

研削音による砥石作業面性状の識別
- 超砥粒砥石への適用 -

金沢大学大学院 佐藤孝志
金沢大学工学部 細川 晃, 山田啓司, 上田隆司

1. 緒言

研削加工では、砥石作業面の状態によって加工精度や仕上げ面性状が大きく変化するため、その測定と評価は極めて重要となる。本研究は、研削加工時に発生する研削音の特徴をニューラルネットワークによって学習し、砥石作業面の状態をインプロセスで識別することを目的としている。前報ではA系砥石を対象としてあらかじめ段階的に異なるいくつかの作業面を生成し、その砥石からの発生音を学習して、実際の研削時に識別することに成功した¹⁾。そこで本報では、高硬度鉄系材料の研削加工に最も多用されているレジンボンドCBN砥石に対して、本手法の有効性を検証した。

2. 砥石の状態を評価するためのパラメータ

無気孔型砥石であるレジンボンドCBN砥石では、砥石作業面の状態を表すパラメータとして、チップポケット深さ h_p を採用した。ここで h_p とは砥粒先端からボンド面までの平均的な深さのことで、砥石の切れ味に大きく影響する。本研究では、触針法によって砥石周方向の砥石断面プロフィールを測定し、得られたプロフィールから h_p を算出している。

3. 実験方法

3.1 ニューラルネットワークの構築 本実験では、メタルボンドダイヤモンドツールによって形直した後、ロータリドレッサによってチップポケットを生成し、識別すべき各基準状態を構築した。表1に設定した基準状態と実際に生成された状態を示す。表1に示すように、状態(1)は $h_p=10\mu\text{m}$ 、(2)は $20\mu\text{m}$ 、(3)は $25\mu\text{m}$ を目標とした。表1に示す基準状態の砥石を用い、表2に示す実験条件で研削を行ったときの研削音の周波数成分を表3に示すネットワークに入力し、ネットワークの学




Fig.1 Schematic illustration of experimental arrangement

Table 1 Surface conditions of the CBN wheel

Condition No. N_d	Average depth of chip pocket h_p μm		
	Target value	Reference	Experiment
(1)	10	10.4	9.9
(2)	20	20.1	19.8
(3)	25	25.4	24.1

Table 2 Experimental conditions

Grinding wheel	CBN140N75B (200×10×31.75 mm)
Workpiece	Hardened SKD11 (HV800)
Length	l_w 50 mm
Width	b_w 8 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)

習を行った。図1に実験装置を示す。

3.2 識別実験 学習した基準状態と同程度の h_p になるように砥石を再ドレッシングし、その砥石からの研削音を入力信号として、学習を終えたネットワークに入力し識別実験を行う。

4. 実験結果

4.1 砥石作業面の確認 表1に示す3つの作業面状態で研削したときの研削抵抗と工作物仕上げ面粗さを図2に示す。図の()は基準状態であり、()が識別実験の入力状態の値である。図より、基準状態と入力状態で、研削抵抗、工作物仕上げ面粗さともに大きな差はなく、両者はほぼ同様の作業面が得られていることがわかる。したがって、このときの研削音を入力して、正しく識別された場合、構築したネットワークはレジンボンドCBN砥石にも適用できるといえる。

4.2 識別結果 表4に識別結果を示す。10回の入力に対し、どの状態に何回出力したかを示している。表にみるように、すべての状態で10回すべてがそのときの作業面の状態を正しく示す結果を示した。なお、表に示した結果は最も識別率の良かった研削音の周波数成分10~15kHzを使用したものである。このことから、このネットワークはレジンボンドCBN砥石においても、異なる作業面を識別する能力があるといえる。

5. 結言

研削音の特徴をニューラルネットワークによって学習することによって、レジンボンドCBN砥石の作業面の状態をインプロセスで識別することが可能である。

参考文献

- 1) 細川, 眞下, 他: 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), 2001年度精密工学会秋季大会講演論文集, (2001) 500.

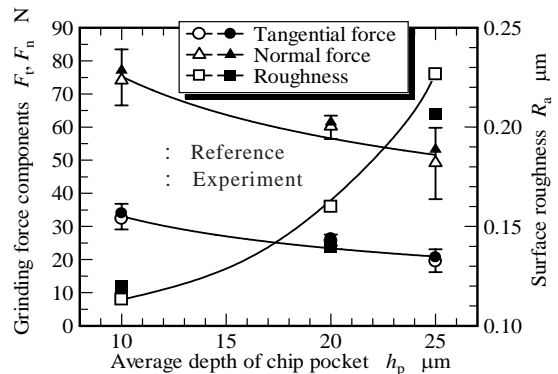


Fig.2 Variations of grinding force components and surface roughness with depth of chip pocket

Table 3 Parameters of the 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	350
Number of neurons in output layer	3
Learning rate	0.0035
Error goal	Sum-square error = 0.1

Table 4 Result of discrimination for CBN140N75B wheel

N_d	h_p ($\mu\text{m}/\text{rev}$)	Result of discrimination (Number of outputs in 10 experiments)		
		(1)	(2)	(3)
(1)	10	10	0	0
(2)	20	0	10	0
(3)	25	0	0	10