

2016/5/18 (水)

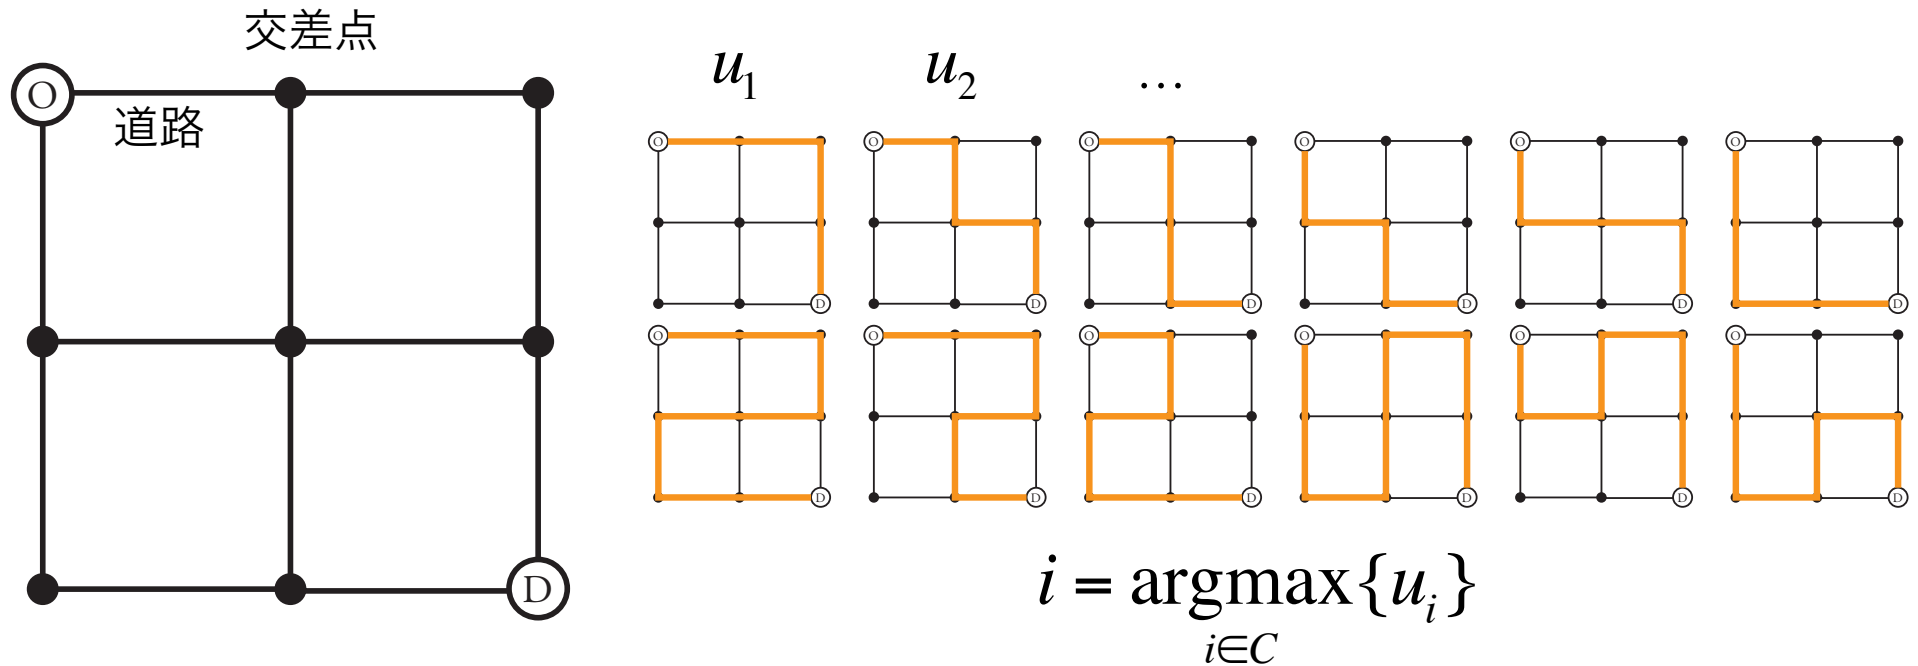
BinN理論談話会@409

経路選択モデルのレビュー

D3 大山雄己

経路選択モデルと選択肢集合

起点(O)から終点(D)に至るまでに利用するルートを選択



経路選択肢は12：実ネットワークでは**列挙不可能**

※ $n \times n$ の格子経路数: 12 ($n=2$), 184 ($n=3$), 8,512 ($n=4$), 1,262,816 ($n=5$),...

Pre-trip / En-route model

1. Pre-trip 型経路選択モデル

出発前にネットワーク情報を入力しているという仮定に基づいてOD間経路の選択を行なう。

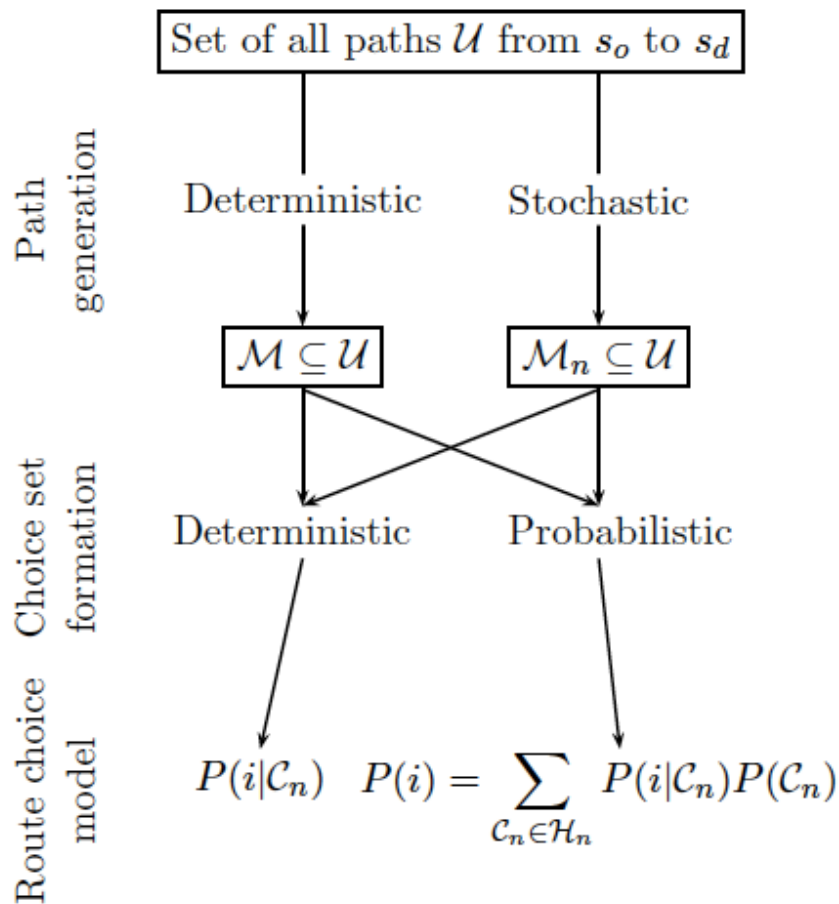
→ **経路集合を明示的に定める**

2. En-route 型経路選択モデル

交差点に立つ度に、逐次的にリンクを選択していく。

→ **明示的な経路列挙を必要としない**

選択肢集合の生成手法



確定的方法：

- K番目最短経路探索 (Eppstein, 1998)
K番目までの最短経路を選択肢集合とする
- Link elimination (Azevedo et al., 1993)
基準を満たさない経路を削除していく
- Branch-and-bound (Prato and Bekhor, 2006)
制約条件を満たす範囲でリンクツリーを網羅的に列挙
- Labeling 法 (Ben-Akiva et al., 1984)
経路長以外でいろいろ最小コスト比較

確率的方法：

- 選択肢のサンプリング補正
: Frejinger et al. (2009)
- MCMCアプローチ
: Flotterod and Bierlaire (2013)

選択肢のサンプリング

- 無数ある経路から，サンプリングによって選択肢集合を生成する（例：目的地サンプリング）
- サンプリングバイアス補正項 $\ln q(\mathcal{C}_n|j)$ を入れたMNLによって選択確率を定式化

$$P(i|\mathcal{C}_n) = \frac{e^{\mu V_{in} + \ln q(\mathcal{C}_n|i)}}{\sum_{j \in \mathcal{C}_n} e^{\mu V_{jn} + \ln q(\mathcal{C}_n|j)}} = \frac{e^{\mu V_{in} + \ln \left(\frac{k_{in}}{q(i)} \right)}}{\sum_{j \in \mathcal{C}_n} e^{\mu V_{jn} + \ln \left(\frac{k_{jn}}{q(j)} \right)}}$$

- 補正項はどのように定式化すればいいのか？

選択肢のサンプリング

- サンプリングバイアス補正項 $\ln q(\mathcal{C}_n | j)$
- 経路*i*を含む選択肢集合 \mathcal{C}_n のサンプリング確率は以下。
(*R*回で経路*j*がそれぞれ*k_{jn}*回取り出される確率)

$$q(\mathcal{C}_n | i) = \frac{R_n!}{\frac{1}{k_{in}} \prod_{j \in \mathcal{C}_n} k_{jn}!} \frac{1}{q(i)} \prod_{j \in \mathcal{C}_n} q(j)^{k_{jn}} = K_{\mathcal{C}_n} \frac{k_{in}}{q(i)}$$

$$K_{\mathcal{C}_n} = \frac{R_n!}{\prod_{j \in \mathcal{C}_n} k_{jn}!} \prod_{j \in \mathcal{C}_n} q(j)^{k_{jn}}$$

- 結局 $q(i)$ に基づく $\rightarrow q(i)$ をどのように定式化するか？

選択肢のサンプリング

重み付きランダムウォーク

1. 初期化：起点ノードを定める
2. 接続リンク $\ell = (v, w)$ の迂回度による重み計算：

迂回度 $x_\ell = \frac{SP(v, s_d)}{C(\ell) + SP(w, s_d)}$ 重み $\omega(\ell|b_1, b_2) = 1 - (1 - x_\ell^{b_1})^{b_2}$ Kumaraswamy 分布

3. リンクのサンプリング確率 $q(\ell|\mathcal{E}_v, b_1, b_2) = \frac{\omega(\ell|b_1, b_2)}{\sum_{m \in \mathcal{E}_v} \omega(m|b_1, b_2)}$
4. リンクサンプリング
5. 終点ノードまでステップを繰り返す.

経路jのサンプリング確率： $q(j) = \prod_{\ell \in \Gamma_j} q(\ell|\mathcal{E}_v, b_1, b_2)$

Metropolis-Hasting Algorithm




Fig. 1. "Rubber band"-like variation of a path.

- 二箇所の固定点(fix)を選定
- 一箇所の移動点を選定し、新しいポジションに移動(drag)
- すなわち、輪ゴム(rubber band)のように経路を変位させるが、その変位がネットワーク上に制限される

経路の重複・相関

経路の相関構造を記述


- Link-Nested logit (CNL): Vovsha and Bekhor (1998)
- Paired Combinatorial logit (PCL): Chu (1989)
- Error Component model (EC): Bekhor et al. (2002)
- Multinomial probit (MNP): Daganzo and Sheffi (1977)

経路の重複による魅力度低下を考慮

- C-logit: Cascetta et al. (1996)
- Path-Size logit: Ben-Akiva and Bierlaire (1999)

$$PS_{in} = \sum_{a \in \Gamma_i} \frac{L_a}{L_i} \frac{1}{\sum_{j \in \mathcal{C}_n} \delta_{aj}},$$

逐次リンク選択モデル



ノード*i*から*j*に遷移する効用：

$$u(j|i) = v(j|i) + V^d(j) + \varepsilon(j)$$

$v(j|i)$: リンク(*i,j*)の効用の確定項

$V^d(j)$: ノード*j*から*D*までの期待効用

入れ子（再帰的）構造を利用

Dial(1971), Bell(1995), Akamatsu(1996)

選択肢集合列挙の必要性を回避

En-route型経路選択モデル

9

Recursive Logit model by Fosgerau et al. (2013)

誤差項：ガンベル分布

$$u_n(a|k) = v_n(a|k) + \mu \varepsilon_n(a) + V_n^d(a) \quad \text{価値関数} \quad (1)$$


$$V_n^d(k) = E \left[\max_{a \in A(k)} \left(v_n(a|k) + V_n^d(a) + \mu \varepsilon_n(a) \right) \right] \quad \forall k \in A. \quad (2)$$

Bellman 方程式 (Rust, 1987)

n : 意思決定者 μ : スケールパラメータ

$G = (A, \mathcal{V})$

links $k, a \in A$




En-route型経路選択モデル

10

Network-GEV model


原・赤松 (2014), Papola and Marzano (2013)

道路ネットワーク構造




数字はリンクコスト

Dial ネットワーク



数字は終点からのコスト

選択枝の誤差構造を表す
GEVネットワーク



$$p(j|i) = \frac{\alpha_{ij} G^j(y)^{\frac{\mu_j}{\mu_i}}}{\sum_{j \in N} \eta_{ij} G^j(y)^{\frac{\mu_j}{\mu_i}}}$$