

**7<sup>th</sup> SICE Symposium on Computational Intelligence**

**May 29-30, 2015, Sendai**

**第7回**

**コンピューターショナル・インテリジェンス研究会  
講演論文集**

**会 期： 2015年5月29日（金）， 30日（土）**

**会 場： 東北大学サイバーサイエンスセンター**

**SICE®**

**カタログ番号 15 PG0007**

著作権 © 2015

公益社団法人計測自動制御学会(SICE)  
〒113-0033 東京都文京区本郷 1-35-28-303

カタログ番号 15 PG 0007

著作権は、計測自動制御学会がもっている  
ので、個人の使用のための複製以外の  
目的で掲載の記事の一部または全文を  
複製する場合には、著作権者に許可を求  
め規定の複製料を支払うこと。

発行日：2015年5月29日

発行者：公益社団法人計測自動制御学会 システム・情報部門  
コンピューターショナル・インテリジェンス部会

# プログラム

講演会場：東北大学サイバーサイエンスセンター 5F 講義室

5月29日（金）

13:30-15:30 CIと進化計算

司会：畠中 利治（大阪大学）

1. 量子情報処理に基づく粒子群最適化アルゴリズムの時変関数最適解探索問題への適用  
○松井 伸之, 磯川 悌次郎（兵庫県立大学） . . . 1
2. トポロジーの切り替えによるPSOの探索効率の改善法に関する一考察  
酒井 駿介, ○畠中 利治, 肖 恒（大阪大学） . . . 5
3. 進化的実験計画におけるベンチマーク問題  
○内種 岳詞（理化学研究所） . . . 9
4. 遺伝的アルゴリズムに基づく病院給食の献立立案支援システムにおける性能評価  
○磯川 悌次郎, 松井 伸之（兵庫県立大学） . . . 13

15:30-15:45 休憩

15:45-17:15 ロボット・制御

司会：本間 経康（東北大学）

5. 滑りを考慮した二足歩行及び動的形状変更能力に基づく評価  
○李 想, 馮 陶然, 今西 裕紀, 見浪 護, 松野 隆幸, 矢納 陽（岡山大学） . . . 17
6. Eye-Vergenceに基づくビジュアルサーボシステム  
○田 宏志, 侯 森, 見浪 護, 于 福佳, 前田 耕市, 矢納 陽（岡山大学） . . . 25
7. 強化学習による自動帆走の状態空間の検討  
○真鍋 秀朗, 橘 完太（工学院大学） . . . 33

18:00-20:00 技術交流会

会場：東北大学理学研究科合同C棟内レストラン

5月30日（土）

9:30-12:00 高次NN・信号処理

司会：市村 匠（県立広島大学）

8. 複素多層パーセプトロン学習における一層の探索枝刈りの効果  
○佐藤 聖也, 中野 良平（中部大学） . . . 37
9. Restricted Boltzmann Machinesを用いた免疫学的記憶細胞を用いたクローン選択  
アルゴリズムの提案  
○鎌田 真（広島市立大学）, 市村 匠（県立広島大学） . . . 43
10. 乳房X線画像診断支援のための多層自己組織化マップによる自動特徴分類の試み  
長谷川 奈保, ○本間 経康, 張 暁勇, 市地 慶, 小山内 実, 阿部 誠,  
杉田 典大, 吉澤 誠（東北大学） . . . 50
11. ベクトル積ホップフィールドニューラルネットワーク  
○小林 正樹（山梨大学） . . . 54
12. 巻き込み分布に従う位相スペクトル差をもつ信号間の位相限定相関関数の統計的性質  
○八巻 俊輔, 川又 政征（東北大学） . . . 58

# 量子情報処理に基づく粒子群最適化アルゴリズムの 時変関数最適解探索問題への適用

○松井伸之 磯川悌次郎 (兵庫県立大学)

## An Application of Quantum-inspired Particle Swarm Optimization Algorithm to Optimization of Time-varying Function

**Abstract**— Quantum-inspired Particle Swarm Optimization(QPSO) is an approach of Quantum-inspired Computational Intelligence in which the concept of quantum mechanics is adopted. QPSO is a method based on Particle Swarm Optimization (PSO). The state of a particle in QPSOs is described by a wave function derived from the Schrödinger equation, whereas the state of a particle in conventional PSOs is determined from its location and velocity. The performances of QPSOs are investigated through the optimization problem for time-varying higher-dimensional functions. The experimental results show that QPSOs outperform the standard PSOs.

**Key Words:** Quantum-inspired PSO, Quantum potential, Time-varying function, Optimization problem

### 1 はじめに

Shor の素因数分解のアルゴリズムや、Grover のデータベース検索アルゴリズムが1990年代に提案されて以来、量子アルゴリズムの研究が盛んに行われている。量子アルゴリズムを用いることにより、通常のコンピュータでは多項式時間で解けないような組合せ最適化問題でも高速に解くことができる。このことから、量子アルゴリズムは従来のアルゴリズムの性能を向上させる手段の一つとして有望視されている<sup>1)</sup>。近年では、このような量子アルゴリズムを含んだより広い量子情報処理のアプローチの一つとして、自然界に存在する生物などに学んだ計算知能と量子情報処理を一体化させるという量子計算知能の試みがなされている<sup>2)</sup>。量子粒子群最適化法 (Quantum-inspired Particle Swarm Optimization : QPSO) はその一つである<sup>3)</sup>。QPSO の基となるPSO は、鳥や昆虫の群れの振る舞いをモデル化した統計的な最適解探索手法の一つである<sup>4)</sup>。探索点を表す粒子が探索空間を移動しながら、目的関数の評価値情報のみを用いて解探索を行う手法であり、目的関数の連続性や微分可能性を必要としない点の特徴である。QPSO はPSO に、量子ダイナミクスを生起するポテンシャル場 (量子ポテンシャル場) を導入した手法である。同手法は、高次元関数の最小解探索問題<sup>5)</sup> やいくつかの応用問題<sup>6)</sup> を通してPSO との性能比較が行われ、従来法よりも高い性能を持つことが示されている。しかしながら、これらの性能評価は静的環境下での最適解探索問題が多く、非定常環境下での評価検討はあまり試みられていない。QPSOがより広く実用に供するためには、非定常環境にもスムーズに適応するように改良がなされねばならない。

本報告では、このような観点から開発したQPSO, Dynamical QPSO, の非環境下適応性能を時間変化により最適解が変化する非定常関数の最適解探索問題を通して評価する。

### 2 粒子群最適化法 (PSO)

QPSO の基本となる PSO の概略を示す。PSO は、自然界に存在する鳥や昆虫の群れが「情報を群れ全体で共有し、行動している」という仮定を基にモデル化された最適解探索手法である。同手法では、群れを構

成する個体は粒子で表され、群れは粒子群として表現される。PSO の粒子は個々で独立して行動するのではなく、粒子の独自情報と粒子群全体の共有情報を組み合わせることによって行動し、多次元探索空間を移動しながら最適解を探索する。

PSO の粒子群はいくつかの粒子から構成される。それぞれの粒子は探索した解を表す粒子位置  $\mathbf{x}_i^t$ 、粒子の移動ベクトル (速度)  $\mathbf{v}_i^t$ 、粒子自身の過去の最適位置  $\mathbf{pbest}_i$  とその評価値、および粒子全体で共有する粒子群全体の過去の最適位置速度  $\mathbf{gbest}$  とその評価値の情報を持つ。ここで、 $i = 1, \dots, N$  は粒子の番号、 $t = 1, 2, \dots$  更新回数で離散時刻である。PSO の粒子は更新式(1)により探索した最適な解方向へ移動する<sup>4)</sup>。

$$\begin{aligned} \mathbf{v}_i^{t+1} &= w\mathbf{v}_i^t + c_1r_1(\mathbf{pbest}_i - \mathbf{x}_i^t) + c_2r_2(\mathbf{gbest} - \mathbf{x}_i^t) \\ \mathbf{x}_i^{t+1} &= \mathbf{x}_i^t + \mathbf{v}_i^{t+1} \end{aligned} \quad (1)$$

### 3 量子粒子群最適化法 (QPSO)

QPSO は、PSO に量子情報処理を導入した手法である。PSO では粒子の状態がそれ自身の粒子の位置と速度によって古典力学的に決定される。一方、量子力学では不確定性原理により粒子の位置と速度を同時に正確に決定することができない。それゆえQPSO における粒子の状態は、位置と速度の代わりにSchrödinger方程式から導かれる波動関数  $\psi(x, t)$  で記述される。また粒子の位置は、量子ポテンシャル場に依存する確率密度関数  $|\psi(x, t)|^2$  によって決定される<sup>3)</sup>。

PSO とは異なり粒子状態が波動関数によって表されることから、QPSO の粒子は速度情報を持たない。そのため、粒子の位置と探索した解から粒子状態の更新を行う。QPSOの粒子状態の更新式を以下に示す<sup>6)</sup>。

$$\mathbf{x}_i^{t+1} = \begin{cases} \mathbf{p}_i^t + \beta|\mathbf{x}_i^t - \mathbf{mbest}|Q^{-1}(\mathbf{u}_i) & \text{if } r \geq 0.5 \\ \mathbf{p}_i^t - \beta|\mathbf{x}_i^t - \mathbf{mbest}|Q^{-1}(\mathbf{u}_i) & \text{otherwise} \end{cases}$$

$$\mathbf{p}_i^t = \phi_i \mathbf{pbest}_i + (1 - \phi_i) \mathbf{gbest} \quad (2)$$

$$\mathbf{mbest} = \frac{1}{N} \sum_{i=1}^N \mathbf{pbest}_i$$

ここで、 $\beta$  は収縮膨張係数、 $\phi_i$  と  $u_i$  の各要素および  $r$  は  $(0,1]$  の一様乱数としている。なお、式(2)中の  $Q^{-1}(u_i)$  が、量子ポテンシャルに起因する量子力学に基づいた確率的広がりを持つ項であり、導入する量子ポテンシャルによって変化する。

本報告において QPSO に導入する量子ポテンシャル  $V(x)$  は、Fig1 に示したデルタ井戸型ポテンシャルと調

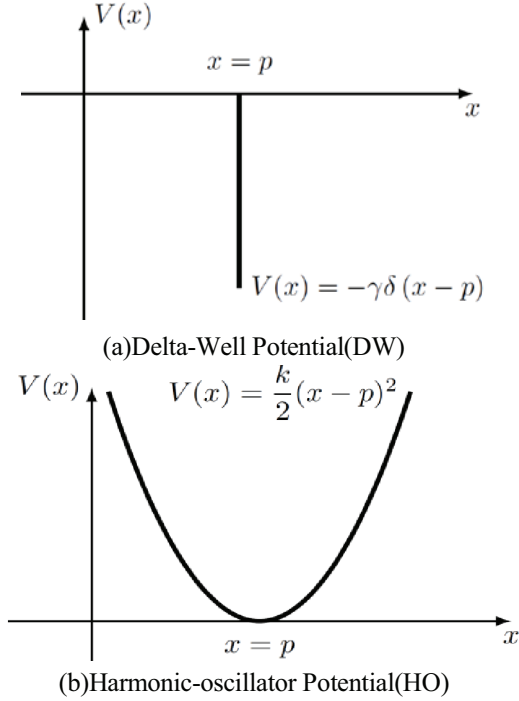


Fig. 1: Quantum Potentials

和振動子ポテンシャルである。

量子ポテンシャルに基づいた  $Q^{-1}(u_i)$  は、デルタ井戸型ポテンシャル (DW) が

$$Q^{-1}(u_i) = \ln u^{-1}$$

であり、調和振動子ポテンシャル (HO) が

$$Q^{-1}(u_i) = \sqrt{\ln u^{-1}}$$

のように導出される<sup>9)</sup>。

#### 4 非定常環境へ適応した量子粒子群最適化法 (Dynamical QPSO)

通常の QPSO では、粒子群が探索する解の評価値は更新が進むにつれ単調減少する。しかし非定常環境下においては、環境の変化により評価関数の形状が変化し、最適解が  $gbest$  から  $gbest^*$  のように移動する場合がある。通常の QPSO は、評価関数の環境変化がない静的問題を対象にしているため、

$$f(gbest^*, t) < f(gbest, t-1)$$

が満たされない限り最適解の更新は行われず、探索した最適解が環境変化により不適切な解のまま拘束されてしまう。そこで、非定常環境へ適応した Dynamical QPSO を提案する。

関数の環境変化を時間変化とし、時刻  $t$  における非定常評価関数を  $f(x; t)$  と表現する。また、各粒子の状

態をそれぞれ  $x_i^t$ ,  $pbest_i^t$  そして  $gbest^t$  と表記する。

Dynamical QPSO では、再評価処理

$$pbest_i^* = \begin{cases} x_i^{t-1} & \text{if } f(x_i^{t-1}, t) < f(pbest_i^{t-1}, t) \\ pbest_i^{t-1} & \text{otherwise} \end{cases}$$

$$gbest^* = \arg \min \{f(pbest_i^*, t)\}$$

にしたがって、環境変化により不適切になった解を現在の環境に適応させる。粒子状態は、再評価処理により求められた  $pbest_i^*$  と  $gbest^*$  を用いた式(2)により更新する。Dynamical QPSO の実行手順を以下に示す。

**Step 1:** 初期時間を  $t=1$  とし、各粒子の位置を一様乱数で初期化する。各粒子において初期化された位置を  $pbest_i^1$  として与える。  $t \leftarrow t+1$  として Step 2 へ移る。

**Step 2:** 前時刻における各粒子の位置と  $pbest_i^t$  を式(3)に従って再評価し  $pbest_i^*$  を求め、 $gbest^*$  を求める。

**Step 3:**  $pbest_i^*$  から  $mbest^*$  を計算する。

$$mbest^* = \frac{1}{N} \sum_{i=1}^N pbest_i^*$$

**Step 4:** 各粒子の位置を以下のように更新する。

$$x_i^{t+1} = \begin{cases} p_i^* + \beta |x_i^t - mbest^*| Q^{-1}(u_i) & \text{if } r \geq 0.5 \\ p_i^* - \beta |x_i^t - mbest^*| Q^{-1}(u_i) & \text{otherwise} \end{cases}$$

$$p_i^* = \phi_i pbest_i^* + (1 - \phi_i) gbest^*$$

**Step 5:** 各粒子の  $pbest_i^t$  と  $gbest^t$  を、それぞれ

$$pbest_i^t = \begin{cases} x_i^t & \text{if } f(x_i^t, t) < f(pbest_i^*, t) \\ pbest_i^* & \text{otherwise} \end{cases}$$

$$gbest^t = \arg \min \{f(pbest_i^t, t)\}$$

に従って求め、このときの  $gbest^t$  を時刻  $t$  における探索解とする。

**Step 6:** 終了条件を満たすまで、 $t \leftarrow t+1$  として Step 2 へ戻る。

#### 5 非定常関数の最小解探索問題


本報告では、非定常関数の最小解探索問題を用いて、Dynamical QPSO の非定常環境適応性能を評価する。なお、Dynamical QPSO に導入する量子ポテンシャル場は調和振動子ポテンシャルである。性能の比較対象として、非定常環境に適応していない従来の PSO およびデルタ井戸型ポテンシャルによる QPSO を、そして非定常環境への適応を図った PSO (Online-PSO)<sup>7)</sup> を用いる。

実験対象関数として、以下に示す二つの非定常関数  $f_1$  と  $f_2$  を用いる。また関数の形状を Fig.2 に示す。


$$f_1(x_1, x_2, t) = 1 - \Theta(x_1, x_2, \omega t) \quad (4)$$

$$f_2(x_1, x_2, t) = 1 - \Theta(x_1, x_2, \omega t) \times \cos\left(\frac{x_1 + \omega t}{45}\right) \sin\left(\frac{2x_2 + \omega t}{90}\right) \quad (5)$$

$$\Theta(x_1, x_2, \theta) = \exp\left[-\frac{1}{2}\left\{\left(\frac{x_1 - 250 - 125 \cos \theta}{40}\right)^2 + \left(\frac{x_2 - 250 + 125 \sin \theta}{40}\right)^2\right\}\right]$$



(a)  $f_1(x_1, x_2, t)$



(b)  $f_2(x_1, x_2, t)$

**Fig.2 Time-varying functions ( $t=45$ )**

ここで  $\omega = 2\pi/A$  であり,  $A$  は関数の時間変化の速さを決定するパラメータである.

対象となる非定常関数は, それぞれ次のような特徴を持つ. 関数  $f_1$  は, 時間に依存して最適解の位置のみが変化する単峰性の非定常関数である. 一方, 関数  $f_2$  は, 実システムへの適用を想定して最適解の位置と評価値が共に時間変化する特徴を持つ多峰性の非定常関数とした. なお, 各関数には定義域を設け, 粒子の位置が関数の定義域内に収まるように制限を与えている. 定義域は  $x_i \in [0, 500]$  である.

## 6 性能評価結果

非定常関数(4) と(5) に含まれる時間変数  $t$  を PSO

の更新回数に対応させ, 時間が1増加したとき, PSO アルゴリズムを1回更新させる. 更新回数に応じて関数を時間変化させたときの最適解探索性能を評価する. 各手法において, 粒子数は  $N=100$ , 最大更新回数は1000ステップとする. また, 各PSOのパラメータを Table 1 に示す.

**Table 1 Parameters in various PSO**


PSO	Online PSO	QPSO (DW)	Dynamical QPSO(HO)
$w = 0.729, c_1 = c_2 = 1.496$		$\beta = 0.71$	$\beta = 1.19$

なお, PSO のパラメータは, 文献8) の解析に基づいて設定し, QPSO のパラメータは, 文献6) に記述されている収束条件の下で実験的に決定する.

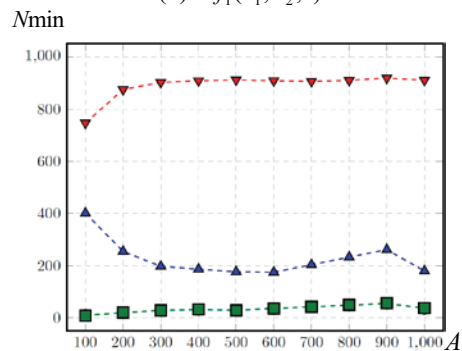
非定常関数の最適解探索においてどの程度最適解が得られているかを示すため, 探索中に最適解に粒子が存在した回数  $N_{min}$  を求める. しかし PSO アルゴリズムでは, 必ずしも最適解と真に等しい値を探索できるわけではない. そこで非定常関数の最適解から許容幅  $d$  を設け, 探索させる最適解に許容を持たせる. そして,  $d$  内に粒子が存在した場合を「最適解に粒子が存在した」と定義する. なお, 本報告では  $d=0.01$  とする.

関数の変化速度  $A$  を100 から1000 まで100 ごとく変化したときの各手法における  $N_{min}$  を Fig.3 に示す.

● - PSO      ■ - QPSO  
▲ - Online PSO      ▼ - Dynamical QPSO



(a)  $f_1(x_1, x_2, t)$



(b)  $f_2(x_1, x_2, t)$

**Fig.3 A dependence of  $N_{min}$**

通常の PSO と QPSO は, 非定常環境に適応できないため, すべての関数において  $N_{min}$  が非常に小さくな

っており、最適解を探索することができていない。Online PSO およびDynamical QPSOは、粒子の再評価処理により従来のPSO アルゴリズムに比べ、 $N_{min}$  が高くなっている。Online PSO とDynamical QPSOで比較すると、単峰性関数である $f_1$  においては、両手法ともに関数の変化速度 $A$ に依存せず $N_{min}$  は非常に高い値となっており、最適解を探索できている。多峰性関数である $f_2$  では、Online PSOは変化速度が遅くなると $N_{min}$  が減少している。一方、Dynamical QPSO手法は変化速度によらずOnline PSO より多くの回数、最適解を探索できている。

Online PSO およびDynamical QPSOを各非定常関数に適用し、各時刻で得られた探索解  $gbest^t$  の軌跡をFig.4に示す。なお、関数の変化速度は $A = 500$  である。

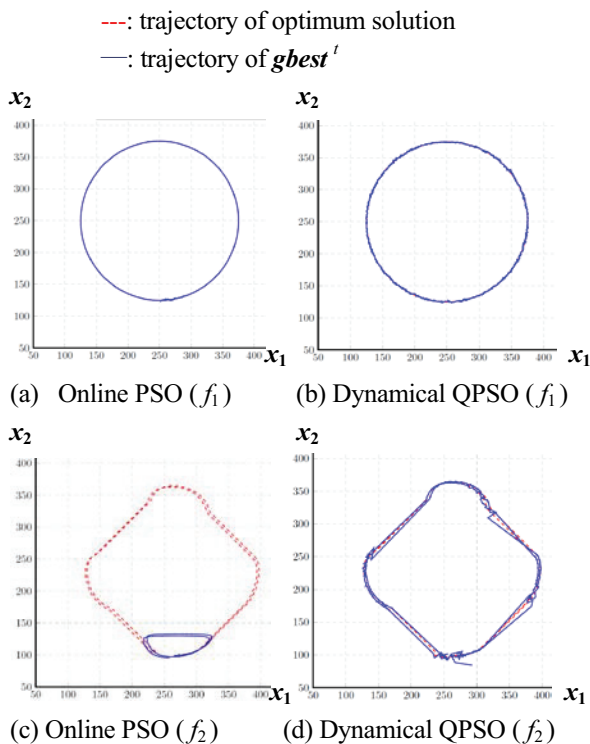


Fig.4 Trajectories in Searching space

Fig.4 において、破線および実線は、それぞれ関数の最適解および探索した解  $gbest^t$  の軌跡を表している。Fig.4(a) と(b) から、単峰性関数 $f_1$  において両手法共に  $gbest^t$  軌跡に歪みがなく最適解と一致している。したがって、時間変化する非定常関数の最適解を正確に追従できている。Fig.4 (c) と(d) から、Online PSO は多峰性関数が持つ局所解に粒子が拘束されてしまい、最適解の追従ができていない。一方、Dynamical QPSO手法は局所解に拘束されることなく時間変化する非定常関数の最適解を追従できている。

## 7 まとめ

群れ行動に基づいた統計的最適解探索手法である PSO に、量子を記述するSchrödinger方程式を実際に解

いて得られた波動関数を用いて解探索を行う手法が量子粒子群最適化法QPSOであった。

本報告では、時間変化などによって環境が変化する最適解探索問題においても効率よく解探索しうるように、QPSOの改良を試みてDynamical QPSOを提案した。このQPSOにおいては、現環境の評価関数にて再評価処理を行う再評価処理アルゴリズムを取り入れている。この再評価処理アルゴリズムは、環境の変化に起因して最適解が移動する結果生じる既探索の解が不適切になるという問題解決のために、Online PSOで開発された手法であるが、QPSOに取り入れた場合、さらに性能が向上することを明らかにした。このことを明示するために、非定常関数の最適解探索問題を通してDynamical QPSO手法の非定常環境への適応性能を評価した。

一つに確定している古典力学的な量と波動関数に基づく分布とを対応させる、などといった量子力学固有の数理概念を、従来応用されてこなかった古典系計算アルゴリズムに適用したわけである。その結果、量子力学に基づいた確率的な広がり局所解に粒子が拘束されることを防ぎ、QPSOの性能向上を誘引したものと考えられる。このように、量子力学が生み出した数理概念を有用な計算資源とする量子計算知能を、現実的な計算知能の実働現場に適用し、その有効性をさらに明らかにすることが今後の課題である。

## 参考文献

- 1) M. A. Nielsen and I. L. Chuang : Quantum computation and quantum information, Cambridge university press (2010)
- 2) N. Nedjah, L.S. Coelho, and L.M. Mourelle: Quantum inspired intelligent systems, **121**. Springer (2008)
- 3) J. Sun, B. Feng, and W. Xu : Particle swarm optimization with particles having quantum behavior, In Evolutionary Computation, Congress on, **1**, 325/331 (2004)
- 4) J. Kennedy and R. Eberhart: Particle swarm optimization, In Proceedings of IEEE International Conference on Neural Networks, **4**, 1942/1948 (1995)
- 5) K. Tazuke, N. Muramoto, N. Matsui, and T. Isokawa: An Application of Quantum-Inspired Particle Swarm Optimization to Function Optimization Problems, Proceedings of International Joint Conference on Neural Networks, 1234/1239 (2013)
- 6) J. Sun, C.H. Lai, and X.J.Wu: Particle Swarm Optimisation: Classical and Quantum Perspectives, Chapman & Hall/CRC Numerical Analysis and Scientific Computing Series. Taylor & Francis (2011)
- 7) 西田健, 坂本哲三: 時変システムのオンライン同定のための適応 PSO, IEEJ Transactions on Electronics, Information and Systems, **131-9**, 1642/1649 (2011)
- 8) M. Clerc and J. Kennedy: The particle swarm - explosion, stability, and convergence in a multidimensional complex space, Evolutionary Computation, IEEE Transactions on, **6- 1**, 58/73 (2002)



# トポロジーの切り替えによる PSO の探索効率の改善法に関する一考察

酒井駿介 ○畠中利治 肖恒 (大阪大学)

## A Study on Search Performance Improvement for PSO by Switching Topology

S. Sakai, \*T. Hatanaka and H. Xiao (Osaka University)

**Abstract**— Conventional particle swarm uses a fixed neighborhood topology during search process. It is well known that the topology has effect for search performance. In this study, a variant of particle swarm with dynamic neighborhood topology is considered to give well performance for complex function optimization problems. The topology changing scheme is proposed based on particle velocity. Then a search performance of the proposed particle swarm is evaluated by CEC 2013 test suite.

**Key Words:** Particle swarm, black-box optimization, evolutionary computation, large-scale global optimization

### 1 はじめに

関数最適化問題は、 $D$ 次元の実数値ベクトル  $\mathbf{x} = (x_1, \dots, x_D)^T$  について、目的関数  $f(\mathbf{x}) \in \mathcal{R}$  を最小化 (あるいは最大化) する最適解  $\mathbf{x}^*$  を求める問題である。多くの実問題は、関数最適化問題に定式化されるが、その中でも、対象とする関数の勾配情報や単峰性か他峰性かといった景観に関する情報などが得られず、変数  $\mathbf{x}$  に対する関数の値  $f(\mathbf{x})$  のみが得られるような問題を、ブラックボックス最適化と言う。進化計算は、このようなブラックボックス最適化の有用なツールであると考えられ、大規模で複雑な関数最適化問題において、その性能を競うコンペティションが進化計算に関する主要な国際会議で実施されるなど、盛んに研究が進められている。特に、差分進化 (Differential Evolution, DE) と粒子群最適化 (Particle Swarm Optimization, PSO) やホタルのアルゴリズム (Firefly Algorithms) などの群知能に基づく最適化法は、実装の容易さに反して高い性能を示すことから、さまざまな改良法が提案されてきている。

このような手法の有用性は、ブラックボックス最適化に限らず、目的関数の数学モデルが陽に与えられる問題においても、高次元かつ多峰性の場合には、並列に探索を進め、有望領域を発見しうる手法は有用である。さらに、最適化に限らず、社会シミュレーションなどにおいて、非常に大きな実行可能領域における適切な実験条件の設定に、このような進化計算に基づく手法が適用できると期待されており、高次元の関数最適化問題において、設計変数空間における有望な領域の絞り込み技術として、性能のよいアルゴリズムの開発が必要である。

こういった要求に対して、進化計算のアルゴリズムでは、利用できる計算資源の中で大域的に探索を進めることと同時にできるだけ早い収束を実現することが望ましい。この観点から、探査と探索あるいは、大域的探索と局所探索のバランスの設計が重要であると考えられ、このためのパラメータの設定法や機能分担もしくは、局所探索法とのハイブリッド化がはかられてきている。

PSO の性能改善においても、多くの改良法ではこのよ

うな目的に対して、パラメータの適応的な設定や粒子の再配置、他の探索メカニズムとのハイブリッド化が提案されている。また、PSO の探索粒子が従う力学系には、パラメータに依存して、安定な領域と不安定な領域とがあるが、不安定さを利用して粒子の移動量を大きくすることで探索範囲を拡大する手法が提案されている。

本研究では、これに対して、近傍粒子の間で *local best* を共有する *local best* モデルにおける近傍を定義するトポロジーに注目し、安定不安定の境界をトポロジーの切り替えによって操作することにより探索範囲を操作することを考えている。具体的には、結合関係が PSO の探索性能に与える影響をいくつかのベンチマーク問題で実験的に検証し、その観察から得られた知見に基づく PSO の探索途中に結合を変化させる規則によって駆動される PSO を提案する。さらに、粒子の移動量のステップ間の変化によって、接続数を変化させることで PSO の探索性能が改善できることを、CEC 2013 のコンペティションで採用されたベンチマーク問題<sup>5)</sup>における性能検証によって示す。

### 2 PSO

PSO における探索粒子は、それぞれの持つ位置 (その要素が  $x_{id}(t)$  で表されている) と速度 (同様に  $v_{id}(t)$ ) のベクトルによって表現される。その動作モデルは要素ごとに以下の式で表される。

$$v_{id}(t+1) = wv_{id}(t) + c_1R_1(p_{id} - x_{id}(t)) + c_2R_2(l_{id} - x_{id}(t)) \quad (1)$$

$$x_{id}(t+1) = x_{id}(t) + v_{id}(t+1) \quad (2)$$

ここで、 $i$  は探索粒子の番号、 $d$  は次元数、 $t$  はステップ数を表している。 $p_{id}$  (*personal best*) と  $l_{id}$  (*local best*) という 2 つの情報を用いて、(1) 式により速度が更新され、(2) 式に従って粒子が解空間内を移動する。 $p_{id}$  は粒子の繰り返し回数  $t$  までの最良な評価値を得たときの位置の要素であり、 $l_{id}$  は近傍の探索粒子の  $p_{id}$  の中で最良な評価値を与える位置である。なお、近傍を全粒子にとると *global best* モデルとなり、粒子の近傍範囲に取

るものが *local best* モデルである。 *local best* モデルモデルのための近傍を定義するトポロジーは、局所解への初期収束をおさえ、大域探索をうながす目的で導入され、種々のトポロジーが示されてきている<sup>8)9)10)</sup>。

また、PSO は任意に定めることができるパラメータ  $w, c_1, c_2$  を有している。  $R_1, R_2$  は乱数であり、 $[0 \sim 1]$  の一様分布からサンプリングされることが通例である。

モデルのダイナミクスを解析することで、繰り返しの続けたときの安定条件を求める研究(例えば<sup>6)</sup>) がなされており、その知見をもとに安定不安定の境界に従ってこれらのパラメータを適切に定めることによる性能改善法が示されてきている<sup>7)</sup>。

また、PSO には、さまざまな改良法が提案され、それらの性能調査が行われている。そこで、改良版の PSO の有用性を示す上でのベースラインとして、Standard PSO-2007(PSO-2007)<sup>11)</sup> が示され、さらに、2011 年には、改良版の Standard PSO-2011(PSO-2011)<sup>12)</sup> が示されている。SPSO-2011 は、CEC2013 のコンペティションで、総合で 20 位<sup>13)</sup> の性能を示し、PSO に基づくアルゴリズムの中では、2 番目の成績をあげている。本発表では、この SPSO-2011 と提案手法の性能を比較する。

### 3 トポロジーが変化する PSO

PSO の粒子の近傍関係のトポロジーとは、探索粒子間の結合形態であり、 $p_{id}$  を参照することができる近傍の探索粒子を定めるものである。探索粒子は初期探索粒子が生成される際に、生成された順番に番号が付けられていく。ネットワークトポロジーはこの番号を元に作られる。なお、ここでの近傍とは、解空間内での距離が近いという意味ではなく、初期化の際に定義された粒子の番号によって、結合しているものであり、双方向に情報交換 (*local best* の参照) が可能とされている。

これまでの検討から、PSO のパラメータが安定条件を満たしていても、Ring 構造の接続数によっては、探索粒子が早期に収束しないこと、特に接続数が多いすなわち、*local best* の共有範囲が大きいときに収束が速く、少ないときは収束しないケースがあることが実験的にも確認されている<sup>14)</sup>。

そこで、ここでは、Ring 構造の接続数を適切に変化させることにより、粒子が解候補の改善を続けるよう適切に動き続けることをはかるための、接続数の増減規則を実験的に求めていくことを考え、探索粒子の評価を行った後、更新した探索粒子の速度を更新前と比較し、探索粒子の速度が大きいたまには Ring 構造の接続数の増加させ、探索粒次ステップの速度が小さいときには Ring 構造の接続数を減少させることにより、大域探索と局所探索のそれぞれの機能をバランスさせるための接続の切り替え条件を検討する。

本手法の概要を Fig.1 に示す。PSO の探索粒子の数を  $N$ 、Ring 構造の接続数を  $R$  とし、 $\mathbf{r}(t)$  は、速度のもととなる合成ベクトルを表す。

$$\mathbf{r}(t) = (\mathbf{p}(t) - \mathbf{x}(t)) + (\mathbf{l}(t) - \mathbf{x}(t)) \quad (3)$$

この大きさに従って、接続数の増減を判定する際に用い




Fig. 1 提案手法の概要図

る定数として、 $\alpha_p, \alpha_m$  と  $\beta_p, \beta_m \in [0, 1]$  を導入する。実際には、つぎステップの  $\mathbf{r}(t+1)$  の大きさが大きくなったものと小さくなったものの割合で、それぞれ、接続数を増減させており、どの程度の変化であれば変化とカウントするか、どの程度の割合であればネットワークを操作するかを  $\alpha_p, \alpha_m, \beta_p, \beta_m$  の設定でチューニングできるようにしている。

すなわち、 $L(\cdot)$  を条件を満たす粒子の個数とするとき、以下のような単純な規則によって、Ring 構造の枝を増減させることとし、 $\alpha_p, \alpha_m, \beta_p, \beta_m$  による性能の違いを調査した。

- if  $L(\alpha_p |\mathbf{r}(t)| \leq |\mathbf{r}(t+1)|) < \beta_p N$  then  $R = R + 2$
- if  $L(\alpha_m |\mathbf{r}(t)| \leq |\mathbf{r}(t+1)|) > \beta_m N$  then  $R = R - 2$

### 4 実験

本研究で提案する PSO の性能を、2013 IEEE Congress on evolutionary computation (CEC2013) の Competition on Real Parameter Single Objective Optimization<sup>5)</sup> のベンチマーク問題を対象に検証した。このコンペティションは実パラメータの単目的最適化問題を対象に、進化計算などのアルゴリズムの性能を競うものである。  $f1 \sim f5$  は、Unimodal Function,  $f6 \sim f20$  は、Basic Multimodal Function,  $f21 \sim f28$  は、Composition Function である。

以下では実験設定について述べる。実験設定は<sup>5)</sup> と<sup>12)</sup> を参照した。ベンチマーク問題の次元数  $D = 10$  で、PSO の探索粒子の総数  $N = 40$  である。PSO の終了条件は探索粒子の評価回数が  $10000 * D$  に達したときとし、1つのベンチマーク問題に対して提案手法を 51 回試行する。PSO のパラメータの設定値は PSO の実験でよく用いられている値である  $w = 0.7, c_1 = c_2 = 1.4$  とした。そして、提案手法のパラメータである  $\alpha_p, \alpha_m, \beta_p, \beta_m$  は、予備実験から接続数の挙動が特徴的な Table 1 の組合せに対して、数値実験を行った。

Table 1 パラメータ設定

$\alpha_p$	$\alpha_m$	$\beta_p$	$\beta_m$
0.95	0.75	0.55	0.45
1.00	1.00	0.60	0.45
1.00	1.00	0.55	0.45

比較に用いた SPSO-2011 の結果を Table 2 に、提案

手法を用いた結果を Table 3-5 に示す。また, Fig. 2-4 には, それぞれのパラメータにおけるある 1 試行におけるすべての目的関数に対する Ring 構造の接続数の推移を示す。

Table 2 SPSO-2011 の評価結果<sup>12)</sup>

Function	$f(x^*)$	Min	Max	Median	Std
f1	-1.400E+03	-1.400E+03	-1.400E+03	-1.400E+03	0.000E+00
f2	-1.300E+03	7.853E+02	4.755E+05	3.504E+04	7.356E+04
f3	-1.200E+03	-1.200E+03	8.251E+07	2.670E+05	1.656E+07
f4	-1.100E+03	2.454E+02	1.856E+04	7.769E+03	4.556E+03
f5	-1.000E+03	-1.000E+03	-1.000E+03	-1.000E+03	3.142E-05
f6	-9.000E+02	-9.000E+02	-8.898E+02	-8.902E+02	4.974E+00
f7	-8.000E+02	-7.974E+02	-7.434E+02	-7.789E+02	1.327E+01
f8	-7.000E+02	-6.798E+02	-6.796E+02	-6.797E+02	6.722E-02
f9	-6.000E+02	-5.987E+02	-5.929E+02	-5.952E+02	1.499E+00
f10	-5.000E+02	-4.999E+02	-4.989E+02	-4.997E+02	2.713E-01
f11	-4.000E+02	-3.970E+02	-3.731E+02	-3.891E+02	5.658E+00
f12	-3.000E+02	-2.970E+02	-2.682E+02	-2.861E+02	6.560E+00
f13	-2.000E+02	-1.946E+02	-1.523E+02	-1.792E+02	9.822E+00
f14	-1.000E+02	2.228E+02	1.109E+03	7.338E+02	2.335E+02
f15	1.000E+02	4.372E+02	1.705E+03	8.743E+02	2.507E+02
f16	2.000E+02	2.002E+02	2.014E+02	2.005E+02	2.457E-01
f17	3.000E+02	3.104E+02	3.416E+02	3.189E+02	5.873E+00
f18	4.000E+02	4.125E+02	4.365E+02	4.178E+02	4.534E+00
f19	5.000E+02	5.003E+02	5.019E+02	5.009E+02	3.886E-01
f20	6.000E+02	6.020E+02	6.040E+02	6.034E+02	4.194E-01
f21	7.000E+02	1.100E+03	1.100E+03	1.100E+03	0.000E+00
f22	8.000E+02	1.206E+03	2.388E+03	1.706E+03	3.431E+02
f23	9.000E+02	1.016E+03	2.776E+03	1.810E+03	3.596E+02
f24	1.000E+03	1.162E+03	1.222E+03	1.214E+03	9.166E+00
f25	1.100E+03	1.300E+03	1.320E+03	1.309E+03	5.943E+00
f26	1.200E+03	1.307E+03	1.520E+03	1.400E+03	5.513E+01
f27	1.300E+03	1.602E+03	1.898E+03	1.636E+03	7.359E+01
f28	1.400E+03	1.500E+03	2.009E+03	1.700E+03	8.362E+01

いくつかのベンチマーク問題において提案手法の方が SPSO-2011 の結果よりも良い性能を示した。特に, パラメータを変化させても, f4, f21, f25 に対して提案手法は SPSO-2011 よりも良い性能を示している場合が多いことがわかっている。このように, Ring 構造の接続数を, 探索粒子の速度を比較することで変化させる PSO で, 単純な規則の導入のみで, 半数近いベンチマークで SPSO-2011 と同等の性能が出ることが示された。

## 5 おわりに

本研究では, PSO の探索粒子が形成するネットワークポロジに着目し, パラメータではなくネットワークポロジの接続数を変化させることで, PSO の性能改善を行うことを目的とした。そして, ネットワークポロジが Ring 構造である PSO において, 探索粒子の速度変化から Ring 構造の接続数を PSO の探索途中で変化させる手法を提案した。

性能比較実験により, SPSO-2011 と提案手法の性能比較を行った結果, いくつかのベンチマーク問題において, 提案手法の方が良い性能を示し, よいパラメータの組合せによっては半数程度で同等かそれに近い結果を得た。

PSO の動作モデルのパラメータ  $w$ ,  $c_1$ ,  $c_2$  の値は固定していたが, この値を調整することでさらなる性能改善が見込まれる。一方で, ここで導入した接続数増減規則を定めるパラメータに対して, 実際の接続数の変化の過程がセンシティブであることから, その要因を考察することは今後の課題である。

Table 3 ベンチマークに対する提案法の結果

Benchmark functions		$(\alpha_p = 0.95, \alpha_m = 0.75, \beta_p = 0.45, \beta_m = 0.55)$			
Function		Min	Max	Median	Std
f1		-1.350E+03	2.097E+03	-7.400E+02	9.391E+02
f2		1.256E+05	1.946E+07	3.194E+06	4.247E+06
f3		5.747E+06	3.095E+10	4.637E+09	6.375E+09
f4		1.785E+03	4.380E+04	1.223E+04	9.992E+03
f5		-9.812E+02	6.175E+02	-7.890E+02	3.458E+02
f6		-8.873E+02	-6.712E+02	-8.200E+02	4.756E+01
f7		-7.817E+02	-4.032E+02	-7.214E+02	5.727E+01
f8		-6.798E+02	-6.795E+02	-6.796E+02	<b>6.006E-02</b>
f9		-5.952E+02	-5.902E+02	-5.922E+02	<b>1.130E+00</b>
f10		-4.953E+02	1.355E+02	-3.841E+02	1.203E+02
f11		-3.779E+02	-2.801E+02	-3.401E+02	2.507E+01
f12		-2.751E+02	-1.873E+02	-2.402E+02	2.299E+01
f13		-1.696E+02	-8.321E+01	-1.314E+02	2.144E+01
f14		4.425E+02	1.857E+03	1.196E+03	3.269E+02
f15		7.582E+02	2.060E+03	1.336E+03	2.885E+02
f16		2.003E+02	2.016E+02	<b>2.009E+02</b>	3.051E-01
f17		3.385E+02	4.219E+02	3.757E+02	2.112E+01
f18		4.390E+02	5.343E+02	4.656E+02	2.533E+01
f19		5.027E+02	1.166E+03	5.150E+02	1.199E+02
f20		6.021E+02	6.050E+02	6.036E+02	6.347E-01
f21		1.102E+03	1.238E+03	1.125E+03	3.107E+01
f22		1.865E+03	2.901E+03	2.315E+03	<b>2.956E+02</b>
f23		1.561E+03	3.153E+03	2.521E+03	<b>3.546E+02</b>
f24		<b>1.132E+03</b>	1.227E+03	1.222E+03	1.290E+01
f25		<b>1.280E+03</b>	1.327E+03	1.321E+03	7.022E+00
f26		1.328E+03	1.526E+03	1.401E+03	<b>4.303E+01</b>
f27		1.726E+03	<b>1.871E+03</b>	1.816E+03	<b>2.797E+01</b>
f28		1.687E+03	2.441E+03	2.249E+03	1.702E+02

Table 4 ベンチマークに対する提案法の結果

Benchmark functions		$(\alpha_p = 0.95, \alpha_m = 0.75, \beta_p = 0.45, \beta_m = 0.55)$			
Function		Min	Max	Median	Std
f1		-1.397E+03	3.173E+03	-1.089E+03	7.069E+02
f2		<b>-2.790E+02</b>	1.043E+07	2.964E+05	1.570E+06
f3		6.084E+07	1.024E+10	1.137E+09	2.214E+09
f4		<b>-8.689E+02</b>	2.302E+04	<b>5.425E+03</b>	5.971E+03
f5		-9.978E+02	-7.305E+02	-9.064E+02	5.965E+01
f6		-8.997E+02	-6.774E+02	-8.590E+02	5.192E+01
f7		-7.882E+02	-6.528E+02	-7.486E+02	3.167E+01
f8		-6.798E+02	-6.795E+02	-6.796E+02	7.646E-02
f9		-5.946E+02	-5.906E+02	-5.922E+02	<b>1.028E+00</b>
f10		-4.991E+02	-2.021E+02	-4.618E+02	6.049E+01
f11		-3.884E+02	-3.017E+02	-3.633E+02	1.785E+01
f12		-2.864E+02	-1.892E+02	-2.611E+02	1.918E+01
f13		-1.939E+02	-7.972E+01	-1.560E+02	2.052E+01
f14		<b>5.621E+01</b>	1.467E+03	8.566E+02	2.822E+02
f15		5.177E+02	<b>1.521E+03</b>	1.022E+03	<b>2.415E+02</b>
f16		2.004E+02	2.014E+02	<b>2.010E+02</b>	<b>2.222E-01</b>
f17		3.232E+02	3.989E+02	3.415E+02	1.906E+01
f18		4.210E+02	5.086E+02	4.416E+02	1.588E+01
f19		5.007E+02	1.075E+03	5.042E+02	8.014E+01
f20		6.026E+02	6.050E+02	6.035E+02	4.565E-01
f21		<b>9.814E+02</b>	1.181E+03	1.108E+03	2.479E+01
f22		<b>1.187E+03</b>	2.519E+03	1.902E+03	<b>2.703E+02</b>
f23		1.499E+03	<b>2.600E+03</b>	2.053E+03	<b>2.517E+02</b>
f24		1.213E+03	1.225E+03	1.218E+03	<b>2.497E+00</b>
f25		1.316E+03	1.324E+03	1.321E+03	<b>2.350E+00</b>
f26		1.335E+03	<b>1.515E+03</b>	1.400E+03	<b>2.468E+01</b>
f27		1.700E+03	<b>1.833E+03</b>	1.779E+03	<b>2.647E+01</b>
f28		1.574E+03	2.459E+03	2.162E+03	1.643E+02

## 参考文献




- 1) J. Kennedy and R. Eberhart : Particle swarm optimization, *Proceedings of the 1995 IEEE International Conference on Neural Networks*, 1942/1948, (1995)
- 2) X.S. Yang, : "Firefly algorithms for multimodal optimization," *Stochastic algorithms: foundations and applications*, Springer Berlin Heidelberg, 169/178, (2009)
- 3) Blum, Christian, and Xiaodong Li : *Swarm intelligence in optimization*. Springer Berlin Heidelberg, (2008)
- 4) R. Storn P. Kenneth : "Differential evolution a simple and efficient heuristic for global optimization over continuous spaces," *Journal of global optimization*,

Table 5 ベンチマークに対する提案法の結果

Benchmark functions ( $\alpha_p = 0.95, \alpha_m = 0.75, \beta_p = 0.45, \beta_m = 0.55$ )				
Function	Min	Max	Median	Std
f1	-1.397E+03	3.798E+02	-1.201E+03	3.772E+02
f2	<b>-5.325E+02</b>	8.761E+06	3.394E+05	1.700E+06
f3	2.585E+07	1.108E+10	1.595E+09	2.680E+09
f4	<b>-8.599E+02</b>	3.760E+04	<b>6.977E+03</b>	6.565E+03
f5	-9.854E+02	-7.342E+02	-9.137E+02	5.602E+01
f6	-8.971E+02	-7.116E+02	-8.798E+02	3.811E+01
f7	-7.872E+02	-6.542E+02	-7.538E+02	3.412E+01
f8	-6.798E+02	-6.795E+02	-6.796E+02	<b>6.607E-02</b>
f9	-5.964E+02	-5.903E+02	-5.920E+02	<b>1.444E+00</b>
f10	-4.985E+02	-1.331E+02	-4.500E+02	6.699E+01
f11	-3.860E+02	-3.198E+02	-3.632E+02	1.583E+01
f12	-2.850E+02	-2.086E+02	-2.599E+02	1.880E+01
f13	-1.875E+02	-1.229E+02	-1.545E+02	1.400E+01
f14	<b>9.355E+01</b>	1.375E+03	8.795E+02	2.676E+02
f15	<b>2.386E+02</b>	<b>1.539E+03</b>	1.006E+03	<b>2.506E+02</b>
f16	2.006E+02	2.015E+02	2.010E+02	<b>2.029E-01</b>
f17	3.245E+02	4.091E+02	3.425E+02	1.780E+01
f18	4.252E+02	4.816E+02	4.439E+02	1.282E+01
f19	5.010E+02	9.033E+02	5.037E+02	5.811E+01
f20	<b>6.011E+02</b>	6.050E+02	6.035E+02	6.532E-01
f21	<b>1.071E+03</b>	1.221E+03	1.110E+03	2.242E+01
f22	1.408E+03	2.486E+03	1.959E+03	<b>2.780E+02</b>
f23	1.289E+03	<b>2.588E+03</b>	2.069E+03	<b>2.867E+02</b>
f24	1.202E+03	1.223E+03	1.219E+03	<b>3.793E+00</b>
f25	<b>1.289E+03</b>	1.325E+03	1.321E+03	6.400E+00
f26	1.338E+03	1.520E+03	1.401E+03	<b>2.792E+01</b>
f27	1.728E+03	<b>1.842E+03</b>	1.789E+03	<b>2.762E+01</b>
f28	1.601E+03	2.391E+03	2.158E+03	1.316E+02

Vol. 11, No. 4, 341/359, (1997)

- 5) J. J. Liang, B. Y. Qu, P. N. Suganthan, Alfredo G. Hernandez-Diaz : "Problem Definitions and Evaluation Criteria for the CEC 2013 Special Session on Real-Parameter Optimization," *Technical Report 201212, Computational Intelligence Laboratory, Zhengzhou University, Zhengzhou China And Technical Report, Nanyang Technological University, Singapore*, (2013)
- 6) 若佐裕治, 田中幹也, 明石卓也 : Particle Swarm Optimization アルゴリズムの安定性解析, システム制御情報学会論文誌, Vol.23, No.1, 9/15, (2010)
- 7) N. Iwasaki, K. Yasuda, and G. Ueno : Particle Swarm Optimization : Dynamic Parameter Adjustment Using Swarm Activity, *Proceedings of the 2008 IEEE International Conference on Systems, Man and Cybernetics*, 2634/2639, (2008)
- 8) R. Eberhart and J. Kennedy : A new optimizer using particle swarm theory, *Proceedings 6th International Symposium on Micromachine Human Science*, 39/43, (1995)
- 9) J. Kennedy and R. Mendes : Population Structure and Particle Swarm Performance, *Proceedings of the 2002 IEEE Congress on Evolutionary Computation*, 1671/1676, (2002)
- 10) R. Mendes, J. Kennedy and J. Neves : The Fully Informed Particle Swarm: Simpler, Maybe Better, *IEEE transactions on evolutionary computation*, Vol.8, No.3, 204/210, (2004)
- 11) D. Bratton, J Kennedy : Defining a Standard for Particle Swarm Optimization, *Proceedings of the 2007 IEEE Intelligence Symposium*, (2007)
- 12) M. Zambrano-Bigiarini, M. Clerc, R. Rojas : Standard Particle Swarm Optimization 2011 at CEC2013: A baseline for future PSO improvements, *Proceedings of the 2013 IEEE Congress on Evolutionary Computation*, 2337/2344, (2013)
- 13) I. Loshchilov, T. Stuetzle and T. Liao : "Ranking Results of CEC'13 Special Session & Competition on Real-Parameter Single Objective Opti-

Fig. 2 接続数の変化の例 ( $\alpha_p = 0.95, \alpha_m = 0.75, \beta_p = 0.55, \beta_m = 0.45$ )Fig. 3 接続数の変化の例 ( $\alpha_p = 1.00, \alpha_m = 1.00, \beta_p = 0.60, \beta_m = 0.40$ ) の場合)Fig. 4 接続数の変化の例 ( $\alpha_p = 1.00, \alpha_m = 1.00, \beta_p = 0.55, \beta_m = 0.45$ ) の場合)mization, [http://www.ntu.edu.sg/home/EPNSugan/index\\_files/](http://www.ntu.edu.sg/home/EPNSugan/index_files/), (2013)

- 14) 酒井, 畠中 : 探索点間の結合が探索に及ぼす影響についての検討, 第6回コンピュータショナル・インテリジェンス研究会講演論文集, (2014)

# 進化的実験計画におけるベンチマーク問題

○内種岳詞 (国立研究開発法人理化学研究所, JST CRST)

## Benchmark Problems for Evolutionary Design of Experiments

\*T. Uchitane (RIKEN, JST CRST)

**Abstract**— Applying analyses for big scale system is often required even if the number of numerical executions gets larger exponentially. However, the number of factors to affect the results of such analyses is fewer than the number of data points in parameter space. This implies that enough analyses results can be estimated if fewer number of system input-output data sets are obtained. The goal of this study is to develop a framework to get good estimation of such analyses by using parameter selection algorithms which is based on evolutionary algorithms. In this paper, benchmark problems are proposed to evaluate the proposed framework.

**Key Words:** huge parameter space, design of experiment, analysis of variance, multivariate analysis, data clustering

### 1 はじめに

計算機の性能向上に伴い、より規模の大きな問題を取り扱いが可能となってきた。問題の規模は様々な解釈が可能であるが、ここではパラメータ空間の大きさを考える。パラメータ空間の大きさは、パラメータ数と各パラメータの水準数によって決定される。一般的に、パラメータ数やその水準数が増えるにつれ、問題の規模が爆発的に増大する。そのため、パラメータの全組み合わせを試行することが困難になる。そのようなシステムの最適な出力をパラメータの全組み合わせを試行することなく得ることを目的に、遺伝的アルゴリズムや粒子群最適化アルゴリズムなど様々な進化計算<sup>1)</sup>の手法が開発されその有用性が示されてきた。

一方で、システムの分析をパラメータの全組み合わせを試行することなく得るための手法も開発されている。システムの分析をより少ない試行数で分析する枠組みは、実験計画法<sup>2)</sup>と呼ばれている。実験計画法はシステムの分析方法ごとに実験計画を立案する必要がある。たとえば、システムの分散分析を行う場合、システムの出力に影響を与えるパラメータやパラメータの交互作用を直交表に割りつけることにより試行数を減らせる。パラメータ数が7かつ水準数が3のとき、パラメータの全組み合わせ数は $3^7$ であるが、交互作用は存在しないと仮定しパラメータの直交関係を考慮することにより試行数は18となる。このように、分析に応じた実験計画を作成することにより試行数のオーダーを下げるのが可能となる。試行数を削減できるのは、システムの応答を入力変数の数の累乗オーダー程度のモデル変数を用いて説明するためである。すなわち、分析で用いるモデルの構造式は入力変数空間の大きさ程の自由度を持たない。そのため、分散分析では直交表を用いるなど、すべてのパラメータの組み合わせを試行することなくデータの構造式を決定できる。

大規模なシステムの分析においては、入力変数の数が増加するため、従来の実験計画法を利用して削減した試行数でさえ応答を得るのが困難となる。たとえば、大規模なシステムの分散分析に用いられるモデルの自由度の増加は、入力変数の交互作用を考慮するためである。交互作用は複数の入力変数を同時に変化させたことが出力値の変化に与える影響を見ることである。こ

こで、入力変数間のすべての交互作用を考慮しなければならないシステムは多くないと考える。すると、入力変数間のすべての交互作用を考慮して立案した実験計画には、解析結果に与える影響が小さい試行が多く含まれている可能性がある。よって、分析に必要な試行だけを探索することで、より少ない試行数で分析結果を得られる可能性がある。たとえば、松島らはシステムの出力が大きく変化する入力変数を発見するために、分散分析の実験計画をシステムの規模に合わせて設計するのではなく、一部のパラメータの組に対して分散分析を行いその結果を判断して実験計画を更新する動的な実験計画法を提案している<sup>3)</sup>。実験計画を分析結果に応じて動的に生成することで、分析結果に与える影響が小さい試行を取り除くことが示されており、試行数が削減されている。

これらの背景より、本研究では、進化計算にヒントを得て、分析結果に与える影響が大きいパラメータの組み合わせを動的に探索することで、より少ない実験数で大規模システムの分析を実現することを目指す。進化計算では、探索すべき入力変数の組を探索済みのシステム応答を参照し動的に生成している。分析における動的な実験計画の文脈においても、探索すべき入力変数の組をシステム応答を参照して生成できるのであれば、妥当な分析結果を得られる可能性があると考えられる。目標の実現のためには、提案手法の性能を測るベンチマーク問題の構築、分析のためのパラメータ探索手法の構築、そして、実問題への適用を行う必要がある。そこで、本稿では、大規模なシステムの分析のベンチマーク問題を提案する。

### 2 大規模システムの分析手法

対象となるシステム方程式を式(1)に示す。

$$Y = F(X), X \in \mathbb{R}^N, Y \in \mathbb{R}^M \quad (1)$$

ここで、 $X, Y, F$  はそれぞれ、入力変数、出力変数、システム関数を表す。 $N$  はパラメータの数であり、 $M$  は出力結果の数である。システムの規模  $S$  は、式(2)

で定める。

$$S = \sum_i^N Level(x_i), x_i \in X \quad (2)$$

ここで、 $Level(x_i)$  は、 $i$  番目の入力変数  $x_i$  の水準数である。たとえば、パラメータ数  $N = 100$  かつ各パラメータ水準が 2 のとき、 $S = 2^{100}$  となる。

システムの分析方法は、以下の 3 種に分類できる。

- Type I: 入力変数  $X$  の属性を得る
- Type II: 出力変数  $Y$  の属性を得る
- Type III: システム関数  $F$  の属性を得る

たとえば、分散分析は入力変数が結果に与える影響を知ることが目的である。そのため、Type I に分類される。また、主成分分析は、多変量の出力変数間の関係を知ることが目的である。そのため、Type II に分類される。最後に、ニューラルネットワークを利用したデータクラスタリングは、分類器の学習によりシステム関数の特徴を得ることが目的である。そのため、Type III に分類される。一般的に、このような分析において得られる属性の数は、パラメータの数や出力変数の数のオーダーであり、パラメータの組み合わせを考慮した試行数のオーダーよりも小さい。

### 3 ベンチマーク問題の構築

#### 3.1 Type I ベンチマーク問題

分散分析は、入力変数が結果に与える影響を知ることが目的である。以下の 3 つのシステム関数に分散分析を適用することを考える。

$$F_{I,1}(X) = y_1 = \sum_{i=1}^N x_i \quad (3)$$

$$F_{I,2}(X) = y_1 = \sum_{i=1}^N x_i^2 \quad (4)$$

$$F_{I,3}(X) = y_1 = \sum_{i=1}^{N-1} (1 - x_i^2) + 100(x_{i+1} - x_i^2) \quad (5)$$

式 (3) と式 (4) のシステム関数では変数間の関係性がないため、入力変数の各  $x_i$  を要因として直交表に割り当て分散分析を行える。すなわち、分析モデルの自由度は入力変数の数のオーダーでとなり爆発しない。一方、式 (5) のシステム関数では変数間に関係性があるため、入力変数の各  $x_i$  を要因とするに加え、 $x_i$  間の交互作用を要因として分散分析を行う必要がある。交互作用を考慮する場合、要因を割り当てる直交表もより試行数の多いものとなる。しかし、交互作用が存在する入力変数の組の数は入力変数の数のオーダーである。そのため、要因の影響を推定しつつ動的に試行数を増やすことで試行数を削減することが期待される。

#### 3.2 Type II ベンチマーク問題

多変量解析の 1 手法である主成分分析は、出力変数間の関係を知ることが目的である。以下のシステム関

数に主成分分析を適用することを考える。

$$\begin{aligned} F_{II,1} &= [y_1, y_2, y_3, y_4]^T \\ &= \left[ \sum_{i=1}^{\frac{N}{2}} 2x_i, \sum_{i=\frac{N}{2}+1}^N 2x_i, \frac{y_1 + y_2}{2}, 2y_1 - y_2 \right]^T \quad (6) \end{aligned}$$

主成分分析では、システムの入力の相関を考慮して結果を見る軸を回転する。複数の出力変数を回転後の 1 軸で表現することにより、システムの入力変数の数より少ない軸の数で出力変数を説明可能になる。このような軸の回転や各軸が説明できる出力変数の割合は、システムの入力の相関行列から求められる。 $F_{II,1}$  の出力変数では、 $y_1$  と  $y_2$  の組と  $y_3$  と  $y_4$  の組は互いに無相関であり、 $y_3$  は  $y_1$  と  $y_2$  と正の相関を持ち、 $y_4$  は  $y_1$  と正の相関を持ち  $y_2$  と負の相関を持つ。そのため、妥当な相関行列が得られるパラメータの組み合わせを優先的に試行することで試行数を削減できることが期待される。

#### 3.3 Type III ベンチマーク問題

ニューラルネットワークを利用したデータクラスタリングは、分類器の学習によりシステム関数の特徴を得ることが目的である。以下の 4 つのシステム関数の入出力をニューラルネットワークで学習することを考える。

$$\begin{aligned} F_{III,1}(X) &= y_1 \\ &= XOR\left(\sum_{i=1}^{N/2} x_i >= \frac{N}{2}, \sum_{i=N/2+1}^N x_i >= \frac{N}{2}\right) \quad (7) \end{aligned}$$

$$\begin{aligned} F_{III,2}(X) &= y_1 \\ &= AND\left(a < \sum_{i=1}^{N/2} x_i < b, \right. \\ &\quad \left. a < \sum_{i=N/2+1}^N x_i < b\right) \quad (8) \end{aligned}$$

$$\begin{aligned} F_{III,3}(X) &= y_1 \\ &= LOGIC\left(\sum_{i=1}^{N/2} x_i + \sum_{i=N/2+1}^N x_i < \frac{N}{4}\right) \quad (9) \end{aligned}$$

ここで、 $XOR$ ,  $AND$ ,  $LOGIC$  はそれぞれ排他的論理和、論理積、真偽を求める論理式である。また、各  $x_i$  の水準を  $[0, 1]$  の 2 水準とする。これらのシステム関数では  $\sum_{i=1}^{N/2} x_i$  や  $\sum_{i=N/2+1}^N x_i$  がある値となる入力変数の組み合わせが複数通りあり、全ての組み合わせを試行する必要はないと考えられる。また、ニューラルネットワークの重みを学習するために  $\sum_{i=1}^{N/2} x_i$  や  $\sum_{i=N/2+1}^N x_i$  が取りうる値をすべて含む学習データも必要かどうか不明である。そのため、少ない試行数で分析を行い、学習に影響を与える可能性が高いパラメータの組み合わせを追加していくことで、より少ない試行回数で分析が実現できると期待される。

## 4 分析に必要な試行数の考察

提案したベンチマーク問題それぞれにおいて、妥当な分析結果を得るために必要な試行の組み合わせを求める。分析結果の妥当性は、パラメータの全組み合わせの試行に対する分析結果と比較することにより検証する。

### 4.1 Type I 分析

分散分析では、要因ごとに F 値を求め、要因が結果に影響を与えるかを仮説検定する。入力変数の数  $N$  に対し、2 変数間の交互作用までを考慮した要因数は、 $N + {}_N C_2$  であり、 $N$  の累乗に比例して増加する。また、 $N = 10, 11, 12$  とすると、要因はそれぞれ 55, 66, 78 であり、要因を直行するように割り付けた試行数はそれぞれ 56, 68, 80 である。よって、入力変数の数  $N$  が増加すると従来の実験計画方による試行数は  $O(N^2)$  で増加する。しかし、 $F_{I,1}$  や  $F_{I,2}$  のように、変数間の交互作用が存在しないシステム関数に対する分析では、必要な要因数は  $N$  であり必要な試行数は  $O(N)$  となる。また、 $F_{I,3}$  のように、変数間の相互作用が存在するがインデックスが隣り合う変数の組み合わせに限定されているシステム関数に対する分析では、必要な要因数は  $N + N - 1$  であり必要な試行数は  $O(N)$  となる。進化計算にヒントを得て試行を選択するときには、結果的に試行数が  $O(N)$  となり、かつ、妥当な要因の F 値が得られることが期待される。

### 4.2 Type II 分析

主成分分析では、出力変数の相関行列から座標を回転して新たな軸とする。よって、より少ない試行数で妥当な相関行列を得るためには、出力変数空間での多様性を最大化するように試行を選択すれば良い。 $F_{II,1}$  の出力変数  $y_1, y_2, y_3, y_4$  は、各入力変数が  $[0, 1]$  の 2 水準を取るとき、それぞれ整数値となり、その値域は  $[0, N]$  である。よって、より少ない試行数で各出力変数の分散を妥当に見積もるためには、無作為に試行を選択するのではなく、一様に試行を選択する必要がある。一様に試行を選択する方法として直交表を用いると、入力変数  $N$  に対して必要な試行数は  $O(N)$  となる。しかし、システム関数によっては選択すべき試行が一様であるとは限らない。進化計算にヒントを得て試行を選択するときには、結果的に一様な選択が行われることが期待される。


### 4.3 Type III 分析

ニューラルネットワークを用いた入出力の学習において、学習データの質は高いほど良い。しかし、試行数を限定したとき、妥当な学習結果を導くための学習データの条件は明らかではない。そこで、 $F_{III,1}$  において、 $\sum_{i=1}^{N/2} x_i$  と  $\sum_{i=N/2+1}^N x_i$  を改めて変数  $x_1, x_2$  と見なして学習データに必要な条件を考える。

Fig. 1 に学習データを 100 点利用したニューラルネットワークの学習結果を示す。利用したニューラルネットワークのモデルは統計処理ソフトウェア R のパッケージ “nnet”<sup>4)</sup> に準拠する。ネットワークのモデルは、2 入力 1 出力で中間層を 1 層もつ。ニューロンの出力関数にはシグモイド関数を利用し中間層のニューロン数の推定を行う。Fig. 1 より、システム関数の入

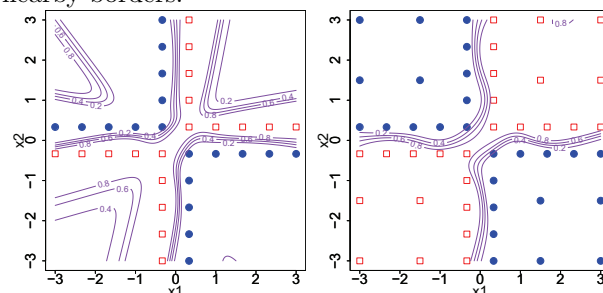
出力をより良く近似できるデータは、入力変数空間で一様に分布していることが求められると考える。

Fig. 1: Examples of pattern classification learning for  $F_{III,1}$  system function. *TRUE* is described as a mark of rectangle and *FALSE* is described as a mark of circle. Level curves of  $NN$  as a probability density function are drawn. In the left figure, a pattern classifier for grid pattern data points is shown and in the right figure, a pattern classifier for random pattern data points is shown.



次に、入力変数空間において試行を削減することを考える。Fig. 2 に出力値が変化する付近のデータ点を集めて学習を行った結果と、出力値が変化する付近のデータ点に加え出力値の変化が起きない領域のデータ点を数点集めて学習を行った結果を示す。Fig. 2 より出力値が変化する付近の入力値だけでなく、出力値が変化しない領域の入力値も学習には必要であることが分かった。よって、出力値が変化する付近の入力値をより多く含み、かつ、出力値が変化しない領域の入力値も含む学習データが必要であると考えられる。

Fig. 2: Examples of pattern classification learning for  $F_{III,1}$  system function with fewer data points. The left figure shows that learned  $NN$  from data points nearby borders. And the right figure shows that learned  $NN$  from data points not only nearby borders and also a few additional points. The pattern classifier in the right  $NN$  is better than the left. This indicate that it is not enough to obtain data points nearby borders.



ここまでは、入力変数の数を 2 と見なして議論を行ったが、実際の学習では入力変数の数は  $N$  である。すると、出力値が変化する付近のデータ点は、多次元平面の付近のデータ点となる。そのため、多次元平面の同定を行い必要性の高い試行を探索する必要がある。ここで、多次元平面の自由度は、入力変数の数である。そのため、必要な試行数は、入力変数の数のオーダーとなることが期待される。

$F_{III,2}$ ,  $F_{III,3}$  に対しても、必要な試行数のオーダー

の見積には同様の議論が成り立つと考える。しかし、出力値が変化する境界となる多次元平面の数がシステムごとに異なるため、多次元平面の数が分析結果と必要な試行数へ与える影響を考慮できる。

## 5 おわりに

大規模システムに対するさまざまな分析において、試行の組み合わせを限定しても分析結果を得られるシステム関数が存在することを示した。そのようなシステム関数に対して、分析に必要な入力変数の組を動的に探索すれば、より少ないシステム関数の計算回数で分析を達成できる可能性がある。本稿では、進化計算にヒントを得て入力変数の組み合わせを動的に選択する進化的実験計画法の提案に先立ち、提案手法評価のためのベンチマーク問題を定式化した。ベンチマーク問題は、分析の種類ごとにより少ない試行数で分析が可能であるシステム関数を含んでいる。次の課題は、進化的実験計画法を提案し、小-中規模のシステムにおいて試行数がどれだけ削減可能かを調査することである。

## 謝辞

本研究は JSPS 科研費 15K17502 の助成を受けたものである。

## 参考文献

- 1) 電気学会進化技術応用調査専門委員会: 進化技術ハンドブック;第1巻;基礎編 (2010)
- 2) 永田靖: 入門 実験計画法, 日科技連出版社 (2000)
- 3) 松島裕康, 山下倫央, 野田五十樹: 実験計画法に基づくパラメータ探索を用いた大規模マルチエージェントシミュレーションの解析, Proceedings of The 27th Annual Conference of the Japanese Society for Artificial Intelligence (2013)
- 4) W. N. Venables and B. D. Ripley: Modern Applied Statistics with S, 4th ed. Springer (2002)



# 遺伝的アルゴリズムに基づく 病院給食の献立立案支援システムにおける性能評価

○磯川悌次郎 松井伸之 (兵庫県立大学)

## Performance Evaluation for Hospital Meal Menu Production Based on Genetic Algorithm

\*T. Isokawa and N. Matsui (University of Hyogo)

**Abstract**— One of the approaches for improving quality of life of patients who are undergoing hospitalization is to improve hospital meals that are provided to them. To plan daily menus for hospital meals is very cumbersome, which involves many conditions for nutrition and allergies, and this will become difficult if patients' preferences of foods are also taken into consideration for a purpose of enhancing patients' quality of life. This task can be formulated as an optimization problem with menu items as variables and specific nutritional and allergic as its constraints. We have proposed a menu creation scheme to satisfy these conditions with being incorporated patients' food preferences, and shows a preliminary result for creating menus for a patient. A genetic algorithm was utilized to better and more efficiently locate combinations of menu dishes for individual patients. This paper demonstrates that a variety of menus can be produced for patients with several ranges of ages, three types of physical activities, and allergic conditions.

**Key Words:** Hospital meals, nutrition intakes, genetic algorithm

### 1 はじめに

様々な疾患により病院に入院を余儀なくされる患者にとって生活の質 (Quality of Life; QOL) は重要な要素であり、これを向上させることは間接的に疾患の治療にもつながると考えられる。入院生活における QOL を向上させる手段の一つとして、病院内にて提供される食事いわゆる病院給食の改善が重要である。現在、様々な病院において病院食のレシピならびにレシピの組み合わせである献立の改善が行われているが、各患者の摂取制限などの様々な制約を満足する献立を日々構築してゆくことは困難であり、各患者の嗜好などを満足することは人手では不可能に近い。

これまでに栄養計算を考慮に入れた献立作成を支援する手法が提案されている。例えば文献<sup>1)</sup>においては摂取栄養素等を考慮したレシピを複数提案するが、どのレシピを献立に含めるかについては使用者が選択する必要がある。主食、主菜などの種別毎に手動でレシピ選択を行う必要がある。文献<sup>2)</sup>のシステムでは自動的に献立の作成を行うことができるが、一度に作成することができる献立は一食のみにとどまっている。文献<sup>3)</sup>においては、摂取栄養素を考慮したレシピを複数組み合わせることにより複数日の献立作成を行うことができるが、病院給食における献立作成において重要であるアレルギーについては考慮していない。

このような背景により、著者らは病院食に対応した献立提案システムを提案している<sup>4)</sup>。本システムでは、遺伝的アルゴリズムを用いることにより、患者の身体特性 (年齢、性別、身長、体重など)、栄養摂取制限ならびに嗜好などを考慮した献立の作成を行うことができる。しかしながら、文献<sup>4)</sup>においては、本提案システムの出力例として一名の仮想患者に対する献立作成例しか示されていない。そこで本論文では、提案システムに対して様々な身体特性を有する患者群に対して献立作成を行うことにより、様々な条件下において安定した献立作成ができることを示す。

### 2 摂取目標量

摂取バランスを考慮するためには、患者に応じて食事の摂取目標量を定める必要がある。本システムでは、その目標量の基準として食品群別摂取量および食品成分別摂取量を用いる。食品群別摂取量および食品成分別摂取量は年齢、性別、体重、身体活動レベルより1日の摂取目標量をそれぞれ求めることができる。なお、身体活動レベルとは日常の身体活動を「低い」、「普通」、「高い」の3段階に区別したものであり、それぞれレベル I, II, III として表記される。レベル I の身体活動とは生活の大部分を座位で過ごし静的な活動が中心であるというものを指す。また、レベル II では座位で過ごすことが中心であるが、移動や立位での作業や軽いスポーツをする程度の身体活動を指す。レベル III はさらに高い身体活動を指す者で有り、移動や立位での仕事が多い仕事に従事しており、活発な運動習慣がある。

本研究では食品群別摂取量および食品成分別摂取量が定められた目標量を偏りなく満たしているものを摂取バランスの良い献立とする。食品成分別摂取量 (Intakes for Food Constituents; IFC) は、三大栄養素であるたんぱく質、脂肪、炭水化物にエネルギー、塩分を加えた5項目における1日の摂取量である。食品群別摂取量 (Intakes for Food Groups; IFG) は、各食品群における1日の摂取量である。ここで食品群とは、栄養的によく似た食品をまとめた集まりであり、本研究では Table 1 に示す4群点数法に基づく分類を採用する。各摂取項目には1日における摂取目標量が定められており、身体情報から文献<sup>5)</sup>より設定することができる。

### 3 提案システム

本研究で提案するシステムでは、入力された身体情報および選択されたレシピに対して摂取バランスを考慮した献立を作成・提示する。具体的には、設定した摂取目標量が充足される割合 (充足率) を計算し、予め設定した閾値を超える献立の組み合わせを探索し提示

Table 1: Four core food groups and their constituents

Group	Foods
1	Milk, dairy products (cheese), eggs (of hens, quails)
2	Seafood (fish, shellfish, calamari), meat (beef, pork, chicken), beans, bean products (bean curd)
3	Vegetables (carrots, spinach), tubers, roots (potatoes, sweet potatoes), fruits (oranges, apples)
4	Grains, cereals (rice, noodle, bread), sugars (caster sugar), fats (sunflower oil, batter)

する。本システムでは、5日分の昼食と夕食の献立(計10食分)を作成する。なお、献立は主食、主菜、副菜2品、汁物の組み合わせにより構成される。ただし、計10食の献立の中では主菜の重複を禁止している。

本提案システムにおいて用いる摂取目標量は、患者の身体情報から計算される。ただし、身長、体重から求めたBMI(ボディマス指数)が18.5未満もしくは25以上の場合、すなわち低体重者または肥満者の場合には、身長に対する適正体重を利用して摂取目標量を設定する。次に、摂取目標量の1/3を一食分の規定量に設定する。この規定量は昼食時の献立を作成する際に用いられる。夕食時の規定量は昼食の過不足分を補うように設定する。すなわち、各摂取項目における第1日目から第5日目までの過不足分の平均をとり、夕食時の規定量に加えることにより昼食時の過不足分を補う。

本手法においては、レシピを適切に組み合わせる献立を作成する方法として遺伝的アルゴリズム(Genetic Algorithm; GA)を導入する。GAを適用するためには、解候補個体(染色体)の表現方法、その個体を評価する評価関数、ならびに個体群に対する遺伝的操作(選択、交叉、突然変異)の定義が必要となる。

各個体は献立候補であるので、主食、主菜、副菜、副菜、汁物という要素から構成される。この各要素に対してシステムに登録されたレシピ番号を二進数表現したものを付与する。各構成要素は5ビットの二進数値で表現するため、個体は25ビット長のビット列となる。

また、この個体に対する評価関数として充足率を用いる。前節にて説明した規定量に対して食品群、食品成分ごとの充足率を求める。充足率 $p_c$ [%]は規定量 $a_T$ と規定量に対する過不足分 $a_e$ から式(1)で求める。ただし規定量として上限および下限が定められている場合には、摂取量が範囲内の場合に充足率を100%とし、範囲外の場合において式(1)により充足率を求める。

$$p_c = |a_T - a_e| / a_T \times 100 \quad (1)$$

さらに、式(1)で求められた充足率の平均と標準偏差を食品群別摂取量と食品成分別摂取量についてそれぞれ計算し、この平均と標準偏差の差を個体の適応度とする。ただし、献立のレシピにアレルギー成分が含まれている、選択レシピが反映されていない、あるいは、ごはん以外の主食および主菜が重複している場合には適応度を0に設定する。

GAにおける個体選択方法はエリート選択とルーレッ

Fig. 1: Implementation of the proposed scheme: entry of physical attributes and output of calculated nutritional intakes

Fig. 2: Implementation of the proposed scheme: list of menus for patient's recommendation

ト選択の組み合わせであり、最も適応度の高い個体を必ず次世代に残し、残りの個体は適応度に応じた確率により選択・淘汰される。また、個体間の交叉方法としては一様交叉を採用する。以下のシステム評価の実験においては、遺伝的アルゴリズムのパラメータとして、個体数60、交叉率0.9、突然変異率0.01とした。

#### 4 提案システムの評価

著者らは提案システムをMicrosoft Windows上のソフトウェアとして実装している。このソフトウェアの動作例をFig. 1, Fig. 2, およびFig. 3に示す。この例では、35歳男性、体重68.5kg、身長170.5cm、身体活動レベルII、食物アレルギーなしという身体特徴を持つ仮想患者に対する献立作成を想定している。この患者の場合、図1に示すように一日における食品群別摂取量は300g(第1群)、220g(第2群)、650g(第3群)、440g(第4群)と算出される。

Fig. 2にはシステムのデータベースに登録されているレシピの一覧と、これより選択された5種類のレシピを示している。データベースに登録しているレシピならびにレシピ名は文献<sup>6)</sup>にある病院食レシピを用いている。

提案システムにより探索された献立の例をFig. 3に示す。この図では、第1日目の昼食と夕食の献立の候

Table 2: An example of nutrient adequacies for the 1st day (male, 35 years, 68.5 kgs, 170.5 cm, Level II of physical activity)

(a) Lunch			(b) Dinner		
	intakes	target intakes		intakes	target intakes
Food group #1	87 g	100 g	Food group #1	100 g	103 g
Food group #2	60 g	73.3 g	Food group #2	55 g	71.5 g
Food group #3	255 g	216.7 g	Food group #3	189.5 g	174.5 g
Food group #4	135 g	146.7 g	Food group #4	157 g	153 g
Averaged adequate for IFGs		85.79	Averaged adequate for IFGs		90.72
Variance for IFGs		4.14	Variance for IFGs		8.29
Point for IFGs		81.65	Point for IFGs		82.43
Energy	750.3 kcal	891.1 kcal	Energy	731.6 kcal	1075.3 kcal
Protein	30 g	20 ~ 45.7 g	Protein	25.9 g	8.9 ~ 60.2 g
Calories	26 g	19.8 ~ 24.8 g	Calories	26.9 g	17.4 ~ 27.3 g
Carbohydrate	96.6 g	111.4 ~ 154.2 g	Carbohydrate	92.6 g	131.5 ~ 226.3 g
Salt	3 g	≤ 3 g	Salt	2.8 g	≤ 2.9 g
Averaged adequate for IFCs		93.19	Averaged adequate for IFCs		87.69
Variance for IFCs		6.62	Variance for IFCs		15.09
Point for IFCs		86.58	Point for IFCs		72.60
Fitness		84.94	Fitness		75.87



Fig. 3: Implementation of the proposed scheme: composed candidates of menus for the first day's lunch and dinner

補が示されており、献立の内容とともに各食品群の摂取量、充足率なども示されている。この第1日目の献立に関する食品摂取量、目標摂取量、およびそれらから算出される適応度を Table 2 に示す。また、5日分の昼食ならびに夕食に関して探索・提示した各献立についての適応度を Table 3 に示す。これらの結果より、提案システムは高い適応度を持つ献立の組み合わせを探索できておりことが分かる。

本提案システムの有効性を示すために、Table 4 に示す患者群についてそれぞれ献立作成を行う。この表に示すように、患者群は年齢、性別、身体特徴、アレルギーなどが互いに異なるように設定した。患者の身長および体重については、日本人の平均付近となるように設定している。各患者に対して、ランダムな嗜好に基づく献立選択および異なる初期個体群を用いた献立探索実験を行った。各日における昼食・夕食の献立に対する平均適応度を Table 5 に示す。この表より、多くの場合において高い適応度を持つ献立群が発見できていることが分かる。いくつかの場合において、特に

Table 3: Fitness values for five days' lunches and dinners for the virtual patient (male, 35 years, 68.5 kgs, 170.5 cm, Level II of physical activity)

Day	Adequacies for lunch [%]	Adequacies for dinner [%]
1	84.94	75.87
2	81.36	74.59
3	76.65	74.53
4	83.69	72.20
5	78.84	67.34
Average	80.50	72.91

患者 Id:W60 に対しては低い適応度の献立しか得られていない。これはデータベースに登録されているレシピ数が少ない(72種類)ことが原因であると考えられ、この問題はレシピのデータベースの拡充により改善可能である。

## 5 まとめ

本研究では、患者の摂取バランスならびに嗜好を考慮した献立作成支援システムについてその有効性の検証を行った。提案システムでは患者の身体情報から摂取目標量を設定することにより患者各個人に応じた献立の作成を行うことができる。様々な仮想患者に対する実行結果より昼食、夕食ともに献立の平均適応度が高い献立を探索できていることがわかり、これにより本システムの有効性を確認できた。

## 参考文献

- 1) 苅米, 藤井, “栄養素等摂取バランスの分析に基づく食生活支援システム,” 日本データベース学会論文誌, 8-4, 1/6 (2010)
- 2) 加島, 石井, “食材分類による献立作成の提案,” 数理解析研究所講究録, 1629, 1/7, (2009)
- 3) 徳美, 袴田, 徳丸, “嗜好と健康を考慮した献立を提供す

Table 4: Several virtual patients with their physical attributes, used for the targets of menu creation

Id.	gender	ages	height [cm]	weight [kg]	Activity level	Allergies
M20	male	18-29	171.4	63.0	3	N/A
M40	male	30-49	170.5	68.5	2	N/A
M60	male	50-69	165.7	65.0	1	N/A
W20	female	18-29	158.0	50.6	3	N/A
W40	female	30-49	158.0	53.0	2	N/A
W60	female	50-69	153.0	53.6	1	N/A
MAc	male	30-49	170.5	68.5	2	Cereal
MAM	male	30-49	170.5	68.5	2	Milk

Table 5: Fitness values for virtual patients (averaged for 10 trials)

Day	M20		M40		M60		W20	
	Lunch	Dinner	Lunch	Dinner	Lunch	Dinner	Lunch	Dinner
1	76.26	66.40	78.82	76.92	85.99	82.72	88.56	83.11
2	76.32	67.13	84.32	75.66	84.00	83.51	82.69	83.24
3	75.44	65.40	80.30	76.95	85.46	80.64	75.30	80.52
4	75.69	65.11	79.87	73.28	82.13	80.18	79.89	79.74
5	75.77	65.70	79.10	72.51	84.04	81.26	86.09	82.41
Average	75.89	65.95	80.48	75.07	84.33	81.66	82.51	81.80

Day	W40		W60		MAc		MAM	
	Lunch	Dinner	Lunch	Dinner	Lunch	Dinner	Lunch	Dinner
1	80.37	80.54	76.37	59.95	74.51	74.14	75.21	74.84
2	85.39	80.29	82.18	63.61	81.88	72.90	74.50	70.86
3	84.58	80.09	64.43	62.39	78.79	71.36	80.85	72.22
4	83.66	80.31	75.82	60.22	73.61	72.33	69.28	67.38
5	82.80	79.53	81.61	68.48	78.45	66.59	80.27	68.57
Average	83.36	80.15	76.08	62.93	77.45	71.46	76.02	70.78

る食生活支援システム～栄養管理システムの最適化～”  
第 27 回ファジィ・システム・シンポジウム講演論文集,  
1135/1140 (2011)

- 4) 磯川, 井尾, 上浦, 小野, 松井, “患者の摂取制限に適応した  
病院給食の献立立案支援システムの構築,” 第 58 回システム  
制御情報学会研究発表講演会講演論文集, 135-7 (2014)
- 5) 厚生労働省: 日本人の食事摂取基準 (2010 年版), <http://www.mhlw.go.jp/shingi/2009/05/s0529-4.html>
- 6) 足立, “せんぼ東京高輪病院 500kcal 台のけんこう定食,”  
ワニブックス (2012)

# 滑りを考慮した二足歩行及び動的形状変更能力に基づく評価

○李 想 馮 陶然 今西 裕紀 見浪 護 松野 隆幸 矢納 陽 (岡山大学)

## Bipedal Walking in Consideration of Slip and The Evaluation Based on Dynamic Reconfiguration Ability

\*X.Li T.Feng H.Imanishi M.Minami T.Matsuno A.Yanou (Okayama University)

**Abstract**– Humanoid’s bipedal walking realized by controllers’ based on Zero Moment Point (ZMP) known as reliable control method deems to be different from human’s walking on the view point that ZMP-based walking does not include falling state. However, the walking control including falling state is vulnerable to turnover. Therefore, keeping the event-driven walking dynamical motion stable is important issue for realization of human-like walking. In this thesis, walking model of humanoid including slipping of supporting foot and contacting foot, bumping, surface-contacting and point-contacting of foot is discussed, and its dynamical equation is derived by Newton-Euler method. Then, we propose walking stabilizer named “Visual Lifting Stabilization” strategy to enhance standing robustness and prevent the robot from falling down. Besides, in order to investigate the flexibility of angular acceleration of each joint of robot, a new concept named Dynamic Reconfiguration Manipulability (DRM) which indicates dynamical shape-changeability by using redundancy is proposed as an index to optimize design and posture control of robots. And then, we apply the DRM into humanoid robot to research its dynamical reconfiguration ability during walking.

**Key Words:** Dynamic Reconfiguration Manipulability, Shape-changeability, Humanoid Robot

### 1 緒言

ヒューマノイドの歩行制御に関しては、Zero-Moment Point (ZMP) と呼ばれる床半力の圧力中心を参照することによって二足歩行を実現する方法<sup>1,2)</sup>が最も有力で現実的な手法であることが知られている。なぜならば、支持多角形の凸包内に ZMP を留めておくことによって、ロボットが転倒することなく安定な歩容が維持されるということが保証されているためである。本田技術研究所の ASIMO を始めとして、多くの実機によるヒューマノイドが ZMP に基づいて現実世界における二足歩行を達成している。ZMP 規範の制御以外にも、リミットサイクルに収束する歩行軌道や関節角度軌道を生成し、これらを参照して二足歩行を生成する手法も存在する<sup>3)</sup>。

しかしながら、上記のモデル化や制御器設計の手法は全て単純化された二足歩行モデルが対象であり、足 (foot) を含むモデルの作成や足の滑りなどが歩行に与える影響に関する議論は避けられる傾向にある。その一方で、文献<sup>4)</sup>は足 (foot) の存在によって多様な歩容が生成されることを明確に指摘し、様々な歩容を含む歩行モデルを作成している。本研究においても、可能な限り詳細に導出されたつま先、足 (foot)、腕、両足の滑り、足の衝突などを含むダイナミクスに基づいた議論を行う。本研究と文献<sup>4)</sup>の観点は共通しているが、本研究は脚だけではなく腰や腕なども含めた全身のモデルを扱う。そして、ヒューマノイドのモデル化において著者らが重要と考えている事は、歩容の変化に応じてダイナミクスに含まれる状態変数の次元が変化するという点である。一例を挙げると、面接地状態 (つま先と踵が接地) から踵が離地する場合にはその足の回転運動を表す変数が新たに必要となるため、状態変数の数が増加する。このような議論は文献<sup>5)</sup>において、“one-legged hopping robot”の運動を対象として行われているが、歩行運動に関しては言及されていない。さらに状態変数の次元が運動の結果に応じて変化する系に対して、制御器の設計や安定性の判別を議論している報告はない。




Fig. 1: Applications of dynamic reconfiguration manipulability for humanoid robot walking on uneven ground

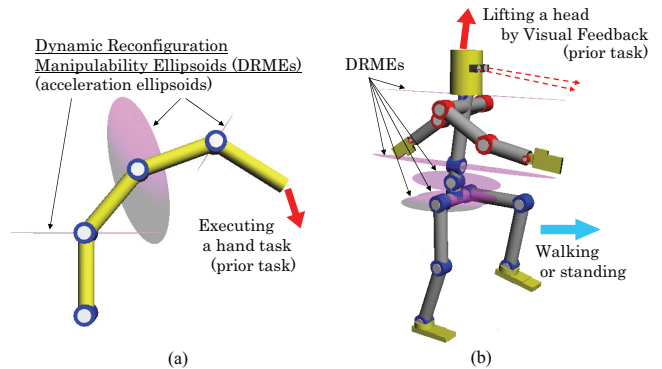


Fig. 2: Applications of dynamic reconfiguration manipulability for (a) redundant manipulator and (b) humanoid robot.

また、足が接地している状況は拘束運動として表現可能であり、文献<sup>6)</sup>は物体が環境と接触しながら運動を行っている状態を滑り摩擦を含めて代数方程式に基づいて表現し、ヒューマンフィギュアへの応用を提案している。これらの文献に基づいて、本論文では分岐を持つマニピュレータとして模擬されたヒューマノイドのダイナミクスを Newton-Euler 法を用いて導出する。マニピュレータに基づいたモデル化は文献<sup>7)</sup>でも行われているが、分岐のない脚のみのモデルが対象となっている。

そして、本文では ZMP に依存しない人間らしい自然




Fig. 3: Definition of humanoid's link, joint and angle number

な二足歩行の実現を考える。ZMPが支持多角形の境界上に存在している時、ヒューマノイドは転倒状態にあり、歩容は不安定となる可能性が高い。このような問題に対して、本研究では“Visual-lifting Stabilization”と名付けた姿勢安定化を行うための戦略をビジュアルサーボとインピーダンス制御<sup>8)</sup>の概念に基づいて提案する。この戦略は文献<sup>9,10)</sup>において提案されている“visual pose estimation”を利用しており、ヒューマノイドが目標物体を実時間で認識することによって取得可能な物体に対する自身の位置/姿勢の偏差をフィードバックすることにより、直立及び歩行状態における姿勢安定化を可能とする。

さらに、ロボットの各関節の角加速度の出しやすさを考察するため、本論文では運動学と動力学的な観点を含めた上での冗長性利用により実現可能な形状変更性を示した概念「動的形状変更可操作性 (Dynamic Reconfiguration Manipulability, DRM)」を提案し、Fig.1とFig.2に示すように冗長マニピュレータのみでなくヒューマノイドロボットの最適設計や姿勢最適化のために運動性能の一つの評価指標を与える。そして、DRMをヒューマノイドロボットに適用し、歩行時における各関節の動的形状変更能力について考察する。

## 2 ヒューマノイドの二足歩行モデル

ヒューマノイドのリンク、関節、関節角度  $q_i$  の定義を Fig.3 示す。物理的なパラメータ設定を Table.1 に示す。モデルは 19 本の剛体リンクと質量や長さを持たない 18 個の回転関節で構成されており、つま先を含む足 (foot)、胴体、腕などの全身モデルを 18 自由度で表現している。下半身は矢状面内の運動しか行わないが、上半身は joint-9, 10, 11 により 3 次元空間内の運動が可能である。

以降では、link-0, ..., 3 によって構成される脚を「支持脚」、link-5, ..., 8 によって構成される脚を状態に応じて「遊脚」または「接地脚」と呼ぶ。

## 3 Visual-lifting Approach

一般的に ZMP を参照しない連続歩行は不安定な歩容が現れるため、困難であるとされる。不安定な歩容とは転倒状態を意味し、一旦転倒状態が生じると安定な姿勢に復帰することは難しい。本章ではこのような問題

Table 1: Physical parameters

Link	$l_i$	$m_i$	$d_i$
Head	0.24	4.5	0.5
Upper body	0.41	21.5	10.0
Middle body	0.1	2.0	10.0
Lower body	0.1	2.0	10.0
Upper arm	0.31	2.3	0.03
Lower arm	0.24	1.4	1.0
Hand	0.18	0.4	2.0
Waist	0.27	2.0	10.0
Upper leg	0.38	7.3	10.0
Lower leg	0.40	3.4	10.0
Foot	0.07	1.1	10.0
Total	1.7	63.8	

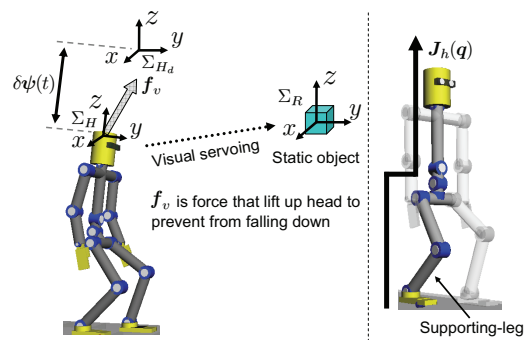


Fig. 4: Concept of Visual-lifting Approach

を避けるために、ヒューマノイドの直立時または歩行時の安定性向上を目的として“Visual-lifting Approach”と呼ぶ戦略を提案する。本戦略の概念は頭部の位置/姿勢を一定に保つことである。まず、その概略図を Fig. 4 に示す。

ヒューマノイドの頭部に固定された座標系  $\Sigma_H$  に基づいて、固定目標物体の位置/姿勢を測定するために Model-based matching 法を使用する。固定目標物体に対して設定された座標系  $\Sigma_R$  と  $\Sigma_H$  の関係は同次変換行列  ${}^H T_R$  として定義される。その結果、頭部の目標位置を表す座標系  $\Sigma_{H_d}$  と  $\Sigma_H$  の偏差を表す同次変換行列  ${}^H T_{H_d}$  は以下の式によって求まる。

$${}^H T_{H_d}(\psi_d(t), \psi(t)) = {}^H T_R(\psi(t)) \cdot {}^{H_d} T_R^{-1}(\psi_d(t)) \quad (1)$$

式 (1) において、 ${}^H T_R$  は文献<sup>9,10)</sup> で提案されている“On-line visual pose estimation”によって測定された  $\psi(t)$  を用いて計算可能であるが、本研究では  ${}^H T_R$  をビジュアルサーボによる認識によって得るのではなく、既知の変数として扱っている。そして、 $\delta\psi(t) = \psi_d(t) - \psi(t)$  として定義される頭部の目標値と実際の偏差を最小とするために、関連した関節に入力されるべきトルクが以下の式により計算される。

$$\tau_h(t) = J_H(q) K_p \delta\psi(t) \quad (2)$$

ここで、 $J_H(q)$  は支持脚から頭部までの位置/姿勢を表すヤコビ行列、 $K_p$  は比例ゲインを表している。す




Fig. 5: Gait's transition

なわち式 (2) は頭部を目標位置に引っ張る力  $f_v$  を生み出し、重力による頭部や重心位置の低下及び予測不可能な滑りや外乱による転倒を防止する効果を持つ。

式 (2) の制御器は本論文で述べる実験の全ての歩容において適用され、歩容の違いに対する Visual-lifting Approach の有効性は第 5 章において検証される。

#### 4 滑りを考慮した二足歩行

人間は歩いたり走ったりする時、両足が地面の摩擦状況により接地脚や支持脚を問わず滑りを生じるはずである。本研究で扱う二足歩行は、Newton-Euler 法を用いることで、衝突などの拘束だけではなく、両足の滑りも考慮することができる。本章ではヒューマノイドの歩行運動中に生じる足の滑りについて述べる。

##### 4.1 接地脚の滑り

ヒューマノイドは Fig. 5 に示す状態遷移を繰り返しながら歩行する。Fig. 5 の (II)、(IV)、(VI)、(VI') 及び (III)、(V)、(V') に示すように、歩行中に生じる接地脚の滑りはダイナミクスに依存している。また、接地脚の進行方向の力  $f_y$  が静摩擦力を上回った場合、すなわち  $|f_y| > |f_x|$  のとき条件  $C_{hy}$  を外して、接地脚は進行方向に滑りを生じる。




Fig. 6: One step of contacting foot ( $K = 0.7$ )

Fig. 6 は Fig. 5 の (II)、(IV)、(VI)、(VI') に示した接地脚の踵の位置変化について、比例ゲイン  $K_p = \text{diag}[20, 290, 1100]$ 、摩擦係数  $K = 0.7$  時の状態を表している。Fig. 6 より、接地脚が接地した後、前方に  $0.078[m]$  滑ってから止まるという運動が分る。この結果により、本研究で扱うモデルは接地脚の滑りを考慮していることが確認できた。

また、摩擦係数と滑り距離の関係を確認するため、摩擦係数を  $0.4$  から  $0.9$  まで  $0.1$  ずつ変化させ、滑り距離との関係について調べた。その結果を Fig. 7 に示す。この図から現実の運動と同じように、摩擦係数の増加

に従って、滑り距離が減少していることが分かる。よって、本研究で扱う接地脚滑りのモデルの妥当性を検証することができた。




Fig. 7: Average distance of slipping

##### 4.2 支持脚の滑り

支持脚滑りのモデルは接地脚滑りのモデルと異なり、根元 (支持脚の爪先) が固定されないという前提で考察する。支持脚の進行方向に対する変位  $y_0$  を追加すれば支持脚の滑りが表現される。ここで、 $y_0$  を追加した場合の支持脚が滑る状態での運動方程式の導出方法について述べる。座標系  $\Sigma_W$  における link-1 の根元の変位は  ${}^W p_1 = [0, y_0, 0]^T$  となり、順動力学計算において  $\Sigma_i$  の原点における加速度  ${}^1 \ddot{p}_1$  は以下の式で導出される。

$${}^1 \ddot{p}_1 = {}^W R_1^T \{ {}^W \ddot{p}_W + {}^W \ddot{p}_1 \} \quad (3)$$

また、逆動力学計算において、支持脚の並進方向の運動方程式は式 (4) のように計算される。

$${}^1 f_1 = {}^1 R_2^2 f_2 + m_1 {}^1 \ddot{s}_1 \quad (4)$$

支持脚の滑りを含む歩行の状態遷移は Fig. 8 に示す。ここで、 $f_t$  は支持脚の並進力、 $f_s$  は支持脚の最大静摩擦力、 $\dot{y}_0$  は支持脚の並進速度である。状態遷移の経路はヒューマノイドの歩行運動によって決定される。つまり、ダイナミクスの解に依存する。Fig. 9 は支持脚のつま先の位置と状態の時間変化を表す。支持脚の滑りを実現するには滑り条件により摩擦係数を非常に小さくしなければならないので、このシミュレーションでは  $K = 0.05$  とした。また、状態 0 は支持脚がつま先点接地、状態 1 は面接地を表す。Fig. 9 より、支持脚が  $0.8[s]$  から  $1.0[s]$  の間に点接地として後方に滑り、 $1.5[s]$  から  $1.75[s]$  の間に面接地として前方に滑ることが分かる。

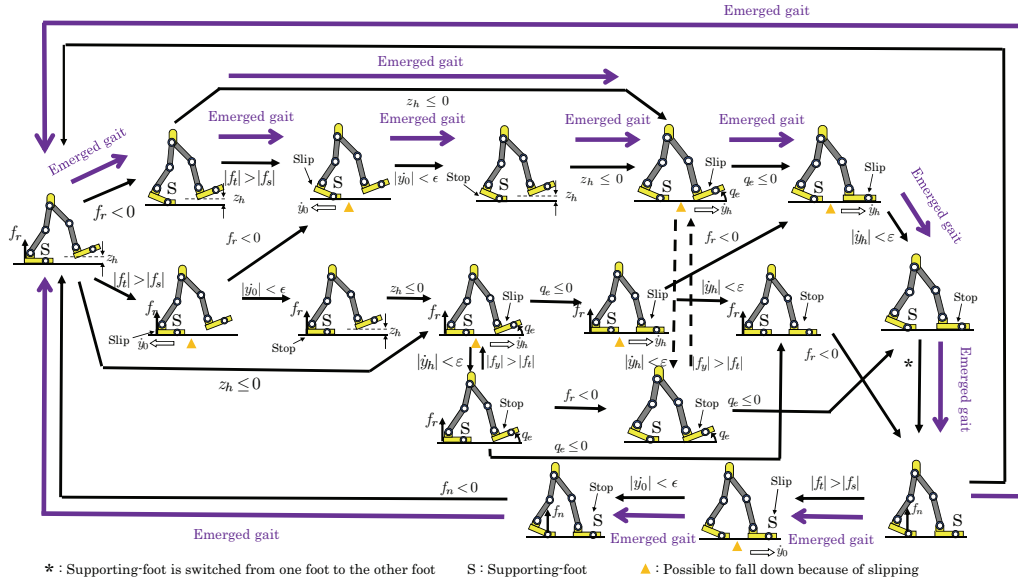


Fig. 8: States and gait transition including slip motion




Fig. 9: Distance and state of slipping

## 5 動的形状変更可操作性 (DRM)

本章ではマニピュレータの可操作性について議論する。リンク動的可操作性は動的可操作性をマニピュレータの各リンク先端に適用した概念であり、他にタスクが与えられていない状態のマニピュレータの動かしやすさを表す。動的形状変更可操作性は動的可操作性と形状変更可操作性をヒントにし本論文で提案される概念であり、手先タスクが与えられている状態でのマニピュレータの動かしやすさを表す。

### 5.1 リンク動的可操作性

リンク動的可操作性は、マニピュレータのハンドにタスクが与えられていない場合、あるリンクの先端がどの方向にどれだけ加速度を出せるのかを表す概念である。各リンクの動きやすさを関節トルクを用いて考える。マニピュレータの運動方程式は一般的に式(5)で表される。

$$M(q)\ddot{q} + h(q, \dot{q}) + g(q) + D\dot{q} = \tau \quad (5)$$

ここで、 $M(q) \in \mathbb{R}^{n \times n}$  は慣性行列、 $h(q, \dot{q}) \in \mathbb{R}^n$  は遠心力、コリオリ力を表す項、 $g(q) \in \mathbb{R}^n$  は重力を表す項、 $D = \text{diag}[d_1, d_2, \dots, d_n]$  は粘性抵抗行列であり、 $\tau \in \mathbb{R}^n$  はトルク、 $q \in \mathbb{R}^n$  は関節角度である。一方、第*i*リンク先端の位置  $r_i$  と関節角度  $q$  の関係は次式で表される。

$$r_i = f_i(q) \quad (i = 1, 2, \dots, n) \quad (6)$$

式(6)を時間  $t$  で微分すると、第*i*リンク先端の速度  $\dot{r}_i$  と角速度  $\dot{q}$  の関係が次式のように表される。

$$\dot{r}_i = J_i(q)\dot{q} \quad (7)$$

ここで、 $J_i(q) \in \mathbb{R}^{m \times n}$  は  $\dot{r}_i$  の  $q$  に関するヤコビ行列であり、0の成分を含んだ行列  $J_i = [\tilde{J}_i, \mathbf{0}]$  として表される。さらに式(7)を時間  $t$  で微分することで、

$$\ddot{r}_i = J_i(q)\ddot{q} + \dot{J}_i(q)\dot{q} \quad (8)$$

が得られる。 $\dot{J}_i(q)\dot{q}$  は  $q$  と  $r_i$  を表す2つの座標系空間の関係が非線形であることに起因する加速度と解釈できる(遠心加速度を発生させる成分  $\dot{q}_i^2$  やコリオリ加速度を発生させる成分  $\dot{q}_{i-1}\dot{q}_i$  などが含まれる項が見られる)。ここで、式(5)、(8)より  $\ddot{q}$  を消去すると、

$$\ddot{r}_i - \dot{J}_i\dot{q} = J_i M^{-1}[\tau - h(q, \dot{q}) - g(q) - D\dot{q}] \quad (9)$$

が得られる。さらに、

$$\tilde{\tau} \triangleq \tau - h(q, \dot{q}) - g(q) - D\dot{q} \quad (10)$$

$$\ddot{\tilde{r}}_i \triangleq \ddot{r}_i - \dot{J}_i\dot{q} \quad (11)$$

によって新たな変数  $\tilde{\tau}$  と  $\ddot{\tilde{r}}_i$  を導入すると式(9)は次式のように表せる。

$$\ddot{\tilde{r}}_i = J_i M^{-1} \tilde{\tau} \quad (12)$$

リンク動的可操作性は式(12)を基礎式として、ダイナミクスのある制約下での関節トルク  $\tilde{\tau}$  によって各リンク先端加速度  $\ddot{\tilde{r}}_i$  の出しやすさの度合いを定量化し指標とする、という考え方である。ここで  $\tilde{\tau}$  の一般解を求めると、

$$\tilde{\tau} = (J_i M^{-1})^+ \ddot{\tilde{r}}_i + [I_n - (J_i M^{-1})^+ (J_i M^{-1})] k \quad (13)$$

ただし、 $(J_i M^{-1})^+$  は  $(J_i M^{-1})$  の擬逆行列、 $I_n \in \mathbb{R}^{n \times n}$  は単位行列、 $k \in \mathbb{R}^n$  は任意ベクトルである。ここで、 $\|\tilde{\tau}\|$  が  $\|\tilde{\tau}\| \leq 1$  を満足するような関節トルク  $\tilde{\tau}$  を用いて実現し得る各リンクの先端加速度  $\ddot{\tilde{r}}_i$  の全てからなる集合を考えると、以下の式(14)で表され、 $J_i(q)$  の値域空間の次元を持つユークリッド空間内の楕円体 (Fig.10) となる。

$$\ddot{\tilde{r}}_i^T [J_i (M^T M)^{-1} J_i^T]^+ \ddot{\tilde{r}}_i \leq 1, \text{ and } \ddot{\tilde{r}}_i \in R(J_i M^{-1}) \quad (14)$$






Fig. 10: (a) Dynamic manipulability ellipsoids (DMEs) represent the realizable accelerations  $\ddot{\mathbf{r}}_i$  for each link without prior task at hand, and (b) dynamic reconfiguration manipulability ellipsoids (DRMEs) represent the realizable accelerations  $\Delta^1 \ddot{\mathbf{r}}_j$  for intermediate links with a hand task being executed as a primary acceleration task.

## 5.2 動的形状変更可操作性 (DRM)

マニピュレータのハンドにタスクが与えられた場合 ( $i = n$ ) の形状変更能力の良し悪しを考える.  $\ddot{\mathbf{r}}_n$  と  $\dot{\boldsymbol{\tau}}$  の関係は式 (12) より次式の様に表される.

$$\ddot{\mathbf{r}}_n = \mathbf{J}_n \mathbf{M}^{-1} \dot{\boldsymbol{\tau}} \quad (15)$$

ハンド目標加速度  $\ddot{\mathbf{r}}_{nd}$  が優先タスクとして与えられる場合,  $\ddot{\mathbf{r}}_{nd}$  を実現するための  $\dot{\boldsymbol{\tau}}$  は, 上式の一般解を求めることによって得られる.

$$\dot{\boldsymbol{\tau}} = (\mathbf{J}_n \mathbf{M}^{-1})^+ \ddot{\mathbf{r}}_{nd} + [\mathbf{I}_n - (\mathbf{J}_n \mathbf{M}^{-1})^+ (\mathbf{J}_n \mathbf{M}^{-1})] \mathbf{l} \quad (16)$$

$\mathbf{l} \in \mathbb{R}^n$  は任意ベクトルであり,  $[\mathbf{I}_n - (\mathbf{J}_n \mathbf{M}^{-1})^+ (\mathbf{J}_n \mathbf{M}^{-1})]$  の単位は無次元であることから  $\mathbf{l}$  の単位は関節トルクと一致する. 式 (16) の右辺第一項は  $\ddot{\mathbf{r}}_{nd}$  を実現する  $\dot{\boldsymbol{\tau}}$  の中で  $\|\dot{\boldsymbol{\tau}}\|$  を最小にする解を与える. また第二項は, 第一項による  $\ddot{\mathbf{r}}_{nd}$  の実現には無関係にマニピュレータの形状を変更する関節トルクを  $\mathbf{l}$  によって与えることを表す. 以下では形状変更のための第  $j$  リンク ( $1 \leq j \leq n-1$ ), すなわち中間リンクの動的形状変更可操作性について考える. ハンド目標タスクの次に優先するタスクを第一動的形状変更タスクと呼び, その優先順位を左肩添え字の“1”で表す. 冗長自由度が多い場合には, 第二, 第三の複数の動的形状変更タスクを実行できる可能性がある. ここで, ハンド目標加速度  $\ddot{\mathbf{r}}_{nd}$  を実現している際の第  $j$  リンク加速度  ${}^1 \ddot{\mathbf{r}}_j$  との関係は, 式 (12) と式 (16) より  $\dot{\boldsymbol{\tau}}$  を消去することによって次式のように表される.

$${}^1 \ddot{\mathbf{r}}_j = \mathbf{J}_j \mathbf{M}^{-1} (\mathbf{J}_n \mathbf{M}^{-1})^+ \ddot{\mathbf{r}}_{nd} + \mathbf{J}_j \mathbf{M}^{-1} [\mathbf{I}_n - (\mathbf{J}_n \mathbf{M}^{-1})^+ (\mathbf{J}_n \mathbf{M}^{-1})] \mathbf{l} \quad (17)$$

さらに式 (11) の関係により式 (17) は次式のように書き直すことができる.

$${}^1 \ddot{\mathbf{r}}_j - \dot{\mathbf{J}}_j \dot{\mathbf{q}} - \mathbf{J}_j \mathbf{M}^{-1} (\mathbf{J}_n \mathbf{M}^{-1})^+ (\ddot{\mathbf{r}}_{nd} - \dot{\mathbf{J}}_n \dot{\mathbf{q}}) = \mathbf{J}_j \mathbf{M}^{-1} [\mathbf{I}_n - (\mathbf{J}_n \mathbf{M}^{-1})^+ (\mathbf{J}_n \mathbf{M}^{-1})] \mathbf{l} \quad (18)$$

ここで,

$${}^1 \ddot{\mathbf{r}}_j \triangleq \dot{\mathbf{J}}_j \dot{\mathbf{q}} + \mathbf{J}_j \mathbf{M}^{-1} (\mathbf{J}_n \mathbf{M}^{-1})^+ (\ddot{\mathbf{r}}_{nd} - \dot{\mathbf{J}}_n \dot{\mathbf{q}}) \quad (19)$$

$$\Delta^1 \ddot{\mathbf{r}}_j \triangleq {}^1 \ddot{\mathbf{r}}_j - {}^1 \ddot{\mathbf{r}}_j \quad (20)$$

$${}^1 \boldsymbol{\Lambda}_j \triangleq \mathbf{J}_j \mathbf{M}^{-1} [\mathbf{I}_n - (\mathbf{J}_n \mathbf{M}^{-1})^+ (\mathbf{J}_n \mathbf{M}^{-1})] \quad (21)$$

によって新たな変数を定義することで, 式 (18) は次式のように表せる.

$$\Delta^1 \ddot{\mathbf{r}}_j = {}^1 \boldsymbol{\Lambda}_j \mathbf{l} \quad (22)$$




Fig. 11: Reconfiguration relation of  $j$ -th intermediate link during hand executing task  $\ddot{\mathbf{r}}_{nd}$ .  ${}^1 \ddot{\mathbf{r}}_j$  means influence of hand task to  $j$ -th link as shown in Eq.(19).  $\mathbf{J}_j \mathbf{M}^{-1} (\mathbf{J}_n \mathbf{M}^{-1})^+ \ddot{\mathbf{r}}_{nd}$  is a induced acceleration of  $j$ -th link by  $\ddot{\mathbf{r}}_{nd}$ . If  ${}^1 \ddot{\mathbf{r}}_j$  is required to be generated at  $j$ -th link,  $\Delta^1 \ddot{\mathbf{r}}_j$  determined by Eq.(20) have to be realized through  $\mathbf{l}$  in Eq.(22).

式 (8), (11), (19) および (20) の関係を Fig.11 に示す. 式 (19) 中の  ${}^1 \ddot{\mathbf{r}}_j$  はマニピュレータのハンドの加速度タスクが原因となり発生する第  $j$  リンクの加速度成分を表しており, 右辺第 1 項は第  $j$  リンクに発生する遠心・コリオリ加速度であり, 右辺第 2 項は手先目標タスク達成に伴い第  $j$  リンクに発生する加速度である. 式 (20) より  ${}^1 \ddot{\mathbf{r}}_j$  に対して加速度  ${}^1 \ddot{\mathbf{r}}_j$  を実現するには,  $\Delta^1 \ddot{\mathbf{r}}_j$  を入力トルクの一部である  $\mathbf{l}$  によって発生させる必要があることがわかる. ここで, 動的形状変更可操作性 (Dynamic Reconfiguration Manipulability, DRM) は, 式 (22) を基礎式として, 目標手先加速度  $\ddot{\mathbf{r}}_{nd}$  に影響を与えない関節トルク  $\mathbf{l}$  によって発生できる中間リンク加速度  $\Delta^1 \ddot{\mathbf{r}}_j$  の出しやすさの度合いを定量化した指標である.  $\Delta^1 \ddot{\mathbf{r}}_j$  を通して  $\forall {}^1 \ddot{\mathbf{r}}_j \in \mathbb{R}^m$  を実現できるかどうかは,  ${}^1 \boldsymbol{\Lambda}_j$  に依存しており,  ${}^1 \boldsymbol{\Lambda}_j$  により  $\forall \Delta^1 \ddot{\mathbf{r}}_j$  の実現の可能性を判定できる. 式 (22) より  $\Delta^1 \ddot{\mathbf{r}}_j$  を実現する一般解  $\mathbf{l}$  を求めると次式となる.

$$\mathbf{l} = {}^1 \boldsymbol{\Lambda}_j^+ \Delta^1 \ddot{\mathbf{r}}_j + (\mathbf{I}_n - {}^1 \boldsymbol{\Lambda}_j^+ {}^1 \boldsymbol{\Lambda}_j) \mathbf{l} \quad (23)$$

式 (23) で,  $\mathbf{l} \in \mathbb{R}^n$  はトルクの次元を持つ新たな任意ベクトルである.  $\mathbf{I}_n - {}^1 \boldsymbol{\Lambda}_j^+ {}^1 \boldsymbol{\Lambda}_j$  にランクが残っている場合には第  $j$  リンク以外の中間リンクの加速度を指定できる余裕がある.  $\mathbf{l}$  が,  $\|\mathbf{l}\| \leq 1$  を満たすように制約を受ける場合には, 式 (23) より次式が得られる.

$$(\Delta^1 \ddot{\mathbf{r}}_j)^T ({}^1 \boldsymbol{\Lambda}_j^+ {}^1 \boldsymbol{\Lambda}_j)^T + \Delta^1 \ddot{\mathbf{r}}_j \leq 1 \quad (24)$$

$\boldsymbol{\Lambda}_j$  が行フルランクの場合, つまり  $\text{rank}({}^1 \boldsymbol{\Lambda}_j) = m$  が成立する場合には, 式 (24) は  $m$  次元空間に広がる楕円体となる.  $\text{rank}({}^1 \boldsymbol{\Lambda}_j) < m$  の場合には式 (24) が縮退した楕円体となることは明らかであり, これらの楕円体は, Fig.10(b) に示されている.

次に, DRM の概念に基づきマニピュレータ形状を比較するための指標について考える. 行列  ${}^1 \boldsymbol{\Lambda}_j$  は特異値分解により,

$${}^1 \boldsymbol{\Lambda}_j = {}^1 \mathbf{U}_j {}^1 \boldsymbol{\Sigma}_j {}^1 \mathbf{V}_j^T \quad (25)$$

$${}^1 \boldsymbol{\Sigma}_j = \begin{matrix} & r & & n-r \\ r & \begin{bmatrix} {}^1 \sigma_{j,1} & & 0 \\ & \ddots & \\ 0 & & {}^1 \sigma_{j,r} \end{bmatrix} & & 0 \\ m-r & \begin{bmatrix} & & 0 & 0 \end{bmatrix} \end{matrix} \quad (26)$$

ただし,  ${}^1 \mathbf{U} \in \mathbb{R}^{m \times m}$ ,  ${}^1 \mathbf{V} \in \mathbb{R}^{n \times n}$  は直交行列であり,  $\text{rank}({}^1 \boldsymbol{\Lambda}_j) = r \leq m$ , かつ  ${}^1 \sigma_{j,1} \geq \dots \geq {}^1 \sigma_{j,r} > 0$  であ

る. 第  $j$  リンクの楕円体の体積に比例する動的形状変更能力は次の式で表される.

$${}^1w_j = {}^1\sigma_{j,1} \cdot {}^1\sigma_{j,2} \cdots {}^1\sigma_{j,r} \quad (27)$$

本論文では,  ${}^1w_j$  を正規化された関節トルクによって第  $j$  リンク先端に作業空間の任意な方向へ加速度を発生できる度合として定義し, 第一動的形状変更可操作度 (Dynamic Reconfiguration Manipulability Measure, 以下 DRMM) と呼ぶことにする. ここで注意しておきたい点は, DRME, DRMM とも  ${}^1\mathbf{A}_j$  のみに依存して定まり,  ${}^1\mathbf{A}_j$  は式 (21) に示すように  $\mathbf{J}_i(\mathbf{q})$ ,  $\mathbf{J}_n(\mathbf{q})$  と  $\mathbf{M}(\mathbf{q})$  の関数, すなわち  $\mathbf{q}$  の関数である. したがって DRME, DRMM ともロボットの形状に直接依存して定まることがわかる.

### 5.3 ヒューマノイドの二足歩行に対する DRM に基づく評価

本節ではまず 3 種類の比例ゲインによる歩行の違いを動的形状変更可操作性を適用して考察する. 与えるゲインは安定な歩行を実現できる範囲内で, 高ゲイン ( $\mathbf{K}_p = \text{diag}[20, 290, 1100]$ ), 中ゲイン ( $\mathbf{K}_p = \text{diag}[20, 290, 950]$ ), 低ゲイン ( $\mathbf{K}_p = \text{diag}[20, 290, 900]$ ) とする. ヒューマノイドは Fig. 12(a), (b), (c) のようにそれぞれ歩行した. 楕円体は見やすさのためにスケールしている. Fig. 12 において, (a), (b) (c) の左から 4 番目のヒューマノイドロボットの状態では支持脚が面接地しているため膝関節に DRM 楕円体が見られない (厳密には線分は存在している). つまり, 変数の次元は  $\mathbf{q} = [q_2, q_3, \dots, q_{18}]^T$  となっている. それ以外では, 点接地であり  $\mathbf{q} = [q_1, q_2, \dots, q_{18}]^T$  となっているため膝関節にも楕円体が見られる (厳密には楕円である). また, Fig. 12(c) の形状は (a) と比べ腰を落とした形状であるので, DRM 楕円体の体積は (c) の方が大きい. Fig. 13 から, 比例ゲインが大きいほど楕円体の体積の総和を表した動的形状変更可操作値 (DRMSI) が小さくなっていることが確認できる. これは, (c) の形状変更能力が (a) の形状より大きいことを意味しているが, (c) の歩行は人間らしい歩行とは言い難い.

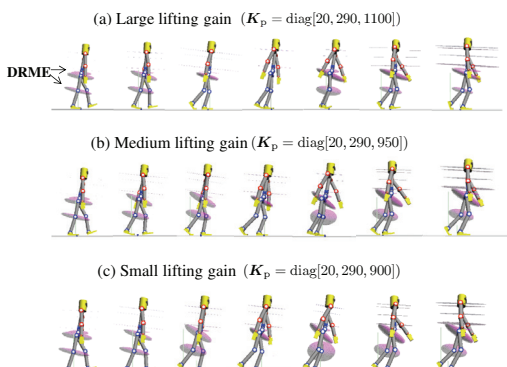


Fig. 12: Screenshot of humanoid walking on uneven ground

さらに, 不整地上を歩くヒューマノイドの動的形状変更能力を考察するため, Fig. 14 に示すような軌道を設計した.




Fig. 13: DRMSI until t=15.0[s]




Fig. 14: The uneven ground

また, 軌道の段差の大きさの変化により動的形状変更能力が変わると考えたため, 段差  $\delta h$  を  $0.01[m], 0.02[m], 0.03[m]$  のように設定した. 安定な歩行を実現できる範囲内のゲイン  $\mathbf{K}_p = \text{diag}[20, 290, 950]$  (腰を落とした歩行) と  $\mathbf{K}_p = \text{diag}[20, 290, 1100]$  (腰を伸ばした歩行) を対象とし, 段差の違いによる各ゲインでの歩行の動的形状変更能力を考察する. DRMSI の時間変化を Fig. 15 から Fig. 26 に示す. 各図の丸印は足が一つ目の階段を下る時の DRMSI を意味している.




Fig. 15: Case: Low lifting-gain ( $\mathbf{K}_p = \text{diag}[20, 290, 950]$ ),  $\delta h = 0.01[m]$




Fig. 16: Case: Low lifting-gain ( $\mathbf{K}_p = \text{diag}[20, 290, 950]$ ),  $\delta h = 0.02[m]$




Fig. 17: Case: Low lifting-gain ( $\mathbf{K}_p = \text{diag}[20, 290, 950]$ ),  $\delta h = 0.03[m]$




Fig. 18: Case: Low lifting-gain ( $K_p = \text{diag}[20, 290, 950]$ ),  $\delta h = 0.04[m]$




Fig. 23: Case: High lifting-gain ( $K_p = \text{diag}[20, 290, 1100]$ ),  $\delta h = 0.01[m]$




Fig. 19: Case: Low lifting-gain ( $K_p = \text{diag}[20, 290, 950]$ ),  $\delta h = 0.05[m]$




Fig. 24: Case: High lifting-gain ( $K_p = \text{diag}[20, 290, 1100]$ ),  $\delta h = 0.02[m]$




Fig. 20: Case: Low lifting-gain ( $K_p = \text{diag}[20, 290, 950]$ ),  $\delta h = 0.06[m]$




Fig. 25: Case: High lifting-gain ( $K_p = \text{diag}[20, 290, 1100]$ ),  $\delta h = 0.03[m]$




Fig. 21: Screenshot of humanoid walking on uneven ground with Low lifting-gain ( $K_p = \text{diag}[20, 290, 950]$ ),  $\delta h = 0.01[m]$




Fig. 26: Case: High lifting-gain ( $K_p = \text{diag}[20, 290, 1100]$ ),  $\delta h = 0.04[m]$




Fig. 22: Screenshot of humanoid walking on uneven ground with Low lifting-gain ( $K_p = \text{diag}[20, 290, 950]$ ),  $\delta h = 0.06[m]$




Fig. 27: Screenshot of humanoid walking on uneven ground with High lifting-gain ( $K_p = \text{diag}[20, 290, 1100]$ ),  $\delta h = 0.01[m]$




Fig. 28: Screenshot of humanoid walking on uneven ground with High lifting-gain ( $K_p = \text{diag}[20, 290, 1100]$ ),  $\delta h = 0.04[m]$

Fig. 15 から Fig. 20 より、腰を落とした歩行の場合は、段差の大きさの増加によって足が一つの階段を下る時の DRMSI が低くなる事が分かる、歩行の様子は Fig. 21 に示す。なお、 $\delta h$  は 0.06[m] になるとヒューマノイドロボットは転倒する、転倒の様子は Fig. 22 に示す。Fig. 23 から Fig. 26 より、腰を伸ばした歩行の場合の DRMSI は腰を落とした歩行の場合より全体的に低い事が分かる、この時の歩行の様子を Fig. 27 に示す。また、 $\delta h$  は 0.04[m] になると転倒し、その様子を Fig. 28 に示す。これらことから、段差が大きくなると、ヒューマノイドロボットが段差を上がったり下ったりするときの形状変更能力が低くなり、また腰を伸ばした歩行より、腰を落とした歩行のほうが不整地の状況に対する形状変更能力が高くなる事が言える。

## 6 結言

本論文では、可能な限り詳細にモデル化された複雑なダイナミクスを持つヒューマノイドロボットについて議論し、人間らしい自然な歩行を実現させるという目的に基づいて、以下の内容について記述した。

まず、支持脚及び接地脚の面接地/点接地に応じて 17 種類の歩容を考え、それぞれの歩容に対して拘束運動や変数の次元の変化を利用して接地脚の滑りや衝突だけではなく支持脚の滑りも含めたモデル化を行った。そして、ロボットの運動性能の評価指標の一つである動的形状変更能力を表す概念「動的形状変更可操作性 (DRM)」を提案した。DRM は先端リンク (手先や頭部) に与えられたタスクの実現に影響しない中間リンクの加速度の出しやすさを関節トルクとの関係で表した概念である。また、DRM をヒューマノイドロボットに適用することで、その妥当性・有効性をシミュレーションにより確認した。

## 参考文献

- 1) M. Vukobratovic, A. Frank and D. Juricic : On the Stability of Biped Locomotion, *IEEE Transactions on Biomedical Engineering*, Vol.17, No.1, (1970)
- 2) M. Vukobratovic and J. Stepanenko : On the Stability of Anthropomorphic Systems, *Mathematical Biosciences*, Vol.15, pp.1/37, (1972)
- 3) Y. Harada, J. Takahashi, D. Nenchev and D. Sato : Limit Cycle Based Walk of a Powered 7DOF 3D Biped with Flat Feet, *Proc. of International Conference on IROS*, pp.3623/3628, (2010)
- 4) Y. Huang, B. Chen, Q. Wang, K. Wei and L. Wang : Energetic efficiency and stability of dynamic bipedal walking gaits with different step lengths, *Proc. IEEE/RSJ International Conference on Intelligent Robots and Systems*, pp.4077/4082, (2010)
- 5) T. Wu, T. Yeh and B. Hsu : Trajectory Planning of a One-Legged Robot Performing Stable Hop, *Proc. IEEE/RSJ International Conference on Intelligent Robots and Systems*, pp.4922/4927, (2010)
- 6) 中村 仁彦, 山根 克 : 拘束条件が不連続に変化するリンク系の動力学—環境と接触しながら運動するヒューマンフィギュアへの応用—, *日本ロボット学会誌*, Vol.18, No.3, pp.435/443, (2000)
- 7) Y. Fujimoto and A. Kawamura : Three Dimensional Digital Simulation and Autonomous Walking Control for Eight-Axis Biped Robot, *Proc. IEEE International Conference on Robotics and Automation*, pp.2877/2884, (1995)
- 8) N. Hogan : Impedance Control; An Approach to Manipulation, Parts I-III, *ASME Journal of Dynamics Systems, Measurement, and Control* Vol.107, No.1, pp.1/24, (1985)

- 9) W. Song, M. Minami, F. Yu, Y. Zhang and A. Yanou : 3-D Hand & Eye-Vergence Approaching Visual Servoing with Lyapunov-Stable Pose Tracking, *Proceedings of IEEE International Conference on Robotics and Automation*, pp.5210/5217, (2011)
- 10) F. Yu, W. Song and M. Minami : Visual Servoing with Quick Eye-Vergence to Enhance Trackability and Stability, *Proceedings of IEEE/RSJ International Conference on Intelligent Robots and Systems*, pp.6228/6233, (2010)

# Eye-Vergence に基づくビジュアルサーボシステム

○田 宏志 侯 森 見浪 護 于福佳 前田 耕市 矢納 陽 (岡山大学)

## Visual Servoing System based on Eye-Vergence

\*Tian Hongzhi, Hou Sen, Minami Mamoru, Yu Fujia, Maeda, Koichi and Yanou Akira (Okayama University)

**Abstract**— Towards moving target visual servoing with hand-eye cameras fixed at the hand is inevitably affected by hand dynamical oscillations, therefore it's difficult to make target's position always at the center of camera's view, because nonlinear dynamical effects of whole manipulator stand against tracking ability. One proposal to solve the problem is that the visual servoing controllers of the hand and eye-vergence are separated independently by decoupling each other, so that the camera can rotate to observe the target object better. The track ability of the eye-vergence motion is superior to the one of hand since the eyes' motion can be quicker than the hand's motion because of the eyes' light mass. In this report the merit of eye-vergence visual servoing for tracking have been confirmed on condition of full six degree-of-freedom(DOF) pose being estimated in real time.

**Key Words:** Visual Servoing, Eye-vergence, 1-step genetic algorithm(GA), Object tracking

### 1 緒言

ロボットビジョンの分野では、最近ビジュアルサーボと呼ばれる制御方法が注目されている<sup>1, 2, 3, 4</sup>。ビジュアルサーボとは、視覚センサから得られる視覚情報をフィードバックループに組み込むことでロボットの動作を制御する方法であり、常に変化する環境や未知の環境で働くロボットへの適応が期待されている。具体的な手法は:位置ベース制御<sup>5</sup>、イメージベース制御<sup>6, 7</sup>とハイブリッド視覚サーボイング<sup>8, 9</sup>の3つに大別される。本報告では位置ベース制御をビジュアルサーボの手法として利用する。ビジュアルサーボの認識能力を向上させるために、ステレオカメラを使用する方法<sup>13</sup>と複数のカメラを使用する方法<sup>14</sup>、または二台のカメラのうち、一台のカメラを手先に固定し、もう一台を動かす方法<sup>15</sup>が提案されている。しかし、これらの方法はカメラの数を増やすことで視角も増加するが、変化する環境に適応することが難しい。Fig.1に示すように、人が動く目標を追従し続ける場合、対象物の移動速度が遅い時は、目標を追従できるが、移動速度が速くて人の顔を目標に向けることができない場合は、目だけで目標を注視することができる。これは目の質量と慣性モーメントが小さいからである。そこでこの特徴で利用した、Eye-Vergence システムを提案した<sup>16</sup>。

Eye-Vergence システムは運動学と動力学についての利点がある。まず、運動学についての利点を説明する。カメラがハンドに固定されている固定ハンドアイシステムは、いくつかの欠点を持つ。例えば、対象物がカメラに近いとき対象物を認識できないこと (Fig.2 (a)),




Fig. 1: People watching a moving object




Fig. 2: Disadvantage of Fixed Camera System




Fig. 3: Advantage of Eye-vergence System

また二つのカメラの可視領域が狭いこと (Fig.2 (b)), さらに可視領域内の対象物であっても Fig.2(c)に示すようにカメラ画像視野の中心に写像されることはない。このことは、レンズ周辺部で大きくなるレンズのひずみの影響を受けやすいという問題を生む。以上より固定ハンドアイシステムは位置/姿勢計測が不正確になる場合や、不可能になる場合があるという本質的な問題を持っていることがわかる。ここで上述の問題を解決するため、本論文では画像の中心で対象物を捉えるためにカメラ自身の姿勢を変化させる自由度を与える。カメラの姿勢を変えることが可能になるので、Fig.3の(a)-(c)に示すように、対象物をよりよく観測することができる。Fig.3の(a)-(c)はFig.2の問題点(a)-(c)に対応したEye-Vergenceシステムの利点を示している。(a), (b)は両眼可視領域が拡大すること、(c)はレンズの中心で対象物を観測することによってレンズ収差により発生する入力画像のひずみを避けられることを示している。最近の研究では、対象物を認識して一定の距離で追従する研究が多い<sup>17, 18</sup>。しかし、ビジュアルサーボの目的は手先を対象物に近づけて掴むなどの動作をすることである。この時、手先と対象物との関係は時変である。Fig. 3に示すようなEye-Vergence




Fig. 4: Dynamical Advantage of Eye-Vergence System  
システムでは、カメラがいつでも最適な角度で対象物を注視し続けることができる。

Eye-Vergence システムの動力的な利点はカメラが移動する対象物を注視できることである。ビジュアルサーボの応用では、安定な閉ループシステムで安定なサーボ動作を保つ必要がある。Fig.4(a) は、カメラが対象物を捉え続けることができる状態を示す。(b) に示すロボットのカメラはハンドに固定されており、対象物が速く動くと、追いつかれることができないとき対象物はカメラの視界から消失し、制御系は暴走するという危険な状態に陥る。よって、ビジュアルサーボシステムにおいては、カメラが動く対象物をカメラ視野内にとらえつづける能力である可追跡性を高めることが非常に重要である。また、カメラの質量と慣性モーメントがコンピュータ全体より小さいので、固定ハンドアイシステムより Eye-Vergence システムの方が対象物を追従しやすい。Fig. 4(c) に示すように、動物が対象物を追従するのと同じ原理で、カメラ視線制御をハンド制御に追加することで、対象物を追跡する能力を高める。

従来の研究<sup>16)</sup>では、対象物の位置/姿勢が既知の場合、位置/姿勢を時変にして、ハンドと対象物の関係から Eye-Vergence システムの効果を確認した。しかし、上に説明した運動学と動力学の利点を実験で確認していない。本論文では、提案した Eye-Vergence システムの利点を確認するために、対象物の追従実験を行った。また、実験の結果から Eye-vergence システムにおける運動学と動力学の利点を確認した。さらに周波数の変化を分析して、提案した Eye-Vergence システムが高い安定性と可追従性を持つことを示す。

## 2 ハンドアイビジュアルサーボ

### 2.1 目標軌道生成

Fig.5 にハンドと対象物の関係を示す。世界座標系を  $\Sigma_W$ 、対象物の座標系を  $\Sigma_M$  と記述する。さらに、実際のハンドの座標系とその目標座標系をそれぞれ  $\Sigma_E$ 、 $\Sigma_{Ed}$  で表すこととする。ハンドの目標状態と対象物との相対的な位置/姿勢関係は  ${}^{Ed}T_M$  によって表し、実際のハンドと対象物との関係は  ${}^E T_M$  によって表す。このとき、 $\Sigma_E$  と  $\Sigma_{Ed}$  との差は  ${}^E T_{Ed}$  として表され、 ${}^E T_{Ed}$  は以下のように記述できる。

$${}^E T_{Ed}(t) = {}^E T_M(t) {}^{Ed} T_M^{-1}(t) \quad (1)$$




Fig. 5: Motion of the end-effector and object  
式 (1) は任意の対象物の運動  ${}^W T_M(t) = ({}^W T_E(t) {}^E T_M(t))$  と任意の時変ビジュアルサーボの目標運動  ${}^{Ed} T_M(t)$  を含む。 ${}^E T_M(t)$  は 1-step GA<sup>13, 19)</sup> とオンラインモデルベース認識法を使って観測される。推定された対象物を  $\Sigma_{\hat{M}}$  で表すと、実際の物体  $\Sigma_M$  と検出された物体  $\Sigma_{\hat{M}}$  の間には、誤差が存在することが一般的である。ここでは、式 (1) で表されるハンドの位置/姿勢誤差  ${}^E T_{Ed}(t)$  を次のように推定した物体  $\Sigma_{\hat{M}}$  に基づいて再構成する。

$${}^E T_{Ed}(t) = {}^E T_{\hat{M}}(t) {}^{\hat{M}} T_{Ed}(t) \quad (2)$$

式 (2) を時間に関して微分すると以下の式を得る。

$${}^E \dot{T}_{Ed}(t) = {}^E \dot{T}_{\hat{M}}(t) {}^{\hat{M}} T_{Ed}(t) + {}^E T_{\hat{M}}(t) {}^{\hat{M}} \dot{T}_{Ed}(t). \quad (3)$$

時間に関してもう一回微分すると以下の式を得る。

$${}^E \ddot{T}_{Ed}(t) = {}^E \ddot{T}_{\hat{M}}(t) {}^{\hat{M}} T_{Ed}(t) + 2 {}^E \dot{T}_{\hat{M}}(t) {}^{\hat{M}} \dot{T}_{Ed}(t) + {}^E T_{\hat{M}}(t) {}^{\hat{M}} \ddot{T}_{Ed}(t), \quad (4)$$

ここで  ${}^{\hat{M}} T_{Ed}$ 、 ${}^{\hat{M}} \dot{T}_{Ed}$ 、 ${}^{\hat{M}} \ddot{T}_{Ed}$  はビジュアルサーボの目標軌道としてあらかじめ与えられ、 ${}^E T_{\hat{M}}$ 、 ${}^E \dot{T}_{\hat{M}}$ 、 ${}^E \ddot{T}_{\hat{M}}$  はカメラによって観測される。Fig.5 に示すように、ビジュアルサーボ過程において 0 にすべき二つの誤差が存在する。一つは実際の物体と検出された物体  ${}^M T_{\hat{M}}$  の誤差である。

もう一つはハンドの目標状態と実際のハンド  ${}^E T_{Ed}$  の誤差である。著者らの研究では、ある仮定のもとで  ${}^M T_{\hat{M}}$  の誤差は 1-step GA オンライン認識法<sup>19, 20)</sup>、MFF 補償法<sup>13)</sup> と Eye-Vergence システムによって 0 に収束することをリアプノフ法により確認し実験でも確認している<sup>21)</sup>。 ${}^E T_{Ed}$  の誤差はハンドビジュアルサーボコントロールによって減少することも実験により確認している。

### 2.2 1-step GA オンライン認識法

対象物の位置/姿勢をリアルタイムで認識するために、本研究では遺伝的アルゴリズム (GA) の一つの方法として 1-step GA 法<sup>19)</sup> を利用する。この方法は GA の進化を操作する時、毎回カメラから新しい画像を入力する。モデルと新しい入力画像の相関関数を適合度とし、最適解を GA で探索し、それをリアルタイムの認識結果として利用する。

しかし、モデルの探索範囲は 3 次元空間内で、位置と姿勢を合わせて 6 個のパラメータがあるため、探索



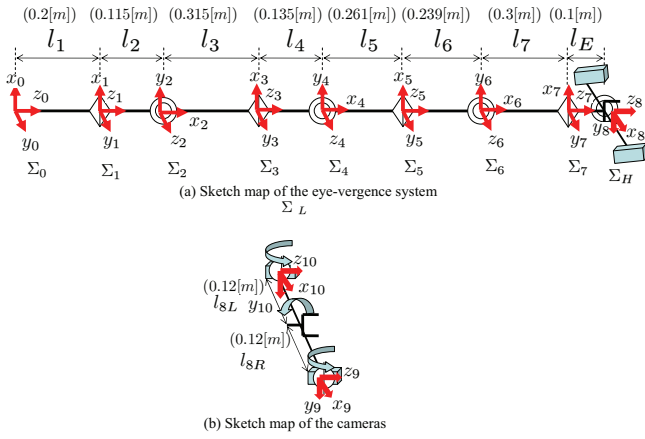


Fig. 9: Frame structure of manipulator




Fig. 10: 3D marker

と与えられる。ここでトル  $K_P$  はバネ定数,  $K_D$  は粘性抵抗を表す。

### 3 ハンドアイビジュアルサーボ実験

#### 3.1 実験環境

提案したビジュアルサーボシステムの有効性を実機によって確認するために、アーム型ロボット PA-10(三菱重工製)を利用する。PA-10の手先には SONY 製のステレオカメラ (ビデオレート 30[fps]) を二台取り付け、複眼で対象物を観測する。本研究は、カメラとして CCD-TRV86(撮像素子:1/6 インチ CCD, 焦点距離:  $f = 3.6[\text{mm}]$ , 視野角:  $\alpha = 38[\text{deg}]$ ) を使用する。画像認識および PA-10 の制御を行う PC には、DELLOptiplex(OS: windows2000. CPU: Pentium4, 2GHz) を使用しており、画像入力ボードは PCI5520 を用いている。マンピュレータとカメラの構造は Fig.9(a) と (b) に示す。

対象物は赤, 緑, 青のボールを組み合わせた 3D マーカーであり、ボールの直径は 40[mm], ボールの中心とマーカーの中心点の距離は 100[mm] であり、Fig.10 に示す。実験における対象物とマンピュレータの座標を Fig.11 に示す。白い矢印は対象物の移動方向を示す。

#### 3.2 実験条件

ハンドの初期姿勢を  $\Sigma_{E_0}$  とする。一方、物体の初期位置は  $\Sigma_{M_0}$  として定義する。 $\Sigma_W$  から  $\Sigma_{E_0}$  への同次変換行列,  $\Sigma_W$  から  $\Sigma_{M_0}$  への同次変換行列は以下のように与えられる。

$${}^W T_{E_0} = \begin{bmatrix} 0 & 0 & -1 & -690[\text{mm}] \\ 1 & 0 & 0 & -150[\text{mm}] \\ 0 & -1 & 0 & 485[\text{mm}] \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (16)$$

$${}^W T_{M_0} = \begin{bmatrix} 0 & 0 & -1 & -1235[\text{mm}] \\ 1 & 0 & 0 & -150[\text{mm}] \\ 0 & -1 & 0 & 585[\text{mm}] \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (17)$$




Fig. 11: Object and the visual-servoing system




Fig. 12: Cameras' and End Effector's gazing point

3D マーカーの運動は次式で与えるものとする。

$${}^W T_M = \begin{bmatrix} 0 & 0 & -1 & -1235[\text{mm}] \\ 1 & 0 & 0 & -150 \cos(\omega t)[\text{mm}] \\ 0 & -1 & 0 & 585[\text{mm}] \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (18)$$

対象物と手先の関係は

$${}^{E_d} \psi_M = [0, -100[\text{mm}], 545[\text{mm}], 0, 0, 0] \quad (19)$$

と与えている。

#### 3.3 Gazing point の定義

カメラの観測能力を調べるため、カメラの注視点を規定する。Fig.12 に示す左右カメラの視線方向が交わる点をカメラの注視点とし、これを Gazing point と呼ぶ。1-step GA による対象物の認識結果をもとに Gazing point を算出しているため、認識誤差が Gazing point に含まれる。Fig.13 のように左右カメラのパン角回りの回転を  $q_{9_d}, q_{10_d}$  とおく。ただし  $0 < q_{9_d} < \frac{\pi}{2}$ ,  $0 < q_{10_d} < \frac{\pi}{2}$  とする。

$$\frac{z}{x} = \tan\left(\frac{\pi}{2} - q_{10_d}\right) \quad (20)$$

$$\frac{z}{240 - x} = \tan\left(\frac{\pi}{2} - q_{9_d}\right) \quad (21)$$

となる。この 2 式を連立して、 $x, z$  を求める。これらの結果より左カメラ座標系から見た Gazing point  ${}^L P$  は、

$${}^L P = \begin{bmatrix} \frac{240 \tan(\frac{\pi}{2} - q_{9_d})}{\tan(\frac{\pi}{2} - q_{10_d}) + \tan(\frac{\pi}{2} - q_{9_d})} \\ 0 \\ \frac{240 \tan(\frac{\pi}{2} - q_{10_d}) \tan(\frac{\pi}{2} - q_{9_d})}{\tan(\frac{\pi}{2} - q_{10_d}) + \tan(\frac{\pi}{2} - q_{9_d})} \end{bmatrix} \quad (22)$$

となり、これに世界座標系から左カメラまでの同次変換行列をかけることにより世界座標系からみた Gaing point が求まる。






Fig. 13: Calculation cameras' gazing point





Fig. 14: Hand eye system and object position


### 3.4 実験結果

Fig. 14 は位置姿勢の 6 変数を認識させる条件の下、対象物の運動周期  $T = 20[s]$  の場合の追従結果のデータとして手先と対象物の位置関係を示している。白い矢印はカメラの視線を示す。(b)の時、手先はちょうど対象物の前にある。(a)と(c)の時、対象物の移動速度が速いため、手先は対象物を追従できていない。固定カメラシステムの場合、追従状態と手先の追従状態は同じであるため、図中の End effector が示す線はそれらの追従運動を表している。この時図より手先と対象物の  $x$  軸方向の距離がカメラの注視点と対象物の距離より明らかに遠いことが分かる。一方、Gazing Point(注視点)と対象物の距離から Eye-vergence システムは対象物を追従しやすいことがわかる。以上より、Eye-Vergence システムは固定カメラシステムより良い追跡性があることがわかる。


カメラから対象物位置/姿勢を認識した場合の実験結果を Fig.15 に示す。即ち、すべての位置姿勢の変数が正しく認識されたとして、 $\omega=0.314(0.1\pi)$ ,  $0.628(0.2\pi)$  と  $1.256(0.4\pi)$  の時の Eye-Vergence システムと固定システムカメラ注視点の結果を Fig.15(a), (b) 及び (c) に示す。各実験は 60[s] 行い、さらにゲイン曲線と位相曲線をトル (d) と (e) に示す。ここで、固定カメラシステムの場合、 $A = M_0 x_{M(t)}$  で、 $B = M_0 x_{E(t)}$  である。また、Eye-Vergence システムの場合、 $A = M_0 x_{M(t)}$ 、 $B = M_0 x_{\hat{M}}$  である。両図において、横軸は周波数  $f$  の対数目盛りとしている。(a)-(e) の図中 End effector と記した曲線は固定カメラシステムの手先追従能力を表し、Gazing point と指示している曲線は Eye-Vergence システムの追従能力を表している。Fig.15 (d) において、ハンドの振幅はカメラの注視点よりも小さい。 $f = 0.05[Hz]$  までは、ハンドとカメラの可追跡性はほぼ等しいだ。一方、Eye-Vergence システムにおいては、ゲインがほぼ  $0[dB]$  であることから  $f = 0.2[Hz]$  までの範囲ではカメラの




(a)  $\omega=0.314$




(b)  $\omega=0.628$



(c)  $\omega=1.256$




(d) amplitude-frequency




(e) angle-frequency


Fig. 15: True object's pose is directly given to the system, which can cancel the recognition error, so in this figure we can see only the dynamic error, and the camera can track the object much better than the end-effector.




(a)  $\omega=0.314$




(b)  $\omega=0.628$



(c)  $\omega=1.256$



(d) amplitude-frequency



(e) angle-frequency

Fig. 16: The object's pose  $\varepsilon_1$ ,  $\varepsilon_2$  and  $\varepsilon_3$  are assumed to be given to servoing controller and the object's pose  $x$ ,  $y$  and  $z$  are recognized by camera.

視界に物体を常に捉えつづけることができる。Fig.15, Fig.16に対象物と手先と Gazing Point(注視点)の時間応答波形を示す。これらの図より、Eye-Vergenceシステムは固定カメラシステムに比べて、振幅の差と位相の遅れが両方とも小さいことが分かる。また、Fig.17, Fig.18と Fig.19から、目標物体は手先座標系の  $x$  軸のみに倒立振り子という運動を行うけれども、図中の End effector が示す線に示すように  $x$ ,  $y$ ,  $z$  軸の三つの方向にカメラで物体を認識し、マニピュレータを制御して、物体を追従している。

よって、Eye-Vergenceシステムは固定カメラシステムよりも優れた安定性を有し、良い追跡性を有することが分かる。

#### 4 結言

本研究では、逆運動学を利用して、各関節の目標角度を計算した。また、新しいコントローラを作り、関節角度を目標角度に追従するようにした。提案したビジュアルサーボシステムの有効性を確認するために、移動対象物のビジュアルサーボ実験を行った具体的には、Eye-Vergenceシステムと固定システムのカメラ注視点の結果を取り、ゲイン曲線と位相曲線を求めた。実験の結果を用いて固定カメラシステムと Eye-Vergenceシステムのカメラの周波数特性を比較し、Eye-Vergenceシステムの可追跡性が固定カメラシステムよりも優れているという結論を得た。

#### 参考文献

- 1) S.Hutchinson, G.Hager, and P.Corke: A Tutorial on Visual Servo Control, IEEE Trans. on Robotics and Automation, Vol.12, No.5, 651/670(1996)
- 2) P.Y.Oh, and P.K.Allen: Visual Servoing by Partitioning Degrees of Freedom, IEEE Trans. on Robotics and Automation, Vol.17, No.1, 1/17(2001)
- 3) E.Malis, F.Chaumette and S.Boudet: 2-1/2-D Visual Servoing, IEEE Trans. on Robotics and Automation, Vol.15, No.2, 238/250(1999)
- 4) P.K.Allen, A.Timchenko, B.Yoshimi, and P.Michelman: Automated Tracking and Grasping of a Moving object with a Robotic Hand-Eye System, IEEE Trans. on Robotics and Automation, Vol.9, No.2, 152/165(1993)
- 5) Wolfgang Sepp, Stefan Fuchs and Gerd Hirzinger: Hierarchical Featureless Tracking for Position-Based 6-DoF Visual Servoing, Proceedings of the 2006 IEEE/RSJ Int. Conf. on Intelligent Robotics and Systems (IROS), 4310/4315(2006)
- 6) Toshifumi Hiramatsu, Takanori Fukao, Keita Kurashiki, Koichi Osuka "Image-based Path Following Control of Mobile Robots with Central Catadioptric Cameras" IEEE International Conference on Robotics and Automation Kobe, Japan, May 12-17(2009)
- 7) Omar Tahri, Youcef Mezouar "Generic Decoupled Image-Based Visual Servoing for Cameras Obeying the Unified Projection Model" IEEE International Conference on Robotics and Automation Kobe, Japan, May 12-17(2009)
- 8) Amei massoud Farahmand, Azad Shademan, Martin Jägersand, Csaba szepesvári "Model-based and Model-free Reinforcement Learning for Visual Servoing" IEEE International Conference on Robotics and Automation Kobe, Japan, May 12-17(2009)
- 9) Dae-Jin Kim, Ryan Lovelett, and Aman Behal "Eye-in-Hand Stereo Visual Servoing of an Assistive Robot Arm in Unstructured Environments" IEEE International Conference on Robotics and Automation Kobe, Japan, May 12-17(2009)

- 10) 松浦・丸：視空間誤差を用いた仮想バネダンパ仮説に基づくダイナミックビジュアルサーボによるEye-In-Hand型ロボットの位置姿勢制御, 日本機械学会論文集 (C編), 77-776, 186/195(2011)
- 11) V.Brandou.et al : Active Stereovision Using Invariant Visual Servoing. Proceedings of IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS'06), 2326/2331(2006)
- 12) D.H Kim, et al. : An image-based control scheme for an active stereo vision system Proceedings of IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS'04), 3375/3380(2004)
- 13) W. Song, M. Minami, Y. Mae and S. Aoyagi, "On-line Evolutionary Head Pose Measurement by Feedforward Stereo Model Matching", IEEE Int. Conf. on Robotics and Automation (ICRA), 4394/4400(2007)
- 14) J. Stavnitzky, D. Capson, "Multiple Camera Model-Based 3-D Visual Servoing", IEEE Trans. on Robotics and Automation, Vol.16, No.6(2000)
- 15) C. Dune, E. Marchand, C. leroux, "One Click Focus with Eye-inhand/Eye-to hand Cooperation", IEEE Int. Conf. on Robotics and Automation (ICRA), 2471/2476(2007)
- 16) Wei. Song, M. Minami, Fujia Yu, Yanan Zhang and Akira Yanou "3-D Hand & Eye-Vergence Approaching Visual Servoing with Lyapunouv-Stable Pose Tracking", IEEE Int. Conf. on Robotics and Automation (ICRA), pp.11, 2011.
- 17) Omar Tahri and Francois Chaumette: Point-Based and Region-Based Image Moments for Visual Servoing of Planar Objects, IEEE Tran. on Robotics, Vol.21, No.6(2005)
- 18) Tarek Hamel and Robert Mahony: Visual Servoing of an Under-Actuated Dynamic Rigid-Body System: An Image-Based Approach, IEEE Trans. on Robotics and Automation, Vol.18, No.2(2002)
- 19) W. Song, M. Minami, S. Aoyagi: On-line Stable Evolutionary Recognition Based on Unit Quaternion Representation by Motion-Feedforward Compensation, International Journal of Intelligent Computing in Medical Sciences and Image Processing (IC-MED) Vol.2, No.2, 127/139(2007).
- 20) M.Minami, W.Song: Hand-eye-motion Invariant Pose Estimation with On-line 1-step GA -3D Pose Tracking Accuracy Evaluation in Dynamic Hand-eye Oscillation, Journal of Robotics and Mechatronics, Vol.21, No.6,709/719(2009)
- 21) W. Song, F. Yu, M. Minami: 3D Visual Servoing by Feedforward Evolutionary Recognition, Journal of Advanced Mechanical Design, Systems, and Manufacturing (JAMDSM) Vol.4, No.4,739/755(2010).
- 22) Tsuneo Yoshikawa: *Foundations of Robotics: analysis and control*, ISBN 0-262-24028-9.
- 23) J. Stavnitzky, D. Capson, "Multiple Camera Model-Based 3-D Visual Servoing, IEEE Trans. on Robotics and Automation, Vol.16, No.6(2000).
- 24) C. Dune, E. Marchand, C. leroux: One Click Focus with Eye-in-hand/Eye-to hand Cooperation, IEEE Int. Conf. on Robotics and Automation (ICRA), 2471/2476(2007).
- 25) Tomoyuki Shiozaki, Toshiyuki Murakami: Trackability Based Motion Control in Mobile Hand-Eye System". SICE-ICASE International Joint Conference, 5304/5309(2006)
- 26) Tsuneo Yoshikawa: *Foundations of Robotics Analysis and Control*, ISBN 0-2622-4028-4.27






Fig. 17: Movement of the x-axis direction of hand coordinate system. The object's pose  $x, y, z, \varepsilon_1, \varepsilon_2$  and  $\varepsilon_3$  are recognized by camera.




Position at y direction in hand coordinate system




Error at y direction in hand coordinate system

(a)  $\omega=0.314$




Position at y direction in hand coordinate system




Error at y direction in hand coordinate system

(b)  $\omega=0.628$




Position at y direction in hand coordinate system




Error at y direction in hand coordinate system

(c)  $\omega=1.256$

Fig. 18: Movement of the y-axis direction of hand coordinate system. The object's pose  $x, y, z, \varepsilon_1, \varepsilon_2, \varepsilon_3$ , are recognized by camera.




Position at z direction in hand coordinate system




Error at z direction in hand coordinate system

(a)  $\omega=0.314$




Position at z direction in hand coordinate system




Error at z direction in hand coordinate system

(b)  $\omega=0.628$



Position at z direction in hand coordinate system



Error at z direction in hand coordinate system

(c)  $\omega=1.256$

Fig. 19: Movement of the z-axis direction of hand coordinate system. The object's pose  $x, y, z, \varepsilon_1, \varepsilon_2, \varepsilon_3$ , are recognized by camera.

# 強化学習による自動帆走の状態空間の検討

○真鍋 秀朗 橋 完太 (工学院大学)

## Consideration of the state representation for semi-autonomous reinforcement learning of sailing within a navigable area

**Abstract**— To sail quickly to a goal within a navigable area, complex control of the rudder and sail is needed. Sailors need to determine the current action considering the time series of states, i.e. not only the current state but also the future state. Reinforcement learning is an appropriate method to learn a complex problem such as sailing. In this paper, we apply the navigable area such that a robotic sailor needs to avoid touching a boundary.

**Key Words:** Reinforcement Learning, Sailing, State Spaces

### 1 はじめに

KonidarisとBarto(2008)<sup>1)</sup>は、強化学習による障害物回避の学習の一例として、ピンボールの実験を行った。迷路状のエリアをボールが壁に衝突しないようゴールさせる実験で、壁に衝突した場合、負の報酬を与える。エピソード数が進むにつれて、だんだんと報酬が増える結果となった。本研究で目標とする学習課題は、ゴールと外壁までの距離だけでなく見かけの風の強さと向きを状態として知覚して帆船の進む方向を決めなければならないため、ピンボールの実験のような単純な障害物の回避だけよりも複雑な問題となる。また、Konidaris(2008)<sup>2)</sup>は、接近における価値関数にフーリエ基底を用い強化学習を行い、エピソード数が多くなるほどタスク達成までのステップ数が少なくなり、良好な結果を得た。

列車や自動車などの人間の運転技術を超える自動化は比較的進んでいるが、帆船操縦の自動化は未解決の問題が多い。帆船の自動航行装置には、設定された針路を保つオートパイロットがある。風や波など外乱の影響を受けやすい帆船の保針性能を向上させるため、これまで外乱に適應するオートパイロット<sup>3)</sup>やファジィ理論を用いる研究<sup>4)</sup>により安定した保針性能が実現された。しかし、人間の判断なくして進路を決定することはできない。そこで、人間の行動を学習して帆船を自動的に効率良く動かせば、機械が人間の判断の代替として人間と同じような操作ができると考える。

帆走は”洋上のチェス”と例えられることが多い。動力源を持たない帆船は風や波の力のみを利用して帆走するため、どのようなコース取りをするか、つまりどの地点にどの方向からどれくらいの速度で入るか、

を予測して進まなければならない。風が吹いて来る方向の左右およそ45°までの方向をデッドゾーンと呼び、帆走の際にデッドゾーンに進むことはできない。そのため、風上の目的地に移動するにはジグザグに移動しなければならない。また、真横から風を受けて帆走することをアビームといい、帆船は風を効率的に受けて最も速く進める。真後ろから風を受けた時が最も速く進むように思えるが、実際は進行風が風を打ち消すためあまり速く帆走できない。目的地に向けて効率的に進むためには、デッドゾーンを避け、できるだけアビームの状態を保つ必要がある。

上記のような複雑な問題を強化学習を利用して帆船に学習させることを目指す。Sterne(2004)<sup>5)</sup>は、自動操縦による目的方向への帆走を実現したが、自動操縦による障害物の回避は実現できなかった。そこで本研究では自動操縦による障害物回避を実現することを目標とする。問題を単純化するため行動を操舵角 $\{-1,0,1\}$ と離散化する。また、ランダムな行動選択から強化学習を開始するのではなく、人間が行動を選択し、ロボットにより人間と同等の行動選択が可能となるかを検証する。状態の表現方法として、望ましい行動を特定でき冗長性を極力排することが求められる。本実験では、帆船から見た風の向き、目的エリアまでの距離、外壁までの距離から状態を定義し、帆船を人間の手で操作した軌跡から状態空間をランダムに分割し、障害物に衝突せずに目標エリアを周回することを目標とする。

## 2 帆船操縦シミュレータ

Fig. 1 に実験に用いた帆船操縦シミュレータの画面を示す。

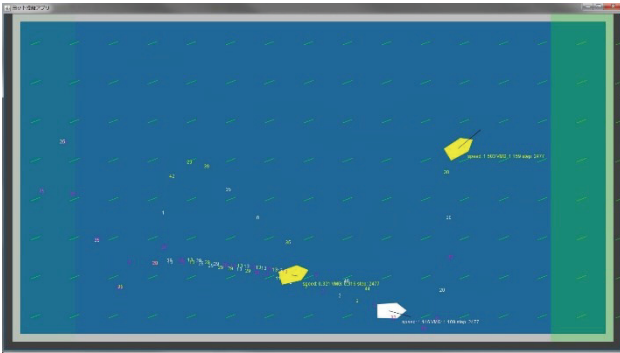


Fig. 1. 帆船操縦プログラム

帆走では、風向きと直交してアビームで走ると大きな加速度が得られる。帆船の速度は、推進力と水から受ける抵抗力により決まる。動いている帆船から見た見かけの風は、絶対風と帆船の速度の逆向きとの合成風となる<sup>6)</sup>。見かけの風が帆を押す力は帆が風を遮る面積に比例する；風が帆を押す力は風速の2乗に比例する；と仮定して、帆船の進行方向に対する見かけの風の方向を $\theta$ 、見かけの風速を $W$ とすると、帆の角度を最適化した場合に帆船は風から $W^2(1 - \cos \theta)$ に比例する推進力を得る。帆船が水から受ける抵抗力は速さの2乗に比例すると仮定する。

画面の東向きをワールド座標系の $x$ 軸、南向きを $y$ 軸とし、 $x$ 座標が0から1,600、 $y$ 座標が0から900である2次元の空間を考える。最初のステップでは、帆船が $x = 190, y = 800$ の位置に速度0でいる。帆船は西側のゴールエリア ( $30 \leq x \leq 190$ ) と東側のゴールエリア ( $1,410 \leq x \leq 1,570$ ) を交互に往復運動する。1ステップを0.025秒、入力は矢印キーで行う。右キーを押せば帆船は右に舵を切り、左キーを押せば帆船は左に舵を切る。キーを離すと方向を変えない状態になる。加速はその時に帆船が出せる最大の加速度を出すものとする。また、帆船が外壁の(4直線 $x = 30, x = 1,570, y = 30, y = 870$ で囲まれる)位置に到達した場合、帆船が壁に衝突したと考え、速度を0にする。

## 3 状態空間の定義

風は、ワールド座標系における東北東の方向から一

定速で吹く設定とする。また、帆船に固定したヨット座標系は帆船の船先(船首)方向を $x$ 軸、船先の右90度の方向を $y$ 軸とする。帆船の船先を $\theta = 0$ とし、帆船の周囲 $\theta = 0, 1, \dots, 359$ に対して目的エリアまでの距離 $d_+(\theta)$ を求める。 $\theta$ の方向に目的エリアが存在しない場合は $d_+(\theta) = \infty$ とする。同様に外壁までの距離 $d_-(\theta)$ を求める。その後、関数 $\ell = e^{-d}$ により $d_+(\theta), d_-(\theta)$ の値を変換し、それぞれを近さ関数 $\ell_+(\theta), \ell_-(\theta)$ と定義する。

$$[d_+(\theta)] = 0^\circ, 1^\circ, \dots, 359^\circ \quad (\text{目的エリアまでの距離})$$

$$[d_-(\theta)] = 0^\circ, 1^\circ, \dots, 359^\circ \quad (\text{外壁までの距離})$$

$$\ell_+(\theta) = e^{-d} \cdot [d_+(\theta)]$$

$$\ell_-(\theta) = e^{-d} \cdot [d_-(\theta)]$$

その後、横軸を $\theta$ 、縦軸を $\ell_+(\theta), \ell_-(\theta)$ とした関数を以下の式でフーリエ変換する。

$$f(\theta) = a_0 + a_1 \cos \theta + b_1 \sin \theta + a_2 \cos 2\theta$$

$$+ b_2 \sin 2\theta + \dots + a_n \cos n\theta$$

$$+ b_n \sin n\theta + \dots$$

$$(n \in \mathbb{N})$$

フーリエ係数の項数 $n = 17$ とした。見かけの風についてはヨット座標系での2次元ベクトルで表す。状態空間は10, 20, 50, 100, 200, 500個に分割してそれぞれ実験を行った。帆船が最初に1周した際の軌跡から得た状態データからランダムに選択した状態を母点とし、状態空間をVoronoi分割した。

## 4 実験

Fig. 2に実験における帆船の学習プロセスを示す。行動の学習はQ学習で行った。Q学習のパラメータは以下のように設定した。

$$\text{学習率 } \alpha = 0.001$$

$$\text{割引率 } \gamma = 0.999$$

行動数: 3 (右折, 直進, 左折)

状態空間の分割数: 10, 20, 50, 100, 200, 500

$$\text{報酬} : r_t = \begin{cases} 1,000 & (\text{目的エリアに到達した時}) \\ -10,000 & (\text{外壁に衝突した時}) \\ -2,000 & (\text{風上を向き続け停止した時}) \\ -1 & (1 \text{ ステップ経過時}) \end{cases}$$

$$\text{行動選択} : \begin{cases} \varepsilon - \text{greedy} & (\rho \geq \varepsilon = 0.01) \\ \text{softmax} & (\rho < \varepsilon = 0.01) \end{cases}$$

ここで、 $\rho$ は $[0,1)$ の一樣乱数である。

帆船が1周すると、 $x = 800, y = 450$ の位置に自機以外の2機の帆船が出現する（以下、エージェント船と呼ぶ）。この2機のエージェント船は自機とQ表を共有して強化学習を行い、Q表に従って行動を選択する。エージェント船が外壁に衝突した場合、 $x = 800, y = 450$ の位置に戻り、行動を再開する。10周したら自機は500,000ステップの間アンカーモードに入る。アンカーモードでは自機をその場に静止させ自機の行動によるQ値の更新を停止し、エージェント船はQ学習を続ける。その後、再び自機を10周させる。これを合計3,000,000ステップになるまで繰り返す。なお、人間が操作した際の1周の平均周回ステップ数は1,424.8(±36.1)ステップであった。実験は状態空間の分割数ごとに2回ずつ行った。

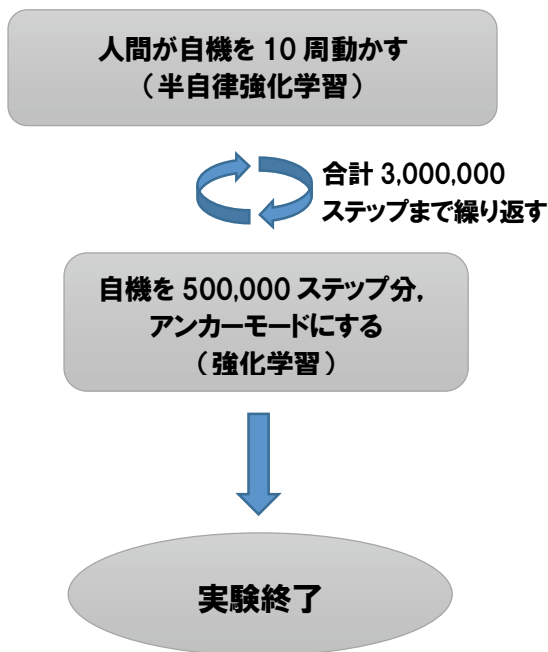


Fig. 2: 実験における帆船の学習プロセス

## 5 実験結果




Fig. 3: 状態空間分割数10, 20, 50での実験結果




Fig. 4: 状態空間分割数100, 200, 500での実験結果

Fig. 3とFig. 4に、状態空間の分割数10, 20, 50とした実験結果、状態空間分割数100, 200, 500での実験結果を示す。縦軸は10,000ステップごとの自機、エージェント船2機の合計3機の報酬の2回の実験での平均値、横軸はステップ数を示している。

## 6 考察

今回の実験では帆船を1周させることはほとんどできなかった。以下はFig. 3とFig. 4のグラフのステップ数 $x_k$ 、合計報酬 $y_k$ を一次式で近似したものである。 $x_k, y_k$ の $k$ は状態空間の分割数を表す。

$$y_{10} = 0.04607(\pm 0.0202.7)x_{10} - 474,947$$

$$y_{20} = 0.02899(\pm 0.0025.1)x_{20} - 430,284$$

$$y_{50} = 0.01975(\pm 0.0001.9)x_{50} - 480,563$$

$$y_{100} = 0.02331(\pm 0.0286.8)x_{100} - 489,586$$

$$y_{200} = -0.00047(\pm 0.0321.9)x_{200} - 500,849$$

$$y_{500} = -0.061(\pm 0.0267.6)x_{500} - 440,724$$

以上の結果から、状態空間の分割数が増えるほど、学習に伴う報酬の増加が少なくなり、分割数500では2回とも学習に伴い報酬が減少したと言える。

しかし、一部の状態において外壁を避ける行動が学習された。例として、分割数100の一つの状態(状態55. 状態の番号はランダム)を挙げる。Fig. 5における赤丸で記した部分に帆船がいる状態が状態55である。



Fig. 5: 分割数100における状態55の図

状態55では、エージェント船が左に舵を切る行動が多く見られた。この時の目的エリアまでの近さ関数  $\ell_+(\theta)$  と外壁までの近さ関数  $\ell_-(\theta)$  をフーリエ係数からフーリエ逆変換により調べたところ、以下のFig. 6のようになった。

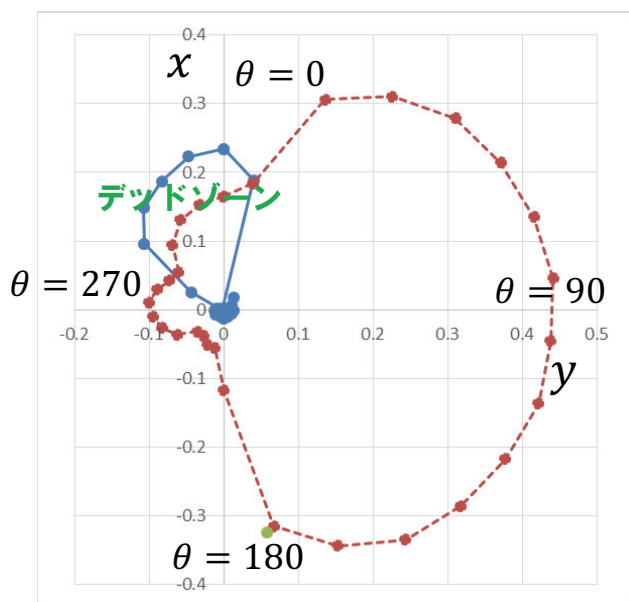


Fig. 6: 状態55における近さ関数と見かけの風の向き

Fig. 6に、状態55における目的エリアと外壁までの近さ関数を示す。実線が目的エリアまでの近さ関数  $\ell_+(\theta)$ 、破線が外壁までの近さ関数  $\ell_-(\theta)$  である。また、図中の矢印は見かけの風の向きを示している。状態55において帆船から見た目的エリアは前方からやや左側が近く、帆船から見た外壁は右側が近いということが分かり、見かけの風の向きは帆船から見て左前方であることが分かる。Fig. 5から分かるように、帆船から見ると前方からやや左側に目的エリアがあり、右側に外壁があるため、状態の把握が良好に行われていることが分かる。また、この時のQ値はそれぞれ左折:-696.8, 直進:-703.2, 右折:-704.1となっており、左折することによって外壁を避けることを学習していることが分かる。

## 7 まとめと今後の課題

今回の実験では帆船を1周させることはほとんどできなかった。しかし、強化学習により外壁が近づいた際に回避する行動を獲得することができた。フーリエ逆変換により目的エリアと外壁までの近さ関数を出し、状態の認識が良好に行われていることを確認した。また、今回は状態空間を自機が1周した際の軌跡からランダムに選択し、状態空間を分割した。今後は、k-means法などを使ったクラスタリングを用い、適切な分割を求めて実験していきたいとも考えている。

## 参考文献

- 1) George Konidaris and Andrew Barto: Skill Discovery in Continuous Reinforcement Learning Domains using Skill Chaining, Computer Science Department, University of Massachusetts Amherst (2008)
- 2) George Konidaris: Value Function Approximation in Reinforcement Learning using the Fourier Basis, University of Massachusetts – Amherst, Computer Science Department Faculty Publication Series, 1/10 (2008)
- 3) 前野, 山川: ファジィ理論を用いた小型船舶用適応型オートパイロット, 知能と情報: 日本知能情報ファジィ学会誌, 17-6, 719/734 (2005)
- 4) 長谷川, 上月, 村松, 小峰, 渡部: 船舶自動航行ファジィエキスパートシステム(SAFES), 日本造船学会論文集; 166, 445/452 (1989)
- 5) Smith, AJ: Applications of the self-organising map to reinforcement learning, Neural Netw., 15, 1107/1124 (2002)
- 6) Philip Jonathan Sterne: Reinforcement Sailing, Master of Science Artificial Intelligence School of Informatics University of Edinburgh (2004)



# 複素多層パーセプトロン学習における一層の探索枝刈りの効果

○佐藤聖也 中野良平 (中部大学)

## How Further Search Pruning Works for Complex-Valued Multilayer Perceptron Learning

\*S. Satoh and R. Nakano (Chubu University)

**Abstract**— In the search space of a complex-valued multilayer perceptron having  $J$  hidden units, C-MLP( $J$ ), there are singular regions, where the gradient is zero, as is the case with a real-valued MLP. Since a method called complex singularity stairs following, C-SSF, starts searches of C-MLP( $J$ ) from singular regions formed from the best solution of C-MLP( $J-1$ ), C-SSF allows for finding excellent solutions. However, the number of searches tends to increase in the process of C-SSF, as  $J$  gets larger. To deal with this problem, we proposed C-SSF1.1, which prunes searches that merge onto previous search routes. In this paper, we propose C-SSF1.3, which goes further with search pruning, and then evaluate the proposed method in terms of solution quality and processing time.

**Key Words:** Complex-valued multilayer perceptron, Singular region, Search pruning

### 1 まえがき

複素ニューラルネットは複素数の情報を扱えるため、実ニューラルネットにない特徴を有する。例えば、複素多層パーセプトロン (複素 MLP) は複素ニューラルネットの一種であるが、その活性化関数には複素数をそのまま扱うタイプや、複素数を実部と虚部に分離しそれぞれを実数として扱うタイプなどがある。本稿では複素数をそのままシグモイド関数に入力する活性化関数を用いるが、その活性化関数は振幅が可変な周期性があり、かつ実数のみが入力されれば実 MLP のシグモイド関数と同じとなる。このような性質を実 MLP で実現することは難しい。

複素 MLP の学習法としては、探索空間の勾配を用いる複素バックプロパゲーション法 (C-BP) <sup>6,7)</sup> や、勾配のみでなく Hesse 行列の逆行列の近似も用いて探索する準 Newton 法の一種の複素 BFGS 法 (C-BFGS) <sup>13)</sup> などが用いられる。C-BFGS は C-BP よりも効率良く探索空間を降下できる。

しかし、複素 MLP の探索空間には、実 MLP と同様、勾配がゼロの特異領域や局所最適解が多数存在するため、C-BFGS を用いたとしても常に訓練誤差を効率良く減少させられるとは限らない。実 MLP の探索法としては、特異領域を回避する方法 <sup>1,2)</sup> が提案されたが、もし回避できたとしても、その後良質の解が得られる保証はない。

探索空間に特異領域が存在する学習モデルは特異モデルと呼ばれるが、特異モデルは MLP のみでなく、ガウス混合モデルや隠れマルコフモデルなども特異モデルである。これらの特異モデルの性質を理論的に解析する研究がなされ、特異モデルの汎化誤差を推定する理論が提案されて来た <sup>14,15)</sup>。

隠れユニット数が  $J$  個の複素 MLP の探索空間上の特異領域は隠れユニット数が  $J-1$  個の複素 MLP の最適解に可約性写像を適用すると形成される。このように形成された特異領域上の全ての点の訓練誤差は可約性写像を適用した解と等しく、また、そのほとんどの点は降下するルートが存在する鞍点である <sup>8)</sup>。この性質を利用し、特異領域を回避するのではなく、逆に利用する複素

特異階段追跡法 (C-SSF: Complex Singularity Stairs Following) が提案された <sup>9)</sup>。この方法は複素 MLP ( $J-1$ ) の最適解と訓練誤差が等しい特異領域から探索空間を降下するため、訓練誤差の単調減少が保証されており、良質の解を得ることができる。しかし、隠れユニット数が多いときはその分特異領域も増えるため、探索数が増大する問題がある。そのため、現在の探索が以前の探索経路と合流する場合は現在の探索を枝刈りする手法を導入した C-SSF1.1<sup>10)</sup> が提案され、処理負荷が軽減されたが、隠れユニット数が多いときは、依然として初期点をランダムに設定して 100 回試行する方法よりも時間が掛かる傾向があった。

本稿では特異領域上の Hesse 行列の固有値を基に探索の優先順位を決定し、探索の上限を設けて一層の探索枝刈りを進めた C-SSF1.3 を提案する。この探索枝刈り手法は実 MLP の探索法である SSF1.4<sup>12)</sup> に導入され、解品質を劣化させることなく処理時間が削減できた。そのため、複素 MLP の学習においても解品質を劣化させることなく処理時間を大幅に削減することが期待できる。後述の計算機実験にて提案法の有効性を評価する。

### 2 複素多層パーセプトロンの特異領域

#### 2.1 可約性写像と特異領域

本節では、隠れユニットが  $J-1$  個の複素 MLP の最適解に可約性写像を適用して隠れユニットを一つ増やすと特異領域が形成されることを簡単に説明する。

ここで、隠れユニットが  $J$  個、出力ユニット 1 個の複素 MLP (複素 MLP( $J$ )) の出力は以下である。ただし、 $\theta_J = \{w_0, w_j, \mathbf{w}_j, j = 1, \dots, J\}$  とし、重みや入出力は全て複素数とする。

$$f_J(\mathbf{x}; \theta_J) = w_0 + \sum_{j=1}^J w_j z_j, \quad z_j \equiv g(\mathbf{w}_j^T \mathbf{x}) \quad (1)$$

学習データ  $\{(\mathbf{x}^\mu, y^\mu), \mu = 1, \dots, N\}$  が与えられて、以下の目的関数を最小にすることを考える。ただし、 $\bar{\delta}^\mu$

は  $\delta^\mu$  の共役複素数とする。

$$E_J = \sum_{\mu=1}^N \delta^\mu \bar{\delta}^\mu, \quad \delta^\mu \equiv f_J(\mathbf{x}^\mu; \boldsymbol{\theta}_J) - y^\mu \quad (2)$$

さらに、隠れユニットが  $J-1$  個の複素 MLP( $J-1$ ) の重みを  $\boldsymbol{\theta}_{J-1} = \{u_0, u_j, \mathbf{w}_j, j=1, \dots, J-1\}$  とする。その出力は以下である。

$$f_{J-1}(\mathbf{x}; \boldsymbol{\theta}_{J-1}) = u_0 + \sum_{j=1}^{J-1} u_j v_j, \quad v_j \equiv g(\mathbf{u}_j^T \mathbf{x}) \quad (3)$$

ここで、複素 MLP( $J-1$ ) の最適解を  $\hat{\boldsymbol{\theta}}_{J-1} = \{\hat{u}_0, \hat{u}_j, \hat{\mathbf{w}}_j, j=1, \dots, J-1\}$  とし、 $\hat{\boldsymbol{\theta}}_{J-1}$  に3種の可約性写像  $\alpha, \beta, \gamma$  を適用して得られる領域をそれぞれ  $\hat{\Theta}_J^\alpha, \hat{\Theta}_J^\beta, \hat{\Theta}_J^\gamma$  とする。

$$\hat{\boldsymbol{\theta}}_{J-1} \xrightarrow{\alpha} \hat{\Theta}_J^\alpha, \quad \hat{\boldsymbol{\theta}}_{J-1} \xrightarrow{\beta} \hat{\Theta}_J^\beta, \quad \hat{\boldsymbol{\theta}}_{J-1} \xrightarrow{\gamma} \hat{\Theta}_J^\gamma$$

$$\hat{\Theta}_J^\alpha \equiv \{\boldsymbol{\theta}_J \mid w_0 = \hat{u}_0, w_1 = 0, w_j = \hat{u}_{j-1}, \mathbf{w}_j = \hat{\mathbf{w}}_{j-1}, j=2, \dots, J\} \quad (4)$$

$$\hat{\Theta}_J^\beta \equiv \{\boldsymbol{\theta}_J \mid w_0 + w_1 g(w_{10}) = \hat{u}_0, \mathbf{w}_1 = [w_{10}, 0, \dots, 0]^T, w_j = \hat{u}_{j-1}, \mathbf{w}_j = \hat{\mathbf{w}}_{j-1}, j=2, \dots, J\} \quad (5)$$

$$\hat{\Theta}_J^\gamma \equiv \{\boldsymbol{\theta}_J \mid w_0 = \hat{u}_0, w_1 + w_m = \hat{u}_{m-1}, \mathbf{w}_1 = \mathbf{w}_m = \hat{\mathbf{w}}_{m-1}, w_j = \hat{u}_{j-1}, \mathbf{w}_j = \hat{\mathbf{w}}_{j-1}, j \in \{2, \dots, J\} \setminus \{m\}\} \quad (6)$$

ただし、 $m=2, \dots, J$  とする。 $\hat{\Theta}_J^\alpha, \hat{\Theta}_J^\beta, \hat{\Theta}_J^\gamma$  の領域の内、目的関数  $E_J(\boldsymbol{\theta})$  の勾配がゼロとなる連続領域（特異領域）は以下の二つの領域である。

(1) 領域  $\hat{\Theta}_J^\alpha$  と  $\hat{\Theta}_J^\beta$  が重なる領域は  $w_{10}$  が任意の特異領域である。ここでは以下が成立するこの領域を  $\hat{\Theta}_J^{\alpha\beta}$  とする。

$$w_0 = \hat{u}_0, \quad w_1 = 0, \quad \mathbf{w}_1 = [w_{10}, 0, \dots, 0]^T \\ w_j = \hat{u}_{j-1}, \quad \mathbf{w}_j = \hat{\mathbf{w}}_{j-1}, \quad j=2, \dots, J \quad (7)$$

(2) 領域  $\hat{\Theta}_J^\gamma$  は、以下の式を満たす特異領域である。

$$w_1 + w_m = \hat{u}_{m-1} \quad (8)$$

## 2.2 複素特異階段追跡法 1.2 の処理の流れ

複素特異階段追跡法 1.2(C-SSF1.2)<sup>11)</sup> は上記の特異領域を探索の初期点として利用する。C-SSF1.1 と 1.2 の違いは、C-SSF1.1 は常に最良の解のみを利用するが、C-SSF1.2 では隠れユニット数が非常に少ないときは上位複数個の解を用いて探索することである。このことにより、C-SSF1.2 では隠れユニット数が非常に少ないときに C-SSF1.1 よりも良い解が得られ、それ以降の探索でも C-SSF1.1 よりも良い解が得られた<sup>11)</sup>。

隠れユニットが  $J_R$  個まで上位  $R$  個の解を用いて探索する C-SSF1.2 の処理の流れを以下に示す。ただし、

考慮する隠れユニットの最大数を  $J_{max}$ 、複素 MLP( $J$ ) の重みを  $\{w_0^{(J)}, w_j^{(J)}, \mathbf{w}_j^{(J)}\}$  とする。

### C-SSF1.2 の処理の流れ

- 1: 隠れユニットが 0 個のときの最大最適解を求める。  
( $\hat{w}_0^{(0)} \leftarrow \bar{y}$ )
- 2: **for**  $J=1, \dots, J_{max}$  **do**
- 3:   **if**  $J \leq J_R$  **then**
- 4:     **for**  $r=1, \dots, R$  **do**
- 5:       隠れユニットが  $J-1$  個のときの探索で得られた  $r$  番目に良質の解に可約性写像を適用して初期点を特異領域上に設定し、Hesse 行列の固有値と固有ベクトルを求める。
- 6:       全ての負の固有値に対応する固有ベクトル方向とその逆方向に探索空間を降下して解を探索する。
- 7:     **end for**
- 8:   **else**
- 9:     隠れユニットが  $J-1$  個のときの探索で得られた最良解に可約性写像を適用して初期点を特異領域上に設定し、Hesse 行列の固有値と固有ベクトルを求める。
- 10:    全ての負の固有値に対応する固有ベクトル方向とその逆方向に探索空間を降下して解を探索する。
- 11:   **end if**
- 12: **end for**

Step 5 と 9 では可約性写像  $\alpha, \beta$  と  $\gamma$  を利用するが、可約性写像  $\alpha, \beta$  を適用して初期点を特異領域  $\hat{\Theta}_J^{\alpha\beta}$  上に設定する方法は以下とする。ただし、隠れユニットが  $J-1$  個のときの探索で得られた解を  $\{\hat{w}_0^{(J-1)}, \hat{w}_j^{(J-1)}, \hat{\mathbf{w}}_j^{(J-1)}\}$  とする。

$$w_0^{(J)} \leftarrow \hat{w}_0^{(J-1)}, \quad w_1^{(J)} \leftarrow 0, \\ \mathbf{w}_1^{(J)} \leftarrow [p, 0, \dots, 0]^T, \\ w_j^{(J)} \leftarrow \hat{w}_{j-1}^{(J-1)}, \quad \mathbf{w}_j \leftarrow \hat{\mathbf{w}}_{j-1}^{(J-1)}, \quad j=2, \dots, J$$

$\gamma$  写像を適用して初期点を特異領域  $\hat{\Theta}_J^\gamma$  上に設定する方法は以下とする。ただし、 $m=2, \dots, J$  とする。

$$w_0^{(J)} \leftarrow \hat{w}_0^{(J-1)}, \quad w_1^{(J)} \leftarrow q \times \hat{w}_{m-1}^{(J-1)}, \\ w_m^{(J)} \leftarrow (1-q) \times \hat{w}_{m-1}^{(J-1)}, \\ \mathbf{w}_1^{(J)} \leftarrow \hat{\mathbf{w}}_{m-1}^{(J-1)}, \quad \mathbf{w}_m^{(J)} \leftarrow \hat{\mathbf{w}}_{m-1}^{(J-1)}, \\ w_j^{(J)} \leftarrow \hat{w}_{j-1}^{(J-1)}, \quad \mathbf{w}_j \leftarrow \hat{\mathbf{w}}_{j-1}^{(J-1)}, \\ j \in \{2, \dots, J\} \setminus \{m\}$$

以下の計算機実験では、 $\hat{\Theta}_J^{\alpha\beta}$  からは  $p = -1, 0, 1$  の3点、 $\hat{\Theta}_J^\gamma$  からは  $q = 0.5, 1.0, 1.5$  (それぞれ内分点、内分と外分の境界点、外分点) の  $3 \times (J-1)$  点を初期点とした。また、 $R=3, J_R=3$  とし、C-SSF1.2 の処理の流れの Step 5 の解の選択では同じ解を選択することを避けるため、 $r > 1$  のとき、 $r-1$  番目の解よりも訓練誤差の差が  $10^{-8}$  以上ある解の中で最小のものを選択した。特異領域上から固有ベクトル方向へ探索する




Fig. 1: Conceptual diagram of eigenvectors at a point in a singular region.

際は勾配法では重みを更新できないため、まず黄金分割法<sup>5)</sup>を用いて重みを一度更新し、その後の探索は準Newton法の一種のC-BFGS<sup>13)</sup>を用いた。

また、C-BFGSで探索空間を降下する際は探索枝刈り処理を行うが、探索枝刈りの閾値 $\epsilon$ は0.3、探索枝刈りの判定と重みの記録は探索ステップ数が $\{100n, n = 1, \dots\}$ のときとする。探索枝刈り処理の詳細は文献<sup>10)</sup>を参照されたい。

### 3 複素特異階段追跡法 1.3

C-SSF1.1と1.2は探索枝刈りを用いることにより処理時間を削減できるが、隠れユニット数が多いときは、依然として初期点をランダムに設定して100回試行する方法よりも時間が掛かる傾向があった<sup>10, 11)</sup>。そこで本稿では、特異領域上のHesse行列の固有値を基に探索の優先順位を決定し、探索数に上限を設けて一層の探索枝刈りを進めたC-SSF1.3を提案する。この探索枝刈り手法は実MLPの探索法であるSSF1.4に導入され、その結果、解品質を劣化させることなく処理時間を削減できた<sup>12)</sup>。そのため、複素MLPの学習においても解品質を劣化させることなく処理時間を大幅に削減することが期待できる。

図1に特異領域上の固有ベクトルの概念図を示す。図に示すように、負の固有値の内、固有値が小さいほどその固有値に対応する固有ベクトル方向の探索空間のたわみが急であると考えられる。そのため、負の固有値が小さいほど、対応する固有ベクトル方向に探索を行って得た解の訓練誤差は小さい傾向があると考えられる。しかし、最小の固有値が最小の訓練誤差をもたらす訳ではないため、複数回の探索を行う必要があると思われる。

C-SSF1.3の処理の流れを以下に示す。C-SSF1.2との違いはStep 10以降である。ただし、探索回数の上限は $Max$ とする。

#### C-SSF1.3の処理の流れ

- 1:  $J = 0$ の大域最適解を求める。( $w_0 = \bar{y}$ )
- 2: **for**  $J = 1, \dots, J_{\max}$  **do**
- 3:   **if**  $J \leq J_R$  **then**
- 4:     **for**  $r = 1, \dots, R$  **do**
- 5:       隠れユニットが  $J - 1$  個のときの探索で得られた  $r$  番目に良質の解に可約性写像を適用して初期点を特異領域上に設定し、Hesse行列の固有値と固有ベクトルを求める。
- 6:       全ての負の固有値に対応する固有ベクトル方向とその逆方向に探索空間を降下して解

を探索する。

- 7:     **end for**
- 8:   **else**
- 9:     隠れユニットが  $J - 1$  個のときの探索で得られた最良解に可約性写像を適用して初期点を特異領域上に設定し、Hesse行列の固有値と固有ベクトルを求める。
- 10:    **while** 選択する負の固有値が無くなるか、探索数が  $Max$  回となるまで以下を繰り返す。 **do**
- 11:     Step 9で計算した負の固有値の中で最も小さい固有値から順に選択し、その固有値に対応する固有ベクトル方向とその逆方向に探索空間を降下して解を探索する。
- 12:    **end while**
- 13:   **end if**
- 14: **end for**

以下の計算機実験では利用する特異領域などの設定は全てC-SSF1.2と同じとし、探索回数の上限 $Max$ は100とした。

### 4 計算機実験


特異領域上のHesse行列の固有値を基に探索枝刈りを行う手法をC-SSF1.2に導入したC-SSF1.3の性能を評価するため、計算機実験を行った。比較する従来法は、C-SSF1.2の他に、直線探索付きバッチ型複素BP法(ここでは単にC-BPと呼ぶ)、準Newton法の一環であるC-BFGS<sup>13)</sup>とした。C-BPとC-BFGSの初期重みは実部と虚部共に区間 $(-1, +1)$ の中からランダムに選択し、各 $J$ で100回の試行を行った。各試行の終了条件は、スイープ回数が1万回を越えるか、探索幅が $10^{-16}$ 以下となった場合とした。

複素MLPの活性化関数はKimら<sup>3)</sup>とLeungら<sup>4)</sup>が独立に提案した以下の活性化関数を用いた。ただし、 $z = a + ib$ ,  $i = \sqrt{-1}$ とする。


$$\begin{aligned} \sigma(z) &= \frac{1}{1 + e^{-z}} \\ &= \frac{1 + e^{-a} \cos b + ie^{-a} \sin b}{1 + 2e^{-a} \cos b + e^{-2a}} \end{aligned} \quad (9)$$

この活性化関数は、特異点を含む正則関数である。正則でない活性化関数を持つ複素MLPの特異領域については解析が行われた<sup>8)</sup>が、正則な活性化関数を持つ複素MLPの特異領域については詳しく解析されていない。しかし、式(9)の活性化関数は振幅が可変な周期性を持つため、入力とともに振幅が変化するような関数に対しても有効に働くと考えられる。

プログラミング言語はMATLAB R2014aを用いた。人工問題1ではCPUがIntel(R) Xeon(R) CPU E5-2687W 0 @ 3.10GHz, RAMが32GBのコンピュータを用い、人工問題2ではCPUがIntel(R) Core i7-2600 3.40 GHz, RAMが12 GBのXPS 8300を用いた。



(a) Training error.



(b) Test error.

Fig. 2: Training and test errors for artificial data 1.

#### 4.1 人工問題 1

人工問題 1 として、以下の重みを持つ複素 MLP から生成したデータを用いて実験を行った。

$$\begin{aligned}
 & (w_0, w_1, w_2, w_3, w_4) \\
 & = (-4 + 3i, 2 - 2i, 3 - 2i, 3 + 5i, 0 - 5i), \\
 & (w_1, w_2, w_3, w_4) \\
 & = \begin{pmatrix} 2 + 4i & 3 + 0i & -5 + 0i & 2 - 2i \\ 5 - 3i & -4 - 2i & -3 - 2i & -4 - 2i \\ 1 + 3i & 3 - 4i & 1 + 1i & -1 - 2i \\ 5 + 5i & -2 - 1i & 4 - 3i & -5 + 2i \\ -3 - 5i & 0 - 1i & 2 - 5i & 4 - 3i \\ 0 + 0i & 0 + 0i & 0 + 0i & 0 + 0i \\ 0 + 0i & 0 + 0i & 0 + 0i & 0 + 0i \\ 0 + 0i & 0 + 0i & 0 + 0i & 0 + 0i \end{pmatrix} \quad (10)
 \end{aligned}$$

訓練データの説明変数  $x_k^\mu$  の実部と虚部は区間 (0,1) の中でランダムに生成した。被説明変数  $y^\mu$  の値は上記の重みを持つ複素 MLP ( $J = 4$ ) の出力の実部と虚部に小さな正規乱数  $\mathcal{N}(0, 0.01^2)$  を加え、500 個のデータ点を生成した。テストデータは、 $x_k^\mu$  を訓練データと同様の方法で訓練データとは別に生成し、 $y^\mu$  には乱数を加えずに 1000 個のデータ点を生成した。考慮する隠れユニットの最大数は  $J_{max} = 6$  とした。

Fig. 2 に各  $J$  で得られた最小の訓練誤差とその解のテスト誤差を示す。図の縦軸は対数表示とした。C-BP では  $J$  を増やすと逆に訓練誤差が増加する傾向にあった。C-BFGS では  $J = 5$  のとき訓練誤差が増加した。C-SSF1.2, 1.3 では、隠れユニットの増加に伴って訓練誤差が単調減少し、 $J = 3$  以降では C-BFGS よりも小さい訓練誤差の解を得た。また、テスト誤差は  $J = 4$  のとき最小値を得た。人工問題 1 は複素 MLP ( $J = 4$ ) から生成したデータを用いたため、C-SSF1.2, 1.3 は正解のモデルを選択できた。

Table 1 に各探索法の探索回数を示す。ただし、C-

Table 1: Numbers of searches for artificial data 1.

$J$	C-BP	C-BFGS	C-SSF1.2	C-SSF1.3
1	100	100	38	38
2	100	100	132	132
3	100	100	321	321
4	100	100	160	100
5	100	100	220	100
6	100	100	237	100

Table 2: CPU time for artificial data 1. (hr:min:sec)

$J$	C-BP	C-BFGS	C-SSF1.2	C-SSF1.3
1	00:35:38	00:00:30	00:00:13	00:00:13
2	00:53:57	00:00:53	00:00:39	00:00:39
3	01:10:27	00:01:08	00:03:09	00:03:09
4	01:39:13	00:02:18	00:01:19	00:01:00
5	01:22:45	00:02:35	00:02:56	00:02:07
6	01:41:25	00:03:54	00:04:06	00:02:53
total	07:23:24	00:11:19	00:12:22	00:10:02

SSF1.2, 1.3 は探索途中で枝刈りされた探索を含む。C-SSF1.3 では  $J = 4$  以降では 100 回のみしか探索していないが、C-SSF1.2 とほぼ同じ解を得、C-SSF1.2 と同様、 $J = 4$  のとき正解モデルを得た。

全ての探索法の処理時間を Table 2 に示す。C-BP 以外は全て 13 分以内に処理が終了したが、C-BP は 7 時間以上かかった。これは探索空間の条件数が大きいこと、勾配のみを利用する C-BP では探索が困難となることの原因と考えられる。C-SSF1.3 は最も速く、C-BFGS よりも 1.1 倍、C-SSF1.2 よりも 1.2 倍速く処理が終了した。C-SSF1.3 は探索数の上限を設定することにより、 $J = 4$  以降では C-BFGS と同様 100 回を探索を行ったが、処理時間は C-BFGS よりも速かった。これは以前の探索経路と合流した場合は探索を枝刈りすること、加えて C-SSF の探索では隠れユニットが  $J - 1$  個の解から形成した特異領域上が初期点であるため、解に収束する時間が初期点をランダムに設定して探索する C-BFGS よりも速い傾向があるためと考えられる。


#### 4.2 人工問題 2

人工問題 2 では、以下の、対数螺旋の線形和の式から生成したデータを用いて実験を行った。


$$\begin{aligned}
 y & = \{0.001e^{0.1\phi} + 2.5e^{-0.1\phi} + 0.1e^{0.05\phi}\} \\
 & \quad \{e^{2i\phi} + e^{5i(\phi+\pi/3)} + e^{12i\phi} + e^{15i\phi}\}, \\
 \phi & = 2\pi x \quad (11)
 \end{aligned}$$

訓練データの  $x^\mu$  は実数区間 (0,10) の中でランダムに生成し、被説明変数  $y^\mu$  の実部と虚部に小さな正規乱数  $\mathcal{N}(0, 0.01^2)$  を加え、1000 個のデータ点を生成した。テストデータは  $x^\mu$  の生成区間は訓練データとは異なり、実数区間 (10, 13) とし、 $y^\mu$  に乱数を加えず 1000 個のデータ点を生成した。つまり、テストデータの  $x^\mu$  の生成区間は未学習である。考慮する隠れユニット数の最大は  $J_{max} = 16$  とした。

Fig. 3 に各  $J$  での最小の訓練誤差とその解のテスト誤差を示す。C-BP は  $J$  が増加しても訓練誤差が減少しておらず、テスト誤差もその他と比べて大きいことがわかる。C-BFGS は  $J = 9, 13, 14, 16$  のとき訓練誤差が増加した。C-SSF1.2, 1.3 は、隠れユニットの増加に伴って訓練誤差が単調減少し、 $J = 5$  以降は C-BFGS



(a) Training error.



(b) Test error.

Fig. 3: Training and test errors for artificial data 2.


Table 3: Numbers of searches for artificial data 2.

$J$	C-BP	C-BFGS	C-SSF1.2	C-SSF1.3
1	100	100	16	16
2	100	100	81	81
3	100	100	162	162
4	100	100	70	70
5	100	100	80	80
6	100	100	177	100
7	100	100	190	100
8	100	100	269	100
9	100	100	568	100
10	100	100	306	100
11	100	100	593	100
12	100	100	583	100
13	100	100	1042	100
14	100	100	770	100
15	100	100	1664	100
16	100	100	838	100


よりも訓練誤差が小さい解を得た。C-SSF1.2, 1.3 のテスト誤差から  $J = 12$  または  $13$  が最良モデルと思われる。

Table 3 に各探索法の探索回数を示す。ただし、Table 2 と同様、C-SSF1.2, 1.3 は探索途中で枝刈りされた探索を含む。C-SSF1.3 は  $J = 6$  以降では 100 回しか探索していなかったが、C-SSF1.2 とほとんど同じ良質の解を得た。


C-BP, C-BFGS, C-SSF1.2, C-SSF1.3 のテスト誤差が最小となったときの隠れユニット数は、それぞれ  $J = 15, 15, 13, 12$  であった。そのときの複素 MLP の出力を Fig. 4 に示す。図に示すように、C-BP はうまく近似できていないことがわかる。C-BFGS では、 $x$  が大きくなるにつれてずれが大きくなっている。一方、C-SSF1.2, 1.3 では  $x = 13$  までうまく予測できていることがわかる。




(a) C-BP( $J = 15$ )



(b) C-BFGS( $J = 15$ )



(c) C-SSF1.2( $J = 13$ )



(d) C-SSF1.3( $J = 12$ )

Fig. 4: Outputs of C-MLPs.

全ての探索法の処理時間を Table 4 に示す。C-BP 以外は全て 5 時間以内に処理が終了したが、C-BP は 41 時間以上かかった。これは人工問題 1 のときと同様、探索空間の条件数が大きいと C-BP では探索が困難となるのが原因と考えられる。C-SSF1.3 は最も速く、C-BFGS よりも 2.3 倍、C-SSF1.2 よりも 3.2 倍速く処理が終了した。

Table 4: CPU time for artificial data 2. (hr:min:sec)

$J$	C-BP	C-BFGS	C-SSF1.2	C-SSF1.3
1	00:38:58	00:01:03	00:00:10	00:00:10
2	01:11:01	00:01:46	00:02:16	00:02:18
3	01:12:26	00:03:38	00:05:27	00:05:33
4	01:29:03	00:04:47	00:03:00	00:03:07
5	01:39:42	00:06:10	00:03:17	00:03:25
6	01:55:47	00:07:22	00:08:27	00:07:08
7	02:11:15	00:09:22	00:09:16	00:06:26
8	02:22:59	00:11:08	00:14:34	00:07:46
9	02:33:36	00:13:54	00:22:46	00:06:55
10	02:54:17	00:15:51	00:13:31	00:06:27
11	03:04:18	00:18:23	00:30:37	00:07:39
12	03:20:16	00:19:35	00:24:39	00:07:27
13	03:49:26	00:22:03	00:38:24	00:09:32
14	04:00:40	00:26:08	00:24:32	00:06:28
15	04:12:06	00:25:33	01:04:22	00:06:42
16	04:33:26	00:28:11	00:31:31	00:07:02
total	41:09:15	03:34:55	04:56:48	01:34:04

## 5 まとめ

本稿では、特異領域上の Hesse 行列の固有値を基に探索の優先順位を決定し、探索数に上限を設けて一層の探索枝刈りを進めた C-SSF1.3 を提案した。C-SSF1.3 は Hesse 行列の負の固有値が小さい順に探索することにより、解品質を劣化させることなく高速化することができた。C-SSF1.2 と比べると人工問題 1 では 1.2 倍、人工問題 2 では 3.2 倍早く、初期重みをランダムに設定する C-BFGS と比べると人工問題 1 では 1.1 倍、人工問題 2 では 2.3 倍早く処理が終了した。C-SSF1.3 は、隠れユニットが非常に小さいとき以外は初期重みをランダムに設定する C-BFGS と同様 100 回探索したが、C-SSF1.3 の方が速く処理が終了した。これは以前の探索経路と合流した場合は探索を枝刈りすることと、加えて C-SSF の探索では隠れユニットが一つ少ない最適解から形成した特異領域上が初期点であるため、解に収束する時間が初期点をランダムに設定して探索する C-BFGS よりも速い傾向があるためと考えられる。

今後の課題としては多様なデータを用いて提案法の性能を評価することが挙げられる。

## 謝辞

本研究は JSPS 科研費 25330294, 26-7159 および中部大学特別研究費 26IS19A の助成を受けて行った。

## 参考文献

- 1) S. Amari: Natural gradient works efficiently in learning, *Neural Comput.*, **10**(2), 251/276 (1998)
- 2) S. Amari, H. Park, and K. Fukumizu: Adaptive method of realizing natural gradient learning for multilayer perceptrons, *Neural Comput.*, **12**(6), 1399/1409 (2000)
- 3) M.S. Kim and C.C. Guest: Modification of backpropagation networks for complex-valued signal processing in frequency domain, *Proc. IJCNN*, **3**, 27/31 (1990)
- 4) H. Leung and S. Haykin: The complex backpropagation algorithm, *IEEE Trans. Signal Process.*, **39**(9), 2101/2104 (1991)
- 5) D.G. Luenberger: Linear and nonlinear programming, Addison-Wesley Publishing Company, Reading, Massachusetts (1984)

- 6) 新田徹, 古谷立美: 複素バックプロパゲーション学習, *情報処理学会論文誌*, **32**(10), 1319/1329 (1991)
- 7) T. Nitta and M. Tanaka: Current status of research on neural networks with high-dimensional parameters, *Circulars of the Electrotechnical Laboratory*, 228, (1999)
- 8) T. Nitta: Local minima in hierarchical structures of complex-valued neural networks, *Neural Networks*, **43**, 1/7 (2013)
- 9) S. Satoh, and R. Nakano: Complex-valued multilayer perceptron search utilizing singular regions of complex-valued parameter space, *Proc. ICANN*, 315/322 (2014)
- 10) 佐藤聖也, 中野良平: 探索枝刈りによる複素多層パーセプトロン探索の高速化, 第 5 回コンピューターショナル・インテリジェンス研究会, 91/96 (2014)
- 11) 佐藤聖也, 中野良平: 複素特異階段追跡法の解品質の改善, 計測自動制御学会 システム・情報部門 学術講演会, 820/824 (2014)
- 12) 佐藤聖也, 中野良平: 特異階段追跡法の一層の高速化と解品質の改善, ニューロコンピューティング研究会, 289/294 (2015)
- 13) 鈴木真矢, 中野良平: 複素 BFGS 法を用いた複素ニューラルネットワークの学習法, *信学論 (D)*, **J96-D**(3), 423/431 (2013)
- 14) S. Watanabe: Algebraic geometry and statistical learning theory, Cambridge University Press, Cambridge, (2009)
- 15) S. Watanabe: A widely applicable Bayesian information criterion, *Journal of Machine Learning Research*, **14**, 867/897 (2013)

# Restricted Boltzmann Machinesを用いた免疫学的記憶細胞を用いたクローン選択アルゴリズムの提案

○鎌田 真 (広島市立大学大学院情報科学研究科知能情報科学系)  
市村 匠 (県立広島大学経営情報学部経営情報学科)

## A proposal of Clonal Selection Algorithm with Immunological Memory by using Restricted Boltzmann Machines

\*S. Kamada (Dept. of Intelligent Systems, Graduate School of Information Sciences, Hiroshima City University )

T. Ichimura (Faculty of Management and Information Systems, Prefectural University of Hiroshima)

**Abstract**— Recently, many machine learning methods with high classification capability such as Deep Learning are developed. Our research aims the analysis of the tourist subject data collected from the Mobile Phone based Participatory Sensing (MPPS) system. Each record consists of image files with GPS, geographic location name, user's numerical evaluation, and comments written in natural language at sightseeing spots where a user really visits. In our previous research, the famous landmarks in sightseeing spot can be detected by Clonal Selection Algorithm with Immunological Memory Cell (CSAIM). However, some landmarks could not be detected correctly because there are not enough amount of information for the feature extraction. In order to improve the weakness, we propose the generation method of immunological memory by Restricted Boltzmann Machines. To verify the effectiveness of the method, some experiments for classification of the subjective data are executed by using machine learning tools for Deep Learning.

**Key Words:** Image Analysis, Clonal Selection Algorithm, Immunological Memory Cells, Restricted Boltzmann Machines, Deep Learning, Smartphone based Participatory Sensing System, Knowledge Discovery

## 1 はじめに

近年、情報技術の進歩に伴い、ビックデータ分析にみられるように、多種多様なデータベースの収集と分析が行われている。Deep Learning と呼ばれる精度の高い機械学習手法が提案されたことにより、分析の対象は、離散値や連続値のような数値データや自然言語だけにとどまらず、画像データにまで広がっている。

Deep Learning は、隠れ層を多層にした階層型ニューラルネットワーク (NN) の構造を持ち、入力データの特徴を表す抽象概念を階層的に学習できる機械学習手法である<sup>1)</sup>。従来の階層型 NN では、多層にすると訓練事例に対して過学習が生じる、下位層において重みが伝搬されにくいなどの問題があったが、Deep Learning では、事前学習を行うことでこの問題を解決した。事前学習には、AutoEncoder<sup>2)</sup> や Restricted Boltzmann Machines(RBM)<sup>3)</sup> などの教師なし学習が使われ、入力データをうまく表現できる確率分布を学習している。特に、RBM は生成モデルで統計的な手法であるため、AutoEncoder よりも高い分類精度を持つ手法として知られている。

画像データの収集方法として、モバイルフォンベースユーザ参加型センシング (Moilephone Based Participatory Sensing; MPPS)<sup>4)</sup> システムが提案されており、また、収集されたデータの分析手法が研究されている。我々は、スマートフォンを用いて広島県の観光情報を収集する Android アプリ (ひろしま観光マップ<sup>5)</sup>) を開発している。このアプリでは、GPS による位置情報、5 段階評価値、短いテキスト文、写真で構成された旅行者の主観的情報を収集することができる。このような主観的で多次元的なデータには曖昧性が多く含まれ

るため、分析には厳密な解を求める統計的な手法や機械学習による手法よりも、人間の持つ曖昧性を取り入れたソフトコンピューティングによる手法が有効であると考えられる。そのため、我々の研究では、ソフトコンピューティングの手法で教師なし学習であるインタラクティブ階層成長型自己組織化マップ (Interactive Growing Hierarchical SOM; Interactive GHSOM)<sup>6)</sup> を用いて、収集された約 800 件の情報について、写真を除く、位置情報、評価値、コメント文を分類してきた。さらに、C4.5<sup>7)</sup> を用いて、インタラクティブ GHSOM の分類結果から IF-THEN ルール形式の知識を獲得した<sup>8)</sup>。獲得した知識をもとに、フィルタリングルールを作成し、観光にとって魅力的な情報や新規性のある情報のみを Twitter や Facebook の SNS に発信するシステムを開発している<sup>9)</sup>。

以前の研究では、撮影された写真が観光地の代表的なランドマークであるかどうかを判別するために、免疫学的記憶細胞を用いたクローン選択アルゴリズム (Clonal Selection Algorithm with Immunological Memory; CSAIM)<sup>10), 11)</sup> を用いた。また、データ分析における情報量を削減するための特徴点抽出方法を提案した<sup>12), 13)</sup>。ところが、分析の結果、一部の写真に対しては、訓練データは識別できるものの、テストデータに対しては識別できないものがあった。これは、特徴抽出のために画像の情報量を削減したため、必要な情報が欠如してしまったことが原因であると我々は考えている。そこで、本論文では、画像を事前に処理せず、RBM を用いて記憶細胞を生成する CSAIM を提案する。提案手法を用いて、ひろしま観光マップによって収集された 3 種類のランドマークの画像に対する識別実験を行った結果、従来の手法よりも優れた結果が

得られたので、ここに報告する。

本論文の構成は次のとおりである。2節では本研究で提案した人工免疫システムである、CSAIMについて述べる。3節ではRBMの基本的な仕組みについて述べる。4節では本研究で提案する、RBMを用いて記憶細胞を生成するCSAIMについて述べる。5節で提案手法の性能評価を行った後、本論文をまとめる。

## 2 免疫学的記憶細胞を用いたクローン選択アルゴリズム

人工免疫システム (Artificial Immune System; AIS) は、多くの生物に備わっている免疫系を応用したシステムであり、パターン認識や最適化などの様々な分野に適用されている<sup>14)</sup>。人工免疫システムには、Burnetが提唱したクローン選択理論 (Clonal Selection Theory)<sup>15)</sup> をもとにしたクローン選択アルゴリズムがある。抗体の増殖過程では主に体細胞超変異 (Somatic Hypermutation; HM) とレセプター編集 (Receptor Editing; RE) の2つの手法があるが、GaoはRECSA (Receptor Editing Clonal Selection Algorithm)<sup>16)</sup> と呼ばれる、REを取り入れたクローン選択アルゴリズムを提案した。

しかし、GaoのRECSAでは、免疫系本来の機能である免疫学的記憶については実装されていない。そこで、本研究ではRECSAによって生成された親和性が高い抗体を記憶細胞に保存する手法として、免疫学的記憶細胞を取り入れたクローン選択アルゴリズム (Clonal Selection Algorithm with Immunological Memory; CSAIM) を提案した<sup>10)</sup>。特定の訓練事例に対して特化した抗体が記憶細胞に保存され、また正答できない訓練事例が表れた場合、それに適応する新たな抗体が生成される。提案手法をあいまい性を含むデータである心疾患データベースに適用した結果、優れた結果を示した<sup>11)</sup>。

### 2.1 クローン選択アルゴリズム<sup>16)</sup>

RECSAにおけるクローン選択アルゴリズムを以下 (Fig. 1) に示す。

**Step 1)**  $m$  個の抗体 ( $Ab_1, Ab_2, \dots, Ab_m$ ) を作成する。

**Step 2)** 作成した  $m$  個の抗体の親和性 ( $D(Ab_1), D(Ab_2), \dots, D(Ab_m)$ ) を計算する。  $D()$  は抗体の親和性を計算する関数である。

**Step 3)**  $m$  個の抗体の中から、親和性の高い  $n$  個の抗体を選択し、これらをエリート抗体とする。

**Step 4)**  $n$  個のエリート抗体を親和性の高い順に並び替え、各エリート抗体を親とするエリートプールを作成する。

**Step 5)** 各エリートプール  $i$  ( $1 \leq i \leq n$ ) で、親抗体のクローンを  $P_i$  個作成する。

$$P_i = \text{round} \left( \frac{(n-i)}{n} \times Q \right) \quad (1)$$

ここで、 $\text{round}()$  は、小数点第1位を四捨五入し、整数値にする関数である。  $Q$  は定

数である。これにより、全てのエリートプールで合計  $\sum P_i$  個の抗体 ( $(Ab_{1,1}, Ab_{1,2}, \dots, Ab_{1,p_1}), \dots, (Ab_{n,1}, Ab_{n,2}, \dots, Ab_{n,p_n})$ ) が作成される。

**Step 6)** 作成したクローンに対して、HM又はREを適用する。  $P_{hm}$  は各クローン抗体がHMを適用する確率、  $P_{re}$  はREを適用する確率である。

$$P_{hm} = a/D() \quad (2)$$

$$P_{re} = (D() - a)/D() \quad (3)$$

ここで、  $D()$  は親抗体の親和性で、  $a$  はパラメータである。

**Step 7)** 各エリートプール  $i$  で、もっとも親和性の高いクローン  $D(B_i)$  を選択する。

$$D(B_i) = \max(D(Ab_{i,1}), \dots, D(Ab_{i,p_i})) \quad (4)$$

**Step 8)** 確率  $P(Ab_i \rightarrow B_i)$  で、親抗体をクローンで置き換える。ここで、  $D(Ab_i) < D(B_i)$  であれば  $P = 1$ 、  $D(Ab_i) \geq D(B_i)$  であれば  $P = 0$ 、  $D(Ab_i) \geq D(B_i), i \neq 1$  であれば  $P = \exp(\frac{D(B_i) - D(Ab_i)}{\alpha})$  である。  $\alpha$  は正の値を持つ定数であり、値が大きいほど親抗体をクローンで置き換える確率  $P$  が高くなる。

**Step 9)**  $t$  世代に1回、  $c (= \beta \times n)$  個の新しい抗体をランダムに作成し、その中で  $m$  個の抗体よりも親和性が高い抗体があれば、置き換える。

**Step 10)** ここで、現在の世代が、最大世代数  $G_{max}$  に達すれば、プロセスを終了する。そうでなければ**Step 3)**に戻る。

Fig. 1: The learning algorithm in RECSA

### 2.2 抗体の構造

Gaoによって提案されたRECSAは、TSPのような組み合わせ最適化問題に適用されている。本研究では、これを分類問題に適用するために、抗体をFig. 2に示すように、入力に対する重み  $w_i$  ( $i = 1, 2, \dots, k$ ) と、出力に対するしきい値  $\theta$  で定義した。これをパラトープ  $P = (w_1, \dots, w_k, \theta)$  とする。

#### 2.2.1 Somatic Hypermutation(HM)とReceptor Editing(RE)

HMは、パラトープ  $P = (w_1, \dots, w_k, \theta)$  から  $w_i$  または  $\theta$  をランダムに選択し、式(5)により更新する。ここで、  $\Delta w$ 、  $\Delta \theta$  は、それぞれ  $-\gamma_w \leq \Delta w \leq \gamma_w$ 、  $-\gamma_\theta \leq \Delta \theta \leq \gamma_\theta$  を満たす。

$$w_i = w_i + \Delta w, \theta = \theta + \Delta \theta \quad (5)$$

REは、パラトープ  $P = (w_1, \dots, w_k, \theta)$  に対して、Fig. 3のようにランダムに選択された2点間の並びを入れ替える操作を行う。






Fig. 2: The antibody structure




Fig. 3: RE for  $w_2, w_{k-1}$

### 2.2.2 親和性

各抗体の親和性は、以下の式により計算される。ここで、 $x^p$  は各訓練事例を表し、 $x_{Target}^p$  は各訓練事例の教師信号であり、 $\{0, 1\}$  をとる。  $tr\_num$  は全ての訓練事例の数である。  $E_{sim}$  は、パラトープの出力に関するパラメタである。

$$f(x^p) = \begin{cases} 1 & \text{if } \sum_{i=1}^k |w_i x_i^p - \theta| \leq E_{sim} \\ 0 & \text{otherwise} \end{cases} \quad (6)$$

$$g(x^p) = \begin{cases} 1 & \text{if } f(x^p) = x_{Target}^p \\ 0 & \text{otherwise} \end{cases} \quad (7)$$

$$Affinity = \sum_{p=1}^{tr\_num} g(x^p) \quad (8)$$

### 2.3 免疫学的記憶細胞

Fig. 4 は CSAIM におけるシステムのフローチャートであり、①から⑧は RECSA のアルゴリズム (Fig. 1) と同じ手順である。 Fig. 5 は生成された抗体のクラスタリング結果から記憶細胞を生成する過程を示している。 CSAIM では、クローン選択アルゴリズムにより抗体を生成した後、Fig. 5 に示すように、生成された抗体をしきい値である  $\theta$  を基準に  $IM (1 \leq q \leq IM)$  個のクラスタに分類する。次に、各クラスタの中心の抗体が記憶細胞に保存される。ここで、記憶される抗体は、類似性の高い特定の訓練事例に対して、学習が行われる。学習はニューラルネットワークのパーセプトロンに基づいた学習である。記憶される抗体は、しきい値である  $\theta_q$  を持ち、 $\theta_q$  に近づくように、抗体の重みが学習される。これにより、特定の訓練事例に対する類似性が高くなる。同じニューラルネットワークの手法でも、バックプロパゲーション (BP) のような非線形分離が可能な手法を用いない理由として、過学習により、 $\theta_q$  により分割された領域を越えたデータ空間全体としての大域解に収束することを避けることを目的としている。また、学習後に誤答する訓練事例が多い場合は、誤答する訓練事例に適応するために、新しく抗体が HM, RE により生成される。その結果、誤答する訓練事例が減少すれば、生成した抗体が記憶細胞に保存される。

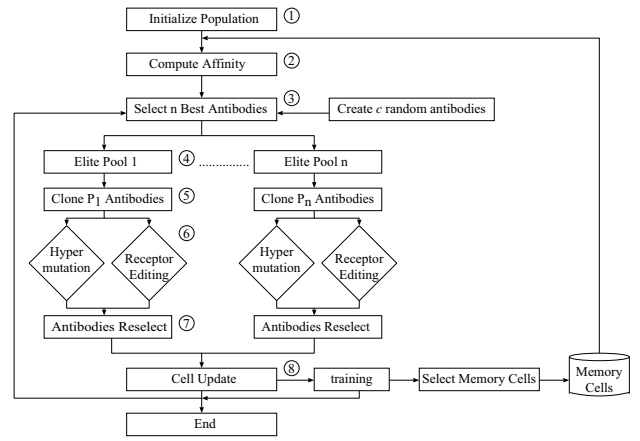


Fig. 4: A flow of CSAIM model




Fig. 5: A generation method of new memory cell

類似性の高い訓練事例は、次のように求められる。訓練事例を  $\vec{d} = (d_1, \dots, d_i, \dots, d_k)$ 、抗体を  $\vec{h} = (h_1, \dots, h_i, \dots, h_k)$  とした時、 $\vec{d}$  と  $\vec{h}$  のユークリッド距離が、予め定められた距離  $\mu_\theta$  以下であれば、一致すると判定するアルゴリズムである。ここで、 $\vec{d}$  の要素  $d'_i$  は式 (9) により求められる。

$$d'_i = d_i \times \frac{h_j}{d_j} (d_i \neq 0 \wedge h_i \neq 0) \quad (9)$$

類似性の高い訓練事例に対して、Fig. 6 に示すようにパーセプトロンによる学習が行われる。

**Step 1)** クラスタリングされた各記憶細胞に対して、式 (10) を用いて特定の訓練事例に対する出力を計算する。

$$O = \sum_{i=1}^k w_i x_i \quad (10)$$

ここで、 $w_i$  は抗体の重みであり、 $x_i$  は訓練事例の要素である。

**Step 2)** 式 (11) により誤差を計算する。

$$E = \frac{1}{2} \delta^2 = \frac{1}{2} (\theta_q - O)^2 \quad (11)$$

ここで、 $q (1 \leq q \leq IM)$  は  $IM$  個にクラスタ




Fig. 7: The structure of RBM

リングされた記憶細胞のインデックスを示す。

**Step 3)** 重みを更新する。

$$w_i = w_i + \eta \delta x_i \quad (12)$$

ここで、 $\eta$  は  $[0.1, 1.0]$  の実数値である。

**Step 4)** 全ての訓練事例に対して、二乗和誤差が期待値以下になるか、訓練回数が予め定められた回数を超えるまで、**Step 1)** から **3)** までを繰り返し実行する。

Fig. 6: The learning algorithm by perceptron in CSAIM

### 3 Restricted Boltzmann Machines

この節では、Restricted Boltzmann Machines (RBM) について説明する。RBM<sup>3)</sup> は、可視層と隠れ層の2層から構成され、確率分布に基づくネットワーク構造を持つモデルである。学習によって入力データをうまく表現できるパラメータを獲得することができる。通常の Boltzmann Machine<sup>17)</sup> では、全ての層のユニット間で相互結合があるが、RBM では、Fig. 7 のように、各層のユニット間の結合を制限することで、計算量を削減するだけでなく、隠れ層の各ユニットごとに独立した確率分布を学習することができる。近年、RBM は Deep Learning における事前学習の1つの手法として使われ、特徴抽出の分野で注目されている。特に、RBM が AutoEncoder<sup>2)</sup> のような決定論的モデルとは異なり、エネルギー関数を用いる確率的なモデルであるため、学習したモデルの最適性を統計的な枠組みを用いて議論できる。

$v_i$  を可視層における  $i$  番目のユニット、 $h_j$  を隠れ層における  $j$  番目のユニットとしたとき、 $\mathbf{v}$  と  $\mathbf{h}$  に対するエネルギー関数  $E(\mathbf{v}, \mathbf{h})$  および確率分布  $p(\mathbf{v}, \mathbf{h})$  は、それぞれ式 (13)、式 (14) のように定義される。ここで、 $\mathbf{v} = \{v_0, \dots, v_i, \dots, v_n\}$  と  $\mathbf{h} = \{h_0, \dots, h_j, \dots, h_m\}$  はそれぞれ可視層と隠れ層のベクトルを指す。

$$E(\mathbf{v}, \mathbf{h}) = \sum_i b_i v_i - \sum_j c_j h_j - \sum_i \sum_j v_i W_{ij} h_j \quad (13)$$

$$p(\mathbf{v}, \mathbf{h}) = \frac{1}{Z} \exp(-E(\mathbf{v}, \mathbf{h})) \quad (14)$$

$$Z = \sum_{\mathbf{v}} \sum_{\mathbf{h}} \exp(-E(\mathbf{v}, \mathbf{h})) \quad (15)$$

ここで、 $b_i$  は  $v_i$  に対するバイアス、 $c_j$  は  $h_j$  に対するバイアスであり、 $W_{ij}$  は  $v_i$  と  $h_j$  間の重みである。ま

た、 $Z$  は分配関数 (partition function) であり、 $\mathbf{v}$  と  $\mathbf{h}$  の全ての可能な組み合わせを示す。

RBM におけるパラメータは、 $\mathbf{v}$  の確率分布  $p(\mathbf{v}) = \sum_{\mathbf{h}} p(\mathbf{v}, \mathbf{h})$  の最尤推定により求められる。最尤推定は与えられた入力データから、尤もらしい確率分布を学習する方法であり、この時、隠れ層のユニットには相互結合がないため、各ユニットごとに独立した確率分布を得ることができる。しかしながら、最尤推定における計算量は、モデルの大きさに応じて指数関数的に増加してしまい、現実的に計算困難である。そこで、マルコフ連鎖モンテカルロ法 (MCMC) に基づいたサンプリング方法として Contrastive Divergence (CD) 法<sup>18)</sup> が提案され、現実的に計算可能となった。CD 法における最適なサンプリング回数については議論がされているが、サンプリング数が1回 (CD-1) でも十分な性能を示すことが知られている<sup>19)</sup>。Fig. 8 は、サンプリング回数が1回の CD 法 (CD-1) のアルゴリズムを示している。

**Step 1)** すべての隠れユニットに対して、可視ベクトル  $\mathbf{v}$  を与えた際の確率  $h_j$  を計算する。

$$p(h_j = 1 | \mathbf{v}) = \text{sigm}(c_j + \sum_i W_{ij} v_i) \quad (16)$$

ここで、 $\text{sigm}()$  はシグモイド関数のように  $[0, 1]$  を出力する関数である。

**Step 2)** すべての可視ユニットに対して、**Step 1)** で計算した隠れベクトル  $\mathbf{h}$  を与えた際の確率  $v'_i$  を計算する。

$$p(v'_i = 1 | \mathbf{h}) = \text{sigm}(b_i + \sum_j W_{ij} h_j) \quad (17)$$

**Step 3)** すべての隠れユニットに対して、**Step 2)** で計算した可視ベクトル  $\mathbf{v}'$  を与えた際の確率  $h'_j$  を計算する。

$$p(h'_j = 1 | \mathbf{v}') = \text{sigm}(c_j + \sum_i W_{ij} v'_i) \quad (18)$$

**Step 4)** バイアスと重みを次のように更新する。

$$\begin{aligned} W_{ij} &= W_{ij} + \eta(v_i h_j - v'_i h'_j) \\ b_i &= b_i + \eta(v_i - v'_i) \\ c_j &= c_j + \eta(h_j - h'_j) \end{aligned} \quad (19)$$

ここで、 $\eta$  は学習率である。

**Step 5)** 全ての可視ベクトルに対して **Step 1)** から **4)** までを繰り返す。

Fig. 8: The learning algorithm in RBM by CD-1

## 4 Restricted Boltzmann Machines を用いた CSAIM の提案

2節で述べたように、CSAIMはパーセプトロンによる学習により、単純なパターンを識別可能な記憶細胞として生成することができる。記憶細胞は、識別できないパターンが出現される度に新しく生成され、蓄積されるが、画像のような膨大で複雑なデータを学習する場合、莫大な記憶細胞が必要になり、それだけ多くのメモリが必要になる。以前の研究では、データ分析における次元数を削減するため、特徴点抽出方法を提案した<sup>12, 13)</sup>。しかしながら、Fig. 10(a)の宮島の鳥居のように、特徴が決まっている画像に対しては識別できるが、Fig. 10(c)の原爆ドームのように、特徴をとらえることが難しく、他の建物等の特徴と違いが見られない画像に対しては識別できなかった。これは、提案した特徴点抽出方法により画像データの情報が削減され、本来必要な情報まで失ってしまったためである。この場合、残ったデータに対して過学習が生じるように学習が行われる。その結果、作成された記憶細胞は、訓練データの特徴には一致するが、テストデータのような未知の特徴を持つパターンに対しては一致しなくなる。実際の生態系の免疫反応でも、少しでも突然変異が起きた抗原は既存の抗体に反応しなくなる場合があることから、本研究で提案した手法は免疫細胞における記憶を忠実に再現していると考えられる。本論文では、事前に画像の情報を削減することなく、画像の特徴を学習し、未知のパターンに対しても類似性が高い記憶細胞を作成するために、パーセプトロンの代わりに、3節で述べたRBMを用いて記憶細胞を生成する手法を提案する。

本論文では、RBMを実装するために、Deep Learningのオープンソースのライブラリとして開発されているPylearn2<sup>20)</sup>を用いた。Pylearn2はtheano<sup>21)</sup>と呼ばれるpythonの数値計算ライブラリがベースになっているため、CUDA<sup>22)</sup>などを用いたGPGPUの計算が可能である。Pylearn2での学習は、“YAML”と呼ばれるXML形式のファイルに学習方法や入力データなどを定義し、これをプログラムに読み込ませることで実行できる。

提案手法では、RBMはDeep Learningにおける事前学習として使われる。訓練画像のピクセル値をRBMの可視層に与えた際、Fig. 8で示したCD-1法により、可視層と隠れ層の間の重みおよびバイアスが学習される。その後、分類問題に適用するために、Deep Belief Networks(DBN)<sup>23)</sup>で行われているように、クラス識別のために出力層を加え、隠れ層と出力層間で教師あり学習を行う(Deep Learningにおけるfine-tuning)。ここでは、パーセプトロンによる学習を行う。パーセプトロンは従来のCSAIMでも使われているが、提案手法ではRBMにより学習された隠れ層を入力として学習を行うため、従来手法よりも入力パターンに対して冗長性をもった応答を行うことができると考えられる。また、従来のCSAIMでは多クラスの分類問題を行う場合、式(6)、式(7)によりそれぞれのクラスに対して一致するかどうか計算していた。提案手法ではFig. 9のようなネットワーク構造を持ち、ソフトマックス関数を用いて、多クラスの訓練事例を同時に分類




Fig. 9: The structure of DBN

できるようにした。ここで、分類したいクラスの数を $l(1 \leq k \leq l)$ としたとき、出力層は $l$ 個の出力ユニットを持ち(クラスの数と出力ユニットの数は同じ)、 $k$ 番目の出力ユニットはクラス $k$ を識別するために使われる。ここで、 $\mathbf{z} = \{z_0, \dots, z_k, \dots, z_l\}$ は出力層のベクトルとする。式(20)によるソフトマックス関数により、各出力ユニット $z_k$ がクラス $k$ に属する確率 $y_k$ が求められる。

$$y_k = \frac{\exp(z_k)}{\sum_k^l \exp(z_k)} \quad (20)$$

パーセプトロンのfine-tuningでは、各訓練事例に対して、その事例が属しているクラスを教師信号として与え、対応する出力ユニットの出力を最大化するようにネットワークの重みとバイアスが学習される。教師信号を持たないテスト事例に対する識別は、可視層に入力を与えた際、出力層で最も大きな値を出力するユニットに対応するクラスを求めることで行う。学習後は通常のCSAIMと同様に、Fig. 9に示すネットワーク構造が記憶細胞として保存される。

## 5 実験

### 5.1 データセット

実験で使用する画像として、Androidスマートフォンアプリケーションである、ひろしま観光マップ<sup>5)</sup>によって収集した画像を用いた。本論文では、収集した画像を用いて2種類のデータセットを作成した。1つが、広島県の観光地として有名な宮島の「鳥居」(Fig. 10(a))と「原爆ドーム」(Fig. 10(c))の2クラスの画像を用いた“データセットA”で、各クラス6枚の訓練画像と2枚のテスト画像を含む(合計16枚((6+2)×2))。もう1つが“データセットB”であり、データセットAに呉の大和ミュージアムにおける「戦艦大和」の模型の画像(Fig. 10(e))を加えた3クラスの画像を持つデータセットであり、より複雑なデータセットである。各クラスの訓練画像とテスト画像の数はデータセットAと同じである(合計24枚((6+2)×3))。全ての画像は48×48ピクセルでグレースケースである。

### 5.2 実験結果

従来のCSAIMと本論文で提案するRBMを用いたCSAIMを使って、前節で述べたひろしま観光マップの2つの画像のデータセットを分析した。CSAIMのパラメータは、 $G_{max} = 100$ ,  $m = 150$ ,  $n = 100$ ,  $Q = 50$ ,  $HM : RE = 1 : 1$ ,  $-1 \leq r_w \leq 1$ ,  $-1 \leq r_\theta \leq 1$ ,

Table 1: Correct Ratio for 2 classes

	正答率	正答率(鳥居)	正答率(原爆ドーム)
CSAIM	100.0%(16/16)	100.0%(8/8)	100.0%(8/8)
(test)	75.0%(3/4)	100.0%(2/2)	50.0%(1/2)
CSAIM with RBM	100.0%(16/16)	100.0%(8/8)	100.0%(8/8)
(test)	100.0%(4/4)	100.0%(2/2)	100.0%(2/2)

Table 2: Correct Ratio for 3 classes

	正答率	正答率(鳥居)	正答率(原爆ドーム)	正答率(戦艦大和)
CSAIM	33.3%(8/24)	100.0%(8/8)	0.0%(0/8)	0.0%(0/8)
(test)	33.3%(2/6)	100.0%(2/2)	0.0%(0/2)	0.0%(0/2)
CSAIM with RBM	83.3%(20/24)	100.0%(8/8)	100.0%(8/8)	50.0%(4/8)
(test)	83.3%(5/6)	100.0%(2/2)	100.0%(2/2)	50.0%(1/2)



(a) Torii in Miyajima 1 (b) Torii in Miyajima 2



(c) Atomic Bomb Dome 1 (d) Atomic Bomb Dome 2



(e) Battleship Yamato 1 (f) Battleship Yamato 2

Fig. 10: An example of data set

$E_{sim} = 0.05$ ,  $t = 10$ ,  $c = 10$ ,  $\eta = 0.1$ ,  $\mu_{\theta} = 0.3$ ,  $t_{IM} = 50$ ,  $E_{min} = 0.001$ ,  $c_{max}^{memory} = \frac{1}{2}n$ ,  $IM = 10$  とした。また, Pylearn2 における RBM のパラメタは, model = Gaussian Binary RBM, number of visible units = 2304, number of hidden units = 80, training\_algorithms = Stochastic Gradient Descent (SGD), batch\_size = 6 とした。実験には次のスペックを持つ PC を用いた。CPU = Intel(R) Core(TM) i7-2600 CPU @ 3.40GHz, GPU = GeForce GTX 750 Ti, Memory = 16GB, OS = Ubuntu 14.04.2 LTS x86\_64.

Table. 1 は, 「鳥居」, 「原爆ドーム」の 2 クラスの画像(データセット A) に対して分類した結果, 得られた正答率を示している。従来の CSAIM では, 鳥居の画像については訓練事例だけでなくテスト事例にも正答できたが, 原爆ドームの画像については, テスト事例に対する正答率が低くなった。一方, 提案手法は, 訓




Fig. 11: Sum of squared error of perceptron

練事例だけでなく, テスト事例に対しても全て正答することができた。Fig. 11 はパーセプトロンによる学習で得られた二乗和誤差の曲線, Fig. 12 は RBM による学習で得られたエネルギー関数の値を示している。どちらの曲線も小さな値に収束しているにもかかわらず, 従来の CSAIM ではテスト事例に対する正答率が低かったことから, 訓練事例のパターンに対して過学習が起きており, テスト事例のパターンに対する一致度が減少してしまったことが原因であると考えられる。また, 学習中に生成された記憶細胞については, 保存できる記憶細胞の最大数に達するまで加算的に生成された。

Table. 2 は, 「鳥居」, 「原爆ドーム」, 「戦艦大和」の 3 クラスの画像(データセット B) に対して分類した結果, 得られた正答率を示している。従来の手法では, データセット A の結果と比べて正答率が大きく減少したが, 提案手法ではそれほど大きな変化もなく, 有効性を示すことができた。ただし, 「戦艦大和」の画像については, 正答率が多少低くなった。この画像の中には, Fig. 10(e), Fig. 10(f) のように, 様々な角度から撮影された画像が含まれており, 該当する特徴以外の情報も 1 つの特徴として学習してしまい, 分類精度が低くなっていた。手法の改良を行うとともに, 教師データを増して検証する必要がある。

## 6 おわりに

MPPS アプリケーションとして開発したひろしま観光マップを用いて, 収集される主観的かつ多次元データ




Fig. 12: Energy Function of RBM

から広島県観光に関する知識獲得手法を提案した。従来の研究では、インタラクティブ GHSOM と C4.5 を用いて、数値データ、自然言語に対する知識獲得手法の提案を行った。一方、画像に対しては、CSAIM を用いてランドマークの画像に対する識別を行ったが、原爆ドームの画像のように、画像自体が複雑で、他の建物等との違いが少ない画像に対しては優れた結果が得られなかった。CSAIM では、記憶細胞の生成過程でパーセプトロンを使って学習しているが、画像データは次元数が多く、複雑であり、情報量を削減すると残ったパターンに対して過学習が生じた。そこで、本論文では、近年 Deep Learning における事前学習の 1 つとして注目されている、RBM を用いて記憶細胞を生成する手法を提案した。提案手法を 3 種類の画像に適用した結果、従来の手法よりも優れた識別結果を得ることができた。今後は、データ数を増やし、提案手法の性能を検証するとともに、RBM における隠れユニットの数について、訓練状況に応じて動的に変更できる手法を提案する。

## 謝辞

本研究は JSPS 科研費 25330366 の助成を受けたものである。

## 参考文献

- 1) Y.Bengio: *Learning Deep Architectures for AI*, Foundations and Trends in Machine Learning archive, Vol.2, No.1, 1/127 (2009)
- 2) Y.Bengio, P.Lamblin, D.Popovici and H.Larochelle: *Greedy Layer-Wise Training of Deep Networks*, in Advances in Neural Information Processing Systems 19 (NIPS '06), 153/60 (2007)
- 3) G.E.Hinton: *A Practical Guide to Training Restricted Boltzmann Machines*, Neural Networks: Tricks of the Trade, Lecture Notes in Computer Science, Vol.7700, 599/619 (2012)
- 4) N.D.Lane, E.Miluzzo, L.Hong, D.Peebles, T.Choudhury and A.T.Campbell: *A survey of mobile phone sensing*, IEEE Communications Magazine, Vol.48, No.9, 140/150 (2010)
- 5) ITProducts, ひろしま観光マップ: <https://play.google.com/store/apps/details?id=jp.itproducts.KankouMap>, [online] (2011)
- 6) T.Ichimura and S.Kamada: *A Generation Method of Filtering Rules of Twitter Via Smartphone Based Participatory Sensing System for Tourist by Interactive GHSOM and C4.5*, 2012 IEEE International Conference on Systems, Man, and Cybernetics (IEEE SMC 2012), 110/115 (2012)
- 7) J.R.Quinlan: *Improved use of continuous attributes in c4.5*, Journal of Artificial Intelligence Research, No.4, 77/90 (1996)
- 8) T.Ichimura, S.Kamada and K.Kato: *Knowledge Discovery of Tourist Subjective Data in Smartphone Based Participatory Sensing System by Interactive Growing Hierarchical SOM and C4.5*, Intl. J. Knowledge and Web Intelligence, Vol.3, No.2, 110/129 (2012)
- 9) 市村匠, 鎌田真: “スマートフォンベースユーザ参加型主観的情報システムからのソーシャルコミュニティへの情報発信方法について”, 2013 IEEE SMC Hiroshima Chapter Young Researchers Workshop, 53/54 (2013)
- 10) T.Ichimura and S.Kamada: *Clustering and Retrieval Method of Immunological Memory Cell in Clonal Selection Algorithm*, Proc. of The 6th International conference on Soft Computing and Intelligent Systems and The 13th International Symposium on Advanced Intelligent Systems(SCIS-ISIS 2012), 1351/1356 (2012)
- 11) T.Ichimura and S.Kamada: *A Classification Method of Coronary Heart Disease Databases by Clonal Selection Algorithm with Immunological Memory Cell*, Intl. J. Biomedical Soft Computing and Human Sciences, Vol.19, No.2, 7/18 (2014)
- 12) T.Ichimura and S.Kamada: *A Clonal Selection Algorithm with Levenshtein Distance based Image Similarity in Multidimensional Subjective Tourist Information and Discovery of Cryptic Spots by Interactive GHSOM*, Proc. of 2013 IEEE International Conference on Systems, Man, and Cybernetics (IEEE SMC 2013), 2085/2090 (2013)
- 13) 鎌田真, 市村匠: “スマートフォンによるユーザ参加型センシングシステムにおける観光写真の Levenshtein 距離を免疫システムによる分類手法”, 計測自動制御学会第 4 回コンピューターショナル・インテリジェンス研究会, 46/53 (2013)
- 14) L.N. de Castro and J.Timmis: *Artificial immune systems: A new computational Intelligence Approach*, Springer-Verlag (1996)
- 15) F.M.Burnet: *The Clonal Selection Theory of Acquired Immunity*, Cambridge, U.K.: Cambridge Univ. Press (1959)
- 16) S.Gao, H.Dai, G.Yang and Z.Tang: *A novel clonal selection algorithm and its application to traveling salesman problem*, IEICE Trans. Fundamentals, Vol.E90-A, 2318/2325 (2007)
- 17) D.H.Ackley, G.E.Hinton and T.J.Sejnowski: *A Learning Algorithm for Boltzmann Machines*, Cognitive Science, 9: 147/169. doi: 10.1207/s15516709cog0901-7 (1985)
- 18) G.E.Hinton: *Training products of experts by minimizing contrastive divergence*, Neural Computation, Vol.14, 1771/1800 (2002)
- 19) T.Tieleman: *Training restricted Boltzmann machines using approximations to the likelihood gradient*, Proc. of the 25th international conference on Machine learning, 1064/1071 (2008)
- 20) I.Goodfellow, David Warde-Farley, et.al.: *Pylearn2: a machine learning research library*, arXiv preprint arXiv:1308.4214 (2013)
- 21) F.Bastien, P.Lamblin, et.al: *Theano: new features and speed improvements*, NIPS 2012 deep learning workshop (2012)
- 22) NVIDIA, CUDA: <http://www.nvidia.co.jp/object/cuda-jp.html>, [online] (2007)
- 23) G.E.Hinton, S.Osindero and Y.Teh: *A fast learning algorithm for deep belief nets*, Neural Computation, Vol.18, No.7, 1527/1554 (2006)

# 乳房 X 線画像診断支援のための 木構造自己組織化マップによる自動特徴抽出の試み

長谷川奈保 ○本間経康 張暁勇 市地慶 小山内実 阿部誠 杉田典大 吉澤誠 (東北大学)

## Mammographic image feature extraction by tree-structured self-organizing map for computer aided diagnosis

N. Hasegawa, ○ N. Homma, X. Zhang, K. Ichji, M. Osanai, M. Abe, N. Sugita and M. Yoshizawa (Tohoku University)

**Abstract**— In breast cancer diagnosis using mammography, it is generally very difficult to find quantitative features to detect the cancer with a sufficient accuracy due to the variability of cancer signs. This paper proposes a new tree-structured self-organizing map (TS-SOM) model that can learn criteria to classify normal breast mammograms in an unsupervised manner. The normal mammograms with different features can be represented by the TS-SOM hierarchically. Given a mammogram, we can calculate the similarity between the mammogram and the hierarchical representation of such normal mammogram TS-SOM, and then determine whether the mammogram is normal or abnormal. Consequently this model has a potential to classify the mammograms into normal or abnormal categories without explicit design of complex diagnostic logic that may be based on fuzzy features of breast density, fibro-glandular shape, etc. The experimental results performed on a standard digital database for screening mammography showed that the proposed method achieved sensitivity of 82% with 20% false positive rate. This result suggested that the proposed method without explicit quantitative features design is effective to detect abnormal mammograms.

**Key Words:** Mammography, computer aided diagnosis (CAD), pattern recognition, and tree-structured self-organizing map (TS-SOM)

### 1 はじめに

乳がんは、日本人女性における部位別がん罹患数の一位を占めており<sup>1)</sup>、社会や家庭において中心的役割を担う 40 代前後から罹患数が急増する。これは、他部位のがんに比べて若年での発症が多いことを意味し、医学的観点だけでなく社会的にも有効な対策が必要とされており、早期発見、早期治療のための定期的な検診普及が進められてきた。現在の乳がん検診においては、従来の視触診に比べ早期のがんでも検出率が高いとされる乳房 X 線撮影による画像診断が広く認知され、受診者が増加している。しかし医師の診断負担が増加しているため、その負担軽減を目的として第 2 の意見を提示するコンピュータ支援診断システム (computer aided detection もしくは computer aided diagnosis: CAD) の開発が行われている<sup>2)</sup>。

乳がんの主な画像所見は微小石灰化、腫瘍および乳腺構築の乱れに大別される。このうち、画像的特徴が定量的に比較的明確な微小石灰化に対しては検出性能の高い CAD システムが開発され臨床応用が開始されているが、残りの所見に対しては十分な検出性能をもつ CAD システムは提案されていない<sup>3)4)</sup>。これは、後者の各所見に対応する病変陰影検出の基になる定量的画像特徴量を明確に定義できておらず、したがってそれらを的確に分類できていないことも要因の一つである。このような問題に対し、我々は多層自己組織化マップにより自動的に木構造的な分類構造を自動的に獲得するモデルを提案し、実際の乳房 X 線画像を用いて正常例に対する分類性能を評価した<sup>5)</sup>。しかし、実際の異常例に対する分類性能は評価しておらず、その有効性についての考察が不十分であった。

そこで本稿では、提案モデルを木構造自己組織化マップ (tree-structured self-organizing map: TS-SOM) と

呼び、実際の乳房 X 線撮影画像を用いて異常例の検出実験を行い、その性能の基礎的検討を行ったので報告する。

### 2 提案手法<sup>5)</sup>

#### 2.1 木構造自己組織化マップ (TS-SOM) による入力画像の分類

TS-SOM による入力画像の分類は、1) 入力画像の位相情報を保持しネットワークパラメータを学習する学習フェーズ、2) 保持した情報を基に入力画像を分類する画像分類フェーズ、3) そして分類情報を詳細化するために本手法が提案する木構造化フェーズの 3 フェーズで行われる。

はじめに 1) 学習フェーズにおける SOM の学習アルゴリズムを説明する。TS-SOM における基本構造を Fig. 1 に示す。入力層と SOM 競合層により構成される入力層のノード数は扱う入力次元に、次層の競合ノード数は多くの場合 1 次元または 2 次元状で実験的に決定される。入力はすべての競合ノードと重み結合しているため、各競合ノードは入力と同次元の結合重みベクトルを保持する。本手法では、表現力の高さと視覚的なわかりやすさを考え競合層は 2 次元格子状を採用した。また計算時間を考慮し 2 次元格子のサイズは  $7 \times 7$  と統一した。予備実験における学習収束状況を考慮し学習時パラメータは最大学習回数を 10000 回、学習率  $\alpha$  の初期値を  $\alpha = 0.1$ 、近傍領域関数における半径の初期値を 2 とした。以下に結合重み係数の更新を行う SOM 学習アルゴリズムの手順を示す。

**STEP 1 初期化:** 学習回数  $t = 0$  において競合層座標  $(i, j)$  における競合ノードが保持する結合重み  $w_{ij}(i = 1, 2, \dots, s, j = 1, 2, \dots, t)$  を乱数により

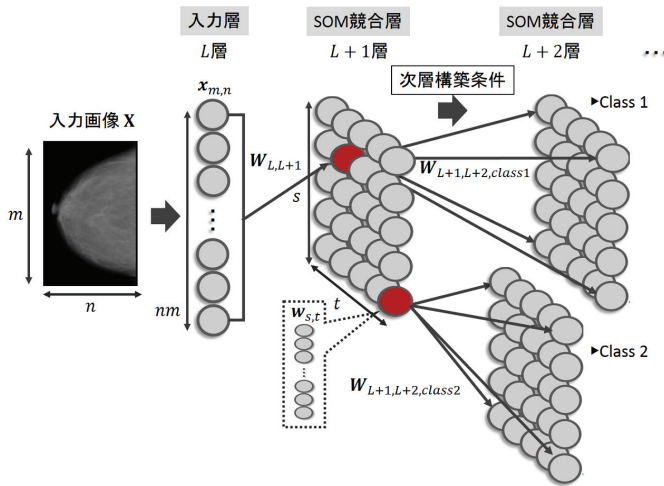


Fig. 1: 木構造自己組織化マップの学習.

初期化する.  $L$  層および  $L + 1$  層における  $\mathbf{w}_{ij}$  の集合を  $\mathbf{W}_{L,L+1}$  とする.

**STEP 2** 入力:  $\mathbf{x}_k (k = 1, 2, \dots, mn)$  を決定する.

**STEP 3** 類似度の算出:  $\mathbf{x}_k$  と  $\mathbf{w}_{ij}$  における類似度すなわちユークリッド距離を以下の式に従い算出する.

$$d_{ij} = \sqrt{\sum_{i=1}^s \sum_{j=1}^t (\mathbf{x}_k(t) - \mathbf{w}_{ij}(t))^2} \quad (1)$$

**STEP 4** 勝者ノードの決定:  $d_{ij}$  が最小の競合ノードを勝者ノード  $c$  として決定する.

**STEP 5** 結合重み係数の更新: 勝者ノードを中心とし  $N_{cij}(t)$  で定義される近傍領域内において結合重み係数を次式に従い更新する. ただし  $\alpha$  は学習率係数 ( $0 < \alpha < 1$ ) を表す.

$$\mathbf{w}_{ij}(t+1) = \mathbf{w}_{ij}(t) + \alpha(t)N_{cij}(t)(\mathbf{x}_k(t) - \mathbf{w}_{ij}(t)) \quad (2)$$

ここで学習率係数  $\alpha(t)$  および近傍領域  $N_c(t)$  は学習回数の増加に伴い以下に定義するように単調減少させる. ただし  $\mathbf{r}_c$  および  $\mathbf{r}_{ij}$  は勝者ノードおよび注目ノードの座標ベクトルを,  $t_{max}$  は最大学習回数を表す.

$$\alpha(t) = 1 - \frac{t}{t_{max}} \quad (3)$$

$$N_c(t) = \exp\left(\frac{|\mathbf{r}_c - \mathbf{r}_{ij}|^2}{2 \sigma^2 \alpha(t)}\right) \quad (4)$$

**STEP 6**: STEP 2 から STEP 5 を最大学習回数に達するまで繰り返す.

続いて画像分類フェーズを説明する. 入力画像が分類される (最も強く反応する) 競合ノードを決定するため, 学習された全結合重み係数に対し, 入力画像を再入力し (1) 式に従い類似度を算出する. このとき最も類似度の高かった結合重み係数を保持する競合ノードを勝者とすることで入力画像の分類とする.

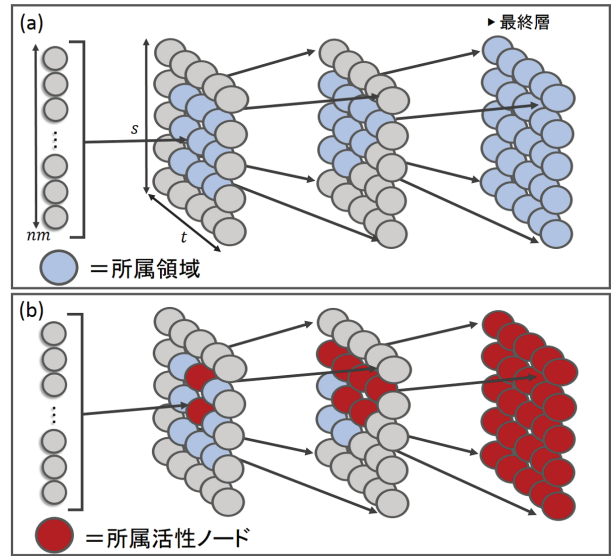


Fig. 2: 所属領域および所属活性ノードの図解.

最後に木構造化フェーズを説明する. 似たような画像が多く含まれる分類に対し, より詳細な分類を行うため, SOM を適応的に追加する. このとき, SOM の特性上, 木構造化対象ノードの近傍ノードも類似する入力画像に対して活性する可能性が高いことから, ある競合ノードに対する近傍 (本稿では 8 近傍) の重み係数に注目し最も類似度の高い競合ノードとクラスを共有する方法で競合層のクラスタリングを行う. 手順を以下に示す.

**STEP 1** クラス番号の初期化: 各競合ノードに対しクラス番号を無作為に割り当てる.

**STEP 2** 類似度の算出: 注目する競合ノードに対し 8 近傍ノードとの結合重み係数に関する類似度を算出する. 類似度は (1) 式を用いる. このとき最も類似度の高い競合ノードが保持するクラス番号を共有する.

**STEP 3**: クラス番号の更新回数が 0 になるまで STEP 2 を繰り返す.

以上により競合層における分類画像のクラスタリングを行い, このとき各クラスに分類される画像を所属データセット, 競合ノードを所属領域と呼ぶ. これを Fig. 2(a) に図解する. また, Fig. 2(b) に示すように, 所属データセットに対し勝者ノードとして活性化するノードを所属活性化ノードと呼ぶ. 最後に各所属領域に対し次層構築条件を適用し木構造を決定する. 条件は

条件 1 所属データセットの画像数が閾値  $T_1$  以上

条件 2 所属領域における結合重み係数の分散が閾値  $T_2$  以上

であり, 本稿では閾値を実験的に決定した.

フェーズ 1) から 3) を繰り返す, TS-SOM による入力画像の分類結果を得る.

### 3 異常例分類実験

臨床データを用いた病変を含む画像の分類実験を行った。先行研究<sup>5)</sup>では分類機能評価のため、学習した TS-SOM の特徴量に対し設計者がラベリングを行い、その情報に基づいた画像分類を行ったが、ここでは入力画像と特徴量の類似度のみに基づいて画像を分類することで、TS-SOM の特徴量だけでなく、その学習後の分類においても、設計者の明示的な分類設計なしで本手法が病変画像の画像分類に応用可能か検討した。

#### 3.1 実験条件

##### 3.1.1 パラメータ設定

TS-SOM を学習するにあたり予備実験によりパラメータ設定を行った。SOM 競合層は計算時間を考慮し二次元格子を  $7 \times 7$  の 49 ユニットとした。予備実験における学習収束状況を考慮し最大学習回数を 10000 回、学習率  $\alpha$  の初期値を 0.1、近傍領域関数における半径の初期値を 2 とした。多層構築における次層構築条件における閾値を  $T_1 = 20$ ,  $T_2 = 5.7$  とした。

##### 3.1.2 臨床データセット

実験データは世界的に標準的なデータベースである Digital Database for Screening Mammography (DDSM)<sup>6)</sup> から病変症例 50 枚、正常例 50 枚の計 100 枚を用いた。病変症例では、腫瘍陰影において特徴量設計が困難とされる不整形および分葉形症例のみで構成した。正常例では、過去にトレーニングデータとして使用されていない画像のみで構成した。

##### 3.1.3 検出閾値

病変を含む症例を分類するために、正常例のみで学習した TS-SOM を用いて入力データと結合重み係数の類似度を検出閾値とした異常画像判別を行う。正常例および病変症例における類似度の傾向を把握するため、横軸に類似度、縦軸に頻度を表した近似分布を Fig. 3 に示す。このとき類似度は相関係数を用い、近似にはカーネル平滑化関数を用いた。緑線は TS-SOM 学習時の正常例のみで構成されたトレーニングデータセット、青線は未使用の正常例のみで構成されたデータセット、そして赤線は病変症例のみで構成されたデータセットにおける近似分布である。それぞれの最頻値は高い順から 0.998, 0.988, 0.981 であった。この傾向から相関係数を類似度とした検出閾値  $T_c$  を設けることで、病




Fig. 3: 相関係数を確率変数とした確率密度近似分布。緑線: TS-SOM 学習における正常例のみのトレーニングデータセット。青線: 未使用の正常例データセット。赤線: 病変症例データセット




Fig. 4: ROC 曲線による性能比較評価。

Table 1: 木構造分類の各層における真陽性率および偽陽性数 (検出閾値  $T_c = 0.985$ )

	1層目	2層目	3層目
真陽性率	0.68	0.80	0.82
偽陽性数	0.20	0.22	0.20

変症例を異常画像として正常例から分類可能と考えられる。

##### 3.1.4 性能評価指標

検出性能の評価指標として、CAD システムの性能評価で一般的に用いられる ROC (response receiver operating characteristic) 曲線を用いた<sup>7)</sup>。ここでは横軸に偽陽性率、縦軸に真陽性率を取り、検出アルゴリズムのパラメータを変化させたときの検出性能をプロットして ROC 曲線を描いた。曲線は左上にあるほど検出性能が高いと評価される。

#### 3.2 実験結果

提案モデルの木構造分類による異常画像分類実験の結果を Fig. 4 に示す。図中、木構造の根に近い 1 層目における分類結果を緑線、2 層目における分類結果を青線、そして葉に近い 3 層目における分類結果を赤線として示す。ROC 曲線を描くパラメータは検出閾値  $T_c$  とした。また、検出閾値が  $T_c = 0.985$  の場合について、各層における真陽性率および偽陽性数の結果を Table 1 に示す。3 層目では真陽性率 82% のとき偽陽率 20% と他層と比較し最も分類性能が高かった。また、ROC 曲線全体の傾向として深層化に伴い検出性能が向上していることから提案法の有用性が示唆された。

#### 3.3 考察

異常画像分類実験において検出閾値が  $T_c = 0.985$  の場合について、真陽性例を Fig. 5 および Fig. 6 に、検出見逃し例を Fig. 7 に示す。真陽性例では Fig. 5 が全層において真陽性だった例を、Fig. 6 では 3 層目でのみ真陽性だった例を示す。図中では、入力に対し各層において勝者だった結合重み係数の可視化および類似度である相関係数を示す。

Fig. 5 では検出閾値  $T_c = 0.985$  のとき、各層とも類似度が低かったため全層で異常画像として検出された。この例では、図中病変症例内に赤線で示すように病変



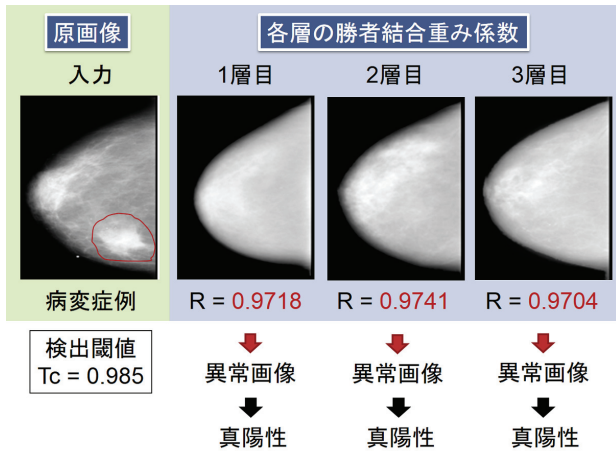


Fig. 5: (真陽性例) 病変症例の入力における各層の勝者結合重み係数の可視化および類似度。

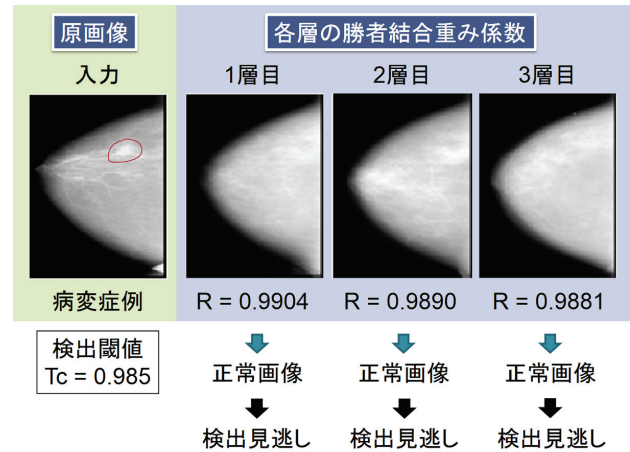


Fig. 7: (検出見逃し例) 病変例の入力における各層の勝者結合重み係数の可視化および類似度。

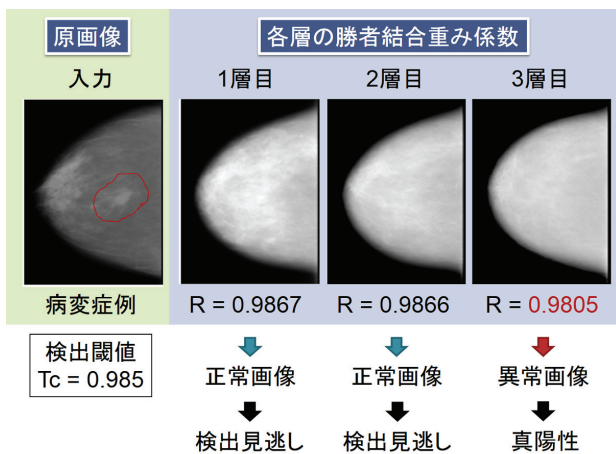


Fig. 6: (真陽性例) 病変症例の入力における各層の勝者結合重み係数の可視化および類似度。

領域が大きかったため、初期層の段階から類似度を大きく下げたと考えられる。

Fig. 6 では検出閾値  $T_c = 0.985$  のとき、1層および2層目では誤って正常画像に分類され、3層目において正しく異常画像として検出された。これは先行研究<sup>5)</sup>で考察した、詳細構造化によってテクスチャがはっきりしたことによる最終層での異常部の際立ちが理由と考えられる。相関係数値は深層化に伴い減少しているが、層間で大きく値が変化しているとはいえない。これは図中病変症例内に赤線で示しているように、病変領域が比較的小さいためであると考えられる。同じく病変領域が小さく、かつ全層で検出を見逃した Fig. 7 では、同様に深層化に伴い微少なながら類似度の減少が確認されるが全層で検出見逃しとなった。これは Fig. 6 における病変は領域が小さいながら乳腺領域と離れているのためテクスチャが際立ったのに対し、Fig. 7 では微小かつ乳腺領域上に重なって存在し低コントラストであることから、画像全体としての類似度が高くなったためと考えられる。なお、Fig. 7 に示す病変症例は検出閾値を高くすることで真陽性として検出可能である。

#### 4 おわりに

本研究では、従来の特徴量設計を伴う画像処理法に対し、入力画像から自動的に詳細構造の分類を行う TS-SOM による自動分類法を、乳がん病変を含む異常画像の検出問題に適用した。臨床データを用いた実験結果により、特異性向上を目的とした深層化に伴う特徴量の詳細化を確認するとともに、そのような基準の木構造化により多様な病変に対する網羅性も兼ね備えた分類機能が自動的に獲得される可能性を確認した。また、明示的な特徴量設計なしで異常症例画像を検出可能なことが例証され、学習された TS-SOM の病変分類論理の有効性が示唆された。

#### 謝辞

本研究の一部は、JSPS 科研費 26540112 の助成を受けた。

#### 参考文献

- 1) 独立行政法人国立がん研究センターがん対策情報センター, <http://ganjoho.jp/professional/index.html>.
- 2) Jinshan Tang, Rangaraj M. Rangayyan, Jun Xu, Issam El Naqa, and Yongyi Yang: Computer-Aided Detection and Diagnosis of Breast Cancer With Mammography, *IEEE Transactions on Information Technology in Biomedicine*, **13-2**, 236/251 (2009)
- 3) Maurice Samulski, Nico Karssemeijer: Optimizing Case-Based Detection Performance in a Multiview CAD System for Mammography, *IEEE Transactions on Medical Imaging*, **30-4**, 1001/1009 (2011)
- 4) Rangayyan RM, Prajna S, Ayres FJ, Desautels JEL: Detection of architectural distortion in mammograms acquired prior to the detection of breast cancer using Gabor filters, phase portraits, fractal dimension, and texture analysis, *International Journal Of Computer Assisted Radiology and Surgery*, **2-6**, 347/361(2008)
- 5) 長谷川奈保, 本間経康, 張曉勇, 大橋悠二, 吉澤誠: 乳房 X 線画像診断支援のための多層自己組織化マップによる特徴分類, 計測自動制御学会東北支部 50 周年記念学術講演会予稿集, 17/20 (2014)
- 6) M. Heath, K. Bowyer, D. Kopans, R. Moore, and P. Kegelmeyer: The Digital Database for Screening Mammography, 5th International Workshop on Digital Mammography, 212/218 (2000)
- 7) Bunch PC, Hamilton JF, Sanderson GK, and Simmons AH: A Free Response Approach to the Measurement and Characterization of Radiographic Observer Performance, *SPIE*, **127**, 124/135 (1977)

# ベクトル積ホップフィールドニューラルネットワーク

○小林正樹 (山梨大学)

## Vector Product Hopfield Neural Networks

\*M. Kobayashi (University of Yamanashi)

**Abstract**— This document describes vector product Hopfield neural networks and their fundamentals. Vector product Hopfield neural networks is a model of three dimensional Hopfield neural network. In this paper, we compare the storage capacity and noise tolerance of vector product Hopfield neural networks with those of complex-valued Hopfield neural networks by computer simulations.

**Key Words:** Vector product, Hopfield neural network

### 1 はじめに

ニューラルネットワークへのベクトル積の導入は新田<sup>1, 2)</sup>により初めて階層型ネットワークに対して行われ、計算機シミュレーションにより、通常のニューラルネットワークと比較して学習が高速であることが示された。その後、筆者<sup>3)</sup>によりホップフィールド型ニューラルネットワーク (HNN) に適用された。そこでは、計算機シミュレーションは行われているものの、他の HNN のモデルとの比較は行われていない。

ベクトル積 HNN (VPHNN : Vector Product HNN) は3次元の HNN である。2次元 HNN のモデルには、複素 HNN<sup>4)</sup> (CHNN : Complex-valued HNN)、hyperbolic HNN<sup>5)</sup>、rotor HNN<sup>6, 7)</sup> などがあり、4次元 HNN のモデルには、四元数 HNN<sup>8)</sup> や可換四元数 HNN<sup>9)</sup> などがある。3次元 Feed-Forward ニューラルネットワークに関しては、外積モデル他にもいくつか提案されている。新田<sup>10, 11, 12)</sup> はニューロンを3次元ベクトル、結合荷重を  $3 \times 2$  行列で表すモデルを提案した。Arena<sup>ら</sup><sup>13)</sup> は四元数を使ったモデルを提案している。一方、3次元 HNN の例は他にほとんどなく、その点で VPHNN は貴重なモデルである。本研究では、記憶容量と雑音耐性について CHNN と計算機シミュレーションにより比較する。

### 2 ベクトル積ホップフィールドニューラルネットワーク

ニューロンの入出力は3次元ベクトルであり、活性化関数はスプリット型を使用する。すなわち、ニューロンの状態は  $(\pm 1, \pm 1, \pm 1)$  である。また、結合荷重も3次元ベクトルで表される。 $j$  番目のニューロンの状態を  $\mathbf{v}_j$ 、 $k$  番目のニューロンから  $j$  番目のニューロンへの結合荷重を  $\mathbf{w}_{jk}$  で表す。このとき、ニューロン  $i$  への入力  $\mathbf{S}_i$  は、

$$\mathbf{S}_i = \sum_{k \neq j} \mathbf{w}_{jk} \times \mathbf{v}_k \quad (1)$$

で与えられる。ここで、 $\times$  はベクトル積である。また、結合荷重は  $\mathbf{w}_{ij} = -\mathbf{w}_{ji}$  という制約を満たす。 $\mathbf{v}_i = (x_i, y_i, z_i)^t$ 、 $\mathbf{w}_{ij} = (a, b, c)^t$  と表し、ニューロンの各成分を独立した通常のニューロンとみなすと、Fig. 1 のようになり、通常の HNN の特殊な場合と分かる。




Fig. 1: Connection Weight.

### 3 学習則

ヘブ学習則に類似した単純な学習則を与える。簡単のため学習パターンが1つであると仮定し、 $(\mathbf{p}_1, \mathbf{p}_2, \dots)$  とする。複数のパターンがある場合は、学習パターンが1つの場合の単純な和で結合荷重を与える。各  $\mathbf{p}_j$  は3次元ベクトルであり、 $(\pm 1, \pm 1, \pm 1)$  の8状態のいずれかの状態を取る。このとき、学習則を次の式で与える。

$$\mathbf{w}_{jk} = \mathbf{p}_k \times \mathbf{p}_j \quad (2)$$

学習則としては、 $\mathbf{w}_{jk} \times \mathbf{p}_k$  と  $\mathbf{p}_j$  が同じ方向を向くことを期待したいが、そうはならない。実際、 $\mathbf{p}_k = \mathbf{p}_j$  のとき、 $\mathbf{w}_{jk}$  は零ベクトルである。しかし、 $\mathbf{p}_j$  と  $\mathbf{p}_k$  が仮に垂直であると仮定すると、 $\mathbf{w}_{jk} \times \mathbf{p}_k$  と  $\mathbf{p}_j$  は同方向である。ただし、活性化関数の定義から  $\mathbf{p}_j$  と  $\mathbf{p}_k$  は垂直になることはない。ここで与えた学習則はあまりうまく機能するようには思えないが、全く機能しないわけではない。

### 4 複素ホップフィールドニューラルネットワーク

ここでは、比較対象とする CHNN について説明する<sup>14)</sup>。ニューロンの入出力は複素数  $s$  である。また、ニューロンの状態数を  $K$  とし、活性化関数  $f(z)$  は次




Fig. 2: Complex-valued neuron ( $K=8$ ).

のように定義される。

$$f(z) = \begin{cases} e^{i\theta_K} & 0 < \arg z \leq 2\theta_K \\ e^{3i\theta_K} & 2\theta_K < \arg z \leq 4\theta_K \\ \vdots & \vdots \\ e^{(K-1)i\theta_K} & 2(K-1)\theta_K < \arg z \leq 2\pi \end{cases} \quad (3)$$

ここで、 $\theta_K = \pi/K$  である。Fig.2 は  $K=8$  のときの複素ニューロンを表したものであり、VPHNN との比較対象として使用される。

VPHNN と同様に、 $j$  番目のニューロンの状態を  $\mathbf{v}_j$ 、 $k$  番目のニューロンから  $j$  番目のニューロンへの結合荷重を  $w_{jk}$  で表す。結合荷重は複素数であり、制約条件  $w_{jk} = \overline{w_{kj}}$  を満たす。ここで、 $\overline{w}$  は  $w$  の複素共役である。ニューロン  $i$  への入力  $S_i$  も同様に

$$S_i = \sum_{k \neq i} w_{ik} \times v_k \quad (4)$$

で与えられる。

次に CHNN のヘブ学習則を与える。簡単のため学習パターンが 1 つであると仮定し、 $(p_1, p_2, \dots)$  とする。各  $p_i$  は複素数であり、 $e^{i\theta_K}, e^{3i\theta_K}, \dots, e^{(2K-1)i\theta_K}$  の  $K$  状態のいずれかの状態を取る。このとき、学習則を次の式で与える。

$$w_{jk} = p_j \overline{p_k} \quad (5)$$

このとき、

$$w_{jk} p_k = p_j \overline{p_k} p_k = p_j \quad (6)$$

となり、学習則として機能していることがわかる。

## 5 計算機シミュレーション

VPHNN の記憶容量と雑音耐性を CHNN とコンピュータシミュレーションで比較する。CHNN は VPHNN と同じく 8 状態をとるニューロンを使用する。ニューロン数は 200 とした。

### 5.1 記憶容量

記憶容量を調べるコンピュータシミュレーションは以下の手順で行われた。

1.  $P$  個の学習パターンをランダムに生成する。

2. 生成された  $P$  個の学習パターンを記憶させる。

3. 全ての学習パターンが安定した場合、学習が成功したと判定する。

$P = 2, 4, \dots, 30$  に対して、各 100 通り試行した。Fig. 3 が実験結果を表すグラフである。横軸が学習パターンの数、縦軸が成功率である。記憶容量の点では大きく改善していることがわかる。

### 5.2 雑音耐性

コンピュータシミュレーションにより雑音耐性を調べた。学習パターンの生成は記憶容量に関するシミュレーションと同様ランダムに生成した。各試行手順は以下のとおりである。

1. 記憶した学習パターンからランダムに 1 つ選び入力として与える。
2. 各ニューロンの状態を確率  $r$  で新しい状態に変更する。新しい状態は 8 状態からランダムに選択される。
3. 与えた学習パターンが完全に復元できたとき、施行は成功したと判定する。

学習パターンを 100 組生成し、各学習パターンに対して 100 回の試行、計 10,000 回の試行を行った。Fig. 4 が実験結果を表すグラフである。横軸が雑音率、縦軸が成功率である。雑音耐性の点でも改善していることがわかる。

## 6 考察

意外なことに計算機シミュレーションでは、記憶容量、雑音耐性のいずれの点でも VPHNN が CHNN を上回った。ここでは、その理由を検討する。まず、記憶容量の点で改善した理由を検討する。VPHNN のパラメータ数が CHNN のパラメータ数より多いことがあげられる。VPHNN のパラメータ数は CHNN のパラメータ数の約 1.5 倍である。また、状態を 3 次元空間に埋め込んだため状態間の距離が大きくなり、状態の分離がしやすくなったことも記憶容量が改善した理由として考えられる。

次に雑音耐性の点で改善した理由を検討する。CHNN の雑音耐性が低い理由として、記憶容量による影響の他、回転不変性があげられる<sup>6, 15, 16, 17, 18</sup>。一方、VPHNN は回転不変性による雑音耐性の低下はないと考えられる。しかし、まだ状態数が少ないため CHNN の回転不変性による雑音耐性の低下は著しいものではないはずである。今後、より状態数の多いモデルを考えたとき、この回転不変性による影響は顕著なものになると予想される。

## 7 まとめ

VPHNN と CHNN の記憶容量と雑音耐性を計算機シミュレーションで比較したところ、意外なことに、いずれも VPHNN が上回る結果となった。この結果の理由としては、(1) パラメータ数、(2) 空間の大きさ、(3) 回転不変性が考えられる。現時点では、活性化関数として最も単純なスプリット型を使用しているため VPHNN はホップフィールドニューラルネットワークの特殊な場合でしかない。今後は、3次元信号としての利




Fig. 3: Storage Capacity.




Fig. 4: Noise Tolerance.

点を生かした活性化関数を検討していくことが課題である。現在の比較では、状態数が8と小さくCHNNの雑音耐性の低下もあまり回転不変性の影響を受けていないと考えられる。状態数が増えるにしたがってCHNNの雑音耐性は著しく低下する。状態数の多いVPHNNのモデルを開発することは、雑音耐性の高いHNNにつながると期待できる。また、学習則も極めて単純な方法しか与えていない。高度な学習則を開発することも今後の課題である<sup>19, 20, 21, 22, 23, 24, 25</sup>。

## 参考文献

- 1) T. Nitta : A Back-Propagation Algorithm for Neural Networks Based on 3D Vector Product, Proceedings of IEEE/INNS International Joint Conference on Neural Networks, **1** 589/592 (1993)
- 2) T. Nitta: An Extension of the Back-Propagation Algorithm to Three Dimensions by Vector Product, Proceedings of 5th IEEE International Conference on Tools with Artificial Intelligence, 460/461 (1993)

- 3) 小林 : 外積を利用した3次元連想記憶, 電気学会論文誌C, **124** 1 150/156 (2004)
- 4) S. Jankowski, A. Lozowski and J. M. Zurada : Complex-valued Multistate Neural Associative Memory, IEEE Transactions on Neural Networks, **7** 6 1491/1496 (2006)
- 5) M. Kobayashi : Hyperbolic Hopfield Neural Networks, IEEE Transactions on Neural Networks and Learning Systems, **24** 2 335/341 (2013)
- 6) M. Kitahara, M. Kobayashi: and M. Hattori : Chaotic Rotor Associative Memory, Proceedings of International Symposium on Nonlinear Theory and its Applications, 399/402 (2009)
- 7) M. Kitahara and M. Kobayashi : Projection Rule for Rotor Hopfield Neural Networks, IEEE Transactions on Neural Networks and Learning Systems, **25** 7 1298/1307 (2014)
- 8) T. Isokawa, H. Nishimura, N. Kamiura and N. Matsui : Associative Memory in Quaternionic Hopfield Neural Network, International Journal of Neural Systems, **18** 2 135/145 (2008)
- 9) T. Isokawa, H. Nishimura and N. Matsui : Commutative Quaternion and Multistate Hopfield Neural Networks, Proceedings of IEEE World Congress on Computational Intelligence, 1281/1286 (2010)
- 10) T. Nitta : A Three-dimensional Back-propagation, Proceedings of INNS World Congress on Neural Networks, **3** 572/575 (1993)
- 11) T. Nitta: Ability of the 3D Vector Version of the Back-Propagation to Learn 3D Motion, Proceedings of INNS World Congress on Neural Networks, **3** 262/267 (1994)
- 12) T. Nitta : Generalization Ability of the Three-Dimensional Back-Propagation Network, Proceedings of IEEE International Conference on Neural Networks, **5** 2895/2900 (1994)
- 13) P. Arena, L. Fortuna, G. Muscato and M. G. Xibilia : Neural Networks in Multidimensional Domains: Fundamentals and New Trends in Modelling and Control, Lecture Notes in Control and Information Sciences, Springer (1998)
- 14) S. Jankowski, A. Lozowski and J. M. Zurada : Attractors Accompanied with a Training Pattern of Multi-Valued Hopfield Neural Networks, IEEE Transactions on Neural Networks, **7** 6 1491/1496 (1996)
- 15) M. Kobayashi: Complex-Valued Multistate Neural Associative Memory, IEEE Transactions on Electrical and Electronic Engineering, **10** 2 195/200 (2015)
- 16) Y. Suzuki, M. Kitahara and M. Kobayashi : Dynamic Complex-valued Associative Memory with Strong Bias Terms, Proceedings of International Conference on Neural Information Processing, 509/518 (2011)
- 17) Y. Suzuki and M. Kobayashi : Complex-valued Bipartite Auto-Associative Memory, IEICE Transactions on Fundamentals of Electronics, Communications and Computer Sciences, **97E-A** 8 1680/1687 (2014)
- 18) S. Furusawa and M. Kobayashi : Chaotic Complex-valued Bidirectional Associative Memory with a Real-valued Context Part, Nonlinear Theory and Its Applications, **4** 3 299/312 (2013)
- 19) M. Kobayashi : Pseudo-Relaxation Learning Algorithm for Complex-valued Associative Memory, International Journal of Neural Systems, **18** 2 147/156 (2008)
- 20) M. Kobayashi, H. Yamada and M. Kitahara : Noise Robust Gradient Descent Learning for Complex-valued Associative Memory, IEICE Transactions on Fundamentals of Electronics, Communications and Computer Sciences, **E94-A** 8 1756/1759 (2011)

- 21) M. Kitahara and M. Kobayashi : Projection Rule for Complex-valued Associative Memory with Large Constant Terms, *Nonlinear Theory and Its Applications*, **3** 3 426/435 (2012)
- 22) 北原倫理, 小林正樹 : ロータ連想記憶の勾配降下学習, *電気学会論文誌 C*, **131** 1 116/121 (2011)
- 23) M. K. Muezzinoglu, C. Guzelis and J. M. Zurada : A New Design Method for the Complex-Valued Multistate Hopfield Associative Memory, *IEEE Transactions on Neural Networks*, **14** 4 891/899 (2003)
- 24) D. Q. Lee: Improving the Capacity of Complex-Valued Neural Networks with a Modified Gradient Descent Learning Rule, *IEEE Transactions on Neural Networks*, **12** 2 439/443 (2001)
- 25) D. Q. Lee: Improvements of Complex-Valued Hopfield Associative Memory by Using Generalized Projection Rules, *IEEE Transactions on Neural Networks*, **17** 5 1341/1347 (2006)

# 巻き込み分布に従う位相スペクトル差をもつ信号間の位相限定相関関数の統計的性質

○八巻俊輔 川又政征 (東北大学)

## Statistical Properties of Phase-Only Correlation Functions Between Signals with Phase-Spectrum Differences Following Wrapped Distributions

\*S. Yamaki and M. Kawamata (Tohoku University)

**Abstract**— This paper reveals statistical properties of phase-only correlation (POC) functions with stochastic phase spectrum differences following wrapped distributions. We assume the phase spectrum differences between two signals to be random variables following a linear distribution. We next convert the linear distribution into a wrapped distribution by wrapping the original linear distribution around the circumference of a unit circle. In deriving general expressions of the expectation and variance of the POC functions, we obtain exactly the same results between in case of a linear distribution and its wrapped distribution.

**Key Words:** Phase-only correlation functions, Wrapped distributions, Directional statistics

### 1 まえがき

位相限定相関 (POC: Phase-Only Correlation) 関数は、2つの信号の類似度を評価する関数として、信号マッチングをはじめとするさまざまな分野に幅広く応用されてきた<sup>1, 2, 3, 4, 5, 6</sup>。POC関数は、2つの信号の位相スペクトルが等しければデルタ関数になる。しかし、実際の信号マッチングにおいて、2つの信号の位相スペクトルが等しくなることはほとんど起こりえない。そのため、2つの信号の位相スペクトルが等しくない場合の POC 関数の性質について理論的に明らかにしなければならない。

著者らのグループは、2つの信号の位相スペクトルが等しくない場合の POC 関数の挙動について統計的に解析した<sup>7, 8</sup>。まず、一般統計学に基づく統計的解析法<sup>7</sup>では、位相スペクトル差が正規分布などの線形確率分布に従うと仮定し、POC 関数の期待値と分散を導出した。次に、方向統計学に基づく統計的解析法<sup>8</sup>では、信号の位相スペクトルが角度データであることを考慮し、位相スペクトル差の確率分布として von-Mises 分布などの円周確率分布を仮定し、POC 関数の期待値と分散を導出した。位相スペクトル差を正規分布と仮定するのが解析の都合上便利である一方で、正規分布は円周確率分布ではないため、角度データの確率分布としては用いることができないという問題点がある。

本論文では、円周確率分布のひとつである巻き込み分布に従う位相スペクトル差を持つ信号間の POC 関数の期待値と分散を導出し、その統計的性質を明らかにする。2つの信号の位相スペクトル差を線形確率分布に従う確率変数と仮定し、巻き込み法を用いて線形確率分布を巻き込み分布に変換する。結果、巻き込み分布を仮定したときの POC 関数の期待値と分散が、もとの線形確率分布を仮定したときの POC 関数の期待値と分散にそれぞれ一致することを示す。本論文の結果は、一般統計学に基づく POC 関数の統計的解析<sup>7</sup>の結果も、方向統計学の概念を用いて説明できることを意味する。

### 2 位相限定相関 (POC) 関数

本章では、POC 関数の定義および POC 関数の性質について述べる。

#### 2.1 POC 関数の定義

長さ  $N$  の2つの信号  $x(n)$  および  $y(n)$  を考える。これらの信号の離散フーリエ変換 (DFT) はそれぞれ、

$$X(k) = \sum_{n=0}^{N-1} x(n)W_N^{kn} = |X(k)|e^{j\theta_k} \quad (1)$$

$$Y(k) = \sum_{n=0}^{N-1} y(n)W_N^{kn} = |Y(k)|e^{j\phi_k} \quad (2)$$

で与えられる。ここで、 $W_N = \exp(-j2\pi/N)$  は離散フーリエ変換の回転因子であり、 $\theta_k$  および  $\phi_k$  はそれぞれ、信号  $x(n)$  および  $y(n)$  の位相スペクトルである。このとき、2つの信号  $x(n)$  および  $y(n)$  の間の POC 関数  $r(m)$  は、2つの信号の正規化クロスパワースペクトルの離散フーリエ逆変換 (IDFT) として、以下で与えられる。

$$r(m) = \text{IDFT} \frac{X(k)Y^*(k)}{|X(k)Y(k)|} = \frac{1}{N} \sum_{k=0}^{N-1} e^{j\alpha_k} W_N^{-mk} \quad (3)$$

ここで、 $\alpha_k = \theta_k - \phi_k$  は2つの信号の位相スペクトル差であり、 $e^{j\alpha_k}$  は位相因子とよばれる。

式(3)で定義された POC 関数の原理について説明する。2つの信号  $x(n)$  および  $y(n)$  それぞれの位相限定信号  $x_{\text{po}}(n)$  および  $y_{\text{po}}(n)$  を以下で定義する。

$$x_{\text{po}}(n) = \text{IDFT} \frac{X(k)}{|X(k)|} = \frac{1}{N} \sum_{k=0}^{N-1} e^{j\theta_k} W_N^{-nk} \quad (4)$$

$$y_{\text{po}}(n) = \text{IDFT} \frac{Y(k)}{|Y(k)|} = \frac{1}{N} \sum_{k=0}^{N-1} e^{j\phi_k} W_N^{-nk} \quad (5)$$

すると、式(3)で定義された POC 関数は、位相限定信号  $x_{\text{po}}(n)$  および  $y_{\text{po}}(n)$  の間の相互相関関数である。

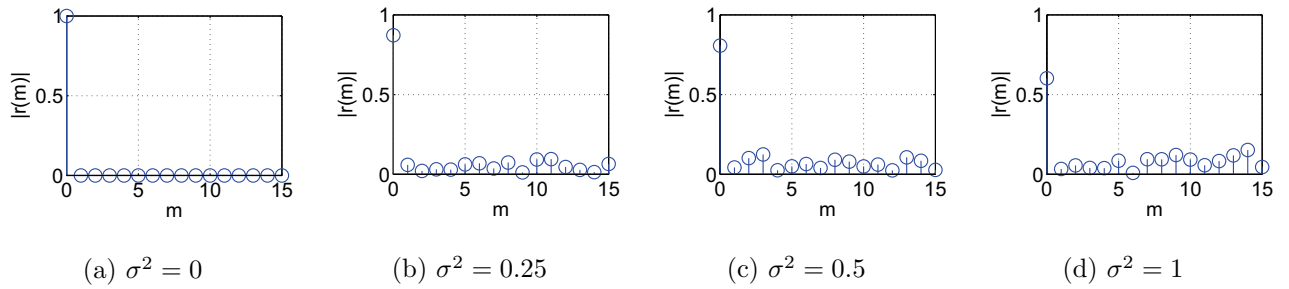


Fig. 1: 位相スペクトル差の分散  $\sigma^2$  の変化に対する POC 関数  $|r(m)|$  の変動の例

式 (4) および (5) より, 位相限定信号は, 周波数振幅スペクトルをすべての周波数において 1 に正規化して得られた信号である. 一般に, 自然音声や自然画像などの信号のエネルギーは低周波領域に集中している. このとき, 振幅スペクトルをすべての周波数において 1 に正規化することは, 信号の高周波成分を強調することに相当する. そのため, 相互相関関数に比べて POC 関数の方が相関関数のピークが鋭くなる傾向にある.

## 2.2 位相スペクトル差が一定値である場合の POC 関数

2 つの信号の位相スペクトル差  $\alpha_k$  が周波数インデックス  $k$  に関して一定値であるとき, すなわち  $\alpha_k = \theta_k - \phi_k = \gamma(\text{const.})$  であるとき, POC 関数  $r(m)$  は下記のとおりデルタ関数になることが知られている.

$$r(m) = \frac{1}{N} \sum_{k=0}^{N-1} e^{j\gamma} W_N^{-mk} = e^{j\gamma} \delta(m) \quad (6)$$

POC 関数を用いたマッチング手法において, この性質が原理として用いられてきた. しかし, 実際の信号マッチングにおいて, 2 つの信号の位相スペクトル差が一定値になることはほとんどないため, 式 (6) の性質は実際の信号マッチングには用いることができない. そのため, 位相スペクトル差が一定値でない場合の POC 関数の性質について理論的に明らかにしなければならない.

## 2.3 位相スペクトル差が一定値でない場合の POC 関数

2 つの信号の位相スペクトル差  $\alpha_k$  が周波数インデックス  $k$  に関して一定値でないときの POC 関数の性質を簡単な実験例で示す. 位相スペクトル差  $\alpha_k$  を平均 0, 分散  $\sigma^2$  の正規分布  $N(0, \sigma^2)$  に従う確率変数であると仮定し, 分散を  $\sigma^2 = 0, 0.25, 0.5, 1$  と変化させながらそれぞれ POC 関数  $r(m)$  を計算した結果を図 1 に示す. 図 1 より, 位相スペクトル差が大きくなるにしたがい, POC 関数  $r(m)$  のピークの高さ  $|r(0)|$  が減少し,  $|r(m \neq 0)|$  の値が増加する傾向にあることが実験的に確かめられる.

## 3 POC 関数の統計的解析<sup>7, 8)</sup>

本章では, 著者らのグループがこれまでに行ってきた POC 関数の統計的解析について紹介する. 位相スペクトル差が 0 でない場合の POC 関数の期待値と分散を理論的に導出し, これまで実験的にしか確かめられていなかった性質に関する理論的な根拠を与えた.

### 3.1 POC 関数の期待値と分散の一般式

位相スペクトル差  $\alpha_k$  をすべての周波数インデックス  $k$  に関して同一の確率分布をもつ互いに独立な確率変数と仮定し, POC 関数  $r(m)$  の期待値  $E[r(m)]$  および分散  $\text{Var}[r(m)]$  の一般式を以下のように導出した<sup>7, 8)</sup>.

$$E[r(m)] = A\delta(m) \quad (7)$$

$$\text{Var}[r(m)] = \frac{1}{N}(1 - |A|^2) \quad (8)$$

ここで, 位相因子  $e^{j\alpha_k}$  の期待値を

$$A = E[e^{j\alpha_k}] \quad (9)$$

とおいている. すなわち, 位相スペクトル差  $\alpha_k$  の確率密度関数を仮定することにより, 式 (7) および式 (8) の値が具体的に決まる.

### 3.2 一般統計学に基づく POC 関数の統計的解析<sup>7)</sup>

位相スペクトル差に正規分布などの線形確率分布を仮定し, POC 関数の期待値と分散を導出した.

#### 3.2.1 特性関数を用いた表現

位相スペクトル差の確率密度関数が与えられたとき, その特性関数を用いて POC 関数の期待値および分散を導出できる. 確率変数  $\alpha_k$  の確率密度関数  $p(\alpha_k)$  の特性関数  $\psi_{\alpha_k}(t)$  は以下で定義される.

$$\psi_{\alpha_k}(t) = E[e^{j\alpha_k t}] = \int_{-\infty}^{\infty} e^{j\alpha_k t} p(\alpha_k) d\alpha_k \quad (10)$$

すなわち, 特性関数  $\psi_{\alpha_k}(t)$  は確率密度関数  $p(\alpha_k)$  のフーリエ変換である. ここで, 式 (9) における  $A = E[e^{j\alpha_k}]$  は特性関数  $\psi_{\alpha_k}(t)$  を用いて以下のように表すことができる.

$$A = E[e^{j\alpha_k}] = \int_{-\infty}^{\infty} e^{j\alpha_k} p(\alpha_k) d\alpha_k = \psi_{\alpha_k}(1) \quad (11)$$

したがって, 正規分布やラプラス分布, レイリー分布など, 特性関数が知られている代表的な確率分布に関しては, その特性関数を利用して POC 関数の期待値および分散を簡単に導出することができる.

#### 3.2.2 正規分布を仮定した場合の例

線形確率分布の例として, 位相スペクトル差  $\alpha_k$  が平均  $\mu$ , 分散  $\sigma^2$  の正規分布  $N(\mu, \sigma^2)$  に従う確率変数と仮定する. すなわち,  $\alpha_k$  の確率密度関数  $p(\alpha_k)$  は

$$p(\alpha_k) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(\alpha_k - \mu)^2}{2\sigma^2}} \quad (-\infty < \alpha_k < \infty) \quad (12)$$




Fig. 2: 位相スペクトル差の分散  $\sigma^2$  に対する POC 関数  $r(m)$  の期待値  $|E[r(0)]|$  および分散  $\text{Var}[r(m)]$

と表される. このとき, 確率密度関数  $p(\alpha_k)$  の特性関数  $\psi_{\alpha_k}(t) = e^{j\mu t} e^{-\sigma^2 t^2/2}$  より,  $A = E[e^{j\alpha_k}]$  は

$$A = E[e^{j\alpha_k}] = \psi_{\alpha_k}(1) = e^{j\mu} e^{-\frac{\sigma^2}{2}} \quad (13)$$

と導出される. 式 (13) を式 (7) および式 (8) に代入し,

$$E[r(m)] = e^{j\mu} e^{-\frac{\sigma^2}{2}} \delta(m) \quad (14)$$

$$\text{Var}[r(m)] = \frac{1}{N} (1 - e^{-\sigma^2}) \quad (15)$$

を得る. 式 (14) および式 (15) より, 位相スペクトル差の分散  $\sigma^2$  に対する POC 関数  $r(m)$  の期待値  $|E[r(0)]|$  および分散  $\text{Var}[r(m)]$  のそれぞれの値は図 2 のように図示できる. 位相スペクトル差の分散  $\sigma^2$  が増加するにしたがい, 期待値  $|E[r(0)]|$  は 1 から 0 に単調減少し, 分散  $\text{Var}[r(m)]$  は 0 から  $1/N$  に単調増加する. 式 (14) および式 (15) は, 図 1 に示した実験的に得られた結果に対して理論的な根拠を与えている.

### 3.3 方向統計学に基づく POC 関数の統計的解析<sup>8)</sup>

一般統計学に基づく統計的解析<sup>7)</sup> では, 位相スペクトル差  $\alpha_k$  を数直線上に分布する線形データと仮定していた. しかし, 位相スペクトル差は円周上に分布する角度データであり, 本来  $[-\pi, \pi)$  の範囲の実数値しかとりえない. そのため, 位相スペクトル差  $\alpha_k$  を線形データではなく, 方向の情報をもつ角度データとして統計的に扱う概念を導入する必要がある. そこで著者らは, 方向統計学に基づく POC 関数の統計的解析法を提案した<sup>8)</sup>.

#### 3.3.1 方向統計学の基礎

方向統計学とは, 角度観測値を含むデータの科学であり, たとえば風向きや渡り鳥の飛び立つ方角, ルーレットの止まる位置, 時刻毎の交通事故発生件数など, 方角や時刻などに依存する量を統計的にあつかう科学である<sup>9, 10, 11, 12, 13)</sup>. これらの量は, 数直線上に分布するデータとしてではなく, 円周上に分布するデータとして考えると都合がよい. その一例として, ある病院に搬送された時刻ごとの患者数のデータ<sup>9)</sup> をヒストグラム化したものを図 3 に示す. 一般的な統計学に基づき, 時刻を数直線上のデータとみなすと, 図 3(a) に示されるような線形ヒストグラムが得られる. しかし,

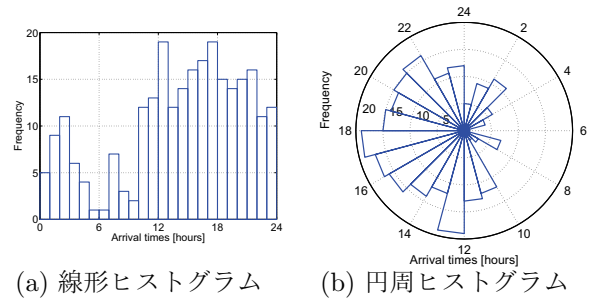


Fig. 3: ある病院に搬送された時刻ごとの患者数データ<sup>9)</sup> のヒストグラム表示




Fig. 4: 方向統計学における平均方向と円周分散の幾何学的解釈. 角度確率変数  $\alpha_1$  および  $\alpha_2$  が与えられたときの 1 次三角モーメント  $A_1$ , 平均合成ベクトル長  $|A_1|$ , 平均方向  $\bar{\alpha}$ , 円周分散  $v$ , 算術平均  $\alpha_m$ .

実際には 0 時と 24 時は同じ時刻であり, 図 3(a) のヒストグラムの左端と右端は循環してつながっていることに注意が必要である. そのため, このような時刻に依存するデータは, 図 3(a) のような線形ヒストグラムで表すよりも, 図 3(b) のような円周ヒストグラムで表す方が適している.

方向統計学では, 角度データを表す統計量を角度確率変数を用いて記述し, 角度データを単位円周上の点と対応づけて平均や分散などを定義する. まず, 角度確率変数  $\alpha \in [-\pi, \pi)$  に関して,  $A_q = E[e^{jq\alpha}]$  を  $q$  次三角モーメントという. ここで, 1 次三角モーメント  $A_1 = E[e^{j\alpha}]$  の絶対値  $|A_1|$  を平均合成ベクトル長, 偏角  $\bar{\alpha} = \arg(A_1)$  を平均方向とそれぞれ定義する. ここで, 関数  $\arg(z)$  は複素数  $z$  の偏角を与える関数であり, その値域を  $\arg(z) \in [-\pi, \pi)$  としている. また, 円周分散  $v$  が平均合成ベクトル長  $|A_1|$  を用いて  $v = 1 - |A_1|$  で定義される.

簡単な例として, 2 つの角度確率変数  $\alpha_1$  および  $\alpha_2$  の平均方向  $\bar{\alpha}$  と円周分散  $v$  の幾何学的な解釈を図 4 に示す. 平均方向  $\bar{\alpha}$  は, 角度確率変数  $\alpha$  を複素数平面上の単位ベクトル  $e^{j\alpha}$  に対応づけたときの平均的な方向を表しており, 円周分散  $v$  は単位ベクトル  $e^{j\alpha}$  の方向のばらつき度合を表している. この例の場合, 平均方向  $\bar{\alpha}$  と算術平均  $\alpha_m = (\alpha_1 + \alpha_2)/2$  が異なることに注意が必要である.






Fig. 5: von-Mises 分布  $VM(0, \beta)$  の確率密度関数

### 3.3.2 円周確率分布

一般に、角度確率変数  $\alpha \in [-\pi, \pi)$  の確率分布は円周確率分布とよばれる。円周確率分布の代表的なものに von-Mises 分布がある。von-Mises 分布は、方向統計学分野でよく知られている対称かつ単峰な分布であり、円周正規分布ともよばれる。平均方向  $\bar{\alpha}$ 、集中度  $\beta$  の von-Mises 分布  $VM(0, \beta)$  の確率密度関数  $p(\alpha_k)$  は

$$p(\alpha_k) = \frac{1}{2\pi I_0(\beta)} e^{\beta \cos(\alpha_k - \bar{\alpha})} \quad (-\pi \leq \alpha_k < \pi) \quad (16)$$

と表される。ここで、 $I_\nu(x)$  は第 1 種  $\nu$  次修正 Bessel 関数である。円周確率分布は、図 5 のように、円周上に分布する関数として図示できる。

### 3.3.3 円周分散を用いた POC 関数の期待値と分散の一般式

位相スペクトル差の確率分布として円周確率分布を仮定すると、POC 関数の期待値と分散を円周分散を用いた単純な関数で表すことができる。まず、式 (9) における  $A = E[e^{j\alpha_k}]$  はまさに 1 次三角モーメントである。すなわち、位相スペクトル差の円周分散  $v$  は  $v = 1 - |A|$  で与えられる。これを用いると、POC 関数  $r(m)$  の期待値  $E[r(m)]$  および分散  $\text{Var}[r(m)]$  は、位相スペクトル差の円周分散  $v$  を用いて以下のように表すことができる。

$$|E[r(m)]| = |A|\delta(m) = (1 - v)\delta(m) \quad (17)$$

$$\text{Var}[r(m)] = \frac{1}{N}(1 - |A|^2) = \frac{1}{N}(1 - (1 - v)^2) \quad (18)$$

すなわち、POC 関数  $r(m)$  の期待値  $E[r(m)]$  および分散  $\text{Var}[r(m)]$  はそれぞれ、円周分散  $v$  の 1 次関数および 2 次関数として表せる。

式 (17) および式 (18) より、位相スペクトル差の円周分散  $v$  に対する POC 関数の  $r(m)$  の期待値  $|E[r(0)]|$  および分散  $\text{Var}[r(m)]$  のそれぞれの値は図 6 のように図示できる。任意の円周確率分布に関して、位相スペクトル差の円周分散  $v$  が 0 から 1 に増加するにしたがい、期待値  $|E[r(0)]|$  は 1 から 0 に単調減少し、分散  $\text{Var}[r(m)]$  は 0 から  $1/N$  に単調増加する。

## 4 巻き込み分布に従う位相スペクトル差を持つ信号間の POC 関数

本章では、巻き込み分布に従う位相スペクトル差を持つ信号間の POC 関数の統計的性質を明らかにする。巻き込み分布は円周確率分布のひとつであり、正規分布やラプラス分布、レイリー分布などの線形確率分布




Fig. 6: 位相スペクトル差の円周分散  $v$  に対する POC 関数  $r(m)$  の期待値  $|E[r(0)]|$  および分散  $\text{Var}[r(m)]$




Fig. 7: 線形データ  $\alpha$  から円周データ  $\tilde{\alpha}$  への変換

の確率密度関数を円周上に巻き込むことにより生成される。位相スペクトル差に巻き込み分布を仮定した場合の POC 関数の期待値と分散は、もとの線形確率分布を仮定した場合の POC 関数の期待値と分散にそれぞれ一致することを示す。

### 4.1 巻き込み分布

まず、数直線上に分布する線形データとして、確率変数  $\alpha \in (-\infty, \infty)$  を考える。線形データ  $\alpha$  を以下により円周データ  $\tilde{\alpha}$  へ変換することを考える。

$$\tilde{\alpha} = \arg(e^{j\alpha}) \quad (-\pi \leq \tilde{\alpha} < \pi) \quad (19)$$

線形データ  $\alpha$  と円周データ  $\tilde{\alpha}$  の関係を図 7 に示す。このとき、円周データ  $\tilde{\alpha}$  の確率分布は線形データ  $\alpha$  の確率密度関数の巻き込み分布として与えられる。線形確率分布の確率密度関数  $p(\alpha)$  から生成される巻き込み分布の確率密度関数  $p_w(\tilde{\alpha})$  は、以下で与えられる。

$$p_w(\tilde{\alpha}) = \sum_{q=-\infty}^{\infty} p(\tilde{\alpha} + 2q\pi) \quad (-\pi \leq \tilde{\alpha} < \pi) \quad (20)$$

巻き込み分布は、式 (20) で表されるように、線形確率分布の確率密度関数を円周上に巻き込み、重なり合った部分を足し合わせることによって生成される。一般に、線形確率分布の確率密度関数  $p(\alpha)$  は

$$\int_{-\infty}^{\infty} p(\alpha) d\alpha = 1 \quad (21)$$

を満たし、巻き込み分布の確率密度関数  $p_w(\tilde{\alpha})$  は

$$\int_{-\pi}^{\pi} p_w(\tilde{\alpha}) d\tilde{\alpha} = 1 \quad (22)$$

を満たすことに注意が必要である。図8は、巻き込み分布の生成例を示している。図8(a)に示される正規分布の確率密度関数  $p(\alpha)$  を円周上に巻き込むことにより、図8(b)に示される巻き込み正規分布の確率密度関数  $p_w(\tilde{\alpha})$  を得る。

#### 4.2 巻き込み分布を仮定した場合の POC 関数の期待値と分散

本節では、位相スペクトル差  $\alpha_k$  に線形確率分布  $p(\alpha_k)$  を仮定した場合とその巻き込み分布  $p_w(\tilde{\alpha}_k)$  を仮定した場合の両者において、POC 関数の期待値および分散が一致することを示す。

巻き込み分布  $p_w(\tilde{\alpha}_k)$  の特性関数  $\phi_{\tilde{\alpha}_k}(t)$  は

$$\phi_{\tilde{\alpha}_k}(t) = E[e^{j\tilde{\alpha}_k t}] = \int_{-\pi}^{\pi} e^{j\tilde{\alpha}_k t} p(\tilde{\alpha}_k) d\tilde{\alpha}_k \quad (23)$$

で定義される。式(10)で定義される線形確率分布の確率密度関数の特性関数とは積分範囲が異なることに注意が必要である。ここで、線形確率分布  $p(\alpha_k)$  の特性関数  $\psi_{\alpha_k}(t)$  とその巻き込み分布  $p_w(\tilde{\alpha}_k)$  の特性関数  $\phi_{\tilde{\alpha}_k}(t)$  は、整数点  $t = q$  において以下の通り一致することが示せる<sup>11)</sup>。

$$\psi_{\alpha_k}(q) = \phi_{\tilde{\alpha}_k}(q) \quad (q = 0, \pm 1, \pm 2, \dots) \quad (24)$$

なお、式(24)の右辺  $\phi_{\tilde{\alpha}_k}(q) = E[e^{jq\tilde{\alpha}_k}]$  は、 $q$  次三角モーメントとも一致している。すなわち、位相スペクトル差  $\alpha_k$  に線形確率分布  $p(\alpha_k)$  を仮定した場合とその巻き込み分布  $p_w(\tilde{\alpha}_k)$  を仮定した場合の両者において、位相因子の期待値  $A$  が以下の通り一致する。

$$A = \psi_{\alpha_k}(1) = \phi_{\tilde{\alpha}_k}(1) \quad (25)$$

このことは、式(7)および式(8)で与えられる POC 関数の期待値および分散が、線形分布とその巻き込み分布の場合の両者において一致することを示している。

位相スペクトル差に線形確率分布を仮定する一般統計学に基づく統計的解析<sup>8)</sup>の結果は、巻き込み分布の考え方を導入することにより、方向統計学に基づく統計的解析の概念で説明ができることを示した。

#### 4.3 巻き込み正規分布を仮定した場合の例

巻き込み分布の具体的な例として、正規分布を円周上に巻き込むことにより得られる巻き込み正規分布について説明する。

式(12)で与えられる正規分布  $N(\mu, \sigma^2)$  の確率密度関数  $p(\alpha_k)$  を式(20)に代入して整理すると、以下の巻き込み正規分布  $WN(\tilde{\mu}, \rho)$  の確率密度関数  $p_w(\tilde{\alpha}_k)$  を得る。

$$p_w(\tilde{\alpha}_k) = \frac{1}{2\pi} \left[ 1 + 2 \sum_{q=1}^{\infty} \rho^{q^2} \cos(q(\tilde{\alpha}_k - \tilde{\mu})) \right] \quad (26)$$


ここで、 $\tilde{\mu}$  は平均方向、 $\rho$  は平均合成ベクトル長であり、もとの正規分布の平均  $\mu$  と分散  $\sigma^2$  とは

$$\tilde{\mu} = \arg(\mu) \quad (-\pi \leq \tilde{\mu} < \pi) \quad (27)$$


$$\rho = e^{-\frac{\sigma^2}{2}} \quad (0 \leq \rho \leq 1) \quad (28)$$

により対応づけられる。また、円周分散  $v (= 1 - \rho)$  は

$$v = 1 - e^{-\frac{\sigma^2}{2}} \quad (0 \leq v \leq 1) \quad (29)$$



(a) 正規分布



(b) 巻き込み正規分布

Fig. 8: 正規分布と巻き込み正規分布の確率密度関数により与えられる。POC 関数の期待値および分散の一般式は、円周分散  $v$  を用いて以下のように表せる。

$$|E[r(m)]| = (1 - v)\delta(m) = e^{-\frac{\sigma^2}{2}} \delta(m) \quad (30)$$

$$\text{Var}[r(m)] = \frac{1}{N}(1 - (1 - v)^2) = \frac{1}{N}(1 - e^{-\sigma^2}) \quad (31)$$

式(30)と(31)はそれぞれ、線形確率分布の正規分布を仮定して導出された式(14)と(15)と一致している。すなわち、位相スペクトル差に巻き込み分布を仮定した場合の結果は、もとの線形確率分布を仮定した場合の結果と一致することが確かめられた。

## 5 むすび

本論文では、円周確率分布のひとつである巻き込み分布に従う位相スペクトル差を持つ信号間の POC 関数の期待値と分散を導出した。まず、2つの信号の位相スペクトル差を線形確率分布に従う確率変数であると仮定した。次に、方向統計学における円周確率分布の生成法のひとつである巻き込み法を用いて、線形確率分布を巻き込み分布に変換した。結果、位相スペクトル差に巻き込み分布を仮定したときの POC 関数の期待値と分散が、もとの線形確率分布を仮定したときの POC 関数の期待値と分散にそれぞれ一致することを示した。すなわち、一般統計学に基づく POC 関数の統計的解析<sup>7)</sup>の結果も、方向統計学の概念を用いて説明できることが示された。

## 参考文献

- 1) C.D. Kuglin and D.C. Hines, "The phase correlation image alignment method," Proc. Int. Conf. Cybernetics and Society, pp.163-165, 1975.
- 2) G. Wolberg and S. Zokai, "Robust image registration using log-polar transform," Proc. IEEE Int. Conf.

- Image Process.(IEEE ICIP), pp.493–496, Vancouver, Canada, Sept. 2000.
- 3) H. Foroosh, J. Zerubia, and M. Berthod, “Extension of phase correlation to subpixel registration,” *IEEE Trans. Image Process.*, vol.11, no.3, pp.188–200, March 2002.
  - 4) M. Hagiwara, M. Abe, and M. Kawamata, “Estimation method of frame displacement for old films using phase-only correlation,” *Journal of Signal Processing*, vol.8, no.5, pp.421–429, Sept. 2004.
  - 5) A.K. Brodzik, “Phase-only filtering for the masses(of DNA data): A new approach to sequence alignment,” *IEEE Trans. Signal Process.*, vol.54, no.6, pp.2456–2466, June 2006.
  - 6) K. Miyazawa, K. Ito, T. Aoki, K. Kobayashi, and H. Nakajima, “An effective approach for iris recognition using phase-based image matching,” *IEEE Trans. Pattern Anal. Mach. Intell.*, vol.30, no.10, pp.1741–1756, Oct. 2008.
  - 7) S. Yamaki, J. Odagiri, M. Abe, and M. Kawamata, “Effects of stochastic phase spectrum differences on phase-only correlation functions —Part I: Statistically constant phase spectrum differences for frequency indices —,” *Proc. IEEE Int. Conf. Network Infrastructure and Digital Content*, pp.360–364, Beijing, China, Sept. 2012.
  - 8) S. Yamaki, M. Abe, and M. Kawamata, “Statistical analysis of phase-only correlation functions based on directional statistics,” *IEICE Trans. Fundam. Electron., Commun., Comput., Sci.*, vol.E97-A, no.12, pp.2601–2610, Dec. 2014.
  - 9) N.I. Fisher, “Statistical analysis of circular data,” Cambridge University Press, 1993.
  - 10) I.L. Dryden and K.V. Mardia, “Statistical shape analysis,” John Wiley & Sons Ltd, 1998.
  - 11) K.V. Mardia and P.E. Jupp, “Directional statistics,” John Wiley & Sons Ltd, 2000.
  - 12) S.R. Jammalamadaka and A. SenGupta, “Topics in circular statistics,” World Scientific, 2001.
  - 13) 清水邦夫, “方向統計学の最近の発展,” *計算機統計学*, vol.19, no.2, pp.127–150, 2006.