ニューロアルゴリズムによる複数接触センサでの材質識別

正員 李 徳勝 正員 信太 克規

(佐賀大学理工学部)

Discrimination of Material Properties by Touch Sensors based on The Neuro Algorithm

Desheng LI, Member Katsunori SHIDA, Member (Saga University)

This paper presents a study on discriminating material properties by touch sensors based on the neuro algorithm. The authors firstly point out that the multi-layer artificial neural network has good results for discriminating material properties. However, it exhausts tremendous time to get synapses by the standard learning method (SLM). To solve the problem, the authors propose an improved neuro algorithm with such process as dividing all samples into several groups, learning synapses within a group by the mean learning method (MLM), and learning synapses between groups by the simulated annealing.

In the paper, a numerical simulation is also described for verifying the proposed algorithm, from which good classification resulted for some materials such as iron, aluminum, copper, brass, rubber, wood and styrene foam. We think that the study is useful to developing an artificial skin tactile sensing system in the future.

キーワード : 接触センサ、材質識別、センサフュージョン、ニューラルネットワーク

1. まえがき

人間の皮膚はその表面から内部にかけて数種類の感覚受容器が多数存在している。特に手の指は優れた触覚機能を有していて、物体の温度、表面状態、硬さ、さらに材質などを識別する、いわゆる触覚センサといえる。その皮膚の感覚機能を工学的な手段で実現することができるならば、知能ロボットの触覚機能として大いに期待されるところである。

著者らは人工的な皮膚感覚の実現を最終的な研究目的として、皮膚のいくつかの感覚機能(温度感覚、硬さ感覚など)を工学的な手段で実現させると共に、皮膚自体は具備していない、物体の物理特性のいくつかの検出機能を加えることによって、物体の材質を複合的に認識することを可能とする接触センサを試作し、実際にいくつかの物体表面に接触させることによって、その物体の材質認識を試みてきた^{1,2)}。本研究は、センサから複合的に得られる情報データを融合して処理する、いわゆるセンサフュージョン^{3,4)}により、単一のセンサによる単一情報では得られない高度な情報獲得を期待し、そのためのインテリジェントな識別アルゴリズム確立を目指している。

筆者らはこれまで、物体の材質識別用複数接触センサの出力を融合して材質識別を行なうための、材質識別ファジィア

ルゴリズムを提案した⁵⁾。そこでは、ファジィ理論に基づいた試料の適合度関数を定義すると共に、試料間の最大相似度 α 及び境界値 γ の概念を提案し、これらの α 、 γ により試料の領域をパターンの的に表すことによる材質識別を試みた。その結果、数値実験において、試料としてのアルミニウム、銅、真鍮、鉄、黒ゴム、木材及び発泡スチロールに対して、センサ出力のばらつきが小さい($\leq 5\%$)場合には、識別正解率は90%以上となるが、センサ出力のばらつきが10%となると、すべての試料に対して、識別正解率は50%–60%にとどまり、識別のためには不十分であることが明らかになった。

そこで、本論文ではニューラルネットワーク理論に基づいて、多種類の触覚センサ又は接触センサの出力を階層構造のニューラルネットワークにおける入力とし、パターンの的に材質を識別するアルゴリズムを試みる。そこで、まず標準学習法(Standard Learning Method、ここではSLMと略記する)で学習を行い、その学習速度が非常に遅いことを問題とする。特に新しい種類の試料の場合、再学習を求める際に、その学習速度の遅さが常に問題となった。本論文はその問題点に対してのいくつかの改善法を提案する。さらに、その改善したアルゴリズムを用いることにより、SLM法より学習速度が大幅にスピードアップすることを数値計算により明らかにする。

図1 階層型ニューラルネットワーク

Fig. 1 Multi-layer artificial neural network

2. 標準学習法(SLM)の問題点

ニューラルネットワークは脳の有する情報処理のメカニズムを模倣する試みである。構造の面から見ると、階層構造型かあるいはすべてのニューロンが結合しあう相互結合型に分類しうる。ここでは、複数接触センサの出力をパター的な問題として処理しようとするゆえに、図1に示すような三層構造のニューラルネットワークを設定する。この場合、通常はバックプロパゲーション学習法(BP法⁶⁾)によりニューロン間の重みあるいはシナプスを学習する。

本研究では、従来のニューラルネットワークによる材質識別の能力を検証するために、まず標準学習法 SLM、すなわち付録の式(5)から式(9)までによるシナプスの学習を行う。その場合、入力ニューロン数は4とし、著者らが試作した二種類のセンサの四つの出力^{1,2,5)}に対応させる。但し、ここでは複数センサのスケールの違いによるトラブルを避けるため、 y_i/y_{iMax} を入力層ニューロンに入力する。中間層のニューロン数は7、出力でのニューロン数も7とし、材質識別実験用サンプルである銅、アルミ、真鍮、鉄、木材、黒ゴム及び発泡スチロールにそれぞれ対応させる。ここで、実験に用いるデータベースを表1に示す⁵⁾。ここで、 y_{iT} とは著者らが試作した三つのセンシング機能を有するセンサ¹⁾(薄い絶縁基板の表面に2本のラセン状の導線を蒸着した、単一構造にもかかわらず、その2本のラセンの四つの端子の組み合わせにより三つのセンシング機能が得られるもの)の温度センシング機能を用いた場合のセンサ出力である。ここでは、センサの温度が最初の温度から15℃だけ低下するまでにかかる時間をセンサの出力として記されている。 y_{iL} は同じセンサのインダクティブな機能によるセンサの出力であり、試料の導電率および透磁率に依存する。 y_{iC} は同じく、キャパシティブな機能によるセンサの出力で、おおむね試料の誘電率により定まるものである。一方、 y_{2P} は光センサ²⁾の出力であり、サンプルの表面光反射率に依存する。

表1 7種類のサンプルのデータベース
Table 1 Database of 7 kinds of samples

No.	j	1	2	3	4	5	6	7
i	sensor	Styrene	Rubber	Cu	Fe	Wood	Brass	Al
1	y_{iT} [s]	120	16	11	11	21	11	11
2	y_{iL} [mV]	10.75	10.75	1.489	13.55	10.75	2.198	1.695
3	y_{iC} [mV]	48.64	64.87	61.85	61.85	53.28	61.85	61.85
4	y_{2P} [V]	1.056	0.072	0.629	0.099	0.661	0.795	0.577

シナプスを学習した後、次にセンサの出力 y_i が、

$$y_i = Y_{ij}(1 + \mu \sigma_{ij}) \quad i=1,2,3,4, \quad j=1,2,\dots,7 \quad (1)$$

と表せる場合について、各サンプル毎に1000回のシミュレーションを行ない、どの程度の正確な識別がなされたか、その割合を求めた。なお、この場合の Y_{ij} は表1に示されるデータベース、すなわちサンプル j に対するセンサ i の出力、 μ はセンサ出力の誤差係数、 σ_{ij} は $[-1,1]$ 内でのそれぞれが互いに無関係の一樣分布乱数である。ここで、指定されたサンプルのデータを入力したとき、それに対応する出力層ニューロンの最大出力が0.5以上を満たす場合を識別が正しいとしている。シミュレーション結果を表2に示す。表2の結果から、従来のニューロアルゴリズムを用いる場合であっても、7種類の材質に対して、かなりの識別率が得られることが分かる。しかし、重み v_{ji} と w_{kj} を学習する際に、全学習誤差 e を小さくするまでには非常に多くの学習回数が必要であり、そのことは大きな問題となる。この場合の学習速度が非常に遅いという原因として以下のことが考えられる。

A) サンプルの中に材質が互いに近いもの、例えば、銅、アルミおよび真鍮が存在しているとき、センサの出力が互いに接近するゆえ、学習効率が著しく低下することが上げられる。このことは実験的に確かめられた。

B) 学習の後半での出力層ニューロンの出力 o_k は教師信号 d_k と接近している。それゆえ、付録に記した式(6)及び(7)から与えられる学習調整量 Δw_{kj} と調整量 Δv_{ji} が出力誤差 $d_k - o_k$ に比例することになり、そのことが学習の効率をかなり低下させることが分かる。

このような標準学習法で生じる問題点を避けるために次の改善法を提案する。

表2 標準学習法によるシミュレーション結果

Table 2 Simulation results by SLM

Simulation conditions: $I=4, J=7, K=7$, Temperature $T=1/2$
 $\eta=0.01$, Learning cycle $L_p=226600$, Time cost $t=9.85$ hours
 Learning error $e=0.030$, Computer: PC-9821-V10

No.	1	2	3	4	5	6	7
μ %	Styrene	Rubber	Cu	Fe	Wood	Brass	Al
2.5	100	100	100	100	100	100	100
5.0	100	100	99.4	100	100	100	93.4
7.5	100	99.2	94.4	99.7	100	100	81.2
10.0	98.6	95.0	87.7	96.0	100	99.4	72.8

3. 材質識別アルゴリズム

3.1 グループ分け

重み v_{ji} と w_{kj} を学習する際、もしサンプルの中に互いの材質が似ていて、センサの出力が近くなるものがなければ、学習の速度ははるかに速くなることが、実験結果から判明した。例えば、前述の7種類のサンプルの材質の中で、性質が近い銅、アルミおよび真鍮の中から、アルミと真鍮を取り除くことができれば、学習速度はきわめて速くなる。そこで、その現象をヒントに以下のような改善法を提案する。

- 1) 物理現象に基づいて、 m 種類のサンプルを K 組の材質の近いもののグループに分ける。その分け方の原則を図2に示す。ここで、 y_1, y_2 はそれぞれセンサ1、センサ2の出力である。また、図2(b)の $S_a, \dots, S_e$ は図2(a)の K 組のグループの内のグループ f 内の五つのサンプルを示している。
- 2) K 組のグループの重心 $M_1, M_2, \dots, M_f, \dots, M_K$ を計算する。その重心の座標をそのグループのデータベースとする。
- 3) グループ内の学習及びグループ間の学習を別々に行う。すなわち、別々のパーセプトロンを用いて学習を行う。その具体的な学習方法を次節で説明する。

本研究では、表1を参考にして、7種類のサンプルの材質を五つのグループに分ける。つまり、発泡スチロールだけのグループ、木材だけのグループ、ゴムだけのグループ、鉄だけのグループ、そして銅、アルミおよび真鍮のグループである。但し、ここでは銅のデータベースを銅、アルミおよび真鍮の三種類の金属の近似中心（ほかのグループのデータベースと遠く離れている）と設定する。

図2 K 個のグループに分けられた m 種類のサンプル
Fig. 2 m kinds of samples divided into K groups

3.2 グループ内の平均処理学習法(MLM)

グループ内の学習を行う際に、従来の標準法を用いて学習を試みたが、かなりの学習時間がかかることが分かった。それは、グループ内の試料の有する互いの値とセンサ出力として得られた生データが近いゆえに、なかなか収束しないことが考えられる。そこで、グループ内で次の平均処理学習法 (Mean Learning Method、ここでは MLM と略記する) を試みる。

- ① グループ内の全てのサンプルに対してセンサの出力が同じである項目を取り除く。
- ② 残ったセンサ出力の平均値を計算する。もしグループ

表3 MLM と SLM の数値結果比較

Table 3 Numerical result comparison of SLM with MLM
Simulation conditions: $l=2, J=5, K=3, T=1/5, \eta=0.01$, for SLM $L_p=39388$, for MLM $L_p=3698$, for SLM $t=607s$, for MLM $t=57s, e=0.030$

	Al		Cu		Brass	
$\mu\%$	SLM	MLM	SLM	MLM	SLM	MLM
5	84.6	100	99.3	100	84.0	100
7.5	75.4	94.3	91.4	97.0	69.4	100
10	68.8	86.5	84.4	89.8	57.7	100
12.5	64.1	80.0	78.5	83.4	47.9	100

f 内に m_f 種類のサンプルの場合に n_f 個のセンサ出力とすると、その平均値 $\bar{Y}_{fi}$ は次のように計算される。

$$\bar{Y}_{fi} = \sum_{j=1}^{m_f} Y_{ij} / m_f \quad i = 1, 2, \dots, n_f \quad (2)$$

- ③ センサの出力からその平均値を差し引いて、ニューラルネットワークの入力とする。

以上の処理の効果を確かめるために、銅、アルミおよび真鍮に対して、表1に示した y_{1L} および y_{2P} のデータを用いて数値計算を行った。その結果を表3に示す。この結果から、同一データにもかかわらず、MLM では、従来の SLM の 607 秒と比べて、学習速度が 10 倍以上も速い 57 秒となり、しかも識別率も全体にかなり上がっていることが分かる。

図3(a)は SLM を用いて分類した銅、アルミおよび真鍮の領域を示す。この図から、真鍮の領域は他に比べて狭い形で表された。さらに、しきい値付きの SLM により分類した結果は真鍮の領域はやや広がった形で得られた。一方、図3(b)には MLM により分類した領域を示す。この場合には、三領域の境界点 M はほぼデータベースの重心に位置し、最もバランスがよい形で得られた。

なお、MLM により学習する際、センサ出力がばらつきを含む、すなわち式(1)からのデータをニューロンの入力とする場合、その学習回数は図4(a)に示されている。この図は、同じ学習誤差 ($e=0.03$) に対して、センサ出力の誤差係数 μ と学習回数 L_p とは逆比例していることを示している。その理由は次のように考えられる。 μ が 0 のとき、学習誤差 e は図4(b)または図4(c)に示すように、学習するに従い単調減少するが、 μ が 0 ではない場合は、学習誤差 e が $\mu=0$ 曲線の下に振動しながら減少し、しかもその振動幅は μ に比例することが分かる。

3.3 グループ間の学習

グループ間の学習を行う際、2 節で指摘したように、SLM の場合、学習に伴って、学習の効率が悪くなるという問題がある。そこで、学習をしながら学習係数 η を上げていくことが有効であろう。また、付録に記した式(8)から、シグモイド関数 $f(x)$ の微分 $f'(x)$ が

$$f'(x) = \frac{\partial f(x)}{\partial x} = \frac{1}{T} f(x)[1 - f(x)] \quad (3)$$

図3 SLM 及び MLM の数値実験結果
Fig. 3 Simulation results of SLM and MLM

で表しうるゆえに、学習調整量 Δw_{kj} 、 Δv_{ji} は、それぞれ

$$\Delta w_{kj} \propto \frac{1}{T}, \quad \Delta v_{ji} \propto \frac{1}{T^2} \quad (4)$$

となることから、温度パラメータ T を徐々に下げる、すなわち annealing⁸⁾ をすることによって、学習効率を上げうると期待できる。

本研究では五つのグループ間の学習に対して、温度パラメータ T の変化の影響を調べた。まず、 T による学習誤差 e の変化が図5に示されている。また、一般性を失わない形で T を変化させた時のシナプス $w_{11}, w_{21}, w_{31}, w_{41}$ 及び w_{51} の変化を図6に示す。さらに、グループ間の識別結果は表4に示す。

数値計算の結果から、 T は非常に敏感なパラメータであることがわかった。得られた結果を以下にまとめる。

- a) T が5、すなわち大きい場合、学習誤差は途中から一定の値となり、またシナプスも非常に緩やかに変化し、学習の収束は期待できない。
- b) T が1/5、すなわち小さい場合、学習誤差は激しく振動し、またシナプスにも振動が発生し、学習は収束しない。
- c) T が定数1の場合、学習誤差は緩やかに下がり、シナプスも緩やかに変化する。本例の場合、 $e=0.03$ までの学習回数 L_p は17819、所要時間は約824秒である。

図4 e あるいは L_p の誤差係数 μ への依存特性
Fig. 4 Error coefficient μ dependency of e or L_p

図5 学習誤差の T への依存特性
Fig. 5 T dependency of learning error

d) T が $1000/(2000+L_p)$, $L_p = 1, 2, 3, \dots$, すなわち、緩やかに下がる場合、学習誤差は急速に0に近くなり、シナプスも早く安定状態になる。本例の場合、 $e=0.03$ までの学習回数 L_p は1297、所要時間は約60秒である。

ここで、 $\mu=10\%$ では、表4の識別率の平均は97.5%、一方、表2の同じ五つの材質の識別率の平均は95.5%であった。

表4 グループ間の識別結果

Table 4 Discriminating results between groups
Simulation conditions: $I=4$, $J=5$, $K=5$, $T=1000/(2000+L_p)$,
 $\eta=0.05$, $L_p=1297$, $t=60$ s, $e=0.03$

No.	1	2	3	4	5
$\mu\%$	Styrene	Rubber	Cu	Fe	Wood
5.0	100	100	100	100	100
7.5	100	99.1	100	99.1	100
10.0	100	92.9	100	94.6	100
12.5	100	86.5	100	89.2	100

図6 シナプスの T への依存性

Fig. 6 T dependency of synapses

3.4 識別アルゴリズム

以上の分析及び数値計算結果から、識別ニューロアルゴリズムを以下のようにまとめることができる。

I) データベースに基づいて、物理現象などによる m 種類のサンプルを K 組の材質の近いグループに分ける。

II) K 個のグループのそれぞれの重心 M_f ($f=1, 2, \dots, K$) を計算する。その重心の座標をそのグループのデータベースとする。

III) 温度パラメータ T を小さくさせながら、グループ間のニューロシナプスを学習する。

IV) 平均処理学習法 (MLM) によるグループ内のニューロシナプスを学習する。

さらに、材質を識別するときは以下のようなステップに従うこととする。

V) n 個のセンサでそれぞれ出力 $y_1, y_2, \dots, y_n$ を得る。それらのデータを K 個のグループのニューラルネットワークに入力する。

VI) その K 個のグループのニューロンの出力層までを計算する。

VII) その最大ニューロン出力に対応するグループ内で、ニューロンの出力層までを計算する。

VIII) グループ内で最大ニューロン出力に対応する材質を決定する。その場合、センサの出力はその材質のデータベースのある程度の範囲内 (例えば、図7に示すアルミの領域は、図3において学習した領域と R_1 を同時に満たす領域である) ならば、その材質と認める。それ以外の場合は新しい材質と認識する。但し、図7の D_1, D_2, D_3 はそれぞれ原点からアルミ、銅及び真鍮までの距離、 R_1, R_2, R_3 は材質の領域半径、 μ はセンサ出力のばらつきにより決まる定数とする

IX) 結果を表示する。さらに、再識別とするか終了とする

図7 アルミ、銅及び真鍮の領域

Fig. 7 Categories of Al, Cu and Brass

本論文においては、物体の材質識別用複数接触センサの出力を融合して材質識別を行なうための、材質識別ニューロアルゴリズムを提案した。ニューラルネットワークの理論を用いて、パターンの材質識別を行う場合、そのシナプスの学習が不可欠である。

本論文は、まず、材質識別の際に標準学習法(SLM)での学習速度が非常に遅いことを明らかにした。そこで、その問題を避けるために、サンプルを物理的な性質に基づいて、おおまかなサンプルのグループ化を提案した。グループ内の学習では、平均処理学習法(MLM)による学習回数を大幅に減らすことができ、識別率も上がることを明らかにした。また、グループ間の学習では、温度パラメータ T の調整によって、学習回数も大幅に減らすことができた。数値計算では、改良したアルゴリズムによって学習速度が従来の SLM の 300 倍以上という非常に高速となることがわかった。

本研究結果は最終的な研究目的である人工皮膚材質認識センシングシステムの実現に有用と考える。

謝辞: 本研究を行うにあたり、貴重なご討論、ご意見を頂いた佐賀大学理工学部講師和久屋 寛氏に深謝致します。

参考文献

- 1) 李 徳勝、信太 克規:「材質識別のための単一構造多機能接触センサ」、電気学会論文集 C、Vol.115-C, 908/913 (1995,7)
- 2) 李 徳勝、信太 克規:「容量-誘導形単一構造接触センサによる材質識別」、計測自動制御学会論文集、Vol.31, No.9, 1252/1257 (1995)
- 3) R.C Luo and M.Kay: Multisensor Integration and Fusion in Intelligent System, IEEE Trans. on SMC, Vol.19, 901/931 (1989)
- 4) 石川 正俊:「センサフュージョンシステム」, JRSJ, Vol.6 No.3, 79/83(1988)
- 5) 李 徳勝、信太 克規:「複数接触センサによる材質識別のファジアルゴリズム」、電気学会論文集 C、Vol.116-C, 374/380 (1996,3)
- 6) D. E. Rumelhart et al: Parallel distributed processing, MIT Press, (1986)
- 7) 李 徳勝、信太 克規:「材質識別のための人工皮膚感覚センサ」佐賀大学理工学部集報、Vol.23-2, (1995,2)
- 8) I.Matsuba: Optimal simulated annealing method and its application to combinatorial problems, Proc. IJCNN'89, I, 541/546 (1989)

BP 法で学習するとき、まず出力層ニューロン出力 O_k と教師信号 d_k との誤差和 E を定義する⁶⁾。

$$E = \frac{1}{2} \sum_{k=1}^K (d_k - o_k)^2 \quad (5)$$

最急降下法の原理によって、重み w_{kj} 、 v_{ji} の調整量 Δw_{kj} 、 Δv_{ji} は次のように求められる。

$$\Delta w_{kj} = -\eta \frac{\partial E}{\partial w_{kj}} = \eta (d_k - o_k) f'(g_k) z_j \quad (6)$$

$$\Delta v_{ji} = -\eta \frac{\partial E}{\partial v_{ji}} = \eta f'(h_j) y_i \sum_{k=1}^K (d_k - o_k) f'(g_k) w_{kj} \quad (7)$$

$$o_k = f(g_k) = \frac{1}{1 + e^{-g_k/T}}, \quad z_j = f(h_j) = \frac{1}{1 + e^{-h_j/T}} \quad (8)$$

$$g_k = \sum_{j=1}^J w_{kj} z_j, \quad h_j = \sum_{i=1}^I v_{ji} y_i \quad (9)$$

ここに、 T は温度パラメータと呼ばれる定数、 η は学習速度係数である。

(平成 8 年 9 月 27 日受付, 同 9 年 2 月 3 日再受付)

李 徳勝 (正員)

1962 年 2 月 23 日生。1988 年 7 月中国ハルビン工業大学大学院修士課程修了。1990 年政府派遣留学生として来日留学。平成 5 年 4 月佐賀大学大学院博士後期課程入学、平成 8 年 3 月修了。博士(工学)。同年 4 月佐賀大学理工学部電気工学科助手、現在に至る。知能計測、触覚センサなどに関する研究に従事。

信太 克規 (正員)

1943 年 5 月 6 日生。1970 年 3 月東北大学大学院工学研究科電子工学専攻修士課程修了。同年 4 月通産省工業技術院電気試験所(現、電子技術総合研究所)入所。1987 年同所標準計測部電気標準室長。1990 年佐賀大学理工学部電気工学科教授、現在に至る。精密電気計測に関する研究に従事。工学博士。計測自動制御学会、応用物理学会、日本 ME 学会、日本ロボット学会、IEEE 会員。