

22nd SICE Symposium on Computational Intelligence

July 15, 2023, Kyoto

第22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：2023年7月15日（土）

会 場：京都工芸繊維大学

SICE[®]

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 23PG0003

著作権 © 2023

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 23PG0003

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：2023年7月15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 22 回コンピューターショナル・インテリジェンス研究会

7月15日(土)

9:50～11:20 (3 件) セッション1 座長: 信川 創(千葉工業大学)

- | | | | |
|---------|-------------------|-----------------|----|
| 9:50 ~ | 中央制御局による通信機能付き自動運 | 上西 翔, 森 禎弘(京都工芸 | 1 |
| 10:20 | 転車に対する減速指示を用いた渋滞解 | 織維大学) | |
| | 消制御の検討 | | |
| 10:20 ~ | 通信機能を持つ自動運転車が交通流量 | 山口瑛人, 森 禎弘(京都工 | 9 |
| 10:50 | に及ぼす影響に関する考察 | 芸織維大学) | |
| 10:50 ~ | 周期が異なる周期パターン間のカーネ | 橋 完太(工学院大学) | 15 |
| 11:20 | ル関数について | | |

12:50～14:20 (3 件) セッション2 座長: 森 禎弘(京都工芸織維大学)

- | | | | |
|---------|--------------------------|------------------|----|
| 12:50 ~ | 長期記憶性と高い説明可能性を有する | 小西文昂, 廣瀬 明, 夏秋 嶺 | 19 |
| 13:20 | 新しいリザーブコンピューティングベ | (東京大学) | |
| | ース手法 | | |
| 13:20 ~ | 運転時における脳波計を用いた | 小澤拓斗, 飯沼 佑太, 信川 | 24 |
| 13:50 | microstate 解析による運転熟練度の評価 | 創(千葉工業大学), 我妻伸 | |
| | | 彦(東邦大学), 稲垣 圭一郎 | |
| | | (中部大学) | |
| 13:50 ~ | 大脳皮質-基底核脳回路システムモデル | 道法浩孝(高知大学), 信川 | 30 |
| 14:20 | における神経挙動のカオス共鳴制御 | 創(千葉工業大学), 西村治 | |
| | | 彦(大和大学), 高橋哲也(金 | |
| | | 沢大学) | |

14:40～15:40 招待講演 座長: 信川 創(千葉工業大学)

講演題目: モデルベース視線計測システムのインプリシットキャリブレーション手法
廣江 葵氏 (大阪成蹊大学)

モデルベース視線計測システムの インプリシットキャリブレーション手法

廣江 葵（大阪成蹊大学）

視線計測技術は、次世代のヒューマンインタフェースにおいて重要な技術として注目を集めており、心理学、医学、マーケティング、エンタテインメントなどの様々な分野での応用が期待されている。しかし、現在の視線計測装置にはいくつかの課題が残されており、それによって応用範囲が制限されている。

視線計測装置の課題の一つとして、ユーザキャリブレーションが挙げられる。従来の視線計測装置では、装置を使用する前に画面上に表示された点をユーザに意図的に注視させるキャリブレーション作業を必要としていた。本研究では、このキャリブレーションを自動化することを目的としている。

本研究では、モデルベースの視線計測手法において課題となるユーザキャリブレーションをインプリシット（暗黙的）に実施する手法を提案した。モデルベースの視線計測手法では、眼球の光軸と視軸のずれを求めることがユーザキャリブレーションに相当する。明示的なキャリブレーションを行う方法では、既知の場所に最低1点（キャリブレーション点）をユーザが注視することにより、このずれを計算している。本研究では、ディスプレイと眼球の光軸の交点周辺からユーザが見ている可能性が高い点を推定し、その点をキャリブレーション点として利用することとした。

ユーザが見ている可能性の高い点を予測するために、ディスプレイに表示している画像に対して Itti の顕著性マップの生成、顔認識、機械学習ベースの顕著性マップの生成、といったアプローチを試みることで、意図的に1点を注視したユーザキャリブレーションに迫る 1.54 度の精度で視線を推定できることを示した。

中央制御局による通信機能付き自動運転車に対する減速指示を用いた渋滞解消のための制御

○上西翔 森禎弘 (京都工芸繊維大学)

Control to relieve traffic congestion using deceleration instructions to Connected Autonomous Vehicles by a central control station

*S. Uenishi and Y. Mori (Kyoto Institute of Technology)

Abstract— In recent years, there has been a lot of research and development on automated vehicles called Connected Autonomous Vehicles (CAV), which have the ability to exchange various information with other vehicles. In the future, there is a possibility that CAVs and Manual Vehicles (MV) will run together on highways, there has been also a lot of research on traffic flow under such road conditions. Existing studies have considered ways to improve road capacity by linking CAVs as much as possible and allowing them to drive with less distance between vehicles than necessary. In this paper, we investigate a method to relieve traffic congestion using data from CAVs on the road and compare the traffic flow rates by giving CAVs the ability to communicate with a central control station, a control device that can aggregate CAVs' driving information.

Key Words: Connected Autonomous Vehicle, central control station

1 はじめに

CAV (Connected Autonomous Vehicle) とは、他の車両と相互に通信を行い、速度などの情報を共有する機能を持った自動運転車のことである。近年、ネットワーク技術、人工知能、センサー技術などの発達により、CAV に関する研究は国内外で盛んに行われている。自動運転技術の発達は、交通事故による犠牲者数を大幅に減少させるだけでなく、道路容量を向上させる効果があると期待されている¹⁾。交通流量を向上させる理由は、CAV の持つ CACC (Cooperative Adaptive Cruise Control) 技術にある。従来は、ACC (Adaptive Cruise Control) という、自律的に前方車両に追従して走行する技術であったが、CACC は、ACC に通信技術を加えたもので、前方車両と相互に通信を行い速度などの情報を共有しながら追従して走行する技術である²⁾。これにより、必要以上に車間距離を開けることなく走行できるため、道路容量の向上が見込まれている。今後、自動運転車両 (CAV) と手動運転車両 (MV) が高速道路上に混在して走行する可能性があり、そのような道路状況において CAV が交通流量にどのような影響を与えるのか、CAV にどのような特性を持たせれば交通流量は向上するのか、など多くの研究がなされている²⁾³⁾。

交通流モデルとして、格子状のセル上で対象を表現し、時間、空間、状態がすべて離散量であるセルオートマトンモデル (CA モデル)⁴⁾、他車両の挙動を自車両に対する刺激として考え、追従挙動を微分方程式を用いて表現する追従モデル⁴⁾、車両の流れをマクロな視点で捉え、流体のように考える流体力学モデルなどがある⁵⁾。中でも、CA モデルはモデルの拡張がしやすく、対象のルール設定が簡単に行えるため、CAV と MV が混在する異種交通流のような複雑なルール、条件、挙動を表現する上で適したモデルとなっている。そのため、本稿でもこの CA モデルを用いることにする。

交通流を向上させるための基本的な方針は 2 つ挙げられる。まず 1 つが、前述のとおり CACC 技術を活かして道路容量を向上させることである。既存の研究で

は、CAV の専用車線を設ける方法²⁾ や、CAV に新たな車線変更ルールを追加することで、積極的に CAV の隊列を組ませる方法⁶⁾ などが提案されており、特定の条件下では道路全体の平均交通流量が向上したという結果が報告されている²⁾⁶⁾。もう 1 つの方針は、渋滞を解消、または緩和することである。²⁾⁶⁾ で行われている方法では、渋滞を解消するための直接的な対処はされていない。本研究では、CAV の持つ通信機能を利用して渋滞は解消されるか、またその結果交通量の向上が見られるかを検証するため、CAV の走行情報を利用した渋滞解消のための制御方法を検討する。また、実際にシミュレーションを行った結果を基に、検討手法による制御が交通流に与える影響について考察する。

2 問題設定

2.1 Two-state Safe-speed セルオートマトンモデル (TS モデル)

CA モデルとは、格子状のセルと単純な規則による、時間、空間、状態が全て離散量で表されるモデルである。この CA モデルは速度決定ルールと車線変更ルールを各車両に持たせ、1 タイムステップずつ全ての車両の速度・位置・走行車線を更新するモデルである。CA モデルを用いると、CAV と MV が混在する異種交通流のような複雑な設定であっても、他のモデルより簡単にルール設定を行うことができ、自由流、同期流、渋滞流という、3 つの特徴的な交通流も再現することが可能である⁷⁾。

Tian⁸⁾ らは、実際の交通流ダイナミクスを再現するために、CA モデルの拡張である TS モデル (Two-state Safe-speed CA モデル) を提案した。本研究はこの TS モデルを用いて交通流を再現する。

2.1.1 セルオートマトンモデル (CA モデル) の基本的な考え方

交通現象だけでなく、生命科学現象、経済現象など、膨大かつ複雑な要素が絡み合う現象を解析の対象とする際、よく用いられるモデルがセルオートマトンモデ

ル (CA モデル) である。CA モデルのメリットは、他のモデルと比べて拡張するためのルール設定が容易であることや、全てが離散量であるため計算機でのシミュレーションが比較的容易に行えることなどが挙げられる。交通流に限定すると、車両情報、道路情報、運転手の心理的特性など様々な要素が互いに影響を及ぼし合い、交通現象を引き起こしているため、これらを微分方程式や流体力学で解析するのは極めて困難である。CA モデルはこのような複雑な設定を、本質を失わない程度に単純化できる。具体的には、車両を、セル上をタイムステップで動く離散的な粒子の流れであると考え、ある速度決定のルールに基づいて、1 タイムステップごとに速度と位置が更新される。

交通流の状態を表すときに用いる最も基本的な物理量は、速度、密度、交通流量である。速度 (velocity) は車両の速さのことであり、CA モデル上では1 タイムステップの更新で移動するセル数と定義される。例えば、車両の現在のセル上の位置が x 、速度が v である場合、1 タイムステップ更新後の車両の位置 x' は

$$x' = x + v \quad (1)$$

で表される。密度 (density) は、道路上の単位セルあたりの車両数と定義される。道路のセル長を L_{road} 、車両数を N 、車両のセル長を L_{veh} とすると、密度 ρ は

$$\rho = \frac{NL_{veh}}{L_{road}} \quad (2)$$

として表される。交通流量とは、ある計測タイムステップ内に道路上の1地点を通過する車両の台数と定義される。ある観測地点において、 T 時間で通過した車の総台数を m 台とすると、 T 時間での交通流量 Q は

$$Q = m \quad (3)$$

と表される。また、交通流量から交通流率 (flow rate) を求めることができる。交通流率は、単位時間あたりに換算された交通流量と定義される。 T 時間での交通流量 Q を用いて、交通流率 q は

$$q = \frac{Q}{T} \quad (4)$$

と表される。ここで、観測する一定区間内に存在する車両の平均速度を \bar{v} とすると、車両が時間 t から $t + \Delta t$ までに進む距離は、十分小さな時間 Δt に対して $\bar{v}\Delta t$ と近似することができる。また、区間内に存在する車両密度 ρ は、十分小さな時間 Δt に対しての変化量は十分に小さく、一定の密度であるとみなすことができる。よって、 Δt 時間の交通流量 Q 、交通流率 q は

$$Q = \rho\bar{v}\Delta t \quad (5)$$

$$q = \rho\bar{v} \quad (6)$$

で求めることができる。

2.1.2 TS モデルの各種ルール

ここでは、MV に対する TS モデルの速度決定ルールと車線変更ルールを説明する。1 タイムステップごとに速度決定ルールですべての車両の速度と位置を更

新し、車線変更ルールで車両が車線変更するか否かの判別をし、車線変更をするなら車線変更先の位置、しないなら現在の車線にとどまる。また、1 タイムステップは実世界の1秒に対応し、人間の反応速度も1秒と仮定している。以下に3つのステップからなる速度決定ルールを示す。

1. 暫定的な速度決定

$$v'_{det} = \min(v + a, v_{max}, d_{anti}, v_{safe}) \quad (7)$$

2. 確率的な減速

$$v' = \begin{cases} \max(v'_{det} - b_{rand}, 0) & (\text{with probability } p) \\ v'_{det} & (\text{otherwise}) \end{cases} \quad (8)$$

3. 車両位置更新

$$x' = x + v' \quad (9)$$

ステップ1では一時的な速度を決める。 v, a は車両の現ステップでの速度、加速度、 v_{max} は車両の最高速度である。 d_{anti} は前方車両が進んだときの予想される前方車間距離、 v_{safe} は簡略化 Gipps モデルで定義された、前方車間距離が d 、前方車両の速度が v_l のときの車両の最高安全速度の制限を考慮した安全速度、 v_{anti} は前方車両の次のタイムステップにおける予想される速度であり、それぞれ次式のように定義される。

$$d_{anti} = d + \max(v_{anti} - g_{safety}, 0) \quad (10)$$

$$v_{safe} = \left[-b_{max} + \sqrt{b_{max}^2 + v_l^2 + 2b_{max}d} \right] \quad (11)$$

$$v_{anti} = \min(d_l, v_l + a, v_{max}) \quad (12)$$

d_{anti} は前方車両が次のステップで動き、実際には現在の車間距離以上に進めることができることから TS モデルに導入された。 g_{safety} は人間の認知機能の限界を考慮した事故を回避するためのパラメータであり、 $g_{safety} \geq b_{rand}$ の制約がある。 $[x]$ は x に最も近い整数を返す関数である。 d_l は前方車両の前方車間距離である。

ステップ2では、MV 運転手のランダムな加減速性を考慮して、MV は確率 p で b_{rand} 減速する。ランダム減速度 b_{rand} とランダム減速確率 p は次の式で定義される。

$$b_{rand} = \begin{cases} a & (v < b_{defense} + [d_{anti}/T]) \\ b_{defense} & (\text{otherwise}) \end{cases} \quad (13)$$

$$p = \begin{cases} p_b & (\text{if } v = 0) \\ p_c & (\text{else if } v \leq d_{anti}/T) \\ p_{defense} & (\text{otherwise}) \end{cases} \quad (14)$$

$p_{defense}$ は以下の式で定義されるロジスティック関数である。

$$p_{defense} = p_c + \frac{p_a}{1 + e^{\alpha(v_c - v)}} \quad (15)$$

Table 1: Parameters in TS model.

Parameters	L_{cell}	L_{veh}	v_{max}	T	a
Units	m	m	m/s	s	m/s ²
Values	0.5	15	27	1.8	0.5
Parameters	b_{max}	$b_{defense}$	P_a	P_b	P_c
Units	m/s ²	m/s ²	-	-	-
Values	3	1	0.85	0.52	0.1
Parameters	g_{safety}	v_c	α		
Units	L_{cell}	L_{cell}/s	s/ L_{cell}		
Values	20	30	10		




Fig. 1: Lane-change model.

T は安全時間間隔, α, v_c はそれぞれロジスティック関数の勾配と中点である. v_{safe}, α, v_c はモデル内での速度決定の際に, 急激な減速や変動を避けるために導入された値である. TS モデルでは, 運転車両は通常状態と防御の状態の2つの状態があり, $v > d_{anti}/T$ が満たされたときに防御状態となる. $b_{defense}, p_{defense}$ はそれぞれ防御の状態における減速度と減速確率である. また, $[x]$ は, x 以下の最大の整数を返す関数である. TS モデルのパラメータを Table1 に示す.

次に TS モデルの車線変更ルールについて説明する. 車両は現在走行している車線と, その左, もしくは右の車線において, 以下の3つの条件式が同時に満たされたとき, 車線変更確率 P_{lc} で左, または右の車線に車線変更を行う.

$$d < \min(v + a, v_{max}) \quad (16)$$

$$d^x > \min(v + a, v_{max}) \quad (17)$$

$$d_{back}^x > v_{max} \quad (18)$$

ここで, d^x は車線変更先の前方車間距離, d_{back}^x は車線変更先の後方車間距離である. また, 式 (16)(17) は車線変更した方が現在の車線にいるよりも運転状況が良くなるというインセンティブ条件を示している. 式 (18) は車線変更先の後方車間距離が安全かどうかを確認する条件である. すなわち, この車線変更モデルでは, 車線変更先の安全が確保されていて, 車線を変更したほうが自車の速度を速くできるのであれば, 確率 P_{lc} で車線変更するというルールである.

まとめると, TS モデルは1タイムステップで, 暫定的な速度決定→確率的な減速→車両位置更新→車線変更の順に車両の速度と位置を更新していく. 車線変更ルールで用いられている変数の関係の模式図を Fig.1 に示す.

2.1.3 Connected Autonomous Vehicle (CAV) の速度決定ルール

Ye ら²⁾ は TS モデルをもとに, 交通流に CAV を含めることで, 複数車線の異種交通流モデルへと拡張した. CAV は MV とは異なり, センサーの範囲 DR (Detection Range) にある車両を検知できる. ここでは, CAV の速度は DR の範囲内で完全に停止できるほど十分に低いと仮定する. CAV は, センサーの情報や通信で得た情報を使って MV よりも早く周りの状況に対応できる. このことを考慮して, CAV の最高速度

Table 2: Parameters in determining CAV's speed.

Parameters	DR	CR	P_{lc}	T_{ACC}	K_1	K_2	a_{max}
Units	m	m	-	s	s ⁻²	s ⁻¹	m/s ²
Values	120	300	0.4	0.5	0.14	0.9	3

v_{max}^{CAV} , 安全速度 v_{safe}^{CAV} , 予想される前方車間距離 d_{anti}^{CAV} は以下の式で定義される.

$$v_{max}^{CAV} = \left[\sqrt{2b_{max}DR} \right] \quad (19)$$

$$v_{safe}^{CAV} = \left[-b_{max} + \sqrt{b^2 + v_{front}^2 + 2b_{max} \min(d_{anti}, DR)} \right] \quad (20)$$

$$d_{anti}^{CAV} = \begin{cases} d + v_{anti} & (\text{if } v_l \text{ is a CAV}) \\ d + v_{anti} - b_{defense} & (\text{otherwise}) \end{cases} \quad (21)$$

CAV は MV に追従して走行する際に, 人間の運転行動には予測不可能な部分があるため, 常に最悪のケースを想定して走行する. よって, CAV は前方車両が MV であるときに防御の状態を維持することを前提としている. つまり, 式 21 の結果は, 前方車両が CAV の場合に大きくなる. CAV の場合, 通常の車両に比べて比較的正確な位置や速度の情報を得ることができるため, 人間の不確定要素のための安全距離は適用されない. 次ステップにおける前方車両の予想される速度 v_{anti}^{CAV} は以下の式で求められる.

$$v_{anti}^{CAV} = \min(d_l, v_l + a_{ACC}, v_{max}, v_l) \quad (22)$$

CAV の自律走行時の加速率 a_{ACC} は以下の式で求められる.

$$a_1 = K_1(d - vT_{ACC}) + K_2(v_l - v) \quad (23)$$

$$a_{ACC} = \lfloor \max(\min(a_1, a_{max}), -b_{max}) \rfloor \quad (24)$$

K_1, K_2 はパラメータであり, T_{ACC} は車両同士で通信するときにかかる時間差である. CAV は, CR(Connected Range) 内の走行状態を知ることが出来る. v_{li} は前方 CR 以内に存在する CAV の平均速度である. 前方 CR 以内に CAV が存在しない場合, v_{max} が適用される.

よって, CAV の場合, 速度決定ルールの式 7 は以下の式に置き換わる.

$$v^{CAV} = \min(v + a_{CAV}, v_{max}^{CAV}, d_{anti}^{CAV}, v_{safe}^{CAV}) \quad (25)$$

また, CAV はランダム減速を行わないため, v^{CAV} が最終的な CAV の速度である. TS モデルの CAV 特有のパラメータを Table2 に示す.

2.2 本研究で扱う問題

本研究では, 道路内部に中央制御局という, 道路上を走行している全ての CAV と相互に通信を行うことができる装置を設ける. 以下に中央制御局についての基本的な設定事項を示す.

- 中央制御局は全ての CAV に対して, 減速の指示が可能である.
- MV の走行情報は取得できない.
- 中央制御局が集約する情報は, 全 CAV の位置情報 (道路上の位置, 走行中の車線) のみである.




Fig. 2: Sample basicmap($P_{CAV} = 20\%$).

- 中央制御局 - CAV 間の通信にかかる時間は極めて小さく、1 タイムステップ間で十分情報のやり取りができる。

本稿では、この中央制御局の機能を利用して、渋滞が発生したときに、それを解消するようにする制御法を検討する。

3 検討する制御手法

3.1 高速道路の交通流に見られる現象

高速道路における交通流は、密度が上昇するにつれて自由流から同期流、そして渋滞流へと変化していく。これらの交通流の状態を基本図を用いて説明する。基本図とは、Fig. 2 のように、横軸に車両密度、縦軸に交通流量、または交通流率をとり、交通量と密度の関係を表した図のことである。

- 自由流...主に低密度域で見られる、車両が自ら速度を選択できるほど車間距離に余裕があり、結果としてほとんどの車両が最高速度に近い速度で走行している状態。基本図で、密度の上昇に伴って交通流量も線形的に上昇しているところで見られる交通流である。
- 同期流...主に中密度域で見られる、車両が互いに影響を及ぼし合いほとんど同じような速度で走行している状態。基本図で、交通流率が最大になった後、線形的に減少している部分で見られる交通流である。
- 渋滞流...主に高密度域で見られる、十分な車間距離を確保できないため、前方車両の影響を大きく受け減速しやすくなっており、停止している車両も存在している状態。基本図で、交通流率が急激に減少しているところから、より密度が高いところで見られる交通流である。

基本的に、渋滞は同期流から渋滞流へ変化する際に発生し始める。同期流の時点では、道路は既に過密度の状態であり、車両の僅かな加減速でも後方に大きく振動するように伝わる。さらに密度が上昇すると、道路容量の限界に達したことで適切な車間距離を保つことが困難となり、速度を急激に落とす車両も現れるようになる。

3.2 低速度区間

渋滞が起きているときの車両密度において、道路上を走行する車両が渋滞時、どのような走行をしてい




Fig. 3: Sample heatmap($P_{CAV} = 20\%$, $density = 30\%$).

るかをヒートマップを用いて説明する。ヒートマップとは、Fig.3 のように、2次元データに格納されている各数値を、色の強弱や濃淡で表現した可視化グラフの一種である。本稿では、縦軸にタイムステップ (0step ~ 3599step)、横軸に道路上の座標 (0cell ~ 4599cell) をとることで、各車線上を走行している車両の速度の時間経過を表す。あるセル上に車両がいる場合、そのセルを車両速度に対応する色でプロットし、車両がない場合は何もプロットしない。速度が大きいほど赤黒い色に、反対に速度が小さいほど青黒い色でマッピングされる。これを1 タイムステップずつ行うことで、車両の速度変化などが読み取れる。

Fig.2 より、CAV 占有率が 20% の場合、密度 30% の時点では既に渋滞流へ変化している。Fig.3 を見ると、渋滞時、青黒い色でプロットされた低速度の車両帯が、時間が経つにつれ後方へ移行していることが確認できる。本稿ではこれを低速度区間と呼ぶことにする。この低速度区間は、通常のシミュレーションでは解消されることはほとんどなく、長い時間交通流を阻害し続けている要因である。

3.3 渋滞解消のための制御

渋滞の定義は、その高速道路の管理者によって独自に定義されている。例えば、NEXCO 中日本は、渋滞を「時速 40km 以下で低速走行あるいは停止発進を繰り返す車列が、1km 以上かつ 15 分以上継続した状態」と定義している⁹⁾。本稿では、速度 10cell/step 以下で走行している車両で構成される低速度区間が、900step 以上継続して発生している状態と定義する。

低速度区間が解消されない原因は、低速度区間から抜け出す車両と入り込む車両の数が同程度であるためである。Fig.4 のように、あるタイムステップ t において、車両 A・B・C が低速度であり、低速度区間の先頭にあたる車両 A が、前方車間距離が大きくなったため速度を上げられる状態になったとする。一方、車両 C の後方にある車両 D は、前方で低速度区間が発生していることを知らずに、車両 D が速度を落とさずそのまま高速度で走行している。次のタイムステップ $t+1$ において、車両 A が低速度区間から脱出したものの、車両 D は、前方車両 (車両 C) がほとんど前進しないため、衝突を恐れて低速度区間の手前の位置で大きく減速する。結果的に、車両 D も低速度となり、車両 B・C・D による低速度区間が発生してしまう。このような現象が繰り返されることによって低速度区間が解消されず、交通流を悪化させてしまう。Fig.3 で見ても、低




Fig. 4: Low-speed section in transition.

速度区間の後方にいる車両のほとんどは、同車線の前方に低速度区間が発生しているにも関わらず、最高速に近いスピードで走行していることが分かる。低速度区間が遷移する様子を簡略化して表した模式図を Fig.4 に示す。

以上のことから、低速度区間が解消されるためには、その区間から抜け出す車両の数よりも、入り込む車両の数が少なくなるようにすればよい。そこで、本稿では道路内部に中央制御局という、道路上を走行している全ての CAV と相互に通信を行うことができる装置を設け、CAV の走行情報から低速度区間の位置を予測し、その後方にいる CAV を減速させることで渋滞を解消するという方法を検討する。以下に、中央制御における制御局と CAV に関する詳細な仕様をまとめる。

まず、各 CAV に対して減速率 r_{dec} ($0.8 \leq r_{dec} \leq 1.0$) を割り当てる。減速率 r_{dec} の数値は、通常は全て 1.0 で設定されている。また、TS モデルにおける速度決定ルールに以下の式を追加する。

$$v^{CAV} = \lfloor v^{CAV} \times r_{dec} \rfloor \quad (26)$$

式 26 により得られた最終的な速度 v^{CAV} が基準値 10cell/s 以下であった場合、CAV は中央制御局に自車の位置（車両後尾位置、車線番号）を送信する。Fig.3 でも見られるように、低速度区間にプロットされた青黒い色は、カラーバーの数値で見ると約 10 以下である。約 10cell/s 以下の速度の車両によって低速度区間が構成されていることから、基準値を 10cell/s と設定する。1 タイムステップ間に、全ての低速度の CAV から車両位置情報を受信すると、制御局はまず各車線ごとの低速度区間の最後尾位置を予測する。中央制御局は MV の走行情報を得ることはできないため、低速度車両帯の後尾に最も近い CAV を推定し、その車両を低速度区間の最後尾車両と仮定する。次に、それぞれの車線で推定した低速度区間の最後尾位置から、後方 $x[\text{cell}]$ ($x_1 \leq x \leq x_2$) にいる CAV に対して、以下の式により減速率を与える。

$$r_{dec} = \frac{0.2}{x_2 - x_1} \times x + \frac{-x_1 + 0.8 \times x_2}{x_2 - x_1} \quad (27)$$

式 27 は、 $x = x_1$ に対して $r_{dec} = dec$ 、 $x = x_2$ に対して $r_{dec} = 1.0$ となる一次関数である。つまり式 27 は、車両が低速度区間に近い位置にいるほど大きく減速させ、反対に遠い位置にいる車両はあまり減速させないという機能を果たす。前述のとおり、上記のルールで減速させる対象は低速度区間の後方 $x_1\text{cell} \sim x_2\text{cell}$ 内にいる CAV である。最後に、減速率を全て 1.0 で初期化し、低速度区間の推定に用いた、低速度の CAV の位置情報も次ステップに引き継がず、初期化してタイムステップを更新する。




Fig. 5: Heatmap ($P_{cav} = 20\%$, $density = 30\%$) without central control station.

4 数値実験

対象とする道路は 4 車線高速道路で、合流部分はなく、左端の車線から順に、LANE1, LANE2, LANE3, LANE4 とする。また、道路の長さ l_{road} は 2.5km (5000 セル) とする。道路には車両が道路長を越えたとき、道路の開始位置に戻るという周期境界条件を設定する。車両の初期条件は、速度はすべて 0 で設定し、車両位置は均一初期配置、CAV の数は (車両数 $\times P_{cav}$) で求め、MV と CAV をランダムに配置する。ここで、 P_{cav} は高速道路に存在する全車両数に対する CAV の車両数の割合であり、均一初期配置は、道路に車両間距離が均等になるように車両を配置する初期配置である。また、シミュレーション時間は 1 時間 (3600 タイムステップ) とする。シミュレーション開始時点では、ほとんどの車両が低速度であるため、中央制御局による低速度区間の予測、及び CAV への減速率送信は、500 タイムステップ以降に行うものとする。

シミュレーションは 2 種類行い、それぞれヒートマップ、基本図を結果として示す。ヒートマップを出力するシミュレーションでは、CAV の道路占有率 P_{cav} を 20%, 80%, それぞれの占有率に対して車両密度を 30%, 35% と設定し、中央制御局がある場合とない場合のシミュレーションを行う。中央制御局がある場合は、さらにパラメータ (x_1, x_2) を、(500, 1500), (500, 2500), (500, 3500) と変化させる。

基本図を出力するシミュレーションでは、密度を 1% ~ 70% まで 1% 間隔で増加させながら交通流率の変動をプロットする。CAV の占有率 P_{cav} を 20%, 80% と変化させ、各占有率に対して、中央制御局がある場合とない場合のシミュレーションを行う。

5 考察

Fig.5~Fig.8, 及び Fig.13~Fig.16 は、CAV 占有率 20% における実験結果である。Fig.5 や Fig.13 に見られるように、中央制御局がない場合、CAV の割合が低いと密度 30% の時点で既に渋滞流に突入しており、低速度区間が長時間発生している。それに対して中央制御局を設けた Fig.6~Fig.8 を見ると、青くプロットされた車両帯がシミュレーションの途中で途切れたり、薄くなる様子が確認できる。これは、低速度区間に入り込む車両数が出て行く車両数を下回る瞬間が存在したためである。中央制御局によって低速度区間の後方を走行する CAV が減速し、周囲の MV もそれに合わせて減速や車線変更することで、低速度区間の解消・緩和




Fig. 6: Heatmap ($P_{cav} = 20\%$, $density = 30\%$) with central control station(deceleration section is 500cell to 1500cell).




Fig. 8: Heatmap ($P_{cav} = 20\%$, $density = 30\%$) with central control station(deceleration section is 500cell to 3500cell).




Fig. 7: Heatmap ($P_{cav} = 20\%$, $density = 30\%$) with central control station(deceleration section is 500cell to 2500cell).




Fig. 9: Heatmap ($P_{cav} = 80\%$, $density = 35\%$) without central control station.

に繋がったと考えられる。Fig.6~Fig.8では、低速度区間の遷移の様子に大きな違いは現れなかった。交通流量で比較すると、Fig.13やFig.14では、密度24%~26%の間に渋滞流へ変化しているのに対し、Fig.15とFig.16では、密度25%~29%の間に渋滞流へ変化しており、密度25%あたりでの交通流量は約8000台増加した。このことから、CAVの割合が低い場合、中央制御局によって渋滞が解消・緩和されることが可能で、特に減速させる区間が長い場合、中密度での交通流量の向上も可能であると言える。

Fig.9~Fig.12, 及び Fig.17~Fig.20は、CAV占有率80%における実験結果である。CAV占有率が大きい場合、MVによるランダム減速の影響が小さくなるので、Fig.17のように中央制御局がない場合も、急激に交通量が減少することはなくなる。Fig.9でも見られるように、大きく停滞している車線はLANE4だけであり、LANE3はあまり渋滞が発生しなかった。Fig.10~Fig.12で比較すると、Fig.11でLANE4のみ交通流が大きく停滞していることが分かる。それ以外は、低速度区間の発生が部分的に見られるだけであった。これは、CAVの割合が大きい場合、減速させるCAVの台数も大きくなるので、ほとんどの車両は全体的に速度を控えて走行することになる。つまり、CAVの割合が大きい場合は、渋滞が発生しにくい、または低速度区間が長くなりにくいメリットがある反面、減速区間にCAV車両が集中するとその車線全体が大きく停滞するデメリットもあると考えられる。Fig.17~Fig.20からは、中密度域における交通流量の変化はあまり見られず、高密度域では中央制御局を設けた場合の交通流量

が約5000台減少していた。以上より、CAVの割合が大きい場合、中央制御局によって渋滞解消・緩和に大きく影響したが、減速区間に多くのCAVが走行している可能性が高く、必要以上に多くの車両を減速させてしまうことによって、交通流量の増加が見られなかったと言える。

6 まとめ

本研究では、渋滞時に見られる低速度区間を解消するために、中央制御局によるCAVの走行情報を利用した低速度区間の後方を走行するCAVへの減速指示方法を検討し、中央制御が交通流に与える影響をシミュレーションによって検証し、考察した。中央制御局を設けた場合、CAVの割合が小さい場合も大きい場合も、低速度区間の解消や緩和の様子が見られた。CAVの割合が小さい場合は、少ない台数のCAVでも周囲の交通流を制御することが可能であり、中密度での交通流量の増加も確認された。CAVの割合が大きい場合は、必要以上に多くのCAVを減速させる可能性があり、交通流量の増加は見られなかった。

今後の課題として、CAVを必要以上に減速させないために、CAVが速度決定ルールによって算出した暫定速度が、低速度の基準値(10cell/s)以下であった場合、減速を行わないという機能が必要である。もしくは、中央制御局が減速率を与える際に、減速させるCAVに台数制限を設ける必要も考えられる。また、本稿で述べた制御手法は、道路上に低速度区間が1つ発生している場合を想定しているため、道路上に低速度区間が複数存在している場合の制御方法も検討する必要がある。さらに、強化学習などの機械学習手法を用いて、減速




Fig. 10: Heatmap ($P_{cav} = 80\%$, $density = 35\%$) with central control station(deceleration section is 500cell to 1500cell).




Fig. 11: Heatmap ($P_{cav} = 80\%$, $density = 35\%$) with central control station(deceleration section is 500cell to 2500cell).

区間の長さや減速率などのパラメータを変化させながら学習していくことで、より最適に近いパラメータを発見できる可能性も考えられる。

参考文献

- 1) Y. Li, H. Wang, W. Wang, L. Xing, S. Liu, and X. Wei, "Evaluation of the impacts of cooperative adaptive cruise control on reducing rear-end collision risks on freeways," Accident Analysis Prevention, vol.98, pp.87–95, 2017.
- 2) L. Ye and T. Yamamoto, "Impact of dedicated lanes for connected and autonomous vehicle on traffic flow throughput," Physica A: Statistical Mechanics and its Applications, vol.490, pp.269–277, Dec. 2015.
- 3) K. Ma and H. Wang, "Influence of exclusive lanes for connected and autonomous vehicles on freeway traffic flow," IEEE Access, vol.7, p.50168–50178, 2019.
- 4) 只木進一, 菊池誠, 杉山雄規, 湯川論, "交通流の科学," 日本物理学会誌, vol.55, no.3, p.166–171, 2000.
- 5) 宮入洋介, "交通流解析における流体モデルとセルオートマトンモデルの比較," 2003.
- 6) 鶴藤勝太, "通信機能を持つ自動運転車両の特性が交通流に与える影響に関する考察," 修士論文, 京都工芸繊維大学大学院, Feb. 2022.
- 7) 西成活裕, "交通流のセルオートマトンモデルについて (特集交通流の数理)," 応用数理, vol.12, no.2, pp.128–139, 2002.
- 8) J. Tian, G. Li, M. Treiber, R. jiang, N. Jia, and S. Ma, "Cellular automaton model simulating spatiotemporal patterns, phase transitions and concave growth pattern of oscillations in traffic flow," Transportation Research Part B, vol.93, pp.560–575, 2016.
- 9) 渋滞の定義は? , NEXCO 中日本 (オンライン), 入手先 <<https://highwaypost.cnexco.co.jp/faq/traffic/rule/345.html>> (参照 2023-2-11) .




Fig. 12: Heatmap ($P_{cav} = 80\%$, $density = 35\%$) with central control station(deceleration section is 500cell to 3500cell).




Fig. 13: Basicmap ($P_{cav} = 20\%$) without central control station.




Fig. 14: Basicmap ($P_{cav} = 20\%$) with central control station(deceleration section is 500cell to 1500cell).




Fig. 15: Basicmap ($P_{cav} = 20\%$) with central control station(deceleration section is 500cell to 2500cell).




Fig. 16: Basicmap ($P_{cav} = 20\%$) with central control station(deceleration section is 500cell to 3500cell).




Fig. 17: Basicmap ($P_{cav} = 80\%$) without central control station.




Fig. 20: Basicmap ($P_{cav} = 80\%$) with central control station(deceleration section is 500cell to 3500cell).




Fig. 18: Basicmap ($P_{cav} = 80\%$) with central control station(deceleration section is 500cell to 1500cell).




Fig. 19: Basicmap ($P_{cav} = 80\%$) with central control station(deceleration section is 500cell to 2500cell).

通信機能をもつ自動運転車が交通流量に及ぼす影響に関する考察

○山口瑛人 森禎弘 (京都工芸繊維大学)

Consideration about the influence of Connecting Autonomous Vehicle on traffic flow

*A. Yamaguchi and Y. Mori (Kyoto Insutitute of Technology)

Abstract— 後まわし In recent years, research and development has been conducted on connected autonomous vehicle (CAV) that have the ability to exchange various information with other vehicles, such as speed and acceleration. In the early stages of CAV deployment, CAV and Manual Vehicle (MV) will be mixed in the traffic flow. Implement features that can take advantage of the CAV's performance and consider their impact through simulation.

Key Words: Connecting Autonomous Vehicle

1 緒言

CAV (Connected Autonomous Vehicle) とは、他 CAV との通信機能を持ち、道路状況や車両の速度や加速度といった情報を共有し、その情報を活用して走行する自動運転車のことである。自動運転技術やネットワーク技術、人工知能、センサー技術など様々なテクノロジーの急速な発展により CAV の研究が国内外で盛んに行われている。自動運転技術が発達すると、道路容量の向上に大きく貢献できると考えられている。その要因の一つとして CACC (Cooperative Adaptive Cruise Control) が挙げられる。CACC とは従来の ACC (Adaptive Cruise Control) というセンサーによって前方車両を追従する機能に加えて、前方車両と通信し前方車両の加減速などの情報を受け取るにより適切な車間距離を維持する機能である¹⁾。

CAV の普及が始まった初期段階において道路交通は、CAV と従来の手動で運転する通常車両 (Manual Vehicle) が混在することが予想される。既存の研究により、CAV の普及率が低い場合、CAV の性能が活かしきれないことが指摘されている²⁾。また、先行研究により、CAV のみが走行可能である CAV 専用車線を設定し CAV を CAV と MV の混合交通からさせることによって、CAV の普及率が低い状況下においても CAV の性能を活かし交通流量が向上することがわかっている³⁾。しかし、CAV 専用車線の設定は一般車両の走行可能な車線数が減少の減少を意味し、CAV 専用車線に十分な車両が存在しない場合は交通流量が下がってしまうデメリットがある。適切な CAV 普及率に対して適切な CAV 専用車線の本数を設定しなければ交通渋滞を引き起こし、道路全体の交通流量が下がることが指摘されている³⁾。そのデメリットを緩和するため CAV を左車線に集める機能をもたせ、疑似的に CAV 専用車線を構成しようとした研究がある。しかし、交通流量の向上は確認されていない⁴⁾。

CAV 間の車間距離は MV の場合より短くなる。この CAV の特性を活かすためには CAV が前後に並ぶ連結状態が望ましい。本稿では疑似的な CAV 専用車線の構成と CAV の連結の 2 つのアプローチによって交通流量を向上させることを考え、CAV に追加した機能がど

のように交通流量に影響を与えるかを考察する。

本論文は 2 章で具体的な問題設定や交通流を表現するモデルについて、3 章で CAV に追加する機能を実装するための新たな車線変更ルールについて説明し、4 章で本研究における数値実験の条件設定と結果を示し、5 章で考察を行う。

2 問題設定

同車線において CAV の連結が発生することによりはじめて CAV の持つ通信機能が有効に活用され、交通流量が向上する。そのために車線変更に必要なルールを追加することによって、CAV の動作を制御する。CAV の連結を促す方法として、鶴藤は 2 車線の高速道路の状況下で以下の 2 つを提案し実装した⁴⁾。

- CAV が 1 つの車線に集まる。
- CAV が連結した場合、車線変更を行わず維持する。

しかし、数値実験の結果、交通流量の向上は確認されなかった。これは特に前者の機能を十分に活用するには、道路の長さや車線数などの十分な道路資源が必要であると考えられる。そこで、本研究では 4 車線に拡張し、数値実験を行うことでその影響を調べる。本章では数値実験に用いる交通流モデルとどのような解析を行うかを説明する。

2.1 Two-state Safe-speed モデル (TS モデル)

実際の交通流ダイナミクスにはメタ安定状態、交通振動、相転移などがある。メタ安定状態とは、車両が過密度で走行しておりわずかな減速によって均衡が崩れてしまう不安定な状態である。交通振動とは、車両のわずかな加速や減速が後方車両に振動するように伝わる現象である。相転移とは、自由流から同期流、同期中から渋滞流などの相が移り変わる現象である。このような交通流ダイナミクスを再現するために、Tian らは Two-state Safe-speed モデル (TS モデル) を提案した⁵⁾。また、Ye らは TS モデルの交通流に CAV を含めた混合交通流モデルへと拡張した³⁾。TS モデルとは、セルオートマトンモデル (CA モデル) を発展させたものであり、CA モデル上で表された車両の速度や車線変更を計算により決定する。

2.1.1 セルオートマトンモデル (CA モデル)

交通流を表現する方法としてよく用いられているモデルがセルオートマトンモデル (CA モデル) である。交通流は車両情報や道路情報、運転手の心理など多数の要素が交通現象を引き起こしている。これらの複雑な絡み合いを計算式で解析することは困難を極める。CA モデルは、この事象を本質を失わない程度に単純化し、計算によって交通現象を解析することを可能にする。

CA モデルでは、道路を格子状のセルで表現する。また、時間、空間、状態量が離散量であり、車両をセル上で動く粒子として扱う。CA モデルは各車両がほぼ最高速で走行する自由流、前方車両と衝突しないため速度を調節しながら走行する同期流、車両が低速で走行する渋滞流の3つの特徴的な交通流を表現できる上、新たなルールを設定するといったモデルを拡張が容易である。

交通流の状態を表す時に用いる物理量として、時間、速度、密度、交通流量がある。時間は CA モデルにおいて離散量としてタイムステップで区切られる。速度は、1 タイムステップの更新で移動するセル数で定義される。つまり車両の現在位置を x 、速度を v とすると1 タイムステップによって更新される車両位置 x' は

$$x' = x + v \quad (1)$$

で表される (Fig.1 に示す)。




Fig. 1: Position update in CA model

密度 (density) は道路あたりの車両数で表される。今回用いる CA モデルでは車両に長さをもたせて複数セルをまとめて1つの車両として表現する。つまり、道路の全セル長を L_{road} 、車両のセル長を L_{veh} 、車両数を N とすると密度 ρ は

$$\rho = \frac{NL_{veh}}{L_{road}} \quad (2)$$

で表される。交通流量は計測タイムステップ間において道路のある1地点を通過した車両の台数で定義される。ある観測地点に計測タイムステップ T 時間の間に通過した車の台数を m とすると、 T 時間の交通流量 Q は

$$Q = m \quad (3)$$

と表される。交通流量から交通流率を求めることができる。交通流率とは、単位時間あたりの交通流量であり、すなわち単位時間あたりに道路の1地点を通過し

た車両の台数を表す。計測タイムステップ T 時間の間に通過した車の台数を m とすると、交通流率 q は

$$q = \frac{m}{T} \quad (4)$$

で表される。ある時刻 t における車両の平均速度 \bar{v} とする。ある車両が時刻 t から $t + \Delta t$ までに進む距離は、十分小さな Δt に対して、 $v\Delta t$ と近似できる。また、測定区間内の車両密度は十分小さな Δt において変化量は小さく、一定であるとみなす。よって、測定時間 Δt における交通流量は

$$Q = \rho \bar{v} \Delta t \quad (5)$$

で求められ、交通流率 q は、

$$Q = \rho \bar{v} \quad (6)$$

で求めることができる。

横軸に密度、縦軸に交通流量もしくは交通流率をとり、交通と密度の関係を示した図は基本図と呼ばれる。本論文では縦軸は交通流率を採用する。

2.1.2 TS モデルにおける速度決定及び車線変更

TS モデルは速度決定と車線変更の2つのステップがあり、1 タイムステップの更新の際に、速度決定ルールによって全車両の位置と速度を更新し、車線変更ルールによって車線変更するか否かを決定し、走行車線を更新する。1 タイムステップは実際の1秒に対応し、人間の反応速度も同じく1秒と設定している。速度決定は3段階に分かれている。各段階の速度決定ルールを示す。

1. 暫定的な速度決定

$$v'_{det} = \min(v + a, v_{max}, d_{anti}, v_{safe}) \quad (7)$$

2. 確率的な減速

$$v' = \begin{cases} \max(v'_{det} - b_{rand}, 0) & (\text{with probability } p) \\ v'_{det} & (\text{otherwise}) \end{cases} \quad (8)$$

3. 車両位置更新

$$x' = x + v' \quad (9)$$

第1段階では暫定的な速度を求める。 v 、 a は現在のタイムステップにおける車両の速度と加速度であり、 v_{max} は車両の最高速度である。 d_{anti} は前方車両が1 タイムステップ進んだ時に予想される前方車間距離である。 v_{safe} は前方車両と衝突しないための安全速度であり、それらは次式で定義される。

$$d_{anti} = d + \max(v_{anti} - g_{safety}, 0) \quad (10)$$

$$v_{safe} = \left[b_{max} + \sqrt{b_{max}^2 + v_{front}^2 + 2b_{max}d} \right] \quad (11)$$

ここで、 d は現在のタイムステップにおける前方車両との車間距離であり、 g_{safety} は人間の反射神経の限界を考慮した事故を回避するための安全を確保するパラ

メータである。 v_{anti} とは前方車両の 1 タイムステップ後の予想される速度であり、次式で定義される。

$$v_{anti} = \min(d_{front}, v_{front} + a, v_{max}) \quad (12)$$

$[x]$ は x に最も近い整数を返す関数である。 d_{front} , v_{front} は現在のタイムステップにおける前方車両の前方車間距離と速度である。

第 2 段階の確率的な減速は、人間は一定の速度で運転することは不可能であり運転中はわずかな加減速が行われているため、暫定的な速度 v'_{det} を確率 p で b_{rand} 減速させることでランダムな加減速を表現している。減速度 b_{rand} 及び減速確率 p は次の式で定義される。

$$b_{rand} = \begin{cases} a & (v < b_{defense} + \lfloor d_{anti}/T \rfloor) \\ b_{defense} & (\text{otherwise}) \end{cases} \quad (13)$$

$$p = \begin{cases} p_b & (\text{if } v = 0) \\ p_c & (\text{else if } v \leq d_{anti}/T) \\ p_{defense} & (\text{otherwise}) \end{cases} \quad (14)$$

T は安全のための時間間隔、 $\lfloor x \rfloor$ は x 以下の最大の整数を返す関数である。 b_{rand} では、通常状態と防御状態の 2 つの状態を表し、 $v \geq b_{defense} + \lfloor d_{anti}/T \rfloor$ であれば、より強い減速を行う。 $b_{defense}$ と $p_{defense}$ はそれぞれ防御的状态における減速度と減速確率であり、 $p_{defense}$ は以下の式で定義される関数である。

$$p_{defense} = p_c + \frac{p_a}{1 + e^{\alpha(v_c - v)}} \quad (15)$$

TS モデルのパラメータは表 1 のとおりである。

Table 1: Parameters in TS model

Parameters	L_{cell}	v_{max}	T	a	b_{max}
Units	m	m/s	s	m/s ²	m/s ²
Values	0.5	27	1.8	0.5	-3
Parameters	$b_{defense}$	p_a	p_b	p_c	g_{safety}
Units	m/s ²	-	-	-	L_{cell}
Values	1	0.85	0.52	0.1	20
Parameters	v_c	α			
Units	L_{cell}/s	s/L_{cell}			
Values	30	10			

CAV は MV と異なり、センサー範囲 DR (Detection Range) 内の車両を検知する。衝突しないために CAV は常に DR の範囲内で完全に停止することが可能な速度で走行する。このことを考慮して、CAV の最高速度 v_{max}^{CAV} 、安全速度 v_{safe}^{CAV} 、予想される前方車間距離 d_{anti}^{CAV} は以下の式で定義される。

$$v_{max}^{CAV} = \left\lceil \sqrt{2|b_{max}|DR} \right\rceil \quad (16)$$

$$v_{safe}^{CAV} = \left\lceil b_{max} + \sqrt{b^2 + v_{front}^2 + 2|b_{max}|\min(d_{anti}, DR)} \right\rceil \quad (17)$$

$$d_{anti}^{CAV} = \begin{cases} d + v_{anti}^{CAV} & (\text{if front is CAV}) \\ d + v_{anti} - b_{defense} & (\text{otherwise}) \end{cases} \quad (18)$$

CAV は前方車両が MV の場合は、人間の予測不可能な運転に対応できるように防御状態となり、車間距離を小さく見積もる。一方で、前方車両が CAV であるときは、通信によって得られた情報をもとに d_{anti}^{CAV} を計算する。 v_{anti}^{CAV} は前方 CAV の予測速度であり、次式で定義される。

$$v_{anti}^{CAV} = \min(d_{front}, v_{front} + a_{CAV}, v_{max}, v_{ave}) \quad (19)$$

v_{ave} は前方 CR (Connection Range) 内の CAV の平均速度であり、CR 内に CAV が存在しない場合は v_{max} が適用される。CAV の自律走行時の加速度 a_{CAV} は以下の式で定義される。

$$a_1 = K_1(d - vT_{ACC}) + K_2(v_{front} - v) \quad (20)$$

$$a_{CAV} = \lfloor \max(\min(a_1, a_{max}), b_{max}) \rfloor \quad (21)$$

K_1 , K_2 は ACC に関するパラメータであり、 T_{ACC} は CAV 同士が通信するときにかかる時間であり、CAV の通信性能を表す。CAV の速度決定においては、 v_{max}^{CAV} , v_{safe}^{CAV} , d_{anti}^{CAV} , a_{cav} , v_{anti}^{CAV} が MV の速度決定の際に用いる変数 v_{max} , v_{safe} , d_{anti} , a , v_{anti} に対応している。TS モデルの CAV 特有のパラメータは Table 2 のとおりである。

Table 2: Parameters of CAV in TS model

Parameters	DR	CR	P_{lc}	T_{ACC}	
Units	m	m	-	s	
Values	120	300	0.4	0.5	
Parameters	K_1	K_2	a_{max}		
Units	s ⁻²	s ⁻¹	m/s ²		
Values	0.14	0.9	3		

TS モデルにおいて、車線変更は速度決定ののちに以下の 3 つの式で定義される条件を満たした場合に、車線変更確率 P_{lc} で車線変更を行う。

$$d < \min(v + a, v_{max}) \quad (22)$$

$$d_{other} > \min(v + a, v_{max}) \quad (23)$$

$$d_{other}^{back} > v_{max} \quad (24)$$

ここで、 d_{other} は車線変更先の前方車間距離、 d_{other}^{back} は車線変更先の後方車間距離を表す。式 22 と式 23 は、共に条件を満たしたとき、現在の車間距離より車線変更先の車間距離のほうが大きく、早い速度を出すことができる状態を示すインセンティブ条件式である。式 24 は車線変更先の後方車間距離が十分とれているかを確認する条件式である。つまり、車線変更をしたほうが交通状況がよくなり状態かつ、車線変更した先で前方後方ともに安全が確保できている場合のみ車線変更を行うことができる。

2.2 解析事項

CAV には本章で説明した車線変更の条件式を変えた新たな車線変更ルールを適用することにより、交通流量にどのような影響が出るのかを考察する。解析するために計測時間内の交通流率の平均、CAV と MV それぞれの左右への総車線変更回数、CAV のうち連結している CAV の割合を百分率で表した CAV 連結率の平均、各レーンの車両のうち CAV の割合を百分率で表した CAV 連結率の平均を示す。密度を横軸、これらを縦軸とした計 4 つをグラフ化し、ルールを適用した場合の交通流を解析していく。

3 CAVの新たな車線変更ルール

鶴藤が提案した車線変更ルールの3つを4車線に拡張し実装する。ルールは以下のとおりである⁴⁾。

ルール1 車線変更先の前方車間距離と後方車間距離の安全が保たれていれば、必ず左へ車線変更する。

ルール2 左車線にいる場合、できるだけ車線変更しない。

ルール3 左車線にいる場合、通信機能を維持することを優先する。

これらはCAVを一番左の車線に集める、もしくは留めるルールである。これらのルールは条件式を変更することにより実装する。ルール1はCAVの車線変更条件において、左への車線変更の車線変更確率 p_{lc} を1にし条件式lc1を消去することで、前方及び後方の車間距離が十分であれば必ず車線変更する。ルール2は一番左の車線にいる場合、右への車線変更確率を $p_{cavlc} = 0.1$ と設定することにより、右車線への変更を抑える。ルール3は、一番左の車線にいる場合前方がCAV出ないときのみかつ条件式22~24を満たした場合のみ車線変更確率 p_{lc} で車線変更を行うことにより、CAVの連結を維持させる。これに加え、現在車線位置に依らずCAVの連結を維持するために以下のルール4及びルール5を実装する。

ルール4 前方車両がCAVでない場合のみ、車線変更を行う。

ルール5 前方車両及び後方車両が共にCAVでない場合のみ、車線変更を行う。

これらはルール3を拡張したものである。ルール4ではCAVの連結が発生した場合において、後方のCAVは車線変更を行わないが前方のCAVは車線変更を行うことが予想されるため、ルール5はより連結状態の維持を徹底させる車線変更ルールである。さらに、ルール1ではインセンティブ条件を確認せず車線変更を行っているため、自由流において不必要な車線変更を行い交通流を妨げることが考えられる。そこで、ルール1を発展させたものとして次の車線変更ルールを提案する。

ルール6 車線変更先の安全が確保されていて車線変更したほうが交通状態がよくなる場合は、必ず左へ車線変更する。

これは、条件式22~24の全てを満たしているなら車線変更確率 p_{lc} を1に設定することにより実装する。まとめると、ルール1~3及び6は左車線へCAVを集めるルールであり、ルール4、ルール5は現在の走行車線に依らずCAVの連結を維持するルールである。また、ルール1~3及び6は組み合わせることもでき、その場合さらにCAVを左車線に集める効果も高まると予想される。

4 数値実験

シミュレーション対象とする道路は4車線高速道路とし左端の車線から順にlane1~lane4とする。合流や出口はないものとする。道路の長さ l_{road} は2.5km(5000

セル)であり、道路の終端に車両が来た場合、道路の開始位置に戻る周期境界条件を設定する。車両の初期条件は、速度はすべて0であり、車両位置は道路に対して均一配置、CAVの数を(車両数 $\times P_{cav}$)で求め、ランダムにMVとCAVを配置する。シミュレーション時間は5600秒とする。シミュレーションの最初の数百秒間は過渡的な状態で、その後、定常状態となる。そこで、解析には最後の3600秒のデータを使用する。シミュレーションでは車両密度とCAV普及率 P_{cav} の2つを変化させる。車両密度 ρ は0.01~0.90まで変化させ、 P_{cav} は0.2~0.7まで変化させる。結果として、基本図、密度に対する総車線変更回数、密度に対する計測時間内の平均CAV連結率、密度に対する各車線の平均CAV占有率の散布図を示す。ルールを実装しない場合とlane1をCAV専用車線にした場合、第3章で説明したルール1~6を単独追加した場合、ルール1~3を組み合わせた場合、そしてルール6とルール2,3を組み合わせた場合の計15パターンの実験を行った。実験結果例として $P_{cav} = 0.3$ の場合において効果が表れたものを以下のFig.2~Fig.8に示す。




Fig. 2: Flow-density diagrams without rule changes




Fig. 3: Number of lane change diagrams without rule changes

5 考察

ルール変更を実装しない場合の基本図であるFig.2を見てみると、車両密度0~0.2までは交通流率が直線




Fig. 4: Flow-density diagrams under CAV dedicated lanes




Fig. 6: Flow-density diagrams for Rule 6 implementation




Fig. 5: Flow-density diagrams for Rule 1 implementation




Fig. 7: Flow-density diagrams for Rule 2 & Rule 6 implementation

的に増加している。この区間はすべての車両がほぼ最高速度で走行している自由流であるため、車両数に比例して交通流率が増加していく。その後車両密度 0.25 あたりまで減少する。この区間は同期流であり、局所的な渋滞が発生することにより車両が最高速度では走れなくなっている。そして同期流のメタ安定状態で速度が不安定になり点が広がり、急激に交通流率が下がる。その後車両密度 0.3 あたりから渋滞流となり交通流率が線形的に下降していく。図 3 は計測時間内で発生した総車線変更回数を示している。自由流のあいだは車線変更する必要がないため、車線変更はほとんど発生しない。しかし、メタ安定状態や渋滞流においては CAV は前方車両が CAV の場合車間距離が短くなることにより、積極的な車線変更を行い交通状態を改善させる。

lane1 を CAV 専用車線に設定した場合の基本図である Fig.4 を見ると、平均交通流率の最大値が低くなっている。これは、CAV 専用車線で通常車両が走行できないことにより他車線と比べて車両台数が少なくなっていることにより著しく交通流率が下がっているからである。一方で車両密度が中密度～高密度域において CAV 専用車線である lane1 の交通流率が大きく向上することにより、平均交通流率が向上している。今回のシミュレーション条件では P_{cav} は 0.3 以上の場合にお

いて CAV 専用車線設置のメリットのほうが大きくなる。特徴的なのは、lane1 の交通流率は車両密度 0.6 付近まで高い点であり、CAV 専用車線の交通容量の大きさがわかる。

次に、ルール 1 を追加した場合の基本図である Fig5 を見る。ルール変更なしの基本図と比較すると平均交通流率のピークの値は低くなっている。これは、前述のとおり自由流においてインセンティブ条件を満たさない交通状況を悪化させる車線変更を行っているからであると考えられる。一方で、中から高密度域において平均交通流率は向上していて、lane1 の交通流率も CAV 専用車線設置ほどではないものの高い値を保っている。

ルール 2～5 を単独で実装した場合は交通流率に大きな差は生まれなかった。

ルール 1 にインセンティブ条件を追加したルール 6 の結果を Fig.6 示す。ルール 1 に比べ自由流における交通流率の低下は発生しなかったが、中から高密度域の lane1 の交通流率は向上しなかった。ルールを追加しない場合と平均交通流率は変わらなかった。

疑似的に CAV 専用車線を設置する方針であるルール 1～3 を組み合わせた場合も平均交通流率は変わらなかった。

最後に、ルール 2 をルール 6 を組み合わせた場合の




Fig. 8: CAV occupancy diagrams for Rule 2 & Rule 6 implementation

結果である Fig.7 を見る．ルール変更なしと比較して低密度域においては交通流率は変わらず中から高密度域においてはわずかに交通流率が向上している．lane1 の交通流率も中密度域において少しの区間ではあるが高い値を維持している．Fig.8 を見ると，中密度域において lane1 の CAV 占有率が大きくなっていることがわかる．これにより，中密度域における lane1 の交通容量が向上していると考えられる．

6 結言

本研究では，CAV が 4 車線の混合交通流にどのような影響を及ぼすかを TS モデルにおける車線変更のルールを変更することにより検証した．ルール 1 を実装すると低密度域の交通流率は下がるものの，CAV 普及率が低い場合は中から高密度域の交通流率は改善した．しかしこの結果は CAV 専用車線の交通流率より全密度，全 CAV 普及率において低い．一方で，ルール 2 とルール 6 を同時に実装すると，低密度域は交通流率が低下せず中から高密度域においてはわずかに交通流率が増加する結果となり，デメリットがない交通量の向上に成功した．

今後の課題として，今回の研究ではタイムステップごとの細かい動きを追い切れていないため，速度のヒートマップなどを用いてミクロに交通流を解析する必要がある．また，今回のルールでは CAV が左車線に集まるが MV が左車線から抜け出せない状況が発生していたため，MV が車線変更を行うことができるように CAV の速度をコントロールするなどの方法も考えられる．

参考文献

- 1) Shladover, S., Su, D., and Lu, X. Y. : Impacts of cooperative adaptive cruise control on freeway traffic flow, Transportation Research Record: Journal of the Transportation Research Board Vol.2324, (2012)
- 2) Chen, D., Ahn, S., Chitturi, M. and Noyce, D.A. : Towards vehicle automation: Roadway capacity formulation for traffic mixed with regular and automated vehicles, Transportation Research Part B Vol.100, (2017)
- 3) Lanhang Ye and Toshiyuki Yamamoto: Impact of dedicated lanes for connected and autonomous vehicle on traffic flow throughput, Physica A: Statistical Mechanics and its Applications Vol.490, (2018)

- 4) 鶴藤 勝太：通信機能を持つ自動運転車両の特性が交通流に与える影響に関する考察, 京都工芸繊維大学大学院, (2022)
- 5) Junfang Tian, Guangyu Li, Martin Treiber, Rui jiang, Ning Jia, Shoufeng Ma. : Cellular automaton model simulating spatiotemporal patterns, phase transitions and concave growth pattern of oscillations in traffic flow., Transportation Research Part B Vol.93, (2016)

周期が異なる周期パターン間のカーネル関数について

○橋 完太 (工学院大学)

On a Kernel Function for Periodic Patterns with Different Periods

* K. Tachibana (Kogakuin University)

Abstract— This paper examines the application of kernel functions for analyzing acceleration patterns during walking. Walking is a periodic motion with variations in stride period and patterns among individuals and within individuals. Multiple channels of data collected simultaneously synchronize with the stride. Zhang et al. (1) provided a walking dataset obtained using accelerometers on five body segments and proposed a walker recognition method based on sparse representation and clustering of signature points in the time-acceleration domain. This paper explores kernel functions suitable for multi-channel walking data analysis and their potential for classification, prediction, anomaly detection, or pattern generation. Morgan and Noehren (2) used fast Fourier transform to analyze walking waveform patterns in individuals with patellofemoral pain. Ullrich et al. (3) proposed a method to detect walking from continuous inertial sensor data using harmonic frequencies. Jung et al. (4) presented a multi-class classification method for walking based on time-frequency representations and deep convolutional neural networks. These studies focused on frequency components and machine learning, but overlooked phase information and waveform differences. In other fields, Fourier transform has been successfully applied for image processing and pattern recognition. Pham et al. (5) used two-dimensional Fourier transform for image denoising, while Liu et al. (6) utilized one-dimensional Fourier transform for green pepper detection. Steinmann et al. (7) explored unsupervised hierarchical exploration of continuous seismograms using Fourier transform. Rahimi and Recht (8) proposed the use of Random Fourier Features (RFF) for kernel machines, and Zhang et al. (9) introduced geometric algebra adaptive filters based on multi-dimensional complex-valued RFF. The paper considers the unique characteristics of walking data and explores the potential of RFF for walking data analysis.

Key Words: gait analysis, acceleration pattern, kernel function

1 はじめに

本稿では、歩行時の加速度パターン解析に有用であろうカーネル関数を検討する。歩行は一般的に周期的な運動であり、周期 (1 stride の時間) や 1 stride 内の運動パターンは個人差があり、個人内でも変動が存在する。また、多チャンネルのデータを同時に取得すると、これらのデータは stride に同期する。

歩行運動についてはさまざまな計測機器を用いて計測されデータ化されている。モーションキャプチャシステムや動画撮影は広く行われている。モーションキャプチャシステムからは 3 次元関節座標が主要な関節について高精度に取得される。動画からは輪郭の形や画面内の 2 次元関節座標が算出される。輪郭の形や関節座標からは関節角度や距離の変化など特徴量が抽出される。

Zhang ら 1) は、歩行者の身体 5 ヶ所 (左上腕, 右前腕, 体幹右下後部, 左大腿, 右下腿) にそれぞれ 3 軸の加速度計を使用した歩行計測データセットを公開し、歩行者の認識手法を提案した。他にも 9 軸センサで 3 次元的な向きと共に、加速度データを取得することが考えられる。先行研究 1) で提供される 176 名の歩行データは、各歩行者の 6 または 12 試行で構成される。サンプリング周波数 100Hz で各試行につき数 10 秒間、欠測なしで与えられる。Zhang ら 1) は、時間加速度領域内の Signature Point によるスパース表現とクラスタリングを組み合わせ、加速度計から得られる特徴点のパターンを抽出し、歩行の分類を行った。

本稿では、このような多チャンネル同時計測歩行データに適用可能なカーネル関数 (類似度関数または距離尺度) を検討する。カーネル関数が適切に設定できれば、目的に応じた統計的手法や機械学習手法によ

て分類や予測, 異常検知, または歩行パターン生成が実行できる。

Morgan と Noehren 2) では、膝蓋大腿関節痛 (Patellofemoral Pain, PFP) を持つ個人の歩行波形パターンが調べられた。高速フーリエ変換を使用して歩行データを周波数領域に変換し、PFP 歩行のパターンが識別された。Ullrich ら 3) は、継続的に計測した慣性センサのデータから歩行を検出する手法を提案した。3) では、ハーモニック周波数を用いて歩行イベントを特定し、歩行を検出した。Jung ら 4) は、時間周波数表現と深層畳み込みニューラルネットワークを組み合わせ、歩行の多クラス分類手法を提案した。歩行データを時間周波数表現に変換し、深層畳み込みニューラルネットワークで特徴を学習した。これらの先行研究 2-4) は、周波数成分ごとの周波数に着目し、特徴抽出を行い、機械学習手法などを活用して有用な結果を示したが、位相情報は有効活用されず、波形の違いは無きものとされた。

歩行パターン分析以外の分野では、Fourier 係数の複素数としての性質がパターン認識に有効に活用されている。Pham ら 5) は、画像に対する 2 次元フーリエ変換を用いた複素ニューラルネットワークを提案した。画像データに 2 次元 Fourier 変換を施し 2 次元周波数ドメイン上の複素数に変換し、ローパスフィルタによって画像のノイズ低減を実現した。Liu ら 6) は、農業における可視光・赤外線スペクトルデータに対し 1 次元 Fourier 変換を基にした複素ニューラルネットワークを提案し、緑ピーマンの検出性能を改善した。Steinmann ら 7) は、連続地震波計データの教師なし学習による階層的探索について検討した。Fourier 変換を用いて周波数ドメインに変換した、階層的なパターン

探索を行った。これらの先行研究は、Fourier 変換の応用により画像処理や信号処理などの様々な分野で優れた結果を示した。これらの例と異なり、1)で提供される歩行データは、a) 基本周波数が 1Hz 程度であり、一連の計測時間（数 10 秒）の間に多くても数 10 周期しか起こらない；b) 厳密な周期関数ではない；c) 同時に観測される 15 チャンネル間は周期が一致しており、しかもそれぞれ 3 チャンネル間は立体幾何的な意味を持っている；という特徴がある。これらの特徴を考慮してカーネル関数を検討する。

一方で、立体幾何的な意味や時系列である意味を一切無視して、15 チャンネル×100Hz×例えば 20 秒=30000 次元の多次元データとして歩行者の特徴を捉える方向も検討する。Rahimi と Recht 8) は、多次元特徴ベクトルに対するカーネルマシンにおいて、Random Fourier Features, RFF の利用を提案した。RFF は、カーネルマシンの計算量を削減する手法として有効であり、高速な学習と推論を可能にする。RFF に幾何的な意味を加味する研究として、Zhang ら 9) は、多次元の複素 RFF に基づく geometric algebra 適応フィルタを提案した。Fourier 変換を用いた複素 RFF を抽出し、画像処理タスクにおいて効果的なフィルタリング結果を示した。本稿では、歩行データに対する RFF とその geometric algebra 適用の可能性を検討する。

2 歩行計測値カーネル関数の検討

歩行は人体の運動であるため個人差はもちろん、一定の個人内変動もあり、その計測データは一步一步、stride 周期も、周期内の力学的な計測値の時系列パターンも異なる。ここでは、周期が少し異なり、波形が同一（周期インパルス波形）であるデータの例として、

$$s = \left[\underbrace{1, 0, 0, 0, 0}_{\frac{1}{5}}, 1, 0, \dots \right], s' = \left[\underbrace{1, 0, 0, 0, 0, 0}_{\frac{1}{6}}, 1, 0, \dots \right],$$

を考える。Fig. 1 に、これらの周期関数を示す。




Fig. 1: Periodic impulse functions with slightly different periods from each other.

周期がそれぞれ 5 と 6 と分かっており、それらの最小公倍数 30 を周期として、それぞれ Fourier 係数

$$\mathcal{F}(s) = (c_k), \mathcal{F}(s') = (c'_k), k \in [0, 14]_{\mathbb{Z}} \text{ を求める.}$$

$$c_k = \begin{cases} 1, & k \equiv 0 \pmod{5} \\ 0, & \text{otherwise} \end{cases}$$

$$c'_k = \begin{cases} 1, & k \equiv 0 \pmod{6} \\ 0, & \text{otherwise} \end{cases}$$

上述のように、1)で提供される歩行データは、a) 基本周波数が 1Hz 程度であり、一連の計測時間（数 10 秒）の間に多くても数 10 周期しか起こらない；b) 厳密な周期関数ではない；という特徴がある。このような最小公倍数の周期での Fourier 分析を歩行データに適用するには 2 つほど問題があるようだ。一つは、100Hz での計測で、例えば周期サンプル数が 100 と 101 のように互いに素になって、最小公倍数 10100 が一連の観測のサンプル数を超えてしまうことが頻繁に起こりそうである。もう一つの問題は、Fourier 係数の複素ベクトルとしてユニタリー内積によって類似度をそのまま計算すると、上記の例では波形が同じでも $\sum_{k=1}^{14} c_k c'_k = 0$ と低くなってしまふ。

そこで、波形を周期や観測された物理量のスケールから切り分けて、横軸の時間方向にも縦軸の物理量方向にも規格化、正規化した波形で別個にカーネル関数とすることを検討する。Fig. 2 に概念図を示す。2 つの歩行データ間の、周期の類似度（または距離）と物理量の類似度（または距離）は並列にそれぞれ周期カーネル関数、物理量カーネル関数によって評価する。

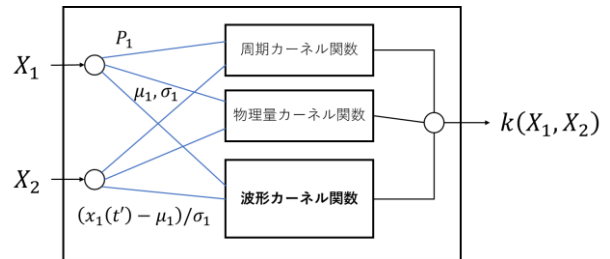


Fig. 2: A scheme of combined use of period kernel, mean-standard deviation kernel, waveform kernel functions.

3 種類のカーネル関数の出力をどのように結合するかは検討が必要だ。上述の例では、周期と物理量が少し異なり、波形カーネル関数として Fourier 級数のユニタリー内積を用いる場合、波形の類似度は最大（距離はゼロ）になる。

3 RFF 導入の検討

1 次元の特徴 x に対応する出力 $f(x)$ が周期関数であるとして、その Fourier 級数展開は $f(x) = \sum_{k \in \mathbb{Z}} c_k \exp jkx$ である。2 次元の特徴 (x, y) に拡張した 2 次元 Fourier 級数は

$$f(x, y) = \sum_{k_1 \in \mathbb{Z}} \sum_{k_2 \in \mathbb{Z}} c_{k_1, k_2} \exp j(k_1 x + k_2 y)$$

である。さらに、 D 次元特徴 \vec{x} に対応する出力 $f(\vec{x})$ の Fourier 級数展開は

$$f(\vec{x}) = \sum_{\vec{k} \in \mathbb{Z}^D} c_{\vec{k}} \exp j(\vec{k}^T \vec{x})$$

ここで、Rahimi と Recht 8) による RFF の提案では、 D 次元格子点上の複素数値 $\mathbb{Z}^D \ni \vec{k} \mapsto c_{\vec{k}} \in \mathbb{C}$ を、 D 次元空間上の実数の確率分布 $p(\vec{\omega}), p: \mathbb{R}^D \rightarrow \mathbb{R}$ で表すと、

$$f(\vec{x}) = \int_{\mathbb{R}^D} p(\vec{\omega}) \exp j(\vec{\omega}^T \vec{x}) d\vec{\omega}$$

とできる。粒子 $\vec{\omega}_i \sim p(\vec{\omega})$ を使って積分を近似すると、

$$f(x) = \sum_{i=1}^{\infty} \exp j(\vec{\omega}_i^T \vec{x}) \approx \sum_{i=1}^m \exp j(\vec{\omega}_i^T \vec{x})$$

RFF は、特徴ベクトルを $\phi(\vec{x}) = [\dots, \exp j(\vec{\omega}_i^T \vec{x}), \dots]^T \in \mathbb{C}^m$ とする。RFFを用いた 2 つの D 次元ベクトル \vec{x}_1, \vec{x}_2 のカーネル関数は $k(\vec{x}_1, \vec{x}_2) = (\phi(\vec{x}_1), \phi(\vec{x}_2))$

$$\begin{aligned} &= \sum_{i=1}^m \exp(j\omega_i^T x_1) (\exp(j\omega_i^T x_2)) \\ &= \sum_{i=1}^m \cos \omega_i^T x_1 \cos \omega_i^T x_2 + \sin \omega_i^T x_1 \sin \omega_i^T x_2 \\ &= \sum_{i=1}^m \cos(\omega_i^T (x_1 - x_2)) = k(x_2, x_1) \end{aligned}$$

である。このカーネル関数は、 D 次元ベクトルの類似度をフーリエ級数展開によって精度よく近似し、計算過程には、低コストの四則演算が D 回かかるが、高コストの三角関数演算は m 回で済むという利点がある。

さて、1)で提供されている歩行データは、c) 同時に計測される 15 チャンネル間は周期が一致しており、しかもそれぞれ 3 チャンネル間は立体幾何的な意味を持っている；という特徴がある。15 チャンネル \times 100Hz \times 例えば 20 秒 $=$ 30000 $=D$ 次元の多次元データとして扱おうとすれば、周期が一步ごとにやや変動する歩行試行の類似度の評価が可能であろう。一方、歩行の特徴についての説明性、解釈可能性が低くならざるを得ない。

4 まとめと今後の課題の整理

本研究では、歩行時の加速度パターン解析におけるカーネル関数の適用を念頭に、周期が異なる周期信号のカーネル関数について検討した。歩行は周期的な運動であり、周期は個人間や個人内での変動が存在する。また、複数のチャンネルのデータは歩行の周期に同期する。先行研究から得られる知見として、歩行データの解析においては位相情報や波形の特徴も重要であることが示唆された。これらの要素を考慮した適切なカー

ネル関数の選択や最適化が求められる。さらに、Random Fourier Features (RFF) の応用範囲を拡大し、位相情報の活用や立体幾何や時系列情報を効率的に活用した解析手法の構築に取り組む必要がある。

今後の課題としては、位相情報の抽出や活用方法の開発、RFF またはその派生を組み込んだカーネル関数や解析手法の最適化、さらなるデータ統合や異種データの組み合わせによる解析の拡張が挙げられる。これらの取り組みにより、歩行解析の精度向上や新たな応用領域の開拓が期待される。

参考文献

- 1) Zhang Y, Pan G, Jia K, Lu M, Wang Y, Wu Z. Accelerometer-Based Gait Recognition by Sparse Representation of Signature Points with Clusters. *IEEE Trans Cybern.* 2015;45(9):1864-1875. doi:10.1109/TCYB.2014.2361287
- 2) Identification of knee gait waveform pattern alterations in individuals with patellofemoral pain using fast Fourier transform, Morgan KD, Noehren B (2018) Identification of knee gait waveform pattern alterations in individuals with patellofemoral pain using fast Fourier transform. *PLOS ONE* 13(12): e0209015. <https://doi.org/10.1371/journal.pone.0209015>
- 3) M. Ullrich et al., "Detection of Gait from Continuous Inertial Sensor Data Using Harmonic Frequencies," in *IEEE Journal of Biomedical and Health Informatics*, vol. 24, no. 7, pp. 1869-1878, July 2020, doi: 10.1109/JBHI.2020.2975361.
- 4) D. Jung, M. D. Nguyen, M. Park, J. Kim and K. -R. Mun, "Multiple Classification of Gait Using Time-Frequency Representations and Deep Convolutional Neural Networks," in *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 28, no. 4, pp. 997-1005, April 2020, doi: 10.1109/TNSRE.2020.2977049.
- 5) Minh Tuan Pham, Van Quang Nguyen, Cao Duy Hoang, Hoang Long Vo, Dinh Khoi Phan, and An Hung Nguyen. 2022. Efficient Complex Valued Neural Network with Fourier Transform on Image Denoising. In *The 5th International Conference on Future Networks & Distributed Systems (ICFNDS 2021)*. Association for Computing Machinery, New York, NY, USA, 48-57. <https://doi.org/10.1145/3508072.3508081>
- 6) Liu X, Yu J, Kurihara T, Wu C, Niu Z, Zhan S. Pixelwise Complex-Valued Neural Network Based on 1D FFT of Hyperspectral Data to Improve Green Pepper Segmentation in Agriculture. *Applied Sciences*. 2023; 13(4):2697. <https://doi.org/10.3390/app13042697>
- 7) Steinmann, R., Seydoux, L., Beaucé, É., & Campillo, M. (2022). Hierarchical Exploration of Continuous Seismograms With Unsupervised Learning. *Journal of geophysical research. Solid earth*, 127(1), e2021JB022455. <https://doi.org/10.1029/2021JB022455>
- 8) Ali Rahimi and Benjamin Recht. 2007. Random Features for Large-Scale Kernel Machines. In *Advances in Neural Information Processing Systems*, J. Platt, D. Koller, Y. Singer, and S. Roweis (Eds.). 20, Curran Associates, Inc.. <https://proceedings.neurips.cc/paper/2007/file/013a006f03dbc5392effeb8f18fda755-Paper.pdf>
- 9) Z. Zhang, P. Cai, M. Shen”, G. Huang and S. Wang, "Geomet-

ric Algebra Adaptive Filter Based on Multi-Dimensional Complex-Valued Random Fourier Features," *2022 IEEE 32nd International Workshop on Machine Learning for Signal Processing (MLSP)*, Xi'an, China, 2022, pp. 1-6, doi: 10.1109/MLSP55214.2022.9943322.

長期記憶性と高い説明可能性を有する新しいリザーバーコンピューティングベース手法

○小西文昂 廣瀬明 夏秋嶺 (東京大学)

A novel reservoir computing-based method with long-term memory and high explainability

*B. Konishi, A. Hirose and R. Natsuaki (The University of Tokyo)

Abstract— In this paper, we propose explainable reservoir computing for learning long-term dependencies and improving explainability by use of self-attention mechanism. We also conduct a recalling pulse experiment in order to measure memory length. The experiment shows that our proposal recalls a pulse with a long delay more successfully than conventional RC and visualizes a relationship between input and output signals.

Key Words: Reservoir computing, Self-attention, Recurrent neural network, Explainable AI

1 Introduction

時間的・空間的な系列データを扱うことが可能な再帰型ニューラルネットワーク (Recurrent neural networks: RNNs) は、音声データ処理や自然言語処理などの多くの分野で非常に高い性能を発揮することが知られている。中でも LSTM(Long short-term memory)¹⁾ や GRU(Gated recurrent unit)²⁾ は、忘却ゲートなどの導入によって、より長期的な記憶をもつことを可能にした。しかし、計算コストが大きいことや勾配消失問題などは重要な課題であり、また再帰的な結合により記憶を保持している関係上、超長期的な記憶は消失されてしまう。

リザーバーコンピューティング (Reservoir Computing: RC) は、RNN の一種である。2001 年に Jaeger によって提案された ESNs (Echo state networks)³⁾ と 2002 年に Maass によって提案された LSM (Liquid state machine)⁴⁾ を基本とする RC は、これらの RNN の問題を解決するユニークな方法である^{5, 6, 7, 8)}。基本的な RC は、入力層と”リザーバー”と呼ばれる隠れ層と出力層の 3 層で構成されている。RC の最大の特徴は、入力層からリザーバーへの結合荷重や、リザーバー内の再帰結合荷重の値はランダムな初期値で固定し、リザーバーから出力層へつながる結合荷重 (Readout) のみを学習するという点にある。これは RC の学習が線形回帰問題に帰着することを意味しており、ムーア-ペンローズの擬似逆行列や勾配法によって高速に学習可能である。加えて、RC は入力信号をリザーバー内高次元空間へ非線形写像をとることによって、カオス時系列予測や高い非線形時系列予測を LSTM や GRU などの通常の RNN よりも高い精度で予測できることが知られている^{9, 6, 10, 11)}。

RC の問題点は、以下の 2 点が挙げられる。一つは、長期的な系列データの依存関係を捉えることが難しいことである。リザーバーの再帰結合により、短期間の履歴情報は保存することができるが、時間経過とともに指数関数的に情報が消失する。この特性により、長期的な履歴情報を保持することができない。次に、予測・分類結果の解釈可能性が低く、ブラックボックスになりやすい点である。DNN と同様、RC によって得られた結果の解釈が難しい。

ニューラル機械翻訳 (Neural Machine Translation:

NMT) をはじめとするあらゆる自然言語処理タスクにおいて著しい性能向上に貢献した注意機構 (Attention) は、これらの問題を解決するポテンシャルがある。近年、長期的な依存関係の学習のため、RC に自己注意機構 (self-attention) を組み込んだシステムがいくつか提案されている。

本論文では、Self-Attention を RC に取り込み、学習タスクに合わせた関連度表現の最適化を行うことで、入出力の関係性を学習・可視化できる Explainable reservoir computing (ERC) with self-attention (SA-ERC) を提案する。さらに、われわれは、入力に与えた単一パルスを一定時間後に想起するタスクを行い、提案手法は、通常の RC と比較して、より長期的な依存関係の学習と説明可能性の向上が可能であることを示す。

2 関連研究

Liu らによって提案された Attention-based Echo State Networks (AESNs)¹²⁾ は、Element-wise attention gate (EleAttG) によって構成された EleAtt-RNN¹³⁾ をベースにしている。通常の RNN の場合においては、EleAttG の結合荷重行列を Backpropagation により全て学習することができる。一方で、RC の場合、RC ブロック以前のパラメータは逆伝播できないため、学習することができない。そのため、ハイパーパラメータが増大してしまい、遺伝的アルゴリズムなどの進化計算手法などを用いて最適化する必要がある。

Sakemi らは、ESNs の Spectral radius と入力の大さを動的に変調する Reservoir gate と Input gate を導入することで、NARMA やローレンツモデル予測タスクにおいて優れた性能を示した¹⁴⁾。しかし、この手法も、gate を用いているため、LSTM や GRU と同様記憶容量には限界がある。また、 t のリザーバーの状態を求める上で $t-1$ の Attention の値が必要であるため、Attention の計算に $t+1$ 以降の状態を考慮することができない。これは、画像や翻訳などの時間的ではない広がりをもつ系列データにおいて適用を難しくする。

Lyu らは、リザーバーを複数並列に用意し、Multi-head Self-attention Memory Encoder (MSME) と Convolutional Memory Learner (CML) を組み合わせた Multiscale Echo Self-Attention Memory Network (MESAMN) モデルを提案した。そして、このモデルを

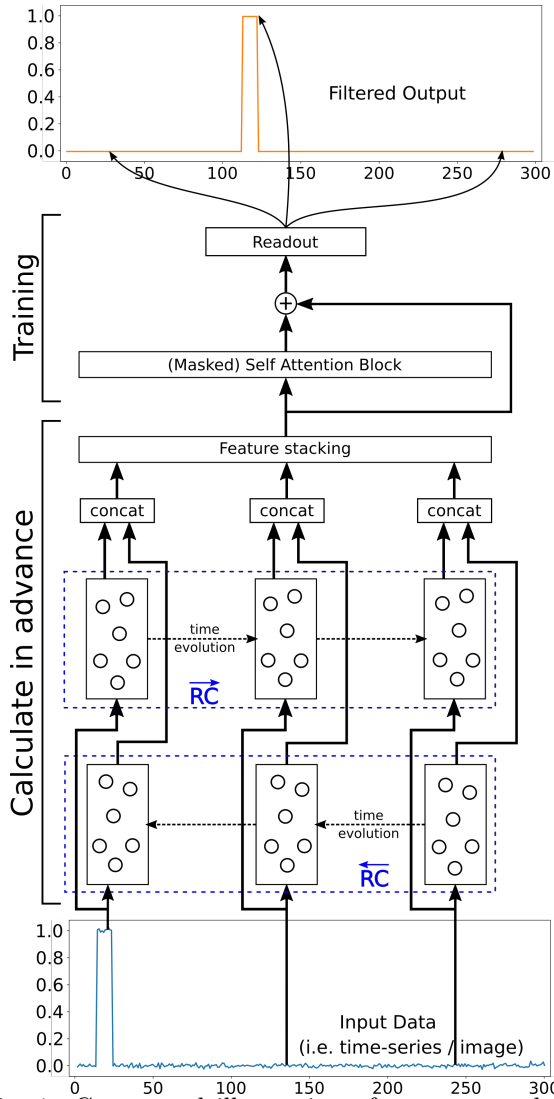


Fig. 1: Conceptual illustration of our proposed SA-ERC

用いて、発話や脳波などの18種類の多変量分類タスクや3D行動認識タスクを行い、従来のDeep LSTM (Long short-term memory)¹⁾などの手法と比較して高い精度で学習できることが確認した。このMSMEの内部では、Enhanced Echo State Representations (E²SRs)と呼ばれるAttentionが用いられている。E²SRsは、リザーバーの特徴量ベクトル同士の自己相関をAttentionとしている。リザーバーの自己相関は学習結果との因果関係を全く反映しないため、学習によって得られた結果を説明することができない。

以上より、本研究では、これらの従来研究では困難であった、超長期的な依存関係を学習しつつも、高い説明可能性を有するリザーバーコンピューティングベース手法であるExplainable reservoir computing (ERC) with self-attention (SA-ERC)を提案する。

3 提案手法

本節では、われわれが提案するSA-ERCについて説明する。Fig. 1は、提案手法の全体のシステム構成である。この手法は、リザーバー計算と注意計算が完全に独立しているため、入力データを基にあらかじめリザーバー計算を行うことができる。

Table 1: Hyperparameters on recalling pulse experiment

Parameter	Value
The number of reservoir N_{res}	64
Spectral radius $\bar{\sigma}(\mathbf{W}_{\text{res}})$	0.9
D_R	16
Optimizer	Adam
Learning rate	10^{-3}
Batch size	64
The number of iteration	5

まず、リザーバー計算部のダイナミクスを次式で定義する。

$$\mathbf{x}(t) = (\mathbf{I} - \mathbf{\Lambda})\mathbf{x}(t-1) + \mathbf{\Lambda} \tanh(\mathbf{W}_{\text{in}}\mathbf{u}(t) + \mathbf{W}\mathbf{x}(t-1) + \boldsymbol{\delta}) \quad (1)$$

$\mathbf{u}(t)$ と $\mathbf{x}(t)$ は、それぞれ時刻 t における入力信号とリザーバーの内部信号であり、 \mathbf{W}_{in} 、 \mathbf{W}_{res} 、 $\boldsymbol{\delta}$ はそれぞれ入力結合荷重、リザーバー内再帰結合荷重およびバイアスである。 $\mathbf{\Lambda}$ は漏れ率行列と呼ばれ、対角成分が対数正規分布に従う乱数で定まる対角行列として定義される¹⁵⁾。

次に、自己注意計算部について説明する。われわれは、Transformerにも用いられる自己注意機構を参考にダイナミクスを構築した。ある時刻 t における適切な出力結果を得るためには、どの時刻のリザーバー特徴量を利用するのが適切であるかを学習し、元特徴量に重み付けを行うために、われわれは関連度スコア \mathbf{R} を次式で定義する。

$$\mathbf{R} = \text{Softmax} \left(\frac{\mathbf{M} \odot (\mathbf{X}\mathbf{W}^{\text{Q}})(\mathbf{X}\mathbf{W}^{\text{K}})^{\text{T}}}{\sqrt{D}} \right) \quad (2)$$

\mathbf{X} は全時刻のリザーバー特徴量をまとめた行列である。 \mathbf{M} はマスク行列であり、時系列予測タスクなどの先読みができない場合に用いる。 \odot はアダマール積を計算する演算子である。 \mathbf{W}^{Q} と \mathbf{W}^{K} は、元々のリザーバー特徴量を関連度を計算するための D 次元空間に写像する行列である。得られた関連度スコア \mathbf{R} と元リザーバー信号との内積を計算することで、全時刻の入力を考慮したリザーバー特徴量を再構成することができる。最終的な出力は次式で与えられる。

$$\mathbf{Y} = (\mathbf{R}(\mathbf{X}\mathbf{W}^{\text{V}}) + \mathbf{X})\mathbf{W}_{\text{out}} + \mathbf{b}_{\text{out}}. \quad (3)$$

学習が必要なパラメータは、通常のRCと同じ出力結合荷重 \mathbf{W}_{out} と出力バイアス \mathbf{b}_{out} および、自己注意計算ブロック内の関連度の計算のための \mathbf{W}^{Q} 、 \mathbf{W}^{K} 、 \mathbf{W}^{V} の5つのみである。

4 単一パルス想起実験

4.1 実験準備

われわれは、提案手法の性能を検証するために、入力信号からノイズの影響を取り除きながら長期的な依存関係を学習するタスクを行う。Fig. 2の破線で表されたグラフは、本実験における入力信号と所望の出力信号である。各手法の出力結果については次節で説明する。 i 番目の入力データ $u_i(t)$ は、次式のように、無作為に決定されたステップ t_i で立ち上がる単一パルス




Fig. 2: Input signal, desired output signal and output signals of conventional RC, MSA-ERC and SA-ERC on recalling single pulse experiment




Fig. 3: RMSE of RC with $N_{\text{res}} = 16, 32$, MSA-ERC and SA-ERC in the recalling single pulse experiment.

と少量のガウス雑音の和によって生成される。

$$u_i(t) = \begin{cases} 1 + \mathcal{N}(0, 0.01^2) & \text{if } t_i \leq t \leq t_i + T_{\text{on}}, \\ \mathcal{N}(0, 0.01^2) & \text{otherwise.} \end{cases} \quad (4)$$

T_{on} はパルスが立ち上がり続ける長さであり、本実験では 10 ステップとする。 i 番目の所望出力信号 $d_i(t)$ は、入力信号からノイズを除き、 τ ステップ遅延させた信号であり、次式で表される。

$$d_i(t) = \begin{cases} 1 & \text{if } t_i + \tau \leq t \leq t_i + \tau + T_{\text{on}}, \\ 0 & \text{otherwise.} \end{cases} \quad (5)$$

本論文では、この実験をパルス想起実験と呼ぶこととする。遅延 τ が大きい程、通常のフィードバック結合構造によって記憶を保持する仕組みの RNN では、非常に想起が難しいことが予想される。

Table 1 は、本実験で使用したハイパーパラメータのリストである。本実験では、単方向のリザーバのみを用い、ミニバッチ学習によって荷重パラメータを更新する。また、 \mathbf{W}^Q と \mathbf{W}^K の初期値は正規乱数に従う同一のランダム行列とし、 \mathbf{W}^V の初期値は単位行列とする。

4.2 実験結果

Fig. 2 の実線で表されたグラフは、時間遅延を 100 ステップとしたときの従来 RC 手法と提案手法である MSA-ERC(先読み無し)、SA-ERC(先読みあり)による学習後の出力結果である。また、Fig. 3 は、各手法を用いて学習・推定したときの時間遅延 τ の大きさの違いに

よる RMSE の推移を示す。RMSE(Root mean square error) は次式で定義される。

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_i (\mathbf{y}_i - \mathbf{d}_i)^2} \quad (6)$$

N はテストデータの数である。Fig. 3 より、全ての時間遅延 τ において、self-attention を用いた提案手法である MSA-ERC と SA-ERC の性能は、RC のみの性能を上回ることがわかる。さらに、先読みを行う SA-ERC を用いた結果は、先読みを行わない MSA-ERC の結果と比較して、遅延の大きさに依らず、より安定した推定が可能であることがわかる。

4.3 考察

Fig. 4 は、Fig. 2 の入力テストケースにおける、MSA-ERC(上図) と SA-ERC(下図) の学習前(左図) と学習後(右図) の対数関連度行列 $\log_{10}(\mathbf{R})$ の可視化結果を示す。この図は、関連度行列を $\mathbf{R} = [r_{i,j}]$ (行: i , 列: j), $r_{i,j}$ とすると、 i ステップ目の出力結果を得るためには、何ステップ目のリザーバ内部信号がより重要であることを示している。Fig. 2 のケースにおいては、117 ステップ目の出力信号と 17 ステップ目のリザーバ信号の関連度を示すスコア $r_{117,17}$ が大きくなることが求められる。左図の学習前の関連度行列の可視化結果は、入力パルスが立ち上がった ($j = 17$) ステップ目付近のリザーバ信号が、($i = 17$) ステップ目の出力にとって、重要であることを示している。しかしながら、本実験では、入力信号が立ち上がった瞬間においては、出力信号は 0 であることが求められるため、この関連度表現は最適ではない。

一方で、右図の学習後の関連度行列は、($j = 17$) ステップ目付近のリザーバ信号が、($i = 117$) ステップ付近の出力にとって、重要であることを示している。これは、入力信号が立ち上がったときのリザーバ信号を、100 ステップ後の出力信号に影響を与えることができることを意味しており、これにより、提案手法は超長期的な依存関係の学習を実現できる。また反対に、十分に学習された関連度行列表現を見ることで、入力と出力信号の間の関係性を適切に説明することが可能であることから、提案手法はリザーバコンピューティングの説明可能性を高めることができると考えられる。

5 おわりに

われわれは、Self-attention を用いることで、長期依存関係の学習と RC の説明可能性を高めるための新しい

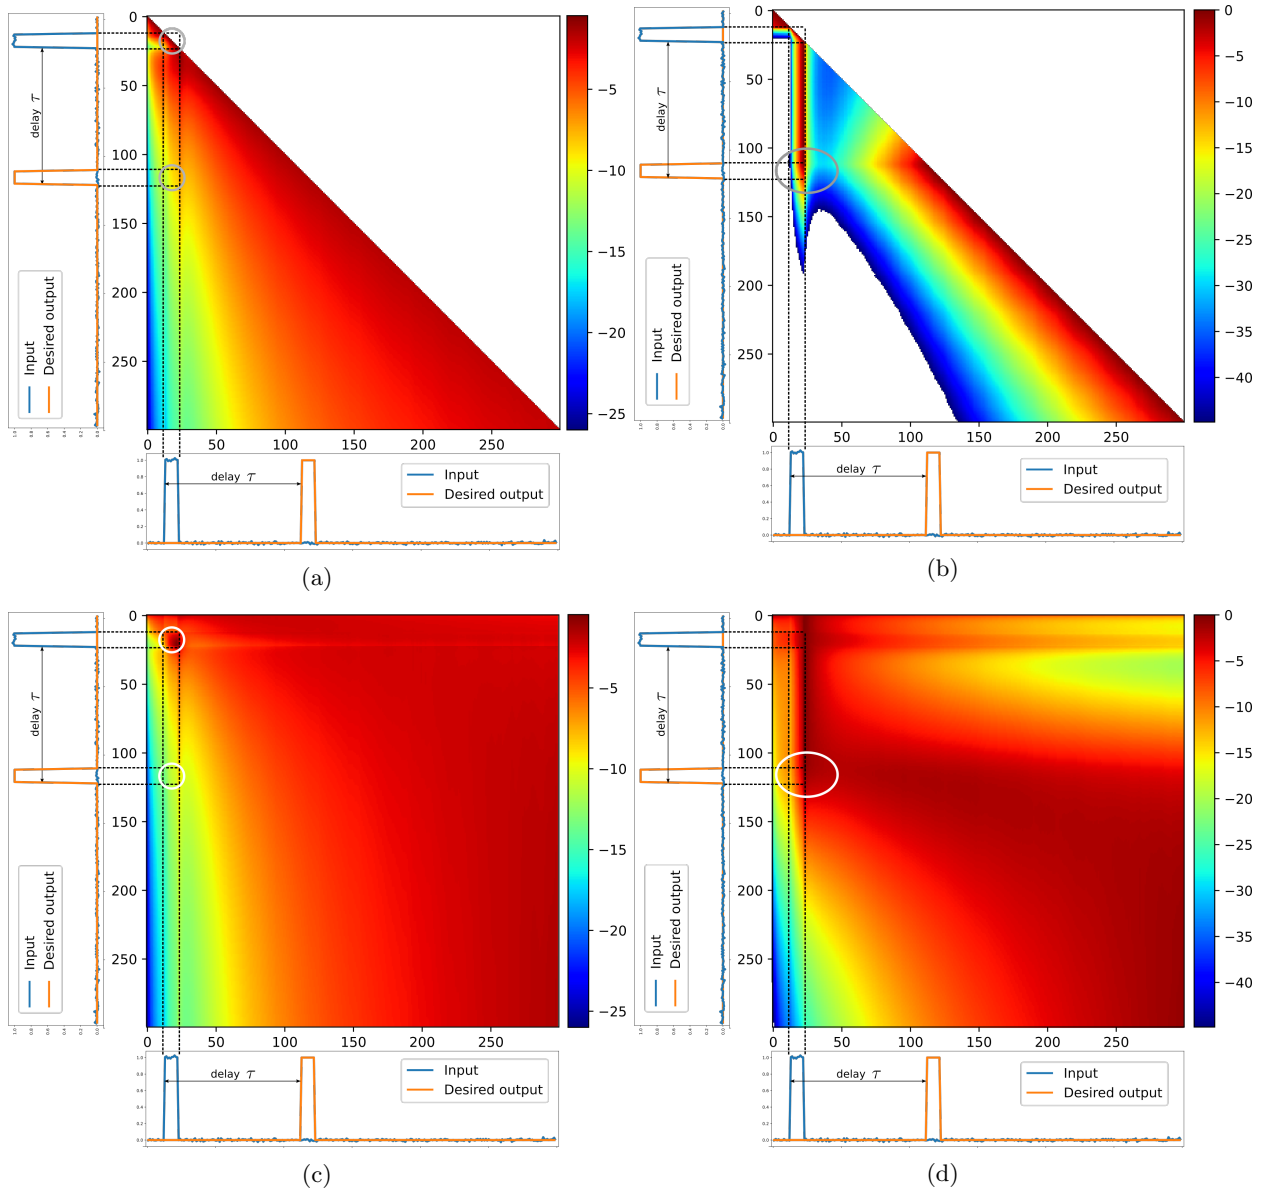


Fig. 4: Logarithmic relevance matrix $\log_{10}(\mathbf{R})$ of MSA-ERC at a step (a) before training and (b) after training (1000 epoch) and SA-ERC at a step (c) before training and (d) after training. Relevance scores in the white area are zero (i.e. $\log_{10}(\mathbf{R}) = -\infty$) in the top figures.

手法を提案した。提案手法は、RC 計算部と Attention 計算部が完全に独立しているため、別々に処理が可能である。また、ステップ $t+1$ 以降のデータも計算に取り入れることができるため、系列信号のフィルタリングや、画像や文章などの双方向性をもつデータに対してより適切に処理可能である。また、オンライン学習や予測タスクの場合には、マスクを取り入れることで容易に学習可能である。

さらに、われわれは、単一パルスを想起するする実験を行い、提案手法は通常の RC と比較して非常に高い記憶性能を持つことを明らかにした。また、Attention 計算部の関連度行列の可視化により、入出力間の関係性を容易に可視化できることを示し、提案手法は RC の解釈可能性を高めることが示唆された。

謝辞

本研究は JSPS 科研費 JP23KJ0549, JP23H00487 の助成を受けたものです。

参考文献

- 1) Sepp Hochreiter and Jürgen Schmidhuber. Long Short-Term Memory. *Neural Computation*, Vol. 9, No. 8, pp. 1735–1780, 11 1997.
- 2) Kyunghyun Cho, Bart van Merriënboer, Dzmitry Bahdanau, and Yoshua Bengio. On the properties of neural machine translation: Encoder–decoder approaches. In *Proceedings of SSST-8, Eighth Workshop on Syntax, Semantics and Structure in Statistical Translation*, pp. 103–111, Doha, Qatar, October 2014. Association for Computational Linguistics.
- 3) Herbert Jaeger. The “echo state” approach to analysing and training recurrent neural networks-with an erratum note. *Bonn, Germany: German National Research Center for Information Technology GMD Technical Report 148*, 2001.
- 4) Wolfgang Maass, Thomas Natschläger, and Henry Markram. Real-time computing without stable states: A new framework for neural computation based on perturbations. *Neural computation*, Vol. 14, No. 11, pp. 2531–2560, 2002.
- 5) Gouhei Tanaka, Toshiyuki Yamane, Jean Benoit

- Héroux, Ryosho Nakane, Naoki Kanazawa, Seiji Takeda, Hidetoshi Numata, Daiju Nakano, and Akira Hirose. Recent advances in physical reservoir computing: A review. *Neural Networks*, Vol. 115, pp. 100–123, 2019.
- 6) Daniel J Gauthier. Reservoir computing: Harnessing a universal dynamical system. *Phys. Rev. Lett*, Vol. 120, No. 024102, p. 2018, 2018.
 - 7) Benjamin Schrauwen, David Verstraeten, and Jan Van Campenhout. An overview of reservoir computing: theory, applications and implementations. In *Proceedings of the 15th european symposium on artificial neural networks. p. 471-482 2007*, pp. 471–482, 2007.
 - 8) Mantas Lukoševičius and Herbert Jaeger. Reservoir computing approaches to recurrent neural network training. *Computer Science Review*, Vol. 3, No. 3, pp. 127–149, 2009.
 - 9) Herbert Jaeger and Harald Haas. Harnessing nonlinearity: Predicting chaotic systems and saving energy in wireless communication. *science*, 2004.
 - 10) Erik Bollt. On explaining the surprising success of reservoir computing forecaster of chaos? the universal machine learning dynamical system with contrast to var and dmd. *Chaos: An Interdisciplinary Journal of Nonlinear Science*, Vol. 31, No. 1, p. 013108, 2021.
 - 11) Shahrokh Shahi, Flavio H Fenton, and Elizabeth M Cherry. Prediction of chaotic time series using recurrent neural networks and reservoir computing techniques: A comparative study. *Machine learning with applications*, Vol. 8, p. 100300, 2022.
 - 12) Chongdang Liu, Rong Yao, Linxuan Zhang, and Yuan Liao. Attention based echo state network: A novel approach for fault prognosis. In *Proceedings of the 2019 11th International Conference on Machine Learning and Computing*, ICMLC '19, p. 489–493, New York, NY, USA, 2019. Association for Computing Machinery.
 - 13) Pengfei Zhang, Jianru Xue, Cuiling Lan, Wenjun Zeng, Zhanning Gao, and Nanning Zheng. Eleatt-rnn: Adding attentiveness to neurons in recurrent neural networks. *IEEE Transactions on Image Processing*, Vol. 29, pp. 1061–1073, 2019.
 - 14) Yusuke Sakemi, Sou Nobukawa, Toshitaka Matsuki, Takashi Morie, and Kazuyuki Aihara. Learning reservoir dynamics with temporal self-modulation. *arXiv preprint arXiv:2301.09235*, 2023.
 - 15) Gouhei Tanaka, Tadayoshi Matsumori, Hiroaki Yoshida, and Kazuyuki Aihara. Reservoir computing with diverse timescales for prediction of multiscale dynamics. *Physical Review Research*, Vol. 4, No. 3, p. L032014, 2022.

運転時における脳波計を用いた microstate 解析による運転熟練度の評価

○小澤 拓斗 飯沼 佑太 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)

Evaluating Driving Performance Using Microstate Analysis With An Electroencephalography During Driving

*T.Ozawa, Y.Inuma, S.Nobukawa (Chiba Institute of Technology)
N.Wagatsuma (Toho University) and K.Inagaki (Chubu University)

Abstract— In recent years, the technological development of advanced driver assistance systems (ADAS) has contributed to the reduction of traffic accidents. It is important to develop ADAS with functions for the optimized assistance according to driving performance. Several studies have revealed the relationship between driving performance and brain activity. Electroencephalogram (EEG) is used to understand neural activity during driving. Microstate analysis is a method to evaluate dynamic brain activity from EEG. This approach reveals the complex mutual interactions of whole-brain networks. In this context, we hypothesized that microstate analysis can detect driving performance from EEG. The results showed that the expert group more sustained state transitions from the frontal to the frontal, while the beginner group exhibited high-frequent state transitions from the occipital to the frontal. This implied that the expert group had efficient cognitive control and suppressed extra bottom-up attention.

Key Words: EEG, microstates, driving

1 はじめに

近年、前方衝突警告、先進緊急ブレーキシステム、ならびにドライバーモニタリングなど、先進運転支援システムの技術開発が進み、交通事故件数の減少に寄与している¹⁾²⁾³⁾⁴⁾⁵⁾⁶⁾。今後、さらに交通事故を減らすためには、運転熟練度に依存した最適なアシストを実現する先進運転支援システムの開発が必要である⁷⁾⁸⁾。

運転能力の評価には、瞳孔測定と視覚的注意に基づく評価方法がある。瞳孔計を用いた研究では、瞳孔径の変動がドライバーの疲労を検出できることが示されている⁹⁾¹⁰⁾。視覚的注意を用いた研究では、幹線道路や自動車、歩行者などの重要な対象物への注視時間や注視回数から、運転能力に影響を与える眠気や疲労を検出できることが示されている¹¹⁾¹²⁾。しかし、これらの方法は車両の振動、バックライト、交通信号などの影響により、正確な運転能力の推定が困難であることが指摘されている¹³⁾¹⁴⁾¹⁵⁾¹⁶⁾。さらに、近年の研究では、運転能力は瞳孔径、視覚的注意などの視覚情報処理だけでなく、意思決定や記憶といった高度な認知機能も深く関与していることが分かっている¹⁷⁾¹⁸⁾¹⁹⁾。先行研究では、脳波 (EEG)、脳磁図 (MEG)、機能的磁気共鳴画像 (fMRI) などで検出される脳活動と、運転能力の間に強い相関関係があることが示されている²⁰⁾²¹⁾²²⁾²³⁾²⁴⁾。なかでも脳波は、携帯性、非侵襲性、高い時間分解能といった利点から、運転中の脳活動の把握に広く利用されている²⁵⁾²⁶⁾²⁷⁾。こうした観点から、脳の神経活動を反映する脳波が、運転能力に関連する神経プロセスの複雑な相互作用を、総合的に評価するのに適していると考えられる。

脳波から運転能力を評価する方法の一つとして、機能的結合性がある。機能的結合は、脳領野間にわたる全脳ネットワークの神経統合を、神経活動の一対一の相互作用として反映する²⁶⁾²⁸⁾²⁹⁾。機能的結合性に着目した手法により、運転能力に影響を与える眠気や疲労に関

連する神経ネットワークの特性が明らかにされている²⁸⁾²⁹⁾。さらに、体積伝導を避けることで高い時間分解能を実現した phase lag index (PLI) を用いた先行研究では、運転経験が視覚知覚機能を支えるガンマ帯の神経回路を増強する可能性が示されている²⁶⁾。しかし、PLI の長期的な時間平均に基づく評価方法では、運転中の認知プロセスに強く関連する動的な脳活動を捉えるには不十分である可能性が指摘されている²⁶⁾³⁰⁾。

運転中の動的な脳活動を捉えるためには、脳波の準安定な空間パターンに着目した microstate 解析が有力な候補となる³¹⁾³²⁾。全電極からの信号を同時に考慮する方法は、microstate の時間的変化を測定することで、全脳ネットワークの相互作用を捉えることができる³²⁾³³⁾³⁴⁾。特に、この microstate の遷移は、運転能力に影響を与える眠気や疲労に関連する神経ネットワークの特性を反映していることが示されている³⁰⁾³⁵⁾。このような背景から全脳ネットワークの相互作用を網羅的に検出できる microstate 解析は、脳波から運転熟練度に関わる脳活動の、瞬間的なダイナミクスを評価するのに適した手法であると仮説を立てた。本研究では、運転初心者及び、運転熟練者の 2 群に分けた被験者にて、microstate 解析を用い、脳の状態遷移を評価することで、この仮説を証明する。

2 手法

2.1 被験者

本研究は中部大学工学部ロボット理工学科において行われた。被験者は、20～23 歳の健康な 15 人 (女性 1 名、男性 14 名) で、生まれつき正常な視力を持つ人か、眼鏡やコンタクトレンズで正常な視力に矯正されている。また、全ての被験者が運転免許証を所持している。被験者は運転の頻度によって、運転初心者群 (以下 beginners 群と呼ぶ)、と運転熟練者群 (以下 experts 群) のグルー




Fig. 1: Location of electrodes used for measurements based on the international 10-20 method.

プに分類した. 本研究では,2 週間に 1 回以下しか運転しない被験者を beginners 群に,2 週間に 2 回以上運転する被験者は experts 群と定義した. この定義からグループ分けを行うと,beginners 群と experts 群はそれぞれ 8 人と 7 人であった. 実験中,自然なドライバーの運転状況に対する理解度を評価するため,被験者は日々の通勤のように運転シーンを視聴するように指示された. これら全ての研究はヘルシンキ宣言に基づいて行われ,中部大学研究倫理委員会の承認を得て実施された(Protocol number:#2021006). また,研究参加者全員からインフォームドコンセントを得ている. 本研究で使った脳波データは,以前に PLI およびパワー解析によって評価された²⁶⁾²⁷⁾.

2.2 脳波の測定方法とデータ前処理

脳波データは,Fig.1 の国際 10-20 システムに基づいて配置された 14 個の電極 (AF3, AF4, F3, F4, F7, F8, FC5, FC6, P8, P7, T7, T8, O1, O2) にて, Emotive EPOC+を用いて測定した³⁶⁾. サンプル周波数は 128Hz である. 測定は,モニター (1920 × 1080 ピクセル) から 60cm 離れた場所に着席し,ビデオカメラで撮影された高速道路での運転シーンを 2~3 分間視聴した. 運転シーンでは,同一車線または側車線 (追い越し車線) の他車両,信号 (赤・黄・緑),標識,歩行者,交差点,横断歩道,高速道路のランプ,赤信号で停止する車などが登場する. この映像の視認範囲は,サイドミラーやバックミラーを含まない前方視界のみである. 先行研究により,この長さの映像刺激によって,experts 群と beginners 群の間でパワースペクトルと PLI での違いが検出できることが明らかにされている²⁶⁾²⁷⁾. したがって,運転熟練度に起因する脳波の microstate から動的特性を評価するためには,2~3 分の動画の長さが適切であると考えられる.

各被験者の脳波データは,ヘッドセットの動き,瞬き,眼球運動,首の筋肉,頭皮の筋肉活動によって生じるアーチファクトを除去するために,artifact subspace reconstruction (ASR) を実施した.ASR を行うための MATLAB スクリプトは,オープンソースのプラグイン機能である EEGLAB の clean_rawdata として公開されている³⁷⁾. 本研究では,脳波データからアーチファクトを識別するために,標準偏差による除去閾値として定義

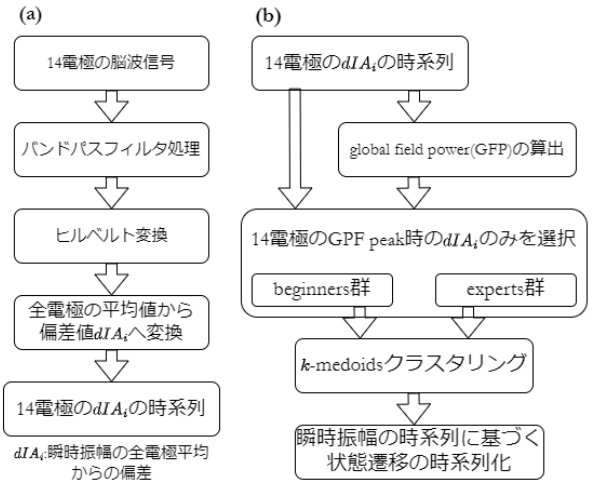


Fig. 2: (a) Estimation process for continuous instantaneous amplitude time-series of electroencephalography (EEG) signals. (b) Estimation process for state using GFP based on the instantaneous amplitude time-series of EEG signals.

されるカットオフパラメータ $SD20\%$ を使用した.

2.3 瞬時振幅分布に基づく Microstate 解析

本研究では,脳波信号における瞬時振幅を利用して,脳活動の状態を定義した. 瞬時振幅のダイナミクスを推定するために用いたプロセスの概略を Fig.2(a) に示す. まず,14 電極から得られた脳波データの時系列を,2-20Hz の周波数範囲でバンドパスフィルタにかけた³⁸⁾³⁹⁾. 次に,瞬時振幅 $IA_i(t)$ ($-\infty \leq IA_i(t) \leq +\infty$) を推定するため,Hilbert 変換を行った. 次に,瞬時振幅を全電極間の平均値から偏差値に変換し, $dIA_i(t)$ (i : 電極位置) と定義した.

$$dIA_i(t) = IA_i(t) - \overline{IA}(t) \quad (1)$$

ここで, $\overline{IA}(t)$ は全電極で平均化した $IA_i(t)$ を示している. さらに,領域特有の空間パワー分布を持つ microstate を定義するため,全電極間の標準偏差から global field power(GFP) を算出し,その GFP 曲線での極大値に対応する $dIA_i(t)$ のみをトポグラフィとして選択した⁴⁰⁾⁴¹⁾.

その後,Fig.2(b) に示すように,beginners 群と experts 群の GFP peak 時における $dIA_i(t)$ のデータを k-medoids アルゴリズムを用いて k 個のクラスターに分類した. 本研究では,電極数が少ないため,クラスターサイズを $k = 2$ に設定した. この手法により,動的な状態遷移は全脳ネットワークの相互作用を領域ごとに分離することなく,反映していると仮定する⁴²⁾⁴³⁾. また,k-medoids アルゴリズムによって分類された状態間の状態遷移の確率を評価した.

2.4 統計解析

本研究では,beginners 群と experts 群の状態遷移確率の群間差を評価するため, t -検定を行った. 多重比較のため, t -scores に対して,Benjamini-Hochberg false discovery rate (FDR) 補正が適用された (4 つの p 値). 有意水準は $q < 0.05$ とした.




Fig. 3: Mean value of $dIA_i(t)$ for the duration of each state in the beginners and experts groups. $dIA_i(t)$: deviation of instantaneous amplitude from the average among all electrodes.

3 結果

高速道路の運転シーンを視聴するタスク下で, beginners 群と experts 群の脳波データを測定し, その瞬時振幅分布から状態遷移特性を導出した. Fig.3は beginners 群と experts 群の k -medoids によって分類された各状態の持続時間における $dIA_i(t)$ の時間平均を示している. 両群とも, #1 では前頭部活性化状態, #2 では後頭部活性化状態であることが確認された. この結果に加え, Fig.3 の状態遷移を評価するため, 遷移確率を #1, #2 の状態間で評価した.

Fig.4(a), (b) は, beginners 群と experts 群の状態遷移確率の平均値を示したものである. Fig.4(c) は, beginners 群と experts 群の状態遷移確率の t 値を示したものである. experts 群の場合, #2 から #1 への状態遷移 ($t = -3.569$ ($p = 0.006$ ($q < 0.05$))) が有意に低く, #1 から #1 への状態遷移 ($t = 3.569$ ($p = 0.006$ ($q < 0.05$))) が有意に高いという結果が得られている.

4 考察

本研究では, 脳波から運転経験を含む運転熟練度を評価するために, microstate 解析を用いて, 運転シーンを視聴するタスク中の beginners 群と experts 群の脳波データを評価した. その結果, 両グループとも, #1 では前頭部活性化状態, #2 では後頭部活性化状態が確認された. experts 群では, #2 から #1 への状態遷移確率は有意に低く, #1 から #1 への状態遷移確率は有意に高くなった.

初めに, experts 群の方が beginners 群より前頭葉が活性化している理由について考察する. 近年の研究では, 前頭皮質の神経活動は, 運転行動に対する視覚的注意, 意思決定, 行動計画など, 運転中の認知制御に強く関係していることが示されている⁴⁴⁾⁴⁵⁾. 特に, fMRI を用いた先行研究では, 熟練者は初心者よりも運転中の前頭葉の活性化が顕著であることが示された⁴⁶⁾. これらの神経活動は, 熟練者が初心者よりも運転経験に基づいて視

覚的注意や意思決定などの認知制御を効率的に行っていることを示していると考えられている⁴⁷⁾⁴⁸⁾⁴⁹⁾. 従って, 本研究の結果 (Fig.4 (c) 参照) は, experts 群の効率的な認知制御の神経活動を反映していると考えられる.

第二に, beginners 群が experts 群に比べて後頭部から前頭部への遷移が活発である理由を考察する. 先行研究では, 熟練者は前頭葉で注意機能を制御していることから, 視覚性ボトムアップ注意を抑制していると考えられている⁴⁶⁾⁵⁰⁾. Panos らは, 熟練者は危険を予測するために効率的な視覚探索を行うのに対し, 初心者は重要な対象を見落としや, 無関係な対象の注視など, 非効率的な視覚探索を行うことを明らかにした⁴⁸⁾. このような視覚特性の違いは, 熟練者が過去の運転経験に基づいて, 危険が最も発生しやすい視覚領域を優先的に探索できることを示唆している⁵¹⁾⁵²⁾. したがって, 本研究の結果 (Fig.4 (c) 参照) は, experts 群において冗長な視覚性ボトムアップ注意の神経活動の抑制を反映していると考えられる.

第三に, 本研究の限界について考察した. 本研究では脳波の microstate 解析を用いて運転経験に関連する運転熟練度を評価したが, 実用化の為に, より多くの参加者を用いたさらなる研究が必要である. さらに, 脳波を用いたパワー解析による先行研究では, 異なる3種類の運転シーン (渋滞, 市街地, 高速道路) を見るタスクで運転熟練度を評価した²⁷⁾. しかし, 本研究では, 高速道路の運転シーンを見るタスクでの評価のみを実施した. 運転経験に依存した熟練度を高精度で深く理解するためには, 今後の研究において, これらを考慮することが不可欠である.

結論として, 本研究では, 運転経験に依存した熟練度に関する脳波の動的特性は, 効率的な認知制御と冗長な視覚性ボトムアップ注意の抑制を反映する神経活動に依存していることを明らかにした. この知見は, 限界はあるものの, 先進運転支援システムにおける運転経験に

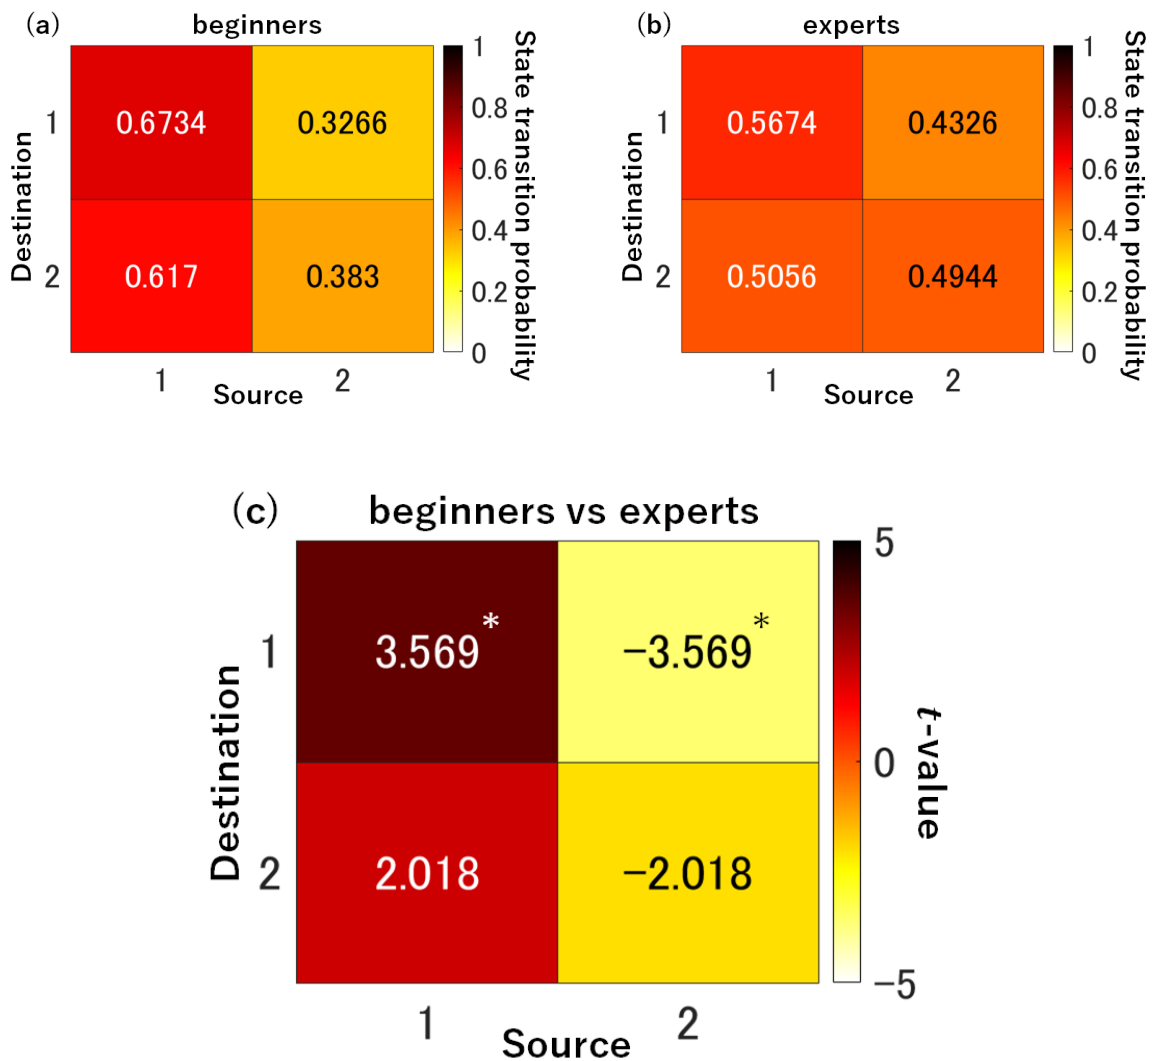


Fig. 4: (a)Mean values of the state transition probabilities between subjects in the beginners driver groups. (b)Mean values of the state transition probabilities between subjects in the experts driver groups. (c) t -value of the state transition probabilities between beginners and experts driver groups.Red (white) colors exhibit higher (smaller) probability in experts driver.The areas marked with asterisks meet the significance level ($q < 0.05$).

依存した運転熟練度の推定に広く活用できる可能性がある。

謝辞

本研究は、JSPS 基盤研究 (C) 科研費 JP17K12781,JP22K12138,JP22K12183 の助成を受けたものである。

参考文献

- George Dimitrakopoulos and Panagiotis Demestichas. Intelligent transportation systems. *IEEE Vehicular Technology Magazine*, vol.5,issue.1,77/84,(2010)
- Sinan Kaplan, Mehmet Amac Guvensan, Ali Gokhan Yavuz, and Yasin Karalurt. Driver behavior analysis for safe driving: A survey. *IEEE Transactions on Intelligent Transportation Systems*, vol.16,issue.6,3017/3032,(2015)
- Jianqiang Wang, Chenfei Yu, Shengbo Eben Li, and Likun Wang. A forward collision warning algorithm with adaptation to driver behaviors. *IEEE Transactions on Intelligent Transportation Systems*, vol.17,issue.4,1157/1167,(2015)
- Ronghui Zhang, Kening Li, Zhaocheng He, Haiwei Wang, and Feng You. Advanced emergency braking control based on a nonlinear model predictive algorithm for intelligent vehicles. *Applied sciences*, vol.7,issue.5,504,(2017)
- Vicente Milanés, Steven E Shladover, John Spring, Christopher Nowakowski, Hiroshi Kawazoe, and Masahide Nakamura. Cooperative adaptive cruise control in real traffic situations. *IEEE Transactions on intelligent transportation systems*, vol.15,issue.1,296/305,(2013)
- Li Li, Ding Wen, Nan-Ning Zheng, and Lin-Cheng Shen. Cognitive cars: A new frontier for adas research. *IEEE Transactions on Intelligent Transportation Systems*, vol.13,issue.1,395/407,(2011)
- Wenshuo Wang, Junqiang Xi, and Huiyan Chen. Modeling and recognizing driver behavior based on driving data: A survey. *Mathematical Problems in Engineering*, vol.14,1/20,(2014)
- Yueru Xu, Zhirui Ye, and Chao Wang. Modeling commercial vehicle drivers' acceptance of advanced driving assistance system (adas). *Journal of Intelligent and Connected Vehicles*, vol.4,issue.3,125/135,(2021)

- 9) Hiroshi Yokoyama, Koma Eihata, Junya Muramatsu, and Yusuke Fujiwara. Prediction of driver's workload from slow fluctuations of pupil diameter. *International Conference on Intelligent Transportation Systems (ITSC)*, **vol.21**,1775/1780,(2018)
- 10) Lin Shi, Leilei Zheng, Danni Jin, Zheng Lin, Qiaoling Zhang, and Mao Zhang. Assessment of combination of automated pupillometry and heart rate variability to detect driving fatigue. *Frontiers in Public Health*, **vol.10**,(2022)
- 11) Titis Wijayanto, Syam Rachma Marcilia, and Galang Lufityanto. Visual attention, driving behavior and driving performance among young drivers in sleep-deprived condition. *KnE Life Sciences*, pages 424/434, (2018)
- 12) Junli Xu, Jianliang Min, and Jianfeng Hu. Real-time eye tracking for the assessment of driver fatigue. *Healthcare technology letters*, **vol.5**,issue.2,54/58,(2018)
- 13) Gowdham Prabhakar, N Madhu, and Pradipta Biswas. Comparing pupil dilation, head movement, and EEG for distraction detection of drivers. In *Proceedings of the 32nd International BCS Human Computer Interaction Conference*,**vol.32**,1/5,(2018).
- 14) Anh Son Le, Tatsuya Suzuki, and Hirofumi Aoki. Evaluating driver cognitive distraction by eye tracking: From simulator to driving. *Transportation research interdisciplinary perspectives*, **vol.4**,100087, (2020)
- 15) A. T. Duchowski. A breadth-first survey of eye-tracking applications. *Behav Res Methods Instrum Comput*,**vol.34**,issue.4,455/470,(2002)
- 16) Maximilian Schwalm, Andreas Keinath, and Hubert D Zimmer. Pupillometry as a method for measuring mental workload within a simulated driving task. *Human Factors for assistance and automation*, **vol.1986**,1/13,(2008)
- 17) Andrew Vakulin, Angela D 'Rozario, Jong-Won Kim, Brooke Watson, Nathan Cross, David Wang, Alessandra Coeytaux, Delwyn Bartlett, Keith Wong, and Ronald Grunstein. Quantitative sleep EEG and polysomnographic predictors of driving simulator performance in obstructive sleep apnea. *Clinical Neurophysiology*,**vol.127**,issue.2,1428/1435,(2016)
- 18) J Perrier, S Jongen, E Vuurman, ML Bocca, JG Ramaekers, and A Vermeeren. Driving performance and EEG fluctuations during on-the-road driving following sleep deprivation. *Biological psychology*,**vol.121**,1/11,(2016)
- 19) Kaarin J Anstey, Timothy D Windsor, Mary A Luszcz, and Gary R Andrews. Predicting driving cessation over 5 years in older adults: Psychological well-being and cognitive competence are stronger predictors than physical health. *Journal of the American Geriatrics Society*, **vol.54**,issue.1,121/126,(2006).
- 20) Muhammad Awais, Nasreen Badruddin, and Micheal Drieberg. Driver drowsiness detection using EEG power spectrum analysis. In *2014 IEEE Region 10 symposium*, pages 244/247,(2014)
- 21) Gianluca Borghini, Giovanni Vecchiato, Jlenia Toppi, Laura Astolfi, A Maglione, R Isabella, C Caltagirone, Wanzeng Kong, Daming Wei, Zhengchun Zhou, et al. Assessment of mental fatigue during car driving by using high resolution EEG activity and neurophysiologic indices. In *2012 annual international conference of the IEEE engineering in medicine and biology society*, pages 6442/6445.(2012)
- 22) Saroj KL Lal and Ashley Craig. A critical review of the psychophysiology of driver fatigue. *Biological psychology*,**vol.55**,issue.3,173/194,(2001)
- 23) Takayuki Nozawa, Yasuyuki Taki, Akitake Kanno, Yoritaka Akimoto, Mizuki Ihara, Ryoichi Yokoyama, Yuka Kotozaki, Rui Nouchi, Atsushi Sekiguchi, Hikaru Takeuchi, et al. Effects of different types of cognitive training on cognitive function, brain structure, and driving safety in senior daily drivers: a pilot study. *Behavioural neurology*,(2015)
- 24) Peiyan Chen, Feng Chen, Lin Zhang, Xiaoxiang Ma, and Xiaodong Pan. Examining the influence of decorated sidewaall in road tunnels using fMRI technology. *Tunnelling and Underground Space Technology*, **vol.99**,103362,(2020)
- 25) Sangtae Ahn and Sung C. Jun. Multi-modal integration of EEG-fnirs for brain-computer interfaces – current limitations and future directions. *Frontiers in Human Neuroscience*, **vol.11**,(2017).
- 26) Masahiro Tsurushima, Keita Otsu, Sou Nobukawa, Nobuhiko Wagatsuma, and Keiichiro Inagaki. Assessment of functional connectivity induced by driving experience. *Nonlinear Theory and Its Applications, IEICE*,**vol.14**,issue.2,559/568,(2023)
- 27) Keiichiro INAGAKI, Tatsuya MARUNO, and Kota YAMAMOTO. Evaluation of EEG activation pattern on the experience of visual perception in the driving. *IEICE Transactions on Information and Systems*,**vol.E103.D**,issue.9,2032/2034,(2020)
- 28) Jichi Chen, Hong Wang, Qiaoxiu Wang, and Chengcheng Hua. Exploring the fatigue affecting electroencephalography based functional brain networks during real driving in young males. *Neuropsychologia*, **vol.129**,200/211,(2019)
- 29) Jichi Chen, Hong Wang, Chengcheng Hua, Qiaoxiu Wang, and Chong Liu. Graph analysis of functional brain network topology using minimum spanning tree in driver drowsiness. *Cognitive neurodynamics*,**vol.12**,569/581,(2018)
- 30) Wenbin Li, Shan Cheng, Hang Wang, and Yaoming Chang. EEG microstate changes according to mental fatigue induced by aircraft piloting simulation: An exploratory study. *Behavioural Brain Research*, **vol.438**,114203,(2023)
- 31) Wanrou Hu, Zhiguo Zhang, Li Zhang, Gan Huang, Linling Li, and Zhen Liang. Microstate detection in naturalistic electroencephalography data: a systematic comparison of topographical clustering strategies on an emotional database. *Frontiers in Neuroscience*, **vol.16**,49,(2022)
- 32) Christoph M Michel and Thomas Koenig. EEG microstates as a tool for studying the temporal dynamics of whole-brain neuronal networks: a review. *Neuroimage*,**vol.180**577/593,(2018).
- 33) Patricia Milz, Pascal L Faber, Dietrich Lehmann, Thomas Koenig, Kieko Kochi, and Roberto D Pascual-Marqui. The functional significance of EEG microstates—associations with modalities of thinking. *Neuroimage*, **vol.125**,643/656,(2016).
- 34) Benjamin A Seitzman, Malene Abell, Samuel C Bartley, Molly A Erickson, Amanda R Bolbecker, and William P Hetrick. Cognitive manipulation of brain electric microstates. *Neuroimage*, **vol.146**,533/543,(2017)
- 35) Marina Krylova, Sarah Alizadeh, Igor Izyurov, Vanessa Teckentrup, Catie Chang, Johan van der Meer, Michael Erb, Nils Kroemer, Thomas Koenig, Martin Walter, et al. Evidence for modulation of EEG microstate sequence by vigilance level. *Neuroimage*, **vol.224**,117393,(2021)
- 36) Richard W Homan, John Herman, and Phillip Purdy. Cerebral location of international 10–20 system electrode placement. *Electroencephalography and clinical neurophysiology*,**vol.66**,issue.4,376/382,(1987)
- 37) Arnaud Delorme and Scott Makeig. EEGLab: an open source toolbox for analysis of single-trial EEG dynamics including independent component analysis. *Journal of Neuroscience Methods*,**vol.134**,issue.1,9/21,(2004)

- 38) Kyungwon Kim, Nguyen Thanh Duc, Min Choi, and Boreom Lee. EEG microstate features for schizophrenia classification. *PLoS one*, vol.16, issue.5, e0251842, (2021)
- 39) Kiran Raj V, Shyam Sundar Rajagopalan, Sujas Bhardwaj, Rajanikant Panda, Venkateswara Reddy Reddam, Chaitanya Ganne, Raghavendra Kenchaiah, Ravindranadh C Mundlamuri, Thenarasu Kandavel, Kaushik K Majumdar, Satishchandra Parthasarathy, Sanjib Sinha, and Rose Dawn Bharath. Machine learning detects EEG microstate alterations in patients living with temporal lobe epilepsy. *Seizure*, vol.61, 8/13, (2018)
- 40) Matthias Gartner, Verena Brodbeck, Helmut Laufs, and Gaby Schneider. "A stochastic model for EEG microstate sequence analysis. *Neuroimage*, vol.104, 199/208, (2015)
- 41) Arjun Khanna, Alvaro Pascual-Leone, Christoph M Michel, and Faranak Farzan. Microstates in resting-state EEG: current status and future directions. *Neuroscience & Biobehavioral Reviews*, vol.49, 105/113, (2015)
- 42) Yuta Iinuma, Sou Nobukawa, Haruhiko Nishimura, and Tetsuya Takahashi. Dynamic characteristics of state transitions composed of neural activity in the brain by circadian rhythms. In 2022 44th Annual International Conference of the IEEE Engineering in Medicine Biology Society (EMBC), 152/157, (2022)
- 43) Sou Nobukawa, Takashi Ikeda, Mitsuru Kikuchi, and Tetsuya Takahashi. Dynamical characteristics of state transition defined by neural activity of phase in alzheimer's disease. In International Conference on Neural Information Processing, 46/54. Springer, (2021)
- 44) Sajjad Basharpour, Fazeleh Heidari, and Parviz Molavi. EEG coherence in theta, alpha, and beta bands in frontal regions and executive functions. *Applied Neuropsychology: Adult*, vol.28, issue.3, 310/317, (2021)
- 45) Chimou Li, Xiaonan Li, Ming Lv, Feng Chen, Xiaoxiang Ma, and Lin Zhang. How does approaching a lead vehicle and monitoring request affect drivers' takeover performance? a simulated driving study with functional MRI. *International journal of environmental research and public health*, vol.19, issue.1, 412, (2021)
- 46) Giulio Bernardi, Luca Cecchetti, Giacomo Handjaras, Lorenzo Sani, Anna Gaglianese, Riccardo Ceccarelli, Ferdinando Franzoni, Fabio Galetta, Gino Santoro, Rainer Goebel, et al. It's not all in your car: functional and structural correlates of exceptional driving skills in professional racers. *Frontiers in human neuroscience*, vol.8, 888, (2014)
- 47) Geoffrey Underwood. Visual attention and the transition from novice to advanced driver. *Ergonomics*, vol.50, issue.8, 1235/1249, (2007)
- 48) Panos Konstantopoulos, Peter Chapman, and David Crundall. Driver's visual attention as a function of driving experience and visibility. using a driving simulator to explore drivers' eye movements in day, night and rain driving. *Accident Analysis & Prevention*, vol.42, issue.3, 827/834, (2010)
- 49) Ashoke Kumar Pradhan, Alexander Pollatsek, Michael Knodler, and Donald L Fisher. Can younger drivers be trained to scan for information that will reduce their risk in roadway traffic scenarios that are hard to identify as hazardous? *Ergonomics*, vol.52, issue.6, 657/673, (2009)
- 50) Jake T Bowling, Karl J Friston, and Joseph B Hopfinger. Topdown versus bottom-up attention differentially modulate frontal-parietal connectivity. *Human brain mapping*, vol.41, issue.4, 928/942, (2020)
- 51) Ismael Muela, Ana B Chica, Pedro Garcia-Fernandez, and Candida Castro. Visual attention in realistic driving situations: Attentional capture and hazard prediction. *Applied ergonomics*, vol.90, 103235, (2021)
- 52) A. Torralba, A. Oliva, M. S. Castelhan, and J. M. Henderson. Contextual guidance of eye movements and attention in real-world scenes: the role of global features in object search. *Psychol Rev*, vol.113, issue.4, 766/786, (2006)

大脳皮質-基底核脳回路システムモデルにおける 神経挙動のカオス共鳴制御

○道法浩孝 (高知大学) 信川 創 (千葉工業大学) 西村治彦 (大和大学)
高橋哲也 (金沢大学)

Chaotic Resonance Control of Neural Activity in Brain Circuit System Model of Cerebral Cortex-Basal Ganglia

*H. Doho (Kochi University) S. Nobukawa (Chiba Institute of Technology)
H. Nishimura (Yamato University) and T. Takahashi (Kanazawa University)

Abstract— Fluctuations in nonlinear systems can enhance the synchronization with weak input signals. Chaotic resonance (CR) is one of such phenomena, caused by a system-intrinsic chaotic fluctuation. CR is observed in systems with chaos-chaos intermittency (CCI), where a chaotic orbit appears between separate regions. Based on the characteristics of CR, we previously proposed a novel method for controlling the chaotic state to an appropriate CR state by adopting a feedback signal from the system itself. This method is called the reduced-region-of-orbit (RRO) feedback method. The RRO feedback method was applied to discrete and continuous time chaotic systems, and its versatility was confirmed. Moreover, we have applied this method to frontal cortex neural system model, and the effectiveness for controlling the system behavior by inducing CR was confirmed. In this study, we examined the responsiveness of CCI to a weak periodic signal by extending the model to the brain circuit level composed of frontal cortex, basal ganglia and thalamus. As a result, we confirmed the effectiveness of the RRO feedback method for stabilizing the neural activity observed in the brain circuit system model of cerebral cortex-basal ganglia.

Key Words: Reduced-Region-of-Orbit Method, Chaotic Resonance Control, Brain Circuit System

1 はじめに

システムが有する決定論的なカオス性がゆらぎ源としての役割を担うノイズフリーな共鳴現象として、カオス共鳴が知られている^{1, 2, 3}。カオス共鳴は、いくつかの非線形システムで観察されるが、典型的なカオス共鳴としては、互いに分離した挙動領域（アトラクタ）間をカオス的に往来するカオス-カオス間欠性（Chaos-Chaos Intermittency : CCI）を伴う非線形システムにおける、微弱な入力信号に対する CCI の同期現象が知られている^{4, 5, 6, 7, 8, 9, 10, 11}。

このカオス共鳴の特性に基づき、我々は CCI を制御する手法として、システムへのフィードバック信号を通してカオス状態をカオス共鳴が誘起されやすい状態に移行させる軌道領域減少（Reduced-Region-of-Orbit : RRO）法を提案した¹²。この手法は、システムのカオスダイナミクスから写像構造を推定し、アトラクタ併合の生起の原因となる写像関数の極大値と極小値をフィードバック信号により低減させることで CCI を制御する。その結果、内部パラメータを随時チューニングすることなくシステムにカオス共鳴を誘起するものである。これまで、この RRO 法をカオスシステム^{12, 13, 14}、ニューラルシステム^{15, 16}に適用し、その汎用性を確認してきた。また、前頭野と感覚野で構成される脳回路システムモデルに適用し、カオス共鳴の誘起による挙動制御の有効性を確認してきた^{17, 18, 19}。

脳の認知機能は前頭野及び感覚野等で構成される神経ネットワークだけでなく、非線形性を伴う複数のネットワークが互いに関連している。したがって、生理学的知見に立脚した広範な神経系を含む神経ネットワークモデルへの RRO 法の適用が求められる。そこで本研究では、前頭野に加え、大脳基底核及び視床までそ

の範囲を拡張した神経システムモデルに対し軌道領域減少法を適用し、外部入力信号へのカオス-カオス間欠性同期による神経ダイナミクスの安定化に対する効果を検証した。

2 モデリング

2.1 大脳皮質-基底核脳回路システム

興奮性と抑制性の2つの神経回路で構成された Baghdadi らによる前頭野と感覚野の神経システム²⁰に、大脳基底核及び視床を加えた大脳皮質-基底核脳回路システムモデル²¹、及び RRO 法によるカオス制御方法の概観を Fig. 1 に示す。前頭野の神経活動は、大脳基底核の Striatum（線条体）を通して入力され直接及び間接の2つの経路を通して GPi/SNr（淡蒼球内節/黒質網様体）より視床に出力される。視床は大脳基底核からの入力を前頭野に出力し大脳基底核と前頭野を中継している。

大脳基底核の神経活動 $y(n)$ 及び前頭野の神経活動 $x(n)$ は、以下の (1) 式から (3) 式で表される。

$$y(n) = -(-S_2 \tanh(-S_1 x(n)) - S_3), \quad (1)$$

$$x(n+1) = F(y(n)), \quad (2)$$

$$F(x) = B \tanh(w_1 x) - A \tanh(w_2 x). \quad (3)$$

ここで、 S_1 及び S_2 は、大脳基底核の Striatum から Gpi/SNr に至る間接経路の結合荷重であり、 S_3 は直接経路の結合荷重である。 A 、 B は抑制性 $I(x)$ と興奮性 $E(x)$ のシナプス結合強度を表し、 w_1 と w_2 は、感覚野から前頭野の興奮性ニューロン集団と抑制性ニューロン集団への結合強度を表す。本研究では、 $w_1 = 1.487$ 、 $w_2 = 0.2223$ 、 $B = 5.82$ のパラメータ設定を用いる^{20, 21}。

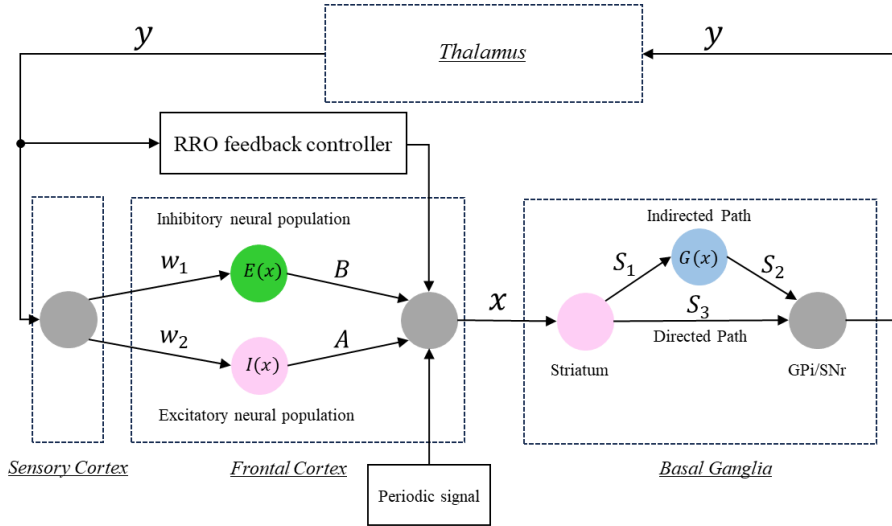


Fig. 1: Overview of brain circuit system model composed of frontal cortex, basal ganglia and thalamus stimulated by a reduced-region-of-orbit (RRO) feedback signal and a periodic signal.

2.2 RRO 信号による前頭野の神経活動の制御

(2) 式及び (3) 式で与えられる前頭野の神経活動に対し, RRO 法によって誘起されるカオス共鳴によりカオス状態から CCI 状態を経て周期的状態への移行制御を行う. 前頭野の神経活動 $x(n)$ は, 以下に示すように RRO フィードバック信号 $u(x)$ と外部入力信号 $S(n) = \alpha \sin(2\pi n/p)$ によって制御される.

$$x(n+1) = F(y(n)) + Cu(y(n)) + S(n), \quad (4)$$

$$u(x) = -(x - x_d) \exp(-(x - x_d)^2 / (2\sigma^2)). \quad (5)$$

ここで, C は RRO フィードバック信号強度, x_d 及び σ は, $x(n)$ のアトラクタ分離を行う $x(n)$ の境界値とフィードバック信号の影響範囲を決めるパラメータである. 本研究では, $x_d = 0$, $\sigma = 1.0$ のパラメータ設定を用いる.

2.3 信号応答性の評価尺度

アトラクタの併合分岐を評価するために, $F(f_{\max})$ と, $F(f_{\min})$ を導入した. $F(f_{\max, \min}) = 0$ は, 分離していたアトラクタの併合点に相当する. また前頭野の神経活動 $x(n)$ のカオス性は, 以下に示すリアプノフ指数により判断した.

$$\lambda = \frac{1}{\tau M} \sum_{k=1}^M \ln \left(\frac{d^k(t_l = \tau)}{d^k(t_l = 0)} \right). \quad (6)$$

前頭野の神経活動 $x(n)$ と微弱周期信号 $S(n)$ との同期は, τ の時間遅れに基づく相関係数を用いて評価した.

$$C(\tau) = \frac{C_{sx}(\tau)}{\sqrt{C_{ss}C_{xx}}}, \quad (7)$$

$$C_{sx}(\tau) = \langle (S(n+\tau) - \langle S \rangle)(x(n) - \langle x \rangle) \rangle, \quad (8)$$

$$C_{ss} = \langle (S(n) - \langle S \rangle)^2 \rangle, \quad (9)$$

$$C_{xx} = \langle (x(n) - \langle x \rangle)^2 \rangle. \quad (10)$$

ここで, $\langle \cdot \rangle$ は, n 回の平均を表す.

RRO フィードバック信号 $Cu(x)$ と微弱周期信号 $S(n)$

による摂動を評価するために, 以下に示す摂動の二乗平均 Θ を導入した.

$$\Theta = \langle (Cu(x(n)))^2 + (S(n))^2 \rangle. \quad (11)$$

ここで, $\langle \cdot \rangle$ は, n 回の平均を表す.

3 結果と考察

3.1 パラメータ設定

最初に, 大脳皮質-基底核脳回路システムモデルを構成するパラメータの設定を, 以下の手順で行い CCI が誘起されるパラメータ領域の同定を行った. 解析の第 1 段階として本研究では簡単のため $S_3 = 0$ とした. 次に, システム挙動の S_1 , S_2 及び A に対する依存性を解析した. Fig. 2 に, $S_1 = 1.2$ のときのリアプノフ指数 λ の A と S_2 に対する依存性を示す. 図において, $S_2 = -1.6$ に対し $A \geq 15$ の一定の領域において適度なカオス領域 ($\lambda \approx 0.3$) が現れている. そこで, $S_1 = 1.2$, $S_2 = -1.6$ に設定し, システム挙動の抑制性シナプス結合荷重 A 依存性を調べた.

Fig. 3 に, 大脳皮質-基底核脳回路システムにおける前頭野神経活動 $x(n)$, リアプノフ指数 λ , 及びアトラクタ併合状態評価指標 $F(f_{\max, \min})$ の A 依存性を示す. $x(n)$ は A の値の増加に伴い周期倍分岐を起こし, $A \gtrsim 16.6$ でカオス挙動を呈している ($\lambda > 0$). $16.6 \lesssim A \lesssim 17.1$ の領域では, $F(f_{\max}) > 0$, $F(f_{\min}) < 0$ であり, $x(n)$ は初期状態 $x(0)$ に応じて正負いずれかの領域にトラップされ, カオス挙動を呈している. $A \gtrsim 17.1$ の領域では, アトラクタ併合条件 $F(f_{\max}) < 0$ と $F(f_{\min}) > 0$ が満たされ, $x(n)$ が正負の領域を遷移する CCI を呈する様子が確認できる. $18.0 \lesssim A \lesssim 19.0$ では, 周期的な挙動が現れる (周期窓). A の値が 19.0 を超えるとカオス状態となり, $A \gtrsim 19.2$ の領域で, 再び CCI が現れる. 上記に基づき, 前頭野における抑制性シナプス結合荷重を $A = 16.7$ に設定した.

3.2 RRO 信号によるカオス共鳴制御

前節で設定したパラメータに基づき, RRO フィードバック信号を用いたシステム挙動の微弱外部入力信号

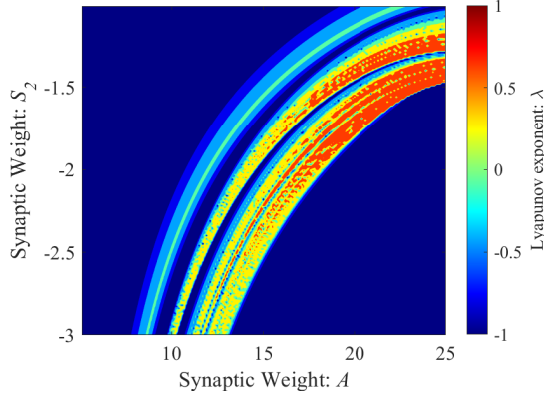


Fig. 2: Dependence of Lyapunov exponent λ on inhibitory synaptic weight A and synaptic weight S_2 .

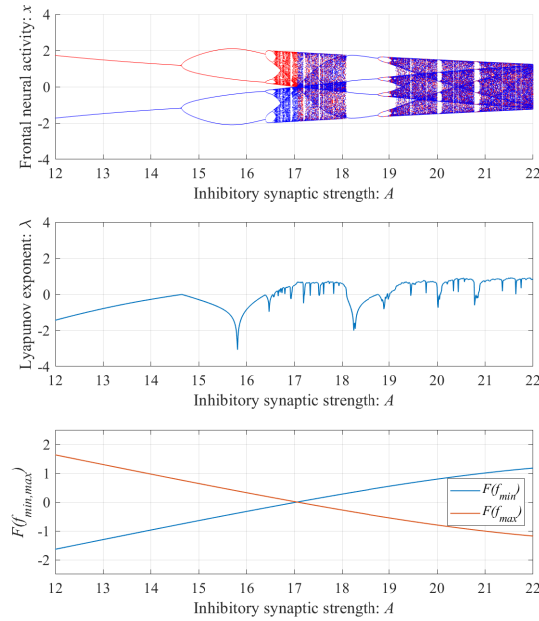


Fig. 3: System behaviors of the brain circuit system model composed of frontal cortex, basal ganglia and thalamus as a function of the synaptic weight from the inhibitory neural population, A .

への同期によるカオス共鳴制御について評価する。前頭野の抑制性シナプス結合荷重を $A = 16.7$ に設定した場合の、前頭野神経活動 $x(n)$ と微弱外部入力信号 $S(n)$ ($\alpha = 0.05$ 及び $p = 32, 64, 128, 256$) との相関係数 $\max_{\tau} C(\tau)$ と摂動 Θ の RRO フィードバック信号強度 C 依存性を Fig. 4 に示す。 $\alpha = 0.05$, $p = 256$ の微弱周期信号に対し、 $\max_{\tau} C(\tau)$ は $C = 0.3$ 付近で極大 ($\max_{\tau} C(\tau) \approx 0.7$) となっており、微弱外部入力信号に対する高い相関が得られている。外部入力信号の周期の減少に伴い、 $\max_{\tau} C(\tau)$ の極大値は減少し、極大値を示す RRO フィードバック信号強度 C の値は高くなる傾向にあるが、 $p = 32$ の信号に対し $\max_{\tau} C(\tau) \approx 0.4$ であり、高い相関は維持されている。以上の結果は、RRO フィードバック信号によってカオス共鳴が誘起されたことを示すものである。カオス共鳴時の摂動は $0.01 \leq \Theta \leq 0.03$ である。




Fig. 4: Synchronization of neural activity $x(n)$ to a weak periodic input signal $S(n)$ ($\alpha = 0.05$ and $p = 32, 64, 128, 256$) and perturbations of the RRO feedback signal and the periodic input signal ($A = 16.7$).

前頭野神経活動 $x(n)$ の時系列変化を解析した結果を、Fig. 5 に示す。上段は RRO フィードバック信号と微弱外部入力信号を印加しなかったとき ($C = 0, \alpha = 0$) の時系列変化であり、中段は RRO フィードバック信号を印加せず ($C = 0$), $\alpha = 0.05$, $p = 256$ の微弱外部入力信号のみを入力したとき時系列変化、下段は RRO フィードバック信号強度を $C = 0.3$ に設定し、 $\alpha = 0.05$, $p = 256$ の微弱外部入力信号を印加したときの前頭野神経活動の時系列変化である。RRO フィードバック信号による制御が加わらない状態では、 $x(n)$ は正の領域

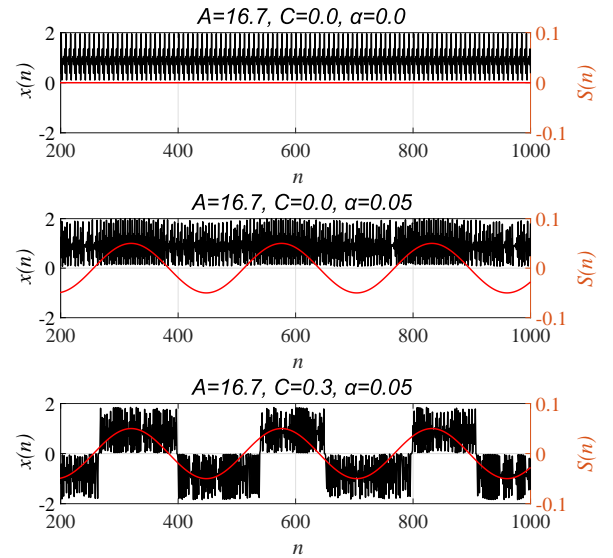


Fig. 5: Typical time series of frontal neural activity $x(n)$. (Top) A case without RRO feedback signal $Cu(y(n))$ and weak input signal $S(n)$. (Middle) A case without RRO feedback signal $Cu(y(n))$ for weak input signal $S(n)$. (Bottom) A case in synchronization with a weak periodic input signal $S(n)$ under the conditions for inducing chaotic resonance ($A = 16.7$)

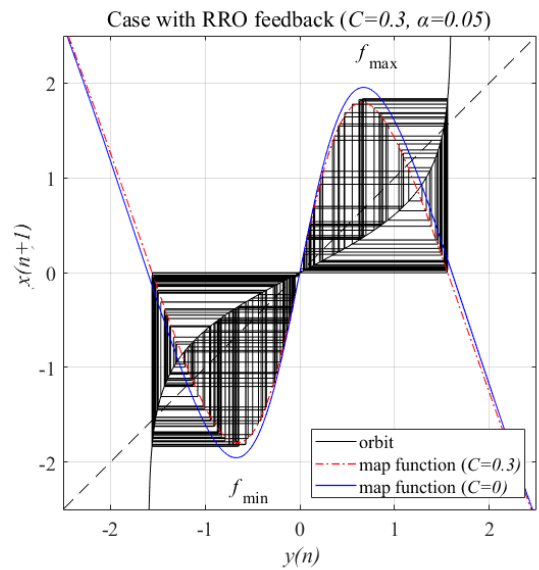





Fig. 6: Map function for $A=16.7$ with and without RRO feedback signal $Cu(y(n))$ for weak input signal $S(n)$ and its return map between $x(n)$ and $x(n+1)$.

に閉じ込められた状態にあり、無信号時には周期に近い挙動 ($p=8$) を呈し、外部入力信号が加わるとカオス状態に移行している。適度な強度の RRO フィードバック信号による制御が加わると微弱外部入力信号の変化に対応した挙動を示し、カオス共鳴状態に移行している。外部入力信号 $S(n)$ とシステム挙動 $x(n)$ の位相差は $1/8p$ 程度である。

Fig. 5 に対応する $x(n)$ と $x(n+1)$ の写像構造と軌道を Fig. 6 に示す。RRO フィードバック信号の効果により、アトラクタ併合条件 $F(f_{\max}) < 0$, $F(f_{\min}) > 0$ が満たされ、正または負いずれか一方の領域に閉じ込められていたシステム挙動が正負の領域をカオス的に往來する CCI 挙動に移行している。

Fig. 7 は、大脳基底核の神経活動 $y(n)$ と $x(n+1)$ の写像構造と軌道である。 $x(n)$ と $y(n)$ の非線形性により、 $y(n)$ の微小な変化が $x(n)$ の大きな変化を生じ、RRO フィードバック信号の制御による効果で $x(n)$ の値が 0 を超え、もう一方のアトラクタ領域に遷移して

Fig. 7: Map function for $A=16.7$ with and without RRO feedback signal $Cu(y(n))$ for weak input signal $S(n)$ and its return map between $y(n)$ and $x(n+1)$.

いる。

3.3 大脳基底核の影響がない場合のカオス共鳴制御

前頭野、大脳基底核及び視床で構成される脳回路システムモデルに対する RRO フィードバック信号によるカオス制御の効果、大脳皮質のみで構成される神経システムモデルに対する効果との比較を通して考察する。Fig. 8 は、感覚野と前頭野のみで構成される神経システムモデルを、Fig. 4 と同様に $A=16.7$ のパラメータ設定で構成し、前頭野神経活動 $x(n)$ と微弱外部入力信号 $S(n)$ ($\alpha=0.05$ 及び $p=32, 64, 128, 256$) との相関係数 $\max_{\tau} C(\tau)$ と摂動 Θ の RRO フィードバック信号強度 C 依存性を取得した結果である。CR を誘起し微弱入力信号に対する高い相関を得るためには、 $C \approx 1$ 程度の RRO フィードバック信号強度が必要である ($\Theta \approx 0.2$)。また、CR が誘起される信号強度のバンド幅は、大脳皮質-基底核脳回路システムモデルの場合に比べて狭くなっている。前頭野、大脳基底核及び




Fig. 8: Synchronization of neural activity $x(n)$ to a weak periodic input signal $S(n)$ ($\alpha = 0.05$ and $p = 32, 64, 128, 256$) and perturbations of the RRO feedback signal and the periodic input signal in the model composed of sensory cortex and frontal cortex ($A = 16.7$).

視床で構成されるシステムモデルにおいては、非線形性の効果により大脳皮質のみで構成されるシステムモデルではCRが誘起されない小さい信号強度 ($C = 0.3$) 及び摂動 ($\Theta \approx 0.01$) でCRが誘起されている。

Fig. 8 において、RRO フィードバック信号強度を $C = 0$ 及び $C = 0.3$ に設定し、 $\alpha = 0.05$ 、 $p = 256$ の微弱外部入力信号を印加したときの前頭野神経活動の時系列変化を Fig. 9 に示す。Fig. 10 は、Fig. 9 に対応する写像構造と軌道である。前頭野、大脳基底核及び視床で構成されるシステムモデルにおいてCCIが誘起された信号強度 $C = 0.3$ では、周期 ($p = 4$) に近い周期的な挙動にとどまっておらず信号 $S(n)$ と呼応していない。

4 おわりに

本研究では、RRO 法によるカオス制御のメカニズムを、前頭野、大脳基底核及び視床で構成される脳回路システムモデルに導入し、シミュレーションを通して、RRO フィードバック信号によって誘起されるカオス共鳴により、脳回路での神経活動が周期的挙動へ移行する過程を評価した。

その結果、モデルを構成するパラメータを前頭野の神経活動がカオス状態となるように調節し、前頭野の抑制性シナプス結合荷重を $A = 16.7$ に設定すると、小さな摂動強度である弱い RRO フィードバック信号によりカオス共鳴が誘起され、微弱外部入力信号と前頭野の神経活動との間に高い相関が得られた。これに対して、大脳皮質のみで構成される神経システムモデルの場合にカオス共鳴を誘起するには、大きな摂動となる強いフィードバック信号が必要であった。さらに、カオス共鳴時のシステム挙動を時系列変化及びリターンマップに基づき考察したところ、大脳皮質-基底核脳回路システムモデルにおけるシステム挙動の非線形性の効果を確認することができた。

今後の課題としては、モデルを構成するパラメータのシステムティックなチューニングにより、RRO フィー




Fig. 9: Time series of frontal neural activity with and without RRO feedback signal $Cu(y(n))$ for weak input signal $S(n)$ in the model composed of sensory cortex and frontal cortex ($A = 16.7$).

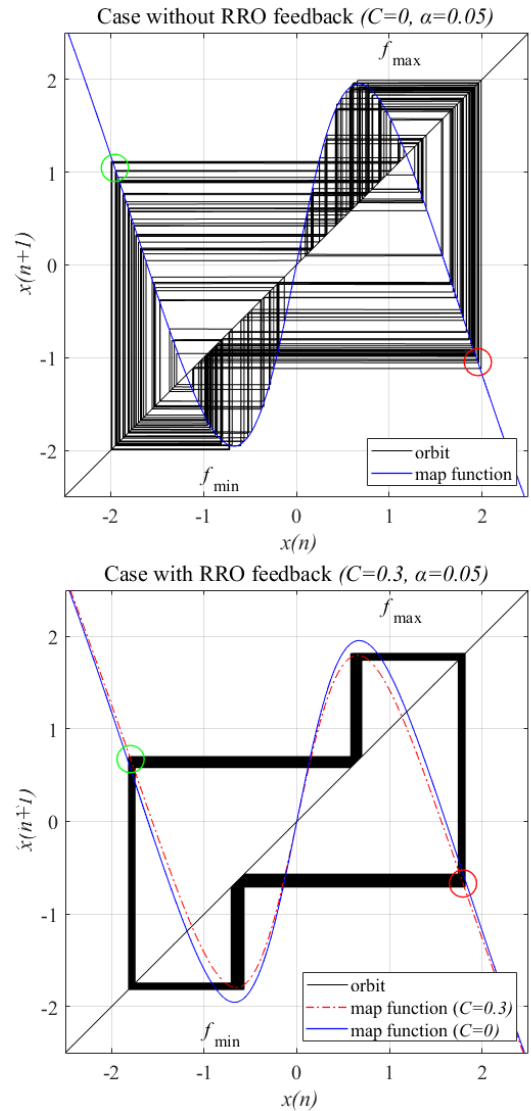


Fig. 10: Map function for $A = 16.7$ with and without RRO feedback signal $Cu(y(n))$ for weak input signal $S(n)$ and its return map between $x(n)$ and $x(n + 1)$ in the model composed of sensory cortex and frontal cortex.

ドバック信号によるカオス制御の効果のさらなる検証が挙げられる。具体的には、大脳基底核のシステム挙動を決定するパラメータの1つである S_3 を $S_3 \neq 0$ に設定し、 $x(n)$ に対する $y(n)$ の偶奇性保存の崩れに対するシステム挙動の分析が必要となる。また本研究では、微弱外部入力信号を前頭野に入力したが、これを大脳基底核に入力し非線形性が強化された場合のカオス共鳴制御への影響の違いの分析が挙げられる。

参考文献

- 1) V.S. Anishchenko, V. Astakhov, A. Neiman, T.Vadivasova and L. Schimansky-Geier : Non-linear Dynamics of Chaotic and Stochastic Systems: Tutorial and Modern Developments". Berlin; Heidelberg: Springer Science & Business Media (2007)
- 2) S. Rajasekar and MAF Sanjuán : Nonlinear Resonances, Cham: Springer (2016)
- 3) H. Nishimura, N. Katada, and K. Aihara : Coherent response in a chaotic neural network, Neural Process. Lett., **12**-1, 49/58 (2000)
- 4) T. Carroll and L. Pecora : Stochastic resonance and crises, Physical review letters, **70**-5, 576/579 (1993)
- 5) T. Carroll and L. Pecora : Stochastic resonance as a crisis in a period-doubled circuit, Physical Review E, **47**-6, 3941/3949 (1993)
- 6) A. Crisanti, M. Falcioni, G. Paladin, and A. Vulpiani : Stochastic resonance in deterministic chaotic systems, Journal of Physics A: Mathematical and General, **27**-17, 597/603 (1994)
- 7) G. Nicolis, C. Nicolis, and D. McKernan : Stochastic resonance in chaotic dynamics, Journal of statistical physics, **70**, no.1-2, pp.125-139, 1993.
- 8) S. Sinha and B.K. Chakrabarti : Deterministic stochastic resonance in a piecewise linear chaotic map, Physical Review E, **58**-6, pp.8009-8012, 1998.
- 9) Q. Li, H. Zeng, and X.S. Yang : On hidden twin attractors and bifurcation in the Chua's circuit, Non-linear Dynam., **77**, pp.255-266, 2014.
- 10) G.L. Baker, G.L. Baker, and J.P. Gollub : Chaotic Dynamics: An Introduction, Cambridge University Press, 1996.
- 11) I. Kovacic and M.J. Brennan : The Duffing Equation: Nonlinear Oscillators and Their Behaviour, John Wiley & Sons, 2011.
- 12) 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, **E101-A**-11, 1900/1906 (2018)
- 13) S. Nobukawa, H. Nishimura, T. Yamanishi, and H. Doho : 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, **E102-A**-3, 524/531(2019)
- 14) 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, **E103-A**-1, 303/312 (2020)
- 15) S. Nobukawa and N. Shibata : Controlling chaotic resonance using external feedback signals in neural systems, Scientific reports, **9**, Article number:4990 (2019)
- 16) 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, **9**, Article number:12630, 15 pages (2019)
- 17) 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, **14**, Article number:76, 15 pages (2020)
- 18) S. Nobukawa, H. Nishimura, H. Doho, and T. Takahashi : Stabilizing circadian rhythms in bipolar disorder by chaos control methods, Frontiers in Applied Mathematics and Statistics, **6**, Article number:562929, 11 pages (2020)
- 19) S. Nobukawa, N. Wagatsuma, H. Nishimura, H. Doho and T. Takahashi : An Approach for Stabilizing Abnormal Neural Activity in ADHD Using Chaotic Resonance, Frontiers in Computational Neuroscience, **15**, Article number:726641, 13 pages (2021)
- 20) G. Baghdadi, S. Jafari, J.C. Sprott, F. Towhidkhal and M.R. Hashime Golpayegani : A chaotic model of sustaining attention problem in attention deficit disorder, Commun Nonlinear Sci. Numer Simulat **20**, 174/185(2015)
- 21) P. S. Shabestari, Z. Rostami, V-T, Pham, P. E. Alsaadi and T. Hayat : Modeling of Neurodegenerative Diseases Using Discrete Chaotic Systems, **71**, 1241/1245(2019)