

プローブ情報を活用した遅れ時間の AI 短期予測に基づく信号制御手法の構築

高橋 翼¹・小根山 裕之²・柳原 正実³

¹学生会員 東京都立大学大学院 都市環境科学研究科 (〒192-0397 東京都八王子市南大沢 1-1)
E-mail: tukapun@gmail.com

²正会員 東京都立大学大学院教授 都市環境科学研究科 (〒192-0397 東京都八王子市南大沢 1-1)
E-mail: oneyama@tmu.ac.jp

³正会員 東京都立大学大学院助教 都市環境科学研究科 (〒192-0397 東京都八王子市南大沢 1-1)
E-mail: yanagihara@tmu.ac.jp

信号制御の主な目的の 1 つは、交通全体の遅れ時間の短縮である。車両感知器を用いた現行制御では遅れ時間の直接観測が困難だが、各車両の時刻や位置等のデータであるプローブ情報を活用すれば、遅れ時間を直接把握できる。よって、プローブ情報を用いれば遅れ時間の直接的な短縮を目的とした制御ができる。プローブ情報の特性である伝送遅れの影響と、プローブ車低混入率による遅れ時間精度の影響は、プローブ情報に基づいた将来の遅れ時間の高精度な予測により解決できるといえる。そこで本研究では、プローブ情報を活用した遅れ時間の AI 短期予測に基づく信号制御手法の構築と、当該手法制御効果の定量評価を行った。結果として、従来信号制御手法と比較した場合、総遅れ時間は有意に小さくなり、プローブ情報を活用した信号制御の有用性を確認できた。

Key Words: *signal control, probe information, AI, delay, traffic simulation*

1. 研究背景

(1) 信号制御の目的

信号制御は、自由走行時に比べて余分に要した通行時間である遅れ時間を小さくすることを目的としている。遅れ時間を小さくすることによる最も大きな効果は、渋滞緩和である。これによって、交通事故発生の抑制と排ガス量の低減が期待できる。渋滞により交通流の円滑性が失われると、運転手のストレスが溜まり、見切り発進や無理な駆け込みを誘発させ、交通事故のリスクが高まる。また渋滞により、発進と停止が繰り返されると、排ガス量が増加する。自動車による排ガスは、地球温暖化の大きな要因の 1 つとなっている。適切な信号制御により、安全で円滑な環境にやさしい道路交通を実現することができる。

(2) 現行の信号制御手法

現在、日本で用いられている動的な交通流観測に基づく信号制御手法（交通応答制御）は、大きく 2 つに分類される¹⁾。

1 つはプログラム選択制御と呼ばれるものである。この制御手法は、曜日や時間帯に応じてあらかじめ定められた信号制御パラメータにより運用されるものであるため、車両感知器や管制センターとの接続が不要かつ、交通需要がある程度パターン化されるような交差点においては、制御効果が期待される。1 交差点内で完結し、コストを抑えられることから、日本では多く用いられている手法である。短所として、都市や地域の再開発等により、交通需要が信号制御の設計時から変化した場合や、突発的な交通需要の変動が起こった場合に、制御効果が薄れるという点が挙げられる。

もう 1 つの信号制御手法は、プログラム形成制御と呼ばれるものである。これは、車両感知器による計測データを活用して算出された、流入交通量と捌け残り台数の和を飽和交通流率で除した値である負荷率に基づき、青時間スプリット・サイクル長・オフセット（以下、信号制御パラメータ）を決定し、信号制御を行うものである。プログラム選択制御とは異なり、あらかじめ有限個の信号制御パラメータが設定されているというわけではなく、交通状況に適したものを自動生成する制御であり、現行

の信号制御手法のなかで最も高度な手法といえる。長所として、プログラム選択制御と比較し、より交通状況に適した信号制御が可能となる点や、信号制御パラメータを自動生成するため、信号制御の設計が不要であるという点がある。

(3) プローブ情報

近年、プローブ車一台一台の時刻と位置（緯度、経度）等を含むデータであるプローブ情報を交通状況の把握や交通施策に活用する動きが見られる。これは、スマートフォンやETC、カーナビゲーション等の普及によって、より多くのプローブ情報を収集できるようになったことが背景にある。

プローブ情報に含まれるデータに基づき、プローブ車の走行を追跡することによって、遅れ時間を高精度に計測することが可能となる。しかし、プローブ情報を活用するにあたって、問題点が2つある。1つ目はデータの伝送遅れの問題である²⁾。通常、プローブ車から送信されたプローブ情報は、一定期間蓄積された後に伝送されるため、最新の交通状況とデータが示す交通状況に差が生じる可能性がある。2つ目はプローブ車の混入率の問題である。吉岡ら³⁾によると、2019年における日中のプローブ車混入率は約12%であった。この混入率の値は、高精度に時々刻々の遅れ時間を算出するためには必ずしも十分であるとは言えない。

(4) 研究目的

上述した現行の信号制御手法では、車両感知器の特性に合わせて遅れ時間を直接考慮しない信号制御手法となっている。一方で、プローブ情報を活用すれば遅れ時間を直接的に動的な信号制御に反映させることが可能である。このとき、得られているプローブ情報に基づいて、将来の総遅れ時間が精度よく算出できれば、上述した伝送遅れや混入率の問題点は解決できると考えられる。

そこで本研究では、プローブ情報を活用したAI短期予測遅れ時間に基づく信号制御手法の構築と当該手法制御効果の定量的評価を目的とし、その評価結果より、当該手法の課題について整理する。

2. 既往研究レビュー

信号制御にプローブ情報を活用することを試みる既往研究は、車両感知器とプローブ情報を併用するものと、プローブ情報単体のみを使うものの2つに大別される。

まず、車両感知器とプローブ情報を併用した既往研究を紹介する。長島ら⁴⁾は、プローブ情報を活用することにより、信号制御パラメータ算出のために必要な待ち行

列長の推定精度の向上を図った。車両感知器による計測だけでなく、プローブ情報も組み合わせることにより制御効果の向上が見られたが、プローブ車混入率が低い場合は、高い場合と比べて制御効果が小さくなったとしている。また、西内ら⁵⁾は、車両感知器により得られる交通需要・飽和交通流率と、プローブ情報により得られる区間旅行時間を用いて、交通シミュレーションを実行することで、観測された交通状況に対し、平均遅れ時間を最小にする信号制御パラメータを決定する手法を構築した。その結果、現状の平均遅れ時間に対して、15秒だけ短縮効果が期待できる信号制御パラメータを見つけることができた。しかし、最適な信号制御パラメータの探索に、交通シミュレーションを用いており、計算に時間がかかるため、効率的な制御手法であるとは言えない。

次にプローブ情報のみを活用した既往研究を紹介する。花房ら⁶⁾は、信号制御の評価指標のための遅れ時間を、プローブ情報のみを使って推定を行った。その結果、プローブ車混入率が高い(50~70%)場合は、相応の精度で推定されていたが、混入率が低い(5~10%)場合は、過小評価になっていることが分かった。また今後の課題点として、プローブ情報の伝送遅れを考慮する必要性が挙げられた。吉岡ら³⁾は、車両感知器の計測情報を使わずに、プローブ情報から得られた平均旅行時間と現状の信号制御パラメータを組み合わせ、負荷率を算出する方法を提案した。課題として、プローブ車混入率が10%程度の時に、捌け残りが発生しない非飽和状態ではプローブ情報から負荷率を算出するのが困難であることが挙げられた。関ら⁷⁾は、定点設置する車両感知器では検知されない渋滞を、プローブ情報を用いることで把握可能であることを確認した。また、車両感知器が設置されない従道路の交通状況をプローブ情報により把握することで、適切な信号制御を行うことができ、幹線道路の渋滞対策に効果を発揮することを確認した。しかし、この研究では、ある期間・時間帯におけるプローブ情報を抽出し、分析したのちに後日、同じ時間帯の信号制御パラメータを調整するという手法が取られており、プローブ情報に基づいた即時的な信号制御は行われていない。塚田⁸⁾は、プローブ情報から読み取った遅れ時間を活用し、多段定周期制御の信号制御パラメータの見直しを行う手法の提案を行った。この手法により、ある条件においては、平均旅行時間が短くなった。しかし、どのような条件において制御効果を最大限に発揮しうるかについて、検討が必要であるとしている。

本研究で提案する信号制御手法の新規性として、プローブ情報の伝送遅れを考慮している点、プローブ車混入率が低い場合を想定している点、最適な信号制御パラメータの探索対象をAIによって予測された遅れ時間とすることで効率的な探索を可能にしている点が挙げられ、

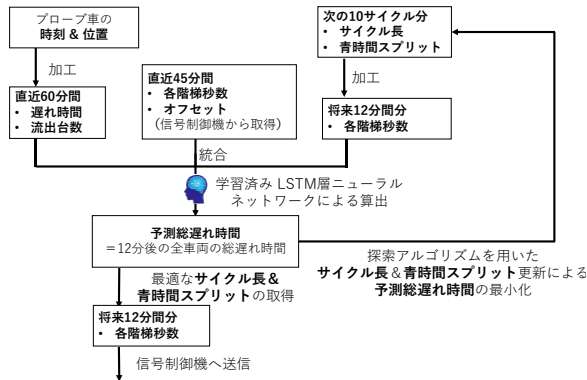


図-1 AIDP のフロー

現行の信号制御手法の枠組みにとらわれない新たな信号制御手法を構築している。また、提案信号制御手法では、オフセットを段階的に変化させることで交通流への影響を緩和させるオフセット追従等の信号制御パラメータの制約が含まれているプログラム形成制御に比べて、このような制約を取り除くことによって、信号制御パラメータの自由度が高くなっているため、遅れ時間をより小さくできる可能性がある。

3. AI 予測遅れ時間準拠制御手法の構築

(1) AI 予測遅れ時間準拠制御手法の概要

以降では、本研究で構築する信号制御手法を AIDP (AI 予測遅れ時間準拠制御手法: AI Delay Prediction based signal control method) と呼ぶ。AIDP では、現時点までに得られている交通状況と信号情報に基づいて、将来のあらゆる信号制御の中で、最小の予測遅れ時間をもたらす信号制御を実施することを目標としている。将来の遅れ時間の予測には AI を用い、予測遅れ時間を最小にする信号制御パラメータは、Nelder-Mead 法 (滑降シンプレックス法) を用いて探索する。図-1 に AIDP のフローを示した。次節以降、各段階の詳細を説明する。

(2) AI による予測

a) AI 導入理由

AIDP では、学習済み AI を用いることによって、ミクロな交通シミュレーションを実行するよりも圧倒的に小さい計算負荷で予測総遅れ時間を算出することができるため、最適な信号制御パラメータの探索を効率よく現実的な時間内で行うことを可能とした。交通状況データといった長期的な時系列データを入力とするため、AI には LSTM 層を含むニューラルネットワークを用いる。

b) AI 入力変数

入力変数は交通状況データである平均遅れ時間、平均流出台数と、信号制御情報である各階梯秒数、オフセッ

トである。平均遅れ時間は式(1)のようにリンク毎に算出され、実際のリンク旅行時間と、一度も停止せずに規制速度で走行した場合のリンク旅行時間との差を、直近 30 分間で平均化したものである。

$$T_{k,t} = \frac{1}{30} \sum_{l=t}^{l+30} \left(\frac{1}{N_l} \sum_{i=1}^{N_l} \left(t_{i,k,l} - \frac{L_k}{\bar{v}_k} \right) \right) \quad (1)$$

$T_{k,t}$: 時刻 t のリンク k 内の平均遅れ時間

$t_{i,k,l}$: 時刻 l から 1 分間の間に i 番目にリンク k から流出したプローブ車両の旅行時間

\bar{v}_k : リンク k 内の規制速度

L_k : リンク k の距離

N_l : 時刻 l から 1 分間の流出プローブ車両台数

平均流出台数とは、直近 1 分間に停止線を通過した車両の台数を、直近 30 分間分だけ収集し、平均したものである (式(2))。

$$V_{k,d,t} = \frac{1}{30} \sum_{l=t}^{l+30} \left(\frac{1}{N_l} \sum_{i=1}^{N_l} \delta^{d_{i,k,l}=d} \right) \quad (2)$$

$V_{k,d,t}$: 時刻 t のリンク k 内の流出 d の平均流出台数

$\delta^{d_{i,k,l}=d}$: 時刻 l から 1 分間の間に i 番目にリンク k から流出したプローブ車両の流出方向が d である場合 1, それ以外の場合に 0 となる変数

N_l : 時刻 l から 1 分間の流出プローブ車両台数

平均遅れ時間及び平均流出台数は、プローブ情報により算出したものであるため、全車両についての交通状況を表した値ではないことに留意されたい。

信号制御情報である各階梯秒数とは、信号表示の切り替えの最小単位ごとの表示時間のことである。オフセットとは、隣接する交差点と対象交差点における青信号開始のずれのことである。系統制御等により複数交差点を制御対象とする場合は、交差点数分だけ各階梯秒数及びオフセットのデータを収集する。

本研究では、以上の各変数が 1 分間隔で更新されるプローブ情報を想定する。したがって、ニューラルネットワークの入力は 1 分間隔の標準化した各変数とした。ここで、LSTM 層を含む再帰的ニューラルネットワークに対応して、時系列順になった 60 タイムステップ分の各変数から遅れ時間が予測される。なお、遅れ時間及び流出台数は直近 60 タイムステップ分、各階梯秒数及びオフセットは直近 45 タイムステップ分と将来の 15 タイムステップ分が用いられる。標準化には、上述した直近のタイムステップ分の変数ごとの平均値等が用いられる。

c) AI 出力値

AI の出力値は、プローブ車・非プローブ車の両方を含んだ全車両の挙動を予測した結果における 7 分後から 12 分後の間の総遅れ時間（以下、予測総遅れ時間）である（式(3)）。

$$T_{t+12} = \sum_k \left(\sum_{i=1}^{N_{t+12}} \left(t_{i,k} - \frac{L_k}{\bar{v}_k} \frac{l_{i,k}}{L_k} \right) \right) \quad (3)$$

T_{t+12} : 時刻 $t + 7$ から $t + 12$ までの 5 分間の全リンク内の総遅れ時間

N_{t+12} : 時刻 $t + 7$ から $t + 12$ までのリンク k 内存在車両台数

$t_{i,k}$: リンク k 内の車両 i の旅行時間

\bar{v}_k : リンク k 内の規制速度

$l_{i,k}$: リンク k 内の車両 i の走行距離

L_k : リンク k の距離

図-2 に AI のニューラルネットワークとしての行動をまとめた、本構造は中間層として LSTM 層と全結合層を 1 つずつ含む。LSTM 層のノード数は AI 入力変数の個数に等しく、その次の全結合層のノード数は 2 個である。また伝送遅れの有り無しの各ケースにおける、AI 入力変数の時系列に沿った関係を表したものが図-3 である。以降、伝送遅れ有りのケースを想定する。

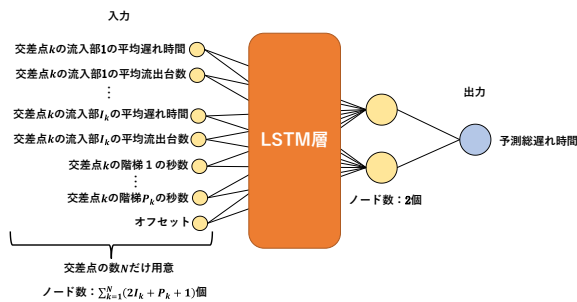


図-2 モデル概要

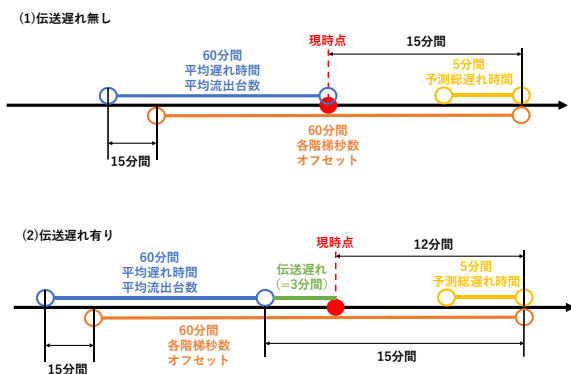


図-3 AI 入力変数の時系列

d) AI の学習

AI の学習には、各交差点の階梯秒数に乱数を与えた交通シミュレーションの結果を用いる。実際の学習データ収集のための、交通シミュレーション設定条件や学習結果は第 4 章で示す。

(3) 探索

a) 最適化問題の定義

探索の目標は、予測総遅れ時間を最小にする信号制御を行うことである。この探索は予測総遅れ時間を算出する AI を含む関数を目的関数とした、目的関数の値を最小化する最適化問題ととらえることができる。

b) 最適化問題における変数

最適化問題において変数として扱う値は、将来 10 サイクル分の主方向青時間スプリット・重要交差点のサイクル長・重要交差点サイクル長との差である。これらには、最大値、最小値の制約が存在するため、式(4)に示す実数空間全体から、この範囲内の値への変換式を用いることで、Nelder-Mead 法では実数空間全体の探索を行う構造とした。

$$P = \frac{\min - MAX}{1 + \exp(x)} + MAX \quad (4)$$

P : 信号制御パラメータ（主方向青時間スプリット・重要交差点サイクル長・重要交差点サイクル長との差）

x : $(-\infty, \infty)$ の実数

MAX : 信号制御パラメータの最大値

\min : 信号制御パラメータの最小値

必要な信号制御パラメータは、主方向青時間スプリット・重要交差点のサイクル長・重要交差点サイクル長との差である。例えば、2 現示の M 個の信号交差点においては、1 サイクルあたり、主方向の青時間スプリット M 個と、重要交差点のサイクル長 1 個と、それ以外の交差点における重要交差点サイクル長との差 $(M-1)$ 個を合わせて、 $2M$ 個となる。オフセットに関しては、重要交差点のサイクル長との差で考慮される。

必要な信号制御パラメータは、主方向青時間スプリット・重要交差点のサイクル長・重要交差点サイクル長との差である。例えば、2 現示の M 個の信号交差点においては、1 サイクルあたり、主方向の青時間スプリット M 個と、重要交差点のサイクル長 1 個と、それ以外の交差点における重要交差点サイクル長との差 $(M-1)$ 個を合わせて、 $2M$ 個となる。オフセットに関しては、重要交差点のサイクル長との差で考慮される。

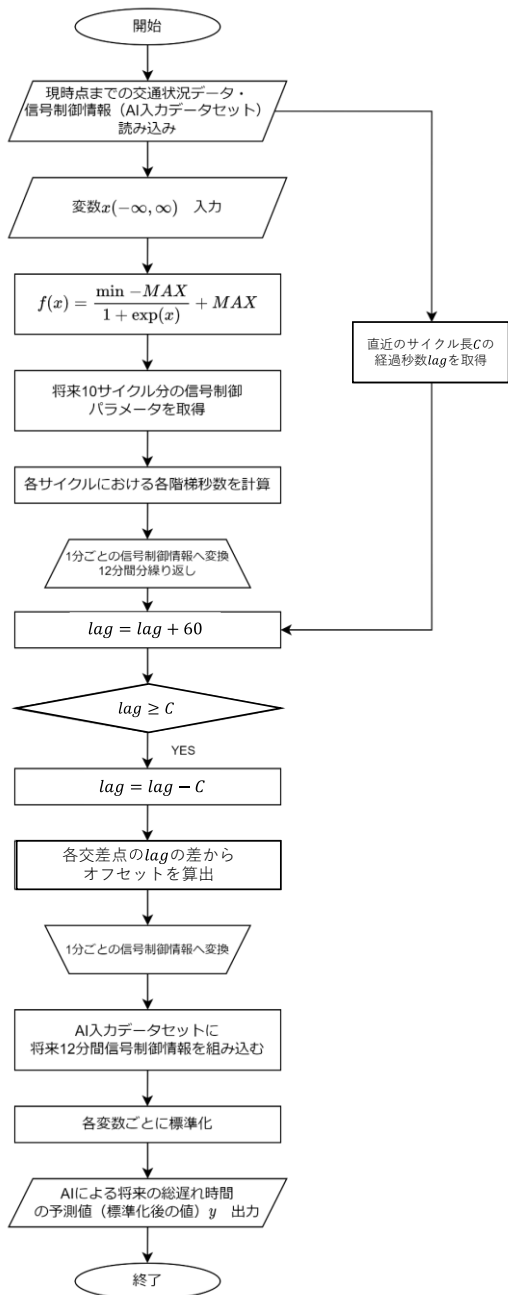


図-4 目的関数のフロー

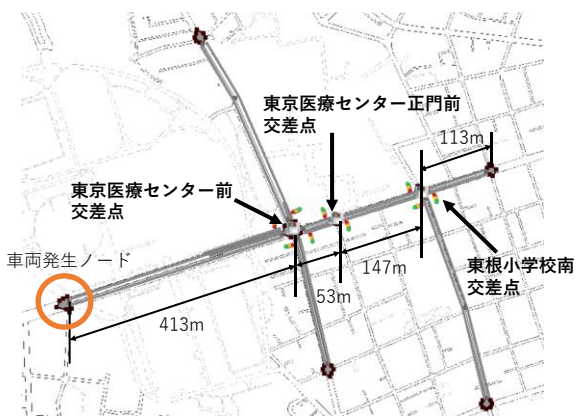


図-5 ネットワークモデル

c) 目的関数

a)節で変換された将来10サイクル分の主方向青時間スプリット・重要交差点のサイクル長・重要交差点サイクル長との差を、12分間1分刻みの各階梯秒数及びオフセットへ変換し、AIの入力データの将来の12タイムステップ分とする。直近のタイムステップのデータと合わせてAIへ入力し、得られた予測総遅れ時間を目的関数の出力とする。図-4に、目的関数のフローを示す。

d) 探索アルゴリズムと初期値

探索には非凸関数にも対応しており、局所解を得るNelder-Mead法を採用した。Nelder-Mead法では、変数の数がNである場合、N+1個の解候補群を初期値として与える。この初期値は、後述する従来信号制御手法により算出された値に近い値を設定する。また、現実的に信号制御へ応用可能な枠組みにするために、探索時間を現在のサイクルが終了するまでの時間に制限する。具体的には、次のサイクルが始まる時刻までの時間で、探索が収束したかどうかに関わらず探索を打ち切る。

4. 実在ネットワークを対象としたAIDPのシミュレーション評価

(1) 評価方法

シミュレーション評価では、プローブ情報を信号制御に活用した場合の制御効果を定量評価し、課題や要件について考察することを目的とする。評価に交通シミュレーションを用いる理由は、低コストかつ、実社会へ影響を及ぼすことなく、制御効果を把握することができるためである。本研究では、株式会社アイ・トランスポート・ラボより提供されているAVENUE[®]を用いる。

ネットワークのモデルは、東京都世田谷区にある駒沢通り(都道416号)の東西約700m、「東京医療センター前」、「東京医療センター正門前」、「東根小学校南」の3交差点である(図-5)。

交通条件として、10分おきのOD交通量・車種構成・プローブ車混入率・希望速度を設定した。発生交通量は、全国道路・街路交通情勢調査⁹⁾の結果を参考に平均発生交通量を設定し、ポアソン分布を仮定した確率分布で10分おきに変動する10分間発生交通量を設定する。さらに、この10分間発生交通量に対して、各OD交通量にランダムに振り分ける。なお、橙色ノードの1か所のみから車両を発生させることとした。その理由は、本研究の初期段階においては信号制御手法の構築にフォーカスを当てており、この段階ではネットワーク設定条件をできる限り単純にすることで、制御手法の特性を把握しやすくするためである。発生する車種は全車両、小型車で、希望速度は、規制速度である40km/hとする。またプロ

表-1 シミュレーション評価における交通条件

10分間平均発生交通量 (台) (平均に対し, ポアソン分布を仮定した確率分布で10分おきに変動)	107
車種構成	小型車のみ
プローブ車混入率 (%)	30
希望速度 (km/h)	40 (規制速度)
従方向の青時間スプリット	0.4以上を確保

表-2 AI学習データにおける交通条件

ネットワークモデル	駒沢通り
10分間平均発生交通量 (台) (平均に対し, ポアソン分布を仮定した確率分布で10分おきに変動)	107
車種構成	小型車のみ
プローブ車混入率 (%)	30
希望速度 (km/h)	40 (規制速度)
従方向の青時間スプリット	制約なし
シミュレーション時間	6:50~9:30 (データ収集は7:30~8:29)
発生交通量のシード値	乱数
車両発生間隔のシード値	1000




図-6 評価関数の出力推移

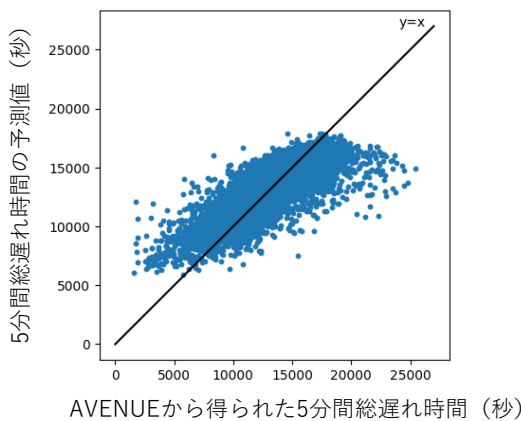


図-7 5分間総遅れ時間の予測値と真値

一車混入率は, 30%とする. また, 今回のケースでは従方向の車両を発生させない代わりに, 従方向スプリットは 0.4 以上確保するように制約をかける. 以上をまとめたものが, 表-1 である.

(2) AI 学習結果

AI の学習時にはドロップアウトを用いており, 過学習をある程度抑制している. 評価関数には絶対平均誤差 (MAE)を用いた. 学習データを収集するにあたり, AVENUE の設定条件を表-2 にまとめた. 合計で 9000 個の時系列データをを用いて学習を行った. 9000個あるデータのうち, 7200個を訓練データ, 1800個を検証データとし, エポック数(学習する回数)を 200 回, バッチサイズ (1 エポックあたりのデータ個数) を 100 個とした. 7200個のうち 100個を選ぶ選び方はランダムとする.

学習の結果を, 図-6 に示す. 図-6 は, 評価関数である絶対平均誤差の推移を, エポック数ごとに示したものである. なお縦軸は, 標準化後の総遅れ時間の絶対平均誤差を表している. これを見ると, エポック数が増えるごとに, 訓練・検証データ共に, 絶対平均誤差が単調に減少するという損失と同様の傾向が見られた. さらに検証データは, 絶対平均誤差の増加が見られないことから, 過学習は起きていないと言える.

図-7 は, 5分間総遅れ時間の予測値と, AVENUE の結果から得られた全車両の 5分間総遅れ時間, すなわち真値における分布をプロットしたものである. 図中の黒線は $y=x$ の線を示しており, 図-7 を見ると, 黒線に対して全体のプロットが寝ている. すなわち, 5分間総遅れ時間が大きくなるほど, 過小に予測し, 5分間総遅れ時間が小さくなるほど, 過大に評価する傾向があると言える. プロットが寝てしまう原因として, 予測総遅れ時間を説明するための情報が入力変数に不足していることや, 入力変数に情報はあっても, 不要な情報に埋もれてしまい入力変数から重要な情報を抽出できていないことなどが考えられる. 対処方法として, より大きな, あるいはより小さな 5分間総遅れ時間となったときのデータを拡充し, AI に学習させることが考えられる. また, 今回構築したニューラルネットワークは図-2 に挙げたように, LSTM 層 1 個と通常の層 1 個といった単純なものとなっているため, LSTM 層や通常の層, ノード数を増やすことによって, より複雑な構成にするということも考えられる. 以降, AIDP では, 学習済み AI を用いる.

(3) 従来信号制御手法による信号制御パラメータ算出

AIDP の有用性を確かめるための比較対象として, 従来信号制御手法による制御効果を確認する必要がある. 従来信号制御手法として第 1 章で説明したプログラム選

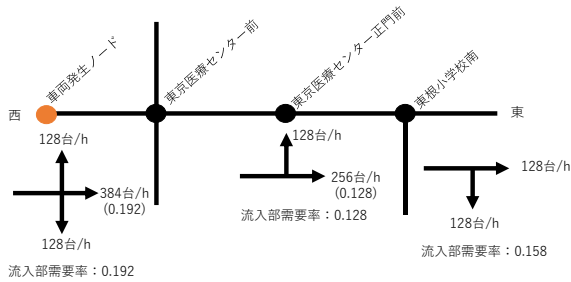


図-8 各交差点の設計交通量

表-3 従来信号制御手法による各階梯秒数

	サイクル長 (秒)	47
「東京医療センター前」	主方向の青時間 (秒)	14
	従方向の青時間 (秒)	15
	右折矢印 (秒)	5
	サイクル長 (秒)	47
「東京医療センター正門前」	主方向の青時間 (秒)	24
	従方向の青時間 (秒)	20
	サイクル長 (秒)	47
「東根小学校南」	主方向の青時間 (秒)	20
	従方向の青時間 (秒)	17
	サイクル長 (秒)	47

択制御を採用した。

従来信号制御手法による信号制御パラメータの算出方法を示す。ここでは、発生交通量が平均 107 (台/10min) の場合を考える。まずは各流入方向の需要率を求める。需要率とは、設計交通量を飽和交通流率で除したものである (式(5))。

$$\lambda = \frac{q}{s} \tag{5}$$

λ : 需要率

q : 設計交通量[台/時間]

s : 飽和交通流率[台/青1時間]

発生交通量が 107 (台/10min) である場合、1 時間あたりに換算すると、642 (台/h) となる。これを 5 つの OD に均等に分けると、1 つの OD 交通量は 128 (台/h) となる。ゆえに、各交差点の設計交通量は図-8 のようになる。

「東京医療センター前」の直進方向の需要率は、 $q = 384, s = 2000$ より $384/2000 = 0.192$ となる。左折・右折方向需要率はそれぞれ、 $q = 128, s = 1800$ より $128/1800 = 0.071$ となる。よって、「東京医療センター前」主方向

の需要率は 0.192 となる。今回のケースでは従方向の青時間スプリットを 0.45 確保する。よって、従方向の需要率は、0.215 となる。したがって「東京医療センター前」交差点の需要率は、 $0.192 + 0.071 + 0.215 = 0.478$ となる。この交差点は重要交差点であるため、ここのサイクル長を全交差点において共通のものとする。サイクル長は Webster の実験式 (式(6)) にしたがって算出する。

$$C = \frac{1.5 * L + 5}{1 - \lambda} \tag{6}$$

C : サイクル長[秒]

L : 損失時間[秒]

λ : 交差点の需要率

$L = 13, \lambda = 0.478$ より、 $(1.5 * 13 + 5) / (1 - 0.478) = 47$ (秒) が共通サイクル長となる。次に青時間を求める。主方向の青時間は、 $(47 - 13) * 0.192 / 0.478 = 14$ (秒)。右折矢印は $(47 - 13) * 0.071 / 0.478 = 5$ (秒)。従方向は、 $(47 - 13) * 0.215 / 0.478 = 15$ (秒)。

「東京医療センター正門前」の主方向の需要率は、 $q = 256, s = 2000$ より $256/2000 = 0.128$ となる。また、同様に従方向の青時間スプリットを 0.45 確保する。よって、従方向の需要率は、0.105 となる。以上より、「東京医療センター正門前」交差点の需要率は、 $0.128 + 0.105 = 0.233$ となる。サイクル長は「東京医療センター前」と共通より、47 (秒)。主方向の青時間は、 $(47 - 3) * 0.128 / 0.233 = 24$ (秒)。従方向は $(47 - 3) * 0.105 / 0.233 = 20$ (秒)。

「東根小学校南」の主方向は右直混用車線である。そのため、飽和交通流率の基本値に対して補正率を乗じる必要がある。まず、左折車混入率は $(128/256) * 100 = 50\%$ である。また、右折車の直進車換算係数は 3.95 とする。したがって右折車混入による飽和交通流率の補正率は、 $100 / (50 + 50 * 3.95) = 0.404$ となる。よって飽和交通流率は $2000 * 0.404 = 808$ となるため、主方向の需要率は、 $128/808 = 0.158$ となる。また、同様に従方向の青時間スプリットを 0.45 確保するため、従方向の需要率は、0.129 となる。以上より、「東根小学校南」交差点の需要率は、 $0.158 + 0.129 = 0.287$ となる。サイクル長は「東京医療センター前」と共通より、47 (秒)。主方向の青時間は、 $(47 - 10) * 0.158 / 0.287 = 20$ (秒)。従方向は $(47 - 10) * 0.129 / 0.287 = 17$ (秒)。以上をまとめると、表-3 のようになる。

(4) シミュレーション結果

図-9 は、両信号制御手法の制御開始からの総遅れ時間の分布を箱ひげ図で表したものである。図を見ると、従

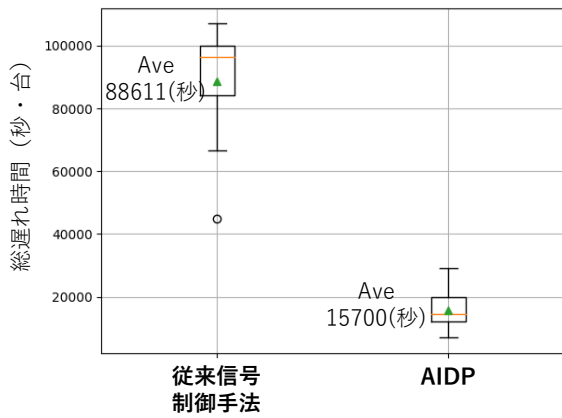


図-9 各制御手法に対する総遅れ時間の分布




図-10 各制御手法に対する5分間総遅れ時間の推移




図-11 探索前後の予測総遅れ時間差の分布

来信号制御手法に対して、AIDP の総遅れ時間が明らかに小さくなっていることが分かる。従来信号制御手法に対して、AIDP の総遅れ時間の平均値はおよそ 82%だけ減少し、その差は0.1%で有意な差であった。(t=-14.47, df=18, p=1.541e-07)

図-10は、両信号制御手法における、5分間総遅れ時間の平均値の推移と、探索の前後における予測総遅れ時間の推移を、制御開始からシミュレーション終了まで表したものである。従来信号制御手法では時間経過ごとに、平均5分間総遅れ時間が上昇していくことが分かる。一方で、AIDP では、増減を繰り返しつつも、ほぼ横ばいに推移していることがわかる。両手法に対する平均5分間総遅れ時間の差はかなり明確に出ていることが分かる。このことから、従来信号制御手法に対する AIDP の有用性が確かめられる。この AIDP の遅れ時間の増減は、約 10 分で繰り返されており、AIDP における遅れ時間の予測も 12 分と近い値であることから、予測時間の影響が結果に出ている可能性がある。また、探索後の予測総遅れ時間は、実際の値(赤線)と比較すると、過大予測となっている。これは図-7で見られたように、実際の5分間総遅れ時間が小さい場合、過大に予測されるという傾向に沿っている。また探索前後で、予測総遅れ時間が小さくなっていることが分かり、正常に探索が行われていることが確かめられる。

図-11 は、探索前後の予測総遅れ時間の差をパレート図に表したものである。図より、探索の大部分が 3000 秒前後の短縮に成功していることが分かる。一方で、500 秒前後の短縮に留まる場合も見られた。これは、探索開始が前サイクルの終了が間近で、ほとんど探索時間が取れなかったことが原因であると考えられる。

図-12 は、「東京医療センター前」交差点における、青時間の推移と、5分間総遅れ時間、発生交通量、平均流出台数の推移の一例を示したものである。これを見る




図-12 青時間、5分間総遅れ時間、発生交通量、平均流出台数の推移の一例

と、1 サイクルごとに信号制御パラメータが変動していることが分かる。ただし、信号制御パラメータの推移と、5 分間総遅れ時間、発生交通量、平均流出台数の推移に明確な関係があるとは言い難い結果となった。

5. まとめ

(1) 結論

本研究では、プローブ情報を活用した遅れ時間の AI 短期予測に基づく信号制御手法の構築ならびに、交通シミュレーションを用いた当該手法の定量評価を行うことができた。従来信号制御手法と比較した場合、総遅れ時間は有意に小さくなり、プローブ情報を活用した信号制御の有用性が明らかとなった。

(2) 課題

本研究では、AIDP の実装と評価により大きく 5 つの課題が明らかになった。

1 つ目は、図-10 において見られたように、AIDP に対する 5 分間総遅れ時間が増減を繰り返しながらも、ほぼ横ばいになったことである。遅れ時間の増減には、予測時間の影響があったと考えられ、今後は予測時間に関して慎重に考慮する必要がある。

2 つ目は最小の予測総遅れ時間を十分に探索しきれていないといった探索性能の問題がある。この問題に関連する要因に、不十分な探索時間・変数の多さ・初期値の与え方などが挙げられる。探索時間に関しては、本研究で用いた交通シミュレーションのシステム上、最大でも 30 秒としている。収束するまでに、通常、数分程度かかることを考えると、30 秒では不十分であると言える。対策として、信号制御と並行して常時探索を行うようにすることが考えられる。変数の多さに関しては、サイクル長や青時間スプリットを共通にするなどといった工夫で解決できる可能性がある。また、初期値によって探索結果が変わる傾向があるため、初期値は慎重に選定を行う必要がある。

3 つ目は AI 予測精度に関する問題である。具体的には、総遅れ時間が大きくなるほど、あるいは、小さくなるほど、誤差が大きくなるといった問題がある。これに対しては、総遅れ時間が小さい場合と大きい場合のデータを拡充して AI に学習させることや、ニューラルネットワークの構造をさらに複雑にすることなどが考えられる。さらには、学習データの中で、先詰まりの有無について考慮することも必要であると考えられる。

4 つ目は、図-12 で見られたように、5 分間総遅れ時間や発生交通量、平均流出台数に追従した信号制御パラメ

ータが実行されているとは言い難い結果となった点である。これは、探索性能か AI 予測精度か、或いはその他のことが起因しているのかどうか慎重に分析を深めていく必要がある。

5 つ目は、交通シミュレーション設定に関して、対向・交差方向の発生交通を考慮していない点や、3 交差点しか制御対象に入れていない点である。本研究では、信号制御手法の構築に主眼を置いたため、交通シミュレーションの設定条件はできるだけ単純にすることで、制御が上手くいかなかった場合に、その原因を特定しやすくするようにした。そのため、発生交通は 1 方向のみしか設定しておらず、また、3 交差点しか制御対象としていない。実際の交差点で信号制御を行うにあたっては、主方向・従方向の両方の交通状況を鑑みた上で、複数交差点において系統的に、最適な制御を行う必要がある。そのため、実際の状況に最適な信号制御手法の構築・シミュレーション評価を行うためには、交通シミュレーションにおいて、対向・交差方向の発生交通や、より多くの交差点を含んだネットワークの設定を行う必要がある。

REFERENCES

- 1) 一般社団法人 交通工学研究会：平面交差の計画と設計 基礎編 一計画・設計・交通信号制御の手引一，2018.11
- 2) 関達也，島津利行，和智誠，榊原肇，大口敬：プローブ情報を活用した信号制御の見直しについて，交通工学論文集，第 8 巻，第 1 号，pp.31-38, 2022.1
- 3) 吉岡利也，榊原肇，テンハーゲンロビン，ローコウスキステファン，大口敬：プローブカーデータを用いた信号制御パラメータ算出手法，生産研究，74 巻 1 号，pp.115-122, 2022
- 4) 長島靖，服部理，小林雅文：プローブ情報の活用による信号制御高度化，SEI テクニカルレビュー，第 184 号，pp.40-pp.43, 2014.1
- 5) 西内裕晶，吉井稔雄：簡易車両感知器とプローブカーを用いた信号制御システム ～システムの構築と道路工事実施時の片側交互通行区間への適用～，交通工学第 39 巻，4 号，p.46, 2004
- 6) 花房比左友，飯島護久，堀口良太：リアルタイム信号制御アルゴリズムのためのプローブ情報を利用した遅れ時間評価，第 8 回 ITS シンポジウム，2009
- 7) 塚田悟之：プローブ情報を活用した信号制御定数パターン見直し支援システムの構築，情報システム学会誌，Vol.14, No.2, pp.65-78, 2018.12
- 8) 株式会社アイ・トランスポート・ラボ：AVENUE 紹介 ホーム ページ ， <http://www.i-transportlab.jp/products/avenue>
- 9) 国土交通省：全国道路・街路交通情勢調査，<https://www.mlit.go.jp/road/census/h27/index.html>

(Received March 6, 2023)