

## Graph Attention Network を用いた複数交通手段の動的均衡配分 Day-to-Day Equilibrium Assignment in Multimodal Network Using Graph Attention Network

小川 大智<sup>†</sup>      羽藤 英二<sup>†</sup>  
Daichi Ogawa      Eiji Hato

### 1. はじめに

交通拠点空間やその周辺の街路では複数交通手段の動線の錯綜が発生しやすいことから、複数交通手段の相互作用を評価する必要がある。具体的には、それぞれの交通手段に属するエージェントの空間的な同時分布とそれに起因する効用関数の変化を推定することができれば、ネットワークの設計等に有用な知見が得られると考えられる。従って、本研究の対象は複数交通手段の交通量に基づく経路選択行動の効用関数の推定である。

交通量を説明変数とした経路選択モデルの推定手法として、交通量配分と経路選択モデルのパラメータの更新を交互に行う、構造推定に基づく方法がある。この方法では、交通量配分アルゴリズムによる暫定的な交通量の配分のもとでパラメータが更新され、繰り返し計算により交通量と経路選択確率が自己無頓着になるように収束計算が行われる。この手法は、未観測変数である交通量を内生的に求める点に特徴があるが、効用関数の推定においては一般に説明変数が外性的か内生的かは考慮されない。しかし、道路幅のような静的な要素と交通量のような不確実性の高い要素を同列で扱って良いかには疑問が残る。

また、本研究では複数交通手段の経路選択行動を同時に扱うことで、他の交通手段の存在を考慮した経路選択モデルの推定を試みる。道路リンク内で交通手段間に負の相互作用がある場合、複数の交通手段がお互いを避ける形で空間的に棲み分けが発生する可能性がある。それぞれ異なる方策を持つプレイヤーの行動は、ゲーム理論的な均衡の概念により定式化可能であるが、他者の行動に不確実性が存在することや、初期状態に依存して必ずしも一つの均衡状態のみが現れるわけではないという点にも注意が必要である。

以上より、本研究では、交通量に依存する相互作用の下での複数の交通手段の均衡的な経路選択行動のモデル化を試みる。Day-to-day の方策更新の枠組みを用いることで、非均衡状態を含めた行動の変化を追跡することが可能になると考えられる。また、完全情報の仮定を緩和した均衡理論を用いることにより、交通量の不確実性を考慮した柔軟なモデル定式化が可能となると考えられる。

## 2. 関連研究

### 2.1 複数交通手段の均衡状態

複数交通手段のネットワーク上での行動は非協力ゲームとして捉えられる。Nash 均衡[1]は非協力ゲームにおいて、全てのプレイヤーが自己の戦略を変更しても得をしないような戦略の組として

される。Nash 均衡では他のプレイヤーとの混合戦略が互いに独立であると仮定するが、これは他の交通手段の行動

を逐一観測して学習するような場合にはやや強過ぎる制約であると言える。

Nash 均衡を緩和した概念として相関均衡[2]がある。相関均衡では、他のプレイヤーの戦略についての完備情報に代わり、確率的な信号を観測すると仮定する。各プレイヤーは観測した信号のもとで最適戦略をとるが、その信号が全プレイヤーによって共通して観測される場合、信号を介してプレイヤー間の戦略が相関を持つこととなる。共通信号を導入することにより戦略同士に相関を認める Nash 均衡よりも広い戦略の均衡を扱うことが可能であるが、プレイヤーは信号に対して必ず最適反応を返すと仮定される。

一方で、質的応答均衡[3]も Nash 均衡を緩和した概念であるが、質的応答均衡では選択に不確実性がある状況が定式化される。質的応答均衡では不確実性パラメータを導入することにより、利得の大きな選択肢には大きな選択確率を、逆に利得の小さな選択肢でも 0 でない小さな選択確率を割り当てる定式化となっている。これにより、より現実的な選択行動が表現可能となっている。

複数交通手段の利用者の経路選択問題では全交通手段の戦略は相関を持つと考えられる。例えば、混雑を回避するような行動は混雑という共通の観測事項により全ての交通手段の利用者がそのリンクの利用を避けるという点で相関を持ちうる。また、各利用者は必ずしも最適応答を行っていないとは限らず、認知誤差等により効用が高くない経路もある一定の確率で選んでいるはずである。経路選択における効用関数をゲーム理論における利得と置き換えることにより、そのような性質に合わせて均衡状態を定義する必要がある。

### 2.2 動的交通量配分

利用者が日々の経験によって交通量のような内生的な変数を学習する様子は Day-to-day の動学として解析されてきた。マルコフ性を仮定した Day-to-day 動学の性質を解析する上で、ポテンシャルゲームによる定式化[4]がよく用いられる。展開ゲームとして表される Day-to-day 動学にポテンシャル関数が定義できれば、ポテンシャル関数の停留点が Nash 均衡となる。単一交通手段の動的均衡配分では、交通量に対して単調増加なコスト関数を用いた場合は Beckmann et al. [5]による定式化が、確率的均衡配分では Fisk[6]による定式化がポテンシャルゲームとしても解釈可能であることが知られている[7]。

また、マルコフ連鎖を用いることで高次元データの分布を生成可能な手法として MCMC[8]がある。MCMC は現在状態で条件付けされた次状態への遷移確率を定めることによりデータサンプリングの計算性を高めている。例えば、統計力学におけるイジング模型の解析ではボルツマン分布に従うスピン状態をサンプリングすることにより磁性等の期待値をシミュレーション可能となっている。また、ボルツマン分布ではエネルギー関数の指数に比例する生起確率

<sup>†</sup> 東京大学 The University of Tokyo

が割り当てられるが、これはポテンシャルゲームにおけるロジット動学の定常分布と同じである。

複数交通手段の動的交通量配分の場合は必ずしもポテンシャル関数が定義できるとは限らないが、MCMC シミュレーションを用いれば交通状態の定常分布や非均衡状態からの緩和時間を議論できる可能性がある。状態集合が離散的な時、MCMC に定常分布が存在するためには非周期性、既約性、正再帰性が満たされる必要があるが、この条件は必ずしもエネルギー関数やポテンシャル関数を必要としないという利点がある。

### 2.3 機械学習モデルによる時系列データ予測

種々の時系列データの将来予測が可能な機械学習モデルが提案されてきている。時系列データを扱う機械学習モデルには可変長の入力の可能な RNN 系のモデル[9]やその発展系として長い系列の相関関係を学習可能な LSTM[10]、自然言語処理を目的として開発された Transformer[11]などがある。それらのモデルは高い汎化性能を示す一方で、解釈が困難なことや長期予測には向かないという欠点がある。動的交通量配分の領域知識を用いて既存の機械学習モデルを拡張することにより、より解釈性が高く長期的な傾向を捉えることの可能なモデルが構築できる可能性がある。

## 3. 提案手法

### 3.1 記号の定義

本研究では一つのネットワークを共有する複数交通手段の経路選択行動をモデル化する。本研究で用いる記号の一覧を表 1 に示す。なお、本研究では計算の簡略さからリンクベースの経路選択モデルを用いるがリンク  $i$  の効用関数を経路  $i$  の効用関数に読み替えればパスベースの経路選択モデルにも適用可能である。

変数	説明	定義域
$N_m$	交通手段数	$\mathbb{N}$
$N_u$	軌跡を観測された利用者数	$\mathbb{N}^{N_m}$
$N_{od}$	OD 需要	$\mathbb{N}^{N_m}$
$d_x$	説明変数次元	$\mathbb{N}$
$d_h$	隠れ変数次元	$\mathbb{N}$
$T$	タイムステップ数	$\mathbb{N}$
$u_i^{(t)}$	時刻 $t$ でのリンク $i$ の効用値	$\mathbb{R}^{N_m}$
$V_i$	リンク $i$ の状態価値関数	$\mathbb{R}$
$x_i$	リンク $i$ の説明変数	$\mathbb{R}^{d_x}$
$h_i^{(t)}$	時刻 $t$ でのリンク $i$ の隠れ変数	$\mathbb{R}^{d_h}$
$\beta$	説明変数に対応するパラメータ	$\mathbb{R}^{N_m \times d_x}$
$W^h$	隠れ変数に対応するパラメータ	$\mathbb{R}^{N_m \times d_h}$
$q_i^{(t)}$	時刻 $t$ でのリンク $i$ の交通量	$\mathbb{R}^{N_m}$
$\lambda$	不確実性パラメータ	$[0, \infty]$
$\gamma$	時間割引率	$[0, 1]$
$p^h$	$h$ の確率分布	
$\mu_{h_i}^{(t)}$	$h_i^{(t)}$ の平均	$\mathbb{R}^{d_h}$
$\sigma_{h_i}^{(t)}$	$h_i^{(t)}$ の分散	$\mathbb{R}^{d_h}$
$A_i$	リンク $i$ の下流リンク集合	

表 1 記号の定義

### 3.2 相関均衡・質的応答均衡に基づく経路選択モデル

本研究では、交通手段間の経路選択行動の相関および不確実性を考慮するため、(1)のような効用関数のもとでのロジット選択を考える。

$$u_i^{(t)}(x_i, h_i^{(t)}; \beta, W^h) = \beta x_i + W^h h_i^{(t)} \quad (1)$$

ここで、 $\beta x$  は相互作用を考慮しない経路選択モデルにおける効用関数を表し、 $W^h h_i^{(t)}$  は相互作用による効用を表す。 $h_i^{(t)}$  はリンク  $i$  での交通手段間相互作用に関わる隠れ変数であり、本研究では  $h_i^{(t)}$  は前時間におけるリンク  $i$  の交通量  $q_i^{(t-1)}$  に依存するものとする。

この定式化において  $h_i^{(t)}$  は全交通手段の共通観測事項であり、交通手段の戦略間に相関を与えるものである。利用者が(1)の効用関数に対する最適戦略を常にとるとき、利用者の戦略は相関均衡により定式化可能である。

一方で、ロジット選択では不確実性パラメータ  $\lambda$  を用いて確率的な選択を扱う。これは質的応答均衡と同様である。質的応答均衡の展開型ゲームへの拡張として Agent Quantal Response Equilibrium (AQRE)[12]があるが、Day-to-day 動学における 1 日分の選択を手番とすれば(1)の効用関数に基づく AQRE を考えることができる。

以上を考慮し、以下のような動学を考える。

1.  $h_i^{(t)}$  を確率分布  $p^h(q^{(t-1)})$  からサンプリング。
2. リンク  $s$  から  $s'$  へ移る選択確率を(2)とし、その元で

$$P(s, s') = \frac{\exp \lambda (u_s^{(t)} + \gamma V_{s'})}{\sum_{s'' \in A_s} \exp \lambda (u_{s''}^{(t)} + \gamma V_{s''})} \quad (2)$$

の配分交通量を求める。

ただし、 $V_i$  はリンク  $i$  の状態価値関数であり、Bellman 方程式によって定義される。効用  $u_i$  が時間変化するとき  $V_i$  も変化したが、本研究では、 $V_i$  のような大域的な情報は時間変化しないと考え、固定値を使用した。

ステップ 1 では交通手段間の経路選択確率の間に相関を発生させる  $h_i^{(t)}$  をサンプリングしており、ステップ 2 では  $u_i^{(t)}$  の元での不確実性を含んだ選択を表している。

### 3.3 GAT による動的均衡配分モデル

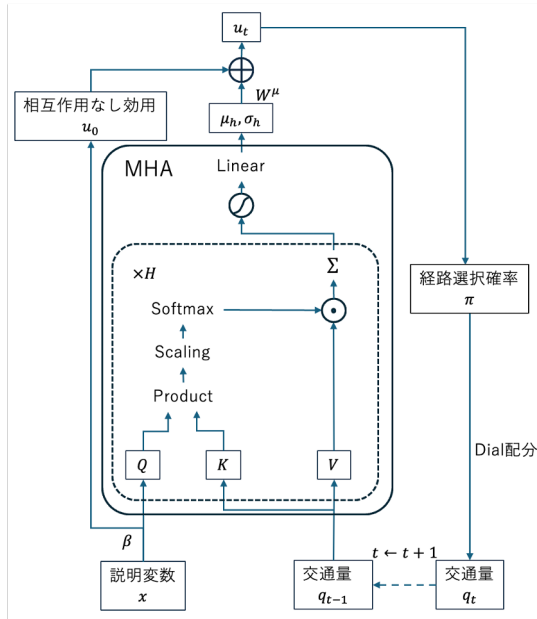
本研究では、 $h_i^{(t)}$  の分布を Graph Attention Network (GAT)[13]により近似することにより 3.2 のモデルの汎化性能向上を試みる。GAT を用いることにより、空間的な近接構造を考慮した  $h_i^{(t)}$  のサンプリングが可能になると考えられる。

GAT では、隣接ノードの特徴量に attention weight をかけたものを足し合わせることでノードの特徴量を更新していく。本研究では、交通ネットワークの線グラフを考え、全交通手段の相互作用なしのリンク効用を query、前タイムステップでリンク交通量を key、value とした multi-head cross attention を用いる。なお、隣接しないノードの特徴量に対する attention weight は全て 0 とする。Multi-head cross attention の出力を複数回作用させた出力を線形レイヤーに入力し、その出力を平均、分散とする正規分布から  $h_i^{(t)}$  のサンプリングを行う。Reparameterization trick[14]を用いることでモデル学習が可能である。

$h_i^{(t)}$  の従う分布は(3), (4)のようになる. 図 1 に GAT を用いた動的均衡配分モデルの概要を示す.

$$\mu_h^{(t-1)} = W^{\mu T} \text{MHA}(\beta x, q^{(t-1)}, q^{(t-1)}) + b^{\mu} \quad (3)$$

$$\sigma_h^{(t-1)} = W^{\sigma T} \text{MHA}(\beta x, q^{(t-1)}, q^{(t-1)}) + b^{\sigma} \quad (4)$$



## 2 GAT を用いた動的均衡配分モデルの概要

### 4. ケーススタディ

#### 4.1 設定

本研究では, 歩行者と自家用車の 2 つの交通手段の GPS 軌跡データから経路選択モデルの効用関数の推定を行った.

GPS 軌跡データは 2007 年 2 月 19 日~3 月 23 日に愛媛県松山市にて行われた松山街中プローブパーソン調査の GPS データを用いた. このデータには 6953 トリップ, 1217626 件の GPS 測位データが含まれている. その中から歩行者と自家用車のトリップのみを抽出し, OpenStreetMap[15]の道路ネットワークにマップマッチングすることで現在リンク, 遷移先リンク, 終端リンクを含む経路選択データの形に整形を行った. 整形されたデータの日付ごとのデータ数を歩車のそれぞれについて図 2 に示す.

経路選択モデルの設定としては, リンクの説明変数として, リンクセントロイドでボロノイ分割を行った領域内の道路密度, 公共施設密度, 住宅密度, 緑地密度, 交通施設密度を設定した. また, GAT のヘッド数は 1, 深さは 1 と設定した.




図 2 日付ごとの経路選択データ数

OD 需要については, 2007 年に松山市にて行われた松山都市圏 PT 調査の結果を用いて, 歩車の朝 6 時から 9 時の需要を割り付けた. PT 調査はゾーンごとに整形されていたため, ゾーン内でリンクにランダムに割り付けを行った. また, 需要の目的地については交通量配分における計算負荷を低減するため, K-means 法[16]により目的地ノードを 10 個のクラスに分割した上で, ランダムに選んだ一点に需要を割り付けた.

交通量配分計算には, 目的地ごとに経路選択モデルによって計算されたリンク選択確率によって Dial のアルゴリズム[17]を実行し, 最後に全ての目的地について足し合わせた.

損失関数は敵対的逆強化学習 (AIRL) [18]に則って設定した. モデルの学習には Adam を使い, 1 日分の経路選択データを学習するごとに配分計算を行った. 1 日分のデータの学習を 1 エポックとして 150 エポックで実施した. 一方,  $h_i^{(t)}$  のサンプリングは, 一つの経路選択データを推論するたびに行った.

### 4.2 学習結果

学習されたモデルを用いて 3 日分の交通量をシミュレーションした. 計算された交通量を歩行者と自動車について図 3 に示す. なお, 2, 3 行目は 2, 3 日目の交通量の 1 日目との差分を示している.

2 段目, 3 段目を見ると地図中央部, 図右下で歩行者の交通量が増加しており, 逆に車の交通量は減少している. これらは歩車間に負の相互作用があるためと考えられ, 時間の発展とともに歩車の棲み分けが発生する可能性がある.

## 5. 結論

本研究では, 複数交通手段の相互作用とその元での均衡状態を推定するため, 相関均衡と質的応用均衡の概念を拡張した経路選択モデルを定式化した. その上で GAT を用いた相互作用の学習および推論の定式化を行った. 実データを用いた数値実験により, 歩車の負の相互作用の影響がみられたが, より定量的な相互作用や均衡解の性質の評価は今後の検討事項である.

### 参考文献

- [1] J. F. Nash, "Equilibrium points in n-person games," Proceedings of the National Academy of Sciences, Vol.36, No.1, pp.48-49 (1950).
- [2] R. J. Aumann, "Subjectivity and correlation in randomized strategies," Journal of Mathematical Economics, Vol.1, No.1, pp.67-96 (1974).

- [3] R. D. McKelvey, T. R. Palfrey, "Quantal response equilibria for normal form games," *Games and Economic Behavior*, Vol.10, No.1, pp.6–38 (1995).
- [4] W. H. Sandholm, "Potential games with continuous player sets," *Journal of Economic Theory*, Vol.97, No.1, pp.81–108 (2001).
- [5] M. Beckmann, C. B. McGuire, C. B. Winsten, "Studies in the Economics of Transportation," (1956). Available: <https://trid.trb.org/View/91120>
- [6] C. Fisk, "Some developments in equilibrium traffic assignment," *Transportation Research Part B: Methodological*, Vol.14, No.3, pp.243–255 (1980).
- [7] M. J. Smith, "The Stability of a Dynamic Model of Traffic Assignment—An Application of a Method of Lyapunov," *Transportation Science*, Vol.18, No.3, pp.245–252 (1984). <https://doi.org/10.1287/trsc.18.3.245>
- [8] W. K. Hastings, "Monte Carlo sampling methods using Markov chains and their applications," *Biometrika*, Vol.57, No.1, pp.97–109 (1970). Available: <https://academic.oup.com/biomet/article-abstract/57/1/97/284580>
- [9] J. L. Elman, "Finding structure in time," *Cognitive Science*, Vol.14, No.2, pp.179–211 (1990). [https://doi.org/10.1207/s15516709cog1402\\_1](https://doi.org/10.1207/s15516709cog1402_1)
- [10] S. Hochreiter, J. Schmidhuber, "Long short-term memory," *Neural Computation*, Vol.9, No.8, pp.1735–1780 (1997).
- [11] A. Vaswani, N. Shazeer, N. Parmar, J. Uszkoreit, L. Jones, A. N. Gomez, L. Kaiser, I. Polosukhin, "Attention Is All You Need," *arXiv preprint arXiv:1706.03762* (2023). <https://doi.org/10.48550/arXiv.1706.03762>
- [12] R. D. McKelvey, T. R. Palfrey, "Quantal response equilibria for extensive form games," *Experimental Economics*, Vol.1, pp.9–41 (1998).
- [13] P. Velickovic, G. Cucurull, A. Casanova, A. Romero, P. Lio, Y. Bengio, "Graph attention networks," *stat*, Vol.1050, No.20, pp.10–48550 (2017).
- [14] D. P. Kingma, M. Welling, "Auto-Encoding Variational Bayes," *arXiv preprint arXiv:1312.6114* (2022). <https://doi.org/10.48550/arXiv.1312.6114>
- [15] OpenStreetMap contributors: "OpenStreetMap," OpenStreetMap Foundation, [Online]. Available: <https://www.openstreetmap.org/>.
- [16] J. MacQueen, "Some methods for classification and analysis of multivariate observations," *Proc. of the Fifth Berkeley Symp. on Mathematical Statistics and Probability*, Vol.1, pp.281–297 (1967).
- [17] C. Fisk, "Some developments in equilibrium traffic assignment," *Transportation Research Part B: Methodological*, Vol.14, No.3, pp.243–255 (1980).
- [18] J. Fu, K. Luo, S. Levine, "Learning robust rewards with adversarial inverse reinforcement learning," *Proc. Intl. Conf. on Learning Representations (ICLR)* (2018).

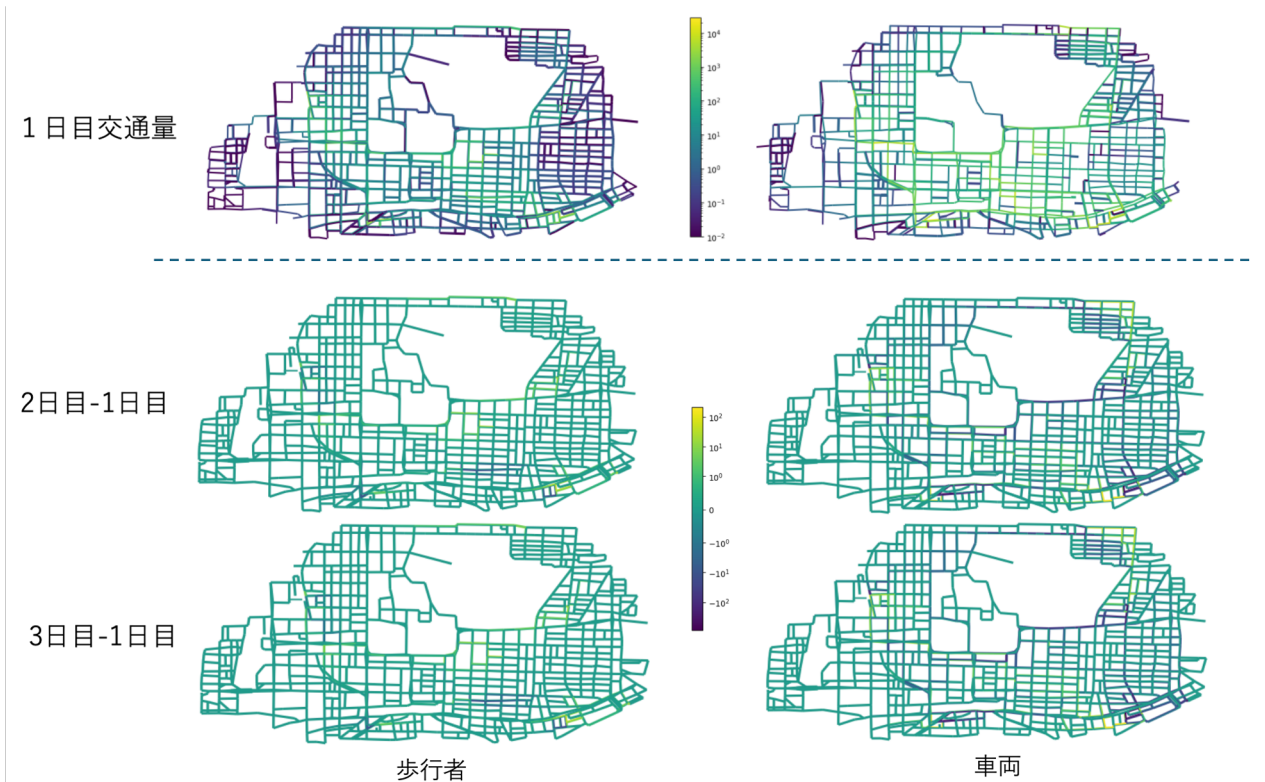


図3 歩車の交通量配分シミュレーションの結果