

近未来交通システム導入時の道路空間再配分に関する数理モデル研究

助成研究者：東京大学 教授 福田大輔
共同研究者：金沢大学 研究協力員 壇辻貴生

概要：

本研究では、自動運転専用レーン配置のためのシミュレーションベース最適化手法を構築する。特に、メタモデル最適化と遺伝的アルゴリズムを組み合わせた Macroscopic Fundamental Diagram constrained Genetic Algorithm (MFDcGA)を開発し、モデルの検証を行った。Sioux falls ネットワークをケーススタディとした検証では、少ない繰り返し計算で他手法よりも良い解を得られることを確認した。

Key Words: MFD, 自動運転専用レーン, 最適配置, シミュレーションベース最適化

1. はじめに

自動運転技術が確立し新たなモビリティが導入された場合、都市の有効活用のため、道路空間の再配分が必要となってくる。実際に、東京都では自動運転車導入を見据え、自動運転専用レーンの導入を検討している。自動運転車のみが走行可能な自動運転専用レーンの導入によって、手動運転車が同一車線から分離され、高密度な追従走行が可能となる。つまり、交通容量増加による渋滞解消が期待される。また、自動運転車は手動運転車と比べ走行時の横方向へのブレが小さいため、自動運転専用レーン導入によって、道路幅員の縮小が可能となり、他の交通手段 (e.g., 歩行者や自転車) への空間を生み出すことも期待される。

他方、自動運転車の普及率が低い状態で多くの自動運転専用レーンの導入は、一般車両への交通容量を低下させ、かえって交通渋滞を悪化させてしまう可能性がある。一方で、普及率が高いにもかかわらず、自動運転専用レーンが適切に配置されていない場合、混合レーンにおいて安全確保のため自動運転車が手動運転車との車間距離を大きくとることが予想されるため、交通渋滞を悪化させる可能性がある。つまり、自動運転車の普及率に合わせた、自動運転専用レーンの最適配置を考える必要がある。

そこで、本研究では、自動運転車と手動運転車が混在している近未来交通システムを想定し、自動運転専用レーン最適配置のための手法を提案することを目的とする。

2. 既往研究

道路ネットワークのネットワークデザイン手法として、バス専用レーンの配置に関する研究は数多くある (詳細なレビューは^{1,2)}等を参考にされたい)。例えば、Mesbah et al., (2011)³⁾では、バス専用レーン配置の最適化問題を定式化し、遺伝的アルゴリズムを用いた解法を用いている。しかし、多くの研究と同様に小さなスケールなネットワークへの適用に留まっている。その要因として、膨大な組み合わせ数が考えられることにある。リンク数が n の場合、バスレーンを配置するか否かの2通りをリンクの数だけ考える必要があり、 2^n 通りの組み合わせが考えられる。つまり、リンク数が増えれば増えるほど、この組み合わせ数は指数関数的に増加していき、大規模ネットワークを対象とする場合、計算コストの高さが課題となる。

他方、大規模ネットワークを対象としたバスレーン配置の最適化問題を扱った研究として、Zheng and Geroliminis (2013)⁴⁾がある。Zheng and Geroliminis (2013)では、車やバス、タクシーなど様々な交通手段が混在するネットワークにおいて、総走行時間最小化問題として、道路空間の各交通手段への配分手法を提案している。大規模ネットワークに適用可能な枠組みである一方で、各交通手段の空間配分割合 (e.g., 各エリアに何%のバスレーンを導入するか) を決定する手法に留まっており、実際のネットワークデザインの提案までは至っていない。

そこで、本研究では上記2つの研究を組み合わせることで、計算効率の高いネットワークデザイン手法、特に、自動運転専用レーン最適配置手法の開発を行う。

3. 手法

(1) モデル設定

本研究では、都心部の一つのエリアを対象に自動運転車と手動運転車が混在する交通システムにおける自動運転専用レーンの最適配置手法を考える。自動運転専用レーン配置デザイン手法は、Bi-level optimization problem として定式化可能である。上位問題では、システム管理者のもつ制約条件下で目的関数を最大化（又は最小化）するため、自動運転専用レーンの配置リンクを決定する。本章では、既存研究に倣い、総走行距離最大化問題として上位問題を定式化する。下位問題では、旅行者の効用を最大化するために交通行動（e.g., 経路選択）を決定する。本研究では、ミクロ交通流シミュレーションによるシミュレーションベースの動的交通量配分によって、下位問題を記述する。また、各時間帯の自動運転車及び手動運転車の交通需要は与件とし、自動運転専用レーンの普及率による需要の変化は考慮しないものとする。

(2) 自動運転専用レーンのためのシミュレーションベース最適化

Bi-level optimization problem として以下の最適化問題を考える。

$$\max_{\mathbf{x}} \sum_{t \in T} \mathbb{E}[n_i(t)v_i(t); \mathbf{x}] \quad (1a)$$

s.t.

$$n_i(t) = DTA(\mathbf{x}) \quad (1b)$$

$$v_i(t) = DTA(\mathbf{x}) \quad (1c)$$

ただし、 \mathbf{x} は各リンクの自動運転専用レーンに関するダミー変数（1 if 自動運転専用レーンが配置, 0 otherwise）のベクトル、 $n_i(t)$ 及び $v_i(t)$ は、それぞれモード i の時間 t における走行台数と速度、 T は対象時間帯の時間集合を表す。目的関数は対象時間帯における総走行距離最大化である。各時間帯及び各交通モードの走行台数 $n_i(t)$ と速度 $v_i(t)$ はミクロ交通流シミュレーションを通じて旅行者の効用最大化問題の結果として算出される。

最適化問題の定式化自体は単純である一方で、対象となる最適化問題は NP-hard であり、解くのが困難なクラスの問題である。このような問題を解く際には、遺伝的アルゴリズムなど汎用的なヒューリスティックな手法が用いられることが一般的であるが、大規模ネットワークを対象とする場合、計算コストの高さが課題となる。そこで、本年度は昨年度構築した計算効率の高いシミュレーションベース最適化手法と遺伝的アルゴリズムを組み合わせた MFD-constrained genetic algorithm (MFDcGA) を開発する。

(3) MFD-constrained Genetic Algorithm (MFDcGA)

a) Genetic Algorithm

本章では、まず基本的な Genetic Algorithm (GA) を説明する。GA は二つの解を組み合わせることで新たな解を生成し、繰り返し解を探索する手法である。まず、 n 個の実行可能解を初期集団として生成する。初期集団を現世代とし、現世代の各個体（各解）に対して評価関数による適応度を計算する。そして、適応度から算出した確率に基づいて個体は選択され、設定された確率に基づいて個体同士の交叉、突然変異、または各個体がそのまま次世代へと受け継がれていくというアルゴリズムである。このアルゴリズムは収束判定を満たすまで繰り返し行われる。

本研究では、GA を自動運転専用レーンの最適配置問題へ適用する。各個体の遺伝子はバイナリー変数 ϕ によって定義し、個体は遺伝子のベクターとして表現され、各遺伝子は道路ネットワークの各リンクに対応する。つまり、各個体は自動運転専用レーンを配置すべきリンクの組み合わせをバイナリー形式で表現したものである。GA はその汎用性から、多くの都市交通問題に適用されてきたが、大規模ネットワークを対象とする場合、解の組み合わせ数は膨大となり、収束までに多くの繰り返し計算が必要となる欠点が存在する。

b) MFDcGA の手順

前章で説明した欠点を解決するため、エリアレベルでの交通流ダイナミクスを制約条件とした計算効率の高い遺伝的アルゴリズムの開発を行う。提案する手法の枠組みは図 1 に示す。提案手法は大きく分けて 3 つの段階で構成される。まず、エリアレベルで巨視的に交通流ダイナミクスが記述可能な交通モデルによって、自動運転専用レーンの道路空間最適割合問題を定式化する。Dantsuji et al., (2022)⁵⁾ に基づいて構築した本交通モデルは道路ネットワークなどの情報を捨象した近似的にモデル化したモデルのため以降はメタモデルと呼ぶ。メタモデル最適化（図中メタモデル①）によって出力された最適割合を制約とした初期集合生成を行う。初期集合生成後は通常の遺伝的アルゴリズムの手順を実行する（図中遺伝的アルゴリズム）。そして、近似的なメタモデルの結果とシミュレーション結果の間に乖離を防ぐため、シミュレーション後メタモデル最適化を実行する（図中メタモデル②）。次の章より各段階の詳細な説明をしていく。

(4) MFD-constrained Genetic Algorithm (MFDcGA)

a) メタモデル最適化

自動運転車 (AV) と手動運転車 (HV) が混在するエリアを考える。本研究のメタモデル最適化はエリアレベルでの巨視的に時事刻々と変化する各交通手段の走

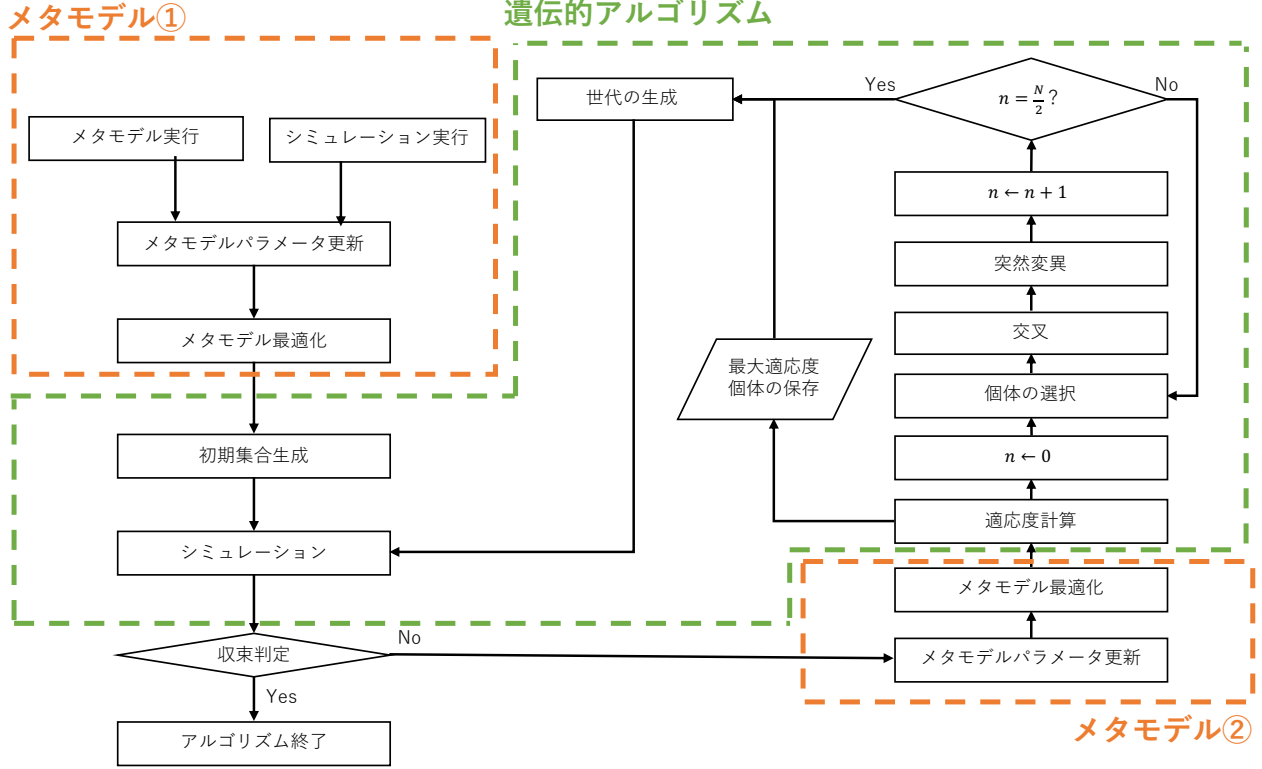


図-1 MFDCGA の枠組み

行台数を記述可能な Macroscopic Fundamental Diagram (MFD) に基づいたモデルである。また、本研究での自動運転専用レーンの道路空間配置の最適化問題の目的関数は総走行距離最大化問題として定義しているため、メタモデル最適化問題は以下のように定式化することが可能である。

$$\min_x \sum_{i \in T} \sum_{i \in I} \hat{n}_i(t) v_i(t) \quad (2)$$

$$\hat{n}_i(t) = \beta_i^i n_i(t) \quad (3)$$

$$n_i(t+1) = n_i(t) - O_i(t) + M_i(t) \quad (4)$$

$$M_i(t) = \min \left[D_i(t), \frac{n_i(t)}{\sum_{i \in I} n_i(t)} C \left(\sum_{i \in I} n_i(t) \right) \right] \quad (5)$$

$$O_i(t) = \frac{n_i(t) v_i(t)}{L} \quad (6)$$

$$n_j^{rl} = x n_j \quad (7)$$

$$n_j^{ml} = (1-x) n_j \quad (8)$$

$$v_{AV}(t) = (1-x) v_{HV}(t) + x v_{rl}(t) \quad (9)$$

$$v_{HV}(t) = v_f^{HV} \left(1 - \frac{n_{HV}(t) + (1-x) \xi n_{AV}(t)}{n_j^{ml}} \right) \quad (10)$$

$$v_{rl}(t) = v_f^{AV} \left(1 - \frac{x n_{AV}(t)}{n_j^{rl}} \right) \quad (11)$$

式 (2) は、手動運転車と自動運転車の対象時間帯での総走行距離最大化の目的関数を表している。ただ

し、 x は自動運転専用レーンの空間配分割合、 $\hat{n}_i(t)$ は、メタモデルパラメータによって補正された時間 t 交通手段 $i \in \{HV, AV\}$ の走行台数であり、式 (3) によって定式化される。式 (4) は交通手段 i の車両保存則を表しており、時間 $t+1$ の走行台数 $n_i(t+1)$ は時間 t の走行台数 $n_i(t)$ から時間 t のトリップ完了台数 $O_i(t)$ を引き、時間 t の流入台数 $M_i(t)$ を足した台数によって算出される。ただし、流入台数 $M_i(t)$ は、時間 t の交通需要 $D_i(t)$ と受け入れ容量 $\frac{n_i(t)}{\sum_{i \in I} n_i(t)} C(\sum_{i \in I} n_i(t))$ の最小値から与えられる (式 (5))。また時間 t のトリップ完了台数は Network Exit Function で与えられる (式 (6))。自動運転専用レーン及び混合レーンの最大走行可能台数は自動運転専用レーン割合 x に依存し、それぞれ式 (7) 及び (8) で与えられる。ただし、 n_j はエリア内での最大走行可能台数である。そして、時間 t の自動運転車の平均速度は混合レーンでの速度 $v_{HV}(t)$ と自動運転車専用レーンでの速度 $v_{rl}(t)$ の加重平均である (式 (10))。そして、混合レーンでの平均速度 (すなわち、手動運転車の平均速度) は Greenshields の速度式を拡張した式によって与えられる (式 (11))。ただし、 v_f^{HV} は手動運転車の自由流速度、 ξ は自動運転車の PCU (Passenger Car Unit) である。また、同様に自動運転専用レーンでの平均速度 $v_{rl}(t)$ も式 (12) によって与えられる。

b) メタモデルパラメータ更新

複雑な交通現象を記述するミクロ交通流シミュレータから出力される結果とネットワークなどいくつかの情報を捨象したメタモデル最適化の結果には乖離が生じる可能性がある。そうした乖離を埋めることを目的にパラメータ更新を行う。

繰り返し計算 k 回目のメタモデルパラメータ更新は以下のように重み付き最小二乗法を用いて行う。

$$\min_{\eta^k} \sum_k w(k) \sum_i \sum_t (\eta_{i,t}^k n_i^k(t) - \mathbb{E}[n_i^k(t)]) \quad (12)$$

s.t.

$$\beta_{i,t}^l \geq \eta_{i,t}^k \beta_{i,t}^{k-1} \geq \beta_{i,t}^u \quad (13)$$

つまり、 k 回目の繰り返し計算のメタモデルパラメータは $\beta_{i,t} = \eta_{i,t}^k \beta_{i,t}^{k-1}$ と表すことができる。

c) メタモデルによって制約された遺伝的アルゴリズム

メタモデルによって解集合が制約された遺伝的アルゴリズムを開発する。アルゴリズムの手順は一般的な GA と同様で (I) 初期集団の生成, (II) 適応度の計算, (III) 個体を二つ選択, (IV) 交叉, (V) 突然変異, (VI) 次世代の個体数が N 個になるまで (III) に戻る, (VII) 次世代を現世代に移す, (VIII) 収束判定を満たすまで (II) に戻るを繰り返す。以下各手順の詳細を説明する。

(I) 初期集団の生成

手順 (I) では、 N 個の個体から構成される初期集団を生成する。一般的な GA では、初期集団をランダムに生成するが、本枠組みではメタモデル最適化によって出力される自動運転専用レーンの最適空間配分割合 x^* によって制約された初期解を生成する。具体的には、最適な自動運転専用レーン長 (i.e., x^*TL ただし、 TL は道路総延長) に合計値が近くなるまで、リンクをランダムに選択していく。 N 個の個体に対して、それぞれ初期解を生成する。

(II) 適応度の計算

各個体 (解) に基づいてミクロ交通流シミュレーションの道路ネットワークに自動運転専用レーンを配置し、シミュレーションより以下の適応度を計算する。

$$f_n = \sum_{i \in T} \sum_{i \in I} n_i(t) v_i(t) - \delta(x - x^*)^2 \quad (14)$$

個体 n の適応度 f_n は総走行距離に加え、メタモデル最適化による最適空間配分割合と実際の空間配分割合の二乗誤差によって表される。ただし、 δ は外性的に与える重み付きパラメータである。つまり、目的関数である総走行距離が高いほど適応度は高くなり、メタモデル最適化による最適空間配分割合から離れた空間配分割合ほど適応度が低くなる。また、既存研究³⁾を参考に、最も適応度の高い個体は次世代へと受け継ぐものとする。




図-2 Sioux falls network

(III) 個体の選択

(II) で定義した適応度に基づき、ルーレット法を用いて各個体の選択確率を算出する。個体 k の選択確率 S_k は次の式で表される。

$$S_k = \frac{f_n}{\sum_{i \in N} f_i} \quad (15)$$

適応度が高いほど、選択確率 S_k が高くなり、次の世代に受け継がれやすくなる。選択確率 S_k に基づいて、2つの個体を選択する。

(IV) 交叉 P_c の確率で選択された2つの個体を交叉する。一点交叉を採用し、交叉点は乱数を発生させ決定する。

(V) 突然変異 P_m の確率で各個体の遺伝子情報を反転させる ($1 \rightarrow 0$ 。または、 $0 \rightarrow 1$)。

(VI) 次世代への継承新たに生成された2つの個体を次世代の集団へと受け継ぐ。 N 個の個体が生成されるまで手順 (III) に戻る。

(V) 世代交代生成された次世代集団を現世代集団とする。

(VI) 収束判定あらかじめ設定した収束判定を満たしていれば、アルゴリズムを終了する。そうでなければ、手順 (II) に戻る。

4. モデルの検証

(1) シミュレーション設定

Sioux-falls network をケーススタディとして、提案手法の妥当性検証を行った。用いるネットワークのリンク数は148、ノード数は100ノードである。ミクロ交通流シミュレーション Aimsun を用いて、シミュレーション上の自動運転車のモデル化は車両の追従モデルのパラメータを調整することで表現した。具体的に、本研究では自動運転車の追従モデルを Cooperative adaptive cruise control (CACC) によって高密度な追従行動を表現




図-3 需要パターン

した。自動運転車は手動運転車との time gap を 10.0 秒、自動運転車との time gap を 0.6 秒シミュレーション時間は 8:00AM から 9:00AM の一時間とし、需要パターンは図 3 に示す通りである。また、各時間帯の需要に対する自動運転車の需要は 20% とする。

遺伝的アルゴリズムに関する各パラメータは以下のように設定した。既存研究³⁾の結果に基づき、各世代の個体数は 31 個とした。また、各確率に関して、交叉が発生する確率を 80%、突然変異の確率を 10% に設定した。自動運転専用レーンの配置可能なリンクは、2 車線以上あるリンクのうち、1 車線のみを対象とし。同一リンクに 2 車線以上の自動運転専用レーンの配置はしないものとする。つまり、自動運転専用レーン配置可能な最大レーン長は 2 車線以上の車線をもつリンクのリンク長総和である。

(2) シミュレーション結果

提案手法の妥当性を検証するため、考えられる最も単純な方法として、最も混雑する箇所に配置する戦略（交通密度高戦略）と最も混雑していない箇所に配置する戦略（交通密度低戦略）を比較対象とした。図 4 は各 iteration における最大総走行距離を表したものである。提案手法である MFDcGA は最初の iteration で目的関数である総走行距離が大きく改善されていることがわかる。また、iteration 2 以降軽微な改善のみみられ、iteration 3 以降は最大走行距離が変化しない結果となった。また、比較対象である交通密度高戦略と交通密度低戦略もそれぞれ iteration 1 で総走行距離が大きくなるが、提案手法と比較すると小さな改善となっている。特に交通密度低戦略では、現状のネットワークのパフォーマンスと比較しても、あまり変化がない結果となった。以上の結果より、提案手法によって少ない繰り返し計算で良い解を得られることが確認された。

図 5 は、iteration 10 における最適解の配置結果を示したものである。自動運転専用レーンの総道路延長に

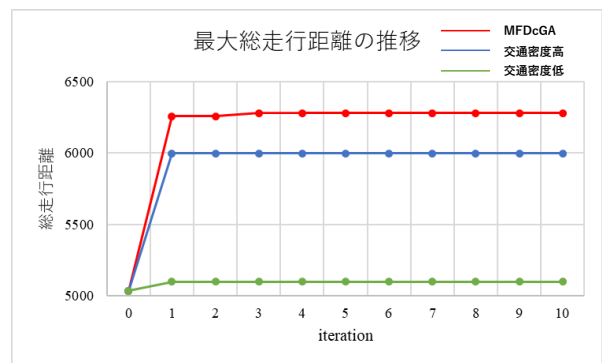


図-4 各 Iteration の結果と比較

対する割合は、27%となった。Platooning の効果は、より長距離で移動する場合に大きくなることが期待されるため、比較的長いリンクに配置されている傾向も読み取れる。

5. 結論

本研究では、自動運転専用レーン配置のためのシミュレーションベース最適化手法を構築した。特に、メタモデル最適化と遺伝的アルゴリズムを組み合わせた MFDcGA を開発し、モデルの検証を行った。Sioux falls ネットワークをケーススタディとした検証では、少ない繰り返し計算で他手法よりも良い解を得られることを確認した。

今後の展望として、以下のつが挙げられる。まず、今回繰り返し計算の回数が 10 回に留まっているが、繰り返し数の増加や異なる初期解による検証で解の性質を検証することである。次に、自動運転車の普及率を与件としてモデルを構築したが、交通手段選択モデルなどを考慮することで、普及率も内生的に決定するより現実的なモデルへ拡張することである。最後に、モデルの頑健性の検証のため、異なるネットワークへの適用も今後の展望の一つである。

参考文献

- 1) Dantsuji, T., Fukuda, D. and Zheng, N.: Simulation-based joint optimization framework for congestion mitigation in multimodal urban network: a macroscopic approach, *Transportation*, Vol. 48, pp. 673–697, 2021.
- 2) Zheng, N., Dantsuji, T., Wang, P. and Geroliminis, N.: Macroscopic approach for optimizing road space allocation of bus lanes in multimodal urban networks through simulation analysis, *Transportation Research Record*, Vol. 2651, No. 1, pp. 42–51, 2017.
- 3) Mesbah, M., Sarvi, M. and Currie, G.: Optimization of transit priority in the transportation network using a genetic algorithm, *IEEE Transactions on Intelligent Transportation Systems*, Vol. 12, No. 3, pp. 908–919, 2011.




図-5 Iteration 10 の配置結果（橙色：自動運転専用レーン配置リンク）

- 4) Zheng, N. and Geroliminis, N.: On the distribution of urban road space for multimodal congested networks, *Transportation Research Part B: Methodological*, Vol. 57, No. C, pp. 326–341, 2013.
- 5) Dantsuji, T., Hoang, N. H., Zheng, N. and Vu, H. L.: A novel metamodel-based framework for large-scale dynamic origin–destination demand calibration, *Transportation Research Part C: Emerging Technologies*, Vol. 136, p. 103545, 2022.

(2023. 4. 20 受付)