

高速道路交通量変動の長期時系列分析

水口正教¹・福田大輔²

¹学生会員 東京工業大学 工学部土木・環境工学科 (〒152-8552 目黒区大岡山 2-12-1-M1-11)

E-mail: m.mizuguchi@plan.cv.titech.ac.jp

²正会員 東京工業大学大学院准教授 理工学研究科木工学専攻 (〒152-8552 目黒区大岡山 2-12-1-M1-11)

E-mail: fukuda@plan.cv.titech.ac.jp

高速道路の交通量は様々な要因により変動している。そのような中で、たとえば料金変動のような政策的介入が交通量に与えた効果を適切に計測するためには、そのような所変動要因成分の抽出と、それを考慮した政策効果の計測が必要となる。本研究では一般状態空間モデルの一種である構造型時系列モデルを交通量の長期時系列データに適用することにより、トレンド成分、周期(季節性、曜日性)成分、自己回帰成分、政策変動成分等を包括的に抽出・推計した。それを踏まえて、ETC 休日特別割引、対距離課金制、ロードプライシング社会実験等の政策効果の推計を試みた。

Key Words : 交通量変動, 構造型時系列モデル, 時系列分析

1. はじめに

交通量や交通密度のような交通に関する諸量は一定ではなく、常に時間的に変動している。例えば、1日の中での交通量を見ると、時間帯によって交通量が大きく異なる。そのような分単位・時間単位での細かい変動だけでなく、日単位の交通量であれば、曜日によって交通量は異なり、月単位の交通量であれば、季節によっても交通量は異なってくるのも明らかである。また、それ以上の長期的なデータも同様に変動することが考えられる。そのような長期的な交通量の変動の分析をすることは、高速道路の長期的な政策を考えるうえで、重要な知見となり得る。

例えば、日単位の交通量変動には、曜日変動・年変動のような周期的な変動、前日からの自己相関による変動などの変動要因が考えられる。月単位・季節単位もしくはそれ以上の年単位の交通量であれば、大局的な変動傾向や、周期的な変動が考えられる。さらに、自然災害のような突発的に起こった大きな出来事や、料金の変更や社会実験のような政策的な介入も交通量に大きな変化をもたらしている。しかし、交通量を見ただけでは、そのような様々な変動を理解することはできない。

そこで、交通量の状態推定を行い、各変動成分に分解することで理解をするという手法が古くからとられてきた。最も初期の研究として、飯田ら(1981)¹⁾が挙げられる。これは、北陸自動車道、中国自動車道において、それぞれ1年間の交通量を日単位で観測している。その観測データを用いて、月変動、日変動を推定している。この研究の成果として、周変動などは周期

性を見ることができたが、1年みのデータであったため、年変動のような長期にわたる周期的な変動は推定できていない。近年、佐々木ら(2012)²⁾は中央自動車道八王子IC-河口湖IC間の平成18年度から平成21年度までの4年間の日別ICペア間交通量を用いて、この観測データからトレンド成分・曜日変動成分・AR成分の3つの状態推定を行った。その結果として、2009年からトレンド成分が増加しており、これをETC 休日特別割引が2009年3月末より実施された影響であると結論付けている。しかし、モデルの中でETC 休日特別割引の影響等は考慮されていない。このように、政策介入の影響をモデル内で明示的に示した研究というのは少ない。

以上のような問題意識のもと、本研究では、各高速道路における長期時系列交通量データから、政策による影響を含む複数の変動成分を抽出することにより、政策的な介入を明示的に評価することを目的とする。対象とするデータは、首都高速道路、阪神高速道路、NEXCO 東日本、NEXCO 中日本、NEXCO 西日本における2005年から2014年の月別交通量データ、阪神高速道路における2006年の日別交通量データである。日別交通量データでは、阪神高速道路内の並行する2路線(神戸線、湾岸線)のデータに対して分析を行う。

2. 推定方法の概要

(1) モデルの定式化

本節では北川(2005)³⁾を参考に、一般状態空間モデルに対する理解をしていく。一般状態空間モデルとは、

時系列を表現する次のようなモデルのことである。

$$x_t = F_t x_{t-1} + G_t v_t \quad (1)$$

$$y_t = H_t x_t + w_t \quad (2)$$

ここで、 x_t は直接観測することのできない k 次元のベクトルで、状態と呼ばれる。 v_t はシステムノイズと呼ばれ、平均 0、分散共分散行列 Q_t に従う正規白色雑音である。一方 w_t は観測ノイズと呼ばれ、平均 0、分散共分散行列 R_t に従う正規白色雑音である。 F_t 、 G_t 、 H_t はそれぞれ $k \times k$ 、 $k \times m$ 、 $l \times k$ の行列である。

今回用いる手法では、与えられた交通量の時系列データ y_t ($t = 1, \dots, T$) を、トレンド成分 u_t 、季節調整成分 s_t 、自己回帰 (AR) 成分 p_t 、料金社会実験などのイベント効果成分 E_t 、および観測ノイズ成分 w_t に分解する。すなわち、式 (2) の観測モデルは次式のように書ける。

$$y_t = u_t + s_t + p_t + \gamma_t + w_t \quad (3)$$

これらの成分に分解することで、季節変動や AR 成分を除いた交通量の真のトレンドや、料金社会実験の影響を観察することができる。

式 3 のように、観測値を、以下で示すような形式で表される観測することのできない成分 (変動成分) に分解したモデルを、構造型時系列モデルと呼ぶ。

次に、式 (3) の観測モデルに含まれる各成分について説明する。

a) トレンド成分

日単位、月単位の交通量を考えた場合、トレンドが急激に変化していくことは考えにくい。そのため、直線もしくは直線からわずかに変化するトレンドモデルを採用することが妥当である。したがって、トレンド成分 u_t のシステムモデルは次のように表される。

$$u_t = u_{t-1} + v_{u,t} \quad (4)$$

ここで、 $v_{u,t}$ はシステムノイズである。式 (4) は今期と 1 期前の差がシステムノイズの分だけわずかに変化していくモデルとなっていることがわかる。突発的な事象が生じていない状況では、このシステムノイズは平均 0、分散 τ_u^2 のガウス分布に従う。つまり $v_{u,t} \sim N(0, \tau_u^2)$ と仮定できる。しかし、突発的な事象が発生した際には、システムノイズを裾の長いコーシー分布などに従うと仮定する必要がある⁴⁾。

また、 x_t 、 F 、 G 、 H はそれぞれ以下のように表される。

$$x_{t,u} = \begin{bmatrix} u_t \end{bmatrix}$$

$$F_u = \begin{bmatrix} 1 \end{bmatrix}$$

$$G_u = \begin{bmatrix} 1 \end{bmatrix}$$

$$H_u = \begin{bmatrix} 1 \end{bmatrix}$$

b) 季節変動成分

次に観測データから、一定の時間間隔で同じようなパターンを繰り返す変動成分を抽出する季節調整成分 s_t のシステムモデルは次のように表される。

$$\sum_{i=0}^{p-1} s_{t-i} = v_{s,t}$$

これは、

$$s_t = s_{t-p} + v_{s,t}$$

という状況を近似的に表している。つまり、今期の値と 1 周期前の値が $v_{s,t}$ となっている。ここで、 $v_{s,t}$ は平均 0、分散 τ_s^2 のガウス分布に従うシステムノイズである ($v_{s,t} \sim N(0, \tau_s^2)$)。これによりトレンドモデルの時と同様に、周期変動が徐々に変化していることを表現している。また、 p は 1 周期の中に含まれるデータ数である。例えば月単位データで年周期変動を表す際には $p = 12$ 、日単位データで曜日変動を表す際には $p = 7$ となる。また、 x_t 、 F 、 G 、 H はそれぞれ以下のように特定化される。

$$x_{t,s} = \begin{bmatrix} s_t \\ s_{t-1} \\ \vdots \\ s_{t-10} \end{bmatrix}$$

$$F_s = \begin{bmatrix} -1 & -1 & \cdots & -1 \\ 1 & & & \mathbf{0} \\ & \ddots & & \\ \mathbf{0} & & & 1 \end{bmatrix}$$

$$G_s = \begin{bmatrix} 1 \\ 0 \\ \vdots \\ 1 \end{bmatrix}$$

$$H_s = \begin{bmatrix} 1 & 0 & \cdots & 0 \end{bmatrix}$$

ここで、 F_s 、 G_s 、 H_s はそれぞれ 11×11 行列、11 次元ベクトル、11 ベクトルである。

c) 自己回帰 (AR) 成分

自己回帰 (AR) 成分とは、過去の状態に基づいて、現在の状態が決定される (自己回帰) ような成分である。AR 成分は、次のシステムモデルで表現される。

$$p_t = \sum_{i=1}^1 a_i p_{t-i} + v_{p,t}$$

ここで、 a_i は自己回帰係数である。今回は 1 次の AR 成分を状態変数として加えるため、ここでは AR 成分の次数を 1 としている。つまり、このモデルは、1 期前の状態の影響のみを受けて状態 p_t を決定していることになる。 $v_{p,t}$ は平均 0、分散 τ_p^2 のガウス分布に従うシステ

ムノイズである ($v_{p,t} \sim N(0, \tau_p^2)$). また, x_t, F, G, H はそれぞれ以下のように表される.

$$\begin{aligned} x_{t,p} &= \begin{bmatrix} p_t \end{bmatrix} \\ F_p &= \begin{bmatrix} a_1 \end{bmatrix} \\ G_p &= \begin{bmatrix} 1 \end{bmatrix} \\ H_s &= \begin{bmatrix} 1 \end{bmatrix} \end{aligned}$$

d) 政策による影響成分

次に, 今回最も注目すべき成分である政策による影響成分について述べていく. まず, 政策による影響成分 $E_t (= \gamma_t f_t)$ のシステムモデルは次式で与えられる.

$$\gamma_t = \gamma_{t-1} \quad (5)$$

つまり, 式 (5) はシステムノイズのないシステムモデル ($\tau_E^2 = 0$) となっており, γ_t は時間に依存せず一定となっている. また, γ_t は政策の効果を評価するパラメータである. ここで, f_t は政策の行われていた期間のみ 1, それ以外で 0 をとるダミー変数である. つまり, E_t は, 政策の行われていた期間のみ有効となる. x_t, F, G, H はそれぞれ以下のようになる.

$$\begin{aligned} x_{t,E} &= \begin{bmatrix} \gamma_t \end{bmatrix} \\ F_E &= \begin{bmatrix} 1 \end{bmatrix} \\ G_E &= \begin{bmatrix} 0 \end{bmatrix} \\ H_{t,E} &= \begin{bmatrix} f_t \end{bmatrix} \end{aligned}$$

e) 観測ノイズ

観測ノイズ w_t は平均 0, 分散 σ^2 のガウス分布に従うと仮定する. すなわち,

$$w_t \sim N(0, \sigma^2) \quad (6)$$

となる.

f) 行列, ベクトルの整理

以上, 式 (3) ~ 式 (6) をまとめると, x_t, v_t, Q_t は以下のようになる.

$$\begin{aligned} x_t &= \left(v_u, v_s, v_p, v_E \right)^T \\ v &= \left(u_t, u_t - 1, s_t, s_{t-1}, \dots, s_{t-p+2}, p_t, \gamma_t \right)^T \end{aligned}$$

$$Q = \begin{bmatrix} \tau_u^2 & & & \mathbf{0} \\ & \tau_s^2 & & \\ & & \tau_p^2 & \\ \mathbf{0} & & & \tau_E^2 \end{bmatrix}$$

v_t, Q_t は時間的に変化せず, 一定の値 v, Q をとっている. 行列 F, G, H は以下のようになる.

$$F = \begin{bmatrix} F_u & & & \mathbf{0} \\ & F_s & & \\ & & F_p & \\ \mathbf{0} & & & F_E \end{bmatrix}$$

$$G = \begin{bmatrix} G_u & & & \mathbf{0} \\ & G_s & & \\ & & G_p & \\ \mathbf{0} & & & G_E \end{bmatrix}$$

$$H_t = \begin{bmatrix} H_u & H_s & H_p & H_{t,E} \end{bmatrix}$$

F, G については時間に依存せず一定であるが, H に関しては, $H_{t,E}$ が時間に依存するため, 変数となる.

(2) 状態推定アルゴリズム

本節では, 観測データ群 $Y_j = \{y_1, y_2, \dots, y_j\}$ に基づいて時刻 t における状態 x_t の推定を行う手法について考える. とくに, $j < t$ の場合は観測区間より先の将来の状態を推定する問題で, 予測と呼ばれる. $j = t$ の場合は観測区間の最終時点, つまり現在の状態を推定する問題で, フィルタと呼ばれる. また, $j > t$ の場合は現在までの観測値に基づいて過去の状態を推定する問題で, 平滑化と呼ばれる.

本研究では式 (4) において, システムノイズにガウス分布を仮定するため, カルマンフィルタを使用して状態推定を行う. 突発事象の発生にも対応した推定手法を構築あうためには, コーシー分布を仮定した上で粒子フィルタを使用する必要がある.

a) カルマンフィルタ

本項では, 状態推定で用いるアルゴリズムであるカルマンフィルタについて解説していく. 状態推定をする際には, 観測データ群 Y_j が与えられた下での状態 x_t の条件付き分布 $P(x_t | Y_j)$ を求めればよい. ここでは式 (4) のシステムノイズにガウス分布を仮定している. よって, v はガウス分布に従う. また, w_t および x_0 についてもガウス分布に従うので, これらの条件付き分布はガウス分布になる. 従って, 状態空間モデルの状態推定の問題を考えるためには, 条件付き分布を規定する平均ベクトルと分散共分散行列だけを求めればよい. 一般に観測データ $\{y_1, y_2, \dots, y_j\}$ が与えられた下での状態 $\{x_1, x_2, \dots, x_j\}$ の条件付き同時分布を求めるためには莫大な計算量を要する. この問題を解決するのがカルマンフィルタと呼ばれる手法であり, 逐次的なアルゴリズムによって状態 x_t の条件付き周辺分布をきわめて効率的に計算することができる. 図 1 にカルマンフィルタの考え方を示す.

以下では状態 x_t の条件付き平均と分散共分散行列を以下のように表す.

$$x_{t|j} \equiv E(x_t | Y_j)$$

$$V_{t|j} \equiv E[(x_t - x_{t|j})(x_t - x_{t|j})^T]$$

カルマンフィルタで直接取り扱うのは, 1 期先予測と, フィルタである. 図 1 が示すように, 以下のアルゴリ

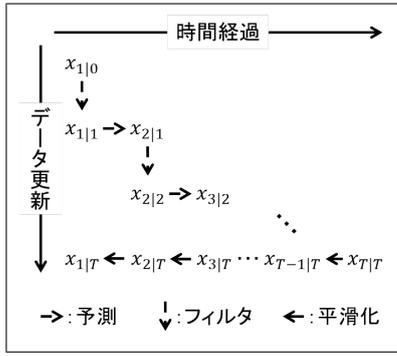


図-1 カルマンフィルタ概念図

ズムに従って1期先予測とフィルタを交互に繰り返すことによってこれらを順次求めていくことができる。1期先予測のアルゴリズム：

$$x_{t|t-1} = F_t x_{t-1|t-1}$$

$$V_{t|t-1} = F_t V_{t-1|t-1} F_t^T + G_t Q_t G_t^T$$

フィルタ：

$$K_t = V_{t|t-1} H_t^T (H_t V_{t|t-1} H_t^T + R_t)^{-1}$$

$$x_{t|t} = x_{t|t-1} + K_t (y_t - H_t x_{t|t-1})$$

$$V_{t|t} = (I - K_t H_t) V_{t|t-1}$$

K_t はカルマンゲインと呼ばれるものである。また、 $y_t - H_t x_{t|t-1}$ は y_t の予測誤差、 $H_t V_{t|t-1} H_t^T + R_t$ はその分散共分散行列となっている。

b) 平滑化

次に、平滑化について取り上げる。平滑化に関しては、固定区間平滑化と呼ばれるアルゴリズムがある。フィルタが時刻 t までの観測データだけを用いて x_t を推定しているのに対し、平滑化のアルゴリズムは得られているすべての観測データを用いて推定を行っている。したがって、平滑化を行うことでフィルタよりも精度のよい状態推定が行える。以下に固定区間平滑化のアルゴリズムを示す。

$$A_t = V_{t|t} F_{t+1}^T V_{t+1|t}^{-1} \quad (7)$$

$$x_{t|T} = x_{t|t} + A_t (x_{t+1|T} - x_{t+1|t}) \quad (8)$$

$$V_{t|T} = V_{t|t} + A_t (V_{t+1|T} - x_{t+1|t}) A_t^T \quad (9)$$

上式の $x_{t+1|t}$, $x_{t|t}$, $V_{t+1|t}$, $V_{t|t}$ には、カルマンフィルタによって得られた結果を用いて計算する。したがって、平滑化を行うためには、まずはカルマンフィルタによって $\{x_{t|t-1}, x_{t|t}, V_{t|t-1}, V_{t|t}\}$ ($t = 1, \dots, T$) を求めた後に式 (7) から式 (9) のアルゴリズムによって $x_{T-1|T}$, $V_{T-1|T}$ から順に $x_{1|T}$, $V_{1|T}$ まで求めればよい。

(3) モデルのパラメータ推定

状態推定を行うに当たり、未知のパラメータ $\theta = (\sigma^2, \tau_u^2, \tau_s^2, \tau_p^2, a)$ を求める必要がある、その方法として、本節では最尤推定法を紹介する。最尤推定法とは、その名の通り、一番もってもらいたいところをもって推定する方法である。ここでも³⁾に基づいて説明していく。

まず、時系列データ (y_1, \dots, y_T) の T 次元同時密度関数を $f_T(y_1, \dots, y_T | \theta)$ と表すことにする。この時、このモデルの尤度は

$$L(\theta) = f_T(y_1, \dots, y_T | \theta)$$

によって定義される。ここで、 $t = T, T-1, \dots, 2$ について

$f_t(y_1, \dots, y_t | \theta) = f_{t-1}(y_1, \dots, y_{t-1} | \theta) g_t(y_t | y_1, \dots, y_{t-1}, \theta)$ が成り立つことを繰り返し適用すると、時系列モデルの尤度は条件付き密度関数の積により

$$L(\theta) = \prod_{t=1}^T g_t(y_t | y_1, \dots, y_{t-1}, \theta) = \prod_{t=1}^T g_t(y_t | Y_{t-1}, \theta)$$

と表現できる。ここで、 $Y_0 = \phi$ とし、 $f_t(y_t | \theta) \equiv g_t(y_t | Y_0, \theta)$ と表すことにする。この時の対数尤度は

$$l(\theta) = \log L(\theta) = \sum_{t=1}^T g_t(y_t | Y_{t-1}, \theta) \quad (10)$$

で与えられる。 $g_t(y_t | Y_{t-1}, \theta)$ は観測値 Y_{t-1} が与えられたときの y_t の予測分布で、平均 $y_{t|t-1}$ 、分散共分散行列 $d_{t|t-1}$ の正規分布となるので、

$$g_t(y_t | Y_{t-1}, \theta) = \left(\frac{1}{\sqrt{2\pi}} \right)^l |d_{t|t-1}|^{-\frac{1}{2}} \exp \left\{ -\frac{1}{2} (y_t - y_{t|t-1})^T d_{t|t-1}^{-1} (y_t - y_{t|t-1}) \right\}$$

と表すことができる。したがって、これを式 (10) に代入することにより、この時系列モデルの対数尤度は

$$l(\theta) = -\frac{1}{2} \left\{ lT \log 2\pi + \sum_{t=1}^T \log |d_{t|t-1}| + \sum_{t=1}^T (y_t - y_{t|t-1})^T d_{t|t-1}^{-1} (y_t - y_{t|t-1}) \right\} \quad (11)$$

によって求めることができる。この式 (11) を最大化するパラメータ θ^* が推定されたパラメータとなる。

3. 実証分析

(1) データの概要

a) 月次交通量データ

本研究で使用する月次データは、日本道路保有・債務返済機構が記載している、各月毎の平均利用台数(千台/日)を基にしている。これにより、各高速道路(阪神高速道路・首都高速道路・NEXCO西日本・NEXCO中日本・NEXCO西日本)における月次交通量データ(1日平均)とした。データの期間は2005年10月~2014年11月となっている。今回は、阪神高速道路、NEXCO東日本の2社についての分析結果を紹介する。各高速道

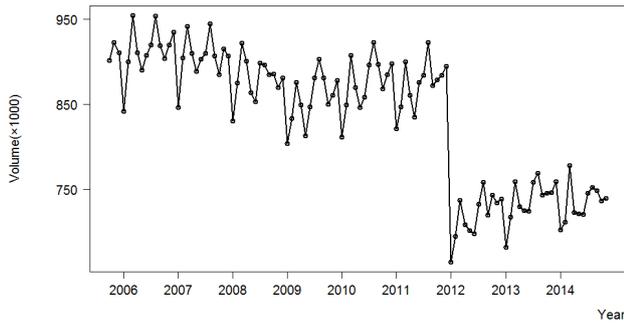


図-2 阪神高速道路 2005/10～2014/11 月別 1 日平均交通量の推移

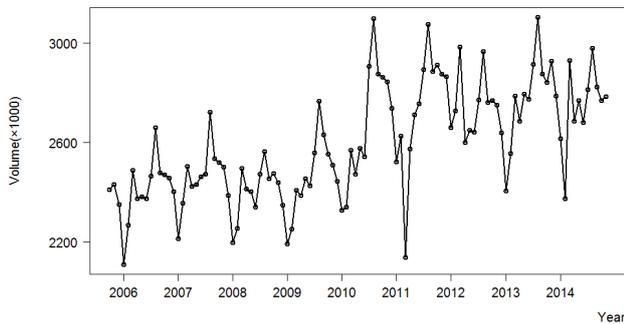


図-3 NEXCO 東日本 2005/10～2014/11 月別 1 日平均交通量の推移

路の交通量を図 2, 3 に示す。これを見ると、図 3 では、2011 年 3 月の交通量が落ち込んでいることがわかる。これは、2011 年 3 月 11 日に発生した東日本大震災の影響が表れたものと考えられる。また、図 2 では、2012 年から急激に交通量が減少している。これは、2012 年から対距離料金制に移行したため、その影響によるものと示唆される。

状態推定に取り入れる政策は、阪神高速道路では、2012 年 1 月 1 日から開始した、対距離料金制とする。NEXCO 東日本では、2009 年 3 月 28 日～2011 年 6 月 19 日に実施されていた ETC 車限定の、ETC 休日特別割引（通称 1000 円高速）の影響を評価する。また、NEXCO 東日本では、東日本大震災の影響が表れているため、これも政策による影響成分と同様の手法で推定し、その影響を見る。

b) 日次交通量データ

本研究で使用する日次データは、阪神高速道路の入り口に設置されているトラフィックカウンターのみの交通量データを路線ごとに集計した。データの期間は 2006 年の 1 年間、分析対象とした路線は神戸線、湾岸線の 2 路線である。この 2 路線の交通量を図 4 に示す。

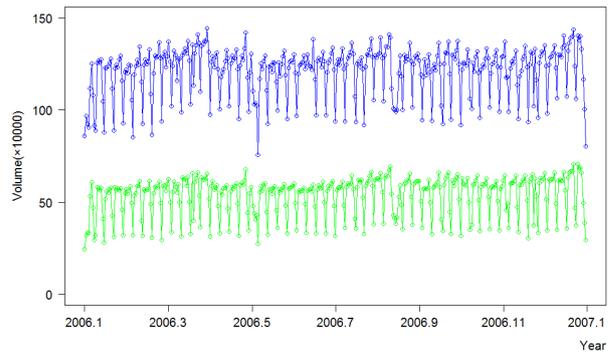


図-4 阪神高速道路 2006 年 日次交通量（神戸線・湾岸線）の推移

表-1 阪神高速道路月次データパラメータ推定結果

| | |
|-----------------------|-------------------------|
| 観測分散 (σ^2) | 4.254×10^{-2} |
| トレンド分散 (τ_u^2) | 3.431×10 |
| 月変動分散 (τ_s^2) | 3.340×10 |
| AR 分散 (τ_p^2) | 2.323×10^{-1} |
| 自己回帰係数 (a) | -8.816×10^{-7} |
| 最大対数尤度 | -305.3216 |
| サンプル数 | 110 |

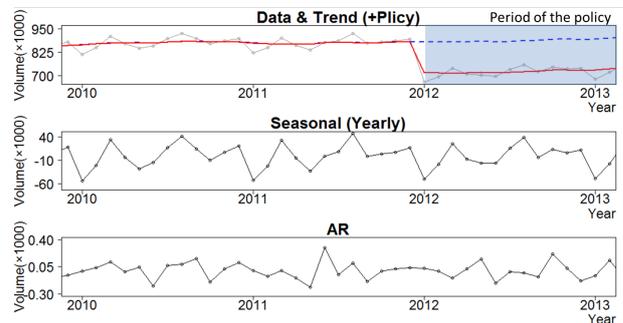


図-5 阪神高速道路月次データ状態推定結果

この 2 路線は並行しており、ここでは、ロードプライシング社会実験という、神戸線の交通を湾岸線へ転換させる目的の社会実験が 2006 年 6 月 12 日から 8 月 11 日まで行われていた。

(2) 状態推定結果

a) 阪神高速道路における推定結果

まず、阪神高速道路の交通量の状態推定を行うに先立ち、各パラメータ (σ^2 , τ_u^2 , τ_s^2 , τ_p^2 , a) を (3) に記した最尤法によって推定した。その結果を表 1 に示す。このパラメータを用いて、阪神高速道路での状態推定を行った。その結果を図 5 に示す。上段にプロットされ

表-2 NEXCO 東日本パラメータ推定結果

| | |
|-----------------------|-------------------------|
| 観測分散 (σ^2) | 1.152×10^3 |
| トレンド分散 (τ_u^2) | 1.700×10^3 |
| 月変動分散 (τ_s^2) | 1.256×10^2 |
| AR 分散 (τ_p^2) | 8.177×10^{-3} |
| 自己回帰係数 (a) | -1.616×10^{-6} |
| 最大対数尤度 | -477.2 |
| サンプル数 | 110 |

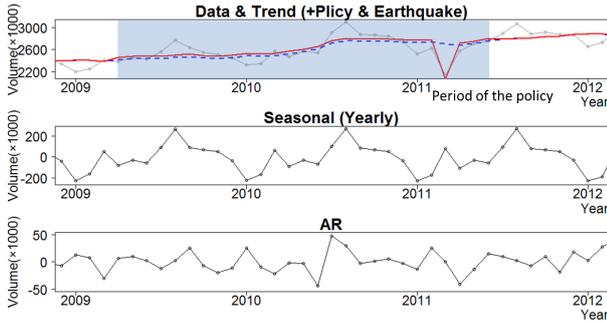


図-6 NEXCO 東日本状態推定結果

ているのが、観測された交通量である。青線で示されているのが、対距離料金制の影響も加味したトレンドである。緑の線は、対距離料金制に移行していなかった場合のトレンドの推移を示している。これを見ると、大幅に交通量が減少しているのがわかる。中段に示されているのは月変動成分、下段に示されているのはAR成分である。また、対距離料金による影響を評価するパラメータの値は平均で-162.6(台/1000)であった。対距離課金制への移行により大幅に交通量が減少したことが分かる。しかし、その原因についてはOD別交通量の分析をしていく必要があると思われる。対距離課金制では、交通距離と料金が比例して増えていくため、長距離交通が減少した結果として交通量が減少したのではないかと推測できる。その点からOD別交通量を分析する必要があると考えられる。

b) NEXCO 東日本における推定結果

まず、パラメータの推定結果を表2に示す。このパラメータを用いて状態推定を行った結果を、図6に示す。1000円高速による影響を評価するパラメータの値は-4.629(台/1000)となった。東日本大震災による影響を表すパラメータは、-445.3(台/1000)という結果になった。NEXCO 東日本では、休日特別割引導入の影響により交通量が前年度から4.2%増加したと発表している⁵⁾。しかし、今回の分析では、休日特別割引の影響による増分のみでは、政策期間中平均で約1.6%の交通量増加にとどまっているという結果となった。これは、単

表-3 神戸線パラメータ推定結果

| | |
|-----------------------|------------------------|
| 観測分散 (σ^2) | 2.904×10 |
| トレンド分散 (τ_u^2) | 7.928 |
| 曜日変動分散 (τ_s^2) | 1.270×10^{-5} |
| AR 分散 (τ_p^2) | 0.023 |
| 自己回帰係数 (a) | 1.004 |
| 最大対数尤度 | -616.4 |
| サンプル数 | 365 |

表-4 湾岸線パラメータ推定結果

| | |
|-----------------------|-------------------------|
| 観測分散 (σ^2) | 2.044×10 |
| トレンド分散 (τ_u^2) | 0.899 |
| 曜日変動分散 (τ_s^2) | 5.643×10^{-8} |
| AR 分散 (τ_p^2) | 6.108×10^{-10} |
| 自己回帰係数 (a) | 1.000 |
| 最大対数尤度 | -477.2 |
| サンプル数 | 365 |

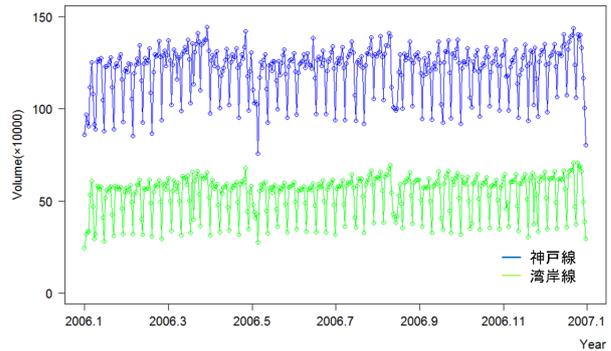


図-7 日次交通量（神戸線・湾岸線）状態推定結果

純に交通量の増加のみを比較した場合では、実際の政策による影響を観察することはできない結果であると考えられる。

c) 日次データにおける推定結果

まず、パラメータの推定結果を表3, 4に示す。神戸線のパラメータ推定では、対数尤度のより低い結果も得られていたが、トレンド成分やAR成分の分散の大きさなどから判断して妥当であると考えられる上の結果を用いることとした。このパラメータを用いて状態推定を行った結果を、図7に示す。この結果からは、神戸線、湾岸線どちらの交通量も社会実験期間中に増加していることになる。2路線間の相関を見るためには、構造VARモデルを用いて、同時点での相関を含む分析を行う必要がある。また、その時に政策による影響も

同時に変数に組み込むことで、より正確な影響を分析することが可能となると考えられる。

4. おわりに

本研究では、構造型時系列モデルを用いて、高速道路における長期時系列データに対し、トレンド成分・月変動成分・AR成分・政策による影響成分の4つの状態を包括的に推定し、政策介入の影響を歪みなく推計する豊富尾を提案した。

つぎに、阪神高速道路、NEXCO 東日本の2005年10月から2014年11月の月別1日平均交通量に対して推定方法の概要で述べた手法を適用した結果を記した。結果として、月変動成分は基本的に分散が小さく、非常に強い周期性を見ることができた。また、AR成分は1以下の小さな値となっていて、1期前(1月前)からの影響というのは、無視できる程度の値であるという結果が示唆された。また、政策による影響についても、対距離料金制・ETC 休日特別割引の二つの政策に対してパラメータを設定し評価することができた。これにより、対距離課金制によって交通量が大幅に減少していたこと、月次データに対しETC 休日割引の影響による交通量の変動だけを抽出した場合は、それほど大きな交通量の増加は表れていないことが示唆された。東日本大震災の影響については、約20%近く交通量が減少しており、その被害の甚大さを伺うことができた。

また、阪神高速道路の日次交通量データでは、路線別のデータの分析を行った。そこでは、神戸線から湾岸線へ交通を転換させる目的のロードプライシング社会実験が行われていたが、その影響について分析したところ、両路線とも交通量が増加する方向に影響を受けたという結果となった。

今後の課題としては、対距離課金制のような運転距離と関係のあるデータを分析するためには、全交通量ではなく、OD別交通量に対して分析を行っていく必要があると考えられる。また、休日特別割引の影響については、月次データとして扱った場合には約1.6%の交通量の増加にとどまっており、日次データに対し、平日・休日のダミー変数を設定し分析することで、異なる結果を得ることができると期待される。また、路線別の分析についても、構造VARモデルを用いることで、政策による影響も同時に変数に組み込んでの分析ができるようになると考えられる。

謝辞： 本研究で使用した阪神高速道路の日次データは、阪神高速道路株式会社様よりご提供いただいたものです。また、東京工業大学理工学研究科土木工学専攻助教の日下部貴彦様にデータの処理に関してご教授

頂きました。ここに記して感謝の意を表します。

参考文献

- 1) 飯田恭敬, 高山純一: 高速道路における交通量変動特性の統計分析, 高速道路と自動車, Vol. 24, No. 12, pp. p22-32, 1981.
- 2) 佐々木邦明, 中沢航太, 山本隆: ベイズ型状態空間モデルを用いた交通量変動の分析 (特集 交通モデリングの今), 交通工学, Vol. 47, No. 2, pp. 27-32, 2012.
- 3) 北川源四郎: 時系列解析入門, 岩波書店, 2005.
- 4) 長尾大道, 樋口知之, 三浦哲, 稲津大祐: 地球地殻の活動監視を目的とした粒子フィルタ法による長期潮位変動解析, 日本統計学会誌, Vol. 42, No. 1, pp. 119-133, 2012.
- 5) NEXCO 東日本: 平成 21 年度営業概況, , http://www.e-nexco.co.jp/company/strategy/pdfs/privatization_reference.pdf2010.

(2015. 4. 24 受付)

Time-series analysis for understanding the variability of traffic volume on expressways

Masanori MIZUGUCHI and Daisuke FUKUDA

Quantities regarding road traffic states such as traffic volume (demand) or speed may be changed over time: some may vary day-by-day and others may vary month-to-month or furthermore year-by-year. It is necessary to know a short-term change within one day or within several hours when evaluating the reliability of travel time. Not only that but also it is necessary to understanding the long-term variation over several years or decades, when making the transport policy such as the one on the tolling. the aim of this study is to conduct long-term time-series modeling for monthly traffic volume data of Japanese urban/interurban highways including Metropolitan Expressway, Hanshin Expressway, East Nippon Expressway, Central Nippon Expressway and West Nippon Expressway and the daily traffic volume data of Hanshin Expressway. By employing a structural time series model that is widely used in the analysis of time-series data, this study tries to estimates the several components of traffic volume variability comprehensively. The states of traffic volume that should be estimated consist of trend component, seasonal component, auto-regressive component and the component representing the effect of the external events such as transport policies or incidents.