

# 誤差修正モデル・閾値モデルを用いた 交通状態予測手法の開発・検討

宮下 明久<sup>1</sup>・井上 亮<sup>2</sup>

<sup>1</sup>学生会員 東北大学博士前期課程 大学院情報科学研究科人間社会情報科学専攻  
(〒980-8579 宮城県仙台市青葉区荒巻字青葉 6-6-06)  
E-mail:miyashita@plan.civil.tohoku.ac.jp

<sup>2</sup>正会員 東北大学准教授 大学院情報科学研究科人間社会情報科学専攻  
(〒980-8579 宮城県仙台市青葉区荒巻字青葉 6-6-06)  
E-mail:rinoue@tohoku.ac.jp

都市内の道路交通は、季節・天候・曜日・時刻による交通需要の変動や、信号の制御パターン等の影響によって複雑な様相を示す。そのため、道路交通の短期的な状態予測手法の開発は、過去数十年に渡り重要なトピックとして、盛んに研究開発が行われている。本研究は、時系列解析の分野で開発された、短期の動的な調整モデルとして有名な誤差修正モデル、及び挙動が大きく変化するデータに対してその状態変化を明示的に記述する閾値モデルを車両感知器データに対して適用・予測する手法を提案した。提案手法を沖縄県の車両感知器データに適用し、リンクごとに異なる傾向を示す交通変数の予測・分析を通して、その妥当性と有用性を確認した。

**Key Words :** *traffic forecasting, traffic sensor data, cointegration, threshold regime switching*

## 1. はじめに

都市部における道路交通渋滞は、所要時間の増加による経済的損失や排気ガス・騒音による環境への影響など様々な問題を引き起こしており、解決すべき重要な都市問題である。交通渋滞の軽減や解決に向けて幹線道路を中心に設置した車両感知器を用いた常時観測が行われており、観測されたデータは、交通管理者による交通状況の監視や管制、道路交通利用者への情報提供に活用されている。特に正確な交通状態の予測は、各種交通マネジメント施策や道路利用者への適切なルートナビゲーションへの応用が期待される、重要な研究対象の一つとして認識されている。過去20年以上に渡って交通状態を予測・モデリングする手法が開発され、1変量の時間的相関関係から多変量の時空間的相関関係を考慮したモデルに、線形性だけでなく非線形性も扱えるように拡張が行われてきた。

これらは主に、統計的な手法と非統計的な機械学習を用いた手法に大別できる。

統計的な手法では、時系列解析の枠組みで開発された Seasonal ARIMA<sup>1)</sup> (Autoregressive Integrated Moving Average) や STARIMA<sup>2)</sup> (Space-Time ARIMA) , カルマンフィルタを用いた状態空間モデル<sup>3)</sup>などが挙げられる。

一方、機械学習を用いた手法では、ニューラルネット

ワーク<sup>4)5)</sup>やノンパラメトリック回帰<sup>6)</sup>, サポートベクターマシン<sup>8)</sup>, ペイジアンネットワーク<sup>9)</sup>などがあり、それぞれの特徴を生かした開発が行われている。

その他の枠組みとして、交通流理論に基づき、境界条件から高速道や一般道における交通状態を推定する研究も行われている。多くの研究者が、セルベースまたはリンクベースのモデリング法を用いている。代表的な研究としては、Cell Transmission Model<sup>10)11)</sup>(CTM) や variational kinematic waves<sup>12)</sup>, CTM-based traffic state estimation models<sup>13)</sup>, second-order traffic flow model with kalman filter<sup>14)15)</sup>, Newell's simplified kinematic wave model<sup>16)</sup>, stochastic Newell's three-detector method<sup>17)18)</sup>などが挙げられる。

これらの膨大な研究が行われている一方で、一般道の長期間に渡る実データから、リンク間の時空間的相関関係や交通工学的要素等を全て考慮した予測手法は提案されていない。理由としては、大きく2つ考えられる。

一つ目は、都市内の道路交通が、季節や天候、曜日、時刻によって変動する需要に加え、多様な出発地・目的地を持つ様々な方向への移動、都市内に設置された信号の制御パターンなどの影響を受けるため、複雑な様相を示すことである。特に、交通流は渋滞時・非渋滞時において挙動が大きく変化することが知られており、その変動を捉えるモデルを構築することが大きな研究課題の一つである。

二つ目は、今まで提案されてきた様々な手法には、それぞれ制限や制約条件があり、それが各手法の拡張を困難にしていることである。特に一般道の車両感知器データのように時間的に継続的かつ高頻度に観測されている大規模データに対しては、予測の実行可能性を確保しつつモデルを構築することが非常に重要である。

そこで本研究では、比較的簡素なモデル構造で拡張性が高く、その構造やパラメータが解釈可能かつ交通流の複雑な挙動や時空間的な相関関係をとらえることが可能な手法が多数提案されている、時系列解析手法に着目する。そして、上記の研究課題を考慮した、より精度の高い予測モデルの構築を行う。その後、沖縄本島で取得された感知器データを用いて、典型的な挙動を示すリンクに着目し、曜日や天候などの条件毎に予測する分析を通して、提案手法の適用可能性や有用性の評価を行う。

## 2. 時系列解析手法を用いた既存研究

時系列解析分野の交通状態予測に関する代表的な既存研究として大きく4つ挙げられる。

1つ目は、Seasonal ARIMA モデル<sup>19)</sup>である。このモデルは、時間的相関を持つ時系列データを扱うために開発された線形モデルである。

2つ目は、時空間的な相関関係を扱えるようにARIMAモデルを拡張した、Space-Time ARIMA(STARIMA)モデルである。空間的相関関係を捉えるためにVARMA(vector autoregressive moving average)モデルがよく用いられるが、パラメータ数が膨大になるという問題点があった。STARIMAは、事前に空間重み行列を作成し、複数の時系列をグループ化することで、パラメータ数を大幅に削減した。Kamarianakis and Prastacos(2003)<sup>20)</sup>によれば、初めて交通流の予測に適用され、その後空間重み行列が動的に変化するモデル<sup>20)</sup>やARやMAの係数が場所ごとに異なるGeneralized STARIMAモデル<sup>21)</sup>などが提案された。

上記のモデルは、いずれも線形モデルであり、交通データに適用する際には、時系列データの空間的相関関係や渋滞時・非渋滞時で挙動が異なるという特性を考慮できないという問題がある。

3つ目は、挙動が大きく変化するデータに対してその状態変化を明示的に記述する、閾値モデル<sup>22,23)</sup>である。推定されたモデルを用いて、各状態がどのような特徴を持っているのか、状態変化がどのような形で起こっているのかなどを分析することが出来る。

4つ目は、計量経済学の分野で、先験的な経済理論をもとに推定される変数間の長期関係式を考慮したモデルとして開発された、誤差修正モデル(Error Correction model)<sup>24)</sup>である。このモデルは、多変量間の時系列相関

関係を考慮することで、短期動学的な挙動や、観測データの中にある隠れた構造の変化を捉えることができることが、経済分野での実証研究によって明らかになっている。

Ma et al. (2015)<sup>24)</sup>は、交通変数間の長期的に成り立つ関係を考慮に入れた誤差修正モデルと閾値モデルの一つである閾値共和分(Threshold Cointegration)の理論を用いた予測手法を提案した。そして、高速道の1時間間隔で観測された車両感知器データに対して、提案手法を適用し、機械学習手法として有名な多層パーセプトロンニューラルネットワークを用いたディープラーニングやサポートベクタマシンとの予測精度比較を行い、提案手法が優れていることを確認した。ただし、詳しくは後述するが、この手法はモデル構造の妥当性などに問題を有する。

本研究では、Ma et al. (2015)において用いられている誤差修正モデル・閾値モデルを用いて、渋滞が高頻度で発生する一般道における、より短い時間間隔のデータの予測に対して適用可能な手法の開発を目指す。

## 3. 共和分・誤差修正モデル・閾値モデル

### (1) 定常性 (Stationarity)

時系列モデルを構築するうえで根幹となる概念が、定常性である。定常性の仮定の下で基礎的な時系列モデルが構築され、そのモデルをもとに非定常なモデルが構築される。定常性は、同時分布や基本統計量の時間不変性に関するものであり、何を不変とするかによって、弱定常性と強定常性の2つに分類される。

ここで、ある時系列データを $y_t$ とする。時系列分析では時系列データ $y_t$ をある確率過程からの1つの実現値とみなし、それを過程と呼ぶ。弱定常性は、過程の期待値 $E(y_t)$ と分散 $Var(y_t)$ 及び自己共分散 $Cov(y_t, y_{t-k})$ が時間を通じて一定であることを要求するもので、共分散定常性とも呼ばれる。この定義は、以下のように表記できる。

$$E(y_t) = \mu, \quad Var(y_t) = \sigma^2 \\ Cov(y_t, y_{t-k}) = E[(y_t - \mu)(y_{t-k} - \mu)] = \gamma_k$$

一方、強定常性は、弱定常性の仮定に加えて、同時分布が不変であることを要求するものである。一般に、時系列解析では期待値や自己相関などの性質の分析が主な目的であり強定常性の仮定は必要としないため、単に定常性という用語は弱定常性を指すことが多い。したがって本研究でもその慣例に従って、単に定常性といった場合は、弱定常性を表すことにする。定常性を満たす時系列を定常過程、定常性を満たさない時系列を非定常過程と呼ぶ。

また、本研究で対象とする車両感知器データは、渋

滞・非滞で挙動が大きく変化するため、期待値や分散が時間依存する非定常なデータであると考えられる。

## (2) 単位根過程と見せかけの回帰

非定常なデータをモデル化する際に有用な概念が単位根過程である。原系列 $y_t$ が非定常過程であり、1階差分系列(階差系列) $\Delta y_t = y_t - y_{t-1}$ が定常過程であるとき、その過程は単位根過程(unit root process)または1次和分過程(integrated process)と呼ばれ、 $y_t \sim I(1)$ と表現する。

単位根過程に従うデータをモデル化する様々な手法が存在するが、分析を行う際には見せかけの回帰(spurious regression)と呼ばれる現象<sup>26)</sup>に注意が必要である。見せかけの回帰とは、単位根過程 $y_t$ と関係のない単位根過程 $x_t$ に回帰すると、回帰の説明力が高いように見える現象であり、この現象によって分析が意味を成さなくなってしまう可能性がある。

見せかけの回帰を回避する方法として、大きく2通りの方法がある。1つ目は、説明変数と被説明変数の(少なくともどちらか一方の)ラグ変数を回帰に含めることである。2つ目は、単位根過程に従う変数の差分をとり、定常過程にしてから解析を行うことである。差分系列を用いて分析を行う際には、過剰差分をとっていたり、この後述べる共和分という関係になっていたりするとモデルが誤って特定される可能性があるため、注意が必要である。

## (3) 共和分(Cointegration)

まず、和分過程の線形和からなる過程の性質を考える。単位根過程と定常過程の線形和によってできる過程は必ず単位根過程になるが、単位根過程同士の線形和を考えると、その結果出てくる過程は単位根過程にも定常過程にもなり得る。単位根過程の線形和が定常過程となるとき、単位根過程の間には共和分の関係が存在すると言われる<sup>26)27)</sup>。

共和分とは、単位根過程 $y_t$ と $x_t$ の間に長期的な均衡関係があり、 $ax_t + by_t$ が定常となるような $a$ と $b$ が存在することを指し、このとき $(a, b)'$ を共和分ベクトルと呼ぶ。

一例として、単位根過程に従う変数 $y_t$ と $x_t$ が共和分しており、長期的に $y_t = \alpha + \beta x_t + u_t$ の関係が成立しているとする。このとき誤差項 $u_t$ は、期待値が0であるだけでなく、 $u_t \sim I(0)$ でなければならない。なぜなら、 $u_t$ を和分の次数1以上の変数であるとすれば、 $t \rightarrow \infty$ のとき $u_t$ は発散する変数となり、 $t \rightarrow \infty$ のとき $y_t$ は $u_t$ のみによって決まり、上式は $x_t$ との関係を表さない式となるからである。例えば、 $u_t$ がランダムウォークする $I(1)$ 変数とすれば、 $t \rightarrow \infty$ のとき $\text{Var}(u_t) \rightarrow \infty$ となり、期待値0に戻るかわからない。従って、推定された長期的関係式が安定的で意味があるかどうか、つまり変数 $y_t$ と

$x_t$ の間に共和分の関係が存在するかどうかは、誤差項 $u_t$ が $u_t \sim I(0)$ つまり定常過程であるかどうかを検定することによって確認することが出来る。

単位根過程 $y_t$ と $x_t$ は個別に考えるとそれぞれの長期的な挙動を予測することは非常に難しい。しかし、 $y_t$ と $x_t$ の間に共和分の関係 $y_t = \alpha + \beta x_t + u_t$ が存在すると、 $u_t = y_t - \alpha - \beta x_t$ が定常過程となる。このとき定常過程の性質より、 $u_t$ は平均回帰的になり、 $u_t$ の長期的な挙動は一定の精度で予測できる。従って共和分は、時系列データ間の長期関係式を記述する方法を与えるため、複数の単位根過程を分析する際に非常に強力なツールとなる。

## (4) 誤差修正モデル(Error Correction Model)

単回帰モデルを例とする。 $y_t$ と $x_t$ はともに $I(1)$ であるとしたとき、もし $y_t$ と $x_t$ が共和分していなければ、 $u_t = y_t - \alpha - \beta x_t$ も $I(1)$ である。例えば、 $u_t$ がランダムウォークするならば、 $E(u_t) = 0$ であっても、期待値0から離れるといつ0に戻ってくるかわからない不安定な動きをする。ところが、 $u_t \sim I(0)$ 、即ち $y_t$ と $x_t$ が共和分の関係にあれば、 $y_t$ と $E(y_t) = \alpha + \beta x_t$ の間のエラーは大きくなり、 $u_t = y_t - E(y_t) = y_t - \alpha - \beta x_t$ が0へ向かう長期関係式への調整メカニズムが働いているはずである<sup>28)</sup>。

長期関係式を $y_t = \alpha + \beta x_t + u_t$ とするとき、典型的な誤差修正モデル ECM は $y_t$ の $t$ 時点での差分 $\Delta y_t$ を被説明変数として、次のように表す。

$$\Delta y_t = \gamma_1 \Delta x_t - \gamma (y_{t-1} - \alpha - \beta x_{t-1}) + \varepsilon_t \quad (1)$$

$$0 < \gamma < 1$$

$y_t$ と $x_t$ が同じ水準で推移する $\Delta x_t = 0$ 、 $\Delta y_t = 0$ の状態を長期とすると、式(1)は長期において、平均的に $y_t = \alpha + \beta x_t + u_t$ が成立することを表している。しかし、短期的には、 $y_{t-1} - \alpha - \beta x_{t-1} > 0$ 、即ち $y_{t-1} > \alpha + \beta x_{t-1}$ と長期的に期待される $\alpha + \beta x_{t-1}$ の水準をすでに $y_{t-1}$ が超えているとき、次の $t$ 期の $y_t$ は $y_{t-1}$ より小さくなる( $\Delta y_t < 0$ )。他方、 $y_{t-1} < \alpha + \beta x_{t-1}$ のとき、 $y_{t-1}$ は長期的に期待される $\alpha + \beta x_{t-1}$ の水準に達していないため $t-1$ 期から $t$ 期にかけての $y_t$ は $y_{t-1}$ より大きくなる( $\Delta y_t > 0$ )という誤差修正メカニズムが働くことを式(1)は表している。式(1)の $(y_{t-1} - \alpha - \beta x_{t-1})$ は誤差修正項 ECT (Error Correction Term)、 $\gamma$ は調整係数と呼ばれ、長期関係式への調整速度を表し、 $\gamma$ の値が1に近いほど調整が速やかであることを示す。 $1/\gamma$ は調整期間になる。

このように、ECMは短期不均衡モデルであり、誤差修正が完了すれば長期関係式の成立を与える<sup>29)</sup>。



### (5) 閾値モデルと閾値共和分

閾値モデル (threshold model) は、ある状態変数  $S_t$  がある閾値を超えているかどうかによって  $y_t$  が従うモデルが変化するモデルである<sup>30)</sup>。特に閾値モデルは状態 (レジーム) が離散的に変化するモデルであり、ある閾値を境に構造が大きく変化するような非線形性を持つ時系列データをモデル化するのに便利である、

閾値共和分 (threshold cointegration) は、共和分関係を持つ時系列データの中に明らかな構造変化があり、それによって長期均衡への調整速度が異なるという特徴を表現するために用いられる閾値モデルである。このモデルでは、状態変数  $S_t$  を誤差修正項 ECT の値とし、ある閾値を境に異なる ECM を推定する。この手法は、Balke and Fomby (1997)<sup>31)</sup> によってはじめて提案され、その後、Hansen and Seo (2002)<sup>32)</sup> や Cetin and Comert (2006)<sup>33)</sup> においてこの手法の妥当性や閾値の検定手法が検証されている。

ここで、閾値共和分を用いた ECM は、閾値  $\theta$  が 1 つの場合、状態変数を ECT 項の絶対値として以下の式(2)で表現することができる。

$$\begin{cases} \Delta y_t = \varphi_{01} + \gamma_{01}(y_{t-1} - \alpha - \beta x_{t-1}) + \varepsilon_t, & |y_{t-1} - \alpha - \beta x_{t-1}| < \theta \\ \Delta y_t = \varphi_{02} + \gamma_{02}(y_{t-1} - \alpha - \beta x_{t-1}) + \varepsilon_t, & |y_{t-1} - \alpha - \beta x_{t-1}| \geq \theta \end{cases} \quad (2)$$

式(2)中の上の式は ECT 項の絶対値が閾値  $\theta$  よりも小さい場合、つまり長期関係式からの逸脱度合いが小さい場合のモデルが推定される。一方下の式は、長期関係式からの逸脱度合いがある閾値  $\theta$  を基準として大きい場合のモデルが推定される。

## 4. 誤差修正モデル・閾値モデルを用いた交通状態予測手法の提案

交通流を表現する交通変数である交通量・速度・密度は、交通流理論において、様々な関係式が推定されていることから、リンクごとにその関係性は異なるが、各交通変数間に何らかの関係があることが推察される。従って、交通変数同士は共和分しているとみなすことができ、それが本研究で共和分・及び誤差修正モデルを用いる理由である。また、交通変数は、渋滞時と非渋滞時で異なる挙動を示すため、その挙動変化を的確にとらえることができればより予測精度の高い手法を開発することが可能であると考えられる。なお今回は、臨界速度によって渋滞・非渋滞を分類することが可能な「速度」を予測対象とし、交通流理論において単純な関係式が線形で表される、速度と密度の長期的な関係に着目して、モデルを構築する。

本章では、まず最初に Ma et al. (2015) の提案手法を紹介

し、その問題点を指摘する。その後、交通流理論を背景とした適切な長期関係式を推定し、渋滞・非渋滞で挙動の大きく変化するデータを精度よく予測できる誤差修正モデル及び閾値モデルを用いた新たな交通状態予測手法を提案する。

### (1) Ma et al. (2015) の提案手法

Ma et al. (2015) において提案された、TS-TVEC モデル (Time-Space Threshold Vector Error Correction Model) は、誤差修正モデル及び閾値モデルの一つである閾値共和分を用いたモデルであり以下の式(3)で表される。

$$\begin{cases} \nabla y_{01,t} = \varphi_{01} + \varphi_{10} ECT_{t-1} \\ \quad + \sum_{j=1}^2 \sum_{i=1}^p \varphi_{1i} \nabla y_{0j,t-i} \\ \quad + \sum_{l=1}^n \sum_{k=1}^3 \pi_{kl} (y_{0k,t-1} - y_{lk,t-1}) + \varepsilon_t, & |ECT_{t-1}| < \theta \\ \nabla y_{01,t} = \varphi_{02} + \varphi_{20} ECT_{t-1} \\ \quad + \sum_{j=1}^2 \sum_{i=1}^p \varphi_{2i} \nabla y_{0j,t-i} \\ \quad + \sum_{l=1}^n \sum_{k=1}^3 \pi_{kl} (y_{0k,t-1} - y_{lk,t-1}) + \varepsilon_t, & |ECT_{t-1}| \geq \theta \end{cases} \quad (3)$$

where  $ECT_{t-1} = y_{01,t-1} - \beta y_{02,t-1}$

このとき、左辺  $\nabla y_{lj,t}$  は  $t$  時点の速度の差分を表し、添え字  $l$  はリンク ( $l=0$  が予測対象リンク)、 $j$  は時系列データの種類 ( $j=1$  は速度、 $j=2$  は密度)、 $t$  は時刻である。右辺第一項は定数項、右辺第二項の  $ECT_{t-1}$  は、 $t-1$  時点の誤差修正項で、 $\varphi$  はパラメータである。右辺第三項は速度及び密度のラグ項で、 $p$  はラグ数を表す。右辺第四項は予測リンクで観測された  $t-1$  時点の各交通変数からそれに対応する前後リンクの値を引いた項であり、 $\pi_{kl}$  はパラメータ、 $n$  は前後リンク数を表す。なお、最大のラグ数は  $p=10$  とし、最適なラグ数  $p$  及び閾値  $\theta$  はグリッドサーチで求める。

このモデルにおける一番の問題点は、ECM の長期関係式 ( $y_{01,t} = \beta y_{02,t} + u_t$ ) に定数項が無く、原点を通る形で長期関係式が推定されていることである。一般に速度と密度の関係は、原点は通らず単調減少の形になる。従って、このモデルで推定された長期関係式は、交通流理論を背景にした速度と密度の関係を満たさないため、モデルが誤って推定されている可能性が高い。

また、前後リンクの情報を組み込んだ右辺第四項は、なぜ予測対象リンクの交通変数値との差分を取った形をとっているのか、渋滞時・非渋滞時で異なる挙動を示すデータに対して閾値共和分による閾値モデルを用いる妥当性、などについて十分な議論がなされていない。

以上より、本研究では、誤差修正モデルにおいて交通

流理論を背景とした適切な長期関係式を推定し、渋滞・非渋滞で挙動の大きく変化するデータを精度よく予測できる閾値モデルを用いた新たな交通状態予測手法の構築を目指す。

## (2) 適切な長期関係式の推定

共和分の定義より、単位根過程 $y_t$ と $x_t$ が共和分しているなら、 $y_t$ と $x_t$ の長期的な均衡関係は「線形和」によって表現される。しかし、交通流理論における交通変数間の長期的に成り立つ関係式は、FD(Fundamental Diagram)の関係式推定問題に帰着され、単純な線形和ではないモデルも多数提案されている<sup>34)35)36)37)</sup>。そこで本研究では、交通流理論をもとにして構築されたFDの関係式をもとに、より予測精度の高いECMを構築することを目指す。

交通流理論をもとにして交通変数間の平均速度と交通密度の関係を表す線形モデルは、Greenshields et al. (1935)<sup>38)</sup>において初めて提案された。平均速度と交通密度の時系列をそれぞれ $y_t$ 、 $x_t$ とすると、Greenshields et al. (1935)のモデルは $y_t = \alpha + \beta x_t + u_t$  ( $\alpha > 0$ ,  $\beta < 0$ ) で表される。Ma et al. (2015)では、この長期関係式は切片 $\alpha$ がない形で推定されているため、この線形モデルで長期的関係式を推定することにより、交通流理論における交通密度と平均速度が満たす最も基本的な関係を表すことができる。

## (3) 自由流・渋滞流による状態の分類

交通流は、自由流・渋滞流によってその挙動が大きく変化しており、Ma et al. (2015)における閾値共和分を用いた長期関係式からの逸脱度合いによる状態変化では、観測データ自体の構造的な変化を追うことは難しい。また、一般道のデータではK-V図上で、交通密度が低い領域では平均速度が極端に高く、交通密度が高い領域では平均速度が著しく低い傾向が見られる。従って、平均速度と交通密度の長期的な関係は、単純な線形式では、渋滞による交通流の構造の変化を考慮したモデルを構築することはできない。

そこで、速度を閾値の基準として状態を2つに分け、グリッドサーチによってRSSが最も小さくなる閾値を決定するモデルを構築する。長期的関係式は、各状態ごとに異なることが予想されるため、各状態ごとにGreenshields et al. (1935)のモデルに則り推定を行う。

以上の議論より、本研究の提案手法は、状態変数に $t-1$ 時点の平均速度 $y_{01,t-1}$ を用いた次の式(4)で表すことができる。このときECT項は、各状態 $m$ によって異なるパラメータがあらかじめ推定されている。

提案手法が一般道の複雑な交通現象を的確にとらえ、様々な時間間隔において精度良く予測可能な手法かどうかを、次章で検証する。

$$\left\{ \begin{array}{l} \nabla y_{01,t} = \varphi_{10} ECT_{1,t-1} \\ \quad + \sum_{j=1}^2 \sum_{i=1}^p \varphi_{1i} \nabla y_{0j,t-i} + \varepsilon_t, \\ \qquad \qquad \qquad y_{01,t-1} < \theta \\ \nabla y_{01,t} = \varphi_{20} ECT_{2,t-1} \\ \quad + \sum_{j=1}^2 \sum_{i=1}^p \varphi_{2i} \nabla y_{0j,t-i} + \varepsilon_t, \\ \qquad \qquad \qquad y_{01,t-1} \geq \theta \end{array} \right. \quad (4)$$

where  $ECT_{m,t-1} = y_{01,t-1} - \alpha_m - \beta_m y_{02,t-1}$ ,  
 $m = 1, 2$

## 5. 沖縄本島南部の車両感知器データへの適用

### (1) データ概要と予測対象リンクの選定

沖縄県警より提供された沖縄本島内の車両感知器による観測データを用いる。2011年6月1日から2013年9月30日までの853日間、沖縄本島南部の二次メッシュ（那覇392725、糸満392715、知念392716、与那原392726）に属するVICSリンク445本における観測結果で、5分間隔の交通量と時間平均速度が記録されている。

交通量と時間平均速度から、交通流理論における交通変数の関係式(交通量) = (平均速度) × (交通密度)を用いて交通密度を推定し、5分、15分、60分間隔のデータを作成した。交通密度の推定には空間平均速度が必要だが、車両感知器データの時間平均速度で代用している。そのため、平均速度が過大で、交通密度を過小に推定していることには注意を要する。また、曜日による車種・運転者層の違いや気象条件の違いが渋滞発生に与える影響を除外するため、平日の各曜日・土休日別、晴天時・雨天時別に区分した。なお、気象条件は、気象庁沖縄気象台那覇観測所のアメダス・時間雨量データを使用して、分析時間帯に1時間当たりの降水量が0.1mm以上の時間帯が含まれていない場合を「晴天」と定義し分析対象にした。なお、分析時間帯に1時間当たりの降水量が0.1mm以上の時間帯が含まれている場合を「雨天」と定義する。

ここで、沖縄県の車両感知器データを用いて、典型的な渋滞パターンの抽出を行った研究 Inoue et al. (2016)<sup>39)</sup>をもとに、予測対象として着目するリンクの選定を行った。着目するリンクの特徴として、渋滞が高い頻度で発生し、速度の分布が低速に偏っているリンク（2次メッシュコード392725、VICSリンク番号13）、渋滞の発生頻度が中程度で、速度の分布が高速から低速まで分布しているリンク（2次メッシュコード392725、VICSリンク番号82）、渋滞がほとんど発生せず、速度の分布が高速に偏っているリンク（2次メッシュコード392725、VICSリンク番号379）とし、これらの特徴をもとに、3つのリンクを選定

した。各リンクのFDを図-1～図-3に示す。なお、図-1～図-3では、0.01%以上の頻度があるデータ点を赤、より頻度が小さいデータ点を寒色系に着色している。

また、提案手法を適用するためには、車両感知器で観測された交通密度・平均速度の原系列が、単位根過程  $I(1)$  であることを確認する必要がある。そこで、単位根検定の代表的手法の一つである Augmented Dickey-Fuller(ADF) 検定を用いて、今回分析に用いる平均速度及び交通密度の時系列データの、原系列が非定常過程、一階差分系列(階差系列)が定常過程となることを確認する。ADF 検定は、真のモデルとして  $AR(p)$  過程を仮定し、帰無仮説を非定常過程、対立仮説を定常過程とした単位根検定である。

上記で選定した3つのリンク(リンク番号379, 82, 13)における平均速度・交通密度の時系列に対し、ADF 検定を用いた結果が表-1～3である。この結果より、すべてのリンクにおいて、原系列が有意水準10%で帰無仮説を棄却できず、階差系列が有意水準1%以下で棄却できる

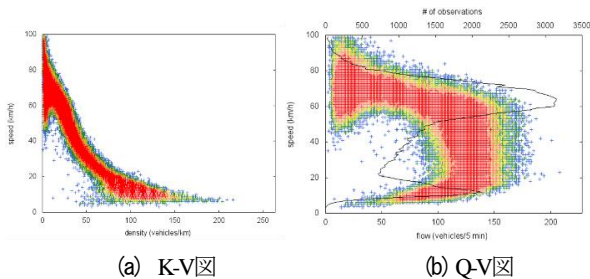


図-1 県道39号線上下りむつみ橋交差点平日・無降雨時  
(2次メッシュコード392725, VICSリンク番号379)




図-2 国道330号線上下り安里十字路平日・無降雨時  
(2次メッシュコード392725, VICSリンク番号82)

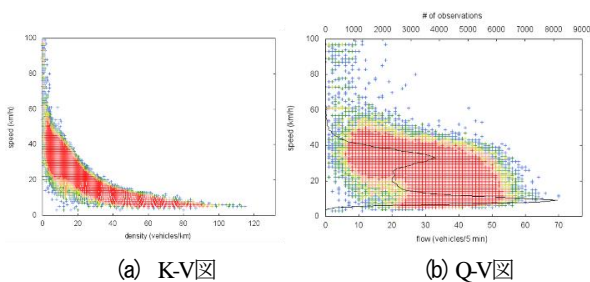


図-3 国道58号線上下り上之屋交差点平日・無降雨時  
(2次メッシュコード392725, VICSリンク番号13)

ことから、今扱う時系列データが単位根過程  $I(1)$  に従っており、提案手法を適用する際に必要な仮定を満たすことが確認できた。

(2) 提案手法の予測精度・有用性の検証

本節では、様々な分析条件における、単純なECMモデル、閾値共和分を用いたモデル、前後リンクの情報を用いたMa et al. (2015)に最も近いモデル、本研究の提案モデルの4つのモデルの予測精度の違いを比較するとともに、最適なモデルにおけるパラメータがどのように推定されているのかについて議論を行い、本研究手法の有用性を検証する。また、推定した各モデルの予測性能は、1時刻後の速度の観測値と予測値の平均二乗誤差MSE (Mean Squared Error) を用いて比較検討する。

今回は、沖縄県那覇市中心部において渋滞が最も多く発生する平日の火曜日・晴天時の45日間の5分、15分、60分間隔の観測データを対象に分析を行う。30日分をパラメータ推定に、15日分を予測に用いる。

表-1 VICSリンク番号379のADF検定結果

		平均速度		交通密度	
		原系列	階差系列	原系列	階差系列
5分 間隔	統計量	-2.391	-27.185	-2.575	-28.246
	P値	0.413	p<0.01	0.335	p<0.01
15分 間隔	統計量	-2.347	-13.719	-2.198	-15.013
	P値	0.431	p<0.01	0.495	p<0.01
60分 間隔	統計量	-2.360	-15.682	-2.550	-15.990
	P値	0.426	p<0.01	0.345	p<0.01

表-2 VICSリンク番号82のADF検定結果

		平均速度		交通密度	
		原系列	階差系列	原系列	階差系列
5分 間隔	統計量	-2.331	-27.654	-2.846	-27.786
	P値	0.438	p<0.01	0.220	p<0.01
15分 間隔	統計量	-2.567	-18.534	-2.370	-19.365
	P値	0.338	p<0.01	0.422	p<0.01
60分 間隔	統計量	-2.995	-12.777	-1.687	-12.829
	P値	0.157	p<0.01	0.711	p<0.01

表-3 VICSリンク番号13のADF検定結果

		平均速度		交通密度	
		原系列	階差系列	原系列	階差系列
5分 間隔	統計量	-2.962	-4.706	-2.946	-25.527
	P値	0.171	p<0.01	0.178	p<0.01
15分 間隔	統計量	-1.688	-14.965	-3.237	-14.545
	P値	0.711	p<0.01	0.371	p<0.01
60分 間隔	統計量	-2.971	-16.158	-2.864	-15.471
	P値	0.168	p<0.01	0.213	p<0.01



本研究の提案手法に加え、次の3つのモデルを比較対象に用いる。一つ目のモデルは、最も単純なECMを用いたモデル(5)である。

$$\nabla y_{01,t} = \varphi_{10}ECT_{t-1} + \varphi_{20}\nabla y_{02,t-1} + \sum_{i=1}^p \varphi_{1i}\nabla y_{01,t-i} + \varepsilon_t \quad (5)$$

where  $ECT_{t-1} = y_{01,t-1} - \alpha - \beta y_{02,t-1}$

このとき、左辺 $\nabla y_{ij,t}$ は $t$ 時点の平均速度の差分を表し、添え字 $l$ はリンク ( $l = 0$ が予測対象リンク)、 $j$ は時系列データの種類 ( $j = 1$ は平均速度、 $j = 2$ は交通密度)、 $t$ は時刻である。右辺第一項の $ECT_{t-1}$ は、 $t - 1$ 時点の誤差修正項で、 $\varphi$ はパラメータである。右辺第二項は交通密度のラグ項である。右辺第三項は平均速度のラグ項で、 $p$ はラグ数を表す。なお、今回は最大のラグ数を $p = 20$ とした。最適なラグ数 $p$ はグリッドサーチで求める。

二つ目のモデルは、モデル(5)に閾値共和分を用いたモデル(6)である。

$$\left\{ \begin{array}{l} \nabla y_{01,t} = \varphi_{10}ECT_{t-1} + \sum_{j=1}^2 \sum_{i=1}^p \varphi_{1i}\nabla y_{0j,t-i} + \varepsilon_t, \\ \qquad\qquad\qquad |ECT_{t-1}| < \theta \\ \nabla y_{01,t} = \varphi_{20}ECT_{t-1} + \sum_{j=1}^2 \sum_{i=1}^p \varphi_{2i}\nabla y_{0j,t-i} + \varepsilon_t, \\ \qquad\qquad\qquad |ECT_{t-1}| \geq \theta \end{array} \right. \quad (6)$$

where  $ECT_{t-1} = y_{01,t-1} - \alpha - \beta y_{02,t-1}$

このとき、状態変数は $t - 1$ 時点の $ECT$ 項の絶対値であり、最適なラグ数 $p$ 及び閾値 $\theta$ はグリッドサーチで求める。

三つ目は、モデル(6)に前後リンクの情報を表す項を加えた、Ma et al. (2015)の提案モデルに最も近いモデル(7)である。Ma et al. (2015)の提案モデルにおいて $ECT_{t-1}$ は $y_{01,t-1} - \beta y_{02,t-1}$ の形で推定されていたが、このモデルでは、切片を加え、より適切に速度と密度間の長期的な関係性を表現できるように改良した。

$$\left\{ \begin{array}{l} \nabla y_{01,t} = \varphi_{01} + \varphi_{10}ECT_{t-1} + \sum_{j=1}^2 \sum_{i=1}^p \varphi_{1i}\nabla y_{0j,t-i} + \sum_{l=1}^n \sum_{k=1}^3 \pi_{kl}(y_{0k,t-1} - y_{lk,t-1}) + \varepsilon_t, \\ \qquad\qquad\qquad |ECT_{t-1}| < \theta \\ \nabla y_{01,t} = \varphi_{02} + \varphi_{20}ECT_{t-1} + \sum_{j=1}^2 \sum_{i=1}^p \varphi_{2i}\nabla y_{0j,t-i} + \sum_{l=1}^n \sum_{k=1}^3 \pi_{kl}(y_{0k,t-1} - y_{lk,t-1}) + \varepsilon_t, \\ \qquad\qquad\qquad |ECT_{t-1}| \geq \theta \end{array} \right. \quad (7)$$

where  $ECT_{t-1} = y_{01,t-1} - \alpha - \beta y_{02,t-1}$

このとき、右辺第一項は定数項、右辺第四項は予測リンクで観測された $t - 1$ 時点の各交通変数からそれに対応する前後リンクの値を引いた項であり、 $\pi_{kl}$ はパラメータ、 $n$ は前後リンク数を表す。

以上3つのモデルと、本研究の提案モデルについて、まず、推定された長期関係式が共和分の関係を有意に表しているかを、 $ECT$ 項の時系列情報に対し、ADF単位根検定を適用することで確認する。ここで、表記の簡略化のため、モデル(5)を①、モデル(6)を②、モデル(7)を③、提案モデルを④とし、各時間間隔ごとの結果を表4にまとめた。この結果より、推定されたすべての長期関係式が、共和分の関係を有意に表していることが確認できた。

続いて、各時間間隔ごとのモデル推定・予測結果を表5にまとめた。この結果より、まずリンク間において予測精度MSEが大きく異なることがわかる。特に渋滞が頻

表-4 a 共和分の検定結果 (60分間隔)

		モデル ①,②,③	モデル④	
			$y_{01,t-1} < \theta$	$y_{01,t-1} \geq \theta$
リンク 13	統計量	-9.447	-8.416	-5.455
	p値	p<0.01	p<0.01	p<0.01
リンク 82	統計量	-9.807	-7.565	-7.226
	p値	p<0.01	p<0.01	p<0.01
リンク 379	統計量	-9.868	-5.226	-5.777
	p値	p<0.01	p<0.01	p<0.01

表-4 b 共和分の検定結果 (15分間隔)

		モデル ①,②,③	モデル④	
			$y_{01,t-1} < \theta$	$y_{01,t-1} \geq \theta$
リンク 13	統計量	-11.375	-10.077	-9.758
	p値	p<0.01	p<0.01	p<0.01
リンク 82	統計量	-11.926	-7.942	-12.854
	p値	p<0.01	p<0.01	p<0.01
リンク 379	統計量	-11.983	-11.633	-4.756
	p値	p<0.01	p<0.01	p<0.01

表-4 c 共和分の検定結果 (5分間隔)

		モデル ①,②,③	モデル④	
			$y_{01,t-1} < \theta$	$y_{01,t-1} \geq \theta$
リンク 13	統計量	-9.277	-4.686	-14.654
	p値	p<0.01	p<0.01	p<0.01
リンク 82	統計量	-12.807	-6.489	-12.008
	p値	p<0.01	p<0.01	p<0.01
リンク 379	統計量	-14.622	-12.663	-16.726
	p値	p<0.01	p<0.01	p<0.01

発し、常に低い速度で推移しているリンク13において、MSEは顕著に低くなっており、渋滞によって変化する速度の幅が大きいリンク82で最もMSEが高くなっている。このことから、渋滞・非渋滞の状態が高頻度で入れ替わり、平均速度の変動が大きいリンク程、予測誤差が大きくなることが推察される。

次に、時間間隔に着目すると、全体的に時間間隔が大きくなるほど、グリッドサーチによって推定される最適なラグ数が増え、モデルの予測精度が上がるがわかる。

モデル間における予測精度の違いに着目すると、すべての分析条件において、本研究の提案手法であるモデル④が他のモデルよりも予測精度が高いことが確認できる。一方で、モデル③が最も予測精度が低く、これは、モデルに組み込んだ前後リンクの情報が予測対象リンクの予測精度を低下させている可能性が示唆される。

ここで、リンク82の15分間隔のデータにおける、各モデルの予測結果及びパラメータ推定結果を図4～5及び表6～9に示す。なお、表6～9において有意水準は、0.1%を‘\*\*\*’、1%を‘\*\*’、5%を‘\*’、10%を‘.’と表す。表7、8では、有意水準10%において有意なパラメータのみを表示した。リンク82には、上流ノードに2つ、下流ノードに3つのリンクが接続しており、一日の平均交通量が多い順に番号を割り振った。表8においてuplink1\_は一番目の上流リンクを表し、dnlink1\_は一番目の下流リンクを表す。閾値モデルを利用したモデル②～④の閾値 $\theta$ はそれぞれ10.762、9.124、24.935であり、各モデルにおける閾値による速度・密度の分類結果を図6～8に示す。

まず、各モデルにおいて直接予測される速度の差分の結果(図4)に着目すると、観測値の変動が最も大きいですが、モデルによる予測値では、モデル③が最も大きく変動していることがわかる。しかし、観測値を正確に追ことはできておらず、それがすべての観測結果においてモデル③が最も予測精度が低い原因であると考えられる。

次に、表6～9の各モデルのパラメータ推定結果に着目する。特に各モデルのECT項に着目すると、基本的なECMを表すモデル①は負の値を取り、正しく推定されているが、閾値共和分を用いたモデル②③では、 $|ECT_{t-1}| \geq \theta$ において、有意なパラメータが推定されていないことがわかる。これは、長期関係式からの逸脱度合いによって長期関係式への修正速度が異なる、という閾値共和分の仕組みを正しく推定できていないと言える。モデル④においては、自由流レジームは負値をとり、長期関係式へ収束する挙動を示すといえるが、渋滞流レジームでは、正の有意な値が推定されている。これは、図5より、15分間隔では速度の時系列において、渋滞流レジームに属する時間は、非常に僅かであり、すぐに自由流レジームに戻るような挙動を示すからであると考え

られる。

最後に、図8で表したモデル④の閾値に着目すると、概ね速度が低下して渋滞していると考えられるレジーム(赤)とそのほかの非渋滞時のレジーム(青)に分類されており、渋滞時と非渋滞時で挙動が大きく変化する交通流の特徴を捉えることが出来ていることがわかる。一方、図6、7では、モデル②、③において推定された関係式と分類されたレジームが描かれているが、モデル④の図8と比べ、長期的な関係式がこのリンクのFDに合っていないことがわかる。また、分類されたレジームも、解釈することが難しい。

以上の考察より、既存研究におけるECMや閾値共和分を用いたモデルと比べ、本研究で提案したモデルが全ての分析条件において予測精度が優れており、交通渋滞による状態変化等を適切に表現できていることが確認できた。

表-5 各モデルの推定・予測結果

モデル	リンク13		リンク82		リンク379	
	lag	MSE	lag	MSE	lag	MSE
60分間隔	① 19	4.452	20	81.836	20	14.392
	② 19	4.463	20	85.187	19	16.544
	③ 17	19.175	20	160.288	12	20.727
	④ 16	3.760	20	64.754	19	13.273
15分間隔	① 2	4.865	2	81.936	20	20.510
	② 6	4.921	4	81.899	20	20.133
	③ 6	9.016	19	91.309	20	20.786
	④ 2	4.735	9	74.934	18	19.555
5分間隔	① 15	5.882	7	80.650	10	33.126
	② 4	6.107	8	79.837	7	33.053
	③ 3	10.617	18	101.204	5	33.097
	④ 4	5.885	17	72.786	10	32.611

表-6 モデル①のパラメータ推定結果

パラメータ	標準偏差	有意水準
ECT	-0.274	***
densityラグ1	-0.172	***
speedラグ1	-0.168	***
speedラグ2	-0.098	***
自由度調整済決定係数 $R^2 = 0.094$		



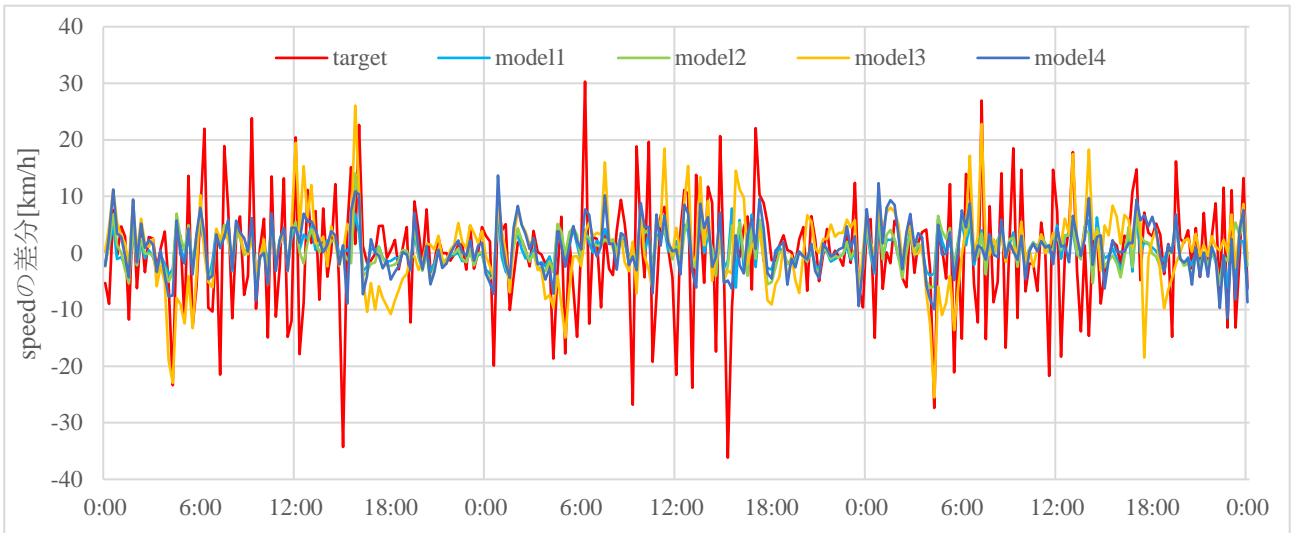


図-4 速度の差分の予測結果 (3日間)




図-5 速度の予測結果 (3日間)

表-7 a モデル②のパラメータ推定結果  $|ECT_{t-1}| < \theta$

	パラメータ	標準偏差	有意水準
ECT	-0.243	0.045	***
speedラグ1	-0.121	0.035	***
densityラグ1	-0.115	0.026	***
speedラグ2	-0.137	0.035	***
densityラグ2	-0.076	0.026	**
speedラグ3	-0.042	0.035	
densityラグ3	-0.007	0.026	
speedラグ4	-0.153	0.034	***
densityラグ4	-0.089	0.023	***
自由度調整済決定係数 $R^2 = 0.115$			

表-7 b モデル②のパラメータ推定結果  $|ECT_{t-1}| \geq \theta$

	パラメータ	標準偏差	有意水準
ECT	0.186	0.155	
speedラグ1	0.314	0.186	.
densityラグ1	-0.117	0.094	
speedラグ2	-0.481	0.201	*
densityラグ2	-0.182	0.088	*
speedラグ3	-0.164	0.180	
densityラグ3	-0.159	0.094	.
speedラグ4	-0.309	0.152	*
densityラグ4	-0.009	0.087	
自由度調整済決定係数 $R^2 = 0.207$			

表-8 a モデル③のパラメータ推定結果 $|ECT_{t-1}| < \theta$

パラメータ	標準偏差	有意水準	
ECT	-0.289	0.089	**
densityラグ1	-0.055	0.026	*
speedラグ2	-0.086	0.034	*
densityラグ2	-0.056	0.025	*
speedラグ4	-0.127	0.034	***
speedラグ6	-0.086	0.034	*
densityラグ7	-0.044	0.025	.
speedラグ8	-0.092	0.034	**
speedラグ9	-0.059	0.034	.
densityラグ9	-0.064	0.024	**
speedラグ14	0.102	0.034	**
densityラグ14	0.065	0.024	**
speedラグ16	-0.067	0.034	*
densityラグ16	-0.053	0.024	*
speedラグ18	0.057	0.033	.
uplink1_volume	-0.003	0.002	.
uplink1_density	0.156	0.038	***
uplink2_speed	-0.029	0.011	**
uplink2_volume	0.004	0.001	**
dnlink1_volume	-0.017	0.003	***
dnlink2_density	0.146	0.058	*

自由度調整済決定係数 $R^2 = 0.237$

表-8 b モデル③のパラメータ推定結果 $|ECT_{t-1}| \geq \theta$

パラメータ	標準偏差	有意水準	
speedラグ1	0.272	0.133	*
speedラグ5	-0.203	0.121	.
densityラグ5	-0.162	0.069	*
densityラグ14	-0.197	0.098	*
densityラグ17	0.193	0.117	.
uplink2_density	-0.215	0.126	.
dnlink1_volume	-0.046	0.012	***
dnlink2_volume	0.025	0.008	**
dnlink2_density	0.330	0.167	*

自由度調整済決定係数 $R^2 = 0.458$

表-9 a モデル④のパラメータ推定結果 $y_{01,t-1} < \theta$

パラメータ	標準偏差	有意水準	
ECT	0.729	0.178	***
speedラグ1	0.367	0.109	***
speedラグ2	-0.366	0.096	***
densityラグ2	-0.107	0.043	*
speedラグ7	0.158	0.078	*

自由度調整済決定係数 $R^2 = 0.145$

表-9 b モデル④のパラメータ推定結果 $y_{01,t-1} \geq \theta$

パラメータ	標準偏差	有意水準	
ECT	-0.531	0.059	***
speedラグ1	-0.108	0.040	**
densityラグ1	-0.128	0.036	***
speedラグ2	-0.083	0.039	*
speedラグ4	-0.109	0.038	**
densityラグ5	-0.069	0.030	*
speedラグ6	-0.075	0.038	*
densityラグ7	-0.047	0.028	.
speedラグ8	-0.069	0.037	.
densityラグ9	-0.069	0.025	**

自由度調整済決定係数 $R^2 = 0.230$




図-6 モデル②の閾値によるFD上の状態分類




図-7 モデル③の閾値によるFD上の状態分類

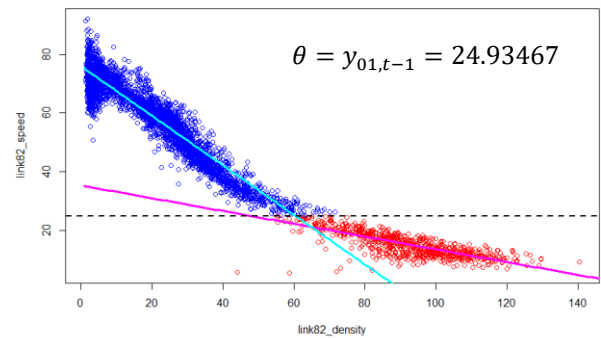


図-8 モデル④の閾値によるFD上の状態分類

## 6. 結論

本研究は、時系列解析の分野で開発された、短期の動学的な調整モデルとして有名な誤差修正モデルと大きな挙動の変化を捉える閾値モデルの手法を車両感知器データに対して適用・予測する手法を提案した。沖縄本島南部の感知器データに対する適用を通して、提案手法は、場所や曜日・天気・時間間隔などの分析条件によって異なる傾向を示す交通変数の予測・分析を通して、その妥当性と有用性を確認した。

なお、今後の課題としては、前後リンクの空間情報をモデルにうまく組み込み、さらに予測精度の高い手法の構築を目指すことや他の機械学習手法との予測精度の比較を行うこと、他の交通変数への予測の適用を行うこと等が挙げられる。

**謝辞：**本研究は公益財団法人日本道路交通情報センターとの共同研究の成果である。また、本研究は、JSPS科研費 15H04053の助成を受けたものである。

## 参考文献

- 1) Williams, B.M., and Hoel, L.A., 2003. Modeling and forecasting vehicular traffic flow as a seasonal ARIMA process: a theoretical basis and empirical results. *Journal of Transportation Engineering (ASCE)*, Vol. 129, pp. 664–672.
- 2) Kamarianakis, Yiannis, and Poulacos Prastacos. 2003. Forecasting traffic flow conditions in an urban network: Comparison of multivariate and univariate approaches, *Transportation Research Record: Journal of the Transportation Research Board*, Vol. 1857, pp. 74-84.
- 3) Antoniou, Constantinos, Moshe Ben-Akiva, and Haris N. Koutsopoulos. 2007. Nonlinear Kalman filtering algorithms for on-line calibration of dynamic traffic assignment models. *IEEE Transactions on Intelligent Transportation Systems*, Vol. 8, No. 4, pp. 661-670.
- 4) Qiao, Fengxiang, Hai Yang, and William HK Lam. 2001. Intelligent simulation and prediction of traffic flow dispersion. *Transportation Research Part B: Methodological*, Vol. 35, No. 9, pp. 843-863.
- 5) Abdulhai, Baher, Himanshu Porwal, and Will Recker. 2002. Short-term traffic flow prediction using neuro-genetic algorithms. *IIS Journal-Intelligent Transportation Systems Journal*, Vol. 7, No. 1, pp. 3-41.
- 6) Zheng, Weizhong, Der-Hong Lee, and Qixin Shi. 2006. Short-term freeway traffic flow prediction: Bayesian combined neural network approach. *Journal of transportation engineering*, Vol. 132, No. 2, pp. 114-121.
- 7) Smith, Brian L., Billy M. Williams, and R. Keith Oswald. 2002. Comparison of parametric and nonparametric models for traffic flow forecasting. *Transportation Research Part C: Emerging Technologies*, Vol. 10, No. 4 pp. 303-321.
- 8) Wu, Chun-Hsin, Jan-Ming Ho, and Der-Tsai Lee. 2004. Travel-time prediction with support vector regression. *IEEE transactions on intelligent transportation systems*, Vol. 5, No. 4, pp. 276-281.
- 9) Castillo, Enrique, José María Menéndez, and Santos Sánchez-Cambronero. 2008. Predicting traffic flow using Bayesian networks. *Transportation Research Part B: Methodological*, Vol. 42, No. 5 pp. 482-509.
- 10) Daganzo, Carlos F. 1994. The cell transmission model: A dynamic representation of highway traffic consistent with the hydrodynamic theory. *Transportation Research Part B: Methodological*, Vol. 28, No. 4, pp. 269-287.
- 11) Daganzo, Carlos F. 1995. The cell transmission model, part II: network traffic. *Transportation Research Part B: Methodological*, Vol. 29, No. 2, pp.79-93.
- 12) Daganzo, Carlos F. 2005. A variational formulation of kinematic waves: basic theory and complex boundary conditions. *Transportation Research Part B: Methodological*, Vol. 39, No. 2, pp. 187-196.
- 13) Muñoz, L., Sun, X., Horowitz, R., and Alvarez, L. 2003. Traffic density estimation with the cell transmission model. *Proceedings of the American Control Conference, Denver, United States of America, June 4-6, 2003*. Vol. 5, pp. 3750-3755
- 14) Nanthawichit, Chumchoke, Takashi Nakatsuji, and Hironori Suzuki. 2003. Application of probe-vehicle data for real-time traffic-state estimation and short-term travel-time prediction on a freeway. *Transportation Research Record: Journal of the Transportation Research Board*, Vol. 1855, pp. 49-59.
- 15) Wang, Yibing, and Markos Papageorgiou. 2005. Real-time freeway traffic state estimation based on extended Kalman filter: a general approach. *Transportation Research Part B: Methodological*, Vol. 39, No. 2, pp. 141-167.
- 16) Newell, Gordon F. 1993. A simplified theory of kinematic waves in highway traffic, part I: General theory. *Transportation Research Part B: Methodological*, Vol. 27, No. 4, pp. 281-287.
- 17) Laval, Jorge, Zhengbing He, and Felipe Castrillon. 2012. Stochastic extension of Newell's three-detector method. *Transportation Research Record: Journal of the Transportation Research Board*, Vol. 2315, pp. 73-80.
- 18) Deng, Wen, Hao Lei, and Xuesong Zhou. 2013. Traffic state estimation and uncertainty quantification based on heterogeneous data sources: A three detector approach. *Transportation Research Part B: Methodological*, Vol. 57, pp. 132-157.
- 19) Box, G. E., Jenkins, G. M., Reinsel, G. C., and Ljung, G. M. 2015. *Time series analysis: forecasting and control*. John Wiley & Sons.
- 20) Min, Wanli, and Laura Wynter. 2011. Real-time road traffic prediction with spatio-temporal correlations. *Transportation Research Part C: Emerging Technologies*, Vol 19, No. 4, pp. 606-616.



- 21) Min, Xinyu, Jianming Hu, and Zuo Zhang. 2010. Urban traffic network modeling and short-term traffic flow forecasting based on GSTARIMA model. *Proceedings of the 13th International IEEE Conference on Intelligent Transportation Systems (ITSC), Funchal, Portugal, September 19-22*, pp. 1535-1540
- 22) Liu, Tanqiu, Xianghai Sun, and Xiang Zhong. 2010. Short-term Traffic Flow Forecasting Based on a Three-regime SETAR Model. *Journal of Highway and Transportation Research and Development*, Vol. 10, pp. 022.
- 23) Kamarianakis, Yiannis, Wei Shen, and Laura Wynter. 2012. Real-time road traffic forecasting using regime-switching space-time models and adaptive LASSO. *Applied stochastic models in business and industry*, Vol. 28, No. 4, pp. 297-315.
- 24) Ma, Tao, Zhou Zhou, and Baher Abdulhai. 2015. Nonlinear multivariate time-space threshold vector error correction model for short term traffic state prediction. *Transportation Research Part B: Methodological*, Vol. 76, pp. 27-47.
- 25) Granger, Clive WJ, and Paul Newbold. 1974. Spurious regressions in econometrics. *Journal of econometrics*, Vol. 2, No. 2, pp. 111-120.
- 26) Phillips, Peter CB. 1986. Understanding spurious regressions in econometrics. *Journal of econometrics*, Vol. 33, No. 3, pp. 311-340.
- 27) Granger, Clive WJ. 1981. Some properties of time series data and their use in econometric model specification. *Journal of econometrics*, Vol. 16, No. 1, pp. 121-130.
- 28) Granger, Clive WJ, and Andrew A. Weiss. 1983. Time series analysis of error-correction models. *Studies in econometrics, time series, and multivariate statistics*, pp. 255-278.
- 29) Engle, Robert F., and Clive WJ Granger. 1987. Co-integration and error correction: representation, estimation, and testing. *Econometrica: journal of the Econometric Society*, pp. 251-276.
- 30) Tong, Howell. 1978. On a threshold model. No. 29. Sijthoff & Noordhoff,
- 31) Balke, Nathan S., and Thomas B. Fomby. 1997. Threshold cointegration. *International economic review*, pp. 627-645.
- 32) Hansen, Bruce E., and Byeongseon Seo. 2002. Testing for two-regime threshold cointegration in vector error-correction models. *Journal of econometrics*, Vol. 110, No. 2, pp. 293-318.
- 33) Cetin, Mecit, and Gurcan Comert. 2006. Short-term traffic flow prediction with regime switching models. *Transportation Research Record: Journal of the Transportation Research Board*, Vol. 1965, pp. 23-31.
- 34) Greenberg, Harold. 1959. An analysis of traffic flow. *Operations research*, Vol. 7, No. 1, pp. 79-85.
- 35) Drake, Joseph S., Joseph L. Schofer, and Adolf D. May Jr. 1967. A statistical analysis of speed-density hypotheses. in vehicular traffic science. *Highway Research Record*, Vol. 154.
- 36) MacNicholas, Michael J. 2011. A simple and pragmatic representation of traffic flow. *Symposium on The Fundamental Diagram*. Vol. 75. pp. 161-177.
- 37) Wang, H., Li, J., Chen, Q. Y., and Ni, D. 2011. Logistic modeling of the equilibrium speed-density relationship. *Transportation research part A: policy and practice*, Vol. 45, No. 6, pp. 554-566.
- 38) Greenshields, B. D., Ws Channing, and Hh Miller. 1935. A study of traffic capacity. *Highway research board proceedings. Vol. 1935. National Research Council (USA)*, Highway Research Board.
- 39) Inoue, R., Miyashita, A. and Sugita, M. 2016. Mining spatio-temporal patterns of congested traffic in urban areas from traffic sensor data. In: *Proceedings of 2016 IEEE 19th International Conference on Intelligent Transportation Systems*, accepted,

(2017. 7. 31 受付)

## DEVELOPMENT AND EXAMINATION OF TRAFFIC STATE PREDICTION METHOD USING ERROR CORRECTION MODEL AND THRESHOLD MODEL

Akihisa MIYASHITA and Ryo INOUE