

リカレント ネットにおける感度調整学習でのカオスダイナミクスの生成と維持

大分大学 ○徳丸侑輝 柴田克成

Generation and Maintenance of Chaotic Dynamics by Sensitivity Adjustment Learning in a Recurrent Neural Network

Yuuki Tokumaru and Katsunari Shibata, Oita University

Abstract: We propose that a recurrent neural network learns to generate chaotic internal dynamics autonomously by "sensitivity adjustment learning" that is a local learning method also we propose. In this learning, an index named "sensitivity", which is the magnitude of gradient vector with respect to the input, is introduced in each neuron, and its weights are updated to increase the index. We confirmed that by the learning, a flat network with 100 neurons firstly generated periodical oscillation, and then generated chaotic dynamics. In a fully-connected network, sometimes the fluctuation range of the neuron outputs dropped or raised suddenly, while it did not in a partially-connected network.

1 はじめに

本研究室では外界の情報をリカレント ネットを含むニューラルネットに直接入力し、状態評価と行動を強化学習で行う End-to-End 強化学習によって、必要な機能をネットワーク内部に創発することを提唱してきた。そして、これまでこの手法で認識や記憶、予測といった機能の創発を確認してきた [1][2][3]。また、Google DeepMind が ATARI のゲーム戦略獲得で、同様のアプローチにより人間を超える性能を示して注目されたが [4]、これもこの手法の有用性を示していると言える。

現在は、人間が持つ典型的な高次機能である思考の創発に向けた研究を行っている。思考という機能について、本研究室ではネットワーク内部のダイナミクスが、「時間の経過とともに外部入力がなくとも状態が次々と意味のある形で移り変わる、つまり自律的かつ合理的な多段階状態遷移」を持つ必要があると考えた。しかし、この多段階の状態遷移を通常のリカレント ネットを使った強化学習で作りに出すことは困難であった。そこでアプローチを変え、不規則ではあるが自律的な状態遷移を行うカオスニューラルネットを導入した。そして、このカオスダイナミクスにより探索を行い、それを学習によって意味のある状態遷移に移行させることで、思考と呼べるようなダイナミクスに成長するという仮説を立てた [5]。

先行研究では、リカレント ネットのリカレント部の、ランダムに設定された重み値のスケールを大きくすることで、カオス性を持たせたカオスニューラルネットを用いて強化学習を行った。その際、内部のカオス性が強すぎると強化学習そのものが上手くいかず、逆に弱すぎても学習に必要な探索が十分にできないこと、また、学習を続ける過程で内部のカオス性が弱まっていくことが確認された [6]。加えて、そもそもハードウェア化されたニューロンが、乱数発生器なしでどうやってランダムな重み値

を生成してカオスダイナミクスを得るのかという疑問点もあった。これらを踏まえ、上記の強化学習を行う上では、ニューラルネットが自律的にカオスダイナミクスを生成・調整する仕組みが必要と考えた。

以上より、本研究では自律的なカオスダイナミクスの生成と維持に向けて、リカレントニューラルネットに対し、まずは強化学習と切り離し、学習によって自律的にカオスダイナミクスを生成する方法の構築を主目的とした。その上で、「各ニューロン入力の微小変化に対する出力の変化量の割合の最大値」をニューロンにおける"感度"と定義し、これを大きくすることでカオスの特徴である初期値鋭敏性を強くすることを考えた。本論文では、この値が大きくなるように重み値を学習させる、という新たな学習方法「感度調整学習」を提案し、それによってリカレント ネットが自律的にカオスダイナミクスを生成するようになったことを報告する。

2 研究方法

本研究では層構造のないフラットな相互結合型のネットワークを考える。各ニューロンの出力 o は

$$u_{j,t} = \sum_{i=1}^N w_{j,i} \cdot o_{i,t-1} \quad (1)$$

$$o_{j,t} = f(u_{j,t}) = \tanh(u_{j,t}) \quad (2)$$

と計算する。ここで、 u はニューロンの内部状態、 w は重み値、 N はニューロン数を表し、 j は当該ニューロン、 i は入力側のニューロンの番号を表し、 t は時刻である。なお、外部からの入力及びバイアスはない。また、活性化関数 $f(u)$ として \tanh を使用した。

ここで、各ニューロンのローカルな重み値の学習における"感度"を次式 (3) に示す。本研究ではこの"感度"の

式を各ニューロンが持つ評価関数 $V_{j,t}$ とした。

$$V_{j,t} = |\nabla_{\mathbf{o}_{t-1}} o_{j,t}| = \sqrt{\sum_{i=1}^N \left(\frac{\partial o_{j,t}}{\partial o_{i,t-1}} \right)^2} = f'(u_{j,t}) |\mathbf{w}_j| \quad (3)$$

なお、式中の $|\mathbf{w}_j|$ は重み値ベクトルの大きさで、

$$|\mathbf{w}_j| = \sqrt{\sum_{i=1}^N w_{j,i}^2} \quad (4)$$

である。

この感度を上昇させるように重み値を、最急上昇法(山登り法)で以下の式(5)のように更新する。ただし、式中の η は学習係数である。

$$\begin{aligned} \Delta w_{j,i} &= \eta \frac{\partial V_{j,t}}{\partial w_{j,i}} = \eta \frac{\partial f'(u_{j,t}) |\mathbf{w}_j|}{\partial w_{j,i}} \\ &= \eta \frac{w_{j,i} f'(u_{j,t}) + \frac{\partial f'(u_{j,t})}{\partial w_{j,i}} |\mathbf{w}_j|^2}{|\mathbf{w}_j|} \quad (5) \end{aligned}$$

本研究は活性化関数として $f(u_{j,t}) = \tanh(u_{j,t})$ を使用しており、このことを念頭に(5)式を変形すると、

$$\Delta w_{j,i} = \eta \frac{(1 - o^2) (w_{j,i} - 2o_{j,t} o_{i,t-1} |\mathbf{w}_j|^2)}{|\mathbf{w}_j|} \quad (6)$$

となる。本論文ではこの式を各重み値の学習に使用した。

3 シミュレーション

3.1 方法

層構造のないフラットな 100 ニューロンの相互結合ネットワークを用意し、外部から入力を入れず、(6)式による重み値学習のみで、カオスダイナミクスが生成されるかを確認する。なお、本来は外界のノイズ等による学習の進展が期待できるが、ノイズなしでは出力が 0 に収束して学習が進まない。そこで今回は、100 ステップに 1 回の間隔で 300,000 ステップまでの間、全ニューロンの内部状態にトリガとしての微小な乱数を付与した。

シミュレーション後の内部ダイナミクスのカオス性の有無やその推移を、リアプノフ指数や出力、評価関数、重み値の各データから確認する。ここで、カオス性の強さを見る指標として使用するリアプノフ指数 λ の算出の式を次式(7)に示す。

$$\lambda = \frac{1}{\tau} \sum_{t=1}^{\tau} \ln \frac{d_{t+1}}{d_t} \quad (7)$$

d_t : 時刻 t での 2 軌道間の距離

τ : 計測したステップ数

調査時の各ニューロンの内部状態に、大きさが 0.001 の摂動としての乱数を入れるパターンと入れないパターンを用意する。そして、それぞれネットワークを $\tau = 10$ ステップ回し、両者の距離の変化を(7)式から算出して初期値鋭敏性を確認した。

その他、本学習で使用した各パラメータを Table 1 に示す。なお、ここでは初期重み値を微小な乱数で決めているが、本学習はニューロン間で何らかの非対称性があれば乱数を使わなくても学習できると考えている。

Table 1: Parameters

名前	設定値
ニューロン数	100
試行ステップ数	1,000,000
初期重み値の値域	[-0.1,0.1]
重み値の学習率 η	0.00001
乱数付与の値域	[-0.1,0.1]

3.2 シミュレーション結果

次の Fig.1(a)~(f) に出力変化の特徴を捉えた各段階での、1~10 個目のニューロン出力、Fig.2 に 1000 ステップごとに算出したリアプノフ指数、Fig.3 に全ニューロン出力の絶対値の平均・最大、Fig.4 に全ニューロンの評価関数の平均、Fig.5 に全重み値の平均(濃い紫の線)と標準偏差(上下の幅)の学習による変化を示す。

学習初期、Fig.1~4 の (a) の部分をみると、トリガ乱数を入れてもすぐに出力は収束し、リアプノフ指数の値からも、出力は非カオスであることが確認できる。その後、リアプノフ指数が正に近づき (Fig.2(b))、評価関数も増加する過程で (Fig.4(b))、出力は周期的な出力に変化した (Fig.1(b))。そこから周期的な状態のまま、出力の大きさは急激に増加するようになる (Fig.3(b)~(c))。そして、リアプノフ指数がほぼ 0 または正に変わるところで出力は非周期に変わり (Fig.1(c))、出力がカオティックになったことがわかる (Fig.2(c))。なお、このときの評価関数の平均も、入力と出力の変化量が同じとされる 1 に近い値となった (Fig.4(c))。

一方で、その後しばらくすると、出力の大きさや評価関数、リアプノフ指数は増減を繰り返すようになった (Fig.1~4 の (e)~(f))。出力の増減自体の原因は不明だが、評価関数の増減については、出力の増減により評価関数内の $f'(u)$ の値が同様に増減して起こっていると考えられる。また、ニューロン出力が飽和すると感度が下がることから、重み値の上昇はどこかで止まると期待していたが、Fig.5 より、重み値は期待に反し全体として大きくなり続け、出力も飽和領域の値を取ることが多くなっていることがわかる (Fig.1、3(f))。

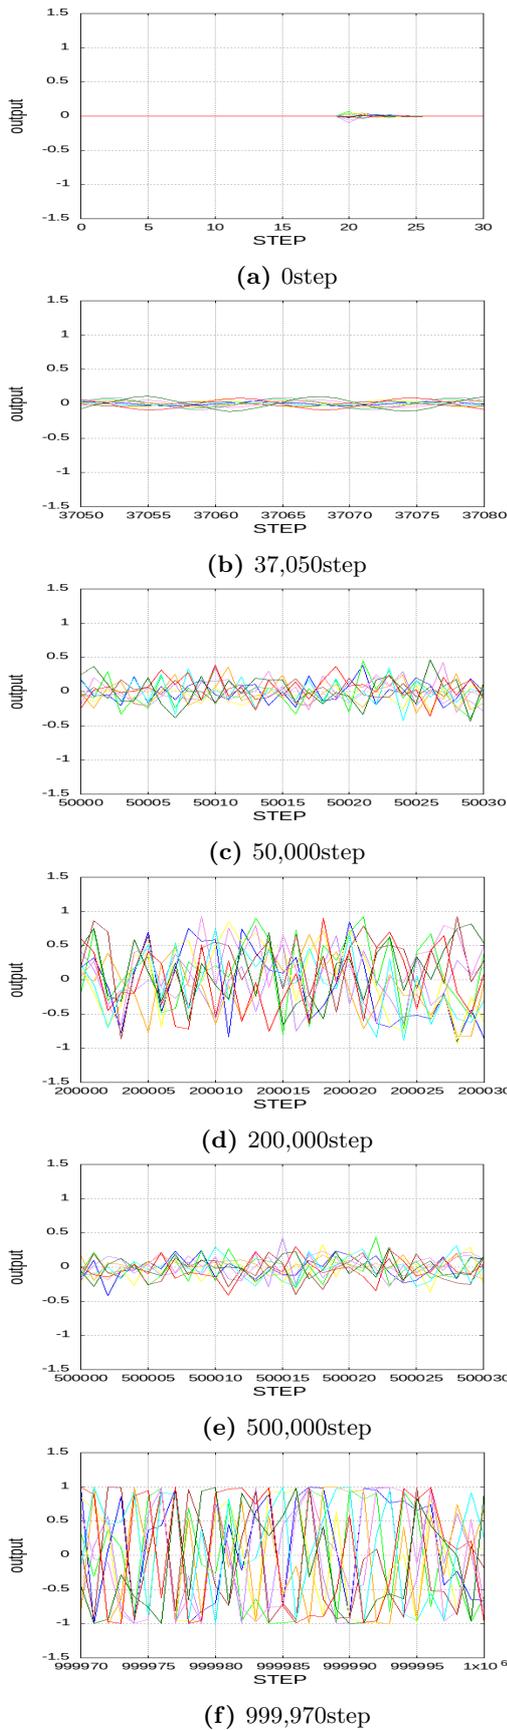


Fig 1: Characteristic variation of 10 neurons' outputs at during learning

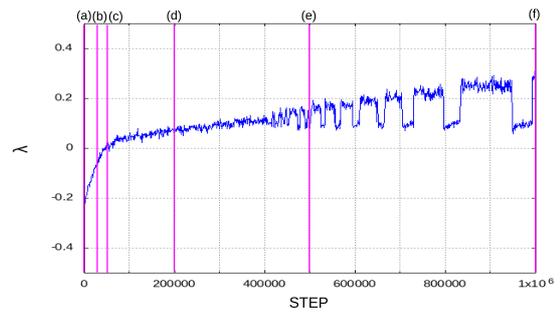


Fig 2: Change of Lyapunov exponent during learning

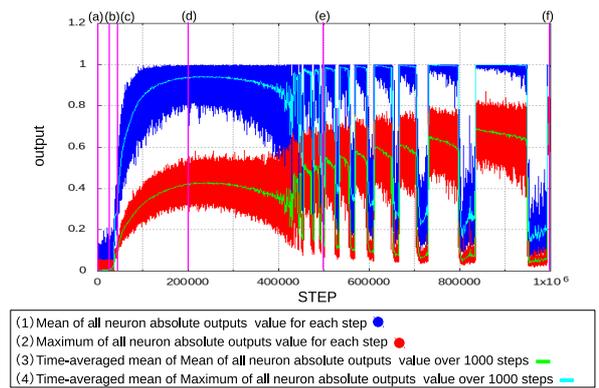


Fig 3: Change of mean and maximum absolute outputs value during learning

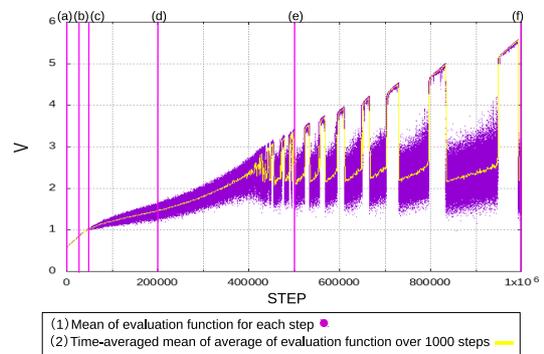


Fig 4: Change of value function during learning

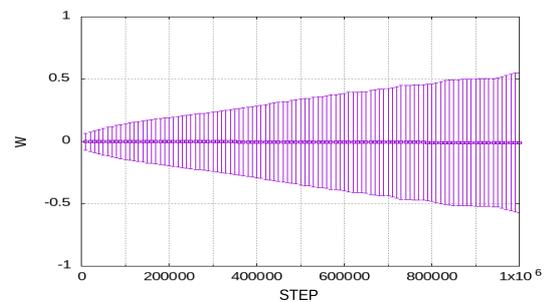


Fig 5: Change of mean and standard deviation of weights during learning

次に、リザバネットなどの大規模なリカレントネットワークではニューロン間の結合を疎にすることが多いことから、ネットワーク結合を全結合から疎結合に変更した場合の学習を行った。以下の Fig.6~8 に例として結合割合を半分の 50% の疎結合にした場合の全出力の絶対値平均・最大および評価関数、リアプノフ指数の各種結果を示す。

これらの結果より、疎結合に変更した場合でもカオスダイナミクスを生成できていることが確認できる。また、結合したニューロン数が半分で、学習係数は同じであるにもかかわらず、学習初期の出力の大きさの急激な増加のタイミングが全結合時とあまり変わらなかった。これは、学習初期において各ニューロンの重み値の大きさの増加が全結合時よりも上がっているためである。これは (6) 式の分母が小さくなることによるものと考えられ、入力数の増減による影響を緩和する効果があると考えられる。

また、50% の疎結合の場合では、前述の全結合時の結果で見られた出力や評価関数の急激な増減が見られなかった。このことについて調査した結果、約 87% の結合割合以下にすることで、この現象が起こらなくなることを確認した。

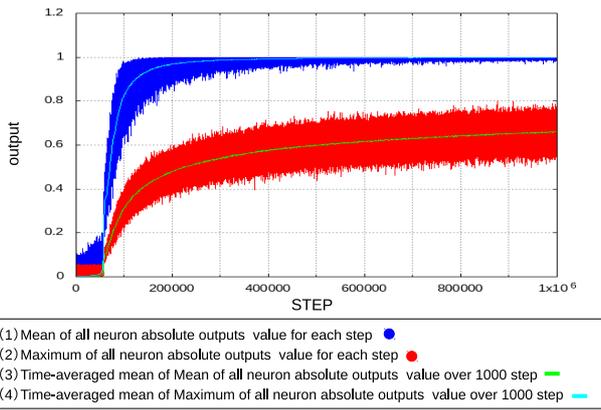


Fig 6: Change of mean and Maximum absolute outputs value during learning (connection rate:50%)

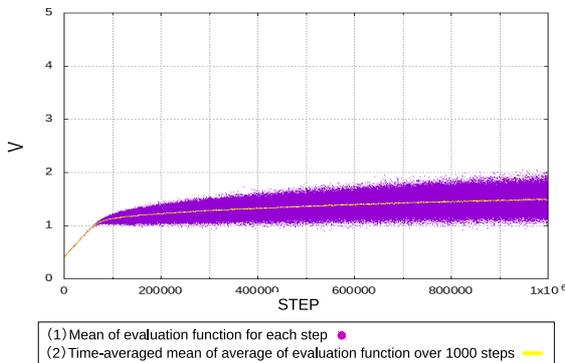


Fig 7: Change of Value function during learning (connection rate:50%)

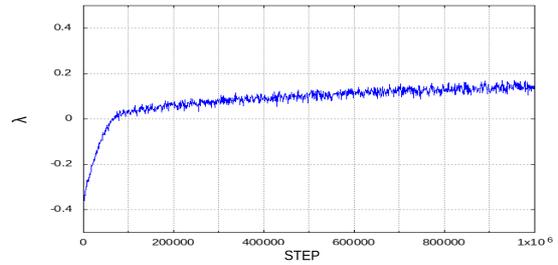


Fig 8: Change of Lyapunov exponent during learning (connection rate:50%)

4 結論

本研究では、各ニューロンに”感度”という基準を導入し、それを増加させるように個々に学習を行う”感度調整学習”を提案した。そして、この学習によってフラットな 100 ニューロンの相互結合ネットワークにおいて、ネットワーク内にカオスダイナミクスが生成されることを確認した。一方で、学習を通じて重み値が増大し続ける、出力の急激な増減が見られる、といった現象も見られた。ネットワーク構造を一定の結合割合以下の疎結合にした場合、出力の急激な増減は見られなかった。

今後は、前述の急激な出力の増減の原因を探るとともに、この学習法を強化学習に導入していきたい。また、「各ニューロンの”感度”による、ネットワークのカオス性の調整」、「乱数でない初期重み値による学習」の確認を行っていきたいと考えている。

謝辞

本研究は JSPS 科研費 (15K00360) の補助を受けた。ここに謝意を表する。

参考文献

- [1] Katsunari Shibata, Tomohiko Kawano : Learning of Action Generation from Raw Camera Images in a Real-World-like Environment by Simple Coupling of Reinforcement Learning and a Neural Network, Proc. of ICONIP, Vol. 5506, pp. 755-762 (2009)
- [2] K.Shibata, H.Utsunomiya : Discovery of Pattern Meaning from Delayed Rewards by Reinforcement Learning with a Recurrent Neural Network, Proc. of IJCNN (Int'l Joint Conf. on Neural Networks), pp. 1445-1452 (2011)
- [3] 柴田克成, 後藤健太 : 予測を要して連続動作を含む柔軟な行動の Actor-Q 学習による獲得, FAN2013 講演論文集, pp. 86-91 (2013)
- [4] V. Mnih, et al.: Human-level control through deep reinforcement learning; Nature, Vol.518, pp.529-533 (2015)
- [5] 柴田克成, 後藤祐樹 : 深層学習が示唆する end-to-end 強化学習に基づく機能創発アプローチの重要性と思考の創発に向けたカオスニューラルネットを用いた新しい強化学習, 「認知科学」 Vol. 24, No1, pp.96-117 (2017)
- [6] 後藤祐樹, 柴田克成 : カオスニューラルネットを用いた強化学習におけるカオス性の影響, 第 36 回計測自動制御学会九州支部学術講演会予稿集, pp. 97-100 (2017)