

離散コサイン変換に基づく 交通流理論の量子化表現

小川 大智¹・羽藤 英二²

¹ 学生会員 東京大学大学院 工学系研究科社会基盤学専攻 (〒113-8656 東京都文京区本郷 7-3-1)
E-mail: dogawa@bin.t.u-tokyo.ac.jp

² 正会員 東京大学大学院教授 工学系研究科社会基盤学専攻 (〒113-8656 東京都文京区本郷 7-3-1)
E-mail: hato@bin.t.u-tokyo.ac.jp

計算機の発達や GPS の普及、また自動運転車の出現に伴い、データとシミュレーションを活用した都市の交通計画の評価は重要性を増している。シミュレーションベースの設計最適化にあたっては、佐佐木¹⁾に代表される車両追従の交通流理論に加え、数値的な実装としてのシミュレーション技術が存在し、機械学習との組み合わせが期待されている。一方で、自動走行でのプラトウニングなどの挙動は、先頭車と後続車が同期することで車列としての情報量が圧縮されており、車両挙動のメカニズムの立式を基本としない従前の機械学習モデルでは、非効率な学習となることが考えられる。そこで本研究では離散コサイン変換とラプラス変換によって車両状態を低次元化し、情報圧縮の精度を評価するとともに、機械学習モデルとの組み合わせ方法について検討を行う。

Key Words: *Surrogate model, Traffic simulation, Neural network*

1. はじめに

交通流理論には佐佐木の追従理論¹⁾などいくつかの理論が存在する一方で、解析的なこれらの理論式をもとに計算の素過程を繰り返すことで場の統計量を推計するシミュレーション技術が存在する。機械学習はこうした第一原理と言える交通流理論を補完し不安定な場の統計量の関係を推計することによって短期的に予測制御を支援するものと考えられる。交通流の支配方程式と機械学習を組み合わせることで場の情報量の時間展開を表現できる一方、自動走行によるプラトウニングなどの挙動は先頭車と後続車が同期することから速度変動などの情報量が圧縮されており、従前の機械学習ではこのような変化する車両挙動のメカニズムの立式を基本としていないため非効率な学習となることに問題があると考えられる。さらに自動走行制御の実現には時空間ネットワーク上の車両同士の動的組み合わせ最適化問題を実現するなんらかの数理的な方法が必要とされており、新たな交通流の表現形式の必要性は高いと言えよう。そこで本研究では離散コサイン変換とラプラス変換によって車両挙動の情報を量子化する方法論を提案し、周波数解析によって交通流の情報圧縮と損失性能の評価を試みる。

2. シミュレーションによる最適化とサロゲートモデル

(1) シミュレーションによる最適化問題の概要と課題

近年の計算機の性能の向上や、スマートフォンの普及に伴うデータの取得可能性の向上、それに付随したモデル適用範囲の拡大に伴い、交通ネットワークや交通サービス、避難計画等を設計する際に、シミュレーションを用いて設計案の性能を評価するということが行われてきている²⁾³⁾

また、近年は、シミュレーションによる設計案ごとの比較にとどまらず、シミュレーションを用いて交通ネットワークの設計変数を最適化しようという取り組みも行われている。説明変数である設計変数と目的関数であるネットワーク評価基準の関係は、一般に解析的には与えられないため、繰り返しのシミュレーションの実行により目的関数を学習しながら最適解を探索するという方法がとられる⁴⁾。

交通ネットワークの設計におけるシミュレーションベースの最適化問題は、交通ネットワークの設計変数を説明変数とし、リンク混雑率や平均トリップ時間、トリップ完了率等の評価指標の期待




図-1 シミュレーションを用いた最適化問題の概要

値等を目的関数とする最適化問題である。交通に関するシミュレーションモデルでは、ゾーン内での集計量を扱うものや、車両ごとの状態を逐次的に更新していくようなマイクロモデル、静的なネットワークを扱うものから動的に変化する交通状態を記述するもの、また、土地利用と相互作用する交通状況のダイナミクスを扱うものなど多様なものが開発されている⁵⁾⁶⁾⁷⁾。交通行動は非常に複雑であることから、その単純化である交通モデルに万能なものは存在せず、政策の目的やスケールに応じて適したモデルが選択される⁸⁾。

一般的に、シミュレーションにより求まる目的関数は解析解を持たないため、説明変数と目的関数の関係は繰り返しのシミュレーション結果に基づき学習され、学習された目的関数に対して一般的な最適化問題の求解アルゴリズムを用いて、最適な説明変数を探索する⁴⁾。この方法では、目的関数を定義域で満遍なく学習する必要があり、目的関数の複雑さに応じてシミュレーションを多数回繰り返し実行する必要がある。一般にマクロなモデルでは計算コストが抑えられているが⁹⁾、近年のリアルタイムでの公共交通のオペレーション¹⁰⁾や自動運転等を含むマルチモーダルな交通システム¹¹⁾の設計など、時空間的に解像度の高い政策を評価するためには、マイクロなシミュレーションを用いる必要がある。そういった、リンクや車両のスケールでのシミュレーションでは計算コストが非常に高くなる。マイクロモデルで最適化問題を効率よく解くために、既往研究では、最適解近傍を限られた数のパラメータを持つ関数で近似し最適解の探索効率を高める方法¹²⁾や、解析解を持つ単純なモデルと誤差項を表す簡単な関数で目的関数を近似することで学習コストを減らす方法¹³⁾などが提案されている。また、機械学習モデルの表現力の向上に伴い、第一原理に基づくシミュレーションの結果を機械学習モデルで学習し、シミュレーションの計算を高速な機械学習モデルで代理するという方法が多方面で検討されている¹⁴⁾。サロゲートモデルを用いた最適化問題のフレームワークを図1に示す。サロゲートモデルを用いる方法としては、一般的な機械学習モデルによりサロゲートモデルを構築した際のサンプル数と推定精度、モデル学習時間の関係を調べ、モデル複雑さとモデル予測精度のバランスの指標であるAIC¹⁵⁾を用いて、モデルを選択する方法が提案されている¹⁶⁾。一方で、これらはマイクロモデルの支配方程式である車両追従式等の構造を考慮したものではないため、近似に用いる関数が目的関数を効率的に捉えやすい表現力をとっているかという点に

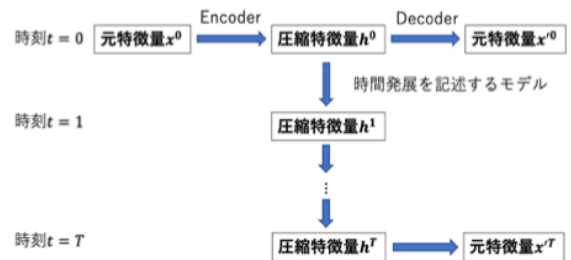


図-2 圧縮された特徴量による計算効率化の概略

疑問が残る。複雑な形の目的関数を、限られた数のサンプルを用いて近似するためには、シミュレーションの支配方程式を何らかの形で事前情報として与える必要があると考えられる。

(2) シミュレーションの概要とサロゲートモデル

マイクロシミュレーションに用いられる車両追従モデルには追突事故に対する安全性をもとにしたものやファジー理論により判断の曖昧さを表現したものなど、種々の定式化が存在する¹⁷⁾。本研究で扱うシミュレーションは、前方車両との近接性により決定される感度関数と、前方車両との速度差で表される刺激関数の積により次タイムステップでの挙動が決定される、GMモデル¹⁸⁾をベースとしたマイクロモデルを用いている。このモデルでは、追従による車両同士の相互作用を考慮しながら、逐次的に車両位置の更新を行う。車両一台一台の挙動を計算するので、非一樣な交通流を表現することができ、信号における車両滞留や車線数の減少による渋滞の発生などを表現することができる。

このマイクロシミュレーションの計算を機械学習モデルにより代替する上で、車両追従式をどのように機械学習モデルに学習させるかということが問題となる。車両一台一台について、周辺車両との関係性から次の挙動を計算するという定式化では計算の効率性に寄与し難いということから、追従・被追従の関係から成る車列での挙動を学習させるということが考えられる。圧縮した特徴量を用いたシミュレーションのイメージを図2に示す。

車列のとりうる状態は必ずしもランダムなものではなく、一定の規則性や分布の偏りを持つと考えられることから、そのような分布の偏りを学習することが計算の効率性に寄与するものであり、車列の挙動について本質的な情報を与えるものであると考えられる。

そのような考え方は機械学習モデル一般でなされており、代表的な潜在表現の学習手法である、オートエンコーダー¹⁹⁾²⁰⁾をはじめ、エンコーダー・デコーダーの形式を採用する多くの深層学習モデルでは、その表現の獲得がモデルの性能を本質的に決定するものである²¹⁾²²⁾²³⁾。車列内に存在する車両の台数は一定ではないため、可変長の入

力を取ることのできる必要があるが、そのようなモデルとして Seq2seq²³⁾がある。このモデルは、過去の入力を保持するセル状態に、古い情報を維持しつつ新しい入力を取り込む構造を導入することにより、可変長のデータを精度良く扱うことのできる LSTM²⁴⁾をエンコーダーとデコーダーとして用いている。このモデルにより、可変長である車両状態のベクトルを固定長である隠れ状態のベクトルに圧縮することができる。しかしながら、一般に、ここで求まる隠れ状態の物理的な意味を解釈することは難しい。従って、この隠れ状態が車列の長さによってどのように変化するかということや先頭車の挙動が後続車にどのような影響を与えるかということを知るのは困難である。また、ここではデータに含まれるさまざまなバイアスが反映されている可能性があるため、どの程度の現象までこのモデルが適用可能なのかということや自動運転車など異なる挙動原理に基づく車両が存在する場合に、隠れ状態に必要な次元数はどのように変化するかなどの知見を得ることは難しい。

そこで、以下では、車列内の車両状態の非一様性という観点から、交通流理論を用いて車両状態を圧縮することを試みる。ここで求められる特徴量は、物理的な意味が明確であり、かつ、それを用いて種々の予測を行う機械学習モデルと組み合わせやすいという特徴がなければならない。

3. 車列の量子化表現とその性質

本研究では、まず、このモデルの特徴である非一様な交通流の時系列の変化を、車列単位でまとめて表現することを考える。そのためには、先頭車両の速度が一定で車両がまとまって同じ速さで走っている状態と、先頭車両が信号に捕捉されることなどにより車両速度に揺らぎが生じた状態の時間変化を考える必要がある。車列の状態を離散コサイン変換²⁵⁾すると、変換後の各成分は車列内の車両状態のばらつき具合に対応するというこにに着目し、定式化を行った。本章では、車列状態の量子化表現の具体的な定式化について記述し、車両追従モデルを用いて空間周波数成分の分布の時間変化を考察する。なお、数理的な扱いやすさから、佐佐木の車両追従モデル¹⁾を用いて考察を行う。

(1) 車列の量子化表現の導出

ここでは、車両数 N の車列について考える。車列の先頭の車両から、その速度を $v_i (i \in \{0, 1, \dots, N-1\})$ とし、 N 次元のベクトル $(v_0, v_1, \dots, v_{N-1})^T$ を車列状態とする。また、先頭車を除く $N-1$ 台の車両は佐佐木の追従理論¹⁾に従う。これは、前方車両との速度差という刺激に対して感度関数が一定のモデルである。

$$v_i(t) = \lambda[v_{i-1}(t - \Delta t) - v_i(t - \Delta t)] \quad (1)$$

ただし、 $i \in \{1, \dots, N-1\}$ であり、 λ は車両追従式のパラメータ、 Δt は反応の遅れ時間を表す。本研究では、 $\Delta t = 1$ とする。

車列の量子化表現を得るため、 N が十分大きいとして境界条件を考える。車両速度先頭車両の走行速度と、その後方を走る車両の速度との関係をラプラス変換を用いて制御論的に捉えると、先頭車両速度から、 i 番目の車両の速度への伝達関数 $G_i(s)$ は、以下のように表される。

$$G_i(s) = [G(s)]^i = \left[\frac{\lambda e^{-s}}{s + \lambda e^{-s}} \right]^i \quad (2)$$

このとき、先頭車両と先頭から2番目の車両の速度差のラプラス変換は、線形性より以下のようになる。

$$\begin{aligned} V_0(s) - V_1(s) &= V_0(s)[1 - G(s)] \\ &= V_0(s) \frac{s}{s + \lambda e^{-s}} \end{aligned} \quad (3)$$

先頭車の速度は車両追従式には従わないことから、 $v_0(t) = 0 (t \leq 0)$, $v_0(t) = v_0 (t > 0)$ と仮定すると、

$$V_0(s) - V_1(s) = \frac{v_0}{s + \lambda e^{-s}} \quad (4)$$

となる。特性根を s_i とすると、

$$v_0(t) - v_1(t) = v_0 \sum_{i=1}^{\infty} \left(-\frac{1}{1 + s_i} \right) e^{s_i t} \quad (5)$$

となり、虚軸から最も近いを s_1 とすると、以下のように近似することができる¹⁾。

$$v_0(t) - v_1(t) = v_0 \left(-\frac{1}{1 + s_1} \right) e^{s_1 t} \quad (6)$$

車両1の速度が一定の値に収束するとき、特性根 s_i の実部は0より小さいことから、式(5)の右辺は時間に対して指数関数的に減少する。すなわち、先頭車が一定速度で走っている場合には、 $v_0(t) - v_1(t) \cong 0$ となる。また、追従車両全体の応答が安定であるとき、先頭車の速度変化は減衰して後続車に伝えられる。すなわち、車両数 N が十分大きい場合には、最後尾から2番目の車両の速度変化は先頭車両の速度変化よりも十分緩やかであり、時間に対してほとんど変化しないと考えることができる。車列の先頭での議論と同様にして、最後尾車両の速度は最後尾から2番目の車両とほとんど等しいと考えることができる。

以上から、先頭車両が短い時間の間加減速を行った後、一定速度で走行する様な状況では、

$$\left. \frac{\partial v_n(t)}{\partial n} \right|_{n=0, N} = 0 \quad (7)$$

という境界条件が成り立つ。

この境界条件を満たす車列状態 $v = (v_0, v_1, \dots, v_{N-1})^T$ の基底として、以下のような成分を持つベクトル $u_m = (u_{m0}, \dots, u_{m(N-1)})^T$, $m \in$

$0, \dots, N-1$ を考えることができる

$$u_{mn} = \begin{cases} \frac{1}{\sqrt{N}}, & m = 0 \\ \sqrt{\frac{2}{N}} \cos\left(\frac{m\left(n + \frac{1}{2}\right)}{N} \pi\right), & m \neq 0 \end{cases} \quad (8)$$

このとき、基底変換を行った後の車列状態 s は、行列 $U = (u_{mn})_{mn} \in R^{N \times N}$ を用いて、以下のよう表される。

$$s = Uv \quad (9)$$

また、 U はユニタリ行列であることから、逆変換は以下の様に表される。

$$v = U^T s \quad (10)$$

式(8)の射影は、離散コサイン変換と等しい変換であり、式(9)の射影は逆離散コサイン変換と等しい。離散コサイン変換は、画像や音声の圧縮技術として JPEG²⁶⁾等 で用いられている。この圧縮は、画像等のデータでは隣あうピクセルの値は近い値を取ることが多いため、変換後の成分の分布が偏ることにより成り立っている。この分布の偏りを捉える周波数成分の分析により、より効率的な画像・動画圧縮の方法が検討されている²⁷⁾。一方で、道路上を走行する車両についても、位置の近い車両は似通った速度で走行していると考えることができそうである。離散コサイン変換後の車両状態 s が車両追従式に従ってどのように変化していくかを考察する。なお、今後離散コサイン変換により射影された車両状態 s を、簡略化のためスペクトルと称することとする。また、式(8)での m が小さい成分を低周波成分、大きい成分を高周波成分と呼ぶこととする。これは、図3に示す様に、 m が大きい成分ほど、空間的な値の変動が激しいためである。

(2) 車両追従式に基づくスペクトル成分の変化の分析

ここでは、スペクトル s の時間変化を分析する。初期条件を時刻 $t = 0, 1$ での全車両の速度分布 $v(0), v(1) \in R^N$ として以下の様に与える。

$$v_i(0) = 0 \quad (i \in \{0, \dots, N-1\}) \quad (11)$$

$$v_i(1) = \begin{cases} v_0, & i = 0 \\ 0, & i \in \{1, \dots, N-1\} \end{cases} \quad (12)$$

また、先頭車両の速度 $v_0(t) (t > 1)$ は車両追従式に従わないため、初期条件から決定することができないが、ここでは、簡単のため $v_0(t) = v_0(t > 1)$ とする。




図-3 各基底における成分の分布 ($N = 10$)

式(9)より、車両 i の速度 $v_i(t)$ は時刻 t に対応するスペクトル $s(t)$ を用いて、以下のよう表される。

$$v_i(t) = U^T s(t) = \sum_{m=0}^{N-1} U_{mi} s_m(t) \quad (13)$$

これを式(1)の車両追従式に代入すると、

$$\begin{aligned} v_i(t) &= \lambda \left[\sum_{m=0}^{N-1} U_{m(i-1)} s_m(t-1) - \sum_{m=0}^{N-1} U_{mi} s_m(t-1) \right] \\ &= \lambda \sum_{m=0}^{N-1} (U_{m(i-1)} - U_{mi}) s_m(t-1) \\ &= \lambda \sqrt{\frac{2}{N}} \sum_{m=0}^{N-1} \left[\left(\cos\left(\frac{m\left(i - \frac{1}{2}\right)}{N} \pi\right) - \cos\left(\frac{m\left(i + \frac{1}{2}\right)}{N} \pi\right) \right) s_m(t-1) \right] \end{aligned} \quad (14)$$

次に、 $v(t)$ を離散コサイン変換した結果を $s(t)$ とし、 $s(t)$ の成分が時刻 $t-1$ でのスペクトルを用いてどのように表されるかを考える。ここで、スペクトルの計算は時間とは無関係のため、 $s(t)$ は $v(t)$ の射影結果であると同時に $s(t)$ の時間微分でもある。式(8)より、

$$\begin{aligned}
 s_n(t) &= U_n v(t) = \sum_{i=0}^{N-1} U_{ni} v_i(t) \\
 &= \sum_{i=0}^{N-1} U_{ni} \left[\lambda \sum_{m=0}^{N-1} (U_{m(i-1)} - U_{mi}) s_m(t-1) \right] \\
 &= \sum_{m=0}^{N-1} \left[\lambda \sum_{i=0}^{N-1} U_{ni} (U_{m(i-1)} - U_{mi}) \right] s_m(t-1)
 \end{aligned} \tag{15}$$

ここで、 $s_m(t-1)$ にかかっている係数を A_{nm} とすると、以下のように式変形することができる。

$$\begin{aligned}
 A_{n0} &= \lambda \sum_{i=0}^{N-1} U_{ni} (U_{0(i-1)} - U_{0i}) \\
 &= \lambda \sum_{i=0}^{N-1} U_{ni} \left(\frac{1}{\sqrt{N}} - \frac{1}{\sqrt{N}} \right) \\
 &= 0
 \end{aligned} \tag{16}$$

$$\begin{aligned}
 A_{m0} &= \lambda \sum_{i=0}^{N-1} U_{0i} (U_{m(i-1)} - U_{mi}) \\
 &= \lambda \sum_{i=1}^{N-1} U_{0i} (U_{m(i-1)} - U_{mi}) \\
 &= \lambda \frac{1}{\sqrt{N}} \sum_{i=1}^{N-1} \left(\sqrt{\frac{2}{N}} \cos \left(\frac{m \left(i - \frac{1}{2} \right)}{N} \pi \right) \right. \\
 &\quad \left. - \sqrt{\frac{2}{N}} \cos \left(\frac{m \left(i + \frac{1}{2} \right)}{N} \pi \right) \right) \\
 &= \begin{cases} \frac{2\sqrt{2}\lambda}{N} \sum_{i=1}^{N-1} \frac{\cos \left(\frac{m}{2N} \pi \right) - \cos \left(\frac{3m}{2N} \pi \right)}{1 - \cos \left(\frac{m}{N} \pi \right)}, & m \text{が奇数} \\ 0, & \text{otherwise} \end{cases}
 \end{aligned} \tag{17}$$

$$\begin{aligned}
 A_{nm} &= \lambda \sum_{i=0}^{N-1} U_{ni} (U_{m(i-1)} - U_{mi}) \\
 &= \lambda \sum_{i=1}^{N-1} U_{ni} (U_{m(i-1)} - U_{mi}) \\
 &= \frac{2\lambda}{N} \sum_{i=1}^{N-1} \cos \left(\frac{n \left(i + \frac{1}{2} \right)}{N} \pi \right) \left(\cos \left(\frac{m \left(i - \frac{1}{2} \right)}{N} \pi \right) \cos \left(\frac{m \left(i + \frac{1}{2} \right)}{N} \pi \right) \right)
 \end{aligned} \tag{18}$$

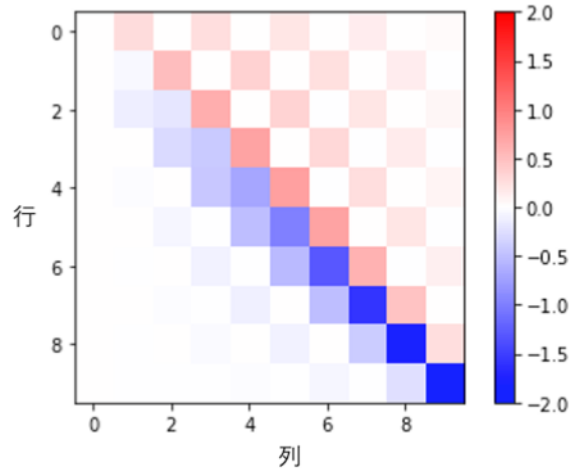


図4 行列 A の成分分布 ($N = 10$)

この行列 A を用いて、スペクトルの時間変化は、

$$s(t) = As(t-1) \tag{19}$$

と表される。 A の要素ごとの値を可視化すると図4のようになり、値が対角成分付近に集中していることがわかる。この傾向は車両数 N が大きいほど顕著であり、 N が十分大きい場合には A は対角行列となる。

式(18)は遅れ時間のある線形の微分方程式であり、スペクトル s のラプラス変換により解くことができる。 $s(t)$ のラプラス変換を $S(\omega)$ とすると、式(18)は以下の様に変換される。

$$\omega S(\omega) - s(0) = e^{-\omega} AS(\omega) \tag{20}$$

$$S(\omega) = (\omega I - e^{-\omega} A)^{-1} s(0) \tag{21}$$

車両数 N が十分大きく、 A が対角行列とみなせるとき、 $m > 0$ について、

$$S_m(\omega) = \frac{s_m(0)}{\omega - e^{-\omega} A_{mm}} \tag{22}$$

式(4)から(6)への変形と同様にして、

$$s_m(t) = s_m(0) \left(-\frac{1}{1 + \omega_1} \right) e^{\omega_1 t} \tag{23}$$

ただし、 ω_1 は式(22)により表されるシステムの特微方程式の最も虚軸に近い根である。 ω_1 の実部が負であれば、成分は時間と共に指数関数的に減少する。 $\omega_1 = \xi_1 + j\eta_1$ とすると、

$$\begin{aligned}
 0 &= \omega_1 - e^{-\omega_1} A_{mm} \\
 &= \omega_1 + e^{-\omega_1} \lambda \left(1 - \cos \left(\frac{m}{N} \pi \right) \right) \\
 &= \left[\xi_1 + \lambda \left(1 - \cos \left(\frac{m}{N} \pi \right) \right) e^{-\xi_1} \cos(\eta_1) \right] \\
 &\quad + j \left[\eta_1 \right. \\
 &\quad \left. - \lambda \left(1 - \cos \left(\frac{m}{N} \pi \right) \right) e^{-\xi_1} \sin(\eta_1) \right]
 \end{aligned} \tag{24}$$

なお、式(18)を $n = m$ の場合に変形すると、 $A_{mm} = -\lambda \left(1 - \cos \left(\frac{m}{N} \pi \right) \right)$ となることを用いた。 $\xi_1 = 0$ を式(24)に代入すると、実部が0になるこ

とより,

$$\eta_1 = \frac{\pi}{2} \quad (25)$$

虚部が 0 となることより,

$$\frac{\pi}{2} - \lambda \left(1 - \cos\left(\frac{m}{N}\pi\right) \right) = 0 \quad (26)$$

$m \in (0, N)$ において, 式(26)を満たす m が存在しない λ の条件は,

$$\lambda < \frac{\pi}{4} \quad (27)$$

であり, これが満たされるとき, スペクトルの第 0 成分以外は時間と共に指数関数的に減衰していく. この減衰の速度は高周波成分になるほど大きい. 図 5 にスペクトルの高周波成分の減衰のイメージを示す. 時間の経過とともに車両の速度のばらつきが減少し, 最終的に第 0 成分, すなわち全車両が等しい速度である成分のみが残ることがわかる.

(3) 量子化表現の意義

以上の検討から, 量子化表現された車両状態では, 高次の成分は速やかに減衰してしまうため, 低次の項にのみ注目すれば良いことがわかる. 今回検討したのは, 線形の車両追従式に対してのみであるが, 非線形のモデルであっても一定速度で走行する車両を複数車両が追従する場合には全車両が先頭車両の速度に近づいていくと考えられることから, 同様の議論が成り立つと考えられる. これを用いると, 扱う変数の数を情報落ち少なく減らすことができるので, シミュレーションの計算効率を高められることが期待できる. 仮に車列の数が一リンクにつき一つと仮定すれば, 扱う変数の数はリンク数に比例することとなり, 交通容量に比例する計算ではなくなる.

また, 車列の量子化表現では, 車両の状態を前

方車両から後方車両への影響の伝搬という捉え方ではなく, 車列全体での場の揺らぎという視点で表現し直している. 信号停止からの発進や希望走行速度, 遅れ時間のばらつき等に伴う車列内での状態の揺らぎは, 運転者が過減速を行う回数を増加させ, 道路の交通容量を減少させる原因になると考えられるが, 2. (1)(2)における定式化では, 車列内の揺らぎの時間変化を微分方程式により直接記述しており, この非効率性を直接的に評価できる手法となりうる. 例えば, 自動運転車両の混在する道路空間では, 非自動運転車と自動運転車の異質性がしばしば問題となる. 両者の間には, 遅れ時間や希望走行速度での差異や, プラトウニング等に代表される行動原理, 追従時における各車両のばらつき具合に違いがあり, それを利用した次元の削減や行動原理の違いに起因する場の揺らぎを解析する際に有用であると考えられる.

4. スペクトルの変化に着目したサロゲートモデル

以上では, 離散コサイン変換により, 多数の車両からなる車列の状態を効率的に低次元の特徴量に圧縮することができることを述べた. 3. で考えた線形モデルでは, 車列の速度の変化は解析的に計算することができるが, 一般の非線形モデルでは, そのような解析的な扱いは難しい. 以上で検討した内容は, 車列の特徴量を圧縮するという点では一般的であることから, さまざまなシミュレーションモデルに適用可能であると考えられ, 各モデルに合わせて柔軟に応用できることが望ましいと考えられる. 本章では, 圧縮された車列の状態を用いて, できる限り少ない数のパラメータでネットワーク状態の変化を記述することを考え

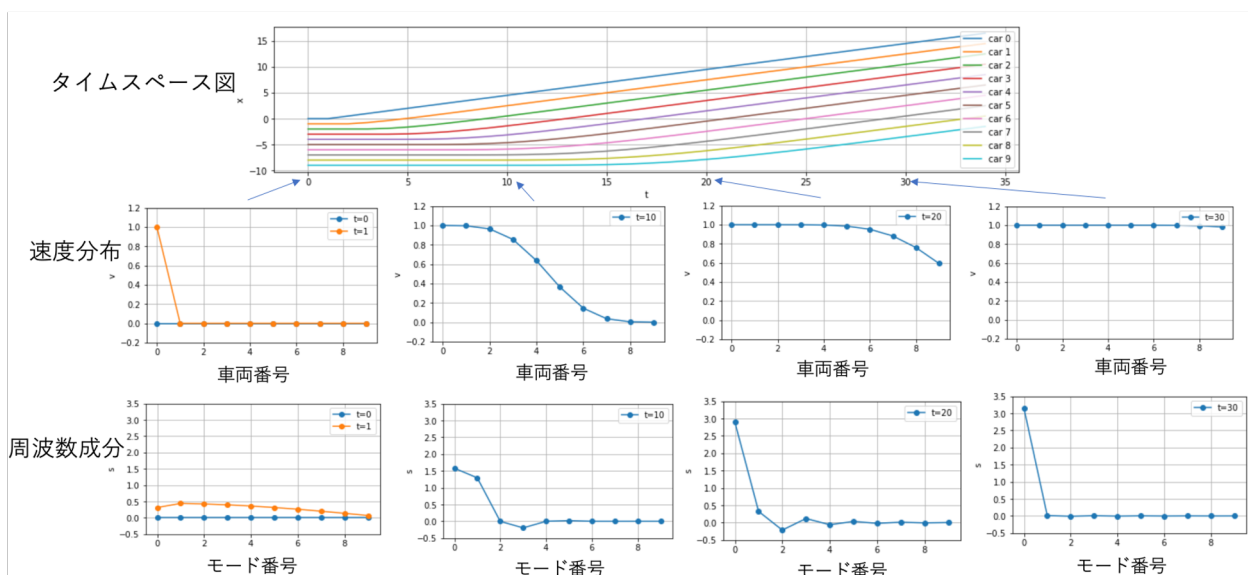


図-5 実空間上での速度分布と周波数成分の関係のイメージ

る．ここでは，非線形の関数を柔軟に扱うことができる，ニューラルネットワーク²⁸⁾を用いて車両状態の変化を近似することを考える．

(1) モデルの構造

一般の車両追従モデルでは，時刻 t での車両の加速度は，前方車両の挙動への感度を表す感度関数と，前方車両の挙動が後方車両の挙動をどれだけ影響を与えるかを表す刺激関数との積で表される．ここで，感度関数は，時刻 t における射等間隔や走行速度の影響を受けるが，刺激関数は，運転者の認知に遅れ時間が発生するため，時刻 $t - \Delta t$ での状態から決定される．一般に刺激関数は前方車両との速度差である．

ここでは，離散化された時間でのシミュレーションを考え，簡単のためシミュレーションのタイムステップと遅れ時間 Δt が共に 1 秒である状況を考える．

このとき，3. で考えた線形モデルは，以下のような式で表される．

$$\begin{aligned} s(t) &= s(t-1) + \dot{s}(t-1) \\ &= s(t-1) + A s(t-2) \end{aligned} \quad (28)$$

特徴量の次元を圧縮するにあたり， s の成分のうち，第 $l-1$ 周波数成分まで考慮するとし，第 l 成分以降は成分の値の平均を用いて考えるものとする．

このとき，新しいベクトル及び行列 $s' \in R^{l+1}$ ， $A' \in R^{(l+1) \times (l+1)}$ を用いて，次のように書き直すことができる．

$$s'_m(t) = \begin{cases} s_m(t), & m < l \\ \text{mean}(s_l(t), \dots, s_{N-1}(t)), & m = l \end{cases} \quad (29)$$

$$A'_{nm} = \begin{cases} A_{nm} & n, m < l \\ \frac{1}{N-l} \sum_{n'=l}^{N-1} A_{n'm} & n = l, m < l \\ \sum_{m'=l}^{N-1} A_{nm'} & n < l, m = l \\ \frac{1}{N-l} \sum_{n=l}^{N-1} \sum_{m'=l}^{N-1} A_{n'm'} & n = m = l \end{cases} \quad (30)$$

$$s'(t) = s'(t-1) + A' s'(t-2) \quad (31)$$

また，時刻 t における先頭車両の速度の変化を $\delta v_0(t)$ とすると，その成分のスペクトルへの影響 $\delta s(t)$ は，

$$\delta s(t) = U'_0 \delta v_0(t) \quad (32)$$

$$U'_{m0} = \begin{cases} U_{m0}, & m < l \\ \frac{1}{N-l} \sum_{m'=l}^{N-1} U_{m'0}, & m = l \end{cases} \quad (33)$$

以上を合わせると，

$$s'(t) = s'(t-1) + A' s'(t-2) + U'_0 \delta v_0(t) \quad (34)$$

となる．ここで，式(18)を用いると車両数 N が l に比べ十分に大きい場合には， A' の各要素は N に反比例する形となる．これは，先頭車両の速度の変化が車列の後ろまで届くのにかかる時間が車列内の車両の台数に比例して増大するという事実と等しい． A' の各要素を N 倍した行列 A'' を用いると，

$$s'(t) = s'(t-1) + \frac{1}{N} A'' s'(t-2) + U'_0 \delta v_0(t) \quad (35)$$

となり，車列状態の変化が車両数 N に依存しない形で書くことができる．

A'' は行列であるが，この写像をニューラルネットワークにより近似することを考える．それにより，関数の学習コストを抑えた上で，支配方程式としての追従式の変化をより直接的に学習することができると考えられる．

すなわち，ニューラルネットワークの関数を f とすると，シミュレーションモデルは次のような形で描くことができる．

$$s'(t) = s'(t-1) + \frac{1}{N} f(s'(t-2)) + U'_0 \delta v_0(t) \quad (36)$$

l を N に依存しない定数とすれば，単一の機械学習モデルで表現が可能となる．

(2) マルチスケールへの展開

(1)のモデルは，車列の車両台数 N ，先頭車両の速度変化，ニューラルネットワークのパラメータによって決定される．ここで，ニューラルネットワークのパラメータは，車両追従式を近似したものと考えられるので，ネットワーク固有のパラメータではない．すなわち，交通ネットワークを評価するためには，シミュレーション内で発生する車列の車両台数及び先頭車両の加速度の同時分布を考えれば良い．ここで，各車列は追従・被追従の関係にはないので，車列の連結と分裂を除いて独立に移動していると考えられる．シミュレーションを行うスケールによらず，先頭車両の加速度と車列長の同時分布のみが分かれば，単一のモデルでシミュレーションを行うことができるという点で，マルチスケールに対応したモデルと考えられる．

5. 数値実験

4. で提案したモデルの精度を評価するため，離散コサイン変換により圧縮した特徴量を用いて，車列状態の時系列変化の予測を行った．ここでは，2 リンクからなる信号付き単路での精度評価を行った．

ここでは，1000 台の車両が，仮想的に作成した 2 リンクから成る単路を走行する場合を考える．車両は 5 秒おきに出発し，ノード 1 からノード 2 を経由し，ノード 3 まで移動する．ノード 1 とノード 2，ノード 2 とノード 3 の距離は共に 550m で




図 6 ノーシミュレーションに用いたネットワークの概要




図 7 車列内の車両数 N の分布




図 8 先頭車加速度の分布

あり、ノード 2 には青時間スプリット 57/120 の信号が設置されている。シミュレーションの結果得られた車両数 2 以上の車列について時刻 $t, t-1, t-2$ の状態を集計することで、5206 サンプルの教師データを作成し、2915 サンプルを教師データ、729 サンプルを検証データ、1562 サンプルをテストデータとした。図 6 にネットワークの概要を、図 7 にマイクロシミュレーションで得られた車列長の分布を図 8 と図 9 にそれぞれ先頭車両の加速度の分布及び車列内の車両全体の速度分布を示す。なお、データに含まれる車列全体の車列長の平均は 6.39 である。信号の有無によりリンク 1 で車列長の長い車列が多くなっており、速度 0 付近の車両が多くなっていることがわかる。それに伴い、先頭車両の加速度の絶対値の大きい車列の分布が異なっていることがわかる。

また、図 10 に特徴量圧縮による誤差と、式 (36) に従い時刻 $t-2, t-1$ での車列状態スペクトルから、時刻 t でのスペクトルを推定し、車両速度分布を求めたときの誤差を示す。また、特徴量圧縮による情報落ちを評価するため、特徴量圧縮の後そのまま車両速度に変換したときの誤差も示す。




図 9 車列内の車両速度の分布

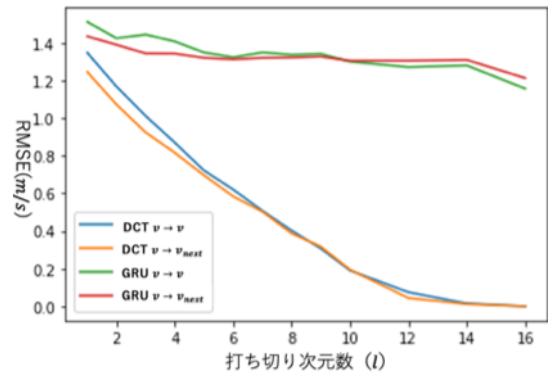


図 10 打ち切り次元数 l と推定誤差 (RMSE)




図 11 $l = 5$ の場合の車両速度分布の真値と推定値の比較 (色は車列長 N)

比較対象として、分散コサイン変換の代わりに可変長入力を扱える機械学習モデルである Seq2seq を用いて特徴量の圧縮を行った場合も示す。なお、ここでは Seq2seq のエンコーダー及びデコーダーには LSTM の派生形である GRU⁽²⁹⁾ を用いた。このモデルは、LSTM よりも構造がシンプルであり、かつ、より高い表現力を持つものである。両者ともに、特徴量圧縮による誤差と次タイムステップの予測の誤差がほとんど一致している。これは、次タイムステップの特徴量に変換することよりも特徴量の圧縮の仕方自体が精度を高める上でボトルネックになっているということを示す。分散コサイン変換による特徴量では、打ち切り次元数が大きい場合には、次状態の予測誤差がほとんど 0

になっていることから比較的簡単な機械学習モデルであっても次状態の予測ができていたことがわかる。また、本検討では、離散コサイン変換を用いたものの方が Seq2seq を用いたものに比べ、打ち切り次元数の増加による精度の向上が顕著になっているという結果が得られた。車列長の平均値が 6.39 であることから打ち切り次元数を 5 で設定すると、離散コサイン変換を用いた場合の次タイムステップの車両速度の真値と予測値の分布は図 11 のようになり、真値の周りに最大誤差が $6m/s$ 、RMSE が $0.70m/s$ となった。この特徴量圧縮に起因する誤差は政策による先頭車量加速度の分布や車列長の分布の変化に対し、十分な小さいか否かという点で評価される。

6. 結論

(1) まとめと課題

本研究では、前方車両から後方車両への影響の伝搬を表す追従理論の定式化が必ずしも機械学習モデルに入力しやすいものではないことから、車列の単位での表現について検討を行った。車列の空間周波数分析では、スペクトルの各成分が車列内の車両状態のばらつき具合が表しており、それらはネットワーク上の各車両の旅行速度と一対一で対応している。

本研究では、まず線形の車両追従式を用いて、車列の表現に適していると考えられる離散的な基底関数を導出し、線形の追従式に基づきスペクトルの時間変化を解析的に分析した。このスペクトルの時間変化は、車列の連結・分裂を除けば車列ごとに独立に計算できる。一定の条件下でスペクトルの高周波数成分は速やかに減衰することから、低周波成分のみを用いた情報圧縮の可能性が示される。これは、シミュレーションにおける計算コストの減少に寄与する結果である。また、スペクトル成分の変化が記述できることから、空間的な車両状態のばらつきが問題となるような現象をより直接的に捉えられるという意義もあると考えられる。例えば、自動運転車の混在する状況での渋滞の伝搬などがそれにあたる。

加えて、スペクトルの各成分は車両状態の揺らぎの程度を表しており、車列の長さが異なっても、物理的な意味は変わらない。すなわち、異なる長さの車列を単一の機械学習モデルで扱うことができると考えられる。本研究では、線形の追従式から導出されたスペクトルの支配方程式のアナロジーにより、異なる長さの車列のスペクトル成分の時間変化を単一の機械学習モデルにより近似する方法を提案した。

最後に、提案モデルを用いて、非線形の追従式に基づき計算された車両の挙動を学習し、精度の評価を行った。時系列の車両挙動の変化の予測のために単純な機械学習モデルを用いた場合でも高

精度で予測ができることが示唆された、

一方で、本研究では、実ネットワークでの数値実験が行えていないことから、課題も残る。第一に、特徴量の次元数の取り方に明確な基準を与えられていない。次元の打ち切りに起因する誤差は車列長の分布に大きな影響を受けるため、特徴量の次元数は実ネットワークでの車列長の分布を与えた上で、政策の評価に必要な予測精度の比較により決める必要がある。ただ、配分計算の前に車列長の分布がわからないことから、繰り返し計算が必要になると予想される。また、扱う追従式によってはスペクトルの高周波成分が減衰しない可能性もあることから、その評価も必要となる。第二に、車列の空間的な広がりを考える必要がある。これは、車両の連結・分裂の評価やネットワークの設計変数の変化による先頭車両速度と車列長分布の解析に必要であると考えられる。車両密度と旅行速度の集計量の観点から車両の挙動を捉えている Fundamental diagram (FD)³⁰⁾を用いれば、車両速度の分布から車列の広がりや長さを計算できると考えられるが、追従式によっては FD が一意に定まらないものも存在する。車頭間隔の情報も周波数領域に変換した上で次タイムステップの予測に利用するというモデルが考えられる。第三に、実ネットワークにおける設計変数の車列状態に与える変化の評価が必要である。車列状態の変化は、それ自体がリンク旅行時間の変化などの形で車列状態の分布に影響することから、繰り返し計算が必要となる。ネットワークにおける計算方法の開発とそれを用いた設計変数に対するモデルの感度の分析を行う必要がある。第四に、本研究で検討したモデルは、ある程度車両がまとまって走行している状況を想定したものであるため、車両が疎にしか存在しない状況では意味を持たない。その具体的な適用範囲についても検討が必要である。

(2) 今後の展望

本研究で検討した、車列内の車両の状態の揺らぎに基づいた定式化では、車両状態の分布の時間変化は互いに独立な車列の先頭車両の加速度と車列の長さで決定される。これらの変数の分布と対象ネットワークにおける説明変数の関係を明らかにすることでネットワークの最適化問題を高速に求解できると考えられる。例えば、車列先頭車両の加速度は、信号による捕捉確率や歩行者・自転車等との相互作用の頻度により影響を受けると考えられる。また、車列長の分布はボトルネック箇所における車線数により変化すると考えられる。そのような要因による交通状態への影響を評価することができれば、複数のモードが混在する交通結節点の評価や道路空間の配分問題に適用できると期待される。

REFERENCES

- 1) 佐佐木綱. 交通流理論, 技術書院, 1965.
- 2) Papageorgiou, G.; Damianou, P.; Pitsillides, A.; Aghamias, T.; Charalambous, D.; Ioannou, P. Modelling and simulation of transportation systems: A scenario planning approach. *Automatika: časopis za automatiku, mjerenje, elektroniku, računarstvo i komunikacije*, 2009, 50.1-2: 39-50.
- 3) PEL, Adam J.; BLIEMER, Michiel CJ; HOOGENDOORN, Serge P. A review on travel behaviour modelling in dynamic traffic simulation models for evacuations. *Transportation*, 2012, 39.1: 97-123.
- 4) AZADIVAR, Farhad. Simulation optimization methodologies. In: *Proceedings of the 31st conference on Winter simulation: Simulation---a bridge to the future-Vol-ume 1*. 1999. 93-100.
- 5) ADNAN, Muhammad, et al. Simmobility: A multi-scale integrated agent-based simulation platform. In: *95th Annual Meeting of the Transportation Research Board Forthcoming in Transportation Research Record*. Washington, DC: The National Academies of Sciences, Engineering, and Medicine, 2016.
- 6) BARCELÓ, Jaime; CASAS, Jordi. Dynamic network simulation with AIMSUN. In: *Simulation approaches in transportation analysis*. Springer, Boston, MA, 2005. 57-98.
- 7) 小林里瑛; 羽藤英二. 都市整備に伴う回遊選択の変化に応答的な土地の両面市場モデル. *都市計画論文集*, 2021, 56.3: 524-531.[Risa, Kobayashi; Eiji, Hato. A two-sided market model of land responsive to changes in site choices associated with urban development. *Journal of the City Planning Institute of Japan*, 2021, 56.3: 524-531.]
- 8) Jones, S. L.; Sullivan, A. J.; Cheekoti, N.; Anderson, M. D.; Malave, D. Traffic simulation software comparison study. *UTCA report*, 2004, 2217.
- 9) MASUDA, S.; HATO, E. Macroscopic network design for dynamic evacuation scheduling with MFD-based assignment using the recursive logit model. 2022.
- 10) Dessouky, M.; Hall, R.; Zhang, L.; Singh, A. Real-time control of buses for schedule coordination at a terminal. *Transportation Research Part A: Policy and Practice*, 2003, 37.2: 145-164.
- 11) RONALD, Nicole; YANG, Jie; THOMPSON, Russell G. Exploring co-modality using on-demand transport systems. *Transportation Research Procedia*, 2016, 12: 203-212.
- 12) BARTON, Russell R.; MECKESHEIMER, Martin. Metamodel-based simulation optimization. *Handbooks in operations research and management science*, 2006, 13: 535-574.
- 13) OSORIO, Carolina; BIERLAIRE, Michel. A simulation-based optimization framework for urban transportation problems. *Operations Research*, 2013, 61.6: 1333-1345.
- 14) VLAHOGIANNI, Eleni I. Optimization of traffic forecasting: Intelligent surrogate modeling. *Transportation Research Part C: Emerging Technologies*, 2015, 55: 14-23.
- 15) BOZDOGAN, Hamparsum. Model selection and Akaike's information criterion (AIC): The general theory and its analytical extensions. *Psychometrika*, 1987, 52.3: 345-370.
- 16) DAVIS, Sarah E.; CREMASCHI, Selen; EDEN, Mario R. Efficient surrogate model development: impact of sample size and underlying model dimensions. In: *Computer Aided Chemical Engineering*. Elsevier, 2018. 979-984.
- 17) BRACKSTONE, Mark; MCDONALD, Mike. Car-following: a historical review. *Transportation Research Part F: Traffic Psychology and Behaviour*, 1999, 2.4: 181-196.
- 18) GAZIS, Denos C.; HERMAN, Robert; ROTHERY, Richard W. Nonlinear follow-the-leader models of traffic flow. *Operations research*, 1961, 9.4: 545-567.
- 19) HINTON, Geoffrey E.; KRIZHEVSKY, Alex; WANG, Sida D. Transforming auto-encoders. In: *International conference on artificial neural networks*. Springer, Berlin, Heidelberg, 2011. 44-51.
- 20) KINGMA, Diederik P.; WELING, Max. Auto-encoding variational bayes. *arXiv preprint arXiv:1312.6114*, 2013.
- 21) KRIZHEVSKY, Alex; SUTSKEVER, Ilya; HINTON, Geoffrey E. Imagenet classification with deep convolutional neural networks. *Communications of the ACM*, 2017, 60.6: 84-90.
- 22) Creswell, A.; White, T.; Dumoulin, V.; Arulkumaran, K.; Sengupta, B.; Bharath, A. A. Generative adversarial networks: An overview. *IEEE signal processing magazine*, 2018, 35.1: 53-65.
- 23) SUTSKEVER, Ilya; VINYALS, Oriol; LE, Quoc V. Sequence to sequence learning with neural networks. *Advances in neural information processing systems*, 2014, 27.
- 24) HOCHREITER, Sepp; SCHMIDHUBER, Jürgen. Long short-term memory. *Neural computation*, 1997, 9.8: 1735-1780.
- 25) AHMED, Nasir; NATARAJAN, T.; RAO, Kamisetty R. Discrete cosine transform. *IEEE transactions on Computers*, 1974, 100.1: 90-93.
- 26) WALLACE, Gregory K. Overview of the JPEG (ISO/CCITT) still image compression standard. In: *Image Processing Algorithms and Techniques*. SPIE, 1990. 220-233.
- 27) LAM, Edmund Y.; GOODMAN, Joseph W. A mathematical analysis of the DCT coefficient distributions for images. *IEEE transactions on image processing*, 2000, 9.10: 1661-1666.
- 28) WIDROW, Bernard; LEHR, Michael A. Perceptrons, Adalines, and backpropagation. *Arbib*, 1995, 4: 719-724.
- 29) DEY, Rahul; SALEM, Fathi M. Gate-variants of gated recurrent unit (GRU) neural networks. In: *2017 IEEE 60th international midwest symposium on circuits and systems (MWSCAS)*. IEEE, 2017, 1597-1600.
- 30) SIEBEL, Florian; MAUSER, Wolfram. On the fundamental diagram of traffic flow. *SIAM Journal on Applied Mathematics*, 2006, 66.4: 1150-1162.

(Received? July 1, 2022)

(Accepted? November 1, 2022)

MULTISCALE SIMULATION BASED ON TRAFFIC FLOW THEORY

Daichi OGAWA and Eiji HATO

As the traffic operation system and network design methodology become sophisticated along with the increasing availability of traffic data, the optimization problem using micro-simulation model is gaining importance. At the same time, the great success in machine learning is expected to lead to new behavior modeling, though there is accumulated knowledge in traffic flow theory. Because of increasing variety of traffic service and development of autonomous driving which have completely different behavioral principle from ordinary cars, the statistical approximation of behavior would lead to incorrect prediction. In this paper, a new feature design method is proposed based on traffic flow theory. The feature can deal with individual behavior in the line of cars efficiently, and is expected to help machine learning models learn agents' behavior effectively. In addition, the feature calculation is based on frequency analysis in space domain, and thus it is interpretable and analytically solvable when the governing car-following model is linear. The meaning of feature does not depend on the size of the line of cars, and applicable regardless of the scale of the target domain.