リカレント形ファジィ推論を用いた研削加工粗さの推定*

小林 太^{*1}, 新井 史人^{*2}, 下島 康嗣^{*3}
福田 敏男^{*4}, 小野田 誠^{*5}, 圓井 則雅^{*5}Online Estimation of Surface Roughness
by Recurrent Fuzzy Inference in Grinding ProcessFutoshi KOBAYASHI, Fumihito ARAI, Koji SHIMOJIMA,
Toshio FUKUDA, Makoto ONODA and Norimasa MARUI

Grinding is frequently used to make smooth surface in the manufacturing system. In grinding process, a measurement of surface roughness is needed for preserving a whetstone and grinding efficiently. However, it is difficult to measure it in process. To reduce processing time, we have to estimate surface roughness in process by online sensing information. In this paper, we propose a multi-sensor fusion system using Recurrent Fuzzy Inference (RFI) for estimating surface roughness. The membership functions of RFI are expressed by Radial Basis Function (RBF) with insensitive ranges. The learning method of this fuzzy model is based on the steepest descent method and incremental learning which can add new fuzzy rules. We apply proposed multi-sensor fusion system to online estimation of surface roughness in grinding process.

Key Words: Sensor Fusion, Fuzzy Inference, Radial Basis Function, Grinding Process, Surface Roughness

1. はじめに

研削加工は加工精度を容易に得ることができる加工法として機械部品・電気部品などの製造工程に使用されている。現在、研削加工においてCBNなどの超砥粒砥石の使用により加工工程の無人化が進んでいる。超砥粒砥石は長寿命であるが、ドレッシング間隔がオペレータの経験により決定されており、従来の砥石に比べランニングコストは高い。また、砥石の摩耗・脱落などの変化に対応して加工状態・加工精度の変化が大きくなる。超砥粒砥石の経済的な適用のためには、砥石の摩耗・脱落による加工精度の劣化の検出と、それを修正するための的確なドレッシング時期の決定や、砥石精度の劣化を踏まえた加工プロセス制御によって加工効率を最適化する必要がある。しかし、内面研削等では砥石の加工精度を研削加工中に計測することは困難であり、研削加工状態を複数のセンサで

計測し、加工精度を推定する方法が必要とされている⁽¹⁾⁽²⁾。

現在、センサにはさまざまな種類があるが、測定原理が異なっているため、得られる計測情報や必要とされる計測時間はさまざまである。研削加工において砥石の加工精度を推定するためには、複数のセンサの計測情報が必要であり、これらの情報を統融合する必要がある。従来より我々はファジィ推論を適用した複数センサ統融合システムを提案し、良好な結果を得てきた^{(3)~(6)}。

ファジィ推論は工学・医学・社会学など数多くの分野で実用化されており、人の知識や経験をファジィルールとして表現できるという利点をもつ。しかし、前件部と後件部のメンバシップ関数の形状およびファジィルールはオペレータにより試行錯誤的に決定されており、このため、ファジィ推論の設計は多くの時間を要し、適切なファジィ推論を詳細に設計するのは困難である。この問題を解決するためにファジィ推論に対する学習法が提案されてきた。学習にバックプロパゲーション法(BP)⁽⁷⁾を適用したファジィニューラルネットワーク(FNN)⁽⁸⁾⁽⁹⁾、ラジアル基底関数(RBF)を用いた学習形ファジィコントローラ⁽¹⁰⁾、遺伝的アルゴリズム(GA)を用いてメンバシップ関数およびファジィ

* 原稿受付 1997年6月20日。

^{*1} 名古屋大学大学院 (☎ 464-8603 名古屋市千種区不老町 1)。^{*2} 正員, 名古屋大学大学院工学研究科。^{*3} 正員, 名古屋工業技術研究所 (☎ 462-8510 名古屋市北区平手町 1)。^{*4} 正員, 名古屋大学先端技術共同研究センター。^{*5} NTN(株)生産技術研究所 (☎ 438-8510 磐田市東貝塚 1578)。

ルールを生成するファジィコントローラ^{(11)~(15)}, その他さまざまな方法⁽¹⁶⁾が提案されている。これらの方法は, オペレータが試行錯誤的に決定していたメンバシップ関数の形状を学習により自動的に獲得していくというものである。これらの学習法は学習速度が遅く, 精度もよくないといった問題があった。また, これらの学習法では学習前にオペレータがメンバシップ関数の形状やファジィルール数を決定しなければならず, 最適なファジィ推論の構造ではなかった。このため, 片山らはニューラルネットワークで行われている追加学習機能⁽¹⁷⁾をファジィ推論の学習に応用し, 学習中にファジィルールを追加して, 最適なファジィ推論を構成する手法を提案した⁽¹⁸⁾。しかし, 片山らの方法では追加するファジィルールのメンバシップ関数の形状はあらかじめ決まっており, そのため, 学習速度が遅く, 効率のよい学習法ではなかった。また, これらの学習法で用いられているファジィ推論は簡略形のファジィ推論であり, センサ統融合システムに適用した場合, 精度のよい推定が困難であった。

本論文では我々は簡略形ファジィ推論からの出力をファジィ推論のリカレント入力として取扱うリカレント形ファジィ推論を提案する。また, このファジィ推論の学習法に片山らが提案したルール追加形の学習法を適用した学習法を用いる。この学習法では, メンバシップ関数の形状, 後件部の実数値を最急降下法により決定し, 誤差が最大となる学習点にルールを追加することが可能である。ここで, 追加するルールのメンバシップ関数の形状は既存のメンバシップ関数の形状を考慮し, 決定することができ, 効率のよい学習が可能である。

提案するリカレント形ファジィ推論はセンサ統融合システムに適用することにより, リカレント入力をシステムが計測できない状態量として取扱うことが可能である。すなわち, リカレント入力を架空のセンサからの情報として使用できる。ここで, 研削加工粗さを高精度に推定するため, 提案するリカレント形ファジィ推論をセンサ統融合システムに適用し, 実際に加工精度の推定を行う。

2. リカレント形ファジィ推論

2.1 リカレント形ファジィ推論 本論文で提案するリカレント形ファジィ推論の概念図を図1に示す。メンバシップ関数は, 図2に示す不感帯をもつRBFで表現されている。これにより, メンバシップ関数の表現能力が向上する。ここで, a_{nj} , b_{nj} , c_{nj} はメンバシップ関数の形状を決定する係数, I_n はファジィ

Fig. 1 Recurrent fuzzy inference

Fig. 2 Membership function based on RBF

推論の入力およびリカレント入力を表す。

はじめに, ファジィ推論の入力値と出力値のRBFの数学的関係を示す。j番めのファジィルールにおけるi番めの入力のメンバシップ関数は式(1), (2)と表せる。

$$f(x_i) = \begin{cases} -b_{ij}(|x_i - a_{ij}| - c_{ij})^2 & (|x_i - a_{ij}| \geq c_{ij}) \\ 0 & (|x_i - a_{ij}| < c_{ij}) \end{cases} \quad \dots\dots\dots (1)$$

$$\mu_{ij} = \exp \{f(x_i)\} \quad \dots\dots\dots (2)$$

ここで, μ_{ij} はi番めの入力に対するj番めのファジィルールの適合度を表す。また, j番めのファジィルールにおけるo番めのリカレント入力のメンバシップ関数は同様に式(3), (4)と表せる。

$$f(y_{t-o}) = \begin{cases} -b_{oj}(|y_{t-o} - a_{oj}| - c_{oj})^2 & (|y_{t-o} - a_{oj}| \geq c_{oj}) \\ 0 & (|y_{t-o} - a_{oj}| < c_{oj}) \end{cases} \quad \dots\dots\dots (3)$$

$$\mu_{oj} = \exp \{f(y_{t-o})\} \quad \dots\dots\dots (4)$$

ここで, μ_{oj} はo番めのリカレント入力に対するj番めのファジィルールの適合度を表す。

また, j番めのファジィルールの適合度および出力値は式(5), (6)と表される。

$$\mu_j = \prod_i \mu_{ij} \cdot \prod_o \mu_{oj} \quad \dots\dots\dots (5)$$

$$y_t = \frac{\sum_{j=1}^J \mu_j \cdot w_j}{\sum_{j=1}^J \mu_j} \quad \dots\dots\dots (6)$$

ここで, w_j はファジィルールの後件部実数値である。

2.2 リカレント形ファジィ推論の学習法 本論文で提案するリカレント形ファジィ推論の学習は図3に示したルール追加形学習アルゴリズムにより行う。

Fig. 3 Procedure of incremental learning

本学習アルゴリズムでは、まずリカレント形ファジィ推論のルールの学習を最急降下法により行う。このときの誤差関数は式(7)に示す出力の二乗誤差を用いる。

$$E_t = \frac{1}{2} \{y_t - y_t^*\}^2 \quad \dots\dots\dots (7)$$

ここで、 y_t , y_t^* は t 番めの学習データに対する出力値、目標出力値を表す。

後件部実数値の更新は式(8)に示すように行う。また、前件部のメンバシップ関数は式(1)の a_{nj} , b_{nj} , c_{nj} の式(9)~(11)により更新する。

$$w_j = w'_j - k_w \frac{\partial E_t}{\partial w_j} \quad \dots\dots\dots (8)$$

$$a_{nj} = a'_{nj} - k_a \frac{\partial E_t}{\partial a_{nj}} \quad \dots\dots\dots (9)$$

$$b_{nj} = b'_{nj} - k_b \frac{\partial E_t}{\partial b_{nj}} \quad \dots\dots\dots (10)$$

$$c_{nj} = c'_{nj} - k_c \frac{\partial E_t}{\partial c_{nj}} \quad \dots\dots\dots (11)$$

ここで、 k_w , k_a , k_b , k_c は学習係数を表す。

次に、新しいファジィルールを追加するかどうかの判断として、誤差が最大となる学習点に注目する。その学習点において最も高いファジィルールの適合度を探索し、その値を λ とする。新しいファジィルールは式(12)を満足したときに追加される。

$$\begin{cases} E_t > Th_E \\ \lambda < Th_l \end{cases} \quad \dots\dots\dots (12)$$

ここで、 Th_E , Th_l はオペレータによりあらかじめ決定される閾値である。新しいファジィルールのメンバシップ関数の形状は λ により式(13)のように計算される。

(a) The fitness value of the other rule is low

(b) The fitness value of the other rule is high

Fig. 4 Generation of the new fuzzy rule

Fig. 5 Increment of new fuzzy rule

Fig. 6 Multi-sensor fusion system using RFI

$$\left. \begin{aligned} a_{ij+1} &= x_i \\ a_{oj+1} &= y_{t-o} \\ b_{ij+1}, b_{oj+1} &= 100.0 \times \lambda \\ c_{ij+1}, c_{oj+1} &= \frac{1-\lambda}{C} \end{aligned} \right\} \quad \dots\dots\dots (13)$$

ここで、 x_i , y_{t-o} は誤差が最大となる学習点での値、 C はオペレータによってあらかじめ決定される係数である。既存のファジィルールの適合度が低い場合、図4(a)のように不感帯は広く、傾きが緩やかなメンバシップ関数が生成される。反対に、既存のファジィルールの適合度が高い場合、図4(b)のように不感帯は狭く、傾きが急なメンバシップ関数が生成される。すなわち、図5に示すように適合度が低い場合既存のルールとの距離が遠くなり、適合度が高い場合既存のルールとの距離が近くなるため、追加するファジィルー

ルの形状を既存のルール of 適合度に応じて変化させる。

2.3 R-RFM によるセンサ統融合システム 提案するリカレント形ファジィ推論を用いたマルチセンサ統融合システムを図6に示す⁽⁶⁾。この図において、センサからの矢印の長さ、太さはそれぞれのセンサの計測時間と情報量を表している。つまり、矢印が長い場合、そのセンサの計測時間は長く、反対に短い場合には計測時間は短い。また、矢印が太いセンサは細いセンサと比べて情報量が多いことを示している。

図6からリカレント形ファジィ推論のリカレント入力とはセンサ統融合システムに適用した場合、システムがもっていない架空のセンサの入力と考えることができる。そのため、システムは従来のセンサでは計測できない状態量を獲得できる。すなわち、センサ統融合システムに提案したリカレント形ファジィ推論を適用することにより、より精度のよい状態の推定が可能となる。

3. 研削加工粗さの推定

リカレント形ファジィ推論を用いたセンサ統融合システムにより研削加工粗さの推定を行う。研削加工システムの概略図を図7に示す。研削盤はCNC内面研削盤であり、複数のセンサにより加工状態を計測する。砥石はビトリファイドボンドCBN砥石を用いる。研削加工を行なう際の加工条件を表1に示す。実験では、研削動力を研削スピンドルの動力計で、法線方向研削力をクイルきしみとして非接触変位計で、加工中の工作物直径をインプロセスゲージで測定し、おのおののアナログ信号をA/Dコンバータを通してコンピュータに取込む。また、これらの出力値より砥石の切れ味を表すパラメータを計算し、センサ統融合システムへの入力として用いる。計算するパラメータは表2に示した研削除去累積量、仕上げ取り代、仕上げ動力、比研削エネルギー、研削力利用率、研削力比、

ドレッシングリードの7項目である。これらのパラメータはすべて同一時刻に得られる情報であり、また情報量も同一である。リカレント入力はセンサ統融合システムから出力される1時刻前の加工粗さの推定値を用いる。これは、ファジィ推論の学習時間をできるだけ減少させるため、最小限のリカレント入力数による加工粗さの推論を行ったためである。サンプリングタイムは加工物1個を加工する時間と考え、加工物一つを加工した時点での加工粗さの推定を行う。

リカレント形ファジィ推論の学習は図8に示したように1個ごとに仕上げ動力を1.0, 0.8, 0.6, 0.4, 0.2 kWと変化させ加工を行った加工データおよび加工粗さを教師データとした。加工は80個の加工物に対して行い、学習は10000回行った。また、ファジィルールを新たに追加するかどうかの判断は20回ごとに行った。ファジィルールの学習における各学習係数およ

Table 1 Process condition

Grinder	CNC internal grinder	
Object	600 rpm	
	Outside Diameter	62 mm
	Inside Diameter	56 mm
	Width	8 mm
Whetstone	CBN230Q150V	
	20000 rpm	
	Outside Diameter	44 mm
	Width	8.5 mm

Table 2 Performance parameter

Parameter	Unit
Cumulative Stock Removal	mm ³
Stock Removal	μm
Grinding Power	kW
Specific Grinding Energy	kW · sec/mm ³
Work Removal Parameter	mm ³ /sec · N
Grinding Power Ratio	(F _t /F _n)
Dressing Lead	mm

Fig. 7 Grinding system

Fig. 8 Roughness vs. grinding power (Teach data)

び閾値は表3に示したものをを用いた。また、リカレント形ファジィ推論の有効性を示すため、リカレント入力を用いた場合と用いない場合の2種類のセンサ統合システムで加工粗さの推定を行い、比較を行う。ここで、入力データは教師データとは異なるデータを用いる。

図9, 10にリカレント入力を用いない通常ファジィ推論で学習を行い、加工粗さの推定を行った結果を示す。図9は10000回学習を行ったときの誤差の最大値と平均値の場合の変化およびファジィルール数の変化を示している。図9より最終的に22個のファジィルールを作成している。また、図10は得られたファジィ推論を用いて推測した加工粗さ、実際に計測した加工粗さ、そのときの仕上げ加工粗さを示す。

Table 3 Learning parameter

Parameter	Value
k_w	0.08
k_a	0.04
k_b	0.04
k_c	0.04
Threshold of Error	0.0001
Threshold of λ	0.45

Fig. 9 Learning result by fuzzy inference without recurrent inputs

Fig. 10 Estimation result by fuzzy inference without recurrent inputs

次に、提案するリカレント形ファジィ推論を用いたセンサ統合システムによる加工粗さの推定結果を図11, 12に示す。図11は10000回学習を行ったときの誤差の最大値と平均値の変化およびファジィルール数の変化を示している。図11より最終的に17個のファジィルールを作成している。また、図12は得られたリカレント形ファジィ推論により推測した加工粗さ、実際に計測した加工粗さ、そのときの仕上げ加工粗さを示す。

図10, 12を比較してみると、リカレント入力を用いた場合と用いない場合ではリカレント入力を用いたほうがより精度よく加工粗さの推定が行えていることがわかる。このときの加工粗さの二乗誤差の平均および最大値を表4に示す。これによってもリカレント入力を用いると精度のよい加工粗さの推定が可能ながわかる。

次に学習経過を比較してみると、提案したリカレント形ファジィ推論はリカレント入力を用いない従来のファジィ推論と比較して、10000回学習を行ったとき

Table 4 Square error of surface roughness

	Average	Maximum
with Recurrent Input	3.71×10^{-4}	4.05
without Recurrent Input	1.59×10^{-2}	4.04

Fig. 11 Learning result by RFI

Fig. 12 Estimation result by RFI

の二乗誤差の平均, 最大値はさほど変わらないが, 学習が速く行えている。また, 追加したファジィルール数もリカレント形ファジィ推論では少なくなり, 効率のよい学習が行えていることがわかる。

このように提案したリカレント形ファジィ推論により, 研削加工における加工粗さの推定が精度よく, また効率的に行えることを示した。

4. ま と め

本論文で我々はリカレント形ファジィ推論を提案し, センサ統融合システムに適用した。また, リカレント形ファジィ推論の学習に最急降下法を基盤としたルール追加形学習法を提案した。この学習法では, メンバシップ関数の形状, 後件部の実数値を最急降下法により決定し, 誤差が最大となる学習点にルールを追加することが可能である。また, 追加するルールのメンバシップ関数の形状は既存のメンバシップ関数の形状を考慮し, 決定する。また, リカレント形ファジィ推論はリカレント入力をもっており, このため, センサ統融合システムに適用することにより実際には計測できない状態量を考慮した推定が可能である。本論文では, 提案したリカレント形ファジィ推論を用いたセンサ統融合システムを研削加工における表面加工粗さの推定システムに適用した。また, 実際に研削加工を行い, その加工状態からの加工粗さの推定によりリカレント形ファジィ推論による加工粗さの推定の有効性を示した。

提案したリカレント形ファジィ推論ではルール追加形学習法により, ファジィルールの追加が可能である。しかし, 本方法ではファジィルールの追加のみしか行っておらず, 冗長となるファジィルールの統合は不可能である。今後の課題として冗長となるファジィルールの統合を行い, 学習速度の向上および推定結果の向上を考えなければいけない。

本研究は“IMS-SIMON: Sensor Fused Intelligent Monitoring System for Machining”の一環として行われた。関係各位に感謝の意を表す。

文 献

- (1) Inasaki, I., Monitoring Technologies for an Intelligent Grinding System, *VDI BERICHE NR*, 1179

- (1995), 31-45.
- (2) Ivester, R., Optimization of Cylindrical Plunge Grinding by Recursive Constraint Bounding, *ASME DSC*, 1 (1995), 529-537.
- (3) Shimojima, K., ほか 3 名, Multi-Sensor Integration System utilizing Fuzzy Inference and Neural Network, *Robotics and Mechatronics*, 4-5(1992), 416-421.
- (4) Shimojima, K., ほか 3 名, Fuzzy Inference Integrated 3-D measuring System with LED Displacement Sensor and Vision System, *Intelligent and Fuzzy Syst.*, 1-1 (1993), 63-72.
- (5) Shimojima, K., ほか 3 名, Sensor Integration System utilizing Fuzzy Inference with LED Displacement Sensor and Vision System, *Proc. 2nd IEEE Int. Conf. Fuzzy Syst.*, (1993), 59-64.
- (6) 下島康嗣・ほか 2 名, リカレント RBF ファジィ推論を用いたセンサ統融合システム, 第 35 回 SICE 学術講演会, (1996), 567-568.
- (7) Rumelhart, D. E., ほか 2 名, *Parallel Distributed Processing*, 1(1986), 547, MIT Press.
- (8) Horikawa, S., ほか 2 名, On Fuzzy modeling using fuzzy neural networks with the backpropagation algorithm, *Neural Networks*, 3-5(1992), 801-806.
- (9) Higgins, C. M. and Goodman, R. M., Learning Fuzzy Rule-Based Neural Networks for Function Approximation, *IJCNN*, (1992), 251-256.
- (10) Linkens, D. A. and Nie, J., Fuzzified RBF Network-based learning control: structure and self-construction, *IEEE Int. Conf. Neural Networks*, (1993), 1016-1021.
- (11) Whitley, D., ほか 2 名, Genetic Algorithm and Neural Networks: Optimizing Connection and Connectivity, *Parallel Computing* 14 (1990), 347-361.
- (12) Lee, M. A. and Takagi, H., Integrating Design Stages of fuzzy system using genetic algorithm, *2nd IEEE Int. Conf. Fuzzy Syst.*, (1993), 612-617.
- (13) Fukuda, T., ほか 2 名, Structure Optimization of Hierarchical Fuzzy Model Using by Genetic Algorithm, *4th IEEE Int. Conf. Fuzzy Syst. and 2nd Int. Fuzzy Eng. Symp.*, (1995), 295-300.
- (14) Shimojima, K., ほか 3 名, RBF-Fuzzy System with GA Gased Unsupervised/Supervised Learning Method, *Int. Joint Conf. 4th Fuzz-IEEE/2nd IFES*, (1995), 253-258.
- (15) Shimojima, K., ほか 3 名, Hierarchical Control System based on Unsupervised Fuzzy-Neuro System, *IEEE Int. Joint Conf. Neural Networks*, (1995), 1403-1408.
- (16) Nomura, H., ほか 2 名, A self-tuning methods of fuzzy control by decent method, *4th IFSA Cong., Eng.*, (1991), 155-158.
- (17) 福田敏男・ほか 6 名, 新規パターンを追加学習するための新しいニューロンモデル, 計測自動制御学会論文集, 29-3(1993), 356-364.
- (18) Katayama, R., ほか 3 名, Self generating radial basis function as neuro-fuzzy model and its application to nonlinear prediction of chaotic time series, *2nd IEEE Int. Conf. Fuzzy Syst.*, (1993), 407-414.