

北大工、朝日新聞・○渋川 勝久、五十嵐 悟、相原 浩史

### 1. はじめに

人間の脳をモデル化し、脳の思考過程を解明して工学的に応用する為に様々なニューラルネットが考え出されている。その一部はかなり実用の段階にまで到達しているが、これまで多入力多出力のモデル化がほとんどである。しかし、人間の思考は多種の情報を入力としても結果としての出力（判断）には二者択一的な面があり、しかもある段階では曖昧（AかBかはっきりしない中間的）な判断をし、次の段階でもBかAかBかというように二者択一的でありしかも曖昧な判断をカスケードに順次行い最後に全体を見比べて決断を下している場合が多分にあると考える。即ち、ある事物を認識したり識別するときに、その対象だけでの判断には曖昧さを残しておき、最終的には前後関係など全体を見て最もそれらしいと思われるところで決断していると考えられる。

本報告では、欠陥の識別にこのような二者択一的でしかも曖昧な判断をも採り入れるためにニューラルネットをカスケードに接続したモデル（識別システム）を提案する。また、実際の欠陥として木材表面の欠点を対象として、このモデルによる欠点の識別実験を行い提案した方法の有用性を確かめる。

### 2. 欠陥識別システム

全体の構成を図1に示す。ニューラルネットをカスケードに接続し、それぞれのニューラルネットが専門的に或一種類の欠陥のみについて識別判断する。各段階でのニューラルネットの出力の値が予め設定された閾値を越えた場合にその欠陥であるとし、そうでなければ次のニューラルネットで識別検査される。最終的にどの欠陥にも識別されなかつた場合には、そのまま識別不可能として‘不明’とすることも考えられるが、ここではそれらを再検討することとしそれぞの段階に於けるニューラルネットの出力値（[0, 1] の実数値）を各ニューラルネットで識別されるべき欠陥への帰属度とみなして、帰属度が最大の値を出した段階における欠陥であると判断した。前述したようにニューラルネットとして多種多様なもの

が考案提出されているが、本研究では、各欠陥を識別するニューラルネットとして教師信号付き学習可能な多階層構造ニューラルネットの代表として知られているバックプロパゲーションモデルを採用した。ニューラルネットの中間層のユニット数、学習定数および出力値を判断する閾値は予備実験を行ってその識別成績によって決めた。中間層と出力層それぞれには隠れユニットが設けられているが、これらはユニット数に数えない。

### 3. 実験方法

前節で提案した方法を用いて木材の表面欠点を識別する。各ニューラルネットへの入力としては種々考えられるが、木材の欠点を対象とした今回は木材を撮影した画像の濃度に関する4種の特徴量を入力とした。木材表面の1画面を $8 \times 8 = 64$ 領域に分け、各領域に於ける濃度の平均値・分散・歪度・尖度を求めてそれを入力とし、領域ごとに欠点の種類を識別する。即ち、ニューラルネットは4入力1出力とし、中間層は1層とした。入出力関数は、入力層では入力値をそのまま出す線形関数とし中間層と出力層ではシグモイド関数とした。データは学習用に600（うち欠点無し189、節212、その他199）、識別実験用に659（欠点無し395、節60、その他204）に分けて用いた。シナプスウェイトの初期値は-0.5～0.5の値をランダムに与え、学習モードはPattern Grain Modeを行った。実際の木材表面には多種多様な欠点があるが、本研究ではデータ数の関係上、

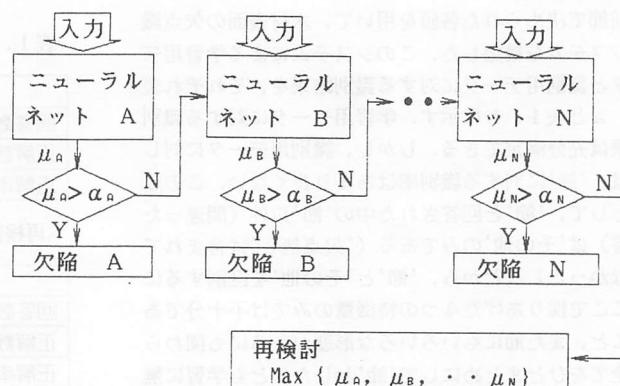


図1. 識別システム構成図

'欠点無し', '節', '節以外の欠点(その他)'の3種類とした。また、識別順序は実際の欠点として数の多いものから'欠点無し', '節', 'その他'の順に調べることとした。

まず、学習定数を決める。中間層のユニット数を3として学習定数 $\alpha$ (ウェイト補正のための比例項の係数)と $\beta$ (慣性項の係数)の組合せを色々変えて学習用のデータを用いて学習させ、同じデータに対する優秀な識別率の組合せ( $\alpha=0.15$ ,  $\beta=90$ )を採用した。なお、学習回数は、50回ではやや不足、300回でほぼ飽和し始め1000回で充分に飽和したと思われたので、学習回数は1000回を標準とした。

次に、学習定数は前述の値に採って中間層のユニット数を1~3の範囲(入力4, 出力1を考慮して)で変え、同じように学習用のデータを用いて学習させ同じデータに対する識別率が比較的よい場合を選んだ結果中間層のユニット数は2と決まった。なお、ここまで実験(学習定数と中間層のユニット数の決定)は、'欠点無し'についてのみ注目して行った。

さらに、それぞれの段階のニューラルネットの出力値をみてその段階で識別されるべき欠点であるか否かを決める閾値を求めなければならない。閾値を大きく採ればそれだけ間違いが少なくなるが、反面そこで識別される数が減る。本研究では、最終的に'不明'とせず再検討を前提にしてあるので、ある程度数が減っても正解率を高く探ることとした。前述の2つの実験と同様に学習用データを用いて、閾値を変えて各欠点に対する正解率を調べてみた結果、欠点無し、節、その他それぞれのニューラルネットの出力値に対する閾値は、0.93, 0.97, 0.99となった。

#### 4. 実験結果

前節で決められた各値を用いて、木材表面の欠点識別システムを構築した。このシステムによる学習用データと識別用データに対する識別結果を、それぞれ表1.aと表1.bに示す。学習用データに対する識別結果は充分満足できる。しかし、識別用データに対しては、'節'に対する識別率はあまり良くない。この原因として、'節'と回答された中の'節'以外(間違った回答)は'その他'のみである('欠点無し'は含まれていなかった)ことから、'節'と'その他'を区別するにはここで採りあげた4つの特徴量のみでは不十分であること、また節にもいろいろな形態が在るにも関わらず全てをひとまとめにして'節'としたことも学習に無理がかかり、結局識別率が良くならなかったのではないかと考えられる。また、データを学習用と識別用と

にランダムに分けて用いたが、データの絶対量がそれほど多くなかったためデータの区分けに偏りが生じていたことも考えられる。一方、同じ識別用データに対して'欠点無し'と'その他'については優秀な識別率が得られている。このことを考慮すれば、上に述べたようなデータ数や欠点の種類の分け方などを改善することにより、本報で提案した欠陥の識別方法は有用であると思われる。

なお、本報では'欠陥'識別システムとして提案したが、この識別システムは〇〇識別システムと考えいろいろな事物を識別するために用いることができる。

#### 5. おわりに

人間が行っている識別過程は、多分に二者択一的な判断過程をカスケードに接続したものであると考えて、そのモデルを提案した。また、そのモデルを使用して実際の木材表面の欠点識別を行い、提案したモデルの有用性を示した。

表1. a 学習用データに対する識別結果

	欠点無	節	その他	再検討へ
回答数	128	130	47	295
正解数	127	119	45	
正解率	0.99	0.92	0.96	

#### 再検討

	欠点無	節	その他
回答数	42	85	168
正解数	35	29	57
正解率	0.83	0.34	0.34

表1. b 識別用データに対する識別結果

	欠点無	節	その他	再検討へ
回答数	280	126	44	209
正解数	280	40	38	
正解率	1.00	0.32	0.86	

#### 再検討

	欠点無	節	その他
回答数	51	114	44
正解数	51	12	24
正解率	1.00	0.11	0.55

$$\text{正解率} = \text{正解数} / \text{回答数}$$