにあたって、始めに Sumida らの先行研究で用いられている既存手法 [2] について説明する。先行研究では、スマートフォンで利用可能な機能のみを使用し、加速度や歩行速度などのデータを取得した後、ニューラルネットワークによる機械学習を基に、心拍数予測モデルを構築している。ニューラルネットワークを図 1 に示す。ニューラルネットワーク

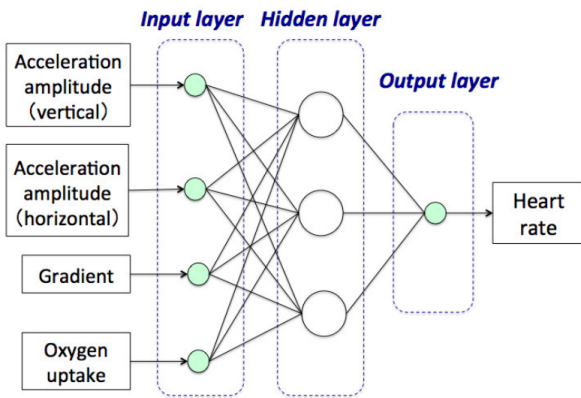


図 1 既存手法で用いるニューラルネットワーク [2]

の入力パラメータは、加速度（垂直方向）・加速度（水平方向）・勾配・酸素摂取量である。

2.1 入力パラメータの取得

入力パラメータとして、加速度・酸素摂取量・勾配を取得する。加速度データは専用のウェアラブルセンサを用いて取得し、加速度の振幅を抽出するために、ハーフオーバーラップ方式 [2] を採用する。ハーフオーバーラップ方式では図 2 に示すようにウィンドウサイズ W の半分ずつ横にウィンドウをずらしながら、ウィンドウごとに平均振幅を算出する。

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 分で定常状態へ近づくと性質を持つ [2]。各運動強度に対応した値とは、運動中に必要とする酸素需要量を意味する。このとき、 t 秒間における酸素摂取量の増加量 ΔU および減少量 ΔD 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需要量 K 、酸素需要量に収束




図 2 ハーフオーバーラップ方式 [2]

するまでの時間を示すパラメータ r_u (増加時), r_d (減少時) を用いて以下のように示すことができる [3,4].

$$\Delta U = Ke^{-r_u/t} \quad (1)$$

$$\Delta D = K(1 - e^{-r_d/t}) \quad (2)$$

酸素需要量がある運動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 は以下の (3)-(6) 式より計算することが可能である [5].

$$K = R + H + V \quad (3)$$

$$R = 3.5 \quad (4)$$

$$H = 0.1 * speed \quad (5)$$

$$V = 1.8 * speed * grade[\%] \quad (6)$$

R は安静時の酸素摂取量, H は歩行速度に基づく酸素摂取量, V は勾配の増加に伴って必要となる酸素摂取量である。 $speed[m/min]$, $grade[\%]$ はそれぞれ、歩行速度、勾配を示す。なお、勾配については、1%は 0.01 を示すものとする。酸素需要量を求めた後は、酸素需要量の変化傾向について調べる。算出の時間間隔を t とし、 i 番目ウィンドウの酸素需要量を K_i 、酸素摂取量を VO_i とする。 i 番目のウィンドウの K_i と 1 つ前のウィンドウの VO_{i-1} を比較し、「増加」・「減少」・「変化なし」のいずれであるか判断する。それぞれの変化傾向に応じ、以下の様に酸素摂取量を求める。

(i) $K_i > VO_{i-1}$ 「増加」の場合

$$\Delta U_i = Ke^{-r_u/t} \quad (7)$$

$$VO_i = VO_{i-1} + \Delta U_i \quad (8)$$

(ii) $K_i < VO_{i-1}$ 「減少」の場合

$$\Delta D_i = K(1 - e^{-r_d/t}) \quad (9)$$

$$VO_i = VO_{i-1} - \Delta D_i \quad (10)$$

(iii) $K_i = VO_{i-1}$ 「変化なし」の場合
・ t 秒前の変化傾向が増加の場合

$$\Delta U_i = K(e^{-r_u/2t} - e^{-r_u/t}) \quad (11)$$

$$VO_i = VO_{i-1} + \Delta U_i \quad (12)$$

・ t 秒前の変化傾向が減少の場合

$$\Delta D_i = K\{(1 - e^{-ra/2t}) - (1 - e^{-ra/t})\} \quad (13)$$

$$VO_i = VO_{i-1} - \Delta D_i \quad (14)$$

また、勾配については (15) 式より求める。

$$grade_k = AD_k / D_k \quad (15)$$

$grade_k$ は k 番目のウィンドウの勾配 [%], AD_k は k 番目のウィンドウの標高差 [m], D_k は k 番目のウィンドウの移動距離 [m] を示す。

2.2 マイニング手法

心拍数予測モデルの学習アルゴリズムとして、ニューラルネットワークを用いる。ニューラルネットワークを用いるのは、入力パラメータとなるデータと心拍数の間には変化の仕方に非線形的な関係がある [2] ためである。

モデルの構築にあたって、マイニングツールの WEKA3.6[6] を使用する。構築したモデルに対して、ある時刻 t_0 から時刻 t_n における加速度や勾配などの時系列データを入力し、出力された値が時刻 t_0 から時刻 t_n の予測心拍数となる。また、学習に使用する心拍数データは、ハーフオーバーラップ形式によってウィンドウサイズ W に分割されたウィンドウごとに平均値を算出した時系列データとする。

2.3 個人差を考慮した心拍数の予測

平均心拍数は、個人によって異なる。例として、年齢・運動習慣の違いによって、平均心拍数はそれぞれである。平均心拍数が個々人の身体によって変化するため、そのまま他者の心拍数と比較することができない、そのため、本稿では、他者の心拍数と比較するため、心拍数の正規化を行う。心拍数を正規化するための式を以下に示す。

$$HR_{ai} = HR_{bi} - HR_{start} \quad (16)$$

$HR_{ai}(i = 1, 2, 3)$ が正規化後の心拍数、 $HR_{bi}(i = 1, 2, 3)$ が正規化前の心拍数、 HR_{start} が個々人の記録開始時の心拍数である。

また、得られた予測心拍数を個々人の本来の心拍数に変換する必要がある。 $PHR_{ai}(i = 1, 2, 3)$ を変換前の予測心拍数、 $PHR_{bi}(i = 1, 2, 3)$ を変換後の予測心拍数とし、以下の式で変換する。

$$PHR_{bi} = PHR_{ai} + HR_{start} \quad (17)$$

また、心拍数の個人差が生じる大きな要因として運動習慣が挙げられる。本稿では、同じ程度の運動習慣の人は、同じような心拍数変化を示すと仮定し、いくつかのカテゴリ化を行う。

3. ストレス指標

本稿では、心拍数に加えてストレス指標も予測する。ストレス指標の予測には R-R interval を用いる [1]。R-Rinterval は心拍数より求めることが可能である。呼吸変動に対応する高周波成分 HF(High Frequency) と、血圧変動に対応する低周波成分 LF(Low Frequency) を R-R interval から求め、ストレス指標 (LF/HF) を出力する。

4. 実験

図 1 に示した Sumida らのニューラルネットワークの入力パラメータとなるデータを実際に歩行者から取得し、取得したデータから心拍数を予測する実験を行った。

4.1 実験環境

被験者は 4 名である。男性が 4 名、年齢は全員 20 代である。歩行ルートは 4 種類あり、それぞれ、吉田山の坂道・今出川通・鴨川沿いの道・京都大学桂キャンパスの坂道である。勾配が大きく変化するのが吉田山の坂道、人が混雑しているのが今出川通、人が少なく歩きやすい道が鴨川沿いの道、勾配がゆるやかに変化するのが桂キャンパスの坂道である。それぞれのルートの距離と標高を示した図を図 3-6 に示す。




図 3 吉田山の坂道の距離と標高




図 4 今出川通の距離と標高




図5 鴨川沿いの道の距離と標高




図6 桂キャンパスの坂道の距離と標高

また、心拍数の個人差を考慮するため、以下の様にカテゴリ化した。

カテゴリ 1：現在運動習慣がなく、過去も運動習慣がない

カテゴリ 2：現在運動習慣があり、過去も運動習慣がある


4人中カテゴリ 1 は 1 人、カテゴリ 2 は 3 人となった。

4.2 使用センサ・アプリケーション

心拍数といった生体情報データを取得することが可能なセンサには様々な種類があるが、本稿では歩行時にセンサを使用するという想定のため、ウェアラブルなセンサを使用する。心拍数・速度・位置情報を取得するために、POLAR 社の「RS800CX」[7]を使用する。RS800CX は腕時計型の心拍計であり、腹部に装着するトランスミッター、位置情報を取得する GPS と連携させる。データの加工・処理にあたっては、POLAR 社のアプリケーション「Polar Pro Trainer 5」を使用する。標高データについては、国土院が公開している標高検索サービス [8] を利用して取得した。この標高データは、Google Maps API によって得られる標高データよりも正確なデータである。各データのサンプリング時間については、それぞれ加速度を 1 秒、心拍数を 1 秒、GPS を 1 秒とする。また、分割するウィンドウサイズ W を 24 秒とする。

4.3 予測精度の算出方法


構築した心拍数予測モデルの予測精度は、心拍数の予測値と



(a) 一人の場合

(b) 二人の場合

図7 鴨川沿いの道での被験者 A の心拍数



(a) 一人の場合

(b) 二人の場合

図8 鴨川沿いの道での被験者 B の心拍数

実測値より計算する平均絶対誤差によって算出する。平均絶対誤差 Er を算出するために、Sumida[2] らの手法を用いる。被験者 $human(A, B, C, D)$ 、ルート $route(r_1, r_2, r_3, r_4)$ で実験を行った際のデータをテストデータとすると、平均絶対値誤差は (18) 式より求めることが可能である。 phr は予測心拍数、 rhr は実際の心拍数、 n はウィンドウの数を示す。

$$Er(human, route) = \frac{\sum_{i=0}^{n-1} |phr(\frac{W_i}{2}) - rhr(\frac{W_i}{2})|}{n} \quad (18)$$

4.4 実験結果および考察


実験を行った結果および考察について述べる。

表 1 に被験者 A-D がそれぞれ一人で歩いた場合の実際の心拍数と予測した心拍数の平均絶対誤差 Er を示す。なお、被験者 C と D の桂キャンパスの坂道の心拍数のデータについては、今回の実験では取得していない。安静状態で心拍数が $7 \sim 7$ bpm 程度変化するため、誤差が 7bpm 以内であれば予測した心拍数の値は正確であると言える。

表 1 心拍数の平均絶対誤差 [bpm]


	吉田山	今出川通	鴨川沿いの道	桂キャンパスの坂道
被験者 A	9.77	8.91	6.24	4.89
被験者 B	23.91	11.66	8.67	6.59
被験者 C	10.27	11.82	6.79	
被験者 D	9.46	8.26	16.47	

図 7-10 は、鴨川沿いの道での被験者 A-D の実際の心拍数と予測した心拍数を示したグラフである。赤い実線が実際の心拍数を示し、青い実線が予測した心拍数を示している。被験者 A と被験者 C では、一人で歩いた場合と二人で歩いた場合で、実際の心拍数および予測した心拍数には大きな差は見られない。



(a) 一人の場合 (b) 二人の場合


図 9 鴨川沿いの道での被験者 C の心拍数



(a) 一人の場合 (b) 二人の場合

図 10 鴨川沿いの道での被験者 D の心拍数

しかし、被験者 B と被験者 D では、一人で歩いた場合と二人で歩いた場合で、実際の心拍数および予測した心拍数に差が現れた。よって、個人差はあるが、共に歩く歩行人数によって心拍数は変動すると言える。歩行人数によって心拍数が変化するならば、心拍数を予測する際に歩行人数を考慮しなければならない。提案手法で述べたように、ニューラルネットワークの入力パラメータとして歩行人数を追加することで改善できるのではないかと考える。



(a) 鴨川沿いの道 (b) 今出川通

図 11 被験者 C が一人の場合の心拍数

図 11 は、被験者 C が鴨川沿いの道と今出川通りを一人で歩いた場合の実際の心拍数と予測した心拍数を示したグラフである。今出川通と鴨川沿いの道を比較した場合、勾配は大きく変わらないが、心拍数の予測精度に大きな差が現れた。差が現れた要因として、道の混雑度が挙げられる。鴨川沿いの道はほとんど人通りがなく、かつ道も広いので、道の混雑度は低いと言える。一方、今出川通は道が狭いだけでなく、通学している学生が多く、多くの人に追い抜かれたり、すれ違ったりするため、混雑度は高いと言える。今出川通と鴨川沿いの道の違いから、道の混雑度は心拍数の変動に影響を及ぼすと言える。

図 12 は、吉田山での被験者 D の実際の心拍数と予測した心拍数を示したグラフである。赤い実線が実際の心拍数を示し、青い実線が予測した心拍数を示している。




図 12 吉田山の坂道での被験者 D の心拍数

29 番目のウィンドウから 35 番目のウィンドウまで下り坂を歩行しており、心拍数が本来下がるべき地点で、予測心拍数は上がっている。心拍数が下がるべき状態で予測値の心拍数が上がってしまった要因として、酸素需要量を求めるための式 (6) が関係していると考えられる。式 (6) は上り坂の場合には対応できるが、下り坂には対応することができない [5,9]。吉田山では勾配が 10% を超える下り坂が存在するため、酸素需要量を正しく求めることができず、心拍数の予測精度が低下したと考えられる。


心拍数から求めたストレス指標 LF/HF を図 13 に示す。LF/HF が高いほど、強いストレスを感じている。なお、ストレス指標については、同じ被験者同士では比較することが可能であるが、他の被験者とは比較することができない。

実験結果より、全体的に鴨川沿いの道よりも今出川通を歩行した場合にストレス指標が高くなる傾向が見られた。今出川通の方が歩行者が多く、道が混雑していたため、被験者のストレスが高まったと考えられる。

また、各ルートにおいて一人で歩くよりも二人で歩く方がストレス指標が低くなる傾向が見られた。このように数人の被験者のデータを集めることで歩行者が感じるストレスの傾向を把握できる。さらに大規模な群衆データとなれば、より正確にストレス傾向を把握することができ、歩行者達のストレスを軽減するルート推薦につなげることが可能である。一方、ストレスの感じ方には個人差があるため、個人にとってストレスが少なくなるルートを推定することも必要である。

5. 提案モデル

今回の実験から、心拍数を予測するにあたって、歩行人数と道の混雑度を考慮しなければならないことがわかった。そこで、ニューラルネットワークの入力パラメータとして歩行人数と混雑度を追加した心拍数予測モデルは、心拍数の予測精度の向上に有効であると考えた。歩行人数や混雑度といった歩行環境を考慮した心拍数予測モデルを図 14 に示す。



* 被験者Bの「今出川 (二人)」のデータは収集しなかった
** 被験者Cと被験者Dの「桂 (一人)」「桂 (二人)」のデータは収集しなかった

図 13 吉田山の坂道での被験者 D の心拍数

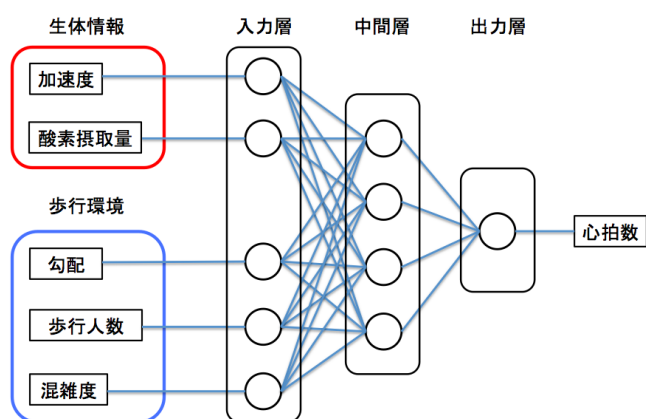


図 14 歩行環境を考慮した心拍数予測モデル

入力パラメータは、(a) 加速度、(b) 酸素摂取量、(c) 勾配、(d) 歩行人数、(e) 混雑度の 5 種類である。歩行人数については、1, 2(人)といった数値を入力をパラメータとする。混雑度の値については、混雑度マップ [10] を用いて求める予定である。混雑度マップを用いることによって、ある特定の領域において、1 時間ごとの領域内に存在している人数を求めることが可能である。

6. まとめと今後の課題

本稿では、Sumida らの手法を用いて心拍数を予測する追実験を行った。追実験は、20 代の 4 人の被験者、4 種類のルートという実験環境で行った。本稿で行った実験結果より、心拍数の予測において歩行人数と道の混雑度を考慮しなければならないことがわかった。

また、実験で求めたストレス指標より、混雑している道を歩行する方がストレス指標は高くなる、一人よりも二人で歩行する方がストレス指標は低くなるという傾向が見られた。

今後の課題として、心拍数予測の精度向上が挙げられる。精度向上のために、入力パラメータにおいてまだ不足しているパラメータを増やすことが考えられる。歩行環境データとして、

路面状態を含めるという展望がある。路面状態とは、路面上の段差や凹凸の状態のことである。これらのデータは、歩行アシストカートの上にスマートフォンを置き、スマートフォンの加速度センサを用いて取得しようと考えている。凹凸が激しい路面では、得られた加速度の振幅が大きくなると考えられる。

路面状態の他にニューラルネットワークの入力パラメータとして、気温や天候なども挙げられる。

また、下り坂の場合であっても酸素需要量を正確に求められるようにしなければならない。

7. 謝 辞

本研究の一部は独立行政法人科学技術振興機構 (JST) の研究成果展開事業「センター・オブ・イノベーション (COI) プログラム」の支援によって行われた。

文 献

- [1] ストレス指標としての自律神経機能活性度 http://hclab.sakura.ne.jp/stress_novice_LFHF.html
- [2] Mayu Sumida, Teruhiro Mizumoto, and Keiichi Yasumoto, Estimating heart rate variation during walking with smartphone, 2013 ACM international joint conference on Pervasive and ubiquitous computing.
- [3] T. J. Barstow and P. A. Mole. Linear and nonlinear characteristics of oxygen uptake kinetics during heavy exercise. J. of Applied Physiology, Vol. 71, No. 6, pp. 2099-2106, 1991.
- [4] 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.
- [5] American College of Sports Medicine. ACSM's Guidelines for Exercise Testing and Prescription (7th edition). Lippincott Williams & Wilkins, Philadelphia, 2005.
- [6] WEKA <http://www.cs.waikato.ac.nz/ml/weka/>
- [7] RS800CX GPS 対応スポーツウォッチ http://www.polar.com/ja/products/maximize_performance/running_multisport/RS800CX_N
- [8] 地理院地図 <http://portal.cyberjapan.jp/help/development.html#api>
- [9] American College of Sports Medicine. ACSM's Resource Manual for Guidelines for Exercise Testing and Prescription (7th edition). Lippincott Williams & Wilkins, 2013/2/1.
- [10] 混雑度マップ <http://lab.its-mo.com/densitymap/>