

# スマートフォン慣性センサを用いた酩酊状態の 歩行検出に関する検討

杉本 広大<sup>1,a)</sup> 平嶋 崇大<sup>2,b)</sup> 前川 卓也<sup>2,3,c)</sup>

**概要:** 本研究では、スマートフォンの慣性センサを用いて歩行を計測することにより、酩酊状態か否かを識別する手法を提案する。アルコールは人間の動作に影響を与えるため、スマートフォンにより計測した歩行時の慣性センサデータに対して機械学習を行うことにより、酩酊状態か素面状態かを識別する。ただしユーザによって歩行動作は異なるため、事前にそのユーザの酩酊および素面状態両方の歩行センサデータを取得することが望ましい。しかしその両方を事前に取得することはコストが大きいため、本研究では他のユーザの酩酊・素面状態の歩行センサデータと、対象のユーザの素面状態の歩行センサデータのみを用いて識別することを目指す。本研究では、実際に取得したデータに対して提案手法を適用し、その識別性能を検証する。

## 1. はじめに

近年、加速度センサやマイク等を搭載したスマートフォンなどのモバイル機器が急激に普及しており、これらの各種センサを用いて日常生活行動の認識を行う研究が盛んに行われている。本稿では、スマートフォンで計測された歩行センサデータ（歩行時における加速度・ジャイロセンサデータ）から、ユーザが酩酊状態か否かの識別を試みる。酩酊状態はユーザの生活を脅かす重要なコンテキストの1つである。例えば、飲酒運転や酩酊時の歩行は自動車事故の主要な原因である [11]。そのため、酩酊状態か否かの識別は日常生活に関わるさまざまな新しいアプリケーションを開発する上で有用である。例えば、酩酊状態のユーザが車を運転しようとしたときにアラームを鳴らすアプリケーションや、酩酊状態か否かによって案内ルートを変更する道案内アプリケーション、酩酊状態のユーザが長時間外を歩き回っている際に家族に位置情報等を送信するアプリケーションなどが考えられる。

本研究では、アルコール摂取が身体のパフォーマンス

（例えば、直立や歩行の安定性）に影響を与えるという事実 [12] に着目し、ユーザの歩行時に得られた歩行センサデータを基に酩酊状態か否かの推定を試みる。ユーザが酩酊状態と素面状態で、歩行センサデータに違いがあると考えられるため、機械学習技術を用いることで歩行センサデータを酩酊状態か素面状態かに分類できると考える。分類を行うため全てのエンドユーザごとに、事前に酩酊時と素面時の両方の歩行センサデータを計測しておくことが理想的であるが、酩酊時の歩行センサデータを事前に用意することはコストの面で困難である。そこで、エンドユーザにそのような大きな負担をかけることなく酩酊状態を検出することを目指す。本研究では、エンドユーザの歩行を識別する際に、訓練データとして事前に計測した他のユーザの酩酊時と素面時の両方の歩行センサデータを使用する。しかし歩行センサデータの分析の結果、歩行センサデータはユーザによって異なることが判明したため、あらかじめ取得したエンドユーザの素面時の歩行センサデータも識別に用いる。素面時の歩行センサデータは、酩酊時の歩行センサデータに比べて比較的容易に取得可能である。

本研究では、まずテストデータとなる歩行センサデータから特徴量を抽出し、特徴量の分布を計算する。各ユーザによる歩行の差異によらない素性を抽出するため、これらの分布と事前に計測してあるそのエンドユーザの素面時歩行センサデータにおける特徴量の分布を比較し、素性を抽出する。そして抽出した素性を基に、アルコール摂取の判別を行う。本研究の学術的貢献は以下の通りである。(1) 多数の実験参加者から得られた酩酊時および素面時の歩行

<sup>1</sup> 大阪大学工学部  
School of Engineering, Osaka University

<sup>2</sup> 大阪大学大学院情報科学研究科  
Graduate School of Information Science and Technology, Osaka University

<sup>3</sup> 国際電気通信基礎技術研究所  
Advanced Telecommunications Research Institute International (ATR)

a) sugimoto.kodai@ist.osaka-u.ac

b) hirashima.takahiro@ist.osaka-u.ac.jp

c) maekawa@ist.osaka-u.ac.jp

におけるスマートフォン慣性センサデータを分析し、比較する。(2) エンドユーザの酩酊時の歩行を用いることなく酩酊状態か否かを識別する手法を提案する。

## 2. 関連研究

センシング技術の発展とともに、様々なセンサを用いてユーザの健康状態を計測・理解する研究が盛んに行われてきた。例えば、Larson ら [6] は肺活量を測定をスマートフォンのマイクを用いて実現した。また、Grimaldi ら [3] はスマートフォンのカメラと内臓の LED フラッシュライトを用いて、指先から心拍を計測している。

身体の異常を検知するために、身体に装着するウェアラブルセンサを用いる研究も数多く行われている。例えば、Natarajan ら [8] は心電図センサを使用することで、コカイン使用の検出を行った。また、Petrofsky ら [9] は歩行時の加速度センサデータにおける、正常な被験者と病气(糖尿病)の被験者との相違を発見している。

次にアルコール摂取の検出に関する研究をいくつか紹介する。皮膚から蒸発するエタノールを検知するウェアラブルセンサを皮膚の表面に装着し、アルコール摂取を検出する研究が行われている [13]。また、レーザーレンジファインダ、加速度計、床圧センサ等の各種センサを用いて酩酊歩行を分析する研究もいくつか行われている [4], [5], [14]。例えば、Kao ら [5] は各ユーザの酩酊時の歩行が類似しているとの仮定に基づき、加速度計を用いて酩酊時歩行の検出を試みた。これらとは対照的に、本研究では身近な既成のセンサデバイス(スマートフォン)を用いてアルコール摂取の検出を試みる。また、歩行センサデータはユーザごとに異なるという知見に基づき、酩酊時の歩行センサデータを検出する手法を設計する。特に、エンドユーザの酩酊時歩行センサデータを訓練データとして利用しない手法を提案する。

## 3. センサデータ

男子学生 18 名を被験者として、歩行センサデータの計測を行った。被験者のズボン右後ろポケットにスマートフォン Galaxy S III を入れて計測を行った。ただし、スマートフォンの向きは統一した。このスマートフォンにおいて、得られる加速度・ジャイロセンサデータはそれぞれ 3 軸データであり、サンプリング周波数は 30Hz である。各被験者は上記のセンサデバイスを使用し、以下の手順に従って歩行を計測した。

- (1) 被験者が素面時に歩行センサデータを計測する。計測する際は、片道 15m の直線の道路を往復する。この歩行センサデータセグメントを noalcohol クラスと呼ぶ。
- (2) 被験者はアルコールを摂取し、30 分経過後に歩行センサデータを計測する。このとき、30 分後とはアルコールを摂取し始めてからの経過時間である。また、




図 1 被験者 D の加速度およびジャイロの時系列センサデータ

レストランでの飲酒等、現実的な状況を想定しているため、被験者は好きなだけ飲食物(アルコールを含む)を摂取してもよい。ただし、少なくともジョッキ 1 杯のお酒を摂取してもらった。この歩行センサデータを alcohol1 クラスと呼ぶ。

- (3) アルコールを摂取し始めてから、1 時間経過後にもう一度歩行センサデータを計測する。この歩行センサデータを alcohol2 クラスと呼ぶ。

18 名の被験者をそれぞれ被験者 A~R と表す。また、単純にエンドユーザが酩酊状態か否かを認識したい際には、alcohol1, alcohol2 クラスをまとめ、総称して alcohol クラスと呼ぶこととする。1 節で述べたように、エンドユーザの素面時歩行センサデータが必要である。この歩行センサデータは異なる 3 日間において素面時に計測した。15m の往復を各日に計測するため、 $2 \times 3 = 6$  つの noalcohol クラスの歩行センサデータを各被験者において収集した。

## 4. データ分析

図 1 は、被験者 A の歩行から得られた時系列歩行センサデータである。noalcohol データの振幅が、alcohol2 データの振幅よりも大きくなっているように見える。さらに、図 2 に被験者 D の加速度センサデータのスライディングウィンドウ毎に計算した分散値の分布を示す(センサデータからの特徴量抽出については後述する)。図 2 より、被験者 D はアルコールを摂取するにつれて分散値が増加していることがわかる。図 3 は同様に被験者 E についての加速度センサデータの分散値の分布を示す。被験者 E の分散値は、被験者 D 同様にアルコールを摂取するにつれて増加している。しかし、noalcohol データに関しては、被験者 D の分散値は被験者 E のものよりも比較的大きい。また、被験者 E の alcohol1 データの値と被験者 D の noalcohol データの値は類似している。このように歩行センサデータはユーザによって異なっており、エンドユーザの noalcohol データなしにアルコール摂取の有無を検出することは困難であると考えられる。一方、図 4 に示すように、被験者 A の加速度センサデータの分散値はアルコール摂取につれて減少している。すなわち、アルコール摂取による歩行センサデータへの影響はユーザによって異なる。また、全体的に alcohol クラスの分布の分散度は noalcohol クラスのそれと比べて大きい傾向が見られる。ただし、図 5 に示すよ




図 2 加速度分散値の分布 (被験者 D)




図 4 加速度分散値の分布 (被験者 A)




図 6 加速度 FFT 第 32 番成分の分布 (被験者 D)

うに被験者 R に関しては成り立っておらず、ユーザによって異なることがわかる。図 6 に被験者 D の加速度センサデータのスライディングウィンドウ毎に計算した FFT 第 32 番成分の分布を示す。アルコール摂取によって分布の分散度が大きくなっている。FFT 第 32 番成分は高周波の成分を表しているため、図 6 より酩酊状態では歩行センサデータにおいて高周波の値が大きくなることがわかる。これは、アルコール摂取によって歩行が不安定になることに基因すると考えられ、他の多くの被験者においても同様の




図 3 加速度分散値の分布 (被験者 E)




図 5 加速度分散値の分布 (被験者 R)

傾向がみられた。

表 1 に被験者ごとに、特徴量 (次節で詳述) を分類の貢献度に応じてランキングした結果の一部を示す。このランキングは、特徴量を用いて歩行センサデータを noalcohol クラスと alcohol クラスに分類する際の寄与度に基づいて計算したものであり、寄与度が大きいほど順位が高くなる。寄与度の計算には、その特徴量によって分類対象のインスタンスをどれだけ曖昧さが低く分類できるかの指標である情報利得を用いた [16]。被験者によって特徴量の順位は様々であるが、いくつかの特徴量 (例えばジャイロデータの分散値) は多くの被験者において高順位であった。以上をまとめると、多くの被験者において共通する特徴量がアルコール摂取の影響を受けているが、特徴量の値の変化は被験者によって異なっている。以上の分析を踏まえて分類手法を構築する。

## 5. 提案手法

テストデータとして、エンドユーザの歩行センサデータセグメント (本研究においては、15m 分の歩行センサデータ) を用いる。上記の分析に基づき、その歩行センサデータセグメントを noalcohol クラスか alcohol クラスに分類する手法を実現する。図 7 に提案手法の概要を示す。まず歩行センサデータセグメントからスライディングウィンドウごとの特徴量を抽出し、特徴量の分布を計算する。図 2 に示すように、分布は歩行センサデータセグメントの特性をよく表す。これらの分布と、事前に計測してあるエンドユーザの素面時歩行センサデータにおける特徴量の分布を比較し、素性抽出を行う。そして抽出した素性を基に、アルコール摂取の判別を行う。

### 5.1 特徴量抽出

各歩行センサデータセグメントにおいて、64 サンプルサイズのスライディングウィンドウごとに特徴量を抽出する。このとき、隣り合うスライディングウィンドウ同士は 90% のオーバーラップである。以下の方法により、テストデータセグメント内の各ウィンドウから特徴量を求める。そして、ガウス分布を用いて各特徴量の分布を表現する。

#### 5.1.1 加速度センサからの特徴抽出

3 軸加速度センサから得られる加速度データは、スマートフォンの姿勢に応じて変化する。そのため、加速度センサの特徴量を計算する際には Gafurov らの研究 [2] にて提案されている合成信号

$$R_i = \arcsin\left(\frac{Z_i}{\sqrt{X_i^2 + Y_i^2 + Z_i^2}}\right) \quad (1)$$

を用いることで、その変化の影響を低減する。ただし、 $R_i$  は  $i$  番目の合成信号をあらわす。また、スマートフォンの向きに依存しない特徴量を抽出するため、加速度データを用いた行動認識の研究 [1], [7], [15] を基に、周波数に関する

表 1 特長量の情報利得ランキング (被験者 A~J)

	A	B	C	D	E	F	G	H	I	J
1	gyroxmm	accvar	gyrovary	accmm	accvar	gyroymm	gyroymm	accvar	gyroymm	gyrovarz
2	gyrovarx	gyrozmm	gyroymm	gyrovary	gyrovary	gyrozmm	gyroxmm	gyroxmm	gyroxmm	gyrozmm
3	accfft_11	accmm	accfftent	gyrozmm	gyroymm	gyrovarz	accvar	accmm	gyrovary	accmm
4	accvar	gyrovarz	gyroxmm	gyroxmm	accmm	gyroxmm	gyrovarx	gyrovary	gyrozmm	gyrovarx
5	gyroymm	gyroxmm	gyrovarx	accvar	accfft_2	gyrovary	accfft_5	gyrovarx	accmm	gyroxmm
6	accmm	accfft_6	accmm	gyroymm	accfft_7	accmm	accmm	gyrozmm	gyrovarz	accvar
7	gyrovarz	accfft_18	accfft_27	gyrovarz	accfft_10	accvar	gyrozmm	gyroymm	accfft_6	gyroymm
8	accfft_7	accfft_7	gyrozmm	accfftent	gyroxmm	gyrovarx	gyrovary	accfft_6	accfft_6	accfft_5
9	gyrozmm	accfft_14	accfft_18	gyrovarx	accfft_9	accfft_5	accfft_1	accfft_1	accfft_8	accfft_0
10	gyrovary	accfft_1	accvar	accfft_6	accfft_22	accfft_11	accfft_13	accfft_7	accfft_9	accfft_14




図 7 提案手法の概要

る特徴量を主に用いる。以下に合成信号から抽出する特徴量を示す。

- 周波数成分：64 サンプルウィンドウから FFT 成分を計算し、その 32 成分を特徴量として用いる。
- 周波数領域エントロピー：離散 FFT 成分から求めた正規化した情報エントロピーである [1]。
- 主要周波数成分：FFT 成分における主要周波数成分である。
- ウィンドウ内センサデータの最大値と最小値の差異
- ウィンドウ内センサデータの分散値

### 5.1.2 ジャイロセンサからの特徴抽出

ジャイロセンサは 3 軸角速度データを出力する。それぞれの軸データに対して、以下の特徴量を求める。

- ウィンドウ内センサデータの最大値と最小値の差異
- ウィンドウ内センサデータの分散値

### 5.2 分布からの素性抽出

上述したように、エンドユーザからいくつかの素面時歩行センサデータセグメントを事前に取得していることを前提とする。これらのセグメントにおける各特徴量の分布と、テストデータセグメントにおける対応する特徴量の分布とを比較し、分類のための素性を抽出する。図 2, 図 4 に示すように、アルコール摂取による特徴量分布への影響(増加や減少)はユーザに依存するため、ここでは主に分布

間の距離を利用した素性抽出を行う。計算された距離は、テストデータセグメントの歩行センサデータと素面時歩行センサデータとの差異を表す。具体的には各特徴量について以下の素性値を計算する。

- 平均距離：上述したように、エンドユーザの noalcohol クラスに対応するいくつかの歩行センサデータセグメントを事前に取得している(本稿においては 4 つのセグメント)。事前に取得した各 noalcohol センサデータセグメントの分布とテストデータセグメントの分布との距離を計算する。この素性値はその 4 つの距離の平均に相当する。
- 最長距離：4 つの距離の最大値である。
- 最短距離：4 つの距離の最小値である。

ただし、次の 2 種類の距離計算に基づいて上記 3 つの素性値を計算する。

- カルバック・ライブラー (KL) ダイバージェンス：KL ダイバージェンスとは、2 つの確率分布 P と Q 間の差を表す一般的に用いられる尺度のことである。確率分布 P と Q の KL ダイバージェンス  $D_{KL}(P||Q)$  は

$$D_{KL}(P||Q) = \int_{-\infty}^{\infty} p(x) \log \frac{p(x)}{q(x)} dx \quad (2)$$

と定義される。本稿ではガウス分布を用いているため、 $p(x) = N(\mu_1, \sigma_1)$ ,  $q(x) = N(\mu_2, \sigma_2)$  である。ただし、 $\mu$  と  $\sigma$  はそれぞれ平均値と分散値を表す。

- 平均値の差：単純に平均値の差を用いる。すなわち2つの分布間において  $|\mu_1 - \mu_2|$  より求める。

またこれらの分布間の距離に加えて、各特微量分布の分散値についても同様に比較し、テストデータセグメントより素性を抽出する。

- 分散値の差：事前に取得した noalcohol センサデータセグメントの各特微量分布の分散値の平均値との差異を求める。

以上7つの素性値 ( $2 \times 3 + 1$ ) を各特微量より抽出する。

### 5.3 クラス分類

上述のように、noalcohol センサデータセグメントと比較することによって、テストデータセグメントから各素性値を抽出する。次に、noalcohol クラスと alcohol クラスに分類するため、抽出した素性値から C4.5 決定木を作成する [10]。本研究では事前に用意した他ユーザから取得した各素性値を訓練データとして、決定木のパラメータ学習を行う。これにより、noalcohol クラスか alcohol クラスかの分類に関する有用な素性情報を複数の他ユーザから学習することが可能である。

## 6. 評価実験

提案するクラス分類手法を、“leave-one-subject-out” 交差検証を用いて評価を行う。すなわち、被験者1人をエンドユーザとし、そのユーザから得られた歩行センサデータをテストデータ、残りの被験者から得られた歩行センサデータを訓練データとして分類性能を求める交差検定手法である。第3章で説明した手順により得られた歩行センサデータセグメントを用いて分類精度を計算する。また、C4.5 決定木を用いた比較用の簡易手法も用意する。この簡易手法では、noalcohol センサデータセグメントとの比較は行わずに、素性値として各特微量分布のパラメータ、すなわち各特微量分布の平均値と分散値を単純に用いる。この簡易手法と提案手法における分類性能を比較することにより、性能の評価を行う。

## 7. 結果

### 7.1 パフォーマンス

評価指標には、以下の式で表される適合率 (precision) と再現率 (recall) の調和平均であり、分類性能の良さを表す F 値 (F-measure) を用いる。

$$F_{measure} = \frac{2 \cdot precision \cdot recall}{precision + recall} \quad (3)$$

表 2 に提案手法と簡易手法のそれぞれのクラス分類精度を示す。提案手法では F 値が 70% 以上と高い精度を示した。また、提案手法の分類精度は簡易手法の分類精度を上回った。これは、提案手法が歩行センサデータはユーザごとに異なるという問題に対処するよう設計されているため

表 2 提案手法・簡易手法によるクラス分類精度 (%)

		平均適合率	平均再現率	平均 F 値
2 クラス	提案手法	72.0	71.5	71.4
	簡易手法	52.9	52.8	52.2
3 クラス	提案手法	40.9	40.7	40.3
	簡易手法	31.7	31.5	31.0




図 8 2 クラス分類における混同行列




図 9 3 クラス分類における混同行列

だと考えられる。図 8 に提案手法と簡易手法の混同行列を示す。混同行列とはクラス分類の結果をまとめた表であり、行が実際のクラス、列が予測分類されたクラスを表す。図 8 の混同行列では、セルの色が濃いほど対応するクラスに予測分類されたインスタンス (歩行センサデータセグメント) 数が多いことを示している。簡易手法で得られた結果は、半数以上の noalcohol の歩行センサデータセグメントが誤って alcohol クラスに分類された。一方、提案手法では noalcohol, alcohol クラス共に多数の歩行センサデータセグメントが正しく分類された。

### 7.2 3 クラス分類

歩行センサデータセグメントを noalcohol, alcohol1, alcohol2 の 3 クラスへの分類を試みた。図 9 に提案手法と簡易手法によるクラス分類混同行列を示す。表 2, 図 9 が示すように、3 クラスの分類精度は非常に低く、alcohol1, alcohol2 のクラス分類を行うことは非常に困難であると考えられる。図 3, 図 4 に示すように、被験者によっては alcohol1 と alcohol2 の分布に大きな違いはみられない。これは被験者によってアルコールを摂取する量、アルコールへの耐性が違うことが要因であると考えられる。本研究ではアルコール摂取時からの経過時間によって分類クラスの設定をしたが、血中アルコール濃度などで分類クラスの設定を行うことも考えられる。

表 3 各被験者のクラス分類精度 (F 値 (%))

被験者	A	B	C	D	E	F	G	H	I
提案手法	61.9	61.9	50.0	100	100	73.3	27.3	73.3	87.3
簡易手法	87.3	73.3	33.3	61.9	56.4	73.3	33.3	36.5	20.0

被験者	J	K	L	M	N	O	P	Q	R
提案手法	73.3	73.3	56.4	73.3	73.3	61.9	73.3	100	27.3
簡易手法	20.0	20.0	50.0	27.3	33.3	73.3	73.3	20.0	56.4

### 7.3 被験者毎の結果

表 3 に提案手法と簡易手法それぞれの各被験者の F 値を示す (2 クラス分類の結果). 多くの被験者において, 提案手法の結果が大幅に簡易手法の結果を上回った. 被験者 D, E, I, Q に関しては, 提案手法において非常に高い精度となった. この被験者らの歩行センサデータはアルコール摂取の影響を大きく受けたと考えられる. 一方で, 被験者 C, G, R の分類精度は悪かった. 第 3 章では説明を省いたが, 酩酊時歩行センサデータを計測する際にお酒の摂取量と, 酩酊度を 5 段階評価 (1: ほぼ素面, 2: ほろ酔い, 3: 酔い, 4: 飲みすぎ, 5: 泥酔) で自己申告してもらった. 被験者 R は, アルコールを摂取し始めて 1 時間の時点でビールをジョッキ 1 杯強のみしか摂取しておらず, また, “2: ほろ酔い” と答えている. この被験者 R のように, アルコール摂取量が少なく, 酔いの程度が低い場合には酩酊状態の検出は困難であると考えられる. 分類精度はエンドユーザのアルコール耐性, アルコール摂取量に依存するであろう. しかし, 被験者 D, E, I はアルコール摂取から 30 分または 1 時間経過の際に “1: ほぼ素面” または “2: ほろ酔い” と回答しているが, 提案手法によって正確に歩行データセグメントを分類することができている. この結果は, エンドユーザが酩酊を認識していない場合においても, アルコール摂取の検出が可能であることを示している.

### 8. おわりに

本稿では, ユーザの素面時歩行センサデータを用いたアルコール摂取を判別する新しい方法を提案した. 提案手法では, エンドユーザの酩酊時歩行センサデータを事前に収集することなく, 酩酊状態か否かを識別することができる. 現実的な環境を想定してポケットにセンサ (スマートフォン) を挿入して歩行センサデータを収集したため, ポケットの深さの違いや大きさの違いによりスマートフォンの揺れ方がユーザによって異なる等不安定な状況であったと考ええる. しかし, 実際に取得したデータに対して酩酊状態に固有の特徴を発見する提案手法を適用することで, 良好な識別性能を確認することができた.

今後の課題は, アルコール摂取量や体へ影響が及ぶまでの時間等の関係を調べ, 分類するクラス設定を検討するこ

とや, 酩酊状態以外の歩行センサデータに影響を与える要因 (例えば, 足の怪我, 高熱等) についても調査することである. 現在は, 足首の捻挫を想定し, 三角巾を用いて被験者の足首を固定し歩行センサデータを計測している (この歩行センサデータセグメントを injured クラスと呼ぶ). 素面時 (健常時) と足首負傷時の時間軸歩行センサデータ, 加速度センサデータの分散の分布をそれぞれ図 10, 図 11 に示す. 図 10 が示すように, 足首負傷時の歩行センサデータの振れ幅は小さく, さらにピークの周期が長いことがわかる. また, 図 11 は足首負傷時の加速度センサデータの分散値は素面時のものより小さい値を示している. 以上の分析より, 負傷時の歩行センサデータを素面時歩行センサデータを用いることで酩酊状態同様に識別できると考える. しかし, 歩行センサデータがそれらの要因によってアルコール摂取と同様の影響を受けてしまうユーザの場合, 提案手法による検出精度は低下するであろう. アルコールを摂取する時間, 場所は時刻や GPS データ (例えばレストランの位置を含む地図を用いる) などを用いてある程度予測できるため, この問題の影響を低減することもできると考える.




図 10 被験者 F の加速度およびジャイロの時系列センサデータ

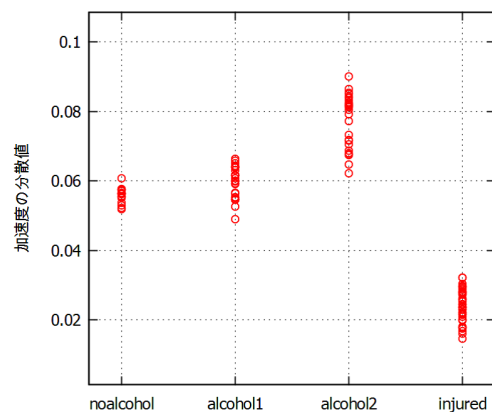


図 11 加速度分散値の分布 (被験者 F)

## 参考文献

- [1] Bao, L., and Intille, S. S. Activity recognition from user-annotated acceleration data. In *Pervasive 2004* (2004), 1-17.
- [2] Gafurov, D., Helkala, K., and Sondrol, T. Biometric gait authentication using accelerometer sensor. *Journal of computers* 1, 7 (2006), 51-59.
- [3] Grimaldi, D., Kurylyak, Y., Lamonaca, F., and Nastro, A. Photoplethysmography detection by smartphone's videocamera. In *International Conference on Intelligent Data Acquisition and Advanced Computing Systems (IDAACS2011)*, vol. 1 (2011), 488-491.
- [4] Jansen, E., Thyssen, H., and Brynskov, J. Gait analysis after intake of increasing amounts of alcohol. *Zeitschrift für Rechtsmedizin* 94, 2 (1985), 103-107.
- [5] Kao, H.-L. C., Ho, B.-J., Lin, A. C., and Chu, H.-H. Phone-based gait analysis to detect alcohol usage. In *UbiComp 2012* (2012), 661-662.
- [6] Larson, E. C., Goel, M., Boriello, G., Heltshe, S., Rosenfeld, M., and Patel, S. N. Spirosmart: using a microphone to measure lung function on a mobile phone. In *UbiComp 2012* (2012), 280-289.
- [7] Maekawa, T., and Watanabe, S. Unsupervised activity recognition with user's physical characteristics data. In *Int'l Symp. on Wearable Computers* (2011), 89-96.
- [8] Natarajan, A., Parate, A., Gaiser, E., Angarita, G., Malison, R., Marlin, B., and Ganesan, D. Detecting cocaine use with wearable electrocardiogram sensors. In *UbiComp 2013* (2013), 123-132.
- [9] Petrofsky, J., Lee, S., and Bweir, S. Gait characteristics in people with type 2 diabetes mellitus. *European Journal of Applied Physiology* 93, 5 (2005), 640-647.
- [10] Quinlan, J. R. *C4.5: Programs for Machine Learning*. Morgan Kaufmann, 1993.
- [11] Schuurman, N., Cinnamon, J., Crooks, V. A., and Hameed, S. M. Pedestrian injury and the built environment: an environmental scan of hotspots. *BMC Public Health* 9, 1 (2009), 233.
- [12] Stainback, R. D. *Alcohol and sport*. Human Kinetics, 1997.
- [13] Swift, R. M., Martin, C. S., Swette, L., Laconti, A., and Kackley, N. Studies on a wearable, electronic, transdermal alcohol sensor. *Alcoholism: Clinical and Experimental Research* 16, 4 (1992), 721-725.
- [14] Teixidó, M., Pallejà, T., Tresanchez, M., Nogués, M., and Palacín, J. Measuring oscillating walking paths with a lidar. *Sensors* 11, 5 (2011), 5071-5086.
- [15] Welk, G., and Differding, J. The utility of the digi-walker step counter to assess daily physical activity patterns. *Medicine & Science in Sports & Exercise* 32, 9 (2000), S481-S488.
- [16] Witten, I., and Frank, E. *Data Mining: Practical machine learning tools and techniques*. Morgan Kaufmann, 2004.