

二項選択ロジットモデルによる集計誤差に関する一考察

広島大学 正員 門田博知

広島大学 正員 ○加藤文教

1. まえがき

非集計行動モデルは、個人の交通行動をより直接的に説明しようとするものであり、地域間移動可能性や短期の交通運営政策の評価に対して、有意なモデルであることは近年の研究で明らかにされてつある。これらでは長期にわたる交通需要予測という点に関してよりも、たとえばより精度よく交通機関選択構造の現況を説明するために検討が進められている。本研究も同様の観点から二機関選択ロジットモデルを用いてその集計化の手法を検討したものであり、立場としては需要予測の前段階に位置していると言える。また非集計行動モデルの集計化に関する研究としては、運輸省のレポートやFred A. Reid¹⁾等の研究があり、共に集計レベルを小分割にすればする程その精度は高くなるという結論を得ているが、我が国ではまだ研究事例が少ない。さらに本研究では、非集計行動モデルが短期の交通運営政策の評価に適しているという点に着目し、集計化の手法を交通運営政策の評価に導入することによって評価方法の簡略化に関しても考察を加えている。

その結果Naive Methodは、集計精度および交通運営政策の評価への適用性に関してClassification MethodおよびEnumeration Methodとほとんど同程度であり、計算が非常に容易であるという利点もあって集計手法として有効な手法であることがわかった。以下ではこの点に関して説明していくものとする。

なお解析は広島都市圏を対象地域として行ったが、資料は昭和54年10月広島市が実施した交通問題意識調査の調査結果の内、ピーク時に最も関連の深い通勤トリップに関するものから得た。

2. 調査の概要と解析対象トリップ

調査は広島市および周辺6町を含む広島都市圏を対象として行われたが、この内通勤トリップに関しては、総世帯数388,223の約1.5%に当たる6,000世帯を無作為に抽出し行われた。なおゾーン区分は旧広島市(1~18)、周辺部(19~40)であるが、実際に調査が実施されたのは1~38の38ゾーンである。調査状況は表1に示す通りであるが、交通問題が都市部流入地点に発生していること等を考慮し、旧広島市では1ゾーン当り約40票、周辺部では約220票と周辺部に重点を置いて調査票が配布された。また今回の解析に当たってもこの点を考慮し、CBD地区に目的地をもつ通勤トリップを対象とした。

主な調査項目は表2に示す通りであり、以下の3項目を意図して行われた。1. 交通機関利用者の意識の把握 2. 将来の公共交通機関利用におけるサービス水準の目標設定 3. 非集計型交通手段選択モデルの作成。

表1 調査状況

抽出世帯数	6,000
内 旧市内1ゾーン当り抽出数	約 70
周辺部1ゾーン当り抽出数	約 220
通勤目的回答者数	5,321
回収率	95.9%
有効解答率	87.5%

表2 主な調査項目

1. 対象者の属性	年齢、性別、職業、自然、自動車保有状況、自動車利用状況および利用目的、公共交通機関利用状況および利用目的、居住地選択理由
2. 公共交通機関の利用状況	アクセス手段、アクセス時間、利用交通機関、運行間隔、乗車時間、料金、定時性、車内混雑状況、乗り換え状況、総所要時間
3. 自動車利用の実態	所要時間、定時性、道路混雑、駐車場利用状況、自動車利用をやめない理由およびやめてもよい理由

3. 二項選択ロジットモデルの作成

ここでは次のような二項選択ロジットモデルを用いた。

$$P_j = \frac{1}{1 + e^{-Z_j}} \quad , \quad Z_j = \beta_0 + \sum_{k=1}^m \beta_k X_{jk} \quad (1) \quad \text{ただし} \quad \begin{aligned} P_j &: \text{個人} j \text{の選択確率} & Z_j &: \text{個人} j \text{の効用} \\ \beta_0 &: \text{定数項} & \beta_k &: \text{変数} X_{jk} \text{のパラメータ} \\ X_{jk} &: \text{変数の値} & m &: \text{変数の数} \end{aligned}$$

なおモデルを作成するに当たって、変数として組み込む調査項目すべてに解答していることをチェックした結果、全サンプル数は881であった。

始めに15変数モデルを作成した。各変数とその内容、およびパラメータとその値は表3に示す通りである。この結果をもとに、多重共線性、および集計化の手順等を考慮し、表4に示すモデル1～モデル5を決定した。

表5は、モデルに組み込んだ各変数の平均値を示したものである。全サンプルの内、男が約80%、車有が約80%と大半を占めており、男では車有が約90%であるのに対して女では約40%となっている。マストラの分担率との関係を見みると、男(=0.483)に対して女(=0.723)、車有(=0.443)に対して車無(=0.857)、とキャパティバな条件が機関選択の上に関係していることがわかる。また乗車時間やコストをみると、車有と車無とのサンプルの間にはかなり大きな

表4 二項選択ロジットモデル

変数	モデル1	モデル2	モデル3	モデル4	モデル5
性別 (男=1, 女=0)		-0.6025 (5.38)		-0.1978 (1.57)	-0.2050 (1.74)
年齢	-0.00372 (1.04)	0.000164 (0.02)	-0.00417 (1.08)	-0.00307 (0.78)	
車有 (車有=1, 車無=0)			-1.0502 (8.71)	-0.9627 (7.32)	-0.9521 (7.29)
乗車時間差	-0.00722 (4.52)	-0.00787 (4.80)	-0.0100 (4.21)	-0.0102 (4.87)	-0.0102 (4.87)
コスト差	-0.000674 (6.52)	-0.000728 (6.57)	-0.000728 (6.18)	-0.000727 (6.21)	-0.000741 (6.25)
乗換回数	-0.1202 (1.67)	-0.0963 (1.31)	-0.0642 (0.85)	-0.0609 (0.80)	-0.0618 (0.82)
運行間隔	-0.00690 (0.12)	-0.00785 (0.13)	-0.00749 (0.24)	-0.00744 (0.22)	-0.00744 (0.22)
定数項	0.2217	0.5661	1.1007	1.1397	1.0328
的中率	42.77	62.54	70.49	71.06	70.83
$\bar{R}^2$	0.080	0.110	0.162	0.163	0.163

* 乗車時間差およびコスト差: MT-CAR

表3 使用変数

変数	変数の内容	パラメータ (t値)
住所	旧広島市1区, 周辺部=0	-0.0899 (0.787)
性別	男=1, 女=0	-0.1917 (1.582)
年齢		-0.004584 (0.743)
車有	有=1, 無=0	-1.0050 (7.527)
乗車時間差	$T_1^{(m)} - T_1^{(c)}$	0.00365 (0.762)
乗車時間差	$T_2^{(m)} - T_2^{(c)}$	-0.0146 (3.624)
乗車時間差	$T_3^{(m)} - T_3^{(c)}$	-0.0174 (0.004)
トリップ長	乗車時間: MT-CAR+17.12	-0.2E-6 (0.023)
コスト差	$C^{(m)} - C^{(c)}$	-0.000705 (5.852)
乗換回数	$C_1^{(m)} - C_1^{(c)}$	-0.1079 (1.345)
運行間隔	$I^{(m)} - I^{(c)}$	-0.0072 (2.899)
定時性差	MT-CAR=1, 乗車時間=0	0.0404 (0.631)
乗車時間差	CAR-CAR=1, 乗車時間=0	0.0180 (0.224)
コスト差	$T_1^{(m)} - T_1^{(c)}$	0.00728 (0.0017)
コスト差	$T_2^{(m)} - T_2^{(c)}$	0.00372 (0.0097)

* () 内の数字はマストラ, C は CAR を示す。
 * ① ② ③ ④ ⑤ ⑥ ⑦ ⑧ ⑨ ⑩ ⑪ ⑫ ⑬ ⑭ ⑮ ⑯ ⑰ ⑱ ⑲ ⑳ ㉑ ㉒ ㉓ ㉔ ㉕ ㉖ ㉗ ㉘ ㉙ ㉚ ㉛ ㉜ ㉝ ㉞ ㉟ ㊱ ㊲ ㊳ ㊴ ㊵ ㊶ ㊷ ㊸ ㊹ ㊺ ㊻ ㊼ ㊽ ㊾ ㊿ ㏀ ㏁ ㏂ ㏃ ㏄ ㏅ ㏆ ㏇ ㏈ ㏉ ㏊ ㏋ ㏌ ㏍ ㏎ ㏏ ㏐ ㏑ ㏒ ㏓ ㏔ ㏕ ㏖ ㏗ ㏘ ㏙ ㏚ ㏛ ㏜ ㏝ ㏞ ㏟ ㏠ ㏡ ㏢ ㏣ ㏤ ㏥ ㏦ ㏧ ㏨ ㏩ ㏪ ㏫ ㏬ ㏭ ㏮ ㏯ ㏰ ㏱ ㏲ ㏳ ㏴ ㏵ ㏶ ㏷ ㏸ ㏹ ㏺ ㏻ ㏼ ㏽ ㏾ ㏿ 㐀 㐁 㐂 㐃 㐄 㐅 㐆 㐇 㐈 㐉 㐊 㐋 㐌 㐍 㐎 㐏 㐐 㐑 㐒 㐓 㐔 㐕 㐖 㐗 㐘 㐙 㐚 㐛 㐜 㐝 㐞 㐟 㐠 㐡 㐢 㐣 㐤 㐥 㐦 㐧 㐨 㐩 㐪 㐫 㐬 㐭 㐮 㐯 㐰 㐱 㐲 㐳 㐴 㐵 㐶 㐷 㐸 㐹 㐺 㐻 㐼 㐽 㐾 㐿 㑀 㑁 㑂 㑃 㑄 㑅 㑆 㑇 㑈 㑉 㑊 㑋 㑌 㑍 㑎 㑏 㑐 㑑 㑒 㑓 㑔 㑕 㑖 㑗 㑘 㑙 㑚 㑛 㑜 㑝 㑞 㑟 㑠 㑡 㑢 㑣 㑤 㑥 㑦 㑧 㑨 㑩 㑪 㑫 㑬 㑭 㑮 㑯 㑰 㑱 㑲 㑳 㑴 㑵 㑶 㑷 㑸 㑹 㑺 㑻 㑼 㑽 㑾 㑿 㒀 㒁 㒂 㒃 㒄 㒅 㒆 㒇 㒈 㒉 㒊 㒋 㒌 㒍 㒎 㒏 㒐 㒑 㒒 㒓 㒔 㒕 㒖 㒗 㒘 㒙 㒚 㒛 㒜 㒝 㒞 㒟 㒠 㒡 㒢 㒣 㒤 㒥 㒦 㒧 㒨 㒩 㒪 㒫 㒬 㒭 㒮 㒯 㒰 㒱 㒲 㒳 㒴 㒵 㒶 㒷 㒸 㒹 㒺 㒻 㒼 㒽 㒾 㒿 㓀 㓁 㓂 㓃 㓄 㓅 㓆 㓇 㓈 㓉 㓊 㓋 㓌 㓍 㓎 㓏 㓐 㓑 㓒 㓓 㓔 㓕 㓖 㓗 㓘 㓙 㓚 㓛 㓜 㓝 㓞 㓟 㓠 㓡 㓢 㓣 㓤 㓥 㓦 㓧 㓨 㓩 㓪 㓫 㓬 㓭 㓮 㓯 㓰 㓱 㓲 㓳 㓴 㓵 㓶 㓷 㓸 㓹 㓺 㓻 㓼 㓽 㓾 㓿 㔀 㔁 㔂 㔃 㔄 㔅 㔆 㔇 㔈 㔉 㔊 㔋 㔌 㔍 㔎 㔏 㔐 㔑 㔒 㔓 㔔 㔕 㔖 㔗 㔘 㔙 㔚 㔛 㔜 㔝 㔞 㔟 㔠 㔡 㔢 㔣 㔤 㔥 㔦 㔧 㔨 㔩 㔪 㔫 㔬 㔭 㔮 㔯 㔰 㔱 㔲 㔳 㔴 㔵 㔶 㔷 㔸 㔹 㔺 㔻 㔼 㔽 㔾 㔿 㕀 㕁 㕂 㕃 㕄 㕅 㕆 㕇 㕈 㕉 㕊 㕋 㕌 㕍 㕎 㕏 㕐 㕑 㕒 㕓 㕔 㕕 㕖 㕗 㕘 㕙 㕚 㕛 㕜 㕝 㕞 㕟 㕠 㕡 㕢 㕣 㕤 㕥 㕦 㕧 㕨 㕩 㕪 㕫 㕬 㕭 㕮 㕯 㕰 㕱 㕲 㕳 㕴 㕵 㕶 㕷 㕸 㕹 㕺 㕻 㕼 㕽 㕾 㕿 㖀 㖁 㖂 㖃 㖄 㖅 㖆 㖇 㖈 㖉 㖊 㖋 㖌 㖍 㖎 㖏 㖐 㖑 㖒 㖓 㖔 㖕 㖖 㖗 㖘 㖙 㖚 㖛 㖜 㖝 㖞 㖟 㖠 㖡 㖢 㖣 㖤 㖥 㖦 㖧 㖨 㖩 㖪 㖫 㖬 㖭 㖮 㖯 㖰 㖱 㖲 㖳 㖴 㖵 㖶 㖷 㖸 㖹 㖺 㖻 㖼 㖽 㖾 㖿 㗀 㗁 㗂 㗃 㗄 㗅 㗆 㗇 㗈 㗉 㗊 㗋 㗌 㗍 㗎 㗏 㗐 㗑 㗒 㗓 㗔 㗕 㗖 㗗 㗘 㗙 㗚 㗛 㗜 㗝 㗞 㗟 㗠 㗡 㗢 㗣 㗤 㗥 㗦 㗧 㗨 㗩 㗪 㗫 㗬 㗭 㗮 㗯 㗰 㗱 㗲 㗳 㗴 㗵 㗶 㗷 㗸 㗹 㗺 㗻 㗼 㗽 㗾 㗿 㘀 㘁 㘂 㘃 㘄 㘅 㘆 㘇 㘈 㘉 㘊 㘋 㘌 㘍 㘎 㘏 㘐 㘑 㘒 㘓 㘔 㘕 㘖 㘗 㘘 㘙 㘚 㘛 㘜 㘝 㘞 㘟 㘠 㘡 㘢 㘣 㘤 㘥 㘦 㘧 㘨 㘩 㘪 㘫 㘬 㘭 㘮 㘯 㘰 㘱 㘲 㘳 㘴 㘵 㘶 㘷 㘸 㘹 㘺 㘻 㘼 㘽 㘾 㘿 㙀 㙁 㙂 㙃 㙄 㙅 㙆 㙇 㙈 㙉 㙊 㙋 㙌 㙍 㙎 㙏 㙐 㙑 㙒 㙓 㙔 㙕 㙖 㙗 㙘 㙙 㙚 㙛 㙜 㙝 㙞 㙟 㙠 㙡 㙢 㙣 㙤 㙥 㙦 㙧 㙨 㙩 㙪 㙫 㙬 㙭 㙮 㙯 㙰 㙱 㙲 㙳 㙴 㙵 㙶 㙷 㙸 㙹 㙺 㙻 㙼 㙽 㙾 㙿 㚀 㚁 㚂 㚃 㚄 㚅 㚆 㚇 㚈 㚉 㚊 㚋 㚌 㚍 㚎 㚏 㚐 㚑 㚒 㚓 㚔 㚕 㚖 㚗 㚘 㚙 㚚 㚛 㚜 㚝 㚞 㚟 㚠 㚡 㚢 㚣 㚤 㚥 㚦 㚧 㚨 㚩 㚪 㚫 㚬 㚭 㚮 㚯 㚰 㚱 㚲 㚳 㚴 㚵 㚶 㚷 㚸 㚹 㚺 㚻 㚼 㚽 㚾 㚿 㜀 㜁 㜂 㜃 㜄 㜅 㜆 㜇 㜈 㜉 㜊 㜋 㜌 㜍 㜎 㜏 㜐 㜑 㜒 㜓 㜔 㜕 㜖 㜗 㜘 㜙 㜚 㜛 㜜 㜝 㜞 㜟 㜠 㜡 㜢 㜣 㜤 㜥 㜦 㜧 㜨 㜩 㜪 㜫 㜬 㜭 㜮 㜯 㜰 㜱 㜲 㜳 㜴 㜵 㜶 㜷 㜸 㜹 㜺 㜻 㜼 㜽 㜾 㜿 㝀 㝁 㝂 㝃 㝄 㝅 㝆 㝇 㝈 㝉 㝊 㝋 㝌 㝍 㝎 㝏 㝐 㝑 㝒 㝓 㝔 㝕 㝖 㝗 㝘 㝙 㝚 㝛 㝜 㝝 㝞 㝟 㝠 㝡 㝢 㝣 㝤 㝥 㝦 㝧 㝨 㝩 㝪 㝫 㝬 㝭 㝮 㝯 㝰 㝱 㝲 㝳 㝴 㝵 㝶 㝷 㝸 㝹 㝺 㝻 㝼 㝽 㝾 㝿 㞀 㞁 㞂 㞃 㞄 㞅 㞆 㞇 㞈 㞉 㞊 㞋 㞌 㞍 㞎 㞏 㞐 㞑 㞒 㞓 㞔 㞕 㞖 㞗 㞘 㞙 㞚 㞛 㞜 㞝 㞞 㞟 㞠 㞡 㞢 㞣 㞤 㞥 㞦 㞧 㞨 㞩 㞪 㞫 㞬 㞭 㞮 㞯 㞰 㞱 㞲 㞳 㞴 㞵 㞶 㞷 㞸 㞹 㞺 㞻 㞼 㞽 㞾 㞿 㟀 㟁 㟂 㟃 㟄 㟅 㟆 㟇 㟈 㟉 㟊 㟋 㟌 㟍 㟎 㟏 㟐 㟑 㟒 㟓 㟔 㟕 㟖 㟗 㟘 㟙 㟚 㟛 㟜 㟝 㟞 㟟 㟠 㟡 㟢 㟣 㟤 㟥 㟦 㟧 㟨 㟩 㟪 㟫 㟬 㟭 㟮 㟯 㟰 㟱 㟲 㟳 㟴 㟵 㟶 㟷 㟸 㟹 㟺 㟻 㟼 㟽 㟾 㟿 㠀 㠁 㠂 㠃 㠄 㠅 㠆 㠇 㠈 㠉 㠊 㠋 㠌 㠍 㠎 㠏 㠐 㠑 㠒 㠓 㠔 㠕 㠖 㠗 㠘 㠙 㠚 㠛 㠜 㠝 㠞 㠟 㠠 㠡 㠢 㠣 㠤 㠥 㠦 㠧 㠨 㠩 㠪 㠫 㠬 㠭 㠮 㠯 㠰 㠱 㠲 㠳 㠴 㠵 㠶 㠷 㠸 㠹 㠺 㠻 㠼 㠽 㠾 㠿 㡀 㡁 㡂 㡃 㡄 㡅 㡆 㡇 㡈 㡉 㡊 㡋 㡌 㡍 㡎 㡏 㡐 㡑 㡒 㡓 㡔 㡕 㡖 㡗 㡘 㡙 㡚 㡛 㡜 㡝 㡞 㡟 㡠 㡡 㡢 㡣 㡤 㡥 㡦 㡧 㡨 㡩 㡪 㡫 㡬 㡭 㡮 㡯 㡰 㡱 㡲 㡳 㡴 㡵 㡶 㡷 㡸 㡹 㡺 㡻 㡼 㡽 㡾 㡿 㢀 㢁 㢂 㢃 㢄 㢅 㢆 㢇 㢈 㢉 㢊 㢋 㢌 㢍 㢎 㢏 㢐 㢑 㢒 㢓 㢔 㢕 㢖 㢗 㢘 㢙 㢚 㢛 㢜 㢝 㢞 㢟 㢠 㢡 㢢 㢣 㢤 㢥 㢦 㢧 㢨 㢩 㢪 㢫 㢬 㢭 㢮 㢯 㢰 㢱 㢲 㢳 㢴 㢵 㢶 㢷 㢸 㢹 㢺 㢻 㢼 㢽 㢾 㢿 㣀 㣁 㣂 㣃 㣄 㣅 㣆 㣇 㣈 㣉 㣊 㣋 㣌 㣍 㣎 㣏 㣐 㣑 㣒 㣓 㣔 㣕 㣖 㣗 㣘 㣙 㣚 㣛 㣜 㣝 㣞 㣟 㣠 㣡 㣢 㣣 㣤 㣥 㣦 㣧 㣨 㣩 㣪 㣫 㣬 㣭 㣮 㣯 㣰 㣱 㣲 㣳 㣴 㣵 㣶 㣷 㣸 㣹 㣺 㣻 㣼 㣽 㣾 㣿 㤀 㤁 㤂 㤃 㤄 㤅 㤆 㤇 㤈 㤉 㤊 㤋 㤌 㤍 㤎 㤏 㤐 㤑 㤒 㤓 㤔 㤕 㤖 㤗 㤘 㤙 㤚 㤛 㤜 㤝 㤞 㤟 㤠 㤡 㤢 㤣 㤤 㤥 㤦 㤧 㤨 㤩 㤪 㤫 㤬 㤭 㤮 㤯 㤰 㤱 㤲 㤳 㤴 㤵 㤶 㤷 㤸 㤹 㤺 㤻 㤼 㤽 㤾 㤿 㥀 㥁 㥂 㥃 㥄 㥅 㥆 㥇 㥈 㥉 㥊 㥋 㥌 㥍 㥎 㥏 㥐 㥑 㥒 㥓 㥔 㥕 㥖 㥗 㥘 㥙 㥚 㥛 㥜 㥝 㥞 㥟 㥠 㥡 㥢 㥣 㥤 㥥 㥦 㥧 㥨 㥩 㥪 㥫 㥬 㥭 㥮 㥯 㥰 㥱 㥲 㥳 㥴 㥵 㥶 㥷 㥸 㥹 㥺 㥻 㥼 㥽 㥾 㥿 㦀 㦁 㦂 㦃 㦄 㦅 㦆 㦇 㦈 㦉 㦊 㦋 㦌 㦍 㦎 㦏 㦐 㦑 㦒 㦓 㦔 㦕 㦖 㦗 㦘 㦙 㦚 㦛 㦜 㦝 㦞 㦟 㦠 㦡 㦢 㦣 㦤 㦥 㦦 㦧 㦨 㦩 㦪 㦫 㦬 㦭 㦮 㦯 㦰 㦱 㦲 㦳 㦴 㦵 㦶 㦷 㦸 㦹 㦺 㦻 㦼 㦽 㦾 㦿 㧀 㧁 㧂 㧃 㧄 㧅 㧆 㧇 㧈 㧉 㧊 㧋 㧌 㧍 㧎 㧏 㧐 㧑 㧒 㧓 㧔 㧕 㧖 㧗 㧘 㧙 㧚 㧛 㧜 㧝 㧞 㧟 㧠 㧡 㧢 㧣 㧤 㧥 㧦 㧧 㧨 㧩 㧪 㧫 㧬 㧭 㧮 㧯 㧰 㧱 㧲 㧳 㧴 㧵 㧶 㧷 㧸 㧹 㧺 㧻 㧼 㧽 㧾 㧿 㨀 㨁 㨂 㨃 㨄 㨅 㨆 㨇 㨈 㨉 㨊 㨋 㨌 㨍 㨎 㨏 㨐 㨑 㨒 㨓 㨔 㨕 㨖 㨗 㨘 㨙 㨚 㨛 㨜 㨝 㨞 㨟 㨠 㨡 㨢 㨣 㨤 㨥 㨦 㨧 㨨 㨩 㨪 㨫 㨬 㨭 㨮 㨯 㨰 㨱 㨲 㨳 㨴 㨵 㨶 㨷 㨸 㨹 㨺 㨻 㨼 㨽 㨾 㨿 㩀 㩁 㩂 㩃 㩄 㩅 㩆 㩇 㩈 㩉 㩊 㩋 㩌 㩍 㩎 㩏 㩐 㩑 㩒 㩓 㩔 㩕 㩖 㩗 㩘 㩙 㩚 㩛 㩜 㩝 㩞 㩟 㩠 㩡 㩢 㩣 㩤 㩥 㩦 㩧 㩨 㩩 㩪 㩫 㩬 㩭 㩮 㩯 㩰 㩱 㩲 㩳 㩴 㩵 㩶 㩷 㩸 㩹 㩺 㩻 㩼 㩽 㩾 㩿 㪀 㪁 㪂 㪃 㪄 㪅 㪆 㪇 㪈 㪉 㪊 㪋 㪌 㪍 㪎 㪏 㪐 㪑 㪒 㪓 㪔 㪕 㪖 㪗 㪘 㪙 㪚 㪛 㪜 㪝 㪞 㪟 㪠 㪡 㪢 㪣 㪤 㪥 㪦 㪧 㪨 㪩 㪪 㪫 㪬 㪭 㪮 㪯 㪰 㪱 㪲 㪳 㪴 㪵 㪶 㪷 㪸 㪹 㪺 㪻 㪼 㪽 㪾 㪿 㫀 㫁 㫂 㫃 㫄 㫅 㫆 㫇 㫈 㫉 㫊 㫋 㫌 㫍 㫎 㫏 㫐 㫑 㫒 㫓 㫔 㫕 㫖 㫗 㫘 㫙 㫚 㫛 㫜 㫝 㫞 㫟 㫠 㫡 㫢 㫣 㫤 㫥 㫦 㫧 㫨 㫩 㫪 㫫 㫬 㫭 㫮 㫯 㫰 㫱 㫲 㫳 㫴 㫵 㫶 㫷 㫸 㫹 㫺 㫻 㫼 㫽 㫾 㫿 㬀 㬁 㬂 㬃 㬄 㬅 㬆 㬇 㬈 㬉 㬊 㬋 㬌 㬍 㬎 㬏 㬐 㬑 㬒 㬓 㬔 㬕 㬖 㬗 㬘 㬙 㬚 㬛 㬜 㬝 㬞 㬟 㬠 㬡 㬢 㬣 㬤 㬥 㬦 㬧 㬨 㬩 㬪 㬫 㬬 㬭 㬮 㬯 㬰 㬱 㬲 㬳 㬴 㬵 㬶 㬷 㬸 㬹 㬺 㬻 㬼 㬽 㬾 㬿 㭀 㭁 㭂 㭃 㭄 㭅 㭆 㭇 㭈 㭉 㭊 㭋 㭌 㭍 㭎 㭏 㭐 㭑 㭒 㭓 㭔 㭕 㭖 㭗 㭘 㭙 㭚 㭛 㭜 㭝 㭞 㭟 㭠 㭡 㭢 㭣 㭤 㭥 㭦 㭧 㭨 㭩 㭪 㭫 㭬 㭭 㭮 㭯 㭰 㭱 㭲 㭳 㭴 㭵 㭶 㭷 㭸 㭹 㭺 㭻 㭼 㭽 㭾 㭿 㮀 㮁 㮂 㮃 㮄 㮅 㮆 㮇 㮈 㮉 㮊 㮋 㮌 㮍 㮎 㮏 㮐 㮑 㮒 㮓 㮔 㮕 㮖 㮗 㮘 㮙 㮚 㮛 㮜 㮝 㮞 㮟 㮠 㮡 㮢 㮣 㮤 㮥 㮦 㮧 㮨 㮩 㮪 㮫 㮬 㮭 㮮 㮯 㮰 㮱 㮲 㮳 㮴 㮵 㮶 㮷 㮸 㮹 㮺 㮻 㮼 㮽 㮾 㮿 㯀 㯁 㯂 㯃 㯄 㯅 㯆 㯇 㯈 㯉 㯊 㯋 㯌 㯍 㯎 㯏 㯐 㯑 㯒 㯓 㯔 㯕 㯖 㯗 㯘 㯙 㯚 㯛 㯜 㯝 㯞 㯟 㯠 㯡 㯢 㯣 㯤 㯥 㯦 㯧 㯨 㯩 㯪 㯫 㯬 㯭 㯮 㯯 㯰 㯱 㯲 㯳 㯴 㯵 㯶 㯷 㯸 㯹 㯺 㯻 㯼 㯽 㯾 㯿 㰀 㰁 㰂 㰃 㰄 㰅 㰆 㰇 㰈 㰉 㰊 㰋 㰌 㰍 㰎 㰏 㰐 㰑 㰒 㰓 㰔 㰕 㰖 㰗 㰘 㰙 㰚 㰛 㰜 㰝 㰞 㰟 㰠 㰡 㰢 㰣 㰤 㰥 㰦 㰧 㰨 㰩 㰪 㰫 㰬 㰭 㰮 㰯 㰰 㰱 㰲 㰳 㰴 㰵 㰶 㰷 㰸 㰹 㰺 㰻 㰼 㰽 㰾 㰿 㱀 㱁 㱂 㱃 㱄 㱅 㱆 㱇 㱈 㱉 㱊 㱋 㱌 㱍 㱎 㱏 㱐 㱑 㱒 㱓 㱔 㱕 㱖 㱗 㱘 㱙 㱚 㱛 㱜 㱝 㱞 㱟 㱠 㱡 㱢 㱣 㱤 㱥 㱦 㱧 㱨 㱩 㱪 㱫 㱬 㱭 㱮 㱯 㱰 㱱 㱲 㱳 㱴 㱵 㱶 㱷 㱸 㱹 㱺 㱻 㱼 㱽 㱾 㱿 㲀 㲁 㲂 㲃 㲄 㲅 㲆 㲇 㲈 㲉 㲊 㲋 㲌 㲍 㲎 㲏 㲐 㲑 㲒 㲓 㲔 㲕 㲖 㲗 㲘 㲙 㲚 㲛 㲜 㲝 㲞 㲟 㲠 㲡 㲢 㲣 㲤 㲥 㲦 㲧 㲨 㲩 㲪 㲫 㲬 㲭 㲮 㲯 㲰 㲱 㲲 㲳 㲴 㲵 㲶 㲷 㲸 㲹 㲺 㲻 㲼 㲽 㲾 㲿 㳀 㳁 㳂 㳃 㳄 㳅 㳆 㳇 㳈 㳉 㳊 㳋 㳌 㳍 㳎 㳏 㳐 㳑 㳒 㳓 㳔 㳕 㳖 㳗 㳘 㳙 㳚 㳛 㳜 㳝 㳞 㳟 㳠 㳡 㳢 㳣 㳤 㳥 㳦 㳧 㳨 㳩 㳪 㳫 㳬 㳭 㳮 㳯 㳰 㳱 㳲 㳳 㳴 㳵 㳶 㳷 㳸 㳹 㳺 㳻 㳼 㳽 㳾 㳿 㴀 㴁 㴂 㴃 㴄 㴅 㴆 㴇 㴈 㴉 㴊 㴋 㴌 㴍 㴎 㴏 㴐 㴑 㴒 㴓 㴔 㴕 㴖 㴗 㴘 㴙 㴚 㴛 㴜 㴝 㴞 㴟 㴠 㴡 㴢 㴣 㴤 㴥 㴦 㴧 㴨 㴩 㴪 㴫 㴬 㴭 㴮 㴯 㴰 㴱 㴲 㴳 㴴 㴵 㴶 㴷 㴸 㴹 㴺 㴻 㴼 㴽 㴾 㴿 㵀 㵁 㵂 㵃 㵄 㵅 㵆 㵇 㵈 㵉 㵊 㵋 㵌 㵍 㵎 㵏 㵐 㵑 㵒 㵓 㵔 㵕 㵖 㵗 㵘 㵙 㵚 㵛 㵜 㵝 㵞 㵟 㵠 㵡 㵢 㵣 㵤 㵥 㵦 㵧 㵨 㵩 㵪 㵫 㵬 㵭 㵮 㵯 㵰 㵱 㵲 㵳 㵴 㵵 㵶 㵷 㵸 㵹 㵺 㵻 㵼 㵽 㵾 㵿 㶀 㶁 㶂 㶃 㶄 㶅 㶆 㶇 㶈 㶉 㶊 㶋 㶌 㶍 㶎 㶏 㶐 㶑 㶒 㶓 㶔 㶕 㶖 㶗 㶘 㶙 㶚 㶛

1). Enumeration Method

$$P_N = \frac{1}{n} \sum_{j=1}^n P_j \quad (2)$$

ただし P_N : グループN全体の選択確率 P_j : グループNに含まれる個人jの
選択確率 n : グループNのサンプル数

都市圏全体の選択確率を求めると、0.01%以下の誤差で実績値と一致した。今回の解析ではモデルのキャリブレーションに最尤法を用いたが、このことは最尤法のメカニズムからも明らかである。(2)式でわかるように、この手法は個人一人一人の選択確率を積み上げるため、短期の交通運営政策の評価に有効である。その反面多くの計算時間や計算費用を要するという欠点もある。またキャリブレーションに用いたサンプルをグループに分類し、そのグループの選択確率を予測する場合には誤差が大きくなる。

2). Naive Method

$$P_N = f_j(\bar{X}_k) \quad (3)$$

ただし $\bar{X}_k$: 各変数のグループ平均値。この $\bar{X}_k$ を(1)式に代入しグループ全体の
選択確率を求める。

精度はEnumeration Methodと比較して劣るが、計算が非常に容易であるという利点をもっている。この手法はグループに含まれる個人各々についてこの選択確率の平均ではなく、グループの各変数の平均値(効用の平均値)によってグループの選択確率を求めるため、一般的に誤差が大きい。

3). Classification Method

$$P_N = \sum_{C=1}^m \frac{n_C}{N} f_j(\bar{X}_{Ck}) \quad (4)$$

ただし $\bar{X}_{Ck}$: サブグループCに
おける各変数の平均値 n_C : サ
ブグループCのサンプル数 N : 全サンプル数

この手法には、地理的レベルでの分類と変数による分類とがあるが、ここは後者によって行った。精度は、分類方法によるところが大きい。Koppelman²⁾は、も値の最も大きい変数によって分類した場合誤差が小さくなると述べている。また小数のサンプル数かなり精度の高い結果が得られるとされている。今回の解析では前述のキャパティブな条件を考慮し、1. 男・女(2分類)、2. 車有・車無(2分類) 3. 男車有・男車無・女車有・女車無(4分類)の3ケースについて検討を加えた。

以上3手法による現況再現性の検討は、Naive MethodとClassification Methodについては表6に、Enumeration Methodについては表7に各々示す通りである。ここでモデル1～5は表4のモデル1～5にそれぞれ対応している。

表6で、相関係数と% RMS誤差に注目すると最も精度の高いのはモデル2、すなわち性別2分類によるClassification Methodであり、以下モデル1、モデル5となっている。ここで表3からわかるようにも値の最も高い変数は車の有無であるのに対して、推計精度は性別2分類した場合がより高く、また性別・車の有無の4分類とした場合よりも性別2分類とした方が精度はより高いことがわかる。このことは事例の研究結果と一致していないが、分類数の問題に関しては事例研究の場合地理的レベルでの検討であり、若干性質の異なっていることに注意を要する。参考としてClassification Methodに関して、サンプルだけでなく、モデルも別々にキャリブレーションして検討した結

表6 NaiveおよびClassificationによる推計

ゾーン	分類率の 実績値	Naive				
		モデル1	モデル2 (性別)	モデル3 (車の有無)	モデル4 (性別・車有・車無)	モデル5 (性別・車有・車無)
旧東部市 中心ゾーン	1	0.532	0.490	0.556	0.605	0.609
	2	0.651	0.569	0.590	0.589	0.588
	3	0.560	0.575	0.616	0.672	0.675
	4	0.600	0.521	0.544	0.555	0.557
	5	0.597	0.556	0.520	0.564	0.554
	6	0.444	0.503	0.442	0.414	0.403
周辺部 (大ゾーン)	17	0.462	0.569	0.545	0.515	0.516
	20	0.615	0.608	0.590	0.572	0.568
	21	0.469	0.547	0.525	0.501	0.499
	22	0.450	0.528	0.491	0.510	0.500
	23	0.431	0.578	0.555	0.580	0.584
	24	0.500	0.512	0.498	0.514	0.506
	25	0.667	0.592	0.586	0.597	0.595
	26	0.630	0.525	0.548	0.491	0.496
	27	0.429	0.599	0.609	0.653	0.652
	28	0.500	0.461	0.475	0.491	0.490
	29	0.677	0.388	0.377	0.376	0.382
	30	0.531	0.573	0.536	0.523	0.518
	31	0.368	0.520	0.534	0.501	0.504
	32	0.441	0.365	0.367	0.335	0.338
	33	0.400	0.498	0.489	0.503	0.501
	34	0.571	0.601	0.596	0.577	0.578
	35	0.611	0.511	0.492	0.498	0.495
	36	0.543	0.515	0.522	0.533	0.532
	37	0.294	0.411	0.403	0.431	0.427
	38	0.524	0.490	0.540	0.539	0.549
平均値		0.516	0.523	0.523	0.523	0.522
相関係数		-0.0064	-0.0065	-0.0063	-0.0061	-0.0057
相関係数		0.2424	0.2899	0.2178	0.2840	0.2449
RMS誤差		19.32	19.33	20.97	20.95	20.66

* E/E1, E2の分類率を示す。

表7 Enumerationによる推計

ゾーン	モデル1	モデル2	モデル3	モデル4	モデル5
平均値	0.519	0.517	0.516	0.516	0.515
相関係数	-0.0027	-0.0028	0.0004	0.0007	0.0010
相関係数	0.3540	0.4408	0.3612	0.3816	0.3840
RMS誤差	18.32	18.09	19.45	19.39	19.24

果、精度はも値の高い変数で分類した場合がより高く、また分類数の多い方がより高いものとなったが、%RMS誤差等の値は表らと比較して若干減少したに過ぎなかった。ゾーン別にみると、23, 27, 28, 31等と実績値と推計値との格差が大きいが、これらは新興住宅地の多いゾーンであり特異な条件を含んでいると思われる。表7をみると、Enumeration Methodの方が、NaiveおよびClassification Method に比べて若干精度が高いことがわかる。しかしながら平均値および残差平均値に注目すると全体としてはほぼ現況を再現しているが、前述したようにキャリブレーションに用いたサンプルをグループに分け、その各々の選択確率を推計する場合には誤差が大きくなることが明確である。さらに全体的にみると、表4に示したモデルの的中率と集計精度との間には関係のないことがわかる。的中率は、モデルをキャリブレーションした場合その精度を示す指標であるが、モデルの精度が高ければ集計精度も高くなるとは言えないようである。また集計精度に関しては3手法ともあまり相違がなく、計算の容易な Naive Method が有効であると言える。

5. 短期交通運営政策の評価への適用

Enumeration Method が短期の交通運営政策の評価に適していることは前述したが、ここでは Enumeration および Naive 両手法によって評価し、その結果を比較検討する。モデルとしてはモデル1を使用し、交通運営政策として、1. マストラの運行間隔の短縮、2. ガソリン代値上げ、3. 乗車時間差の短縮、の3つを取り上げた。その結果は図1に示す通りである。ここガソリン代の値上げは、タクシーおよび同乗を除く CAR 利用のみに影響を及ぼすものとしている。

まず現況値、すなわち現況再現性に注目すると、Enumeration Method は実績値(466人)と一致しており、Naive Method は4人の誤差がある。また転換者数の推移をみると、ガソリン代値上げに対しては両手法ともほとんど一致しているが、他の2政策に対しては若干 Naive Method の方が大きくなる傾向にある。しかしながらその誤差は小さく、交通運営政策の評価に対して、Naive Method が十分適用できるものと考えられる。

参考文献


- 1). 運輸省：大都市圏における交通機関選択に関する調査(1978年3月)
- 2). Fred A. Reid: Aggregation Methods And Tests, The Urban Travel Demand Forecasting Project Final Report Series Volume VII, Institute of Transportation Studies University of California (July 1978)

図1. 交通運営政策の評価

7-772 数: 221 公共交通機関利用人数実績: 466


短縮率	公共交通機関利用人数(人)	
	Enumeration	Naive
1.0 (現況)	466	470
0.9	470	475
0.8	475	481
0.7	479	486
0.6	484	491
0.5	489	497

□ Enum ■ Naive CARからマストラへの転換者数



ガソリン値上げの影響

価格 (円/ℓ)	公共交通機関利用人数(人)	
	Enumeration	Naive
150 (現況)	466	470
170	471	475
190	476	481
210	482	486
230	487	492
250	492	497



乗車時間差短縮の影響

短縮時間 (分)	公共交通機関利用人数(人)	
	Enumeration	Naive
0 (現況)	466	470
2	473	478
4	480	486
6	489	494
8	495	502
10	502	510

