

1. はじめに

人間の脳には役割により機能する箇所が分かれていく機能分化と呼ばれる現象がある。一方、人工ニューラルネットワークでも、Echo State Network (ESN)[1]を用いた機能分化の手法が提案されており、特定の時間または空間パターンに反応するニューロンを学習することが確認されている [2]。この手法では、Genetic Algorithm (GA) を用いて ESN の Reservoir 層のニューロンの構造と重みを探索する。探索の結果から Reservoir 層のニューロンの出力と正解ラベルから相互情報量を算出し、機能分化を確認している。しかし、GA による最適な重みの探索には膨大な時間が必要になる。そこで本研究では、Hessian-Free 法を用いたより効率的な探索方法を提案する。

2. 先行研究

ESN は、入力層、Reservoir 層、出力層の 3 層で構成され、出力層のみを学習する。入力層と Reservoir 層の重みは 0 から 1 の間でランダムに決定する。Yamaguti ら [2] は、図 1 のように Reservoir 層のニューロンを Input Neurons と Output Neurons に分けた拘束条件付き ESN で空間・時間パターンの分類を行っている。出力層の学習後、GA を用いて Reservoir 層の構造と重みを探索する。その際、各ニューロンの相互情報量から、ネットワークの機能分化を確認している。しかし、全ニューロンの重みの組み合わせは膨大なため、GA による最適な構造と重みの両者を十分に探索することは困難である。




図 1. 拘束条件付き ESN のネットワーク構造

3. 提案手法

本研究では、ニューロンの重み最適化と ESN の構造探索を段階的に行う手法を提案する。全ニューロンの重みを Hessian-Free 法による重みの最適化と、GA による Reservoir 層の構造を探索を繰り返すことで、効率的に探索することが可能となる。

3.1. Hessian-Free 法を用いた ESN の学習

Hessian-Free 法は、再帰型ニューラルネットワークの学習における勾配消失・爆発問題を解決しつつ、長期的なデータの特徴抽出が可能な学習法である [3]。Hessian-Free 法はニューロンの重みの更新値が閾値以下の時は重みの探索を共役勾配法で行う。共役勾配法を用いた場合の重みの更新式を式 (1) に示す。

$$W_{k+1} = W_k - T_k M_k \quad (1)$$

ここで、 W_k は現在の重みの集合であり、 W_{k+1} は更新後の更新後の重みの集合である。式 (1) の T_k は接ベクトル、 M_k は共役勾配である。一方で、更新値が閾値以上の時は重みの探索をガウスニュートン法で行う。ガウスニュートン法を用いた場合の重みの更新式を式 (2) に示す。

$$W_{k+1} = W_k - (\nabla F_k^T \nabla F_k)^{-1} F_k \nabla F_k \quad (2)$$

ここで、式 (2) の F_k は誤差の値、 ∇F_k は勾配ベクトルである。

3.2. GA による構造の探索

Reservoir 層のニューロンの構造を決定するために、GA による探索を行う。図 2 に提案手法による構造探索の流れを示す。まず、step1 にて、全ニューロンの重みを Hessian-Free 法で最適化する。step2 は、GA を用いて Reservoir

層のニューロンの接続構造を探索する。step3 では、GA によって生成される個体の精度が収束するまで、step1 と step2 を繰り返す。図 2 のオレンジ色の矢印は探索により優れていると発見された構造を示す。




図 2. ESN の構造探索の流れ

4. 実験概要

Reservoir 層の構造と重みの探索について、従来手法と提案手法の比較実験を行う。実験には Reservoir 層に 32 個のニューロンを持つ拘束条件付き ESN を用いて、cos 波の周波数と分割数を組み合わせたパターンの分類を行う。提案手法における Hessian-Free 法の学習回数は 20Epoch である。GA のパラメータは、個体数を 200、淘汰する数を 180、世代数を従来手法で 500 世代、提案手法で 5 世代とする。GA による探索後、提案手法と従来手法で Reservoir 層のニューロンと正解ラベルから相互情報量を求め機能分化を確認する。


5. 実験結果

表 1 に精度比較の結果を示す。表 1 より時間情報と空間情報の両方で提案手法の精度が高い。これにより、Hessian-Free 法を用いることで構造と重みの効率的な探索が可能である。

表 1. 従来手法と提案手法の比較精度 [%]

分類種類	従来手法	提案手法
空間情報	85.6	100.0
時間情報	55.3	91.2

図 3(a) に従来手法、図 3(b) に提案手法の時間と空間の相互情報量の結果を示す。図 3(a) から、空間、時間情報量の両者ともに高くなるように進化していることが分かる。一方、提案手法では空間、時間情報のどちらかが高くなるように進化している。以上より、提案手法は、ニューロンの機能分化を誘発することが可能である。



(a) 従来手法 (b) 提案手法
図 3. 機能分化の結果

6. おわりに

本研究では効率的に重みを決定する方法を提案し、少ない世代数で機能分化を誘発することが出来た。今後の予定としては、探索後の Reservoir 層のニューロンが時間と空間パターンの情報をどのように処理しているのかについての分析、考察などが挙げられる。

参考文献

- [1] H. Jaeger, *et al.*, “Harnessing Nonlinearity: Predicting Chaotic Systems and Saving Energy in Wireless Communication”, Science, 2004.
- [2] Y. Yamaguti, *et al.*, “Functional differentiations in evolutionary reservoir computing networks”, Chaos 2021.
- [3] J. Martens, *et al.*, “Learning recurrent neural networks with hessian-free optimization”, ICML, 2011.