

プローブカーデータを用いた高速道路における自動交通異常検出

赤塚 裕人[†] 高須 淳宏[‡] 相原 健郎[‡] 安達 淳[‡]

東京大学大学院[†] 国立情報学研究所[‡]

1 はじめに

交通異常は自然災害や交通事故、故障車、道路工事等の出来事によって、車の流れが妨げられる事象のことである。交通異常が発生するとそれによって異常渋滞が発生し、経済損失や環境汚染などを引き起こす。また、災害時に発生する交通異常は緊急車両の通行を妨げるなど、さらなる被害拡大につながる恐れがある。

このような背景から、自動交通異常検出(AID: Automatic (Automated) Incident Detection) アルゴリズムに関する研究が数多く行われてきた。従来の AID アルゴリズムでは道路にあらかじめ設置されたループティテクタ等のセンサを用いて、道路上の交通量や車両密度を測定しそれを元に異常検出を行ったり、定点ビデオカメラの映像に画像処理技術を適用して事故の検出を行ったりしていた。しかし、そのようなセンサは、センサを設置した特定の道路のデータしか得る事ができず、また設置と維持に多大な費用と人員が必要であるという問題がある。

これに対して、近年車載 GPS センサから車のリアルタイムな走行データ(PCD: Probe Car Data)が得られるようになり、対費用効果の高さから従来の定点センサに変わって注目を集めている。GPS センサを搭載した車(PC: Probe Car)は道路網を動くセンサのような役割を果たすため、非常に大規模なデータを得る事ができる。

以上の点を踏まえて、本研究の目的は PCD を用いてリアルタイムに交通異常を検出することである。PCD には低コストで大規模なデータを得られるという利点があるため、それを最大限生かす事のできる交通異常検出手法を考える必要がある。これまでの PCD を用いる研究においては、平均速度や旅行時間といった速度に関係した特徴量が主に使用されている[1]。

しかし、平均速度や旅行時間は平気速度(旅行時間)が通常より遅い(長い)ことが分かったとしても、単なる渋滞が原因なのか、事故によって異常渋滞が発生しているのか区別するのが難しい。そこで、本研究では PCD から得る事ができ、個人差の影響を受けにくく、道路上の交通状態をうまく表す特徴量と、それを用いた異常検出手法を提案する。

2 提案手法

本研究で提案する特徴量は Yoon らの時間-空間的交通状態を元にして[2]。時間-空間的交通状態は時間的平均速度(TMS: Temporal Mean Speed)と空間的平均速度(SMS: Spatial Mean Speed)からなる。ある車が総距離 L の対象区間を旅行時間 T で通過したときの TMS は以下の式で定義される。

$$TMS = \frac{L}{T}$$

一方で、総距離 L の対象区間を N 個の長さ L/N の小区間に分け、ある車が i 番目の小区間を通過するのにかかった時間を t_i とするとき、SMS は以下の式で定義される。

$$SMS = \frac{\sum_{i=1}^N \frac{(L/N)}{t_i}}{N}$$

これらの特徴量には、車が停止したり減速したりする時間が長く、車がそのような状態になる小区間の割合が全体に対して小さいほど、TMS に比べて SMS が大きくなるという特徴がある。自然渋滞の場合区間全体を通して比較的遅い速度、もしくは加減速を繰り返して走行するため TMS と SMS は共に小さくなる。一方で、交通事故が発生して走行可能車線が減少した場合、事故発生地点より前では速度は大きく減少し長時間停止する事態にもなり得る。逆に事故発生地点より先では流入する車の台数が減少することで道路が空いた状態になり、ドライバーの好きな速度で走行できるようになる。そのため、交通異常発生時に対象区間を通過する車は TMS に比べて SMS が大きくなると考えられる。そこで、この TMS と SMS の差異を交通異常検出のための新たな特徴量とする。対象道路区間 X を i 番目に通過した車の TMS と SMS の差異 $dev_{i,X}$ を以下の

Automatic Incident Detection on Highway Using Probe Car Data

[†] Hiroto Akatsuka(akatsuka@nii.ac.jp)

[‡] Atsuhiro Takasu(takasu@nii.ac.jp)

[‡] Kenro Aihara(kenro.aihara@nii.ac.jp)

[‡] Jun Adachi(adachi@nii.ac.jp)

The University of Tokyo([†])

National Institute of Informatics([‡])

2-1-2 Hitotsubachi, Chiyoda-ku, Tokyo 101-8430, Japan




図 1: 特徴量ベクトル

式で定義する.

$$dev_{i,X} = \frac{|TMS_{i,X} - SMS_{i,X}|}{\sqrt{2}}$$

この特徴量は対象道路区間における車の速度の“ゆらぎ”のような指標であり道路上の交通状態を表す. 本研究では交通異常検出に以下の特徴量ベクトル $\vec{f}_{i,X}$ を用いる.

$$\vec{f}_{i,X} = (dev_{i-1,X}, dev_{i,X}, dev_{i,downX}, TMS_{i,downX})$$

ここで区間 $downX$ は区間 X の次の区間を表す. 2011年2月~2011年3月の間に首都高速渋谷線のある区間を通過したPCの \vec{f} 特徴量ベクトルをプロットしたグラフを図1に示す. 表示の関係上 $TMS_{i,downX}$ は除いてプロットしている.

交通異常発生時には対象道路区間 X におけるゆらぎが急激に大きくなり, 逆に X の次の区間 $downX$ では流入台数の減少によってゆらぎは非常に小さくなり, 速度の絶対値も大きくなると考えられる. このことはあるしきい値 d_1, d_2, d_3, v_{min} を用いて以下の式で表す事ができる.

$$dev_{i-1,X} \leq d_1 \wedge dev_{i,X} \geq d_2 \wedge dev_{i,downX} \leq d_3 \wedge TMS_{i,downX} \geq v_{min}$$

“ゆらぎ”の分布はそれぞれの道路毎に異なるため, しきい値は過去のデータから自動的に決定する必要がある. そこで, 過去のデータから得られた $dev_{i,X}$ と $dev_{i,downX}$ のリストを k-means を用いて4つにクラスタリングし, 各クラスタ重心それぞれ小さい順から $c_{1,X}, c_{2,X}, c_{3,X}, c_{4,X}, c_{1,downX}, c_{2,downX}, c_{3,downX}, c_{4,downX}$ とする. これを用いて各しきい値 $d_1 \sim d_3$ を $d_1 = (c_{2,X} + c_{3,X})/2, d_2 = c_{4,X}, d_3 = (c_{1,downX} + c_{2,downX})/2$ とする. 日本には制限速度が 50km/h の高速道路区間が存在するため $v_{min} = 50\text{km/h}$ とする.

3 評価実験

実験には 2011年2月~2011年12月のPCDと2011年中に首都高速道路で発生した表1に示す3件の事故データを使用する.

表 1 事故データ

No	日時	道路	住所
1	08/12 15:00	渋谷線上り	世田谷区
2	09/18 07:00	新宿線下り	杉並区
3	09/22 06:05	新宿線上り	港区

表 2 実験結果

	No. 1	No. 2	No. 3	Total
テスト数	32087	22410	15504	70001
誤り数	13	17	22	52
誤り率(%)	0.04	0.08	0.14	0.07

交通事故を発生から1時間後に検出してもPCDを用いる利点がない. また, ほぼ同時にPCが通過した場合, 対象区間における交通状態の変化を捉える事ができない. よって, $\vec{f}_{i,X}$ を生成し異常検出手法を適用するのは $(i-1)$ 番目と i 番目のPCの通過時刻の差が40分以下かつ3分以上の場合とする. 異常として検出された $\vec{f}_{i,X}$ は, 事故発生時刻が $(i-1)$ 番目と i 番目のPCの通過時刻の間であれば正しい, そうでなければ誤りであると判断する.

AIDの評価においては, 検出率と誤り率が一般的な指標である. しかし, 現状3件の事故データしか入手できておらず, 他の交通異常も多数発生していると考えられる. 3件の事故については全て正しく検出できたため, 本稿では検出率については言及しない. 誤り数と誤り率の実験結果を表2に示す. テスト数は $\vec{f}_{i,X}$ が生成された数である. 実験の結果から, 道路毎に提案手法の性能に差があることが分かる. 最も誤り数の多いNo.3の事故が発生した道路区間は, 都心に位置し付近に出入り口も多いため, 短いサイクルで頻繁に交通状態が変化しており, それによって不正解数も多くなったと考えられる.

4 まとめ

本稿ではPCDを用いた高速道路におけるAIDのための新しい特徴量とそれを用いた異常検出手法を提案した. 実際のPCDを用いた実験から提案手法によって高い精度で異常検出を行えることを確認した. 今後は事故データをさらに集め検出率も含め詳細に評価したい.

参考文献

- [1] Y.Li, et al., Motorway incident detection using probe vehicles, ICETransport, 2005
- [2] J.Yoon, et al., Surface street traffic estimation, MobiSys, 2007.