


都市交通計画における計算理論と 観測技術に関する最新研究のレビュー

研究会「次世代インフラを巡る理論と観測の研究課題を考える」

2013/09/20(金)
浦田, 柳沼, 斉藤

交通行動の記述・予測

交通計画では、交通現象を何らかの数理モデルを用いて記述し、需要を予測することが必須の手順である。



- 目的地 (どこへ?)
- 出発時刻 (いつ?)
- 交通機関 (どの手段で?)
- 利用経路 (どの道で?) etc...

離散選択モデルによるアプローチ

交通行動の特徴

- 何かを**選択**する行動
- 個人の**確率的**なふるまい(決定論ではない)
- 選択肢は**離散**が多い

e.g. 鉄道vs自動車、高速道路vs一般道etc...

交通行動を記述する手法として、ランダム効用最大化理論に基づく**離散選択モデル**が広く用いられている。

ランダム効用最大化

ランダム効用最大化

確率的な誤差を含む効用(望ましさ)が最も高い選択肢を選ぶ行動原理

選択肢*i*の効用

$$U_i = V_i + \varepsilon_i$$

選択肢*i*の確定項

観測可能な効用の構成要素
e.g. 料金、所要時間、個人属性etc...

選択肢*i*の誤差(ランダム)項

観測不可能な効用の構成要素

- 非観測属性
- 測定誤差
- 情報の不完全性


誤差項を用いて効用を確率的に表現

= **確率的選択行動**

離散選択モデル (1)

誤差項に確率分布を仮定することで
離散選択モデルを導出できる

- IIDガンベル分布
⇒多項ロジットモデル(MNL)
- 多変量正規分布
⇒多項プロビットモデル(MNP)
- 一般化極値分布(GEV)
⇒NL, PCL, CNL, OGEV etc...
- GEV+正規分布等
⇒MXL



羽藤 (2002)

離散選択モデル (2)

多項ロジットモデル

$$P(i) = \frac{\exp(\mu V_i)}{\sum_{j \in C} \exp(\mu V_j)}$$

- Closed-form
- 選択肢間の相関を無視(IIA)

表現力は劣るが、通常の最適化アルゴリズムでパラメータ推定が可能であり、ソースコードの開発が容易

⇒爆発的に各分野に普及

多項プロビットモデル

$$P(i) = \int_{\varepsilon_1=-\infty}^{\varepsilon_i+V_i-\varepsilon_1} \cdots \int_{\varepsilon_i=-\infty}^{\infty} \cdots \int_{\varepsilon_J=-\infty}^{\varepsilon_i+V_i-\varepsilon_J} \phi(\varepsilon) d\varepsilon_J \cdots d\varepsilon_1$$
$$\phi(\varepsilon) = \frac{1}{(\sqrt{2\pi})^{J-1} |\Sigma|^{1/2}} \exp\left(-\frac{1}{2} \varepsilon \Sigma^{-1} \varepsilon'\right)$$

- Open-form
- 選択肢間の相関を表現

表現力は高いが、選択肢数-1の多重積分が必要であり、パラメータ推定は非常に煩雑

⇒計算が困難であるため
近年まで伸び悩む...

プロビットモデルの応用例（1）

構造化プロビットモデルの首都圏鉄道需要予測への適用 (屋井1998, 清水1999, 岩倉2010)

- 経路重複を持つ首都圏鉄道網において、個人ごとに利用区間の異なる選択肢の共分散構造を表現することが必要

⇒ **誤差項を構造化**

分散共分散行列

経路長に依存する誤差

$$\varepsilon_i = \varepsilon_i^{Length} + \varepsilon_i^{Route}$$

経路固有の誤差

$$\Sigma = \sigma_{Length}^2 \begin{pmatrix} L_1 & L_{12} & \cdots & L_{1j} \\ L_{12} & L_2 & & \vdots \\ \vdots & & \ddots & \\ L_{1j} & \cdots & & L_j \end{pmatrix} + \sigma_{Route}^2 I$$

L_{ij} : 重複区間長

プロビットモデルの応用例 (2)


- ・ 運輸政策18号答申に構造化プロビットを導入(岩倉2010)
⇒ 高い予測精度を実現(全駅間断面交通量は実績の±10%)

発着駅	各経路の選択確率	実績(H7センサス)	独立性非考慮	独立性考慮
大宮駅 →	i 東北→山手	33%	28%	27%
	j 東北→京浜東北	15%	24%	20%
		48%	52%	47%
神田駅	k 京浜東北	53%	47%	52%
選択確率計		100%	100%	100%
川越駅 →	i 東上→埼京	19%	26%	19%
	j 東上→京浜東北	43%	42%	43%
		62%	68%	62%
新宿駅	k 川越→埼京	39%	31%	38%
選択確率計		100%	100%	100%

- ・ 構造化プロビットとMXLの比較分析(清水1999)
⇒ MXLより計算時間が4倍早く、計算時間の変動も1/10
推定パラメータの変動係数もMXLより小さい

MNP推定手法の発展


開発当初から多重積分の計算がネックとなり、各種の数値計算アルゴリズムが提案



近年のプロビットモデル再来(私見)には計算機性能とアルゴリズム改良が大きく寄与している

計算機の進化(CPU)

クロック周波数の経年変化(企業別)



マルチコアCPUの台頭 ⇒ 並列化の時代

- Core2Duo⇒2core
- Core i7⇒4core
※HT時は8core
- Xeon phi⇒60core!!


計算処理速度は大幅に進化しており、かつマルチコア化による並列処理が環境の充実がより高速化を促す

※http://cpudb.stanford.edu/visualize/clock_frequency

計算機の進化(メモリ)

メモリ容量の経年変化

格納可能なデータ量を意味し、数値計算を行う上で重要





2000年頃からメモリ容量が急増し、多変数・多サンプルのモデル推定や多くのメモリを要するシミュレーション法やベイズ推定(MCMC)が可能となる

※http://flatrock.org.nz/topics/info_and_tech/artificial_consciousness.htm

Private から Sharing へ

組合せ数爆発




齊藤いつみ: 共有型交通システムの動学的特性とその制御手法の提案, 東京大学修士論文, 2012

ここまでのまとめ

- 離散選択モデルの精緻化と表現可能な交通行動の進展の背後には計算機科学の進展あり
⇒ **今後も計算手法の改良が重要**
- CPU性能向上により自動的に計算速度の向上する状況(フリーランチ)は終わりを迎えつつある
⇒ **並列処理に関する実装論も必要**

交通需要・行動の予測と観測

交通計画では、交通現象を何らかの数理モデルを用いて記述し、需要を予測することが必須の手順である。



短期変動把握のためのシステム構築


Advanced Traveler Management / Information Systems

観測対象の設定と予測システムの構築

短期変動: イベント影響, ゾーンマネジメント,
レーン閉鎖, ランプ・信号制御,
HOVレーン, 混雑課金

Simulation-based DTA system

- **時間依存**する交通需要と交通サービスの関係性を明らかにする
- 混雑の場所と影響を予測する



短期変動把握のためのシステム構築

■時間帯別OD推定 <断面交通量は実測可能>

$$\text{Minimize } z(\mathbf{x}_1, \dots, \mathbf{x}_H, \beta_1, \dots, \beta_H) = \sum_{h=1}^H [z_1(\mathbf{M}_h, \mathcal{M}_h) + z_2(\mathbf{x}_h, \mathbf{x}_h^a) + z_3(\beta_h, \beta_h^a)]$$

subject to the following constraints:

$$\left. \begin{aligned} \mathcal{M}_h &= f(\mathbf{x}_1, \dots, \mathbf{x}_h, \beta_1, \dots, \beta_h, G_1, \dots, G_h) \\ l_h^x &\leq \mathbf{x}_h \leq u_h^x \\ l_h^\beta &\leq \beta_h \leq u_h^\beta \end{aligned} \right\} \quad \forall h \in \{1, 2, \dots, H\}$$

M: 断面交通量 (実測値, 推計値)

x: OD交通量 (操作変数)

β : パラメータ (操作変数)

h: 時間帯

G: 道路ネットワーク

◆Demand Simulator

- 個人の時間価値, 情報取得, 移動の特徴を考慮
- **day-to-day**では実績ODと断面交通量から時間帯別の想定OD表を作成
- **within-day**では情報, イベント生起を元にOD表を修正

◆Learning Model

ドライバーの認知旅行時間の更新 $\bar{T}_k^t = \lambda T_k^{t-1} + (1 - \lambda) \bar{T}_k^{t-1}$,

t: day

k: path

$\bar{T}$: 経験時間交通量

λ : 更新パラメータ



リンク交通量を用いたOD推定

■時系列相関を考慮した推定方法の工夫

- ・交通量変化の**時系列相関**を考慮し、評価に**カルマンフィルタ**を適用
- ・計算量は増えるものの、精度は向上

$$\partial x_h = \sum_{p=h-q'}^{h-1} f_h^p \partial x_p + w_h,$$

実績ODと推計ODの差 ∂x_h は、時間帯 h 以前の差 ∂x_p は相関がある



リンク交通量観測地点の最適配置

OD交通量を所与として、リンク交通量観測地点の**最適配置**を求める
(リンク交通量とOD交通量推計の関係性も予め与える)

目的関数1：推計経路交通量の誤差最小化

$$\begin{aligned} & \underset{f_r; \forall r \in \mathcal{R}}{\text{Minimize}} && \sum_{x \in \mathcal{R}} \sum_{y \in \mathcal{R}} (f_x - f_x^0) \gamma_{xy} (f_y - f_y^0), && f: \text{経路交通量} (f^0: \text{真値}) \\ & \text{subject to} && \hat{f}_r = f_r; \quad \forall r \in \mathcal{R}, && \hat{v}: \text{観測リンク交通量} \\ & && \hat{v}_a = \sum_{r \in \mathcal{R}} \delta_a^r f_r; \quad \forall a \in \mathcal{L}, && a: \text{リンク}, x, y, r: \text{経路} \\ & && && \gamma_{xy}: \text{重み} \end{aligned}$$

目的関数2：観測地点数の最小化

$$\begin{aligned} & \underset{z}{\text{Minimize}} && n_{sc} = \sum_{a \in \mathcal{L}} z_a, && z_a: \text{リンク} a \text{ が観測地点を含めば} 1 \\ & \text{subject to} && \sum_{a \in \mathcal{L}} z_a d(r, r_1, a) \geq 1; \quad \forall (r, r_1) | r \neq r_1, && \text{異なる経路は異なる} \\ & && \sum_{a \in \mathcal{L}} z_a \delta_a^r \geq 1; \quad \forall r, && \text{地点} 1 \text{ つ以上で観測} \\ & && && \text{経路内で} 1 \text{ 回以上観測} \end{aligned}$$

$$\delta_a^r = \begin{cases} 1 & \text{if path } r \text{ contains link } a, \\ 0 & \text{otherwise,} \end{cases}$$

$$d(r, r_1, a) = \begin{cases} 1 & \text{if } \delta_a^r \neq \delta_a^{r_1}, \\ 0 & \text{otherwise.} \end{cases}$$

リンク交通量観測地点の最適配置

目的関数3：コスト最小化

1観測地点あたりのコスト

$$M_1 = \underset{z}{\text{Minimize}} \sum_{a \in \mathcal{A}} \mathcal{P}_a z_a$$

目的関数4：識別可能交通量最大化

$$M_2 = \underset{y, z}{\text{Maximize}} \sum_{i \in I} \sum_{r \in R_i} \frac{f_r^0}{t_i^0} y_r,$$

$$\text{subject to} \quad \sum_{a \in \mathcal{A}} z_a d(r, r_1, a) \geq y_r; \quad \forall (r, r_1) | r \neq r_1,$$

$$\sum_{a \in \mathcal{A}} z_a \delta_a^r \geq y_r; \quad \forall r,$$

$$\sum_{a \in \mathcal{A}} \mathcal{P}_a z_a \leq \mathcal{B},$$

y_r : 他のルートと識別可能であれば1

t_i : OD交通量

I : リンク交通量観測地点

異なる経路は異なる

地点1つ以上で観測(識別時)

経路内で1回以上観測(識別時)

予算制約


経路交通量が特定できる状態を”識別”とする

目的関数5：識別可能経路数最大化


$$M_3 = \underset{y, z}{\text{Maximize}} \sum_{i \in I} \sum_{r \in R_i} y_r,$$

リンク交通量観測地点の最適配置

目的関数4: 識別可能交通量最大化



目的関数5: 識別可能経路数最大化



複数の目的関数の設定も可能

⇔ メタヒューリスティクスにより近似解が算出可能

リンク交通量とサンプルODの融合

MEUSE (Matrix Estimation Using Structure Explicitly) model

- 駐車場における**サンプル的な発地調査データ**(情報が詳細)
- **リンクの交通量**調査データ(廉価に入手できる)
- 事前OD交通量(過去の調査結果, 交通量との整合無し)

最小化目的関数 (推計値と実測値の差の最小化)

$$\underbrace{\sum_{i \in O, j \in D \setminus S} w_{ij}^t (T_{ij} - t_{ij})^2}_{\text{OD交通量}} + \gamma \underbrace{\sum_{a \in A} w_a^v (V_a - v_a)^2}_{\text{リンク交通量}} + \underbrace{\sum_{j \in S} w_j^s (f_j - \bar{f}_j)^2}_{\text{駐車場調査の調査対象割合の分散}} + \underbrace{\sum_{j \in S, i \in P_j} w_{ij}^f (f_{ij} - f_j)^2}_{\text{駐車場調査の発地の分散}} + \sum_{j \in S, i \in Q_j} w_{ij}^t T_{ij}^2$$

w は各項の重みづけの変数

i: 出発地 O: 出発地群

j: 到着地(駐車所) D: 到着地群

A: 交通量観測リンク

T_{ij} : ij間のOD交通量の推定交通量

t_{ij} : ij間のOD交通量の事前推定交通量

V_a : リンクaの推定リンク交通量

v_a : リンクaの実測リンク交通量

γ : リンク交通量の重み付けパラメータ

p_{ij}^a : ij間のOD交通量のうちのリンクaへの配分割合

S: 駐車場調査を行った目的地(駐車場)

リンク交通量

$$\sum_{i \in O, j \in D} p_{ij}^a T_{ij} = V_a$$

リンク交通量とサンプルODの融合

超幾何分布を用いて、次の関係式で、**観測OD交通量**と**真のOD交通量**の関係を整理

$$t'_{ij} = H(D_j, t^*_{ij}, pD_j)$$


D_j : 駐車場jが到着地となる交通量(観測可能)

t^*_{ij} : (観測できない) 真のij間のOD交通量

超幾何分布

$H(N, N_0, n)$ は $f(x) = \frac{{N_0 \choose x} {N - N_0 \choose n - x}}{{N \choose n}}$ の確率分布に従う.

駐車場jが到着地となる交通量分布 ($N=D_j$)



超幾何分布の分散

$$V(x) = n \frac{N_0}{N} \frac{N - N_0}{N} \frac{N - n}{N - 1}$$

GPSデータの取得⇒**リンクコスト**が観測可能

UEのリンクコストとGPS由来のリンクコストの差の最小化も定式化し、OD推定
(Nie and Zhang 2008, 2010)


公共交通利用データの活用によるOD推定

バス・鉄道の利用データ⇔ICカードで自動取得（パッシブデータ）

- ➡ 一定料金交通（バスなど）は乗る時のみ観測のため、**目的地は不明**
1交通手段ずつの観測であり、**乗継ぎのあるトリップは不明**

■乗継ぎなし利用者


- ・次の乗車駅が降車駅



- ・最後のトリップは1日の最初の乗車駅に戻る



■乗継ぎあり利用者

- ・乗継ぎ乗車駅と乗車時間から、時空間制約を考慮し、前の移動の降車駅を算出（降車時間はバスロケーションデータを活用）



パッシブの複数データを組合せて，OD推定に利用

公共交通利用データの活用によるOD推定



公共交通の利用者のOD推定(**時空間の分解能**が詳細化)
→滞在(乗り換え)の空間と時間を把握

常時観測データを用いた交通機関判別




Bcalsによる常時観測

トリップ: 984

ロケーションデータ: 341,712

取得データ: 加速度, 運動強度, 緯度経度等
(調査対象者は持ち運びのみ)



機械学習理論を用いた自動判別結果

判別器 移動手段	鉄道	車	自転車	徒歩	全体
SVM	100	87.0	95.1	88.3	88.0
SVM × AdaBoost	100	92.6	95.1	90.8	91.4

表中は適合率(%) ※適合率=(正しく判別されたサンプル数)/(全サンプル数)

まとめ

day-to-day, within-day, real-time の交通予測技術の装備へ
ーイベント混雑予測, ゾーンマネジメント, 混雑課金などの検討

リンク交通量によるOD交通量の推計 ← 時系列の確率過程 (カルマンフィルタ)

リンク交通量観測の最適配置 ← 最適化理論やメタヒューリスティクス

サンプル調査を用いたOD推計 ← 確率分布

常時観測データを用いた交通状態判別 ← 機械学習, ルールベースの判別

大規模データが取得可能

数理理論の活用

人間行動, 交通行動の豊かさ・複雑さ

単純なデータ化が難しい行動を表現する
ランダム効用理論と誤差項の構造化
仮説と観測 (準拠集団, 劣化, 端末, ,)

参考文献

Sundaram, S., Koutsopoulos, H.N., Ben-Akiva, M., Antoniou, C., Balakrishna, R.: Simulation-based dynamic traffic assignment for short-term planning applications, *Simulation Modelling Practice and Theory*, Vol. 19, pp. 450-462, 2011.

Bierlaire, M., Crittin, F.: An Efficient Algorithm for Real-Time Estimation and Prediction of Dynamic OD Tables, *Operations Research*, Vol. 52, No. 1, pp.116-127, 2004.

Flotterod, G., Bierlaire, M., Nagel, K. : Bayesian Demand Calibration for Dynamic Traffic Simulations, *Transportation Science*, 45-4, 541-561, 2011.

Minguez, R., Cambronero, SS., Castillo, E., Jimenez, P., Optimal traffic plate scanning location for OD trip matrix and route estimation in road networks, *Transportation Research Part B*, 44, 282-298, 2010.

Bierlaire, M., Toint, P.L.: MEUSE: an origin-destination matrix estimator that exploits structure, *Transportation Research Part B*, Vol.29,No.1, 47-60, 1995.

Nie, Y. and Zhang, H. M.: A variational inequality formulation for inferring dynamic origin-destination travel demands. *Transportation Research Part B*, Vol. 42, 635-662, 2008.

Nie, Y., Zhang, H. M.: A relaxation approach for estimating origin-destination trip tables. *Network and Spatial Economics*, Vol. 10, pp.147-172, 2010.

Munizaga, MA., Palma, C.: Estimation of a disaggregate multimodal public transport Origin-Destination matrix from passive smartcard data from Santiago, Chile, *Transportation Research Part C*, Vol. 24, pp. 9-18, 2012.

参考文献

- Jay B. Gordon, Haris N. Koutsopoulos, Nigel H.M. Wilson, John Attanucci, Gabriel Sanchez : A Methodology for the Inference of public transportation linked trips from automated fare collection and AVL data, TRISTAN, San Pedro De Atacama, 2013.6
- Zhao, J., Rahbee, A., Wilson, N.H.M.: Estimating a Rail Passenger Trip Origin-Destination Matrix Using Automatic Data Collection System, Computer-Aided Civil and Infrastructure Engineering, Vol. 22, pp. 376-387, 2007.
- Imaizumi, T., Awais, S. M., Hato, E., Incorporating the physical load into activity analysis focused on the built environment for pedestrians, 第33回交通工学研究発表会論文報告集, pp. 541-546, 2013.
- 齊藤いつみ: 共有型交通システムの動学的特性とその制御手法の提案, 東京大学修士論文, 2012
- 岩倉成志: 東京圏の都市圏鉄道計画における構造化プロビットモデル, オペレーションズリサーチ, Vol. 55, pp. 159-163, 2010
- 清水哲夫, 屋井鉄雄: Mixed Logit Modelとプロビットモデルの推定特性に関する比較分析, 土木計画学研究・論文集, No. 16, pp. 587-590, 1999.
- 屋井鉄雄, 中川隆広, 石塚順一, シミュレーション法による構造化プロビットモデルの推定特性, 土木学会論文集, No. 604/IV-41, pp. 11-21, 1998.

ご清聴ありがとうございました.