

F-003

車輻運動モデル用ニューラルネットワークの構造と学習

Structure and Learning Method of Neural Network for Vehicle Motion Model.

瀬田 至† 手塚 俊介† 鳥居 毅†
Itaru Seta Syunsuke Tezuka Tsuyoshi Torii

1. まえがき

近年、車輻の挙動差を高精度にかつ定量的に評価し設計に反映し開発することが求められている。しかし、車輻挙動の定量評価、複数車輻の比較評価を行う場合、実走行ではドライバ操作を一定にできないこと等に起因するノイズ混入が常に問題となる。また、物理モデルを用いた挙動近似では、高次元化の限界や、パラメータチューニング問題で、定量評価に使えるほど高精度化が望めない。

そこで、著者らは、実挙動データを用いて学習により車輻挙動を高精度に再現しうる車輻モデルを構築し、これをもって車輻の定量評価を行うことを目指している。

今回は、車輻モデル構築に NN (ニューラルネットワーク) を用いたモデル構造と GA (遺伝的アルゴリズム) による学習アプローチを採用した。その結果、レーンチェンジの挙動近似において、物理モデルでは表現しにくい、非線形領域まで高精度に近似したヨーレート車輻運動モデルの獲得に成功した。また、この車輻挙動モデルを用いて、ドライバ操作に依存しない定量評価が行えたので報告する。

2. 車輻モデル構造

今回検討した車輻モデルは、前輪舵角 (ステアリング角度×ステアリングギアレシオ) 及び、車体速度の時系列データよりヨーレートを計算するモデルとした。NN 構造を図1に示す。NN に入力するデータは、前輪舵角、車体速度及び、1 入力前のデータから計算した前輪舵角速度、車体加速度とする。

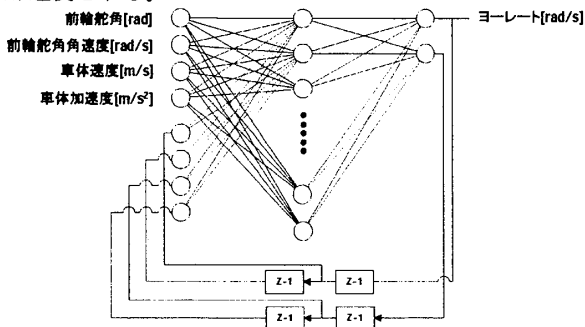


図1、NN 車輻モデル構造

出力はヨーレートとし、遅れ要素を含むフィードバックループを複数付加した構造とした。ニューロンの個数は入力層 8、中間層 15、出力層 2 とした。この様な構造とすることで、NN 構造に過去の履歴を記憶、利用する能力が与えられ、状態変化に対応したより高精度なモデルになると考えられる。

†富士重工業(株) スバル技術研究所
〒181-8577 東京都三鷹市大沢 3-9-6
Tel:0422-33-7454 Mail: setai@tky.subaru-fhi.co.jp

3. 学習法

(1) 学習アルゴリズム

実際に計測した挙動データを教師データとし、NN の結合係数 (重み係数、バイアス) を実数値 GA で決定した。交叉方法は SPX で、代表的な演算パラメータを表1に示す。揺らぎ発生率とは、各遺伝子座にガウス分布を付加する操作 (揺らぎ操作) を行う発生確率である。最適解近傍での探索能力を向上させるために導入し、誤差分布 (3σ) は NN 結合重み定義域の 1/10000 程度に設定した。これは、交叉によって優秀なスキーマが破壊されるリスクを回避しつつ、補助的に局所探索を進める役割を果たしている。

一方突然変異については、各遺伝子座に確率的にランダム操作を加えるほか、変異が起こった場合、変更する遺伝子座が連続するように一時的に変異確率を高めている (突然変異連続率)。これは突然変異による局所解からの脱出能力を高めるためである。

表1 GA 演算パラメータ

個体数	100 固体
選択方法	トーナメント+エリート保存
エリート保存率	10[%]
交叉率	60 [%]
交叉方法	SPX
突然変異率	0.3 [%]
突然変異連続率	50 [%]
揺らぎ発生率	10[%]

(2) 適応度

適応度 E は以下のように設定した。

$$E = \sum_{i=0}^n \left(\left(|Yrs - SimYrs| + 1 \right)^2 - 1 \right) \dots (1)$$

E: 適応度 Yrs: 計測ヨーレート (rad/sec)

SimYrs: NNモデル出力ヨーレート (rad/sec)

4. 実験

今回はダブルレーンチェンジ走行に限定したモデル学習実験及び、特性の似ている車種 A,B (それぞれセダン) での比較実験を行った。

学習評価用データとして、図2に示すパイロンの間を、非線形挙動領域も含めた限界走行に近い 60~70km/h で走行した車輻挙動データを数種類サンプリングした。1つのデータは 5秒程度、ヨーレート、車速、舵角をサンプリング周期 50Hz で計測した。各車種 3つのデータを教師データとして用いて、モデル学習を行った。




図2、走行パターン

(1) 進化過程

車種 A の学習での進化過程を図 3 に示す。試行回数は 4 回、2000 世代までの平均演算時間は、約 20 分 (Pentium4 3.4GHz OS:Windows XP) である。なお、車種 B の進化過程も車種 A と同等であった。




図3、進化過程

(2) モデル精度

車種 A における未学習データでのシミュレーション結果を示す。モデルへの入力データを図 4 に、シミュレーション結果と、計測値との比較を図 5 に示す。計測データに対する誤差検証を行った結果最大で 1.9deg/sec 誤差が発生した。この誤差分布を図 6 に示す。車種 B のモデル精度に関しても車種 A と同等であった。




図4、モデル入力データ




図5、車種 A ヨーレート計算結果




図6 誤差分布

(3) 車種比較結果

モデルへの入力条件を同一にして (図 7)、車種 A,B 比較した結果を図 8 に示す。グラフより、入力に対し、車種 A の方が全体的に遅れ生じている。車種 B に比べても最大 0.14sec 程度遅れている。




図7、車種比較用入力データ




図8、車種比較結果

5. 考察

進化過程や、モデル精度より、今回使用した GA パラメータは、適切であったと考えられる。また、適応度の変化率が鈍る 500 世代以降も徐々に低下していることから、揺らぎ操作も有効に機能している。

モデル精度は、計測値に対して誤差-0.1~0.1deg/sec を中心とした分布が得られ、高精度なヨーレート挙動モデルが実現できた。今回の走行状態が、限界走行領域も含んでいることを考慮すると、数理モデルでは表現が難しい、非線形領域まで対応したモデルが構築されたと考えられる。また、車種 A の結果 (図 4, 5) より 2.5 秒付近の入力対しての挙動遅れの近似性の良さが判断でき本構造の NN は遅れを伴う挙動に関しても十分に近似性能が高いモデルである。これは、NN モデル構造の遅れ要素が大きく寄与していると考えられる。

最後に、車種間の定量比較について、テストドライバーより「車種 A,B 共に限界性能はほぼ同じであるが、車種 B の方がリニアな乗り味で車種 A の方がハンドル入力に対して応答が遅れる」とのコメントを頂いている。NN モデルでの比較結果と一致し、定量的に評価を裏付けることができた。

6. まとめ

NN を用いたモデル構造と GA による学習アプローチを採用し、限定領域ではあるが、非線形領域でも高精度に再現するモデル構築に成功した。また、本手法を用いることで、定量的に車種間の挙動差を観測することができた。今後は、モデルの適応領域を拡げて行く。

参考文献

[1] 手塚, 鳥居, 他 「無人飛行体着陸制御用ニューラルネットワークの構造と学習」, 飛行機シンポジウム (第 42 回) 論文集, pp538-542, 2004
 [2] 鳥居, 松田, 他 「分散 GA による 4 脚歩行ロボットの歩行パターン生成」, 人工知能学会全国大会 (第 14 回) 論文集, pp606-607, 2000