

G-004

## 損傷したニューラルネットワークにおける再学習法の検討

## Consideration of Re-training Method in Damaged ANN

黒川 秀行† Goutam Chakraborty† 馬淵 浩司† 松原 雅文†

Hideyuki Kurokawa† Goutam Chakraborty† Hiroshi Mabuchi† Masafumi Matsuhara†

## 1. はじめに

人工ニューラルネットワーク(Artificial Neural Network 以下 NN)は学習機能を持ち、コンピュータ上で解決しにくいパターン認識や記憶、判断といった問題を処理できる事で知られている。一般的に NN では学習されたネットワークの一部が僅かに損傷しただけでも認識、記憶等の精度は著しく低下してしまう<sup>[1]</sup>。

そこで、NN に対して作為的に断線やノード損傷を与える事により損傷状態をシミュレートし、NN に与える影響、および認識率との関係を調査する<sup>[2]</sup>。これにより、損傷に強い頑強なニューラルネットワークの特徴を見出す。

本稿では、Back Propagation 法を用いた階層型 NN を取り扱う。この NN に対し、ノード間の経路を切断し、損傷の規模が与える影響を調べる事により、修復に有効な再学習法を検討する事を目的とする。

## 2. 評価実験

学習データの違いによる影響を確認するため、入力、出力の次元数が異なるデータを用いて評価実験を行った。

## 2. 1 実験データ

本実験においてのパターン分類データは UCI Machine Learning Repository<sup>[3]</sup>のデータを用いた。今回はその中から癌の分類、あやめの分類、英単語の母音の分類の3つを扱う。

癌の分類 (データ数:683)	
入力	出力
1.Clump Thickness	1.Benign
2.Uniformity of Cell Size	2.Malignant
3.Uniformity of Cell Shape	
4.Marginal Adhesion	
5.Single Epithelial Cell Size	
6.Bare Nuclei	
7.Bland Chromatin	
8.Normal Nucleoli	
9.Mitoses	

あやめの分類 (データ数:150)	
入力	出力
1.Sepal length	1.Iris-setosa
2.Sepal width	2.Iris-versicolor
3.Petal length	3.Iris-virginica
4.Petal width	

英単語の母音の分類 (データ数:300)	
入力	出力
1.First formant	1.~10.Vowel
2.Second formant	
3.Third formant	

## 2. 2 NN の仕様

入力層、中間層、出力層の3層を持つ階層型 NN を用いた。再学習回数は十分に学習できると考えられる 200,000 回、学習率  $\eta$  は 0.01 とした。中間層のノード数は癌の分類が 10、あやめと母音の分類は 15 とした。総接続数は順に  
 $(9+1) \times 10 + (10+1) \times 2 = 122$   
 $(4+1) \times 15 + (15+1) \times 3 = 123$   
 $(3+1) \times 15 + (15+1) \times 10 = 220$   
 となる。

## 2. 3 実験手順

はじめに、通常の学習を行い正常時の認識率を測定する。次に、入力-中間、中間-出力間に存在する経路を乱数的に切断する。その後、損傷したネットワークに対して再学習を行い、再学習時の認識率を測定する。この損傷を 1 経路ずつ増やして行く事で損傷の規模を広げていく。

この時の再学習の定義として、

1. 損傷部以外の経路の結合荷重を乱数で初期化し、改めて学習を始める新規再学習
2. 損傷後の結合荷重に手を加えずに学習を始める再学習の2つを用いた。

## 2. 4 実験結果および考察

以上の条件で各データに対して 5 回ずつ試行を繰り返した。以下に実験結果の平均を取ったものを図 1~3 に示す。

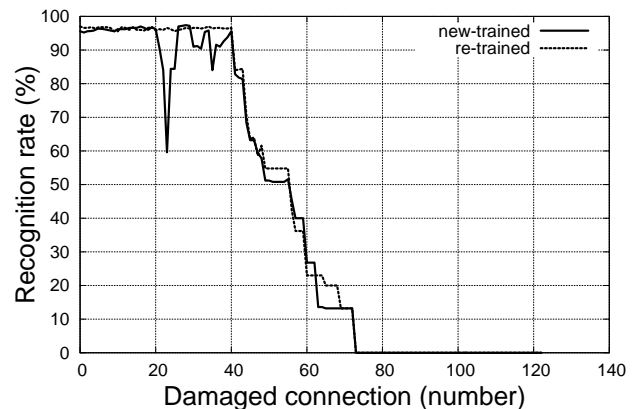


図 1: 癌の分類での再学習結果

† 岩手県立大学大学院 ソフトウェア情報学研究科

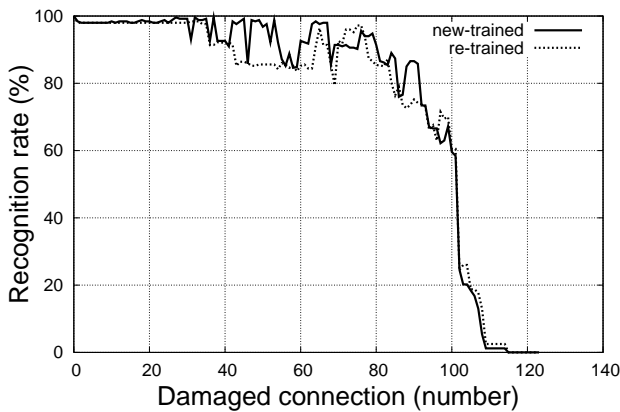


図2: あやめの分類での再学習結果




図3: 母音の分類での再学習結果

図1の結果からは、新規再学習と再学習による修復率の違いは見られなかった。損傷経路数が40本を超えた辺りから認識率が下がり始める事から、必須経路数は総経路数122から損傷経路数40を引いた82となり、これは

$$(9+1) \times 7 + (7+1) \times 2 = 86$$

とほぼ同値に相当するので癌の分類データに対する必須中間ノード数は7であることがわかる。

次に図2の結果から、新規再学習と再学習の大きな違いは見られないが、損傷経路数40~70の認識率などから、新規再学習のほうがわずかに修復効果が高い。また、多少の上下はあるものの損傷経路数80本辺りから認識率が下がり始める事から、

$$123 - 80 = 43$$

$$(4+1) \times 5 + (5+1) \times 3 = 43$$

となり、あやめの分類データに対する必須中間ノード数は5であることがわかる。

最後に図3の結果から、損傷経路数が60本辺りから認識率が下がり始めるので、

$$220 - 60 = 160$$

$$(3+1) \times 11 + (11+1) \times 10 = 164$$

となるので、英単語の母音分類データに対する必須中間ノード数は11であることがわかる。また、新規再学習の方が再学習よりも認識率が高い。

図1~3から共通して、損傷経路が1本増えるだけで大きく認識率が変動する場合がある。さらに、損傷が増えると大きく認識率が戻る場合がある。これは損傷箇所の結合荷重がネットワークに対する依存度が高かったためだと考えられる。また、損傷規模が大きくなっているにもかかわらず認識率が高くなる現象は、それぞれの状態での汎化能力が異なっているからだと考えられる。

その他に、出力される次元数が多いほど新規再学習の効果が高くなる傾向が見られる。この理由としては問題空間の複雑さが挙げられ、初期結合荷重に多様性のあることが影響を与えている事が考えられる。

### 3. おわりに

本研究により、損傷と再学習後の認識率は、正常な接続経路数に影響される事がわかった。また、出力次元数が多いほど新規再学習が有効である傾向が見られた。

損傷後に十分な経路が残っている場合、再学習を用いた修復は可能である。しかし、損傷率が上昇し問題空間をカバーできる限界を越えてしまうと、再学習を行っても修復できる認識精度は低下していく。

本稿では通常の Back Propagation 法を用いた階層型 NN に対して損傷実験を行った。これに対して NN に耐故障性を持たせる手法が提案されている<sup>[4][5]</sup>。

今後は、これらのフォールトトレランスを有する NN に対して同等の実験を行い、耐故障性を持つ NN の特徴を探っていく。また、単一断線故障を修復する手法や構成の異なる NN モデルも提案されている<sup>[6][7]</sup>。このようなネットワークの機能復元法と再学習の違いを調査する事で、よりよい再学習法を探っていく予定である。

#### 参考文献

- [1] 守一雄, 都築誉史, 楠見孝 編著, "コネクショニストモデルと心理学 脳のシミュレーションによる心の理解", 北大路書房, 2001.
- [2] 黒川秀行, GoutamChakraborty, 馬淵浩司, 松原雅文, "損傷したニューラルネットワークでの再学習に関する一考察", 電気関係学会東北支部連合大会, September 2006.
- [3] UCI Machine Learning Repository, <http://mllearn.ics.uci.edu/MLRepository.html>
- [4] 丹康雄, 南谷崇, "フォールトトレランスを有する階層型ニューラルネットワークとその性質", 信学論(D-I), vol.J76-D-I, no.7, pp.380-389, July 1993.
- [5] 西垣正勝, 都筑輝泰, 曾我正和, "ニューラルネットワークの耐最悪故障化学習", 信学論(D-I), vol.J83-D-I, no.1, pp.203-214, January 2000.
- [6] 岩城秀和, 小川秀光, 平林晃, "単一断線故障を修復可能な最適汎化ニューラルネットワーク", 信学論(D-II), vol.J83-D-II, no.2, pp.805-813, February 2000.
- [7] 楊棟林, 松本直也, 水野尚, "ショートカット結合をもつニューラルネットワークモデルの学習能力について", 信学論(D), vol.J90-D, no.7, pp.1836-1839, July 2007.