

神経回路による時系列パターンの追加学習

佐藤正義[†] 山内康一郎[‡]

北海道大学 大学院情報科学研究科[§]

1 はじめに

神経回路による時系列パターンの学習法はこれまでにも多くの研究が行われてきた[1]。しかし、同一規則性を持って発生する時系列パターンを繰り返し何度も与えて学習させるものがほとんどであり、新しい規則性を持って発生する時系列パターンを追記的に学習できる手法はほとんど開発されてこなかった。これは、追記的学習による干渉が、以降の全ての時系列パターン認識結果に影響するため、静的な空間パターンの学習タスクよりも格段に難しくなるからであろう。この傾向は、神経回路などのようなモデルベース学習器で顕著であると考えられる。そこで、リカレントネットワークの追加学習法に、筆者の一人が以前から提案してきた ILS(Incremental Learning through Sleep)[2] を導入することで、忘却を伴わずかつ少ないメモリリソースで時系列パターンを追加的に学習できるシステム、Recurrent-ILS(Re-ILS)を提案する。

2 提案システム Re-ILS

Re-ILS は、それまでに得られた知識で認識を行いつつ新たに得られたデータを丸暗記学習を行う Awake Phase と、それまでの知識と新たに得られた知識を織り交ぜて不要ユニットを削除しながら再学習を行う Sleep Phase の二種類の Phase、そして Sleep Phase の後に、丸暗記した内容を消去する等の処理を行う Post Sleep Phase をこの順序で繰り返すことによって時系列パターンを追加的に学習する(図1参照)。以下に、それぞれの学習 Phase を詳述する。

2.1 Awake Phase

Awake Phase での学習は、その前の Sleep Phase までの知識を保持するパラメータ固定のネットワークである Main Net(M-Net)と、新たに得られるデータを丸暗記学習する Fast Net(F-Net)によって行われる。M-Net はパラメータ固定の RBF で構成し、F-Net は Generalized Regression Neural Network(MGRNN)[3]

で構成する。入力は M-Net と F-Net の両方に同時に与えられ、ネットワーク全体の最終出力は二つのネットワークの出力の重み付き和によって計算される。この最終出力と教師信号の誤差がある一定の閾値を超えると、与えられた入力データは未知であるとみなし、F-Net に入力データに対応する新しい中間細胞を割り付けることによって丸暗記学習を行う。また、最終出力は時間遅れが発生する delay-line に送られ、次以降の入力の一部となることでリカレントネットワークを実現している。Awake Phase では、一定の時間長の入力を学習すると終了し、次の Sleep Phase へと進む。

2.2 Sleep Phase

Sleep Phase では、それまで保持していた M-Net の過去の記憶と、Awake-Phaseにおいて得られた F-Net の新しい記憶から、新しい知識を再構築すること目的とする。再構築された知識は最終的には M-Net の結合強度として保存される。これを実現するために、別途 Slow learning Net(S-Net)を用意し、M-Net と F-Net の両方から擬似学習サンプルを想起、生成して学習させる。ただし、S-Net はその学習に先立って M-Net のパラメータ(結合荷重、中間細胞等)をコピーして初期化するものとする。こうすることによって、S-Net は、M-Net が保持していた記憶と F-Net が保持していたデータを織り交ぜたサンプルを学習することとなる。S-Net の学習では新たな中間細胞の追加と不要な中間細胞の削除を同時に MRAN[4] の学習アルゴリズムを使用するため、冗長な中間細胞を減らしながら学習することができる。S-Net は M-Net と F-Net の中間細胞数に比例した数の擬似サンプルを学習する。Post Sleep Phase では、S-Net を M-Net と置き換え、次の Awake Phase へと進む。

3 計算機シミュレーション

提案した Re-ILS の有効性を示すため、Re-ILS と、従来型のオンライン型学習法である MRAN とをそれぞれ実装したロボットを用いて、計算機シミュレーションにより、パフォーマンスを比較した。ロボットに求められる課題は、青、黄色、赤、紫の 4 種類の色の異なる障害物があるフィールド上を、障害物や壁に衝突することなくスタートからゴールまでたどり着くというも

Incremental learning of Spatio-temporal patterns using Neural Network

[†]Masayoshi Sato

[‡]Koichiro Yamauchi

[§]Graduate School of Information Science and Technology, Hokkaido University

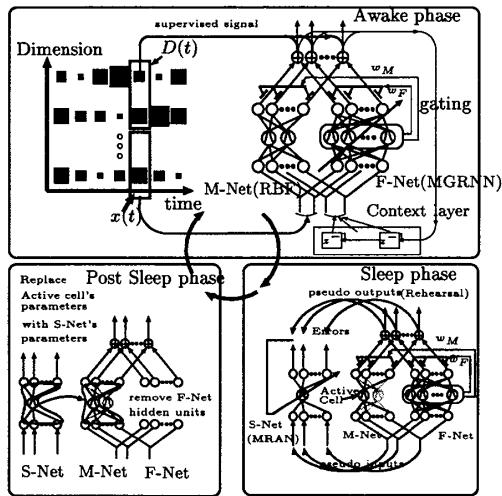


図 1: 睡眠期間を導入した時系列パターンの追加学習

のである。ロボットは各障害物の色を構成する「Red」「Green」「Blue」のそれぞれを感じる 17 個、合計 51 値の視覚センサーを持つ。Re-ILS および MRAN は、これらセンサーからの 51 次元の入力から、1 次元の方向舵制御信号を出力とする。Re-ILS と MRAN には直前 6 ステップにおいて自ら出力した方向を delay-line に保持させ、入力にフィードバックさせた。Re-ILS を実装したロボットの図を図 2 に示す。学習タスクは、フィールドの右上から左下へ向かう経路 A を学習させた後、さらにもう一つ、フィールドの右下から左上へ向かう経路 B を追加学習させ、その後、両方の経路を再現できるかどうかを観察した(図 3 参照)。Re-ILS では、経路 A と経路 B を提示する合間に睡眠期間を挿入した。二つの経路は途中で得られる視覚情報が同一となる部分があり、現時点での視覚情報だけではなく過去に辿った経路情報を用いなければ区別できないという時系列パターンとなっている。

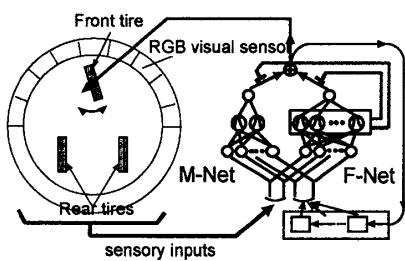


図 2: Re-ILS を実装したロボット

実験の結果、Re-ILS を実装したロボットはどちらの経路も再現することができたが、MRAN を実装したロボットは時系列パターンを正しく追加学習できず、途中で壁に衝突してしまい、学習させたはずの経路を正しく再現することができなかつた(図 4)。さらに、学習を完了させた後のそれぞれのネットワークの中間細

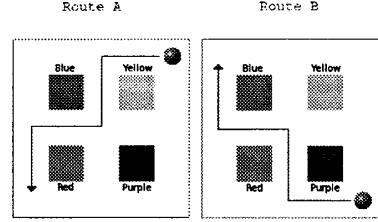


図 3: 学習させる経路

胞数を調べると、経路 A の学習直後、経路 B の学習直後のどちらにおいても Re-ILS の中間細胞数が MRAN のそれよりも少ないと確認された(表 1)。

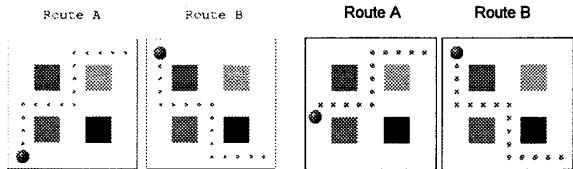


図 4: 学習後のロボットの挙動(点線はロボットの軌跡)Re-ILS(左), MRAN(右)

	Re-ILS	MRAN
経路 A を学習させた直後	3	5
経路 B を学習させた直後	6	10

表 1: ネットワークの中間細胞数

4 まとめ

本研究では、リカレントネットワークと睡眠期間を導入した追加学習法である ILS を用いる Re-ILS を提案した。また、計算機シミュレーションの結果、より少ないメモリリソースで時系列パターンを追加的に正しく学習できることができた。今後の課題は、フィードバックさせる過去の履歴数の決定等のパラメータ設定があげられる。

参考文献

- [1] S. Kremer, "ISpatiotemporal Connectionist Network: A Taxonomy and Review" Neural Computation, vol. 13, 249–306, (2001)
- [2] K. Yamauchi and J. Hayami , "Incremental Learning and Model Selection for Radial Basis Function Network through Sleep" IEICE TRANSACTIONS on Information and Systems, Vol. E90-D, No.4, 722–735, (2007)
- [3] D. Tomandl and A. Schober, "A Modified Generalized Regression Neural Network (MGRNN) with a new efficient training algorithm as a robust 'black-box-tool' for data analysis" Neural Networks Vol. 14, 1023–1034 , (2001)
- [4] "L. Yingwei et al: A Sequential Learning Scheme for Function approximation Using MinimalRadial Basis Function Nwural Networks,Neural Computation, Vol 9, 461–478, (1997)