

# 旋削工具異常状態の Radial Basis Function ネットワークを利用した判定手法

三好由記博\*

## Abnormal state judgement for the turning tools by using the Radial Basis Function Network

Yukihiro MIYOSHI\*

**Synopsis:** A method to judge the abnormal tool states during the turning operation is presented. “Self-Organizing Feature Maps”, one of the unsupervised learning system, appeared to be an effective method to select a set of feature signals which can be used to identify the tool state. A simple and understandable network, which consists of the “Gaussian Radial Basis Function”, is proposed as the system to judge the abnormal tool states classifying the feature signals. Results of the verification using the cutting test data showed the usefulness of the proposed method for the tool abnormal state judgement.

**Keywords:** abnormal state judgement, turning tool, feature signal, radial basis function network, self-organizing feature maps

**要旨:** 旋削加工中の工具異常状態を判定するための手法を提案した。工具状態同定に利用する特徴信号の選択手段として、教師なし学習システムのひとつである“Self-Organizing Feature Maps”が有効であった。特徴信号を分類して工具状態を判断するシステムとして“Gaussian Radial Basis Function”で構成した簡単かつ理解しやすいネットワークを提案した。切削実験データを使った検証の結果、工具異常状態判定手法としての有効性が示された。

**キーワード:** 異常状態判定, 旋削工具, 特徴信号, radial basis function ネットワーク, self-organizing feature maps

### 1. はじめに

旋削加工中の工具摩耗あるいは工具欠損を加工中に検出するための手法<sup>1)</sup>は既に多数報告されているが、必ずしも加工現場で広く使われているわけではない。その最大の原因は信頼性にあると考えられる。信頼性を上げるためには複数のセンサ信号を用いるのがよいとされているが、その信号選択の適切な方法論が確立しているわけではない。また、加工現場に受け入れられ、かつ種々の加工で利用可能な手法であるためには、工具判定の内容が理解しやすいものでなくてはならない。複数の信号をパターン分類する手法としてニューラルネットワークは

よく使われる手法であるが、最も代表的なシグモイド関数とバックプロパゲーションを使った多層ニューラルネットワークはネットワークの内部状況を外から評価しにくくブラックボックスとして扱わざるを得ない。本研究では、工具異常状態判定に関する多数の特徴信号の中から適切な組合せを選択する方法として、教師なしの分類手法である Self-Organizing Feature Maps を利用した方法を提案し、また内容の理解が容易な工具異常状態判定手法として Gaussian Radial Basis Function を応用した簡単なネットワークを提案して、工具摩耗あるいは工具欠損に対してその有効性を確認することを目的とする。

### 2. 切削実験

横フライス盤ベッド上に固定した圧電型工具動力計に横切刃角 $15^\circ$ の超硬スローアウェイバイトを取付け、さらに、3軸の加速度センサと AE センサを取付けて、

\* 工学部機械工学科 教授 工学博士  
Dept. of Mechanical Engineering, Professor, Dr. of Engineering

AISI1055材の旋削実験を行い、工具異常状態判定手法の確立およびその検証に使用するデータを取得した。各切削実験中に、工具動力計で検出した切削力の3成分、 $F_x$  (送り分力),  $F_y$  (背分力),  $F_z$  (主分力), 加速度センサで検出した  $x, y, z$  方向の加速度信号  $a_x, a_y, a_z$  および AE センサからの AE 信号実効値  $A_e$  を、それぞれサンプリングレート10 kHz でサンプリングし、マイクロコンピュータに取りこんだ。実験には、欠損したチップを8個、摩耗したチップを11個、異常のないチップを14個使用し、欠損したチップでの切削実験を23回、摩耗したチップでの切削実験を23回、異常のないチップでの切削実験を23回、合計69回の切削実験を行った。

69回分の切削実験データから表1に示す33回(欠損したチップ、摩耗したチップ、異常のないチップ、各々の切削実験11回づつ)の実験データを選んで工具異常状態判定手法の確立に使うこととした。また、表3に示した残り36回の実験データは工具異常状態判定手法が確立した後に、その検証に使うこととした。なお、表1、表3には、各切削条件ごとに、使用した欠損チップのノーズ部分の欠落部高さ、摩耗チップの逃げ面摩耗幅  $VB$  および異常のないチップの使用個数を併記した。なお図1には、本研究で以下に現れる切削信号、各種特徴信号と提案手法との関連をまとめて示した。

Table 1 Experiments for the candidates of the feature signals (33 cuttings)

Depth of cut mm	Feed mm/rev	Cutting speed m/min	Tool with fracture	Tool with wear	Tool with no defect
			Lost height at the nose radius mm	Flank wear land width VB mm	Number of tools
0.76	0.12	95-100	1.5, 1.6, 1.7	0.5, 0.8, 0.9	4
0.51	0.24	90-95	0.9, 1.3, 1.7, 2.1	0.7, 0.9, 1.0, 1.2	3
0.51	0.12	115-120	1.6	0.2, 1.2	1
0.51	0.24	115-125	1.3, 1.5, 1.8	0.9, 1.0	3

Table 2 Effective Feature signals selection by "Self-organizing feature maps"

Number of features used, $d$	Number of data assigned to incorrect group, $n_e$	Features used for "Self-organizing" $y_i^{[1]}$							
		Related to force signals			Related to acceleration signals			AE	Other features used in other combination
7	2	$\zeta_{xi}$	$\zeta_{yi}$	$r_{yzi}$	$S_{yi}$	$\epsilon_{xi}$	$\epsilon_{zi}$	$\bar{A}_e$	$S_{zi}$
	3	$\zeta_{xi}$	$\zeta_{yi}$	$r_{yzi}$	$\epsilon_{xi}$	$\epsilon_{yi}$	$\epsilon_{zi}$	$\bar{A}_e$	
	3	$\zeta_{xi}$	$\zeta_{yi}$	$r_{yzi}$	$S_{yi}$	$\epsilon_{xi}$	$\epsilon_{zi}$	$\bar{A}_e$	
6	2	$\zeta_{xi}$	$\zeta_{yi}$	$r_{yzi}$	$S_{yi}$	$\epsilon_{xi}$	$\epsilon_{zi}$	$\bar{A}_e$	$\zeta_{zi}, S_{zi}, \epsilon_{yi}$
	2	$\zeta_{xi}$	$\zeta_{yi}$	$r_{yzi}$	$S_{yi}$	$\epsilon_{xi}$	$\epsilon_{zi}$	$\bar{A}_e$	
	3	$\zeta_{xi}$	$\zeta_{yi}$	$r_{yzi}$	$\epsilon_{xi}$	$\epsilon_{zi}$	$\bar{A}_e$		
5	2	$\zeta_{xi}$	$\zeta_{yi}$	$r_{yzi}$	$S_{yi}$	$\epsilon_{xi}$	$\epsilon_{zi}$	$\bar{A}_e$	$\zeta_{zi}, S_{zi}, S_{xi}, S_{yi}, S_{zi}, \epsilon_{xi}, \epsilon_{yi}$
	2	$\zeta_{xi}$	$\zeta_{yi}$	$r_{yzi}$	$S_{yi}$	$\epsilon_{xi}$	$\epsilon_{zi}$	$\bar{A}_e$	
	3	$\zeta_{xi}$	$\zeta_{yi}$	$r_{yzi}$	$\epsilon_{xi}$	$\epsilon_{zi}$	$\bar{A}_e$		
4	2	$\zeta_{xi}$	$\zeta_{yi}$	$r_{yzi}$	$S_{yi}$	$\epsilon_{xi}$	$\epsilon_{zi}$	$\bar{A}_e$	$\zeta_{yi}, \zeta_{zi}, S_{xi}, S_{yi}, S_{zi}, \epsilon_{yi}$
	3	$\zeta_{xi}$	$\zeta_{yi}$	$r_{yzi}$	$\epsilon_{xi}$	$\epsilon_{zi}$	$\bar{A}_e$		
	3	$\zeta_{xi}$	$\zeta_{yi}$	$r_{yzi}$	$S_{yi}$	$\epsilon_{xi}$	$\epsilon_{zi}$	$\bar{A}_e$	
3	3	$\zeta_{xi}$	$\zeta_{yi}$	$r_{yzi}$	$S_{yi}$	$\epsilon_{xi}$	$\epsilon_{zi}$	$\bar{A}_e$	$\zeta_{yi}, \zeta_{zi}, \epsilon_{yi}, \epsilon_{zi}$
	4	$\zeta_{xi}$	$\zeta_{yi}$	$r_{yzi}$	$S_{yi}$	$\epsilon_{xi}$	$\epsilon_{zi}$	$\bar{A}_e$	
	4	$\zeta_{xi}$	$\zeta_{yi}$	$r_{yzi}$	$S_{xi}$	$\epsilon_{xi}$	$\epsilon_{zi}$	$\bar{A}_e$	
2	4	$\zeta_{xi}$	$\zeta_{yi}$	$r_{yzi}$	$S_{xi}$	$\epsilon_{xi}$	$\epsilon_{zi}$	$\bar{A}_e$	
	5	$\zeta_{xi}$	$\zeta_{yi}$	$r_{yzi}$	$S_{xi}$	$\epsilon_{xi}$	$\epsilon_{zi}$	$\bar{A}_e$	
	6	$\zeta_{xi}$	$\zeta_{yi}$	$r_{yzi}$	$S_{xi}$	$\epsilon_{xi}$	$\epsilon_{zi}$	$\bar{A}_e$	

Table 3 Experiments for the verification of the proposed method (36 cuttings)

Depth of cut mm	Feed mm/rev	Cutting speed m/min	Tool with fracture	Tool with wear	Tool with no defect
			Lost height at the nose radius mm	Flank wear land width VB mm	Number of tools
0.76	0.12	95-100	0.9, 1.3, 1.8, 2.1	0.7, 0.8, 0.9, 1.2	5
0.51	0.24	90-95	1.2, 1.5, 1.5, 1.6	0.5, 0.5, 0.8, 0.8, 0.9, 1.0	3
0.51	0.12	115-120	—	0.8	2
0.51	0.24	115-125	0.9, 1.3, 1.6, 1.7	1.2	2

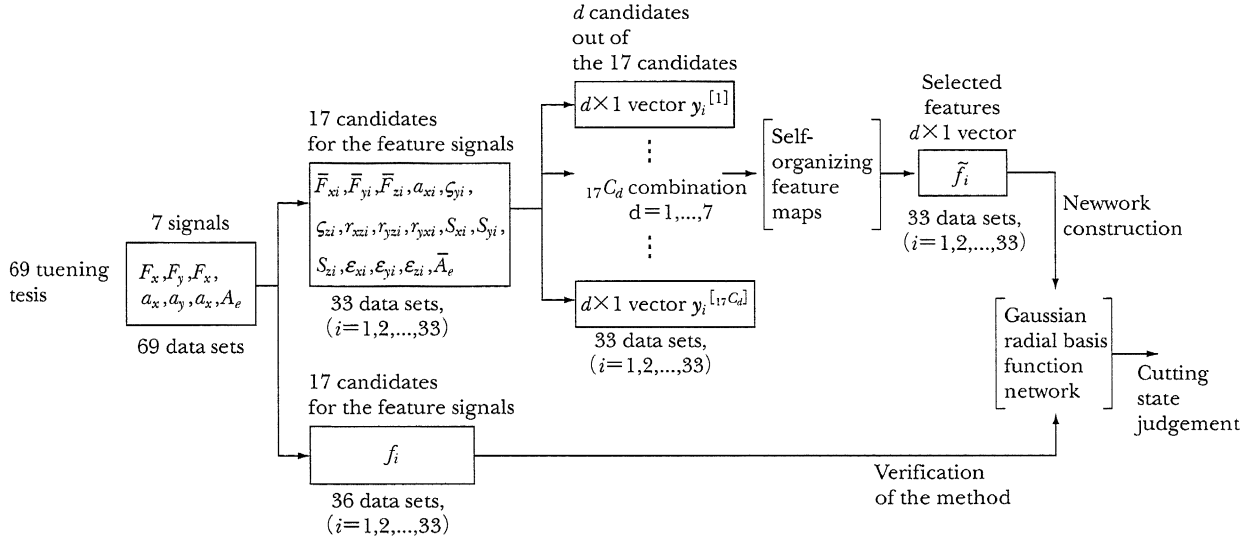


Fig. 1 Cutting signals and feature signals appeared in this research

### 3. 特徴信号の候補

切削実験中に検出した7種類の信号  $F_x, F_y, F_z, a_x, a_y, a_z, A_e$  を前処理して17種類の信号

$$\begin{aligned} & \bar{F}_{xi}, \bar{F}_{yi}, \bar{F}_{zi}, R_i, \zeta_{xi}, \zeta_{yi}, \zeta_{zi}, r_{xzi}, r_{yzi}, r_{yxi}, S_{xi}, S_{yi}, S_{zi}, \varepsilon_{xi}, \varepsilon_{yi}, \\ & \varepsilon_{zi}, \bar{A}_e \quad i=1, 2, \dots, 33 \end{aligned} \quad (1)$$

とし、工具の異常状態を反映した信号(以下、特徴信号)の候補として使用した。ただし、添字  $i$  は  $i$  番目の切削実験中に得られた信号であることを示す。 $\bar{F}_{mi}$ ,  $m=x, y, z$  は切削力成分  $F_m(t)$  の時間平均値を切削面積で割って求めた単位面積あたりの切削力である。 $R_i$  はその切削力の合力  $R_i = \sqrt{\bar{F}_{xi}^2 + \bar{F}_{yi}^2 + \bar{F}_{zi}^2}$  を表している。 $S_{mi}$ ,  $m=x, y, z$  は  $m$  方向の加速度信号  $a_m$  の標準偏差を、 $\bar{A}_e$  は AE 信号の実効値  $A_e$  の時間平均値をそれぞれ示している。その他の9信号はすべて無次元量であり、以下のように定義する。

$$\zeta_{mi} = \frac{\bar{F}_{mi}}{R_i}, \quad m=x, y, z \quad (2)$$

$$r_{xzi} = \frac{\bar{F}_{xi}}{\bar{F}_{zi}}, \quad r_{yzi} = \frac{\bar{F}_{yi}}{\bar{F}_{zi}}, \quad r_{yxi} = \frac{\bar{F}_{yi}}{\bar{F}_{xi}} \quad (3)$$

$$\varepsilon_{mi} = \frac{\sigma_{mi}}{S_{mi}}, \quad m=x, y, z \quad (4)$$

ただし、 $\sigma_{mi}$  は  $m=x, y, z$  方向の加速度信号  $a_{mi}$  に2次の自己回帰モデル  $a_{mi}(t) + \phi_1 a_{mi}(t-1) + \phi_2 a_{mi}(t-2) = e_{mi}(t)$  をあてはめた場合に得られる  $e_{mi}(t)$  の標準偏差である。 $\zeta_{mi}$  は、 $m=x, y, z$  方向の力成分  $\bar{F}_{mi}$  の相対的な大きさを、 $r_{xzi}, r_{yzi}, r_{yxi}$  は  $xz, yz, yx$  各平面内での切削力の向きを、それぞれ代表しており、欠損や摩耗によってチップ切刃の形状が変化すれば、それに応じて値が変化するものと考えられる。 $\varepsilon_{mi}$  は  $m=x, y, z$  方向の加速度信号に自己回帰モデルをあてはめた場合に自己回帰モデルでは表現しきれない信号成分の大きさを代表しており、特に工具の欠損によって切れ刃が複雑な形状になればそれに応じて変化するものと考えられる<sup>2)</sup>。例えば、図2の切削信号 ( $\alpha$  番目の実験データ) は、摩耗したチップを使つての切削実験より得られた信号であり、これを前処理すれば式(1)に対応した17個の特徴信号候補が (3.81, 5.33, 5.25, 8.39, 0.45, 0.63, 0.63, 0.72, 1.01, 1.40, 0.54, 0.38, 0.23, 1.01, 0.90, 0.95, 1.15) と計算される。






Fig. 4 Selected feature signals

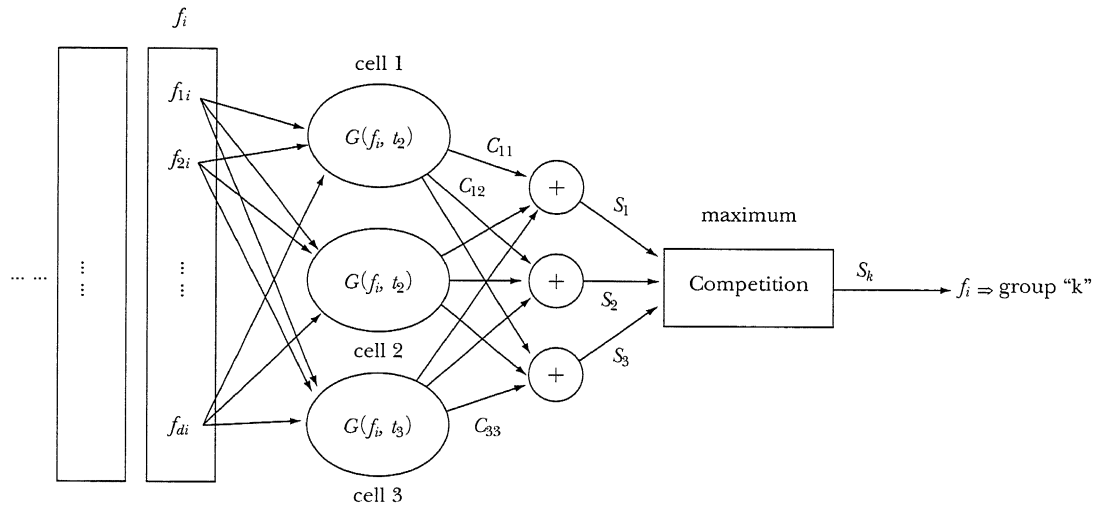


Fig. 5 Network for the tool state judgement (Gaussian radial basis function network)

の加速度信号  $a_y$  の標準偏差  $S_{yi}$ 、背分力-主分力平面内の切削力の向きを表す  $r_{yi}$  などが重要な特徴信号である。表 2 より、今回の特徴信号候補では、誤った割付数  $n_e$  を 2 つより小さくできないこと、また、特徴の数  $d$  を 4 つよりさらに増やしてもグループ分けは改善されないことが分かる。

誤った割付データ数の最小値  $n_e=2$  を、できるだけ少数の特徴信号数  $d$  で実現していることより、本研究では 4 つの特徴信号  $S_{xi}$ ,  $r_{yi}$ ,  $S_{yi}$ ,  $\bar{A}_e$  を以下の判定に用いることとする。図 4 は、この 4 つの特徴信号  $S_{xi}$ ,  $r_{yi}$ ,  $S_{yi}$ ,  $\bar{A}_e$  を 33 個の実験全てについてグラフ化したものである。異常のない工具と摩耗・欠損工具は、 $S_{yi}$ ,  $\bar{A}_e$  の 2 つの特徴信号で識別可能であるが、摩耗工具と欠損工具の識別には、さらに  $S_{xi}$  と  $r_{yi}$  が必要である。

## 5. 工具状態の判定

### 5.1 ネットワークの設定

3 種類の工具状態（正常、摩耗、欠損）のどれかに対応した未知の  $4 \times 1$  特徴信号ベクトル  $f_i$  を工具状態に対応した 3 グループに分類するために、本研究では図 5 に示すように Gaussian Radial Basis Function  $G(f_i, t_k)$ ,  $k=1, 2, 3$  で構成したネットワーク<sup>4)</sup>を使用する。各グループの中心を表す  $4 \times 1$  ベクトルを  $t_k$ 、入力段の重みを表す  $4 \times 4$  行列を  $W_k$  として各セルの出力は式(5)で表される。

$$G(f_i, t_k) = e^D, D = -\frac{1}{2} (f_i - t_k)^T W_k^T W_k (f_i - t_k),$$

$$i=1, 2, \dots, 33 \quad k=1, 2, 3 \quad (5)$$




Fig. 6 Feature signals used for the verification

通常の Radial Basis Function を使ったネットワークは、多数の  $G(f_i, t_k)$  を使って複雑な境界を表現し、その重み付きの和として 1 出力を得るものであるが、図 4 に示す 3 つの工具状態間の関係はさほど複雑ではない。ここでは 3 つの工具状態に対応させて単純に 3 つのセル  $G(f_i, t_1)$ ,  $G(f_i, t_2)$ ,  $G(f_i, t_3)$  を使い、その出力に  $3 \times 3$  の重み行列  $c$  をかけて  $3 \times 1$  の出力ベクトル  $S_i$  を得る。 $S_i$  の 3 要素それぞれが 3 つの工具状態の指標となる。4 つの特徴信号  $s_{xi}$ ,  $r_{yzi}$ ,  $S_{yi}$ ,  $\bar{A}_e$  から成る 33 個の入力をネットワークに入力すれば、式(5)にしたがって  $3 \times 33$  要素の行列  $G = \{G(t_k, f_i)\}$  で表される出力が 3 つのセルから得られる。したがって 33 個の入力に対して、ネットワークからは  $3 \times 33$  要素の行列  $S$  で表される出力が得られる。

$$S = cG \quad (6)$$

ネットワーク構築に際しては、図 4 に示す選定済みの特徴信号  $\tilde{f}_i = (s_{xi}, r_{yzi}, S_{yi}, \bar{A}_e)^T$ ,  $i = 1, 2, \dots, 33$  を、異常のない工具に対応したもの、摩耗工具に対応したもの、欠損工具に対応したものに分割し、それぞれの平均値ベクトル  $t_1, t_2, t_3$  と共分散行列  $\Sigma_1, \Sigma_2, \Sigma_3$  を求め、式(5)の  $W_k^T W_k$  を  $\Sigma_k^{-1}$  で置き換える。さらに、異常のない工具に対応した目標出力を  $\tilde{s}_1 = (1, 0, 0)^T$ 、摩耗工具に対応した目標出力を  $\tilde{s}_2 = (0, 1, 0)^T$ 、欠損工具に対応した目標出力を  $\tilde{s}_3 = (0, 0, 1)^T$  とし、式(6)の  $S$  を  $\tilde{S} = \{\tilde{s}_i\}$  で置き換えて、式(7)より  $c$  を定める。

$$c = (G^T G)^{-1} G^T \tilde{S} \quad (7)$$

以上より、各グループの中心  $t_1, t_2, t_3$ 、重み行列  $W_k^T W_k = \Sigma_k^{-1}$ 、出力の重み行列  $c$  が定まり、工具状態判定のためのネットワークは完成したことになる。なお、計算された  $c$  の値は、

$$c = \begin{pmatrix} 2.77 & 0.00 & 0.00 \\ 0.00 & 2.02 & -0.43 \\ 0.00 & 0.15 & 1.65 \end{pmatrix} \quad (8)$$

となり、最初のセル、すなわち異常のない工具を代表するセルと、他のセルの間には重なりあいが無いものの、 $c_{23}$ ,  $c_{32}$  にやや大きな値があることから、摩耗工具と欠損工具を代表するセルどうしには、やや大きな重なりあいが残っていることがわかる。すなわち、摩耗工具と欠損工具の識別には、どちらともとれない場合があることが分かる。

このネットワークに  $4 \times 1$  特徴信号ベクトル  $f_i$  を入力して工具状態を判定する場合は、 $3 \times 1$  出力ベクトル  $S_i = (S_{1i}, S_{2i}, S_{3i})$  の 3 要素の最大値を求め、それが  $S_{1i}$  なら工具に異常はないと判断し、 $S_{2i}$  なら摩耗工具、 $S_{3i}$  なら欠損工具と、それぞれ判断する。

## 5.2 工具状態判定の検証

ネットワーク構築に使用した図 4 の特徴信号  $\tilde{f}_i = (s_{xi}, r_{yzi}, S_{yi}, \bar{A}_e)^T$ ,  $i = 1, 2, \dots, 33$  を、最初に図 5 のネットワークに入力して、判定手法を確認する。判定結果は表 4 に示すように、33 データ中 30 データについては正しい工具状態を判定したが 3 データについては摩耗と欠損の間で誤判定となった。次に、ネットワーク構築に使用していない表 3 に示す実験より得られた特徴信号  $f_i = (s_{xi}, r_{yzi}, S_{yi}, \bar{A}_e)^T$ ,  $i = 1, 2, \dots, 36$  を図 5 のネットワークに入力して工具状態を判定する。この 36 回の実験より得られた未使用の特徴信号をグラフに示すと図 6 のようになる。判定結果は表 5 のようになり、36 データ中 31 データに対しては正しい工具状態を判定した。残り 5 データ中、4 データについては摩耗と欠損を互いに誤って判定し、1 データについては異常のない工具を摩耗と誤って判定した。

正しい判定の割合は86%、異常有無の判定は97%の正解率であった。

## 6. ま と め

旋削加工中の工具摩耗と工具欠損を検出する手法について検討し以下の結果を得た。

- (1) 工具異常判定に使用する複数の特徴信号の組合せは、Self-Organizing Feature Maps を使って選択可能である。選択の結果、選択する特徴信号数がある域を越えると工具異常状態判定に対する効果が飽和することがわかった。
- (2) Gaussian Radial Basis Function を応用したネットワークにより工具異常状態判定のための単純で分かりやすいシステムが構築可能であった。
- (3) 構築した判定システムに新しいデータを入力して工具異常状態を判定した結果86%の正解率であり、異常有無に限れば97%の正解率であったことから、ほぼ実用的な判定システムが構築できていることが確認でき

た。

謝 辞：本研究の実験データ取得を支援していただいた Wisconsin-Madison 大学 M. F. DeVries 教授をはじめとする関係各位に謝意を表します。

## 参 考 文 献

- 1) L. Dan and J. Mathew, Tool Wear and Failure Monitoring Techniques for Turning—A Review, *Int. J. Mach. Tools Manufact.*, Vol.30, No. 4 (1990), pp. 579.
- 2) 三好由記博, モデルパラメータの変化を使った切削異常状態のインプロセス検知, *精密工学会誌*, 59巻3号(1993), pp. 467-472
- 3) T. Kohonen, *Self-Organization and Associative Memory*, Third Edition, Springer-Verlag, (1989) pp. 130-133
- 4) T. Poggio, F. Girosi, *Networks for Approximation and Learning*, reprinted from *Proc. IEEE*, vol. 78, no. 9, Sept. (1990) pp. 1481-1497, C. Lau edited, *Neural Networks*, IEEE Press, (1991) pp. 91-106.