

4K-8

ニューラルネットワークのリンク故障に対する 高速な再学習法

山森 一人 堀口 進

北陸先端科学技術大学院大学情報科学研究所

1 はじめに

ニューラルネットワークは人間の脳の構造を模倣したシステムである。脳内の個々のニューロンは、現在の計算機デバイスよりもはるかに低速で動作しているにもかかわらず、脳全体としての性能や信頼性は計算機とは比較にならないほど優秀である。

人間の脳では毎日多くのニューロンが死滅しているにもかかわらず脳の機能が失われないことから、ニューラルネットワーク自体にフォールトトレランス性が備わっていると考えられる。しかし、VLSI 上に実装されたニューラルネットワークでは、リンクやユニットの故障は致命的なものであり、もはや正しい解を提示することができない。このため、故障したニューラルネットワークの再学習法が数多く提案されている [1]。

本研究では、一部のリンクやユニットが故障したニューラルネットワークを再度機能させるための部分再学習法を提案する [2]。提案する部分再学習法は、故障したリンクやユニットに関する部分だけを取り出して、出力として单一のユニットを持つネットワークだけ再学習を行う手法である。このときの初期重みとして、乱数を用いる場合と故障前の重みを用いる場合について比較検討する。

2 部分再学習法

本研究で対象とするニューラルネットワークは、3層完全結合型ニューラルネットワークとし、学習アルゴリズムは誤差逆伝搬法とする。各ユニットの応答関数はシグモイド関数である。

ニューラルネットワークの部分再学習法として、一度完全に学習が行なわれたあと、隠れ-出力層間でリン

High Speed Retraining for Neural Networks with a Faulty Link

Kunihiro Yamamori, Susumu Horiguchi

Japan Advanced Institute of Science and Technology

15 Asahi-dai, Tatsunokuchi, Ishikawa 923-12, Japan

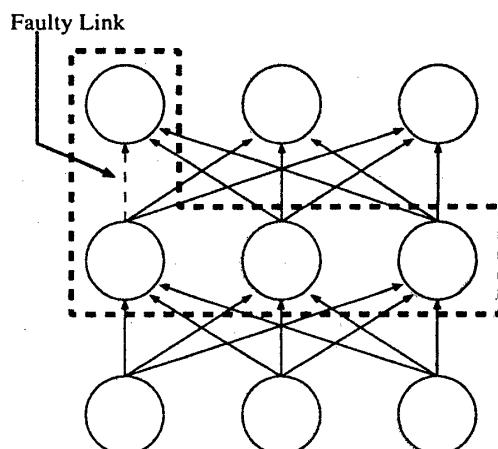


図 1: リンク故障で再学習を行なう部分ネットワーク

ク故障が発生した場合を考える。部分再学習法では、この故障が影響を与えるユニットだけを再学習の対象とする。図 1 の例では、破線で囲まれた部分のネットワークのみが再学習の対象となる。これにより 3 層全体を再度学習させる場合に比べて、再学習を行なうユニット数を大幅に削減することができ、必要となる学習時間の短縮が可能となる。

対象となった部分ネットワークにおける再学習は、入力に隠れユニットの出力を用いた誤差逆伝搬により再学習を行なう。リンク故障の場合はそのリンクの重みを 0、ユニットの故障はその出力を 0 として再学習を行なう。誤差逆伝搬法のバックワードバスにおける重みの更新は、故障したリンクについては行なわない。また、再学習を行なう時の初期重みとして乱数を使用した場合と、故障リンクの重みのみ 0 とした故障前の重みを初期重みとして用いた場合を比較検討した。

3 部分再学習法の性能評価

部分再学習法の性能を議論するため、XOR 問題を対象とする小規模ニューラルネットワークと、人間の顔画像認識を対象とする大規模ニューラルネットワーク [3] について再学習実験を行なった。

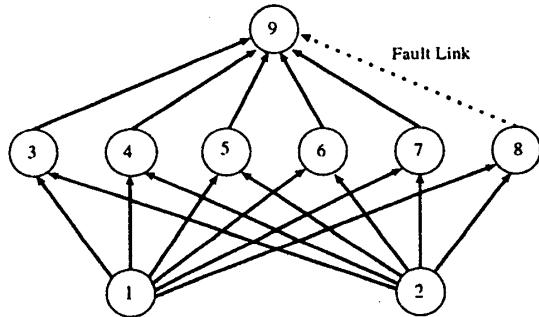


図 2: XOR 問題で用いたネットワークの構成

表 1: ネットワークの収束速度と出力値

| 入力 1 | 入力 2 | 3L-RIW | PR-FIW | PR-RIW |
|---------|------|--------|--------|--------|
| 0 | 0 | 0.17 | 0.17 | 0.18 |
| 0 | 1 | 0.71 | 0.77 | 0.70 |
| 1 | 0 | 0.79 | 0.79 | 0.84 |
| 1 | 1 | 0.12 | 0.13 | 0.14 |
| Epoch 数 | | 34 | 4 | 9 |

3.1 XOR 問題

入力層 2, 隠れ層 6, 出力層 1 のニューラルネットワークで XOR 問題を学習させ, 図 2 で示すように隠れ層-出力層のリンクの 1 つに故障が発生した場合の再学習実験結果を表 1 に示す。表 1 中, 3L-RIW は 3 層全体を乱数初期重みにより再学習させた場合, PR-FIW は部分学習法を用い, 故障前の重みをそのまま初期重みとして用いた場合, PR-RIW は部分学習法で初期重みに乱数を使用した場合である。表 1 より, 3 層を再度学習させる場合に比べ, 故障前の重みを初期重みとした部分再学習法は約 1/8 の処理時間でネットワークの再学習を行なえることが明らかとなった。

3.2 顔画像認識問題

入力層 64, 隠れ層 40, 出力層 32 のネットワークを用いて顔画像認識問題の再学習実験を行なった。実験は 3.1 節での実験と同じく, 隠れ層-出力層間のリンク 1 つが故障を起したと仮定した。実験では, 全ての隠れ層-出力層間のリンクに対して再学習実験を行なった。表 2 に再学習実験の結果の一部を示す。

表 2 から分かるように, 再学習の際に故障を起す前の重みを初期重みとして使用することにより, 乱数を初期重みとして使用する場合に比べて約 1/10 の時間で再学習を完了することができた。これは, 故障を起

表 2: 平均収束時間

| 出力ユニット番号 | 1 | 4 | 7 | 10 |
|----------|------|------|-------|------|
| RIW | 6.16 | 6.88 | 13.91 | 4.17 |
| FIW | 0.49 | 0.56 | 1.37 | 0.30 |

単位:秒

こす前の重みを用いることにより, 誤差が最小値に近い位置から再学習を開始できるためと考えられる。

4 おわりに

階層型ニューラルネットワークのリンク故障に対する高速な部分再学習法を提案し, その再学習性能について検討した。その結果, 故障したリンクに関するユニットだけを取り出して再学習させることにより, 3 層全体を再学習させる場合に比べ大幅に高速化することができた。また, 故障部分の再学習に当たり, 故障を起す前の重みを初期重みとして使用することで, 乱数を初期重みとして再学習を行なう場合に比べ約 10 倍の速度で学習を完了させることができた。

今後の課題としては, 隠れ層のユニット数を変えた場合に部分再学習法が有効であるかどうかの検証と, 複数のリンクやユニットが同時に故障を起こした場合の並列再学習法についての検討を行なう。

謝辞

本研究の一部は, 文部省科学研究助成を用いて行なわれた。関係各位に感謝する。

参考文献

- [1] C.Khunasaraphan, K.Vanapipat, C.Lursinsap, "Weight Shifting Techniques for Self-Recovery Neural Networks", *IEEE Trans. on Neural Networks*, Vol.5, pp.652-658, 1994
- [2] Jung H.Kim, 山森 一人, 堀口 進, "The Fault-Tolerant Design of Artificial Neural Networks", *Proc. of JTC-CSCC95*, pp.687-690
- [3] 山森 一人, 阿部 亨, 堀口 進, "超並列計算機上のニューラルネットワークを用いた顔画像認識に関する研究", 第 49 回情報処理学会全国大会講演論文集 (2), pp.271-272