摩耗粉の形態識別におけるニューラルネットワークの適用*

杉村 丈一^{*1}, 梅田 彰彦^{*2}, 山本 雄二^{*1}

Wear Debris Identification with Neural Networks

Joichi SUGIMURA, Akihiko UMEDA and Yuji YAMAMOTO

A feedforward neural network is applied to identification of wear debris generated under different sliding conditions. In order to describe characteristics of debris of various shapes and sizes, four representative parameters for groups of randomly sampled wear debris, i. e. 50% volumetric diameter, average elongation, average roundness and average reflectivity, are used as inputs to the network. Debris sampled in five steel sliding experiments are chosen as examples. It is shown that identification results depend on the ranges of these parameters, and that the ranges are determined by the sample size used for averaging. In the present case, a sample size of fifty pieces of debris provides a satisfactory identification result with less than ten percent error. It is also demonstrated that use of data for larger particles leads to better results. We discuss how the network determines difference in debris features, and how this approach can be applied to diagnosis of sliding surfaces.

Key Words: Tribology, Wear, Neural Network, Wear Debris, Morphology, Condition Monitoring

1. 緒 言

機械摺動面のコンディションモニタリングを目的として、作動油中に含まれる摩耗粉の形態の観察や解析が従来より行われてきた⁽¹⁾⁽²⁾。これは、内科の血液検査と同じように、少量の油を採取して調べるといういたって簡便なものであるが、直接見ることの困難なトライボ損傷の状況を知るためにきわめて有効な手段である。しかし、画像処理技術やコンピュータの利用によって、摩耗粉の形や大きさの定量的なデータが容易に得られるようになった今日においても、そのデータの使われ方は未だ定性の域をでない場合が多い。

Roylanceらは、摩耗粉画像解析の自動化とそれに基づいた診断システムに関する研究を進めているが、正常摩耗、シビア摩耗、アブレシブ摩耗などの大まかな摩耗の範疇での摩耗粉の形状パラメータの値の範囲を示すにとどまっている⁽³⁾⁽⁴⁾。これは血液検査に例えれば、詳細な分析データから単にその人が健康かどうかの判定を下すだけのようなものである。応用技術として実用化しているフェログラフイー⁽⁵⁾においても、分析

結果から適切な診断を下すためには、対象とする機械の挙動を熟知した担当者の経験と勘が要求される。

摩耗粉の形態解析をさらに有効な診断技術に発展させるためには、上述のような大まかな分類ではなく、摩耗の進行状況や表面生成物などの摺動面の詳細な状態の定量的な把握に結びつけることが必要である。そのためには、大きさや形の千差万別な無数の粒子の集団のもつさまざまな特徴と、摩擦に関連する因子との間の因果関係を考慮に入れた整理方法の確立が必要である。これはとりもなおさず、未だ解明されていない摩耗の発生機構に立ち入ることを意味する。

本研究は、この問題への新たな視点からのてがかりを得るために、パターン認識をはじめとして多くの分野で汎用技術として定着しつつある人工ニューラルネットワーク⁽⁶⁾⁽⁷⁾を用いて、摩耗粉形態の識別とそれに基づいた摺動状態診断を試みるものである。人工ニューラルネットワークは、対象とする問題の入出力間の非線形な関係を学習によって捉えることができる点で有望であり、単なる摩耗粉の特徴抽出だけではなく、摩耗現象の因果関係解明の糸口が引き出される可能性も期待できる。以下では、かかる試みの第一歩として、階層型ニューラルネットワークによる摩耗粉発生条件の識別について報告する。

* 原稿受付 1995年2月21日。

^{*1} 正員, 九州大学工学部 (〒812 福岡市東区箱崎6-10-1)。^{*2} 学生員, 九州大学大学院。

図1 摩耗粉の形態パラメータ

表1 摩擦実験条件

Experiment	Apparatus Specimen	Lubricant	Load (N)	Sliding (Rolling) Speed (mm/s)	Sliding Distance (m)
A	P/D*	None	58.8	6.28	82.9
B	P/D	H60*	58.8	6.28	82.9
C	P/D	H60+DBDS (0.5wt%)	58.8	6.28	82.9
D	P/D	H60+S(0.2wt%)	58.8	6.28	67.9
E	2D*	P500*	277	754/377*	679

* P/D: Pin-on-Disk Machine, SUJ2 vs S45C(200HV)
 2D: Twin-Disk Machine, S45C(650HV) vs S45C(200HV)
 H60, P500: Mineral Base Oils, 8.2cSt and 88cSt @40°C, respectively
 754/377: Rolling Speeds of faster and slower specimens

表2 摩耗粉形態パラメータの平均値

Experiment	50% Volumetric Diameter (μm)	Elongation	Roundness	Reflectivity
A	13.79	1.38	1.42	85.3
B	9.22	1.54	1.58	83.1
C	7.83	1.57	1.73	60.1
D	7.42	1.76	1.79	88.2
E	4.23	1.43	1.47	130.0

2. 摩耗粉の形態パラメータ

2.1 形態パラメータの測定 摩擦実験で用いた潤滑油を孔径0.45 μmのメンブレンフィルターによって濾過し、フィルター上に捕捉された摩耗粉の形態を、光学顕微鏡、CCDカメラ、パーソナルコンピュータなどからなる画像処理装置⁽⁸⁾を用いて解析した。本論文では、ピン/ディスク試験機による炭素鋼と軸受鋼の滑り実験4種類⁽⁸⁾と、2円筒型試験機⁽⁹⁾による炭素鋼同士の転がり-滑り実験の計5実験A～Eで得られた摩耗粉を取り上げる。表1に実験条件を示す。

ニューラルネットワークによる解析では、図1に示す長短度(Elongation)、複雑度(Roundness)、光沢度(Reflectivity)、および50%体積径の計4つの形態パラメータを採用した。50%体積径は、その径以下の径をもつ摩耗粉の体積の合計が全摩耗体積のちょうど半分となるような径であり、代表径(Representative Diameter)の分布から求めた。代表径とは粒子の投影面

図2 摩耗粉の長短度：実験AおよびB

積の平方根と定義した。光沢度は、CCDカメラの出力の非線形性を補正するために各画素のグレイレベルを γ 変換した後、粒子内の全画素の平均をとったものである。なお、白色基準面の光沢度は200とした⁽⁸⁾。顕微鏡の対物レンズは倍率40倍のものをを用い、各実験条件ともフィルター上のランダムな位置50画面に含まれる径0.6 μm以上の摩耗粉約1500～3200個について上記のパラメータを計算した。

2.2 形態パラメータの分布と平均値 結果の一例として、実験AとBから任意に選んだ摩耗粉それぞれ500個ずつの代表径と複雑度の関係を図2に示す。図2に代表されるように、各形態パラメータは広い範囲に分布しており、実験ごとの値の存在範囲は同一ではないが部分的に重複しているため、摩耗粉1個のパラメータ値からそれがどの実験のものか直ちに判断することはできない。従って、摩耗粉の形態を識別するためには、集団としての性質、例えば平均値などを用いる必要がある。表2は、50%体積径及び他の3種の形態パラメータの各実験ごとの平均値を示す。これより摩耗粉形態の大まかな違いが類推できる。例えば、無潤滑の実験Aは大きく丸みを帯びた形、DBDS添加油の実験Cは光沢度が低くでこぼこした形、硫黄添加油の実験Dは細長い形、などである。

平均値を用いた比較を行う場合に、それを求める際のサンプル数が常に問題となる。既報⁽⁸⁾で述べたように、有限個の摩耗粉に対するパラメータの平均値の分散は「サンプル数に反比例して」変化するので、数が多い方が母集団の平均値に近い値を得やすい。一方、作動中の機械から摩耗粉をサンプリングすることを想定すると、必要数が多くては実用上不都合である。

図3(a)は、測定データを摩耗粉50個ずつの小グループにランダムにわけ、各グループごとの複雑度と長短度

図3 長短度と複雑度の平均値の分布範囲：図中の記号は実験を表す

の平均値のばらつきの大まかな範囲を示したものである。図3(b)は、グループのサンプル数を200にした場合である。今回の例においては、サンプル数200では2つのパラメータだけで5つの実験は完全に分離し、サンプル数50でも、光沢度や50%体積径などとあわせて多次元データの分布としてとらえると5つの実験はほぼ分離する。

2.3 大サイズの摩耗粉の形態 図4は、実験Bの摩耗粉について、代表径に対する長短度、複雑度の平均値と、標準偏差で表したばらつきの範囲を示したものである。どちらのパラメータも径が大きいほど増加する傾向があり、長短度は数 μm 以上ではほぼ一定値に落ちつく。他の実験についても、増加の程度は異なるが、傾向は同じであった。一方、数 μm 以下の小さい径に対してはこれらのパラメータは小さく、実験による差が認められない。この理由は、解析画像の分解能の影響によって、仮に細長い、あるいは複雑な形の粒子があったとしても、正しくパラメータ値に反映されないためと考えられる。すなわち、より大きな摩耗粉のほうが形態の特徴を明確に捉えやすい。図3(c)に、代表径が $2.74\mu\text{m}$ 以上の摩耗粉（測定画像上で画素数100以上に相当）について、サンプル数20の小グループごとの複雑度と長短度の平均値の範囲を示す。サンプル数は図3(a)の半分以下だが、5実験の範囲がよりはっきりわかれている。

3. ニューラルネットワークによる識別

3.1 階層型ニューラルネットワーク 図5に示す典型的なフィードフォワード型のニューラルネットワークを用いて、前章で示した5つの実験の摩耗粉の形態の識別を行った。前述の4つの形態パラメータを入力データとし、値の範囲が概ね0から1の範囲に収まるように、50%体積径と光沢度はそれぞれ1/10と1/255

図4 摩耗粒径による長短度と複雑度の平均値の変化：実験B、○印が平均値、縦線の長さは標準偏差の2倍を表す

をかけた値を入力し、長短度と複雑度からは1を引いた値を入力した。出力層はユニット数5で、正しい認識を行った場合にその実験番号に対応するユニットは1に近い値を、それ以外のユニットは0に近い値を出力する。例えば実験Bの期待出力は(0, 1, 0, 0, 0)である。中間層数とそのユニット数は種々の組合せを設定したが、

図5 摩耗粉識別のためのニューラルネットワーク

表3 ネットワークへの入力データ例：
実験A，摩耗粉50個ずつの平均値

Debris Group No.	50% Volumetric Diameter (μm)	Elongation	Roundness	Reflectivity
1	13.76	1.398	1.416	85.45
2	15.12	1.347	1.445	84.61
3	11.08	1.298	1.404	84.63
4	10.80	1.350	1.409	113.0
5	9.240	1.338	1.349	92.31
6	8.109	1.438	1.422	84.94
7	7.868	1.362	1.413	121.3
8	4.418	1.376	1.410	77.52

表4 表3の入力データに対する出力例：
全体平均値を学習したネットワーク

Debris Group No.	Outputs from Unit:					Decision
	A	B	C	D	E	
1	0.972	0.083	0.004	0.000	0.004	A
2	0.990	0.023	0.006	0.000	0.002	A
3	0.870	0.149	0.011	0.000	0.016	A
4	0.721	0.462	0.002	0.000	0.054	A
5	0.442	0.508	0.004	0.000	0.080	B
6	0.045	0.796	0.014	0.000	0.066	B
7	0.041	0.817	0.001	0.000	0.393	B
8	0.000	0.063	0.029	0.004	0.635	E

以下では中間層1層，ユニット数20の場合の結果のみを示す。

判定させるデータは，前章で示した摩耗粉の小グループごとの形態パラメータの平均値とし，最も大きい出力値に対応する実験を判定結果とした。一方，学習における教師データは，各実験について形態パラメータの全体の平均値を与える場合と，判定データと同じサンプル数で別の摩耗粉の小グループごとの平均値を複数与える場合を設定した。学習はモーメント項をもつ誤差逆伝播学習則を用いたプログラムを作成して行った。収束判定条件はすべての出力ユニットで平

表5 ネットワークによる摩耗粉識別の
正答率 (%)

Sample Size/ Number of Data Identified	Sample Size/ Number of Training Data	Experiments					Average
		A	B	C	D	E	
200/5	All*	100	100	100	100	100	100
100/10	All*	70	100	100	90	100	92
50/20	All*	50	85	80	95	95	81
50/20	50/5	80	80	95	85	85	85
50/20	50/10	90	100	100	90	85	93

* Trained with the average parameters of all the debris in Table 2

表6 ネットワークによる大摩耗粉識別の
正答率 (%)

Sample Size/ Number of Data Identified	Sample Size/ Number of Training Data	Experiments					Average
		A	B	C	D	E	
5/20	All*	85	60	60	55	70	66
5/20	5/5	85	55	60	85	70	71
10/15	All*	100	60	67	60	73	72
10/15	10/5	87	47	80	100	100	83
10/15	10/10	87	47	67	100	100	80
20/8	20/5	100	75	100	100	100	95

* Trained with the average parameters of all the large debris

均自乗誤差0.01以下，または学習の繰返し数10000以下とした。正常に収束した場合の学習繰返し数は200から400程度であった。

3.2 識別結果 結果の一例として，実験Aのデータの一部を表3に，またそれぞれに対するネットワークの出力例を表4に示す。用いたネットワークは，表2に示したパラメータの全体平均値によって学習させたものであり，表3のデータはサンプル数50の小グループごとのパラメータ値である。表からわかるように，各パラメータ値が全体平均，すなわち教師データに近い場合は正しく実験Aと判定しているが，5番目以降のそうでないものは実験BあるいはEと誤認している。この例では，小グループの50%体積径が全体に対する値よりかなり小さいことが誤認の最大の原因のようである。50%体積径は，全体数に占める割合の低い10μm以上の大摩耗粉によって大きく左右され，特にサンプル数が少ない場合にはそれらが含まれるかどうかによって大幅に値が異なるためである。

表5に判定の正答率をまとめて示す。小グループのサンプル数が200の場合には，ネットワークは5種類の摩耗粉を完全に認識する。サンプル数が100，50の場合にはやや成績が劣るが，教師データとして複数の小グループの値を与えると，正答率は9割以上まで向上している。つまり，50%体積径のようにばらつきの大きいパラメータがあっても，複数の異なるデータを学習させることによって，ネットワークはそのばらつきを

図6 ネットワークの識別領域：全体平均値を学習したネットワーク

図7 ネットワークの識別領域：小グループ10組ごとの平均値を学習したネットワーク

正しく把握する。実験Aは、前述のとおり長短度と複雑度が実験BやEと区別できない場合があるが、50%体積径の絶対値が大きいかつ広く分布しているという特徴を与えたことによって、正しく認識されたと考えられる。

表6は、代表径が2.74 μ m以上の摩耗粉について、50%体積径を除いた3つの形態パラメータを入力として行った結果である。小グループのサンプル数は5, 10, 20とした。これだけ少ない摩耗粉でもネットワークは十分に識別したことがわかる。摩耗粉数5と10の場合はパラメータ値の存在範囲が重複しているために正答率は若干低い、20の場合は小さな径の摩耗粉も含めた表5の結果よりもさらにより成績を得た。

4. 考察

4.1 ネットワークによる特徴認識 今回解析の対象とした実験は、実験E以外はすべて同一の試験片形状、摺動材料、荷重、滑り速度で行ったものであり、摩耗率の推定値もすべて $10^{-8} \sim 10^{-9} \text{ m}^2/\text{N}$ の範囲内にあった。このことは、これらが多種多様な摩耗現象全体からすれば、かなり近い条件での摩耗であったことを意味し、そのような摩耗のわずかな差違を摩耗粉の

形態的特徴によって識別できたことは意義深い。ニューラルネットワークが正しく摩耗粉を識別できた大きな理由は、摩耗粉の形態パラメータの平均値を与えることによって、5つの実験の値の存在範囲が明確に分離されたためである。

このような方法を実用的な診断システムに応用していくためには、さらに多岐にわたる条件の摩耗にどう拡張するか考える必要がある。そのためにはまず、ニューラルネットワークがどのように識別を行ったのか、確認しておく必要があろう。図6, 7に、任意のデータに対してネットワークがどう判定するかを調べた結果を示す。図6は表5の最初の3例で用いた、形態パラメータの全体平均値によって学習したネットワークであり、図7は表5の5番目の、サンプル数50の小グループ10組によって学習したものである。入力データ4個のうち光沢度を80に固定し、50%体積径の3つの値に対して、長短度-複雑度図中に各条件の判定領域を示した。また、表3の判定データの位置を、50%体積径の最も近い図中にデータ番号で示した。

ニューラルネットワークは、入力値の特徴空間を教師データの期待出力パターンに従って分ける。その分け方の複雑さは教師データとネットワークの構造に依

存するが⁷⁾、今回の場合は判定条件が5個のため単純な領域分けになっている。教師データが5組のみの図6のネットワークは領域分けが大ざっぱであり、表3に示した4つの誤認データは確かに実験Aの領域からはずれている。一方図7では、複数の異なるパラメータ値の組合せを学習したために、ばらつきの範囲を考慮に入れた領域分けに成功したことがわかる。

4.2 ネットワークによる摩耗の評価と分類 学習したネットワークに、新たに今回とは異なる未知の摺動条件による摩耗粉のデータを入力したら、どうなるであろうか。もしそれが学習したデータの存在範囲内であれば、AからEのいずれかの判定を得るであろう。領域間の境界に近いデータの場合は、ネットワークからの出力のいくつかは表4の4番目や5番目の例のように0や1近傍ではなく中間の値をとりうる。いずれにせよ、判定結果はその摩耗粉の形態が今回与えたいずれかの摺動条件下の摩耗に類似していることを意味するはずであり、例えば今回のデータは、潤滑剤の効き方の違いの認識に役立つと考えられる。すなわち、ニューラルネットワークを用いることによって、異なる潤滑条件や摺動材料に対して、摩耗過程の類似性や共通点を見いだすことが期待できる。

新たな入力データが学習データの存在範囲内にない場合は、判定の解釈は注意を要する。図6、7からわかるように、ネットワークは教師データの存在しない範囲、すなわち学習を行っていない値の領域に対して、いずれかの出力を発生するためである。しかしながら、階層型ニューラルネットワークは、学習済みの状態からさらに簡単に追加学習を行うことができるので、上述のようないずれにも属さない領域にあるデータの入出力関係を加えることが可能である。この能力は実用上有効であり、さらに多くの条件下で生じた摩耗粉について学習と判定を進め、既知のパターンとそうでないものの区別を行わせることによって、摩耗粉の形態による摩耗現象の詳細なカテゴリー分けが可能になると考えられる。すなわち、緒言で述べたいわゆる「経験と勘」の計算機による実現である。

今回はネットワークからの出力として単に実験番号を与えたが、摺動材料や荷重などの詳細な作動条件や、摩耗量、摩擦係数などの項目を出力パラメータとすることによって、カテゴリー分けをより具体的にを行うことができる。さらにより詳細な解析として、材料硬度、組織変化、表面反応生成物、表面粗さなど摩耗に関連した諸因子を出力、あるいは入力パラメータとして採用し、それらの関係因子間の相互関係をニュー

ラルネットワークに学習させることによって、摩耗状態の診断だけでなく、摩耗の因果関係解明の糸口が得られる可能性がある。このような摩耗現象の整理を行う意味で、両方向結合型のニューラルネットワークや自己組織化ニューラルネットワーク⁸⁾の適用も試みる価値があると思われる。

5. 結 論

摩耗粉の形態の分類と摩擦状態の診断への応用を目的として、摩耗粉データの解析に階層型ニューラルネットワークを適用した。形態パラメータの平均値を入力データとして用いることにより、5つの実験の摩耗粉形態の識別が可能であることを示した。それらの平均値のばらつきの範囲はサンプル数によって異なり、その範囲をカバーする複数の教師データを与えることによって、ネットワークは正しく識別を行った。また、比較的大きな摩耗粉の形態パラメータ値を用いることによって、さらに識別結果が向上することを示した。

謝 辞

本研究の一部はメカトロニクス技術高度化財団による研究助成（平成3年度事業分）によって実施したことを記して謝意を表する。また、潤滑油を提供下さった出光興産（株）に感謝申し上げる。

文 献

- (1) 日本トライボロジー学会編、小特集・機械の寿命予測とメンテナンス・トライボロジー、トライボロジスト、39-7 (1994), 553-603.
- (2) Hunt T. M., Handbook of Wear Debris Analysis and Particle Detection in Liquids, (1993), Elsevier.
- (3) Roylance B. J., ほか4名, Lubrication Engr., 50(1994), 111-116.
- (4) Roylance B. J. and Raadnui S., Wear, 175(1994), 115-121.
- (5) Scott D., ほか2名, Wear, 34(1976), 251-260.
- (6) 例えば, Dayhoff J. E. 著, 桂井訳: ニューラルネットワークアーキテクチャ入門, (1992), 森北出版.
- (7) Lippmann R. P., IEEE ASSP Mag., 4(1987), 4-22.
- (8) Sugimura J., ほか2名, 投稿中.
- (9) Sugimura J., ほか2名, Proc. 20th Leeds-Lyon Symp. on Tribology, (1994), 125-137, Elsevier.