

ニューラルネットワークを用いたトライボセンサシステムの開発\*  
(セラミック圧電体を用いたトライボセンサ)長 南 征 二\*<sup>1</sup>, 江 鐘 偉\*<sup>1</sup>  
森 和 男\*<sup>2</sup>, 宗 片 陽 一\*<sup>3</sup>Development of Tribosensor System Using Neural Networks  
(Tribosensor Using Piezoelectric Ceramics)Seiji CHONAN, Zhongwei JIANG,  
Kazuo MORI and Yoichi MUNEKATA

This paper presents a study on the development of a new tribosensor that has the sensitivity of human skin. The sensor is basically a piezoceramic AE sensor. It is placed and moved on the material to be identified. The voltage signal from the sensor is first stored in digital memory for a fixed period of time. It is then analyzed to obtain the maximum signal strength, the total number of concaves and convexes of the signal, and the number of crossings with the line of mean signal strength. Each set of the parameters obtained is compared with the training set of data in the neural networks, and the material of the measured sample is fixed. Experimental results obtained show that the present sensor system identifies the material 85% correctly for 120 samples of 6 different materials.

**Key Words:** Tactile Sensor, Tribosensor, Rubbing, Data Analysis, Neural Network

## 1. 緒言

人間の手の持つ感覚に触覚があるが、触覚センサと呼ばれるものはすでに開発されロボットマニピュレータなどにも導入されている。しかしながら従来の触覚センサは、単なる圧力センサであるかあるいはマトリクス状に配置した圧力センサから構成されるいわゆる分布型触覚センサであり、対象物に触れた時の圧力や対象物の形状を把握することは可能であるが対象物表面の他の情報を検知することは困難である<sup>[1, 2]</sup>。人間の手はこれ以外に“なでて”対象物の硬さ、表面状態、材質などを知る触覚機能も有している。例えば、指を紙や布、ビニール等に押し付けるだけでは材質を同定することは一般に困難であったが、指をさらに少し動かすことによってそれらが何であるかを判断することが可能となる。センサが対象物と接触した際にその表面粗さやすべり易さなどを感知することができれば対象物の性質を知りそれに応じて動作が制御できるよう

になるため、マニピュレータ等の機能は飛躍的に高められ、柔軟な操作を行うことが可能となる。

人間の指の感覚を模したセンサのひとつとしてHoweら<sup>[3]</sup>は、ひも状PVDF圧電フィルムを埋めた円筒状ゴムをロボットフィンガに巻きつけた形状の接触センサを作成し、そのセンサで対象物表面をなでた際に得られる動的応力の理論解析と実験を行っている。平石ら<sup>[4]</sup>は透明板と突起を有する弾性シート、およびCCDカメラを組み合わせるにより2次元的な触覚パターンを得る光導波板型の分布型触覚センサを開発した。しかしながらこれらのセンサは応力や圧力を感知するのみであり、対象物表面の情報検知や材質認識は行っていない。




図1 トライボセンサシステムの概略図

\* 原稿受付 1994年7月13日。

\*<sup>1</sup> 正員, 東北大学工学部 (〒980 仙台市青葉区荒巻字青葉)。

\*<sup>2</sup> 正員, 機械技術研究所 (〒305 つくば市並木1-2)。

\*<sup>3</sup> 東北大学大学院。

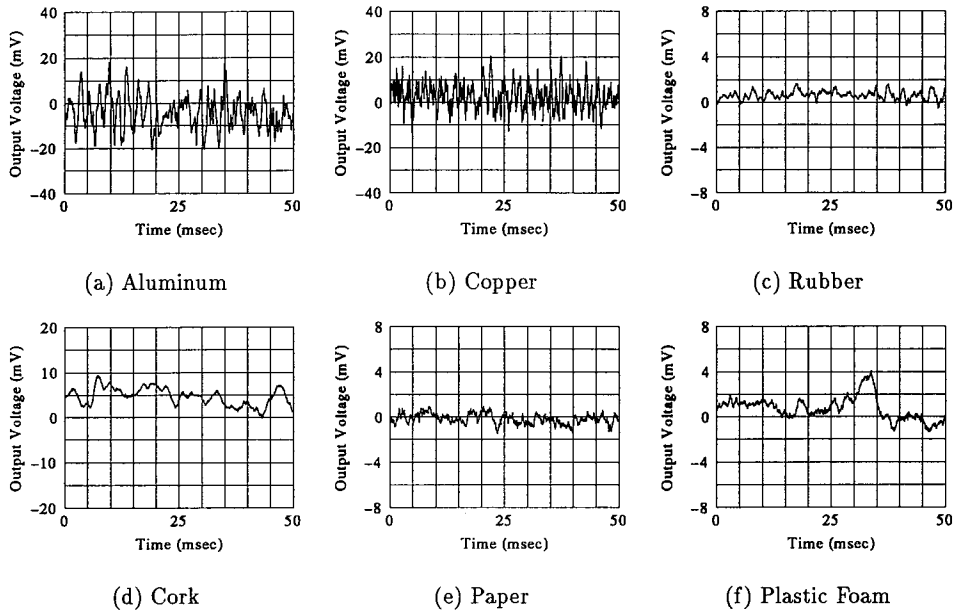


図2 セラミック圧電センサの出力信号

本研究は以上の点に鑑み、人間の手のような触覚機能を有する新しい複合触覚センサ「トライボセンサ」<sup>[5]</sup>システムの開発を試みるものである。具体的には、セラミック圧電素子をトライボセンサに改良し、センサで種々の材質の表面をなで、発生する機械的トライボロジー現象を電気的に測定し、データに含まれる対象面情報を信号処理しニューラルネットワークを用いて対象物の材質を同定するものである。さらにニューラルネットワーク認識システムへの入力データを如何に与えるかについて検討を加え、新しい信号分析・分類方法を提案する。

## 2. トライボセンサシステムおよび実験方法

### 2.1 セラミック圧電トライボセンサ

圧電素子には応力や歪みを加えると電圧を生じるセンサ機能と、電圧を加えると応力や歪みを発生させるアクチュエータ機能がある。特に圧電素子は応力や歪み等の高速変化に敏感に反応するため、現在衝撃振動センサやAEセンサなどに広く使用されている。また、セラミック圧電素子は硬く高感度なため、対象物表面の微小凹凸と衝突するときに生ずる振動や音を感知する能力に優れている。このことに鑑み本研究はセラミック圧電素子を触覚センサとして使用、対象物表面をなでることによって発生する機械的なトライボロジー情報を電気的に測定し対象物の材質を同定することを

試みる。圧電センサとしては市販のAEセンサ(エヌエフ回路設計ブロックAE-900S-WB)の接触部にステンレス鋼の探子をつけて改良したものを使用した。本センサはPZT(ジルコン酸チタン酸鉛磁器)を使用しており、フラット周波数特性を持ちかつ雑音を小さく抑えるよう調整されている。

### 2.2 トライボセンサシステム

図1にトライボセンサシステムの概略を示す。装置は試料表面の状態を測定するセンサ、センサ出力を記憶するデジタルストレージオシロスコープ、オシロスコープよりGP-IB経由で送られるデータの処理を行うコンピュータより構成されている。

試料表面のトライボロジー情報はセンサを手で把持しできるだけ一定の速度と力で試料表面を移動させることにより測定した。また、センサ出力に対して余分なデータを付加したりデータの一部を削除することのないよう、センサはプリアンプを使用せず高精度のデジタルストレージオシロスコープと直結した。得られたデータは量子化ビット数8ビット、4000点のデジタル信号としてGP-IBを経由でパーソナルコンピュータに送られ、信号処理が行われる。

### 2.3 測定試料

測定試料は、金属材料、非金属材料、表面がなめらかな材質、粗い材質など性質の異なるものを各種取りそろえる意味でアルミニウム板、銅板、天然ゴム、コ

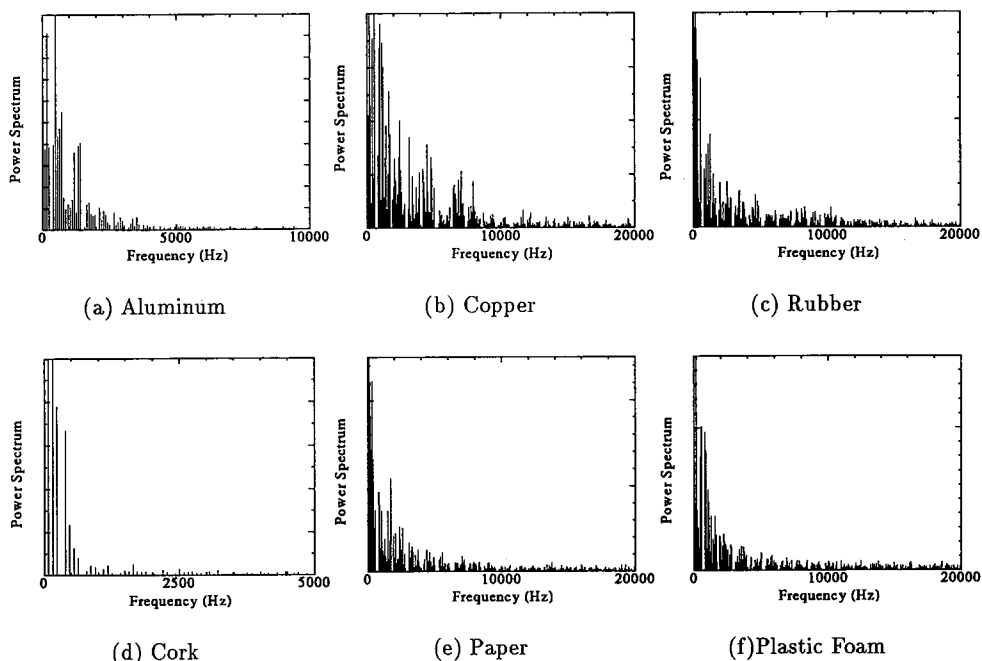


図3 FFTによる信号処理結果

ルク板、上質紙、発泡スチロールの6種類を使用した。図2に各材質の表面を圧電セラミックセンサでなでることによって得られたデータの一例を示す。横軸は時間、縦軸はセンサの出力電圧を表す。なお、測定に際しては全ての材質に対してサンプリング周期を0.0125 msecと一定とした。測定データに見られる特徴を上げると、センサ出力は金属材料であるアルミニウム板や銅板では大きく、表面の粗いコルク板や発泡スチロールでは中程度であり、表面のなめらかな天然ゴムや上質紙では小さくなっていることが分かる。

### 3. 信号処理および材質認識

セラミック圧電センサが対象物を擦ったときに発生する信号は対象物の材質、表面状態によって異なるが、センサの押付け強さ、擦る速度等にもかなり影響されることが分かっている。従って、本研究では信号処理や識別にニューラルネットワークを適用し学習による識別方法を考える。一方、本セラミック圧電センサを用いて測定したデータは8ビットの4000点のデジタル信号としてコンピュータに転送されるので、測定データをそのままニューラルネットワークに入力・分析するには不適當である。そこで本研究では測定したデータに対して、各材質や表面荒さの特徴を如何に抽出しニューラルネットワークに与えるかについていくつかの信号処理方法を検討した。なお、ニューラルネット

ワークは階層型ネットワークであり、学習方式は外部からあらかじめ学習のための正解を与える教師付き学習を、また学習アルゴリズムはバックプロパゲーション(誤差逆伝播法)を採用した。

#### 3.1 FFT解析法

測定データの特徴を抽出するための信号処理用手法としては確率密度関数や、時系列データの周波数特性を用いるFFT解析法が一般的である<sup>[6]</sup>。ここでは始めにFFT解析によりデータ処理を行ってみる。測定データの周波数特性を調べるため、始めにC言語を用いてFFT処理用プログラムを作成した。自作ソフトによる、各試料の測定データに対して行ったFFT処理結果の一例を図3に示す。アルミニウム板とコルク板についてはそれぞれ0~10 kHzと0~5 kHz区間で、ほかの材質については0~20 kHz区間での処理結果を示す。これらの結果を見ると、コルク板をなでた時の信号は低い周波数域に集中しているのに対し、銅板では高い周波数域まで分布していることがわかる。また、パワースペクトルの最大値は金属材料であるアルミニウム板や銅板では500 Hz近傍にあるのに対し、他の材質では100~200 Hz域に見られる。このように金属材料と非金属材料ではデータの分布に若干の差が見られるが、アルミニウム板と銅板および非金属材料間で違いを見分けられるほど結果に差はなく、FFT処理




図4 パルス計数分類法の概念

の結果からニューラルネットワーク用学習用データを抽出することは困難であると言える。

### 3.2 パルス計数分析法

図4にパルス計数分析法の概念を示す。これはセンサによって得られたデータを基準電圧と交差するランダムなパルスの連続と考え、パルスの幅と高さでそれぞれを分類するものである。すなわち交差パルス幅は、データの最大値と最小値の中間値である基準電圧線と交差する近隣2点間の時間とし、得られたパルスの集合を  $2^n + 1 \sim 2^{n+1}$ , ( $n = 1 \sim 8$ ) の等比時間域に分類した。また、パルス高さに関しては得られた一連のデータの最大値と最小値の差を8等分し分類した。このように、各パルス幅、パルス高さに対応するパルス数を求め、それらを  $8 \times 8$  のマトリックスに配置する。さらにニューラルネットワークにおいてパターン認識の形でデータを与えるため、各昇目のパルス数をそれらの中の最大パルス数で正規化した。

次に、このようにして得られた  $8 \times 8$  次元のパターンをニューラルネットワークの学習用データとして使用し、材質認識を行う。ニューラルネットワークの細胞数は入力層で64、中間層で20、出力層で6とした。センサで対象物表面をなでることによって得られた各材質10個のデータのうち任意の5個を学習用データとして使い、出力層細胞の出力と正解値との誤差が十分に小さくなるまで最大5000回の学習を行わせた。その後、学習済みのニューラルネットワークを用いて、学習用データで使ったデータとは別の各材質5個のデータに対して材質認識を行った。図5に(a)アルミニウム板、(b)銅板、(c)天然ゴム、(d)コルク板、(e)上質紙、(f)発泡スチロールを擦った場合のデータに対して得られた結果の一例を示す。同図の縦軸は正解率を示し、1に近いほどその材質である可能性が高く、0に近いほどその材質である可能性の低いことを示している。なお、以下では認識の結果が0.5を越え、かつそ

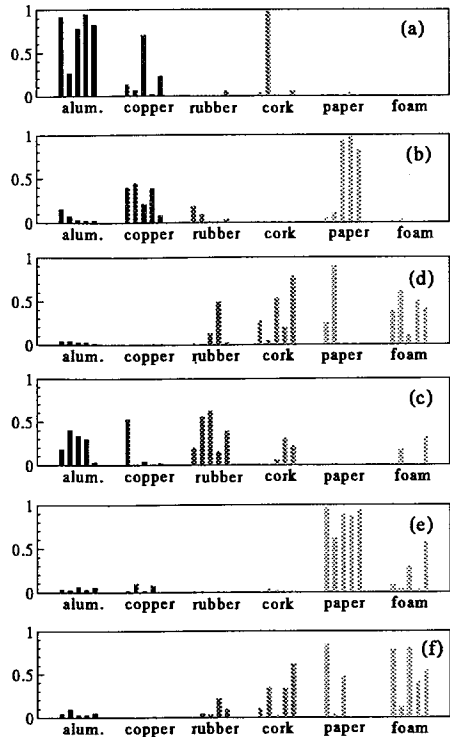


図5 パルス計数分析法を用いて認識した結果の一例;(a)アルミニウム板、(b)銅板、(c)天然ゴム、(d)コルク板、(e)上質紙、(f)発泡スチロール。

の他の材質よりも値が大きい場合は正しく認識されたものとし、いずれの材質の認識結果も0.5を越えない場合は認識できなかったと判別したものとする。

本例の場合、(e)上質紙はすべて正しく認識され、(a)アルミニウム板は銅板やコルク板と誤って認識されている場合もあるが、ほぼ正しく認識されているといえる。それに対して(b)銅板は誤って上質紙と認識されがちであること、その他の材質も本方法によっては正確に判断することが困難であることが分かる。本データ処理の場合、合計30の試料のうち14試料しか正しく認識されておらず、7つの試料の材質は特定できなかった。同様な材質認識をさらに各材質につき15個の試料に対して行った。前後合計120の試料を識別させた結果を表1に示す。表よりアルミニウム板、銅板、コルク板はおよそ60%以上の正解率を得られているに対し、上質紙や発泡スチロールではわずか40%の正解率しか得られておらず、総合して120の試料のうち正しく認識されたのは64であり、正解率は全体で53%であった。

表1 パルス計数分析法の正解数と正解率

Material	Number of recognition	(Percentage)
Aluminum	13	( 65 % )
Copper	12	( 60 % )
Rubber	10	( 50 % )
Cork	12	( 60 % )
Paper	8	( 40 % )
Foam	9	( 45 % )
Total	64	( 53 % )




図6 パルス総数・最大振幅・交差パルス数分類法の概念

### 3.3 パルス総数・最大振幅・交差パルス数による分類

人間が手で物体をなでる場合、すべりの程度や刺激の頻度、あるいは刺激の強さから表面荒さや材質の識別を行っていると考えられる。このことに鑑み以下新しいデータ処理分類方法を考えてみる。すなわち、刺激の強さを表わす指標として信号の最大振幅をとり、信号上に表れる凹凸を刺激パルスの頻度と考えパルス総数と定義する。さらに、信号の最大値と最小値の中間値を基準電圧として、信号が基準電圧と交差する点の数を交差パルスの数と考えすべりの頻度を表す指標とする。この三つのパラメータの概念を図6に示す。本方法を用いて処理されたデータの3次元表示の一例を図7に示す。図より、測定データは各材質毎にほぼまとまって分布していることが観測される。

このように得られたパルス最大振幅、パルス総数、交差パルス数のパターンをニューラルネットワークの学習用データとして使用し材質認識を行った。ニューラルネットワークの細胞数は入力層で3、中間層で10、出力層で6とした。3.2節のパルス計数分析法で処理結果を学習認識させた場合と同様、始めにセンサで対象物表面をなでることによって得られた各材質10個のデー




図7 パルス総数・最大振幅・交差パルス数による各材質の測定データの3次元分布

タうちの5個を学習用データとして用い、出力層細胞の出力と正解値との誤差が十分小さくなるまで最大10000回の学習を行った。その後、学習用データで使ったデータとは別の各材質5個のデータに対して材質認識を行った。得られた結果の一例を図8に示す。本例の場合、(a)アルミニウム板、(b)銅板および(c)天然ゴムは全て正しく認識されている。また、(d)コルク板は発泡スチロールと誤って認識されたケース、(e)上質紙は発泡スチロールと認識されたケースもあるが、5個のデータに対して認識を行った結果を平均して判断するとすべての試料について材質は特定できていると言える。同様な材質認識を各材質につきさらに15個の試料を追加し、合計120の試料に対して行った場合の結果を表2に示す。表中の値は各材質につき20のデータを識別させたうちどれだけの数が正解したかを示す。これより、パルス総数、最大振幅、交差パルス数を用いて処理を行った場合はどの材質であっても正解数に大きな違いはなく、全体で85%という非常に高い精度で正しく認識できたことがわかる。

### 3.4 学習用データについて

本節では、パルス総数・最大振幅・交差パルス数分類法を用いてニューラルネットワークによる認識を行わせる際の、学習用データの選び方について考察する。

#### 3.4.1 学習用データの数

上述の結果では学習用データの数を5としたが、ここでは学習用データの数が結果に及ぼす影響を調べる。学習用データの数を1, 2, 3, 5, 30と変化させた場合の判別結果をまとめて表3に示す。表中の値は各材質につき5つの試料を識別させた場合にいくつ正しく認識したかを示している。これを見ると、学習用データが一つしかない場合には結果が良くないのはもちろん

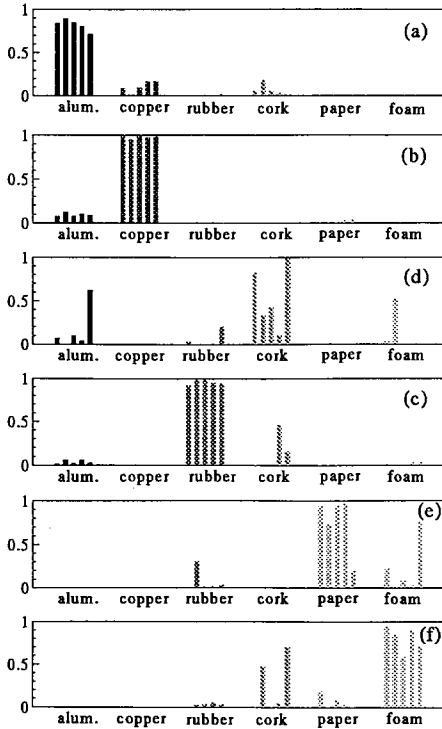


図8 パルス総数・最大振幅・交差パルス数分類法を用いて認識した結果の一例

表2 パルス総数・最大振幅・交差パルス数分類による認識結果の正解数と正解率

Material	Number of recognition (Percentage)
Aluminum	18 ( 90 % )
Copper	16 ( 80 % )
Rubber	20 ( 100 % )
Cork	13 ( 65 % )
Ppaper	18 ( 90 % )
Foam	17 ( 85 % )
Total	102 ( 85 % )

のこと、学習用データが多すぎても認識結果が悪いことが分かる。教師信号が増えれば学習効果は上がるはずであるがこのような結果になるのは学習用データとして使用した信号にもある程度のばらつきがあり、学習用データが増えるとそのばらつきによって各材質の学習用データに違いが見られなくなることが原因の一つであると思われる。実際に学習用データの元で学習を行う場合、学習用データが多すぎると出力層細胞の

表3 学習用データの数の違いによる認識結果の違い

Material	Number of training signals				
	1	2	3	5	30
Aluminum	4	2	5	5	0
Copper	5	3	5	5	5
Rubber	1	5	5	5	5
Cork	1	4	3	2	5
Paper	4	4	4	4	0
Foam	5	5	5	5	3
Total	20	23	27	26	18

表4 パルス総数・最大振幅・交差パルス数分類による認識結果の正解数と正解率

Material	Number of recognition (Percentage)	
	□ Group	● Group
Aluminum	9 ( 90 % )	9 ( 90 % )
Copper	8 ( 80 % )	8 ( 80 % )
Rubber	10 ( 50 % )	9 ( 90 % )
Cork	8 ( 80 % )	6 ( 60 % )
Paper	9 ( 90 % )	9 ( 90 % )
Foam	8 ( 80 % )	9 ( 90 % )
Total	52 ( 87 % )	50 ( 83 % )

出力と正解値との誤差がなかなか小さくならない。これより、学習用データは各材質の特徴的なデータを示す数個があれば十分であることが言える。

### 3.4.2 測定条件と材質によるデータのばらつき

実測データは、測定条件(測定日)および材質の違いによってばらつきが生ずるが、それらが認識結果に如何に影響するかを次に調べてみる。ここで、異なる測定条件下で得られた測定データの集合をそれぞれ□、●で示し、アルミニウム板、銅板、コルク板の3種類の材質につき (i) 縦軸に交差パルス数、横軸にパルス最大振幅、(ii) 縦軸にパルス総数、横軸にパルス最大振幅、さらに (iii) 縦軸にパルス総数、横軸に縦軸に交差パルス数を取った場合の分布を図9に示す。図より、アルミニウム板の信号は測定日によってデータ分布にかなり違いが見られる一方、コルク板はわりあい安定して分布していること、銅板は測定日に関係なくデータにばらつきのあることがわかる。

上記の測定データのばらつきに対する有効な学習方法を見出すための学習用データの選び方について考え

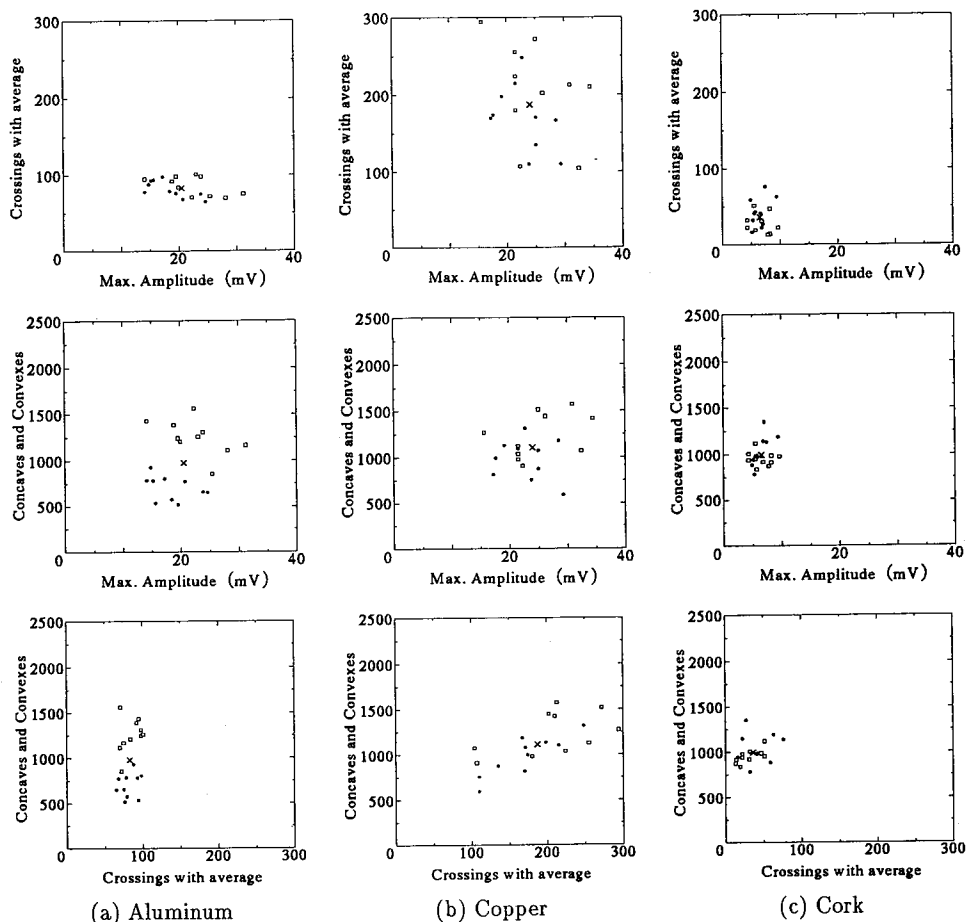


図9 測定条件と材質によるデータのばらつき

表5 パルス総数・最大振幅・交差パルス数分類による認識結果の正解数と正解率

Material	Number of recognition	(Percentage)
Aluminum	16	( 80 % )
Copper	15	( 75 % )
Rubber	18	( 90 % )
Cork	16	( 80 % )
Paper	18	( 90 % )
Foam	11	( 55 % )
Total	94	( 78 % )

る。今まで任意の5個のデータを学習用データとして用いてきたが、これとは別にパルス総数、最大振幅、交差パルス数の各平均値を学習用データとして使用する

ことを検討する。まず、□と●の二つのグループ各10個のデータについてそれぞれ平均値を求め、それらを□と●の各グループの学習用データとしてニューラルネットワークに与え、各グループ10個の試料データについて認識を行わせた。その結果を表4に示す。各材質はほとんど8割以上の正解率が得られている。次にこれら20個のデータをまとめた平均値(図9中の×印)を学習用データにして用いた場合の結果を表5に示す。表より、測定日の異なる2グループのデータ間の偏差が大きいにもかかわらず、発泡スチロールを除けば各材質ほぼ75%以上の正確が得られていることがわかる。

比較のため、図9の□と●印で示した各10個のデータをさらに5個づつ■、□、●、○と4グループに分け、その中の■、□、●の3グループを個別に学習用データとして使用し、残りの○印グループのデータを試料データとして認識させて見た。結果を表6に示す。表を見る

と、学習用データが■や□の時にアルミニウム板の認識結果が悪く、学習用データが■の時に発泡スチロールの認識結果が悪くなっているが、これは学習用データと試料である○が離れて分布していることが原因である。逆にどのような学習用データでも良好な識別結果となっている銅板や天然ゴムでは、試料である○のそばに各学習用データが存在している。また、●印グループのデータを学習用データとして使用し、同一日に得られた○グループのデータを認識させるとかなり高い率で正解が得られることから本方法を用いる場合は、学習用データに用いる信号は試料となる信号と同じ条件下(日時)で測定する必要のあることがわかる。

以上より、加算平均を用いた学習用データの作成は学習時間の短縮や学習効率の向上に有効であると言える。

#### 4. 結言

種々の材質の表面を AE センサでなでることによって得られる信号をデータ処理し材質識別を行うニューラルネットワークの構築を試みた。得られた結果を要約すると以下ようになる。

1. センサで対象物表面をなでることによって得られた信号を処理することによって材質の識別が可能となる。
2. 信号処理法としてはパルス総数・最大振幅・交差パルス数による分類方法が有効であり、本方法を用いることで約 85 % 以上の材質の識別率を得ることができた。
3. 加算平均法を用いてパルス総数・最大振幅・交差パルス数の各平均値をニューラルネットワークの学習用データとして使用することでデータのばらつきがあっても十分高い率で正解を得ることができる。

最後に、本研究は平成 4～6 年度文部省科学研究費補助金(試験研究)の助成を受けて行われたことを記す。

表 6 データの測定条件による認識結果の違い

Material	Training set		
	■	□	●
Aluminum	0	0	5
Copper	5	5	5
Rubber	5	5	5
Cork	3	3	2
Paper	4	1	4
Foam	1	3	5
Total	18	17	26

#### 文 献

- (1) Joseph Jurczyk and Kenneth A. Loparo: Mathematical Transforms and Correlation Techniques for Object Recognition Using Tactile Data, IEEE Transactions on Robotics and Automation, 5, 3 (1989) 359-362.
- (2) 谷江 和雄: 解説 ロボットセンサの現状—機構を中心として—, 日本ロボット学会誌, 9, 7 (1991) 888-893.
- (3) Robert D. Howe and Mark R. Cutkosky: Dynamic Tactile Sensing: Perception of Fine Surface Features with Stress Rate Sensing, IEEE Transactions on Robotics and Automation, 9, 2 (1993) 140-151.
- (4) 平石 久人, 鈴木 夏夫, 金子 真, 谷江 和雄: 光導波板型の分布形触覚センサによる触知対象の輪郭形状抽出, 日本機械学会論文集(C編), 55, 516 (1989) 2091-2099.
- (5) 森 和男: トライボセンサ開発の展望, トライボロジスト, 37, 2 (1992) 91-95.
- (6) 松田 稔: デジタル信号処理入門(1984), 日刊工業新聞社.
- (7) 小池 慎一: C による科学技術計算(1987), CQ 出版社.
- (8) 小口 京吾, 丸山 久友, 横道 正和: AE 信号の特徴抽出装置の開発(マニュアル).