

車両挙動モデリングにおける Hamiltonian Neural Networkの適用可能性

塩見 康博¹

¹正会員 立命館大学准教授 環境都市工学科 (〒525-8577 滋賀県草津市野路東1-1-1)

E-mail: shiomi@fc.ritsumei.ac.jp

ミクロ交通流シミュレーションは、車両挙動に関する数理モデルに従って、時々刻々の車両の加減速度、および車線変更の有無を計算する。しかしながら、数理モデルは多数のパラメータに支配されているため、パラメータの組み合わせや乱数シードの設定によって、非現実的な車両挙動が出現する場合がある。そこで、本研究では、モデルパラメータに依存しない、データ駆動型の車両挙動モデルを構築する。具体的には、車両走行軌跡データを用いて、周辺車両と自車の時系列的な関係から、次タイムステップの自車の状態を学習するモデルを考える。その上で、i) データのみからタイムステップ毎の自車の速度をCNNで学習させたケース、ii) 自車と周辺車両挙動の力学的な因果関係を明示的に考慮したHamiltonian Neural Networkで学習させたケース、iii) 従来の追従モデルの推定精度を比較する。

Key Words: Port-Hamiltonian Neural Network, CNN, Microscopic traffic simulation, ZTD

1. はじめに

ミクロ交通流シミュレーションは、車両挙動に関する数理モデルに従って、個々の車両の加減速度、および車線変更の有無を計算するものである。各車両には異なるパラメータで挙動特性が与えられており、それぞれがエージェントとして互いに作用を及ぼすことで、渋滞の発生やその延伸などのダイナミックな現象が創発される。

そのため、道路設計や交通計画、動的交通マネジメントの評価など、実務的にも幅広く利用されているツールである。また、コネクティッド車両や自動走行車両(CAV)の普及を想定した場合、CAVはマニュアル運転車を含む周辺車両の個々の存在位置や速度などを把握することが望ましい。それを実現するためには、観測データをミクロ交通流シミュレーションと同化させ、個別車両レベルでの交通状況を推定することが有効となる。

しかしながら、数理モデルは多数のパラメータに支配されているため、パラメータの組み合わせや乱数シードの設定によって、非現実的な車両挙動が出現する場合がある¹⁾。また、車両挙動の柔軟性とパラメータの数は概ねトレードオフの関係にあり、詳細な交通状態の再現を意図してモデルの自由度を高めると、実現現象を再現するためのパラメータキャリブレーションが困難になる、という課題がある。

一方、近年の画像解析技術の発展やIoTの普及により、車両走行挙動軌跡データの収集が容易となりつつある。たとえば、阪神高速道路(株)が提供するZTD²⁾では画像センシングにより、2つの区間でピーク時間帯の合計10時間分の全車両の走行軌跡データが公開されている。これらのリッチなデータを活用すれば、数理モデルに頼らないデータ駆動型の車両挙動モデル³⁾が構築できると考えられる。

一般的な追従モデルは、周辺車両から受ける影響に応じた加速度を算出するモデル構造となっている。そのため、シミュレーションの時間進展とともに、推定された加速度の誤差が積分され、その結果として生起する交通現象にゆがみが発生する可能性がある。これは、加速度を目的変数とする限り、データ駆動型モデリングであっても避けられない課題である。その対策として、モデルで学習する変数を加速度ではなく、次タイムステップの車両の存在位置とすることも考えられうる。しかし、この場合、ドライバーは周辺車両との関係でアクセルやハンドル角度を調整する、という自然な因果構造が保持されないため、非現実的な挙動を出力する可能性を否定できない。

そこで本研究では、Hamiltonianで記述されるエネルギー保存則の成立を前提とした上で、物体の挙動を学習するHamiltonian Neural Network(HNN)⁴⁾を車両挙動のモデ

リングに適用する. 具体的には, まず, HNN の概要を示すとともに, 追従モデルが複数の物体間の相互作用関係を記述する Port-Hamiltonian System として記述できることを説明する. その上でニューラルネットワークにより Hamiltonian を学習する HNN を適用し, タイムステップ毎の自車の速度と位置を予測するモデルを構築する. 構築したモデルを ZTD による走行軌跡データに適用し, i) 従来の追従モデル, ii) CNN により自車の速度のみを学習したモデル, iii) HNN により自車の速度と位置を学習したモデルの 3 つの精度比較を行う. なお, 本稿ではモデルの概要のみを示す.

2. Hamiltonian Neural Network の概要

HNN は物体の次の状態を直接予測するのではなく, ハミルトニアン力学で記述される運動方程式を保持したまま予測するモデルである.

従来の数値シミュレーションは初期条件と境界条件を設定した上で, 物体の状態の変化量を数値モデルとして記述し, その積分をとることにより, 状態の時間変化をシミュレートする. すなわち, 物体の初期位置と初速度をそれぞれ \mathbf{q}_0 と \mathbf{p}_0 表すと時刻 T における物体の状態 \mathbf{q}_T と \mathbf{p}_T は式(1)のように記述される.

$$(\mathbf{q}_T, \mathbf{p}_T) = (\mathbf{q}_0, \mathbf{p}_0) + \int_0^T \mathbf{S}(\mathbf{q}, \mathbf{p}) dt \quad (1)$$

ここで $\mathbf{S}(\mathbf{q}_T, \mathbf{p}_T)$ は何らかの物理法則によって理論的に記述される状態の変化量であり, 物体の運動の場合には運動方程式, Kinematic wave theory の場合には交通量保存則が相当する. そのため, 理論的に記述された $\mathbf{S}(\mathbf{q}_T, \mathbf{p}_T)$ に対し, 何らかの攪乱の影響や, あるいは数値計算をする際の近似精度による誤差が含まれる. この誤差が時間的に積分されるため, 予測値である $(\mathbf{q}_T, \mathbf{p}_T)$ の精度は時間経過とともに低くなるのが容易に想像できる.

物理現象に対して, 直感的に機械学習を適用するのであれば, $(\mathbf{q}_t, \mathbf{p}_t)$ と $(\mathbf{q}_{t+1}, \mathbf{p}_{t+1})$ のデータを学習し, 前者から後者の予測を行うのが最もシンプルな考え方であろう. このとき, 損失関数は式(2)のような形で記述される.

$$L(\theta) = \|\mathbf{q}_t - \hat{\mathbf{q}}_t\|_2 + \|\mathbf{p}_t - \hat{\mathbf{p}}_t\|_2 \quad (2)$$

ただし, $\|\cdot\|_2$ は L_2 ノルムを表し, $\hat{\cdot}$ は推定値を表す. しかしながら, この場合, 一切の物理的な因果関係を無視することとなり, \mathbf{q}_t と \mathbf{p}_t の間に当然成立すべき関係性が保持されないまま, シミュレーションが展開される可能性がある.

一方, HNN では, 運動方程式 (ここでは, $\mathbf{S}(\mathbf{q}_T, \mathbf{p}_T)$ に相当する) をハミルトニアン形式で記述し, そのハミルトニアン \mathcal{H}_θ 自体を学習する構造となる. すなわち, \mathbf{q} と \mathbf{p} のダイナミクスはハミルトニアン関数 \mathcal{H}_θ を導入すると, この勾配としてそれぞれ記述される.

$$\begin{aligned} \frac{\partial \mathbf{q}}{\partial t} &= \frac{\partial \mathcal{H}_\theta}{\partial \mathbf{p}} \\ \frac{\partial \mathbf{p}}{\partial t} &= -\frac{\partial \mathcal{H}_\theta}{\partial \mathbf{q}} \end{aligned} \quad (3)$$

これは, 位置の変化がハミルトニアンを介して速度に変換される保存則を表している. この上で, 損失関数を以下のように定義すれば, 速度と位置の保存関係が成立したまま, データ駆動でその関係を記述するニューラルネットワークを構築することができる.

$$L(\theta) = \left\| \frac{\partial \mathbf{q}}{\partial t} - \frac{\partial \mathcal{H}_\theta}{\partial \mathbf{p}} \right\|_2 + \left\| \frac{\partial \mathbf{p}}{\partial t} + \frac{\partial \mathcal{H}_\theta}{\partial \mathbf{q}} \right\|_2 \quad (4)$$

Greydanus et al.⁴⁾ はこれにより時間経過による誤差の蓄積が抑制され, 精度の高いシミュレーションが可能となったことを報告している.

3. ハミルトニアン形式による追従モデルの表現

追従モデルの 1 つである Optimal Velocity (OV) モデルは, 車両 i の加速度 $\dot{v}_i(t)$ を, 現在の速度 $v_i(t)$ と車間距離で定義される最適速度との差で記述するものである. 具体的には, 式(5)として表される.

$$\dot{v}_i(t) = \kappa [V_i(x_j - x_i) - v_i(t)] \quad (5)$$

ただし, j は影響を受ける車両 id を, κ は係数を表す. $V_i(x_j - x_i)$ は最適速度関数であり, 自車の位置 x_i と周辺車両 j の位置 x_j との相対関係 (Δx_{ij}) で当該車両が目標とする速度を算出するものである. 可能な走行速度は上限・下限をもつことから, 最適速度関数は以下の関数形で定義される.

$$V_i(\Delta x_{ij}) = \alpha + \beta \cdot \tanh(\Delta x_{ij}) \quad (6)$$

ただし, α, β はそれぞれ定数を表す.

ここで, ハミルトニアン力学における一般座標を導入し, $v_i(t)$ を p , Δx_{ij} を q で表す. このとき, $\alpha = 0$ としても一般性に影響はないことを考えると, 式(5)より

$$\frac{dp}{dt} = \kappa [-p + \beta \cdot \tanh(q)] \quad (7)$$

とかける. また, 距離の時間変化はそのときの速度に他ならず,

$$\frac{dq}{dt} = p \quad (8)$$

が成立する. 式(7)と式(8)をまとめると,

$$\begin{aligned} \frac{d}{dt} \begin{bmatrix} p \\ q \end{bmatrix} &= \begin{bmatrix} \kappa[-p + \beta \cdot \tanh(q)] \\ p \end{bmatrix} \\ &= \begin{bmatrix} -\kappa & \kappa \\ 1 & 0 \end{bmatrix} \begin{bmatrix} p \\ \beta \cdot \tanh(q) \end{bmatrix} \end{aligned} \quad (9)$$

ここで, $\mathcal{H}_\theta(p, q)$ を式(10)として定義する.

$$\mathcal{H}_\theta(p, q) = \frac{\kappa}{2} p^2 + \beta \ln \cosh(q) \quad (9)$$

このとき, 式(9)は以下のように書き換えられ, OV モデルがポントハミルトニアン系として記述できることが分かる⁵⁾.

$$\frac{d}{dt} \begin{bmatrix} p \\ q \end{bmatrix} = \begin{bmatrix} -\kappa & \kappa \\ 1 & 0 \end{bmatrix} \begin{bmatrix} \frac{\partial \mathcal{H}_\theta}{\partial p} \\ \frac{\partial \mathcal{H}_\theta}{\partial q} \end{bmatrix} \quad (9)$$

これは, 車間距離の変化が速度に変換されるというシステムにおけるエネルギー保存の関係を記述しているものと解釈できる.

なお, p と q を 2 次元空間に拡張し, 自車と周辺車両の関係を影響行列 (Incidence matrix) で表すと, 車線変更を含む車両挙動を一元的に表現することが可能となる.

4. おわりに

本稿では, Hamiltonian Neural Network の概要を説明するとともに, 追従モデルの 1 つである OV モデルがハミルトニアン系として記述できることを示した. これにより, 個別車両の位置・速度のデータから次タイムステップの位置・速度を直接予測するニューラルネットワークモデルとは異なり, 車両挙動に関わる周辺車両との相互作用の因果関係を考慮する形でデータを学習することが可能となる.

一方で, 自然現象に関わる物理モデルとは異なり, 車

両挙動は人間の意思決定の結果として観察される挙動である. そのため, 必ずしもエネルギー保存の関係が成立するとは限らない. また, モデル自体のシステム誤差も少なくないため, 必ずしも予測精度の向上にはつながらないとも考えられる.

今後は, 走行軌跡データに対し,

- 1) 位置・速度のデータから次ステップの位置・速度を直接学習するニューラルネットワークモデル
 - 2) ハミルトニアンを介して次ステップの位置・速度を学習するハミルトニアンニューラルネットワークモデル
 - 3) 数理モデルベースの車両挙動モデルをデータに基づいてキャリブレーションしたケース
- を適用し, それぞれの推定精度, およびシミュレーション結果の妥当性について検討を行う.

謝辞: 本研究は Zen Traffic Data の利用を前提として着想を得たものです. また, JSPS 科研費 19H02268 の助成を受けたものです. ここに記して謝意を表します.

参考文献

- 1) Mariko Nakai and Yasuhiro Shiomi: Dynamic calibration of microscopic traffic simulation at sags. Proceedings of the 24th HKSTS international conference, 2019.
- 2) 阪神高速道路株式会社: ZTD Zen Traffic Data, <https://zen-traffic-data.net> (2020年3月8日アクセス)
- 3) Xiao Wang, Rui Jiang, Li Li, Lin Yilun, and Xinhua Zheng: Capturing Car-Following Behaviors by Deep Learning. IEEE Transactions on Intelligent Transportation Systems, Vol. 19, No.3, pp.910-920, 2017.
- 4) Sam Greydanus, Misko Dzamba, and Jason Yosinski: Hamiltonian Neural Networks. <http://arxiv.org/abs/1906.01563>.
- 5) J. Popping: An Overview of Microscopic and Macroscopic Traffic Models, Graduation Thesis of Faculty of Mathematics and Natural Sciences, University of Groningen, 2013.

DEEP LEARNING BASED CAR FOLLOWING MODEL

Yasuhiro SHIOMI