

17th SICE Symposium on Computational Intelligence

March 25-26, 2021, Online

第17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：2021年3月25日(木)，26日(金)

会 場：オンライン開催

**SICE**<sup>®</sup>

主 催：計測自動制御学会 システム・情報部門

企 画：コンピューターショナル・インテリジェンス部会，知能工学部会

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

カタログ番号 21PG0003

著作権 © 2021

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 21 PG 0003

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：2021年3月25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 17 回コンピューテーショナル・インテリジェンス研究会プログラム

3月25日(木)

13:35～14:50 (3件) 司会 礪川 悌次郎 (兵庫県立大学)

- 1 帆と舵の並列ファジィ推論 1  
○松原 太一, 橘 完太 (工学院大学)
- 2 ファジィ推論を用いた帆走ロボットの障害物回避実験 8  
○福場 亮輔, 橘 完太 (工学院大学)
- 3 深層強化学習を用いた帆船の自動運転 15  
○河村 亮, 橘 完太 (工学院大学)

15:10～16:20 (3件) 司会 森 禎弘 (京都工芸繊維大学)

- 4 帆船ロール角の逐次データ同化 22  
○森本 明日香, 橘 完太 (工学院大学)
- 5 数値モデルおよび粒子群最適化法による河川水質予測 27  
○上田 剛士, 礪川 悌次郎 (兵庫県立大学), 中川 学, 笠原 隆史 (奈良市企業局),  
松下 智則, 中山 俊一, 井上 晴夫 (オルガノプラントサービス株式会社),  
若松 次男 (株式会社コンテック), 宮ノ下 友明,  
畠田 泰彦, 鳥羽 裕一郎 (オルガノ株式会社), 上浦 尚武 (兵庫県立大学)
- 6 複数の複雑性指標を用いたアルツハイマー病における脳波の判別 32  
○安藤 桃, 信川 創 (千葉工業大学), 菊知 充 (金沢大学),  
高橋 哲也 (福井大学, 金沢大学, 魚津神経サナトリウム)

16:40～17:30 (2件) 司会 礪川悌次郎 (兵庫県立大学)

- 7 注意選択を再現する深層ニューラルネットワークモデルの情報表現 38  
○我妻 伸彦, 渡邊 将以, 増本 真子 (東邦大学), 日高 章理 (東京電機大学), 田村 弘 (大阪大学)
- 8 反射から群論理への進化による概念の誕生: デジタル言語論理層第2進化 43  
○得丸 久文 (カラハリプロジェクト)

3月26日(金)

9:15~10:25 (3件) 司会 森 禎弘 (京都工芸繊維大学)

- 9 ノイズ下における神経システムのカオス共鳴の性能評価 49  
○信川 創 (千葉工業大学), 我妻 伸彦 (東邦大学), 西村 治彦 (兵庫県立大学),  
稲垣 圭一郎 (中部大学), 山西 輝也 (福井工業大学)
- 10 カオス系における位相同期と移動情報量により評価された機能的結合 53  
○戸部 真弓菜, 信川 創 (千葉工業大学)
- 11 走行シーン認知における運転経験と事象関連電位 P300 の評価 59  
端名 陸, 前田 純之介, 山本 昂汰 (中部大学), 信川 創 (千葉工業大学),  
我妻 伸彦 (東邦大学), ○稲垣 圭一郎(中部大学)

10:45~11:55 (3件) 司会 信川 創 (千葉工業大学)

- 12 時系列予測に基づく行動決定のための大脳新皮質学習に関する基礎検討 63  
○藤野 和志, 青木 健, 高玉 圭樹, 佐藤 寛之 (電気通信大学)
- 13 構造適応型深層学習を用いた道路網認識手法 RoadTracer への適用 68  
○鎌田 真, 市村 匠 (広島県立大学)
- 14 距離学習を用いた鯨の個体識別システムの構築 73  
中原 諒, ○磯川 悌次郎, 上浦 尚武 (兵庫県立大学)

# 帆と舵の並列ファジィ推論

○松原太一 橘完太 (工学院大学)

Parallel fuzzy reasoning of sail and rudder

T. Matsubara and K. Tachibana (Kogakuin University)

**Abstract**— As far as the author knows, no research has been conducted to parallelize the control of the sail and rudder of a sailing ship and clarify its effect. In this research, we implement a multi-threaded program that fuzzily infers the control of sail servomotor and rudder servomotor based on the observed values of the GPS receiver, wind direction and speed sensor, and 9-axis sensor used for sailboat control. We conducted actual sailing experiments to clarify the effect of parallelizing sensors and actuators in the control of sailing ship. As a result of comparison under similar wind conditions during the experiment, it was found that the propulsion force increased by the parallelizing.

## 1 はじめに

近年、ロボットの制御を並列処理する研究が行われている[1][2]。同時に自動車における自動運転技術[3]は盛んに研究されており、自動運転技術の発展によって生活の利便性が向上している。また、水上での自動運転(Unmanned Surface Vehicle, USV)としてモータボートや船舶[4][5]などが研究されている。実機 USV を用いて目標点までの経路や予め設定された経路を辿るように帆と舵を独立に制御する研究[6][7]が行われた。また、風向風速センサを使わず GPS で受信した艇速と加速度計で算出したロール角によってファジィ推論し、帆と舵を直列的に制御する研究[8]も行われた。帆船は風などの自然エネルギーを動力とする。風の変化に素早く反応できれば帆船を制御の効率が改善されると考える。筆者が調べた限りでは、帆船の帆と舵の制御を並列化し並列化の効果を明らかにした研究は行われていない。本手法では、帆船制御で用いる GPS 受信機、風センサ、9 軸センサ、帆サーボモータおよび舵サーボモータとメインプログラムをマルチスレッド化して実装する。そして、帆船の制御においてセンサとアクチュエータを並列化する効果を明らかにする。

## 2 提案手法

### 2.1 実験に用いる実機

Fig. 1 に、本研究の実機実験に用いた小型帆船 RC Yacht Monsoon の写真を示す。帆船の制御には、9 軸センサ (MPU-9250/6500), GPS 受信機 (型番 BU-353S4), ドローン搭載超小型超音波風向風速センサ (型番 FT-205EV) を接続した Raspberry Pi model 3B+ を使用する。Raspberry Pi の GPIO 端子と小型帆船の帆と舵のサーボモータとをジャンプワイヤでつなげて制御する。この際の配線図は付録に示す。GPS モジュールは、帆船の状態として緯度・経度・進行方向・速度を随時取得する。強風時に帆が閉じすぎていると転覆の危険度が増すため 9 軸センサを用いてローリング (船の横倒し) を計測し、後述のファジィルールによって帆を少し開くことにより転覆を防ぐ。各センサと Raspberry Pi は防水対策としてお弁当

箱に入れ、粘土や粘着テープなどで補強して小型帆船に搭載する。



Fig1. Small sailing ship

### 2.2 直列手法と並列手法

3 つのセンサと 2 つのサーボモータを直列に用いる帆走データ (令和 2 年 12 月 8 日 (火) 10:24 に開始した試行@手賀沼) を研究室の他のメンバーが取得した。以降、このデータを直列データ、直列データを取得した手法を直列手法と呼ぶ。直列手法は GPS を取得後、風計と 9 軸を順次計測し、Sail の PWM 値を制御し Rudder を時系列パターン制御する。Fig. 2 に、直列手法のシーケンス図を示す。使用する各センサのサンプリング周波数は以下の通りである、GPS 受信機 1Hz 以下、風速センサ 5Hz 以上、9 軸 100Hz 以上。また、舵サーボモータは 1~2 秒の時系列パターンに従って制御する。そのため、長い場合には 2 秒間隔 (0.5Hz) で GPS も風速センサも 9 軸センサも観測することになる。

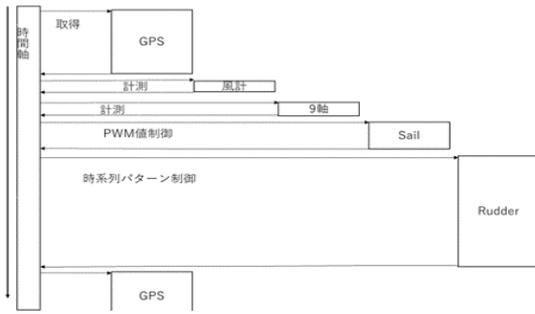


Fig.2. Sequence diagram of serial method

一方、本手法では3つのセンサの計測と2つのアクチュエータの制御を並列化し、GPSと風センサの計測直後に舵サーボモータを、9軸センサと風センサの計測直後に帆サーボモータを、互いに独立に動かす。以降、本手法を並列手法と呼ぶ。Fig.3に、並列手法で用いるクラス概要図を示す。Fig.4に、並列手法のシーケンス図を示す。本手法では風計と9軸を計測したタイミングでSailのPWM値を制御し、GPSを取得し風計を計測したタイミングでRudderの時系列パターン制御を開始する。

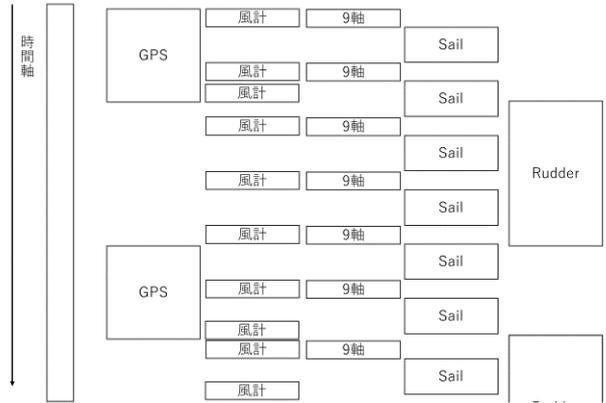


Fig4. Sequence diagram of parallel method

### 2.3 舵と帆のファジィ推論

GPSの位置情報から計算した目的点の方向  $goalAngle$  と、風センサにより取得した風データを用い、ファジィ推論により舵を制御する。 $goalAngle$  に対して3つのファジィ集合 **Right** (目標が右), **Center** (目標が正面), **Left** (目標が左) の各メンバーシップ関数のメンバーシップ値を算出する。また真の風向 **TWA** に対して3つのファジィ集合 **DZR** (風向が右前方のデッドゾーン<sup>1</sup>), **DZL** (風向が左前方のデッドゾーン), **NDZ** (デッドゾーン以外) の各メンバーシップ関数のメンバーシップ値を算出する。またメンバーシップ値は  $\min, \max$  演算を用いる。Fig.5に  $goalAngle$  についてのメンバーシップ関数を示す。Fig.6に **TWA** に対してメンバーシップ関数を示す。Table 1に舵のファジィルールを示す。ここでは1は面舵一杯, -1は取り舵一杯である。舵の推論値を  $[-1, 1]$  の範囲で求める。舵の推論値は1が面舵いっぱい (**FullRight**), 0.5が面舵 (**halfRight**), 0が直進 (**Center**), -0.5が取舵 (**HalfLeft**), -1が取舵いっぱい (**FullLeft**) となる。

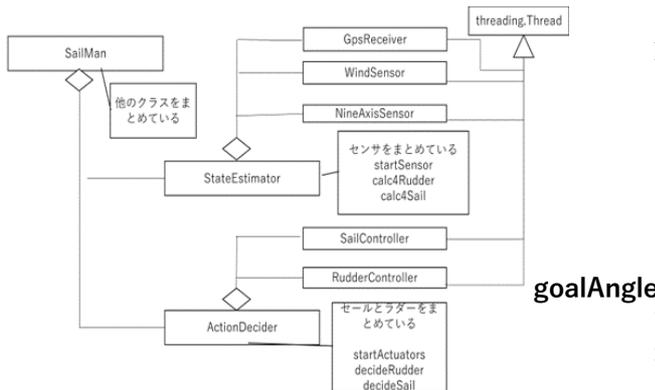


Fig3. Outline of the program of the proposed method

Table 1 Ship Fuzzy IF-THEN Rule

TWA

<sup>1</sup>Deadzone とは推進力を生かしにくい条件のことを指しており風の向きが  $45^\circ$  から-

$45^\circ$  の時を意味する。

	DZR	DZL	NDZ
R	HalfLeft (-0.5)	FullRight (1)	FullRight (1)
C	FullLeft (-1)	FullRight (1)	Center (0)
L	FullLeft (-1)	HalfRight (0.5)	FullLeft (-1)

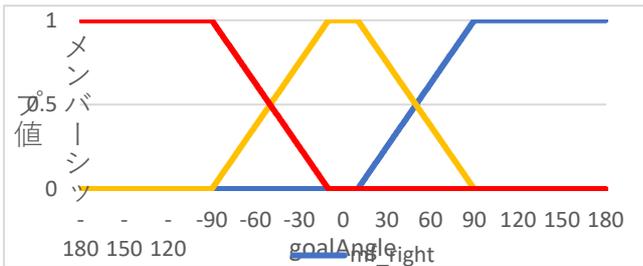


Fig5. Membership function for goalAngle

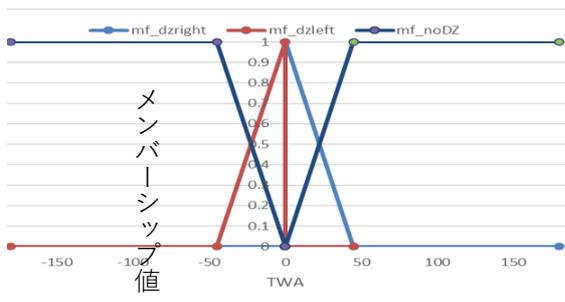


Fig 6. Membership function for TWA

舵の制御と並列に、風センサで取得した風データと 9 軸センサで得たヒーリング<sup>2</sup>を用い、ファジィ推論により帆の推論値を求める。見かけの風向 AWA に対してラベル W.Head (向かい風), W.Tail (追い風) の各ファジィ集合のメンバーシップ値を算出する。Head で帆を閉じ Tail では帆を開く。またヒーリングに対してラベル H.Small (ヒーリングが小さい), H.Big (ヒーリングが大きい) の各ファジィ集合についてメンバーシップ値を算出する。Fig. 7 に AWA についてのメンバーシップ関数, Fig. 8 にヒーリングについてのメンバーシップ関数を示す。Table 2 に帆のファジィルールを示す。帆の推論値 0 が全閉 Close, 0.5 が半開 halfopen, 1 で全開 open を示す。

<sup>2</sup> ヒーリングとは船の傾きを意味している。

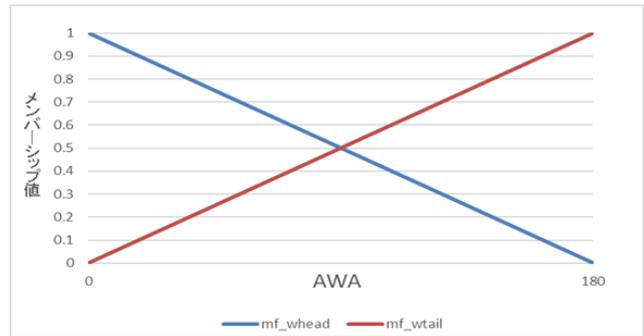


Fig7. Membership function for AWA

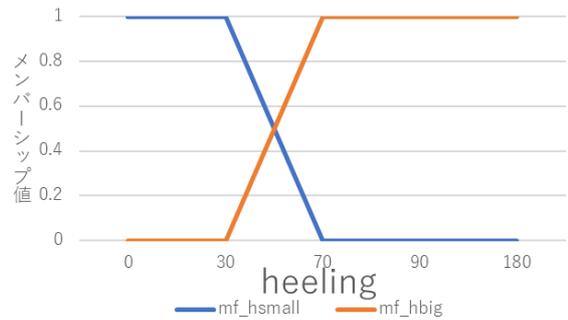


Fig8. Membership function for Heeling

Table2. Sail Fuzzy IF-THEN Rule

	Hsmall	Hbig
Whead	0(close)	0.5(Half open)
Wtail	1(open)	1(open)

### 2.4 操作時間のファジィ推論

風向風速センサより得た見かけの風速 AWS を用いて操作時間をファジィ推論する。AWS から B.Slow, B.Fast の各ラベルを持つファジィ集合のメンバーシップ値を算出する。Fig. 9 に AWS についてのメンバーシップ関数を示す。

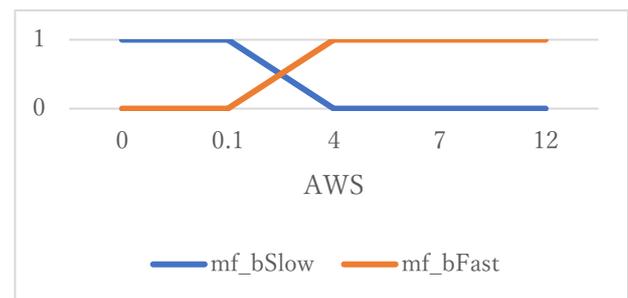


Fig. 9 Membership function for AWS

## 3 実験結果

実験前に定めた目標点へ向かう自動帆走において、センサとサーボモータを並列化した効果を確認する実機実験を行った。試行 1 ではスタート地点から目標点 1 まで帆走する。試行 2 では目標点 1, 目標点 2 の順に経由し、最終的に最終目標点へ帆走する。目標

る。

点までの距離が 6m 以下の時に目標点到達とみなす。類似した環境での帆走データを比較し、マルチスレッド化した効果を検証する。Table 3 に帆と舵の推論値と PWM (パラメータ) の設定値を示す。Full Open, Full Close は帆のパラメータ, Full Right, Center, Full Left が舵のパラメータである。また (1) 及び (2) に PWM 値を求める計算式も以下に示す。帆の推論値は  $reasoning_{sail}$ , 舵の推論値は  $reasoning_{rudder}$  とする。Table. 3 Sail and rudder inference values (parameters) and PWM settings

	推論値	PWM 値 (パラメータ)
帆	1	63 (Full Open)
	0	38 (Full Close)
舵	1	66 (Full Right)
	0	91 (Center)
	-1	116 (Full Left)

$$PWM_{sail} = (Full\ Open - Full\ Close) * reasoning_{sail} + Full\ Close(1)$$

$$PWM_{rudder} = \frac{(Full\ Right - Full\ Left)}{2} * reasoning_{rudder} + Center(2)$$

実験に用いたソースコードおよび取得したデータはすべて Dropbox フォルダ <https://00m.in/i-sail2020ay> で閲覧可能である。また実験時の映像を YouTube <https://tinyurl.com/y97mdg6f> で視聴可能である。

- ・実験場所. 千葉県我孫子市手賀沼
- ・実験開始日時
- 試行 1) 2020 年 12 月 27 日 11:12:22
- 試行 2) 2020 年 12 月 27 日 11:31:40
- 目標点 1. 35.859442 N, 40.028966 E
- 目標点 2. 35.85978 N, 140.028584 E
- 最終目標点. 35.859911 N, 140.02916 E

### 3. 2 実験結果

Fig. 10 に、試行 2 における帆船の緯度と経度を示す。目標点 1(goal1)と目標点 2(goal2), 最終目標点(goal3)をオレンジの点で示す。goal1, goal2 に順に到達したあと goal3 に向かう途中、水深が浅いところに行き座礁したため終了した。Fig. 11 に目標点までの距離と経過時間を示す。目標点をオレンジ色で示す。矢印で風を示す。

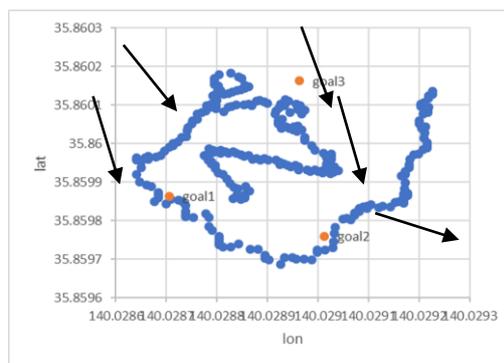


Fig10. Trial 2 sailing route

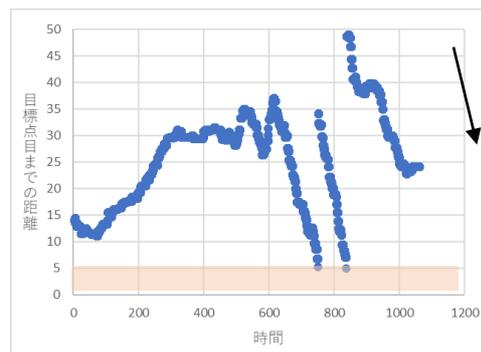


Fig11. Elapsed time of distance to the target point

Fig.12 に、試行○開始後 200.00~203.00 秒の各センサ取得データおよび帆と舵の推論値を示す。上から AWA(見かけの風向), ヒーリング, 帆の値(sailReasoning), 真の風向(TWA), 目標点の方向(goalAngle), 舵の値(rudderReasoning)を示す。帆の制御に必要な AWA とヒーリングが取得され次第, 帆の推論値が更新されている。

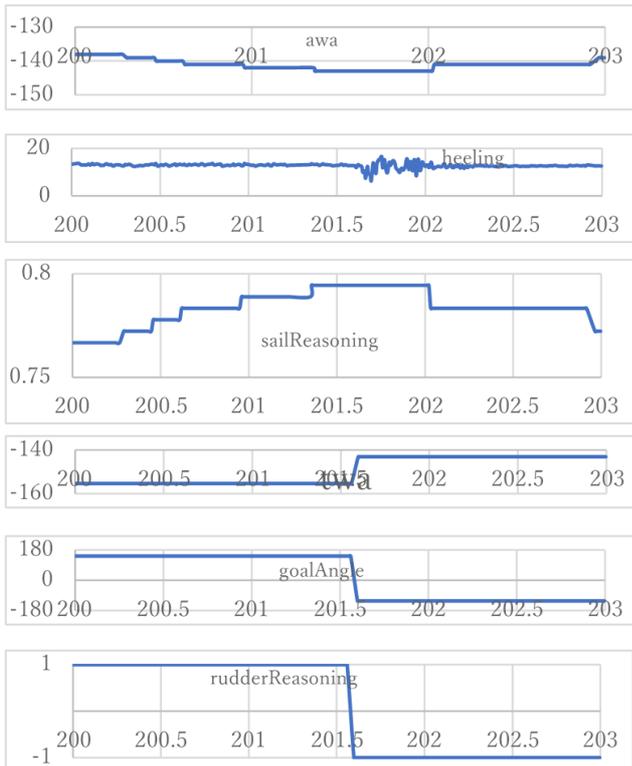


Fig12. Data acquired by each sensor and inferred values of sail and rudder

並列化の効果を明らかにするためには直列手法と並列手法を同時に同じ環境で実機実験をすることが望ましいが本年度はできなかった。そのため、直列データと並列手法のデータについて推進力を求めて比較する。推進力を求める式を(1), (2)に示す。

$$(推進力)-(抵抗力)=\tilde{m}(加速度) \quad (1)$$

$$(推進力)=(抵抗力)+\tilde{m}(加速度) \quad (2)$$

ここで、抵抗力 $V_0BS^2$ は初速度と船のスピード2乗求める。加速度 $\frac{\Delta BS}{\Delta t}$ は時間分の船のスピードで求める。 $\tilde{m}$

は帆船の負荷質量を意味する。

比較の際、GPSがどうたらこうたらしたものは除く。Fig13に、横軸：加速度；縦軸：抵抗力としてTWSが0.3[m/s]未満のデータについて直列手法（青）と並列手法（橙）の散布図を示す。図の右上に行くほど推進力が大きいことを示す。Fig. 14, 15, 16, 17, 18, 19に、TWSが0.3以上0.4未満、0.4以上0.5未満、0.5以上0.6未満、0.6以上0.7未満、0.7以上0.8未満の場合についてそれぞれ示す。

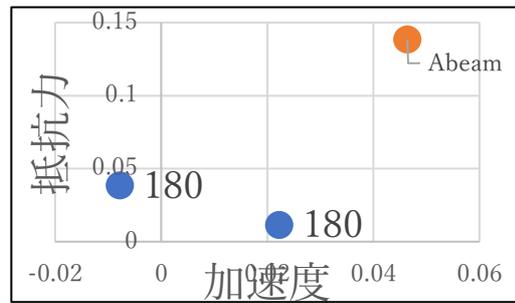


Fig13. TWS0.1~0.2

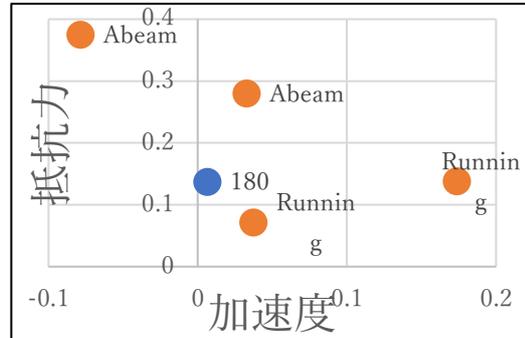


Fig14. TWS0.3~0.4

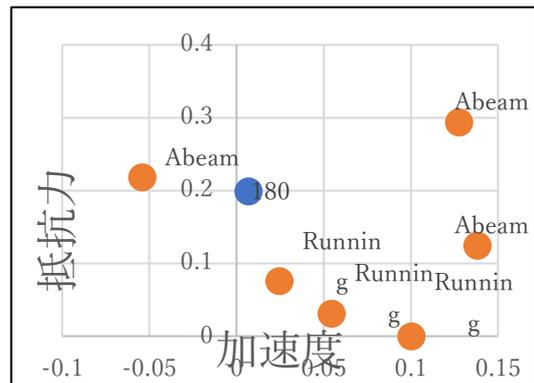


Fig15. TWS0.4~0.5

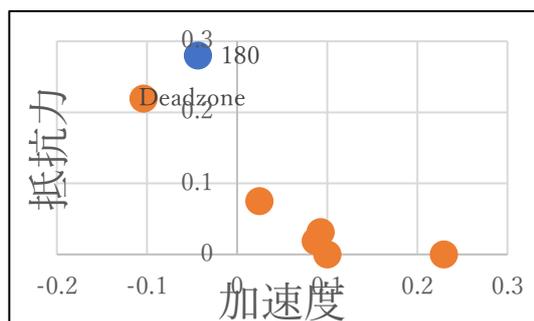


Fig16. TWS0.5~0.6

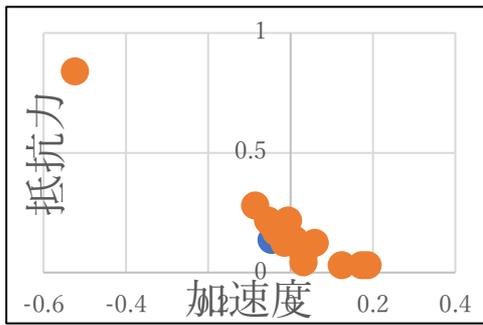


Fig17. TWS0.6~0.7

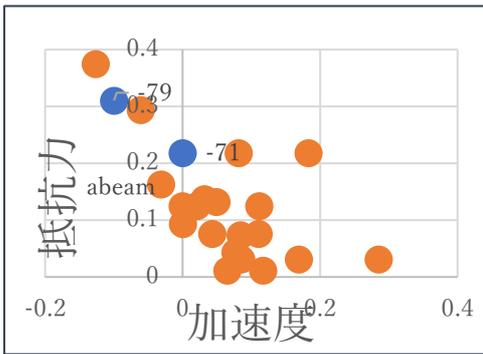


Fig18. TWS0.7~0.8

#### 4 考察

Fig.12 の各センサ取得データおよび帆と舵の推論値を見ると、提案手法のシーケンス図通りに見かけの風向と船の傾きを取得後帆の値を出し、真の風向と目標点の方向を取得後舵の値を出していることが分かった。そのため設計通りに帆船が制御されていることが確認できた。

Fig.13~18 の、推進力を構成する、加速力（横軸）と抵抗を打ち消す力（縦軸）について、両者の値が大きくなる場合、つまりグラフの右上になる場合を「推進力が優れる」、逆に両者の値が小さくなる場合、つまりグラフの左下になる場合を「推進力が劣る」と呼ぶことにする。

風向は、真の風向 TWA を基に 3 つに分類できる。TWA の分類分けは、横方向から風を受ける  $45 \leq TWA \leq 135$  [deg] または  $-45 \geq TWA \geq -135$  [deg] (以下, Abeam), 船尾方向からの追い風を受ける  $135 < TWA \leq 180$  [deg] または  $-135 > TWA > -180$  [deg] (以下, Running), 船首方向からの向かい風を受ける  $-45 < TWA < 45$  [deg] (以下, Deadzone) の 3 種類である。同じ風速であっても Abeam 条件が最も効率的に風を推進力に活かしやすく、次に Running 条件であり、Deadzone 条件は風を推進力として活かしにくい。

Fig.13 に示した  $TWS < 0.3$  の条件では、直列手法の 2 つのデータ点はどちらも  $TWA = 180^\circ$  つまり Running 条件であった。それに対して並列手法のデータは Abeam 条件 ( $TWA = 124$ ) だったこともあり、直列手法

の 2 点のいずれよりも推進力が優れている。

Fig.14 に示した  $TWS \in [0.3, 0.4)$  の条件では、直列手法は  $TWA = 180^\circ$  つまり船尾方向からの追い風であった。並列手法の 4 点は追い風よりも推進しやすい Abeam 条件と追い風の Running 条件であった。Running 条件の 1 点以外の 3 点は推進力に優れていた。

Fig.15 に示した  $TWS \in [0.4, 0.5)$  の条件では、直列手法は  $TWA = 180^\circ$  つまり船尾方向からの追い風であった。並列手法の 6 点は Abeam 条件または Running 条件であった。直列データよりも推進力に優れたデータは Abeam 条件 ( $TWA = 107^\circ$ ) であった。

Fig.16 に示した  $TWS \in [0.5, 0.6)$  の条件では、直列手法は  $TWA = 180^\circ$  つまり船尾方向からの追い風であった。並列手法の 6 点のうち 1 点が直列手法に劣っているが、このとき追い風よりも推進しにくい逆風の Deadzone 条件 ( $TWA = 11^\circ$ ) であった。

Fig.17 に示した  $TWS \in [0.6, 0.7)$  の条件では、直列手法は  $TWA = -26^\circ$  つまり逆風で推進しにくい Deadzone 条件であった。並列手法の 16 点（うち同じ Deadzone 条件が 5 つ）でありいずれも推進力に優れていた。

Fig.18 に示した  $TWS \in [0.7, 0.8)$  の条件では直列手法の 2 点は  $TWA = -71, -79$  つまり船尾方向から追い風で推進しやすい Abeam 条件であった。並列手法の 20 点（うち同じ Abeam 条件が 14 つ）であり劣っているときがあるが Deadzone より ( $TWA = -61$  deadzone) になっている。

Fig. 13, 14, 15, 16, 17, 18 の結果を風向をもとに詳しく調べ比較した結果、直列手法と比べて提案手法のほうが推進力が大きくなるのがうかがえる。考えられる要因としては、並列化したことにより帆を迅速に動かすことができたからだと考える。

#### 5 結論

本研究では、帆船制御で用いる GPS 受信機、風向風速センサ、9 軸センサの観測値をもとに帆サーボモータおよび舵サーボモータの制御をファジィ推論するプログラムをマルチスレッド化して実装した。実機帆走実験を行い、帆船の制御においてセンサとアクチュエータを並列化する効果を明らかにした。実験中の類似した風の条件で比較した結果、並列化することで推進力が増すことがうかがえた。

#### 参考文献

- 1) 笠原秀樹. マルチマイクロプロセッサシステムでのロボットアーム制御計算の並列処理 IEEE 巻 1, 号 2, 1985 年 6 月
- 2) 安田 源一 マルチスレッドプログラミングによる産業用ロボットシステムの分散制御 第 52 回自動制御連合講演論文集, 229-229, 2009
- 3) 津川定之. “自動運転システムの展望”, 国際交

通安全学会誌, 37 卷, 3 号, p199-207, 2013  
年 1 月

- 4) 清水悦郎. ”国内における自動運航船の現状と動向”, 日本マリンエンジニア学会誌, 54 卷, 4 号, p606-610, 2019 年
- 5) 浜松, 加賀谷, 河野. ”非線形 Receding Horizon 制御の自動操船システムへの適用”, 計測自動制御学会論文集, 44 卷, 8 号, p685-691, 2008 年
- 6) C. Sauze, M. Neal. ”An Autonomous Sailing Robot for Ocean Observation”, in proceedings of TAROS 2006, p190-197, Sep. 2016
- 7) F. Bars, L. Jaulin. ”An Experimental Validation of a Robust Controller with the VAIMOS Autonomous Sailboat”, Robotic Sailing, p73-84, 2012
- 8) 橋 完太, 清水 教平, 氏家 智行. “ロボット帆船のファジィ化と実機実験” 第 35 回ファジィシステムシンポジウム 講演論文集 p. 705-71

# ファジィ推論を用いた帆走ロボットの障害物回避実験

○福場亮輔 橘完太 (工学院大学)

## Obstacle avoidance experiment of autonomous sailing robot using fuzzy reasoning

\* R. Fukuba and K. Tachibana (Kogakuin University)

**Abstract**— In this study, we implemented obstacle avoidance control for sailing boat by fuzzy inference using dynamic risk and conducted actual machine experiments. Although it was possible to avoid obstacles in general, the avoidance control did not work well and sometimes it collided with an obstacle. It was confirmed that avoidance control is performed based on the degree of risk.

**Key Words:** Fuzzy reasoning, Sailing boat, Obstacle avoidance

### 1 はじめに

現在、2020年までの自動運転の実用化を目指して、完全自動運転車の取り組みが自動車メーカーやIT企業を中心に進められている<sup>1)</sup>。また、他の移動手段である鉄道<sup>2)</sup>や、航空機<sup>3)</sup>、船舶<sup>4)</sup>についての自動運転も研究が行われており、私達の生活がより便利になることが期待される。船舶にはエンジンやモータなどの動力を持つ船舶と、自らの動力を持たない船舶がある。自ら動力を持たない船舶である帆船は、風の弱い状態での航行速度などの点で動力船を下回っているが、燃料を用いずに風エネルギーを利用している為、環境負荷や航続距離の点で大きく優れている<sup>5)</sup>。また、船舶の自動運転は、陸上と異なり水面の影響を大きく受け制御が難しい。特に、帆船の自動運転においては動力源が風であるため、環境の変化が多岐にわたるため難易度が高く、未だ帆船の自動運転は実用化されていない。

帆船の自動運転についての研究には、シミュレーションや実機を用いた実験が行われている。阿部ら<sup>6)</sup>や清水ら<sup>7)</sup>の実機実験では、GPS受信器の位置情報を用いて目標点に達することに成功した。また、Stelzerら<sup>8)</sup>も実機実験において目標方向への帆走に成功した。しかし、これらの研究では障害物に対する回避制御を実装していない。武田<sup>9)</sup>は、帆船の障害物との相対位置を用いるファジィ推論を帆走ロボットに実装して障害物を回避する実験を行った。しかし、武田の手法では障害物との相対速度を考慮していない。障害物との相対速度が異なれば回避行動は変化してくる。前田ら<sup>10)</sup>は、陸上における障害物との相対速度を考慮した障害物回避のシミュレーションを行った。実機での障害物回避は、石川ら<sup>11)</sup>が陸上ロボットで、Fernandezら<sup>12)</sup>は自動車で、松田ら<sup>13)</sup>や橋本ら<sup>14)</sup>は模型の動力船でそれぞれ行った。

本研究では、帆船の回避行動の決定に相対速度を用いた障害物回避を提案する。実験には小型帆船の実機を用い、相対速度を用いたファジィ推論により決定した障害物回避制御で障害物を回避する課題を行う。

### 2 実験器具

本研究では、小型帆船の模型(MONSOON900)を改造して水上実験を行う。帆船にはGPS受信器(BU-353S4,S/N1: S4U0128753,S/N2:S4U0128648)、ドローン搭載超小型超音波風向風速センサー(FT-205EV,S/N:2000-292)を接続したRaspberry Pi 3 Model B+を搭載し、pythonで作成したプログラムを実行して舵と帆を制御する。帆船に搭載したRaspberry PiのGPIO端子と小型帆船の舵と帆のサーボモータとをジャンプワイヤで接続して制御する。GPS受信器から緯度・経度・進行方向、速度の情報を取得する。風向風速センサーからは風向と風速の情報を取得する。以下、Fig.1に実験に用いた小型帆船を示す。帆船の詳細を付録のTable S1に示す。センサーやバッテリー、それらの防水ケースなど積載物の重量によるピッチモーメントについては付録のTable S2に示す。



Fig. 1:小型帆船の模型

### 3 舵の制御

Fig.2に、提案手法の概要図を示す。提案手法では、まずGPS受信器で取得した帆船の緯度、経度、進行方向と、予め設定した障害物の緯度、経度を元に障害物との相対位置を算出し、武田<sup>9)</sup>と同様の手法でファジィ推論により静的危険度を計算する。静的危険度の絶対値が設定した定数(本実験では0.4)以上の場合、舵の

操舵を動的危険度に基づく回避行動に切り替える。静的危険度が設定した値未満の場合、予め設定した目標座標へ向かうように舵を制御する。Fig.3に静的危険度の絶対値が0.4未満の範囲を示す。この図の枠線の内側に障害物がある場合、回避行動に移す。

静的危険度は武田<sup>9)</sup>が用いた手法と前件部は同様であり、後件部はシングルトンを用いる。Fig.4に、進行方向を基準とする障害物の方向のファジィ集合を示す。左から順にLL, LS, RS, RLのファジィ集合からなり、障害物の角度について各ファジィ集合のメンバーシップ値を表す。障害物の角度は-180°から180°とする。Fig.5に、障害物との距離のファジィ集合を示す。NとM, Fのファジィ集合からなり、距離について各ファジィ集合のメンバーシップ値を表す。Fig.6に、静的危険度のファジィルールを示す。前件部の各メンバーシップ関数との対応を表す。後件部のシングルトンはLSL, LSS, LDS, LDL, RSL, RSS, RDS, RDLからなり、それぞれ赤い数字に対応する。動的危険度は、前田ら<sup>10)</sup>の手法と同様に計算する。帆船と障害物との相対速度からファジィ推論を用いて計算する。Fig.7に、相対速度の角度についてのファジィ集合を示す。左から順に、VLL, VLM, VLS, VRS, VRM, VRLのファジィ集合からなり、相対速度の角度のメンバーシップ値を表す。相対速度の角度は-180°から180°とする。Fig.8に、相対速さについてのファジィ集合を示す。VFとVSのファジィ集合からなり、相対速さのメンバーシップ値を表す。Fig.9に、動的危険度についてのファジィルールを示す。前件部の各メンバーシップ関数との対応を表す。シングルトンはLSL, LSS, LDS, LDL, RSL, RSS, RDS, RDLからなり、それぞれ赤い数字に対応する。

ファジィ推論について、はじめに前件部についてMin演算を行い、すべてのルールについて適合度を求め、重複した複数のルールについてMax演算を行う。すべてのルールについてメンバーシップ値を求めたら、シングルトンとの重み付き平均で危険度を算出する。危険度は-1から1までの範囲となる。算出した動的危険度をそのまま舵の出力値とする。舵は-1(取舵いっぱい)から1(面舵いっぱい)までの範囲とする。例を挙げると、相対速度が2m/sで-90°の場合、前件部のVLMが1, VFが1となり、後件部のLSSのメンバーシップ値が1で他の後件部のメンバーシップ値は0となる。その時の動的危険度は0.4となる。他の例を挙げると、相対速度が1m/sで45°の場合、前件部のVRSが0.5, VRMが0.5, VFが0.5, VSが0.5になり、後件部のRSLが0.5, RSSが0.5となる。その時の動的危険度の値は-0.25となる。

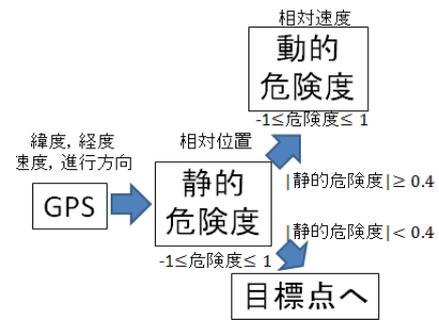


Fig. 2:提案手法の概要図

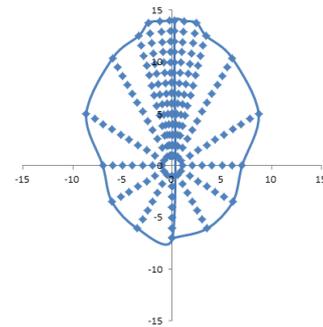


Fig. 3:回避行動を起こす範囲

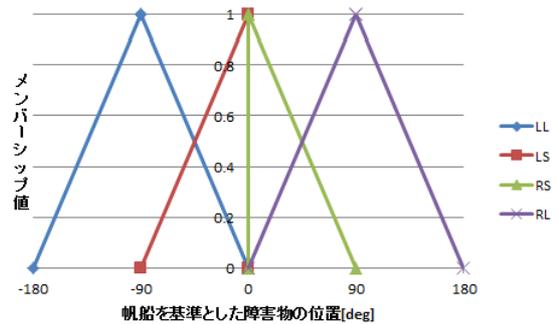


Fig. 4:障害物の角度についてのファジィ集合

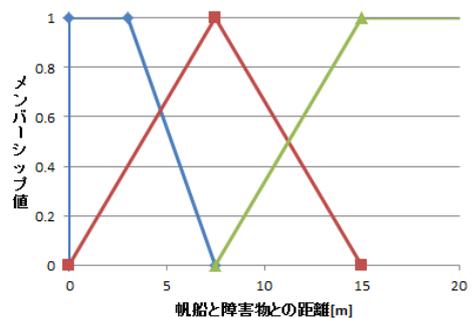


Fig. 5:障害物との距離についてのファジィ集合

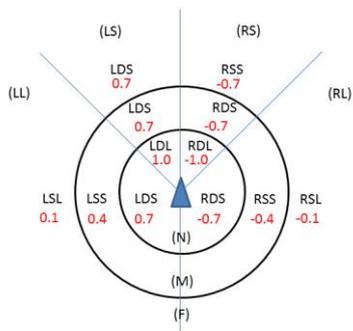


Fig. 6: 静的危険度のファジィルール

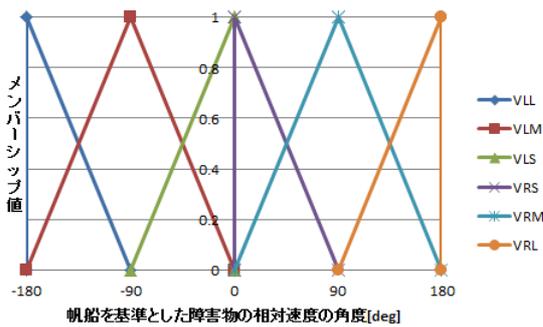


Fig. 7: 相対速度の角度についてのファジィ集合

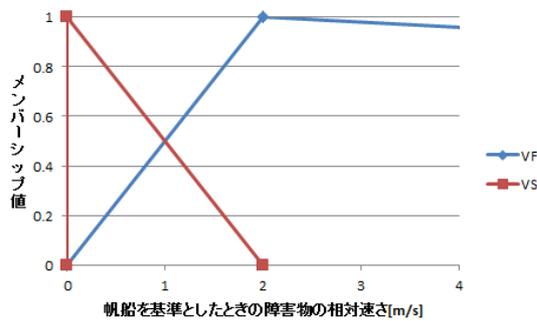


Fig. 8: 相対速さについてのファジィ集合

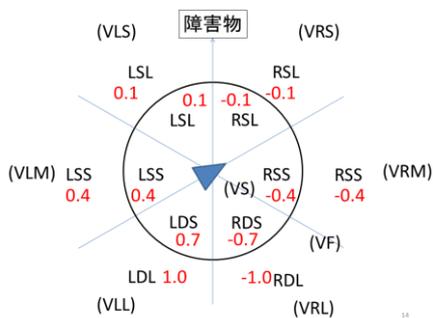


Fig. 9: 動的危険度のファジィルール

## 4 帆の制御

帆の制御について、帆の開閉を、風向風速計で取得した見かけの風向より、ファジィ推論を用いて計算する。Fig.10に、帆の制御に用いたファジィ集合を示す。追い風なら帆を開き、向かい風なら帆を閉じる制御を行う。

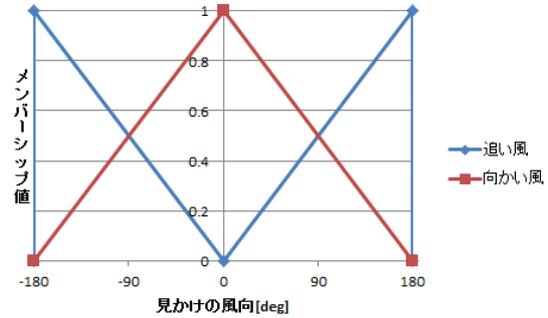


Fig. 10: 風向についてのファジィ集合

## 5 実験内容

本実験では、目標点への経路に障害物座標を設定し、目標点への帆走中の回避行動を実機実験で検証した。実験では湖上のオブジェ(河童の噴水)の座標を障害物として設定した。目標点1〜3へ順に向かい、帆船から目標点への距離が6m以内になった場合、目標点到達とする。上述の提案手法が障害物回避として有効かどうかを調べる。

- ・ 実験場所：千葉県我孫子市手賀沼
- ・ 実験日：2020年12月11日(金)
- ・ 実験開始時刻(JST)：試行1)10:50, 試行2)12:53, 試行3)12:59, 試行4)13:18, 試行5)14:19, 試行6)14:56, 試行7)15:15, 試行8)15:49
- ・ 目標点1座標：35.85996N, 140.0289E
- ・ 目標点2座標：35.85996N, 140.0281E
- ・ 目標点3座標：35.86001N, 140.0293E
- ・ 障害物座標：35.85996N, 140.0285E

実験に用いたソースコード及び取得したデータは全て以下のURL(Dropbox) <https://00m.in/i-sail2020ay>で閲覧可能である。また、実験時の映像を以下のURL(YouTube) <https://tinyurl.com/y5fj2hdt>で視聴可能である。Table 1に実験時の舵と帆の推論値とサーボモータのPWM値との対応を示す。

Table 1: 舵と帆の推論値とサーボモータのPWM値との対応

種類	推論値	PWM値
----	-----	------

舵	1	69(Full Right)
	0	94(Center)
	-1	119(Full Left)
帆	1	50(Full Open)
	0	30(Full Close)

操船の流れは、帆を推論値に基づいて操作し、0.1秒のスリープを行い、舵を推論値に基づいて操作し推論値の分スリープした後、舵をセンターに戻し1.75秒スリープするというものである。

## 6 実験結果

試行1から試行8まで実験を行った結果、試行2、試行3、試行4は障害物に接近する経路をたどったが、それ以外は障害物に接近しない経路を帆走した。なお、試行1～試行5ではS/N1、試行6～試行8ではS/N2のGPS受信器を使用した。以下は試行2、試行3、試行4の結果である。

### 7 試行2での回避行動

Fig.11に試行2の帆走経路を示す。横軸：経度、縦軸：緯度で、青線が目標点1までの経路、赤線が目標点2までの経路、水色のアスタリスクが障害物、青矢印が回避行動時の風向、黄色い点は回避行動を行った(静的危険度の絶対値が0.4以上となった)点を表している。帆船は、目標点1へ到達した後、目標点2へ向かう途中に障害物に接近し、試行開始後175.69秒から237.68秒の際に回避制御を行ったが、回避ができずに障害物と衝突してしまった。

Fig.12に試行2で衝突前に回避行動の際の危険度の推移を示す。青線が静的危険度、緑線が動的危険度、赤線が回避行動へ遷移する閾値0.4である。危険度は絶対値で示す。回避に失敗しているため、危険度があまり下がらないことが分かる。



Fig. 11: 試行2での帆走経路

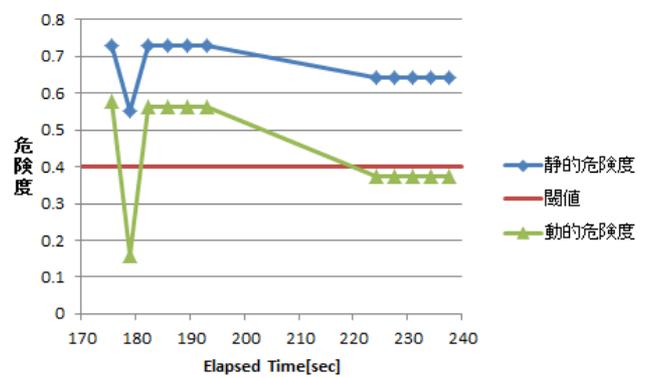


Fig. 12: 試行2での危険度の推移

### 8 試行3での回避行動

Fig.13に試行3の帆走経路を示す。ピンクの線は目標点3への経路を示しており、他の色分けは試行2と同様である。帆船は、試行3開始後439.88秒から475.97秒まで回避行動をとった。Fig.13より、障害物に対して回避行動をとった後、目標点2へ向かっていることが分かる。障害物を回避することに成功した。

Fig.14に試行3の回避行動開始直前から終了直後の静的危険度および動的危険度の推移を示す。Fig.14の青線は静的危険度、緑線は動的危険度、赤線は回避行動を取る閾値0.4である。危険度は絶対値である。Fig.14より、障害物への接近で上昇した危険度が、障害物を回避したことで大きく低下したことが分かる。これより、回避行動が有効に働いていたことが分かる。

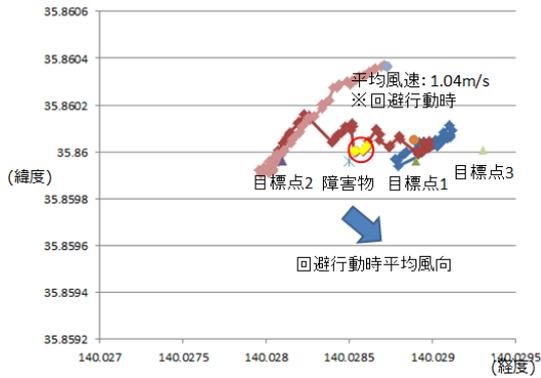


Fig. 13: 試行 3 での帆走経路

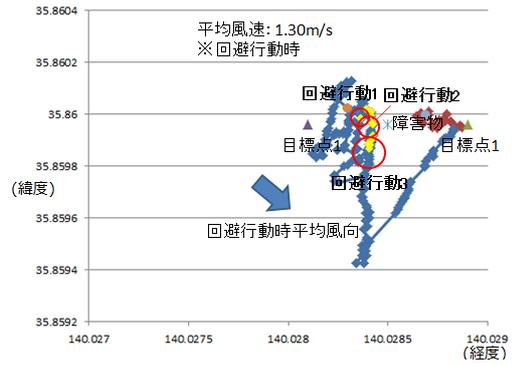


Fig. 15: 試行 4 での帆走経路

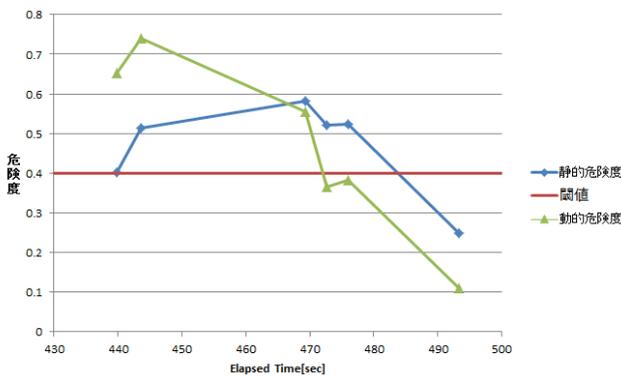


Fig. 14: 試行 3 での危険度の推移

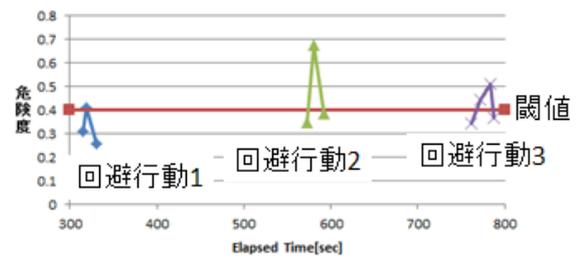


Fig. 16: 試行 4 での静的危険度の推移

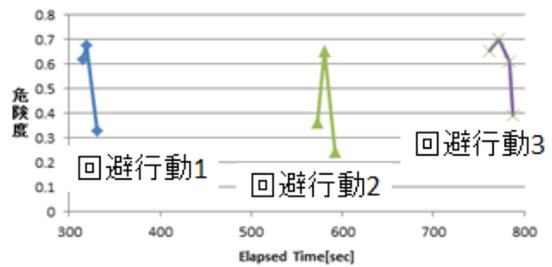


Fig. 17: 試行 4 での動的危険度の推移

## 9 試行4での回避行動

Fig.15 に試行 4 の帆走経路を示す. 色分けは試行 2 と同様である. 回避行動が 3 回に別れて行われたため, それぞれ試行 4 開始後 318.93 秒での回避行動を回避行動 1, 開始後 580.36 秒での回避行動を回避行動 2, 開始後 772.45 秒から 783.37 秒での回避行動を回避行動 3 と呼ぶ. 試行 4 でも試行 3 と同様に, 障害物の回避に成功した.

Fig.16 に試行 4 の回避行動開始直前から終了直後の静的危険度の推移, Fig.17 に同様の動的危険度の推移を示す. Fig.16 について, 青線が回避行動 1, 緑線が回避行動 2, 紫線が回避行動 3 の推移, 赤線が回避行動を取る閾値 0.4 をそれぞれ表している. Fig.17 について, 青線が回避行動 1, 緑線が回避行動 2, 紫線が回避行動 3 の推移をそれぞれ表している. 障害物に接近することで上昇した危険度が, 各回避行動により障害物を回避したことで, 低下している.

## 10 考察

実験中全試行にわたり, 帆船の挙動は不安定で, 目標点ではない方向へ向かうことが多くあった. 試行 2 では障害物に衝突してしまっていたが, 試行 3, 試行 4 では回避に成功した. 原因として, 風速の不足と GPS 受信器の特性が考えられる.

実験当日は風が弱く, 帆船の速度が遅かった. 風速は最大 3.8m/s, 平均風速 1.2m/s であり, 最大艇速 0.74m/s, 平均艇速 0.32m/s で, 全観測 2628 回のうち艇速 0.3m/s 未満が 1747 回であった. 艇速が著しく遅いと舵が効かないため, 正しい方向へ向きを変えることができない. 次に, GPS 受信器について, 位置情報が

数秒間更新されないことがあり、また、艇速が 0.3m/s 未満のとき進行方向が正しく出力されないことが多かった。舵の制御は GPS から取得した進行方向を用いて計算しているため、先述の艇速 0.3m/s 未満の場合、不正な方向へ向かうと考えられる。緯度経度および進行方向がどちらも正しいのは速度が 0.3m/s 以上かつ GPS データの更新が行われているもののみであると言える。

試行 2 での障害物へ衝突する直前の観測でも、艇速が遅く、位置情報の更新も行われていなかった。Table2, Table3, Table4 は、各試行の経過時間、速度、進行方向、障害物との距離を、回避行動が始まった後についてそれぞれ示している。各表中 GPS が更新されていない、または、速度が 0.3m/s 未満で進行方向が不正となった時刻の行を黄色に塗り分けた。試行 2 では、回避行動中の観測 11 回のうち回避行動開始時の最初の観測の 1 回でしか正しい GPS データを受信できていなかった。試行 3 では 15 回中 5 回、試行 4 では 18 回中 3 回不正ではない GPS データを取得できた。

進行方向が不正になってしまう問題点の解決策として、風があり船が走る日に実験を行う、ジャイロセンサおよびコンパスを用いて GPS に頼らない状態推定を行うことなどが挙げられる。障害物回避に関しては、不正ではないデータに限って見ると回避制御が有効に働いていた。本実験では静止した障害物についてのみ回避実験を行ったが、相対速度に基づいて回避行動を決定するため、他の船舶などの動く障害物についても適用可能である。

また、今回の実験では静的危険度が閾値を超えた際に動的危険度に基づいて回避制御を行うものであったが、速度に応じて閾値を変更し、早めに障害物を回避するなどのより堅実な回避制御が必要になってくる。さらに、動的な障害物や複数の障害物にも対応しなければならぬ環境での検証も必要である。

Table 2:試行 2 での回避行動中のデータ

経過時間	GPS更新時刻 2020-12-11	速度	進行方向	障害物との距離
175.6941	55.54.0	0.305	242.8773	1.9663
178.8072	55.57.0	0.101	0	1.6530
182.3766	56.00.0	0.279	103.1143	1.6530
185.9228	56.00.0	0.279	103.1143	1.6530
189.4711	56.00.0	0.279	103.1143	1.6530
193.0187	56.00.0	0.279	103.1143	1.6530
224.2781	56.42.0	0.107	63.8465	1.6530
227.6332	56.42.0	0.107	63.8465	1.6530
230.9748	56.42.0	0.107	63.8465	1.6530
234.3287	56.42.0	0.107	63.8465	1.6530
237.6846	56.42.0	0.107	63.8465	1.6530

Table 3:試行 3 での回避行動中のデータ

経過時間	GPS更新時刻 2020-12-11	速度	進行方向	障害物との距離
439.8835	06.30.0	0.37	197.507	12.1249
443.6150	06.33.0	0.38	229.850	11.6366
447.3215	06.33.0	0.38	229.850	11.6366
451.0284	06.33.0	0.38	229.850	11.6366
454.5966	06.44.0	0.18	272.951	9.6011
458.2890	06.48.0	0.2	242.357	8.8655
461.9957	06.48.0	0.2	242.357	8.8655
465.6883	06.48.0	0.2	242.357	8.8655
469.2397	06.59.0	0.37	288.736	6.0937
472.5974	07.03.0	0.37	316.247	5.3199
475.9679	07.06.0	0.42	302.081	5.2786
479.3238	07.06.0	0.42	302.081	5.2786
482.6646	07.06.0	0.42	302.081	5.2786
486.0204	07.06.0	0.42	302.081	5.2786
489.3613	07.06.0	0.42	302.081	5.2786

Table 4:試行 4 での回避行動中のデータ

経過時間	GPS更新時刻 2020-12-11	速度	進行方向	障害物との距離
318.9250	23.39.0	0.362	76.7157	12.5723
322.5838	23.39.0	0.362	76.7157	12.5723
326.2278	23.39.0	0.362	76.7157	12.5723
550.6384	27.30.0	0.267	143.0536	11.4143
554.2983	27.30.0	0.267	143.0536	11.4143
557.9023	27.37.0	0.177	152.9742	8.9704
561.3789	27.42.0	0.205	184.3336	8.2421
576.7449	27.57.0	0.267	143.0536	7.0647
580.3613	28.00.0	0.306	122.9991	6.3947
584.0053	28.00.0	0.306	122.9991	6.3947
587.6647	28.00.0	0.306	122.9991	6.3947
765.1009	31.06.0	0.267	20.9925	13.0555
768.7934	31.09.0	0.274	44.4378	11.7266
772.4505	31.12.0	0.442	25.7054	11.9552
776.1093	31.12.0	0.442	25.7054	11.9552
779.8019	31.12.0	0.442	25.7054	11.9552
783.3700	31.23.0	0.407	2.1798	7.9037
813.3275	31.54.0	0.265	104.2663	9.8691

## 11 結論

本研究では、ファジィ推論による帆船の障害物回避制御を実装し、実機にて実験を行った。概ね障害物を回避したが、回避制御がうまく働かずに障害物に衝突

してしまうこともあった。衝突した原因として、風速の不足、GPS受信器の特性が考えられた。不正ではないデータに限ってみると、障害物が接近すると、ファジィ推論により危険度を算出し、危険度に基づいて回避制御を行うことが確認できた。

## 12 付録

Table S1:帆船の詳細データ

項目	数値
全長	980mm※1
全高	1800mm
帆面積	0.38m <sup>2</sup>
重量	4.2kg※2

※1：船体の全長 900mm にアルミ板での延長 80mm を合わせたもの

※2：センサーなど積載物を含めての測定値

Table S2:積載物のデータ

積載物	重量	搭載位置	搭載位置
モバイルバッテリー (EMA100 SCBK)	413g※3	船体ピッチ軸から後方 310mm	船体ロール軸から上方 75mm
Raspberry Pi 3 Model B+	120g※4	船体ピッチ軸から後方 120mm	船体ロール軸から上方 60mm
GPS 受信器	67g	船体ピッチ軸から前方 485mm	船体ロール軸から上方 140mm
風向風速センサー	263g※5	船体ピッチ軸から前方 485mm	船体ロール軸から上方 230mm

※3：防水カバー、スイッチを含む

※4：防水カバーを含む

※5：アルミ板を含む

ピッチモーメントは、船体前部は145.5[Nm]、船体後部は142.43[Nm]で、差し引き3.1[Nm]である。

## 参考文献

- 1) 青木啓二, “自動運転車の開発動向と技術課題”, 情報管理, 60 巻, 4 号, p.229-239, 2017
- 2) 水間毅, “鉄道における自動運転の歴史と今後”, 計測と制御, 56 巻, 2 号, p93-98, 2017
- 3) 金井喜美雄, “航空機制御技術と自動車への応用”, 計測と制御, 45 巻, 3 号, p177-184, 2006
- 4) 福戸淳司, “自律船研究の動向”, 日本航海学会誌 NAVIGATION, 200 巻, p4-11, 2017
- 5) Jose C. Alves, Nuno A. Cruz, “an autonomous sailing platform for oceanographic missions”, OCEANS 2008, Quebec City, Canada, 2008
- 6) 橋完太, 阿部圭一郎, “風上の目標点に到達する帆走の実機実験”, 第 34 回ファジィシステムシンポジウム講演論文集, p846-850, September, 2018
- 7) 橋完太, 清水教平, 氏家智行, “ロボット帆船のファジィ化と実機実験”, 第 35 回ファジィシステムシンポジウム講演論文集, p705-714, 2019
- 8) Roland Stelzer, Tobias Proll, Robert I. John, “Fuzzy Logic Control System for Autonomous Sailboats”, 2007 IEEE International Fuzzy System Conference, London, UK, 2007
- 9) 武田賢成, “ファジィ推論を用いた自律帆走の障害物回避”, 平成三十一年度令和元年度工学院大学卒業論文, 2019
- 10) 前田陽一郎, 竹垣盛一, “ファジィ推論を用いた移動ロボットの動的障害物回避制御”, 日本ロボット学会誌, 6 巻, 6 号, p518-522, 1988
- 11) 石川繁樹, 浅香俊一, “移動障害物を含むような動的変化を伴う走行環境における自律移動ロボットの走行誘導方式”, 日本ロボット学会誌, 11 巻, 6 号, p856-867, 1993
- 12) David Fernandez Llorca, Vincente Milanes, Ignacio Parra Alonso, Miguel Gavilan, Ivan Garcia Daza, Joshue Perez, Miguel Angel Sotelo, “Autonomous Pedestrian Collision Avoidance Using a Fuzzy Steering Controller”, IEEE Transactions on Intelligent Transportation Systems, Volume:12, issue:2, p390-401, 2011
- 13) 松田秋彦, 橋本博公, 谷口裕樹, 寺田大介, 三好潤, 溝口弘泰, 長谷川勝男, 世良亘, “無人航行制御技術の最前線” 海洋理工学会誌, 23 巻, 1 号, p47-51, 2017
- 14) 橋本博公, Haiging Shen, 松田秋彦, 谷口裕樹, “漁船の衝突防止への AI 活用”, 日本水産工学会誌, 56 巻, 1 号, p51-55, 2019

# 第 17 回 CI 研究会 深層強化学習を用いた帆船の自動運転

○河村亮 橘完太 (工学院大学)

## Acquisition of Autonomous Sailboat Behaviors by Deep Reinforcement Learning

\* R.Kawamura and K.Tachibana (Kogakuin University)

**Abstract**—The autopilot of sailing vehicle, which has been attracting attention in recent years, requires a complicated judgment that takes wind into consideration. In this study, we first construct simulations of a motor boat, which does not need to consider the wind, of a sailing boat with a fixed wind, and of a sailing boat with fluctuating wind. Using each of these simulations, Deep Q-Networks of different sizes are trained. And we clarify the relationship between DQN size and the ability to acquire behavior to reach the goal.

**Key Words:** Reinforcement Learning, Sailing Boat, Simulation

### 1 はじめに

近年, 自動車<sup>1)</sup>, 鉄道<sup>2)</sup>, 航空機<sup>3)</sup>, 船舶<sup>4)</sup>の自動運転の研究が国内外で盛んに行われている. 船舶の自動運転は, 帆船と動力船が考えられる. 帆船は燃料を積まず風のエネルギーを利用するため, 燃料コストが安いことが動力船に比べ優れている<sup>5)</sup>. 無人の自動帆船の普及で, 気象データ収集, 海洋監視など, 多くの海洋事業へ適用できる<sup>6)</sup>. 特に, 必ずしも急を要しないが燃料補給や船員の生活の質確保などのコストが大きくなる海洋事業にうってつけである.

一般に, 自動運転には, 認知, 判断, 操縦の各機能が必要である. また, これら各機能は人間のエンジニアがすべてをプログラミングするには複雑すぎる. 帆船では, 既に強化学習の一手法である Q 学習を用いた帆船の経路計画が行われている<sup>6)</sup>. 強化学習とは, 環境と行動から, 将来の報酬の期待値が最大となる行動を推定する機械学習法である. しかし, Q 学習の課題として状態空間の分割離散化した後の状態数の爆発が挙げられる. その解決策として, Q 学習における状態行動価値関数(Q 関数)をニューラルネットワークで表現した Deep Q-Network(以下 DQN)が提案されている. DQN は, 自動運転<sup>7)</sup>やゲーム<sup>8)</sup>, コンピュータ将棋<sup>9)</sup>などで効果が確認されており, 動力船においても自動運転が提案されている<sup>10)</sup>. しかしながら, Fig. 1 のように帆船の動力源は風という予測困難な自然エネルギーであり, 動力船と比較すると, 状態空間が広く複雑であり自動運転が難しい.

本研究では, 帆船とモータボートのシミュレーション上で, DQN の深層強化学習を用いた自動運転を提案する. Fig. 2 に, 帆船のシミュレーションモデルを示す. シミュレーションモデルではサージ:前後の動き; スウェイ:左右の動き;とヨー:水平面の進行方向;の 3 自由度(Degrees of Freedom, DOF)の動きを模倣し, サージ速度・スウェイ速度・ヨー角速度も考慮する. DQN は, 状態行動対の価値を定める関数をニューラルネットで近似する手法である. Fig. 3 に, 深層強化学習におけるシミュレータとエージェントの関係を示す. また, 帆船とモータボートそれぞれの学習について, 層の数と層内のニューロン数が異なるいくつかの DQN で比較し, モータボートよりも状態空間の次元が高く学習が難しいと思われる帆船においても, DQN の学習がふるまい獲得に有効であるかを明らかにする.

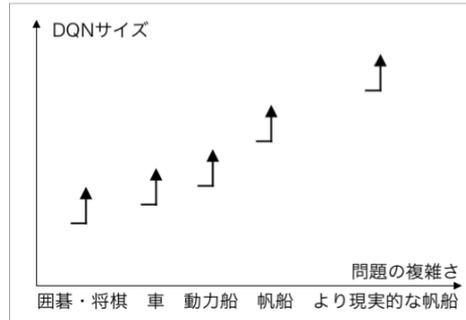


Fig. 1: Relationship between the size of the DQN and the complexity of the problem

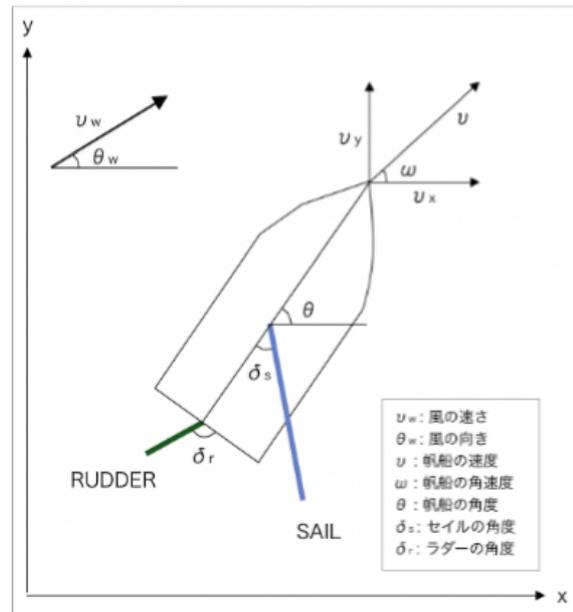


Fig. 2: Simulation model of a sailing ship

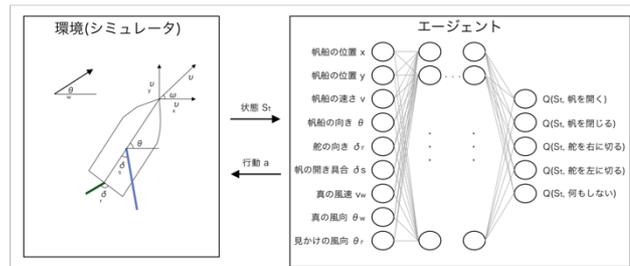


Fig. 3: About Deep Reinforcement Learning

## 2 シミュレーション実験

シミュレーションでは、単純化のため、スタート地点、ゴール地点は常に一定とした。シミュレーションモデルは、Github 上の mbocamaz/SailboatSimulation<sup>1</sup> を参考に作成した。マップのサイズは 500x500 であり、スタート地点を座標(100,100)、ゴール地点(450,450)とし  $x \in (300,500)$ かつ  $y \in (300,500)$ の範囲をゴール到達とみなす。また、マップの外に出たときや、帆船の場合 700 ステップまでにゴール到達しないときには失敗とみなしエピソードを終了する。同様にモータボートの場合は 150 ステップで失敗とみなしエピソードを終了する。

帆船においては、風を固定としたシミュレーションモデルと風にゆらぎをもたせたシミュレーションモデルで比較を行った。風にゆらぎをもたせたシミュレーションモデルでは、風速  $v_w$  は、1 つ前のステップの風速に一樣乱数  $U(-0.1, +0.1)$  に従う乱数を加えて変化させる。ただし、風速の上限は 15、下限は 9 とする。風向  $\theta_w$  においても同様に、一樣乱数  $U(-5.7, +5.7)$  に従う乱数を加えて変化させる。ただし、風の角度の上限は 0、下限は 171 とする。

モデル 1 の中間層は 3 層であり入力側からそれぞれ  $N_1 = 32, N_2 = 64, N_3 = 128$  個のニューロンを持つ。モデル 1 の自由パラメータ数は帆船の場合 11,740、モータボートの場合 11,360 である。  $N$  は入力層とニューロン層である。各層のニューロン数を  $N_i$  のとき、  $i$  は入力層を 0 とし、3 もしくは 4 まで動く。自由パラメータ数はニューラルネットワークの重み係数の数の総和であり、  $\sum_{i=1}^n N_{i-1} * N_i + N_i$  で求められる。同様に、表 1 のモデル 2~4 の行にそれぞれ自由パラメータ数、層数と層内のニューロン数を示す。これらの学習モデルについて、それぞれ 20 万ステップの学習を 5 試行行う。

環境  $s$ , 次の環境  $s'$ , 行動  $a$ , 報酬  $r$ , 割引率  $\gamma$  としたときに、Q 学習は、ある環境における行動の価値を繰り返し更新し学習をする手法である<sup>11)</sup>。

$$Q(s, a) \leftarrow Q(s, a) \alpha \left[ r + \gamma \max_a Q(s', a) - Q(s, a) \right] \quad (1)$$

DQN は Q 学習と、Deep Neural Network を組み合わせた手法であり、Q 値の更新を式 2 の誤差関数を用いて行う。

$$E(s, a) = \left( r + \gamma \max_a Q(s', a) - Q(s, a) \right)^2 \quad (2)$$

また、学習の安定化のため、Experience Replay で学習を行う<sup>12)</sup>。Experience Replay は、試行により獲得した状態、行動、報酬をメモリに蓄積し、ランダムサンプリングすることで Q-network の重み付けをする手法であり、本研究では、1000 ステップ毎に重み付けを行

った。また、割引率は 0.8 とし、学習率は最初の 62,500 ステップで 1.0 から 0.01 に減少させながら、学習モデルに適用した。実験に用いたソースコード及び取得しデータは全て以下の Dropbox<sup>2</sup> から閲覧可能である。

Table. 1: Number of neurons in a layer for each reinforcement learning model

学習モデル	帆船のニューロン数	モータボートのニューロン数
モデル 1	11,740[32, 64, 128]	11,360[32, 64, 128]
モデル 2	2,784[32, 64]	2,592[32, 64]
モデル 3	1,016[8, 16, 32]	920[8, 16, 32]
モデル 4	352[32]	256[32]

### 2.1 帆船

#### 2.1.1 帆船のシミュレーションモデル

- $\theta$ , 帆船の向き,  $[-\pi, \pi]$  ワールドの  $x$  軸に向くと  $\theta = 0$
- $v$ , 帆船の速さ,  $[0, \infty]$
- $v_x$ , 帆船のワールドの  $x$  軸方向の速度成分
- $v_y$ , 帆船のワールドの  $y$  軸方向の速度成分
- $s$ , セイルの開き具合,  $[0, 1]$
- $\delta_s$ , セイルの角度,  $[0, \frac{\pi}{2}]$  船の前後軸を基準
- $\delta_r$ , ラダーの角度,  $[0, \pi]$   $\delta_r = \frac{\pi}{2}$  でラダーが Center, 船の左右軸を基準
- $\omega$ , ヨー角速度
- $x$ , 帆船の  $x$  軸座標,  $[0, 500]$
- $y$ , 帆船の  $y$  軸座標,  $[0, 500]$
- $\theta_w$ , 真の風ベクトルの向き,  $[-\pi, \pi]$
- $v_w$ , 真の風速
- $\theta_r$ , 見かけの風向の絶対値,  $[0, \pi]$
- $dt$ , 前回のステップからの経過時間,  $(0, 1)$

見かけの風向の絶対値  $\theta_r$  は、左右を区別せず、次のように求める。  $a \% b$  は、  $a$  を  $b$  で割ったときの余りを表

<sup>1</sup> <https://github.com/mbocamaz/SailboatSimulation>

<sup>2</sup> <https://00m.in/i-sail2020ay>

す.

$$\begin{aligned}\theta_r &= |\theta_w - \theta| \%(2\pi) \\ \theta_r &:= 2\pi - \theta_r (\sin \theta_r < 0 \text{ の場合})\end{aligned}\quad (3)$$

風がセイルを押し力を計算する際、セイルの角度 $\delta_s$ を、風の当たり方によって、いったん $[0, 1]$ の範囲に正規化する.  $\pi - \theta_r$ は、 $\theta_r$ と反対側の風の角度を表す.

$$\delta_s = \min\left(s, (\pi - \theta_r) \frac{2}{\pi}, 1\right) \quad (4)$$

ヨー角速度 $\omega$ は $v, \delta_r$ から求められる.  $\Delta\omega_r$ は水がラダーを押し抵抗によるヨーモーメントである.  $v$ が大きいほどラダーの影響が $\omega$ に反映されやすい.  $\Delta\omega_d$ は船体の抵抗によるヨーモーメントである.  $\omega$ の絶対値が大きいほど旋回しにくいことを表す.

$$\Delta\omega_r = -\log(|v| + 1) \delta_r \quad (5)$$

$$\Delta\omega_d = -\text{sgn}(\omega)\omega^2 0.4 \quad (6)$$

$$\omega = \omega + (\Delta\omega_r + \Delta\omega_d)dt \quad (7)$$

$$\theta = \theta + \omega dt \quad (8)$$

速度 $v$ は $\delta_s, \delta_r$ から求められる.  $P_r$ はラダーからの速度係数の抗力であり、ラダーを大きく切った場合は、より大きな抵抗がかかることを表す.  $v_{max}$ は推進力に相当し、 $v_{max} - v$ は推進力から、速度に比例する抵抗を引いた値である. 式(13, 14)の $v_w$ に関する式は、風により帆船が流される力を表す.

$$P_r = 1 - 0.9 \sin\left(\left|\frac{\delta_r \pi}{2}\right|\right) \quad (9)$$

$$P_m = \sin\left(\frac{\pi}{2} \cdot \frac{\pi}{2} / \theta_r\right) \delta_s \quad (10)$$

$$v_{max} = (-0.2v_w + 0.8v_w^2 - 0.2v_w^3)P_r(P_m + 1) \quad (11)$$

$$v = v + (v_{max} - v)dt \quad (12)$$

$$v_y = v \cdot \cos\theta + 0.1v_w \cdot \cos\theta_w \cdot \log \quad (13)$$

$$v_x = v \cdot \sin\theta + 0.1v_w \cdot \sin\theta_w \cdot \log \quad (14)$$

$$\text{direction} = \text{atan}\left(\frac{v_y}{v_x}\right) \quad (15)$$

$$\text{speed} = \|(v_x, v_y)\| \quad (16)$$

$$v = \cos(\text{direction} - \theta) \text{speed} \quad (17)$$

速度を考慮した帆船の位置 $x, y$ は次のように求められる.

$$x = x + v_x dt \quad (18)$$

$$y = y + v_y dt \quad (19)$$

### 2.1.2 帆船の DQN エージェント

Fig. 4 にモータボートの DQN エージェントのネットワークを示す. 帆船の DQN ネットワークは、{帆船の位置 $x, y$ , 帆船の速さ $v$ , 帆船の向き $\theta$ , 舵の向き $\delta_r$ ,

真の風速 $v_w$ , 真の風向 $\theta_w$ , 見かけの風向 $\theta_r$ , 帆の開き具合 $s$ }を状態変数として扱い、{帆を開く $s+=0.1$ , 帆を閉じる $s-=0.1$ , 舵を右に切る $\delta_r-=\frac{\pi}{20}$ , 舵を左に切

る $\delta_r+=\frac{\pi}{20}$ , 何もしない}の5つの行動から1つを選択する.

報酬は、ゴールまでの距離 $GD$ の前時刻との差 $\Delta GD$ を用い、 $GD$ が減っていれば正の報酬 $0.08\Delta GD$ ,  $GD$ が増えていけば負の報酬となるよう $-0.08\Delta GD$ とする. ただし、帆船の速度成分 $v_x$ と $v_y$ の片方が正でもう片方が負の場合は報酬 $0$ とする. 加えて、帆船が $x \notin (50, 450)$ または $y \notin (50, 450)$ に位置する場合は負の報酬 $-0.7$ を与える. エピソード終了の上限ステップ数を超えた場合とマップの外に出た場合は報酬 $-15$ を与え、ゴールに到達した場合には $+80$ の報酬を与える.

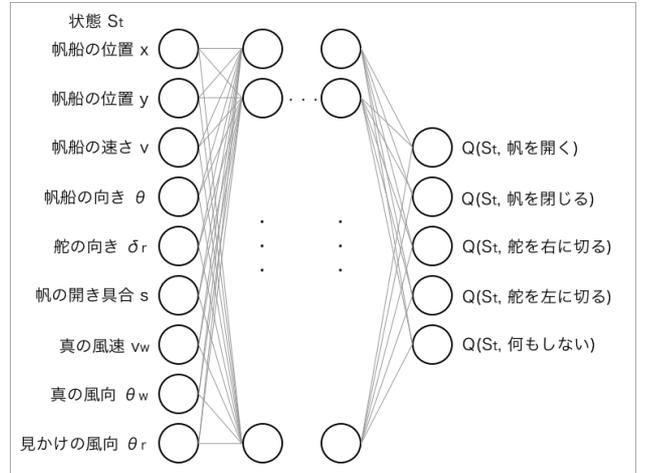


Fig. 4: DQN network of sailing ships

## 2.2 モータボート

### 2.2.1 モータボートのシミュレーションモデル

- $m$ , モータの状態  $[0, 1]$

モータボートにおいては、セイルの状態を考えず、モータの状態を加えた. モータの状態 $m$ は、 $v_{max}$ に依存し、以下のように表される.

$$v_{max} = 50m \cdot P_r \quad (20)$$

### 2.2.2 モータボートの DQN エージェント

Fig. 5 にモータボートの DQN エージェントのネットワークを示す. {モータボートの位置 $x, y$ , モータボートの向き $\theta$ , モータボートの速さ $v$ , モータの強さ $m$ , 舵の向き $\delta_r$ }を状態変数として扱い、{モータを強める $m+=0.1$ , モータを弱める $m-=0.1$ , 舵を右に切る $\delta_r-=\frac{\pi}{20}$ , 舵を左に切る $\delta_r+=\frac{\pi}{20}$ , 何もしない}の5つの行動から1つを選択する.

報酬は、ゴールまでの距離 $GD$ の前時刻との差 $\Delta GD$ ,

ゴールまで最も近づいた距離 $GD_{min}$ を用い、 $GD_{min}$ が更新されたときに正の報酬 $0.08\Delta GD$ 、それ以外は負の報酬となるよう $-0.08\Delta GD$ とする。加えて、帆船が $x \notin (80, 420)$ または $y \notin (80, 420)$ に位置する場合は負の報酬 $-0.95$ を与える。エピソード終了の上限ステップ数を超えた場合とマップの外に出た場合は報酬 $-15$ を与え、ゴールに到達した場合には $+50$ の報酬を与える。

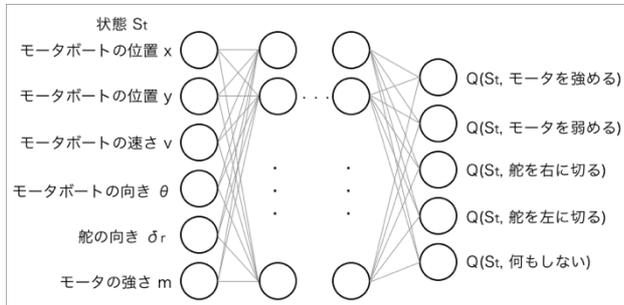


Fig. 5: Motorboat DQN Network

### 3 実験結果

Fig.6 に、風を固定とした帆船 DQN の最後の 10 エピソード中ゴールに到達した回数を、Fig.9 に、ゴール到達までに要したステップ数を箱ひげ Fig.6 で示す。Fig.24 に、ステップ数と報酬の累計を示す。Fig.7, Fig.10, および Fig.25 に、風にゆらぎをもたせた帆船 DQN について、Fig.8, Fig.11 および Fig.26 に、モータボートについて同様に示す。

Fig.12 に、風を固定とした帆船 DQN モデル1の最後の 10 エピソードの帆船軌跡を水色で示す。そのうち最短ステップでゴールに到達したエピソードを青色で示す。Fig.13, 同様にモデル2を、Fig.14 にモデル3を、Fig.15 にモデル4について示す。Fig.16, Fig.17, Fig.18, および Fig.19 に、風にゆらぎをもたせた帆船 DQN について、また、Fig.20, Fig.21, Fig.22, Fig.23 に、同様にモータボートの軌跡を示す。

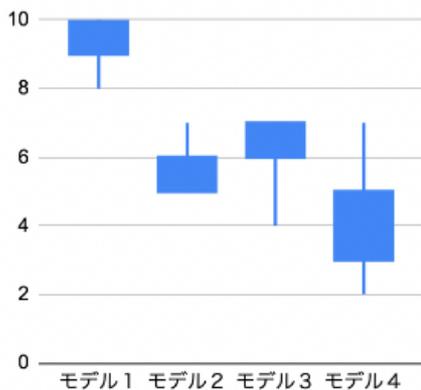


Fig.6 : Reachability in a sailing ship with wind and fixed

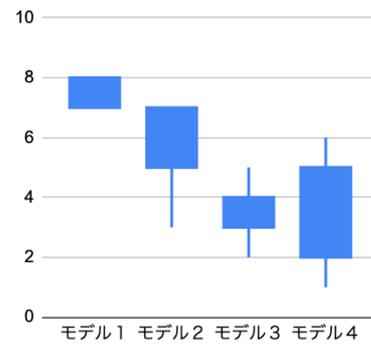


Fig.7 : Reachability in a sailing ship with fluctuating wind

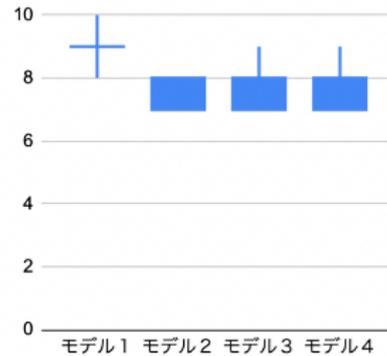


Fig. 8 : Reachability in motor boats

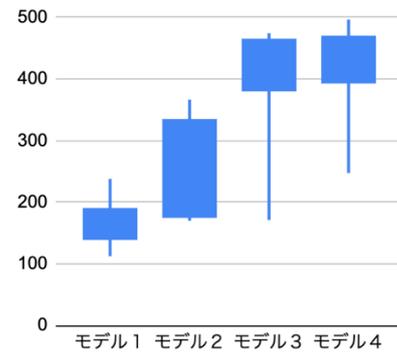


Fig. 9 : Number of steps required to reach the destination in a sailing ship with fixed wind

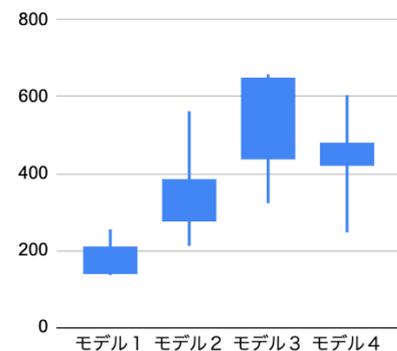


Fig. 10 : Number of steps required to reach the destination in a sailing ship with fluctuating wind.

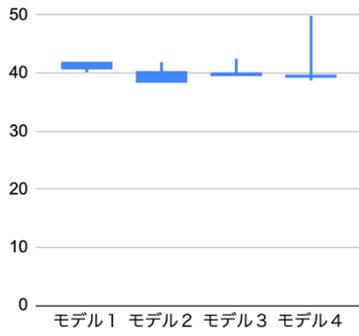


Fig. 11 : Number of steps required to reach the destination on the motorboat

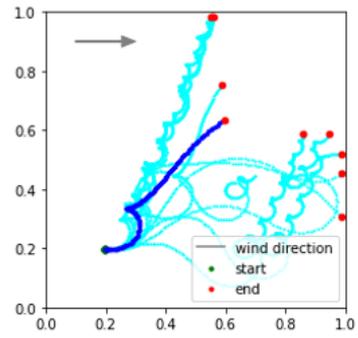


Fig. 15 : Model 4 Sailboat trajectory with fixed wind

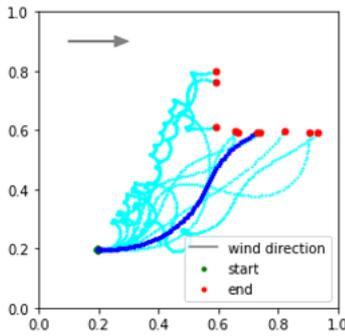


Fig. 12 : Model 41 Sailboat trajectory with fixed wind

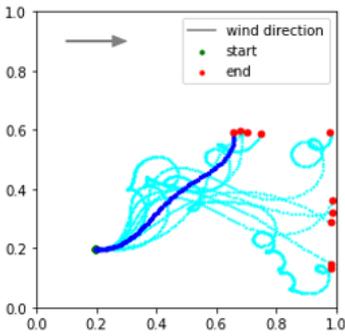


Fig. 13 : Model 2 Sailboat trajectory with fixed wind

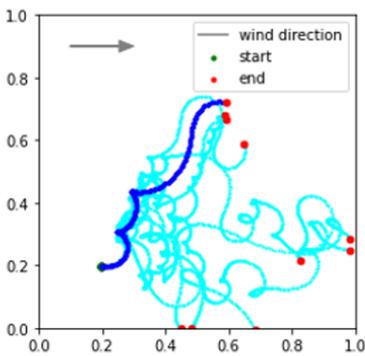


Fig. 14 : Model 3 Sailboat trajectory with fixed wind

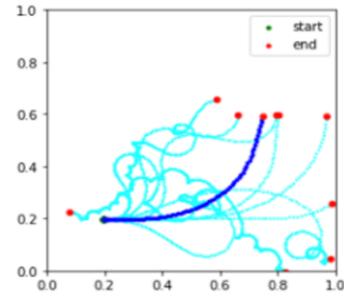


Fig. 16 : Model 1 Sailing ship trajectory with fluctuating

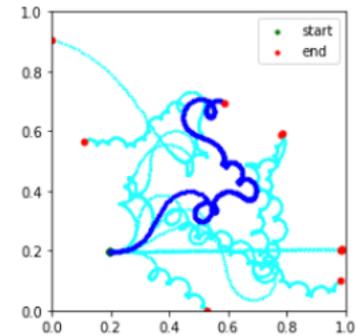


Fig. 17 : Model 2 Sailing ship trajectory with fluctuating wind

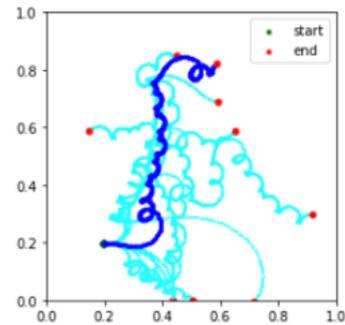


Fig. 18 : Model 3 Sailing ship trajectory with fluctuating wind

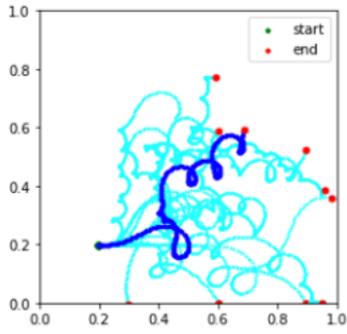


Fig. 19: Model 4 Sailing ship trajectory with fluctuating wind

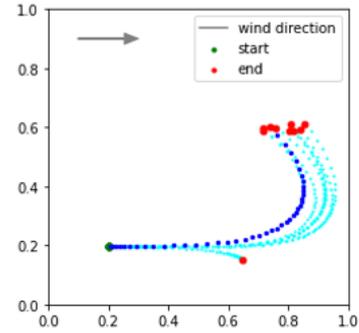


Fig. 23 : Model 4 motorboat trajectory

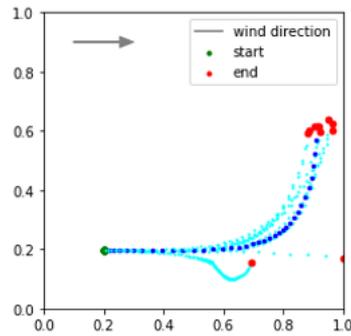


Fig. 20 : Model 1 motorboat trajectory

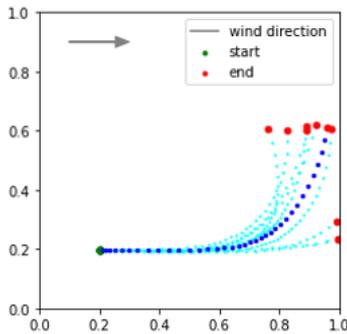


Fig. 21 : Model 2 motorboat trajectory

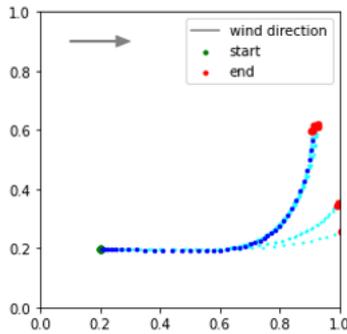


Fig. 22 : Model 3 motorboat trajectory

#### 4 考察

Fig. 6 より, 自由パラメータ数が大きい DQN モデル 1 によって平均 9.2/10 回到達し, それよりも小さなモデルでは平均 5.2/10 回であったことから, 帆船の強化学習には複雑なモデルが必要であることがわかる. また, Fig.7 の風にゆらぎを持たせたシミュレーションモデルの学習モデル 1 では, 平均 7.4 回であったことから, ニューラルネットワークが風を考慮したシミュレーションモデルの特徴を把握するには, より大きなニューロン数が必要であることが考えられる.

Fig. 20, 21, 22, 23 から, モータボートは, ゴールまでの軌道がほぼ同一であり, ゴール到達までのステップ数が収束していることがわかる. Fig. 12, 13, 14, 15 より帆船は, 収束していない. これは, 帆に当たる風の受け方が違うからであると考えられる. 帆船のモデル間を比較すると, ニューロン数が大きいほど到達までのステップ数が少ない傾向がある. このことから, 真の風を把握するためには大きなニューロン数が必要であることが考えられる.

Fig.26 のグラフより, モータボートはニューロン数を大きくした場合, 報酬の累計が小さく, 少ないニューロン数で十分学習できることがわかる. Fig.24 のグラフより, 帆船の学習済みモデル 1 とモデル 2, 3, 4 を比較すると, ニューロン層の大きさが学習の進み方に直接影響することがわかる. これは, 帆船では動力源が風であるため, モータボートより速度や方向を調整することが難しく, 状態数が増えているからであると考えられる.

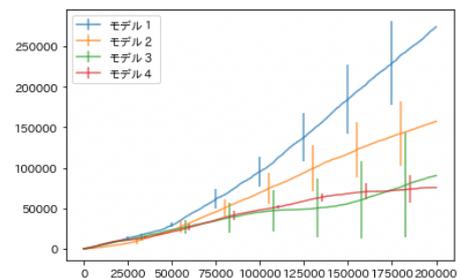


Fig. 24 : Cumulative reward in sailing ships with fixed wind

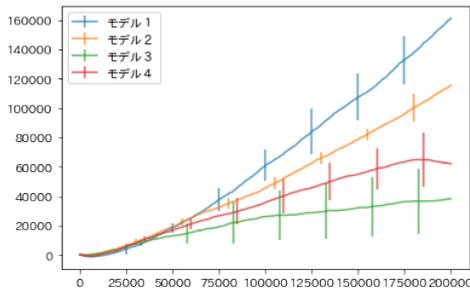


Fig. 25 : Cumulative rewards for sailing ships with fluctuating winds

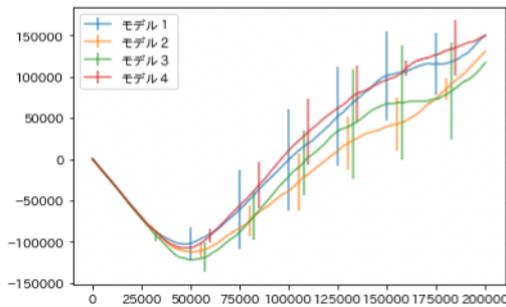


Fig. 26 : Cumulative reward in motorboat

## 5 結論

本研究は、シミュレーションで深層強化学習が帆船に有効であるか確かめた。その結果、有効ではあるが、動力船であるモーターボートと比較すると、大きなニューロン数が必要であるという結論を得た。

また、風にゆらぎを持たせたシミュレーションモデルと風を固定したシミュレーションモデルの到達率について、風にゆらぎをもたせたシミュレーションモデルは風を固定とした場合より、1.8ポイント小さかった。このことから、より現実的なシミュレーションを行う場合には、より複雑なモデルが必要であることが考えられる。

しかしながら、本研究では次の時刻での風の状態は乱数を元に変化させているため、現実との差異がまだ大きい。今後は、現実の環境と差異を少なくするため、データ同化でより実機に近いシミュレーションにしたり、より複雑なモデルでの大規模な学習を行ったりして、実用性を高めていきたい。

## 参考文献

- 1) 横山 利夫, 武田 政宣, 藤田 進太郎, 安井 裕司 : Honda の運転支援および自動運転の現状と今後, 計測と制御, 54 巻 11 号, 828/831 (2015)
- 2) 古関隆章 : 鉄道自動運転技術の動向, 電気学会誌, 140 巻 5 号, 303/306 (2020)
- 3) 安信 誠二, 足立 剛史 : 知的運転支援による飛行機操縦システムの提案, ファジィシステムシンポジウム 講演論文集, 12, 803/804 (1996)

- 4) Samuel Yanes Luis, Daniel Gutiérrez Reina, Sergio L. Toral Marín : A Multiagent Deep Reinforcement Learning Approach for Path Planning in Autonomous Surface Vehicles: The Ypacaraí Lake Patrolling Case, IEEE Volume 9, 17084/17099(2021)
- 5) J.C. Alves, Nuno Alexandre Cruz : FAST - an autonomous sailing platform for oceanographic missions, Oceans'14 MTS/IEEE (2014)
- 6) Andouglas Gonçalves da Silva Junior, Davi Henrique dos Santos, Alvaro Pinto Fernandes de Negreiros, João Moreno Vilas Boas de Souza Silva, Luiz Marcos Garcia Gonçalves I : High-Level Path Planning for an Autonomous Sailboat Robot Using Q-Learning, Sensors (2020)
- 7) Sallab, Ahmad EL, Abdou, Mohammed, Perot, Etienne, Yogamani, Senthil : Deep Reinforcement Learning framework for Autonomous Driving, Electronic Imaging, Autonomous Vehicles and Machines, 70/76 (2017)
- 8) 水上直紀, 鶴岡慶雅 : 強化学習を用いた効率的な和了を行う麻雀プレイヤー, ゲームプログラミングワークショップ 2016 論文集 2016 巻, 81/88 (2016)
- 9) 和田 悠介, 五十嵐 治一 : 将棋の局面評価関数におけるディープラーニングの利用, ゲームプログラミングワークショップ 2017 論文集 2017 巻, 244/249 (2017)
- 10) Yujiao Zhao, Xin Qi, Yong Ma, Zhixiong Li, Reza Malekian, Miguel Angel Sotelo : Path Following Optimization for an Underactuated USV Using Smoothly-Convergent Deep Reinforcement Learning, IEEE Transactions on Intelligent Transportation Systems (2020)
- 11) 吉本 潤一郎, 銅谷 賢治, 石井 信 : 強化学習の基礎理論と応用 Fundamental Theory and Application of Reinforcement Learning, 計測と制御, 44 巻, 313/318 (2005)
- 12) Volodymyr Mnih, Koray Kavukcuoglu, David Silver, Andrei A. Rusu, Joel Veness, Marc G. Bellemare, Alex Graves, Martin Riedmiller, Andreas K. Fidjeland, Georg Ostrovski, Stig Petersen, Charles Beattie, Amir Sadik, Ioannis Antonoglou, Helen King, Dharshan Kumaran, Daan Wierstra, Shane Legg, Demis Hassabis : Human-level control through deep reinforcement learning, Nature (2015)

# 帆船ロール角の逐次データ同化

○森本明日香 橋完太 (工学院大学)

## Data assimilation of sailboat roll angle

\* Morimoto Asuka and Tachibana Kanta (Kogakuin University)

**Abstract** — In a previous study of ship data assimilation, sequential data assimilation of parametric rollover in irregular headwaves was performed. In this study, we implemented a particle filter to sequentially data assimilate from asynchronous observations of wind direction and speed (sampling frequency averaging 3.75Hz) and roll angle and roll angular velocity (sampling frequency averaging 37.86Hz). The coefficient of the sail force  $k$ , and the roll inertial moment  $I$ , were estimated from about 160,000 observations. It was confirmed that the confidence of  $k$  and  $I$  increased as the data assimilation increased.

**Key Words:** Data assimilation, Sailboat roll dynamics, Particle filter

### 1 はじめに

データ同化<sup>[1]</sup>は気象学や海洋学分野で用いられる手法である。物理法則などの法則に基づいて時空間のシミュレーションモデルを構成し、モデルの計算を行うことで、実際の地球システムなどの再現、解明、予測を行える<sup>[2]</sup>。数値シミュレーションを行うには、初期条件、境界条件、パラメータなどを与える必要がある。データ同化の目的は、「実測データを用いて数値シミュレーションモデルの精度・性能を改善すること」と「物理法則を表現するシミュレーションを用いることで、観測の不足を補ったり観測誤差を修正したりする」ことの二つが挙げられる。データ同化を実際に行うには数値シミュレーションモデル、観測データ、統計科学の知見、高性能な計算機が必要である。物理法則に基づいた数値シミュレーションではなく、特に根拠もなく作ったモデルで時間発展を記述してもデータ同化は可能であるが、物理法則に基づいた数値シミュレーションを使うと、観測で得られる知見だけではなく、物理学の知見を投入できる。データ同化の手法<sup>[3]</sup>には線形ガウス状態遷移モデルを用いるカルマンフィルタ(KF)のほか、非線形系でも扱え、計算効率がよいアンサンブルカルマンフィルタ(EnKF)<sup>[4]</sup>や粒子フィルタ(PF)<sup>[5]</sup>が提案されている。

KF では線形ガウスでない場合に妥当な計算結果を得られない<sup>[6]</sup>が、PF では線形ガウスの仮定を必要とせず一般状態空間モデルを対象にできる。また、PF は行列計算を必要とせず、プログラムの実装が容易である。

近年、自動運転の研究は自動車のみならず、航空機<sup>[6]</sup>や船舶<sup>[7]</sup>でも盛んである。自ら動力を持たない帆船は、風をエネルギーとして進むため、環境負荷と航続距離の面で優れているが、陸上と異なり波や風の影響を大きく受け帆船の自動運転は困難である。帆船の自動運転プログラムをすべて人間が設計することは、状態空間が広く複雑であるため困難であり、機械学習の導入が期待できる。複雑な問題に対する機械学習の利用には大量の学習データが必要となり、現実世界で取得する帆走データに加えてシミュレーションでの帆走データを得るために、現実に即したシミュレーションを構築する必要がある。帆船の動きは数値シミュレーションと現実の水上的動きは異なる部分が出てくる。本研究では、数値シミュレーションと水上での差を埋めて、より現実に近いシミュレーションを行えるようデータ同化を行う。

本研究では自動帆走のシミュレーションモデルと実機帆走の観測データをデータ同化し、直接は測ることのできない動力学的特性を推定する。船には6自由度(サージ・スウェイ・ヒープ・ロール・ピッチ・ヨー)ある。Fig.1に船の6自由度を示す。本研究では、ロールとその時間変化の状態推定と、ロールに関する動力学的特性、つまり、横風成分が船を横倒しにする力の係数  $k$  とロールの慣性モーメント  $I$  の推定を同時に行う。

Fig.2にデータ同化の流れを示す。風センサおよびジャイロセンサによる観測値から、未知数である動力学的特性を求める。力学的シミュレーションに対応した状態遷移モデルを構成する。状態変数および観測変数は確率変数である。観測値  $O_t$  は観測変数  $Z_t$  の実現値として生成されるとする。観測モデルによってシミュレーションモデル(状態遷移モデル)と観測値を組み込むことでデータ同化を行う。

帆のない船が向かい波を進むときのロールについてデータ同化<sup>[8]</sup>は既に行われている。本研究では帆船が受ける風の情報とロール運動からデータ同化を行う。データ同化手法としてPFを用いる。PFはノンパラメトリックな任意の確率分布を取り扱うことが可能<sup>[9]</sup>であり、分散型の並列計算機に適したアルゴリズムである利点<sup>[10]</sup>もある。データ同化において、PFの問題点もある<sup>[11]</sup>。それは高次元の分布関数を表現するには、膨大な粒子数が必要であること、逐次推定を進めていくにつれて分布関数を表現するための粒子数が不足する「退化」現象が起こりやすいこと、また、シミュレーションモデルが重い場合には超高並列計算機の利用が必要であることが挙げられる。これらに注意してPFを用いたデータ同化を行う必要がある。本研究での推定対象はロール回転方向のみの1自由度でありシミュレーションモデルも小規模で単純であるためPFを利用する。

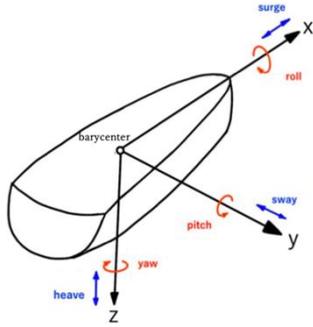


Fig.1: 6 degrees of freedom of the ship

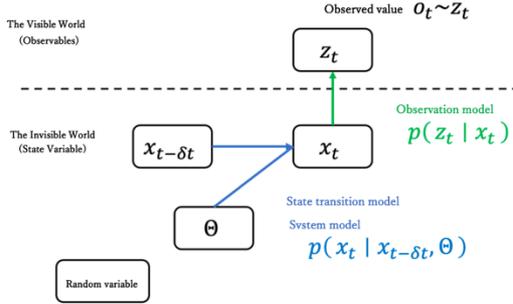


Fig.2: Data assimilation by particle filter

Fig.3 に、データ同化における PF の処理の流れをシーケンス図で示す。PF オブジェクトの予測 (predict) メソッドでは各 Particle オブジェクトの状態遷移を行い、尤度計算 (calcLikelihood) では各 Particle オブジェクトの尤度を計算する。復元抽出 (resampling) ではベイズの定理により事後分布を近似する粒子の分布を得る。

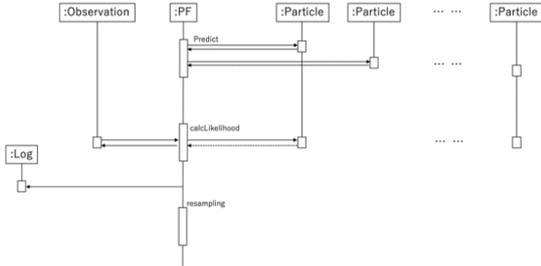


Fig.3: Process flow of particle filter

## 2 データ同化実験

### 2.1 状態変数と状態遷移モデル

本研究では観測されたデータとシミュレーションを突き合わせて、定数パラメータ (後述の  $k$  と  $I$ ) を推定する。これらの定数パラメータは、2種類の流体 (空気と水) が関わり、船体や帆の形状、材料の材質や力学的特性、質量バランスなど個々の船舶によって異なる一方、厳密に求め

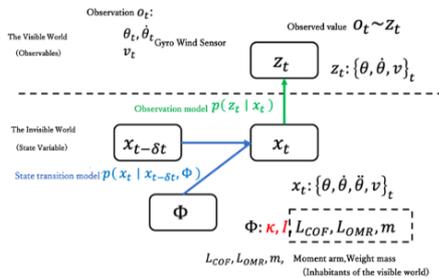


Fig.4: Data assimilation by particle filter

るためには流体力学の実験が必要になる。流体力学の実験には費用も時間も膨大にかかるため、データ同化により推定する。

Fig.4に、帆船ロール角の粒子フィルタによるデータ同化のベイジアンネットワークを示す。各時刻の状態変数は、ロール角  $\theta$ 、ロール角速度  $\dot{\theta}$ 、ロール角加速度  $\ddot{\theta}$ 、および、帆が押される風速の横向き成分  $v$  である。観測変数は、実機実験中に加速度ベクトルから算出したロール角とジャイロセンサで計測したロール角速度、および、風センサと帆のPWM値から算出した  $v$  である。状態遷移モデルのことを力学シミュレーションとも呼ぶ。シミュレータの定数パラメータ  $k, I$  は各粒子では確定的に取り扱い、粒子フィルタ全体としてはパラメータ空間での確率分布として取り扱われる。

数値シミュレーションモデルは物理法則に基づいたロール角のモーメント式を用いる。Fig.5に、帆船を後ろから見た図を示す。これは左舷から風を受けている場合の図である。帆が風を受けると風下方向へのロールモーメントが生じる。船が傾くと、錘の重力が加わることで復元力モーメントが働く。風によるロールモーメントと復元力モーメントの差に比例した角加速度  $\ddot{\theta}$  が求められる。この際、未知数である  $k$  と  $I$  が関わる。風速のうち帆に当たる横向き成分の速さを  $v_t$ 、風を受ける帆の角を  $\phi_t$  とし、

$$v_t = \begin{cases} 0 & (|\phi_t| \geq |AWA_t|) \\ AWS_t \sin(|AWA_t| - |\phi_t|) \cos|\phi_t| & (\text{otherwise}) \end{cases} \quad (1)$$

$$\ddot{\theta} = I^{-1}(k v_t L_{COF} \cos \theta_t - mg L_{OMR} \sin \theta_t) \quad (2)$$

となる。ここで、 $AWS_t$  は見かけの風速、 $AWA_t$  は見かけの風向である。Fig.6に、 $v_t$  を求める時の上から見た帆船の図を示す。

帆が風を受ける力の中心の高さ  $L_{COF}$  と錘の中心までの長さ  $L_{OMR}$ 、錘にかかる重力  $mg$  は実機を計測した。Table 1 にこれらの計測値を示す (計測日: 2020年12月17日; メジャー (型番 H119-75, TAJIMA) とデジタルクッキングスケール (型番 KJ-212, 株式会社タニタ) による)。  $v_t$  は、 $|\phi_t| \geq |AWA_t|$  の場合、帆が風の力を受けないため 0 である。  $\ddot{\theta}$  を積分 (加算) して角速度  $\dot{\theta}$  を求め、  $\dot{\theta}$  を積分 (加算) してロール角  $\theta$  を求める。定数  $\Phi$  には、船の実機情報である帆の長さや錘の重さや、実機観測できない力学的特性 (2) 式の  $k, I$  の値が含まれる。

状態遷移モデルにおいて  $v_t$  は、試行 1, 試行 2, 試行 3 では前回の観測からの時間に関わらず 60% の粒子をランダムに選んで初期化し、40% は (3) 式で更新した。このことにより、1 秒たつとほぼすべての粒子が初期化され、風の時間連続性を反映できなかった。そこで、試行 4, 試行 5, 試行 6 は全体の 0.3% を初期化し、99.7% を (3) で状態遷移し、風の時間連続性を反映させた。

$$v = v + \varepsilon_v \\ \varepsilon_v \sim N(0, 0.0425) \quad (3)$$

センサのサンプリング周波数は平均約 37.86Hz で観測し、観測時刻が異なるため更新された観測データのみを尤度計算に用いる。

## 2.3 データ同化

粒子フィルタにおける状態変数  $\theta$ ,  $\dot{\theta}$ ,  $\ddot{\theta}$ ,  $v_t$  の初期分布は、正規分布と一様分布を用いる。その際、千葉県我孫子市手賀沼で 2020 年 12 月 8 日に行った実機実験データを参考に正規分布  $N(\mu, \sigma)$  の  $\mu$  と  $\sigma$  を四分位数から求めた。k と I は正の値であるので、対数正規分布を用いる。Table 2 に  $\theta$ ,  $\dot{\theta}$ ,  $\ddot{\theta}$ ,  $v_t$  の初期分布の  $\mu$ ,  $\sigma$  を示す。k と I は Table 3 および Table 4 の初期値となるよう対数正規分布のパラメータを決める。

Table 2: Initial value

	$\mu$	$\sigma$
$v_t$	0	0.85
$\theta$	0	0.29
$\dot{\theta}$	0	0.065
$\ddot{\theta}$	0	0.05

$i$  番目の粒子の尤度  $L(i)$  は、粒子が仮説として持つ横風成分  $v_i$ , 角速度  $\dot{\theta}_i$ , 角度  $\theta_i$  と観測データから求められた横風成分  $v_o$ , 角速度  $\dot{\theta}_o$ , 角度  $\theta_o$  を用い、

$$L(i) = \exp \left\{ - \left( \frac{v_i - v_o}{\sigma_v} \right)^2 - \left( \frac{\dot{\theta}_i - \dot{\theta}_o}{\sigma_{\dot{\theta}}} \right)^2 - \left( \frac{\theta_i - \theta_o}{\sigma_{\theta}} \right)^2 \right\} \quad (4)$$

$$L(i) = \exp \left\{ - \left( \frac{v_i - v_o}{\sigma_v} \right)^2 \right\} \quad (5)$$

$$L(i) = \exp \left\{ - \left( \frac{\dot{\theta}_i - \dot{\theta}_o}{\sigma_{\dot{\theta}}} \right)^2 - \left( \frac{\theta_i - \theta_o}{\sigma_{\theta}} \right)^2 \right\} \quad (6)$$

とする。(4)は風センサ、9軸センサどちらも更新された場合の式となる。風センサのみの場合は(5)の式になり、9軸センサのみの場合は(6)の式で尤度計算を行う。Predict では観測値と得られたデータから次の時間の予測を行い、データの同化を行う。PF 初期においては、粒子の密度を確保するため、粒子数を初め 10,000 個に設定し、観測 1 回ごとに 1,000 個ずつ減らし、10 回目以降は 1,000 個の粒子で実験を行う。8 万行以上のデータを用いてデータ同化を行うため 10,000 個の粒子であると膨大な時間がかかってしまうため、密度を確保でき次第粒子の数を減らし、実験時間削減を目的とする。上述の数値シミュレーションモデルと観測データを用い、PF を用いたデータ同化を行った。データ同化は 6 回試行し、試行 1, 試行 2, 試行 5 は実験 2 のデータを用いて行い、試行 3, 試行 4, 試行 6 は実験 1 のデータを用いて試行した。試行 2, 試行 3, 試行 4, 試行 5, 試行 6 の k と I の初期値は、前の試行の最後の分布を引き継いで行う。

## 3 データ同化結果

Table 3, Table 4 に k と I の分布をそれぞれ示す。どちらの

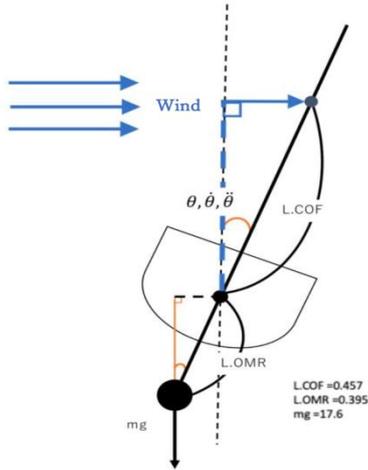


Fig.5: Roll moment

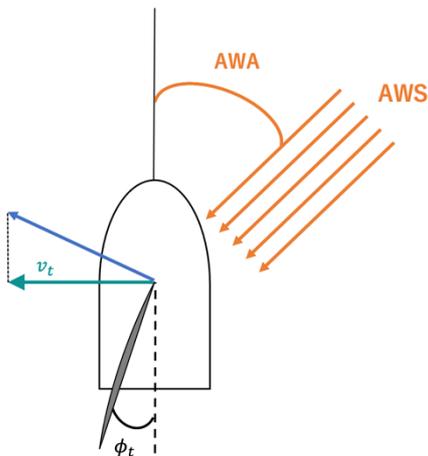


Fig.6: A sailing ship viewed from above

Table 1: Value of the component

成分の名前	値(単位)
L.COF	0.475 (m)
L.OMR	0.395 (m)
mg	17.6 (kgW)

## 2.2 実機実験データ

実機実験の場所日時を以下に示す。

- ・実験場所：千葉県我孫子市手賀沼
- ・実験開始日時：実験 1) 2020 年 12 月 27 日 11:12  
実験 2) 2020 年 12 月 27 日 11:31

実験の映像をこの URL (<https://tinyurl.com/y97mdg6f>) に示す。

実機帆走中の風センサと 9 軸センサの観測データおよび帆のサーボモータへの指令値をデータ同化に用いる。ただし、風センサのサンプリング周波数は平均約 3.75Hz, 9 軸

Table も試行 1 の初期値, 試行 1 で得られた最後の分布, 試行 2 で得られた最後の分布, 試行 3 で得られた最後の分布, 試行 4 で得られた最後の分布, 試行 5 で得られた最後の分布, 試行 6 で得られた最後の分布の順に示す. Fig.7, Fig.8 に, これらの分布の確率密度を図示する. 今回使用した観測データは 8 万行以上あり全てを図にすると比較が困難なため, Fig.9~Fig.12 は一部を抜き出して図示する. Fig.9 と Fig.10 に, 実験 2 開始 284.6218 から 558.1398 秒後を抜き出して試行 1, 試行 2, 試行 5 の  $k$  と  $I$  の推定期待値をそれぞれ示す. Fig.11 と Fig.12 にそれぞれ実験 2 開始 600.0077~713.6199 秒後を抜き出して試行 3, 試行 4, 試行 6 の  $k$  と  $I$  の推定期待値をそれぞれ示す. Fig.9~Fig.12 の縦軸は対数目盛で示す.

Table 3:  $k$  distribution values

	第 1 四分位	中央値	第 3 四分位	四分位範囲 IQR
初期値	2.051	4.376	18.533	16.482
試行 1 後	3.85597	4.672967	5.629286	1.773316
試行 2 後	1.858379	2.006326	2.204649	0.346170
試行 3 後	1.188232	1.264888	1.370653	0.182421
試行 4 後	1.122048	1.157454	1.186761	0.064713
試行 5 後	1.068923	1.077665	1.085724	0.016801
試行 6 後	1.062312	1.083571	1.113991	0.051679

Table 4:  $I$  distribution values

	第 1 四分位	中央値	第 3 四分位	四分位範囲 IQR
初期値	0.2021	0.3679	0.6697	0.4676
試行 1 後	1.646403	1.815267	2.096667	0.450264
試行 2 後	1.056028	1.094099	1.129786	0.073758
試行 3 後	1.428544	1.477667	1.515507	0.086963
試行 4 後	1.165805	1.267933	1.380903	0.215098
試行 5 後	1.111600	1.126520	1.144470	0.032870
試行 6 後	0.992029	1.031430	1.060887	0.068858

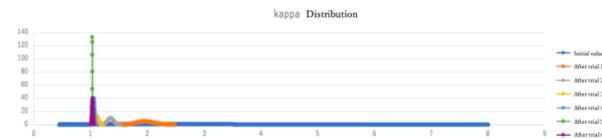


Fig.7:  $k$  distribution

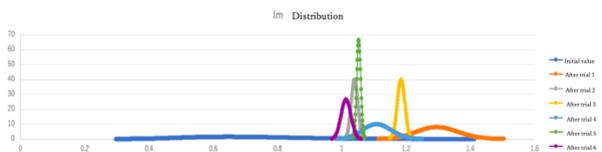


Fig.8:  $I$  distribution

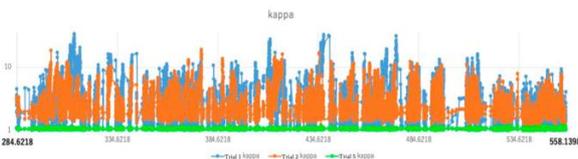


Fig.9: Value of  $k$  in trial 1, trial 2, and trial 5

Fig.10: Value of  $I$  in trial 1, trial 2, and trial 5

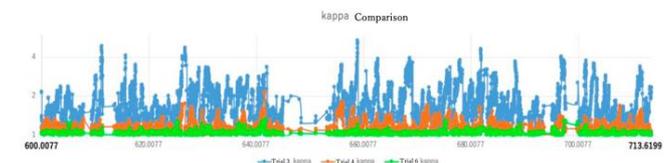


Fig.11: Value of  $k$  in trial 3, trial 4, and trial 6

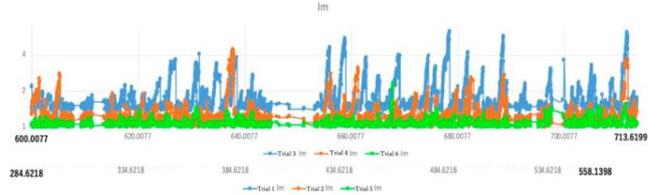


Fig.12: Value of  $I$  in trial 3, trial 4, and trial 6

## 4 考察

Table 2, Table 3, Fig.7, Fig.8 より, 試行 1 の初期値よりも IQR が小さくなっていることがわかる. データ同化によって分布の幅は狭まり, 確信度の高い推定となっていることと言える. しかし, 試行 4 ではロール慣性モーメント  $I$  の分布が広がった. これは試行 1~試行 3 では横風の時間連続性を考慮しない状態遷移モデルを用い観測ごとに  $v$  の分布が初期分布にかなり近付き, 横風の時間連続性の制約がないため慣性モーメントについての思い込みが強くなり, 試行 4 では, 横風の時間連続性を考慮するよう改善した結果, 慣性モーメントについての確信度が低くなったと考える. 試行 5, 試行 6 にてデータ同化を進めることで IQR は小さくなっていき再び  $I$  について確信度が高まったと考える.

Fig.9, Fig.10, Fig.11, Fig.12 よりそれぞれ特定のタイミングの観測データで桁違いに大きく推定されていることがわかる. 大きく推定されるタイミングは試行 1 と試行 2, 試行 3 と試行 4 で大きな違いは出ていない.

これらの結果から, データ同化された動力学的特性の推定値の分布を引き継ぎ繰り返すことで, 確信度を高めることができたと考える. 本研究では同データでの試行は 3 回であったが, 何度も繰り返すことで確信度は高められるのではないかと考える.

今回データ同化を PF で行なった. 8 万行という膨大なデータ量を扱ったため, パソコン (プロセッサ: Intel (R) Core (TM) i7-6700 CPU 3.40GHz 3.41GHz, 実装 RAM: 8.00GB) による実験時間は試行 1 回につき約 8 時間から 9 時間となった. 手法の改善や高性能な計算機により実験時間を短くすることができるのではないかと考える.

## 5 結論

本研究では 1 自由度 (ロール) のみをデータ同化することにより, 横風成分が船を横倒しにする力の係数  $k$  とロールの慣性モーメント  $I$  を推定した. その結果,  $v_t$  の時間連続性を考慮することで慣性モーメント  $I$  の制約が生まれ, 分布が広がった. データ同化を進めることで, 確信度の高い推定値を得られるという結論を得た.

現実に近いシミュレーションを行うための定数パラメータを推定する際に粒子フィルタが有用であることがわかった. 本研究では 1 自由度のみの推定を行ったが, 今後は 6 自由度全てを用い, より現実に近いパラメータ推定を行い, シミュレーションの実用性を高めていきたい.

## 参考文献

- [1] 樋口知之. (2011) 『予測にいかす統計モデリングの基本-ベイズ統計入門から応用まで』, 講談社
- [2] 中村和幸, 上野玄太, 樋口知之: “データ同化-その概念と計算アルゴリズム”, 統計数理, 53巻, 2号, p211-229, 2005年.
- [3] 村上章, 西村伸一, 藤澤和謙, 中村和幸, 樋口知之: “粒子フィルタによる地盤解析のデータ同化”, 応用力学論文集, 12, pp.99-105, 8月2009年.
- [4] Evensen Geir: “The ensemble Kalman filter:Theoretical formulation and practical implementation”, Ocean Dynamics, 53, p343-367, 2003.
- [5] Kitagawa, G.: Monte Carlo Filter and Smoother for non-Gaussian nonlinear state space model, journal of Computational and Graphical Statistics, Vol.5, No.1, p1-25, 1996.
- [6] 安信 誠二, 足立 剛史: “知的運轉支援による飛行機操縦システムの提案”, ファジィシステムシンポジウム講演論文集, 12, p.803-804, 1996年.
- [7] 森下 隆: “船舶自動化システム技術”, 日本舶用機関学会誌, 21巻, 11号, p.715-724, 1986年.
- [8] 寺田大介, 橋本博公, 松田秋彦: “不規則向かい波中のパラメトリック横揺れの逐次データ同化”, 日本船舶海洋工学会講演会論文集, 22, np.2016S-GS2-21, pp.193-195, 2016年.
- [9] 北川源四郎: “モンテカルロ・フィルタおよび平滑化について”, 統計数理, 44巻, 1号, p31-48, 1996年
- [10] Evensen Geir: “Sequential data assimilation with a non-linear quasi-geostrophic model using Monte Carlo methods to forecast error statistics, Journal of Geophysical Research”, 99, p10143-10162, 1994.
- [11] 上野玄太: “粒子フィルタとデータ同化”, 統計数理, 67巻, 2号, p241-253, 2019年

# 数理モデルおよび粒子群最適化法による河川水質予測

○上田 剛士<sup>1</sup> 磯川 悌次郎<sup>1</sup> 中川 学<sup>2</sup> 笠原 隆史<sup>2</sup>  
松下 智則<sup>3</sup> 中山 俊一<sup>3</sup> 井上 晴夫<sup>3</sup>, 若松 次男<sup>4</sup>,  
宮ノ下 友明<sup>5</sup> 畠田 泰彦<sup>5</sup> 鳥羽 裕一郎<sup>5</sup> 上浦 尚武<sup>1</sup>  
(<sup>1</sup>兵庫県立大学 <sup>2</sup>奈良市企業局 <sup>3</sup>オルガノプラントサービス株式会社  
<sup>4</sup>株式会社コンテック <sup>5</sup>オルガノ株式会社)

## A Tank Model Based Prediction System for River Water Quality

\*T. Ueda<sup>1</sup>, T. Isokawa<sup>1</sup>, M. Nakagawa<sup>2</sup>, T. Kasahara<sup>2</sup>,  
T. Matsuishita<sup>3</sup>, S. Nakayama<sup>3</sup>, H. Inoue<sup>3</sup>, T. Wakamatsu<sup>4</sup>,  
T. Miyanoshita<sup>5</sup>, Y. Shimada<sup>5</sup>, Y. Toba<sup>5</sup>, and N. Kamiura<sup>1</sup>  
(<sup>1</sup>University of Hyogo <sup>2</sup>Nara City Enterprise Bureau <sup>3</sup>Organo Plant Service Corporation  
<sup>4</sup>Contec Corporation <sup>5</sup>Organo Corporation)

**Abstract**— In water purification plants, it is necessary to predict the quality of raw water (or turbidity) in the river in order to put in appropriate amount of polymer coagulant, particularly on rainfall. This task is manually conducted by operators in the plant, but these should be conducted in automatic manner for operating many plants by a few operators. In this paper, we propose a system for predicting the quality of raw water from the distribution of precipitation around the river. This system consists of a mathematical model called tank model, in which a series of water tanks with their holes produces water and turbidity as output on injecting water of rainfall as an input to a tank. We adopt so-called particle swarm optimization (PSO) for configuring the parameters in the tank model, so that time series of actual turbidity can be presented by this model. Experimental results show that rapid rises for turbidity can be predicted by using this model.

**Key Words:** Water Quality, Tank model, Water purification, Particle Swarm Optimization

## 1 はじめに

水道水は日本において生活に最も身近なライフラインであり、浄水場では安全かつ適正に配水されることが求められている。浄水場では凝集、沈殿、ろ過、消毒のプロセスからなる方式が一般的であり、この過程が水道水の安全に関して非常に重要である。しかし水道事業に携わる職員の数は減少の一途をたどっており、すべての浄水場に人員を常駐させることが難しくなっている。そのため小規模な浄水場では無人化での運転が進んでいる。また、こうした状況を踏まえて、浄水場では水質自動制御システムの必要性が大きくなっている。

一定以上の水質を確保する観点では、バランスのとれた細かい管理による濁質の沈殿処理強化や病原性微生物の十分な消毒が求められている。しかしながら、現状では、目視での判断に基づいた量の薬品が投入されており、集中豪雨などが起こった際に発生する急激な水質の変化に対応した制御を行うことが困難である。この問題に加えて、降雨量が多量になった際に、浄水場の職員が薬品の注入量の調節のため無人浄水場に行くことは浄水場が水源に近い場合、安全が確保できない、人材不足などにより難しい、などの問題がある。一時的に薬品の注入量を増やしたとしても、水質の変化に合わせて調節をしなければ過剰注入となり薬剤のコストの増加や水道水の臭いの原因になってしまう。

そこで本研究では、水質自動制御システムを実現する第一歩として、河川から取水する水の品質、すなわち河川水の濁度を予測するシステムの構築することを目的とする。濁度予測を行う上で、浄水場が取水して

いる河川の流量が濁度算出の要因の一つとなると考えられる。そのため、河川に流れ込む雨量から河川流量を予測し、この予測流量から濁度を求めることにより濁度の予測を行う。

降雨による雨量と河川流量の関係を表現するために、菅原によって提案されたタンクモデルが一般的に知られている<sup>1)</sup>。タンクモデルでは、河川流域を水を蓄える複数のタンクとして取扱い、このタンクから流出する水量により流域における流量を表現する。タンクからの流出係数を変化させることにより様々な流出現象を表現できることが示されており、これは簡易に記述可能でありながら比較的再現性の高いモデルであるといえる。しかしタンクモデルは、現実の河川流域に近づけようとするほど設定すべきモデルパラメータの数が多くなるという問題がある。パラメータの決定は試行錯誤で決定するケースが多く、膨大な過去データや試行回数が必要であるため、実際に河川流量を表現するモデルを手動で構成することは困難である。このような背景より、最適化手法を用いたパラメータ探索手法が提案されている<sup>2, 3)</sup>。

本研究では、このタンクモデルのパラメータ決定に進化計算手法の一つである粒子群最適化法 (Particle Swarm Optimization: PSO)<sup>4)</sup>を採用する。過去の一定期間において計測された雨量と流量について、モデルパラメータを決めるための学習データとする。この学習データにより得られたパラメータを用いて雨量のみから流量の予測を行い、得られた予測値を実測データと比較して評価を行う。



Fig. 1: Nisou river (Nara, Fig. 2: Tsukise Water Plant (Nara, Japan))

## 2 河川流量に関する数理モデル

### 2.1 流量の測定方法

本研究では、河川流量に関する数理モデルを構築し、そのパラメータ設定を実流量および濁度の時系列データを学習データとして PSO により最適化を行う。まず、実際の流量の測定方法について説明する。実流量および濁度のデータは、二双川(奈良県奈良市, 図1 参照)から取水された原水から得られるものである。この河川に流れ込む流域として、河川周辺  $4\text{km}^2$  の領域を仮定した。また、月瀬浄水場(図2)は奈良県奈良市月ヶ瀬地区にある小規模な無人浄水場であり、取水した水を以下で説明する方法のより処理を行っている。

#### 1. 取水と凝集剤注入

河川から取水された水は着水井で水位や水量を調節して薬品飽和池に送られる。取水された水には砂や土などが含まれており、これらを凝集して沈殿させるために凝集剤(ポリ塩化アルミニウム, 以下 PAC とする)を濁度に応じた量で注入する。

#### 2. 沈殿処理

薬品飽和池で PAC を混ぜられた水はフロック形成池に送られる。フロックとは細かい砂や土などが PAC と混ざり固まってできる粒のことであり、これが形成されると沈殿池に水が送られる。沈殿池では形成されたフロックを沈殿させ、上澄み水がろ過地に送られる。

#### 3. ろ過

沈殿池で取り除ききれなかったフロックなどの汚れを砂や砂利を通してろ過する。

#### 4. 消毒と配水

ろ過された水は次亜塩素酸ソーダを注入して消毒し浄水池に貯められる。貯水池から各家庭に水道水が配水される。

モデルパラメータを設定するための学習用データ・テスト用データの取得方法について説明する。まず河川流量については、取水点付近の水位をデジタルカメラにより画像取得した上で水位点を計測し、そこから流量を推定することにより得られる。2019年2月1日から2019年4月20日まで、および、2019年5月17日から2019年6月23日までの期間において、月瀬浄水場のこの川における取水点の水位を5分おきに測定した。

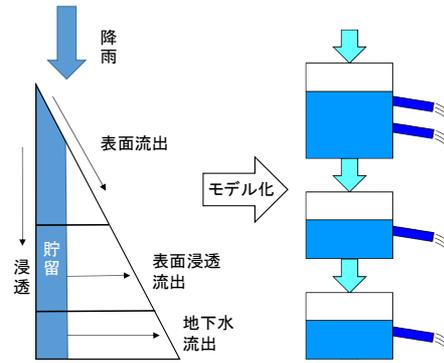


Fig. 3: Mathematical modeling of rainfall-runoff behaviors and their tank model

この水位から流量を算出し流量データとした。また、取水した水の濁り具合すなわち濁度については、取水の際の濁度を浄水場にある濁度計により測定したものを用了。学習用・テスト用のデータとして、対象領域における降雨量が必要となる。これについては、気象庁ナウキャスト(<https://www.jma.go.jp/bosai/nowc/>)にて表示される降雨状況の画像中の画素情報より各時刻での降雨量を決定した。

### 2.2 タンクモデルによる河川流出のモデル化

タンクモデルとは菅原によって提案された河川の流出解析のための数理モデルである<sup>1)</sup>。このモデルでは、側面に流出孔、底面に浸透孔を持つ貯留タンクをいくつか縦に直列に配置したような構造を持っており、河川周辺に降り注いだ雨水が、山岳表面や地下などの様々な経路を経て河川に流れ込むという挙動をモデル化している。このモデルでは、降雨が最上段のタンクから注入されると、一部は流出孔から外部に流出し、一部は浸透孔から一段下のタンクへと浸透する。各タンクは流域の帯水層に対応しており、各流出孔からの流出の合計を河川流量とする。

#### 2.2.1 直列3段タンクモデル

本研究で用いたタンクモデルは直列に3つのタンクを接続したものである。まず河川周辺のモデルとそのタンクモデルとの関係を図3に示す。このモデルでは、一段目のタンクにおける側面出力が山岳表面を流れる水が河川に流れ込むことに対応している(表面流出)。二段目のタンクは山岳を通して河川に流れ込む水に対応する(表面浸透流出)。さらに三段目のタンクは地下水が河川に流出していることに対応している。一段目では通常の降水のほか、局所的に大量の降水がある場合を表現できるように流出孔が二つ設けられている。

また、本研究で用いるタンクモデルについて、パラメータとその対応関係を表1と図4にそれぞれ示す。このタンクモデルにおける時間発展方法について説明する。まず、時刻  $t$  における流量を  $rf(t)$  とすると、 $rf(t)$  は以下の式で表される。

$$rf(t) = rf_{11}(t) + rf_{12}(t) + rf_2(t) + rf_3(t) \quad (1)$$

ここで、 $rf_n(t)$  は各流出孔からの流出量であり、それぞれ表1のパラメータを用いて以下の式により定義される。

$$rf_{11}(t) = a_{11}[S_1(t) - (L_{11} + L_{12})] \quad (2)$$

Table 1: Parameters in the tank model

パラメータ	パラメータ名
$R$	降水量
$S_n$	貯留高
$L_n$	流出孔の高さ
$a_n$	流出係数
$b_n$	浸透係数

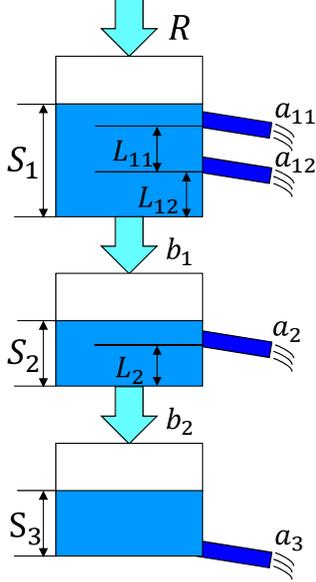


Fig. 4: The tank model with parameters used in this paper

$$rf_{12}(t) = a_{12}[S_1(t) - L_{12}] \quad (3)$$

$$rf_2(t) = a_2[S_2(t) - L_2] \quad (4)$$

$$rf_3(t) = a_3S_3(t) \quad (5)$$

ここで、 $S_n(t)$  は各タンクの水の貯留量であり、式 (2) ~ (5) および降水量  $R(t)$  を用いて以下の式により定義される。

$$S_1(t+1) = S_1(t) - b_1S_1(t) - rf_{11}(t) - rf_{12}(t) + R(t+1) \quad (6)$$

$$S_2(t+1) = S_2(t) - b_2S_2(t) - rf_2(t) + b_1S_1(t) \quad (7)$$

$$S_3(t+1) = S_3(t) - rf_3(t) + b_2S_2(t) \quad (8)$$

次に、本手法にて用いる河川流量と濁度の関係について説明する。濁度とは水の濁りの程度を表すものであり、視覚濁度、透過光濁度、散乱光濁度および積分球濁度に区分し表示される<sup>5)</sup>。本手法では、時刻  $t$  における濁度  $tb(t)$  は以下の式により定義する。

$$tb(t) = tb_{11}(t) + tb_{12}(t) + tb_2(t) + tb_3(t) \quad (9)$$

ここで、 $tb_n(t)$  は各流出孔からの流出濁度であり、表 2 に示すパラメータと式 (2) ~ (5) を用いて以下のように定義される。

$$tb_{11}(t) = c_{11}rf_{11}(t)^{d_{11}} \quad (10)$$

$$tb_{12}(t) = c_{12}rf_{12}(t)^{d_{12}} \quad (11)$$

$$tb_2(t) = c_2rf_2(t)^{d_2} \quad (12)$$

$$tb_3(t) = c_3rf_3(t)^{d_3} \quad (13)$$

Table 2: Parameters in turbidity estimation

パラメータ	パラメータ名
$c_{inc_n}$	降水量
$d_{inc_n}$	貯留高
$c_{dec_n}$	流出孔の高さ
$d_{dec_n}$	流出係数

Table 3: Search domain for parameters in tank model

パラメータ	最小値	最大値
$L_{11}$	$1.00 \times 10^{-11}$	$1.00 \times 10^{-1}$
$L_{12}, L_2$	0	$1.00 \times 10^{-1}$
$a_{11}, a_{12}, a_2, a_3$	$1.00 \times 10^{-11}$	1.00
$b_1, b_2$	$1.00 \times 10^{-11}$	$5.00 \times 10^{-1}$

さらに、本モデルでは水中での濁度物質の振る舞いを考慮したパラメータを導入する。現実には測定される濁度は、流量の上昇時にはそれに応じて上昇するが、流量が下降する時には緩やかな変化となる。そのため上述の式において濁度係数と濁度乗数について流量の上昇・下降で異なるパラメータを用いる。例えば、 $tb_{11}(t)$  については次式のように定義する。

$$tb_{11}(t) = \begin{cases} c_{11}^{inc} f_{11}(t)^{d_{11}^{inc}} \left( \frac{df_{11}(t)}{dt} \geq 0 \right) \\ c_{11}^{dec} f_{11}(t)^{d_{11}^{dec}} \left( \frac{df_{11}(t)}{dt} < 0 \right) \end{cases} \quad (14)$$

### 3 実験

#### 3.1 学習データを用いたパラメータ推定

まず、2 節において説明したタンクモデルについて、PSO によりパラメータ探索・推定を行った結果について説明する。学習データとして、2019 年 2 月 1 日から 2019 年 3 月 31 日までの期間のデータをパラメータ探索のための学習データとした。PSO における各粒子が持つタンクモデルパラメータによりタンクモデルを構成した後に、降雨量データをタンクモデルに入力し、タンクモデルからの流量出力を得る。この流量出力と実際の河川流量のデータとの間の絶対誤差を用いて各粒子を評価する。各粒子のパラメータ修正とモデル構成・評価を繰り返すことにより、パラメータ探索を行う。

実験での PSO の設定は、粒子数は 30、探索回数は 30 回とし、この PSO でのパラメータ探索を 100 回試行した。評価関数は学習データと予測データの絶対誤差であるが、流量が  $840\text{m}^3/\text{h}$  以上での絶対誤差については 10 倍の重みづけを行った。タンクモデルの条件として、タンクの初期貯留量  $S_n(0)$  は  $S_1(0) = 0$ 、 $S_2(0) = 100$ 、 $S_3(0) = 100$  とし、パラメータの探索範囲の下限値と上限値を表 3 に示す値にした。PSO によるパラメータ探索により得られた結果を表 4 および図 5 に示す。図 5 より、降雨量に合わせて流量を変化させることができていることがわかる。また、実測値の変化の傾向と同じ傾向を示しており、良好な結果を得られるパラメータが得られたと考えられる。

次に、出力された流量に式 (10) ~ (13) を適用して濁度を算出し、同じ期間の濁度データとの絶対誤差で評価を行うことにより濁度パラメータを算出した。この濁度パラメータについて探索する下限値と上限値を表 5 に示す値とした。この探索に用いる PSO の条件としては、粒子数は 30、探索回数は 30 回とし、PSO でのパラメータ探索を 100 回試行した。評価関数は学習デー

Table 4: Obtained parameters in tank model

パラメータ	値
$L_{11}$	$7.37 \times 10^{-4}$
$L_{12}$	0.00
$L_2$	$9.95 \times 10^{-2}$
$a_{11}$	$1.41 \times 10^{-3}$
$a_{12}$	$1.78 \times 10^{-2}$
$a_2$	$1.29 \times 10^{-4}$
$a_3$	$1.00 \times 10^{-11}$
$b_1$	$3.80 \times 10^{-1}$
$b_2$	$1.14 \times 10^{-4}$

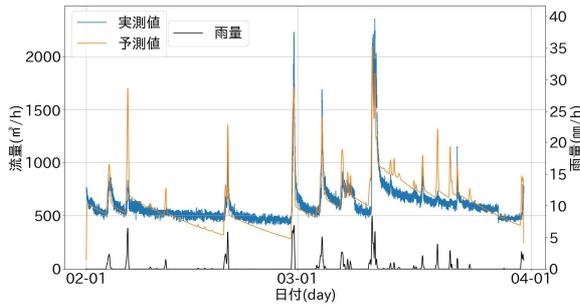


Fig. 5: 雨量変化に伴う実測流量とタンクモデルの出力流量の変化 (学習期間)

タと予測データの絶対誤差としているが、濁度が10以上となる場合には絶対誤差に2倍に重み付けを行った。得られたパラメータおよび濁度変化を表6および図5に示す。図6より、実測値と同じような変化の傾向を示しており、PSOによる探索により良好な結果が得られるパラメータを得ることができた。

### 3.2 テストデータを用いたパラメータ評価

次に前節において得られたタンクモデルのパラメータを用いて、学習期間ではない2019年4月1日から2019年6月30日までの期間にて流量と濁度を予測した結果について説明する。

降水量データを、求めたタンクモデルパラメータを適用したタンクモデルに入力し、流量を算出した結果を図7に示す。図7より、実測値と同じような値の傾向を示しており、良好な結果を得ることができたといえる。次に予測した流量をもとにして、探索して得られた濁度パラメータを用いて濁度を予測した結果を図8に示す。この結果より、濁度の変化の傾向は予測できているといえる。この評価期間においては、濁度が10を超えることは14回あり、そのうち6回は予測値の方が先に濁度10を超えていることが分かる。このとき、

Table 5: Search domain for turbidity parameters

パラメータ	最小値	最大値
$c_{inc11}, c_{inc12}, c_{inc2}, c_{inc3}$	$1.00 \times 10^{-2}$	$1.00 \times 10^5$
$d_{inc11}, d_{inc12}, d_{inc2}, d_{inc3}$	$1.00 \times 10^{-5}$	$1.00 \times 10^1$
$c_{dec11}, c_{dec12}, c_{dec2}, c_{dec3}$	$1.00 \times 10^{-2}$	$1.00 \times 10^5$
$d_{dec11}, d_{dec12}, d_{dec2}, d_{dec3}$	$1.00 \times 10^{-5}$	$1.00 \times 10^1$

Table 6: Obtained turbidity parameters

パラメータ	値
$c_{inc11}, c_{inc12}$	$1.00 \times 10^{-2}, 1.00 \times 10^{-2}$
$c_{inc2}, c_{inc3}$	$1.00 \times 10^{-2}, 2.24 \times 10^3$
$d_{inc11}, d_{inc12}$	$5.85 \times 10^{-1}, 1.73 \times 10^{-1}$
$d_{inc2}, d_{inc3}$	1.31, $3.76 \times 10^{-1}$
$c_{dec11}, c_{dec12}$	$1.00 \times 10^{-2}, 6.07 \times 10^3$
$c_{dec2}, c_{dec3}$	$3.57 \times 10^2, 1.78 \times 10^3$
$d_{dec11}, d_{dec12}$	$4.95 \times 10^{-1}, 1.32,$
$d_{dec2}, d_{dec3}$	1.26, $9.11 \times 10^{-1}$

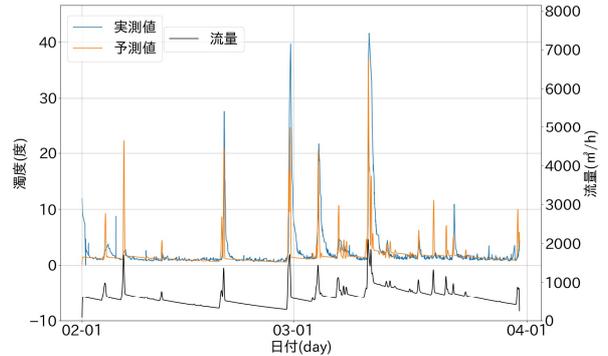


Fig. 6: 予測流量の変化に伴う予測濁度と実測濁度の変化 (学習期間)

平均して100.0分早く予測できていた。また、濁度が20を超えることは7回あり、そのうち2回は予測のほうが早く濁度20を超えている。平均して67.5分早く予測できていた。

得られた結果のまとめとして、学習データより実際の河川流量と同じような値の傾向を示すことができるタンクモデルのパラメータを求めることができた。濁度についても実測値と同じような傾向を示しており、高い評価を得られるパラメータを推定することができた。また、これらのパラメータを用いてテストデータで予測を行った結果、河川流量においては実測値と同じような傾向を示していた。しかし、大量の降雨や梅雨期の連続する降雨があるときの河川流量は予測できていなかった。これは、学習期間が短い(約2ヶ月)のためタンクモデルのパラメータが多量の降水に対応できるような値になっていないためと考えられる。濁度においても実測値と同じ傾向を示し、先行研究よりも高い精度で予測することができた。また、濁度が10を超える点において時間的に平均して100分前に予測できており、

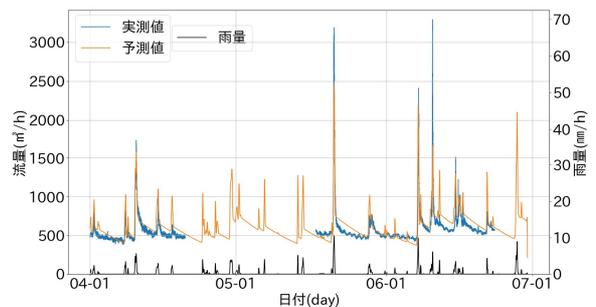


Fig. 7: 雨量変化に伴う実測流量とタンクモデルの出力流量の変化 (テスト期間)

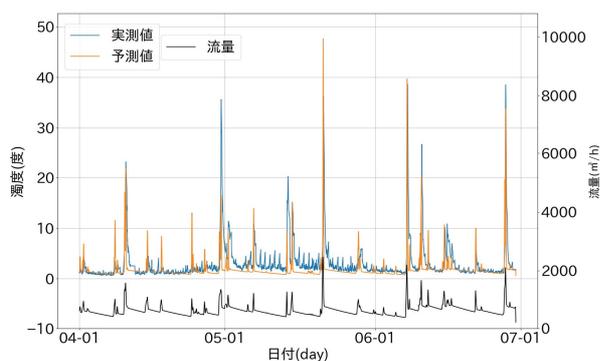


Fig. 8: 予測流量の変化に伴う予測濁度と実測濁度の変化 (テスト期間)

浄水場での対応決定に非常に有用であると考えられる。しかし、濁度が10を超えるときに予測精度は42.9%で20を超えるときに精度は28.6%であった。これは、式(10)～式(13)より、濁度の変化が流量の変化に伴って変化することしかできないためであると考えられる。

#### 4 まとめ

本論文では、水質自動制御システムを実現する第一歩として濁度予測システムの構築を行った。対象とする河川のモデル化を図るため直列3段タンクモデルのパラメータおよび河川流量から濁度を算出する際の濁度パラメータをPSOを用いて求めた。また、そのパラメータを用いて実際に降水量からの河川流量、そこから算出できる濁度を予測し、実測値と比較した。

パラメータの推定を行った結果、実際の河川流量および原水濁度実測値と同じような傾向を示すパラメータを推定することができた。推定したパラメータを用いてテストを行った結果、テストデータと同じ傾向の出力が得られた。また、実際の濁度よりも早く濁度の上昇を予測することができ、浄水場での運用において有用であることが分かった。今回の研究では、先行研究よりも精度の高い予測システムを構築することができた。

今後の課題として、タンクモデルではモデルの形状およびパラメータ探索範囲の検討や学習データの増加が考えられる。特に学習データは1年間分の用意ができれば各季節にも対応でき、より精度が高くなるのではないかと考えられる。濁度では濁度の算出法の再考が考えられる。また、両方の系において別のパラメータ探索アルゴリズムの使用を検討することも考えられる。

#### 参考文献

- 1) 菅原正巳: 流出解析法, 水文学講座 7, 共立出版 (1972)
- 2) 小林, 丸山: Powell の共役方向法によるタンクモデル定数の探索, 農業土木学会論文集, 65, 42/47 (1976)
- 3) 田中丸: タンクモデル定数の大域的探索, 農業土木学会論文集, 63(4), 103/112 (1976)
- 4) J. Kennedy and R. C. Eberhart: Particle swarm optimization, Proceedings of the IEEE International Conference on Neural Networks, 4, 1942/1948 (1995)
- 5) JIS 規格, JIS K 0101, <https://kikakurui.com/k0/K0101-2017-01.html>

# 複数の複雑性指標を用いたアルツハイマー病における脳波の判別

○安藤桃 信川創 (千葉工業大学) 菊知充 (金沢大学) 高橋哲也 (福井大学, 金沢大学, 魚津神経サナトリウム)

## Classification of Alzheimer's Disease by Combining Multiple Complexity Indexes

\*M. Ando and S. Nobukawa (Chiba Institute of Technology)

M. Kikuchi (Kanazawa University)

T. Takahashi (University of Fukui, Kanazawa University, Uozu Shinkei Sanatorium)

**Abstract**— In recent years it has been reported that early diagnosis of Alzheimer's disease (AD) and early intervention significantly delay the progression of the disease; hence establishment of early diagnosis and early intervention is emphasized. As a diagnostic index for AD patients the evaluation of the complexity of the dependence of the electroencephalography (EEG) signal on the temporal scale of AD patients is effective. In this study, we performed multiscale entropy analysis and multi-fractal analysis on the EEG of AD and healthy subjects. As a result, it was found that the classification accuracy of AD is improved by combining two complexity indexes.

**Key Words:** EEG signal, Alzheimer's disease, multifractal, multiscale entropy, early diagnosis

### 1 序論

Alzheimer's disease (AD) は認知症の最も一般的な形態であり、主に晩年に発症する進行性神経変性疾患である<sup>1)</sup>。AD は認知症の全症例の約 65% を占めている。世界保健機構によると、AD の世界的な有病率が 2019 年の 0.4% から 2030 年には 0.6% に増加し、2050 年までには 1.2% に増加すると予想されている<sup>2)</sup>。明確な治療法が見つからない AD ではあるが、近年では AD の早期診断と早期介入が病気の進行を大幅に遅らせることが報告されており、早期診断や早期介入の確立が重要視されている<sup>1)</sup>。AD では、進行性の神経細胞死、神経原繊維変化、広範囲にわたる脳領域の老人斑の 3 つの主な解剖学的変化が見られる<sup>3, 4)</sup>。AD 発症前の症状として軽度の認知障害 (MCI) が見られる<sup>5)</sup>。また、AD の診断後の平均余命は 3~9 年であり、多くの患者は病気の進行性の経過を伴って生きていく。このことから MCI 状態や初期の AD での診断が重要である。AD の診断としては、PET と MRI が多く使われており、神経伝達物質の活動障害とアミノイドベータプラークの沈着と脳萎縮を検出している<sup>6, 7, 8)</sup>。他には EEG や MEG, fMRI によって神経活動の時間的挙動に基づく研究が行われている<sup>9, 10, 11, 12, 13, 14, 15, 16)</sup>。

その中でも EEG は、費用対効果が高く、広く入手可能である。そして非侵襲的であるため、EEG は臨床応用において非常に有効である<sup>17, 18)</sup>。AD の病理学的進行は脳領域間の神経活動の低い同期および低い時間的複雑性をもたらす。特に複雑性の分析は広範囲の脳領域間の神経活動の相互作用の障害をもたらす AD の皮質切断を検出するための有益なアプローチである。AD 患者の EED 信号の複雑性を評価するために、決定論的カオスと相関次元やリアプノフ指数などのフラクタル次元に着目した研究が行われている<sup>19)</sup>。これらの研究によって AD 患者の神経活動の複雑性の低減が報告されている<sup>10, 20, 21, 22, 23, 24, 25)</sup>。また、EEG ダイナミクスは、記憶機能や認知機能、知覚機能などが theta 波や beta 波, gamma 波の各バンドの各時間スケールにおいて異なる役割を果たしている<sup>26)</sup>。このことか

ら AD 患者の脳波信号の時間スケールへの依存性の複雑性の評価は AD 患者の診断指標として効果的である<sup>27, 28, 16)</sup>。

複雑性の時間スケール依存性としてマルチスケールエントロピー (Multiscale entropy : MSE) 解析とマルチフラクタル (Multifractal : MF) 解析が挙げられる<sup>13, 14)</sup>。AD に対する EEG の時間スケール依存性に関して MSE 解析は、AD の前頭領域の小さな時間スケールでより低い複雑さも示し、より大きな時間スケールで AD の脳領域全体でより高い複雑さが観察された<sup>27, 29)</sup>。特に Zorick らは、MF 解析に基づく統計モデルは認知障害から AD への重症度と進行の程度の臨床段階を検出できると報告した<sup>2)</sup>。MSE 解析と MF 解析は、AD の脳波の複雑性の変化を検出することができるため AD のバイオマーカーになる可能性がある<sup>27, 29, 16)</sup>。

また、Cukic らは MSE 解析と MF 解析が健康な被験者において互いに補完的な情報を持っていると報告した<sup>30)</sup>。したがって、この補完的な関係は AD 識別の精度の向上に寄与する可能性がある。これに関連して、本研究では、MSE 解析と MF 解析を組み合わせると AD における脳波の変化を捉えることができる可能性があるという仮説を立てる。本研究では、AD と健康な被験者 (healthy control : HC) の脳波に対して MSE 解析と MF 解析を行った。

### 2 解析方法

#### 2.1 被験者

本研究の被験者は、18 名の健康な高齢者と 16 名の AD 患者である<sup>28, 16, 27)</sup>。健康な高齢者は、非喫煙者であり、投薬を行っていない。また、過去に癲癇または頭部外傷を含む医学的または神経学的状態を有する被験者やアルコールまたは薬物依存の経歴がある被験者は除外した。AD 患者は、中枢神経系に作用する投薬を受けていない。患者は NINCDS-ADRDA の基準を満たす probable AD であり DSM-IV 基準の一次性変性痴呆発症前の状態である。各患者は Function Assessment Stage (FAST) および Mini-Mental State Exami-

nation(MMSE)で評価した。患者3名が軽度 (FAST 3) であり患者7名が中程度 (FAST 4), 患者6名が軽度の認知症 (FAST 5)であった。MMSEスコアは10-26の範囲であり, 平均は15.56であった。被験者の詳細を表1に示す。すべての被験者は, 研究に対する説明の後, インフォームドコンセントを得ている。また, 本研究は金沢大学の倫理委員会によって承認され, ヘルシンキ宣言に従って実施した。

## 2.2 脳波計測

脳波データを記録及び前処理するための手法は研究で報告され確立されている<sup>27)</sup>。脳波を計測する際は, 被験者は防音の録音室に座り, 部屋の証明が制御された。脳波計測は, 国際10-20法という電極配置から16電極 (Fp1, Fp2, F3, F4, C3, C4, P3, P4, O1, O2, F7, F8, Fz, Pz, T5, T6)を用いた。両耳朶結合を参照結果として脳波活動を計測した。脳波測定には日本光電社のEEG-4518を用いり, 眼球運動は, 双極心電図 (EOG) を使用して観測した。サンプリング周波数200Hzと2.0-60Hzのバンドパスフィルターを使用して記録した。電極/皮膚コンダクタンスインピーダンスは, 各電極で5k $\Omega$ 未満に制御した。被験者の脳波信号は, 目を閉じた安静状態で10-15分間測定した。ビデオ監視システムを使用して, 参加者の覚醒を視覚的に検査し目を閉じて覚醒状態のエポックのみが測定されたことを確認した。また, 脳波信号およびEOGレコードの目視検査により, 目を閉じて覚醒状態で記録された脳波信号時系列セグメントが特定された。MSE解析とMF解析は, 連続する50秒 (10000データポイント)のエポックに対して実行した。

## 2.3 マルチフラクタル解析

マルチフラクタル解析では, 離散ウェーブレット変換の係数から導出されたウェーブレットリーダーが広く使用されている<sup>31, 32)</sup>。マルチフラクタル解析はHölder指数によって, データXの構造を特徴づけている部分構造のフラクタル次元をスペクトルによって表現する解析方法である。離散信号X(t)の離散Wavelet係数は(1)式で示される。

$$d_X(j, k) = \int_R X(t)2^j \psi_0(2^{-j}t - k)dt \quad (1)$$

$$(j = 1, 2, \dots, k = 1, 2, \dots)$$

ここで $\psi_0$ はコンパクトサポートなmother wavelet関数とする。1次元のwavelet leadersは(2)式で表される。

$$L_X(j, k) = \sup_{\lambda \in 3\lambda_{j,k}} |d_X(j, k)| \quad (2)$$

ここで,  $\lambda = \lambda_{j,k} = [k2^j, (k+1)2^j]$ はスケール $2^j$ による時間間隔を,  $3\lambda_{j,k-1} = \cup \lambda_{j,k} \cup \lambda_{j,k+1}$ は隣接時間を表す。特異値スペクトルは, wavelet leadersによって(3)式で示される<sup>31, 32)</sup>。

$$D(h) = \inf_{q \neq 0} (1 + qh - \zeta_L(q)) \quad (3)$$

ここで,  $h$ と $q$ はそれぞれHölder指数とwavelet leadersのモーメントを示す。スケーリング指数 $\zeta_L(q)$ と構造関数 $S_L(q, j)$ は(4)式と(5)式で示される。

$$\zeta_L(q) = \liminf_{j \rightarrow 0} \left( \frac{\log_2 S_L(q, j)}{j} \right) \quad (4)$$

$$S_L(q, j) = \frac{1}{n_j} \sum_{k=1}^{n_j} |L_X(j, k)|^q \quad (5)$$

ここで,  $n_j$ はスケール $2^j$ の場合のXのサンプル数を示す。本研究では,  $D(h)$ の評価のために, 滑らかさの指標として一次キュムラント $c_1$ を使用し, マルチフラクタル性の指標として二次キュムラント $c_2$ を使用した。本研究では, マルチフラクタル解析をWavelet Toolbox of MATLAB(<https://jp.mathworks.com/products/wavelet.html>)によって実施する。

## 2.4 マルチスケールエントロピー解析

脳波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は(1)式のように定義される。

$$h(r, m) = -\log \frac{C_{m+1}(r)}{C_m(r)} \quad (6)$$

$C_m(r)$ は $|x_i^m - x_j^m| < r (i \neq j, i, j = 1, 2, \dots)$ の確率を示す。 $x_i^m$ は $m$ 次元ベクトル $x_i^m = x_i, x_{i+1}, \dots, x_{i+m-1}$ を示す。MSE解析においては,  $x_1, x_2, \dots, x_N$ を(2)式で, 粗視化した時系列 $y_j$ に対して行う。

$$y_j^{(\tau)} = \frac{1}{\tau} \sum_{i=(j-1)\tau+1}^{j\tau} x_i \quad (1 \leq j \leq \frac{N}{\tau}) \quad (7)$$

ここで,  $\tau (\tau = 1, 2, \dots)$ は時間スケールを表す。

## 2.5 統計解析

$c_1$ と $c_2$ では, 健康な高齢者とADに有意差があるかを判断するためにrepeated measure ANOVA (ANOVA)を行った。被験者間要因として健康な高齢者とADのグループを使用し, 被験者内要因として16電極を使用した。そして事後 $t$ 検定を使用して, 健康な高齢者とADおよび電極ごとの相互作用の主効果を評価した。ここで,  $c_1$ と $c_2 (q < 0.05)$ での多重比較の $t$ 値にBenjaminiHochbergの誤検出率補正を適用している。

サンプルエントロピーでも健康な高齢者とADに有意差があるかを判断するためにANOVA解析を行った。被験者間要因として健康な高齢者とADのグループを使用し, 被験者内要因として16電極と時間スケールを使用した。そして事後 $t$ 検定を使用して, 健康な高齢者とADおよび電極と時間スケールごとの相互作用の主効果を評価した。

Receiver operating characteristic (ROC) カーブを使用してADの分類を行った。主成分分析は次元削減の前処理として使用し,  $c_1, c_2$ , サンプルエントロピーに基づくロジスティック回帰を使用した。ROCカーブ

Table 1: Physical characteristics of healthy control (HC) and subjects with Alzheimer’s disease (AD).

	HC participants	AD participants	$p$ values
Male/female	7/11	5/11	0.72
Age(year)	59.3 (5.3, 55-66)	57.5 (4.7, 43-64)	0.31
MMSE score	NA	15.5 (4.7, 10-26)	NA

は主成分を使用し HC と AD を分類する能力を評価するために使用した. 識別の精度は, ROC カーブの下の面積 (AUC) によって評価した. この時, AUC=1.0 は完璧な識別に対応し, AUC=0.5 はランダムな識別に対応している.

### 3 解析結果

#### 3.1 マルチフラクタル解析

本研究では, 健康な高齢者と AD に対してマルチフラクタル解析を行った. 健康な高齢者と AD の  $c_1$  と  $c_2$  の ANOVA 解析結果を Table 2 に示す. 結果から,  $c_1$  において高い主効果と Group $\times$ node との相互作用が見られた. 事後  $t$  検定では, F3, Fz, F4, C3, C4, P3, Pz, P4 の 8 か所において  $c_1$  の値が有意に高いという結果が見られた. 事後  $t$  検定の結果を Fig. 1 に示す.

#### 3.2 マルチスケールエントロピー解析

本研究では, 健康な高齢者と AD に対して MSE 解析を行った. 健康な高齢者と AD の  $c_1$  と  $c_2$  の ANOVA 解析結果を Table 3 に示す. 結果から, 主効果は見られなかったが Group $\times$ scale での相互作用が見られた. 事後  $t$  検定では, 時間スケール 1~5(0.005~0.025[s]) で AD のサンプルエントロピーが有意に低いという結果が見られた. 事後  $t$  検定の結果を Fig. 2 に示す.

#### 3.3 ROC カーブ

$c_1$  と  $c_2$  のとサンプルエントロピーの分類能力を評価するために ROC カーブを求めた. 第一主成分から第三主成分を使用して求めた ROC の結果を Fig. 3 に示す. サンプルエントロピーは, 時間スケール 1~5 の値を平均化している.  $c_1$  の AUC は 3 種類のデータの中で一番大きく AUC=0.85 であった. さらに, これらすべての値を使用した場合の AUC は 1.0 になり, 分類能力の向上が見られた.

### 4 考察

本研究では, マルチフラクタル解析とマルチスケールエントロピー解析間の補完的な関係に着目して分類能力を評価した. マルチフラクタル解析では脳波信号の滑らかさの指標である  $c_1$  が AD において増加したが,  $c_2$  では有意な変化は見られなかった. マルチスケールエントロピー解析では, AD が小さい時間スケールでサンプルエントロピーが減少した. 分類精度では  $c_1$  が一番高い分類精度を示し,  $c_1$ ,  $c_2$ , サンプルエントロピーの全てのデータを使用した場合には分類精度が向上した.

第一に AD の  $c_1$  が増加する理由を考える必要がある. AD における EEG/MEG では複雑性の現象が多く報告されている<sup>33, 10, 34, 20, 21, 22, 35, 24</sup>. それに対して, サンプルエントロピーも複雑性の低下を示した.  $c_1$  とサンプルエントロピーの間には負の相関があること

から  $c_1$  の増加は小さい時間スケールでの複雑性の低下によって引き起こされたと考えられる.

第二に AD において小さい時間スケールで複雑性の低下が見られる理由を考える必要がある. AD における

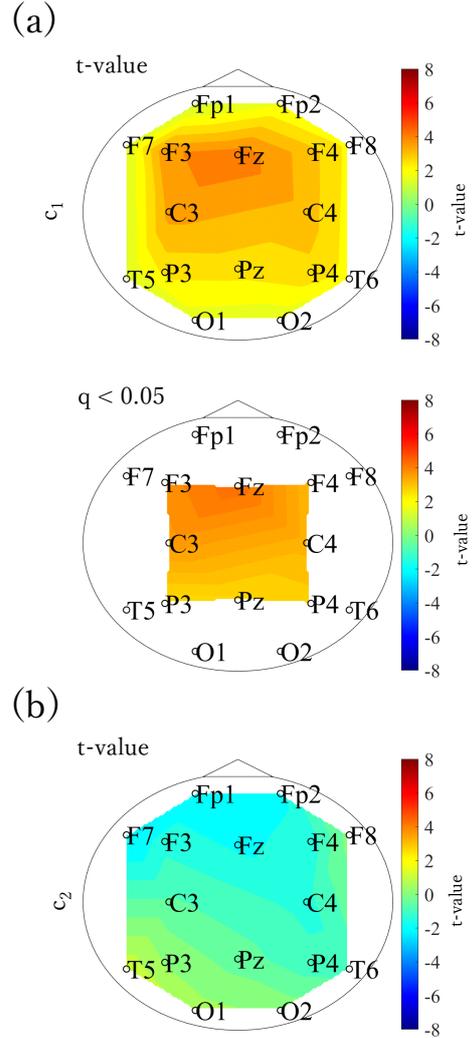


Fig. 1: (a)  $t$  values between the AD and HC groups. The warm (cold) color represents higher (smaller)  $c_1$  values of AD than those for HC. The left and right correspond to the  $t$ -value and  $t$ -value satisfying the false discovery rate (FDR) correction criteria  $q < 0.050$ .  $c_1$  of the AD group had significantly higher values at F3, Fz, F4, C3, C4, P3, Pz, and P4. (b)  $t$ -value between the AD and HC groups warm (cold) color represents higher (smaller)  $c_2$  values of AD than those for HC. There are no-significant high/low  $t$ -values satisfying FDR correction criteria  $q < 0.05$ .

Table 2: AD vs. HC repeated measure ANOVA analysis results ( $F$  value ( $p$  value)) in multifractal (MF) analysis results,  $F$  and  $p$  value with  $p < 0.05$  are represented by bold characters.

	Group	Group $\times$ node
$c_1$	<b><math>F = 9.088</math> (<math>p = 0.005</math>)</b>	$F = 1.460$ ( $p = 0.204$ )
$c_2$	$F = 0.654$ ( $p = 0.425$ )	$F = 1.981$ ( $p = 0.072$ )

Table 3: AD vs. HC repeated measure ANOVA results ( $F$  value ( $p$  value)) in multi scale entropy (MSE) analysis results,  $F$  and  $p$  value with  $p < 0.05$  are represented by bold characters.

Group	Group $\times$ node	Group $\times$ scale	Group $\times$ node $\times$ scale
$F = 1.233$ ( $p = 0.275$ )	$F = 1.860$ ( $p = 0.129$ )	<b><math>F = 11.457</math></b> ( <b><math>p = 0.003</math></b> )	$F = 0.979$ ( $p = 0.451$ )

神経伝達物質の変化, アミロイド  $\beta$  およびタウタンパク質の沈着によって引き起こされるガンマアミノ酪酸 (GABA) シグナル伝達システムの機能不全に関する研究が報告されている. これらの変化により, GABA シグナル伝達システム<sup>36, 37, 38</sup>) によって生成されるガンマバンド活動の振動が減少する. その結果, ガンマバンド活動の相互作用の機能不全は遅い時間スケールよりも速い時間スケールで複雑さを軽減する<sup>28, 39</sup>).

第三に  $c_1$ ,  $c_2$ , サンプルエントロピーの全てのデー

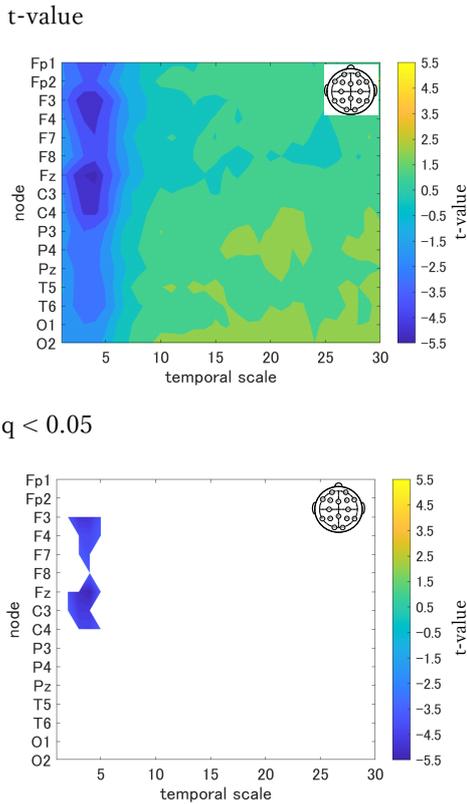


Fig. 2: Multi-scale entropy analysis in HC and AD group. The horizontal axis represents the temporal-scale factor,  $\tau$ .  $t$ value between the AD and HC groups(left part). The warm (cold) color represents a higher (smaller) sample entropy value for AD than that for HC. The  $t$ -value satisfying the FDR correction criteria  $q < 0.050$ . Significantly smaller sample entropy of AD low temporal scale regions 1 to 5 (0.005 to 0.025 s).

タを使用した時に分類精度が最も高くなる理由を考える必要がある. Cukie et al. らの研究によるとサンプルエントロピーとフラクタル次元は時間スケールで補完的な関係があることが報告されており<sup>30</sup>), この関係は複雑性の変化を検出する能力を向上させることができる. 従って本研究の結果はフラクタル次元に対応する  $c_1$  とサンプルエントロピーの補完的な関係によって AD の分類精度が向上する可能性が考えられる. また, AD におけるマルチフラクタル解析の研究ではマルチフラクタルの程度が複雑性の疾患特有の変化を反映していることが報告されている<sup>2)</sup>. 結果から  $c_2$  の分類精度は高くないが,  $c_2$  は分類精度の向上に寄与する可能性があると考えられる.

本研究の限界として, EEG 信号は電極直下の神経活動を常に反映しているとは言えない点と本研究では 16 個の電極を使用して脳波の測定を行ったが, 空間分解能が低いため AD の複雑な機能的接続構造を特定することが出来ない点が挙げられる. この問題は高い空間分解能を備えている MEG を使用することで解決できると考えられる.

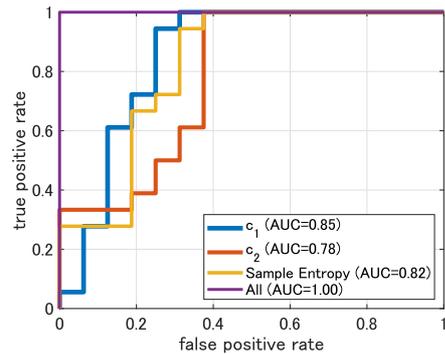


Fig. 3: Receiver operating characteristic curve (ROC) for  $c_1$ ,  $c_2$ , and sample entropy. The area under the ROC curve (AUC) is shown in the legend. As classifier, logistic regression is used. In this case,  $c_1$ ,  $c_2$ , and sample entropy, each 1st-3rd principal component was used separately. In the case represented by “ALL,” all 1st-3rd principal components component of  $c_1$ ,  $c_2$ , sample entropy were used. We evaluated ROC in the case using all these values; the results show the enhancement of classification ability (AUC = 1.00).

## 5 結論

本研究では、MSE 解析とマルチフラクタル解析を組み合わせると AD における脳波の変化を捉えることができる可能性があるという仮説を基に AD と健康な被験者の脳波に対して MSE 解析とマルチフラクタル解析を行った。結論として、MSE 解析とマルチフラクタル解析の両方で、AD の脳波の複雑性が減少した。MSE 解析の結果とマルチフラクタル解析の結果をそれぞれ使用するよりも 2 つのデータを組み合わせることで、分類精度が向上することがわかった。いくつかの制限が残っているが、本研究の結果は、MSE 解析とマルチフラクタル解析が AD の神経活動の変化を検出する上で補完的な役割を果たすことを示していると考えられる。MSE 解析とマルチフラクタル解析の両方を使用すると、AD の診断をサポートするツールの開発が容易になる可能性があると考えられる。

## 参考文献

- 1) Liu, Siqi and Liu, Sidong and Cai, Weidong and Pujol, Sonia and Kikinis, Ron and Feng, Dagan : Early diagnosis of Alzheimer's disease with deep learning, 2014 IEEE 11th international symposium on biomedical imaging (ISBI), 1015/1018 (2014)
- 2) Zorick, Todd and Landers, Jordan and Leuchter, Andrew and Mandelkern, Mark A : EEG multifractal analysis correlates with cognitive testing scores and clinical staging in mild cognitive impairment, Journal of Clinical Neuroscience, (2020)
- 3) Sims, Rebecca and Van Der Lee, Sven J and Naj, Adam C and Bellenguez, Céline and Badarinarayan, Nandini and Jakobsdottir, Johanna and Kunkle, Brian W and Boland, Anne and Raybould, Rachel and Bis, Joshua C and others : Rare coding variants in PLCG2, ABI3, and TREM2 implicate microglial-mediated innate immunity in Alzheimer's disease, Nature genetics, 49, 1373/1384 (2017)
- 4) Yamaguchi-Kabata, Yumi and Morihara, Takashi and Ohara, Tomoyuki and Ninomiya, Toshiharu and Takahashi, Atsushi and Akatsu, Hiroyasu and Hashizume, Yoshio and Hayashi, Noriyuki and Shigemizu, Daichi and Boroevich, Keith A and others : Integrated analysis of human genetic association study and mouse transcriptome suggests LBH and SHF genes as novel susceptible genes for amyloid- $\beta$  accumulation in Alzheimer's disease, Human genetics, 137, 521/533 (2018)
- 5) Gauthier Serge and Reisberg Barry and Zaudig Michael and Petersen Ronald C and Ritchie Karen and Broich Karl and Belleville Sylvie and Brodaty Henry and Bennett David and Chertkow Howard and others : Mild cognitive impairment, The lancet, 367, 1262/1270 (2006)
- 6) McKhann Guy M and Knopman David S and Chertkow Howard and Hyman Bradley T and Jack Jr Clifford R and Kawas Claudia H and Klunk William E and Koroshetz Walter J and Manly Jennifer J and Mayeux Richard and others : The diagnosis of dementia due to Alzheimer's disease: recommendations from the National Institute on Aging-Alzheimer's Association workgroups on diagnostic guidelines for Alzheimer's disease, Alzheimer's & dementia, 7-3, 263/269 (2011)
- 7) Sperling Reisa A and Aisen Paul S and Beckett Laurel A and Bennett David A and Craft Suzanne and Fagan Anne M and Iwatsubo Takeshi and Jack Jr Clifford R and Kaye Jeffrey and Montine Thomas J and others : Toward defining the preclinical stages of Alzheimer's disease: Recommendations from the National Institute on Aging-Alzheimer's Association workgroups on diagnostic guidelines for Alzheimer's disease, Alzheimer's & dementia, 7-3, 280/292 (2011)
- 8) Ewers Michael and Sperling Reisa A and Klunk William E and Weiner Michael W and Hampel Harald : Neuroimaging markers for the prediction and early diagnosis of Alzheimer's disease dementia, Trends in neurosciences, 34-8, 430/442 (2011)
- 9) Greicius Michael D and Srivastava Gaurav and Reiss Allan L and Menon Vinod : Default-mode network activity distinguishes Alzheimer's disease from healthy aging: evidence from functional MRI, Proceedings of the National Academy of Sciences, 101-13, 4637/4642 (2004)
- 10) Jeong Jaeseung : EEG dynamics in patients with Alzheimer's disease, Clinical neurophysiology, 115-7, 1490/1505 (2004)
- 11) Stam Cornelis J : Nonlinear dynamical analysis of EEG and MEG: review of an emerging field, Clinical neurophysiology, 116-10, 2266/2301 (2005)
- 12) Dickerson Bradford C and Sperling Reisa A : Functional abnormalities of the medial temporal lobe memory system in mild cognitive impairment and Alzheimer's disease: insights from functional MRI studies, Neuropsychologia, 46-6, 1624/1635 (2008)
- 13) Yang Albert C and Tsai Shih-Jen : Is mental illness complex? From behavior to brain, Progress in Neuro-Psychopharmacology and Biological Psychiatry, 45, 253/257 (2013)
- 14) Takahashi Tetsuya : Complexity of spontaneous brain activity in mental disorders, Progress in Neuro-Psychopharmacology and Biological Psychiatry, 45, 258/266 (2013)
- 15) Wang Bin and Niu Yan and Miao Liwen and Cao Rui and Yan Pengfei and Guo Hao and Li Dandan and Guo Yuxiang and Yan Tianyi and Wu Jinglong and others : Decreased complexity in Alzheimer's disease: resting-state fMRI evidence of brain entropy mapping, Frontiers in aging neuroscience, 9, 378 (2017)
- 16) Nobukawa Sou and Yamanishi Teruya and Kasakawa Shinya and Nishimura Haruhiko and Kikuchi Mitsuru and Takahashi Tetsuya : Classification Methods Based on Complexity and Synchronization of Electroencephalography Signals in Alzheimer's Disease, Frontiers in Psychiatry, 11, (2020)
- 17) Vecchio Fabrizio and Babiloni Claudio and Lizio Roberta and Fallani Fabrizio De Vico and Blinowska Katarzyna and Verrienti Giulio and Frisoni Giovanni and Rossini Paolo M : Resting state cortical EEG rhythms in Alzheimer's disease: toward EEG markers for clinical applications: a review, Supplements to Clinical neurophysiology, 62, 223/236 (2013)
- 18) Kulkarni Nilesh and Bairagi Vinayak : EEG-based diagnosis of alzheimer disease: a review and novel approaches for feature extraction and classification techniques, (2018)
- 19) Kantz Holger and Schreiber Thomas : Nonlinear time series analysis, 7, (2004)
- 20) Woyshville Mark J and Calabrese Joseph R : Quantification of occipital EEG changes in Alzheimer's disease utilizing a new metric: the fractal dimension, Biological psychiatry, 35-6, 381/387 (1994)
- 21) Besthorn C and Sattel H and Geiger-Kabisch C and Zeffass R and Förstl H : Parameters of EEG dimensional complexity in Alzheimer's disease, Electroencephalography and clinical neurophysiology, 95-2, 84/89 (1995)
- 22) Jelles B and Van Birgelen JH and Slaets JPJ and Hekster REM and Jonkman EJ and Stam CJ : Decrease of non-linear structure in the EEG of Alzheimer patients compared to healthy controls, Clinical Neurophysiology, 110-7, 1159/1167 (1999)
- 23) Bluth Charles and Bluth James : Health care information system, (2004)

- 24) Smits Fenne Margreeth and Porcaro Camillo and Cottone Carlo and Cancelli Andrea and Rossini Paolo Maria and Tecchio Franca : Electroencephalographic fractal dimension in healthy ageing and Alzheimer ' s disease, *PloS one*, **11-2**, e0149587 (2016)
- 25) Al-nuaimi Ali H and Jammeh Emmanuel and Sun Lingfen and Ifeakor Emmanuel : Higuchi fractal dimension of the electroencephalogram as a biomarker for early detection of Alzheimer ' s disease, 2017 39th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), 2320/2324 (2017)
- 26) Klimesch Wolfgang and Sauseng Paul and Hanslmayr Simon and Gruber Walter and Freunberger Roman : Event-related phase reorganization may explain evoked neural dynamics, *Neuroscience & Biobehavioral Reviews*, **31-7**, 1003/1016 (2007)
- 27) Mizuno Tomoyuki and Takahashi Tetsuya and Cho Raymond Y and Kikuchi Mitsuru and Murata Tetsuhito and Takahashi Koichi and Wada Yuji : Assessment of EEG dynamical complexity in Alzheimer ' s disease using multiscale entropy, *Clinical Neurophysiology*, **121-9**, 1438/1446 (2010)
- 28) Nobukawa Sou and Yamanishi Teruya and Nishimura Haruhiko and Wada Yuji and Kikuchi Mitsuru and Takahashi Tetsuya : Atypical temporal-scale-specific fractal changes in Alzheimer ' s disease EEG and their relevance to cognitive decline, *Cognitive neurodynamics*, **13-1**, 1/11 (2019)
- 29) Ni, Huangjing and Zhou, Luping and Ning, Xinbao and Wang, Lei and Alzheimer ' s Disease Neuroimaging Initiative (ADNI) : Exploring multifractal-based features for mild Alzheimer ' s disease classification, *Magnetic resonance in medicine*, **76-1**, 259/269 (2016)
- 30) Cukic, Milena B and Platisa, Mirjana M and Kalauzi, Aleksandar and Oommen, Joji and Ljubisavljevic, Milos R : The comparison of Higuchi fractal dimension and Sample Entropy analysis of sEMG: effects of muscle contraction intensity and TMS, *arXiv preprint arXiv:1803.10753*, (2018)
- 31) Wendt Herwig and Abry Patrice : Multifractality tests using bootstrapped wavelet leaders, *IEEE Transactions on Signal Processing*, **55-10**, 4811/4820 (2007)
- 32) Jaffard, Stéphane and Lashermes, Bruno and Abry, Patrice : Wavelet leaders in multifractal analysis, *Wavelet analysis and applications*, 201/246 (2006)
- 33) Smailovic, Una and Koenig, Thomas and Laukka, Erika J and Kalpouzos, Grégoria and Andersson, Thomas and Winblad, Bengt and Jelic, Vesna : EEG time signature in Alzheimer ' s disease: Functional brain networks falling apart, *NeuroImage: Clinical*, **24**, 102046 (2019)
- 34) Kulkarni, Nilesh : Use of complexity based features in diagnosis of mild Alzheimer disease using EEG signals, *International Journal of Information Technology*, **10-1**, 59/64 (2018)
- 35) Wickramasinghe, Nilmini and Geisler, Eliezer : *Encyclopedia of healthcare information systems*, (2008)
- 36) Nava-Mesa, Mauricio O and Jiménez-Díaz, Lydia and Yajeya, Javier and Navarro-Lopez, Juan D : GABAergic neurotransmission and new strategies of neuro modulation to compensate synaptic dysfunction in early stages of Alzheimer ' s disease, *Frontiers in cellular neuroscience*, **8**, 167 (2014)
- 37) Govindpani, Karan and Calvo-Flores Guzmán, Beatriz and Vinnakota, Chitra and Waldvogel, Henry J and Faull, Richard L and Kwakowsky, Andrea : Towards a better understanding of GABAergic remodeling in Alzheimer ' s disease, *International journal of molecular sciences*, **18-8**, 1813 (2017)
- 38) Calvo-Flores Guzmán, Beatriz and Vinnakota, Chitra and Govindpani, Karan and Waldvogel, Henry J and Faull, Richard LM and Kwakowsky, Andrea : The GABAergic system as a therapeutic target for Alzheimer ' s disease, *Journal of neurochemistry*, **146-6**, 649/669 (2018)
- 39) Ahmadelou, Mehran and Adeli, Hojjat and Adeli, Anahita : Fractality and a wavelet-chaos-methodology for EEG-based diagnosis of Alzheimer disease, *Alzheimer Disease & Associated Disorders*, **25-1**, 85/92 (2011)

# 注意選択を再現する深層ニューラルネットワークモデルの情報表現

○我妻伸彦 渡邊将以 増本真子 (東邦大学)

日高章理 (東京電機大学) 田村弘 (大阪大学、CiNet)

## Analyses based on Neuronal Representations of Natural Images for Understanding the Mechanisms of DCNN Saliency Map Model

\* N. Wagatsuma, S. Watanabe, M. Masumoto (Toho University)

A. Hidaka (Tokyo Denki University) and H. Tamura (Osaka University, CiNet)

**Abstract**— Recent saliency map models based on deep convolutional neural networks (DCNNs) realize the greater performance for predicting the location of attentional selection and human gaze compared to that based on biologically plausible mechanisms. Interestingly, selection of the activation function for developing the DCNN model is a critical factor for determining the characteristics of the responses in model neurons as well as the performance of the trained model. In this study, to understand activation-function-dependent mechanism for attentional selection, we investigated the correspondence between layers of a DCNN saliency map model trained by using the Swish function and monkey visual cortices for natural image representations. Our results suggested that intermediate and higher-intermediate level layers of the DCNN saliency map model based on the Swish activation function have similar characteristics regarding the responses to the neural representation in V1.

**Key Words:** Attention, Deep convolutional neural network, Saliency map, Swish activation function

### 1 はじめに

外界から投射される膨大な視覚情報は、網膜から大脳視覚皮質へと送られる。その時、我々の視覚系は、視野内に投影された全ての情報を均等に処理しているわけではない。その瞬間に、最も注目すべき物体・空間を選択し、それを重点的に処理する。これが注意選択である<sup>1)</sup>。注意選択は、情報を取捨選択し、実環境に適応するために獲得された生物の知覚戦略である<sup>2)</sup>。処理すべき情報を決定する注意選択の大脳視覚皮質メカニズムを理解するために、計算論的モデル構築とそのシミュレーション研究が盛んに行われている。注意選択の代表的なモデルとして、Ittiらにより提案された saliency map (顕著性マップ)モデルが知られている<sup>3)</sup>。Ittiらの saliency map は、主に生体の初期視覚野の情報処理系に基づくモデルであり、ヒトの注意選択特性を良く説明する。

従来の saliency map モデルは、大脳生理学的・心理物理学的知見に基づくネットワーク構造を作り込むことで、注意選択領域を再現した<sup>4)5)</sup>。最近では、深層畳み込みニューラルネットワーク (Deep Convolutional Neural Network, DCNN)を用いて、ヒト注意選択領域と視線位置を予測する saliency map モデルを機械学習的に獲得する研究が盛んに行われている。Panらが提案した DCNN saliency map モデル<sup>6)</sup>は、極めて高い精度でヒト視線位置を予測した。

DCNNが獲得した人工的なネットワーク構造を神経回路モデルとして利用することで、ヒト大脳視覚情報処理メカニズムの理解を試みる研究も進められている<sup>7)8)</sup>。近年、学習された DCNN saliency map モデル<sup>6)</sup>の情報処理特性が、大脳初期視覚野 V1 の応答特性に類似していることが報告された<sup>9)</sup>。これは、ヒトの注意選択領域決定において、大脳初期視覚系の情報処理が重要な役割を果たす皮質メカニズムの存在を示唆している。また、DCNNを構築する活性化関数は、学習に

より獲得されるモデルの性能決定に大きく寄与する<sup>10)</sup>。しかし、活性化関数が、獲得されるモデル構造に対して、どのような変化を引き起こすかは明らかになっていない。

本研究では、活性化関数 Swish<sup>10)</sup>を適用した DCNN が学習により獲得した saliency map モデルの応答特性とサル大脳視覚皮質の活動を比較した。具体的には、自然物体表面画像に対するサル大脳視覚野 V1、V4、IT の応答表現<sup>11)</sup>と DCNN saliency map モデルを構成する各階層が示す情報表現の類似度を定量的に評価した。解析結果から、活性化関数 Swish を用いた DCNN saliency map モデルの中高次階層が、大脳初期視覚野 V1 と類似する応答特性を獲得していることが示唆された。また、このような応答特性は、標準的な活性化関数である Rectified Linear Unit (ReLU)を用いた DCNN saliency map が示した応答特性とは異なる傾向であることが確認された。これらの結果から、DCNNが獲得するモデル構造の決定において、活性化関数の性質が重要な役割を果たす可能性が示された。

### 2 方法

#### 2.1 Swish 活性化関数を適用した DCNN-based saliency map モデル

本研究で用いたヒトの注意選択特性を獲得する DCNNの構造をFig. 1(A)に示す。これは、Panらにより提案されたSalNet<sup>6)</sup>のネットワーク構造に対して、畳み込み層の後に用いられる活性化関数として、Swish関数<sup>10)</sup>を適用したモデルである。活性化関数Swishは以下の式で与えられる。

$$f(x) = x / (1 + \exp(-\beta x))$$

ここで、 $\beta$ は、学習により最適化される変数である。 $\beta = 1.0$ のSwish関数をFig. 1(B)に示す。また、構築した

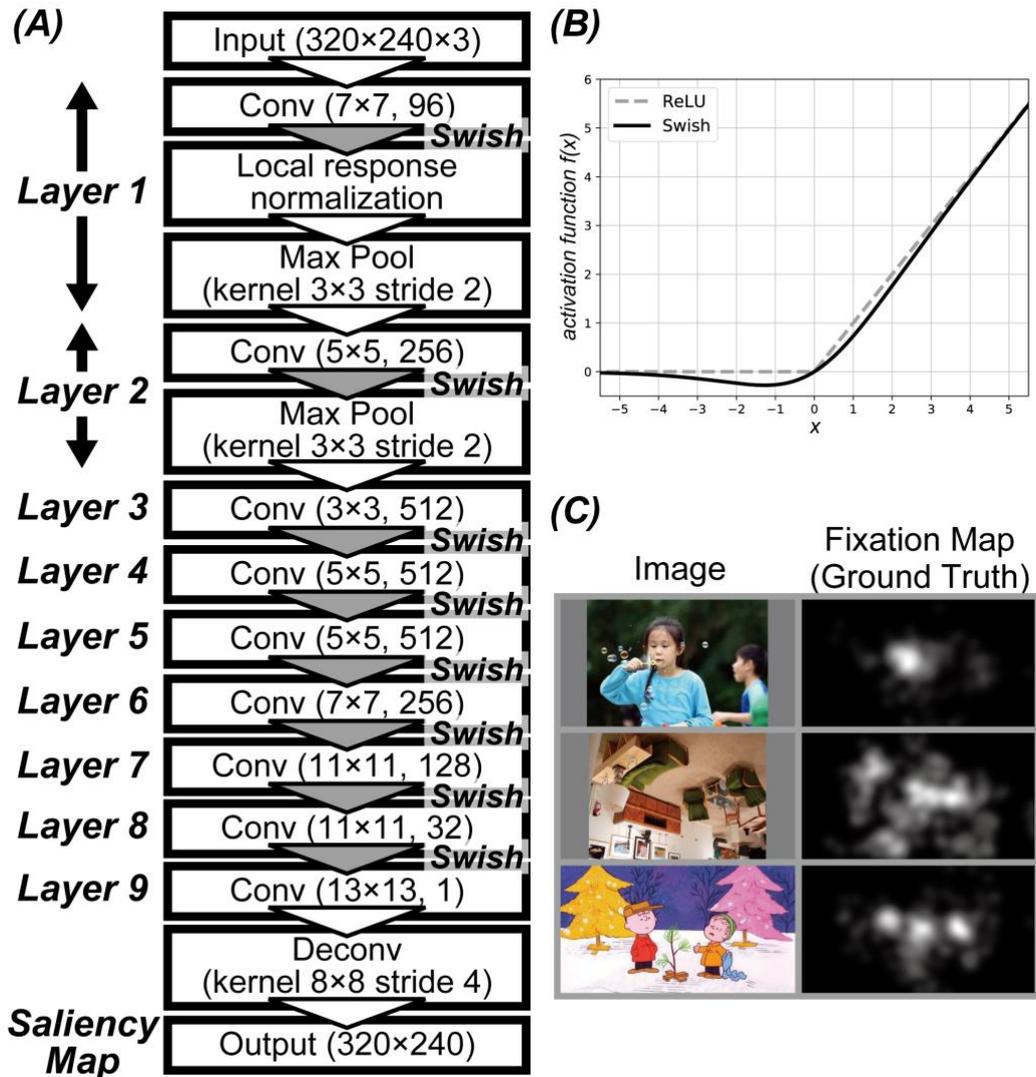


Fig. 1: 活性化関数 Swish<sup>10)</sup>を用いた DCNN saliency map モデル。(A)解析した DCNN saliency map モデルの構造。本研究では、Pan らが提案する DCNN saliency map モデル<sup>6)</sup>に対して、活性化関数 Swish を適用した。(B) 活性化関数 Swish<sup>10)</sup>と活性化関数 ReLU。実線が Swish、破線が ReLU を示す。2つの活性化関数はよく似た応答を示すが、 $x=0$  近傍における応答が異なる。(C) 注意選択位置予測を実現するための学習データ。左の Image に対するヒト被験者の視線位置が右図の Fixation Map(固視特性画像)に示されている。右図の白い領域は、ヒトがよく注視した空間位置を意味する。

DCNNにおいて、プーリングは最大値プーリング、出力層はDeconvolution関数がいられる。

ネットワークは、入力として自然画像を与えられる。入力画像から、ヒトの視線位置と注意選択領域を予測する saliency map が計算される。ネットワークを学習させるため、自然画像に対するヒトの固視特性画像を Ground Truth として用いた。誤差関数として平均 2 乗誤差を使用した。ネットワークは、Adam<sup>12)</sup>を用いた最適化により、学習された。

DCNN saliency map モデルにヒトの注意選択特性を獲得させるため、自然画像に対するヒトの固視特性画像を学習データとして適用した。固視特性画像は、視線追跡装置を用いて計測されたデータに基づき、生成される。本研究では、CAT2000<sup>13)</sup>、MIT Dataset<sup>14)</sup>、FIGRIM Fixation Dataset<sup>15)</sup>などの視線追跡データセッ

ト、合計約5700枚を用いて、ネットワークを学習させた。用いた学習データの例をFig. 1(C)に示す。学習後のネットワークに自然画像を入力として与えることで、ヒトの注意選択位置を予測する saliency map が算出される。

## 2.2 画像間非類似度行列

Tamuraらは、ニホンザル(*Macaca fuscata*)に8カテゴリ(石、樹皮、葉、花、果物、蝶翅、羽毛、皮)64枚からなる自然物体表面画像(Fig. 2)を呈示し、初期視覚野(V1)、中次視覚野(V4)、高次視覚野(IT)の神経活動電位を記録した<sup>11)</sup>。この実験で計測された刺激呈示期間中の平均発火率を、DCNN saliency map モデルの解析に用いた<sup>9)</sup>。

サルの神経細胞集団及び、DCNN saliency map を構成

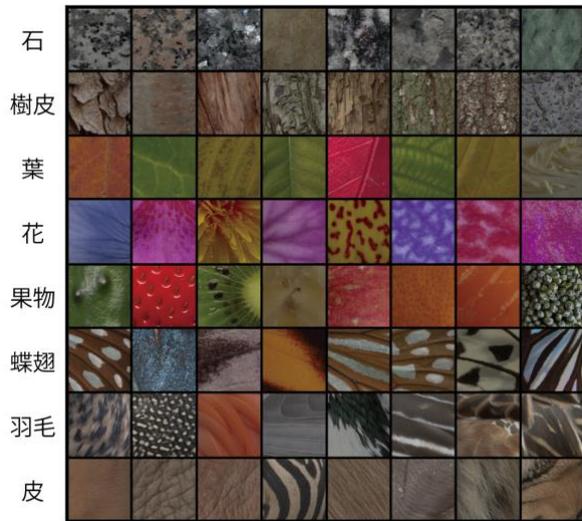


Fig. 2:サルを用いた電気生理実験<sup>11)</sup>と本論文の解析に用いた自然物物体画像。

する階層のモデル細胞集団による画像情報表現の類似性を定量的に検討するため、全画像ペア(2016ペア)間の画像間非類似度行列を算出した<sup>16)</sup>。詳細な画像間非類似度の算出方法は、先行研究<sup>9)</sup>に記載されている。画像間非類似度が小さいほど、その画像ペアに対して類似した表現が行われていると考えられる。また、神経細胞集団とDCNNモデル細胞集団が示す情報表現が類似している場合、互いに類似した画像間非類似度行列が得られると予測できる。サル大脳視覚皮質V1、V4、ITの神経細胞集団のそれぞれの応答に基づき、画像間非類似度行列を算出した。サル視覚皮質の神経活動に基づく画像間非類似度行列は、先行研究<sup>9)</sup>に示されている<sup>9)</sup>。さらに、DCNN saliency mapモデルを構成する全階

層に対して、モデル細胞集団の出力に基づく画像間非類似度行列を算出した。

### 3 結果

#### 2.1 獲得された DCNN モデルが算出する saliency map

活性化関数 Swish (Fig 1.(B))を用いたネットワーク (Fig 1.(A))へと学習データを適用し、入力画像から saliency map を算出する DCNN モデルを獲得した。はじめに、学習された DCNN モデルが算出した saliency map を Fig. 3 に示す。定性的に評価するため、モデルに Toronto dataset<sup>17)</sup>を適用した。用いた活性化関数に関わらず、DCNN モデルが出力した saliency map は、固視特性画像と類似する応答傾向を示した。また、本研究で構築した Swish 活性化関数を用いた DCNN モデルが出力した saliency map は、強い応答領域の近傍に、非常に弱い応答領域を出現させることがあった。これは、ReLU 活性化関数を用いて学習された DCNN モデルが算出した saliency map では確認されなかった傾向である。この結果は、DCNN に適用する活性化関数の性質により、獲得されるモデル構造が変化するという可能性を示唆している。

#### 2.2 Swish 活性化関数を用いた DCNN saliency map モデルとサル大脳視覚野の対応

Swish 活性化関数を用いたネットワークを学習させ、入力画像から saliency map を出力する DCNN モデルを作成した。学習された DCNN モデルへと自然物物体画像 (Fig. 2)を適用したシミュレーションを実行し、ネットワークを構成するモデル細胞の応答を抽出した。この抽出されたモデル細胞応答に基づき、DCNN の全階層における画像間非類似度行列を計算した。算出された画像間非類似度行列の例を Fig. 4 に示す。ReLU 活性化関数を用いた DCNN モデルから計算された画像

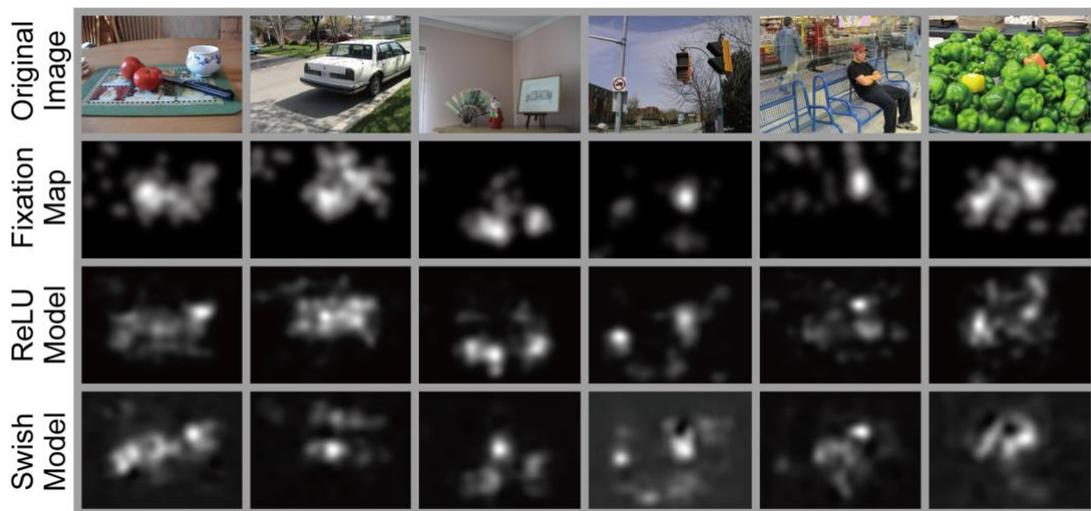


Fig. 3: 学習された DCNN モデルが算出した saliency map。上の行から順番に、入力画像<sup>17)</sup>、ヒト被験者の固視特性画像(Ground-Truth)<sup>17)</sup>、ReLU 活性化関数を用いた DCNN モデルの saliency map、Swish 活性化関数を用いた DCNN モデルの saliency map を示す。注意選択される領域は、白で示されている。学習された DCNN モデルは、ヒトの固視特性画像と類似した saliency map を生成した。一方、Swish 活性化関数を適用した DCNN モデルが算出する saliency map は、強い応答を示す空間領域(白)の近傍に、非常に弱い応答領域を出現させることがあった。

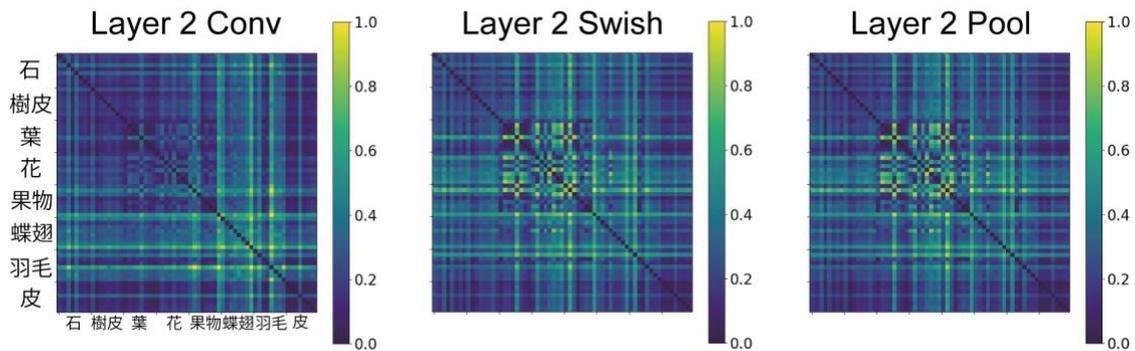


Fig. 4: Swish 活性化関数を用いた DCNN saliency map モデルの第 2 層を構成するモデル細胞から計算された画像間非類似度行列。行列内の各ピクセルは、Fig. 2 で示した 2 枚の自然物物体表面画像に対する応答の近さを表現する。0 のピクセル値(黒)は、2 枚の画像に対するモデル細胞の応答が同一であることを意味する。

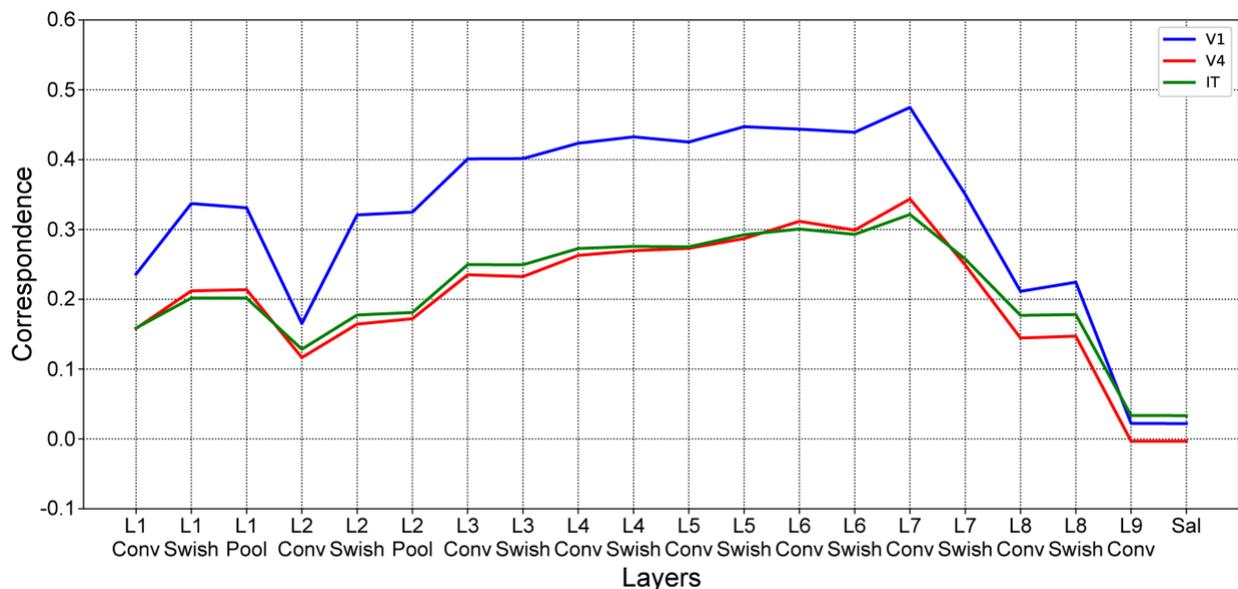


Fig. 5: サル視覚野神経活動と Swish 活性化関数を用いた DCNN saliency map モデルの相関値。横軸に DCNN モデルの階層、縦軸に神経活動とモデルニューロンの相関を示す。青線が V1 と DCNN saliency map モデル階層との相関を意味する。DCNN モデルと V4 間の相関を赤線、DCNN モデルと IT 間の相関を緑線でそれぞれ表現した。

間非類似度行列(参考文献<sup>9</sup>参照)と比較して、行列のピクセル値が全体的に低くなる傾向が確認された。これは、Swish を用いた DCNN saliency map モデルのモデル細胞の応答が、2 枚の入力画像間で類似していることを意味する。これより、DCNN が学習により獲得するモデル構造が、適用する活性化関数の性質により決定されるという可能性が定性的に示された。

サル視覚野神経活動に基づく画像間非類似度行列(参考文献<sup>9</sup>参照)と Swish を用いた DCNN saliency map モデルを構成する階層の出力に基づく画像間非類似度(例 Fig. 4)の相関値を Fig. 5 に示す。Fig. 5 の青線は V1 と DCNN saliency map モデルの各階層間の相関を示す。同様に、DCNN モデルと V4 間の相関を赤線、DCNN モデルと IT 間の相関を緑線で、それぞれ表現した。DCNN モデルの階層レベルに関わらず、V1 の神経活動に基づく画像間非類似度行列が DCNN saliency map モデルに対して、他視覚野よりも高い相関値を示した。

一方、V4 と IT の画像間非類似度行列に基づき算出された相関値は、同程度の大きさを示した。また、視覚野のレベルにかかわらず、DCNN の第 2 層から第 7 層まで、階層のレベルが上がるに伴い、神経活動と DCNN モデル応答の間の相関が上昇した

#### 4 考察

Swish 活性化関数を用いた DCNN saliency map モデルの第 1 層から第 8 層を構成するモデル細胞の応答に基づく画像間非類似度行列は、V4・IT 野よりも、初期視覚野 V1 の神経活動に基づく画像間非類似度行列と高い相関値を示した。これは、ReLU 活性化関数を用いた DCNN saliency map モデルと同様の傾向<sup>9</sup>であり、DCNN saliency map モデルの低次層-中高次層の情報処理が、低次視覚野(V1 野)の情報表現と対応する可能性を示唆する。

ReLU 活性化関数を用いた DCNN saliency map モデ

ルは、初期階層(第1層と第2層)や中高次階層(第6層と第7層)がV1の神経活動と特に高い相関を示した<sup>9)</sup>。一方、本研究のSwishを用いたDCNN saliency mapモデルの場合、DCNN初期階層とV1間の相関値は比較的小さい。さらに、第7層までDCNNの階層レベルが上昇するとともに、その相関値が上昇した。これは、活性化関数の性質により、DCNN saliencyモデルの階層と脳視覚野間の対応が変化することを示している。これらの結果は、DCNNに適用する活性化関数が、学習により獲得されるモデル構造の決定に重要な役割を果たす可能性を示唆する。

## 5 終わりに

Swish 活性化関数を用いた DCNN saliency map モデルのネットワーク応答とサル大脳視覚皮質活動の定量的な比較から、生体の注意選択決定において、中高次視覚野の活動よりも、初期視覚野 V1 の応答が重要な役割を果たす皮質メカニズムが示唆された。また、ネットワークの階層間を連絡する活性化関数の性質が、DCNNが獲得するモデル構造の決定に大きく寄与する可能性が示された。

## 6 謝辞

本研究は、科研費(19K12737)の助成を受けた。

## 参考文献

- 1) Posner, M. I. : Orienting of attention, *The Quarterly Journal of Experimental Psychology*, Vol. 32, 3/25 (1980)
- 2) 我妻伸彦 : 視覚皮質の層構造局所回路モデル-大規模シミュレーションが予測した視覚情報処理メカニズム-, *日本神経回路学会誌*, Vol. 22, 112/124 (2015)
- 3) Itti, L. & Koch, C. : A saliency-based search mechanism for overt and covert shift of visual attention, *Vision Research*, Vol. 40, 1489/1506 (2000)
- 4) Russell, A. F., Mihalas, S., von der Heydt, R., Niebur, E., & Etienne-Cummings, R. : A model of proto-object based saliency, *Vision Research*, Vol. 94, 1/15 (2014)
- 5) Wagatsuma, N. : Saliency model based on a neural population for integrating figure direction and organizing border ownership, *Neural Networks*, Vol. 110, 33/46 (2019)
- 6) Pan, J., McGuinness, K., O'Connor, N. E., & Griot-Nieto, X. : Shallow and deep convolutional networks for saliency prediction, *Proceedings of 29th IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Vol. 29, 598/606 (2016)
- 7) Yamins, D. L. K., & DiCarlo, J. J. : Using goal-driven learning models to understand sensory cortex, *Nature Neuroscience*, Vol. 19, 356/365 (2016)
- 8) Pospisil, D. A., Pasupathy, A., & Bair, W. : 'Artiphysiology' reveals V4-like shape tuning in deep network trained for image classification, *eLife*, e38242 (2018)
- 9) Wagatsuma, N., Hidaka, A., & Tamura, H. : Correspondence between monkey visual cortices and layers of a saliency map model based on a deep convolutional neural network for representations of natural images, *eNeuro*, ENEURO.0200-20.2020, 1/19 (2020)
- 10) Ramachandran, P., Zoph, B., & Le, Q. C. : Swish: a self-gated activation function, *arXiv*, 1710.05941 (2017)
- 11) Tamura, H., Otsuka, H., & Yamane, Y. : Neurons in the inferior temporal cortex of macaque monkeys are sensitive to multiple surface features from natural objects, *bioRxiv* (2016)
- 12) Kingma, D., & Ba, J. : A method for stochastic optimization, *arXiv*, 1412.6980 (2014)
- 13) Borji, A. & Itti, L. : CAT2000: a large scale fixation dataset for boosting saliency research, *arXiv*, 1505.03581 (2015)
- 14) Judd, T., Ehinger, K., Durand, F. & Torralba, A. : Learning to predict where humans look, *IEEE International Conference on Computer Vision*, Vol. 12, 2106/2113 (2009)
- 15) Bylinskii, Z., Isola, P., Bainbridge, C., Torralba, A. & Oliva, A. : Intrinsic and extrinsic effects of image memorability, *Vision Research*, Vol. 116, 165/178 (2015)
- 16) Goda, N., Tachibana, N. & Komatsu, H. : Representation of the material properties of the objects in the visual cortex of nonhuman primates, *The Journal of Neuroscience*, Vol. 34, 2660/2673 (2014)
- 17) Bruce, N., & Tsotsos, J. : Saliency, attention, and visual search: an information theoretic approach, *Journal of Vision*, Vol. 9(3)-5, 1/24 (2009)

# 反射から群論理への進化による概念の誕生

得丸久文（著述業）

## The Birth of Concept with the Evolution from Reflex to Group Logic

Kumon Tokumaru (Writer)

**Abstract**— Concept was invented in very low noise environment such as Monasteries and Schools. It is plausible that, thanks to thorough thoughts, conceptual name is connected by group logic to conceptual meaning, which is a set of relevant elements and without exception. It is time to understand the mechanism of concept to rectify and develop collective human intelligence.

**Key Words:** Digital Linguistics, Evolution of Intelligence, Immune Cell Networks, Group

### 1 はじめに：概念はどう成長・発達するか

#### 1.1 概念理解のむずかしさ

概念なくして思考なし。正しい思考をするためには、正しい概念をもつ必要がある。たとえば我々は日常的に言語を使って思考する。しばしばみられる思考のパターンは「〇〇であるか否か」と二元論的であり、「郵政民営化は是か非か」といった政治的選択、「放射能は安全か危険か」といった科学的評価のような形で提示される。

提示される思考パターンは単純な二元的構造（二者選択）であるのだが、主語である「郵政民営化」や「放射能」が何か十分に論じられることは少ない。仮にきちんと丁寧に論じられていたら今度はそれを理解することがむずかしく、評価することはさらにむずかしい。それらは複雑で、目に見えないからだ。そのためほとんどの人は、それが何であるかを理解しないまま、賛成か反対かの意見を求められ、判断を迫られる。

本来であれば、ひとつひとつの言葉が、① なぜ今それが問題であるのか（議論されなければならないのか）、② それは何を意味するのか、③ 我々はどのように生きていけばよいのか、という文脈のなかで徹底的に吟味される必要がある。我々は複雑な問題をどのように自分の意識（知能）のなかで取り扱えばよいのだろうか。この問題は、科学的な概念においても同様である。その概念を正しく理解するためには時間と労力がかかるので、「右に倣え」、「大勢に合わせる」という選択肢がとられている。

#### 1.2 条件反射からの進化と考える

パブロフの条件反射実験は、記号（ベルやブザーの音）とイヌの口の中に投入される刺激物（エサや塩酸）を結びつける実験であった。1) 概念もその延長にあるのではないか。それはどのように複雑化して、どのようにして獲得されるのだろうか。

筆者が探したかぎり複雑な概念の獲得や操作を扱ったのは、発達心理学者であるピアジェの「知能の心理学」やヴィゴツキーの「思考と言語」であった。2) 3)

ヴィゴツキーは、「概念は、記憶によって獲得される連合的結合のたんなる総和でも自動的な知的技能で

もなく、複雑な真の思考活動であり、それはたんなる暗記で習得できるようなものではなく、概念が意識に発生するためには、子ども自身の思想がその内部的発達において高度の段階に達していることをつねに要求する」という。それは総合化の活動である。知識の量や質の問題ではなく、その人が言葉とそれが意味するものを全身全霊で総合化し、妥当な意味を求める知的営為のなかで、言葉の意味が成長する。

たとえば「郵政民営化」にしても「放射能」にしても、その言葉と関連した事実、科学的発見、現象などを学習し、思考していくと、自分の意識上で記憶が相互にネットワークし、ある段階で、正しい行動や判断を生むに足る複雑な意味を構成するようになる。

#### 1.3 群=ひとつの例外もなく集合が意味を成す

筆者はピアジェやヴィゴツキーが心理現象として分析し考察した概念の意味の成長・発達を、哺乳類の脳の生物構造と論理構造に結びつけながら、複雑化のメカニズムを解明したいと試行錯誤してきた。パブロフの条件反射実験でイヌが示した二分法（記号のパターン認識）と二元論（記号と意味の二元的な結びつけ）を使って、正しく概念の意味を複雑化する道筋を示すことが、ホモサピエンスとしての知的進化につながると思うからだ。その結果ピアジェが群性を論じていたことを知り、それについて考えた結果到達したのが群の論理の導入である。

言葉記号Aが集合B全体を意味とする群を構成するならば、 $A=B$ は1対全の関係で二元的にむすびつき複雑な意味をもちうるのではないか。ある言葉にまつわる知識を、ひとつも例外がないというところまで学習し考え抜いて確認したとき、Aは概念になる。

もし例外が現れたら、そのときに例外を除外すべく名称を変更させるか、例外を含めるべく概念の定義を改めればよい。

こうして概念を正しく用いるためには、群についての知識が求められる。

## 2 記号の意味の生物構造と論理構造

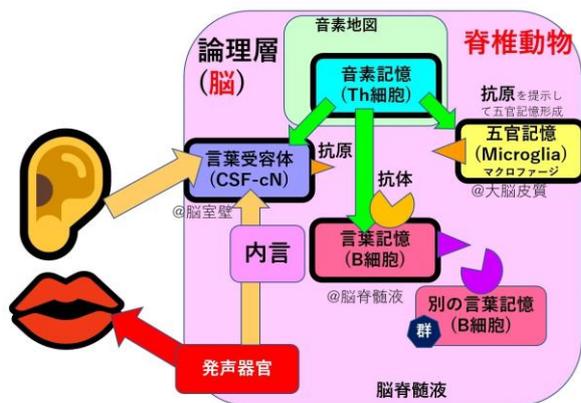
### 2.1 言語処理は脳室内免疫細胞ネットワーク

ヒトが言語をどのように処理しているかについての仮説はこれまでなかった。筆者は、鈴木孝夫の言語学、パブロフの条件反射実験、イェルネのノーベル講演「免疫システムの生成文法」などを総合し、**脳室内の免疫細胞ネットワーク**が言語処理を司るという仮説を2012年以来提唱しつづけている。4)5)6)

鈴木は動物の脊髄反射メカニズムが言語処理の神経基盤であると見定め、「鳥類の音声活動 記号論的考察」を書いた。パブロフは犬の脳皮質を切除しても条件反射が回復することを確認した。この事実は一般に流布している脳皮質で言語が処理されているとする思い込みを否定するものである。イェルネは、Bリンパ球が1000万以上の語彙数を持ち、神経細胞として作用するので、言葉を司るのに必要とされる能力をもつと述べた。7)

耳から入力される音声の中の内容語の音韻波形の記憶は脳室壁の脳脊髄液接触ニューロンの抗原として構築される。音声が入力されるとこの抗原が活性化し、脳脊髄液中を浮遊しているBリンパ球の抗体を活性化させる。五官の記憶は海馬で記録されて、脳皮質上のマイクログリアが保持する。マイクログリアの細胞膜上に抗原が構築され、Bリンパ球の抗体とネットワークする。これらの抗原と抗体が鍵と鍵穴のように特異的に結合する調整役は、ヘルパーTリンパ球の仕事であろう。

これが脳室内免疫細胞ネットワーク仮説である。筆者はこの仮説を国内に限らず海外の査読付き学会でも発表しているが、これまで誰からも反証も疑問も呈されていない。



(図1) 脳室内免疫細胞ネットワークと群スイッチ

## 2.2 神経細胞の二分法と二元論

イェルネは、ノーベル賞受賞理由となった免疫ネットワーク理論の講演の最後で、リンパ球は神経細胞と非常によく似ていて、「これら2つのシステムは、我々の身体のすべての器官のうち、非常に多くの種類の刺激に対して満足のいく反応をする能力という点で突出している。どちらのシステムも二分法と二元論を示す。両方のシステムの細胞は、信号を受け取ることができるとともに送り出すことができる。どちらのシステムにおいても、信号は興奮性か抑制性かのどちらかである。この2つのシステムは、ともに他の多くの身体組織の中に侵入するが、それぞれはいわゆる「血液と脳のバリア」によって分けられているようにみえる。

神経システムはニューロンのネットワークであり、それは1細胞の軸索と樹状突起が他の神経細胞群とシナプス結合を築いてできている。人間の体内にはおよそ100億個の神経細胞があるが、リンパ球はおよそ1兆個存在している。リンパ球はつまり、神経細胞よりも100倍、数が多いのである。

リンパ球はネットワークを構成するために繊維による結びつきを必要としない。リンパ球は自由に動き回るので、直接的な接触か、あるいは彼らが放出する抗体分子によって相互に作用する。」と述べた。8)

リンパ球はモバイル・アドホック・ネットワークででき、細胞数が神経細胞の百倍ある。つまり、リンパ球はモバイル進化した神経細胞なのである。そして二分法は、抗原と抗体の特異的結合によって実現される。二元論は「A+B=C」のように二つの入力統合されてCの行動をとる場合や、「If A then B」のようにAの入力がBを引き起こすことをいう。

鈴木が記号活動として紹介するティンバーゲンの実験観察結果では、「首の短い影」(A)が「近づく」(B)と「危険信号を発する」(C)鳥の行動や、互いの動作によって生殖行動に導かれる魚の雄雌の連鎖反応が確認されている。9)

この脊髄反射は、2.1の生物構造で処理可能である(表1)。言語処理や知能構築もこの免疫細胞の二分法と二元論によって行われているのではないかと。

## 脳室内免疫細胞ネットワーク

(免疫細胞は5億年前にモバイル進化したニューロン)

細胞	役割	能動/受動	NW端末	場所	移動性
ヘルパーT細胞	監督・指示			CSF内	移動
B細胞	記号・概念	受動/能動	抗体/抗原	CSF内	移動
脳脊髄液接触ニューロン(CSF-cN)	刺激受容・伝達	賦活	抗原	脳室壁	固定
マイクログリア	五官記憶	受動	抗原	脳皮質	固定

ヘルパーT細胞のおかげで特異的結合する抗原と抗体が同時に別の細胞上で産生する

(表1) 脳室内免疫細胞ネットワーク

## 2.3 言葉記号による自己中心的な個別記憶の想起

幼児はある言葉を聞くと、その言葉によってあるひとつの記憶を「自己中心的に」思い出す。そしてこの自己中心性は、大人についても同じである。「われわれがだまって考えていることのすべては、機能心理学の観点からすれば、社会的言語ではなくて、まさにこのような自己中心的言語だからである。」3)

ことばの意味とは何かを論じた言語学者は意外と少ない。鈴木孝夫は「意味」とは「個人がある音声形態と結びつけて頭の中に持っている知識及び体験の総体」であるとする。10) 個人の記憶だから自己中心的であるのだ。たとえば「クスクス」という料理の意味は、それを自分で食べたときに生まれる。

鈴木は「総体」をことばの意味の定義に加えたが、それは「意味を生み出す基盤」であるが、厳密に言えば「そのときに思い浮かぶ意味」とは違う。たとえば、経験を積んで、その言葉と結びつく記憶を複数あるとき、言葉の刺激に対しては具体的な体験記憶をひとつだけ反射的に思い出す。それは話し手の込めた意味ではないこともあるが、それはお互いにわからない。何かのきっかけで勘違いが判明したとき、聞き手は次の記憶を探し始めることになるが、そもそも話し手が言

葉に込めた意味の記憶を共有しているとはかぎらない。言葉の意味とは、むしろ「言葉刺激が入力されたときに反射的に想起されるある特定の個人の体験または知識の記憶」というべきではないか。鈴木 の定義にいう「知識及び体験の総体」のなかから、状況において最優先される記憶、あるいは聞き手が状況に最適と思う記憶が想起される。この想起されたものが意味ではないか。総体とすると逸脱例（たとえば「めちゃくちゃ不味いラーメン」）も含んでしまうことになる。

言語の自己中心性は、われわれが脊髄反射機構をつかって言葉を処理するという仮説と整合する。個人がある言葉を聞いた後に具体的な体験をすれば、脳内で言葉記号の記憶が生まれ、それと関連づけられた五官の記憶が記銘される。これはパプロフの条件反射実験のはじめに行われる「条件づけ」と同じ現象であり、ヒトの脳に固有のものではない。

脊髄反射で言語処理することの制約は、自己中心性のほかにも、記憶ベース、不随意、反射、記号単体のみ、誤り訂正不能など数多くある。11)

大事なことは、意味がひとつの記憶であろうと、総体であろうと、個人の体験や知識であるなら、意味は学習や経験を通じて獲得されるものであり、足りなければ学習し、成長・発展するものだということである。誤り訂正も容易ではないが、不可能ではないことをわかるべきである。そして概念の意味もここから発展するのではないか。

### 3 概念の意味の論理構造

#### 3.1 集合を意味とし、論理操作できるものが概念

鈴木が「総体」という言葉を定義に加えた理由は、言葉は「その言葉と関係をもつすべての体験と知識を総合化したもの」を意味とする場合があるからだ。

たとえば、新しい趣向のラーメンを食べて、「これはラーメンの概念を打ち破る」というとき、「ラーメン」はそれまでに味わったすべてのラーメンを示す。より正確にいうと、経験したすべてのラーメンを吟味し、評価して、秩序づけ体系化した記憶の総体をさす。

わずかひと言で「自分がこれまでに味わったすべてのラーメンの体系」（体験だけでなく、知識の記憶が含まれることもある。一方、逸脱例は除外されている。）を指し示し、ひと言が集合をまとめてひとつのものとして操作できる。これが概念ではないか。

つまり鈴木は、記号と概念をまとめた場合の言葉の意味を論じていたということになる。筆者はそれを二つに分化させることが必要だと考える。

2.3 の鈴木 の定義に少しだけ手を入れて、概念を「個人がある音声形態と結びつけて頭の中に持っている知識及び体験の体系化された総体」といったん考えてみる。単なる記憶の寄せ集めではなく、そこには体系化あるいは総合化の知的活動が存在する。また、「これはラーメンの概念を打ち破る」というように、概念はひとまとまり（の集合）として論理操作でき、例外というものが無い。また「ラーメンとスパゲッティは麺類である」（類の概念）、「ヤゴはトンボの幼虫であり、アオムシはアゲハ蝶の幼虫である」（関係性の概念）というように抽象化の次元がひとつ上がった高次概念を生みだせることが重要である。

概念の定義は「個人がある音声形態と結びつけて頭

の中に持っている知識及び体験の体系化された集合であり、群として操作した結果が新たな意味を生む」とするのはどうだろう。

#### 3.2 概念の意味を均衡させるために求められる条件

ピアジェは「知能の心理学」の第2章「『思考心理学』と論理操作の心理学的性質」で、概念（＝論理操作の対象となる体系化された集合）の「均衡法則をひき出す」ことが重要であり、それは数学においては、「群」として「はっきり規定された体系を構成している操作の相互依存関係を発見している」と述べている。

ピアジェは数学的群論を参考にして、以下の5つの数式を満足することが、概念を論理操作した結果、新たな概念を産み出すの条件であると提示している。その5つの条件は、以下の通りである。2)

- (I) 合成性  $x + x^1 = y; y + y^1 = z; \text{etc.}$
- (II) 可逆性  $y - x = x^1 \text{ or } y - x^1 = x.$
- (III) 連合性  $(x + x^1) + y^1 = x + (x^1 + y^1) = (z).$
- (IV) 同一性  $x - x = 0; y - y = 0; \text{etc.}$
- (V) 同質性  $x + x = x; y + y = y; \text{etc.}$

これらの条件に照らして、概念と意味の結びつきを確かめて、群を構成することを確認めたくて、概念を用いるとよいのではないか。

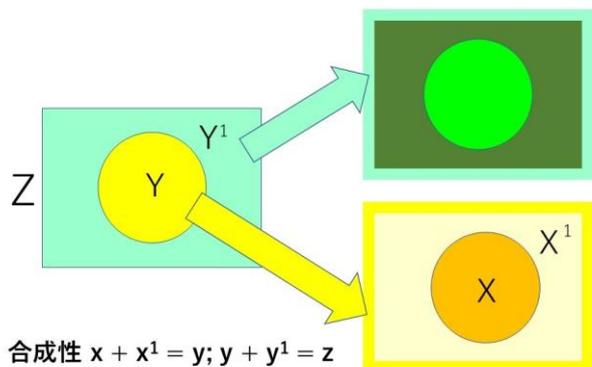
#### (I) 合成性 $x + x^1 = y; y + y^1 = z; \text{etc.}$

例外がないことが重要であるので、つねに全体を意識したうえで概念を用いる必要がある。それを確かめるために、合成性の式を使う。

全体は排中律にもとづいてきれいに二分されている必要がある。そのため  $x * x^1 = 0$  ( $x$  であると同時に  $x^1$  であるものは存在しない)の式をピアジェは示している。

比較して議論する二つの概念が、きれいに二分されていない場合も議論が歪みを生む。たとえばデカルトは『方法序説』で「動物たちの理性が人間よりも少ないということだけではなく、動物たちには理性が無いことを示している。」と述べている。しかし人間も動物であり、動物と人間の二分は排中律を構成しない。

#### 二分木による分類(合成性)



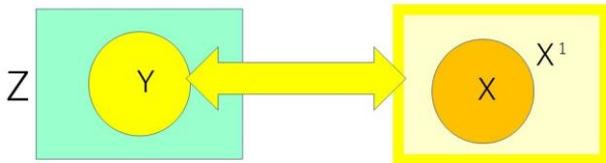
(図2) 合成性

「 $x + x^1 = y; y + y^1 = z$ 」という式は、分類を意味する。二分がきちんと明確に行われていれば、群の演算結果が正しい意味を生む。

**(II) 可逆性  $y - x = x^1$  or  $y - x^1 = x$ .**

常に逆操作ができることが保証されていれば、三段論法の詭弁を排除できる。段階的に複雑化・簡素化が行えるので、概念を定義して分解することもできれば、逆に複雑化することもできる。

**二分木による分類(可逆性)**



可逆性  $y - x = x^1$  or  $y - x^1 = x$

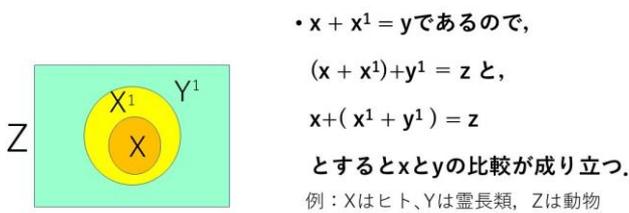
(図3) 可逆性

定義は、ある概念を別の下位概念にもとづく方程式化することであるので、はじめから精密に定義できなくても、まずは暫定的に定義して、分析や比較の結果を反映させて細かく（あるいは連立させて）精緻に定義できる。

**(III) 連合性  $(x + x^1) + y^1 = x + (x^1 + y^1) = (z)$ .**

似ているが微妙に意味の異なる概念を比較するとき、別の概念を基準にして差を示す手法が可能となる。異なる構造・範囲を持つ二つの概念（同じ名前でも定義が違う場合も）を比較して、過不足を調整することもできる。

**二分木による分類(連合性)**



連合性  $(x + x^1) + y^1 = x + (x^1 + y^1) = z$

(図4) 連合性

**(IV) 同一性  $x - x = 0; y - y = 0; etc.$**

これは一般的な2つのものの比較であり、多様な形をとりうる。言葉の定義とその言葉が指し示す現象がぴったりと同じであるか、漏れがないか、例外がないか、あれこれと丁寧に吟味する。

たとえば「反射」=「本能」と示されたとき、反射についてあれこれと調べ、本能について同様に調べると、それらはたしかに同じ現象を違った学問分野で別々の名前をつけているだけであることがわかる。同

一性はこのような場合にも適用できる論理である。

**(V) 同質性  $x + x = x; y + y = y; etc.$**

ある元を群に含めるかどうか判断するための論理。同質のものはひとつの群に吸収される。この場合、同質性をみとめる根拠は何か、定義は何かも言語化する必要がある。

これらの条件を満たした言葉については、図1にあるような群スイッチをオンにして概念として扱うことが望まれる。

ピアジェはこの後で群性体の加法的操作や乗法的操作を論じている。これらの操作によって、新たな群が生まれ、それは概念操作の結果を意味とする。

筆者が探したかぎり、数学者がピアジェの考察を検討した例はない。また、概念の意味を群論と結びつけて論じた心理学者や言語学者はピアジェ以外には知らない。これはピアジェが先駆的であったということだ。筆者は2020年の年間を通じて、信学会HCS研究会、情報処理学会MPS研究会・NL研究会、科研費シンポジウム(基礎研究(A)20H00576)などを通じて、概念が群であることについての検討結果を吟味していただいたが、誰からもとくに異論や疑念は提示されなかった。

12) 13) 14) 15) 16)

概念は、反射的な1対1の結合が、静かな環境で徹底的に学び考えた結果、群の1対全の論理へ進化したものと考えるとよいのではないか。

**4 群スイッチを頭に入れておく**

**4.1 意味の複雑さを識別するスイッチ**

言葉の意味にはいくつかの種類があると考えられるが、それをうまく分類した先行研究にはまだ遭遇していない。筆者は(a) 体験の記憶と(b) 知識の記憶で、保持されている生物組織が違う（体験記憶は大脳皮質上のマイクログリア細胞、知識の記憶は脳室内を浮遊するBリンパ球）と考えられるので二分するとよい。ヴィゴツキーは概念を生活概念と科学概念を分けるが、その違いも体験記憶か知識記憶かによると思われる。

また複雑さにも次数と呼ぶべき違いがある。それは言葉と意味を結びつける論理の違いであり、(i) 1対1の反射の論理のほか、(ii) 1対全の群の論理がある。群である概念を操作すると、双方の群に属する元が(iii) そして概念を二元操作すると全対全の記憶のネットワークが生まれ、それはより抽象度の高い意味を構成する。17)

**3種の論理と2種の記憶が意味を構築**

言葉と記憶を結びつける論理	(a) 五官記憶	(b) 思考操作の記憶
(i) 1対1 反射	特定の五官記憶の想起	科学的記号: 恣意的命名 (科学的な現象)
(ii) 1対全 群	生活概念: 五官記憶の総合化	科学的概念: 学際的統合による科学的現象の総合化
(iii) 全対全 複雑ネットワーク	類と関係性の複雑概念(生活概念の概念操作による)	科学的複雑概念 概念相互の自由なネットワーク

(表2) 2種の記憶と3種の論理が生み出す意味

すると表2に示すように、2種の記憶と3種の論理のマトリックスとして意味を区別することができる。

記憶の種類や群やネットワークについての知識を別途もっていれば、我々の神経免疫細胞は自然と6種類の意味のカテゴリーに応じて言葉を正しく獲得し、取り扱えるようにならないだろうか。

#### 4.2 科学的概念の誤り訂正を可能にするスイッチ

科学は、それまで誰も気づかなかった現象や物質を誰かが発見して、それを実現している不可視のメカニズムや法則を解明する行為である。

現象や物質の理解が適切であるかどうか、不可視のメカニズムや法則を導き出す思考過程が妥当であるかどうか、容易には判断できない場合が多い。その結果、間違った概念が伝えられることもあれば、意図的に偏った信念や偽情報が流布されることもある。学校で習う教科書の記述が間違っているということもままあることである。

あまたある科学的知識のなかで、部分的に誤った概念は誤りを訂正してから受容し、偽情報は拒否して受け入れないことが重要となる。どうすればそれができるだろうか。

科学的概念の場合は、概念の妥当性を確かめる手段が限られているために、追加的スイッチを用意して、概念の意味するものの絶対座標（たとえば分子構造や地理的・時間的座標系など）を明らかにし、ある科学者がどのようにして新しい現象や物質を発見して概念化したかの発明・発見史、全体像を概観するための参照モデルスイッチなどが用意されているべきだと考える。

##### ① 分子構造スイッチ(MS: Molecular Structure)

分子構造(Molecular Structure)は生物に関する議論における絶対座標を提供する。たとえば、「クオリア」や「ミラーニューロン」というとき、それが具体的な分子構造や細胞組織をふまえて議論されているのかを確かめる必要があるのではないか。それのない便宜的表現として用いられている言葉は、思考を混乱させるので受け入れない。

分野科学でそれぞれ別々の名前と呼ばれている現象が、分子構造や細胞組織・器官を同定すると、別の視点で同じメカニズムを観察していることがわかることがある。たとえば「反射」は「本能」であるというのは、脳生理学で反射と呼ぶ現象は、動物生態学が本能と呼ぶ現象と同じメカニズムであるということだ。

##### ② 時空間の絶対座標スイッチ(AC: Absolute Coordinate)

その現象がいつ、どこで生まれたかを明らかにする。それによって現象相互の関係もみえてくる。

##### ③ 発明発見史スイッチ(DH: Discovery History)

新たな科学的概念を発見し提唱する人間は、そもそもどのようにしてそれを発見するに至ったかを説明し、記録に残す義務をもつ。それができないなら、せめて背景となる観察や思考過程を書き残しておかなければならない。

たとえば、熱力学概念のエントロピーは、ボルツマンではなく、クラウジウスが導き出したものである。八木江里博士は、クラウジウスの論文の解析を行って「構成要素の配置の変化量」( $\Delta S$ )をエントロピーと呼

んだことを解明した。(18) (19)

一方、情報理論においてエントロピーは情報量を表すとされるが、この概念がどのようにして導かれたのかという質問に、シャノン本人が答えていない。このために情報理論エントロピーは、正しいかどうか評価する手段がない。これでは受け入れようがない。(20)

##### ④ 参照モデルスイッチ(RF: Reference Model)

我々の脳はきわめて単純な脊髄反射のメカニズムを使って、言語を処理し、知能を構築している。そのため複雑な概念を理解することが苦手である。複雑な概念を正しく理解するためには、表や図の形式で参照モデルをつくると、思考が整理される。

記憶に体験か知識か、論理に反射か群かネットワークかという区別があることを知り、科学的概念を正しく理解するためには分子構造をたしかめ、発生した時空間を明らかにし、発明物語をひもとき、参照モデルにして概観する手法があることを知っていれば、学習にあたって誤りや歪みを脳内に取り込まないですまないだろう。

## 5 おわりに：デジタル進化の最終段階

筆者は2007年に南アフリカ共和国にある最古の現生人類洞窟を訪問したことをきっかけとして、ヒトの言語が音節という信号の獲得によるデジタル進化であると気づいた。(21) どうして音素共有が始まったかと振り返ってみると、ヒトが13万年前から南アフリカの南部海岸線に穿たれた巨大洞窟群に住むようになり、安全な洞窟のなかで乳児が生後1年間寝たきりで生活するように晩成化し、乳幼児の世話をするために祖母が家族の一員となって真社会性化したことが考えられる。真社会性動物は、共同体独自の匂いや鳴き声をもつ傾向にあり、その匂いや鳴き声が仲間であることの身分証明書の役割を果たす。そして匂いや鳴き声が違うグループに対して敵対するゼノフォビア（外国人嫌い）の特徴をもつ。人類史上、戦争や陰謀がなくなれないのはこの性質のためであろう。そして、言語ごとに音節の作り方が個性的であることもこれで説明がつく。

	信号	特徴	論理進化	誕生時期	場所
1	音節	音素とモーラ	文法	66千年前	南ア
2	文字	消えない音節	概念	5千年前	中東
3	Bit	対話する音節	誤り訂正	60年前	米国

(表3) デジタル信号の三段階進化

音節は時間軸上で離散的であるために、文法的な音節によって言葉を修飾し接続することを可能にした。文字は消えないために、過去の人々が一生をかけて獲得した知識を概念化して書き残すと、後世の人間は読書百遍の要領で読み解いて連続的に発展させるようになった。これが文明という現象であり、**概念は深淵な知識を伝える記号**である。そしてその深淵なる知識は、きちんとした手法を用いると、正しく継承され、さらには誤りを訂正し、発展するものであるということを知り、人類は知るべきである。

問題は、真社会性であるために、目上の人から教えられることを疑うことなく受け入れる傾向であり、間違いを見つけても目上にはそれを指摘しない風潮である。このために科学的文献や概念のなかには、誤っているのに訂正されないままになっているものが数多くある。また、外国人に対して、わざと誤った概念や歪んだ概念を教えて、その国の科学技術の発展を阻害する破壊工作も行われている。これらの蓄積された誤りや歪みを正すことが求められるのだが、なかなか実効的手段がなかった。

5000年前、文字の発明によって時空を超える「消えない音節」が生まれ、20世紀後半にはbitの発明によって検索エンジンに対して反応する「対話する音節」が生まれた。今、インターネットの検索エンジンにキーワードを投入すると、それと関連する「きわめて大量であるが、信頼性の保証のない言語情報」のリストや本文を手にすることができる。インターネットからの言語情報が信頼性に欠けるといふ認識はとても重要である。実はそれ以外の学校で習うことも著名な科学者の書いたことも、すべて誤りを含んでいる可能性がある。真に受けてはいけない。

およそすべての科学的な概念には、日常的な注意力では検知できない歪や誤りが含まれていて、それが人類共有知のさらなる発展を阻害している可能性がある。と考えるべきだ。

それを乗り越えるために、デジタル通信技術に固有の前方誤り訂正(Forward Error Correction)の手法を用いるべきだ。前方誤り訂正は、情報を受け取った人が自力で誤りを正す技術である。それはまず本人の言葉を復元し確かめて(通信路誤り訂正)、次いで原著者の思考過程を段階的に追体験する(情報源誤り訂正)と、誤りを正した言語情報を受容できる。

概念が群であるということをもまえて、知識再生的な受容を心掛けると、誤りや歪みをもつ概念が正されて、人類は大きな知的進化を遂げることにならないだろうか。

## 参考文献

- 1) I.P. パプロフ(1927) 大脳半球の働きについて- 条件反射学, 川村浩訳,岩波文庫 1975
- 2) ピアジェ 知能の心理学 みすず書房 1967
- 3) ヴィゴツキー 思考と言語, 明治図書, 1962
- 4) 得丸 記号と言語と条件反射-鈴木孝夫の『鳥類の音声活動-記号論的考察』に刺激されて,信学技報 TL2012-1
- 5) 得丸, 言葉理解と意味理解の生物構造: 言語は大脳皮質で処理されていない (デジタル言語学), 人工知能学会 SIG-SLUD089-010
- 6) 得丸 言語現象とパターン認識~ヒトの意識の脳室内免疫応答ネットワーク仮説,信学技報 PRMU-112(495):1-6
- 7) Jerne, N.K. (1984) The Generative Grammar of the Immune System (The Nobel Lecture)
- 8) Jerne, N.K. (1974) Toward a Network Theory of Immune System, Ann Immunol (Paris). 125C(1-2) :373-89
- 9) 鈴木孝夫, 鳥類の音声活動 記号論的考察, 言語研究
- 10) 鈴木孝夫, 言語文化学ノート, 大修館書店
- 11) 得丸 言語処理装置としての脊髄反射回路~言語情報オートマトン正規化のための工夫 (デジタル言語学), 信学技報 COMP2018-10

- 12) 得丸 群論理に基づく概念操作~ 言葉記号から概念への進化 (デジタル言語学)~信学技報 HCS2019-54
- 13) 得丸 概念とは群である-学習における前方誤り訂正の必要性, 科研費シンポ「大規模複雑データの理論と方法論の革新的展開」, 2020年12月19日
- 14) 得丸 概念語の複雑性、ならびに『きわめて大量だが信頼性の保証がない言語情報』の取り扱いについて, 科研費シンポジウム「多様な分野のデータに対する統計科学・機械学習のアプローチ」, 2020年9月29日
- 15) 得丸 概念に求められる群性 概念の意味の前方誤り訂正のために Vol.2020-MPS-130 No.2 2020/9/29
- 16) 得丸 複雑系の言語学-概念処理における群スイッチ, 研究報告自然言語処理 2020-NL-246(20)1-19
- 17) 得丸 概念語の複雑次数 論理操作のフラクタル構造 信学技報 EMM2018-49
- 18) 八木, 林, 依田, 岡本 クラウジウス研究からわかった 19世紀物理学の側面, 日本物理学会誌 69(2014):230-232
- 19) 佐々真一 クラウジウス著, 八木江里監訳, 八木他訳, クラウジウス熱理論論文集; エントロピーの起源としての力学的熱理論, 東海大学出版会, 2013 日本物理学会誌 69(2014):247
- 20) 得丸 情報理論のエントロピー概念の再構成~シャノンの伝記とフォン・ノイマンの手記を参考に 信学技報 RECONF2019-35
- 21) 得丸 真社会性と音素共有 ヒトの言語獲得におけるミッシングリンク 信学技報 HCS2020-40
- 22) 得丸 言語的人類の知能の三段階デジタル進化, 日本認知科学会第37回大会論文集
- 23) 得丸 デジタル言語学 知能発展の第三段階 FIT2020 E-017

# ノイズ下における神経システムのカオス共鳴の性能評価

○信川創 (千葉工業大学) 我妻 伸彦 (東邦大学) 西村治彦 (兵庫県立大学)  
稲垣圭一郎 (中部大学) 山西輝也 (福井工業大学)

## Chaotic Resonance in Neural Systems under Noises

\*S. Nobukawa, (Chiba Institute of Technology), N. Wagatsuma (Toho University),  
H. Nishimura (University of Hyogo), H. Nishimura (University of Hyogo),  
K. Inagaki (Chubu University), and T. Yamanishi (Fukui University of Technology)

**Abstract**— Recent progress in studies for stochastic resonance applied various fields for engineering applications. The deterministic chaos also causes a phenomenon similar to stochastic resonance, which is known as chaotic resonance. Previously, we proposed “reduced region of orbit” (RRO) feedback methods, which achieves inducing the chaotic resonance by the external feedback signals. However, this evaluation was conducted under the noise-free conditions. Considering fact that background noise and measurement error to estimate the RRO feedback strength exist in the real situation, the influence of these factors to chaotic resonance must be evaluated for application of chaotic resonance. Therefore, in this study, we evaluate the chaotic resonance induced by RRO feedback method in the chaotic neural systems under the stochastic noise. Concretely, we focus on the chaotic resonance induced by RRO feedback signals in the neural system composed of excitatory and inhibitory neurons that is the typical neural systems for emergence of chaotic resonance under additive noise and the feedback signals including measurement error (called contaminant noise).

**Key Words:** Chaotic resonance, feedback control, noise, synchronization.

## 1 はじめに

幅広い非線形システムにおいて、確率的ノイズの印加やシステム内部の動的なゆらぎによって、周期性や同期性といった時空間的な秩序性が顕在化する現象が広く知られている<sup>1, 2, 3, 4, 5, 6</sup>。このような現象の中で、確率共鳴は適切な強度をもった付加的な確率ノイズが、障壁/閾値特性をもった非線形システムの微弱信号への応答性を増強する現象である。近年の確率共鳴研究の進展により、医用工学<sup>7, 8</sup>や無線通信<sup>9</sup>、低消費電力なメモリデバイス<sup>10, 11, 12</sup>などの幅広い領域において応用が広がっている。確率共鳴の工学的応用研究については、Table 1 にまとめた。

確率的ノイズの印加だけでなく、決定論的なカオスも確率共鳴と同様の共鳴現象を引き起こすことが知られており、カオス共鳴と呼ばれている<sup>3, 4, 6</sup>。カオス共鳴は、カオス-カオス間欠性 (chaos-chaos intermittency: CCI) と呼ばれる複数のアトラクタ領域を間欠的に往来するシステムにおいて、アトラクタ併合分岐付近のパラメータ領域で微弱信号への応答性が最大化する現象として観測されている<sup>3, 4, 6</sup>。カオス共鳴は、cubic 離散写像<sup>17</sup>や Chua 回路<sup>18</sup>、神経システム<sup>19, 20, 17, 21, 22</sup>などの多様なシステムにおいて観測されている。さらに、これまでに我々は、微弱な入力信号に対するカオス共鳴の応答感度が確率共鳴と比較して高いことを報告している<sup>20, 22</sup>。しかし、カオス共鳴の工学的応用は確率共鳴と比較して進んでいない。

その原因としては、アトラクタ併合分岐の制御はシステムの内部パラメータの調整が必要ではあるが、特に生体システムの場合では内部パラメータの調整が困難である場合が多い。この問題への対応として我々は、軌道領域減少 (reduced region of orbit: RRO) 法と呼ばれる外部フィードバック信号により、アトラクタ併合分岐を誘起する手法を考案した<sup>23</sup>。この手法により、内

部パラメータを調整することなく、RRO フィードバック信号強度を調整することで、アトラクタ併合分岐を誘導し、さまざまなシステムにおいてカオス共鳴の生起を制御できるようになった<sup>23, 24, 25, 18, 21, 22, 26</sup>。しかし、この RRO 法により制御されたカオス共鳴の評価は主にノイズ・フリーな環境で評価されており、ノイズのカオス共鳴に対する影響についてはほとんど分かっていない。

実際のカオス共鳴環境下においては、付加的ノイズと RRO feedback 信号を推定する際の計測誤差 (混入ノイズと本研究では呼ぶ) が存在すると考えられる。よって、実環境におけるカオス共鳴の応用には、これらの2種類のノイズのカオス共鳴の影響の評価が必要となる。そこで本研究では、RRO 法により誘起されたカオス共鳴の信号応答性をこれらの2種類のノイズ下において評価し、その影響を調べる。具体的には、Sinha によって提案された興奮性と抑制性ニューロンにより構成されたカオス共鳴を生起する神経システムに対し<sup>27</sup>、RRO フィードバック信号と前述のノイズ、弱入力信号を印加してカオス共鳴の性能評価を行う。

## 2 モデル

Sinha によって提案された興奮性ニューロンと抑制性ニューロンで構成される離散神経システムにおいて、興奮性ニューロンの神経活動の神経活動と抑制性ニューロンの神経活動の和である有効神経ポテンシャル  $z(t)$  のダイナミクスは、(1) 式で表される<sup>27</sup>。

$$z(t+1) = F(z(t)) = F_a(z(t)) - kF_b(z(t)) \quad (1)$$

Table 1: 確率共鳴の工学的応用研究.

対象システム	応用技術の概要
生体システム	外科医の触覚感度を増強させる振動ノイズを印加するウェアラブルデバイス <sup>7, 8)</sup> .
生体システム	触覚感覚の麻痺をもった患者の触覚感度を増強するノイズ印加によるリハビリ法 <sup>13, 14)</sup> .
生体システム	経頭蓋磁気刺激法により視覚野に印加された適度なノイズによる視覚刺激の認知精度の向上法 <sup>15)</sup> .
無線通信システム	二位相偏移変調方式におけるノイズ印加による誤り率の向上法 <sup>9)</sup> .
無線通信システム	無線センサネットワークにおけるノイズ印加による位置推定の向上法 <sup>16)</sup> .
メモリシステム	双安定状態をもったメモリ素子において、背景ノイズを利用することで低消費電力でも駆動できるメモリデバイス <sup>10, 11)</sup> .

ここで、 $F_a$  と  $F_b$  は興奮性ニューロンと抑制性ニューロンの活性化関数で、

$$F_a(X) = \begin{cases} -1 & (X < -1/a) \\ aX & (-1/a \leq X \leq 1/a) \\ 1 & (X > 1/a) \end{cases} \quad (2)$$

$$F_b(Y) = \begin{cases} -1 & (Y < -1/b) \\ bY & (-1/b \leq Y \leq 1/b) \\ 1 & (Y > 1/b) \end{cases} \quad (3)$$

で表される。興奮性ニューロンと抑制性ニューロンの活性化関数の閾値は  $1/a$  と  $1/b$  にそれぞれ対応する。本研究では、( $a = 5.95, 5.96, 5.97, b = 3.42, k = 1.3811$ ) のパラメータ設定を用いる。このパラメータ設定によって、外部入力がない場合、 $z(t)$  は初期値  $z(0)$  に応じて、 $z(t)$  の正負のどちらかの領域にトラップされる<sup>27)</sup>。

我々はこれまでに、この有効神経ポテンシャル  $z(t)$  のダイナミクスに対して RRO フィードバック信号を印加し、アトラクタ併合分岐の制御を行ってきた<sup>21, 22)</sup>。本研究では、(4) と (5) 式に示されるように、付加的ノイズ  $D_a\xi(t)$  と混入ノイズ  $D_c\eta(t)$  の RRO 法への影響を調べる。

$$z(t+1) = F(z(t)) + Ku(z(t) + D_c\eta(t)) + D_a\xi(t) \quad (4)$$

$$u(z) = -(z - z_d) \exp(-(z - z_d)^2 / (2\sigma^2)) \quad (5)$$

ここで、 $D_a$  と  $D_c$  はノイズ強度を、 $\xi, \eta$  は平均値 0 で分散 1 のガウス型白色ノイズを表す。関数  $u$  は RRO フィードバック信号、 $K$  はその信号強度、 $z_d$  はアトラクタの併合位置、 $\sigma$  は RRO フィードバック信号の影響範囲を表す。本研究では、RRO フィードバック信号は  $z_d = 0, \sigma = 1/a$  に設定する<sup>23, 21, 22)</sup>。また、カオス共鳴の信号応答性の評価のために、 $S(t) = A \sin 2\pi\Omega t$  を (4) 式に印加する。

$$z(t+1) = F(z(t)) + Ku(z(t) + D_c\eta(t)) + D_a\xi(t) + S(t) \quad (6)$$

本研究では、 $A = 0.03, \Omega = 0.001$  の設定を用いる。

### 3 結果

Fig.1 に入力信号  $S(t)$  と  $z(t)$  の符号によって離散化された時系列との相互相関係数  $\max_\tau C(\tau)$  を示す。 $\max_\tau C(\tau)$  の付加ノイズ強度  $D_a$  と RRO フィードバック強度  $K$  依存性の結果からは、最適なフィードバック

強度 ( $K \approx 0.09$  ( $a = 5.95$  の場合),  $0.07$  ( $a = 5.96$  の場合),  $0.05$  ( $a = 5.97$  の場合)) で  $\max_\tau C(\tau)$  はピークを持つが、そのピーク値は  $D_a$  の増加に伴って単調に減少する様子が確認できる。一方、 $\max_\tau C(\tau)$  の混入ノイズ強度  $D_c$  と RRO フィードバック強度  $K$  依存性の結果からは、 $D_c \lesssim 0.1$  の領域では  $\max_\tau C(\tau)$  のピークは  $D_c$  の増加に伴って減少する。しかし、 $D_c \gtrsim 0.1$  の領域では、ノイズフリーの場合のピーク値よりは劣化するが、 $K \approx 0.05$  ( $a = 5.95$  の場合),  $0.04$  ( $a = 5.96$  の場合),  $0.03$  ( $a = 5.97$  の場合) で  $\max_\tau C(\tau)$  が比較的高いピークを持つ領域が現れる。このことから、付加ノイズと混入ノイズはカオス共鳴の性能にそれぞれ質的に異なる影響を与え得ると言える。

### 4 おわりに

本研究では、興奮性-抑制性ニューロンによって構成される神経システムにおいて、RRO フィードバック信号によって誘起されるカオス共鳴のノイズへの影響を調べた。その結果、付加的ノイズは単調にカオス共鳴の信号応答性を劣化させる。混入ノイズは一定レベルのノイズ強度までは信号応答性を劣化させるが、それ以上のノイズ強度においては比較的高い信号応答性を保持したフィードバック強度領域が現れる。

このような 2 種類のノイズが異なる影響を信号応答性に与えるのかについて考察する。最初に付加的ノイズについては、アトラクタ併合付近においては自律的な CCI の頻度は低く、その状況においてノイズが印加された場合、ノイズは外因性の CCI を誘起する。これにより CCI の頻度が増加し、弱入力信号に誘導された CCI を乱すことでカオス共鳴の信号応答性を劣化させているものと考えられる。一方混入ノイズの場合は、弱い強度領域においては付加的ノイズと同様に CCI の頻度が増加し、カオス共鳴の性能が単調に劣化する。しかし、強い強度をもった混入ノイズは、アトラクタ併合分岐を誘導する RRO フィードバック信号  $u$  のプロフィールを乱すため、CCI 頻度が低下し、それによってカオス共鳴の信号応答性が比較的に保存されたものと考えられる。このようなノイズのカオス共鳴への質的な影響の違いは、カオス共鳴の工学応用において考慮しなければならない点であると考えられる。

### 謝辞

本研究の一部は、栢森情報科学振興財団 研究助成 (K32 XXV 571)(SN) と JSPS 科研費 基盤研究 (C)(18K11450)(TY), 基盤研究 (C)(20K11976)(NH) の助成を受けている。

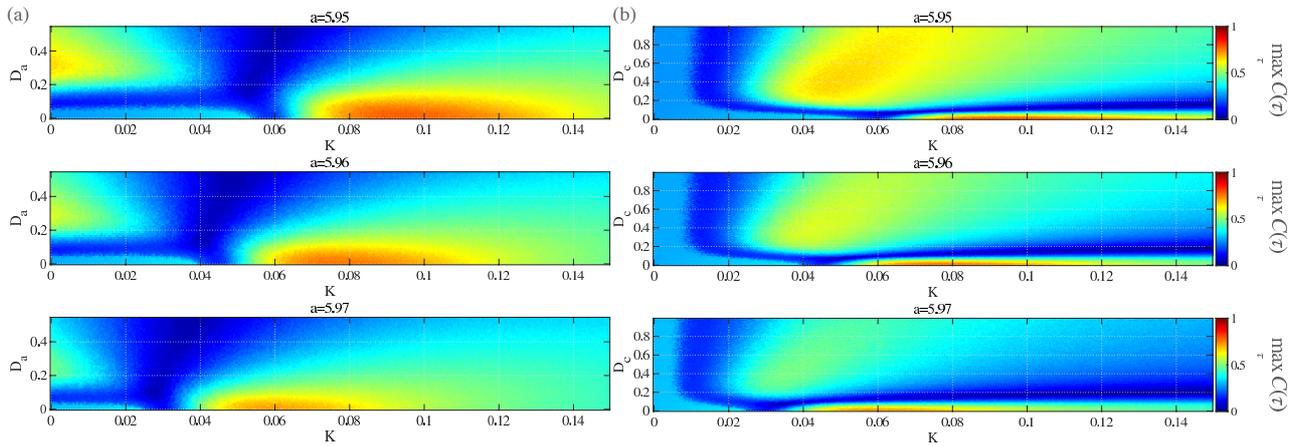


Fig. 1: 入力信号  $S(t)$  と  $z(t)$  の符号によって離散化された時系列との相互相関係数  $\max_{\tau} C(\tau)$ . (a)  $\max_{\tau} C(\tau)$  の付加ノイズ強度  $D_a$  と RRO フィードバック強度  $K$  依存性 ( $D_c = 0$ ). (b)  $\max_{\tau} C(\tau)$  の混入ノイズ強度  $D_c$  と RRO フィードバック強度  $K$  依存性 ( $D_a = 0$ ).

## 参考文献

- 1) G. P. Harmer, B. R. Davis, and D. Abbott, "A review of stochastic resonance: Circuits and measurement," *IEEE Transactions on Instrumentation and Measurement*, vol. 51, no. 2, pp. 299–309, 2002.
- 2) A. Pikovsky, M. Rosenblum, and J. Kurths, *Synchronization: a universal concept in nonlinear sciences*. Cambridge university press, 2003, vol. 12.
- 3) V. S. Anishchenko, V. Astakhov, A. Neiman, T. Vadivasova, and L. Schimansky-Geier, *Nonlinear dynamics of chaotic and stochastic systems: tutorial and modern developments*. Springer Science & Business Media, 2007.
- 4) S. Rajasekar and M. A. F. Sanjuán, *Nonlinear resonances*. Springer, 2016.
- 5) S. H. Strogatz, "Nonlinear dynamics and chaos with student solutions manual: With applications to physics, biology," *Chemistry, and Engineering*. CRC Press, 2018.
- 6) S. Nobukawa and H. Nishimura, "Synchronization of chaos in neural systems," *Frontiers in Applied Mathematics and Statistics*, vol. 6, p. 19, 2020.
- 7) Y. Kurita, M. Shinohara, and J. Ueda, "Wearable sensorimotor enhancer for fingertip based on stochastic resonance effect," *IEEE Transactions on Human-Machine Systems*, vol. 43, no. 3, pp. 333–337, 2013.
- 8) Y. Kurita, Y. Sueda, T. Ishikawa, M. Hattori, H. Sawada, H. Egi, H. Ohdan, J. Ueda, and T. Tsuji, "Surgical grasping forceps with enhanced sensorimotor capability via the stochastic resonance effect," *IEEE/ASME Transactions on Mechatronics*, vol. 21, no. 6, pp. 2624–2634, 2016.
- 9) Y. Tadokoro, H. Tanaka, Y. Nakashima, T. Yamazato, and S. Arai, "Enhancing a bpsk receiver by employing a practical parallel network with stochastic resonance," *Nonlinear Theory and its Applications, IEICE*, vol. 10, no. 1, pp. 106–114, 2019.
- 10) S. Ibáñez, P. Fierens, R. Perazzo, G. Patterson, and D. Grosz, "On the dynamics of a single-bit stochastic-resonance memory device," *The European Physical Journal B*, vol. 76, no. 1, pp. 49–55, 2010.
- 11) A. Stotland and M. Di Ventra, "Stochastic memory: Memory enhancement due to noise," *Physical Review E*, vol. 85, no. 1, p. 011116, 2012.
- 12) L. Duan, F. Duan, F. Chapeau-Blondeau, and D. Abbott, "Stochastic resonance in hopfield neural networks for transmitting binary signals," *Physics Letters A*, vol. 384, no. 6, p. 126143, 2020.
- 13) L. R. Enders, P. Hur, M. J. Johnson, and N. J. Seo, "Remote vibrotactile noise improves light touch sensation in stroke survivors' fingertips via stochastic resonance," *Journal of neuroengineering and rehabilitation*, vol. 10, no. 1, p. 105, 2013.
- 14) N. J. Seo, M. L. Kosmopoulos, L. R. Enders, and P. Hur, "Effect of remote sensory noise on hand function post stroke," *Frontiers in human neuroscience*, vol. 8, p. 934, 2014.
- 15) O. Van der Groen, M. F. Tang, N. Wenderoth, and J. B. Mattingley, "Stochastic resonance enhances the rate of evidence accumulation during combined brain stimulation and perceptual decision-making," *PLoS computational biology*, vol. 14, no. 7, p. e1006301, 2018.
- 16) D. He, "A novel wireless sensor networks multilateration positioning method based on quartic double-well bistable stochastic resonance technique," *Nonlinear Theory and Its Applications, IEICE*, vol. 8, no. 1, pp. 49–57, 2017.
- 17) S. Nobukawa, H. Nishimura, and T. Yamanishi, "Evaluation of chaotic resonance by lyapunov exponent in attractor-merging type systems," in *International Conference on Neural Information Processing*. Springer, 2016, pp. 430–437.
- 18) S. Nobukawa, H. Doho, N. Shibata, H. Nishimura, and T. Yamanishi, "Chaos-chaos intermittency synchronization controlled by external feedback signals in chua's circuits," *IEICE TRANSACTIONS on Fundamentals of Electronics, Communications and Computer Sciences*, vol. 103, no. 1, pp. 303–312, 2020.
- 19) S. Sinha and B. K. Chakrabarti, "Deterministic stochastic resonance in a piecewise linear chaotic map," *Physical Review E*, vol. 58, no. 6, p. 8009, 1998.
- 20) 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.
- 21) S. Nobukawa and N. Shibata, "Controlling chaotic resonance using external feedback signals in neural systems," *Scientific reports*, vol. 9, no. 1, p. 4990, 2019.
- 22) S. Nobukawa, N. Shibata, H. Nishimura, H. Doho, N. Wagatsuma, and T. Yamanishi, "Resonance phenomena controlled by external feedback signals and additive noise in neural systems," *Scientific reports*, vol. 9, no. 1, pp. 1–15, 2019.
- 23) S. Nobukawa, H. Nishimura, T. Yamanishi, and H. Doho, "Controlling chaotic resonance in systems with chaos-chaos intermittency using external feedback," *IEICE Transactions on Fundamentals of Electronics, Communications and Computer Sciences*, vol. 101, no. 11, pp. 1900–1906, 2018.

- 24) —, “Induced synchronization of chaos-chaos intermittency maintaining asynchronous state of chaotic orbits by external feedback signals,” *IEICE Transactions on Fundamentals of Electronics, Communications and Computer Sciences*, vol. 102, no. 3, pp. 524–531, 2019.
- 25) S. Nobukawa, N. Wagatsuma, and H. Nishimura, “Chaos-chaos intermittency synchronization induced by feedback signals and stochastic noise in coupled chaotic systems,” *IEICE TRANSACTIONS on Fundamentals of Electronics, Communications and Computer Sciences*, vol. 103, no. 9, pp. 1086–1094, 2020.
- 26) H. Doho, S. Nobukawa, H. Nishimura, N. Wagatsuma, and T. Takahashi, “Transition of neural activity from the chaotic bipolar-disorder state to the periodic healthy state using external feedback signals,” *Frontiers in Computational Neuroscience*, vol. 14, p. 76, 2020.
- 27) S. Sinha, “Noise-free stochastic resonance in simple chaotic systems,” *Physica A: Statistical Mechanics and its Applications*, vol. 270, no. 1-2, pp. 204–214, 1999.

# カオス系における位相同期と移動情報量により評価された機能的結合

○戸部真弓菜 信川創 (千葉工業大学)

## Functional Connectivity Evaluated by Phase Synchronization and Transfer Entropy, Functional connectivity

\*M. Tobe and S. Nobukawa (Chiba Institute of Technology)

**Abstract**— Various types of indexes for functional connectivity, which have developed over the decades, opened new avenues for revealing complex neural networks in the brain. Particularly, Phase Lag Index (PLI) defined by instantaneous phase dynamics achieves high spatial-temporal resolution; Transfer Entropy (TE) defined by information flow reveals directed network characteristics. However, the relationship between PLI and TE remains unclear. In this context, we hypothesize that a complementary relationship exists to discover new aspects for functional connectivity, which cannot be detected by either PLI or TE. To validate this hypothesis, we evaluated the synchronization in coupled Rössler model using PLI and TE. As the result, we found non-linear relationships between PLI and TE. This relationship might be utilized to reveal the complex spatial-temporal functional connectivity.

**Key Words:** Phase Lag Index, Transfer Entropy, Chaos, Functional connectivity

### 1 はじめに

EEG (Electroencephalogram), fMRI (Functional magnetic resonance imaging), MEG (Magnetoencephalography) などといったニューロイメージング技術の発達により、高い時間分解や空間分解能の精度で脳の活動を記録することができるようになった。従来の研究で試みられてきたのは、局所的な神経活動のみに着目し、個々のニューロンや脳部位が特定の脳機能にどう関与するかという機能の局在性を明らかにすることである。しかし、人間の脳をより理解するためには、様々な神経部位で記録された脳活動間の相互依存性と因果関係の測定が必要である。そのため近年では、機能局在ではなく脳のネットワーク全体へ目を向けた機能的結合についての研究が多く行われるようになってきている<sup>1)</sup>。

脳の機能的に着目した以前の研究からは、統合失調症やアルツハイマー病、加齢などの要因により、脳の機能的結合に異常が起こることが明らかになっている<sup>2, 3, 4)</sup>。また、このことにより、認知機能には脳の機能的結合が関連しているとも考えられている。

脳の機能的結合を定量化するための方法としては、様々な指標が使われている。その中でも、Phase Lag Index (PLI) という2つの信号の位相の同期に着目した指標や<sup>5)</sup>、2つ以上の時系列間の同期の一貫性を推定する位相コヒーレンス (IC)、パス長やクラスタリング係数、スモールワールド性などグラフ理論に基づいたネットワークトポロジーの指標を用いた研究などが行われている<sup>6, 7, 8)</sup>。現在の研究の多くでは、これらの指標を用いることで、脳の機能的結合の観点より様々な脳領域間の相互作用を調べている。

ここで、PLIとは、2つの時系列信号間の瞬時位相差の分布の非対称性から機能的結合を評価する、信号間の同期を調べるための指標である<sup>5)</sup>。統合失調症患者と

健常者の脳波に対し PLI を用いて機能的結合の比較を行った研究では、統合失調症患者の脳波では健常者の脳波と比較して脳の Beta 波や Gamma 波といった高周波帯域で機能的結合に異常があることが分かっている<sup>2)</sup>。また、アルツハイマー病の患者の脳波における Alpha 波、Beta 波、Gamma 波の機能的結合の低下<sup>4)</sup>や、加齢の影響による前頭葉領域内での半球間接続の低下が起こることも分かっている<sup>9)</sup>。

他の機能的結合を調べる指標としては、近年、情報量の伝達性を定量化する新しい指標である Transfer Entropy (TE: 移動情報量) に注目が集まっている<sup>10)</sup>。TE は振動子を仮定しないモデルフリーな指標である。また、TE は条件付き確率を使用して情報理論の観点から2つの信号間の因果的な相互作用や情報の流れを検出することができる解析方法である。TE を実際に脳波に対して適用し結合を調べた研究としては、レビー小体型認知症の脳波や、てんかん患者の脳波に関して情報の流れから機能的結合を調べる研究などが行われている<sup>11, 12)</sup>。

ここで、従来より用いられている指標である PLI は、脳波の位相の同期の度合いにより結合の強度を推定する指標である。しかし、PLI は信号の位相のみに着目しており、2つの信号間での実際の情報の流れは反映されていない。それに対し、TE は信号間の情報の流れを有向で捉えられるという特徴を持っている。また、PLI は振動子を仮定したものであるが、TE はこのような事前の仮定を必要としないモデルフリーな方法である。これらの特性の違いにより、PLI と TE の2つの指標間には脳の機能的結合の推定における相補的な関係があるのではないかと予想される。また、PLI と TE の関係性が明らかになれば、脳の機能的結合の新たな側面を捉えられる可能性がある。しかし、PLI と TE を直接比較した研究はまだなく、PLI と TE との関係性についてはまだよく分かっていない。

そこで、本研究では、脳の機能的結合の指標として使われている PLI と TE の関係性について分析する。そのためにレスラー結合系によるカオス振動子のモデルを用いて2つの時系列信号間の結合の強度による PLI と TE の特性を調べた。また、PLI と TE の関係性の評価を行った。

## 2 手法

### 2.1 レスラーモデル

ニューロン活動の同期を調べるためには、2つの結合されたレスラーニューロンモデルで分析されることがある<sup>13)</sup>。これは、比較的強い同期挙動、多様な同期特性というレスラー結合モデルの特徴が脳領野間の神経活動の相互作用をシンプルなモデルとして表すのに適しているためである。

レスラーモデルは、以下の(1)~(3)式で表される3変数の連立常微分方程式である<sup>14)</sup>。これらの方程式は、フラクタル特性をもつカオスアトラクタを生成する。

$$\dot{x} = -(y + z) \quad (1)$$

$$\dot{y} = x + \frac{1}{5}y \quad (2)$$

$$\dot{z} = \frac{1}{5} + z(x - \mu) \quad (3)$$

(1)~(3)式において、 $\mu$  は秩序パラメータをあらわす定数である。上記のレスラーモデルは、(3)式に非線形項をもつ非線形方程式である。これらの解は、Fig.1のような $(x, y, z)$ の3次元の相空間内の軌跡として表される。

このモデルにおいて、 $x$ の値を時間とともにプロットしたものはFig.2に示すような非周期的振動となる。本研究では、脳の領野間の神経活動の相互作用をレスラー結合モデルでシミュレートする。次に、(1)~(3)式のレスラーモデルを2つ結合したモデルを(4)~(9)式に

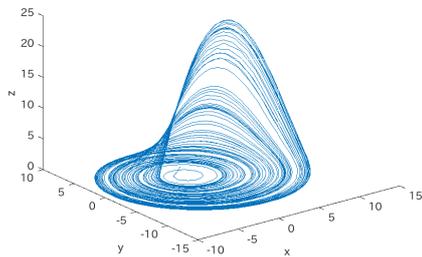


Fig. 1 (1)~(3)式におけるレスラーモデルのアトラクター。

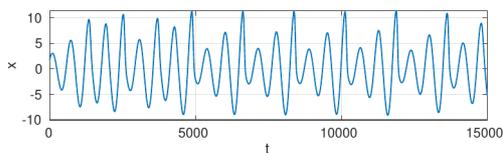


Fig. 2 (1)~(3)式のレスラーモデルにおける $x$ の時間変化。

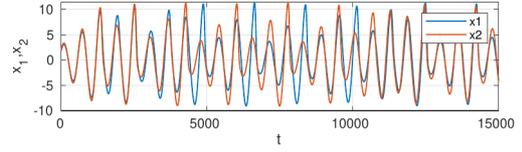


Fig. 3 (4)~(9)式のレスラー結合系モデルにおける $x_1, x_2$ の時間変化。

表す。

$$\dot{x}_1 = -(y_1 + z_1) \quad (4)$$

$$\dot{y}_1 = x_1 + \frac{1}{5}y_1 + A(y_2 - y_1) \quad (5)$$

$$\dot{z}_1 = \frac{1}{5} + z_1(x_1 - \mu) \quad (6)$$

$$\dot{x}_2 = -(y_2 + z_2) \quad (7)$$

$$\dot{y}_2 = x_2 + \frac{1}{5}y_2 + A(y_1 - y_2) \quad (8)$$

$$\dot{z}_2 = \frac{1}{5} + z_2(x_2 - \mu) \quad (9)$$

$A$ は結合強度を調整するためのパラメータであり、(5)、(7)式が結合項となる。 $\mu$ は秩序パラメータを示す定数であり、本研究では $\mu = 5.7$ に設定した。このモデルについて、 $x_1, x_2$ の値を時間とともにプロットするとFig.3に示す非周期的振動が得られる。

本研究では、解析に用いるための2つの時系列信号を(4)~(9)式に示したレスラー結合系モデルより得る。具体的な手順として、レスラー結合系モデルを4次のルンゲクッタ法によって数値的に解き、その解曲線を得る。ここで、初期値自体の影響を減らすために初期値は10セットを用いて行い、その平均をとった。求められた解を100[Hz]でリサンプリングし、解の中から $x_1, x_2$ の2つを時系列信号として使用した。また、結合強度 $A$ の値を変えることで、同期の程度の異なる時系列ペア $x_1(t), x_2(t)$ を生成した。

### 2.2 Phase Lag Index 解析

Phase Lag Index (PLI) は、2つの時系列信号間の瞬時位相の分布の非対称性から機能的結合を評価する、信号間の同期を調べるための指標である<sup>5)</sup>。

まず、位相成分の差を調べるために、2つの信号間の瞬時位相の差を求める。2つの信号における同時刻での観測された信号の位相をそれぞれ $\phi_x, \phi_y$ とすると、2つの信号の位相差は、

$$\Delta\phi(t) = |\phi_x(t) - \phi_y(t)| \quad (10)$$

と表せる。2つの信号の時系列に対し、ヒルベルト変換を用いて瞬時位相と振幅を求める。瞬時位相の時系列を求めると、

$$\phi(t_k), k = 1 \cdots N \quad (11)$$

となる。ここで、 $N$ はサンプル数、 $t_k$ は離散時間ステップを表している。

この瞬時位相の時系列を用いて、PLIは以下の式で得

られる。

$$PLI = |\langle \text{sign}(\Delta\phi_{\text{rel}}(t)) \rangle| = \left| \frac{1}{N} \sum_{n=1}^N \text{sign}(\Delta\phi_{\text{rel}}(t_k)) \right| \quad (12)$$

なお,  $\text{sign}$  は signum 関数であり, 以下のように定義される。

$$\text{sign}x = \begin{cases} 1 & : x > 0 \\ 0 & : x = 0 \\ -1 & : x < 0 \end{cases} \quad (13)$$

ここで, 位相差  $\Delta\phi(t)$  は,

$$\Delta\phi(t) = \Delta\phi_{\text{rel}}(t) \bmod 2\pi \quad (14)$$

となる。そのため,  $\Delta\phi(t)$  は位相に同期性がない場合は 0 から  $2\pi$  に一様に分布することから 0 に近い値をとる。また, 位相がある値を中心に分布するような偏りのある分布を示した場合は 1 に近い値をとる。このことより, PLI の値の範囲は  $0 \leq \text{PLI} \leq 1$  となる。PLI = 0 に近いほど同期が低い, つまり結合があまりないことを示し, PLI = 1 に近いほど同期が高い, つまり結合が大きいことを示している。

ここで, 1 つの信号源から発生した脳波が複数の電極で同時に記録された場合に, その脳波が同期しているように見えてしまうボリュームコンダクションの影響を取り除くために, PLI では位相差が 0, もしくは  $\pi$  の場合を除いている。このことにより, PLI はボリュームコンダクションの影響を受けにくいという特徴を持つ<sup>5)</sup>。

本研究では, 2 つの時系列信号に対し, それぞれ 5[sec] ごとのエポックに区切って PLI を求め平均化し, PLI の値とした。

### 2.3 Transfer Entropy 解析

本研究では, 2 つの時系列信号間の情報の流れや因果性を調べるために Transfer Entropy (TE) を用いる。TE は Schreiber らによって考案された, 情報理論における相互情報量, つまり 2 つの確率変数間の相互の依存度を表す値を一方への因果性を表す量へ拡張したものである<sup>5, 15)</sup>。

#### 2.3.1 Transfer Entropy

相互情報量を一方の因果性を表す値へ拡張するために Transfer Entropy (TE) を導入する。2 つの時系列  $x(t)$  と  $y(t)$  がマルコフ過程で近似できると仮定して, (15) 式に示す一般化されたマルコフ条件からの偏差を計算する因果関係の尺度が Schreiber らにより提案された<sup>10)</sup>。

$$p(y_{t+1} | \mathbf{y}_t^n, \mathbf{x}_t^m) = p(y_{t+1} | \mathbf{y}_t^n) \quad (15)$$

ここで,  $\mathbf{x}_t^m = (x_t, x_{t+1}, \dots, x_{t-m+1})$  および  $\mathbf{y}_t^n = (y_t, y_{t+1}, \dots, y_{t-n+1})$  はそれぞれ,  $m$  次と  $n$  次のマルコフ過程である。

(15) 式の右辺は,  $n$  ステップ前までの履歴が与えられたときに  $y_{t+1}$  の値を得る確率を示している。また, 左辺は,  $x(t)$  と  $y(t)$  の両方の履歴がある場合に  $y_{t+1}$  の値を得る確率を示している。この考え方は, 因果性を検証

する代表的な手法の 1 つである Granger Causality と概念的には非常に似たものである<sup>16)</sup>。しかし, TE は線形・非線形に関わらず事前にかなる種類の依存性も想定しておらず, ノンパラメトリックであるという利点があり, この点で Granger Causality と異なる。しかし, TE ではデータから確率を推定する必要があるため, 確率分布を求めるための非常に長い時系列を必要とするなど, デメリットもある。

(15) 式の等号が成り立つのは,  $y$  の遷移確率 (ダイナミクス) が  $x$  の過去から独立している場合, つまり  $x$  から  $y$  への因果関係がない場合である。

$x$  と  $y$  間の因果関係の存在を測定するために,  $x$  から  $y$  への TE を以下のように定義する。

$$T_{X \rightarrow Y} = \sum_{y_{t+1}, \mathbf{y}_t^n, \mathbf{x}_t^m} P(y_{t+1}, \mathbf{y}_t^n, \mathbf{x}_t^m) \log \frac{p(y_{t+1} | \mathbf{y}_t^n, \mathbf{x}_t^m)}{p(y_{t+1} | \mathbf{y}_t^n)} \quad (16)$$

これは,  $x$  から  $y$  への有向の情報の流れを定量化したものである。この定義に基づいて, 時系列  $x_t$  から  $y_t$  への TE は次のように記述できる。

$$T_{X \rightarrow Y} = \sum_{y_{t+u}, \mathbf{y}_t^{d_y}, \mathbf{x}_t^{d_x}} P(y_{t+u}, \mathbf{y}_t^{d_y}, \mathbf{x}_t^{d_x}) \log \frac{p(y_{t+u} | \mathbf{y}_t^{d_y}, \mathbf{x}_t^{d_x})}{p(y_{t+u} | \mathbf{y}_t^{d_y})} \quad (17)$$

ここで,  $t$  は離散値の時間インデックス,  $u$  は予測時間, つまり離散値の時間間隔を示している。さらに,  $\mathbf{y}_t^{d_y}$  および  $\mathbf{x}_t^{d_x}$  は以下に示すような,  $d_y, d_x$  次元の遅延ベクトルである。

$$\begin{aligned} \mathbf{x}_t^{d_x} &= (x(t), x(t-\tau), \dots, x(t-(d_x-1)\tau)) \\ \mathbf{y}_t^{d_y} &= (y(t), y(t-\tau), \dots, y(t-(d_y-1)\tau)) \end{aligned} \quad (18)$$

TE の範囲は,  $0 \leq T_{X \rightarrow Y} \leq \infty$  である。  $T_{X \rightarrow Y} = 0$  の時は  $x$  と  $y$  の間に因果関係がないことを示している。また,  $T_{X \rightarrow Y}$  が 0 より大きい値をとるとき,  $x$  が  $y$  を引き起こしていることを示している。

ここで, TE は本質的に非対称であり, 遷移確率に基づいているため, 方向の情報と動的な情報が組み込まれている。TE を使う大きなメリットは, 対象となる 2 つのシステム間の相互作用についての特定のモデルを想定していないことである。これは, 未知の非線形相互作用の検出が必要な場合に特に役に立つ<sup>17)</sup>。

本研究では, 埋め込み遅延  $\tau$ , 埋め込みベクトル  $d_x = d_y = d$  はそれぞれパラメータとして与えた。  $\tau = 11$ ,  $d = 5$  とし, 2 つの時系列間の TE を求めた。

### 2.4 相関係数

本研究では, 2 つの時系列信号の同期の度合いを調べるために, 線形相関係数であるピアソンの相関係数を使用した<sup>18)</sup>。  $\bar{X}_a = \sum_{i=1}^n (X_{a,i})/n$  および  $\bar{Y}_b = \sum_{i=1}^n (X_{b,i})/n$  という平均をもつ行列  $X$  の列  $X_a$  予備行列  $Y$  の列  $Y_b$  について, ピアソンの相関係数  $\rho(a, b)$  は

以下のように定義される。

$$\rho(a, b) = \frac{\sum_{i=1}^n (X_{a,i} - \bar{X}_a)(Y_{b,i} - \bar{Y}_b)}{\sqrt{\sum_{i=1}^n (X_{a,i} - \bar{X}_a)^2} \sqrt{\sum_{i=1}^n (Y_{b,i} - \bar{Y}_b)^2}} \quad (19)$$

ここで、 $n$  は各列の長さを表し、相関係数  $\rho$  の範囲は  $-1 < \rho < 1$  である。また、 $\rho = -1$  は完全な負の相関を、 $\rho = +1$  は完全な正の相関を示す。 $\rho = 0$  は列の間に相関がないことを示す。

### 3 結果

本研究では、PLI, TE が時系列間の同期の程度によってどのように値が変化するかを調べる。そのために、同期の程度の違う時系列を用意する。同期の程度を調整できるモデルとして、レスラー結合モデルを用いた。具体的には、(4)~(9) 式のレスラー結合系モデルを数値的に解き、得られた解の  $x_1$  と  $x_2$  を時系列ペアとして用いた。微分方程式の時系列ペアに対し、微分方程式の時間の次元を秒とおき、全部で 500 秒分の最初の 10 秒間を取り除いた 490 秒分を使用した。時系列ペアに対しては、0.5~4.0[Hz] でのバンドパス処理を行った。

時系列について、同期の程度の調整は、結合パラメータ  $A$  の値を変えることで行う。 $A$  の値を変えることで同期の程度の異なる具体的な例として、 $A$  の値別に 3 つの時系列を Fig.4 に示した。(同期の程度が小・中・大の例として、 $A = 0$ ,  $A = 0.015$ ,  $A = 0.1$  をそれぞれ示す。)

これらの時系列ペアに対し、PLI と TE とを用いて同期の程度の評価を行った。このとき、PLI は時系列を 5 秒ごとの 98 エポックに分割し、それらの平均を求め、TE は時系列全体を使って求めた。この違いは PLI は瞬時位相の偏りを見るため、ある程度短い時系列を使用す

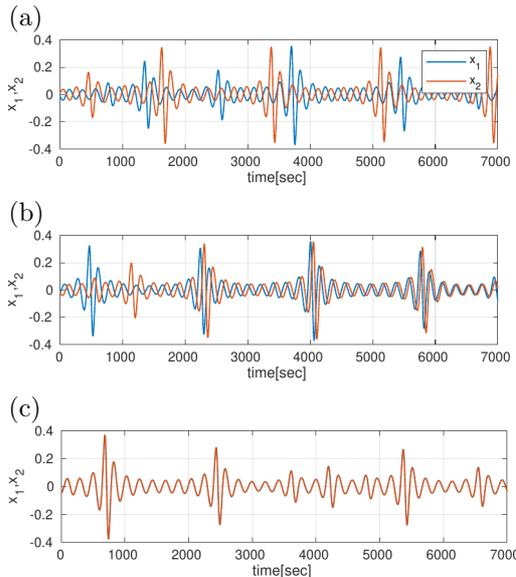


Fig. 4 レスラー結合モデルの各結合強度  $A$  における  $x_1, x_2$ . ( $\mu = 5.7$ ). (a) $A = 0$ , (b) $A = 0.015$ , (c) $A = 0.1$

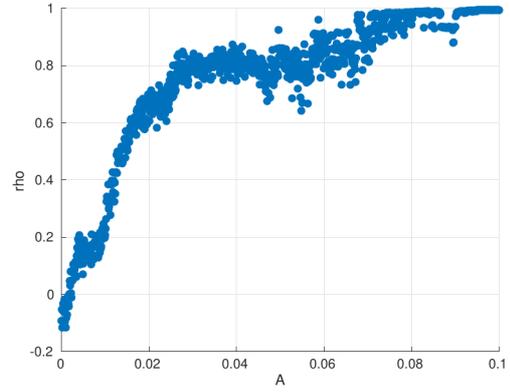


Fig. 5 結合パラメータ  $A$  と時系列間の相関係数  $\rho$  の関係。

る必要があるが、一方 TE は確率分布を構成するための長い時系列長が必要となるためである。

同期の程度の違う時系列ペア  $x_1(t), x_2(t)$  に対し PLI と TE の値を求めるために、 $A$  の値を幅  $\Delta A = 0.0001$  として 0 から 0.1 までの範囲で、合計 1001 個の  $A$  の値で時系列のペア  $x_1(t), x_2(t)$  を用意した。そして、それぞれの時系列間で相関係数を求めた。Fig.5 は結合パラメータ  $A$  の値と、その  $A$  で得られた時系列ペア  $x_1(t), x_2(t)$  の相関係数  $\rho$  の関係を表している。Fig.5 より、 $A$  に対して単調に  $\rho$  が増加し  $A = 0.07$  付近で  $\rho = 1$  に収束する関係であることがわかる。特に、 $A=0.07$  付近で  $\rho$  の値は 1 になる、つまり完全同期になっている。このことについて、Fig.5 の (c) において  $x_1, x_2$  の時系列が完全に重なっていることから、完全同期になっていることがわかる。

PLI, TE のそれぞれの結合パラメータ  $A$  に対する依存性を表したものが Fig.6 である。PLI の場合  $A \lesssim 0.07$  の範囲で、TE の場合  $A \lesssim 0.05$  の範囲で、PLI  $\approx 0.6$ , TE  $\approx 0.3$  付近の値を保持する。一方、PLI の場合  $A \gtrsim 0.07$ , TE の場合  $A \gtrsim 0.05$  では、両指標とも単調に減少した。

Fig.7 は TE と PLI の関係を散布図に示したものである。散布図におけるポイントは、ある  $A$  の値における時系列ペア  $x_1(t), x_2(t)$  に対して求めた PLI と TE の値を示している。Fig.7 からは、TE と PLI が TE  $\lesssim 0.12$ , PLI  $\lesssim 0.60$  までは線形関係にあるが TE  $\gtrsim 0.12$ , PLI  $\gtrsim 0.60$  から非線形な関係であることが読み取れる。

### 4 考察

本研究では、機能的結合の評価の指標である、瞬時位相差に着目した PLI と、時系列間の因果性に着目した TE の比較をした。比較のために、カオス振動子であるレスラー結合系モデルの時系列を用いて、時系列間の同期の程度の違いにおける PLI と TE の値の関係性を調べた。その結果、TE と PLI の間には、非線形の関係があることがわかった。

まず、結合強度パラメータ  $A$  と PLI, または TE の関係について考察する。両指標とも結合強度の値が小さい領域では高い値を保持し、ある一定値から単調に減少する傾向が見られた。結合強度の増加に伴う PLI の減少の理由としては PLI の性質によるものが考えられ

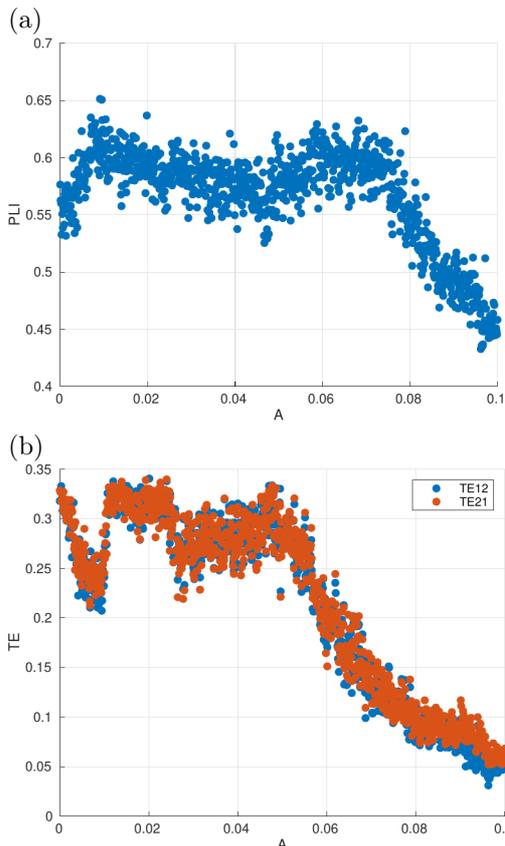


Fig. 6 結合強度  $A$  に対する依存性. (a) PLI の結合強度  $A$  に対する依存性. (b) TE の結合強度  $A$  に対する依存性.

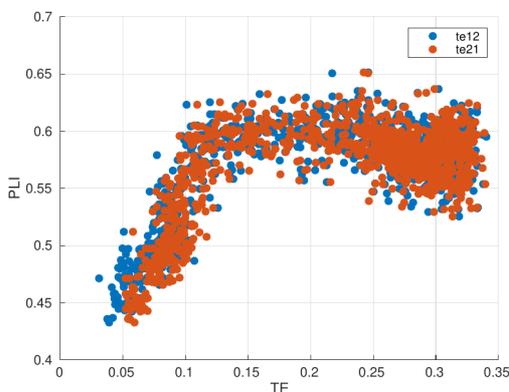


Fig. 7 TE と PLI の関係.

る. PLI は結合の大きさを示す指標であるが, 位相差の分布が  $0$  または  $\pi$  付近となる場合に PLI の値が小さくなるという性質がある. これは, 脳波の解析においてボリュームコンダクションの影響により, PLI が 1 つの信号源から発生した脳波が複数の電極で同時に記録された場合にその脳波が同期しているように見えてしまうことを避けるためである<sup>5)</sup>. そのため, 結合強度の高い領域では 2 つの時系列が完全同期の形となり, それに伴って PLI の値は減少した (Fig.6 を参照). このことは, 結合パラメータ  $A$  と時系列間の相関係数  $\rho$  の関係と, PLI と結合強度に対する  $A$  の関係より, 相関係数がほぼ 1 となる  $A$  の値と PLI の値が下がり始める  $A$  の値が同じこ

とからも考えられる (Fig.5 と 6 を参照). また, TE の減少の理由としては,  $A$  の値の高い領域では情報の流れの量が減少したためと考えられる. 結合強度の高い領域では時系列同士がほぼ同じ形の時系列になる (Fig.4 を参照). TE は情報の流れの量から結合を推定するものであるため, 完全同期に近い  $A$  の値の高い領域では情報の流れが減少し, TE が減少する理由になった.

次に, TE と PLI の関係について考察する. 小さな TE の値領域では PLI と TE は線形関係にあるが, ある TE 値以上では PLI は TE の変化に対して一定値に収束する様子が確認された. このような, TE の変化に対し PLI が変化しない関係となった要因としては, PLI の特性によるものが考えられる. PLI では位相平面上の正負の偏りを評価しているが, それには位相差を 1, 0, -1 に離散化する操作が含まれている. このことより, PLI の評価では位相差の大きさの情報が失われており, そのことが PLI の値に影響したと考えられる. 一方, TE には時系列の離散処理は含まれず, そのような状況下においても, 天井効果は現れにくいと考えられる. 一方, 短い時系列間の評価においては, TE はその条件付き確率の推定過程において, 長い時系列長を必要とする. しかし, PLI においてはその優れた時間分解能によって, 比較的短い時系列で評価が可能である.

しかし, 本研究では, TE と PLI の関係性についてはわかったが, その理由まで完全に特定できたわけではない. 本研究の今後の課題として, 位相差の大きさによって重み付けをして PLI を評価する Weighted Phase Lag Index (WPLI) を用いて更に比較する必要がある<sup>19)</sup>.

## 5 結論

本研究では, 脳の機能的結合を推定する指標として使われている PLI と TE の関係性の分析を行った. レスラー結合系によるカオス振動子のモデルを使用して推定を行う時系列信号のペア  $x_1(t)$ ,  $x_2(t)$  を生成し, その時系列信号間の結合の強さに対する PLI と TE の値の変化, また PLI と TE の関係について調べた. 今回の結果により, PLI と TE は単純な相関関係でなく, 結合強度に応じて相補的な関係があることがわかった.

脳の機能的結合を調べる研究においては, 結合を分析するために, 複数の指標を用いて様々な側面からの推定を行う. 従来から用いてきた PLI をはじめとする他の指標と TE を組み合わせて使うことで, 機能的結合による脳の特徴をより詳しく分析できるようになる可能性がある. また, 機能的結合に異常があることが分かっている統合失調症やアルツハイマー病などといった疾患の脳波の解析において活用できる可能性がある. ほかに, 機能的結合の評価の応用例として, 脳機能が精神疾患等の病態を評価するバイオマーカーとしての活用や, 機械学習への応用が今後期待できる<sup>4)</sup>.

## 参考文献

- 1) Ying Liu and Selin Aviyente: Directed information measure for quantifying the information flow in the brain, In *2009 Annual International Conference of the IEEE Engineering in Medicine and*

- Biology Society*, 2188/2191 (2009)
- 2) Tetsuya Takahashi, Takashi Goto, Sou Nobukawa, Yuji Tanaka, Mitsuru Kikuchi, Masato Higashima and Yuji Wada: Abnormal functional connectivity of high-frequency rhythms in drug-naïve schizophrenia, *Clinical Neurophysiology*, **129-1**, 222/231 (2018)
  - 3) Marjolein MA Engels, Cornelis J Stam, Wiesje M van der Flier, Philip Scheltens, Hanneke de Waal and Elisabeth CW van Straaten: Declining functional connectivity and changing hub locations in Alzheimer's disease: an EEG study, *BMC neurology*, **15-1**, 145 (2015)
  - 4) Sou Nobukawa, Teruya Yamanishi, Shinya Kasakawa, Haruhiko Nishimura, Mitsuru Kikuchi and Tetsuya Takahashi: Classification Methods Based on Complexity and Synchronization of Electroencephalography Signals in Alzheimer's Disease, *Frontiers in Psychiatry*, **11** (2020)
  - 5) Cornelis J Stam, Guido Nolte and Andreas Daffertshofer: Phase lag index: assessment of functional connectivity from multi channel EEG and MEG with diminished bias from common sources, *Human brain mapping*, **28-11**, 1178/1193 (2007)
  - 6) Luis R Peraza, Aziz UR Asghar, Gary Green and David M Halliday: Volume conduction effects in brain network inference from electroencephalographic recordings using phase lag index, *Journal of neuroscience methods*, **207-2**, 189/199 (2012)
  - 7) Kamil Jonak, Paweł Krukow, Katarzyna E Jonak, Cezary Grochowski and Hanna Karakuła-Juchnowicz: Quantitative and qualitative comparison of EEG-based neural network organization in two schizophrenia groups differing in the duration of illness and disease burden: graph analysis with application of the minimum spanning tree, *Clinical EEG and neuroscience*, **50-4**, 231/241 (2019)
  - 8) Elzbieta Olejarczyk and Wojciech Jernajczyk: Graph-based analysis of brain connectivity in schizophrenia, *PLoS One*, **12-11**, e0188629 (2017)
  - 9) Sou Nobukawa, Mitsuru Kikuchi and Tetsuya Takahashi: Changes in functional connectivity dynamics with aging: A dynamical phase synchronization approach, *Neuroimage*, **188**, 357/368 (2019)
  - 10) Thomas Schreiber: Measuring information transfer, *Physical review letters*, **85-2**, 461 (2000)
  - 11) Meenakshi Dauwan, Edwin Van Dellen, Lotte van Boxtel, Elisabeth CW van Straaten, Hanneke de Waal, Afina W Lemstra, Alida A Gouw, Wiesje M van der Flier, Philip Scheltens, Iris E Sommer et al.: EEG-directed connectivity from posterior brain regions is decreased in dementia with Lewy bodies: a comparison with Alzheimer's disease and controls, *Neurobiology of aging*, **41**, 122/129 (2016)
  - 12) Wenpo Yao and Jun Wang: Networked information interactions of epileptic EEG based on symbolic transfer entropy, *BioRxiv*, 543496 (2019)
  - 13) Jun Lian, Jianwei Shuai and Dominique M Durand: Control of phase synchronization of neuronal activity in the rat hippocampus, *Journal of neural engineering*, **1-1**, 46 (2004)
  - 14) Otto E Rössler: An equation for continuous chaos, *Physics Letters A*, **57-5**, 397/398 (1976)
  - 15) Katsunori Kitano: Transfer entropy を用いた神経回路の解析, *Annual Review 神経*, **2017**, 1/5 (2017)
  - 16) Clive WJ Granger: Investigating causal relations by econometric models and cross-spectral methods, *Econometrica: journal of the Econometric Society*, 424/438 (1969)
  - 17) Raul Vicente, Michael Wibral, Michael Lindner and Gordon Pipa: Transfer entropy—a model-free measure of effective connectivity for the neurosciences, *Journal of computational neuroscience*, **30-1**, 45/67 (2011)
  - 18) MathWorks 日本: 線形相関または順位相関 MATLAB corr, <https://jp.mathworks.com/help/stats/corr.html> (2020年12月22日現在)
  - 19) Martin Vinck, Robert Oostenveld, Marijn Van Wingerden, Francesco Battaglia and Cyriel MA Pennartz: An improved index of phase-synchronization for electrophysiological data in the presence of volume-conduction, noise and sample-size bias, *Neuroimage*, **55-4**, 1548/1565 (2011)

# 走行シーン認知における運転経験と事象関連電位 P300 の評価

端名陸, 前田純之介, 山本昂汰(中部大学), 信川 創(千葉工業大学),

我妻伸彦(東邦大学), ○稲垣圭一郎(中部大学)

## Evaluation of Driving Experience and Event Related Potential P300 in Cognition of Driving Scenes

R. Hatana, J. Maeda, K. Yamamoto (Chubu University),

S. Nobukawa (Chiba Institute of Technology), N. Wagatsuma (Toho University),

\*K. Inagaki (Chubu University)

**Abstract**—The number of traffic accidents is gradually decreased due to the remarkable development of ITS technologies. The accidents related to visual cognition, however, are still occurred frequently especially in beginner drivers. For the cognition of traffic scenes, the scene is scanned and understood using eye movements which are adequately controlled by the attention process. In the present study, we focused on the attention related event-related potential, P300, and investigate its response characteristics for beginner and expert drivers.

### 1 はじめに

近年, AI 技術の目覚ましい発展も相まって ITS 技術の高度化と普及が進んでいる. 国土交通省の統計報告によると, 交通事故発生総数はここ数年減少傾向が続いている<sup>1)</sup>. こうした交通事故の減少傾向が続く今日においても, 認知ミスや誤運転などのヒューマンエラーによる交通事故の発生件数は, 依然として減少が鈍化している. こうしたヒトに起因する事故要因に着目すると, 安全不確認, わき見運転, 動静不注意といった視覚認知を伴う項目が上位 3 位までを占めており, かつ大半の交通事故がこれらによるものと分析されている. 一方で, 同報告において, 視覚認知が伴う交通事故発生総数を, 運転経験をもとに見てみると, 免許取得後の経験の少ないドライバよりも運転経験を重ねたドライバは, 引き起こす事故件数が約半減することが示されている<sup>2)</sup>. これらから, 運転経験が運転時における視覚認知行動を改善または最適化していることが予想される. こうした, 運転経験と視覚認知に絡む脳情報処理の理解は, 得られる情報をフィードバックすることでヒューマンエラーに絡む交通事故を低減させことにつながるものと考えられている.

従来, 運転行動を対象とした脳波計測を伴う研究は, 運転操作に係るもの<sup>3-5)</sup>, 運転時の外乱や疲れの影響<sup>6-11)</sup>を評価したもの, 感情の状態<sup>12)</sup>を評価したもの, 視覚認知を対象としたものなど<sup>13, 14)</sup>, 数多く行われている. 運転操作に係る報告では, 池西らが, ドライバの操作技術やレーン認知行動を対象に脳波計測を実施し, ステアリング操作や加減速といった操舵意図と脳活動領域の関係性を明らかにしている<sup>3-5)</sup>. 運転時の外乱の影響を評価したものは, 音や視覚的な外乱の影響が右前頭前皮質に強く出ること<sup>6-8)</sup>, 認知制御への影響が事象関連電位 P300 の下位成分である P3b に確認されること<sup>9)</sup>, 外乱の影響そのものや外乱によって生じる疲れを脳波やその機能的結合から検出する方法<sup>10, 11)</sup>が報告されている. また, 運転時の感情の状態を評価したものは,  $\theta$  波と  $\alpha$  波の活動パターンから運転技能向上に絡む感情のフロー状態を推定できることが報告されている<sup>12)</sup>. 視覚認知を対象としたものでは, 運転経験により脳波の  $\alpha$  波および  $\beta$  波の賦活パターンに影響すること<sup>13)</sup>や  $\gamma$  波帯域に関する

機能的結合強度が変化すること<sup>14)</sup>が報告されている. こうした研究が進むなかで, 走行シーンの認知において最も重要とされる視覚的な注意については, シーンに対する有効視野や視線分布などの報告(例えば<sup>15)</sup>)は多いものの, その根底をなす視覚的注意に関する脳活動など走行シーンの視覚認知情報処理に関しては, いまだに未解明な部分が多く存在する.

本研究では, 視覚認知過程で最も重要な情報処理である注意に着目し, 運転経験との関連性を脳波計測により評価することを目的とする. 特に, 計測対象の脳波として, 注意に深く関連すると考えられている事象関連電位 P300<sup>16, 17)</sup>に着目し, 運転経験によるその応答特性の変化を解析する.

### 2 実験方法

#### 2.1 被験者

走行シーンの認知課題における脳波は, 運転免許証を有しかつ正常脳波を呈する年齢19歳~24歳の男性20名から計測した. 本実験では, 運転頻度に応じて被験者を以下のように分類した. 週に頻繁に運転するものは熟練者, 週1回以下のほとんど運転しないものや免許取得後半年以下のものは, 初心者に分類した. その結果, 熟練者は10名, 初心者は10名であった.

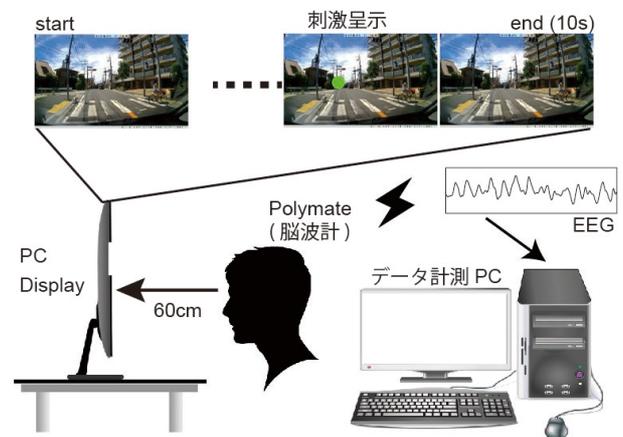


Fig.1 Experimental setup

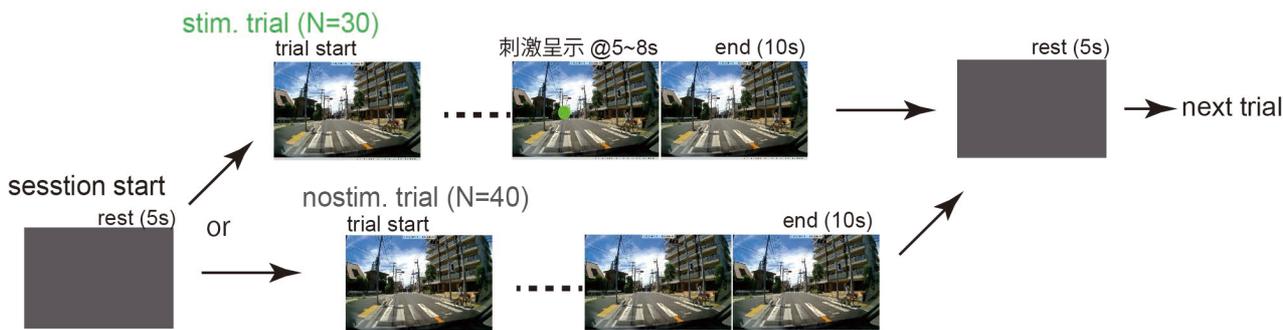


Fig.2 Experimental protocol. 10 sec driving scenes with visual stimulus (stim. trial, N=30) or without visual stimulus (no stim. trial, N=40) was randomly presented. 5 sec gray stationary image was presented when changing driving scene. The visual stimulus appeared at the center of left visual field in stim. trial. Subjects were supposed to count number of recognized visual stimulus and to report number of visual stimulus at the end of whole experimental sessions.

実験に際して、視力の低い被験者は免許証に記載の方法でこれを矯正した。また、事前アンケートにより体調不良を伴う場合や眠気を有するなど、正常とみなせない、または覚醒度が低い場合は実験参加を見合わせた。

## 2.2 実験セットアップ

走行シーンの認知課題に利用した実験環境をFig.1に示す。実験環境は、座席シート、顎台、刺激呈示用PCモニタ、脳波計、計測および刺激制御用計算機によって構成されている。刺激呈示用のPCモニタは、被験者が着座する座席シートから60cmの位置に設置した。このとき、被験者の視野角は約±30度であった。

## 2.3 認知刺激課題

Fig.2に、本実験で用いた走行シーンの認知課題の概要を示す。被験者にはビデオカムコーダによって撮影した車両前方の走行シーン(1920x1080pixel)を10秒視聴してもらう。呈示する走行シーンは、走行シーンの左視野中央(X=1600, Y=540)に、視野角1.25度に相当する緑色の認知刺激を50ミリ秒含むものと、こうした認知刺激呈示を含まないもので構成されている。なお、本実験において、認知刺激は走行シーン視聴開始後5秒~8秒の間のランダムなタイミングで呈示した。走行シーン動画の切り替わり時には、5秒間のグレー画像を呈示した。実験では、認知刺激を含むものを30シーン、刺激呈示のないものを40シーンの合計70シーンをランダムに呈示し、被験者に視聴させた。本研究では、被験者の注意をあらかじめ喚起するために、事前に特定の位置に認知刺激が呈示されることのみを教示し、それ以外は通常の運転と同様に走行シーンを視聴するように教示した。また、走行課題遂行時に、刺激を認知した場合は、その数をカウンタにより計測するように指示した。

## 2.4 脳波計測

脳波計測には、Polymate AP108(ミュキ技研)を用いた。被験者には、中部大学実験倫理委員会において承認された実験プロトコルを事前に説明し、インフォームドコンセントを得た。被験者には、刺激呈示用モニタから60cmの位置に着座してもらい、頭部動作によるノイ

ズを軽減させるため顎台にて頭部を固定した。このとき、実際の運転時と同様の視野となるように走行シーン呈示用のモニタ位置を調整した。電極配置に際して、頭皮上の油分による電極抵抗の増加を避けるために、事前にアルコールで油脂の除去を行ったのち、国際10-20法<sup>17)</sup>に基づいて、Czの位置に電極を配した。脳波は、サンプリング周波数500Hzにて計測した。

## 2.5 解析方法

一般に事象関連電位P300は、低頻度刺激と高頻度刺激で構成したオドボール課題において、低頻度刺激に対する数十回程度の脳波応答を加算平均することで求められる<sup>16), 17)</sup>。本研究では、認知刺激に対するP300の発生の有無を評価するため、この認知刺激を前述の低頻度刺激ととらえ、同様に加算平均処理をした。

はじめに、計測した脳波をサンプリング周波数500Hzで計算機に読み取る。P300は、1Hz~5Hzのδ帯域に出現することから、計測脳波に対してバンドパスフィルタ(1Hz ~5Hz)を適用する。その後、認知刺激呈示時刻に対して-200ミリ秒から800ミリ秒の範囲を切り出し、DC成分を除去する。認知刺激を呈示した際の脳波30トライアル分を同様に処理し、加算平均を求めた。ここで、瞬きや眼球運動、体動などによるアーティファクトを除外するため、前述の処理によって得られた切り出し区間の標準偏差を求め、±3SD以上の値を含む場合は加算平均処理から除外した。また、認知刺激に対するP300応答と比較するために、認知刺激を含まない走行シーンに対する応答を評価した。認知刺激を含まないシーンの各施行で計測された脳波に対して、切り出し時刻を走行シーン呈示後5~8秒の間となるように乱数で求め、その時刻から1秒間の脳波を用いて加算平均処理を行った。

P300の定義については諸説あるが、一般に刺激呈示後、250ミリ秒から600ミリ秒に陽性のピークを持つものとして定義される<sup>18)</sup>。本研究においても、認知刺激呈示後、250ミリ秒から600ミリ秒に陽性のピークを有するものをP300として定義した。

P300の特徴として、実験時の刺激への注意や興味の影響が頂点潜時や頂点振幅に現れることが知られている(例えば<sup>19)</sup>)。こうしたことから、本研究ではbaseline-peak法によってP300の頂点振幅を求めた。認知刺激呈示時刻前200ミリ秒間の平均振幅値をbaselineとし、

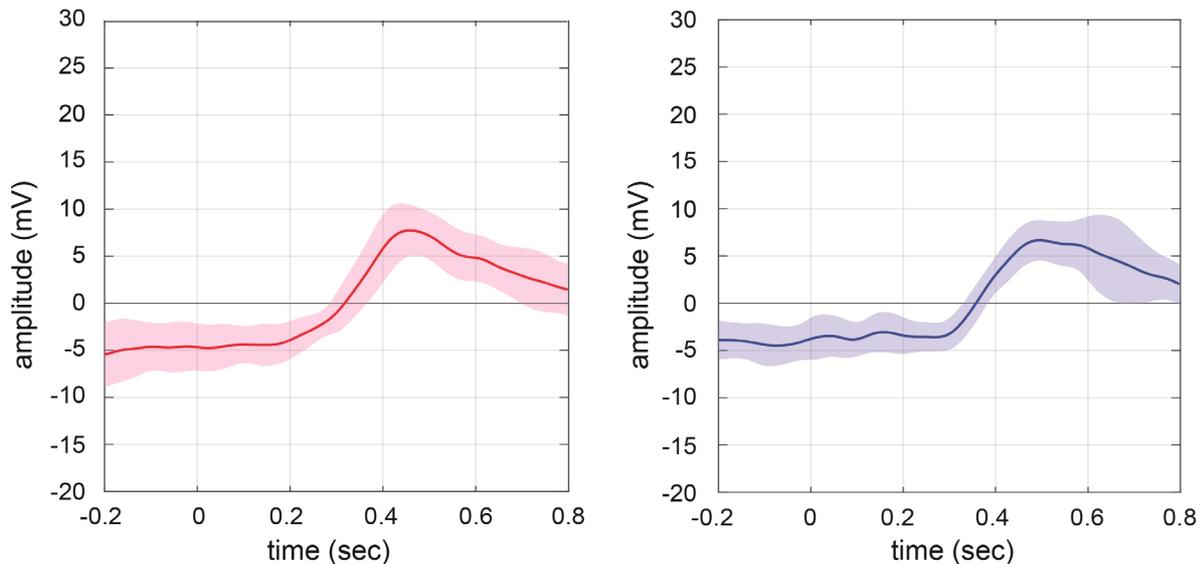


Fig.3 Grand average of event-related potential P300 for experts (left) and beginners (right). Solid line and pale colored area are average and  $\pm 1$  standard deviation.

P300とbaseline間の振幅をP300の頂点振幅として定義した。また、頂点潜時については、認知刺激呈示時刻からP300頂点発生時刻までの経過時間として定義した。

### 3 結果

#### 3.1 事象関連電位 P300 応答

本実験では、熟練者については10名中9名、初心者については10名中7名においてP300の出現が見られた。Fig.3にこれら熟練者と初心者のP300応答の総平均についてまとめる。熟練者ならびに初心者ともに、刺激呈示後300ミリ秒から500ミリ秒においてピークを持つP300が出現していることがわかる。一方で、図には示していないが、認知刺激を含まない走行シーンに対しては、熟練者、初心者ともにP300の出現は確認されなかった。

#### 3.2 刺激認知と P300 応答特性

次に、本実験における初心者と熟練者の走行シーン内に呈示した認知刺激の認知率とP300の頂点潜時ならびに頂点振幅について評価した。Table.1は、初心者と熟練者別の刺激の認知率、頂点潜時および頂点振幅をまとめたものである。

認知刺激の認知率については、初心者群で94.5%、熟練者群で96.5%であり、わずかに熟練者群で高い結果となったが、両被験者群ともに高い認知率となっている。次に、P300の頂点出現までの潜時については、初心者群で542ミリ秒、熟練者群で467ミリ秒であり、熟練者のほうが初心者よりもP300の頂点潜時が早くなる傾向がみられた。P300の頂点振幅については、初心者群で7.91mV、熟練者群で8.16mVであり、熟練者のほうが初心者よりもわずかに高値となる傾向が確認された。最後にP300の頂点潜時と頂点振幅についてWelchのt検定によって有意差の評価をした結果について述べる。P300の頂点潜時、頂点振幅ともに、有意差が認められなかった。

## 4 考察

本研究では、視覚認知過程で最も重要な情報処理である注意に着目し、注意に深く関連されると考えられている事象関連電位P300の応答特性に関して、初心者と熟練者を対象に走行シーン認知課題を用いて評価をした。結果では、初心者、熟練者ともにほとんどの被験者において、P300の出現が認められた。さらに、有意差は確認できなかったものの熟練者のほうが初心者よりもP300の頂点潜時が早くなる傾向が確認された。

従来の調査研究では、視覚認知が絡む交通事故発生件数は、運転経験の長いドライバーよりも、免許取得後間もないドライバーやペーパードライバー、運転頻度が低いドライバーに顕著であるという報告がある。また、近年の我々の研究において、走行シーン認知に関する運転経験の差が、脳波の賦活パターンに反映されることも明らかにされている<sup>12), 13)</sup>。こうした結果は、運転経験を積むことによって、走行シーンの認知に絡むヒト脳の情報処理が最適化されている可能性を裏付けているものと推測される。本実験では、初心者、熟練者ともに注意に関連すると考えられている事象関連電位P300の出現が確認された。今回、実験に際して初心者、熟練者ともに、認知刺激が特定の位置に出現することを強く教示している。こうした教示により、注意の空間分布が固定され、比較的高い注意意識に基づいて走行シーンの認知タスクを両被験者群ともに遂行していることが考えられる。結果として、熟練者、初心者ともに認知刺激の認知率が高くなっており、また、この高い注意意識により、P300の出現率も高くなったと考えることができる。このとき、P300の応答特性である潜時と頂点振幅についてみてみると、頂点振幅ではほぼ同じ値となるが、有意差がないものの潜時については、熟練者のほうが初心者よりも早くなる傾向が確認された。従来研究で、P300の頂点潜時や振幅は、注意対象への興味などを反映すると考えられている。本結果からは、運転経験によるP300の応答特性の差が頂点潜時により反映されており、今後より多くの被験者による実験結果の検証も要するが、

Table1. Perception rate for visual stimulus, latency and peak amplitude for P300 in beginners and experts

parameter	beginneers	experts
perception rate for visual stimuli (%)	94.5	96.5
latency (ms)	526±74	480±48
peak amplitude (mV)	7.91±2.29	8.16±2.39

運転経験による注意特性の差異が、P300 の頂点潜時に反映される可能性が示唆された。

次に、前述の P300 の頂点潜時の差異と運転経験について考察する。事象関連電位 P300 は、その下位成分である P3a と P3b に分類できることが知られている。一般に P300 の頂点潜時が早いものは P3a、遅いものは P3b に分類される<sup>20)</sup>。P3a と P3b はそれぞれ異なる情報を反映すると考えられている。P3a は注意をより強く反映し、P3b は対象とした課題への意識をより反映するものと報告されている<sup>16), 17)</sup>。本実験では、熟練者の P300 の頂点潜時が初心者に比べて早くなることが確認された。Fig.3 から明確に P3a と P3b を区別することは難しいが、先の P3a と P3b に関する潜時の違いを考慮すると、熟練者は、より注意を反映する P3a を多く含んでいる可能性が考えられる。一方で、初心者は、認知課題への意識集中が増した結果  $\beta$  や  $\gamma$  帯域が優位に増加するといった我々の従来研究<sup>13)</sup>にもあるように課題そのものに関連性の強い P3b を多く含む可能性が考えられる。熟練者は初心者に比べ P300 の潜時が早くなる本実験結果は、こうした違いを反映した可能性のあるものと考えられる。

## 5 まとめ

本研究では、視覚認知過程で最も重要な情報処理である注意に着目し、運転経験との関連性を脳波計測により評価した。注意に深く関与すると考えられている事象関連電位 P300 を対象に、運転熟練者と初心者で走行シーンに認知刺激を呈示する認知課題を遂行させたところ、P300 が熟練者、初心者を問わずほとんどの被験者で出現することを確認した。さらに P300 の応答特性である、頂点潜時ならびに頂点振幅を評価したところ、頂点潜時において有意差はないものの、熟練者と初心者の差異が確認された。さらに、こうした差異が、走行シーンの認知という課題への取り組み方やそれに絡む注意の持ち方による可能性が示唆された。今後は、より被験者を増やし、P300 脳波に反映されると考えられる前述の情報の違いについて検討を進める予定である。

## 参考文献

- 1) National Police Agency, "The occurrence of traffic accidents and the traffic violation control in 2017", 2017.
- 2) S. Wako: ITS: R & D and Perception as the Open Information and Telecommunications Infrastructure, Institute of Electronics, Information and Communication Engineers A, vol. J81-A-4, pp.465-466 (1998).

- 3) 池西 俊仁, 鎌田 崇義, 永井 正夫: PARAFAC によるレーンチェンジ時の脳波分析を用いた認知・判断状態の検出, 日本機械学会論文集 C 編, 81-823, pp.3461-3469 (2010).
- 4) 池西 俊仁, 鎌田 崇義: 脳内電流源推定手法を用いた前方車両に対するドライバの操舵意図推定, 日本機械学会論文集 C 編, 76-772, pp. 14-00390 (2015).
- 5) 池西 俊仁, 鎌田 崇義: 脳波を用いた前方車両追従時におけるドライバの加減速意図の推定手法の検討, 自動車技術会論文集, 48-5, pp.1127-1134 (2017).
- 6) C. Lin, S. Chen, L. Ko and Y. Wang: EEG-based brain dynamics of driving distraction., The 2011 International Joint Conference on Neural Networks, pp.1497-1500 (2011).
- 7) C. Lin, S. Chen, T. Chiu, H. Lin, L. Ko: Spatial and temporal EEG dynamics of dual-task driving performance, J. Neuroeng. Rehabil., 8-11 (2011).
- 8) H. Almahasneh, W. Chooi, N. Kamel, A.S. Malik: Deep in thought while driving: An EEG study on drivers' cognitive distraction., Transportation Research Part F: Traffic Psychology and Behaviour, 26-A, pp.218-226 (2014).
- 9) M. Karthaus, E. Wascher, S. Getzmann: Effects of visual and acoustic distraction on driving behavior and EEG in young and older car drivers: A driving simulation study," Frontiers in Aging Neuroscience, 10-420 (2018).
- 10) G. Bajwa, M. Fazeen, R. Dantu: Detecting driver distraction using stimuli-response EEG analysis, arXiv, 1904.09100v1, (2019).
- 11) H. Wang, X. Liu, J. Li, T. Xu, A. Bezerianos, Y. Sun, F. Wan: Driving fatigue recognition with functional connectivity based on phase synchronization, IEEE Transactions on Cognitive and Developmental Systems, (2020).
- 12) 川崎真弘, 甲斐田幸佐, 岸浩司, 渡部生聖, 山田整, 山口陽子: シータ波とアルファ波を用いた運転技能の向上に伴う喜びと満足度の推定, 人間工学, 46-5, pp.307-316 (2010).
- 13) K. Inagaki, T. Maruno, K. Yamamoto: Evaluation of EEG activation pattern on the experience of visual perception in the driving, IEICE Trans. on Info. & Sys., vol.E103-D-9, pp.2032-2034 (2020).
- 14) S. Nobukawa, N. Wagatsuma, K. Inagaki: Gamma band functional connectivity enhanced by driving experience, IEEE explore, IEEE Lifetech 2021, (2021).
- 15) K. Sato: Visual search and peripheral vision performance by novice and experienced drivers, IATSS Review, 19 pp.191-199 (1993).
- 16) D. Friedman, Y.M. Cycowicz, H. Gaeta: The novelty P3: an event-related brain potential (ERP) sign of the brain's evaluation of novelty, Neuroscience & Biobehavioral Reviews, 25-4, pp.355-373 (2001).
- 17) J. Polich: Updating P300: An Integrative Theory of P3a and P3b, Clin. Neurophysiol. 118-10, pp. 2128-2148 (2007).
- 18) H. H. Jasper: The ten twenty electrode system of the international federation, Electroencephalography and Clinical Neurophysiology, 10, pp.371-375 (1958).
- 19) 加賀佳美, 相原正男: P300 基礎, 臨床神経生理学, 41-2, pp.80-85 (2013).
- 20) 田中元志, 本間智大, 井上浩, 新山喜嗣, 高橋徹, 熊谷昌則, 秋山美展: 食品の好み評価時の事象関連電位に関する実験的検討, 電学論 C, 131-1, pp.96-101, (2010).

# 時系列予測に基づく行動決定のための 大脳新皮質学習に関する基礎検討

○藤野和志 青木健 高玉圭樹 佐藤寛之 (電気通信大学)

## A Preliminary Study on Cortical Learning Algorithm for Action Decision Using Forecast

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

**Abstract**— We propose an action decision method based on the cortical learning algorithm, which is a time-series forecast algorithm. The proposed method is composed of two CLA predictors. The first predictor is for the state, which is the input. The second predictor is for the action prediction, which is the output. The proposed method involves interaction between the two CLA predictors. The interaction called feedback utilizes the action data in the second predictor for the state prediction in the first predictor. The feedback emphasizes the state prediction and helps the state prediction, especially when the state input from the environment is missed due to the environmental uncertainty. Also, the proposed method enhances the learning not only from the actual data of input state and output action but also from the artificially generated data of them. Experimental results using the continuous mountain car task in an uncertain environment show the proposed method achieves higher goal achievement than conventional methods using the deep deterministic policy gradient and the long short-term memory.

**Key Words:** Time series forecast, Action decision

### 1 はじめに

人の予測や意思決定は、大脳新皮質によって実現されると考えられている。大脳新皮質学習アルゴリズム (Cortical Learning Algorithm, 以下 CLA) は、大脳新皮質の構造をコンピュータ上で模倣した時系列予測法である<sup>1)</sup>。CLA を発展させることで、大脳新皮質が担う意思決定の実現も期待される<sup>2)</sup>。本稿では、時系列予測する従来の CLA を、時系列予測と行動決定する方法へ発展させる。従来の行動決定法には、Deep Q Network (DQN)<sup>3)</sup> や Deep Deterministic Policy Gradient (DDPG)<sup>4)</sup> などの強化学習アルゴリズムがある。これらは、一部のタスクにおいて、人間レベルの性能を発揮できる<sup>3)</sup>。行動決定法は、今後、自動運転やロボット制御などの実世界のタスクに利用されることが期待されている。しかし、行動決定する従来の強化学習アルゴリズムは、環境から状態を適切に観測できることを前提としており、実世界で生じる状態の観測ノイズや欠損への対処に難しさがある。状態の観測におけるノイズや欠損に対処するため、状態の起こりやすさを信念値として算出し、適した行動を選択する方法が検討されているが<sup>7)</sup>、膨大な計算コストを要するところに問題がある。また、信念値を考慮しない DQN や DDPG などの強化学習アルゴリズムでは、この手段をそのまま利用できない。

本稿では、環境から得られるはずの状態に欠損が生じる環境においてロバストに行動決定することを目的とし、CLA を基礎として、入力値である状態を予測値で補完する方法を提案する。提案法は、状態を予測する CLA の予測器と、行動を予測する CLA の予測器を接続する。二つの予測器の間には、相互関係を構築する。提案法には、既存の強化学習アルゴリズムの行動を模倣させる。提案する模倣 CLA は、環境から観測する状態の文脈と、模倣対象の強化学習アルゴリズムが出力する行動の文脈を結び付けることで行動の模倣を

可能にする。提案する模倣 CLA の効果は、環境から得られる状態が欠損する連続マウンテンカー問題を用いて検証する。

### 2 大脳新皮質学習アルゴリズム (CLA)

#### 2.1 方法

CLA の予測器を Fig. 1 に示す。予測器は、セル、カラム、リージョン、シナプスによって構成される。

CLA の予測器は、ビット列の入力データを受け取る。各入力データビットとカラムの間には、シナプスを設ける。各シナプスには、永続値がある。永続値が閾値以上するとき、シナプスは接続状態になる。永続値が閾値未満のとき、シナプスは切断状態になる。Fig. 1 では、接続状態のシナプスを実線、切断状態のシナプスを破線で示す。各カラムには、通常と活性の2状態がある。1の入力データビットと接続状態にあるシナプスを一定数以上有するカラムを活性状態にする。これによって、各時点の入力データビット列を CLA の内部表現にする。活性状態になったカラムについて、1の入力データビットに配置されたシナプスの永続値を増加させ、0の入力データビットに配置されたシナプスの永

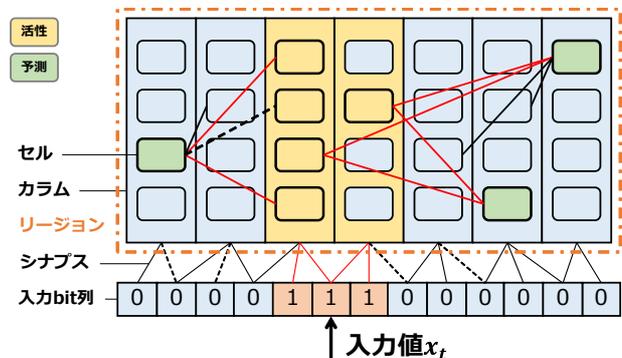


Fig. 1: CLA の予測器

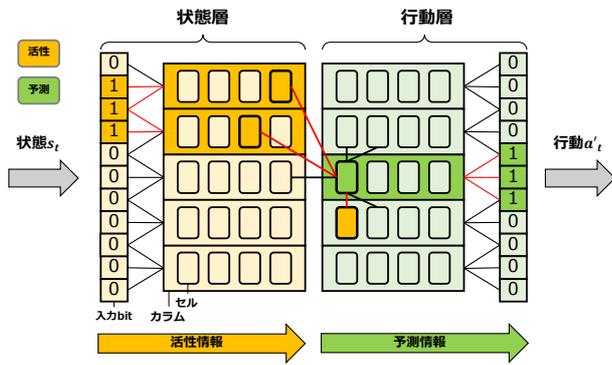


Fig. 2: 模倣 CLA の予測器

続値を減少させる。この処理を空間プーリングという。

セルには、通常、活性、予測の3状態がある。活性状態のカラムにおいて、予測状態のセルを活性状態にする。前時点において、このセルを予測状態にした活性状態のセルとのシナプスの永続値を増加させ、通常状態のセルとのシナプスの永続値を減少させる。活性状態のカラムに予測状態のセルが存在しなければ、すべてのセルを活性状態にする。活性状態のセルによって、入力データの文脈を内部表現する。次に、活性状態のセルと接続状態のシナプスを一定数以上有するセルを予測状態にする。予測状態のセルによって、次時点の入力データを内部表現する。この処理を時間プーリングという。

従来のCLAは、各時点の入力データから次時点の入力データを予測する。入力データが欠損しても、CLAは、前時点で予測した入力データを仮に入力することで予測を維持できる。環境から得られる状態を入力データとすると、CLAなら、状態が欠損しても予測を維持できる。CLAに行動決定する仕組みを導入できれば、DQNやDDPGなどの強化学習アルゴリズムより、状態が欠損するタスクに対応しやすい。

## 2.2 行動決定法への課題

従来のCLAは、時系列予測法であり、行動決定する仕組みを持たない。また、従来のCLAが予測するデータは、入力データと同じ意味のデータになる。入力データが、状態データなら、予測も状態データになる。そのため、状態と行動のデータを取り扱うなら、二つの予測器を組み合わせる必要がある。また、状態と行動を結びつけるためには、状態を扱う予測器と、行動を扱う予測器の間にシナプスを設ける必要がある。また、予測器の間のシナプスによる予測の相互関係を設計する必要がある。

# 3 提案：行動決定する模倣CLA

## 3.1 二重予測器

提案する模倣CLAの予測器をFig. 2に示す。提案法の予測器は、従来のCLAの予測器を2つ連結する。一つ目は、環境から観測する状態データを扱う予測器であり、状態層と呼ぶ。二つ目は、行動データを扱う予測器であり、行動層と呼ぶ。これら二つの予測器の間には、シナプスを設ける。片側の予測器のセルの活性パターンをもう片方の予測器におけるセルの予測パターンの生成に利用する。状態層から行動層へのシナプスは、行動を出力するためのシナプスである。

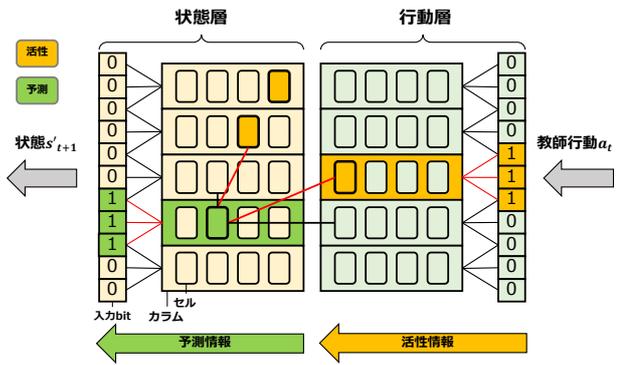


Fig. 3: フィードバック

入力された状態に対して適切な行動を出力するためには、行動層に行動の教師データを入力し、行動を出力するためのシナプスを構築する必要がある。そのため、本研究では、既存の強化学習アルゴリズムによって獲得した行動を、行動層に教師データとして入力することで模倣学習させる。時点 $t$ において、環境から観測した状態データ $s_t$ は、状態層に入力する。従来のCLAと同じ手続きに基づいて、状態層の一部のカラム群を活性状態にし、一部のセル群を活性状態にする。状態層の活性状態のセルから、行動層のセルに接続されたシナプスによって、行動層に時点 $t$ の行動 $a_t$ を表現する予測状態のセルを生成する。これをFig. 2に例示する。行動層において、予測状態のセルを内包するカラム群から予測行動 $a_t$ を出力する。次に、教師データの行動 $a_t$ を、行動層に入力する。予測行動 $a_t$ を表現する予測状態のセル群と、教師データの行動 $a_t$ によって活性状態になったカラム群を利用して、予測状態のセルのシナプスの永続値を更新する。活性状態のカラム内に存在する予測状態のセルについて、シナプスの永続値を増加させる。一方、通常状態のカラム内に存在する予測状態のセルについて、シナプスの永続値を減少させる。

## 3.2 フィードバック

次時点 $t+1$ の状態 $s_{t+1}$ を予測するため、状態層の内部において、セルとセルを関係付けるシナプスに基づいて、活性状態のセル群から予測状態のセル群を選ぶ。また、状態層のセルと行動層のセルを関係付けるシナプスに基づいて、行動層における活性状態のセル群から、状態層における予測状態のセル群を選択する。これをフィードバックと呼ぶ。これをFig. 3に例示する。フィードバックは、状態層への入力値が欠損したとき、行動層のセルの状態を利用して、状態層のセルを予測状態にし、状態の予測を持続させる効果がある。ただ、行動層におけるセルの活性情報が状態層に過剰に伝達すると、状態層における正しい予測状態のセルの生成の弊害になる。そのため、フィードバック強度 $r$ をパラメータとし、 $r$ に応じた割合で行動層と状態層の活性状態のセルを選択する。 $r$ が大きいほど、行動層の活性状態のセルが、状態層におけるセルの予測状態化に利用されるようになる。

## 3.3 反芻学習

強化学習アルゴリズムによる行動の教師データを利用する学習を通常学習と呼ぶ。行動の教師データから

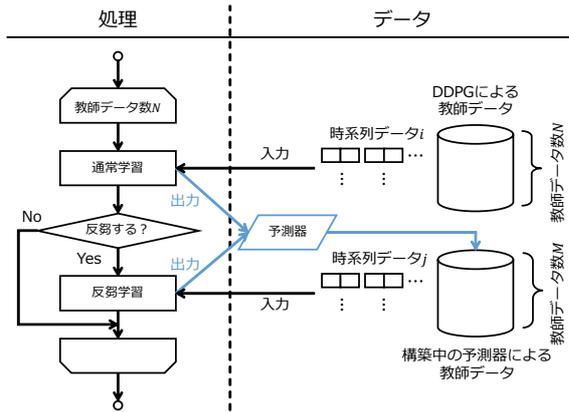


Fig. 4: フィードバックの効果

乖離した状態データの入力に対処するため、反芻学習を提案する。通常学習と反芻学習の関係を Fig. 4 に示す。教師データを用いる通常学習の後、反芻学習する。反芻学習は、行動の教師データによって通常学習した結果の予測器に対して、模倣した行動を試行する。得られた状態を模倣 CLA に入力して学習することで、教師データでは得られない状態に対して学習する。

本稿では、通常学習 10 回につき、反芻学習を 1 回実行する。これにより、過度な反芻学習が、通常学習を阻害することを抑制する。また、行動層のセルと状態層のセルを関係付けるフィードバックのためのシナプスは、反芻学習のときに配置する。

#### 4 実験設定

OpenAI Gym の連続マウンテンカー問題<sup>9)</sup>を用いて提案する模倣 CLA の性能を検証する。提案する模倣 CLA、模倣対象にした強化学習アルゴリズムである DDPG<sup>4)</sup>、DDPG に LSTM<sup>5)</sup> を組み合わせた DDPG+LSTM を比較する。提案する模倣 CLA におけるフィードバック、反芻学習の効果を明らかにするため、模倣 CLA(FB なし、反芻なし)、模倣 CLA(FB なし、反芻あり)、模倣 CLA(FB あり、反芻あり) の 3 つのアルゴリズムを比較する。模倣 CLA(FB なし、反芻なし) は、フィードバックせず、反芻学習もしない。模倣 CLA(FB なし、反芻あり) は、フィードバックせず、反芻学習する。模倣 CLA(FB あり、反芻あり) は、フィードバックして反芻学習もする。

連続マウンテンカー問題において、初期状態から終了条件を満たす状態までの一連の流れを一つのエピソードとする。模倣 CLA では、1000 エピソードの通常学習、100 エピソードにおいて反芻学習した。

連続マウンテンカー問題は、谷底の車を押すことで丘の上のゴールへの到達を目指す。状態は、車の位置と速度である。位置は、 $[-1.2, 0.6]$  の連続値である。0.5 の地点にゴールを設置する。速度は、 $[-0.07, 0.07]$  の連続値である。初期位置は、 $[-0.6, -0.4]$  のランダム値にする。初期速度は、0.0 にする。行動は、車を押す力の大きさである。車を押す力は、 $[-1.0, 1.0]$  の連続値である。-1.0 に近い値ほど、ゴールとは逆方向に車を強

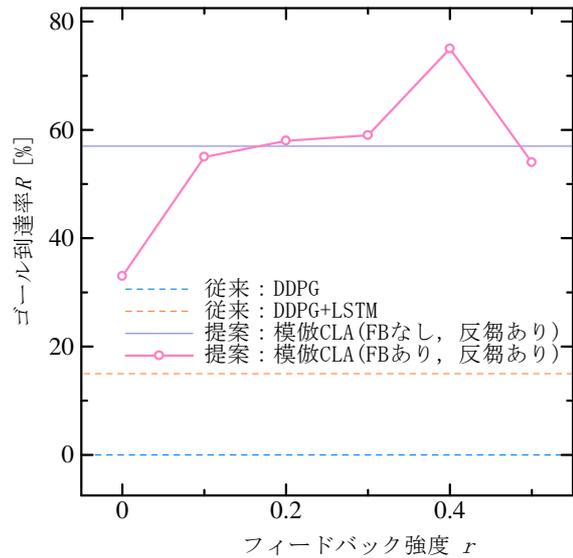


Fig. 5: フィードバックの効果

く押す。1.0 に近い値ほど、ゴールの方向に車を強く押す。学習後のテストでは、各時点において、入力される状態が正常に得られる確率  $P_m$  を用いる。  $P_m = 1$  のとき、全時点において状態が正常に得られる。  $P_m$  の減少に伴って状態の欠損が増加し、予測の難しさが増す。

### 5 実験結果と考察

#### 5.1 フィードバックの効果

フィードバックの効果を検証するため、フィードバック強度  $r$  の変化に対するゴール到達率を Fig. 5 に示す。データ正常率  $P_m = 0.025$  で速度が欠損する連続マウンテンカー問題を用いた。従来の DDPG, DDPG+LSTM, 模倣 CLA(FB なし、反芻あり) のゴール到達率を水平線で示した。

この結果から、まず、ふたつの模倣 CLA は、従来の DDPG と DDPG+LSTM より高いゴール到達率を示すことがわかる。次に、フィードバック強度  $r$  には、ゴール到達率を最大化する適切な値が存在することがわかる。フィードバック強度  $r = 0.4$  を用いる模倣 CLA は、フィードバックを用いない模倣 CLA より高いゴール到達率を達成することがわかる。このことから、適切に強度を調整したフィードバックは、模倣 CLA のロバスト性の向上に、貢献することが確かめられた。

以降の実験では、フィードバックを用いる模倣 CLA では、フィードバック強度  $r$  を 0.4 に固定した。

#### 5.2 速度の欠損に対する効果

速度が欠損する連続マウンテンカー問題において、速度のデータ正常率  $P_m$  を変化させたときのゴール到達率の結果を Fig. 6 に示す。この結果から、データ正常率  $P_m$  の増加に従って、すべてのアルゴリズムのゴール到達率が改善することがわかる。従来の DDPG は、LSTM で予測することによってゴール到達率が改善する。提案する模倣 CLA(FB なし、反芻あり) は、従来の DDPG+LSTM よりゴール到達率が高いことがわかる。さらに、提案する模倣 CLA(FB あり、反芻あり) は、提案する模倣 CLA(FB なし、反芻あり) より高いゴール到達率を示すことがわかる。

これらの結果から、提案する模倣 CLA は、速度の

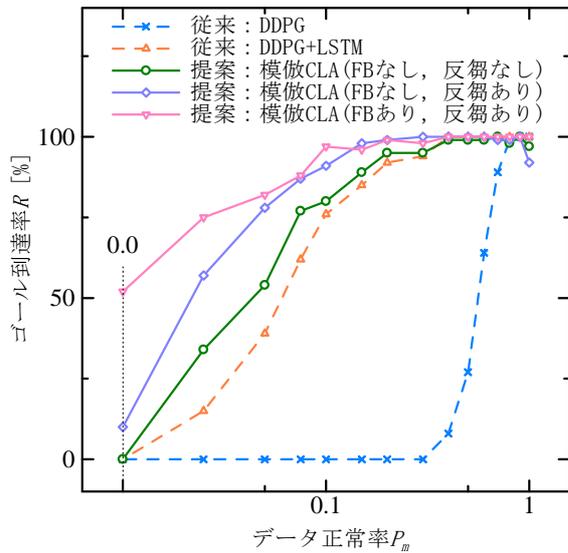


Fig. 6: 速度の欠損に対する到達率

欠損に対して、従来の DDPG や DDPG+LSTM より、ロバストに機能することが確かめられた。また、速度の欠損におけるフィードバックは、広い範囲のデータ正常率において、模倣 CLA のロバスト性を高めることが確かめられた。

### 5.3 位置の欠損に対する効果

位置が欠損する連続マウンテンカー問題において、位置のデータ正常率  $P_m$  を変化させたときのゴール到達率の結果を Fig. 7 に示す。この結果から、速度の欠損と同様に、データ正常率  $P_m$  の増加に従って、すべてのアルゴリズムのゴール到達率が改善することがわかる。また、提案する模倣 CLA (FB なし、反芻あり) は、従来の DDPG+LSTM よりゴール到達率が低いことがわかる。提案する模倣 CLA より、DDPG+LSTM のゴール到達率が高い理由としては、DDPG による行動決定において、位置の情報の重要度が低いことが考えられる。DDPG+LSTM にとって、位置の情報の重要度が低いいため、位置が欠損しても、行動決定に大きな影響を受けないと考えられる。このことは、Fig. 7 において、欠損の対策をしていない DDPG のゴール到達率が高いことから推測される。一方で、模倣 CLA (FB なし、反芻あり) は、データ正常率 0.0 において、速度の欠損と位置の欠損の両方で、ゴール到達率が 50% 程度であることがわかる。このことから、模倣 CLA (FB なし、反芻あり) は、行動決定において、DDPG よりも、速度の重要度と位置の重要度の差が小さく、様々な状態の欠損に対応できる可能性がある。

これらの結果から、提案する模倣 CLA は、位置の欠損に対して、従来の DDPG+LSTM と同等のロバスト性はないが、一定値以上のゴール到達率を保つことがわかった。

### 5.4 速度と位置の欠損に対する効果

速度と位置が欠損する連続マウンテンカー問題において、速度と位置のデータ正常率  $P_m$  を変化させたときのゴール到達率の結果を Fig. 8 に示す。この結果から、データ正常率  $P_m$  の増加に従って、すべてのアルゴリズムのゴール到達率が改善する傾向があることがわかる。しかし、模倣 CLA の結果は、速度の欠損に比べて、

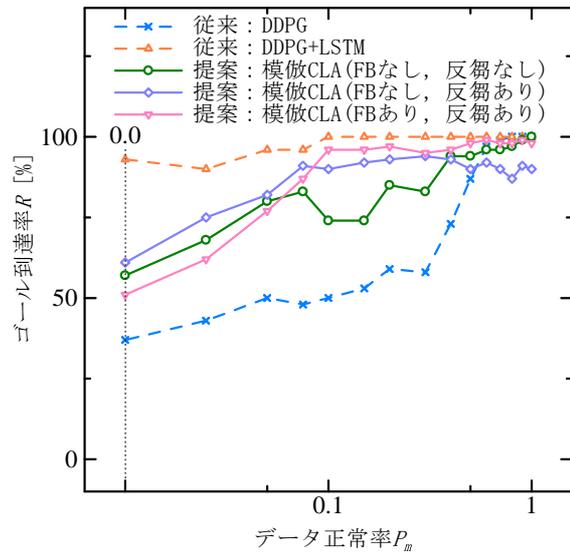


Fig. 7: 位置の欠損に対する到達率

ゴール到達率が安定していないことがわかる。また、提案する模倣 CLA (FB なし、反芻あり) は、データ正常率  $P_m = 0.0$  を除き、従来の DDPG+LSTM とほぼ同じ推移になることがわかる。データ正常率  $P_m = 0.0$  では、正常なデータが入力されない。そのため、ゴール到達率は、状態を予測する予測器の性能に、強く影響を受ける。この場合、シナプスと入力値によっては、予測値が出力できなくなる CLA よりも、LSTM の方が有利であると考えられる。フィードバックを入れた模倣 CLA は、データ正常率の全域で、残り二つの模倣 CLA よりも、ゴール到達率が高いことがわかる。このことから、フィードバックが、速度と位置の欠損に対して、模倣 CLA のロバスト性を高めることがわかる。

これらの結果から、提案する模倣 CLA は、速度と位置の欠損に対して、従来の DDPG+LSTM と同等の水準で、ロバストに機能することが確かめられた。

## 6 まとめ

本稿では、環境から観測する状態データに欠損が生じる行動決定タスクにおいて、ロバストに機能する行動決定手法の確立を目的とし、状態と行動をそれぞれ予測する二つの CLA を接続することによって、既存強化学習アルゴリズムの行動を模倣する CLA を提案した。観測する位置と速度の状態データに欠損が生じる連続マウンテンカー問題において、提案法は、模倣した強化学習アルゴリズムより、ゴール到達率が高く、ロバストに動作することがわかった。また、一部において、LSTM を用いて欠損に対応した強化学習アルゴリズムに、ゴール到達率で劣るが、提案法は、欠損する状態の要素の種類に左右されにくく、欠損に対して、ロバストに動作することがわかった。

今後の課題としては、提案法が、ノイズに対しても、ロバストであるか検証することである。また、より複雑なタスクでも、提案法が、ロバストに動作可能か検証する。

## 参考文献

- 1) J. Hawkins, A. Subutai and D. Dubinsky: Hierarchical temporal memory including HTM cortical learning algorithms, Technical report, Numenta, Inc, (2010)

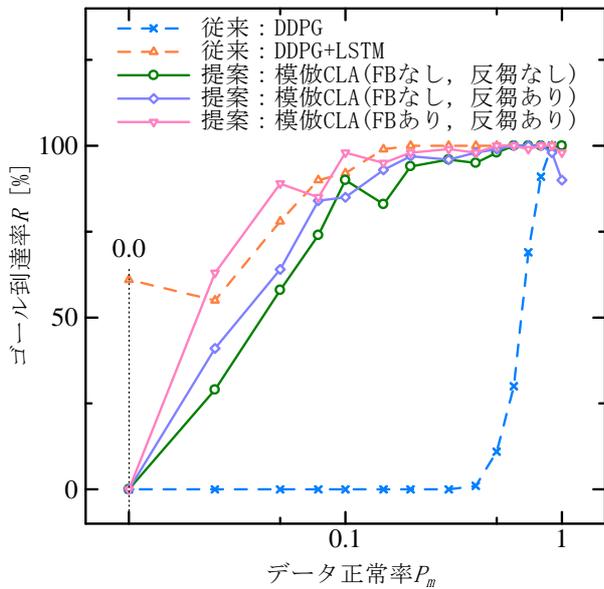


Fig. 8: 速度と位置の欠損に対する到達率

- 2) J. Hawkins and S. Blakeslee, *On Intelligence*, Times Books, 2004.
- 3) V. Mnih, K. Kavukcuoglu, D. Silver, A. Rusu, J. Veness, M. Bellemare, A. Graves, M. Riedmiller, A.

Fidjeland, G. Ostrovski, S. Petersen, C. Beattie, A. Sadik, I. Antonoglou, H. King, D. Kumaran, D. Wierstra, S. Legg and D. Hassabis: Human-level control through deep reinforcement learning, *Nature*, **Vol. 581**, No. 7540, pp. 529/533, (2015)

- 4) T. Lillicrap, J. Hunt, A. Pritzel, N. Heess, T. Erez, Y. Tassa, D. Silver and D. Wierstra: Continuous control with deep reinforcement learning, *International Conference on Learning Representation (ICLR)*, (2016)
- 5) S. Hochreiter and J. Schmidhuber: Long Short-Term Memory, *Neural Computation*, **Vol. 9**, No. 8, pp. 1735/1780, (1997)
- 6) B. Bakker: Reinforcement learning with long short-term memory, *Proceedings of the 14th International Conference on Neural Information Processing Systems (NIPS)*, pp. 1475/1482, (2001)
- 7) 木村 元, Leslie Pack Kaelbling: 部分観測マルコフ決定過程下での強化学習, *人工知能学会誌*, **Vol. 12**, No. 6, pp. 822/830, (1997).
- 8) htm.core, <https://github.com/htm-community/htm.core> (2020/4/21 アクセス)
- 9) OpenAI Gym, <https://github.com/openai/gym> (2020/9/18 アクセス)
- 10) Keras RL2, <https://github.com/wau/keras-rl2> (2020/9/18 アクセス)
- 11) Keras, <https://github.com/keras-team/keras> (2020/12/24 アクセス)

# 構造適応型深層学習を用いた道路網認識手法 RoadTracerへの適用

○鎌田 真 (県立広島大学 地域基盤研究機構) 市村 匠 (県立広島大学 地域創生学部)

## Automatic Extraction of Road Networks from Aerial Images by using Adaptive Structural Deep Learning

\*S. Kamada and T. Ichimura (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 can obtain appropriate number of hidden layers in DBN. In this paper, our model is applied to an automatic recognition method of road network, called RoadTracer. RoadTracer can generate a road map on the ground surface from aerial photograph data. In the search algorithm of network graph, a CNN is trained to find network connectivity between roads with high detection capability. However, the system takes long calculation time for not only training phase but also inference phase, then may not reach high accuracy. In order to improve the accuracy and calculation time, our Adaptive DBN was implemented on the RoadTracer instead of the CNN. We reported the accuracy and calculation time of our model in the experimental results.

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

### 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, 12)</sup>. 他にも CXRS などの胸部レントゲン写真のベンチマークデータセットに対しても, 高い分類能力と疾患部位検出結果を示すことができている<sup>13)</sup>.

深層学習は様々な分野に応用されており, 中でも航空写真等から地表の道路網を認識し, 道路地図を自動生成する技術として RoadTracer が知られている<sup>14)</sup>. 道路地図を作成することは, 測量から始まり, 道路の種類等の様々な情報を記入しなければならず, 当然のことながら, 長時間の複雑な作業を人によって行わなければならない. 従来では, CNN におけるセグメンテーション技術により道路網の自動検出が行われていたが<sup>15)</sup>, 道路地図の場合, 道路周辺の森, 建物, 影等

がノイズとなり, 上空の写真からのみでは道路を正確に検出できなかった. このため, RoadTracer では, 従来セグメンテーション技術ではなく, 与えられた入力画像を学習しながら, 深層学習を用いて画像認識し, その結果を道路の連続性をもとに, 次の区画を探索するアルゴリズムを提案した.

しかしながら, RoadTracer では, 学習や探索に長時間の計算が必要となり, また検出精度も高いとは言えない. 文献<sup>16)</sup>では, 広島県安芸郡熊野町の道路データを用いた RoadTracer の評価が行われているが, シカゴや東京のような都市部と比較して, 森林部や入り組んだ道の多い熊野町では精度が上がらないことが指摘されている. このため, 本論文では, RoadTracer の画像認識で使用されている深層学習モデルに, 我々が開発した構造適応型深層学習法を適用し, 精度や推論時間の改良を試みる.

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

#### 2.1 Restricted Boltzmann Machine

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

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

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

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

ここで、 $v_i$  は  $i$  番目の可視ニューロン、 $h_j$  は  $j$  番目の隠れニューロンである。 $b_i$  は  $v_i$  に対するパラメタ、 $c_j$  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 値のパターンの組み合わせに対するエネルギーを示す。一般的に、RBM では計算量の観点から Contrastive Divergence (CD) 法<sup>17)</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。

## 2.3 ニューロン生成/消滅アルゴリズム

我々は、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。この 2 つのパラメタの関連性から、ニューロン生成条件を式 (4) に示すように定義した<sup>12)</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

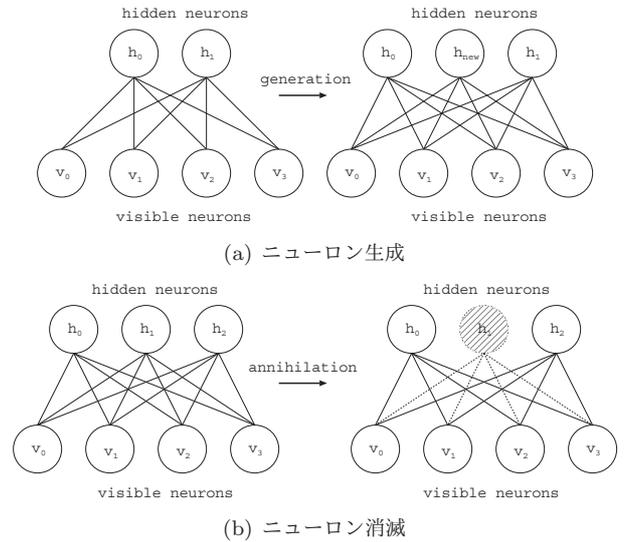


Fig. 1: 構造適応型 RBM

冗長なニューロンとし、これを削除する。

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

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

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

RoadTracer は、航空写真等から地表の道路網を認識し、道路地図を自動生成する技術である<sup>14)</sup>。一般的には、CNN におけるセグメンテーション技術が知られているが、RoadTracer では、与えられた入力画像を学習しながら、深層学習を用いて画像認識し、その結果を道路の連続性をもとに、次の区画を探索するアルゴリズムを提案した。3.1 節で、この探索的アルゴリズムについて述べ、3.2 節で探索アルゴリズムの中で使われている深層学習の決定関数について述べる。

#### 3.1 グラフ探索アルゴリズム

RoadTracer では、道路地図データは交差点等を頂点としたグラフ構造として扱われる。探索アルゴリズムでは、任意の初期地点  $v_0$ 、空のグラフ  $G$ 、探索履歴を格納する頂点スタック  $S$  を初期化し、各ステップにおいて後述する決定関数に基づいて次の地点に「歩く」、もしくは「止まる」行動を行い、 $G$  及び  $S$  を更新する。このステップを探索範囲がなくなるまで反復的に繰り返す。Algorithm 1 はアルゴリズムの疑似コードを示している。

決定関数は、現在のグラフ  $G$ 、現在の探索位置  $S_{top}$ 、 $S_{top}$  を中心とした航空写真を入力とし、行動  $action$  と角度  $\alpha$  を出力する関数である。行動  $action$  は、「歩く」、もしくは「止まる」のみで、ここで「歩く」が選択された場合、角度  $\alpha$  の方向へ一定の距離進み、このパスが  $G$  及び  $S$  に追加される。一方、「止まる」が選択された場合、頂点スタック  $S$  から現在の探索位置  $S_{top}$  が取り出され、次のステップにおいて前に戻る行動がとられる。

Fig. 2 は、交差点での探索の挙動を示している。ここでは、まず、青色の道路に対して、オレンジの初期地点からスタートし、右方向に向かって、1 から 4 の頂点がグラフ  $G$  及び頂点スタック  $S$  に追加される。次に、交差点に到達し、決定関数により最初に分かれ道の上側を探索する。この上側の分かれ道の最後まで探索が到達すると、決定関数は「停止」を選択する。さらに、残された分かれ道に沿って前の探索されたそれぞれの頂点に戻る。上側の分かれ道に隣接する他の道がない場合、決定関数は元の交差点に戻るまで「停止」を選択し続ける。交差点まで戻ると、次に決定関数は下側の分かれ道へ探索を導く。この分かれ道の最後に到達すると、決定関数は  $S$  が空になるまで繰り返し「停止」を選択する。 $S$  が空になれば、道路網の構築が完成する。

#### 3.2 CNN の決定関数

RoadTracer では、CNN は探索アルゴリズムにおける決定関数として使われる。文献<sup>14)</sup>では、CNN は入力層、17 層の畳み込み層、出力層から構成され、ここで、入力層は、現在の探索位置を中心とした  $d \times d$  の航空写真の RGB 画像と、現在までに探索したグラフ  $G$  の 4 チャンネルである。これに対して、出力は行動  $action$  と角度  $\alpha$  の 2 種類であり、行動は 2 つのニューロンを用いて  $O_{action} = (O_{walk}, O_{stop})$  と表され、ソフトマックス関数により求める。角度は、 $[0, 2\pi]$  の範囲を  $a$  個のニューロンで  $O_{angle} = (o_1, \dots, o_a)$  と表現し、シグモイド関数で求める。 $O_{walk}$  が選択された場合、 $\text{argmax}_i(o_i)$  に対応する角度に一定距離歩く。

---

#### Algorithm 1 グラフ探索アルゴリズム<sup>14)</sup>

---

**Require:** A starting location  $v_0$  and the bounding box  $B$  initialize graph  $G$  and vertex stack  $S$  with  $v_0$

- 1: **while**  $S$  is not empty **do**
- 2:    $action, \alpha := \text{decision func}(G, S_{top}, Image)$
- 3:    $u := S_{top} + (D \cos \alpha, D \sin \alpha)$
- 4:   **if**  $action = \text{stop}$  or  $u$  is outside  $B$  **then**
- 5:     pop  $S_{top}$  from  $S$
- 6:   **else**
- 7:     add vertex  $u$  to  $G$
- 8:     add an edge  $(S_{top}, u)$  to  $G$
- 9:     push  $u$  onto  $S$
- 10:   **end if**
- 11: **end while**

---

### 4 構造適応型深層学習を用いた RoadTracer

#### 4.1 決定関数の学習

文献<sup>14)</sup>では、CNN を用いて決定関数の学習及び推論が行われているが、本論文では、提案手法である構造適応型深層学習を用いて学習及び推論ができるよう、3.2 節で示した入出力構造をもとに実装した。学習では、文献<sup>14)</sup>と同様に、アメリカ合衆国イリノイ州シカゴを含む 25 都市のデータを学習した。これらのグラフデータと航空写真は、それぞれ OpenStreetMap<sup>18)</sup> と Google Map のサテライト画像 API を用いて取得した。各都市の範囲は概ね 24km 平方 km で、画像は 1 ピクセルに対して 60cm の解像度である。学習や推論の際に深層学習に与える入力画像のサイズは  $512 \times 512$  の RGB 画像である。Nvidia RTX 2080Ti $\times$ 2 の PC を用いて学習システムを構築したところ、従来の CNN では約 1 週間程度の計算時間を要し、構造適応型 DBN では、5 日程度で計算が終了した。シカゴに対する検出精度は、従来の CNN と構造適応型 DBN でそれぞれ 94.7% と 95.4% となり、大きな違いは見られなかった。

#### 4.2 広島熊野地域への適用

RoadTracer ではシカゴ等の都市部のデータを用いた評価が行われているが、本論文では、テストデータとして、広島県安芸郡熊野町地域における航空写真を使用し、山間部における入り組んだ道路も正しく探索することができるのか検証した。Fig. 3(a) は、使用した熊野町の航空写真を示している。画像の解像度は  $4096 \times 4096$  ピクセルであり、Google Map のサテライト画像 API を用いて取得した。

Table 1 は、Fig. 3(a) の画像に対する検出精度と推論時間を示している。構造適応型 DBN の検出精度は 80.2% となり、従来の CNN に比べて 5% 弱高く、44 個の頂点を追加で発見できた。また、推論時間も 15 分程度早い結果となり、これは、CNN に比べて DBN 方が小さなモデルであるためだと考えられる。Fig. 3(b) 及び Fig. 3(c) は、従来の CNN と構造適応型 DBN において、実際に検出された道路を描画しているが、構造適応型 DBN はより多くの道路を検出していることが分かる。構造適応型 DBN で検出できなかった 19.8% は、見た目では分かりづらい非常に細かな道や、田んぼ等、元の学習データには含まれなかった特徴が起因

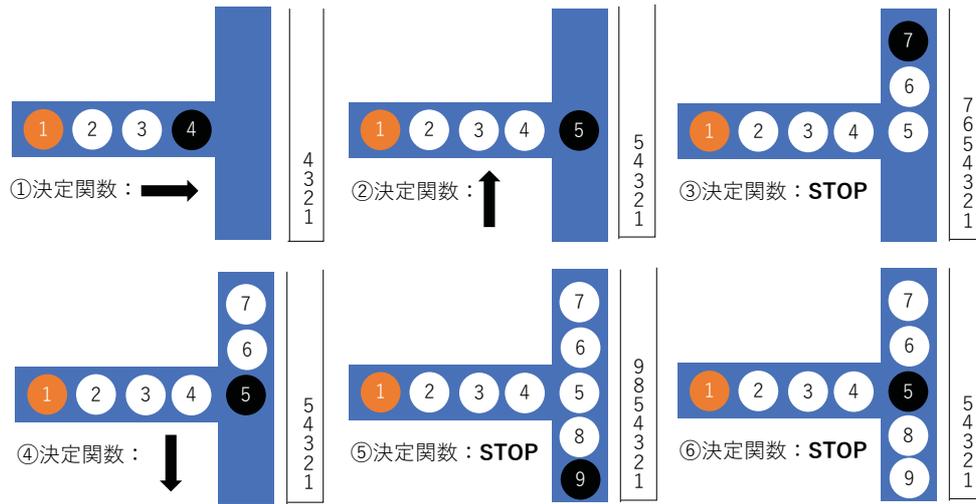


Fig. 2: 探索アルゴリズムの例



Fig. 3: 広島県熊野町地域における構造適応型 DBN の推論結果

していると考えられ、今後の課題である。本論文では無償の Google Map を用いて評価したが、高解像度で有料の衛星画像を使えばより精度が向上すると考えられる。

## 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。本論文では、提案したモデルを道路網の自動検出における RoadTracer に適用した。RoadTracer は、CNN の推論結果をもとにした探索アルゴリズムにより道路を検出する仕組みであるが、検出精度と推論時間に課題があった。本論文では、提案モデルの構造適応型 DBN を用いて RoadTracer を実装した。広島県熊野町地域の航空写真を用いて評価したところ、従来の CNN よりも高い検出精度が得られた。検出できなかった箇所は、見た目では分かりづらい非常に細かな道や、田んぼ等、元の学習データには含まれなかった特徴が起因していると考えられ、今後の課題である。

Table 1: 検出精度

モデル	検出精度	探索時間 (分)
CNN	75.4%	49.2
構造適応型 DBN	80.2%	35.4

## 謝辞

本研究開発は JSPS 科研費 (課題番号: 19K12142, 19K24365), 独立行政法人情報通信研究機構 (NICT) の委託研究 (課題番号: 21405) の助成を受けたものです。

## 参考文献

- 1) Y.Bengio: *Learning Deep Architectures for AI*, Foundations and Trends in Machine Learning archive, vol.2, no.1, 1/127 (2009)
- 2) V.Le.Quoc, R.Marc's Aurelio, et.al.: *Building high-level features using large scale unsupervised learning*, Proc. of 2013 IEEE International Conference on Acoustics, Speech and Signal Processing, 8595/8598 (2013)
- 3) C.Szegedy, W.Liu, et.al.: *Going Deeper with Convolutions*, 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 1/9 (2015)
- 4) K.He, X.Zhang, S.R en, J.Sun: *Deep residual learning for image recognition*, Proc. of 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 770/778 (2016)

- 5) G.E.Hinton: *A Practical Guide to Training Restricted Boltzmann Machines*, Neural Networks, Tricks of the Trade, Lecture Notes in Computer Science (LNCS, vol.7700), 599/619 (2012)
- 6) G.E.Hinton, S.Osindero and Y.Teh: *A fast learning algorithm for deep belief nets*, Neural Computation, vol.18, no.7, 1527/1554 (2006)
- 7) S.Kamada and T.Ichimura: *An Adaptive Learning Method of Restricted Boltzmann Machine by Neuron Generation and Annihilation Algorithm*, Proc. of 2016 IEEE International Conference on Systems, Man, and Cybernetics (IEEE SMC 2016), 1273/1278 (2016)
- 8) S.Kamada and T.Ichimura: *A Structural Learning Method of Restricted Boltzmann Machine by Neuron Generation and Annihilation Algorithm*, Neural Information Processing, vol.9950 of the series Lecture Notes in Computer Science, 372/380 (2016)
- 9) A.Krizhevsky: *Learning Multiple Layers of Features from Tiny Images*, Master of thesis, University of Toronto (2009)
- 10) 鎌田真, 市村匠: 忘却機能を持った *Deep Belief Network* による構造適応型学習, 計測自動制御学会第9回コンピュータ・インテリジェンス研究会講演論文集, 92/97 (2016)
- 11) S.Kamada and T.Ichimura: *An Adaptive Learning Method of Deep Belief Network by Layer Generation Algorithm*, Proc. of IEEE TENCON2016, 2971/2974 (2016)
- 12) S.Kamada, T.Ichimura, A.Hara, and K.J.Mackin: *Adaptive Structure Learning Method of Deep Belief Network using Neuron Generation-Annihilation and Layer Generation*, Neural Computing and Applications, doi.org/10.1007/s00521-018-3622-y, 1/15 (2018)
- 13) 市村匠, 鎌田真: *ChestX-ray8* を用いた構造適応型 *Deep Belief Network* による胸部疾患位置検出システム, 計測自動制御学会システム・情報部門学術講演会 2018 講演論文集 (SSI2018), SS10-08 (2018)
- 14) F.Bastani, et.al.: *RoadTracer: Automatic Extraction of Road Networks from Aerial Images*, arXiv:1802.03680 [cs.CV] (2018)
- 15) G.Mátyus, et.al.: *DeepRoadMapper: Extracting road topology from aerial images*, Proc. of the IEEE Conference on Computer Vision and Pattern Recognition (ICCV), 3438/3446 (2017)
- 16) 寒竹夏水, 鎌田真, 市村匠: 航空写真を用いた深層学習による道路網認識手法 *RoadTracer* の動作パラメタ実験, 2020 IEEE SMC Hiroshima Chapter Young Researchers WorkShop, 24/28 (2020)
- 17) G.E.Hinton: *Training products of experts by minimizing contrastive divergence*, Neural Computation, vol.14, no.8, 1771/1800 (2002)
- 18) S.Coast, OpenStreetMap: <https://www.openstreetmap.org/> (2021/3/15 閲覧)

# 距離学習を用いた鯨の個体識別システムの構築

中原 諒, ○磯川 悌次郎, 上浦 尚武 (兵庫県立大学)

## A Whale Identification System Based on Metric Learning

R. Nakahara, \*T. Isokawa, and N. Kamiura (University of Hyogo)

**Abstract**— This paper presents an identification system for humpback whales (*Megaptera novaeangliae*) based on convolutional neural networks. The proposed system accepts the image of fluke for whale and then makes identification for this image. The proposed system consists of two components; the first one extracts the fluke region from the input image and the second one identifies a whale from the fluke image. The experimental results show that the fluke images can be correctly extracted and high identification rate can be achieved by incorporating Adacos loss function in the network.

**Key Words:** Whale, Identification, Metric Learning

### 1 はじめに

クジラがどのような移動や回遊パターンを持つのかを知ることは、分布生態を明らかにする生物学的な興味だけでなく、クジラを利用あるいは保護管理しようとするときにも重要な情報となる。クジラの移動や回遊を長期間にわたって調べることは現実的には不可能であり、個々のクジラがいつどこで確認されたかという記録を繋いでいくことで、その移動を知る手法が取られている<sup>1)</sup>。

個々のクジラを確認するためには、個々のクジラの個体識別を行う必要があり、ザトウクジラ (*Megaptera novaeangliae*) の場合は、尾ビレの観察を行い個体を記録する。ザトウクジラの尾びれには、黒と白の色素沈着や傷跡、吸虫が見られる、このような特徴を利用して、研究者たちは尾ビレの画像から個々のクジラを照合し記録をしている。個体の照合は個々の研究者の目視によって画像を確認し、同一の個体がいまいか確かめている。そのため、データベースに登録されているクジラの個体数が大きくなるほど、照合には過重な労力と時間を要する。このような背景から、個々のクジラの画像から個体識別あるいは個体候補を出力することが可能なシステムが望まれている。現在のところ、このようなシステムを構築することはほとんど検討されていないのが現状である<sup>2)</sup>。

近年、畳み込みニューラルネットワーク (CNN) は画像認識分野における様々なタスクにて高い精度を達成し、コンピュータビジョン及び機械学習の分野で広く使われているモデルである。上述の個体識別システムを構成する際には、この CNN に基づいたシステムが有効であると考えられる。

CNN ベースのネットワークでは、クラス分類を行うために softmax 損失を用いて学習を行う。softmax 損失は、学習用のミニバッチから稀なサンプルを無視して、より多数のサンプルによく適合するように学習を行う。しかし、ザトウクジラのデータベースには個体あたりのサンプル画像数が 1 枚から 3 枚と少ない枚数の個体が多いため、softmax 損失を用いるとどの個体もうまく識別できないネットワークが構成される可能性がある。

これに対して距離学習 (Metric Learning) は、入力された特徴量を同じものはより類似度が高くなるように、

違うものは類似度が低くなるように特徴量抽出器を学習させる手法である。距離学習では、サンプル数が少ないデータセットの識別に適しており、人間の顔識別タスクなどに用いられている。Adacos 損失を用いた個体識別は人間の顔識別タスクにおいて良い結果を示している。そのため、ザトウクジラにおける個体識別においても有効に働く可能性が高い。

このようなことから、本研究では、Adacos 損失を採用したザトウクジラの個体識別システムの構築および評価を行うことを目的とする。また、比較のため、softmax 損失を用いたザトウクジラの個体識別システムについても同時に評価を行う。

### 2 準備

#### 2.1 データセット

本研究では、データ分析コンペティションサイト Kaggle にて登録されている Humpback Whale Identification (<https://www.kaggle.com/c/humpback-whale-identification/>) にて用いられているザトウクジラの尾ビレ画像を識別対象とする。ザトウクジラの尾ビレの画像の例を図 1 に示す。この図に見られるように、ザトウクジラの尾ビレには黒と白の色素沈着と傷跡、吸虫の付着があり、これらはそれぞれのクジラに固有のものである。画像の枚数は 25,360 枚であり、それぞれの画像についてクジラの個体 Id でラベル付けされており、3,000 以上のユニークなクジラの個体がデータセットに含まれている。このデータセットの特徴として、画像の枚数が 1 枚から 3 枚のクジラの個体がデータセットの多くを占めている。また、図 1(b) のように尾ビレが真後ろから取られていないものや尾ビレが一部隠れている画像も存在する。



(a) (b)  
Fig. 1: Examples of whale fluke

## 2.2 deeplabv3

Chen らにより提案された deeplabv3 はエンコード-デコード構造を持つセマンティックセグメンテーションモデルである<sup>3)</sup>。本研究では、クジラの尾ビレ画像から尾ビレ領域をマスクした画像を作成するためにこの deeplabv3 を使用する。deeplabv3 では Atrous 畳み込み層と、Atrous Spatial Pyramid Pooling(ASPP) の 2 つの手法が導入されている。  $x$  は 2 次元の入力特徴量マップ、  $y$  は出力特徴量、  $i$  は特徴量の位置、  $w$  は重み、  $r$  をレート値とすると、Atrous 畳み込み層は式 (1) で表される。

$$y[i] = \sum_k x[i + r \cdot k]w[k] \quad (1)$$

標準的な畳み込み層は  $r = 1$  の場合に対応する。  $r$  を変更することにより、フィルターの視野を適応的に変更することが可能である。

ASPP は Atrous 畳み込み層を用いて異なるスケールの特徴を抽出する手法である。異なるレートを持つ 4 つの Atrous 畳み込み層を適用することにより、画像レベルの特徴を連結させる。その特徴量を求める空間次元にバイリニア補完を用いてアップサンプリングを行う。

deeplabv3 のネットワーク構造を図 2 に示す。本研究では、50 層の ResNet をベースモデルとして学習を行う。

## 2.3 Adacos

Adacos は Zhang らによって提案されたコサイン類似度ベースの softmax 損失の計算方法の一つである<sup>4)</sup>。特徴量抽出器によって得られた  $i$  番目の特徴量ベクトルを  $x_i$ 、  $y_i$  を正解ラベル、  $N$  をバッチサイズとすると、  $i$  番目の特徴量がクラス  $j$  である確率  $P_{i,j}$  は、softmax 関数を用いて式 (2) で表される。

$$P_{i,j} = \frac{e^{f_{i,j}}}{\sum_{k=1}^C e^{f_{i,k}}} \quad (2)$$

ここで  $C$  はクラス数、  $f_{i,j}$  は softmax 関数の入力 logits、  $P_{i,j}$  は  $x_i$  をクラス  $j$  に割り当てる確率を表す。ミニバッチのクロスエントロピー損失は式 (3) で表される。

$$L_{CE} = -\frac{1}{N} \sum_{i=1}^N \log P_{i,y_i} = -\frac{1}{N} \sum_{i=1}^N \frac{e^{f_{i,y_i}}}{\sum_{k=1}^C e^{f_{i,k}}} \quad (3)$$

Adacos では、この入力 logits を工夫することにより、入力された特徴量  $x$  のクラス内の分散を小さくし、

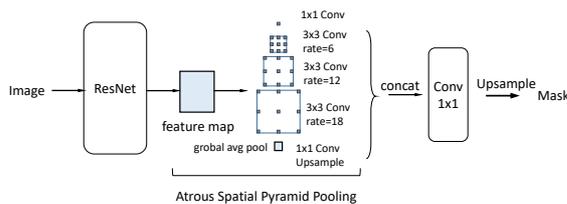


Fig. 2: The network structure for deeplabv3

クラス間の分散を大きくなるように学習を行わせる。Adacos における logits  $f_{i,j}$  は式 (4) にて表される。

$$f_{i,j} = \tilde{s}^{(t)} \cdot \cos(\theta_{i,j}) \quad (4)$$

ここで  $\cos(\theta_{i,j})$  は特徴量  $\vec{x}_i$  と  $j$  クラスへの重み  $\vec{W}_j$  のコサイン類似度であり、式 (5) で表される。  $\tilde{s}^{(t)}$  は以下で述べられる  $t$  イテレーション目の動的適用スケールパラメータである。正規化を行うことにより、データセット内の少ないサンプルに対しても学習を行わせることが可能となる。

$$\cos(\theta_{i,j}) = \frac{\vec{x}_i \cdot \vec{W}_j}{\|\vec{x}_i\| \cdot \|\vec{W}_j\|} \quad (5)$$

次に、動的適用スケールパラメータ  $\tilde{s}^{(t)}$  について説明する。学習が進むに連れ正解ラベルへの監視が弱くなっている。そこで、動的適用スケールパラメータを設計し、徐々に監視を強くする。具体的には、  $\theta_{med}^{(t)}$  を導入する。  $\theta_{med}^{(t)}$  は、  $t$  イテレーション目のミニバッチ内の正解ラベルの角度  $\theta_{i,y_i}^{(t)}$  の中央値であり、ネットワークの学習の進行度を大まかに表す。学習初期においては  $\theta_{med}^{(t)}$  が大きい値となり監視が強くなりすぎるため、  $\theta_{med}^{(t)}$  が  $\frac{\pi}{4}$  より小さい場合のみにおいて使用する。以上より、動的適用スケールパラメータ  $\tilde{s}^{(t)}$  は式 (6) で表される。

$$\tilde{s}^{(t)} = \begin{cases} \sqrt{2} \cdot \log(C - 1) & (t = 0) \\ \frac{\log B_{avg}^{(t)}}{\cos(\min(\frac{\pi}{4}, \theta_{med}^{(t)}))} & (t \geq 1) \end{cases} \quad (6)$$

ここで  $B_{avg}^{(t)}$  は式 (7) で表される。

$$B_{avg}^{(t)} = \frac{1}{N} \sum_{i=1}^N \sum_{k \neq y_i} e^{\tilde{s}^{(t-1)} \cdot \cos(\theta_{i,k})} \quad (7)$$

## 2.4 クジラの個体識別手法

本論文では、クジラの個体識別の手法として Adacos 損失を用いたザトウクジラの個体識別システムを構築する。識別システムは検出部と識別部から構成される。検出部では、ザトウクジラの尾ビレの領域の検出し、画像に対してマスクを適用させることにより尾ビレ領域を抽出する。この得られた画像について前処理を行うことにより識別部の入力となる。識別部では ResNet を特徴量抽出器として特徴量を抽出し、この得られた特徴量について類似度を比較することにより個体の識別を行う。図 3 に本実験に用いるクジラの個体識別システムの概要図を示す。

学習は検出部と識別部に分けて実施する。クジラの尾ビレ領域の検出では、検出器に deeplabv3 を用いてザトウクジラの尾ビレ画像について学習を行うことにより入力画像から尾ビレの領域を検出する。識別部の学習では、マスクの適用が行われたザトウクジラの尾ビレの画像を入力として ResNet による特徴抽出を行うことによりクラス分類を行う。クラス分類を行うことで、ResNet から得られる特徴量を埋め込み空間において同一のものは近く、異なるものは遠く埋め込むように学習を行う。実験では 18 層、50 層、101 層の ResNet

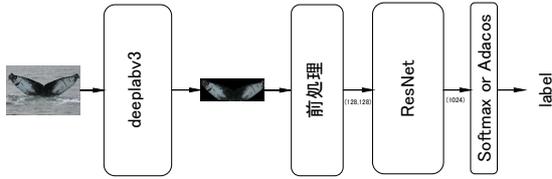


Fig. 3: Overview of the proposed system



(a) Original image (b) Masked image

Fig. 4: An example of masked images produced by deeplabv3

を用いて性能の評価を行う。また損失関数の違いによる識別性能の違いを検討するために、損失関数として softmax 損失と Adacos 損失を用いて比較を行う。

### 3 実験結果

#### 3.1 deeplabv3 を用いた尾ビレのマスク画像の作成

deeplabv3 を用いて、クジラの尾ビレ画像について尾ビレ領域の検出実験を行う。学習に使用するデータとしてザトウクジラの尾ビレ画像 450 枚とそのマスク画像 450 枚を用い、訓練データとして 360 枚を学習に用い、残り 90 枚をテストデータとする。前処理およびデータセットの増強として、大きさの変更、水平反転、垂直反転、正則化を行った。学習モデルには Resnet50+deeplabv3 を使用した。本実験では、該当画素がクジラの尾ビレであるかそうでないかの二値分類となるため、学習モデルの最終層の出力ニューロン数が 1 と変更している。最終層以外の初期重みは COCO train2017 データセットで事前学習された重みを使用する。学習回数は 30epoch とし、ミニバッチは 8、損失関数に交差エントロピー誤差、最適化関数に Adam を用い、学習率は 0.001、最小学習率は 0.0001 とした。

作成したモデルを用いてテストデータについて性能の評価を行った。学習の結果、損失は 0.0921、検出性能を表す mIoU は 0.892 となった。また、テストデータを入力した場合に作成されたマスクを図 4 に示す。この図に示すように、クジラの尾ビレの領域の検出が正確できていることがわかる。

#### 3.2 クジラの個体識別

本節では、Resnet を用いたザトウクジラの個体識別を行った結果を示す。ここでは、二種類の性能評価実験により、ザトウクジラの個体識別システムの識別性能を評価する。

一つ目の実験はザトウクジラの個体識別実験である、この実験では、2,932 頭のクジラを識別し、その上位 1 件の正答率と上位 5 件の正答率について評価を行う。二つ目の実験は、1:1 検証である。与えられた 2 枚のザトウクジラの尾ビレ画像に対して、同一個体であるかそうでないかを判定する。本実験では AUC を算出することにより評価を行った。

学習に用いるデータセットは、ザトウクジラの尾ビレ画像のうち、2 枚以上のサンプル数を持つ個体を用いた。画像の枚数は 13,624 枚であり、ユニークな個体の数は

Table 1: Identification rates by the proposed system

model	loss	top1-acc	top5-acc
ResNet18+softmax	2.185	64.3	75.8
ResNet50+softmax	2.012	66.0	78.0
ResNet101+softmax	1.940	66.4	78.0
ResNet18+Adacos	1.990	80.0	87.8
ResNet50+Adacos	1.946	82.8	90.0
ResNet101+Adacos	2.042	81.4	88.5

2,931 頭である。この画像セットについて、8,174 枚を訓練データ、5,450 枚をテストデータとし、個体ごとの画像の枚数の割合が同程度になるようにデータの分割を行った。前処理及びデータセットの増強に、deeplabv3 によるマスクの適用、尾ビレの領域の切り取り、ランダムなアフィン変換、正則化を行った。ザトウクジラの尾ビレの識別には、18 層、50 層、101 層の ResNet を採用し、ResNet の出力は 1,024 次元とした。Imagenet で事前学習された重みを ResNet の初期重みとする。損失関数に softmax 損失または Adacos 損失を採用した。識別層 (softmax 層あるいは Adacos 層) の入力ニューロン数は 1,024、出力ニューロン数は 2,931 とし、それぞれについて学習と評価を行った。学習回数は 50epoch とし、ミニバッチサイズは 32、最適化関数に Adam を使用し、初期学習率は 0.0005、最小学習率は 0.00005 とした。

学習したモデルについてテストデータを用いて上位 1 件の正答率、上位 5 件の正答率を算出した結果を表 1 に示す。この結果より、50 層の ResNet を特徴量抽出器として Adacos 層を導入したモデルが他のモデルに比べて高い正答率を上げていくことが確認でき、この場合の上位 5 件の正答率は 90.0% であった。また、ResNet の深さが同じモデルについて Softmax 層と Adacos 層を導入したものを比較すると、Adacos 層を用いたモデルがより正答率が高いことがわかる。

次に 1:1 検証の結果について説明する。学習したモデルについて、2 枚のザトウクジラの画像を入力し、得られた特徴量のコサイン類似度を比較することにより同一の個体であるかを識別を行う。識別閾値を変化させることにより ROC 曲線を描き、AUC を算出し評価を行った。評価に用いるデータは訓練データに使用していないザトウクジラの尾ビレ画像を用いる。この評価データの中には、学習していない個体についても含まれている。6000 組のザトウクジラの尾ビレ画像のペアを作成し、同一の個体についての画像のペアが 1200 組、同一でない個体についてのペアが 4800 組とした。

表 2 に各モデルについての AUC を示す。この結果より、50 層の ResNet を特徴量抽出器とし Adacos 層を導入したモデルが、他のモデルに比べて高い AUC であることがわかる。また、ResNet の層の深さが同程度のモデルを比較すると、Adacos 層を導入したモデルのほうが高い AUC であることがわかる。この結果は、先ほどの上位 5 件の正答率における評価と同じ傾向である。さらに、学習に用いていない個体についても個体の識別を行うことができていることが確認できた。

### 4 まとめ

本研究では、ザトウクジラの尾ビレから個体識別を行うシステムを構築しその性能評価を行った。このシ

Table 2: AUC values in correspondence test

model	AUC
ResNet18+softmax	0.9613
ResNet50+softmax	0.9687
ResNet101+softmax	0.9690
ResNet18+Adacos	0.9895
ResNet50+Adacos	0.9916
ResNet101+Adacos	0.9911

システムは尾ビレの検出器と識別部から構成されており、尾ビレの検出器に deeplabv3、識別部に Adacos が導入された ResNet を採用した。提案法ではザトウクジラの尾ビレの画像を検出器で検出後、尾ビレ領域についてマスクを作成する。そしてそのマスクを画像に適用し、前処理を行い識別部へ入力する。画像を識別部にて特徴量を抽出し識別を行った。

本研究では、三つの実験を行った。第一の実験は deeplabv3 を用いたザトウクジラの尾ビレ領域のマスク作成であり、実験結果より、入力された画像についてマスクが良好に作成されていることが示された。第二の実験は、ザトウクジラの個体識別に関するものであり、ザトウクジラ 2,931 頭についてクラス分類を行った。実験結果より、50 層の ResNet と Adacos 損失を用いたネットワークで、上位 1 件の正答率 82.8%、上位 5 件の正答率 90.0% となった。softmax 損失を用いたネットワークに対して、Adacos 損失を用いたネットワークは識別率の向上が確認できた。第三の実験では、ザト

ウクジラの個体が同一のものであるか 1:1 検証を行った。6000 組のペアについて提案法を適用し、Adacos 損失を用いた 50 層の ResNet の使用により AUC として 0.9916 を達成した。このことから学習していない画像について、高精度で識別を行えることが示された。

以上の結果より、Adacos が導入された ResNet を用いた識別システムにおいてザトウクジラの個体識別を行うことが可能であることが示された。提案法を使用することで、照合に要する時間を短縮できると考えられる。今後の課題として、尾ビレの画像についての位置合わせ手法の検討、マッコウクジラの個体識別への適用が挙げられる。

## 参考文献

- 1) 村山, 中原, 森, “イルカ・クジラ学 イルカとクジラの謎に挑む,” 東海大学出版社, pp.74–90, 2002.
- 2) 小林, 近藤, 辻井, 興, 日田, 吉川, 岡部, 小川, 李, 東, 岡本, 内田, 三谷: “日本国内におけるザトウクジラ (*Megaptera novaeangliae*) の海域間交流に関する自動照合システムを用いた研究,” 2020 年度勇魚会オンラインシンポジウム, 2020.
- 3) Chen, L. C., Papandreou, G., Schroff, F., & Adam, H., “Rethinking atrous convolution for semantic image segmentation,” arXiv preprint arXiv:1706.05587, 2017.
- 4) Zhang, X., Zhao, R., Qiao, Y., Wang, X., & Li, H., “Adacos: Adaptively scaling cosine logits for effectively learning deep face representations,” In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, pp.10823–10832, 2019.