

G-005

## 階層型ニューラルネットワークの入出力関係を変えずに耐故障性を高める構築法

Enhancing Fault Tolerance Keeping Network Input/Output for Multi Layer Neural Networks

眞弓 正彦†

高瀬 治彦†

北 英彦†

林 照峯†

Masahiko Mayumi

Haruhiko Takase

Hidehiko Kita

Terumine Hayashi

## 1 はじめに

ニューラルネットワークは、脳の神経回路網を模倣した計算モデルである。そのため、脳が持つさまざまな特徴を引き継いでいると考えられている [1]。

本論文では、ニューラルネットワークの特徴のうち、耐故障性に着目する。耐故障性は、ネットワーク内部に故障が生じて、故障前の入出力関係を実現し続ける能力である。これは安全性や信頼性の向上に関わる重要な性能である。

具体的には、階層型ニューラルネットワークにおいて入出力関係を変えないで、耐故障性を向上させる手法を提案する。この手法により、入出力の特性をそのままに、高い耐故障性を付与できる。例えば、学習により汎化能力を高めたうえで、耐故障性を高めることが容易にできる。

## 2 故障モデル

一般に、MLN 内部に生じうる故障は数多く存在する [2]。MLN で考えられる故障には、ユニット出力の故障、ユニット間の結合の故障、結合荷重の故障などが考えられる。ここで、ユニット出力の故障、結合荷重の故障は、ユニット間の結合の故障に帰着できる。そのため、本論文では、ユニット間の結合の故障だけを考え、特に、結合が故障した結果、その結合荷重の値が0になったとみなすモデルを取り扱う。結合荷重の値が0に固定されてしまう故障 (0 縮退故障) は、ユニット間の結合が断線する故障と等価である。

## 3 従来法とその問題点

本論文では、入出力関係を変えないで耐故障性を高める手法として、Augmentation 法 (AUG 法) [3] に着目する。

AUG 法は、中間層ユニット数を増加させることで、ネットワークに冗長性を持たせ、耐故障性を向上させる手法である。具体的には、中間層ユニット数を  $n$  倍する。その結果、中間層の冗長性が増し、耐故障性が向上する。なお、中間層ユニットを増加させる際に、元のネットワークの入出力関係を維持するために、入力層-中間層間の結合荷重はそのままコピーし、中間層-出力層間の結合荷重は  $1/n$  倍する。

AUG 法を用いることで、元となるネットワークの入出力関係はそのままに、耐故障性が向上する。しかし、すべての中間層ユニットを一律に増加させるため、増加させても耐故障性があまり向上しない中間層ユニットまで増加させてしまい、無駄が生じやすいという問題点がある。

## 4 提案法

前節で述べたように、AUG 法では増加させる中間層ユニットに無駄が生じやすい。そこで本論文では、各中間層ユニットの重要度に応じて、その増加倍率を変化させる Local Augmentation 法 (LAUG 法) を提案する。ここで、中間層ユニットの重要度とは、それに接続している結合の重要度の最大値とする。また、各結合の重要度は、その結合の故障により生じる影響の大きさ (ネットワーク出力の変化) とする。これにより、中間層ユニットを増加させることで、耐故障性が効果的に向上する。

LAUG 法では、元となるネットワークの中間層ユニット数  $b$  から、重要な中間層ユニットを一つずつ選び増加させること

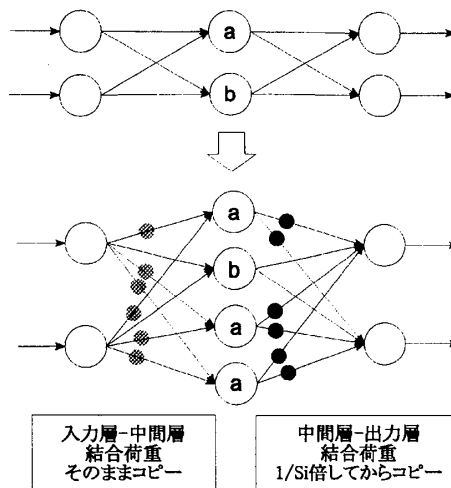


図 1: LAUG 法における仮ネットワークの構築

を、中間層ユニット数の上限  $u$  まで繰り返す。具体的な手順は、以下のとおりである。

1. 適当な学習法によりネットワークを構築する。これを元ネットワークとする。
2. 元ネットワークの各中間層ユニット  $i$  に倍率  $s_i$  を設定し、初期値を1とする。ここで、 $1 \leq i \leq b$  である。
3. 倍率  $s_i$  に基づき、手順1で得たネットワークから仮ネットワークを構築する。元ネットワークの各中間層ユニット  $i$  を、その倍率  $s_i$  で増加させる。このとき、入力層-中間層間の結合荷重は元のネットワークの結合荷重の値をそのままコピーし、中間層-出力層間の結合荷重は元のネットワークの値を  $1/s_i$  倍する (図1)。
4. 仮ネットワークから最もネットワークの出力に影響を及ぼす結合を探す。
5. 手順4で求めた結合に繋がっている中間層ユニットを求め、それに対応する  $s_i$  を1増やす。
6. 手順3~5を  $\sum_{i=1}^b s_i = u$  となるまで繰り返す。
7. 最終的に得られた倍率  $s_i$  から、手順3と同様にネットワークを構築し、これを最終的なネットワークとする。

ここで、手順4は重要な結合の一つ選ぶ手順である。この手法にはさまざまな方法が考えられる。ここで重要な結合とは、その結合の故障により生じる影響が大きな結合のことなので、手順4'のように故障が発生した場合のシミュレーション (故障シミュレーション) を行うことでそれを探す手法が、最も正確であるといえる。これを LAUG (precise) 法とする。

$$4'. \max_p \sum_k \frac{1}{2} (Y_k^p - \hat{y}_k^p)^2 \text{ を生じさせる結合を探す。}$$

†三重大学大学院工学研究科

ここで、 $g_k^p$  は、仮ネットワークにおいて、あるひとつの結合荷重を故障させた時の出力である。

ただし、手順4'のように故障シミュレーションを行う手法では、結合数、入力パターン数に比例した計算が必要であり、時間がかかる。そこでこれを近似的に求める手法を提案する。文献[4]では、中間層-出力層間の強い結合の故障は、ネットワークの出力に大きな影響を与えることが指摘されている。そこで、結合の強さ(結合荷重の絶対値の大きさ)により、結合の重要度を測る(手順4'')。これをLAUG(weight)法とする。

4''. 仮ネットワーク中から、最も大きな絶対値の荷重を持つ中間層-出力層間の結合を探す。

## 5 実験

ここでは、簡単な認識を行う問題の学習を通じて、提案法の有効性を確認する。比較対象として、最も性能が高い耐故障性を高める手法のひとつであるWMA法[4]を用いる。

実験データとして、UCI[5]の機械学習用データであるwineを用いる。wineは、13の成分値の入力で3種類のワインを識別するものであり、178個のデータを持つ。以下に示す実験結果は全て10回実験をおこなった平均値である。

実験結果の「BP30」は、BP学習法を用いて中間層ユニット30個で学習したことを表し、「WMA30」についても同様である。また、「BP10+AUG30」は、BP学習法を用いて中間層ユニット10個で学習した後、AUG法で中間層ユニットを30個に増やしたということを表し、「BP10+LAUG30(precise)」、「BP10+LAUG30(weight)」も同様である。

まず、ネットワーク構築時間を表1に示す。ネットワーク構築時間は、学習時間と中間層を増加させる時間を合わせたものである。表1より、「BP10+AUG30」と「BP10+LAUG30(weight)」は、最も短い時間ですんでいる。

次に、複数の故障を考慮した耐故障性を測定するために、故障率の増加に対する認識率の低下を調べる。故障率の増加に対する認識率の低下の実験結果を図2に示す。縦軸が認識率(%), 横軸が故障率(%)を表す。故障率は、それぞれの結合荷重を故障させる確率を表す。図2より、WMA法、LAUG法、AUG法の順に高い耐故障性を得た。また、LAUG(precise)法とLAUG(weight)法により、ほぼ同等の耐故障性を得た。

## 6 考察

表1より、ネットワーク構築時間はWMA法が最も長くなっている。これは、耐故障性を高めるための学習に時間がかかっているからである。さらに、LAUG(precise)法、LAUG(weight)法を用いた場合、「BP30」よりも時間が短くなっている。これは、元ネットワークを少ないユニットで学習することで、大幅に学習時間が短くなるためである。また、AUG法とLAUG(weight)法を用いた場合、LAUG(precise)法を用いた場合よりも時間が短くなっている。これは、故障シミュレーションをおこなわず、増加させる中間層ユニットを決定しているためである。実際、AUG法、LAUG(weight)法を用いた場合には、ほとんど時間がかかっていない(0.1秒未満)。

図2より、LAUG法を用いた場合は、学習時から耐故障性を考慮したWMA法には及ばないものの、それに次ぐ高い耐故障性を得たことがわかる。また、LAUG(precise)とLAUG(weight)法を用いた場合の結果に差はなく、近似的に最も重要な結合を選んで問題ないことがわかる。

以上より、LAUG(weight)法により、短時間で高い耐故障性をネットワークに付与できることがわかる。

表1: ネットワーク構築時間

	構築時間 (sec)
BP30	12.8
WMA30	109.9
BP10+AUG30	5.9
BP10+LAUG30 (precise)	10.3
BP10+LAUG30 (weight)	6.0

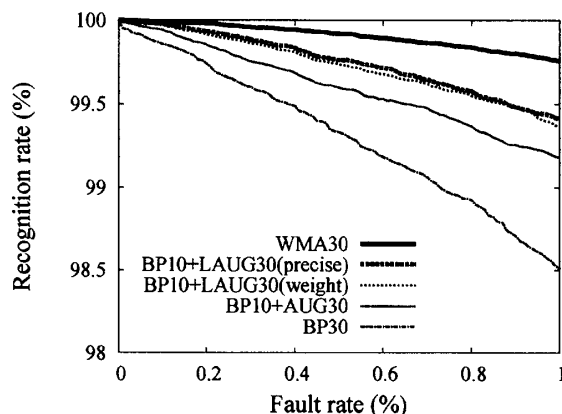


図2: 故障による認識率の変化

## 7 まとめ

本論文では、階層型ニューラルネットワークの入出力関係を変えずに耐故障性を高める手法を提案した。

実験により、提案したLAUG(weight)法を用いることで、高い耐故障性を有するネットワークの構築に短い時間で成功した。

提案されているさまざまな学習法とLAUG法を組み合わせることで、ニューラルネットワークの入出力の特性を損なわずに耐故障性を容易に向上させることができる。

## 参考文献

- [1] 白井 支朗, 岩田 彰, 久間 和生, 浅川 和雄: 基礎と実践 ニューラルネットワーク, コロナ社, 1995.
- [2] George Bolt: Fault Models Artificial Neural Networks, Proc. of 1991 International Joint Conference on Neural Networks, pp.1373-1378, 1991.
- [3] Martin D.Emmerson, Robert I.Damper: Determining and Improving the Fault Tolerance of Multilayer Perceptrons in a Pattern-Recognition Application, IEEE Transactions on Neural Networks, Vol.4, No.5, 1993.
- [4] TAKASE Haruhiko, KITA Hidehiko, HAYASHI Terumine: A study on the simple penalty term to the error function from the viewpoint of fault tolerant training, Proc. of 2004 International Joint Conference on Neural Networks, pp.1045-1050, 2004.
- [5] Newman, D.J., Hettich, S., Blake, C.L., Merz, C.J.: UCI Repository of machine learning databases, [http://www.ics.uci.edu/~mllearn/MLRepository.html], University of California, 1998.