

# 加速度センサを用いた行動計測に基づく運転動作解析手法

多田昌裕<sup>†</sup> 大村 廉<sup>†</sup> 岡田昌也<sup>†</sup>  
納谷 太<sup>†</sup> 野間春生<sup>†</sup>  
鳥山朋二<sup>†</sup> 小暮 潔<sup>†</sup>

本研究では、人と自動車の相互作用である運転動作に着目し、運転動作の一連の過程において人が体をどのように動かして自動車を操作したのかを、無線加速度センサを用いて計測する手法を提案する。提案手法は、「人の操作の結果、ハンドルがどう動いたか」ではなく「人が手をどのように動かしてハンドルを操作したのか」に着目した新しいタイプの運転動作計測手法であり、車載センサを用いる従来手法では検出が困難であった、運転動作・機器操作の過程そのものに潜む問題点の検出（適合率 76.6%、再現率 83.1%）を実現した。

## A Method for Measuring and Analyzing Driving Behavior Using 3D-Accelerometers

MASAHIRO TADA,<sup>†</sup> REN OHMURA,<sup>†</sup> MASAYA OKADA,<sup>†</sup>  
FUTOSHI NAYA,<sup>†</sup> HARUO NOMA,<sup>†</sup> TOMOJI TORIYAMA<sup>†</sup>  
and KIYOSHI KOGURE<sup>†</sup>

In this paper, focusing on driving behavior emerging from complex interactions between a driver and a vehicle, we propose a method for directly measuring and analyzing driving behavior using wireless 3D-accelerometers. Whereas existing systems installed many sensors into a specialized vehicle to indirectly measure driving behavior, our method attaches wireless 3D-accelerometers to a driver to directly measure his/her behavior in a vehicle. By directly measuring driving behavior, our method allows to point out shortcomings in vehicle operation procedure as potential causes of dangers with precision of 76.6% and recall of 83.1%.

### 1. はじめに

筆者らは、日常生活の中での人々の行動をユビキタス・センサ・ネットワークで観測し、得られたデータから人々が積み重ねている行動経験・知識を構築する研究を進めている。本研究では、移動手段として日常的に使われる機会が多い自動車の運転動作を取り上げ、運転者の車内での振舞いそのものを計測可能な手法を開発し、経験豊かな運転熟練者と初心者の技能の違いを特徴付ける動作の抽出を試みる。

運転動作は、操作客体たる自動車や周りの環境との係わり合いの中で、相互作用的に形成していくものである。そして、人はそのような相互作用から得られる知識により、自らの操作能力を向上させる。初心者のころはそのような知識が少ないため、無駄な動きが目

立っていたとしても、長く運転するうちに自分なりの操作方法の最適化をすすめ、無駄のない運転、疲れにくい運転の方法を身につけていく。

図1は、同一の自動車で同一のカーブを曲がった際の運転熟練者と初心者のハンドル捌きの違いを示したものである。熟練者、初心者ともカーブ進入後（図1左列）まずハンドルを切り（図1中央列）、一定の操舵角に達した時点でハンドルの保持に移行（図1右列）している。このとき、運転者の動作の結果どれだけハンドルが回ったのかのみに着目すると、熟練者と初心者の間に大きな差は認められない（図1右列）。しかし運転動作の結果ではなく、ハンドルを切り、その後保持するという一連の運転動作の過程に着目してみると、熟練者は適宜ハンドルを持ち替えて無理のない姿勢でハンドルを保持できているのに対し（図1右上）、初心者はハンドルをほとんど持ち替えることなく、両手を交差させた無理な姿勢のまま2秒近くハンドルを保持していた（図1右下）。

<sup>†</sup> (株) 国際電気通信基礎技術研究所 知識科学研究所  
ATR Knowledge Science Laboratories



図 1 初心者と熟練者のハンドル捌きの違い

Fig. 1 Difference in steering control behavior between a novice driver and an experienced driver

このように、たとえハンドル操舵角という運転動作の結果には差が生じなくとも、その結果に行き着くまでの運転動作の過程は、一般的には経験を重ねるうちに洗練されていく。自動車の挙動を決めているのはあくまでも人間の操作であり、経験を重ねて得られた知識（運転のコツ、洗練など）は、運転動作の結果（ハンドルの操舵角の変化量、車の挙動など）よりも運転者が体を動かして自動車を操作する一連の過程の中にこそ色濃く反映されると考えられる。図 1 に示した例のような、運転動作の結果だけを見ても推察できない、運転動作の過程に含まれる行動経験・知識を抽出するためには、運転者が車中でどのような行動をしているのかを直接的に計測する必要がある。

しかしながら、運転動作解析を扱った従来手法の大半は、運転者の動作の結果であるハンドル操舵角、アクセル開度などを操作客体たる自動車に取り付けたセンサで間接的に計測するにとどまっております。操作主体たる運転者の動作そのものを直接的に計測するという観点欠けていた。

そこで本研究では、運転動作解析のための新しいアプローチとして、運転者自身に無線加速度センサを取り付け、運転者が体をどのように動かして自動車を操作したのか、運転動作の一連の過程そのものを計測する手法を提案する。提案手法は「人の操作の結果、ハンドルがどう動いたか」ではなく「人が手をどのように動かしてハンドルを操作したのか」に着目した新しいタイプの運転動作計測手法であり、車載センサを用いる従来手法ではなしえなかった、運転動作・機器操作の過程そのものに潜む問題点（ハンドルを回す際の手の運びが不適切など）を計測することができる。この特長を活かし、本稿では様々な運転経歴を持つ人々

の運転動作を無線加速度センサで直接的に計測し、そこから行動経験・知識抽出の手がかりと考えられる初心者特有の動作（熟練者が経験を重ね、運転技能を向上させていく過程で排除した動作）の検出を試みる。

## 2. 関連研究との比較

従来、運転動作を計測するには、ハンドル操舵角センサ、アクセル/ブレーキの開度センサ、車両加速度センサ、GPS、車載カメラなど様々なセンサを搭載した特殊車両<sup>1)~5)</sup>を使用するのが常であった。これら計測専用の特殊車両の多くは、マルチモーダルなセンサ・ネットワークからの情報を統合することで、どのような場所、どのような状況下で、どのような運転操作を行なったかを体系的に記録することができる。しかしながら、従来の研究はいずれも自動車本体に取り付けたセンサで運転動作の結果を間接的に計測するにとどまっております。運転動作そのものを直接的に計測する提案手法とは大きく異なる。

運転者の情報を直接的に計測する手法としては、車載カメラを用いた視線検出<sup>6)~8)</sup>や乗員の姿勢検出<sup>9)</sup>などが提案されている。また、Mourant<sup>10)</sup>、Chapman<sup>11)</sup>、Falkmer<sup>12)</sup>らは、運転中の視線移動に着目し、運転初心者と熟練者との間にどのような差があるのかを解析している。しかしながら、本研究のように車内での運転動作の一連の過程を直接的に計測し、そこでの運転初心者と熟練者の違いを明らかにしようとした研究例は筆者らが知る限りない。

## 3. 無線加速度センサを用いた運転動作計測

運転動作そのものを計測する際、運転者に様々なデバイスの装着を強いることは、自然な動きの阻害にも

つながるため好ましくない。

被験者の動きを阻害しない計測手法としては、カメラを用いたビジョンベースの手法が一般的であるが、運転動作そのものの計測を実現するためには、走行中の環境光の急激な変化や両手の交差等に伴うオクルージョンなど様々な問題を解決する必要がある。実験室環境など限定された条件下であれば、運転者の身体各部の位置を複数の車載カメラ映像から推定する手法も提案されているが<sup>(13),14)</sup>、実環境下での有効性の検証は未だなされていない。

そこで本研究では、環境光変化やオクルージョンの影響を受けないデバイスとして、筆者らが開発した小型無線加速度センサ(図2)を用い、運転動作そのものの直接的な計測を行う。今回用いた加速度センサは、100Hzで取得した3軸加速度データをBluetoothによりPCホストへとリアルタイム無線送信することができる。また、小型軽量(36.5mm(W)×39mm(H)×10mm(D),18g)で、コードの類も一切ないため、被験者の行動をほとんど阻害せずに動作データを取得することができる。本研究では、運転動作の一連の過程において頻繁に動く部位である被験者の両手首に加速度センサを装着し、運転中の両手の動きを計測した。

加速度測定軸は、図3に示すように、10時10分の位置でハンドルを握った時、おおよそX軸がハンドル接続方向、Y軸がハンドル軸方向、Z軸がハンドル中心からみて放射状方向となるようにセットした。また、4章で述べる自動車起因ノイズ低減フィルタを生成するため、運転席のダッシュボード上にも加速度センサを設置した。



図2 小型無線加速度センサ  
Fig. 2 Wireless 3D-accelerometer

#### 4. Wavelet による自動車起因ノイズの低減

加速度センサを用いることにより、環境光変化やオクルージョンの影響は排すことができるものの、ロードノイズや車体の運動変化に伴う加速度など自動車に起因する様々なノイズの問題は依然として残る。

運転者に取り付けた加速度センサの位置(座標,向き,傾き)を正確に知ることができれば、すなわち加



図3 運転者に取り付けた加速度センサ  
Fig. 3 3D-accelerometers attached to a driver

速度センサのローカル座標系を世界座標系に変換する行列が求めれば、車載加速度センサの出力を元に自動車に起因するノイズを完全に除去することも可能である。しかしながら、加速度センサの性質上、時々刻々と変化するセンサの位置を正確に把握することは非常に難しい。3次元超音波位置センサや関節角度センサなどと併用すれば加速度センサの位置を推定することも可能ではあるが、これらのセンサは自動車内で用いるには大掛かりで、運転者の自然な動きを阻害する恐れがある。また、これらのセンサ自体も自動車ノイズの影響を受けてしまう。

そこで本研究では、ノイズ除去を近似的に実現するため、車載加速度センサに記録された加速度(自動車に起因するノイズの原因)と同じ周波数帯をカットする wavelet フィルタを運転動作データに対して局所選択的に適用し、自動車起因ノイズの低減を試みる。

##### 4.1 Wavelet 解析

Wavelet 解析は、mother wavelet と呼ばれる関数を用いて、時間と周波数の両面から信号を分解して分析する手法であり、非常データ解析に有効であることが知られている。なお、mother wavelet  $\psi(t)$  は

$$\int_{-\infty}^{\infty} \psi(t) dt = 0, \quad \int_{-\infty}^{\infty} \psi^2(t) dt = 1, \quad (1)$$

を満たす関数の総称である<sup>15)</sup>。本研究では mother wavelet として Daubechies の wavelet 関数を用いた。Mother wavelet を  $\psi(t)$  とするとき、離散 wavelet 変換に基づく wavelet 展開係数  $d_{j,k}$  は次式で表される<sup>15)</sup>。

$$d_{j,k} = \int_{-\infty}^{\infty} \psi_{j,k}(t) x(t) dt, \quad (2)$$

$$\psi_{j,k}(t) = 2^{-j/2} \psi(2^{-j}t - k). \quad (3)$$

$d_{j,k}$  は信号  $x(t)$  の時点  $2^j k$ 、周波数レベル  $2^{-j}$  における成分を抽出したものである。

このとき、元の信号  $x(t)$  は次式の離散 wavelet 逆変換によって復元される<sup>15)</sup>。

$$x(t) = \sum_j \sum_k d_{j,k} \psi_{j,k}(t). \quad (4)$$

#### 4.2 Wavelet によるノイズ低減フィルタ

運転者に取り付けた無線加速度センサからの加速度データを  $x_{dri}(t)$ 、自動車ダッシュボードに取り付けた無線加速度センサからの加速度データを  $x_{car}(t)$  とする。また、 $x_{dri}(t)$ 、 $x_{car}(t)$  の wavelet 展開係数をそれぞれ  $d_{dri j,k}$ 、 $d_{car j,k}$  とする。

いま、時点  $2^j k$  において、自動車に起因する周波数レベル  $2^{-j}$  の加速度が生じたとする。この自動車起因の加速度の大きさは、 $x_{car}(t)$  の時点  $2^j k$ 、周波数レベル  $2^{-j}$  の成分を捉えた  $d_{car j,k}$  の絶対値の大きさに対応する。本研究では、 $x_{dri}(t)$  の時点  $2^j k$  に対して周波数レベル  $2^{-j}$  の成分を除去するフィルタを局所的に適用することで、運転者の加速度データに混入した自動車起因の加速度成分の低減を試みる。具体的には、 $d_{dri j,k}$  の値を 0 とした上で、離散 wavelet 逆変換をかける。以上の処理を数式で記述すると、以下のようになる。

$$x_{denoise}(t) = \sum_j \sum_k \delta_{j,k} d_{dri j,k} \psi_{j,k}(t), \quad (5)$$

$$\delta_{j,k} = \begin{cases} 1 & \text{if } |d_{car j,k}| < \alpha_j \\ 0 & \text{otherwise} \end{cases} \quad (6)$$

ここで  $\alpha_j$  は、時点  $2^j k$  において自動車に生じた周波数レベル  $2^{-j}$  の加速度が、車内の運転者の加速度データに無視できないノイズとして混入するかを判定する閾値である。運転者加速度センサと車載加速度センサの位置関係が不明であるため、本研究では車載加速度センサの各軸データから生成したノイズ低減フィルタ全てを、運転者加速度データの各軸に各々適用する。

ところで、運転動作によって生じる加速度と、自動車起因の加速度の周波数帯が同じであった場合、閾値  $\alpha_j$  の設定如何によっては、ノイズ低減処理により運転動作データが損なわれる恐れがある。そこで本研究では、運転動作データと自動車起因加速度データのエネルギーを周波数レベルごとに比較し、運転動作データのエネルギーが大きい周波数レベルでは  $\alpha_j$  の値を大きくするなど、できるだけ運転動作データが損なわれないよう  $\alpha_j$  の値を実験的に設定した。 $\alpha_j$  の値を自動的に決定するための方策については、7章で考察する。

Wavelet によるノイズ低減手法の適用結果の一例を図4に示す。横軸は時間 (s)、縦軸は加速度の値 (mG、ただし  $1G = 9.8m/s^2$ ) である。自動車に取り付けた加速度センサの出力を見ると、ロードノイズ(データ全域に渡る細かな上下動)、縁石を乗り越えた際の加速度(時点 112933 秒、112934 秒で生じた大きな上下方向加速度)、車両前後加速度(時点 112934 秒から

112940 秒にかけての加速度)が記録されていることが分かる。これらの自動車起因ノイズが運転者の右手に取り付けた加速度センサの出力に混入し、実際には時点 112933~112940 秒の間に運転者の右手は動いていないにも関わらず、あたかも右手が動いたかのような加速度として記録されている。自動車加速度の影響を排した運転動作加速度の真値を知ることは困難なため、ノイズ低減手法の効果を定量的に評価することは難しい。しかしながら、図4に示すように、ノイズ低減手法を適用することで自動車起因ノイズの影響をある程度低減できることがわかる。

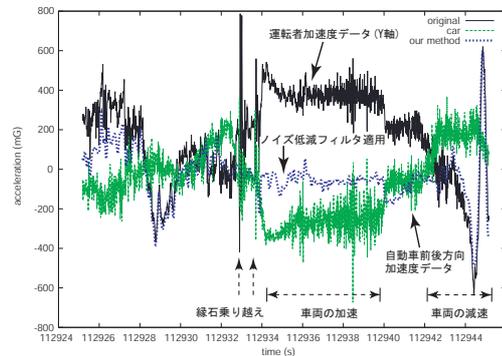


図4 自動車起因ノイズの低減  
Fig. 4 Reduction of car-caused noise

## 5. 運転動作解析

### 5.1 運転動作特徴量

本研究では、自動車に起因するノイズを低減した運転者の加速度データ(両手首につけた無線加速度センサから各々3次元、計6次元)に対して、時間方向に移動する時間窓を適用、文献<sup>16)</sup>に倣い、窓の範囲内の各加速度の平均(6次元)・分散(6次元)、加速度データ間の相関( ${}_6C_2 = 15$ 次元)を計算する。文献<sup>16)</sup>では、歩く、歯を磨くなど同じパターンが継続的に繰り返し出現する動作を識別対象としているため、窓の大きさを512サンプル分(文献<sup>16)</sup>ではサンプリング周波数76.25Hzのため6.7秒に相当)と比較的大きく設定している。しかしながら、運転動作、特に初心者の運転動作にはハンドルから急に手を離すなど突発的かつ単発的に発生するパターンが多く、時間窓を大きく設定すると、このようなパターンが埋もれてしまう恐れがある。そこで本研究では、窓の大きさを128サンプル分(本研究ではサンプリング周波数100Hzのため1.28秒に相当)と比較的小さな値に設定した。また、突発的な動作パターンがいつ発生したのかを検出

するため、窓の移動量を 10 サンプル分 (0.1 秒に相当) と細かく設定した。

文献<sup>16)</sup>では上述の特徴量に加え、Fourier 変換を用いた周波数領域特徴量を抽出しているが、非定常なデータの解析には Fourier 変換よりも wavelet 変換の方が適していることが知られている<sup>15)</sup>。そこで本研究では、次式で定義する  $D_j$  を算出し、特徴量とする。

$$D_j = \sqrt{\frac{\sum_k d_{j,k}^2 / N_j}{2^j}}. \quad (7)$$

ここで、 $d_{j,k}$  は周波数レベル  $2^{-j}$  の wavelet 展開係数、 $N_j$  は  $d_{j,k}$  の個数である。窓の大きさを 128 サンプル分としたとき、周波数レベル  $2^{-1}, \dots, 2^{-7}$  の wavelet 展開係数を得ることができるが、運転動作の解析に有用な情報が必ずしもすべての周波数レベルに含まれているわけではない。本研究では、運転動作データのエネルギーを周波数レベル別に算出、検討した結果、特にエネルギーの大きかった周波数レベル  $2^{-5}, \dots, 2^{-7}$  に関してのみ、 $D_j$  を算出 (18 次元) することとした。

以上の値 (加速度の平均・分散、加速度間の相関、 $D_j$ ) を取りまとめ、ある時点  $t$  の運転動作特徴量ベクトル  $\mathbf{x}_t$  (45 次元) とする。本研究では次元圧縮のため、抽出した運転動作特徴量ベクトル集合に主成分分析を適用した後に、以降の処理を行う。

## 5.2 初心者特有の動作の検出

運転のスタイルは人それぞれであり、理想の運転スタイルを一意に定義することは難しい。しかし、どのような運転スタイルの人であっても、一般的には経験を重ねるうちに無駄な動作や危険な動作を排除し、操作方法の最適化を進めていくと考えられる。本研究では、操作方法の最適化の過程、すなわち無駄な動作を排除していく過程の中にこそ、運転のコツなど経験から得られる知識が潜んでいると考え、計測した運転動作データから、熟練者には見られない初心者特有の動作 (経験を重ねた熟練者が排除した無駄あるいは危険な動作) の検出を試みる。

従来の教師あり学習では、すべてのデータにラベル付けを行い、同一のラベルが付与されたデータに共通のパターンを見出すことで学習を行う。しかしながら、初心者特有の動作のパターンを予め網羅的に予測、収集することは不可能に近い。

そこで本研究では、日常の運転時に起こりえる様々な状況下で、様々な運転スタイルの熟練者の運転動作を網羅的に計測し、状況・運転スタイルの多様性を考慮した通常運転動作データ集合を構築する。この通常運転動作データ集合が、熟練者の運転スタイルの多様性を十分網羅できるほど大きければ、集合に含まれな

い乖離データは、熟練者であればないであろう危険な、あるいは無駄の多い運転動作とみなすことが出来る。本研究では、通常運転動作データ集合を教師データとした 1 クラス SVM により、乖離データの検出を行う。

## 5.3 1 クラス SVM

1 クラス SVM の基本的な考え方は、次式のガウシアンカーネル  $K(\mathbf{x}, \mathbf{x}')$  を用いて写像を行うと、元の空間の乖離データは原点近くに写像されるという性質を利用し、原点と通常の運転動作データとを分けるような識別超平面を求めるというものである<sup>17)</sup>。

$$K(\mathbf{x}, \mathbf{x}') = \exp(-\gamma \|\mathbf{x} - \mathbf{x}'\|^2). \quad (8)$$

このとき識別関数は

$$f(\Phi(\mathbf{x})) = \text{sgn}(\mathbf{w}^T \Phi(\mathbf{x}) - \rho), \quad (9)$$

となる。関数  $\text{sgn}(u)$  は  $u > 0$  のときには 1、それ以外は  $-1$  となる符号関数、 $\mathbf{w}$  は重みベクトル、 $\rho$  はバイアス項である。また、 $\Phi$  は非線形な写像であり、 $\Phi$  で写像される先での内積 ( $\Phi(\mathbf{x}) \cdot \Phi(\mathbf{x}')$ ) は、元の空間で定義される  $K(\mathbf{x}, \mathbf{x}')$  の値と一致するものとする。

教師データのうち、あらかじめ決められた割合  $\nu \in (0, 1]$  のデータが原点側に残る (乖離データとされる) ような識別超平面を求めするために、以下の問題を解き、重みベクトル  $\mathbf{w}$  を求める。

$$\min \frac{1}{2} \|\mathbf{w}\|^2 + \frac{1}{\nu N} \sum_{i=1}^N \xi_i - \rho$$

$$\text{subject to } \mathbf{w}^T \Phi(\mathbf{x}_t) \geq \rho - \xi_i, \quad \xi_i \geq 0.$$

ここで、 $\xi_i$  はスラック変数である。

教師データは熟練運転者の動作のみで構成されているため、そのうちの極少数のみを乖離データとみなすような識別超平面を求め、本研究では、 $\nu = 0.0001$  とし、教師データの 0.01% のみが乖離データとなるように設定した。また、カーネルパラメータ  $\gamma$  の値は実験的に  $\gamma = 0.3$  とした。

## 6. 実験と結果

本研究では、1 周約 600m のテストコース (図 5) を設置し、各被験者にこのコースをオートマチックトランスミッション搭載の小型車で 5 周してもらい、その間の運転動作を無線加速度センサで計測した。

被験者は 20 歳代から 70 歳代までの男女 30 名 (男性 18 名、女性 12 名) である。被験者の運転経歴は、長年日常的に車を運転しているベテランから、免許取得以来 10 年以上運転していないペーパードライバー、実験の 1 週間前に免許を取得したばかりの人まで多岐にわたる。

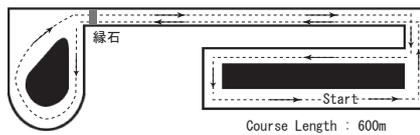


図 5 実験で使用したコース  
Fig. 5 Test course layout

本研究では、全被験者 30 名のうち長年日常的に車を運転している 15 名のデータを熟練運転動作とみなし、教師データとした。そして、残り 15 名を運転初心者とみなし、その運転動作データから初心者特有の運転動作の検出を行った。

### 6.1 ビデオを用いた初心者特有動作の目視確認

提案手法の有効性を定量的に評価するため、実験中の全被験者の運転動作を撮影したビデオを全編目視で確認し、熟練者には見られない初心者特有の運転動作がどの程度含まれているのかを調査した。なお、この調査は 8 年間無事故無違反の優良運転者によって実施された。調査の結果、初心者特有と考えられる運転動作が 59 件確認された。内訳は、両手を交差させたままなど無理/不安定な姿勢での長時間ハンドル保持が 19 件、ハンドルが全く手についていないなど不安定なハンドル捌きが 16 件、カーブ中に片手/両手を離れた例が 15 件、急なハンドル操作が 9 件である。

このうち、運転動作そのものの問題が、運転動作の結果（ハンドルの操舵角の変化量、車の挙動など）の異常として観測可能な形で表出したのは、急なハンドル操作の 9 件のみであった。残りの 50 件は、熟練者から見ると不安を禁じえない運転動作ではあるものの、今回の実験に限って言えば車の挙動に異常をきたすまでには至らなかった、いわば潜在的な事故誘因動作である。次節では、従来手法では検出が難しいこれら潜在的な事故誘因動作を、提案手法でどの程度検出できるのか検証する。

### 6.2 初心者特有動作の自動抽出結果

筆者らは、まず各被験者の両手首に取り付けた加速度センサのデータに対して自動車起因ノイズ低減フィルタを適用し、運転動作特徴量ベクトルを抽出した。抽出した運転動作特徴量ベクトル集合に主成分分析を適用したところ、累積寄与率 99% で 37 次元の主成分を得た。このうち、熟練者 15 名のデータを教師データとして、1 クラス SVM による識別超平面を構築した。

1 クラス SVM により、初心者 15 名の運転動作データからの乖離データ（熟練運転動作から乖離した動作）検出を行ったところ、64 件のデータが初心者特有の動作であると判定された。そのうち、真に初心者特有

の動作だったもの（前節のビデオ目視の結果による）は 49 件であった。つまり、検出結果の正確さの指標である適合率は 76.6% (49/64)、検出漏れの少なさの指標である再現率は 83.1% (49/59) であった。

図 6 に、提案手法によって検出された初心者特有動作の例を示す。検出例 1 の被験者は、急なカーブを曲がっている最中に、右手をハンドルから離してウィンカーの操作を行っている。ウィンカーの操作を行っている間、急カーブを右折中であるにもかかわらず 2 秒以上も左手一本でハンドル下部を持つという不安定な保持姿勢が続いた。不安定ながらハンドルの保持は続けているため、ハンドル操舵角自体には異常は現れていないものの、一歩間違えば事故になりかねない危険な動作である。

検出例 2 の被験者は、ハンドルを戻す際に手がすべり、体勢を崩してハンドルに倒れ掛かってしまった。この後、すぐに持ち直したものの、これも公道であれば事故につながりかねない危険な動作である。

検出例 3 の被験者は、両手を重ねるようにしてハンドルの同一箇所を持ち、不安定な体勢になろうとも両手を離すことなくハンドルを回し続けた。この被験者は、ハンドルを回している最中に体勢を崩しかけており、やはり危険な動作であると考えられる。

図 6 に示した動作は、ハンドル操舵角という運転動作の結果だけに着目すると問題はないように見えるが、運転動作の一連の過程そのものに着目してみると、いずれも事故につながりかねない問題を孕んでいることが分かる。運転動作そのものを直接的に計測する提案手法は、自動車の挙動として表出しない、しかし事故を誘発する危険性を孕む潜在的な事故誘因動作を 70% 以上の精度で検出することを可能とした。

## 7. 考 察

従来、人と自動車との係わり合いの計測には専ら自動車側のセンサ情報が利用されてきた。しかしながら、自動車の運転は操作それ自体が複雑であり、ハンドルを回すという運転動作ひとつとってみても、そこには各人のスタイル、習熟度、技量など、様々な知識が内在している。今回実施した実験でも、観察された初心者特有の動作 59 件のうち、50 件が自動車の挙動の変化を伴わない（自動車に搭載したセンサでは検出が難しい）潜在的な事故誘因動作であった。この結果は、複雑な操作を伴う自動車運転では、操作主体たる人の動作そのものの計測が重要であるという筆者らの主張を裏付けるものである。

本研究では、運転者の動作を計測するために無線加

## 加速度センサを用いた行動計測に基づく運転動作解析手法

検出例1: 急なカーブの途中で、右手をハンドルから離してウィンカー操作。



検出例2: ハンドルを戻す際、手がすべり姿勢を崩してハンドルに倒れ掛かる。



検出例3: 両手を重ねるようにしてハンドルの同一部位を持ち、そのまま回し続ける。



図 6 初心者特有の動作検出結果例

Fig.6 Examples of driving behaviors characteristics to novice drivers

速度センサを用いた。加速度センサは、身体への装着位置を基準点とした加速度および重力加速度を出力するだけの簡便なセンサであるが、実験の結果、加速度センサデータのみでも70%以上の精度で初心者特有の動作を検出できることを実証した。自動車運転の場合、運転者は必ず着座し、運転席に配置された機器を操作することになる。その結果、自ずと姿勢や動作の自由度が制限され、起こりうる動作パターン数も相当数減少する。このような自動車を運転するという行為に伴う自由度の制限があったため、加速度センサからの情報だけでも70%を超える検出精度を実現できたと考えられる。

同様のことが、熟練運転者の動作を集めた教師データ集合の生成にも言える。本研究では、教師データが運転スタイルの多様性を十分網羅できているという仮定の下、1クラスSVMで検出された乖離データを初心者特有の動作であるとみなしている。日常生活で人がとりうる動作パターンを網羅することは不可能に近いが、熟練者が運転席に座ってハンドルを回す動作のパターンは、動作に伴う制約ゆえに、莫大な量のデータを収集せずともある程度網羅することは可能である。今回の実験では、15人分の熟練者データを教師データ集合として70%を超える検出精度を実現したが、これも運転動作に伴う制約が良い方向に影響したからだと考えられる。運転スタイルの多様性を十分網羅するには、どれくらいの量の教師データが必要か、統計的指

標などを導入し明らかにすることが今後の課題である。

提案手法の汎用性に関して言えば、加速度センサは速度変化を伴う動きは精度よく計測できるものの、緩やかな動きはほとんど計測できない。例えば、おそるおそるハンドルから手を離すような動きを提案手法では検出することができなかった。このような動きを検出する用途では、加速度センサだけではなく、他のセンサを相互補完的に運用することが不可欠であろう。また、今回の実験は同一の車で、外乱の少ないコースを周回するという、かなり統制された環境下で実施している。そのため、車種、コース、外乱が各々異なる場合に本手法がどの程度有効か、今後慎重に検討する必要がある。

本研究では、ノイズ低減フィルタ適用の可否を決める閾値を実験的に決定したが、この処理を自動化するための方策について論じたい。いま、運転者動作データと自動車加速度データを各々wavelet変換し、時点 $2^j k$ 、周波数レベル $2^{-j}$ のwavelet展開係数 $(d_{dri j,k}, d_{car j,k})$ を得たとする。ここで、 $\lambda_{j,k} = |d_{car j,k}| / |d_{dri j,k}|$ を導入すると、時点 $2^j k$ 、周波数レベル $2^{-j}$ において、自動車加速度の影響が運転動作データに占める割合を大まかにではあるが推定することができる。 $\lambda_{j,k}$ の値がある閾値を超える部位に対しフィルタをかける $(d_{dri j,k} = 0)$ とすることで、自動車加速度の影響が大きい部位を選択的に除去することができる。自動車加速度が運転動作に与える影響のエネルギー総和は、

自動車加速度のエネルギー総和を超えることはない。そのため、閾値はフィルタで除去した成分のエネルギー総和が自動車加速度エネルギーとほぼ等しくなるような値を探索的に決定すればよい。なお、本研究では wavelet によるノイズ低減を試みたが、今後は独立成分分析など他手法の適用可能性も検証していきたい。

## 8. ま と め

本稿では、人と自動車の相互作用である運転動作に着目し、無線加速度センサにより運転動作の一連の過程を直接的に計測する手法を提案した。提案手法は「人の操作の結果、ハンドルがどう動いたか」ではなく「人が手をどのように動かしてハンドルを操作したのか」に着目した新しいタイプの運転動作計測手法であり、車載センサを用いる従来手法ではなしえなかった、運転動作・機器操作の過程そのものに潜む問題点を計測・抽出することを可能とした。

幅広い運転経歴の被験者を集めた実験では、経験から得られる知識が潜むと考えられる初心者特有の運転動作を、提案手法は適合率 76.6%、再現率 83.1%の精度で検出し、その有効性を実証した。今回の実験で観察された初心者特有動作の大半は、車の挙動に異常をきたすまでには至らない潜在的な事故誘因動作であったが、従来手法では検出が難しいこれらの動作を提案手法が検出できたということは注目すべき結果であろう。さらに、提案手法は自動車ではなく運転者自身に無線加速度センサを取り付けるため、専用車両を必要とせず、多種多様な車両への応用も容易である。

本研究では、人と自動車との係わり合いという観点から運転操作のみに着目したが、公道運転の際には人と環境との係わり合いも重要になってくる。ある状況下では妥当な運転動作でも、別の状況下では危険な運転動作になることも少なくないと考えられる。今後は、環境との係わり合いも考慮に入れ、状況認識技術と組み合わせた運転解析手法を検討していきたい。

謝辞 本研究は、情報通信研究機構の委託研究により実施したものである。

## 参 考 文 献

- 1) Oliver, N. and Pentland, A.: Graphical Models for Driver Behavior Recognition in a Smartcar, *IEEE IV2000*, pp.7-12 (2000).
- 2) 赤松幹之: 運転行動データベースの構築とアクティブセーフティ技術への利用, *自動車技術*, Vol.57, No.12, pp.34-39 (2003).
- 3) 赤松幹之: 計測用車両を用いた実路運転でのドライバー評価, *自動車技術*, Vol.58, No.12, pp.

- 53-59 (2004).
- 4) McCall, J., Achler, O. and Trivedi, M.M.: Design of an Instrumented Vehicle Testbed for Developing Human Centered Driver Support System, *IEEE IV2004*, pp.483-488 (2004).
- 5) 景山一郎, 栗谷川幸代: ドライバモニタリングカーの構築, *自動車技術*, Vol.58, No.12, pp.46-52 (2004).
- 6) Smith, P., Shah, M. and da Vitoria Lobo, N.: Monitoring Head/Eye Motion for Driver Alertness with One Camera, *ICPR2000* (2000).
- 7) Takemura, K., Ido, J., Matsumoto, Y. and Ogasawara, T.: Drive Monitoring System Based on Non-Contact Measurement System of Driver's Focus of Visual Attention, *IEEE IV2003*, pp.581-586 (2003).
- 8) Ishikawa, T., Baker, S., Matthews, I. and Kanade, T.: Passive Driver Gaze Tracking with Active Appearance Models, *ITSWC* (2004).
- 9) Trivedi, M.M., Cheng, S.Y., Childers, E. M.C. and Krotosky, S.J.: Occupant Posture Analysis with Stereo and Thermal Infrared Video: Algorithms and Experimental Evaluation, *IEEE Trans. Vehicular Technology*, Vol.53, No.6, pp.1698-1712 (2004).
- 10) Mourant, R.R. and Rockwell, T.H.: Strategies of visual search by novice and experimental drivers, *Human Factors*, Vol.14, pp.325-335 (1972).
- 11) Chapman, P.R. and Underwood, G.: Visual Search of Driving Situations: Danger and Experience, *Perception*, Vol.27, No.8, pp.951-964 (1998).
- 12) Falkmer, T. and Gregersen, N.P.: A Comparison of Eye Movement Behavior of Inexperienced and Experienced Drivers in Real Traffic Environments, *Optometry & Vision Science*, Vol.82, No.8, pp.732-739 (2005).
- 13) Stockman, G., Chen, J. L., Cui, Y. and Reynolds, H.: Measuring Body Points on Automobile Drivers Using Multiple Cameras, *Image and Vision Computing*, Vol.15, No.4, pp.317-329 (1997).
- 14) Cheng, S.Y., Park, S. and Trivedi, M.M.: Multiperspective Thermal IR and Video Arrays for 3D Body Tracking and Driver Activity Analysis, *IEEE OTCBVS* (2005).
- 15) 刈屋武昭, 矢島美寛, 田中勝人, 竹内 啓: 経済時系列の統計, 岩波書店 (2003).
- 16) Bao, L. and Intille, S.S.: Activity Recognition from User-Annotated Acceleration Data, *Pervasive*, pp.1-17 (2004).
- 17) 麻生英樹, 津田宏治, 村田 昇: パターン認識と学習の統計学, 岩波書店 (2003).