

15th SICE Symposium on Computational Intelligence

June 29-30, 2019, Kanagawa

第 15 回コンピューターショナル・インテリジェンス研究会

講演論文集

期 日：2019 年 6 月 29 日(土)，30 日(日)

会 場：慶應義塾大学 矢上キャンパス

**SICE**<sup>®</sup>

主 催：計測自動制御学会 システム・情報部門

企 画：コンピューターショナル・インテリジェンス部会，知能工学部会

協 賛：システム制御情報学会，日本知能情報ファジィ学会，進化計算学会，電気学会，  
情報処理学会，日本神経回路学会，日本機械学会，人工知能学会，ヒューマ  
ンインタフェース学会，電子情報通信学会，IEEE Computational Intelligence  
Society Japan Chapter (CISJ)，IEEE Systems, Man, and Cybernetics Society Japan  
Chapter

カタログ番号 19PG0006

著作権 © 2019

公益社団法人計測自動制御学会(SICE)  
〒101-0052 東京都千代田区神田小川町 1-11-9 金子ビル 4 階

カタログ番号 19PG0006

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

発行日：2019年6月29日

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

## 第 15 回コンピューテーショナル・インテリジェンス研究会プログラム

6月29日(土)

13:30~15:10 (4 件) 司会 黒江 康明 (関西大学, 京都工芸繊維大学)

- 1 強化学習に基づく群行動制御モデルの構成 1  
○磯川 梯次郎, 上山 晃弘, 松井 伸之, 湯本 高行, 上浦 尚武 (兵庫県立大学)
- 2 大脳新皮質学習における異なる時系列データの複合予測に関する基礎検討 5  
○長島 晶彦, 青木 健, 高玉 圭樹, 佐藤 寛之 (電気通信大学)
- 3 AffectNet: 顔表情データベースの構造適応型 DBN による感情モデルの KL 情報量を用いた精度向上 13  
○鎌田真, 市村匠 (県立広島大学, 地域基盤研究機構)
- 4 様々な発火パターンを実現する Particle Swarm Optimization によるリカレントスパイクニューラルネットワークの学習法 19  
○黒江 康明 (関西大学, 京都工芸繊維大学), 飯間 等 (京都工芸繊維大学), 前田 裕 (関西大学)

15:20~16:20 (3 件) 司会 深井 寛修 (株式会社明電舎)

- 5 温熱環境が心的要因と作業効率に及ぼす影響の評価 27  
○堀田 健斗, 満倉 靖恵 (慶應義塾大学), 古橋 拓也, 折戸 真里, 伏江 遼 (三菱電機株式会社)
- 6 衣類型導電性繊維を用いた動作に頑健な心拍推定手法の提案 31  
○増山 義輝, 満倉 靖恵 (慶應義塾大学)
- 7 長時間連続計測によるステロイドホルモン投与マウスの終夜行動解析 35  
○葛西 凜々子, 吉田 慶多朗, 田中 謙二, 満倉 靖恵 (慶應義塾大学)

16:30~17:30 Invitation to Computational Intelligence Fons Scientiae Project

6月30日(日)

10:00~11:20 (3件) 司会 満倉 靖恵 (慶應義塾大学)

- 8 対象物の事前知識を必要としないステレオビジョン空間認識を用いたビジュアルサーボ 39  
○山本 太郎, 王 俊祥, 汪 魯傑, 寇 ギョウ郡, 田 宏志, 李 想, 戸田 雄一郎, 見浪 護 (岡山大学)
- 9 連続カオスシステムにおける外部フィードバック信号によるカオス共鳴制御の検討 46  
○信川 創, 柴田 夏作 (千葉工業大学), 道法 浩孝 (高知大学), 西村 治彦 (兵庫県立大学), 山西 輝也 (福井工業大学)
- 10 自律走行ロボットによる照度計測の自動化 50  
新井 智之, ○荒川 俊哉, 井上 椋太 (首都大学東京), 辻元 誠, 谷口 和彦 (株式会社きんでん), 久保田 直行 (首都大学東京)

13:00~14:20 (4件) 司会 畠中 利治 (大阪大学)

- 11 局地的大雨の危険性提示方法提案のための脳波解析・雨音特徴量抽出 54  
○佐藤 慧一, 満倉 靖恵 (慶應義塾大学), 中島 広子 (国立研究開発法人防災科学技術研究所), 島崎 敢 (名古屋大学)
- 12 オリーブオイルのストレス緩和効果および嗜好性と月経周期の関連性評価 58  
○奈良 莉紗, 満倉 靖恵, 浜田 望 (慶應義塾大学)
- 13 聴覚性ブレイン・コンピュータインタフェースにおける学習データ削減手法の検討 62  
○荻野 幹人 (株式会社電通サイエンスジャム), 満倉 靖恵 (慶應義塾大学)
- 14 マウスの脳波および筋電図を用いたセロトニン神経活動推定 66  
○大橋 孝裕, 吉田 慶多朗, 満倉 靖恵, 田中 謙二 (慶應義塾大学)

# 強化学習に基づく群行動制御モデルの構成

○磯川悌次郎 上山晃弘 松井伸之 湯本高行 上浦尚武 (兵庫県立大学)

## A Sheepdog Model with Reinforcement Learning Scheme

\*T. Isokawa, A. Ueyama, N. Matsui, T. Yumoto, and N. Kamiura (University of Hyogo)

**Abstract**— A sheepdog agent model based on reinforcement learning is presented, where small number of sheepdog agents autonomously lead a group of sheep agents to a cerin location. The performance of the presented model is evaluated through computer experiments for leading sheep agents with and without several obstacles, with compared to a rule-based agent model.

**Key Words:** Sheepdog, Cooperative behavior, Reinforcement learning, Q-Learning

### 1 はじめに

近年, ネットワークやインフラなどの制御システムの複雑化により, 自律分散システムやマルチエージェントシステムを用いた研究, 産業応用が注目されている. これらを用いることにより, 今まで不可能であった大規模シミュレーションや, 広域でのシステム制御が必要なセンサネットワークなどに応用が期待されている<sup>1)</sup>.

しかし複数のエージェントを同時に行動させるためのシステム構築は非常に複雑である. このようなシステム構築を行うための一方法として, 自然界の現象を模倣することによって効率の良いシステムを自律的に構成することが検討されている. その一つとして, 魚や鳥などが行う群行動は統率個体を持つことなく群れを形成することができるため, 一種の自律分散システムとし考えることができる. 群行動を再現する数理モデルとしては birdoid<sup>2)</sup>, 青木の魚群モデル<sup>3)</sup> などが提案されており, 環境適応性を持つ群形成モデルとして, 強化学習を用いた森廣らのモデル<sup>4, 5)</sup> も提案されている.

一方, 多数の個体が一つの目的に対して群行動を行うシステムに対して, 少数の統率個体が多数の群行動個体を制御するシステムについてはそれほど多くの検討はなされていない. 統率個体を導入することによって, 多数の局地的な群行動のみを行う個体と群れを制御する個体を用いて, 群れ全体で効率的に目的を達成させることができる. このようなシステムは羊の群れと牧羊犬の行動を模倣することによりモデル化が可能である<sup>6)</sup>. 文献<sup>7)</sup>では, 羊と牧羊犬の行動規則を定義することにより, 牧羊犬モデルが羊モデルの群れを集めて誘導させることが可能であることも示されている. しかし上記の牧羊犬制御モデルではオープンスペース環境に羊モデルと牧羊犬モデルを配置しており, 障害物の存在する環境は想定されていない. そのため障害物を設置した環境に対しての検証と環境の変化に柔軟に対応できるモデルの提案が必要である.

本研究では多数の羊モデルを少数の牧羊犬モデルが誘導を行う牧羊犬問題に対して, 環境の変化に対応するために強化学習を用いた牧羊犬モデルを提案する. 強化学習を用いることにより環境の変化に対して適応するための学習を行うことができ, 適切な牧羊犬制御が可能になると考えられる. 牧羊犬モデルが目標点まで

羊モデルの群れを誘導するシミュレーションを行い目標点到達までの時間を測定することによって, 既存の規則ベースの牧羊犬モデルと強化学習を用いた牧羊犬モデルの性能や特性を比較する. また障害物が存在する場合や複数の牧羊犬モデルが存在し協調動作を行わせる場合においても, 規則型と学習型の群制御の性能比較を行う.

### 2 羊の群れモデル

生物が群れを形成する理由はその生物の生態によって異なっている. Hamilton が提唱している利己的集合仮説<sup>8)</sup>では多数の個体が群れを作ることによって捕食者からの危険性を減らすことができるとしている. 利己的集合とは, 自身の身を捕食者から守るため群れを形成し捕食される確率を減らす行動のことである. 群れを形成することで周囲への監視頻度を増加させ監視範囲を広げることができる. また, 個々の監視タイミングをずらすことで一個体の負担を減らすこともできる. 利己的集合による行動は羊にも見られ, 牧羊犬から逃げられる場合には羊の群れの中心に逃げ込むように移動する. これにより羊は群れを形成し, 群れ全体が牧羊犬から離れるように移動する. 本研究では文献<sup>7)</sup>に基づき, 以下に示す規則を羊モデルに定める.

- 他の羊に衝突しないように回避し, 群れから離れた場合には群れの中心方向へ移動する
- 牧羊犬が近づいた場合には牧羊犬から離れつつ羊の群れの中心方向へ向かう
- 障害物に衝突しないように回避する

以上の各規則に基づき移動方向ベクトルを計算し, これらを合成することにより最終的な移動方向を決定する.

図1は牧羊犬モデルが接近してきた場合の羊モデルの移動方向を示す. 牧羊犬モデルが一定距離  $r_s$  に近づいた場合, 牧羊犬モデルから離れる方向ベクトル  $R^s$  を決定する. 次に対象の羊モデルが観測できる範囲  $r_a$  の群れの重心位置 LCM を測定し, 重心方向への方向ベクトル  $C$  を決定する. また他の羊モデルとの衝突を回避するための方向ベクトル  $R^a$  も決定する. 以上の方向ベクトル  $R^s, C, R^a$  を合成して最終的な移動方向を決定する. ただし羊モデルには他の羊モデルの位置, 牧羊犬モデルの位置, 障害物の位置は取得できるが, 目標

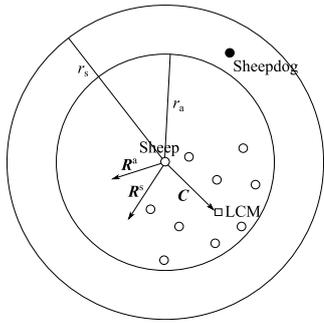


Fig. 1: Preceptible ranges for sheep agents

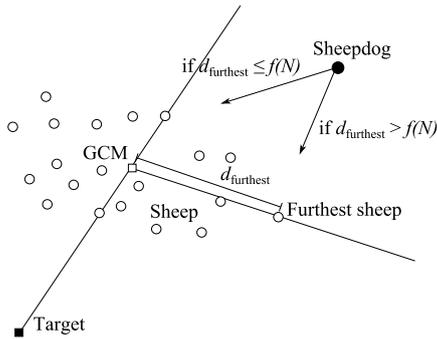


Fig. 2: Preceptible ranges and actions for sheepdog agent

点に関する情報は取得できない。そのため目標点に移動するためには牧羊犬モデルによる誘導が必要となる。

### 3 牧羊犬モデル

#### 3.1 規則型牧羊犬モデル

羊モデルの群れを目標点まで誘導する牧羊犬の行動をモデル化する。牧羊犬モデルの行動に関しては羊モデルと同様に Strömbom ら<sup>7)</sup>により示されている。羊の群れを制御する牧羊犬の行動は大きく分けて以下の2つの規則にわけることができる。

- 羊の群れが広がっている場合には群れを集める行動をとる
- 羊の群れが集まっている場合には群れを目標点に誘導するように行動する

以上の規則を持った牧羊犬モデルを実現するための行動方法を図2に示す。牧羊犬モデルは羊モデルの群れの重心 GCM から最も離れている羊モデル Further sheep を観測する。羊モデル Further sheep と羊モデルの群れの重心の距離  $d_{further}$  が一定以上離れている場合 ( $d_{further} > f(N)$ )、牧羊犬モデルは群れを集めるために羊モデル Further sheep に向かって移動する。羊モデル Further sheep の距離が一定以下の場合 ( $d_{further} \leq f(N)$ )、牧羊犬モデルは目標点から群れの重心方向に最も離れた羊モデルに向かって移動する。その結果、羊モデルの群れ全体を目標点に誘導させることができる。このとき牧羊犬モデルが群れを集めるか誘導するかの行動を切り替える判断距離  $f(N)$  は、羊モデルの群れの個体数  $N$  によって調整される。また障害物に対しては羊モデルと同様に衝突しないよう回避する行動をとる。

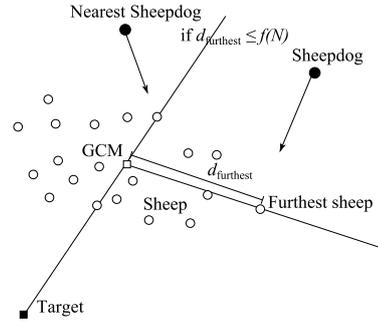


Fig. 3: Preceptible ranges and actions for multiple sheep agents

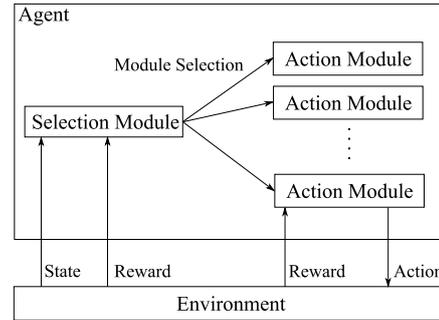


Fig. 4: A framework for selective learning machines

他に牧羊犬モデルが存在する場合には群れを集める行動と群れを誘導する行動を分担して行う。目標点から群れの重心方向に最も離れた羊モデルに近い牧羊犬モデル (Nearest sheepdog) が群れの誘導を行う (図3)。それ以外の牧羊犬モデルは群れを集める行動を行うため、群れの重心から最も離れている羊モデル Further sheep へ移動する。これにより牧羊犬モデルは役割を分担することで群れ制御の効率を上げることができる。

#### 3.2 学習型牧羊犬モデル

文献<sup>7)</sup>において示されている牧羊犬制御モデルは牧羊犬と羊のみが設置されたオープンスペース環境において実験されているが、現実には障害物等による環境の変化が想定される。規則ベースの牧羊犬モデルでは障害物の設置による環境の変化に対する適応が十分に行えないと考えられる。そのため強化学習を用いた牧羊犬モデルによって、牧羊犬の行動と環境の変化に対応した行動を学習させる。牧羊犬モデルの学習には Q-learning<sup>9)</sup>を用いる。

本研究では羊モデルの群れと障害物に対する行動を学習するため、必要となる環境情報が増加している。環境が複雑になることによって一つの行動選択学習器のみでは適切な行動を行えない可能性がある。そのため図4に示すような、取得した環境から適切なモジュールを選択するように学習を行う環境選択モジュールと、選択された状態に対する行動選択を学習する行動選択モジュールに分離する。取得した状態から環境選択モジュールが適切な行動選択モジュールを選択することで、羊モデルの群れと障害物が存在している環境においても適切な学習が行えるようになると思われる。牧羊犬モデルの状態および行動選択によって環境から報酬が与えられる。

学習型牧羊犬モデルは自身の認識する対象によって環境を設定している。牧羊犬モデルは認識範囲に障害

物、羊モデル、他の牧羊犬モデルが存在している場合の組み合わせによって環境を定め、適切な行動選択を行うモジュールを選択する。障害物に対しては回避行動を行い、羊モデルに対しては群れの広がりによって集める行動か誘導する行動を行う。他の牧羊犬が存在する場合には、規則型と同様に群れ制御の役割を分担することで協調動作を行うように学習させる。

例として1体の学習型牧羊犬モデルと羊モデルの群れが存在している場合に、牧羊犬モデルの環境選択モジュールが羊モデルの群れに対して行動を行わせるよう行動選択モジュールを選択した場合を想定する。羊モデルの群れに対する行動選択モジュールを選択された牧羊犬モデルは群れから最も離れた個体と群れの重心までの距離  $d_{\text{further}}$  によって状態を定義する。 $d_{\text{further}}$  が一定以上離れている場合、群れの重心から最も離れた羊モデルを行動対象個体とする。群れが一定以下の距離に集まっている場合には、目標点から群れの重心方向へ最も離れた羊モデルを行動対象個体とする。牧羊犬モデルは行動対象個体に対して

- $a_0$  : 対象個体に近づく行動
- $a_1$  : 対象個体と並進する行動
- $a_2$  : 対象個体から離れる行動

の三通りの行動を定義し行動選択モジュールの学習を行う。羊の群れの広がり  $d_{\text{further}}$  が一定以上離れている場合には、牧羊犬モデルは群れを集める行動を行わせるように報酬を設定する。一方  $d_{\text{further}}$  が一定以下の距離になっている場合には、牧羊犬モデルが群れを誘導する行動を選択するように報酬を設定する。これにより羊モデルの群れに対する行動を行う牧羊犬モデルは、群れを集めて目的地へと誘導させるように学習することができる。障害物や他の牧羊犬モデルに対しては衝突を回避する行動を選択するように報酬を設定する。

## 4 計算機実験によるモデルの評価

### 4.1 評価方法

規則ベース牧羊犬モデルと強化学習を用いた牧羊犬モデルの牧羊犬制御を比較する。各牧羊犬モデル、羊モデルの大きさを1(Body Length : BL)と定義し、その個体の存在する環境として高さ2048(BL)、幅2048(BL)の平面上を用いた。目標点を平面上の右下に設置し、羊モデルは平面上の中央付近にランダムに配置し、牧羊犬モデルは目標点と同じ場所に配置した。各牧羊犬モデルは羊モデルを10体から150体を10体ずつ増加させたときそれぞれに対して100回誘導を行う。牧羊犬モデルが羊モデルの群れを目標点まで誘導し、群れの重心が目標点に到達するまでの時間を計測した。ただし誘導時間が20000stepを超えた場合には誘導失敗とみなす。また同様の条件で障害物を設置した場合のシミュレーションを行った。

### 4.2 結果

図5に障害物が無い環境における規則型と学習型の牧羊犬モデルが羊モデルの群れを誘導した平均時間と、最小誘導時間を示す。図より強化学習を用いた学習型の牧羊犬モデルは規則型の牧羊犬モデルと比較して、羊モデルの個体数が少ない場合に平均時間が増加している。これは十分に学習を行っていない学習型の牧羊犬モデルが、群れの誘導を適切に行えていないためだといえる。しかし図5より羊モデルの個体数を増加させ

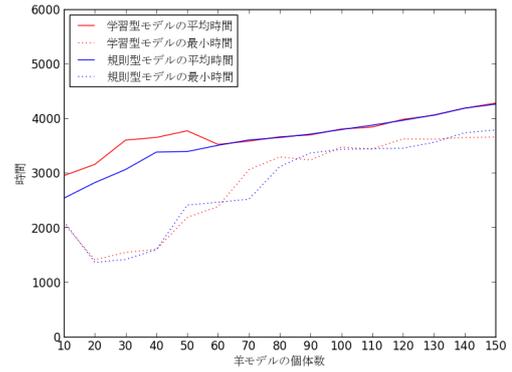


Fig. 5: Average and minimum iterations for rule-based and learning-based models

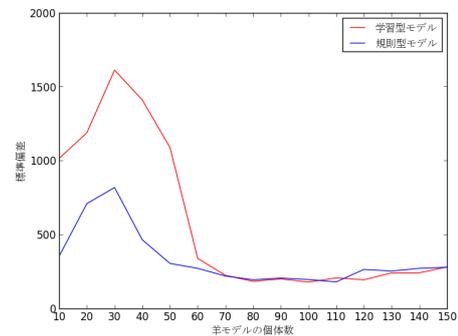


Fig. 6: Standard deviations of iterations for rule-based and learning-based models

ていくことにより、学習型の牧羊犬モデルも規則型の牧羊犬モデルと同等の時間で誘導を行えることも示されている。点線で示した最小誘導時間に関しても規則ベース、学習ベース共に羊モデルの個体数が増加するに従って平均誘導時間に近づいている。図6には規則ベースと学習型の牧羊犬モデルの誘導時間の標準偏差を示している。羊モデルの個体数が少ない場合には規則型の牧羊犬モデルが学習型よりも低い値を示しているが、羊モデルの個体数が増加するに従ってほぼ等しい値を示している。よって強化学習を用いた学習ベースの牧羊犬モデルは既存の規則ベースの牧羊犬モデルとほぼ同等の群れの誘導性能を有しているといえる。

障害物が設置された環境において学習ベースの牧羊犬モデルと羊モデルの群れのシミュレーション結果を図7に示す。牧羊犬モデルが羊モデルの群れに接近後、群れの広がりを抑えるために左右に移動しながら目的地へと誘導していることがわかる。障害物を設置した場合の誘導平均時間と最小時間を図8に示す。規則型、学習型共に障害物が存在することによって誘導時間が増加していることがわかる。図9に牧羊犬モデルの誘導失敗回数を示す。この結果より規則型と比較して学習型牧羊犬モデルの誘導失敗回数が少ないことが分かる。このことから学習型牧羊犬モデルは規則型と比較して環境の変化に対しても対応できていることがわかる。

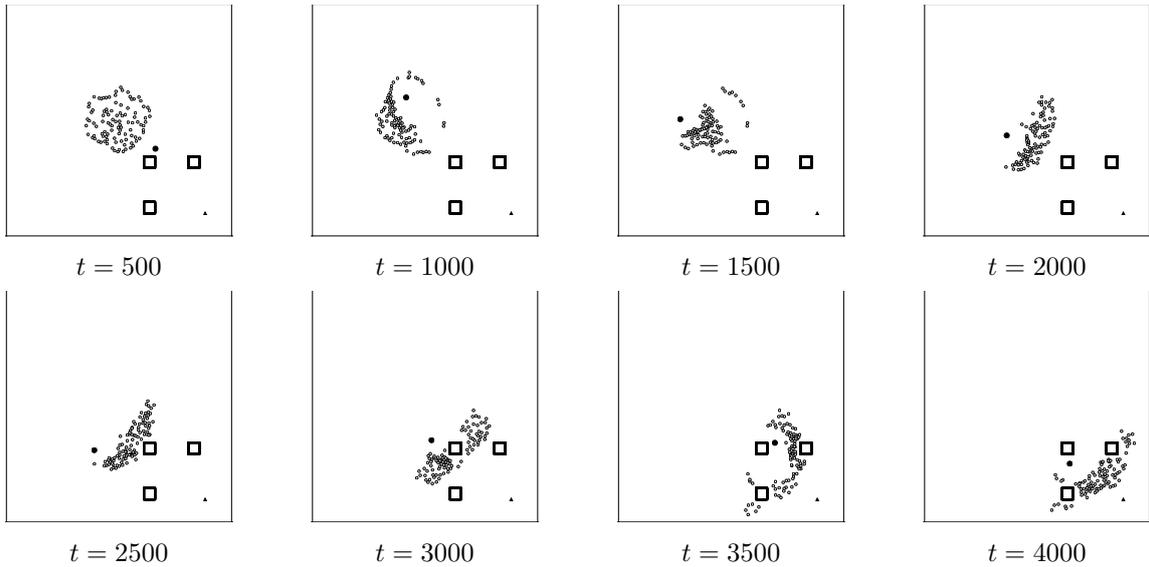


Fig. 7: Configurations for sheep and sheepdog agents with obstacles (number of sheep agents=100)

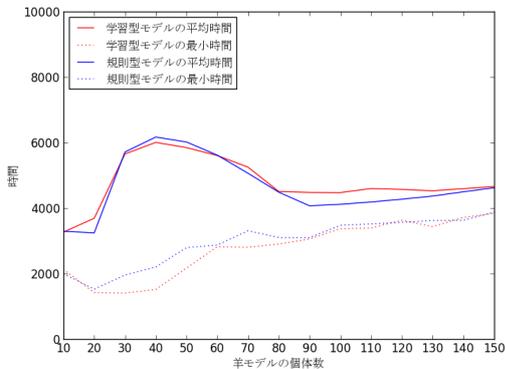


Fig. 8: Average and minimum iterations for rule-based and learning-based models with obstacles

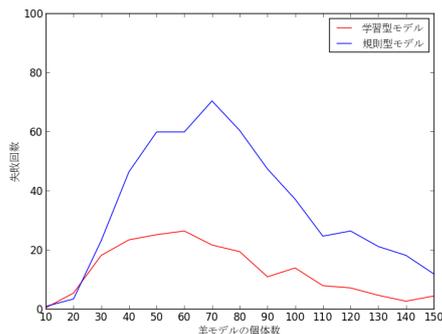


Fig. 9: The number of mistakes for leading with obstacles

## 5 まとめ

本研究では牧羊犬モデルに対して強化学習を導入することで既存の規則ベースのモデルと牧羊犬制御性能に対する比較を行った。シミュレーションによる評価より強化学習を用いた牧羊犬モデルは規則ベースとほぼ同等の性能で羊モデルの群れの誘導が行えているといえる。障害物を設置した場合にも、学習型は規則型と同等の時間で誘導を行うことができている、また規

則型よりも誘導失敗回数を低く抑えることが可能である。これらの結果より、本論文にて提案した学習型モデルは環境の変化に適応可能なモデルであるといえる。

## 参考文献

- 1) 伊藤, 大塚: 未来の社会システムを支えるマルチエージェントシステム研究 (2), 人工知能学会誌, 28 (3), 370/379 (2013)
- 2) C. W Reynolds: Flocks, herds, and schools: A distributed behavioral model, ACM SIGGRAPH Computer Graphics, 21(4), 25/34 (1987)
- 3) I. Aoki: A simulation study on the schooling mechanism in fish, Bulletin of the Japanese Society of Scientific Fisheries, 8(8) 1081/1088 (1982)
- 4) K. Morihiro, T. Isokawa, H. Nishimura, M. Tomimasu, N. Kamiura, and N. Matsui: Reinforcement Learning Scheme for Flocking Behavior Emergence, Journal of Advanced Computational Intelligence and Intelligent Informatics, 11(2), 155/161 (2007)
- 5) A. Ueyama, T. Isokawa, H. Nishimura, and N. Matsui: A Comparison of Grouping Behaviors on Rule-based and Learning-based Multi-agent Systems, Recent Advances in Natural Computing, Mathematics for Industry, vol.14, 27/40 (2015)
- 6) 東, 田淵, 杉江: 牧羊犬制御のモデル化, 計測自動制御学会論文集, 48(12) 882/888 (2012)
- 7) D. Strömbom, R. P. Mann, A. M. Wilson, S. Hailes, A. J. Morton, D. J. Sumpter, and A. J. King: Solving the shepherding problem: heuristics for herding autonomous, interacting agents, Journal of The Royal Society Interface, 11(100) (2014)
- 8) W. D. Hamilton: Geometry for the selfish herd, Journal of theoretical Biology, 31(2), 295/311 (1971)
- 9) C. J. C. H. Watkins and P. Dayan: Q-learning, Machine Learning, 8, 279/292 (1992)

# 大脳新皮質学習における異なる時系列データの 複合予測に関する基礎検討

○長島晶彦 青木健 高玉圭樹 佐藤寛之 (電気通信大学)

## A Preliminary Study on Ensemble Prediction of Different Time-series Data in Cortical Learning Algorithm

\*A. Nagashima, T. Aoki, K. Takadama, and H. Sato (The University of Electro-Communications)

**Abstract**— The cortical learning algorithm is one of the time-series prediction algorithms. This work addresses an ensemble prediction of different time-series data in the cortical learning algorithm. In the proposed method, we input two kinds of data into the predictor. If their data can contribute to improving their predictions, the proposed algorithm utilizes synapses among them, and the proposed algorithm does not utilize their synapses otherwise. Experimental results show that the proposed algorithm enhances the ensemble predictions for artificial related data while maintaining the independent prediction accuracy for non-related data.

**Key Words:** Hierarchical Temporal Memory, Cortical Learning Algorithm, Time Series Forecasting

### 1 はじめに

大脳新皮質をモデル化し時系列データをパターンに変換することで学習する理論として階層時間記憶 (Hierarchical temporal memory, 以下 HTM)<sup>1)</sup>がある。この HTM を具現化し、アルゴリズムに落とし込んだ大脳新皮質学習アルゴリズム (Cortical Learning Algorithm, 以下 CLA)<sup>2, 3)</sup>がある。CLA は時系列データを学習し、現在の時刻の入力から次の時刻の入力を予測するアルゴリズムである。時系列データを学習する関連研究として、再帰型ニューラルネットワーク (Recurrent Neural Network, RNN)<sup>4)</sup>や、長短期記憶 (Long-short Term Memory, LSTM)<sup>5)</sup>が存在する。応用的にタクシーの乗車数の時系列予測問題で LSTM よりも高い性能を示した結果<sup>6)</sup>が報告されている。また、CLA は時系列データの学習だけでなく物体の位置情報とその感覚データの組み合わせから物体を認識することに応用する実験<sup>7)</sup>が行われている。

本研究は CLA を用いて複数時系列データを学習する場合に注目する。CLA の予測器は、セル、多数のセルを内包するカラム、更にカラムを多数配置したリージョンによって構成される。入力データの時系列パターンは、シナプスで接続されたセルの関係によって表現される。ヒトの場合、視覚、聴覚、触覚といった入力毎に異なる予測器が存在するとは考えづらく、単一の仕組みで複数の入力を処理していると考えられる。CLA も同様に、複数の異なる入力データを単一のリージョンに入力可能と考えられる。ヒトは、視覚による入力データから、聴覚の入力を予測・補完するような異なるデータを用いた予測を行うと考えられる。CLA でも同様に複数の異なる時系列データを入力する場合、それぞれが関係性の高い入力データのとき、それらのデータの関係性から、単独で予測するより予測精度が高まる可能性がある。一方、関係性の低い入力データのとき、CLA はデータの関係性を見つけるためにシナプスを増やして、多様なセルの関係を作るが、これが予測の弊害になる。

本研究では、CLA における単一のリージョンに異なる複数の時系列データを入力した場合の予測精度向上を目的とし、異なる入力データ間のセルに対するシナプスの追加を制御する方法を構築する。本稿では、複数のテスト時系列データを入力し、複数時系列データの学習の効果と提案法の効果을明らかにする。

### 2 大脳新皮質アルゴリズム (CLA)

ここでは、単一の時系列データを学習する CLA について記述する。まず CLA の学習器とその構成要素について述べた後、CLA の学習手順を述べる。

#### 2.1 構成要素

CLA の概略図を Fig. 1 に示す。CLA の学習器をリージョンと呼び、リージョンは入力ビットを受け取り学習する。リージョンは多数のセルを内包するカラム群によって構成され、各カラムは入力ビットと接続するシナプスを持つ。学習ではセル間のシナプスを形成・更新しながらシナプスネットワークを構築する。この学習器はリージョンが入力を受け取り、シナプスネットワークからセルを予測状態にすることで予測を行う。ここでは CLA の構成要素について述べる。

##### 2.1.1 カラム

カラムは通常と活性の二つの状態を取る。各カラムはシナプスにより幾つかの入力ビットと紐づけられ、紐づけられたビットの内、1 が立っているビット数が閾値を超えたカラムは活性状態となる。カラムは上記の特性により、入力ビットをリージョン内で表現する役割を持つ。リージョンはカラムの活性パターンを学習することで、間接的に入力を学習する。

##### 2.1.2 セル

セルは通常、活性、予測の三つの状態を取る。セルがこの三つの状態を遷移することで、リージョンは入力データの文脈を保存し予測が可能になる。セルの状態遷移については 2.2.3 項で述べる。セルはシナプスをまとめるセグメントを持ち、セルの持つセグメント内のシナプスは他のセルに向けて接続されている。

### 2.1.3 シナプス

シナプスは接続元、接続先、永続値の三つの情報を持つ。また、シナプスは接続状態または切断状態の二つの状態を取る。シナプスは接続元に向けて接続先の情報を引き渡す役割を持ち、リージョン内の様々な構成要素の状態遷移を引き起こす。学習を繰り返す中で、シナプスの状態を決める値である永続値は更新され、永続値が閾値を超えると接続状態に、下回ればシナプスは切断状態へと遷移する。

例えば、カラムが持つシナプスの場合、接続元はカラムであり、接続先は入力ビットとなる。シナプスが接続状態の場合、シナプスはカラムへと接続先のビットの値を伝える。伝えられた値から、カラムは入力ビットの状態を知ることが出来る。接続元の活性状態への遷移に貢献したシナプスは永続値が増加し、より接続先との繋がりを強固にする。対して、活性状態への遷移に貢献しなかったシナプスは永続値が減少する。シナプスによってリージョン内の各構成要素は自身の状態遷移に必要な情報のみを抽出し、予測を可能にする。

## 2.2 学習の流れ

CLA は入力変換、空間プーリング、時間プーリング、出力変換の四つのステップから学習と予測を行う。ここでは、CLA の学習の流れをこれらのステップに沿って説明する。

### 2.2.1 入力変換

CLA は、ある時刻  $t$  に入力される実数値  $input(t)$  を入力ビット列に変換する。入力ビット列は、以下の式に従い 1 を隣接して並べることで生成される。この 1 が連続して並んだビットをチャンクと呼ぶ。入力の実数値の最大値  $max$ 、最小値  $min$ 、ビット列の長さ  $n$ 、チャンクサイズ  $w$  とすると、チャンクが配置される範囲  $[start, end]$  は次の式で決定される。

$$start = \text{floor}\left(\frac{(input(t) - min) \times (n - w)}{max - min}\right) \quad (1)$$

$$end = start + w - 1 \quad (2)$$

### 2.2.2 空間プーリング

2.2.1 項に従い実数値を変換して得られたビット列をリージョンに入力し、カラムの活性パターンに変換する処理を空間プーリングと呼ぶ。空間プーリングは主

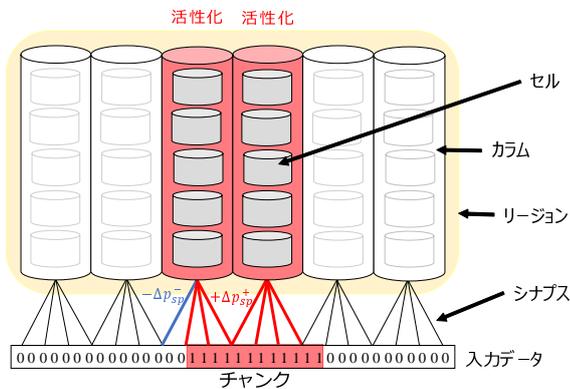


Fig. 1: 空間プーリング

に活性カラムの選択と永続値の更新から成り立つ処理である。この処理の概略図を Fig. 1 に示す。

初期化処理として、各カラムは入力ビット列との相対的な位置から対応するビットが決定され、対応したビットを中心として一定の範囲内のビットに向けてシナプスが形成される。シナプスは永続値  $p_{sp} = [0, 1]$  を持つ。永続値はユーザーによって決められた閾値  $T_{sp}$  を基準に  $p_{sp} \geq T_{sp}$  となれば接続状態、 $p_{sp} < T_{sp}$  であれば切断状態に遷移する。空間プーリングにおいて、シナプスは形成される時、半数は  $T_{sp}$  を超えるように設定され、半数は  $T_{sp}$  を下回るように設定される。データが入力されたとき、 $i$  番目のカラムの持つ接続状態のシナプスの内、接続先のビットが 1 になっている数を  $overlap_{column}(i)$  とする。 $overlap_{column}(i)$  が 0 でない場合、その  $i$  番目のカラムは活性候補となる。活性候補となった各カラムは  $overlap_{column}(i)$  を参照し、 $overlap_{column}(i)$  が大きいカラム一定数が活性となる。

その後シナプスの永続値を更新する。活性状態のカラムの持つシナプスの全てについて、接続・切断状態によらず、1 が立っているビットと紐づけられたシナプスの永続値は  $\Delta p_{sp}^+$  増加し、0 と紐づけられたシナプスの場合は永続値が  $\Delta p_{sp}^-$  減少する。

### 2.2.3 時間プーリング

時間プーリングは、活性セルの選択、予測セルの選択、シナプスの更新から構成される。各処理についてまとめた概略図を Fig. 2 に示す。以下ではこれらの各処理について述べる。

#### Algorithm 1 活性状態とするセルの選択

```

1: for all Column  $\in$  activeColumns do
2:   for  $i \leftarrow 1$  to cellsPerColumn do
3:     if Column.getCell(i).predictiveState = true
4:       then
5:         Column.getCell(i).activeState  $\leftarrow$  true
6:         for all Segment  $\in$ 
7:           Column.getCell(i).segments do
8:             if Segment.learningState = true then
9:               updateSegmentList.add(Segment)
10:            end if
11:          end for
12:        else if  $i = cellsPerColumn$  then
13:          bCell  $\leftarrow$  Column.BestMatchingCell()
14:          bSeg  $\leftarrow$  bCell.BestMatchingSegment()
15:          updateSegmentList.add(bSeg)
16:        end if
17:      end for
18:    end for

```

最初に、活性状態とするセルの選択について、擬似コードを Algorithm 1、疑似コード内で使用する変数とその説明を Table 1 に記載する。まず、活性セルの選択では 2.2.2 項によって活性状態になったカラムに内包されたセルから活性となるセルを選択する。活性状態のカラム内のセルで予測状態のセルが存在する場合、そ

Table 1: Algorithm 1 の変数

変数名	説明
activeColumns	活性状態のカラム群
predictiveState	セルの予測状態, true または false
activeState	セルの活性状態, true または false
learningState	学習するためのフラグ
updateSegmentList	更新するセグメントのリスト

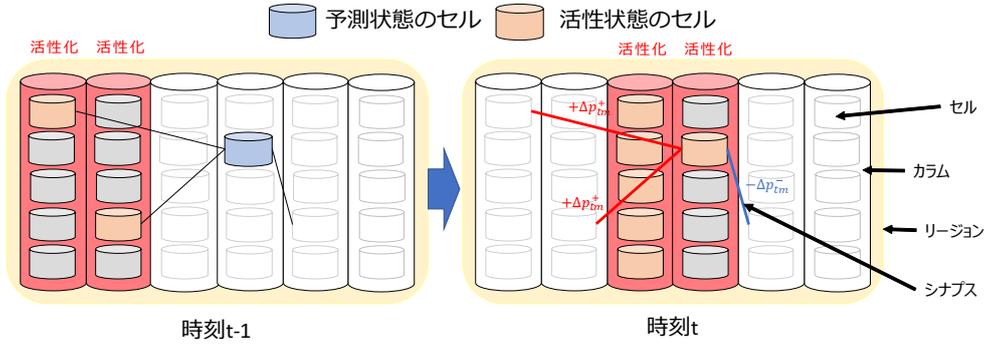


Fig. 2: 時間プリーング

のセルを活性状態にする．その後，そのセルの持つ全てのセグメントを参照し，そのセルを予測状態にしたセグメントを全て更新リストに追加する．この処理は3行目から9行目に示されている．次に，予測状態のセルがない場合，カラム内の全てのセルを参照し，最も予測状態に近かったセルを探す *BestMatchingCell* と呼ばれる処理を行う．そのセルの中で前時刻に活性状態であったセルと最も多くの接続状態のシナプスを持ったセグメントを探す *BestMatchingSegment* を行い，そのセグメントを更新リストに追加する．これは Algorithm 1 の10行目から15行目に記されている．予測状態のセルがないとき，全てのセルが学習の対象となりえることで，新しい入力のパターンに対応することが可能になる．

#### Algorithm 2 予測状態とするセルの選択

```

1: for  $i \leftarrow 1$  to  $numCells$  do
2:    $bSeg \leftarrow Cell(i).BestMatchingSegment()$ 
3:   if  $bSeg.numActiveConnected \geq T_A$  then
4:      $bSeg.learningState \leftarrow true$ 
5:      $Cell(i).predictiveState \leftarrow true$ 
6:   end if
7: end for

```

予測セルの選択の疑似コードを Algorithm 2 に，使用する変数を Table 2 に記載する．この処理では，まず全セル中で現時刻において活性しているセルと最も多くの接続状態のシナプスを持ったセグメントを参照する．この処理は2行目に記されている．セグメントに含まれたシナプスの内，接続状態かつ接続先のセルが活性状態になっているシナプスの数が閾値  $T_A$  を超えているセグメントが存在すれば，そのセグメントを持つセルは予測状態へと遷移する．この処理は3行目，4行目に記されている．

シナプスの更新では，活性セルの選択で作られた更新リストのセグメントを参照し，内部のシナプスを更新する．この処理の疑似コードを Algorithm 3 に，疑似コード内で使用する変数を Table 3 に示す．更新リスト *updateSegmentList* に含まれた各セグメントにおいて，セグメントが持つシナプスを更新する．シナプスは

Table 2: Algorithm 2 の変数

変数名	説明
$numActiveConnected$	接続状態かつ活性状態のセルと接続されたシナプスの数

#### Algorithm 3 シナプスの更新

```

1: for all  $segment \in updateSegmentList$  do
2:   for all  $synapse \in segment$  do
3:      $pCell \leftarrow synapse.getPresynapticCell()$ 
4:     if  $preActiveCellsList.contains(pCell) = 1$  then
5:        $synapse.permanence$  is increased by  $\Delta p_{tm}^+$ 
6:       if  $synapse.permanence \geq T_{tp}$  then
7:          $synapse.connectState \leftarrow true$ 
8:       end if
9:     else
10:       $synapse.permanence$  is decreased by  $\Delta p_{tm}^-$ 
11:      if  $synapse.permanence < T_{tp}$  then
12:         $synapse.connectState \leftarrow false$ 
13:      end if
14:    end if
15:    if  $synapse.permanence > 1.0$  then
16:       $synapse.permanence \leftarrow 1.0$ 
17:    else if  $synapse.permanence \leq 0.0$  then
18:       $DestroySynapse(synapse)$ 
19:    end if
20:  end for
21: for all  $Cell \in preActiveCellsList$  do
22:   for  $i \leftarrow 1$  to  $segment.getAllSynapse.size()$  do
23:    if  $segment.getSynapse(i).getPresynapticCell = Cell$  then
24:      break
25:    end if
26:    if  $i = segment.getAllSynapse.size()$  then
27:       $segment.makeSynapse(Cell)$ 
28:    end if
29:  end for
30: end for
31: end for

```

Table 3: Algorithm 3 の変数

変数名	説明
$permanence$	シナプスの持つ永続値
$preActiveCellsList$	前時刻において活性していたセルのリスト
$connectedState$	シナプスの接続状態
$presynapticCell$	シナプスの接続先の情報

永続値  $p_{tp} = [0, 1]$  を持ち，閾値  $T_{tp}$  を基準に  $p_{tp} \geq T_{tp}$  となれば接続状態， $p_{tp} < T_{tp}$  であれば切断状態に遷移する．3行目から14行目は，シナプスの永続値を更新しており，接続先のセルが前時刻に活性状態になっているシナプスの永続値を  $\Delta p_{tm}^+$  増加し，通常状態のセルを接続先として持つシナプスの場合は永続値が  $\Delta p_{tm}^-$  減少させることを表す．また，永続値が1を超えないように丸め込む処理と，永続値が0を下回ったときシナプスを削除する処理が15行目から19行目に記載さ

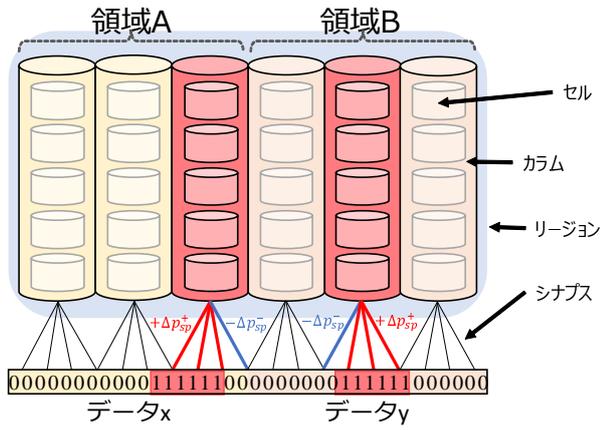


Fig. 3: 複合予測の空間プーリング

れている。次に、21行目から25行目にかけて前時刻に活性したセルとの間にシナプスが存在するかを確認する。全てのシナプスを参照し、前時刻に活性したセルとの間にシナプスが存在していなかった場合、そのセグメントには前時刻に活性していたセルに向けてシナプスが追加される。この処理は26行目から30行目に記される。

### 2.3 出力変換

CLA内ではセルの状態のパターンによって予測が表現される。実際に値を出力するため、内部表現から実数値に変換するデコーダーが必要となる。CLAではこのデコーダーに単純パーセプトロンを用い、誤り訂正学習を行う。この誤り訂正学習では時刻 $t$ の入力値を教師データとして、時刻 $t-1$ の際の活性状態のセルを学習データとしている。

## 3 複合予測

### 3.1 入力変換

複数ある時系列データの $i$ 番目の時系列データの入力値 $input_i(t)$ に関して入力ビット長 $n_i$ 、時系列データ内の最大値 $max_i$ 、最小値 $min_i$ 、チャンクの大きさ $w_i$ とすると入力変換によってチャンクが配置される範囲 $[start_i, end_i]$ は以下の式となる。

$$start_i = \text{floor}\left(\frac{(input_i(t) - min_i) \times (n_i - w_i)}{max_i - min_i}\right) \quad (3)$$

$$end_i = start_i + w_i - 1 \quad (4)$$

複数時系列データを学習する際、この入力変換によって得られた各時系列データに対応するビット列を全て連結して入力データとして扱う。このように入力データを扱うことで、とある入力 $x$ を受け取るカラム集合A、また別の入力 $y$ を受け取るカラム集合Bのように一つのリージョン内のカラムを複数の集合に分けることが可能となる。以下ではこの各入力を受け取るカラム集合を”領域”と呼称する。

### 3.2 空間プーリング

複合予測における空間プーリングの概略図をFig. 3に示す。複数時系列データを同時学習させる場合も、単一の時系列データを学習させるCLAと同様に、空間プーリングは入力データから活性するカラムを決定する処理である。複数時系列データで学習させる場合、3.1で述べた通り各入力に対応するカラムの領域が分かれ

る。このとき、複合予測では各入力ビットと、それぞれに対応する領域毎に個別に空間プーリングを行う。空間プーリングを分割することで各入力に対するカラムの活性数が固定され、リージョンにおける入力の表現能力が担保される。

### 3.3 時間プーリング

複合予測における時間プーリングの概略図を、Fig. 4に示す。空間プーリングとは異なり、時間プーリングでは2.2.3項と同様に処理を行う。そのため、複数時系列を学習する場合であっても、領域を横断して紐づけられるシナプスが形成される。領域を横断するシナプスにより、ある領域に存在するセルは別の領域のセルの情報を参照して予測状態へと遷移が可能になる。

### 3.4 出力変換

2.3節で使ったデコーダーを入力するデータの個数分用意する。各デコーダーは別々の領域と結び付けられ、その領域の時刻 $t$ の入力値を教師データとして、時刻 $t-1$ の際のセルの活性状態を学習データとしている。

## 4 問題点：異なる複数データの同時予測

本稿では、複数の入力データのビット列を連結して一つのリージョンに入力する。複合予測による問題点の概念図をFig. 5に示す。各入力データビットのシナプスは、近くのカラムに配置されるため、データ $x$ は主として左側の黄色いカラム群、データ $y$ は主として右側の赤いカラム群が内部表現化する。しかし、内部のセルのシナプスは、双方の領域のカラム群を横断して配置される。

従来のCLAでは、複数の関連性が高いデータを入力する場合、それぞれを入力データを単独で予測するときよりも予測精度が高まる。一方、関連性が低いデータを入力する場合、従来のCLAは、それぞれを入力データの関係性を見つけようとし、セル間のシナプス数が増大する。その結果、関係性を見出すことが困難になり、正しい予測をもたらすシナプスが悪影響を受け、予測精度が悪化する問題が生じる。複数のデータの関連性が低い場合、異なる領域間のセル間の不要なシナプスの生成を抑制する仕組みを導入できれば、複数データの同時予測性能が高まると考えられる。

## 5 提案：貢献度に基づくシナプス追加の抑制

異なる複数の時系列データの予測精度向上を目的とし、異なる入力データを扱う領域間のセルに対するシナプスの追加を制御する方法を構築する。2種類のデータ $x$ とデータ $y$ が入力される例をFig. 6に示す。それぞれのデータ領域に対する各シナプスの貢献度を算出し、関係性の低い異なるデータの入力領域を横断するシナプスの追加を抑制する。

### 5.1 方法

時間プーリングにおけるシナプスの更新時に提案法を実行する。ここでは、提案する方法を組み込んだ場合におけるシナプスの更新の疑似コードをAlgorithm 4に、新たに使用する変数の説明をTable 4に記載する。

提案法では、シナプスの貢献度を導入し、その初期値を1とする。シナプスの更新における新たな処理としてAlgorithm 4における8行目に、永続値が加算(シナプス強化)されるたびに1増加させる処理を導入す

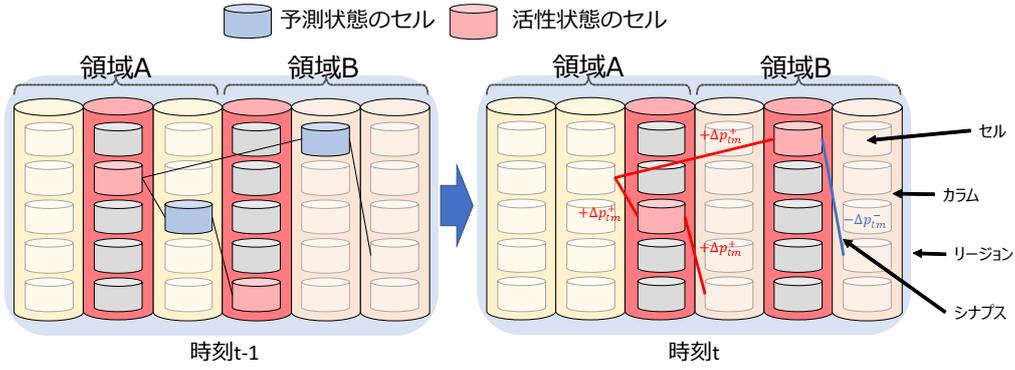


Fig. 4: 複合予測の時間プーリング

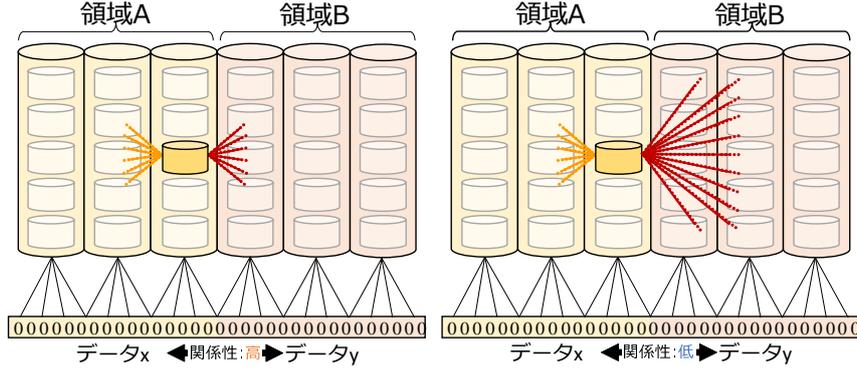


Fig. 5: 複数時系列データの問題点

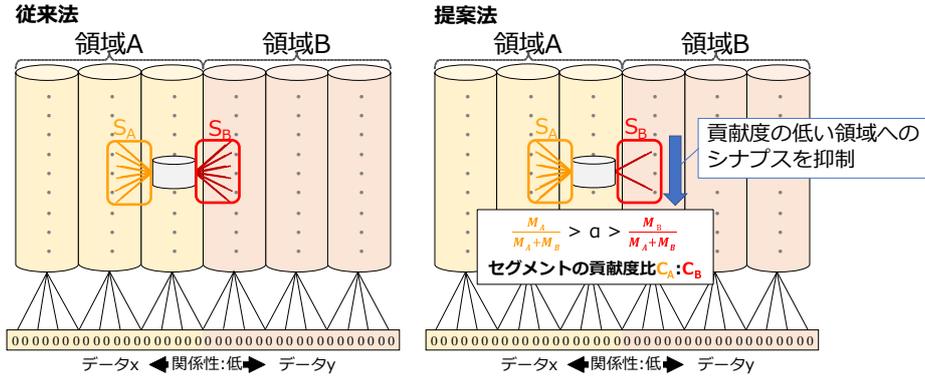


Fig. 6: 貢献度に基づくシナプス追加制御の考え方

Table 4: Algorithm 4 の変数

変数名	説明
contribution	シナプスの貢献度
otherRegionContributionRatio	他領域の貢献度比
proposalState	提案法のフラグ, true または false
Region	セルが配置された領域, A または B

る。21 行目では、各データ入力領域に着目し、内部のセルの各セグメントの持つ全シナプスについて、配置先の領域毎の貢献度の平均値を算出する。例として時系列データ  $x, y$  を入力し、それぞれを学習する領域 A、領域 B があり、領域 A に存在するセルを考える。セルのセグメントは領域 A に形成したシナプスの集合  $S_A$

と領域 B に形成したシナプスの集合  $S_B$  を持つ。  $S_A$  に含まれるシナプスの貢献度を  $S_{AC}$  と表すとき、  $S_A$  の貢献度の平均  $M_A$  は次の式で表される。

$$M_A = \frac{\sum S_{AC}}{|S_A|} \quad (5)$$

このセグメントの貢献度比  $C_A : C_B$  は次の式で決定される。

$$C_A : C_B = \frac{M_A}{M_A + M_B} : \frac{M_B}{M_A + M_B} \quad (6)$$

例えば、領域 A に存在するあるセルのセグメントについて、同領域 A 内のセルとのシナプスが 100 本あり、それらの貢献度の総和が 1,000 場合、貢献度の平均値は 10 になる。一方、別領域 B 内のセルとのシナプスが 50 本あり、それらの貢献度の総和が 50 の場合、貢

---

**Algorithm 4** 提案法ありのシナプスの更新
 

---

```

1: for all segment ∈ updateSegmentList do
2:   for all synapse ∈ segment do
3:     pCell ← synapse.getPresynapticCell()
4:     if preActiveCellsList.contains(pCell) = true
       then
5:       synapse.permanence is increased by Δptm+
6:       if synapse.permanence ≥ Ttp then
7:         synapse.connectState ← true
8:       end if
9:       synapse.contribution is increased by 1
10:    else
11:      synapse.permanence is decreased by Δptm-
12:      if synapse.permanence < Ttp then
13:        synapse.connectState ← false
14:      end if
15:    end if
16:    if synapse.permanence > 1.0 then
17:      synapse.permanence ← 1.0
18:    else if synapse.permanence ≤ 0.0 then
19:      DestroySynapse(synapse)
20:    end if
21:  end for
22:  segment.calcContributionRatio()
23:  if segment.getOtherRegionContributionRatio <
     α then
24:    segment.ProposalState ← true
25:  end if
26:  for all Cell ∈ previousActiveCellsList do
27:    for i ← 1 to segment.getAllSynapse.size() do
28:      syn ← segment.getSynapse(i)
29:      if syn.getPresynapticCell == Cell then
30:        break
31:      end if
32:      if i = segment.getAllSynapse.size() then
33:        if segment.ProposalState =
           false || Cell.Region =
           segment.parentCell.Region then
34:          segment.makeSynapse(Cell)
35:        end if
36:      end if
37:    end for
38:  end for
39: end for

```

---

献度の平均値は1になる。領域 A 内のシナプスの貢献度平均 10 に対して、別領域 B へのシナプスの貢献度平均 1 場合、このセグメントの時系列予測には、同一領域 A 内部のシナプスの貢献度が大きく、別領域 B からのシナプスの貢献度は低いといえる。すなわち、このセグメントに関して、他領域のデータの予測に対する貢献度は低いといえる。

従来法は、時刻  $t$  で活性状態になった各セルについて、時刻  $t - 1$  において活性状態だったセルとの間にシナプスを設ける。この場合、関連性の弱いデータが入力される領域に対しても新たにシナプスが追加される。提案法は、各セルが存在する領域を自領域、存在しない領域を他領域とし、他領域の貢献度比  $segment.getOtherRegionContributionRatio$  が閾値  $\alpha$  以下の場合、そのセグメントの提案法のフラグを有効にする。これは 22 行目から 24 行目に記されている。また、31 行目から 33 行目に示す通り、提案法のフラグが有効であるとき、他領域へシナプスを生成しない。これによって関係性が低い領域へのシナプス追加を回避する。

## 5.2 期待される効果

5.1 節で述べた手法によって以下の効果が期待される。

- 不要な他領域の情報の抑制

- シナプスの過剰形成の抑止

自領域と他領域の関係性が低い場合、他領域にシナプスを作らなくすることで、他領域からそのセグメントへと予測に役立たない情報が伝わることを抑える。既に形成されている他領域に紐づけられたシナプスについては、学習を繰り返すことで永続値の減少によって削除される。よって長期的には単体の領域での予測と同じ状態になる効果と、更にシナプスの過剰形成を抑えた予測器の最適化が期待出来る。

## 6 実験設定

### 6.1 入力する時系列データとパラメータ

複合予測の効果と提案法の効果を検証するため、2 種類の入力を用いて実験を行う。入力ビットの前半を正弦波とし、入力ビットの前半を学習するカラム群を領域 A とする。次に、領域 B が対応している後半のビットに正弦波を入れる場合と、ロジスティック写像を入れる場合の二つの場合で実験する。後半のビットが正弦波のときを関係性の高い入力、後半のビットがロジスティック写像のときを関係性が低い入力の場合とする。また、今回は比較のために各実験で領域 A に正弦波を入力し、領域 B に何も入力しなかった場合を記載する。これは、従来の CLA の予測精度に相当する。時刻  $t$  における正弦波の入力  $input_{sin}(t)$  は以下の式で表す。

$$input_{sin}(t) = \sin\left(\frac{(t-1) \times \pi}{50}\right) \quad (7)$$

ロジスティック写像について、本稿では係数を  $a = 3.5699456$  とし、時刻  $t$  でのロジスティック写像の入力値を次式で表す。

$$input_{log}(t+1) = 3.5699456 \cdot input_{log}(t) \cdot (1 - input_{log}(t)) \quad (8)$$

ロジスティック写像の初期値に関して、 $input_{log}(1) = 0.3$  とする。これらの入力をそれぞれ  $w_i = 11$  のチャック長を持つ長さ  $n_i = 256$  のビット列に変換し、結合することで  $n = 512$  の入力ビット列とする。エンコーダーのパラメータは正弦波を入力する場合  $max_{sin} = 1.0, min_{sin} = -1.0$ 、ロジスティック写像を入力する場合  $max_{log} = 1.0, min_{log} = 0$  とした。空間プーリングのパラメータは、 $T_{sp} = 0.1, \Delta p_{sp}^+ = 0.05, \Delta p_{sp}^- = 0.025$  とした。時間プーリングは  $T_A = 4, T_{tp} = 0.5, \Delta p_{tp}^+ = 0.1, \Delta p_{tp}^- = 0.1$  とした。全体でのカラム数は 512 カラム、各データを表現する領域に 256 カラムずつ割り当てた。入力時刻数は  $[1, 30,000]$ 、30 試行の平均値で結果を比較する。提案法の閾値  $\alpha$  は 0.45 に設定した。

### 6.2 評価尺度

評価指標には予測誤差を用いる。予測誤差とは時刻  $t+1$  の入力値  $input(t+1)$  と時刻  $t$  の出力値  $output(t)$  の絶対差を指す。今回はこの予測誤差に 100 回毎の移動平均を用いた値  $\Delta e(t)$  を計算する。 $\Delta e(t)$  は次の式で求められる。

$$\Delta e(t) = \frac{\sum_{i=t}^{t+99} |input(i+1) - output(i)|}{100} \quad (9)$$

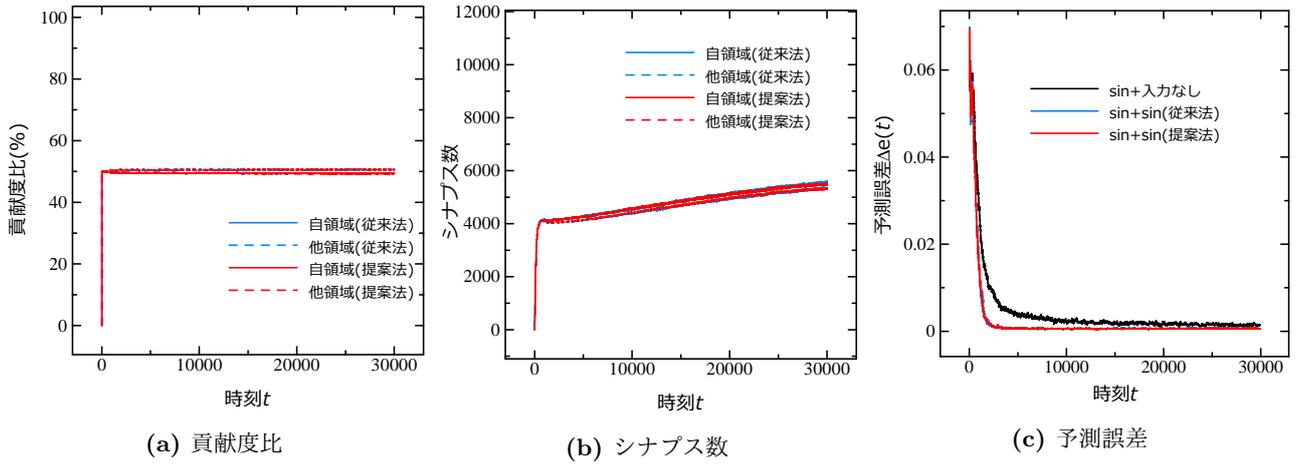


Fig. 7: 正弦波と正弦波

Table 5: 正弦波と正弦波

(a) 総予測誤差		(b) 入力時刻:20001-30000 の誤差合計	
方法	総予測誤差	方法	総予測誤差
単体 (従来)	134.38	単体 (従来)	15.56
複合予測 (従来)	66.27	複合予測 (従来)	6.41
複合予測 (提案)	65.41	複合予測 (提案)	6.17

さらに、内部状態の解析のために貢献度の推移とシナプス数の推移を入力時刻毎に計測した。例えばあるリージョンが A 領域, B 領域を持ち、それぞれ入力  $x$ , 入力  $y$  を受け取るとする。貢献度やシナプスは個々のセルが持つ値だが、全体の動きを確認するため、ある領域に注目してその領域に含まれる全セルを確認する。A 領域に  $n$  個のセルがあり、A 領域内の  $i$  番目のセル  $c_{Ai}$  が A 領域に紐づけられたシナプスが  $X_i$  本, B 領域に紐づけられたシナプスが  $Y_i$  本を持つとする。A 領域にある全てのセルから、B 領域に紐づけられたシナプスの集合を  $A(x)B(y)$  のように表すと、自領域に紐づけられたシナプス数  $|A(x)A(x)|$  と、他領域に紐づけられたシナプス数  $|A(x)B(y)|$  は次のように表現される。

$$|A(x)A(x)| = \sum_{i=0}^{n-1} X_i \quad (10)$$

$$|A(x)B(y)| = \sum_{i=0}^{n-1} Y_i \quad (11)$$

$c_{Ai}$  の貢献度比が  $C_{Ai} : C_{Bi}$  のとき、A 領域の貢献度比  $A(x)A(x)_C : A(x)B(y)_C$  は次のように定義した。

$$A(x)A(x)_C : A(x)B(y)_C = \frac{\sum_{i=0}^{n-1} C_{Ai}}{\sum_{i=0}^{n-1} C_{Ai} + \sum_{i=0}^{n-1} C_{Bi}} \times 100 : \frac{\sum_{i=0}^{n-1} C_{Bi}}{\sum_{i=0}^{n-1} C_{Ai} + \sum_{i=0}^{n-1} C_{Bi}} \times 100 \quad (12)$$

## 7 実験結果と考察

### 7.1 実験結果:正弦波と正弦波

入力される二つのデータの関係性が高い場合として、領域 A に正弦波、領域 B に正弦波を入力した際の結果を示す。

#### 7.1.1 貢献度の推移

正弦波を入力する領域 A に注目した場合の貢献度比の推移を Fig. 7a に示す。自領域とは、領域 A のセル

から領域 A のセルへのシナプスの貢献度であり、他領域とは、領域 A のセルから領域 B のセルへのシナプスの貢献度を示す。Fig. 7a を見ると、提案法の有無に関わらず、領域 A に含まれるセルが持つ貢献度比は、二つの領域が同様に 50% 近くを推移していることがわかる。この結果から、自領域、他領域の二つの領域がともに予測に貢献していることがわかる。

#### 7.1.2 シナプス数の推移

正弦波を入力する領域 A に注目した場合のシナプス数の推移を Fig. 7b に示す。Fig. 7b から、自領域、他領域に形成されるシナプスは提案法の有無に関わらず、ほぼ同数で推移していることがわかる。提案法は関係性の低い領域へのシナプスを抑制するための手法であるが、この結果から、関係性が高ければシナプスが抑制されないことがわかる。

#### 7.1.3 予測誤差の推移

正弦波を入力する領域 A に注目した場合の予測誤差の推移を Fig. 7c に示す。単体での予測結果が黒、複合予測のみで予測を行ったものを青、複合予測に提案法を適用したものを赤で記載した。更に、このときの誤差の合計を Table 5 に示す。Fig. 7c と Table 5a における、正弦波単体での入力を行う従来法と正弦波と正弦波を入力する従来法の比較から、関係性の高い入力を用いれば単体での学習よりも予測精度が高くなることがわかる。次に、Table 5b の正弦波と正弦波を入力する場合の従来法と、提案法の結果を見ると、学習が進んだ後でも提案法によって予測精度が下がっていないことがわかる。つまり、提案法は関係性が高い複数入力において予測を阻害しないことがわかる。

### 7.2 実験結果:正弦波とロジスティック写像

入力される二つのデータの関係性が低い場合として、領域 A に正弦波、領域 B にロジスティック写像を入力した際の結果を示す。

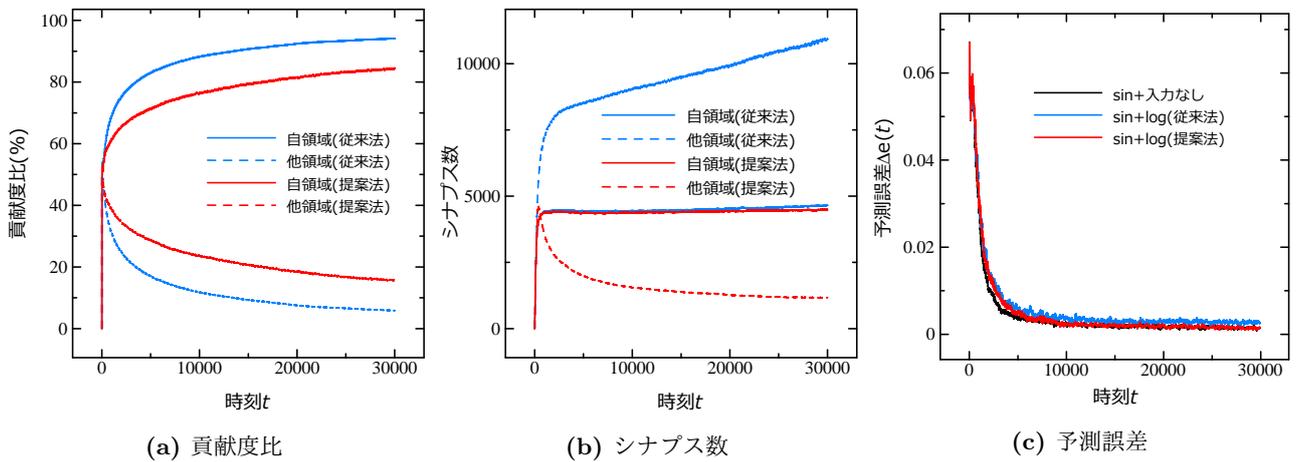


Fig. 8: 正弦波とロジスティック写像

Table 6: 正弦波とロジスティック写像

(a) 総予測誤差

方法	総予測誤差
単体 (従来)	134.38
複合予測 (従来)	177.00
複合予測 (提案)	148.50

(b) 入力時刻:20001-30000 の誤差合計

方法	総予測誤差
単体 (従来)	15.56
複合予測 (従来)	28.32
複合予測 (提案)	16.23

### 7.2.1 貢献度の推移

正弦波を入力する領域 A に注目した場合の貢献度比の推移を Fig. 8a に示す. この結果から, 従来法と提案法はともに, 自領域のシナプスの貢献度は上昇し, 他領域のシナプスの貢献度は低下することがわかる. すなわち, 正弦波の予測には, 正弦波が入力される領域 A のセルへのシナプスの貢献度が高く, ロジスティック写像が入力される領域 B のセルへのシナプスは貢献度が低いといえ, 提案法で算出される貢献度の妥当性が確認できた.

### 7.2.2 シナプス数の推移

正弦波を入力する領域 A に注目した場合のシナプス数の推移を Fig. 8b に示す. 正弦波が入力される領域 A のシナプス数は, 従来法, 提案法ともに同程度である. また, 他領域において, 従来法はシナプス数が増加し続ける. その結果, 予測が阻害される. 一方, 提案法の場合, 他領域の貢献度が低いため, 徐々にシナプス数が減少することがわかる. この結果から, 提案法が貢献度の低い領域へのシナプスを抑制することが確認できた.

### 7.2.3 予測誤差の推移

正弦波を入力する領域 A に注目した場合の予測誤差の推移を Fig. 8c に, このときの合計の誤差を Table 6 に記した. Table 6a を見ると, 正弦波のみを入力する従来法は, 正弦波とロジスティック写像を入力する従来法より予測誤差が小さいことがわかる. すなわち, 従来法は, 正弦波とロジスティック写像を同時に入力することによって, 正弦波の予測が阻害されて予測精度が低下すると考えられる. 次に, 提案法を適用した場合を見ると, ロジスティック写像と正弦波を入力する従来法より予測誤差が小さいことがわかる. 特に, 入力時刻 20,001 回から 30,000 回に注目した Table 6b を見ると, 学習が進むことで予測精度がより高くなることがわかる. 以上のことから, 提案法を適用した複合予測では正弦波のみを入力する従来法よりは予測誤差

が大きいものの, ロジスティック写像の入力による阻害を抑制できていると考えられる.

## 8 まとめ

CLA における異なる複数の時系列データの複合予測の精度向上を目的とし, 入力データ領域毎の予測の貢献度を導入し, 貢献度に合わせて新たなシナプス生成を抑制する方法を提案した. その結果, 提案法によって関係性の低いデータが同時入力された場合, 予測を阻害するシナプス生成を抑制し, 時系列予測の精度が改善されることが確かめられた. 更に, 関係性の高い入力を同時に用いた場合, 単体入力での予測よりも予測精度が高まることが確かめられた. 今後は, 入力する時系列データの種類を増やした際の影響を調べ, その結果から入力するデータ数, データの種類に応じて提案法の閾値  $\alpha$  を動的に決定する方法を検討する.

## 参考文献

- 1) J. Hawkins and S. Blakeslee: On Intelligence: How a New Understanding of the Brain Will Lead to the Creation of Truly Intelligent Machines, Times Books (2005)
- 2) J. Hawkins, A. Subutai, and D. Dubinsky: Hierarchical temporal memory including HTM cortical learning algorithms, Technical report, Numenta, Inc. (2010)
- 3) J. Hawkins and A. Subutai: Why Neurons Have Thousands of Synapses, a Theory of Sequence Memory in Neocortex, *Frontiers in Neural Circuits*, **Vol. 10**, 1/13 (2016)
- 4) J. L. Elman: Finding structure in time, *Cognitive Science*, No. 14, 179/211 (1990)
- 5) S. Hochreiter and J. Schmidhuber: Long Short-Term Memory, *Neural Computation*, **Vol. 9**, No. 8, 1735/1780 (1997)
- 6) Y. Cui, S. Ahmad, and J. Hawkins: Continuous Online Sequence Learning with an Unsupervised Neural Network Model, *Neural Computation*, **Vol. 28**, Issue 11, 2474/2504 (2016)
- 7) J. Hawkins, A. Subutai and Y. Cui: A Theory of How Columns in the Neocortex Enable Learning the Structure of the World, *Frontiers in Neural Circuits*, **Vol. 11**, 11/81 (2017)

# AffectNet: 顔表情データベースの構造適応型 DBN による感情モデルの KL 情報量を用いた精度向上

○鎌田 真 市村 匠 (県立広島大学 地域基盤研究機構)

## An Emotion Categorical Model by Adaptive Structure Deep Belief Network for AffectNet and the Consideration on Improvement of Classification Accuracy using KL Divergence

\*S. Kamada and T. Ichimura (Research Organization of Regional Oriented Studies, Prefectural University of Hiroshima)

**Abstract**— Deep Learning has a hierarchical network architecture to represent the complicated feature of input patterns. We have developed the adaptive structure learning method of Deep Belief Network (DBN) that can discover an optimal number of hidden neurons for given input data in a Restricted Boltzmann Machine (RBM) by neuron generation-annihilation algorithm, and hidden layers in DBN. The system has higher classification capability on some benchmark data sets. However, the system cannot decide the output category when the training data set includes ambiguous output with same input pattern as shown in the AffectNet database: the database for facial expressions. In this paper, we investigated the training situation by using KL divergence for the divided the training data according to the misjudgement for the two emotional categories assigned by the annotators.

**Key Words:** Deep Learning; Deep Belief Network; Restricted Boltzmann Machine, Adaptive Structure Learning; AffectNet

### 1 はじめに

近年, Deep Learning(深層学習)<sup>1, 2)</sup> が人工知能の理論的な研究だけでなく, 産業を中心とした様々な場面で利用され始めている。ILSVRC と呼ばれる画像認識の世界大会では, GoogleNet<sup>3)</sup> や ResNet<sup>4)</sup> で知られるように, 人間の認識能力を大きく上回る Deep Learning モデルが発表されている。従来の階層型ニューラルネットワークとは異なり, Deep Learning では事前学習が行われることが大きな特徴の一つである。各層ごとに学習を行うことで入力データに含まれる特徴を事前学習し, それらの複数の特徴を階層的に組み合わせることで, データ全体の特徴を高い精度で表現することができる。

確率モデルである Restricted Boltzmann Machine(RBM)<sup>5)</sup> を事前学習し, その RBM を階層化することで, 高度な分類性能をもつ Deep Belief Network(DBN)<sup>6)</sup> がある。我々は, 入力データ空間に応じて適切と考えられる隠れニューロン数及び隠れ層数を学習中に自動で求める構造適応型学習法を提案している<sup>7, 8)</sup>。提案手法は, 画像ベンチマークデータセット<sup>9)</sup> に対して従来手法よりも高い分類精度を示している<sup>10, 11)</sup>。他にも CXR8 などの胸部レントゲン写真のベンチマークデータセットに対しても, 高い分類能力と疾患部位検出結果を示すことができている<sup>12)</sup>。我々が開発した深層学習システムは, 教師データに対する分類能力が高いだけでなく, 未知のデータに対する分類精度も高いため, 一般的に汎化能力に優れていると考えている。

本論文では, 構造適応型 DBN を顔表情データベース AffectNet<sup>13)</sup> に適用した。AffectNet は, 自然な感情表情, 快/不快, 好感度のデータベースとして Mahoor らが公開しているもので, インターネット上から収集された顔画像に対して, 8 種類の感情が人によってラ

ベル付けされている。学習結果として, 訓練データに対してほぼ 100% の分類精度を示した。テストデータに対しても, 既存の手法よりも高い分類精度を示せたものの, 一部のラベルには, 複数の感情や曖昧な特徴が含まれており, 正しい分類ができなかった。これはラベル付けした人の主観によって分類されたデータを用いているため, 感情の判定が難しい事例が含まれていると考えられる。

これらは, 入力パターンが同じであるが, 出力カテゴリが異なるデータを取り扱う時に生じると考えられる。モデルの学習時に与えるデータがデータクレンジングが行われていない場合や, 学習後に収集されたデータに矛盾が発見される場合など見られる現象で, 通常は該当するデータに対して何らかの手段で再学習を促すか, もしくはモデルを再度学習しなおすなどの方法により解決されているだろう。しかしながら, AffectNet や医療情報のように, 主観的な情報が含まれていたり, 与えられた情報だけでは判定しきれずに他の情報を加味して判断しなければならない状態は現実世界に多く存在している。このような場合, アンサンブル学習のように, 複数のモデルを用いた学習法が効果的であると考えられる。また, 2 つのモデルの確率分布の違いを表現する方法として, KL 情報量が知られている。本研究では, このようなモデルの実現のために, ここでは, 既存の学習モデルに対して, 誤った結果を生じたデータについて 2 つのモデルを構築し, その KL 情報量について調査した。本論文では, 学習後に高くない正答率を示したデータのうち, 教師信号が二つ以上のカテゴリに含まれる可能性があるデータを抽出し, そのモデルに対して, 学習モデルを構築した。KL 情報量の違いによって, 別のモデルを構築し, アンサンブル学習を行う必要がある状態を調査するために, このモデルと元のモデルの KL 情報量を測定し, その変化

と2つのモデルを用いたときの正答率を比較したので、ここに報告する。

## 2 構造適応型 Deep Belief Network による学習手法

### 2.1 Restricted Boltzmann Machine

RBM<sup>5)</sup> は、可視層と隠れ層の2層から構成されるネットワーク構造を持ち、確率分布に基づいて入力データに含まれる特徴を隠れニューロン上で学習することができる。RBMの学習では、与えられた入力データに対して、式(1)のエネルギー関数を最小にするパラメータ  $\theta = \{b, c, W\}$  が最尤推定により求められる。

$$E(\mathbf{v}, \mathbf{h}) = - \sum_i b_i v_i - \sum_j c_j h_j - \sum_i \sum_j v_i W_{ij} h_j, \quad (1)$$

$$p(\mathbf{v}, \mathbf{h}) = \frac{1}{Z} \exp(-E(\mathbf{v}, \mathbf{h})), \quad (2)$$

$$Z = \sum_{\mathbf{v}} \sum_{\mathbf{h}} \exp(-E(\mathbf{v}, \mathbf{h})) \quad (3)$$

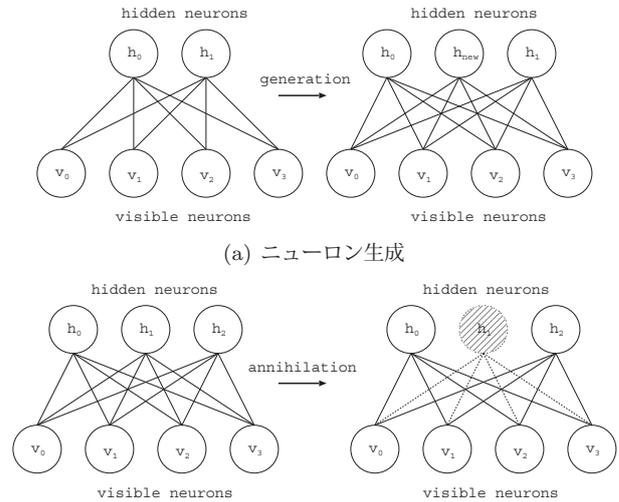
ここで、 $v_i$  は  $i$  番目の可視ニューロン、 $h_j$  は  $j$  番目の隠れニューロンである。 $b_i$  は  $v_i$  に対するパラメータ、 $c_j$  は  $h_j$  に対するパラメータ、 $W_{ij}$  は  $v_i$  と  $h_j$  間の重みである。 $\mathbf{v} \in \{0, 1\}^I$  と  $\mathbf{h} \in \{0, 1\}^J$  はそれぞれ可視層と隠れ層のベクトルであり、 $I$  と  $J$  は可視ニューロン数、隠れニューロン数である。式(2)は入力  $\mathbf{v}$  と  $\mathbf{h}$  の確率分布である。式(3)の  $Z$  は分配関数 (partition function) であり、 $\mathbf{v}$  と  $\mathbf{h}$  の全ての2値のパターンの組み合わせに対するエネルギーを示す。一般的に、RBMでは計算量の観点から Contrastive Divergence(CD)法<sup>14)</sup>による学習が行われる。

### 2.2 Deep Belief Network

Deep Belief Network(DBN)は、事前学習を行ったRBMを複数積み重ねることで、入力データの特徴を階層的に学習することができるDeep Learning手法である<sup>6)</sup>。DBN自体はRBMを積み重ねたモデルであるため教師なし学習モデルであるが、最上位層に出力層を加え、ソフトマック法等により計算された出力値と教師信号との誤差を最小化することで、教師あり学習に適用できる(Fine-Tuning)。

### 2.3 ニューロン生成/消滅アルゴリズム

我々は、階層型ニューラルネットワークにおける文献<sup>15)</sup>の手法に基づき、RBMの学習中において最適な隠れニューロン数を自動で求めるニューロン生成/消滅アルゴリズムによる構造適応型学習手法を提案している<sup>7)</sup>。ニューロン生成は、学習中におけるパラメータの変分に基づいて行われる。例えば、学習データに対して十分な数の隠れニューロンがあれば、一般的に学習が進むにつれて重みベクトルの変分は小さな値になる。一方で、パラメータの変分が収束しない場合は、学習データに対するネットワークの表現能力が不足しており、データが持つ特徴(確率分布)を隠れニューロン上で線形分離できていないことが原因だと考えられる。このような場合、関連する位置に隠れニューロンを挿入することで、多くの次元でデータを表現できると考えられ、学習が収束する。我々の調査では、RBMの3つのパラメータ  $\theta = \{b, c, W\}$  のうち、CD法による学習



(a) ニューロン生成

(b) ニューロン消滅

Fig. 1: 構造適応型 RBM

の収束に関係しているパラメータは  $c$  と  $W$  とした。この2つのパラメータの関連生から、ニューロン生成条件を式(4)に示すように定義した<sup>16)</sup>。

$$WD_{c_j} \cdot WD_{W_j} > \theta_G \quad (4)$$

ここで、 $WD_{c_j}$ 、 $WD_{W_j}$  はそれぞれ  $j$  番目の隠れニューロンのパラメータと重みに関するWDであり、その計算方法については文献<sup>15)</sup>に示されている。 $\theta_G$ は閾値で予め与えられる。学習中に式(4)を満たす隠れニューロンが存在する場合、Fig. 1(a)のように、該当する隠れニューロンの近傍に新しいニューロンがその属性(パラメータや重みの値)を継承するように挿入される。

一方、入力データに対して十分な数の隠れニューロンが生成された後、そのうち出力に寄与していない、すなわち冗長な値を出力する隠れニューロンが存在する可能性がある。構造適応型RBMでは、一定の学習の後、式(5)を満たす隠れニューロンが存在すれば、ニューロン消滅アルゴリズムを適用し、該当する隠れニューロンをFig. 1(b)のように消去する。式(5)では、すべての入力データに対する隠れニューロンの出力値の平均を観察し、その値が一定の閾値以下のニューロンを冗長なニューロンとし、これを削除する。

$$\frac{1}{N} \sum_{n=1}^N p(h_j = 1 | \mathbf{v}_n) < \theta_A, \quad (5)$$

$$p(h_j = 1 | \mathbf{v}_n) = \sigma(b_j + \sum_i W_{ij} v_i) \quad (6)$$

ここで、 $\mathbf{v}_n$  は  $N$  個の入力データセットに含まれる入力データである。 $p(h_j = 1 | \mathbf{v}_n)$  はRBMの可視層に入力データ  $\mathbf{v}_n$  が与えられたときの隠れニューロン  $h_j \in \{0, 1\}$  の発火確率を示している。ここで、 $\sigma()$  はシグモイド関数で  $[0, 1]$  を出力する関数である。 $\theta_A$  は、予備実験における分類精度と削除するニューロンの活性化をもとに閾値として予め与えた。

### 2.4 層の生成条件

構造適応型RBMにおけるニューロン生成アルゴリズムでは、学習中のWD(パラメータ  $c$  と  $W$  の変分)を

Table 1: Category of AffectNet

カテゴリ名	訓練データ数	テストデータ数
Neutral (中立)	74,874	500
Happy (幸せ)	134,415	500
Sad (悲しみ)	25,459	500
Surprise (驚き)	14,090	500
Fear (恐怖)	6,378	500
Disgust (嫌悪)	3,803	500
Anger (怒り)	24,882	500
Contempt (軽蔑)	3,750	500
None (なし)	33,088	500
Uncertain (不確実)	11,645	500
Non-Face (顔なし)	82,414	500
合計	414,798	5500

観察したが、構造適応型 DBN<sup>10)</sup> では、個々の RBM ではなく、ネットワーク全体の WD とエネルギーを式 (7) と式 (8) で観察した。

$$\sum_{l=1}^k (\alpha_{WD} \cdot WD^l) > \theta_{L1}, \quad (7)$$

$$\sum_{l=1}^k (\alpha_E \cdot E^l) > \theta_{L2} \quad (8)$$

ここで、 $WD^l = \sum_{j=1}^J (WD_{c_j}^l \cdot WD_{W_j}^l)$  であり、 $WD_{c_j}^l$  と  $WD_{W_j}^l$  はそれぞれ  $l$  層目の RBM における  $c_j$  と  $W_j$  に関する WD を示している。 $E^l$  はエネルギー関数である。 $\theta_{L1}$ 、 $\theta_{L2}$  は閾値で、予め与えられる。ある  $k$  層の RBM において式 (7) 及び式 (8) を同時に満たす場合、入力データに対するネットワーク全体の表現能力が不足していると考え、 $k$  層の学習が終了した時点で、 $k+1$  層の RBM を生成し、学習を行う。

### 3 AffectNet

AffectNet は、文献<sup>13)</sup> によって作成された人間の感情を含む顔画像データベースである。Table 1 に示すように、11 種類のカテゴリが与えられており、訓練データとテストデータに分割されている。Fig. 2 は、11 種類のカテゴリの画像サンプルを示している。これらのカテゴリは、インターネット上から収集された画像に対して、快/不快、好感度に基づいて人の主観によってラベル付けされたものである。文献<sup>13)</sup> では、同じ画像に対して 2 人のアノテーター (画像に対して感情の種類を付与する人) の分類結果が一致する割合を各カテゴリに対して示している。人の感情には曖昧な特徴が多く含まれていることから、アノテーターの精度は高くない。Table 2 はこの分布を文献<sup>13)</sup> から引用したものである。また、“None”、“Uncertain”、“Non-Face”の 3 種類のカテゴリは、顔の感情に関するカテゴリではなく、文献<sup>13)</sup> でも学習では取り扱っておらず、本論文でも同様に、これらを 3 種類を除く、8 種類のデータを構造適応型 DBN で学習した。

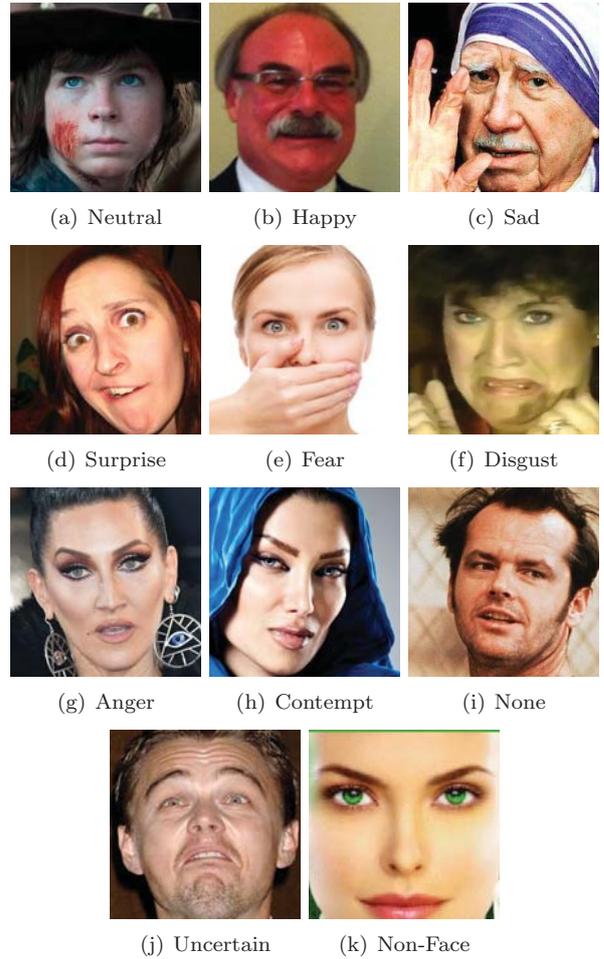


Fig. 2: AffectNet の画像サンプル

## 4 AffectNet に対する構造適応型 DBN の分類精度

### 4.1 分類精度

提案手法の構造適応型 DBN を用いて AffectNet の訓練データを学習し、テストデータを用いて分類制度を評価した。構造適応型 DBN の学習パラメータとして、勾配の学習手法を Stochastic Gradient Descent (SGD)、学習係数を 0.01、バッチサイズは 100、学習の最大反復回数を 500 回、初期隠れニューロン数を 300 とした。構造適応型 RBM のパラメータとして、 $\theta_G = 0.050$ 、 $\theta_A = 0.100$  とし、構造適応型 DBN のパラメータとして、 $\theta_{L1} = 0.1$ 、 $\theta_{L2} = 0.1$  とした。

Table 3 は、AffectNet に対する分類結果を示している。文献<sup>13)</sup> に記載されている CNN (AlexNet) では、テストデータに対して 60% 程度であった (訓練データの記載はなし)。一方、構造適応型 DBN では、訓練データに対しては概ね 100% の分類精度を示した。テストデータに対しては、平均 87.4% の分類精度となった。最も分類できたカテゴリは “Happy” であり、一方、最も分類できなかったカテゴリは “Anger” であった。また 90% の分類精度を下回ったカテゴリは、“Neutral”、“Sad”、“Surprise”、“Anger”、“Contempt” であった。

### 4.2 誤分類された事例の調査

4.1 節において誤って分類された事例が、どのカテゴリに分類されているかを調査した。Table 4 は、Table 3

Table 3: AffectNet に対する分類精度

カテゴリ名	CNN(文献 <sup>13)</sup> )	Adaptive DBN	
	テストデータ	訓練データ	テストデータ
Neutral	63.0%	99.3%	87.8%
Happy	88.0%	99.9%	92.4%
Sad	63.0%	99.2%	84.2%
Surprise	61.0%	99.4%	85.8%
Fear	52.0%	99.5%	90.4%
Disgust	52.0%	99.3%	92.4%
Anger	65.0%	98.2%	78.4%
Contempt	8.0%	98.8%	87.6%

の分類結果に対する混合行列 (Confusion Matrix) を示している. 混合行列とは, 8 種類のカテゴリがどのカテゴリに予測されたかを示すものである. 数値はサンプル数である.

Table 4 から, “Anger” が “Disgust” と誤って分類されている事例が多いことが分かった. 同様な事例として, “Sad” と “Suprise”, “Contempt” と “Neutral” のカテゴリ間で誤って分類される傾向があった.

## 5 構造適応型 DBN の再学習モデルの構築と KL 情報量による評価

4.2 節で誤って分類された理由として, 人の感情には 1 つ以上の複数の感情が含まれていることが多く, 非常に曖昧であることが原因であると仮定する. 文献<sup>13)</sup>では, 1 枚の画像に対して 2 人のアノテーターのラベル付けの結果が一致する割合が, 各カテゴリに対して示されている. これを見ると, 2 人のラベル付けが一致する割合は決して高くなく, 最も高いもので Happy の 79.6%, 一方, Neutral, Contempt, Anger では, 50.8%, 66.9%, 62.3% と低く, この傾向は, Table 4 の結果にも現れている. AffectNet では, 1 枚の画像には, 8 種類のカテゴリのうち 1 種類しか教師信号として割り当てられていないが, 上記のような曖昧なデータが含まれているとすると, 1 つの学習モデルで全てのデータを完全に分類することは難しいだろう. 学習中に曖昧なデータが含まれているかどうか発見できれば, それを 1 つの状態, もしくは新しいラベルとして考え, またアンサンブル学習の考えを用いて異なるモデルで学習することで, よりデータを表現できると考えられる.

このことから, 本研究では, 曖昧性を含むラベルのデータに対し, アンサンブル学習のように複数のモデルの KL 情報量を用いて再学習する方法を提案する. 本論文では, この実現のために, 1) 曖昧なデータのみを別モデルとして抽出し, 学習可能かどうか検討する. また, 2) 1) で構築したモデルと元のモデルの KL 情報量を測り, モデルの違いを測定し, KL 情報量が新規モデル作成の基準になるかどうか検討する. 1) では, 4.2 節の結果に基づき, 曖昧なデータとして Anger と Disgust, Sad と Surprise, Contempt と Neutral の 3 つの組を考え, それぞれモデル 1, モデル 2, モデル 3 として学習を行った. 2) については, 本論文の結果, モデルの基準を今後定める.

KL 情報量 (Kullback-Leibler divergence) は 2 つの確率分布の違いを測る指標である.  $P_T$  と  $P_S$  を確率分布,  $x_i$  を入力すると,  $P_T$  と  $P_S$  の KL 情報量は式 (9)

Table 5: AffectNet の曖昧なカテゴリに対する分類精度

	分類精度	
モデル 1	89.3%	(42 / 47)
モデル 2	91.3%	(21 / 23)
モデル 3	91.6%	(33 / 36)

もしくは式 (10) により計算される.

$$D_{KL}(P_T||P_S) = \sum_i P_T(x_i) \log \frac{P_T(x_i)}{P_S(x_i)}, \quad (9)$$

$$D_{KL}(P_S||P_T) = \sum_i P_S(x_i) \log \frac{P_S(x_i)}{P_T(x_i)} \quad (10)$$

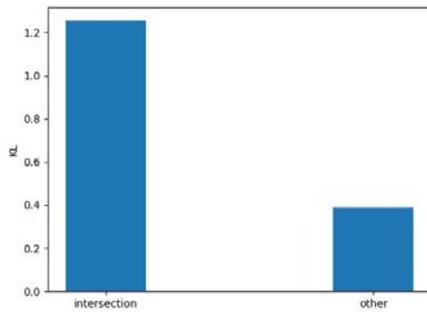
KL 情報量では,  $D_{KL}(P_T||P_S) \neq D_{KL}(P_S||P_T)$  であり, 非対称である. これらは用途によって使い分けるべきであり, 文献<sup>17)</sup>の蒸留 (Distillation) モデルでは, 学習した元の親モデル  $P_T$  に蓄えられた知識を同性能を持った小さな子モデル  $P_S$  で表現するために, 式 (9) により, 2 つのモデルの出力の確率分布が等しくなるように, 子モデルを学習している.

本論文では, 文献<sup>17)</sup>のように親モデルを継承した子モデルを構築するのではなく, 親モデルとは異なり, 曖昧なデータを表現するための子モデルを構築するために, 式 (10) により KL 情報量を計算した. ここで, 元のモデルを  $P_T$ , 曖昧なデータを表現するための子モデルを  $P_S$  とする. 各確率分布は式 (2) により計算される.

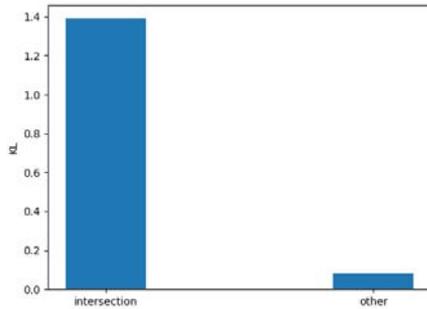
上記の 1) より, 学習した親モデルとは別に, Anger と Disgust 用にモデル 1, Sad と Surprise 用にモデル 2, Contempt と Neutral 用にモデル 3 を新たに作成した. Table 5 は, 各モデルの学習後の分類精度を示している. 各モデルで曖昧なデータを個別に学習することにより, 89%以上の精度で分類することができた. 括弧の値はサンプル数を示している. Fig. 3 は, ここで学習したそれぞれの子モデルと元の親モデルとの KL 情報量を示している. Fig. 3(a) はモデル 1 と親モデルにおいて, Anger と Disgust の曖昧なデータを与えた際の KL 情報量を横軸の左側 (intersection), それ以外の全てのデータを与えた際の KL 情報量を横軸の右側 (other) で示している. Fig. 3(b), Fig. 3(c) は, モデル 2, モデル 3 について同様の結果を示している. これらの結果から, 曖昧なデータを与えた場合と曖昧な特徴を含まないデータを当てた場合, KL 情報量に明確な違いが現れていることが分かった. また, 正答率については, Table 3 と Table 5 の数値を補完した結果ではあるが, Table 6 のようになった. 全体的には, 再学習後において分類精度は向上したが, 100%の精度には至っていない. Anger と Disgust において, Anger に対する分類精度は向上したが, Disgust に対する分類精度は向上していない. これらの事例については, 誤分類された事例を今後調査する. なお, Happy と Fear については, 本実験において再学習を行っておらず, 変化していないため記載していない.

## 6 おわりに

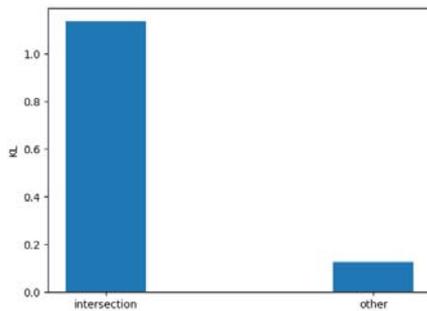
本研究では尤度の概念を用いた統計的なモデルである RBM, DBN に着目し, 学習中にニューロンの生成



(a) モデル 1 (Anger と Disgust)



(b) モデル 2 (Sad と Suprise)



(c) モデル 3 (Contempt と Neutral)

Fig. 3: 再学習したモデルに対する KL 情報量

／消滅及び階層化を行うことで最適な構造を求める構造適応型 DBN を提案している。本論文では、提案したモデルを顔表情データベース AffectNet に適用した。人の感情には複雑で曖昧な特徴が多く含まれているため、特定のカテゴリに対しては分類できなかったが、別モデルを作成することで学習を行った。また、各子モデルと元のモデルとの KL 情報量を測定した結果、モデル間の確率分布に明確な違いが見られ、新しい子モデルの作成に利用できる可能性が分かった。今後は、KL 情報量をもとに、学習中に曖昧なデータを発見し、アンサンブル学習により別モデルとして学習するモデルを開発する。このための KL 情報量の閾値設定や、子モデルの構造や新規ニューロン、層の生成の関連性について今後も調査を行い、学習アルゴリズムを開発する予定である。

## 謝辞

本研究開発は JSPS 科研費 (課題番号: 19K12142) の助成を受けたものです。

## 参考文献

- 1) Y.Bengio: *Learning Deep Architectures for AI*, Foundations and Trends in Machine Learning archive, vol.2, no.1, 1/127 (2009)
- 2) V.Le.Quoc, R.Marc's Aurelio, et.al.: *Building high-level features using large scale unsupervised learning*, Proc. of 2013 IEEE International Conference on Acoustics, Speech and Signal Processing, 8595/8598 (2013)
- 3) C.Szegedy, W.Liu, et.al.: *Going Deeper with Convolutions*, 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 1/9 (2015)
- 4) K.He, X.Zhang, S.R en, J.Sun: *Deep residual learning for image recognition*, Proc. of 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 770/778 (2016)
- 5) G.E.Hinton: *A Practical Guide to Training Restricted Boltzmann Machines*, Neural Networks, Tricks of the Trade, Lecture Notes in Computer Science (LNCS, vol.7700), 599/619 (2012)
- 6) G.E.Hinton, S.Osindero and Y.Teh: *A fast learning algorithm for deep belief nets*, Neural Computation, vol.18, no.7, 1527/1554 (2006)
- 7) S.Kamada and T.Ichimura: *An Adaptive Learning Method of Restricted Boltzmann Machine by Neuron Generation and Annihilation Algorithm*, Proc. of 2016 IEEE International Conference on Systems, Man, and Cybernetics (IEEE SMC 2016), 1273/1278 (2016)
- 8) S.Kamada and T.Ichimura: *A Structural Learning Method of Restricted Boltzmann Machine by Neuron Generation and Annihilation Algorithm*, Neural Information Processing, vol.9950 of the series Lecture Notes in Computer Science, 372/380 (2016)
- 9) A.Krizhevsky: *Learning Multiple Layers of Features from Tiny Images*, Master of thesis, University of Toronto (2009)
- 10) 鎌田真, 市村匠: *忘却機能を持った Deep Belief Network による構造適応型学習*, 計測自動制御学会第 9 回コンピュータ・インテリジェンス研究会講演論文集, 92/97 (2016)
- 11) S.Kamada and T.Ichimura: *An Adaptive Learning Method of Deep Belief Network by Layer Generation Algorithm*, Proc. of IEEE TENCON2016, 2971/2974 (2016)
- 12) 市村匠, 鎌田真: *ChestX-ray8 を用いた構造適応型 Deep Belief Network による胸部疾患位置検出システム*, 計測自動制御学会システム・情報部門学術講演会 2018 講演論文集 (SSI2018), SS10-08 (2018)
- 13) A.Mollahosseini, B.Hasani, M.H.Mahoor: *AffectNet: A Database for Facial Expression, Valence, and Arousal Computing in the Wild*, IEEE Transactions on Affective Computing, vol.pp, no. 99, 18/31 (2017)
- 14) G.E.Hinton: *Training products of experts by minimizing contrastive divergence*, Neural Computation, vol.14, no.8, 1771/1800 (2002)
- 15) T.Ichimura and K.Yoshida Eds.: *Knowledge-Based Intelligent Systems for Health Care*, Advanced Knowledge International (ISBN 0-9751004-4-0) (2004)
- 16) S.Kamada, T.Ichimura, Akira Hara, and Kenneth J. Mackin: *Adaptive Structure Learning Method of Deep Belief Network using Neuron Generation-Annihilation and Layer Generation*, Neural Computing and Applications, doi.org/10.1007/s00521-018-3622-y, 1/15 (2018)
- 17) G.E.Hinton, O.Vinyals, J.Dean: *Distilling the Knowledge in a Neural Network*, arXiv:1503.02531 [stat.ML] (2014)

Table 2: 文献<sup>13)</sup>引用「TABLE 6 Category of AffectNetAgreement Between Two Annotators in Categorical Model of Affect (%)」

	Neutral	Happy	Sad	Surprise	Fear	Disgust	Anger	Contempt	None	Uncertain	Non-Face
Neutral	50.8	7	9.1	2.8	1.1	1	4.8	5.3	11.1	1.9	5.1
Happy	6.3	79.6	0.6	1.7	0.3	0.4	0.5	3	4.6	1	2.2
Sad	11.8	0.9	69.7	1.2	3.4	1.3	4	0.3	3.5	1.2	2.6
Surprise	2	3.8	1.6	66.5	14	0.8	1.9	0.6	4.2	1.9	2.7
Fear	3.1	1.5	3.8	15.3	61.1	2.5	7.2	0	1.9	0.4	3.3
Disgust	1.5	0.8	3.6	1.2	3.5	67.6	13.1	1.7	2.7	2.3	2.1
Anger	8.1	1.2	7.5	1.7	2.9	4.4	62.3	1.3	5.5	1.9	3.3
Contempt	10.2	7.5	2.1	0.5	0.5	4.4	2.1	66.9	3.7	1.5	0.6
None	22.6	12	14.5	8	6	2.3	16.9	1.3	9.6	4.3	2.6
Uncertain	13.5	12.1	7.8	7.3	4	4.5	6.2	2.6	12.3	20.6	8.9
Non-Face	3.7	3.8	1.7	1.1	0.9	0.4	1.7	0.4	1.2	1.4	83.9

Table 4: 分類結果に対する混合行列

		予測されたカテゴリ							
		Neutral	Happy	Sad	Surprise	Fear	Disgust	Anger	Contempt
実際のカテゴリ	Neutral	439	2	7	5	8	16	4	19
	Happy	7	462	2	0	4	12	1	12
	Sad	12	3	421	13	11	20	5	15
	Surprise	15	4	10	429	11	22	0	9
	Fear	10	2	10	10	452	8	3	5
	Disgust	8	2	3	5	8	462	5	7
	Anger	14	4	8	10	9	47	392	16
	Contempt	17	8	6	3	2	21	5	438

Table 6: AffectNet に対する分類精度 (再学習後, 再学習したカテゴリのみ記載)

カテゴリ名	再学習前		再学習後	
	訓練データ	テストデータ	訓練データ	テストデータ
Neutral	99.3%	87.8%	99.3%	90.8%
Sad	99.2%	84.2%	99.2%	90.3%
Surprise	99.4%	85.8%	99.4%	90.8%
Disgust	99.3%	92.4%	99.3%	92.4%
Anger	98.2%	78.4%	98.2%	90.9%
Contempt	98.8%	87.6%	98.8%	91.6%

# 様々な発火パターンを実現する Particle Swarm Optimization によるリカレントスパイクングニューラルネットワークの学習法

○黒江康明 (関西大学, 京都工芸繊維大学) 飯間等 (京都工芸繊維大学) 前田裕 (関西大学)

## Learning Method of Recurrent Spiking Neural Networks to Realize Various Firing Patterns by Particle Swarm Optimization

\*Y. Kuroe (Kansai University, Kyoto Institute of Technology), H. Iima (Kyoto Institute of Technology) and Y. Maeda (Kansai University)

**Abstract**— In artificial spiking neural networks (SNNs) the information processing and transmission are carried out by spike trains in a manner similar to the generic biological neurons. In biological neural networks of living organisms, various firing patterns of nerve cells have been observed, typical example of which are burst firings and periodic firings. In this paper we propose a learning method which can realize various firing patterns for recurrent SNNs (RSSNs). We have already proposed learning methods of RSSNs in which the learning problem is formulated such that the number of spikes emitted by a neuron and their firing instants coincide with the given desired ones. In this paper, in addition to that, we consider several desired properties of a target RSSN and proposes cost functions for realizing them. Since the proposed cost functions are not differentiable with respect to the learning parameters and their gradients do not exist, we propose a learning method based on the particle swarm optimization (PSO). The performance of the proposed method is demonstrated through numerical experiments.

**Key Words:** Spiking Neural Network, Firing Pattern, Learning Method, Particle Swarm Optimization, Burst Firing, Periodic Firing

### 1 はじめに

スパイクングニューラルネットワーク (以下 SNN) は、スパイク列の発生時刻あるいは時間間隔により情報を処理する点で生体に近く、近年活発に研究されている<sup>1)</sup>。SNN は連続信号と不連続なスパイク信号が混在したハイブリッドシステムとなっており、解析・設計が非常に困難である。そのため学習法の研究もあまり多くないが、これまで教師付き学習法として、リカレント SNN (以下 RSSN) に対する勾配法に基づく学習法<sup>2, 3)</sup> や階層型の SNN に対するバックプロパゲーション法と同様の勾配法に基づく学習法<sup>4)</sup> が提案されている。これらの学習法は勾配法に基づく方法なので、発生時刻を学習する問題など勾配が定義できる問題しか扱えない。ところが、SNN の学習問題においてはスパイクの発生時刻そのものよりその発生頻度、密度が問題となることが多く、この場合は勾配が定義できない。そこで著者らは、勾配の情報を用いない非線形最適化問題の解法の有効な1つである Particle Swarm Optimization<sup>5)</sup> (以下 PSO) を用いた、RSSN の学習法を先に提案した<sup>6)</sup>。PSO は目的関数の連続性や勾配を必要とせず様々な目的関数を設定できる。

一方、生体ニューロンにはバースト発火や周期発火などの、特徴的な発火パターンが多数存在することが知られている<sup>7)</sup>。また、これまでに観察されている生体ニューロンの発火パターン以外に、スパイクが発生する密度やスパイクの符号に着目するような様々な発火パターンが実現できると、その応用も広がると考えられる。たとえば SNN の応用例に、視覚系の特徴抽出機構のモデルを構築する研究<sup>8)</sup> がある。このモデルでは、物体の動きに対する光刺激にニューロンが応答することで運動方向選択性や動的視差を実現しており、ニューロンの応答の違いはスパイク列の発生する密度により表現される。

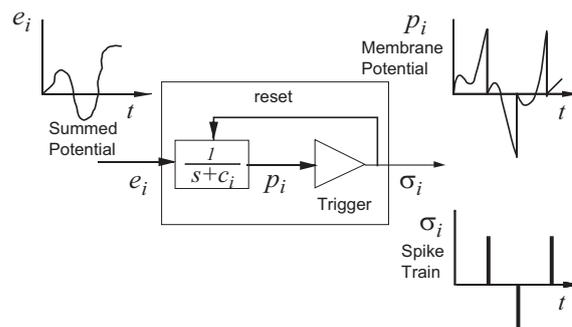


Fig. 1: Schematic of the firing mechanism of the integrate and fire type SN.

本論文では、PSO を用いた様々な発火パターンを実現するための SNN の学習法を提案する。PSO を用いることにより生体ニューロンに見られるバースト発火や周期発火含む様々な発火パターンを実現するための学習問題を定式化することができる。

### 2 スパイクングニューラルネットワーク

本論文ではスパイクングニューロン (以下 SN) のモデルとして代表的である Fig.1 に示す integrate-and-fire モデルを対象とする。

#### 2.1 発火機構のモデル

SNN の  $i$  番目のニューロン  $SN_i$  の発火機構の数学モデルは次式のように表される。すなわち、発火を促す入力刺激である  $e_i(t)$  が積分機構 (一次遅れ要素  $\frac{1}{s+c_i}$ ;  $c_i$  は定数) に入力され、内部状態  $p_i(t)$  の絶対値があるしきい値  $s_i (> 0)$  に達すると  $SN_i$  はスパイクを発し、内部状態を零にリセットする。なお、スパイクの表現には Dirac のデルタ関数  $\delta(t)$  を用いており、その符号はスパイクが発生する直前の内部状態  $p_i(t)$  の符号が保存

されるものとする。

$$\sigma_i(t) = \sum_{k_i=1}^{K_i} \varepsilon_{i,k_i} \times \delta(t - t_{i,k_i}) \quad (1)$$

$$t_{i,k_i} = \min[t : t > t_{i,k_i-1}, |p_i(t)| \geq s_i] \quad (2)$$

$$\varepsilon_{i,k_i} = \text{sgn}[p_i(t_{i,k_i}^-)] \quad (3)$$

$$\frac{dp_i(t)}{dt} = -c_i p_i(t) + e_i(t), \quad t_{i,k_i-1} < t < t_{i,k_i} \quad (4)$$

$$p_i(0) = p_i^0, \quad (5)$$

$$p_i(t_{i,k_i}^+) = 0, \quad k_i = 1, \dots, K_i, \quad (6)$$

ここで、 $\sigma_i(t)$  は  $\text{SN}_i$  の出力スパイク列、 $K_i$  は開始時刻 ( $t = t_0$ ) から終了時刻 ( $t = t_f$ ) までに  $\text{SN}_i$  が発した総スパイク数、 $t_{i,k_i}$  はニューロンが  $k_i$  ( $k_i = 1, 2, \dots, K_i$ ) 番目のスパイクを発した時刻 (ただし、 $t_{i,0} = 0$ )、 $\varepsilon_{i,k_i}$  は  $k_i$  番目のスパイクの符号である。

## 2.2 RSNN のモデル

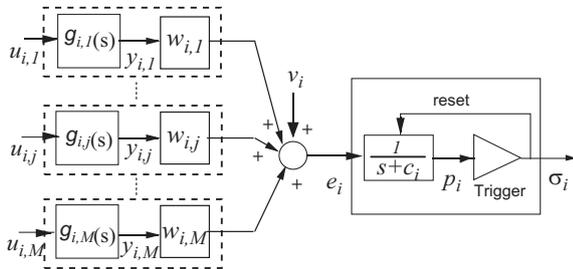


Fig. 2: Model of the connections of  $i$ th spiking neuron in the SNN.

本論文で対象とするのは、Fig.2に示す2.1節で説明した発火機構をもつニューロンが相互に結合したRSNNモデルである。ただし  $M$  はネットワークに含まれるニューロンの数で、Fig.2は  $i$  番目のニューロン  $\text{SN}_i$  を中心として描いた図である。各ニューロン  $\text{SN}_j$  からの出力信号  $u_{i,j}(t)$  は、遅延を表す伝達要素  $g_{i,j}(s)$  を通り、出力  $y_{i,j}(t)$  はシナプス結合荷重  $w_{i,j}$  により重み付けされる。さらにこれらの信号及び外部からの入力  $v_i(t)$  が加算され、 $\text{SN}_i$  の入力  $e_i(t)$  となる。

$$e_i(t) = \sum_{j=1}^M w_{i,j} y_{i,j}(t) + v_i(t), \quad (7)$$

$$u_{i,j}(t) = \sigma_j(t), \quad (8)$$

$$\frac{d\mathbf{x}_{i,j}(t)}{dt} = \mathbf{A}_{i,j} \mathbf{x}_{i,j}(t) + \mathbf{b}_{i,j} u_{i,j}(t) \quad (9)$$

$$y_{i,j}(t) = \mathbf{c}_{i,j} \mathbf{x}_{i,j}(t) \quad (10)$$

$$\mathbf{x}_{i,j}(0) = \mathbf{x}_{i,j}^0, \quad i, j = 1, \dots, M \quad (11)$$

$$g_{i,j}(s) = \mathbf{c}_{i,j} (s\mathbf{I} - \mathbf{A}_{i,j})^{-1} \mathbf{b}_{i,j},$$

ここでは、 $g_{i,j}(s)$  は状態空間表現として表しており、 $\mathbf{x}_{i,j}(t)$  は  $g_{i,j}(s)$  の  $N$  次元状態ベクトル、 $\mathbf{A}_{i,j}$ 、 $\mathbf{b}_{i,j}$ 、 $\mathbf{c}_{i,j}$  は  $N \times N$  行列、 $N \times 1$  ベクトル、 $1 \times N$  ベクトル、 $\mathbf{I}$  は  $N \times N$  の単位行列、 $\mathbf{x}_{i,j}^0$  は  $\mathbf{x}_{i,j}(t)$  の初期値である。

## 3 様々な発火パターンを実現する学習法

### 3.1 生体に見られる発火パターン例

脳に電極を取り付けて直流電流のパルスを入力すると、生体ニューロンの細胞膜電位はさまざまな反応を示す。そのなかでここでは二つの例、すなわちバースト発火と周期発火をとりあげる。バースト発火とはFig.3のように、発火回数が突発的に増減し、発火する時間区間と発火しない時間区間が明確に分かれ、発火期間においては急激にある程度の数を発火させるパターンである。周期発火はFig.4に示すように、一定の周期ごとに同じ波形を持続的に繰り返す発火パターンである。バースト発火や周期発火の他にも発火時刻、発火回数などによって様々な発火パターンがある。

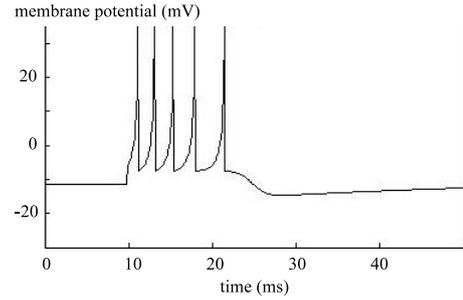


Fig. 3: An example of burst firing pattern.

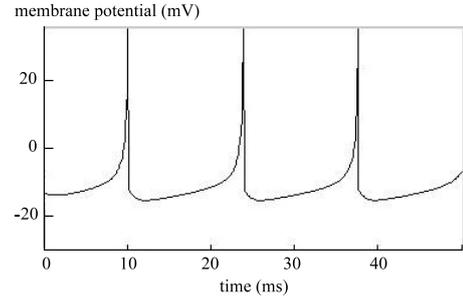


Fig. 4: An example of periodic firing pattern

### 3.2 学習問題の定式化

#### 3.2.1 様々な発火パターンを実現する学習問題

本節では、バースト発火や周期発火を含む発火パターンをSNNの学習によって実現するための学習問題を定式化する。先に述べたように生体ニューロンに見られるバースト発火は、発火する時間区間と発火しない時間区間をもつ発火パターンであり、これを実現するためにはどの時間区間でどのように発火が起こるかを考えなくてはならない。そこで、所望のスパイク列を時間区間ごとに分けて指定する学習問題を設定する。SNNが動作する開始時刻を  $t = t_0$ 、また終了時刻  $t = t_f$  とし、この区間  $0 \leq t < t_f$  を各  $\text{SN}$  ごとにくつかの小区間に分割する。 $i$  番目のニューロン  $\text{SN}_i$  に対する区間の分割数を  $S_i$  とし、各  $\text{SN}_i$  の  $tv_i$  ( $tv_i = 1, 2, \dots, S_i$ ) 番目の小区間は始点時刻を  $t_{i,tv_i}^s$ 、終点時刻を  $t_{i,tv_i}^e$  とし、 $t_{i,tv_i}^s \leq t < t_{i,tv_i}^e$  ( $tv_i = 1, 2, \dots, S_i$ ) とする。このとき、 $t_{i,tv_i}^s$  と  $t_{i,tv_i}^e$  は次式を満たす。

$$\begin{aligned} t_{i,tv_i}^e &= t_{i,tv_i+1}^s (i = 1, \dots, M; tv_i = 1, \dots, S_i - 1) \\ t_{i,1}^s &= t_0, t_{i,S_i}^e = t_f (i = 1, \dots, M) \end{aligned} \quad (12)$$

$$\begin{aligned} &\text{Minimize } J_1 \\ &\text{w.r.t. } \mathbf{X}_1 \end{aligned} \quad (14)$$

筆者らはすでに (1)~(11) 式で表される RSNN に対しその学習法を提案している<sup>2, 3)</sup>。ここでは時間区間  $[t_0, t_f]$  において各ニューロンが発生するスパイクの発生回数及び発生時刻を与えられた望みの発生回数及び発生時刻に一致させるような問題として学習問題を定式化している。本稿ではさらに、スパイクの発生時刻は問題とせずに発生回数を与えられた望みの発生回数に一致させること<sup>6)</sup>に加えて、発生回数の下限値ある望みの値とすること、発生回数の上限値あるいは下限値、あるいはその両方ある望みの値とすること、さらに発生するスパイクの符号を望みの符号に一致させることを目的として取り入れて学習問題を設定する。本論文では、バースト発火や周期発火を含めた様々な発火パターンを実現するために学習問題を次のように設定する。

#### 学習問題

(1)~(11) 式で表される RSNN において、各ニューロン  $SN_i$  の任意の数の任意の時間区間  $t_{i,tv_i}^s \leq t < t_{i,tv_i}^e$  で、以下のいずれかの項目が望みのスパイク列として与えられたとき、これらのスパイク列を発生する RSNN シナプス結合荷重の値を決定せよ。

- a) スパイクの発生回数と発生時刻
- b) スパイクの発生回数
- c) スパイクの発生回数の上限値
- d) スパイクの発生回数の下限値
- e) スパイクの発生回数の上限値と下限値
  - a') スパイクの発生回数, 発生時刻と符号
  - b') スパイクの発生回数と符号
  - c') スパイクの発生回数の上限値と符号
  - d') スパイクの発生回数の下限値と符号
  - e') スパイクの発生回数の上限値, 下限値と符号

ここで、項目 a)–e') のいずれかを指定された  $SN_i$  の集合を  $O$ 、 $SN_i$  で項目 a)–e') のいずれかを指定された時間区間番号の集合を  $U_i$  とし、時間区間  $t_{i,tv_i}^s \leq t < t_{i,tv_i}^e (S_i \in O, tv_i \in U_i)$  において、 $SN_i$  が発生するスパイクの発生回数を  $K_{i,tv_i}$ 、 $k_{i,tv_i}$  番目のスパイクの発生時刻を  $t_{i,k_{i,tv_i}}$  ( $k_{i,tv_i} = 1, 2, \dots, K_{i,tv_i}$ )、そのスパイクの符号を  $\epsilon_{i,k_{i,tv_i}}$  とする。

本稿での学習問題は、 $SN_i (i \in O)$  から時間区間  $t_{i,tv_i}^s \leq t < t_{i,tv_i}^e (tv_i \in U_i)$  で実際に発生するスパイクの発生時刻  $t_{i,k_{i,tv_i}}$ 、発生回数  $K_{i,tv_i}$ 、符号  $\epsilon_{i,k_{i,tv_i}}$  が指定した条件から外れた尺度を表す目的関数を定義し、これを  $J_{i,tv_i}(t_{i,k_{i,tv_i}}, K_{i,tv_i}, \epsilon_{i,k_{i,tv_i}})$  とし、その総和をとる次式の目的関数  $J_1$  を考える。

$$J_1 = \sum_{i \in O} \sum_{tv_i \in U_i} \alpha_{i,tv_i} J_{i,tv_i}(t_{i,k_{i,tv_i}}, K_{i,tv_i}, \epsilon_{i,k_{i,tv_i}}) \quad (13)$$

ここで、 $\alpha_{i,tv_i}$  は重みパラメータである。学習パラメータを  $\mathbf{X}_1 = (w_{1,1}, w_{1,2}, \dots, w_{i,j}, \dots, w_{M,M})$  とすると、本論文の学習問題は以下のような最適化問題として定式化できる。

なお、各目的関数  $J_{i,tv_i}$  の具体的な定義については 3.3 節で説明する。

#### 3.2.2 周期発火を実現する学習問題

ネットワークに持続的な周期現象を持たせるためには、そのネットワークは非線形ダイナミカルシステムである必要があり、(1)~(11) 式で表される RSNN はそのようなシステムの 1 つである。本項では、前項で設定した学習問題における様々な発火パターンがさらに周期的となる学習問題を考える。すなわち、所望の周期を  $T$  として周期的なスパイク列を発生するような RSNN を学習により実現する。周期的なスパイク列を実現するにはネットワークのダイナミクスが周期的である必要がある。このために (1)~(11) 式で表される RSNN が周期的であるためには、ネットワークの全ての状態が次の周期条件を満たす必要がある。

$$p_i(t) = p_i(t + T), \quad \mathbf{x}_{i,j}(t) = \mathbf{x}_{i,j}(t + T) \quad (15)$$

本論文では周期発火を実現するために、この条件を満たすように学習問題を定式化する。そのために、時間区間  $t_0 \leq t < t_0 + T$  内を  $S_i$  個の時間区間  $t_0 \leq t < t_{i,1}^e, \dots, t_{i,S_i}^e \leq t < t_{i,S_i}^e (= t_0 + T)$  に分割して任意の時間区間に対して前項の条件 a)–e') の望みのスパイク列を指定するとき、以降の時間区間  $t_0 + T \leq t < t_0 + 2T$ ,  $t_0 + 2T \leq t < t_0 + 3T$ , ... でも同じスパイク列を発生させ、(15) 式を満足するスパイク列が発生するような SNN のパラメータを決定する問題として設定する。ただし、周期性を持つことを可能とする初期値は未知であるため、学習パラメータはシナプス結合荷重  $w_{i,j}$  だけではなく、 $SN_i$  の内部状態の初期値  $p_i^0$  と  $SN_i$  間の伝達要素の内部状態の初期値  $x_{i,j}^{0,n} (n = 1, \dots, N)$  から成るベクトルも学習パラメータとし、これらすべてからなるベクトル  $\mathbf{X}_2 = (w_{1,1}, \dots, w_{i,j}, \dots, w_{M,M}, p_1^0, \dots, p_M^0, x_{1,1}^{0,1}, \dots, x_{i,j}^{0,n}, \dots, x_{M,M}^{0,N})$  を学習パラメータとする。

それぞれの時間区間  $t_{i,tv_i}^s \leq t < t_{i,tv_i}^e$  で望みのスパイク列を得るための目的関数  $J_1$  を設定するとともに、周期的スパイク列を得るための目的関数として、SNN に与えた初期値が周期的であるかどうかを表す指標を  $J_2(p_i^0, x_{i,j}^{0,n})$  として、これも目的関数として設定する。これらの  $J_1, J_2$  を用いて、周期的スパイク列を実現する学習問題は以下の最適化問題として定式化できる。

$$\begin{aligned} &\text{Minimize } J_1 + \beta J_2 \\ &\text{w.r.t. } \mathbf{X}_2 \\ &\text{subject to } |p_i^0| < s_i \end{aligned} \quad (16)$$

ここで、 $J_1$  は (13) 式で与えられ、 $\beta$  は重みパラメータである。 $J_2$  の具体的な定義については 3.3 節で説明する。なお制約条件  $|p_i^0| < s_i$  は、初期状態  $p_i^0$  の絶対値がしきい値  $s_i$  より大きいと、ネットワークの開始時刻  $t = t_0$  にこの条件を満たすニューロンが必ず発火するので、これを防ぐために設けた条件である。

### 3.3 目的関数の設定

本論文で最適化アルゴリズムとして用いる PSO は目的関数の連続性や勾配を必要とせず目的関数値のみを用いる方法で、制約が少なく様々な目的関数を扱うことができる。そのため、種々の問題をどのように最適化問題と設定し、またそれらの目的関数をどのように設定するかが重要となる。ここでは、前項で設定した学習問題の項目 a)–e) および周期条件である (15) 式を実現するための目的関数を提案する。

#### 3.3.1 発火時刻に関する目的関数

時間区間  $t_{i,tv_i}^s \leq t < t_{i,tv_i}^e$  において、各ニューロン  $SN_i$  が発生するスパイクの望みの発生回数を  $K_{i,tv_i}^d$ 、望みの発生時刻を  $t_{i,k_i,tv_i}^d$  ( $k_i,tv_i=1,\dots,K_{i,tv_i}^d$ ) とする。このとき、各ニューロン  $SN_i$  が発生するスパイクの発生回数と時刻が望みのそれらに一致するよう目的関数  $J_{11}$  を次のように設定する。

$$J_{11} = \sum_{k_i,tv_i=1}^{K_{i,tv_i}^{min}} |t_{i,k_i,tv_i}^d - t_{i,k_i,tv_i}|^{ex} + J_{111} \quad (17)$$

$$J_{111} = \begin{cases} \sum_{k_i,tv_i=K_{i,tv_i}^d+1}^{K_{i,tv_i}} |t_{i,k_i,tv_i}^p - t_{i,k_i,tv_i}|^{ex}, & (K_{i,tv_i} > K_{i,tv_i}^d) \\ \sum_{k_i,tv_i=K_{i,tv_i}+1}^{K_{i,tv_i}^d} |t_{i,k_i,tv_i}^d - t_{i,K_{i,tv_i}}|^{ex}, & (K_{i,tv_i} < K_{i,tv_i}^d) \\ 0, & (K_{i,tv_i} = K_{i,tv_i}^d) \end{cases} \quad (18)$$

ここで、 $K_{i,tv_i}^{min} = \min\{K_{i,tv_i}, K_{i,tv_i}^d\}$ 、 $ex$  は差の何乗をとるかを決めるパラメータであり、通常は  $ex = 1$  あるいは  $ex = 2$  と選ばれる。また、 $J_{111}$  はスパイクの発生回数が一致しない場合のペナルティ関数である<sup>2, 3)</sup>。実際に発生したスパイクの数が望みの数より多い、すなわち  $K_{i,tv_i} > K_{i,tv_i}^d$  の場合、過剰に発生したスパイクを抑えるために終了時刻  $t_f$  よりも十分大きい値の時刻  $t_{i,k_i,tv_i}^p$  を教師信号とし、過剰に発生したスパイクの発生時刻との誤差をペナルティ項としている。 $K_{i,tv_i} < K_{i,tv_i}^d$  の場合、実際に発生する最後のスパイクの発生時刻  $t_{i,K_{i,tv_i}}$  に不足している  $K_{i,tv_i}^d - K_{i,tv_i}$  個のスパイクが同時に発生したと考え、望みのスパイクの発生時刻との誤差をペナルティ項としている。

#### 3.3.2 発火回数の上限値に関する目的関数

時間区間  $t_{i,tv_i}^s \leq t < t_{i,tv_i}^e$  において、各ニューロン  $SN_i$  が発生するスパイクの発生回数の望みの上限値を  $K_{i,tv_i}^{du}$  とする。このとき、目的関数  $J_{i,tv_i}$  はスパイクの発生回数が  $K_{i,tv_i}^{du}$  を上回った回数に応じて値が増加するように設定すればよい。そこで目的関数  $J_{12}$  を次式のように設定する。

$$J_{12} = \max(K_{i,tv_i} - K_{i,tv_i}^{du}, 0)^{ex} \quad (19)$$

#### 3.3.3 発火回数の下限値に関する目的関数

時間区間  $t_{i,tv_i}^s \leq t < t_{i,tv_i}^e$  において、各ニューロン  $SN_i$  が発生するスパイクの発生回数の望みの下限値を  $K_{i,tv_i}^{dl}$

とする。このとき目的関数  $J_{i,tv_i}$  はスパイクの発生回数が  $K_{i,tv_i}^{dl}$  を下回った回数に応じて値が減少するように設定すればよい。そこで目的関数  $J_{13}$  を次式のように設定する。

$$J_{13} = \max(K_{i,tv_i}^{dl} - K_{i,tv_i}, 0)^{ex} \quad (20)$$

#### 3.3.4 スパイクの符号に関する目的関数

時間区間  $t_{i,tv_i}^s \leq t < t_{i,tv_i}^e$  において、各ニューロン  $SN_i$  が発生するスパイクの望みのスパイクの符号を  $\epsilon_{i,k_i,tv_i}^d$  とする。2.1 節で説明したスパイクの発生機構より、 $SN_i$  が発生するスパイクの符号が望みの符号  $\epsilon_{i,k_i,tv_i}^d$  と一致するためには、望みの発生時刻が与えられている場合

$$p(t_{i,k_i,tv_i}^{d-}) = \epsilon_{i,k_i,tv_i}^d s_i.$$

を満たす必要があり、また望みの発生時刻が与えられている場合

$$p(t_{i,k_i,tv_i}) = \epsilon_{i,k_i,tv_i}^d s_i.$$

を満たす必要がある。従って望みの符号を持たせる目的関数  $J_{14}$  は 2 種類考えられ、これらを  $J_{141}$ 、 $J_{142}$  とし、次のように設定する。

$$J_{141} = \sum_{k_i,tv_i=1}^{K_{i,tv_i}^d} |\epsilon_{i,k_i,tv_i}^d s_i - p(t_{i,k_i,tv_i}^{d-})|^{ex} \quad (21)$$

$$J_{142} = \sum_{k_i,tv_i=1}^{K_{i,tv_i}^{min}} |\epsilon_{i,k_i,tv_i}^d s_i - p(t_{i,k_i,tv_i}^-)|^{ex} \quad (22)$$

#### 3.3.5 スパイク列を周期的にするための目的関数

発生スパイク列を周期  $T$  の周期パターンにするためには、(15) 式の条件を満たすようにすればよい。従って周期  $T$  の周期的スパイク列を実現するための目的関数  $J_2$  は、次式のように設定する。

$$J_2 = \sum_{n_T=1}^{N_T} \sum_{i=1}^M \left( |p_i^0 - p_i(t_0 + n_T T)|^{ex} + \sum_{j=1}^M \sum_{n=1}^N |x_{i,j}^{0,n} - x_{i,j}^n(t_0 + n_T T)|^{ex} \right) \quad (23)$$

ここで、 $N_T$  は初期時刻から何周期目かを表す整数で、理論上は  $N_T = 1$  で十分であるが、数値計算上の精度を考慮して導入している。

なお (16) 式の最適化問題において、 $|p_i^0| < s_i$  を満たさない場合に、制約条件に対してペナルティ  $J_{p0}$  を次式のように定義する。

$$if |p_i^0| \geq s_i \quad J_{p0} = \max(|p_i^0| - s_i, 0)^{ex} \quad else \quad J_{p0} = 0 \quad (24)$$

このペナルティ関数を用いて (16) 式の目的関数  $J_2$  を  $J_2 + \gamma J_{p0}$  と置き換え、(16) 式の制約付き最適化問題を、制約なしの最適化問題として解くことにする。

### 3.4 様々な発火パターンを実現するための目的関数

3.2.1 項で設定した学習問題の項目 a)–e) を実現するためには以上のように定義した目的関数  $J_{11}$ 、 $J_{12}$ 、 $J_{13}$  および  $J_{14}$  を適切に選びそれらを組み合わせればよい。

各項目 a)–e) は、目的関数を次のようにすることにより実現できる。

- a)  $J_{11}$  b)  $J_{12} + J_{13}$  ( $K^{du} = K^{dl}$  とする)  
 c)  $J_{12}$  d)  $J_{12}$  e)  $J_{12} + J_{13}$   
 a')  $J_{11} + J_{14}$  b')  $J_{12} + J_{13} + J_{14}$  ( $K^{du} = K^{dl}$  とする)  
 c')  $J_{12} + J_{14}$  d')  $J_{12} + J_{14}$  e')  $J_{12} + J_{13} + J_{14}$

またこれらの発火パターンをさらに周期的にする場合、これらに (23) 式の目的関数を組み合わせればよい。

### 3.5 PSO に基づく SNN の学習法

(17) 式で定義される目的関数  $J_{11}$  は ネットワークパラメータ  $\mathbf{X}_1 = (w_{1,1}, w_{1,2}, \dots, w_{i,j}, \dots, w_{M,M})$  に関して微分可能で勾配が存在する。文献 2, 3) では、この目的関数を最小化するため勾配法に基づく学習法が提案されている。一方、目的関数  $J_{12}, J_{13}$  および  $J_{14}$  は ネットワークパラメータ  $\mathbf{X}_1$  に関して微分可能ではなく勾配が定義できない。従って本論文では (14) 式および (16) 式の最適化問題を解くために、Particle Swarm Optimization method (PSO)<sup>5)</sup> を用いることにする。ここでは PSO の概略を説明する。

目的関数を  $J(\mathbf{X})$  とし、決定変数  $\mathbf{X}$  の次元を  $N_x$ ,  $\mathbf{X} = (x_1, \dots, x_n, \dots, x_{N_x})$  とし、 $J(\mathbf{X})$  を最少とする決定変数を求める最適化問題を考える。PSO は、複数のメンバー particle からなる swarm を用意し、すべての particle が最適化問題の解を探索するために繰り返し用いられる。particle の数を  $P$  とし、 $\mathbf{X}^p = (x_1^{p,k}, \dots, x_n^{p,k}, \dots, x_{N_x}^{p,k})$  を  $p$  番目の particle ( $p = 1, 2, \dots, P$ ) の  $k$  番目の探索の繰り返し回数における解候補とする。  $k+1$  番目における解候補は、PSO の更新式に基づいて以下のように計算される。

$$x_n^{p,k+1} = x_n^{p,k} + \Delta x_n^{p,k+1} \quad (25)$$

$$\begin{aligned} \Delta x_n^{p,k+1} &= W \Delta x_n^{p,k} \\ &+ C_1 \text{rand}_1()^{p,k} (pbest_n^{p,k} - x_n^{p,k}) \\ &+ C_2 \text{rand}_2()^{p,k} (gbest_n^k - x_n^{p,k}) \end{aligned} \quad (26)$$

ここで、更新量  $\Delta \mathbf{X}^p = (\Delta x_1^p, \dots, \Delta x_n^p, \dots, \Delta x_{N_x}^p)$  は  $p$  番目の particle の速度ベクトルと呼ばれる。 $\text{rand}_1()^{p,k}, \text{rand}_2()^{p,k}$  は 0 から 1 の間に分布する一様乱数、 $W, C_1, C_2$  は重み係数である。また、 $pbest_n^{p,k} = (pbest_1^{p,k}, \dots, pbest_n^{p,k}, \dots, pbest_{N_x}^{p,k})$  は Particle  $p$  が  $k$  回目までに発見した最良解、 $gbest_n^k = (gbest_1^k, \dots, gbest_n^k, \dots, gbest_{N_x}^k)$  は群れ全体が  $k$  回目までに発見した最良解であり、次式で与えられる。

$$pbest_n^{p,k} = x_n^{p,k^*} \quad (27)$$

$$gbest_n^k = pbest_n^{p^*,k} \quad (28)$$

$$k^* = \arg \min_{1 \leq k' \leq k} J(\mathbf{X}^{p,k'}) \quad (29)$$

$$p^* = \arg \min_{1 \leq p \leq P} J(pbest_n^{p,k}) \quad (30)$$

## 4 数値実験

### 4.1 学習問題と実験条件

次の 4 つの問題を考え実験を行った。

**実験 1:** 最初の実験で対象とするネットワークは、Fig.5 に示す 5 つのスパイクニューロン  $SN_i (i = 1, \dots, 5)$  が

相互に結合し、それに 1 つの入力ニューロン  $SN_{input}$  が各ニューロンにトリガー入力を与えるために結合している RSNN である。ここでトリガー入力は  $v_i(t) = \delta(0)$  のように与える。この RSNN に学習させたい望みの発火パターンを Table 1 に示す。この表に示すように時間区間  $[0.0, 5.0)$  において、 $SN_1$  に発生させるスパイクは数は 2 で、時刻  $t = 1.0$  に負のスパイクを発生させ、時刻  $t = 1.5$  に正のスパイクを発生させる。 $SN_2$  に発生させるスパイクの数は 1 で、時刻  $t = 2.0$  に正のスパイクを発生させる。他のニューロン  $SN_3, SN_4$  および  $SN_5$  には望みの発火パターンは与えていない。この実験は、3.2.1 項における項目 a') を指定した学習問題を扱っている。

**実験 2:** 対象とするネットワークは、実験 1 のそれと同じである。この実験では、時間区間  $[0.0, 5.0)$  を二つの小区間  $[0.0, 2.5)$  と  $[2.5, 5.0)$  に分割し、それぞれの区間に対し学習させたい望みの発火パターンを Table 2 に示すように与える。表から分かるように、各ニューロン  $SN_1, SN_2, SN_3$  および  $SN_4$  に対し発火の個数、個数の上限値、個数の下限のみ望みのパターンとして与え、発火時刻は指定していない。この実験では、3.2.1 項における項目 b), c), d) および e) を指定した学習問題を扱っている。

**実験 3:** この実験では、3.2.1 節における項目 b) を指定した学習問題で、望みのスパイクの数と望みの符号をもつバースト発火を実現する学習問題を扱っている。対象とするネットワーク実験 1 と 2 と同じ Fig. 5 に示すもので、時間区間  $[0.0, 5.0)$  を 3 つの小区間  $[0.0, 1.0), [1.0, 1.5), [1.5, 5.0)$  についてそれぞれ望みの発火パターンを Table 3 に示すように与える。すなわち  $SN_1$  に小区間  $[1.0, 1.5)$  のみに望みの数のスパイクと望みの符号を持つようなスパイクを発生させ、その他の小区間  $[0.0, 1.0)$  および  $[1.5, 5.0)$  には発火させないバースト発火を実現させる。表に示すように三つの条件 I, II および III でそれぞれ異なる望みのスパイク数と望みの符号のバースト発火を実現する問題である。

**実験 4:** この実験では、3.2.1 項における項目 b) を指定し、さらにそれを周期的にする周期発火を実現する学習問題を扱っている。対象とするネットワークは、Fig. 6 に示すような二つのニューロンが相互に結合している RSNN である。このようにした理由は、一般に、神経振動子の実現にこのような二つのニューロンが相互に結合しているネットワークがよく用いられるからである。時間区間  $[0.0, 20.0)$  を 5 つの小区間  $[0.0, 4.0), [4.0, 8.0), [8.0, 12.0), [12.0, 16.0)$  および  $[16.0, 20.0)$  に分割し、それぞれの区間に対し望みの発火パターンを Table 2 のように与えたとともに、これらの発火パターンが周期  $T = 20$  の周期パターンとなるよう周期条件  $p_i(0) = p_i(20)$ ,  $x_{i,j}(0) = x_{i,j}(20)$  を満たすよう学習させる。この実験においては、Table 2 に示すように二つの条件 I および II で、それぞれ望みのスパイク数が異なる周期発火を実現する。

上記の学習問題を解くために、(14) 式および (16) 式の最適化問題の目的関数を適切に設定する必要があり、各実験においてそれぞれ、次のように目的関数を選んで学習を実行することにする。

$$\text{Ex. 1: } J = \sum_{i \in O} \sum_{tv_i \in U_i} J_{11} + J_{141} + J_{142}$$

$$\text{Ex. 2: } J = \sum_{i \in O} \sum_{tv_i \in U_i} J_{12} + J_{13}$$

$$\text{Ex. 3-I,II: } J = \sum_{i \in O} \sum_{tv_i \in U_i} J_{12} + J_{13} + J_{142}$$

$$\text{Ex. 3-III: } J = \sum_{i \in O} \sum_{tv_i \in U_i} J_{12} + J_{13}$$

$$\text{Ex. 4: } J = \sum_{i \in O} \sum_{tv_i \in U_i} J_{12} + J_{13} + J_2 + \gamma J_{p0}$$

ただし, Ex. 3-I,IIにおける $J_{12}$ と $J_{13}$ の $K_{i,tv_i}$ は, $K_{i,tv_i}^{sign}$ と置き換えて実験をおこなった. $K_{i,tv_i}^{sign}$ は $SN_i$ が発火したスパイクの数のうちその符号が望みの符号となっている数である.

各実験においてパラメータは次のように設定した. SNNのパラメータはすべての例題で, $c_i = 0.2$ , $s_i = 1.0$ とし, $g_{i,j}(s)$ は指数的に減衰する2つの関数の差がよく用いられることから $N = 2$ として, $A_{i,j} = \begin{pmatrix} -3.0 & 0.0 \\ 0.0 & -6.0 \end{pmatrix}$ , $\mathbf{b}_{i,j} = \begin{pmatrix} 1.0 \\ 1.0 \end{pmatrix}$ , $\mathbf{c}_{i,j} = (1.0, -1.0)$ とした. 実験1,2,および3では内部状態の初期値を $p_i^0 = 0.0$ , $\mathbf{x}_{i,j}^0 = \begin{pmatrix} 0.0 \\ 0.0 \end{pmatrix}$ とした.

全ての実験において,各目的関数の指数パラメータ $ex$ を2とした.また,実験4の $J_2$ のパラメータ $N_T$ を $N_T = 1$ ,重みパラメータ $\gamma$ を $\gamma = 25$ とした. PSOの更新式のパラメータについては, $(W, C_1, C_2) = (0.7, 1.4, 1.4)$ , Particleの数を $P = 100$ あるいは $P = 200$ ,学習最大回数を $T_{max} = 5000$ あるいは $T_{max} = 10000$ とし,解候補を $T_{max}$ 回更新することを終了条件とした.各Particleの初期解候補,初期速度として, $w_{i,j}^{p,0}$ , $\Delta w_{i,j}^{p,0}$ は $[-10, 10]$ の範囲でランダムに決定した.また,実験4では $p_i^0$ , $\Delta p_i^0$ , $x_{i,j}^{0,n}$ , $\Delta x_{i,j}^{0,n}$ は $s_i = 1.0$ であることを考慮して, $[-1, 1]$ の範囲でランダムに決定した.

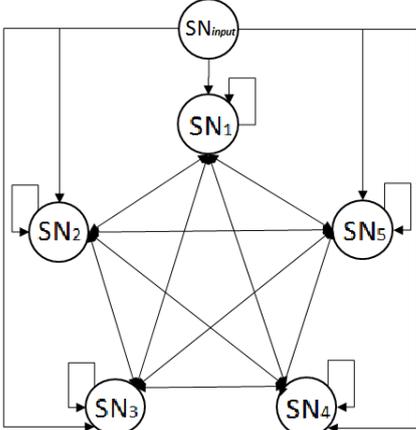


Fig. 5: Fully connected five neurons  $SN_i (i = 1, 2, \dots, 5)$  and one input neuron  $SN_{input}$ .

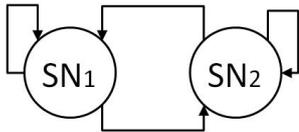


Fig. 6: RSNN consists of mutually connected two neurons  $SN_i (i = 1, 2)$ .

Table 1: Desired Firing Sequences (Ex. 1)

Ex. 1 ( $S_1, \dots, S_5 = 1, t_f = 5.0$ )	
$(t_{i,tv_i}^s, t_{i,tv_i}^e)$	0.0, 5.0)
$SN_1$	$K_{1,1}^d = 2, t_{1,1}^d = 1.0, t_{1,2}^d = 1.5,$ $\epsilon_{1,1}^d = -, \epsilon_{1,2}^d = +$
$SN_2$	$K_{2,1}^d = 1, t_{2,1}^d = 2.0, \epsilon_{2,1}^d = +$

Table 2: Desired Firing Sequences (Ex. 2)

Ex. 2 ( $S_1, S_2 = 2, t_f = 5.0$ )		
$(t_{i,tv_i}^s, t_{i,tv_i}^e)$	0.0, 2.5)	2.5, 5.0)
$SN_1$	$K_{1,1}^d = 8$	$K_{1,2}^d = 3$
$SN_2$	$K_{2,1}^d = 8$	$K_{2,2}^d = 3$
$SN_3$	$K_{3,1}^{du} = 10$	$K_{3,2}^{du} = 10$
$SN_4$	$K_{4,1}^{dl} = 10, K_{4,1}^{du} = 5$	$K_{4,2}^{dl} = 20, K_{4,2}^{du} = 15$

Table 3: Desired Firing Sequences (Ex. 3)

Ex. 3 ( $S_1 = 3, S_2, \dots, S_5 = 1, t_f = 5.0$ )				
	$(t_{i,tv_i}^s, t_{i,tv_i}^e)$	0.0, 1.0)	1.0, 1.5)	1.5, 5.0)
I	$SN_1$	$K_{1,1}^d = 0$	$K_{1,2}^d = 10,$ $\epsilon_{1,2}^d = +$	$K_{1,3}^d = 0$
II	$SN_1$	$K_{1,1}^d = 0$	$K_{1,2}^d = 10,$ $\epsilon_{1,2}^d = -$	$K_{1,3}^d = 0$
III	$SN_1$	$K_{1,1}^d = 0$	$K_{1,2}^d = 20,$	$K_{1,3}^d = 0$

## 4.2 実験結果と考察

**実験1の結果:** 学習後のネットワークを,入力ニューロン $SN_{input}$ のトリガー信号入力を学習時と同じにしてシミュレーションした結果の内部状態 $p_1(t)$ および $p_2(t)$ の時間波形をそれぞれFig. 7とFig. 8に示す. 図より分かるように時間区間 $[0.0, 5.0)$ において, $SN_1$ は時刻 $t = 1.0$ 付近で負のスパイクを発生し,時刻 $t = 1.5$ 付近で正のスパイクを発生し,また $SN_2$ は $t = 1.0$ 付近で正のスパイクを発生させている.これはTable 1と一致し,学習が正しく行われていることが分かる.

**実験2の結果:** 先と同様に学習後のネットワークをシミュレーションした結果の内部状態 $p_1(t)$ , $p_2(t)$ , $p_3(t)$ および $p_4(t)$ の時間波形をそれぞれ, Fig.9, Fig.10, Fig. 11, Fig. 12に示す.これらの図より各ニューロン $SN_1$ , $SN_2$ , $SN_3$ および $SN_4$ は,それぞれTable 2示す望みの発火個数,個数の望みの上限値,望みの下限値どおりに発火しており,正しく学習できていることがわかる.

**実験3の結果:** この実験で扱っているのはバースト発火を実現する問題である.先と同様に学習後のネットワークをシミュレーションした結果の内部状態 $p_1(t)$ の時間波形をそれぞれ, Fig. 13, Fig. 14およびFig. 15に示す. Fig. 13はTable 3の条件Iの結果で, $[1.0, 1.5)$ のみに10個の正のスパイクを発生させる, Fig. 14は条件IIの結果で10個の負のスパイクを発生させる,またFig. 15は条件IIIの結果で符号を指定しない20個のスパイクを発生させる問題の結果である.それぞれ所望のバースト発火ができており,提案法により正しく学習されていることがわかる.

**実験4の結果:** この実験で扱っているのは周期発火を実現する問題である.学習後に得られたすべての結合重みとすべての状態変数の初期状態を用いてネットワー

Table 4: Desired Periodic Firing Sequences (Ex. 4

Ex. 4-I ( $S_1 = 5, t_f = 20.0$ )			
$t_{i,tv_i}^s, t_{i,tv_i}^e$	0.0, 4.0)	4.0, 8.0)	8.0, 12.0)
SN <sub>1</sub>	$K_{1,1}^d = 4$	$K_{1,2}^d = 4$	$K_{1,3}^d = 4$
$t_{i,tv_i}^s, t_{i,tv_i}^e$	12.0, 16.0)	16.0, 20.0)	
SN <sub>1</sub>	$K_{1,4}^d = 4$	$K_{1,5}^d = 4$	

Ex. 4-II ( $S_1 = 5, t_f = 20.0$ )			
$t_{i,tv_i}^s, t_{i,tv_i}^e$	0.0, 4.0)	4.0, 8.0)	8.0, 12.0)
SN <sub>1</sub>	$K_{1,1}^d = 2$	$K_{1,2}^d = 4$	$K_{1,3}^d = 2$
$t_{i,tv_i}^s, t_{i,tv_i}^e$	12.0, 16.0)	16.0, 20.0)	
SN <sub>1</sub>	$K_{1,4}^d = 4$	$K_{1,5}^d = 2$	

クをシミュレーションした結果の内部状態  $p_1(t)$  の時間波形をそれぞれ, Fig.16 および Fig.17 に示す. Fig. 16 は Table 4 の条件 I の結果で, 各小区間に 4 個ずつのスパイクを発火させる, Fig. 17 は条件 II の結果で, 各小区間にそれぞれ 2, 4, 2, 4, 2 個のスパイクを発火させ, しかもそれぞれの発火パターンを周期的にした結果である. それぞれ所望の周期発火パターンが実現できており, 提案法により正しく学習されていることがわかる.

Fig. 18 は横軸は PSO の更新回数, 縦軸は目的関数値として学習による目的関数の収束の様子を, 実験 4 条件 II の実験で得られた例を示したものである. 図より非常に効率よく学習できているのが分かる.

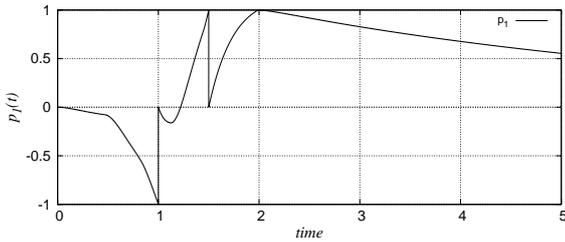


Fig. 7: Time evolution of  $p_1(t)$  after learning in Ex. 1.

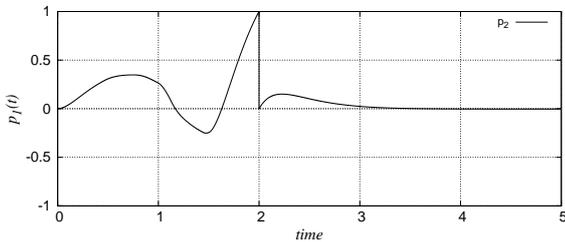


Fig. 8: Time evolution of  $p_2(t)$  after learning in Ex. 1.

## 5 おわりに

本論文では RSNN を対象として, PSO を用いた様々な発火パターンを実現するための学習法を提案した. 生体ニューロンのバースト発火やスパイクが発生する密度, スパイクの符号に着目する様々な発火パターン, またそれらが周期的になる周期発火を実現するための学

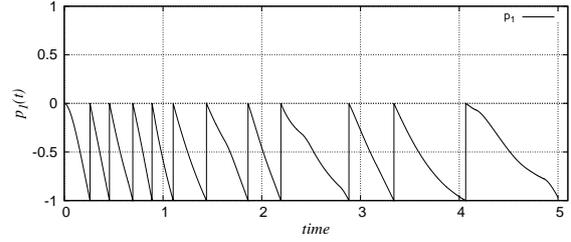


Fig. 9: Time evolution of  $p_1(t)$  after learning in Ex. 2.

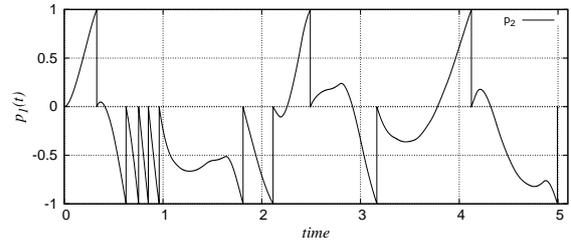


Fig. 10: Time evolution of  $p_2(t)$  after learning in Ex. 2.

習問題を定式化し, それらに応じて目的関数を提案した. いくつかの問題に対し, 数値実験を行うことにより提案法の有用性を確認した.

謝辞: 本取組の一部は, 2018 年度関西大学教育研究高度化促進費において, 課題「革新的なイノベーション創生を目指した取り組み」として促進費を受け, その成果を公表するものである. また本研究の一部は, 日本学術振興会科学研究費補助金 (18K11483) の援助を受けて行われた.

## 参考文献

- 1) W.Maass and C.Bishop(Eds.) : Pulsed Neural Networks, MIT Press (1998)
- 2) K.Selvaratnam, Y.Kuroe and T.Mori:Learning Methods of Recurrent Spiking Neural Networks — Transient and Oscillatory Spike Trains, システム制御情報学会論文誌, ol.13, No.3, pp.95-104 (2000)
- 3) Y. Kuroe, and T. Ueyama: Learning Methods of Recurrent Spiking Neural Networks Based on Ad-

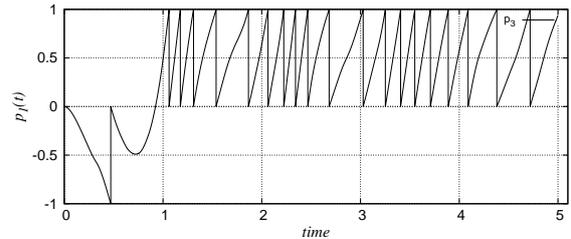


Fig. 11: Time evolution of  $p_3(t)$  after learning in Ex. 2.

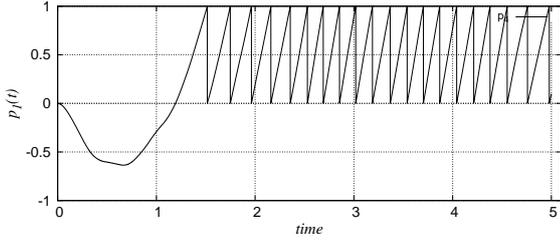


Fig. 12: Time evolution of  $p_4(t)$  after learning in Ex. 2.

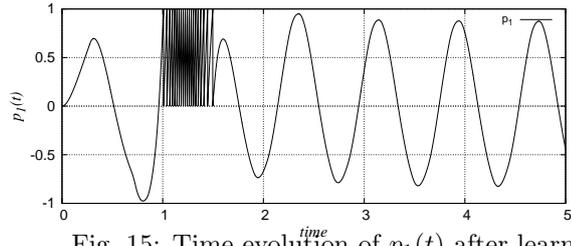


Fig. 15: Time evolution of  $p_1(t)$  after learning in Ex. 3-III.

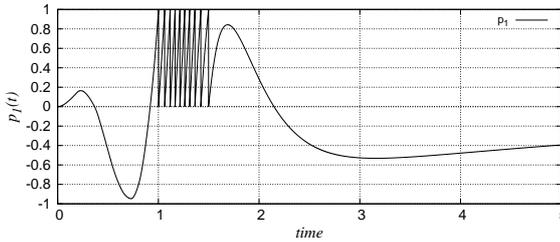


Fig. 13: Time evolution of  $p_1(t)$  after learning in Ex. 3-I.

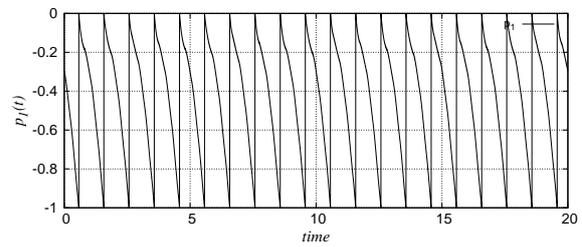


Fig. 16: Time evolution of  $p_1(t)$  after learning in Ex. 4-I.

- oint Equations Approach, Proc. of WCCI 2010 IEEE World Congress on Computational Intelligence, pp.2561-2568, 2010.
- 4) S.M.Bohte, J.N.Kok and H.L.Poutre : Error-Backpropagation in Temporally Encoded Networks of Spiking Neurons, Neurocomputing, ol.48, Issues 1-4, pp.17-37 (2002)
  - 5) J.Kennedy and R.C.Eberhart : Particle swarm optimization, Proc. of IEEE International Conference on Neural Networks, pp.1942-1948 (1995)
  - 6) 山本, 黒江, 飯間: Particle Swarm Optimization によるリカレントスパイクニューラルネットワークの学習法, 計測自動制御学会論文集, ol.46, No.11, pp.685-691 (2010)
  - 7) E.M. Izhikevich : Which model to use for cortical spiking neurons?, IEEE Transactions on Neural Networks, ol.15, No.5, pp.1063-1070 (2004)
  - 8) 木村, 黒江, 小寺, 村田: スパイクニューラルネットワークを用いた視覚系の特徴抽出モデルの構築, 計測自動制御学会論文集, ol.45, No.11, pp.612-619 (2009)

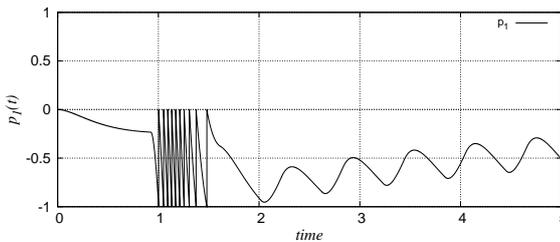


Fig. 14: Time evolution of  $p_1(t)$  after learning in Ex. 3-II.

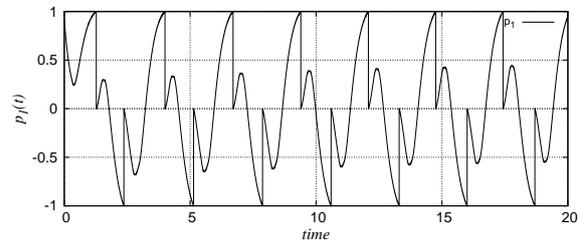


Fig. 17: Time evolution of  $p_1(t)$  after learning in Ex. 4-II.

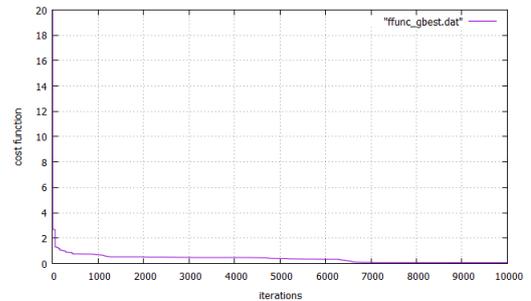


Fig. 18: Variation of the cost function  $J$  during learning obtained from the result Ex. 4-II.

# 温熱環境が心的要因と作業効率に及ぼす影響の評価

○堀田健斗 満倉靖恵 (慶應義塾大学)

折戸真理 伏江遼 古橋拓也 (三菱電機株式会社)

## Effect of Thermal Environment for Mental Factor and Work Efficiency

\*Kento Horita, Yasue Mitsukura (Keio University)

Mari Orito, Ryo Fushie, Takuya Furuhashi (Mitsubishi Electric Co. Ltd)

**Abstract**— The purpose of this study is to clarify the effect of thermal environment on human. It is said that improvement of workspace leads to increase work efficiency. In this paper, we clarified the relationship between work performance and mental factors caused by thermal environment while rainy season using prefrontal cortex electroencephalogram (EEG) and electrocardiogram (ECG). As a result, in a hot and humid environment, adding air flow improved concentration and alertness with low stress. These results suggested that work performance was related to changes in mental factors during work caused by thermal environment.

### 1 はじめに

本研究の目的は、生体信号を用いて温熱環境が心的要因と作業効率に及ぼす影響を明らかにすることである。近年、作業効率を向上させるために作業空間の改善が課題とされており、作業効率を高める環境の特定を試みる研究が増えている。先行研究では複数の環境においてタスクを実行し、その成績が良い環境を作業効率が高い環境と定義している<sup>1)</sup>。しかし、このように定義された作業効率のよいとされる環境は、ストレスや疲労などの蓄積による心的要因が原因の作業効率低下を客観的に考慮できていない。したがって、温熱環境による心的要因の変化と作業効率の関係性を明らかにする必要があると考える。本研究では、温熱環境によるストレスの変化とタスク成績を考慮した作業空間の評価を行った。ストレスの評価にはストレス負荷と関係があるとされている前頭前野部位の脳波<sup>2)</sup>とストレス指標である LF/HF を心電から算出して用いた<sup>3)</sup>。この目的を遂行することで、一時的な作業効率向上だけでなく、長期的な作業効率向上を目指す。

### 2 実験

本研究では、梅雨の時期の温熱環境に着目した。被験者数は28名(男性:20名, 女性:8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。実験では温熱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, 心電計測, 認知タスクを行った。脳波計測にはMindWave Mobile<sup>4)</sup> (Neuro Sky社)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)。心電計測にはPOLAR H10<sup>5)</sup> (POLAR社)を用いた (Fig. 3参照)。取得した心電データからPOLAR V800<sup>6)</sup> (POLAR社)を用いて心拍間隔(R-R interval: RRI)の時系列データを算出した。本実験はTable. 1に示す室温, 湿



Fig. 1: MindWave Mobile.

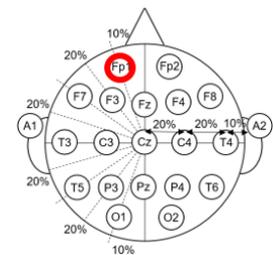


Fig. 2: International 10-20 system.



Fig. 3: POLAR H10.



Fig. 4: POLAR V800.

Table. 1: Experimental conditions

Condition	Temperature[°C]	Humidity[%]	Air flow
A	27±1	60±10	None
B	27±1	60±10	Upper body
C	28±1	80±10	None
D	28±1	80±10	Upper body

度, 気流が異なる4種類の空調条件下でタスクを行い, タスク中およびその前後に脳波, 心電の計測を行った。Fig. 5に空調機器の配置を示す。Fig. 5に示す配置の温度計を用いて室温の管理, 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。被験者は計測開始前に環境に慣れるために20分間の馴化時間を過ごした。馴化終了後, 安静閉眼状態で30秒間計測を行

い、その後計測を行いながらタスクを 12 分間行った。タスク終了後、再び安静閉眼状態で 30 秒間計測を行った。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. 6 参照)。タスクには集中力や注意力を要するクレペリン検査と発想力を要するマインドマップを採用し、それぞれ 2 セットずつ行った。

### 3 解析

各空調条件のストレス値, LF/HF, 作業効率の比較で用いた解析手順についてそれぞれ述べる。

#### 3.1 脳波解析

タスク前後の安静閉眼状態(30 秒)の間に取得した脳波データに対して解析を行った。

まず、各被験者の脳波データからストレス値を算出した。ここで取得したストレス値は、リアルタイム感性分析装置“感性アナライザ©電通サイエンスジャム”を用いて取得した。感性アナライザは脳波からリアルタイムで各周波数の振幅スペクトルの組み合わせによる独自のアルゴリズムによって 1 秒ごとに 0-100 % で 5 つの感性が算出される。本研究ではそのうちの一つであるストレス値に注目し、毎秒ごとに取得した。次に、タスク前後のストレス値から被験者ごとに 30 秒のデータの平均値を算出した。取得した各空調条件のタスク前と後のストレス値に対して有意差検定を行い、タスク前後のストレス値変化が有意か否かを検証した。有意水準は 5 % とした。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。本研究のタスク前後のストレス値比較には、両側 2 標本  $t$  検定を採用した。

#### 3.2 心電解析

タスク中(720 秒)の間に取得した RRI の時系列データに対して解析を行った。RRI とは心電図の R 波のピークとピークの時間間隔を指し、呼吸や血圧変動などで揺らぎが生じている。この揺らぎは心拍変動と言われ、自律神経機能と関連している。

RRI データに対して前処理として外れ値の除去を行った。外れ値は任意の RRI データの前後 10 点の平均値(mRR)を基準とし、閾値は 1.5mRR 以上および 0.5mRR 以下とした。外れ値と判断された RRI データは mRR に置換した。次に、自己回帰モデルを用い、時間領域から周波数領域へ変換する<sup>8)</sup>。自己回帰モデルとは任意の値  $x_s$  を過去の値  $x_{s-j}$  に重み  $a_j$  を乗じた値に残差  $\varepsilon_s$  を加えた線形和で表わす手法であり、以下の式で表わされる。

$$x_s = \sum_{j=1}^M a_j x_{s-j} + \varepsilon_s \quad (1)$$

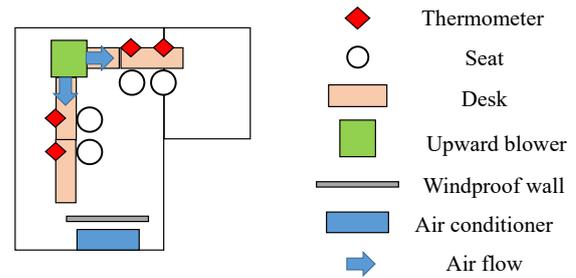


Fig. 5: Experimental placement.

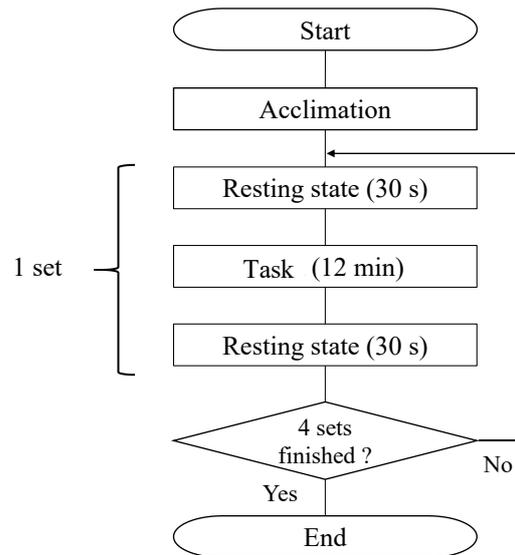


Fig. 6: The procedure of the proposed method.

$$PSD(f) = \frac{\sigma^2}{\left|1 - \sum_{k=1}^p a_p(k)e^{-j2\pi k f}\right|^2} \quad (2)$$

上式で算出した自己回帰モデルで得られる波形のパワースペクトル密度は以下の式で求められる。

$a_p(k)$ はモデル係数、 $\sigma^2$ は予測残差、 $p$ は次数を表している。自己回帰モデルの次数決定には赤池情報量基準(An Information Criterion: AIC)を用いた。AIC は自己回帰モデルの最大尤度およびモデルパラメータの自由度により次数を決定する手法である。次に、算出したパワースペクトル密度から心拍変動の低周波成分(Low Frequency: LF)と高周波成分(High Frequency: HF)の比である LF/HF を算出した。心拍変動における LF は血圧変動に由来し、交感神経の活性度合いを示す。HF は呼吸変動に由来し、副交感神経の活性度合いを表す。交感神経と副交感神経の活性度合いの比はストレス評価に用いられており、交感神経が優位、すなわち LF/HF の値が大きいほどストレス負荷が大きいとされている。本研究では、LF, HF の周波数帯域をそれぞれ、0.05~0.15 Hz, 0.15~0.40 Hz と設定し、被験者ごとに各空調条件の LF/HF を算出した。算出した LF/HF に対して有意差検定を行い、各空調条件間の LF/HF の差が有意か否かを検証した。本研究の LF/HF の比較は、有意差検定の中でもクラスカル・ウォリス検定とボンフェローニの多重比較を用いた。

### 3.3 タスク成績解析

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タスク成績を解析に用いた。1条件につきそれぞれのタスクを2回ずつ行っているため2回のタスク成績の平均をとり、被験者ごとにそれぞれのタスク成績を1つずつ取得した。取得したタスク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タスク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タスク成績、 $x_n$ は各被験者のタスク成績、 $\bar{X}_n$ は各被験者の全空調条件におけるタスク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タスク成績平均を1としたとき、各空調条件のタスク成績が平均に対しての割合で表される。正規化したタスク成績に対して有意差検定を行い、各空調条件間のタスク成績の差が有意かを検証した。本研究のタスク成績の比較は、LF/HFの比較と同様に、クラスカル・ウォリス検定とボンフェローニの多重比較を用いた。

## 4 結果

### 4.1 脳波解析結果

Fig. 7 に各空調条件のタスク前後のストレス平均値を示す。タスク前後のストレス値平均値に対して有意差検定を行った結果、高温多湿の環境である条件 C、Dにおいて有意水準5%でタスク後にストレスが有意に減少していることを確認した。

### 4.2 心電解析結果

Fig. 8 に各空調条件のタスク中の LF/HF 平均値を示す。タスク中の LF/HF を用いて条件間で有意差検定を行った結果、条件 D において最も低い値を示し、条件 C と D の間に有意水準5%で有意差を確認した。

### 4.3 タスク成績解析結果

Fig. 9, 10 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タスク成績平均値を示す。正規化後のクレペリン検査、マインドマップのタスク成績を用いて条件間で有意差検定を行った結果、すべての条件間で有意差は確認されなかったが、クレペリン検査では条件 D、マインドマップでは条件 A において最も高い成績を示した。

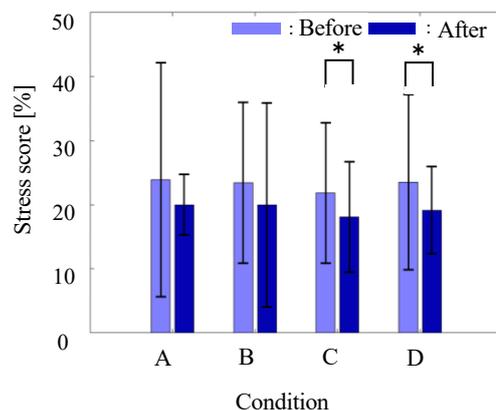


Fig. 7: Stress score before and after work.

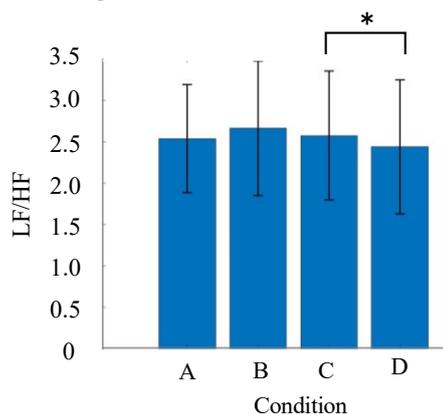


Fig. 8: LF/HF during task.

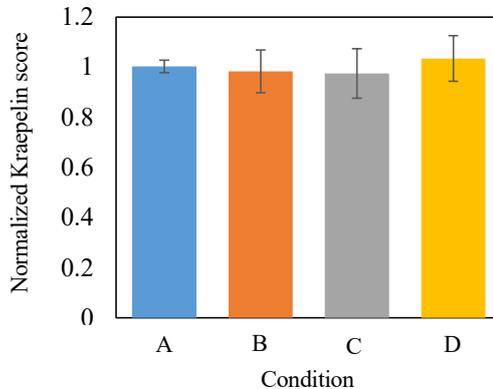


Fig. 9: Normalized Kraepelin score.

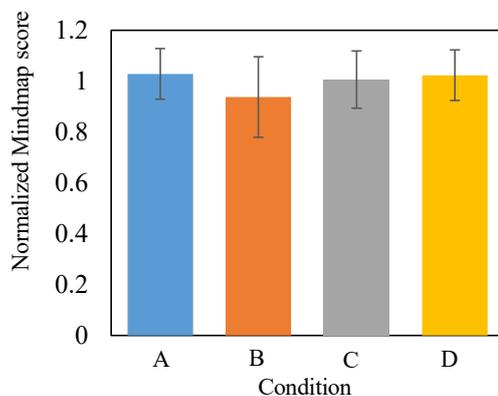


Fig. 10: Normalized Mindmap score.

## 5 考察

各空調条件のタスク前後のストレス値の平均値に対して、有意差検定を行った結果、条件 C、D においてタスク後有意にストレスが減少していることを確認した。Fig. 7 より全空調条件においてタスク後にストレスが減少する傾向を確認できるが、高温多湿の条件である C、D においてのみ有意差が確認されたことからタスク中の発汗とタスク後のストレス減少効果に関係していると考えられる。また、各空調条件のタスク中の LF/HF を比較した結果、条件 D において最も低い値を示した。高温・多湿環境下で気流を付加した条件 D において LF/HF が低い値を示したことから、気流によって汗の気化が促進され、交感神経が優位でなくなったことが原因として考えられる。発汗により交感神経が支配的に働くため、気流によって発汗を抑制することで交感神経の活動が減少したと考えられる<sup>9)</sup>。正規化後のクレペリン検査、マインドマップのタスク成績の比較を行った結果、クレペリン検査では条件 D、マインドマップでは条件 A において最も高い成績を示した。

以上の結果より、高温・多湿環境においては気流を付加することで少ないストレスで集中力や注意力が向上させることを確認した。この理由として、室温および湿度の上昇に伴う発汗が気流によって気化し、副交感神経が優位になったことが考えられる。そして、副交感神経が優位になることによって、ストレスが低下し、クレペリン検査のタスク成績向上に繋がったと考えられる。

## 6 おわりに

本研究では、生体信号を用いて温熱環境が心的要因と作業効率に及ぼす影響を明らかにすることを目的とし、4 つの空調条件下で脳波計測、心電計測、認知タスクを行った。その結果、下記のような結果を得た。

- 1) 全条件でタスク後のストレス減少が確認され、高温多湿環境下では有意にストレス減少。
- 2) 高温多湿の環境下で気流を付加することで、タスク中のストレス負荷が低減。
- 3) 高温多湿の環境下で気流を付加することで、集中力や注意力を要するクレペリン検査のタスク成績が最大。

上記の結果から、高温・多湿環境においては気流を付加することで少ないストレスで集中力や注意力を向上させることを確認した。先行研究では、28℃環境に比べ、27℃環境における作業効率は高いとされている<sup>10)</sup>。本研究ではマインドマップの気流なし条件について、上記の先行研究と同様の傾向を確認した。しかし、クレペリン検査及びマインドマップの気流を付加した条件について、27℃環境に比べ、28℃環境において高い作業効率となる傾向を示した。このことから、先行研究と異なり、気流付加のない環境に比べ、気流付加を行うことで作業環境の温度と作業効率の関係は、より高温側で作業効率が向上する可能性を示した。以上より、梅雨の気候において、気流の付加が一時的な作業効率を向上させるだけでなく、ストレスの蓄積を抑制することで長時間の作業効率向上の可能性がある。今後は気流の解析を行い、心的要因変化と気流の詳細な関係を解明していく。

## 参考文献

- 1) K. C. H. J. Smolders and 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) 郭鐘声, 小竹元基, 鎌田実: 室内空間における覚醒度および熱的快適感の違いによる自律神経系指標と中枢神経系指標の類似性と相違性, *日本機械学会論文集*, **83**-849, 16 (2017)
- 3) 井上博, 「循環器疾患と自律神経機能」, 医学書院, 2001.
- 4) Mind Wave Mobile, <http://www.neurosky.jp/products/>, 2018/11/21 アクセス
- 5) POLAR H10, <https://www.polar.com/ja/products/accessories/h10>, 2018/10/10 アクセス
- 6) POLAR V800, <https://www.polar.com/ja/products/pro/V800>, 2018/10/10 アクセス
- 7) 感性アナライザ, <https://kansei-analyzer.com/>, 2018/9/30 アクセス
- 8) H. Akaike: Information Theory and an Extension of the Maximum Likelihood Principle, *Selected papers of hirotugu akaike*, 199/213 (1998)
- 9) 清水潤, et al.: 血流および発汗調節に関する自律神経機能の顔面と四肢の差異について, *東北大学歯学雑誌*, **26**-1 (2007)
- 10) Seppanen, et al.: Effect of Temperature on Task Performance in Officeenvironment, Ernest Orlando Lawrence Berkeley NationalLaboratory, **LBNL-60946**, (2006)

# 衣類型導電性繊維を用いた動作に頑健な心拍推定手法の提案

○増山義輝 満倉靖恵 (慶應義塾大学)

## Robust Heart Beats Detection Method for Motion by Measuring ECG Through Conductive Fibers

\* Yoshiki Mashiyama and Yasue Mitsukura (Keio University)

**Abstract**— In this paper, we propose a robust method for motion for detecting heart beats from electrocardiogram (ECG) measured through conductive fibers by a clothing typed device. In recent years, heart rate is an effective index for describing mental and physical condition. Accordingly, many types of wearable devices have been developed. However, some devices have problem such as large burdens on subjects caused by wearing oppression and contact dermatitis. In this research we focus on a clothing typed device made of stretchable conductive fibers that can be comfortably worn. The ECG measured by a clothing typed device contains uncertainty in the measured waveform. In this research, we propose a motion robust heart beats detection method using discrete wavelet transform. In order to evaluate the effectiveness of the proposed method, we show the comparison of R waves detection result between proposed method and conventional method. As a result, it was confirmed that proposed method could detect R waves with higher accuracy than conventional method.

**Key Words:** R waves, ECG, conductive fibers

### 1 はじめに

本研究の目的は、衣類型導電性繊維から心電図を取得し、動作に頑健かつ正確に心拍を推定する事である。心拍は自律神経系活動や身体活動によって変動することから、精神活動および身体活動の状態を評価する有効な指標として医療やヘルスケア分野において着目されている[1]。また、心拍は睡眠時の睡眠段階の判定の指標として有用であることや、運動時の消費カロリーの推定に有効であること、運動に伴うカテコラミンの増加による不整脈に起因した突然死などが問題となっていることから不整脈を未然に検知するため、ウェアラブル型の心拍計測デバイスなどが多く提案されてきた[2-4]。これらのウェアラブル型の心拍計測デバイスの多くは取得した心電図中のR波と呼ばれる波を検出することで心拍のタイミングを推定している。R波は心臓が血液を動脈に駆出する際の電氣的活動に伴って生成される特徴であることから、心電図において心拍のタイミングを測定するための有効な特徴量として使用されている[5]。これらのウェアラブル型の心拍計測デバイスには、動作時の接触不具合などによって計測波形に不確実性を含むなどの課題が残る機器もある。加えて、胸部への装着に伴う圧迫によって被験者へ不快感を与えるものや、粘着性電極面による接触性皮膚炎発症の可能性があるなど、装着に伴う被験者への負担が大きいというデメリットがある。また、電極面の洗浄や交換ができず、発汗を伴う運動時の利用において不衛生であるというデメリットがある[6,7]。これらの背景より、本研究では、伸縮性があり装着感を感じない洗濯可能な導電性繊維を用いた動作に頑健な衣類型心電図計測システムに着目した。衣類型心電図計測

システムは、既存の心拍計測機器に対して低負担での装着が可能になるため、より長時間の健康状態の連続したモニタリングが可能になると考えられる。また、睡眠時の計測においては機器の装着による睡眠の障害を抑制することが可能になると考えられる。しかし、衣類型心電図計測システムによって得られた心電図には、筋電や動作時の摩擦によってアーチファクトが混入する。そこで、本研究では衣類型心電図計測システムによって得られた心電図からアーチファクトに頑健に心拍情を取得する手法の提案を行う。本論文は全6章で構成される。2章では、衣類型心電図計測システムによる心電図の取得を目的とした実験の詳細について述べる。3章では、提案手法である動作に頑健な心拍推定手法について述べる。4章では実験に対して行った解析について述べる。5章では検証実験の結果および考察について述べる。6章では本論文のまとめについて述べる。

### 2 実験

動作に頑健な心拍推定手法の構築のために、衣類型心電図計測システムを用いて運動時の計測を行った。実験では、成人男性1名に対し、継続的に様々な動作を含有した計測が可能であるサッカーのプレイ中に衣類型心電図計測システムを着用させ、練習試合中の12.5分間の計測を行った。衣類型心電図計測システム内面の導電繊維を用いた計測箇所を以下のFig.2に示す。計測部位は、標準12誘導法に基づいたV1-V2箇所とした[8]。また、衣類型心電図計測システムは差動アンプを用いてサンプリング周波数250HzでV1箇所とV2箇所の電極間の電位差の計測を行う。



Fig.1 Clothing typed device (Overall)



Fig.2 Clothing typed device (Inside)

### 3 提案手法

本研究では離散ウェーブレット変換を用いた心拍推定手法を提案する。ここで、安静時に衣類型心電図計測システムによって取得した心電図の例を Fig. 3 に示し、運動時に衣類型心電図計測システムによって取得した心電図の例を Fig. 4 に示す。Fig. 3 より、安静時に衣類型心電図計測システムによって取得した心電図には大きなアーチファクトの類は見られないが、Fig. 4 より、運動時に衣類型心電図計測システムによって取得した心電図には、運動に伴う摩擦や筋肉の活動に伴う筋電などのアーティファクトが混入していることがわかる。よって、運動時には心電図のピークである R 波を従来手法である波高や加速度などの特徴を用いて特定することが困難であった。そこで、得られた心電図の波形と理想的な心電図の波形との相関を利用するテンプレートマッチングを検討したが、運動に伴い瞬時心拍数が変動することや、アーティファクトの混入から単一のテンプレートでは十分な R 波の特定が困難であった。しかし、提案手法である離散ウェーブレット変換は、入力信号を、マザーウェーブレットと呼ばれる基底関数の拡大・縮小・平行移動したものの足し合わせとして分解するアルゴリズムである。この性質より、マザーウェーブレットを理想的な心電図の波形にすることで、入力信号のマザーウェーブレットとの相関が高い箇所が心電図の R 波であると考えられる。ここで、既存手法である Pan-Tompkins アルゴリズムによって R 波特定を行った結果の例を Fig. 5 に示し、離散ウェーブレット変換を用いて R 波特定を行った結果の例を Fig. 6 に示す。Pan-Tompkins アルゴリズムは心電図の R 波を特定するために広く用いられているアルゴリズムである[10]。Fig. 5 より、既存手法である Pan-Tompkins アルゴリズムでは赤矢印で示した箇所にように心電図中の R 波の次の波である S-T 波を R 波として誤検出していることがわかる。しかし、Fig. 6 から、提案手法である離散ウェーブレット変換では R 波の波形に着目することで S-T 波を R 波として誤検出することを抑制し、正確に R 波のタイミングを特定している。以上より、離散ウェーブレット変換を用いることで、瞬時心拍数の変動やアーティファクトに対して頑健に心電図の R 波を特定することが可能になると考えられる。

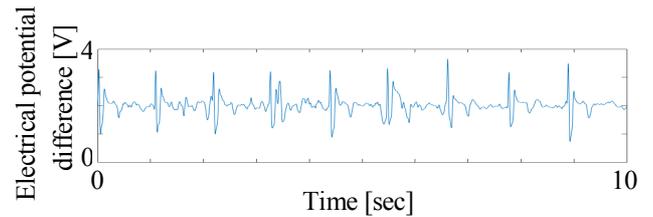


Fig.3 Resting state

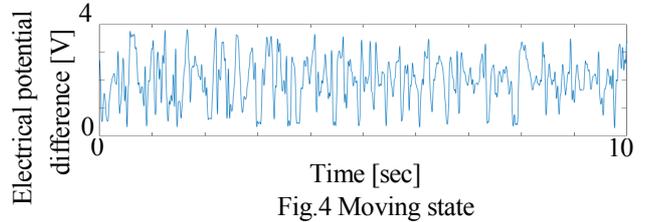


Fig.4 Moving state

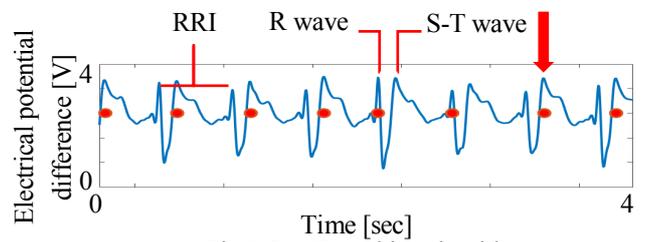


Fig.5 Pan-Tompkins algorithm

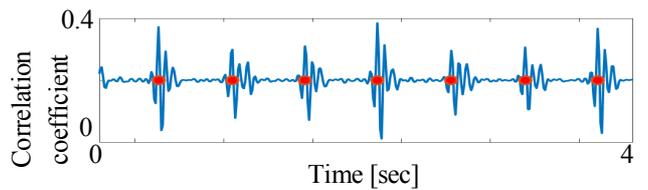


Fig.6 Proposed method

### 4 解析

まず、取得した心電図に対し、筋電などのアーティファクトを除去するため、筋電の周波数特性や心電の周波数特性を考慮し、通過帯域が 0.5 から 30 Hz のバンドパスフィルタを適用した[11]。次に、提案手法として、フィルタ処理後信号に対して離散ウェーブレット変換を適用した。そこから得られた心電図とマザーウェーブレットとの相関係数の時系列信号に対して局所的な最大値探索を行うことで R 波の特定を行った。同様に、心電図の R 波特定アルゴリズムの既存手法である Pan-Tompkins アルゴリズムを取得した心電図のフィルタ処理後信号に対して適用し、R 波の特定を行った。また、特定された R 波から R 波同士の間隔(RRI)を算出した。特定結果および RRI 算出結果を比較することで、提案手法の既存手法に対する評価を行った。本研究で行った解析のフローチャートを Fig.7 に示す。

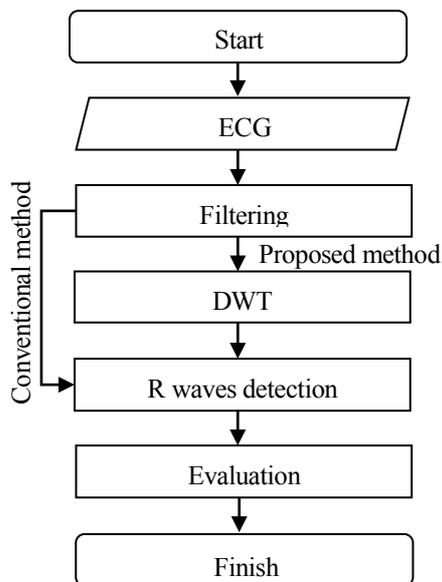
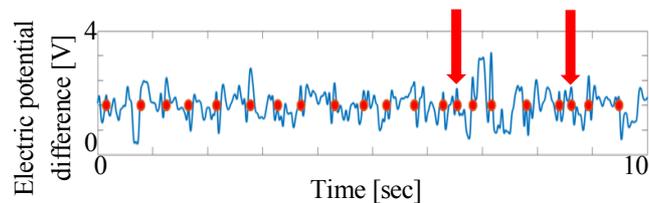


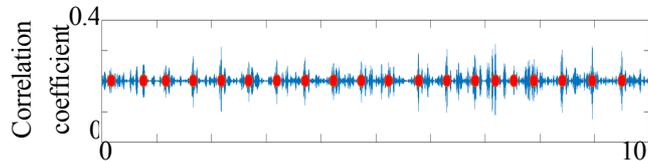
Fig. 7: Flowchart of analysis

## 5 結果および考察

フィルタ処理後波形および既存手法用いて R 波を特定した結果を Fig.8 (a)および Fig.9 (a)に示し、マザーウェーブレットとの相関係数波形および提案手法用いて R 波を特定した結果を Fig.8 (b)および Fig.9 (b)に示す。特定された R 波は赤点で示す。また、特定された R 波同士の間隔(RRI)を算出した結果を Fig. 10 に示す。Fig.8 (a)より、既存手法ではアーティファクトの混入によって R 波の特定が困難であり、赤矢印で示した隣接する R 波との時間が過短な箇所を R 波として誤検出している事がわかる。しかし、Fig.8 (b)より、提案手法ではマザーウェーブレットとの相関係数を算出することによって、定常的なピークを確認する事が可能となり、既存手法に対して R 波の誤検出を抑制している事がわかる。また、Fig.9 (a)より、既存手法では R 波と考えられる定常的なピークを特定できていないことがわかる。しかし、Fig.9 (b)より、提案手法では既存手法で未検出であったピークを特定できていることから、提案手法は瞬時心拍数の変動や筋電や動作時の摩擦などのアーチファクトに対して頑健に R 波を特定していると考えられる。Fig. 10 (a)より、既存手法では RRI 波形のばらつきが大きいことがわかる。しかし、Fig. 10 (b)より、提案手法では既存手法に対し RRI 波形のばらつきが抑制されている。ここで、隣接する R 波との時間が過短な箇所を R 波と特定することで RRI は小さくなり、R 波の未検出をすることで RRI は大きくなることから、誤検出および未検出が RRI 波形のばらつきに現れると考えられる。よって、提案手法では R 波の誤検出および未検出を抑制していたと考えられる。以上より、提案手法を用いる事で運動時においても高精度な R 波の特定が可能であったと考えられる。

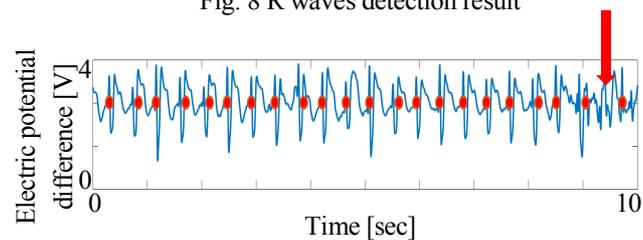


(a) Conventional method

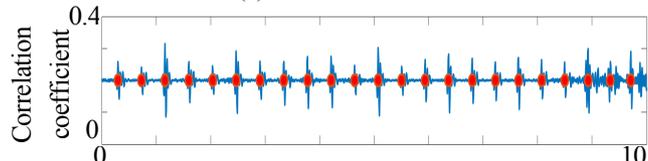


(b) Proposed method

Fig. 8 R waves detection result

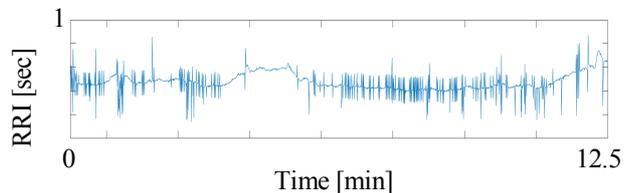


(a) Conventional method

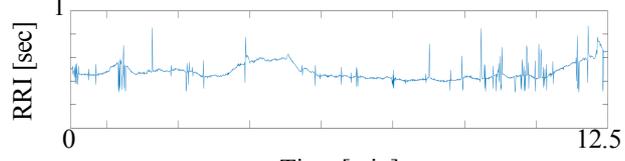


(b) Proposed method

Fig. 9 R waves detection result



(a) Conventional method



(b) Proposed method

Fig. 10 Calculation RRI result

## 6 おわりに

本研究では、衣類型導電性繊維から心電図を取得し、動作に頑健かつ正確な心拍推定手法の提案を行った。本研究で得られた知見は以下の通りである。

- 提案手法では離散ウェーブレット変換を用いることで、動作に頑健な心拍の推定が可能になったと考えられる。
- 衣類型心電図計測システムの問題点の解決が可能になったと考えられる。

今後は、より高精度なアーチファクト除去を目的とし、加速度波形および適応フィルタを用いた手法の適用を検討する[12].

## 参考文献

- [1] M. Malik, et al., "Heart Rate Variability Standards of Measurement, Physiological Interpretation, and Clinical Use", *European Heart Journal*, Vol. 17, pp. 1354-381, 1996.
- [2] L.R. Keytel, et al., "Prediction of Energy Expenditure from Heart Rate Monitoring During Submaximal Exercise", *J Sports Sci*, Vol. 23, pp. 289-297, 2005.
- [3] T. Takeda, et al., 「心拍変動を用いた時間依存睡眠段階遷移モデル」, *DBSJ Japanese Journal*, Vol. 14, No. 16, pp. 1-7, 2016.
- [4] H. Musha, et al., 「スポーツ中の突然死の動向と展望」, *体力科学*, Vol. 63, No. 1, 2014.
- [5] O. Ohtani, et al., 「カラー図解 人体の成城構と機能 II 循環器」, 日本医事 新報社, 2017.
- [6] M.A. Audran, et al., "Contact Dermatitis from Electrocardiograph-Monitoring Electrode: Role of P-Tert-Butylphenol-Formaldehyde Resin", *Contact Dermatitis* Vol. 48, pp. 108-111, 2003.
- [7] R. Wang, et al., "Accuracy of Wrist-Worn Heart Rate Monitors", *AMA Cardiol*. Vol. 2, No. 1, pp. 104-106, 2017.
- [8] J. Malmivuo, et al., "Bioelectromagnetism. 15. 12-Lead ECG System", *Oxford University Press*, pp.277-289, 1975.
- [9] J. Nyboer, et al., "Electrical Impedance Plethysmography: A Physical and Physiologic Approach to Peripheral Vascular Study." *Circulation*, Vol. 2, No. 6, pp. 811-821, 1950
- [10] J. Pan and W.J. Tompkins, "A Real-Time QRS Detection Algorithm" *IEEE Transaction on Biomedical Engineering*, Vol. 32, No. 3, 1985.
- [11] H. Sato, 「表面筋電図のパワースペクトル」, *人類学雑誌*, Vol. M.R. Ram, et al., "A Novel Approach for Motion Artifact Reduction in PPG Signals Based on AS-LMS Adaptive Filter" Vol. 61, No. 5, pp. 1445-1457, 2012.
- [12] Y. D. Lee, et al., "Wireless Sensor Network Based Wearable Smart Shirt for Ubiquitous Health and Activity Monitoring", *Sensors and Actuators*. Vol. 140, pp. 390-395, 2009.

## 長時間連続計測による

# ステロイドホルモン投与マウスの終夜行動解析

○葛西凜々子 吉田慶多朗 田中謙二 満倉靖恵(慶應義塾大学)

## Behavioral Analysis of Steroid Hormone-Treated Mouse

### by Automated Long-Term Overnight Continuous Measurement

\* R. Kasai, K. Yoshida, K. Tanaka and Y. Mitsukura (Keio University)

**Abstract**— Steroid hormones are widely used as anti-inflammatory agents, but their side effects are large. It is important to identify appropriate doses and duration since mental disorders as one of side effects of steroid is a problem. We analyzed the long-term behavior of mice to grasp the behavioral change by administration of steroid hormone. As a result of our analysis, the total walking distance decrease significantly after day 24. The number of rearing times also decrease after day 23. The ingested amount reached 40.2 $\mu$ g and 38.8 $\mu$ g on each day. Steroid hormones induce depression-like behavior, such as decrease of physical activities. Therefore we presented that depression-like behavior of steroid hormone administered mouse changed at specific dose and duration.

**Key Words:** Image processing, Translational research

## 1 はじめに

本稿は、ステロイドホルモンの長期投与によるマウスの行動変化を捉えることを目的とした。ステロイドホルモンを主成分とするステロイド薬は強力な抗炎症作用を持ち、気管支喘息・肺炎・膠原病・リウマチ性疾患をはじめ多くの疾患・病態の治療において広く用いられている。しかし、ステロイド薬の副作用は依然として大きな臨床課題である<sup>1)</sup>。クッシング症候群や糖尿病等、重篤な副作用が数多く存在するが、その一つとして、うつ症状を伴うステロイド誘発性精神障害がある。これは長期投与患者の約3割に報告されており、深刻な問題となっている<sup>2)</sup>。この問題を未然に防ぐためには、ステロイド薬の適切な投与量と投与期間を明らかにすることが重要となる。

既存研究ではヒトの代替としてマウスにコルチコステロン(マウスにおけるステロイドホルモン)を長期投与し、マウスのうつ様行動(うつ症状を示す行動)の発現を確認している<sup>3)</sup>。通常の行動からうつ様行動への変化は、マウスにおけるステロイド誘発性精神障害の発症により起こると考えられているためである。既存研究における行動計測は一般的にうつ様行動の検出手法とされている行動実験によるものである。これは、マウスをケージ以外の新しいフィールドに置き、歩行量や中心滞在時間等の行動変化を調査するというものである。しかし、この実験手法はマウスにとって新しい環境であることが重要であるため、1週間に1度、30分程度のみでの計測に限られる。結果として、ステロイド誘発性精神障害の発現のタイミングは行動変化を確認した3-4週間の間と推定された。しかし、これは前に述べたように少ない計測回数から推定されているため、曖昧であり正確性に欠けるという問題点がある。更に、うつ様行動の重要な指標の一つであるリアリング(立ち上がり)行動は直接観察及びビデオ記録の分析により手動で評価されている。しかし、手動の行動解析は再現性の低さ、定性的であることが問題視されている<sup>3)</sup>。

従って本研究では、長時間連続で行動解析を行い、深度センサを用いてリアリング行動を定量的に評価する。長時間連続の行動解析により、より詳細な投与期間を推定することが出来る。更に、マウスは歩く、走る、グルーミング等の二次元情報による区別が可能な行動のみならず、止まる行動、座る行動や、前述のリアリング(立ち上がり)行動等の二次元情報のみによる区別が困難な行動を取る。そこで、深度センサを用いることでマウスの平面的な移動だけでなく、姿勢の変化や上下方向の運動にも着目することが出来る。これにより、うつ様行動の重要な指標の一つであるリアリング(立ち上がり)行動を捕捉し、ステロイドホルモン投与によるマウスのうつ様行動の発現のタイミングをより正確に捉えることが出来る。

## 2 実験

### 2.1 実験手順

本研究では、マウス2匹に対し期間終夜実験を行った。実験の流れをFig. 1に示す。1匹をコルチコステロン飲水投与マウス、他方をコルチコステロン非投与マウス(コントロールマウス)とした。投与溶液中のコルチコステロン量は水100mlにつき35 $\mu$ gとした。なお、コルチコステロンは水に対し難溶性を示すため、溶解を促す作用を持つデキストリンを加えており、条件統一のためコントロールマウスの投与溶液にも加えている。投与溶液中のデキストリン量は水100mlにつき450 $\mu$ gとした。

マウスは計測環境に慣れるまで探索行動が多くなるという特徴を持つため、その影響を排除するために2日間の順応期間の後に投与及び計測を開始した。深度センサ(Kinect<sup>®</sup>)をケージ上部に設置し、4週間連続して深度計測を行った(Fig. 2 参照)。マウスは1匹ずつケージ内で飼育した。ケージは、大きさ18cm×26cm×60cmとして透明アクリル板で作成した。このケージの高さは一般的なケージの2倍以上であるが、これは深度計測

に赤外線パルスを利用しており、遮蔽物を避ける目的から本ケージには上蓋が無く、その際にマウスの脱走を防ぐためである。マウスは8週齢の性経験のないオス、C57BL/6J系統を2匹用いた。実験環境の明暗条件は、6時30分から18時を明条件、それ以外の時間を暗条件とした。

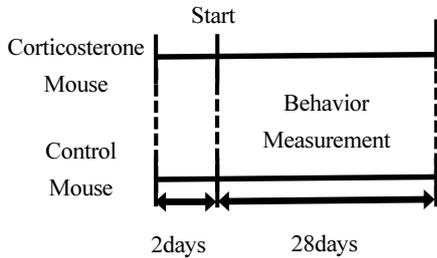


Fig. 1: Experimental flow

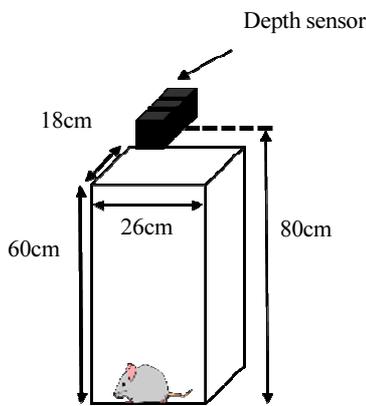


Fig. 2: Cage and depth sensor

## 2.2 計測機器及び計測原理

本研究で用いた深度センサ(Kinect®)は ToF(Time of Flight: ToF)方式を用いて、赤外線パルスを照射し、対象物で反射した光が受光素子に入射するまでの時間遅れを求めることで深度を計測している。この計測原理により上下方向の行動の捕捉が可能となり、リアリング行動を検出することが可能となる。ここで、深度センサはマウスの行動のみに着目するためケージの床から 15cm 上までを深度計測範囲に設定しており、約 0.02mm の深度差を捕捉可能である。マウスの体長は 7cm 以下であることを考慮すると十分な精度であると考えられる。

## 3 解析

本研究における解析対象は、既存研究においてうつ様行動の指標とされている総歩行距離、中心滞在時間、リアリング回数とした。解析の概要を Fig. 3 に示す。まず、取得した深度情報を輝度値に変換することで画像化し、その画像にメディアンフィルタによる処理を施すことで、ノイズ除去を行った。これは、深度を計測する際の機器の電源や蛍光灯の点滅由来のインパルスノイズの影響をなくすためである。平滑化した画像に対して、ケージ内全体の画像からマウスのみを検出

する処理を行う。マウスの輪郭を検出することで重心を求め、重心の位置変化から 1 時間ごとの総歩行距離、中心滞在時間を算出した。中心滞在時間は、ケージの各辺を三分割する直線で区切られた中央の区画を中心と定義し算出した。

次に、マウスの姿勢を推定するために、マウスの中心軸上の輝度値を取得した(Fig. 4 参照)。ここで中心軸の定義はマウスの脊柱に沿った軸とし、輪郭に対して最小二乗法を用いて求めた。そして輝度値が閾値を超える場合をリアリング行動と定義し、その回数を算出した。ここで閾値は、輝度 100(ケージ床から約 5.86cm 以上の高さを表す)とし、中心軸上のピクセル数の 1/3 が閾値を超える場合をリアリング行動と定義した。この定義は、RGB カメラで録画した映像を精査し、マウスが立ち上がった時間を深度情報と比較し閾値の変化による正答率を確認して決定した。

最後に、コルチコステロン飲水投与マウス及びコルチコステロン非投与マウス(コントロールマウス)の 2 匹のマウス間において、1 時間ごとの総歩行距離や中心滞在時間、リアリング回数に差があるか明らかにするために有意水準 5%で両側二標本 t 検定を行った。検定は 1 時間ごとの値の 24 時間平均を対象とした。

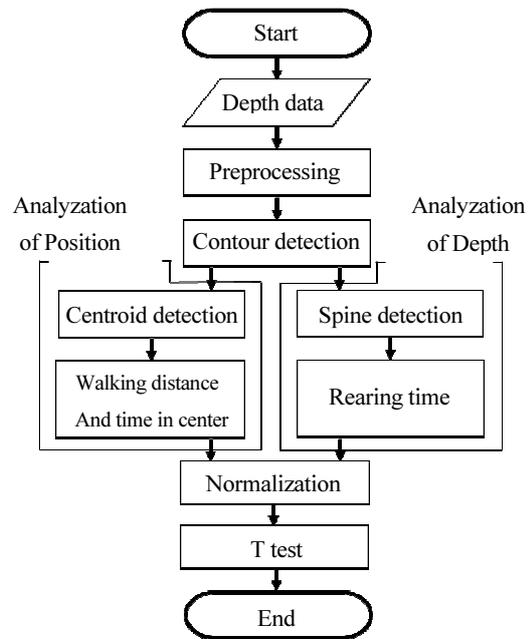


Fig. 3: Analysis flow

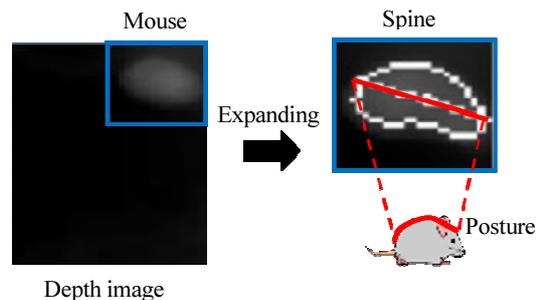


Fig. 4: Spine (posture) detection

## 4 実験結果と考察

### 4.1 長時間計測による結果の妥当性

総歩行距離と中心滞在時間、リアリング回数算出結果の一例として、コントロールマウスにおける実験開始後 24 時間 (1 日目) の結果を Fig. 5 と Fig. 6 に示す。x 軸は実験における明暗サイクルと経過時間を対応させた表記方法であるツァイトゲバー時刻(ZT)で表しており、明暗条件の切り替えを行う 6 時 30 分を ZT=0 とした。また、中心滞在時間は 5 分ごとの平均とした。暗条件(ZT=11.5-24.0)の ZT=6.0, 17.5, 19.0 において、中心滞在時間及びリアリング回数の増加を確認した。これは、マウスが夜行性であるため夜間に活動量が増加することと合致する。一方、明条件(ZT=0-11.5)の ZT=6.0 における増加は、ZT=6.0 前後で行う体重計測によりマウスが覚醒するためだと考えられる。以上に加え、総歩行距離の時間経過に伴う増加を確認したことから、明暗条件及び時間経過に伴うマウスの行動変化を捉えたと考ええる。

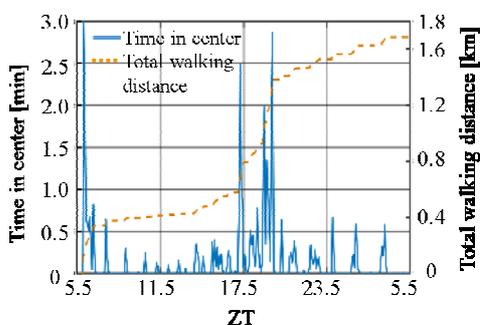


Fig. 5: Total walking distance and time in center in 24 hour

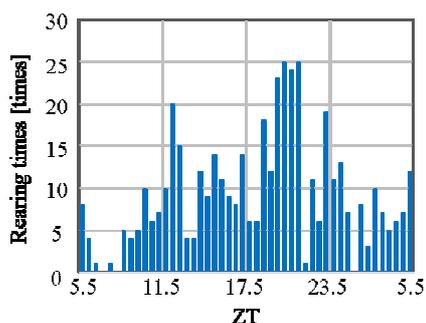


Fig. 6: Rearing times in 24 hour

### 4.2 コルチコステロンによるマウスの行動変化

コルチコステロン飲水投与マウス及びコントロールマウス間における総歩行距離、中心滞在時間及びリアリング回数の 1 日毎の有意差検定結果を Table 1 に示す。まず、2 匹のマウス間において中心滞在時間に有意差は確認されなかった。ここでマウスは、壁に触れケージ内の周辺部をより好んで歩行する「接触走性」という行動パターンを示し、特に不安時に明るい中心部分よりも暗い壁際を好むことが知られている<sup>4)</sup>。そ

のため、コルチコステロン飲水投与マウスにおいてうつ様行動として中心滞在時間の減少が考えられた。しかし実験中、ケージの中心部分に深度センサによる影が生じたため、中心が暗くなり、うつ状態である場合も中心に滞在しうる環境であったと可能性がある。従って本研究では中心滞在時間の有意な減少が確認されなかったと考える。

一方で、投与 24 日目以降の総歩行距離及び投与 23 日目以降のリアリング回数に有意な減少を確認した。また、各日までのコルチコステロン累積投与量はそれぞれ 40.2 $\mu$ g 及び 38.8 $\mu$ g となった。上記の値の減少原因は、慢性的なコルチコステロン量の増加であると考えられる。コルチコステロンは副腎皮質ステロイドホルモンであり、視床下部-下垂体-副腎(HPA)系のフィードバック機構により、分泌量がある一定量を上回る、あるいは下回ることのないように制御されている<sup>5)</sup>。よって、一過性のストレス等、短期的なコルチコステロン量の増加に対しては、ネガティブフィードバックが働くため増加したコルチコステロンは時間経過と共に減少する。しかし、長期投与による慢性的なコルチコステロン量の増加に対しては、HPA 系の過活動によるフィードバック機構の阻害が起こる<sup>5)</sup>。これにより、HPA 系の調節機能が働かず、通常よりも多量のコルチコステロンが体内に存在することになる。従って、受動的ストレス反応として行動意欲の減退を起こすことが知られているコルチコステロンが<sup>6)</sup>、長期投与時には体内に多量に存在するため、行動に変化が見られると考える。歩行やリアリング(立ち上がり)行動はマウスが周囲環境を探索する際に行う動きであり、行動意欲に基づく行動であるため、総歩行距離とリアリング回数の減少はコルチコステロンの長期投与による行動変化であると考えられる。また、この結果は既往研究においてうつ様行動が投与開始後 3 週間から 4 週間に確認されたことから妥当であると考えられる。

Table 1: Day that value decrease significantly of corticosterone-treated mouse

Index	Day that value decrease significantly
Total walking distance	24, 25, 26, 28
Time in center	None
Rearing times	9-12, 23-28

続いて、9-12 日目におけるリアリング回数の減少について考察を述べる。ステロイド誘発性精神障害には早期型、中期型、後期型の 3 種類が存在する<sup>7)</sup>。早期型は投与開始後 2 週間以内に発症し、軽度かつ一過性である。中期型は投与開始後 2 週間から 1 か月で発症し、投与量がある程度減量されるまでうつ状態が持続する。後期型は投与開始後数か月で発症するが、患者数は少ない。本研究で着目しているのは中期型である。よって、うつ様行動が初めて発現した後も、うつ様行動が持続して確認されると考える。9-12 日目は投与開始後 2 週間以内である点、及び 13 日目以降に有意差がなくなっていることから軽度で一過性の症状と考える点から、9-12 日目にコルチコステロン投与マウスにおいて確認されたリアリング回数の減少は、早期型の精神障害に相当するうつ様行動の可能性はある。

## 5 おわりに

本研究は、ステロイドホルモンの長期投与によるマウスの行動変化を捉えることを目的とした。長時間連続で行動解析を行った結果、40.2 $\mu$ g を摂取した投与24日目以降の総歩行距離及び38.8 $\mu$ g を摂取した投与23日目以降のリアリング回数に有意な減少を確認した。以上から、ステロイドホルモン長期投与によるマウスのうつ様行動の発現を捉えた可能性がある。本研究においてマウスのうつ様行動の発現を捉え、精神障害が生じるまでの投与量及び投与期間を定量的に調査することは、人間においてステロイド誘発性精神障害の発症までの投与量を明らかにすることに役立つと考えられる。明らかになった投与量を参考にすることで、治療時における投与ステロイド量の適切な調節に繋がり、最終的にはステロイド誘発性精神障害患者の減少が期待出来る。

しかし、コントロールマウス及び投与マウスが1匹ずつと少ないため、2匹のマウスの個体差による影響から未検出のうつ様行動が存在、もしくは正確な発現のタイミングが検出出来ていない可能性がある。従って、より統計的にうつ様行動が発現するタイミングを検証するために、今後はコントロールマウスとコルチコステロン投与マウスの個体差による影響について、個体数を増やすことで検討していく必要がある。

## 参考文献

- 1) A. L. Buchman: Side Effects of Corticosteroid Therapy, Journal of Clinical Gastroenterology, 33 巻-4 号, 289/294 (2001)
- 2) 厚生労働省: 薬剤誘起性うつ病, 重篤副作用疾患別対応マニュアル, 14/18 (2008)
- 3) R. A. Brachman: Ketamine as a Prophylactic Against Stress Induced Depressive like Behavior, Biological Psychiatry, 79-9 号, 776/786 (2016)
- 4) 山口: 不安関連行動の評価法, 日薬理誌, 130 巻, 105/101 (2007)
- 5) ネスラー: 分子神経薬理学 臨床神経科学の基礎, 始ページ/終ページ, 株式会社西村書店, 306/307 (2004)
- 6) 吾郷: うつ病と副腎皮質ステロイドホルモン受容体, 日薬理誌, 134 巻, 304/308 (2009)
- 7) M. Ciriaco: Corticosteroid-Related Central Nervous System Side Effects, Journal of pharmacology & pharmacotherapeutics, 4-1 号, 94/98 (2013)

# 対象物の事前知識を必要としない ステレオビジョン空間認識を用いたビジュアルサーボ

○山本太郎 寇ギョウ郡 田宏志 王俊祥 汪魯傑 李想 戸田雄一郎 見浪護 (岡山大学)

## Visual servoing by using stereo vision spatial recognition without predefined target knowledge

\*T. Yamamoto, Y. Kou, H. Tian, J. Wang, L. Wang, X. Li, Y. Toda and M. Minami  
( kayama University)

**Abstract**— We proposed a hand-eye visual servoing system without using predefined knowledge about target objects, for aiming the construction of robot system that take autonomous actions by robots themselves at unknown environment. In this study, the method of the system is introduced and the result of an experiment to track two objects which appears one after another in real time is also shown.

**Key Words:** visual servoing, Dual-eyes recognition

### 1 緒言

視覚情報をフィードバックループに組み込むビジュアルサーボがロボットの制御方式の一つとして提唱されて久しい。これまでに複数のカメラを用いる方法<sup>1)</sup>, ステレオカメラを用いる方法<sup>2)</sup>, RGB-D センサーを用いる方法<sup>3)</sup>, 手先にカメラを取り付けるハンドアイ方式<sup>4)</sup>等さまざまなものが発表されているが, それらは対象物およびモデルの形状や大きさ, 色などの情報をあらかじめ与えておく必要がある<sup>5, 6, 7)</sup>。しかしビジュアルサーボの活躍が求められる分野は時々刻々と変化するような環境であったり未知の環境であったりすることが考えられ, 予備知識が与えられるような環境は限定的であるため, より柔軟な認識方法が求められている。著者らのグループは, 2次元 Photo-model を用いて3次元立体対象物の位置姿勢計測ができること<sup>8)</sup>, またその計測結果に基づいてステレオビジョンハンドアイロボットの位置・姿勢の制御が可能であることを示した。またこの結果である Photo-model を用いたビジュアルサーボ系において, 左カメラ画像から Photo-model を生成することができれば事前に用意すべき Photo-model が不要であることに気付いた。著者らの研究グループはこの事前モデル定義を必要としない撮像対象物の位置・姿勢計測法を Projection-based Pose Tracking と呼び, これを用いたビジュアルサーボを Projection-based visual Servoing として提案した。本報ではこの認識法の概要について述べ, 複数物体についてシステムを再起動させずに認識, 追従した実験の結果についても報告する。

### 2 システム概要

本報で述べるロボットシステムに用いている対象物の認識手法は, 静止画像認識が基本となる。よって, ここでは, 1枚の静止画像に対する認識手法の概要を説明する。

Fig.1 に Projection-based Pose Tracking の手順の概略図を示す。PA10 に搭載されるカメラは Fig.2 に示すように, 2台のカメラを用いる。基準点を手先座標系  $\Sigma_H$  とする。また基準座標系  $\Sigma_W$  とする。左のカメラ座標系を  $\Sigma_{CL}$ , 画像座標系を  $\Sigma_{IL}$ , 右のカメラ座標

系を  $\Sigma_{CR}$ , 画像座標系を  $\Sigma_{IR}$  とする。左カメラ画像に映った対象物をモデルとして抽出し, 3次元空間における位置姿勢  $\phi = ({}^{CL}z_{MiC}, {}^{Hx}\theta_M, {}^{Hy}\theta_M)$  を GA(遺伝的アルゴリズム) の遺伝子により決定する。このとき,  ${}^{CL}x_{MiC}$  および  ${}^{CL}y_{MiC}$  は  ${}^{CL}z_{MiC}$  より求められる。このモデルを左カメラ画像から3次元空間へ逆射影し右カメラ画像に再度射影することで, 2次元の平面モデルを得る。この平面モデルと右カメラ画像との照合により適合度関数を計算し, 評価を行う。そして, 空間中の平面モデルの位置姿勢  $\phi$  (3変数) が対象物の位置姿勢と一致したとき, 適合度関数の値が最大値を示す。そのため, 対象物の認識問題は, 適合度関数の最大値探索問題に変換できる。適合度関数の最大値を探索・発見する場合, 様々な方法があるが, 一番単純かつ簡単な方法は全探索法である。これは, 全てのとりうる値を計算することで最大値を発見するものであり, 必ず最大値を発見できるが効率が悪い, つまり計算時間を多く費やすといった欠点を持っている。目標としているビジュアルサーボは動画像認識であり, 動画像認識は計算処理が短いことが重要であるため, 本研究では最適解探索に GA を適用することで, 効率良く短時間で最大値探索処理を行う。そして, GA が収束した時, GA の遺伝子により決定される立体モデルの位置姿勢  $\phi$  を対象物の位置姿勢と考えることで, 対象物の位置姿勢が計測できる。

### 3 位置姿勢認識

#### 3.1 射影変換行列

Fig.3(a) に示す中心射影の関係から, カメラの焦点距離を  $f$ , 中心座標を  $({}^I x_0, {}^I y_0)$ , カメラ座標  $\Sigma_C$  における  $x$  軸,  $y$  軸の距離 [mm] と画像座標系  $\Sigma_I$  における  $x$  軸,  $y$  軸の距離 [pixel] の比を  $\eta_x, \eta_y$  [mm/pixel] とする。また,  $\Sigma_C$  における任意の座標  $({}^C x_i, {}^C y_i, {}^C z_i)$  は,  $\Sigma_I$  で像  $({}^I x_i, {}^I y_i)$  となる。Fig.3(b) より  $\triangle oab$  と  $\triangle oa'b'$  が相似であることより,

$$ab : a'b' = bo : b'o \quad (1)$$

と表され, これは

$$X : Y = A : B \quad (2)$$

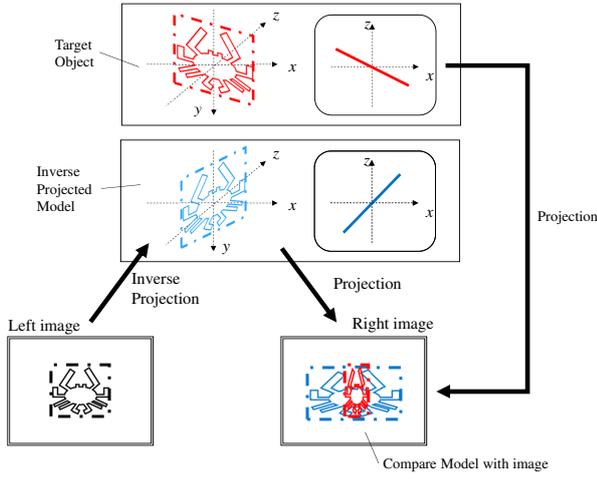


Fig. 1: Projection-based Method process

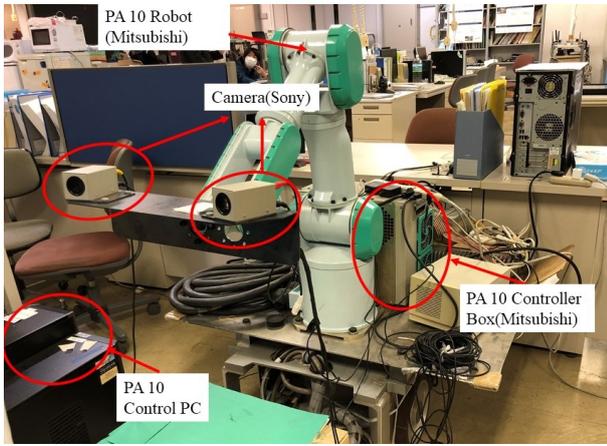


Fig. 2: Hand-eye manipulator used in the system

$$\frac{X}{Y} = \frac{A}{B} \quad (3)$$

と書ける。よって、任意の点と像の座標関係は Fig.3(a) より次式で表される。

$$\frac{{}^I y_i \eta_x}{C x_i} = \frac{a}{C z_i} \quad (4)$$

$$\frac{{}^I x_i \eta_y}{C y_i} = \frac{a}{C z_i} \quad (5)$$

また、対象物からのカメラの距離  $a$  は、焦点距離  $f$  に比べ大きいので、 $a \doteq f$  と近似できると考えられる。以上のことと式 (4), (5) より式 (6) が導出される。

$$\begin{bmatrix} {}^I x_i \\ {}^I y_i \end{bmatrix} = \frac{1}{C z_i} \begin{bmatrix} \frac{f}{\eta_x} & 0 & 0 & 0 \\ 0 & \frac{f}{\eta_y} & 0 & 0 \end{bmatrix} \begin{bmatrix} C x_i \\ C y_i \\ C z_i \\ 1 \end{bmatrix} \quad (6)$$

これより、カメラへの射影変換行列を  $\mathbf{P}$  と表し、次のようにまとめる。

$$\mathbf{P}^{(C z_i)} = \frac{1}{C z_i} \begin{bmatrix} \frac{f}{\eta_x} & 0 & 0 & 0 \\ 0 & \frac{f}{\eta_y} & 0 & 0 \end{bmatrix} \quad (7)$$

### 3.2 左右カメラへの射影変換

まず、手先座標系  $\Sigma_H$  とモデル座標系  $\Sigma_{M_i}$  の関係は、 $\Sigma_H$  から  $\Sigma_{M_i}$  への同次変換行列を  ${}^H \mathbf{T}_{M_i}$ 、 $\Sigma_H$  及び  $\Sigma_{M_i}$  で表した空間中に逆射影された  $i$  番目のモデル上の任意座標を  ${}^H \mathbf{r}_{Mij}$ 、 ${}^{M_i} \mathbf{r}_j$  とすると、 ${}^H \mathbf{r}_{Mij}$  は、

$${}^H \mathbf{r}_{Mij} = {}^H \mathbf{T}_{M_i} {}^{M_i} \mathbf{r}_j \quad (8)$$

と表される。左カメラ座標系  $\Sigma_{CL}$  と手先座標系  $\Sigma_H$  の関係は、 $\Sigma_{CL}$  から  $\Sigma_H$  への同次変換行列を  ${}^{CL} \mathbf{T}_H$  とすると、 ${}^{CL} \mathbf{r}_{Mij}$  は、

$${}^{CL} \mathbf{r}_{Mij} = {}^{CL} \mathbf{T}_H {}^H \mathbf{r}_{Mij} \quad (9)$$

と表される。左画像座標系  $\Sigma_{IL}$  と左カメラ座標系  $\Sigma_{CL}$  の関係は、 ${}^{IR} \mathbf{r}_{Mij}$  と同様に、射影変換行列  $\mathbf{P}$  を使うと、 ${}^{IL} \mathbf{r}_{Mij}$  は、

$${}^{IL} \mathbf{r}_{Mij} = \mathbf{P} {}^{CL} \mathbf{r}_{Mij} \quad (10)$$

と表される。

また、右カメラ座標系  $\Sigma_{CR}$  と手先座標系  $\Sigma_H$  の関係は、 $\Sigma_{CR}$  から  $\Sigma_H$  への同次変換行列を  ${}^{CR} \mathbf{T}_H$  とすると、 ${}^{CR} \mathbf{r}_{Mij}$  は、

$${}^{CR} \mathbf{r}_{Mij} = {}^{CR} \mathbf{T}_H {}^H \mathbf{r}_{Mij} \quad (11)$$

と表される。右画像座標系  $\Sigma_{IR}$  と右カメラ座標系  $\Sigma_{CR}$  の関係は、射影行列  $\mathbf{P}$  を使い、 ${}^{CR} \mathbf{r}_{Mij}$  を  $\Sigma_{IR}$  に対して射影することで、 ${}^{IR} \mathbf{r}_{Mij}$  は、

$${}^{IR} \mathbf{r}_{Mij} = \mathbf{P} {}^{CR} \mathbf{r}_{Mij} \quad (12)$$

と表される。よって、式 (8), (9), (10) より左画像への射影変換が、式 (8), (11), (12) より右画像への射影変換が求まる。

$${}^{IL} \mathbf{r}_{Mij} = \mathbf{P} {}^{CL} \mathbf{T}_H {}^H \mathbf{T}_{M_i} {}^{M_i} \mathbf{r}_j \quad (13)$$

$${}^{IR} \mathbf{r}_{Mij} = \mathbf{P} {}^{CR} \mathbf{T}_H {}^H \mathbf{T}_{M_i} {}^{M_i} \mathbf{r}_j \quad (14)$$

本研究では、手先にカメラを直接固定しているため、 ${}^{CL} \mathbf{T}_H$ 、 ${}^{CR} \mathbf{T}_H$  は既知である。そこで、式 (13), (14) を次のように変形する。

$${}^{IL} \mathbf{r}_{Mij} = \mathbf{P} {}^{CL} \mathbf{T}_{M_i} {}^{M_i} \mathbf{r}_j \quad (15)$$

$${}^{IR} \mathbf{r}_{Mij} = \mathbf{P} {}^{CR} \mathbf{T}_{M_i} {}^{M_i} \mathbf{r}_j \quad (16)$$

### 3.3 左カメラからの逆射影変換

Projection-based Matching 法では、左カメラにおいて作成したモデルを逆射影変換を用いて空間中へ投影する。この逆射影変換を行うために、まず射影変換行列式 (7) に対応する逆射影変換行列  $\mathbf{P}^+$  を定義する。

$$\mathbf{P}^+(C z_i) = C z_i \begin{bmatrix} \frac{\eta_x}{f} & 0 & 0 & 0 \\ 0 & \frac{\eta_y}{f} & 0 & 0 \end{bmatrix}^T \quad (17)$$

いま、画像座標系上のモデル中心座標  ${}^{IL} \mathbf{r}_{iC}$  からカ

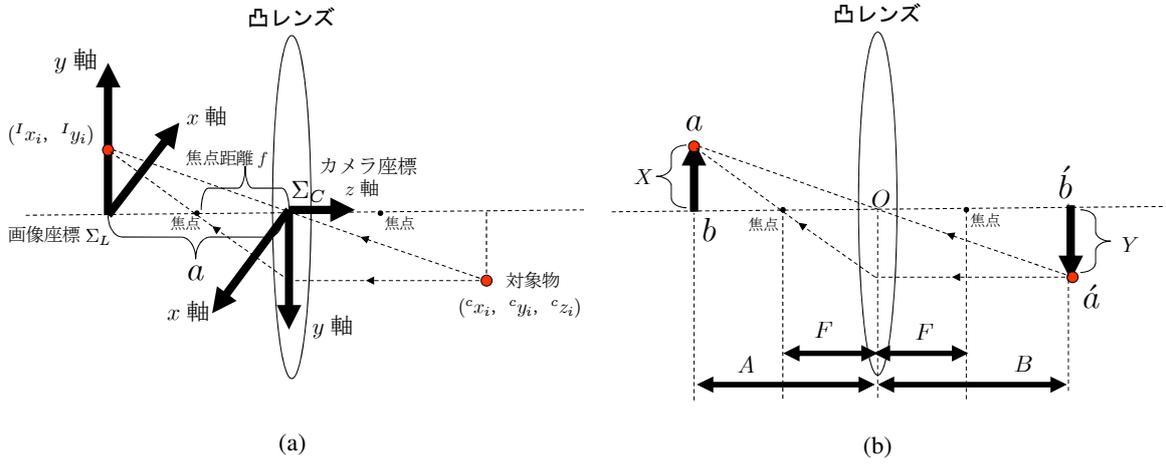


Fig. 3: Geometrical relations of a convex lens

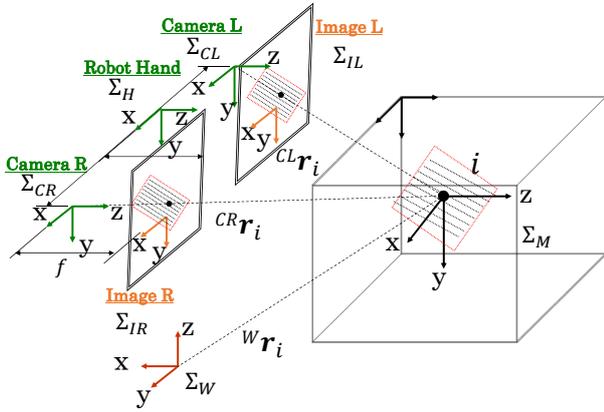


Fig. 4: Coordinate system

メラ座標系上でのモデル中心座標  ${}^{CL}\mathbf{r}_{Mi}$  への逆射影変換は冗長項をもつ一般解の形を用いた次式で表される。

$$\begin{bmatrix} {}^{CL}x_{Mi} \\ {}^{CL}y_{Mi} \\ {}^{CL}z_{Mi} \\ 1 \end{bmatrix} = \mathbf{P}^+(l_3) \begin{bmatrix} {}^{IL}x_{Mi} \\ {}^{IL}y_{Mi} \end{bmatrix} + (\mathbf{I}_4 - \mathbf{P}^+(l_3)\mathbf{P})\mathbf{l} \quad (18)$$

ここで  $\mathbf{l}$  は任意の定数  $l_1$  から  $l_4$  を用いて表される任意ベクトルである。

$$\mathbf{l} = \begin{bmatrix} l_1 \\ l_2 \\ l_3 \\ l_4 \end{bmatrix} \quad (19)$$

次に、空間中のモデル座標系上にある点  ${}^{Mi}\mathbf{r}_j$  の、カメラ座標系への同次変換を考える。この同次変換は式 (20) で表される。

$$\begin{bmatrix} {}^{CL}x_{Mij} \\ {}^{CL}y_{Mij} \\ {}^{CL}z_{Mij} \\ 1 \end{bmatrix} = {}^{CL}\mathbf{T}_{Mi}({}^{CL}\mathbf{r}_{Mi}, {}^{CL}\phi_{Mi}) {}^{Mi}\mathbf{r}_j \quad (20)$$

この式を展開し式 (18) の関係を用いると,  ${}^{CL}x_{Mij}$ ,  ${}^{CL}y_{Mij}$ ,  ${}^{CL}z_{Mij}$  が, 式 (21) に例示するように  ${}^{CL}z_{Mi}$  および  ${}^{Mi}x_j$ ,  ${}^{Mi}y_j$  の関数として与えられる。ここで  $L\theta_{ix}$ ,  $L\theta_{iy}$  は左カメラから見た対象物の角度である。

$$\begin{aligned} {}^{CL}z_{Mij} &= S_{L\theta_{ix}} {}^{Mi}y_j - C_{L\theta_{ix}} S_{L\theta_{iy}} {}^{Mi}x_j + {}^{CL}z_{Mi} \\ &= \begin{bmatrix} -C_{L\theta_{ix}} S_{L\theta_{iy}}, S_{L\theta_{ix}}, 0, {}^{CL}z_{Mi} \end{bmatrix} \begin{bmatrix} {}^{Mi}x_j \\ {}^{Mi}y_j \\ 0 \\ 1 \end{bmatrix} \end{aligned} \quad (21)$$

ここで,  $\Sigma_M$  に逆射影したモデルの座標  ${}^{Mi}x_j$ ,  ${}^{Mi}y_j$  を求めるために, 式 (15) の逆射影式 (22) を展開する。展開すると  ${}^{Mi}x_j$ ,  ${}^{Mi}y_j$  と  ${}^{CL}z_{Mi}$  との関係式が得られるため, これよりモデルの逆射影後の座標  ${}^{Mi}\mathbf{r}_j$  が求められる。

$${}^{Mi}\mathbf{r}_j = {}^{Mi}\mathbf{T}_{CL}({}^{CL}\mathbf{r}_{Mi}, {}^{CL}\theta_{Mi}) \cdot \mathbf{P}^+({}^{CL}z_{Mij}) \cdot {}^{IL}\mathbf{r}_j \quad (22)$$

以上のことから, 空間中に逆射影されたモデルの  $\Sigma_{CL}$  上での座標  ${}^{CL}\mathbf{r}_{Mij} = ({}^{CL}x_{Mij}, {}^{CL}y_{Mij}, {}^{CL}z_{Mij})$  は,  ${}^{CL}z_{Mi}$  及び  $L\theta_{ix}$ ,  $L\theta_{iy}$  が与えられれば一意に定まることが分かる。 $\Sigma_{CL}$  と  $\Sigma_H$  との位置関係は既知であるため,  $L\theta_{ix}$ ,  $L\theta_{iy}$  は手先座標系から見る対象の姿勢  $Hx\theta_M$ ,  $Hy\theta_M$  より求められる。

### 3.4 適合度関数の定義

左右ビデオカメラから入力される画像は, 0 ~ 359 で表される色相値によって構成される。探索モデルは, Fig.5 に示すように対象物の評価とその周囲の色相変化を評価するために, 内部領域  $S_{R,in}$ ,  $S_{L,in}$  と帯領域  $S_{R,out}$ ,  $S_{L,out}$  によって構成される。ここで, 右画像領域  ${}^{IR}\mathbf{r}_i^j(\phi_M^j)$  における色相値に基づく評価値を  $p_R({}^{IR}\mathbf{r}_i^j(\phi_M^j))$  とする。対象物を評価する内部領域において, モデルの色相値  $H_{MR}$  とカメラ画像の色相値  $H_{IR}$  の差が  $\pm 20$  以内の場合の評価値を “+2”, また, 対象物を評価する内部領域において, モデルの色相値

とカメラ画像の色相値が  $\pm 20$  以上離れていた場合は、評価値を “-1” と設定する。背景を評価する帯領域の評価値を “0.1” と設定し、帯領域においてモデルの色相値とカメラ画像の色相値が  $\pm 20$  以上離れていた場合は、評価値を “-1” と設定する。

このような正負の評価値をもつ探索モデルと画像との相関を表す適合度関数を次式に示す。

$$F_R(\phi_M^j) = \left( \begin{array}{c} \sum_{IR\mathbf{r}_i^j \in S_{R,in}(\phi_M^j)} p_{R,in}(IR\mathbf{r}_i^j(\phi_M^j)) + \sum_{IR\mathbf{r}_i^j \in S_{R,out}(\phi_M^j)} p_{R,out}(IR\mathbf{r}_i^j(\phi_M^j)) \\ / (2 \times N_{R,in} + 0.1 \times N_{R,out}) \end{array} \right) \quad (23)$$

$$p_{R,in}(IR\mathbf{r}_i^j(\phi_M^j)) = \begin{cases} 2, & \text{if } (|H_{IR}(IR\mathbf{r}_i^j(\phi_M^j)) \\ & -H_{MR,in}(IR\mathbf{r}_i^j(\phi_M^j))| \leq 20); \\ -1, & \text{otherwise.} \end{cases} \quad (24)$$

$$p_{R,out}(IR\mathbf{r}_i^j(\phi_M^j)) = \begin{cases} 0.1, & \text{if } (|H_{IR}(IR\mathbf{r}_i^j(\phi_M^j)) \\ & -H_{MR,out}(IR\mathbf{r}_i^j(\phi_M^j))| \leq 20); \\ -1.0, & \text{otherwise.} \end{cases} \quad (25)$$

この関数は、右画像領域  $IR\mathbf{r}_i^j(\phi_M^j)$  の中で、 $S_{R,in}(\phi_M^j)$  に重なる入力画像の評価値  $p_{R,in}(IR\mathbf{r}_i^j(\phi_M^j))$  の合計値と  $S_{R,out}(\phi_M^j)$  に重なる入力画像の評価値  $p_{R,out}(IR\mathbf{r}_i^j(\phi_M^j))$  を加えることで、右画像の適合度  $F(\phi_M^j)$  を得る。これらを加算した適合度関数  $F(\phi_M^j)$  を用いて、右の画像と再射影された平面モデルとを評価する。この適合度関数  $F(\phi_M^j)$  は、空間中に逆射影されたモデルの持つ位置 姿勢情報より一意に決定する関数であり、逆射影されたモデルが対象物と一致すれば、右画像においても対象物と探索モデルが一致するはずである。ただし、 $F(\phi_M^j) \leq 0$  の場合、 $F(\phi_M^j) = 0$  とする。

同様に、左画像領域  $IL\mathbf{r}_i^j(\phi_M^j)$  における色相値に基づく評価値を  $p_L(IL\mathbf{r}_i^j(\phi_M^j))$  とする。対象物を評価する内部領域において、モデルの色相値とカメラ画像の色相値の差が  $\pm 20$  以内の場合は、評価値を “+2”， $\pm 20$  範囲の以外の場合は、評価値を “-1” と設定する。帯領域では、モデルの色相値とカメラ画像の色相値の差が  $\pm 20$  以内の場合は、評価値を “+0.1”， $\pm 20$  範囲以外の場合は、評価値を “-1” と設定する。このような正負の評価値をもつ探索モデルと画像との相関を表す適合度関数を次式に示す。

$$F_L(\phi_M^j) = \left( \begin{array}{c} \sum_{IL\mathbf{r}_i^j \in S_{L,in}(\phi_M^j)} p_{L,in}(IL\mathbf{r}_i^j(\phi_M^j)) + \sum_{IL\mathbf{r}_i^j \in S_{L,out}(\phi_M^j)} p_{L,out}(IL\mathbf{r}_i^j(\phi_M^j)) \\ / (2 \times N_{L,in} + 0.1 \times N_{L,out}) \end{array} \right) \quad (26)$$

$$p_{L,in}(IL\mathbf{r}_i^j(\phi_M^j)) = \begin{cases} 2, & \text{if } (|H_{IL}(IL\mathbf{r}_i^j(\phi_M^j)) \\ & -H_{ML,in}(IL\mathbf{r}_i^j(\phi_M^j))| \leq 20); \\ -1, & \text{otherwise.} \end{cases} \quad (27)$$

$$p_{L,out}(IL\mathbf{r}_i^j(\phi_M^j)) = \begin{cases} 0.1, & \text{if } (|H_{IL}(IL\mathbf{r}_i^j(\phi_M^j)) \\ & -H_{ML,out}(IL\mathbf{r}_i^j(\phi_M^j))| \leq 20); \\ -1.0, & \text{otherwise.} \end{cases} \quad (28)$$

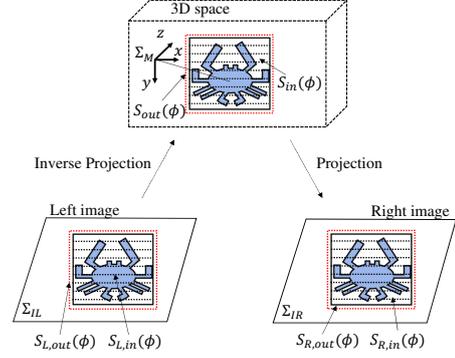


Fig. 5: Searching model

### 3.5 RT-MS GA

前項で述べた適合度関数を用いることによって、対象物の位置 姿勢を探索する問題は、適合度関数  $F(\phi_M^j)$  の最大値を探索する問題に置き換えることができる。本手法では、この最大値を探索する最適化問題に対して GA を適応することで探索時間の短縮を行う。また、個体の位置 姿勢情報を表す遺伝子情報を以下に示す。

$$\begin{array}{c} CL_{z_{Mi}} \quad Hx_{\theta_{Mi}} \quad Hy_{\theta_{Mi}} \\ \underbrace{01 \cdots 01}_{10bit} \quad \underbrace{00 \cdots 01}_{7bit} \quad \underbrace{11 \cdots 01}_{7bit} \end{array}$$

個体の位置 姿勢は Projection-based Matching 法における立体モデルの位置 姿勢を表しており、上位 10bit がこの遺伝子で与えられる空間中に逆射影したモデルのカメラからの距離を表わし、残り 14bits は 7bit ずつで、空間中に逆射影したモデルの姿勢を表わしている。このとき使用する bit 数は探索時間短縮のために減らすことがある。次に、各個体は自分の位置 姿勢情報を用いて式 (26) に示した適合度関数  $F(\phi_M^j)$  より適合度値を得る。この値の優劣により進化処理が行われ、世代交代による次世代の集合が構成される。このとき、次世代の集合は前世代において適合度が高かった位置 姿勢、つまり対象物を表す適合度関数の最大値近辺に向かって近づく。この処理 (世代交代) を繰り返すことにより、GA は対象物の位置 姿勢を表す最大値を発見する。GA を用いた探索過程を Fig.6 に示す。

ただし一般には GA の収束を一定時間待つ必要があり、適合度関数が十分に高い値を示すときに対象物の認識を完了すると、その時点では周囲の状況が大きく変化している可能性がある。そこで提案されたのが Real-Time Multi-Step GA である。これは新しく入力され

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 の進化を進め、その時点で最も高い適合度を与える個体とその時刻における位置・姿勢として出力する実時間遺伝的認識法である。Fig.7 にフローチャートを示す。

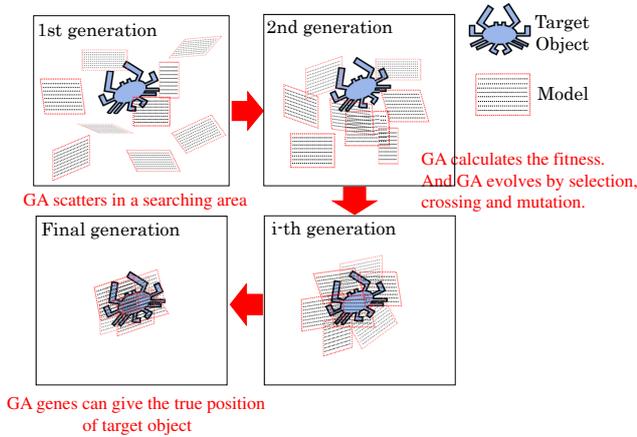


Fig. 6: Search Process using GA

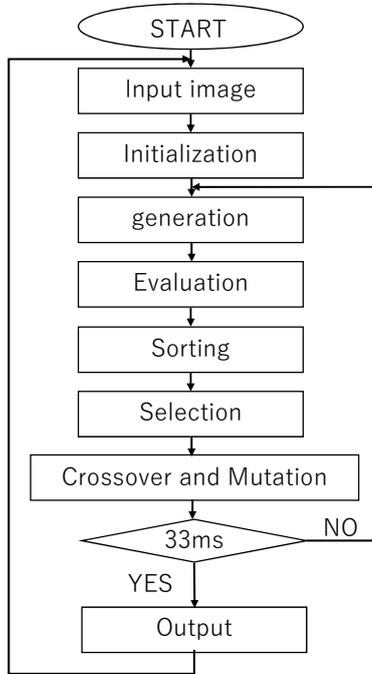


Fig. 7: Flowchart of Real-Time Multi-Step GA

## 4 交換される対象物に対する認識・追従実験

### 4.1 実験環境

本システムは対象物把持ロボット (Target ObjectRobot) とビジュアルサーボ認識ロボット (.S.-Robot) との二つの部分で構成されている。ロボットはともに三菱重工業株式会社製の PA10 であり、認識部のカメラセンサーは FCR-I 11A(Sony 製) である。各部分の座標関係は Fig.8 で表す。また今回使用した対象物を Fig.9 に示す。

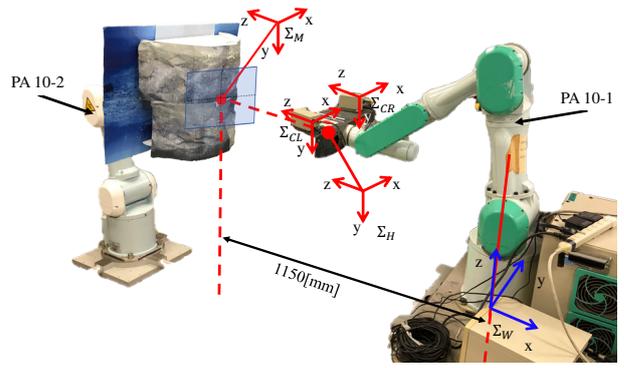


Fig. 8: The experiment environment

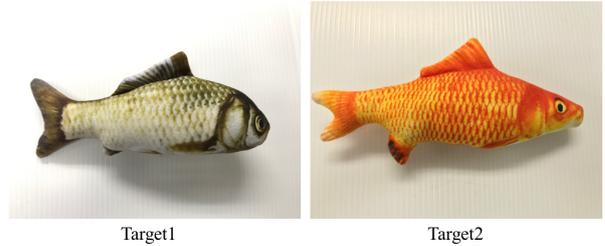


Fig. 9: Target objects

### 4.2 実験内容

本実験では、対象物を実時間中に交換しながら、それぞれの対象物に対して一定の距離を保つようにビジュアルサーボを行う。まず  $({}^W x, {}^W y, {}^W z) = (-1150, -50, 550)$  の位置に対象物を設置し、 $\Sigma_W$  の  $y$  軸方向に  $+50$ 、 $z$  軸方向に  $-50$ 、 $y$  軸方向に  $-50$ 、 $z$  軸方向に  $+50$  のように一周移動させる。そこで対象物を異なるものへ変更した後、システムを再起動せずにモデルを再度作成して認識させ、同様に対象物を移動させる。このときビジュアルサーボ認識ロボットは対象物の位置姿勢を認識し、 ${}^W x_M, {}^W y_M, {}^W z_M$  の偏差がそれぞれ  $500, 0, 100$ [mm] となるように目標を設定し動作する。

### 4.3 実験結果

対象物の認識結果を Fig.10 に、それを元にしたビジュアルサーボ認識ロボットの目標位置と実際の位置の結果を Fig.11 に示す。Fig.10 において破線が対象物の真値、実線が認識値である。また Fig.11 において破線がビジュアルサーボ認識ロボットの目標位置、実線が実際の位置である。結果としては、Projection-based Matching 法を用いたビジュアルサーボシステムは実時間に交換される対象物についても見失うことなく認識した。 $\Sigma_W$  の  $y$  軸方向については対象物の真値と認識との間に最大  $50$ [mm] ほどの誤差が見られるが、 $x$  軸方向、 $z$  軸方向についてはほぼ真値付近で認識していることが分かる。またビジュアルサーボ認識ロボットの位置についても、指定した距離を保って動作していることが分かる。

## 5 結言

本報では、Projection-based Pose Tracking の概要と、それを用いた認識、ビジュアルサーボ実験の結果について報告した。今回の実験結果より、Projection-

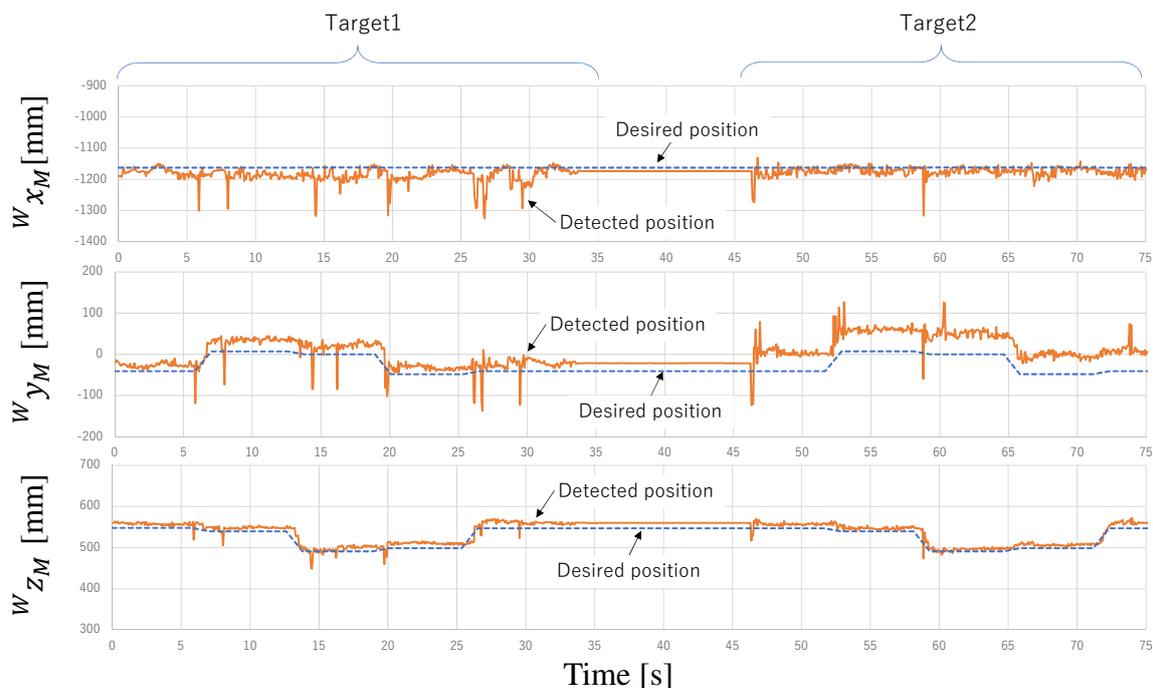


Fig. 10: The detection result and desired position of target in x,y, axis

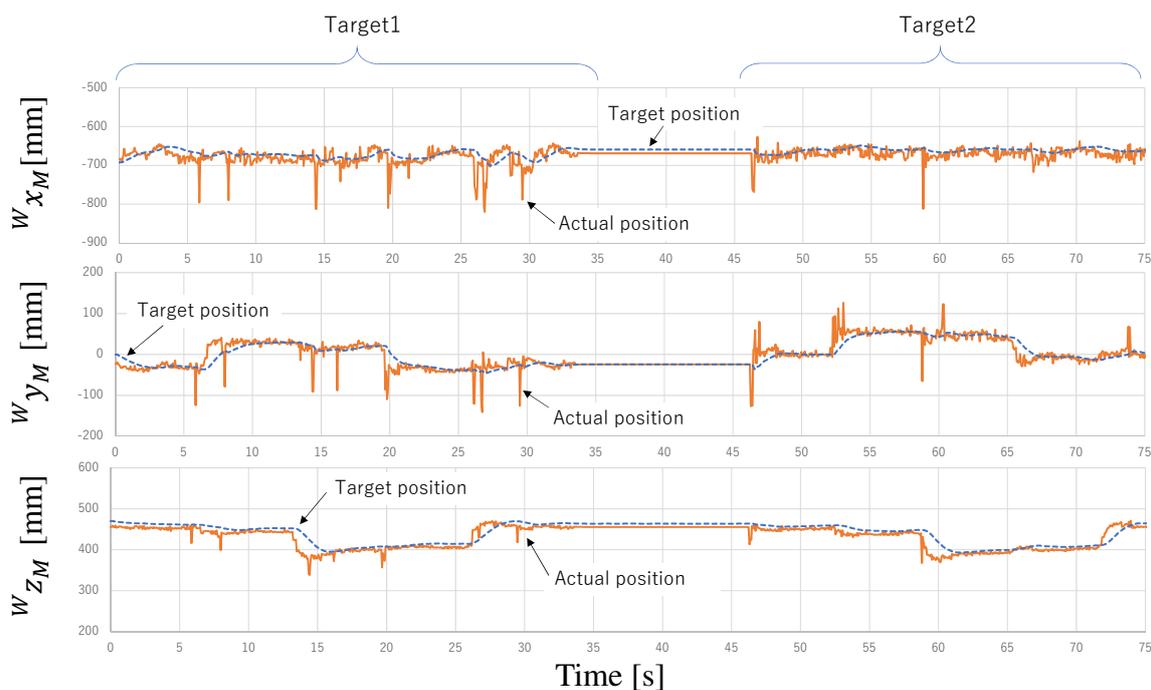


Fig. 11: The target hand position and actual hand position of PA10-1 in x,y, axis

based Pose Tracking によって実時間中に交換された未知対象物についてその位置を認識できることがわかった。今後は本システムの認識精度やロバスト性についての検証を進めていく予定である。

#### 参考文献

- 1) J. Stavnitzky, D. Capson: "Mutiple Camera Model-Based 3-D Visual Servoing," IEEE Trans. on Robotics and Automation, vol.16, No.6 (2000)
- 2) W. Song, M. Minami, Y. Mae and S. Aoyagi: "Online Evolutionary Head Pose Measurement by Feed-forward Stereo Model Matching," IEEE Int. Conf. on Robotics and Automation (ICRA), 4394/4400, (2007)
- 3) Baraglia, Jimmy, et al: "Initiative in robot assistance during collaborative task execution." 2016 11th ACM/IEEE International Conference on Human-Robot Interaction (HRI). IEEE (2016)
- 4) 松浦精太郎, 丸典明: "視空間誤差を用いた仮想バネダンパ仮説に基づくダイナミックビジュアルサーボによるEye-In-Hand型ロボットの位置姿勢制御", 日本機械学会論文集 (C編). 77-776, pp.186-195 (2011)
- 5) Petsch, Susanne, and Darius Burschka: "Estimation of spatio-temporal object properties for manipulation tasks from observation of humans." Robotics and Au-

tomation (ICRA), 2010 IEEE International Conference on. IEEE (2010)

- 6) Myint, Myo, et al: " Visual-servo-based autonomous docking system for underwater vehicle using dual-eyes camera 3D-pose tracking." 2015 IEEE/SICE International Symposium on System Integration (SII). IEEE (2015)
- 7) Cui, Yu, et al: "Analyses about Trackability of Hand-eye-vergence Visual Servoing in Lateral Direction." Applied Mechanics and Materials. vol. 772. Trans Tech Publications (2015).
- 8) Khaing Win Phyu, Ryuki Funakubo, Ikegawa Fumiya, Yasutake Shinichiro, Mamoru Minami: "Verification of Recognition Performance of Cloth Handling Robot with Photo-model-based Matching," IEEE ICMA 2017, Takamatsu, August 6-9 (2017)

# 連続カオスシステムにおける外部フィードバック信号による カオス共鳴制御の検討

○信川創 柴田夏作 (千葉工業大学) 道法浩孝 (高知大学) 西村治彦 (兵庫県立大学)  
山西輝也 (福井工業大学)

## Controlling Chaotic Resonance by External Feedback Signals in Continuous Chaotic Systems

\*S. Nobukawa, N. Shibata (Chiba Institute of Technology),  
H. Nishimura (University of Hyogo), and T. Yamanishi (Fukui University of Technology)

**Abstract**— It is widely known that fluctuations in nonlinear systems can enhance the synchronization with weak input signals. These nonlinear synchronization phenomena are classified to stochastic resonance and chaotic resonance. Many applications of stochastic resonance have been proceeding, utilizing its enhancing effect for the signal sensitivity. While, few studies for application of chaotic resonance have not been reported. Under this circumstances, previously, we developed a method to control the chaotic state for appropriate state of chaotic resonance by the external feedback signal called a reducing the range of orbit (RRO) feedback method for discrete chaotic systems. This method might facilitate the application of chaotic resonance. However, in the process applying RRO feedback method to the actual chaotic systems including biological systems, the developing the RRO feedback signals in the continuous chaotic systems must be considered. Therefore, in this study, we extended the RRO feedback method to continuous chaotic systems by focusing on the map function on the Poincaré section. We applied the extended RRO feedback method to Chua's circuit as a continuous chaotic system. As the results, it is confirmed that the RRO feedback signal can induce the chaotic resonance. In conclusion, this study is the first to report the application of RRO feedback to a continuous chaotic system. This outcome of this study will bring further device development of chaotic resonance.

**Key Words:** Chaotic resonance, Feedback control.

## 1 はじめに

微弱な入力信号に対する信号応答性が、外界からのノイズの影響によって増強される現象として、確率共鳴が知られており、気象システムから生体システム、社会システムに至る様々な非線形システムで観測されている<sup>1, 2, 3)</sup>。近年、この確率共鳴の優れた信号応答性に着目した工学的な応用研究が活発に行われている<sup>4, 5, 6, 7, 8, 9)</sup>。Tadokoroらは、デジタル通信における受信感度を確率共鳴のメカニズムにより、増強する通信方式を提案した<sup>8)</sup>。また、医用工学的な応用としては、Kuritaらは、外科手術における執刀医の触覚感度をノイズ振動によって増強させるウェアラブルなデバイスの開発を行った<sup>4, 7)</sup>。また、ノイズ振動の印加による麻痺患者の触覚感動の増強法などが提案されている<sup>5, 6)</sup>。更に、Groenらは、認知機能レベルでの確率共鳴のメカニズムの適用として、Transcranial random noise stimulation と呼ばれる非侵襲的な刺激印加の手法により、視覚野にノイズを加えることで、人間の知覚能力を向上させる手法を提案している<sup>9)</sup>。

このような確率的ノイズの印加だけでなく、非線形システムの内的なゆらぎであるカオスによっても類似した信号応答性の増強現象が起こることが知られており、カオス共鳴と呼ばれている<sup>10)</sup>。このカオス共鳴については、これまでに確率共鳴よりも高い信号応答性の増強が実現することが示されているが<sup>11, 12)</sup>、その工学的応用には至っていない。その理由の一つとして考えられるのは、確率共鳴では、外界からのノイズの強度を調整することで、確率共鳴を生起させるが、カオス共鳴ではシステム内部のパラメータ調整が必要で

あることが挙げられる。一般に、生体システムのように外界からシステム内部のパラメータを調整することは、困難であることが多い。

このような状況の中、我々は外界からのフィードバック信号の印加によって、システム内部のパラメータを調整することなく、確率共鳴を生起させる軌道領域減少法 (Reduced region of orbit (RRO) method) を提案し、cubic 離散写像や cubic 離散写像結合系、興奮性-抑制性のニューラルシステムのようなカオス離散写像システムへの適用を進めてきた<sup>13, 14, 15)</sup>。この手法は、外界からの摂動によって、カオス軌道を不動点や安定軌道に誘導する OGY 法<sup>16)</sup> や遅延フィードバック法<sup>17, 18)</sup>、 $H_\infty$  法<sup>19)</sup> とは異なり、カオスを除去することなくカオス状態を共鳴に適した状態に遷移させる方法である。しかし、実際の生体システムへの RRO 法の適用には、RRO 法の連続システムへの拡張が必要となる。そこで、本研究では、カオス共鳴が生起する条件であるカオス-カオス間欠性 (chaos-chaos intermittency (CCI)) を示す連続カオスシステムである Chua 回路<sup>20, 21)</sup> を対象に、Poincaré 断面上でのシステム挙動に着目した RRO 法の適用を行う。

## 2 モデルと評価指標

### 2.1 RRO フィードバック信号を伴う Chua 回路

Chua 回路 ((1)-(3) 式) は double-scroll 型のアトラクタ構造を持ち、その軌道は CCI を示すことが知られて

いる<sup>20, 21)</sup>.

$$\dot{x} = \alpha(y - x) - \alpha f(x) \quad (1)$$

$$\dot{y} = x - y + z \quad (2)$$

$$\dot{z} = -\beta y - \gamma z \quad (3)$$

ここで、関数  $f$  は Chua 回路におけるダイオードの非線形特性を与える関数であり、(4) 式で与えられる。

$$f(x) = m_1 x + \frac{1}{2}(m_0 - m_1)(|x + 1| - |x - 1|) \quad (4)$$

本研究では、軌道が CCI を示す ( $\alpha = 8.5, \beta = 12.0732, \gamma = 0.0052, m_0 = -0.1768, m_1 = -1.1468$ ) のパラメータ設定を用いる<sup>21)</sup>。また、数値解析では、非線形微分方程式のソルバーである SUNDIALS を用いる<sup>22)</sup>。

本稿では、併合した2つのカオスアトラクタを RRO 法によって分離する。Fig. 1 に、連続カオスシステムへの RRO 法の適用法を示す。Poincaré 断面  $P$  を  $i(i = 1, 2, \dots)$  回目通過する時の RRO フィードバック信号は  $P$  上での  $z$  値である  $z_i$  の関数  $u$  とフィードバック強度  $K$  で与えられる。文献<sup>13, 14)</sup> で我々は、CCI が生じる場合、アトラクターは3次の写像の構造を持ち、局所的な最大値と最小値の絶対値の減少によって CCI が抑制されること示した。本稿では、 $z_i$  の写像における局所最大値と最小値を減少させるように(5) 式のように関数  $u$  を設計する。

$$u(X) = -(X - \mu) \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(X - \mu)^2}{2\sigma^2}\right) \quad (5)$$

尚、Poincaré 断面は  $P = \{(x, y, z) | x = 0, y < 0\}$ <sup>23)</sup> のように設定する。 $\mu$  は  $z_i$  を分離する中心値で、 $\sigma$  は RRO フィードバック信号の影響する範囲を決定するパラメータであり、 $(\mu, \sigma) = (-3.7, 0.3)$  のように設定する。そして、 $Ku(z_i)$  を(6) 式に従い印加する。

$$\dot{z} = -\beta y - \gamma z + Ku(z_i) \quad (6)$$

更に、入力信号である  $S(t) = A_s \sin(2\pi f_s t)$  への信号応答性の評価のために、 $\dot{z}$  に(7) 式に従い、信号を印加する。

$$\dot{z} = -\beta y - \gamma z + Ku(z_i) + S(t) \quad (7)$$

## 2.2 信号応答性の尺度

アトラクタ併合が生じる状況下では、 $z_i$  の軌道は  $z_i \leq \mu$  と  $z_i > \mu$  の領域を行き来する、すなわち  $z_i$  での CCI が生じる。この CCI の  $S(t)$  への応答性を評価するために、本研究では、CCI の切り替り時間  $T_{cci} = t_{k+1} - t_k$  ( $k = 1, 2, 3, \dots$ ) (ただし、 $t_k$  はアトラクタの切り替り時刻) の  $S(t)$  の周期  $T_s = 1/f_s$  周りでの強度<sup>24)</sup>:

$$P_1 = \int_{0.75T_s}^{1.25T_s} P(T_{cci}) dT_{cci}. \quad (8)$$

を用いる。ここで、 $P(T_{cci})$  は  $T_{cci}$  の確率分布を表す。

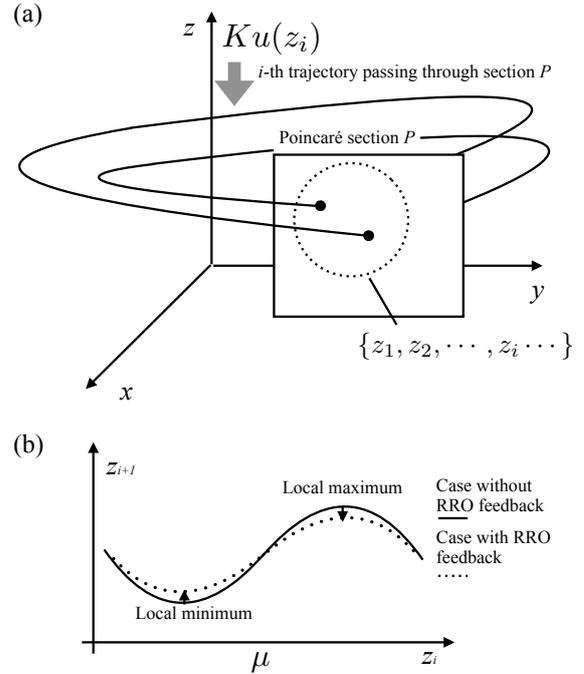


Fig. 1: Overview of the “reduced region of orbit” (RRO) feedback control method for continuous chaotic systems. (a) Orbit of a chaotic system and the RRO feedback signal. (b) Map function of  $z_i$  on Poincaré section  $P$ .

## 3 結果

### 3.1 Chua 回路における内部パラメータによるアトラクタ併合分岐

RRO フィードバック信号強度  $K = 0$  の場合における Fig.2 に  $z_i$  の分岐図を  $\alpha$  の関数として示す。この結果から、 $\alpha$  の増加に伴って、周期倍分岐を起こし、 $\alpha \gtrsim 8.42$  の領域でカオスが出現する様子が確認できる。更に、 $8.42 \lesssim \alpha \lesssim 8.48$  の場合、 $z_i$  は  $-4.5 \lesssim z_i \lesssim -3.7$  か  $-3.7 \lesssim z_i \lesssim -2.5$  の領域に初期値に応じて閉じ込められる様子が確認できる。 $\alpha \gtrsim 8.48$  では、 $z_i$  は両領域を行き来する CCI が生じることが分かる。

### 3.2 Chua 回路における RRO 法によるアトラクタ併合分岐の制御

RRO フィードバック信号  $K = 0$  において、 $z_i$  の CCI が生じる  $\alpha = 8.52$  に固定し、RRO フィードバック信号  $Ku(z_i)$  を印加する。Figure 3 は、 $z_i$  の分岐図を  $K$  の関数として示したものである。 $0 \lesssim K \lesssim 0.21$  においては、 $z_i$  は  $-4.5 \lesssim z_i \lesssim -3.7$  と  $-3.7 \lesssim z_i \lesssim -2.5$  の領域で CCI を示す。 $K$  の上昇に伴って、 $K \gtrsim 0.21$  で  $z_i$  は  $-4.5 \lesssim z_i \lesssim -3.7$  か  $-3.7 \lesssim z_i \lesssim -2.5$  の領域に初期値に依存してトラップされる。

### 3.3 Chua 回路における RRO 法によるカオス共鳴の誘起

微弱な正弦波入力信号 ( $S(t) = A_s \sin(2\pi f_s t), A_s = 10^{-3}$ ) に対する信号応答性を評価する。Fig. 3 は  $P_1$  の RRO フィードバック強度  $K$  に対する依存性を示したものである ( $\alpha = 8.52$ )。この結果から、 $P_1$  は、Fig.4 でアトラクタ併合が生じた  $K$  付近でピークを持ち、更にそのピーク値は入力周波数  $f_s$  に依存する様子が確認できる。これは、カオス共鳴が  $P_1$  のピーク近傍で、

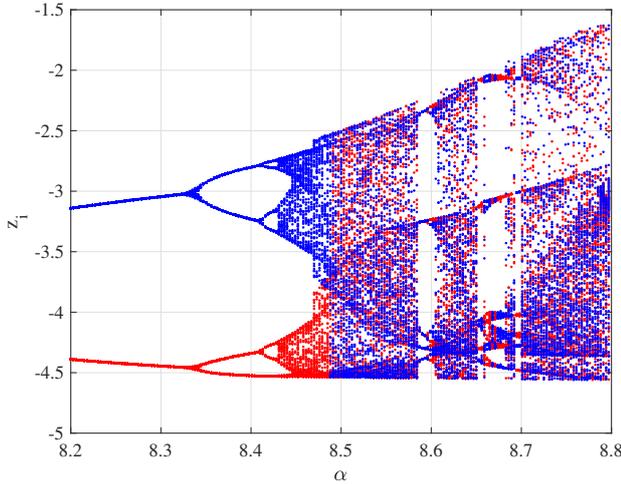


Fig. 2: Bifurcation diagram of  $z_i$  as function of internal parameter  $\alpha$ . Different initial values:  $(x(0), y(0), z(0)) = (-6.0489, 0.0839, 8.7739)$  (plotted with blue points) and  $(6.0489, -0.0839, -8.7739)$  (plotted with red points).

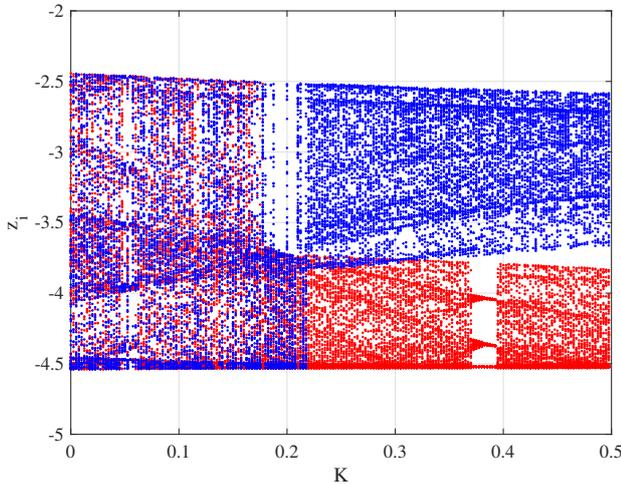


Fig. 3: Bifurcation diagram of  $z_i$  as function of strength of RRO feedback signal  $K$ . Different initial values:  $(x(0), y(0), z(0)) = (-6.0489, 0.0839, 8.7739)$  (plotted with blue points) and  $(6.0489, -0.0839, -8.7739)$  (plotted with red points).

RRO フィードバック信号により誘導できたことを表している。

#### 4 おわりに

本稿では、これまで離散カオスシステムのアトラクタ併合分岐の制御において提案された RRO 法を、Poincaré 断面上での写像構造に着目することで、連続カオスシステムへ拡張した。更に、この RRO 法によって、Chua 回路におけるアトラクタ併合分岐を制御し、CCI が外部の微弱入力信号と同期するカオス共鳴を誘起した。

まず、RRO 法によるアトラクタ併合分岐のメカニズムについて、考察を行う。CCI を示すアトラクタは 3 次の写像構造を持つことが知られている<sup>13, 14)</sup>。Chua 回路においても  $z_i$  の写像構造に同様の 3 次の構造を確認している。Chua 回路に RRO フィードバック法を適用

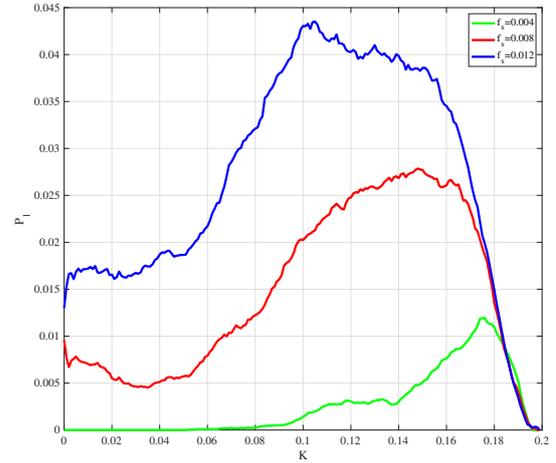


Fig. 4: Dependence of strength of distribution for CCI interval  $T_{cci}$  on RRO feedback signal  $K$ .

するにあたって、離散カオスシステムと同様に<sup>13, 14)</sup>、フィードバック関数  $u$  (5) 式) の極大・極小がそれぞれ  $z_i$  の極小・極大に対応するように設定している。更に、(6) 式で印加される  $Ku(z_i)$  は Poincaré 写像から Poincaré 写像の通過まで一定値をとる。この為、 $z_i$  は  $K(u(z_i))$  の符号に対応した方向でバイアスを受け  $z_{i+1}$  に反映される。この効果によって、 $z_i$  の写像構造における極大値と極小値が低下することで、アトラクタ併合条件<sup>13)</sup> が破れ、CCI を伴うアトラクタ併合が分離すると予想される。

次に、弱正弦波入力に対する信号応答性に関しては、本稿で提案した連続カオスシステムに拡張した RRO 法によって、Chua 回路における信号応答性がアトラクタ併合付近のフィードバック強度でピークを示し、その信号応答性が入力周波数依存性を持つことを確認した。このような信号応答特性は、内部パラメータ調整によって誘起されるカオス共鳴の性質と一致している<sup>10)</sup>。また、離散カオスシステムにおいて、RRO 法によって、誘導したカオス共鳴も同様に適度なフィードバック強度で信号応答性がピークを示したことから<sup>13, 15)</sup>、本稿で連続システムに拡張した RRO 法が、離散カオスシステムの場合と同様の効果を示すということが確認された。

更に、今後の研究課題について述べる。本稿で示した RRO 法では、アトラクタ分離効果を持つことが示されたが、今後、分離したアトラクタを併合させる効果を持つ RRO 法の設計があげられる。また、RRO フィードバック法の連続ニューラルシステムへの適用も重要な課題である。

結論として、本稿では RRO 法の連続カオスシステムへの拡張を行い、カオス共鳴の誘起に成功した。この拡張が、カオス共鳴のメカニズムを利用した信号応答性の増強デバイスの開発の一助となることが期待される。

#### 謝辞

本研究の一部は、JSPS 科研費 若手研究 (18K18124)(SN) と基盤研究 (C)(18K11450)(TY) の助成を受けている。

## 参考文献

- 1) R. Benzi, A. Sutera, and A. Vulpiani, "The mechanism of stochastic resonance," *Journal of Physics A: mathematical and general*, vol. 14, no. 11, p. L453, 1981.
- 2) S. Nobukawa and H. Nishimura, "Enhancement of spike-timing-dependent plasticity in spiking neural systems with noise," *International journal of neural systems*, vol. 26, no. 05, p. 1550040, 2016.
- 3) S. Nobukawa, R. Hashimoto, H. Nishimura, T. Yamanishi, and M. Chiba, "Noise-induced phenomena in the kaldor business cycle model," *Transactions of the Institute of Systems, Control and Information Engineers*, vol. 30, no. 12, pp. 459–466, 2017.
- 4) Y. Kurita, M. Shinohara, and J. Ueda, "Wearable sensorimotor enhancer for fingertip based on stochastic resonance effect," *IEEE Transactions on Human-Machine Systems*, vol. 43, no. 3, pp. 333–337, 2013.
- 5) L. R. Enders, P. Hur, M. J. Johnson, and N. J. Seo, "Remote vibrotactile noise improves light touch sensation in stroke survivors' fingertips via stochastic resonance," *Journal of neuroengineering and rehabilitation*, vol. 10, no. 1, p. 105, 2013.
- 6) N. J. Seo, M. L. Kosmopoulos, L. R. Enders, and P. Hur, "Effect of remote sensory noise on hand function post stroke," *Frontiers in human neuroscience*, vol. 8, p. 934, 2014.
- 7) Y. Kurita, Y. Sueda, T. Ishikawa, M. Hattori, H. Sawada, H. Egi, H. Ohdan, J. Ueda, and T. Tsuji, "Surgical grasping forceps with enhanced sensorimotor capability via the stochastic resonance effect," *IEEE/ASME Transactions on Mechatronics*, vol. 21, no. 6, pp. 2624–2634, 2016.
- 8) Y. Tadokoro, H. Tanaka, Y. Nakashima, T. Yamazato, and S. Arai, "Enhancing a bpsk receiver by employing a practical parallel network with stochastic resonance," *Nonlinear Theory and Its Applications, IEICE*, vol. 10, no. 1, pp. 106–114, 2019.
- 9) O. Van der Groen, M. F. Tang, N. Wenderoth, and J. B. Mattingley, "Stochastic resonance enhances the rate of evidence accumulation during combined brain stimulation and perceptual decision-making," *PLoS computational biology*, vol. 14, no. 7, p. e1006301, 2018.
- 10) V. S. Anishchenko, V. Astakhov, A. Neiman, T. Vadivasova, and L. Schimansky-Geier, *Nonlinear dynamics of chaotic and stochastic systems: tutorial and modern developments*. Springer Science & Business Media, 2007.
- 11) H. Nishimura, N. Katada, and K. Aihara, "Coherent response in a chaotic neural network," *Neural Processing Letters*, vol. 12, no. 1, pp. 49–58, 2000.
- 12) S. Nobukawa, H. Nishimura, and N. Katada, "Chaotic resonance by chaotic attractors merging in discrete cubic map and chaotic neural network," *IEICE Trans. A*, vol. 95, no. 4, pp. 357–366, 2012.
- 13) S. Nobukawa, H. Nishimura, T. Yamanishi, and H. Doho, "Controlling chaotic resonance in systems with chaos-chaos intermittency using external feedback," *IEICE Transactions on Fundamentals of Electronics, Communications and Computer Sciences*, vol. 101, no. 11, pp. 1900–1906, 2018.
- 14) —, "Induced synchronization of chaos-chaos intermittency maintaining asynchronous state of chaotic orbits by external feedback signals," *IEICE Transactions on Fundamentals of Electronics, Communications and Computer Sciences*, vol. 102, no. 3, pp. 524–531, 2019.
- 15) S. Nobukawa and N. Shibata, "Controlling chaotic resonance using external feedback signals in neural systems," *Scientific reports*, vol. 9, no. 1, p. 4990, 2019.
- 16) E. Ott, C. Grebogi, and J. A. Yorke, "Controlling chaos," *Physical review letters*, vol. 64, no. 11, p. 1196, 1990.
- 17) K. Pyragas, "Continuous control of chaos by self-controlling feedback," *Physics letters A*, vol. 170, no. 6, pp. 421–428, 1992.
- 18) H. Nakajima, "On analytical properties of delayed feedback control of chaos," *Physics Letters A*, vol. 232, no. 3-4, pp. 207–210, 1997.
- 19) W. Jiang, Q. Guo-Dong, and D. Bin, " $H^\infty$  variable universe adaptive fuzzy control for chaotic system," *Chaos, Solitons & Fractals*, vol. 24, no. 4, pp. 1075–1086, 2005.
- 20) L. O. Chua, *Introduction to nonlinear network theory*. McGraw-Hill, 1969.
- 21) G. Leonov, N. Kuznetsov, and V. Vagaitsev, "Localization of hidden chua's attractors," *Physics Letters A*, vol. 375, no. 23, pp. 2230–2233, 2011.
- 22) A. C. Hindmarsh, P. N. Brown, K. E. Grant, S. L. Lee, R. Serban, D. E. Shumaker, and C. S. Woodward, "Sundials: Suite of nonlinear and differential/algebraic equation solvers," *ACM Transactions on Mathematical Software (TOMS)*, vol. 31, no. 3, pp. 363–396, 2005.
- 23) Q. Li, H. Zeng, and X.-S. Yang, "On hidden twin attractors and bifurcation in the chua's circuit," *Nonlinear Dynamics*, vol. 77, no. 1-2, pp. 255–266, 2014.
- 24) S. Sinha and B. K. Chakrabarti, "Deterministic stochastic resonance in a piecewise linear chaotic map," *Physical Review E*, vol. 58, no. 6, pp. 8009–8012, 1998.

# 自律走行ロボットによる照度計測の自動化

○荒川俊哉 新井智之 井上椋太 久保田直行 (首都大学東京)  
戸田雄一郎 (岡山大学) 辻元誠 谷口和彦 (株式会社きんでん)

## Automation of illuminance measurement by the autonomous mobile robot

\* T. Arakawa, T. Arai, R. Inoue, N. Kubota (Tokyo Metropolitan University)

Y. Toda (Okayama University) M. Tsujimoto, K. Taniguchi (Kinden Corporation)

**Abstract**— In recent years, the research has been conducted on the robots which automatically measure the illuminance at indoor construction sites due to the declining birthrate and aging population which cause the labor shortage. Therefore, for the purpose of efficiency improvement of illuminance measurement work, we developed an illuminance measurement robot that measures illuminance at a target point while performing environmental map building and self-localization. From the experimental results of actually measuring the illuminance, it was confirmed that the developed robot can carry out the task sufficiently, and it is expected to be able to be fully active in the actual site.

**Key Words:** illuminance measurement, SLAM, LRF, fuzzy control, multi-objective coordination

## 1 はじめに

近年、少子高齢化の問題に伴い、労働力不足が深刻な問題となっている。建設現場においても、労働者不足問題は一刻も早く対応すべき課題であり、その影響を受ける作業として照度計測がある。この作業は通常、外界からの光の影響を受けづらい夜間に行う必要があり、計測と記録に計2名を要している。さらに測定箇所は多く、測定後もデータを整理したりする必要があり、負担の大きい業務である。そこで本研究では、建設現場における照度測定作業を、ロボット技術を用いた自動化によって効率化することを研究目的とする。これまで、本研究では自動化に向けて実験を行っており、有効性を示してきた[1]。現在、照度計測に必要な自己位置推定、照度測定点への移動、障害物回避等の実用的な機能を追加し、商品化の最終段階にある。本稿では開発したロボットを用いて、実際の使用環境を想定した照度計測の実験を行い、商品化する上での有効性について議論する。

## 2 照度測定ロボットのシステム構成

本研究において、商品化を前提として照度測定ロボットの開発を行った。Fig.1に外観図を示す。基本的な照度計測において、一般照明の照度は、床面から800mmの高さで測定することがJIS規格で決められているため、照度計を図のように棒の先に取り付けた。また、床面から150mmの高さでも計測できるようにロボットの後部に照度計を取り付けられるように設計した。また、センサとして、Laser Range Finder (LRF)、バンパセンサ、落下防止センサをロボットに搭載している。基本的にLRFによって得られる距離データをもとに自己位置推定や障害物検知を行い、ロボットを制御する。LRFでは検出できない低い障害物の検知にバンパセンサを、階段などの段差の検知に落下防止センサを使用する。LRFには北陽電機株式会社から発売されている測域センサであるUTM-30LX[2]を、照度計にはコニカミノルタ株式会社から発売されているT10[3]を使用した。

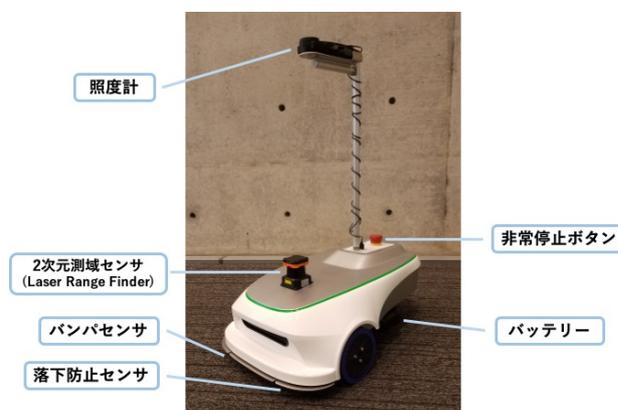


Fig. 1 External view

## 3 照度計測ロボットの智能化制御

### 3.1 環境地図構築と自己位置推定

照度計測ロボットが与えられた測定点に移動するためには、環境地図の構築と自己位置推定をする必要がある。本研究では、地図表現方法として、占有格子空間地図を用いる。占有格子空間地図は、2次元空間を格子として表現し、計測情報に応じて各格子の占有度を更新していく地図の表現手法である。得られたセンサデータから、地図内で対応するセルに対して占有度の更新を行うのだが、対象となるセルには占有度を上げ、センサが透過したセルは占有度を下げる。以下にセルの占有度の更新式を示す。

$$map_t(x, y) = \frac{hit_t(x, y)}{hit_t(x, y) + err_t(x, y)} \quad (1)$$

ここで  $hit_t(x, y)$  と  $err_t(x, y)$  はそれぞれ、時刻  $t$  までに格子  $(x, y)$  において、測域センサによって計測された回数と測域センサの信号が透過した回数である。

また、ロボットの自己位置推定には進化戦略に基づく手法を用いた。具体的な進化戦略の手法としては、

$\mu$ 個の子個体を生成し、山登り的に探索を行なっていく( $\mu+1$ )-ESを用いる。

( $\mu+1$ )-ESは、常に親個体を $\mu$ 個体保持するため解集合の多様性が保たれた状態において、近傍探索が可能な手法であり、より精度の高い自己位置推定が可能となるため本研究において採用した。自己位置推定の最適化における、進化戦略では、各個体を現時点におけるロボットの自己位置( $g_{k,1}, g_{k,2}$ )と姿勢( $g_{k,3}$ )として表現し、各遺伝子に対して、遺伝的操作を行なっていくことによって、探索を行なっていく。遺伝的操作の1つである、交叉には、最良個体とランダムに選択された個体から交叉を行なうエリート交叉を用いる。また、突然変異には以下の式によって計算される適応的突然変異を用いる。

$$g_{k,h} \rightarrow g_{k,h} + \left( \alpha_h \cdot \frac{fit_{max} - fit_k}{fit_{max} - fit_{min}} + \beta_h \right) \cdot N(0,1) \quad (2)$$

ここで、 $fit$ は、 $k$ 番目の個体の適応度を表し、 $fit_{max}$ と $fit_{min}$ は、それぞれ、個体群中の最大、最小の適応度を表す。また、 $N(0,1)$ は、平均0、分散1の正規乱数を $\alpha h$ と $\beta h$ は、それぞれ、係数とオフセットを表す。このように突然変異では、 $\alpha h$ の値によって、探索範囲を設計することが可能であり、遠隔モニタリングに使用する移動ロボットの最大移動速度に応じて、適切な係数を設計することによって、ロボットにおける自己位置推定のための探索を行なうことが可能である。また、 $k$ 番目の適応度 $fit_k$ は以下の式によって計算される。

$$fit_k = p_t^{occ}(x_{i,L}, y_{i,L}) \cdot \sum_{i=1}^M map_t(x_{i,L}, y_{i,L}) \quad (3)$$

$$p_t^{occ}(x_{i,L}, y_{i,L}) = \frac{\sum_{i=1}^M hit'_t(x_{i,L}, y_{i,L})}{\sum_{i=1}^M hit'_t(x_{i,L}, y_{i,L}) + \sum_{i=1}^M err'_t(x_{i,L}, y_{i,L})} \quad (4)$$

$$hit'_t(x_{i,L}, y_{i,L}) = \begin{cases} 1 & \text{if } hit_t(x_{i,L}, y_{i,L}) > 0 \\ 0 & \text{else if } err_t(x_{i,L}, y_{i,L}) > 0 \end{cases} \quad (5)$$

$$err'_t(x_{i,L}, y_{i,L}) = \begin{cases} 1 & \text{if } err_t(x_{i,L}, y_{i,L}) > 0 \\ 0 & \text{else if } hit_t(x_{i,L}, y_{i,L}) > 0 \end{cases} \quad (6)$$

式(4)より、自己位置推定解の探索において、適応度は、基本的に地図の占有度の総和によって決定される。適応度が高くなるほど、測域センサのよって計測された格子の座標と現時点までに構築された地図情報の一致度合いが高くなるため、より精確に自己位置を推定できることが期待される。そのため、本問題は最大化問題として帰着される。

### 3.2 照度測定点への移動と障害物回避

各行動における各モータへの出力の計算には簡易型ファジィ推論を用いる。ファジィ if-then ルールは以下のようなになる。

**IF**  $x_{k,1}$  is  $A_{k,i,1}$  and ... and  $x_{k,M}$  is  $A_{k,i,M}$

**THEN**  $y_{k,1}$  is  $w_{k,i,1}$  and ... and  $y_{k,N}$  is  $w_{k,i,N}$

ここで、 $k$ は行動番号を表し、 $k=1$ は障害物回避、

$k=2$ は目標追従を表す。 $M$ は各行動における入力数であり、障害物回避ではLRFからの計測データを一定角度ごとに5分割して用いるため $M=5$ 、目標追従、最適目標位置追従では距離が前方、ゼロ、後方の3種と角度のずれが左右2方向にあるため積をとって $M=6$ となる。 $N$ はロボットの出力数であり、両輪の出力であるので $N=2$ となる。

適合度の計算には以下の式で表されるガウス型メンバシップ関数を用いる。

$$\mu_{A_{k,i,j}}(x_{i,j}) = \exp\left(-\frac{(x_{i,j} - a_{i,j})^2}{b_{i,j}^2}\right) \quad (7)$$

$a_{i,j}, b_{i,j}$ はメンバシップ関数の中央値と幅を表す。

メンバシップ関数により各入力に対する適応度を求め掛け合わせることで各ルールの発火度を計算する。

$$\mu_{k,i} = \prod_{j=1}^M \mu_{A_{k,i,j}}(x_{k,j}) \quad (8)$$

各ルールの設定出力値に対し、発火度を重みとした重み付け平均を取ることで、行動 $k$ における両輪の出力 $y_{k,l}$  ( $l=1,2$ )を得る。 $R$ はルール数である。

$$y_{k,l} = \frac{\sum_{i=1}^R \mu_{k,i} w_{k,i,l}}{\sum_{i=1}^R \mu_{k,i}} \quad (9)$$

### 3.3 多目的行動調停

上記で述べた通り、照度計測ロボットは目標追従や障害物回避を行う必要があり、その時々でどの行動を優先するかを決定する。多目的行動調停では、各行動(行動1:障害物回避、行動2:目標追従)の出力 $y_{k,l}$ を行動 $k$ の重み $wgt_k$ をセンサ値によって更新し、各出力の重み付け和を取ることで環境に適した最終出力 $y_l$ を算出する。 $K$ はタスク行動の総数であり、本研究においては $K=2$ である。

$$y_l = \frac{\sum_{k=1}^K wgt_k \cdot y_{k,l}}{\sum_{k=1}^K wgt_k} \quad (10)$$

$y_{k,l}$ は $k$ 番目の行動出力における両輪 ( $l=1,2$ )の出力を表す。また、重みの更新則は次のように行われる。ここで $\alpha$ は忘却係数であり、センサ情報が初期値と同値になった場合に、累積の重み更新幅が0に戻ってしまうことを防ぐ目的がある。

$$wgt'_k = \alpha \cdot wgt_k + \Delta wgt_k \quad (11)$$

$$wgt_k \leftarrow \frac{wgt'_k}{\sum_{k=1}^K wgt'_k} \quad (12)$$

障害物回避、目標追従、最適目標位置追従をそれぞれ、行動1、行動2とし、式(4.6)における各タスク行動の重み更新則 $\Delta wgt_k$  ( $k=1,2$ )を設定する。

$$\begin{bmatrix} \Delta wgt_1 \\ \Delta wgt_2 \end{bmatrix} = \begin{bmatrix} dw_{1,1} & dw_{1,2} \\ dw_{2,1} & dw_{2,2} \end{bmatrix} \begin{bmatrix} si_1 \\ si_2 \end{bmatrix} \quad (13)$$

$si_m$  ( $m=1,2$ )は環境知覚情報を表し、それぞれLRFから求めた障害物の接近度や、目標までの相対角度。最適目標位置までの距離である。 $dw_{k,m}$ は行動 $k$ が $si_m$

によって受ける影響を定める定数パラメータである。 $\Delta w_{gtk}$ ,  $dw_{k,m}$ ,  $sim$ の値は正規化され、0~1の範囲の値を取る。 $sim$ が高い値となったときに $\Delta w_{gtk}$ が大きき値を取るよう $dw_{k,m}$ の値を決めることで知覚された状況に適した統合出力を得ることができる。

### 3.4 その他の行動設計

障害物回避には、基本的に LRF の計測データとファジィ制御を用いて行なっていくが、LRF の取り付け位置よりも低い位置にある障害物など、LRF の計測範囲内に存在しない障害物については回避を行うことができない。そこで、ロボットに搭載するバンパセンサの接触によって障害物を検知する。バンパセンサによって検知した場合、障害物の大きさが未知であるため、多目的行動調停にバンパセンサを用いた障害物回避を組み込むことは効率の悪いことが予想される。したがって、多目的行動調停よりも優先してバンパセンサによる障害物回避を行う。具体的には、左のバンパセンサに衝突した場合には、左後方へ後退し、右または中央のバンパセンサに衝突した場合には、右後方へ後退することによって障害物回避を行なっていく。

また、測定点上に障害物が存在するために、測定点へ到達できず、照度が計測できない場合が想定される。この場合、目標となる測定点への到達に対してある制限時間を設け、制限時間を越えた時点で、現在位置の照度を計測し、次の測定点へ目標を変更することによって対応を行なっていく。

## 4 実験結果

実際の照度計測を想定して、屋内フロアにて実験を行なう。本実験環境において、設定した計測地点及び環境地図構築を行なった結果を Fig.3 に示す。また、実際にロボットが移動した軌跡を Fig.4 に示す。図中の赤い円は照度の測定点を示す。環境地図構築開始時点 (Fig.3 左図) では、LRF の計測データと CAD 図から生成された環境地図がほぼ一致していることがわかる。その後、ロボットは環境地図の更新を行いながら、照度計測のための移動を開始し、各計測地点を通過しながら計測終了地点まで移動をしている (Fig.3 右図)。Fig.4 より、ロボットは、本研究において用いているファジィ制御による目標位置追従によりオーバーシュートは生じているものの各計測地点を適切に通過できていることが確認できる。この際における、各計測地点と照度計測時の測定点の座標値及び照度値を Table 1 に示す。Table 1 より、設定した計測地点と実際に測定した地点の誤差の平均値は、約 194 [mm]、最大値は 204 [mm]となっていることから、本研究において開発を行なった照度測定ロボットは、照度測定作業への利用としては十分な精度の位置決め制御を行えると評価できる。

次に、同様の環境において、測定点に障害物が存在する場合の照度測定用ロボットの走行に関する実験を行なっていく。実験環境は、最初の測定点を障害物に囲われている位置に設定し、ロボットが測定点にて照度を測定できない環境とした。走行実験の結果を Fig.5、Fig.5 に示す。Fig.5(a)において、LRF による障害物の検知はできているものの障害物の後ろに測定点が存在するため、ロボットは可能なかぎり障害物に近接していき、障害物の直前で正面からの侵入が不可能であると判断し、側面へ移動している。側面方向からも同様に障害物に近づくに連れて多目的行動調停における障害物回避に対する行動の重みが大きくなっていき、旋回による回避を行っている (Fig.5(b))。この過程を繰り返して、測定点の周囲を一定距離を保って旋回する行動をとっている。一周した時点で、設定された制限時間を越えたため、測定不能な測定点と判断し、現在位置での照度を計測し、測定を終了している (Fig.5(c))。このように、本ロボットは想定と異なり、測定点へ到達できない場合においても、適切に測定点をスキップし、次の測定点へと移動可能な手法であると考えられる。

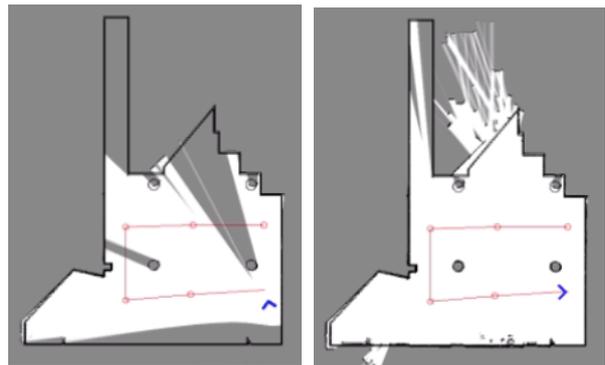


Fig.3 Results of map building

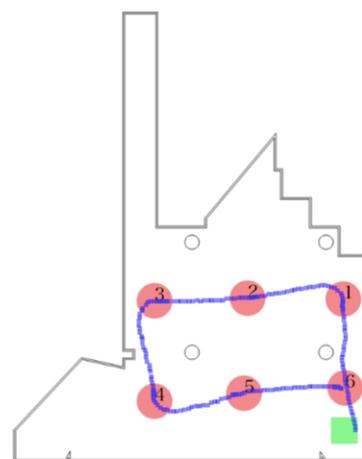


Fig.4 Movement trajectory (1)

**Table 1 Results of illuminance measurement**

測定点	設定座標(m)		測定座標(m)		測定点誤差(m)	照度値(lx)
	x	y	x	y		
1	39.641	38.900	39.592	39.048	0.156	541
2	34.105	38.900	34.303	38.850	0.204	688
3	28.866	39.048	29.063	39.048	0.198	231.1
4	28.866	44.782	28.866	44.584	0.198	137.4
5	33.907	44.337	33.710	44.386	0.204	474
6	39.690	43.991	39.493	44.040	0.204	447



(a)



(b)

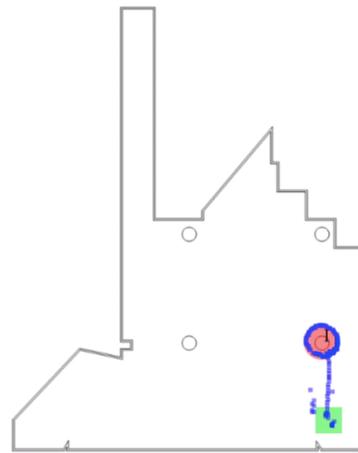


(c)



(d)

**Fig.5 Obstacle avoidance**



**Fig.6 Movement trajectory (2)**

## 5 おわりに

本研究では、照明の照度測定を自動化する照度測定ロボットの開発を行なった。実際に屋内環境において照度測定の実験を行い、開発したロボットは十分な精度で各計測地点を辿り、障害物を回避する性能を有していることを示した。今後、実際の施工現場での検証を行うことによって、さらに改善を行なっていく予定である。

## 参考文献

- 1) 戸田 雄一郎, WeiHong Chin, 新井 智之, 辻元 誠, 谷口 和彦, 久保田 直行, ”照度測定の自動化に向けた自律移動ロボットの知能化技術”, 日本保全学会 第15回学術講演会, pp.157-160,福岡国際会議場, 2018.
- 2) HOKUYO, <http://www.hokuyo-aut.co.jp/>
- 3) コニカミノルタ株式会社 T10, [https://www.konicaminolta.jp/instruments/support/discontinued\\_products/t10/index.html](https://www.konicaminolta.jp/instruments/support/discontinued_products/t10/index.html)

# 局地的大雨の危険性提示方法提案のための 脳波解析・雨音特徴量抽出

○佐藤慧一 満倉靖恵 (慶應義塾大学)

中島広子 (国立研究開発法人防災科学技術研究所) 島崎敢 (名古屋大学)

## EEG Analysis and Rain Sound Feature Extraction for Notification of Localized Torrential Rain Risk

\* Keiichi Sato, Yasue Mitsukura, (Keio University)

Hiroko Nakajima (National Research Institute for Earth Science and Disaster Resilience)  
and Kan Shimazaki (Nagoya University)

**Abstract**—In this research, the final purpose is to propose a sound notification to effectively convey the risk of localized torrential rain. In this paper, we evaluate stress of localized torrential rain by EEG analysis and extract frequency feature of rain sound. For EEG analysis, it was confirmed that there was no linear relationship between stress value and precipitation. For the questionnaire, it was confirmed that the mood condition worsened as the amount of precipitation increased. For rain sound analysis, it was suggested that the correlation between power spectrum of rain sound and stress value could be used as frequency feature. From this result, it is suggested that using these features will lead to sound creation according to the degree of danger.

**Key Words:** EEG, FFT, Signal feature extraction

### 1 はじめに

本研究は、局所的大雨の危険性を効果的に伝えるための音提示方法の提案を最終目的とする。本稿では、前段階として脳波解析による局所的大雨のストレス評価および雨音の周波数特徴量抽出を試みる。局地的・短時間の強い雨を指す局所的大雨は近年増加しており、河川の氾濫や土砂災害、心的外傷ストレス障害(PTSD: Post Traumatic Stress Disorder)などを引き起こす危険性がある<sup>1)</sup>。この対策として予測の精度・速度向上や各個人への正確な情報伝達が挙げられる。情報伝達に着目すると、Table 1に示すように雨の強さの表し方として雨量に対応した「やや強い雨」「激しい雨」などの予報用語が定められている<sup>2)</sup>。しかしながら、これらと実際の雨の強さは独立であるため、その強さは想像であり、個人によっても解釈が異なっている。局所的大雨の強さを効果的に万人に伝える方法が必要であり、各個人の適切な避難行動の実施のために役立つことが予想できる。本研究では、雨音の周波数特性と生体信号である脳波の関連性に着目し、危険性提示方法を提案する。生体信号データベースに基づいて脳波からストレス値を算出する感性アナライザを用いて、局所的大雨の降雨量の違いによるストレス変化を評価する<sup>3)</sup>。また、雨音の周波数解析により降雨量ごとの周波数特性の違いとストレス変化を関連付ける。これらの関連付けにより、降雨量に応じた危険度合いを伝えるのに効果的な周波数特性を特定し、その特徴を用いた音による危険性提示方法を提案する。

### 2 実験

実験は大型降雨施設実験と雨音聴取実験の2種類存在する。大型降雨施設実験は、濡れなど、実環境に近い条件での実験が可能であるが、大きなコストと時間がかかるためデータ数の増加が困難である事や、アンケートの実施が困難であるといった欠点が存在する。

そのため、雨音以外の影響の考慮が不可能であるがデータ数が増加しやすくアンケートの実施ができる雨音聴取実験を実施した。Table 2にそれぞれの実験の利点・欠点を示す。いずれの実験でも、脳波計は単極脳波計MindWave Mobile (BMD ver., NeuroSky社)を用いた<sup>4)</sup>。計測部位はFig. 1に示す国際10-20法に基づいたFp1(左前頭前野)箇所とした<sup>5)</sup>。感性アナライザ (Dentsu ScienceJam Inc.)を用いることで、脳波データからストレス値が取得可能である。以下ではそれぞれの実験について説明する。

#### 2.1 大型降雨施設実験

大型降雨施設実験では、自然界に近い局所的大雨を再現する防災科学技術研究所の大型降雨実験施設にお

Table 1: Precipitation and its image

雨量 [mm/h]	予報用語	人の受けるイメージ
10~20	やや強い雨	ザーザーと降る
20~30	強い雨	どしゃ降り
30~50	激しい雨	バケツをひっくり返したように降る
50~80	非常に激しい雨	滝のように降る
80~	猛烈な雨	息苦しくなるような 圧迫感・恐怖感

Table 2: Experiments

	大型降雨施設実験	雨音聴取実験
環境要因	実環境に近い条件	雨音のみ
データ数	増加が困難	増加が容易
降雨量の順番	一定	ランダム化が可能
アンケート	実施が困難	実施が容易

いて、降雨下で傘を差した被験者3名の脳波計測と雨音録音を行った<sup>6)</sup>。降雨量は0, 30, 60, 100, 180, 300mm/hの6段階に設定し、順番は昇順、計測は各降雨量において1分間とした。実験施設は野外にあり、実験は施設を締め切らずに実施するため、施設内の気温は外気温に依存する。被験者は予めヘルメット・レインコート・長靴・脳波計を装着し、傘と録音用のマイクを持って雨の中に立った。初めに降雨量0mm/hと設定し、1分間の脳波測定と録音を行った。この1分間の間、被験者は大きく動くことなく、また声を発することなく、環境音を録音した。測定および録音の終了後に降雨量を30mm/hに設定し、同様に脳波測定および録音を行った。これを繰り返し、降雨量を段階的に増加させ、降雨量300mm/hでの脳波測定および録音が終了後に脳波計を取り外し、実験の終了とした。録音について、サンプリング周波数は16kHzとした。

## 2.2 雨音聴取実験

雨音聴取実験では、大型降雨施設実験で録音した30~300mm/hの5段階の雨音を用いて、被験者16名の音聴取時の脳波計測を行った。大型降雨施設実験の実験施設での実験では降雨量を段階的に増加させるため順番が一定であり、降雨量の順番による脳波への影響が考えられる。そのため雨音聴取実験では、実験施設で録音した各降雨量の雨音をランダムに提示し、各降雨量の雨音聴取時の脳波計測を行った。被験者は椅子に着席し、脳波計とイヤホンを装着した。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。眼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。雨音はイヤホンで聴取し、あらかじめ定めた一定音量で再生した。脳波計を装着した後に脳波計測を開始し、1種類の雨音の再生時間を1分とし、雨音聴取とアンケートを交互に実施した。5種類の雨音聴取の終了後に脳波計測を終了とした。雨音聴取実験の流れをFig. 2に示す。

## 3 解析および結果

### 3.1 脳波

感性アナライザを用いて、各実験で得た脳波データからストレス値を取得した。しかしながら被験者のストレス平均値に大きな差異が確認されたため、大型降雨施設実験では0mm/h時、雨音聴取実験では30mm/h時の平均ストレス値をベースラインとし各降雨量の平均ストレス値との比である変化率を求めることで個人差の影響を考慮した。

算出したストレス値変化率について、聴取した雨音の降雨量間の有意差を検定した。有意差検定は次の手順で行った。初めに、データの正規性を確認するためにリーフォース検定を行った。その結果、正規性の確認されないデータが存在したため、ノンパラメトリック検定であるウィルコクソンの符号順位検定を採用した。この検定は2つのデータ間に対応がある場合、中央値に差があるかどうかを検定する手法である。

大型降雨施設実験における各降雨量での平均ストレス値変化率の例をFig. 3に、雨音聴取実験における各降

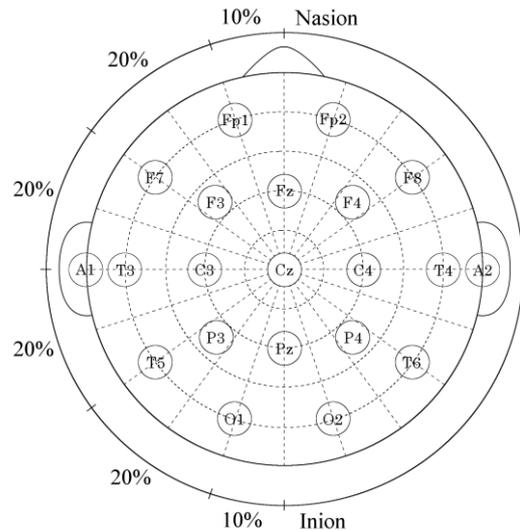


Fig. 1: International 10-20 system<sup>5)</sup>

Questionnaire ①	Rain sound listening ①	Questionnaire ②	Rain sound listening ②	...
	60 s		60 s	
...		Questionnaire ⑤	Rain sound listening ⑤	Questionnaire ⑥
			60 s	

Fig. 2: The flow of rain sound listening experiment

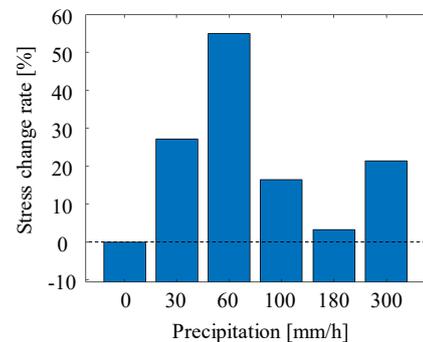


Fig. 3: Example of stress change rate for each precipitation in large-scale rain simulator experiment

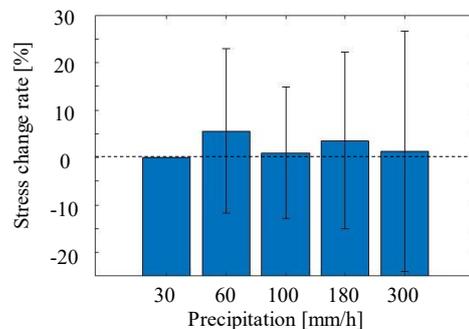


Fig. 4: Stress change rate for each precipitation in rain sound listening experiment (\*:  $p < 0.05$ )

雨量での平均ストレス値変化率をFig. 4に示す. 降雨量とストレス変化率との間には線形的な関係は確認されなかった.

### 3.2 アンケート

本研究ではアンケートとして日本語版POMS (Profile of Mood State) 短縮版を用いた<sup>7)</sup>. POM短縮版では気分の尺度として、「緊張 - 不安 (Tension - Anxiety)」「抑うつ - 落込み (Depression-Dejection)」「怒り - 敵意 (Anger-Hostility)」「活気 (Vigor)」「疲労 (Fatigue)」「混乱 (Confusion)」の6項目が設けられている. 30項目の質問に5段階で回答することで, これら6項目の尺度のT得点(標準化点数(T-score))が算出される. 各尺度の雨音聴取前後のアンケートのT得点差を算出し, 各雨音聴取による変化として対応付けた. 例えば, Fig. 2の雨音聴取①による変化は, アンケート②のT得点からアンケート①のT得点を引いた点数となる. 算出した各尺度のT点数について, 脳波解析と同様に, 聴取した雨音の降雨量間の有意差を検定した.

各降雨量でのT得点をFig. 5に示す. 6尺度のうち,

「緊張 - 不安」「抑うつ - 落込み」「疲労」「混乱」では降雨量が増加するほどT得点が高くなる傾向, 「活気」ではT得点が高くなる傾向が確認された.

### 3.3 雨音

取得した雨音信号はサンプリング周波数16kHzであった. 初めに, 前処理として外れ値補正および正規化を行った. 外れ値補正は中央値絶対偏差(MAD: Median Absolute Deviation)を用いた. MADの4倍を超えて中央値から離れている値を外れ値と検出し, 最も近い非外れ値で置き換えた. その後, 最小値0, 最大値1に正規化した. 次に, FFT(Fast Fourier Transform)を行うことで帯域幅10Hz毎のパワースペクトルを算出した. 8000Hzまでのパワースペクトルが算出されるため, データ数は各降雨量に対し800データ存在する. 最後に, 相関分析を行うことで, ストレス値の変化量とパワースペクトルの相関係数が有意に大きい周波数帯を抽出した. 有意確率が0.05未満となった周波数帯は8つであった. それぞれの周波数帯の相関係数と有意確率をTable 3に示す.

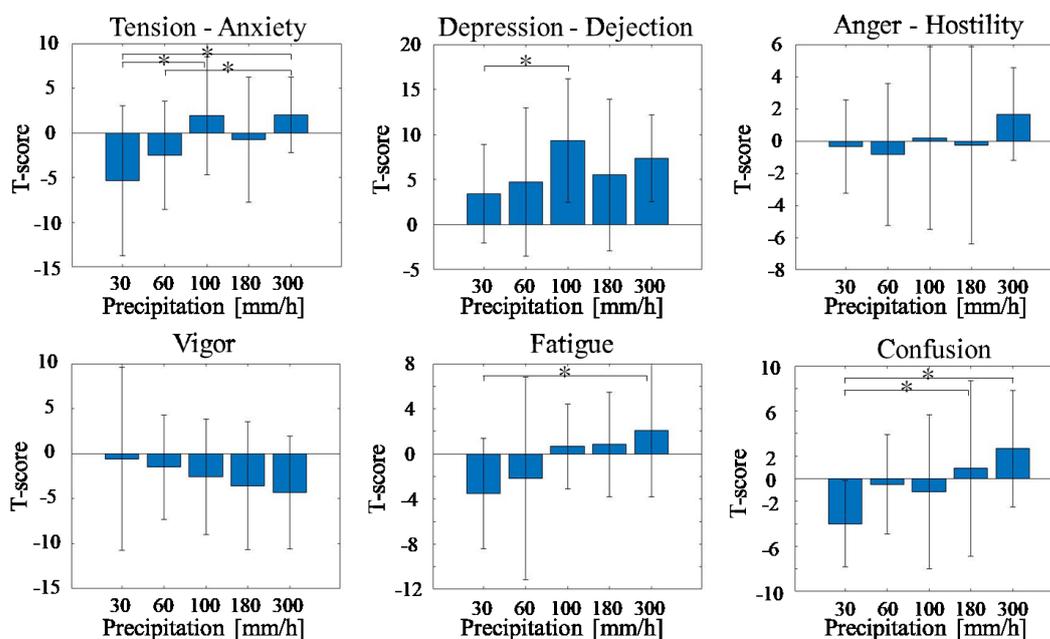


Fig. 5: T-score for each precipitation (\*:  $p < 0.05$ )

Table 3: Frequency band with significance probability less than 0.05

Frequency band [Hz]	Correlation coefficient	Significance probability
951-960	0.961	0.0094
1001-1010	0.902	0.036
1051-1060	0.918	0.028
1541-1550	0.904	0.036
1561-1570	0.927	0.024
1611-1620	0.955	0.011
2051-2060	0.938	0.018
2091-2100	0.917	0.029

## 4 考察

Fig.3, 4より, 降雨量の増加に伴って脳波解析によるストレス値が増加すると仮説を立てて実験を行ったが, ストレス値と降雨量との間には線形的な関係は確認されなかった. しかしながら, Fig. 5に示すアンケート結果では, 降雨量が増加するほど気分状態が悪化する傾向が確認された. この結果から, 脳波解析によるストレス値とアンケートによる気分状態は異なるものを示すと考えられる. そのため, 今回はストレス値の変化率と雨音のパワースペクトルの相関を用いたが, 脳波によるストレス値とアンケート, それぞれのパワースペクトルとの相関が利用できることを示唆している. また, Table 3に示す8つの周波数帯を特徴量として用いることで, ストレス値の変化に効果的な音の設計が可能であることを示唆している. この周波数帯のパワーが大きい音は, ストレスを感じやすいと考えられる.

## 5 おわりに

本研究では, 局所的大雨の危険性を効果的に伝えるための音提示方法の提案を最終目的としている. 本稿では, その前段階として脳波解析による局地的大雨のストレス評価および雨音の周波数特徴量抽出を試みた. 脳波解析では, ストレス値と降雨量との間には線形的な関係は確認されなかった. アンケートでは, 降雨量が増加するほど気分状態が悪化する傾向が確認された. 雨音解析では周波数特徴量としてパワースペクトルとストレス値の変化率の相関が利用できることを示唆した.

ストレス値について, 今後は周波数特徴量の他に時系列解析手法の検討を行う必要があると考えている. 時系列で特徴を掴むことで, 情報提示に用いる音の長さや細かい周波数の設計に繋がる. また, 今回はストレス値の個人差を考慮するため, 基準となる0mm/h時のストレス値を用いたが, 今後は安静時のストレス値を用いるなどの工夫が必要である. 雨音について, 今回はパワースペクトルを特徴量として用いたが, 今後は音量など他の特徴量を併用しようと考えている. そして最終目的を達成するため, 脳波および雨音の特徴を関連付け, 危険度合いに応じた音作成および提示実験を実施する.

## 参考文献

- 1) 気象庁: 大雨や猛暑日など(極端現象)のこれまでの変化, <[https://www.data.jma.go.jp/cpdinfo/extreme/extreme\\_p.html](https://www.data.jma.go.jp/cpdinfo/extreme/extreme_p.html)> (2019.6.5)
- 2) 気象庁: 予報用語 雨の強さと降り方, <[http://www.jma.go.jp/jma/kishou/known/yougo\\_hp/amehyo.html](http://www.jma.go.jp/jma/kishou/known/yougo_hp/amehyo.html)> (2019.6.5)
- 3) 株式会社電通サイエンスジャム: 感性アナライザ, <<https://kansei-analyzer.com/>> (2019.6.5)
- 4) NeuroSky, Inc.: MindWave, <<https://store.neurosky.com/pages/mindwave>>, (2019.6.5)
- 5) 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.
- 6) 国立研究開発法人 防災科学技術研究所: 大型降雨実験施設, <<http://www.bosai.go.jp/shisetsu/rain/>> (2019.6.5)
- 7) 横山和仁: POMS 短縮版 手引きと事例解説, 金子書房, 2005.

# オリーブオイルのストレス緩和効果 および嗜好性と月経周期の関連性評価

○奈良莉紗 満倉靖恵 浜田望 (慶應義塾大学)

## Evaluating Stress Relief Effect of Olive Oil and Correlation between Palatability and Menstrual Cycle

\* Risa Nara, Yasue Mitsukura and Nozomu Hamada (Keio University)

**Abstract**— In this paper, we aimed to evaluate stress relief effect of olive oil and correlation between palatability and menstrual cycle. Female hormone balance causes changes in the menstrual cycle and stress resistance. In recent years, it is known that fluctuation of this balance may cause symptoms including premenstrual syndrome (PMS). We focused on menstrual cycle to perceive the hormone balance, and attempted to evaluate therapeutic properties of olive oil. Then, we defined the therapeutic properties as stress relief effect. In order to evaluate the effect of olive oil, considering palatability is necessary. This is because palatability plays an important role in selecting components to be taken into body, but differences in the components may have an effect on stress relief. In this research, we acquired stress information from electroencephalogram (EEG). Subsequently, we used questionnaire to evaluate palatability. As a result, it was confirmed that stress tended to decrease when smelling olive oil. Furthermore, the questionnaire results suggested that palatability changed with menstrual cycle.

**Key Words:** EEG, Menstrual cycle, Olive oil

### 1 はじめに

本稿は、脳波を用いてオリーブオイルのストレス緩和効果および同オイルに対する嗜好性と月経周期の関連性を評価することを目的とする。

月経周期とは、月経期、卵胞期、排卵期、黄体期の4期から構成される女性特有のバイオリズムである。月経開始から約4日間を月経期、月経期後の約7日間を卵胞期、卵胞期後の約5日間を排卵期、排卵期後の約14日間を黄体期と呼ぶ。この周期には、卵胞ホルモンであるエストラジオールや黄体ホルモンであるプロゲステロン等の女性ホルモンバランスが深く関連しており、分泌量から月経周期を判断することが可能である(Fig. 1 参照)[1]。ホルモンバランスの変動は、嗜好性の変化やストレス等身体に様々な影響を及ぼすことが明らかになっており、深刻な問題を引き起こす場合もある。中でも、ストレスの影響を受けやすい月経前症候群(Pre Menstrual Syndrome: PMS)は黄体期において情緒不安定や不眠等のうつ病に似た症状を呈し、潜在患者数は18万人に上ることが報告されている[2]。

ホルモンバランスの変動により生じるストレスやPMS等の不調を緩和するために、不飽和脂肪酸の摂取やアロマセラピーの利用が好ましいとされている[3-4]。オリーブオイルは主成分として不飽和脂肪酸を多く含み、さらにアロマオイルと同様の香り成分、Hexanal(C<sub>6</sub>H<sub>12</sub>O)や2-(E)-Hexenal(C<sub>6</sub>H<sub>10</sub>O)を含むことから不調緩和のために注目されている。しかしながら、オリーブオイルの不調緩和効果を定量的評価が可能な指標を用いて検証した文献は未だ存在しない。これに対し本研究では、不調緩和をストレス緩和と定義した上で脳波を用いて評価する。また、この効果を評価する上でホルモンバランスの変動による嗜好性の変化を考慮することも重要である。この理由として、嗜好性は体内に取り入れる成分を選択する段階において大き

な役割を果たすが、選択する成分の違いが不調緩和に影響を及ぼす可能性が考えられることがある。しかしながら、オリーブオイルにおける嗜好性変化の有無は確認されていない。以上より本研究では、脳波から取得したストレス情報を指標としてオリーブオイルがもたらす不調緩和に関する定量的評価を行うと同時に、オリーブオイルを用いて月経周期と嗜好性の関連性について評価する。

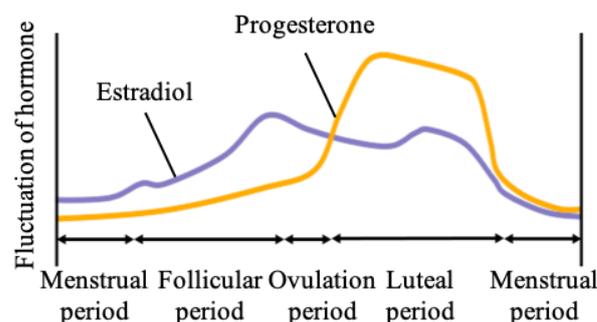


Fig. 1: Fluctuation of hormone balance and menstrual Cycle[5]

### 2 実験

#### 2.1 実験手順

オリーブオイルのストレス緩和効果を定量的に評価するために、ストレス指標の算出に用いる脳波を計測した。ストレス評価方法として、アンケートの実施や血液検査等も挙げられる[6]。しかしながら、アンケートは主観による定性的な評価であることや血液検査は被験者への負担の大きさが問題である。一方で、脳波

を用いたストレス評価は、定量的かつ非侵襲的であるという特徴を持つ。

まず、60秒間の安静閉眼状態の脳波計測を実施した後、被験者は匂いや含まれる成分量が異なる3種類のオリーブオイルA、B、Cの中から匂いが最も好ましいと感じるものを選択する。この時、時間制限や試行回数、確認する順番の指定は設けずに選択する。続いて、再度60秒間の安静閉眼状態の脳波計測を行う。計測終了後、選択したオリーブオイルの種類および女性被験者に限り4期ある月経周期のうちどの期における計測であるかを記録する(Fig. 2参照)。上記の計測は、匂いに対する慣れの影響を排除するために1日につき1回の計測を上限とした。被験者は、20代の健康男性21名および正常な月経を有する健康女性5名とした。脳波計測箇所は国際10-20法に基づく左前頭前野部位Fp1とし、サンプリング周波数は512Hzとした(Fig. 3参照)[7]。選択した計測箇所はストレス情報や感性情報の計測に適した脳波計測箇所である。

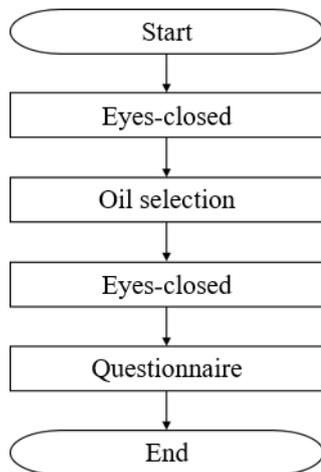


Fig. 2: Experimental flow

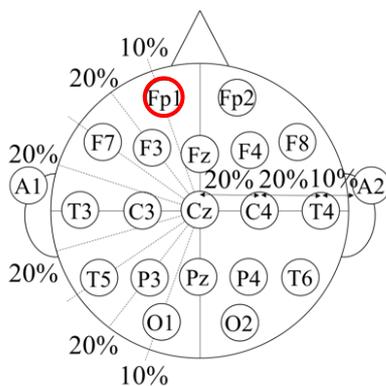


Fig. 3: International 10-20 system

## 2.2 計測装置及び使用機器

本研究では、簡易型脳波計を用いて脳波計測を行った(Fig. 4 参照)。脳波計には大型脳波計と簡易型脳波計の二種類がある[8]。大型脳波計は複数の穴が開いたキャップを頭部に装着し、必要な箇所に電極を設置することで計測が可能となる。実験目的に応じて計測箇所を選択出来る利点を持つ一方で、装着時において頭皮にゲルを塗布する必要性や締め付けが強いことなどから計測時の負担が大きい点が欠点である。簡易型脳波計は、計測箇所が一点に限られるもののキャップが不必要であることから短時間での装着が可能であり計測時の負担を軽減することが出来る。本研究ではストレス情報を取得対象としており、左前頭前野部位 Fp1 から取得した脳波のみから評価可能であること、また脳波計装着によるストレスを軽減する必要があることから、簡易型脳波計を計測装置として採用した。

本研究で用いるストレス情報は、左前頭前野部位 Fp1 より取得した脳波を感性アナライザ©電通サイエンスジャムに入力することで取得した。感性アナライザ©電通サイエンスジャムは脳波から感性をリアルタイムで読み取る事ができる装置である[9]。「好き」「興味」「集中」「ストレス」「沈静」の五つの感性をリアルタイムで算出することが可能である。1秒ごとに 0-100 の数値で値を算出することにより、ミクロな変化も捉えられるという利点がある。また、75秒間のキャリブレーションが行われて、脳波の個人差が考慮されている。これらの感性の推定には、15年以上に渡り取得した生体信号データベースが用いられている。

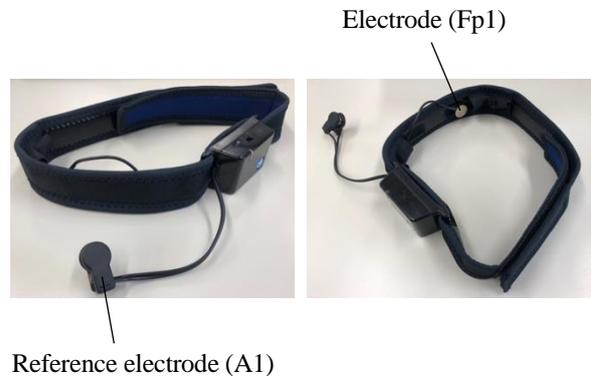


Fig. 4: Simple EEG

## 3 解析

### 3.1 ストレス変化率算出

オリーブオイルのストレス緩和効果を評価するために、左前頭前野部位 Fp1 の脳波から感性アナライザ©電通サイエンスジャムを用いてストレス情報を取得した(Fig. 5 参照)。取得したオリーブオイル選択前後 60秒間のストレス情報から、被験者ごと各状態における中央値およびその差分を算出した。続いて、算出した差分をオリーブオイル選択前の中央値で割ることで変

化率を算出した。次に、オリーブオイル選択後にストレスの低下が確認されたデータを抽出し、オリーブオイル選択前後 60 秒間のデータを用いて有意差検定を実施した。検定は、片側 2 標本 t 検定を用いており有意水準は 5% とした。ここで、実験で取得したデータ数は男性被験者において 274 データ、女性被験者において 276 データであったが、欠損データを排除したためここでは男性被験者において 239 データ、女性被験者において 235 データを解析対象とした。

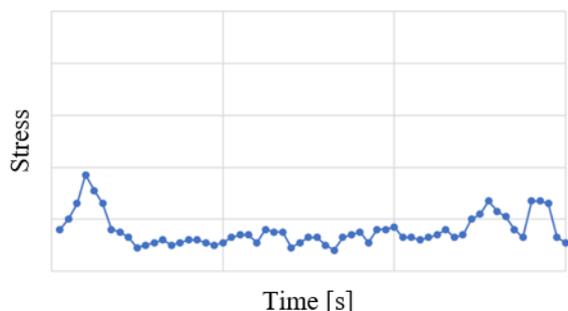


Fig. 5: Stress fluctuation

### 3.2 オリーブオイル選択割合算出

オリーブオイル選択と月経周期の関連性を評価するために、各オリーブオイルの選択割合を算出した。選択割合は、各オリーブオイルの選択回数を被験者ごとの全計測回数で割ることにより算出した。続いて、月経周期およびオリーブオイルの二属性間における独立性を評価するためにカイ二乗独立性検定を実施した。検定は、女性被験者のデータのみを対象とし有意水準は 5% とした。次に、クラメールの連関係数  $V$  を算出した。クラメールの連関係数  $V$  は、値が 1 に近づくほど強い関連があると判断される。ここで、男性被験者において 274 データ、女性被験者において 276 データを解析対象とした。

## 4 実験結果及び考察

### 4.1 ストレス変化率算出結果

ストレス変化率を算出した結果、オリーブオイル選択を経て男性および女性被験者で平均 12.0% と 14.2% のストレス緩和傾向を確認した。また、この緩和傾向は男性および女性被験者でそれぞれ 69.0% と 68.1% のデータで確認出来た。このデータに対し有意差検定を行った結果、男性および女性被験者でそれぞれ 83.6% と 74.4% のデータで有意差が確認出来た。このことから、オリーブオイルには性別に関係なくストレス緩和傾向がある可能性が明らかとなった。

### 4.2 オリーブオイル選択割合算出結果

はじめに、各オリーブオイルの選択割合を算出した。ここでは、最も計測データ数が多い男女各 1 名の結果を示す。男性被験者のオリーブオイル A, B, C の選

択割合はそれぞれ 25.0%, 9.4%, 65.6% であり、女性被験者においては同じ順に 32.5%, 40.9%, 26.6% であった。このことから、男性被験者においては実験の実施時期に関わらず特定のオリーブオイルを選択し易い傾向を持つことに対し、女性被験者においては実験の実施時期に依存して変化する可能性を確認した (Fig. 6 参照)。また、この傾向は他の被験者においても確認出来た。続いて、女性被験者のデータに対しカイ二乗独立性検定を実施した結果、有意差が確認された ( $\chi^2(6) = 13.732, P < 0.05$ )。次に、クラメールの連関係数  $V$  を算出すると  $V = 0.158$  となり、月経周期およびオリーブオイルの二属性間には弱い関連があることがわかった。以上より、女性においては月経周期に伴いオリーブオイルに対する嗜好性が変化する可能性が考えられる。

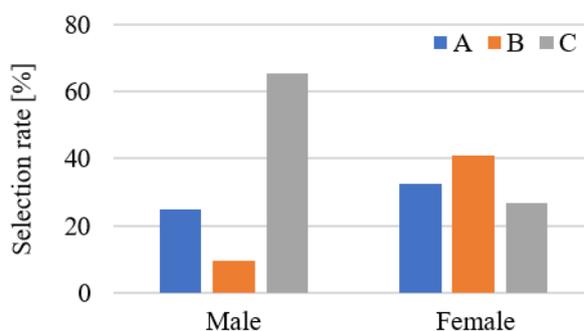


Fig. 6: Selection rate of olive oil

## 5 おわりに

本稿は、オリーブオイルのストレス緩和効果および同オイルに対する嗜好性と月経周期の関連性を評価することを目的とした。本目的を遂行するために、オリーブオイル選択前後における脳波計測と選択したオリーブオイルの種類、女性被験者に限り月経周期を記録した。その結果、以下のような結果が得られた。

- 1) オリーブオイル選択を経て男性および女性被験者において 12.0% と 14.2% のストレス低下。
- 2) 女性被験者に限り月経周期に伴い嗜好性が変化する傾向を確認。

以上の結果は、女性特有の不調緩和のための新たな手段の提案、またその不調緩和効果の最大化のために貢献出来る。しかし、本稿ではわずか女性 5 名に対する実験結果であること、また月経周期の把握は月経終了時からの経過日数により推測したため、必ずしも正確な月経周期が得られていたとは限らない点が問題として挙げられる。今後は、被験者数を増加させより信頼性を高めると共に、基礎体温計測を実施することで月経周期をより正確に把握していく必要がある。

## 参考文献

- 1) RAYMOND L. VANDE WIELE et al. : “Mechanisms Regulating the Menstrual Cycle in Women”, Proceedings of the 1969 Laurentian Hormone Conference, Vol. 26, pp. 63-90, (1970)

- 2) T. Takeda et al. : “Prevalence of Premenstrual Syndrome and Premenstrual Dysphoric Disorder in Japanese Women”, Archives of Women's Mental Health, Vol. 9, No. 4, pp. 209-212, (2017)
- 3) Shinji Watanabe, et al. : “Efficacy of  $\gamma$ -linolenic Acid for Treatment of Premenstrual Syndrome, as Assessed by a Prospective Daily Rating System”, Journal of Oleo Science, Vol. 54, No. 4, pp. 217-224, (2005)
- 4) T. Uzuncakmak, et al. : “Effect of Aromatherapy on Coping with Premenstrual Syndrome: A Randomized Controlled Trial”, Complementary Therapies in Medicine, Vol. 36, pp. 63-67, (2018)
- 5) 武谷 雄二 : 「エストロゲンと女性のヘルスケア」, メジカルビュー社, (2015)
- 6) 田中 喜秀, et al. : “ストレスと疲労のバイオマーカー”, 日本薬理学雑誌, Vol. 137, No. 4, pp. 185-188, (2011)
- 7) 末永 和榮 et al. : 「デジタル臨床脳波学」, 医歯薬出版株式会社, (2011)
- 8) 満倉 靖恵 : “脳波解析による感性アナライジング”, 電気学会誌, Vol. 136, No. 10, pp. 687-690, (2016)
- 9) 感性アナライザ, 電通サイエンスジャム,  
<https://kansei-analyzer.com/>, 2019/5/27 アクセス.

# 聴覚性ブレイン・コンピュータインタフェースにおける 学習データ削減手法の検討

○荻野幹人 (電通サイエンスジャム) 満倉靖恵 (慶應義塾大学)

## Investigation of Learning Data Reduction Method for Auditory Brain-Computer Interface.

\*M. gino (Dentsu ScienceJam Inc.) and Y. Mitsukura (Keio University)

**Abstract**— Brain-computer interface (BCI) is a new technology to present intentions by a brain activity. Most of BCI technology detect event-related potential called P300. Pattern recognition methods are used to discriminate the presentation of P300 and select the command that user s P300 responds. To apply BCI technology for practical use, an accuracy and a convenience. Previous studies have focused on improvement of the accuracy, however a convenience has not been remarked. One of the method to improve the convenience of BCI is reduction of learning data. The learning data, which is recorded by users before using the BCI as command system, is used to train the pattern recognition model. In this study, we combine the trained FLDA model by one sub ect and other FLDA model which is trained by the other sub ects. The method improved the accuracy and it leads to reduce learning data and improve a convenience of BCI.

**Key Words:** Brain-computer interface, EEG, Learning data reduction

### 1 はじめに

新しいコミュニケーション手段として、脳活動を使って意思表示を行なうブレイン・コンピュータインタフェース (BCI) の研究が行われている<sup>1)2)</sup>。BCIは事象誘発電位であるP300を検出する手法が用いられる事が多く、P300の出現をパターン認識手法で判別して、伝えたい意思の選択を行なう。Alan Kayによると、コンピュータ技術の発展には、Institutional, Personal, Intimateの3段階がある<sup>3)</sup>。Institutionalとは研究所レベルでやっと利用できるという状況であり、現在のBCIのフレームワークはほとんどがこの段階にある。BCIの実用化にあたっては、技術をPersonalのレベルにもっていく必要があり、BCIの精度、簡便性の向上が必要となる。これまでに多くの研究者が、BCIの精度を向上を目的に研究を発表してきた。しかしながら、簡便性の観点には、あまり目が向けられてこなかった。

BCIの簡便性の向上のためには、デバイスとフレームワークという視点がある。脳波計がデバイスにあたり、小型化や装着感等の向上が必要である。近年の半

導体技術の進歩によって小型の脳波計が発売されている。これらの脳波計は市場規模こそ小さいが徐々に世の中に浸透してきている。一方のフレームワークは、刺激の提示方法や回数、脳波の取得時間・回数といったBCIの使用方法である。フレームワークはBCIの精度を向上させるために慎重に検討されるべきであるが、BCIの簡便性としての視点ではあまり検討がされてこなかった。

本研究では、簡便性の観点からフレームワークを設計するため、事前取得データの削減を行なう。事前取得データとはBCIを使用する前に、予めP300のパターンをデータ化し、パターン認識手法を学習させるために利用されるデータである。事前取得データが多いフレームワーク程、BCIの精度は向上する傾向にあるが、一方で事前取得データに時間がかかり過ぎ、被験者の疲労を招き、使用感の低下に繋がる恐れがある。そこで、本研究では事前取得データ削減のために、別のユーザから構築したモデルを用いる事を考える。予め取得済みの他の被験者のデータと、新しく被験者から取得された少量のデータを融合することで、少ないデータ

でのモデル構築を目指す。実験では、聴覚刺激を用いた BCI のデータに対し、本手法を適用し、その効果を検証する。

## 2 解析方法

### 2.1 フィッシャーの線形判別 (FLDA)

P300 を含む脳波データとそうでないデータの判別にはフィッシャーの線形判別 (FLDA) が用いられる<sup>4)</sup>。クラス  $C_1$  の点が  $N_1$  個、クラス  $C_2$  の点が  $N_2$  個ある 2 クラス問題を考えると、2 つのクラスの平均ベクトルは以下の式で表される。

$$\mathbf{m}_1 = \frac{1}{N_1} \sum_{n \in C_1} \mathbf{x}_n, \mathbf{m}_2 = \frac{1}{N_2} \sum_{n \in C_2} \mathbf{x}_n \quad (1)$$

FLDA は重みベクトル  $\mathbf{w}$  を定める事によって、クラス分離を最大にする射影を選択することを目的とする。式 (1) を重みベクトルによって射影すると、

$$m_1 = \mathbf{w}^T \mathbf{m}_1, m_2 = \mathbf{w}^T \mathbf{m}_2 \quad (2)$$

となる。それぞれのクラスのクラス内分散は、

$$s_1^2 = \sum_{n \in C_1} (y_n - m_1)^2, s_2^2 = \sum_{n \in C_2} (y_n - m_2)^2 \quad (3)$$

となる。FLDA の評価関数は式 (4) によって表され、最大化を行うことで、重みベクトル  $\mathbf{w}$  を求める。

$$J(\mathbf{w}) = \frac{(m_2 - m_1)^2}{s_1^2 + s_2^2} \quad (4)$$

### 2.2 重みベクトルの合成

事象関連電位の分布が<sup>5)</sup>、被験者に共通するのか、被験者毎に異なるのかは、BCI の判別モデルを生成する際に重要な問題となる。多くの研究が被験者毎に分布を定めているが、一方で被験者全体のデータを用いて推定した分布を用いた学習モデルも、ある程度の精度を持つことが知られている。本研究ではその両方の性質を利用した重みベクトルの合成を行う。ある被験者のデータから学習される重みベクトルの確率分布を  $p(\mathbf{w}_o)$ 、その他の被験者のデータから学習される重みベクトルの確率分布を  $p(\mathbf{w}_{AL})$  とする。それぞれに正規分布を仮定すると、 $\mathcal{N}(\mathbf{w}_o | \mu_o, \sigma_o^2)$ 、 $\mathcal{N}(\mathbf{w}_{AL} | \mu_{AL}, \sigma_{AL}^2)$  となる。

ここで、合成係数  $\alpha$  を導入すると、合成後の分布の平均は以下のように計算される。

$$\mu_s = (1 - \alpha)\mu_o + \alpha\mu_{AL} \quad (5)$$

本研究では、(5) 式によって計算された  $\mu_s$  と、ある被験者個人データから求められる  $\mu_o$  とを比較して、合成効果の検証を行う。

## 3 実験方法

### 3.1 実験フレームワーク

本研究では聴覚刺激を用いた BCI のデータを用いた。Fig. 1(A) に実験フローを示す。各聴覚刺激は 150 ms に設定し、これらをランダムに被験者に提示した。音の間のインターバルは 250 ms に設定した。1 sequence 内に 5 つの sub-trial をランダムに入れ込み、30 sequence を実施した。1 trial 毎に音刺激の提示は停止した。よって、被験者は 30 sequence からなる 1 trial につき、1 コマンド入力する形になり、実験では 1 trial 毎に入力するターゲットを指定された。1 run につき、5 trial を実行し、全部で 15 trial を実行した。音の方向、音の種類は Simon らの研究を参考に選定を行った<sup>5)</sup>。Fig. 1(B) に提示した音の方向を示す。音の提示方向は、 $0^\circ$ 、 $45^\circ$ 、 $90^\circ$ 、 $135^\circ$ 、 $180^\circ$  とした。また、Fig. 1(C) に提示した音の種類を示す。音刺激としては、単純な音階を持つ音刺激よりも、自然界の音を使用した方が、精度が上がるため、音の種類は、Duck, Singing bird, Frog, Seagull, Dove の 5 種類とした。

### 3.2 被験者

被験者は健常な男女 9 名 (女性 3 名, 男性 6 名) 及び ALS 患者の男性 1 名とした。健常者の年齢は脳波測定時、 $33.0 \pm 8.2$  歳、ALS 患者の年齢は 31 歳であった。ALS 患者の機能評価スケールの値は 17 であった。被験者は全員、実験の前日の 21 時からカフェインとアルコールの摂取を控えるように指示を行った。

### 3.3 実験機器

脳波計には単極型脳波計である Mind ave Mobile BMD 版 (NeuroSky 社) を使用した。サンプリング周波数 512Hz であるこの脳波計は、2 極の電極を国際 10-20

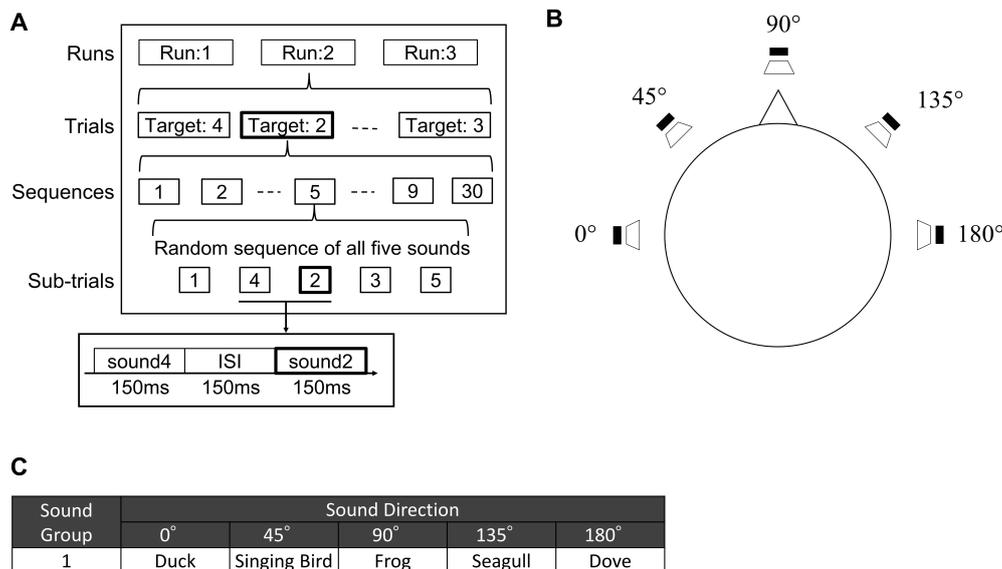


Fig. 1: (A) 実験フロー, (B) 音の方向, (C) 音の種類

法に従う A1-FpZ 部に装着するデバイスである。音はカナル型イヤホン (EM01K, FOSTE) を使用して, iPad から流し, 脳波の測定も iPad から行うことで脳波データと音の同期を行った。

### 3.4 前処理

脳波データに事象関連電位が含まれているか否かの分類をする前に, 前処理を脳波データに対して実行し, 分類が可能な形に変換した。まず, 通過域 0.5–10H のバターワースフィルタを適用した。分類対象データは音刺激の提示開始から 1 秒間のデータとし, 512 サンプルを用いた。対象データのベースラインを補正するため, 音刺激提示直前の 100ms のデータを平均し, 各サンプルデータから差し引いた。最後に, ダウンサンプリングを実行し, 512 サンプルのデータを 16 サンプルに変換した。

### 3.5 検証方法

Fig. 1(A) にも示したが, 本実験では, 各被験者に対して合計 3 Run (15 trial) のデータを取得した。検証では, テスト対象被験者の脳波データ以外は 15 trial を, 事前に取得している事を想定した。テスト対象被験者を除く 9 名のデータ, 合計 135 trial から学習される重みベクトルを  $\mu_{AL}$  とした。テスト対象被験者 1 名のデータは可変とし, 1 Run (5 trial) を取得した想定, 2 Run (10 trial) を取得した想定, 3 Run (15 trial) を取得し

た想定で, それぞれ重みベクトル  $\mu_o$  を求め,  $\mu_{AL}$  と合成した  $\mu_s$  を利用した時とのパフォーマンスの比較を行った。厳密には BCI の精度は 1 trial-out cross-validation を用いて算出するため, テストの 1 trial を除き, 全体が 5 trial の際には 4 trial が学習データ, 10 trial の際には 9 trial が学習データ, 15 trial の際には 14 trial が学習データである。

## 4 結果

合成係数  $\alpha$  を変化させた際の精度変化を Fig. 2 に示す。  $\alpha = 0$  の時は他の被験者のデータを使わず,  $\alpha = 1$  の時は他の被験者のデータのみを使用した形になっている。想定通り, テスト対象被験者の学習データ数 (Run 数) を多くするのに従って, 精度は高くなった。  $\alpha = 0.0$  の際に, 59.0%, 64.6%, 66.0% の順に上昇傾向が見られる。また, 全ての Run 数において,  $\alpha$  の値を増加させ, 他の被験者のデータから学習された重みベクトルの比率を高くするに連れて, 精度が上昇している事が見て取れる。更に,  $\alpha = 0.9$  の時と比較して,  $\alpha = 1.0$  の際に精度は下降した。 Table 1 に,  $\alpha = 0$  の時と精度が最大になる  $\alpha$  を設定した時をまとめた。データとして 1 Run のみを使用際には, 59.0% だった精度が  $\alpha = 0.7$  とすると, 63.6% へ上昇した。 2 Run 使用した際には  $\alpha = 0.7$  に設定時, 64.6% から 65.8% への上昇が見られ, 3 Run を使用した際には,  $\alpha = 0.8$  に設定時, 66.0% か

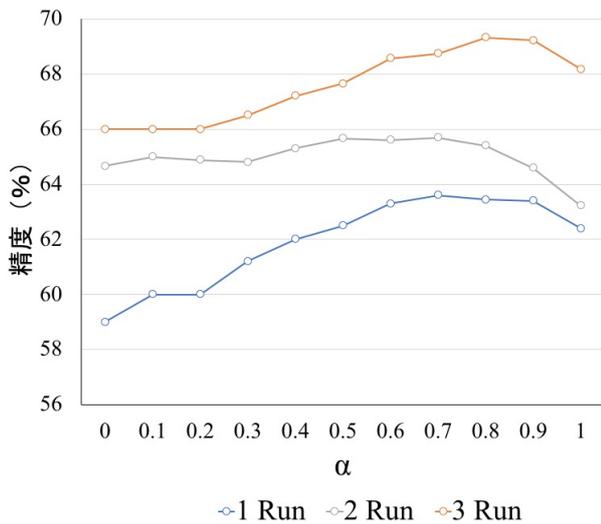


Fig. 2: 合成係数  $\alpha$  を変化させた時の精度の変化

Table 1: 重みベクトル合成時の精度変化 (%)

Sub.	1 Run		2 Run		3 Run	
	$\alpha=0.0$	$\alpha=0.7$	$\alpha=0.0$	$\alpha=0.7$	$\alpha=0.0$	$\alpha=0.8$
1	10.0	<b>50.0</b>	33.0	<b>53.0</b>	20.0	<b>40.0</b>
2	60.0	60.0	60.0	<b>67.0</b>	80.0	60.0
3	70.0	70.0	67.0	67.0	60.0	<b>80.0</b>
4	40.0	<b>50.0</b>	60.0	53.0	80.0	80.0
5	70.0	70.0	73.0	67.0	80.0	<b>100</b>
6	40.0	40.0	47.0	47.0	0.0	0.0
7	90.0	90.0	87.0	<b>100</b>	100	100
8	60.0	<b>70.0</b>	67.0	53.0	60.0	<b>100</b>
9	60.0	60.0	60.0	<b>67.0</b>	80.0	80.0
10	90.0	<b>100</b>	93.0	93.0	100	100
Mean	59.0	<b>63.6</b>	64.6	<b>65.8</b>	66.0	<b>69.3</b>

ら 69.3%への上昇が見られた。

## 5 考察

本研究では、他の被験者の学習用データを合成する事で、対象被験者の学習用データを削減する事を目的に実験を試みた。Fig. 2 及び、Table 1 より、他被験者のデータから学習された重みベクトルを合成することで、合成する前よりも精度を上昇させられる事が分かった。これにより、BCIを成立させるための事前学習用データの削減可能性を示唆した。課題としては、合成によって精度上昇を実現しているものの、テスト対象被験者の学習データ数の量を増やした方が精度上昇が大きい事である。また、10名の被験者の平均精度は上昇したが、被験者によっては $\alpha$ によって、精度低下を

招いている被験者もいた。このため、合成パラメータ $\alpha$ の設定は今後慎重に検討されるべきと考える。

## 6 おわりに

BCIの実用化にあたっては、Alan KayによるPersonalのレベルに技術を到達させる必要があり、BCIの精度、簡便性の向上が必要となる。BCIの簡便性の向上のためには、デバイスとフレームワークという視点がある。本研究ではデバイスとして、単極脳波計を使用した。一方、簡便性の観点からフレームワークを設計するため、事前取得データの削減を行なった。事前取得データ削減のために、別のユーザから構築したモデルを用い、予め取得済みの他の被験者のデータと、新しく被験者から取得された少量のデータを融合することで、少ないデータでのモデル構築を目指した。結果、FLDAの重みベクトルを合成した時の方が、合成しない時よりも精度が向上することが分かった。本研究では重みベクトルの合成を単純な加算平均で行って効果を検証し、他被験者の学習データを使用することの意義を見出したが、今後、さらなる精度の向上を図るためには、より適切な合成方法が検討されるべきであると考えられる。

## 参考文献

- 1) 長谷川良平：ブレイン-マシンインタフェースの現状と将来, 信学誌, (91)-12 1066/1075 (2008)
- 2) 田村潤ら：声刺激による聴覚ブレイン・コンピュータ・インタフェースの可能性, 電子情報通信学会技術研究報告, (111)-467 281/286 (2012)
- 3) 廣瀬通孝：ウェアラブル・コンピュータ：ウェアラブル・コンピュータの展開情報処理, (40)-9 (1999)
- 4) 加納慎一郎ら：聴覚刺激の音脈分凝を利用したBCIシステムの開発, 電子情報通信学会技術研究報告 ニューロコンピューティング, (107)-542 445/449 (2008)
- 5) Simonら：An auditory multiclass brain-computer interface with natural stimuli: usability evaluation with healthy participants and a motor impaired end user, Frontiers in Human Neuroscience, (8/) 1039 (2015)

# マウスの脳波および筋電図を用いたセロトニン神経活動推定

○大橋孝裕 吉田慶多朗 満倉靖恵 田中謙二 (慶應義塾大学)

## Estimation of Serotonin Nervous Activity using EEG and EMG in Mice

\* Takahiro Oohashi, Keitaro Yoshida, Yasue Mitsukura, and Kenji F. Tanaka (Keio University)

**Abstract**— The purpose of this study is to estimate the serotonin nervous activity. Recent advances in fiber photometry and optogenetics have made it possible to measure and manipulate nervous activity in real time in mice. However, these technologies interfere with handling of light and cannot be applied simultaneously. In this paper, we aim to supplement fiber photometry by estimating nervous activity using electroencephalogram (EEG) and electromyogram (EMG) that can be measured simultaneously. In the analysis, nervous activity was divided into three states, and discrimination surface was determined using linear discriminant analysis. As a result, the accuracy was over 90%.

**Key Words:** EEG, Serotonin, Estimation

### 1 はじめに

近年、ファイバーフォトメトリやオプトジェネティクスの技術の発達により、マウスのリアルタイムな神経活動計測や操作が可能となってきた。ファイバーフォトメトリは、カルシウムとの結合により立体構造が変化するカルシウムセンサーを細胞種特異的に発現させることで、光により神経活動を計測する技術である。また、オプトジェネティクスは、光により活性化するたんぱく質を細胞種特異的に発現させることで、光を用いて神経活動の操作を行う技術である。この2つの技術を同時適用することができれば、ファイバーフォトメトリによる計測で得られた神経活動を基に、選択的にオプトジェネティクスによる操作を行うことができると思われる。しかしながら、この技術は共に光を扱うため、オプトジェネティクスの光がファイバーフォトメトリの計測に影響を与えてしまうため、同時適用ができない。そこで、本研究ではオプトジェネティクスと同時計測可能な脳波、および筋電図を用いて神経活動を推定することで、ファイバーフォトメトリによる計測を補うことを目的とする。つまり、この目的が達成されることで、計測と操作の実質的な同時適用が可能となる。

研究対象とする神経細胞はセロトニン神経細胞とした。セロトニン神経細胞は神経伝達物質がセロトニンである神経細胞であり、脳幹の縫線核に局在している<sup>2)</sup>。ヒトとマウスの縫線核の位置をFig. 1に示す。セロトニン神経細胞の活動は情動、抑うつ、覚醒、注意、および自律神経系の調節と関係があり、その機能が低下することでうつ病や睡眠障害を引き起こす原因となる<sup>3)</sup>。うつ病の発症とセロトニン神経活動の低下の相関により、うつ状態は脳内のセロトニンの減少と関係があることが明らかとなっている<sup>4)</sup>。また、睡眠段階によりセロトニン神経細胞の発火頻度が異なることも知られている<sup>2)</sup>。

そこで、セロトニン神経活動を脳波、および筋電図から推定することで、オプトジェネティクスによるセロトニン神経への操作が選択的にできるようになり、セロトニン神経活動による行動への影響、および因果関係が明らかになる。

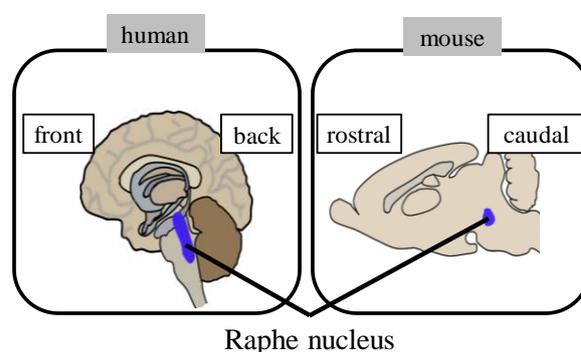


Fig. 1: Position of raphe nucleus

### 2 計測実験

本研究で使用するデータはマウス3匹から計測した。実験に用いるマウスは縫線核にカルシウムセンサーを発現させた。計測状態は自由行動下であり、計測環境は暗所とした。実際の計測の様子をFig. 2に示す。計測項目はファイバーフォトメトリによるイエローとシアンの蛍光、脳波、および筋電図とした。ファイバーフォトメトリにおけるカルシウムセンサーとしてはYellow Cameleon-nano50 (YC-nao50) を使い、光ファイバーを用いて蛍光を取得した。脳波は大脳皮質、筋電図は僧帽筋から取得した。光ファイバー、脳波電極、および筋電図電極の配置の様子をFig. 3に示す。サンプリング周波数はいずれも1000Hzであり、計測は合計6回、各2時間行った。



Fig. 2: Measurement

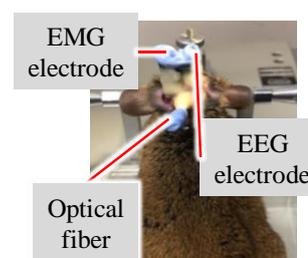


Fig. 3: Placement of measurement parts

### 3 解析

まず、セロトニン神経活動はファイバーフォトメトリによるイエローとシアン蛍光の強さの比により定義した。平均化後、局所的な最大値・最小値を算出し、セロトニン神経活動を3つの状態に分けた。

脳波に対しては高速フーリエ変換を用いて、パワースペクトルを算出し、筋電図に対しては形状の特徴を反映する4つの指標の値を算出した。

セロトニン神経活動により定義された3つの状態間で、脳波、および筋電図から算出された指標の値の差異の有無を検証した。有意差が確認された値を特徴量として、推定のための識別面を決定した。以下に詳細を記す。

#### 3.1 セロトニン神経活動

ファイバーフォトメトリにより得られたイエローとシアンの蛍光の比を算出し、セロトニン神経活動を数値化した。その後、オーバーラップを伴う4000点毎の平均化を行った。オーバーラップのシフト幅は500点とした。平均化を行った後、局所的な最大値・最小値を算出し、セロトニン神経活動を3つの状態に分けた。以下に局所的な最大値・最小値の算出方法を記す。

##### A) 極値算出

セロトニン神経活動に対して微分係数を計算することにより極大点、および極小点を算出する。

##### B) “局所的”の示す範囲の決定

A.で算出した極値が“局所的”なものであるかを判断する。極値と同じ値をとる点の内、時間軸の前後を見て最も近い点をそれぞれ1点ずつ算出する。この2点の間の区間を“局所的”の示す範囲と定義する。

##### C) 状態分け

B.で定義した2点と極値との間の区間における最大値、または最小値を時間軸の前後でそれぞれ算出する。極値との差異が小さい方を対象とし、閾値と比較する。閾値を超えている場合には極値、および前後2点を局所的な最大・最小値とした。閾値は扱っているデータの最大値と最小値の差の1/10の値とした。

A-Cの過程を、局所的な最大値を例としてFig. 4に示す。

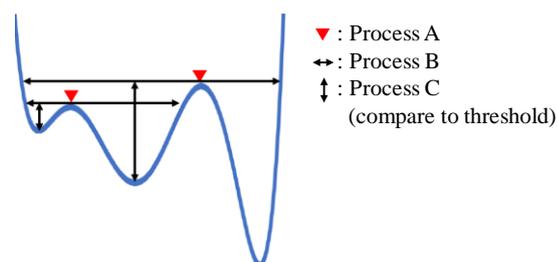


Fig. 4: Local maximum value

### 3.2 脳波

脳波データに高速フーリエ変換を適用し、時間領域から周波数領域に変換する。フーリエ変換とは信号を周波数の異なる正弦波および余弦波の和として考え、信号を周波数領域に変換する手法である。本研究で扱う脳波データは離散信号であり、離散フーリエ変換を適用する。その際には、切り取ってきた有限信号が無限に繰り返されていると考える。その場合、有限信号の両端が連続でない場合、本来信号に含まれる周波数とは異なる周波数成分が含まれてしまう可能性がある。これを解決するために、有限区間の両端を連続にする窓関数を使用する。本研究では窓関数の中でもハミング窓を使用した。ハミング窓を適用した後、以下の式によってフーリエ変換を行った。

$$F(k) = \sum_{n=0}^{N-1} f(n) e^{-i\frac{2\pi}{N}kn} \quad (1)$$

ここで $f(n)$ は時間領域の信号、 $F(k)$ はフーリエスペクトル、 $N$ は有限区間内のデータ数を表す。高速フーリエ変換は4000点毎に行い、シフト幅は500点とした。高速フーリエ変換を行った後、パワースペクトルを算出した。1-100Hzのパワースペクトルを特徴量の候補とした。

### 3.3 筋電図

筋電図からは4つの特徴量の候補を算出した。以下にそれぞれの詳細を記す。

#### • Root mean square (RMS)

RMSは筋電図の平均的な振幅の大きさを示す指標であり、(2)式で定義される。

$$\text{RMS} = \sqrt{\frac{1}{N} \sum_{n=1}^N x(n)^2} \quad (2)$$

#### • Zero crossing

ゼロクロスは筋電図が、基準点である電位差0を通過した回数とした。

#### • Slope sign changes

Slope sign changesは筋電図の傾きの正負が変化する点の個数とした。

#### • Waveform length (WL)

WLは計測データ間での変動の大きさの和を示す指標であり、(3)式で定義される。

$$\text{WL} = \sum_{n=1}^{N-1} |x(n+1) - x(n)| \quad (3)$$

### 3.4 線形判別

3.2および3.3節において算出した特徴量候補のうち、3.1で定義した3状態間で差異があるものを抽出するため、多重比較検定を行った。優位水準は5%とした。検定により有意差が検出された指標を特徴量として、フィッシャーの線形判別分析を用いて識別面を決定した。フィッシャーの線形判別分析は(4)の式で

定義される評価関数が最も大きくなる変換ベクトル  $w$  を求める手法である。

$$\frac{w^T (m_1 - m_2)}{S_1^2 + S_2^2} \quad (4)$$

$$S_k^2 = \sum_{n=1}^N (w^T x_n - w^T m_k)^2 \quad (5)$$

ここで  $m_k$  は平均ベクトル、 $N$  はデータ数、 $k$  は比較する状態の数を表す。

識別面の精度の評価には 100 分割交差検証法を用いた。

## 4 結果および考察

### 4.1 セロトニン神経活動

イエローとシアンの蛍光の比を算出した後の平均化を行う前の値を Fig. 5, 平均化後の値を Fig. 6 に示す。平均化を行うことにより、比較的大きな変動が抽出され、細かい振動は除去されていることが分かる。

セロトニン神経活動を局所的 maximum・minimum とそれ以外の 3 状態に分類した様子を Fig. 7 に示す。Fig. 7 より蛍光の比の絶対値としては小さくとも、局所的には maximum や minimum となっている部分を分類できていることが分かる。以降は局所的 maximum を状態 A, 局所的 minimum を状態 B, その他を状態 C と記す。

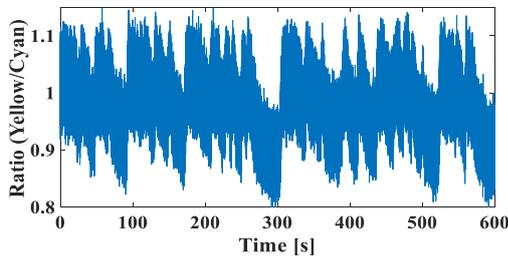


Fig. 5: Serotonin nervous activity before averaging

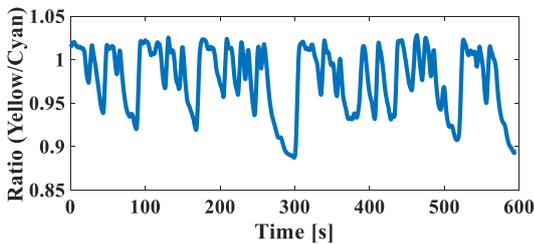


Fig. 6: Serotonin nervous activity after averaging

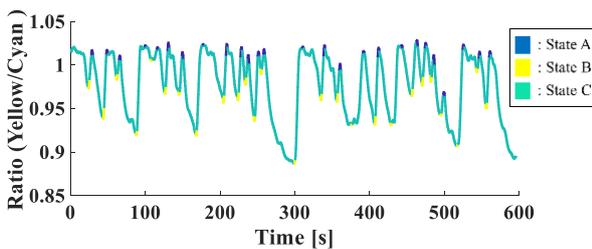


Fig. 7: Classified serotonin nervous activity

### 4.2 脳波

取得した脳波データに対し、高速フーリエ変換を適用した際の 1-30Hz におけるパワースペクトルを Fig. 8 にスペクトログラムの一例として示す。パワースペクトルは最大値を 1, 最小値を 0 として正規化を行った。大きい値を黄色、小さい値を青で示した。Fig. 8 より時間変化とともに優位な周波数域が変化していることが分かる。

### 4.3 筋電図

3.3 にて記した 4 つの指標の時系列変化の一例を Fig. 9, 10, 11, 12 に示す。

Fig. 9 の RMS の時系列変化を見ると、セロトニン神経活動が状態 A の時に RMS が大きく、セロトニン神経活動が状態 B の時に RMS が小さい傾向があることが分かる。

Fig. 10 の Zero crossing の時系列変化を見ると、セロトニン神経活動が状態 A の時は Zero Crossing の変動が大きいことが分かる。

Fig. 11 の Slope sign changes の時系列変化を見ると、セロトニン神経活動が状態 A の時は比較的 Slope sign changes が多いことが分かる。

Fig. 12 の WL の時系列変化を見ると、RMS と形状が類似しているが、Fig. 9 で見られていた 100s 付近のセロトニン神経活動が状態 B かつ RMS が大きいとい

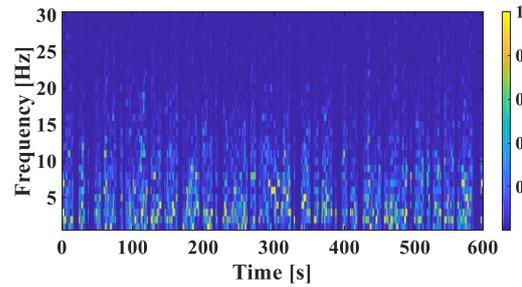


Fig. 8: Spectrogram of EEG

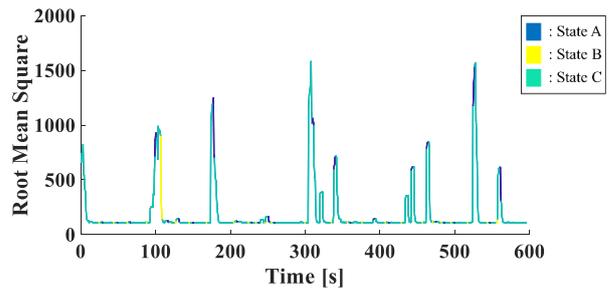


Fig. 9: Time series change of RMS

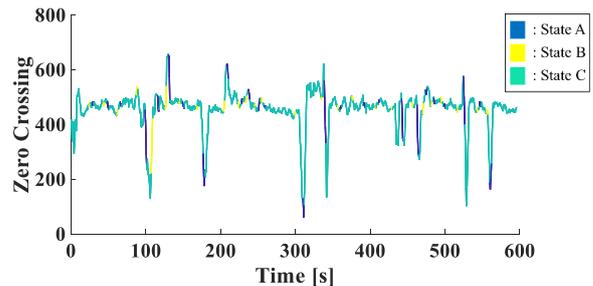


Fig. 10: Time series change of zero crossing

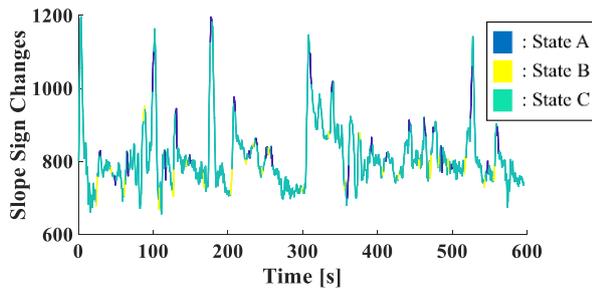


Fig. 11: Time series change of slope sign changes

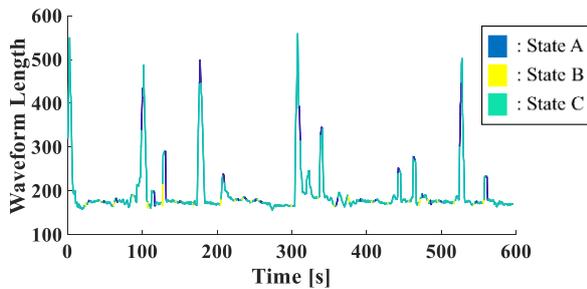


Fig. 12: Time series change of WL

う特徴が無くなっている. このことより WL は RMS より, セロトニン神経活動が状態 A の時に大きく, セロトニン神経活動が状態 B の時に小さいという傾向より鮮明に表れる可能性がある.

#### 4.4 線形判別

多重比較検定により, 有意水準を 5%として有意差の確認された特徴量を Table 1 に示す. Table 1 より, 脳波において, 個体内のすべての比較で共通して有意差が検出されている周波数があることが分かる. このことより, 新たな特徴量として, ある特定の帯域を用いることで, より有力な特徴量となる可能性がある. 筋電図の指標は有意差が検出されている比較項目が多いことが分かる. このことより筋電図が有力な推定特徴量である可能性がある.

Table 1: Feature value for which the significant difference was detected

		State			
		A vs. B	A vs. C	B vs. C	
Mouse number	1	EEG [Hz]	2, 8-15, 17-19, 25-100	8, 9, 12, 13, 28-31, 34-36, 38, 40-43, 45-53, 55, 58-100	1, 2, 7, 11-14, 17, 19, 26-100
		EMG	All	All	RMS, Slope sign changes, WL
	2	EEG [Hz]	1, 6-23, 25, 26, 28, 29, 32, 36-100	1, 2, 5-22, 27, 30, 32-100	2, 4, 5, 9-23, 25, 28, 29, 31-33, 35, 49, 50, 76, 81, 85, 86, 88-90, 94, 95, 97-100
		EMG	All	All	RMS, Zero crossing
	3	EEG [Hz]	7-20, 22-27, 34, 79, 82, 83, 86, 88-100	4, 8-18, 21, 22, 26, 28, 29, 63, 78, 85, 87, 89, 91, 93-95, 98, 100	5, 7-29, 34, 35, 68, 71, 72, 75, 76, 78-100
		EMG	All	RMS, Zero crossing, WL	All

Table 2: Accuracy of discrimination surface

		State		
		A vs. B, C	B vs. A, C	C vs. A, B
Mouse number	1	91.6%	96.7%	96.8%
	2	97.8%	92.1%	91.0%
	3	96.0%	98.5%	97.6%

また, 有意差の検出された特徴量を基に決定した識別面の交差検証法による評価を Table 2 に示す. Table 2 よりすべての個体, すべての比較において, 交差検証法による精度が 90%を超えていることが分かる.

#### 5 おわりに

本研究では, ファイバーフォトメトリによるセロトニン神経活動を推定することを目的とし, EEG と EMG を特徴量としてフィッシャーの線形判別分析を用い, 推定を行った. その結果, 3 匹すべてのマウスで 90%以上の推定精度を記録した. 今後はデータ数を増加させるとともに, 今回作成した識別面を他の個体に適用しより一般性のある評価を行っていく.

#### 参考文献

- 1) Jounhong Ryan Cho, et al. : Dorsal Raphe Dopamine Neurons Modulate Arousal and Promote Wakefulness, by Salient stimuli, *Neuron*, 9, 1205/1219, (2017)
- 2) Eric R. Kandel, et al. : PRINCIPLES OF NEURAL SCIENCE, medical science international, (1981)
- 3) 鈴木良典, 清蔭恵美, 樋田一徳, 「マウス嗅球神経回路におけるセロトニンニューロンのシナプスの微細構造解析」, *川崎医学会誌*, 40-2, 89/102, (2006)
- 4) K. P. Lesch, et al. : A Possible Mechanism of the Nucleus Accumbens and Ventral Pallidum 5-Ht1B Receptors Underlying the Antidepressant Action of Ketamine: a PET Study with Macaques, *Translational Psychiatry*, 4-1, (2014)