

力学系学習木による効率的な学習のための階層性を利用した入力ベクトル決定法*

濱翔平[†] 平井諒[†] 高橋城志^{‡§} 山田浩貴[‡] 尾形哲也[‡] 菅野重樹[‡] 金天海[†]
 岩手大学[†] 早稲田大学[‡] 日本学術振興会特別研究員[§]

1 はじめに

関数近似器は自動車やロボットといった剛体の運動軌道の近似や、画像処理・音処理をはじめとするマルチモーダル情報処理などに用いられており、近年特にその需要が高まっている。特に我々は、階層型統計学習をもとに追加学習時の記憶保持と汎化能力を両立した逐次関数近似器である力学系（連続系）学習木 [1] を提案している。沼倉らの実験では力学系学習木はニューラルネットワークと較べ安定かつ素早い誤差収束を実現している [1]。沼倉らと江藤らは学系学習木を船体と車体にそれぞれ応用し、船体や車体の状態に応じて慣性、摩擦、水面抵抗、駆動力等により発生する加速度の学習・推定を実現している [2, 3]。同様に渡辺らはヒト型ロボットへ応用し、腕関節角度に対するペン先位置や筆圧の学習・推定を実現している [4]。力学系学習木の他手法との比較を表 1 に示す。力学系学習木は統計処理を用いた逐次学習を行うため、ニューラルネットワークに見られるような致命的忘却の問題 [5] に陥らない。また、階層性を用いて学習データの汎化範囲を自動的に調整するため、強化学習などに用いられる単純格子分割に較べ良好な汎化能力を有する。力学系学習木にはリカレントニューラルネットワーク (RNN) のような隠れ状態を学習する能力は無いが、力学系の状態が明示的に入力に与えられる範囲では学習に問題を生じることはいない。しかしながら、前記の研究において力学系学習木に対する入力ベクトルの設定は経験的に行われており、その設計指針は明確ではない。そこで本研究では、力学系学習木の階層性を有効利用し、効率的な学習を実現するための入力ベクトル決定法を提案する。

表 1: 力学系学習木の他手法との比較

	◎○△×, RA … ランダムアクセス	◎○△×, RA … ランダムアクセス	◎○△×, RA … ランダムアクセス	◎○△×, RA … ランダムアクセス
単純格子分割	◎	×	◎	×
ニューラルネットワーク	×	○	○	○
力学系学習木	◎	◎	◎	×

2 力学系学習木の構造と学習

力学系（連続系）学習木は木構造を用いた階層型学習器であり、根となるノードが n 次元入力空間を表現していると考え、根から葉の方へ n 次元（副層）の d 分木を形成することで、根の入力空間を d^n 個に分割した各入力空間に葉のノードを一対一に対応させる。そしてその葉のノードを根として更に n 次元 d 分木の形

成を N 回行うことで形成される N 階層 n 次元 d 分木が力学系学習木である。力学系学習木は力学系の状態（入力）とその状態における状態遷移速度ベクトル（出力）の対応を学習することで力学系の関数近似を行う。学習では入出力ベクトル対を力学系学習木に入力する。力学系学習木はこの入出力ベクトル対に応じて根から入力に対応した葉までのノードを逐次探索・作成する。探索・作成した全ノードに出力ベクトルの相加平均を保持させることにより、根寄りの荒い入力空間から葉寄りの細かい入力空間までのノードに対し、出力ベクトルを対応づける [1]。

3 提案法（高学習効率のための入力ベクトル決定法）

力学系学習木は入力ベクトルの先頭要素が上位に、末尾要素が下位にそれぞれ対応するように副層を形成する。この際、より上位の副層は入力ベクトル空間に対してより強い汎化を行うため、学習による出力ベクトル調整の影響が入力ベクトル空間上のより広い範囲に伝播する。そのため、力学系学習木では、入力ベクトル上の要素の順序をいかに対応付けるかが学習効率に大きく影響を及ぼす可能性がある。この要素の順序について、我々は「入力ベクトル上の要素の順序として、出力ベクトルへの影響が大きな要素を先頭側に、小さな要素を末尾側に配置することで学習効率が上がる。」という仮説を立てた。この仮説は、出力ベクトルに対する各入力ベクトル要素の偏微分を考え、その絶対値が大きい順に要素を配置することと同意である。

4 実験

（実験設定）：本提案法の仮説を検証するため、ヒト型ロボットシミュレータによる検証実験を行った。実験設定は高橋らが行ったクランク回しタスク [6] に準じ、高橋らがリカレントニューラルネットワークで行った実験と同様に、PD 制御により生成した 889 ステップの軌道を力学系学習木に学習させた (図 1)。入力ベク




図 1: クランク回しシミュレーション

トル要素の順序の違いによる学習効果の違いを検証するため、ロボットの肩・肘・手首関節から得られた角度・角速度・トルクを力学系学習木の入力ベクトル (9 次元) に対応付け、肩・肘・手首関節の加速度を出力ベクトルに対応付けて学習を行った。入力ベクトルの要素の順序としては、「角度、加速度、トルク (AVT)」「角速度、角度、トルク (VAT)」「肩、肘、手首 (SEW)」「肘、肩、手首 (ESW)」「手首、肘、肩 (WES)」の 5 通りとし、指定の無い要素の順序は、角度、角速度、トルクまたは、肩、肘、手首に固定した。よって、例えば AVT であれば、「角度 (肩), 角度 (肘), 角度 (手先),

*Input vector definition for efficient learning using hierarchy of dynamics learning tree

[†]Shohei Hama, Ryo Hirai and Chyon Hae Kim (tenkai@iwate-u.ac.jp) are with Iwate University

[‡]Kuniyuki Takahashi, Hiroki Yamada, Tetsuya Ogata and Shigeki Sugano are with Waseda University

[§]Kuniyuki Takahashi is with Research fellowship for young scientist in Japan society for the promotion of science

角速度 (肩), 角速度 (肘), 角速度 (手先), トルク (肩), トルク (肘), トルク (手首)」の順になる.

(実験結果): 図2から図6に正解データとの角度誤差を, 図7から図11に正解データとの角速度誤差を, 図12から図17に肩, 肘, 手首の角度及び角速度についての正解データとSEWの軌道の比較を示す. 表2には全ステップの誤差の合計を示す.

表 2: 全 889 ステップの誤算の合計

	AVT	VAT	SEW	ESW	WES
角度誤差 [rad × 889]	9.39	6.46	0.38	6.11	5.57
角速度誤差 [rad/s × 889]	6.74	4.67	0.64	4.26	4.18




図 2: AVT (角度誤差)




図 3: VAT (角度誤差)




図 4: SEW (角度誤差)




図 5: ESW (角度誤差)




図 6: WES (角度誤差)




図 7: AVT (角速度誤差)




図 8: VAT (角速度誤差)




図 9: SEW (角速度誤差)




図 10: ESW (角速度誤差)




図 11: WES (角速度誤差)

(考察): 実験結果より, 「肩, 肘, 手首」の順に入力ベクトル要素を構成することで最良の結果が得られた. これは肩の動作が手先座標に与える影響が肘や手首よりも大きいことが理由であると考えられる. これより, 前記仮説の正しさが示唆された.

提案法により, リカレントニューラルネットワーク [6] と比較して高速な学習が実現できた. d をデータ数, i を学習の繰り返し数 (イテレーション数) として, ニューラルネットワークによるバッチ学習には $O(d \times i)$ の計算時間がかかる. 対して提案法は逐次学習により $O(d)$ の計算時間で学習ができる (イテレーション数 = 1). この結果, リカレントニューラルネットワークでは数千秒を要した学習が数ミリ秒で実現できた.

また, 学習誤差については文献 [6] には正確な数値が無いので比較が難しいが, 関節角度については平均 4.27×10^{-5} [rad], 関節角速度については平均 7.19×10^{-5} [rad/s] 程度と, 正解データとほぼ同様の軌道が得られており, 実用上の問題は無いと考えられる.




図 12: 肩 (正解データ (実線) と SEW (点線), 角度)




図 13: 肘 (正解データ (実線) と SEW (点線), 角度)




図 14: 手首 (正解データ (実線) と SEW (点線), 角度)




図 15: 肩 (正解データ (実線) と SEW (点線), 角速度)




図 16: 肘 (正解データ (実線) と SEW (点線), 角速度)




図 17: 手首 (正解データ (実線) と SEW (点線), 角速度)

5 おわりに

力学系学習木の入力ベクトル要素の構成において, 出力ベクトルへの影響度を考慮することで, その学習効率が改善できることが分かった. また, リカレントニューラルネットワークによる学習と比較してより高速な学習が実現できること, 学習誤差が十分に低減できることなども分かった. 今後はより一般的な力学系においても実験を進め, 提案仮説の検証を行う予定である.

謝辞

本研究の一部は JSPS 科研費 25220005, 15H01710, 15K20850, 15J12683, 文科省博士課程教育リーディングプログラム「実体情報学博士プログラム」, 文科省早稲田大学理工研プロジェクト研究「自然と共生する知能情報機械系に関する基盤研究」, 新学術領域研究「構成論的発達科学」24119003 の助成を受けたものです.

参考文献

- [1] 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: "力学系学習木 - 連続力学系の階層型学習-", 情報処理学会全国大会, (2015).
- [2] 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: "力学系予測による小型船舶の外乱推定," 日本ロボット学会学術講演会, (2015).
- [3] 江藤圭吾, 沼倉彬雄, 小林祐一, 金天海: "力学系学習木を用いた車体動力学の推定," 計測自動制御学会 SI 部門講演会, (2015).
- [4] K. Watanabe, A. Numakura, S. Nishide, M. Gouko, and C. H. Kim: "Efficient Body Babbling for Robot's Drawing Motion," IEEE Inter. Conf. on Mechatronics and Automation, (2015).
- [5] R. M. French: "Catastrophic forgetting in connectionist networks," Trends in Cognitive Science, Vol. 3, No. 4, (1999).
- [6] K. Takahashi, T. Ogata, H. Yamada, H. Tjandra and S. Sugano: "Effective Motion Learning for a Flexible-Joint Robot," IEEE/RSJ Inter. Conf. on Intelligent Robots and Systems, (2015).