

IV-187 ディリクレ分布を用いた新たなベイズ更新法

東京工業大学 学生員 魚谷 憲
 東京工業大学 正 員 屋井 鉄雄
 東京工業大学 正 員 岩倉 成志
 東京工業大学 学生員 高田 和幸

1. はじめに

交通需要データは、定期的、継続的に収集されるケースが多く、これらは長年に渡り各種交通計画策定の重要な基礎統計として、また予測技術発展の原動力として大いに貢献してきた。しかし、近年の交通技術進歩に伴って、様々な環境変化が生じつつある。また、従来の調査方法においては様々な問題も指摘され始めている。そのため、将来を見越して、データ収集技術を見直す必要性は高い。また、交通需要予測の目的や要求も時代と共に変化し、わが国の国内においては必ずしも大規模調査に基づく技術論ばかりが要求されるとは考えにくい。本研究ではベイズ更新法において追加的に統合利用する集計量の誤差の考え方を考え、誤差分布を新たな分布に置き直した更新過程の提案を行う。

2. 従来のパラメータ更新法について

Ben-Akivaら(1988)のグループでは、集計データの信頼性(分散など)が不明なことから、ポアソン分布を当てはめた方法論を開発しているが、個々の観測値が平均と標準偏差の等しい独立な分布に従う仮定は現実的とはいえない。また、森地ら(1987)は、離散選択モデルのパラメータ推定時や移転時に追加的に得られる集計データを用いて、信頼性や再現性のより高いパラメータ値を得る方法論を提案した。集計データの誤差分布を正規分布とすることで、集計データの持つ信頼性を更新手続きに取り込むことに成功している。以下にこのベイズ更新法の概要を示す。

離散選択モデル(例えば、ロジット型モデル)のパラメータ θ が、個人データだけを用いて最尤推定された場合を考える。このパラメータは漸近的に正規分布に従うため、以下のような密度関数を持つ確率変数と見なすことができる。

$$f(\theta) \propto \exp\left[-\frac{1}{2}(\theta - \theta_d)^T \Sigma_d^{-1}(\theta - \theta_d)\right] \quad (1)$$

これは平均 θ_d で分散共分散マトリクスが Σ_d の多項正規分布である。ここで、集計データ行列が Q で与えられ、その値の離散選択モデルを用いた推計値を $Q(\theta)$ で表し、 Q

を正規分布に従う誤差 ε を用いて、

$$Q = Q(\theta) + \varepsilon \quad (2)$$

と表せば、パラメータ θ の事後確率密度は、

$$f(\theta | Q) = f(\theta) \cdot L(Q | \theta) \quad (3)$$

によって表される。ここで、尤度関数 $L(Q | \theta)$ は、

$$L(Q | \theta) \propto \exp\left[-\frac{1}{2}(Q - Q(\theta))^T \Sigma_\varepsilon^{-1}(Q - Q(\theta))\right] \quad (4)$$

であるから、結局事後密度関数は、

$$f(\theta | Q) \propto \exp\left\{-\frac{1}{2}(\theta - \theta_d)^T \Sigma_d^{-1}(\theta - \theta_d) - \frac{1}{2}(Q - Q(\theta))^T \Sigma_\varepsilon^{-1}(Q - Q(\theta))\right\} \quad (5)$$

であり、この式の最大化によって、新たなパラメータ θ^* を決められる。実際の計算において、 Q に何をを用いるかは、それが離散選択モデルを用いて推計できる値でありさえすれば他に際だった制約条件はいらない。したがって、大変応用範囲の広い更新方法である。

3. 多項分布を用いたパラメータの更新方法

以上の更新方法では、追加的な集計データの信頼性を表す分散が必要であったが、必ずしも明らかでない。また、誤差の設定における今一つの仮定である「選択肢間の独立性」については、更新するモデルがシフトモデルであることを考えると必ずしも適当であったとは言えない。そこで、本研究では集計データの分布に多項分布を用いることによって、交通機関などの選択肢間の競合関係を考慮した分布形を設定し、データの誤差分散について明示的な設定行わない方法をまず提案した。ここでは、段階的な更新方法を述べる。したがって、通常の最尤法で離散選択モデルのパラメータを推定した後に、集計データの分布に次の分布を当てはめて、ベイズ更新による新しいパラメータを得る計算手順となる。

交通量 $X_1, X_2, X_3, \dots, X_k$ が

$$\frac{X!}{X_1! \cdot X_2! \cdot \dots \cdot X_k!} p_1^{X_1} \dots p_{k-1}^{X_{k-1}} (1 - p_1 - \dots - p_{k-1})^{X_k} \quad (6)$$

なる多項分布に従うと考える。ここで、 X は総交通量、 p にはディリクレ分布と離散選択モデルより得られるシェアを当てはめることによって、従来と同様な考え方に基づくディリクレパラメータの更新方法を作り出せる。上式(6)が追加データによる尤度関数に相当するため、複数のODペアで複数の交通手段の交通量 X_{jk} が観測された場合を想定すると、尤度 $L_a(=L(X|\theta))$ は、

$$L_a = \prod_{j=1}^J \frac{X_j!}{x_{j1}! \cdots x_{jk}!} p_{j1}^{x_{j1}} \cdots p_{jk}^{x_{jk}} (1 - p_{j1} - \cdots - p_{jk})^{X_j - x_{j1} - \cdots - x_{jk}} \quad (7)$$

によって表される。ここで J はODペアの個数を表し、 j がそのうちの各ODに対応する。したがって、 X_{ji} 、 p_{ji} は各々、ODペア j の交通機関 i の観測交通量とモデルによる推計シェアを表す。この場合、事前分布が非集計サンプルから作成した離散選択モデルのパラメータ分布(1式)である。したがって、事後確率密度は(3)式と同様でありこの分布を対数変換すれば

$$\begin{aligned} \ln f(\theta|q) &= \ln f(\theta) + \ln L(q|\theta) \\ &= -\frac{1}{2}(\theta - \theta_d)^T \Sigma_d^{-1}(\theta - \theta_d) \\ &\quad + \sum_{j=1}^J \sum_{k=1}^K \{X_{jk}\} \ln p_{jk} + C \end{aligned} \quad (8)$$

$$C = \ln \prod_{j=1}^J \frac{X_j!}{x_{j1}! \cdots x_{jk}!} \quad (9)$$

である。(8)式の最大値を求めれば新しいパラメータ θ を得られる。(8)式の第1項は最小2乗法と同等な線形式であるが、第2項には選択確率 p_{jk} が含まれ θ に関する非線形項になっているため、この計算には非線形最適化計算が必要である。

4. ディリクレ分布を用いたパラメータの更新方法

交通量 $X_1, X_2, X_3, \dots, X_k$ がパラメータ $(\alpha, q_1), (\alpha, q_2), (\alpha, q_3), \dots, (\alpha, q_k)$ の独立なディリクレ分布に従うとすれば、その比 z_i

$$z_i = X_i / (X_1 + \cdots + X_k), i=1, \dots, k \quad (10)$$

の同時確率密度関数は、

$$\frac{\Gamma(q_1 + \cdots + q_k)}{\Gamma(q_1) \cdots \Gamma(q_k)} z_1^{q_1-1} \cdots z_{k-1}^{q_{k-1}-1} (1 - z_1 - \cdots - z_{k-1})^{q_k-1} \quad (11)$$

なるディリクレ分布に従う。ここで q_i は以下の式で表されると仮定する。

$$q_i = T \cdot p_i(\theta) \quad (12)$$

T は総交通量、 $p_i(\theta)$ は離散選択モデルより得られるシ

アである。この時、 q_i が交通量であるため整数で近似したガン関数にスターリング公式を当てはめることにより

$$\frac{\Gamma(q_1 + \cdots + q_k)}{\Gamma(q_1) \cdots \Gamma(q_k)} = \frac{T! \cdot q_1 \cdots q_k}{q_1! \cdots q_k! \cdot T} \quad (13)$$

を得る。この関係を用いれば、尤度関数 $L(q|\theta)$ は、

$$\begin{aligned} \ln(q|\theta) &= \ln(T!) - \sum \ln(q_i!) \\ &\quad + \sum \ln(q_i) + \ln T + \sum (q_i - 1) \ln z_i \\ &= \sum (q_i - 1) \ln \frac{z_i}{q_i} + C \end{aligned} \quad (14)$$

である。ここで3.で述べた多項分布の場合と同様にベイズ更新の手続きに乗せると、

$$\begin{aligned} \ln f(\theta|q) &= -\frac{1}{2}(\theta - \theta_d)^T \Sigma_d^{-1}(\theta - \theta_d) \\ &\quad + \sum_{j=1}^J \sum_{k=1}^K (q_{jk} - 1) \ln \frac{z_{jk}}{q_{jk}} + C' \end{aligned} \quad (16)$$

である。この(16)式の最大化をすることによって新しいパラメータ θ を得られる。 C と C' はパラメータ θ には無関係な定数項である。

表1にパラメータ更新結果を示す。パラメータ更新を行ったモデルは、平成2年度に実施した家庭訪問調査より作成した非集計ディリクレ型、高速道選択モデルである。調査は京浜地域を対象にし、目的地は伊豆・箱根・三浦・房総に限定した。回収票は1048票、モデル作成に用いたサンプルは777サンプルである。このモデルをもとに、同年実施の道路交通量調査より得た29ゾーンの経路別集計データを用いて更新した。

表1. パラメータ更新結果

	非集計モデル のパラメータ	多項分布 による更新結果	ディリクレ分布 による更新結果
総時間(時間)	-0.00845	-0.0173	-0.0156
総費用(円)	-0.00201	-0.000181	-0.000121
海沿い距離(km)	0.0171	0.0133	0.0141
定数項	-0.0889	-0.905	-0.922

5. おわりに

本研究は、従来より提案されていたベイズ更新方法を集計データに対する異なる仮定に基づいて定式化したものである。構造化された多項分布を用いた方法と、ディリクレ分布を用いた方法の2つの更新法の提案を行った。

[参考文献]

森地 茂、屋井 鉄雄、平井節生：
個人データと集計データとの統合利用によるモデル構築方法
土木計画学研究論文集，No 5，pp51-58，1987