

# Hebb 則と時空間学習則のパターン分離能力の比較

Comparison of pattern discrimination ability between the Hebbian learning and the spatiotemporal learning rules

塚本陽太<sup>1</sup>      塚田啓道<sup>2</sup>      塚田稔<sup>3</sup>      池口徹<sup>1</sup>  
 Yota Tsukamoto      Hiromichi Tsukada      Minoru Tsukada      Tohru Ikeguchi  
 東京理科大学<sup>1</sup>      中部大学 AI 数理データサイエンスセンター<sup>2</sup>      玉川大学 脳科学研究所<sup>3</sup>

## 1 はじめに

塚田らは、海馬を用いた生理学実験により、シナプス後ニューロンの発火がシナプス可塑性に寄与しない時空間学習則 (STLR) を発見している [1]。シナプス前ニューロンとシナプス後ニューロンの双方の発火タイミングがシナプス可塑性に寄与する Hebb 則 [2] とは異なり、STLR は類似した入力を識別するパターン分離能力に優れているとされている [3, 4]。本稿では、入力パターン類似度を変化させた場合に、パターン分離能力がどのように変化するかを、Hebb 則、Hebb± 則、STLR を対象として調査したので報告する。

## 2 モデル

本稿では、入力層と出力層がともに  $N (= 120)$  個の形式ニューロンからなる全結合のフィードフォワードネットワークを用いた。離散時刻  $t_n$  における  $j$  番目のシナプス前ニューロンと  $i$  番目のシナプス後ニューロンの出力を  $x_j(t_n), y_i(t_n)$ , ( $i, j = 1, \dots, N$ ) とし、1 ならば発火、0 ならば静止とする。また、 $j$ - $i$  間のシナプス荷重を  $w_{ij}(t_n)$  とする。ニューロンの内部状態および出力は式 (1)、式 (2) により決定される。ここで、 $\eta$  は発火の閾値である。

$$s_i(t_n) = \sum_{j=1}^N w_{ij}(t_n) x_j(t_n) \quad (1)$$

$$y_i(t_n) = \begin{cases} 1 & s_i(t_n) \geq \eta \\ 0 & s_i(t_n) < \eta \end{cases} \quad (2)$$

Hebb 則、Hebb± 則、STLR はそれぞれ式 (3)、式 (4)、式 (5) で表される。

$$w_{ij}(t_{n+1}) = w_{ij}(t_n) + \Delta w x_j(t_n) y_i(t_n) \quad (3)$$

$$w_{ij}(t_{n+1}) = \begin{cases} w_{ij}(t_n) + \Delta w, & x_j(t_n) = y_i(t_n) = 1 \\ w_{ij}(t_n), & x_j(t_n) = y_i(t_n) = 0 \\ w_{ij}(t_n) - \Delta w, & \text{otherwise} \end{cases} \quad (4)$$

$$w_{ij}(t_{n+1}) = \begin{cases} w_{ij}(t_n) + \Delta w, & J_{ij}(t_n) \geq \theta_1 \\ w_{ij}(t_n), & \theta_2 < J_{ij}(t_n) < \theta_1 \\ w_{ij}(t_n) - \Delta w, & J_{ij}(t_n) \leq \theta_2 \end{cases} \quad (5)$$

ここで、 $\Delta w$  は学習率、 $\theta_1, \theta_2$  はそれぞれ長期増強、長期減弱のパラメータである。また、式 (5) の  $J_{ij}(t_n)$  はニューロン  $i$  への入力の同時性の時間履歴であり、式 (6) および式 (7) で定義される [3]。ここで、 $\lambda$  は時定数であり、本稿では  $\lambda = 223[\text{ms}]$  とした [5]。

$$J_{ij}(t_n) = \sum_{m=0}^n I_{ij}(t_m) \exp\left(-\frac{t_n - t_m}{\lambda}\right) \quad (6)$$

$$I_{ij}(t_n) = w_{ij}(t_n) x_j(t_n) \sum_{k=1, k \neq j}^N w_{ik}(t_n) x_k(t_n) \quad (7)$$

## 3 パターン分離能力の評価

入力系列として、0 と 1 が 60 ビットずつランダムに並ぶ 120 ビットの系列を 5 個生成した。この際、各系列間のハミング距離が常に同じ値  $D$  となるように調整している。系列の  $j$  番目の要素はニューロン  $j$  の発火の有無を表す。

5 個の系列を並び替えた 120 通りの系列を、同じ初期状態のニューラルネットワークに  $n = 1, 2, \dots, 5$  において与えることで学習させた後、出力取得用の系列を与えることで出力を得た。得られた 120 個の出力系列のうち、異なる出力系列の個数によりパターン分離能力を評価した。入力系列のハミング距離を  $D = 4, 8, \dots, 40$  と変化させたときの各学習則のパターン分離能力の変化の様子を図 1 に示す ( $\Delta w = 1.0$ )。




図 1 入力系列のハミング距離  $D$  とパターン分離能力の関係。エラーバーは 100 回試行による平均値からの標準偏差の範囲を表す。

図 1 より、Hebb 則と Hebb± 則は入力系列のハミング距離  $D$  に関係なくパターン分離能力が低い。一方、STLR はパラメータによって傾向が大きく異なることが分かる。 $(\theta_1, \theta_2) = (10, 1)$  ではパターン分離能力が極めて低い。 $(\theta_1, \theta_2) = (30, 16)$  では入力系列のハミング距離  $D$  の増加に伴いパターン分離能力が低下するが、 $(\theta_1, \theta_2) = (22, 2)$  では向上する。以上の結果は、STLR がパラメータに応じて特定の入力系列のハミング距離を検出できることを示唆する。今後は、学習における閾値コントロールが導入された生理学実験の結果 [6] なども考慮して、この仮説の検証を行う予定である。本研究の一部は、JSPS 科研費 JP20H04246, JP20H00596, JP21H03514, JP22K18419 及び東北大学電気通信研究所共同プロジェクト研究 R05/A19, R05/B13 の助成を受けた。

## 参考文献

- [1] M. Tsukada et al., *Neural Networks*, 9(8), 1357–1365, 1996.
- [2] D. O. Hebb, Oxford: Wiley, 1949.
- [3] M. Tsukada and X. Pan, *Biological Cybernetics*, 92(2), 139–146, 2005.
- [4] H. Tsukada and M. Tsukada, *Frontiers in Systems Neuroscience*, 15, 624353, 2021.
- [5] T. Aihara et al., *Hippocampus*, 7(4), 416–426, 1997.
- [6] E. Sugisaki et al., *Brain Research*, 1649, 44–52, 2016.