

ニューラルネットワークによる砥石作業面状態の識別*

—砥石作業面性状のインプロセス評価に関する研究—

細川 晃** 織田正人*** 眞下和史† 佐久間邦郎†† 山田啓司** 上田隆司**

Discrimination of Grinding Wheel Surface by Means of Neural Network Technique

—Studies on In-process Evaluation of Grinding Wheel Surface—

Akira HOSOKAWA, Masato ODA, Kazufumi MASHIMO, Kunio SAKUMA, Keiji YAMADA and Takashi UEDA

In this study, a new technique of in-process evaluation of the wheel surface is proposed. Five specified wheel surfaces are prepared as the references via the appropriate dressing procedure, and grinding sounds generated by these wheels are discriminated by analyzing the dynamic frequency spectrum with a neural network technique. In the case of conventional vitrified-bonded alumina wheel, grinding sound can be identified under the optimum network configuration in such that learning rate is 0.0029 and number of hidden layer is 420. This system can recognize instantaneously the difference of the wheel surface in a good degree of accuracy insofar as the dressing conditions are relatively widely changed. In addition, the network perceives the wheel wear because the grain tips are flattened as grinding proceeds and the grinding sound resembles to that of the wheel generated with lower dressing feed.

Key words: grinding wheel surface, in-process evaluation, grinding sound, neural network, dressing, vitrified-bonded alumina wheel, grinding force, surface roughness

1. 緒 言

研削加工においては、砥石作業面の状態によって加工精度、加工能率および仕上げ面性状などが大きく変化するため、その測定と評価は極めて重要な作業となる。そのため、これまで触針法や顕微鏡観察法など種々の方法によって砥石作業面の幾何学的あるいは形態的特徴を抽出する試みがなされているが^{1)~3)}、測定時間や簡便性・操作性などの面から、実際の研削作業に適用できるものは少ない⁴⁾。また、研削加工では加工条件に応じて砥石作業面が加工中に変化するため、本来、砥石の状態はインプロセスで測定できることが望ましい。

一方、AEや加工音など比較的容易に収集できる信号を用いて切削や研削における加工状態をインプロセスで診断する研究も数多く行われている^{5)~7)}。しかし、これらの多くは工具欠損や工具摩耗あるいは砥石寿命などによって大きく変化する“加工状態”を観測対象にしており、目直し条件などによって変化する“砥石作業面の状態”を評価することを目的としたものではない。実際、著者の一人らはホーニングにおける代表的な加工状態(脱落状態/切削状態/磨き状態)をホーニング音によって監視できることを示している⁸⁾。

このような背景の下、本研究では、研削加工時に発生する研削音を入力信号として、その特徴をニューラルネットワークの手法を適用して解析することにより、砥石作業面の状態をインプロセスで認識するシステムの構築を試みた。本報では

その第一段階として、比較的粒度の大きい在来A系砥石を対象としてその作業面の差違を認識する実験を行った。

2. 実験方法

砥石と工作物の干渉の結果として発生する研削音は、砥石作業面の状態を大きく反映したものであるが、その特徴から砥石表面の幾何学的なパラメータ(突出し量など)を直接算出することは難しい。そこで本研究では、あらかじめ基準となるいくつかの砥石作業面を生成し、それらによって発せられる研削音を基準信号として学習し、実際の研削時の発生音が基準信号のどれに類似しているかを識別する手法を提案した。

2.1 実験装置および実験条件

図1に実験装置を示す。実験は在来A系砥石(A60K7V)を用いて炭素鋼S55Cの1パスプランジ研削を行い、その時に発生する研削音を精密騒音計(JEIC TYPE 1030)で測定する。このとき、音を検知するコンデンサ型マイクロフォンは、図に示すように、研削点の前方150 mmの位置に固定した。収集した研削




Fig.1 Schematic illustration of experimental arrangement

* 原稿受付 平成14年5月20日
 ** 正会員 金沢大学工学部(金沢市小立野2-40-20)
 *** 学生会員 金沢大学大学院(現、富士通ゼネラル; 神奈川県川崎市高津区末長1116)
 † 学生会員 金沢大学大学院(金沢市小立野2-40-20)
 †† 学生会員 金沢大学大学院(現、上野特許事務所; 名古屋市中区栄3-21-23)

Table 1 Experimental conditions

Grinding wheel	A60K7V (205×20×31.75 mm)	
	$V_F=42.5\%$, $V_G=49.0\%$, $V_B=8.5\%$	
Workpiece	S55C (400HV20)	
Length	l_w	50 mm
Width	b_w	10 mm
Operating parameters		
Wheel speed	v_s	25 m/s
Work speed	v_w	10 m/min
Depth of cut	a	10 μm
Grinding fluid	Water-based solution (1:50 in water)	

Table 2 Dressing conditions for formation of reference wheel

Condition No.	Dressing feed	Condition No.	Dressing feed
N_d	s_d $\mu\text{m}/\text{rev}$	N_d	s_d $\mu\text{m}/\text{rev}$
(1)	10		
(2)	20	(23)	35
(3)	50	(34)	75
(4)	100	(45)	200
(5)	300		

Wheel speed: $v_s = 25$ m/s
 Dressing depth $a_d = 10$ $\mu\text{m} \times 5$ passes
 Grinding fluid: Water-based solution (1:50 in water)
 Dresser: Single-point diamond dresser

音はデータレコーダに記録した後周波数解析を行い、その処理波形を後述するニューラルネットワークの入力信号とした。研削抵抗の測定には圧電センサ (KISTLER 9251A) を組み込んだ2分力動力計を使用した。なお、図に示すように、研削動力計の振動の影響を排除するため、研削音の収集は電磁チャック上に直接固定した工作物を研削した時に行っている。

表1に実験条件および計測機器の仕様を示す。

2.2 基準砥石作業面の生成

本実験ではドレッシング条件を変えて異なる砥石作業面を形成した。通常、A系在来砥石では単石ダイヤモンドドレッサを砥石軸方向にトラバースさせて行う。このとき、ドレッサ切り込み a_d およびドレッサ送り速度 s_d によって砥石作業面上の砥粒は種々の形態で破碎し、その破碎形態に応じた切れ味を示すことになる⁹⁾。ここでは、表2に示すように、粒度#60の砥石に対して s_d を10~300 $\mu\text{m}/\text{rev}$ の範囲で変化させ、状態(1)~(5)の5段階の異なる‘基準状態’の砥石作業面を生成した。すなわち、砥石作業面は状態(1)から状態(5)へと s_d が大きくなるにしたがって砥粒先端がフラットな切れ味の悪い状態から砥粒先端が鋭利で研削性能の高い状態になると考えられる。なお、後述するが、表2における状態(23)、(34)および(45)はそれぞれ基準状態(2)と(3)、(3)と(4)および(4)と(5)の中間のドレッシング速度で生成した状態を示している。

図2に表2に示す状態(1)~(5)の砥石を用い、表1に示す実験条件で研削したときの研削抵抗 F_t (○), F_n (△) および研削方向と直角方向の仕上げ面粗さ R_a (□) の測定結果を示す。図中の(●, ▲, ■)は後述する研削音の識別実験において、改めてドレッシングした後に研削した時の結果である。図にみるように、ドレッシング条件に応じて研削抵抗が段階的に変化しており、適度に異なる砥石状態が生成されていることが確認できる。

一方、仕上げ面粗さもドレッシング送りの増加とともにほぼ段階的に大きくなっているが、状態(1)と(2)に大きな差は生じてい

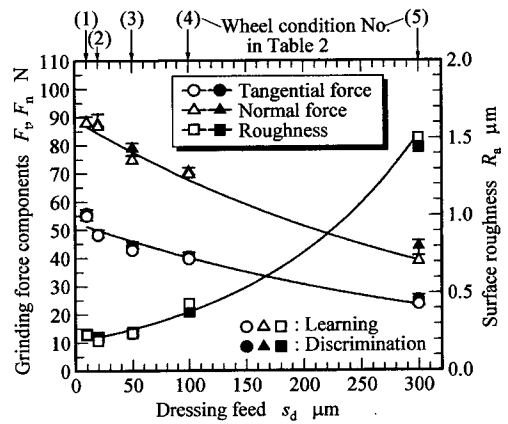


Fig.2 Variations of grinding force components and surface roughness with dressing conditions

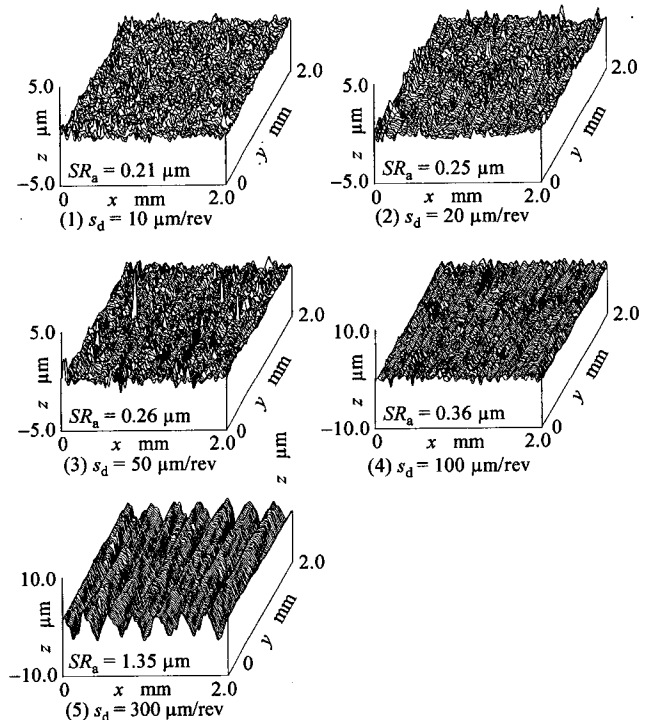


Fig.3 3D roughness images of the work surface ground with five reference wheels which are dressed by different dressing feed

ない。図2より、およそ $R_a=0.2$ μm が#60砥石を用いたプランジ研削における限界粗さと考えられる。図3は工作物仕上げ面の三次元粗さプロフィールである。工作物に残された加工痕は砥石作業面を直接反映したものと考えられ、その状態の推定には極めて有用である。図にみるように、すべての基準状態で明確な研削条痕が観測され、ドレッシング速度が高速にしたがって、条痕の凹凸が大きくなっていることがわかる。特に、状態(4)と(5)で仕上げ面が粗くなっており、 s_d が100 $\mu\text{m}/\text{rev}$ を越えるあたりから砥粒の破碎が顕著になったものと推察される。また、図2の結果と同様、状態(1)と(2)に大きな差が認められないこともわかる。なお、図3に示す粗さは表示部分の三次元粗さ SR_a であるため、図2の値とは多少異なっている。

以上の結果より、これらの5つの状態を段階的にその切れ味が異なる‘基準的な砥石作業面’として妥当と判断した。

2.3 研削音の特性

図4に表1に示す各基準状態で炭素鋼S55Cをプランジ研削し




Fig.4 Frequency spectra of the grinding sounds for five kinds of grinding wheel conditions

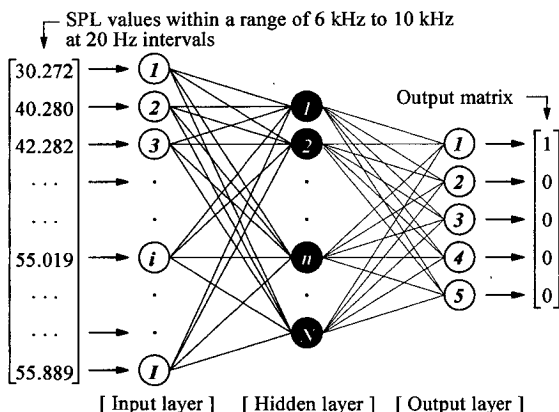


Fig.5 Neural network structure

た時に得られる研削音(工作物への食い付きおよび離脱時を除いた定常研削状態)のパワースペクトルの例を示す。これは、精密騒音計によって収集された研削音をFFTアナライザでデータ処理し、周波数スペクトル表示したものである。図にみるように、すべての状態で砥石の固有振動数に起因するピークがみられ、全体的に類似した波形となっている。したがって、研削音のスペクトル波形の特徴のみでこれらを区別することは極めて難しく、また、個々の周波数成分が何に起因するかを詳しく分析することも容易ではない。そのため、本研究では図4に示されるような研削音の周波数成分を入力、砥石の状態((1)~(5)のいずれか)を出力とするニューラルネットワークを構築して、研削音から砥石作業面状態の識別を行っている。

3. ニューラルネットワークによる研削音の認識

3.1 ネットワークの構成

ここでは、表2に示す(1)~(5)の5つの基準状態の研削音を学習し、実際の研削音が学習した研削音のどれに最も類似して

Table 3 Parameters of neural network configuration

Structure	Multiple layer network
Architecture	Feed forward network
Learning rule	Error back propagation (EBP)
Number of hidden layer	1
Neuron model	Static analogue model
Transfer function	Log-sigmoid
Number of neurons in input layer	201
Number of neurons in hidden layer	50 - 500
Number of neurons in output layer	5
Learning rate	$5 \times 10^{-4} - 4 \times 10^{-3}$
Maximum number of epochs	5000
Error goal	Sum-square error = 0.1




Fig.6 Learning result of the neural network constructed

いるかを認識するネットワークを構築する。図5に示すように、ネットワークへの教師信号としては図4に示す周波数成分の6 kHz~10 kHzの範囲を20 Hzごとに201個に分割し、その各周波数の音圧レベルSPLを成分とする201行1列の列ベクトルで与えることにした⁸⁾。なお、上記の周波数帯域はネットワークが比較的収束しやすい範囲を実験的に決定したものであるが、基本的にはどの範囲内でも学習可能である。出力は基準状態の数を行数とする5行1列の列ベクトルである。出力信号の数字1の出力される位置により、砥石作業面の状態を識別する¹⁰⁾。入力・出力とも静的信号であることから、ネットワークの構造はフィードバック回路のない階層型とし、学習アルゴリズムは、このタイプのネットワークに一般的に用いられている誤差逆伝播法(BP法)とした。隠れ層数は、論理演算回路の構築に必要な最低限の1層としている。各セルは、処理をする信号が静的であること、BP法ではセルの伝達関数が微分可能でなければならないことから、伝達関数にシグモイド関数を持つ静的アナログモデルとした。表3にネットワークの構造を示す。

3.2 研削音の学習

学習比、隠れ層セル数は実際に学習実験を行うことにより最適な値を決定する必要がある¹¹⁾。ネットワークの学習目標値を平均自乗和誤差で0.1とし、最大学習エポック数5000以内に0.1に達しない場合には学習を終了した。

図6に学習結果を示す。図にみるように、学習比が0.003以上になるとエポック数が増大して学習が収束しなくなる場合もでてくるが、学習比0.001~0.003、隠れ層セル数150~500の範

Table 4 Result of grinding sound discrimination

Input sound		Result of discrimination (Number of outputs in 10 experiments)				
N_d	s_d ($\mu\text{m}/\text{rev}$)	(1)	(2)	(3)	(4)	(5)
(1)	10	8	2	0	0	0
(2)	20	0	10	0	0	0
(3)	50	2	0	8	0	0
(4)	100	0	0	0	10	0
(5)	300	0	2	0	0	8

困では、両者が増加するにしたがって収束するまでに要するエポック数が減少するという妥当な結果となっており、ネットワークは安定して収束するとみなすことができる。本研究では、収束を早くするため学習比を0.0029、隠れ層数を420として識別実験を行った。

4. 砥石作業面状態の識別

4.1 基準ドレッシング条件による砥石作業面

表1に示す各基準条件で改めてドレッシングを施した後、研削を行った時の研削音を識別した結果を表4に示す。表の数字は、各ドレッシング条件について10回の実験を行い、どの状態に何回出力したかを示している。例えば、条件(1)でドレッシングした場合、10回中8回は正しく“状態(1)”と出力し、2回だけ“状態(2)”と誤って判別したことになる。図2をみてもわかるように、研削抵抗(●, ▲)は基準状態学習時の値(○, △)と同程度であり、全体として基準状態と類似した砥石作業面が形成されたと判断できる。実切り込みなどの研削条件を含め毎回完全に同じ加工状態を再現できるとは限らず、また、周囲の雑音の影響などによって異なった結果を出力する可能性があることは避けられない。したがって、10回程度研削を行い、その識別結果の最頻値が正しく認識されれば、実用上本システムによって砥石作業面の識別は可能であると考えている。このような観点から表4をみると、概ね識別率が8/10以上になっており、問題なく識別できていることがわかる。

なお、本手法は基本的には識別する時と同じ研削形式での研削音を学習していれば、トラバース研削などの他の研削形式にも適用できる。

ところで、ドレッシング送りがある程度小さくなると、砥粒の破砕頻度が低下して先端が比較的平坦なよく似た砥石作業面が形成されると考えられる。実際、状態(1)と(2)では仕上げ面粗さに明確な違いはでていない。しかしこのような場合でも両者は正しく識別されている。今後、ネットワーク構造の最適化によってさらに識別能を向上させることも考えられる。

4.2 基準外ドレッシング条件による砥石作業面

実際の加工現場では、決められたドレッシング条件で目直しをしても必ずしも目的とする砥石作業面状態が得られるとは限らない。そこで本節では、本識別法の応用例として、ネットワークが学習した状態(基準状態)以外の研削音を入力した場合、システムがどのような識別結果を示すかを検討した。

表1に示すように、状態(2)と(3)、(3)と(4)および(4)と(5)の各ドレッサ送り速度の中間値である $s_d=35, 75, 200 \mu\text{m}/\text{rev}$ で再ドレスした砥石(それぞれ、状態(23), (34), (45)とする)で研削した際に発生する研削音をネットワークに入力した。

図7に中間条件でドレッシングした砥石で研削した際の研削抵抗(●, ▲)を示すが、それぞれ対応する基準状態の間に抵抗

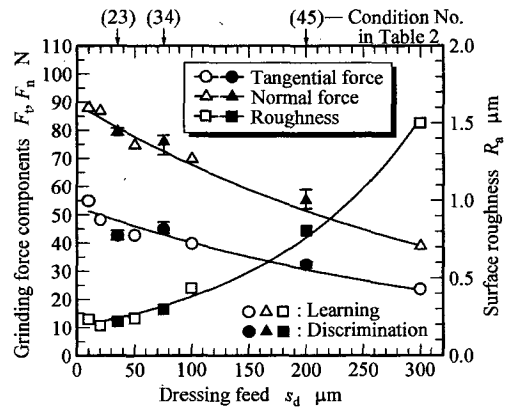


Fig.7 Variations of grinding force components and surface roughness with dressing conditions

Table 5 Result of discrimination for unlearned wheel conditions

Input sound		Result of discrimination (Number of outputs in 10 experiments)				
N_d	s_d ($\mu\text{m}/\text{rev}$)	(1)	(2)	(3)	(4)	(5)
(23)	35	0	0	9	1	0
(34)	75	0	0	0	8	2
(45)	200	0	0	0	3	7

値がほぼ収まっていることがわかる。このことから、砥石の状態は各基準状態の中間的な状態になっているものと推察される。

表5が識別結果で、10回の実験に対してどの状態に何回出力したかを示している。ここで、入力信号である状態(23)は基準状態(2)と(3)の中間的な状態と予想されるため、状態(2)と(3)の欄にハッチングを施している。状態(34)、状態(45)も同様である。表5より、状態(23)は状態(3)に、状態(34)は状態(4)に近い状態と推察される。全体として、識別結果はほとんどハッチング領域内にあり、作成したネットワークはその状態に最も近い基準状態を識別結果として出力することがわかる。この特性を利用すると、ドレス条件が未知の砥石やドレッサの摩耗によって所定の状態が得られない砥石の研削音を数パス分収集することで、砥石の作業面状態を予測することが可能と言える。

4.3 砥粒摩耗によって変化した砥石作業面

4.1節で記述したように、基準状態の砥石作業面は、状態(5)から状態(1)へと砥粒先端がよりフラットに変化していると考えられる。一方、研削過程において、砥粒の脱落や比較的大きな破砕がなく摩滅摩耗のみが進行するような場合には、研削音は砥粒がフラットな状態に変化するであろう。そこで、本識別手法の妥当性を検証するため、はじめに比較的切れ味が良好な状態(4)にドレッシングした後研削によって摩耗を進行させ、ネットワークが研削音をどのように認識するかを確かめた。なお、上記のような摩滅摩耗(砥粒の平坦化)を効率よく進行させるため、S55Cを切り込み $5 \mu\text{m}$ で乾式研削を行った。ただし、識別実験(研削音の収集)は前節と同様に表1の研削条件で行い、研削抵抗および仕上げ面粗さも併せて測定した。

図8に研削量 V_w によって変化する研削抵抗、仕上げ面粗および砥石半径減 ΔR を示す。図中の破線は図2に示す基準状態の値を示している。図にみるように、研削量が増加するにしたがって F_t, F_n ともに増加し、砥石摩耗が進行したことがうかがえる。同時に、仕上げ面粗さも減少している。研削抵抗および仕上げ面粗さの値から推測すると、砥石作業面は状態(4)から




Fig.8 Variations of grinding force components, surface roughness and radial wheel wear with accumulated stock removed

状態(3)あるいは(2)に近づいたと推察される。

砥石摩耗が進行する過程における研削音をネットワークに入力した結果を表6に示す。実験は10回行い、ハッチングはその最頻値を示している。研削量 $V_w=0$ とは $s_d=100 \mu\text{m/rev}$ の条件でドレッシングした直後の砥石で、“状態(4)”と正しく識別されていることがわかる。また、研削量が増加するにしたがって、識別結果は状態(4)から状態(3)にシフトしている。これは、砥石作業面が徐々に摩耗して砥粒先端がフラットになり、研削音がドレッシング送りが低速なものに類似していくためと考えられる。ただし、 $V_w=10 \text{ mm}^3$ 以降はすべての出力が状態(3)から変化していない。これは、今回用いた砥石の結合度が比較的軟らかく、摩耗と同時に局部的に微小破壊が生じたものと考えている。図は省略するが、比較的結合度が高く摩滅摩耗が主体となる場合には、状態(4)→(3)→(2)と識別結果がシフトした¹²⁾。いずれにしてもドレッサによる砥粒の平坦化と摩耗による砥粒の平坦化とは厳密には異なっており、砥石摩耗の検知を目的とする場合には学習状態を増やすなどの対処が必要となる。

以上のことから、本研究で作成したネットワークには限定した条件下ではあるが、砥石の摩耗状態をもある程度認識する能力があると言え、この特性を利用すると、目直し状態から砥石寿命の識別にまでネットワークの適用範囲を拡張することが可能になると考えられる。

5. 結 言

在来ビトリファイドボンドA系砥石に対し、研削時に発生する研削音の特徴をニューラルネットワークを用いて学習し、砥石作業面の状態をインプロセスで識別する手法を提案した。以下に、本研究で得られた結果を示す。

- (1) ドレッシング条件を変化させて段階的に異なる状態の作業面を生成し、それらの砥石から発生する研削音をニューラルネットワークを用いて学習し、砥石作業面の状態を識別することが可能である。
- (2) このときのネットワーク構造はフィードバック回路のない階層型で、隠れ層数が1層、伝達関数が対数シグモイド

Table 6 Result of discrimination for worn wheel

Input sound V_w (mm ³)	Result of discrimination (Number of outputs in 10 experiments)				
	(1)	(2)	(3)	(4)	(5)
0	0	1	2	7	0
10	0	0	6	0	4
20	0	1	7	1	1
30	0	1	7	1	1
40	0	0	6	0	4
50	0	0	9	0	1

The initial wheel condition is (4): $s_d = 100 \mu\text{m/rev}$

という単純なもので十分である。そして、この構成の下、学習比0.001~0.003、隠れ層セル数150~500の範囲でネットワークは安定して収束する。

(3) ネットワークが学習した状態(基準状態)以外の研削音を入力した場合、ネットワークはその状態に最も近い基準状態を識別結果として出力する。したがって、学習させる状態は必要最小限でよい。

(5) 砥粒の脱落や大きな破碎がなく摩耗が進行している状態の砥石からの研削音を入力した場合、ネットワークの出力はドレッシング送り速度がより小さな基準状態にシフトする。これは、砥粒先端がフラットになると研削音が類似するためであり、限定した条件下ではあるが、作成したネットワークは砥石の摩耗を認識する能力があると言える。

謝 辞

本研究を行うにあたり、砥石および研削液のご提供を頂いた株式会社ミズホならびに日本グリース株式会社の各社に謝意を表します。なお、本研究の一部は、文部省科学研究費補助金(平成10年度、基盤研究(C)、課題番号10650117)を得て行われたことを付記する。

参 考 文 献

- 1) 松井正己, 田牧純一: 砥石表面トポグラフィの測定に関する研究—触針法, 精密機械, 50, 4 (1984) 672.
- 2) 安井平司, 津和秀夫: 砥石作業面性状の定量化に関する研究(第1報)一切れ刃分布, 精密機械, 40, 8 (1974) 639.
- 3) J. Verkerk and T. H. Delft: Final Report Concerning CIRP Cooperative Work on the Characterization of Grinding Wheel Topography, Annals of the CIRP, 26 2 (1977), 385.
- 4) 細川 晃, 安井平司, 鐘尾幸久, 佐藤 郁: 画像解析による砥石作業面の評価(第1報)—砥粒および切れ刃摩耗面分布のポストプロセス測定, 精密工学会誌, 62, 9 (1996) 1297.
- 5) 樋口誠宏, 矢野章成: 研削音による加工状態の診断—研削音に関する基礎的研究(第2報), 精密機械, 49, 8 (1983) 1071.
- 6) 山本 晃, 森 和男: 加工音による工具状態インプロセス診断技術—ウェーブレット変換を用いた多刃工具の以上検出, 広島県立東部工業技術センター研究報告, 9 (1996) 64.
- 7) 謝 榮哲, 稲崎一郎: AEを利用した目直しおよび研削プロセスの監視, 日本機械学会論集(C編), 51, 468 (1985) 2174.
- 8) 佐久間邦郎, 岡島健一, 上田隆司: ホーニング音の研究—ニューラルネットワークによる監視システムの構築, 精密工学会誌, 67, 5 (2001) 814.
- 9) 河村末久, 矢野章成, 樋口誠宏, 杉田忠彰: 研削加工と砥粒加工, 共立出版, 東京, (1998) 121.
- 10) 例えば, 合原一幸: ニューロ・ファジ・カオス, オーム社, 東京, (1995) 60.
- 11) 菊池豊彦: 入門ニューロコンピュータ, オーム社, 東京, (1989) 39.
- 12) 眞下和史, 細川 晃, 山田啓司, 上田隆司: 砥石作業面性状のインプロセス評価に関する研究—(第3報)研削音による砥石作業面性状識別法の適用範囲, 2001年度精密工学会秋期大会学術講演会講演論文集, 500.