



# ニューラルネットワークによる材料組織のパターン認識

遠嶋 雅徳\*・鈴木 俊夫\*\*・小林 史典\*\*\*・南 雄介\*\*\*\*

Pattern Recognition of Microstructures using Neural Networks  
Masanori TOJIMA, Toshio SUZUKI, Fuminori KOBAYASHI and Yusuke MINAMI

**Synopsis :** A pattern recognition system for microstructures using neural networks has been developed. The system consists of two neural networks, a feature extraction network and a classification network. The feature extraction network classifies local area patterns of an input image into reference vectors and generates the histogram of the classified vectors. The classification network learns the histogram data of sample images using the back-propagation algorithm and classifies the microstructures into pre-determined categories. The system shows high performance in the classification of graphite shapes in cast irons and of grain sizes of stainless steels.

**Key words :** neural network ; pattern recognition ; microstructure ; graphite shape ; grain size.

## 1. 緒言

コンピュータによる画像処理技術は、欠陥や亀裂の測定、破面解析、腐食面計測や結晶粒解析などに成果を収めてきた<sup>1)</sup>。また、材料組織画像処理を目的とした汎用システムも開発されてきている<sup>2)</sup>。しかし、画像処理の目的の多くは材料組織の定量的計測であり、組織の識別、着目領域の抽出といった基本的判断は専門家が行っている。実際、材料組織の識別などには概念的判断が必要であり、判断機能を持つ画像認識システムの開発が考えられる。しかし、材料組織に関する知識や判断は複雑かつ曖昧で、言語表現が困難である。また、経験や判断に個人差があるため、一般的な取扱いが困難である。これらの理由から、組織解析を目的とした画像処理エキスパートシステムの開発はさほど進んでいない。一方、脳の情報処理機構をモデルとしたニューラルネットワークは、パターン認識能力に優れ<sup>3)</sup>、手書き文字認識などの有効性が報告されている<sup>4)</sup>。したがって、ニューラルネットワークを材料組織解析に適用することにより、組織の識別や評価を行うことが可能である。ニューラルネットワークは、以下に述べる点から材料組織の識別に有効と考えられる。

一般に材料組織を計測するためには、対象領域の切り出しや画像修復といった前処理が必要となるが、その手順や基準は対象や画質に依存し、一般化が難しい。しかし、材料組織の識別に限定すれば、対象となる基地、粒子の区別や前処理は必ずしも必要でなく、組織画像全域のパターン

認識を行えば十分である。そして、その機能は組織画像をニューラルネットワークに学習させることにより実現できる。

著者らはそのような観点からニューラルネットワークを用いて、球状黒鉛と片状黒鉛の識別を行った<sup>5)</sup>。その結果、入力画像の局所的特徴を抽出し、これを学習することにより黒鉛形状が判別できた。しかし、このシステムでは、材料組織の識別で重要な最適観察倍率と入力領域の決定を作業者が決定しなければならなかった。実際の顕微鏡操作では組織識別に最適な観察倍率や領域を試行錯誤的に選び出しており、その最適値は対象に依存して一定でない。したがって、観察倍率や観察領域の決定をいかに最適化するかは、材料組織認識システムを構築する上で重要な点であり、前報の方式には限界があった。

本研究では、これを改良し、特定の対象に限定されない材料組織パターン認識システム構築の結果を報告する。ここでは、最適観察倍率、観察領域の問題を分解能の異なる複数の画像を入力データとすることにより克服した。すなわち、十分な領域を持つ組織画像から順次モザイク化処理して作成した複数の入力画像とし、それらの最適重み、すなわち最適な倍率を学習により決定させる。この方法により、粒子と基地の区別や前処理を省略できる。さらに、ノイズや情報の欠落にも影響を受けない識別が可能となる。

以下に本システムの構成と識別動作、鉄黒鉛形状判別とステンレス鋼結晶粒度判定の試験によって検討したシステムの有効性を述べる。

平成5年12月3日受付 平成6年4月8日受理 (Received on Dec. 3, 1993; Accepted on Apr. 8, 1994)

\* 東京大学大学院生（現：コマツ（株））(Graduate Student, The University of Tokyo, now Komatsu Ltd.)

\*\* 東京大学工学部 (Faculty of Engineering, The University of Tokyo, 7-3-1 Hongo Bunkyo-ku Tokyo 113)

\*\*\* 九州工業大学情報工学部 (Faculty of Computer Science and System Engineering, Kyushu Institute of Technology)

\*\*\*\* NKK総合材料研究所 (Materials & Processing Research Center, NKK Corporation)

## 2. システムの構成

本システムは入力画像の局所的な特徴量をデータとしている。これは、入力画像の画素を入力層ニューロンに対応させる方法では、形状や位置が不定である材料組織に適用できないからである。システムは、入力画像の局所的特徴量を抽出する特徴抽出ネットワークとその出力を統合し判断する分類ネットワークの2つから構成されている。

特徴抽出ネットワークは、1つの画像からモザイク化処理を繰り返し作成した分解能の異なる3種類の画像について、局所的特徴量のヒストグラムを生成する。分類ネットワークはこのヒストグラムを入力データとした学習を行い、組織を分類する。Fig. 1に本システムの模式図を示す。

### 2・1 特徴抽出ネットワーク

特徴抽出ネットワークは、入力層は9個、出力層は25個のニューロンからなる2層階層型ニューラルネットワークで、入力画像の局所的特徴を一種のベクトル量化法により抽出、分類する。すなわち、多次元入力ベクトル( $3 \times 3$ 画素の局所パターン)と最適整合する参照ベクトルを求め、距離の近い一群の入力ベクトルを一つの参照ベクトルで代表させる。ここで、距離はあらかじめ用意された参照ベクトルと入力ベクトルの内積として定義する。

なお、出力層の数を25とする特別な根拠はない。出力層の数は参照ベクトル(特徴抽出ニューロンの荷重ベクトル)の数に対応する。この参照ベクトルは複数のサンプル画像の局所領域パターン( $3 \times 3$ 画素)を自己組織化アルゴリズムにしたがって学習、形成させるが、この学習計算時間はニューロン数の増加につれ飛躍的に増加する。このため出力層を増やすことには限度があること、また、予備的な検討の結果では出力層数25以上ではあまり判別性能に向上が見られなかったことから、ここでは現実的な値として25を選んだ。

特徴抽出ネットワークの具体的な操作は次のようになる。

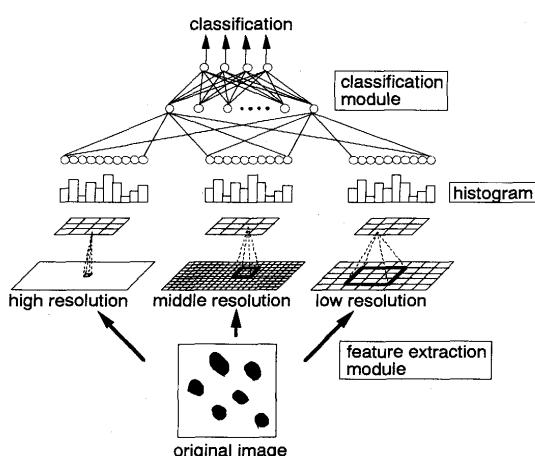


Fig. 1. Structure of the system.

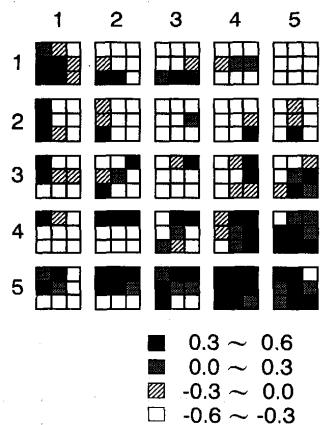


Fig. 2. Reference vectors used in the feature extraction network.

各モザイク画像について全ての領域を被うように $3 \times 3$ 画素領域を切りとり、入力ベクトルとする。そして、参照ベクトルに対して最適整合する入力ベクトルの数を算出し、ヒストグラムを作成する。これにより、入力画像の特徴量として3つのヒストグラムが生成される。なお、ヒストグラムは最大値を1として規格化する。ここで参照ベクトルは出力層のニューロンの荷重ベクトルに相当し、その数は25とした。入力ベクトルは $3 \times 3$ 画素領域の局所パターンである。したがって入力ベクトル、参照ベクトルとも9次元のベクトルで、ノルムが1になるように規格化した。なお、本研究では、球状黒鉛、片状黒鉛の顕微鏡組織画像を自己組織化アルゴリズムにより学習し、形成されたパターンを参照ベクトルとして用いた<sup>5)</sup>。Fig. 2にこの参照ベクトルを示す。

### 2・2 分類ネットワーク

分類ネットワークは3層の階層型ニューラルネットワークで、各層間のニューロンは全結合とし層内結合はない。また、各ニューロンは入力の総和に対してシグモイド関数を作用させた値を出力する。ネットワークの学習にはバックプロパゲーション法<sup>6)</sup>を用いた。

入力層には特徴抽出ネットワークで生成されたヒストグラムデータを入力する。したがって入力層のニューロン数はヒストグラムの要素数と等しく75となる。中間層のニューロン数は20とした。出力層のニューロン数は分類すべきカテゴリの種類に等しく、鋳鉄黒鉛形状の判別では4、結晶粒度の判定では10である。なお、学習後の判別実験では、入力データに対し出力ニューロンの出力最大のものを分類結果とした。

## 3. 識別動作

本システムがどのように組織を識別するかを正確に把握することは難しい。これは、ニューラルネットワークが多対1非線形写像であり、因子分析などの手法が有効でない

ためである。そこで、黒鉛形状判別を例として、特徴抽出ニューロン数、参照ベクトル、モザイク画像の組み合わせ数を変化させた場合の正答率変化を求め、本システムの判別機能を予備的に検討した。

### 3・1 参照ベクトル

Fig. 3 は、216の学習サンプルを用い、特徴抽出ニューロンの数を4から25まで変化させた場合の黒鉛形状判別正答率を示す。この黒鉛形状判別の正答率は、Fig. 5 に示した4種類の黒鉛形状の各々54枚のサンプル画像に対する正答率の合計から算出した。また、ここでは参照ベクトルによるシステムの判別性能への影響を見るために、2つの方法で作製した参照ベクトルを用いた。1つは前述のように自己組織化アルゴリズムにより学習、形成したもの、もう1つは参照ベクトルの各要素の値(1から-1までの値)を乱数として与えたものである。図中の□印は自己組織化アルゴリズムにより学習・形成した参照ベクトルを用いた場合の結果を、●印は比較としてベクトル要素を乱数により決定した参照ベクトルを用いた場合の結果を示す。いずれの場合もニューロン数の増加につれ正答率は上昇していく。

自己組織化による参照ベクトルを用いた場合、ニューロン数が4の場合でも正答率は85%を越える。これは黒鉛粒子の判別では内部とエッジの区別が基本的であり、その比率から判別が可能であることと理解できる。しかし、乱数による参照ベクトルを用いた場合の正答率は明らかに低い。したがって、参照ベクトルは対象の特徴を反映したものであること、すなわち、この例では局所的特徴を粒子の内部、エッジに正確に区別できることが必要となる。しかし、参照ベクトルによる正答率の差はニューロン数の増加につれ減少し、ニューロン数25ではその差は見られなくなる。したがって、黒鉛形状判別のように比較的単純な識別では、ニューロン数あるいは参照ベクトルが十分多ければシステムの識別能力は参照ベクトルにさほど依存せず、むしろ後述の分解能による局所特微量の相対変化がより重要となっていることが分かる。なお、このような点は後述のようにサンプル数を変化させた場合の黒鉛形状に対応した出力ニ

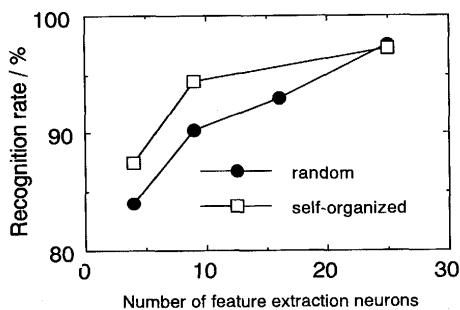


Fig. 3. Recognition rate for graphite shapes vs. number of feature extraction neurons. Symbols of ● and □ show the results with self-organized reference vectors and randomly generated ones.

ューロンの出力の推移を見ていくことにより推定できる。

### 3・2 分解能

次に、本システムの識別機能に重要な分解能の効果を見る。Fig. 4 は3種の入力モザイク画像のうち、各分解能について1画像を用いた場合(図中a, b, c)3つのうちの2つを組み合わせて用いた場合(d, e), 3つを用いた場合(f)の正答率を示す。また、2つの棒グラフはそれぞれ、25の特徴抽出ニューロンを用いた場合、4つのニューロンを用いた場合の結果である。図からも明らかなように、1つのモザイク画像だけを用いる場合には、判別結果は画像の分解能に大きく依存し、最適な観察倍率が重要であることが分かる。しかし、単独としては有効でない分解能の画像も、これらを組み合わせていくことによりシステムの判別能力は著しく向上する。この傾向は特徴抽出ニューロン数が少ない場合により顕著である。

以上の結果は、組織画像の識別にも局所的特微量分布とともに分解能の違いによる分布の相対変化量が判別に基本的な重要性を持つことを示している。

我々が顕微鏡により組織を観察する場合には、組織のおおまかな形状や色調、粒子の位置などをるために低倍率の観察を行い、その後により詳細な組織形状や内部組織を高倍率で観察する。すなわち、異なる倍率での複数の観察結果を総合して組織を判断している。そのような意味で、本システムには我々の顕微鏡観察操作と同様の機能が含まれていることになる。なお、システム構築の過程で行った予備試験では、各モザイク画像ヒストグラムデータに対応した入力層のそれぞれに分割して中間層と部分結合した場合の正答率は、入力層-中間層を全結合した場合に比べ低かった。この点に関する詳細な検討は行っていないが、局所特微量とその分解能による変化量の情報を総合して判別が行われていることの根拠と考えられる。

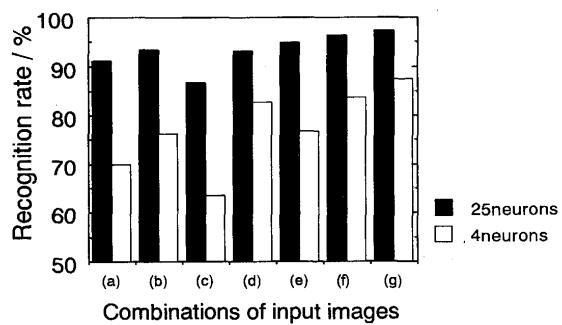


Fig. 4. Change in recognition rate with different combinations of input images. Shaded and open columns show the results with 25 and 4 feature extraction neurons, respectively.  
(a) 128×128 pixels (b) 64×64 pixels (c) 32×32 pixels (d) 128×128 pixels and 64×64 pixels (e) 128×128 pixels and 32×32 pixels (f) 64×64 pixels and 32×32 pixels (g) 128×128 pixels, 64×64 pixels and 32×32 pixels

## 4. システムの性能評価

### 4・1 試料

本研究では、粒子形状分類の例として鋳鉄の黒鉛粒子形状を、基地、テクスチャ分類の例としてステンレス鋼の結晶粒度判定を取り上げた。入力画像は顕微鏡組織写真をCCDカメラで撮影した256階調のモノクロ画像で、原画像の画素数は鋳鉄試料の場合で $256 \times 256$ 画素、結晶粒度判定のステンレス鋼試料では $512 \times 400$ 画素である。この原画像を $2 \times 2$ 画素、 $4 \times 4$ 画素、 $8 \times 8$ 画素の領域で平均化した3種類の2値化モザイク画像とした。この3種類の画像が特徴抽出

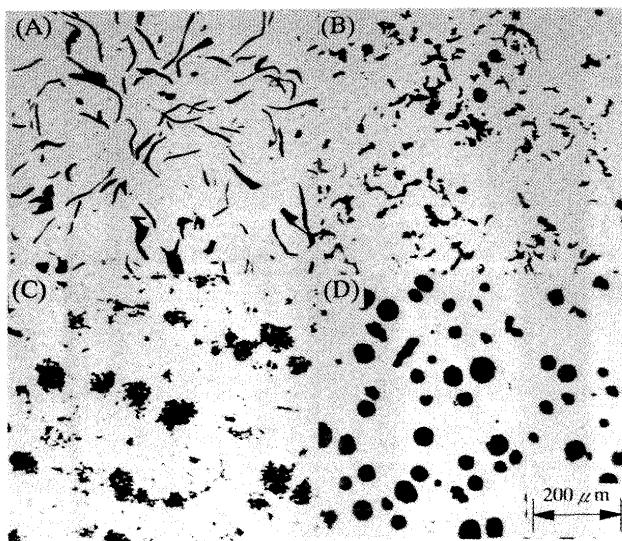


Fig. 5. Original images of graphite shapes.  
(A) flake graphite (B) CV graphite (C) semi-nodular graphite (D) nodular graphite

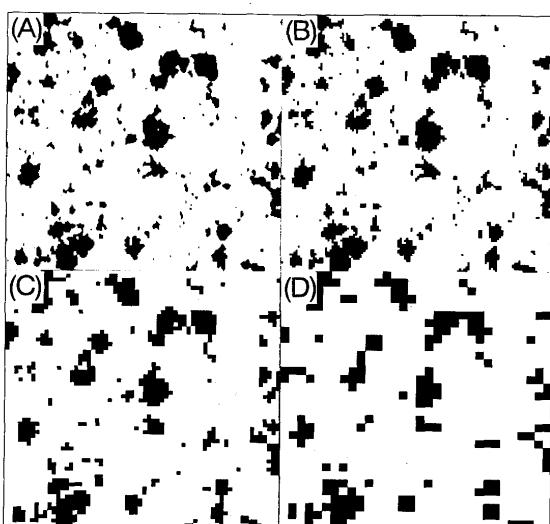


Fig. 6. Binary mosaic images of semi-nodular graphite.  
(A) 256 by 256 pixels (original image) (B) 128 by 128 pixels  
(C) 64 by 64 pixels (D) 32 by 32 pixels

ネットワークへの入力となる。

### 4・1・1 鋳鉄試料

片状黒鉛鋳鉄、CV黒鉛鋳鉄、塊状黒鉛鋳鉄、球状黒鉛鋳鉄の4種類の鋳鉄を試料とした。Fig. 5に4種類の鋳鉄の原画像を、Fig. 6に塊状黒鉛の場合のモザイク化処理した画像の例を示す。この例では図の(B), (C), (D)がシステムへの入力となる。この平均化とモザイク処理は原画像から分解能の異なる画像を取り出すことに対応する。また、これら3つの入力に対する分類ネットワークの最適の重みが学習により既に決定されているので、システムは最適分解能の入力画像を主たる基準として黒鉛形状の判別を行うことになる。

### 4・1・2 ステンレス鋼試料

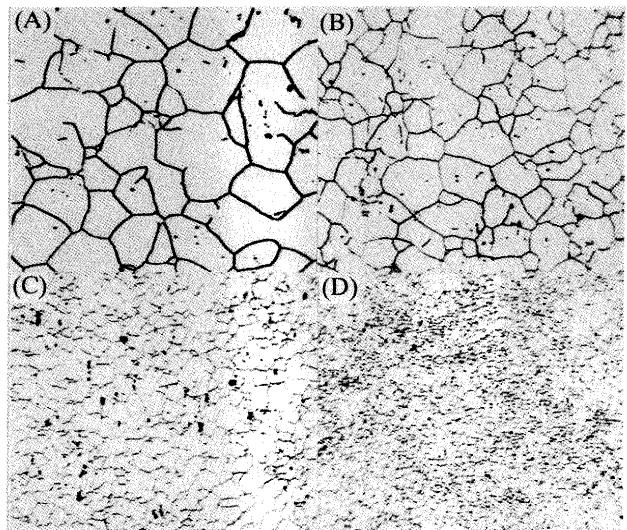


Fig. 7. Original images of samples with different grain size number.  
(A) 2.5 (B) 4.5 (C) 7.0 (D) 9.5

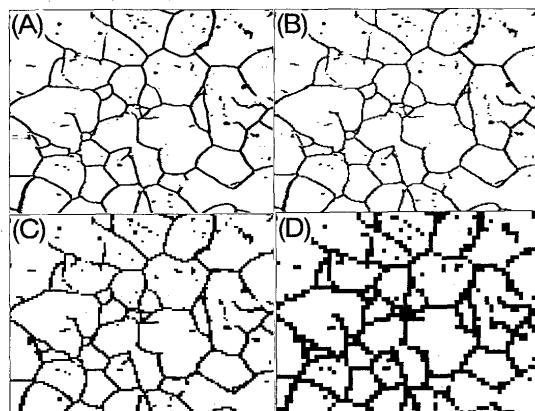


Fig. 8. Binary mosaic images of a sample with grain size number 2.5.  
(A) 512 by 400 pixels (original image) (B) 256 by 200 pixels  
(C) 128 by 100 pixels (D) 64 by 50 pixels

用いた試料は2種のステンレス鋼で、これらを顕微鏡写真倍率を変えた写真を用意した。具体的には、いくつかのステンレス鋼顕微鏡撮影フィルムを所定の異なる倍率で焼き付け、相対粒度の異なる写真を作製した。この写真のサイズは、経験者が通常業務として粒度判定を行う際に用いる顕微鏡投影画面の大きさとほぼ同程度に設定した。これらの写真を経験者が目視によりASTM粒度に分類した。試料写真の分類された粒度は、2.5, 3.0, 4.0, 4.5, 5.0, 6.5, 7.0, 7.5, 9.0, 9.5の10種類であり、この粒度が教師データとなる。ただし、ここでは顕微鏡写真をさらにCCDカメラで撮影しているので、以下に述べる粒度は、相対的値となる。Fig. 7に粒度2.5, 4.5, 7.0, 9.5の結晶粒の原画像を、また、Fig. 8にモザイク画像の例を示すが、(B), (C), (D)が入力画像に対応する。

#### 4・2 黒鉛形状の判別結果

各黒鉛形状のサンプル数を等しくし、学習サンプル総数を8から216まで変化させて学習した場合の正答率の変化を求めた。なお、判別テストには288の未学習サンプルを用いた。Fig. 9に学習サンプル数による正答率の変化を示す。学習サンプル数の増加につれ正答率は急速に増加し、サンプル数216で、正答率は97.2%となる。ただ、サンプル数が100程度で正答率はほぼ95%となり、その後はあまり増加しない。出力ニューロンの出力の大きさは、いわば判別の確信度を示し、これを基準に判別の学習の過程を見ることがで

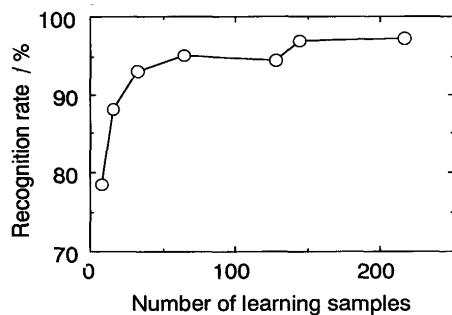


Fig. 9. Recognition rate for graphite shapes vs. the number of learning samples.

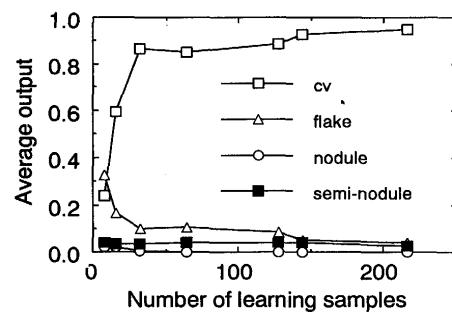


Fig. 10. Variation of average output of each output neuron with number of learning samples for CV samples.

Table 1. Result of the grain size classification.

		output									
		2.5	3.0	4.0	4.5	5.0	6.5	7.0	7.5	9.0	9.5
Input	2.5	9	7	-	-	-	-	-	-	-	
	3.0	6	2	-	-	-	-	-	-	-	
	4.0	-	-	4	5	2	-	1	-	-	
	4.5	1	-	8	5	6	-	-	-	-	
	5.0	-	-	1	1	9	-	-	-	-	
	6.5	-	-	-	-	-	2	3	5	-	
	7.0	-	-	-	-	-	2	12	6	-	
	7.5	-	-	-	-	-	1	1	9	-	
	9.0	-	-	-	-	-	-	-	3	5	
	9.5	-	-	-	-	-	-	-	2	18	

きる。Fig.10にCV黒鉛の試験画像に対して学習サンプル数を変化させた場合の黒鉛形状に対応した出力ニューロン出力値の変化を示す。この例では、サンプル数が少ない場合にも、システムはCV黒鉛と塊状あるいは球状黒鉛を容易に区別している。しかし、形状の類似した片状黒鉛との区別の精度を上げるには、さらに多くのサンプルが必要になる。このように学習サンプルが少ないとときは、CV黒鉛と片状黒鉛の区別、球状黒鉛と塊状黒鉛の区別が十分でないが、学習サンプル数の増加につれその判別が改善されていく。ただ、これらの中には人間でも判別し難いものも含まれており、判別結果は妥当と考えられる。また、十分な正答率が得られる画像サンプル数が一試料につき30程度であることは、実際の顕微鏡観察を考えれば十分に実用的な範囲と言える。

#### 4・3 結晶粒度の判定結果

結晶粒度データの学習には162の画像サンプルを、テストには98の未学習画像サンプルを用いた。判定結果をTable 1に示す。各サンプルの粒度そのものを正しく判定しているものは少なく、黒鉛形状判別のような高い正答率は得られない。しかし、画像サンプルの粒度を2.5~3.0, 4.0~5.0, 6.5~7.5, 9.0~9.5の4つのグループと分類した場合には、入力グループと出力グループはほぼ一致し、4つのグループを基準とした場合の正答率は98.5%となる。経験者が粒度を判定する場合にも粒度0.5の程度の個人差があると言われている。この点を考慮すれば、上記の判定結果は現段階で十分満足のいくものである。

## 5. 結言

ニューラルネットワークを用いて組織画像をパターン学習し、組織識別を行うシステムを構築した。このシステムは粒子と基地を同列のものとして扱うことが出来るほか、多少の画像ノイズや情報の欠落にもさほど影響を受けない識別が可能である。このような性能は、自己組織化した参照ベクトルにより分類した画像の局所的特徴量分布と、異なる分解能の画像における局所的特徴量分布の相対変化を組み合わせて学習することにより達成されている。

本システムを用いて、粒子画像分類の例として鋳鉄の黒鉛形状判別、領域パターン分類として結晶粒度判定を行ったところ、黒鉛形状判別では95%以上の正答率を、また、結晶粒度判定では粒度0.5の許容範囲で98%以上の正答率を得ることが出来た。したがって、本システムを発展させることにより、より複雑な組織の識別も可能であると考えられる。

最後に本研究経費の一部は文部省科学研究補助金(一般研究(C)課題番号04650626)によるものであることを記し、

謝意を表する。

## 文 献

- 1) 金属材料の新しい画像解析技術 (日本鉄鋼協会編), (1989)
- 2) 宮島明, 古君修, 柳澤満, 斎藤文夫: 川鉄技報, 21 (1989), p.362
- 3) 中野馨監修: ニューロコンピュータの基礎, (1990), [コロナ社]
- 4) 福島邦彦: 電子通信学会論文誌, J62-A (1979), p.658
- 5) 遠嶋雅徳, 府川和弘, 鈴木俊夫: 鑄物, 65 (1993), p.8
- 6) D.E.Rumelhart, J.L.McClelland and PDP Research Group: Parallel distributed processing, (1986), [MIT Press], 甘利俊一監訳: PDPモデル認知科学とニューロン回路網の探索, (1989), [産業図書]