

加速度センサを用いた自動車運転時のハンドル操作分析

多田 昌裕[†], 大村 廉[†], 納谷 太[†], 野間 春生[†], 鳥山 朋二[†], 小暮 深[†]

[†]ATR 知識科学研究所

〒 619-0288 京都府「けいはんな学研都市」光台 2-2-2

従来の運転行動分析システムでは、自動車に種々のセンサを設置し、運転者の操作行動の結果、ハンドルやペダルひいては自動車がどのように動いたのかを記録している。それに対して、本研究では「人の操作の結果、ハンドルがどう動いたか」ではなく「人がハンドルをどう動かしたのか、その一連の操作過程」に着目、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ハンドルを操作したのか、運転動作そのものの過程を記録した。本研究では、様々な被験者（熟練者・ベーパードライバーを含む）の運転動作データから、各人の運転動作の癖や技量上の欠点（ハンドルを回す際の手の運びがおかしいなど）を定量的に評価・抽出する手法を開発した。

Analysis of Steering Control Behavior Using 3D-Accelerometers

Masahiro TADA[†], Ren OHMURA[†], Futoshi NAYA[†], Haruo NOMA[†], Tomoji TORIYAMA[†], Kiyoshi KOGURE[†]

[†]ATR Knowledge Science Laboratories

2-2-2 Hikaridai, Kansai Science City, Kyoto, 619-0288 Japan

In this paper, we propose a driving behavior analysis method requiring no special car in which many sensors are installed. By attaching wireless 3-D accelerometers called "B-Pack" to drivers, we can directly capture drivers' steering control behaviors: i.e. while steering angle sensors can only capture "results of driving behaviors", B-Pack can capture "processes of driving behaviors". We have developed a driving behavior analysis method to detect bad motions/characteristic motions of a driver by comparing his/her driving behavior data to that of experts' using data mining method.

1 まえがき

筆者らは、日常生活の中での我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我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、日常の移動手段として我々が何気なく使っている自動車に着目、運転技能・経歴が各々異なる様々な運転者の運転動作を計測し、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。

従来、運転動作を計測するには、各種センサを搭載した特殊車両 [1][2][3] ないしはドライブシミュレータ [4][5] のいずれかを使用するのが常であった。例えば文献 [1][2][3] では、自動車本体にハンドル操舵角センサ、アクセル/ブレーキの開度センサ、車両加速度センサなど様々なセンサを取り付け、日常運転行動を計測している。しかしながら、操作客体たる自動車本体に取り付けたセンサは、運転者の操作行動の結果を間接的に計測することは出来るが、操作主体たる運転者の操作行動そのものを直接計測することは出来ない。例えば、操舵角センサからの情報で

ハンドルの切り角がおかしいという事は知りえたとしても、運転者がどのようにハンドルを操作したから異常な切り角になったのかを知ることは出来ない。

そこで本研究では、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、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、運転動作そのものの過程を記録・解析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「人がハンドルをどう動かしたのか、その一連の操作過程」に着目した新しいタイプの運転動作分析手法であり、従来手法ではなしえなかった、運転動作・機器操作における技量上の欠点（たとえば、ハンドルを回す際の手の運びがおかしいなど）を計測・解析・抽出することができる。さらには、各人の運転動作の癖や事故につながりかねない危険な動作、熟練者との動きの違いなどの情報をフィードバックすることにより、運転技能向上を支援することができ、運転者全体の技能レベルの底上げに寄与することが期待される。

コストの面から言えば、従来手法は自動車にセンサを取り付けるため、多くの場合専用車両を用意す

る必要があり、初期導入費用はかなりの額となる。しかし、提案手法で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、初期導入費用をはるかに低く抑えることができる。

本稿では、運転動作の内、特にハンドル操作に着目し、各人のハンドルさばきの癖や欠点を定量的に評価する手法を開発した。

本稿の構成は以下の通りである。2章では、運転者に取り付けてその動作を取得するための無線加速度装置「B-Pack」について述べる。3章では、B-Packで取得した加速度データから、運転者の動作と車に起因する加速度成分（ノイズ）とを wavelet を用いて分離するための手法について述べる。4章では、運転動作加速度データから、事故につながりかねない危険な動作や各運転者の癖を抽出する手法について述べる。5章では、運転熟練者、ペーパードライバー、初心者など様々な運転者を被験者として実験を行い、提案手法の有効性を検証する。そして6章で結論を述べる。

2 小型無線加速度センサ装置「B-Pack」

本研究では、ATR で開発した小型無線加速度センサ装置「B-Pack」[6] (図1) を用いて自動車運転時の操作行動を計測する。




図1: 小型無線加速度センサ装置「B-Pack」

B-Pack は3軸加速度センサを内蔵し、100Hz で取得した加速度データを 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。B-Pack は小型軽量 (36.5mm (W) × 39mm (H) × 10mm (D), 17g) 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、被験者の両手首に B-Pack 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2に示すように、ハンドルを両手で握った時、おおよそ X 軸がハンドルを回す

向き、Y 軸が車両進行方向、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、自動車本体の加速度を計測するため、運転席のダッシュボード上にも B-Pack を設置した。




図2: 運転者に取り付けた B-Pack

3 Wavelet による自動車起因ノイズ除去

加速度センサはその性質上、運転者自身の動きだけでなく、自動車に起因する様々なノイズ（エンジン振動、地面からの突き上げ、加減速やカーブに伴う G など）も同時に計測してしまう。そこで本研究では、wavelet を利用したノイズ除去フィルタを構築し、B-Pack で取得した加速度データを運転者自身の動作を捉えた成分と、自動車に起因するノイズ成分とに分離する。

3.1 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、非定常データの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 [7]。Mother wavelet としては様々なものが提案されているが、本研究では 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 [7]。

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

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

$d_{j,k}$ 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 [7].

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

3.2 Wavelet によるノイズフィルタ

運転者に取り付けた B-Pack 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 B-Pack 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. この時, 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を除去するには, $x_{dri}(t)$ 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ればよい. 具体的には, $d_{dri,j,k}$ の値を 0 とした上で, 離散 wavelet 逆変換すればよい. 以上の処理を数式で記述すると, 以下ようになる.

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

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

ここで α_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ノイズとして混入するほど大きいかを判定するための閾値である.

提案ノイズ除去手法は, 運転者の加速度データすべてから一律に特定周波数を除去するのではなく, 自動車本体で測定された加速度の大きさ・周波数帯をトリガーとして局所選択的にノイズ除去を行うため, 運転者の動作データを損なうことなく, 自動車起因のノイズのみを正確に除去することが出来る.

提案ノイズ除去手法の適用結果の一例を図 3 に示す. 横軸は時間 (1×10^{-2} sec), 縦軸は加速度の値 (1×10^{-3} G) である. 自動車に取り付けた加速度センサの出力 (図 3 中の -1 G 前後に分布する実線) にはロードノイズ (データ全域に渡る細かな上下動) や縁石を乗り越えた際の加速度 (時点 112804920 で生

じた大きな上下方向加速度) が記録されており, これらの車起因の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 (薄い破線) に混入している. しかし, 提案ノイズ除去手法を適用することでこれら自動車起因のノイズはほぼ完全に分離・除去されている (太い実線) ことが分かる.




図 3: 車に起因する加速度の除去

4 運転動作解析

4.1 運転動作特徴量

本研究では, 自動車に起因するノイズを除去した運転者の加速度データ (両手首につけた B-Pack 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, 窓の範囲内での各加速度の平均・分散, および加速度データ間の相関を計算し, 運転動作特徴量ベクトル x とする. なお, 窓の大きさは 100 サンプル分 (1sec 相当), 移動量は 10 サンプル分 (0.1sec 相当) とした.

4.2 危険な運転動作の検出手法

運転のスタイルは人それぞれであり, たとえばカーブを曲がる際, 一気にハンドルをきる人もいれば, 徐々にハンドルをきっていく人もいる. しかしながら, 走行中に両手をハンドルから離すなどの危険な運転動作は, どのような運転スタイルであっても熟練者の通常運転中にはまず起こり得ない.

SVM など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, 通常の運転中にはほとんど発生しない危険な運転動作のパターンを予め網羅的に収集す

ることは不可能に近い。

そこで本研究では、危険な運転動作ではなく、普段の運転時に発生しうる動作をさまざまな運転者から収集し、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。そして、収集した通常運転動作データ集合を教師データ集合として、そこから著しく乖離したデータを危険な運転動作と判定する手法を提案する(図4)。

さまざまな運転スタイルの運転者*i*による、危険動作の起きていない時点 t_i の通常運転動作特徴量の集合を $X^+ = \{x_{i,t_i}^+\}$ とする。技量が未知の運転者*k*の時点 t における運転動作特徴量 $x_{k,t}$ が教師データ集合(通常運転のデータ集合)からどの程度乖離しているかの尺度として、乖離度を次式で定義する。

$$\text{乖離度} = \sum_i \sum_{t_i} \log(1 - \exp(-\|x_{i,t_i}^+ - x_{k,t}\|)) \quad (7)$$

ここで、 $\|x_{i,t_i}^+ - x_{k,t}\|$ は教師データ x_{i,t_i}^+ と $x_{k,t}$ の間のユークリッド距離である。この距離が大きいほど、(7)式中の $\exp()$ の値は0に近くなり、結果 $\log()$ の値も0に近くなる。逆に、教師データとの距離が近いほど $\log()$ の値は急激に $-\infty$ に近づく。つまり、さまざまな運転スタイルでの通常動作を集めた教師データ集合内の一つでも $x_{k,t}$ に近ければ、 $x_{k,t}$ は普段の運転でも発生し得る動作と考えられるので、その乖離度の値は大きな負の値をとる。反対に、 $x_{k,t}$ が通常運転動作から完全に乖離している、すなわち普段の運転では起こりえない動作であった場合には、乖離度の値は0に近くなる。

本研究では、この乖離度の値が閾値よりも0に近ければ、通常の運転動作から著しく乖離した危険運転動作と判定する。

4.3 運転動作における個人の癖の検出

危険な運転動作をすることが少ない熟練者であっても、その運転スタイルには自己流の癖が染み付いていることが少なくない。

前節で定義した乖離度の教師データを、模範的な運転をする人の運転特徴量集合に入れ替えると、各運転者の固有の癖を検出することが出来る。

5 実験と結果

本研究では、ATR敷地内に1周600mのテストコース(図5)を設置、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B-Packで計測した。




図4: 危険な運転動作の抽出手法




図5: 実験で使ったコース

被験者は20歳代から60歳代までの男女21名(男性15名、女性6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、免許取得以来ほとんど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初心者まで多岐にわたる。

まず、Waveletを利用したノイズ除去フィルタにより、各被験者の両手首に取り付けたB-Packの加速度データから自動車に起因するノイズを除去し、運転動作特徴量ベクトルを抽出した。

5.1 危険な運転動作の検出結果

本研究では、全被験者21名のうち、長年日常的に車を運転している被験者8名のデータを危険な運転動作がない通常運転動作とみなし、乖離度を算出するための教師データとした。そして、残り12名の運転動作データの乖離度を算出した。その中で、乖離度の値が特に高い値を示した危険な運転動作を図6-8に

示す。図6-8中のグラフの横軸は時間 ($1 \times 10^{-1} \text{sec}$)、縦軸は乖離度の値であり、乖離度の値が0に近いほど通常運転動作から乖離していることを示す。




図 6: 危険な運転動作の抽出例 1

運転者 A は、実験の1週間前に免許を取得したばかりの初心者である。運転者 A のデータの乖離度を算出したところ、5箇所で閾値を超える動作が抽出された。ビデオで確認したところ、最も乖離度の高かった時刻には、右カーブの途中でウィンカーを出し忘れたのに気づき、両手をハンドルから離してウィンカーに手を伸ばしていることが分かった(図6)。運転中にハンドル両手を離すという行為は言うまでもなく非常に危険である。乖離度が閾値を超えた他の4箇所でも、ビデオ確認の結果、ハンドルを回す動作が非常にぎこちないなど、危険とまでいえないまでも常とは異なる動作をしていることが分かった。なお運転者 A のビデオ確認の結果、乖離度によって抽出された場面以外では、著しく危険な運転動作は認められなかった。

運転者 B は、ここ数年全く車を運転していないパーパードライバーである。運転者 B のデータの乖離度を算出したところ、1箇所で閾値を超える動作が抽出された。ビデオで確認したところ、最も乖離度の高かった時刻には、左折後ハンドルを戻す際に右手が




図 7: 危険な運転動作の抽出例 2

すべり、体勢を崩しかけていたことが分かった(図7)。乖離度によって抽出されたこの動作は、公道上であればかなり危険である。なお運転者 B のビデオ確認の結果、乖離度によって抽出された1箇所以外では、著しく危険な運転動作は認められなかった。

運転者 C は、免許取得以来ほとんど車を運転していないパーパードライバーである。運転者 C のデータの乖離度を算出したところ、3箇所で閾値を超える動作が抽出された。ビデオで確認したところ、最も乖離度の高かった時刻には、右折時にハンドルを切りすぎ、あわててハンドルを逆方向に切っていることが分かった(図8)。これは公道上では事故につながりかねない危険な動作である。また、乖離度が閾値を超えた他の2箇所をビデオで確認したところ、ハンドルを回す動作が非常にぎこちないことが確認できた。なお運転者 C のビデオ確認の結果、乖離度によって抽出された場面以外では、著しく危険な運転動作は認められなかった。

5.2 個人の癖の検出結果

次に、前節で教師データとして用いた運転熟練者8名の内、もっとも運転が上手だと評価された熟練者のデータを模範運転データとし、残り7名の運転の

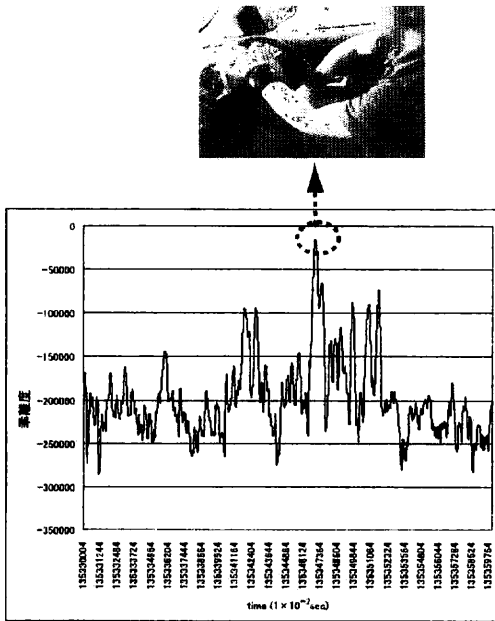


図 8: 危険な運転動作の抽出例 3




図 9: 熟練者の癖の抽出例 1

癖を評価した。

熟練運転者 D の運転動作データの乖離度を算出したところ、9 箇所で閾値を超える動作が検出された。ビデオで確認したところ、閾値を超えた 9 箇所のうち 8 箇所（適合率 89%）でハンドルを回す際、両手を大きく交差させていることが分かった（図 9）。なお、運転者 D のビデオ確認の結果、この癖が起きたのは乖離度によって検出された 8 箇所の場面のみであった（再現率 100%）。運転者 D の運転時間は 6 分 9 秒であったため、この動作を 46 秒に一度行っていることになる。また、乖離度によって検出されたこの動作は、模範運転データとした被験者のビデオでは確認できなかったため、運転者 D の癖であると考えられる。

次に、熟練運転者 E の運転動作データの乖離度を算出したところ、20 箇所で閾値を超える動作が検出された。ビデオで確認したところ、閾値を超えた 20 箇所のうち 16 箇所（適合率 80%）でカーブ中に左手がシフトレバーに伸びていた（図 10）。また、乖離度が閾値を超えた残りの 4 箇所のうち 2 箇所では、運転者 D と同様に両手を大きく交差させており、2 箇所ではコースを同乗者に確認する際に右手でジェスチャーをしていることが確認された。

運転者 E のビデオ確認の結果、左手をシフトレバーに伸ばす動作が認められたのは乖離度によって検出された場面（16 箇所）を含む全 19 箇所であった（再現率 84%）。運転者 E の運転時間は 7 分 59 秒であったため、この動作を 25 秒に一度行っていることになる。運転者 E は、普段マニュアルトランスミッション車に乗っているため、常にシフトレバーに左手を伸ばすのが癖になっていると考えられる。

次に、熟練運転者 F の運転動作データの乖離度を算出したところ、13 箇所で閾値を超える動作が検出された。ビデオで確認したところ、閾値を超えた 13 箇所のうち 8 箇所では右折の際に左手を逆手にしてハンドルを回す動作（図 11）をしていることが分かった。また、残りの 5 箇所ではハンドル下部を両手を揃えて持ち、その体勢のままハンドルを切っていたことが分かった。

運転者 F のビデオ確認の結果、ハンドルを逆手で回す動作が認められたのは、乖離度によって検出された場面（8 箇所）を含む全 10 箇所であり（再現率 80%）、右折のたびに逆手でハンドルを回すのが癖になっていることが分かる。




図 10: 熟練者の癖の抽出例 2




図 11: 熟練者の癖の抽出例 3

6 まとめ

本稿では、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、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、運転動作そのものの過程を記録・解析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「人がハンドルをどう動かしたのか、その一連の操作過程」に着目した新しいタイプの運転動作分析手法であり、「ハンドルから両手を離す」、「運転席で体勢を崩す」といった車載センサでは把握できない危険な運転動作を高精度で抽出することが可能となった。さらには、「両手を大きく交差させる」、「左手をシフトレバーに伸ばす」、「逆手でハンドルを回す」といった、運転者がハンドルを操作する際の動きの癖までをも高精度に検出できた。

提案手法は、操作主体たる運転者自身に無線加速度センサを取り付けるため、種々のセンサを搭載した特殊な車を必要とせず、非常に低コストですむ。また、操作客体に関する制限はほとんどないため、多種多様な車両（バス、トラック、重機など）を対象とした解析も簡単に実現でき、今後様々な場面での応用が期待される。

謝辞

本研究は、情報通信研究機構（NICT）の委託研究「日常行動・状況理解に基づく知識共有システムの研究開発」により実施したものである。

参考文献

- [1] 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.
- [2] 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.
- [3] N. Oliver and A. Pentland, “Graphical Models for Driver Behavior Recognition in a Smartcar,” In Proc. of IEEE Conference on Intelligent Vehicles, 2000.
- [4] 福井 勝彦, 高橋 俊道, “Study of the Performance of a Driver-vehicle System for Changing the Steering Characteristics of a Vehicle,” 豊田中央研究所 R & D レビュー, Vol.40, No.4, pp.20-25, 2005.
- [5] S. Zhai and R. Woltjer, “Human Movement Performance in Relation to Path Constraint - The Law of Steering in Locomotion -,” In Proc. of IEEE VR2003, pp.149-156, 2003.
- [6] R. Ohmura, F. Naya, H. Noma and K. Kogure, “B-Pack: Bluetooth Based Wearable Sensing Device for Nursing Activity Recognition,” In Proc.

of the International Symposium on Wireless Pervasive Computing 2006.

- [7] 刈屋, 矢島, 田中, 竹内, 経済時系列の統計, 岩波書店, 2003.
- [8] S.G. Mallat, "A theory for multiresolution signal decomposition: the wavelet representation," IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 11, Issue 7, 1989.
- [9] J.S. Walker, A Primer on Wavelets and Their Scientific Applications, CRC Press, 1999.