

# ニューラルネットワークによるクライン＝ ゴールドバーガー・モデルの制御

Control of the Klein-Goldberger Model using Neural Network

釜 国男

Kunio KAMA

## 1. はじめに

二次の目的関数をもつ線形モデルの制御問題については確率的な場合を含めていまや標準的な解法があり、計量経済モデルの制御問題に広く応用されている<sup>1)</sup>。また、二次の損失関数その他さまざまな目的関数をもつ非線形モデルについても線形近似法をはじめ多くの解法が考案されている。しかし数学的な最適制御理論に基づくこれらの方法を適用するには<sup>2)</sup>、人為的変数の定義や非線形方程式のテーラー展開、係数行列の作成など時間と労力を要する非常に面倒な作業を行わなければならない。さらに線形近似によって良い近似解が得られるという保証も一般にはない。確率的な問題になると解を得ることすら容易ではない。このような理由から、中規模ないし大規模モデルに対して最適制御法を適用することは实际的ではなく、これまでのところもっぱら研究目的の小規模モデルに限定されているのが実情である。

本研究ではこうした状況に対処するため従来のアプローチとはまったく異なるノンパラメトリックな制御法を提案し、これを米国経済のクライン＝ゴールドバーガー・モデル（以下ではK-Gモデルと略する）に適用してその有効性を検討する。後述するようにこの方法は煩雑な手作業をほとんど必要としない上、任意の目的関数をもつ線形及び非線形モデルに適用可能で確率的な制御問題も取り扱うことが可能であり、K-Gモデルのみならず現在使われているような実用的な大規模モデルに対しても有効と考えられる。さらに従来の方法が研究者に過重な負担をかけるのとは対照的に、新しい方法では遺伝的アルゴリズム（Genetic Algorithm; GA と略）をコンピュータに実行させて制御システムの最適化を行うので大幅な省力化が可能である。

これまでのアプローチでは計量経済モデルの誘導型係数をもとに計算により制御ルールを導出していたが、新しいアプローチでは階層型ニューラルネットワークへ制御入力をインプットし出力ユニットからのアウトプットを制御変数に割り当てる。このためネットワークの結合係数を最適に設定する問題が生ずるが、これは遺伝的アルゴリズムで解決する。GA は組合せ最適化の手法として様々の

1) 基本的な文献は Chow[3], [4]である。初期の応用例としてクライン戦間期モデルに対する Bogaard=Theil[2]の研究がある。

2) 制御理論の経済学への応用については Kendrick[7]が参考になる。

問題に適用されているが、そのグローバル・サンプリングの特徴を活かしてネットワークのトレーニングにも応用されている<sup>3)</sup>。とくにバックプロパゲーション・アルゴリズムが使用できない制御問題ではGAによる調整が有効と考えられる。そこで初めに階層型ニューラルネットワークとGAについて簡単に説明しておこう。

## 2. 階層型ニューラルネットワークとGAによるウェイト調整

ニューラルネットワークはユニット間の結合の仕方により相互結合型と階層型に大別されるが、後者は図1に示したように適当な数のユニットを含むいくつかの層を連結したものである。入力層、中間層、出力層からなる3層構造のネットワークでは、情報は入力層から入り、出力層へ向かって進み、その間に処理されて出力層から外部へ出力される。3層にそれぞれ  $n_1$ ,  $n_2$ ,  $n_3$  個のユニットが含まれているネットワークへ入力ベクトル  $x =$

3) Whitely=Hanson[10], Montana=Davis[9]など。

$(x_1, x_2, \dots, x_{n1})$  が入力されたとき、各ユニットの入出力関係は次のようになる。

$$\text{入力層: } o_{1i} = x_i \quad i=1, 2, \dots, n_1$$

$$\begin{aligned} \text{中間層: } u_{2j} &= \sum w_{ji} o_{1i} - \theta_{2j} \\ o_{2j} &= f(u_{2j}) \quad j=1, 2, \dots, n_2 \end{aligned}$$


$$\begin{aligned} \text{出力層: } u_{3k} &= \sum w_{kj} o_{2j} - \theta_{3k} \\ o_{3k} &= f(u_{3k}) \quad k=1, 2, \dots, n_3 \end{aligned}$$

ここで、 $w_{ji}$  と  $w_{kj}$  は結合係数で、 $\theta_{2j}$  と  $\theta_{3k}$  はしきい値と呼ばれる。入力層のユニットは単に入力を中間層へ伝達するだけで、それ自身は処理は行わない。中間層と出力層のユニットは前層からの加重和がしきい値より大きいときは1に近い値を出力し、小さいときは0に近い値を出力する。入出力関数  $f(u)$  としては階段関数とシグモイド関数がよく用いられる。しかし、ニューラルネットワークを制御問題へ使用する場合にはこれらの関数では出力が区間  $[0, 1]$  に限定されるので不便である。そこで本研究では、出力層の入出力関数は線形式

$$f(u) = u$$

とする（中間層のユニットはシグモイド関数）。また計算の簡単化のためしきい値はす

図1 3層ニューラルネットワークの構造



べて省略する。なお入力値は次の変換式によりスケーリングを行う。

$$x_i = 1 / [1 + \exp(-x_i)]$$

次に GA について必要な要点のみ記すと<sup>4)</sup>、結合係数は10個の2進数  $x_0 \sim x_9$  で表示し

$$2^9 x_9 + 2^8 x_8 + 2^7 x_7 + 2^6 x_6 + 2^5 x_5 + 2^4 x_4 + 2^3 x_3 + 2^2 x_2 + 2 x_1 + x_0$$

で10進数に変換する。このとき変換した値は0～1023の整数値となるが、このままでは良好な制御は望めないので511を差し引き、さらに問題に応じて100, 50, または30で割る。したがって係数の値域は  $[-5.11, 5.12]$ ,  $[-10.22, 10.24]$ , または  $[-17.03, 17.07]$  で、歩幅は0.01, 0.02, 0.03となる。当然、値域が広がるほど歩幅も大きくなる。ネットワークの構造上、決定すべきウェイトは18個あるので、染色体の長さは180ビットとする。集団のサイズは50個体でエリート戦略を使用し、150世代の最良個体を最終的な解として採用する。また個体の適応度には平均平方誤差率 (RMSE率)

$$\text{RMSE率} = \sqrt{\frac{1}{n} \sum_{i=1}^n \left\{ \frac{100(O_i - O_i^*)}{O_i^*} \right\}^2}$$

の逆数をあてる。ここで、 $O_i^*$ ：目標値、 $O_i$ ：制御値、 $n$ ：制御期間である。

## 2. 制御結果

### 2.1 制御目標

K-Gモデルは20個の内生変数と14個の外

生変数からなる中規模の非線形モデルで、データ期間は戦時を除く1929-1952である<sup>5)</sup>。しかし、新しい制御法を検討するのが主目的のこの研究では戦中、戦後は除き1931-1941年に期間を限定する ( $n=11$ )。提案した方法は二次の損失関数を含む任意の目的関数に対して適用可能であるが、ここでは実質国民総生産と一般物価水準 (GNPデフレーター) を取り上げそれらの安定化制御を行う。具体的にはそれぞれの目標値を設定しモデルの解と目標値との差が最小となるような制御ルールを導出する。GNPの目標値は1929-1941年の実績値にタイムトレンドを当てはめた回帰式から求めた。また同じ期間の平均物価水準を物価の目標値とする。制御変数としていくつか選択できるが、以下では(実質)政府支出と法人税を取り上げる。後者は4つある直接税の中で最も税収が大きいからである。

### 2.2 政府支出の制御

政府支出はモデルの最も重要な外生変数のひとつであり、最初にこの変数を政策変数とした場合について検討する。その際、変数のレベルそのものを制御する方式と変化分を制御する方式の2つが考えられるが、ニューラルネットワークの出力値に上・下限がないのでレベルについて制御を行うことにした。ネットワークへインプットするのは、実質GNPまたは物価の偏差D (目標値-制御値) とその変化分  $\Delta D$  であり、政策のタイムラグを考慮してt期の政府支出  $G_t$  はt-1期の  $D_{t-1}$  と  $\Delta D_{t-1}$  をもとに決定されるものと仮定する。政府支出および法人税以外の外生変数には実績値を代入し、政策変数の値だけを

4) 詳しくは釜[6]参照。

5) Klein=Goldberger[8]参照。モデルは同書90-92ページの戦後のデータを含む再推計版である。

調整する。ニューラルネットワークを調整するにはあらかじめその構造を決めなければならないが、入力層と出力層のユニット数はそれぞれ入力変数および制御変数の数で決まる。一方、中間層のユニット数は自由に決めることができるが、必要以上に増やしても計算時間がかかる割には制御結果は必ずしも良くならない。逆に簡略化し過ぎると時間の節約にはなるが、きめ細かな制御が出来なくなる。こうした点を考慮して試行錯誤の結果、中間層には6ユニットを配することにした。したがって調整すべき結合係数は、入力－中間層に12個、中間－出力層で6個の計18個となる。

以上の設定をもとにGAを実行すると、表1の結合係数が得られる。この表で入力層の1番目の入力所得の制御偏差、2番目はその変化分である。表をみると、各層のすべてのユニットが隣接する層のほとんど全部のユニットとリンクしており、ネットワーク内部の情報の流れはきわめて複雑である。そこで入出力関係だけに注目して（基準化した） $D$ および $\Delta D$ と出力値の関係を表示したものが図2である。ここで $D=0.5$ は目標値と制御値が等しい状態に対応し、前者が後者より大きいとき $D>0.5$ 、小さいとき $D<0.5$ となる。


また $t-2$ 期から $t-1$ 期にかけて偏差が変わらないとき $\Delta D=0.5$ 、（代数的に）増加するとき $\Delta D>0.5$ 、減少するとき $\Delta D<0.5$ となる。政府支出の調整パターンを表す関数曲面は比較的単純な形をしているが、中央部で斜めの線にそって急激に変化しているのが特徴的である。古典的なPI制御に対して、一種の非線形PI制御を実現していると見ることもできる。図3はネットワークを介して政府支出を制御したときのGNPの水準を現実値および目標値（破線）と比較したものである。シミュレーション期間はたまたま米国経済の大変動期にあたり所得は激しい変動を示しているが、対照的に制御値は目標経路にそって直線的に増加し所得の変動はほぼ完全に除かれている。これを数値で示すと、GNPのRMSE率は現実値の10.92%に対して制御値は1.09%と大幅に縮小する。きわめて印象的な結果である。

つぎに政府支出の動きを見てみよう（図4）。実際の政府支出は1931-33年には大不況であるにも関わらず少し削減され、その後は1940年まで着実に増加したが、1941年になると戦争の影響で急増している。一方、制御値は1931年から32年にかけて急拡大して消費と投資の落ち込みをカバーして不況の発生を

表1 結合係数（政府支出によるGNPの制御）

		中 間 層					
		1	2	3	4	5	6
入力層	1	8.98	-9.58	8.66	-7.02	-10.06	-5.18
	2	-9.90	-10.16	0.16	5.22	-10.22	7.20
		中 間 層					
		1	2	3	4	5	6
出力層		6.42	-10.22	9.62	-0.94	0.02	4.50

図2 コントロールマップ (実質 GNP の制御)



防止している。1932年以降は36年の一時的な急増を除くと全体的に一定ないしは漸増気味で推移し、期末にかけて大きく増加するようなことはない。またレベルでも大きな違いが見られ、1941年を除いて制御値が現実値を大きく上回っている。GNPを目標レベルまで引き上げるには支出面からこれだけの刺激策をとる必要があるわけである。なお政府支出のこのような動きはGNP以外の実質変数も安定化させる効果がある。すなわち所得と同

様、消費についても回帰式を当てはめ理論値を基準にRMSE率を求めると、実績値の6.75%に対して政府支出を制御すると1.08%にとどまる。同じく投資は44.73%から13.45%へ、実質賃金は4.08%から2.80%へそれぞれ低下する。しかし実質変数の安定化と引きかえに名目変数の変動はかえって大きくなる。たとえばGNPデフレーターはRMSE率は実績値の5.63%に対して7.98%、名目賃金（時間当り賃金指数）は7.86%から

(10億ドル)

図3 実質GNPの制御結果





図4 政府支出の現実値と制御値

(10億ドル)



12.57%へ増大する。

次に、これまで一定としてきたGAのパラ

メータを実験的に変更した場合について触れ

ておこう。まず結合係数の歩幅を0.01,

0.0125, 0.02, 0.033とすると, GNPのRMSE率はそれぞれ1.61, 1.43, 1.09, 0.99%となる. したがって広い値域を大きな歩幅で探索する方が誤差は小さくなる. 伊庭〔5〕によると, 集団数は50~150がよいとされる. そこで集団数を30, 50, 80, 100としてGAを実行すると, 誤差率は1.26, 1.09, 0.94, 1.00%となる. 個体数を増やしても必ずしも誤差は減少しないことがわかる. またニューラルネットワークの中間層のユニットを4, 8, 10, 12個とすると, 誤差率はそれぞれ1.09, 0.79, 1.23, 0.84%となる. したがってユニットを追加しても制御パフォーマンスの改善は必ずしも望めない. しかしいずれのケースでも, パラメータを変更しても誤差率はあまり変わらないのでパラメータ調整に多くの時間を費やすのは時間の無駄と言える.

所得とならんで物価もマクロ経済政策の重要な目標であり, 通常は物価安定のために金融政策が割り当てられる. しかしK-Gモデルにはめばしい金融政策手段が含まれていないので, 引き続き政府支出で物価を制御することにする. 1929-41年の平均物価水準をターゲットにして, ニューラルネットワークのトレーニングを行うと表2の結合係数が得られる. 制御結果をみると(図5), 現実値

は非常に大きな変動を示しているのに対して制御値の変動はきわめて小さく, 目標水準とほとんど変わらない. すなわちGNPデフレーターはRMSE率は5.63%から僅かに0.63%へ大幅に縮小する. しかも都合の良いことに, 同時に実質変数も安定化する効果がある. たとえば実質消費は6.75%から3.95%, 投資は44.03%から26.47%へ誤差率は減少する. ただしこれは価格・賃金ブロックの定式化が不完全なK-Gモデル特有の現象かも知れない. いずれにしても表2のウェイトを持つネットワークを用いれば物価をほぼ完全にコントロールすることが可能であり, 提案した方法がきわめて有効であることを示している.

### 2.3 法人税の制御

ケインジアン・タイプのK-Gモデルでは, 政府支出とならんで財政政策のもう一方の柱である租税政策は消費や投資支出を通じて生産, 雇用や物価に影響を与える. そこで直接税のうちとくに企業に対する法人税を取り上げ, これを調整してGNPと物価を安定化の問題について考える. 政府支出と同様に最適化アルゴリズムを実行すると, 表3, 4の結合係数が得られる. この場合も制御結

表2 結合係数(政府支出による物価の制御)

		中 間 層					
		1	2	3	4	5	6
入 力 層	1	-3.167	2.167	-11.100	12.067	-12.233	1.500
	2	7.033	-15.833	-16.667	-11.033	0.333	-12.700
		中 間 層					
		1	2	3	4	5	6
出 力 層		12.200	4.900	-7.433	7.300	-3.033	2.433

果はきわめて良好で、実質GNPのRMSE率は2.26%、GNPデフレーターは1.78%となる。ただし、そのためには税収はマイナス、つまり法人税の大幅な払い戻しが必要である。現実の所得を上回る目標水準を達成するには1932年（実績値はマイナス）だけでなく全期間を通じて払い戻しを行わなければならない。もちろん実際にはこうしたことはあり得ないが、モデルの枠内では法人税を唯一の政策手段とする限りマイナスの税収は避けられない。政府支出に比べると誤差は僅かに増加するが、これはモデルの構造上、法人税は家計と企業の可処分所得を通じて間接的に総需要に影響を与えるためと考えられる。

#### 2. 4 政府支出と法人税の同時制御

これまで政府支出と法人税をそれぞれ単独

で調整する比較的簡単な制御問題を取り上げたが、実現可能性という点では両者を同時に制御するのが望ましいであろう。このためニューラルネットワークの構造を変更して出力ユニットを2個に増やし、ひとつは政府支出、もうひとつは法人税に割り当てる。中間層のユニット数を6とすると、合わせて24の結合係数が含まれる。このような設定のもとにGNPをターゲットとして制御を行うと、RMSE率は0.87%と先に示した政府支出を単独で調整する場合とまったく同じ結果となる。しかし法人税の減税を伴うために物価は実績値に比べてむしろ安定化する。すなわちGNPデフレーターのRMSE率は1.92%にとどまり、実績値はもちろん、政府支出だけを制御する場合と比べても低くなる。したがって所得と物価を同時に安定化するには、

表 3 結合係数（法人税によるGNPの制御）

		中 間 層					
		1	2	3	4	5	6
入力層	1	4.967	-16.500	-17.033	-13.500	2.300	5.667
	2	-16.167	5.000	-2.833	-16.833	5.533	-5.033
		中 間 層					
		1	2	3	4	5	6
出力層		2.733	5.667	-7.900	-12.767	-7.100	10.833

表 4 結合係数（法人税による物価の制御）

	中 間 層						
	1	2	3	4	5	6	
入力層	1	-12.900	-16.967	-17.033	-16.267	-16.900	0.433
	2	0.533	8.600	0.133	-16.933	14.967	-4.233
	中 間 層						
	1	2	3	4	5	6	
出力層	13.900	16.567	11.767	-3.167	-0.500	-9.833	



複数の政策手段を組み合わせる適用ポリシー・ミックスの考え方が有効であることが分かる。同じくふたつの政策手段を物価安定のために適用すると、ほぼ完全に目標を達成することが出来る (RMSE 率は0.67%)。

最後に生産と物価を同時に制御する問題を考える。ふたつの政策手段を併用すると、どちらから一方を安定化すると結果的に他方も安

定化するが、ここでは初めから両者の安定化を目指した制御を行う。そのために4つの入力と2つの出力を持つニューラルネットワークを構築し、これを実質GNPとGNPデフレーター各誤差率の和 (逆数) を適応度として遺伝的アルゴリズムでトレーニングした (表5)。この表で入力層の4つのユニットには上から順にGNPの偏差、その変化分、




表5 結合係数 (政府支出と法人税による GNP と物価の制御)

		中間層					
		1	2	3	4	5	6
入力層	1	-3.80	2.63	-5.11	-4.63	3.85	-5.11
	2	-5.03	-0.31	-5.11	-5.08	2.72	-5.11
	3	-5.11	4.52	-5.11	-5.11	3.91	0.01
	4	-5.11	-0.62	1.29	-5.11	-3.91	-0.95
		中間層					
		1	2	3	4	5	6
出力層	1	-5.09	-4.81	-4.07	-5.10	3.92	0.31
	2	-5.03	-3.91	-0.30	3.89	-5.11	-4.07

デフレーターの変動、その変化分が入力される。また出力層の1番目のユニットは政府支出、2番目は法人税に対応する。これをもとに制御を行うと、GNPの誤差率は1.09%、デフレーターは1.50%となる。いずれも低い値であり、しかも両者の合計2.59%はこれまで検討した中で最低である。したがって適当なウェイトをもつ4入力ネットワークを用いることにより、物価を一定水準に保ったまま総生産を目標値に合わせてコンスタントに増やすことが可能である。

## 2. 5 確率的制御

K-Gモデルの研究で知られるアーデルマン兄弟〔1〕は、モデルの動学的特性を検討して外部から確率的なショックを加えると多くの変数で現実に観察されるような循環変動が生じることを示した。つまり景気循環は外生的なショックとそれに対するシステムの反応から生ずるという外生的な循環理論と整合的な結果を得たわけである。こうした見方に立つと確定的な問題よりむしろ確率的な変動を含むような制御問題に取り組むべきである。またこれとは別に、現実の経済システムには絶えずさまざまなショックが加わり、不確実な条件下で政策決定が行われることは明白な事実である。しかし一般に非線形モデルの確率的制御は非常に難しい問題であり、解析的手法で解を求めるのは困難である。他方、解析的手法によらない本稿のアプローチは、計算時間を別にすれば確定的な場合と同様に良い近似解を得ることが可能である。そこで最後に、モデルの外から確率的なショックを加えたときに新しい方法がどの程度有効であるのかチェックすることにした。具体的には

多数の正規乱数（平均ゼロで系列相関なし、分散は残差からの推定値）を発生させ、これを定義式を除く15の構造方程式の右辺に加えながら政府支出によるGNPの安定化制御を行う。このような計算を200回繰り返してRMSE率の平均値（逆数）を求め、これを適応度として誤差率の平均値が最小となるようなネットワークを構成する。なお、ほとんど常に解が得られる確定的なシミュレーションと異なり、確率的なショックを導入すると個体（ネットワーク）によっては収束解が得られない場合があるが、このような個体は致死遺伝子として排除する。表6はこうして得られたニューラルネットワークの結合係数を示す。また図6は、表6の係数から導出した入力と出力値との関係を表している。図によると入力値がともに小さい領域を別にとると、政府支出を決定するのは主として制御偏差のDであることがわかる<sup>6)</sup>。そして $\Delta D$ が小さいときは出力値はほぼ一定となるが、 $\Delta D$ が大きくなるとDに比例して出力は増大する。言うまでもなく確率的なショックの大きさによって内生変数の値は異なるが、ひとつの実現例を図7に示す。政府支出に実績値を代入したときは実質GNPは目標を大きく下回るが、表6の結合係数をもつニューラルネットワークで制御した場合にはほぼ目標経路にそって増加する。この他のケースでも誤差は小さく、RMSE率の平均値は3.62%に止まる。したがってシステムの外部から確率的なショック（アーデルマンのタイプIIのショック）が加わる場合でも、確定的な制御問題と

6) Dと $\Delta D$ がゼロに近いときは出力はマイナスとなるが、現実にはあり得ない領域で無視してもかまわない。

表6 結合係数 (政府支出による GNP の確率的制御)

		中 間 層					
		1	2	3	4	5	6
入力層	1	-12.767	14.967	-2.100	0.200	-16.967	-16.967
	2	-8.500	-8.500	0.033	2.167	-16.633	-16.933
出力層		中 間 層					
		1	2	3	4	5	6
		-17.033	8.667	-12.767	12.833	-10.633	0.033

図6 コントロールマップ (実質 GNP の確率的制御)





図7 実質GNPの確率的制御結果



基本的には同じ方法で優れた政策反応関数を導出できることが分かる。計算時間の制約で物価や法人税については省略したが、政府支出の結果から見てやはり良好な成果が得られるものと予想される。

### 3. 結 論

脳の情報処理機構を模した人工的なネットワークモデルである階層型ニューラルネットワークは、その優れた非線形特性を生かしてパターン認識や関数近似の問題に応用されている。本研究ではそれをマクロ計量経済モデルの制御問題へ適用する方法を提示し、有名なクライン＝ゴールドバーガー・モデルに適用してその有効性を検討した。従来のアプローチが単一のユニットで情報処理を行うのに対して、ここで提示したアプローチでは入力情報は複数のユニットに分散処理され統合

されて出力される。各ユニットは結合係数によって連結され、問題ごとに結合係数の値を適当に変更することで同一のネットワークを繰り返し使用することができる。問題は結合係数をどのように設定するかであるが、通常使用されるバックプロパゲーション・アルゴリズムは教師データがないので使えない。そこで係数の設定は一種の関数最適化の問題であると見なして、遺伝的アルゴリズムによって最適な係数値を探索する方法を取った。この方法は非常に有効で政府支出と法人税を政策目標として比例－微分制御を行うと、誤差率を2%以下に抑えることができる。また確率的な制御問題に対しても適用可能である。さらに目的関数を自由に選べること、従来の方法のように微分情報を必要としないなど多くの優れた特徴を具えている。このように提案した方法は現在の形でもかなり実用性

の高いものであるが、今後さらに以下の点について改善したい。

#### (1) 構造設計

比較的規模が小さく構造も簡単なK-Gモデルでは単純な構造のネットワークで十分であるが、複雑な構造の大型モデルではネットワーク構造の設計が重要な問題となる。ランダムに発生させた構造の中からベストのものを選ぶ方法も考えられるが、これは多くの無駄な計算を含み効率が良くない。それよりは構造の決定にもGAを使い段階的に最適な構造を探索する方が効率的である。具体的には染色体上にネットワークの構造を表現し、それをトレーニングの可能なネットワークに変換して最適な結合係数と誤差を求めて適応度とする。つまり構造と結合係数の二つのレベルでGAを適用するわけである。これは実行可能な方法であり、すでに簡単な問題について応用が試みられている。制御用ネットワークの構造設計にも応用できるであろう。

#### (2) ハイブリッド化

GAは最適解の近傍に近づくのは速いが、局所探索能力が低いという問題がある。この問題を解決する方法として、ヒューリスティック・アルゴリズムとGAを組み合わせることが考えられる。たとえば初期段階をGAで探索し途中からヒューリスティックに切り替えたり、逆に局所解をヒューリスティックで求め局所解の集合に対してGAを適用する。ヒューリスティックとしては山登り法やランダムサーチのような探索法が有効であろう。

#### (3) 動的な突然変異率

GAの実行中に初期収束が起きて進化が停止することがあるが、これを抑制して個体群の多様性を維持するために突然変異率を動的に変化させる対策が考えられる。たとえばニューラルネットワークの焼きなまし法に倣ってははじめは変異率を高くし世代が進むにつれて低くする方法や、一定世代進化が停止したときに変異率を高くする方法が考えられる。

#### (4) 高速化

GAは並列計算を繰り返し行う関係で最終解を得るまでに膨大な計算が必要であり、ソフト面やハード面の工夫により高速化するのが望ましい。GAをソフトウェアで実現する現在のやり方でも計算機の演算能力の向上により計算時間を短縮できるが、より根本的な解決策はGAの演算回路をハードウェア上で実現することである。こうしたハード化の研究はすでに始まっており、簡単な実システムに対してその高速性能が確認されている。計量経済モデルの制御にも応用できる程度にまで実用化されることを期待したい。

#### 参 考 文 献

- [1] I. Adelman and F. Adelman, "The Dynamic Properties of the Klein-Goldberger Model", *Econometrica*, Vol. 27, pp. 596-625
- [2] P. J. M. Boggard and H. Theil, "Macrodynmic Policy-Making: An Application of Strategy and Certainty Equivalence to the Economy of the United States, 1933-36", *Macroeconomica*, Vol. 11, pp. 149-67
- [3] G. C. Chow, "Optimal stochastic Control of Linear Economic systems", *Journal of Money, Credit and Banking*, Vol. 2, pp. 291-302
- [4] \_\_\_\_\_, *Analysis and Control of Dynamic Sys-*

- tems, New York: Wiley, 1975
- [5] 伊庭齐志『遺伝的アルゴリズムの基礎』オーム社, 1994年
- [6] 釜 国男「遺伝的アルゴリズムによるポートフォリオ選択問題の一解法」, 『創価経済論集』第23巻3号, pp. 83-94
- [7] D. Kendrick, "Control Theory with Applications to Economics", in K. Arrow and M. D. Intriligator, eds., *Handbook of Mathematical Economics*, Vol. 1, Amsterdam: North-Holland, 1981
- [8] L. R. Klein and A. S. Goldberger. *An Econometric Model of the United States, 1929-1952*, Amsterdam: North-Holland, 1955
- [9] D. Montana and L. Davis, "Training Feedforward Neural Networks Using Genetic Algorithms", *Proceedings of International Joint Conference on Artificial Intelligence*, Morgan Kaufmann, 1989
- [10] D. Whitely and T. Hanson, "Optimizing Neural Networks Using Faster, More Accurate Genetic Search", in J. D. Schaffer ed, *Proceedings of the Third International Conference on Genetic Algorithms*, Morgan Kaufmann, 1989