

スマートフォン搭載3軸加速度センサと 3軸ジャイロセンサを用いた自転車の挙動認識

宇佐見 友理^{1,a)} 石川 和明² 高山 敏典² 柳澤 政生¹ 戸川 望^{1,b)}

概要: 自動車・バイクの挙動認識に基づいて危険運転を予測し, 事故を未然に防げるようになった. しかし, 自転車の挙動認識に目を向けた研究は少ない. 自転車はバイクと同じ二輪車であるが, バイクと異なり車道以外を走行する可能性があるため歩行者や電柱といった障害物を回避する動作が多くなる. そのため, バイク向けの挙動認識手法を自転車に適用すると回避動作を正確に認識することは難しい. 既存の自転車の挙動認識手法として, スマートフォンを後輪軸横に設置することでセンサのノイズを低減し, 自転車の挙動を比較的正確に認識する手法が提案されているが, この手法では, 自転車が遅い速度で曲がった際, 角速度の変化を十分に認識できず, 直進状態と右左折状態でのセンサの値に違いが現れにくくなり誤認識につながるという問題点がある. さらにユーザが停車中にスマートフォンを利用できず実用的ではない. 一方, スマートフォンの設置位置をハンドル部分にすると, センサがノイズの影響を受けやすくなり自転車の挙動認識そのものが難しくなる. 本稿では, スマートフォンに搭載された3軸加速度センサと3軸ジャイロセンサを用いた自転車の挙動認識手法を提案する. 提案手法では, スマートフォンをハンドル部分に取り付けることで, ハンドルの回避動作の認識を可能とし, ユーザが停車中にスマートフォンを利用可能とする. 自転車走行の際にバランスをとるために行う周期的なハンドル操作に着目しこれに基づくセンサのノイズを除去し, また機械学習により自転車の挙動を学習することで, 正確な自転車の挙動認識を可能とする. 提案手法を用いて自転車の挙動(停止・直進・右折・左折)を認識したところ, 既存手法のF値が0.6を超える程度であったのに対して, 4つの挙動全てについてF値が0.8を超える高い精度となった.

1. はじめに

近年, 自動車・バイクの挙動認識に基づいて危険運転を予測し, 事故を未然に防げる研究が進んでいる [1-4].

一方, 自転車の危険運転に目を向けると, 警察庁が公表した自転車事故分析資料によると, 自転車の事故件数は緩やかに減少しているものの, 都内の自転車事故の件数は, 平成29年の一年間で11901件あり, 都内で発生した全事故件数の約3分の1を占めている [5]. 警察庁は自転車走行時のルールを設定し, 危険運転減少を目指しているが, ルールを守っているユーザは少ない [6]. 自転車の挙動認識により危険運転の防止や注意をすることで, 自転車事故減少に貢献できる [7-9]. ところが, 自転車の挙動認識に目を向けた研究は少ない.

自転車はバイクと同じ二輪車であるが, バイクは車道の

み走行可能である一方, 日本では自転車は車道に加えて通行可の標識がある歩道を徐行して通行できる. さらに多くの自転車ユーザは交通ルールを守らず車道以外を走行する可能性があるため, 歩行者や電柱といった障害物を回避する動作が多くなる. そのため, バイク向けの挙動認識手法 [1-4] を自転車に適用すると, これらの自転車の回避動作を正確に認識することは難しいと考えられる. さらに自転車はバイクとは異なり, 走行中に絶えず左右にハンドルをきり続けることでバランスをとり走行しているため [10-12], ハンドル操作によるノイズが強く影響してくる.

これまでの自転車の挙動認識手法は, 大きく分けて, 直接センサ機器を用いる手法と, スマートフォン搭載センサを用いる手法に分類できる.

センサ機器を用いた自転車の挙動認識手法 [7, 8, 13]

センサ機器を用いる手法は, 自転車やユーザに挙動認識するために必要なセンサを予め取り付け, そのセンサから得た値を用いて自転車の挙動を認識している. 河内らは, 自転車に光電センサとロータリーエンコーダを取り付けることで自転車の走行環境をリアルタイムに取得した [13]. 下山らは, 自転車に複数のセ

¹ 早稲田大学
Waseda University

² ゼンリンデータコム
ZENRIN DataCom

^{a)} yuri.usami@togawa.cs.waseda.ac.jp

^{b)} togawa@togawa.cs.waseda.ac.jp

ンサとマイコンを取り付け、危険運転と認識した場合に運転者やその周りにいる人に対して警告を発するシステムを提案した [7]。大井らは、ユーザに取り付けたモーションセンサからユーザの運転姿勢を検出し、危険運転かどうかを認識した [8]。これらの手法 [7, 8, 13] では、自転車の挙動を認識するために必要なセンサ機器を用意し自転車やユーザに取り付けなければならないが、ユーザの負担になる。

スマートフォン搭載センサを用いた自転車の挙動認識手法 [9]

スマートフォン搭載センサを用いる手法として、スマートフォンに搭載された 3 軸加速度センサの値から自転車の挙動を認識する手法がある [9]。後藤らは、スマートフォンの設置位置を自転車の後輪軸横にすることで、センサの値をフィルタリングすることなくノイズの影響を最小限に抑え、右左折時のセンサの値に特徴が現れやすくしている。ところが自転車の速度が遅いまま自転車が曲がる場合、ハンドルに設置した場合と比べて角速度の影響が小さくなるため、直進状態と右左折状態でのセンサの値に違いが現れにくくなり誤認識に繋がる。さらにユーザが停車中にスマートフォンを利用できない。

本稿では特別なセンサ機器を必要とせず、またユーザが利用しやすいようにスマートフォンを自転車のハンドル部分に取り付け自転車の挙動認識を目指す。スマートフォンをハンドル部分に取り付ける場合、走行中のバランスをとるためのハンドル操作の影響を受けやすくなるため、自転車の挙動認識が難しくなる。いかにハンドル操作による影響を少なくし正確に挙動を認識するかが最大の問題となる。

そこで本稿では、スマートフォンに搭載された 3 軸加速度センサと 3 軸ジャイロセンサを用いた自転車の挙動認識手法を提案する。自転車の挙動を認識するにあたって、自転車走行の際にバランスをとるために行う周期的なハンドル操作に着目し、これにもとづくセンサのノイズを除去し、また機械学習により自転車の挙動を学習することで、スマートフォンを自転車のハンドル部分に取り付けた場合でも精度の高い自転車の挙動認識を実現する。提案手法を用いた自転車の挙動認識の実装と評価を行い、提案手法の有効性を評価する。

本稿の貢献は以下の通りである。

- (1) 自転車のハンドル部分に取り付けたスマートフォンのセンサに対して、自転車走行の際にバランスをとるために行う周期的なハンドル操作に着目し、これにもとづくセンサのノイズを除去し、また機械学習により自転車の挙動を学習することで、スマートフォンをハンドル部分に取り付けた場合でも精度の高い自転車の挙動認識を実現する。




図 1: スマートフォン搭載の加速度センサとジャイロセンサの軸。




図 2: スマートフォンの設置位置。




図 3: 時間窓毎の挙動認識の例。

- (2) 総サンプル数 8969 個の学習データと総サンプル数 295 個のテストデータに対して提案手法を適用したところ、自転車の 4 つの挙動 (停止・直進・右折・左折) の F 値が 0.8 を超える高い精度になったことを確認した。既存手法では、右折状態の F 値が 0.62, 左折状態の F 値が 0.72 であったのに対して、提案手法は、右折状態の F 値が 0.89, 左折状態の F 値が 0.90 となり、より正確な自転車の挙動認識が実現された。

2. 自転車の挙動認識問題

まず本章では自転車の挙動認識問題を定義する。3 軸の加速度センサ・ジャイロセンサを搭載するスマートフォンを用いるとする。スマートフォンに搭載されている加速度センサ・ジャイロセンサの軸を図 1 に示す。3 軸加速度センサは、スマートフォンの X 軸・Y 軸・Z 軸の 3 軸方向の成分の加速度を取得できる。図 2 のように Y 軸を進行方向とし画面を上にして地面と水平にスマートフォンを自転車

に設置した場合、加速度センサの値は、加速時に Y 軸方向正の値をとり、減速時に負の値をとる。車体を倒すなど左右方向の加速度は、右向きに力が働いた場合 X 軸方向正の値をとり、左向きに力が働いた場合負の値をとる。さらに、重力や上下の振動など上下方向の加速度は、上向きに力が働いた場合 Z 軸方向正の値をとり、下向きに力が働いた場合負の値をとる。ジャイロセンサの値は、軸を中心として左回りすると正の値をとり、右回りすると負の値をとる。

ユーザは各自所持するスマートフォンを自転車のハンドル部分に取り付けて自転車を運転するものとする。スマートフォンの設置位置を図 2 に示す。センサの Y 軸を自転車の進行方向として、ハンドル部分に水平に設置されたセンサより、 t_s [秒] ごと(本稿では、 $t_s = 0.05$ 秒とする)に 3 軸加速度センサの値 a_x , a_y , a_z と 3 軸ジャイロセンサの値 ω_x , ω_y , ω_z が与えられる。時間窓 T [秒] を設定し、時間窓毎に与えられた 3 軸加速度センサの値と 3 軸ジャイロセンサの値から自転車の挙動(停止・直進・右折・左折)を認識する(図 3) *1。以上の準備のもと、挙動認識問題を以下に定義する。

定義 1 (自転車の挙動認識問題)。自転車の挙動認識問題とは、スマートフォン搭載センサより、 t_s [秒] ごとに 3 軸加速度センサの値と 3 軸ジャイロセンサの値が与えられたとき、時間窓 T [秒] ごとに自転車の挙動(停止・直進・右折・左折)を認識することである。

3. スマートフォン搭載センサを用いた自転車の挙動認識

自転車の挙動をスマートフォン搭載センサによって認識すると、3 軸加速度センサの値と 3 軸ジャイロセンサの値には必ず以下に示すノイズが含まれる [14, 15]。

- (A) 路面からのノイズ(加速度センサ・ジャイロセンサ)
- (B) ハンドル操作によるノイズ(加速度センサ・ジャイロセンサ)
- (C) ドリフトによるノイズ(ジャイロセンサ)

(A) 路面からのノイズは、認識する挙動の周波数より高周波であるため、LPF (Low Pass Filter) を用いたり、使用するセンサの軸を限定することで除去可能である。

(B) ハンドル操作によるノイズは、加速度センサとジャイロセンサに強く影響を与える。(B) ハンドル操作によるノイズは、(A) 路面からのノイズや (C) ドリフトによるノイズとは違い、ユーザのペダリング等により発生するノイズであり、個人差や走行状況に左右される。

(C) ドリフトによるノイズは、ジャイロセンサに強く影響を与える。一般に、ジャイロセンサのドリフトを除去するには、ドリフトの影響を受けない加速度センサより算出

した角度とジャイロセンサによる値とを比較し、カルマンフィルタや相補フィルタを適用することが多い [16]。

例えば、加速度センサ・ジャイロセンサを水平な状態に設置する。重力加速度は Z 軸方向のみにかかる。このとき、X 軸を中心に加速度センサが回転すれば、Y 軸方向に加速度がかかり、Y 軸を中心に加速度センサが回転すれば、X 軸方向に加速度がかかる。これら重力加速度の値を用いれば、ジャイロセンサの値を使わずに加速度センサだけを用いて X 軸ならびに Y 軸の角度を算出することができ、これらの値をもとにジャイロセンサのドリフトによるノイズを除去可能となる。

ところが、加速度センサ・ジャイロセンサを水平な状態に設置し Z 軸を中心に加速度センサが回転する場合には、重力加速度は Z 軸方向のみにかかり続ける。そのため、加速度センサの値だけを使って Z 軸の角度を算出することは原理的に不可能となり、ジャイロセンサ Z 軸のドリフトによるノイズは除去できないことになる。後述するように、提案手法はジャイロセンサ Z 軸の値を必要とするため、こうした加速度センサの値との比較による補正処理は困難になる。


既存のスマートフォン搭載センサを用いた挙動認識手法では [9]、自転車の後輪軸横が (A) 路面からのノイズと (B) ハンドル操作によるノイズの影響が最も小さいスマートフォンの設置位置であることを示し [17]、自転車の後輪軸横に設置したスマートフォンの加速度センサから自転車の挙動を認識している。一方、自転車のハンドル部分にスマートフォンを取り付けて自転車の挙動を認識した場合、加速度センサ・ジャイロセンサともに自転車走行の際にバランスを取るために行う周期的なハンドル操作によって、強く (B) ハンドル操作によるノイズの影響を受け、そのため正確な自転車の挙動認識が難しくなる。

そこで本稿では自転車の挙動認識をするにあたって、スマートフォン搭載センサから取得した 3 軸加速度センサの値と 3 軸ジャイロセンサの値に対し、(1) フィルタリングに基づくノイズ低減処理することで上記 (A)~(C) によるノイズの影響を低減し、(2) 機械学習を導入することで自転車の挙動を認識する手法を提案する。


3.1 フィルタリングに基づくノイズ低減処理

前述したように、自転車のハンドル部分に取り付けたスマートフォン搭載の 3 軸加速度センサと 3 軸ジャイロセンサは、(A) 路面からのノイズと (B) ハンドル操作によるノイズと (C) ドリフトによるノイズの影響を受ける。特に (B) ハンドル操作によるノイズは、(A) 路面からのノイズと (C) ドリフトによるノイズとは違い、ユーザがペダリング等で発生させるノイズであり、個人差や走行状況に左右される。3 軸加速度センサは (A) 路面からのノイズと (B) ハンドル操作によるノイズの影響を受け、3 軸ジャイロセ


*1 実際には、3.2.2 節で議論するように時間窓同士に重なりがあるスライドウィンドウ方式をとる



(a) X 軸の値.




(b) Y 軸の値.




(c) Z 軸の値.


図 4: 直進時の加速度センサ値の周波数分布.



(a) X 軸の値.



(b) Y 軸の値.



(c) Z 軸の値.

図 5: 蛇行運転時の加速度センサ値の周波数分布.

ンサは (A) 路面からのノイズと (B) ハンドル操作によるノイズと (C) ドリフトによるノイズの影響を受けるため、各センサに適したフィルタリングに基づくノイズ低減処理を提案する。

3.1.1 3 軸加速度センサに対するフィルタリング


3 軸加速度センサは、(A) 路面からのノイズや (B) ハンドル操作によるノイズからの影響を受ける。そこで自転車のハンドル部分にスマートフォンを取り付けるとスマートフォンの搭載の 3 軸加速度センサが、どのようなノイズの影響を受けるかを調べるための予備実験を行った。

予備実験では、スマートフォンを自転車のハンドル部分に取り付け、平坦な道路上をふらつかずに約 50m 直進し、そのあと同じ道路上をランダムで蛇行運転した。使用したスマートフォンは HUAWEI Mate9 [18] である (以降も同じスマートフォンを使った)。直進時の 3 軸加速度センサの値の周波数分布を図 4 に示す。ランダムで蛇行運転時の 3 軸加速度センサの周波数分布を図 5 に示す。直進時と蛇行


運転時の 3 軸加速度センサ値の周波数分布を比較すると、蛇行運転時では 0.5Hz 付近でピークを示し次に 1.5Hz 付近でピークを示している一方、直進運転時では 1.5~2.5Hz でピークを示している (黒枠)。

このことから、(A) 路面からのノイズや (B) ハンドル操作によるノイズの周波数は共に 1.5~2.5Hz、右左折や蛇行運転などの自転車の方向が変わるような挙動の周波数は 0.5Hz 付近だと考えられる。(A)・(B) によるノイズの周波数 (1.5~2.5Hz) は自転車の挙動の周波数 (0.5Hz 付近) より高いため、LPF を使用することでノイズの除去が可能であると考えられる。そこで、1Hz 以上の高周波成分をノイズとして除去することとする。

続いて加速度センサの値に 1Hz をカットオフ周波数とする LPF を適用する効果を調べる予備実験を実施した。図 15 に示す実験ルートを一週し、左折時にデータに特徴が現れるか分析した。LPF として、窓関数を周波数分解能が小さくピークが目立ちやすいハミング窓、カットオ



(a) フィルタリングに基づくノイズ低減処理前.



(b) フィルタリングに基づくノイズ低減処理後.

図 6: 加速度 X 軸の時間窓毎の平均値 (時間窓の大きさ=32).

フ周波数を 1Hz と設定し、二輪車の挙動認識の手法 [1] を参考に標本数は 19 とした. X 軸の加速度センサを例にとる. 時間窓 T_i ($i = 0, 1, 2, \dots$) の大きさを 1.6 秒とすると, $t_s = 0.05$ 秒ごとにセンサの値が得られるとき, T_i の中には, 32 個の X 軸の加速度値が得られる. これらに LPF を適用すると, 同様に LPF 適用後の X 軸の加速度値が 32 個得られる. なお時間窓 T_i はスライドウィンドウ方式に従って, 50%オーバーラップさせて移動させる (3.2.2 節参照).

各時間窓 T_i に対して X 軸の加速度の平均値 $a_x(i)$ を求め, これをプロットしたグラフを図 6 に示す. ここで時間窓番号 29-33, 56-59, 99-103, 122-126 で左折している. LPF 適用前 (図 6a) では, 自転車の速度が十分にだまらないうちに左折した場合 (時間窓番号 29-33, 56-59, 99-103), 左折時のデータに特徴が現れているが, 自転車の速度が遅いまま左折した場合 (時間窓番号 122-126), 左折時のデータに特徴が現れず直進時との違いがあまりない. 一方, LPF 適用後 (図 6b) は時間窓番号 29-33, 56-59, 99-103 だけでなく, 時間窓番号 122-126 でも特徴的な形状をしており, 左折していることが分かる. 右折や停止のときも同様の傾向が見られる.

3.1.2 3 軸ジャイロセンサに対するフィルタリング

3 軸ジャイロセンサは, (A) 路面からのノイズや (B) ハンドル操作によるノイズの他に (C) ドリフトによる影響を受ける. (A) 路面からのノイズは凸凹した路面を走行することによる上下運動であるため, スマートフォンを地面と水平に取り付けた場合, ジャイロセンサ Z 軸だけに着目す






図 7: 右折時のジャイロセンサの各軸から得られる角度推移.



(a) フィルタリングに基づくノイズ低減処理前.



(b) フィルタリングに基づくノイズ低減処理後.

図 8: ジャイロセンサ Z 軸のドリフト.

れば (A) 路面からのノイズの影響を受けにくいと考えられる. しかもジャイロセンサ X 軸 Y 軸の値は, 右左折しても角度変化に大きな特徴が見られず (図 7), 自転車の挙動認識にはジャイロセンサ Z 軸を用いることにする.

そこで自転車のハンドル部分に取り付けたスマートフォン搭載のジャイロセンサ Z 軸が, どのようなノイズの影響を受けるかを調べるために予備実験を行った. まず, (C) ドリフトの影響を調べるため, スマートフォンを水平な机の上に画面を上にして放置した場合, ジャイロセンサ Z 軸がどの程度ドリフトの影響を受けるかを調べた. ドリフトの影響を確かめるにあたって, $t_s = 0.05$ 秒ごとにジャイロセンサ Z 軸から得られる角速度 $\omega_z(i)$ ($i = 0, 1, 2, \dots$) から角度の変化量 $d_z(i)$ を式 (1) のように求める [19].

$$\begin{cases} d_z(0) = 0 \\ d_z(i) = \frac{1}{2}t_s \times (\omega_z(i-1) + \omega_z(i)) \quad (i = 1, 2, \dots) \end{cases} \quad (1)$$




図 9: スライドウィンドウ方式.

表 1: 時間窓の大きさごとの挙動認識に対する F 値.

	停止	直進	右折	左折
20 サンプル	0.99	0.98	0.86	0.75
60 サンプル	1	0.98	0.9	0.91
32 サンプル	1	0.99	0.89	0.90

フィルタリングに基づくノイズ低減処理前のドリフトの様子を図 8a に示す. 水平な机の上に画面を上にしてスマートフォンを置いているのにも関わらず, 角度が増えている. 325 秒経過した時点で $t_s = 0.05$ 秒ごとの角度の変化量 $d_z(i)$ の最大値は 0.09 度であった. つまり式 (2) に示すように, 0.09 度以下の d_z を除去することでドリフトの影響を取り除けると考えられる.

$$d'_z(i) = \begin{cases} 0 & (d_z \leq 0.09) \\ d_z(i) & (d_z > 0.09) \end{cases} \quad (2)$$

次に, (B) ハンドル操作によるノイズがジャイロセンサ Z 軸にどのように影響するかを調べるために, 平坦な道路上を直進し $t_s = 0.05$ 秒ごとの自転車の方向の変化量 $d_z(i)$ を求めた. 自転車の方向の変化量 $d_z(i)$ は式 (1) を用いて算出する. 自転車走行の際にバランスをとるために行うハンドル操作は周期的であるため, 閾値 α を定め, 自転車の方向の変化量 $d_z(i)$ が α 以下だった場合, 自転車の方向は変化していないと判断することで, 角度の変化を滑らかにする. つまり式 (3) のように自転車の方向の変化量 $d_z(i)$ を算出する.

$$d'_z(i) = \begin{cases} 0 & (d_z \leq \alpha) \\ d_z(i) & (d_z > \alpha) \end{cases} \quad (3)$$

閾値 α は, 直進時の自転車の方向の変化量 $d_z(i)$ の平均値が 0.49 度であったことから, $\alpha = 0.49$ に設定した.

以上をまとめると, 式 (3) は式 (2) を含むため, 式 (3) によって角度の変化量 d'_z を求めることで (B) ハンドル操作によるノイズを低減するだけでなく, (C) ドリフトによるノイズを除去できる (図 8b).

3.2 自転車の挙動認識手法

自転車の挙動は, ユーザによって個人差があり, かつ走行状況によって異なるため, 自転車の挙動ごとに閾値を定




図 10: 時間窓毎の加速度 X 軸 Z 軸の平均値.




図 11: 時間窓毎の加速度 Y 軸の平均値.

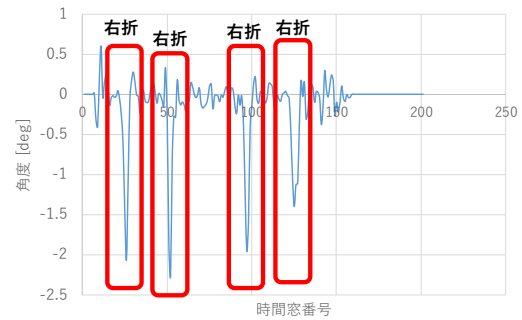


図 12: 時間窓毎のフィルタリングに基づくノイズ低減処理後のジャイロ Z 軸の平均値.




図 13: 時間窓毎のフィルタリングに基づくノイズ低減処理後のジャイロ Z 軸の正の値の個数と負の値の個数.

めて挙動を認識することはできない. よって自転車の挙動認識には, 多くの過去の走行データを分析し過去の事象から現在の状態を素早く認識できる機械学習を用いる.

機械学習には K 近傍法 [20] や SVM (Support Vector Machine)[21] などがあるが, 加速度センサの値やジャイロ

センサの値は、走行状況によって外れ値を含む場合があるため、自転車の挙動の認識には外れ値の影響を受けずに正しく認識できることが望まれる。そこで、複数の弱学習器を用いた多数決によるアンサンブル学習をするランダムフォレスト [22, 23] を用いる。機械学習により自転車の挙動を認識するにあたって、機械学習に用いる特徴量の種類と特徴量の算出方法を設定する必要がある。

3.2.1 特徴量の設計

加速度センサ X 軸・Z 軸の平均値

スマートフォンを Y 軸が進行方向になるように自転車のハンドル部分に取り付け (図 2)、図 15 で表される実験ルートを右回りに一周した。 $t_s = 0.05$ 秒ごとに加速度センサ X 軸・Y 軸・Z 軸の値が得られたとき、時間窓 $T_i = 1.6$ 秒の中の加速度 X 軸・Z 軸の平均値を図 10 に示し、時間窓 $T_i = 1.6$ 秒の中の加速度 Y 軸軸の平均値を図 11 に示す。なおセンサ値は、フィルタリングに基づくノイズ低減処理適用済みとする。また時間窓は後述するスライドウィンドウ方式とし 50% の時間をオーバーラップしている。

加速度センサ X 軸の平均値・加速度センサ Z 軸の平均値は停止時は 0 に近く、走行時は 0 を中心に周期的に値が振れるため、静止状態と走行状態を判別できると考えられる。さらに右左折するには進行方向 (本稿では Y 軸) を軸として自転車ごと身体を傾けて曲がるため、右左折時に加速度センサ X 軸・Z 軸の値に変化が見られると考えられる。図 10 では、赤枠で囲った部分で右折したことが分かる。一方、進行方向である加速度センサ Y 軸の値は、走行時に常に負の値をとっており、右折時と直進時の違いが現れない (図 11 の赤枠)。よって自転車の挙動認識には、加速度センサ Y 軸の値は用いず加速度 X 軸・Z 軸の値を用いる。

結論として、自転車の挙動を認識するには、右左折時に加速度センサ X 軸・Z 軸の平均値が必要と考えられる。

自転車の方向の変化量の平均・正の値の個数・負の個数

図 2 のように自転車にスマートフォンを設置すれば、ジャイロセンサ Z 軸の値と式 (1) を用いると自転車の方向の変化量を算出することができる。3.1.2 節の議論に基づき、自転車の方向の変化量 $d_z(i)$ にフィルタリングに基づくノイズ低減処理を適用した際、時間窓毎の自転車の方向の変化量の平均値、正の値の個数、負の値の個数を図 12 と図 13 に示す。前項と同様に、図 15 の実験ルートを右回りに一周し、センサ値を $t_s = 0.05$ 秒ごとに取得した。時間窓 $T_i = 1.6$ 秒、50% の時間をオーバーラップしたスライドウィンドウ方式とした。

自転車の方向の変化量の平均値・正の値の個数・負の値の個数は、停止時にユーザが自転車のハンドルを

動かさないと仮定すると 0 になり、右左折時に大きく値が変化するため、停止状態と直進状態と右左折状態を判別できる。

結論として、自転車の挙動を認識するには、右左折時に自転車の方向の変化量の平均値・正の値の個数・負の値の個数が必要と考えられる。

自転車の挙動認識のための特徴量

以上自転車の挙動を認識するための特徴量は

- (1) 加速度 X 軸の平均値
 - (2) 加速度 Z 軸の平均値
 - (3) 自転車の方向の変化量の平均値
 - (4) 自転車の方向の変化量の正の値の個数
 - (5) 自転車の方向の変化量の負の値の個数
- の 5 次元とするのが最適と思われる。

3.2.2 特徴量の算出方法

提案手法は、[24] を参考に、ある大きさの時間窓を移動させて時間窓毎に特徴量を算出するスライドウィンドウ方式により前項の 5 つの特徴量を算出するものとする (図 9)。この際、時間窓をどのような大きさに設定するかが大きな問題となる。

まず、情報の損失を抑え時間窓毎の特徴量の変化を滑らかにするため、隣接する時間窓をオーバーラップさせるものとする。提案手法では、[24] にない、図 9 のように、50% の時間をオーバーラップするものとした。

次に、時間窓の大きさを設定する予備実験として、1 つの時間窓の中に 20 サンプル、32 サンプル、60 サンプルを含むように時間窓を設定し、自転車の挙動を認識した。予備実験の条件は、後述する 4.1 節と同一とした。学習データとして図 15 の実験ルートを左周りに 27 周、右回りに 28 周した走行データを用い、テストデータとして右折 3 回、左折 3 回した走行データを用いた。

結果を表 1 に示す。表 1 は、自転車の 4 つの挙動に対して F 値を比較したものである (F 値の定義は 4.1 節を参照)。

時間窓の大きさが 20 サンプルの場合は、他の 2 つ (32 サンプル・60 サンプル) より F 値が低い結果となった。これは、時間窓の大きさが小さいと挙動の特徴が捉えにくくなるためである。次に、時間窓の大きさが 32 サンプルの場合と 60 サンプルの場合を比較すると、F 値はほぼ同一となる。しかしながら、時間窓の大きさを 60 サンプルに設定すると、時間窓の個数が 32 サンプルの場合と相対的に比べて少なくなる。例えば、センサから 0.05 秒ごとにデータを取得し、データ数が 1000 個になったとする。時間窓の大きさを 32 サンプルとした場合、50% (16 サンプル分) オーバーラップさせるため、時間窓の個数は 62 個となる。一方、時間窓の大きさを 60 サンプルとした場合、時間窓の個数は 33 個となり、32 サンプルの場合と比べて半分程度に減少する。そのため、一瞬のふらつきなどの細かな挙動が認識できなくなると考えられる。そこで、時間窓の大



図 14: 測定時の自転車.



図 15: 実験ルート.

きは 32 サンプル, つまり 1 つの時間窓の大きさは 0.05 秒 \times 32 = 1.6 秒に設定することにする.

4. 評価実験

提案した自転車の挙動認識手法を実データに適用し, 提案手法を評価する.

4.1 実験方法と条件

実データとしてユーザ 1 人の走行データを取得した. 実験端末は HUAWEI Mate9 [18] を使用し, センサから値を取得する間隔 $t_s = 0.05$ 秒とした. 測定時の自転車の状態を図 14 に示す. 端末の画面を上に向けて地面と水平にな




図 16: 各特微量の寄与率.




図 17: 正の値の個数の比較.

表 2: 自転車の挙動認識結果 (フィルタリングに基づくノイズ低減処理を適用しない場合).

	停止	直進	右折	左折	F 値
停止	30	7	0	0	0.87
直進	1	198	3	0	0.96
右折	0	2	13	0	0.84
左折	0	2	0	7	0.87

るように自転車のハンドル部分に取り付ける. Y 軸正の方向を進行方向として測定する. この状態で図 15 に示す実験ルートを走行した. 実験ルートは, 大田区の住宅地で, 歩道と電柱があり, 一部坂道となっている. この実験ルートを左回りと右回りに複数回走行したデータを学習データとした. 学習データから時間窓毎の特微量を算出し, 予め手でラベル付けした. テストデータは, 実験ルートとは別で用意する. 挙動認識の評価をするため, テストデータに対しても学習データと同様に手でラベル付けし, 挙動認識の結果と比較し評価する. 評価指標として F 値を用いる. F 値の式を式 (2) に示す.

$$F = \frac{2 \times Recall \times Precision}{Recall + Precision} \quad (4)$$

Recall は再現率, *Precision* は適合率を指す. 再現率とは実際に正であるデータのうち正であると識別されたデータの割合, 適合率は正と識別したデータのうち実際に正であるデータの割合のことを言う. 再現率と適合率はトレードオフの関係にあるため, これらを統合して評価できる F 値を評価指標とした.




図 18: 負の値の個数の比較.

表 3: 自転車の挙動認識結果 (フィルタリングに基づくノイズ低減処理を適用した場合).

	停止	直進	右折	左折	F 値
停止	34	3	0	0	0.96
直進	0	199	1	2	0.98
右折	0	1	14	0	0.93
左折	0	2	0	7	0.78

表 4: 8 分割交差法による正解認識率.

フィルタリングに基づく ノイズ低減処理を適用しない場合	フィルタリングに基づく ノイズ低減処理を適用した場合
0.964	0.976

4.2 フィルタリングに基づくノイズ低減処理の効果

3.1 節で提案したフィルタリングに基づくノイズ低減処理手法の効果調べるため、評価実験を行った。

4.2.1 実験条件

学習データとして、実験ルートを左回りに 5 周、右回りに 4 周した総サンプル数 1656 個の走行データを用いた。テストデータとして、左折 2 回、右折 3 回した総サンプル数 263 個の走行データを用いた。

フィルタリングに基づくノイズ低減処理前のデータは、3.1 節で説明したフィルタリングに基づくノイズ低減処理をせず、センサから得たデータをそのまま 3.2 節で説明した挙動認識手法を適用した。フィルタリングに基づくノイズ低減処理後のデータは、フィルタリングに基づくノイズ低減処理をして、フィルタリングに基づくノイズ低減処理をしたデータに挙動認識手法を適用した。

4.2.2 実験結果

フィルタリングに基づくノイズ低減処理を適用しない場合の挙動認識結果を表 2、フィルタリングに基づくノイズ低減処理を適用した場合の挙動認識結果を表 3 に示す。停止・直進・右折時の F 値はフィルタリングに基づくノイズ低減処理を適用した方が大きくなった。フィルタリングに基づくノイズ低減処理を適用した場合の結果では、左折し始めのデータの値と直進状態のデータの値が近くなったため、直進状態が左折状態と認識されることが多く、左折時の F 値がフィルタリングに基づくノイズ低減処理を適用し

表 5: 既存手法 [9] の認識結果.

	加速	等速	時計回り	反時計回り	F 値
加速	65	7	1	1	0.88
等速	6	41	0	0	0.86
時計回り	1	0	40	30	0.62
反時計回り	0	0	17	63	0.72

表 6: 自転車の挙動認識結果.

	停止	直進	右折	左折	F 値
停止	32	0	0	0	1
直進	0	232	0	1	0.99
右折	0	3	12	0	0.89
左折	0	2	0	13	0.90

ない場合より小さくなった。

フィルタリングに基づくノイズ低減処理を適用しない場合の学習データとフィルタリングに基づくノイズ低減処理を適用した場合の学習データを 8 分割交差法で評価した正解認識率を表 4 に示す。正解数を $n_{correct}$ 、総データ数を N とおくと、正解認識率 $accuracy$ は式 (5) のように表される。

$$accuracy = \frac{n_{correct}}{N} \quad (5)$$

8 分割交差法では、フィルタリングに基づくノイズ低減処理を適用した場合の方が正解認識率が良くなった。フィルタリングに基づくノイズ低減処理を適用しない場合とフィルタリングに基づくノイズ低減処理を適用した場合の各特徴量の寄与率を図 16、時間窓毎の正の値の個数の比較を図 17、負の値の個数の比較を図 18 に示す。フィルタリングに基づくノイズ低減処理を適用しない場合では時間窓毎の正の値の個数と負の値の個数ともに停止時と直進時で違いが見られないが、フィルタリングに基づくノイズ低減処理を適用した場合は停止時と直進時で違いが見られる。図 16 より、フィルタリングに基づくノイズ低減処理が各特徴量の寄与率に影響していることがわかる。フィルタリング前ではジャイロセンサ Z 軸の平均値に大きく依存しているのに対して、フィルタリング後ではジャイロセンサ Z 軸の平均値の寄与率が正の値の個数と負の値の個数に分散されている。

結果として、フィルタリングによるノイズ低減処理を適用した方が良いことが分かる。

4.3 既存手法との比較

比較手法として後藤らの手法 [9] を用い、提案手法と比較した。この手法は、スマートフォンをノイズの影響を受けにくい自転車の後輪軸横に取り付けることで、センサにフィルタリングすることなく自転車の挙動認識をする手法である。

4.3.1 実験条件

手法 [9] は、自転車の後輪軸横に設置してあるスマートフォンの 3 軸加速度センサをもとに、特徴量を算出し SVM により自転車の挙動 (加速運動・等速運動・時計回り走行・反時計回り走行) を認識している。算出する特徴量は 11 次元である。

提案手法では、学習データとして実験ルートを左回りに 27 周、右回りに 28 周した総サンプル数 8969 個の走行データを用いた。テストデータは、右折 3 回、左折 3 回した総サンプル数 295 個のデータを用いた。

4.3.2 実験結果

手法 [9] と提案手法による実験結果を表 5、表 6 に示す。手法 [9] では、加速状態と等速状態の F 値は 0.8 を超えているが、時計回り円走行と反時計回り円走行の F 値は 0.8 を超えておらず精度が悪い。一方提案手法では、4 つ全ての状態の F 値が 0.9 に近い値をとっており高い精度となった。

手法 [9] と提案手法を比べると、提案手法の方が右折 (時計回り円走行) と左折 (反時計回り円走行) の F 値が高いことが分かる。これは、スマートフォンをハンドル部分に取り付けたことで、提案手法で用いるジャイロセンサから算出する特徴量が右折時と左折時で大きく異なり、右折状態と左折状態が正確に認識できたからだと考えられる。

提案手法において、一瞬でもふらつくと、ジャイロセンサ Z 軸の値が大きく変化しやすいため実際は直進状態でも右折状態または左折状態と誤認識されやすいことが分かった。右左折状態の F 値が他の状態より低い、これは右左折し始めは特徴量の変化量が少なく、データの値が直進状態と近くなったためだと考えられる。

以上、総合して提案手法は既存手法と比較して高い精度で自転車の挙動を認識していることが分かる。

5. おわりに

本稿では、スマートフォン搭載 3 軸加速度センサと 3 軸ジャイロセンサから自転車の挙動を認識する手法を提案した。提案手法では、自転車走行する際にバランスをとるために行う周期的なハンドル操作に基づいて、3 軸加速度センサ・3 軸ジャイロセンサそれぞれに適したフィルタリングをすることで、高精度に自転車の挙動を認識した。総サンプル数 8969 個の学習データを用いて、総サンプル数 295 個のテストデータを認識したところ、4 つ全ての状態 (停止・直進・右折・左折) の F 値が 0.8 を超える高い精度となった。今後は、通常運転の他に危険運転 (急ハンドル・急ブレーキ等) を認識するアルゴリズムを開発する予定である。

参考文献

[1] 神村吏, 木谷友哉, 渡辺尚, “スマートフォン搭載の加速度センサジャイロセンサを使用した二輪車の挙動収集,” 情

報処理学会研究報告高度交通システム (ITS), vol. 2012, no. 2, pp. 1–8, 2012.

[2] Tsukasa Kamimura, Tomoya Kitani, and Daniel L Kovacs, “Automatic classification of motorcycle motion sensing data,” in *Proc. 2014 IEEE International Conference on Consumer Electronics-Taiwan (ICCE-TW)*. IEEE, 2014, pp. 145–146.

[3] 神村吏, 木谷友哉, “SVM を用いた二輪車の運転挙動分類の基礎検討,” マルチメディア, 分散協調とモバイルシンポジウム (DICOMO) 2014 論文集, vol. 2014, pp. 44–52, 2014.

[4] —, “位置情報を用いた二輪車モーションセンシングデータへの正解データ自動ラベリング手法の一提案,” 情報処理学会研究報告マルチメディア通信と分散処理 (DPS), vol. 2013, no. 6, pp. 1–6, 2013.

[5] National Police Agency, “報道発表資料,” <http://www.npa.go.jp/news/release/index.html/>.

[6] —, “自転車の定義,” <http://www.keishicho.metro.tokyo.jp/bicyclette/jmp/bicyclette.pdf>.

[7] 下山直起, 安藤輝, 山和人, 石井貴拓, 平山雅之, “マルチセンサを用いた走行解析による自転車事故防止システムの検討,” 情報処理学会研究報告システムと LSI の設計技術 (SLDM), vol. 2015, no. 51, pp. 1–6, 2015.

[8] 大井将徳, 中村嘉隆, 高橋修, “モーションセンサを用いた自転車違反運転検知システム,” 情報処理学会マルチメディア, 分散, 協調とモバイル (DICOMO2015) シンポジウム, vol. 2015, pp. 265–271, 2015.

[9] 後藤秀信, 三浦元喜, “加速度センサを使用した自転車の挙動認識,” 情報処理学会インタラクティブ 2014 論文集, vol. 2014, pp. 309–312, 2014.

[10] 仁木宏, 村上俊之, “ハンドル制御による電動自転車の走行安定化に関する一考察,” 電気学会論文誌 D (産業応用部門誌), vol. 125, no. 8, pp. 779–785, 2005.

[11] 佐口 太一, 吉田 和夫, 高橋 正樹, “自律走行自転車ロボットの安定化走行制御,” 日本機械学会論文集 C 編, vol. 73, no. 731, pp. 2036–2041, 2007.

[12] 毎日新聞, “走行中の自転車はなぜ倒れない,” <https://mainichi.jp/articles/20160501/kei/00s/00s/002000c>.

[13] 河内雄太, 田端佑介, 金田重郎, “自転車センサを用いた市街地走行環境と阻害度の測定,” 情報処理学会第 75 回全国大会講演論文集, vol. 2013, no. 1, pp. 165–166, 2013.

[14] 小花祐輔, 高橋淳二, 宇佐美格, 狐崎直文, 戸部義人, “自転車走行時の路面情報抽出: 基本検討および実測定 (モバイルアプリケーション, ユビキタスサービス, モバイル分散クラウド, モバイルアドホックネットワーク, センサネットワーク, モバイルネットワーク及び一般),” 電子情報通信学会技術研究報告. MoNA, モバイルネットワークとアプリケーション, vol. 114, no. 31, pp. 107–113, 2014.

[15] 野村智洋, 牧野友哉, 白石陽, “快適な運転支援のためのスマートフォンを用いた路面状況の推定手法の提案,” 第 75 回全国大会講演論文集, vol. 2013, no. 1, pp. 169–170, 2013.

[16] 多摩川精機, ジャイロセンサ技術. 東京電機大学出版局, 2011.

[17] Hidenobu Goto and Motoki Miura, “Examination of sensor positions to detect bicycle speeding behavior.” in *KES-IIMSS*, 2013, pp. 204–211.

[18] HUAWAI, “HUAWAI Mate 9,” <https://consumer.huawei.com/jp/phones/mate9/>.

[19] “ジャイロ (角速度) から角度の算出方法,” <https://garchiving.com/angular-from-angular-acceleration/>.

[20] Leif E Peterson, “K-nearest neighbor,” *Scholarpedia*, vol. 4, no. 2, p. 1883, 2009.

- [21] Mathias M Adankon and Mohamed Cheriet, “Support vector machine,” in *Encyclopedia of biometrics*. Springer, 2009, pp. 1303–1308.
- [22] 波部 齊, “ランダムフォレスト,” 情報処理学会研究報告 コンピュータビジョンとイメージメディア (CVIM), vol. 2012, no. 31, pp. 1–8, 2012.
- [23] Leo Breiman, “Random forests,” *Machine learning*, vol. 45, no. 1, pp. 5–32, 2001.
- [24] Bao Ling and Intille Stephen, “Activity recognition from user-annotated acceleration data,” *Pervasive Computing*, pp. 1–17, 2004.