

# スパース性に基づいた自己増殖型ニューラルネットワークの提案

日大生産工 ○森川 雄太 日大生産工 山内 ゆかり

## 1. まえがき

昨今、ビッグデータの解析による社会・経済の問題解決や業務の付加価値向上への期待からデータサイエンスの研究が進められている。

ビッグデータの解析手法として、自己増殖型ニューラルネットワーク (Self-Organizing Incremental Neural Network: SOINN)[1]がある。この手法は、入力に対して動的にネットワーク構造を変化させるため、追加学習が可能である。さらに、一定の入力回数ごとに発生したノイズを自動的にネットワークから削除する機能も備わっており、ノイズ耐性が高い。これらの特性により、SOINNは実世界に溢れる情報に即した逐次的な学習を可能としている。

また、最近ではスパース性[2]という考え方が注目されている。スパースとは「疎」を意味する言葉。これに因んで、あらゆる物事に含まれる質的な情報はごく僅かであるという仮定をスパース性という。この仮定に基づき、本質的な情報を抽出しようという研究も行われている。ビッグデータは膨大なデータであり、特徴量もまた大きくなることが多い。しかし、僅かな本質的な特徴量にだけ計算を割くことができれば、大幅な軽量化が可能となる。また、ビッグデータとしながらも、有益なデータが十分に取れない場合もある。そのようなときも、本質的な特徴を抽出できれば、僅かなデータからも高い精度が見込める。

不要な情報を排除し、必要な情報だけに目を向けるという意味でSOINNとスパース性は似ているところがある。一方で、そのための道筋はSOINNとは全く別のかたちとなっているため、私はこの二つの手法は共存が可能ではないかと考えた。本研究では、SOINNにスパース性の考え方に基づく改良を加え、データ解析性能の向上を目指す。

## 2. 自己増殖型ニューラルネットワーク

自己増殖型ニューラルネットワーク (Self-Organizing Incremental Neural Network: SOINN)には複数の拡張が存在するが、最も基本的なSOINNとされている Adjusted SOINN[1]について説明する。

図1にアルゴリズムのフローチャートを示し、概要を説明する。

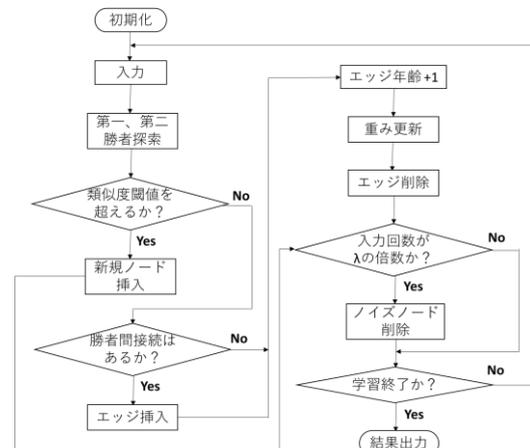


図 1. Adjusted SOINN アルゴリズム フローチャート

まず、入力に対して、既存のノードとユークリッド距離から勝者ノードを探索する。勝者ノードは、最近傍と次点近傍の二者を探索し、これらにより各ノードの重み、状態を更新する。

入力に対する挙動は第一、第二勝者ノードいずれかとのユークリッド距離が以下に示す閾値  $T_i$  を超えるか否かで変化する。ただし、 $i$  はノード番号、 $N_i$  はノード  $i$  の連結ノード集合、 $A$  は全ノードの集合、 $W_i$  は重みベクトルである。

$$\text{if } N_i \neq \emptyset \text{ then} \\ T_i \leftarrow \max_{c \in N_i} |W_i - W_c| \quad (1)$$

$$\text{else} \\ T_i \leftarrow \max_{c \in A \setminus \{i\}} |W_i - W_c| \quad (2)$$

入力と第一、第二勝者いずれかとのユークリッド距離が類似度閾値を超える場合、ノードの分布が不十分である。即ち、入力に新規性ありとし、入力パターンを新たなノードとして挿入する。

両者ともに閾値を越えなかった場合は、勝者ノード間の重み、状態を更新する。エッジ年齢を0にリセットし、第一勝者に繋がる全エッジの年齢を1加齢する。このとき、第一、第二勝者間にエッジが存在しない場合はエッジを挿入してからエッジ年齢を更新する。

そして、(3), (4)に示す重み更新式に従い、勝者ノードとその近傍ノードの重みベクトルを更新する。ただし、 $t_i$  はノード  $i$  が勝者ノードに選択された回数である。

$$\Delta W_{s_1} \leftarrow \frac{1}{t_{s_1}} (\xi - W_{s_1}) \quad (3)$$

$$\Delta W_i \leftarrow \frac{1}{100t_i} (\xi - W_i) \quad (4)$$

$$(\forall i \in N_{s_1})$$

また、状態更新によりエッジ年齢が事前定義閾値  $age_{max}$  を越えたエッジを削除し、さらに削除されたエッジに連結されていたノードのうちエッジを持たなくなったノードを削除。入力パターンがノード削除周期  $\lambda$  の倍数ごとに連結ノードが1つ以下のノードを全て削除する。この挙動により、ノイズの削除が成され、前述のノイズ耐性が得られる。入力からノード削除までの挙動を繰り返すことで、入力に対する近似分布となるノードとノード間の接続関係を示すエッジからなるネットワークを動的に構成することができる。

### 3. 提案手法

本研究では、SOINN の自己増殖のアルゴリズムにスパース性の考え方を取り入れ、クラスタリングの過程で情報の本質を抽出し、次元圧縮をする動的なネットワークを提案する。

具体的には、SOINN のアルゴリズムに従い、訓練データからネットワークを構成する。SOINN 空間内のノードの重みから、各次元の分散を求め、重要度閾値  $\mu$  を超えないときはその次元を不要な次元として変数に 0.0 を代入し、圧縮する。そして次元圧縮したネットワークを既存ノードとして、もう一度訓練データを用いて学習する。

提案手法で用いる SOINN は木村らが提案した改良[3]を取り入れ、ノード削除の周期を入力回数によるものから、ノード年齢によるものとしている。

また、提案手法における SOINN の変更点として、勝者探索式に  $\alpha_d$  の乗算を加えている。

変更した探索式を以下に示す。ただし、 $\xi$  は入力パターン、 $d$  は次元番号、 $\alpha$  は入力とノードのユークリッド距離にかかる係数である。

$$\arg \min_{i \in N} \sum_{d=1}^D (\xi_d - W_{i_d})^2 * \alpha_d \quad (5)$$

$\alpha_d$  は 1.0 で初期化されており、 $\mu$  に従い不要と判断された次元を 0.0 とし、以降その次元の重みが無視される。

### 4. 実験

本実験では手書き数字画像データセット MNIST を用いて、実験を行う。

訓練データを SOINN 及び提案手法で学習し、その量子化誤差  $Q_e$ 、トポロジー誤差  $T_e$ 、ニュー

ロン利用率  $U$ 、クラスタリング精度  $C_a$  の指標で比較する。提案手法で、通常の SOINN で一度、次元圧縮後にもう一度学習することから、SOINN は2度同じ訓練データを学習してから評価を行う。

比較は、それぞれのデータごとにシミュレーションを10回行い、その平均を用いる。

また、次元圧縮により、学習データが少ない場合の精度の向上を期待して、各データの 1/10, 1/5, 1/3, 1/2 の学習データでの結果も比較する。以下にその結果をまとめる。

表1. SOINN 実験結果

SOINN	Ca(%)	Qe	Te	U(%)
1/10	80.50	1445.16	0.6602	98.20
1/5	80.06	1446.86	0.6599	97.55
1/3	79.71	1444.85	0.6502	98.08
1/2	80.07	1440.56	0.6396	97.83
1/1	80.91	1438.37	0.6519	97.91

表2. 提案手法 実験結果

提案手法	Ca(%)	Qe	Te	U(%)
1/10	79.37	1451.80	0.6662	98.23
1/5	79.44	1454.52	0.6664	98.42
1/3	79.64	1448.43	0.6574	98.53
1/2	80.27	1442.32	0.6466	98.02
1/1	80.32	1440.92	0.6419	98.01

### 5. まとめ

本研究では、スパース性の考え方を取り入れ、本質的特徴量の抽出を意識したネットワークを提案した。次元削減によるネットワークの軽量化を図りつつも、各指標の結果から重大な特徴の損失は少ないように思われる。

今回は、各次元の重要度を測る指標としてノードの重みの分散を用いたが、将来的には  $l_1$  ノルム正則化を用いたソフト閾値による判別を行うかたちでの実験を行いたい。

### 参考文献

- [1]山崎和博, 卷渕有哉, 申富饒, 長谷川修, SOINN とその実践, 日本神経回路学会誌 Vol.17, No.4(2010), 187-196
- [2]永原正章, スパースモデリング-基礎から動的システムへの応用-, コロナ社, (2017)
- [3]木村大毅, PICHAJ Kankuekul, 長谷川修, 属性知識の高速オンライン学習と転移による未知クラス推定, 知能と情報(日本知能情報フレンジイ学会誌) Vol.26, No.5, (2014), 830-843