

神経回路モデルを用いたプリミティブの階層的学習

安田 伊慶[†]西出 俊[‡]康 鑫[‡]任 福継[‡][†] 徳島大学 大学院先端技術科学教育部[‡] 徳島大学 大学院社会産業理工学研究所

1. はじめに

近年、人間の行動認識や監視など、多くの研究分野で時系列データの学習が必要不可欠である。各時刻間の状態遷移を確率的にモデル化する手法として Hidden Markov Model (HMM) が有効であり、人間の行動学習において大きな成果を挙げている [1]。一方、近年深層学習による手法も注目されており、リカレントニューラルネットワークを用いた時系列の学習に関する研究も多数行われている [2]。リカレントニューラルネットワークを用いた学習においては、時系列の長さや複雑さによって学習性能が大きく低下することが課題である。本稿では認知の基本単位であるプリミティブに注目し、時系列をプリミティブに分割し、プリミティブの複雑さによってリカレントニューラルネットワークの構造を変化させていくことでモデル内にプリミティブ表現を獲得し、その組合せとして時系列を学習する手法を提案する。

2. Multiple Timescales Recurrent Neural Network (MTRNN)

本研究では山下らが提案した Multiple Timescales Recurrent Neural Network (MTRNN) を学習モデルとして用いる [3]。MTRNN は現在の状態 $IO(t)$ を入力し、次の状態 $IO(t+1)$ を出力する予測器である。通常のリカレントニューラルネットワークと異なり、コンテキスト層は階層的に構成されている。本研究では入出力ニューロン層 (IO) に加えて、Fast Context 層 (C_f)、Slow Context 層 (C_s) の三種類のニューロン層で MTRNN を構成する。各ニューロン層には時定数と呼ばれるパラメータが設定されており、ニューロン値の挙動の大きさは時定数の小ささに依存する。時定数は IO 層、 C_f 層、 C_s 層の順に大きく設定する。本研究で用いる MTRNN の構成を図 1 に示す。

2.1 MTRNN の計算

MTRNN の計算には順計算と誤差逆伝播計算の二つがある。順計算では各時刻の状態値を入力することで次時刻の状態値を出力として計算する。誤差逆伝播計算では Back Propagation Through Time (BPTT) アルゴリズムに基づき [4]、順計算で計算した出力値と学習系列の状態

値の誤差を初期時刻まで逆伝播することで誤差を積算する。本稿では紙面の都合上、計算式は省略するが、詳細については [3] を参照されたい。

本研究では MTRNN の学習と認識の機能を主に用いる。MTRNN の学習は与えられた学習データ系列に対して、MTRNN の重みとコンテキスト初期値を適応させる処理である。順計算で出力値を求めた後、誤差逆伝播計算によって計算した誤差の積算値によって重みの値とコンテキスト層の初期値 $C_f(0)$ と $C_s(0)$ を更新する。コンテキスト層の初期値は入出力の挙動を決定するものであり、 $C_f(0)$ と $C_s(0)$ はそれぞれ低次と高次の情報を扱う。MTRNN の認識は与えられた系列に対応するコンテキスト初期値を求める処理である。与えられた系列を MTRNN に入力し、学習と同様に順計算と誤差逆伝播計算を行う。誤差逆伝播計算の際、重みは更新せず、コンテキストの初期値のみを更新し、収束したコンテキスト初期値が MTRNN による時系列の表現となる。

2.2 提案手法

日下らの研究成果ではアルファベットを入力することで C_f には単語情報、 C_s には文法情報が自己組織化されるように異なるレベルの情報が獲得できることが示された [5]。離散的データでは通常の学習で明確に階層的な情報が自己組織化できることは確認できているが、連続データでは同様の結果が必ずしも得られるとは限らない。

本研究では学習データの複雑さに合わせて、MTRNN の構造を変化させることで階層的な情報の自己組織化を実現することを目的とする。本手法では学習を 2 段階に分け、第 1 段階では入出力層 IO と C_f のみで構成される MTRNN で学習を行う。その際、学習データはプリミティブとなる単純な系列のみを用いる。第 1 段階の学習が収束後、第 2 段階では学習した MTRNN の構成に C_s ニューロン層を接続し、引き続き学習を行う。学習データは第 1 段階で用いた単純系列に加え、プリミティブの組合せから構成される複雑な系列も加える。本学習により、第 1 段階でプリミティブの情報を C_f に自己組織化し、第 2 段階ではプリミティブの組合せ方を C_s に自己組織化する。

3. 実験設定

本実験では描画系列を用いて手法を評価する。実験データの取得には Wacom 社の液晶タブレット Cintiq 13HD (DTK-1301/KO) (図 2) を用いる。本稿では基礎的な実験として単純な系列の学習結果について報告する。具体的には第 1 段階では円弧の描画系列を学習し、第 2 段階では円の描画系列を学習する。円弧は円の上下左右を起点とし、時計回りに 1/4 描いたものを、円は上を起点として時計回りに 3 周描いたものを用いる。描画の際、液晶タブレットの座標値を毎秒 10 フレームで取得した。

MTRNN の入出力ニューロンは液晶タブレットの座標値を $[0,1]$ に正規化したものを用いたため 2 個とし、 C_f と C_s のニューロン数も共に 2 個とした。本実験では単純な実験設定であるため、ニューロン数も少なく設定し




図 1: MTRNN の構成



図 2: ペンタブレット

ているが、より複雑なデータを学習する際はニューロン数も多く設定することが必要である。各ニューロン群の時定数は 10 , C_f , C_s の順に 2 , 5 , 70 と実験的に設定した。

4. 実験結果

本実験では通常の学習と提案手法で学習した場合の C_s 空間の解析を行う。基礎的な実験であったため、学習誤差については双方に大きな差は見られなかった。

通常の学習で構築した MTRNN を用いて各円弧と円 (3 周) を認識した際の C_s 系列と提案手法による認識結果をそれぞれ図 3 と図 4 に示す。それぞれの図において、円の C_s は赤色の実線で、円弧は上・右・下・左を起点として描いた系列の C_s がそれぞれ緑・青・紫・水色の実線で描かれている。赤色の実線の系列に注目すると、双方とも緑・青・紫・水色の近くを 3 回ずつなぞる形で描画されているが、提案手法の方がより近くを通っていることが分かる。本実験結果より、提案手法の方が従来手法と比べ、よりプリミティブを明確にした学習が可能であることを示唆する結果が得られた。

5. 考察

本実験結果では 4 つの円弧をプリミティブとし、その組み合わせから成る円を MTRNN に段階的に学習することで、より明確にプリミティブを C_s 空間に表現すること




図 3: 通常の学習による学習結果

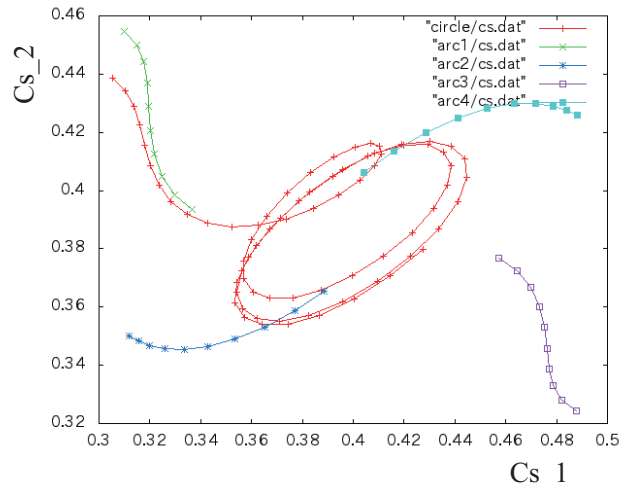


図 4: 提案手法による学習結果

が可能であることを示した。本実験では円という単純なデータのみで有効性を確認したが、より多くのデータ種類や量に対する有効性の確認は今後の課題として残されている。また、円をプリミティブとし、複数の円からなる図形の描画を学習する際は C_s より時定数がさらに大きいコンテキスト層を MTRNN に付加することでさらに階層的な学習が可能になることが期待される。

6. おわりに

本稿では MTRNN を用い、学習データと MTRNN の構成を段階的に変化させることでプリミティブをより明確に表現できる学習法を提案した。提案手法では 10 と C_f のみで構成された MTRNN でプリミティブとなる学習データで学習を行い、学習が収束すると C_s も付加してプリミティブの組み合わせから成る学習データで学習を継続して行う。円と円弧を用いた実験の結果、単純データを用いた場合において本手法の有効性を確認することができた。今後はより多くのデータを用いた学習における有効性を確認すると共に、 C_s で自己組織化した情報をプリミティブとしてその組み合わせから成る図形をさらに学習する場合の有効性についても検証していきたい。

謝辞

本研究は科学研究費補助金、若手研究 (A)(課題番号 16H05877) の支援を受けた。

参考文献

- [1] W. Takano, J. Obara, and Y. Nakamura, "Action recognition from only somatosensory information using spectral learning in a hidden Markov model," *Robotics and Autonomous Systems*, Vol. 79, pp. 29-35, 2016.
- [2] Y. Du, W. Wang, and L. Wang, "Hierarchical Recurrent Neural Network for Skeleton Based Action Recognition," in *Proc. of Int. Conf. on Computer Vision and Pattern Recognition*, pp. 1110-1118, 2015.
- [3] Y. Yamashita and J. Tani, "Emergence of Functional Hierarchy in a Multiple Timescale Recurrent Neural Network Model: a Humanoid Robot Experiment," *PLoS Computational Biology*, Vol. 4, No. 11, e1000220, 2008.
- [4] P. Werbos, "Backpropagation through time: What it does and how to do it," *Proc. of the IEEE*, Vol. 78, No. 10, pp. 1550-1560, 2002.
- [5] W. Hinoshita, H. Arie, J. Tani, H. G. Okuno, and T. Ogata, "Emergence of Hierarchical Structure Mirroring Linguistic Composition in a Recurrent Neural Network," *Neural Networks*, Vol. 24, Issue 4, pp. 311-320, 2011.