長・中・短期記憶を用いた発見的最適化法

正員 村田 純一 (九州大学)

学生員 瀧上 哲司 (九州大学)

正員 平澤 宏太郎 (九州大学)

Heuristic Optimization Using Long, Medium, and Short Term Memories

Murata Junichi, Member, Fuchikami Tetsuji, Student Member, Hirasawa Kotaro, Member (Kyushu University)

An optimization method is proposed for unconstrained optimization problems, including neural network training. To avoid falling into local optima, the method is based on stochastic search and performs diversified and intensified searches alternately. Besides, for more efficient search of the solution space, it utilizes its history of searching which is stored in long, medium and short term memories and controls the diversification and intensification of the search. The method includes minimum number of adjustable parameters aiming at a generic method that does not need much parameter tuning. An example shows that the method can find the global optimum irrespective to the initial solutions.

キーワード：最適化，集中・分散制御，長・中・短期記憶

1. はじめに

従来の連続変数の目的関数の最適値探索法には，主として2つのものがある⁽¹⁾。その1つが勾配法と呼ばれるもので最も一般的である。これは勾配による局所探索が基本であるが，ローカルミニマムに陥りやすいという欠点がある。もう1つがランダム探索，シミュレーティッドアニーリング等に代表される確率的探索法である。しかしこれも無駄な探索を繰り返したり，収束に時間がかかるといった短所が存在する。いずれの手法も問題をはらんでおり一長一短で，最良だとは言いがたい。

本研究では，この最適化という立場に主眼を置き，また関連してニューラルコンピューティング，制御の分野にも及んでいる。

ニューラルネットワークを用いて，制御系を構成する制御器やシステムモデルを実現することを考えた場合，ニューラルネットワークの学習が必要である。そのニューラルネットワーク学習は一般に勾配法で行われている。しかし学習には膨大な時間が必要な上，学習が局所解であるローカルミニマムに収束してしまう可能性も大きい。そこで，現在そのニューラルネットワークの最適化には，ネットワークの複雑化を制限するペナルティ項を学習アルゴリズムに加える方法や，学習を高速化するために勾配情報を慣性項として加える方法等が考えられている。しかし，いずれもローカルミニマム打破のための根本的な解決法とはなっていない。

い。それはまた一般の最適化手法にも通ずる問題である。

以上のような背景を基にして，局所的でない最適値の獲得が本研究の動機となっている。そしてそのための新しくシステマチックに最適化を実行できる手法の確立をねらいつている。

2. 最適解探索の方針

長・中・短期記憶を用いた発見的最適化法の基本的な考え方は，探索点決定の過程に，過去の情報（記憶）を反映させ，より効率的に最適点探索を進めようというものである。図1は，過去の状態，探索点，目的関数値をフィードバックさせて，状態を遷移していく様子を示している。また，点線で表されているパラメータ更新機構は，提案手法にでてくるパラメータ（後に説明されている，記憶の長さを

図1 提案手法の枠組

Fig.1. Frame of Proposed Method

決定する λ 、メンバーシップ関数の形状を決定する D 、 I)を自動的に設定する機構で、将来提案手法に組み込む予定である。

本手法の最も重要な特徴として、集中、分散制御が挙げられる。探索プロセスに、集中的局所的、分散的大域的という2つの側面を持たせ、状況に応じてシステマティックにコントロールして最適化を行なう。

集中(intensification)とは、最適値の存在が有望な領域を局所的に探索することを表し、ローカルミニマムを発見することを狙いとしている。分散(diversification)とは、集中探索をある程度行ったら、探索を大域的に広げることを表し、ローカルミニマムからの脱出を狙いとしている。

探索過程に集中と分散が必要な理由は、そのどちらか片方だけでは、探索が不十分に終わってしまうためである。目的関数の局所的でない最適値を獲得するという事はつまり、大域的最適値を高精度で求めることと換言できる。その目標を達成するためには、2つの方向性が必要である。それは、探索を広範囲に分散させる方向性と、最適値の存在が有望な領域では探索を局所的に集中させる方向性である。集中探索のみでは、局所的には細かく探索可能だが、獲得された解は局所解で終わってしまう危険性が高い。また、分散探索のみでは、探索領域は拡大可能でも、最適解の存在しそうな領域または、狭く複雑な形状の領域探索には密度の低い探索しか実現出来ず、力不足である。そこで、集中と分散を自然に繰り返し、見込みがある時は集中が強化され見込みがない時は分散へ切り替わるようにコントロール出来れば非常に有効である。

また、移動方向に関しても、状況に応じて制御することによって、最適値の存在が望めない範囲への探索点の発散を抑制し、探索点が、最適点へスムーズに向かうようにする。

上述のような点を盛り込んだ提案手法の性質及び特徴から、従来手法のランダム探索法、シミュレーテッドアニーリング等の確率探索法によく見られる、無駄な試行の繰り返しを減少させることが可能であり、また、勾配法で問題となるローカルミニマムに捕まりにくくなるということが期待できる。また、類似の方針「集中化と多様化を効率的に実現する」を持つRasVal⁽⁹⁾と呼ばれる手法があるが、RasValでは、過去の探索成功・不成功情報による間接的な勾配情報を活用している。つまり、現在の探索点の近傍の地形を把握して探索を進める。それに対して、本論文で提案する手法は、次節で説明する長さの異なる記憶を用いることで、探索する地形を異なる尺度で把握している。つまり、短期的な記憶によって狭範囲の地形を把握し、長期的な記憶によって広範囲の地形を把握し、探索を進める。探索する地形を狭範囲、広範囲共に把握することによって、より効率のよい探索が実現できる。

3. 長・中・短期記憶

本研究において提案する新しい最適化法において鍵となっているのが、本節で説明する長・中・短期記憶である。こ

れら3種類の記憶を探索点決定の過程に反映させる。ここでは、それぞれの記憶の具体的な内容について説明する。

まず状態を、次の要素からなるベクトルとして定義する。ここで k は探索の繰り返し回数を表す。

探索点	S_k
探索点間の距離	d_k
探索点間の平均距離	$\bar{d}_k$
正規化された探索点の移動方向	n_k
探索点の移動方向	m_k
探索点の短期平均移動方向	$\bar{n}_k$
探索点の長期平均移動方向	$\bar{\bar{n}}_k$
目的関数値	E_k
現在の目的関数最小値に対する改善率	I'_k
前回の目的関数値に対する改善率	I''_k
目的関数値の短期平均改善率	$\bar{I}_k$
目的関数値の長期平均改善率	$\bar{\bar{I}}_k$

ここで、探索結果 z の平均を次のように考える。

$$\bar{z}_k = \lambda \bar{z}_{k-1} + (1 - \lambda) z_k \dots \dots \dots (1)$$

$$(0 < \lambda < 1)$$

この探索結果の平均が記憶の働きをする。記憶を短期、中期、長期に分ける方法として、上に示した探索結果の平均の式の λ に注目する。それぞれの記憶に用いる λ をそれぞれ、 λ_S 、 λ_M 、 λ_L とし、

$$\lambda_S < \lambda_M < \lambda_L \dots \dots \dots (2)$$

となるように設定する。このように設定することによって、長期の情報においては過去の記憶(平均)が、大きな意味を持ち、逆に、短期の情報においては現在の状態が大きな意味を持つようになる。

次に、それぞれの記憶の具体的な内容を説明する。

短期記憶(最適値の存在が有望な領域での集中探索を制御する)

- 短期平均改善率

$$\bar{I}_k = \lambda_S \bar{I}_{k-1} + (1 - \lambda_S) I'_k \dots \dots \dots (3)$$

$$(0 < \lambda_S < 1)$$

ここで、 I'_k は、短期記憶のために用いる目的関数 $E(S_k)$ の改善率である。

$$I'_k = \begin{cases} \frac{\min - E(S_k)}{\min} & (E(S_k) < \min) \\ 0 & (\text{otherwise}) \end{cases} \dots \dots \dots (4)$$

$\min$ は、現時点における目的関数の最小値である。 $\min$ と現在の目的関数値との間で改善率を考えることによって、次のような利点がある。

図2のように、集中探索において、前回の目的関数値との間で改善率を考えると、 $\min$ よりも明らかに値の悪い

領域でも改善が行なわれたと判断する恐れがある。そこで $\min$ との間で改善率を考えることによって、このようなまよかしの改善を防ぐことが出来る。

また、前述のように短期記憶は集中探索を制御するので、最適値の存在が有望な領域を積極的に探索するために、改悪された場合は、改悪率は考えずに改善率を 0 とする。こうすることによって、効率良く集中探索が行なわれる。

●短期平均移動方向

$$\bar{n}_k = \lambda_S \bar{n}_{k-1} + (1 - \lambda_S) n_k \dots\dots\dots (5)$$

$$(0 < \lambda_S < 1)$$

ここで、 n_k は、探索点の移動ベクトルを単位ベクトルに正規化したものである。

$$n_k = \frac{S_k - S_{k-1}}{|S_k - S_{k-1}|} \dots\dots\dots (6)$$

こうすることによって、 $\bar{n}_k$ は移動距離の影響を受けず、分散探索の大きなジャンプも集中探索と同じレベルのものとして取り扱うことが出来る。

短期記憶は、短期平均改善率、短期平均移動方向の 2 つである。これら短期的に記憶した改善率、移動方向を集中探索を行なう際の探索点決定に反映させることによって、最適値の存在が有望な領域で、効率の良い集中探索が実現出来る。

中期記憶（集中探索と分散探索の切替えを制御する）

●平均移動距離

$$\bar{d}_k = \lambda_M \bar{d}_{k-1} + (1 - \lambda_M) d_k \dots\dots\dots (7)$$

$$(0 < \lambda_M < 1)$$

ここで、 d_k は、探索点の移動距離である。

$$d_k = |S_k - S_{k-1}| \dots\dots\dots (8)$$

中期記憶は、平均移動距離のみである。中期的に記憶した移動距離を次の探索点への距離に反映させ、集中探索と分散探索を効率良くコントロールする。平均移動距離が大きくなると、分散探索から集中探索に切り替わり、逆に、平均移動距離が小さくなると、集中探索から分散探索に切り替わる。この集中と分散の自律的切替えによって、探索がある所に収束することを未然に防いでいる。よって、提案手法では探索をグローバルミニマムに収束させるのではなく、探索の途中でグローバルミニマムを探索することを狙いとしている。

長期記憶（最適値の存在が望めない状況を判断し、分散探索を制御する。）

●長期平均改善率

$$\bar{I}_k = \lambda_L \bar{I}_{k-1} + (1 - \lambda_L) I''_k \dots\dots\dots (9)$$

図 2 集中・分散探索における改善率

Fig. 2. Improvement in Intensification and Diversification Search

$$(0 < \lambda_L < 1)$$

ここで、 I'_k は、長期記憶のために用いる目的関数 $E(S_k)$ の改善率である。

$$I'_k = \frac{E(S_{k-1}) - E(S_k)}{E(S_{k-1})} \dots\dots\dots (10)$$

I''_k では、 I'_k のように $\min$ と現在の目的関数との間で改善率を考えるのではなく、前回の目的関数値との間で改善率を考える。分散探索は長期的なものなので、図 2 のように、 $\min$ よりも値の悪い領域で改善が行なわれたとしても長期的には正しいことがあるからである。

また、長期記憶は見込みの無さを積極的に考えるので、見込みの無い度合を表すために改悪率も考慮し、より効率的な分散探索が行なわれるようにする。

●長期平均移動方向

$$\bar{m}_k = \lambda_L \bar{m}_{k-1} + (1 - \lambda_L) m_k \dots\dots\dots (11)$$

$$(0 < \lambda_L < 1)$$

ここで、 m_k は、正規化しない探索点の移動ベクトルである。

$$m_k = S_k - S_{k-1} \dots\dots\dots (12)$$

こうすることによって、 $\bar{m}_k$ は移動距離の影響を受け、大きなジャンプが大きな意味を持ち、長期的な移動方向が表現出来る。

また、見込みの無さを積極的に考えるため、改善された場合の移動方向は、 $m_k = 0$ とし、改悪された場合のみを

考える。

長期記憶は、長期平均改善率、長期平均移動方向の2つである。これら長期的に記憶した改善率、移動方向を用いて最適値の存在が望めない領域を判断することによって、効率の良い分散探索が実現出来る。

4. ファジィ推論を用いた探索点の決定

ここで、探索点は、正規分布によって確率的に求める。

$$f(S_k) = \frac{1}{(2\pi)^{n/2} |\Sigma|^{1/2}} \exp - \frac{1}{2} (S_k - C_k)^T \Sigma^{-1} (S_k - C_k) \quad (13)$$

$$\Sigma = \begin{pmatrix} \sigma^2 & \dots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \dots & \sigma^2 \end{pmatrix} \dots\dots\dots (14)$$

n は、 S_k の次元である。

よって、探索点決定パラメータは、正規分布の平均 C_k と、分散 σ^2 である。

長・中・短期記憶を探索点決定の過程に次のように反映させる。

- (1) 平均移動距離が小さくなったら（集中探索が続いたら）、次の探索点までの距離、正規分布の分散を大きくして、大域的に探索を広げる。
- (2) 平均移動距離が大きくなったら（分散探索を行ったら）、次の探索点までの距離、正規分布の分散を小さくして、局所的に探索を集中させる。
- (3) 短期平均改善率が大い時は、有望であるので、次の探索点までの距離、正規分布の分散を小さくして、局所的な集中探索を続行し、また短期平均移動方向と同じ方向に進む。
- (4) 短期平均改善率が小さい時は、次の正規分布の分散を大きくして、大域的に探索を広げ、また短期平均移動方向（逆方向も含む）とは違う方向に進む。
- (5) 長期平均改善率が小さい時は、次の正規分布の分散を大きくして、大域的に探索を広げ、また長期平均移動方向とは違う方向に進む。

上に示した5つの項目の実現は、以下の5つのファジィルールによって行なう。

- (1) IF $\bar{d}_k$ is SL then $|C_{k+1} - S_k|$ is LG and σ^2 is LG
- (2) IF $\bar{d}_k$ is LG then $|C_{k+1} - S_k|$ is SL and σ^2 is SL
- (3) IF $\bar{I}_k$ is LG then $|C_{k+1} - S_k|$ is SL and σ^2 is SL and $C_{k+1} - S_k = \bar{n}_k$
- (4) IF $\bar{I}_k$ is SL then σ^2 is LG and $C_{k+1} - S_k \neq \bar{n}_k$
- (5) IF $\bar{I}_k$ is SL then σ^2 is LG and $C_{k-1} - S_k \neq \bar{m}_k$

図3 メンバシップ関数

Fig. 3. Membership Function

LG, SL は、大、小を表すファジィ集合であり、図3のメンバシップ関数によって定義される。

図3中の各 D は探索点の移動距離に関するメンバシップ関数の形状を決定するパラメータで、各 I は改善率に関するメンバシップ関数の形状を決定するパラメータである。ここで、メンバシップ関数の D_B , D_T の値は対象に応じて予め決めておく。また、 D_M は D_S と D_L の中点とする。

分散 σ^2 についてのファジィ集合に表れる α は、次のようなことを基に決定する。探索点 S_{k+1} は平均 C_{k+1} 、分散 σ_{k+1}^2 の正規分布によって決める。よって σ_{k+1}^2 が大きいと、 S_{k+1} は C_{k+1} の周りで大きくばらつく。このばらつきの範囲内に前回の探索点 S_k が含まれるかどうかは、

$$\alpha = \frac{|C_{k+1} - S_k|}{\sigma_{k+1}^2} \dots\dots\dots (15)$$

によって決まる。 α が小さければ σ^2 が大きくなるので、前回の探索点が次の探索範囲に含まれる確率が大きくなる。逆に、 α が大きければ σ^2 が小さくなるので、前回の探索点が次の探索範囲に含まれる確率が小さくなる。そこで、例えば S_{k+1} が C_{k+1} から $|C_{k+1} - S_k|$ 以上離れる確率を5%としたいときは、 $\alpha = 2$ とする。

メンバシップ関数で設定すべきパラメータは、 D_S , D_L , I_S , I_L の4つである。

現時点では、これらのパラメータは取り扱う問題に応じて自ら設定しなければならないが、将来はこれらのパラメータの自動設定を考えている。

また、メンバシップ関数の横軸は、広い範囲に対応で

図4 ファジィ推論
Fig. 4. Fuzzy Inference

きるように対数をとる。

以上のようにして決定したメンバーシップ関数に、平均移動方向 $\bar{d}_k$ 、短期平均改善率 $\bar{I}_k$ 、長期平均改善率 $\bar{I}_k$ の値を代入し、5つのファジィルールに従ってファジィ推論を行ない、探索点決定のパラメータを決定する。

ファジィ推論の方法⁽⁴⁾を、ファジィルール1の一部を例に説明する。

IF $\bar{d}_k$ is SL then $|C_{k+1} - S_k|$ is LG

平均移動距離 $\bar{d}_k$ を図4のようにメンバーシップ関数にプロットする。“IF $\bar{d}_k$ is SL”という前提が成り立つ度合を $\mu_{sl}(\bar{d}_k) \leq 1$ で表し、“then $|C_{k+1} - S_k|$ is LG”という結論も、その度合だけ採用する。つまり、図4の太線で囲まれた部分が結論となる。

次に、ファジィ集合の結論を普通の値 x^* に変換する。各 x ($\log |C_{k+1} - S_k|$) について、その度合を考慮して平均値を求める。(重心法)

$$x^* = \frac{\int x \mu(x) dx}{\int \mu(x) dx} \dots\dots\dots (16)$$

しかし、ルールは複数なので、複数の結論が出てくる。そこで、それぞれの結論をそれが正しいと言える度合 $\int \mu_i(x) dx$ に応じて重み付け、平均を考える。(面積比法)

$$x = \frac{\sum_i x_i^* \int \mu_i(x) dx}{\sum_i \int \mu_i(x) dx} = \frac{\sum_i \int x \mu_i(x) dx}{\sum_i \int \mu_i(x) dx} \dots\dots (17)$$

以上のようなファジィ推論を用いて、 $|C_{k+1} - S_k|$ 、 $C_{k+1} - S_k$ 、 σ^2 が決定し、探索点決定パラメータである正規分布の平均 C_k と、分散 σ^2 を求めることができる。

なお、J.Matyas のランダム探索法⁽⁵⁾ではコンパクト集合 S 上で大域的最小値を見出すことが証明されている。証明の前提として、

- (a) $E(x)$ は唯一の最適解を持つ
- (b) どのような $\bar{E} > E(x_{opt})$ においても、 $G(\bar{E})$ は空集合でない
ここで、 x_{opt} : パラメータベクトル x の最適値
 $G(\bar{E}) = \{x | E(x) < \bar{E}\}$
- (c) どのような探索パラメータベクトル $x \in S$ に対しても $f(x) \neq 0$ である

上記3条件が仮定されている。提案手法における探索のための確率密度関数 $f(x)$ は正規分布に従っているので、(c) の条件を満足している。よって、(a)、(b) の条件を満足する最適化問題、つまり孤立していない唯一の最適解を持つ最適化問題であれば、提案手法は確率100%でグローバルミニマムを探索できることが保証されている。

5. アルゴリズム

長・中・短期記憶を用いた発見的最適化法のアルゴリズムを以下に示す。

Step 1 初期探索点 S_0 、初期記憶 $\bar{I}_0$ 、 $\bar{d}_0$ 、 $\bar{I}_0$ を設定する(各初期記憶は0と設定)。目的関数値 $E(S_0)$ を計算し、 $\min = E(S_0)$ とする。 $k=0$ とする。

Step 2 長・中・短期記憶 $\bar{I}_k$ 、 $\bar{d}_k$ 、 $\bar{I}_k$ の値からファジィ推論によって、次の探索点を決定する正規分布の平均までの距離 $|C_{k+1} - S_k|$ 、正規分布の分散 σ_k^2 を求め、次の探索点を決定する。

Step 3 探索結果より、 d_k 、 I'_k 、 I''_k を計算し、各記憶を更新する。 $E(S_k) < \min$ ならば、 $\min = E(S_k)$ とする。

Step 4 k が最初に決めた探索回数に等しければ計算はストップ。そうでなければ、 $k = k+1$ とし、**Step 2** へ戻る。

6. シミュレーション

シミュレーション検証に用いたのは、次のような2変数目的関数⁽⁶⁾(図5)である。

$$E(x, y) = (4 - 2.1x^2 + \frac{x^4}{3})x^2 + xy + (-4 + 4y^2)y^2 + 1.031628 \cdot (18)$$

最適値(最小点)は次の通りである。

図5 2変数目的関数
Fig. 5. Objective Function

$x = \pm 0.08984201, y = \mp 0.71265640$ の時, 0

この目的関数には2つの最適値が存在するが、少なくともどちらか一方の最適値を探索すると考えれば、本節で取り扱う最適化問題は、4節で述べた大域的な最小値探索の条件 (a), (b) を満足する。

本節では、提案手法のシミュレーションによる探索状況の検証及び、勾配法との比較を行なう。シミュレーションに用いた計算機は Pentium 166MHz のパーソナルコンピュータ、OS は Linux、プログラムは C 言語である。シミュレーションは、3つの初期値パターンを与えて行なった。最適点付近である (0.5, 0.5)、局所解付近である (1.5, 1)、両者共に離れた (2, 2) の3種類である。探索回数は5000回に統一している。

以上のようなシミュレーション条件における計算時間は2～3秒程度である。

次に、提案手法の設定すべきパラメータを以下にまとめる。

Table 1. Parameter Values

表1 設定パラメータ値

D_B	-6.0	I_S	0.01
D_S	-1.7	I_L	0.05
D_M	-1.2	λ_S	0.81
D_L	-0.7	λ_M	0.9
D_T	-0.4	λ_L	0.999

なお、勾配法におけるステップ幅に関する設定パラメータは最善目的関数値が最小となる値に設定した。

提案手法における探索結果は乱数発生に依存するので、3種類の異なる乱数系列を用いてシミュレーションを行なった (case 1-3)。表に示しているのは、提案手法、勾配法それぞれにおける最善目的関数値である。

Table 2. Best Performance Value

表2 最善目的関数値

$[\times 10^{-4}]$

Initial value	Proposed method				Gradient method
	case 1	case 2	case 3	Ave.	
(0.5, 0.5)	3.27	0.14	0.31	1.24	0.00
(1.5, 1.0)	0.22	0.00	0.43	0.22	3.13×10^4
(2.0, 2.0)	0.77	1.73	0.43	0.98	3.13×10^4

表に整理されたシミュレーション結果より勾配法では初期値が最適点付近に設定された場合は、非常に良い精度で最適点に収束するが、それ以外の場合はローカルミニマムに収束する結果となっている。それに対して、提案手法における最善目的関数値は初期値、あるいは局所解に依存しないことが分る。よって提案手法による探索は、ローカルミニマムに陥ることなく、また最適値の存在が望めない領域へ発散することなく進められている。

図6 初期値 (2, 2) における最善目的関数値 (min)

Fig. 6. Best Performance

図7 初期値 (2, 2) における探索

Fig. 7. Search in Initial Value (2, 2)

図6では、提案手法と勾配法の改善目的関数値のグラフを比較している。

勾配法では、早い段階でローカルミニマムに収束しているのに対し、提案手法では、階段状に改善していくのが特徴的であり、探索回数を増やすことによってさらなる改善が期待できる。

次に、提案手法の探索が方針通りに進められているかを確かめるため、それぞれの探索過程を詳しく検証する。

図7より探索点がローカルミニマムに収束することなく、最適点

$(-0.08984201, 0.71265640)$, $(0.08984201, -0.71265640)$

付近で集中していることが分かる。一旦局所解付近を集中的に探索しているが、短・中期的ルールの働きによりローカルミニマムを脱出し、最適点付近へ探索領域が移動している。さらに、見込みの無い方向への発散を長期的ルールが抑制し、移動方向を修正している様子が顕著に表れている。

図8は、集中探索と分散探索の切替えを示している。この図から探索点が局所的な集中探索をしばらく繰り返した後、大きくジャンプして再び局所的な集中探索をしばらく行うという挙動が把握出来る。これは、集中・分散という

図8 移動距離 d と平均移動距離 $\bar{d}$ (overline d), ($0 \leq$ 繰り返し回数 ≤ 100)

Fig.8. Movement Distance and Average Movement Distance

対照的な2つのフェーズのコントロールによる探索が実現出来ていることを示すものである。

以上のシミュレーション結果を考察すると、提案手法はローカルミニマムに捕らわれることなく、探索を押し進めることが可能な手法であることが確認された。

7. おわりに

本論文では、最適化問題として連続変数の目的関数の最小点探索問題を取り扱い、局所的でない最適値の獲得を目的とした新しいシステムティックな最適化手法を提案した。

この手法の探索方針は、探索プロセスに集中的局所的な探索フェーズと分散的大域的な探索フェーズという異なる側面を持たせ、これら2つのフェーズを探索によって獲得した長・中・短期記憶によってシステムティックにコントロールするというものである。

今回のシミュレーションの結果、本論文で提案した最適化手法が集中・分散のコントロールによって局所解を回避し、最適値付近で集中的に探索を進めていることが確認できた。この手法によって精度の高い最適化が期待できる。

将来的にはニューラルネットワーク学習への応用を考えているが、そのための今後の課題として、パラメータの自動設定が挙げられる。今回のシミュレーションでは、移動距離に関するパラメータを目的関数のスケールに応じて自ら決定しなくてはならなかった。問題に応じたパラメータの自動設定が今後の課題である。

(平成9年8月11日受付, 同10年4月14日再受付)

文 献

- (1) 奈良宏一, 佐藤泰司: システム工学の数理手法, コロナ社 (1996)
- (2) 古賀勝, 平澤宏太郎, 大林正直, 村田純一: 微分情報を用いたランダム探索最適化手法, 計測自動制御学会 論文集 Vol.32, No.8, 1277/1286 (1996)
- (3) N.SHAO, K.HIRASAWA, M.OHBAIYASHI, K.TOGO: Generalization Capability of Radial Basis Function Controller Using Random Search Method with Variable Search Length in Uni-

versal Learning Network, 九州大学大学院 システム情報科学研究科報告 Vol.2, No.1, 平成9年3月 掲載予定

- (4) 本田中二, 大里有生: ファジィ工学入門, 海文堂出版 (1989)
- (5) J.Matyas: Random optimization, Automation and Remote Control, Vol.26, 244/251 (1965)
- (6) 馬場則夫: 確率的アプローチに基づく最適化システム制御情報学会誌 システム/制御/情報 第40巻 第4号 p152 (1996)

村田 純一 (正員) 1959年1月19日生。1986年3月九州大学大学院工学研究科博士後期課程電気工学専攻修了。1986年4月九州大学工学部助手。1988年4月同大学工学部助教授。1996年5月同大学大学院システム情報科学研究科助教授。現在に至る。電気学会, 計測自動制御学会, システム制御情報学会, IEEEの各会員。主として学習, 自己組織化システムに関する研究に従事。工学博士。

淵上 哲司 (学生会員) 1974年12月9日生。1997年3月九州大学工学部電気工学科卒業。1997年4月九州大学大学院入学。現在システム情報科学研究科電気電子システム工学専攻修士課程在学中。

平澤 宏太郎 (正員) 1942年1月26日生。1964年3月九州大学工学部電気工学科卒業。1966年3月九州大学大学院工学研究科電気工学専攻修了。1966年4月(株)日立製作所入社日立研究所勤務。1989年8月同所副所長。1991年8月大みか工場主管技師長。1992年12月九州大学工学部教授。1996年5月同大学大学院システム情報科学研究科教授。現在に至る。電気学会, 計測自動制御学会, 情報処理学会, IEEEの各会員。工学博士。