

## ニューラルネットを用いた事故検知方法の有効性の検討

信州大学工学部 正会員 奥谷 巍  
 信州大学大学院 鹿野 俊生  
 信州大学工学部 ○中本 嘉実

### 1.はじめに

近年、脳の高度な情報処理をモデル化した人工的神経回路網（ニューラルネット）の研究が活発に行われている。特に、バックプロパゲーション（以下、BPと略記）法は、外部環境からの入力信号を学習し、その情報を記憶、自己組織化するというニューロンの情報処理システムを実現したものであり、様々な分野でそのパターン認識能力および特徴抽出能力を生かした応用研究の報告がなされている。

本研究では、ニューラルネットのパターン認識能力を利用し、交通事故の検知方法の一手法としてBP法を適用し、シミュレーションより得られる交通变量のパターンを学習、ニューラルネットワークの自己組織化が終了した時点で、その完成したニューラルネットワークにより事故検知のテストを行う。その時の標定率により、BP法の事故検知に対する有効性を検討する。

### 2.ニューラルネットワークモデル

ニューロンの人工的なモデル（ユニット）は、図-1に示されるような、多入力1出力の素子が用いられる。また、ニューラルネットワークは、このユニットが互いにシナプス結合により接続したもので、この結合の度合いを結合荷重と呼ぶ。ニューラルネットワークの自己組織化は、結合荷重の強弱の変化によって担われており、結合荷重は学習により変化する。

BP法は、図-2のような入力層、中間層、出力層からなる階層型ニューラルネットに対する教師付き学習方法で、このニューラルネットの入出力関係は、次のように表せる。

$$O_k = f(z_k) \quad (1)$$

$$z_k = \sum_j w_{kj} H_j + \gamma_k \quad (2)$$

$$H_j = f(y_j) \quad (3)$$

$$y_j = \sum_i u_{ji} x_i + \theta_j \quad (4)$$

ここで、 $O_k$ :出力層ユニットkの出力、 $z_k$ :出力層へのユニットkの入力、 $w_{kj}$ :中間層ユニットjから出力層ユニットkへの結合荷重、 $\gamma_k$ :出力層ユニットkのオフセット、 $H_j$ :中間層ユニットjの出力、 $y_j$ :中間層ユニットjへの入力、 $u_{ji}$ :入力層ユニットiから中間層ユニットjへの結合荷重、 $x_i$ :入力層ユニットiの出力、 $\theta_j$ :中間層ユニットjのオフセット。

また、応答関数 $f(x)$ としては、図-3のような出力が $[0, 1]$ の範囲内である単調非減少のシグモイド関数が用いられ、次式で表される。

$$f(x) = 1 / (1 + \exp(-x)) \quad (5)$$

学習、すなわち結合荷重の更新は出力層における誤差を最小化するよう入力層に向かい行われ、学習による結合荷重の修正量 $\Delta u_{ji}$ 、 $\Delta w_{kj}$ は次式で与えられる

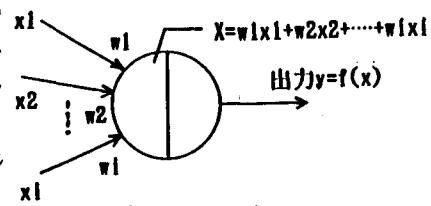


図-1 ユニット

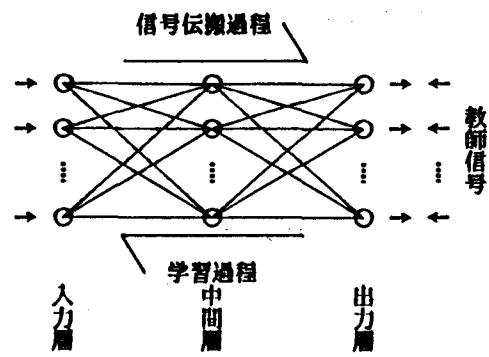


図-2 3層ニューラルネット

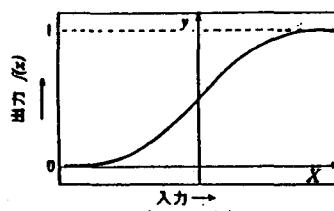


図-3 シグモイド関数

$$\Delta u_{j,i} = \alpha \left( \sum_k \delta_k w_{k,j} \right) f'(y_j) x_i \quad (6)$$

$$\Delta w_{k,j} = \alpha \delta_k h_j \quad (7)$$

ここで、

$$f'(y_j) = h_j(1-h_j) \quad (8)$$

$$\delta_k = (t_k - o_k) o_k (1-o_k) \quad (9)$$

### 3. 事故検知への適用

今回の事故検知では、先述した従来の3層型ニューラルネットワークの他に、2つの変形型ニューラルネットワークを適用した。1つは、図-4(a) のように第1、第2のニューラルネットワークから構成されるもので (NN2) 、入力信号に交通量と速度を用いた場合の NN2 の構造を次に示す。まず、第1のニューラルネットで、交通量データのみから特徴抽出し事故区間の検知を行う。そして、第2のニューラルネットで、第1のニューラルネットでの出力値と、速度のデータを入力信号とし、学習することにより最終的な事故区間の標定結果を得る。もう1つの変形ニューラルネットは、NN2 の拡張型で、図-4(b) のように第1、第2、第3のニューラルネットから構成されており (NN3) NN2 同様、入力信号に交通量と速度データを用いる場合の NN3 の構造を次に示す。NN3 では、第1、第2のニューラルネットで、それぞれ交通量、速度のデータから事故区間を標定、第3のニューラルネットで、第1、第2での標定と、速度のデータより最終的結果を得る。ここで、NN2 での第1のニューラルネットと、NN3 での第1、2のニューラルネットは、あらかじめ単独に学習させ、完成しているニューラルネットを用い、最終的な事故区間を標定する段階での学習は行わない。

具体的な計算例では、事故検知対象区間を5区間とし、各区間にニューラルネットの出力ニューロンを対応させる(図-5)。入力信号は、上流と下流における交通変量データを用い、その特徴を抽出し、事故の起きた区間、事故の起きていた時間を検知しようとするものである。すなわち、対象区間内のいかなる事故に対しても、正しく標定するニューラルネットを完成させるために、全事故パターンのシミュレーションデータをニューラルネットに学習させる。また、実際の交通流に対応させるため、シミュレーション計算値と実際の交通流とのずれも考慮したパターンも学習させることとした。入力信号に対するずれは次式に従うものとする。

$$x_i = x_i (1 + \varepsilon R_i) \quad (10)$$

ここで、 $R_i : [0, 1]$  の範囲内での乱数、 $\varepsilon$  : ずれの割合を表す係数。

なお本研究において、学習は事故の発生した区間、時間帯を正しく標定できた割合(標定率)が一定となるまで行うものとし学習終了後の未使用データによる検知テスト結果から、その有効性を検討する。

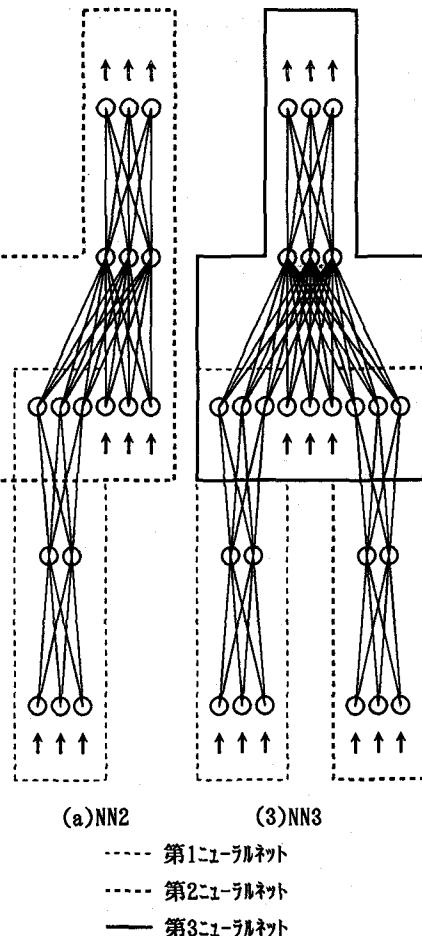


図-4 変形型ニューラルネット

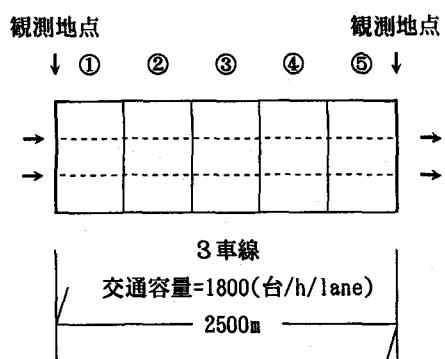


図-5 対象区間