

## 耐最悪故障化学習の拡張

1J-11

 真柄 建太郎 西垣 正勝  
 静岡大学情報学部

 都筑 輝泰 曾我 正和  
 シャープ 岩手県立大学

### 1 はじめに

単一断線故障に対するフォールトトレラント回路をニューラルネットワークを用いて効率よく実現することを目的とする。既に著者らのグループは、最悪故障時の出力のみを教師信号に一致させることで効率よく耐故障性を得る耐最悪故障化学習アルゴリズムを提案した[1]。しかし、その学習アルゴリズムでは、故障を中間層-出力層間の単一断線に仮定していた。本稿では、故障の範囲を3層ニューラルネットワークの全ての配線における単一断線故障に拡張する。

### 2 使用モデル

- ネットワークは3層フィードフォワード型のニューラルネットワークを用いる。入力層、中間層、出力層のニューロン数はそれぞれ  $n_i$ ,  $n_h$ ,  $n_o$  である。入力層第  $i$  ニューロン-中間層第  $j$  ニューロン間の結合枝を  $L_{ij}$ , その結合荷重を  $v_{ij}$  とする。中間層第  $j$  ニューロン-出力層第  $k$  ニューロン間の結合枝を  $l_{jk}$ , その結合荷重を  $w_{jk}$  とする。
- ネットワークに第  $p$  パターンを入力した際の入力層第  $i$  ニューロンの出力を  $e_{pi}$ , 中間層第  $j$  ニューロンの出力を  $h_{pj}$ , 出力層第  $k$  ニューロンの出力を  $o_{pk}$  とする。なお,  $e_{pi}$  は入力層に入力されたパターンと等しい。また, 第  $p$  パターンにおける出力層第  $k$  ニューロンに対する教師信号を  $t_{pk}$  とする。
- ネットワークに第  $p$  パターンを入力した際の中間層第  $j$  ニューロンの入力の荷重和を  $s_{pj}$ , 出力層第  $k$  ニューロンの入力の荷重和を  $u_{pk}$  とする。  $s_{pj} = \sum_{i=1}^{n_i} v_{ij} \cdot e_{pi}$ ,  $u_{pk} = \sum_{j=1}^{n_h} w_{jk} \cdot h_{pj}$  である。また,  $h_{pj} = \text{sigm}(s_{pj})$ ,  $o_{pk} = \text{sigm}(u_{pk})$  である。なお,  $\text{sigm}(\cdot)$  はシグモイド関数である。
- $L_{ij}$  の断線を  $F_{ij}$  と記す。  $F_{ij}$  の発生により中間層第  $j$  ニューロンの入力は  $s_{pj}^{F_{ij}}$  に誤り, その結果, 出

力  $h_{pj}$  が  $h_{pj}^{F_{ij}}$  に誤る。さらに  $h_{pj}^{F_{ij}}$  により出力層第  $k$  ニューロンの入力は  $u_{pk}^{F_{ij}}$  に誤り, その結果, 出力が  $o_{pk}^{F_{ij}}$  に誤る。

- $l_{jk}$  の断線を  $f_{jk}$  と記す。  $f_{jk}$  により出力層第  $k$  ニューロンの入力は  $u_{pk}^{f_{jk}}$  に誤り, その結果, 出力が  $o_{pk}^{f_{jk}}$  に誤る。

### 3 耐最悪故障化学習

#### 3.1 学習アルゴリズム

耐最悪故障化学習 [1] では、最悪故障  $f_{max}$  が起きた時の出力を教師信号  $t_{pk}$  に一致させるように学習を行う。この操作は全ての故障出力を教師信号に一致させることに通じ, したがってニューラルネットワークの耐故障性が保証される。本アルゴリズムの評価関数は次のようになる。

$$EME = \sum_p \sum_k (t_{pk} - o_{pk}^{f_{max}})^2$$

評価関数の極小化には通常の誤差逆伝搬アルゴリズムを用いればよい。

#### 3.2 最悪故障の推定

最悪故障を引き起こす断線を見つけるためには、全ての結合枝を断線させ、故障出力を求め、それらを比較検討するという煩雑な操作が必要となる。しかし、2値出力システムにおいては、シグモイド関数の単調増加性を利用して、高速に故障出力を推定することが可能である [1]。耐最悪故障化学習アルゴリズムを効率的に動かすためには、最悪故障の高速推定は不可欠のものと言える。

中間層-出力層間の単一断線故障を仮定した場合、最悪故障を推定するアルゴリズムは以下ようになる。

各学習反復ごと、各パターン  $p$  毎に以下を行う。

- 出力層の各ニューロン  $k$  に対して、

$$\begin{cases} t_{pk} = 1 & \text{ならば} & \max_j \{w_{jk} \cdot h_{pj}\} \\ t_{pk} = 0 & \text{ならば} & \min_j \{w_{jk} \cdot h_{pj}\} \end{cases}$$

を満たす結合枝  $l_{jk}$  を求める。ここで各  $k$  に対して  $J$  は異なり得る。この断線がパターン  $p$  に対する最悪故障の候補  $f_{pk}^{max}$  となる。

2.  $\{f_{pk}^{max} | i = 1, 2, \dots, n\}$  の中から

$$\begin{cases} t_{pk} = 1 & \text{ならば} & \min_k \{u_{pk}^{f_{pk}^{max}}\} \\ t_{pk} = 0 & \text{ならば} & \max_k \{u_{pk}^{f_{pk}^{max}}\} \end{cases}$$

を満たす結合枝  $l_{jk}$  を求める。この断線がパターン  $p$  に対する最悪故障  $f_p^{max}$  となる。

## 4 耐最悪故障化学習の拡張

3.2節で示した最悪故障推定アルゴリズムは、中間層—出力層間の単一断線を想定したものである。本稿ではこれを拡張し、3層ニューラルネットワークの全結合の単一断線を仮定した場合における最悪故障を推定するアルゴリズムを構築する。

まず単一断線故障の起こる部位に基づき、全故障集合を次の3つの場合に分類して説明する。

1. 故障なしの場合：

任意の故障により、出力が教師信号に近づく方向に変位するならば、故障なしの状態  $o_{pk}$  が教師信号から最も異なる出力を呈することになる。

2. 中間層—出力層間に断線故障が起こった場合：

3.2節で示されるように、 $l_{jk}$  の断線 ( $f_{jk}$ ) が起こった場合、パターン  $p$  の入力に対する出力層第  $k$  ニューロンの出力は次式となる。

$$o_{pk}^{f_{jk}} = \text{sigm}(u_{pk}^{f_{jk}}) = \text{sigm}(u_{pk} - w_{jk} \cdot h_{pj}) \quad (1)$$

3. 入力層—中間層間に断線故障が起こった場合：

$L_{ij}$  の断線 ( $F_{jk}$ ) が起こった場合、パターン  $p$  に対する中間層第  $j$  ニューロンの出力は次式となる。

$$h_{pj}^{F_{jk}} = \text{sigm}(s_{pj}^{F_{jk}}) = \text{sigm}(s_{pj} - v_{ij} \cdot e_{pi}) \quad (2)$$

ここで、 $\{F_{ij} | i = 1, 2, \dots, n\}$  の中で  $h_{pj}$  が正の方向に最も誤る状態を引き起こす故障を  $F_{ij}^+$  とし、その場合の  $h_{pj}^{F_{ij}}$  を  $h_{pj}^{F_{ij}^+}$  と記す。一方、 $h_{pj}$  が負の方向に最も誤る状態を引き起こす故障を  $F_{ij}^-$  とし、その場合の  $h_{pj}^{F_{ij}}$  を  $h_{pj}^{F_{ij}^-}$  と記す。ここで明らかに

$$h_{pj}^{F_{ij}^-} \leq h_{pj} \leq h_{pj}^{F_{ij}^+} \quad (3)$$

である。いかなる  $x$  においても  $0 < \text{sigm}(x) < 1$  であるので式 (3) は次式となる。

$$0 < h_{pj}^{F_{ij}^-} \leq h_{pj} \leq h_{pj}^{F_{ij}^+} < 1 \quad (4)$$

出力層第  $k$  ニューロンは、中間層第  $j$  ニューロンが  $h_{pj}^{F_{ij}^+}$  に誤ることによって

$$o_{pk}^{F_{ij}^+} = \text{sigm}(u_{pk}^{F_{ij}^+}) = \text{sigm}(u_{pk} - w_{jk}(h_{pj} - h_{pj}^{F_{ij}^+})) \quad (5)$$

$h_{pj}^{F_{ij}^-}$  に誤ることによって

$$o_{pk}^{F_{ij}^-} = \text{sigm}(u_{pk}^{F_{ij}^-}) = \text{sigm}(u_{pk} - w_{jk}(h_{pj} - h_{pj}^{F_{ij}^-})) \quad (6)$$

の故障出力を呈する。

上記1～3の場合を統合し、最悪故障を引き起こす断線を見つける。式 (4) を変形することにより

$$h_{pj} - h_{pj}^{F_{ij}^+} \leq 0 \leq h_{pj} - h_{pj}^{F_{ij}^-} < h_{pj} \quad (7)$$

を得るので

$$\begin{cases} w_{jk} \geq 0 \text{ の場合} \\ u_{pk} - w_{jk} \cdot h_{pj} < u_{pk} - w_{jk}(h_{pj} - h_{pj}^{F_{ij}^-}) \leq u_{pk} \\ \leq u_{pk} - w_{jk}(h_{pj} - h_{pj}^{F_{ij}^+}) \\ w_{jk} < 0 \text{ の場合} \\ u_{pk} - w_{jk}(h_{pj} - h_{pj}^{F_{ij}^+}) \leq u_{pk} \\ \leq u_{pk} - w_{jk}(h_{pj} - h_{pj}^{F_{ij}^-}) < u_{pk} - w_{jk} \cdot h_{pj} \end{cases} \quad (8)$$

が成立する。シグモイド関数が単調増加であること、及び、式 (1)、式 (5)、式 (6) を用いることにより、式 (8) は

$$\begin{cases} w_{jk} \geq 0 \text{ の場合} & o_{pk}^{f_{jk}} < o_{pk}^{F_{ij}^-} \leq o_{pk} \leq o_{pk}^{F_{ij}^+} \\ w_{jk} < 0 \text{ の場合} & o_{pk}^{F_{ij}^+} \leq o_{pk} \leq o_{pk}^{F_{ij}^-} < o_{pk}^{f_{jk}} \end{cases} \quad (9)$$

となる。したがって最悪故障は

$$\max\{|o_{pk} - o_{pk}^{F_{ij}^+}|, |o_{pk} - o_{pk}^{f_{jk}}|\} \quad (10)$$

を満たす断線となることが分かる。

## 5 まとめ

故障モデルを3層ニューラルネットワークの全結合の単一断線故障に拡張し、最悪故障推定アルゴリズムを改良した。今後は実用性の検討に移る予定である。

## 参考文献

- [1] 西垣, 都筑, 曾我: ニューラルネットワークの耐最悪故障化学習, 電子情報通信学会論文誌, D-I(採録決定)