

プログラムの簡略化を用いた多峰性遺伝的プログラミングの検証

○村野慧 吉田修武 原田智広 ターウォンマットラック (立命館大学)

Verification of Multimodal Genetic Programming Introducing Program Simplification

* K. Murano, S. Yoshida, T. Harada and R. Thawonmas (Ritsumeikan University)

Abstract— In this research, we introduce program simplification into Multimodal Genetic Programming (MMGP) and verify its effectiveness. In recent years, multimodal optimization that simultaneously acquires a global optimum solution and multiple local optimum ones is studied in an optimization method represented by an evolutionary algorithm (EA). MMGP simultaneously acquires global and local optimum programs in a single run. However, since MMGP divides the solution set to several clusters depending on the tree similarity, some programs cannot be assigned to appropriate cluster when a redundant subtree is generated in the optimization process. To overcome this problem, this research introduces a simplification of a program into MMGP to remove redundant subtrees. The experiment in which MMGP with and without the simplification are compared reveals that the simplification does not significantly improve the search ability of MMGP because the simplification does not affect the optimization process of MMGP in the benchmark problem used in this research.

Key Words: Genetic Programming, Simplification, Multimodal optimization

1 はじめに

近年, 進化的アルゴリズム (EA) に代表される最適化手法において, 大域最適解と複数の局所最適解を同時に獲得する多峰性最適化が研究されている. ここで, 局所最適解とは, 大域最適解よりも低い適応度を持つが, 局所的な領域では最適となる解である. この中で, プログラムを最適化対象とする遺伝的プログラミング (Genetic Programming: GP) ¹⁾ に多峰性最適化の概念を導入し, 大域最適プログラムと局所最適プログラムを同時に獲得する Multimodal Genetic Programming (MMGP) が提案された ²⁾. MMGP ではプログラムの遺伝子表現である木構造の類似度を用いたクラスタリングによって解集団を複数のクラスタに分割し, クラスタ毎に最適化を行うことで多峰性を保った探索が可能な手法である. しかし, MMGP ではクラスタリングに木構造の類似度を用いるため, 最適化の過程で冗長な部分木 (例えば, $x-x$) が生成されると, プログラム同士の木構造の類似度が適切に評価されず, 多峰性探索の妨げになる問題がある.

この問題を解決するために, 本論文では MMGP にプログラムの冗長な部分木を取り除く簡略化 (Simplification) ³⁾ の機構を適用する. GP における簡略化では, プログラムの木構造を末端ノードから走査し, 冗長な部分木があれば簡略化を適用する操作をルートノードまで実行し, 最終的に簡略化された木構造を出力する.

簡略化の影響を分析するため, 本論文では簡略化を適用する MMGP と適用しない従来の MMGP を先行研究で提案された多峰性プログラム最適化のベンチマーク問題に適用する. 本論文では, 簡略化の適用方法として2つの手法を検証する. 1つ目は, 遺伝的操作によって生成される全てのプログラムに対して簡略化を適用する方法である. 2つ目は, 木構造類似度を計算する際は, 簡略化を適用するが, 最適化は簡略化をしないプログラムのまま実行する手法である.

本論文の構成は以下の通りである. 2章では, 一般的な遺伝的プログラミング, 本論文で実験の対象となる多峰性遺伝的プログラミングと簡略化について述べる. 3章では MMGP への簡略化の導入方法について述

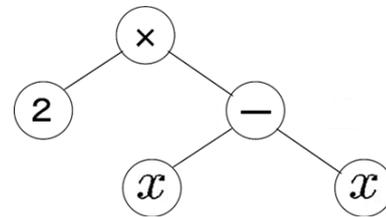


Fig. 1: An example of a tree structure used in GP

べる. 4章では簡略化を導入しない従来の MMGP と簡略化を導入した MMGP を比較する実験を行い, その結果を示す. 最後に5章では, 本論文のまとめと今後の課題とを述べる.

2 関連研究

2.1 遺伝的プログラミング

GP は John Koza によって考案された遺伝的アルゴリズム (Genetic Algorithm: GA) ⁴⁾ の拡張手法であり, 最適化対象として数式やプログラムを扱う. GA における遺伝子型の表現が主に配列であるのに対し, GP では木構造を用いる. これにより, GA では表現できなかった数式やプログラムのコードなど, 構造を持ったデータを表現することができる.

Fig. 1 に $(2 \times (x - x))$ という数式を表現する木構造の例を示す. この木構造は演算子 (図中“ \times ”と“ $-$ ”) と変数 (図中“ x ”), 定数 (図中“ 2 ”) で構成される.

2.2 多峰性遺伝的プログラミング (MMGP)

2.2.1 多峰性最適化問題

多峰性最適化問題は, 大域最適解だけでなく, すべての局所最適解を求める問題である. 局所最適解とは, 局所的な領域における最適解である. Fig. 2 に多峰性最適化問題の例を示す. Fig. 2 において縦軸は適応度, 横軸は探索空間を表し, 適応度が高いほど優良解であ

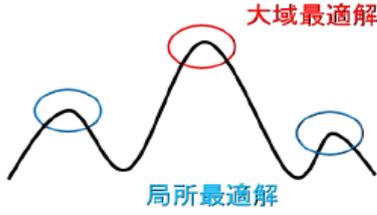


Fig. 2: An example of the multimodal optimization problem

るとする. このとき, 赤丸に示される解は探索空間全体の中で優良の解であることから大域最適解, 青丸で示される解は大域最適解よりは適応度が劣るが局所的な領域では最良の解であることから局所最適解とそれぞれ定義される.

2.2.2 多峰性プログラム最適化問題

本論文では, 先行研究²⁾で提案された多峰性プログラム最適化問題のベンチマーク問題を使用する. このベンチマークは 4 変数 x, y, z, w を入力とし, 以下の式により与えられる入出力値に基づく関数同定 (symbolic regression) 問題として定義する:

$$f(x, y, z, w) = x^2 + y^2 \quad (1)$$

$$z = (x + y + a)^2 + \delta \quad (2)$$

$$w = a^2/2 + xy + xa + ya + \delta \quad (3)$$

ここで a は定数であり, δ は変数 z と w に与えられる誤差を示す. δ が 0 の場合, この式は次のように再構成される.

$$f(x, y, z, w) = x^2 + y^2 \quad (4)$$

$$= z - 2w \quad (5)$$

式 (1) より, 与えられた入出力値を変数 z と w を用いて式 (5) で表現できる. δ が 0 よりも大きく, z と w に誤差が加えられる場合, 式 (5) で算出される値は大域最適解の計算結果と比較して誤差が含まれることから局所最適解とみなすことができる.

2.2.3 MMGP のアルゴリズム

Algorithm 1 に MMGP の疑似コードを示す. Algorithm 1 で, C_g は g 世代のクラスタリングされた母集団を示し, C_g^i は C_g の i 番目のクラスタを示す. MMGP では, 5 行目から 18 行目で新規個体を生成する. 11 行目では, 選択された 2 個体に対して交叉を行う. 14 行目では, 選択された個体に対して突然変異を行う. 交叉では, あるクラスタ C_g から親 $p1$ を選択し, ランダムに選択されたクラスタ C_r から別の親 $p2$ を選択する. この選択により, すべてのクラスタを均等に参照しながら, 各クラスタ内で個体を局所的に最適化できる. 突然変異

Algorithm 1 A flow of MMGP

```

1:  $P_0 \leftarrow$  random initialization
2:  $C_0 \leftarrow$  clustering( $P_0$ )
3: for  $g = 0$  to  $G$  do
4:    $P'_g \leftarrow \phi$ 
5:   for  $i = 1$  to  $|C_g|$  do
6:     for  $j = 1$  to  $|P_g|/|C_g|$  do
7:       if rand(0,1) < crossover probability then
8:          $p1 =$  tournament( $C_g^i$ )
9:          $r =$  randint(0,  $C_g$ )
10:         $p2 =$  tournament( $C_g^r$ )
11:        newIndividual  $\leftarrow$  crossover( $p1, p2$ )
12:      Else
13:         $p =$  tournament( $C_g^i$ )
14:        newIndividual  $\leftarrow$  mutation( $p$ )
15:      end if
16:       $P'_g \leftarrow P'_g \cup \{newIndividual\}$ 
17:    end for
18:  endfor
19:  $P_{g+1} \leftarrow P_g \cup P'_g$ 
20:  $C_{g+1} \leftarrow$  clustering( $P_{g+1}$ )
21: for  $i = 1$  to  $|C_{g+1}|$  do
22:    $L_i = \text{Max}(1, |C_{g+1}^i|)$  do
23: end for
24: while  $|P_{g+1}| > |P_g|$  do
25:   for  $i = 1$  to  $|C_{g+1}|$  do
26:     if  $|P_{g+1}^i| = |P_g| \vee |C_{g+1}^i| \leq L_i$  then
27:       Break
28:     end if
29:      $p \leftarrow$  negative_tournament( $C_{g+1}^i$ )
30:      $C_{g+1}^i \leftarrow C_{g+1}^i \setminus \{p\}$ 
31:   end for
32: end while
33: end for

```

では, クラスタ C_i から親が選択される. 次に, 20 行目で, 現母集団 P_g と新規個体集団 P'_g を用いて Rui らの類似度計算⁵⁾ (詳細は 2.2.4 節) に基づいてクラスタリングする. 24 行目から 32 行目で母集団がもとの母集団サイズに戻るまで評価値の低い個体を削除する. この時, クラスタ内の個体が消滅することを防ぐため, 各クラスタ内の個体が半数以下, または 1 以下とならないように制限する. それでも, 元の母集団サイズに戻らない場合, 評価値の低い個体から削除する. これらの処理を世代数の制限まで繰り返す.

2.2.4 木構造間類似度

MMGP では, クラスタリングに用いる類似度の指標として, Rui らが提案した木構造間の類似度計算⁵⁾ を用いる. この類似度計算は木構造間の編集距離を算出する Tree Edit Distance⁶⁾ よりも少ない計算量で算出可能である. 類似度計算では, 各木構造に対して Binary Branch Vector と呼ばれる表現を用いて特徴ベクトルを算出し, そのベクトルを用いて類似度を計算する.

3 提案手法

従来の MMGP では、大域最適解と局所最適解を同時に獲得するために、木構造類似度に基づくクラスタリングが重要な役割を持つ。しかし、プログラムに冗長な部分木（例えば、 $x-x$ ）が含まれる場合、適切な類似度を計算できず、クラスタの分割が正常に機能しない場合がある。具体的には、冗長な部分木を含む以外は同様の機能をもつプログラムが異なるクラスタに分類される、あるいは全く異なる機能をもつプログラムが冗長な部分木によって類似度が増加して同じクラスタに分類される可能性がある。この問題を解決するために、本研究では MMGP に冗長な部分木を除去するプログラムの簡略化を導入する。

3.1 プログラムの簡略化(Simplification)

プログラムの簡略化の目的はプログラムに含まれる冗長的な部分木を除去することによって、より小さいプログラムを得ることである。例えば、 $x-x$, y/y のような部分木は、 $x-x=0$, $y/y=1$ のように簡略化が可能である。プログラムの簡略化には様々な方法が存在するが、本研究ではあらかじめ定義された複数のルールに基づく Wong らの簡略化³⁾を使用する。

Table. 1 に簡略化のルールを示す。Table. 1 では、定数は小文字（例： a, b, x, j ）で表され、変数は大文字（例： A, B, X, J ）で表される。Precondition はルール適用前の部分木、Effective Result は適用後の簡略化結果を表す。まず、木構造を末端ノードから走査し、Table. 1 のルールに当てはまるものがあれば、ルールに従って簡略化を行う。下の Table. 1 のルールに当てはまるものが無くなれば、全ての簡略化が終了した後に、結果を出力する。

具体的には、以下の手順で簡略化を行う。

- 1) 木構造を末端ノードから順番に走査する。
- 2) 走査して末端ノードが 2 個続けて変数、定数、またはハッシュ値だった場合、その末端ノード 2 つにハッシュを適用して計算し、ハッシュ値として出力する。
- 3) ハッシュを適用するノードが Table. 1 の簡略化のルールの条件と一致する場合、そのルールを適用して簡略化する。
- 4) 全てのノードが処理されるまで繰り返し、最終的な簡略化された木構造を出力する。

3.2 プログラムの簡略化を導入した MMGP

本研究では、MMGP にプログラムの簡略化を導入することで、適切なクラスタリングを実現し、探索性能の向上をはかる。簡略化の導入方法として、本研究では 2 つの方法を検証する。1 つ目は、最適化の過程ですべてのプログラムに簡略化を適用し、簡略化をした

Table 1: The rule of simplification³⁾

Precondition	Effective Result
$If < 0 (a, b, C) \rightarrow$	$B \text{ if } a < 0, \text{ else } C$
$If < 0 (A, B, C) \rightarrow$	B
$a + b \rightarrow$	$c, c = a + b$
$a - b \rightarrow$	$c, c = a - b$
$a \times b \rightarrow$	$c, c = a \times b$
$a \div b \rightarrow$	$c, c = a \div b$
$a + (b + C) \rightarrow$	$c + C, c = a + b$
$a + (b - C) \rightarrow$	$c - C, c = a + b$
$a - (b + C) \rightarrow$	$c - C, c = a - b$
$a - (b - C) \rightarrow$	$c + C, c = a - b$
$a \times (b \times C) \rightarrow$	$c \times C, c = a \times b$
$a \times (b \div C) \rightarrow$	$c \div C, c = a \times b$
$a \div (b \div C) \rightarrow$	$c \times C, c = a \div b$
$a + (B + c) \rightarrow$	$b + B, b = a + c$
$a + (B - c) \rightarrow$	$b + B, b = a - c$
$a - (B + c) \rightarrow$	$b - B, b = a - c$
$a - (B - c) \rightarrow$	$b - B, b = a + c$
$a \times (B \times c) \rightarrow$	$b \times B, b = a \times c$
$a \times (B \div c) \rightarrow$	$b \times B, b = a \div c$
$a \div (B \div c) \rightarrow$	$b \div B, b = a \times c$
$A \div 1 \rightarrow$	A
$A \div A \rightarrow$	1
$0 \div A \rightarrow$	0
$0 \times A = A \times 0 \rightarrow$	0
$A \times 1 = 1 \times A \rightarrow$	A
$A + 0 = 0 + A \rightarrow$	A
$A - 0 \rightarrow$	A
$A - A \rightarrow$	0
$A \times \frac{1}{B} = \frac{1}{B} \times A \rightarrow$	$\frac{A}{B}$
$A \times \frac{B}{A} = \frac{B}{A} \times A \rightarrow$	B

プログラムを進化する方法 (MMGP with full simplification, 以降 MMGP-FS). 2 つ目は、MMGP の類似度計算の際にのみ簡略化を適用し、最適化は簡略化をしないプログラムのまま実行する方法 (MMGP with simplification for clustering, 以降 MMGP-SC) である。

4 実験

4.1 実験手法

簡略化の有効性を検証するため、本論文では多峰性プログラム最適化問題を用いる実験を行う。実験では、簡略化を用いない MMGP と上記で述べた 2 手法と比較する。本実験ではプログラムの木の最大深さは先行研究で用いられた 4 に加え、最大深さ 8 も使用し、複雑な木構造での簡略化の効果を検証する。MMGP では、クラスタリングを打ち切る閾値 d によって結果が異なるため、閾値 $d = \{0.5, 0.6, 0.7, 0.8, 0.9\}$ で比較する。教師データは、変数 x と y をそれぞれ -1 から 1 までの 0.2 刻みで 121 個とし、式(2)と式(3)の α は 2, δ は平均 0, 標準偏差 0.1, 0.01, 0.001 の正規分布で与える 3 種類

Table 2: Success ratio of finding the global and local optimal solutions ($\delta = 0.1$, maximum depth=4)

d	Original MMGP		MMGP-FS		MMGP-SC	
	Global	Local	Global	Local	Global	Local
0.5	100%	100%	100%	100%	100%	100%
0.6	100%	100%	100%	100%	100%	100%
0.7	100%	100%	100%	100%	100%	100%
0.8	100%	100%	100%	100%	100%	100%
0.9	100%	85%	100%	90%	100%	90%

Table 3: Success ratio of finding the global and local optimal solutions ($\delta = 0.01$, maximum depth=4)

d	Original MMGP		MMGP-FS		MMGP-SC	
	Global	Local	Global	Local	Global	Local
0.5	100%	100%	100%	100%	100%	100%
0.6	100%	100%	100%	100%	100%	100%
0.7	100%	100%	100%	100%	100%	100%
0.8	100%	100%	100%	100%	100%	100%
0.9	100%	90%	100%	80%	100%	90%

Table 4: Success ratio of finding the global and local optimal solutions ($\delta = 0.001$, maximum depth=4)

d	Original MMGP		MMGP-FS		MMGP-SC	
	Global	Local	Global	Local	Global	Local
0.5	100%	100%	100%	100%	100%	100%
0.6	100%	100%	100%	100%	100%	100%
0.7	100%	100%	100%	100%	100%	100%
0.8	100%	100%	100%	100%	100%	100%
0.9	100%	95%	100%	95%	100%	90%

を使用する。試行回数は 20 回とし、世代数は 500 世代とする。母集団サイズは 500 個体、交叉確率は 0.9 とする。変数として x, y, z, w の 4 つ。関数ノードは $+$, $-$, \times , \div の 4 つ、実数定数値の c を用いる。適応度関数は下記の式を使用する:

$$fitness = \sum_{i=1}^D |result_i - target_i| \quad (6)$$

ここで、 D は教師データ数とし、 $result_i$ は個体の i 番目の教師データの入力値に対する計算結果、 $target_i$ は i 番目の教師データの出力値とする。標準偏差の値に応じて、局所最適解の適応度はそれぞれ、20, 2, 0.2 ほどになる

4.2 評価基準

提案手法、および MMGP で遺伝子型の異なる大域最適解と局所最適解を同時に獲得できているかを評価するために、本実験では変数の一つを制限した場合の最良個体を確認する。具体的には、各試行で得られる解集団の中で、 x, y, z, w のそれぞれの変数を含まないプログラムの中で最良の適応度を求め、20 試行分の分布を調べる。例えば、式(5)に示す局所最適解が獲得されている場合、変数 x を制限した場合も変数 y, z と w を用いるプログラムで低い (優れた) 適応度を達成できるため、変数 x を制限した場合の最良の適応度は低い値に分布する。これにより、大域最適解と局所最適解が 1 試行で同時に獲得できることを示す。

Table 5: Success ratio of finding the global and local optimal solutions ($\delta = 0.1$, maximum depth=8)

d	Original MMGP		MMGP-FS		MMGP-SC	
	Global	Local	Global	Local	Global	Local
0.5	100%	100%	100%	95%	100%	100%
0.6	100%	95%	100%	100%	100%	100%
0.7	100%	100%	100%	100%	100%	100%
0.8	100%	85%	100%	60%	100%	85%
0.9	100%	60%	100%	35%	100%	35%

Table 6: Success ratio of finding the global and local optimal solutions ($\delta = 0.01$, maximum depth=8)

d	Original MMGP		MMGP-FS		MMGP-SC	
	Global	Local	Global	Local	Global	Local
0.5	100%	100%	100%	100%	100%	100%
0.6	100%	100%	100%	100%	100%	100%
0.7	100%	100%	100%	100%	100%	85%
0.8	100%	95%	100%	100%	100%	70%
0.9	100%	60%	100%	80%	100%	40%

Table 7: Success ratio of finding the global and local optimal solutions ($\delta = 0.001$, maximum depth=8)

d	Original MMGP		MMGP-FS		MMGP-SC	
	Global	Local	Global	Local	Global	Local
0.5	100%	100%	100%	100%	100%	100%
0.6	100%	100%	100%	100%	100%	100%
0.7	100%	100%	100%	100%	100%	100%
0.8	100%	95%	100%	85%	100%	80%
0.9	100%	80%	100%	50%	100%	65%

4.3 実験結果

Table 2~7 に簡略化を用いない従来の MMGP と簡略化を導入した 2 つの MMGP (MMGP-FS, MMGP-SC) が 20 試行中で最終母集団に大域最適解 (式(1)の表現) と局所最適解 (式(5)の表現) を含む割合を示す。Table 2~4 は最大深さ 4 の結果、Table 5~7 は最大深さ 8 の結果を表す。これらの結果から、いずれの手法も閾値 d を適切に設定することで大域最適解と局所最適解を高い割合で獲得可能であることがわかる。特に、 $d = 0.6, 0.7$ の場合にいずれかの手法も探索成功率 100% を達成していることがわかる。一方、 $d = 0.8, 0.9$ の場合は局所最適解の探索成功率が低下していることがわかる。特に、クラスタリングの時のみ簡略化を適用する MMGP-SC で他の手法と比較して局所最適解の発見率が低下していることがわかる。

次に Fig. 3, 4 に各手法でそれぞれの変数を含まない中での最良適応度の世代推移を示す。ただし、誤差を与える正規分布の標準偏差は 0.01、閾値は探索成功率が 100% に近い $d = \{0.5, 0.6, 0.7\}$ の結果のみ示している。縦軸は適応度、横軸は世代数を表す。水色、橙色、灰色、黄色、青色の線は、それぞれ変数を制限しない (No restriction), x を含まない場合 (without x), y を含まない場合 (without y), z を含まない場合 (without z), w を含まない場合 (without w) を表す。Fig. 3, 4 か

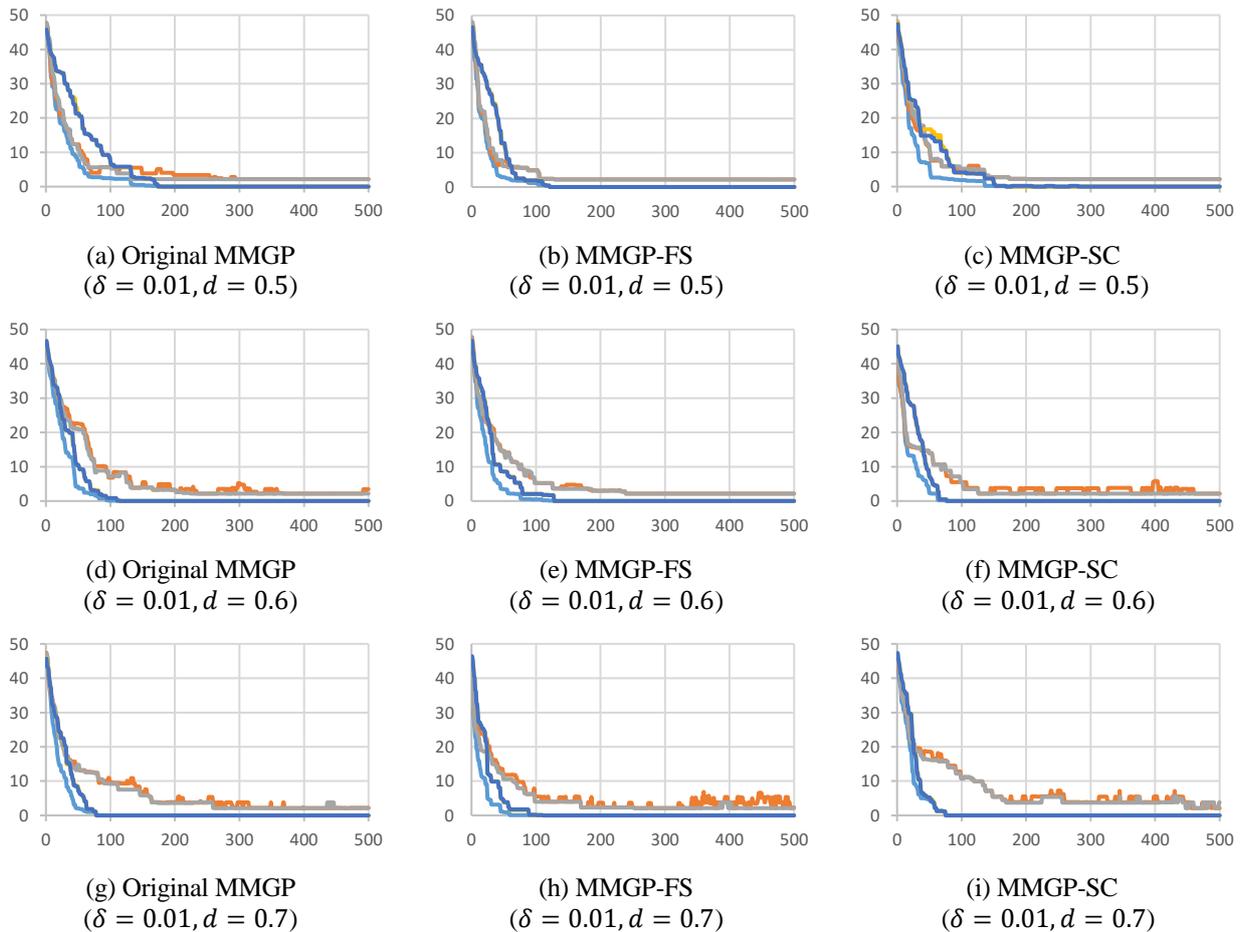


Fig. 3: Experimental result (maximum depth=4).

Blue: No restriction, Orange: without x, Gray: without y, Yellow: without z, Blue: without w.

ら、閾値が高くなるほど、局所最適解を発見する速度が遅くなり、また、閾値 $d=0.7$ の時のMMGP-SCは、他の手法と比べて、さらに遅くなっていることがわかる。しかし、それ以外では、どの手法もあまり推移の違いが見られず、局所最適解を獲得できていることがわかる。

以上の結果から、MMGPに簡略化を導入した場合も、探索性能に大きな影響を与えないことが明らかになった。また、クラスタリングの閾値を大きく設定した場合に局所最適解の探索性能が著しく低下することが示された。

4.4 考察

実験の結果から、プログラムの簡略化はMMGPの探索性能に大きな影響をあたえないことが示された。本節ではこの理由を考察する。

Fig. 5にクラスタ数の世代推移、Fig. 6に1世代あたりに簡略化が適用された回数を示す。Fig. 5において縦軸はクラスタ数、横軸は世代数を表す。Fig. 6において縦軸は1世代あたりにプログラムの簡略化が適用された回数、横軸は世代数を表す。水色は簡略化を用いないMMGP、橙色はMMGP-FS、灰色はMMGP-SCの結果をそれぞれ示す。なお、いずれも最大深さ8、標

準偏差0.01、閾値 $d=0.6$ の時の結果を示している。

4.4.1 MMGP-FS

Fig. 5より、簡略化を導入することで従来のMMGPよりもMMGP-FSのクラスタ数が減少していることがわかる。これは、従来のMMGPでは冗長な部分木を含むことで類似度が低下していたプログラム同士が、簡略化によって類似度が高まり、同一のクラスタに分類される可能性が高まったためである。このことから、プログラムの簡略化はMMGPの探索の際のクラスタリングの結果に影響を及ぼしていることがわかる。

一方、Fig. 6から、プログラムの簡略化は最適解の初期（特に10世代目まで）は多数適用されているが、それ以降はほとんど適用されていないことがわかる。具体的には、毎世代生成される500個体中、簡略化が適用されているのは25個体（5%）程度である。さらに、Fig. 5から、MMGP-FSにおいて初期世代ではクラスタ数が減少しているが、その後探索が進むにつれてMMGPと同様にクラスタ数が増加している。このことから、MMGP-FSでは簡略化の効果が現れるのは探索初期のみであり、それ以降は、従来のMMGPと同様に最適化を行ったため、最適化性能に大きな違いが見られなかったと考えられる。

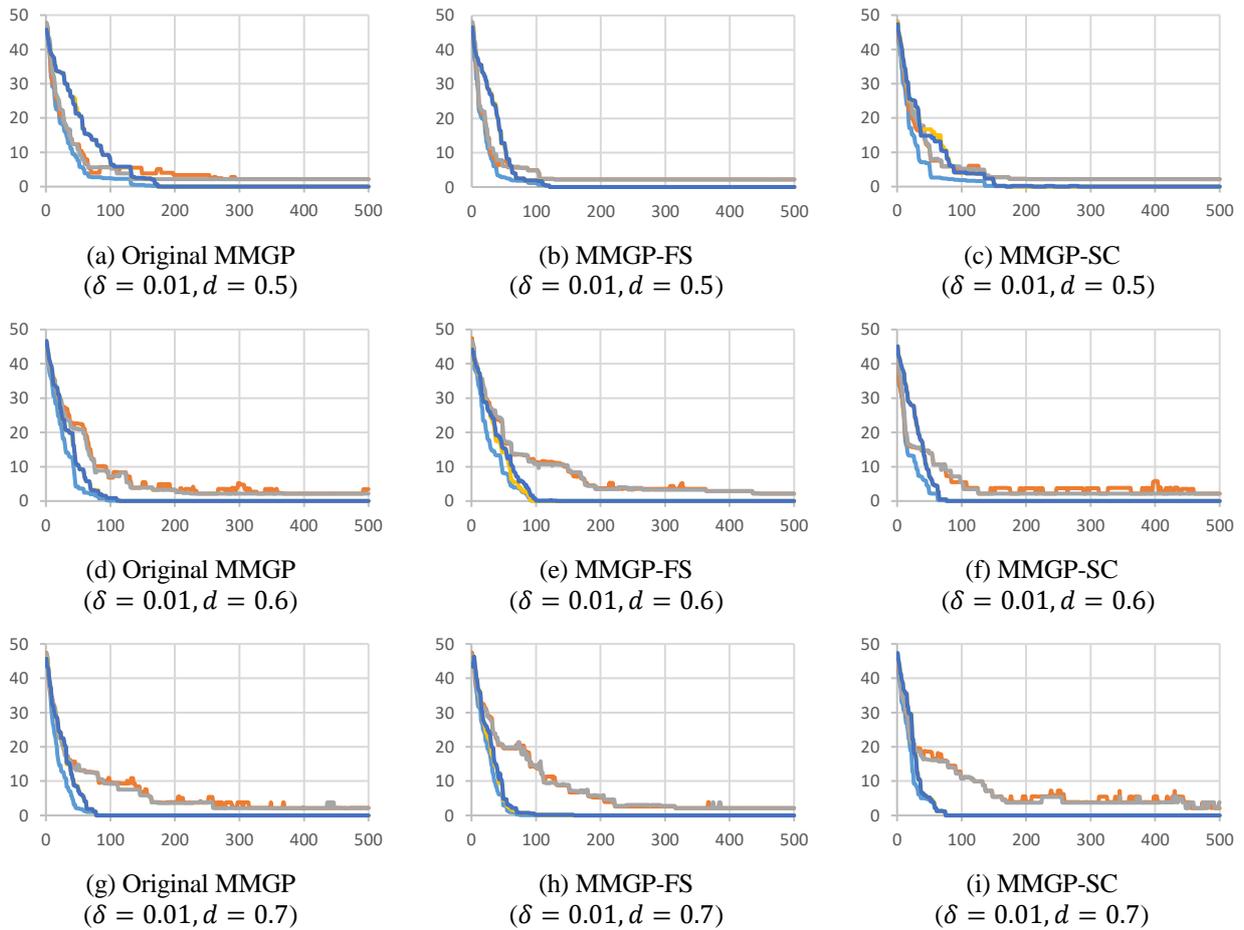


Fig. 4: Experimental result (maximum depth=8).

Blue: No restriction, Orange: without x, Gray: without y, Yellow: without z, Blue: without w.

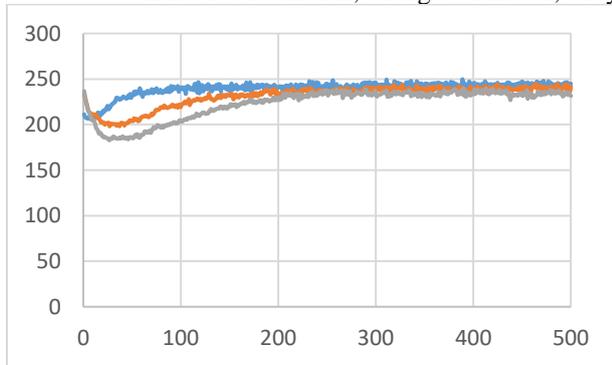


Fig. 5: The number of clusters in $\delta = 0.01$ and $d = 0.6$.

Light blue : Original MMGP, Orange : MMGP-FS.
Gray : MMGP-SC

4.4.2 MMGP-SC

クラスタリングのときだけ簡略化をする MMGP-SC も MMGP-FS と同様に探索初期にクラスタ数が減少するが、探索が進むにつれてクラスタ数は増加していることがわかる。一方、簡略化の回数は 150~200 回の間を推移している。これは、クラスタリングのときにだけ簡略化を適用し、実際に遺伝的操作の対象となるのは簡略化前の解であるためである。

従来の MMGP と比較して、最適化性能に大きな違いが見られない理由は、簡略化の有無が生存選択や遺

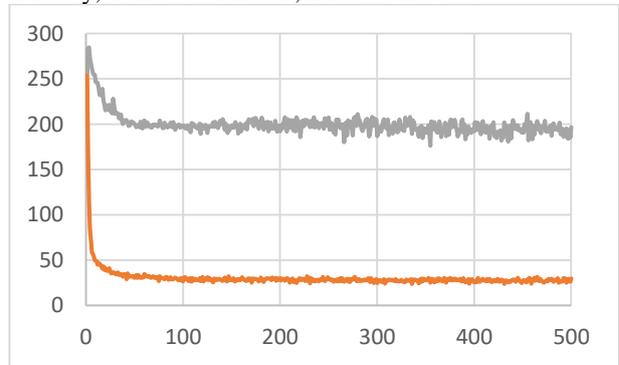


Fig. 6: The number of applications of simplification in $\delta = 0.01$ and $d = 0.5$.

Orange : MMGP-FS, Gray : MMGP-SC

伝的操作の結果に大きな影響を与えないためである。例えば、 $x^2 + y^2$ というプログラムと冗長な部分木を含む $x^2 + y^2 + z - z$ というプログラムの 2 個体が存在した場合を考える。従来の MMGP では同じクラスタには入らないが、どちらも優れた適応度を有するため生存選択で選択される確率が高い。一方、MMGP-SC ではこれらのプログラムは同じクラスタに分類されるが、どちらも優れた適応度を有するため、同様に淘汰されることが無い。一方、遺伝的操作（特に交叉）では、対象となるクラスタとランダムな他のクラスタから親

個体を選択するため、特にクラスタ数が多い場合には同一クラスタに属している場合も異なるクラスタに属する場合も遺伝的操作の結果に大きな影響はないと考えられる。このことから、MMGP と MMGP-SC の結果に大きな差が見られなかったと考えられる。

5 まとめ

本論文では、多峰性プログラム最適化の解法である MMGP において、冗長な部分木によって木構造（プログラム）の類似度が適切に評価されない問題を解決するために、プログラムの簡略化を導入し、その影響を分析した。具体的には、すべてのプログラムに簡略化を適用し、簡略化したプログラムを進化する方法（MMGP-FS）と、MMGP の類似度計算の際にのみ簡略化を適用し、最適化は簡略化をしないプログラムのまま実行する方法（MMGP-SC）を提案した。簡略化を適用しない従来の MMGP と 2 つの提案手法を多峰性プログラム最適化のベンチマーク問題に適用する実験を行い、簡略化の影響を分析した。

実験の結果、全ての手法において、大域最適解と局所最適解の探索性能に大きな差は見られないことを示した。これは、MMGP-FS では、初期世代以外では簡略化がほとんど適用されず、影響が小さいためである。一方、MMGP-SC では、特にクラスタ数が多い場合に簡略化によるクラスタリング結果が生存選択や遺伝的操作の結果に与える影響が小さいためである。

今回の実験において、冗長な部分木を削除する簡略化を導入した場合も、MMGP の探索性能に与える影響が小さいことが明らかになった。しかし、この結果は遺伝的操作法の変更や扱う多峰性プログラム最適化問題の特性によっても変化する可能性がある。そのため、今後は、遺伝的操作法の違いと簡略化の影響を分析するとともに、本研究で使用したベンチマーク問題以外の複雑な問題に対しても MMGP を適用し、簡略化と多峰性探索の関係性を明らかにする。

参考文献

- 1) John Koza: Genetic Programming On the Programming of Computers by Means of Natural Selection, MIT Press, (1992).
- 2) 吉田 修武, 原田 智広, ターウォンマツ ラック, "木構造類似度を用いる多峰性遺伝的プログラミング," 計測自動制御学会論文誌, 第 54 巻第 8 号, 2018. (採録決定済み)
- 3) Phillip Wong, Mengjie Zhang: Algebraic simplification of GP programs during evolution, GECCO '06 Proceedings of the 8th annual conference on Genetic and evolutionary computation, Pages 927-934, (2006)
- 4) David E. Goldberg: Genetic Algorithms in Search, Optimization and Machine Learning, Addison-Wesley Long man Publishing Co., Inc., Boston, MA, USA,

(1989).

- 5) Yang Rui, Panos Kalnis, and Anthony KH Tung: Similarity evaluation on tree-structured data, Proceedings of the 2005 ACM SIGMOD international conference on Management of data, ACM, pp. 754-765, (2005).
- 6) Kaizhong Zhang and Dennis Shasha: Simple fast algorithms for the editing distance between trees and related problems, SIAM Journal on Computing, 18:1245-1262, pp. 1245-1262, (1989)

エネルギーマネジメントを考慮した ジョブショップスケジューリング問題に対する Reactive Hybrid Particle Swarm Optimization の提案

○川口嵩平 福山良和 (明治大学大学院)

Reactive Hybrid Particle Swarm Optimization for Job-Shop Scheduling Problems Considering Energy Management

* S. Kawaguchi and Y. Fukuyama (Meiji University)

Abstract— This paper presents reactive hybrid particle swarm optimization based job-shop scheduling problems considering energy management. Conventionally, the scheduling in factories and optimization of energy plants have been solved separately. Namely, energy costs have been ignored when the scheduling is optimized. However, it should be considered from the management point of view. This paper tries to optimize production scheduling and energy plant in order to minimize production time (makespan) and total energy costs simultaneously. Effectiveness of the proposed method is verified through simulations with 10 jobs 10 machines problem and it is verified that the proposed method obtain higher quality solutions than the conventional method.

Key Words: Job-shop scheduling problem, Energy management, Reactive hybrid particle swarm optimization, Combinatorial optimization problem

1 はじめに

工場における生産計画問題は、工場に課せられた顧客納期を守りながら製品を製造・納品を行うために重要な問題である。生産計画問題は通常、ある制約のもとで納期を最小化する組合せ最適化問題として定式化され、最適化問題の中で典型的な問題の一つとして研究が行われてきた^{1,2)}。その中で機械の処理順序が異なる多数のジョブを扱う生産形態のことをジョブショップと呼び、ジョブショップ型の生産形態を持つ工場におけるスケジューリング問題をジョブショップスケジューリング問題(以下、JSP)という。JSPは問題の規模が大きくなるにつれて組合せの数が膨大になり、最適解を得ることが難しくなる問題として知られている³⁾。この問題の規模の拡大に対応するために、様々な進化計算手法^{1,2,4-7)}が適用されてきた。近年では、実際の工場内での制約に合わせたより実用的なJSPへの適用検討も行われている⁸⁻⁹⁾。

従来のJSPの研究は、全ての工程が終わった際の総生産時間(以下、メイクスパン)の最小化のみに注力してきた²⁾。しかし、工場の運営コストの中で工場の1次エネルギーコストは大きな比重を占めており、経営的観点から見て1次エネルギーコストの最小化は重要である。研究の動向として、2次エネルギー消費の最小化を考慮した生産計画の最適化を行う研究は、著者らの研究を含めいくつか行われている¹⁰⁻¹¹⁾。しかし、これら研究は、ピーク時の2次エネルギーを抑えることを実現できているが、エネルギープラントが不適切な運用を行う場合、ピーク時間帯のエネルギー購入が増大する可能性が考えられる。つまり、工場での2次エネルギーのピークシフトだけでは、1次エネルギーコストの最小化は実現できない。また、現状としてエネルギープラント最適運用計画問題は2次エネルギー消費量を固定値として解かれている¹²⁾。すなわち、エネルギープラントの最適運用を行う際、生産計画は固

定値として研究が行われてきた。しかし、1次エネルギーコストの最小化は、生産計画とエネルギープラント最適運用を同時に考慮することで実現できる。

近年、現実の生産計画は消費者のニーズの多様化により、単品種多量生産から多品種少量生産に移行が進んでいる。Tabu Search(以下、TS)の場合、他の手法に比べパラメータが唯一初期タブーリスト長(以下、TL長)のみと少ないという利点がある。しかし、探索効率性は初期TL長に深く依存するため、シミュレーションの際、毎回初期TL長を事前に調整しなければならない¹³⁾。一方、TSの改良版手法であるReactive Tabu Search(以下、RTS)は、探索の中でTL長を自動調整することが出来る¹⁴⁾。著者らはエネルギーマネジメントを考慮したJSPに対してParallel Reactive Tabu Search(以下、PRTS)を用いた解法を提案した¹⁵⁾。この提案法により、TL長を探索毎に自動調整することで初期TL長の事前調整をせずに、メイクスパンの最小化と1次エネルギーコストの最小化を定量的に評価できるスケジューリングを得ることを確認した。つまり、多品種少量生産への対応が可能であることを確認した。しかし、解の質に改善の余地があった。これに対しHPSOは、PSOとTSを統合することでTSのみを用いたJSPへの適用手法に比べ、より質の高い解を生成できることを提案しており¹⁶⁾、HPSOと著者らが提案しているPRTSを統合することにより、解の質の改善が期待できる。

本論文では、Reactive Hybrid Particle Swarm Optimization(以下、RHPSO)を用いてJSPを解く際に、スケジューリングの情報をもとにエネルギーマネジメントシステム(以下、EMS)を用いてスケジューリングの1次エネルギーコストを求め、1次エネルギーコスト最小化を目的関数に入れることにより、これまでのメイクスパン最小化だけでなく、最適なエネルギーや機器の運用を行う解法を提案する。提案法は、10機械10ジョブのJSPに適用することにより、解の質の向上を確認した。また、目的関数の重みを変更することにより、目

的に合った生産計画及び1次エネルギーコストを得られることを確認した。

2 EMSを考慮したJSPの定式化¹⁵⁾

本論文ではfig. 1に示すように主問題をJSP, 副問題をEMSと定め, 双方を考慮することで最適なスケジューリング及び最適なエネルギー・機器の運用方法を行うモデルを構築した。

2.1 主問題

主問題であるJSPは, 以下のように記述できる⁴⁾. J 個の各ジョブは M 台の機械を使って生産を行い, 各ジョブは M 個の工程を持ち, ジョブによって機械の処理時間や工程順序が予め決まっているものとする. 機械は故障しないことを前提とし, 一つの機械は同時に2つ以上のジョブを処理できない. また, 一度処理が開始された機械工程は途中で中断できない. これらの条件を満たし, メイクスパンを最小化することを目的とした問題である. 本研究では, 機械のエネルギー消費量も予め決めている. 例として, 3機械3ジョブ問題の場合の条件をTable 1に示す. この情報を用いることで, 1つのスケジュールを表現することが可能となる. また, 主問題にて求めたスケジュールを基にスケジュールのエネルギー負荷を求め副問題に送り, 副問題を解く (Fig. 2参照).

(a) 決定変数

決定変数は, 各工程の作業終了コマ番号 $FOE(O_{m,j}) (m = 1, 2, \dots, M, j = 1, 2, \dots, J)$ となる. ここで, $O_{m,j}$ は, ジョブ j の機械 m の工程である. 従って, 決定変数の数は, $M \times J$ となる. この $M \times J$ の決定変数が決まれば解となるスケジュールが決定する.

(b) 目的関数

全工程が終了するまでのメイクスパンの最小化と1つのスケジュールにかかる1日のエネルギーコスト (購入電力量, 購入ガス量の和) の最小化を目的関数とす

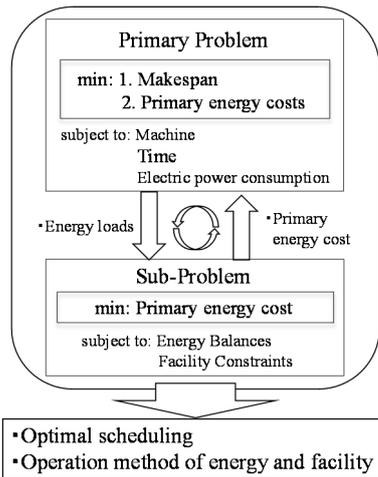


Fig 1: The relationship between JSP and EMS.

Table 1: An Example of JSP with 3 jobs and 3 machines.

Job Num	Technical order in every jobs (Machine Num, Processing Time, Electric Power energy Consumption)		
	Machine Num	Processing Time	Electric Power energy Consumption
Job1	(1, 3, 2)	(2, 2, 2)	(3, 1, 1)
Job2	(2, 5, 3)	(1, 2, 2)	(3, 3, 3)
Job3	(3, 1, 1)	(1, 5, 1)	(2, 4, 2)

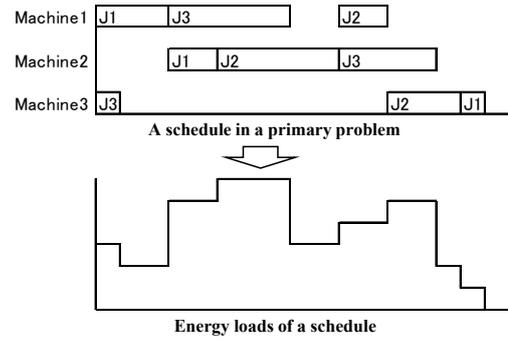


Fig 2: Calculation of an energy load using a schedule.

る. なお, 本問題は一般的には多目的関数となるが, この2つの目的関数をスカラー化手法により1つの目的関数とした.

$$\text{minimize } w_1 \times MS + w_2 \times EC + w_p \times Penalty \dots (1)$$

$$MS = \max FOE(O_{m,j}) \dots (2)$$

ここで, MS :メイクスパン, EC :1日のエネルギーコスト, w_1, w_2 :目的関数の各項に対する重み係数 ($w_1 + w_2 = 1$), w_p :ペナルティ値に対する重み係数, $Penalty$:制約条件式 (7)を越えた分を二乗した時の和の合計値

(c) 制約条件

以下にJSPの制約条件式を示す.

$$MS \geq FOE(O_{m,j}) \dots (3)$$

$$FOS(O_{m,j}) \geq 0 \dots (4)$$

$$FOE(O_{m,j}) = FOS(O_{m,j}) + T_{m,j} \dots (5)$$

$$FOS(O_{m+1,j}) \geq FOE(O_{m,j}) \dots (6)$$

$$MS \leq MSlimit \dots (7)$$

ここで, $FOS(O_{m,j})$:各工程の作業開始コマ番号, $T_{m,j}$:各工程の処理コマ数, $MSlimit$:メイクスパン上限値

制約条件式 (7)を満たさない場合, 制約違反量の2乗ノルムの合計にペナルティ係数を乗じた値を目的関数値にペナルティ値として付加する((1)式第3項)外点ペナルティ関数を用いた.

2.2 副問題

副問題であるエネルギープラントは, 電気学会産業応用部門「情報知能システムの新展開とその産業応用調査専門会」がまとめた「産業応用のための最適化ベンチマーク問題集」の3.2節「エネルギープラント運用計画のための最適化ベンチマーク問題」にて提案されたモデルである¹⁷⁾. そのエネルギープラントをfig. 3に示す. このプラントは, 電力負荷に対し, 電力会社か

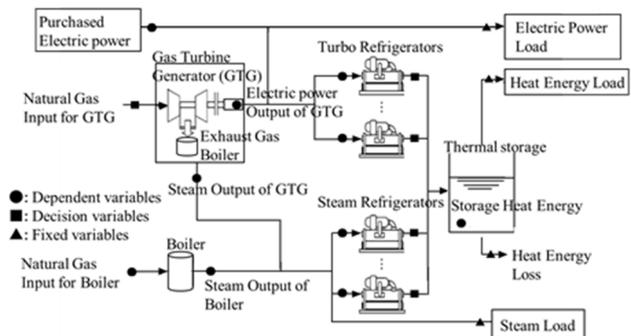


Fig 3: A Target Energy Plant¹⁷⁾.

らの購入電力とガスを購入し、ガスタービンの発電により電力エネルギーを供給し、蒸気負荷に対しては、ガスタービンの排熱とボイラでの蒸気生成、熱負荷にはターボ冷凍機、蒸気吸収式冷凍機によって冷水を供給する構成となっている。副問題であるエネルギープラント最適運用計画問題は、線形計画問題、混合整数線形計画問題、混合整数非線形計画問題^{12,18)}として定義することが出来る。本論文では、副問題を線形計画問題として定式化し、数値計画法のソルバーの1つであるGLPK¹⁹⁾を用いて解いている。

(a) 決定変数

EMSにおける決定変数は以下に示す、1日24時間、つまり24点の入出力の数値を決定変数(連続値)となる。

- ・ターボ冷凍機：熱出力量($x_{ti}^k: k=1, \dots, K, i=1, \dots, N_t$)
- ・蒸気吸収式冷凍機：熱出力量($x_{si}^k: k=1, \dots, K, i=1, \dots, N_s$)
- ・ガスタービン：消費ガス量($x_{gi}^k: k=1, \dots, K, i=1, \dots, N_g$)

各変数は1日当たり24点($K=24$)持っている。

(b) 目的関数

1日の1次エネルギーコスト(購入電力量、購入ガス量の和)の最小化とする。

$$\min EC = \sum_{k=1}^K \{C_{Ep}^k e_p^k + C_{Gp}^k (\sum_{i=1}^{N_g} x_{gi}^k + \sum_{i=1}^{N_b} g_{bi}^k)\} \dots (8)$$

ここで、 K :1日の分割点数、 C_{Ep}^k :時刻 k における電気購入単価、 e_p^k :時刻 k における電気購入量、 C_{Gp}^k :時刻 k におけるガス購入単価、 N_g :ガスタービン数、 N_b :ボイラ数、 g_{bi}^k :時刻 k における i 台目のボイラにおける消費ガス量

e_p^k は従属変数であり、 x_{ti}^k によって計算されるターボ冷凍機の消費電力量と電力供給量によって計算される。 g_{bi}^k も同様に従属変数であり、 x_{si}^k により導出される。

(c) 制約条件

以下にEMSの制約条件を示す。

- ・需給バランス:各機器の電気、熱、ガスの入出力は、固定値として設定する電気、熱、蒸気の各負荷とバランスが取れている必要がある。
- ・機器特性:各機器の入出力の上下限值、入出力特性を満たす。

副問題にて求めた1次エネルギーコストを主問題に送り、1次エネルギーコストを考慮した生産計画の評価を行う。

3 JSP に対する RHPSO の提案

3.1 HPSO

HPSO は、JSP に適用させるためにエージェントの速さや更新方法を改良し、優先リストを用いた PSO と、局所探索法として知られている TS を組み合わせた手法として開発された¹⁶⁾。

(a) 優先リスト、速さの表現方法

HPSO では、各エージェントがスケジュール、優先リスト、速さを持つ。優先リストを以下に示す。

$$Y^n = \begin{bmatrix} y_{11}^n & \dots & y_{1j}^n \\ \vdots & \ddots & \vdots \\ y_{M1}^n & \dots & y_{Mj}^n \end{bmatrix} \dots (9)$$

ここで、 n :エージェント番号、 Y^n : n 番目のエージェ

ントの優先リスト、 y_{mj}^n : n 番目のエージェントの機械 m ジョブ j の工程における優先度
優先リストにおいて、同じ機械の中で優先度 y_{mj}^n が小さい工程ほど優先度が高い。また、優先リストが決まると一つのスケジュールが決定される。工程の速さを以下に示す。

$$V^n = \begin{bmatrix} v_{11}^n & \dots & v_{1j}^n \\ \vdots & \ddots & \vdots \\ v_{M1}^n & \dots & v_{Mj}^n \end{bmatrix} \dots (10)$$

ここで、 n :エージェント番号、 V^n : n 番目のエージェントの速さ群、 v_{mj}^n : n 番目のエージェントの機械 m ジョブ j の工程の速さ($v_{mj}^n \in \{0,1\}$)

PSO の速さは、決定変数の変化量を表している²⁰⁾。一方、HPSO における速さは PSO とは異なり、優先リストの更新処理において工程を交換する際に交換できるかどうかを示している。速さが0のとき交換可能であり、1のとき交換不可である。

(b) 初期スケジュール生成方法

初期スケジュールは、以下に述べる G&T アルゴリズム²¹⁾を用いてエージェント毎にランダムに生成する。

(c) HPSO で用いる処理

HPSO では、速さ更新、各エージェントの最良値($pbest$)及び全エージェントの最良値($gbest$)の優先リストを用いた優先リスト更新、G&T アルゴリズムによるスケジュール生成、 $pbest$ と $gbest$ の更新の4つの処理を行う。 $pbest$ と $gbest$ に保存する要素を目的関数値と優先リストとしている。

- 1) 速さ更新 HPSO では、工程の速さが0の工程が優先リストの優先度を変更することができ、優先度を変更した工程の速さを1とする。速さ更新では、速さを以下の手順で1を持つ工程の速さを0にする。

Step.1 工程毎に0~1間の乱数 v_{rand} を求める。

Step.2 $v_{mj}^e = 1 \cap v_{rand} \geq S$ のとき、 $v_{mj}^e = 0$ とする。

- 2) 優先リスト更新 交換操作及び突然変異を行うことで優先リストの更新を行う。

Step.1 優先リストの機械 m からランダムにジョブ J_1 を求め、そのジョブの優先度 y_1 を求める。

Step.2 0~1間の乱数 y_{rand} を求め

$y_{rand} \leq C_1$ のとき

機械 m ジョブ J_1 の優先度 y_1 と同じ優先度を持つ $pbest$ のジョブを J_2 とする。 $v_{mJ_1}^e = 0 \cap v_{mJ_2}^e = 0 \cap J_1 \neq J_2$ のとき J_1 と J_2 の優先度を交換し、 $v_{mJ_1}^e$ に1を代入する。

$C_1 \leq y_{rand} \leq C_1 + C_2$ のとき

機械 m ジョブ J_1 の優先度 y_1 と同じ優先度を持つ $gbest$ のジョブを J_2 とする。 $v_{mJ_1}^e = 0 \cap v_{mJ_2}^e = 0 \cap J_1 \neq J_2$ のとき J_1 と J_2 の優先度を交換し、 $v_{mJ_1}^e$ に1を代入する。

($0 \leq C_1 \leq 1, 0 \leq C_2 \leq 1, C_1 + C_2 \leq 1$)

Step.4 $m_{rand}(1 \sim M)$, $J_{rand1}(1 \sim J)$, $J_{rand2}(1 \sim J)$ をランダムに求め、優先リストの機械 m_{rand} のジョブ J_{rand1} と J_{rand2} の優先度を入れ替え、入れ替えた工程の速さ $v_{m_{rand}J_{rand1}}^e$ と $v_{m_{rand}J_{rand2}}^e$ に1を代入する。

- 3) G&T アルゴリズムによる変更スケジュール生成

優先リストを用いて G&T アルゴリズムにより変更スケジュールを生成する。

- Step. 1 各ジョブの中で、スケジュールされていない工程のうち処理順序を守った処理開始可能作業の集合 A を求める。
- Step. 2 既に決定したスケジュールを変更せずに最も早く工程を開始した場合の集合 A に属する工程の $FOS(O_{m,j})$ と $FOE(O_{m,j})$ を求める。
- Step. 3 集合 A の中で最も $FOE(O_{m,j})$ の早い工程を O_{fast} とし O_{fast} を処理する機械を M_{fast} とする。
- Step. 4 M_{fast} で処理される工程且つ集合 A に属する工程の中で、その $FOS(O_{m,j})$ が O_{fast} の $FOS(O_{m,j})$ より小さい工程の集合を集合 B とする。
- Step. 5 $O \in (B \cup O_{fast})$ を満たす集合 C の中で、工程が 1 つの場合その工程を選ぶ。工程が複数存在する場合、優先リストの M_{fast} の中で優先度の高い工程を選ぶ。
- Step. 6 選ばれた工程をスケジューリングし、集合 A から除く。
- Step. 7 集合 A が空集合ならば Step.8 へ、それ以外 Step.1 へ。
- Step. 8 スケジュール完成。

4) TS によるローカルサーチ HPSO にて更新したスケジュールに対して TS を用いて局所探索を行う。本論文では、クリティカルブロック近傍 (以下, CB) を用いた近傍解生成法²²⁾を用いている。また, TS の処理は解の更新が閾値 $Iter_{max}$ 以上行われな場合、停止する。

5) $pbest$ と $gbest$ の更新 多様性を維持するために以下の条件を用いて $pbest$ と $gbest$ の更新を行う。

- Cond. 1 更新後のエージェントの目的関数値 ($agent_{obj}$) が, $gbest$ の目的関数値 ($gbest_{obj}$) より良い場合, エージェントの中で最も悪い $pbest$ の目的関数値 ($pbest_{objworst}$) に現在の $gbest_{obj}$ を代入し, $gbest_{obj}$ に $agent_{obj}$ を代入する。
- Cond. 2 $agent_{obj}$ が, $gbest_{obj}$ より悪く $pbest_{objworst}$ より良い場合, $pbest_{objworst}$ に $agent_{obj}$ を代入する。
- Cond. 3 $agent_{obj}$ が $gbest_{obj}$ 又は $pbest$ の目的関数値 ($pbest_{obj}$) と同じ場合, 同じ値であった $gbest_{obj}$ 又は $pbest_{obj}$ に $agent_{obj}$ を代入する。

3.2 EMS を考慮した JSP に対する RHPSO

RHPSO は, HPSO の TS 部を改良版手法である RTS に改良した手法である。

(a) RTS の概要

RTS では, TS アルゴリズムに加えて Reaction 機能, Escape 機能の処理を行う。本論文では, 例として Reaction 機能を示す。

以下の方法により TL 長を自動調整する。

- Step.1 探索済みの探索点の状態はすべて保存リストに保存しておく。
- Step.2 新しい探索点に移動した時に, その探索点が

以前に探索された点であり, ある一定以下の探索回数 (CYCLEMAX) で再度探索された場合, 探索がループしているとみなし TL 長を長くする。

$$TL^{k+1} = TL^k \times (1.0 + \alpha) \dots\dots\dots (1\ 1)$$

ここで, TL^k : RTS のイタレーション k 回目における TL 長, α : TL 長の修正率

- Step.3 以前探索された状態が現れるまでの探索回数の移動平均より長い間 TL 長の修正がなかった場合, もしくはすべての隣接状態がタブーであった場合, TL 長を短くする。

$$TL^{k+1} = TL^k \times (1.0 - \alpha) \dots\dots\dots (1\ 2)$$

Reaction で TL 長を計算する際は TL 長を実数として保存しており, 実際の TL 長として使用する際には, 小数点以下を切り捨て整数値に直すという方法を用いている。この機能を用いることで, 探索サイクルからの脱出に繋がり, より広い範囲の探索を可能にしている。また, RTS の処理は解の更新が閾値 $Iter_{max}$ 以上行われない場合, 停止する。

(b) 提案法アルゴリズム

上述の定式化及び EMS を考慮した JSP に対する RHPSO の提案法のアルゴリズムを示す。

- Step.1 3・1 節(b)で説明した方法によりエージェント毎に初期スケジュールを生成する。
- Step. 2 エージェント毎に初期スケジュールの目的関数値及び優先リストを $pbest$ に保存し, $pbest$ の中で最も目的関数値が良いエージェントの目的関数値と優先リストを $gbest$ に保存する。
- Step. 3 エージェント毎に 3・1(c)1)~3) の処理を行う。
- Step. 4 エージェント毎に 3・2(a) の RTS を行う。
- Step. 5 3・1(c)5) の $pbest$ と $gbest$ の更新を行う。
- Step. 6 探索回数が上限に達した場合終了し, それ以外は Step. 3 へ。

4 シミュレーション

4.1 シミュレーション条件

Table 2 に対象とする 10 機械 10 ジョブの各ジョブの工程順序, 処理コマ数, 及び電力消費量を示す。JSP は機械数とジョブ数によって全スケジュール数が決定する。N 台の機械と K 個のジョブの場合, 組合せの数は $(K!)^N$ 通り存在する。従ってメタヒューリスティック手法の適用が必要となる。

最初の作業開始コマ番号 0 を午前 8 時と設定し, 1 コマあたりの時間を 1 分 (1 時間につき 60 コマ) と定めることで, 現実的な工場を想定した。また, 本論文で扱う 10 機械 10 ジョブ問題はベンチマーク問題であり, メイクスパンのみを考慮した場合の最適解は 943 である²³⁾。

本論文では, 10 機械 10 ジョブの JSP に対して以下の 2 ケースに関するシミュレーションを実施した。

- Case 1: メイクスパンの最小化のみを考慮した JSP に対し, RHPSO を適用した提案法と PRTS¹⁵⁾ 及び HPSO¹⁶⁾ を適用した従来法の比較を行う。

Table 2: 10 jobs and 10 machines problem.

Job	Factory operation information (Machine number, Number of processing time, Electric power energy consumption)									
1	(8,62,10)	(9,24,5)	(6,25,15)	(4,84,10)	(5,47,5)	(7,38,15)	(3,82,25)	(1,93,10)	(10,24,10)	(2,66,5)
2	(6,47,5)	(3,97,15)	(9,92,10)	(10,22,5)	(2,93,25)	(5,29,25)	(8,56,10)	(4,80,15)	(1,78,15)	(7,67,15)
3	(5,45,5)	(8,46,15)	(7,22,10)	(3,26,10)	(10,38,10)	(1,69,15)	(5,40,15)	(4,33,20)	(9,75,15)	(6,96,5)
4	(5,85,10)	(9,76,5)	(6,68,10)	(10,88,25)	(4,36,20)	(7,75,25)	(3,56,5)	(2,35,15)	(1,77,20)	(8,85,10)
5	(9,60,5)	(10,20,10)	(8,25,5)	(4,63,10)	(5,81,5)	(1,52,15)	(2,30,25)	(6,98,10)	(7,54,20)	(3,86,15)
6	(4,87,20)	(10,73,15)	(6,51,5)	(3,95,10)	(5,65,20)	(2,86,5)	(7,22,5)	(9,58,5)	(1,80,10)	(8,65,15)
7	(6,81,5)	(3,53,15)	(8,57,10)	(7,71,10)	(10,81,5)	(1,43,15)	(5,26,15)	(9,54,10)	(4,58,5)	(2,69,15)
8	(5,20,5)	(7,86,15)	(6,21,10)	(9,79,20)	(10,62,20)	(3,34,10)	(1,27,5)	(2,81,5)	(8,30,5)	(4,46,5)
9	(10,68,15)	(7,66,5)	(6,98,10)	(9,86,15)	(8,66,10)	(1,56,15)	(4,82,10)	(2,95,15)	(5,47,5)	(3,78,15)
10	(1,30,5)	(4,50,15)	(8,34,15)	(3,58,10)	(2,77,5)	(6,34,15)	(9,84,5)	(5,40,10)	(10,46,10)	(7,44,10)

Case 2 : エネルギーマネジメントを考慮した JSP に対して RHPSO を適用した提案法と PRTS¹⁵⁾を適用した従来法の比較を行う。この際、目的関数の重み係数を変化させた時の結果の比較を行う。

つまり、Case 1 では、従来の JSP に対する最適化の有効性を検証し、Case 2 では、EMS を考慮した JSP に対してメイクスパンの最小化と 1 次エネルギーコストの最小化の重みを変化させた時の結果の比較を行う。

以下に、各パラメータを示す。

(RHPSO・HPSO 共通パラメータ)

・探索回数:100, $Iter_{max}$:100, S :0.5, C_1 :0.6, C_2 :0.1

(PRTS パラメータ)

・探索回数 : 10000,

(RHPSO・PRTS パラメータ)

・初期 TL 長 : 10~50 を 10 刻み,

(共通パラメータ)

・初期スケジュール数 : 32, 試行回数 : 30,

・TL 長 : 10~50 を 10 刻み,

・TL 長の修正率 α : 0.1, CYCLEMAX : 30,

・ N_g : 1, N_t : 1, N_s : 2, $MSlimit$: 960,

Case 1:重み係数 w_1 : 1.0, 重み係数 w_2 : 0.0,

Case 2:重み係数 w_1 : 0.1~1.0 (0.1 刻み),

重み係数 w_2 : 0.0~0.9 (0.1 刻み),

重み係数 w_p : 0.2.

4.2 シミュレーション結果

Table 3 に、Case 1 に対して PRTS, HPSO, RHPSO を適用した際のメイクスパンの平均値, 最小値, 最大値, 標準偏差値を示す。Table 3 より、提案法である RHPSO 及び従来法の PRTS は、TL 長を 10 から 50 全てにおいて最適解である 943 を得ることが確認できた (table 3 太字)。一方、従来法である HPSO は、TL 長を 40 にした場合、最適解である 943 を得たが、TL 長を 10~30, 50 にした場合、試行回数 30 回全てにおいて最適解を得ることが出来なかった。つまり、著者らが提案した PRTS と本論文の提案法である RHPSO の JSP

Table 3: Comparison of averages, the minimum, the maximum, and standard deviation values of makespan values for case 1 among PRTS, HPSO, RHPSO methods.

	TLL	Ave.	Min.	Max.	Std.
PRTS	10	943	943	943	0.000
	20	943	943	943	0.000
	30	943	943	943	0.000
	40	943	943	943	0.000
	50	943	943	943	0.000
HPSO	10	945.167	943	952	2.282
	20	943.133	943	947	0.718
	30	943.133	943	947	0.718
	40	943	943	943	0.000
	50	943.267	943	947	0.998
RHPSO	10	943	943	943	0.000
	20	943	943	943	0.000
	30	943	943	943	0.000
	40	943	943	943	0.000
	50	943	943	943	0.000

問題への有効性が確認できた。

Table 4 に、Case 2 に対して Case 1 で有効性が確認できた PRTS と RHPSO を適用し、例として初期 TL 長を 10 にした際の目的関数値の平均値及び標準偏差値を示す。Ave.列は、各数値の全重み係数 w_1 に対する平均値を示している。Table 4 より、提案法である RHPSO の目的関数値の平均値及び標準偏差値は、 $w_1 = 0.9$ 以外のすべての重みに対して PRTS に比べ質の高い値を得ることが確認できた。また、各数値の全重み係数 w_1 に対する平均値より、RHPSO は PRTS に比べ、平均値及び標準偏差値が優れていることが確認できた。特に、標準偏差値において、提案法である RHPSO は、従来法である PRTS と比較し約 38.6%改善され、様々な試行に対して質の高い解を得ることができていることを確認した。

Fig. 4 に、提案法を用いて w_1 を変化させた時のメイクスパン及び 1 次エネルギーコストの平均値の推移を

Table 4: Comparison of average and standard deviation values of the objective function values for case 2 between PRTS and RHPSO methods.

	w_1	0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9	1.0	Ave.
PRTS	Ave.	121.898	119.462	117.261	114.748	112.340	109.951	107.502	105.039	102.308	99.263	110.977
	Std.	0.287	0.303	0.268	0.249	0.181	0.161	0.136	0.064	0.017	0.000	0.166
RHPSO	Ave.	121.706	119.432	117.023	114.685	112.244	109.834	107.443	105.02	102.364	99.263	110.901
	Std.	0.221	0.169	0.150	0.097	0.128	0.092	0.054	0.050	0.055	0.000	0.102

示す。Fig. 4 より、 w_1 を 1.0 にした場合 (Case 1) , 最適メイクスパン (943) を得ることが出来るものの、1 次エネルギーコストが高いスケジュールが生成されることを確認した。一方、 w_1 を 0.1 にした場合、つまり 1 次エネルギーコストの最小化を強調した場合、Case 1 のスケジュールと比較して、メイクスパンは多少伸びてしまうものの、1 次エネルギーコストを約 5.6%抑えたスケジュールが生成されることを確認した。

5 まとめ

本論文では、RHPSO を用いて JSP を解く際に、スケジュールの情報をもとに EMS を用いてスケジュールの 1 次エネルギーコストを求め、1 次エネルギーコスト最小化を目的関数に入れることにより、これまでのメイクスパン最小化だけでなく、最適なエネルギーや機器の運用を行う解法を提案した。

メイクスパンの最小化のみを考慮する従来型の JSP に対して、提案する RHPSO 及び著者らが提案した PRTS が従来法である HPSO と比較し、初期 TL 長によらず、常に最適なメイクスパンを探索できることを確認した。また、著者らが提案するエネルギーマネジメントを考慮した JSP に対して RHPSO 及び PRTS を適用し比較することで、提案法である RHPSO が従来法である PRTS に比べ解の質が高い結果を得られるとともに、目的関数の重みを変更することにより、目的に合った生産計画及び 1 次エネルギーコストを得られることを確認した。

今後は、より大規模な問題への適用性を検討するとともに、並列分散処理などの高速化を検討していく。

参考文献

- 1) D. C. Mattfeld: Evolutionary Search and the Job Shop, Springer-Verlag Berlin Heidelberg (1996)
- 2) A. Jain and S. Meeran: Deterministic job-shop scheduling: Past, present and future, European Journal of Operational Research, pp. 390-434 (1999)
- 3) J. Adams, E. Balas and D. Zawack: The Shifting Bottleneck Procedure for Job Shop Scheduling, Management Science, Vol. 34, No. 3, pp.391-401 (1988)
- 4) T. Yamada and R. Nakano: A Genetic Algorithm Applicable to Large-Scale Job-Shop Problems, Parallel Problem Solving from Nature: PPSN II, pp. 281-290, (1992)
- 5) M. Amico and M. Trubian: Applying tabu search to the job-shop scheduling problem, Annals of Operations Research, Vol. 41, No. 3, pp.231-252, (1993)
- 6) G. Zhang, et al.: An effective hybrid particle swarm optimization algorithm for multi-objective flexible job-shop scheduling problem, Journal of Computers & Industrial Engineering, vol. 56, issue 4, pp. 1309-1318, (2009)
- 7) K. Huang and C. Liao: Ant colony optimization combined with taboo search for the job shop scheduling problem, Computers & operations research, vol. 35, No. 4, pp. 1030-1046, (2008)
- 8) F. Raupp, et al: A Newton-based heuristic algorithm for multi-objective flexible job-shop scheduling problem, Journal of Intelligent Manufacturing, vol. 27, pp. 409-416, (2016)
- 9) J. Xiong, et al.: Robust scheduling for multi-objective flexible job-shop problems with random machine breakdowns, International Journal of Production Economics, vol. 141, Issue 1, pp.

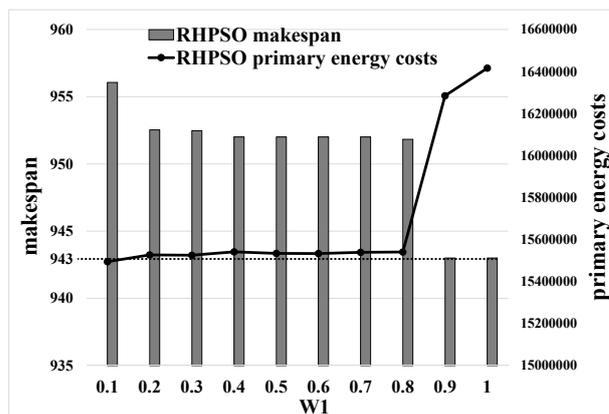


Fig. 4: Transitions of averages of makespan and the primary energy costs by changing w_1 by the proposed method.

112-126, (2013)

- 10) S. Kawaguchi and Y. Fukuyama: Parallel Reactive Tabu Search for Job-Shop Scheduling Problems Considering Peak Shift of Electric Power Energy Consumption, Proc. SICE Annual Conference 2017, pp. 955-960, (2017)
- 11) R. Zhang, et al.: Solving the energy-efficient job shop scheduling problem: A multi-objective genetic algorithm with enhanced local search for minimizing the total weighted tardiness and total energy consumption,” Journal of Cleaner Production, (2016)
- 12) 西村典大・福山良和・松井哲郎：エネルギープラントのオンライン最適運用計画に対するディペンダブルな並列 DEEPSO による方式の提案, 電気学会論文誌 C, vol. 137, No. 8, (2017)
- 13) F. Glover and M. Laguna: Tabu Search, Kluwer Academic Publishers, (1997)
- 14) R. Battiti: The Reactive Tabu Search, ORSA Journal on Computing, vol. 6, No. 2, pp. 126-140, (1994)
- 15) S. Kawaguchi and Y. Fukuyama: Parallel Reactive Tabu Search for Job-Shop Scheduling Problems Considering Energy Management, Proc. of IEEE SSCI2017, pp.2906, November, 2017)
- 16) D. Y. Sha, and C. Hsu: A hybrid particle swarm optimization for job shop scheduling problem, Journal of Computers & Industrial Engineering, vol. 51, issue 4, (2006)
- 17) 電気学会 情報知能システムの新展開とその産業応用調査専門委員会：産業応用のための最適化ベンチマーク問題集, 電気学会技術報告, 第 1287 号, 3.2 節, (2013)
- 18) 伊藤, 横山：コージェネレーションの最適計画—インテリジェント・フレキシブル・コージェネレーションを目指して, 産業図書, (1990)
- 19) GLPK ウェブサイト, <https://en.wikibooks.org/wiki/GLPK>
- 20) R. Eberhart, Y. Shi, and J. Kennedy: Swarm Intelligence, Morgan Kaufmann, 2001
- 21) B.Giffler and G. L. Thompson: Algorithms for Solving Production Scheduling Problems, Operations Research, vol. 8, No. 8, pp. 487-503, (1960)
- 22) E. Balas: Machine Sequencing Via Disjunctive Graphs: An Implicit Enumeration Algorithm, Operations Research, vol. 17, No. 6, pp. 941-957, (1969)
- 23) Beasley: OR-library ウェブサイト, <http://people.brunel.ac.uk/~mastjib/jeb/info.html>

Global-best Modified Brain Storm Optimization による スマートコミュニティ全体最適化

○佐藤繭子 福山良和 (明治大学大学院) 飯坂達也 松井哲郎 (富士電機株式会社)

Total Optimization of Smart Community by Global-best Modified Brain Storm Optimization

* M. Sato, Y. Fukuyama (Meiji University), T. Iizaka, and T. Matsui (Fuji Electric, Co. Ltd.)

Abstract— This paper proposes a total optimization method of a smart community(SC) by global-best modified brain storm optimization(GMBSO). Energy cost, actual electric power loads at peak load hours, and CO₂ emission are minimized by the proposed method. Many evolutionary computation techniques such as Differential Evolutionary Particle Swarm Optimization (DEEPSO), Modified Brain Storm Optimization (MBSO), and Global-best brain storm optimization (GBSO) have been applied to the problem. However, there is still room for improving solution quality. The paper proposes GMBSO, which is a combined method of MBSO and GBSO. The proposed method is applied to a total optimization problem of a SC. The results by the proposed method is compared with those by conventional DEEPSO, BSO, MBSO, and GBSO based methods.

Key Words: Smart Community, Total Optimization, Global-best Brain Storm Optimization,

1 はじめに

現在, 地球温暖化が進んでおり, その要因として二酸化炭素 (以下, CO₂) などの温室効果ガスの排出量増加があげられる. その排出を削減するためにもエネルギーの有効活用が必要である. そこで太陽光や風力発電などの再生可能エネルギーや蓄電技術, 最新の情報通信技術を活用し, 持続可能かつ環境負荷が少ない地域社会を実現しようとするスマートコミュニティ(以下, SC)の実証試験が世界中で行われている¹⁻³⁾. 日本では, 次世代エネルギー・社会システム実証として神奈川県横浜市, 愛知県豊田市, 京都府けいはんな学研都市, 福岡県北九州市の4都市の実証があげられる⁴⁾. 東日本大震災以降は, 地域社会を復興する際に環境へ配慮した都市作りやSC導入の検討がされている⁵⁾.

一方, SCの実現により実際に環境負荷が少なくなるかどうかには, モデルを使った検証が必要である. 産業分野, ビルや家庭などの民生分野, 水処理, 電力・ガス分野などのモデル化が, 個々の分野において, 静的なエネルギーバランスモデルや, 過渡的な現象も考慮した動的モデルなど様々なレベルで進んでいる⁶⁻⁸⁾. しかし, SC全体を通して, 分野間の連携も考慮したエネルギー消費や環境負荷を計算できるようなモデルは, 構築されていなかった.

これに対し, 電気学会では, SCの実現検討特別研究グループを設置し, SC全体を通してエネルギー消費や環境負荷を計算できるようなSCモデルを構築してきた⁹⁻¹¹⁾. これにより, SC全体を通してエネルギー消費や環境負荷を計算できるようになったが, 実際に, 様々な設備を調整してエネルギー消費や環境負荷が最も小さくなるようなSC全体の設備の運用方法を検討するには至っていなかった. つまり, SCのさまざまな分野間の連携を考慮した全体最適化までは行われていなかった.

それに対し著者らは, 電気学会のSCモデルを利用して, SC全体の分野間連携を考慮し, SCのエネルギーコストの最小化とエネルギー需要のピークシフトを

行う大規模最適化と Particle Swarm Optimization¹²⁾, Differential Evolution¹³⁾, Differential Evolutionary Particle Swarm Optimization (以下, DEEPSO)¹⁴⁾, Modified Brain Storm Optimization (以下, MBSO)¹⁵⁾, Global-best Brain Storm Optimization (以下, GBSO)¹⁶⁾によるSC全体最適化¹⁴⁾を提案した. しかし, 従来法の場合, 解の質に改善の余地があった.

以上のような背景より, 本論文では, Global-best Modified Brain Storm Optimization (以下, GMBSO)によるSC全体最適化を提案する. MBSOとGBSOを統合したGMBSOを新たに提案し, これをSC全体最適化に適用した結果と, 従来法のDEEPSO, BSO, MBSO, GBSOを適用した結果と比較し, 提案法によりコストの最小化, CO₂排出量の最小化, 実電力負荷のピークシフトを実現しており, より効率的な設備の運転を実現することが確認ができた.

2 スマートコミュニティモデル

2.1 全体モデルの概要⁹⁾

SCの評価基準としては, エネルギーコスト, 環境保全性, 利便性, 快適性, 安全性などが挙げられるが, このモデルでは, エネルギーコストとCO₂排出量のみを取り上げている. また, SCは, 極めて広い対象を含んでいるが, このSCモデルでは, 電力, ガス, 上下水道, 産業, 業務, 家庭, 鉄道分野を考慮している (Fig. 1参照). このモデルでは, エネルギー供給側とエネルギー需要側に分類されている. エネルギーの供給と需要に伴い, CO₂が排出され, コストのやり取りがある. これにより, SC全体においてエネルギーの流れがどのようになっているのか, CO₂排出量は各分野でどの程度なのか, またSC全体でどのくらいのエネルギーが供給され, 消費されるか, CO₂が排出されるかなどの定量的な評価が可能となっている.

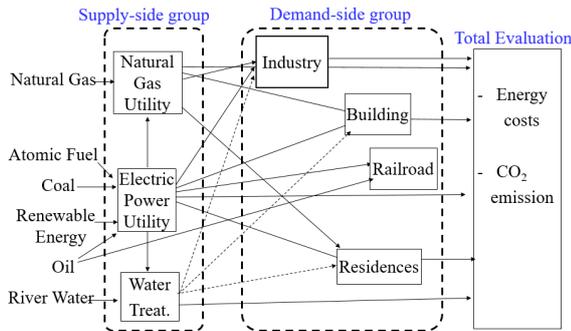


Fig. 1: A Configuration of a smart community model ¹¹⁾.

2.2 エネルギー供給モデル ¹⁰⁾

エネルギー供給側は、ガスモデル、電力モデル、上水モデル、下水モデルから成る。これらはエネルギー需要モデルに対応し、各モデルに様々なエネルギーを供給する。また、エネルギーは需要と供給が一致するように供給側から需要分のエネルギーが供給される。

ガス供給形態には、都市ガス事業とLPガス事業がある。このモデルでは、都市ガスのみを対象とする。このガス分野モデルでは、ガスエネルギーのソースとしてのみモデル化されている。つまり、需要側の各分野で必要なガス量をそのまま供給するモデルとなっている。

電力分野では、エネルギー源となる原子力・火力・水力・再生可能エネルギーなどの各種発電設備があり、それぞれの発電費用、CO₂排出量を計算することができる。また、各発電種別の単価、発電量、比率により、平均の発電単価が計算できるようになっている。さらに、各種発電機の負荷の最適な比率が評価できるようになっている。

上水モデルでは、水需要、再生可能エネルギー量、デマンドレスポンス（以下、DR）要求量を固定値として与える。下水モデルでは、流入下水量、DR要求量、再生可能エネルギー量を固定値として与える。また、水分野では水処理の過程でCO₂等の温室効果ガスが発生するため、他分野のように使用電力量とガス使用量からCO₂排出量を換算するのではなく、水量から換算することとしている。

2.3 エネルギー需要モデル ¹¹⁾

エネルギー需要側の各分野は、産業モデル、業務モデル、家庭モデル、鉄道モデルの各モデルで構成される。これらはエネルギー供給モデルと連携している。

産業・業務・家庭分野においては、その分野内に、エネルギー供給設備と様々なエネルギー負荷がある。電力やガス等のエネルギー供給側モデルから分

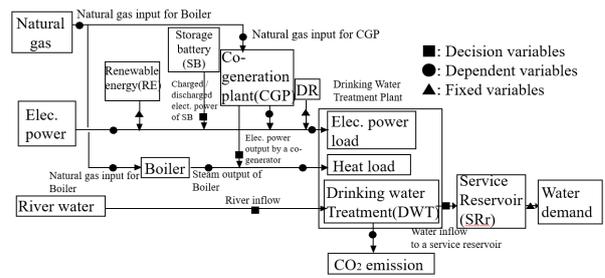


Fig. 2: A Configuration of a drinking water treatment plant model ¹⁰⁾.

野内のエネルギー供給設備に1次エネルギーが供給され、このエネルギー設備から様々なエネルギー負荷に対し2次エネルギーが供給されるモデルとなっている。従って、1時間毎の1日分の各分野の様々なエネルギー負荷が与えられると、必要な1次エネルギー量が明確になり、この必要な1次エネルギー量が、エネルギー供給側から供給されるモデルとなっている。

産業モデルは、電気学会産業応用部門「情報知能システムの新展開とその産業応用調査専門委員会」がまとめた「産業応用のための最適化ベンチマーク問題」で提案された産業向けエネルギーユーティリティモデル⁹⁾に太陽光発電（以下、PV）・蓄電池・DR要求量を追加したモデルである（Fig.3参照）。本来ならば業種毎に産業モデルを構築する必要があるが、このモデルにおいては、産業モデルはこの1種類であり、複数の工場を考慮する必要がある場合、同じ工場が複数個あることとしてモデル全体と連携する。

業務分野では、ショッピングセンターや大型ビルなどの大規模施設を対象としている。このモデルは産業モデルと同様であるが、蓄電池がないことだけが異なる。SC全体では、複数の大型業務施設を考慮する必要があるが、このモデルにおいては、基本的に同じ業務施設が複数個あることとしてモデル全体と連携する。

家庭分野は、集合住宅と一戸建てを扱う必要があり、それぞれ特性が大きく異なる。しかし、ここではモデルは同じものとして、入力データにより2つの違いを表現するものとする。ここで複数の家庭を考

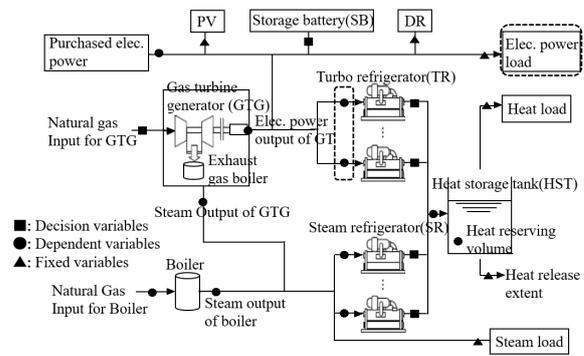


Fig. 3: A Configuration of an industrial model ¹¹⁾.

慮する必要がある場合は、同じ家庭が複数個あることとしてモデル全体と連携する。

鉄道分野は、鉄道運行、駅、車両基地、オフィス、発電設備など様々な設備からなる。ただし、駅やオフィスは業務分野でのビルとみなせる。そこで、ここでの鉄道分野は、鉄道運行のみによりエネルギー消費を求めている。

3 スマートコミュニティ全体最適化の定式化

3.1 決定変数

各分野の決定変数を以下に挙げる。

上水分野：取水量、送水量、コジェネ起動停止・発電量、蓄電池充放電量（5個）

下水分野：揚水量、コジェネ起動停止・発電量、蓄電池充放電量（4個）

産業分野：ガスタービン起動停止・発電量、ターボ冷凍機起動停止・熱出力、蒸気吸収式冷凍機起動停止・熱出力、蓄電池充放電量（7個）

業務分野：ガスタービン起動停止・発電量、ターボ冷凍機起動停止・熱出力、蒸気吸収式冷凍機起動停止・熱出力（6個）

家庭分野：燃料電池起動停止・発電量、エコキュート起動停止・熱出力、蓄電池充放電量（5個）

鉄道分野：運行本数、平均運行距離、時間平均速度、車両定員、編成車両数、乗車人数、平均乗車距離（7個）

上記の決定変数は、それぞれ1日の毎時間分（24個）存在するため、決定変数の数は、例えば各設備が1台ずつとしても816個となり、大規模最適化問題となる。

3.2 目的関数

電力及びガスからエネルギーを購入するため、電力・ガス分野以外の全ての分野におけるエネルギーコストの和の最小化を1つ目の目的関数としている。また、SC全体のピークシフトを行うため、SC全体のピーク時間に対する電力・ガス分野以外の電力エネルギーを消費する分野の実電力負荷の和の最小化を2つ目の目的関数としている。ここで、実電力負荷とは、各分野において、実際に電力エネルギーを蓄電あるいは他のエネルギーに変換する設備、および元々の電力負荷の消費エネルギーの和を意味する。さらに、SCは環境負荷を考慮したコミュニティであるため、SCのCO₂排出量の最小化を3つ目の目的関数としている。なお、本問題は一般的には多目的関数となるが、簡単のため、この3つの目的関数をスカラー化手法により1つの目的関数とした。

$$\min \left\{ w_1 \sum_{n=1}^N \sum_{j=1}^T (BuyG_{nt} \times GU_{nt} + BuyE_{nt} \times EU_{nt}) + w_2 \sum_{n=1}^N \sum_{m=mps}^{mpe} (GL_{nm}) + w_3 \sum_{n=1}^N \sum_{j=1}^T (BuyG_{nt} \times GC + BuyE_{nt} \times EC) \right\} + w_4 \times Penalty \quad (1)$$

ここで、 N ：電力・ガス以外の分野数、 T ：1日の時間数(=24)、 $BuyG_{nt}$ ：分野 n の時間 t のガス購入量、 GU_{nt} ：分野 n の時間 t ガス単価、 $BuyE_{nt}$ ：分野 n の時間 t の電力購入量、 EU_{nt} ：分野 n の時間 t の電力料金単価、 GL_{nm} ：分野 n の時帯 m の実電力負荷、 mps ：実電力負荷のピーク時間帯開始時間、 mpe ：実電力負荷のピーク時間帯終了時間、 GC ：購入ガス量からCO₂排出量への変換係数、 EC ：購入電力量からCO₂排出量への変換係数、 w_1, w_2, w_3 ：各関数に対する重み係数($w_1 + w_2 + w_3 = 1$)、 w_4 ：ペナルティ値に対する重み係数、 $Penalty$ ：決定変数や従属変数が制約を満たさない分を二乗した時の和。

一般的には、決定変数が設定されると、エネルギーバランスや設備特性により従属変数が計算される。その従属変数が制約の上下限値外に値をとる場合は、制約違反量の合計の2乗ノルムにペナルティ係数を乗じた値を目的関数値にペナルティ値として付加する((1)式第4項)外点ペナルティ関数を用いる。

3.3 制約条件

(a) エネルギーバランス 産業・業務分野では、電力・蒸気・熱エネルギーバランスを考慮する。家庭分野では、電力・熱・給湯エネルギーバランスを考慮する。電力エネルギーバランスは、購入電力量により、しわ取りを行っている。蒸気エネルギーバランスは、ボイラへの燃料(ガス)入力でしわとりを行っている。産業・業務分野の熱エネルギーバランスは、蓄熱槽への入力でしわとりを行っている。家庭分野の熱エネルギーバランスは、ガスコンロと熱負荷が1対1対となっている。家庭分野の給湯エネルギーは、貯湯槽内熱量がなくなったら瞬間湯沸器を自動起動しながら、貯湯槽熱入出力でしわ取りを行っている。以上のエネルギーバランスは、下式により一般的に表現できる。

$$g_{nr}(\mathbf{y}, \mathbf{z}) = 0, (n = 1, \dots, N, r = 1, \dots, R_n) \\ \mathbf{y} = (y_1, \dots, y_L)^T, \mathbf{z} = (z_1, \dots, z_L)^T \quad (2)$$

ここで、 \mathbf{y} ：各決定変数に対応する設備の起動・停止（起動：1、停止：0）ベクトル、 \mathbf{z} ：各決定変数に対応する起動中の設備の入力又は出力を表す連続変数ベクトル、 $g_{nr}(\mathbf{y}, \mathbf{z})$ ：分野 n のエネルギー r のバランス式、 L ：決定変数の数、 R_n ：分野 n のエネルギー種別数。

エネルギーバランスは、各エネルギーの需要に対し、各分野の設備によってエネルギーを供給することと、

ガスや電力を購入することで保たれている。

(b) 設備特性 各設備の効率を示す関数は等式制約で、その設備が出力できる範囲の上下限界は不等式制約で、下式で表現できる。

$$g_{nq}(\mathbf{y}, \mathbf{z}) = 0, (n = 1, \dots, N, q = 1, \dots, Q_n) \quad (3)$$

ここで、 $g_{nq}(\mathbf{y}, \mathbf{z})$: 分野 n の設備 q の設備特性、 $h_{nq}(\mathbf{y}, \mathbf{z})$: 分野 n の設備 q の設備制約、 Q_n : 分野 n の設備数。

上述のように、 y_i が決定すると、 z_i の出力範囲が決定されるため、設備特性は y_i と z_i の関数となっている。

本問題で扱う設備の特性は一般的に非線形特性となっており、設備の起動停止および起動停止に関する制約条件や、起動時の最低出力を考慮すると、決定変数は離散・連続値の両方となる。従って、上記定式化は、混合整数非線形最適化問題となり、各種進化計算手法の適用が必要となる。

4 MGBSO によるスマートコミュニティ大規模最適化

4.1 BSO の概要¹⁷⁾

BSOは2011年に開発された進化計算手法である。BSOのアルゴリズムを以下に示す。

- Step.1 初期解生成: 一様乱数を用いて n 個の個体生成。
- Step.2 クラスタリング: n 個の個体を k -means法を用いて m 個のクラスタに分ける。
- Step.3 新個体生成: 1または2個のクラスタをランダムに選択し、新個体を生成する。
- Step.4 選択: i 新しく生成された個体と、それと既存の個体を比較し、評価が良い方の個体を残す。
- Step.5 決められた最大反復回数に達したらStep.6へ。そうでなかったら、Step.2へ。
- Step.6 最終的に得られた解を最適解として出力する。

後述のように、提案するMP-GBSODEは上記Step.2,3を改良するため、以下、この2つのステップについて説明する。Step.2では、 k -means法により m 個のクラスタに分けた後、クラスタ毎に、目的関数値が小さい順にランキングを生成し、1位となった個体をクラスタセンターとする。また、 $p_{clustering} < rand(1,0)$ の時、上下限界内の一様乱数で生成した個体をクラスタセンターに置き換える。Step.3では、新個体は1つ、または2つの個体を元に生成される。新個体生成には、以下の(4)~(6)式を用いる。

$$x_{ij}^{new} = x_{ij}^{old} + \xi(ite\text{r}) \times rand(1, 0) \quad (4)$$

$$\xi(ite\text{r}) = \text{logsig} \left(\frac{0.5 \times ite\text{r}_{max} - ite\text{r}}{c} \right) \times rand(1, 0) \quad (5)$$

$$x_{ij}^{old} = rand(i) \times x_{ij}^{selected1} + (1 - rand(i)) \times x_{ij}^{selected2} \quad (6)$$

$(i = 1, \dots, I, j = 1, \dots, L)$

ここで、 x_{ij}^{new} : i 番目の新個体の決定変数 j , x_{ij}^{old} : i

番目の既存個体の決定変数 j , $\xi(ite\text{r})$: 反復回数 $ite\text{r}$ 回目のステップサイズ関数, $ite\text{r}_{max}$: 最大反復回数, c : ステップサイズ関数 $\xi(ite\text{r})$ 内の $\text{logsig}()$ 関数の傾斜を変えるための係数, $x_{ij}^{selected1}$, $x_{ij}^{selected2}$: クラスタのセンターまたはランダムに選択された i 番目の個体の決定変数 j , I : 最大個体数, L : 決定変数の数

x_{ij}^{old} の選択方法は確率を用いて4つに分類される。

- $P_{One} > rand(0,1)$ の時、1つのクラスタをランダムに選択する。
 - Pattern1. $P_{OneCenter} < rand(0,1)$ の時、ランダムに選択された1つのクラスタ中心を x_{ij}^{old} とする。
 - Pattern2. $P_{OneCenter} \leq rand(0,1)$ の時、現在のクラスタからランダムに個体を選択し x_{ij}^{old} とする。
- $P_{One} \leq rand(0,1)$ の時、2つのクラスタをランダムに選択する。
 - Pattern3. $P_{TwoCenter} < rand(0,1)$ の時、2つのクラスタ中心($x_{ij}^{selected1}$, $x_{ij}^{selected2}$)と(6)式を用いて x_{ij}^{old} を生成する。
 - Pattern4. $P_{TwoCenter} \geq rand(0,1)$ の場合: 2つのクラスタからランダムに選択した2つの個体($x_{ij}^{selected1}$, $x_{ij}^{selected2}$)と(6)式を用いて x_{ij}^{old} を生成する。

4.2 MBSO の概要¹⁸⁾

BSOは k -means法を用いるため、処理負荷が大きい問題点があった。そこで、MBSOは計算負荷を低減するため、Simple Grouping Methodを用いる。また、局所探索解に収束することを避けるため、Idea difference strategyという考え方により、より新しい解を取り入れている。MBSOの更新式を以下にあげる。

$$x_{ij}^{new} = \begin{cases} random(L_j, H_j) & (random(0,1) < pr) \\ x_{ij}^{old} + random(0,1) \times (x_{ij}^{selected1} - x_{ij}^{selected2}) & (pr \leq random(0,1)) \end{cases} \quad (7)$$

$(i = 1, \dots, I, j = 1, \dots, L)$

ここで、 x_i^{new} : i 番目の更新後個体, x_i^{old} : i 番目の更新前個体, $random(L_j, H_j)$: D 次元問題の決定変数 j の最小値 L_j , 最大値 H_j 間の一様乱数, $x_{ij}^{selected1}$, $x_{ij}^{selected2}$: 現在の個体からランダムに選択された2つの個体の決定変数 j の値。

4.3 GBSO の概要¹⁹⁾

GBSOはEl-Adbによって2017年に開発されたBSOの改良手法である。GBSOでは、クラスタリングにユークリッド距離を用いず、探索領域を限定しないため、 k -meansの代わりにFitness-based Grouping(以下、FbG)を用いる。以下に、FbGのアルゴリズムを示す。

Step. 1 個体の目的関数値順にランキングを生成する。
 Step. 2 (8)式を用いてM個の個体をK個に分類する。

$$g(i) = (R(i) - 1)\%K + 1 \quad (i = 1, \dots, M) \quad (8)$$

ここで, $g(i)$:個体*i*のグループ番号, $R(i)$:個体*i*の順位。
 GBSOでは, x_{ij}^{old} が確定した時に, 条件により $gbest$ を用いて x_{ij}^{old} を修正する。著者らは, GBSOの $gbest$ を用いる条件式と $gbest$ による x_{ij}^{old} の修正式を以下のように改良した²¹⁾。

$$C > rand(1,0) \quad (9)$$

$$C = C_{min} + \frac{iter}{iter_{max}} \times (C_{max} - C_{min}) \quad (10)$$

$$x_{ij}^{old} = x_{ij}^{old} + rand(1,0) \times C \times (x_j^{gbest} - x_{ij}^{old}) \quad (11)$$

ここで, C は $gbest$ の情報を用いるかどうかを選択するための確率, C_{max} : C の値の最大値, C_{min} : C の値の最小値 x_j^{gbest} : $gbest$ 個体の決定変数*j*。

4.4 GMBSOの提案

提案するGMBSOは, MBSOとGBSOの統合手法である。4.1節のBSOアルゴリズムにおいて, Step. 2のクラスタリングにはGBSOで提案されたFbGを用い, 解の更新式はMBSOの更新式を用いる。また, 個体の更新に用いる x_{ij}^{old} が決まった時, かつ条件式(9)式を満たす時, GBSOで提案された修正式を改良した修正式(11)を用いて x_{ij}^{old} を修正する。

Step.1 初期解生成: 一様乱数を用いて*n*個の個体生成。

Step.2 クラスタリング:

Step. 2-1 *n*個の個体をFbGを用いて*m*個のクラスタに分ける。

Step. 2-2 各個体の目的関数値を求めてランキングを生成し, ランキングが1位の個体を各クラスタのクラスタセンターとする。

Step.3 新個体生成:

Step. 3-1 4.1節のPettern.1-4を用いて x_{ij}^{old} を選択し, $p_{clustering} < rand(1,0)$ の時, 上下限值内の一様乱数で生成した個体をクラスタセンターに置き換える。

Step. 3-2 条件(9)式を満たす時, (10)(11)式を用いて x_{ij}^{old} を修正する。

Step. 3-3 (7)式を用いて新個体を生成する。

Step.4 選択: *i*新しく生成された個体と, それと既存の個体を比較し, 評価が良い方の個体を残す。

Step.5 決められた最大反復回数に達したらStep.6へ。そうでなかったら, Step.2へ。

Step.6 最終的に得られた解を最適解として出力する。

提案するGMBSOは一般的な連続型変数を扱う進化計算手法であり, 様々な問題に適用可能である。

5 GMBSOによるSC全体最適化

5.1 切り上げ関数¹⁴⁾

上記にある決定変数に示されている各分野の設備は, 各々最低出力が決まっており, 起動停止と起動時の出力値を扱う必要がある。そのため, これらは離散変数と連続変数である。本論文では, その2つの変数を1つの連続変数に変換する切り上げ関数を用いて, 連続変数のみを用いて最適化問題を解く。

5.2 探索領域の削減¹⁴⁾

一般的には, 現在の運用値から見て, 設備の単位時間当たりの入出力変化量と入出力範囲の上下限值から実行可能領域を求め探索領域とする。つまり, 設備特性のみを考慮し探索領域を決定する。これに対し, 本論文では, 平日運用の継続性と負荷・コスト特性を考慮し, さらに厳密に探索領域を削減することを提案する。また, この削減は, 専門的知識やノウハウから制約条件を追加することとなる。

設備特性, 平日運用の継続性, 負荷特性を考慮することより, 蓄熱設備の探索領域の削減が以下のように可能である。蓄熱設備においては, 蓄熱量の初期値 ($HST_{initial}$)を与え, 各時間の前時点の蓄熱量, 熱入力(最大・最小), 熱出力(熱負荷), ロスを考慮すると, 以下(12)-(14)式のように示される。

$$HST_0 = HST_{initial} \quad (12)$$

$$ForMax_j = HST_{j-1} + HinMax - Hout_j - Loss \quad (13)$$

$$ForMin_j = HST_{j-1} + HinMin - Hout_j - Loss \quad (14)$$

$$(j = 1, \dots, T)$$

ここで, HST_j : 時間*j*の蓄熱量, $ForMax_j$: 初期値から求めた熱入力最大値を続けた時の時間*j*の蓄熱量, $ForMin_j$: 初期値から求めた熱入力最小値を続けた時の時間*j*の蓄熱量, $HinMax$: 熱入力最大値, $HinMin$: 熱入力最小値, $Hout_j$: 時間*j*の熱出力(熱負荷), $Loss$: 毎時間の熱ロス, T : 1日の総時間 (=24)

また, 平日運用の継続性を考慮して, 24時を初期値と同じ値とする。これは, 現問題に対して, 「0時と24時の値を同じにする」という制約条件を追加したこととなる。これを利用し, 24時から時間の逆方向に(12)-(14)式と同様の考え方を利用して $BackMax_j$, $BackMin_j$ を求める(Fig.4の一点鎖線)。以上の範囲と上下限值を考慮すると, 各時間帯の実行可能領域は以下のように表現できる。

$$TMax_j = \min\{ForMax_j, BackMax_j, HSTMax\} \quad (15)$$

$$TMin_j = \max\{ForMin_j, BackMin_j, HSTMin\} \quad (16)$$

ここで, $TMax_j$: 時間*j*の蓄熱量最大値, $TMin_j$: 時間*j*の蓄熱量最小値, $BackMax_j$: 24時から求めた入力値最大値の時の時間*j*の蓄熱量, $BackMin_j$: 24時から求めた入力値最小値の時の

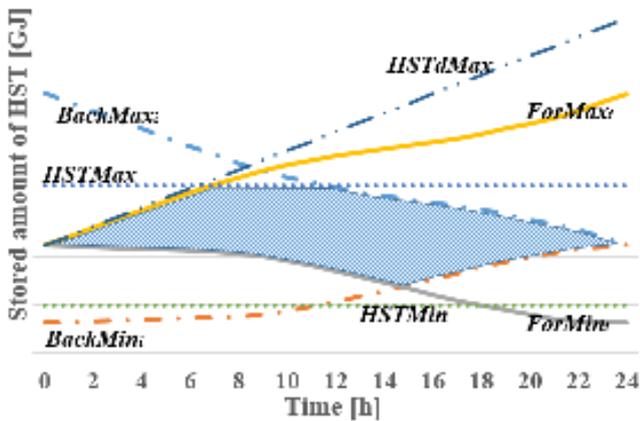


Fig. 4: A feasible region considering only facility characteristics of a heat storage tank and the proposed reduced search space.

時間 j の蓄熱量, $HSTMax$: 蓄熱槽上限値,
 $HSTMin$: 蓄熱槽下限値

一般的には, 蓄熱設備の単位時間当たりの入出力変化量最大値と最小値および上下限值 (Fig.4. の $HSTMax, HSTMin, HSTdMax$) の範囲を従属変数の実行可能領域とするが, 設備特性だけでなく, 継続性及び熱負荷特性を考慮して, Fig.4.斜線部の様に探索領域を削減することができる。蓄熱設備の探索領域削減は, 産業・業務・家庭モデルで利用される。

5.3 GMBSOによるSC全体最適化アルゴリズム

- Step.1 一様乱数により初期探索個体を生成する。
- Step.2 エネルギーコスト, 実電力負荷, CO_2 排出量を考慮し, 各個体の目的関数値を計算する。運用値が制約を超える時, ペナルティ値を目的関数値に付加する。
- Step.3 クラスタリング: 4.3 節で説明した FbG と 4.1 節で説明した BSO のクラスタリングアルゴリズムを用いて個体を分類し, クラスタセンターを設定する。
- Step.4 新個体生成: 4.2 節に示した MBSO の更新式(7)式を用いて新個体を生成する。また, 条件(9)を満たす時, 4.3 節に示した GBSO の修正式(10)式を用いて x_{ij}^{old} を修正する。
- Step.5 選択: 新個体の目的関数値を計算する。運用が制約を超える時, ペナルティ値を目的関数値に付加する。同じ個体番号の新個体と既存個体を比較し, 目的関数値が良い方を新個体とする。
- Step.6 最小の目的関数値をとる既存の個体 ($gbest$) と更新した個体の目的関数値を比較し, $gbest$ より小さい目的関数値をとる個体を $gbest$ とし更新。 $abest$ も同様に更新する。
- Step.7 反復回数が事前に設定した最大反復回数に達したら, Step.8 へ。そうでなければ, Step. 3 へ。

Step.8 最終的に得た運用解と目的関数値を出力。

5 シミュレーション

5.1 シミュレーション条件

富山市を想定し, 施設数は各分野で, 産業: 15, 業務: 50, 家庭: 45000, 上水道: 1, 下水道: 1, 鉄道: 1 とした²⁰⁾。 DEEPSO, BSO, MBSO, GBSO, 及び提案法である GMBSO を用いた手法を比較した。各手法のパラメータを示す。

・ DEEPSO¹⁴⁾パラメータ

τ : 0.2, τ' : 0.02, 各項の重み係数初期値: 0.5, R : 1.

・ BSO, MBSO, GBSO 共通パラメータ

$p_{clustering}$: 0.5, $p_{generation}$: 0.5, $p_{OneCluster}$: 0.2,

$p_{TwoCluster}$: 0.2, K : 5, c : 0.5.

・ MBSOパラメータ

Cr : 0.2, F : 0.5.

・ GBSOパラメータ

C_{min} : 0.1, C_{min} : 0.9.

個体数は 80, 試行回数は 50 回とした。最大反復回数は, 各手法間で評価回数を同一とするため, BSO, MBSO, GBSO と提案する GMBSO を用いた手法は 2000 回とした。 DEEPSO を用いた場合, クロウンを 1 つ作成し, これも評価するため, 目的関数の評価回数を同一とするため, 半分の 1000 回とした。上記のパラメータは, 事前シミュレーションで良い解を確認した値を設定している。

また, 以下のように, SC の目的の異なる 3 ケースを想定したシミュレーションを実施した。

Case 1: w_1 : 1, w_2 : 0, w_3 : 0 (エネルギーコスト削減)

Case 2: w_1 : 0, w_2 : 0, w_3 : 1 (CO_2 排出量削減)

Case 3: w_1 : 0.00001, w_2 : 0.99998, w_3 : 0.00001 (3 項を同程度に考慮するため。)

ペナルティ項に用いる重みは w_4 : 100000000

シミュレーションプログラムは, Intel Xeon E5-2660 (2.20GHz) PC 上の C 言語 (gcc version 4.4.7) を利用し構築した。

5.1 シミュレーション結果

Table.1 は DEEPSO, BSO, MBSO, GBSO, 提案する GMBSO による各ケースの目的関数値の平均値, 最小値, 最大値, 標準偏差値比較を示している。値は全てのケースで DEEPSO による結果の平均値を 100% としたときの値を示している。提案法である GMBSO による目的関数値の平均値, 最小値, 最大値, 標準偏差が最も削減されていることが確認できた。

Table.2 は, DEEPSO, BSO, MBSO, GBSO, 提案する GMBSO による Case1 (エネルギーコスト最小化) の時の最良運用解を示している。例として産業モデルにおけるガスタービン電力出力量と購入電力量を示す。このモデルにおいて, 8 時から 22 時のガスタービンによる電力出力量が安く, 購入電力料が高くなっている。エネルギーコストを下げるためには, 8 時から 22 時の

ガスタービンによる電力出力量が増え、購入電力量が減るべきである。シミュレーションの結果、提案法により、8時から22時のガスタービンによる電力出力量が最も増え、購入電力量が最も減っていることが確認できた(Table2のSum行)。

Table.3は、DEEPSO, BSO, MBSO, GBSO, 提案するGMBSOによるCase2(CO₂排出量最小化)の時の最良運用解を示している。例として産業モデルにおける

Table 1: Comparison of average, the minimum, the maximum, and standard deviation rates of Case 1, 2, and 3 among DEEPSO, BSO, GBSO, MBSO, and the proposed GMBSO.

Case		Ave.	Min.	Max.	Std.
1	DEEPSO	100	98.75	101.63	0.57
	BSO	97.13	96.46	97.96	0.30
	MBSO	97.2	96.75	97.66	0.20
	GBSO	95.94	95.55	97.03	0.26
	GMBSO	95.06	94.9	95.29	0.09
2	DEEPSO	100	99.53	100.58	0.20
	BSO	99.28	98.98	99.6	0.14
	MBSO	99.38	99.15	99.5	0.06
	GBSO	98.29	98.22	98.42	0.04
	GMBSO	98.26	98.17	98.36	0.04
3	DEEPSO	100	99.44	100.88	0.32
	BSO	99.64	99.38	99.87	0.09
	MBSO	98.37	98.3	98.46	0.04
	GBSO	99.36	99.12	99.53	0.10
	GMBSO	98.1	98.05	98.16	0.03

*) All of values are rates when the average of the objective function value of the conventional DEEPSO based method is set to 100 %.

Table 2: Comparison of the best facility operation for case 1 among DEEPSO, BSO, GBSO, MBSO, and the proposed GMBSO in an industrial model.

	DEEPSO		BSO		MBSO		GBSO		GMBSO	
	A	B	A	B	A	B	A	B	A	B
1	0.00	8.21	0.00	7	0.00	7.59	0.00	7.00	0.00	7.25
2	0.00	5.13	0.00	7.07	0.00	5.22	0.00	7.07	0.00	7.16
3	0.00	8.08	0.00	7.22	0.00	8.03	0.00	7.22	0.00	7.15
4	0.00	8.08	0.00	7.17	0.00	8.22	0.00	7.17	0.00	7.00
5	0.00	8.29	0.00	9.17	0.00	9.23	0.00	9.17	0.00	9.17
6	0.00	8.90	0.00	8.9	0.00	8.91	0.00	8.90	0.00	9.25
7	0.00	9.03	0.00	9.24	0.00	9.18	0.00	9.24	0.00	9.12
8	6.00	1.09	7.46	1.84	6.71	0.30	7.46	1.84	8.98	0.12
9	10.65	2.15	8.98	1.99	12.36	0.55	8.98	1.99	10.74	0.22
10	10.92	2.24	13.85	0.95	11.63	1.37	13.85	0.95	14.71	0.33
11	14.06	3.81	18.32	0.61	16.68	2.2	18.32	0.61	18.80	0.17
12	14.32	8.67	20.00	4.67	18.45	4.91	20.00	4.67	19.72	4.98
13	14.99	2.61	15.48	2.31	18.54	0.59	15.48	2.31	17.06	0.88
14	13.02	9.20	19.4	2.78	18.81	3.49	19.40	2.78	20.00	2.00
15	13.86	9.32	20.00	3.08	19.05	4.14	20.00	3.08	20.00	3.07
16	18.84	6.07	16.14	4.96	18.55	4.55	16.14	4.96	20.00	1.10
17	10.88	13.03	18.27	4.51	18.48	4.43	18.27	4.51	20.00	2.79
18	18.16	3.84	20.00	1.97	18.55	3.44	20.00	1.97	20.00	1.99
19	20.00	3.11	20.00	3.04	18.37	4.07	20.00	3.04	19.15	3.85
20	19.44	1.96	17.25	4.09	17.14	3.66	17.25	4.09	20.00	1.23
21	17.26	0.09	16.33	0.93	16.79	0.87	16.33	0.93	17.12	0.08
22	7.26	4.97	11.56	0.59	10.84	1.16	11.56	0.59	12.13	0.09
23	0.00	13.03	0.00	13.05	0.00	12.97	0.00	13.05	0.00	12.92
24	0.00	10.38	0.00	10.45	0.00	10.45	0.00	10.45	0.00	10.20
Sum	209.65	72.15	243.02	38.32	240.97	39.72	243.02	38.32	258.43	22.90

*) A: the amount of electric power output by GTG, B: the amount of purchased electric power, Sum: summation of each column A, and B at 8 to 22 hours.

ガスタービン電力出力量と購入電力量を示す。このモデルにおいて、CO₂排出量を下げするためには、1日においてガスタービンによる電力出力量が増え、購入電力量が減るべきである。シミュレーションの結果、提案法により、ガスタービンによる電力出力量が最も増え、購入電力量が最も減っていることが確認できた(Table3のSum行)。

6 まとめ

本論文では、Global-best Modified Brain Storm Optimization(以下、GMBSO)によるSC全体最適化を提案した。MBSOとGBSOを統合したGMBSOを新たに提案し、これをSC全体最適化に適用した結果と、従来法のDEEPSO, BSO, MBSO, GBSOを適用した結果と比較し、提案法によりコストの最小化、CO₂排出量の最小化、実電力負荷のピークシフトを実現しており、より効率的な設備の運転を実現することが確認できた。

今後の展開としては、大規模最適化に、より効果的な探索手法の開発と適用を行っていく。

参考文献

- 1) 経済産業省：スマートグリッド[®],スマートコミュニティ,
http://www.meti.go.jp/policy/energy_environment/smart_community/
- 2) Xcel Energy, SMARTGRIDCITY,
<http://smartgridcity.xcelenergy.com/>

Table 3: Comparison of the best facility operation for case 2 among DEEPSO, BSO, GBSO, MBSO, and the proposed GMBSO in an industrial model.

	DEEPSO		BSO		MBSO		GBSO		GMBSO	
	A	B	A	B	A	B	A	B	A	B
1	0.00	8.21	0.00	7	6.00	1.21	7.26	0.11	0.00	7.25
2	0.00	5.13	0.00	7.07	6.00	1.12	0.00	5.30	0.00	7.16
3	0.00	8.08	0.00	7.22	6.09	0.91	7.68	0.36	0.00	7.15
4	0.00	8.08	0.00	7.17	6.98	0.26	7.62	0.65	0.00	7.00
5	0.00	8.29	0.00	9.17	8.45	0.76	7.72	1.56	0.00	9.17
6	0.00	8.90	0.00	8.9	6.18	2.88	9.00	0.18	0.00	9.25
7	0.00	9.03	0.00	9.24	8.75	0.36	8.87	0.17	0.00	9.12
8	6.00	1.09	7.46	1.84	7.02	2.19	7.14	0.04	8.98	0.12
9	10.65	2.15	8.98	1.99	8.42	2.54	12.80	0.30	10.74	0.22
10	10.92	2.24	13.85	0.95	13.15	1.72	12.90	0.04	14.71	0.33
11	14.06	3.81	18.32	0.61	17.47	1.49	17.95	0.40	18.80	0.17
12	14.32	8.67	20.00	4.67	18.26	6.47	19.96	3.27	19.72	4.98
13	14.99	2.61	15.48	2.31	17.18	0.52	17.21	0.18	17.06	0.88
14	13.02	9.20	19.4	2.78	18.14	4.11	19.95	2.21	20.00	2.00
15	13.86	9.32	20.00	3.08	18.26	4.96	19.95	3.28	20.00	3.07
16	18.84	6.07	16.14	4.96	20.00	1.30	19.94	4.66	20.00	1.10
17	10.88	13.03	18.27	4.51	18.43	4.58	19.95	3.90	20.00	2.79
18	18.16	3.84	20.00	1.97	19.70	2.51	19.91	2.14	20.00	1.99
19	20.00	3.11	20.00	3.04	17.03	5.87	19.91	3.20	19.15	3.85
20	19.44	1.96	17.25	4.09	20.00	1.19	19.91	1.39	20.00	1.23
21	17.26	0.09	16.33	0.93	16.00	1.23	17.19	0.12	17.12	0.08
22	7.26	4.97	11.56	0.59	8.63	3.54	12.07	0.06	12.13	0.09
23	0.00	13.03	0.00	13.05	10.83	2.23	12.73	0.09	0.00	12.92
24	0.00	10.38	0.00	10.45	8.80	1.66	10.39	0.06	0.00	10.20
Sum	209.65	72.15	243.02	38.32	305.77	55.62	328.00	33.66	258.43	22.90

*) A: the amount of electric power output by GTG, B: the amount of purchased electric power, Sum: summation of each column A and B of whole of a day.

- 3) S. A. A. Jaber: "The MASDAR Initiative", Proc. of the first International Energy 2030 Conference, pp.36-37 (2006)
- 4) 経済産業省：スマートコミュニティ実証について, http://www.meti.go.jp/policy/energy_environment/smart_community/community.html (2010)
- 5) 経済産業省東北経済産業局：「スマートコミュニティ・ガイドライン～再生可能エネルギーを活用したまちづくりの進め方～」
- 6) 鈴木亮平・他：エネルギープラント運用計画のための最適化ベンチマーク問題，電気学会 C 部門大会 TC7-2 (2012-9)
- 7) Y. Makino, et al.: Development of a Smart Community Simulator with Individual Emulation) Modules for Community Facilities and Houses, Proc. of IEEE 4th GCCE (2015).
- 8) 河原林雅・他：Particle Swarm Optimization による送水計画問題の最適化，電気学会産業計測制御研究会 IIC-07-6, pp. 25-30 (2007)
- 9) 安田恵一郎：スマートコミュニティの定義とモデル構築，電気学会全国大会，1-H1-2 (2015).
- 10) 山口順之・他：スマートコミュニティにおけるエネルギー供給モデル，電気学会全国大会，1-H1-3 (2015)
- 11) 松井哲郎・他：スマートコミュニティにおけるエネルギー需要モデル，電気学会全国大会，1-H1-4 (2015).
- 12) 佐藤繭子・福山良和：PSO を用いたスマートコミュニティの全体最適化，電気学会システム研究会，ST-16-011 (2016)
- 13) 佐藤繭子・福山良和：探索領域の削減を考慮した Differential Evolution によるスマートコミュニティ全体最適化，平成 28 年電気学会 C 部門大会，GS4-2 (2016-8)
- 14) 佐藤繭子・福山良和：Differential Evolutionary Particle Swarm Optimization によるスマートコミュニティ全体最適化，電気学会論文誌 Vol.137, No. 9, pp.1266-1278 (2017)
- 15) 佐藤繭子・福山良和：Modified Brain Storm Optimization を用いたスマートコミュニティの全体最適化，電気学会全国大会，3-026 (2018)
- 16) M. Sato, Y. Fukuyama: Total Optimization of Smart City by Global-best Brain Storm Optimization, Proc. of GECCO 2018, (2018)
- 17) Y. Shi: Brain storm optimization algorithm, Proc. of International Conference in Swarm Intelligence. Springer, p.303-309 (2011).
- 18) Zhi-hui Zhan, Jun Zhang, Yu-hui Shi, and Hai-lin Liu, A Modified Brain Storm Optimization, Proc. of IEEE WCCI (2012).
- 19) M. El-Adb: Global-best brain storm optimization algorithm, in Swarm and Evolutionary Computation Vol. 37 pp. 27-44.
- 20) 菅野智司・他:スマートコミュニティモデルの活用，電気学会全国大会，1-H1-5 (2015)

顔正面と両手挙動の2動画像からの運転者上半身挙動の把握

生駒 哲一 (日本工業大学)

Grasping Upper Part Body Motion of Car Driver from Two Videos of Facial Frontal and Hands Behavior

Norikazu Ikoma (Nippon Institute of Technology)

Abstract— Grasping method of car driver's upper body motion by state space modeling and state estimation approach from two videos captured by facial frontal camera and hands behavior camera set above a seatbelt roller has been proposed for potential use of advanced safety driving support related to human factor in autonomous/manual driving. Head posture and hands motion in 3 dimensional space (i.e., not over image plane but in real space) have been obtained by state estimation via particle filter with state space formulation consisting of state vector with head posture and two palm/arm postures, smooth and consistent motion of the head and the two palm/arm, and likelihood evaluation over the two image frames of facial frontal camera and hand behavior camera, in addition with initial probability distribution of the state vector. Estimation result over videos captured at a driving simulator facility equipped with the two cameras have been reported as a first trial of the proposed method.

Key Words: Car driver, video image, human behavior

1 はじめに

運転者の状況を考慮した高度な安全運転支援や、自動運転レベル2～レベル3における人-機械間の運転主権受け渡し等で、運転者の状況をモニターし把握することが求められている。外界を把握する車載センサの活用が精力的に進められる一方で、キャビン内にもセンサを設置して、運転車や搭乗者の状況を把握し、的確な安全支援や安心・快適を提供する試みも重要性を増してきている。例えば、ドライブレコーダの新しい活用法¹⁴⁾を、著者は提案している。

運転者の状況をカメラなどのセンサ信号から把握する既存研究としては、汎用的な非ガウスフィルタであるパーティクルフィルタ¹⁾を活用して、運転者の物理的な挙動を推定する枠組み¹³⁾が提案され、安全運転支援に向けた運転者挙動の実時間推定³⁾として、一連の方法論が提案されている。より具体的には、顔(頭部)姿勢とステアリングを操作する両手挙動の推定を実時間でを行う方法⁶⁾が提案されている。

そこでは、顔を正面から撮影するカメラをステアリング奥に設置し、更に、ステアリングを見下ろすように撮影するカメラを、シートベルト巻取りの上部に設置している。これらの二つのカメラの動画像に対し、カメラごと個別に推定を行っている。従って、顔を正面から撮影するカメラからは、顔(頭部)の姿勢の推定結果が得られ、もうひとつのカメラからはステアリングを操作する両手挙動の推定結果が得られ、これら二つの推定の間の関連性は考慮されていない。

本研究では、顔を撮影するカメラ、および、ステアリングを撮影するカメラの、2種類のカメラから得られる二つの動画像を入力信号とし、運転者の上半身挙動を推定する方法を検討する。ここでの上半身とは、左右の両肩を結ぶ線分、左右の両腕、および頭部を指す。以下では、まず、運転者の顔(頭部)姿勢の推定と、ステアリングを操作する両手挙動の推定とを、個別に説明した後、これら二つの推定を同時に行う方法について論じる。二つの同時推定を段階的に進めるアプローチを採り、それに基づく実画像実験についても述べる。

2 運転者の顔姿勢の推定

運転者の顔を正面から撮影するために、カメラをステアリング・コラムの上部に設置し、動画像を得る。動画像中の時刻 k の画像フレームを \mathbf{I}_k^{face} と表す。初期時刻1から現在時刻 k までの画像フレームを、まとめて $\mathbf{I}_{1:k}^{face}$ と表記し、これがすなわち動画像を表している。

動画像 $\mathbf{I}_{1:k}^{face}$ から、運転者の顔(頭部)の姿勢の6自由度のうち、左右および上下の位置 (x, y) と、首の回転角度 θ の3自由度を、パーティクルフィルタを用いて推定する方法が提案されている⁶⁾。状態変数は、上述の3自由度から成るベクトル

$$\mathbf{x}_k^{face} = [x_k, y_k, \theta_k] \quad (1)$$

であり、その実現値がパーティクルとなる。多数のパーティクルにより、状態の事後確率分布

$$p(\mathbf{x}_k^{face} | \mathbf{I}_{1:k}^{face}) \quad (2)$$

を近似的に表す。

パーティクルフィルタのアルゴリズムでは、まず、適切な初期分布 $p_0(\mathbf{x}_0^{face})$ に従うパーティクル群を生成し、推定を開始する。その後、以下の手順に従い、パーティクル群を、時刻 $k-1$ から k へと時間更新する。

状態の時間変化は、時間的な滑らかさを考慮したシステムモデル(ダイナミクス)に基づくものとする。システムモデルは、抽象的な一般形としては、マルコフ性を表す条件付き確率分布

$$f(\mathbf{x}_k^{face} | \mathbf{x}_{k-1}^{face}), \quad (3)$$

あるいは、確率項 \mathbf{v}_k^{face} を持つ差分方程式

$$\mathbf{x}_k^{face} = \mathbf{f}^{face}(\mathbf{x}_{k-1}^{face}, \mathbf{v}_k^{face}) \quad (4)$$

で表される。パーティクルフィルタの時間更新アルゴリズムとしては、システムモデルに従い、各パーティクルの1期先予測値を得る。

システムモデル具体的な式は、左右および上下の位置 (x, y) については

$$x_k = x_{k-1} + v_k^x, \quad y_k = y_{k-1} + v_k^y \quad (5)$$

首の回転角度 θ については

$$\theta_k = \theta_{k-1} + v_k^\theta \quad (6)$$

となる。上記の各式において、 v_k^x, v_k^y, v_k^θ は確率項であり、システムノイズとも呼ばれる。ここでは互いに確率的に独立とする。 v_k^x および v_k^y は正規分布に従うものとし、 v_k^θ は円周角における確率分布であるフォンミーゼス分布と、裾の重い分布（ここでは一様分布）との混合分布に従うものとする。

パーティクルフィルタの時間更新アルゴリズムでは、次に、動画像中の時刻 k の画像フレーム \mathbf{I}_k^{face} に対し、尤度計算を行う。尤度は、抽象的な一般形としては、状態を条件に持つ観測（ここでは画像フレーム）の確率モデル

$$h(\mathbf{I}_k^{face} | \mathbf{x}_k^{face}) \quad (7)$$

であり、これに、パーティクルと画像フレームを代入して、尤度値が算出される。

パーティクルフィルタの時間更新アルゴリズムの最後のステップとしては、算出された尤度に比例する確率で、1期先予測のパーティクル群から復元抽出を行い、ろ波（フィルタ）のパーティクル群を得る。これで、時刻 $k-1$ から k への時間更新が完了する。

具体的な尤度計算は、顔位置および瞳の色の2要素から成り、各要素の概略は次の通りである。顔位置の尤度は、顔検出器¹⁵⁾を画像フレームに適用して得られる顔の位置と大きさを観測値とし、1期先予測のパーティクルから算出される顔位置仮説との誤差より算出する。瞳の色の尤度は、検出前追跡のアプローチに基づき、1期先予測のパーティクルから算出される瞳領域仮説に対して、瞳の基準色との照合を行い得られる。

顔検出器¹⁵⁾による顔の位置や大きさだけでなく、顔器官（目や鼻など）の検出器⁴⁾も活用すれば、観測情報がより豊かになり、首の傾げ角 φ も扱うことができる²⁾。この場合、状態変数は、下記の4自由度から成るベクトルとなる。

$$\mathbf{x}_k^{face} = [x_k, y_k, \theta_k, \varphi_k] \quad (8)$$

新たに追加された傾げ角 φ_k の時間変化を表すシステムモデルは、式(6)と同様とし、そのシステムノイズはフォンミーゼス分布に従うものとする。

3 ステアリングを操作する両手挙動の推定

カメラをシートベルト巻き取り器の上方に設置し、ステアリングを見下ろすように撮影した動画像 $\mathbf{I}_{1:k}^{hand}$ から、ステアリングを操作する両手の挙動を推定する一連の方法が、著者により提案されている。まず、素朴な方法によるステアリング操作における手の握り位置（角度）の推定^{11) 12)}では、左右の各手のステアリング上での握り位置（角度）

$$\mathbf{x}_k^{hand} = [\vartheta_k^L, \vartheta_k^R] \quad (9)$$

を推定項目とし、画像フレーム \mathbf{I}_k^{hand} の肌色に着目して尤度計算を行い、パーティクルフィルタにて状態推定

$$p(\mathbf{x}_k^{hand} | \mathbf{I}_{1:k}^{hand}) \quad (10)$$

を行う。状態の時間変化については、状態ベクトルの要素ごと独立に、円周上のランダムウォークに従うモデル式を用いる。

次に、相互に隠れを生じ得る両手ステアリング操作挙動の推定¹⁰⁾では、左右の手が交差し隠れることや、半袖シャツを着用した場合に腕部分の肌色が露出することなどへの対処を提案している。半袖シャツであっても、長袖シャツであっても、手首の部分が露出していることに着目して、手首部分の肌色領域も尤度評価に加えるようにしている。ステアリングの握り位置から、手首部分の領域への角度 ψ を推定項目に加え、状態ベクトルは

$$\mathbf{x}_k^{hand} = [\vartheta_k^L, \vartheta_k^R, \psi_k^L, \psi_k^R] \quad (11)$$

となる。追加された手首部分の領域への角度 ψ のシステムモデルは、角度の変化範囲を経験的に限定したもので、左右の手でその範囲は異なる。限定した範囲において、左右それぞれ独立なランダムウォークに従う。

式(11)の状態を推定することで、手首の延びる向きが概略的ながら分かる。次の時刻においては、片手の掌から腕の領域を削除した画像を生成し、これを反対の手の尤度評価に用いることで、左右手の相互作用に関する複雑な問題を回避している。

更に、片手運転や、両手を放した運転などにも対処する方法を提案している。そこでは、左右の各手の尤度の値に着目し、値が小さい場合には、対応する手は存在しないものと見なす。また、パーティクルフィルタのアルゴリズムにおいて、パーティクルごとに左右手の解釈がまちまちになる問題への対処方法も提案している。

色特徴（肌色）のみでなく、深度センサを活用⁸⁾し、腕の部分も尤度評価に加える方法⁹⁾も提案されている。さらには、GPUによる並列計算と深度カメラを用いた実装方法も⁷⁾提案されている。

4 顔姿勢と両手挙動の同時推定

顔部姿勢の状態推定を式(2)で、両手挙動の状態推定を式(10)で、個別に実施する方法が提案されている。これらに対して、本研究では、これら二つを関連させて同時に推定し、同時確率分布

$$p(\mathbf{x}_k^{face}, \mathbf{x}_k^{hand} | \mathbf{I}_{1:k}^{face}, \mathbf{I}_{1:k}^{hand}) \quad (12)$$

を得る。その方法は、これまでのモデル化を、顔部姿勢と両手挙動の同時確率分布へと素直に拡張すればよい。ただし、状態ベクトルの次元が高くなり、モンテカルロ誤差も大きくなるため、実装にあたっては、粒子数を増やす等の措置が必要となる。

5 実験

運転シミュレータにてステアリングを操作する動画像を撮影し、これに対して提案法にて状態推定を行った。パーティクルフィルタの実装にはC言語のライブラリ⁵⁾を用いた。これにより、パーティクルフィルタの

アルゴリズムは自動的に計算されるため、プログラミング実装は主たるモデル計算の部分に注力することができた。実装においては、頭部姿勢推定プログラムと、両手挙動推定プログラムとを、共通するパーティクルフィルタライブラリに合併する作業を実施した。ライブラリが汎用に作られている為、特に困難は生じずに、比較的短時間（数日程度）で完成することができた。

実験の結果得られた動画像のうち、いくつかの典型的な時刻の画像フレームを、Fig. 1 および Fig. 2 に示す。それぞれ、頭部姿勢推定の結果と、両手挙動推定の結果である。頭部姿勢推定の結果において、各時刻の3つの画像は、左が原画像において顔器官検出⁴⁾を適用した結果、中央がパーティクルフィルタによる推定結果（平均値）、右が全パーティクルを描画したものである。両手挙動推定の結果においては、左が原画像、中央がパーティクルフィルタによる推定結果（平均値）、右が全パーティクルを描画したものである。

6 まとめと今後の課題

ステアリング奥に設置したカメラで撮影した顔の動画像と、シートベルト巻き取り器上方に設置したステアリングを見下ろすように撮影するカメラの動画像から、状態空間モデルとパーティクルフィルタによる状態推定にて、頭部姿勢と両手挙動の同時確率分布を推定する方法について述べ、運転シミュレータにて撮影した動画像に対する予備的な実験結果を報告した。

今後の課題としては、まず、提案法の定性的な性能評価などが挙げられる。次に、提案法に基づき、これを運転者の上半身挙動の推定へと拡張することが挙げられる。ここでの上半身とは、両肩を結ぶ線分、両腕（上腕・前腕・手首・掌）、頭部を指す。上半身は複雑な多関節にて構成されるが、これを適切に簡略化して、得られる画像等のセンサ情報からの確かに推定する方法を考案する必要がある。

謝辞

本研究は、統計数理研究所共同研究プログラム（30－共研－2014）の助成を受けた。

参考文献

- 1) 生駒哲一, "パーティクルフィルタ～汎用的な非ガウスフィルタ", 計測と制御, Vol.56, No.9, pp.644-649, 2017.
- 2) 生駒哲一, "パーティクルフィルタによる運転者顔姿勢の実時間推定における首傾げの扱いについて", 第32回信号処理シンポジウム, pp.506-511, 2017.
- 3) 生駒哲一, 『パーティクルフィルタによる運転者挙動の推定と運転意図推測への応用』, ドライバ状態の検知・推定技術と運転支援・自動運転への応用, 技術情報協会, 2016.
- 4) V.Kazemi and J.Sullivan, "One millisecond face alignment with an ensemble of regression trees", 2014 IEEE Conference on Computer Vision and Pattern Recognition (CVPR 2014), pp.1861-1874, 2014.
- 5) Norikazu Ikoma, "Programming Implementation of Particle Filter into a General Library Framework", Ninth International Conference on Innovative Computing, Information and Control (ICICIC2014), ICICEL, Vol.9, No.3, pp.655-663, 2014.
- 6) 生駒 哲一, パーティクルフィルタによる運転者の顔姿勢および両手挙動の実時間推定, 自動車技術会論文集, Vol.44 No.3, pp.919-924, 2013.
- 7) Norikazu Ikoma, "GPGPU Implementation for Steering Hands Tracking of a Car Driver by Particle Filter

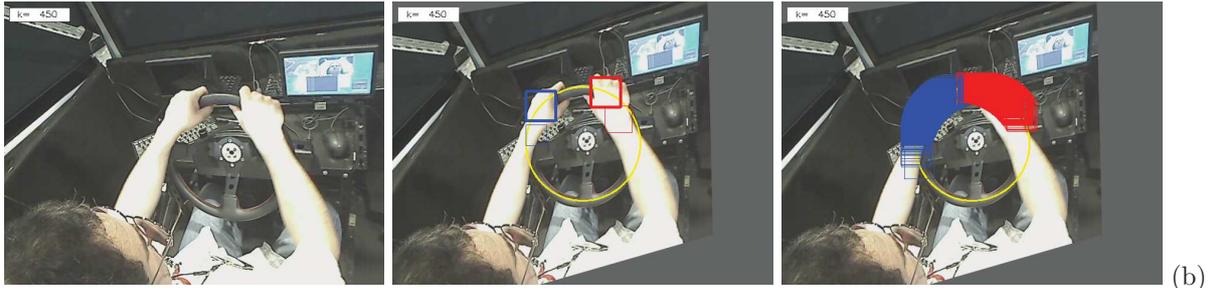
- with Depth Image Sensor", The Second International Conference on Robot, Vision and Signal Processing (RVSP-2013), Dec.10-12, 2013, Kitakyushu, Japan, pp.164-167, 2013.
- 8) Norikazu Ikoma, "Hands and arms motion estimation of a car driver with depth image sensor by using particle filter", The 14th International Symposium on Advanced Intelligent Systems (ISIS2013), Nov.13-16, 2013, Daejeon, Korea, S1b-4, 2013.
- 9) Norikazu Ikoma, "Tracking of Car Driver's Hands in Depth Image Sensor by Particle Filter", 8th International Conference on Innovative Computing, Information and Control (ICICIC2013), Sep.14-17, 2013, Kumamoto, Japan, A5-06, ICICIC2013-840, 2013.
- 10) Norikazu Ikoma, "Real-Time Motion Estimation of Car Driver's Hands and Arm's Direction in Vision under Possible Mutual Occlusion by Particle Filter", 6th Int'l Conf. on Soft Computing and Intelligent Systems and 13th Int'l Sympo. on advanced Intelligent Systems (SCIS & ISIS 2012), Nov.20-24, Kobe, JAPAN, pp.701-704, 2012.
- 11) "Visual tracking of both hands of car driver by particle filter", N.Ikoma, 5th Int'l Conf. on Soft Computing and Intelligent Systems and 11th Int'l Sympo. on advanced Intelligent Systems (SCIS & ISIS 2010), Dec.8-12, Okayama, JAPAN, pp.1547-1552, 2010.
- 12) 生駒 哲一, "ステアリング周辺における運転者両手挙動の動画像追跡について", 第20回インテリジェントシステムシンポジウム (FAN2010), Paper no.143, 2010.
- 13) N.Ikoma, Y.Tanaka, Y.Inokuchi, I.Miyasita, K.Kawamoto, and T.Nishida, "Car Driver's Body Motion Estimation for Safety Driving using Particle Filter", Proc. of 4th International Symposium on Computational Intelligence and Industrial Applications, pp.17-25, 2010.
- 14) N.Ikoma, K.Matsuda, K.Akahoshi, K.Kawamoto, H.Kawano, and H.Maeda, "A new concept of drive recording system by estimating human intention using particle filters", The Second International Conference on Innovative Computing, Information and Control (ICICIC2007), Sep. 5-7, Kumamoto, Japan, CD-ROM(C11-08.pdf), 2007.
- 15) P.Viola and M.Jones, "Rapid object detection using a boosted cascade of simple features", Proc. of 2001 IEEE Computer Society Conf. on Computer Vision and Pattern Recognition (CVPR 2001), pp. I-511-I-518, 2001.



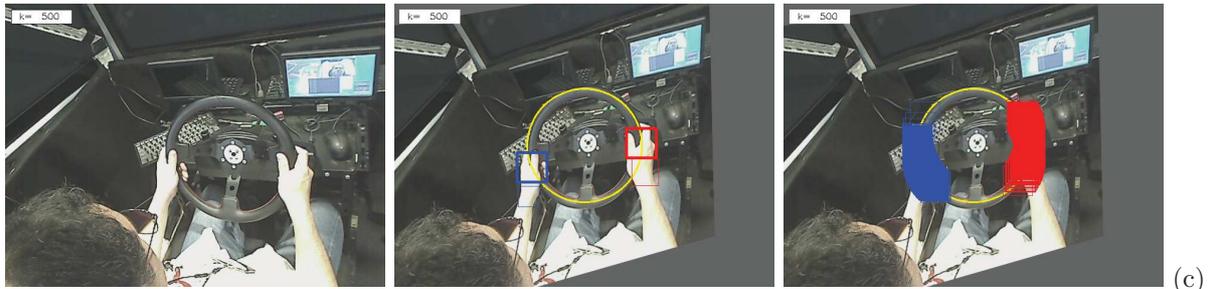
Fig. 1: 実験結果 (頭部姿勢推定の結果)



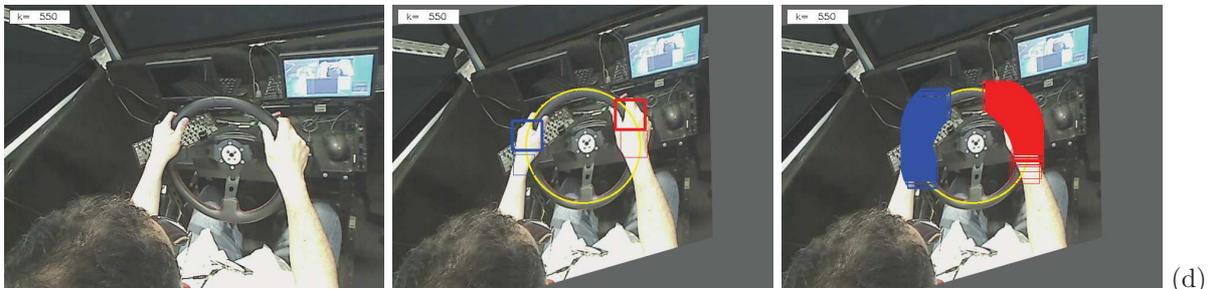
$k = 400$



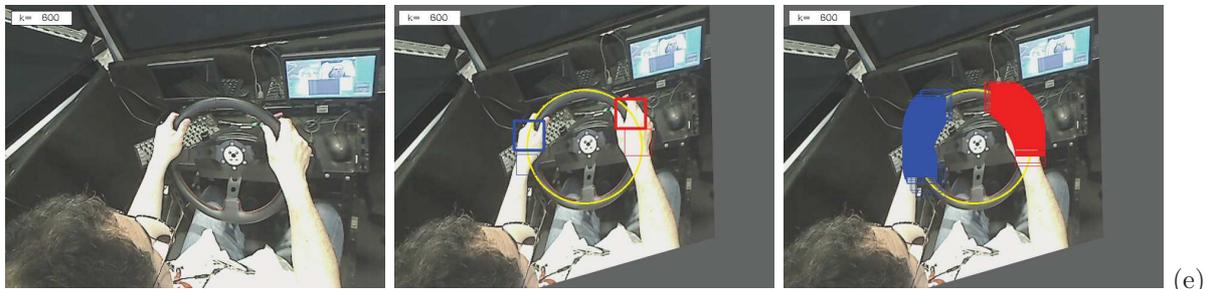
$k = 450$



$k = 500$



$k = 550$



$k = 600$

Fig. 2: 実験結果（両手挙動推定の結果）

内装の違い・就寝前の音楽聴取が 睡眠および知的生産性に与える影響の評価

○佐藤慧一 浅野貴大 満倉靖恵 (慶應義塾大学)

Effects of House Interior and Music Listening on Sleep Quality and Workplace Productivity

* Keiichi Sato, Takahiro Asano and Yasue Mitsukura (Keio University)

Abstract—The purpose of this study is to quantitatively evaluate effects which house interior and music listening have on sleep quality and workplace productivity. Sleep deprivation reduces workplace productivity, so improvement of sleep quality is important. In this study, we focus on house interior and music listening, which are used in previous studies as environmental factors considered to affect sleep quality. We measured using the simple electroencephalogram (EEG) device and polysomnography (PSG). The result showed that music listening made subjects strained and wooden interior improved typing task speed through improving sleep quality. From this result, we identified the appropriate conditions for sleep quality and workplace productivity.

Key Words: EEG, Sleep Stage, Workplace Productivity

1 はじめに

近年、ICTの発展によるオフィスワークの変化に伴い、知的生産性を向上させるための研究がなされている¹⁾。そのアプローチは大きく2つに分けられる。1つ目は、知的創造を生むワークプレイスの整備である。一例として、コミュニケーションが活発で知的刺激に満ちた執務空間づくりが挙げられる²⁾。2つ目は、知的生産の主体となるオフィスワーカーの生活行動に着目することである。生活行動の中でも睡眠について着目する。人は睡眠が不足すると翌日の知的生産性が低下するといわれている³⁾。そのため、睡眠の質を向上させることが翌日の知的生産性の向上のために重要な要因の1つであると考えられている。睡眠に影響すると考えられる環境要因として、既往研究で多く扱われている寝室の内装の違いと音楽聴取に着目する。

木の香りは交感神経活動を抑制する働きがあるとされており、寝室の内装を木質化することで睡眠の質が向上するといわれている^{4,5)}。また、音楽聴取が交感神経活動や不安、心拍数、呼吸数の低下をもたらすと考えられており⁶⁾、睡眠前に音楽を聴くことで睡眠の質が向上するといわれている⁷⁾。しかしながら、既往研究の多くは内装の違いや睡眠前の音楽聴取が睡眠の質にもたらす影響をアンケート等により定性的に評価している。したがって、これらの影響を定量的に評価する研究を行う必要があるといえる。定量的に評価する方法として、生体信号を用いた評価が挙げられる。

そこで本研究では、脳波計測と終夜睡眠ポリグラフ (Polysomnography: PSG) 検査を実施することにより睡眠の質にもたらす影響を定量的に評価する。既往研究において前頭葉部位の脳波は知覚や情動の影響が表れるとされているため⁸⁾、前頭葉部位の脳波を単極脳波計で計測することで情動変化と脳波の相関性を調査する。単極脳波計は被験者への負担が比較的軽いことから、実環境に近い条件下での計測が可能である。また、終夜睡眠ポリグラフ検査とは睡眠中の生体現象を計測する方法である。計測した指標を基に睡眠段階を30秒毎に5段階で判定することで睡眠の質を評価する。そして、これらの計測結果と知的生産性評価タスクとの関係を調査する。

本研究では、寝室の内装の違いと睡眠前の音楽聴取が睡眠の質にもたらす変化を介して翌日の知的生産性に

与える影響を定量的に評価することを目的とする。寝室の内装が木質・非木質の部屋において、音楽聴取あり・なしの条件下で実験を行う。脳波計測および睡眠深度計測を実施することにより、内装の違いと睡眠前の音楽聴取が睡眠の質にもたらす変化を介して知的生産性に与える影響を定量的に評価する。

2 実験および解析

2.1 実験条件

実験は、健常20代男女19名を対象として行った。被験者は、内装が木質の部屋に宿泊する群、非木質の部屋に宿泊する群に分けられた。いずれの部屋も広さ、方角、天井高は統一した。被験者は1泊の実験を2回行い、1泊は就寝前に音楽聴取あり、もう1泊は音楽聴取なしとした。よって2日間の音楽聴取の順番は、1日目は音楽聴取あり・2日目は音楽聴取なしの群と、1日目は音楽聴取なし・2日目は音楽聴取ありの群とに分けられた。また、1部屋に同時に宿泊する人数は1名または2名であった。

本研究で実施する実験の流れをFig. 1に示す。被験者は20:30に集合し、環境に慣れるため21:00までの30分間自由に活動した後、脳波計測を行った。音楽聴取ありの被験者は、内装の異なる2部屋それぞれにおいて、21:00から音楽を1時間聴取した。用いる音楽は、株式会社USENのチャンネルC-19 "ヒーリングミュージック ~癒し音楽~" とした。この音楽は、あらかじめ定めた一定音量でスピーカーから再生した。音楽聴取の有無に関わらず、21:00から22:00までの1時間は、デスクワークを行った。デスクワーク中は、計測者は別室にて待機した。デスクワークが終了した22:00から脳波計測を行った。その後、終夜睡眠ポリグラフ検査装置を装着し、睡眠中の生体信号を計測した。睡眠時間は23:00~6:00の7時間であった。睡眠時は部屋には被験

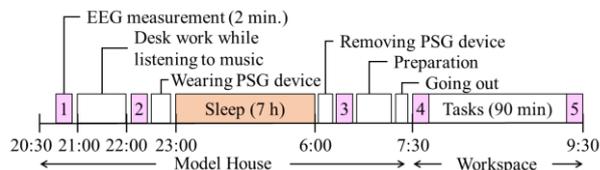


Fig. 1: The experimental flow

者のみとするため、終夜睡眠ポリグラフ検査装置の装着後に計測者は退出し、別室にて待機した。午前6:00の起床直後に終夜睡眠ポリグラフ検査装置を取り外し、脳波計測を行った。朝食等の外出準備の後、別の建物にある作業空間に移動した。この部屋は被験者全員同一の部屋であった。その後、午前7:30から脳波計測を行った。脳波計測後、知的生産性の内、知識処理を計測するタスクとしてタイピングを2回、知識創造を計測するタスクとしてマインドマップを3回行った。タスクはFig. 2に示す流れで、合計90分間行った。タスク終了後、脳波計測を行って本実験の終了とした。

2.2 終夜睡眠ポリグラフ検査(Polysomnography: PSG)による睡眠検証実験

睡眠中の生体信号を計測し睡眠段階を判定するため、就寝前に終夜睡眠ポリグラフ検査装置を装着した。本研究では、フィリップス・レスピロニクス合同会社製の終夜睡眠ポリグラフ検査装置であるアリスPDx⁹⁾を用いて睡眠中の生体信号を計測した。計測項目は、脳波(Fig. 3に示す国際10-20法におけるC3, O2箇所)、眼球運動、心電図、呼吸曲線、酸素飽和度、前脛骨筋電図、オトガイ筋電図、いびき、体位、および体動である。装着が完了した被験者から計測を開始し、起床後に計測を終了した。計測した生体信号を用いて、R&K法に基づき5段階(Wakefulness: WK, Rapid Eye Movement sleep: REM, non-REM sleep 1-3: N1, N2, N3)の睡眠段階を判定した。R&K法とは、脳波、眼電図、筋電図を用いて睡眠を30秒毎に5種類の睡眠段階に判定するゴールドスタンダードな睡眠評価法である¹¹⁾。それぞれの睡眠段階について、全睡眠時間における割合を算出した。また、消灯からN1, N2, N3に至るまでの時間(Latency)、一度入眠してからWKと判別された合計時間である中途覚醒時間(Wake After Sleep Onset: WASO)、全記録時間と全睡眠時間の比である睡眠効率(Sleep efficiency)を算出した。それぞれの睡眠指標について二標本検定を行うことで、有意差を検証した。

2.3 知的生産性計測実験

知的生産性を計測するタスクとして、タイピングとマインドマップを実施した。タイピングは予め用意されたPCとキーボードを用いて、各試行毎に定められた英文を入力した。1試行の制限時間は20分間とし、1回の実験で2試行実施した。また、制限時間内にタイピングが終了しないよう十分な長さの英文を用いた。マインドマップとは、紙の真ん中に与えられた主題から連想される単語を放射状に繋げながら書き出すタスクである。関連した単語を繋げて書き出すことにより発想を可視化することが可能であるため、知的創造性を計測するタスクとして有効であると知られている。本実験では「仲間」、「健康」等、各試行毎に定められた主題を用いた。1試行の制限時間は12分間とし、1回の実験で3試行実施した。

タイピングの正打数、誤打数、マインドマップの書き出した単語数のそれぞれについて、1日目から2日目にかけての増加率(Increase rates)を算出した。それぞれの成績の絶対値では大きな個人差が生じてしまうのに対し、増加率を算出することにより個人差を考慮することが可能である。増加率の算出の概要をTable 1に示す。増加率は、被験者毎に1日目と2日目の同じ試行間

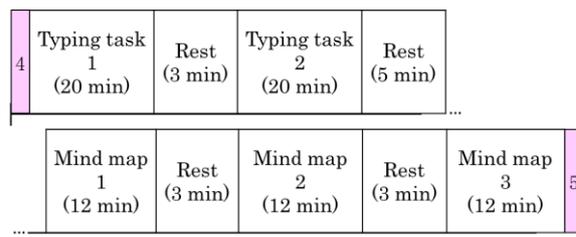


Fig. 2: The procedure of the proposed task flow

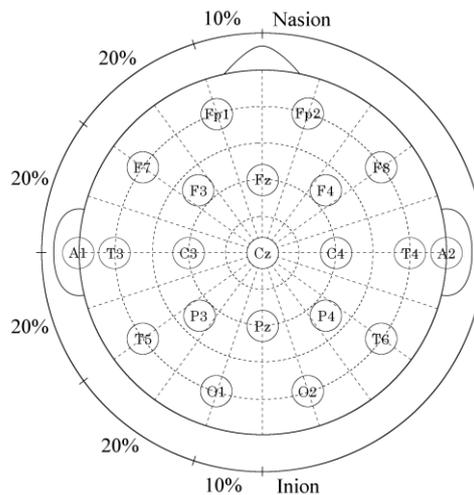


Fig. 3: International 10-20 system¹⁰⁾

Table 1: The calculation of increase rates

	Score		Increase Rates
	Day 1	Day 2	
Task 1	A	B	B / A
Task 2	C	D	D / C
Task 3	E	F	F / E
Average	$((B / A) + (D / C) + (F / E)) / 3$		

での比を算出し、平均値を求めることによって算出した。よって1被験者につき、タイピングの正打数(Correct)、誤打数(Wrong)、マインドマップの書き出した単語数の増加率がそれぞれ1データずつ与えられる。睡眠指標とタスクの増加率について相関係数(Correlation coefficient)を算出した。

2.4 脳波計測実験

被験者は椅子に着席し、単極脳波計を装着して脳波計測を行った。計測は閉眼かつ安静の状態で行った。視覚情報を脳に送る眼球は脳に近いので、瞬きによる眼電信号は脳波信号に混入しやすい。目を閉じることによってこれを抑制し、ノイズの少ない脳波データを取得することが可能である。1回の計測は2分間とした。本研究では、単極脳波計の中でもNeuroSky社のMindWave Mobile¹²⁾を用いて脳波計測を行った。脳波計測箇所は、Fig. 3に示す国際10-20法におけるFp1箇所とした。

取得した脳波信号のサンプリング周波数は512Hzであった。初めに、計測した脳波信号に対しフィルタリ

ング処理を行った。通過域が1-30Hzの帯域通過フィルタを適用し、脳波信号に混入した筋電や眼電といったノイズを除去した。次に、フィルタを適用した脳波信号に対し、512点で高速フーリエ変換を行うことで時間領域から周波数領域へと変換し、パワースペクトルを求めた。変換を行う際、512点を切り出し区間としてハミング窓を適用した。また、時間窓のシフト量は512点とした。脳波信号のサンプリング周波数と高速フーリエ変換の点数が等しいため、得られるパワースペクトルの周波数分解能は1Hzである。本研究では1-30Hzの区間の30次元のパワースペクトルデータを使用する。その後、脳波の個人差を考慮するため、正規化を行った。正規化は、1-30Hzのパワースペクトルの合計が1となる手法を用いた。最後に、2群のデータの差異を検証するため、パワースペクトルの周波数毎に二標本t検定を行った。

3 結果および考察

3.1 就寝前の音楽聴取による影響

初めに、就寝前の音楽聴取が睡眠に与える影響を評価する。音楽聴取ありの群と音楽聴取なしの群との睡眠指標の差異を算出した結果をTable 2に示す。ただし、木質の部屋に宿泊した群内および非木質の部屋に宿泊した群内でそれぞれ睡眠指標を算出した。Table 2において用いたデータは、1回目の宿泊で音楽聴取あり、2回目の宿泊で音楽聴取なしの順で実験を行った17名である。Table 2より、 p 値が0.1および0.05を下回る指標がないことから、音楽聴取による睡眠への影響がないことが確認された。

音楽聴取が睡眠に影響を与えないという結果は、既往研究の結果と一致しない。そのため、本実験における音楽聴取が被験者にどのような影響を与えたのかを調査するため、音楽聴取前後の脳波に着目した。音楽聴取前後の脳波のパワースペクトルに対し、周波数毎に有意水準0.01で二標本t検定を行った結果、音楽聴取なしではいずれの周波数でも有意差が確認されなかった。一方音楽聴取ありでは、音楽聴取後に有意に18Hz成分が増加したことが確認された。18Hzは集中

や緊張の状態で見られる β 波帯域のスペクトルであるため、18Hz成分の増加は集中や緊張状態になったことを表している。睡眠中の脳波は低周波成分が大きな割合を占める⁸⁾。そのため、就寝前の脳波は β 波帯域よりも低周波である帯域の脳波が増加することで入眠しやすくなり、睡眠の質も向上すると考えられる。18Hz成分が増加するという今回の結果は、音楽聴取は睡眠に対して悪い影響を与えるという意味を示していると考えられる。この原因として、本実験は音楽聴取あり・音楽聴取なしの条件においてそれぞれ1日ずつ実施したため、普段聴き慣れない音楽を聴いたことにより緊張状態となったと考えられる。よって、実験日数を増加させ音楽聴取に慣れさせることにより、脳波への影響は変化すると考えられる。また本研究では、音楽聴取中にデスクワークを実施した。音楽聴取がデスクワークへの集中を促進したことで、睡眠に影響を与えたのではないかと考えられる。

3.2 寝室の内装の違いによる影響

初めに、寝室の内装の違いが睡眠に与える影響を評価する。木質の部屋に宿泊した群と非木質の部屋に宿泊した群との睡眠指標の差異を算出した結果をTable 3に示す。ただし、音楽聴取ありの群内および音楽聴取なしの群内でそれぞれ算出した。Table 3において用いたデータは、1回目の宿泊で音楽聴取あり、2回目の宿泊で音楽聴取なしの順で実験を行った17名である。Table 3より、音楽聴取の有無に関わらず、N3の割合が有意に増加していることが分かる。したがって、内装木質化は深睡眠の割合を有意に増加させることを明らかにした。

次に、内装木質化で増加したN3が翌日の知的生産性に与える影響を評価する。N3の割合とタスク成績の増加率の相関係数を算出した結果をTable 4に示す。結果を、相関係数が1を赤、0を白、-1を青としたカラースケールを用いて示した。Table 4より、タイピングの正打数とN3の割合が、木質の部屋に宿泊した群において強い正の相関があることが分かる。したがって、内装木質化はN3の割合を増加させることによって、翌日の知識処理の速度に良い影響を与えるという

Table 2: Differences in sleep data between music listening and silence

	REM [%]	N3 [%]	N3 / REM	Latency [min]			WASO [%]	Sleep efficiency [%]
				N1	N2	N3		
Wood	-6.31	-2.79	5.53	-7.69	-3.86	-8.81	-0.310	1.24
Non-wood	2.71	-1.16	-0.233	8.67	2.22	7.61	0.901	-1.12

*: $p < 0.05$ **: $p < 0.10$

Table 3: Comparison of increase rates of task performance by order of music listening

	REM [%]	N3 [%]	N3 / REM	Latency [min]			WASO [%]	Sleep efficiency [%]
				N1	N2	N3		
Music	-6.58*	10.1**	1.66	-12.3	-9.79	-22.8*	-3.41	4.53
Silence	2.44	11.7*	0.829**	4.08	-3.69	-6.41	-2.20	2.16

*: $p < 0.05$ **: $p < 0.10$

Table 4: Correlation coefficients between the ratio of N3 and increase rates of tasks

		N3	
Mind map		Wood	-0.318
		Non-wood	0.425
Typing task	Correct	Wood	0.788
		Non-wood	-0.310
	Wrong	Wood	0.0830
		Non-wood	0.404



ことを明らかにした。

4 おわりに

本研究では、寝室の内装の違いと睡眠前の音楽聴取が睡眠の質に与える変化を介して翌日の知的生産性に与える影響を評価することを目的とした。この目的を遂行するため、終夜睡眠ポリグラフ検査装置を用いて医療現場と同様に睡眠中を計測し、各睡眠段階の割合等の睡眠指標を算出した。算出した睡眠指標に対して音楽聴取・内装の条件毎に有意差検定を行い、各条件による睡眠への影響を検証した。次に、知的生産性を計測するタスクを実施し、2日間の成績の増加率を算出した。算出した増加率と睡眠指標との相関係数を求めることで、各条件下での睡眠と知的生産性の関係を検証した。さらに、音楽聴取の有無それぞれの成績の増加率を比較することで、知的生産性を向上させる音楽条件を検証した。また、脳波計測を実施し、各被験者の脳波データのパワースペクトルを算出した。各周波数成分に対して有意差検定を行うことで、各計測間での脳波の変化を検証した。実験の結果、音楽聴取については、睡眠の質への影響を確認できなかった。既往研究の結果とは異なる結果であった。そこで音楽聴取前後の脳波解析を行ったところ、短期的な音楽聴取により緊張状態となったためであるという可能性、音楽聴取とデスクワークの組み合わせにより就寝前に集中力を増加させたためであるという可能性を示した。また、内装の違いについては、睡眠の質を向上させることによって知識処理の速度を増加させることを明らかにした。

本研究では、2日間の音楽聴取の順番に人数の偏りが生じてしまったことや、被験者数が十分でないと考えられることから、被験者数を増加させ検証する必要があると考えられる。また、脳波計測実験によって実験デザインに問題があるということが分かったため、実験の長期化や音楽聴取中の行動の改善といった実験デザインの再構築が必要である。また、寝室の内装木質化が睡眠の質に与える変化を介してタイピングに影響を与えることが確認できたが、より創造的なタスクであると考えられるマインドマップへの影響は確認できなかった。よって、知的生産性を測定するための他のタスクを実施することで知的創造への影響を評価する必要があると考える。さらに、内装木質化が睡眠の質の変化を介して翌日の知的生産性に与える影響を評価したが、なぜ内装木質化がこのような影響を与えるかについては本研究では明らかにしていない。既往研究において、内装木質化による木の色彩・香り・感触といった要因が就寝前の交感神経の抑制に寄与すると

いわれているが^{4,5)}、これらの要因について定量評価を行うことにより、内装木質化が睡眠の質を変化させる要因を調査する必要があると考えられる。

参考文献

- 1) 建築環境・省エネルギー機構：知的創造のためのワークプレイス計画ガイドライン, 丸善出版, (2013)
- 2) 沼中ら：知的生産性向上を目指した執務空間におけるコミュニケーションおよび環境要素に関する実態調査, 日本建築学会環境系論文集, **80**-713 (2015)
- 3) Colten H. R. and Altevog B. M. : Sleep Disorders and Sleep Deprivation: An Unmet Public Health Problem, 137/172, National Academy of Sciences (2006)
- 4) 山本ら：香気成分セドロールが睡眠に及ぼす影響, 日本生理人類学会誌, **8**-2, 25/29 (2003)
- 5) 西村ら：睡眠の質と日中の知的生産性を高める住宅内装木質化率に関する被験者実験, 空調和・衛生工学会大会学術講演論文集, **6**, 265/268 (2016)
- 6) A. Mofredj M.D. *et al.* : Music Therapy, A Review of the Potential Therapeutic Benefits for the Critically Ill, Journal of Critical Care, **35**, 195/199 (2016)
- 7) Harmat L., Takács J. and Bódzis R. : Music Improves Sleep Quality in Students, Journal of Advanced Nursing, **62**-3, 327/335 (2008)
- 8) A. M. Bhatti *et al.* : Human emotion recognition and analysis in response to audio music using brain signals, Computers in Human Behavior, **65**, 267/275, (2016)
- 9) Alice PDx Portable sleep diagnostic system, Philips, [online] <https://www.usa.philips.com/healthcare/product/HC1043941/alice-pdx-portable-sleep-diagnostic-system>
- 10) 日野原, 宮岡, 千葉：脳とこころのプライマリケア 5 意識と睡眠, シナジー (2012)
- 11) Rechtschaffen A. and Kales A. 著 清野茂博訳：睡眠脳波アトラス：標準用語・手技・判定法, 医歯薬出版 (1971)
- 12) MindWave, NeuroSky, Inc., [online] <https://store.neurosky.com/pages/mindwave>

室内環境が人に与える影響の解析～脳波を用いた人の状態計測～

○堀田健斗 満倉靖恵 (慶應義塾大学)

美寿見奈穂 小前草太 古橋拓也 (三菱電機株式会社)

Effect on Humans of Indoor Environment using Electroencephalogram

*Kento Horita, Yasue Mitsukura (Keio University)

Naho Misumi, Sota Komae, Takuya Furuhashi (Mitsubishi Electric Corporation)

Abstract— The aim is to clarify effect of indoor environment on humans using electroencephalogram (EEG) in this paper. It is said that improvement of workspace was an issue to improve work efficiency, recently. Previous research cannot assert that work efficiency is good in the long term because work efficiency reduction by mental factors such as stress is not considered. In this paper, we clarified the relationship between work performance and mental factors caused by indoor environment using prefrontal cortex EEG. In this experiment, we focused on the thermal environment and EEG measurement, task and questionnaire survey were carried out under five conditions with different room temperature and air flow. In the experiment, it was shown that work efficiency was related to fluctuations in stress and concentration during work by air flow hitting the upper half of the body. These results suggested that work performance was related to changes in mental factors during work caused by indoor environment.

Key Words: Thermal environment, EEG

1 はじめに

本稿は、脳波を用いて室内環境が人に与える影響を明らかにすることを目的とする。

近年、残業時間規制に伴う労働時間減少によって限られた時間で業績を上げるための方針として室内環境の改善による作業効率向上に注目が集まっている。室内環境の影響に関する先行研究は、作業成績を比較して作業効率が向上する環境を定義している研究¹⁾²⁾と室内環境と脳活動の関係性に着目した研究³⁾⁴⁾が存在する。前者の研究では複数の環境下において作業を行い、作業成績が良い環境を作業効率が向上する環境と定義しているが、定義された環境はストレスや疲労の蓄積などの心的要因による作業効率低下を考慮できていないため、長期的に作業効率が良い環境であると断言できない。そのため、室内環境が人に与える影響と作業効率の関係性を明らかにする必要がある。後者の研究は室内環境の変化に伴う脳活動の変化に関する研究である。室内環境の影響は大きく感覚刺激による自律神経系に対する影響と室内環境に対する感情誘発による影響の2つに分類される。感覚刺激による自律神経系に対する影響とは光刺激、温冷刺激などの感覚刺激が視床下部の視交叉上核を経由して自律神経系に投射されることによって発生し、概日リズム位相の後退、メラトニン分泌の抑制、覚醒度の増加などの影響が挙げられる。このような覚醒効果は前頭前野部位における脳波の θ 波と β 波が関係している³⁾。室内環境に対する感情誘発とは室内環境の環境要素による感覚刺激に対して発生する情動のことであり、光刺激、温冷刺激に関しては脳の扁桃体や前帯状回皮、前頭前野などが関連している⁴⁾。このように室内環境が人に与える影響に関する研究は存在するが、その影響と作業効率向上の関係性を定量的に評価した研究は見られない。そのため、本稿では室内環境が人に与える影響の評価を行い、長期的に良い室内環境の発見を目指す。室内



Fig. 1: MindWave Mobile.

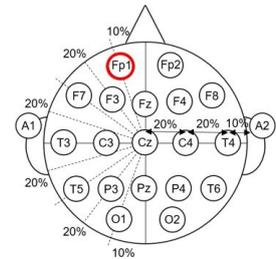


Fig. 2: International 10-20 system.

環境が人に与える影響の評価には覚醒効果や感情誘発と関連が深い前頭前野部位の脳波を用いた。以上のことから、本研究では室内環境によるストレスや集中など心的要因の変化と作業効率の関係性の評価を行った。

2 実験

本研究では、室内環境として夏季の温熱環境に着目した。被験者数は27名(男性:16名,女性:11名)とした。服装として、男性は半袖ワイシャツ、背広下衣のズボン(計約0.5 clo)、女性は半袖ワイシャツ、パンツスーツ(計約0.4 clo)を着用し、実験に参加した。実験では室内環境が人に与える影響の定量評価を行うため、それぞれの空調条件下で脳波計測、作業を行った。脳波計測にはMindWave Mobileを用いた(Fig. 1参照)。MindWave Mobileはサンプリング周波数512 Hz、計測箇所は左前頭前野部位(Fp1)である。Fp1は国際10-20法によって定められた部位である(Fig. 2参照)。

本実験はTable. 1に示す室温および気流が異なる5種類の空調条件下で作業を行い、作業中およびその前後の脳波計測を行った。Fig. 3に実験風景および空調機器の配置を示す。Fig. 3に示す配置の温度計を用いて室温の管理、上向き送風機および下向き送風機を用いて気流の発生、エアコンを用いて室温の制御を行った。

被験者は脳波計測開始前に環境に慣れるために20分

間の順化の時間を過ごした。順化終了後、安静閉眼状態で30秒間脳波計測を行い、その後脳波計測を行いながら作業を12分間行った。作業終了後、再び安静閉眼状態で30秒間脳波計測を行った。この手順を1セットとし、各空調条件につき4セットずつ行った(Fig. 4参照)。作業はクレペリン検査とマインドマップを2セットずつ行った。クレペリン検査とは簡単な一桁の足し算を1分毎に行を変えながら行う作業であり、マインドマップとは紙の中心に書かれた主題から連想される単語を放射状に書き出す作業である。

3 解析

各空調条件の作業効率と感性値の比較で用いた解析手順についてそれぞれ述べる。感性値とは、感性分析システム“感性アナライザ⁵⁾”を用いて脳波を取得後、周波数変換を行った上で各周波数の振幅スペクトルの組み合わせから独自のアルゴリズムによって1秒ごとに0-100%で算出される“好き、興味、集中、沈静、ストレス”の5種類の値である。本研究では5種類の感性値の内、作業中の心的要因と関係があると考えられる“集中、沈静、ストレス”の3種類を解析に用いた。

3.1 感性値

作業前後の安静閉眼状態(30 秒)と作業(720 秒)の間に取得した感性値に対して解析を行った。

作業前後の感性値は被験者ごとに 30 秒のデータの平均値を算出した。算出した作業前後の感性値の平均値に対して作業前後における有意差の有無を検証するために有意差検定を行った。有意差検定とは調査や実験を行って集められたデータを基に設定された仮説が正しいか否かを統計的に判断する手法である。本研究では有意差検定の中でも両側2標本t検定を用いた。

作業中の感性値は被験者ごとに 720 秒のデータのエントロピーを算出した。エントロピーとは時系列データの乱雑さや不規則性の尺度である。本研究では、作業中の感性値の変動の乱雑さを検証するためにサンプルエントロピー⁶⁾を用いた。サンプルエントロピーはエントロピーを使った手法の中でも 100-2000 程度の短いサンプル数の時系列データの解析に適している。本研究で扱う時系列データはデータ数が 700 程度であるため、サンプルエントロピー解析を行った。サンプルエントロピーは N 個のサンプルからなる時系列データに対して、 i, j 番目のサンプルにおける m 個の成分を持つベクトル $x_m(i)$, $x_m(j)$ を考える。そして $x_m(i)$, $x_m(j)$ のベクトル間の最大距離 d を算出し、以下の式で表されるようなベクトルの類似度を評価する変数 $s_{i,j}^m$ を定義する。

$$s_{i,j}^m = \begin{cases} 1 & d[x_m(i), x_m(j)] \leq r \\ 0 & d[x_m(i), x_m(j)] > r \end{cases} \quad (1)$$

r はこの類似度を評価するために閾値である。 $s_{i,j}$ は $d \leq r$ を満たすとき1, $d > r$ を満たすとき0となる変数であり、全ての i, j の組み合わせに対して $s_{i,j}^m$ を求め、加算していくことによって $d \leq r$ となる回数を数えることができる。サンプルエントロピー $SampEn(m, r, N)$ は $s_{i,j}^m$ を用いて以下の式で定義される。

Table. 1: Experimental conditions

Condition	Temperature [°C]	Air flow
A	28	None
B	28	Lower body 28°C
C	28	Upper body 28°C
D	25	None
E	28	Lower body 25°C

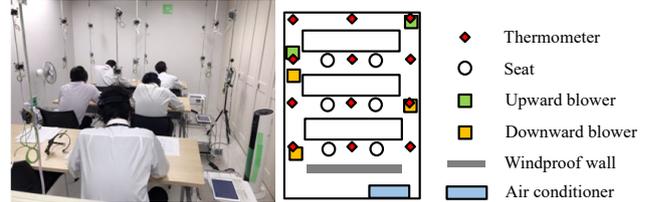


Fig. 3: Experimental image.

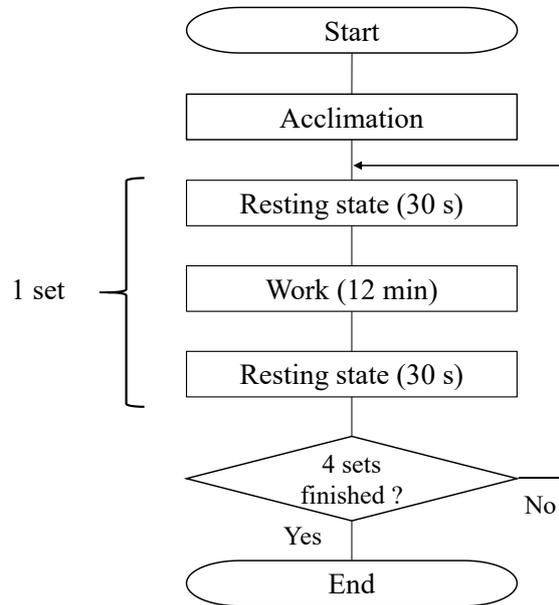


Fig. 4: The procedure of the proposed method.

$$SampEn(m, r, N) = -\ln \frac{\sum_{i=1}^{N-m-1} \sum_{j=i+1}^{N-m-1} s_{i,j}^{m+1}}{\sum_{i=1}^{N-m-1} \sum_{j=i+1}^{N-m-1} s_{i,j}^m} \quad (2)$$

上式において $s_{i,j}^m$ はベクトル間の類似度、 m はベクトルの次元、 r は閾値、 N はサンプル数を表している。サンプルエントロピーが大きい値であればデータは乱雑であり、サンプルエントロピーが小さい値であればデータは規則的で乱雑ではないことを意味する。本研究では被験者ごとに作業中の感性値のサンプルエントロピーを算出し、2標本t検定を用いて2条件ずつ総当たりで各空調条件間の比較を行った。

3.2 作業成績

各空調条件においてクレペリン検査、マインドマップそれぞれの作業成績を解析に用いた。1条件につきそれぞれの作業を2回ずつ行っているため2回の作業成績の平均をとり、被験者ごとにそれぞれの作業成績を1つずつ取得した。

取得した作業成績は個人差が大きく、被験者間での比較が困難であったため作業成績の正規化を行った。正規化は以下の式で求められる。

$$y_n = \frac{x_n}{\bar{X}_n} \quad (3)$$

y_n は各被験者の正規化後の作業成績、 x_n は各被験者の作業成績、 \bar{X}_n は各被験者の全空調条件における作業成績の平均値を表している。この正規化によって各被験者内の全空調条件の作業成績平均を1としたとき、各空調条件の作業成績が平均に対しての割合で表される。正規化した作業成績に対して2標本t検定を用いて2条件ずつ総当たりで各空調条件間の比較を行った。

4 結果

4.1 感性値

Fig. 5 に各空調条件の作業前後のストレス平均値を示す。作業前後の各感性値の平均値に対して有意差検定を行った結果、足元気流を発生させた条件 B, E において有意水準 5 %で作業後にストレスが有意に減少していることを確認した。また、ストレス以外の他の感性値は全空調条件において有意差は確認できなかった。

次に、Fig. 6 に各空調条件のサンプルエントロピーの平均値を感性値ごとに示す。作業中の各感性値より算出したサンプルエントロピーに対して有意差検定を行った結果、上半身気流を発生させた条件 C において全感性値のサンプルエントロピーが他条件より有意に大きな値を示した。

4.2 作業成績

Fig. 7, 8 に各空調条件のクレペリン検査、マインドマップそれぞれの作業成績平均値を示す。正規化後のクレペリン検査、マインドマップの作業成績に対して有意差検定を行った結果、条件 C において作業成績が最も有意に高いことを確認した。

5 考察

各空調条件の作業前後の各感性値の平均値に対して有意差検定を行った結果、条件 B, E において作業後ストレスが有意に減少していることを確認した。条件 B, E は一般に健康に良いとされている頭寒足熱とは逆の温度関係である頭熱足寒を再現した環境であった。しかし、本研究では足元に気流を発生させ、被験者が頭熱足寒であると推定される条件 B, E において作業後ストレスが有意に減少した。このことから、これまでの研究では頭寒足熱が良いとされてきたが、足元に気流を当てることで何らかの新しい効果を発見できたと考える。

各空調条件の作業中の各感性値より算出したサンプルエントロピーに対して有意差検定を行った結果、上半身気流を発生させた条件 C において全感性値のサンプルエントロピーが他条件より有意に大きな値を示した。これは作業中に上半身に当たる気流が一定ではなかったことが原因として考えられる。本実験では、上半身に風を送る際に実験室の気流循環を良くするため、上向き送風機を首振り運転していた。このため、被験者への風当たりが不規則な気流となり、皮膚から

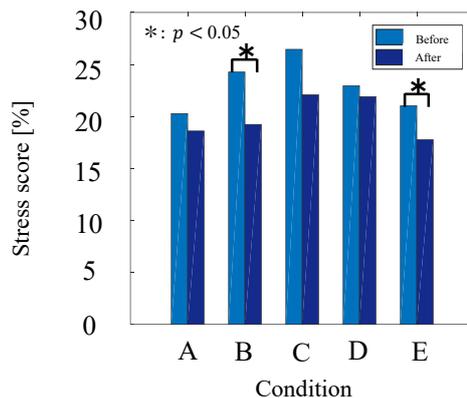


Fig. 5: Stress score before and after work.

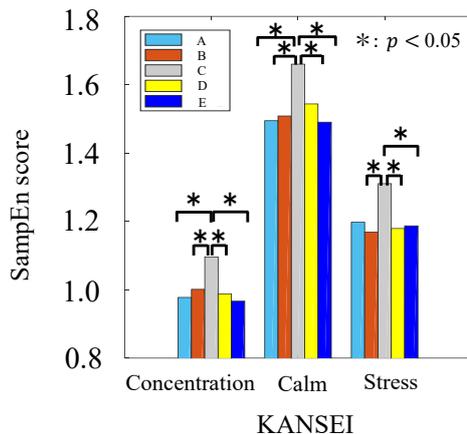


Fig. 6: Sample entropy score during work.

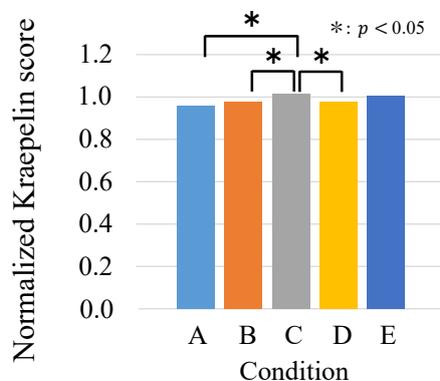


Fig. 7: Normalized Kraepelin score.

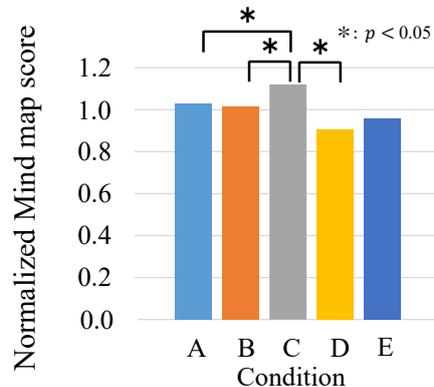


Fig. 8: Normalized Mind map score.

脳への感覚刺激の入力も不規則になったと考えられる。一般に、脳に入力された感覚刺激は視床を経て前頭前野部位に投射される⁸⁾。このため、前頭前野部位に入力される感覚刺激が不規則な場合、前頭前野部位の脳波から算出される感性値のサンプルエントロピーが大きな値を示したと考えられる。また、被験者の服装が半袖であり、足元気流に比べ直接気流が肌に触れる面積が大きかったことも影響していると考えられる。

正規化後のクレペリン検査、マインドマップの作業成績に対して有意差検定を行った結果、条件Cにおいて作業成績が最も有意に高いことを確認した。以上の結果より、上半身に当たる気流による作業中の感性値変動が最も作業効率と関係していると考えられる。これは上半身気流によって露出部分の多い上半身の肌が直接刺激され、覚醒効果が起こり、脳の前頭前野部位が活性化したことが原因であると考えられる。

6 おわりに

本研究では、脳波を用いて室内環境が人に与える影響を明らかにすることを目的とした。本目的を遂行するために、作業前後の感性値の同一条件内比較、作業中の感性値のサンプルエントロピーおよび作業成績の条件間比較を行った。この結果、上半身に当たる気流が最も作業効率と関係しており、そのとき作業中の感性値が変動することがわかった。今後の課題としては、四季に合わせた実験条件の検討が必要である。本稿では夏季の温熱環境に着目したが、冬季は夏季と温度、湿度等が異なるため室内環境の影響も異なることが考えられる。また、室温、気流以外の光、音など他の環境要素についての実験を行っていく必要がある。

参考文献

- 1) K. C. H. J. Smolders, Y. A. W. De Kort : Bright Light and Mental Fatigue: Effects on Alertness, Vitality, Performance and Physiological Arousal, *Journal of environmental psychology*, **39**, 77/91 (2014)
- 2) Seppanen, Olli, Fisk, William J., Faulkner, David. : Cost Benefit Analysis of the Night-Time Ventilative Cooling in Office Building, Lawrence Berkeley National Laboratory, (2003)
- 3) Kubota, Yasutaka, et al. : Dorsolateral Prefrontal Cortical Oxygenation during REM Sleep in Humans, *Brain research*, **1389**, 83/92 (2011)
- 4) 近藤祐樹, 侯磊, 綿貫啓一: NIRS を用いた室内空調の温熱的快適性評価 (室内温度変化に伴う脳賦活解析), *日本機械学会論文集 C 編*, **79-807**, 4075/4083 (2013)
- 5) 感性アナライザ, <https://kansei-analyzer.com/>, 2018/1/15 アクセス
- 6) Richman, Joshua S., J. Randall Moorman: Physiological Time-series Analysis using Approximate Entropy and Sample Entropy, *American journal of physiology-Heart and circulatory physiology*, **78-6**, 2039/2049 (2000)
- 7) Kato Masako, et al. : The Effects of Facial Fanning on Thermal Comfort Sensation during Hyperthermia., *Pflügers Archiv*, **443-2**, 175/179 (2001)
- 8) Whalen, Paul J., et al. : Masked Presentations of Emotional Facial Expressions Modulate Amygdala Activity without Explicit Knowledge, *Journal of Neuroscience*, **18-1**, 411/418 (1998)

Skeleton Data based Human Action Recognition in a Continuous Video

Bangli Liu¹, Naoyuki Kubota², Zhaojie Ju¹, Honghai Liu¹

¹ *University of Portsmouth*

² *Tokyo Metropolitan University*

Abstract— As an essential step towards comprehensive understanding of human behavior in video, human action detection aims to detect and recognize actions for each frame. However, it is more challenging than isolated action recognition where the actions are pre-segmented by giving the starting and ending frames. This paper proposes a novel method to jointly detect and recognize human actions in continuous videos. The proposed method detects the starting point of an action according to the distribution of skeleton movement, and then a snippet-based classifier is proposed to find the most likely action class continuously. Experimental results confirm that our method outperforms the state-of-the-art methods in terms of both detection accuracy and recognition precision.

Key Words: Action Recognition, Action Detection, Skeleton Data

1 INTRODUCTION

Human action recognition has received growing interest due to its wide range of applications such as public surveillance, elderly care and human-computer interaction. Early proposed strategies mainly recognize human action from 2D sequences captured by RGB cameras[1]. However, the sensitivity to illumination changes and subject texture variations often degrades the recognition accuracy. These problems can be solved by using depth information acquired by depth sensors such as Microsoft Kinect and ASUS Xtion, which have been promoting the research on human action recognition. With the availability of 3D joint positions extracted by a real time skeleton tracking algorithm [2], a lot of researchers use these joints to build action representations.

Although significant works have been made for isolated action recognition [3][4], their performance in untrimmed continuous videos remains unclear. Compared to isolated videos where actions are pre-segmented according to the action category and each video only contains one completely performed action, it is more challenging to identify actions from untrimmed videos for two reasons: firstly, the execution boundaries of various action categories are required to be detected accurately; secondly, due to the performance of action detection algorithm, only partial actions might be available for recognition.

In this paper, the boundary of actions is firstly detected based on the distribution of skeleton movement. Once the starting of an action is obtained, a snippet-based classifier which considers an effective spatial-temporal feature as input is designed to process immediately for action recognition. We use the sliding window after the action occurring to improve the detect accuracy in a fragment level. Fig. 1 shows the basic idea of the proposed method for continuous action recognition.

2 RELATED WORKS

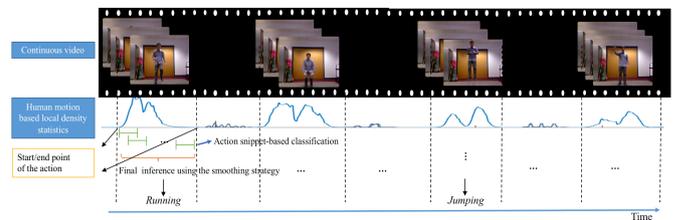


Fig. 1: The flowchart of the proposed method for action detection and recognition.

This section reviews two related works: human action recognition and human action detection.

2.1 Human Action Recognition

The development of cost-effective RGB-D sensors encourages a good deal of approaches based on 3D joint coordinates proposed for human action recognition[5][6][7]. Xia et al. [5] depicted key human postures using a histogram of 3D joint locations in a spherical coordinate, and the temporal evolution was represented by using a Discrete Hidden Markov Model. Vemulapalli et al. [6] made use of the rotations and translations between body parts to model relative 3D geometry relation, with which human motion was encoded as curves in the Lie group. EigenJoints was proposed in [7], where the difference of joints including posture, motion and offset information was combined and input into the classifier for motion recognition. Qiao et al. [8] applied a trajectorylet based on local feature representation to capture ample static and dynamic information of actions. Further exemplar-SVM was then used to learn and select a discriminative trajectorylet detector set. These methods have achieved satisfactory recognition results on trimmed clips which just contain one fully complete action category. However, the performance of these method is unclear when applied to realistic applications where action boundaries are not known.

2.2 Human Action Detection

Compared to the action recognition in trimmed videos, action detection is a more challenging and realistic problem [9]. Most of the state-of-the-art methods handle the detection problem using heuristics based sliding window approaches. Shao et al. [10] used the local maxima/minima value of varying motion gradients for action segmentation. In [11], each video frame was assigned a label based on the comparison between its representation and template representations. More related to our skeleton based detection model, Huang et al. [12] proposed to employ bag of words for each different body joints and build a sequential max-margin event detectors (SMMED) for early action detection. Escalante further improved the early action detection performance by employing an easy naive Bayes based method. However, the early action detection requires predefined action start point label which limits its usage in practical applications. In contrast, our method is able to directly detect and recognize the relative motion in a given video sequence.

3 PROPOSED METHOD

3.1 Action Detection based on Skeleton Motion

With the availability of 3D joint coordinates extracted by a real time tracking algorithm [2], we propose to describe skeleton motion using the displacement offset of each joint. Herein, skeleton displacement offset d is computed as follows:

$$\begin{cases} \Delta x_t^i = x_t^i - x_1^i, \\ \Delta y_t^i = y_t^i - y_1^i, \\ \Delta z_t^i = z_t^i - z_1^i, \end{cases} \quad (1)$$

Where x^i, y^i, z^i are coordinates of i -th joint.

Table 1: The procedure of representing human skeleton motion in low dimensional space using LPP algorithm.

Input: human skeleton motion set $D = d_1, d_2, \dots, d_t$ at $t = 1, 2, \dots, T$.
Output: mapped representation on low dimension space $p = W^T d$
Step 1: Constructing te adjacency graph. Let G denote a graph with m nodes. An edge is put between nodes i and j if data d_i and d_j are 'close'. LPP will choose the projections which can optimally preserve this adjacency graph.
Step 2: Choosing the weights. W is a symmetric matrix with weight value $w_{ij} = 1$ if and only if nodes i and j are connected, otherwise $w_{ij} = 0$.
Step 3: Computing Eigenmaps. The objective function: $\min \sum_{i,j} \ p_i - p_j\ ^2 S_{ij}$; According to $p = W^T d$, $\frac{1}{2} \sum_{i,j} (p_i - p_j)^2 S_{ij} = \frac{1}{2} \sum_{i,j} (W^T d_i - W^T d_j)^2 S_{ij}$ $= W^T D(D - S)D^T W = W^T DLD^T W$ Compute the eigenvectors and eigenvalues for the generalized eigenvector problem: $DLD^T W = \lambda X C X^T W$
Step 4: Mapping data. $p = W^T d$

We assume the skeleton motion feature lies on a low dimensional manifold embedded in the ambient space, locality preserving projection(LPP) [16] is consequently applied to linearly transform the motion feature to a subspace. LPP

can optimally preserves the local neighborhood structure of the data while mapping it to a lower dimensional space. Following the procedure listed in Table. 1, the skeleton motion is represented in a subspace by a linear transformation $p = W^T d$.

The density distribution of such skeleton motion tends to vary from action to action, therefore, it is reasonable to detect the occurrence of actions depending on the change of skeleton motion's distribution. We assume the skeleton displacement offset p is the random variable in a feature space from a distribution with an unknown density $q(p)$, which could be estimated using the following equation:

$$ldv(p) \propto \frac{1}{m} \sum_{p_i \in Km(p_j)} \frac{1}{(\sqrt{2\pi}h \cdot d_m(p_i))^{dim}} \exp\left(-\frac{rd_m(p, p_i)}{2(h \cdot d_m(p_i))^2}\right) \quad (2)$$

where dim is the dimensionality of data, and $d_m(p_i)$ denotes the distance between point p_i and its m -th nearest neighbor. $h \cdot d_m(p_i)$ is the bandwidth at point p_i . This bandwidth is adaptive by adding distance $d_m(p_i)$. The improved bandwidth enjoys small bandwidth in density regions and big bandwidth in sparse regions, thus enables the density function robust to the change of data distribution. $Km(p_i)$ includes m neighbor points of point p_i . Compared to the holistic comparison, the local measure depending on $Km(p_i)$ yields more effective density estimation by reducing computation cost from the whole data set to local neighbors. $rd_m(p, p_i)$ is the reachability distance.

Since the density distribution of data points from different actions is distinctive, we denote the local density ratio in Eq. 3 which provides the density relationship for the action boundary detection.

$$ldr(p) \propto \frac{\sum_{p_i \in Km(p_j)} \frac{ldv(p_i)}{m}}{ldv(p) + c \cdot \sum_{p_i \in Km(p)} \frac{ldv(p_i)}{m}} \quad (3)$$

Where $ldr(p)$ denotes the ratio of average estimated density of its neighbors to the density at p . c is a scaling constant to avoid infinity values of ldr caused by very small estimated density at point p .

The local estimated density of targeted actions has apparent difference compared to normal actions, and this value will convert dramatically at its starting and ending time. This sudden convert referred to as action boundaries in action sequence can be regarded as a type of impulses. We detect them via wavelet transform. Wavelet transform is a powerful technique for analyzing irregular data, owing to its great capacity in providing the frequency and according time lo-

cation information of signals. This makes the wavelet transform suitable for detecting impulses occurring at any time. The sequence of density ratio ldr is simultaneously decomposed using a low-pass and high-pass filter known as a quadrature mirror filter, as shown in Fig. 2. Approximation and detail coefficients are outputs from the low-pass and high-pass filter, respectively. The significant difference of density distribution between the occurrence of the action and its neighbors allows us to detect impulses during a time series with a high accuracy. The bottom part in Fig. 3 demonstrates that the starting (red stars) and ending (red circles) points can be accurately detected by the wavelet transform.

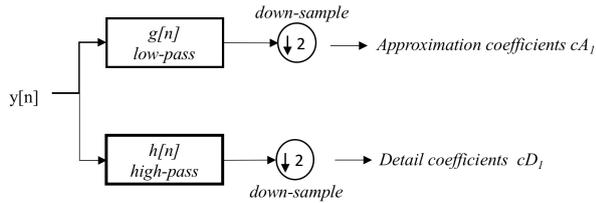


Fig. 2: One level Discrete Wavelet Transform

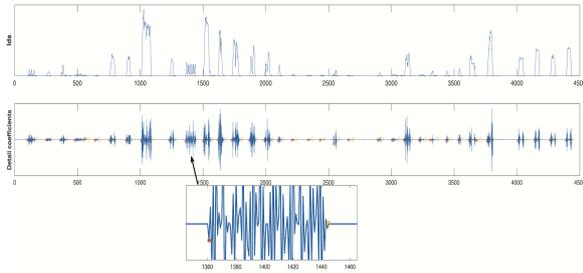


Fig. 3: The local density ratio of a continuous video and action starting/ending points detection through wavelet

3.2 Continuous Action Recognition

3.2.1 Action Representation

We utilized the 3DMTG feature descriptor which combines the moving trend and geometry property of skeleton joints [13] for action recognition. Fig. 4 shows the general framework of the 3DMTG feature descriptor. The upper part of Fig. 4 is the 3D moving trend feature where a histogram of 26 bins corresponding to 3D moving directions is adopted to store the moving trend of each joint through the whole action video. The lower part of Fig. 4 is the geometry property feature which is acquired from the N frames of the action sequence. In the geometry property feature, the world coordinate is firstly translated into the local coordinate system with respect to the hip-center and then the relative displacement of each joint is computed. To address unequal length of geometry property feature caused by length of action sequences, the relative displacement property of each action instance is interpolated to the unified dimension, $M \times 20 \times 3$. Both 3D moving trend and geometry property features are normalized.

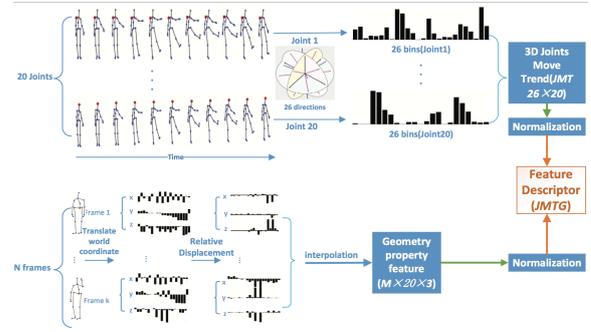


Fig. 4: The flowchart of 3DMTG feature descriptor

3.2.2 Snippet-based Classifier

Since action durations exhibit considerable variability due to the performance of action detection algorithm, we explore features from snippets incorporating partial temporal segment of actions in different performing stages. We randomly generate snippets from untrimmed videos using a sliding window strategy. The proposed snippet-based classifier makes essential use of local temporal information, thus makes it robust to variations in execution time.

Table 2: Framework of Action detection.

<p>Input: human skeleton motion set $D = d_1, d_2, \dots, d_t$ at $t = 1, 2, \dots, T$. Snippet-based classifier C, window size $length$, stride $step$ and threshold δ.</p> <p>Output: Start points $StartP$ and end points $EndP$ of actions, action class $Label$</p> <p>Initialization: $StartP = 0, EndP = 0$.</p> <p>while $t < T$</p> <ul style="list-style-type: none"> · Map data d_t to lower dimension space using LPP: $p_t = W^T d_t$; · Compute local density ratio $ldr(p_t)$; · Detect $StartP$ and $EndP$ according to detail coefficients $cD1$ and δ using dwf: $cD1[t] = \sum_{k=-\infty}^{+\infty} y[k]h[2t-k]$, where h is the high-pass filter; if $cD1(t) > \delta$ $StartP = t$; Start snippet-based action recognition from time t using sliding window; Assign each snippet a specific class label $label(i)$ by the classifier C. until $cD1(t) < \delta$ $EndP = t$; Smooth the labels of snippets from the detected sequence over time $StartP$ to $EndP$; Select the final $Label$ with highest probability to the detected sequence; <p>end</p>
--

3.2.3 Framework of Action Detection

Table. 2 lists the detailed procedure of action detection and recognition. The action boundaries are detected using the wavelet transform from local density ratio sequence. And then the snippet-based classification is processed to classify partial actions continuously. Our method achieves lower computation cost compared to continuous recognition over whole video, because the action recognition is processed intermittently if and only if the occurrence of actions is detected.

4 EXPERIMENT RESULTS

We evaluated the proposed method on the MAD database [12], which is a RGBD database providing continuous videos. The database has 40 sequences of 35 activities (e.g. *running, crouching, jumping, throw, basketball dribble, kicking*). Activities in each sequence are performed continuously with null class inserted between two activities. Three modalities were recorded in this database: RGB video, depth, and 3D coordinates of 20 human body joints. At test time, local density ratio is computed using Eq. 3 and then

pass the local density ratio sequence through the wavelet transform to detect action boundaries. For a fair comparison, we performed five-fold-cross-validation as set in [12]. At train time, we trained a snippet-based 36-class classifier, where action snippets representing different action stage of one class were picked up from videos.

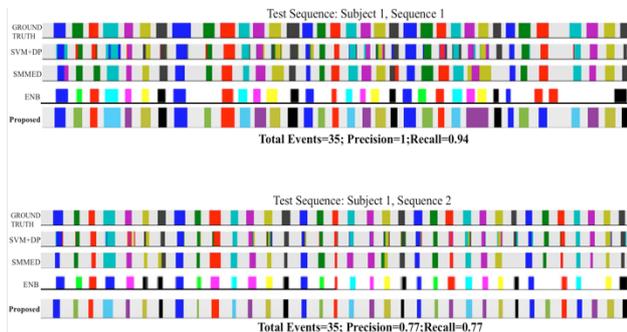


Fig. 5: The comparable results with SVM+DP[14], SMMED[12], and ENB[15] on two sequences in the MAD database.

Fig. 5 shows another action detection performance of different methods. We reproduce the result of SVM+DP and SMMED from [12] and the result of ENB from [15]. *Precision* and *Recall* indicate the percentage of the detected actions who has 0.5 overlap with the ground truth and the percentage of correctly detected actions, respectively. It can be seen from these color bars that the performance of our method is the closest to the ground truth compared to other listed methods. Although SVM+DP and SMMED could detect almost all action occurrence, the accuracy of classification within a detected action is relatively low. In spite of better performance in classification within detected actions of ENB, its missing detection rate decreases. Our method is able to detect actions correctly with lower missing detection rate than ENB and performs higher classification accuracy than all listed methods.

5 CONCLUSIONS

In this paper, a novel skeleton movement based method was proposed to jointly detect and recognize human actions in continuous videos. We took advantage of a skeleton based adaptive density estimation for efficiently detecting action boundaries. The recognition of detected actions is performed sequentially using the proposed snippet-based classifier. A comparison with the state-of-the-art methods in publicly available database shows that our method obtains outstanding results including detection and classification performance. In the future, we plan to extend the proposed method to combine RGB and depth information to improve the detection accuracy.

REFERENCES

- 1) Niebles, J. C., & Fei-Fei, L. (2007, June). A hierarchical model of shape and appearance for human action classification. In *Computer Vision and Pattern Recognition, 2007. CVPR'07. IEEE Conference on* (pp. 1-8). IEEE.
- 2) Shotton, J., Fitzgibbon, A., Cook, M., Sharp, T., Finocchio, M., Moore, R., ... & Blake, A. (2011, June). Real-time human pose recognition in parts from single depth images. In *Computer Vision and Pattern Recognition (CVPR), 2011 IEEE Conference on* (pp. 1297-1304). IEEE.
- 3) Shahroudy, A., Ng, T. T., Yang, Q., & Wang, G. (2016). Multimodal multipart learning for action recognition in depth videos. *IEEE transactions on pattern analysis and machine intelligence*, 38(10), 2123-2129.
- 4) Du, Y., Wang, W., & Wang, L. (2015). Hierarchical recurrent neural network for skeleton based action recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 1110-1118).
- 5) Xia, L., Chen, C. C., & Aggarwal, J. K. (2012, June). View invariant human action recognition using histograms of 3d joints. In *Computer vision and pattern recognition workshops (CVPRW), 2012 IEEE computer society conference on* (pp. 20-27). IEEE.
- 6) Vemulapalli, R., Arrate, F., & Chellappa, R. (2014). Human action recognition by representing 3d skeletons as points in a lie group. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 588-595).
- 7) Yang, X., & Tian, Y. (2014). Effective 3d action recognition using eigenjoints. *Journal of Visual Communication and Image Representation*, 25(1), 2-11.
- 8) Shao, L., Ji, L., Liu, Y., & Zhang, J. (2012). Human action segmentation and recognition via motion and shape analysis. *Pattern Recognition Letters*, 33(4), 438-445.
- 9) Gaidon, A., Harchaoui, Z., & Schmid, C. (2011, June). Action sequence models for efficient action detection. In *Computer Vision and Pattern Recognition (CVPR), 2011 IEEE Conference on* (pp. 3201-3208). IEEE.
- 10) Shao, L., Ji, L., Liu, Y., & Zhang, J. (2012). Human action segmentation and recognition via motion and shape analysis. *Pattern Recognition Letters*, 33(4), 438-445.
- 11) Kulkarni, K., Evangelidis, G., Cech, J., & Horaud, R. (2015). Continuous action recognition based on sequence alignment. *International Journal of Computer Vision*, 112(1), 90-114.
- 12) Huang, D., Yao, S., Wang, Y., & De La Torre, F. (2014, September). Sequential max-margin event detectors. In *European conference on computer vision* (pp. 410-424). Springer, Cham.
- 13) Liu, B., Yu, H., Zhou, X., Tang, D., & Liu, H. (2016, October). Combining 3d joints moving trend and geometry

- property for human action recognition. In *Systems, Man, and Cybernetics (SMC), 2016 IEEE International Conference on* (pp. 000332-000337). IEEE.
- 14) Hoai, M., Lan, Z. Z., & De la Torre, F. (2011, June). Joint segmentation and classification of human actions in video. In *Computer Vision and Pattern Recognition (CVPR), 2011 IEEE Conference on* (pp. 3265-3272). IEEE.
 - 15) Escalante, H. J., Morales, E. F., & Sucar, L. E. (2016). A naive bayes baseline for early gesture recognition. *Pattern Recognition Letters*, 73, 91-99.
 - 16) He, X., & Niyogi, P. (2004). Locality preserving projections. In *Advances in neural information processing systems* (pp. 153-160).

簡素な数台のロボットを使った トラッキング・システムにおける量子揺らぎ

○伊丹哲郎 (RIDC) 松井伸之 (兵庫県立大学) 幸田憲明 (松江工業高等専門学校)

概要 量子揺らぎ下のロボットの集団が衝突することにより物体を搬送するトラッキング・システムにおいて、各ロボットの装備の簡素化を図る方法を示す。具体的には搭載されたセンサーによるロボットの自己位置の計測を不要とする。このために量子揺らぎ力を、時間変化するが、空間にわたる定数として近似する。

キーワード: 自己位置計測をしないロボット, ロボット集団による物体搬送, 量子揺らぎによる力

1 はじめに

著者らは、物体を複数個のロボットにより搬送する研究を行ってきた^{4, 5, 7)}。ロボットは外界センサを搭載せず互いの通信もない、という意味で「簡素」である。ここで物体もロボットも $\sim 1[m]$, $\sim 1[kg]$ のオーダーの大きさを持ち、その仕事は $\sim 1[s]$ オーダーの時間でなされる。すなわちその動きはふつうの力学に支配される。この搬送系をナノ・スケールに適用する場合であっても、量子効果が無視できる範囲内であれば、設計の基礎は古典力学のみにある。この点を強調するために、分子・原子より小さな系を「微視的(ミクロスコピック)」と呼ぶことに対応した「巨視的(マクロスコピック)」という言葉のをわれわれの研究報告において冠した事が多い。さてロボット工学のひとつの目標は衝突フリーであるが、提案システムでは、ロボットと対象物体あるいはロボット同士を積極的に衝突させる。つまり衝突を繰り返すことによって物体を希望軌道にトラックするよう仕向ける作戦を取っている。この際、液体分子の揺らぎに起因するブラウン運動や、その運動を温度場で制御するブラウン・モータ²⁾にヒントを得ることができる。すなわち衝突を繰り返すロボットを液体分子に見立て、これを動かすには温度場のかわりにポテンシャル場を使う。花粉あるいはブラウン・モータの駆動部は搬送すべき物体に対応する。物体にかつてな揺らぎ運動(ブラウン運動)をされては意味がないので、その運動を制御するためにポテンシャル場を適切に時々刻々に変形させることになる。これはブラウン・モータで温度勾配を操作することで液体分子の運動、したがって駆動部の運動の制御を行うことと同じである。なおブラウン運動は分子が $\sim 10^{23}$ 個オーダー(液体なのでもっと多く)存在する世界の現象であり、その個数は人工物として製造すべきロボットで模擬できる規模ではない。しかし花粉と分子の相対的スケールを巨視系に適用すると、実は分子の個数はそこまで膨大でもなく、複数個のロボットが物体のまわりに走り回る世界と個数規模から見て変わる所はない。ブラウン運動と巨視的トラッキング系が異なる大きな点とは、前者では熱揺らぎが現象を支配し、一方われわれのシステムは揺らぎを隠してあまりある決定論的な古典力学に従っている事である。

われわれは巨視的物体の搬送システムの基本構成を、Fig.1の通りとしてきた^{4, 5, 7)}。そして生物物理で発展した非常に少数個の分子に対する統計力学⁹⁾を援用し、系がボルツマン分布でモデル化されるとした。すなわち物理変数を系の平均エネルギーとした。これにより

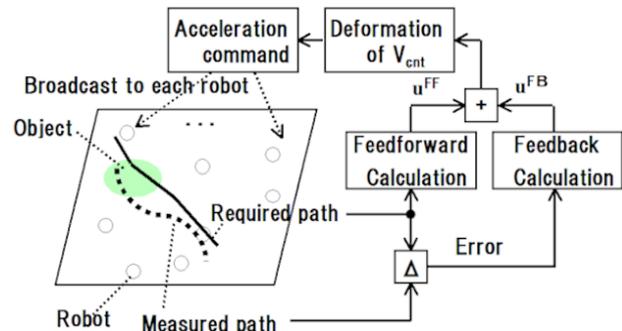


Fig. 1: 巨視的な物体搬送システムの構成

図中の先行値 u_{FF} を設計した。この先行値を、物体がトラッキングの経路から逸れることを修復するフィードバック1項 $u_{FB} = \text{func}(\bar{X}^{req} - \bar{X})$ で修正することでロボットへの加速度入力を計算したのである。つまり揺らぎ効果を、ボルツマン分布の温度パラメータを通して、先行値 u_{FF} として表現したとも言える。

それでは、揺らぎをもっと直接的にわれわれの巨視系に導入するにはどうすればよいか? 著者ら⁶⁾はこの目的のために、量子力学をニュートン力学に揺らぎを加えたものとする方法論を利用した。波動関数 Ψ による物体搬送の設計計算をやっておいて、実際には波ではなく、その波の揺らぎを受けるロボットを使う、という考え方である。この事前の設計計算が先行値 u_{FF} に相当する。ここで先行値あるいは揺らぎがなければどういう結果になるか、を復習しておく。単純なフィードバック u_{FB} だけでは物体はトラッキングしない。フィードバックだけが作用するときの物体の運動経路を、ロボットのそれとともに示すと Fig.2 となる。ロボットはあまりに規則的に動きすぎるため、領域全体をくまなく動きまわってはいない事が分かる。このような事実から次のことが言える。単純なフィードバック u_{FB} に加え、 Ψ の効果を揺らぎとしてロボット運動に引加すれば、トラッキングがなされること、その理由は揺らぎがロボットに規則的でない運動を与え閉じた領域を運動し尽くすことであることが分かった。しかし次の問題が残る。

- 量子揺らぎ力は座標に依存する。このため、ロボットの自己位置センサー(たとえばGPS)を要し、本来の研究の趣旨である「簡素なロボット」概念に反する。

¹func: 誤差 $\bar{X}^{req} - \bar{X}$ の関数として制御入力を決める関数。単純に比例+微分をとることが多い。

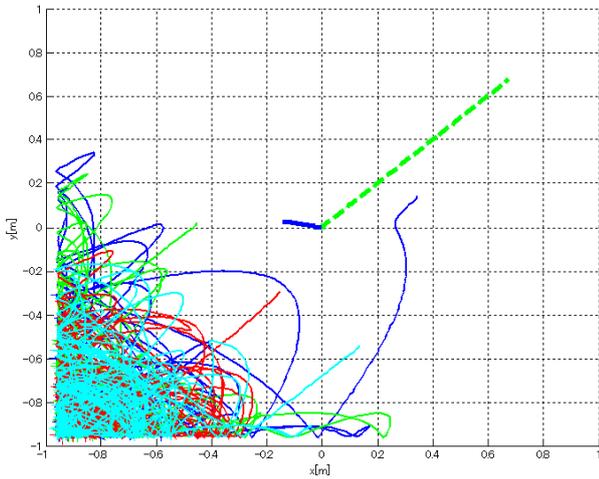


Fig. 2: フィードバックによるポテンシャル力 V_{cnt} のみが作用するときの、ロボットと物体の領域内の軌跡。青太実線が物体、緑太破線がそのトラッキングすべき経路、細い実線(青、緑、赤、シアン)は4台のロボットの軌跡である。

- 物体の位置誤差フィードバック u_{FB} に加えるにあたり、複雑な演算を要する量子揺らぎでなくとも単純なランダム力の作用があればトラッキングができるのではないかと？

そこで本報では、量子揺らぎの力を時間変化はするが空間にわたる定数として近似する。またその結果を単純なランダム力の作用によるトラッキング成績と比較する。

量子揺らぎの計算は 2 でなされるが、置かれた仮定とフィードバック・ループ構造を 2.1 と 2.2 それぞれで確認した上で、ロボットに作用する力(加速度)の計算を 2.3 で詳述する。得られた基礎式を使い 3 で数値シミュレーションを提示する。はじめにシステム・パラメータ H_R を含め計算条件を 3.1 で与え、結果とその単純なランダム力の作用の比較を 3.2 で示す。まとめと課題は 4 に示す。

2 量子揺らぎ力の計算

量子ダイナミクスについてはすでに報告⁶⁾しているが、ここでは仮定事項を明確に列挙し、また揺らぎ力がフィードバックで決まるループ構造に焦点をあてまとめ直した。ロボットに作用する揺らぎ力を系統的に計算することを目的とする。

2.1 巨視的な系に作用する量子揺らぎ

物体 B もロボット R いずれも、その座標 \vec{X} あるいは \vec{x} の時間変化が巨視的なニュートン力学で決まることは自明である。両者は相互の衝突を介して力学的に結合している。ここではこの結合系をあえて量子力学的な波動関数 $\Psi(\vec{x}, \vec{X}; t)$ で記述した上で、物体とロボットの運動を抽出する。すなわち物体にはエーレンフェストの定理⁸⁾を適用し、その運動量 $\vec{P} = M\dot{\vec{X}}$ の量子力学的な期待値 $\langle \vec{P} \rangle$ に対してニュートン方程式を書きくだす。一方ロボットについては、結合系の波動関数から \vec{x} だけに依存する波動関数 $\psi(\vec{x}; t)$ を抽出する。この $\psi(\vec{x}; t)$ に対するシュレディンガー方程式は複素数値であるが、その実数部分はロボットに量子揺らぎ力

が追加された形のニュートン方程式になる。(なおシュレディンガー方程式の虚数部分は使わないから、本報では興味を持たない。) 以上により、互いに衝突する物体 B とロボット R の古典力学であって、 R に揺らぎ力が作用する方程式が系統的に得られる。

はじめに全体系の波動関数 $\Psi(\vec{x}, \vec{X}; t)$ の以下のシュレディンガー方程式から出発する。

$$\begin{aligned}
 iH_R \frac{\partial \Psi}{\partial t} &= \hat{H} \Psi \\
 &= -\frac{H_R^2}{2M} \frac{\partial^2 \Psi}{\partial \vec{X}^2} - \frac{H_R^2}{2m} \frac{\partial^2 \Psi}{\partial \vec{x}^2} \\
 &\quad + (V_{cnt}(\vec{x}; \mathbf{u}) + V_B(|\vec{x} - \vec{X}|) + V_{B0}(\vec{X})) \Psi \quad (1)
 \end{aligned}$$

右辺の第1, 2項は、物体とロボットそれぞれの運動エネルギーである。第3項は制御入力 \mathbf{u} で決まる外力を表す。第4, 5項はそれぞれ物体とロボットの衝突、壁反力のエネルギーである。

本稿の興味は、波の揺らぎの下で運動するロボットが、物体を実際に駆動しトラッキングの用をなすか否かである。このため、単に簡単化という理由でなされた仮定は以下である。

- モーメントによる物体の回転は、計算対象としない。
- ロボットは質点として扱い、その大きさはロボットに対する壁反力のパラメータとしてのみ考慮する。
- 量子揺らぎを算定する上で、波動関数にロボット同士の衝突の情報を含めない。本来は衝突相互作用を含めたロボット台数だけの多体問題の量子力学を考慮せねばならない。しかしそこから量子揺らぎを計算することは非常に複雑である。すなわちあるロボット i_R に別のロボット達 $j_R (\neq i_R)$ の情報が入りこんでくる。ここに量子力学の「全体性」構造が顕著に現れるわけで、したがってこれを積極的に考慮することで「陰的な」ロボット間通信を考えたことになる。この点は別途の検討とする。

またエーレンフェストの定理を適用するために、以下の特殊な変形をした。

- 物体の量子揺らぎを無視し物体側の規格化定数を $N (\int_{\Omega} d^2 \vec{X} N \delta(\vec{X} - \vec{X}(t)) = 1)$ として、全系の波動関数を、

$$\Psi(\vec{x}, \vec{X}; t) = N \delta(\vec{X} - \vec{X}(t)) \times \psi(\vec{x}; t) \quad (2)$$

の変数分離形に仮定する。ここで $\vec{X}(t) \equiv \langle \vec{X} \rangle$ 。

さて(1)の波動関数 Ψ にわたる期待値を取り、エーレンフェストの定理⁸⁾に基づいて物体 B の運動を記述するニュートン方程式を導出する。物理量 $\hat{\omega}$ の期待値 $\langle \hat{\omega} \rangle \equiv \int d^2 \vec{X} \int d^2 \vec{x} \Psi^* \hat{\omega} \Psi$ と B の運動量の演算子表

現 $\hat{P} = -iH_R \frac{\partial}{\partial \vec{X}}$ を使うと、物体の運動方程式として

$$\begin{aligned}
M \frac{d^2 \langle \vec{X} \rangle}{dt^2} &= \frac{d}{dt} \int d^2 \vec{X} \int d^2 \vec{x} \Psi^* \left(-iH_R \frac{\partial}{\partial \vec{X}} \right) \Psi \\
&= \left\langle -\frac{\partial}{\partial \vec{X}} \left(V_B(|\vec{x} - \vec{X}|) + V_{B0}(\vec{X}) \right) \right\rangle \\
&= -\frac{\partial}{\partial \vec{X}(t)} V_{B0}(\vec{X}(t)) \\
&\quad - \frac{\partial}{\partial \vec{X}(t)} \int d^2 \vec{x} \psi^*(\vec{x}; t) V_B(|\vec{x} - \vec{X}(t)|) \psi(\vec{x}; t)
\end{aligned} \tag{3}$$

を得る。ここで $d^2 \vec{x} \psi^* \psi$ は、ロボットが平面領域 $d^2 \vec{x}$ に存在する確率である。すなわち (3) 右辺 3 行第 2 項は、力 $-\frac{\partial}{\partial \vec{X}} V_B(|\vec{x} - \vec{X}|)$ に確率の重みをつけた加算平均である。ここで、部分積分において領域を囲む壁表面の境界条件 $\Psi = \frac{\partial \Psi}{\partial \vec{x}} = 0$, また $\frac{\partial V_{cnt}}{\partial \vec{X}} = 0$ を使う。そして (3) のロボットとの衝突項は

$$-\frac{\partial}{\partial \vec{X}(t)} \sum_{i_R} V_B(\vec{x}_{i_R} - \vec{X}(t)) \tag{4}$$

と置き換えて計算される。

次にロボットに対するシュレディンガー方程式を立てる必要があるが、それは全系のシュレディンガー方程式 (1) の物体座標 \vec{X} にわたる積分によって得られる。物体の運動エネルギー項 $-\frac{H_R^2}{2M} \frac{\partial^2 \Psi}{\partial \vec{X}^2}$ は発散であるから $\int d^2 \vec{X}$ の下でゼロになる。ゆえにロボット側のみの波動関数が (2) から

$$\int d^2 \vec{X} \Psi(\vec{X}, \vec{x}; t) = \psi(\vec{x}; t) \tag{5}$$

であることに注意すれば、波動方程式として

$$\begin{aligned}
iH_R \frac{\partial \psi}{\partial t} &= -\frac{H_R^2}{2m} \frac{\partial^2 \psi}{\partial \vec{x}^2} \\
&\quad + \int d^2 \vec{X} (V_B + V_{B0}) \Psi + V_{cnt} \psi \\
&= -\frac{H_R^2}{2m} \frac{\partial^2 \psi}{\partial \vec{x}^2} \\
&\quad + \left((V_{cnt}(\vec{x}; u) + V_B(|\vec{x} - \vec{X}(t)|) + V_{B0}(\vec{X}(t))) \right) \psi,
\end{aligned} \tag{6}$$

を得る。ここで注意すべきは、物体とロボットの相互作用 V_B が右辺に入るのは当然のこととして、(ロボット位置には依存しないはずの) 物体 $\vec{X}(t)$ の受ける壁反力 V_{B0} も考慮されるべきことである。さて (6) の実数部を計算しよう。実関数 C, S^q を使って波動関数を $\psi = e^C e^{i \frac{S^q}{\hbar}}$ と局座標表示して (6) に代入する。するとシュレディンガー方程式 (6) の実数部は質点のハミルトン・ヤコビ方程式¹¹⁾ であって、ポテンシャル力に量子揺らぎ項

$$V^q = -\frac{H_R^2}{2m} \left(\vec{\nabla}^2 C + (\vec{\nabla} C)^2 \right), \tag{7}$$

が入ったものに等しくなる。すなわちシュレディンガー方程式 (6) の実数部から次の運動方程式が導出される。

$$m \frac{d^2 \vec{x}}{dt^2} = -\frac{\partial}{\partial \vec{x}} \left((V_{cnt}(\vec{x}; u) + V_B(|\vec{x} - \vec{X}(t)|) + V^q[\psi(\vec{x}; t)]) \right) \tag{8}$$

ここで右辺第 3 項が量子揺らぎ力である。また物体の壁反力は \vec{x} に依存しないのでその偏微分はゼロとした。また揺らぎポテンシャルの計算は¹⁰⁾ に従う。

2.2 トラッキングのフィードバック・ループ構造

以上の (3), (4) と (8) が、量子揺らぎ下のロボット群による物体運動の制御を決める状態方程式となる。すなわち (6) によりロボットの波動関数 ψ が制御入力 u で制御され、その結果を受けて (3), (4) で $\vec{X}(t)$ が制御される。以上はフィードバックを通じてなされ、そのループ構造は Fig.3 で示すとおりである。

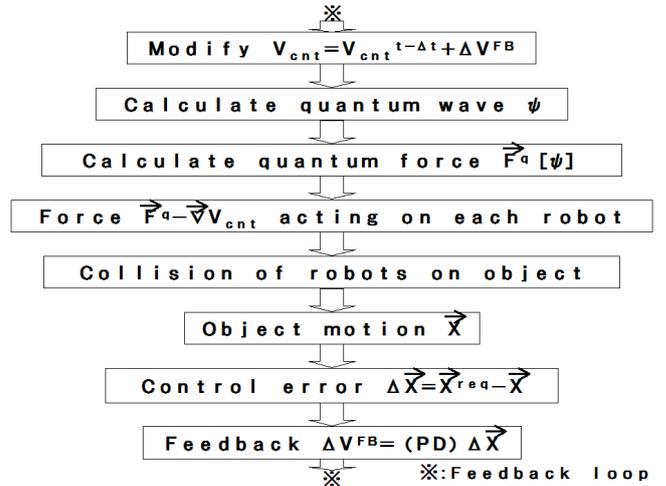


Fig. 3: 量子揺らぎ下のロボットによる物体駆動のフィードバック・ループ構造

波を積極的に制御するためには、外場 V_{cnt} を操作する必要がある。ここではもっとも単純と言う意味で次の線形の形を取り、

$$V_{cnt}(\vec{x}) = a_1 x_1 + a_2 x_2 \tag{9}$$

パラメータ a_1 と a_2 を操作入力 u とする。この a_1, a_2 については、これら先行値 (フィードフォワード) を \vec{X}^{req} から決め、それで不足する量をフィードバックで補うというのが本来の設計法である。しかし現状ではその先行値計算の方法が未だ無い。そこですべてをフィードバックでまかなう。すなわち

$$\vec{a} \equiv \begin{bmatrix} a_1 \\ a_2 \end{bmatrix} = C(\vec{X}^{req} - \vec{X}) \tag{10}$$

である。一般には C は非対角行列であり、また比例成分のみならず微分や積分成分も含めて表現しているとする。ただし本稿では対角項のみの比例成分に限定し、 a_1 と a_2 で比例定数も等しいとする。

$$a_i = P \times (X^{req}_i - X_i), \quad i = 1, 2. \tag{11}$$

なおここで注意すべきは比例定数 P が正値であればマゼンタ色細実線の \vec{X}^{req} に追従できることである。

波はあるていどの時間遅れを伴って物体に到達するから、このような目標値に対しては、最初のうちは X_1 も X_2 も目標値より小さい。従って (11) で $P > 0$ なら a_1, a_2 は正になる。ということはポテンシャルの形を考えれば分かる通り、通常の質点力学であればこれは $F_1 = -a_1, F_2 = -a_2$ という「左下向き」の力 \vec{F} を与えるはずである。しかし逆に正值の a_i により波が「左下向き」に駆動される結果として、物体裏側への回り込みが発生する。このため物体を「右上方向に」、すなわち \vec{x}^{req} に追従する方向に駆動できるのである。この質点力学の予想とは逆方向に物体が駆動される現象は、著者らの従来研究でも見られたものである⁵⁾。すなわちこれは連続体の「波の回り込み」という共通要因を表現している。

2.3 計算方法

量子力学的な揺らぎは、(7) のとおり特徴的なパラメータの平方、 H_R^2 、に比例する付加的なポテンシャル V^q によって表現される。ここで波動関数絶対値を $R^q \equiv |\psi| = e^C$ と指数関数で表現した。その理由は次のとおりである。この表現により、 R^q が境界でゼロ $R^q = 0$ になることを、境界での C 値の負の「大きな」値 $C = -\alpha$ として近似できる。これは R^q 値をゼロからゼロに近い「非常に小さな」正の値 $R^q = e^{-\alpha}$ 、に緩和したことと数学的にはまったく同じである。しかしコンピュータでの数値的な四則演算においては、 $e^{-\alpha}$ どうしよりも $-\alpha$ を演算の対象とする方が誤差が少ない。そこで本報告では、量子ポテンシャル V^q の計算にあって (7) のとおり C を使う。

この $C(\vec{x}, t)$ の2階微分までが V^q の計算には要される。従って量子揺らぎ力 \vec{F}^q の計算には、 C の3階微分までが必要である。これらの微分計算では、通常は数値微分すなわち有限差分法 (FDM) が適用される。しかし場 C には一般に凹凸が多く FDM のためには空間メッシュ幅、また対応して計算の安定性のため時間刻み幅を非常に小さくとらねばならない可能性がある。そこで既知の関数 $\{f_n(\vec{x}), n \in I\}$ の線形結合 $C_{approx} = \sum a_n(t) f_n(\vec{x})$ で C を近似し、 C_{approx} の3階微分演算により $\vec{F}^q = \text{func}(\frac{\partial}{\partial x}, \dots, \frac{\partial^3}{\partial y^3}) C_{approx}$ を算出することにする。これは C の強い凹凸のために激しく振動する量子揺らぎ力を緩和した量である、とみなすこともできる。われわれは、ロボットに作用する揺らぎ力の算定を系統的に実行するという立場であり、そのために量子力学という既存の枠組みを利用しているだけなのである。すなわち極度に振動が強い量子揺らぎは、緩和してこれをロボットに作用することに問題はないと考えられる。さてその既知関数 $f_n(\vec{x})$ であるが、通常は三角関数が選ばれる。それは微分が容易だからである。しかしわれわれの C 場では、先述のようにその境界条件が $C = -\alpha$ (負の大きな値) である。このため三角関数は使えず、ここでは単に計算の簡単さという理由から、多項式を取ることとする。

そしてフィットされた C 場から最終的に定数の揺らぎ力を抽出する。これは近似された C 場の単純な平均に過ぎない。ロボットへの揺らぎ力としては、この位置によらない力を用いる。

3 シミュレーション

3.1 計算条件

シミュレーションの条件は表 1 に与えるとおりでである。パラメータ値は従来研究^{5, 6)} と同じである。ただトラッキングの運転条件 (物体の移動速度) は従来⁶⁾ の 10 倍速として速い運動にも追従できることを確認する。この条件に対応して揺らぎパラメータを $H_R = 2$ ととる。なお本報では考慮しない ($\gamma = \delta = 0$) が、摩擦力は物体に関してはニュートン方程式に追加するだけで簡単に導入できる。しかしロボット側については、われわれは量子力学を使って揺らぎを計算する立場であるから、摩擦についてもこれを考慮した量子力学を考える必要がある。これはエネルギー散逸系であって一般には確立していない。そこでこれは付録に方法論を示す。

Table 1: Parameters

meaning	parameter	value
geometry	$[-S_1, S_1]$	$S_1 = 1[\text{m}]$
	$\times [-S_2, S_2]$	$S_2 = 1[\text{m}]$
number of robots	N_0	4[-]
radius	robot: $\frac{a_R}{2}$	0.05[m]
	object: R_B	0.25[m]
mass	robot: m	0.3[kg]
	object: M	37.5[kg]
coefficient of restitution	e	1[-]
collision potential ¹⁾	σ_S	4[J]
	σ_v	4[J]
	n_S	12[-]
	n_v	12[-]
wall reaction	c_R	4[J]
	c_B	4[J]
	n_{cR}	12[-]
friction coefficients	robot: γ	0[kg/s]
	object: δ	0[kg/s]
quantum fluctuation	H_R	2[J · s]

3.2 量子揺らぎ下のロボットによるトラッキング

本報では全 10 ケースのロボット初期配置を考えたが、以下の図 (Fig.4~7) はその代表的なケースに対するものである。はじめに、量子力学的な波動関数は数値的に計算されるが、その計算の「正しさ」(必要条件に過ぎないが) を Fig.4 に示す。これは、波動関数の絶対値平方 $|\psi|^2$ の全領域にわたる積分の初期値からの誤差の時間トレンドの図である。支配式はエネルギー保存を前提とするため、誤差の発生はエネルギーの系外への散逸すなわち計算の破綻を意味する。しかし全 10 ケースで 5[] 程度に収まっており、本報で採った計算スキーム³⁾ は妥当と判定する。次に計算では C 場をを 10 次までの多項式関数で展開したが、その係数の時間変化を Fig.5 に示す。時間トレンドはほぼ一定の平均値のまわりで振動しており、これも計算の安定性を示す。ポテンシャル下での規則的な運動以外に計

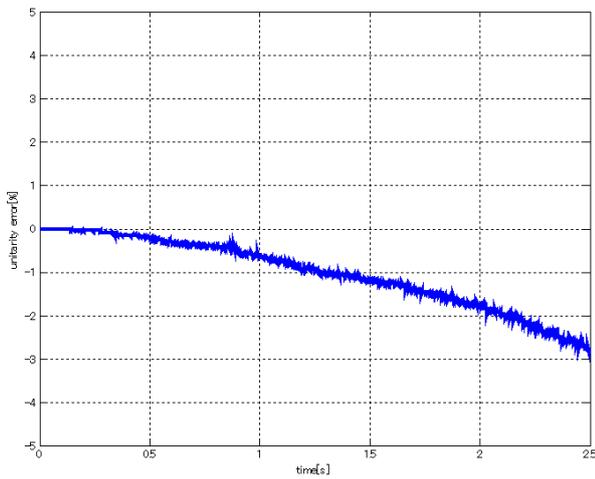


Fig. 4: 波動関数の計算誤差. 系のエネルギー保存の割合を表す.

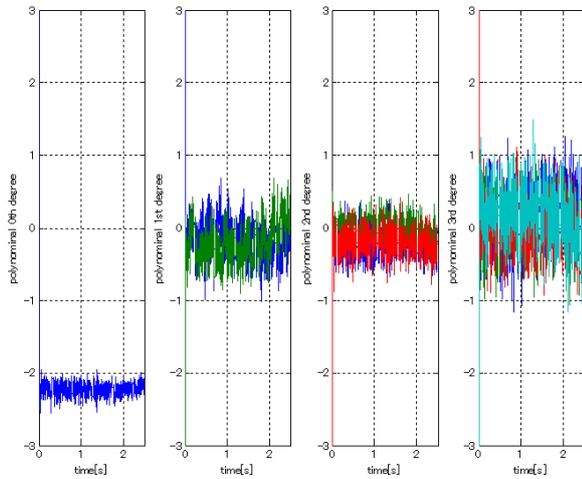


Fig. 5: C 場の展開係数 $a_n(t)$ ($n = 1, 2, \dots, 10$) の時間トレンド.

算で得られた量子揺らぎが引加されるため、また互いにとどきの衝突があるため、各ロボットは Fig.6 に示すとおり領域内を不規則に動き回る。この結果とし

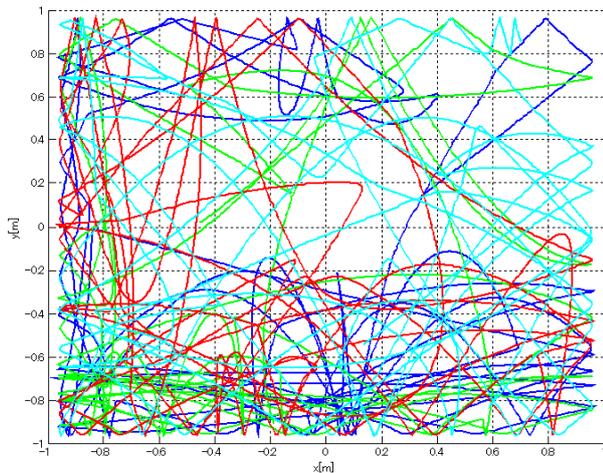


Fig. 6: ロボットの領域内の運動. 青: 1, 緑: 2, 赤: 3, シアン: 4 番目, の計 $N_R = 4$ 台のロボット.

て物体が Fig.7 のように希望経路にトラッキングされ

る。シミュレーションを実施した 10 ケースのうち 9

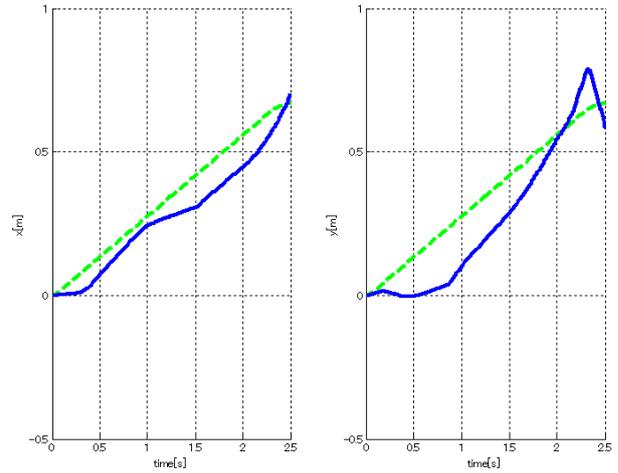


Fig. 7: 物体のトラッキング状況. 左: $X_1(t)$, 右: $X_2(t)$, のそれぞれ時間変化.

ケースで、フィードバック比例定数 P の設定値を 1 割ていどのばらつき範囲に収められた。1 ケースについては、他 9 ケースの P 値の平均からおおきくずれたところに設定してもトラッキングがなされなかった。次にロボットに V_{cnt} によるフィードバックの他には単純に大きさが一様乱数の力を x, y それぞれの方向に引加する。一様乱数による力のもとでもトラッキングに成功するケースもあるが、成功に導くべきフィードバック比例定数のばらつきが大きく、設計上の困難が生じる。

4 まとめと議論

ロボットに対する量子揺らぎの従来⁶⁾の概念にあつては、ロボットの自己位置の計測が必要であった。すなわちロボットは簡素な構造ではなかった。本報は量子揺らぎを、時間変化はするが領域にわたり定数と近似しそれを解消した。効果はシミュレーションで確認した。プロトタイプロボットによる実験検証は進捗中であり、別途の報告とする。科研費 (C)16K00337 の支援を受けた。

参考文献

- 1) Gould and Tobochnik. *Simulation Physics*. Pierson Education, 2000.
- 2) P Hänggi and F Marcheson. Artificial brownian motors: Controlling transport on the nanoscale. *Reviews of Modern Physics*, Vol. 81, pp. 383–442, 2009.
- 3) Iitaka. *Introduction to quantum dynamics* (in Japanese). Maruzen Pub., 1996.
- 4) T Itami. Continuum mechanical analysis of collective motion of robots. *Transactions of the Society of Instrument and Control Engineers*, Vol. 48-3, pp. 141–150, 2012.
- 5) T Itami. Macroscopic group robots inspired by brownian motion. In Y Tan, editor, *Handbook of Research on Design, Control, and Modeling of Swarm Robotics*, Vol. 1. 1st edition, 2015.

- 6) T Itami and N. Matsui. 量子ダイナミクスによる群ロボットの知的タスク処理. 第12回コンピュータショナルインテリジェンス研究会.
- 7) T Itami and N. Matsui. Experimental study on macroscopic brownian motion using sphere shaped robots. In *iwnc9*, 2015.
- 8) L.I.Schi . *Quantum Mechanics*. McGraw Hill, 1968.
- 9) F Oosawa. *Statistical mechanics(in Japanese)*. 2011.
- 10) P.A.Machado. *Computational Approach to Bohm's Quantum Mechanics*. PhD thesis, McMaster University, 2007.
- 11) 伊丹, 松井, 乾, 全. 量子力学的手法によるシステムと制御. コロナ, 2017.

A ロボット群に作用する摩擦の扱い

ロボットには摩擦が作用する. すなわち通常は系からはエネルギーが散逸する. ところが通常の量子力学⁸⁾はエネルギーが保存するシステムを対象とするため, 摩擦が作用する系に対する量子揺らぎを計算するすべがない. そこで今後の展開のためにロボット群に摩擦が作用するときのハミルトン形式による力学を開発したのでここで紹介する. 系をふつうに量子化することで量子力学への移行も機械的になされる. ロボットに作用する力が保存ポテンシャルの負勾配と速度に依存する摩擦力であるとする. 摩擦は速度に比例した量としてモデル化されることが多いため, ここでも摩擦力を $-\gamma\dot{x}$ とし, 正の比例定数 γ は位置や速度には依存しないとする. はじめに線形最適フィードバック制御との関連づけを理由として, ポテンシャル外力はバネ反力 $-m\omega^2\vec{x}$, すなわち調和振動子を扱う.

速度に比例した摩擦力が作用する調和振動子の運動方程式は,

$$m\ddot{x} = -m\omega^2x - \gamma\dot{x} \quad (12)$$

である. これを導出するラグランジアンを計算するために, 先ず $x_1 \equiv x$ とし,

$$\dot{x}_1 = x_2 \equiv f_1(\vec{x}, u) \quad (13)$$

と置く. すなわち速度 \dot{x} を改めて独立した変数 x_2 と考える. すると運動方程式 (12) は,

$$u \equiv x_2, \quad (14)$$

$$\Gamma \equiv -\frac{\gamma}{m} < 0 \quad (15)$$

として以下である.

$$\dot{x}_2 = -\omega^2x_1 + \Gamma u \equiv f_2(\vec{x}, u) \quad (16)$$

これらの (13) と (16) は, 次の制御の状態方程式と見なすことができる.

$$\begin{aligned} \frac{d}{dt} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} &= \begin{bmatrix} 0 & 1 \\ -\omega^2 & 0 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} + \begin{bmatrix} 0 \\ \Gamma \end{bmatrix} u \\ &= A\vec{x} + Bu \end{aligned} \quad (17)$$

この (17) で表現される系は

$$U = [B \quad AB] = \begin{bmatrix} 0 & \Gamma \\ \Gamma & 0 \end{bmatrix} \quad (18)$$

が $\text{rank}(U) = 2$ だから可制御である. そしてわれわれの目標は, (14) を最適フィードバック入力とするような制御仕様を見つけることである.

状態方程式 (17) による制御を制御仕様

$$L = Ru^2 + Q_1x_1^2 + Q_2x_2^2 \quad (19)$$

に対して最適化するには次のリッカチ方程式

$${}^tAP + PA + Q - PBR^{-1}{}^tBP = 0 \quad (20)$$

の解

$$P = \begin{bmatrix} p_1 & p \\ p & p_2 \end{bmatrix} \quad (21)$$

を使い

$$u = -R^{-1}{}^tBP\vec{x} \quad (22)$$

これが (14) に一致するように (19) のパラメータを決める. (22) から, $p = 0$, $p_2 = -\frac{R}{\Gamma}$ である. これを (20) に代入し $p_1 = \omega^2p_2 = \frac{m\omega^2R}{\gamma}$, また x_1, x_2 の重みは $Q_1 = 0$, $Q_2 = \frac{\Gamma^2p_2^2}{R} = R$ と計算される. 以上から

$$|P| = p_1p_2 = \omega^2p_2^2 > 0 \quad (23)$$

と P の正定性は確保されている. 共通因子 $R = \frac{m}{2}$ とすれば制御仕様は結局

$$L(\vec{x}, u) = \frac{m}{2} \left(\frac{u^2}{2} + \frac{x_2^2}{2} \right) \quad (24)$$

である.

運動方程式を導くための未定乗数 $\vec{\lambda}$ を使い, ハミルトニアン

$$H \equiv -(L + \vec{\lambda} \cdot \vec{f}) \quad (25)$$

により正準形式を適用でき, 量子力学を構築できる¹¹⁾. すなわち量子揺らぎも摩擦を含んだ形で計算できる. 一般的な力の場合もまったく同様に展開できる.

GPS計測と制御を組み込んだ水中模擬充電システムの構築

○李想 Khin Nwe Lwin 許弘毅 山田大喜 戸田雄一郎 松野隆幸 見浪護 (岡山大学)

Construction of Underwater Simulated Charging System Incorporating GPS Measurement and Control

*X.Li K.Lwin H.Xu D.Yamada Y.Toda T.Matsuno M.Minami (Okayama University)

Abstract— Today, many robots are being researched and developed for various underwater tasks such as seabed exploration. Furthermore, research on autonomous underwater robot (AUV) is still in the developing stage and it can be said that it will become very important in the future. Currently, our research group is working on development of an automatic charging system based on visual servo technology for underwater robot which can perform various tasks such as automatic management of marine ranch, sea bottom search. However the measure of sailing to the working area and returning to the charging equipment have not been completed yet. In this paper, an automatic underwater simulation charging system for realizing the automatic control of underwater robot will be proposed. The system is using GPS measurement and guidance control method. And the usefulness of this automatic guidance system will be discussed by a repetition accuracy experiment and a guidance control experiment using mobile robot. Finally, the result of the newest simulated charging experiment in the actual sea of Okayama will be report.

Key Words: Underwater robot, GPS guidance, Automatic charging

1 緒言

今日、水中ロボットは様々な場面で用いられている。例えば、魚の養殖業において水底に沈んだ死魚の回収や、地震で被災した漁港の被害調査、また、水力発電所での水中の壁面や設備検査などが挙げられる。なかでも、水深数百～数千メートルの海底調査といった人が立ち入ることができない過酷な環境下において、これらのロボットの利用は大きく期待されている。このような場面では海底調査、海底マッピング、生物調査等を行う際には水中ロボットの長時間航行が必要である。海上から有線で電力供給することを想定した Remotely Operated Vehicle(ROV)を用いる場合、ケーブルの張力の外乱による水中ロボットの制御への悪影響、ケーブルの摩耗や絡まり、波による消耗、メンテナンス等様々な問題がある。

そこでバッテリーを搭載し、給電ケーブルをなくした Autonomous Underwater Vehicle(AUV)を用いることを想定すると、現在利用されている水中ロボットのバッテリーの持続時間は長くても十数時間程度と短いため、充電のために海上と海底を行き来しなくてはならないことが問題となる。したがって、水中での長時間稼働を実現するには海中に給電設備を設置しロボットが自動で充電を行えることが理想である。

そこで、水中充電施設を想定した装置に対して水中ロボットが自動で接近し嵌合を行う誘導制御システムの研究が盛んに行われてきた。著者らは、複眼で3次元立体マーカー(3Dマーカー)の3次元位置・姿勢を動画像列の中で実時間認識する手法(Three Dimensional Move on Sensing(3D-MoS)と呼んでいる)を提案し、プールでのアプローチ・嵌合実験¹⁾、動画像中に映り込む外乱に対するロバスト性の研究²⁾、光環境の変化に適応する画像処理の研究³⁾、また動画像中で3次元マーカーを認識する際の認識時間応答改善方法に関する研究を行ってきた。なお、著者らは、3Dマーカーを用いたビジュアルサーボによってプールでの実験だけでなく和歌山県と岡山県の海においても嵌合実験を成功させた⁴⁾⁵⁾。

実際の運用時には、我々の認識システムは様々な種類の中水中ロボットに搭載可能かつ、有効性を確認する必要がある。これまでの研究には、広和株式会社製作のROVを用いてきた。AUVにおいて我々の認識システムの有効性を確認するために、東京大学所有のTuna-Sand 2に提案認識システムを搭載し嵌合実験を行った。嵌合実験は東京大学生産技術研究所内の実験プールにて行い、成功した⁶⁾⁷⁾。これにより、AUVにおいても我々の提案認識システムの有効性を確認することができた。

そして、現段階(第2段階)の研究目標として、従来の研究に用いてきた広和製水中ロボットとは異なる軸構成のROV(DELTA-150)に高精度のGPS計測と誘導制御を導入し、ビジュアルサーボ技術と連携することで、現在の水中ロボット(ROV)に欠けている作業海域への航行や充電装置までの帰投手段を補完し、水中ロボットのAUV化を目指している。

本論文では、水中ロボットのAUV化実現に向けてGPS計測と誘導制御を組み込んだ自動水中模擬充電システムを提案する。そして、GPS計測・誘導システムの有用性について、GPS測位の繰り返し精度や移動ロボットを用いた誘導制御実験を用いて議論する。さらに、岡山県の実海域で行われた模擬充電実験について報告する。

2 システム概要

ビジュアルサーボ技術をGPS計測・制御と結合した水中模擬充電システムの概要をFig.1に示す。Fig.1より、本システムの開発は3つの段階に分かれている。

第1段階: ROVの前方に搭載している2台の水中カメラ(前向き)で充電装置(ステーション)に設置した3Dマーカーの位置・姿勢を実時間で認識することで、模擬の充電動作(ドッキング)を実現する。

第2段階(現段階): GPSとビジュアルサーボをベースとした自律航行システムの開発を行う。Fig.1(2nd phase)より、この段階では2台の水中カメラ(下向き)、GPS、地磁気センサー、圧力センサーをROVに搭載し、PCなどの制御類機器はROVの後方に牽引している耐圧容器(MY2)に格納する。この航行システ

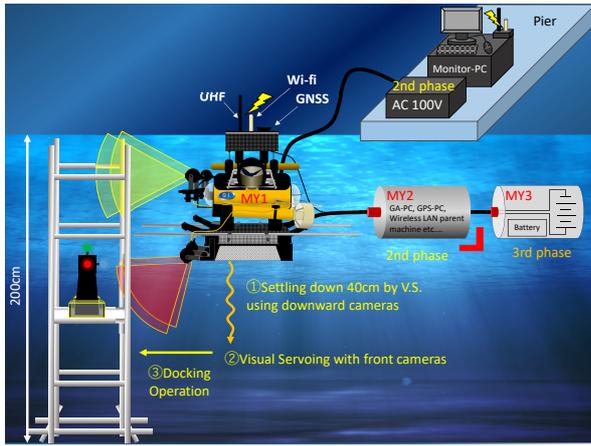


Fig. 1: Overview of underwater charging system

ムは ROV が海面（アンテナ類が海面から露出）に留まるとき、GPS の測位情報を用いて予定の作業海域または充電装置までの誘導制御を実現する。さらに、ROV が水面下で作業する時は下向きのカメラを利用したビジュアルサーボで自己位置を推定し、誘導制御を行う。

第3段階：ROV の後方に2つ目の耐圧容器（Fig.1 の MY3 部分、ROV の電池を格納）を追加し、実際の水中充電を行う。

3 GPS による自動航行・帰投制御

GPS の計測・制御システムを ROV に搭載する前に、GPS 受信機の測位精度と制御有効性について確認実験を行った。

3.1 繰り返し精度確認実験

RTK-GPS 測位機器の動作確認及び測位の繰り返し精度を検証するために、GPS 受信機（移動局）を台車に乗せて100回の模擬帰投実験を行った。

Fig.2に示すように、繰り返し精度確認実験の場所は岡山大学工学部1号館前の駐車場とし、実験エリアの配置と実験装置の寸法はFig.2, 3に示す。GPS 基地局のアンテナは地面から2.1mのところ固定され、座標原点である嵌合位置より1.8m離れた。移動局は台車に搭載され、アンテナの高さは1.9mである。

実験の流れは：1、移動局台車を初期位置に置き、この位置を座標原点(0, 0)として設定する。2、移動局台車をランダムに移動させてから所定位置(0, 0)に戻らせて、台車の位置を記録する。3、手順2を100回行い、繰り返し精度を確認する。

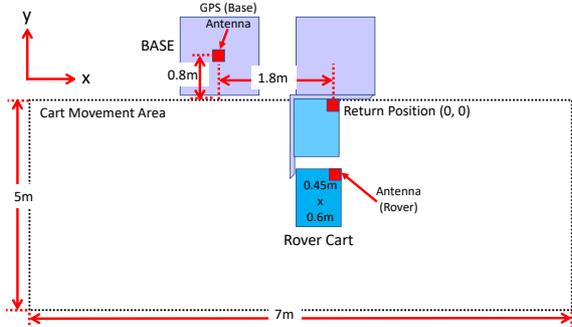


Fig. 2: Dimensions and layout of the experiment area

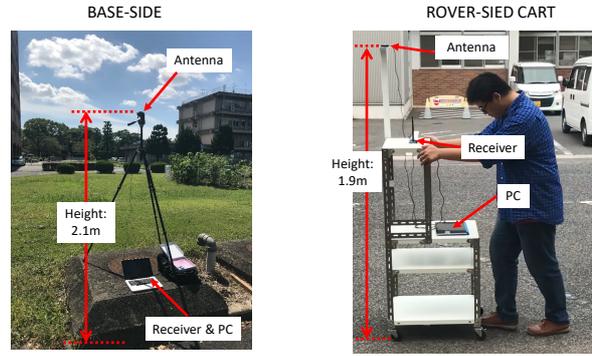


Fig. 3: Based side and rover side of GPS receiver

実験結果を Fig.4, 5 に示す。Fig.4 は移動局台車がランダム移動してから、座標原点に戻る際の測定位置、Fig.5 は X 方向と Y 方向に対する偏差の近似正規分布曲線を表している。Fig.4 より、100 回の位置測定結果の分布は原点から X 方向 $\pm 30\text{mm}$ 、Y 方向 $\pm 40\text{mm}$ の範囲内に収まっている。さらに、Fig.5 より、X 方向、Y 方向の測位誤差分布はいずれも 3 倍標準偏差 ($\pm 3\sigma$) 以内に入る確率が 99% 以上あるため、GPS 測位機器は良い繰り返し精度を有することが分かった。

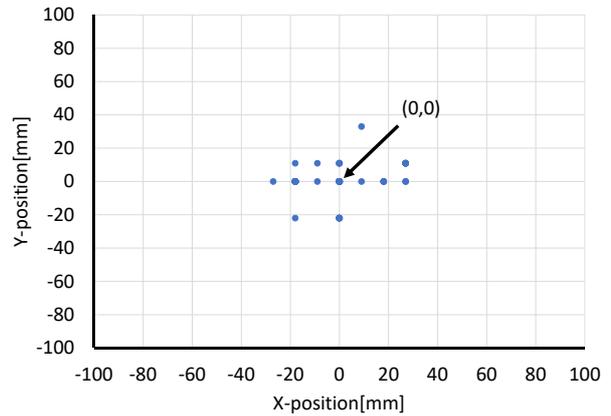


Fig. 4: Measurement position of GPS rover side receiver

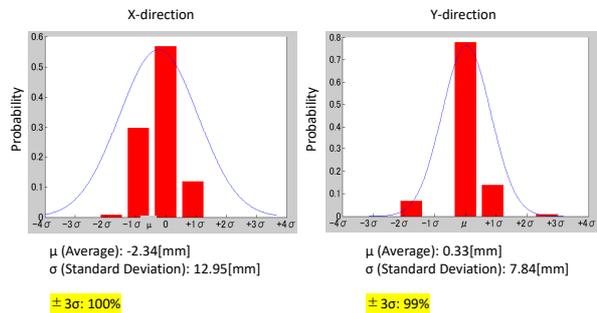


Fig. 5: Approximate normal distribution curve of deviation in x-direction and y-direction

3.2 移動ロボットを用いた制御確認実験

GPS 制御システムの有効性を検証するために、GPS 受信機を Fig.6 に示した移動ロボットに搭載し、事前に指定した 4 つの目標地点への誘導制御実験を行った。

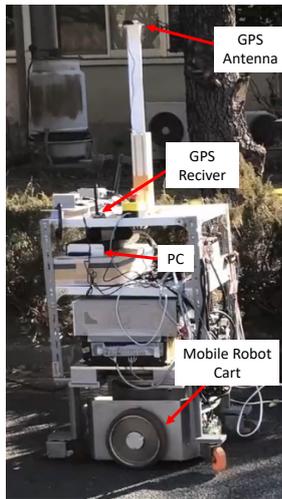


Fig. 6: Mobile robot with GPS receiver (rover side)

Fig.7に示すように、本実験の場所は岡山大学工学部11号館北側の道路を選んだ。誘導制御実験では、事前に4つの目標点及び目標方位角を順次指定し、GPSの測位データを用いて、移動ロボットをそれらの目標点まで誘導する。移動ロボットの初期位置・方位角は $(x_0, y_0, \theta_0) = (0[m], 0[m], -1[^\circ])$ で、追従の目標は $(x_{d1}, y_{d1}, \theta_{d1}) = (2[m], 0[m], 90[^\circ])$ 、 $(x_{d2}, y_{d2}, \theta_{d2}) = (2[m], 2[m], 180[^\circ])$ 、 $(x_{d3}, y_{d3}, \theta_{d3}) = (0[m], 2[m], 270[^\circ])$ 、 $(x_{d4}, y_{d4}, \theta_{d4}) = (0[m], 0[m], 0[^\circ])$ である。停止条件は距離偏差0.2m以下、角度偏差 2° 以下と設定した。

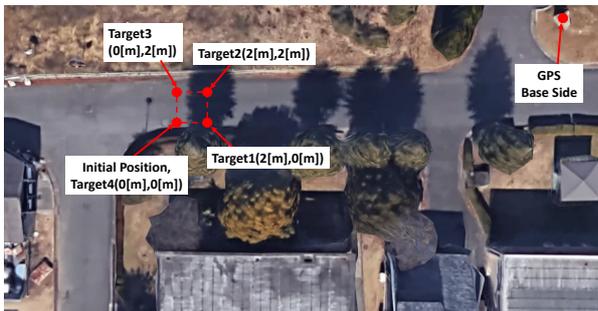


Fig. 7: Layout of the experiment area

Fig.8は移動ロボットの移動経路を示している。Fig.8より、移動ロボットの移動経路は正方形になっていて、最終の停止位置 $(0.092[m], 0.033[m])$ と初期位置 $(0[m], 0[m])$ の位置制御偏差も想定許容範囲 (Fig.8の赤い破線丸) 内に収まっており、GPS測位データを利用した制御システムは有効であることが分かる。

4 ビジュアルサーボ技術による模擬充電実験

本システムの第1段階の実現として、GPS誘導で、ROVを充電装置に帰投できたことを想定し、ビジュアルサーボで模擬充電実験を2018年1月16日、岡山県瀬戸内市牛窓町にある岡山大学理学部付属牛窓臨海実験場にて行なった。

4.1 嵌合条件

Fig.9にROVが嵌合を行う条件をフローチャートで示す。ロボット前方に搭載された複眼カメラに対象物が

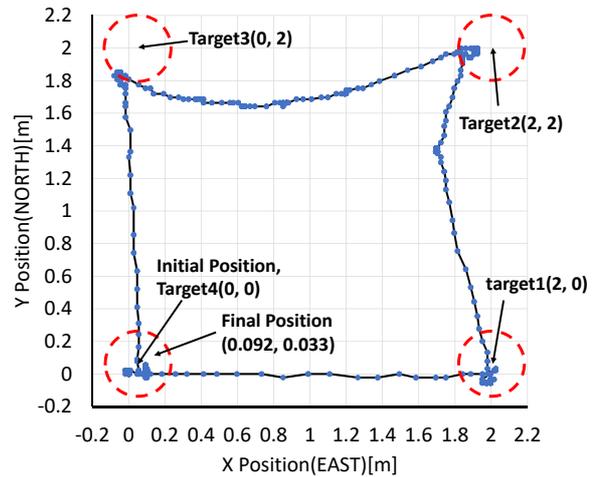


Fig. 8: Movement path of mobile robot (GPS measurement)

映し出されるまで、ロボットを手動操作で対象物に接近させる。ロボットを対象物にある程度接近させ、適合度の値が0.2以上に上昇したことが確認された後、手動操作から自動制御へ切り替えることで (a) Visual Servoing 状態へ移行させる。

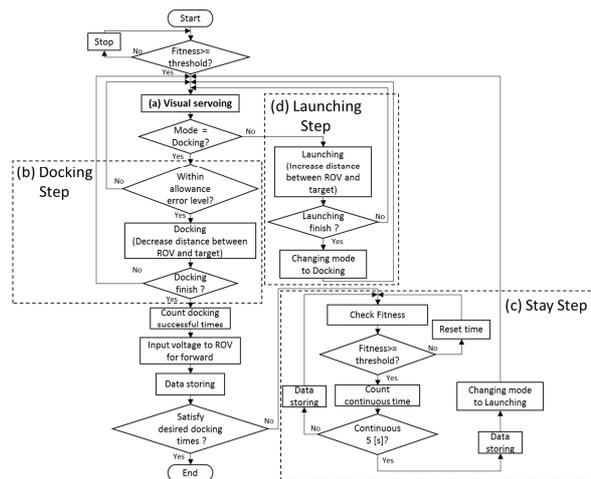


Fig. 9: Flow chart of ROV docking condition

(a) Visual Servoing

ROVが3Dマーカーを発見し、目標とする相対的位置・姿勢 $[x_d, y_d, z_d] = [600, 0, 0][mm]$ 。姿勢はクォータニオンで表現し、 $\epsilon_d = [\epsilon_1, \epsilon_2, \epsilon_3] = [0, 0, 0]$ に追従することで対象物と正対する状態である。ここで、 ϵ_1, ϵ_2 は x_H, y_H 軸周りの姿勢であるが、重心と浮心の関係により安定に0に保たれている。ROVが3Dマーカーの正面に移動し、嵌合穴の中心から y_H 軸、 z_H 軸方向の誤差が $\pm 40[mm]$ 、 ϵ_3 の誤差が ± 0.0615 以下に留まる状態が $165[ms]$ 連続すると以下に示す (b) Docking を経てロボットは仮想給電設備への嵌合を実行する。

(b) Docking

ROVが前進して嵌合動作を行なっている状態である。 $|y_d - y| \leq 40[mm]$ かつ $|z_d - z| \leq 40$ を満たすとき、奥行き方向の目標値を $x_d = 600 - 30t[mm]$ (t : 嵌合を始めたときを $t = 0[s]$ とする) と時変で減少させること

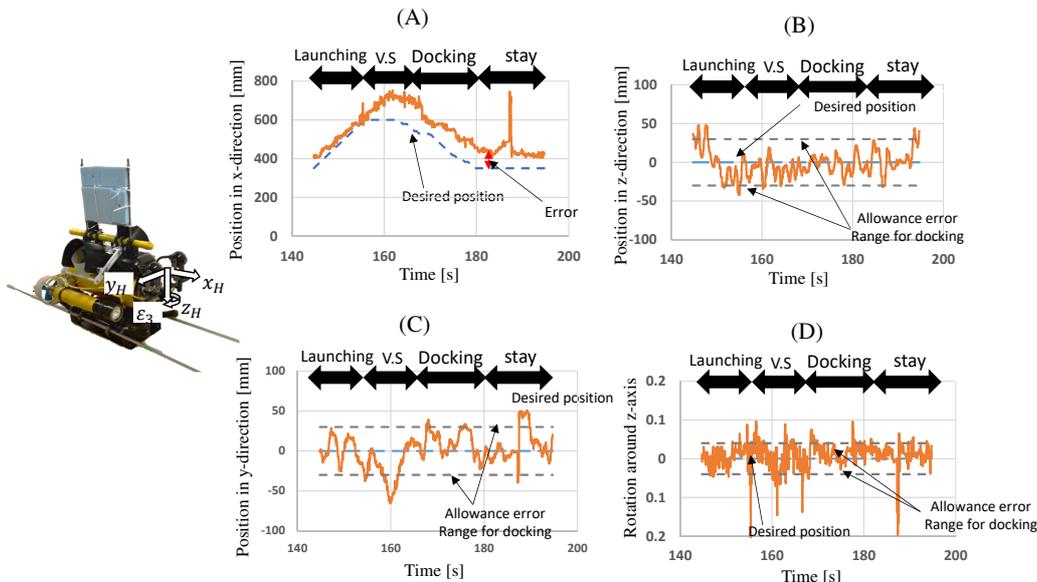


Fig. 10: Experimental results of simulated charging experiment. (A)Position in x-direction (B)Position in z-direction (C)Position in y-direction (D)Rotation around z-axis (ϵ_3).

で ROV が 30[mm/s] の速度で x 軸方向に前進し嵌合穴に嵌合する。 x_d が最終値 350[mm] となることで嵌合を完了する位置に ROV が移動する。ただし途中で嵌合の条件 (y 軸, z 軸方向の誤差が ± 40 [mm] 以下) を満たさなくなった場合, その時点での x 軸方向の時変目標値を固定して再び (a)Visual Servoing に戻る。

(c)Stay

嵌合が完了した状態である。この状態でも Visual Servoing 状態と同様に 3D マーカーに対して一定の相対的位置・姿勢 ($[x_d, y_d, z_d] = [350, 0, 0]$ [mm], $\epsilon_d = [\epsilon_1, \epsilon_2, \epsilon_3] = [0, 0, 0]$) を保つように制御がなされる。

(d)Launching

ROV が後退して初期位置に戻っている状態である。奥行き方向の目標値を $x_d = 600$ mm までを増加させ, DELTA-150 を後退させる。

4.2 結果・考察

実験結果を Fig.10 に示す。図中青の破線は目標値 (適合度の場合には動作のしきい値), 灰色の破線は嵌合条件の範囲を示している。 Fig.10(A) の x 方向の目標値は 600[mm] から 350[mm] の減少している。そして, この際, Fig.10(B)(C)(D) より, y_d, z_d, ϵ_3 について嵌合条件 (165[ms] の間, 目標値 y_d, z_d について ± 40 [mm], ϵ_3 について ± 0.0615) を満たしており, 嵌合動作を行なうことができたということがわかる。ここで ϵ_3 はクォータニオンの値であるため単位を持たない。おおよその目安として, $[\epsilon_1, \epsilon_2] = [0, 0]$ とした場合, 度数法で約 $\pm 7^\circ$ 程度である。

5 結言

本論文では, 水中ロボットの AUV 化実現に向けて GPS 計測と誘導制御を組み込んだ自動水中模擬充電システムを提案した。そして, 繰り返し精度に関する実験と移動ロボットの誘導制御実験, そして岡山県の実海域で行われた模擬充電実験を用いて, このシステムの有用性について議論した。

謝辞

本研究では三井 E& S 造船株式会社と広和株式会社 マリンシステム部の協力を得ました。ここに謝意を表します。

参考文献

- 1) 矢納陽, 大西翔太, 石山新太郎, 見浪護, “水中自動充電を目指したビジュアルサーボ型水中ロボットの自動嵌合制御”, 日本機械学会論文集 Vol.81, No.832, p.15-00391, 2015.
- 2) Myo Myint, Kenta YONEMORI, Akira YANO, Shintaro ISHIYAMA and Mamoru MINAMI, “Robustness of Visual-Servo against Air Bubble Disturbance of Underwater Vehicle System Using Three-Dimensional Marker and Dual-Eye Cameras”, MTS/IEEE OCEANS, Washington, 18.Oct - 22.Oct, 2015.
- 3) Myo Myint, Kenta Yonemori, Akira Yanou, Khin Nwe Lwin, Mamoru Minami and Shintaro Ishiyama, “Visual-based Deep Sea Docking Simulation of Underwater Vehicle Using Dual-eyes Cameras with Lighting Adaptation”, MTS/IEEE OCEANS, Shanghai International Convention Center, April 10-13, 2016.
- 4) 米森 健太, Myo Myint, Khin Nwe Lwin, 向田直樹, 菊池章, 見浪護, 石山新太郎, 松野隆幸, 矢納 陽, “ビジュアルサーボを搭載した水中ロボットの実海域嵌合制御”, 日本機械学会論文集, No.16-00410 DOI: 10.1299/transjsme.16-00410.
- 5) Myo Myint, Kenta Yonemori, Khin New Lwin, Akira Yanou and Mamoru Minami, “Dual-eyes Vision-based Docking System for Autonomous Underwater Vehicle: An Approach and Experiments”, Journal of Intelligent & Robotic Systems, 2017.
- 6) 松野隆幸, 西田祐也, 米森健太, 李想, 向田直樹, 加藤直輝, Myo MYINT, 山田大喜, Nwe Lwin KHIN, 見浪護, “複眼立体認識を用いた水中嵌合実験 (AUV を用いた制御機能検証)”, 日本機械学会論文集, Vol.84, No.858, 2018 年 2 月.
- 7) 向田直樹, 西田祐也, 李想, 米森健太, Myo Myint, Khin Nwe Lwin, 松野隆幸, 見浪護, “複眼立体認識システムを搭載させた Tuna-Sand 2 の嵌合実験”, 第 35 回 日本ロボット学会学術講演会 (RSJ 2017), C3C2-05, 2017.9.11-14.

ヒトの歩行における運動学データに基づく 生体内負荷の最適化による床反力推定

○林祐一郎 長谷和徳 工藤あすか (首都大学東京)

Estimation of Ground Reaction Force by Optimizing Biomechanical Load Based on Kinematic Data during Human Gait

* Y. Hayashi, K. Hase and A. Kudo (Tokyo Metropolitan University)

Abstract— In conventional direct measurement methods of body motion, optical motion capture system and force plate have been used. However, conventional force plates require a large scale experimental facility and these are very expensive. Therefore, the purpose of this study is to enable gait analysis with only kinematic data. It performs the estimation of ground reaction force using optimization of biomechanical load. As a result of the optimization, ground reaction force could be estimated with some degree of accuracy and the effectiveness of the proposed method was validated. On the other hand, its accuracy was not much affected by gait speed.

Key Words: Biomechanics, Gait analysis, Ground reaction force, Force plate, Kinematic data, Optimization

1 緒言

身体運動計測においては、身体の関節などの位置に反射マーカを貼り付け、運動中にそれらのマーカを複数台の光学式モーションキャプチャカメラで撮影し、マーカの3次元位置座標の変化を計測するシステムが多く導入されている¹⁾。そして、運動計測に基づく歩行解析では、床反力計を用いて接地時間および離地時間を検出し、1歩行周期中の計測データを精度良く得ることは非常に重要となる。また、外部からの観察のみでは不可能な生体内の力学的な働きを定量的に分析する剛体リンクモデル解析が基盤技術として利用されている²⁾。これらの方法では計測装置が高価な上、実験内容は制限され自然な動作の計測が困難となるため、床反力計を用いずに高精度な歩行計測を実現すれば科学的知見をさらに生み出せると考えられる。

しかし、既存の関数近似による床反力推定³⁾では、被験者の歩行の特徴への依存度が高いため、より汎用的であると考えられる。生体内負荷の最適化を用いた床反力推定の方法を提案しなければならないといえる。

そこで、本研究では、運動学データから床反力や歩行周期を推定し、同時に計測した床反力計の計測値と推定値を比較し、高精度に床反力を推定する方法について検討することを目的とする。また、推定精度が歩行速度に影響されないかを検討する。

2 歩行実験

2.1 実験装置

Natural Point 社製の光学式モーションキャプチャカメラを計17台、テック技販社製の床反力計と大阪自動電機社製のマットスイッチを1台ずつ用いた。全ての装置のサンプリング周波数は100 Hzである。

2.2 実験方法

マーカはVicon Plug-in-Gaitモデルに従って被験者に配置する。前節で記した実験装置はFig. 1に示すように配置した。そして、健康成人男性5名の被験者は実験前に床反力計に脚を接地できるよう歩行練習を行

った。被験者が行った歩行は通常の歩行 nw(normal walking)、速い歩行 fw(fast walking)、遅い歩行 sw(slow walking)である。本実験ではそれぞれの歩行速度で3試行を行った。

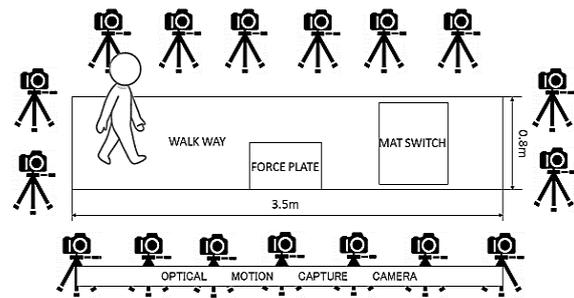


Fig. 1 A schematic of gait experiment.

2.3 データの選別

本研究では、歩行速度と推定精度の関係を定量的に評価したいが、被験者が歩行速度を調節することは困難である。そのため、nwの平均歩行速度を基準としてfwはnw+15%より速いデータ、swはnw-15%より遅いデータとなるように各被験者のnw、fw、swをそれぞれ1データずつ選別した。

3 床反力の推定アルゴリズム

並進運動方程式より得られる外力ベクトルの和 F_{ext} の算出式を(1)式に示す。以後、ベクトルは太字の記号で示す。 F_R は右脚、 F_L は左脚に作用する外力である。 m_i は*i*セグメントの質量、 a_i は*i*セグメントの加速度、 g は重力加速度を示す。

$$F_{ext} = F_R + F_L = \sum_{i=1}^n m_i (a_i - g) \quad (1)$$

片脚支持期の床反力の大きさについて、(1)式から求めることができる。しかし、(1)式では F_R と F_L の方向や

大きさとそれらの作用点位置が定まらない。それらを誤って推定した際には、姿勢を維持するために異常に大きな関節反力や関節モーメントが発生すると考えられる。歩行解析においてこれらの生体内負荷は重要な指標となるため、 \mathbf{F}_R と \mathbf{F}_L の方向や大きさとそれらの作用点位置を精度良く求めたい。そのため、本研究ではヒトは歩行時に生体内への負荷が最小になるように歩いていると仮定することで床反力を推定する。

まず、床反力が発生している期間を推定するために脚の接地判別が必要である。歩行時の立脚期に脚の速度が遅くなり、高さは低くなる。そのため、被験者に配置した踵と爪先のマーカーの速度と高さにより接地判別を行う。モーションキャプチャにより爪先と踵の前後・左右・鉛直方向の速度 v_x, v_y, v_z と位置が得ら

れる。そして、(2)式により v_x, v_y から水平面の速度 v_{xy}

を算出した。接地判別ではそれらの速度と高さ z 、速度の閾値 v_{thres} 、高さの閾値 z_{thres} を用いた。また、 v_z は脚を降ろすときに負の値になるため絶対値にして判別を行った。接地判別は各脚の踵と爪先それぞれについて行われる。接地判別式を(3)式に示す。

$$v_{xy} = \sqrt{v_x^2 + v_y^2} \quad (2)$$

$$\mathbf{F}_{ext} = \begin{cases} \sum_{i=1}^n m_i (\mathbf{a}_i - \mathbf{g}) & \text{if } \begin{cases} z_{thres} < z \\ v_{thres} < |v_z| \\ v_{thres} < v_{xy} \end{cases} \\ \mathbf{0} & \text{otherwise} \end{cases} \quad (3)$$

次に、床反力の作用点位置が足裏から離れないように3種類の制約を設けた。具体的には、鉛直方向の作用点位置を 0m とし、前後方向の作用点位置は踵と爪先のマーカーの間となる。そして、左右方向の作用点位置は踵と爪先のマーカーの左右方向の位置の平均値から 0.05m 以内とした。

また、最適化の変数は前後、左右、鉛直方向の床反力と床反力の作用点位置である。最小化する生体内負荷は、床反力の和の差と関節モーメントの和の差と自由度を与えるために筋骨格モデルに設けた仮想関節に働くモーメントと反力である。床反力の和は(1)式で算出した \mathbf{F}_{ext} と最適化により推定した両脚の床反力の差 \mathbf{F}_{error} を(4)式により求める。外部モーメント \mathbf{M}_{ext} も同様に(5)式で算出して(6)式により差を求める。(5)式は角加速度 $\dot{\omega}_i$ 、加速度 ω_i 、質量中心から j 関節までの位置 \mathbf{r}_{ij} 、 j 関節反力 \mathbf{F}_j 、慣性テンソル \mathbf{J}_i を用いている。

(6)式の \mathbf{M}_R と \mathbf{M}_L は右脚、左脚に作用する外部モーメントを示す。

$$\mathbf{F}_{error} = \mathbf{F}_{ext} - (\mathbf{F}_R + \mathbf{F}_L) \quad (4)$$

$$\mathbf{M}_{ext} = \sum_{i=1}^n [\mathbf{J}_i \dot{\omega}_i + \omega_i \times (\mathbf{J}_i \omega_i)] - \sum_{i=1}^n \sum_{j=1}^{K_i} (\mathbf{r}_{ij} \times \mathbf{F}_j) \quad (5)$$

$$\mathbf{M}_{error} = \mathbf{M}_{ext} - (\mathbf{M}_R + \mathbf{M}_L) \quad (6)$$

さらに、生体内負荷の最適化では目的関数が最小となる変数を共役勾配法と呼ばれる数値計算法によって探索計算する。目的関数を(7)式に示す。 \mathbf{M}_{vir} は仮想関節モーメント、 \mathbf{F}_{vir} は仮想関節反力である。仮想関節は空間座標と身体座標の間に設けられ、仮想関節への負荷は $\mathbf{0}$ が理想的となるため最小化する。 $\alpha_1, \dots, \alpha_4$ は経験的に求めた係数である。

$$I = \alpha_1 \|\mathbf{M}_{vir}\|^2 + \alpha_2 \|\mathbf{M}_{error}\|^2 + \alpha_3 \|\mathbf{F}_{vir}\|^2 + \alpha_4 \|\mathbf{F}_{error}\|^2 \quad (7)$$

本研究では、データの平滑化の有無と $|v_z|, v_{xy}$ の

v_{thres} を変えた4種類の条件で床反力を推定した。床反力の推定条件をTable 1に示す。全ての条件で z_{thres} は 0.03m とした。平滑化においては、カットオフ周波数 10Hz のバターワースフィルタを用いて v_{thres} の0.2の推定後の床反力と作用点位置のデータを平滑化した。 $|v_z|,$

v_{xy} の v_{thres} は接地判別の精度の向上のために変更した。そして、生体内負荷が最小となる床反力や作用点位置の最適値を求めたが最適値が微細に変化しており、ヒトが床反力や作用点位置を精細に調節することは困難である。そのため、滑らかに最適値に向かうようにデータの平滑化処理を行った。

Table 1 Estimation condition of ground reaction force.

Estimation condition	v_{thres} [m/s]		z_{thres} [m]	Smoothing
	Vertical direction	Horizontal plane		
v_z only	0.05	OFF	0.03	OFF
v_{thres} 0.05	0.05	0.05	0.03	OFF
v_{thres} 0.2	0.2	0.2	0.03	OFF
Smoothing data	0.2	0.2	0.03	ON

4 推定方法の評価指標

4.1 絶対誤差

接地判別の精度を評価するために、計測値と推定値の踵接地、爪先離地時間の比較をFluitらの方法に基づいて行った⁴⁾。5Nの閾値を用いて鉛直方向の床反力から踵接地、爪先離地時間を求める。踵接地、爪先離地時間は計測結果と推定結果からそれぞれ得られる。得られた計測結果と推定結果の踵接地、爪先離地時間の絶対誤差を算出した。推定では踵接地、爪先離地時間を1歩行周期で複数回得ることがあった。その場合には、 0.1s 以上踵接地が続いた時間と次の爪先離地時間を用いることにした。

4.2 相関係数

計測値と推定値を比較するために、2種類のデータの類似度を定量化できるピアソンの積率相関係数 ρ

を算出した. 定義式を(8)式に示す. x_i , y_i は計測値と推定値, \bar{x} , \bar{y} は計測値, 推定値の平均値を示す.

$$\rho = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \quad (8)$$

4.3 平均平方 2 乗誤差

Ren らや Guo らの方法に従って, 平均平方 2 乗誤差 RMSE を算出した^{5,6)}. x_i は各変数の計測値, y_i は各変数の推定値, N は 1 歩行周期のデータ数として(9)式により床反力の RMSE を算出した. ここで, 床反力は前後, 左右, 鉛直方向で推定されているので各方向の RMSE を算出する.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - y_i)^2} \quad (9)$$

また, N を立脚期のデータ数として同様に前後, 左右方向の作用点位置の RMSE を算出した.

5 結果と考察

5.1 計測結果と推定結果

計測結果と 4 つの推定条件で推定した鉛直方向の床反力の推定結果を Fig. 2~Fig. 5 に示す. 縦軸は体重で正規化した鉛直方向の床反力, 横軸は時間であり右脚踵接地時間 0s を基準とした. また, 実線は計測値, 破線は推定値を示す. そして, 各グラフに示された 3 本の縦線は左から, 1 回目の右脚踵接地時間, 右脚爪先離地時間, 2 回目の右脚踵接地時間である.

計測結果では遊脚期に床反力が発生することはなかったが, v_z のみの推定結果では遊脚期に 1N/kg 以上の鉛直方向の床反力が発生した. 次に, v_{thres} 0.05 の推定結果については, 1 歩行周期間に床反力が 5N/kg 以上になってから 0N/kg になることが数回あったが, 計測結果では 1 回のみであった. そして, v_{thres} 0.2 では, v_z のみと v_{thres} 0.05 で発生した計測値と異なる現象はなかったが, 計測値と比べて床反力が小刻みに変化していた. しかし, データ平滑化では計測値と同様に滑らかに鉛直方向の床反力が変化した.

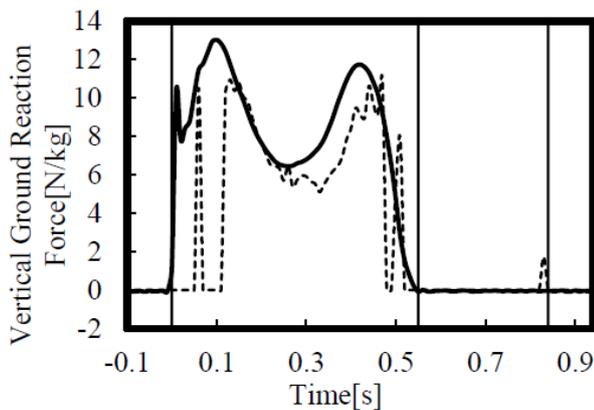


Fig. 2 Estimated result of vertical ground reaction force by v_z only and measurement result.

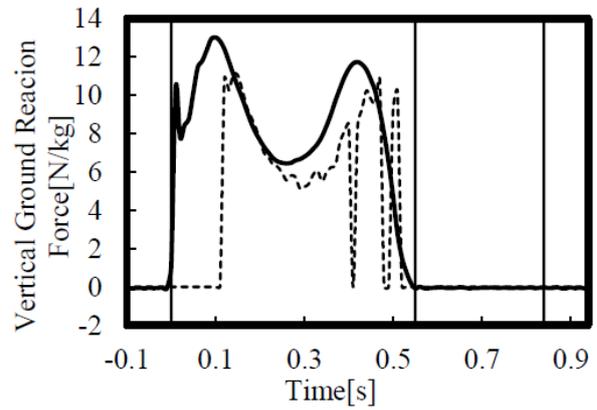


Fig. 3 Estimated result of vertical ground reaction force by v_{thres} 0.05 and measurement result.

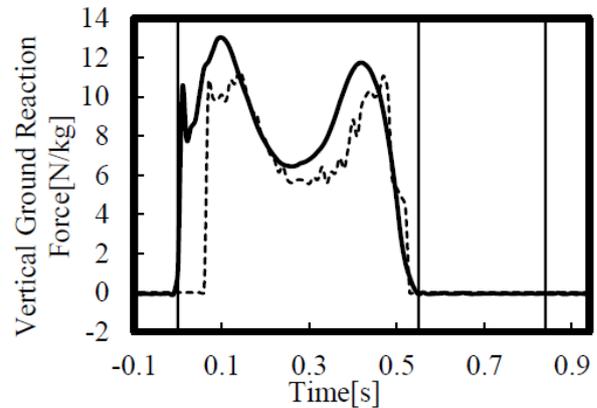


Fig. 4 Estimated result of vertical ground reaction force by v_{thres} 0.2 and measurement result.

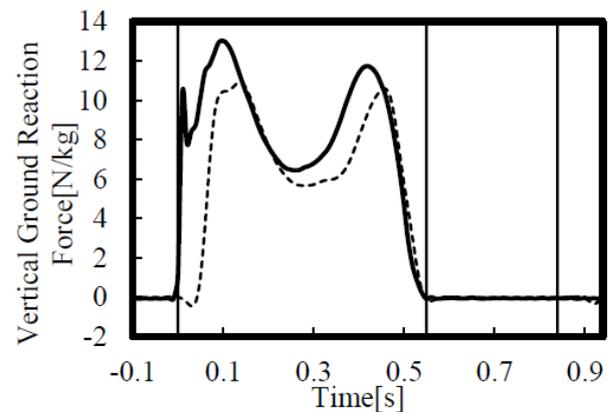


Fig. 5 Estimated result of vertical ground reaction force by smoothing data and measurement result.

5.2 評価指標の算出

Table 2 に踵接地時間と爪先離地時間の絶対誤差の平均値を示す. v_z のみ, v_{thres} 0.05 は踵接地時間で 0.1s, 爪先離地時間で 0.05s 以上の誤差があったが, v_{thres} 0.2 とデータ平滑化の誤差は半分以下となった.

次に, Table 3 に v_{thres} 0.2 とデータ平滑化の 1 歩行周期の相関係数と RMSE を示し, Table 4 に立脚期の作用点位置の相関係数と RMSE を示す. 評価関数は歩行速度別に算出し, 床反力は前後, 左右, 鉛直方向の値

を平均した。また、作用点位置は前後、左右方向で平均した。その結果、データ平滑化の RMSE は $v_{thres} 0.2$ よりも小さくなっていた。そして、データ平滑化の相関係数は $v_{thres} 0.2$ に比べて大きくなる傾向があった。加えて、データ平滑化の床反力の RMSE は体重の 10% 以下であり、相関係数は 0.7 以上で正の強い相関があった。しかし、作用点位置の相関係数は 0.3 以下であり無相関であった。

Table 2 Average of absolute errors of heel contact time and toe-off time.

Absolute error[s]	v_z only	$v_{thres} 0.05$	$v_{thres} 0.2$	Smoothing data
Heel contact time	0.117	0.110	0.0540	0.0540
Toe-off time	0.0507	0.0500	0.0240	0.0240

Table 3 Value of the evaluation function of the ground reaction force from the estimation method of $v_{thres} 0.2$ and smoothing data.

Gait speed	$v_{thres} 0.2$			Smoothing data		
	nw	fw	sw	nw	fw	sw
RMSE[N/kg]	0.628	0.594	0.473	0.615	0.565	0.451
Correlation coefficient [-]	0.690	0.697	0.698	0.702	0.723	0.717

Table 4 Value of the evaluation function of the action point position from the estimation method of $v_{thres} 0.2$ and smoothing data.

Gait speed	$v_{thres} 0.2$			Smoothing data		
	nw	fw	sw	nw	fw	sw
RMSE[m]	0.0553	0.0648	0.0550	0.0546	0.0641	0.0546
Correlation coefficient [-]	0.141	0.252	0.175	0.164	0.244	0.186

5.3 考察

v_z のみと $v_{thres} 0.05$ は結果より接地判別の精度が低いと考えられる。そこで、 v_{xy} を加えて v_{thres} は 0.2 m/s に変更し、接地判別の精度を改善することができた。次に、 $v_{thres} 0.2$ の結果は微細に変化したが計測値では滑らかに変化した。そのため、ヒトが床反力や作用点位置を精細に調節できず、最適値に向かうようにそれらを調節していると仮定し、最も接地判別の精度が良かった $v_{thres} 0.2$ を平滑化処理した。データ平滑化は $v_{thres} 0.2$ と比べて RMSE は小さく、相関係数は大きくなる傾向であり、床反力の推定精度を改善できた。

Fig. 6 に v_z のみとデータ平滑化の RMSE と歩行速度の関係を示す。RMSE は前後、左右、鉛直方向の和を示す。破線はデータ平滑化の近似線、実線は v_z のみの

近似線である。 v_z のみは歩行速度が速いと RMSE が大きくなる傾向であったがデータ平滑化ではその傾向を抑制できた。

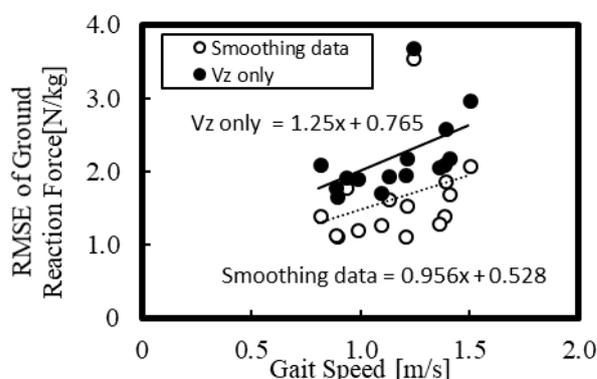


Fig. 6 Relationship between RMSE of v_z only, smoothing data and gait speed.

6 結言

本研究では、4種類の条件下における床反力の推定方法について検討した。それらにおいて脚の踵、爪先の鉛直方向と水平面の速度0.2m/s、高さ0.03mと設定した閾値を用いて接地判別を行い、データの平滑化を行った床反力推定の結果が精度的に最も優れていた。また、評価指標の値から床反力は体重の10%以下の誤差が生じる精度で推定でき、歩行速度による影響を減らすことができた。

参考文献

- 1) 持丸正明：身体の運動計測技術の動向，計測と制御，**36-9**, 609/614 (1997)
- 2) Land, W. M., Volchenkov, D., Blasing, E. B. and Schack, T. : From action representation to action execution: exploring the links between cognitive and biomechanical levels of motor control, *Frontiers in Computational Neuroscience*, **7-127**, 1/14 (2013)
- 3) Karatsidis, A., Bellusci, G., Schepers, M. H., Zee, D. M., Andersen S. M. and Veltink, H. P. : Estimation of ground reaction forces and moments during gait using only inertial motion capture, *Sensors*, **17-1** (2016), DOI: 10.3390/s17010075
- 4) Fluit, R., Andersen, S. M., Kolk, S., Verdonchot, N. and Koopman, M. J. F. H. : Prediction of ground reaction forces and moments during various activities of daily living, *Journal of Biomechanics*, **47-10**, 2321/2329 (2014)
- 5) Ren, L., Jones, K. R. and Howard, D. : Whole body inverse dynamics over a complete gait cycle based only on measured kinematics, *Journal of Biomechanics*, **41-12**, 2750/2759 (2008)
- 6) Guo, Y., Storm, F., Zhao, Y., Billings, A. S., Pavic, A., Mazza, C. and Guo, Ling-Zhong. : A New Proxy Measurement Algorithm with Application to the Estimation of Vertical Ground Reaction Forces Using Wearable Sensors, *Sensors*, **17-10** (2017), DOI: 10.3390/s17102181

V-型 ROV の複眼ビジュアルサーボシステムの構築

Development of Dual-eyes Visual Servoing Control System for V-shaped Thruster Vehicle

学	○許 弘毅 (岡山大)	非	Myint Myo (Thanlyin Technological University)
学	中村 翔 (岡山大)	学	神田 佳希 (岡山大)
学	Lwin Khin New (岡山大)	正	松野 隆幸 (岡山大)
正	戸田 雄一郎 (岡山大)	正	見浪 護 (岡山大)

Horng Yi HSU, Okayama University, pcvv4h2h@s.okayama-u.ac.jp
Myo MYINT, Thanlyin Technological University
Sho NAKAMURA, Okayama University
Yosiki KANDA, Okayama University
Khin New LWIN, Okayama University
Takayuki MATSUNO, Okayama University
Yuichiro TODA, Okayama University
Mamoru MINAMI, Okayama University

Nowadays, a variety of robots has been studied and developed for undersea exploration. It is necessary for the robot to work long time in water in order to efficiently perform given tasks. We proposed a system to make the robot able to come back power supply unit and automatically charge battery under water. We confirmed ROV(Remotely Operated Vehicle) have conducted docking that assumes charging battery under water by the system, having shown it effective. As a next step, we tried docking that the system could apply for new ROV. Then, we constructed a new control system using Jacobian that shows relationship voltage and velocity. After we confirmed the system is effective, docking experiment in the sea have been conducted. In this report, the structure and result of experiments are reported in detail.

Key Words: Dual-eyes, Remotely Operated Vehicle, Visual Servoing

1 緒言

近年、海底探索等のために様々な水中ロボットの研究・開発が行われている。効率的にこれらの作業を行うためにはロボットが水中で長時間活動できることが必要不可欠である。私たちはロボットの作業時間延長のため、ロボットに搭載したカメラによって給電設備を認識し自動で嵌合を行い充電するシステムを提案した。提案システムを用いて実海域において給電設備への充電を想定した嵌合制御が行えることを確認し、提案システムが有効であることを示した。次の段階として、そのシステムを別のロボットに適用し、運用可能か確認を行っている。提案システムを適用する新しい水中ロボット (DELTA-150) の制御系を構築した後、実海域での嵌合実験を行った。本論文では、DELTA-150 による実海域での嵌合実験について記述する。

2 ROV(Remotely Operated Vehicle)

本研究では QI 製 ROV(DELTA-150) に新しく提案システムを適用できるかを検証する。まず、DELTA-150 について説明する。Fig. 1 に DELTA-150 を示す。座標系は Fig. 1 に示すとおりに定義している。スラスタは前後方向および z_H 軸回転用に 2 つ、上下・左右用に 2 つ搭載されている。上下・左右用のスラスタには整流板が付けられており、この角度を調整することにより上下・左右への推力バランスを決定する。また、 y 軸方向に移動するときに発生する x 軸回転をなくすためにダンパが付けられている。ロボットは 20[kg] で、横幅 450[mm]、奥行き 600[mm]、高さ 395[mm] であり最大水深 50[m] に対応している。なお、ロボットの大きさはそれぞれの長さの最大をロボットの長さとしている。

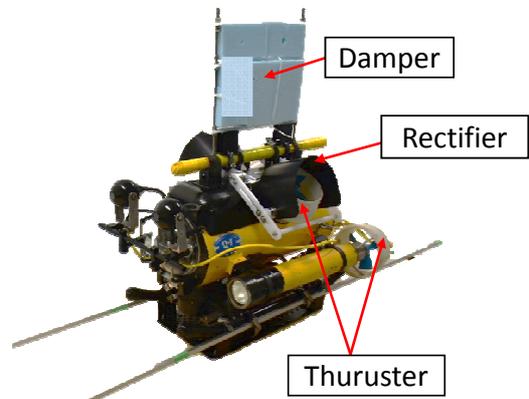


Fig.1 Overview of DELTA-150

3 3次元位置・姿勢認識

ロボット前方に搭載された 2 基の固定カメラから取得した画像情報をもとに対象物の 3 次元位置・姿勢認識を行う。提案する制御系のブロック図を Fig.2 に示す。提案するシステムでは、両眼カメラから取得した画像を PC に転送し、Real-Time Multi-Step GA と Model-based Matching 法 [1] を組み合わせて対象物との相対的位置・姿勢を認識している。本報告における Real-Time Multi-Step GA と 1-Step GA[2] は、まったく同様の手法である。

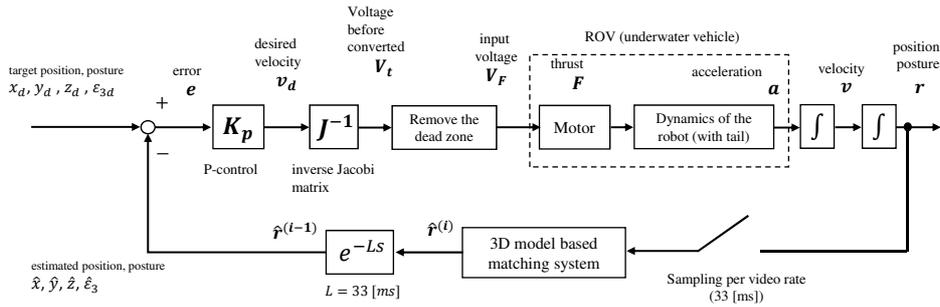


Fig.2 Block diagram for DELTA-150

一般的に、GA（遺伝的アルゴリズム）を用いた最適解探索では、GA が最適解を決定する際ある程度の時間を要するため、最適解が得られた時には周囲の環境が大きく変化している可能性が高い。そこで本研究では、Real-Time Multi-Step GA を採用した。Real-Time Multi-Step GA とは、入力された画像に対し、ビデオレート（33[ms]）で次の画像が入力されるまでの間だけ GA 遺伝子の進化を進め、その時点で最大適合度を与える遺伝子情報を最新の対象物の位置・姿勢として出力する方法で、これにより実時間での認識を可能としている。また、このとき評価に使用する適合度とは、Model-based Matching 法で定義される対象物とモデルとの一致度合いを示す適合度関数から得られる値である。これにより、提案システムでは対象物の 3次元位置・姿勢の実時間認識を可能としている。

4 ビジュアルサーボコントローラ

3章の認識手法による認識結果から、水中ロボットに搭載した4つのチャンネルへ指令電圧を送ることで、水中ロボットと対象物間で以下の相対的目標位置・姿勢 (x_d [mm], y_d [mm], z_d [mm], ϵ_{3d}) を保つようにビジュアルサーボを行う。なお ϵ_{3d} はクォータニオン姿勢表現による値を用いており、単位を持たない。本報告における座標系は Fig.1 に示している。

また、 x [mm], y [mm], z [mm], ϵ_3 を GA で認識した、ロボットから見た対象物の位置・姿勢とおき、その相対的目標位置・姿勢に水中ロボットを移動させるため、以下の P 制御から計算される指令電圧 [V] を各チャンネルへ与える。式 (1) の逆ヤコビ行列は実際に DELTA-150 に電圧を加え動作させ、速度計測を行い、求めたものである。

$$\begin{bmatrix} V_{\epsilon_3} \\ V_x \\ V_y \\ V_z \end{bmatrix} = J^{-1} K_P \begin{bmatrix} \epsilon_{3d} - \epsilon_3 \\ x_d - x \\ y_d - y \\ z_d - z \end{bmatrix} \quad (1)$$

x 軸および y 軸まわりの姿勢に関しては、ロボットの移動によらず微小であるため、制御の対象として扱わない。

5 実海域での嵌合実験

実海域で嵌合実験を行った。1月16日15時41分から19回連続嵌合に成功し、17時38分から10回連続嵌合成功した。15時41分から19回連続嵌合を昼間の嵌合実験とし、17時38分から10回連続での嵌合実験を夜間の嵌合実験として結果を述べる。Table 1 に実験時の環境を示す。昼間も夜間も濁度が約 2[FTU:Formazin Turbidity Unit] であり、以前実海域で行ったときに比べ低かった。実海域での嵌合実験のフローチャートを Fig. 3 に示し、Fig. 4 に実際の嵌合時の様子、Fig. 5 に実験時の様子を示す。嵌合実験は Fig. 3 中の (a)Visual servoing, (b)Docking step, (c)Stay step, (d) Launching step を繰り返す

すことによって行われている。まず、嵌合実験のフローチャートについて説明する。DELTA-150 の前方に搭載された複眼カメラに対象物が映し出されるまで、ロボットを手動操作で対象物に接近させる。ロボットを対象物にある程度接近させ、適合度の値が 0.2 以上に上昇したことが確認された後、手動操作から自動制御へ切り替えることで Visual servoing 状態へ移行させる。

(a)Visual servoing

ROV が対象物を発見し、目標とする相対的位置・姿勢に追従することで対象物と正対する状態である。ROV が対象物の正面に移動し、一定時間留まることで Docking step へ移行する。

(b)Docking step

ROV が前進して嵌合動作を行なっている状態である。認識値がある条件を満たすとき、奥行き方向の目標値を時変で減少させることで ROV が x 軸方向に前進し嵌合穴に嵌合する。 x_d が最終値 350 mm となることで嵌合を完了する位置に ROV が移動し、Stay step へ移行する。ただし途中で嵌合の条件 (y 軸, z 軸方向の誤差が ± 40 mm 以下) を満たさなくなった場合、その時点での x 軸方向の時変目標値を固定して再び Visual servoing に戻る。

(c)Stay step

嵌合が完了した状態である。嵌合棒を嵌合穴へ押し付け、ロボットを停滞させデータを保存する。その後、Launching step へ移行する。

(d) Launching step

嵌合が終了した後、連続嵌合を行うために対象物に対して、後退している状態である。その後、 $x_d=600$ [mm] になったところで Visual Servoing に移行する。

Fig. 6 に昼間と夜間の嵌合実験のデータとそのときの DELTA-150 からの画像を示す。グラフはそれぞれ 4 回目に嵌合を行ったときの DELTA-150 の前進方向における認識値を示している。DELTA-150 からの画像に映っている赤、青、緑の 3 色の球体を搭載している物を対象物としてビジュアルサーボを行っている。グラフより Visual servoing 状態から Docking step へ移行後、Stay step へと条件を満たしながら、移行していることが確認できる。そのため、実海域で嵌合は行えていると判断した。

Table 1 Environment of experiment in day time and night time

	day	night
Turbidity[FTU]	1.92	2.2
Depth[m]	1.9	2.8
Illumination(surface)[lx]	25000	0
Illumination(in water)[lx]	7300	0

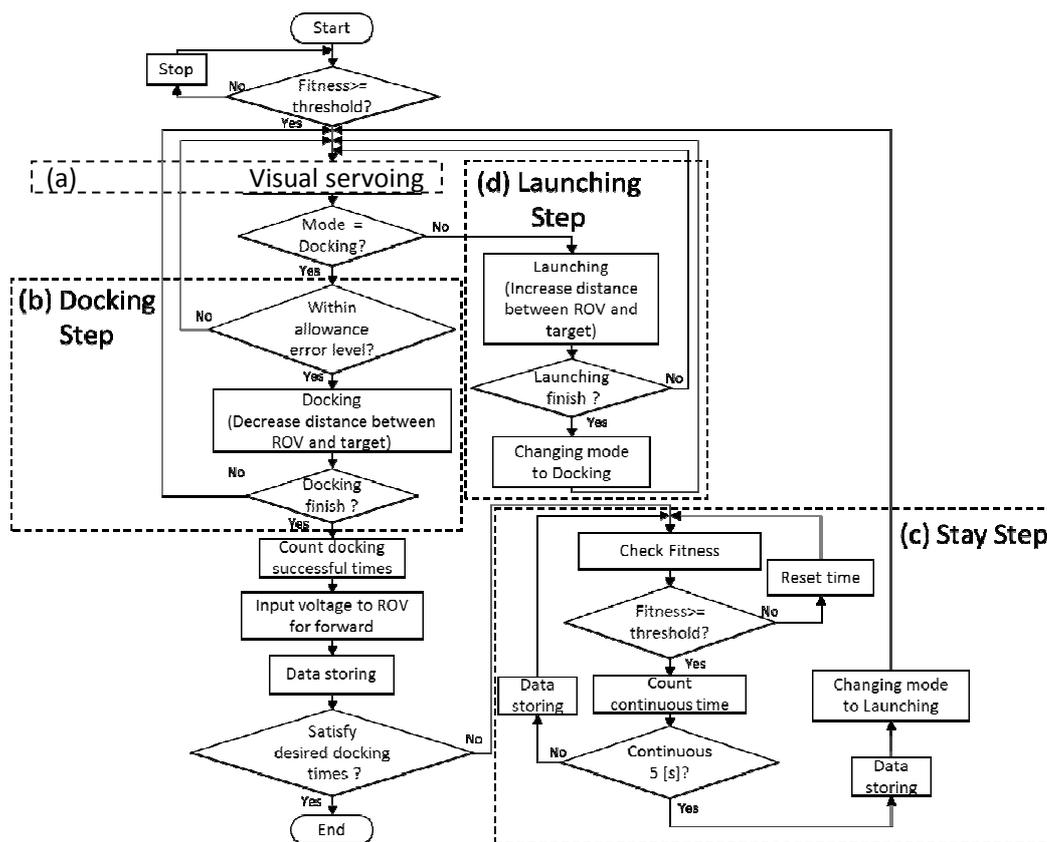


Fig.3 Flowchart of docking experiment

6 結言

本論文では、我々が提案したロボットに搭載した複眼カメラによって給電設備を認識し、自動で嵌合を行い充電するシステムを別のロボットである DELTA-150 に適用した。そして、DELTA-150 を用いて嵌合実験を行い、嵌合可能であることを確認した。今後、制御用コンピュータとバッテリーを搭載し、完全自立型の中水ロボット (AUV) の製作を行い、このシステムによる嵌合実験の成功を目指す。

謝辞

本研究では三井株式会社の協力を得ました。ここに謝意を表します。

References

- [1] 大西祥太, 須浪唯介, 西村健太, 矢納陽, 石山新太郎, 見浪護 (岡山大), 藤本勝樹 (広和 (株))” MOS 制御知能を搭載した遠隔操作型水中ロボット (ROV) の自律制御化 (AUV) 技術”, 第 57 回自動制御連合講演会, 1B08-2, 2014.
- [2] 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, pp 127-139, 2007.
- [3] 西村健太, 候森, 前田耕市, 見浪護, 矢納陽, ビジュアルサーボ中の実時間ポーズトラッキング性能の解析, ロボティクス・メカトロニクス講演会 2013, 2013.

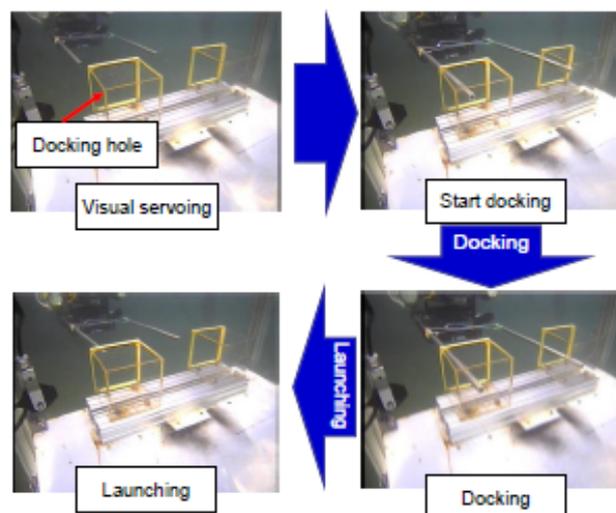


Fig.4 Appearance of docking

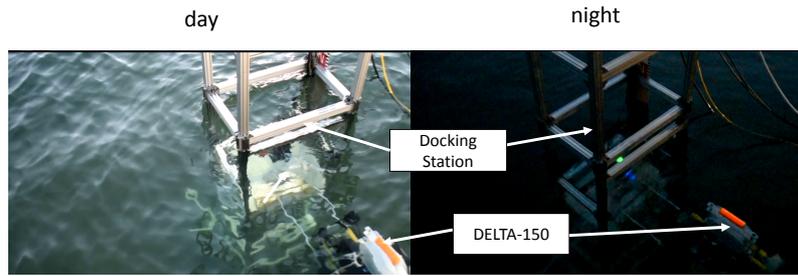


Fig.5 Appearance of docking experient in day time and night time

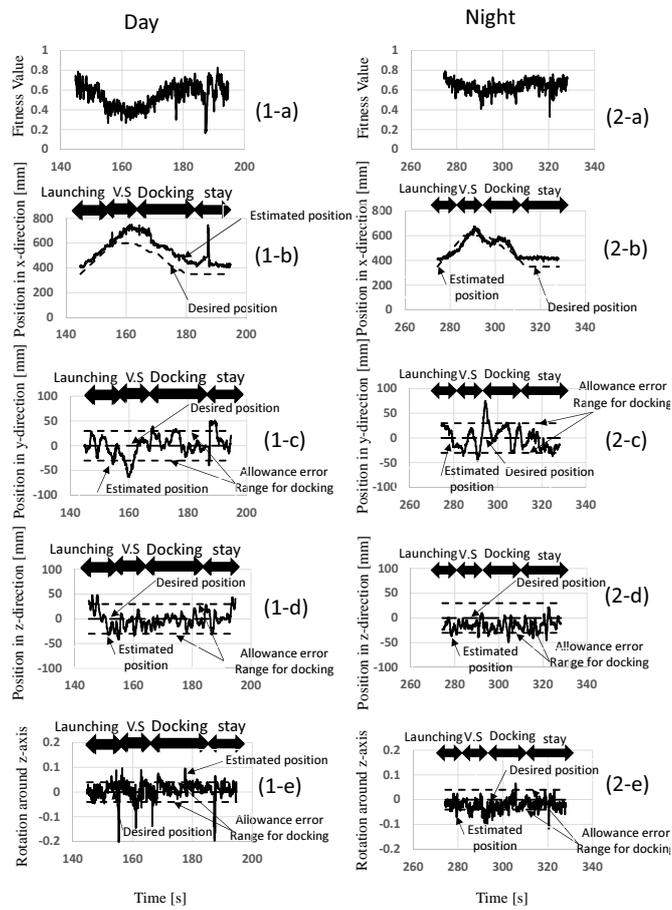


Fig.6 Recognized position in x direction for docking experiment in day time. picture is left and right camera images taken at the times labeled A1,A2,and A3 in the time profiles