

13th SICE Symposium on Computational Intelligence

June 16-17, 2018, Hachioji

第13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：2018年6月16日(土)，17日(日)

会 場：首都大学東京 南大沢キャンパス

**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：情報処理学会，システム制御情報学会，電子情報通信学会，電気学会，日本  
神経回路学会，日本知能情報ファジィ学会，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，進化計算学会，IEEE Computational  
Intelligence Society Japan Chapter (CISJ)，IEEE Systems, Man, and Cybernetics  
Society Japan Chapter

著作権 © 2018

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 18 PG 0006

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：2018年6月16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13回コンピュータショナル・インテリジェンス研究会プログラム

発表 25 分（発表 20 分、質疑応答 5 分）

6月16日（土）

13:05～14:45（100分4件） 司会 畠中利治（大阪大学）

- 1 人とロボットとの協調的コミュニケーションのためのジェスチャ認識 1  
大保武慶，遠藤翔太（東京工芸大学）
- 2 Projection-based ビジュアルサーボシステム 5  
寇ギョウ郡，田宏志，李想，見浪護（岡山大学）
- 3 油圧ショベル掘削作業における感性フィードバック制御を目的としたストレス変動のむだ時間抽出 10  
奈良莉紗，満倉靖恵，浜田望（慶應義塾大学）
- 4 A Robot-based Sports Game for Health Promotion 14  
Nan Shuo, S. Shao and Naoyuki Kubota（首都大学東京）

15:00～16:40（100分4件） 司会 本間経康（東北大学）

- 5 再帰型機械学習を用いた時間-周波数マスキングによる音源分離手法の提案 18  
吉村俊太，満倉靖恵，浜田望（慶應義塾大学）
- 6 遺伝子ネットワークにおける周期発現パターン遷移列の周期感度の解析法 26  
森禎弘，黒江康明（京都工芸繊維大学）
- 7 興奮性-抑制性モジュールにより構成されたスパイクニューラルネットワークによる想起パターンの動的遷移特性 33  
信川創（千葉工業大学），西村治彦（兵庫県立大学），山西輝也（福井工業大学）
- 8 前腕装着型導電性繊維を用いた脈波取得による心拍推定手法の提案 37  
増山義輝，奈倉正樹，満倉靖恵（慶應義塾大学）

16:55～18:10（75分3件） 司会 満倉靖恵（慶應義塾大学）

- 9 Cost-sensitive learningにおけるboostingの適応的しきい値調整の検討 41  
佐々木勇人，濱上知樹（横浜国立大学）
- 10 CXR8 医療ベンチマーク画像を用いた構造適応型 Deep Belief Network による検診データの分析 45  
鎌田真（広島市立大学），市村匠（県立広島大学）
- 11 自己構成型の大脳新皮質学習アルゴリズムに関する検討 51  
鈴ヶ嶺聡哲，青木健，高玉圭樹，佐藤寛之（電気通信大学）

6月17日(日)

9:30~10:45 (75分3件) 司会 生駒哲一(日本工業大学)

- 12 プログラムの簡略化を用いた多峰性遺伝的プログラミングの検証 59  
村野慧, 吉田修武, 原田智広, ターウォンマット・ラック(立命館大学)
- 13 エネルギーマネジメントを考慮したジョブショップスケジューリング問題に対する Reactive Hybrid Particle Swarm Optimization の提案 66  
川口嵩平, 福山良和(明治大学)
- 14 Global-best Modified Brain Storm Optimization によるスマートコミュニティ全体最適化 72  
佐藤繭子, 福山良和(明治大学), 飯坂達也, 松井哲郎(富士電機)

11:00~12:00 Invitation to Computational Intelligence Fons Scientiae Project

13:30~15:10 (100分4件) 司会 福山良和(明治大学)

- 15 顔正面と両手挙動の2動画像からの運転者上半身挙動の把握 80  
生駒哲一(日本工業大学)
- 16 内装の違い・就寝前の音楽聴取が睡眠および知的生産性に与える影響の評価 85  
佐藤慧一, 浅野貴大, 満倉靖恵(慶應義塾大学)
- 17 室内環境が人に与える影響の解析~脳波を用いた人の状態計測~ 89  
堀田健斗, 満倉靖恵(慶應義塾大学), 美寿見奈穂, 小前草太, 古橋拓也(三菱電機)
- 18 Skeleton Data based Human Action Recognition in a Continuous Video 93  
Bangli Liu (University of Portsmouth), Naoyuki Kubota (首都大学東京),  
Zhaojie Ju and Honghai Liu (University of Portsmouth)
- 15:25~17:05 (100分4件) 司会 久保田直行(首都大学東京)
- 19 簡素な数台のロボットを使ったトラッキング・システムにおける量子揺らぎ 98  
伊丹哲郎(ロボット産業振興会議), 松井伸之(兵庫県立大学),  
幸田憲明(松江工業高等専門学校)
- 20 GPS計測と制御を組み込んだ水中模擬充電システムの構築 104  
李想, Khin New Lwin, 許弘毅, 山田大喜, 戸田雄一郎, 松野隆幸, 見浪護(岡山大学)
- 21 ヒトの歩行における運動学データに基づく生体内負荷の最適化による床反力推定 108  
林祐一郎, 長谷和徳, 工藤あすか(首都大学東京)
- 22 V型ROVの複眼ビジュアルサーボシステムの構築 112  
許弘毅(岡山大学), Myint Myo (Thanlyin Technological University), 中村翔, 神田佳希,  
Lwin Khin New, 松野隆幸, 戸田雄一郎, 見浪護(岡山大学)



# 人とロボットとの協調的コミュニケーションのための ジェスチャ認識

大保武慶 ○遠藤翔太 (東京工芸大学)

## Gesture Recognition for Human-Robot Collaborative Communication

T. Obo and \* S. Endo (Tokyo Polytechnic University)

**Abstract**— Recently, various types of communication robots have been developed and become more familiar with us. Human-like conversation with gestures and verbal cues makes a contribution to provide more natural communication. In this study, we proposed a gesture recognition method based on dynamic time warping and pulse neuron model. To extract temporal pattern of depicting gesture, we implemented an online learning structure in the human-robot interaction.

**Key Words:** Gesture Recognition, Human-Robot Interaction, Imitation Learning

### 1 はじめに

我々は様々な形式の言葉や身振りを使う一方で、特に気にすることもなく、それらを瞬時に解釈することができる。言葉や記号の解釈の仕組みに着目すると、D.Sperber と D.Wilson によって提唱された関係性理論の概念が重要な役割を果たす。従来、人間のコミュニケーションは、送り手が情報をコード化し、受け手がコードを復号化する過程であると考えられてきた。これはコードモデルと呼ばれる概念である。しかし、コードモデルでは、送り手の意図まで受け手に伝えることができないことや、復号化されていない部分に関する解釈に言及しないなど、その限界が指摘されてきた。D.Sperber と D.Wilson は、送り手の意図と受け手の推論を分けて考える意図明示推論的コミュニケーションを提唱し、コードモデルのみに依存しない、受け手側の蓋然的な推論の存在に基づくコミュニケーションモデルを考えた<sup>2)</sup>。これは、H.P.Grice の提唱する協調原理や会話格率に準ずる概念でもある。意図明示推論コミュニケーションでは、受け手の解釈は要する労力と認知的効果の観点から、送り手の行為自体に最適な関連性が含まれていると考える。しかし、このような推論モデルを考慮したとはいえ、送り手と受け手の間で推論規定を同様に作用させるためには、双方が同様の知識集合を有しているだけでなく、それが共通する知識となっている必要がある。そのため、コミュニケーションにおいて想定される知識集合を顕在化した「相互認知環境」の構築が重要とされる。

我々は相手に何か気づかせようと意図することで、その意図を明示する行為を直視的な動作で表現することがある。例えば、指さし動作は、「あれ」や「これ」と発話するだけで、話者の意図を受け手に容易に解釈させる。これは外界の環境やそのまま個人へ内面化されることで成立するように思われる。しかしながら、乳児が母親との関係で指さし動作を獲得する過程を考えると、乳児は初めから指さし機能を持っているわけではなく、さらに、母親の模倣をするわけでもない。この点に関して、L.S.Vygotsky は、はじめは乳児が何かを掴もうとして手を伸ばすことが、母親の援助得られることに気づくことで、指さし機能へと変化することを指摘している。ここで重要なのは、乳児の行為が、母親との関係で新しい意味を獲得したという過程であ

る。つまり指さし動作の獲得は、単に外にあるものを個人に内面化する過程ではなく、社会的行為の関係が変化することによって、双方の活動を再編し、新しい意味を作り出す過程である<sup>3)</sup>。

また、M.Tomasello は、指さし、物まねを用いたコミュニケーションにおいて、「自己」・「他者」・「もの」の三者間の関係である三項関係について重要視している<sup>4)</sup>。これは共同注意において見られる。例えば「あれを見て」と物体を指さしして他者とその物体の認識を共有するとき共同注意が行われ、三項関係が生まれている。このような共同注意は自己と他者の「共通概念基盤」の形成に用いられる。

以上のように、人間同士のコミュニケーションでは、投機的なメッセージのやり取り、互いにメッセージを推論することでコミュニケーションが生まれる。メッセージは相手の解釈に依存しているため、積極的に相手に推論させる協調的な行為が必要となる。また、このような協調的なコミュニケーションを成立させるには相互的な行為の中から推論するための情報の構造化も必要である。そこで本研究では、ロボットとの協調的なコミュニケーションを実現するため、指さし動作の検出および対象物の認識、さらに、ジェスチャの形や意味が表現内容に応じて自由に変化できる描写的ジェスチャの認識に着目し、人とロボットとのインタラクションの中から意味を創発することを目指したコミュニケーションシステムを構築する。

### 2 協調的コミュニケーションのための指さしの検出と情報構造化

#### 2.1 コミュニケーションロボット

本研究では、コミュニケーションロボットとして、富士ソフト株式会社の「PALRO」を用いる (Fig. 1)。PALRO (パルロ) は富士ソフトが開発しているヒューマノイドロボットである。PALROは、顔認識や個人識別、動体検知が可能で、音源方向を認識、音声合成エンジンで発声なども可能である。PALROの全高は約40 cm、重さはバッテリーを含めて約1.6 kgである。全身に搭載されたアクチュエータを用いて様々な動作を生成することができる。PALROの主な仕様を表1にまとめる。



Fig. 1: Communication robot: PALRO.

Table 1: Specification of PALRO

本体	全高	40 cm
	重量	1.6 kg
	可動部	23 軸
	消費電力	60 W
センサ	加速度センサ×1, ジャイロセンサ×1, 距離センサ×1, 圧力センサ×8	

## 2.2 距離画像センサを用いた指さし検出

本研究では、人の直示的ジェスチャの検出及び物体認識を行うため、Microsoft社によって開発されたKinectセンサを適用する。Kinectセンサを用いて指さし姿勢を検出する方法はいくつか提案されているが、その多くはKinectセンサによって取得される関節位置情報に基づく方法である。しかし、関節位置情報に基づく姿勢推定は、被験者の体型等による個人差の影響も受けやすい。そのため、本研究では、運動学モデルと遺伝的アルゴリズム (GA) を用いた方法を適用し、Kinectセンサから得られる情報から関節角度を推定し、指さし姿勢の検出を行う。

運動学モデルは、上腕部、前腕部、手先において、4つの関節から構成される。ここでは、遺伝的アルゴリズムを用いることで、Kinectセンサによって取得された各関節位置に運動学モデルの関節位置を近似させるように各関節角度を求める (Fig. 2)。 $i$  番目に生成した解候補は以下のように表現される。

$$\mathbf{g}_i = (\theta_{i,1}, \theta_{i,2}, \theta_{i,3}, \theta_{i,4}) \quad (1)$$

また、 $i$  番目の解候補から順運動学を解いた後の肘と手先における各関節位置を  $\mathbf{p}_i^{GA}$  ( $i=1, 2$ )、Kinectセンサによって計測された各関節位置を  $\mathbf{p}$  とすると、適応度は以下のように表現できる。

$$f_i = \sum_{j=1}^S (\alpha_j \|\mathbf{p}_j^{GA} - \mathbf{p}_j\| + \beta) \quad (2)$$

$f_i$  は  $i$  番目の個体の適応度、 $S$  は関節数、 $\alpha_j$  は重み係数、 $\beta_j$  はペナルティ項である。ペナルティ項は、生成した解候補が人間モデルの可動域外の値をとる場合や1ステップ前の値と比較し解候補との差分がある閾値より大きな場合に加算される値である。以上のように、この問題は適応度が最小になるように各関節角度を求める最小化問題として帰着される。

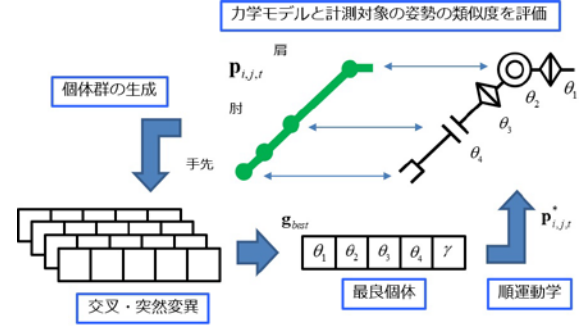


Fig. 2: Joint angle estimation based on genetic algorithm.

指さし姿勢は、得られた関節角度に基づき検出を行う。本研究では、肩の関節角度である  $\theta_1$  または  $\theta_2$  が 30 度以上で、肘の関節角度  $\theta_3$  が 20 度以下のときに、指さし姿勢と定義し、検出を行うこととした。また、指さし方向の推定には、運動学モデルの手先と肘の位置情報から方向ベクトルを求めている。

## 2.3 指さしに基づく知識情報の構造化

本提案手法では、指さし方向の推定結果に基づき対象物体の認識を行うが、従来手法では、物体認識における領域分割などを行う場合、データ量が多く処理が膨大化することがある。そこで本研究では、Kinectセンサによって取得された点群座標データから空間的な特徴点を抽出する。さらに、得られた位相空間に対して、指さし動作や人間-ロボット間の発話内容の関連づけを行うことで、共有可能な知識として構造化を行う。具体的には、特徴抽出として Growing Neural Gas (GNG) というトポロジカル・マッピング手法を適用し、関連づけに Hebb 則に基づく相関学習を適用する (Fig. 3)。また、本研究では、指示対象への時空間的な隣接性をモデル化するため、発火による文脈表現が可能なパルスニューロンモデルを適用する。

## 3 人とロボットとの相互作用に基づく表象的ジェスチャのモデル化と認識

### 3.1 テンプレートマッチングに基づく表象的ジェスチャの検出

ジェスチャは、ノンバーバルコミュニケーションの身体感覚的要素の一つで、伝えるべき内容に関連のある情報を表現する際の身体の動きである。表象的ジェスチャは、指示対象の時空間的な隣接性と類似性に基づき発生する身体の動きである。何かを指し示すとき「あれ」や「これ」などと指を指し示す行為は、隣接性に基づく動きとして「直示的ジェスチャ」と呼ばれる。また、指示対象と身体の動きの類似性に基づくジェスチャを「描写的ジェスチャ」という。

本章では、人とロボットとの相互作用の中から描写的ジェスチャを学習・認識するための方法を提案する。ジェスチャ認識の方法は、従来研究において、様々提案されているが、その主な課題としては、(1) 動作に関する空間的な分解能の設定、(2) 時系列データの文脈的な表現、(3) 追加学習などによる個人差への対応などが挙げられる。そこで本研究では、まず課題 (1) に対して、計測環境を格子状空間として捉えることで、Dynamic Time Warping (以下、DTW) に基づくテン

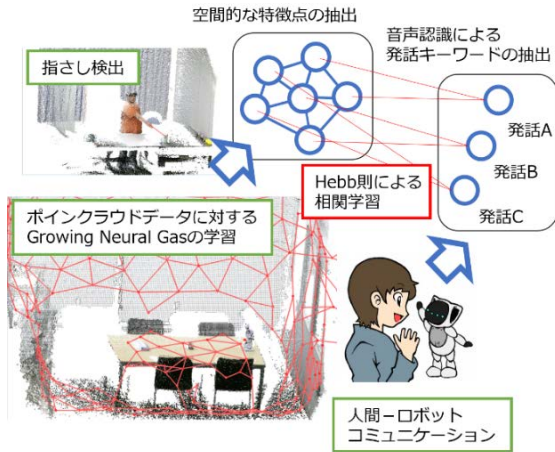


Fig. 3: Learning structure in human-robot interaction.

プレートマッチングを適用する (Fig. 4). また, 課題 (3) で述べているように, 各個人によって動作の大きさが異なることも考えられることから, ジェスチャを量子化して, 部分プレートマッチングを行う. さらに, たとえプレートと同一経路をたどるジェスチャでも, 時間的特性が異なる場合もあることから, 課題 (2) への対策として, パルスニューロンモデルから構成される Spiking Neural Network (以下, SNN) を用いた学習・認識システムを構築する.

DTW は, 動的計画法に基づき, 要素数の異なる連続的なデータ間の類似度を求める方法である. ここで, 長さ  $N$  の連続的なパターン  $\mathbf{S} = (s_1, s_2, \dots, s_N)$  と, 長さ  $M$  のプレート  $\mathbf{T} = (t_1, t_2, \dots, t_M)$  との類似性を最大限に求める問題を考えると, パターン  $\mathbf{S}$  と  $\mathbf{T}$  との類似度の最大化問題として帰着させることができる. DTW では, プレート  $\mathbf{T}$  に対して, 連続的なパターン  $\mathbf{S}$  を膨張 (Expansion), 収縮 (Contraction), 適合 (Match) させながら, 類似度を計算していく. 本研究では, DTW の問題に対する定式化として, Forward DP-Formulation に基づく解法を用いる. 連続的なパターン  $\mathbf{S}$  の  $i$  番目の要素とプレート  $\mathbf{T}$  の  $j$  番目の要素との類似度を  $d(i, j)$ ,  $(i, j)$  までの類似度が最大となる評価関数を  $V(i, j)$  とすると, 以下のように表現できる ( $i = 1, 2, \dots, N, j = 1, 2, \dots, M$ ).

$$V(i, j) = d(i, j) + \max \begin{cases} V(i-1, j) & \text{: Expansion} \\ V(i, j) & \text{: Match} \\ V(i, j-1) & \text{: Contraction} \end{cases} \quad (3)$$

また本研究では, 類似度の計算において, 3次元空間内での方向ベクトルを比較するため, コサイン類似度を適用する.

$$d(i, j) = \frac{\mathbf{s}_i \cdot \mathbf{t}_j}{\|\mathbf{s}_i\| \|\mathbf{t}_j\|} \quad (4)$$

DTW を適用することで, 手先軌道の時系列データからプレートに基づきジェスチャを推定することができる (Fig. 5). 一方, そのためには, 事前にプレートを作成し, コミュニケーションに必要なジェスチャを定義しなければならない. しかしながら,

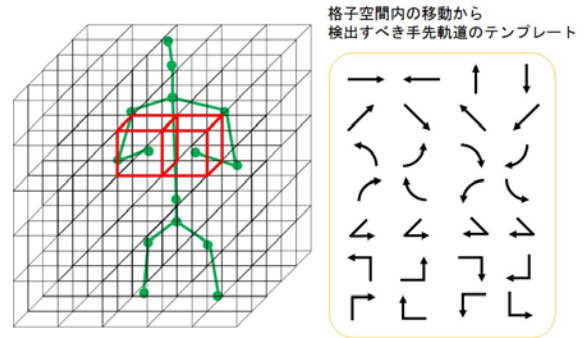


Fig. 4: Grid space and templates for recognizing primitive behavioral patterns.

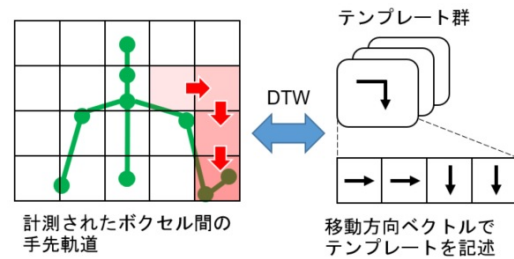


Fig. 5: Template matching for gesture recognition.

本研究で対象とする描写的ジェスチャは, 必ずしも身振りのかたちを一般的に定義できるものではなく, コミュニケーションの中での相互作用を通じて意味づけされるため, ジェスチャ全体を成す長期的なプレートを事前に設計することは難しい. そのため本研究では, ジェスチャを構成する部分的な動作を対象としてプレートマッチングを行い, 認識されたプレートの文脈的關係から描写的ジェスチャとして使用される動作を追加的に学習・認識するシステムを構築する.

### 3.2 パルスニューロンモデルに基づく描写的ジェスチャの抽出

各プレートの認識結果を文脈的に表現するため, パルスニューロンモデルに基づく発火表現を用いる. 一般的なニューロンモデルは, 工学的応用において有用な性質の一部のみを用いているが, 実際の脳内のニューロンの応答特性はより複雑なダイナミクスをもつ. パルスニューロンモデルは, 神経細胞の内部状態の変化を実際の生体反応により近い表現で模式化しており, 発火の有無やそのタイミングに基づき出力の振る舞いに変化するモデルである.

本研究では, パルスニューロンモデルの一つであるスパイク発火モデルをより簡易的に表現したモデルを適用する. 内部状態  $h$  は, 時刻  $t$  において以下のように与えられる.

$$h(t) = \gamma h(t-1) + h^{ext}(t) + h^{ref}(t) \quad (5)$$

ここで,  $h^{ext}(t)$  は外部環境からの入力値,  $h^{ref}(t)$  はニューロンの不応期を表現する値,  $\gamma$  は減衰率を示す ( $0 < \gamma < 1$ ). パルスニューロンモデルでは, 内部状態が任意の閾値を超えると, その瞬間だけ出力を与える発火現



象を起こす。神経発火の有無を  $p(t) \in \{0, 1\}$  とすると、以下の式のように表現できる。

$$p(t) = \begin{cases} 1 & \text{if } h(t) \geq q \\ 0 & \text{otherwise} \end{cases} \quad (6)$$

また、神経細胞には、一度発火すると、一定期間は発火が抑制される不応期とよばれる特性がある。不応期を表現する項  $h^{ref}(t)$  は、次のように計算される。

$$h^{ref}(t) = \begin{cases} -R & \text{if } p(t-1) = 1 \\ \gamma^{ref} \cdot h^{ref}(t-1) & \text{otherwise} \end{cases} \quad (7)$$

さらに、神経細胞の活動電位は、シナプス後電位に基づくニューロン間の結合関係によって伝搬される。シナプス後電位は、発火の有無に基づき以下のようにモデル化される。

$$h^{PSP}(t) = \begin{cases} 1 & \text{if } p(t) = 1 \\ \gamma^{PSP} \cdot h^{PSP}(t-1) & \text{otherwise} \end{cases} \quad (8)$$

本研究では、DTW の各テンプレートに対してパルスニューロンモデルを一つずつ割り当て、描写的ジェスチャを構成する各動作の文脈的關係をモデル化する。具体的には、「人」、「ロボット」、「対象物」の三項関係から、人が指差しなどによってロボットと共同注意した対象物に対して、付加的に描写的ジェスチャを行うことで、対象物に対する共通概念の形成を目指す。ここでは、DTW によって算出される評価関数  $V(N, M)$  に基づき、パルスニューロンモデルへの入力を与える。

$$h_i^{ext}(t) = \begin{cases} 1 & \text{if } \arg \max_{0 < i \leq L} V_i(N, M) = i \\ 0 & \text{otherwise} \end{cases} \quad (9)$$

$L$  は用意したテンプレートの総数である。

また、学習手法には、以下のように Hebb 則に基づく逐次学習を適用する。

$$w_{i,j} \leftarrow (1 - \eta) \cdot w_{i,j} + \eta \cdot h_j^{PSP}(t-1) \quad \text{if } p_i(t) = 1 \quad (10)$$

ここで、 $w_{i,j}$  はニューロン  $j$  からニューロン  $i$  への結合強度であり、 $\eta$  は学習係数を示している。

#### 4 予備実験

提案手法による描写的ジェスチャの学習、認識を検証するための予備実験を実施した。本実験では、先に述べた三項関係に基づき、被験者には対象物に指差しをしてもらった後で、その対象物を表現する描写的ジェスチャを行ってもらった。図 6 に実験の様子を示す。図中(A)では、計測環境下にあるボールを指差すことで被験者、ロボット、ボールの参考関係を構築する。その後、図中(B)にて、ロボットが「対象物がなにか」を尋ねたときに、被験者が「ボール」と言いながら、円を描くようなジェスチャを行っている(図中(C))。

また、図 7 には、円を描くときのテンプレートマッチングの結果を示す。結果より、テンプレートの ID が、右手の場合において「16」、「3」、「19」、「2」、「13」、「20」、左手の場合において「15」、「1」、「23」、「2」、「14」、「24」と順に選択されているのが確認できた。右手の場合において、テンプレート




Fig. 6: Experiment of gesture recognition.




Fig. 7: Template matching based on DTW.

の内容を確認すると、16番は「上移動から右移動へのL字の移動」、3番は「右方向への移動」、19番は「上から右方向へ時計回りに円弧を描く移動」、2番は「下方向への移動」、13番は「下移動から左移動へのL字の移動」、20番は「右から下方向へ時計回りに円弧を描く移動」となっていた。以上より、部分的な動作のテンプレートが描写的ジェスチャの形状に合わせて呼び出されていることがわかる。左手に関しても同様の結果となった。さらに、テンプレートの選択に合わせてパルスニューロンモデルを発火させることにより、Hebb 学習に基づき「円を描く」描写的ジェスチャのモデルを作成することが出来る。

#### 5 おわりに

本稿では、ロボットとの協調的なコミュニケーションを実現するため、表象的ジェスチャに着目し、指差し動作の検出および描写的ジェスチャの認識手法を提案した。予備実験では、簡易的な三項関係に基づく実験事例を示し、ロボットが追加的にジェスチャを学習できることを示した。

#### 参考文献

- 1) D. Wilson and D. Sperber: Relevance theory, Handbook of pragmatics (eds L. Horn & G. Ward), Oxford: Blackwell, pp. 607-632 (2004)
- 2) D. Wilson: Linguistic Structure and Inferential Communication, in Proceedings of the 16th International Congress of Linguists, (1998)
- 3) 喜多壮太郎: ジェスチャー 考えるからだ, 金子書房, (2002)
- 4) M. Tomasello, M. Carpenter, and U. Liszkowski: A New Look at Infant Pointing, Child Development, vol. 78 (3), pp. 705-722 (2007)

# Projection-based ビジュアルサーボシステム

○寇 ギョウ郡 田 宏志 李 想 見浪 護 (岡山大学)

## Projection-based Visual Servoing System

\*Y. Kou H. Tian X. Li M. Minami (Okayama University)

**Abstract**— Nowadays, in the field of robot vision, the control method called visual servoing attracts attention. Visual servoing is one of the methods for controlling robots. By incorporating visual information obtained from the installed visual sensor into the feedback loop, it is expected to enable robots to work in the constantly changing environment or unknown environment. Now, in this field, there were some methods that have been proposed to realize visual servoing. However, in those methods, the pre-knowledge such as the size, color, shape of the target is needed to some extent, which may lead a low flexibility to the system. To this issue, we proposed the project-based method. In this method, we use a dual-eyes configuration to perform the visual servoing towards the arbitrary target object. First, the model was created by image shown in left camera in real time, by using homography in projection geometry, then the image in the left camera is projected into 3D space to make a search model, then project the 3D search model into the right camera again to estimate the position and rotation of target object. In this paper, the recognition accuracy of position and orientation of unknown target object was verified.

**Key Words:** Visual Servoing, Projection-based, RT-MS GA

## 1 緒言

近年, 社会の発展に伴う, ロボットへの要求は, 従来のように操縦者がロボットを介して作業を行うものから, 変化する環境の中でロボット自身が自律行動をとるものへと変化している. ロボットは工場現場, 深海探索などの常に変化する環境または未知の環境で作業することが期待されている.

その要求を対応するため, 常に変化する環境中ロボットが正確的に距離を感知することが重要である. 人間では, 環境中の物体を二つ目で距離を測れる, それは視差により, 大脳に三角測量と生活の経験で距離が分かる, 精確的な結果と言えないですが, 大体の距離感を掴むことができる. しかし, 現段階では, ロボットが人間の知性というものを持つことができないから, 障害物を避けるため, ロボットが一般的に距離センサを搭載し, 周辺の環境を感知する. 距離センサが主に光学式, 超音波式, レーザー光線式に分かれている. 距離センサでロボットが環境と距離を感知できるが, 距離センサの検出距離が短い, 影響を受けやすい, 検出空間が狭いなどの欠点を持っている. さらに, 複雑な環境をマッピングするなら時間がかかるの特徴がある. 常に変化するの環境へ応用することが難しい.

その問題に対して, 我々はビジュアルサーボが一つの解決策と考える.

ビジュアルサーボとは, ロボットを制御する方式のひとつである. 搭載される視覚センサから得られる視覚情報をフィードバックループに組み込むことによりロボットを制御する.

現在, ビジュアルサーボを実現するため, いくつかの方法が提案されているが, これらの方法は入力目標値により, 位置ベース法 (position-based method), 特徴ベース法 (image-based method) と 2-1/2-D 方 (2-1/2-2 method) 3つに大別される<sup>1), 2)</sup>. しかし, 以上の方法は対象物の大きさ, 色, 或いは形状などの事前知識がある程度必要であり, これによりシステムに柔軟性が低下する可能性がある. この問題を解決するた


め, 我々の研究グループは射影ベース認識法という方法を提案した. この方法では, 任意対象物に対するビジュアルサーボを目的として, Dual-eyes カメラによる認識を行う. 上記各認識手法の特徴を Fig.1 のテーブルに示す.

射影ベース法は, 実時間にモデルを作り, 変更することができるという特徴により, システムの柔軟性を向上しながら, 任意物体を対象物として認識することが可能である. さらに, Dual-eyes カメラを搭載し, 両カメラの視差により奥行き方向の距離を検出しやすい, 可視領域が広いなどのメリットがある. 本報では, 射影ベースにより未知対象物の位置と姿勢の追従精度を検証する.

## 2 Projection-based 認識法

### 2.1 探索用モデル生成

まず, Fig.2(a) に示すような画像を左カメラから取得する.



(a)Background and target object (b)Extraction of target object

Fig. 2: Model Generation Process

画像中心点から辺の長さが  $240(\text{Pixel})$  の正方形をモデルとして切り出す. 正方形内部が  $13(\text{Pixel})$  ごとにサンプリング点を生成し, 各サンプリング点の色情報が記録される. そして, 画像座標系  $\Sigma_{IL}$  が Fig.2(a) に示すように画像の中心に設定されている. これにより, 各サンプリング点が画像座標系  $\Sigma_{IL}$  での位置情報が得られる. そこで, 画像座標系での位置情報と色情報を持つ

	Position-based method	Image-based method	2-1/2-D Servoing	Projection-based method (本法)	Photo-model-based[3] (本研究室から提案)	Model-based [4] (本研究室から提案)
認識可能な対象物	三次元対象物	二次元対象物	三次元対象物	任意対象物	任意対象物	三次元対象物
モデルの定義・実験的知識	三次元モデルとして必要	特徴点として必要	画像と三次元情報[6]	実時間にモデルを作成, 事前のモデル定義は不要	①対象物の写真 ②写真からカメラまでの距離	三次元モデルとして必要
対象物まで距離の認識	モデルにより認識可能	データベースにより認識可能[5]	認識可能	認識可能	認識可能[7]	認識可能[8]
正確のシステム校正 (カメラのパラメータなど)	必要	不要	必要	必要	必要	必要
ロボットの形を確定	出来る	出来ない	出来る	出来る	出来る	出来る
利点	①既知モデルによりビジュアルサーボが簡単 ②デカルト座標系で直接に制御するため, 軌道計画は簡単	システムの校正が不要のため, ロバスト性は高い	①三次元モデルは必要ない ②Position-basedとImage-based法の欠点を克服できる.	①先験的知識が不要のため, 柔軟性は高い ②デカルト座標系で直接に制御するため, 軌道計画は簡単 ③任意対象物までの距離を認識できる	①写真によって, 速くモデルを作れ, 速く対象物を変更できる ②対象物の接平面をモデルとして作ることで, 対象物の寸法, 形と色などの定義が不要	①対応点の探す不要 ②既知モデルの三次元点群により画像認識精度が高い
欠点	①モデルの定義は面倒, いろいろなターゲットに使用できない[4] ②カメラなどのハードウェアからの影響を受けやすい	作業空間中のロボット制御は困難	事前情報が必要のため, 柔軟性は不十分	現段階, 対象物と背景の色は似ている場合が認識し難い	写真が撮る時, 対象物とカメラの距離が必要	モデルの作りは時間がかかる

Fig. 1: The features of visual servoing method

ているモデルが生成される. モデルの外側から二層が帯部分 ( $S_{L,out}$ ) であり, 正方形の部分は面部分 ( $S_{L,in}$ ) と定義されている.

## 2.2 射影ベース認識法の概要

Fig.3 に示すように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. 前節で説明したモデル生成の方法で左カメラ画像に映った対象物をモデルとして抽出し, Fig.3 に示すようにモデルを左カメラ画像から GA(遺伝的アルゴリズム) の遺伝子からの位置/姿勢  $\phi = (x, y, z, \epsilon_1, \epsilon_2, \epsilon_3)$  ( $\epsilon$  はクォータニオンの姿勢変数) 情報を用いて, 3次元空間へ逆射影する. 逆射影されたモデルを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, 対象物の位置と姿勢を得ることができる. 従って, 平面モデルの位置/姿勢  $\phi$  (6変数) が対象物の位置/姿勢 (6変数) 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, 探索範囲内すべての可能性を探索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認識であり, 動画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. 従って, GA がある程度収束した時, 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.

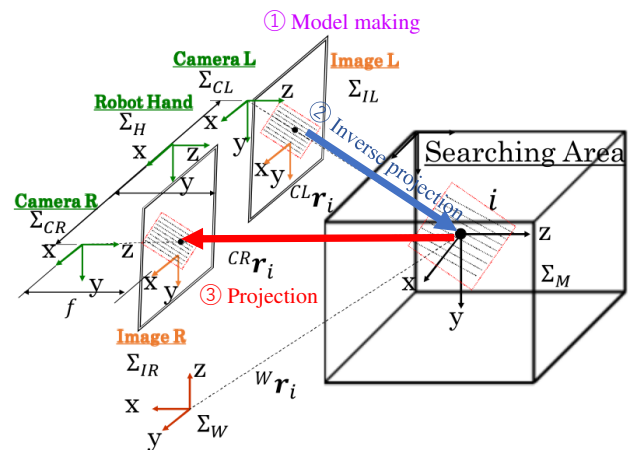


Fig. 3: Overview of Projection-based Method

## 3 認識結果評価手法

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



システムでは対象物の3次元位置・姿勢の実時間認識を可能としている。また、提案システムによる対象物の位置・姿勢の認識情報は、Fig.3に示すGA探索空間内で獲得される。

### 3.1 適合度関数

左右カメラ映る画像と逆射影した結果を評価するため、本研究は適合度関数を利用して、認識結果を評価する。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.4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、 $N$ は面部分と帯部分の評価点の総点数、 $H_{IR}(IRr_i)$ は右カメラ画像の色相値、 $H_{MR}(IRr_i)$ はモデル各サンプリング点の色相値と定義し、右画像領域 $IRr_i^j(\phi_M^j)$ における色相値に基づく評価値を $p_R(IRr_i^j(\phi_M^j))$ 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が20以上離れていた場合は、評価値を“-1”と設定する。モデルの色相値と右カメラ画像の色相値の差が20以下の場合は、評価値を“+2”と設定する。また、モデルの色相値と右カメラ画像の色相値の差が20以下の場合は、評価値を“+0.1”と設定し、他の点の評価値を“-0.5”とする。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。

$$F(\phi_M^j) = \left\{ \begin{array}{l} \sum_{IRr_i^j \in S_{R,in}(\phi_M^j)} p_{R,in}(IRr_i^j(\phi_M^j)) + \sum_{IRr_i^j \in S_{R,out}(\phi_M^j)} p_{R,out}(IRr_i^j(\phi_M^j)) \\ \hline S_{R,in}(\phi_M^j) \quad S_{R,out}(\phi_M^j) \end{array} \right\} / N \quad (1)$$

$$p_{R,in}(IRr_i^j(\phi_M^j)) = \begin{cases} 2, & \text{if } (|H_{IR}(IRr_i^j(\phi_M^j)) - H_{MR}(IRr_i^j(\phi_M^j))| \leq 20); \\ -1, & \text{if } (|H_{IR}(IRr_i^j(\phi_M^j)) - H_{MR}(IRr_i^j(\phi_M^j))| > 20); \\ 0, & \text{otherwise.} \end{cases} \quad (2)$$

$$p_{R,out}(IRr_i^j(\phi_M^j)) = \begin{cases} 0.1, & \text{if } (|H_{IR}(IRr_i^j(\phi_M^j)) - H_{MR}(IRr_i^j(\phi_M^j))| \leq 20); \\ -0.5, & \text{otherwise.} \end{cases} \quad (3)$$

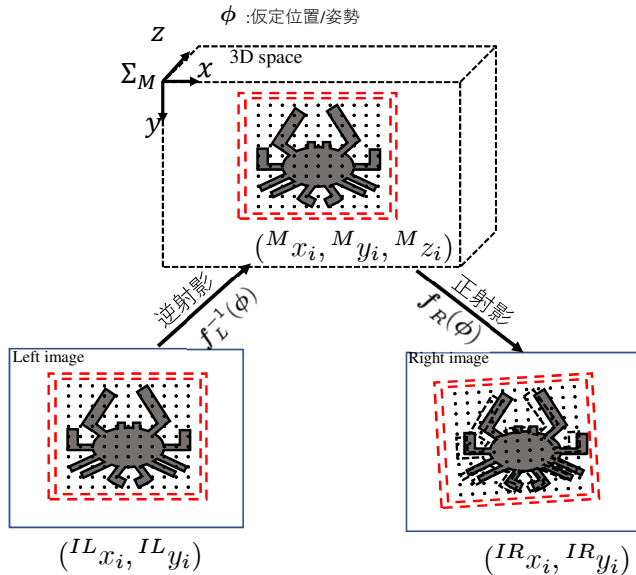


Fig. 4: Searching Model

この関数は、右画像領域 $IRr_i^j(\phi_M^j)$ の中で、 $S_{R,in}(\phi_M^j)$ に重なる入力画像の評価値 $p(IRr_i)$ の合計値から、 $S_{R,out}(\phi_M^j)$ のそれを差し引くことで、右画像の適合度 $F_R(\phi_M^j)$ 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、 $F_R(\phi_M^j) \leq 0$ の場合、 $F_R(\phi_M^j) = 0$ とする。

### 3.2 RT-MS GA

前節で述べてき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 $F_R(\phi_M^j)$ 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を適用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。

$$\begin{array}{ccc} C L z_{M i C} & H x \theta_M & H y \theta_M \\ \underbrace{01 \cdots 01}_{10 \text{ bit}} & \underbrace{00 \cdots 01}_{7 \text{ bit}} & \underbrace{11 \cdots 01}_{7 \text{ bit}} \end{array}$$

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。

探索時に、Fig.5に示すようにまず、探索区間中にGAの初期個体を生成する。次に、式(1)に示した適合度関数 $F(\phi_M^j)$ より各個体の適合度値を得る。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。

しかし、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であり、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を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。

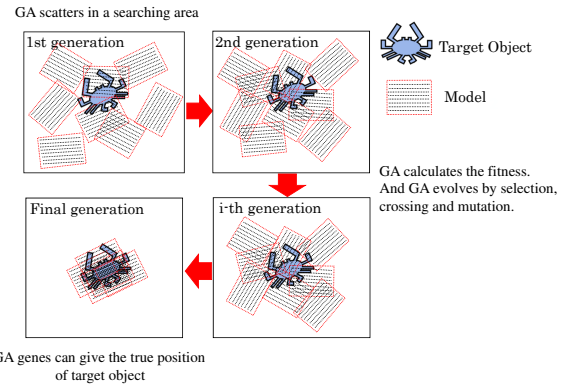


Fig. 5: Evolution Process of GA

本研究では、まずGA-PC1で左画像から切り出した部分をモデルとして左画像中RT-MS GAで $(ILx_{ij}, ILy_{ij})$ を探索する。求められた $(ILx_{ij}, ILy_{ij})$ をルーターでGA-PC2に転送し、逆射影を行う。逆射影の計算により空間中探索モデルの位置 $(Mx_{ij}, My_{ij}, Mz_{ij})$ を見つける。そしてRT-MS GAで各探索モデルを右カメラ比較し、適合度が高い結果を求める。ここで、現段階射影ベース法を用いたビジュアルサーボシステムが33[ms]の中に、左カメラの進化世代数は20代、右カメラの進化世代数は15代、その特徴により実時間で対象物の位置と姿勢を検出することができる。

## 4 移動中対象物に向けた認識実験

### 4.1 システム構成

本システム構成は対象物把持ロボット (Target Object-Robot) とビジュアルサーボ認識ロボット (V.S.-Robot) 二つ部分で構成されている。ロボットは PA10 三菱重工業株式会社製であり、認識部のカメラセンサーが FCR-IX11A (Sony 製) である。各部分の座標関係は Fig.6 で表す。




Fig. 6: The Coordinate System

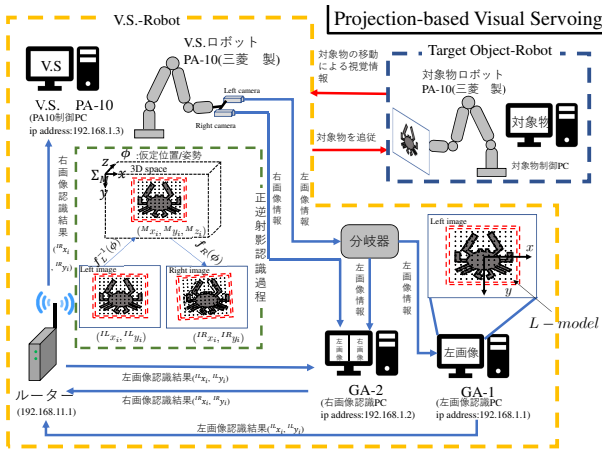


Fig. 7: The Experiment Environment

### 4.2 実験内容

実験の構成図は Fig.7 で表されている。本実験では、対象物とハンドの間の位置と姿勢を一定の値を保つことを目標として、20 秒の周期で奥行方向 ( $\Sigma_x$  方向) のビジュアルサーボをする。ここで、対象物とハンドの位置と姿勢の関係は式 (4) のように表されている。また、対象物の移動は式 (5) で表されている。まず GA-PC1 で左画像から切り出した部分をモデルとして左画像中 RT-MS GA で  $({}^Lx_{ij}, {}^Ly_{ij})$  を探索する。求められた  $({}^Lx_{ij}, {}^Ly_{ij})$  をルーターで GA-PC2 に転送し、逆射影を行う。逆射影の計算により空間中探索モデルの位置  $({}^Mx_{ij}, {}^My_{ij}, {}^Mz_{ij})$  を見つける。そして RT-MS GA で各探索モデルを右カメラ比較し、適合度が高い結果を求める。そして、対象物を  ${}^MX$  に軸回りの回転角度を  $\epsilon_1$ ,  ${}^MY$  に軸回りの回転角度を  $\epsilon_2$  として、30 秒周期で  $-5^\circ \sim 5^\circ$  の往復回転についてビジュアルサーボをする。

$${}^Hd\phi_M = [0[mm], -80[mm], 500[mm], 0, 0, 0]. \quad (4)$$

$$L = -100 + 100 \cos(\omega t)[mm]. \quad (5)$$

そこで、式 (4) の関係を用いて、ハンドの目標位置と姿勢が認識された対象物の位置と姿勢から得られる。ハンドの目標位置と姿勢を用いて、ビジュアルサーボをすることができる。

### 4.3 実験結果

実験の結果は Fig.8 で示す。図中赤い線は対象物位置の真値、黒点線は追従結果である。結果から見ると、射影ベース法を用いたビジュアルサーボシステムは対象物の移動軌道に沿って、見失うことなしで連続に対象物を認識した。最初の 4 秒間で対象物を探索し、4 秒以後認識結果は対象物の軌道に収束している。奥行方向 ( $\Sigma_x$ ) の認識結果は約最大 50[mm] の誤差が持っている。上下、左右及び姿勢の認識結果が真値に収束していることが分かる。




Fig. 8: The Experiment Result

## 5 結言

本文では、射影ベース認識法を用いたビジュアルサーボシステムで対象物の認識結果を報告した。今回行った実験結果より、我々が提案したビジュアルサーボシステムが位置及び姿勢における認識できることが分かる。今後は対象物の位置/姿勢認識精度を向上させることを目指して、本システムロボスタ性を検証し研究を進めていく予定である。



## References

- 1) Kragic, Danica and Henrik I. Christensen. "Survey on Visual Servoing for Manipulation."
- 2) Hutchinson, Seth, Gregory D. Hager, and Peter I. Corke. "A tutorial on visual servo control." *IEEE transactions on robotics and automation* 12.5 (1996): 651-670.
- 3) Khaing Win Phyu, Ryuki Funakubo, Ryota Hagiwara, Hongzhi Tian, Mamoru Minami, "Verification of photo-model-based pose estimation and handling of unique clothes under illumination varieties", *Journal of Advanced Mechanical Design, Systems, and Manufacturing*, Vol.12, No.2.
- 4) 田 宏志, 寇 ギョウ郡, 見浪 護 "横軸方向周波数応答実験による両眼転導ビジュアルサーボの評価", *日本機械学会論文集* Vol.87, No.857, 2017
- 5) Song, Jinseon and Yongwan. "Image Features Comparison-Based Position Estimation Method Using a Camera Sensor." (2016).
- 6) Chaumette, Fran?ois, and Ezio Malis. "2 1/2 D visual servoing: a possible solution to improve image-based and position-based visual servoings." *Robotics and Automation, 2000. Proceedings. ICRA'00. IEEE International Conference on*. Vol. 1. IEEE, 2000.
- 7) 舟久保 龍希, Khaing Win Phyu, 田 宏志, 寇 ギョウ郡, 見浪 護, 矢納 陽 "複眼ハンドアイロボットを用いた不定形単品衣服ハンドリングとビジュアルサーボ", 第 27 回インテリジェント・システム・シンポジウム
- 8) Yejun Kou, Hongzhi Tian, Mamoru Minami, Takayuki Matsuno, "Improved eye?vergence visual servoing system in longitudinal direction with RM?GA", *Artif Life Robotics*, Vol.23, Issue 1

# 油圧ショベル掘削作業における 感性フィードバック制御を目的としたストレス変動のむだ時間抽出

○奈良莉紗 満倉靖恵 浜田望 (慶應義塾大学)

## Extraction of Time Delay in Stress Fluctuation during Excavation Work for KANSEI Feedback Control System in Hydraulic Excavators

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

**Abstract**— In this paper, we aimed to define and extract time delay in stress fluctuation during excavation work to realize a control system of hydraulic excavators (KANSEI feedback control system). In recent years, stress caused by harsh working environments has been a considerable problem in society because it may lead to life-threatening diseases including depression. We focused on construction sites as examples of harsh working environments. Attempts have been made to reduce noise and vibration of hydraulic excavators to improve the environment surrounding workers. These attempts do not consider operability however, which is also a considerable cause of stress. We attempted to improve the operability of hydraulic excavators by realizing automatic control system using stress values (KANSEI feedback control system). In order to realize this system, finding correlation between control output and stress is necessary. In this research, we acquired stress value using KANSEI analyzer. KANSEI analyzer calculates KANSEI value (stress value) per second, which is represented in percentage (0%: low degree – 100%: high degree). Subsequently, we defined and extracted the time delay in stress fluctuation. As a result, it was confirmed that the time delay tended to increase with working time.

**Key Words:** EEG, Kansei, Hydraulic excavators

### 1 はじめに

近年、過酷な労働環境により生じるストレスは深刻な社会問題となっており、労働環境に起因するストレスに直面している労働者は全体の半数に及ぶと言われている[1]。ストレスとは外部からの刺激により生じる心拍数の上昇や胃腸の不調などを伴う身体反応を指す。適度なストレスは人間が成長するために必要であるとされているが、長期に渡る場合や過度のストレスは生体に悪影響を及ぼす。ストレスは集中力の低下を引き起こし、これは労働現場における仕事効率の低下に繋がる。さらには、うつ病などの生命に関わる病気を発症することもあるため、排除することが必要とされている。現在、過酷な労働環境は数多く存在するが、本研究ではその中でも長時間労働で知られる建設現場に着目する。現場では、油圧ショベルなどの建設機械が発する騒音や振動を軽減し、労働者を取り巻く環境を改善することでストレス軽減への取り組みがなされている。しかし、油圧ショベルの操作性により操縦者が感じるストレスは考慮されていないため、ストレスの排除の余地がある。本研究では、ストレス情報を用いて油圧ショベルの操作性向上を目的とする。ストレスを感性の1つと捉え油圧ショベルの感性フィードバック制御[2, 3]を実現することで、機体の操作性を改善し更なるストレスの軽減が期待出来ると考える。感性は、見るものや聞くものなどの刺激に含まれる多義的で曖昧な情報を受け取る直感的な能力を指す[4]。感性が備わっていなければ、外部から与えられる刺激に対して感情が生じることはないと言われている。本研究で考える感性フィードバック制御のブロック線図を Fig. 1 に示す。通常の機体制御に加えて、感性情報に含まれるストレス値を元に制御パラメータの調整を行うこと

で操作のアシストを行う制御手法を表している。感性フィードバック制御を用いることで、熟練度を問わず全てのユーザーに対して操作が快適な機体を実現出来るのではないかと考える。むだ時間は、システムの安定化に深く関連しているため、感性フィードバック制御の実現にはむだ時間を明らかにする必要がある。油圧ショベル操作時におけるストレス変動のむだ時間は感性フィードバック制御系におけるむだ時間に相当するため、制御パラメータの調整を適切に行うために明らかにする必要がある。本研究では、油圧ショベル掘削作業時におけるストレス変動のむだ時間を抽出する。




Fig. 1: KANSEI feedback control system

### 2 実験

#### 2.1 実験手順

ストレス変動のむだ時間を抽出するために油圧ショベルを用いた掘削作業中の脳波計測を行った。脳波を用いたストレス計測は一般的に行われており、非侵襲的で負担が少なくリアルタイムな計測が可能であると

いう特徴を持つ。脳波計測時の掘削作業は全12サイクル行い、前半の6サイクルを掘削作業1、後半の6サイクルを掘削作業2とした(Fig. 2 参照)。各作業前には、30秒間の安静閉眼状態を設けている。各サイクルは掘削、持上旋回、排土、復帰で構成され、作業時間は無制限とした。さらに、計測終了後に操作性に関する自由回答形式の聞き取り調査を実施した。実験は、二種類の油圧ショベル(機体A及び機体B)に対して熟練及び非熟練者各1名を被験者として、それぞれの条件において10セット行った。これは、油圧ショベルの特性の違いや操縦者の熟練度の差が操作性に与える影響を考慮するためである。脳波計測箇所は国際10-20法[5]に基づく左前頭前野部位Fp1とし、サンプリング周波数を512Hzとした(Fig. 3参照)。選択した計測箇所はストレスを含む感性情報の容易な取得に適していると言われている。

操作中は油圧ショベル上に3台のビデオカメラを設置して作業映像を取得した。これは、ストレス変動のむだ時間を抽出する際に、ストレス変動と作業のイベント時刻を同期する必要がある為である。

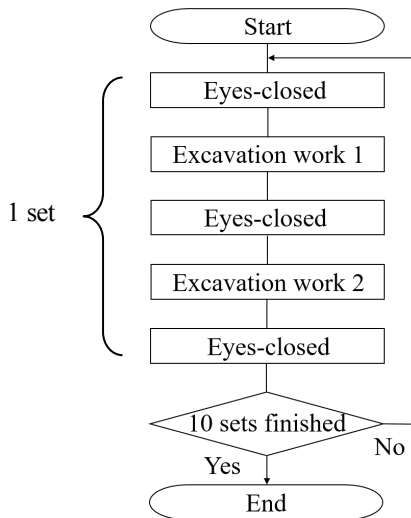


Fig. 2: Experimental flow

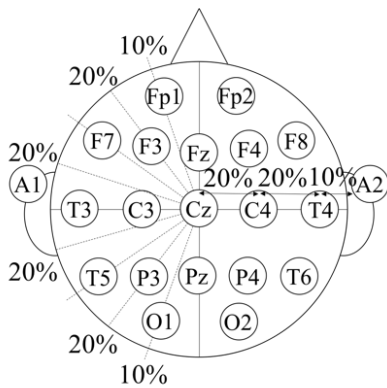


Fig. 3: International 10-20 system

## 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。脳波計には大型脳波計と簡易型脳波計の二種類がある。大型脳波計は装着に長時間かかること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問題である。一方で、簡易型脳波計は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(Fig. 4 参照)。本研究ではストレスを評価対象としており、脳波計装着によるストレスを軽減する必要があるため、簡易型脳波計を用いて計測を行った。本研究で用いるストレス値は計測した脳波を感性アナライザに入力することで取得した。感性アナライザは、脳波から感性評価を行う装置である[6]。「好き度」「興味度」「集中度」「ストレス度」「沈静度」の五つの感性をリアルタイムに分析することが出来る。得られたデータは0-100%の数値で示される。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。これらの感情の推定に用いられている独自のアルゴリズムには、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: EEG device

## 3 解析

### 3.1 ストレス値取得とデータの切り出し

取得した脳波データを感性アナライザに入力し1秒毎にストレス値を取得した。この処理は脳波計測中にリアルタイムで行った。

掘削作業1と掘削作業2では6サイクルの作業を連続して行っているため、作業映像を用いてサイクル毎にストレス値データの切り出しを行った。Fig. 5とFig. 6に取得したストレス値とデータの切り出し例を示す。




Fig. 5: Stress value




Fig. 6: Data segmentation

### 3.2 むだ時間抽出

切り出したサイクル毎のデータに対して、掘削作業時におけるストレス変動のむだ時間の抽出を行った。まず、各サイクルの開始時刻を0秒としサイクル毎にグラフ化した。その後、グラフよりストレス変動の極大値の中で値が最大となる時刻までの時間を求め、それをむだ時間と定義した(Fig. 7 参照)。




Fig. 7: Detection of time delay

また、Fig. 8 に示す①及び②のように、極大値の中で最大となる時刻が1サイクルのデータ内に複数存在するデータが確認された。本研究では、初めに極大値の中で最大となる時刻が掘削作業を開始したことに起因するストレス反応であると考えた。つまり Fig. 8 において、掘削作業開始時刻から①の時刻までがむだ時間であると定義して抽出を行った。




Fig. 8: Selection of time delay

## 4 実験結果及び考察

定義に基づいて抽出したむだ時間を、掘削作業 1 (1-6 サイクル)及び掘削作業 2 (7-12 サイクル)それぞれに対して平均値として算出した。掘削作業 1 において、機体 A を使用した際の熟練者におけるむだ時間の平均値は 6.1 秒、非熟練者においては 7.9 秒であった。掘削作業 2 においては熟練者と非熟練者の順にそれぞれ 6.5 秒と 8.1 秒であった。また、機体 B を使用した際の熟練者におけるむだ時間の平均値は掘削作業 1 において 7.8 秒、非熟練者においては 8.9 秒であった。掘削作業 2 においては熟練者と非熟練者の順にそれぞれ 7.8 秒と 9.3 秒であった(Table 1 参照)。

まず、異なる種類の油圧ショベルを用いた際のむだ時間を比較する。掘削作業 1 及び 2 のいずれにおいても機体 A に対して機体 B 使用時にむだ時間の平均値が大きな値となる傾向が確認出来た。さらに、聞き取り調査の結果機体 B と比較して機体 A の動作速度が早いこと、また軽い力でレバー操作が可能であることを確認した。この特性の違いにより作業に要する時間が機体ごとに大きく異なっていたことから、各機体を用いた際の 1 サイクルの作業に要する時間に着目する。機体 A を使用した際の熟練者における平均時間は 12.2 秒であり非熟練者においては 14.9 秒であった。また、機体 B を使用した際の熟練者における平均時間は 14.8 秒であり非熟練者においては 15.1 秒であった。従って、機体 A と比較して機体 B 使用時において 1 サイクルの作業に要する時間は長くなる傾向が確認出来た。つまり、機体の特性の違いにより生じる作業時間の増加に伴いむだ時間が大きな値を取る傾向を持つことが考えられる。

同様に、異なる熟練度の操縦者が油圧ショベルを操作した際のむだ時間を比較すると、熟練者に対して非熟練者のむだ時間の平均値が大きな値となる傾向が確認出来た。また、各被験者の 1 サイクルの作業に要する時間に着目すると熟練者と比較して非熟練者の場合に 1 サイクルの作業に要する時間は長くなる傾向が確認出来た。つまり、操縦者の熟練度の違いにより生じる作業時間の増加に伴いむだ時間が大きな値をとる傾向を持つことが考えられる。

続いて、各条件 1 サイクルごとに算出したむだ時間の平均値をグラフ化し、線形近似を行った結果の一例を Fig. 9 と Fig. 10 に示す。横軸はサイクル数、縦軸はむだ時間であり、近似直線は点線で示されている。

Table 1: Time delay in stress fluctuation

	Time delay [s]			
	Hydraulic excavator A		Hydraulic excavator B	
	Skilled	Unskilled	Skilled	Unskilled
Excavation work 1	6.1	7.9	7.8	8.9
Excavation work 2	6.5	8.1	7.8	9.3

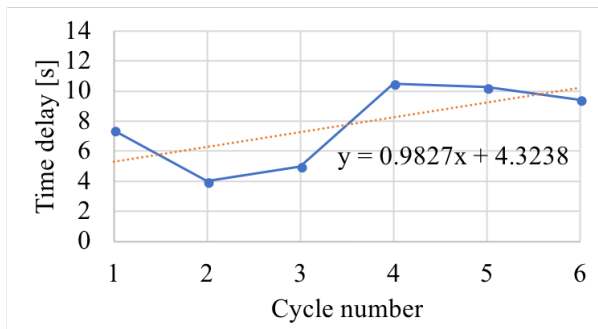


Fig. 9: Graph of time delay 1




Fig. 10: Graph of time delay 2

近似直線の傾きは、熟練者が機体 B を使用した際の掘削作業 2 及び非熟練者が機体 A を使用した際の掘削作業 1 を除きすべて正の値を示した。そのため、サイクル数が増加し作業時間が長くなることでむだ時間が増加する傾向を持つ可能性が改めて確認された。傾きが負の値を示したデータは 10 セットの計測のうち欠損データが多く含まれていた。つまり、データ数が減少することにより傾きが負の値を示した可能性が考えられる。以上より、本研究で定義したむだ時間は作業時間の長さによらず一定の値を示す可能性は低く、作業時間の長さ按比例して増加する可能性が示唆された。この結果は、感性フィードバック制御の実現の際に時変となるむだ時間を考慮した上で制御パラメータを算出する必要性があることを意味すると考える。

## 5 おわりに

本研究では、制御出力とストレスの関係を明確にするために油圧ショベル掘削作業時におけるストレス変動のむだ時間を抽出した。その結果、本研究で定義したむだ時間が作業時間に比例して増加する傾向を明らかにした。むだ時間を明らかにすることは、感性フィードバックシステムの実現及び安定化に貢献することが出来る。しかし本研究ではわずか 12 サイクル分の掘削作業を 10 セット行った際のデータに対して解析を行ったため、サイクル数及びセット数がさらに増加した場合、言い換えると作業時間がより長くなった場合にも同様の結果が得られるとは限らない。これを明らかにするためには、サイクル数の増加やセット数の増加を検討していく必要がある。

## 謝辞

本研究は、文部科学省科研費基盤研究 (S) YYK7S01 の助成を受けたものです。

## 参考文献

- 1) S. M. Jex : “Stress and Job Performance: Theory, Research, and Implications for Managerial Practice”, Sage Publications Ltd, (1998)
- 2) Takuya Kinoshita et al. : “Design of a Data-Oriented Kansei Feedback System”, International Conference on Artificial Life and Robotics, (2017)
- 3) 木下 拓矢 et al. : 「感性フィードバック制御系における感性情報処理に関する考察」, 電気学会研究会資料, No. 5, pp. 45-50, (2017)
- 4) 藤田和生 : 「感情科学」, 京都大学学術出版社, (2007)
- 5) 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)
- 6) 感性アナライザ, 電通サイエンスジャム, <https://kansei-analyzer.com/>, 2018/4/22 アクセス.



## A Robot-based Sports Game for Health Promotion

\* N.Shuo, S.Shao, N.Kubota (Tokyo Metropolitan University)

**Abstract**— To encourage elder people to participate in exercise, it is important to increase the motivation of them. We suppose that self-efficacy theory which present by Bandura is suitably on this situation. In order to prove our suppose, we invent a robot-based game which refer to sport game “golf”. Instead of normal golf ball, we use the ball robot “SPRK” which is controllable, so we can increase winning percentage secretly. In order to make SPRK interaction to human smoothly, the position of detection of SPRK must be efficiently and correct. We promote a reliable detection system by using Kinect, then we test the game of the “golf robot”. Also, future research is required to ascertain the effects of such challenges on self-efficacy in elder people.

**Key Words:** Ball robot, Robot-based sport, HRI, Self-efficacy, Positioning

### 1 INTRODUCTION

Exercise and physical activity have been demonstrated to have wide-ranging effects on a host of physical conditions including coronary artery disease, obesity, cancers, and all-cause mortality. Moreover, it appears that these effects are not unique to the young but are also reliably demonstrated in older adults [1,2]. In addition to the physiological effects of exercise, a considerable literature suggests that a number of psychological conditions are also influenced, including cognitive functioning and anxiety.

Self-efficacy expectations are the individual's beliefs in his/ her capabilities to execute necessary courses of action to satisfy situational demands and are theorized to influence the activities that individuals choose to approach, the effort expended on such activities, and the degree of persistence demonstrated in the face of failure or aversive stimuli [3,4]. Perceptions of personal efficacy have typically been identified as important predictors of exercise and other health outcomes [5] but have largely been ignored as psychosocial outcomes in and of themselves. With respect to exercise and physical activity, even relatively short, acute bouts of physical activity have been shown to enhance self-efficacy.

The problem of exploring an environment belongs to the fundamental problems in mobile robotics. In order to construct a model of their environment mobile robots need the ability to efficiently explore it. The key question during exploration is where to move the robot in order to minimize the time needed to completely explore an environment. This problem unfortunately is already NP-hard for known, graph-like environments. In this case it directly corresponds to the problem of finding the shortest roundtrip through all nodes of the graph, which is the well-known traveling salesman problem.

Learning from demonstration is a promising approach that can transfer many robot prototypes remaining in re-search laboratories to the real world since it typically does not require any expert knowledge of robotics technology teaching robots' new tasks. It thus allows end-users to teach robots what robots should do based on their own requirements at their place. LfD also has been attracting a lot of interest from researchers in the field of Human-Robot Interaction (HRI) because it helps robots to learn new tasks that are infeasible to be

learned using pre-programming like personal requirements as their human counterparts. Furthermore, the HRI perspective can help to build a robot learning process more efficiently learn a new task from observations. End-users can teach robots anew task what robots should do without any expert knowledge of robotics technology.



Fig. 1: The robotic ball Sphero SPRK

The Sphero SPRK is a robotic remote-controlled ball capable of rolling around on its own in any direction at multiple speeds. Numerous games have been designed for the SPRK for smartphones and tablets. However, most of these games provide an interface for controlling the SPRK that is far from natural. These games also do not put a strong focus on the physical environment around the SPRK. This work discusses a control scheme used to control a SPRK with another SPRK, and a pervasive game leveraging this scheme that emphasizes physical properties of the environment to create an immersive experience.

This paper proposes a robot-based game using self-efficacy theory for increase the motivation on sports game. The rest of this paper is organized as follows. Section II explains the related works and previous research results. Section III explains the detection algorithm and the control system on ball robot d. Section IV shows simulation experimental results of the proposed method, and Section V summarizes the paper, and discusses the future works.

## 2 RELATED WORKS

### 2.1 Self-efficacy Theory

Self-efficacy is a psychology theory which given by Albert Bandura [3,4]. hypothesized that expectations of personal efficacy determine whether coping behavior will be initiated, how much effort will be expended, and how long it will be sustained in the face of obstacles and aversive experiences. Persistence in activities that are subjectively threatening but in fact relatively safe produces, through experiences of mastery, further enhancement of self-efficacy and corresponding reductions in defensive behavior. In the proposed model, expectations of personal efficacy are derived from four principal sources of information: performance accomplishments, vicarious experience, verbal persuasion, and physiological states. The more dependable the experiential sources, the greater are the changes in perceived self-efficacy.

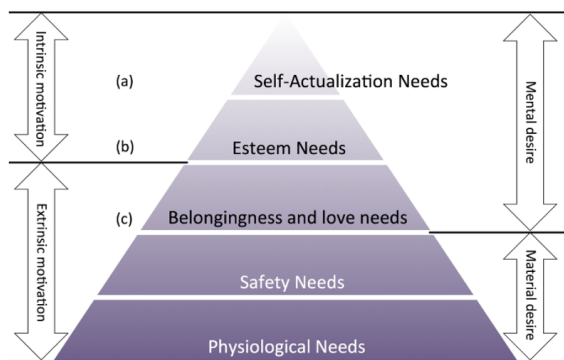


Fig. 2: Five Stage Model of Needs

This five-stage model can be divided into basic (or deficiency) needs (e.g. physiological, safety, love, and esteem) and growth needs (self-actualization) [7].

The deficiency, or basic needs are said to motivate people when they are unmet. Also, the need to fulfil such needs will become stronger the longer the duration they are denied. For example, the longer a person goes without food the hungrier they will become. One must satisfy lower level basic needs before progressing on to meet higher level growth needs. Once these needs have been reasonably satisfied, one may be able to reach the highest level called self-actualization.

Every person is capable and has the desire to move up the hierarchy toward a level of self-actualization. Unfortunately, progress is often disrupted by failure to meet lower level needs. Life experiences including divorce and loss of job may cause an individual to fluctuate between levels of hierarchy. Maslow noted only one in a hundred-people become fully self-actualized because our society rewards motivation primarily based on esteem, love and other social needs.

### 2.2 SPRK for Edutainment

SPRK is a remote-controlled robotic ball, designed by Orbtix. It is capable of moving around in any direction and in various speeds. The SPRK is a differential drive mobile robot enclosed in a spherical case. The dynamics of the SPRK are driven by the nonlinear coupling between the internal mechanism and the outer spherical encasing. In

addition, proprietary underlying controllers govern how the command velocities are interpreted to low-level motors. The proprietary embedded software uses the on-board gyro-accelerometers to balance the robot up-right while rolling. The caster wheels on top of the internal mechanism ensures constant contact of the lower wheels that are driven via two motors. The embedded software interfaces with heading and velocity (or x-y velocity) command inputs sent via Bluetooth communication. A high-fidelity model of the robot would include several internal states characterize the internal mechanism and controller. However, rather than seeking to approximate a high dimensional model, a reduced state model was sought. The mainly using of SPRK is in STEM education (Science, Technology, Engineering and Mathematics) to teach children learning how to programing.

Specifically, the introduction of Sphero SPRK in the Kindergarten classroom is suggested, following the implementation of two additional activities in which children take action with their bodies. [8]. The proposed activities concern teaching the notion of speed in Kindergarten by utilizing the program the robot SPRK. In the first activity, children will realize that the faster competitor in a fixed-distance race is the one who needs the shortest time to reach the finish. Through this activity children are required to solve a problem that animals living in a forest face. Additionally, hand-claps will be used to count time with the help of chronometer. Children will be requested to run individually or in dyads, while the others count their time using hand-claps and all together will collect and write down the data related to the time each child needs to reach the finishing point, on a board. At the end of the activity, children will be requested to compare their collected data and decide which one of the competitors is faster, but also to justify their answer.

### 2.3 Interaction between human and SPRK

Also, the research about interaction between human and SPRK has been done [9]. Digital games for animals within Animal Computer Interaction are usually single-device oriented, however richer interactions could be delivered by considering multimodal environments and expanding the number of technological elements involved. In these playful ecosystems, animals could be either alone or accompanied by human beings, but in both cases the system should react properly to the interactions of all the players, creating more engaging and natural games. Technologically-mediated playful scenarios for animals will therefore require contextual information about the game participants, such as their location or body posture, in order to suitably adapt the system reactions. This paper presents a depth-based tracking system for cats capable of detecting their location, body posture and field of view. The pro-posed system could also be extended to locate and detect human gestures and track small robots, becoming a promising component in the creation of intelligent inter-species playful environments.

In order to control the SPRK robot we need to detect it first. In Pons's research, the Kinect has been using to detect the human and SPRK, k-means clustering has been used to detect the gesture of human and cat. The accuracy of cat's

gesture recognition is about 84%. They are still working on human or other pets.

This research provides a 200cm x 270cm area for tracking the pet and human, but if consider detecting SPRK during the sport, a larger area is needed. Also, in this research, only detection of cat has been considered. If we extent the detection area, the cost of the detection algorithm might be too complex for the real time detection. To obtain these needs, we invented a method that have both extremely high efficient and low cost. We will introduce this method in chapter 3.

### 3 POSITIONING SYSTEM of SPRK

The size of SPRK is too small to be detected in normal ways. Controlling of SPRK robot and make it move towards the right position. The problem is listed as follow: We need to detect the SPRK in complex environment. Also, the positioning algorithm must be low cost for the real time processing. Moreover, a high accuracy is needed.

Our solution is given by this: use retroreflection phenomenon and infrared ray. We noticed that visible light and infrared ray can be classified by camera filter easily, if we can make the SPRK retroreflection infrared ray, the background and SPRK will be classified by extremely low cost.




Fig. 3: Principle of retroreflection

If the distance between infrared camera and the object become closer, the reflected light of infrared rays will also become strong, and there is a possibility of misrecognition. Therefore, it is considered that the optimum detection distance is 1 m to 7 m. The irradiation range that can be grasped with a measurement distance of 2.5 meters is approximately 300cm x 300cm. Reflections occur frequently on a flat surface of glass or the like from the frontal front, so that erroneous recognition is likely to occur.

Angle between the x-axis of camera coordinate and the 0-axis of SPRK movement coordinate. To detect SPRK using both infrared camera and infra-red light. However, since SPRK does not emit infrared rays, the reflection seal is attached to the outside and the infrared ray transmitted from the infrared camera is reflected to make it easy to detect.

For use, objects that can be easily reflected are as follows.

- Floor (depending on material)
- Book covers
- Eyeglasses
- Glass
- Hair decoration (light shiny)

When the background is made of a material that is easy to reflect, there is light that is reflected by the surface other than the reflective tape. For this reason, there are cases where it is erroneously recognized by reflection. Since it cannot be measured if the robot comes out of the infrared irradiation range, it is necessary to measure the irradiation range of the infrared ray and the camera. The image of reflective objects under the infrared camera would show the better result.



Fig. 4: Detection of Robot SPRK

In order to get the best reflective result, we chose several inflective coatings and make the comparison among them. We divided the test into two groups: one group is under the situation of normal camera, whereas another group capture the frames under the infrared camera.

It is also necessary to get the position of SPRK robot from the detected image. We applied SSGA for SPRK detection, and the result shows that it is fast and accurate. The genetic algorithm for SPRK detection shows as follows:

Algorithm 1 Genetic algorithm for SPRK detection

```

INPUT
G = {g1, g2...gN}
θ as the threshold filter
OUTPUT
Gc ⊂ G for the set of candidate targets
K is the number of detected SPRK robot
START
for i ← 2 to t for the maximum iteration time do
  for j ← 1 to N the number of genetic units do
    Calculating the fitness value f(gj) for each genetic gj
    Reproduction the offspring according to the fitness value
    Generate offspring from the crossover of two parents
    Mutate some generated offspring
  end for
end for
for j ← 1 to N the number of genetic units do
  Gc ← {gj} ∪ Gc if f(gj) ≥ θ
end for
K1 = {t1} add K1 to K for initialization
k = 1
for i ← 2 to n do
  find the ti in some cluster Km in K such that dis(ti, km) is the smallest.
  if dis(ti, tm) < θ then
    Km ← Km ∪ {ti}
  else
    k ← k + 1; Kk = {ti}; add Kk to K
  end if
end for
end for

```

## 4 EXPERIMENT

### 4.1 Simulation

It is noticed that SPRK is a ball robot and it can be moved to any direction. As figure 1 shows, the O is start point and T is the goal point. SPRK's location is P(P<sub>x</sub>, P<sub>y</sub>). Movement speed is v, alpha is the angle between the move direction(v) and T axis. What we need is to calculate the acceleration to (a<sub>final</sub>). In this case, the acceleration can be divide into 2 parts by different purpose: the accelerate to control distance between SPRK and axis T (a<sub>d</sub>) and accelerate to control move direction(a<sub>alpha</sub>).






Fig. 5: Coordinate system

It is hard to make balance between  $a_d$  and  $a_\alpha$ . We use fuzzy control to solve this problem the membership function is shown in figure 6.



Fig. 6: Fuzzy membership function of wd.

If then rule:

If the distance is negative-big and alpha is negative-big then accelerate direction will be 30degree.

If the distance is negative-big and alpha is positive-big then accelerate direction will be 20degree.

If the distance is small and alpha is negative-big then accelerate direction will be 5degree.

If the distance is small and alpha is positive-big then accelerate direction will be -5degree.

If the distance is small and alpha is small then accelerate direction will be 0degree.

If the distance is positive-big and alpha is negative-big then accelerate direction will be -20degree.

If the distance is positive-big and alpha is positive-big then accelerate direction will be -30degree.




Fig. 7: Simulation result

The simulation result is shown by Fig.7.

## 5 COLCLUSION

This paper describes the development of a positioning system for robot-based sports game for health promotion, based on the analysis of depth information captured with a Microsoft Kinect® sensor and reflect tape. The IR-based tracking system is capable of detecting a robot SPRK's location.

Our immediate future work will be put the system in actual use. We are also working on improving efficacy of fuzzy control by using GA. After this, we will focus on design the experiment of promote people to do the sport, like how to design the game and how to encourage people to participate in. We will also extent this system into other use like entertainment for young children.

## REFERENCE

- 1) Blair, S. N., Kohl, H. W., Paffenbarger, R. S., Clark, D. G., Cooper, K. H., & Gibbons, L. W. (1989). Physical fitness and all-cause mortality. *Jama*, 262(17), 2395-2401.
- 2) Bouchard, C., Shephard, R. J., Stephens, T., Sutton, J. R., & McPherson, B. D. (1990). Exercise, fitness, and health: the consensus statement. In *Exercise, fitness, and health: a consensus of current knowledge: proceedings of the International Conference on Exercise, fitness and health, May 29-June 3, 1988, Toronto, Canada.* (pp. 3-28). Human Kinetics Publishers.
- 3) Bandura, A. (1986). *Social foundations of thought and action: A social cognitive theory*. Englewood Cliffs, NJ, US: Prentice-Hall, Inc.
- 4) Bandura, A. (2014). *Social cognitive theory of moral thought and action*. In *Handbook of moral behavior and development* (pp. 69-128). Psychology Press.
- 5) Marcus, B. H., Selby, V. C., Niaura, R. S., & Rossi, J. S. (1992). Self-efficacy and the stages of exercise behavior change. *Research quarterly for exercise and sport*, 63(1), 60-66.
- 6) Sphero Robot Ball | Game System for iOS and Android. <http://www.gosphero.com>.
- 7) Maslow, Abraham H. "A theory of human motivation." *Psychological review* 50.4 (1943): 370.
- 8) Ioannou, M., & Bratitsis, T. Utilizing Sphero for a speed related STEM activity in Kindergarten.
- 9) Pons, P., Jaen, J., & Catala, A. (2015, November). Developing a depth-based tracking system for interactive playful environments with animals. In *Proceedings of the 12th International Conference on Advances in Computer Entertainment Technology* (p. 59). ACM.

## 再帰型機械学習を用いた

# 時間-周波数マスクングによる音源分離手法の提案

○吉村俊太 満倉靖恵 浜田望 (慶應義塾大学)

## Blind Source Separation using Time-Frequency Masking and Machine Learning with Recurrent

\* Shunta Yoshimura, Yasue Mitsukura and Nozomu Hamada (Keio University)

**Abstract**— In this paper, we present a blind source separation method for multichannel mixtures of speech sources. A lot of research on blind source separation employ direction of arrival estimation to extract features and time-frequency masking to cluster frequency components because of its simplicity and low computational cost. However, the spatial aliasing problem occurs with closely spaced microphones, leading to the decreased accuracy of direction of arrival estimation. we propose a method using recurrent supervised machine learning to estimate direction of arrival and time-frequency masks. Experiments designed to separate mixtures of two speech signals with 4cm spacing microphone array are conducted under real conditions and results show that the proposed method works better than the existing method.

**Key Words:** Blind Source Separation, Recurrent Neural Network, Time-Frequency Masking.

### 1 はじめに

本研究の目的は、混合音から個別の音声の分離を高精度に行うことである。近年、スマートフォンやスマートスピーカー等の音声認識を用いる電子機器が広く普及し始めている。しかし、複数人が同時に話している状況において特定の話者の音声に対して正しく音声認識を行うことは困難である。また、会議のように複数人が同時に発言する状況において発言を自動的に記録し文字情報化するためには、複数人の指示や発言を同時に認識して個別に処理を行うことが求められる。このような背景により、音声認識の前処理として混合音から特定の話者の音声をリアルタイムに分離する必要がある。以上の条件を満たすためには、マイク数よりも音源数が多い劣決定条件に対応することおよび繰り返し演算等を伴わず計算コストが小さいことの2つの制約を満たさなければならない。

音源分離は以前から様々な手法が研究されており、マイク数より音源数が少ない優決定条件において、独立成分分析やビームフォーミングといった手法によって高い精度で音源分離を行うことが可能である<sup>1)</sup>。一方で劣決定条件においては上記の手法では高い精度で音源分離を行うことが出来ない。劣決定条件に対応した音源分離手法は主に2つのアプローチで研究されてきた。1つ目はモデル化によるアプローチであり、音声信号が混合する過程を数式によってモデル化し、分離音を再度混合した際に元の混合音に近くなるように最尤推定やベイズ推定を行う。2つ目は時間-周波数マスクングであり、混合音のスペクトログラムにおける各時間-周波数 bin をマスクングすることにより、分離音のスペクトログラムを推定する。

モデル化によるアプローチの代表的な手法として非負値行列因子分解(Nonnegative Matrix Factorization, NMF)<sup>2)</sup>がある。NMFはモノラル音楽信号に対する楽器音分離において用いられてきたが、マルチチャンネル信号への拡張<sup>3)</sup>や教師付き機械学習の利用<sup>4)</sup>、到来方向推定手法の利用<sup>5)</sup>等の拡張が提案されており、楽器音ではなく音声に対する適用も盛んに研究されている<sup>4,6)</sup>。しかし、NMFはEMアルゴリズムに代表される繰

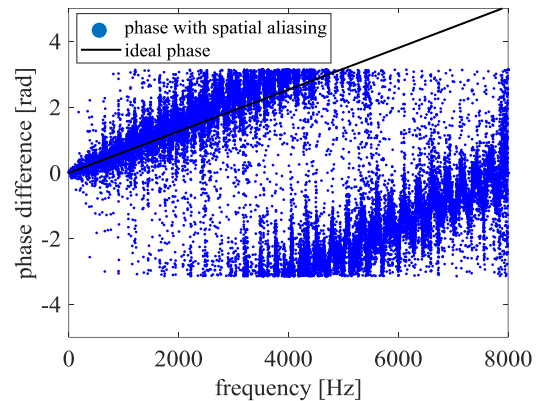


Fig. 1: Spatial Aliasing

り返し演算によって最尤推定を行う手法であることから計算コストが非常に高く、信号長の10倍以上の処理時間が必要である<sup>3)</sup>。このため、音声認識等の信号長と同程度の時間における処理が求められる場合にNMFを適用することは困難であり、計算コストの削減が課題である。NMFの他にモデル化を行う手法として、混合行列を推定し分離を行う手法が提案されており<sup>7)</sup>、劣決定条件において最も分離性能が高い手法の一つであるが<sup>8)</sup>、NMFと同様に計算コストが非常に高いことが欠点である。

時間-周波数マスクングは、混合音のスペクトログラムにおける各時間-周波数 bin に実数値を乗算し、分離音のスペクトログラムを推定する手法である。時間-周波数 bin とは短時間フーリエ変換の各時間、周波数 index の成分を表す。時間-周波数マスクングによる音源分離は大規模な繰り返し演算を行わず、短時間フーリエ変換における区間ごとに高速な処理を行うことが可能であるため、音声認識の前処理として適しており、広く研究されている。一般にスペクトログラムに乗算する実数値を0と1の2値に限定することにより、時間-周波数マスクングを時間-周波数 bin のクラスタリング問題と捉えることで問題の簡略化が行われる。マルチチャンネル音源分離における従来手法では、マイ

ク間の位相差やパワーの差から音源の到来方向推定を行い、その結果をクラスタリングの特徴量としてクラスタリングを行う手法が提案されており<sup>9-13</sup>、近年では Deep Neural Network に代表される教師付き機械学習を用いる手法も盛んに提案されている<sup>14-16</sup>。中でも澤田らによる手法<sup>13</sup>は DOA に関係する特徴量と条件付き確率を用いることにより、現在において最も高い分離性能を達成している手法の一つである<sup>8</sup>。

時間-周波数マスクングによる音源分離手法の問題点として、到来方向推定の精度低下による音源分離の失敗がある。到来方向推定の精度低下の大きな原因として、マイク間距離が小さくサンプリング周波数が大きい場合に、マイク間の位相差から到来方向が一意に決定しない空間エリアシング問題がある。一般に周波数と位相差は線形な関係であるが、空間エリアシングの発生により位相差が丸め込まれ、周波数と位相差は非線形な関係となるため、到来方向推定が困難となる。空間エリアシングの例を Fig. 1 に示す。また、屋内においては壁や天井、床、様々な障害物によって反射した音である反響音の影響が無視できない。反響音の到来方向は様々であり、音源からマイクに直接届く音の到来方向推定は難しい。

本研究では、再帰ニューラルネットワーク(Recurrent Neural Network, RNN)に代表される再帰型教師付き機械学習により高精度な到来方向推定を実現し、高精度に時間-周波数マスクングを行うことを目指す。

## 2 時間-周波数解析

本章では短時間フーリエ変換による時間-周波数領域表現について述べる。

時間-周波数解析とは、時間信号の周波数領域表現における時間変化を解析することである。信号が解析区間全域で非定常である時、信号に含まれる各周波数成分は信号全体で一定ではなく時間変化するため、局所的な周波数成分を得ることが出来る時間-周波数解析が必要である<sup>17</sup>。特に音声は発音によって周波数成分が異なるため、一般に非定常である。以上より、音声信号処理において時間と周波数の2つの軸から信号を解析することが必要である。一般に音源分離において時間-周波数解析として短時間フーリエ変換(Short-Time Fourier Transform, STFT)が用いられる。本研究においても STFT により時間-周波数解析を行う。

離散時間信号 $x(n)$ に対して DFT による周波数スペクトル $X(k)$ は次式により与えられる。

$$X(k) = \sum_{n=0}^{N-1} w(n)x(n)e^{-j\frac{2\pi k}{N}n} \quad (2.1)$$

ここで $k$ は周波数インデックス、 $N$ は解析区間長、 $w(n)$ は窓関数である。窓関数は様々なものが存在するが、本論文では次式で示す hann 窓を用いる。

$$w(n) = 0.5 - 0.5 \cos\left(\frac{2n\pi}{N}\right) \quad (2.2)$$

STFT とは、信号長が長い信号に対して解析区間をずらしながら DFT を行うことで周波数スペクトルの時間変化を求める手法である。解析区間をずらす間隔を $T$ すると、短時間フーリエ変換によるスペクトログラム $X(l, k)$ は次式で与えられる。




Fig. 2: Direction of Arrival

$$X(l, k) = \sum_{n=0}^{N-1} w(n)x(Tl + n)e^{-j\frac{2\pi k}{N}n} \quad (2.3)$$

ここで $l$ は解析区間のインデックスである。音声信号処理においては解析区間をずらす間隔 $T$ を $N/2$ と設定することが多い。これは信号復元が容易であるためである。短時間フーリエ変換の逆変換は次式で与えられる。

$$y(Tl + n) = \frac{1}{N} \sum_{l'=-\infty}^{\infty} w_s(n - T(l' - l)) \sum_{k=0}^{N-1} X(l, k)e^{j\frac{2\pi n}{N}k} \quad (2.4)$$

ここで $w_s$ は合成窓であり本研究では次式に示す合成窓を用いる。

$$w_s(n) = \begin{cases} 1, & \text{if } 0 \leq n \leq N - 1 \\ 0, & \text{else,} \end{cases} \quad (2.5)$$

## 3 時間-周波数マスクング

本章では従来手法で一般的アプローチである到来方向推定を用いて時間-周波数マスクングを行う手法について述べる。まず、3.1 節において、音声信号に対して成り立つ W-Disjoint Orthogonality, WDO 性について述べる。次に 3.2 節において到来方向推定について述べ、3.3 節で時間-周波数マスクングによる分離音生成について述べる。

### 3.1 音の WDO 性

時間-周波数マスクングは時間-周波数領域における音声の WDO 性を前提として行われる。時間-周波数領域において、音声の振幅スペクトルが十分大きな値を持つ時間-周波数 bin は少なく、疎らに存在する。そのため、異なる音源による複数の音声同士が同じ時間-周波数 bin で重なりあうことはほとんどなく、1つの時間-周波数 bin に対し1音源の周波数成分のみが含まれると仮定できる。これを音の WDO 性と呼ぶ<sup>11</sup>。

### 3.2 到来方向推定

音の到来方向(Direction of Arrival, DOA)は各マイクの観測信号を利用して推定することが可能である。Fig. 2 より、2つのマイクに対して方位角 $\theta$ で音が到来する場合を考える。マイク間距離 $d$ および音源と $i$ 番目のマ

イク間の距離 $q_i$ に対し、次式が成り立つ。

$$q_1 - q_2 = d \cos \theta \quad (3.1)$$

反響音の存在を無視した場合、音源から発せられた音声信号 $s(t)$ を $i$ 番目のマイクによって観測した信号 $c_i(t)$ は次式で与えられる<sup>8)</sup>。

$$c_i(t) = \frac{1}{\sqrt{4\pi q_i}} s\left(t - \frac{q_i}{v}\right) \quad (3.2)$$

ここで $v$ は音速である。観測信号 $c_i(t)$ をサンプリング周波数 $f_s$ で離散化した信号 $c_i(n)$ の DFT を $C_i(k)$ とすると、 $C_i(k)$ は(3.3)式で与えられる。

$$\begin{aligned} C_i(k) &= \sum_{n=0}^{N-1} c_i(n) e^{-j\frac{2\pi k}{N}n} \\ &= \frac{|S(k)|}{\sqrt{4\pi q_i}} e^{j(\angle S(k) - \frac{2\pi k}{N} \frac{q_i}{v} f_s)} \end{aligned} \quad (3.3)$$

ここで $S(k)$ は $s(t)$ を離散化した信号 $s(n)$ の DFT である。以上より、 $C_1(k)$ と $C_2(k)$ の位相差 $\Delta\varphi_{12}(k)$ は(3.4)式で与えられる。

$$\Delta\varphi_{12}(k) = \frac{2\pi f_s k}{N} \cdot \frac{d}{v} \cos \theta \quad (3.4)$$

(3.5)式より、マイク間距離 $d$ が既知であれば、位相差 $\Delta\varphi_{12}(k)$ から DOA を推定することが可能である。周波数領域における位相差 $\Delta\varphi_{1i}(k)$ を Interaural Phase Difference, IPD と呼ぶ。音の WDO 性より、1つの時間-周波数 bin に対し1音源の周波数成分のみが含まれると仮定できるため、混合音の STFT から計算した IPD は各時間-周波数 bin ごとに異なる音源の DOA を表していると考えられる。本研究では DOA を推定するために IPD を用いる。

次にマイク本数と DOA 推定の関係について述べる。Fig. 2 より、マイク 2 本を用いて DOA 推定をする場合、IPD を用いることで $\cos \theta$ を求めることが出来る。しかし、方位角 $\theta$ は $-\pi \leq \theta \leq \pi$ の範囲であるため、マイク同士を結んだ直線に対して対称な角度 $-\theta$ を区別することが出来ない。そのため、方位角 $\theta$ を $-\pi \leq \theta \leq \pi$ の範囲で一意に求めるためには少なくともマイク 3 本が必要である。

マイク $M$ 本( $M \geq 3$ )を用いて方位角 $\theta$ を推定する手法<sup>18)</sup>を以下で述べる。まず、マイク 1 を原点とした時の各マイクの位置ベクトルを $\mathbf{r}_i$ と定める。音源の到来方向を表す伝搬ベクトル $\mathbf{a}$ を次式で定める。

$$\mathbf{a} = [\cos \theta, \sin \theta]^T \quad (3.5)$$

マイク 1 とマイク $i$  ( $i = 2, \dots, M$ )に対し、信号の到達時間差 $\tau_i$ は次式で与えられる。

$$\tau_i = -\frac{1}{v} (\mathbf{r}_1 - \mathbf{r}_i)^T \mathbf{a} \quad (3.6)$$

ここで変換行列 $\mathbf{T}$ を(3.7)式で定めると(3.8)式が得られる。

$$\mathbf{T} = [\boldsymbol{\tau}_x, \boldsymbol{\tau}_y] = -\frac{1}{v} \begin{bmatrix} \mathbf{r}_1 - \mathbf{r}_2 \\ \vdots \\ \mathbf{r}_1 - \mathbf{r}_M \end{bmatrix}^T \quad (3.7)$$

$$\boldsymbol{\tau} = [\tau_2, \dots, \tau_M]^T = \mathbf{T} \mathbf{a} \quad (3.8)$$

また、観測位相差は次式で得られる。




Fig. 3: Procedure of proposed method

$$\Delta\boldsymbol{\varphi}(k) = [\Delta\varphi_{12}(k), \dots, \Delta\varphi_{1M}(k)]^T = \frac{2\pi f_s k}{N} \boldsymbol{\tau} \quad (3.9)$$

DOA の推定は観測位相差ベクトル $\Delta\boldsymbol{\varphi}(k)$ から伝搬ベクトル $\mathbf{a}$ を求めることである。そのため、Gram-Schmidt の直交化法により $\boldsymbol{\tau}_x$ および $\boldsymbol{\tau}_y$ から正規直交ベクトル $\mathbf{u}_1, \mathbf{u}_2$ を算出する。まず、(3.10)式により第一成分 $\mathbf{u}_1$ を定める。

$$\mathbf{u}_1 = \frac{\boldsymbol{\tau}_x}{|\boldsymbol{\tau}_x|} \quad (3.10)$$

第二成分 $\mathbf{u}_2$ は次式により、第一成分 $\mathbf{u}_1$ に直交するベクトル $\hat{\mathbf{u}}_2$ から算出される。

$$\hat{\mathbf{u}}_2 = \boldsymbol{\tau}_y - (\mathbf{u}_1 \cdot \boldsymbol{\tau}_y) \mathbf{u}_1 \quad (3.11)$$

$$\mathbf{u}_2 = \frac{\hat{\mathbf{u}}_2}{|\hat{\mathbf{u}}_2|} \quad (3.12)$$

(3.10)~(3.12)式を行列形式でまとめると次式が得られる。

$$\mathbf{U} = \begin{bmatrix} \boldsymbol{\tau}_x & (\mathbf{u}_1 \cdot \boldsymbol{\tau}_y) \\ |\boldsymbol{\tau}_x| & |\hat{\mathbf{u}}_2| |\boldsymbol{\tau}_x| \\ 0 & 1 \\ & |\hat{\mathbf{u}}_2| \end{bmatrix} \quad (3.13)$$

$$[\mathbf{u}_1, \mathbf{u}_2] = [\boldsymbol{\tau}_x, \boldsymbol{\tau}_y] \mathbf{U} = \mathbf{T} \mathbf{U} \quad (3.14)$$

また、係数ベクトル $\mathbf{c}$ を(3.18)式で定めると(3.17)式より(3.19)式の関係が得られる。

$$\mathbf{c} = [c_1, c_2]^T = [\boldsymbol{\tau} \cdot \mathbf{u}_1, \boldsymbol{\tau} \cdot \mathbf{u}_2]^T \quad (3.15)$$

$$\boldsymbol{\tau} = c_1 \mathbf{u}_1 + c_2 \mathbf{u}_2 = \mathbf{T} \mathbf{U} \mathbf{c} \quad (3.16)$$

(3.8)式および(3.16)式を比べることにより、伝搬ベクトル $\mathbf{a}$ を得る。

$$\mathbf{a} = \mathbf{U} \mathbf{c} \quad (3.17)$$

以上より、マイク $M$ 本( $M \geq 3$ )を用いて方位角 $\theta$ を一意に推定することが出来る。

### 3.3 マスキング

時間-周波数マスキングは計算コストが小さく、音源数の制約が存在しないため劣決定条件における音源分離が可能な手法である。時間-周波数マスキングは混合音の STFT による時間-周波数スペクトルを用いて各音源の DOA を算出し、推定 DOA からマスクを作成する。

マイク 1 によって観測した混合音のスペクトログラムを $X_1(l, k)$ とする。時間-周波数マスキングとは、マスク $Z(l, k)$ を用いて分離音のスペクトログラム $Y(l, k)$ を得る手法であり、次式で定められる。



$$Y_j(l, k) = Z_j(l, k)X_1(l, k) \quad (3.18)$$

正確なスペクトログラムを得るためにはマスク  $Z(l, k)$  は複素数でなければならないが、音声においては振幅成分が非常に重要であることから、一般に  $Z(l, k)$  は実数である。

各時間-周波数 bin の DOA を  $\hat{\theta}(l, k)$  とし、それらをまとめることで得られる推定 DOA を  $\theta$  とする。DOA からマスクを作成する場合、 $\hat{\theta}(l, k)$  と  $j$  番目の方位角  $\theta$  が最も近い際にその時間-周波数 bin が  $j$  番目のクラスに属するとして、次式でマスクを定める。

$$Z_j(l, k) = \begin{cases} 1, & \text{if } j = \underset{1 \leq i \leq J}{\operatorname{argmin}}(|\theta_i - \hat{\theta}(l, k)|) \\ 0, & \text{else,} \end{cases} \quad (3.19)$$

3.2 節の DOA 推定と(3.18), (3.19)式を用いた音源分離は一定の精度を持つものの、反響音が大きい場合や空間エリアシングが発生する場合に DOA 推定の精度が低下し、音源分離の精度も低下してしまう。この問題を解決するために、提案手法では教師付き機械学習の 1 つである RNN によって特徴量クラスタリングを行う。

## 4 提案手法

本章では提案手法について述べる。提案手法では 3.2 節における DOA 推定を行った後、RNN による特徴量クラスタリングを行い、時間-周波数マスクを推定する。Fig. 3 に提案手法の流れを示す。4.1 節では提案手法における特徴量抽出について述べる。4.2 節では RNN を用いたクラスタリングについて述べる。4.3 節では得られたスペクトログラムから音声を時間信号として得る方法について述べる。

### 4.1 特徴量抽出

本節では RNN によってクラスタリングを行う際の特徴量を算出する過程について述べる。

まず、3 個のマイクで構成されたマイクロホンアレイによって混合音を得る。各マイクで取得した混合音  $x_i(n)$  を半区間オーバーラップ STFT によってスペクトログラム  $X_i(l, k)$  に変換する。時間信号への復元を行う必要があることから、STFT は半区間オーバーラップで行い、窓関数として(2.2)式で示すハン窓を適用する。

次に各時間-周波数 bin において DOA 推定を行う。まず、マイク 1 とマイク  $i$  間の IPD  $\Delta\phi_{1i}(l, k)$  を次式より得る。ただし、 $-\pi < \Delta\phi_{1i}(l, k) \leq \pi$  とする。

$$\Delta\phi_{1i}(l, k) = \angle \frac{X_i(l, k)}{X_1(l, k)} \quad (4.1)$$

(3.9)式を変形することにより、次式で遅延ベクトル  $\boldsymbol{\tau}(l, k)$  を得る。

$$\boldsymbol{\tau}(l, k) = \frac{N}{2\pi f_s k} \Delta\boldsymbol{\phi}(l, k) \quad (4.2)$$

ただし、 $\Delta\boldsymbol{\phi}(l, k) = [\Delta\phi_{12}(l, k), \Delta\phi_{13}(l, k)]^T$  である。その後、(3.7)式によってベクトル  $\boldsymbol{\tau}_x$  および  $\boldsymbol{\tau}_y$  を算出し、(3.10)–(3.13)式によって変換行列  $\mathbf{U}$  を算出する。最後に(3.15)式より係数ベクトル  $\mathbf{c}(l, k)$  を算出し、(3.17)式によって伝搬ベクトル  $\mathbf{a}(l, k)$  を得る。

得られた伝搬ベクトル  $\mathbf{a}(l, k)$  は各時間-周波数 bin に




Fig. 4: Recurrent Neural Network for proposed method

おける振幅を考慮していない。よって、実際に音源からの音声が存在する場合とノイズのみが存在する場合を区別していないため、クラスタリングの際に信頼性の低い特徴量が混入してしまう可能性がある。そのため、振幅によるノイズ判定を行った。まず、マイク 1 の振幅スペクトログラム  $|X_1(l, k)|$  の時間平均  $X_{mean}(k)$  を次式で得る。

$$X_{mean}(k) = \frac{1}{L} \sum_{l=0}^{L-1} |X_1(l, k)| \quad (4.3)$$

各時間-周波数 bin に対し、振幅スペクトログラム  $|X_1(l, k)|$  とその時間平均  $X_{mean}(k)$  の比が閾値  $\varepsilon$  以下である場合にノイズと判定し、伝搬ベクトルの成分をそれぞれ 0 とする。閾値  $\varepsilon$  は経験的に求め、 $-5.0$  dB とした。

$$\mathbf{a}(l, k) \leftarrow \begin{cases} \mathbf{a}(l, k), & \text{if } 10\log_{10} \frac{|X_1(l, k)|}{X_{mean}(k)} \geq \varepsilon \\ [0, 0]^T, & \text{else,} \end{cases} \quad (4.4)$$

直流成分である 0 番目の周波数 bin を除く全ての伝搬ベクトル  $\mathbf{a}(l, k)$  を時間フレーム  $l$  ごとにまとめ、特徴量ベクトル  $\mathbf{p}(l)$  を算出する。

$$\mathbf{p}(l) = [\mathbf{a}(l, 1)^T, \dots, \mathbf{a}(l, K)^T]^T \quad (4.5)$$

ここで  $K$  は最大周波数インデックスであり、 $N/2$  に等しい。伝搬ベクトル  $\mathbf{a}(l, k)$  は 2 次元であり、特徴量ベクトル  $\mathbf{p}(l)$  の次元は  $N$  である。

### 4.2 クラスタリング

本節では RNN を用いた特徴量クラスタリングについて述べる。提案手法で用いる RNN の構造を Fig. 4 に示す。Fig. 4 の黒線は全結合、赤線は再帰結合を表す。

特徴量クラスタリングは、まず過去と現在の特徴量ベクトルを入力として RNN に与え、音源数分の時間-周波数マスク  $\mathbf{z}(l)$  を得る。次に、時間-周波数マスク  $\mathbf{z}(l)$  をバイナリマスク  $\mathbf{z}'(l)$  へ変換する。

RNN の層構造は、中間層を 3 層として 1 層目で再帰処理を行う全 5 層の全結合ニューラルネットワークとした。各層のユニットの数は 4096 個に設定した。活性化関数は出力層において sigmoid 関数を設定し、その他の層では Rectified Linear Unit, ReLU 関数を設定した。ReLU 関数は次式で与えられる。

$$f_{ReLU}(x) = \begin{cases} x, & \text{if } x \geq 0 \\ 0, & \text{else,} \end{cases} \quad (4.6)$$

再帰処理を行う回数は実験的に求め、4 回に設定し




Fig. 5: Microphone array used in experiments

Table 1: Experiment's setting

Mic	height [m]	1.2
	position	equilateral triangle
	distance [cm]	4.0
Subject	number	3 males
	distance from mic [m]	1.5

た. 入力に与える特徴量ベクトル $\mathbf{p}(l)$ の数は時刻 $l-4$ から $l$ までの5個であり、これはサンプリング周波数16 kHzの信号に対して2048点のSTFTを適用した際、約0.38秒分の音声から得られる特徴量である.

出力は時刻 $l$ における音源数 $J$ 個分のソフトマスク $\mathbf{z}(l)$ である. 出力層の活性化関数はsigmoid関数であるため、出力 $\mathbf{z}(l)$ の各要素は $[0,1]$ の連続値を取る. よって次式によってバイナリマスク $\mathbf{z}'(l)$ への変換を行う.

$$z'(l, k) = \begin{cases} 1, & \text{if } z(l, k) \geq 0.5 \\ 0, & \text{else,} \end{cases} \quad (4.7)$$

ただし、 $z(l, k)$ は時刻 $l$ における出力 $\mathbf{z}(l)$ の $k$ 番目の要素である.

各音源の振幅スペクトログラムを $|S_j(l, k)|$ と表す時、学習における正解データとなるバイナリマスク $t_j(l, k)$ は(4.8)および(4.9)式により作成する.

$$t'_j(l, k) = \begin{cases} 1, & \text{if } j = \operatorname{argmax}_j |S_j(l, k)| \\ 0, & \text{else,} \end{cases} \quad (4.8)$$

$$t_j(l, k) = \begin{cases} t'_j(l, k), & \text{if } 10 \log_{10} \frac{|X_1(l, k)|}{X_{\text{mean}}(k)} \geq \varepsilon \\ 0, & \text{else,} \end{cases} \quad (4.9)$$

(4.8)式は各音源の振幅スペクトルの比較によるバイナリマスク作成であり、(4.9)式は(4.4)式と同様のノイズ判定である.

学習において用いたコスト関数 $E$ を次式で示す.

$$E = \frac{1}{JKL} \sum_{j,k,l} |z_j(l, k) - t_j(l, k)|^2 + \beta \left( 1 - \frac{\sum_{j,k,l} z_j(l, k) t_j(l, k)}{\sum_{j,k,l} t_j(l, k)} \right) \quad (4.10)$$

(4.10)式の第1項は平均2乗誤差を表し、第2項は出力の再現率 $r$ に基づく値である. ただし $\beta$ はハイパーパラメータであり、非負の実数である. 音声のスペクト




Fig. 6: Position of sound sources in evaluation

Table 2: Patterns of subjects and sources

Pattern	(s1, s2)
A	(m1, m2)
B	(m2, m3)
C	(m3, m1)

ログラムにおいて十分大きな成分を持つ時間-周波数 bin は少なく、多くの成分は0に近い非常に小さい値である. 非常に小さい値を持つ時間-周波数 bin は、(4.4)および(4.9)式によるノイズ判定によってマスクの値を0として扱うため、マスクの成分の多くは0であり1となる時間-周波数 bin は少ない. そのため、学習において出力が全て0となる場合にコスト関数 $E$ の値が十分小さくなり、誤差逆伝播法による最適化に失敗してマスク適用後の分離音声が無音になってしまう可能性が考えられる. よって、教師データの値が1となる時間-周波数 bin においてマスクの値が1となることが最適化において重要であり、教師データの値が1となる場合に推定値が1である割合を表す再現率 $r$ をコスト関数 $E$ に組み込む. 全時刻においてRNNの出力に対する再現率 $r$ は次式で与えられる.

$$r = \frac{\sum_{j,k,l} z'_j(l, k) t_j(l, k)}{\sum_{j,k,l} t_j(l, k)} \quad (4.11)$$

誤差逆伝播法による最適化を行うためには、コスト関数 $E$ が微分可能かつ微分値が0以外となる場合が存在しなければならない. しかし、再現率 $r$ を直接コスト関数 $E$ に組み込んだ場合、(4.7)式より微分値が常に0となるため、誤差逆伝播法による最適化を行うことが出来ない. そのため、RNNの出力 $\mathbf{z}(l)$ をそのまま用いて次式により近似再現率 $r'$ を算出し、コスト関数 $E$ に組み込んだ.

$$r' = \frac{\sum_{j,k,l} z_j(l, k) t_j(l, k)}{\sum_{j,k,l} t_j(l, k)} \quad (4.12)$$

### 4.3 分離音生成

クラスタリングによって得られたバイナリマスク $\mathbf{z}'_i(l)$ を用いて(3.18)式により直流成分を除く周波数 bin のスペクトログラム $Y(l, k)$ を推定する. このスペクトログラム $Y(l, k)$ に対して直流成分を0として付加した後、(2.4)式によって逆STFTを行い、分離音を得る.

## 5 実験および結果

本章では提案手法の有効性を示すために行った実験

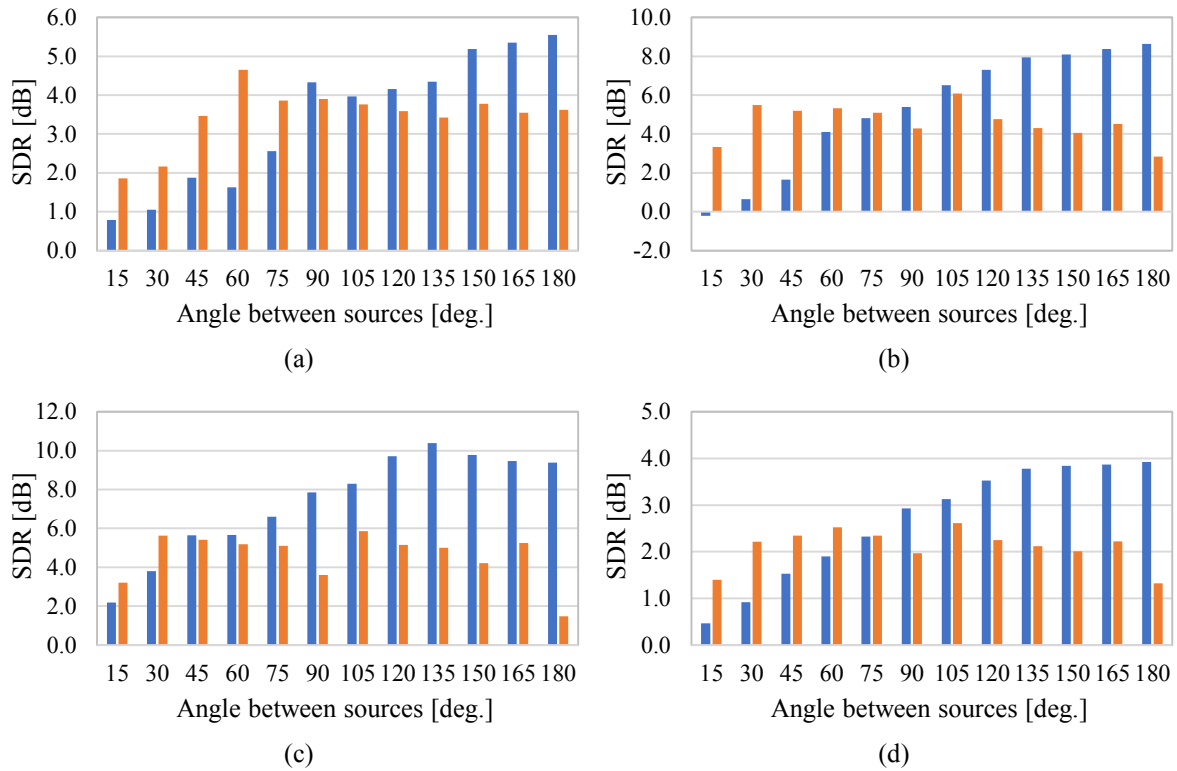


Fig. 8: Experimental results of proposed method(blue) and conventional method(orange) measured in SDR.  
 (a): average of pattern A, (b): average of pattern B, (c): average of pattern C, (d): average of all patterns.

について述べる. 6.1 節において実環境実験の概要および条件について述べる. 6.2 節では実環境実験の結果および考察を示す.

## 5.1 実験

提案手法の有効性を示すため, 実環境における録音音声を用いた 2 音源の音源分離実験を行った. 本実験では音源間角度を 15 度から 180 度の間で 15 度ずつ変化させ, それぞれの音源間角度において分離性能を評価した. 一般に音源間角度が小さい程到来方向推定が困難となり分離結果も悪化する. 実験を行うにあたり, 各音源の音声を個別に録音して正解データを作成し, それらをプログラムで合成することにより混合音を作成した. 実験に使用したマイクロホンアレイを Fig. 5 に示す. このマイクロホンアレイは 4 個のマイクで構成されるが, 実験では①~③で示すマイクのみを使用した.

比較対象は提案手法と到来方向推定を伴う時間-周波数マスクを行う従来手法<sup>9)</sup>とした. 従来手法は混合音の全時間フレームを用いて特徴量を算出し到来方向推定を行う手法であるが, 本実験ではバイナリマスクを推定する際に用いる特徴量の数を揃えるため, 提案手法と同様に過去と現在合わせて 5 フレーム分の特徴量を用いて到来方向を推定し, 各時間フレームに対するバイナリマスクを求めた.

実験の各条件を Table. 1 に示す. また, 2 つの音源を  $s_1, s_2$  としてそれぞれの音源位置を Fig. 6 に示す. 音源  $s_1$  の位置を方位角 0 度に設定し, 左回りを正として  $\pm 180$  度の方位角を設定した. 音源  $s_1$  の位置は固定とした. 音源  $s_2$  の位置は方位角 15 度から 180 度の間において 15 度間隔で設定した. 被験者の組み合わせは 3 通りとし, 被験者  $m_1, m_2, m_3$  と音源  $s_1$  および  $s_2$  の

対応を Table. 2 に示す.

各被験者は各音源位置で日本語の単語を 3 秒間で読み上げ, 5 単語分を録音した. 録音した音声に対し, 単語の被りを除いた 20 通りの混合音を作成した. 音声のサンプリング周波数は 16000 Hz とし, STFT は 2048 点, 半区間オーバーラップで行った.

RNN の学習データは既存の音声データセットとルームインパルスレスポンスによって作成した. 音声データセットは既存研究で多く用いられている TSP Speech Database<sup>19)</sup>を使用した. TSP Speech Database は, 無響室において男女各 12 名の英語話者がそれぞれ 60 個の文章読み上げを行い, その音声を約 15 cm 前に設置されたマイクによって録音したものである. 各被験者が読み上げる文章は Harvard Sentences<sup>20)</sup>から抽出した 720 個の文章を用いている. 欠損データを除いた音声の総数は 1378 個であるが, 本研究では男女各 7 名の音声を 10 個ずつ抽出して使用し, その総数は 140 個である. また, 音声の長さは平均で 2.37 秒であり, 最大で 4.79 秒, 最小で 1.34 秒である. ルームインパルスレスポンスは Matlab “Shoobox” Roomsim<sup>21)</sup>によるシミュレーションデータを用いた. シミュレーションにおけるマイクロホンアレイの位置を Fig. 7 に示す.

音声データセットにおける被験者同士の組み合わせに対し, 音源位置を 24 箇所からランダムに 2 箇所を選択して割り当てた. 各音声に対して該当するルームインパルスレスポンスを積み込んだ後, 加算合成することで混合音を作成した. 作成した混合音の数は 11040 個であり, これらの混合音を学習データセットとして使用した.

学習においてはミニバッチ学習を適用し, バッチサイズは混合音 16 個分とした. 学習回数は 50 回とし, 誤差逆伝播法におけるパラメータの更新には Adam 法



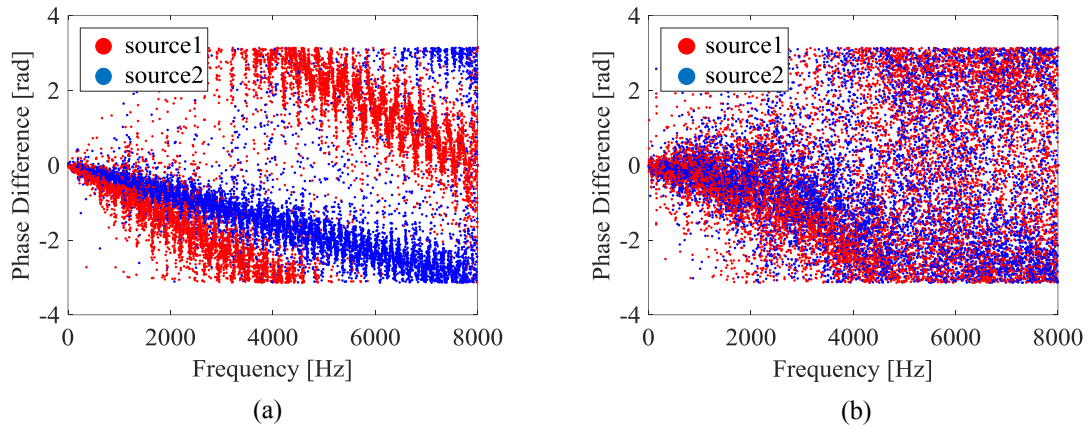


Fig. 9: Phase difference between mic1 and 2. (a): training data, (b): experimental data.

Table 3: Standard deviation of phase difference.

	Training data	Experimental data
Standard deviation [rad]	0.49	1.34

<sup>22)</sup>を用いた.

評価指標は信号対歪み比(Signal to Distortion Ratio, SDR)<sup>23,24)</sup>を用いた. SDR は大きい値ほど分離音の歪みが小さく正解音に近いことを表すため, 分離性能が良いと言える.

## 5.2 結果

従来手法と提案手法における SDR の平均を Fig. 8 に示す.

Fig. 8(a)より, 全パターンでの平均 SDR において, 音源間角度が 90 度以上の場合において提案手法が従来手法を上回った. 音源間角度が 180 度の場合においてその差は最大で 2.6dB となり, これは従来手法の SDR の 197%であった. 一方で, 音源間角度が 90 度未満では提案手法が従来手法を下回った. 音源間角度が 30 度の場合においてその差は最大で 1.3dB となり, これは従来手法の 59%であった.

Fig. 8(a)-(c)より, 被験者の組み合わせによって SDR が大きく変化することがわかった. 特に被験者 m3, m1 の組み合わせにおける平均 SDR は他の被験者の組み合わせと比べて大きく, 音源間角度が 135 度の場合において最大値 10.4dB を達成し, 音源間角度が 45 度以上の場合に提案手法の平均 SDR が従来手法を上回った. また, 被験者 m1, m2 および m2, m3 の組み合わせにおいても, 音源間角度が 90 度以上の場合に提案手法の平均 SDR が従来手法を上回った.

## 5.3 考察

Fig. 8(d)より, 音源間角度が 90 度以上の場合に提案手法の SDR が従来手法を上回った点について, 従来手法では提案手法と同じ 5 フレーム分の特徴量のみを用いた DOA 推定が不安定であったことが原因であると考えられる. 従来手法では DOA 推定の結果をクラスタリング重心として時間-周波数 bin のクラスタリングを行うため, DOA 推定が不安定であった場合, 分離音の推定精度が大きく低下してしまう.

一方で音源間角度が 75 度以下の場合に提案手法の

SDR が従来手法を下回った点について, 提案手法において RNN の学習に用いた音声と実環境下における実験で得られた音声の違いが原因であると考えられる. 実環境下における実験で得られた音声は観測位相差の分散が大きいため, 音源間角度が小さくなるほど各音源由来の観測位相差の重なりが大きくなってしまい, クラスタリングが困難となることが考えられる.

提案手法において RNN の学習に用いた音声と実環境下における実験によって得られた音声のうち, 音源間角度 30 度の音声におけるマイク 1, 2 の位相差の例を Fig. 9 に示す. 学習に用いた音声は位相差の分散が小さく, 各音源の位相差の重なりが小さい. しかし, 実験によって得られた音声は位相差の分散が大きく, 各音源の位相差が大きく重なってしまっていることが分かる. 実際に音源位置が 150 度の 1 音源に対するマイク 1, 2 の位相差の標準偏差を求めた結果を Table 3 に示す. 実験によって得られた音声は学習に用いた音声に比べて標準偏差が 2.7 倍となっている. このことから, 学習に用いた音声と実環境下における実験によって得られた音声の位相差の分布に大きな差があったことが分かる. 以上より, RNN の学習の効果が実験においてクラスタリングに反映されなかったことが音源間角度 75 度以下の状態で提案手法の平均 SDR が低くなった原因であると考えられる.

## 6 おわりに

本研究の目的は混合音から個別の音声の分離を高精度に行うことであった. この目的を達成するため, RNN を用いた高精度な時間-周波数マスキングによる音源分離手法を提案した.

時間-周波数マスキングを用いた従来手法では, マイク間の位相差を用いて時間-周波数 bin ごとに DOA 推定を行った後, 時間-周波数 bin のクラスタリングを行うが, 位相差から DOA を一意に決定できない空間エリアシング問題による DOA 推定の精度低下が問題であった. そこで, 提案手法では教師付き機械学習の 1 つである RNN を用いて高精度な DOA 推定とクラスタリングを行うことで, 高精度な時間-周波数マスキングによる音源分離手法を提案した.

提案手法の精度を明らかにするために実環境下における 2 音源分離実験を行い, 従来手法と提案手法に対して平均 SDR による分離性能評価を行った. その結果, 音源間角度が 90 度以上の場合に提案手法の平均



SDR が従来手法を上回り、最大で 197%向上した。また、音源間角度が 90 度未満の場合では、提案手法の平均 SDR が従来手法を 59%下回った。しかし、音源間角度が 90 度未満の場合でも、被験者の組み合わせにより提案手法の平均 SDR が従来手法を上回る場合が存在した。以上より、高精度な時間-周波数マスクングを実現できたことを確認した。

今後の課題としては、音源間角度が小さい場合の分離性能の向上と音源数の増加による劣決定条件への対応が考えられる。今後はこれらの課題に取り組み、さらに高精度な音源分離手法の構築を目指す。

## 謝辞

本研究は JSPS 科研費基盤研究(S)YYK7S01 の助成を受けたものです。

## 参考文献

- 1) F. Asano, S. Ikeda, M. Ogawa, H. Asoh and N. Kitawaki : Combined Approach of Array Processing and Independent Component Analysis for Blind Separation of Acoustic Signals, *IEEE Transactions on Speech and Audio Processing*, 11-3, 204/215 (2003)
- 2) D. Seung and L. Lee : Algorithms for Non-Negative Matrix Factorization, *Advances in Neural Information Processing Systems*, 13, 556/562 (2001)
- 3) H. Sawada, H. Kameoka, S. Araki and N. Ueda : Multichannel Extensions of Non-Negative Matrix Factorization with Complex-Valued Data, *IEEE Transactions on Audio, Speech and Language Processing*, 21-5, 971/982 (2013)
- 4) T. Virtanen, J. F. Gemmeke and B. Raj : Active-Set Newton Algorithm for Overcomplete Non-Negative Representations of Audio, *IEEE Transactions on Audio, Speech and Language Processing*, 21-11, 2277/2289 (2013)
- 5) J. Nikunen and T. Virtanen : Direction of Arrival Based Spatial Covariance Model for Blind Sound Source Separation, *IEEE/ACM Transactions on Audio, Speech and Language Processing*, 22-3, 727/739 (2014)
- 6) A. Ozerov and C. Fevotte : Multichannel Nonnegative Matrix Factorization in Convolutional Mixtures for Audio Source Separation, *IEEE Transactions on Audio, Speech and Language Processing*, 18-3, 550/563 (2010)
- 7) J. Cho and C. D. Yoo : Underdetermined Convolutional BSS: Bayes Risk Minimization Based on a Mixture of Super-Gaussian Posterior Approximation, *IEEE/ACM Transactions on Audio, Speech and Language Processing*, 23-5, 828/839 (2015)
- 8) S. Gannot, E. Vincent, S. Markovich-Golan and A. Ozerov : A Consolidated Perspective on Multimicrophone Speech Enhancement and Source Separation, *IEEE/ACM Transactions on Audio, Speech and Language Processing*, 25-4, 692/730 (2017)
- 9) M. Sekikawa and N. Hamada : Source Separation for Arbitrary Array Configuration in the Presence of Spatial Aliasing, *International Journal of Signal Processing Systems*, 4-1, 32/36 (2016)
- 10) R. Ishida, M. Sekikawa, Y. Mitsukura and N. Hamada : Mean Shift Based Direction Finding and Separation of Multiple Sources Using Microphone Array in the Presence of Spatial Aliasing, 2015 10th Asian Control Conference (ASCC), 1/4 (2015)
- 11) O. Yilmaz and S. Rickard : Blind Separation of Speech Mixtures via Time-Frequency Masking, *IEEE Transactions on Signal Processing*, 52-7, 1830/1847 (2004)
- 12) N. Roman, D. Wang and G. J. Brown : Speech segregation based on sound localization, *The Journal of the Acoustical Society of America*, 114-4, 2236/2252 (2013)
- 13) H. Sawada, S. Araki and S. Makino : Underdetermined Convolutional Blind Source Separation via Frequency Bin-Wise Clustering and Permutation Alignment, *IEEE Transactions on Audio, Speech and Language Processing*, 19-3, 516/527 (2011)
- 14) Y. Jiang, D. Wang, R. Liu and Z. Feng : Binaural Classification for Reverberant Speech Segregation Using Deep Neural Networks, *IEEE/ACM Transactions on Audio, Speech and Language Processing*, 22-12, 2112/2121 (2014)
- 15) Y. Yu, W. Wang, J. Luo and P. Feng : Localization Based Stereo Speech Separation Using Deep Networks, 2015 IEEE International Conference on Digital Signal Processing (DSP), 153/157 (2015)
- 16) Y. Wang, A. Narayanan and D. Wang : On Training Targets for Supervised Speech Separation, *IEEE/ACM Transactions on Audio, Speech and Language Processing*, 22-12, 1849/1858 (2014)
- 17) 和田 成夫 : よくわかる信号処理 フーリエ変換からウェーブレット変換まで, 森北出版 (2009)
- 18) K. Fujimoto, N. Ding and N. Hamada : Multiple Sources' Direction Finding by Using Reliable Component on Phase Difference Manifold and Kernel Density Estimator, 2012 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), 2601/2604 (2012)
- 19) P. Kabal : TSP speech database, McGill Univ., (2002) [online] Available: <http://www-mmsp.ece.mcgill.ca/Documents/Data/> [2017/11/24 アクセス]
- 20) IEEE Subcommittee on Subjective Measurements : IEEE Recommended Practice for Speech Quality Measurements, *IEEE Transactions on Audio and Electroacoustics*, 17-3, 225/246 (1969)
- 21) D. R. Campbell, K. J. Palomäki and G. J. Brown : A Matlab Simulation of "Shoebox" Room Acoustics for Use in Research and Teaching, *Computing and Information Systems Journal*, 9-3 (2005)
- 22) D. P. Kingma and J. Ba : Adam: A Method for Stochastic Optimization, the 3rd International Conference for Learning Representations, (2015)
- 23) E. Vincent, R. Gribonval and C. Fevotte : Performance measurement in blind audio source separation, *IEEE Transactions on Audio, Speech and Language Processing*, 14-4, 1462/1469 (2006)
- 24) V. Emiya, E. Vincent, N. Harlander and V. Hohmann : Subjective and Objective Quality Assessment of Audio Source Separation, *IEEE Transactions on Audio, Speech and Language Processing*, 19-7, 2046/2057 (2011)

# 遺伝子ネットワークにおける周期発現パターン遷移列の 周期感度の解析法

森禎弘 ○黒江康明 (京都工芸繊維大学)

## Analysis method of Period Sensitivity for cyclic expression pattern sequences in gene regulatory networks

Y. Mori and \*Y. Kuroe (Kyoto Institute of Technology)

**Abstract**— Sensitivity analysis is fundamental and essential in analysis and design in any system. This paper proposes a method of sensitivity analysis for rhythmic phenomena in gene regulatory networks. We model gene regulatory networks by using piece-wise linear differential equation model and periodic phenomena are expressed by using periodic orbits and corresponding expression pattern sequences. Sensitivity analysis of rhythmic phenomena is very difficult because rhythms appear autonomously as periodic phenomena in nonlinear systems and only few studies have been done. In general, sensitivities of period and phase are calculated by using numerical methods approximately. In this paper, we show that sensitivity of period of gene regulatory networks can be derived analytically.

**Key Words:** Gene regulatory network, Period sensitivity, Piece-Wise Linear differential equation model

### 1 はじめに

生体内では歩行運動や呼吸, 心臓の鼓動などさまざまなリズム現象が見られる. またサーカディアン・リズムとよばれる1日を周期とするリズム現象も存在する. これらのリズム現象は, 生体内の特定のニューラルネットワークあるいは遺伝子ネットワーク (GRN) が司っていることが知られており, これらの現象の生理的および数理的な解明が盛んに行われてきた.

GRNは生体内の周期現象など様々な現象を司っていると考えられており, GRNを対象とした研究が様々な観点から盛んに行われている. その一つに, GRNのどの遺伝子が発現しているかを表す発現パターンと, 発現パターンの変化を表す発現パターン遷移列 (EPS) に着目した研究がある<sup>1, 2, 3, 4</sup>. それらでは, ブーリアンネットワークや区分的線形微分方程式モデルを用いて解析や設計が行われている. 区分的線形微分方程式モデルは, 遺伝子間の相互作用が遺伝子の発現・非発現によって定まるため, ブーリアンネットワークモデルのような論理関数を用いたモデルと化学反応式に基づく詳細な非線形微分方程式モデルの中間的なモデルと考えられる. そのため, 他の微分方程式のモデルに比べて扱いが簡単で, かつブーリアンネットワークに対して得られている理論的な結果をより容易に利用できると期待できる. また, GRNの解析や設計において, たとえば周期動作の場合の周期のように, 時間や発現量の情報が重要な場合がある. 区分的線形微分方程式モデルを用いると, ブーリアンネットワークでは扱えない時間や発現量などの情報も扱うことができる.

システムのパラメータが微小変動したとき, システムの振る舞い, 特性や性能がどのように変化するかを調べることで, すなわちパラメータ感度の解析は, システムの解析, 設計におけるさまざまな場面で必要となり, GRNを含むあらゆるシステムにとって非常に重要な問題である. システムの振る舞い, 特性や性能のパラメータに関する感度は, 通常, それらのパラメータ

に関する微分として定義される.

システムの感度解析の研究は古くからなされ, これまで多くの研究がある. ところがリズム現象, すなわち周期現象に関する感度解析の研究はそれほど多くない. その理由は, システムの周期解は一般に初期状態には依存しない非線形現象の定常状態として自律的に決まり, そのパラメータの依存性の表現を得ることが困難であるためである. 周期現象の感度に関してこれまでいくつかの研究があるが<sup>5, 6, 7</sup>, 近似的な扱いが含まれる, その具体的な計算法が示されていない, 計算効率が考慮されていないというような問題がある. 筆者らは既にリズム現象の感度解析として, その現象の特徴的な量である周期と位相に対する感度解析法を提案している<sup>8</sup>. その提案法では, 解軌道が滑らかであるようなシステムの周期現象に対して周期と位相の感度に関する数学的に厳密な表現を導出し, 感度方程式あるいは随伴方程式を解くことで効率よく感度を求めるアルゴリズムを示している.

本稿では, GRNのモデルとして区分的線形微分方程式モデルを用い, GRNの周期現象の感度解析法を提案する. 本稿で対象としているGRNの場合, そのダイナミクスが発現パターンに依存して切り替わり, 解軌道が滑らかとはならない. そのため文献8)の方法を適用することができない. そこで, 本稿では文献8)で示されている周期感度に関する表現の導出方法を拡張して, 区分的線形微分方程式モデルに対する表現を導出する. そして, その表現に基づく周期感度の解析法を提案する. 本稿の解析法では, 導出した周期感度の表現において求めるべき量を解析的に導出することができるので, 文献8)の解析法のように感度方程式あるいは随伴方程式を解くことなく, 簡単な計算により周期感度を求めることができる. また, 文献14)では本稿で対象としている区分的線形微分方程式モデルに対して, 周期感度を解析的に求める方法を提案している. そこで, 本稿で示す周期感度の表現から文献14)の解析法が導出できることも示す.

\*同志社大学嘱託研究員, 関西大学客員教授

## 2 遺伝子ネットワークモデルと問題記述

本稿で対象とする GRN のモデルは、次式の微分方程式で表されるモデルである<sup>1)</sup>。

$$\begin{aligned} \frac{d}{dt}x_i(t) &= -d_i x_i(t) + f_i(y_1(t), y_2(t), \dots, y_n(t), \\ &\quad w_{i,1}, w_{i,2}, \dots, w_{i,m_i}), \quad x_i(0) = x_{0,i} \quad (1) \\ y_i(t) &= h(x_i(t)), \quad i = 1, 2, \dots, n \quad (2) \end{aligned}$$

ここで、 $x_i(t)$  は  $i$  番目の遺伝子の発現・非発現が切り替わる値を基準値 0 とした遺伝子  $i$  の発現によって生成される物質の濃度を表し、 $x_{0,i}$  はその初期状態である。 $n$  は遺伝子の数である。 $f_i: \{0, 1\}^n \rightarrow R$  は遺伝子間の相互作用を表す関数、 $w_{i,j}$  は  $f_i$  のパラメータ、 $m_i$  はその個数を表す。 $d_i$  は  $i$  番目の遺伝子の生成物の分解速度に関する正実数パラメータである。 $h$  はしきい値関数で、

$$h(x) := \begin{cases} 0 & \text{if } x < 0 \\ 1 & \text{if } x \geq 0 \end{cases}$$

である。 $y_i(t)$  は遺伝子  $i$  の発現・非発現を表し、値が 1 のとき発現していること、0 のとき発現していないことを表す。

以下ではこのモデルをベクトル形式で次式のように表す。

$$\frac{d}{dt}\mathbf{x}(t) = -\mathbf{D}\mathbf{x}(t) + \mathbf{f}(\mathbf{y}(t), \mathbf{w}), \quad \mathbf{x}(0) = \mathbf{x}_0 \quad (3)$$

$$\mathbf{y}(t) = \mathbf{H}(\mathbf{x}(t)) \quad (4)$$

ここで、 $\mathbf{x}(t) = [x_1(t) \ x_2(t) \ \dots \ x_n(t)]'$ 、 $\mathbf{x}_0 = [x_{0,1} \ x_{0,2} \ \dots \ x_{0,n}]'$ 、 $\mathbf{y}(t) = [y_1(t) \ y_2(t) \ \dots \ y_n(t)]'$ 、 $\mathbf{f} = [f_1 \ f_2 \ \dots \ f_n]'$ 、 $\mathbf{w}' = [w'_1 \ w'_2 \ \dots \ w'_n]$ 、 $\mathbf{w}_i = [w_{i,1} \ w_{i,2} \ \dots \ w_{i,m_i}]$  であり、 $\mathbf{x}'$  はベクトル  $\mathbf{x}$  の転置である。 $\mathbf{D}$  は対角行列で、 $\mathbf{D} = \text{diag}\{d_1, d_2, \dots, d_n\}$  である。 $\mathbf{H}(\mathbf{x})$  は、 $\mathbf{H}(\mathbf{x}) = [h(x_1) \ h(x_2) \ \dots \ h(x_n)]'$  である。 $\mathbf{y}(t)$  は時刻  $t$  における各遺伝子の発現・非発現を表すベクトルで、発現パターンと呼ばれる。

相互作用関数としては、つぎの関数、

$$\begin{aligned} f_i(\mathbf{y}, \mathbf{w}_i) &:= w_{i,1} + \sum_{j=1}^n w_{i,j+1} y_j \\ &\quad + \sum_{j=1}^{n-1} \sum_{k=j+1}^n w_{i,j+k+n+2} y_j y_k \\ &\quad + \dots + w_{i,2^n} y_1 \dots y_n, \quad i = 1, 2, \dots, n \quad (5) \end{aligned}$$

あるいはこれと等価な関数がよく用いられる<sup>13)</sup>。本稿では、これを相互作用関数として用いることにする。式 (5) の相互作用関数において、たとえば  $w_{i,j+1}$  は遺伝子  $j$  の発現による生成物が遺伝子  $i$  の発現プロセスに作用する強度を表し、2 次以上の項の係数、たとえば  $y_j y_k$  の係数は、 $j$  番目と  $k$  番目の遺伝子の発現によって生成される二つのタンパク質間に相互作用が存在し、その結果として  $i$  番目のタンパク質の生成に作用する強度を表す。

状態  $\mathbf{x}(t)$  は、微分方程式 (3), (4) に従って時間発展する。 $\mathbf{x}(t)$  の時間発展において、 $i$  番目の要素  $x_i(t)$  の

符号が変わると  $\mathbf{y}(t)$  の  $i$  番目の要素  $y_i(t)$  の値が変化し、発現パターン  $\mathbf{y}(t)$  があるパターンから別のパターンに変化する。そのため、この発現パターン  $\mathbf{y}(t)$  の一連の時間変化は、GRN の遺伝子の発現・非発現がどのような順で変化していくかということを表している。

本稿では、 $\mathbf{y}$  が変化することを発現パターンが遷移するといひ、 $\mathbf{y}$  がある発現パターン  $\hat{\mathbf{y}}$  から別の発現パターン  $\bar{\mathbf{y}}$  に遷移することを  $\hat{\mathbf{y}} \rightarrow \bar{\mathbf{y}}$  と表記する。また、 $\mathbf{x}(t)$  がある初期状態  $\mathbf{x}(0)$  から微分方程式 (3), (4) に従って時間発展するとき、発現パターンが  $\mathbf{y}^{(0)} \rightarrow \mathbf{y}^{(1)} \rightarrow \mathbf{y}^{(2)} \rightarrow \dots$  と遷移したとする。この発現パターンの遷移の列を EPS と呼び、このとき式 (3), (4) の GRN はこの EPS をもつという。

式 (3), (4) の GRN は、周期解をもつと仮定し、これがリズム現象を実現しているものとする。周期解が存在するとすると、GRN は周期的な EPS をもつ。すなわち、 $p$  を EPS の遷移回数として

$$\mathbf{y}^{*(0)} \rightarrow \mathbf{y}^{*(1)} \rightarrow \dots \rightarrow \mathbf{y}^{*(p)}, \quad \mathbf{y}^{*(0)} = \mathbf{y}^{*(p)} \quad (6)$$

をもつ。パラメータ  $\mathbf{w}$  が微小変動したときの周期軌道の変動は微小である。そのため、本稿ではこの周期的な EPS は、パラメータ  $\mathbf{w}$  が微小変動したとしても変化しないとする。また、 $\phi(t, \mathbf{x}_0, \mathbf{w})$  を、初期条件を  $\mathbf{x}(0) = \mathbf{x}_0$  としたときの、微分方程式 (3), (4) で表されるシステムの時刻  $t$  での解とする。

式 (3), (4) の GRN がもつ周期解の状態空間における軌道を  $\gamma$  とし、この軌道上の一点を  $\mathbf{x}_\gamma$  とする。 $\gamma$  が周期軌道であるということより、任意の点  $\mathbf{x}_\gamma \in \gamma$  に対し、

$$\mathbf{x}_\gamma = \phi(T, \mathbf{x}_\gamma, \mathbf{w})$$

が成立する。ここで、 $T$  は周期解の周期であり、周期  $T$  は GRN のパラメータ  $\mathbf{w}$  に依存して決まる。以下ではパラメータ  $\mathbf{w}$  の要素の一つを  $w_j$  で表し、そのパラメータ  $w_j$  に対する周期の感度を  $\frac{\partial T}{\partial w_j}$  と表す。

本稿では、式 (3), (4) で表される GRN におけるリズム現象、すなわち式 (6) の周期 EPS をもつ式 (3), (4) の GRN の周期軌道  $\gamma$  を対象として、その特徴的な量である周期のパラメータ感度、すなわち  $\frac{\partial T}{\partial w_j}$  を求める方法を提案する。

## 3 周期のパラメータ感度解析法

周期軌道  $\gamma$  の周期に対するパラメータ感度を求めるためには、まず、周期のパラメータに関する依存性の表現を得る必要があるが、その表現を得ることは一般に困難である。文献 8) では、解が滑らかであるシステムに対して周期感度の数学的に厳密な表現を導出し、それに基づいて周期感度を求める方法を提案している。そこで、ここでは文献 8) の考え方に基いて本稿の解が滑らかとはならないシステムに対して周期感度の表現を導出する。そして、それを基にして周期感度を求める方法を提案する。

### 3.1 数学的準備

以下では、本稿で必要となるいくつかの数学的な準備を与える。システムの周期解の定性的な性質や安定性を解析するための重要なツールとしてポアンカレ写像 (Poincaré Map) が知られている<sup>9), 10)</sup>。ポアンカレ写像の基本的な考え方は、連続時間システムの周期軌

道の解析を、それより1次元低い離散時間システムに置き換えて解析することであり、次のように定義される。  
【ポアンカレ写像の定義】

周期解の軌道を  $\gamma$  とする。  $\gamma$  上の一点を  $\mathbf{x}_{\gamma_0}$  とし、この点で  $\gamma$  と横断的に交わる超平面（曲面）  $\Sigma$  を考える。  $U \subset \Sigma$  を点  $\mathbf{x}_{\gamma_0}$  の近傍とする。点  $\mathbf{x} \in U$  に対して

$$\mathbf{P}(\mathbf{x}) = \phi(\mathcal{T}, \mathbf{x}, \mathbf{w}) \quad (7)$$

で定義される写像  $\mathbf{P}: U \rightarrow \Sigma$  をポアンカレ写像とよぶ。ただし  $\mathcal{T}(\mathbf{x})$  は点  $\mathbf{x}$  から出発した解軌道  $\phi(t, \mathbf{x}, \mathbf{w})$  が最初に  $\Sigma$  にもどってくる時刻である。すなわち、  $\mathcal{T}(\mathbf{x}) = \min\{t | \phi(t, \mathbf{x}, \mathbf{w}) \in \Sigma\}$  である。

明らかに、  $\mathbf{x}_{\gamma_0} = \mathbf{P}(\mathbf{x}_{\gamma_0})$ 、  $\mathcal{T}(\mathbf{x}_{\gamma_0}) = T$  が成立し、周期軌道上の点は、ポアンカレ写像の不動点となる。なお、  $\gamma$  と横断的に交わる超平面（曲面）  $\Sigma$  は、ポアンカレ断面と呼ばれる。

周期軌道に対し、上記の様に定義されるポアンカレ写像を導入することにより、周期軌道  $\gamma$  の近傍での解の振る舞いの定性的な性質を調べることができる。

### 3.2 一般のシステムに対する周期感度の解析法

ここでは、文献8)で示されている感度の表現の導出を簡単に説明する。微分方程式で表される非線形自律システムの周期解としてモデル化できるものを対象とする。

$$\frac{d}{dt}\mathbf{x}(t) = \hat{\mathbf{f}}(\mathbf{x}(t), \hat{\mathbf{w}}) \quad (8)$$

ここで、  $\mathbf{x}(t)$  は状態ベクトル、  $\hat{\mathbf{w}}$  はパラメータベクトルであり、それぞれ  $n$  次元ベクトル ( $\mathbf{x} \in \mathbb{R}^n$ )、  $m$  次元ベクトル ( $\mathbf{w} \in \mathbb{R}^m$ ) であるとする。  $\hat{\mathbf{f}}$  は非線形のベクトル関数で ( $\hat{\mathbf{f}}: \mathbb{R}^n \times \mathbb{R}^m \rightarrow \mathbb{R}^n$ )、  $\mathbf{x}$  および  $\hat{\mathbf{w}}$  に関してそれぞれ1階連続微分可能とする。また、  $\hat{\phi}(t, \mathbf{x}_0, \hat{\mathbf{w}})$  を、初期条件を  $\mathbf{x}(0) = \mathbf{x}_0$  としたときの、式(8)で表されるシステムの時刻  $t$  での解とする。すなわち、  $\hat{\phi}(t, \mathbf{x}_0, \hat{\mathbf{w}})$  は次式を満たす。

$$\hat{\phi}(t, \mathbf{x}_0, \hat{\mathbf{w}}) = \mathbf{x}_0 + \int_0^t \hat{\mathbf{f}}(\hat{\phi}(\tau, \mathbf{x}_0, \hat{\mathbf{w}}), \hat{\mathbf{w}}) d\tau$$

式(8)のシステムは、非自明な孤立した周期解、すなわちリミットサイクルを持つと仮定し、これがリズム現象を実現しているものとする。この周期解の状態空間における軌道を  $\hat{\gamma}$  とし、この軌道上の一点を  $\mathbf{x}_{\gamma}$  とする。  $\hat{\gamma}$  が周期軌道であるということより、任意の点  $\mathbf{x}_{\gamma} \in \hat{\gamma}$  に対し、

$$\mathbf{x}_{\gamma} = \hat{\phi}(\hat{T}, \mathbf{x}_{\gamma}, \hat{\mathbf{w}}) \quad (9)$$

が成立する。ここで、  $\hat{T}$  は周期解の周期であり、周期  $\hat{T}$  はシステムのパラメータ  $\hat{\mathbf{w}}$  に依存して決まる。ポアンカレ断面は次式で表されるとする。

$$\hat{\sigma}(\mathbf{x}) = 0 \quad (10)$$

ここで、  $\hat{\sigma}$  は  $\hat{\sigma}: \mathbb{R}^n \rightarrow \mathbb{R}$  なる写像である。対象とする周期軌道  $\hat{\gamma}$  に対し、ポアンカレ断面は適切に設定できるとし、  $\hat{\sigma}(\mathbf{x})$  は既知であるとする。周期軌道とポア

ンカレ断面の交点  $\mathbf{x}_{\gamma_0}$  は式(9)を満たすので、次式が成立する。

$$\mathbf{x}_{\gamma_0} = \hat{\phi}(\hat{T}, \mathbf{x}_{\gamma_0}, \hat{\mathbf{w}}) \quad (11)$$

また  $\mathbf{x}_{\gamma_0}$  は  $\Sigma$  上の点であることから

$$\hat{\sigma}(\mathbf{x}_{\gamma_0}) = 0 \quad (12)$$

が成立する。

ここで、パラメータ  $\hat{\mathbf{w}}$  が  $\Delta\hat{\mathbf{w}}$  だけ変化し  $\hat{\mathbf{w}} + \Delta\hat{\mathbf{w}}$  となったとする。このとき周期軌道  $\hat{\gamma}$  は周期状態を維持したままで、ポアンカレ断面  $\Sigma$  との交点  $\mathbf{x}_{\gamma_0}$  と周期  $\hat{T}$  がそれぞれ  $\mathbf{x}_{\gamma_0} + \Delta\mathbf{x}_{\gamma_0}$  と  $\hat{T} + \Delta\hat{T}$  と変化したとする。すなわち次式が成立するとする。

$$\mathbf{x}_{\gamma_0} + \Delta\mathbf{x}_{\gamma_0} = \hat{\phi}(\hat{T} + \Delta\hat{T}, \mathbf{x}_{\gamma_0} + \Delta\mathbf{x}_{\gamma_0}, \hat{\mathbf{w}} + \Delta\hat{\mathbf{w}}) \quad (13)$$

さらに  $\mathbf{x}_{\gamma_0} + \Delta\mathbf{x}_{\gamma_0}$  は  $\Sigma$  上の点なので式(12)より次式が成立する。

$$\hat{\sigma}(\mathbf{x}_{\gamma_0} + \Delta\mathbf{x}_{\gamma_0}) = 0 \quad (14)$$

ここで、式(13)の右辺をテーラー展開し式(11)を用いることにより

$$\begin{aligned} \Delta\mathbf{x}_{\gamma_0} = & \frac{\partial}{\partial t} \hat{\phi}(\hat{T}, \mathbf{x}_{\gamma_0}, \hat{\mathbf{w}}) \Delta\hat{T} + \frac{\partial}{\partial \mathbf{x}_0} \hat{\phi}(\hat{T}, \mathbf{x}_{\gamma_0}, \hat{\mathbf{w}}) \Delta\mathbf{x}_{\gamma_0} \\ & + \frac{\partial}{\partial \mathbf{w}} \hat{\phi}(\hat{T}, \mathbf{x}_{\gamma_0}, \hat{\mathbf{w}}) \Delta\hat{\mathbf{w}} + O(\Delta^2) \end{aligned} \quad (15)$$

が得られる。ここで  $O(\Delta^2)$  は、  $\Delta$  に関しての2次以上の高次の項を表す。さらに式(14)の左辺をテーラー展開し、式(12)を用いることにより、

$$\frac{\partial}{\partial \mathbf{x}} \hat{\sigma}(\mathbf{x}_{\gamma_0}) \Delta\mathbf{x}_{\gamma_0} + O(\Delta^2) = 0 \quad (16)$$

が得られる。式(15)と式(16)を、  $\Delta\hat{T}$  と  $\Delta\mathbf{x}_{\gamma_0}$  を未知数とした連立方程式と考えると、最終的に式(17)が得られる。

$$\begin{aligned} & \begin{bmatrix} \mathbf{I} - \frac{\partial}{\partial \mathbf{x}_0} \hat{\phi}(\hat{T}, \mathbf{x}_{\gamma_0}, \hat{\mathbf{w}}) & -\frac{\partial}{\partial t} \hat{\phi}(\hat{T}, \mathbf{x}_{\gamma_0}, \hat{\mathbf{w}}) & 0 \\ \frac{\partial}{\partial \mathbf{x}} \hat{\sigma}(\mathbf{x}_{\gamma_0}) & 0 & 0 \end{bmatrix} \begin{bmatrix} \Delta\mathbf{x}_{\gamma_0} \\ \Delta\hat{T} \end{bmatrix} \\ & = \begin{bmatrix} \frac{\partial}{\partial \mathbf{w}} \hat{\phi}(\hat{T}, \mathbf{x}_{\gamma_0}, \hat{\mathbf{w}}) \\ 0 \end{bmatrix} \Delta\hat{\mathbf{w}} + O(\Delta^2) \end{aligned} \quad (17)$$

ここで記述の簡単のため、式(17)の左辺の係数行列を  $\hat{\mathbf{S}}$ 、右辺第1項の係数行列を  $\hat{\mathbf{V}}$  とし式(17)を次のように表す。

$$\hat{\mathbf{S}} \begin{bmatrix} \Delta\mathbf{x}_{\gamma_0} \\ \Delta\hat{T} \end{bmatrix} = \hat{\mathbf{V}} \Delta\hat{\mathbf{w}} + O(\Delta^2) \quad (18)$$

この方程式を解くことにより、次式が得られる。

$$\begin{bmatrix} \Delta\mathbf{x}_{\gamma_0} \\ \Delta\hat{T} \end{bmatrix} = \hat{\mathbf{S}}^{-1} \hat{\mathbf{V}} \Delta\hat{\mathbf{w}} + O(\Delta^2) \quad (19)$$

これより感度が次の様に求まる。

$$\begin{aligned} \frac{\partial x_{\gamma_0 j}}{\partial \hat{w}_i} &= \left\{ \hat{\mathbf{S}}^{-1} \hat{\mathbf{V}} \text{の } j \text{ 行 } i \text{ 列要素} \right\} \\ \frac{\partial \hat{T}}{\partial \hat{w}_i} &= \left\{ \hat{\mathbf{S}}^{-1} \hat{\mathbf{V}} \text{の } (n+1) \text{ 行 } i \text{ 列要素} \right\} \end{aligned}$$

これが周期感度の表現である。文献8)では、この感度表現を基にして感度方程式あるいは随伴方程式を解くことで周期感度を求める方法を提案している。

### 3.3 遺伝子ネットワークの周期感度の解析法

本稿では、ポアンカレ断面を  $S_0$  とし、対象とする周期解  $\gamma$  が  $S_0$  を横切る時刻を初期時刻  $t = 0$  とする。ここで、 $S_r, r = 0, 1, \dots, p-1$  は二つの領域  $\Omega_{\mathbf{y}^{*(r)}}$  と  $\Omega_{\mathbf{y}^{*(r+1)}}$  の境界で

$$S_r := \left\{ \mathbf{x} \mid x_{i_r} = 0, y_i^{*(r)} = h(x_i), \right. \\ \left. i = 1, 2, \dots, i_r - 1, i_r + 1, \dots, n, \right\} \quad (20)$$

である。また、 $i_r$  は  $\mathbf{y}^{*(r)}$  と  $\mathbf{y}^{*(r+1)}$  で異なる要素の添字で、 $y_{i_r}^{*(r)} \neq y_{i_r}^{*(r+1)}, y_i^{*(r)} = y_i^{*(r+1)}, \forall i \neq i_r$  である。また、 $\Omega_{\mathbf{y}}$  は式 (3), (4) の GRN が発現パターン  $\mathbf{y}$  をとる  $\mathbf{x}$  の  $n$  次元実数空間における領域で、次式で定義される。

$$\Omega_{\mathbf{y}} := \{ \mathbf{x} \mid \mathbf{y} = \mathbf{H}(\mathbf{x}) \}$$

しきい値関数  $h$  の定義からわかるように、 $\Omega_{\mathbf{y}}$  は  $n$  次元実数空間の象限の一つとなる。

ポアンカレ断面  $S_0$  上の点  $\mathbf{x}_{\gamma_0}$  から始まる解軌道は周期軌道  $\gamma$  であるので、 $S_1, S_2, \dots, S_{p-1}$  と順に交差して  $S_0$  と  $\mathbf{x}_{\gamma_0}$  で交差する。この周期軌道が  $S_r, r = 1, 2, \dots, p$  と交差する座標を  $\Psi^{(r)}, r = 1, 2, \dots, p$ ,  $S_r$  上の点  $\Psi^{(r)}$  で解軌道が  $S_r$  と交差してからつぎに境界  $S_{r+1}$  と交差するまでにかかる時間を  $T^{(r+1)}$  とする。式 (3), (4) のダイナミクスは発現パターンに依存して切り替わるが、発現パターンが変化しない間のダイナミクスは線形であることを利用すると、 $\Psi^{(r+1)}$  は  $\Psi^{(r)}$ ,  $T^{(r+1)}$  と  $\mathbf{e}(\mathbf{y}^{*(r)})$  に依存し、つぎの関係式が成り立つことがわかる。

$$\Psi^{(r+1)} = \mathbf{g}(\Psi^{(r)}, T^{(r+1)}, \mathbf{e}(\mathbf{y}^{*(r)})), \\ r = 0, 1, \dots, p-1 \quad (21)$$

$$g_i(\mathbf{x}, t, \mathbf{e}) = x_i \exp(-d_i t) + e_i (1 - \exp(-d_i t)) \\ i = 1, 2, \dots, n \quad (22)$$

ただし、 $\Psi^{(0)} := \mathbf{x}_{\gamma_0}$  である。また、 $\mathbf{e}(\mathbf{y})$  は発現パターンに対して次式で定義される  $n$  次元実数空間内の点である。

$$\mathbf{e}(\mathbf{y}) := \left[ \frac{f_1(\mathbf{y}, \mathbf{w})}{d_1}, \frac{f_2(\mathbf{y}, \mathbf{w})}{d_2}, \dots, \frac{f_n(\mathbf{y}, \mathbf{w})}{d_n} \right]' \quad (23)$$

さらに、 $\Psi^{(p)}$  は周期解軌道が  $S_0$  に戻ってきたときの交点なので

$$\Psi^{(0)} = \Psi^{(p)} = \mathbf{g}(\Psi^{(p-1)}, T^{(p)}, \mathbf{e}(\mathbf{y}^{*(p-1)})) \quad (24)$$

$$T = \sum_{r=1}^p T^{(r)} \quad (25)$$

が成り立ち、 $\Psi^{(p)}$  がポアンカレ写像を与えることが分かる。また、 $\Psi^{(r)}$  が  $S_r$  上の点であることから

$$\Psi_{i_r}^{(r+1)} = 0, \quad r = 0, 1, \dots, p-1 \quad (26)$$

が成り立つ。以下では、これらの超平面  $S_r$  を表す条件式の左辺を  $\sigma_r(\mathbf{x}), r = 0, 1, \dots, p-1$  と表記する。たとえば、 $\sigma_0(\mathbf{x}) = x_{i_0}$  である。

今システムのパラメータが  $\mathbf{w}$  から  $\Delta \mathbf{w}$  だけ変動して  $\mathbf{w} + \Delta \mathbf{w}$  となったとし、周期軌道  $\gamma$  は周期状態を維持したままで、 $S_0$  との交点  $\mathbf{x}_{\gamma_0} = \Psi^{(0)}$  と周期  $T$  がそれぞれ  $\mathbf{x}_{\gamma_0} + \Delta \mathbf{x}_{\gamma_0}$  と  $T + \Delta T$  になり、 $S_r$  上の点から始まる解軌道が境界  $S_{r+1}$  と交差するまでにかかる時間  $T^{(r+1)}$  が  $T^{(r+1)} + \Delta T^{(r+1)}$  になったとする。また、 $S_r$  と周期軌道の交点  $\Psi^{(r)}, r = 1, 2, \dots, p-1$  と  $\mathbf{e}(\mathbf{y}^{(r)}), r = 0, 1, \dots, p-1$  がそれぞれ  $\Psi^{(r)} + \Delta \Psi^{(r)}, r = 1, 2, \dots, p-1$  と  $\mathbf{e}(\mathbf{y}^{(r)}) + \Delta \mathbf{e}(\mathbf{y}^{(r)}), r = 0, 1, \dots, p-1$  となったとする。すると、周期状態が維持されていることから次式が成立する。

$$\Psi^{(0)} + \Delta \Psi^{(0)} = \Psi^{(p)} + \Delta \Psi^{(p)} \\ = \mathbf{g}(\Psi^{(p-1)} + \Delta \Psi^{(p-1)}, T^{(p)} + \Delta T^{(p)}, \\ \mathbf{e}(\mathbf{y}^{*(p-1)} + \Delta \mathbf{e}(\mathbf{y}^{*(p-1)}))) \quad (27)$$

$$T + \Delta T = \sum_{r=1}^p \left( T^{(r)} + \Delta T^{(r)} \right) \quad (28)$$

また、式 (21) と  $\Psi^{(r)}, r = 0, 1, \dots, p-1$  がそれぞれ  $S_r, r = 0, 1, \dots, p-1$  上の点であることから次式が成り立つ。

$$\Psi^{(r+1)} + \Delta \Psi^{(r+1)} \\ = \mathbf{g}(\Psi^{(r)} + \Delta \Psi^{(r)}, T^{(r+1)} + \Delta T^{(r+1)}, \\ \mathbf{e}(\mathbf{y}^{*(r)} + \Delta \mathbf{e}(\mathbf{y}^{*(r)}))) \\ r = 0, 1, \dots, p-2 \quad (29)$$

$$\Psi_{i_r}^{(r)} + \Delta \Psi_{i_r}^{(r)} = 0, \quad r = 0, 1, \dots, p-1 \quad (30)$$

式 (27) の右辺をテーラー展開し、式 (24) が成り立つことより

$$\Delta \Psi^{(0)} \\ = \frac{\partial}{\partial \mathbf{x}} \mathbf{g}(\Psi^{(p-1)}, T^{(p)}, \mathbf{e}(\mathbf{y}^{*(p-1)})) \Delta \Psi^{(p-1)} \\ + \frac{\partial}{\partial t} \mathbf{g}(\Psi^{(p-1)}, T^{(p)}, \mathbf{e}(\mathbf{y}^{*(p-1)})) \Delta T^{(p)} \\ + \frac{\partial}{\partial \mathbf{e}} \mathbf{g}(\Psi^{(p-1)}, T^{(p)}, \mathbf{e}(\mathbf{y}^{*(p-1)})) \frac{\partial}{\partial \mathbf{w}} \mathbf{e}(\mathbf{y}^{(p-1)}) \Delta \mathbf{w} \\ + O(\Delta^2) \quad (31)$$

が得られる。同様に、式 (29) の右辺をテーラー展開し、式 (21) を用いることにより

$$\Delta \Psi^{(r+1)} \\ = \frac{\partial}{\partial \mathbf{x}} \mathbf{g}(\Psi^{(r)}, T^{(r+1)}, \mathbf{e}(\mathbf{y}^{*(r)})) \Delta \Psi^{(r)} \\ + \frac{\partial}{\partial t} \mathbf{g}(\Psi^{(r)}, T^{(r+1)}, \mathbf{e}(\mathbf{y}^{*(r)})) \Delta T^{(r+1)} \\ + \frac{\partial}{\partial \mathbf{e}} \mathbf{g}(\Psi^{(r)}, T^{(r+1)}, \mathbf{e}(\mathbf{y}^{*(r)})) \frac{\partial}{\partial \mathbf{w}} \mathbf{e}(\mathbf{y}^{(r)}) \Delta \mathbf{w} \\ + O(\Delta^2) \quad (32)$$

が得られる。さらに、式 (25) と式 (26) に注意すると、式 (28) と式 (30) より

$$\Delta T = \sum_{r=1}^p \Delta T^{(r)} \quad (33)$$

$$\Delta \Psi_{i_r}^{(r)} = 0, \quad r = 0, 1, \dots, p-1 \quad (34)$$

が得られる．式 (31) から式 (34) までを  $\Delta\Psi^{(r)}$ ,  $r = 0, 1, \dots, p-1$ ,  $\Delta T^{(r)}$ ,  $r = 1, 2, \dots, p$  および  $\Delta T$  を未知数とする方程式として連立させると，最終的に次式が得られる．

$$\begin{bmatrix} I - \frac{\partial}{\partial \mathbf{x}} \mathbf{G}(\Psi, T, \mathbf{E}) & -\frac{\partial}{\partial t} \mathbf{G}(\Psi, T, \mathbf{E}) & \mathbf{0} \\ \frac{\partial}{\partial \mathbf{x}} \Sigma(\mathbf{x}) & \mathbf{0} & \mathbf{0} \\ \mathbf{0} & -1 & 1 \end{bmatrix} \begin{bmatrix} \Delta\Psi \\ \Delta T \\ \Delta T \end{bmatrix} = \begin{bmatrix} \frac{\partial}{\partial \mathbf{e}} \mathbf{G}(\Psi, T, \mathbf{E}) \frac{\partial}{\partial \mathbf{w}} \mathbf{E} \\ \mathbf{0} \\ \mathbf{0} \end{bmatrix} \Delta \mathbf{w} + \begin{bmatrix} O(\Delta^2) \\ \mathbf{0} \\ 0 \end{bmatrix} \quad (35)$$

ここで，

$$\begin{aligned} \Psi' &= [\Psi^{(0)'} \quad \Psi^{(1)'} \quad \dots \quad \Psi^{(p-1)'}] \\ T' &= [T^{(1)} \quad T^{(2)} \quad \dots \quad T^{(p)}] \\ E' &= [e(\mathbf{y}^{*(0)})' \quad e(\mathbf{y}^{*(1)})' \quad \dots \quad e(\mathbf{y}^{*(p-1)})'] \end{aligned}$$

$$\begin{aligned} \frac{\partial}{\partial \mathbf{x}} \Sigma(\mathbf{x}) &= \text{diag} \left[ \frac{\partial}{\partial \mathbf{x}} \sigma_0(\mathbf{x}) \quad \frac{\partial}{\partial \mathbf{x}} \sigma_1(\mathbf{x}) \quad \dots \quad \frac{\partial}{\partial \mathbf{x}} \sigma_{p-1}(\mathbf{x}) \right] \end{aligned}$$

で， $I$  は適当なサイズの単位行列， $\mathbf{0}$  は適当なサイズの零行列（零ベクトル）， $\mathbf{1}$  は要素がすべて 1 である適当なサイズのベクトルである．また， $\frac{\partial}{\partial \mathbf{x}} \mathbf{G}(\Psi, T, \mathbf{E})$ ， $\frac{\partial}{\partial t} \mathbf{G}(\Psi, T, \mathbf{E})$  と  $\frac{\partial}{\partial \mathbf{e}} \mathbf{G}(\Psi, T, \mathbf{E})$  は，

$$\begin{aligned} \frac{\partial}{\partial * } \mathbf{G}(\Psi, T, \mathbf{E}) &= \begin{bmatrix} \mathbf{0} & \dots & \dots & \mathbf{0} & \frac{\partial}{\partial * } \mathbf{g}^{(p-1)} \\ \frac{\partial}{\partial * } \mathbf{g}^{(0)} & \mathbf{0} & \dots & \mathbf{0} & \mathbf{0} \\ \mathbf{0} & \frac{\partial}{\partial * } \mathbf{g}^{(1)} & \mathbf{0} & \dots & \mathbf{0} \\ & & \vdots & & \\ \mathbf{0} & \dots & \mathbf{0} & \frac{\partial}{\partial * } \mathbf{g}^{(p-2)} & \mathbf{0} \end{bmatrix} \end{aligned}$$

である．ただし，

$$\mathbf{g}^{(r)} := \mathbf{g}(\Psi^{(r)}, T^{(r+1)}, e(\mathbf{y}^{*(r)}))$$

であり， $*$  は  $\mathbf{x}$ ,  $t$  あるいは  $e$  のいずれかを表す．

ここで記述の簡単のため，式 (35) の左辺の係数行列を  $\mathbf{S}$ ，右辺第 1 項の係数行列を  $\mathbf{V}$  として式 (35) を次のように表す．

$$\mathbf{S} \begin{bmatrix} \Delta\Psi \\ \Delta T \\ \Delta T \end{bmatrix} = \mathbf{V} \Delta \mathbf{w} + \begin{bmatrix} O(\Delta^2) \\ \mathbf{0} \\ 0 \end{bmatrix} \quad (36)$$

この方程式を解くことにより，次式が得られる．

$$\begin{bmatrix} \Delta\Psi \\ \Delta T \\ \Delta T \end{bmatrix} = \mathbf{S}^{-1} \mathbf{V} \Delta \mathbf{w} + \begin{bmatrix} O(\Delta^2) \\ \mathbf{0} \\ 0 \end{bmatrix} \quad (37)$$

これより感度が次の様に求まる．

$$\begin{aligned} \frac{\partial x_{\gamma_0 j}}{\partial w_i} &= \{ \mathbf{S}^{-1} \mathbf{V} \text{ の } j \text{ 行 } i \text{ 列要素} \} \\ \frac{\partial T}{\partial w_i} &= \{ \mathbf{S}^{-1} \mathbf{V} \text{ の } (n * p + p + 1) \text{ 行 } i \text{ 列要素} \} \end{aligned}$$

これが求めるべき感度の表現である．そして，この表現が式 (17) の周期感度の表現の一種の拡張になっていることがわかる．

$\mathbf{g}$ ,  $\sigma_r$ ,  $r = 0, 1, \dots, p-1$  がそれぞれ式 (22), (26) のように与えられているので， $\mathbf{S}$  と  $\mathbf{V}$  の各要素はそれらを微分することによりつぎのように解析的に導くことができる．

$$\frac{\partial}{\partial x_j} g_i = \begin{cases} \exp(-d_i t) & \text{if } i = j \\ 0 & \text{if } i \neq j \end{cases}$$

$$\frac{\partial}{\partial t} g_i = \begin{cases} -d_i(x_i - e_i) \exp(-d_i t) & \text{if } i = j \\ 0 & \text{if } i \neq j \end{cases}$$

$$\frac{\partial}{\partial e_j} g_i = \begin{cases} 1 - \exp(-d_i t) & \text{if } i = j \\ 0 & \text{if } i \neq j \end{cases}$$

$$\frac{\partial}{\partial x_j} \sigma_i(\mathbf{x}) = \begin{cases} 1 & \text{if } i = j \\ 0 & \text{if } i \neq j \end{cases}$$

また， $e(\mathbf{y})$  の定義は式 (23) であるので，これも解析的に導くことができる．たとえば  $f_i$  の  $y_k y_l$  の項の係数を  $w_j$  とすると

$$\frac{\partial}{\partial w_j} e_i(\mathbf{y}) = \frac{1}{d_i} y_k y_l$$

である．よって， $\mathbf{x}_{\gamma_0}$ ,  $\Psi^{(r)}$ ,  $r = 1, 2, \dots, p-1$  および  $T^{(r)}$ ,  $r = 1, 2, \dots, p$  を求めることができれば，行列  $\mathbf{S}$  と  $\mathbf{V}$  の各要素が計算でき，周期感度を求めることができる．これらは，文献 8) と同様にして， $\mathbf{x}_{\gamma_0} = \Psi^{(0)}$ ,  $\Psi^{(r)}$ ,  $T^{(r+1)}$ ,  $r = 1, 2, \dots, p-1$  に関する非線形連立方程式

$$\Psi^{(0)} - \mathbf{g}(\Psi^{(p-1)}, T^{(p)}, e(\mathbf{y}^{*(p-1)})) = 0 \quad (38)$$

$$\begin{aligned} \Psi^{(r+1)} - \mathbf{g}(\Psi^{(r)}, T^{(r+1)}, e(\mathbf{y}^{*(r)})) &= 0 \\ r &= 0, 1, \dots, p-2 \end{aligned} \quad (39)$$

$$\Psi_{i_r}^{(r+1)} = 0, \quad r = 0, 1, \dots, p-1 \quad (40)$$

をニュートン法などを用いて数値的に解くことで求めることができる．以上のように，本稿の解析法では文献 8) の解析法のように感度方程式あるいは随伴方程式を解くことなく，簡単な計算により周期感度を求めることができる．

### 3.4 周期感度の解析的導出法

ここでは，本稿で導出した周期感度の表現から文献 14) で導出している周期感度の解析法を導く．具体的には，文献 14) ではまずポアンカレ断面との交点  $\mathbf{x}_{\gamma_0}$  とパラメータ  $\mathbf{w}$  を用いて周期とポアンカレ写像を表し，それらから周期感度を導いているが，ここでは先に導出した式 (35) の表現を解析的に解くことで文献 14) の補題 1 と定理 1 に示されている結果を導く．

式 (34) を式 (32) の第  $i_r$  番目の式に代入し， $\Delta T^{(r)}$ ,  $r = 1, 2, \dots, p$  について解くと次式が得られる．

$$\begin{aligned} \Delta T^{(r+1)} &= -\frac{1}{\frac{\partial}{\partial t} g_{i_r}^{(r)}} \left( \frac{\partial}{\partial x_{i_r}} g_{i_r}^{(r)} \Delta \Psi_{i_r}^{(r)} \right. \\ &\quad \left. + \frac{\partial}{\partial \mathbf{e}} g_{i_r}^{(r)} \frac{\partial}{\partial \mathbf{w}} e(\mathbf{y}^{*(r)}) \Delta \mathbf{w} \right) + O(\Delta^2) \end{aligned} \quad (41)$$

これを式 (32) に代入して次式を得る.

$$\begin{aligned} \Delta \Psi^{(r+1)} &= \left( \frac{\partial}{\partial \mathbf{x}} \mathbf{g}^{(r)} - \frac{1}{\frac{\partial}{\partial t} g_{i_r}^{(r)}} \frac{\partial}{\partial t} \mathbf{g}^{(r)} \frac{\partial}{\partial \mathbf{x}} g_{i_r}^{(r)} \right) \Delta \Psi^{(r)} \\ &+ \left( \frac{\partial}{\partial \mathbf{e}} \mathbf{g}^{(r)} - \frac{1}{\frac{\partial}{\partial t} g_{i_r}^{(r)}} \frac{\partial}{\partial t} \mathbf{g}^{(r)} \frac{\partial}{\partial \mathbf{e}} g_{i_r}^{(r)} \right) \frac{\partial}{\partial \mathbf{w}} \mathbf{e}(\mathbf{y}^{*(r)}) \Delta \mathbf{w} \\ &+ O(\Delta^2) \end{aligned} \quad (42)$$

文献 14) では,  $\Psi^{(r)}$  と  $\Psi^{(r+1)}$  の関係が

$$\Psi^{(r+1)} = \hat{\mathbf{g}}(\Psi^{(r)}, \mathbf{e}(\mathbf{y}^{*(r)})) \quad (43)$$

$$\begin{aligned} \hat{g}_i^{(r)}(\mathbf{x}, \mathbf{e}) &:= e_i + (x_i - e_i) \left( \frac{e_{i_r}}{e_{i_r} - x_{i_r}} \right)^{\frac{d_i}{d_{i_r}}} \\ i &= 1, 2, \dots, n, \quad r = 0, \dots, p-1 \end{aligned} \quad (44)$$

で与えられることを利用して  $\Delta \Psi^{(r)}$  と  $\Delta \Psi^{(r+1)}$  の関係を次式のように示している.

$$\begin{aligned} \Delta \Psi^{(r+1)} &= \frac{\partial}{\partial \mathbf{x}} \hat{\mathbf{g}}^{(r)} \Delta \Psi^{(r)} + \frac{\partial}{\partial \mathbf{e}} \hat{\mathbf{g}}^{(r)} \frac{\partial}{\partial \mathbf{w}} \mathbf{e}(\mathbf{y}^{*(r)}) \Delta \mathbf{w} \\ &+ O(\Delta^2), \quad r = 0, 1, \dots, p-1 \end{aligned} \quad (45)$$

式 (22) の  $\mathbf{g}$  の定義と式 (44) の  $\hat{\mathbf{g}}^{(r)}$  の定義に注意すると, 式 (42) はこの式と等価であることを示すことができる. よって, 文献 14) と同様にして,  $\Delta \Psi^{(r)}$  を式 (42) に代入することを  $r = 0$  から  $r = p-1$  まで順に行うことで,  $\Delta \Psi^{(0)} = \Delta \Psi^{(p)}$  と式 (42) から構成される差分方程式を  $\Delta \Psi^{(0)}$  について解くことができ, 文献 14) のつぎの補題が得られる.

**補題 1** 式 (3), (4) の GRN が周期軌道を持ち, その周期軌道における EPS が式 (6) の EPS であるとする. このとき, ポアンカレ断面  $S_0$  と周期解軌道の交点  $\mathbf{x}_{\gamma_0}$  の感度は次式で得られる.

$$\frac{\partial \mathbf{x}_{\gamma_0}}{\partial w_j} = \left( \mathbf{I} - \mathbf{A}^{(p)} \right)^{-1} \mathbf{B}^{(p)} \quad (46)$$

ここで,

$$\begin{aligned} \mathbf{A}^{(r+1)} &= \prod_{k=0}^r \frac{\partial}{\partial \mathbf{x}} \hat{\mathbf{g}}^{(k+1)} \\ \mathbf{B}^{(r+1)} &= \prod_{k=1}^r \frac{\partial}{\partial \mathbf{x}} \hat{\mathbf{g}}^{(k+1)} \frac{\partial}{\partial \mathbf{e}} \hat{\mathbf{g}}^{(1)} \frac{\partial}{\partial w_j} \mathbf{e}(\mathbf{y}^{*(0)}) \\ &+ \prod_{k=2}^r \frac{\partial}{\partial \mathbf{x}} \hat{\mathbf{g}}^{(k+1)} \frac{\partial}{\partial \mathbf{e}} \hat{\mathbf{g}}^{(2)} \frac{\partial}{\partial w_j} \mathbf{e}(\mathbf{y}^{*(1)}) + \dots \\ &+ \frac{\partial}{\partial \mathbf{x}} \hat{\mathbf{g}}^{(r+1)} \frac{\partial}{\partial \mathbf{e}} \hat{\mathbf{g}}^{(r)} \frac{\partial}{\partial w_j} \mathbf{e}(\mathbf{y}^{*(r-1)}) \\ &+ \frac{\partial}{\partial \mathbf{e}} \hat{\mathbf{g}}^{(r+1)} \frac{\partial}{\partial w_j} \mathbf{e}(\mathbf{y}^{*(r)}) \end{aligned} \quad (48)$$

である.

さらに, 関数  $u^{(r)}(\mathbf{x}, \mathbf{e})$ ,  $r = 1, 2, \dots, p$  を

$$u^{(r)}(\mathbf{x}, \mathbf{e}) := -\frac{1}{d_i} \log_e \left( \frac{e_{i_r}}{e_{i_r} - x_{i_r}} \right) \quad (49)$$

と定義すると, 式 (41) が次式と等価であることを示すことができる.

$$\begin{aligned} \Delta T^{(r+1)} &= \frac{\partial}{\partial \mathbf{x}} u^{(r)}(\Psi^{(r)}, \mathbf{e}(\mathbf{y}^{*(r)})) \Delta \Psi^{(r)} \\ &+ \frac{\partial}{\partial \mathbf{e}} u^{(r)}(\Psi^{(r)}, \mathbf{e}(\mathbf{y}^{*(r)})) \Delta \mathbf{e}(\mathbf{y}^{*(r)}) \\ &+ O(\Delta^2) \end{aligned} \quad (50)$$

この式と式 (32), (33) より  $\Delta T$  を  $\mathbf{x}_{\gamma_0}$  と  $\Delta \mathbf{w}$  を用いて表すことで文献 14) のつぎの定理が導かれる.

**定理 1** 式 (3), (4) の GRN が周期軌道を持ち, その周期軌道における EPS が式 (6) の EPS であるとする. このとき, 周期の感度は次式で得られる.

$$\begin{aligned} \frac{\partial T}{\partial w_j} &= \sum_{r=0}^{p-1} \frac{\partial}{\partial \mathbf{x}} u^{(r+1)} \mathbf{A}^{(r)} \left( \mathbf{I} - \mathbf{A}^{(p)} \right)^{-1} \mathbf{B}^{(p)} \\ &+ \sum_{r=0}^{p-1} \left( \frac{\partial}{\partial \mathbf{x}} u^{(r+1)} \mathbf{B}^{(r)} + \frac{\partial}{\partial \mathbf{e}} u^{(r+1)} \frac{\partial \mathbf{e}(\mathbf{y}^{*(r)})}{\partial w_j} \right) \end{aligned} \quad (51)$$

ただし,  $\mathbf{A}^{(0)} = \mathbf{I}$ ,  $\mathbf{B}^{(0)} = \mathbf{0}$  である. また, 表記の簡単のため,  $u^{(r)}(\Psi^{(r)}, \mathbf{e}(\mathbf{y}^{*(r)}))$  を  $u^{(r)}$  と略記している.

## 4 数値例

つぎの区分的線形微分方程式モデルで与えられる GRN がもつ周期現象の周期感度を求める.

$$\begin{aligned} \frac{dx_i(t)}{dt} &= -x_i(t) + w_{i,1} + w_{i,2}y_1(t) + w_{i,3}y_2(t) \\ &+ w_{i,4}y_3(t) + w_{i,5}y_1(t)y_2(t) \\ &+ w_{i,6}y_1(t)y_3(t) + w_{i,7}y_2(t)y_3(t) \\ &+ w_{i,8}y_1(t)y_2(t)y_3(t), \quad i = 1, 2, 3 \end{aligned} \quad (52)$$

パラメータ  $w$  は  $\mathbf{w}_1 = [1 \ 1 \ -1 \ -4 \ 2 \ 2 \ 2 \ -4]$ ,  $\mathbf{w}_2 = [-3 \ 4 \ 3 \ 1 \ -2 \ -2 \ -2 \ 4]$ ,  $\mathbf{w}_3 = [-2 \ -1 \ 2 \ 1 \ 2 \ 2 \ 2 \ -4]$  である. この GRN は周期軌道を持ち, 周期は  $T = 7.62117979882$ , ポアンカレ断面  $S_0$  との交点は,  $\gamma_0 = [2.5615528128 \ 1.4384471872 \ 0.0]'$  である. また, この周期軌道における周期 EPS は

$$\begin{aligned} [1 \ 1 \ 1]' &\rightarrow [0 \ 1 \ 1]' \rightarrow [0 \ 0 \ 1]' \rightarrow [0 \ 0 \ 0]' \\ &\rightarrow [1 \ 0 \ 0]' \rightarrow [1 \ 1 \ 0]' \rightarrow [1 \ 1 \ 1]' \end{aligned} \quad (53)$$

である. この GRN の周期現象に対して周期感度を求めた. 提案法と差分法によって求めた結果の一部を表 1 に示す. 差分法では, パラメータをそれぞれ 0.0001, 0.001 あるいは 0.01 増加させて感度の近似値を求めている. 表 1 より, 提案法によって周期感度が求められていることが確認できる.

## 5 おわりに

リズム現象はありとあらゆるシステムにみられる興味深い非線形現象で, その発生メカニズムを解明し, その成果を利用してシステムの解析, 設計における種々の問題の解決を図ろうとする研究が盛んになっている. その際, 重要なツールの一つが感度解析法である. 筆

Table 1: Results

Sensitivities	Proposed method	$\delta w_j = 0.0001$	$\delta w_j = 0.001$	$\delta w_j = 0.01$
$\frac{\partial T}{\partial w_{1,9}}$	0.05626	0.00009680	0.0009726	0.009726
$\frac{\partial T}{\partial w_{1,10}}$	-0.5043	-0.5531	-0.5527	-0.5488
$\frac{\partial T}{\partial w_{1,11}}$	1.255	1.174	1.175	1.179
$\frac{\partial T}{\partial w_{1,12}}$	0.3771	0.3106	0.3106	0.3102
$\frac{\partial T}{\partial w_{1,13}}$	1.028	1.038	1.039	1.043
$\frac{\partial T}{\partial w_{1,14}}$	0.2194	0.2425	0.2425	0.2422
$\frac{\partial T}{\partial w_{1,15}}$	1.097	1.106	1.107	1.111
$\frac{\partial T}{\partial w_{1,16}}$	0.2194	0.2425	0.2425	0.2422

者らはこれまで、リズム現象の感度解析法として、特にリズムの周期と位相のパラメータに関する感度を求める方法を提案している。

本稿では、GRNのモデルとして区分的線形微分方程式モデルを用い、GRNの周期現象の感度解析法を提案した。本稿で対象としている区分的線形微分方程式モデルの場合、そのダイナミクスが発現パターンに依存して切り替わる。このような場合の周期感度の数学的に厳密な表現を導出し、それを基にして周期感度を求める方法を提案した。数値例で、差分法によって近似的に求めた値と比較し、提案法によって周期感度が求められることを確認した。

ここでの提案法は、文献8)の方法を、一種のハイブリッドシステムへ適用できるように拡張したものと考えることができる。そのため、同様にして一般的なハイブリッドシステムに対する周期感度の表現を導出することができると期待できる。また、周期現象において特徴的な量としては、周期の他に位相がある。位相の感度を解析的に求める方法については今後の課題である。

## 参考文献

- 1) L. Glass, Combinatorial and topological methods in nonlinear chemical kinetics, *The Journal of Chemical Physics*, **63**-4, 1325/1335 (1975)
- 2) 市瀬, 合原: 遺伝子ネットワークモデルとその設計について, 第15回回路とシステム(軽井沢)ワークショップ, 589/593 (2002)
- 3) H. Nakayama, H. Tanaka and T. Ushio, The formulation of the control of an expression pattern in a gene network by propositional calculus, *J. Theor. Biol.*, **240**-3, 443/450 (2006)
- 4) Y. Mori and Y. Kuroe, Synthesis Method of Gene Regulatory Networks Having Desired Expression-Pattern Transition Sequences, *Proc. of 2013 9th Asian Control Conference*, 6 pages (2013)
- 5) D. Edelson and V. M. Thomas, Sensitivity Analysis of Oscillating Reactions. 1. The Period of the Oregonator, *J. Phys. Chem.*, **85**-11, 1555/1558 (1981)
- 6) M. A. Kramer, H. Rabitz and J. M. Calo, Sensitivity Analysis of Oscillatory Systems, *Appl Math Modelling*, **8**, 328/340 (1984)
- 7) A. K. Wilkins, B. Tidor, J. White and P. I. Barton, Sensitivity Analysis for Oscillating Dynamical Systems, *SIAM Journal on Scientific Computing*, **31**-4, 2706/2732 (2009)
- 8) 森, 黒江: リズム現象における位相・周期感度の解析法, 計測自動制御学会第5回コンピュータショナル・インテリジェンス研究会講演論文集, 60/67 (2015)
- 9) J. Guckenheimer and P. Holmes, *Nonlinear Oscillations, Dynamical Systems, and Bifurcations of Vector Field*, New York: Springer-Verlag (1983)

- 10) 黒江: ダイナミカルシステム入門, 計測自動制御学会誌計測と制御, **46**-4, 230/239 (2007)
- 11) Y. Kuroe, Computer-Aided Design Method of Stabilizing Controllers for Chaotic Systems, *Proceedings of 2012 IEEE International Symposium on Intelligent Control (ISIC) Part of 2012 IEEE Multi-Conference on Systems and Control*, 282/288 (2012)
- 12) 郡, 森田: 生物リズムと力学系, 共立出版 (2011)
- 13) H. de Jong, Modeling and simulation of genetic regulatory systems: a literature review, *Journal of Computational Biology*, **9**-1, 67/103 (2002)
- 14) 森, 黒江: 遺伝子ネットワークにおける周期発現パターン遷移列の感度解析法, 第62回システム制御情報学会研究発表講演会講演論文集, 6 pages, (2018)



# 興奮性-抑制性モジュールにより構成された スパイクングニューラルネットワークによる 想起パターンの動的遷移特性

○信川創 (千葉工業大学) 西村治彦 (兵庫県立大学) 山西輝也 (福井工業大学)

## Dynamical Transition of Emergent Patterns in Spiking Neural Networks Composed of Excitatory-Inhibitory Neural Modules

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

**Abstract**— Recently, spiking neural networks, which have the physiological neural and synaptic properties, have been applied to machine learning. While, the studies by physiological neural network models and neuroimaging modality reported that the fluctuation of neural activities can enhance the brain functions such as cognitive and learning functions, which is called stochastic resonance or stochastic facilitation phenomenon. However, few studies have focused on the application of these phenomenon to machine learning in the spiking neural network. Therefore, in this study, the characteristic for the noise induced dynamical pattern transitions, which can be utilized to the exploration of embedded patterns in associative memory, was evaluated in the spiking neural network. Through the periodicity/complexity evaluation of the noise induced transitions in the spiking neural network with two excitatory-inhibitory neural modules, we revealed that deterministic periodic behaviors called as coherence resonance arises at appropriate noise frequency.

**Key Words:** spiking neural network, synchronization, coherence resonance, multiscale entropy analysis

## 1 はじめに

これまで主に生理学的なモデリングに用いられてきたスパイクングニューラルネットワークを、パターン識別や時系列予測といった機械学習へ適用する研究がはじまっている<sup>1, 2)</sup>。さらに近年、この実問題に適用されつつあるスパイクングニューラルネットワークに対して、発火タイミング依存シナプス可塑性や興奮性シナプス荷重分布の対数正規性などの生理学的に詳細な特徴をモデルに取り入れることで、学習や記憶性能の強化が実現できることが報告されている<sup>3, 4)</sup>。例えば、Albersらは、発火タイミングに基づいた学習器である Tempotron<sup>1)</sup> のメカニズムを発火依存シナプス可塑性と抑制性シナプス結合によって実現することに成功した<sup>3)</sup>。また、Hirataniらは興奮性シナプス荷重の対数正規性によって、連想記憶における記憶の想起精度が高められること報告している<sup>4)</sup>。

ニューラルシステムにおけるゆらぎの存在が信号伝達や認知機能といった脳・神経系における機能性を高める確率共鳴/確率促進現象に関する研究が、モデル<sup>5, 6, 7, 8, 9)</sup> や脳機能画像法<sup>10, 11, 12, 13, 14, 15)</sup> によるアプローチによって進められている。しかし、実際の機械学習機構への確率共鳴/確率促進現象の応用については、従来の rate coding のニューロンモデルに基づく研究がほとんどあり<sup>16, 17)</sup>、スパイクングニューラルネットワークでの取り組みは極めて少ない<sup>8, 9)</sup>。

このような中で、本研究では連想記憶におけるパターン探索に適用可能な動的なパターン遷移モードのノイズによる誘起について検討を行う。具体的には、興奮性ニューロン集団と抑制性ニューロン集団によって構成されたモジュールを用いて、一方のモジュールの発火活動が誘起する発火パターンを生成する結合形態を導入する。そして、外界からのノイズ入力に対する発

火パターンのダイナミクス特性を、周期性・複雑性・決定論性の視点から評価する。

## 2 モデルと評価方法

### 2.1 スパイクングニューラルネットワーク

各ニューロンの膜電位  $v$  のダイナミクスは積分発火モデルにより (1) 式で与えられる。

$$\frac{dv}{dt} = -\frac{1}{\tau_m}(v - V_L) - g_E(v - V_E) - g_I(v - V_I) + I_{ex} \quad (1)$$

ここで、膜電位の時定数  $\tau_m$  は、20[ms](興奮性ニューロン)と10[ms](抑制性ニューロン)に設定する。漏れ電流と興奮性シナプス後電流、抑制性シナプス後電流の大きさを決定するパラメータを  $V_L = -70$ [mV],  $V_E = 0$ [mV],  $V_I = -80$ [mV] に設定する。興奮性/抑制性シナプスコンダクタンスである  $g_E/g_I$ [ms<sup>-1</sup>] は (2) 式で表される。 $I_{ex}$  はポアソン過程によって生成される外部入力であり、発火頻度  $\Lambda$  [Hz] で入力を与える。

$$\frac{dg_X}{dt} = -\frac{g_X}{\tau_s} + \sum_j G_{X,j} \sum_{s_j} \delta(t - s_j - d_j), \quad X = E, I \quad (2)$$

ここで、 $\delta(t)$  はデルタ関数であり、 $G_j, d_j, s_j$  はそれぞれシナプス荷重、遅れ時間、ニューロン  $j$  からの発火時刻を表す。

減衰定数  $\tau_s$  は 2[ms] に、 $d_j$  は  $[d_0 - 1 : d_0 + 1]$ [ms] の一様乱数とし、興奮性-興奮性のシナプス結合においては  $d_0 = 2$ 、他のシナプス結合においては、 $d_0 = 1$  とする。発火の閾値は  $V_{thr} = -50$ [mV] で発火後は  $v$  を  $V_r = -60$ [mV] にリセットする。尚、応答期は 1[ms] とする。

図1にスパイクングニューラルネットワークの結合形態を示す。本研究では、5000個からなる興奮性ニューロ

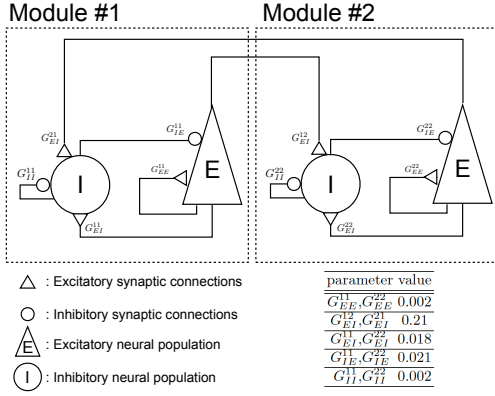


Fig. 1: Topology of spiking neural network.

ン集団と 1000 個からなる抑制性ニューロン集団を 1 つのモジュールとし、2 つのモジュールが興奮性ニューロン集団から抑制性ニューロン集団への興奮性シナプス結合により繋がる。module #1,2 の興奮性ニューロン集団には #1~#5000, #5001~#10000 のニューロン番号を抑制性ニューロン集団には 10001~11000, 11001~12000 のニューロン番号をそれぞれを振る。このような結合強度の設定で、一方の module の発火活動が活性化する活動パターンが生成される。

## 2.2 評価方法

### 2.2.1 発火活動の評価

発火活動の評価を、(3) 式で与えられる興奮性ニューロン集団の発火率  $r_E$  [Hz] と抑制性ニューロン集団の発火率  $r_I$  [Hz] を用いて評価する。

$$r_X(t) = 1000 \frac{S_X(t)}{\Delta t N_X} \quad X = E, I \quad (3)$$

ここで、 $S_E$  と  $S_I$  は 0.1 [ms] の幅をもつ bin における各ニューロン集団における発火回数を示す。本研究では、 $r_E(t)$  と  $r_I(t)$  は 10 [ms] の幅をもつ Gaussian-shaped 窓で平滑化する。

### 2.2.2 固有相関量

$r_E$  の時系列の周期性を評価するために、(4) 式による固有相関量<sup>18)</sup>を用いる。

$$\tau_c = \frac{1}{T} \int_0^T C_{rr}(\tau)^2 d\tau, \quad (4)$$

ここで、 $C_{rr}(\tau)$  と  $T$  は  $r_E$  の時系列と遅れ時間  $\tau$  の時間積分範囲を示す。 $r_E$  の周期性がない場合は、 $\tau_c \rightarrow 0$  となり、 $r_E$  の周期性が強くと見られる場合は  $\tau_c \gg 0$  に対応する。

### 2.2.3 マルチスケールエントロピー

$r_E$  の時系列の複雑性の時間スケールへの依存性の評価を行うためにマルチスケールエントロピー (Multiscale entropy: MSE) 解析<sup>19)</sup>を行う。確率変数  $\{x_1, x_2, \dots, x_N\}$  に対して、サンプルエントロピー (Sample Entropy: SamEn) は (5) 式のように定義される。

$$h(r, m) = -\log \frac{C_{m+1}(r)}{C_m(r)}, \quad (5)$$

$C_m(r)$  は  $|\mathbf{x}_i^m - \mathbf{x}_j^m| < r$  ( $i \neq j$ ,  $i, j = 1, 2, \dots$ ) の確率を示す。 $\mathbf{x}_i^m$  は  $m$  次元ベクトル ( $\mathbf{x}_i^m =$

$\{x_i, x_{i+1}, \dots, x_{i+m-1}\}$ ) を示す。MSE 解析においては、 $\{x_1, x_2, \dots, x_N\}$  を (6) 式で、粗視化した時系列  $y_j$  に対して行う。

$$y_j^{(\tau)} = \frac{1}{\tau} \sum_{i=(j-1)\tau+1}^{j\tau} x_i, \quad (1 \leq j \leq N/\tau) \quad (6)$$

ここで、 $\tau$  ( $\tau = 1, 2, \dots$ ) は時間スケールを表す。本研究では、 $m = 2$ ,  $r = 0.2$  に時間スケール幅は 100 [ms] を用いる。

### 2.2.4 サロゲートデータ法

$r_E$  の時系列がスパイクングニューラルネットワークの非線形ダイナミクスを反映しているかの評価のために、iterated amplitude adjusted Fourier transform (IAAFT)<sup>20)</sup>を  $r_E$  の時系列に適用する。ここで、反復回数は、 $r_E$  のパワースペクトルがオリジナルデータのスペクトルと一致するように 1000 回に設定し、10 個の IAAFT のサロゲートデータを作成する。そして、 $r_E$  とその IAAFT サロゲートデータ間で MSE プロフィールを比較する。

## 3 結果

Fig.2 にモジュール #1 と #2 におけるスパイクングニューラルネットワークのラスタプロットと興奮性ニューロン集団平均発火率  $r_E$  の時系列を示す。入力ノイズの頻度が小さい  $\Lambda = 0.9$  [Hz] においては、各モジュールの発火頻度は 0.8 [Hz] 程度で一定の値を取る。しかし、 $\Lambda = 1.04$  [Hz] では、モジュールが活性化する期間 (1.0[Hz] 程度) と不活性化する期間 (0.5[Hz] 程度) を交互に繰り返す、その遷移が module#1 の活性パターンと module#2 の活性パターンの切替りに対応している様子が観察される。さらに強い入力ノイズ頻度の場合 ( $\Lambda = 1.16$  [Hz]) では一方のモジュールでの活性化が固定される。

次に、 $r_E$  の固有相関量  $\tau_c$  の入力ノイズ頻度  $\Lambda$  への依存性を Fig.3 に示す。 $\Lambda \approx 1.1$  で  $\tau_c \approx 0.5$  のピークを示す特性が観測される。この結果から、活性パターンの遷移は、適度な入力ノイズ頻度のもとでダイナミクスの周期性が顕在化するコヒーレンス共鳴<sup>18)</sup>の特性を持つといえる。

さらに、この  $r_E$  時系列の MSE 解析を実施し、 $r_E$  の IAAFT サロゲートデータに対する MSE プロフィールとの比較を行う (Fig.4)。一方の module の発火モードに固定される  $\Lambda = 0.9, 1.16$  の場合では、 $r_E$  時系列の SampEn のプロフィールは IAAFT サロゲートデータのプロフィールと一致している。しかし、コヒーレンス共鳴が生じた入力ノイズ頻度である  $\Lambda = 1.11$  においては、 $r_E$  時系列の SampEn は、全ての scale において、IAAFT サロゲートデータの場合よりも高い傾向を示す。これは、コヒーレンス共鳴が生じた場合の  $r_E$  の挙動は、決定論的なダイナミクスにより生まれている可能性を示唆するものである。

## 4 おわりに

本研究では、2 つの興奮性-抑制性モジュールから構成されるスパイクングニューラルネットワークにおいて、入力ノイズによって、記録パターンの遷移モードへの分岐が生じることを確認した。その遷移モードのダイ

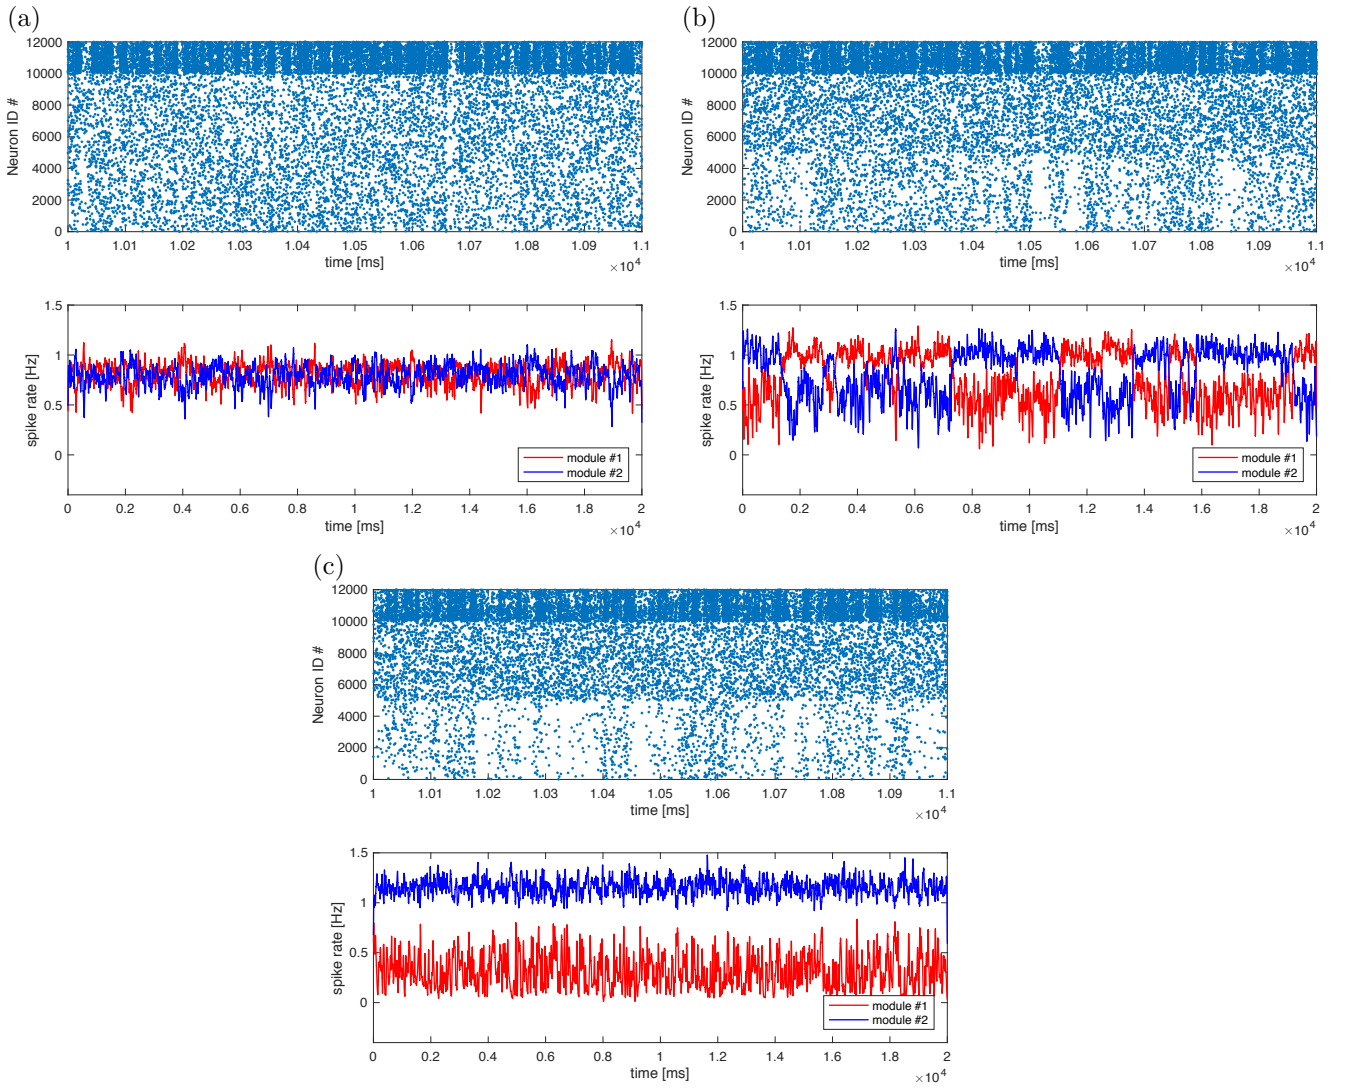


Fig. 2: Dependence of time-series of neural activity on noise frequency  $\Lambda$ . Scatter plots (upper) and Excitatory and inhibitory Spiking rates  $r_E$  and  $r_I$ . (a)  $\Lambda = 0.9$  case. (b)  $\Lambda = 1.04$  case. (c)  $\Lambda = 1.16$  case.




Fig. 3: Dependence of correlation time  $\tau_c$  on noise frequency  $\Lambda$ .

ナミクスにおいて、適度なノイズ頻度において周期性が顕在化するコヒーレンス共鳴の生起が確認され、さらにその複雑性プロフィールは決定論的なダイナミクスを反映していることが示唆された。今後の課題は、パターン遷移の時間間隔の確率分布の解析と、大規模な

スパイクングニューラルネットワーク中でのノイズ誘起性のパターン遷移の検討が挙げられる。

## 謝辞

本研究は JSPS 科研費 若手研究 (18K18124) の助成を受けた。

## 参考文献

- 1) R. Gütig and H. Sompolinsky, “The tempotron: a neuron that learns spike timing–based decisions,” *Nature neuroscience*, vol. 9, no. 3, p. 420, 2006.
- 2) E. Tu, N. Kasabov, and J. Yang, “Mapping temporal variables into the neocube for improved pattern recognition, predictive modeling, and understanding of stream data,” *IEEE transactions on neural networks and learning systems*, vol. 28, no. 6, pp. 1305–1317, 2017.
- 3) C. Albers, M. Westkott, and K. Pawelzik, “Perfect associative learning with spike-timing-dependent plasticity,” in *Advances in neural information processing systems*, 2013, pp. 1709–1717.
- 4) N. Hiratani, J.-N. Teramae, and T. Fukai, “Associative memory model with long-tail-distributed hebbian synaptic connections,” *Frontiers in computational neuroscience*, vol. 6, p. 102, 2013.
- 5) N. Schweighofer, K. Doya, H. Fukai, J. V. Chiron, T. Furukawa, and M. Kawato, “Chaos may enhance

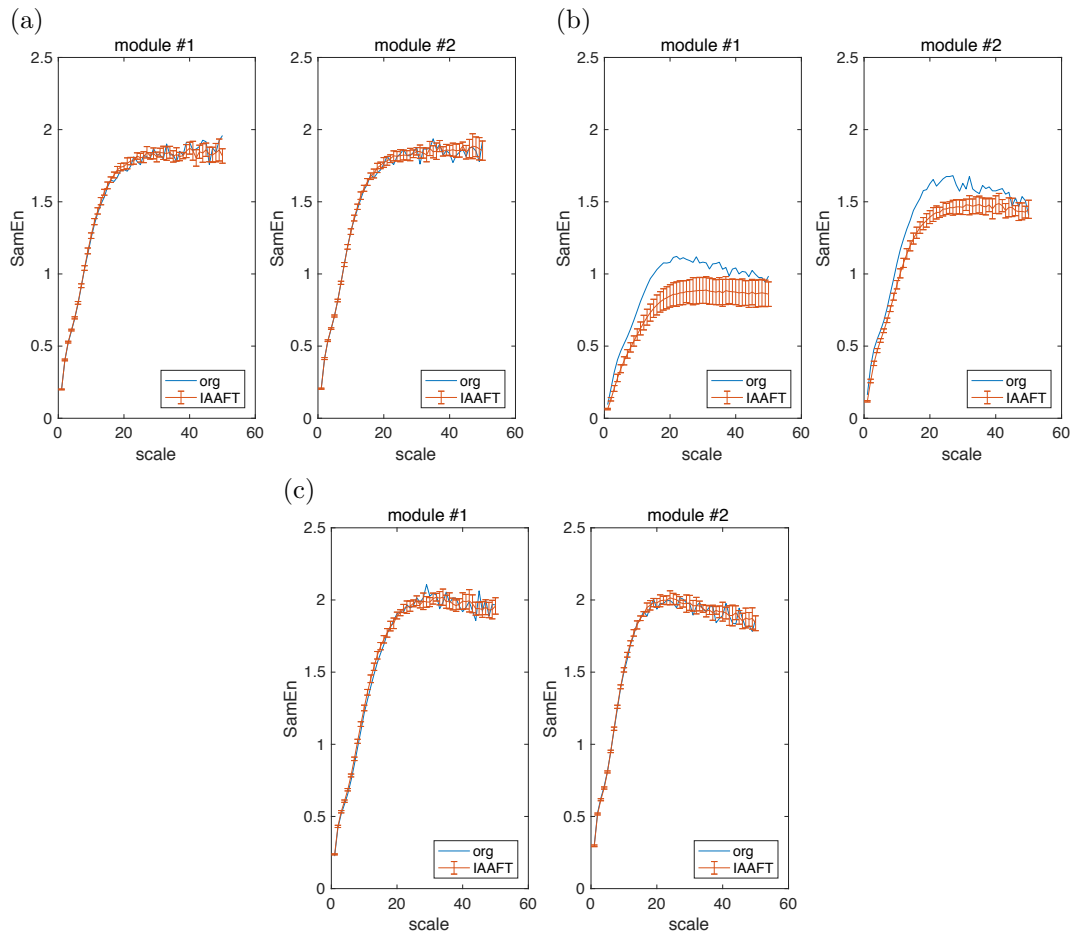


Fig. 4: Dependence of Sample Entropy (SampEn) of neural activity on temporal scale. (a)  $\Lambda = 0.9$  case. (b)  $\Lambda = 1.11$  case. (c)  $\Lambda = 1.16$  case.

- information transmission in the inferior olive,” *Proceedings of the National Academy of Sciences of the United States of America*, vol. 101, no. 13, pp. 4655–4660, 2004.
- 6) S. Nobukawa and H. Nishimura, “Chaotic resonance in coupled inferior olive neurons with the Izhikevich neuron model,” *Neural Computation*, vol. 28, no. 11, pp. 2505–2532, 2016.
  - 7) S. Nobukawa, H. Nishimura, and T. Yamanishi, “Chaotic resonance in typical routes to chaos in the Izhikevich neuron model,” *Scientific reports*, vol. 7, no. 1, p. 1331, 2017.
  - 8) J. Park, H. Mori, Y. Okuyama, and M. Asada, “Chaotic itinerancy within the coupled dynamics between a physical body and neural oscillator networks,” *PloS one*, vol. 12, no. 8, p. e0182518, 2017.
  - 9) T. Kanamaru, “Chaotic pattern alternations can reproduce properties of dominance durations in multistable perception,” *Neural computation*, vol. 29, no. 6, pp. 1696–1720, 2017.
  - 10) A. R. McIntosh, N. Kovacevic, and R. J. Itier, “Increased brain signal variability accompanies lower behavioral variability in development,” *PLoS Comput Biol*, vol. 4, no. 7, p. e1000106, 2008.
  - 11) T. Takahashi, R. Y. Cho, T. Murata, T. Mizuno, M. Kikuchi, K. Mizukami, H. Kosaka, K. Takahashi, and Y. Wada, “Age-related variation in eeg complexity to photic stimulation: a multiscale entropy analysis,” *Clinical Neurophysiology*, vol. 120, no. 3, pp. 476–483, 2009.
  - 12) D. D. Garrett, N. Kovacevic, A. R. McIntosh, and C. L. Grady, “Blood oxygen level-dependent signal variability is more than just noise,” *The Journal of Neuroscience*, vol. 30, no. 14, pp. 4914–4921, 2010.
  - 13) —, “The importance of being variable,” *The Journal of Neuroscience*, vol. 31, no. 12, pp. 4496–4503, 2011.
  - 14) T. Takahashi, “Complexity of spontaneous brain activity in mental disorders,” *Progress in Neuro-Psychopharmacology and Biological Psychiatry*, vol. 45, pp. 258–266, 2013.
  - 15) A. C. Yang and S.-J. Tsai, “Is mental illness complex? from behavior to brain,” *Progress in Neuro-Psychopharmacology and Biological Psychiatry*, vol. 45, pp. 253–257, 2013.
  - 16) I. Tokuda, K. Aihara, and T. Nagashima, “Adaptive annealing for chaotic optimization,” *Physical Review E*, vol. 58, no. 4, p. 5157, 1998.
  - 17) 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.
  - 18) A. S. Pikovsky and J. Kurths, “Coherence resonance in a noise-driven excitable system,” *Physical Review Letters*, vol. 78, no. 5, p. 775, 1997.
  - 19) M. Costa, A. L. Goldberger, and C.-K. Peng, “Multiscale entropy analysis of complex physiologic time series,” *Physical review letters*, vol. 89, no. 6, p. 068102, 2002.
  - 20) T. Schreiber and A. Schmitz, “Improved surrogate data for nonlinearity tests,” *Physical Review Letters*, vol. 77, no. 4, p. 635, 1996.



# 前腕装着型導電性繊維を用いた脈波取得による心拍推定手法の提案

○増山義輝 奈倉正樹 満倉靖恵 (慶應義塾大学)

## Heart Rate Estimation Method by Measuring Pulse Wave Through Conductive Fibers Mounted on Forearms

\* Yoshiki Mashiyama, Masaki Nagura and Yasue Mitsukura (Keio University)

**Abstract**— In this paper, we propose a method for estimating heart rate from pulse wave measured through conductive fibers mounted on forearms. In recent years, heart rate is an effective index for describing mental and physical condition. Accordingly, many types of wearable heart rate measuring devices have been developed. However, there are problems such as uncertainty in the measured waveform caused by contact failure and large burdens on subjects caused by wearing oppression. Hence, it is necessary to have a device that causes less burdens and can measure stably. In this research, we propose a forearm-mounted pulse wave measuring device made of stretchable conductive fibers that can be comfortably worn and can reduce contact failure. In addition, we propose a method for estimating heart rate from pulse wave measured by proposed device. In order to evaluate the effectiveness of the proposed method, we show the accuracy of measuring heart rate and the occurrence probability of the heart rate variability waveform. As a result, it was confirmed that pulse wave can be measured stably irrespective at both rest and moving state by the proposed method.

**Key Words:** heart rate, pulse wave, conductive fibers

### 1 はじめに

本研究の目的は、前腕装着型導電性繊維を用いて脈波を取得し、得られた脈波から心拍の推定を行う手法を提案する事である。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手法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、心拍は運動時の消費カロリーの推定に有効であることや、睡眠時の睡眠段階の判定の指標として有用であることから、今日まで心拍情報の取得を行う機器が多く提案されてきた[2,3]。しかし、計測精度の高い大型の計測機器では、取得可能な環境が安静時に限定されているため動作を伴う場合の利用は困難であり、動作時での利用に適さないという問題点があった。近年、この問題点に対しウェアラブル型のデバイスなどが多く提案されている。しかし、これらのウェアラブル型のデバイスには、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、粘着性電極面の装着に伴う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を持つものがある[4]。加えて、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り、低負担かつ高精度な心拍情報計測可能な手法が必要である[5]。これらの背景より、本研究の最終目的は、伸縮性があり装着感を感じない導電性繊維を用いた衣類型心拍情報計測システムの構築である。衣類型心拍情報計測システムを構築することによって、衣類として着用することで計測が可能となるため、日々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。そこ


で今回の目的は最終目的の前段階として、導電性繊維を用いた前腕装着型脈波取得装置およびそこから得られた計測信号から心拍情報を取得する手法の提案とする。本論文は全5章で構成される。2章では、提案デバイス(ハードウェア)および心拍情報取得手法(ソフトウェア)について述べる。3章では、提案手法の精度評価を目的とした検証実験の実験手順および評価手法について述べる。4章では検証実験の結果および考察について述べる。5章では本論文のまとめおよび今後の課題について述べる。

### 2 提案手法

#### 2.1. 製作デバイス

##### 2.1.1. 前腕装着部

本研究では動作時の機器のずれ抑制や装着の簡便性の観点から、心拍情報取得に伸縮性のある導電性繊維素材を用いる。取得部位としては、既存のチェストストラップ型心拍計において使用される胸部と比較し、圧着による負荷が小さいと考えられる前腕部を選択した。前腕部から心拍情報を取得するために製作した前腕装着部を Fig. 1 (a)に示す。また、実際に装着した様子を Fig. 1 (b)に示す。



(a) (b)  
Fig. 1: Forearm attachment



### 2.1.2. 制御部

本研究では、前腕部から心拍情報を取得するためにインピーダンス式脈波計の取得原理を用い、前腕装着型脈波取得装置の開発を行った[6]。この原理では、心臓の拍動に伴う血管の容積変化が生体インピーダンス変化として現れることから、生体インピーダンス変化を計測することにより拍動に伴う血管の容積変化すなわち脈波の推定を行う原理である。取得原理は次式で表される。

$$\Delta E \approx \frac{Z^2 I}{\rho L^2} \Delta V \quad (1)$$

(1)式において、 $\Delta E$ は電位差、 $Z$ は生体インピーダンス、 $\rho$ は血液の抵抗、 $L$ は血管の単位長さ、 $\Delta V$ は血液の量、 $I$ は本研究では細胞の活動に伴う活動電位の容積伝導と定義する[7]。よって、細胞の活動に伴う活動電位を介して生体インピーダンス変化が体表に電位差として現れると考え、取得した電位差から拍動に伴う血管の容積変化を計測することで、前腕部から脈波を間接的に計測することが可能である。計測信号では同様の活動電位の一部である筋電がノイズとして混入することが懸念されるが、筋電図の周波数帯域は10~200Hzであるとされており、脈波の周波数帯域である0.5~4Hzとは異なるため信号の分離が可能であると考えられる[8,9]。実際に製作した装置をFig.2に示す。

### 2.2. 心拍情報取得手法

脈波の発生は心臓の活動と密接に関係しており、心臓の拍動に応じた血管の圧変化や容積変化のことを脈波と呼ぶ。よって、脈波と心拍には強い関連性があり、脈拍数の変動は心拍数の変動と一致する[10]。こうした特性を利用し、取得した波形から心拍情報を得る。実際に提案手法によって取得した信号の生波形をFig.3に示す。Fig.3より、計測波形には交流障害や筋電などの脈波成分以外のノイズが多く混入していることがわかる。そこでまず、計測波形を脈波成分とその他のノイズ成分に分離を目的として、計測信号に対して通過帯域0.5-10 Hzのバンドパスフィルタを用いてフィルタ処理を行った。次に、フィルタ処理後の信号に対してフーリエ変換を行い、求めた信号のパワースペクトルを入力として非負値行列因子分解を行った。非負値行列因子分解は、観測行列 $P$ を基底行列 $H$ とアクティ




Fig. 2: Hardware

ベーション行列 $W$ の積に低ランク近似するアルゴリズムである。独立成分分析といった他の信号分離手法と異なり単極信号の信号分離が可能となることに加え、頻出する成分を同一の基底で表現することで次元を削減するアルゴリズムであることから、定常的な成分である脈波成分の分離に有効であると考えられる[11]。本研究では基底行列 $H$ の基底数を5-10として分解を行った。次に、分離後の脈波成分データに対して、局所的な最大値探索を行うことで心臓の拍動のタイミングの抽出を行った[12]。得られた心臓の拍動のタイミングから、心拍数および心拍間隔の算出を行った。計測信号に対して提案手法を適用し、信号分離を行った結果および心拍情報抽出結果をFig.4に示す。また、心拍情報取得手法のフローチャートをFig.5に示す。




Fig. 3: Measurement raw signal by proposed device




Fig. 4: Result of heart rate estimation method

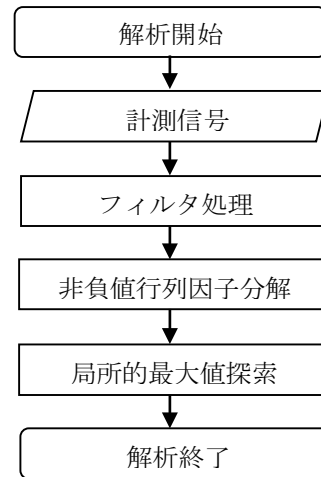


Fig. 5: Flowchart of heart rate estimation method

### 3 検証実験

#### 3.1 実験

提案手法の有効性を示すため、提案手法を用いた脈波および従来手法を用いた心電図の同時計測を行い、そこから推定した心拍情報を比較することで精度評価を行った。心電図の計測にはフィリップス・レスピロニクス社の Alice PDx の心電図計測機能を用いた[13]。被験者は 20 代の男性健康者 5 名を対象とし、計 6 姿勢の各 1 分間を 1 セットの計測とし、計 2 セットの計測を行った。各計測姿勢は以下の通りである。

- 姿勢 1: 座った状態で手を机の上に置き安静
- 姿勢 2: 座った状態で手を PC の上に置き安静
- 姿勢 3: 座った状態で手を膝の上に置き安静
- 姿勢 4: 座った状態で手を膝の上に置き安静
- 姿勢 5: 立った状態で腕だけ走る動作
- 姿勢 6: 立った状態で走る動作

ここで、姿勢 1-4 を安静時、姿勢 5-6 を動作時とした。また、実験の流れを以下の Fig. 6 に示す。

#### 3.2 評価手法

本研究では、精度評価のために心拍数の比較およびサンプルエントロピー解析を行った。また、評価手法のフローチャートを以下の Fig. 7 に示す。心拍数の比較では、同時計測を行った心電図から得られた心拍数を正解値とし、安静時の心拍数を比較することで提案手法の正確性の評価を行った[14]。また、サンプルエン




Fig. 6: Experiment procedure

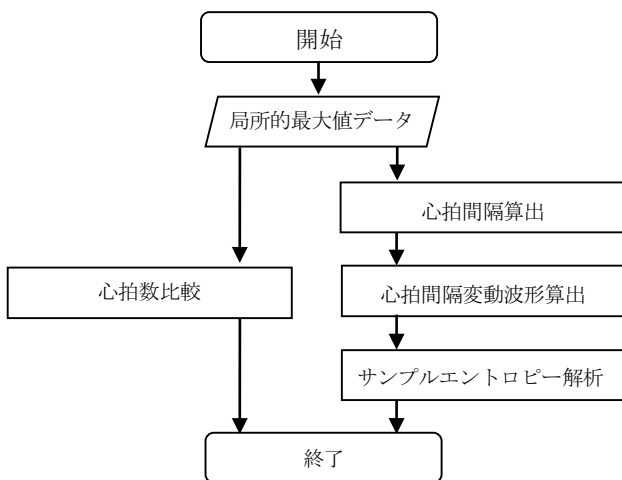


Fig. 7: Flowchart of evaluation method

トロピー解析では、安静時および動作時の心拍変動波形に対し、時系列信号の乱雑さの評価指標であるサンプルエントロピーを算出した[15]、次節では心拍変動波形のサンプルエントロピーの生起確率値を比較することで計測特性の評価を行った。

### 4 結果および考察

安静時の計測において提案手法により推定された心拍数の心電図から得られた心拍数に対する正解率を各被験者の非負値行列因子分解の基底数ごとに算出した結果を以下の Table. 1 に示す。Table. 1 より、正解率の平均は  $91.4 \pm 6.7\%$  であった。よって非負値行列因子分解の適用によって妥当な心拍情報の抽出が可能であったと考えられる。また、被験者ごとに正解率が最大となる最適な基底数が異なっていることがわかる。これは、被験者ごとに体内の血管の組成が異なっていることや、前腕部の体毛の有無などが原因として考えられる。次に、動作時の計測特性の評価結果である心拍変動波形のサンプルエントロピーの生起確率値を Fig. 7, 8 に示す。また、実験において動作タスク終了後の従来手法の心拍間隔の時系列変動波形の例を Fig. 8 に示す。Fig. 8 より、動作終了直後の心拍間隔は安静時の心拍間隔に対して大きな変化は見られなかったことから、動作時においても安静時同等の心拍間隔であったと考えられる。しかし、Fig. 9 から、従来手法では安静時と動作時の心拍間隔の時系列変動波形のサンプルエントロピーの生起確率の変化が大きく、動作時に接触

Table. 1: The accuracy rates of heart rate in resting stste

被験者	心拍数正解率 [%]					
	基底数 5	基底数 6	基底数 7	基底数 8	基底数 9	基底数 10
1	97.4	93.6	96.5	95.4	95.9	94.2
2	91.4	95.4	96.6	98.3	97.8	98.3
3	73.5	78.9	81.2	82.7	82.2	85.7
4	83.4	87.1	89.8	88.1	92.2	90.1
5	95.4	93.5	97.1	95.3	96.6	97.7




Fig. 8: Waveform of heart rate variability




Fig. 8: Conventional method




Fig. 9: Proposed method

不具合などから計測波形に不確実性を含んでいると考えられる。Fig. 10 より、提案手法ではサンプルエントロピーの生起確率の変化が小さいことから動作時に計測特性の変化が小さかったと考えられる。しかし、提案手法は従来手法に対し最も生起確率の高いサンプルエントロピーの値が大きいことから、アルゴリズムの改善を行い安静時の計測精度を向上させることで動作時においても安定した計測が実現可能であると考えられる。

## 5 おわりに

本研究では、前腕装着型導電性繊維を用いた脈波取得による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。

- 提案手法では伸縮性のある導電性繊維を用いることで、装着による被験者への負担を軽減することが可能になったと考えられる。
- 検証実験の結果より、提案手法では安静時および動作時において計測特性の変化が小さく、安定した計測が実現可能であると考えられる。

従来手法に対し最も生起確率の高いサンプルエントロピーの値が大きいという結果から信号分離の精度が不十分であったことが考えられる。よって、今後の課題として信号分離手法などのアルゴリズムの改善を行うことで計測精度の向上が必要である。

## 謝辞

本研究は、文部科学省科研費基盤研究(S)YYK7S01の助成を受けたものです。

## 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] 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.
- [5] R. Wang, et al., "Accuracy of Wrist-Worn Heart Rate Monitors", *AMA Cardiol*. Vol. 2, No. 1, pp. 104-106, 2017.
- [6] 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
- [7] S.B. Rutkove, "Introduction to Volume Conduction", *The Clinical Neurophysiology Primer*, pp 43-53, 2007.
- [8] 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.
- [9] L. Mainardi, et al., "Photoplethysmography Pulse Rate Variability as a Surrogate Measurement of Heart Rate Variability During Non-Stationary Conditions", *Physiological Measurement*, Vol. 31, pp. 1271-1290, 2010.
- [10] H. Kameoka, 「非負値行列因子分解」, *計測と制御*, Vol.51, No.9, pp.835-844, 2012.
- [11] Philips, <https://www.philips.com/healthcare/product/HC1043941/alice-pdx-portable-sleep-diagnostic-system>, 2018/5/21 アクセス.
- [12] MathWorks, <https://jp.mathworks.com/help/signal/ref/findpeaks.html>, 2018/5/21 アクセス.
- [13] J. Pan and W.J. Tompkins, "A Real-Time QRS Detection Algorithm" *IEEE Transaction on Biomedical Engineering*, Vol. 32, No. 3, 1985.
- [14] J. Yentes, et al., "The Appropriate Use of Approximate Entropy and Sample Entropy with Short Data Sets.", *Ann Biomed Eng.*, Vol. 41, No. 2, pp. 349- 365, 2013.

# Cost-sensitive learningにおける boostingの適応的しきい値調整の検討

○ 佐々木 勇人 濱上 知樹 (横浜国立大学)

## Study about adaptive thresholded boosting in cost-sensitive learning

\*H. Sasaki and T. Hamagami (Yokohama National University)

**Abstract**— Cost-sensitive learning can deal with trade-off between true positive rate and false positive rate of detection. Although the control of these two rate is especially important for detection problems, optimal costs of wrong detections are usually unknown. To tackle the problem, our previous research has proposed adaptive thresholded AdaBoost, where false positive rate of a strong classifier is controlled to keep a target value instead of setting costs of wrong detections. In this research, a preliminary investigation is conducted to generalize the adaptive thresholded technique to other boosting methods, such as MadaBoost and Gentle AdaBoost.

**Key Words:** boosting, cost-sensitive learning

### 1 はじめに

検出問題では検出率 (True Positive Rate: TPR) と偽陽性率 (False Positive Rate: FPR) のいずれかが重要視される。これは TPR と FPR がトレードオフの関係にあるためである。トレードオフの関係にある TPR と FPR を制御するために、偽陽性・偽陰性の検出に対して異なる罰則値を設定する学習問題が cost-sensitive learning<sup>1)</sup> である。

ここで問題となるのが、罰則値の決定方法である。実問題では罰則値をどう設定すべきかという明確な指標があることは少ない。検出の性能を評価する場合には TPR と FPR が用いられるが、罰則値の設定によっては TPR や FPR に関する制約や目標を満足できない。

さらに、一般的に検出対象 (正例) はそれ以外のデータ (負例) と比べて数が少ないため、TPR と比べて FPR のほうが汎化誤差は小さくなりやすい。また、正例が少ない場合にできる限り TPR を高くしたい場合には FPR の上昇を許容する必要がある。したがって TPR と FPR を制御して検出性能を保証するためには FPR の許容値を定めて TPR を最適化することが有効である。

一定の FPR を保証しながら TPR を最適化するために、筆者らの文献<sup>2)</sup> では boosting<sup>3)</sup> における適応的なしきい値調整を提案した。FPR を一定に保つようにしきい値を適応的に定めることは cost-sensitive learning の罰則値を適応的に設定することに対応する。さらに、直感的な指標である FPR をハイパーパラメータとすることで、トレードオフの関係にある TPR と FPR を明示的に制御することが可能となる。

一方で、文献<sup>2)</sup> では boosting の中でも AdaBoost のみ焦点を当てて評価が行われていた。しかしながら AdaBoost にはいくつかの欠点があり、FPR を一定に保てない場合がある。本稿で対象とする TPR と FPR の制御が重要となる問題では、正例と負例が特徴空間上で重なっている状況が存在する。そうした状況では、正例と負例の重なり部分の誤分類が過剰に強調され、FPR の目標値に対する追従性に悪影響を与えてしまう。

また、AdaBoost の離散的な出力をする学習器ではしきい値を目標の値に調整できない問題も存在してい

た。そこで本稿では AdaBoost 以外の boosting 手法に適応的なしきい値調整手法を導入し、FPR の目標値に対する追従性について検討を行う。

### 2 Boosting における cost-sensitive learning

あるドメイン  $\mathcal{X}$  上で定義される  $x$  の二値分類問題を考える。また、 $x$  とそれに付与される分類ラベル  $y \in \{-1, +1\}$  は分布  $D_0(x, y)$  に従っているとす。

boosting は式 (1), (2) のモデルで表現される分類器  $H_T(x)$  に関して、式 (3) の損失関数を最小化する問題として定式化される。

$$H_T(x) = \text{sign}[F_T(x)] \quad (1)$$

$$F_T(x) = \sum_{t=1}^T f_t(x) \quad (2)$$

$$\mathcal{R}[H_T; D_0] = \mathbb{E}_{(x,y) \sim D_0}[U(-yF_T(x))] \quad (3)$$

ここで式 (2) 中の  $f_t: \mathcal{X} \rightarrow \mathbb{R}$  は弱学習器である。また、式 (3) 中の  $U: \mathbb{R} \rightarrow \mathbb{R}_{\geq 0}$  は式 (4) で表される zero-one 損失の上界であり、 $\mathcal{R}[H_T; D_0]$  は誤分類率の上界になっている。

$$L(z) = \begin{cases} 1 & z \geq 0 \\ 0 & \text{otherwise} \end{cases} \quad (4)$$

分類器は弱学習器を逐次的に追加することで greedy に最適化される。すなわち、各ステップ  $t$  で追加される弱学習器  $f_t \in \mathcal{F}$  は  $\mathcal{R}[H_T; D_0]$  を最小化するように選択されるが、具体的な最小化方法は boosting の手法ごとに異なる。

ここまでは cost-insensitive な (誤分類率を最小化するための) boosting について述べた。これまでの議論を cost-sensitive learning に拡張するためには偽陽性および偽陰性に対する罰則  $C(y) = \exp(-y\tau^*)$  を式 (3) に導入すればよい。ここで  $\tau^* \in \mathbb{R}$  は学習前に予め設定しておくハイパーパラメータであり、偽陽性の分類に対する罰則は  $\exp(\tau^*)$ 、偽陰性に対する罰則は  $\exp(-\tau^*)$  となる。

この罰則値  $C(y) = \exp(-y\tau^*)$  により cost-sensitive な損失関数  $\mathcal{R}_C[H_T; D_0]$  を表現すると

$$\mathcal{R}_C[H_T; D_0] = \mathbb{E}_{(x,y) \sim D_0} [\exp(-y\tau^*) U(-yF_T(x))] \quad (5)$$

となる。したがって cost-sensitive な boosting を実現するためには、式 (5) で表される損失関数を cost-insensitive な場合と同様に弱学習器  $f \in \mathcal{F}$  により逐次的に最適化すればよい。

### 3 AdaBoost における適応的しきい値調整

AdaBoost の場合には  $U(z) = \exp(z)$ ,  $\mathcal{F} = \{\alpha h \mid \alpha \in \mathbb{R}, h: \mathcal{X} \rightarrow \{-1, +1\}\}$  のもと、 $\mathcal{F}$  上での座標降下法で  $\mathcal{R}_C[H_T; D_0]$  を最適化する。座標降下法では勾配  $\frac{\partial \mathcal{R}_C[H_t, D_0]}{\partial \alpha_t}$  が大きくなるような弱分類器  $h_t$  が選択されるが、この操作は式 (7) で重み付けられた誤分類率の最小化 (式 (6)) と同義である。

$$h_t = \operatorname{argmin}_h \mathbb{E}_{(x,y) \sim D_t} [L(-yh(x))] \quad (6)$$

$$\begin{aligned} D_t(x, y) &= \exp(-y\tau^*) D_0(x, y) U'(-yF_t(x)) / Z_t \\ &= \frac{\exp(-y\tau^*) D_0(x, y) \exp(-yF_t(x))}{Z_t} \end{aligned} \quad (7)$$

ただし  $Z_t$  は正規化項である。特に式 (7) は cost-insensitive な AdaBoost において  $D_0(x, y) \leftarrow D_0(x, y) \exp(-y_i\tau^*)$  として分布更新式を適用することと同義である。

しかしながら、boosting の分布更新は初期分布の非対称性をすぐに打ち消してしまう<sup>4, 5)</sup> ため、 $D_0$  に導入された非対称性は最終的な分類器にはほとんど反映されない。そこで適応的しきい値調整手法では非対称性を保ちながら、さらには、各ステップ  $t$  における分類器  $H_t$  の FPR を  $FPR_{target}$  に近づけながら boosting を行うために分布更新式を式 (9) のように修正する。

$$FPR[F_{t-1} - \tau^{(t-1)}; D_0] = FPR_{target} \quad (8)$$

$$D_{t+1}(i) = \frac{\exp(-y_i\tau^{(t-1)}) D_t(i) \exp(-y_i\alpha_t h_t(x_i))}{Z_t} \quad (9)$$

ここで  $FPR[F; D]$  は分布  $D$  に対する分類器  $\operatorname{sign}[F]$  の偽陽性率、 $FPR_{target}$  は予め設定する FPR の目標値を表し、 $D_t(i) = D_t(x_i, y_i)$  とする。最終的なアルゴリズムを Algorithm 1 に示す。

さらに、適応的しきい値調整手法では cost-sensitive learning の罰則パラメータ  $\tau^*$  が  $\tau^{(t)}$  の累積値により推定される。 $\tau^*$  の推定値を  $\hat{\tau}_t$  とすると

$$\hat{\tau}_t = \sum_{s=1}^t \tau^{(s)} \quad (10)$$

である。2 節で述べたように、cost-sensitive learning では予め罰則値を決めた上で損失関数の最小化を行う。しかしながら実問題では罰則値の設定方法に明確な指針があることは少ない。提案手法は  $\tau^*$  を設定する代わりに FPR の目標値  $FPR_{target}$  をハイパーパラメータと設定している。すなわち、分類器の FPR が  $FPR_{target}$  になるように、cost-sensitive learning における罰則値を適応的に修正している。本研究の目的はトレードオ

---

#### Algorithm 1 Adaptive thresholding for AdaBoost

---

**Input:**

$FPR_{target}$  : allowable value for false positive rate  
 $T$  : maximum iterations of boosting  
 $\mathcal{D} = \{\mathbf{x}_i, y_i\}_{i=1}^N$  : training dataset

**Initialize:**

$D_0 = \frac{1}{N}$ ,  $F_0(\mathbf{x}) = 0$ ,  $\alpha_0 = 0$ ,  $h_0(\mathbf{x}) = 0$ ,  $\tau^{(0)} = 0$   
**for**  $t = 1 \dots T$  :

    Calculate threshold  $\tau^{(t-1)}$  satisfying bellow:

$$FPR[F_{t-1} - \tau^{(t-1)}; \mathcal{D}] = FPR_{target}$$

    Update the distribution  $D_t$ :

$$D_t(i) \leftarrow \exp(-y_i\tau^{(t-1)}) D_t(i) \exp(-y_i\alpha_{t-1} h_{t-1}(x_i))$$

    Normalize the distribution  $D_t$ :

$$D_t(i) \leftarrow \frac{D_t}{\sum_i D_t(i)}$$

    Train a weak learner  $h_t$  according to  $D_t$

    Calculate  $\alpha_t$  by using  $h_t$  and  $D_t$ :

$$\begin{aligned} \epsilon_t &= \sum_{y_i \neq h_t(x_i)} D_t(x_i) \\ \alpha_t &= \frac{1}{2} \ln \frac{1 - \epsilon_t}{\epsilon_t} \end{aligned}$$

    Produce a strong learner  $F_t$ :

$$F_t = F_{t-1} + \alpha_t h_t$$

**end for**

    Calculate threshold  $\tau^{(T)}$  satisfying bellow:

$$FPR[F_T - \tau^{(T)}; \mathcal{D}] = FPR_{target}$$

**Output:**  $H_T(\mathbf{x}) = \operatorname{sign}[F_T(\mathbf{x}) - \tau^{(T)}]$

---

フ関係にある TPR と FPR を明示的に制御する事があり、 $FPR_{target}$  は直感的なハイパーパラメータとして機能する。

### 4 AdaBoost 以外の手法に対する適応的しきい値調整

適応的しきい値調整は分布の更新則のみを修正しており、AdaBoost 以外の boosting 手法にも適用可能である。

また、AdaBoost は boosting の中でも特に有名なアルゴリズムであるが以下のような欠点も存在する。

- $F_t(x)$  が連続ではなく離散的である
- 訓練データに外れ値が含まれていた場合に影響を受けやすい

$F_t(x)$  が離散的な場合には式 (8) を満たす  $\tau^{(t)}$  が存在しない可能性があり、そうした場合には  $FPR_{target}$  に追従するようなしきい値調整ができない。加えて、TPR と FPR の制御が重要となる問題では、正例と負例が特



微空間上で重なっている状況が存在する。AdaBoost では正例と負例の重なり部分の誤分類が過剰に強調されてしまうため、FPR の目標値に対する追従性に悪影響を与えてしまう。外れ値に対してロバストな boosting アルゴリズムとしては MadaBoost<sup>6, 7)</sup>、連続値を出力する Gentle AdaBoost<sup>8)</sup> が挙げられる。また、MadaBoost や Gentle AdaBoost は AdaBoost に対する変更点が少なく、逐次的しきい値調整手法の適用が容易である。そこでこの二つの boosting 手法に関して適応的しきい値調整を適用する方法を次に述べる。

#### 4.1 MadaBoost に対する適応的しきい値調整

MadaBoost は訓練データセットに外れ値を含む場合や、フィルタリング技法により boosting を行う場合に有効な手法である<sup>6, 7)</sup> MadaBoost は AdaBoost と同様に離散値を出力し、座標降下法により最適化される。AdaBoost との違いは  $U(z)$  である。MadaBoost では式 (11) が  $L(z)$  の上界として利用され、その一次導関数は式 (12) で表される。

$$U(z) = \begin{cases} 1+z & z \geq 0 \\ \exp(z) & z < 0 \end{cases} \quad (11)$$

$$U'(z) = \begin{cases} 1 & z \geq 0 \\ \exp(z) & z < 0 \end{cases} \quad (12)$$

訓練データに外れ値が含まれていた場合、 $z = -yF(x)$  の値は一般に大きくなる。AdaBoost で用いられる  $U'(z) = \exp(z)$  は  $z$  が大きいデータに対して指数的に重みをつけて訓練するため、外れ値の影響が残りやすい(式 (7) 参照)。一方で MadaBoost では、 $z \geq 0$  に関して  $U'(z) = 1$  である。したがって、外れ値を含めた誤分類に対する罰則が過剰に大きくなりにくい。結果として外れ値の影響が残りにくい最適化手法になっている。

MadaBoost における適応的しきい値調整は式 (9) の変更以外は AdaBoost と同様である。

$$\begin{aligned} D_t(x, y) &= \exp(-y\tau^{(t-1)})D_0(x, y)U'(-yF_t(x))/Z_t \\ &= \frac{\exp(-y\tau^{(t-1)})D_0(x, y) \min(1, \exp(-yF_t(x)))}{Z_t} \end{aligned} \quad (13)$$

#### 4.2 Gentle AdaBoost に対する適応的しきい値調整

Gentle AdaBoost は  $U(z)$  は AdaBoost と同じ exponential 関数であるが、 $\mathcal{F} = \{f \mid f: \mathcal{X} \rightarrow \mathbb{R}\}$  のように弱学習器が連続値を出力する。これに伴い、 $\mathcal{R}_C$  の greedy な最適化が closed-form で表現できなくなる。そこで Gentle AdaBoost では  $\mathcal{R}_C$  をニュートン法で最適化する。具体的には、式 (5) を  $f_t(x) = 0$  の周りで二次導関数近似した上で最適化を行う。結果的には AdaBoost と  $D_t$  の更新方法は変わらないものの、式 (14) のように  $f_t(x)$  と  $y$  との重み付き二乗誤差が最小になるように  $f_t$  が獲得される。

$$f_t = \operatorname{argmin}_{f \in \mathcal{F}} \mathbb{E}_{(x, y) \sim D_t} [(y - f(x))^2] \quad (14)$$

連続値を出力する学習器が得られる boosting としては Gentle AdaBoost 以外にも Real AdaBoost や Logit Boost などが挙げられる。しかしながら文献<sup>8)</sup> で説明されているように Real AdaBoost や Logit Boost は、事後分布  $P(+1 \mid x)$  が 0 や 1 に近いような場合に数値的に不安定になってしまう。さらに同文献では Gentle AdaBoost の性能は基本的に Real AdaBoost および Logit Boost と同等がそれ以上と述べられていた。こうした理由から本研究では  $F_t(x)$  が連続になるような boosting 手法として Gentle AdaBoost を採用している。

## 5 実験

AdaBoost で適応的しきい値調整を行った場合、FPR の目標値に追従できない場合がある。この理由は 4 節で挙げた AdaBoost のいくつかの欠点の原因と予想される。そこで 4 節で挙げた MadaBoost と Gentle AdaBoost に関して、FPR の追従性の実験を行う。これらの手法は AdaBoost の欠点を回避することが期待される。AdaBoost, MadaBoost, Gentle AdaBoost それぞれに関して通常のしきい値調整手法と適応的しきい値調整の FPR 追従性を確認した。

各設定の boosting は独立に 30 試行ずつ行われ、そうして得られた FPR のばらつき度合いや中央値により追従性を評価する。

また、この実験では擬似データで評価を行う。正例と負例の分布に重なりが存在し、トレードオフの関係にある TPR と FPR を制御することが重要な問題設定として次のデータセットを用意した。

- 正例  $x_+ \sim \mathcal{N}(\mu_+, \sigma)$
- 負例  $x_- \sim \mathcal{N}(\mu_-, \sigma)$

を扱い ( $\mu_+ = +1, \mu_- = -1, \sigma = 1$ )、これらのデータの二値分類を行った。訓練データセットは 10000 個、テストデータはその 10 倍の 100000 個生成した。さらに、検出問題では一般的に正例と負例の個数が不均衡であることから、正例と負例の比率を 1:10 に設定した。すなわち  $\frac{P_Y(+1)}{P_Y(-1)} = \frac{1}{10}$  である。

続いて以下に学習の設定を示す。

- 弱学習器 (AdaBoost, MadaBoost): 決定木 (深さ 2)
- 弱学習器 (Gentle AdaBoost): 回帰木 (深さ 2)
- boosting ステップ数  $T = 100$
- FPR の目標値  $FPR_{target} = 0.159$

$FPR_{target} = 0.159$  というのは、識別の境界  $x = 0$  に対応している。正例と負例が不均衡な場合にも、均衡時の解を得られるか確認するためにこの値に設定した。

以上の設定で 6 つの手法を比較する。

1. AdaBoost + 通常のしきい値調整
2. AdaBoost + 適応的しきい値調整
3. MadaBoost + 通常のしきい値調整
4. MadaBoost + 適応的しきい値調整
5. Gentle AdaBoost + 通常のしきい値調整
6. Gentle AdaBoost + 適応的しきい値調整




Fig. 1: Box plot of FPRs.

### 5.1 実験結果

テストデータに対する FPR が  $FPR_{target}$  にどの程度追従するのかを Fig. 1 に示す. 図中の横軸のラベルはそれぞれの手法を表している. さらに図中の点線は  $FPR_{target}$  であり, 箱ひげ図の中央値が点線に近く, ばらつき度合いが小さいほど FPR の追従性が高い.

まずは, 同じ boosting 手法同士で比較する. 中央値に着目すると, どの boosting 手法においても適応的しきい値調整 (Adaptive) のほうが通常のしきい値調整 (Normal) よりも追従性が高いことが確認できる.

一方で, Fig. 2 に示す TPR の箱ひげ図に着目すると, Gentle AdaBoost に関する TPR の中央値は, Adaptive よりも Normal のほうが最適値に近い. TPR と FPR はトレードオフの関係にあり, FPR が  $FPR_{target}$  に近づいた場合には対応する TPR も最適値に近づくはずである. これが成り立たないということは, Gentle AdaBoost においては適応的しきい値調整を行うことにより FPR の追従性は高くなるものの, その結果過学習してしまい TPR が低下することを意味している.

続いて, boosting 手法の差異について検討する. Fig. 1 および Fig. 2 の箱ひげ図をみると, AdaBoost と MadaBoost の FPR や TPR のばらつき度合いは同程度である一方で, Gentle AdaBoost のばらつき度合いは前者二つと比較して小さい. この結果は Gentle AdaBoost が連続値に対応した学習器であることに起因する.

$F(x)$  が離散的である場合,  $FPR[F(x) - \tau] = FPR_{target}$  を満たす  $\tau$  が存在しない場合があるが,  $F(x)$  が連続であればそのような問題は生じない. しかしながら, Gentle AdaBoost の FPR のばらつき度合いが小さくなる一方で, FPR の中央値に関する追従性は他の boosting 手法と比べて低い. Fig. 2 の TPR の結果からみても, Gentle AdaBoost は他の 2 つの boosting 手法と比べて過学習しやすいことがわかった.

## 6 おわりに

実験結果から, 適応的しきい値調整は AdaBoost, MadaBoost, Gentle AdaBoost のいずれに対しても, FPR の追従性を高めることが確認された.

加えて 3 つの boosting 手法を比較すると, AdaBoost と MadaBoost は同じような性能を示した. ただし, MadaBoost はフィルタリング技法で良い性能を示すという利点がある. AdaBoost はフィルタリング技法に適したアルゴリズムではないと言われているが<sup>7)</sup>, MadaBoost に適応的しきい値調整を適用することで,




Fig. 2: Box plot of TPRs.

適応的しきい値調整をフィルタリング技法にも適用できる可能性がある.

一方で, Gentle AdaBoost は過学習を起こしやすく, さらに適応的しきい値調整により過学習が促進されることが Fig. 2 の結果から示唆された. しかしながら Gentle AdaBoost は FPR のばらつき度合いが小さいという特長もある. 今後は Gentle AdaBoost において過学習を抑えながら適応的しきい値調整を適用し, FPR のばらつきを抑えながらも目標値への追従性を高める手法を検討する.

### 参考文献

- 1) Charles Elkan: The foundations of cost-sensitive learning, In *International joint conference on artificial intelligence*, **17**, 973/978 (2001)
- 2) 佐々木勇人, 中田雅也, 山本みづき, 竹島徹平, 湯村寧, 濱上知樹: 生殖医療支援を目的とした精子検出における偽陽性率の調整に関する検討, 第 45 回知能システムシンポジウム講演論文集 (2018)
- 3) Yoav Freund and Robert E Schapire: A decision-theoretic generalization of on-line learning and an application to boosting, In *European conference on computational learning theory*, 23/37 (1995)
- 4) Paul Viola and Michael Jones: Fast and robust classification using asymmetric adaboost and a detector cascade, In *Advances in neural information processing systems*, 1311/1318 (2002)
- 5) Hamed Masnadi-Shirazi and Nuno Vasconcelos: Cost-sensitive boosting, *IEEE Transactions on pattern analysis and machine intelligence*, **33-2**, 294/309 (2011)
- 6) Carlos Domingo, Osamu Watanabe et al.: MadaBoost: A modification of AdaBoost, In *COLT*, 180/189 (2000)
- 7) 金森敬文, 畑埜晃平, 渡辺治: ブースティング: 学習アルゴリズムの設計技法, 森北出版 (2006)
- 8) Jerome Friedman, Trevor Hastie, Robert Tibshirani et al.: Additive logistic regression: a statistical view of boosting (with discussion and a rejoinder by the authors), *The annals of statistics*, **28-2**, 337/407 (2000)

# CXR8 医療ベンチマーク画像を用いた構造適応型 Deep Belief Network による検診データの分析

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

## An Adaptive Structural Learning Method of Deep Belief Network using CXR8 database and Its analysis of Comprehensive Medical Examination Data

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

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

**Abstract**— 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. Moreover, a system predicting a probability of cancer was developed by training the comprehensive medical examination data on the proposed method. In this paper, the classification accuracy of the adaptive DBN is verified on the chest X-ray image benchmark data set CXR8. Moreover, the training result of CXR8 is embedded to the system in order to improve the precision of the cancer prediction. The classification accuracy of the experiment result is reported in this paper.

**Key Words:** Deep Learning; Deep Belief Network; Restricted Boltzmann Machine, Adaptive Structure Learning; Comprehensive Medical Examination Data; CXR8

## 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>. さらに, 提案手法を健康診断における血液検査データや癌検診結果が記録されている医療画像を含む医療検診データ<sup>12)</sup> に適用し, 癌の可能性を予測する深層学習システムを開発し, タブレット端末上で予測結果を医師に提供するシステムを構築した<sup>13)</sup>. ここでは, 入力データとして医療画像が検査項目に含まれていない場合でも, 血液検査データの異常項目の関係性から癌の可能性を計算することができる. 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.

検診データの中で, 胸部 X 線検査は, 一般の定期健康診断に含まれている簡易的な検査であるため, 癌検診のデータに比べて多くのデータが蓄積されているが, 癌等の病気に関するラベルは与えられておらず, 要検査等の判定結果に留められている. 一方, 上記のような実際の検診データとは異なり, 胸部 X 線画像ベンチマークテストとして ChestX-ray8(CXR8)<sup>14)</sup> が公開されている. CXR8 には, 要検査等の判定ではなく, 肺に関する病気や癌に関する症状ラベルが与えられている. そこで, 本論文では, CXR8 で学習したモデルに検診データの胸部 X 線画像を与え, 要検査の判定しか与えられていないデータから癌予測を試みた. さらに, 以前提案した Fine Tuning 法<sup>15)</sup> を用いて, 精度が向上するようにモデルの Tuning を行った. その結果, 胸部 X 線画像から高い精度で癌予測可能なモデルを構築できた. 本論文では, 得られた分類精度について報告する.

## 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.

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



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

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

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  $v_i$  に対するパラメタ、  $c_j$  は  $h_j$  に対するパラメタ、  $W_{ij}$  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 패턴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>16)</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>17)</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 つのパラメタ  $\theta = \{\mathbf{b}, \mathbf{c}, \mathbf{W}\}$  のうち、CD 法による学習の収束に関係しているパラメタは  $\mathbf{c}$  と  $\mathbf{W}$  とした<sup>18)</sup>。この 2 つのパラメタの関連生から、ニューロン生成条件を式 (4) に示すように定義した<sup>19)</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>17)</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

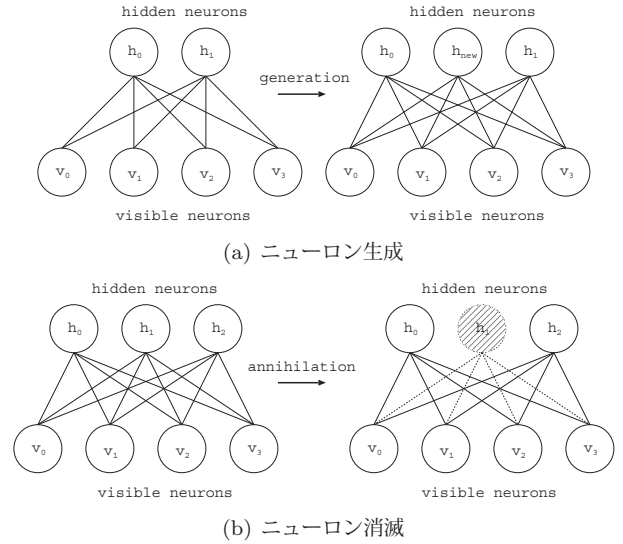


Fig. 1: 構造適応型 RBM

場合がある。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値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 (パラメタ  $\mathbf{c}$  と  $\mathbf{W}$  の変分) を観察したが、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  $W_j^l$  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

Table 1: CXR8 のカテゴリ

分類		データ数	
正常	正常: No Finding	60,361	
異常	癌	形状大: Mass	5,782
		形状小: Nodule	6,331
	その他	肺拡張不全: Atelectasis	11,559
		心肥大: Cardiomegaly	2,776
		胸水: Effusion	13,317
		肺浸潤: Infiltration	19,894
		肺炎: Pneumonia	1,431
気胸: Pneumothora	5,302		
合計		112,120	




Fig. 2: ROC 曲線

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 構造適応型 DBN による CXR 胸部 X ベンチマーク画像の分類

“ChestX-ray8 (CXR8)” は、文献<sup>14)</sup>によって公開されている胸部 X 線画像のベンチマークテストである。30,805 人の患者から収集した 112,120 枚の胸部 X 線画像が含まれており、Table 1 に示すように、各画像は、正常ラベル及び 8 種類の異常ラベルに分類される。これらの 8 種類の異常ラベルの中には、癌に関連する症状として、“Mass” と “Nodule” が定義されている。なお、全 112,120 個のデータは、訓練データ 86,524 個とテストデータ 25,596 個に予め分割されている。

提案手法の構造適応型 DBN を用いて CXR8 の学習を行った。提案手法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。これらのパラメータの値は、予備実験の結果による最良の組み合わせである。

Table 2 は、テストデータの各症状に対する分類精度

を示している。Table 2 の “ResNet-50” は ResNet<sup>4)</sup> と呼ばれる深層学習モデルを用いた精度である。この数値は文献<sup>14)</sup>に記載されているが、ResNet と比較して、提案手法は全ての症状ラベルに対して高い分類精度を示すことができた。

Fig. 2 は、提案手法の各症状ラベルの分類結果に対する ROC (Receiver Operating Characteristic) 曲線を示している。ROC 曲線とは、縦軸に、陽性を陽性と正しく予測する率である Sensitivity、横軸に、陰性を誤って陽性と予測する率である 1-Specificity をプロットした曲線である。ROC 曲線と縦軸と横軸で囲まれた面積ができるだけ大きいものほど良いモデルである。文献<sup>14)</sup>に記載されている ResNet の ROC 曲線と比較して、Fig. 2 の ROC 曲線の方が、各症状に対して良い精度を示している。

さらに、文献<sup>15)</sup>で提案されている知識獲得手法を用いて、Fine Tuning を行った。Fine Tuning より、CXR8 の各症状に対する分類精度は数%向上した。特に、正常 (No Finding) と異常 (その他) の肺拡張不全 (Atelectasis) に対する精度が大きく向上し、全ての症状ラベルに対して 90% 以上の分類精度を示した。

### 4 CXR を用いた検診データの癌予測

我々は、広島県環境保健協会<sup>12)</sup>から提供された定期健康診断データを用いて、癌の可能性を予測するシステムを開発している。構築したネットワークは、テストデータに対し 95.5% の高い精度で予測できている<sup>13)</sup>。ここでは、入力データとして医療画像を与えない場合でも、画像の平均的な特徴を与えることで、血液検査データの異常項目の関係性から癌の可能性を予測している。また、Fig. 3 に示すように、入力された検診データから癌の可能性を予測するタブレットインターフェースを開発し、その結果を医師に提供するシステムを構築している。

3 節で示したように、構造適応型 DBN は CXR8 に対し高い分類精度を示した。本論文では、CXR8 で学習したモデルを用いて、癌の判定結果が与えられていない一般の検診データの胸部 X 線画像から癌の予測を行った。検診データは、広島県環境保健協会<sup>12)</sup>から提供された定期健康診断データである。2012 年から 2015 年の 4 年間で、118,165 人の記録であり、一般的な健康診断に含まれている胸部 X 線画像と、癌検診に含まれている胸部 CT 画像がある。癌検診は、一般的に健康診断において異常があった場合の精密検査として行われるため、胸部 CT 画像のデータ数は胸部 X 線画像のデータ数に比べて極めて少ない。また、胸部 X 線画像には癌の判定に関する情報は与えられていない。

Table 3 は、CXR8 で学習したモデルに検診データの胸部 X 線画像を与えた結果を示している。全データに対し、正常と予測された割合は 86.0% となり、癌と予測された割合は 1.0% となった。また異常であるが癌以外の病気 (その他) に予測された割合は 13.0% となった。Table 4 は、Table 3 の予測結果の各分類に対する精度を示している。正常、異常 (その他) に比べて、異常 (癌) に対する精度が低くなっている理由は、癌と予測された 1,298 件のデータの中に、検診において要検査と判定されているものの、癌検診を受けていないデータが一定数いるためである。



Table 2: CXR8 の分類精度

分類		Accuracy			
		ResNet-50	DBN	DBN(Fine Tuning)	
正常	正常: No Finding	-	87.0%	90.4%	
異常	癌	形状大: Mass	56.0%	94.2%	95.0%
		形状小: Nodule	71.6%	98.7%	98.8%
	その他	肺拡張不全: Atelectasis	70.6%	81.8%	90.5%
		心肥大: Cardiomegaly	81.4%	99.5%	99.5%
		胸水: Effusion	73.6%	99.6%	96.8%
		肺浸潤: Infiltration	61.2%	95.2%	96.3%
		肺炎: Pneumonia	63.3%	95.8%	96.0%
気胸: Pneumothora	78.9%	95.9%	96.9%		

Table 3: CXR8 で学習したモデルに環保協様の胸部 X 線画像を与えた結果

分類		予測されたデータ数	合計
正常	正常: No Finding	111,642 (86.0%)	111,642 (86.0%)
異常	癌	形状大: Mass	519 (0.4%)
		形状小: Nodule	779 (0.6%)
	その他	肺拡張不全: Atelectasis	4,207 (3.1%)
		心肥大: Cardiomegaly	2,337 (1.8%)
		胸水: Effusion	4,147 (3.2%)
		肺浸潤: Infiltration	2,277 (1.8%)
		肺炎: Pneumonia	1,508 (1.2%)
		気胸: Pneumothora	2,428 (1.9%)
合計		16,907 (13.0%)	129,847 (100.0%)

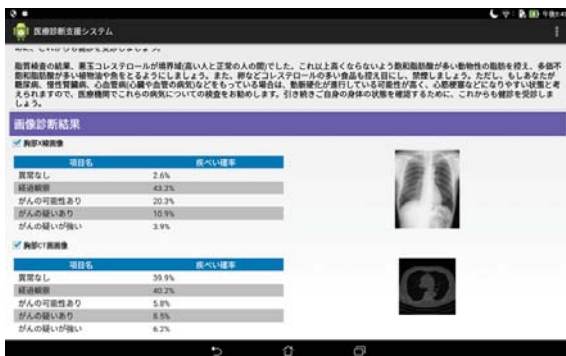


Fig. 3: 医療診断支援システム

胸部 X 線画像からシステムにより癌と予測されたデータは、1,298 件あり、このうち、実際に癌検診を受けたデータと、癌検診を受けていないデータは、それぞれ 910 件、388 件あった。癌検診を受けた 910 件の 98.0% が実際の胸部 X 線において要検査と判定されている。一方で、要検査と判定されているのにも関わらず、癌検診を受けていないデータが 252 件 (65.2%) あった。また、システムで癌と予測されたが、実際の胸部 X 線において正常と判定され、癌検診を受けていないデータは 136 件 (34.8%) あった。このデータを調査したところ、136 件中 91 件 (67.2%) は、実際の胸部 X 線において正常と判定されているものの、医師の所見において軽度な異常に関するコメントが記されており、今後の経過観察において注意が必要なデータである。

システムが癌と予測し、癌検診を受けた 910 件のデー

タに対し、胸部 X 線の判定結果 (要検査・正常) と癌検診の判定結果 (癌・癌でない) の関連を調査したところ、実際の胸部 X 線画像で正常と判定されているが、癌検診の結果、癌であったデータが数件あった。この結果については、データ数は少ないが、医師のヒューマンエラーによる誤判定である可能性も考えられる。また、システムにより癌と予測され、実際の胸部 X 線において要検査と判定されたが、癌検診の結果、癌でなかったデータは 339 件 (38.0%) あった。実際の癌検診を受けた中で癌と判定されている割合が 45.1% であることから、この 38.9% という数値はそれほど低い数値ではないと考えられる。

本実験では、CXR8 の分類における Mass (形状大) と Nodule (形状小) を癌と定義している。システムの分類結果を調査したところ、Mass に比べて、Nodule に分類されたデータ数の方が比較的多いが、一方で、Mass の方が、胸部 X 線画像の判定で要検査と判定され、実際に癌検診を受けた割合は多い。逆に、Nodule には、実際の胸部 X 線において正常と判定されているのにも関わらず、癌検診を受けた結果、癌だったケースが見られた。システムの分類精度で比較したところ、システムが癌と予測し、癌検診の結果、実際に癌であった割合は、Nodule に比べて Mass の方が高くなり、その数値は Nodule が 43.8% (228/520)、Mass が 85.4% (333/390) であった。予測した結果に対する精度のみを考えれば、Mass のみを考慮した方が精度は上がるが、Nodule と予測され癌と判定された件数も一定数いることから、両者の関係はトレードオフであると言える。

Table 4: システムの予測結果に対する分類精度

分類	予測されたデータ数	分類精度	Fine Tuning
正常	111,642	91.3%	91.8%
異常 (癌)	1,298	43.2%	47.0%
異常 (その他)	16,907	88.2%	90.4%

胸部 X 線画像から癌以外の異常と予測されたデータ数は 16,907 件だった。この 16,907 件のデータに対しては、98.2%が癌検診を受けていないが、癌検診を受け、かつ癌と判定されたデータが 4 件あった。この 4 件については、本来癌であるデータをシステムが発見できなかった事例である。なお、システムの予測結果で正常と予測された中で、実際に癌であった事例は見られなかった。

CXR8 と同様に、検診データの結果に対しても、Fine Tuning を行った。Table 3 に示すように、各症状に対して数%分類精度が向上した。Fine Tuning により、1)Fine Tuning 前ではシステムが癌と誤って予測した事例が、Fine Tuning 後に、癌でないと正しく予測できるようになったケース、2)Fine Tuning 前ではシステムが癌でないと誤って予測した事例が、Fine Tuning 後に、癌であると正しく予測できるようになったケースが見られた。結果として、癌検診を受けた事例の中で、癌を癌と予測できた割合が 99.8%から 99.9%に増えた、また、システムにより癌と予測されたが、実際には癌でなかった割合が 38.3%から 28.9%に減少した。

## 5 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/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。提案したモデルを医療検診データに適用し、癌の可能性を予測する深層学習システムを開発し、タブレット端末上で予測結果を医師に提供するシステムを開発している。本論文では、胸部 X 線画像のベンチマークテスト CXR8 で学習した深層学習モデルを用いて、通常の検診データの胸部 X 線画像の分類を行った。CXR8 で学習した深層学習モデルは、90%以上の高い確率で癌の有無を分類できている。ベンチマークテストを用いたシステムによる評価の結果、ほとんどのケースにおいて、癌に対するシステムの予測結果と医師による判定は概ね一致していた。一方で、システムが癌と判定し、人間は正常と判定したケースや、逆に、システムは正常と判定し、人間は癌と判定したケースも少ないながら発見できた。このような結果の中には、ヒューマンエラーによる医師の誤判定の可能性も含まれており、今後の追加調査が必要である。また、システムや医師により、要検査と判定されたにも関わらず、実際には精密検査を受けていない患者が一定数見られた。このようなケースの中には、実際には癌である事例も含まれている可能性が考えられる。本実験の結果として、簡易検査のため要検査等の判定のみしか与えられていない胸部 X 線画像から、癌等の詳細な病変を予測することが可能になった。

## 謝辞

本研究開発は JSPS 科研費 (課題番号: JP17J11178) 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 回コンピュータショナル・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) 広島県環境保健協会: <http://www.kanhokyo.or.jp/>, (2017 年 12 月 2 日閲覧)
- 13) 鎌田真, 市村匠: **学習率変化と忘却効果を取り入れた構造適応型 Deep Belief Network 学習による検診データの分類**, 計測自動制御学会システム・情報部門学術講演会 2017 講演論文集 (SSI2017), 119/124 (2017)
- 14) X.Wang, Y.Peng, L.Lu, Z.Lu, M.Bagheri, R.M.Summers, *ChestX-ray8: Hospital-scale Chest X-ray Database and Benchmarks on Weakly-Supervised Classification and Localization of Common Thorax Diseases*, Proc. of IEEE CVPR, 3462/3471 (2017)

- 15) S.Kamada and T.Ichimura: *Fine Tuning of Adaptive Learning of Deep Belief Network for Misclassification and its Knowledge Acquisition*, International Journal Computational Intelligence Studies, vol.6, no.4, 333/348 (2017)
- 16) G.E.Hinton: *Training products of experts by minimizing contrastive divergence*, Neural Computation, vol.14, no.8, 1771/1800 (2002)
- 17) T.Ichimura and K.Yoshida Eds.: *Knowledge-Based Intelligent Systems for Health Care*, Advanced Knowledge International (ISBN 0-9751004-4-0) (2004)
- 18) 鎌田真, 市村匠, 原章: ニューロン生成/消滅アルゴリズムによる構造適応型 *Restricted Boltzmann Machine*, 計測自動制御学会第8回コンピューテーショナル・インテリジェンス研究会講演論文集, 90/96 (2015)
- 19) 鎌田真, 市村匠: リカレント構造適応型 *Deep Belief Network* による時系列データの学習, 計測自動制御学会論文集 (to appear in 2018)

# 自己構成型の大脳新皮質学習アルゴリズムに関する検討

○鈴木嶺 聡哲 青木 健 高玉 圭樹 佐藤 寛之 (電気通信大学)

## A Study on Self-Structured Cortical Learning Algorithm

\*S. Suzugamine T. Aoki K. Takadama and H. Sato  
(The University of Electro-Communications)

**Abstract**— The cortical learning algorithm is one of time-series data prediction algorithms based on the human neuro cortex. The cortical learning algorithm uses multiple columns to represent input data, and each column has multiple cells to represent time-series pattern of input data. The numbers of columns and cells are user-defined parameters for the conventional cortical learning. Their appropriate parameters depend on input data. However, characteristics of input data are generally unknown before the learning. To avoid the parameter settings of the number of columns and cells, in this work we propose a self-structured cortical learning algorithm which dynamically adding columns and cells according to input data. Experimental results using test time-series data involving a sine wave, its combined one, and the logistic mapping of Chaos show not only the proposed method can dynamically struct columns and cells depending on input data but also the prediction accuracy is also improved.

**Key Words:** time-series prediction, cortical learning algorithm

### 1 はじめに

時系列データを予測する階層時間記憶は、哺乳類の大脳新皮質をモデル化した概念である<sup>1)</sup>。階層時間記憶を具現化したアルゴリズムの1つに大脳新皮質アルゴリズム (Cortical Learning Algorithm, 以下CLA)<sup>2, 3)</sup>がある。CLAの学習器は、複数のカラムと、複数のセルによって構成される。各カラムは、複数のセルを内包する。また、各カラムは、複数の入力データビットとの間にシナプスを持つ。カラムは、入力データビットとのシナプス接続によって活性状態になり、複数のカラムの活性パターンによって入力データを表現する<sup>4, 5)</sup>。また、セルとセルの間にもシナプスネットワークがあり、その関係によってセルの状態を遷移させることで、入力データの時系列パターンを表現・予測する。関連研究として、従来のニューラルネットワークに基づく時系列予測モデルであるリカレントニューラルネットワーク<sup>6)</sup>や長短期記憶 (Long Short-Term Memory, 以下LSTM)<sup>7)</sup>がある。これらにおいては、シナプスネットワークを構築するために、計算コストがかかる最適化を要することが基本だが、CLAは、シナプスネットワークを簡素なアルゴリズムで構築できる利点がある。応用例としては、異常検知への適用<sup>8)</sup>があり、また、タクシー乗車数の時系列予測において、CLAはLSTMより高い予測精度を示すことが報告されている<sup>9)</sup>。CLAは、有望な時系列予測アルゴリズムのひとつではあるものの、カラムとセル数をパラメータとして事前に設定しなければならないところに問題がある。適切なカラムとセルの数は入力データによって異なるが、入力データは未知であるため、適切なカラムとセル数を事前に設定することは困難である。

本研究では、CLAにおけるカラムとセルの数の事前設定を不要にすることを目的とし、入力される時系列データに合わせて動的にカラムとセルを構成する方法を提案する。すなわち、提案法は、入力データにあわせて学習器を自己構成する。正弦波、正弦波の合成波、カオスのロジスティック写像を時系列予測する実験において、提案法の効果を検証する。

### 2 大脳新皮質学習アルゴリズム (CLA)

#### 2.1 学習器

CLAの学習器の構成をFig. 1に示す。CLAの学習器全体をリージョンと呼ぶ。リージョン内には、複数のカラムが存在する。それぞれのカラム内には、複数のセルが存在する。入力データはバイナリビット列で表現し、各ビットとカラムの間にシナプスを用意する。また、セルとセルの間にもシナプスを用意する。Fig. 1は、リージョン内に5つのカラムがあり、各カラムが5つのセルを持つ場合の例である。

##### 2.1.1 カラム

カラムには、活性と通常の2状態がある。各カラムは、シナプス接続された入力データビットの1の数が一定数以上のときに活性状態になり、それ以外は通常状態になる。カラムの役目は、入力データビット列をカラム群の活性パターンによって学習器の内部表現に変換することである。カラム数が多い場合は内部表現できる入力データの粒度が高く、カラム数が少ない場合は内部表現できる入力データの粒度が低くなる。

従来のCLAでは、カラム数を事前にパラメータとして決定する必要がある。

##### 2.1.2 セル

セルには、通常、活性、予測の3状態がある。これらの状態を用い、セルは2つの役目をこなす。




Fig. 1: CLAの構成






Fig. 2: カラムの活性




Fig. 3: カラムのシナプスの更新




Fig. 4: セルの活性

1つ目は、同一のデータ値が入力され、カラムによる内部表現が等しくても、その前に入力されたデータの時系列が異なれば、それを区別できるようにする役目である。これには、セルの活性状態が使われる。具体的には、活性したカラムの中に、予測状態のセルが存在すれば、そのセルを活性させる。予測状態のセルが存在しない場合、すべてのセルを活性させる。このように、入力されたデータの文脈情報を表現する。

2つ目は、次の入力データを予測する役目である。これには、セルの予測状態が使われる。具体的には、すべてのセルについて、シナプス接続されたセルの活性数が一定数以上のセルを予測状態にする。すなわち、次の入力データで活性状態になるカラム内のセルを予測状態にできれば、予測成功ということになる。セル数は多いほど、多数の時系列パターンを表現可能になるが、適切なセル数は入力データによって異なる。

従来のCLAでは、セル数を事前にパラメータとして決定する必要がある。また、すべてのカラムにおいて等しいセル数が用いられる。

## 2.2 入力変換

実数値のデータをバイナリビット列に変換してCLAの学習器に入力する。本研究では、入力される実数値  $X(t)$  を、バイナリビット列における1のチャンクの位置に変換する。実数値の入力データの最大値を  $max$ 、最小値を  $min$ 、変換後のバイナリビット列の長さを  $n$ 、チャンクの長さを  $w$  とすると、入力バイナリビット列  $\mathbf{x}(t) = (x_1(t), x_2(t), \dots, x_n(t)) \in \{0, 1\}^n$  は、次式で表される。

$$x_i(t) = \begin{cases} 1, & \text{If } \left\lfloor \frac{(X(t)-min) \cdot (n-w)}{max-min} \right\rfloor < i \leq \left\lfloor \frac{(X(t)-min) \cdot (n-w)}{max-min} \right\rfloor + w, \\ 0, & \text{Otherwise,} \end{cases} \quad (i = 1, 2, \dots, n). \quad (1)$$

## 2.3 空間プーリング

$t$  時点における入力データ  $\mathbf{x}(t)$  を、カラムの活性パターンによって学習器の内部表現に変換する処理を空間プーリングという<sup>4, 5)</sup>。

### 2.3.1 カラムの活性

各カラムは、複数のシナプスを持つ。各シナプスは、異なる入力データビットに配置される。各シナプスには、永続値  $p_{sp} = [0, 1]$  がある。永続値の閾値  $T_{sp}$  に対して、 $p_{sp} \geq T_{sp}$  のときに接続状態、 $p_{sp} < T_{sp}$  のときに切断状態になる。学習開始前、各カラムは、近くの

データビット列にシナプスを配置する。この際、ランダムに半数のシナプスを接続状態 ( $p_{sp} \geq T_{sp}$ ) にし、残りの半数のシナプスを切断状態 ( $p_{sp} < T_{sp}$ ) にする。

入力データ  $\mathbf{x}(t)$  を学習器の内部表現に変換するため、各カラムについて、データビット1と接続状態にあるシナプス数を重複数  $ol_c$  として計数し、 $ol_c$  が閾値  $T_{ol_c}$  以上のカラムを活性候補にする。活性候補のカラム群から、前回活性状態になってからの経過時間の長さと同重複数  $ol_c$  の多さを考慮して、複数のカラムを活性状態にする。Fig. 2は、重複数  $ol_c$  が高い2つのカラムが活性状態になる例を示している。この手順により、入力データビット列  $\mathbf{x}(t)$  が、カラム群の活性パターンによる学習器の内部表現に変換される。

### 2.3.2 シナプスの永続値の更新

活性状態になったカラムが持つシナプスの永続値  $p_{sp}$  を更新する。入力データビット1に配置されたシナプスの場合、永続値を  $\Delta p_{sp}^+$  増加させることで接続を促す。入力データビット0に配置されたシナプスの場合、永続値を  $\Delta p_{sp}^-$  減少させることで切断を促す。Fig. 3は、カラムの活性に寄与した赤色のシナプスの永続値を  $\Delta p_{sp}^+$  増加させ、活性に寄与しなかった青色のシナプスの永続値を  $\Delta p_{sp}^-$  減少させる例を示している。

## 2.4 時間プーリング

空間プーリングによって決定した活性状態のカラム内のセルのうち、活性状態にするセルを決定する処理を時間プーリングという。これにより、入力データの時系列における出現パターンを学習器内において表現する。さらに、現在の活性状態のセルから、次の入力データで活性状態になるセルを予測するために、セルを予測状態にする処理を施す。これにより、時系列におけるデータの出現パターンを予測する。

### 2.4.1 セルの活性

各セルも、複数のシナプスを持つ。セルの各シナプスは、異なるセルに配置される。各シナプスには、永続値  $p_{tp} = [0, 1]$  がある。永続値の閾値  $T_{tp}$  に対して、 $p_{tp} \geq T_{tp}$  のときに接続状態、 $p_{tp} < T_{tp}$  のときに切断状態になる。セルのシナプスの接続・切断状態は、セルを活性状態、予測状態にするために利用する。

まず、活性状態の各カラムに含まれるセルの中で、活性状態にするセルを決定する。活性状態の各カラムにおいて、1時点前の  $t-1$  時点のデータ入力によって予測状態になったセルが存在すれば、そのセルを活性状態にする。予測状態のセルが存在しない場合、カラム内のすべてのセルを活性状態にする。Fig. 4では、 $t-1$






Fig. 5: セルのシナプス更新




Fig. 6: セルの予測状態化




Fig. 7: カラムの自己構成 (提案)

時点で予測状態だったセル  $c_1$  が、 $t$  時点では活性状態のカラム内に存在するため、活性状態になる例を示している。  $t-1$  時点で予測状態だったセル  $c_2$  が存在するカラムは、 $t$  時点では通常状態になるため、セル  $c_2$  は活性状態にしない。また、 $t-1$  時点において予測状態のセルが存在せず、 $t$  時点において活性状態になったカラムでは、すべてのセルを活性状態にしている。

## 2.5 シナプスの永続値の更新

予測状態から活性状態になったセルのシナプスの永続値を更新する。これを Fig. 5 に例示する。  $t$  時点で活性状態になったセル  $c_3$  に注目する。  $t-1$  時点で、セル  $c_3$  が予測状態になったときに、活性状態だったセルとの間に存在するシナプスの永続値  $p_{tp}$  を  $\Delta p_{tp}^+$  増加させることで接続を促し、それ以外の通常状態のセルとの間に存在するシナプスの永続値  $p_{tp}$  を  $\Delta p_{tp}^-$  減少させることで切断を促す。

### 2.5.1 セルの予測

次に、予測状態にするセルを決定する。学習器内に存在する各セルについて、活性状態のセルと接続状態のシナプス数を  $ol_e$  として計数し、閾値  $T_{ol_e}$  以上になれば予測状態にする。予測状態のセル群は、次に入力されるデータを予測するための学習器における内部表現になる。 Fig. 6 は、セル  $c_4$  に注目する例を示す。実線は接続状態、破線は切断状態のシナプスを示す。  $t$  時点で、セル  $c_4$  は、活性状態のセルと接続状態のシナプスを  $ol_e = 2$  本持つ。これが閾値  $T_{ol_e} = 2$  以上となり、セル  $c_4$  を予測状態にしている。

## 2.6 出力変換

予測状態のセル群から予測値を算出する。本稿では、まず、各入力データビットに対して、予測状態のセルが存在するカラムと接続状態にあるシナプス数を計数する。その数が大きい順に入力データビットのチャンク長  $w$  までを 1、それ以外を 0 として予測データビット列を生成する。予測データビット列から実数の予測値へ変換するとき、全ビット長  $n$  における 1 のチャンク長  $w$  で表現できるすべてのビット列に対して、予測データビット列とのハミング距離が最も短いビット列に対応する実数値を出力する。

## 3 問題点：カラムとセル数の事前設定

従来の CLA は、カラムとセルの数を事前にパラメータとして設定しなければならないところに問題がある。カラムは多いほど、入力データを高粒度に内部表現へ変換できる。セルは多いほど、時系列における出現パ

ターンを高粒度に内部表現へ変換できる。しかし、カラムとセルは、多いほど計算コストを必要とするだけでなく学習速度も低下するため、単に多くすれば良いというわけにはいかない。また、入力する時系列データによって、適切なカラムとセル数は異なる。入力データは未知であるため、適切なカラムとセルの数を事前に設定することは困難である。さらに、従来の CLA は、すべてのカラムが同一数のセルを持つが、入力データによっては、多数のセルを必要とするカラムとそうでないカラムが生じる。そのため、セル数の設定によっては、セルが不足するカラムが存在したり、無駄なセルが存在するカラムが存在したりする。

これらの問題を解決するためには、入力データに合わせてカラムとセル数を自己調整し、学習器を自己構成することが有効と考えられる。

## 4 提案：自己構成型 CLA

本稿では、CLA の学習器を構成するカラムとセル数を入力データに合わせて動的に配置・利用する自己構成型 CLA を提案する。これにより、未知の入力データを受け取る前に学習器の規模を設定しなければならない従来の CLA の問題を打破する。

提案する自己構成型 CLA の特徴は、カラムを自己構成する動的空間プーリング、セルを自己構成する動的空間プーリングである。我々は、これまでもカラムとセルの動的構成に関して基礎的な検討をしてきた<sup>10)</sup>。本稿で提案するアルゴリズムには、動的空間プーリングで追加するカラムに対して入力データビットと複数のシナプスを自動的に配置する仕組み、動的空間プーリングにおいて複数時点をさかのぼってシナプスネットワークを再構築する仕組みを新たに追加する。

### 4.1 動的空間プーリング

動的空間プーリングでは、入力データにあわせてカラムを構成した上で、入力データをカラムの活性パターンによる内部表現に変換する。

まず、存在する各カラムについて、データビット 1 と接続状態にあるシナプス数を重複数  $ol_c$  として計数し、閾値  $T_{ol_c}$  以上のカラムを活性候補にする。次に、各入力データビットについて、活性候補のカラムと接続状態にあるシナプス数を重複数  $ol_i$  として計数する。活性候補のカラム数が  $N^{ac}$  より少ない場合、リージョン内にカラムを 1 つ追加する。追加したカラムのシナプスは、重複数  $ol_i$  が少ない入力データビットの順に  $N^s$  本設置する。ただし、 $N^s \geq T_{ol_c}$  に設定する。結果として、追加したカラムは活性候補になる。この追加処




Fig. 8: 動的時間プリーングにおけるリプレイ処理 (提案)




Fig. 9: 動的時間プリーングにおけるバックトラック処理 (提案)

理を、活性候補のカラム数が  $N^{ac}$  になるまで繰り返す。次に、活性候補のカラムから、カラム数  $N^{ac}$  までを活性状態にする。上述の処理でカラムを追加した場合は、活性候補にしたすべてのカラムを活性状態にすることになる。カラムを追加しておらず、活性候補のカラム数が  $N^{ac}$  より多い場合は、重複数  $ol_c$  が多い順に  $N^{ac}$  までのカラムを活性状態にする。

Fig. 7 は、活性状態にするカラム数  $N^{ac} = 2$  に対して、活性候補になるカラムが1つしかなく、もう1つのカラムを追加する例を示している。追加されたカラムは、活性候補になったカラムとのシナプス接続数  $ol_i$  が小さい入力データビットの順に、赤色のシナプスを配置することがわかる。

#### 4.2 動的時間プリーング

動的時間プリーングは、活性状態のカラムの集合に対して、セルを自己構成しながら活性状態のセル、さらに予測状態のセルを決定する処理である。

まず、活性状態のカラム内に予測状態のセルが存在する場合は、そのセルを活性状態にする。活性状態のカラム内に予測状態のセルが存在しない場合は、確率  $p_{rep}$  でリプレイ処理を実行する。

##### 4.2.1 リプレイ

リプレイは、過去  $\delta$  時点をさかのぼって活性状態になったセルのシナプスを切断し、新たにセルを再生成することでシナプスネットワークを再構築する修復処理である。具体的には、時間を  $\delta$  時点さかのぼり、 $t - \delta$  時点において活性状態のセルと、 $t - \delta + 1$  時点において活性状態のセルとのシナプスを切断する。 $t - \delta + 1$  時点において活性状態のカラム内に新しいセルを生成し、既存の活性状態のセルの代わりに活性状態にする。生成したセルと、そのときに活性状態である他のセルとの間に新しいシナプスを構築する。この処理を  $t - 1$  時点まで繰り返す。最後に、 $t$  時点で活性状態のカラム内に新しくセルを生成し、そのセルと  $t - 1$  時点におい




Fig. 10: セルの生成 (提案)

て活性状態のセルとの間にシナプスを配置する。新しく生成したセル群を時刻  $t$  で活性したセルとする。

Fig. 8 にリプレイ処理の例を示す。時刻  $t$  時点において、活性状態ではあるが予測セルが存在しないひとつのカラムに注目し、リプレイ処理を施す。さかのぼる過去の時点数を  $\delta = 3$  とし、 $t - 3$ ,  $t - 2$ ,  $t - 1$  と付記したセルは、その時点で活性状態だったことを表す。まず、状態 (a) において、シナプス接続された  $t - 3$ ,  $t - 2$ ,  $t - 1$  時点で活性状態だったセルが存在することがわかる。次の状態 (b) において、それらのシナプスを切断する。状態 (c) において、 $t - 3$ ,  $t - 2$ ,  $t - 1$  時点で活性状態だったセルと同じカラム内に新しく3つセルを生成し、時系列の順番にシナプスを接続する。状態 (d) において、注目するカラム内に新しくセルを生成し、時刻  $t - 1$  の活性したセルとシナプスを接続する。このように、リプレイは過去にさかのぼってセルとシナプスネットワークを再構成する。

##### 4.2.2 バックトラック

確率  $1 - p_{rep}$  でリプレイ処理を実行しない場合について、活性状態のカラム内に予測状態のセルが存在しなければ、バックトラック処理を実行する。

バックトラックは、学習器内に新たなセルを生成せずに、過去にさかのぼって活性状態にするセルを決定




Fig. 11: 入力データ

する処理である。バックトラック処理では、まず、予測状態のセルが存在しない活性状態のカラム内の各セルについて、 $t-1$  時点で活性状態だったカラム内のセルとのシナプス数を重複数  $ol_e$  として計数し、閾値  $N^{ac}$  以上の場合に活性状態にする。また、 $t-1$  時点で活性状態だったカラムにおける  $t-1$  時点の活性状態のセルへシナプスを接続しなおす。

具体例を Fig. 9 に示す。状態 (a) において、予測状態のセルが存在しない活性状態のカラムに注目する。状態 (b) には、 $t-1$  時点で活性状態だったカラムの上部に  $t-1$  を付記した。また、そのカラムにおいて  $t-1$  時点で活性状態だったセルにも  $t-1$  を付記した。このとき、注目するカラムの各セルについて、 $t-1$  時点で活性状態だったカラム内のすべてのセルとのシナプス数を重複度  $ol_e$  として計数する。ここでは、セル  $c_5$  の重複度が  $ol_e = 2$  になる例を示している。状態 (c) で、セル  $c_5$  の重複度  $ol_e = 2$  が  $N^{ac} = 2$  であるため活性状態にする。さらに、 $t-1$  時点で活性状態だったセルへシナプスを接続しなおしている。このように、バックトラックでは、既存のセルを用いて活性状態を作る。

#### 4.2.3 セルの追加と予測状態化

予測状態のセルが存在しない活性状態のカラム内に、重複数  $ol_e$  が閾値  $T_{ol_e}$  以上のセルがあれば、各カラムにつき 1 つをランダムに選択して活性状態にする。重複数  $ol_e$  が閾値  $T_{ol_e}$  以上のセルがなければ、カラム内に新たにセルを生成し、 $t-1$  時点で活性状態だったセルとの間にシナプスを配置、生成したセルを活性状態にする。これを Fig. 10 に例示する。

最後に予測状態にするセルを決定する。各セルについて、活性状態のセルに加えて  $t$  時点でセルが追加されたカラム内のすべてのセルに対して、接続されたシナプス数を  $ol_e$  として計数し、各カラムに 1 つの制限の下で  $ol_e$  が大きい順に  $N^{ac}$  個のセルを選択して予測状態にする。

## 5 実験設定

本稿では、従来の LSTM、従来の CLA、提案する自己構成型 CLA の時系列予測の性能を比較する。従来の LSTM の実装には、Keras<sup>11)</sup> を利用した。CLA の実装には、NuPIC<sup>12)</sup> を利用した。

### 5.1 入力データ

入力データとして、正弦波、合成波、ロジスティック写像の 3 種類のテスト時系列データを用いる。これら

を、それぞれ次式で定義する。

$$X_{\sin}(t) = \sin\left(\frac{t-1}{50}\right), \quad (2)$$

$$X_{\text{com}}(t) = \sum_{k \in \{1,3,5,7,9\}} \frac{\sin\left(\frac{(t-1) \cdot k \cdot \pi}{50}\right)}{k}, \quad (3)$$

$$X_{\log}(t) = 4.0 \cdot X_{\log}(t-1) \cdot \{1 - X_{\log}(t-1)\}. \quad (4)$$

3 種類の入力データについて、Fig. 11 に示す。

### 5.2 パラメータ

入力データについて、CLA は、式 (2)-(4) の実数値を  $n = 2,048$  ビットのバイナリ表現  $\mathbf{x}(t) = (x_1(t), x_2(t), \dots, x_n(t))$  に変換する。チャンク長は、 $w = 40$  ビットにした。各入力データの最大、最小値について、式 (2) の正弦波と式 (3) の合成波は、 $[\min, \max] = [-1.0, 1.0]$  に設定した。式 (4) のロジスティック写像は、 $[\min, \max] = [0.0, 1.0]$  に設定し、初期値は  $X_{\log}(0) = 0.1$  にした。また、すべての入力データについて、入力期間は  $t \in [1, 10^5]$  にした。

予測アルゴリズムについて、従来の LSTM は、隠れ層のユニット数を 100 に設定した。損失関数は平均二乗誤差を用い、最適化アルゴリズムは正弦波と合成波では SGD、ロジスティック写像では RMSProp を採用した<sup>11)</sup>。CLA は、空間プーリングにおいてカラムの状態を決める閾値を  $T_{ol_c} = 2$ 、時間プーリングにおいてセルの状態を決める閾値を  $T_{ol_e} = 15$  にした。従来の CLA について、カラム数は 2048、各カラムのセル数は 32 に設定した。カラムのシナプスの永続値の増減量は、それぞれ  $\Delta p_{sp}^+ = 0.05$ 、 $\Delta p_{sp}^- = 0.025$  にした。セルのシナプスの永続値の増減量は、それぞれ  $\Delta p_{tp}^+ = 0.1$ 、 $\Delta p_{tp}^- = 0.1$  にした。提案する自己構成型 CLA について、まず、動的空間プーリングに関して、各カラムのシナプス数は  $N^s = 2$  にした。また、活性状態にするカラム数は  $N^{ac} = 20$  にした。次に、動的時間プーリングについて、リプレイ処理の実行確率は  $p_{rep} = 0.01$  にした。また、リプレイ処理でさかのぼる過去の時点数は  $\delta = 5$  にした。さらに、提案する自己構成型 CLA は、従来の CLA で用いるセルの総数  $2048 \cdot 32 = 65,536$  を目安とし、セル総数が 60,000 を超えたときに自己構成処理を停止させる。

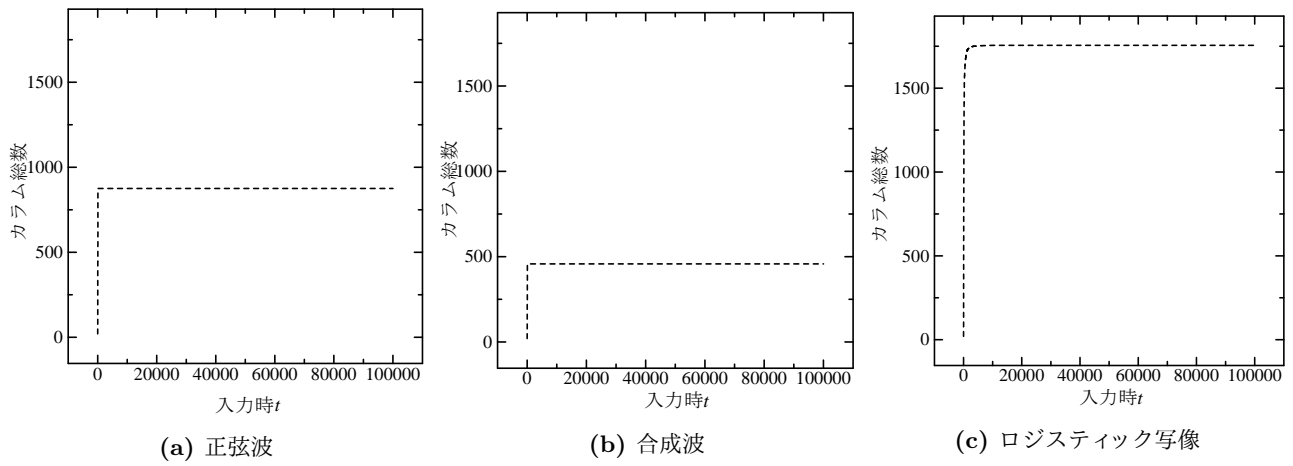


Fig. 12: 提案する自己構成型 CLA におけるカラム数の推移




Fig. 13: 提案する自己構成型 CLA におけるセル数の推移




Fig. 14: 提案する自己構成型 CLA におけるセルの分布

### 5.3 評価尺度

評価尺度として、真値と予測値の絶対誤差である予測誤差を用いる。予測誤差は、小さいほど良好な結果と判断する。各予測アルゴリズムは、独立した 100 回試行の予測誤差の平均値で比較する。

## 6 実験結果と考察

### 6.1 カラム数の変化

提案する自己構成型 CLA におけるカラムの総数の推移を Fig. 12 に示す。

まず、すべての入力データにおいて、カラム数は入力回数の増加に伴って増加し、一定数に収束することがわかる。また、カラム数の収束値は、入力データによって異なることがわかる。周期関数である正弦波と合成波を比べると、正弦波の方が合成波よりカラム数が多いことが見て取れる。Fig. 11 に示した入力データの波形から、合成波は正弦波より入力値に偏りが大きいことがわかる。正弦波の予測では、合成波より偏りが小さく多様な入力値を表現する必要があるため、合成波より多くのカラムが必要になる。非周期関数であ



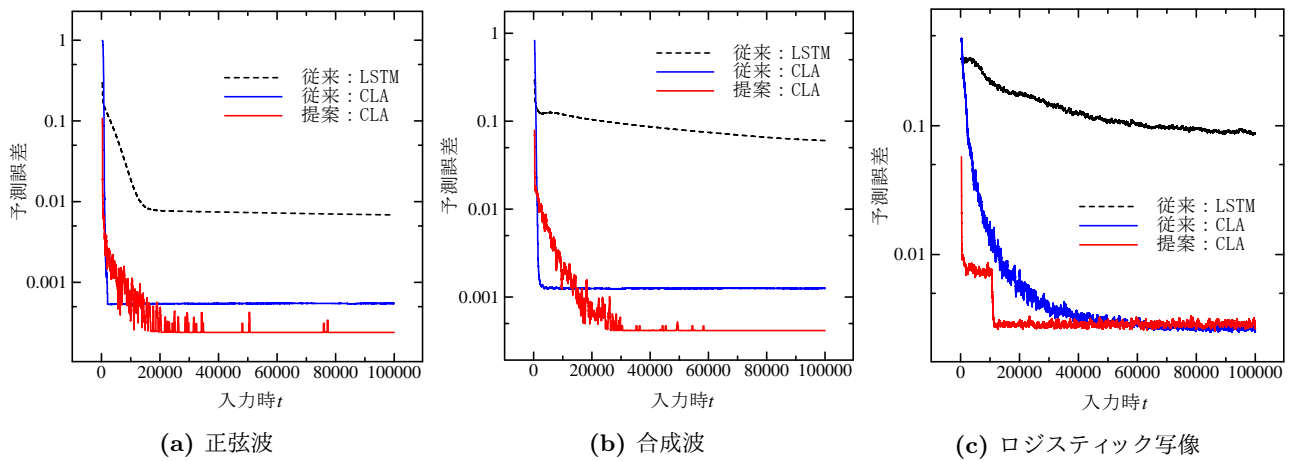


Fig. 15: 予測誤差の推移

Table 1: 総予測誤差

(a) 正弦波		(b) 合成波		(c) ロジスティック写像	
方法	総予測誤差	方法	総予測誤差	方法	総予測誤差
LSTM(従来)	1459.63	LSTM(従来)	8559.98	LSTM(従来)	13781.74
CLA(従来)	567.43	CLA(従来)	465.60	CLA(従来)	1143.98
自己構成 CLA(提案)	72.84	自己構成 CLA(提案)	136.44	自己構成 CLA(提案)	353.93

るロジスティック写像については、周期関数である正弦波と合成波と比較して、入力データビットのパターンが多いため、カラム数も多くなることがわかる。

これらの結果から、提案する自己構成型 CLA は、入力データに合わせてカラム数を自己調整できることが確認できた。

## 6.2 セル数の変化

提案する自己構成型 CLA におけるセルの総数の推移を Fig. 13 に示す。セルの追加最大数も水平線で示した。

周期関数である入力の正弦波、合成波の入力データについては、セル数が最大数まで到達せず、学習途中でセル数が一定数に収束することがわかる。正弦波と合成波におけるセル総数の収束値を比べると、合成波の方が正弦波より多いことがわかる。Fig. 11 に示したように、合成波は正弦波より入力値に偏りが大きい。そのため、合成波の方が正弦波より多くの時系列の出現パターンをセルによって表現する必要があるためである。非周期関数であるロジスティック写像の入力データについては、提案する自己構成型 CLA によって生成したセルの数が最大の 60,000 に到達することがわかる。前述の通り、現状の自己構成型 CLA では、セル数が最大数に到達するとセルの追加を停止する。CLA は、過去に入力されたデータの内部表現に基づいて予測するため、非周期関数を予測しようとする提案する自己構成型 CLA ではセルは増加し続けることになる。この点については、今後、適切な入力データの出現パターンの分解粒度で自動的にセル数の追加を停止する仕組みを検討する予定である。

提案する自己構成型 CLA では、カラムごとに内包するセル数が異なる。カラムごとのセル数の差異を Fig. 14 に示す。ここでは、カラムをセル数について昇順に整列させた結果を掲載した。正弦波と合成波を比較すると、合成波の方が正弦波よりセル数の偏りが大きいことがわかる。Fig. 11 に示したように、合成波は正弦

波より入力値に偏りが大きい。同一のデータ値が入力された場合に、その出現パターンを区別するために、多くのセルが必要になるためである。一方、ロジスティック写像においても、カラム間のセル数に差異が生じていることがわかる。

これらの結果から、提案する自己構成型 CLA は、入力データに合わせてセル数を自己調整できることが確認できた。

## 6.3 予測誤差の比較

3 種類の入力データに対する予測誤差の推移の結果を Fig. 15 に示す。また、総予測誤差の結果をそれぞれ Table 1 に示す。

正弦波の入力データにおける Fig. 15a の結果から、2 つの CLA は従来の LSTM より小さい予測誤差で推移することがわかる。およそ 20,000 入力で、従来の LSTM における予測誤差は収束しており、それ以上にデータを入力しても、さらなる予測誤差の減少は見られないことがわかる。Table 1a に示す総予測誤差からも、2 つの CLA が従来の LSTM より予測誤差が小さく、予測性能が高いことがわかる。この傾向は、Fig. 15b, Fig. 15c に示す合成波とロジスティック写像の入力に対しても同様である。これらの結果から、本稿で用いたテスト入力データにおいて、CLA が従来の LSTM より高い予測性能を示すことが明らかになった。

次に、2 つの CLA の予測誤差を比較する。まず、本稿で用いたすべての入力データにおいて、学習開始直後を見ると、提案する自己構成型 CLA が、従来の CLA より小さい予測誤差を示すことがわかる。学習開始直後、従来の CLA の予測誤差は、従来の LSTM より高い。一方、提案する自己構成型 CLA の予測誤差は、従来の LSTM より低いことがわかる。2 種類の CLA の予測誤差は、入力回数の増加に伴って減少するが、およそ 15,000 入力を超えると予測誤差が一定値に収束する。予測誤差の収束値は、提案する自己構成型 CLA の方が、従来の CLA より低いことがわかる。ロジスティック



ク写像の入力データにおいては、学習末期を見ると、提案する自己構成型 CLA と従来の CLA の予測誤差はほぼ同等だが、学習初期を見ると、提案する自己構成型 CLA による予測誤差の減少が従来の CLA より早いことがわかる。

これらの結果から、提案する自己構成型 CLA は、カラムとセル数を自己構成できるだけでなく、従来の CLA と LSTM より良好な予測性能を示すことが確認された。

## 7 まとめ

本研究では、時系列データ予測のための大脳新皮質学習アルゴリズムにおいて、カラムとセル数の事前設定を不要にすることを目的とし、カラムとセルを入力データに合わせて自己構成する大脳新皮質学習アルゴリズムを提案した。複数のテスト入力データを用いた実験の結果、提案法は、入力データに合わせてカラムとセルを動的に構成するだけでなく、従来の大脳新皮質学習アルゴリズムや LSTM より時系列予測の精度も高められることがわかった。

今後の課題として、学習の過程で不要になったカラムやセルを削除する仕組みを導入する予定である。また、リプレイ処理において、ユーザーが指定した地点まで処理をさかのぼるのではなく、正しい予測を生成できる最小の時点までを再帰的に処理をさかのぼる方法を構築する予定である。さらに、周期性の低い入力データに対して、時系列の出現パターンの表現粒度を適応的に決定できる方法を構築する予定である。

## 参考文献

- 1) J. Hawkins, 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," Technicalreport, 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*, pp. 1–13, 2016.
- 4) Y. Cui and S. Ahmad, J. Hawkins: "The HTM Spatial Pooler—A Neocortical Algorithm for Online Sparse Distributed Coding," *Frontiers in Neuroscience*, doi: 10.3389/fncom.2017.00111, 2017.
- 5) J. Hawkins and S. Ahmad, Y. Cui: "A Theory of How Columns in the Neocortex Enable Learning the Structure of the World," *Frontiers in Neural Circuits*, Vol. 11, Article 81, pp. 1–18, 2017.
- 6) J.L. Elman: "inding structure in time," *Cognitive Science*, No. 14, pp. 179–211, 1990.
- 7) S. Hochreiter and J. Schmidhuber: "Long Short-Term Memory," *Neural Computation*, Vol. 9, No. 8, pp. 1735–1780, 1997.
- 8) A. Lavin and S. Ahmad: "Evaluating Real-time Anomaly Detection Algorithms the Numenta Anomaly Benchmark," *Proc. of the 14th International Conference on Machine Learning and Applications (IEEE ICMLA '15)*, pp. 38–44, 2015.
- 9) Y. Cui, S. Ahmad, and J. Hawkins: "Continuous Online Sequence Learning with an Unsupervised Neural Network Model," *Neural Computation*, Vol. 28, Issue. 11, pp. 2474–2504, 2016.
- 10) 鈴ヶ嶺 聡哲, 青木 健, 高玉 圭樹, 佐藤 寛之: "大脳新皮質学習におけるカラムとセルの動的構成に関する検討," 第 117 回数理解モデル化と問題解決 (MPS) 研究会報告, 情報処理学会, Vol. 2018-MPS-117, No. 24, pp. 1–2, 2018.
- 11) Keras: Deep Learning for humans, <https://github.com/keras-team/keras> (2018/5/1 access)
- 12) nupic.core: Implementation of core NuPIC algorithms, <https://github.com/numenta/nupic.core> (2018/5/1 access)