

断線に対する耐故障性をもつニューラルネットワークの一構成法

1 D-4

河野 英太郎

丹 康雄

南谷 崇

東京工業大学 工学部

1 はじめに

近年、ニューラルネットワークに関する研究が盛んに行なわれている。ニューラルネットワークは特徴として並列分散処理、学習能力、汎化能力等を持つ。また、ニューラルネットワークに期待される特徴として耐故障性が挙げられているが、定量的な指標の設定[1]や耐故障性を高めるための試み[2]は少ない。

本稿では、階層型ネットワークを対象とした場合、その入力線を多重化したユニットを導入することにより断線に対して耐故障性を有するネットワークが構成できることを示す。

2 階層型ネットワーク

2.1 基本構成

しきい値素子のユニットが多層に配置され、層間のユニットの結合によって構成されたネットワークを階層型ネットワーク(Layered Network)と呼ぶ。

階層型ネットワークには様々なモデルがあるが、多層 Perceptron や Rumelhart らの提案した誤差逆伝搬(Error Back Propagation)モデル[3]はその代表的なものである。誤差逆伝搬モデルは入出力の教師パターンへの提示を繰り返すことによって学習が進む。このモデルについては多くの応用・実用研究がある[4]。

誤差逆伝搬モデルでは、ユニットは入力荷重和に対してS字状(Sigmoid) 関数を用いることで出力を計算している。

一般に、誤差逆伝搬モデルではユニットを2層以上用いる。この時、ネットワークへの入力部分も1層と考える。従って、ユニットが2層の場合には入力層(Input Layer)、隠れ層(Hidden Layer)、出力層(Output Layer)がそれぞれ1層ずつで3層の(階層型) ネットワークと呼ばれる。あるユニットの出力を V とすると式(1) のように表される。

$$V = g\left(\sum_{i=1}^n w_i x_i + \theta\right) \quad (1)$$

$$g(x) = \frac{1}{1 + e^{-x}} \quad (2)$$

但し、 x_i はユニットへの入力、 w_i はその入力に対する荷重、 θ はユニットのしきい値である。

誤差逆伝搬モデルではネットワークの出力と教師パターンとから成る評価関数を設けて、最急降下法により各々の荷重が評価関数を減少させるように学習規則が導かれている。

2.2 耐故障特性

断線を起こすと、ネットワークの出力が誤るような結合を必須結合と呼ぶことにする。通常の誤差逆伝搬学習では耐故障性に関する評価はなされていないので、単にネットワークの構成要素を増やしたとしても必ずしも耐故障性のあるネットワークが得られるとは限らない。

図1に XOR 問題におけるユニットの隠れ層のユニット数と必須結合数との関係を示す。図1の例では、ネットワークの構成要素を増やしても必須結合数の平均値(Average)は減少していない。

3 耐故障化の手法

以下の手法では必須結合をなくすことによるネットワークの耐故障化を考える。ネットワーク中の必須結合数を0にすることによ

A Compositional Method of Neural Networks with Fault-tolerance for disconnection.

Eitaro Kohno, Yasuo Tan, Takashi Nanya

Tokyo Institute of Technology, Faculty of Engineering

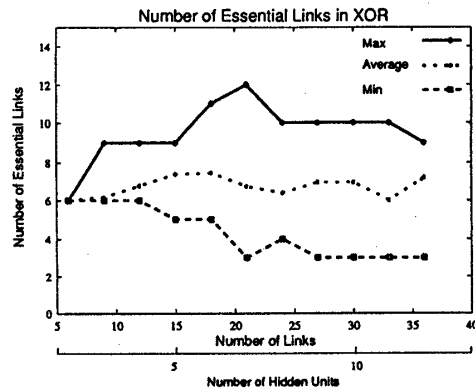


図1: ネットワークの結合(隠れ層ユニット)数と必須結合数

て単一断線に対する故障マスク性能を持つネットワークが実現できる[5][6]。

ネットワーク中のある1つのユニットの入出力について考えると、断線はユニットへの入力値の変動をひき起こす。必須結合の断線によって、ユニット入力が変動(結合重みの0縮退)し、ユニットの出力が大きく変化する。その結果としてネットワーク全体の出力に大きな影響を与える。

ネットワーク中のある1つのユニットでの断線の影響をマスクする(あるいはマスクしたとみなせる)ための入力の変動の低減方法として、入力線の多重化を行なったユニット(以下多重化ユニット)を導入する。

3.1 多重化ユニット

式(1)で表されるようなユニットに対して各々の入力線を k 本に多重化した多重化ユニットの出力 V^k を次のように定義する。

$$V^k = g\left(k\left(\sum_{i=1}^n w_i x_i + \theta\right)\right) \quad (3)$$

ユニットが入力ベクトルを0または1に分類する分類器と考える場合、分類される入力ベクトル空間の境界部分を分離超平面(Separating Hyperplane)と呼ぶ。式(3)のような多重化ユニットは式(1)の持つ分離超平面を保存している。

式(3)に示した多重化ユニットは式(1)のパラメータ w_i 、 x_i および多重度 k を用いて構成することができる。

3.2 断線の故障マスク

多重化ユニットにおいてある一つの結合が断線したときのユニットの出力 $V^{k'}$ は

$$V^{k'} = g\left(k\left(\sum_{i=1}^n w_i x_i + \theta\right) - w_m x_m\right) \quad (4)$$

となる。

ユニットが入力の0および1への分類器と考えると次の式を満たせば良い。




図 2: XOR を実現するネットワークの例




図 3: ユニットの重みの分散による構成

$$k \left(\sum_{i=1}^n w_i x_i + \theta \right) - w_m x_m > 0 \quad \text{iff} \quad \sum_{i=1}^n w_i x_i + \theta > 0 \quad (5)$$

$$k \left(\sum_{i=1}^n w_i x_i + \theta \right) - w_m x_m < 0 \quad \text{iff} \quad \sum_{i=1}^n w_i x_i + \theta < 0 \quad (6)$$

これらの式を解くといずれの場合も多重化ユニットの多重度 k は次のようになる。

$$k > \frac{w_m x_m}{\sum_{i=1}^n w_i x_i + \theta} \quad (m = 1, 2, \dots, n) \quad (7)$$

このようにして構成された多重化ユニットを用いてネットワークを再構成する。

4 構成法

本稿で提案する構成法は次のようなものである。

1. 通常の誤差逆伝搬学習によりネットワークを求める。
2. 各々のユニットについて入出力と式 (7) を用いて多重度を計算する。
3. 式 (7) の n 個の不等式を満たす整数のうち最小のものをそのユニットの多重度として採用する。
4. 3. で求めた多重度をもつ多重化ユニットを用いてネットワークを再構成する。

5 シミュレーション結果

図 4 に XOR を実現する最小の構成のネットワークに本構成法を適用して得られたネットワークを示す。

また、図 2, 3 にはそれぞれ、誤差逆伝搬学習によって求められたネットワーク、図 2 の重みを分配したユニットを用いた構成によるネットワークを示す。

ここでは断線によって、ネットワークの出力と学習時の教師信号との差が 0.5 より大きくなった時その結合を必須結合と考えている。

前述した構成法によって多重化ユニットを用いれば、誤差逆伝搬学習によって求めたネットワークの必須結合をなくすことができた。

6 考察

6.1 多重化ユニットによる構成法

本構成法において多重化ユニットの導入は次のような特徴を持つ。

- 入力線の多重化
入力線を多重化することにより断線時の入力の変動が軽減されている。

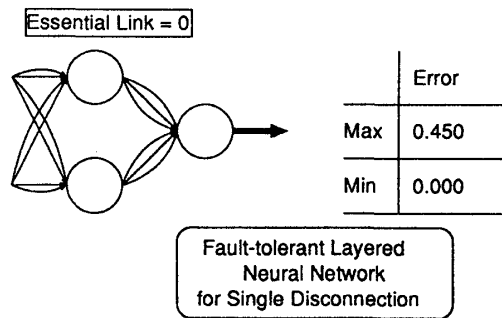


図 4: 多重化ユニットによる単一断線に対して耐故障性を持つ構成

• 出力函数の急峻化

多重化ユニットの導入により、オリジナルのユニットの入力ベクトルと分離超平面との距離が大きくなる。従って、多重化ユニットを導入することにより、故障時の入力の変動の影響が軽減されている。

これらの特徴のうち出力函数の急峻化は S 字状函数に特有なもので、出力函数として単位ステップ函数を用いるようなユニットから構成されるネットワークでは考慮の必要がない。

6.2 多重断線の故障マスクへの拡張

本稿で提案した構成法を用いれば、式 (7) を修正することにより多重断線に対する故障マスク特性を持つようなネットワークを構成することができる。

$$k > \frac{t w_m x_m}{\sum_{i=1}^n w_i x_i + \theta} \quad (m = 1, 2, \dots, n) \quad (8)$$

ここで t は対象とする断線の多重度である。

ネットワーク中のすべての多重化ユニットの多重度が式 (8) を満たす場合には、ネットワークの t 重以下の多重度を持つ断線をマスクできると考えられる。

7 まとめ

本稿では、階層型ニューラルネットワークにおいて多重化ユニットを導入することによって、断線の故障マスク行なう構成法を提案した。多重化ユニットは式 (7) を満たすような多重度を持つ。

本構成法では、多重化ユニットを用いることにより断線により変化するユニットの入力の変動範囲を制限し、故障マスクを実現している。

参考文献

- [1] R. K.Chun and L. P. Mcnamee, *Immunization of Neural Networks against Hardware Faults*, IEEE Int. Symp. on Circuits and Systems, Vol. 1, pp. 714-718, (1990)
- [2] 丹 康雄, 南谷 崇, 階層型ニューラルネットの耐故障性に関する一考察, 情報処理学会第 42 回全国大会, Vol. 6, pp.104-105 (1991)
- [3] D. E. Rumelhart, G. E. Hinton and R. J. Williams, *Learning internal representations by error propagation*, *Parallel Distributed Processing*, Vol. 1, D. E. Rumelhart and G. E. Hinton (Eds.), Cambridge, MA: MIT Press, pp.318-362, (1986)
- [4] J. Hertz, A. Krogh and R. G. Palmer, *Introduction to the Theory of Neural Computation*, Addison-Wesley, (1991)
- [5] 丹 康雄, 南谷 崇, 遺伝アルゴリズムによる耐故障ニューラルネットワークの実現, 情報処理学会第 44 回全国大会, (1992)
- [6] 名古 和行, 丹 康雄, 南谷 崇, 内部表現の分散化によるニューラルネットワークの耐故障化の一手法, 情報処理学会第 44 回全国大会, (1992)