

# 全国規模のプロブカーデータを用いた広域的異常事象の検出手法の構築

日下部 貴彦

<sup>1</sup>正会員 東京大学講師 空間情報科学研究センター (〒277-8568 千葉県柏市柏の葉5-1-5)  
E-mail: t.kusakabe@csis.u-tokyo.ac.jp

近年、商用車プロブカーデータをはじめとした広域かつ長期間・継続的に収集された移動体データがみられるようになった。これらのデータは、動的な変化や広域な変動のデータを継続的な収集することに長けている一方で、大量かつ多次元のデータとなるためこのようなデータに含まれる特徴的な現象や異常値等を検出することは容易ではない。このような、特徴的な現象、異常値の検出は、交通システムの常時のモニタリングに必要なだけでなく、シミュレーション構築や施策評価など平常時の定常な状態のデータを峻別することが求められる場合にも必要となる。一方で、これまでのプロブカーデータを用いた以上検出手法では、ある路線や地点で発生する異常状態に着目しており、エリア規模で道路ネットワークのサービスレベルでの異常状態の検知には対応していない。そこで本研究では、本研究では、数TB規模の全国で収集された大規模なプロブカーデータに対し広域的に影響を及ぼす異常事象を検出するための方法を構築し、構築手法の検出特性についてまとめる。

**Key Words :** Probe Vehicle, OLAP, Incident detection, MRF, k-means++

## 1. はじめに

近年の自動車交通の観測では、事業車の運行管理システム<sup>1)</sup>やオンラインでのナビゲーションシステム<sup>3)</sup>、ETC2.0などの普及により、従来の車両感知器等の定点観測での観測網と比較して、より広範囲の道路ネットワークでの自動車交通のデータ収集が可能となりつつある。このような、長期間・継続的に観測された交通データには、分析者も予期していないような変動が観測されたりイベントや災害等にインシデント等、あらかじめ観測範囲を限定することが難しい現象などを観測している可能性があり、このような現象を抽出するために、可視化およびデータマイニングによる特徴抽出や異常状態の検出手法が検討されてきている<sup>4)</sup>。

これまでの交通現象の異常検出手法は、交通流を対象としたものが中心である。これらの研究では、高速道路等の地点・路線で発生する交通事故等の交通障害を迅速かつ正確に検出することを目的としている。これらの研究では、車両感知器データによる定点での速度、交通量の観測値を用いるもの<sup>5)6)8)</sup>が中心である。プロブカーなどの移動体観測による検出手法<sup>9)10)</sup>は、定点での観測機器の整備が不十分な地点でも適用可能でも適用可能である反面、交通量の情報が得られず速度や旅行時間の情報のみから推定せざるを得ないことから、検出精度・速

度に課題がある。以上に示した異常検出手法は、交通システムの常時のモニタリングおよび、事故処理等の異常への対応を念頭に、迅速な検出や発生地点の特定を念頭に設計されたものであった。

一方で、近年では、車両検知器データをはじめとした長期間・継続的な交通データの蓄積を背景として、需要の変動などの統計的なモデリング及びその変動の要因に関する分析手法<sup>11)12)</sup>も提案されている。プロブカーデータでは、より広範囲の道路ネットワークのデータ利用が可能なることから、エリア全体の道路のLOS (Level of Service) 評価の検討がなされるなど、従来の路線単位の利用だけでなく道路ネットワーク全体でのデータ活用も行われつつある<sup>13)</sup>。このような評価・分析では、評価の対象とはなる平常時の定常な状態のデータを峻別することが必要であると考えられる一方、気象災害等の影響を分析するには異常な状態の時間と空間の範囲を抽出することが求められる。しかし、大量のプロブデータからこのような異常な状態を峻別し、抽出するための手法は、これまで十分には検討されていない。例えば、Candiaら<sup>14)</sup>は、携帯電話の通話記録データ (Call detail recordデータ) による接続数のメッシュデータを用いて、異常状態の検出を行っている。神谷・布施<sup>15)</sup>では、メッシュ人口データに対して統計的異常検出手法を提案し、異常状態の抽出を行っている。プロブカーデータを用いた例では、Horiguchiら<sup>16)</sup>がエリア集

計QK 曲線を用いて、非日常的な混雑状況を持つメッシュを検出、可視化する方法を提案している。一方で、これまでの分析では、メッシュごとの異常状態を把握する方法は、提案されているものの、道路交通のサービスレベルに影響しかつ空間への広がりをもつ異常現象に、特化したものは提案されておらず、また全国規模での異常状態の抽出方法の実装には至っていない。

そこで本研究では、長期間・継続的にかつ全国的に観測されるプローブカーデータを念頭に、サービスレベルに影響しかつ空間への広がりをもつ異常事象を検出し、異常領域の抽出を行う手法を提案し、構築手法の検出特性についてまとめる。

## 2. 方法

プローブカーデータは、個々の車両の一定間隔（例えば、本研究で用いたデータでは1秒毎）の位置情報を収集していることから、全国で数万台以上の規模のデータでは、定点データと比較してデータサイズは膨大となる。本研究での広域での空間的な広がりのある異常状態の抽出では、必ずしもこのような詳細な情報が検出時に直接必要になるわけではない。そこで、計算処理に要する時間を念頭に、交通状態を表す状態量を定義したうえで、メッシュデータを作成し、異常状態検出手法を適用する。ここで状態量には、各時間帯の平均旅行時間を用いる。なお、メッシュ等の特定の集計領域内の平均的な交通状態は、Edie<sup>17)</sup>の定義を用いて集計することが可能である。交通状態を用いる指標として、平均旅行時間を用いた理由は、プローブカーのみのデータからその混入率に関わらず求められる交通状態は、速度およびその逆数の平均旅行時間であり、また、速度と比較して旅行時間の増減が利用者にとってより直接的に受容される道路のパフォーマンスであるためである。よって、本研究の検出手法では、通行実績の異常については検出できず、実勢のパフォーマンスの異常検出となることに留意されたい。

異常状態検出手法は、各メッシュの異常がある変動パターンを日ごとに検出するモデルと、このような異常の空間的な広がりを検出するモデルの二段階で構成することにより、時間的変動の異常とネットワーク上での異常の波及の双方を考慮した検出を行う。本研究では、前者の方法としてクラスタリングを用いたノンパラメトリックな異常検出手法<sup>9)</sup>を応用し、後者には、空間統計解析や画像処理の分野で活用されているマルコフ確率場モデル (MRF)<sup>18)</sup>を用いる。

### (1) メッシュデータの生成

本研究では、目下部・朝倉<sup>19)</sup>および水口ら<sup>13)</sup>でのメッ

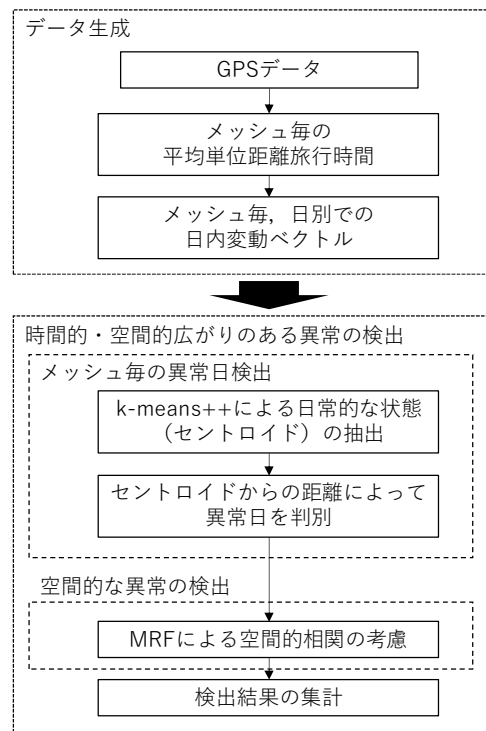


図-1 クラスタリング・MRFによる異常状態検出のながれ

シュ生成方法を用いて、各メッシュの時刻ごとのLOSを示す状態量である平均旅行時間データを作成する。

$m \in M$ をメッシュ、 $\tau$ を離散的な時刻を示す番号とし、 $i \in A_{m\tau}$ を $m$ を $\tau$ に走行した車両とする。また、この車両のメッシュ内での総走行距離を $d_i$ 、総走行時間を $t_i$ として表す。このとき、Edieの定義を用いると、平均旅行時間は、

$$T_{m\tau} = \frac{\sum_{i \in A_{m\tau}} t_i}{\sum_{i \in A_{m\tau}} d_i} \quad (1)$$

である。以上より、各時刻の平均旅行時間を求める手順は、メッシュ内に入った各車両の観測点を集計して、各車両のメッシュ内での時間帯ごとの総旅行時間 $t_i$ 、総走行距離 $d_i$ を求めたうえで、各メッシュの対象時間帯に存在するすべての車両の総旅行時間および総走行距離をそれぞれで合計し、これらの合計の商をとる手順となる。

### (2) クラスタリングによる異常検出モデル

Within-dayおよびDay-to-dayのメッシュごとの交通状態は、そのメッシュに属する道路の種別や接続関係の特性、曜日や季節、天候などの日ごとに変わる様々な要因によって決まる需要および供給側の状況に応じて変化する。このような、変化を表す関数の形状をあらかじめすべてのメッシュで定義することは容易ではないことから、パラメトリックな方法の適用は難しい。DRMが整備されており、もっとも導入が容易であると考えられる、道路の種別や接続関係の特性であっても、道路の開通や長期間の通行止めなどの情報を常にデータの取得期間と対応

したバージョンを整備するためには、一定のシステム整備が必要であるほか、このようなデータを整備できたとしても、車線運用の変更などのDRMで整理されていない情報を全国規模であらかじめ取得し整理した上で分析を行うことは難しい。一方で、大量のデータを背景として、そのメッシュごとの特性を取得データそのものから、日常を表す交通状態を表現することができれば、事前に様々な変動要因を表すデータ収集を収集することなく、Within-dayおよびDay-to-dayのメッシュごとの交通状態の変化を表現できると考えられる。そこで本研究では、平常を表す交通状態をノンパラメトリックな方法を用いて表現し、平常から外れるデータ系列を異常として峻別するアプローチをとる。

#### a) ノンパラメトリックモデルによる平常状態の抽出

本研究では、メッシュごとに各日 $k \in K$ の時間帯 $l \in L$ の平均旅行時間 $T_{m\tau(k,l)}$ を並べたベクトル

$$X_{mk} = \{T_{m\tau(k,l)} \mid l \in L\} \quad (2)$$

を定義し、このベクトルをメッシュごとにクラスタリングする。なお、クラスタリングにはk-means法の収束性とクラスタ中心（クラスタ内分散を最小化する点）の近似比を改善したk-means<sup>+</sup>法を用いる。

クラスタ数 $N(C)$ をあらかじめ定義してクラスタリングを行うことにより、各クラスタ $c \in C$ の重心

$$X_{mc} = \{T_{mcl} \mid l \in L\} \quad (3)$$

を得ることができる。

$$d_{mck} = |X_{mk} - X_{mc}| \quad (4)$$

を各日のベクトルとクラスタの重心とのユークリッド距離として定義するとき、各データの所属クラスは

$$c_{mk} = \operatorname{argmin}_{c \in C} d_{mck} \quad (5)$$

であり、この時の距離を

$$d_{mk}^* = d_{mc_{mk}} \quad (6)$$

とする。

本研究では、 $X_{mc}$ をクラスタ $c$ に属する平常な日の平均的な状態を示しているとみなし、このような日との乖離度である $d_{mk}^*$ を指標として、異常な日を検出する。

$P_m(d)$ をメッシュ $m$ で距離 $d_{mk}^*$ が $d$ よりも小さいデータの割合とするとき、ある日の平均旅行時間ベクトル $X_{mk}$ が与えられたときの検出結果は、

$$Y_{mk} = \begin{cases} 1 & \text{if } p(d_{mk}^*) \geq \alpha \\ 0 & \text{otherwise} \end{cases} \quad (7)$$

とする。ただし、 $Y_{mk} = 1$ のとき異常状態を示す。

なお、本研究の方法では、クラスタ数をあらかじめ定義する必要がある。本研究では、異常として定義する現象の割合 $\alpha$ より所属数が低くなるクラスタが現れない最大のクラスタ数を割り当てる。例えば、クラスタ数3での結果の各クラスタの所属データ数割合の最小値が6%であり、クラスタ数4でのそれが4%であった場合には、クラスタ数3の結果を用いる。

#### b) マルコフ確率場モデル (MRF) による空間的検出

aでの検出結果 $Y_{mk}$ は、各メッシュでのモデルに基づいた判定であるため、異常状態の空間的な波及の有無にかかわらず検出、非検出が判断される。したがって、空間的な波及のない異常状態が検出されることや、隣接メッシュがすべて異常状態であっても平常状態として検出されることが一定程度ありうる。よって、aでの方法のみでは、空間的な波及のある異常状態に限定して、その連続した領域を抽出することは難しい。そこで、本項の方法では、aでの検出結果をもとに空間的な広がりがある異常状態のみを検出する方法を構築する。

MRFでは、 $y_k$ を各メッシュの検出状況としたとき、

$$E(y_k) = \eta \sum_{m \in M} \delta_{mk}(y_{mk}) + \beta \sum_{(m_1, m_2) \in A} \delta(y_{m_1 k}, y_{m_2 k}) \quad (8)$$

としたとき、エネルギー関数を

$$q(y_k) \propto \exp(-E(y_k)) \quad (9)$$

で表す。 $A$ はメッシュの隣接ペアを示す集合である。また、

$$\delta_{mk}(y) = \begin{cases} 1 & \text{if } y = Y_{mk} \\ 0 & \text{otherwise} \end{cases} \quad (10)$$

$$\delta(y_1, y_2) = \begin{cases} 1 & \text{if } y_1 = y_2 \\ 0 & \text{otherwise} \end{cases} \quad (11)$$

である。式の第一項目はaとの関係を示している項であり、第二項目は平滑化項を示している。

このとき、

$$y_k^* = \operatorname{argmin}_{y_k} E(y_k) \quad (12)$$

を求めることにより空間的な検出状況考慮した検出結果を得ることができる。この結果は確率伝播法<sup>21)</sup>で求めることができる。

#### c) 検出結果の検出組の集計

上記に示した検出結果について、地理的・時間的に近傍の検出結果は、同様の事象を発端とした影響であると想定し、これらをまとめたまとめた検出組を設定する。具体的には、異常が検出された各メッシュについて8方向のいずれかのメッシュが、その異常検出の前日・当日・翌日に異常検出状態であれば、同じ検出組として扱う。また、これらの検出組について範囲や継続日数を集計することにより、事象の規模や影響具合を評価できると考えられる。

### 3. 適用例

#### (1) データの概要

本研究で用いたデータは、(株)富士通交通・道路データサービスが収集したプローブカーデータである。プローブデータは、約4万7千台(2014年10月時点)の商用



車に設置されたGPS搭載のデジタルタコグラフから収集されたものであり、各車両の1秒毎の緯度・経度の情報である。ただし、ここで用いたデータは、停止時間に基づく起終点判別を行い、秘匿処理のためにそれらの起点・終点の直近を省いたデータセットとなっている。対象地域は、日本全域であり、使用したデータの収集期間は、2014/1/1~12/31の1年間である。この間のトリップ数は、延べ70,336,364トリップであり、一日あたりにすると327,923トリップ/日となった。ドット数は、133,574,067,086ドット観測されていた。

### (2) メッシュ化とデータクリーニング

2章1節で述べた方法により、メッシュデータを作成した。この際、メッシュの最小単位は、標準地域メッシュの第3次メッシュ（1メッシュあたり約1km<sup>2</sup>）とし、集計時間単位は15分とした。メッシュ処理の結果、1ドット以上の観測があったメッシュ数は、196,209メッシュであった。

これらのメッシュには、年間を通じて継続的な観測がないものや、1日のほとんどの時間帯について観測がないものも含まれる。また、隣接のメッシュがない孤立メッシュもあり、このようなメッシュは本研究の空間への広がりをもつ異常事象をあてはまるものを抽出することが難しいことから除外する必要がある。

そこで本研究では、期間中の50%以上の日に観測がありかつ平均で1日当たり6時間以上の観測があるメッシュを抽出したのち、孤立メッシュを削除するデータクリーニングを実施した。この結果、対象データは、33,941メッシュ114,968,208,399ドットが対象データとなった。これは、86.1%のデータに相当する。メッシュ当たりの平均観測日数は364.3日、観測があった日の平均観測時間は9.0時間であり、対象のメッシュではピーク時間を中心とした時間帯で十分な観測が得られている。

### (3) クラスタリングの結果

本分析では、異常と判別する事象の割合を $\alpha = 0.05$ とし、クラスタリングにおいても、所属割合が最小のクラスタで $\alpha$ を下回らない最大のクラスタ数の結果を適用する。この結果、クラスタ数は、図-2のような分布となり全体の47.3%はクラスタ数が1となった。このことはほとんどの領域で、日常的な変動パターンが1種類であることを示している。渋滞流が発生しないメッシュでは、平均旅行時間に大きな変動は生じないと考えられることから妥当な結果だと思われる。また、クラスタ数が2以上のメッシュでは平日と土休日での変動によるものや季節変動によるものが中心であると考えられる。図-3は、クラスタ数の空間分布を示したものである。北海道や東北地方では、クラスタ数が比較的大きいメッシュが多く

あり、これは雪による影響等季節的な変動が影響しているものと考えられる。また、混雑が発生する首都圏等の都市部でも多くのクラスタ数が抽出されているメッシュがあるほか、プローブカーのデータ数が少ない端部でも比較的大きなクラスタ数が観測されており、クラスタ数の分布については今後の検証が必要である。




図-2 クラスタリング数の分布

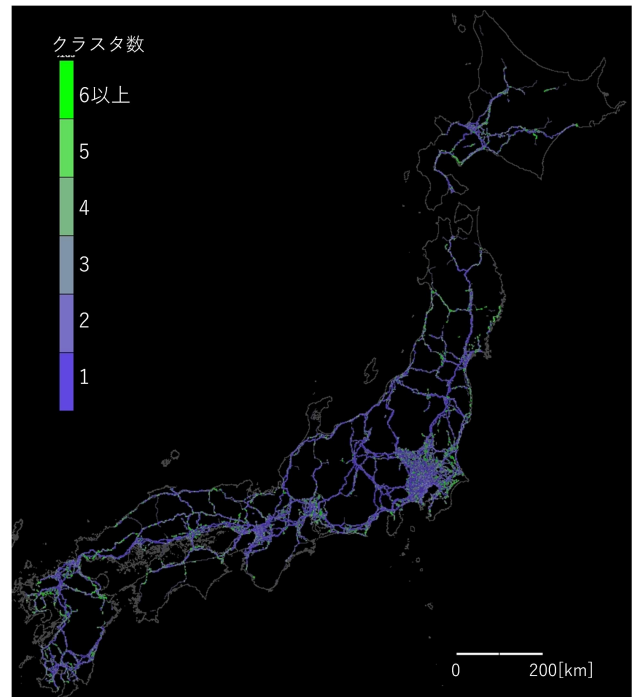


図-3 クラスタリング数の空間分布




図-4 クラスタリングによる検出組の検出期間長




図-5 クラスタリングによる検出組あたりのメッシュ数

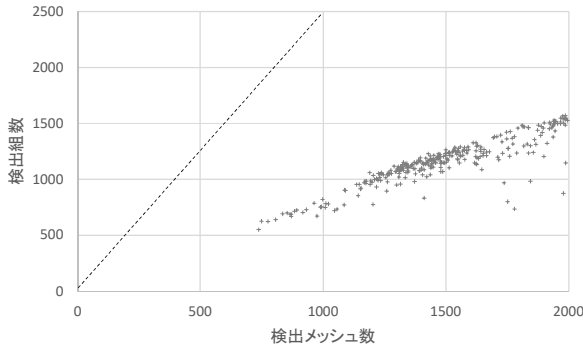


図-6 クラスタリングによる検出組数とメッシュ数の関係

クラスタリングのみから異常を抽出した結果については、検出数について図-4および図-5にまとめる。図-4は、検出組ごとの検出期間の分布、図-5はメッシュ数の分布を示している。期間中に対象の5%に当たる延べ605,477メッシュを異常として検出した。これは、341,253件の検出組となった。検出組の検出期間の80.9%は1日であり、最大値は22日であった。検知範囲の81.6%は1メッシュであり、最大値は1,619メッシュあった。図-6に各日の検出メッシュ数と検出組数の関係を示す。この図より、検出メッシュ数が少ない日は、各検出組に含まれるメッシュ数は少なく、多くなるにつれて検出組に含まれるメッシュ数が大きくなる傾向があることがわかり、多くのメッシュでの異常が検出される場合には、空間的な連なりがあり、異常検出数が少ない日には個々の現象の空間的な広がり小さいことがわかる。

以上に示したように、クラスタリングのみから検知では、1メッシュのみでの検知が大部分を占め、検知範囲が小さいものが中心に検出されていることがわかる。また、8方向のメッシュについて前日・当日・翌日を同じ検出組とすることから、延べ26メッシュ日が対象となる一方、5%(つまり1/20)が検出対象となることから、一様にランダムな単発的な異常がある場合にこれらの異常が同一の検出組として取り扱われてしまう場合がある。このような検出組では、実際には異なる異常現象にも関わらず複数日としてカウントされることから、20日間など長い検出期間が観測されてしまっていると考えられる。




図-7 クラスタリングとMRF併用による検出組の検出期間長




図-8 クラスタリングとMRF併用による検出組あたりのメッシュ数




図-9 クラスタリングとMRF併用による検出組数とメッシュ数の関係

#### (4) 空間的検出結果

本節では、前節の結果にMRFを用いて、空間的な広がりのある異常のみを検出する。なお、MRFのパラメータである $\eta$ と $\beta$ は先験的に、それぞれ8.0と1.0とした。

図-7および図-8に、各検出組の検出期間とメッシュ数の分布を示す。延べ95,431メッシュで構成される14,054件の検出組が抽出された。検出組の検出期間の88.9%は1日となり、最大値は9日となった。クラスタリングでの考察で述べたように、空間上に広がりをもたない個別の異常検出が減り、検出組として過剰にまとめてしまっていたメッシュが減ったためと考えられる。検知範囲の1メッシュのみで構成される検出組は330組のみとなり、




図-10 検出組数の日変動

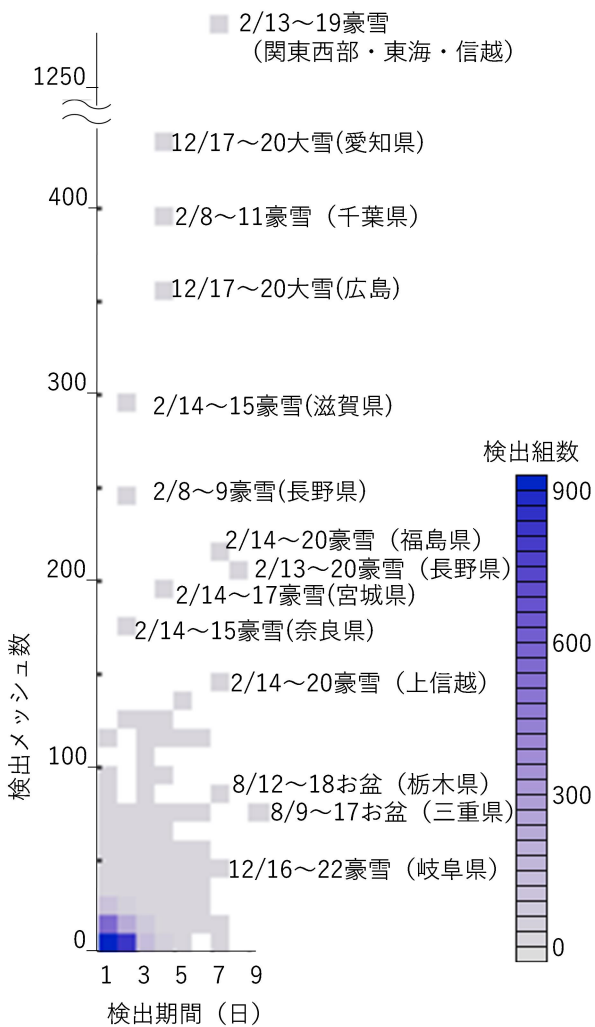


図-11 検出組あたりの検出期間とメッシュの関係

最大値は1,284メッシュとなった。図-9に各日の検出メッシュ数と検出組数の関係を示す。クラスタリングのみの場合と比較すると、検出数が大幅に減少しているほか、各検出組に含まれるメッシュ数も増加していることがわ

かる。このことより、空間的に広がりのない異常検出結果は、非検出状態となったことがうかがえる。

図-10は、日々の検出組数をそれぞれのメッシュ数毎に集計したものである。図によると、メッシュ数が1以上5未満がほとんどを占めるほか、メッシュ数が多い検出組が多く検出される日には、メッシュ数が少ない検出組の検出も増える傾向があることがわかる。また、正月、ゴールデンウィーク、お盆などの長期休暇には多くの検出が見られるほか、2月7～9日、2月14～16日、12月17～18日にかけて発生した豪雪、大雪時にも検出数が伸びていることがわかる。

図-11は、検出組のメッシュ数と検出日数の関係を示したものでこの図である。この図では、右上に向かうほど検出エリアが広く検出日数も大きくなることから重大な影響のある異常であると解釈できる。これらの結果によると、大雪、豪雪、お盆期間の交通集中によるものが比較的、期間、範囲ともに大きいことがわかる。

図-12に例として、多くのメッシュが検出された平成26年豪雪<sup>21)22)</sup>について示す。図は、2014年2月14～19日の検出結果である。平成26年豪雪では、14日から16日にかけて関東・更新を中心に記録的な積雪があった。図からは、14日に近畿地方から関東西部にかけて、15日には甲信から東北地方にかけて、異常の検出区域が移動していることが読み取れる。降雪後の17日以降は、徐々に検出範囲が狭まり、豪雪災害からの道路ネットワークの復旧状況が読み取れる。図-13はゴールデンウィークのピークである5月3日の検出状況である。各方面の高速道路の大阪、名古屋、東京の郊外部での渋滞による異常検出が顕著に見られることがわかる。図-14は、2014年11月13日に北関東地域で発生した濃霧時の検出結果を図示したものである。この図では、高速道路等にかかわらず空間的に集中した地域での検出がみられることがわかる。




図-12 豪雪時の検出結果 (2014年2月14～19日)

#### 4. まとめ

本研究では、長期間・継続的にかつ全国的に観測されるプローブカーデータを対象として、時間・空間的な影響が広がりがある異常事象を検出するための方法を構築した。プローブカーデータをEdieにて意義に基づいた平均旅行速度のメッシュとして集計したのち、それぞれのメッシュについて1日の旅行速度の変動パターンをクラスタリングすることにより、メッシュごとに非日常の変動パターンの日を検出する方法を構築した。さらに、MRFを用いて空間的な広がりのある非日常的なパター

ンを検出する方法とした。3章の分析により、提案手法による検出結果では、豪雪等の災害やお盆やGW等の長期休暇の期間の影響などが、大きな影響として現れた。また、一般道、高速道路のいずれを含むメッシュについても異常の検出があったほか、検出された異常の時間的・空間的な範囲を集計することが確認できた。3章4節の分析結果より、MRFを適用することにより、クラスタリングのみで異常検知を行う場合と比較して、空間的な広がりがある現象のみの検出ができることが確認できた。






図-13 ゴールデンウィークの検出結果 (2014年5月3日)




図-14 濃霧時の検出結果 (2014年11月13日)

謝辞：本研究で用いたプローブカーのデータは、(株)富士交通・道路データサービスより提供していただいたものである。ここに感謝の意を表します。

#### 参考文献

- 1) 宇野伸宏, 永廣悠介, 飯田恭敬, 田村博司, 中川真治：バスプローブデータを利用した所要時間信頼性評価手法の構築, 土木計画学研究・論文集, Vol.23, pp.1019-1028, 2006.
- 2) 濱島光宏：商用車プローブデータの収集と活用可能性 (特集 ビッグデータ), 交通工学, Vol.50, No.1, pp.30-33, 2015.
- 3) 太田恒平, 大重俊輔, 矢部努, 今井龍一, 井星雄貴：携帯カーナビのプローブ交通情報を活用した道路交通分析, 土木計画学研究発表会・講演集, Vol.47, 323, 2013.
- 4) 日下部貴彦, 井料隆雅, 朝倉康夫：車両検知器データを用いた交通流可視化技術の開発, 交通工学,

Vol.43, No.4, pp.59-68, 2008.

- 5) 成岡尚哉, 瀬尾亨, 日下部貴彦, 朝倉康夫：ノンパラメトリック手法による車両検知器データからの突発的ボトルネック検出法, 交通工学論文集, Vol.1, No.1, pp.11-20, 2015.
- 6) 船岡直樹, 佐藤光, 割田博, 桑原雅夫：首都高速道路における突発的ボトルネック判定手法構築に関する研究, 交通工学研究発表会論文集, Vol.29, pp.301-304, 2009.
- 7) Payne H.J. : Development and testing of incident detection algorithms, Volume 1: summary of results., *Report No. FHWA-RD-76-19*, FHWA, Washington D.C., April 1976.
- 8) Lin W.H. and Daganzo C.F. : A simple detection scheme for delay-inducing freeway incidents, *Transportation Research Part A: Policy and Practice*, Vol. 31, No. 2, pp. 141-155, 1997.
- 9) Petty. K. F., Skabardonis. A. and Varaiya. P. P. : Incident detection with probe vehicles: performance, infrastructure requirements and feasibility, *Transportation Systems 1997, A Proceedings Volume from the 8th IFAC/ IFIP/ IFORS Symposium, Chania, Greece, June 16-18, 1997*, Vol. 1, pp. 125-130, 1997.
- 10) Asakura, Y., Kusakabe, T., Nguyen, N.X. and Ushiki, T.: Incident detection methods using probe vehicles with on-board GPS equipment, *Transportation Research Part C: Emerging Technologies*, In press, 2016.
- 11) 井料隆雅, 岩谷愛理, 朝倉康夫：都市高速道路における時間帯別流入交通量の週変動分析, 第 27 回交通工学研究発表会論文報告集, pp. 173-176, 2007. .
- 12) 上田大樹, 井料隆雅, 朝倉康夫：長期 ETC 統計データによる異なるランプ間 OD 交通量と旅行時間の相関分析, 交通工学, Vol.49, No.3, pp. 43-52, 2014.
- 13) 水口正教, 日下部貴彦, 福田大輔, 朝倉康夫：プローブデータを用いたエリアレベルでの旅行時間信頼性評価, 土木計画学研究・講演集, Vol. 54, 2016.
- 14) Candia, J., Gonzalez, M. C., Wang, P., Schoenharl, T., Madey, G. and Barabasi, A. L.: Uncovering individual and collective human dynamics from mobile phone records, *Journal of Physics A: Mathematical and Theoretical*, Vol. 41, No. 22, pp. 1-11, 2008.
- 15) 神谷啓太, 布施孝志：メッシュ人口データに対するノンパラメトリックベイズに基づく統計的異常検知手法の適用可能性の検証, 土木学会論文集 D3(土木計画学), Vol.72, No.5, pp.1\_759-I\_769, 2016.
- 16) Horiguchi, R., Iijima, M. and Hanabusa, H: Traffic information provision suitable for TV broadcasting based on macroscopic fundamental diagram from Floating Car Data, *Proceedings of 13th International IEEE Conference on Intelligent Transportation Systems*, 2010.
- 17) Edie, L.: Discussion of traffic stream measurements and definitions, In Alomond, J. ed. *Proceedings of the 2nd International Symposium on the Theory of Traffic Flow*, pp. 139-154, Organisation for Economic Cooperation and Development, Paris, 1963
- 18) Besag, J.: Spatial interaction and the statistical analysis of lattice systems, *Journal of the Royal Statistical Society. Series B (Methodological)*, Vol. 36, No. 2. pp.192-236, 1974.
- 19) 日下部貴彦, 朝倉康夫：プローブカーデータのクラスタリングによる分析, 土木計画学研究・講演集,



Vol. 53, 2016.

- 20) Arthur, D. and Vassilvitskii, S.: k-means++: the advantages of careful seeding, Proceedings of the eighteenth annual ACM-SIAM symposium on Discrete algorithms. Society for Industrial and Applied Mathematics Philadelphia, PA, USA. pp. 1027–1035, 2007.
- 21) Pearl, J: Probabilistic Reasoning in Intelligent Systems: Networks of Plausible Inference (2nd ed.), Morgan Kaufmann, 1988.
- 22) 気象庁：災害時自然現象報告書 2014 年第 2 号 発達した低気圧による 2 月 13 日から 2 月 19 日の大雪、暴風雪等, 2014.

(2017.4.28 受付)

## DETECTION METHOD OF WIDE AREA INCIDENT WITH MASSIVE PROBE VEHICLE DATA

Takahiko KUSAKABE