

不確定オートマトンによる学習制御

北嶋 靖三 浅居喜代治
(大阪市立大学 工学部) (大阪府立大学 工学部)

§1. まえがき

制御対象の特性が未知でかつ多峰性の目的関数をもつ制御系の最適点を探索する方法としてはいろいろあるが、その一つの方法として目的関数の極値を学習的に求める学習制御がある。この学習制御系において、学習動作を行なわせるためには、内部状態の遷移が不確定な不確定オートマトンをコントローラとして用い、その遷移特性を学習によって変化させねばよい。このようにすればオートマトンの内部で一種の自己組織動作が行なわれ、最適点を探索するのに最初は大局的探索が、次いで最適点近傍における局部探索が行なわれて早く最適点を探索することができるようになる。

この不確定オートマトンとしては、状態の遷移が遷移確率によって行なわれる確率オートマトン^{(1),(2)}とメンバシップ関数の概念⁽³⁾によって状態遷移が行なわれるあいまいオートマトン⁽⁴⁾

とが考えられる。ここではこれら二つのオートマトンの学習特性などについて比較検討した結果について述べる。

§2. 確率オートマトンによる学習制御

確率オートマトンはある状態から他の状態への遷移が遷移確率に基づいて行なわれるオートマトンで、次のような二つの形のものが考えられる。その一つは状態遷移が行なわれる際に出力が出される枝出力形のオートマトンで、他の一つは遷移が行なわれたのちにその状態に用意されていくつかの出力の中から出力選択の確率に基づいて一つの出力が出される状態多出力形オートマトンである。これらの確率オートマトンの特性は次式で示される。

(a) 枝出力形確率オートマトン

$$M = \{ S, X, U, \{ P(u/x) \} \} \quad (1)$$

ただし、 $S = \{ s_1, s_2, \dots, s_N \}$: N 個の状態の空でない集合、

$X = \{ x_1, x_2, \dots, x_M \}$: M 個の入力の集合、 $U = \{ u_1, u_2, \dots, u_S \}$: S 個の出力の集合、 $P(u/x)$: $N \times M$ の確率遷移マトリクス。

一入力の場合の確率遷移マトリクスは

$$P(u_i/x_j) = [p_{ij}(u_k/x_j)] \quad \left. \right\} \quad (2)$$

$$\sum_{k=1}^N \sum_{j=1}^M p_{ij}(u_k/x_j) = 1$$

ただし, $u_h \in U$, $x_i \in X$, $h=1, 2, \dots, S$, $i, j = 1, 2, \dots, V$,
 $p_{ij}(u_h/x_i)$: 入力 x_i が加えられたとき, 状態 s_i から状態 s_j
へ遷移が行なわれ, かつ出力 u_h を出す確率, $p_{ij}(u_h/x_i) \geq 0$.

(b) 状態多出力形確率オートマトン

$$M = \{S, X, U, \{P(x)\}, Q(s)\} \quad (3)$$

ただし, S, X, U : (1)式の場合と同様, $P(x)$: $V \times V$ の
確率遷移マトリクス, $Q(s)$: 出力選択の確率マトリクス ($V \times S$)
一入力の場合を考えて.

$$\begin{aligned} P(x_1) &= [p_{ij}(x_1)] \quad , \quad \sum_{j=1}^V p_{ij}(x_1) = 1 \\ Q(s) &= [q_{jh}] \quad \sum_{h=1}^S q_{jh} = 1 \end{aligned} \quad \} \quad (4)$$

これらの確率オートマトンを用いた場合の学習制御系を図 1 に示す。

図において, 制御対象は確率オートマトンの出力に対応した操作量 u_h が加えられると, 出力 x_i を出す。目的関数評価部は u_h および x_i から系の目的関数を計算し, この目的関数の値が最適値に近づいているか(成功といふ)あるいは遷移が, これが(失敗といふ)を判定し, 成功信号あるいは失敗信号を遷移確率修正部へ送る。遷移確率修正部では, これらの信号が加えられると, 成功信号の場合は確率オートマトンの遷移確率が大きくなり, 失敗信号の場合は遷移確率が小さくなるように, 遷移が行なわれた枝の遷移確率を修正する。確率オ-

オートマトンに次の入力が加えられると、新しく修正された確率遷移マトリクスに基づいて遷移が行なわれる。

このような動作が繰り返し行なわれて、制御対象への最適操作量が決定される。また、確率オートマトンの内部では最適操作量が選ばれるような歴または状態を選択する確率が大きくなり、一種の自己組織動作が行なわれることとなる。

これらのオートマトンにおいて、確率の修正は次式で示されると linear reinforcement algorithm によって行なわれる。

$$P_{ij}(n+1) = \alpha P_{ij}(n) + (1-\alpha) \lambda_{ij}(n) \quad (5)$$

$$P_{ik}(n+1) = \alpha P_{ik}(n) + (1-\alpha) \frac{1-\lambda_{ik}(n)}{\nu-1} \quad (6)$$

($k \neq j$)

ただし、

$$\lambda_{ij}(n) = \begin{cases} \frac{I(n)}{I_{\max}} & \text{成功のとき } (I \geq \bar{I}) \\ 0 & \text{失敗のとき } (I < \bar{I}), \end{cases}$$

$I(n)$ ：目的関数の値， I_{\max} ：現在までの I の最大値

この場合 $P_{ij}(n+1)$ 以外の確率はすべて一様に $(1-\lambda_{ij}(n))/\nu-1$ に收めんように修正される。したがって学習の初期においては修正量の変動が大きくなる。この変動を小さくするためには、修正時にかける確率分布に従って次式のように荷重 \bar{w} を付加すればよい。

$$P_{ik}(n+1) = \alpha P_{ik}(n) + (1-\alpha)(1-\lambda_{ik}(n)) \bar{w} \quad (7)$$

($k \neq j$)

ただし、

$$\bar{W} = \frac{P_{ik}(n)}{1 - P_{ij}(n)}$$

また、

$$\bar{W} = \frac{\frac{P_{ij}(n) - P_{ij}(n+1)}{(\nu-1)(1-\alpha)} + P_{ik}(n)}{1 - \lambda_{ij}(n)} \quad (8)$$

とし、

$$\begin{aligned} P_{ik}(n+1) &= \alpha P_{ik}(n) + (1-\alpha) \left\{ P_{ik}(n) + \frac{P_{ij}(n) - P_{ij}(n+1)}{(\nu-1)(1-\alpha)} \right\} \\ &= P_{ik}(n) + \frac{P_{ij}(n) - P_{ij}(n+1)}{\nu-1} \end{aligned} \quad (9)$$

のよろく $P_{ik}(n+1)$ の收れん値を $P_{ij}(n) - P_{ij}(n+1)$ によつて
修正する方法も考えられる。

この linear reinforcement algorithm に用いられてる係数 α は收れんの速さに関するもので、この値が小さければ收れんが速くなる。したがつて、この α の値を系の目的関数の値に対応して変化せらるようすすれば、学習の初期においては α の値が小さく、学習の進行に従つて大きくなることができ、最適点を早く探索することができるとともに、ハントンノスの少ない制御を行なわせることができる。

この考えに基づいて、ここでは α の値を次のように定めていふ。

$$\alpha = 1 - \left| \frac{I(n) - \bar{I}(n)}{\bar{I}(n)} \right| \quad (10)$$

ただし、 $\bar{I}(n)$ ：目的関数の累積平均値

$I(n)$ が $0 < I(n) < \bar{I}(n)$ あるいは $\bar{I}(n) < I(n) < 2\bar{I}(n)$ の範囲にあれば、 α の値は $0 < \alpha < 1$ となり、 $f_{ij}(n+1)$ は入力 $i_j(n)$ に收れんとすることとなる。また、 $I(n) = \bar{I}(n)$ の場合には $\alpha = 1$ となり $f_{ij}(n+1)$ の値は修正されない。

以上述べた学習制御系において、枝出力形確率オートマトンを用いる場合には、枝の遷移確率を上記の方法で修正することにより最適点の探索を行なわせることができる。

また状態多出力形を用いる場合には、遷移が行なわれたのちの状態から一つの出力が選択されることがから、ある出力が選ばれる確率 θ_{jh} は、

$$\theta_{jh} = [\pi_i] [p_{ij}] [g_{jh}] [\eta_h] \quad (11)$$

ただし、 $i, j = 1, 2, \dots, \nu$, $h = 1, 2, \dots, S$,

$[\pi_i]$ ：状態分布ベクトル, $[p_{ij}]$ ：確率遷移マトリクス,

$[g_{jh}]$ ：出力選択マトリクス, $[\eta_h]$ ： h 番目か1の列ベクトル $\begin{bmatrix} 0 \\ \vdots \\ 1 \\ \vdots \\ 0 \end{bmatrix}$,

となり、試行の成功あるいは失敗によって p_{ij} および θ_{jh} の二つの確率が上記の方法で修正される。

この場合の学習特性は、(i) 遷移確率 p_{ij} によってある状態が選ばれ、成功か失敗かによって p_{ij} が (5), (9) および (10) 式を用いて修正される（大局的探索）。(ii) ある状態が選ばれると、その状態内で出力が選択確率 θ_{jh} によって選

ばれる。この場合、この状態における出力に対応した目的関数の平均値を求めるために何回かの探索が行なわれる（局部的探索）。

このように(i)と(ii)とが交互に繰り返されて最適点が探索される。

3. あいまいオートマトンによる学習制御

あいまいオートマトンは筆者らによって提案されたものであり、状態間の遷移がメンバシップ関数（以下MFと略記）に基いて行なわれるものである。この場合も確率オートマトンと同様枝出力形および状態多出力形のものが考えられる。

枝出力形および状態出力形あいまいオートマトンは次のように表められる。

(a) 枝出力形あいまいオートマトン

$$M = \{ S, X, U, \{ F(u/x) \} \} \quad (12)$$

ただし、 S, X, U ：(1)式の場合と同じ、 $F(u/x)$ ： $U \times X$ あいまい遷移マトリクス。

一入力の場合のあいまい遷移マトリクスは、

$$F(u_h/x_1) = [f_{ij}(u_h/x_1)] \quad (13)$$

ただし、 $u_h \in U, x_1 \in X, h=1, 2, \dots, \xi, i, j = 1, 2, \dots, v$,
 $f_{ij}(u_h/x_1)$ ：入力 x_1 がきて出力 u_h を出す場合の、状態 s_i

から状態 s_j への枝による遷移に対する MF, $0 \leq f_{ij}(u_i/x_i) \leq 1$.

(b) 状態多出力形あいまいオートマトン

$$M = \{S, X, U, \{F(x)\}, G(s, u)\} \quad (14)$$

ただし, $F(x)$: $\mathcal{V} \times \mathcal{U}$ あいまい遷移マトリクス, $G(s, u)$:

$\mathcal{V} \times \mathcal{U}$ の出力選択マトリクス。

これらのあいまいオートマトンを用いた学習制御系を図2に示す。

MFの修正法は確率オートマトンの場合と同様 linear reinforcement algorithm を用いていますが、確率オートマトンとは異なり、遷移が行なわれた枝の MF のみが修正される。

$$f_{ij}(n+1) = \alpha f_{ij}(n) + (1-\alpha) I_{ij}(n) \quad (15)$$

ただし,

$$I_{ij}(n) = \begin{cases} I(n)/I_{\max} & \text{成功の場合} \\ 0 & \text{失敗の場合} \end{cases}$$

枝出力形あいまいオートマトンを用いた場合の学習特性は、高次遷移特性を用いた大局的探索に特徴があり、学習が進むに従って探索の範囲が縮小されて最適点が探索される。この場合オートマトン内部では最適探索に寄与した枝の MF は1に、そうでない枝の MF は0に近づくので、明らかに自己組織動作が行なわれていることがわかる。

状態多出力形の場合は、(15)式に示された f_{ij} の修正以外に出力選択の MF の修正が行なわれる。

$$g_{jh}(n+1) = \alpha g_{jh}(n) + (1-\alpha) \lambda_{jh}(n) \quad (16)$$

この場合の学習特性は次のようになる。

(i) どの状態に最適点が存在するかを推定するためには次遷移特性を利用して各状態間を探索する(大局的探索)。この場合図2においてスイッチ S_1 および S_2 は端子 "1" へ接続される。(ii) ある状態に最適点が存在すると推定されたならば、その状態におけるいくつかの出力を探索する(局部的探索)。スイッチ S_1 および S_2 は端子 "2" へ接続される。(iii) ある状態に最適点が存在する可能性が強くなれば、その状態をとり易くする(自己ループの形成)。スイッチ S_1 および S_2 は端子 "3" へ接続される。(iv) ある状態に最適点が存在しないと判定されれば、その状態をとり難くする(淘汰)。スイッチ S_1 および S_2 は "4" に接続される。

§4. シミュレーション実験

以上述べた確率オートマトンおよびあいまいオートマトンを用いた場合の学習制御系のシミュレーション実験を、目的関数の応答面が双峰性のものについて行なった。その結果を図3～図7に示す。

図から明らかなように、確率オートマトンおよびあいまいオートマトンのどちらの場合も局部的最適点を避けて真の最

適点に到達しており、その学習特性は類似している。また状態多出力形オートマトンを用いた場合の方が枝出力形の場合に比べて最適点への到達が速い。あいまいオートマトンと確率オートマトンとを用いた場合を比較すると、あいまいオートマトンの方は最適点へ到達するためのパスが確定なものから次第に確定的なものとなるため速く最適点に到達し、最適点到達後はその点を保持するためのパスが決定されるためにハントングロスが少なくなる。これに対し確率オートマトンの場合は、確率に基づいて遷移が行なわれたためランダム性があり、また遷移が行なわれた枝以外の枝の確率も同時に修正されるため最適点への到達が遅くなる。最適点へ到達したのも、その点以外の点をとる場合があり、ハントングロスが大きくなる。

オートマトンの構造が学習により、 π 変化する様子を検討するため、遷移確率 p_{ij} , f_{ijk} および遷移MF f_{ijl} , g_{jkl} の変化を探索回数を横軸にとって示したのが図8である。これらの場合も linear reinforcement algorithm によると確率またはMFの修正が行なわれるため收束の様子は類似していきが、その速さはMFの方が速く1に收めんとしている。

§5 オートマトン

以上確率オートマトンおよびあいまいオートマトンの2種の不確定オートマトンを学習制御系のコントローラとして用いた場合の学習特性について述べたが、どちらの場合も学習の進行に従って自己組織動作を行ない、局部的最適点を避け、真の最適点に到達している。しかし、確率オートマトンの場合には、確率に基づいて遷移が行なわれたためランダム性があり、また遷移が行なわれた枝以外の枝の確率も同時に修正されるため最適点への到達が遅い。あいまいオートマトンの場合には、学習が進むに従って最適点を離ぶパスが確定的になるため最適点への到達が速く、オートマトン内部における自己組織動作が非常に明らかに現われている。また、演算操作は比較演算のみであるから簡単である。


§6 参考文献

- (1) G.M. McMurtry and K.S. Fu : A variable structure automaton used as a multimodal searching technique, IEEE. Trans. on A.C., AC-11, 3, pp. 379~387, July (1966).
- (2) J.M. Mendel and K.S. Fu : Adaptive learning, and pattern recognition systems, Academic Press, 1970, pp. 393~431
- (3) L.A. Zadeh : Fuzzy sets, Information and control, 8, 3,

pp. 338 ~ 353, June (1965).


(4) 北嶋・清臣：“かのまのオートマトンによる学習制御”，14, 9,

pp. 551 ~ 559, 9月(昭和45年).



S_1, S_2, S_3, S_4, S_5 : Samplers

Fig. 1 Block diagram of learning control system using stochastic automaton.



"S" : Success signal , "F" : Failure signal , S_1 and S_2 :
 Switches , 1 : Global search , 2 : Local search ,
 3 : Self loop , 4 : Selection .

Fig. 2 Block diagram of learning control system
 using fuzzy automaton.






Fig. 3 Number of trials on response surface of objective function.
 (a) Mealy type of stochastic automaton. (b) Moore type of stochastic automaton.

200



STANDARD DEVIATION : 0.1

Fig. 4 An example of results of simulation study
(case of Mealy type of stochastic automaton).





Fig. 5 An example of results of simulation study
(case of Moore type of stochastic automation).






Fig. 7
 • TRIAL POINTS AT STARTING TIME(7 POINTS).
 × TRIAL POINTS AT FINAL STAGE(1 POINT).
 ○ OPTIMUM POINT.
 ◻ LOCAL OPTIMUM POINT.
 △ SADDLE POINT.
 () NUMBER OF TRIALS.
 ○ STATE NUMBER.

Fig. 7

An example of results of simulation study
 (case of Moore type of fuzzy automaton).




Fig. 8 Convergent behaviours of probabilities p_{ij}, q_{jh} and membership functions f_{ij}, g_{jh} .