

力学系学習木における適応的ノード選択

菅原康滉* 三浦勇氣* 栗林倫* 沼倉彬雄* 加藤成将*

佐藤和幸* 富澤武弥† 三好扶* 明石卓也* 金天海*

岩手大学* 大船渡市役所†

1 まえがき

任意の系の入出力関数の近似関数を、入出力値を学習することで生成する関数近似という手法がある。特に、入出力値の間の関係が非線形かつ連続である場合、非線形連続関数近似[‡]と呼ばれており、その中の一つに力学系学習木 (Dynamics Learning Tree:DLT)[1] がある。DLT は木構造を用いた手法であり、そのノードは予測出力値を保持し出力値により予測出力値を更新している。また、入力値によりノードを選択し、そのノードから予測出力値を得る。DLT は、小型船舶の無波無動力時加速度の関数近似化 [2] などの実機に利用されている。上記のような実機から入出力値を取得する場合、入出力値の出力値にノイズが付加されている。従来法は、このノイズの影響を受け易いため、予測出力値と真の出力値の間の平均予測誤差が大きくなり易い。

そこで本研究では、出力値と予測出力値の間の平均誤差を用いて適応的にノードを選択することで、DLT を実機に用いたときに従来法より平均予測誤差を縮小する手法を提案する。

2 DLT(力学系学習木)

DLT について一般的に議論する。任意の系の入出力関数 f が与えられた際に、与えられた制約の中で f と最も類似するような近似関数 \hat{f} の最適解 \hat{f}° を得る関数近似問題は以下のように定義できる。

$$\hat{f}^\circ := \arg \min_f E \quad (1)$$

ただし、

$$E := \int_I \|\mathbf{o} - \hat{\mathbf{o}}\| d\|\mathbf{i}\| \quad (2)$$

$$\mathbf{o} := f(\mathbf{i}) \quad (3)$$

$$\hat{\mathbf{o}} := \hat{f}(\mathbf{i}) \quad (4)$$

であり、 E は f と \hat{f} の間の平均予測誤差、 $I \subset \mathbb{R}^\mu$ は入力空間、 $\mathbf{o} \in O$ は出力値、 $\hat{\mathbf{o}} \in O$ は予測出力値、 $\mathbf{i} \in I$ は入力値、 $O \subset \mathbb{R}^r$ は出力空間、 \mathbb{R} は実数の全体集合である。なお、 \mathbf{i} 、 \mathbf{o} 、 $\hat{\mathbf{o}}$ の第 k 成分はそれぞれ i_k 、 o_k 、 \hat{o}_k である。この問題は、 f が未知であり式 3 に従って入出力値 $d := \{\mathbf{i}, \mathbf{o}\}$ が取得できるという制約条件を伴う。また、この問題に \hat{f} を式 5 により更新関数 χ で逐次更新するという制約条件を加えるとオンライン関数近似問題となる。

$$\hat{f} \leftarrow \chi(\hat{f}, d) \quad (5)$$

この問題において、逐次更新時の汎化と記憶保持の間にトレードオフの関係がある。DLT は、その関係を ξ 分木を用いることで解消させたオンライン関数近似器である。

2.1 ξ 分木

ξ 分木は、各ノード v が ξ 個以下の子ノードを持つ順序根付き木である。 v を以下のように定義する。

$$v := \{l, p, \mathbf{c}, \hat{\mathbf{o}}, u, S\} \quad (6)$$

l は v の深さ、 p は v の親ノード、 \mathbf{c} は v の子ノード、 u は $\hat{\mathbf{o}}$ の更新回数、 $S \subseteq I$ は部分入力空間[§]である。なお、 l の最大の深さは ρ 、 v の第 x 番目の子ノードは $c_x \in \mathbf{c}$ であり、根ノードの S は I と同値である。一方、任意の v の c_x が保持する部分入力空間は

$$\{\mathbf{i} \in S \mid S \in v \wedge a_{\min} \leq i_\zeta \leq a_{\max}\} \quad (7)$$

と同値である。ただし、

$$\zeta := (l \bmod \mu) + 1 \quad (l \in v) \quad (8)$$

$$a_{\max} := b x + i_{\min} \quad (9)$$

$$a_{\min} := a_{\max} - b \quad (10)$$

$$b := |i_{\max} - i_{\min}| / \xi \quad (11)$$

であり、 i_{\max} 、 i_{\min} は $S \in v$ 上の \mathbf{i} の i_ζ の最大値、最小値である。

2.2 学習

任意の d を用いて当該ノードが保持する $\hat{\mathbf{o}}$ を、式 12 により更新することが学習である。なお、未学習時の ξ 分木は根ノードのみから成る。

$$\hat{\mathbf{o}} \leftarrow (u \hat{\mathbf{o}} + \mathbf{o}) / (u + 1) \quad (\mathbf{o} \in d) \quad (12)$$

初めは根ノードを当該ノードとする。式 13 から m を求める。

$$m := \text{ceil}((i_\zeta - i_{\min}) / b) \quad (13)$$

当該ノードの第 m 番目の子ノード c_m が生成済みであるなら、 c_m を当該ノードへ変更する。 c_m が未生成なら、 c_m を生成し当該ノードへ変更する。当該ノードの深さが ρ より小さいなら、上記のような当該ノードの変更を繰り返す。

図 1 により学習について説明する。図 1 の左側が入力空間

$$\{\mathbf{i} \in \mathbb{R}^2 \mid \forall k (-4q \leq i_k \leq 4q)\} \quad (14)$$

であり、右側が 2 分木である。なお、出力空間 O は \mathbb{R}^2 の部分空間である。入出力値 $\{(3q, 3q), (q, q)\}$ を用いて学習すると、ノード v_{12}, v_{13}, v_{14} が生成され、ノード $v_1, v_2, v_{12}, v_{13}, v_{14}$ が保持する予測出力値が式 12 により更新される。なお、三角形は入力値 $(3q, 3q)$ である。




図 1: 力学系学習木の学習・予測 ($\mu = 2, \rho = 4, \xi = 2$)

2.3 予測

任意の \mathbf{i} を用いてノード配列 \mathbf{v} を導き、その中から深さ l が最も大きいノードを選択しそのノードが保持している予測出力値を得ることが予測である。 \mathbf{v} は当該ノードとなったノードから成る。初めは根ノードを当該ノードとする。式 13 から m を求める。当該ノード

Adaptive Node Selection in Dynamics Learning Tree

*Yasuhiro Sugawara, Yuki Miura, Hitoshi Kuribayashi, Akio Numakura, Narimasa Kato, Kazuyuki Sato, Tamotsu Miyoshi, Takuya Akashi, and Chyon Hae Kim are with Iwate University.

†Takeya Tomizawa is with Ofunato City Hall.

‡以降、非線形連続関数近似を単に関数近似と表記する。

§部分入力空間とは、入力空間の部分空間のことである。

ドの第 m 番目の子ノード c_m が生成済みであるなら、 c_m を当該ノードへ変更する。当該ノードの深さが ρ より小さいなら、上記のような当該ノードの変更を繰り返す。

図1により予測について説明する。入力値 $(-q, -3q)$ を用いて予測すると、 $\mathbf{v} = (v_1, v_6, v_7, v_8)$ となり \mathbf{v} の中で最も深いノード v_8 が選択され v_8 の予測出力値を得られる。なお、五角形が入力値 $(-q, -3q)$ 、灰色の空間が v_8 が保持する部分入力空間である。

3 ノイズの影響

実機から入出力値 d を取得する場合、出力値 $\mathbf{o} \in d$ にノイズ \mathbf{z} が付加されている。このような入出力値をノイズ付加入出力値 d^z とし、次のように定義する。

$$d^z := \{\mathbf{i}, \mathbf{o}^z\} \quad (\mathbf{o}^z = \mathbf{o} + \mathbf{z}) \quad (15)$$

ただし、 \mathbf{o}^z はノイズ付加入出力値である。 d^z を用いて学習した DLT で予測するとき、選択されるノードは \mathbf{v} の中で更新回数が最も少ない。そのため、予測出力値はノイズの影響を受け易く平均予測誤差が大きくなり易い。

そこで、従来法より平均予測誤差を縮小する手法として誤差ベース予測を提案する。

4 誤差ベース予測

予測出力値 $\hat{\mathbf{o}}$ と \mathbf{o}^z の間の平均誤差 \bar{r} は \mathbf{o}^z の偏り度合いであり、 \mathbf{z} が小さい傾向にあれば \bar{r} も小さい。以上のことから、 \mathbf{v} の中から \bar{r} が最小であるノードを選択しノイズの影響を低減させる。この選択法が誤差ベース予測である。

ノード v を次のように再定義し \bar{r} を v に保持させる。

$$v := \{l, p, \mathbf{c}, \hat{\mathbf{o}}, u, S, \bar{r}\} \quad (16)$$

$\hat{\mathbf{o}}$ を式12により更新する前に、 \bar{r} を式17により更新する。

$$\bar{r} \leftarrow (1 - \alpha) \bar{r} + \alpha \|\hat{\mathbf{o}} - \mathbf{o}^z\| \quad (17)$$

ただし、

$$\alpha := \begin{cases} 0 & (u = 0) \\ 1/u & (1/u > \epsilon) \\ \epsilon & (\text{otherwise}) \end{cases} \quad (18)$$

であり、 α は忘却係数、 ϵ の変域は $0 \leq \epsilon < 1$ である。忘却係数を設けることで、直近の \mathbf{o}^z に重点を置く。

DLT を実機に用いたときに提案法が従来法より平均予測誤差を縮小できるかを検証するために、単振動と小型船舶の運動に対して実験を行った。

5 実験1

単振動の運動を DLT に学習させ従来法と提案法で予測を行った。

5.1 内容

単振動の運動方程式は $\ddot{y} = -y$ を用いた。なお、 \ddot{y} は加速度、 y は位置である。位置と速度を入力値、加速度を出力値とする。この出力値にノイズを付加させることでノイズ付加入出力値を生成し、実機から取得したようなノイズ付加入出力値を構成する。また、検証用の入出力値は運動方程式により取得した。

3万個のノイズ付加入出力値と1.5万個の入出力値から構成されるデータを60個用意した。そして、そのデータのノイズ付加入出力値により学習し、平均予測誤差を求めた。なお、 $\mu = 2, \rho = 40, \xi = 3$ の DLT を用いた。

5.2 結果

従来法と提案法の平均予測誤差は図2となった。縦軸が平均予測誤差、横軸が ϵ 、破線が従来法、実線が提案法である。図2より、 ϵ が0.74以下であれば、提案法は従来法より平均予測誤差を縮小するという結果となった。また、 $\epsilon = 0.13$ のとき平均予測誤差が最小で

あった。




図2: 実験1結果

6 実験2

無波無動力時の小型船舶の運動を学習させ従来法と提案法で予測を行った [3]。

6.1 内容

小型船舶には、船底にカメラ、船上にジャイロセンサが取り付けられている。カメラで前後方向の位置を取得し、その位置から速度を求め、そしてその速度から加速度を求める。また、ジャイロセンサで角速度 (yaw) を取得し、その角速度から角加速度を求める。上記の速度と角速度を入力値とし、加速度と角加速度をノイズ付加入出力値として、ノイズ付加入出力値を構成した。そして、検証用の入出力値はモーションキャプチャを用いて取得した。

4分間で取得したノイズ付加入出力値と入出力値から構成されるデータを41個用意した。そして、40データのノイズ付加入出力値により学習し残りの1データを用いて交差検証を行い、平均予測誤差を求めた。なお、 $\mu = 2, \rho = 22, \xi = 3, \epsilon = 0.01$ の DLT を用いた。

6.2 結果

従来法と提案法の平均予測誤差はそれぞれ0.701と0.525であった。つまり、提案法は従来法より平均予測誤差を縮小するという結果になった。

7 結論・展望

本研究では、DLT を実機に用いたときに従来法より平均予測誤差を縮小する手法として誤差ベース予測を提案した。単振動と無波無動力時の小型船舶の運動を学習し提案法を試したところ、提案法は従来法より平均予測誤差を縮小した。

今後は、出力値の分散により平均予測誤差を縮小する手法について研究する予定である。

参考文献

- [1] 沼倉彬雄, 加藤成将, 佐藤和幸, 富沢武弥, 三好扶, 明石卓也, 金天海: "力学系学習木-連続力学系の階層型学習-", 情報処理学会第77全国大会, (2015).
- [2] Akio Numakura, Shigenobu Kato, Kazuyuki Sato, Takeya Tomizawa, Tasuku Miyoshi, Takuya Akashi and Chyon Hae Kim: "FAD learning: Separate Learning for Three Accelerations -Learning for Dynamics of Boat through Motor Babbling-", ICRA, (2016).
- [3] 三浦勇氣, 菅原康滉, 栗林倫, 沼倉彬雄, 加藤成将, 佐藤和幸, 富沢武弥, 三好扶, 明石卓也, 金天海: "力学系学習木による画像ベース小型船舶挙動学習", 平成28年度情報処理学会東北支部研究会, (2016).