2023 年度発表文献集

Publication List 2023



東京理科大学 工学部情報工学科 池口研究室

Ikeguchi Laboratory,
Department of Information and Computer Technology,
Faculty of Engineering,
Tokyo University of Science

2024 年 4 月作成

目次

1 原著論文

(1) Mitsuki Fukuya, Tomoko Matsumoto, Yutaka Shimada, and Tohru Ikeguchi,
"Central emotions and hubs in a colexification network,"
Scientific Reports, Vol. 13, 21823, 2023.
https://doi.org/10.1038/s41598-023-48922-8 2

(2) Yota Tsukamoto, Honami Tsushima, and Tohru Ikeguchi,
"Analysis on responses of chaotic Izhikevich neurons to periodic forcing,"
Nonlinear Theory and Its Applications, IEICE, Vol. 14, No. 4, pp. 677–690, 2023.
https://doi.org/10.1587/nolta.14.677 10

(3) Yota Tsukamoto, Honami Tsushima, and Tohru Ikeguchi,
"Rich spike patterns from a periodically forced Izhikevich neuron model,"
Nonlinear Theory and Its Applications, IEICE, Vol. 14, No. 2, pp. 215–227, 2023.
https://doi.org/10.1587/nolta.14.215 24

2 査読あり国際会議

(1) Kazuya Sawada and Tohru Ikeguchi,
"Nonlinear dynamics of temporal network,"
Proceedings of 2024 Dynamics Days US, p. 7, Jan. 2024. 38

(2) Honami Tsushima, Takafumi Matsuura, Tohru Ikeguchi,
"Importance of Time Limit Constraint for Multiple-Vehicle Bike Sharing System Routing Problem,"
Proceedings of 2023 International Symposium on Nonlinear Theory and Its Applications (NOLTA 2023), 6036, Sep. 2023. 39

(3) Fengkai Guo, Honami Tsushima, Takafumi Matsuura, Takayuki Kimura, Tohru Ikeguchi,
"A Study on Two-Objective Posting Poster Problem for Public Office Election,,"
Proceedings of 2023 International Symposium on Nonlinear Theory and Its Applications (NOLTA 2023), 6157, Sep. 2023. 41

3 査読あり国内会議

(1) 福家 水月，松本 朋子，島田 裕，池口 徹,
"Colexification network を用いた語族比較,"
2023 年電子情報通信学会 NOLTA ソサイエティ大会, NLS-8, 2023. 46

(2) 郭 豊愷，對馬 帆南，松浦 隆文，木村 貴幸，池口 徹，
“二つの目的を考慮した公職選挙ポスター掲示問題に対する発見的解法の開発,”
2023 年電子情報通信学会 NOLTA ソサイエティ大会, NLS-13, 2023. 47
4 査読なし国内学会
(1) 塚本 陽太，塚田 啓道，塚田 稔，池口 徹，
“Hebb 則と時空間学習則の時空間学習則のパターン分離能力の比較,”
2024 年電子情報通信学会 総合大会, N-1-10, 2024 年. 49
(2) 澤田 和弥，島田 裕，池口 徹，
“スパイク列の発火率差が因果性検出に与える影響,”
2024 年電子情報通信学会 総合大会, N-1-20, 2024 年. 50
(3) 郭 豊愷，松浦 隆文，木村 貴幸，池口 徹，
“公職選挙ポスター掲示問題における初期解構築法の性能比較,”
2024 年電子情報通信学会 総合大会, N-1-22, 2024 年. 51
(4) 澤田 和弥，島田 裕，池口 徹，
“マーク付点過程に対する因果性検出手法の一検討,”
2023 年電子情報通信学会 ソサイエティ大会, N-1-21, 2023 年. 52
(5) 塚本 陽太，對馬 帆南，池口 徹，
“カオス応答を呈する Izhikevich ニューロンに正弦波入力を印加した場合の応答解析,”
2023 年電子情報通信学会 ソサイエティ大会, N-1-24, 2023 年. 53
5 学位論文
5.1 博士論文
(1) 澤田 和弥,
“Detecting causality for point processes based on nonlinear dynamical system theory,”
東京理科大学 大学院 工学研究科情報工学専攻, 博士論文 2024. 55
5.2 修士論文
(1) 郭 豊愷,
“Solving the Posting Poster Problems for Public Office Election Using Heuristic Methods,”
東京理科大学 大学院工学研究科 情報工学専攻, 修士論文 2024. 58
(2) 塚本 陽太,
“Pattern Discrimination Ability of Spatiotemporal Learning Rule and the Effect of Temporal History,”
東京理科大学 大学院工学研究科 情報工学専攻, 修士論文 2024. 60
5.3 卒業論文
(1) 阿部 賢一,
“てんかん患者の脳波データに対する再帰定量化解析,”
東京理科大学 工学部 情報工学科, 卒業論文 2024. 62

(2) 新井 慎之介,
“セルオートマトンを用いた交通モデルによる最適な信号サイクル長の解析に関する研究,”
東京理科大学 工学部 情報工学科, 卒業論文 2024. 66
(3) 市川 健太,
“アルファ近接度を用いたカオスダイナミクスによる TSP の解法,”
東京理科大学 工学部 情報工学科, 卒業論文 2024. 70
(4) 関口 真音,
“てんかん患者の脳波データに対する再帰定量化解析,”
東京理科大学 工学部 情報工学科, 卒業論文 2024. 74
(5) 山口 倖之介,
“擬似乱数生成器の統計的性能評価に関する研究,”
東京理科大学 工学部 情報工学科, 卒業論文 2024. 78
(6) 山本 陽翔,
“拡張時空間学習則のパターン分離能力の解析,”
東京理科大学 工学部 情報工学科, 卒業論文 2024. 82
(7) 吉田 しおん,
“Echo State Network を用いた非線形時系列予測に関する研究,”
東京理科大学 工学部 情報工学科, 卒業論文 2024. 86

6 その他の国内発表会

6.1 研究会

(1) 吉田 しおん，池口 徹,
“エコーステートネットワークにおけるリザバー層のダイナミクス,”
電子情報通信学会 技術研究報告, vol. 123, no. 287, NLP2023-62, pp. 15–20, 2023. 91
(2) 関口 真音，池口 徹,
“てんかん患者の脳波データに対する再帰定量化解析,”
電子情報通信学会 技術研究報告, vol. 123, no. 287, NLP2023-64, pp. 21–26, 2023. 97

6.2 東北大学電気通信研究所共同プロジェクト研究発表会

(1) Kazuya Sawada and Tohru Ikeguchi,
“Detecting causality for marked point processes with twin surrogate method,”
FY 2023 RIEC Annual Meeting on Cooperative Research Projects, B-37 I, Feb. 2024. 103
(2) Makoto Sekiguchi and Tohru Ikeguchi,
“Determinisity of electroencephalogtaphic (EEG) potentials of epileptic seizure,”
FY 2023 RIEC Annual Meeting on Cooperative Research Projects, B-37 II, Feb. 2024. 104
(3) Shion Yoshida and Tohru Ikeguchi,
“Dynamics of reservoir layer in time series prediction,”
FY 2023 RIEC Annual Meeting on Cooperative Research Projects, B-37 III, Feb. 2024. 105

7 非線形ワークショップ

7.1 2023 年 5 月, 日本工業大学

(1) 郭豊 愷,
“二つの目的を考慮した公職選挙ポスター掲示問題に対する発見的開放の開発,”
非線形ワークショップ, 2023. 107
(2) 福家 水月,
“意味ネットワークを用いた語族比較,”
非線形ワークショップ, 2023. 108
7.2 2023 年 7 月, 東京理科大学
(1) 澤田 和弥,
“マーク付点過程に対する因果性検出,”
非線形ワークショップ, 2023. 109
(2) 塚本 陽太,
“時空間学習則において時間履歴がパターン分離能力とシナプス荷重の関係に与える影響,”
非線形ワークショップ, 2023. 110
(3) 吉田 しおん,
“エコーステートネットワークを用いたカオス時系列予測,”
非線形ワークショップ, 2023. 111
7.3 2023 年 8 月, 夏の大会
(1) 郭豊 愷,
“公職選挙ポスター掲示問題においてグルーピング手法に関する調査,”
夏の大会, 2023. 112
(2) 塚本 陽太,
“時空間学習則の時間履歴によるパターン分離能力とシナプス荷重分布の関係の変化,”
夏の大会, 2023. 113
(3) 福家 水月,
“多義語ネットワークにおける中心頂点の調査,”
夏の大会, 2023. 114
(4) 阿部 賢一,
“論文 Lyapunov exponents for temporal networks の紹介,”
夏の大会, 2023. 115
(5) 新井 慎之助,
“交通流と Nagel-Schreckenberg モデルの紹介,”
夏の大会, 2023. 116
(6) 市川 健太,
“巡回セールスマン問題に対する近似解放のアルゴリズムの比較,”
夏の大会, 2023. 117
(7) 関口 真音,
“脳波データのアトラクタ再構成における適切な遅れ時間,”
夏の大会, 2023. 118

(8) 山本 陽翔,
“拡張時空間学習則のパターン分離能力,”
夏の大会, 2023. 119
(9) 吉田 しおん,
“リザバーコンピューティングにおけるリザバー層のダイナミクス,”
夏の大会, 2023. 120
7.4 2023 年 11 月, 東京都市大学
(1) 郭豊 愷,
“公職選挙ポスター掲示問題を解く手法に関する調査,”
非線形ワークショップ, 2023. 121
(2) 新井 慎之助,
“論文 A Multi-agent nased cellular automata for intersection traffic control simulation の紹介,”
非線形ワークショップ, 2023. 122
(3) 関口 真音,
“てんかん患者の脳波データに対する再帰定量化解析,”
非線形ワークショップ, 2023. 123
(4) 山本 陽翔,
“拡張時空間学習則のパターン分離能力とその頑健性,”
非線形ワークショップ, 2023. 124
(5) 吉田 しおん,
“ESN を用いたロジスティック写像の予測におけるパラメータの影響,”
非線形ワークショップ, 2023. 125
7.5 2023 年 12 月, 埼玉大学
(1) 福家 水月,
“多義語ネットワークにおける中心感情と基本的感情の関係,”
非線形ワークショップ, 2023. 126
(2) 阿部 賢一,
“時系列のテンポラルネットワーク変換と解析,”
非線形ワークショップ, 2023. 127
(3) 市川 健太,
“巡回セールスマン問題に対するカオスタブーサーチにおけるアルファ近接度の有効性,”
非線形ワークショップ, 2023. 128
7.6 2024 年 2 月, 東北大学
(1) 池口 徹,
“統計的検定を用いた疑似乱数生成器の性能比較,”
東北大学電気通信研究所共同プロジェクト研究，非線形ワークショップ合同研究会, L5, 2024. 129

(2) 塚本 陽太，塚田 啓道，塚田 稔，池口 徹,
“Hebb 則と時空間学習則のパターン分離能力の比較,”
東北大学電気通信研究所共同プロジェクト研究，非線形ワークショップ合同研究会,
L5, 2024. 130
(3) 吉田 しおん，池口 徹,
“リザバー層の力学系に対する再帰定量化解析,”
東北大学電気通信研究所共同プロジェクト研究，非線形ワークショップ合同研究会,
L5, 2024. 131
(4) 山本 陽翔，池口 徹,
“時空間学習則のパターン分離能力,”
東北大学電気通信研究所共同プロジェクト研究，非線形ワークショップ合同研究会,
L5, 2024. 132
(5) 澤田 和弥，池口 徹,
“サロゲートデータを用いた点過程に対する因果性検出,”
東北大学電気通信研究所共同プロジェクト研究，非線形ワークショップ合同研究会,
L5, 2024. 133
(6) 郭豊 愷，松浦 隆文，木村 貴幸，池口 徹,
“公職選挙ポスター掲示問題における初期解構築法の性能比較,”
東北大学電気通信研究所共同プロジェクト研究，非線形ワークショップ合同研究会,
L5, 2024. 134
8 受賞，その他
(1) 塚本 陽太,
電子情報通信学会 2023 年度学術奨励賞,
2024 年 3 月 5 日 136
(1) 塚本 陽太,
2023 年度 東京理科大学 学生表彰,
2024 年 3 月 7 日 137
(1) 塚本 陽太,
2023 年度 東京理科大学奨励賞,
2024 年 3 月 18 日 138

原著論文

www.nature.com/scientificreports

scientific reports

Check for updates

OPEN

Central emotions and hubs in a colexification network

Mitsuki Fukuya[1]✉, Tomoko Matsumoto[2,4], Yutaka Shimada[3,4] & Tohru Ikeguchi[1,4]

By focusing on colexification, we detected central emotions sharing semantic commonalities with many other emotions in terms of a semantic relationship of both similarity and associativity. In analysis, we created colexification networks from multiple languages by assigning a concept to a vertex and colexification to an edge. We identify concepts of emotions with a large weight in the colexification network and specify central emotions by finding hub emotions. Our resultant central emotions are four: "GOOD," "WANT," "BAD," and "LOVE."

Emotions have a significant influence on human decision-making and behavior. The study of the semantics of emotion words has a rich history in the fields of psychology and linguistics. This research includes both qualitative semantic analyses (e.g., Wierzbicka, 1992[1], 1999[2] and Johnson-Laird et al., 1989[3]) and quantitative analysis based on semantic similarity ratings (e.g., Russell, 1980[4]). Recently, unlike these traditional studies, Jackson et al. introduced a novel strategy for the classification of emotions using a colexification dataset from a perspective of network theory[5].

Colexification is the phenomenon of a single word associated with multiple concepts having assumed semantic relationships[6]. For example, the Spanish word "malo" can have two meanings "BAD" and "SEVERE"; thus, the two concepts, "BAD" and "SEVERE," are colexified in Spanish. Colexification indicates that the concepts have relevance, including similarity and associativity, which might generate perceived covariation and co-occurrence[7]. Colexification analysis is a newer linguistic method of indirect semantic similarity analysis that has the advantage of not requiring the collection of similarity data from subjects, because it is based on an existing semantic relation (known from translation dictionaries and the like). Jackson et al. focused on the concepts of emotions (emotional concepts) and identified groups of the emotional concepts by a cluster analysis based on the similarity between the emotional concepts in the relevance[5]. However, Jackson et al. only compared languages through the identified groups of the emotional concepts in the colexification network, and they did not sufficiently discuss the relationship between emotions and features of vertices corresponding to the emotional concepts in the colexification network.

Therefore, in this study, we attempted to clarify the relationship between the structure of a colexification network and emotions by identifying hubs in the colexification network. We created a colexification-based network, where vertices represent concepts of emotions, and two vertices are connected if their corresponding concepts are directly or indirectly colexified. A vertex connected with many edges in a network is termed as a hub in the network theory. In a network, emotions corresponding to hub vertices are semantically related to many other emotions. We identified hub vertices within the colexification network, which we refer to as *"central emotions."* We will later discuss how the central emotions differ from the traditional concept of basic emotions, thereby elucidating the significant emotions within a colexification network. As a result, we extracted four central emotions as follows: "GOOD," "WANT," "BAD," and "LOVE."

Estimating central emotions through network theory offers a distinct advantage, as it allows us to identify emotions evoked not only by similar emotions but also dissimilar emotions that are linked to each other associatively or by cooccurence (e.g. Kuppens et al., 2004[7]). Hence, central emotions hold significance not only within relationships based on similarity, but also across relationships that span different groups.

Methods

Creating a network of colexification

Figure 1 shows a flow of how to generate an emotional colexification network.

[1]Department of Information and Computer Technology, Tokyo University of Science, 6-3-1 Niijuku, Katsushika-ku 125-8585, Tokyo, Japan. [2]Institute of Arts and Sciences, Tokyo University of Science, 1-3 Kagurazaka, Shinjuku-ku 162-8601, Tokyo, Japan. [3]Department of Information and Computer Sciences, Saitama University, 255 Shimo-okubo Sakura-ku, Saitama-shi 338-8570, Saitama, Japan. [4]These authors contributed equally: Tomoko Matsumoto, Yutaka Shimada, Tohru Ikeguchi. ✉email: fukuya@hisenkei.net

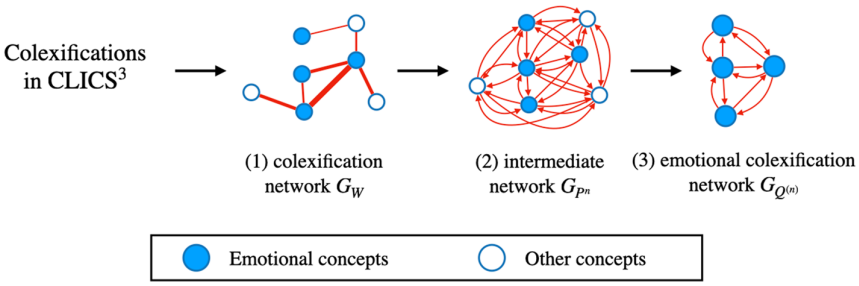


Figure 1. How to generate an emotional colexification network for our analysis.

First, we created a weighted adjacency matrix $W = (w_{ij})$ using all concepts in CLICS[38] and defined a colexification network G_W, whose weighted adjacency matrix is W (Fig. 1(1)). In the colexification network G_W, the vertices represent concepts. Two vertices are connected by a weighted edge when their corresponding concepts are colexified in one or more languages. Let c_i be a concept corresponding to vertex i and w_{ij} be the weight of the edge connecting vertices i and j, which corresponds to the number of languages in which two concepts c_i and c_j are colexified. Figure 2 shows how to define an edge weight in a colexification network. An example in Fig. 2 uses three concepts "BAD," "SEVERE," and "UGLY," which are colexified in Spanish, French, and Russian.

In Fig. 2, for example, the weight of the edge connecting "BAD" and "SEVERE" is two because "BAD" and "SEVERE" are colexified in two languages, French and Spanish. Concepts connected by edges with large weights tend to be colexified in many languages and more relevant to each other.

Second, we created an intermediate network G_{P^n} (Fig. 1(2)). In Fig. 2, no edges are drawn between "SEVERE" and "UGLY"; however, both these concepts and "BAD" are colexified in three languages. Therefore, "SEVERE" and "UGLY" have an indirect connection through the colexification associated with "BAD."

To quantify this indirect relationship and clarify relationships between distant vertices, we applied a random walk approach to the colexification network. In our random walk approach, random walkers move along edges based on the transition probability matrix $P = (p_{ij})$, where p_{ij} is the probability of a random walker on vertex i moving to vertex j in network G_W. In a network G_W with N_W vertices, p_{ij} is defined as $p_{ij} = w_{ij} / \sum_{s=1}^{N_W} w_{is}$. The transition probability matrix after n steps is P^n, and the (i, j)th element of P^n, namely p_{ij}^n, shows the indirect relationship between concepts c_i and c_j. The transition probability matrix is expected to converge as n increases mathematically, and then P^n satisfies $p_{ij}^n = \pi_j$ for a sufficiently large n, where π_j is the probability of being at vertex j and satisfies $\sum_{j=1}^{N_W} \pi_j = 1$.

In the following, we set $n = 10^3$, where p_{ij}^n nearly converged. We created a network G_{P^n} whose directed weighted adjacency matrix is P^n. The network G_{P^n} is a directed network as the edge weights are transition probabilities, and it quantifies the indirect relationships between vertices. In a network G_{P^n}, p_{ij}^n shows the relevance of the vertex i to the vertex j as the edge weights. Moreover, if p_{ij}^n with a large n has a large value, a random walker in the network G_{P^n} will reach vertex j from vertex i after passing through many vertices. In other words, the concept c_j is likely to be associated with the concept c_i via many concepts when p_{ij}^n has a large value.

Finally, we created an emotional colexification network $G_{Q^{(n)}}$ (Fig. 1(3)). We defined 25 typical emotional concepts based on the definitions of typical emotions from a previous study[5] (see also Sec. S1 in SI text for details). Extracting the 25 typical emotional concepts and edges that connect them from the network G_{P^n}, we generated a 25×25 weighted adjacency matrix $Q^{(n)} = (q_{ij}^{(n)})$ by deleting rows and columns corresponding to concepts that are not the 25 typical emotional concepts. By focusing on emotional concept c_j when $q_{ij}^{(n)}$ is large in a network $G_{Q^{(n)}}$, we identify the emotional concepts having a strong relevance to other emotional concepts. We defined hubs in a network $G_{Q^{(n)}}$ from meaning-intensive emotional concepts.

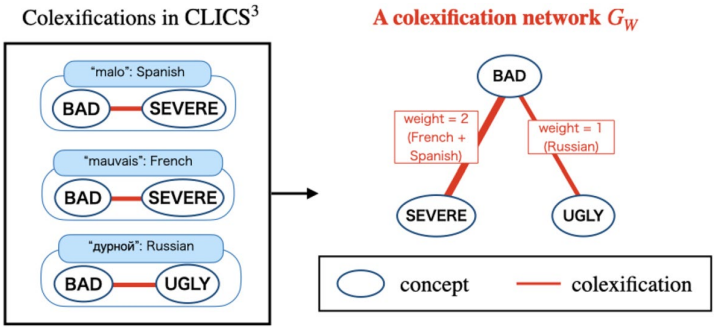


Figure 2. How to define an edge weight in the colexification network G_W.

Specifying hub vertices

In this study, we used the emotional colexification network that is a directed weighted network. Thus, we defined a hub as a vertex whose sum of weights of incoming edges is large. An incoming edge connecting to vertex i in the emotional colexification network indicates the strength of relevance in terms of other concepts. We defined the strength of incoming edges of a vertex i, denoted by $\mathrm{In}_{\mathrm{i}}^{(\mathrm{n})}$, as follows: $\mathrm{In}_{\mathrm{i}}^{(\mathrm{n})} = \sum_{\mathrm{j}=1,\mathrm{j}\neq\mathrm{i}}^{\mathrm{N}_{\mathrm{Q}^{(\mathrm{n})}}} \mathrm{q}_{\mathrm{ji}}^{(\mathrm{n})}$, where $N_{Q^{(n)}}$ is the number of vertices in $G_{Q^{(n)}}$, $q_{ji}^{(n)}$ is the probability that a random walker on vertex j moves to vertex i after n steps, and π_i is the probability of being at vertex i. If $q_{ji}^{(n)}$ converges to π_i in any j for $n \to \infty$, $\mathrm{In}_{\mathrm{i}}^{(\mathrm{n})}$ is described as follows: $\mathrm{In}_{\mathrm{i}}^{(\mathrm{n})} = (\mathrm{N}_{\mathrm{Q}^{(\mathrm{n})}} - 1)\pi_{\mathrm{i}}$. The strength $\mathrm{In}_{\mathrm{i}}^{(\mathrm{n})}$ is proportional to the probability of reaching a vertex i from all vertices in an emotional colexification network $G_{Q^{(n)}}$. In other words, the strength $\mathrm{In}_{\mathrm{i}}^{(\mathrm{n})}$ is associativity based on the relevance of a concept corresponding to vertex i to all concepts.

We also defined $r_i^{(n)}$ as the rank of vertex i in the descending order of $\mathrm{In}_{\mathrm{i}}^{(\mathrm{n})}$, and the rate of change in $\mathrm{In}_{\mathrm{i}}^{(\mathrm{n})}$ is denoted by $\theta_i^{(n)}$, as follows: $\theta_i^{(n)} = \mathrm{In}_{\mathrm{i}}^{(\mathrm{n})}/\mathrm{In}_{\mathrm{h}}^{(\mathrm{n})}$, where vertex h has a rank $r_h^{(n)}$ satisfying $r_h^{(n)} = r_i^{(n)} + 1$.

We defined hubs in the emotional colexification network $G_{Q^{(n)}}$ as vertices with large $\mathrm{In}_{\mathrm{i}}^{(\mathrm{n})}$ and the largest $\theta_i^{(n)}$. Concepts corresponding to hubs in network $G_{Q^{(n)}}$ are considered to be abstract and have many elements in common with other emotional concepts. We interpret these concepts as central emotions from the perspective of language using colexification.

Investigating relationships of emotions

The network $G_{Q^{(n)}}$ shows not only direct but also indirect relationships as weights of edges. However, the direct relationships have stronger relevance than indirect relationships. To represent both of these direct and indirect relationships as edge weights in the network, a directed weighted adjacency matrix $R^{(n)}$ is defined as follows: $R^{(n)} = \sum_{s=1}^{n} \alpha^s Q^{(s)}$. The elements of $Q^{(n)}$ are always larger than or equal to 0. Therefore, $\alpha = 0.8$, so that the values of the elements of R converge as n increases. We define a network $G_{R^{(n)}}$ whose directed weighted adjacency matrix is $R^{(n)}$, and call $G_{R^{(n)}}$ an aggregated emotional colexification network.

To extract a set of emotional concepts densely connected to each other in the aggregated emotional colexification network $G_{R^{(n)}}$, we used the cluster optimal community detection algorithm (cluster_optimal in R-igraph)[9]. Emotional concepts belonging to the same community are strongly related to each other. Then, we defined the result of community detection of emotional concepts as the discrete classification of emotions based on the similarity of emotions. To show the relationship between the results of community detection and hubs in the emotional colexification network $G_{R^{(n)}}$, the emotional concepts with high relevance to the emotional concepts of the hubs were stratified by hierarchical clustering of edge weights.

Results

Figure 3 shows the networks $G_{Q^{(n)}}$ and distributions of edge weights with increasing n.

At all networks $G_{Q^{(n)}}$ in Fig. 3, the thickness and color of the edges, namely edge weights in the network $G_{Q^{(n)}}$, change as n increases and converge to a constant value when $n = 10^3$ (Fig. 3d). Moreover, the distributions of edge weights in Fig. 3c,d show that edges with the same weights exist in networks $G_{Q^{(10^2)}}$ and $G_{Q^{(10^3)}}$.

The network $G_{Q^{(10^3)}}$ in Fig. 3a shows that most of the red edges with large weights are connected to the four vertices "GOOD," "WANT," "BAD," and "LOVE." These red edges were identified as the edge weights indicated by the four red circles located on the right side of the distribution of edge weights when $n = 10^3$.

Moreover, we also found that the four red circles in Fig. 3d indentify edges with significantly large weights directed to the four vertices, or "GOOD," "WANT," "BAD," and "LOVE." This means that these four vertices are most likely to acquire edges with high weights in the emotional colexification network.

We calculated $\mathrm{In}_{\mathrm{i}}^{(10^3)}$ and $\theta_i^{(10^3)}$ of vertices in the emotional colexification network $G_{Q^{(n)}}$ when $n = 10^3$ to confirm that the above-mentioned four vertices are hubs. Table 1 presents the rank of $\mathrm{In}_{\mathrm{i}}^{(\mathrm{n})}$ and $\theta_i^{(n)}$. In Table 1, the four concepts, "GOOD," "WANT," "BAD," and "LOVE" have the largest values of $\mathrm{In}_{\mathrm{i}}^{(\mathrm{n})}$. Moreover, the rate of change $\theta_i^{(n)}$ of "LOVE" is 1.8, which is near two and the largest among the four vertices with high values of $\mathrm{In}_{\mathrm{i}}^{(\mathrm{n})}$. For vertex i, where $r_i^{(n)}$ is lower than four, the value of $\theta_i^{(n)}$ is nearly constant and close to unity. These results indicate that these four vertices have edges with high weights and can be considered hubs in the emotional colexification network. Therefore, we defined the four emotional concepts, "GOOD," "WANT," "BAD," and "LOVE," which are hubs in the emotional colexification network. Thus, we identified central emotions considered on the emotional colexification network, which are connected with a strong relevance to other concepts, namely "GOOD," "WANT," "BAD," and "LOVE."

To visualize how strongly other emotional concepts have relevance to the emotional concepts corresponding to "GOOD," "WANT," "BAD," and "LOVE," we classified the network vertices into multiple layers according to the strength of their relevance with the hubs. Figure 4 shows an aggregated emotional colexification network to confirm the relationships between four hubs and other vertices.

In Fig. 4, we arranged vertices on six layers: hubs are placed on Layer 1, vertices having a strong connection with these four hubs are placed on Layer 2, and vertices having a strong connection with vertices on Layer l are placed on Layer $l + 1$ ($l = 1, \ldots, 5$) (see Sec. S2 in SI text for details). The vertices belonging to the same community have the same color; five communities were identified by the community detection. The vertices in Layers 2 and 3 have high relevance for emotional concepts corresponding to the four hubs, and most of the vertices belong to the community to which the hub belongs. However, in the communities where the color of the vertices is pink or blue, concepts with lower relevance to the hub were identified such as "HOPE," "HAPPY," and "GLOOMY."

Focusing on relationships between hub vertices and communities in Fig. 4, a community whose color of vertices is pink has two hubs, "LOVE" and "WANT," whereas communities whose color of vertices is yellow and green have no hub. This indicates that in the emotional colexification network, concepts that are easily associated with many concepts and communities based on relevance are independent of each other.

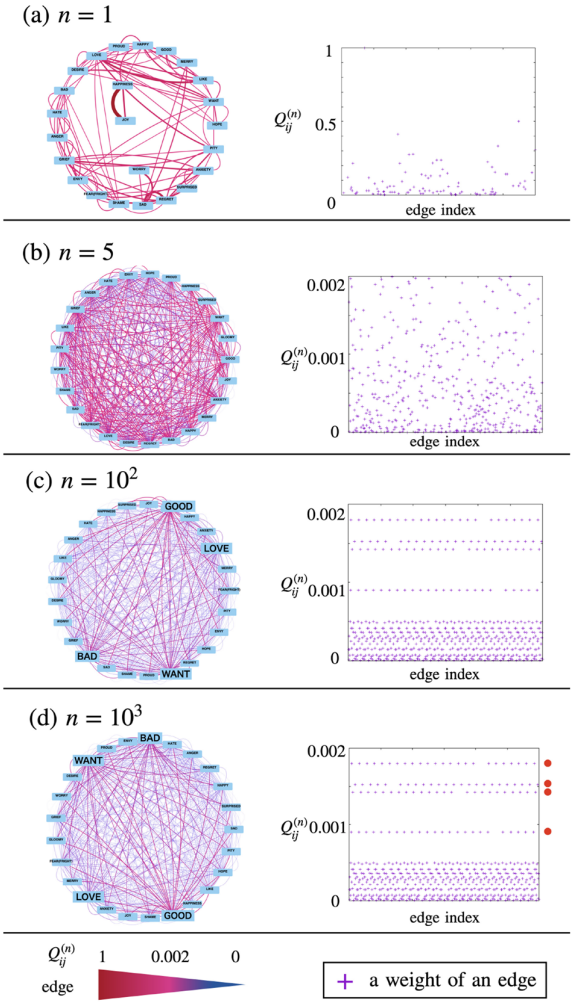


Figure 3. Emotional colexification networks and distributions of edge weights when $n = 1, 5, 10^2$, and 10^3. The left panel shows emotional colexification networks $G_{Q^{(n)}}$. The width of an edge in the networks becomes large as the edge weight increases. The color of an edge in the networks changes to red from blue as the edge weight increases. Four vertices corresponding to emotional concepts – "GOOD," "WANT," "BAD," and "LOVE" – are connected by red edges with large weights in the network $G_{Q^{(10^3)}}$. The right panel plots of distributions of edge weights in the networks $G_{Q^{(n)}}$ as $n = 1, 5, 10^2$, and 10^3. The vertical and horizontal axes indicate edge index and edge weights, respectively. Four red circles indicate incoming edge weights of the four vertices.

The advantage of our study is to quantify relationships not only between similar emotions but also between dissimilar emotions that are linked to each other associatively or by cooccurence. We examined the relevance between the most fundamental mutually exclusive emotional concepts: "GOOD" and "BAD." The result in Fig. 4 shows that "GOOD" and "BAD" were mutually connected by an edge whose weight is 2.74×10^{-3} and an edge whose weight is 3.47×10^{-3} in the emotional colexification network (Fig. 4). To investigate the concepts associated with the relevance between "GOOD" and "BAD," we have illustrated their colexifications as depicted in Fig. 5.

Figure 5 shows the results of extracting the concepts having colexifications with "GOOD" and "BAD" in the network G_W. The six concepts surrounded by the black square in Fig. 5, demonstrate colexifications with both "GOOD" and "BAD." Among these six concepts, "BRAVE" is a concept evoked from relevance to "GOOD" and "BAD." Furthermore, we find two elements to the English word *brave*: admirable and reckless. Hence, within the colexification network, relationships between dissimilar emotions that are linked to each other associatively or by cooccurence can indeed exist owing to the consideration of both similarity and associativity. Thus, our approach facilitates the identification of concepts that serve as bridges between emotional concepts from a new perspective.

$r_i^{(n)}$	Vertex	$\mathrm{In}_i^{(n)}$	$\theta_i^{(n)}$
1	GOOD	4.49×10^{-2}	1.17
2	WANT	3.81×10^{-2}	1.07
3	BAD	3.55×10^{-2}	1.57
4	LOVE	2.25×10^{-2}	1.80
5	FEAR (FRIGHT)	1.25×10^{-2}	1.03
6	GRIEF	1.21×10^{-2}	1.16
7	LIKE	1.04×10^{-2}	1.00
8	HAPPY	1.03×10^{-2}	1.13
9	HATE	9.10×10^{-3}	1.01
10	DESIRE	8.99×10^{-3}	1.13
11	ANGER	7.92×10^{-3}	1.07
12	REGRET	7.38×10^{-3}	1.04
13	HOPE	7.06×10^{-3}	1.13
14	ANXIETY	6.21×10^{-3}	1.16
15	SHAME	5.35×10^{-3}	1.31
16	PITY	4.06×10^{-3}	1.11
17	ENVY	3.64×10^{-3}	1.00
18	PROUD	3.64×10^{-3}	1.89
19	SURPRISED	1.92×10^{-3}	1.12
20	SAD	1.71×10^{-3}	1.23
21	HAPPINESS	1.39×10^{-3}	1.85
22	MERRY	7.49×10^{-4}	1.75
23	JOY	4.28×10^{-4}	1.33
24	WORRY	3.21×10^{-4}	3.00
25	GLOOMY	1.07×10^{-4}	

Table 1. Rank of $\mathrm{In}_i^{(n)}$ and the rate of change $\theta_i^{(n)}$ in network $G_{Q^{(n)}}$ when $n = 10^3$.

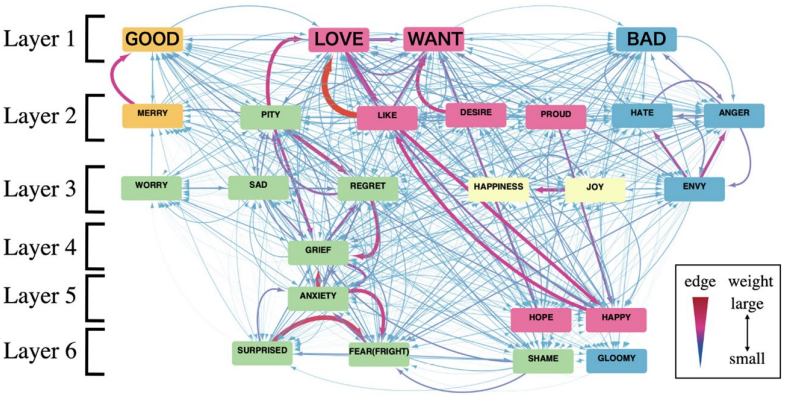


Figure 4. The aggregated emotional colexification network. Vertices of the same color indicate that they belong to the same community. Red edges indicate large edge weights. The thickness of the edges indicates large edge weights.

Discussion

We detected four hub emotions: "GOOD," "WANT," "BAD," and "LOVE." The characteristics of these central emotions are discussed below in comparison with the related concepts such as basic emotions in the fields of psychology and biology and semantic primes in the field of linguistics.

First, we compared the central emotions identified in the colexification analysis with two prominent proposals regarding the biologically basic emotions of humans. Studies of basic emotions have a long and rich history, originating from the pioneering work of Charles Darwin[10], who argued that biologically basic emotions are

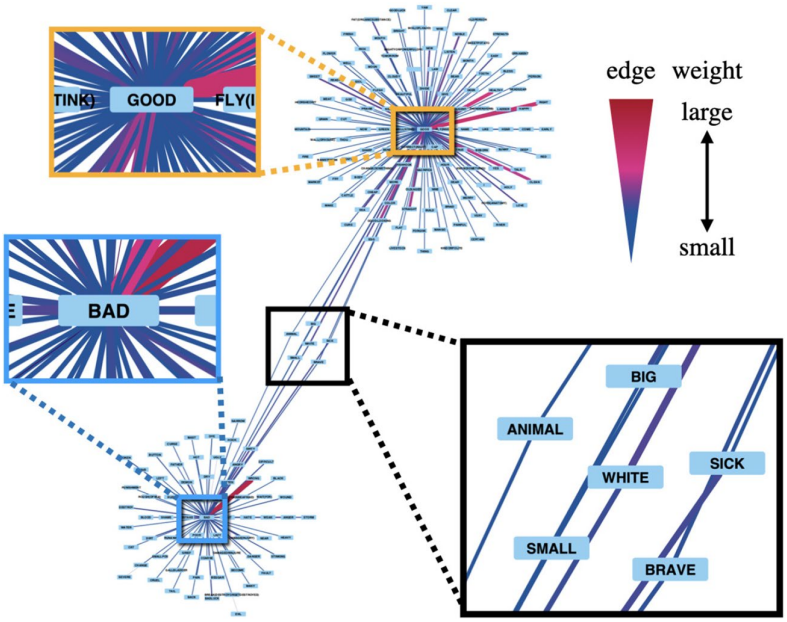


Figure 5. Concepts which have colexifications both "GOOD" and "BAD." Red edges indicated large weights, and blue edges indicated small weights.

characterized by typical facial expressions. Building partly on Darwin, Paul Ekman provided evidence for six basic emotions characterized by distinct facial expressions[11, 12]. Several other researchers also proposed lists of basic emotions[13–15]; however, it should be noted that the exact number and identity of the biologically basic emotions remain a subject of debate among psychologists (e.g., Ortony and Turner, 1990[16]; Ortony, 2022[17]), as is the relation of the proposed basic to nonbasic emotions (e.g., Ekman, 1992[18]; Johnson-Laird and Oatley, 1989[3]). Although our study is concerned with people's emotional concepts rather than with emotions per se, our findings are relevant to these debates if one assumes that the prominent role that basic emotions are claimed to play by basic emotion theorists in human experience is reflected in the emotion lexicon in semantically central concepts. Based on this assumption, we compared the four central emotions detected in the colexification analysis ("GOOD," "WANT," "BAD," and "LOVE") with seven inherited emotions discussed in detail by Darwin (sadness, happiness, anger, contempt, hate, fear, and surprise) and the six basic emotions originally proposed by Ekman (happiness, sadness, anger, fear, disgust, and surprise). Evidently, there is only very limited agreement. Although "GOOD" and "BAD" can be interpreted as referring generally to, respectively, positive emotions (feeling good) and negative emotions (feeling bad) and the emotions proposed by Darwin and Ekman are either positive (happiness) or negative (all other emotions with the exception of surprise), none of the basic emotions proposed by these theorists corresponds exactly to one of our central emotions. Conversely, the states referred to by "LOVE" and "WANT" do not have counterparts in the list of basic emotions proposed by Darwin and Ekman.

Second, we compared our four central emotions to the list of semantic primes assumed in the natural semantic metalanguage (NSM) proposed by Wierzbicka and coworkers. NSM is a system of meaning representation based on a set of conceptual primitives, called semantic primes, that have been found to be encoded in numerous languages and on this basis, are assumed to be universal, by NSM theorists[19, 20]. To identify the semantic primes, the NSM researchers studied numerous languages using traditional semantic methods. Intriguingly, the set of semantic primes includes three of our four central emotion concepts: "GOOD," "BAD," and "WANT." This agreement supports our conclusion that the central concepts identified by colexification analysis are shared by many languages rather than being specific to English. It also shows that the identification of the central emotion concepts is not specific to colexification analysis, because three of them were also obtained using traditional semantic analysis. The exception is "LOVE," which we identified as a central emotion concept but which is not on the list of semantic primes. However, rather than considering this non-agreement as problematic, we believe it shows that our quantitative semantic method, or analysis by colexification networks, is able to identify possible candidates of semantic primes that have been overlooked by the traditional semantic analysis.

Although the discussion so far has been comparison of our central emotions with basic emotions and semantic primes, various other theories of emotions exist such as appraisal theories of emotions[21, 22] and psychological constructionist theories of emotions[23]. For example, following the definition of emotion in the appraisal theory of emotions by Gendron and Barrett[21], emotion is an act of making meaning whereas emotional concepts in the colexification network, or the central emotions, are concepts based on the meaning of words and are defined from a language perspective. On the other hand, Mun described that the psychological constructionist theory of emotions differs from the basic emotions theory and the appraisal theory of emotions, which define emotions as

products of individual psychological interpretations[24]. Thus, in comparing these emotion theories, concepts of emotion in the colexification approach may help provide new insights into emotions and needs to be discussed in more depth in the future.

Furthermore, the concepts "GOOD," "WANT," and "BAD" that were obtained as central emotions can be also used to evaluate emotional states and in this case they do not directly represent emotions. Therefore, we additionally investigated the emotional concepts in the colexification network without these three central emotions (see Sec. S3 in SI text). The result indicates that even when the three vertices of "GOOD," "WANT," and "BAD" were not considered, the ranking order of the other emotional concepts remained consistent and did not fluctuate; the rate of change $\theta_i^{(n)}$ for "LOVE" is larger than 1.5 and is ranked as the first.

Conclusion

Emotions have an important role in human communication. In our analysis, we specified central emotions by finding hub emotions in the emotional colexification network. We confirmed that the vertices corresponding to the following emotional concepts are central emotions: "GOOD," "WANT," "BAD," and "LOVE." Furthermore, by expressing the relationships between emotional concepts in an emotional colexification network, we clarified the relationships between emotional concepts considered not having relevance for their dissimilarity.

This study contributes to the literature on basic emotions by adding new knowledge from a novel perspective. Many studies in the field of psychology explore basic emotions only with a focus on the similarity of emotional concepts. Further, we quantified not only the similarity between concepts but also their associativity in the network. Thereby, our detected central emotions reflect the relationship between emotional concepts, not only within groups based on similarity but also across the groups.

These findings are broadly connected with the literature on natural language processing. Concepts associated with sentiments or emotions play an important role in the field of natural language processing, particularly sentiment analyses. The sentiment analysis methods enable us to identify semantically positive and negative orientations of written texts and have various applications such as identifying the sentiment orientation of product reviews[25], predicting votes from congressional reports[26], management research[27], assessing damages caused by disasters[28], and mental health applications[29,30]. Despite these wide applications of sentiment analysis techniques, fine-grained sentiment analysis still seems to be difficult because many sentiment classifiers thus far provide only a few semantic orientations, for example, positive, negative, and neutral orientations. To obtain further fine-grained sentiment analyses, it is necessary to understand significant emotions and the inter-emotional-concept relationships discussed in this paper. In this sense, our findings can also potentially contribute to further technological advances in sentiment analysis and increase the range of its applications.

In this study, we examined the colexification of central emotions for all languages combined, i.e. without distinguishing between different languages or language families. However, as Jackson et al. show that colexification networks differ more or less between different language families, there might also be differences between languages in central emotion concepts by the colexification networks. Possible reasons for these differences are (i) that the emotion concepts include partly different meanings in different languages and (ii) that the patterns of perceived (and possibly, of actual) covariation between emotions differ between cultures (Kuppens et al., 2004[7]). To mitigate such concern, we separately examined which emotions serve as core emotions within each of the two language families: Austronesian languages and Indo-European languages. The result is that the central emotions, "GOOD," "WANT," "BAD," and "LOVE" consistently appear in these colexification networks (see Sec. S4 in SI text for details).

Finally, it is important to acknowledge the limitations of colexification-based analyses of emotions. Colexification is only one facet of the semantic relationships among emotion terms, and the CLICS^3 database does not include all existing emotion concepts. As a consequence, the colexification networks derived from this database provide only partial information about the structure of the emotion lexicon. Future research should therefore also address the potential limitations of the colexification analysis of emotions.

Data availibility

We use the newest dataset constructing CLICS^3 (https://clics.clld.org) as of 21st October 2021.

Received: 25 April 2023; Accepted: 1 December 2023
Published online: 09 December 2023

References

1. Wierzbicka, A. Defining emotion concepts. *Cogn. Sci.* **16**, 539–581 (1992).
2. Wierzbicka, A. *Emotions Across Languages and Cultures: Diversity and Universals* (Cambridge University Press, 1999).
3. Johnson-Laird, P. N. & Oatley, K. The language of emotions: An analysis of a semantic field. *Cogn. Emotion.* **3**, 81–123 (1989).
4. Russell, J. A. A circumplex model of affect. *J. Personal. Social Psychol.* **39**, 1161–1178 (1980).
5. Jackson, J. C. *et al.* Emotion semantics show both cultural variation and universal structure. *Science* **366**, 1517–1522 (2019).
6. François, A. *Semantic Maps and the Typology of Colexification: Intertwining Polysemous Networks Across Languages in From Polysemy to Semantic Change: Towards a Typology of Lexical Semantic Associations* 163–215 (John Benjamin Publishing, 2008).
7. Kuppens, P., Mechelen, I. V., Smits, D. J. M. & Boeck, P. D. Associations between emotions: Correspondence across different types of data and componential basis. *Eur. J. Personal.* **18**, 159–176 (2004).
8. ...Rzymski, C. *et al.* The database of cross-linguistic colexifications, reproducible analysis of cross-linguistic polysemies. *Sci. Data* **7**, 1–12 (2020).
9. Csardi, G. & Nepusz, T. The igraph software package for complex network research. *Int. J. Complex Syst.* **1695**, 1–9 (2006).
10. Darwin, C. *The expression of the emotions in man and animals* (John Murray, 1872).
11. Ekman, P. Basic emotions. *Handbook of Cognition and Emotion* **98**, 45–60 (1999).
12. Ekman, P. & Cordaro, D. What is meant by calling emotions basic. *Emotion Rev.* **3**, 364–370 (2011).

13. Keltner, D., Tracy, J. L., Sauter, D. & Cowen, A. What basic emotion theory really says for the twenty-first-century study of emotion. *J. Nonverbal Behav* **43**, 195–201 (2019).
14. Plutchik, R. The nature of emotions: human emotions have deep evolutionary roots, a fact that may explain their complexity and provide tools for clinical practice. *Am. Sci.* **89**, 344–350 (2001).
15. Osgood, C. E., May, W. H. & Miron, M. S. Cross-cultural universals of affective meaning. *Univ. Ill. Press* **1**, 156996 (1975).
16. Ortony, A. & Turner, T. J. What's basic about basic emotions?. *Psychol. Rev.* **97**, 315–331 (1990).
17. Ortony, A. Are all "basic emotions" emotions? A problem for the (basic) emotions construct. *Perspect. Psychol. Sci.* **17**, 41–61 (2022).
18. Ekman, P. An argument for basic emotions. *Cogn. Emotion* **6**, 169–172 (1992).
19. Wierzbicka, A. Natural semantic metalanguage. *Int. Encycl. Lang. Social Interact.* **12**, 1–17 (2015).
20. Goddard, C. *Natural Semantic Metalanguage: The state of the Art, in Cross-linguistic Semantics* (John Benjamins Publishing, 2008).
21. Gendron, M. & Barrett, L. F. Reconstructing the past: A century of ideas about emotion in psychology. *Emotion Rev* **1**, 316–339 (2009).
22. Moors, A., Ellsworth, P. C., Scherer, K. R. & Frijda, N. H. Appraisal theories of emotion: State of the art and future development. *Emotion Rev* **5**, 119–124 (2013).
23. Barrett, L. F. Variety is the spice of life: A psychological construction approach to understanding variability in emotion. *Cogn. Emotion* **23**, 1284–1306 (2009).
24. Mun, C. *Interdisciplinary Foundations for the Science of Emotion: Unification without Consilience* (Springer, 2021).
25. Liu, B. & Zhang, L. *A Survey of Opinion Mining and Sentiment Analysis in Mining Text Data* (Springer, London, 2012).
26. Thomas, M., Pang, B. & Lee, L. *Get out the Vote: Determining Support or Opposition from Congressional Floor-Debate Transcripts* (Association for Computational Linguistics, London, 2006).
27. Kang, Y., Cai, Z., Tan, C. W., Huang, Q. & Liu, H. Natural language processing (NLP) in management research: a literature review. *J. Manag. Anal.* **7**, 139–172 (2020).
28. Wu, D. & Cui, Y. Disaster early warning and damage assessment analysis using social media data and geo-location information. *Decision Support Syst.* **111**, 48–59 (2018).
29. Gruebner, O. *et al.* A novel surveillance approach for disaster mental health. *PLoS one* **12**, e0181233 (2017).
30. Calvo, R. A., Milne, D. N., Hussain, M. S. & Christensen, H. Natural language processing in mental health applications using non-clinical texts. *Nat. Language Eng.* **23**, 649–685 (2017).

Acknowledgements
We acknowledge many linguists who provided us with the word lists needed to detect and analyze interlingual colexifications. We also acknowledge the beneficial and insightful feedbacks of our editor and two anonymous reviewers.

Author contributions
Conceptualization: T.M., Y.S., T.I., Methodology: T.M., Y.S., T.I., Investigation: M.F., T.M., Y.S., T.I., Visualization: M.F., Funding acquisition: T.M., Y.S., T.I., Project administration: T.M., Y.S., T.I., Supervision: T.I., Writing—original draft: MF, Writing — review and editing: M.F., T.M., Y.S., T.I.

Funding
The research of T. M. was supported by JSPS KAKENHI Grant Numbers JP21H03514, JP21H04391, and JP22K13339. The research of Y. S. was supported by JSPS KAKENHI Grant Numbers JP21H03508, JP21H03514, and JP22K18419. The research of T. I. was supported by JSPS KAKENHI Grant Numbers JP20H00596, JP21H03514, and JP22K18419.

Competing interests
The authors declare no competing interests.

Additional information
Supplementary Information The online version contains supplementary material available at https://doi.org/10.1038/s41598-023-48922-8.

Correspondence and requests for materials should be addressed to M.F.

Reprints and permissions information is available at www.nature.com/reprints.

Publisher's note Springer Nature remains neutral with regard to jurisdictional claims in published maps and institutional affiliations.

Open Access This article is licensed under a Creative Commons Attribution 4.0 International License, which permits use, sharing, adaptation, distribution and reproduction in any medium or format, as long as you give appropriate credit to the original author(s) and the source, provide a link to the Creative Commons licence, and indicate if changes were made. The images or other third party material in this article are included in the article's Creative Commons licence, unless indicated otherwise in a credit line to the material. If material is not included in the article's Creative Commons licence and your intended use is not permitted by statutory regulation or exceeds the permitted use, you will need to obtain permission directly from the copyright holder. To view a copy of this licence, visit http://creativecommons.org/licenses/by/4.0/.

© The Author(s) 2023

NOLTA, IEICE

Paper

Analysis on responses of chaotic Izhikevich neurons to periodic forcing

Yota Tsukamoto [1], *Honami Tsushima* [1], *and Tohru Ikeguchi* [1,2]

[1] *Graduate School of Engineering, Tokyo University of Science, 6–3–1 Niijuku, Katsushika-ku, Tokyo 125-8585, Japan*

[2] *Faculty of Engineering, Tokyo University of Science, 6–3–1 Niijuku, Katsushika-ku, Tokyo 125-8585, Japan*

Received April 10, 2023; Revised June 15, 2023; Published October 1, 2023

Abstract: The Izhikevich neuron model can reproduce various types of neurons, including chaotic neurons, by utilizing appropriate parameter sets. This study analyzes the responses of a periodically forced Izhikevich neuron with chaotic parameters using three measures—the diversity index, the coefficient of variation, and the local variation—to quantify interspike intervals (ISIs). The evaluation of ISIs combining these three measures clarifies the differences in neuronal activities, but evaluation using an individual measure cannot. In addition, we analyzed the change in the stability of the equilibrium points caused by a periodic input on a phase plane. The results indicate that in electrophysiologically feasible parameter sets, the stability of equilibrium points plays a crucial role in determining the critical amplitude around which irregular activities transition to regular ones. Thus, the relationship between neural behavior and the period and amplitude of the input current is contingent upon the existence and stability of equilibrium points.

Key Words: Izhikevich neuron model, interspike interval, diversity index, coefficient of variation, local variation

1. Introduction

Neuronal responses to periodic forcing have been investigated to elucidate the electrophysiological properties of neurons. Periodic forcing results in both periodic and irregular responses, such as quasiperiodic and chaotic responses. Hayashi et al. first demonstrated, using *Onchidium*'s giant neurons, that a single neuron fires chaotic spikes in response to sinusoidal forcing [1]. Aihara et al. stimulated squid giant axons using periodic forcing and identified periodic, quasiperiodic, and chaotic responses [2].

Furthermore, neuronal model activity has also attracted considerable attention. Hodgkin and Huxley were pioneers in this field. They proposed the Hodgkin–Huxley model that demonstrated that four-dimensional ordinary differential equations could reproduce the dynamics of the membrane potential of squid giant axons [3]. Aihara et al. observed that sinusoidal forcing in the Hodgkin–Huxley

This work is licensed under a Creative Commons Attribution NonCommercial, No Derivatives 4.0 License.
Nonlinear Theory and Its Applications, IEICE, vol. 14, no. 4, pp. 677–690 ©IEICE 2023 DOI: 10.1587/nolta.14.677

model resulted in periodic, quasiperiodic, or chaotic responses depending on both the amplitude and frequency of the stimulation [4]. Although the Hodgkin–Huxley model reflects electrophysiological mechanisms of spike generation, its high dimensionality renders it computationally inefficient. Subsequently, several simple models were proposed for this purpose, such as FitzHugh–Nagumo model [5, 6], Morris–Lecar model [7], and Hindmarsh–Rose model [8]. Among these, the Izhikevich neuron model [9] was demonstrated to reproduce various neural responses and have high computational efficiency [10].

The responses of the Izhikevich neuron model to sinusoidal forcing were analyzed with a focus on mode locking in [11]. In addition, Nobukawa et al. investigated the behavior of the model for weak sinusoidal stimulation [12, 13]. In our previous studies, we analyzed responses by applying sinusoidal forcing to five principal types of Izhikevich neurons: regular spiking, fast spiking, intrinsically bursting, chattering, and low-threshold spiking [14–21]. Consequently, the coefficient of variation was high for regular responses and low for irregular responses. The positional relationship between the two nullclines was significant for the regularity of the responses. However, all these neuron types were periodic, and chaotic neurons have yet to be studied.

The Izhikevich neuron model can reproduce chaotic spiking with constant input [10]. For example, in [10], Izhikevich described the reproduction of chaotic responses using a parameter set. However, the parameter set by Izhikevich requires a large negative input current, which is electrophysiologically unrealistic. On the other hand, Naiki et al. analyzed the Izhikevich neuron model with Lyapunov exponents on the Poincaré section [22] and identified parameter sets with a positive input current that induce chaotic behavior [23]. In [23], it is also indicated that the parameter sets could lead to different chaotic behavior such as regular-like responses and burst-like ones.

Previous researches [11–21] only investigated responses of periodic neurons stimulated by periodic forcing, while the present study investigates responses of chaotic neurons stimulated by periodic forcing. Then, in the present study, we used five parameter sets that reproduced the chaotic responses proposed by Izhikevich [10] and Naiki et al. [23] and analyzed the responses of the chaotic Izhikevich neuron model stimulated by sinusoidal forcing with a focus on ISIs. In order to investigate chaotic Izhikevich neurons from a viewpoint of ISIs, the diversity index [23, 24], the coefficient of variation, and the local variation [25–27] were adopted to quantify ISIs. In addition, the nullclines, stability of the equilibrium points, and bifurcation of the equilibrium points were considered to assess regular and irregular behavior produced from the forced Izhikevich neuron model.

2. Izhikevich neuron model

The Izhikevich neuron model is described as follows [9]:

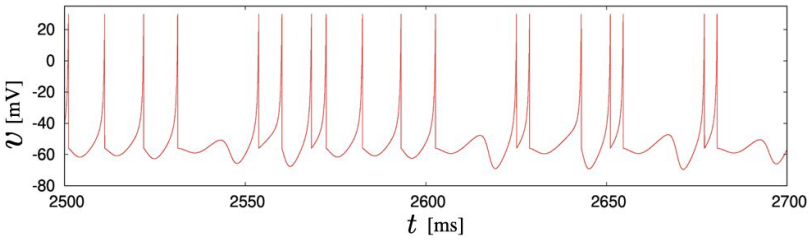
$$\begin{cases} \dfrac{dv}{dt} = 0.04v^2 + 5v + 140 - u + I(t), \\ \dfrac{du}{dt} = a(bv - u), \end{cases} \tag{1}$$

where v represents the membrane potential [mV] and u is the recovery variable. In Eq. (1), $I(t)$ is the input current, and t is the time [ms]. In the present study, $I(t)$ is the sum of the direct current I_{DC} and alternating current I_{AC}:

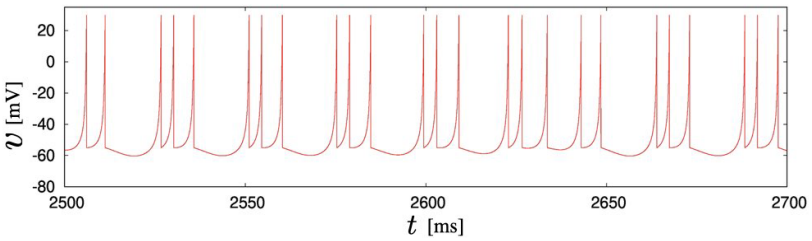
$$I(t) = I_{DC} + I_{AC} = I_{DC} + A \sin \frac{2\pi}{T} t. \tag{2}$$

Table I. Parameters a, b, c, d, and direct current I_{DC} of interest.

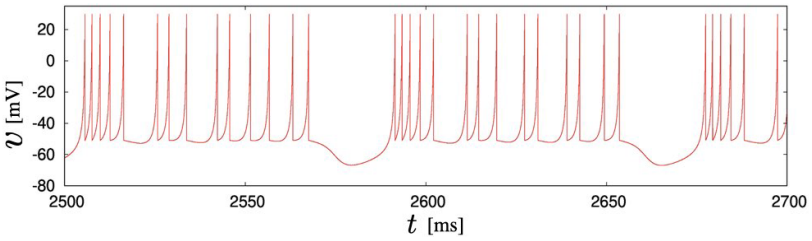
Neuron type	a	b	c	d	I_{DC}
Chaos 1 [10]	0.2	2.0	−56	−16	−99
Chaos 2 [23]	0.05110	0.2	−55	2	10
Chaos 3 [23]	0.05	0.2	−50.96	2	10
Chaos 4 [23]	0.02	0.498	−47.6	2	10
Chaos 5 [23]	0.01	0.61	−56	2	10



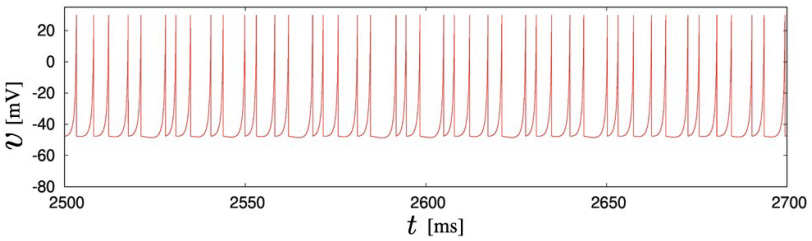
(a) Chaos 1 [10]



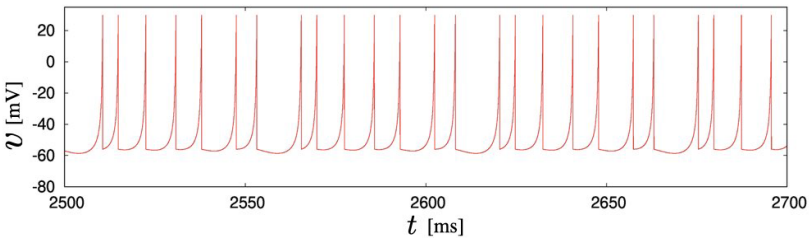
(b) Chaos 2 [23]



(c) Chaos 3 [23]



(d) Chaos 4 [23]



(e) Chaos 5 [23]

Fig. 1. Responses of the chaotic Izhikevich neuron model with a constant input. Regular-like (d, e), burst-like (c), and intermediate (a, b) responses can be observed.

Equation (1) governs the fluctuations in the membrane potential. When a neuron fires a spike, v and u are discretely reset, as follows:

$$\text{when } v \geq 30 \text{ [mV]}, \quad \text{then} \begin{cases} v \leftarrow c, \\ u \leftarrow u + d. \end{cases} \tag{3}$$

This after-spike resetting contributes to computational efficiency; and thus, this model has been widely accepted. Prameters a and b in Eq. (1) and c and d in Eq. (3) are dimensionless parameters to set neuron types. Various neuron types can be reproduced by using appropriate sets of parameters a, b, c, and d. Table I presents the parameter sets used in this study.

Chaos 1 [10] was first introduced by Izhikevich, who proposed the Izhikevich neuron model. However, this parameter involves electrophysiologically unrealistic input current since I_{DC} has a large negative value. Chaos 2–5 were proposed by Naiki et al., who analyzed a single Izhikevich neuron with Lyapunov exponents on the Poincaré section [23]. Although they are all chaotic neurons, they reproduce different kinds of chaotic behavior. Some show regular-like patterns, while others show burst-like patterns (See Fig. 1).

The Euler method and linear interpolation were adopted for the numerical experiments [28]. The Euler method is computationally efficient for ordinary differential equations; thus, it is often used to simulate neural network models. To accurately detect firing times, linear interpolation was executed when the membrane potential exceeded 30 [mV], which is the threshold for firing (Eq. (3)). The estimated firing time t_F is subsequently given by the following formula:

$$t_{\mathrm{F}} = t + \frac{30 - v(t)}{v(t+h) - v(t)} h, \tag{4}$$

where h is the time step, set to 0.01, and $v(t) < 30 \leq v(t+h)$.

3. Analysis methods

3.1 ISI measures

Three measures are adopted to analyze the ISIs: the diversity index D [23, 24], the coefficient of variation C_v, and the local variation L_v [25–27]. These three measures are independent and quantify different properties of ISIs. The diversity index D is a simple measure to identify chaotic response. It reflects how often the same ISIs are repeated, not ISI values themselves. On the contrary, the coefficient of variation C_v and the local variation L_v, calculated from ISI values, quantify variation of ISIs; the former is suitable to represent variation of a whole spike sequence, while the latter to extract intrinsic spike characteristics, eliminating the effect of global modulation.

3.1.1 Diversity index

We adopted the diversity index D [23, 24] to distinguish between periodic and irregular responses as follows:

$$D = \frac{M}{N}. \tag{5}$$

In Eq. (5), N is the total number of ISIs and M is the number of different values of ISIs. While using Eq. (5), N should be long enough to avoid misidentification that a periodic response be irregular. If two ISIs are equal to six decimal places, then they two are regarded as the same value. When N is significantly greater than M, resulting in $D \approx 0$, the response of interest is periodic. By contrast, when M is close to N, resulting in $D \approx 1$, the response of interest is irregular.

3.1.2 Coefficient of variation

The coefficient of variation C_v is defined as the standard deviation σ divided by the mean ISI $\bar{s}$.

$$C_v = \frac{\sigma}{\bar{s}}. \tag{6}$$

The unbiased variance σ^2 is given by:

$$\sigma^2 = \frac{1}{N-1} \sum_{i=1}^{N} (s_i - \bar{s})^2, \tag{7}$$

where $\bar{s} = \frac{1}{N} \sum_{i=1}^{N} s_i$ denotes mean ISI. C_v converges to unity for a Poisson spike and $C_v = 0$ for the period one response.

3.1.3 Local variation

The local variation L_v quantifies ISIs in a different manner compared to C_v [25–27].

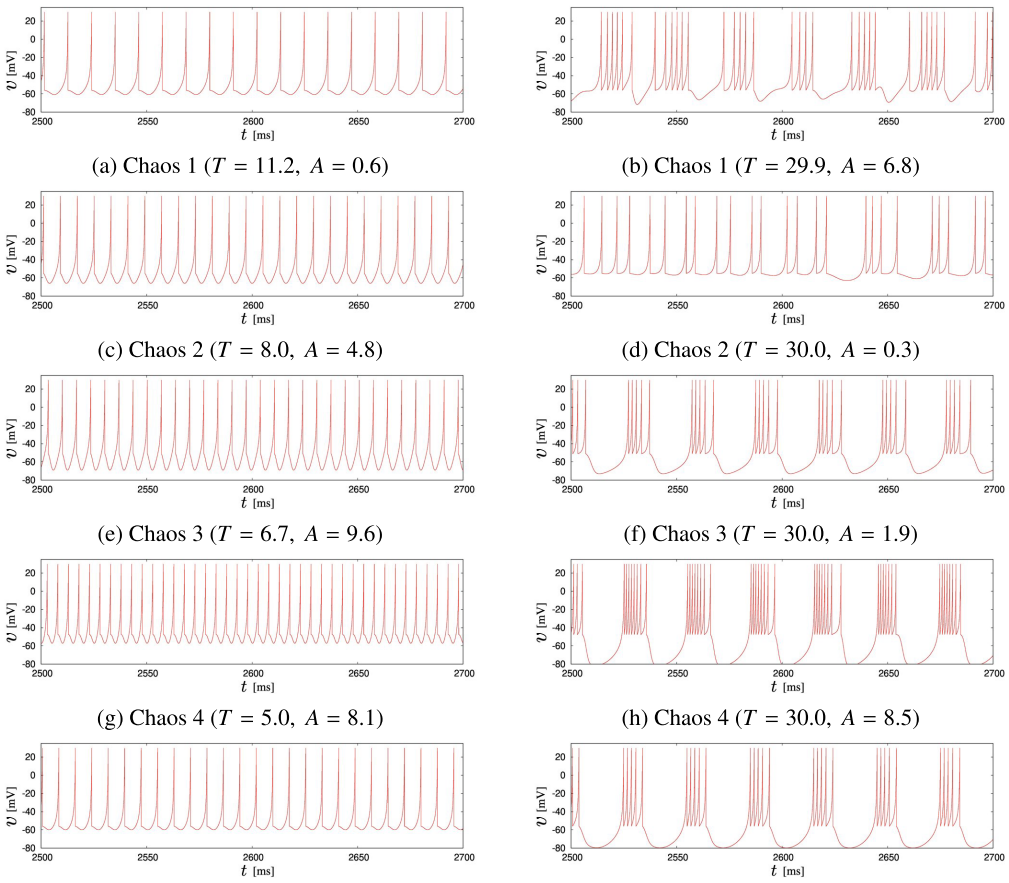
$$L_v = \frac{1}{N-1} \sum_{i=1}^{N-1} \frac{3(s_i - s_{i+1})^2}{(s_i + s_{i+1})^2}. \tag{8}$$

In Eq. (8), L_v converges to unity for a Poisson spike and to zero for a period one response, which is the same as C_v. However, L_v is robust to modulation; it has lower values for modulated spike trains as compared to C_v.

3.2 Nullcline

Nullcline analysis is widely accepted to explain mechanism of spiking behavior of neuron models. In order to investigate where the difference of responses derives from, we observed nullclines on a phase plane.

The Izhikevich neuron model has two variables: v and u. The v-nullcline is a parabola while the u-nullcline is a straight line, as shown in Fig. 8. Thus, they can have at most two intersections, i.e., two equilibrium points. In this study, the sinusoidal current was applied to the Izhikevich neuron model (Eq. (2)). The v-nullcline was then periodically moved in the direction of the u-axis on the v-u plane (phase plane).

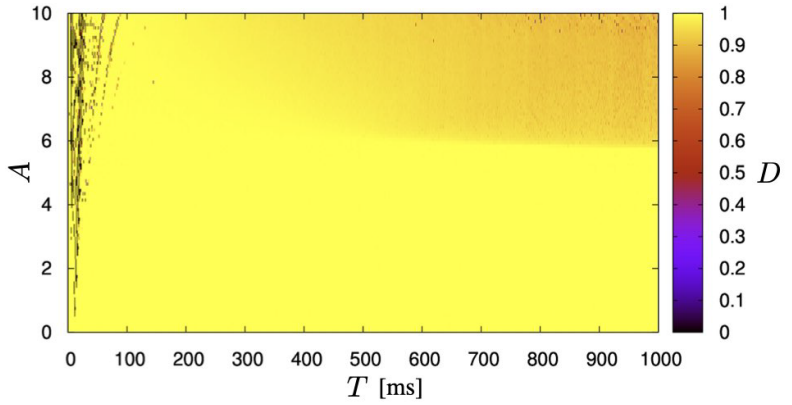


(a) Chaos 1 (T = 11.2, A = 0.6)
(b) Chaos 1 (T = 29.9, A = 6.8)
(c) Chaos 2 (T = 8.0, A = 4.8)
(d) Chaos 2 (T = 30.0, A = 0.3)
(e) Chaos 3 (T = 6.7, A = 9.6)
(f) Chaos 3 (T = 30.0, A = 1.9)
(g) Chaos 4 (T = 5.0, A = 8.1)
(h) Chaos 4 (T = 30.0, A = 8.5)
(i) Chaos 5 (T = 7.8, A = 2.0)
(j) Chaos 5 (T = 30.0, A = 8.9)

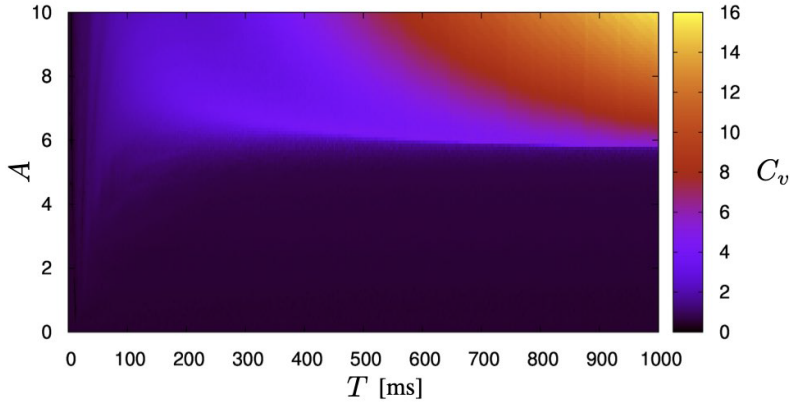
Fig. 2. Typical spike patterns induced by sinusoidal forcing. Periodic responses (a, c, e, g, i) and chaotic responses (b, d, f, h, j) can be observed.

4. Results

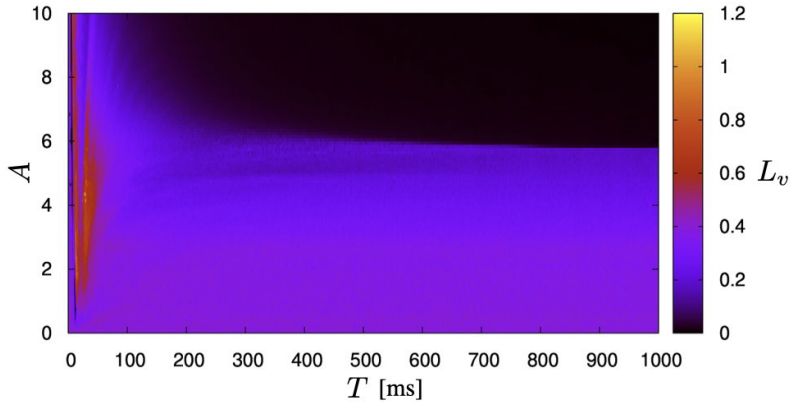
We stimulated the Izhikevich neuron models with the five parameter sets listed in Table I with sinusoidal forcing by changing the period T and the amplitude A. The typical spike patterns induced by sinusoidal forcing are shown in Fig. 2. The spike sequences in $0 \leq t \leq 5\ 000$ were eliminated as transient states, while those in $5\ 000 < t \leq 15\ 000$ were used. Figures 3–7 present the results of the evaluation of the diversity index D, the coefficient of variation C_v, and the local variation L_v for the Izhikevich neuron models.



(a) Diversity index D

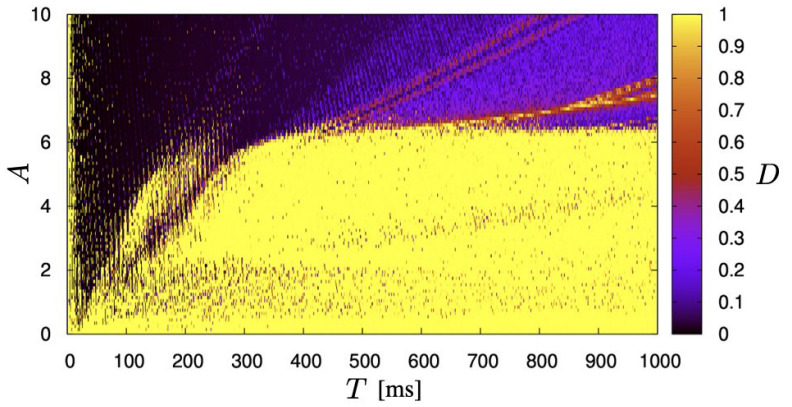


(b) Coefficient of variation C_v

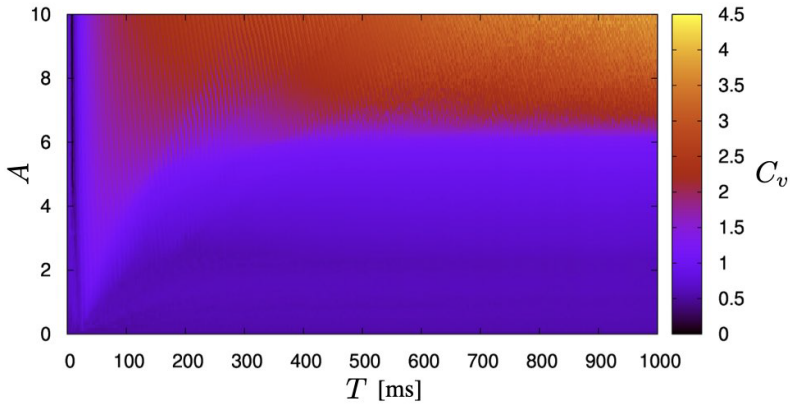


(c) Local variation L_v

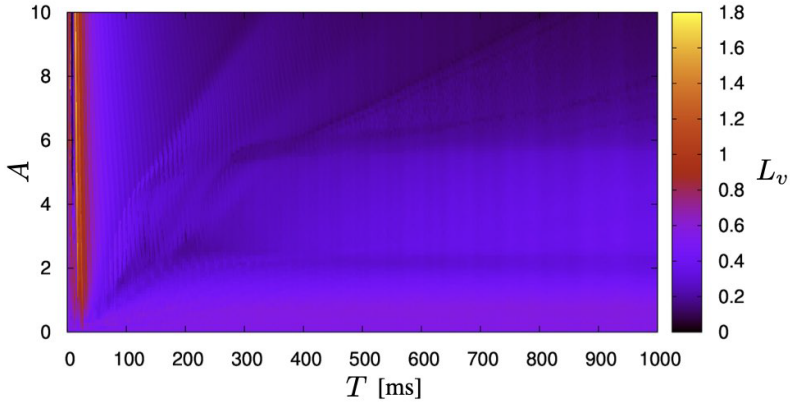
Fig. 3. ISI quantification of Chaos 1.



(a) Diversity index D



(b) Coefficient of variation C_v

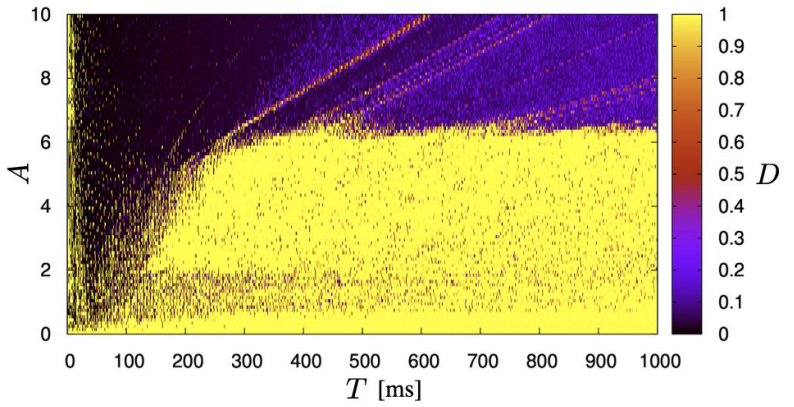


(c) Local variation L_v

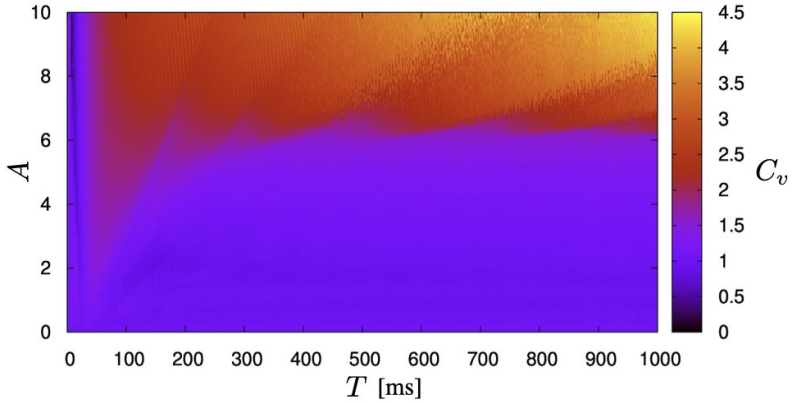
Fig. 4. ISI quantification of Chaos 2.

The results for Chaos 1 showed chaotic activity over a wider region (Fig. 3(a)). However, C_v was relatively high in certain regions (Fig. 3(b)). Chaos 2 and 3 change their behavior qualitatively around $A = 6$ (Figs. 4(a) and 5(a)), and C_v (Figs. 4(b) and 5(b)). In contrast, Chaos 4 and 5 do not show such a characteristic. For all cases with the five parameter sets, L_v is close to zero in most regions (Figs. 3(c)–7(c)).

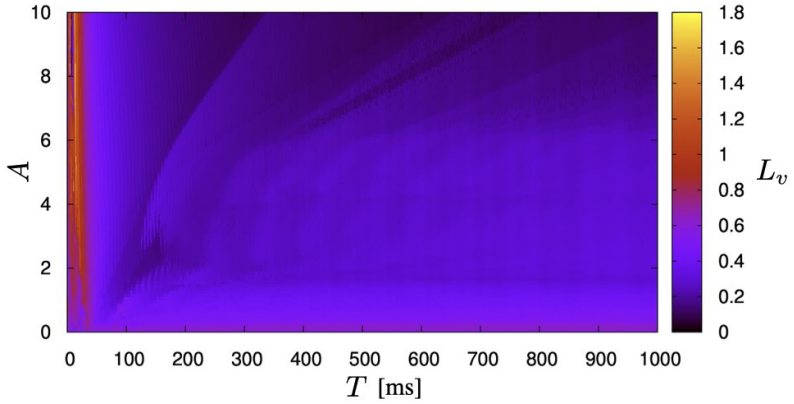
Subsequently, by setting $A = 0$ and changing I_{DC}, we evaluated the real part of the eigenvalues of the equilibrium points to analyze their stability. The range of I_{DC} was determined such that the two



(a) Diversity index D



(b) Coefficient of variation C_v

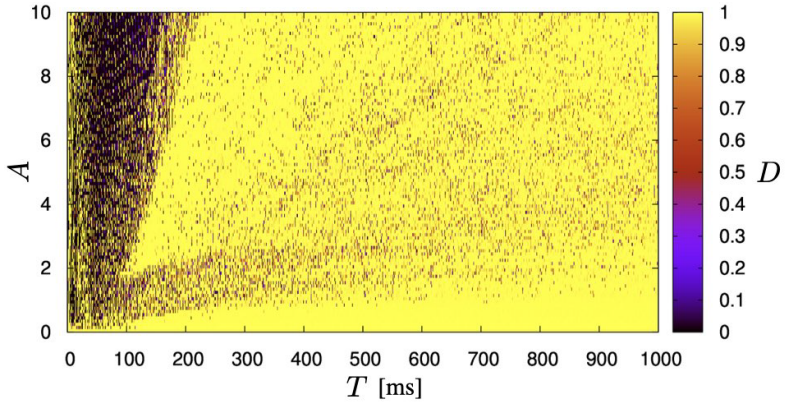


(c) Local variation L_v

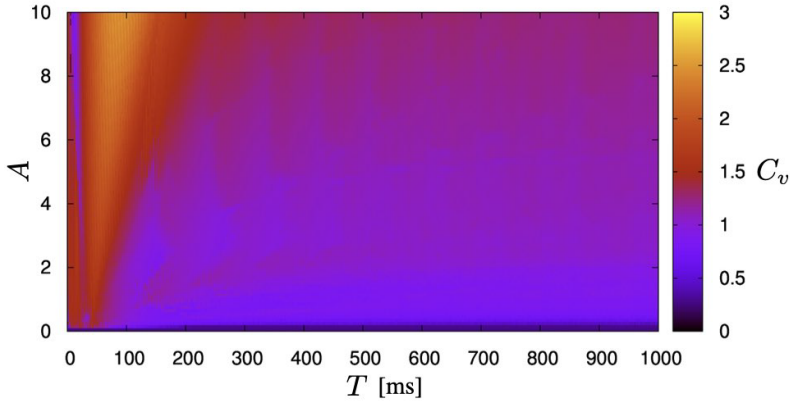
Fig. 5. ISI quantification of Chaos 3.

nullclines intersect. Let us define the two equilibrium points $(v_1^*,\ u_1^*)$ and $(v_2^*,\ u_2^*)$ such that $v_1^* < v_2^*$. Figures 9–11 show the results for Chaos 1, 2, and 3, respectively. In the case of Chaos 4 and 5, the nullclines never intersect; therefore, stability is not discussed here (Fig. 8(c)).

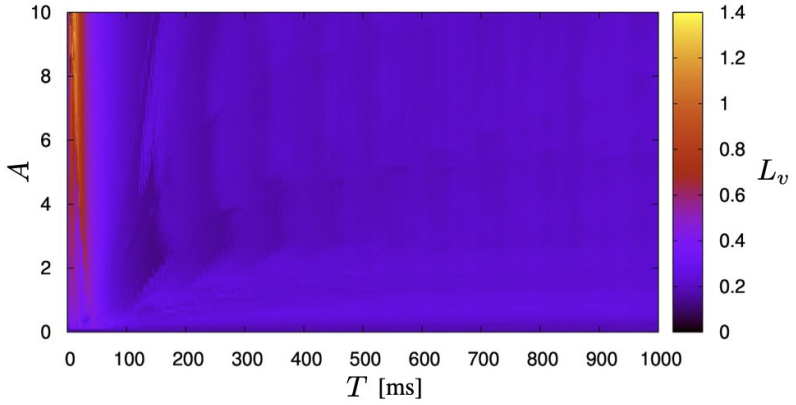
From Figs. 9–11, it can be observed that Chaos 1–3 have common characteristics: $(v_1^*,\ u_1^*)$ undergoes the Hopf bifurcation, i.e., the real parts of the two eigenvalues change their signs simultaneously, as the input fluctuates; and $(v_2^*,\ u_2^*)$ remains a saddle point. Thus, stability of $(v_1^*,\ u_1^*)$ is to be discussed, $(v_2^*,\ u_2^*)$ not.



(a) Diversity index D



(b) Coefficient of variation C_v

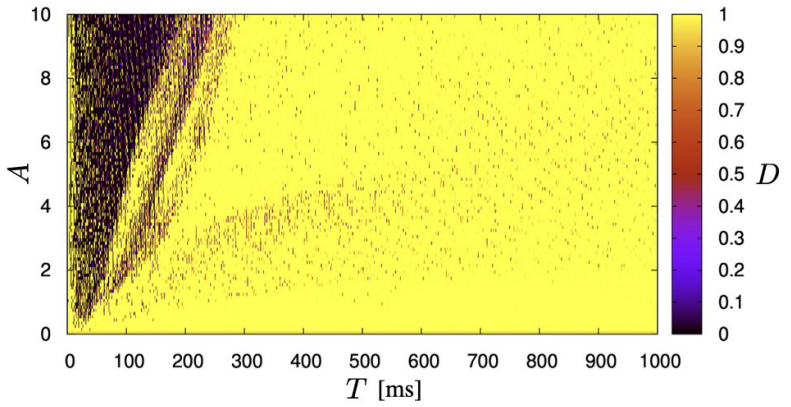


(c) Local variation L_v

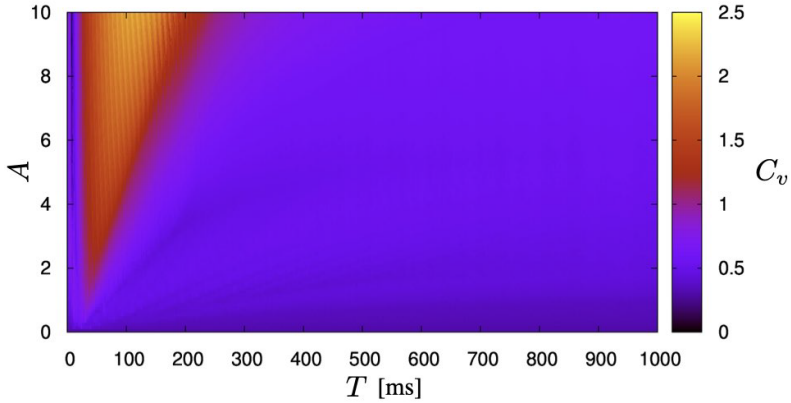
Fig. 6. ISI quantification of Chaos 4.

5. Conclusion

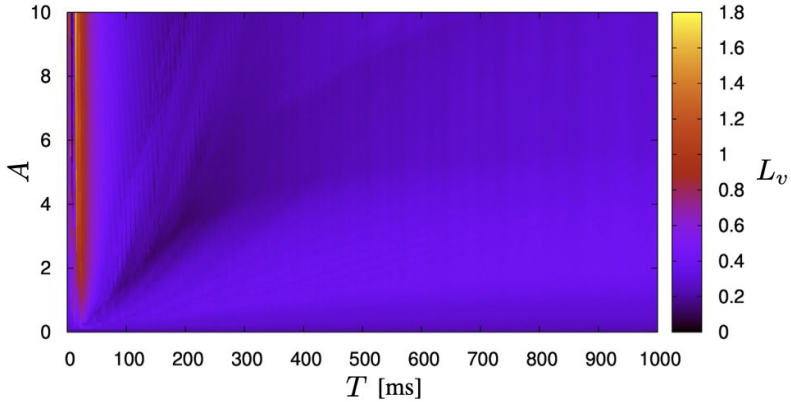
In this study, we investigated responses of chaotic Izhikevich neurons stimulated by periodic inputs using three measures: the diversity index D, the coefficient of variation C_v, and the local variation L_v, all of which quantify ISIs differently. The evaluation of ISIs combining these three measures clarifies the differences in neuronal activities that evaluation using an individual measure cannot. Combination of the three measures of ISIs can be applied to other nonlinear dynamical systems or real data obtained from physiological experiments. In addition, the stability of the equilibrium



(a) Diversity index D



(b) Coefficient of variation C_v

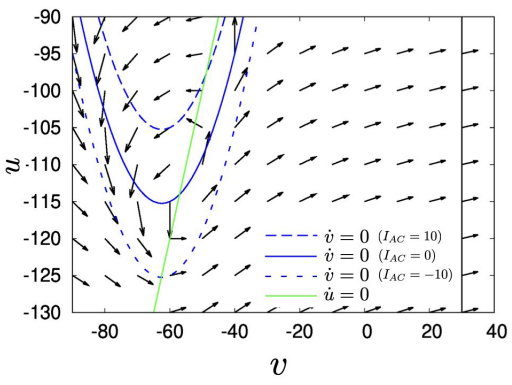


(c) Local variation L_v

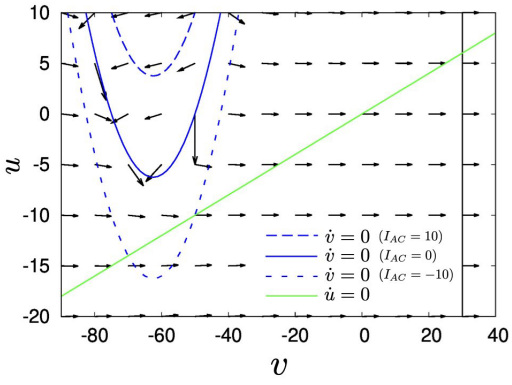
Fig. 7. ISI quantification of Chaos 5.

points, i.e., intersections of the two nullclines, was evaluated because the sinusoidal forcing moves the v-nullcline in the direction of the u-axis on the phase plane, and the number of equilibrium points and their stabilities change according to the phase of the input current.

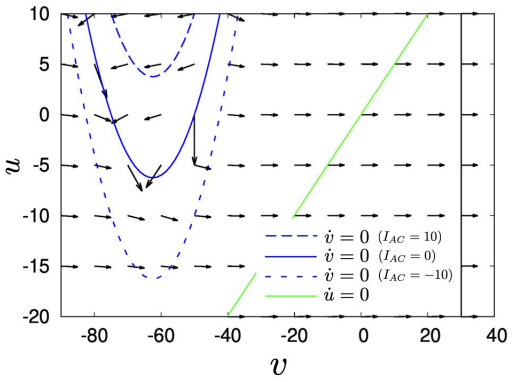
In this study, we used the five parameter sets listed in Table I. The results of the numerical experiments and analyses indicate that these five parameter sets can be classified into three groups. (i) Chaos 1 had two equilibrium points regardless of phase of input currents. This neuron reproduced irregular activity for most periods T and amplitudes A of input. However, the magnitude of the



(a) Chaos 1

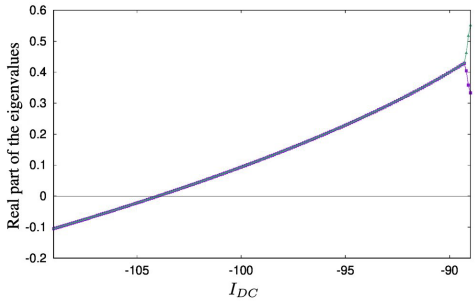


(b) Chaos 2

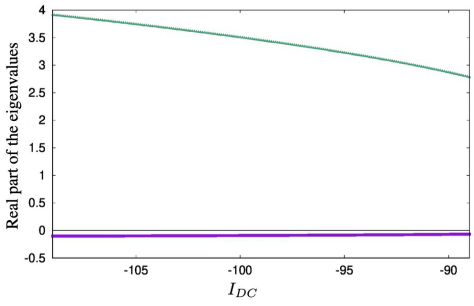


(c) Chaos 4

Fig. 8. The v- and u-nullclines and vector fields. Blue solid curves are the v-nullclines corresponding to the case of $I_{AC} = 0$, and the green solid straight lines are the u-nullclines. Dashed blue curves are the v-nullcline corresponding to the case of $I_{AC} = \pm 10$. Black arrows indicate vector fields. The vertical lines $v = 30$ are the threshold for firing. Chaos 3 and 5 have a similar phase plane to Chaos 2 and 4, respectively.



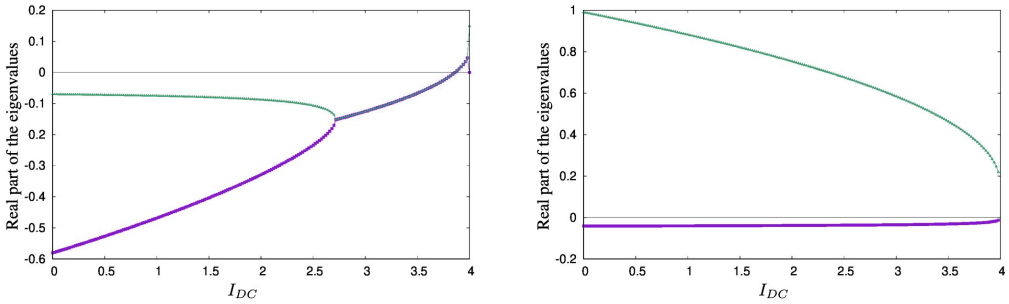
(a) Real parts of eigenvalues of $(v_1^*,\ u_1^*)$



(b) Real parts of eigenvalues of $(v_2^*,\ u_2^*)$

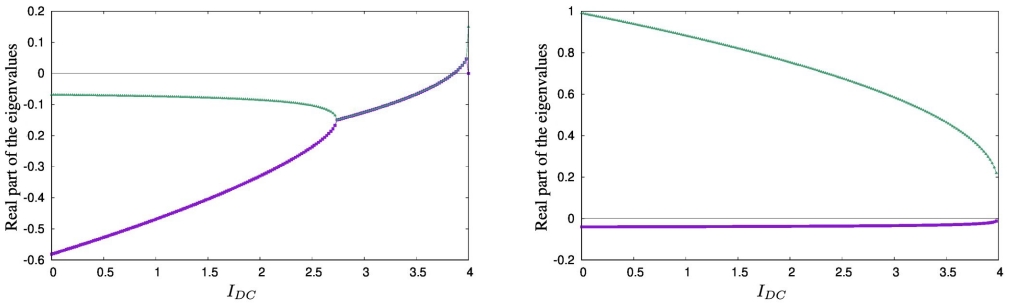
Fig. 9. Stability of equilibrium points for case of Chaos 1.

coefficient of variation C_v changed at approximately $A = const.$ line. (ii) For Chaos 2 and 3, at most two equilibrium points appeared depending on the phase of the input, and their activities switched from irregular to regular at approximately $A = const.$ line. The coefficient of variation C_v was high when the diversity index D was low, indicating periodic responses, and it was low when the diversity index D was high, indicating irregular responses; The local variation L_v was low, which indicates that the modulation effect is significant, for both responses. (iii) Chaos 4 and 5, which have no equilibrium



(a) Real parts of eigenvalues of $(v_1^*,\ u_1^*)$ (b) Real parts of eigenvalues of $(v_2^*,\ u_2^*)$

Fig. 10. Stability of equilibrium points for case of Chaos 2.



(a) Real parts of eigenvalues of $(v_1^*,\ u_1^*)$ (b) Real parts of eigenvalues of $(v_2^*,\ u_2^*)$

Fig. 11. Stability of equilibrium points for case of Chaos 3.

points, did not show qualitative changes around $A = const.$ lines, and reproduce both regular and irregular responses. However, the diversity index D was negatively correlated with the coefficient of variation C_v and the local variation L_v was low. These characteristics are similar to those of Chaos 2 and 3. This means that chaotic responses are almost regular (periodic or bursting) in appearance and that regular responses comprise greatly different ISIs. The results of the classification show that the relationship between behavior and the period T and amplitude A of the input current depends on the existence and stability of the equilibrium points. While nullcline analysis in this research does not directly explain the mechanism of irregularity of the spiking behavior, chaotic neurons are classified according to positional relationship between nullclines.

In [29], behavior of neuron models are categorized into various scenarios. However, constant inputs are assumed to analyze behavior of neuron models. In this case, resting states correspond to an equilibrium point before bifurcation, and firing states correspond to an orbit such as a limit cycle after bifurcation. Then, input current causes this bifurcation, according to which neural behavior is categorized.

In contrast, in our study, input current is sinusoidal wave and continuously fluctuates. Thus, qualitative transition of phase portraits occurs over firing states constantly. For this difference, responses shown in Fig. 2 could not be categorized in the same way as [29]. However, a neuron model stimulated by periodic forcing follows a certain scenario in a short time, especially for a large T. Therefore, possible future work includes a fusion of analyses of periodically forced neuron models and bifurcation analysis.

In this study, we analyzed a periodically forced Izhikevich neuron model using chaotic parameter sets. In the analysis, we used three measures to evaluate the complex behavior of ISIs. We also discussed the changes in the stability of the equilibrium points. However, the Izhikevich neuron model is a hybrid dynamical system with continuous spike-emitting mechanisms and a discontinuous reset process for state variables [28]. Thus, a potential avenue for future research is to explore the application of analytical methods from the field of hybrid dynamical systems to investigate how

irregular and regular behaviors arise when sinusoidal forcing is applied to these systems.

Acknowledgments

The research of H. T. was partially supported by JSPS KAKENHI Grant Number JP22J12396. The research of T. I. was partially supported by JSPS KAKENHI Grant Numbers JP20H00596, JP21H03514, and JP22K18419.

References

[1] H. Hayashi, S. Ishizuka, M. Ohta, and K. Hirakawa, "Chaotic behavior in the Onchidium giant neuron under sinusoidal stimulation," *Physics Letters A*, vol. 88, no. 8, pp. 435–438, April 1982. DOI: 10.1016/0375-9601(82)90674-0

[2] K. Aihara, T. Numajiri, G. Matsumoto, and M. Kotani, "Structures of attractors in periodically forced neural oscillators," *Physics Letters A*, vol. 116, no. 7, pp. 313–317, June 1986. DOI: 10.1016/0375-9601(86)90578-5

[3] A.L. Hodgkin and A.F. Huxley, "A quantitative description of membrane current and its application to conduction and excitation in nerve," *Journal of Physiology*, vol. 117, no. 4, pp. 500–544, August 1952. DOI: 10.1113/jphysiol.1952.sp004764

[4] K. Aihara, G. Matsumoto, and Y. Ikegaya, "Periodic and non-periodic responses of a periodically forced Hodgkin–Huxley oscillator," *Journal of Theoretical Biology*, vol. 109, no. 2, pp. 249–269, July 1984. DOI: 10.1016/S0022-5193(84)80005-3

[5] J. Nagumo, S. Arimoto, and S. Yoshizawa, "An active pulse transmission line simulating nerve axon," *Proceedings of the IRE*, vol. 50, no. 10, pp. 2061–2070, October 1962. DOI: 10.1109/JRPROC.1962.288235

[6] R. FitzHugh, "Impulses and physiological states in theoretical models of nerve membrane," *Biophysical Journal*, vol. 1, no. 6, pp. 445–466, July 1961. DOI: 10.1016/S0006-3495(61)86902-6

[7] C. Morris and H. Lecar, "Voltage oscillations in the barnacle giant muscle fiber," *Biophysical Journal*, vol, 35, no. 1, pp. 193–213, July 1981. DOI: 10.1016/S0006-3495(81)84782-0

[8] J.L. Hindmarsh and R.M. Rose, "A model of neuronal bursting using three coupled first order differential equations," *Proceedings of the Royal Society of London. B. Biological Sciences*, vol. 221, no. 1222, pp. 87–102, March 1984. DOI: 10.1098/rspb.1984.0024

[9] E.M. Izhikevich, "Simple Model of Spiking Neurons," *IEEE Transactions on Neural Networks*, vol. 14, no. 6, pp. 1569–1572, November 2003. DOI: 10.1109/TNN.2003.820440

[10] E.M. Izhikevich, "Which Model to Use for Cortical Spiking Neurons?," *IEEE Transactions on Neural Networks*, vol. 15, no. 5, pp. 1063–1070, September 2004. DOI: 10.1109/TNN.2004.832719

[11] A. Farokhniaee and E.W. Large, "Mode-locking behavior of Izhikevich neurons under periodic external forcing," *Physical Review E*, vol. 95, no. 6, 062414, June 2017. DOI: 10.1103/PhysRevE.95.062414

[12] S. Nobukawa, H. Nishimura, and T. Yamanishi, "Chaotic resonance in typical routes to chaos in the Izhikevich neuron model," *Scientific Reports*, vol. 7, no. 1, pp. 1–9, May 2017. DOI: 10.1038/s41598-017-01511-y

[13] S. Nobukawa, H. Nishimura, T. Yamanishi, and J.Q. Liu, "Analysis of chaotic resonance in Izhikevich neuron model," *PLoS one*, vol. 10, no. 9, e0138919, September 2015. DOI: 10.1371/journal.pone.0138919

[14] Y. Tsukamoto, H. Tsushima, and T. Ikeguchi, "Non-periodic responses of the Izhikevich neuron model to periodic inputs," *NOLTA*, vol. 13, no. 2, pp. 367–372, April 2022. DOI: 10.1587/nolta.13.367

[15] Y. Tsukamoto, H. Tsushima, and T. Ikeguchi, "Non-Periodic responses of the Izhikevich neuron model with periodic inputs," *Proc. of The 2021 Nonlinear Science Workshop*, NLSW-54, December 2021.

[16] Y. Tsukamoto, H. Tsushima, and T. Ikeguchi, "Responses of the Izhikevich neuron model to periodic inputs –In case of fast spiking neurons–," *Proc. IEICE General Conference*, N-1-16, March 2022, in Japanese.

[17] Y. Tsukamoto, H. Tsushima, and T. Ikeguchi, "Responses of the Izhikevich neuron model to periodic inputs –In case of burst firing–," *Proc. NOLTA Society Conference*, A-9, June 2022, in Japanese.

[18] Y. Tsukamoto, H. Tsushima, and T. Ikeguchi, "Rich Spike Patterns from the Izhikevich Neuron Model in Response to Periodic Inputs," *Proc. 2022 International Symposium on Nonlinear Theory and Its Applications*, B2L-E-03, December 2022.

[19] Y. Tsukamoto, H. Tsushima, and T. Ikeguchi, "Periodic Input Leads an Izhikevich Neuron to Induce both Periodic and Irregular Responses," *Proc. 2023 RISP International Workshop on Nonlinear Circuits, Communications and Signal Processing*, 3AM1-1-3, March 2023.

[20] Y. Tsukamoto, H. Tsushima, and T. Ikeguchi, "Rich Spike Patterns from the Izhikevich Neuron Model in Response to Periodic Inputs," *NOLTA*, vol. 14, no. 2, pp. 215–227, April 2023.

[21] Y. Tsukamoto, H. Tsushima, and T. Ikeguchi, "Responses of the Izhikevich Neuron Model to Periodic Inputs –In Case of Chaotic Neurons–," *Proc. IEICE General Conference*, N-1-7, March 2022, in Japanese.

[22] S. Nobukawa, H. Nishimura, T. Yamanishi, and J.Q. Liu, "Evaluation methods of chaotic state in spiking neural system with state dependent jump," *Transactions of the Institute of Systems, Control and Information Engineers*, vol. 29, no. 5, pp. 210–215, May 2016, in Japanese. DOI: 10.5687/iscie.29.210

[23] K. Naiki, Y. Shimada, K. Fujiwara, and T. Ikeguchi, "Chaotic responses and chaos synchronization in Izhikevich neuron model," *IEICE Transactions on Fundamentals of Electronics, Communications and Computer Sciences*, vol. J100-A, no. 5, pp. 195–204, May 2017, in Japanese.

[24] N. Sugiura, K. Fujiwara, R. Hosaka, and T. Ikeguchi, "Chaotic response of the Izhikevich neuron model and its statistical analysis," *IEICE Technical Report*, vol. 113, no. 116, pp. 43–48, July 2013, in Japanese.

[25] S. Shinomoto, K. Shima, and J. Tanji "Differences in spiking patterns among cortical neurons," *Neural computation*, vol. 15, no. 12, pp. 2823–2842, December 2003. DOI: 10.1162/089976603322518759

[26] S. Shinomoto, Y. Miyazaki, H. Tamura, and I. Fujita, "Regional and laminar differences in in vivo firing patterns of primate cortical neurons," *Journal of Neurophysiology*, vol. 94, no. 1, pp. 567–575, July 2005. DOI: 10.1152/jn.00896.2004

[27] S. Shinomoto, H. Kim, T. Shimokawa, N. Matsuno, S. Funahashi, K. Shima, I. Fujita, H. Tamura, T. Doi, K. Kawano, N. Inaba, K. Fukushima, S. Kurkin, K. Kurata, M. Taira, K. Tsutsui, H. Komatsu, T. Ogawa, K. Koida, J. Tanji, and K. Toyama, "Relating neuronal firing patterns to functional differentiation of cerebral cortex," *PLoS Computational Biology*, vol. 5, no. 7, e1000433, July 2009. DOI: 10.1371/journal.pcbi.1000433

[28] E.M. Izhikevich, "Hybrid spiking models," *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, vol. 368, no. 1930, pp. 5061–5070, November 2010. DOI: 10.1098/rsta.2010.0130

[29] E.M. Izhikevich, "Neural excitability, spiking and bursting," *International Journal of Bifurcation and Chaos*, vol. 10, no. 6, pp. 1171–1266, June 2000. DOI: 10.1142/S0218127400000840

NOLTA, IEICE

Paper

Rich spike patterns from a periodically forced Izhikevich neuron model

Yota Tsukamoto [1], *Honami Tsushima* [1], *and Tohru Ikeguchi* [1,2]

[1] *Graduate School of Engineering, Tokyo University of Science, 6-3-1 Niijuku, Katsushika-ku, Tokyo 125-8585, Japan*

[2] *Faculty of Engineering, Tokyo University of Science, 6-3-1 Niijuku, Katsushika-ku, Tokyo 125-8585, Japan*

Received October 7, 2022; Revised December 23, 2022; Published April 1, 2023

Abstract: Physiological experiments have described the electrophysiological properties of a single neuron, and mathematical models formulating neuronal activity have been proposed to elucidate the mechanism of information processing by the brain. In the present study, we investigated one such model, the Izhikevich neuron model, stimulated by sinusoidal inputs, with the parameter sets of four principal neuron types: regular spiking, fast spiking, intrinsically bursting, and chattering neurons. We adopted three measures: the diversity index, the coefficient of variation, and the local variation, to quantify interspike intervals from different viewpoints. The combined evaluation of these three measures clarified that the positional relationship of the nullclines, which is determined by the amplitude of sinusoidal forcing, plays a crucial role in the intrinsic properties of a periodically forced Izhikevich neuron model. Moreover, we used stroboscopic plots to clarify qualitative differences between attractors. The results also imply that such combined evaluation is applicable to the classification of neurons.

Key Words: Izhikevich neuron model, interspike interval, diversity index, coefficient of variation, local variation

1. Introduction

The key objective of neuroscience is to unravel the basic mechanism of information processing in the brain. Basic investigations aiming to achieve this goal include efforts to understand the function of a single neuron. Consequently, the dynamical properties of neurons have been investigated in two main paradigms: physiological experiments and mathematical models.

A series of physiological experiments have clarified that periodic inputs lead a neuron to periodic, quasi-periodic, or chaotic responses, depending on the amplitude and period of the inputs. Hayashi et al. [1] used a giant neuron of *Onchidium* and demonstrated chaotic spiking in response to a sinusoidal input current. Aihara et al. [2] observed that periodic stimulation led a giant axon of *Doryteuthis bleekeri* to demonstrate periodic, quasi-periodic, and chaotic responses.

With the development of computational neuroscience, various mathematical neuron models have

This work is licensed under a Creative Commons Attribution NonCommercial, No Derivatives 4.0 License.
Nonlinear Theory and Its Applications, IEICE, vol. 14, no. 2, pp. 215–227 ©IEICE 2023 DOI: 10.1587/nolta.14.215

been proposed and investigated. The pioneers were Hodgkin and Huxley [3], who conducted a physiological experiment to inspect the electrophysiological properties of a single neuron and formulated them as the Hodgkin–Huxley model, which consists of a set of four-dimensional ordinary differential equations. Aihara et al. [4] confirmed that a periodically forced Hodgkin–Huxley model was able to reproduce periodic, quasi-periodic, and chaotic responses of neurons. Although the Hodgkin–Huxley model has biophysically meaningful variables and parameters and shows the highest ability of reproducing various spike patterns, it requires numerous floating-point operations for simulation, which makes it difficult to implement large-scale simulations. Consequently, computationally simpler models have been proposed.

A prominent model is the Izhikevich neuron model [5], which is a reduced variant of the Hodgkin–Huxley model. In particular, the Izhikevich neuron model is a two-dimensional hybrid spiking neuron model. It achieves computational effectiveness and high reproducibility of neuronal behavior. Farokhniaee et al. [6] studied the mode-locking behavior of a periodically forced Izhikevich neuron model; however, non-periodic behavior was not mentioned. In previous studies [7, 8], Nobukawa et al. investigated chaotic responses to weak sinusoidal stimulation. However, only representative pairs of amplitude and frequency were evaluated. Therefore, here, we carried out a comprehensive evaluation using a wider range of amplitude and period pairs. We have already investigated the responses of a regular spiking (RS) neuron of the model to sinusoidal input and identified periodic and quasi-periodic behavior [9, 10]. However, much remains to be learnt about the non-periodic responses of other types of neurons to periodic inputs.

In the present study, we analyzed the responses of three other principal neuron types: fast spiking (FS) [11], intrinsically bursting (IB) [12], and chattering (CH) [12] neurons, as well as an RS neuron, in response to periodic forcing; and compared the results obtained for RS, FS, IB, and CH neurons.

In the analysis, we adopted three measures: the diversity index D, the coefficient of variation C_v, and the local variation L_v, all of which focus on interspike intervals (ISIs). The evaluation of these three measures implied that the positional relationship of the two nullclines, determined by the amplitude of sinusoidal inputs, plays a crucial role in the periodicity or non-periodicity of responses. Moreover, comparison among these measures may be applicable to classification of neurons.

2. The Izhikevich neuron model

The Izhikevich neuron model [5] is a hybrid spiking neuron model, which involves a combination of a continuous and discrete part. This combination facilitates compatibility between computational complexity and reproducibility.

The Izhikevich neuron model is described as two-dimensional, ordinary differential equations and is defined as follows:

$$\begin{cases} \dfrac{dv}{dt} = 0.04v^2 + 5v + 140 - u + I(t) \\ \dfrac{du}{dt} = a(bv - u) \end{cases} \tag{1}$$

with the reset process after firing described as follows:

$$\text{when } v \geq 30 \text{ [mV]}, \quad \text{then} \begin{cases} v \leftarrow c \\ u \leftarrow u + d. \end{cases} \tag{2}$$

Here, v and u are the membrane potential [mV] and recovery variable, respectively, and t is time [ms]. The variable u provides negative feedback to v, which corresponds to the activation of K^+ ionic currents and inactivation of Na^+ ionic currents. $I(t)$ is a time-dependent input current, whereas a, b, c and d are dimensionless parameters. Various spike patterns, including chaotic spiking, are reproduced when the parameters are properly set and $I(t)$ is constant. Table I shows the parameter sets for some principal spike patterns in case that the input current is constant ($I(t) = 10$) [5].

The four spike patterns in Table I, all of which are periodic, are briefly explained below.

RS The most typical spike pattern. The frequency is initially high, and soon decreases and becomes periodic, which is referred to as spike frequency adaptation.

Table I. The parameters a, b, c, d, and input current $I(t)$ of the principal spike patterns.

spike pattern	a	b	c	d	$I(t)$
regular spiking (RS)	0.02	0.2	-65	8	10
fast spiking (FS)	0.1	0.2	-65	2	10
intrinsically bursting (IB)	0.02	0.2	-55	4	10
chattering (CH)	0.02	0.2	-50	2	10

FS A train of periodic spikes with significantly higher frequency than RS. Spike frequency adaptation is hardly observed.

IB The burst, firing with extremely high frequency, followed by a train of spikes.

CH A train of bursts at certain intervals.

In the present study, $I(t)$ is not constant but periodic input comprising two parts: a constant part I_{DC} and a periodic part $I_{AC} = A\sin(2\pi/T)t$:

$$I(t) = I_{DC} + I_{AC} = I_{DC} + A\sin\frac{2\pi}{T}t, \tag{3}$$

where A and T represent the amplitude and the period of a sinusoidal wave, respectively. Throughout the simulations, the constant part remains fixed ($I_{DC} = 10$). The amplitude A and period T are changed and their effect on spike patterns are examined.

3. Analysis methods

We adopted three measures to analyze ISIs: the diversity index D [14, 15], the coefficient of variation C_v, and the local variation L_v [16, 17]. Let us define the i-th firing time of a neuron as t_i. The i-th ISI (s_i) is defined as $s_i = t_{i+1} - t_i$. For each neuron type, we compute the above-mentioned three measures from a consecutive sequence of ISIs.

3.1 The diversity index

The diversity index D is defined as follows [14, 15]:

$$D = \frac{M}{N}, \tag{4}$$

where N is the total number of ISIs and M is the number of different values of ISIs. Given a sufficiently large N, M is approximately equal to N and D is close to unity when a response is irregular. In contrast, M is significantly smaller than N and D is close to zero when a response is periodic. In this study, the i-th and j-th values of ISI up to six decimal places are considered equivalent.

3.2 The coefficient of variation

The unbiased variance σ^2 is given by

$$\sigma^2 = \frac{1}{N-1}\sum_{i=1}^{N}(s_i - \bar{s})^2, \tag{5}$$

where $\bar{s} = \frac{1}{N}\sum_{i=1}^{N} s_i$ is the average ISI. The coefficient of variation C_v is defined as

$$C_v = \frac{\sigma}{\bar{s}}. \tag{6}$$

$C_v \to 1$ for a spike sequence following a Poisson distribution. On the other hand, $C_v = 0$ when all the ISIs are the same.

3.3 The local variation

The local variation L_v is defined as follows [16, 17]:

$$L_v = \frac{1}{N-1} \sum_{i=1}^{N-1} \frac{3(s_i - s_{i+1})^2}{(s_i + s_{i+1})^2}. \tag{7}$$

The *three* in Eq. (7) is taken so that L_v converges to unity for a spike sequence following a Poisson distribution. Like C_v, $L_v = 0$ when $s_i = const.$ for any i, and $L_v = 1$ when a spike sequence follows a Poisson distribution. It differs from C_v in that L_v remains low even though the ISIs are locally periodic in appearance and are globally modulated.

For the diversity index D, it matters whether two ISIs differ; however the actual difference between the two is not relevant. In contrast, the coefficient of variation C_v and the local variation L_v represent the difference between two ISIs. While C_v quantifies the distribution of ISIs, L_v is subject to their temporal order; for a shuffled sequence of ISIs, L_v undergoes a change; however C_v does not. Thus, L_v can evaluate the intrinsic properties of a neuron without the influence of modulation.

3.4 Stroboscopic plots

Stroboscopic plots display the Poincaré sections for different phases of a sinusoidal signal. Stroboscopic plots have been used to qualitatively analyze neuronal activity [1, 2]. When a response is periodic, distinct points are plotted on each stroboscopic plot, which means that the attractor is a limit cycle. When a response is not periodic, different plots are obtained according to the attractor type. In the present study, we obtained Poincaré sections at phases $0°$, $30°$, $\cdots$, $330°$.

4. Numerical simulation

In this study, the Izhikevich neuron model is numerically calculated by the Euler method with the interval $h = 0.01$ [ms]. For a more accurate simulation, the firing time t_F was determined by linear interpolation, as follows:

$$t_{\mathrm{F}} = t + \frac{30 - v(t)}{v(t+h) - v(t)} h, \tag{8}$$

where t suffices $v(t) < 30$ and $v(t+h) \geq 30$. Although the Euler method is less accurate than the Runge–Kutta method, the Euler method with linear interpolation provides sufficiently accurate firing times and requires relatively few computations per spike [13]. Spike sequences in $0 \leq t \leq 5,000$ are omitted in order to eliminate transient states. Spike sequences for 10,000 [ms] $(5,000 < t \leq 15,000)$ are used to compute the measures of ISIs.

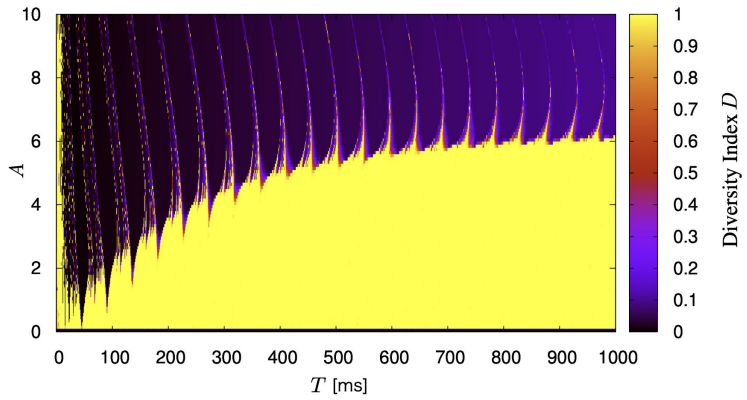
5. Results

In this section, we evaluate the ISIs of different neuron types comprehensively and quantitatively. We also investigate qualitative differences between periodic and irregular responses based on the Poincaré sections by stroboscopic plots.

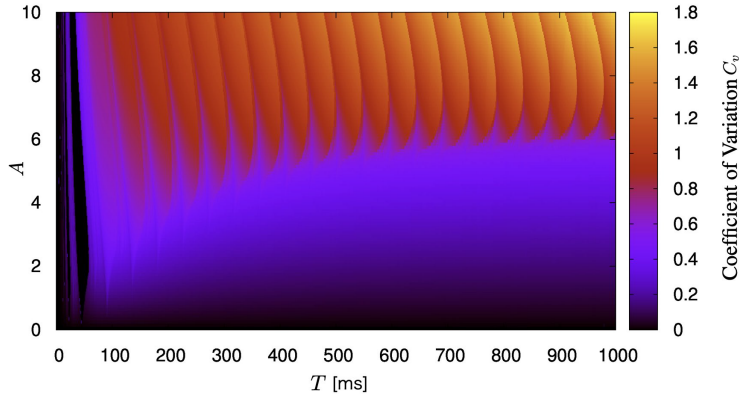
5.1 Evaluation of ISIs

Figures 1–4 show the measures of RS, FS, IB, and CH neurons, respectively. Each figure comprises three color maps (showing the diversity index D, the coefficient of variation C_v, and the local variation L_v), where the horizontal and the vertical axes represent the period T and the amplitude A, respectively, and color bar indicates the values of measures. We changed the period T over the range of $1 \leq T \leq 1,000$ and the amplitude A over the range of $0 \leq A \leq 10$ for every measure.

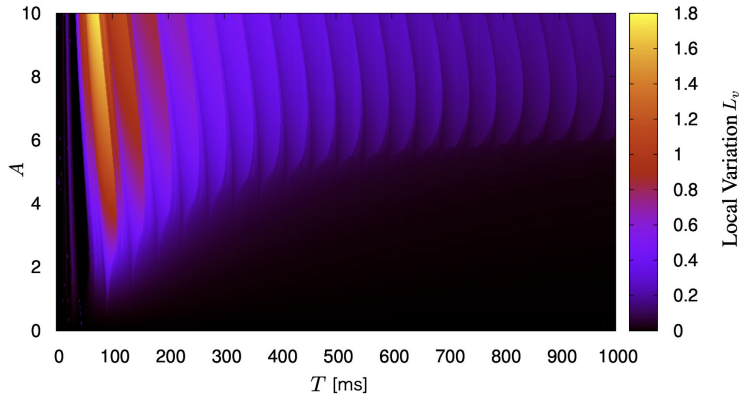
The diversity indices of the four types of neurons share similarity with each other (see Figs. 1–4(a)), that is to say, the boundary between the region of periodic responses and that of non-periodic responses converges to approximately $A = 6$ as T increases. Hereinafter, this boundary is referred to as the $A = 6$ boundary. An analytical consideration of the nullclines might explain the reason for this phenomenon.



(a) The Diversity Index D



(b) The Coefficient of Variation C_v

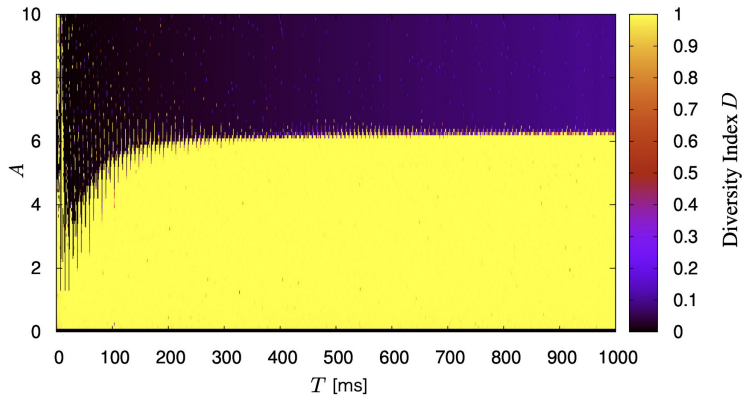


(c) The Local Variation L_v

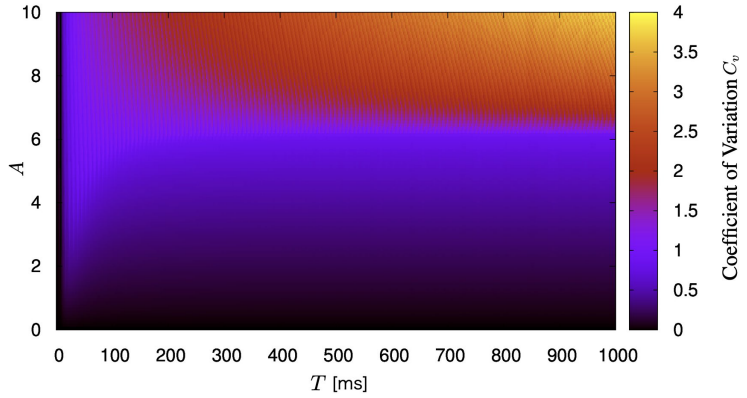
Fig. 1. Comparison of the three measures quantifying interspike intervals (ISIs) calculated from spike trains induced by regular spiking (RS) neurons.

Here, we consider a phase plane of the Izhikevich neuron model (the horizontal and the vertical axes represent the variables v and u, respectively). The v-nullcline, defined as $\frac{dv}{dt} = 0$, is as follows:

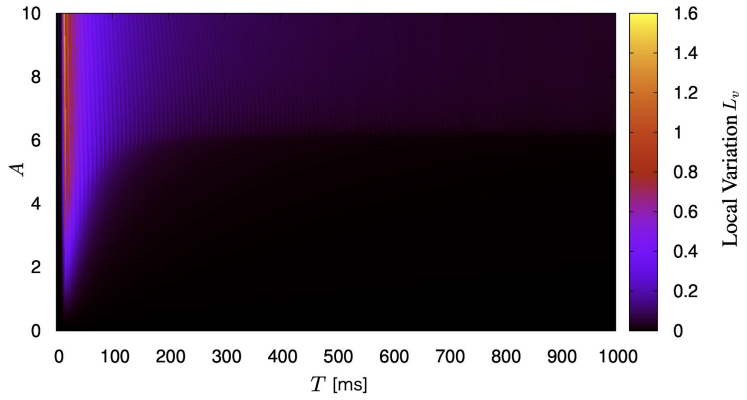
$$u = 0.04v^2 + 5v + 140 + I(t). \tag{9}$$



(a) The Diversity Index D



(b) The Coefficient of Variation C_v



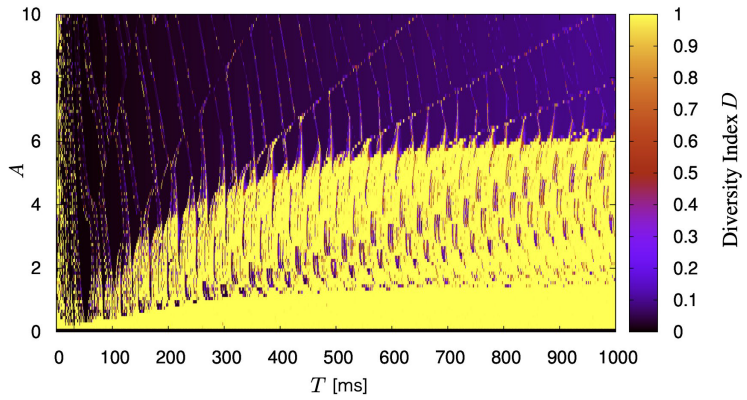
(c) The Local Variation L_v

Fig. 2. Comparison of the three measures quantifying interspike intervals (ISIs) calculated from spike trains induced by fast spiking (FS) neurons.

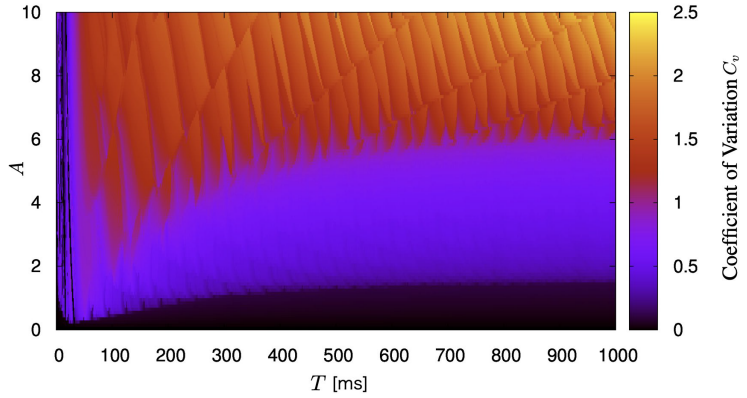
Likewise, the u-nullcline is given by

$$u = bv. \tag{10}$$

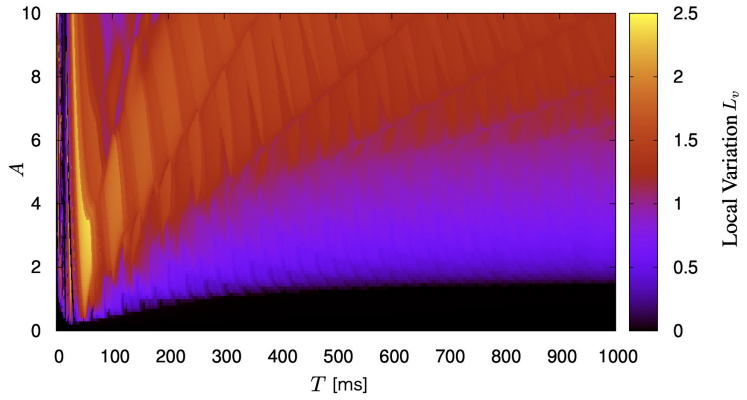
Note that both can be expressed as a function u of v. The v-nullcline is a parabola that moves in the direction of the u axis accompanying the fluctuation of I_{AC} in Eq. (3) and the u-nullcline is a straight



(a) The Diversity Index D



(b) The Coefficient of Variation C_v

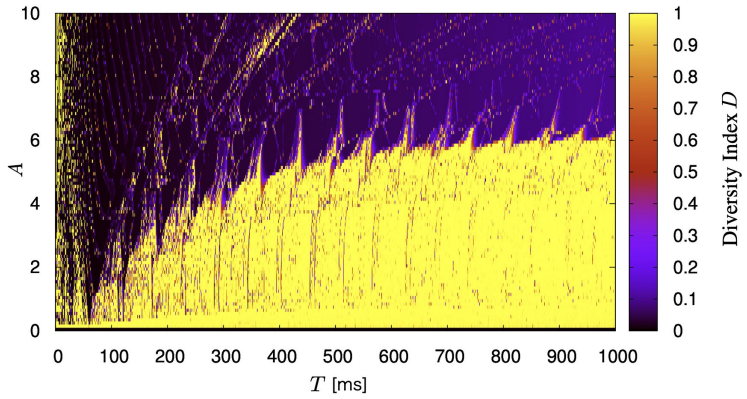


(c) The Local Variation L_v

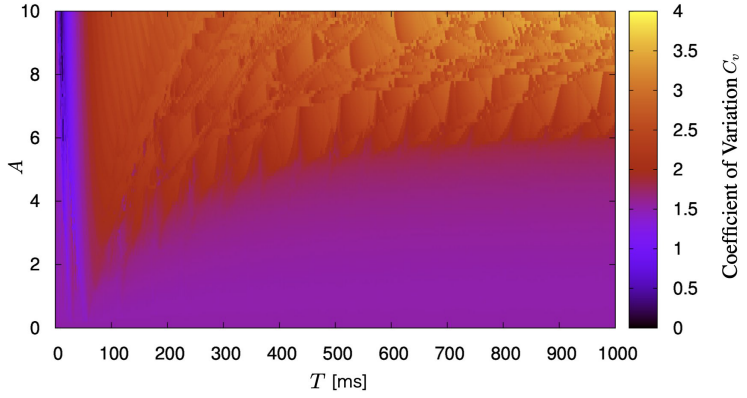
Fig. 3. Comparison of the three measures quantifying interspike intervals (ISIs) calculated from spike trains induced by intrinsically bursting (IB) neurons.

line (see Fig. 5). When the u-nullcline is tangential to the v-nullcline, i.e., they have a single common point, the quadratic equation

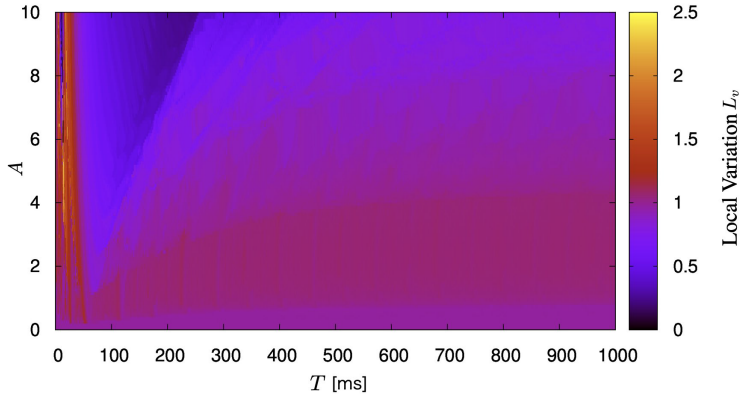
$$0.04v^2 + 5v + 140 + I(t) = bv \tag{11}$$



(a) The Diversity Index D



(b) The Coefficient of Variation C_v



(c) The Local Variation L_v

Fig. 4. Comparison of the three measures quantifying interspike intervals (ISIs) calculated from spike trains induced by chattering (CH) neurons.

has a double root. The discriminant of Eq. (11) is as follows:

$$\Delta = (5 - b)^2 - 4 \cdot 0.04 \cdot (I(t) + 140). \tag{12}$$

$\Delta = 0$ when Eq. (11) has a double root, and $b = 0.2$ for all the spike patterns analyzed in the present

study (Table I); thus, $I(t) = 4$. Considering that the input current (Eq. (3)) is a sinusoidal wave with the amplitude A and $I_{DC} = 10$, the v-nullcline with the amplitude $A = 6$ is tangential to the u-nullcline when Eq. (3) takes the minimum value. Therefore, the $A = 6$ boundary is related to the positions of the v- and the u-nullclines.

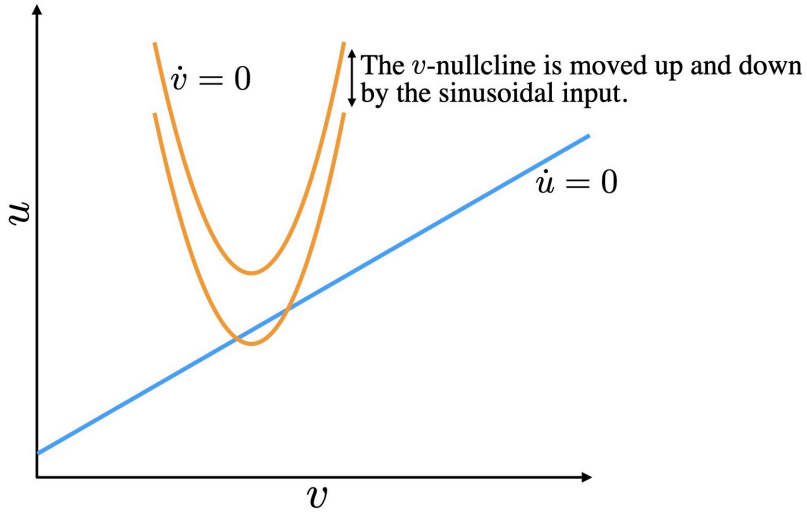


Fig. 5. A schematic diagram of the phase plane.

The straightforward inference is that a higher D corresponds to a higher C_v, because an irregular spike sequence leads to various ISIs and a high deviation value. However, the results are the inverse of the straightforward inference. For all four neuron types, a higher D corresponds to a lower C_v on the T-A planes. In the case of periodic spike patterns, the same series of ISI(s) is repeated, which leads to lower Ds. The degree to which differences between two consecutive ISIs vary is remarkable, and leads to higher C_vs. On the other hand, for non-periodic spike patterns, the result implies that each ISI differs slightly; therefore, M in Eq. (4) grows along with N, which means $D \approx 1$, while C_v is significantly low (see Fig. 6).

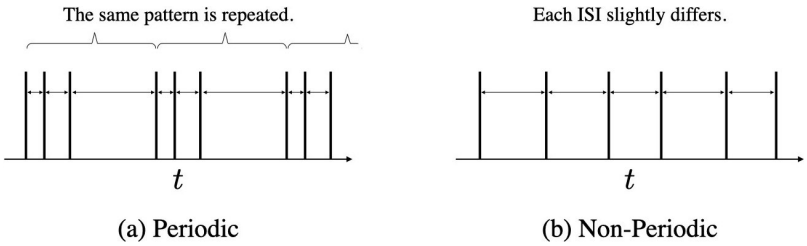
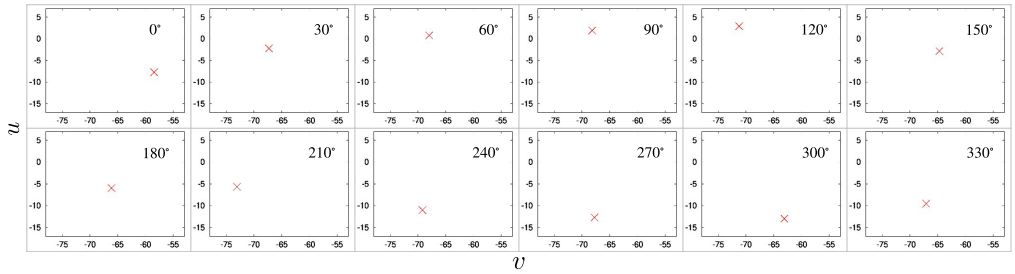


Fig. 6. Schematic illustrations of the two spike patterns. (a) While spikes are periodic, ISIs vary significantly. (b) While spikes are non-periodic, ISIs vary little.

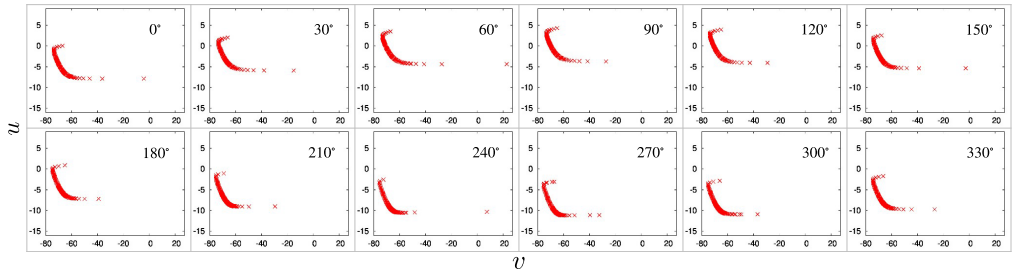
For RS, FS, and IB neurons, a higher C_v corresponds to a higher L_v on the T-A planes, and vice versa. However, for CH neurons, a higher C_v corresponds to a lower L_v, which implies a behavioral difference from the other three neuron types.

5.2 Stroboscopic plots

Figures 7–10 show stroboscopic plots of RS, FS, IB, and CH neurons, respectively. Figures 7–10(a) show stroboscopic plots for a periodic response. A single state point is plotted on each Poincaré section, which indicates that the attractor is a limit cycle. Periodic responses with other As and Ts also result in a single point or a number of points, which indicates limit cycles. On the other hand, stroboscopic plots of an irregular response resulted in curves (Figs. 7(b) and 8(b)), scattered plots

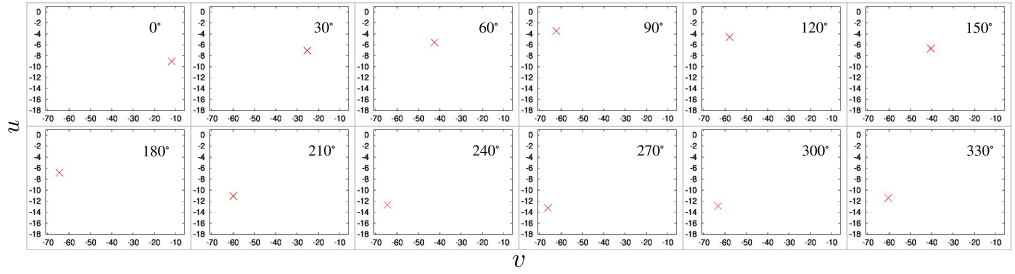


(a) $T = 600$ and $A = 7.5$

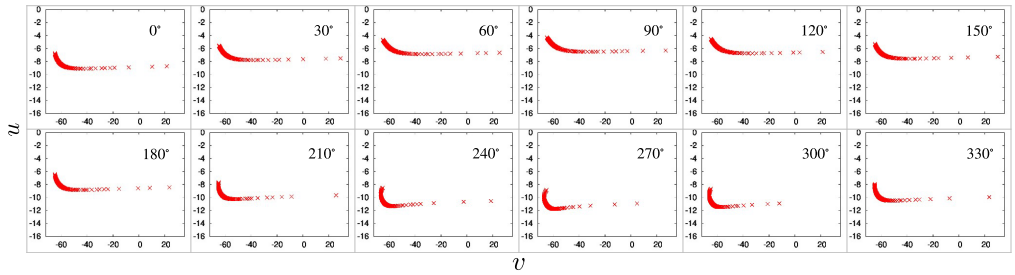


(b) $T = 600$ and $A = 4.5$

Fig. 7. Stroboscopic plots of regular spiking (RS) neurons. (a) Periodic activity is induced. (b) Irregular activity is induced.



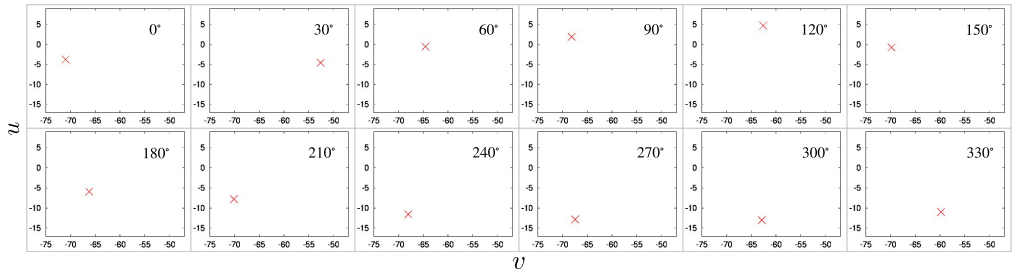
(a) $T = 600$ and $A = 7.5$



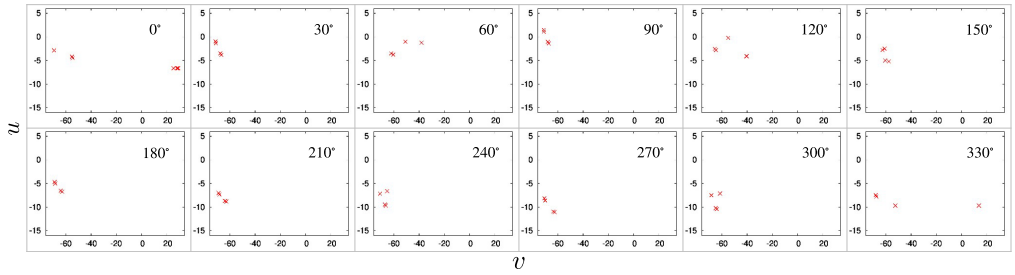
(b) $T = 600$ and $A = 4.5$

Fig. 8. Stroboscopic plots of fast spiking (FS) neurons. (a) Periodic activity is induced. (b) Irregular activity is induced.

(Fig. 9(b)), or plots changing with phase of periodic input (Fig. 10(b)). This indicates that attractors are qualitatively different from a limit cycle. In particular, the curves (Figs. 7(b) and 8(b)) imply that the attractor is a torus and that the irregular response is quasi-periodic. Normally, stroboscopic plots of quasi-periodic dynamical systems are closed curves. However, we observed open curves because of the state jump of the Izhikevich neuron model (Eq. (2)).

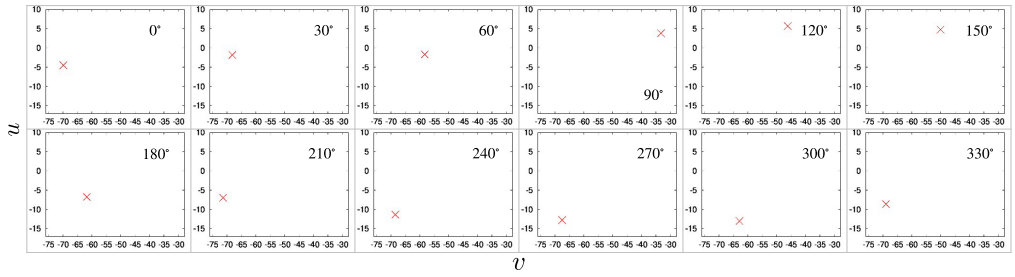


(a) $T = 600$ and $A = 7.5$

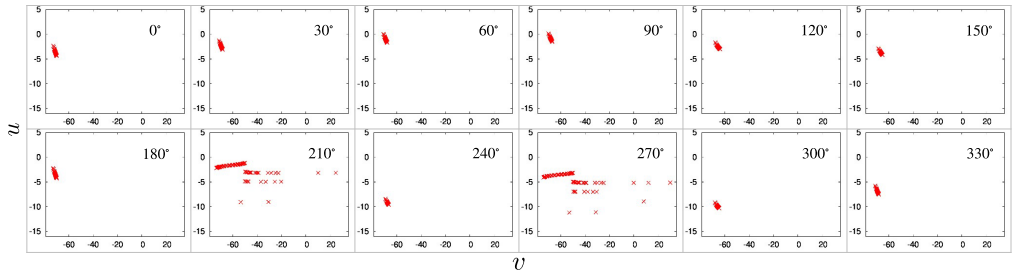


(b) $T = 600$ and $A = 4.5$

Fig. 9. Stroboscopic plots of intrinsically bursting (IB) neurons. (a) Periodic activity is induced. (b) Irregular activity is induced.



(a) $T = 600$ and $A = 7.5$



(b) $T = 600$ and $A = 4.5$

Fig. 10. Stroboscopic plots of chattering (CH) neurons. (a) Periodic activity is induced. (b) Irregular activity is induced.

6. Conclusion

In this study, spike sequences of four principal neuron types (RS, FS, IB, and CH neurons) in response to sinusoidal inputs have been investigated from the perspective of ISIs. Correlations among the diversity index D, the coefficient of variation C_v, and the local variation L_v were found to differ among the four neuron types.

Evaluation with a single measure can extract a measure-specific characteristic. On the other hand, comparison of the three measures could elucidate the dynamical properties of the Izhikevich neuron model. For all four neuron types studied here, D takes a lower value with $A > 6$ and a higher value with $A < 6$, whereas C_v takes a higher value with $A > 6$ and a lower value with $A < 6$. This indicates a significant difference in extrinsic spike patterns. Although L_v depends less on the firing rate, values of L_v also significantly change around the $A = 6$ boundaries for all four neuron types. This boundary corresponds to those of D and C_v, which implies that the intrinsic dynamical properties of a periodically forced Izhikevich neuron model transitions with the amplitude of the periodic input. From a theoretical viewpoint, the two nullclines of the Izhikevich neuron model intersect with $A > 6$, but not with $A < 6$. Therefore, the positional relationship of the two nullclines may play a critical role not only in extrinsic, but also in intrinsic dynamical properties.

Qualitative analyses with stroboscopic plots clarified the differences of attractor type between periodic and irregular responses. For periodic behavior, plots comprise distinct points, which indicates a limit cycle. In contrast, for irregular behavior, plots are composed of curves or irregularly scattered points. Considering the period and amplitude of sinusoidal waves, these two factors may result in qualitative differences between attractors and lead to periodical or irregular behavior.

Combined evaluation of more than one measure may be applicable to classification of neurons. A CH neuron demonstrates a different relationship of the magnitude of the three measures: a higher D corresponds to a lower C_v and a higher L_v. For the neurons other than CH, both C_v and L_v are lower when D is higher. Thus, neurons can be classified according to differences in the relationship of the magnitudes of measures.

In this study, we focused only on ISIs to analyze the dynamical behavior of a periodically forced Izhikevich neuron model. This is because ISIs are one of the easiest targets for inferring the dynamical properties of a single neuron. This increases the ease of application to physiological experiments. However, bifurcation analysis is also an important issue. Other future work will include evaluating Lyapunov spectra for dynamical systems with a reset process [18], because the discrete part of the hybrid spiking neuron model impedes estimation of the maximum Lyapunov exponent using ordinary methods.

Acknowledgments

The research of H. T. was partially supported by JSPS KAKENHI Grant Number JP22J12396. The research of T. I. was partially supported by JSPS KAKENHI Grant Numbers JP20H00596, JP21H03514, and JP22K18419.

References

[1] H. Hayashi, S. Ishizuka, M. Ohta, and K. Hirakawa, "Chaotic behavior in the Onchidium giant neuron under sinusoidal stimulation," *Physics Letters A*, vol. 88, no. 8, pp. 435–438, April 1982. DOI: 10.1016/0375-9601(82)90674-0

[2] K. Aihara, T. Numajiri, G. Matsumoto, and M. Kotani, "Structures of attractors in periodically forced neural oscillators," *Physics Letters A*, vol. 116, no. 7, pp. 313–317, June 1986. DOI: 10.1016/0375-9601(86)90578-5

[3] A.L. Hodgkin and A.F. Huxley, "A quantitative description of membrane current and its application to conduction and excitation in nerve," *Journal of Physiology*, vol. 117, no. 4, pp. 500–544, August 1952. DOI: 10.1113/jphysiol.1952.sp004764

[4] K. Aihara, G. Matsumoto, and Y. Ikegaya, "Periodic and non-periodic responses of a periodically forced Hodgkin–Huxley oscillator," *Journal of Theoretical Biology*, vol. 109, no. 2, pp. 249–269, July 1984. DOI: 10.1016/S0022-5193(84)80005-3

[5] E.M. Izhikevich, "Simple Model of Spiking Neurons," *IEEE Transactions on Neural Networks*, vol. 14, no. 6, pp. 1569–1572, November 2003. DOI: 10.1109/TNN.2003.820440

[6] A. Farokhniaee and E.W. Large, "Mode-locking behavior of Izhikevich neurons under periodic external forcing," *Physical Review E*, vol. 95, no. 6, 062414, June 2017. DOI: 10.1103/

PhysRevE.95.062414

[7] S. Nobukawa, H. Nishimura, and T. Yamanishi, "Chaotic resonance in typical routes to chaos in the Izhikevich neuron model," *Scientific Reports*, vol. 7, no. 1, pp. 1–9, May 2017. DOI: 10.1038/s41598-017-01511-y

[8] S. Nobukawa, H. Nishimura, T. Yamanishi, and J.Q. Liu, "Analysis of chaotic resonance in Izhikevich neuron model," *PloS one*, vol. 10, no. 9, e0138919, September 2015. DOI: 10.1371/journal.pone.0138919

[9] Y. Tsukamoto, H. Tsushima, and T. Ikeguchi, "Non-periodic responses of the Izhikevich neuron model to periodic inputs," *NOLTA*, vol. 13, no. 2, pp. 367–372, April 2022. DOI: 10.1587/nolta.13.367

[10] Y. Tsukamoto, H. Tsushima, and T. Ikeguchi, "Non-Periodic responses of the Izhikevich neuron model with periodic inputs," *Proc. 2021 Nonlinear Science Workshop*, NLSW-54, December 2021.

[11] Y. Tsukamoto, H. Tsushima, and T. Ikeguchi, "Responses of the Izhikevich neuron model to periodic inputs –In case of fast spiking neurons–," *Proc. IEICE General Conference*, N-1-16, March 2022, in Japanese.

[12] Y. Tsukamoto, H. Tsushima, and T. Ikeguchi, "Responses of the Izhikevich neuron model to periodic inputs –In case of burst firing–," *Proc. IEICE NOLTA Society Conference*, A-9, June 2022, in Japanese.

[13] E.M. Izhikevich, "Hybrid spiking models," *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, vol. 368, no. 1930, pp. 5061–5070, November 2010. DOI: 10.1098/rsta.2010.0130

[14] N. Sugiura, K. Fujiwara, R. Hosaka, and T. Ikeguchi, "Chaotic response of the Izhikevich neuron model and its statistical analysis," *IEICE Technical Report*, vol. 113, no. 116, pp. 43–48, July 2013, in Japanese.

[15] K. Naiki, Y. Shimada, K. Fujiwara, and T. Ikeguchi, "Chaotic responses and chaos synchronization in Izhikevich neuron model," *IEICE Transactions on Fundamentals of Electronics, Communications and Computer Sciences*, vol. J100-A, no. 5, pp. 195–204, May 2017, in Japanese.

[16] S. Shinomoto, K. Shima, and J. Tanji, "Differences in spiking patterns among cortical neurons," *Neural computation*, vol. 15, no. 12, pp. 2823–2842, December 2003. DOI: 10.1162/089976603322518759

[17] S. Shinomoto, Y. Miyazaki, H. Tamura, and I. Fujita, "Regional and laminar differences in in vivo firing patterns of primate cortical neurons," *Journal of Neurophysiology*, vol. 94, no. 1, pp. 567–575, July 2005. DOI: 10.1152/jn.00896.2004

[18] F. Bizzarri, A. Brambilla, and G.S. Gajani, "Lyapunov exponents computation for hybrid neurons," *Journal of Computational Neuroscience*, vol. 35, no. 2, pp. 201–212, February 2013. DOI: 10.1007/s10827-013-0448-6

査読あり国際会議

Nonlinear dynamics of temporal networks

Kazuya Sawada*, Tohru Ikeguchi
Tokyo University of Science
*sawada@hisenkei.net

As large-scale data become observable, network data, or information of connectivity of multiple elements, are attracting particular attention. Typical network data include networks of friendships, information diffusion, and infectious disease transmission. Since the late 1990s, research on networks has been active [1, 2], and today, the analysis frameworks for complex networks are well established. However, the networks analyzed in these studies are networks generated by the accumulation of connections between vertices, i.e., static networks that do not take temporal evolution into consideration. On the other hand, many real-world networks are dynamically evolving, namely, temporal networks and analysis of the temporal networks has been attracting attention in recent years [3]. In this study, we report on our analysis of the dynamics of temporal network generated from real contact data, by transforming them into time series. We use real contact data provided by Sociopatterns [4] for five classes of students and teachers in a French high school in 2012. In numerical experiments, the contact data is divided into time windows, and a network is generated in each time window. We then obtained a distance matrix by calculating the Hamming distance between the adjacency matrices of the networks in each time window. Furthermore, we obtained one-dimensional time series by applying the classical multidimensional scaling [5] to the distance matrix. Finally, we reconstructed attractors by transforming the obtained time series into a time-delay coordinate system [6]. We then found that temporal networks generated from real contact data have deterministic and recurrence structure.

References

[1] D. J. Watts and S. H. Strogatz, *Nature*, **393**(6684): 440–442, 1998.

[2] A. L. Barabási and R. Albert, *Science*, **286**(5439): 509–512, 1999.

[3] N. Masuda and P. Holme, *Sci. Rep.*, **9**(795): 1–11, 2019.

[4] Sociopatterns: http://www.sociopatterns.org (accessed on 8 April 2022).

[5] J. C. Gower, *Biometrika*, **53**(3–4): 325–338, 1966.

[6] T. Sauer et al., *J. Stat. Phys.*, **65**(3): 579–616, 1991.

Importance of time limit constraint for multiple-vehicle bike sharing system routing problem

Honami Tsushima[1], Takafumi Matsuura[2], and Tohru Ikeguchi[1]

[1] Department of Information and Computer Technology, Graduate School of Engineering,
Tokyo University of Science, 6–3–1 Niijuku, Katsushika-ku, Tokyo 125-8585, Japan
[2] Department of Information and Computer Technology, Faculty of Advanced Engineering,
Nippon Institute of Technology, 4–1 Gakuendai, Miyashiro-machi, Minamisaitama-gun, Saitama 345-8501, Japan
[3] Department of Information and Computer Technology, Faculty of Engineering,
Tokyo University of Science, 6–3–1 Niijuku, Katsushika-ku, Tokyo 125-8585, Japan
Email: honami@hisenkei.net

Abstract— In this study, we investigated the importance of a time limit constraint for a bicycle sharing system (BSS) rebalancing problem. As a result, we found that the variance of the number of visited ports by each vehicle can be reduced by setting a working time on ports and imposing the time limit constraint.

1. Introduction

A BSS is attracting attention as one of the eco-friendly transportation systems. However, the BSS has a problem that users cannot rent/return bicycles at ports. Therefore, multiple vehicles are used to adjust the number of bicycles at each port. Recently, many researchers proposed various BSS rebalancing problems (BSSRPs) to find efficient routes [1, 2]. In the BSSRPs, multiple constraints such as capacity and time limit constraints of the vehicles are considered to determine the efficient routes. For example, Dell'amico et al. proposed a bike sharing rebalancing problem (BRP) and an extension of the one-commodity pickup and delivery vehicle routing problem with maximum duration (1-PDVRPD) to BRP [1]. Then, we proposed multiple-vehicle bike sharing system routing problem (mBSSRP) [2]. In the BRP, capacity constraint is imposed, but time limit constraint and working time on each port are not imposed. On the other hand, in the 1-PDVRPD and the mBSSRP, capacity, time limit and working time on each port are considered. It is desirable that operators who are rebalancing bicycles have same working time when we consider real situation for rebalancing bicycles. However, the importance of whether or not to set a time limit and working time on each port have not been discussed. In this study, we investigate the variance of the number of visited ports of vehicles when we set and change the time limit constraint and working time on each port using two heuristic algorithms.

2. BSS rebalancing problem and heuristic methods

In the BSSRP, a depot, ports and a set of cost C_{ij} from port i to port j are given. An objective of many BSSRPs is to minimize traveling costs for vehicles with a capacity constraint. The capacity constraint is that vehicles cannot pickup more bicycles than their capacity, and delivery less than zero. Then, the time limit constraint is that vehicles must return to the depot within the time limit, and the working time on each port is the time pickup/delivery one bicycles on a vehicle.

To solve the BSSRP, in this study, we use destroy and repair algorithm (DR) [1] and tabu search (TS) [2]. In the DR, an initial tour is constructed by using a greedy algorithm. Then, the initial tour is improved by seven local search methods. Finally, the tour is iteratively destroyed and repaired, and improved by the seven local search methods, until a stopping criterion is met.

In the TS, the search for solution is performed by iteratively transitioning to neighborhood solutions. In the method, the neighborhood solutions are constructed by the Or-opt, the CROSS-exchange and the 2-opt. First, an initial solution is constructed by a greedy method that is based on the farthest insertion method. Then, the initial tour is improved using two local search methods. Finally, the tour is iteratively improved using the Or-opt and the CROSS-exchange which are controlled by the TS. In the tabu list, combinations of staring ports for exchanged/inserted subtours are recorded.

3. Numerical experiment

To investigate the variance of the number of visited ports of vehicle in case with and without the time limit constraint, we used the instances used in Ref. [1]. The details of the instances are shown in Table 1. In Table 1, the first column shows the city name, the second column shows the number of ports and the third column shows the capacity of a vehicle. The values of parameters in the DR were set to the same values as described in Ref. [1]. In the TS, tabu tenure was set to 100 for San Antonio instance and 150 for Denver and Minneapolis instances. The stopping criterion for small size instance (San Antonio) was set to 10 seconds, 600 seconds for medium size instance (Denver) and 1,800 seconds for large size instance (Minneapolis) in case

ORCID iDs First Author: 0000-0003-2711-2435, Second Author: 0000-0002-8007-0556, Third Author: 0000-0001-9280-9541

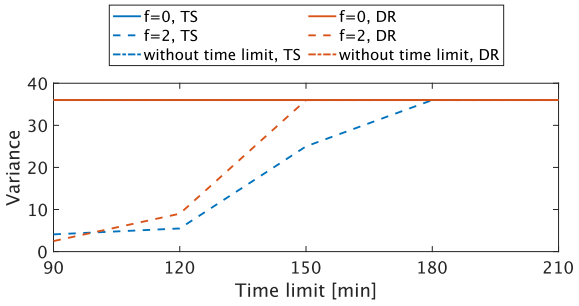
of using both methods.

We investigated the variance of the number of visited ports for vehicles in three scenarios: (1) without a time limit, (2) with a time limit but without a working time ($f = 0$) [min] at each port, and (3) with a time limit and a working time ($f = 2$) [min] at each port.

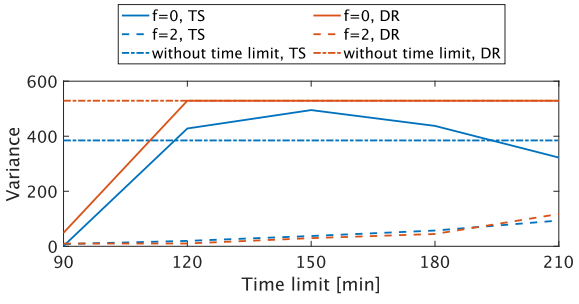
Table 1: BRP instances [1].

City	# of ports	capacity of a vehicle
San Antonio	23	30
Denver	51	30
Minneapolis	116	30

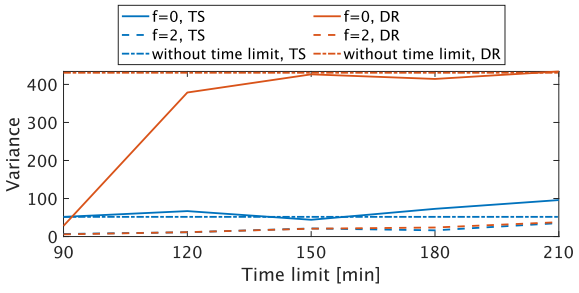
Figure 1 shows the variance of the number of visited ports of vehicles as the length of the time limit is changed. For the small size instance (Fig. 1 (a)), the variance of the number of visited ports of vehicles takes large values as the time limit increases when the working time on each port was set (dotted line). Then, similar result was obtained for the medium size instance in Fig. 1 (b). Therefore, working time on each port and the time limit constraint are important to equalize the workload of the operators who are rebalancing bicycles. For the large size instance (Fig. 1 (c)), the variance of the number of visited ports of vehicles also takes small value by the setting working time on each port and the time limit constraint. However, the difference between TS and DR values is large. Since TS uses two types of local search and DR uses seven types of local search, the number of iterations differs, which may have caused the difference in the value of variance. Therefore, TS can construct tour with small variance of the number of visited ports, when we treat large size instances.



(a) San Antonio



(b) Denver



(c) Minneapolis

Figure 1: Relationship between the length of the time limit and variance of the number of visited ports of vehicles.

4. Conclusion

In this paper, we investigate the importance of the time limit constraint for the BSSRP. As a result, we found that the variance of the number of visited ports of vehicles takes small value by the setting working time on each port and the time limit constraint. Therefore, to equalize the work time of operators, it is important to set the time limit constraint and working time on each port.

This work was supported by JSPS KAKENHI Grant Numbers JP22J12396, JP22KJ2808, JP19K04907, JP22K04602, JP20H00596, JP21H03514, JP22K18419.

References

[1] Mauro Dell'Amico, Manuel Iori, Stefano Novellani, Thomas Stützle, "A destroy and repair algorithm for the bike sharing rebalancing problem," *Computers & Operations Research*, vol. 71, pp. 149–162, 2016.

[2] Honami Tsushima, Takafumi Matsuura, and Tohru Ikeguchi, "Searching Strategies with Low Computational Costs for Multiple-Vehicle Bike Sharing System Routing Problem," *Applied Sciences*, vol. 12, no. 5, 2675, 2022.

A Study on Two-Objective Posting Poster Problem for Public Office Election

Fengkai Guo[1], Honami Tsushima[1], Takafumi Matsuura[2], Takayuki Kimura[2], and Tohru Ikeguchi[1]

1 Tokyo University of Science, 6-3-1 Niijuku, Katsushika-ku, Tokyo 125-8585, Japan
2 Nippon Institute of Technology, 4-1 Gakuendai, Miyashiro-machi, Minamisaitama-gun, Saitama 345-8501, Japan
Email: guofengkai@hisenkei.net

Abstract— The target of the Posting Poster Problem for Public Office Election (PPPOE) is to convey information about candidates to voters as quickly as possible. Thus, it is important to design optimal routes of vehicles for posting posters. In this work, we proposed the PPPOE that minimizes two objectives: the total traveled distance by vehicles and the difference in traveled distance between vehicles when constructing routes for displaying posters. We also investigated the balance between the two objective functions. Numerical experiments illustrated a trade-off relationship between the total traveled distance and the standard deviation of the vehicles' traveled distance.

1. Introduction

In elections for public office in Japan, one of the most common ways of providing information about candidates is to post election posters. After the candidates have registered their candidacy on the date of election announcement, they are informed of assigned positions in the poster boards. Then, the candidates and their staffs start posting the posters immediately to make their candidacy be known as soon as possible. To complete the work of posting posters quickly, it is necessary to design efficient poster posting routes. Therefore, we proposed a new problem called "Posting Poster Problem for Public Office Election (PPPOE)," which constructed poster posting routes as a discrete optimization problem[1]. To discuss how to achieve the optimal poster posting route, we introduced two types of objective functions[2, 3]. The first is a min-sum type objective function[2], which aims to minimize the total traveled distance by the vehicles. The second is a min-max type objective function[3], which focuses on minimizing the length of the longest route to reduce the difference in the total traveled distance by each vehicle. By solving PPPOE with the min-sum type objective function, we can obtain routes with the shortest total traveled distance. However, it has been clarified that there are differences in the total traveled distance between vehicles. On the other hand, using the min-max type objective function, we succeeded in reducing the difference in traveled distance between vehicles. However, the total traveled distance increased significantly. Therefore, in this study, we introduced an objective function of two objectives that aims to minimize both the total traveled distance and the disparity in the traveled distance between vehicles. The objective function has an adjusting parameter p of the two objectives. We also investigated a trade-off relationship between the total traveled distance and the standard deviation of vehicles' traveled distance.

ORCID iDs First Author: 0009-0003-2567-6314, Second Author: 0000-0003-2711-2435, Third Author: 0000-0002-8007-0556, Fourth Author: 0000-0003-0160-6146, Fifth Author: 0000-0001-9280-9541

2. Posting Poster Problem for Public Office Election with Two Objectives

In the PPPOE, an election office and poster boards are given. The vehicles depart from the election office, display posters at all the poster boards for which they are responsible, and return to the election office. In this problem, all locations including the election office and the poster boards are represented by the set $C = \{0, 1, ..., n\}$, where 0 denotes the election office. Let $K = \{1, 2, ..., v\}$ be the set of the vehicles used in the poster posting operation, D be the maximum distance that one vehicle can travel, and Q be the maximum capacity of the vehicle. Next, we defined the following decision variable x_{ijk} that determines the assignment of posters for vehicle k and the poster boards in which they are visited.

$$x_{ijk} = \begin{cases} 1\text{: vehicle } k \text{ moves from board } i \text{ to board } j \text{ directly,} \\ 0\text{: Otherwise.} \end{cases} \tag{1}$$

Using the above variables, the PPPOE with the two objectives is formulated as follows.

$$\min \quad p \sum_{k=1}^{v} \sum_{i=0}^{n} \sum_{j=0}^{n} d_{ij} x_{ijk} + (1-p) \sqrt{\frac{1}{v} \sum_{k=1}^{v} \left(\sum_{i=0}^{n} \sum_{j=0}^{n} d_{ij} x_{ijk} - \frac{\sum_{k=1}^{v} \sum_{i=0}^{n} \sum_{j=0}^{n} d_{ij} x_{ijk}}{v} \right)^2}, \quad (0 \le p \le 1), \tag{2}$$

$$\text{s.t.} \quad \sum_{j \in C} \sum_{k \in K} x_{ijk} = 1, \quad \forall i \in C \setminus \{0\}, \tag{3}$$

$$\sum_{i \in C} \sum_{k \in K} x_{ijk} = 1, \quad \forall j \in C \setminus \{0\}, \tag{4}$$

$$\sum_{i \in C} \sum_{j \in C} x_{ijk} \le Q, \quad \forall k \in K, \tag{5}$$

$$\sum_{i \in C} \sum_{j \in C} d_{ij} x_{ijk} \le D, \quad \forall k \in K, \tag{6}$$

$$\sum_{i \in C \setminus \{0\}} x_{i0k} = 1, \quad \sum_{j \in C \setminus \{0\}} x_{0jk} = 1, \quad \forall k \in K, \tag{7}$$

$$\sum_{i \in S} \sum_{j \in S} x_{ijk} \leq |S| - 1, \quad \forall S \subseteq C \setminus \{0\}, |S| \geq 2, \forall k \in K. \tag{8}$$

Equation (2) is the objective function of the PPPOE with the two objectives, which minimizes both the total traveled distance and the difference in traveled distance between vehicles. In Eq. (2), the sum of p times of the total traveled distance and $(1 - p)$ times of the standard deviation of the traveled distance between vehicles is minimized, where p is an adjustment parameter ($0 \leq p \leq 1$). Equations (3) and (4) indicate that every poster board should be visited exactly once by a vehicle. Equations (5) and (6) are the capacity constraint and the distance constraint for the vehicles. Equation (7) represents that each vehicle leaves the election office and returns to the election office again. Equation (8) is a sub-tour elimination constraint.

3. A heuristic method for solving the PPPOE with the two objectives

To construct good near-optimal solutions of the PPPOE with the two objectives, we proposed a heuristic method which includes a construction method and improvement methods.

3.1. Construction method

To generate an initial poster-posting route, we used the farthest-insertion method[4] as the construction method. As shown in Fig. 1, the farthest-insertion method consists of the following steps to construct the initial routes.

1. Select v poster boards using the maximum number of vehicles (v), and construct round trip routes between each selected poster board and the election office (Fig. 1(a)).
2. Select the poster board k that is the farthest from the election office and is not included in each route (Fig. 1(b)). The poster board k is then inserted between two poster boards in a way that minimizes the incremental traveled distance and satisfies the distance and the capacity constraints.
3. Repeating the step 2 until all poster boards are inserted (Fig. 1(c)).

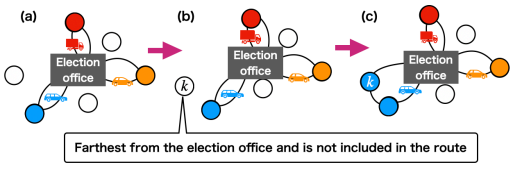


Figure 1: How to construct an initial tour by the farthest-insertion method.

3.2. Improvement method

The initial poster-posting routes are improved by the CROSS-Exchange method and the 2-opt method. The CROSS-Exchange method[5] is an improvement method for solving the vehicle routing problem, which improves the routes by exchanging partial routes of each vehicle.

A procedure of the CROSS-Exchange method is described as follows.

1. Select two routes from among all the routes. For example, in Fig. 2, the yellow and green routes are selected.
2. Two partial routes from each selected route are exchanged. In Fig. 2, the yellow and green partial routes which are marked by red rectangles are exchanged. Two routes after the CROSS-Exchange are shown in the right of Fig. 2.
3. Many possible combinations of partial tour exist for the exchange. In this study, a pair of partial routes is selected and exchanged so that the resulting tours are feasible and the value of the objective function is the most decreasing one.

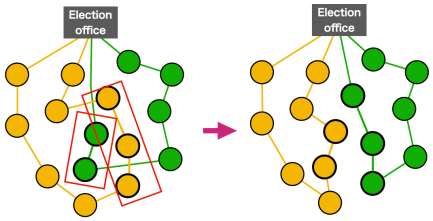


Figure 2: An example of the CROSS-Exchange.

The 2-opt method[6] can reduce the length of the routes by deleting two edges from a route and adding new two edges using the following procedure.

1. Select two poster boards i and j on a current route respectively. Let k and l be next poster boards visiting after i and j.
2. If the sum of distance d_{ij} and d_{kl} is shorter than the sum of distance d_{ik} and d_{jl}, the edges $i-k$ and $j-l$ are deleted and the edges $i-j$ and $k-l$ are added. Figure 3 shows an example of the 2-opt method.
3. Repeat steps 1 and 2 until a local optimal solution is obtained.

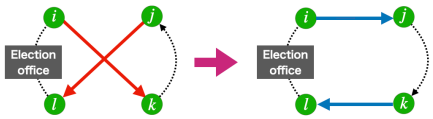


Figure 3: An example of the 2-opt method.

4. Numerical experiment and result

4.1. Experimental data and Condition

To construct an actual poster posting route, we use a real data on the arrangement of poster boards in Noda City,

Chiba Prefecture, Japan. Figure 4 shows a layout of the poster boards. The data are obtained by calculating the latitude and longitude of geographical locations of poster boards provided by the Noda City Election Administration Committee. We projected them onto a two-dimensional plane.

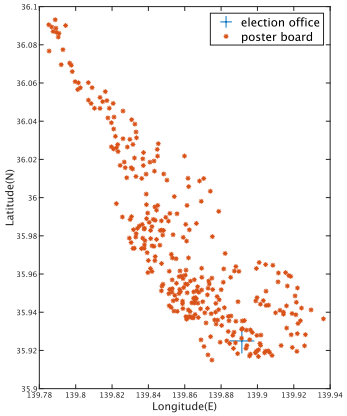


Figure 4: Arrangement of poster boards in Noda City, Chiba Prefecture, Japan. Red points are poster boards and blue plus is an election office used in this study.

In numerical experiments, we first constructed initial routes by the farthest-insertion method. Then, the initial routes were improved by the CROSS-Exchange and the 2-opt method until a local optimal solution is obtained.

4.2. Poster posting routes of Noda City

For the parameter settings, the adjustment parameter p is set to between 0.1 and 0.3 with a step size of 0.01. The number of available vehicles v is set to 12, the distance constraint D is set to $2.7f$ where f is the distance from the election office to the farthest poster board. The capacity constraint Q is set to 30. Numerical experiments are performed 30 times due to the randomness of the farthest-insertion method. Under these conditions, we calculated the results for the total traveled distance of the poster posting routes and the standard deviation of the travel distance for each vehicle.

Figure 5 shows the total traveled distance and the standard deviation (SD) of the traveled distance by vehicles with several values of the parameter p. Figure 6 shows a relationship between the total traveled distance and the standard deviation (SD). From these results, we can find that as the value of p changes from 0.1 to 0.3, the total traveled distance decreased and the standard deviation increased.

4.3. Poster posting routes of former Noda City and former Sekiyado Town

The current Noda City was merged by the former Noda City (the area below 36°N in Fig. 4) and the former Sekiyado Town (the area above 36°N in Fig. 4). Then, the

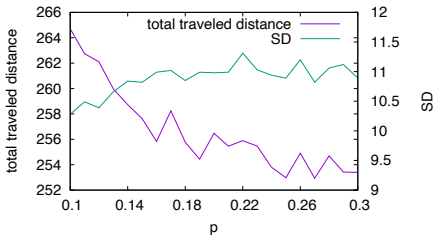


Figure 5: The result of Noda City's total traveled distance and standard deviation (SD) incase of changing p.

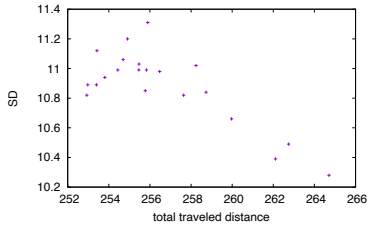


Figure 6: Relationship between total traveled distance and standard deviation (SD) in the Noda City.

poster boards are distributed in the northwest to southeast direction due to the geographical shape of the current Noda city. To improve the standard deviation of the travel distance of each vehicle, we divided the current Noda City into two regions: the former Noda City and the former Sekiyado Town. Then, we solved PPPOE for each region.

In this experiment, for the former Noda City, the number of vehicles is nine and the distance constraint is set to $D = 4.7f$. On the other hand, for the former Sekiyado Town, the number of vehicles is three and the distance constraint is $D = 2.7f$. The capacity constraint Q is set to 30. The experiments are also performed 30 times.

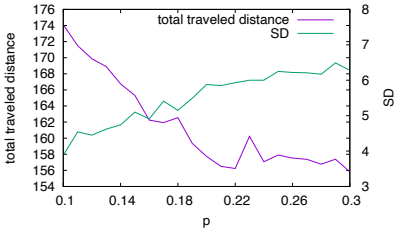


Figure 7: Relationship between the total traveled distance and the standard deviation (SD) incase of changing p for the former Noda City.

Figures 7 and 8 show the results of the total traveled distance and the standard deviation (SD) of the traveled distance by vehicles with changing the parameter p. Figures 9 and 10 show relationships between the total traveled dis-

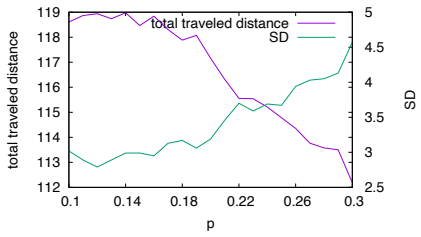


Figure 8: Relationship between the total traveled distance and the standard deviation (SD) incase of changing p for the former Sekiyado Town.

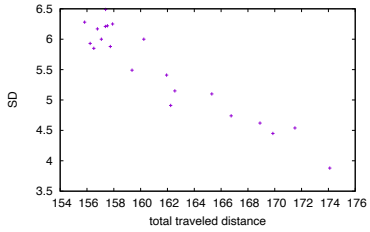


Figure 9: Relationship between the total traveled distance and the standard deviation (SD) in the former Noda City.

tance and the standard deviation (SD) for the former Noda City and the former Sekiyado Town. Figures 7 and 8 show that as p increases from 0.1 to 0.3, the total traveled distance is decreased and the standard deviation increased. From Figs. 9 and 10, we can observe a trade-off relationship between the total traveled distance and the standard deviation of the traveled distance for each vehicle.

Table 1: Comparison of results for the current Noda city, the former Noda City and the former Sekiyado Town for $p = 0.1$.

Data	Distance	SD
Current Noda City	264.710[km]	10.28
Former Noda City	174.101[km]	3.88
Former Sekiyado Town	118.612[km]	3.02

Table 1 shows the result of total traveled distance and standard deviation (SD) by the current Noda City, the former Noda City, and the former Sekiyado Town for $p = 0.1$. In Table 1, the total traveled distance from the former Noda City and the former Sekiyado Town are calculated as follows: 174.101[km]+118.612[km]=292.713[km]. Thus, the total traveled distance increases by 30[km] compared to solving the PPPOE for the current Noda City. However, the standard deviations of the regions are 3.88 and 3.02. By dividing the current Noda City, the standard deviation can be reduced by 70%.

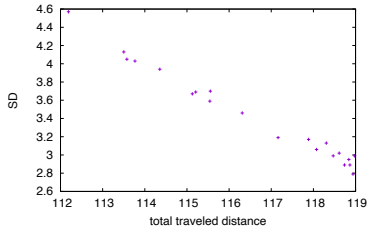


Figure 10: Relationship between the total traveled distance and the standard deviation (SD) in the former Sekiyado Town.

5. Conclusion

In this study, we proposed a new PPPOE with two objectives: the total traveled distance and the standard deviation of the traveled distance of each vehicle. In the objective function, an importance of each objective is adjusted by the parameter p. Then, we investigated the features of constructed tours by changed the adjustment parameter p. From the results of numerical experiments, we found that as p increased, the total traveled distance decreased and the standard deviation of the traveled distance by each vehicle increased. It was also confirmed that there is a trade-off relationship between the total traveled distance and the standard deviation of the traveled distance of each vehicle.

Acknowledgements

We thank the Noda City Election Administration Committee for providing us the geographical data of poster boards in Noda City, Chiba Prefecture, Japan. We also thank Mr. Yusuke Nakamura, a member of the Noda City Council, for reforming us of actual poster posting process. This study was supported by JSPS KAKENHI Grant Numbers JP22J12396, JP19K04907, JP22K04602, JP19K04395, JP21H03514, JP22K18419 and JP23K04274.

References

[1] T. Ikeguchi, *IEICE Technical Report.*, Vol. 122, No. 373, pp. 52–57, 2023, in Japanese.

[2] F. Guo, et. al., *2023 IEICE General Conference*, N-1-9, 2023, in Japanese.

[3] F. Guo, et. al., *IEICE Technical Report.*, Vol. 122, No. 436, pp. 104–109, 2023, in Japanese.

[4] T. Hoshino, et. al., *IEICE Transactions*, Vol. 90A, No. 5, pp. 431–441, 2007, in Japanese.

[5] E. Taillard, et. al., *Transportation science*, Vol.31, No. 2, pp.170-186, 1997.

[6] K. Yamamoto and H. Kubo, *Invitation to the traveling salesman problem*, Asakura Publishing Co., Ltd, 1997, in Japanese.

査読あり国内会議

Colexification networkを用いた語族比較

Comparison of language families using colexification network

福家水月 [1]　松本朋子 [1]　島田裕 [2]　池口徹 [1]

東京理科大学 [1]　埼玉大学 [2]

1　はじめに

人間のコミュニケーションの手段である言語には多くの種類が存在する．これらの言語では，種々の概念が様々な単語を用いて表現される．近年，単一の単語が複数の概念を表す colexification に着目して，概念同士の類似性を調査する研究が行われている [1]．この研究では，概念を頂点とし，二つの概念を有する単語が存在するとき，これらの頂点を枝で繋いでネットワークを作成する．これにより，ネットワークの観点から概念間の関係を定量的に捉えることが可能になる．このように colexification に基づいて生成されるネットワークを Colexification network (CN) と呼ぶ．CN において多くの頂点と枝で結ばれる頂点は，多数の概念と類似性・関連性が高く，中心的な概念であると考えられる．我々はこれまでに，CN から多言語に共通する基本的感情を抽出できること [2, 3]，CN において多数の概念と関連が強い概念には環境や動作を表すものが多いこと [4] を明らかにしている．本稿では，アフロ・アジア語族とインド・ヨーロッパ語族における colexification のデータから個別の CN を作成することで，中心的な概念がこれらの二語族間でどのように異なるのかを調べた結果を報告する．

2　数値実験

本稿では，以下の手順で CN における頂点 i の強度 In_i を算出し，強度の値が高い頂点を中心的な概念と定義する．

1. colexification のデータベース (CLICS^3)[5] を用いて CN を作成する．その際，枝の両端の頂点に対応する概念に対して，colexification を呈する単語の数を枝の重みとすることで重み付きネットワーク G を作成する．G において，概念 i と j を繋ぐ枝の重みを w_{ij} とする．
2. G の頂点数を N とし，遷移確率行列を $P = (p_{ij})$, $p_{ij} = w_{ij} / \sum_{k=1}^{N} w_{ik}$ と定義する．
3. $P^n (n = 10^3)$ を有向重み付き隣接行列としたネットワーク G' を作成する．
4. G' に対して頂点 i の強度を $\mathrm{In}_i = \sum_{k=1}^{N} p_{ki}^n$ と定義する．ここで，p_{ki}^n は P^n の第 (k, i) 成分を表す．

表 1 に，アフロ・アジア語族およびインド・ヨーロッパ語族の $G'(n = 10^3)$ における強度 In_i^n の順位表を示す．表 1 より，アフロ・アジア語族では “BOY,” “SON” などの人に関係する概念，インド・ヨーロッパ語族では “WOOD,” “LEATHER” などの自然素材に関係する概念の強度 In_i^n が高い．この結果は，どの概念同士が強い類似性・関連性を有するのかなどの認識が語族によって異なることを示唆するものである．

表 1: 強度 In_i^n の順位表

	アフロ・アジア語族		インド・ヨーロッパ語族	
	概念	In_i^n	概念	In_i^n
1	BOY	8.11	WOOD	7.18
2	MEAT	7.70	LEATHER	7.01
3	SON	7.09	FUR	6.95
4	SEIZE	6.69	CARRY	6.78
5	HOLD	6.69	EARTH (SOIL)	6.37
6	FLESH	6.28	END (OFSPACE)	6.31
7	DAUGHTER	6.28	GO	6.02
8	WEAVE	5.88	MEAT	5.85
9	LANGUAGE	5.88	MAN	5.85
10	OLDMAN	5.27	KEEP	5.85

一方，表 1 より，アフロ・アジア語族からは “SEIZE,” “HOLD,” インド・ヨーロッパ語族からは “CARRY,” “GO” などの動作に関係する概念の強度 In_i^n の値も高い．このことから，動作に関する概念は，語族に関わらず他の概念に対して強い類似性・関連性を有しており中心的な概念である可能性が示唆された．

3　まとめ

本稿では，アフロ・アジア語族とインド・ヨーロッパ語族から作成した colexification network を用いて，これらの語族における中心的な概念が何かを調査した．その結果，これらの語族で中心的な概念には，異なる概念と共通した概念の両者が存在することを確認した．本研究の一部は，JSPS 科研費 JP21H03514, JP21H04391, JP22K13339, JP21H03508, JP22K18419, JP20H00596, の助成を受けたものである．

参考文献

[1] A. François, *Semantic maps and the typology of colexification: Intertwining polysemous networks across languages in From Polysemy to Semantic Change: Towards a typology of lexical semantic associations*, ed. M. Vanhove, John Benjamins Amsterdam, pp. 163–215, 2008.

[2] Fukuya et al., Proc. of RISP NCSP’22, 1AM1-1-1, pp. 1–4, 2022.

[3] 福家 他, IEICE 2022 総合大会, N-1-27, 2022.

[4] 福家 他, IEICE NOLTA ソ大会, A-16, 2022.

[5] J. M. List *et al.*, https://clics.clld.org/, (Last visited Mar. 21st, 2023).

二つの目的を考慮した公職選挙ポスター掲示問題に対する発見的解法の開発

A Heuristic Method for Solving Posting Poster Problem for Public Office Election with Two Objectives

郭 豊愷 [1]　對馬 帆南 [1]　松浦 隆文 [2]　木村 貴幸 [2]　池口 徹 [1]

東京理科大学 [1]　日本工業大学 [2]

1　まえがき

公職選挙における立候補者のポスター掲示作業の効率化のために，我々は既に，目的関数が異なる二つの公職選挙ポスター掲示問題を提案している [1, 2, 3]．これらのうち，車両の総移動距離を最小化する min-sum 型の目的関数を用いた公職選挙ポスター掲示問題 [2] を解くことで，総移動距離の短い巡回経路を得ることができたが，車両間の移動距離に差が生じることが明らかとなった．そこで，車両の最長移動距離を最小化する min-max 型の目的関数を用いた公職選挙ポスター掲示問題 [3] とその解法を提案した．その結果，車両間の移動距離の差を減少させることには成功したが，総移動距離が大幅に増加する結果となった．そこで本稿では，車両の総移動距離と車両間の移動距離の差の両者の最小化を考慮した公職選挙ポスター掲示問題とその発見的解法を提案し，その結果について報告する．

2　二つの目的を考慮した公職選挙ポスター掲示問題と解法

本稿で対象とする公職選挙ポスター掲示問題の目的は巡回経路の総移動距離と各車両の移動距離の標準偏差の和の最小化であり，$\min\{p \times$ 総移動距離 $+ (1-p) \times$ 車両間移動距離の標準偏差 $\}$ で定義される．ここで p は調整パラメータである $(0 \leq p \leq 1)$．

提案解法では最遠挿入法 [4] を用いて初期ポスター掲示巡回経路を構築する．次に CROSS-Exchange を用いて局所最適解が得られるまで改善操作を行った後，2-opt 法を用いて各巡回経路の経路長を改善する．

CROSS-Exchange は，異なる二つの巡回経路から部分経路を選び，それらを交換することでより良い解を構築する．提案解法では，最も目的関数が改善できる交換を行う最良移動戦略を用いた．

3　数値実験・結果

千葉県野田市の公職選挙ポスター掲示場の位置情報 (1 つの選挙事務所と 324 ヶ所のポスター掲示場) に対して，提案解法の有効性を調査した．本実験では目的関数のパラメータを $p = 0.1$ に設定した．利用可能な車両数は 12 台とし，各車両の最大移動距離は，選挙事務所から最遠の掲示場までの距離の 2.7 倍，各車両のポスター最大積載枚数は 30 枚に設定した．一部のポスター掲示場は離れた場所に設置されているため，野田市を旧野田市部分と旧関宿町部分に分けた場合 [3] の結果も調査した．min-sum 型，min-max 型及び二つの目的を考慮した公職選挙ポスター掲示問題に対する計算結果を表 1 に示す．

表 1　実験結果 (30 回平均)

目的関数	データ	総移動距離 [km]	標準偏差
min-sum 型 [2]	野田市全体	241.254	10.79
min-max 型 [3]	野田市全体	469.928	2.54
二つの目的	野田市全体	266.443	10.25
min-max 型 [3]	旧野田市	176.739	1.00
	旧関宿町	123.214	1.26
二つの目的	旧野田市	172.258	3.04
	旧関宿町	119.414	2.79

表 1 より，二つの目的を考慮した場合，総移動距離は min-max 型の目的関数を用いたときよりも 203.485[km](= 469.928[km] − 266.443[km]) 短くなり，標準偏差は min-sum 型の目的関数を用いたときよりも 0.54(= 10.79 − 10.25) 小さくなることが示された．また，野田市を旧野田市部分と旧関宿部分に分けて，二つの公職選挙ポスター掲示問題として解いた場合，野田市全体のポスター掲示巡回経路長は 291.672[km] (= 172.258[km]+119.414[km]), min-max 型目的関数の場合は 299.953[km](= 176.739[km] + 123.214[km]) となり，総移動距離が 8.281[km](= 299.953[km] − 291.672[km]) 短くなることもわかった．

4　まとめ

本稿では，総移動距離と車両間の移動距離の標準偏差の最小化を考慮した公職選挙ポスター掲示問題とその発見的解法の提案を行った．数値実験の結果，二つの目的を考慮することで，車両間の移動距離の標準偏差を小さくしながら，車両の総移動距離を小さくすることに成功した．

本稿で使用した千葉県野田市におけるポスター掲示場の位置情報をご提供いただいた千葉県野田市選挙管理委員会, 実際のポスター掲示作業に関する状況をご教示いただいた中村裕介野田市議会議員に感謝します．なお，本研究の一部は，JSPS 科研費 JP22J12396, JP19K04907, JP22K04602, JP19K04395, JP21H03514, JP22K18419 の助成を受けた．

参考文献

[1] 池口, 信学技報, 122(373), 52–57, 2023.

[2] 郭, 他, 信学総大, N-1-9, 2023.

[3] 郭, 他, 信学技報, 122(436), 104–109，2023.

[4] 星野, 他, 信学論文誌, 90-A(5), 431–441, 2007.

査読なし国内学会

Hebb 則と時空間学習則のパターン分離能力の比較

Comparison of pattern discrimination ability between the Hebbian learning and the spatiotemporal learning rules

塚本陽太 [1] 塚田啓道 [2] 塚田稔 [3] 池口徹 [1]
Yota Tsukamoto Hiromichi Tsukada Minoru Tsukada Tohru Ikeguchi

東京理科大学 [1] 中部大学 AI 数理データサイエンスセンター [2] 玉川大学 脳科学研究所 [3]

1 はじめに

塚田らは，海馬を用いた生理学実験により，シナプス後ニューロンの発火がシナプス可塑性に寄与しない時空間学習則 (STLR) を発見している [1]．シナプス前ニューロンとシナプス後ニューロンの双方の発火タイミングがシナプス可塑性に寄与する Hebb 則 [2] とは異なり，STLR は類似した入力を識別するパターン分離能力に優れているとされている [3, 4]．本稿では，入力パターンの類似度を変化させた場合に，パターン分離能力がどのように変化するのかを，Hebb 則，Hebb± 則，STLR を対象として調査したので報告する．

2 モデル

本稿では，入力層と出力層がともに $N(=120)$ 個の形式ニューロンからなる全結合のフィードフォワードネットワークを用いた．離散時刻 t_n における j 番目のシナプス前ニューロンと i 番目のシナプス後ニューロンの出力を $x_j(t_n), y_i(t_n), (i, j = 1, \cdots, N)$ とし，1 ならば発火，0 ならば静止とする．また，j-i 間のシナプス荷重を $w_{ij}(t_n)$ とする．ニューロンの内部状態および出力は式 (1)，式 (2) により決定される．ここで，η は発火の閾値である．

$$s_i(t_n) = \sum_{j=1}^{N} w_{ij}(t_n) x_j(t_n) \tag{1}$$

$$y_i(t_n) = \begin{cases} 1 & s_i(t_n) \geq \eta \\ 0 & s_i(t_n) < \eta \end{cases} \tag{2}$$

Hebb 則，Hebb± 則，STLR はそれぞれ式 (3)，式 (4)，式 (5) で表される．

$$w_{ij}(t_{n+1}) = w_{ij}(t_n) + \Delta w x_j(t_n) y_i(t_n) \tag{3}$$

$$w_{ij}(t_{n+1}) = \begin{cases} w_{ij}(t_n) + \Delta w, & x_j(t_n) = y_i(t_n) = 1 \\ w_{ij}(t_n), & x_j(t_n) = y_i(t_n) = 0 \\ w_{ij}(t_n) - \Delta w, & \text{otherwise} \end{cases} \tag{4}$$

$$w_{ij}(t_{n+1}) = \begin{cases} w_{ij}(t_n) + \Delta w, & J_{ij}(t_n) \geq \theta_1 \\ w_{ij}(t_n), & \theta_2 < J_{ij}(t_n) < \theta_1 \\ w_{ij}(t_n) - \Delta w, & J_{ij}(t_n) \leq \theta_2 \end{cases} \tag{5}$$

ここで，Δw は学習率，θ_1, θ_2 はそれぞれ長期増強，長期減弱のパラメータである．また，式 (5) の $J_{ij}(t_n)$ はニューロン i への入力の同時性の時間履歴であり，式 (6) および式 (7) で定義される [3]．ここで，λ は時定数であり，本稿では $\lambda = 223$[ms] とした [5]．

$$J_{ij}(t_n) = \sum_{m=0}^{n} I_{ij}(t_m) \exp\left(-\frac{t_n - t_m}{\lambda}\right) \tag{6}$$

$$I_{ij}(t_n) = w_{ij}(t_n) x_j(t_n) \sum_{k=1, k\neq j}^{N} w_{ik}(t_n) x_k(t_n) \tag{7}$$

3 パターン分離能力の評価

入力系列として，0 と 1 が 60 ビットずつランダムに並ぶ 120 ビットの系列を 5 個生成した．この際，各系列間のハミング距離が常に同じ値 D となるように調整している．系列の j 番目の要素はニューロン j の発火の有無を表す．

5 個の系列を並び替えた 120 通りの系列を，同じ初期状態のニューラルネットワークに $n = 1, 2, \cdots, 5$ において与えることで学習させた後，出力取得用の系列を与えることで出力を得た．得られた 120 個の出力系列のうち，異なる出力系列の個数によりパターン分離能力を評価した．入力系列のハミング距離を $D = 4, 8, \cdots, 40$ と変化させたときの各学習則のパターン分離能力の変化の様子を図 1 に示す ($\Delta w = 1.0$)．

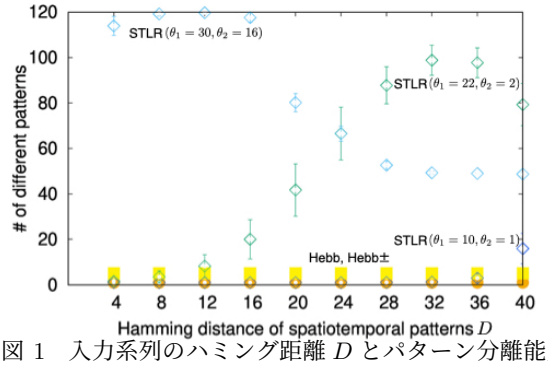


図 1 入力系列のハミング距離 D とパターン分離能力の関係．エラーバーは 100 回試行による平均値からの標準偏差の範囲を表す．

図 1 より，Hebb 則と Hebb± 則は入力系列のハミング距離 D に関係なくパターン分離能力が低い．一方，STLR はパラメータによって傾向が大きく異なることが分かる．$(\theta_1, \theta_2) = (10, 1)$ ではパターン分離能力が極めて低い．$(\theta_1, \theta_2) = (30, 16)$ では入力系列のハミング距離 D の増加に伴いパターン分離能力が低下するが，$(\theta_1, \theta_2) = (22, 2)$ では向上する．以上の結果は，STLR がパラメータに応じて特定の入力系列のハミング距離を検出できることを示唆する．今後は，学習における閾値コントロールが導入された生理学実験の結果 [6] なども考慮して，この仮説の検証を行う予定である．本研究の一部は，JSPS 科研費 JP20H04246，JP20H00596，JP21H03514，JP22K18419 及び東北大学電気通信研究所共同プロジェクト研究 R05/A19，R05/B13 の助成を受けた．

参考文献

[1] M. Tsukada et al., *Neural Networks*, 9(8), 1357–1365, 1996.
[2] D. O. Hebb, Oxford: Wiley, 1949.
[3] M. Tsukada and X. Pan, *Biological Cybernetics*, 92(2), 139–146, 2005.
[4] H. Tsukada and M. Tsukada, *Frontiers in Systems Neuroscience*, 15, 624353, 2021.
[5] T. Aihara et al., *Hippocampus*, 7(4), 416–426, 1997.
[6] E. Sugisaki et al., *Brain Research*, 1649, 44–52, 2016.

スパイク列の発火率差が因果性検出に与える影響

Effect on difference of firing rates on detecting causality for spike trains

澤田 和弥 [1] 島田 裕 [2] 池口 徹 [1,3]
Kazuya Sawada Yutaka Shimada Tohru Ikeguchi

東京理科大学大学院 工学研究科 [1] 埼玉大学大学院 理工学研究科 [2] 東京理科大学 工学部 [3]

1 はじめに

我々の身の回りにはサンプリング間隔が等間隔ではない点過程データが偏在する．例えば，神経活動から得られるスパイク列，経済活動から得られる取引成立時系列，地震活動から得られる地震発生時系列などである．これらの点過程データのみから，因果関係を検出することは重要なトピックである．我々はすでに，神経スパイク列に対する因果性検出手法を提案している [1]．提案手法は，inter-spike interval (ISI) からの力学系再構成技術 [2] と発火時刻による ISI の時間インデックスの対応付けにより，convergent cross mapping (CCM) [3] を拡張した手法である．提案手法では，ISI 時系列を相互に予測することで因果性を検出するが，スパイク列の間に発火率の差が存在する場合，予測精度が低下してしまうという問題がある．そこで本稿では，提案手法による因果性検出において，スパイク列の発火率の差と予測精度の関係を定量的に調査した結果を報告する．

2 手法

まず，スパイク列に対する因果性検出の提案手法の概要 [1] について述べる．簡単のため，2 つのスパイク列 S_1, S_2 を観測した場合を考える．n 番目の発火時刻をそれぞれ $S_i(n)$ $(i = 1, 2)$ $(n \geq 1)$ とすると，ISI 時系列の n 番目の値は，$T_i(n) = S_i(n+1) - S_i(n)$ $(n \geq 1)$ となる．次に，ニューロン i の ISI 時系列 $T_i(n)$ $(i = 1, 2)$ から状態空間を再構成し，ニューロン j の ISI 時系列 $T_j(n)$ $(j = 1, 2 | i \neq j)$ をオリジナルの CCM と同様に予測する．その際，ISI の時間インデックスは，発火時刻が最も近いものを対応付ける．提案手法では，上記の方法により相互に予測した ISI 時系列の予測精度が有意に高い値であるかを検定するため，twin surrogate 法 [4] を導入している．具体的には，予測対象の ISI 時系列からサロゲート時系列を生成し，同様に予測精度を算出し，その最大値と最小値の範囲と比較している．

3 数値実験

数値実験では，gap junction で結合した Izhikevich モデル [5, 6]: $\dot{v}_i = 0.04v_i^2 + 5v_i + 140 - u_i + I_i + \sum_{i \neq j, j=1}^{N} w_{ij}(v_j - v_i)$, $\dot{u}_i = a_i(b_i v_i - u_i)$ によりスパイク列を生成した．ここで，$v_i \geq 30$ のとき，$v_i \leftarrow c_i$, $u_i \leftarrow u_i + d_i$ にリセットされる．スパイク列はリセットされた時刻に生成されるとした．ただし本稿では，$N = 2$ とし，パラメータは，$a_i = 0.2$, $b_i = 2$, $c_i = -56$, $d_i = -16$, $I_i = -99$, $w_{12} = 0.1$, $w_{21} = 0.05$ $(i = 1, 2)$ とした．すなわち，2 つのニューロンが両方向に結合している．ここで，スパイク列 S_i の発火数を F_i とし，2 つのスパイク列の発火率差を $\Delta = (F_1 - F_2) \times 100/F_1[\%]$ $(F_1 \geq F_2)$ とする．提案手法はカオス的なスパイク列に対して有効であるが，所望の発火率を有するカオス的なスパイク列を生成するために，Izhikevich モデルのパラメータを調整するのは容易ではない．そこで，スパイク列 2 のスパイクをランダムに削除し，発火率の差を変化させたスパイク列を生成した．本稿では，Δ は 10 から 50 まで 5 刻みで変化させた．また，発火率ごとに 50 パターンのスパイク列を生成し，生成したスパイク列に提案手法を適用した．図 1 に，発火率の差と提案手法によって得られた予測精度の平均値および最小から最大の範囲の関係を示す．ここで，$\rho[T_i|T_j]$, $\rho'[T_i|T_j]$

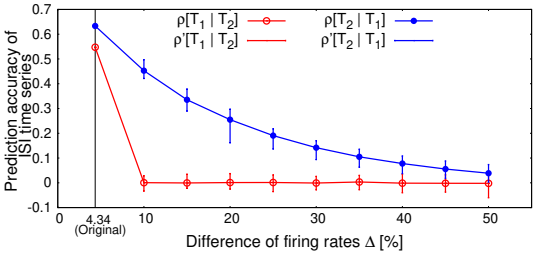


図 1 発火率の差 Δ と ISI 時系列の予測精度の関係．

はニューロン j の ISI を用いてニューロン i の ISI を 50 回予測した平均予測精度と最小値から最大値の範囲を示す．図 1 から，$\rho[T_1|T_2]$ は，少しでも発火率に差が生じるとほぼ 0 となっている．これは，スパイク列 2，すなわち予測器を構成するスパイク列をランダムに削除したことに起因する予測精度の低下であると考えられる．一方，$\rho[T_2|T_1]$ の値は，Δ の増加に伴い，徐々に低下し，$\Delta = 50$ 程度でほぼ 0 となっている．これは，発火率が 2 倍程度となると正確に因果性検出が行えない可能性を示すものである．本研究の一部は，JSPS 科研費（No. JP22KJ2815, JP20H00596, JP21H03514, JP21K12093, JP22K18419），東北大学電気通信研究所共同プロジェクト研究 R05/A19, R05/B13 の援助を受けて行われた．

参考文献

[1] K. Sawada et al., *Phys. Rev. E*, submitted.
[2] T. Sauer, *Phys. Rev. Lett.*, **72**, 24, 3811–3814, 1994.
[3] G. Sugihara et al., *Science*, **338**, 6106, 496–500, 2012.
[4] M. Thiel et al., *Europhys. Lett.*, **75**, 4, 535–541, 2006.
[5] E.M. Izhikevich, *IEEE TNN*, **14**, 6, 1569–1572, 2003.
[6] 内木 他, **信学論** *A*, **J100-A**, 5, 195–204, 2017.

公職選挙ポスター掲示問題における初期解構築法の性能比較

Performance evaluation of construction methods of initial solutions of PPPOE

郭 豊愷 [1] Fengkai Guo
松浦 隆文 [2] Takafumi Matsuura
木村 貴幸 [2] Takayuki Kimura
池口 徹 [1] Tohru Ikeguchi

東京理科大学 [1]
日本工業大学 [2]

1 まえがき

我々は既に，公職選挙における立候補者のポスター掲示作業の効率化のための公職選挙ポスター掲示問題（PPPOE）[1] とそれを解く発見的解法を提案した [2]．発見的解法は，初期ポスター掲示巡回経路を構築する構築法とそれを改善する改善法からなる．発見的解法を用いて PPPOE を解くことで，経験的なグループ分けに基づく最適解 [1] より，総移動距離の短い巡回経路を得ることを示した [2]．一方，これまでの配送計画問題に対する構築法の研究において，配送領域を分割して初期解を構築する手法の中では，円形分割スキームが良い上界を与えることが報告されている [3]．そこで本稿では，円形分割スキームと最遠挿入法 [2, 4] の性能比較を行うことで，構築法の差違が改善法の結果にどのような影響を与えるかについて調査したので報告する．

2 円形分割スキーム

円形分割スキーム [3] は以下の手順からなる．図 1 は最大ポスター積載枚数を 4 枚とした場合における実行例である．

1. 選挙事務所を中心，ポスター掲示場が含まれる円において半径を回転して，円を等面積の扇形に分割する (図 1(a) では三分割)．
2. 分割された扇形に含まれるポスター掲示場数が車両の最大ポスター積載枚数を超えた場合は，円の外側から弧によってその扇形を小領域に分割する (図 1(b) ではポスター掲示場数が 4 である 5 つの小領域と 4 未満の 3 つの小領域に分割)．
3. ポスター掲示場数が 4 未満の小領域を統合し，車両の最大ポスター積載枚数を超えないように，統合した領域を半径によって再分割する (図 1(c) では再統合した領域が二つの小領域に分割されている)．
4. 分割された各小領域を 1 台の車両が担当する．各小領域内の掲示場を訪問する初期巡回経路は最近傍法で構築する (図 1(d))．

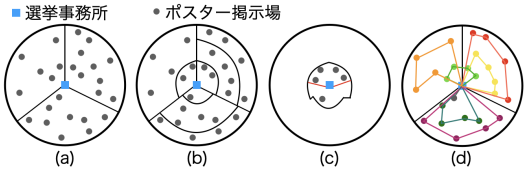
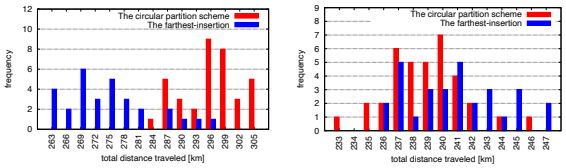


図 1 円形分割スキームの手順

3 数値実験・結果

本稿では，千葉県野田市の公職選挙ポスター掲示場の位置情報 (1 つの選挙事務所と 324 ヶ所のポスター掲示場) に対して，初期解構築に最遠挿入法を用いた場合 [2] と円形分割スキームを用いた場合で性能を比較した．なお，各手法で生成した初期経路は CROSS-Exchange を用いて局所最適解が得られるまで改善し，その後，各車両の経路を 2-opt 法にて改善する [2]．利用可能な車両数は 12 台とし，各車両の最大移動距離は，選挙事務所から最遠の掲示場までの距離の 2.7 倍，各車両の最大ポスター積載枚数は 30 枚に設定した．最遠挿入法を用いる場合は異なる初期解 30 個を作成した．円形分割スキームを用いる場合，初期等面積の扇形数を 5 に設定し，図 1(a) における半径の方向を 0° から 10° ずつ回転させた 36 種類の初期解を作成した．

最遠挿入法および円形分割スキームで成生した初期解の総巡回路長を局所探索で改善して得られた局所最適解の総移動距離の分布を図 2 に示す．



(a) 初期解 (b) 局所最適解

図 2 2 つの構築法を用いて構築したポスター掲示巡回経路の総移動距離の分布

図 2(a) より，最遠挿入法の方が短い初期巡回経路を構築できていることが分かる．しかし，改善法適用後の結果は，円形分割スキームの場合が 233[km]~246[km] で平均 239.340[km]，最遠挿入法の場合が 236[km]~247[km] で平均 241.331[km] となった．以上の結果から，初期解構築では最遠挿入法が優れているが，改善法を適用する場合は円形分割スキームが総移動距離が短い解を得ることができることが分かる．

本稿で使用した千葉県野田市におけるポスター掲示場の位置情報をご提供いただいた千葉県野田市選挙管理委員会，実際のポスター掲示作業に関する状況をご教示いただいた中村裕介議員に感謝します．なお，本研究の一部は，JSPS 科研費 JP19K04907，JP22K04602，JP19K04395，JP23K04274，JP21H03514，JP22K18419 および東北大学電気通信研究所共同プロジェクト研究 R05/A19，R05/B13 の助成を受けた．

参考文献

[1] 池口徹, 信学技報, 122(373), 52–57, 2023.

[2] 郭豊愷ほか, 2023 信学総大, N-1-9, 2023.

[3] M. Haimovich and A.H.G. Rinnooy. Kan, *Math. of Operations Res.* , 10(4), 527–542, 1985.

[4] 星野聖ほか, 信学論文誌, 90-A(5), 431–441, 2007.

マーク付点過程に対する因果性検出手法の一検討

A study on causality detection method for marked point processes

澤田 和弥 [1] 島田 裕 [2] 池口 徹 [1]
Kazuya Sawada Yutaka Shimada Tohru Ikeguchi

東京理科大学 [1] 埼玉大学 [2]

1 はじめに

我々は経済，地震データなどからマーク付点過程 (以下，MPP) を観測する場合が多数ある．観測した MPP から，その背後にあるシステムの変数間の因果性を検出することができれば，システムの理解の一助となることが期待される．そこで我々はすでに，MPP に対する因果性検出手法を提案している [1]．提案手法は，MPP のイベント間隔 (以下，IEI) 時系列とマーク時系列の 2 次元時系列から力学系を再構成する技術 [2] と，イベント発生時刻による MPP 間の時間対応により因果性検出を実現している．しかし，IEI 時系列とマーク時系列の両者を用いる提案手法がこれらのうち一方のみを用いて因果性検出を行う手法よりも高い検出精度を示すのかということについては明らかになっていない．そこで本稿では，IEI 時系列とマーク時系列から力学系を再構成して因果性検出する場合と IEI 時系列のみ，あるいはマーク時系列のみから力学系を再構成して因果性検出する場合について，性能の比較を行った結果を報告する．

2 因果性検出手法

我々がすでに提案している MPP に対する因果性検出手法 [1] では，IEI 時系列とマーク時系列から力学系を再構成し，IEI 時系列とマーク時系列をそれぞれ相互に予測する．本稿では，提案手法の比較として，IEI 時系列のみから力学系を再構成し，IEI 時系列を予測する場合，マーク時系列のみから力学系を再構成し，マーク時系列を予測する場合とした．これらの手法では，時系列長を増加させた際にその予測精度が上昇，収束するかどうかで因果性を検出することができる [3]．

3 数値実験

本稿では，式 (1) で定義される結合 Lorenz 方程式 [4] により生成した時系列データの極大値を抽出することで，MPP を生成した [5]．

$$\begin{cases} \dot{x}_1 = \sigma(y_1 - x_1) + C_{12}(x_2 - x_1) \\ \dot{y}_1 = r x_1 - y_1 - x_1 z_1 \\ \dot{z}_1 = -b z_1 + x_1 y_1 \\ \dot{x}_2 = \sigma(y_2 - x_2) + C_{21}(x_1 - x_2) \\ \dot{y}_2 = r x_2 - y_2 - x_2 z_2 \\ \dot{z}_2 = -b z_2 + x_2 y_2 \end{cases} \tag{1}$$

式 (1) のパラメータは $\sigma = 10$, $r = 28$, $b = 8/3$ とした．また，Lorenz1 $(x_1,\ y_1,\ z_1)$ から Lorenz2 $(x_2,\ y_2,\ z_2)$ への結合強度 C_{21}，Lorenz2 から Lorenz1 への結合強度 C_{12} は，(A) 両方向結合 $(C_{12} = C_{21} = 1.5)$，(B) 片方向結合 $(C_{12} = 0,\ C_{21} = 1.5)$，(C) 結合なし $(C_{12} = C_{21} = 0)$ の 3 種類とした．また，IEI 時系列とマーク時系列の 2 次元時系列を用いる場合，IEI 時系列のみ，またはマーク時系列のみを用いる場合のいずれも再構成次元 $m = 10$, 時間遅れ $\tau = 1$ として遅延座標系を用いて再構成し，相互予測を行った．実験では，時系列長を 1,000 から 10,000 まで 1,000 刻みで変化させた．結合 Lorenz 方程式から生成したマーク付点過程に提案手法，比較手法を適用した際の予測に用いたデータ長と平均予測精度の関係を図 1 (a)，(b) に示す． ここで，平均予測精度は，

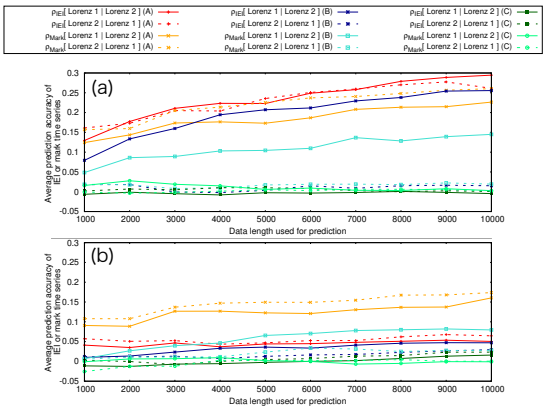


図 1 結合 Lorenz 方程式から生成した MPP に (a) 提案手法，(b) 比較手法を適用した際の予測に用いたデータ長と平均予測精度の関係

x_i, y_i, z_i $(i = 1, 2)$ から生成した MPP の情報を用いて，x_j, y_j, z_j $(i \neq j,\ j = 1, 2)$ の IEI またはマーク時系列を予測した場合の 9 通りの予測精度の平均値である．図 1 (a) から，時系列長の増加とともに，(A) の 4 つの予測精度と (B) の Lorenz1 から Lorenz2 への因果性を示す予測精度は比較的高い値に上昇している．また，(C) の予測精度は，時系列長が増加しても上昇していない．これらの結果は，結合強度により与えた因果性を正しく検出していることを示すものである．一方，図 1 (b) では，時系列長の増加とともに予測精度が上昇したのは (A) でマーク時系列を予測した場合 (オレンジ色の線) のみであり，正しく因果性を検出できていないことが分かる．したがって，MPP に対する因果性検出において，IEI とマーク時系列の 2 次元時系列から力学系を再構成することが重要であることを示すものである．

なお，本研究の一部は JSPS 科研費 (No. JP22J14621, JP22KJ2815, JP20H00596, JP21K12093, JP21H03514, JP21H03508, JP22K18419) の援助を受けて行われた．

参考文献

[1] 澤田 和弥 他，信学技報，**122**(436): 89–94, 2023.
[2] K. Sawada et al., *J. Signal Processing, RISP*, **25**(4): 127–131, 2021.
[3] G. Sugihara et al., *Science*, **338**(6106): 496–500, 2012.
[4] V. Anishchenko et al., *Phys. Rev. E*, **57**(1): 316–322, 1998.
[5] N. Yabuta and T. Ikeguchi, *Proc. of 2007 Int. Symp. on NOLTA*, 16–19, 2007.

カオス応答を呈する Izhikevich ニューロンに正弦波入力を印加した場合の応答解析

Analysis of behavior of chaotic Izhikevich neurons in response to sinusoidal forcing

塚本陽太 [1]　　對馬帆南 [1]　　池口徹 [1,2]

東京理科大学 大学院工学研究科 [1]　　東京理科大学 工学部 [2]

1　はじめに

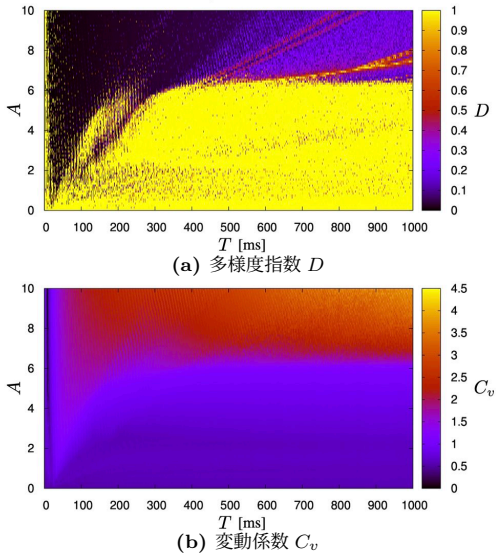
我々は既に，Izhikevich ニューロンモデル [1] が周期応答を示す場合とカオス応答を示す [2] 場合に正弦波入力を印加した際の応答を調査している [3–11]．しかし，文献 [2] で示されたパラメータは外部入力が大きな負の値となっており，生理学的に妥当とはいえない．一方，内木らは，外部入力が正の値となる場合にカオス応答を示すパラメータの存在を報告している [12]．本稿では，内木らによるカオスパラメータ [12] を Izhikevich ニューロンモデルに与えた際の正弦波入力に対する応答を調査したので報告する．

2　モデルと評価指標

Izhikevich ニューロン [1] への入力を正弦波 $I(t) = I_{DC} + A\sin\frac{2\pi}{T}t$ とする．内木らが報告した Izhikevich ニューロンがカオス応答を示す 4 種類のパラメータ [12] を用いて，周期 T，振幅 A を変化させた場合の発火時間間隔 (ISI) の振舞いを調査した．ISI の評価指標として，多様度指数 D [12, 13] と変動係数 C_v を用いた．多様度指数は，周期応答では $D \approx 0$，非周期応答では $D \approx 1$ となるため，応答がカオス的かを簡易的に識別することができる．

3　結果と考察

内木らが示したパラメータの中で 2 種類のパラメータを用いた場合の D と C_v の結果を図 1 と図 2 に示す．

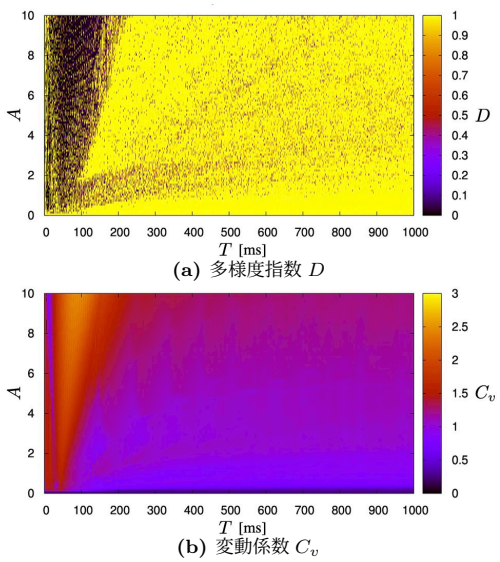


(a) 多様度指数 D

(b) 変動係数 C_v

図 1: 内木らによるパラメータ 1 ($a = 0.0511, b = 0.2, c = -55, d = 2, I_{DC} = 10$)

図 1 では $A = 6$ 付近でカオス応答から周期応答に変化しているが，図 2 では同様の特徴は見られなかった．一方，いずれのパラメータでも，カオス応答のときは C_v が低く，周期応答のときは C_v が高い傾向にある点は共通していた．これは，カオス応答では，わずかに異なる値から ISI が構成されているのに対し，周期応答では，ISI の値が大きく異なるためである．



(a) 多様度指数 D

(b) 変動係数 C_v

図 2: 内木らによるパラメータ 2 ($a = 0.02, b = 0.498, c = -47.6, d = 2, I_{DC} = 10$)

次に，Izhikevich ニューロンモデルのヌルクラインの位置関係を調査した．その結果，図 1 のパラメータでは，A の値によっては入力の変動に伴い Hopf 分岐が発生するのに対し，図 2 のパラメータでは 2 つのヌルクラインが常に離れており，分岐が発生しないという違いが見られた．本稿で示していない 2 つのパラメータも図 1 と図 2 のいずれかと類似した結果となった．

本研究の一部は，JSPS 科研費 JP22J12396，JP22KJ2808，JP20H00596，JP21H03514，JP22K18419 の助成を受けた．

参考文献

[1] Izhikevich, *IEEE TNN*, 14(6), 1569–1572, 2003.
[2] Izhikevich, *IEEE TNN*, 15(5), 1063–1070, 2004.
[3] Tsukamoto et al., *NOLTA, IEICE*, 13(2), 367–372, 2022.
[4] Tsukamoto et al., *Proc. of NLSW2021*, NLSW-54, 2021.
[5] 塚本 他，電子情報通信学会総合大会，N-1-16，2022.
[6] 塚本 他，電子情報通信学会 NOLTA ソサイエティ大会，A-9，2022.
[7] Tsukamoto et al., *NOLTA, IEICE*, 14(2), 215–227, 2023.
[8] Tsukamoto et al., *Proc. of NOLTA2022*, B2L-E-03, 2022.
[9] Tsukamoto et al., *Proc. of NCSP'23*, 3AM1-1-3, 2023.
[10] 塚本 他，電子情報通信学会総合大会，N-1-17，2023.
[11] Tsukamoto et al., submitted to *NOLTA, IEICE*, 2023.
[12] 内木 他, 信学論 A, J100-A(5), 195–204, 2017.
[13] 杉浦 他, 信学技報, 113(116), 43–48, 2013.

学位論文

様式３（　３枚中　１枚）

論 文 の 要 旨

2023　年　9 月　29 日

氏名　　澤田　和弥

論文題目

Detecting causality for point processes based on nonlinear dynamical system theory

---

(非線形力学系理論に基づく点過程に対する因果性検出に関する研究)

論文要旨

観測技術の向上により，様々な分野で高精度に大量の時系列データを観測可能となっている．特に，サンプリング間隔が一定な時系列データだけでなく，イベント発生時刻が記録された点過程データ，イベント発生時刻に何らかの情報を伴うマーク付点過程も観測可能となっている．典型的な点過程データとして，神経活動により得られるスパイク列がある．また，マーク付点過程として，地震活動，経済活動などのデータがある．

このように様々な点過程データ，マーク付点過程データを観測できるようになったにも関わらず，点過程データ，マーク付点過程データ生成の背後にあるシステムの因果関係が明らかになっていない場合が多い．観測した点過程データ，マーク付点過程データから，事象間の関連性，すなわち因果関係を明らかにすることができれば，生体活動，自然現象，経済活動など実世界に遍在する種々の複雑現象を理解する一助となるだけでなく，予測・診断・制御などの種々の工学的応用が可能となる．そのため，点過程データ，マーク付点過程データに対する因果性検出手法の開発が必要とされている．

これまで，時系列データ間の因果性を検出する手法として，線形回帰に基づく Granger causality，情報理論に基づく transfer entropy などが広く用いられている．しかし，これらの手法は決定論的非線形力学系から得られる時系列データに対しては，有効ではない場合があり，様々な問題を有している．一方，非線形力学系理論に基づく因果性検出手法として convergent cross mapping (CCM) が提案されており，決定論的非線形力学系に対する

因果性検出において有効であることが示されている．しかし，CCM は等間隔でサンプリングされた時系列を対象としており，点過程データ，マーク付点過程データに対する高性能な因果性解析手法の開発が必要である．このような背景から，非線形力学系理論の立場からの点過程データ，マーク付点過程データに対する因果性解析手法を開発することが本論文の目的である．

本論文ではまず，非線形時系列解析において最も重要な課題である，観測時系列を遅延座標系へ変換し力学系を再構成する際のパラメータ選択の基準に関して議論する．適切な再構成パラメータの選択は非線形力学系理論の立場からの因果性検出においても重要な問題である．具体的には，再構成したアトラクタの 2 点間距離分布と真のアトラクタの 2 点間距離分布の類似度を Jensen-Shannon (JS) divergence により比較し，適切な再構成パラメータを探索した．その結果，これまで先行研究で議論されていた埋め込み窓の重要性を定量的に明らかにした．

次に，CCM を応用したネットワークの結合推定手法を提案し，ネットワーク構造の違いが結合推定精度に与える影響を調査した．その結果，ランダムネットワークよりもコミュニティ構造を持つネットワークの方が結合推定精度が高く，次数が高くなるにつれて，結合推定精度が低下することを明らかにした．これは，CCM などの相互予測精度に基づく因果性検出手法の適用限界を示唆する結果である．

さらに，CCM を拡張した点過程データに対する因果性検出手法を提案している．CCM をスパイク列に拡張する際，スパイクの物理的に厳密な時間対応が取れないことが問題である．したがって，スパイク列の発火間隔からの力学系再構成の技術と，発火時刻によるスパイク列の対応によって拡張を実現した．また，因果性検出の際には，スパイク列から twin surrogate データを生成し，予測精度の有意性をサロゲートデータを用いた統計的仮説検定により評価した．神経細胞の振舞いを再現する数理モデルから生成したスパイク列に対して提案手法を適用し，その有効性を示した．

最後に本論文では，スパイク列に対する因果性検出の提案手法をマーク付点過程 (marked point process: MPP) に拡張している．その際，MPP をイベント間隔 (inter-event interval: IEI) 時系列とマーク時系列の 2 次元時系列が観測されたとみなすことで MPP から再構成する手法を提案した．提案手法で MPP から再構成したアトラクタが MPP を生成した真のアトラクタと幾何学的に類似するかどうかを 2 点間距離分布から評価した．その結果，従来の埋め込み定理で要求される次元以上で 2 点間距離分布は類似すること，したがって，提案手法により観測 MPP を生み出した非線形力学系を再構成できることを示して

いる．さらには，MPP からの力学系再構成の提案手法を用いた MPP に対する因果性検出手法を，非線形結合力学系から生成した MPP に対して適用し，その有効性を示した．また，IEI とマーク時系列から力学系を再構成することが因果性検出において本質的に重要であることも定量的に示した．

以上をまとめるに，本論文では，(1) 力学系再構成の際の埋め込み窓の重要性を定量化し，適切な再構成パラメータ決定の指針を与えた．また，(2) CCM を用いた結合推定の手法を提案し，ネットワーク構造の違いが結合推定精度に与える影響を明らかにした．さらに，(3) CCM をマークのない点過程に拡張した手法を提案し，神経スパイク列の数理モデルに対してその有効性を示した．次に，(4) MPP からの力学系再構成の手法を提案し，再構成の可能性について幾何学的な性質から示した．最後に，(5) MPP からの力学系再構成の技術を用いることで，MPP に対する因果性検出手法を提案し，その有効性を示した．

修士論文要旨

主査: 博士（工学）池口 徹 教授
副査: 博士（理学）池辺 淑子 准教授
副査: 博士（工学）立川 智章 准教授

論文提出者 情報工学専攻 郭 豊愷

論文題目 Solving the Posting Poster Problems for Public Office Election Using Heuristic Methods
公職選挙ポスター掲示問題に対する発見的解法に関する研究

In Japan, one of the election activities in public office elections is posting posters for candidates. Posters are usually posted by election staffs of each candidate on the day the election is announced. The election staffs depart from the election office, visit all the poster boards for which they are responsible, and return to the election office after the posters have been posted. If we consider the election office as a depot and the poster boards as customers, we can think of this as a kind of discrete optimization problem.

In this thesis, we define this problem as the Posting Poster Problems for Public Office Election (PPPPOE). First, we use the poster boards' layout in Noda City, Chiba Prefecture, as a concrete example, to discuss the solution-finding performance of the exact solution when using the solver for the case of experiential grouping currently used in actual congressional election campaigns up to now.

Next, in order to construct better poster posting routes, we propose three types different objective functions of Posting Poster Problems for Public Office Election: (1) a min-sum type objective function that minimizes the total distance traveled, (2) a min-max type objective function that minimizes the standard deviation of the distance traveled, and (3) a two-objective function that considers minimize both the total distance traveled and standard deviation. To get the solution for PPPPOE in a short time, we propose an approximate solution method for Posting Poster Problems for Public Office Election with these objective functions, and investigate the performance of the proposed method and the characteristics of the total distance traveled for different objective functions. Numerical experiments confirm that the heuristic method can obtain approximate solutions in a short time.

In addition, to discuss the performance of the experiential grouping of poster boards, we make grouping results using two region division methods, the sweep method and the circular partitioning scheme as used in vehicle routing problem. The results show that the to compare with the experiential grouping, region division methods can get more efficient grouping result. In the end, by changing the location of the election office we consider the question of where a better location is to locate the election office within the area of Noda City.

修士論文要旨

主査:　博士（工学）池口 徹　　教授
副査:　博士（理学）池辺 淑子 准教授
副査:　博士（工学）立川 智章 准教授

論文提出者　情報工学専攻　郭 豊愷

論文題目　Solving the Posting Poster Problems for Public Office Election Using Heuristic Methods
公職選挙ポスター掲示問題に対する発見的解法に関する研究

日本では，公職選挙における選挙活動の一つに，候補者のポスター掲示がある．ポスターの掲示は通常，各候補者の選挙スタッフが告示日に分担して行う．複数の選挙スタッフが，当該選挙事務所を出発し，担当する全てのポスター掲示場を周り，ポスターを貼り終えた後，選挙事務所に戻ってくる．これは，選挙事務所をデポ，ポスター掲示場を顧客と捉えれば，離散最適化問題と考えることができる．

本論文では，まず公職選挙ポスター掲示問題を離散最適化問題として定式化する．その際，千葉県野田市のポスター掲示場配置を具体例として，これまで，議会議員選挙活動において，実際に使われている経験的なポスター掲示場のグループ化を用いた場合について，ソルバーを用いた厳密解法の解探索性能について議論する．

次に，より良いポスター掲示巡回経路を構築するために，本論文では以下の三つの目的関数を導入した手法を提案する．これらは (1) 総移動距離を最小化する min-sum 型，(2) 移動距離の標準偏差を最小化する min-max 型および (3) 両者の最小化を考慮する二目的関数型である．これらの目的関数とした公職選挙ポスター掲示問題の近似解法も提案し，提案解法の性能と目的関数の違いによる経路長の特徴について調査する．数値実験の結果，発見的解法では短時間的に近似解が求められることを確認した．さらに，min-sum 型目的関数を用いると総移動距離が最小化できること，min-max 型目的関数を用いると移動距離の標準偏差の最小化を実現できることが明らかになった．また，二目的関数を用いる場合，総移動距離と移動距離の標準偏差の関係が明らかになった．

さらに，経験的に採用されているポスター掲示場のグループ化の性能を議論するため，配送計画問題における二つの領域分割法，スイープ法および円形分割スキームを用いて，グルーピングの結果を求めた．領域分割を行なった結果，経験的なグループ分けよりもっと効率的なグルーピング配置が求められた．最後に，選挙事務所の位置を変更し，千葉県野田市の区域内でどこに選挙事務所を設置するのが最適かという問題を考えることにより，より良い選挙事務所の位置を定めることができる．

修士論文要旨

主査: 池口 徹　　教授
副査: 赤倉 貴子　教授
副査: 立川 智章 准教授

論文提出者　情報工学専攻　塚本 陽太

論文題目　Pattern Discrimination Ability of Spatiotemporal Learning Rule and the Effect of Temporal History
時空間学習則のパターン分離能力と時間履歴情報の影響

シナプス可塑性を実現する学習則として Hebb 則が知られている．Hebb 則は，シナプス前ニューロンとシナプス後ニューロンの双方が同時に発火したときにシナプス荷重を増強する．また，スパイクタイミング依存可塑性 (STDP) もシナプス前ニューロンとシナプス後ニューロンの発火時刻の差に基づき長期増強 (LTP) と長期減弱 (LTD) を引き起こす．一方，海馬を用いた生理学実験から，シナプス前ニューロンの集合的な活動およびその時間履歴のみに基づくシナプス可塑性である時空間学習則 (STLR) が提案されている．数値シミュレーションの結果から，Hebb 則は類似した入力パターンを同一視する「パターン統合」に優れ，STLR は微小な差を検出する「パターン分離」に長けていることが知られている．しかし，多くの研究では STDP を含む Hebb 系の学習則のみが対象であり，STLR のモデルに関する研究はまだ乏しい．そこで本論文では，形式ニューロンからなる 1 層のフィードフォワードニューラルネットワークを用いて，LTP および LTD の影響度，学習速度，時間履歴といった要素が STLR によるパターン分離能力とどのような関係があるのかを調査した．

まず，類似パターンを 2 種類の Hebb 系の学習則，STLR，時間履歴を省略した STLR により学習させ，パターン分離能力を比較した．その結果，STLR および時間履歴を省略した STLR は高いパターン分離能力を示した．特に，LTP および LTD の影響度を適切に設定した STLR は極めて高いパターン分離能力を示すことを確認した．また，時間履歴によりパターン分離能力が向上し，かつ学習速度の影響が大きくなることが分かった．入力パターンの類似度とパターン分離能力の関係を調査した結果，STLR は LTP および LTD の影響度に応じた特定の類似度の入力パターンを検出できる可能性が示唆された．

続いて，STLR，時間履歴を省略した STLR による学習時のシナプス荷重分布を調査した．時間履歴を省略した STLR は，高いパターン分離能力を示す場合，分布が多峰性になる傾向が見られた．一方 STLR では，シナプス荷重分布の多峰性とパターン分離能力の間に明確な関係が見られなかった．これらの結果は，STLR におけるシナプス荷重分布には反映されないネットワーク構造の重要性を示唆している．

修士論文要旨

主査: 池口 徹 教授
副査: 赤倉 貴子 教授
副査: 立川 智章 准教授

論文提出者 情報工学専攻 塚本 陽太

論文題目 Pattern Discrimination Ability of Spatiotemporal Learning Rule and the Effect of Temporal History
時空間学習則のパターン分離能力と時間履歴情報の影響

The Hebbian learning rule is a famous learning rule to achieve synaptic plasticity. It strengthens synaptic weights if a presynaptic neuron and a postsynaptic neuron fire simultaneously. Spike-timing dependent plasticity also induces long-term potentiation (LTP) and long-term depression (LTD) depending on the difference of firing time between presynaptic and postsynaptic neurons. On the other hand, spatiotemporal learning rule (STLR), synaptic plasticity reflecting only activity of population of presynaptic neurons and its temporal history, has been proposed based on a physiological experiment of a hippocampus. Numerical experiments have clarified that the Hebbian learning rule excels in pattern completion, to identify an input pattern with a slightly different one, and that STLR excels in pattern discrimination, to detect slight differences. However, most studies consider only variants of the Hebbian learning rules, including STDP, and much remains to be studied about STLR models. Thus, in this thesis, we investigated the relationship between pattern discrimination ability of STLR and factors such as influence of LTP and LTD, learning rate, and temporal history, adopting a single-layered feed-forward neural network consisting of formal neurons.

Firstly, we compared pattern discrimination ability of two variants of the Hebbian learning rules, STLR, and STLR that omits temporal history by applying similar input patterns. As a result, STLRs with and without temporal history showed a high pattern discrimination ability. In particular, STLR with proper parameters proved to have extremely a high pattern discrimination ability. Moreover, temporal history improved pattern discrimination ability and contributed to a great influence of learning rate. Results of experiments on the relationship between similarity of input and pattern discrimination ability implied that STLR could detect a certain similarity of input patterns according to influence of LTP and LTD.

Secondly, we investigated synaptic weight distributions of STLRs with and without temporal history. For STLR omitting temporal history, bimodal and multimodal distribution tended to imply a low and a high pattern discrimination ability, respectively. STLR, on the other hand, did not have a clear relation between multimodality and a high pattern discrimination ability. These results imply the importance of network structures, which are not reflected in weight distribution.

テンポラルネットワークの
非線形ダイナミクスの解析に関する研究

阿部賢一 (池口徹 教授)

1　はじめに

現実世界に存在するネットワークが有する種々の性質について1990年代の終わりから様々な解析が行われている．また，現在では，時間発展に伴ってネットワーク構造が時々刻々と変化するテンポラルネットワークに関する研究も進んでいる．例えば，テンポラルネットワークが有する周期的なパターンの識別方法が提案されている [1]．また，テンポラルネットワークを静的なネットワークへ近似することにより，静的なネットワークへの分析手法により分析できる可能性が示されている [2]．一方，スペクトル距離と階層的クラスタリングより，テンポラルネットワークの状態を推定できることも示されている [3]．さらに，スペクトル距離と古典的多次元尺度法を用いることでコンタクトデータから生成したテンポラルネットワークの非線形ダイナミクス解析も行われている [4–7]．

本論文では，まずカオス的応答を示す1変数の時系列から変換したテンポラルネットワークに対してリカレンスプロットを算出し，再帰定量化解析を適用することで，カオスダイナミクスの検出が可能かを調査した．次に，実際のコンタクトデータをテンポラルネットワークに変換し，再帰定量化解析を適用することでコンタクトデータの有するダイナミクスの特徴を調査した．その結果，調査対象のコンタクトデータには再帰性と決定論性があることが確認できた．

2　テンポラルネットワークと再帰定量化解析

2.1　テンポラルネットワーク

本研究で対象とするテンポラルネットワークでは，時間発展に伴ってネットワーク構造が変化する．離散時刻 t において n 個の頂点を有するネットワークを G_t とする．

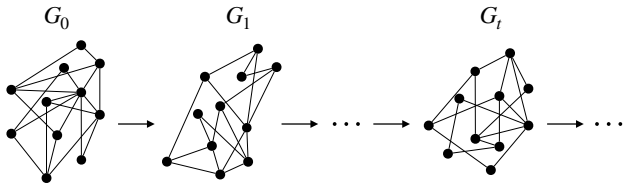


図 1: テンポラルネットワークの例

このとき，テンポラルネットワークは各時刻のネットワーク G_t の集合 $S = \{G_t\}_{t\geq 0}$ で表される．ただし，$G_t = a_{ijt}\,(i, j = 1, 2, ..., n)$ であり，時刻 t において，頂点 i と頂点 j が接続されていれば $a_{ijt} = 1$，そうでなければ $a_{ijt} = 0$ である．

2.2　再帰定量化解析 [8]

2.2.1　リカレンスプロット

リカレンスプロットは時系列データが示す時間発展の特徴を可視化した2次元の二値画像である．時刻 i, j におけるネットワーク G_i, G_j 間の距離を d_{ij}，d_{ij} の最大値を $D_{\max}$，最小値を $D_{\min}$，閾値を ϵ_d とする．このとき，リカレンスプロットの第 (i, j) 番目の画素値 $R(i, j)$ は式 (1) となる．

$$R(i,j) = \begin{cases} 1, & \text{if}\,(\,d_{ij} < \epsilon_d) \\ 0, & \text{otherwise} \end{cases} \tag{1}$$

ただし，$\epsilon_d = D_{\min} + (D_{\max} - D_{\min}) \cdot 2^{\theta}$ とし，θ を変化させることで解析した．

2.2.2　システムの決定論性

リカレンスプロットに対する再帰定量化解析で用いられる尺度の一つに DET(Determinism) がある．DET はリカレンスプロットにおいて，ある長さを有する斜め線が形成される割合を示し，システムの将来の状態が過去の状態と近接するかという特徴 (決定論性の程度) を定量化する．DET が 1 に近ければ，決定論性があるといえる．時系列長を N とすると，長さ l の斜め線のヒストグラム $P(l)$ は式 (2) となる．

$$P(l) = \sum_{i,j=1}^{N} (1 - R(i-1, j-1))(1 - R(i+l, j+l)) \prod_{k=0}^{l-1} R(i+k, j+k) \tag{2}$$

$P(l)$ を用いると，DET は式 (3) により定義される．

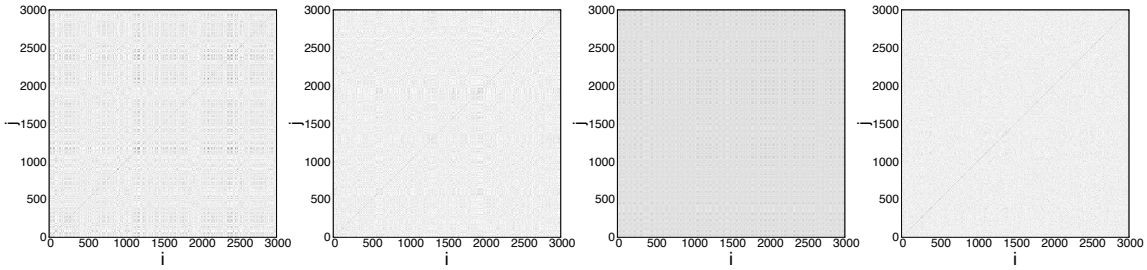
$$\mathrm{DET} = \frac{\sum_{l=l_{\min}}^{N} lP(l)}{\sum_{l=1}^{N} lP(l)} \tag{3}$$

3　解析結果

3.1　カオス時系列をテンポラルネットワークに変換する場合の解析

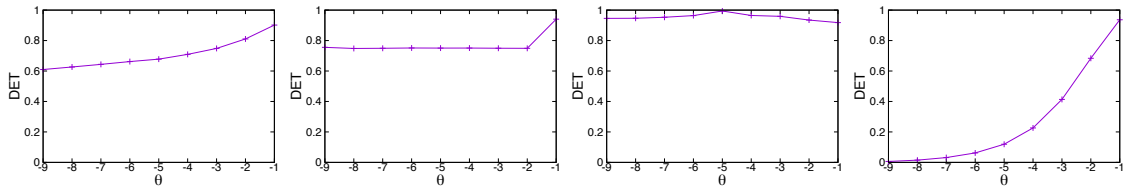
本論文では，初期値が 0.01, 過渡状態が 10,000 ステップのロジスティック写像 [9] の時系列，初期値が 0.001, 過渡状態が 100,000 ステップのベルヌーイシフト写像 [10] の時系列，初期値が 0.3, 過渡状態 10,000 ステップのカオスニューロン [11] の時系列，およびランダム時系列に対して解析を行った．全ての時系列長は 3,000 である．時系列は辞書のトリック [12] と呼ばれる手法により時系列データをテンポラルネットワークに変換する．

変換後のテンポラルネットワークに対して，各時刻間のネットワークに対してハミング距離を用いて距離行列を作成する．この距離行列を閾値 ϵ_d より二値化することで，リカレンスプロットを作成した．その際，$\theta = -9, -8, ..., -1$ とした．また，$l_{\min} = 2$ とした．リカレンスプロットの例を図 2 に，DET の結果を図 3 に示す．



(a)　(b)　(c)　(d)

図 2: $\theta = -5$ とした場合の，(a) ロジスティック写像，(b) ベルヌーイシフト写像，(c) カオスニューロン，(d) ランダム時系列のリカレンスプロット．



(a)　(b)　(c)　(d)

図 3: 閾値のパラメータ θ を変化させたときの，(a) ロジスティック写像，(b) ベルヌーイシフト写像，(c) カオスニューロン，(d) ランダム時系列から作成したリカレンスプロットに対する DET．

図 2 より，ロジスティック写像，ベルヌーイシフト写像，カオスニューロンはランダム時系列と比べて，特徴的なプロットパターンを有している．また，図 3 より，ロジスティック写像，ベルヌーイシフト写像，カオスニューロンの時系列の DET は θ の値に依存せず 1 に近い．これらの結果はカオス的応答を示す時系列から作成したテンポラルネットワークを用いて決定論性が検出できることを示している．

3.2 コンタクトデータの解析

表 1 に示すコンタクトデータ [13] をテンポラルネットワークに変換し，解析を行った．コンタクトデータにはコンタクト時間とその際コンタクトしている人の組み合わせが記録されている．そこで．コンタクトデータを t_w 秒の時間窓に分割し，各時間窓においてコンタクトがある場合は，コンタクトしている人を頂点，コンタクトを枝としてテンポラルネットワークを作成する．

表 1: コンタクトデータの概要

データ	時期（期間）	実験参加者数	総コンタクト数
フランスの小学校	2009 年 10 月（2 日間）	242 人	125,773 回
フランスの高校	2011 年 12 月（4 日間）	126 人	28,561 回
	2012 年 11 月（7 日間）	180 人	45,047 回
フランスの国際会議	2009 年 6 月（2 日間）	403 人	70,261 回
マラウイ共和国の農村	2019 年 12 月 ∼ 2020 年 1 月（14 日間）	86 人	102,293 回

表 1 のコンタクトデータから変換したテンポラルネットワークに対し，式 (1) を用いてリカレンスプロットを作成した．結果を図 4 に示す．また，時間窓幅 t_w を変化させた場合の DET の変化の様子を図 5 に示す．

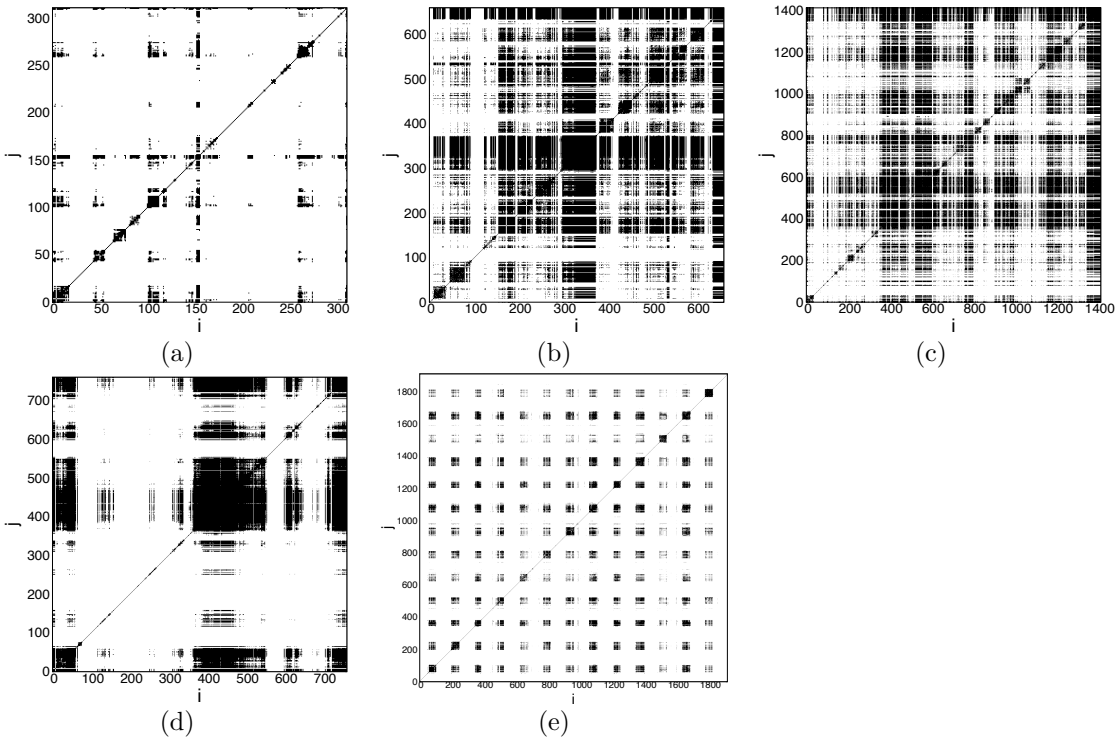


図 4: (a) フランスの小学校 ($t_w = 200, \theta = -2$)，(b) 2011 年のフランスの高校 ($t_w = 200, \theta = -4$)，(c) 2012 年のフランスの高校 ($t_w = 200, \theta = -4$)，(d) フランスの国際会議 ($t_w = 100, \theta = -4$)，(e) マラウイ共和国の農村 ($t_w = 600, \theta = -4$) のリカレンスプロット．

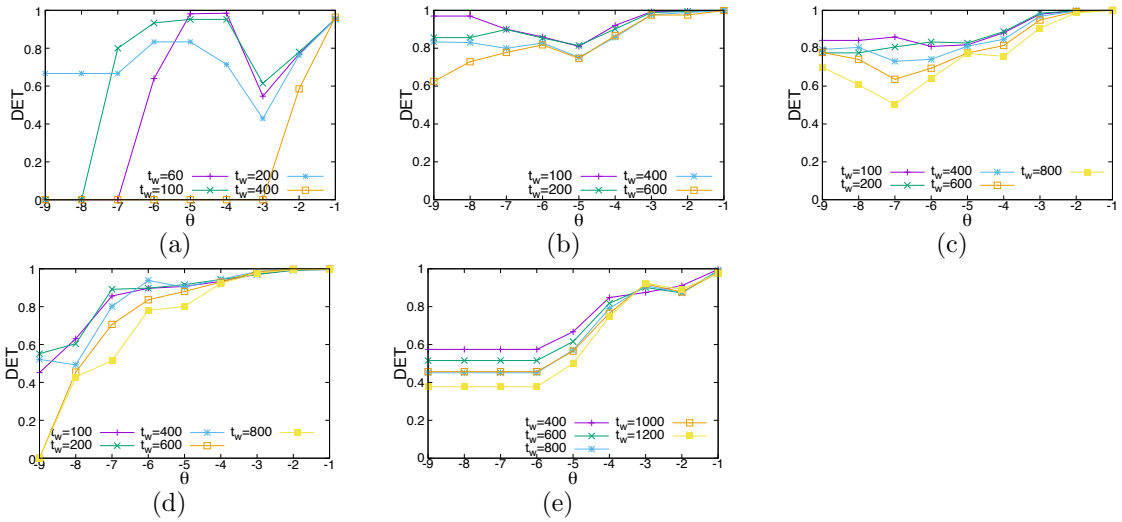


図 5: 時間窓幅 t_w を変化させたときの，(a) フランスの小学校，(b) 2011 年のフランスの高校，(c) 2012 年のフランスの高校，(d) フランスの国際会議，(e) マラウイ共和国の農村の DET.

図 4 より，リカレンスプロットから，コンタクトデータは再帰的な特徴を有することが分かる．また，図 5 より，DET が 1 に近いことが分かる．これらの結果は，表 1 のコンタクトデータが再帰性，決定論性を有することを示すものである．

4　まとめ

本論文では，カオス的応答を示す時系列から変換したテンポラルネットワークに再帰定量化解析を適用することで，カオスダイナミクスの検出が可能であることを確認した．さらに，人間のコンタクトデータを変換することで得られたテンポラルネットワークから作成したリカレンスプロットに対して再帰定量化解析を適用した．その結果，解析対象のコンタクトデータには再帰性と決定論性が存在することが明らかになった．

参考文献

[1] M. Lahiri and T. Y. Berger-Wolf, “Mining periodic behavior in dynamic social networks,” *Proc. of IEEE International Conference on Data Mining*, pp. 373–382, 2008.

[2] H. H. K. Lentz, T. Selhorst and I. M. Sokolov, “Unfolding accessibility provides a macroscopic approach to temporal networks,” *Phys. Rev. Lett.*, Vol. 110, No. 11, p. 118701, 2013.

[3] N. Masuda and P. Holme, “Detecting sequences of system states in temporal networks,” *Sci. Rep.*, Vol. 9, No. 40, p. 795, 2019.

[4] 伊藤大河, 澤田和弥, 對馬帆南, 池口徹, “スペクトル距離を用いたテンポラルネットワークの非線形ダイナミクスの解析,” 電気情報通信学会 技術研究報告, Vol. 122, No. 145, pp. 55–71, CCS2022–39, 2022.

[5] 伊藤大河, 澤田和弥, 對馬帆南, 池口徹, “スペクトルグラフ距離と古典的多次元尺度構成法を用いたテンポラルネットワークの解析,” 2022 年度電気情報通信学会ソサイエティ大会, N–1–18, 2022.

[6] 澤田 和弥，池口 徹，“テンポラルネットワークの時間発展ダイナミクス,” 2022 年電子情報通信学会ソサイエティ大会, B–15, 2022.

[7] K. Sawada and T. Ikeguchi, “Nonlinear dynamics of temporal networks,” 2024 Dynamics Days US, 32, 2024.

[8] 池口徹，山田泰司，小室元政，合原一幸編，カオス時系列解析の基礎と応用，産業図書株式会社，2000.

[9] R. May, “Simple mathematical models with very complicated dynamics,” *Nature*, Vol. 261, No. 5560, pp. 459–467, 1976.

[10] M. Goda, at el., “A new class of disordered systems a modified bernoulli system with long-range structural correlation,” *J. Phys. Soc. Jpn.*, Vol. 60, No. 7, pp. 2295–2304, 1991.

[11] K. Aihara, T. Takabe and M. Toyoda, “Chaotic neural networks,” *Phys. Lett. A*, Vol. 144, No. 6, pp. 333–340, 1990.

[12] A. Caliguri, at el., “Lyapunov exponents for temporal networks,” *Phys. Rev. E*, Vol. 107, Iss. 4, p. 044305, 2023.

[13] Sociopatterns: `http://www.sociopatterns.org/`（最終閲覧日 2023/12/28）

セルオートマトンを用いた交通モデルによる交通信号最適化に関する研究

新井慎之介 (池口徹 教授)

1 はじめに

クルマ社会と呼ばれる現代において，道路交通は日常に欠かせないものとなっている．渋滞による経済損失は年間 12 兆円，時間損失は 1 人あたり年間 30 時間にもなる重要な問題である [1]．渋滞の緩和策として，道路の拡張や新設などが挙げられるが，実際に行うには膨大な費用と時間がかかり容易に試すことはできない．したがって，どのようにすれば渋滞の発生を防止できるのか，あるいは発生した渋滞を解消できるかを交通流をモデル化することで明らかにすることが望まれている．

交通流をモデル化する手法の一つとして，Cellular Automata[2](以下，CA) の理論を用いる手法が 1990 年代に発表されている [3]．このような CA を用いたモデルの一つに Nagel-Schreckenberg モデルがある．このモデルでは，1 車線の道路において 4 つのルールを適用して高速道路での交通流を再現している．

一方，近年は現実世界のシステムやプロセスをモデル化するために使用される，Agent Based Model (ABM) と CA を組み合わせたモデルも提案されている [4]．ABM におけるエージェントとは，周囲の状況に合わせて判断や行動を自律的に行うオブジェクトのことである．文献 [4] では，車両，道路，交差点をエージェントとしてみなしている．

CA は空間上に格子状のセルを多数配置し，近傍のセルの状態を基に自身の状態も変化させることで次の状態を決定する．CA は，単純な状態変化のルールからでも複雑な状態を生み出すことが可能であり，交通を単純化しつつ複雑な現象を再現できるため交通流のモデル化と相性が良い．道路をセルに分割し，車両の有無でセルの状態値を変化させることで CA を交通のモデル化に適用することができる．

交通信号が一巡するまでの時間のことをサイクル長というが，日本におけるサイクル長は海外先進国と比べて長いことが知られている．本論文では，CA と ABM を組み合わせたモデルの 1 つである Multi-agent based cellular automata model (MABCA モデル)[4] を用いて，短いサイクル長と長いサイクル長どちらが交通を最適化するか調査した．様々なサイクル長に対して，3 種類の流量を設定し実験を行った．評価指標として，目的地までの移動時間と平均速度を求めることでサイクル長の性能評価をした．その結果，短いサイクル長が交通を最適化する結果を得た．

2 Multi-agent based cellular automata model[4]

2.1 道路エージェント

道路エージェントは，道路状況を保持し，道路状況に応じて車両を流入させる．車両の流入確率は式 (1) で表される．

$$P(\chi) = \frac{(\lambda t)^{\chi} e^{-\lambda t}}{\chi!} \tag{1}$$

ここで，t は時間間隔を表し，$P(\chi)$ は時間間隔 t 内に流入する車両の数が χ である確率，λt は時間間隔 t 内に流入する車両の台数を表す．

2.2 車両エージェント

道路上を走行する車両を表し，車両の速度，行き先などの情報を保持する．また，他の車両エージェントの情報をもとに加減速，車線変更を行う．加減速には前方車両との距離を考慮を

する車両追従ルールを用いている．前方の車両を考慮することで，現実の交通で発生する前方車両の速度によってドライバーが加減速をする現象などを再現することができる．また，車線変更は行き先の情報をもとに 3 つの種類に分類される．1 種類目は速度を上げるための車線変更，2 種類目は交差点から遠く離れている位置にいる車両が，確率的に行う車線変更，3 種類目は交差点や停止している車両に近づいたために強制的な車線変更である．

2.3　交差点エージェント

交差点エージェントは，時間，道路の混雑状況によって信号を制御することで，交差点の交通を管理する．図 1 には交差点エージェントの持つ情報を示した．左から，車両の位置，速度，行き先の情報を表す．

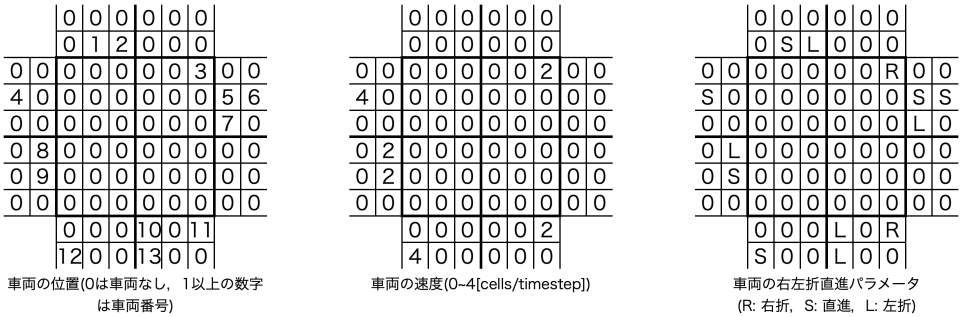


図 1: 交差点エージェントの概要図

2.4　道路状況

MABCA モデルで使用している道路を図 2 に示す．0~19 番の 20 本の道路と I_1, I_2, I_3 の 3 つの交差点で構成されている．道路は 3×150 のセルに，交差点は 6×6 の正方形のセルに分割されている．また，1 セルは実際の距離で 4m の長さに相当する．3, 4, 8, 10, 12, 15, 17, 19 番の道路からは車両が流入し，0, 7, 9, 11, 13, 16, 18 番の道路からは車両が外に流出する．

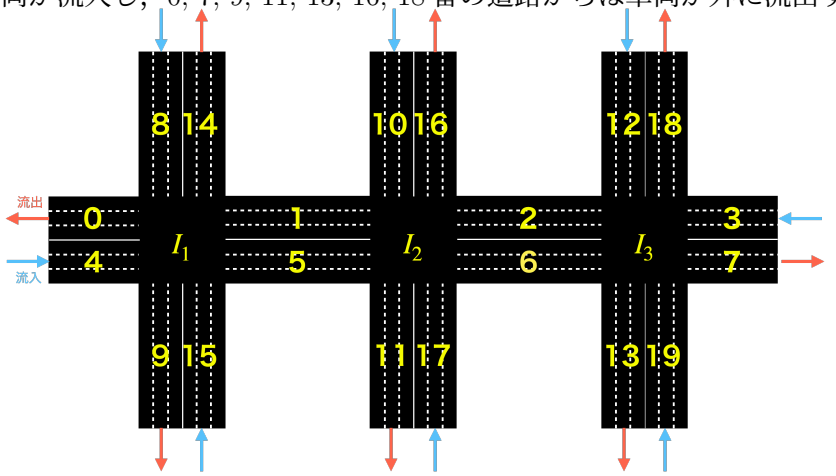


図 2: シミュレーションで用いる道路

2.5　信号制御

MABCA モデルでは，図 3 に示す 4 つのフェーズにより交差点の交通を制御している．フェーズとは青信号のパターンのことである．フェーズ 1 からフェーズ 4 まで順に実行し，その後フェーズ 1 に戻る．それぞれのフェーズの間には全ての信号を赤にする全赤信号時間が 3 秒割り当てられている．また，フェーズ 1 から再度フェーズ 1 に戻るまでの時間をサイクル長と呼ぶ．それぞれのフェーズの時間を $p_i (i = 1, 2, 3, 4)$ とすると，サイクル長 C は $C = p_1 + p_2 + p_3 + p_4 + 12$

となる．文献 [4] では各フェーズの時間を $p_1 = 37$ 秒，$p_2 = 25$ 秒，$p_3 = 15$ 秒，$p_4 = 21$ 秒として交差点の交通を制御している．

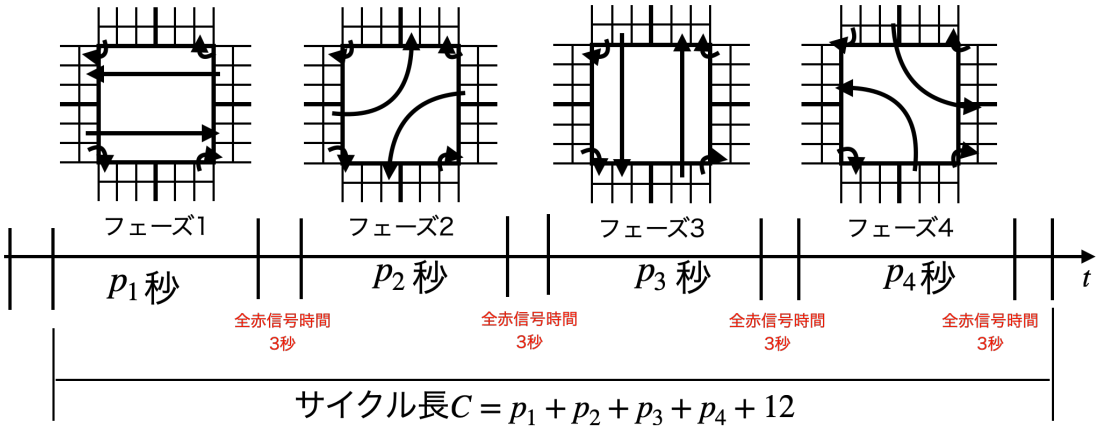


図 3: 4 つのフェーズ

3　サイクル長の性能評価

3.1　サイクル長

サイクルの長さによって，交通流が変化するか調査し交通を最適化するサイクル長を求める．図 3 の $p_i (i = 1, 2, 3, 4)$ を $k (0.1 \leq k \leq 1.7)$ 倍することでサイクル長を変化させたときの平均速度と移動時間を計算する．

表 1: サイクル長の設定

	p_1	p_2	p_3	p_4	C
MABCA モデル	37	25	15	21	110
サイクル長を変更	$37 \times k$	$25 \times k$	$15 \times k$	$21 \times k$	$23 \leq C \leq 180$

3.2　流入量

図 2 に示す道路に車両を流入させて実験を行う．文献 [4] では，表 2 に示すように車両を流入させている．本研究では，この流入量を 0.19 倍，1.0 倍 (文献 [4] と同じ流入量)，5.40 倍とした 3 種類の流入量に対して実験を行う．

表 2: 流入させる車両台数 (E: East, S: South, W: West, N: North)

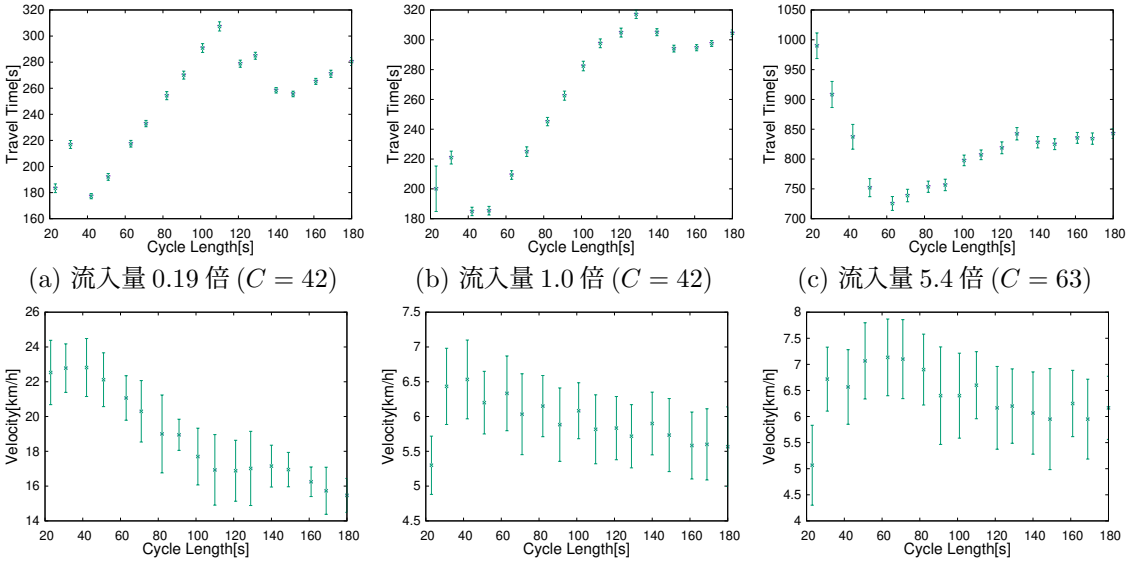
道路に発生する車両の情報			I_1				I_2				I_3			
			E	S	W	N	E	S	W	N	E	S	W	N
0-3000 タイムステップ	流入量 (台数)	直進		144	216	144		144		144	180	144		144
		左折		144	216	144		144		144	180	144		144
		右折		144	216	144		144		144	180	144		144

3.3　評価指標

交通流を解析する指標として，移動時間と平均速度を用いる．本研究での移動時間とは経路 $(4 - I_1 - 5 - I_2 - 6 - I_3 - 7)$ を移動するのにかかる時間とする．また，平均速度とは道路上にいる車両速度の平均の値のことである．

3.4　実験結果

各サイクル長に対し，様々な流量で移動時間と平均速度を計測した結果を図 4 に示す．図 4(a)∼(b) は移動時間の結果であり，図 4(d)∼(f) は平均速度の結果である．



(a) 流入量 0.19 倍 ($C = 42$)　(b) 流入量 1.0 倍 ($C = 42$)　(c) 流入量 5.4 倍 ($C = 63$)

(d) 流入量 0.19 倍 ($C = 42$)　(e) 流入量 1.0 倍 ($C = 42$)　(f) 流入量 5.4 倍 ($C = 63$)

図 4: 異なるサイクル長に対して流入量を変更し移動時間と平均速度を計算した結果 (括弧の中は移動時間が最短，平均速度が最大となるときのサイクル長)

図 4 から，流入量が 0.19 倍，1.0 倍の場合，移動時間が最短，平均速度が最大となるのはサイクル長 42 秒のときである．また，流入量が 5.40 倍の場合はサイクル長 63 秒のときであることがわかった．このことから，流入量が低い高いに関わらず，サイクル長が短いときが交通をうまく制御し移動時間と平均速度を最適化すると考えられる．

4　まとめと今後の課題

本研究では，CA と ABM を組み合わせた Multi-agent based cellular automata model を実装し，サイクル長と流入量を変化させ，サイクル長の大きさによって交通流に変化があるか調査を行った．その結果，流入量に関わらず短いサイクル長は交通を最適化することがわかった．

今後はこのシミュレータに新たな道路の設置，歩行者の追加などエージェントを増やすなど現実の交通をより忠実に再現し，交通の解析を行う予定である．

参考文献

[1] 国土交通省 効果的な渋滞対策の推進, `https://www.mlit.go.jp/road/ir/ir-perform/h18/07.pdf`(最終閲覧日: 2024 年 1 月 16 日)

[2] S. Wolfram, “A new kind of science,” *Wolfram Media Champign*, Vol. 5, 2002.

[3] K. Nagel and M. Schreckenberg,“A cellular automaton model for freeway traffic,” *Journal de Physique I*, Vol. 2, No. 12, pp. 2221–2229, 1992.

[4] W. Jinghui, L. Wei, J. Yajuan, Q. Shuangshuang, and L. Jiawei, “A multi-agent based cellular automata model for intersection traffic control simulation,” *Physica A: Statistical Mechanics and its Applications*, Vol. 584, 126356, 2021.

アルファ近接度を用いたカオスダイナミクスによる TSP の解法

市川健太 (池口徹 教授)

1 はじめに

巡回セールスマン問題 (Traveling Salesman Problem，以下 TSP) とは，都市の集合と各都市間の移動コストが与えられたとき，全ての都市をちょうど一度ずつ訪問し，出発した都市に戻る巡回経路のうち，総移動コストが最小の巡回経路を求める組合せ最適化問題である．計算量理論的に TSP は $\mathcal{NP}$ 困難に属する．そのため，求めた解の最適性が保証される厳密解法だけでなく，短時間で優れた近似解を求める近似解法などの研究も盛んに行われている．

TSP に対する様々な近似解法の中で，多くの問題で最適解を求めることができる近似解法として，Lin-Kernighan-Helsgaun 法 (以下 LKH 法)[1] が注目されている．LKH 法は，巡回経路上の k 個の枝を交換する k-opt 交換 ($2 \leq k \leq 5$) を適応的に用いる近似解法である．解を改善する際，任意の都市に対して追加する枝候補 (以下，候補セット) をアルファ近接度により算出することで，計算時間の大幅な短縮を行っている．

一方，カオスダイナミクスを用いることで良好な解を効率的に探索できることが報告されている [2, 3]．文献 [2] では，2-opt 法とカオスダイナミクスを融合した手法の性能が解析されている．文献 [3] では，組合せ最適化問題の解法として有効とされているタブーサーチをカオスニューロンモデルにより実現し，探索のダイナミクスをカオスへと拡張することでタブーサーチより効果的な解法を実現している．

本論文では都市間の距離とアルファ近接度により作成した候補セットを，カオスサーチ [2, 3] に適用した新しい解法を提案する．その際 TSPLIB[4] のベンチマーク問題を解くことで，カオスサーチにおけるアルファ近接度の有効性を数値実験によって検証した．

2 提案手法

本論文での解法は，候補セットの作成・更新，初期巡回経路を出力する構築法，与えられた巡回経路を元により短い巡回経路を探索し出力するカオスサーチの 3 つに分けられる．構築法とカオスサーチにより局所最適解を求める過程を 100 回繰り返し，最良の局所最適解が見つかるたびに候補セットを更新することで，より良い解の探索を行う．用いる解法のフローチャートを図 1 に示す．

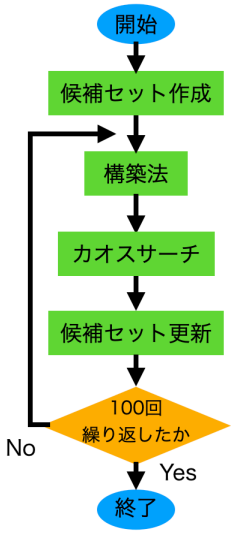


図 1: 提案手法のフローチャート

2.1 候補セット

任意の都市 i, j に対し，都市 i と j を結ぶ枝を $e(i, j)$ とし，$e(i, j)$ の長さを $d(i, j)$ とする．任意の都市 i に対して二番目に近い都市との距離を $b(i)$ としたとき，全ての i に対して，最も $b(i)$ が大きい都市を l とする．例えば，図 2 のように都市の座標が与えられた場合，$i = 1$ としたとき $b(1) = d(1, 11)$，$i = 2$ としたとき $b(2) = d(2, 4)$ である．また，$b(i)$ が最大である都市は都市 1 であるため，$l = 1$ となる．全域木に都市 l からの枝を 1 本追加することで，サイクルを作り巡回経路に近づけたグラフを 1-tree という．ここで，図 2 のように，1-tree を構成する枝のコストの総和が最小となる 1-tree を最小 1-tree という．都市 l と都市 l から二番目に近い都市との枝は最小全域木に含まれないため，最小 1-tree は最小全域木にその枝を加えたグラフとなる．このとき，枝 $e(i, j)$ に対するアルファ近接度 $\alpha(i, j)$ は，最小 1-tree のグラフ T を枝 $e(i, j)$ 含む 1-tree $T^{+}(i, j)$ に変化させる過程で増加するコストである．例えば，図 2 におい

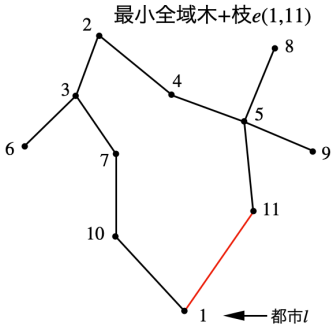
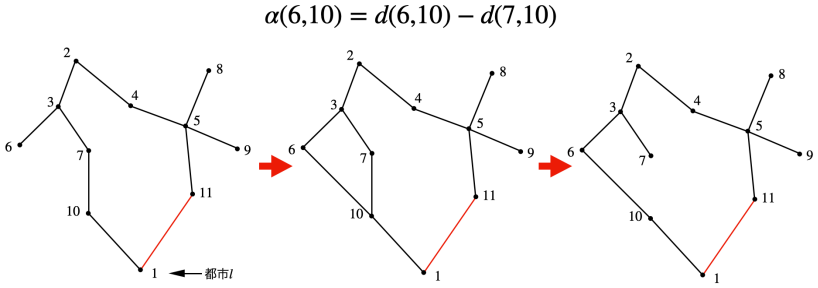


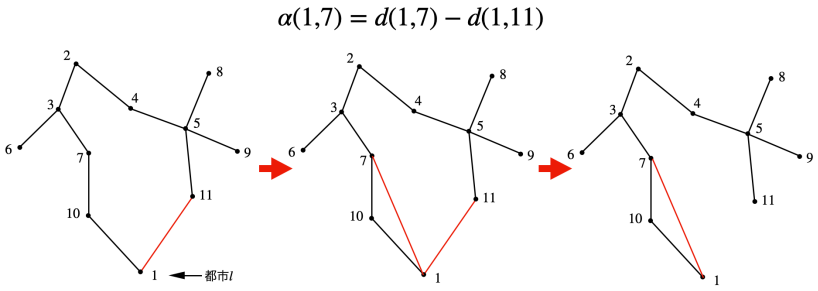
図 2: 最小 1-tree

て，$\alpha(6,10), \alpha(1,7)$ を求める過程は図 3(a),(b) で示される．

枝 $e(i,j)$ が T に含まれている場合，$T^+(i,j)$ は T と等しくなるため，$\alpha(i,j)=0$ となる．都市 i,j のいずれも l と異なり，枝 $e(i,j)$ が T に含まれていない場合 (図 3(a))，$T^+(i,j)$ は T に枝 $e(i,j)$ を追加し，T 上に新たにできるサイクル上の枝のうち枝 $e(i,j)$ 以外の最長の枝を削除することにより得られる．したがって，$\alpha(i,j)$ は $d(i,j)$ から削除する枝の長さを引いた値となる．一方，都市 i,j のいずれかが l であり，枝 $e(i,j)$ が T に含まれていない場合 (図 3(b))，$T^+(i,j)$ は T に枝 $e(i,j)$ を追加し，都市 l から伸びる枝のうち枝 $e(i,j)$ 以外の最長の枝を削除することにより得られる．したがって，$\alpha(i,j)$ は $d(i,j)$ から削除する枝の長さを引いた値となる．



(a) 枝 $e(6,10)$ のアルファ近接度の算出手順



(b) 枝 $e(1,7)$ のアルファ近接度の算出手順

図 3: アルファ近接度の算出手順

アルファ近接度は巡回経路の総移動距離の短縮を考慮しているが，最小 1-tree をさらに巡回経路に近づけた後アルファ近接度を求めれば，より優れた尺度になる [1]．また，巡回経路とは全ての都市の次数が 2 である 1-tree である．そこで，より多くの都市の次数が 2 となるよう部分勾配最適化を行う．この部分勾配最適化とは，各都市に対してペナルティを設定した最小 1-tree を構築し，次数が 2 より高い都市はペナルティーを大きく，次数が 2 より低い都市はペナルティーを小さくし，それぞれの都市から伸びる枝の長さにそのペナルティーを加えるという過程を繰り返すことで，ペナルティーの値を調整していく．全ての都市における次数が 2 となる，もしくはペナルティーの更新度が 0 となった場合，部分勾配最適化を終了する．その後，得られた最小 1-tree を元に，全ての 2 都市間のアルファ近接度を求める．部分勾配最適化の手順を以下に示す．

(1) ステップ数 $m=0$ とする．また，m ステップ目の更新度を $t_\pi(m)$，都市 i におけるペナルティー $\pi_i(m)$ を i 番目の要素にもつ n 次の行ベクトルを $\boldsymbol{\pi}(k)$ と定義し，$t_\pi(0)=1$，$\boldsymbol{\pi}(0)=\boldsymbol{0}$ とする．
(2) 任意の都市 i,j について，$c(i,j)=d(i,j)+\pi_i(m)+\pi_j(m)$ と定義する．
(3) $c(i,j)$ を第 (i,j) 成分にもつ $n\times n$ 行列 $\boldsymbol{C}$ を元に最小 1-tree $\boldsymbol{T}(m)$ を構築する．
(4) $\boldsymbol{T}(m)$ の次数の行列を $\boldsymbol{k}(m)$ とし，$0\le i\le n$ について，$v_i(m)=k_i(m)-2$ とする．
(5) $t_\pi(m)$ を決定する．
(6) $\boldsymbol{v}(m)=\boldsymbol{0}$ または $t_\pi(m)=0$ であれば，終了する．
(7) $\boldsymbol{\pi}(m+1)=\boldsymbol{\pi}(m)+t_\pi(m)(0.7\boldsymbol{v}(m)+0.3\boldsymbol{v}(m-1))$ とする．ただし，$\boldsymbol{v}(-1)=\boldsymbol{v}(0)$ とする．
(8) $m=m+1$ とし，手順 (2) に戻る．

距離で候補セットを作成する場合は，全ての都市 i において距離 $d(i,j)$ が最も短い 5 つの枝が候補セットとなる．一方，アルファ近接度で候補セットを作成する場合は，全ての都市 i においてアルファ近接度 $\alpha(i,j)$ が最も短い 5 つの枝が候補セットとなる．また，カオスサーチ終了後，得られた巡回経路長がそれまでの最適巡回経路長よりも短い場合，得られた巡回経路とそれまでの最適巡回経路に共通する枝を候補セットに加えることで候補セットの更新を行う．

2.2 構築法

構築法は LKH 法 [1] で用いられている構築法を用いる．構築法の手順を以下に示す．

(1) 巡回経路の出発地点としてランダムに都市 i を選択する．

(2) 次に向かう都市として，以下の (a)∼(c) の条件を満たす未訪問の都市からランダムに都市 j を選択する．

(a) $e(i,j)$ が候補セットの枝である．

(b) (アルファ近接度で候補セットを作成した場合のみ)$\alpha(i,j)=0$ である．

(c) 2 回目以降の繰り返しにおいて，$e(i,j)$ が現在の最適巡回経路に属する．

上記の (a)∼(c) を満たす都市がなければ，(a) のみを満たし，かつ未訪問の都市からランダムに都市 j を選択する．それでも条件を満たす都市がなければ，未訪問の都市からランダムに都市 j を選択する．

(3) $i=j$ とし，未訪問の都市があれば，手順 (2) に戻る．

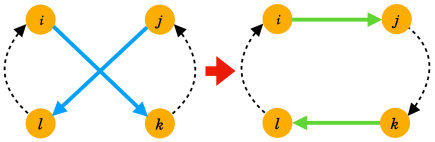


図 4: 2-opt の操作例

2.3 カオスサーチ

用いる解法はカオスサーチであり，2-opt 法に基づく局所探索を行う．2-opt 法の操作例を図 4 に示す．現在の解を D_0，D_0 に対して都市 i,j を対象とした 2-opt 交換を実行した場合の実行可能解の巡回経路を D_{ij} としたとき，図 4 のように都市 i,j に対し 2-opt 交換を行った際の巡回経路長の差分 Δ_{ij} を $D_0 - Dij$ とする．カオスダイナミクスによる探索法において，各ニューロンは外部入力 (式 (1))，発火率制御 (式 (2))，不応性 (式 (3)) に関する三種類の内部状態をもつ．これらは以下の式で定義される．ただし，t は更新のステップ数とし，式 (1) で j の候補となる都市は全ての都市ではなく，都市 i の候補セットに含まれる枝のもう一方の都市 j とする．

$$\xi_i(t+1) = \max_j\{\zeta_j(t+1)+\beta(t)(\Delta_{ij}(t)-F_r(t))\} \tag{1}$$

$$\eta_i(t+1) = -W(t)\sum_{k=1,k\neq i}^{n} x_k(t)+W(t) \tag{2}$$

$$\zeta_i(t+1) = k_r\zeta_i(t)-\gamma x_i(t)+R \tag{3}$$

この時，ニューロン i の出力 $x_i(t)$ は式 (4) で定義される．$x_i(t+1)>\frac{1}{2}$ の場合，式 (1) により選ばれた都市 i と都市 j により 2-opt を用いて枝が結ばれる．

$$x_i(t+1) = f\{\xi_i(t+1)+\eta_i(t+1)+\zeta_i(t+1)\} \tag{4}$$

Δ_{ij} の平均値 $\bar{\Delta}(t)$ の制御を行うパラメータ $F_r(t)$ は，発火したニューロン数が $n/8$ より小さい場合は，発火率を高くするため $F_r(t+1)=F_r(t)+(\bar{\Delta}(t)-F_r(t))C$ とする．そうでない場合，$F_r(t+1)=(1-C)F_r(t)$ とする．Δ_{ij} の分散の制御を行うパラメータ $\beta(t)$ は，$\beta(t+1)=\beta(t)+(B/S_R(t)-\beta(t))C$ のように定義される．ここで，$S_R(t)$ は Δ_{ij} の標準偏差である．$W(t)$ は適切な接続効果を得るため，$W(t+1)=W(t)+C(W_BS_R(t)\beta(t)-W(t))$ のように定義される．

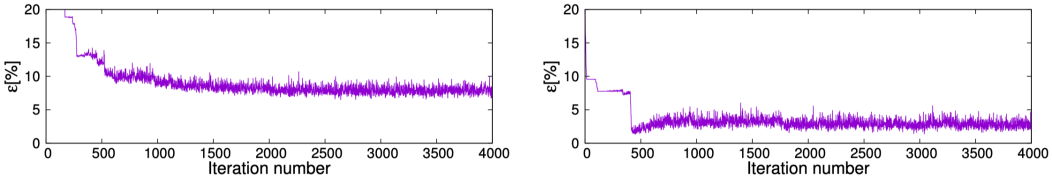
本論文では，各パラメータの値は $F_r(0)=0,\beta(0)=0.15,W(0)=0.15,k_r=0.95,\gamma=1,R=0.15,C=0.01,B=1,W_B=2.2\times10^{-5}$ とした．また，イタレーション数は 4,000 とする．

3 実験結果

本稿では，TSPLIB[4] のインスタンスのうち，都市間の距離が対称である ($d(i,j)=d(j,i)$) インスタンス 111 問を用いた．また，候補セットを距離で作成した場合とアルファ近接度で作成した場合で，カ

オスサーチを用いて求めた解と既知最適解との誤差率の比較を行った．ここで，誤差率 ϵ[%] は，求められた巡回経路長を M，既知最適解を T とすると，$\epsilon = \frac{M-T}{T} \times 100$ で定義される．

インスタンス lin318 に対し提案解法を適用した際の誤差率の推移の様子を図 5 に示す．また，提案解法を適用することで求めた局所最適解の誤差率の平均 [%] を，候補セットの更新を行う場合と行わない場合，かつ候補セットを距離で作成した場合とアルファ近接度で作成した場合で比較した結果の一部を表 1 に示す．都市数 1,000 未満のインスタンスは 100 回実行した平均，都市数 1,000 以上のインスタンスは 10 回実行した平均である．



(a) 距離　　(b) アルファ近接度

図 5: lin318 における誤差率の推移

表 1: TSPLIB のベンチマーク問題で得られた誤差率 [%]

インスタンス	都市数	誤差率 [%](候補セット更新なし)		誤差率 [%](候補セット更新あり)	
		距離	アルファ近接度	距離	アルファ近接度
burma14	14	0.000	0.000	0.000	0.000
kroA100	100	1.192	0.595	0.101	0.014
lin105	105	0.687	0.078	0.000	0.000
kroA200	200	2.302	1.262	0.309	0.288
lin318	318	4.188	1.419	1.105	0.734
pcb1173	1173	6.218	4.480	2.741	2.628
pr2392	2392	20.061	11.283	4.765	1.473

表 1 から全てのインスタンスにおいて，アルファ近接度で候補セットを作成した場合の誤差率が小さくなっていることが分かる．したがって，巡回経路を構築・改善する際の尺度として，アルファ近接度は距離より優れていることが分かる．また，候補セットの更新を行うことにより，距離，アルファ近接度共に誤差率が小さくなっており，候補セットの更新は有効であることも分かる．

4　まとめと今後の課題

本論文では，TSP に対して，2 都市間距離ではなくアルファ近接度 [1] を導入した場合のカオスサーチの性能について評価した．その結果，距離と比べてアルファ近接度は巡回経路を構築するのにより有効であることが示された．今後の課題として，都市数の多いインスタンスにおける適切なパラメータの調査を行うことなどが考えられる．

参考文献

[1] Keld Helsgaun, “An effective implementation of the Lin–Kernighan traveling salesman heuristic,” *European Journal of Operational Research*, Vol. 126, No. 1, pp. 106–130, 2000.

[2] Mikio Hasegawa, Tohru Ikeguchi and Kazuyuki Aihara, “Solving large scale traveling salesman problems by chaotic neurodynamics,” *Neural Networks*, Vol. 15, No. 2, pp. 271–283, 2002.

[3] Mikio Hasegawa, Tohru Ikeguchi and Kazuyuki Aihara, “Exponential and chaotic neurodynamical tabu searches for quadratic assignment problems,” *Control and Cybernetics*, Vol. 29, No. 3, pp. 773–788, 2000.

[4] Reinelt Gerhard, “TSPLIB,” *ORSA Journal on Computing*, Vol. 3, No. 4, pp. 376–384, 1991.

てんかん患者の脳波データに対する再帰定量化解析

関口真音 (池口徹 教授)

1 はじめに

林ら [1]，合原ら [2] により単一ニューロンがカオス応答を示すことが明らかにされている．また，ニューロンの集合的な活動を観測した脳波データもカオス的応答を示す可能性が示唆されている [3]．特に，てんかんなどの疾患における脳波がカオス性を有すること [4]，および，強度が異なることも明らかにされている [5]．てんかんは，神経細胞の異常な興奮が原因で痙攣などの発作を反復する慢性の中枢神経疾患である．てんかん患者には発作時の脳波だけでなく，発作間欠時の脳波にも特有の所見が見られる．そのため，非発作時と発作時の脳波データに対する解析が行われている [6]．

本論文では，健常者の脳波データ，てんかん患者の発作時および非発作時の脳波データに対して非線形力学系理論に基づく時系列解析を適用する．そのためには，計測された 1 変数の脳波データから高次元空間における力学系のアトラクタを再構成する必要がある．そこで本論文では，脳波データを時間遅延座標系へ変換し，アトラクタを再構成した．観測時系列から再構成状態空間への変換では，遅れ時間の大きさと再構成状態空間の次元という 2 つのパラメータを適切に決定する必要がある．本論文では，非線形性を有するデータに対して有効とされている相互情報量による遅れ時間の設定を採用し [7]，再構成次元の設定には，Cao の手法を導入した [8]．

また，再構成したアトラクタに対する解析手法として，リカレンスプロット (Recurrence Plot，以下 RP) [9] を用いた．RP は，アトラクタ上の 2 点間距離の関係を 2 値画像として可視化し，ダイナミクスを定性的に調査する方法である．RP から力学系の特徴量を抽出することを再帰定量化解析 (Recurrence Quantification Analysis，以下 RQA) [10] も提案されている．RQA 指標の一つに決定論性の評価指標である Determinism (DET) がある．DET はデータが有する決定論性を評価することができる．本論文では，時間遅延座標系の適切なパラメータを推定してアトラクタを再構成し，DET により疾患と脳波の特徴の関係を調査した．

2 解析手法

2.1 アトラクタ再構成

脳波データに非線形力学系理論に基づく時系列解析法を適用するため，脳波データを時間遅れ座標系に変換する．具体的には，時系列長 n の脳波データ x_t $(t = 1, \cdots, n)$ を，再構成次元 m，遅れ時間 τ として，式 (1) により再構成ベクトル $\boldsymbol{v}_t(\tau, m)$ に変換する．

$$\boldsymbol{v}_t(\tau, m) = (x_t, x_{t+\tau}, \cdots, x_{t+(m-1)\tau}) \ \ (t = 1, 2, \cdots, n - (m-1)\tau) \tag{1}$$

式 (1) の時間遅延座標系を用いる場合，遅れ時間 τ と再構成次元 m を適切に設定する必要がある．本論文では，遅れ時間 τ を相互情報量により決定した．観測された脳波データと，遅れ時間 τ の時間遅延データから相互情報量 $I(\tau)$ を算出し，$I(\tau)$ が極小値をとる最小の τ を適切な遅れ時間 τ_0 とした [7]．また，再構成次元の推定に Cao の手法 [8] を用いた．この手法では，遅れ時間が与えられた座標系と，元の座標系の近傍の変化を測ることで，最小埋め込み次元の推定が行われる．

2.2 再帰定量化解析

RP は，アトラクタの構造的特性を可視化する解析手法である．式 (1) で生成した m 次元再構成アトラクタ上の 2 点間距離 $d^m_{i,j}$ は，$d^m_{i,j} = |\boldsymbol{v}_i(\tau, m) - \boldsymbol{v}_j(\tau, m)|$ で定義される．また，RP の第 (i, j)

の画素値 $P_{i,j}$ は，閾値を θ_r として式 (2) により決定される．

$$P_{i,j} = \begin{cases} 1 & (\text{if } d^m_{i,j} \leq \theta_r) \\ 0 & (\text{otherwise}) \end{cases} \tag{2}$$

なお，本論文では，2 点間距離の最大値 $d^m_{\max}$ の $10^r (r < 0)$ 倍として θ_r を定義し，r を変化させることで解析を行った．閾値 θ_r を変化させてリカレンスプロット上にプロットされる点の割合 (リカレンスレート) を $R(\theta_r)$ という．本論文では，再帰定量化解析により，RP から脳波データの決定論性の評価を行った．DET は，RP 上に打たれた点の総数に対して，45 度の傾きの斜め線を構成する点の割合として定義される．RP 上の長さ l の斜め線の数を $S(l)$ として，決定論性指標 D は式 (3) で定義できる．

$$D = \frac{\sum_{l=l_{\min}}^{N-1} lS(l)}{\sum_{l=1}^{N-1} lS(l)} \tag{3}$$

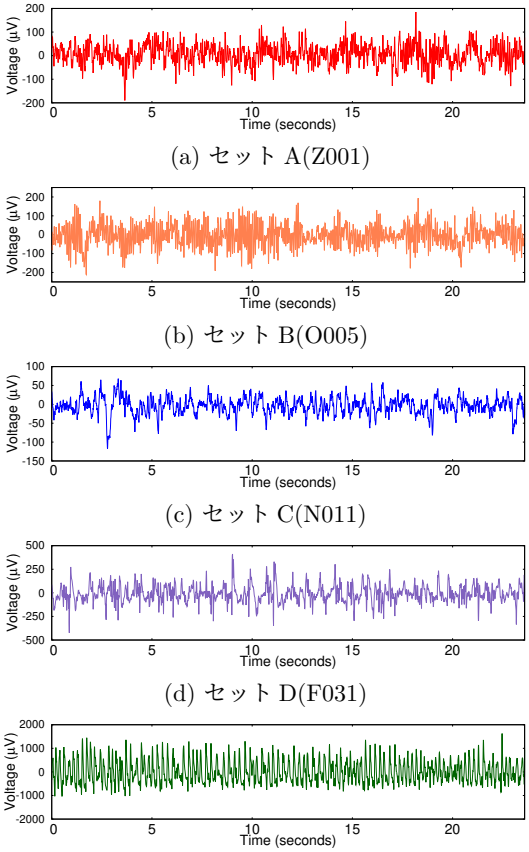
ここで，$N = n - (m-1)\tau$ である．また，$l_{\min}$ は斜め線の最小の長さを表し，本論文では $l_{\min} = 2$ とする．

3 脳波データ

本論文で使用したデータは，ドイツのボン大学てんかんセンターがオンラインで公開している健常者とてんかん患者の脳波データである [11]．このデータセットにおけるてんかん患者は，側頭葉てんかんと診断されている．データは表 1 に示す，5 つのセットからなる．図 1 に脳波データの例を示す．図 1 で示す Z001，O005，N011，F031，S028 はデータの番号である．各セットには，100 名のデータが含まれている．また，一つの脳波データは，173.61Hz で 23.6 秒間観測された $n = 4,097$ のデータである．

表 1: 脳波データ

A	健常	開眼状態
B		閉眼状態
C	てんかん	間欠時 (原生領域の反対半球)
D		間欠時 (原生領域の半球)
E		発作時



(a) セット A(Z001)

(b) セット B(O005)

(c) セット C(N011)

(d) セット D(F031)

(e) セット E(S028)

図 1: 脳波データの例

4 解析結果

4.1 遅れ時間と再構成次元の推定

各セット 100 人のデータから算出した，遅れ時間の平均と標準偏差を表 2 に示す．また，推定される最小埋め込み次元を表 3 に示す．

表 2 より，非発作時のてんかん患者の遅れ時間の平均は，健常者よりも大きい．また，てんかん患者の標準偏差の値は，健常者の標準誤差の値と比べて大きい．この結果は，てんかん患者の脳波

表 2: 遅れ時間の平均と標準偏差

セット	健常者		てんかん患者		
	A	B	C	D	E
平均	9.08	5.07	20.55	19.38	10.28
標準偏差	2.94	1.12	6.29	9.64	6.93

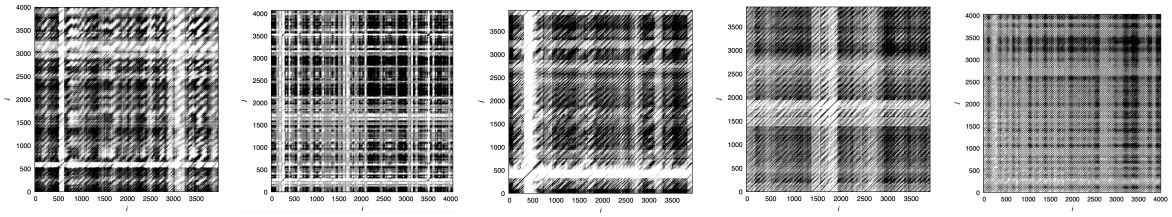
表 3: 最小埋め込み次元の平均と標準偏差

セット	健常者		てんかん患者		
	A	B	C	D	E
平均	9.29	8.87	8.77	8.5	8.82
標準偏差	2.74	2.86	1.64	2.42	3.9

データは個人差が大きいことを示唆するものである．また，開眼時の健常者と発作中のてんかん患者では，遅れ時間の平均値がほぼ一致していることが分かる．さらに，非発作時のてんかん患者 (セット C，セット D) の遅れ時間に注目すると，遅れ時間の平均値の間には有意差はなく，てんかんの原性領域か否かは遅れ時間に大きな影響を与えないと考えられる．表3において，Cao の手法から推定された最小埋め込み次元は，セット間で違いがないことがわかる．そのため，てんかん患者の脳波データは，再構成次元への影響が小さいと考える．

4.2 リカレンスプロットと決定論性評価

リカレンスレート $R = 0.5$ のときの，リカレンスプロットを図2に示す．ここでは，遅れ時間を相互情報量，再構成次元を Cao の手法に基づいて決定し，アトラクタを再構成した．



(a) セット A (Z001) (b) セット B (O005) (c) セット C (N011) (d) セット D (F031) (e) セット E (S028)

図 2: 脳波データの RP

図3に，RP の閾値と DET の関係を示す．図3より，全ての閾値で，てんかん患者 (セット C，セット D，セット E) の決定論性指標 D は，健常者 (セット A，セット B) より大きくなる．これより，てんかん患者は健常者よりも決定論性が強いことが示唆される．

経験的に RP の閾値として扱われるリカレンスレート $R = 0.1$ であるときの決定論性指標 D の結果を表4に示す．表4より，全てのセットで D が 1 に近く，脳波データが決定論的であることが示唆された．

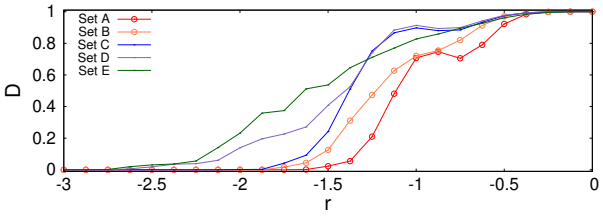


図 3: 閾値を変化させた決定論性指標 D の推移

表 4: R=0.4 の決定論性指標 D

セット	健常者		てんかん患者		
	A	B	C	D	E
D	0.99	0.99	0.98	0.99	0.98

5 まとめ

本論文では，健常者とてんかん患者の脳波データに対して，時間遅延座標系の遅れ時間と再構成次元の推定を行い，アトラクタを再構成した．さらに，RP に対する再帰定量化解析を行い，決定論性を評価した．まず，相互情報量に基づく遅れ時間の推定結果から，健常者と発作中のてんかん患者の脳波データでは，算出された遅れ時間がほぼ同じ値となり，類似した性質を有することが明ら

かになった．一方，てんかん患者の非発作時と発作中の脳波データの遅れ時間は，異なる値となることもわかった．次に，再構成次元の推定結果から，健常者とてんかん患者の間に僅かな差があることを確認した．さらに，RP から決定論性指標を算出し，脳波データの決定論性を調査した．その結果，てんかん患者の脳波データの決定論性の強さは，健常者の脳波データよりも強いことが明らかになった．

参考文献

[1] H. Hayashi *et al.*, "Chaotic behavior in the onchidium giant neuron under sinusoidal stimulation," *Physics Letters A*, Vol. 88, No. 8, pp. 435–438, 1982.

[2] K. Aihara *et al.*, "Structures of attractors in periodically forced neural oscillators," *Physics Letters A*, Vol. 116, No. 7, pp. 313–317, 1986.

[3] T. Ikeguchi *et al.*, "An analysis on Lyapunov spectrum of electroencephalographic (EEG) potentials," *IEICE TRANSACTIONS (1976-1990)*, Vol. 73, No. 6, pp. 842–847, 1990.

[4] A. Babloyantz and A. Destexhe, "Low-dimensional chaos in an instance of epilepsy," *Proceedings of the National Academy of Sciences*, Vol. 83, No. 10, pp. 3513–3517, 1986.

[5] K. Schindler *et al.*, "Forbidden ordinal patterns of periictal intracranial EEG indicate deterministic dynamics in human epileptic seizures," *Epilepsia*, Vol. 52, No. 10, pp. 1771–1780, 2011.

[6] H. Adeli *et al.*, "A wavelet-chaos methodology for analys is of EEGs and EEG subbands to detect seizure and epilepsy," *IEEE Transactions on Biomedical Engineering*, Vol. 54, No. 2, pp. 205–211, 2007.

[7] A. M. Fraser, "Reconstructing attractors from scalar time series: A comparison of singular system and redundancy criteria," *Physica D: Nonlinear Phenomena*, Vol. 3, No. 3, pp. 391–404, 1989.

[8] L. Cao, "Practical method for determining the minimum embedding dimension of a scalar time series," *Physica D: Nonlinear Phenomena*, Vol. 110, Nos. 1–2, pp. 43–50, 1997.

[9] J. -P. Eckmann *et al.*, "Recurrence plot of dynamical systems," *World Scientific Series on Nonlinear Science Series A*, Vol. 16, pp. 441–446, 1995.

[10] N. Marwan *et al.*, "Recurrence plots for the analysis of complex systems," *Physics Reports*, Vol. 438, No. 5–6, pp. 237–329, 2007.

[11] R. G. Andrzejak *et al.*, "Indications of nonlinear deterministic and finite-dimensional structures in time series of brain electrical activity: Dependence on recording region and brain state," *Physical Review E*, Vol. 64, No. 6, 061907, 2001.

発表文献

[P1] 関口 真音, 池口 徹, てんかん患者の脳波データに対する再帰定量化解析, 電子情報通信学会技術研究報告, Vol. 123, No. 287, pp. 21–26, NLP2023-64, 2023.

[P2] M. Sekiguchi and T. Ikeguchi, "Determinisity of electroencephalogtaphic(EEG) potentials of epileptic seizure," FY2023 RIEC Annual Meeting on Cooperative Research Projects, Feb. 2024, 発表予定.

擬似乱数生成器の統計的性能評価に関する研究

山口 倖之介 (池口徹 教授)

1　はじめに

乱数には，物理乱数と擬似乱数の 2 種類存在する．物理乱数とは，物理現象を用いた手法によって生成された乱数であり．例えば，半導体レーザにて発生するカオス的レーザー出力揺らぎや雑音であるダイオードノイズなどが挙げられる．物理乱数には，予測が難しく再現性が困難であるという特徴がある．一方，擬似乱数とは，数値計算を元に作成される乱数であり，擬似乱数は物理乱数に対して，再現性が高いという特徴がある．

擬似乱数の中には，ランダム性が低く，値が偏りやすい，あるいは規則性がある擬似乱数も存在する．例えば，線形合同法による乱数である．線形合同法の擬似乱数では，求めた擬似乱数を順に三次元空間でプロットをすると規則性のある形になることが知られている．このように乱数に統計的偏りがあると，数値シミュレーションなどを行う際，得られる結果が不正確となることがあるため非常に危険である．

そこで本論文では，様々な疑似乱数生成器から乱数を生成し，どの擬似乱数生成器が良好な性能を表すのかを，乱数生成時間と共に調査をした．なお，擬似乱数の性能調査には NIST 検定 [1] を用いた．

2　NIST 検定

NIST 検定は，米国国立標準技術研究所 (NIST) で開発された検定方法であり，$0, 1$ からなる 2 値乱数から得られた任意の数列に対し，数列がランダム性の高さを統計的に評価するものである [1]．NIST 検定には以下の 15 項目の検定項目がある．

検定項目は，1. 等頻度検定，2. ブロック単位の等頻度検定検定，3. 連検定，4. ブロック単位の最長連検定，5. 累積和検定，6. 2 値行列ランク検定，7. DFT 検定，8. 重なりのないテンプレート適合検定，9. 重なりのあるテンプレート適合検定，10. ユニバーサル統計量検定，11. 近似エントロピー検定，12. ランダム回遊検定，13. ランダム回遊変量検定，14. 系列検定，15. 線形複雑度検定である．

3　擬似乱数の検定

本論文では，以下の六つの擬似乱数を調査対象とした．

1. 整数ロジスティック写像 [2] は，ロジスティック写像 $x_{t+1} = ax_t(1-x_t)$ を $X_{t+1} = \lfloor aX_t(10^N - X_t) \times 10^{-N} \rfloor$ に変換し，小数点以下を切り捨てした値を求めるものである．ただし，N は，変換における精度である．

2. メルセンヌツイスタ [3] は，疑似乱数生成器が生成する乱数列が同じパターンで繰り返されるまでの長さが $2^{19937} - 1$ であり，高性能高速擬似乱数生成法である．

3. srand は，C 言語に組み込まれている関数である．srand は実際に乱数を出力する関数ではなく，srand で初期値を生成し，rand 関数でその初期値を用いて乱数を出力する．rand は C 言語に組み込まれている関数である．rand 関数では線形合同法が用いられ，周期は 2^{32} である．

4. ran1[4] は，線形合同法に基づいて作成された関数であり，周期は 10^8 である．

5. ran2[4] は，線形合同法に基づいて作成された ran1 を改良したもので周期は 2.3×10^{23} ある．浮動小数点数の精度の限界を突破すれば「完全」な乱数と言われる特徴を持つ．

6. ran3[4] は，減算法に基づいて作成されたものであり，整数の精度が 16 ビット程度のとき，引数の型や値を変更することによって浮動小数点たけで計算することができる．

本実験では，まず擬似乱数生成器から $n = 10^9$ 個の乱数列 $\epsilon = \{\epsilon_1, \epsilon_2, \cdots \epsilon_n\}$ を生成する．次に，これをビット長が 10^6 ビットの部分乱数列に分割し，NIST 検定を 10^3 回行う (図 1)．検定後出力される検定量がそれぞれの分布において偏った統計量である場合は不合格，そうでない場合は合格とし，検定回数に対する合格数を算出した．

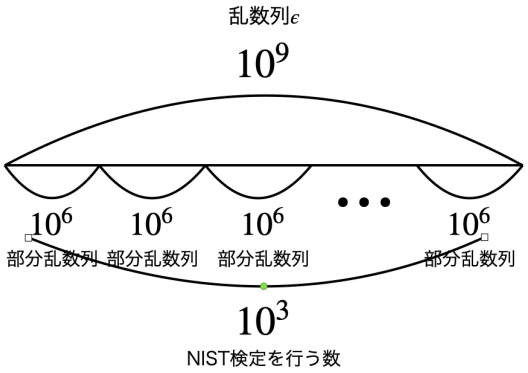


図 1: 擬似乱数列の分割方法

また，擬似乱数生成器に対して排他的論理和演算 (XOR) を行い，排他的論理和演算を行う場合と行わない場合で NIST 検定の合格数に差があるのかという実験も行った．排他的論理和演算では擬似乱数生成器に二つの初期値を与え，得られた二つの系列 ϵ_1，ϵ_2 の各要素に XOR を用いて得た乱数列 ϵ に対し NIST 検定を行う．排他的論理和演算の計算方法を図 2 に示す．排他的論理和演算を行うことで，0 と 1 の個数を半分の値に近づけることができ，また，乱数列に含まれるパターン，周期性が打ち消されることが期待される．

数値実験において，整数ロジスティック写像の数値計算精度 N の値は 20 とする [2]．$N \geq 20$ の場合，整数ロジスティック写像に安定的に合格するからである．

各擬似乱数生成器から擬似乱数を出力し，中央値を閾値として，$\epsilon_t <$ 中央値の場合は 1，それ以外を 0 とした．



図 2: XOR の計算

4 実験結果

4.1 擬似乱数生成器の比較

各擬似乱数における合格数を比較した結果を表 1 に示す．

表 1 の結果からメルセンヌツイスタと ran2 にの合格数の平均値が最も高いことがわかる．一方，標準偏差に着目するとメルセンヌツイスタの方が値が小さいことから，ran2 と比べてメルセンヌツイスタの方が安定的に高い検定結果を出している．また，時間の観点からでは，整数

表 1: 擬似乱数生成器の NIST 検定の合格数の比較

擬似乱数生成器	平均値	標準偏差	最大値	最小値	中央値	時間 [s]
整数ロジスティック写像	13.7	0.458	15	5	12	0.017
メルセンヌツイスタ	14.8	0.433	15	14	15	5.16
ran1	14.7	0.458	15	14	15	7.01
ran2	14.8	0.4	15	14	15	15.29
ran3	14.75	3.024	15	1	15	5.07
rand	13	0	13	13	13	7.86
srand	14.65	0.4	15	13	15	7.88

ロジスティック写像が最も早く乱数を生成し，合格数の最大値が 15 であることから実際の乱数生成に適した生成器の一つであると考えられる．

4.2 排他的論理和演算 (XOR)

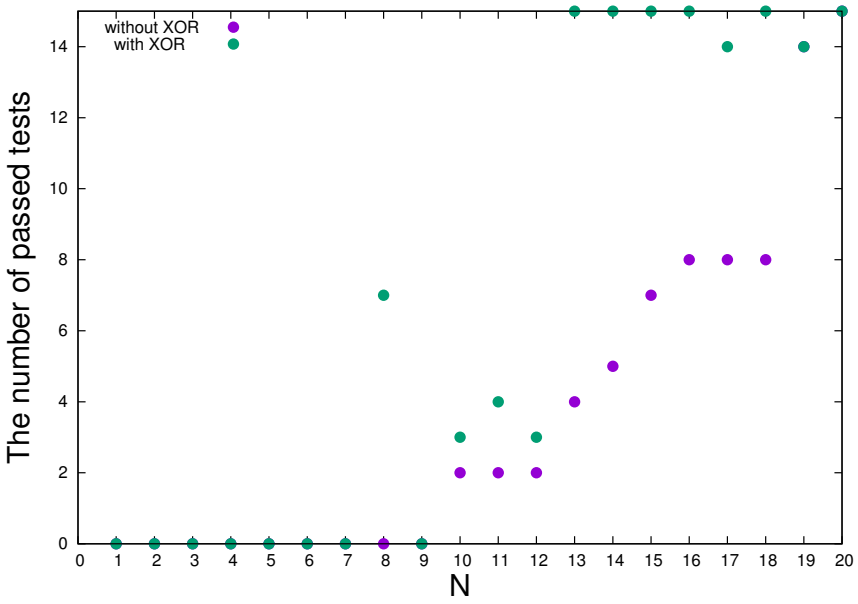


図 3: XOR をした前と後での数値計算精度 N の違いによる NIST 検定の結果

図 3 は整数ロジスティック写像に対して，XOR を適用した場合と適用しない場合の数値計算精度 N の違いによる最大合格数の変化の図である．図 3 より，XOR を適用しない場合，$N = 9$ までは最大合格数が 0 であるのに対し，XOR を適用した場合では，$N = 7$ までが最大合格数が 0 であった．また，15 個全ての項目に合格した N に関しては，XOR を適用しない場合，$N = 20$ のときに 15 個全てに合格したが，XOR を適用した場合では，$N = 13$ のときに 15 個全てに対して合格した．これらの結果により，XOR 処理を行うことで NIST 検定に合格しやすくなるということがわかる．

表 2 は六つの擬似乱数生成器に対して XOR 処理をした結果である．合格数の平均値が低いものもあるが，中央値を見るとほとんどが合格数が 15 になっている．中央値が 15 で平均値が

表 2: XOR 処理を行った擬似乱数生成器の NIST 検定の合格数の比較

擬似乱数生成器	平均値	標準偏差	最大値	最小値	中央値	時間 [s]
整数ロジスティック写像	13.6	3.226	15	0	14	0.0242
メルセンヌツイスタ	14.5	0.626	15	13	15	10.2198
ran1	14.3	2.494	15	5	15	8.6584
ran2	14.4	1.293	15	10	15	31.3441
ran3	14.1	1.454	15	9	14	10.2318
srand	14.75	0.433	15	14	15	15.8313

低い理由として，合格数がとても低い場合が存在したと考えられる．一方，計算時間の観点から見ると整数ロジスティック写像は短い計算時間となり，他の擬似乱数生成器の約 $\frac{1}{2}$ の時間である．表 1，2 の結果から考えると，ランダム性が低い場合で XOR 処理は擬似乱数の性能向上に寄与すると考えられる．

5　まとめ

本論文では，整数ロジスティック写像，メルセンヌツイスタ，ran1，ran2，ran3，srand を用いて生成した 10^9 個の擬似乱数に対して NIST 検定を行い，性能の比較を行った．NIST 検定の結果，メルセンヌツイスタが最も高いランダム性を有するが，乱数を早く生成するという点では整数ロジスティック写像が良いことが分かった．XOR を行った場合では，平均値は少し下がる場合もあるが，検定項目全てに合格した個数は増加したものもあった．また，合格数が小さい結果はほとんどないことから XOR 処理を行うことで，ランダム性が低い擬似乱数はより安定した結果を得ることができると考えられる．

参考文献

[1] A. Rukhin, J. Soto, J. Nechvatal, M. Smid, and E. Barker, “A statistical test suite for random and pseudorandom number generators for cryptographic applications,” *Booz-allen and hamilton inc mclean va*, Vol 22, 2001.

[2] S. Kanamaru, Y. Shimada, K. Fujiwara, and T. Ikeguchi, “Performance evaluation of chaotic random numbers generated from responses of integer logistic maps,” *Nonlinear Theory and Its Applications*, IEICE, Vol. 12, No. 3, pp. 489–499, 2021.

[3] 松本眞, “擬似乱数ユーザーの方へ-Mersenne Twister 法開発者より (⟨ 特集 ⟩ 統計科学における乱数),” 日本統計学会誌, Vol. 35, No. 2, pp. 165–180, 2006.

[4] W. H. Press, S. A. Teukolsky, W. T. Vetterling, and B. P. Flannery, 丹慶勝市, 奥村晴彦, 佐藤俊郎, 小林誠訳, “Numerical recipes in C[日本語版]C 言語による数値計算レシピ,“ 技術評論社, 1992.

拡張時空間学習則のパターン分離能力の解析

山本陽翔 (池口徹 教授)

1　はじめに

脳は1000億個のニューロンから構成されている．ニューロンは他のニューロンとシナプスを通じて繋がっており，ニューロンが電気信号を発すること (以下，発火という) により情報を伝達している．発火に応じてシナプス荷重を増強させることで信号を伝達しやすくする長期増強とシナプス荷重を減弱させることで信号を伝達しにくくする長期減弱により学習が行われる．学習により，類似した入力パターンの差異を識別するパターン分離という能力が働く．

ヘブ則 [1] は，入力ニューロンと出力ニューロンが同時に発火するときにシナプス荷重を増加させる学習則である．ヘブ±則 [2] は，シナプス荷重の増加と減少の両者を考慮するようにヘブ則を拡張した学習則である．また，海馬の生理学実験に基づいて提案された学習則として時空間学習則 [2] があり，パターン分離能力を持つことが知られている．時空間学習則は，ヘブ則と異なり，入力ニューロンの同時発火性とその時間履歴によって学習を行う．また，拡張時空間学習則 [3] は，逆行性伝達物質仮説 [4] に基づいてニューロンのシナプス前終末が活性化しているときだけでなく，活性化していないときも同時に学習するように時空間学習則を拡張した学習則である．拡張時空間学習則は，入力ニューロンがどれだけ同時に発火するかに加え，どれだけ同時に発火しないかによっても学習を行い，高いパターン分離能力が期待されている．しかし，拡張時空間学習則がどれほどのパターン分離能力を有するかは未だ明らかにされていない．

そこで本論文では，入力パターンのハミング距離を変化させて学習したときのパターン分離能力を調べることで拡張時空間学習則のパターン分離能力を評価する．その際，ヘブ則，ヘブ±則，時空間学習則のパターン分離能力を比較することで，各学習則が入力パターンの違いをどのように識別できるかも調査した．さらに，学習済みネットワークの重みを入れ替えたときのパターン分離能力を調べることで，学習則のパターン分離能力の頑健性を調査した．

2　ニューラルネットワークと学習則

2.1　ニューラルネットワーク構造

本論文で用いた一層フィードフォワードニューラルネットワーク図1に示す [5]．このニューラルネットワークの構造では，入力ニューロン j (= 1, 2, ..., N) と出力ニューロン i (= 1, 2, ..., N) がシナプス荷重 w_{ij} で全結合している．ニューロン j からの入力を x_j, ニューロン i の出力を y_i として，$x_j, y_i = 0$ は発火なし，$x_j, y_i = 1$ は発火ありを表す．

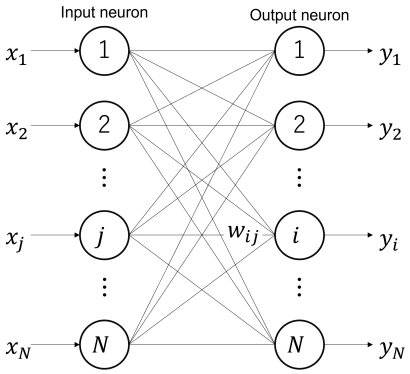


図 1: ネットワーク構造

時刻 t_k $(k = 1, 2, \cdots)$ における入力ベクトル $\boldsymbol{X}(t_k) = (x_1(t_k), x_2(t_k), \cdots, x_j(t_k), \cdots, x_N(t_k))^T$ とシナプス荷重ベクトル $\boldsymbol{W}_i(t_k) = (w_{i1}(t_k), w_{i2}(t_k), \cdots, w_{ij}(t_k), \cdots, w_{iN}(t_k))$ を用いて，時刻 t_k における出力ニューロン i の内部状態 $s_i(t_k)$ と出力 $y_i(t_k)$ は，式 (1)，式 (2) で表される．

$$s_i(t_k) = \sum_{j=1}^{N} w_{ij}(t_k) x_j(t_k) = \boldsymbol{W}_i(t_k)\boldsymbol{X}(t_k) \tag{1}$$

$$y_i(t_k) = F(s_i(t_k) - \eta) \tag{2}$$

ここで，η は発火の閾値であり，F はステップ関数である．

2.2 学習則

ヘブ則においてシナプス荷重の更新式は，α を学習率とすると式 (3) で表される [1]．

$$w_{ij}(t_{k+1}) = w_{ij}(t_k) + \alpha \cdot y_i(t_k) \cdot x_j(t_k) \tag{3}$$

ヘブ±則は，ヘブ則を拡張した学習則であり，シナプス荷重の増加と減少の両者を考慮している [2]．ヘブ±則においてシナプス荷重の更新式は，式 (4) で表される．

$$w_{ij}(t_{k+1}) = \begin{cases} w_{ij}(t_k) + \alpha, & \text{if}(x_j(t_k) = 1, y_i(t_k) = 1) \\ w_{ij}(t_k), & \text{if}(x_j(t_k) = 0, y_i(t_k) = 0) \\ w_{ij}(t_k) - \alpha, & \text{otherwise} \end{cases} \tag{4}$$

時空間学習則は，生理学実験に基づいて提案された学習則である [2]．時空間学習則は，入力ニューロンの空間一致性とその時間履歴に基づいてシナプス荷重を変化させる．空間一致性 $I_{ij}(t_k)$ は，時刻 t_k において，入力ニューロン j の発火が出力ニューロン i に届いたときに，他の入力ニューロンがどれほど同時に発火しているかを表しており，式 (5) で表される．

$$I_{ij}(t_k) \;=\; w_{ij}(t_k) \cdot x_j(t_k) \cdot \left\{ \sum_{q=1, q\neq j}^{N} w_{iq}(t_k) \cdot x_q(t_k) \right\} \tag{5}$$

空間一致性 $I_{ij}(t_m)$ の時間履歴 $J_{ij}(t_k)$ は，式 (6) で表される [2]．

$$J_{ij}(t_k) = \sum_{m=0}^{k} I_{ij}(t_m) \exp\left(-\frac{t_k - t_m}{\lambda} \right) \tag{6}$$

ここで，λ はダイナミクスの時定数であり，本論文では $\lambda = 223$ とする [6]．また，シナプス荷重の変化は式 (7) で表される．

$$w_{ij}(t_{k+1}) = \begin{cases} w_{ij}(t_k) + \alpha, & \text{if}(J_{ij}(t_k) \geq \theta_1) \\ w_{ij}(t_k), & \text{if}(\theta_1 > J_{ij}(t_k) > \theta_2) \\ w_{ij}(t_k) - \alpha, & \text{if}(\theta_2 \geq J_{ij}(t_k)) \end{cases} \tag{7}$$

ここで，θ_1, θ_2 はそれぞれシナプス荷重の長期増強と長期抑制の閾値である．り，α は学習率である．

拡張時空間学習則は，時空間学習則の拡張手法であり，逆行性伝達物質仮説 [4] に基づいて提案された．この仮説は，ニューロンが入力ベクトル $\boldsymbol{X}$ (シナプス前終末が活性化しているとき) だけでなく，$x_j^\dagger = 1 - x_j$ として，x_j の 0 と 1 を反転させた共役ベクトル $\boldsymbol{X}^\dagger = (x_1^\dagger, x_2^\dagger, \cdots, x_j^\dagger, \cdots, x_N^\dagger)^T$ (シナプス前終末が活性化していないとき) も同時に学習することを意味する．共役ベクトル $\boldsymbol{X}^\dagger$ の空間一致性 $I_{ij}^\dagger(t_k)$ は，式 (8) で表される．

$$I_{ij}^\dagger(t_k) \;=\; w_{ij}(t_k) \cdot x_j^\dagger(t_k) \cdot \left\{ \sum_{q=1, q\neq j}^{N} w_{iq}(t_k) \cdot x_q^\dagger(t_k) \right\} \tag{8}$$

式 (5) と同様に，空間一致性 $I_{ij}^\dagger(t_m)$ の時間履歴 $J_{ij}^\dagger(t_k)$ は，式 (9) で表される．

$$J_{ij}^\dagger(t_k) = \sum_{m=0}^{k} I_{ij}^\dagger(t_m) \exp\left(-\frac{t_k - t_m}{\lambda} \right) \tag{9}$$

ここで，シナプス荷重の変化は式 (10) または式 (11) で表される．

$$w_{ij}(t_{k+1}) = \begin{cases} w_{ij}(t_k) + \alpha, & \text{if}(J_{ij}(t_k) \geq \theta_1) \\ w_{ij}(t_k), & \text{if}(J_{ij}(t_k) < \theta_1) \end{cases} \tag{10}$$

$$w_{ij}(t_{k+1}) = \begin{cases} w_{ij}(t_k) - \alpha, & \text{if}(J_{ij}^\dagger(t_k) \geq \theta_2^\dagger) \\ w_{ij}(t_k), & \text{if}(J_{ij}^\dagger(t_k) < \theta_2^\dagger) \end{cases} \tag{11}$$

ここで，$J_{ij}(t_k) \geq \theta_1$ と $J^{\dagger}_{ij}(t_k) \geq \theta^{\dagger}_2$ を同時に満たす場合，$w_{ij}(t_{k+1}) = w_{ij}(t_k)$ とする．また，θ_1, $\theta^{\dagger}_2$ はそれぞれシナプス荷重の長期増強と長期減弱の閾値である．

3 実験

本論文では，ハミング距離 (HD) が等しい 5 つの空間パターン $\{A_1, A_2, A_3, A_4, A_5\}$ を用意する．これらの空間パターンは 0 と 1 のビット数がともに 60 ビット，$N = 120$ ビットのパターンである．5 つの空間パターンを並び替えた $5! = 120$ 通りの時空間パターン S_l $(l = 1, 2, \cdots, 120)$ をそれぞれ同じ初期状態のネットワークに入力して学習した．最後に，学習したネットワークに対して空間パターンの一つ A_5 を再度入力したときに得られる 120 個の出力パターン P_l $(l = 1, 2, \cdots, 120)$ を取得した．

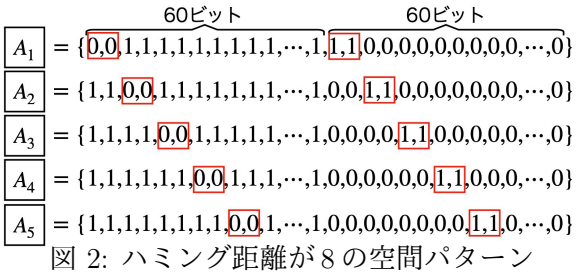


図 2: ハミング距離が 8 の空間パターン

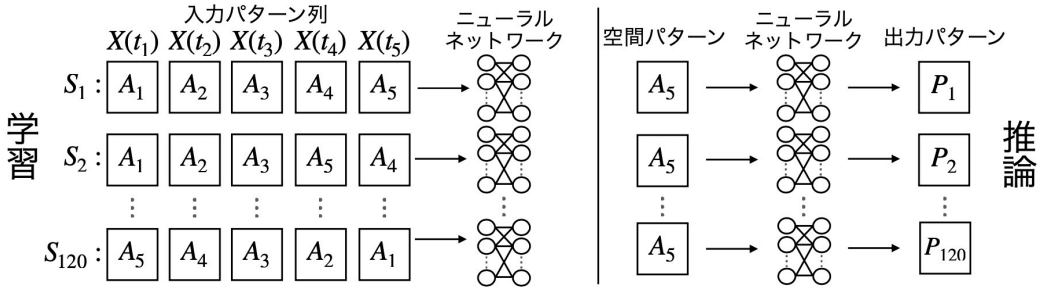


図 3: 時空間パターンの学習と推論

3.1 時空間パターンのハミング距離を変化させた際のパターン分離能力

ニューラルネットワークに対して，空間パターン間のハミング距離を変えて，120 通りの時空間パターンを学習したときの出力パターン P_l $(l = 1, 2, \cdots, 120)$ の異なる出力パターン数 C により，パターン分離能力とした．

各学習則の出力パターン数を図 4 に示す．図 4 より，ヘブ則はどの学習率，ハミング距離においても出力パターン数 C が小さい．ヘブ ± 則は学習率が低く，ハミング距離が大きいときに出力パターン数 C が大きい．時空間学習則，拡張時空間学習則は，どのハミング距離でも出力パターン数が大きいパラメータが存在し，適切なパラメータを設定することでパターン分離能力が高くなる．

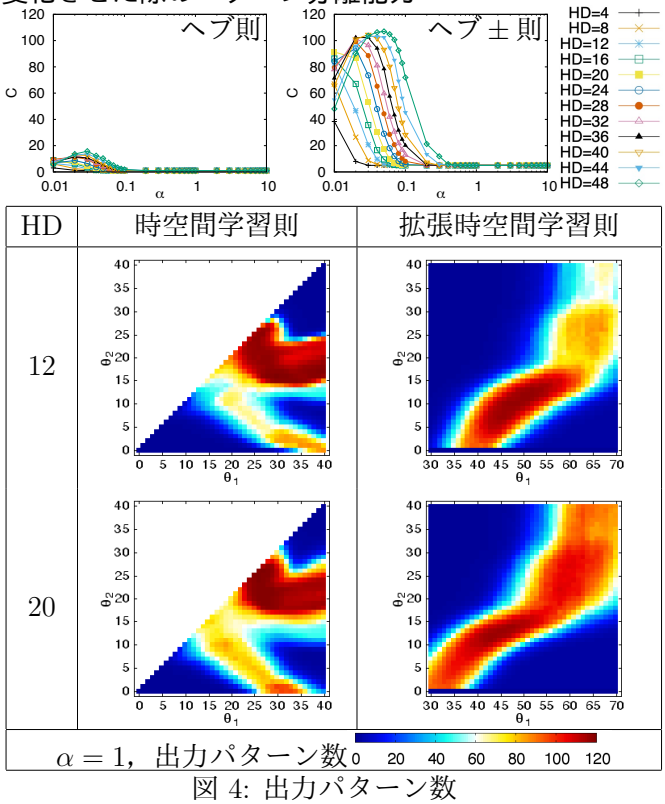


図 4: 出力パターン数

3.2　学習則の頑健性

時空間パターンを学習したネットワークに対して，シナプス荷重 w_{ij} を確率 p でランダムシャッフルした際の出力パターン数を調査することで，学習則のパターン分離能力への頑健性を調査した．確率 p を $p = 0$ から大きくしたときに，出力パターン数 C が 100 以上となる最大の p を p' とする．p' が大きいほど学習則のパターン分離能力への頑健性が高いといえる．

時空間パターンを学習したネットワークに対して，p を変化させた場合の出力パターン数を図 5 に示す．図 5 より，拡張時空間学習則の p' は時空間学習則の p' より大きくなり，パターン分離能力への頑健性が高いことが分かる．

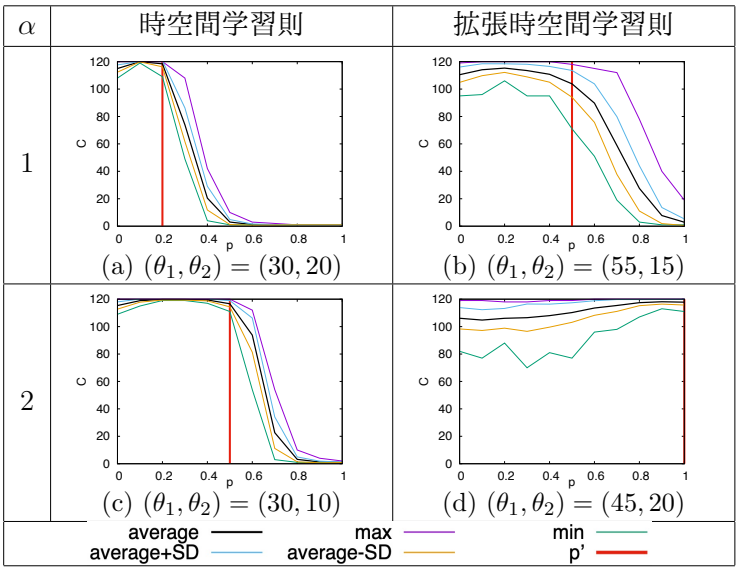


図 5: p を変化させた場合のパターン分離能力の推移

4　まとめ

本論文では，入力する時空間パターンのハミング距離を変化させたときの学習則のパターン分離能力を調査した．その結果，ヘブ則，ヘブ ± 則はどのハミング距離でもパターン分離能力が低く，時空間学習則，拡張時空間学習則ではどのハミング距離でもパターン分離能力が高いパラメータが存在した．また，時空間学習則と拡張時空間学習則のパターン分離能力への頑健性を調査した結果，拡張時空間学習則の方がパターン分離能力への頑健性が高いことが判明した．

参考文献

[1] D. O. Hebb, “The organization of behavior: A neuropsychological theory,” Oxford: Wiley, 1949.

[2] M. Tsukada and X. Pan, “The spatiotemporal learning rule and its efficiency in separating spatiotemporal patterns,” *Biological Cybernetics*, Vol. 92, No. 2, pp. 139–146, 2005.

[3] H. Tsukada, S. Nara, and M. Tsukada, “A systematic identification of the difference characteristics for sequence discrimination between Hebb and extended spatiotemporal learning rule,” preprint, 2024.

[4] E. R. Kandel and T. J. O’dell, “Are adult learning mechanisms also used for development?,” *Science*, Vol. 258, No. 5080, pp. 243–245, 1992.

[5] H. Tsukada and M. Tsukada, “Comparison of pattern discrimination mechanisms of Hebbian and spatiotemporal learning rules in self-organization,” *Frontiers in Systems Neuroscience*, Vol. 15, 624353, 2021.

[6] T. Aihara, M. Tsukada, and H. Matsuda, “Two dynamic processes for the induction of long-term potentiation in hippocampal CA1 neurons,” *Biological Cybernetics*, Vol. 82, pp. 189–195, 2000.

Echo State Networkを用いた非線形時系列予測に関する研究

吉田しおん (池口徹 教授)

1 はじめに

Reservoir computing (以下，RC) は，リカレントニューラルネットワークモデルから派生した概念であり，高速な機械学習に適した計算の枠組みである．従来の人工ニューラルネットワークによる機械学習では，高精度なデータ解析を実現するために計算時間と計算資源を必要とする．一方，RCでは，入力した時系列をリザバー層で時空間パターンに変換し，出力層でのみ簡便な学習を行うことで，高速な時系列解析を実現している [1]．このように，RCは高速に時系列解析を行うことができるため，文法構造の学習，金融時系列の予測などに広く用いられている [2]．また，実用性の高いRCの実現のために，ノイズに頑健なRCも提案されている [3]．

RCは高速かつ高精度に時系列予測などを行うが，どのような動作原理で高精度な時系列予測が実現されているかは明らかになっていない．そこで，近年では，RCの動作原理を解析的，数値実験的に明らかにしようとする研究が進められている [4, 5, 6, 7]．例えば，文献 [6] では，RCを用いてカオス応答を示すロジスティック写像の予測を行い，RCにおけるパラメータの1つと得られた予測値の間に，ロジスティック写像が持つ分岐構造が存在することを示している．これは，RCが学習したパラメータのみならず，力学系の本質的なダイナイクスを学習していることを示している．また，文献 [7] では，RCの内部システムと入力した時系列を生成した力学系が，位相共役となっていることを仮定し，Takensの埋め込み定理 [8, 9] に沿った解析的な証明を試みている．

本論文では，RCの一つであるecho state network (以下，ESN) [10] を用いて，カオス時系列の予測を行うことで，RCの動作原理について数値実験により調査する．具体的には，予測を行う際のESNの力学系が有する特徴について調査した．その結果，ESNのパラメータ設定により，予測を行う際のESNの力学系のアトラクタ構造が変化していることがわかった．

2 Echo State Network

ESNは従来のリカレントニューラルネットワークの特殊なモデルである [1]．本研究では，ESNの基本モデルを用いて時系列予測を行う．ESNの基本モデルの構造を図1に示す．

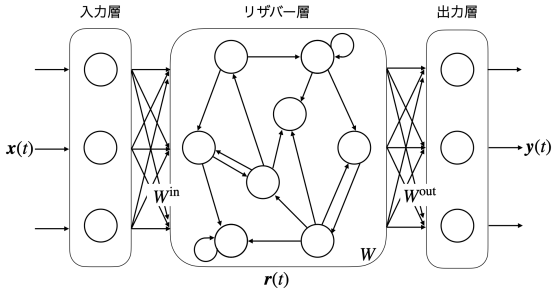


図 1: ESNの基本モデル

図1において，入力層のノード数を N_x，リザバー層のノード数を N，出力層のノード数を N_y とする．図1では，$N_x = 3, N = 8, N_y = 3$ の場合を示している．時刻 t における入力ベクトルを $\boldsymbol{x}(t) \in \mathbb{R}^{N_x}$，リザバー状態ベクトルを $\boldsymbol{r}(t) \in \mathbb{R}^{N}$，出力ベクトルを $\boldsymbol{y}(t) \in \mathbb{R}^{N_y}$ と表す．ここで，本論文では，入力層のノード数を $N_x = 1$，出力層のノード数を $N_y = 1$ とするため，以降，入力ベクトル $\boldsymbol{x}(t)$ を入力値 $x(t)$，出力ベクトル $\boldsymbol{y}(t)$ を出力値 $y(t)$ とする．また，入力結合重み行列を $\boldsymbol{W}^{\mathrm{in}} \in \mathbb{R}^{N \times N_x}$，リザバー結合重み行列を $\boldsymbol{W} \in \mathbb{R}^{N \times N}$，出力結合重み行列を $\boldsymbol{W}^{\mathrm{out}} \in \mathbb{R}^{N_y \times N}$ と表す．結合重み行列のうち，入力結合重み行列 $\boldsymbol{W}^{\mathrm{in}}$，リザバー結合重み行列 $\boldsymbol{W}$ はあらかじめ乱数で与えられた固定値とし，出力結合重み行列 $\boldsymbol{W}^{\mathrm{out}}$ についてのみ学習を行う．

リザバー結合重み行列 $\boldsymbol{W}$ はスパース性を持つように設計することが多い [10]．よって，本研究でもリザバー層のネットワークはスパースであるとした．具体的には，$\boldsymbol{W}$ の構造をランダムネットワークの 1 つである，Erdős-Rényi (以下，ER) モデル [11] に従うランダムネットワークとし，結合確率 $p = 2\%$ とした．

ESN を用いて時系列予測を行う際に，リザバー層が満たすべき性質の 1 つに echo state property (以下，ESP) がある．ESP は，異なるリザバー状態ベクトルの初期状態 $\boldsymbol{r}(0), \boldsymbol{r}'(0)$ から状態更新を開始しても，十分時間経過した際には，同じ時系列入力に対して同じ時系列出力が得られるという再現性を保証する性質である．これを満たすためには，活性化関数を $f = \tanh$ とする場合，リザバー結合重み行列 $\boldsymbol{W}$ のスペクトル半径を $\rho(\boldsymbol{W}) = \max_i |\theta_i| < 1$ $(i = 1, \ldots, N)$ とする [10]．また，出力結合重み行列 $\boldsymbol{W}^{\text{out}}$ の学習はリッジ回帰を用いた．

各時刻 t において，入力層に入力値が与えられると，その情報はリザバー層によって変換され，出力層へと伝播する．時刻 t におけるリザバー状態ベクトル，出力値は式 (1), (2) で更新される．

$$\boldsymbol{r}(t) = \boldsymbol{f}\left(\boldsymbol{W}^{\text{in}} x(t) + \boldsymbol{W}\boldsymbol{r}(t-1)\right) \tag{1}$$

$$\hat{y}(t) = \boldsymbol{W}^{\text{out}} \boldsymbol{r}(t) \tag{2}$$

式 (1) において，$\boldsymbol{f}(\cdot)$ は活性化関数 $f(\cdot)$ を各要素に適用したベクトル値関数である．

3 ESN の動作原理の解析

3.1 ESN を用いたフリーラン予測

本論文では，ESN を用いて時系列のフリーラン予測を行う．ESN を用いたフリーラン予測では，式 (2) によって得られた時刻 t における予測値 $\hat{y}(t) = \boldsymbol{W}^{\text{out}}\boldsymbol{r}(t)$ を時刻 $t+1$ での入力値とする．$N_x = N_y$ のとき，式 (1) の入力値 $x(t)$ を，予測値 $\hat{y}(t)$ とすると，リザバー層の状態更新式は式 (3) で表される．

$$\boldsymbol{r}(t+1) = \boldsymbol{f}\left(\boldsymbol{W}^{\text{in}}\boldsymbol{W}^{\text{out}}\boldsymbol{r}(t) + \boldsymbol{W}\boldsymbol{r}(t)\right) \tag{3}$$

ここで，式 (3) より，リザバー状態ベクトル $\boldsymbol{r}(t)$ のみによって次の値 $\boldsymbol{r}(t+1)$ が決まるため，自律系の力学系となっている．そこで，本論文では，式 (3) を ESN の力学系とし，その力学的特性を評価する．具体的には，ESN の N 次元の力学系に対して，主成分分析を行いアトラクタ構造を調査した．

3.2 実験条件

ESN の基本モデルを用いて，非線形力学系のフリーラン予測を行った．本論文では，ロジスティック写像: $x(t+1) = 4x(t)(1-x(t))$ から得られるカオス的な振舞いをする時系列を予測対象の一つとしている．カオス性を示す力学系から観測される時系列のフリーラン予測において，軌道不安定性から，予測値のわずかな差が，時間経過とともに拡大してしまう．そのため，1 ステップ先予測と異なり，状態値間の誤差による評価は適切ではない．そこで，不変測度を用いて予測精度を評価した．具体的には，入力時系列の状態値の頻度分布とフリーラン予測で得た時系列の状態値の頻度分布間の Kullback-Leibler divergence (以下，KL divergence) を用いて予測精度を評価した．

表 1: ESN の基本モデルのパラメータ

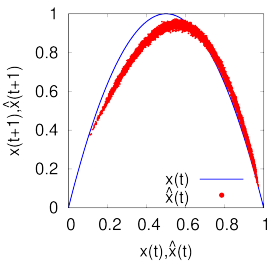
ハイパーパラメータ	値
入力次元 N_x, 出力次元 N_y	1
リザバー層のノード数 N	50
$\boldsymbol{W}$ のスペクトル半径 $\rho(\boldsymbol{W})$	0.98
$\boldsymbol{W}$ の結合密度 p	2%
リッジ回帰の正則化パラメータ	10^{-7}
学習データの時系列長	1,000
フリーラン予測の時系列長	10,000

本論文で用いた ESN のパラメータを表 1 に示す．入力結合重み行列 $\boldsymbol{W}^{\text{in}}$ の要素は，範囲 $[-0.1, 0.1]$ で一様分布に従う乱数で与える．また，リザバー結合重み行列 $\boldsymbol{W}$ の要素は，平均 0，分散 1 の正規分布から，範囲 $[-1, 1]$ だけ取り出した，切断正規分布に従う乱数で与える．さらに，KL divergence を求める際の入力時系列の状態値の頻度分布とフリーラン予測で得た時系列の状態値の頻度分布のビン幅は 0.01 とした．

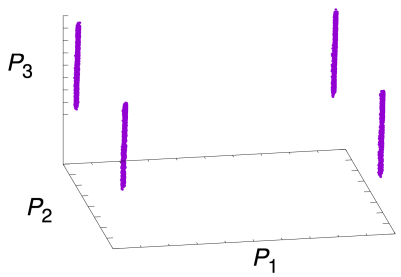
3.3 結果

入力結合重み行列 $\boldsymbol{W}^{\text{in}}$，リザバー結合重み行列 $\boldsymbol{W}$ の要素を決める乱数を 200 通りとして予測を行った．200 通りの結果のうち，KL divergence によって評価した予測精度が類似している 2 通りのロジスティック写像の予測時系列のリターンマップと，その際の ESN の力学系の主成分分析の結果を図 2 に示す．また，主成分分析による寄与率を表 2 に示す．表 2 における C_i は，第 i 主成分の寄与率である．

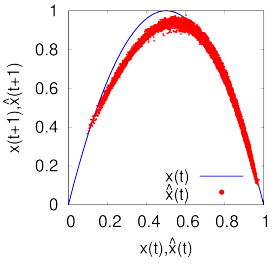
図 2 (a), (c) は，真の時系列 $x(t)$ と予測値の時系列 $\hat{x}(t)$ のリターンマップを重ね書きしている．また，図 2 (b), (d) は，ESN の $N = 50$ 次元の力学系に対して主成分分析を行い，第 3 主成分までプロットした結果である．軸の P_i は第 i 主成分を表す．図 2 (a), (c) に示す入力時系列の状態値の頻度分布とフリーラン予測で得た時系列の状態値の頻度分布間の KL divergence の値は，それぞれ，0.0425, 0.0441 であった．これより，これらの予測精度は同程度であると考える．しかし，50 次元の ESN の力学系のアトラクタ構造は，大きく異なることがわかる (図 2 (b), (d))．特に，図 2 (b) は，4 箇所で直線となっており，今回調査した 200 通りの結果の中でよく見られる結果となった．図 2 (d) は，ロジスティック写像のリターンマップのように，放物線となっていることがわかった．また，表 2 より，寄与率はどちらも第 3 主成分までに 90% を超えているが，第 1 主成分の寄与率に差があることがわかる．これらの結果より，ESN が同じような予測精度を有するとしても，ESN が持つ力学系のアトラクタ構造はさまざまであることがわかった．



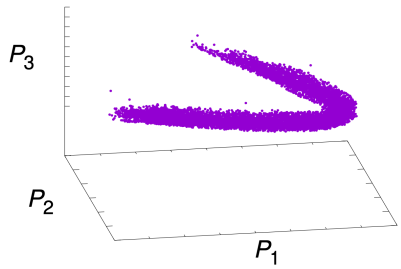
(a) 真のリターンマップとフリーラン予測して得たリターンマップ 1



(b) 図 2 (a) の ESN の力学系の主成分分析の結果



(c) 真のリターンマップとフリーラン予測して得たリターンマップ 2



(d) 図 2 (c) の ESN の力学系の主成分分析の結果

図 2: リザバー層のノード数 $N = 50$ としてロジスティック写像のフリーラン予測を行った結果

表 2: ESN の力学系に対して求めた主成分の寄与率

寄与率	C_1	C_2	C_3	累積寄与率
図 2 (b)	48.71%	33.37%	9.91%	91.99%
図 2 (d)	75.02%	16.09%	6.52%	97.63%

4 まとめ

本論文では，RC の 1 つである，ESN を用いて，カオス応答を示すロジスティック写像のフリーラン予測を行うことで，ESN の力学系には，どのようなダイナミクスが存在するのかを調査した．ESN の力学系に対して主成分分析を適用した結果，ESN によるフリーラン予測の結果と ESN の力学系のアトラクタ構造には相関が見られないことがわかった．

一方，リザバー結合重み行列 $\boldsymbol{W}$ の要素は乱数で与えており，$\boldsymbol{W}$ の設計によって，ESN の力学系のアトラクタ構造が異なることがわかった．このことから，予測が成功する場合のリザバー層のネットワーク構造に，特有の構造があると考え，このような構造の存在とその定量的評価が今後の課題の 1 つである．

参考文献

[1] 田中剛平, 中根了昌, 廣瀬明, リザバーコンピューティング 時系列パターン認識のための高速機械学習の理論とハードウェア, 森北出版, 2021.

[2] G. Tanaka, T. Yamane, J. B. Héroux, R. Nakane, N. Kanazawa, S. Takeda, H. Numata, D. Nakano, and A. Hirose, “Recent advances in physical reservoir computing: A review,” *Neural Networks,* Vol. 115, pp. 100–123, 2019.

[3] D. Li, M. Han, and J. Wang, “Chaotic time series prediction based on a novel robust echo state network,” *IEEE Transactions on Neural Networks and Learning Systems,* Vol. 23, No. 5, pp. 787–799, 2012.

[4] J. Pathak, Z. Lu, B. R. Hunt, M. Girvan, and E. Ott, “Using machine learning to replicate chaotic attractors and calculate Lyapunov exponents from data,” *Chaos,* Vol. 27, 121102, 2017.

[5] M. U. Kobayashi, K. Nakai, Y. Saiki, and N. Tsutsumi, “Dynamical system analysis of a data-driven model constructed by reservoir computing,” *Physical Review E,* Vol. 104, No. 4, 044215, 2021.

[6] M. Hara and H. Kokubu, Learning Dynamics by Reservoir Computing (In Memory of Prof. Pavol Brunovskỳ), *Journal of Dynamics and Differential Equations,* 2022, https://doi.org/10.1007/s10884-022-10159-w.

[7] A. Hart, J. Hook, and J. Dawes “Embedding and approximation theorems for echo state networks,” *Neural Networks,* Vol. 128, pp. 234–247, 2020.

[8] F. Takens, “Detecting strange attractors in turbulence,” *Dynamical Systems and Turbulence,* Vol. 898, pp. 366–381, 1981.

[9] T. Sauer, J. A. Yorke, and M. Casdagli, “Embedology,” *Journal of Statistical Physics,* Vol. 65, No. 3, pp. 579–616, 1991.

[10] H. 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,* Vol. 148, No. 34, 2001.

[11] P. Erdős and A. Rényi, “On the evolution of random graphs,” *Publ. Math. Inst. Hung. Acad. Sci,* Vol. 5, No. 1, pp. 17–60, 1960.

[12] S. Kullback and R. A. Leibler, “On information and sufficiency,” *The Annals of Mathematical Statistics,* Vol. 22, No. 1, pp. 79–86, 1951.

発表文献

[P1] 吉田しおん, 池口徹, “エコーステートネットワークにおけるリザバー層のダイナミクス,” 電子情報通信学会技術研究報告, Vol. 123, No. 287, pp. 15–20, NLP2023-62, 2023.

[P2] S. Yoshida and T. Ikeguchi, “Dynamics of reservoir layer in time series prediction,” FY2023 RIEC Annual Meeting on Cooperative Research Project, Feb. 2024, 発表予定.

その他国内発表会

一般社団法人　電子情報通信学会
THE INSTITUTE OF ELECTRONICS,
INFORMATION AND COMMUNICATION ENGINEERS

信学技報
IEICE Technical Report

エコーステートネットワークにおけるリザバー層のダイナミクス

吉田しおん[†,††] 池口　徹[†]

† 東京理科大学 工学部 情報工学科　〒125-8585 東京都葛飾区新宿 6–3–1
†† shion@hisenkei.net

あらまし　リザバーコンピューティングは，高速かつ高精度に時系列解析を行う機械学習の枠組みであり，近年幅広い分野で用いられている．本稿では，リザバーコンピューティングの 1 つであるエコーステートネットワークを用いて，カオス性を有する時系列データを予測したときのリザバー層に対する主成分分析の適用と，最大リアプノフ指数の算出により，なぜ高精度な時系列解析が可能となるのか，その動作原理を解析する．主成分分析を適用した結果，リザバー層は入力した時系列のアトラクタを再構成することがわかった．また，最大リアプノフ指数を算出した結果，正の値を持つことがわかった．これより，エコーステートネットワークを用いた時系列予測では，リザバー層が入力する時系列データの特徴を再現していること，従って，リザバー層は力学系の埋め込みに相当する機能を有することがわかった．

キーワード　エコーステートネットワーク，リザバーコンピューティング，非線形時系列予測，埋め込み定理

Dynamics of Reservoir in Echo State Network

Shion YOSHIDA[†,††] and Tohru IKEGUCHI[†]

† Department of Information and Computer Technology, Faculty of Engineering, Tokyo University of Science
Niijuku 6–3–1, Katsushika-ku, Tokyo, 125-8585, Japan
†† shion@hisenkei.net

Abstract　Reservoir computing is one of the frameworks for machine learning for fast and highly accurate analysis of time series and it has been widely real world time series in recent years. In this report, to clarify the working principle that enables highly accurate time series analysis we applied principal component analysis and calculated the largest Lyapunov exponent for dynamics of reservoir layer when chaotic time series data are predicted using an echo state network, which is one of reservoir computing. The results of a principal component analysis show that dynamics of reservoir layer reproduces behavior of the input time series. In addition, the largest Lyapunov exponent exhibits a positive value. Therefore, in time series prediction using an echo state network, the reservoir layer reproduces the features of the time series and operates an embedding of nonlinear dynamical systems.

Key words　echo state network, reservoir computing, nonlinear time series prediction, embedding theorem

1. はじめに

リザバーコンピューティング（reservoir computing，以下 RC）は，リカレントニューラルネットワークモデルから派生した概念であり，高速機械学習に適した計算の枠組みである．従来の人工ニューラルネットワークによる機械学習では，高精度な計算を実現するために計算時間と計算資源を必要とする．一方，RC では，リザバー層で時系列入力を時空間パターンに変換し，出力層で簡便な学習アルゴリズムを用いることで，高速にパターン解析を行うことを実現している [1]．RC は特に時系列解析に適しており，音声認識，文法構造の学習，金融時系列の予測などに用いられている [2]．また，実用性の高い RC の実現のために，ノイズに頑健な RC が提案されている [3]．

RC は高速かつ高精度に時系列予測などを行うが，どのような動作原理で高精度な時系列予測が実現されているかは明らかになっていない．そこで，近年では，動作原理を解析的，数値実験的に明らかにしようとする研究が進められている [5]〜[8]．例えば，文献 [6] ではリザバー層のノード数を 3 として RC にロジスティック写像を入力し，リザバー層を構成するハイパーパラメータと得られた予測値の間にロジスティック写像が持つ分岐構造が存在することを示している．また，文献 [7] では RC のリザバー層が入力した時系列に対して埋め込みとなる条件を仮定し，解析的な証明を与えることを試みている．

本稿では，RC の一つであるエコーステートネットワーク

This article is a technical report without peer review, and its polished and/or extended version may be published eleswhere.
Copyright ©2023 by IEICE

(echo state network，以下 ESN) [4] のリザバー層の力学系が入力した時系列を生成した元の力学系に対して埋め込みとなっているかどうかを数値的に検証する．具体的には，リザバー層の力学系に対して，主成分分析の適用と，最大リアプノフ指数の推定により調査した結果を報告する．

2. エコーステートネットワーク

2.1 基本モデル

ESN は従来のリカレントニューラルネットワークの特殊なモデルである．本節では，ESN の基本モデルについて述べる．ESN の基本モデルの構造を図 1 に示す．図 1 において，入力層のノード数を N_x，リザバー層のノード数を N，出力層のノード数を N_y と表す．図 1 では，$N_x = 3, N = 8, N_y = 3$ の場合を示している．時系列データを用いるため，各ノードの状態は離散時間 $t = 1, 2, \ldots$ で発展する．時刻 t における入力ベクトルを $\boldsymbol{x}(t) = (x_1(t), x_2(t), \ldots, x_{N_x}(t))^{\mathrm{T}}$，リザバー内部状態ベクトルを $\boldsymbol{r}(t) = (r_1(t), r_2(t), \ldots, r_N(t))^{\mathrm{T}}$，出力ベクトルを $\boldsymbol{y}(t) = (y_1(t), y_2(t), \ldots, y_{N_y}(t))^{\mathrm{T}}$ と表す．ここで，T は行列，ベクトルの転置を表す．本稿では，入力層のノード数を $N_x = 1$，出力層のノード数を $N_y = 1$ とするため，以降，入力ベクトル $\boldsymbol{x}(t)$ を入力値 $x(t)$，出力ベクトル $\boldsymbol{y}(t)$ を出力値 $y(t)$ とする．また，入力結合重み行列を $\boldsymbol{W}^{\mathrm{in}} \in \mathbb{R}^{N \times N_x}$，リザバー内部結合重み行列を $\boldsymbol{W} \in \mathbb{R}^{N \times N}$，出力結合重み行列を $\boldsymbol{W}^{\mathrm{out}} \in \mathbb{R}^{N_y \times N}$ と表す．結合重み行列のうち，入力結合重み行列 $\boldsymbol{W}^{\mathrm{in}}$，リザバー内部結合重み行列 $\boldsymbol{W}$ はあらかじめ乱数で与えられた固定値とし，出力結合重み行列 $\boldsymbol{W}^{\mathrm{out}}$ についてのみ学習を行う．また，リザバー内部結合重み行列 $\boldsymbol{W}$ はスパース性を持つように設計することが多い [4]．本稿でもこれを考慮して，$\boldsymbol{W}$ はスパース性を持つように設計した．

各時刻 t において，入力層に入力ベクトルが与えられると，その情報はリザバー層によって変換され，出力層へ伝播する．時刻 t におけるリザバー内部状態ベクトル，出力ベクトルの状態更新は式 (1), (2) で更新される．

$$\boldsymbol{r}(t) = \boldsymbol{f}\left(\boldsymbol{W}^{\mathrm{in}} x(t) + \boldsymbol{W}\boldsymbol{r}(t-1)\right) \tag{1}$$

$$y(t) = \boldsymbol{W}^{\mathrm{out}} \boldsymbol{r}(t) \tag{2}$$

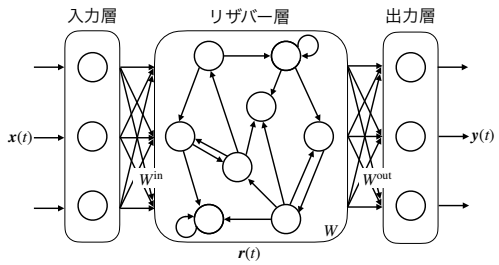


図 1　ESN の基本モデル

式 (1) において，$\boldsymbol{f}(\cdot)$ は活性化関数 $f(\cdot)$ を各要素に適用したベクトル値関数である．

2.2 エコーステートプロパティ

ESN を用いて時系列予測を行うに際して，リザバー層が満たすべき性質の 1 つにエコーステートプロパティ（echo state property，以下 ESP）がある．これは，異なるリザバー状態ベクトルの初期状態から状態更新を開始しても，十分時間経過した際には，同じ時系列入力に対して同じ時系列出力が得られるという，再現性を保証する性質である [1]．活性化関数を $f = \tanh$ とすると，ESP を満たすための経験的な条件は式 (3) で表現できる [4]．

$$\rho(\boldsymbol{W}) = \max_i |\theta_i| < 1 \ \ (i = 1, \ldots, N) \tag{3}$$

ここで，$\rho(\boldsymbol{W})$ は $\boldsymbol{W}$ のスペクトル半径であり，式 (3) で示すように $\boldsymbol{W}$ の固有値 θ_i の絶対値の最大値で求められるが，式 (3) の不等式を満たすためには，スペクトル半径が 1 未満になるようにリザバー内部結合重み行列 $\boldsymbol{W}$ を設計する必要がある．そこで，行列 $\boldsymbol{W}'$ の要素 w'_{ij} を任意の分布に従う乱数として与え，リザバー内部結合重み行列 $\boldsymbol{W}$ を，$\boldsymbol{W}'$ の固有値 θ'_i の絶対値の最大値 $|\theta'_{\max}|$ を用いて式 (4) のようにスケーリングする．

$$\boldsymbol{W} = \frac{1}{|\theta'_{\max}|} \rho \boldsymbol{W}' \tag{4}$$

ここで，式 (4) の ρ は $\boldsymbol{W}$ のスペクトル半径 $\rho(\boldsymbol{W})$ の規模を表し，スペクトル半径 $\rho(\boldsymbol{W})$ の大きさを調節する ESN のハイパーパラメータである．

2.3 学　習　則

本稿では，出力結合重み行列 $\boldsymbol{W}^{\mathrm{out}}$ の学習にリッジ回帰（式 (6)）を用いている．$\boldsymbol{W}^{\mathrm{out}}$ は，データ長 L の学習時系列 $\{x(l)\}_{l=1}^{L}$ に対して 1 ステップ先予測を行い，予測値 $\hat{y}(l) = \boldsymbol{W}^{\mathrm{out}} \boldsymbol{r}(l)$ と予測値に対応する学習データ $x(l+1)$ との誤差が小さくなるように最小二乗法を用いて求める．また，過学習を緩和させるために $\boldsymbol{W}^{\mathrm{out}}$ についての正則化項を加えると $\hat{y}(l)$ と $x(l+1)$ の二乗誤差は式 (5) で表される．

$$E(\boldsymbol{W}^{\mathrm{out}}) = \sum_{l=0}^{L} ||\boldsymbol{W}^{\mathrm{out}} \boldsymbol{r}(l) - x(l+1)||^2 + \beta[\mathrm{Tr}(\boldsymbol{W}^{\mathrm{out}} \boldsymbol{W}^{\mathrm{out}\,\mathrm{T}})] \tag{5}$$

ここで，β は正則化パラメータであり，正則化項の大きさを調節する．時刻 $[1, L]$ の学習時系列 $x(l)$ を列ベクトルとして並べた行列を $\boldsymbol{X}$，リザバー状態ベクトル $\boldsymbol{r}(t)$ を列ベクトルとして並べた行列を $\boldsymbol{R}$ とすると，E を最小化する $\boldsymbol{W}^{\mathrm{out}}$ は式 (6) より求められる．

$$\boldsymbol{W}^{\mathrm{out}} = \boldsymbol{X}\boldsymbol{R}^{\mathrm{T}}(\boldsymbol{R}\boldsymbol{R}^{\mathrm{T}} + \beta \boldsymbol{I})^{-1} \tag{6}$$

ここで，$\boldsymbol{I}$ は単位行列を表す．

3. リザバー層の力学的特性の評価

ESN を用いたフリーラン予測では，式 (2) によって得られた時刻 t における予測値 $\hat{y}(t) = \boldsymbol{W}^{\mathrm{out}} \boldsymbol{r}(t)$ を時刻 $t+1$ の入力値とする．$N_x = N_y$ のとき，式 (1) の入力値を $x(t)$，予測値を $\hat{y}(t)$

とすると，リザバー層の状態更新式は式 (7) で表される．

$$\boldsymbol{r}(t+1) = \boldsymbol{f}\left(\boldsymbol{W}^{\mathrm{in}}\boldsymbol{W}^{\mathrm{out}}\boldsymbol{r}(t) + \boldsymbol{W}\boldsymbol{r}(t)\right) \tag{7}$$

式 (7) より，リザバー状態ベクトル $\boldsymbol{r}(t)$ のみによって次の値 $\boldsymbol{r}(t+1)$ が決まるため，自律系となっている．そこで式 (7) をリザバー層の力学系とし，主成分分析と最大リアプノフ指数から力学的特性を評価する．

ここで，力学的特性の評価指標について述べる前に，入力する真の時系列 $x(t)$ と得られた予測時系列 $\hat{x}(t)$ から遅延座標系によるアトラクタの再構成 [9] を行う手法について説明する．遅延座標系によるアトラクタの再構成を行う理由は，元の力学系が有する全ての変数を観測できない場合でも，再構成したアトラクタは，その背景にある元の力学系が持つ力学的特性を保持するためである．入力する真の時系列 $x(t)$ と得られた予測時系列 $\hat{x}(t)$ について，遅延座標系によるアトラクタの再構成を行い，これらについて比較することで，得られた予測時系列 $\hat{x}(t)$ が入力する真の時系列 $x(t)$ が有する力学的特性を再現できているか評価する．

真の時系列 $x(t)$ から遅延座標系によるアトラクタの再構成を行うとき，再構成次元を m，遅れ時間を τ として，真の時系列の遅れ時間ベクトル $\bar{\boldsymbol{x}}(t)$ を式 (8) のように作成する．

$$\bar{\boldsymbol{x}}(t) = (x(t), x(t+\tau), x(t+2\tau), \ldots, x(t+(m-1)\tau)) \tag{8}$$

同様に，予測時系列の遅れ時間ベクトル $\bar{\hat{\boldsymbol{x}}}(t)$ は式 (9) のように作成する．

$$\bar{\hat{\boldsymbol{x}}}(t) = (\hat{x}(t), \hat{x}(t+\tau), \hat{x}(t+2\tau), \ldots, \hat{x}(t+(m-1)\tau)) \tag{9}$$

3.1 主成分分析

主成分分析（principal compornents analysis，以下 PCA）は多次元データの情報をできるだけ損なうことなく低次元に射影する手法である．情報の損失が少なくなるように低次元に射影することは，射影軸上の分散が大きくなるように射影することである．よって，主成分分析は分散が最大となる射影軸を求める．これは，多次元のデータの分散共分散行列の固有値 μ_i $(i = 1, \ldots, N)$ を求めることで得られる．また，固有値 μ_i が 0 に近い場合，データ全体に与える影響がほとんどないため，これを除くことで次元が削減される．第 i 番目に大きい固有値が全データの情報をどれだけ説明しているかを示す指標を寄与率という．第 i 主成分の寄与率 C_i は分散共分散行列の固有値 μ_i を用いて，式 (10) により求められる．

$$C_i = \frac{\mu_i}{\sum_{i=1}^{N}\mu_i} \tag{10}$$

主成分分析をリザバー層の力学系に適用すると，N 次元から 2, 3 次元に射影することができ，リザバー層の力学系のアトラクタを可視化することができる．このアトラクタが，入力した時系列を生成した力学系と類似している場合，リザバー層の力学系が入力した時系列を生成した力学系のアトラクタを再構成していると考えられる．

3.2 最大リアプノフ指数

リアプノフ指数を用いることで，カオス力学系の特徴の 1 つである，軌道不安定性を評価することができる [9]．ある時刻において，2 点間の距離が $||\delta_0||$ であったとき，時刻 t 後の距離 $||\delta_t||$ は式 (11) で表される．

$$||\delta_t|| \approx ||\delta_0|| e^{\lambda t} \tag{11}$$

式 (11) における λ がリアプノフ指数である．リアプノフ指数が $\lambda < 0$ のとき，$||\delta_0|| e^{\lambda t} < 0$ となり，2 つの解の差が 0 に収束するため，軌道不安定性を持たないことがわかる．一方，$\lambda > 0$ のとき，$||\delta_0|| e^{\lambda t} > 0$ となり，2 つの解の差が大きくなるため，軌道不安定性を持つ．

本稿では，最大リアプノフ指数 [10] を計算することでリザバー層の力学系の軌道不安定性を評価する．時刻 t におけるアトラクタ上の点を $x(t)$ とする．また，$x(t)$ を中心とする半径 ϵ の球に入る近傍点を $x_i(t)$ $(i = 1, \ldots, U(t))$ とする．このとき，$x(t)$ と $x_i(t)$ の k 時間後の距離を $d(x(t+k), x_i(t+k))$ とする．本稿では，2 点間の距離をユークリッド距離で計算した．$d(x(t+k), x_i(t+k))$ を用いると式 (11) は，式 (12) と表せる．

$$d(x(t+k), x_i(t+k)) \approx d(x(t), x_i(t)) e^{\hat{\lambda_1}(t)k} \tag{12}$$

ここで，式 (12) の $\hat{\lambda_1}(t)$ は時刻 t における最大局所膨張率である．式 (12) を変形すると，$\hat{\lambda_1}(t)$ は式 (13) と表せる．

$$\hat{\lambda_1}(t) \approx \frac{1}{k}\log\left(\frac{d(x(t+k), x_i(t+k))}{d(x(t), x_i(t))}\right) \tag{13}$$

各時刻 $t = 1, \ldots, T$ において，$x(t)$ が持つ近傍点の数 $U(t)$ だけ式 (13) より最大局所膨張率を求め，平均をとる．これを式 (14) で表す．

$$\bar{\lambda_1} \approx \frac{1}{T}\frac{1}{k}\sum_{t=1}^{T}\frac{1}{U(t)}\sum_{i=1}^{U(t)}\log\left(\frac{d(x(t+k), x_i(t+k))}{d(x(t), x_i(t))}\right) = \frac{1}{k}S(k) \tag{14}$$

式 (14) より $S(k) \approx \bar{\lambda_1} k$ となる．すなわち，$S(k)$ は k の関数で表され，横軸を k，縦軸を $S(k)$ としてプロットした図の傾きから最大リアプノフ指数 $\bar{\lambda_1}$ が推定される．

4. 解 析 結 果

ESN の基本モデルを用いて，ロジスティック写像，ローレンツ方程式に対してフリーラン予測を行った．本実験で用いた ESN のハイパーパラメータを表 1 に示す．ここで，入力結合重み行列 $\boldsymbol{W}^{\mathrm{in}}$ の要素は範囲 $[-1, 1]$ で一様分布に従う乱数で与える．また，リザバー結合重み行列 $\boldsymbol{W}$ の要素は範囲 $[-1, 1]$ で正規分布に従う乱数で与える．各時系列データに対して，$\boldsymbol{W}^{\mathrm{in}}$, $\boldsymbol{W}$ の要素を決める乱数の種を $[0, 199]$ の 200 通りとして予測を行った．

4.1 ロジスティック写像

ロジスティック写像を式 (15) に示す．

$$x(t+1) = ax(t)(1 - x(t)) \tag{15}$$

表 1　本実験で用いた ESN の基本モデルの詳細

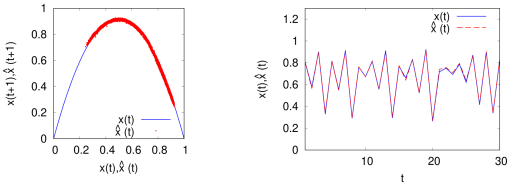
ハイパーパラメータ	ロジスティック写像	ローレンツ方程式
入力次元 N_x, 出力次元 N_y	1	
リザバー層のノード数 N	100	300
スペクトル半径の規模 ρ	0.98	
結合密度 p	0.02	
正則化パラメータ β	10^{-7}	10^{-6}
学習データの長さ L	1,000	
フリーラン予測の長さ L_f	10,000	

ここで，文献 [6] のパラメータに従い $a = 3.7$ とした．初期値を $x(0) = 0.2$ とし，過渡状態を除いた時刻 $t = 10,000$ から学習データとして用いた．

フリーラン予測を行い，リザバー層の力学系がロジスティック写像のリターンマップの再現に成功した場合の結果を図 2 に示す．図 2 (a) は，入力した時系列を横軸を $x(t)$, $\hat{x}(t)$，縦軸を $x(t+1)$, $\hat{x}(t+1)$ とした結果であり，入力した真の値 $x(t)$ と予測値 $\hat{x}(t)$ を重ね書きしている．また，図 2 (b) は 1 ステップ先予測により得た予測時系列と真の時系列を示しており，横軸は時刻 t，縦軸は真の値と予測値の状態値 $x(t)$, $\hat{x}(t)$ を示している．図 2 (a) において，フリーラン予測によりロジスティック写像の再現に成功するとき，真のロジスティック写像のリターンマップ上に予測値がプロットされる．図 2 (a) では，$a = 3.7$ の場合のロジスティック写像が取りうる範囲 $[0.28, 0.92]$ で予測値 $\hat{x}(t)$ が真のロジスティック写像のリターンマップ上にプロットされているため，ロジスティック写像の再現に成功している．また，図 2 (b) より，1 ステップ先予測は予測値 $\hat{x}(t)$ と実の値 $x(t)$ の差が小さく，正しく予測できていることがわかる．

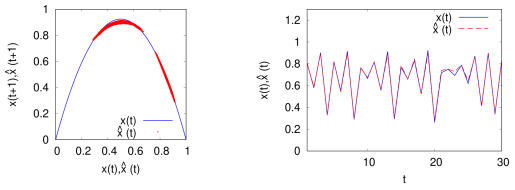
次に，ロジスティック写像の再現が正確に行えない場合の例を図 3 に示す．図 3 (a) をみると，式 (15) の固定点 $\left(1 - \frac{1}{a} \approx 0.73\right)$ にあたる部分がプロットされていないことが分かる．このように，ESN の基本モデルを用いたフリーラン予測では，乱数で値を決める $\boldsymbol{W}^{\text{in}}$ と $\boldsymbol{W}$ の構造によって，図 3 (a) のような入力した時系列を生成する力学系の再現に失敗することがある．しかし，再現に失敗した場合でも，図 3 (b) で示すように，1 ステップ先予測した時系列は高い精度で行われる．

次に，ロジスティック写像の再現に成功した場合（図 2）と，ロジスティック写像の再現に失敗した場合（図 3）について，



(a) 予測値と真の値のリターンマップ　(b) 1 ステップ先予測して得た予測時系列と真の時系列

図 2　ロジスティック写像の再現に成功した例と 1 ステップ先予測の時系列

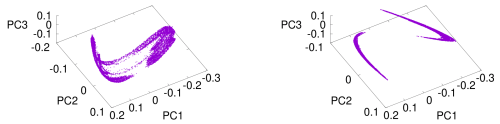


(a) 予測値と真の値のリターンマップ　(b) 1 ステップ先予測して得た予測時系列と真の時系列

図 3　ロジスティック写像の再現に失敗した例と 1 ステップ先予測の時系列

リザバー層の力学系に対して主成分分析を行うことで比較した．主成分分析によって，3 次元に次元を削減した結果を図 4 に示す．図 4 の各軸は第 i 主成分 $PC(i)$ $(i = 1, 2, 3)$ である．また，このときの寄与率を表 2 に示す． 表 2 より，いずれの場合も，第 1 主成分から第 3 主成分の累積寄与率は 99% であり，$N = 100$ 次元のリザバー層の力学系を 3 次元に射影しても情報の損失が少ないことがわかる．また，図 4 (a) より，予測値 $\hat{x}(t)$ がロジスティック写像の再現に成功する場合は，リザバー層の力学系は放物線のようにプロットされることがわかった．この結果は，予測値 $\hat{x}(t)$ だけでなく，リザバー層の力学系も，入力したロジスティック写像の特徴を再現しているものである．一方，図 4 (b) より，予測値 $\hat{x}(t)$ がロジスティック写像の再現に失敗する場合は，予測値 $\hat{x}(t)$ と同様に，リザバー層の力学系にも穴が生じていることがわかった．

ここで，フリーラン予測を行うことでロジスティック写像に再現に成功する場合のリザバー層の力学系が，ロジスティック写像の特徴を捉えていることを定量的に確認するために，最大リアプノフ指数を推定した．ロジスティック写像に再現に成功する場合のリザバー層の力学系に式 (14) を適用した結果を図 5 に示す．図 5 (a) の横軸は局所膨張率を測るための経過時間 k，縦軸は式 (14) における $S(k)$ の値である．また，図 5 (b) の横軸は局所膨張率を測るための経過時間 k，縦軸は $S(k)$ の k の差分を 1 として算出した傾きの推移を表している．傾きの推移が一

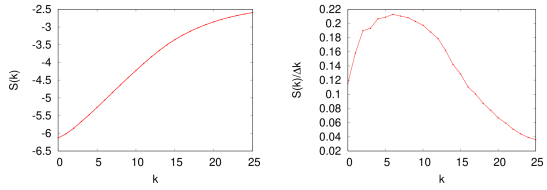


(a) 入力の再現に成功するときの主成分分析　(b) 入力の再現に失敗するときの主成分分析

図 4　ロジスティック写像 $a = 3.7$ に対してフリーラン予測を行った場合のリザバー層の力学系に対する主成分分析の結果

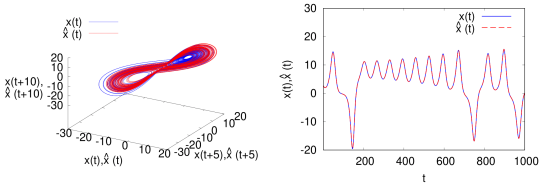
表 2　ロジスティック写像 $a = 3.7$ を予測したときのリザバー層の力学系に対して求めた主成分の寄与率

寄与率	C_1	C_2	C_3	C_4	C_5
図 4 (a)	93.7%	4.7%	1.2%	0.2%	0.1%
図 4 (b)	94.0%	4.0%	1.6%	0.2%	0.1%



(a) リザバー層の力学系に対して式 (14) を適用した結果　(b) 図 5(a) の局所的な傾き

図 5　ロジスティック写像を予測したリザバー層の力学系の最大リアプノフ指数



(a) 再構成次元 $m = 3$, 遅れ時間 $\tau = 5$ (b) 1 ステップ先予測して得た予測時系列とした予測値と真の値のアトラクタ　列と真の時系列

図 6　ローレンツ方程式の再現に成功した例と 1 ステップ先予測の時系列

定となる値が最大リアプノフ指数として推定される．図 5 (b) より，傾きの推移を確認すると，0.21 付近で極大となることがわかる．すなわち，ロジスティック写像を予測したリザバー層の力学系の最大リアプノフ指数は正の値をとること，従って，軌道不安定性を有することが分かる．しかし，パラメータ $a = 3.7$ のロジスティック写像のリアプノフ指数は 0.37 であり，真のリアプノフ指数の値よりも低い結果となった．

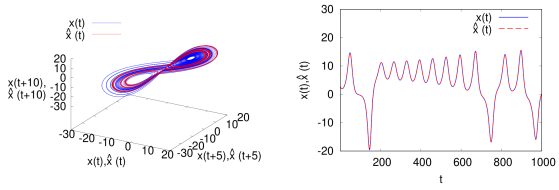
4.2　ローレンツ方程式

次に，ESN の基本モデルを用いてローレンツ方程式のフリーラン予測を行った．ローレンツ方程式を式 (16) に示す．

$$\begin{cases} \dot{x} = & \sigma(-x+y) \\ \dot{y} = & -xz+rz-y \\ \dot{z} = & -xy-wz \end{cases} \tag{16}$$

ここで，パラメータ $\sigma = 10, r = 28, w = 8/3$ とした．初期値を $x(0) = 1.0$, $y(0) = 1.0$, $z(0) = 1.0$ とし，刻み幅 0.02 として 4 次のルンゲクッタ法で解軌道を算出した．過渡状態を除いた時刻 $t = 10,000$ から学習データとして用いた．また，式 (16) の第 1 式により生成された時系列のみ観測した状況を考え，これを学習データとした．

フリーラン予測を行い，リザバー層の力学系がローレンツ方程式のアトラクタの再現に成功した結果を図 6 に示す．図 6 (a) は，入力した時系列を再構成次元 $m = 3$，遅れ時間 $\tau = 5$ で遅延座標系に変換して得たアトラクタであり，入力した真の値 $x(t)$ と予測値 $\hat{x}(t)$ を重ね書きしている．また，図 6 (b) は 1 ステップ先予測により得た予測時系列と真の時系列を示しており，横軸は時刻 t，縦軸は真の値と予測値の状態値 $x(t), \hat{x}(t)$ を示している．図 6 (a) においてもロジスティック写像の結果と同様に，



(a) 再構成次元 $m = 3$, 遅れ時間 $\tau = 5$ (b) 1 ステップ先予測して得た予測時系列とした予測値と真の値のアトラクタ　列と真の時系列

図 7　ローレンツ方程式の再現に失敗した例と 1 ステップ先予測の時系列

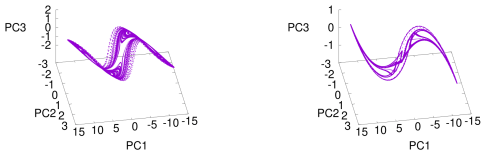
真の値 $x(t)$ から再構成したアトラクタ上に予測値 $\hat{x}(t)$ がプロットされていることから，フリーラン予測によりローレンツ方程式の再現に成功している．また，図 6 (b) より，1 ステップ先予測は予測値 $\hat{x}(t)$ と真の値 $x(t)$ の波形のズレが小さく，正しく予測できていることがわかる．

ローレンツ方程式を対象とした場合もロジスティック写像の場合と同様に，リザバー層の力学系の構造によってはローレンツ方程式の再現が正確に行われない場合がある．その様子を図 7 に示す．図 7 (a) より，予測値 $\hat{x}(t)$ は真の値 $x(t)$ と比較して密度が低いアトラクタとなっており，真の値 $x(t)$ のアトラクタを再現できていないことが分かる．よって，ローレンツ方程式の場合においても，ESN の基本モデルを用いたフリーラン予測では，$\boldsymbol{W}^{\text{in}}, \boldsymbol{W}$ の構造によって，図 7 (a) のように入力した時系列を生成する力学系の再現に失敗することが確認された．しかし，ローレンツ方程式についても，フリーラン予測が失敗した場合でも，図 7 (b) のように 1 ステップ先予測は高い精度で行われる．

次に，ローレンツ方程式の再現に成功した場合（図 6）と，ローレンツ方程式の再現に失敗した場合（図 7）について，リザバー層の力学系に対して主成分分析を適用した．図 8 は，主成分分析によって 3 次元に次元を削減した結果である．図 8 の各軸は第 i 主成分 $PC(i)$ $(i = 1, 2, 3)$ である．また，このときの寄与率を表 3 に示す．表 3 より，いずれの場合も，第 1 主成分から第 3 主成分の累積寄与率は 99% であり，$N = 300$ 次元のリザバー層の力学系を 3 次元に射影しても情報の損失が少ないことがわかる．また，図 8 (a) より，予測値 $\hat{x}(t)$ がローレンツ方程式の再現に成功する場合，リザバー層の力学系ローレンツ方程式のアトラクタのようにプロットされることがわかった．よって，予測値 $\hat{x}(t)$ だけでなく，リザバー層の力学系も，入力したローレンツ方程式の特徴を再現している．この結果は，多次元の力学系から観測された 1 次元の時系列データを学習データとして ESN の基本モデルでフリーラン予測を行うとき，リザバー層の力学系が，入力時系列を生成した力学系を再構成す

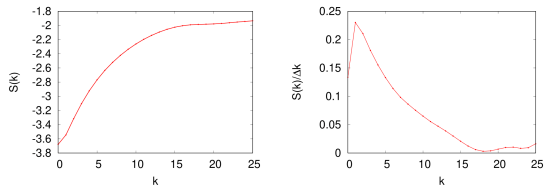
表 3　ローレンツ方程式を予測したときのリザバー層のダイナミクスの主成分分析による寄与率

寄与率	C_1	C_2	C_3	C_4	C_5
図 8 (a)	96.1%	3.3%	0.4%	0.9%	0.4%
図 8 (b)	97.0%	2.5%	0.3%	0.7%	0.5%



(a) 入力の再現に成功するときのリザバー層の主成分分析　(b) 入力の再現に失敗ときのリザバー層の主成分分析

図 8　ローレンツ方程式のフリーラン予測を行ったリザバー層の力学系の主成分分析



(a) リザバー層の力学系に対して式 (14) を適用した結果　(b) 図 9(a) の局所的な傾き

図 9　ローレンツ方程式を予測したリザバー層の最大リアプノフ指数の計算結果

るように機能することで，元の力学系のアトラクタを再現することができていると考える．一方，図 8 (b) より，予測値 $\hat{x}(t)$ がローレンツ方程式の再現に失敗する場合は，予測値 $\hat{x}(t)$ と同様に，密度が低いアトラクタとなることがわかった．

ここで，フリーラン予測を行うことでローレンツ方程式の再現に成功する場合のリザバー層の力学系が，ローレンツ方程式の特徴を捉えていることを定量的に確認するために，最大リアプノフ指数を算出した．ローレンツ方程式の再現に成功する場合のリザバー層の力学系に対して式 (14) を適用した結果を図 9 に示す．図 9 (a) の横軸は局所膨張率を測るための経過時間 k，縦軸は式 (14) における $S(k)$ の値である．また，図 9 (b) の横軸は局所膨張率を測るための経過時間 k，縦軸は $S(k)$ の k の差分を 1 として算出した傾きの推移を表している．図 9 (b) より，傾きの推移を確認すると，0.22 付近で極大となることがわかる．よって，ローレンツを予測したリザバー層の力学系の最大リアプノフ指数は正の値をとり，軌道不安定性を有している．しかし，ローレンツ方程式の最大リアプノフ指数は，0.90 であるため，真の値より低い結果となった．

5. ま と め

本稿では，エコーステートネットワークを用いてカオス性を持つロジスティック写像，ローレンツ方程式のフリーラン予測を行ったときのリザバー層に，どのようなダイナミクスが存在するのかを調査した．主成分分析を適用した結果，リザバー層は入力した時系列のアトラクタを再現することがわかった．また，最大リアプノフ指数を算出した結果，正の値となり，カオス性を有することがわかった．しかし，最大リアプノフ指数は真の最大リアプノフ指数の値よりも低い結果となった．これは，リザバー層の力学系が，ロジスティック写像の場合は $N = 100$ 次元，ローレンツ方程式の場合は $N = 300$ 次元であり，対象とした力学系の次元よりも高いため，過剰な次元に対する偽のリアプノフ指数が存在し [11]，これらが正の値を取った可能性があると考えられる．

以上の結果より，エコーステートネットワークが高精度で予測を行う背景には，リザバー層が埋め込みと同等の機能を有しているためであると考えられる．一方，リザバー層の結合重み行列 $\boldsymbol{W}$ の要素は乱数で与えており，$\boldsymbol{W}$ の設計によってフリーラン予測の結果が異なることがわかった．このことから，予測が成功する場合のリザバー層の構造には，特別な特徴があると考えられる．このような構造の存在とその定量的評価が今後の課題の 1 つである．

謝辞　本研究の一部は，JSPS 科研費（Nos. JP20H00596, JP21H03514, JP22K18419）の援助を受けて行われた．

文　献

[1] 田中剛平, 中根了昌, 廣瀬明, リザバーコンピューティング 時系列パターン認識のための高速機械学習の理論とハードウェア, 森北出版, 2021.

[2] G. Tanaka, T. Yamane, J. B. Héroux, R. Nakane, N. Kanazawa, S. Takeda, H. Numata, D. Nakano, and A. Hirose, "Recent advances in physical reservoir computing: A review," *Neural Networks,* Vol. 115, pp. 100–123, 2019.

[3] D. Li, M. Han, and J. Wang, "Chaotic time series prediction based on a novel robust echo state network," *IEEE Transactions on Neural Networks and Learning Systems,* Vol. 23, No. 5, pp. 787–799, 2012.

[4] H. 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,* Vol. 148, No. 34, 2001.

[5] J. Pathak, Z. Lu, B. R. Hunt, M. Girvan, and E. Ott, "Using machine learning to replicate chaotic attractors and calculate Lyapunov exponents from data," *Chaos,* Vol. 27, No. 12, 2017.

[6] M. Hara, and H. Kokubu, Learning Dynamics by Reservoir Computing (In Memory of Prof. Pavol Brunovský), *Journal of Dynamics and Differential Equations,* 2022, https://doi.org/10.1007/s10884-022-10159-w.

[7] A. Hart, J. Hook, and J. Dawes, "Embedding and approximation theorems for echo state networks," *Neural Networks,* Vol. 128, pp. 234–247, 2020.

[8] M. U. Kobayashi, K. Nakai, Y. Saiki, and N. Tsutsumi, "Dynamical system analysis of a data-driven model constructed by reservoir computing," *Physical Review E,* Vol. 104, No. 4, 044215, 2021.

[9] 池口徹, 山田泰司, 小室元政, カオス時系列解析の基礎と応用, 合原一幸編, 産業図書, 2000.

[10] U. Parlitz, "Estimating Lyapunov exponents from time series," in Chaos detection and predictability, ed. Charalampos (Haris) Skokos, Georg A. Gottwald, and Jacques Laskar, pp. 1–34, *Springer,* 2016.

[11] T. D. Sauer, J. Tempkin, and J. A. Yorke, "Spurious Lyapunov exponents in attractor reconstruction," *Physical Review Letters,* Vol. 81, No. 20 pp. 4341–4344, 1998.

一般社団法人　電子情報通信学会
THE INSTITUTE OF ELECTRONICS,
INFORMATION AND COMMUNICATION ENGINEERS

信学技報
IEICE Technical Report

てんかん患者の脳波データに対する再帰定量化解析

関口　真音[†,††] 池口　　徹[††]

†† 東京理科大学 工学部 情報工学科 東京都葛飾区新宿 6–3–1
E-mail: †mokoto@hisenkei.net

あらまし　本稿では，健常者とてんかん患者の脳波データに対して，非線形力学系理論に基づく時系列解析法を適用することにより，その特性を解析する．はじめに，脳波データを遅延座標系へ変換することでアトラクタを再構成する．その際，遅れ時間の決定に相互情報量を用いることで適切な遅れ時間を算出し，脳波データの特性を比較した．次に，最小の再構成次元を推定し，健常者とてんかん患者で異なる傾向を示すことを明らかにした．また，リカレンスプロットによりアトラクタの構造的特性を可視化し，再帰定量化解析により決定論性を定量的に評価した．この結果，本稿で使用した脳波データに決定論性があることを確認し，てんかん患者は健常者よりも決定論性が強いことが示唆された．

キーワード　非線形時系列解析，脳波，埋め込み，相互情報量，リカレンスプロット

Recurrence quantification analysis on electroencephalographic (EEG) potentials of epileptic seizure

Makoto SEKIGUCHI[†,††] and Tohru IKEGUCHI[††]

†† Department of Information and Computer Technology, Faculty of Engineering,
Tokyo University of Science
6–3–1 Niijuku Katsushika-ku, Tokyo, 125–8585 Japan
E-mail: †mokoto@hisenkei.net

Abstract　In this report, we analyze the characteristics of electroencephalographic (EEG) potentials of healthy individuals and epileptic patients by applying time series analysis method based on the nonlinear dynamical systems theory. First, an attractor is reconstructed by transforming the EEG data into a delay coordinate system. In this process, the appropriate delay time is calculated by using the mutual information. Then, the characteristics of the attractors were visualized by recurrence plots, and determinism was evaluated by recurrence quantification analysis. As a result, we confirmed the determinism of the EEG data used in this report, and suggested that epileptic patients are more deterministic than healthy individuals.

Key words　Nonlinear Time Series Analysis，EEG，Embedding，mutual information，Recurrence Plot

1. はじめに

林 [1]，合原ら [2] によりニューロンがカオス応答を示すことが明らかにされている．また，ニューロン活動をマクロに観測した脳波データもカオス的応答を示す可能性が示唆されている [3]．特に，てんかんなどの疾患における脳波がカオス性を有すること [4]，さらには，その強度が異なることも明らかにされている [5]．てんかんは，神経細胞の異常な興奮に起因する痙攣などの発作を反復する慢性の中枢神経疾患である．てんかんの診療における脳波検査は，診断や治療効果測定，予後の予測に有用であるとされている．てんかん患者では発作時の脳波だけでなく，発作間欠時の脳波も特有の所見が見られることがあるため，重要なデータとなる．そのため，発作中と非発作時の脳波データに対する解析が行われている [6]．その際，脳波データから再構成状態空間への変換で用いられる遅れ時間の大きさと再構成状態空間の次元に関する種々の検討が必要である．

本稿では，健常者の脳波データ，てんかん患者の発作時および非発作時の脳波データに対して非線形力学系理論に基づく時系列解析を適用する．まず，計測された 1 変数の脳波データから高次元空間における力学系のアトラクタを再構成する必要がある．そこで本稿では，脳波データを時間遅延座標系へ変換し，アトラクタを再構成した．観測時系列から再構成状態空間への変換では，遅れ時間の大きさと再構成状態空間の次元を適切に決定する必要がある．遅れ時間の決定手法では，自己相関

This article is a technical report without peer review, and its polished and/or extended version may be published eleswhere.
Copyright ©20xx by IEICE

関数を用いる手法，相互情報量を用いる手法が広く知られている．本稿では，非線形性を正確に評価することのできる相互情報量による遅れ時間の設定を採用した [7]．また，再構成次元の設定には，Cao の手法を導入した [8]．

本稿では，再構成したアトラクタに対する解析手法として，リカレンスプロット (Recurrence Plot，以下 RP) [9] を用いている．RP は，解析対象データの 2 点間距離の変化を視覚化することで，そのダイナミクスを定性的に把握することができる．また，時系列信号の有する非定常性の検出に優れている．この手法では，元の時系列から再構成したアトラクタ上の各点間の相関関係を 2 次元の 2 値画像に可視化する．RP による力学系の定量化を再帰定量化解析 (Recurrence Quantification Analysis，以下 RQA) [10] という．様々な RQA 指標の一つに決定論性の評価指標である Determinism (DET) がある．DET は，再構成アトラクタに決定論的な構造が存在すると高い値となり，データが有する周期性や規則性を評価することができる．本稿では，時間遅延座標系の適切なパラメータを調査し，推定されたパラメータで算出した DET の比較を行った．

2. 解 析 手 法

2.1 再構成状態空間

脳波データに非線形力学系理論に基づく時系列解析法を適用するため，脳波データを時間遅れ座標系に変換する．具体的には，時系列長 n の脳波データ x_t $(t = 1, \cdots, n)$ を，再構成次元 m，遅れ時間 τ として，式 (1) により再構成状態空間ベクトル $\boldsymbol{v}_t(m)$ に変換する．

$$\boldsymbol{v}_t(m) = (x_t, x_{t+\tau}, \cdots, x_{t+(m-1)\tau}) \quad (t = 1, 2, \cdots, n-(m-1)\tau) \tag{1}$$

2.1.1 遅れ時間の決定

式 (1) の時間遅延座標系を用いる場合，遅れ時間 τ を適切に設定する必要がある．本稿では，遅れ時間 τ を相互情報量により決定した．確率変数を $X_i (i = 1, 2, \cdots, L)$，$X_i$ が計測される確率を $p(X_i)$，確率変数を $Y_j (j = 1, 2, \cdots, M)$，$Y_j$ が計測される確率を $p(Y_j)$ とする．$p(X_i)$ と $p(Y_j)$ の同時確率を $p(X_i, Y_j)$ で表すと，X_i と Y_i の相互情報量 I は式 (2) で示される．

$$I = \sum_{i=1}^{L} \sum_{j=1}^{M} p(X_i, Y_j) \log \frac{p(X_i, Y_j)}{p(X_i) p(Y_j)} \tag{2}$$

実際には，X_i を x_i とし，Y_j を $x_{j+\tau}$ とすることで，x_i と $x_{j+\tau}$ の相互情報量 $I(\tau)$ を算出する．また，τ の値を変化させ，$I(\tau)$ が最初に極小値をとる時間を，式 (1) の時間遅延座標の遅れ時間 τ_0 とする [7]．

2.1.2 再構成次元の決定

本稿では，Cao の手法 [8] により，再構成次元を推定した．$\boldsymbol{v}_i(m)$ は第 i 番目の m 次元の再構成ベクトル，$n(i, m)$ は $\boldsymbol{v}_i(m)$ の最近傍点のインデックスを表す．このとき，式 (3) の $a(i, m)$ を算出する．

$$a(i, m) = \frac{\|\boldsymbol{v}_i(m+1) - \boldsymbol{v}_{n(i,m)}(m+1)\|}{\|\boldsymbol{v}_i(m) - \boldsymbol{v}_{n(i,m)}(m)\|} \tag{3}$$

ここで，$||\cdot||$ はユークリッド距離を示す．式 (3) は，m 次元における $\boldsymbol{v}_i(m)$ の最近傍点 $\boldsymbol{v}_{n(i,m)}(m)$ が $m+1$ 次元になったとき，どのくらい近傍でなくなるかを表す．また，$a(i, m)$ の平均値 $E(m)$ は，式 (4) で計算される．

$$E(m) = \frac{1}{n - m\tau} \sum_{i=1}^{n-m\tau} a(i, m) \tag{4}$$

さらに，m 次元から $m+1$ 次元への $E(m)$ の変化である $E_1(m)$ を式 (5) に示す．

$$E_1(m) = E(m+1)/E(m) \tag{5}$$

決定論的なデータの場合，m を大きくしたとき $E_1(m)$ が収束する．そこで，このときの m_0 を最小の再構成次元とする．本稿では，$|E_1(m+1) - E_1(m)| \leq \Theta$ のとき $E_1(m)$ が収束したとした．その際，$\Theta = 10^{-1}, 10^{-2}, 10^{-3}$ について検討を行った．なお，ランダムデータの場合，$E_1(m)$ は理論的には収束しないが，m が十分に大きいとき，$E_1(m)$ がゆっくり増加しているのか，変化が止まっているかを判断することが困難となる場合がある．そこで，式 (6) の指標を定義する．

$$E^*(m) = \frac{1}{n - m\tau} \sum_{i=1}^{n-m\tau} |x_{i+m\tau} - x_{n(i,m)+m\tau}| \tag{6}$$

式 (6) から，式 (7) が算出される．

$$E_2(m) = E^*(m+1)/E^*(m) \tag{7}$$

ランダムデータは過去の値は将来の値と独立しているため，$E_2(m)$ はどの m に対しても 1 に等しくなる．一方，決定論的なデータでは，$E_2(m) \neq 1$ となる m がいくつか存在する．

2.2 リカレンスプロット

RP は，アトラクタの構造的特性を可視化する解析手法である．アトラクタ上の 2 点間相関を 2 次元の 2 値画像として表現する．式 (1) で生成した m 次元再構成アトラクタ上の 2 点間距離 $d^m_{i,j}$ は，式 (8) で定義される．

$$d^m_{i,j} = ||\boldsymbol{v}_i(m) - \boldsymbol{v}_j(m)|| \tag{8}$$

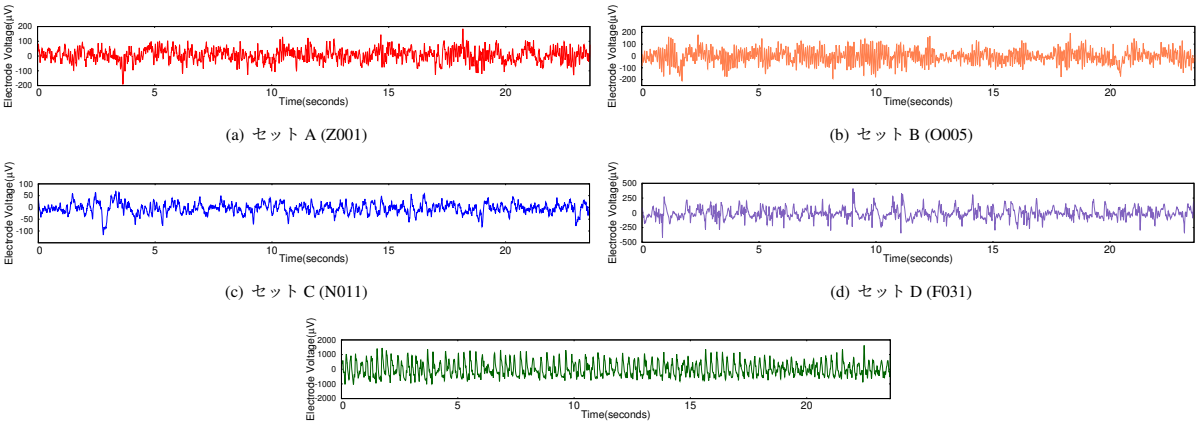
RP の (i, j) 番目の画素値 $P_{i,j}$ は，2 点間距離の閾値を θ_r として式 (9) により決定される．

$$P_{i,j} = \begin{cases} 1 & (\text{if } d^m_{i,j} \leq \theta_r) \\ 0 & (\text{otherwise}) \end{cases} \tag{9}$$

なお，本稿では，式 (10) のように 2 点間距離の最大値 $d^m_{\max}$ の 10^r 倍として θ_r を定義し，r を変化させることで解析を行った．

$$\theta_r = 10^r \cdot d^m_{\max} \tag{10}$$

本稿では，RP による決定論性の定量的化評価として式 (12) の決定論性指標 D を用いる．D は，RP 上に打たれた点の総数



(a) セット A (Z001)

(b) セット B (O005)

(c) セット C (N011)

(d) セット D (F031)

(e) セット E (S028)

図 1　使用した脳波データの例

K に対して，45 度の傾きの斜め線を構成する点の割合から算出される．RP 上の長さ l の斜め線の数 $S(l)$ は，式 (11) で定義される．

$$S(l)=\begin{cases}\displaystyle\sum_{j=2}^{N-l}(1-P_{i+l,j+l})\prod_{k=0}^{l-1}P_{i+k,j+k} & (i=1)\\ \displaystyle\sum_{i=2}^{N-l-1}\sum_{j=i+1}^{N-l}(1-P_{i-1,j-1})(1-P_{i+l,j+l})\prod_{k=0}^{l-1}P_{i+k,j+k} & (i\geq 2)\end{cases} \tag{11}$$

RP は対称行列であるため，式 (11) では $i<j$ としている．ここで，$N=n-(m-1)\tau$ である．このとき，決定論性指標 D は式 (12) で定義できる．

$$D=\frac{1}{K}\sum_{l=l_{\min}}^{N-1}lS(l)=\frac{\sum_{l=l_{\min}}^{N-1}lS(l)}{\sum_{l=1}^{N-1}lS(l)} \tag{12}$$

式 (12) の $l_{\min}$ は，斜め線の最小の長さを表し，本稿では $l_{\min}=2$ とする．また，RP の対角線の 2 点間距離は $d^m_{i,i}=0$ であるが，これは同一点の距離であるため斜め線の数には含めない．

3.　脳波データ

本稿で使用したデータは，ドイツのボン大学てんかんセンターでオンライン公開されている健常者とてんかん患者の脳波データである [11]．図 1 に，5 セットの時系列の例を示す．図 1 で示されている Z001，O005，N011，F031，S028 はデータの番号である．

図 1(a) は開眼時の健常者（セット A），図 1(b) は閉眼時の健常者（セット B），図 1(c) は非発作時のてんかん患者（原性領域の反対半球のデータ，セット C），図 1(d) は非発作時のてんかん患者（原性領域の半球のデータ，セット D），図 1(e) は発作時のてんかん患者の脳波データである（セット E）．このデータ セットにおける てんかん患者は，側頭葉てんかんと診断されている．各セットには，100 個のデータが含まれている．また，一つの脳波データは，173.61Hz で 23.6 秒間サンプリングされた長さ $n=4,097$ のデータである．

4.　解 析 結 果

4.1　遅れ時間値の推定

遅れ時間値 τ を $0\leq\tau\leq 50$ で変化させたときの相互情報量の変化を図 2 に示す．図 2 の結果は，各セットの平均である．また，各データに対して決定した遅れ時間値の分布を図 3 に示す．さらに，これより算出した遅れ時間値の平均と標準偏差を表 1 に示す．

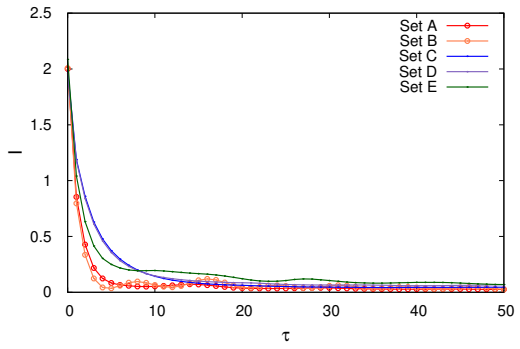


図 2　遅れ時間を変化させたときの相互情報量

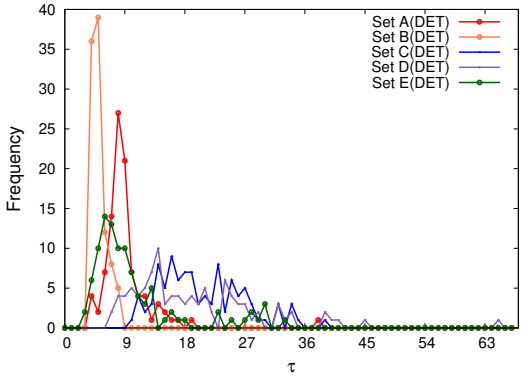
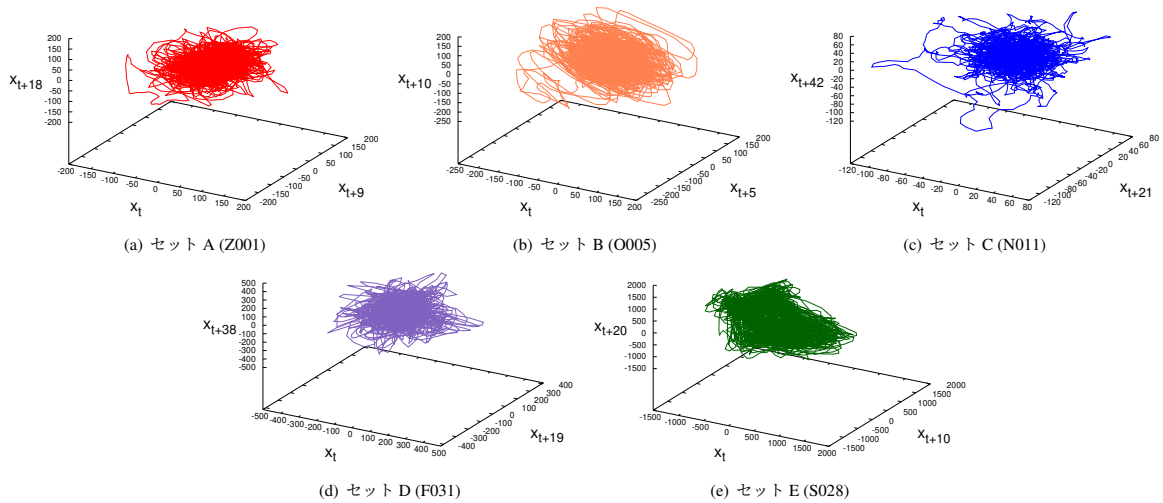


図 3　遅れ時間の分布



(a) セット A (Z001)　(b) セット B (O005)　(c) セット C (N011)

(d) セット D (F031)　(e) セット E (S028)

図 4　脳波の再構成アトラクタ

表 1　遅れ時間の平均と標準偏差

セット	健常者		てんかん患者		
	A	B	C	D	E
平均	9.08	5.07	20.55	19.38	10.28
標準偏差	2.94	1.12	6.29	9.64	6.93

図 2 の相互情報量の変化に注目すると，非発作時のてんかん患者 (セット C，セット D) では，遅れ時間に対する相互情報量の変化が単調減少であるのに対して，健常者と発作中てんかん患者の 3 つセット (セット A，セット B，セット E) は，遅れ時間に対する相互情報量の変化に揺らぎがある．このため，非発作時のてんかん患者の遅れ時間が大きくなると考えられる．また，てんかん患者 (セット C，セット D，セット E) の標準偏差の値は，健常者 (セット A，セット B) の標準誤差の値と比べて大きい．この結果は，てんかん患者の脳波データはデータ間に個人差があることを示唆するものである．

図 3 では，健常者 (セット A，セット B) と発作中のてんかん患者 (セット E) の遅れ時間の分布は近いことが分かる．また，非発作時のてんかん患者 (セット C，セット D) の遅れ時間の分布は形状が似ていることも分かる．また，表 1 より，開眼時の健常者 (セット A) と発作中のてんかん患者 (セット E) では，遅れ時間の平均値がほぼ一致していることが分かる．さらに，非発作時のてんかん患者 (セット C，セット D) の遅れ時間に注目すると遅れ時間の平均値の間には有意差はなく，てんかんの原性領域か否かは遅れ時間に大きな影響を与えないと考えられる．

遅れ時間を表 1 に基づき決定し，脳波の時系列を 3 次元の再構成状態空間に変換した結果を図 4 に示す．5 つのセットの 3 次元のアトラクタから，視覚的に空間的構造の特徴を得ることは困難である．

4.2　再構成次元の推定

再構成次元 m を $1 \leq m \leq 25$ としたときの $E_1(m)$ の推移を図 5 に示す．また，$E_1(m)$ の結果に対して収束判定を $\Theta = 10^{-1}$

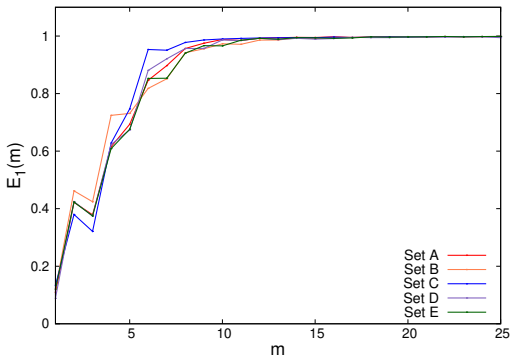


図 5　再構成次元を変化させたときの指標 $E_1(m)$ の推移

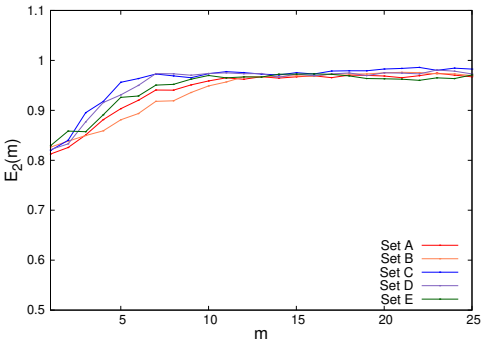
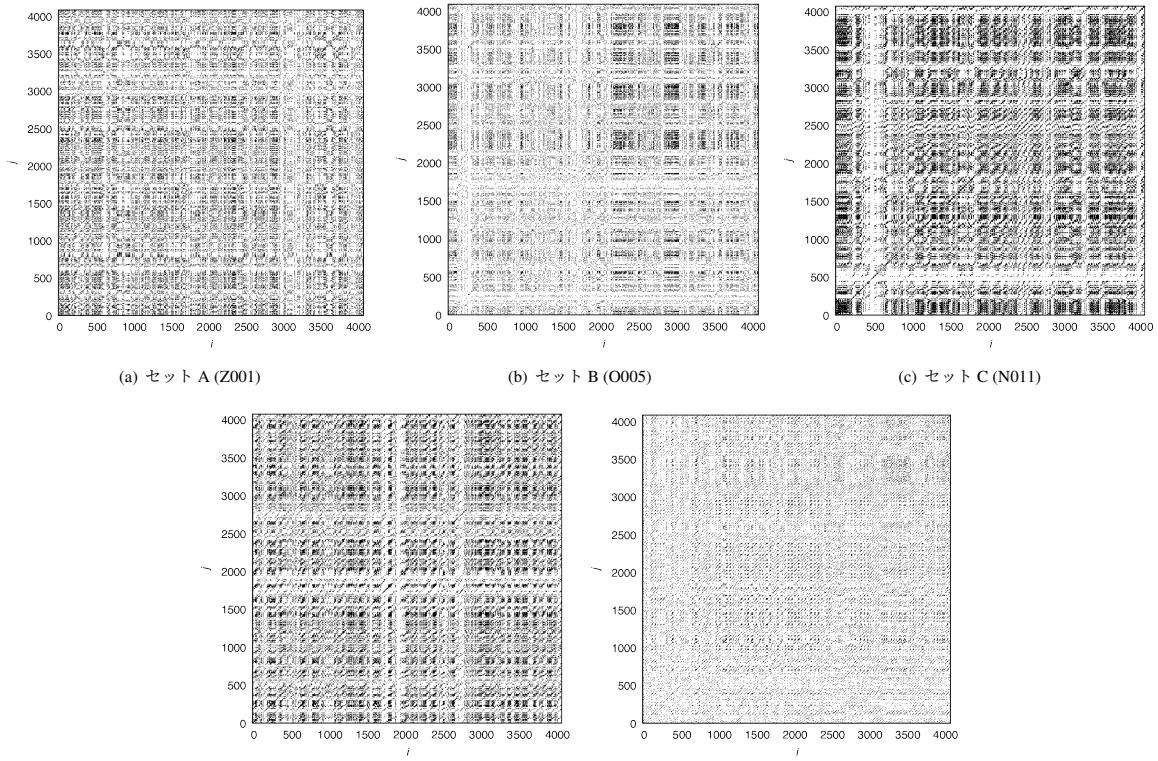


図 6　再構成次元を変化させたときの指標 $E_2(m)$ の推移

, 10^{-2}, 10^{-3} として推定される最小埋め込み次元を表 2 に示す．さらに，再構成次元を m を $1 \leq m \leq 25$ としたときの $E_2(m)$ の推移を図 6 に示す．

図 5 をみると，5 つのセット全てに対して指標 $E_1(m)$ が 1 に収束していることが分かる．また，図 6 では，全てのセットが $E_2(m) \neq 1$ となっており，対象としたデータはランダムではない．したがって，指標 $E_1(m)$ から，最小埋め込み次元が推定できる．表 2 において $\Theta = 10^{-1}$ として収束判定をした場合，図



(a) セット A (Z001)　(b) セット B (O005)　(c) セット C (N011)

(d) セット D (F031)　(e) セット E (S028)

図 7　脳波データの RP

表 2　$|E_1(m+1) - E_1(m)| \leq \Theta$ とした最小埋め込み次元の平均

Θ		10^{-1}	10^{-2}	10^{-3}
健常者	A	4.56	9.29	15.23
	B	3.75	8.87	15.23
てんかん患者	C	3.81	8.77	12.36
	D	3.64	8.5	13.3
	E	2.23	8.82	16.71

5 では収束していない値が最小埋め込み次元として推定されてしまうため，この収束判定は適切ではない．一方，図 5 をみると表 2 において $\Theta = 10^{-2}$ と $\Theta = 10^{-3}$ として得られた最小埋め込み次元は，1 に収束している．そこで，$\Theta = 10^{-2}$ を収束判定として採用した．

4.3　再帰定量化解析

遅れ時間を表 1 に基づき決定し，再構成次元 $m = 2$ としたときの RP を図 7 に示す．ただし，閾値は $r = -1$ としている．

相互情報量を用いて決定した遅れ時間と，Cao の手法により推定された再構成次元を適用して，全てのセットの決定論性指標 D を計算した．このとき，RP の閾値 r に対して平均した結果を図 8 に示す．また，決定論性指標 D と同じ閾値でプロットされる割合 K/N^2 を図 9 に示す．

図 8 の結果では，全ての閾値で，てんかん患者 (セット C, セット D，セット E) の決定論性指標 D は，健常者 (セット A, セット B) の決定論性評価指標 D より大きくなる．これより，

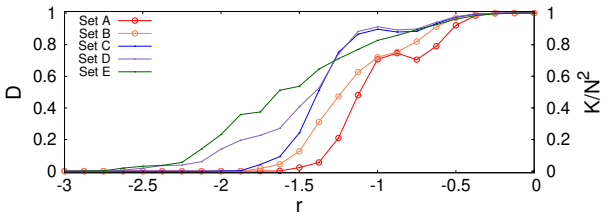


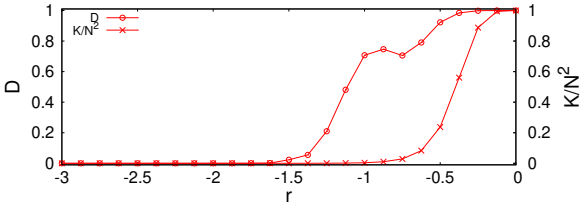
図 8　決定論性指標 D

表 3　プロットされる点の数 k が 50% を超えるときの決定論性指標 D の値

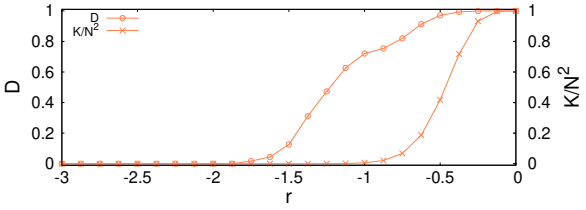
セット	健常者		てんかん患者		
	A	B	C	D	E
D	0.99	0.99	0.98	0.99	0.98

てんかん患者は健常者よりも決定論性が強いと示唆される．

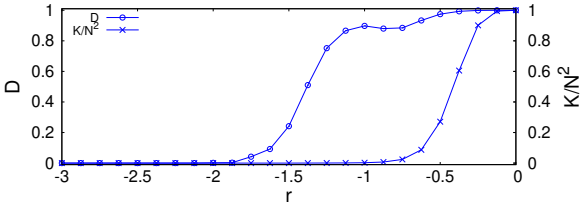
図 9 では，全てのセットについて，プロットされる点の数の割合 K/N^2 が 50% を超えるためには，閾値を $r = -0.375$ より大きく設定する必要があることが分かる．プロットされる点の数の割合 K/N^2 が 50% を超える $r = -0.375$ について，決定論性指標 D の結果を表 3 に示す．表 3 より，全てのセットが 1 に近く，脳波データが決定論的があることが示唆された．



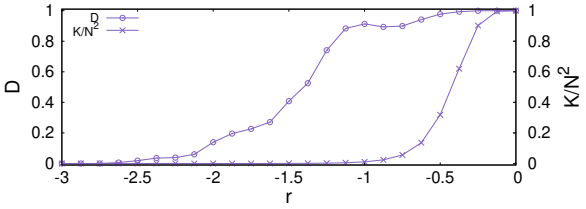
(a) セット A (開眼時の健常者)



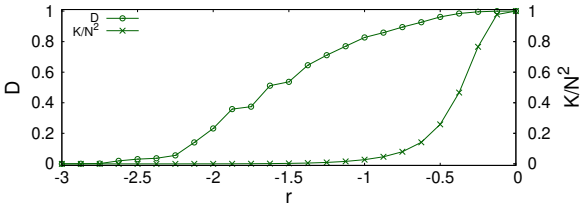
(b) セット B (閉眼時の健常者)



(c) セット C (非発作時のてんかん患者 原性領域の反対半球)



(d) セット D (非発作時のてんかん患者 原性領域の半球)



(e) セット E (発作時のてんかん患者)

図 9　RP の閾値を変化させたときの決定論性指標 D とプロットされる割合

5. ま と め

本稿では，健常者とてんかん患者の脳波データに対して，非線形力学系理論に基づく時系列解析を用いた解析を行った．また，時間遅延座標系に変換する際，遅れ時間と再構成次元の推定を行った．さらに，RP に対する再帰定量化解析を行い，決定論性を評価した．

まず，相互情報量に基づく遅れ時間の推定結果から，健常者と発作中のてんかん患者の脳波データでは，算出された遅れ時間値がほぼ同じ値となり，類似した性質を有することが明らかになった．一方，てんかん患者の非発作時と発作中の脳波データの遅れ時間は，異なる値となることもわかった．次に，再構成次元の推定結果から，健常者とてんかん患者の次元に僅かな差があることを確認した．さらに，RP から決定論性指標を算出し，脳波データの決定論性を調査した．その結果，てんかん患者の脳波データの決定論性の強さは，健常者の脳波データよりも強いことが明らかになった．

謝辞　本研究の一部は，JSPS 科研費（No. JP20H00596, JP21H03514，JP22K18419）の援助を受けて行われた．

文　献

[1] H. Hayashi, S. Ishizuka, M. Ohta, and K. Hirakawa, “Chaotic behavior in the onchidium giant neuron under sinusoidal stimulation,” *Physics Letters A*, Vol. 88, No. 8, pp. 435–438, 1982.

[2] K. Aihara, T. Numajiri, G. Matsumoto, and M. Kotani, “Structures of attractors in periodically forced neural oscillators, ” *Physics Letters A*, Vol. 116, No. 7, pp. 313–317, 1986.

[3] T. Ikeguchi, K. Aihara, S. Itoh, and T. Utsunomiya, “An analysis on Lyapunov spectrum of electroencephalographic (EEG) potentials,” *IEICE TRANSACTIONS (1976-1990)*, Vol. 73, No. 6, pp. 842–847, 1990.

[4] A. Babloyantz, A. Destexhe, “Low-dimensional chaos in an instance of epilepsy,” *Proceedings of the National Academy of Sciences*, Vol. 83, No. 10, pp. 3513–3517, 1986.

[5] K. Schindler, H. Gast, L. Stieglitz, A. Stibal, M.Hauf, R. Wiest, L. Mariani, and C. Rumme, “Forbidden ordinal patterns of periictal intracranial EEG indicate deterministic dynamics in human epileptic seizures,” *Epilepsia*, Vol. 52, No. 10, pp. 1771–1780, 2011.

[6] H. Adeli, S. Ghosh-Dastidar, and N. Dadmehr, “A wavelet-chaos methodology for analys is of EEGs and EEG subbands to detect seizure and epilepsy,” *IEEE Transactions on Biomedical Engineering*, Vol. 54, No. 2, pp. 205–211, 2007.

[7] A. M. Fraser, “Reconstructing attractors from scalar time series: A comparison of singular system and redundancy criteria,” *Physica D: Nonlinear Phenomena*, Vol. 3, No. 3, pp. 391–404, 1989.

[8] L. Cao, “Practical method for determining the minimum embedding dimension of a scalar time series,” *Physica D: Nonlinear Phenomena*, Vol. 110, Nos. 1–2, pp. 43–50, 1997.

[9] J. -P. Eckmann, S. Oliffson Kamphorst, and D. Ruelle, “Recurrence plot of dynamical systems,” *World Scientific SeriesonN onlinear Science Series A*, Vol. 16, pp. 441–446, 1995.

[10] N. Marwan, M. Carmen Romano, M. Thiel, and J. Kurths, “Recurrence plots for the analysis of complex systems,” *Physics Reports*, Vol. 438, No. 5–6, pp. 237—329, 2007.

[11] R. G. Andrzejak, K. Lehnertz, F. Mormann, C. Rieke, P. David, and C. E. Elger, “Indications of nonlinear deterministic and finite-dimensional structures in time series of brain electrical activity: Dependence on recording region and brain state,” *Physical Review E*, Vol. 64, No. 6, 061907, 2001.

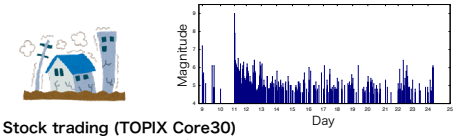
Detecting causality for marked point processes with twin surrogate method

○Kazuya Sawada (sawada@hisenkei.net) and Tohru Ikeguchi
Department of Information and Computer Technology, Graduate School of Engineering, Tokyo University of Science

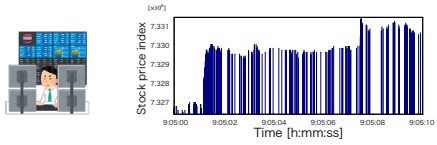
1. Introduction

Marked point process (MPP)
→ Event series with marked values

・Earthquake (2011/03/11)



・Stock trading (TOPIX Core30)

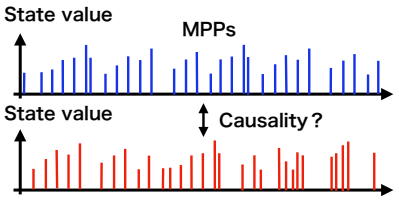


We often observe various MPPs.

2. Position of this study

System / Data type	Stochastic system	Nonlinear deterministic dynamical system
Time series	Granger causality [1] Transfer entropy [2]	Convergent cross mapping [3]
Point process	Transfer entropy [2]	Proposed method for spike trains [4]
Marked point process		This study

3. Purpose

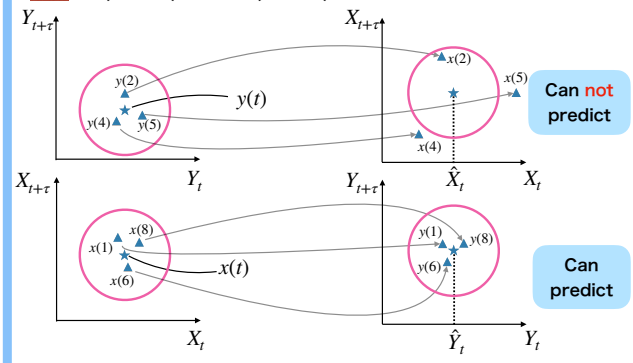


Development of causality detection method for MPPs
→ We propose extended method of CCM

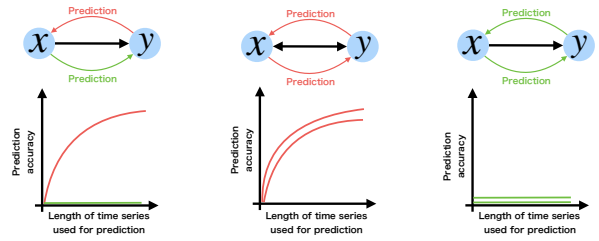
4. Convergent cross mapping (CCM) [3]

Detecting causality method based on mutual predictability

e.g. Y (Cause) ⟶ X (Result)

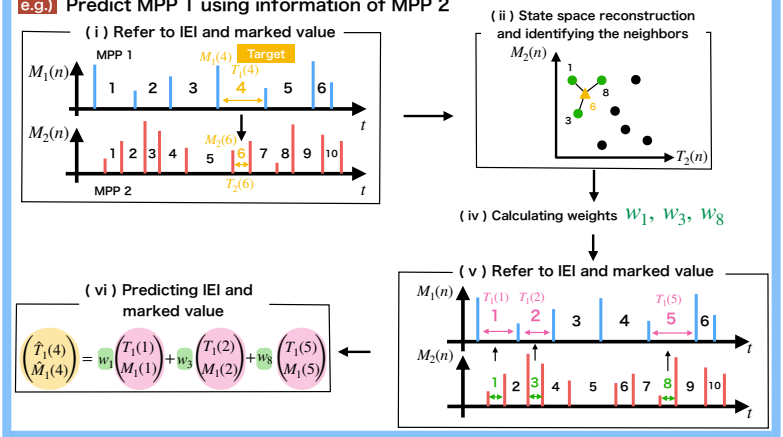


unidirectional coupling | bidirectional coupling | non-coupling



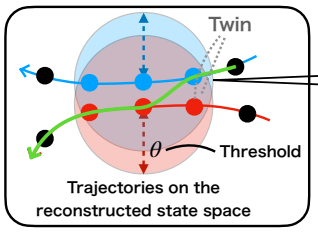
5. Proposed method of mutual prediction for MPPs [5]

e.g. Predict MPP 1 using information of MPP 2



6. Twin surrogate method [6]

A method for generating alternative time series that destroys temporal order while preserving information as a nonlinear dynamical system, especially flow.



Twin: Points sharing the same neighborhood

Probabilistic transition to next index or next index of twin
↓
Flow are not destroyed

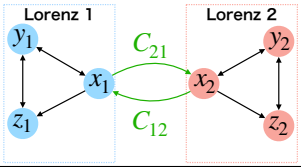
Detecting causality using statistical hypothesis testing with TS data

7. Generating method of MPPs with causality

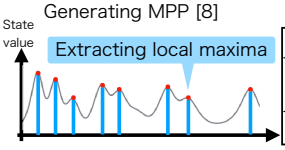
Coupled Lorenz system [7]

$$\begin{cases} \dot{x}_1 = \sigma_1(y_1 - x_1) + C_{12}(x_2 - x_1), \\ \dot{y}_1 = r_1 x_1 - y_1 - x_1 z_1, \\ \dot{z}_1 = -b_1 z_1 + x_1 y_1, \end{cases} \quad \begin{cases} \dot{x}_2 = \sigma_2(y_2 - x_2) + C_{21}(x_1 - x_2), \\ \dot{y}_2 = r_2 x_2 - y_2 - x_2 z_2, \\ \dot{z}_2 = -b_2 z_2 + x_2 y_2. \end{cases}$$

Causality between variables

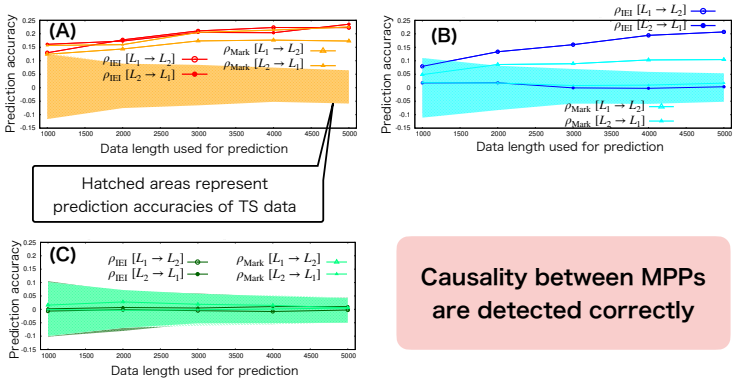


Generating MPP [8]



(A) Bidirectional case	$C_{12} = C_{21} = 1.5$
(B) Unidirectional case ($L_1 \to L_2$)	$C_{12} = 0,\ C_{21} = 1.5$
(C) Non-coupling case	$C_{12} = C_{21} = 0$

8. Results



Hatched areas represent prediction accuracies of TS data

Causality between MPPs are detected correctly

Acknowledgment

This research was supported by JSPS KAKENHI Grant Numbers JP22KJ2815, JP20H00596, JP21H03514, and JP22K18419 and Cooperative Research Projects (R02/A31 and R05/B13) of Research Institute of Electrical Communication, Tohoku University.

References

[1] C. W. Granger, *Econometrica,* **37** (3): 424–438, 1969.
[2] T. Schreiber, *Phys. Rev. Lett.,* **85** (2): 461–464, 2000.
[3] G. Sugihara et al., *Science*, **338** (6106): 496—500, 2012.
[4] K. Sawada et al., submitted to Phys. Rev. E.
[5] 澤田 他, 信学技報, **121** (436): 89–94, 2023.
[6] M. Thiel et al., *EPL*, **75**: 535–541, 2006.
[7] V. Anishchenko, et. al., *Phys. Rev. E*, **57** (1): 316–322, 1998.
[8] N. Yabuta, et. al., *Proc. of 2007 Int. Symp. on NOLTA*, 16–19, 2007.

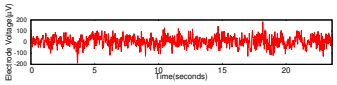
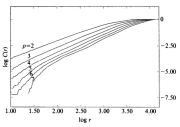
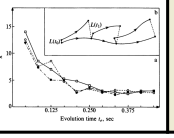
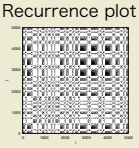
Deterministy of electroencephalogtaphic (EEG) potentials of epileptic seizure

B-37

Makoto Sekiguchi Tohru Ikeguchi

Department of Information and Computer Technology, Facility of Engineering, Tokyo University of Science

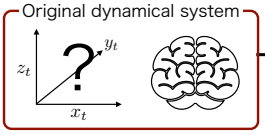
1. Introduction

	Previous research [1][2]		This research
EEG data			
A chaotic dynamical systems	Selif-similarity	Orbital instability	Determinisity
Analysis Method	Correlation dimension 	Lyapunov exponent 	Recurrence plot 

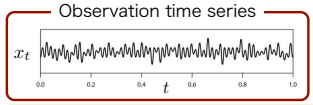
Analysis of determinism in healthy subjects and epileptic patients

2. Detecting Determinism using Recurrence plot

Original dynamical system



Observation time series

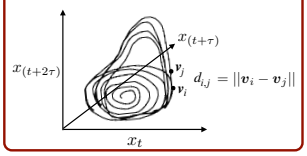


Reconstruction of attractor through time delay [3][4]

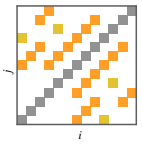
$$\boldsymbol{v}_t(m) = \left(x_t, x_{t+\tau}, \cdots, x_{t+(m-1)\tau}\right)$$

τ: time delay, m :embedding dimension

Reconstructed state space



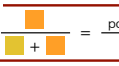
Recurrence plot [5]



$$P_{i,j} = \begin{cases} 1 & (\text{if } d_{i,j} \le \theta_r) \\ 0 & (\text{otherwise}) \end{cases}$$

$$R = \frac{\text{All recurrence points}}{\text{Total number of pixels}}$$

DET (Determinism) [6]

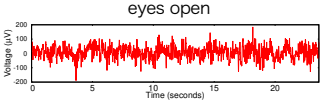


$$\text{DET} = \frac{\text{points from diagonal lines}}{\text{All recurrence points}}$$

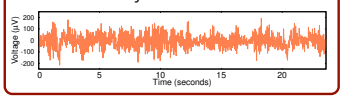
3. Data [7]

Healthy subjects

Set A
eyes open

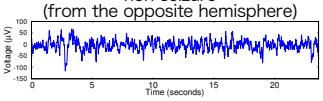


Set B
eyes closed

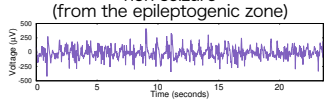


Epileptic subjects

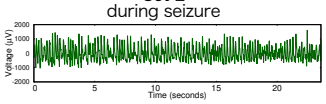
Set C
non-seizure
(from the opposite hemisphere)



Set D
non-seizure
(from the epileptogenic zone)



Set E
during seizure



The number of sets	5
The number of files in a set	100
Data length of one file	4,097
Sampling frequency	173.6Hz
Measuring time	23.6s

4. How to decide τ and m ?

Time delay τ [8]

Set	Healthy subjects		Epileptic subjects		
	Eyes open	Eyes closed	Interval (Opposite hemisphere)	Interval (Epileptogenic zone)	Seizure
	A	B	C	D	E
Average	9.08	5.07	20.55	19.38	10.28
Standard deviation	2.94	1.12	6.29	9.64	6.93

Time delay for healthy subjects and epileptic subjects are close

Embedding dimension m [9]

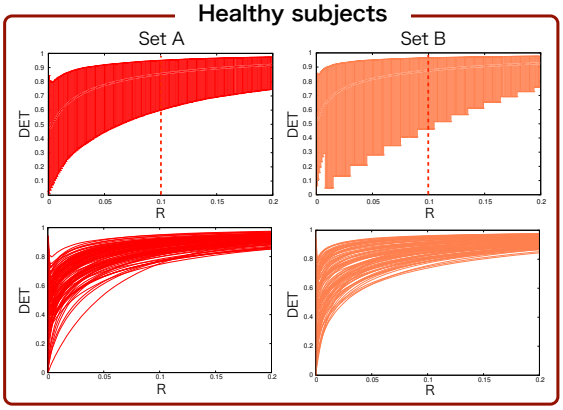
Set	Healthy subjects		Epileptic subjects		
	Eyes open	Eyes closed	Interval (Opposite hemisphere)	Interval (Epileptogenic zone)	Seizure
	A	B	C	D	E
Average	9.29	8.87	8.77	8.5	8.82
Standard deviation	2.74	2.86	1.64	2.42	3.9

No difference between healthy subjects and epileptic subjects

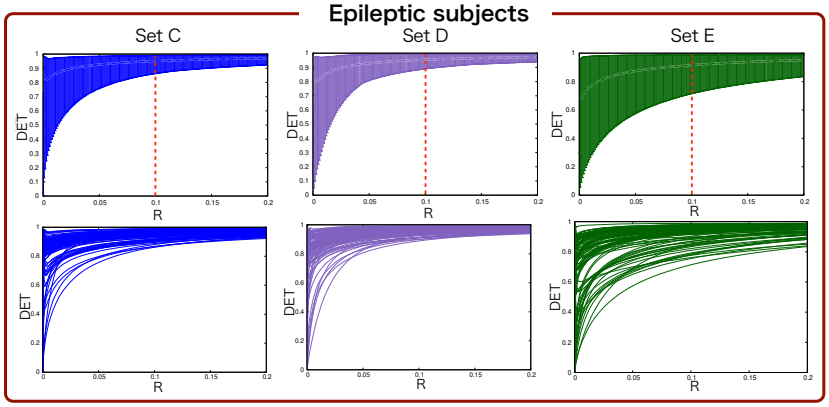
5. DET (Determinism)

Epileptic subjects are more deterministic than healthy individuals

Healthy subjects



Epileptic subjects



6. Conclusion

Time delay	Time delay values for healthy subjects and epileptic subjects are close
Embedding dimension	No difference between healthy subjects and epileptic subjects
Determinism	Epileptic subjects are more deterministic than healthy individuals

Acknowledgment

This research was supported by JSPS KAKENHI Grant Numbers JP20H00596, JP21H03514, and JP22K18419 and Cooperative Research Projects (R02/A31 and R05/B13) of Research Institute of Electrical Communication, Tohoku University.

References

[1] H. Adeli et al.,*IEEE Trans Biomed Eng*, 54, 2, 205-211, 2007.
[2] A. Bobloyantz et al., *Proc Natl Acas Sci*, **83**, 10, 3513-3517, 1986.
[3] F. Takens, *Dynamical System and Turbulence*, **898**, 366–381,1981.
[4] T. Sauer et al., *J. Stat. Phys.*, **65**, 579–616,1991.
[5] J. -P. Eckmann et al., *Europhys. Lett.*, **4**, 937–977,1987.
[6] N.Marwan et al., *Phys. Reports*, **438**, 5–6, 237–329, 2007.
[7] Andrzejak RG et al., *Phys. Rev*, **64**, 5–6, 061907, 2001.
[8] A .M .Fraser et al., *Phys. D*, **3**, 3, 391–404, 1989.
[9] L. Cao, *Phys. D*, **110,** 1–2, 43–50,1997.
[10] 関口 真音, 池口 徹, 電子情報通信学会技術研究報告, **123**, 287, 21–26, NLP2023-64, 2023.

B-37

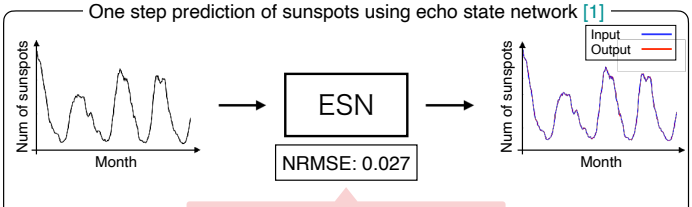
Dynamics of reservoir layer in time series prediction

○Shion Yoshida Tohru Ikeguchi

Department of Information and Computer Technology, Facility of Engineering, Tokyo University of Science

1. Introduction

One step prediction of sunspots using echo state network [1]



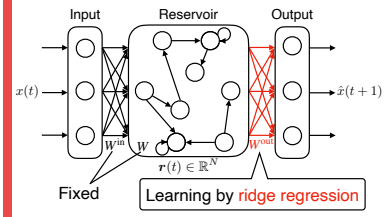
How to predict with high accuracy?

Purpose: Clarify the working principle to predict time series with high accuracy

Analysis focused on dynamics of reservoir layer

2. Echo state network [2]

● One step prediction (training phase)



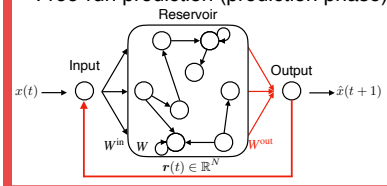
State update equations

$$\begin{cases} \boldsymbol{r}(t+1) = \boldsymbol{f}\left(\boldsymbol{W}^{\text{in}} x(t) + \boldsymbol{W}\boldsymbol{r}(t)\right) \\ \hat{x}(t+1) = \boldsymbol{W}^{\text{out}} \boldsymbol{r}(t+1) \end{cases}$$

Where:

$x(t)$	is input value
$\boldsymbol{r}(t)$	is reservoir state vector
$\hat{x}(t)$	is output value
$\boldsymbol{W}^{\text{in}}$	is input weighting matrix
$\boldsymbol{W}$	is reservoir weighting matrix
$\boldsymbol{W}^{\text{out}}$	is output weighting matrix

● Free-run prediction (prediction phase)



$$x(t+1) = \hat{x}(t+1) = \boldsymbol{W}^{\text{out}} \boldsymbol{r}(t+1)$$

State update equation

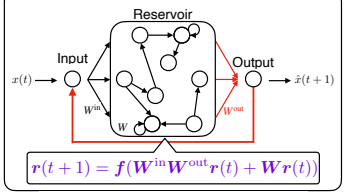
$$\boldsymbol{r}(t+1) = \boldsymbol{f}(\boldsymbol{W}^{\text{in}} \boldsymbol{W}^{\text{out}} \boldsymbol{r}(t) + \boldsymbol{W}\boldsymbol{r}(t))$$

Autonomous dynamical system

→Dynamical system of reservoir layer

3. Experiment prodedures

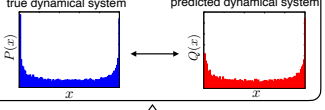
(1) Free-run prediction



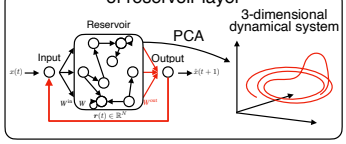
(2) Prediction accuracy

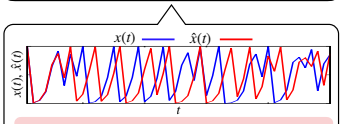
Kullback Leibler divergence [3]

$$\text{KLD} = \sum_x P(x) \log \frac{P(x)}{Q(x)}$$



(3) Attractor of dynamical system of reservoir layer





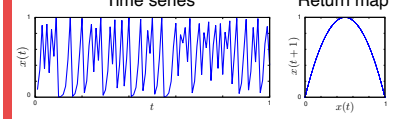
Cannot be evaluated in error due to orbital instability characteristic of chaos

Investigate relationship between prediction accuracy and attractor structure of dynamical system of reservoir layer

Prediction target: logistic map

$$x(t+1) = 4x(t)(1 - x(t))$$

Time series / Return map

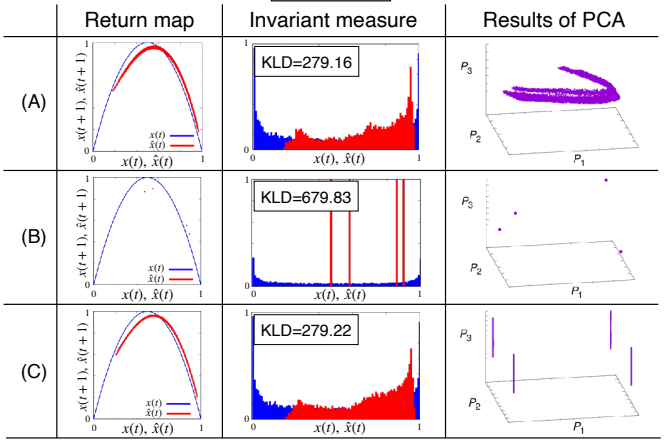


Parameter value

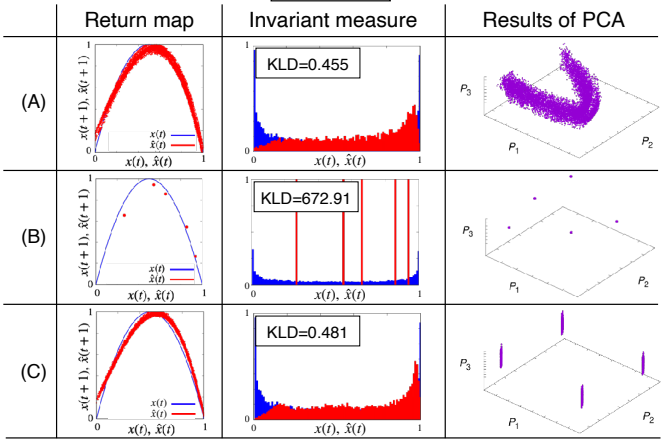
Input and output dimension	1
Number of reservoir layer nodes N	20, 50, 100
Structure of reservoir wighting matrix W	Ramdom network (Probability of coupling: 2%)
Number of training data	1,000
Number of free-runs	10,000
Number of traials	200

4. Results

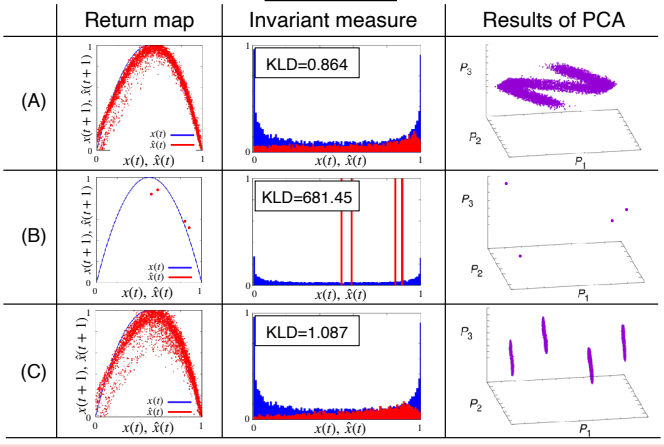
(1) $N = 20$



(2) $N = 50$



(3) $N = 100$



(A), (B) → return map and results of PCA are similar

(A), (C) → KL divergence values are comparable but results of PCA are different

→Dynamical system of reservoir layer predicting high accuracy have various structures

5. Conclusion

1. Prediction results and dynamical system of reservoir layer show similar behavior.
2. When prediction accuracy is almost same, dynamical system show different behavior.

→To understand working principle, W^{out} should also be investigated

Acknowledgment

This research was supported by JSPS KAKENHI Grant Numbers JP20H00596, JP21H03514, and JP22K18419 and Cooperative Research Projects (R02/A31 and R05/B13) of Research Institute of Electrical Communication,Tohoku University.

References

[1] WDC-SILSO, 13-month smoothed monthly total sunspots number, https://www.sidc.be/silso/DATA/SN_ms_tot_V2.0.txt

[2] H. Jaeger et.al., *GMD Technical Report*, **148**, 34, 2001.

[3] S.Kullback and R. Leibler, *Publ. Math. Inst. Hung. Acad. Sci.*, **65**, 3, pp. 79—86, 1951.

[4] M. Hara and H. Kokubu, *Journal of Dynamics and Differential Equation*, pp. 1–26 2022.

[5] 吉田しおん, 池口徹, 電子情報通信学会 技術研究報告, **123**, 287, pp. 15–20, NLP2023-62, 2023.

非線形ワークショップ

二つの目的を考慮した公職選挙ポスター掲示問題に対する発見的解法の開発

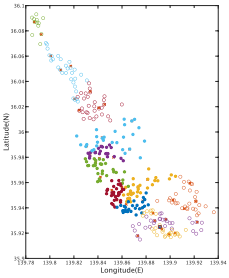
東京理科大学 池口研究室 M2 郭豊愷

1. 公職選挙ポスター掲示問題

公職選挙におけるポスター掲示

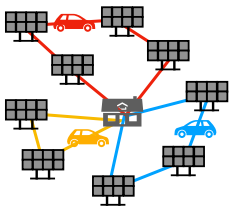


選挙スタッフ(ボランティア)は立候補者の情報を有権者に
早く伝えるために最適なポスター掲示巡回経路を構築する必要がある



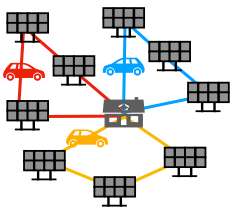
千葉県野田市
ポスター掲示場の配置図

総移動距離を最小化したい



min-sum型
公職選挙ポスター掲示問題[1]

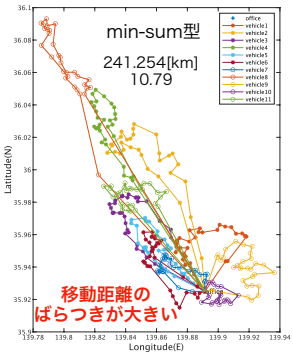
車両の移動距離のばらつきを最小化したい

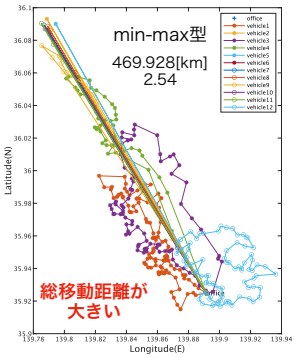


min-max型
公職選挙ポスター掲示問題[2]

2. 先行研究

min-sumとmin-max型目的関数を用いるとき
構築したポスター掲示巡回経路





3. 二つの目的を考慮した公職選挙ポスター掲示問題の定式化

用いる変数の説明

$C = \{0, 1, ..., n\}$　掲示場所n個

$K = \{1, 2, ..., v\}$　車両v台

D　車両の最大走行距離

Q　車両の最大積載量

d_{ij}　掲示場所$_i$,$_j$間の移動コスト(距離)

決定変数

$$x_{ijk} = \begin{cases} 1 & (\text{車両}k\text{が経路}i,j\text{を通る}) \\ 0 & (\text{それ以外}) \end{cases}$$

目的関数

$$\text{Min}\ \{p\sum_{k=1}^{v}\sum_{i=0}^{n}\sum_{j=0}^{n} d_{ij}x_{ijk} + (1-p)\sqrt{\frac{1}{v}\sum_{k=1}^{v}(\sum_{i=0}^{n}\sum_{j=0}^{n} d_{ij}x_{ijk} - \frac{\sum_{k=1}^{v}\sum_{i=0}^{n}\sum_{j=0}^{n} d_{ij}x_{ijk}}{v})^2}\}$$

制約

各掲示場所には1台の車両が1度のみ訪問できる

$$\sum_{j\in C}\sum_{k\in K} x_{ijk} = \sum_{i\in C}\sum_{k\in K} x_{ijk} = 1,\ \forall i, j \in C \setminus \{0\}$$

車両の最大移動距離と最大積載量は超えてはいけない

$$\sum_{i\in C}\sum_{j\in C} d_{ij}x_{ijk} \le D,\ \sum_{i\in C}\sum_{j\in C} x_{ijk} \le Q,\ \forall k \in K$$

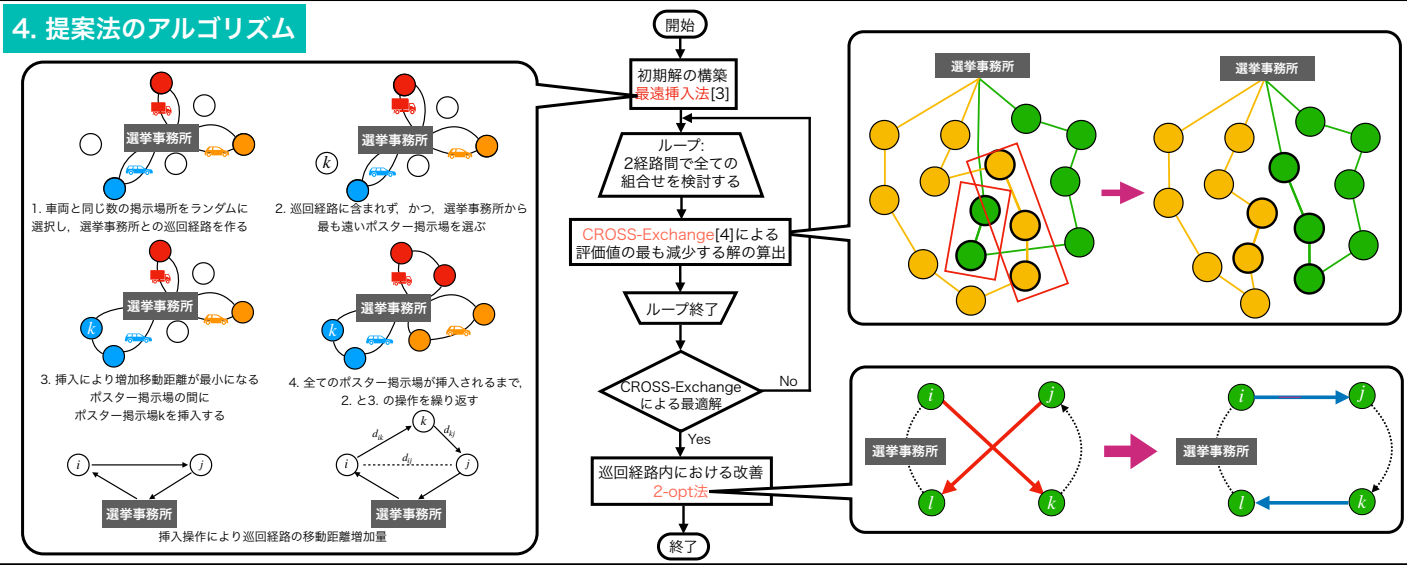
各車両には選挙事務所(デポ)を出発して再び選挙事務所に戻る

$$\sum_{i\in C\setminus\{0\}} x_{i0k} = 1,\ \sum_{j\in C\setminus\{0\}} x_{0jk} = 1, \forall k \in K$$

巡回路には選挙事務所が含まれる

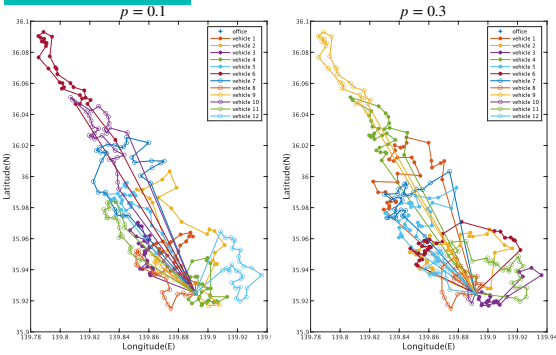
$$\sum_{i\in S}\sum_{j\in S} x_{ijk} \le |S| - 1, \forall S \subseteq C \setminus \{0\}, |S| \ge 2, \forall k \in K$$

4. 提案法のアルゴリズム



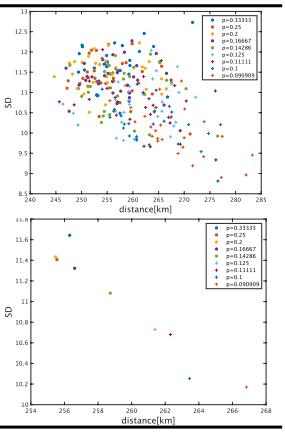
5. 実験と結果

距離制約D: デポ(事務所)から最遠の掲示場所までの距離のh倍.　実験パラメータ: $n = 324$, $v = 12$, $h = 2.7$, $Q = 30$



実験結果: 30回平均

目的関数	パラメータp	総移動距離	標準偏差
min-sum型	-	241.254[km]	10.79
min-max型	-	469.928[km]	2.54
二つの目的	$p = 0.1$	263.443[km]	10.25
二つの目的	$p = 0.2$	261.521[km]	11.37
二つの目的	$p = 0.3$	254.387[km]	11.49



6. まとめ

・全ての実験結果より，min-sum型目的関数の性能がもっといい.
・提案する目的関数では，pを変更させるとき，総移動距離と標準偏差のトレードオフが見えた.

参考文献

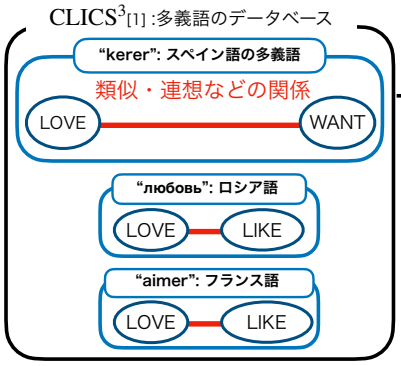
[1] 郭, 他, 信学総大, N-1-9, 2023.
[2] 郭, 他, 信学技報, 122(436), 104--109, 2023.
[3] 星野, 他, 電子情報通信学会論文誌 A, Vol. 90, No.5, pp. 431--441, 2007.
[4] E.Taillard, et al., Transportation science Vol.31, No.2, pp.170-186, 1997.

4 意味ネットワークを用いた語族比較

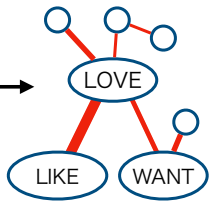
東京理科大学 池口研究室 M2 福家水月

1. 背景・目的

CLICS^3[1] :多義語のデータベース



意味ネットワーク



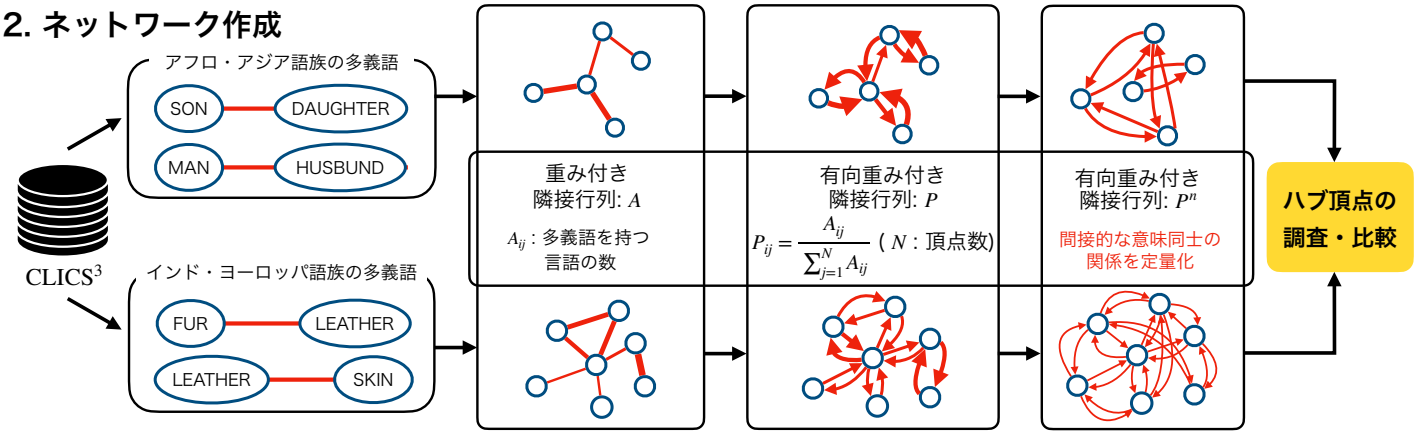
ネットワーク解析により
意味同士の関係の特徴を明らかにする

これまで作成した意味ネットワーク[2,3]

ハブ頂点=多くの頂点と枝を持つ頂点

頂点＼言語	ユニバーサル (言語数: 3,061)	語族別
感情を表す意味（頂点数: 25）	ハブ頂点 GOOD WANT BAD LOVE ↓ 基本的感情	ハブ頂点 GOOD WANT BAD LOVE + 一部の語族で固有のハブ ↓ 語族の特徴を抽出できる？
全ての意味（頂点数: 3,000）	ハブ頂点 EARTH WOOD 環境を表す意味 TAKE HOLD 動作を表す意味 ↓ 語族の特徴と言語圏の環境が強く関係?	**本発表** 語族特有の中心的な意味を調査

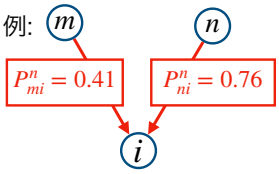
2. ネットワーク作成



3. ハブの定義

強度 In_i

例:



$$\mathrm{In}_i = P^n_{mi} + P^n_{ni} = 0.41 + 0.76 = 1.17$$

変化率 θ_i

例:

r_i	頂点	In_i	θ_i
1	BOY	8.11	
2	MEAT	7.70	0.95
3	SON	7.09	0.92
4	SEIZE	3.00	2.36
5	HOLD	2.50	1.20

r_i: In_iの値を降順に並べた時の順位

$\theta_j = \mathrm{In}_i / \mathrm{In}_j \ (r_i = r_j - 1)$

$\theta_j > 1.5,\ \theta_k < 1.5 \ (r_j = r_k - 1)$ の時, 頂点jがハブ頂点の境目

4. 実験結果

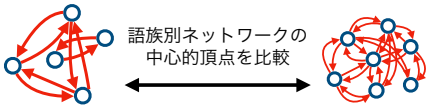
有向重み付き隣接行列: $P^n \ (n = 1.0 \times 10^3)$

r_i	アフロ・アジア語族 頂点	In_i	θ_i	インド・ヨーロッパ語族 頂点	In_i	θ_i	ユニバーサル[3] 頂点
1	BOY	8.11		WOOD	7.18		HOLD
2	MEAT	7.70	0.95	LEATHER	7.01	0.97	EARTH (SOIL)
3	SON	7.09	0.92	FUR	6.95	0.99	TAKE
4	SEIZE	6.69	0.94	CARRY	6.78	0.97	SKIN
5	HOLD	6.69	0.99	EARTH (SOIL)	6.37	0.94	GO
6	FLESH	6.28	0.93	END (OF SPACE)	6.31	0.99	WOOD
7	DAUGHTER	6.28	0.99	GO	6.02	0.95	MAN
8	WEAVE	5.88	0.93	MEAT	5.85	0.97	SEIZE
9	LANGUAGE	5.88	0.99	MAN	5.85	1.00	
10	OLDMAN	5.27	0.89	KEEP	5.85	1.00	

: 人を表す意味
: 環境を表す意味
: 動作を表す意味

- アフロ・アジア語族…**人**を表す意味が高い強度
  インド・ヨーロッパ語族…**環境**を表す意味が高い強度 → **語族間における意味表現の差**
- 動作を表す意味: **語族で共通して中心的な意味である可能性**
- 語族別のネットワークでハブは存在しない → **2つの言語において意味のカテゴリが中心的**

5. まとめ・今後の課題



- 語族別に異なる中心的頂点
- 語族間で共通した中心的頂点
- 中心的な意味のカテゴリ

今後の課題

語族別ネットワークにおける
コミュニティ検出

参考文献

[1] J. M. List et al., https://clics.clld.org/, (Last visit Nov. 25th, 2021).
[2] M. Fukuya et al., *Proc. of RISP NCSP'22*, 1AM1-1-1, pp. 1–4, 2022.
[3] 福家 他, IEICE NOLTA ソ大会, A-16, 2022.

18

マーク付点過程に対する因果性検出

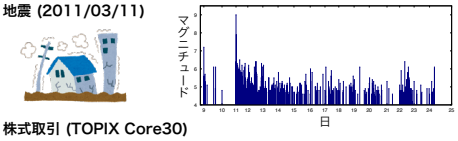
東京理科大学 池口研 D3　澤田 和弥

非線形問題解決集団 池口研究室

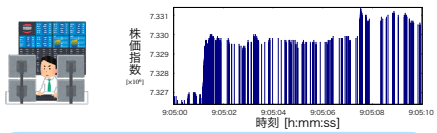
1. はじめに

イベントに付加情報が付与されたデータ

・地震 (2011/03/11)



・株式取引 (TOPIX Core30)



我々の身の回りにはマーク付点過程が多く存在する

2. 時系列データに対する因果性検出

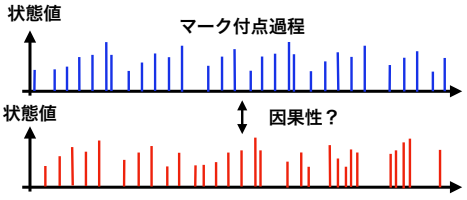
Granger causality [1]
- 予測モデルの構築が必要
- 主に線形な因果関係のみが対象

Transfer entropy [2]
- 確率分布生成にデータが多く必要
- 時間遅延を伴う因果関係に対して計算時間が増加

Convergent cross mapping (CCM) [3]
- 比較的短い時系列データで因果性検出可能
- モデルフリーな手法
- 非線形な因果関係を検出可能

そのままマーク付点過程に適用不可

3. 研究目的



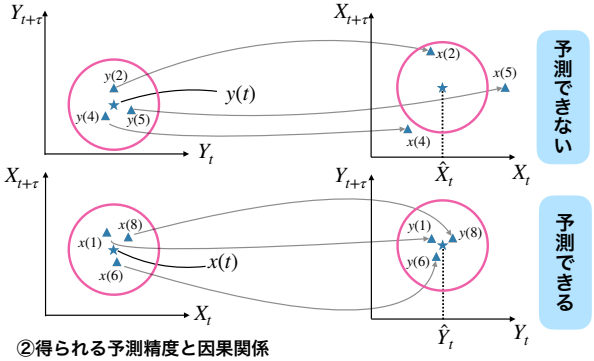
マーク付点過程データに対する因果性検出手法の開発

⟶ CCMの拡張

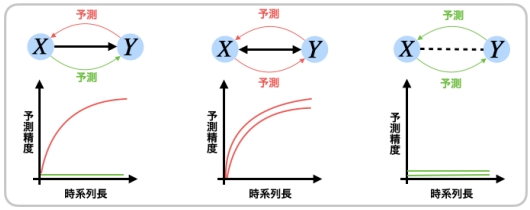
4. Convergent cross mapping (CCM) [3]

in-sampleな相互予測精度によって因果性を検出する手法

例 Y (原因) ⟶ X (結果)



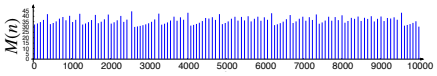
②得られる予測精度と因果関係



5. 提案手法

5.1. マーク付点過程からの力学系再構成 [4]

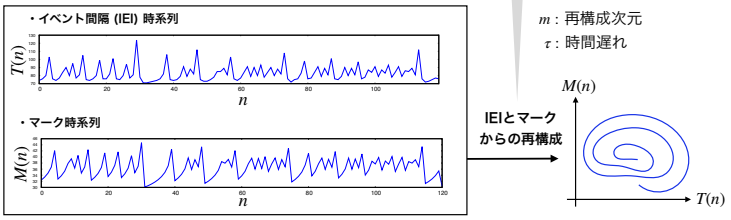
・マーク付点過程



2次元時系列を用いた遅延ベクトル [5]

$$V(n) = (T(n),\ M(n),\ \ldots,\ T(n+(m-1)\tau),\ M(n+(m-1)\tau))$$

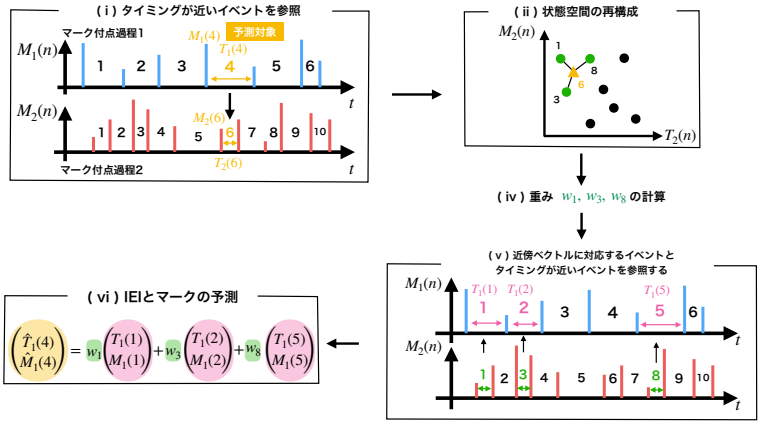
m : 再構成次元
τ : 時間遅れ



IEI&マーク時系列から力学系を再構成

5.2. マーク付点過程の相互予測手順 [6]

例 マーク付点過程2の情報を使ってマーク付点過程1を予測



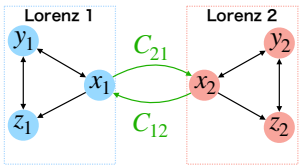
$$\begin{pmatrix}\hat{T}_1(4)\\ \hat{M}_1(4)\end{pmatrix} = w_1\begin{pmatrix}T_1(1)\\ M_1(1)\end{pmatrix} + w_3\begin{pmatrix}T_1(2)\\ M_1(2)\end{pmatrix} + w_8\begin{pmatrix}T_1(5)\\ M_1(5)\end{pmatrix}$$

6. 結合Lorenz方程式からのマーク付点過程生成

結合Lorenz方程式 [7]

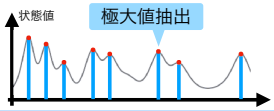
$$\begin{aligned}\dot{x}_1 &= \sigma_1(y_1 - x_1) + C_{12}(x_2 - x_1),\\ \dot{y}_1 &= r_1 x_1 - y_1 - x_1 z_1,\\ \dot{z}_1 &= -b_1 z_1 + x_1 y_1,\\ \dot{x}_2 &= \sigma_2(y_2 - x_2) + C_{21}(x_1 - x_2),\\ \dot{y}_2 &= r_2 x_2 - y_2 - x_2 z_2,\\ \dot{z}_2 &= -b_2 z_2 + x_2 y_2 .\end{aligned}$$

変数間の因果関係

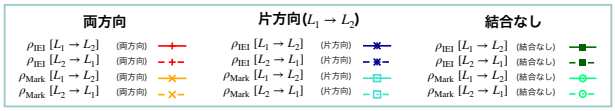


両方向	$C_{12} = C_{21} = 1.5$
片方向 ($L_1 \to L_2$)	$C_{12} = 0,\ C_{21} = 1.5$
結合なし	$C_{12} = C_{21} = 0$

マーク付点過程の生成法 [8]



7. 結果

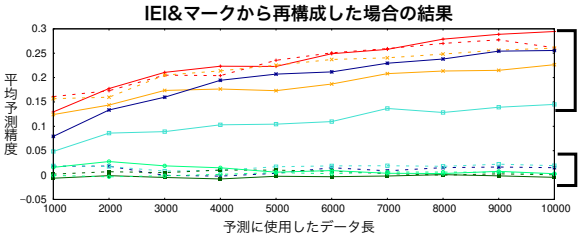


平均予測精度 (マーク): $\rho_{\mathrm{Mark}}[\,L_i \to L_j\,] = \frac{1}{9}\sum_{p\in\mathbf{L}_i}\sum_{q\in\mathbf{L}_j}\rho[\,M_p \mid \Phi_q\,]\quad (i,j=1,2,i\neq j)$

平均予測精度 (IEI): $\rho_{\mathrm{IEI}}[\,L_i \to L_j\,] = \frac{1}{9}\sum_{p\in\mathbf{L}_i}\sum_{q\in\mathbf{L}_j}\rho[\,T_p \mid \Phi_q\,]\quad (i,j=1,2,i\neq j)$

$\mathbf{L}_i = \{x_i, y_i, z_i\}$

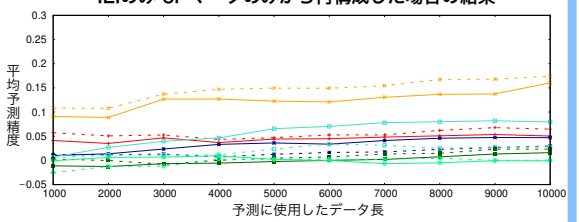
IEI&マークから再構成した場合の結果



IEI&マークを用いた場合
因果性検出できた

IEIのみ or マークのみを用いた場合
因果性検出できなかった

IEIのみ or マークのみから再構成した場合の結果



参考文献

[1] C. W. Granger, *Econometrica*, **37**, 3, 424–438, 1969.
[2] T. Schreiber, *Phys. Rev. Lett.*, **85**, 2, 461–464, 2000.
[3] G. Sugihara et al., *Science*, **338**, 496—500, 2012.
[4] K. Sawada, et. al., *J. of Signal Processing*, **25** (4): 127–131, 2021.
[5] T. Sauer, et. al., *J. Stat. Phys.*, **65** (3): 579–616, 1991.
[6] 澤田 他, 信学技報, **121** (436): 89–94, 2023.
[7] V. Anishchenko, et. al., *Phys. Rev. E*, **57** (1): 316–322, 1998.
[8] N. Yabuta, et. al., *Proc. of 2007 Int. Symp. on NOLTA*, 16–19, 2007.

17

時空間学習則において時間履歴がパターン分離能力とシナプス荷重の関係に与える影響

東京理科大学 池口研究室 M2 塚本陽太

1. 背景

脳では2つの学習則が共存

Hebb則[1]

入力と出力の同時性

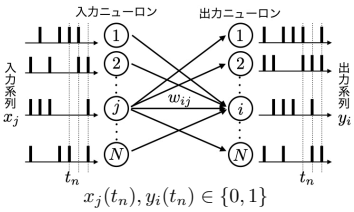
時空間学習則[2]

入力どうしの同時性 + 時間履歴

目的

時空間学習則における時間履歴の重要性を調査

2. ネットワーク



$$x_j(t_n), y_i(t_n) \in \{0,1\}$$

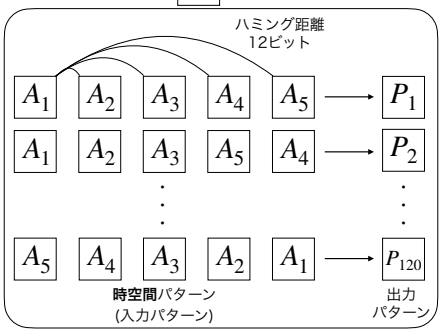
$$s_i(t_n) = \sum_{j=1}^{N} w_{ij}(t_n) x_j(t_n)$$ 入力の重み付け和

$$y_i(t_n) = F(s_i(t_n) - \eta)$$ η: 発火の閾値

$$F(u) = \begin{cases} 1 & u > 0 \\ 0 & u \leq 0 \end{cases}$$ 出力の決定

3. 入力系列

空間パターン $A_1 = \{0,1,0,0,1,\cdots,1,0\}$ 120ビット



×10回試行

シナプス荷重の初期値の影響を考慮

異なる出力パターンの個数をカウント
個数が多いほど分離能力が高い

4. 時空間学習則

時間履歴あり[3]

空間一致性

$$I_{ij}(t_n) = w_{ij}(t_n)x_j(t_n) \sum_{k=1,k\neq j}^{N} w_{ik}(t_n)x_k(t_n)$$
$$\approx w_{ij}(t_n)x_j(t_n)s_i(t_n)$$

入力ニューロンが同時にどれくらい発火したかを定量化

時間履歴

$$I_{add}(t_n) = \sum_{m=0}^{n} I_{ij}(t_m) \exp\left(-\frac{t_n - t_m}{\lambda}\right)$$

λ : 時定数

シナプス荷重の更新

$$w_{ij}(t_{n+1}) = \begin{cases} w_{ij}(t_n) + \Delta w & I_{add}(t_n) > \theta_1 \\ w_{ij}(t_n) & \theta_1 \geq I_{add}(t_n) \geq \theta_2 \\ w_{ij}(t_n) - \Delta w & I_{add}(t_n) < \theta_2 \end{cases}$$

θ_1 : 増強の閾値　θ_2 : 減弱の閾値

時間履歴なし[4]

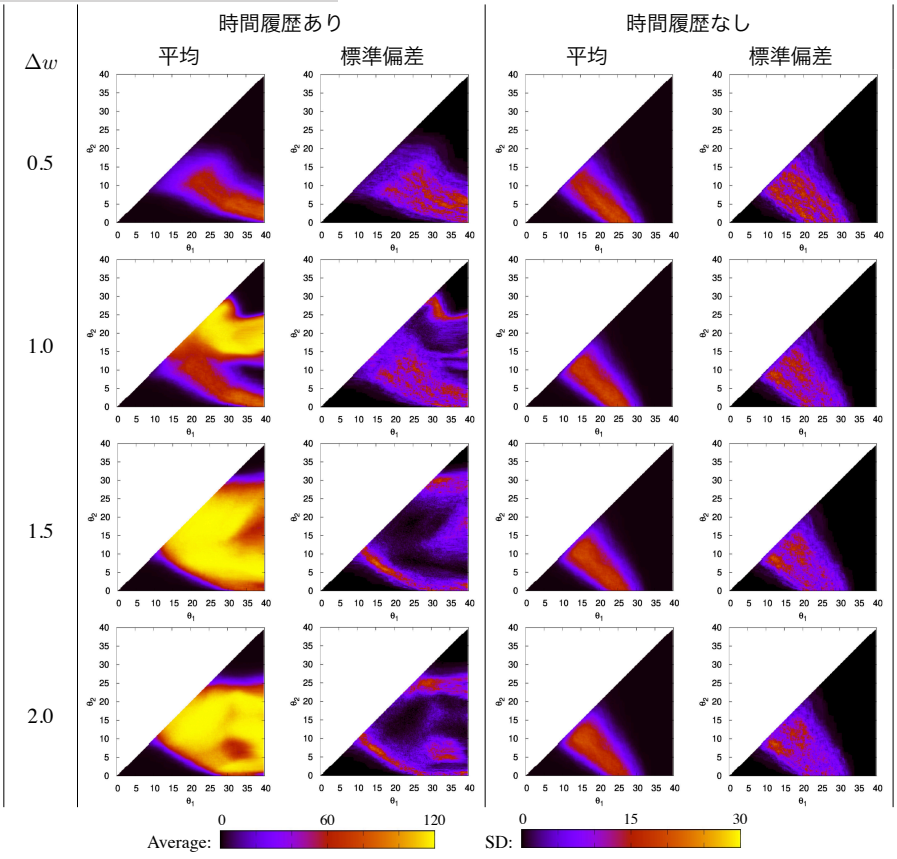
シナプス荷重の更新

$$w_{ij}(t_{n+1}) = \begin{cases} w_{ij}(t_n) + \Delta w & I_{ij}(t_n) > \theta_1 \\ w_{ij}(t_n) & \theta_1 \geq I_{ij}(t_n) \geq \theta_2 \\ w_{ij}(t_n) - \Delta w & I_{ij}(t_n) < \theta_2 \end{cases}$$

θ_1 : 増強の閾値　θ_2 : 減弱の閾値

時間履歴を含まず，空間一致性により増強・減弱を決定

5. パターン分離能力の比較



時間履歴の方がパターン分離能力(高) 初期状態へのロバスト性(高)

6. シナプス荷重分布

パターン分離能力とシナプス荷重分布の関係は
時間履歴ありとなしでどのような違いがあるか

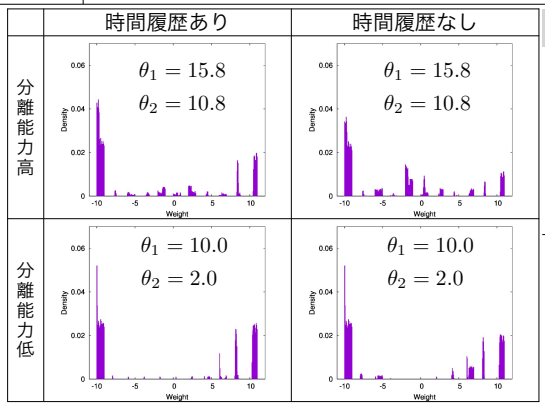
時間履歴あり: 関係が曖昧
時間履歴なし: 多峰性が高い分離能力を表す

↓

時間履歴ありでは
シナプス荷重から分離能力が分からない

↓

時間履歴ありでは
ネットワーク構造が重要



7. まとめ

時間履歴による影響

- パターン分離能力の向上
- 初期値への頑健性
- ネットワーク構造の重要性

参考文献

[1] D. O. Hebb, Oxford: Wiley, 1949.
[2] M. Tsukada et al., *Neural Networks*, **9**(8), 1996.
[3] M. Tsukada et al., *Biol. Cybern.*, **92**(2), 139—146, 2005.
[4] H. Tsukada et al., *Front. Syst. Neurosci.*, **15**(11), 2021.

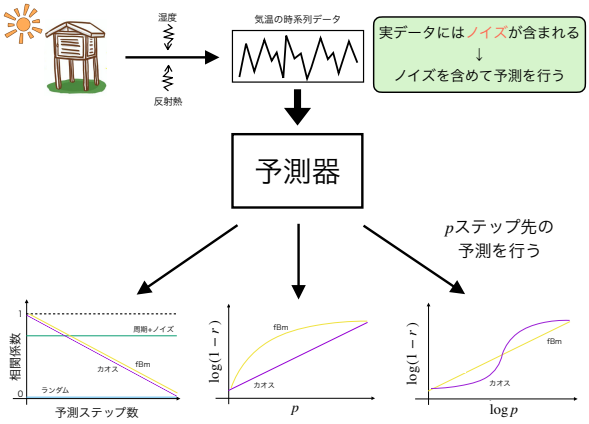
15

エコーステートネットワークを用いたカオス時系列予測

東京理科大学 池口研究室 B4 吉田しおん

非線形問題解決単団 池口研究室 NONLINEAR DYNAMICAL SYSTEM

1. はじめに



予測ステップを変更して予測することで，時系列データを識別できる！[1]

2. 目的

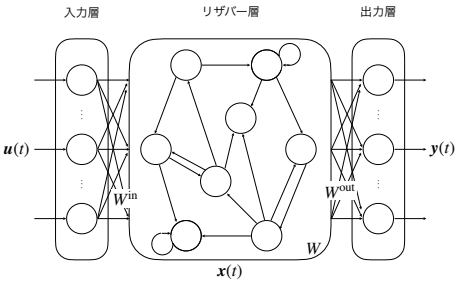
ESNを用いて

(1) ノイズと予測精度の関係を調査

(2) 時系列予測による実データの識別

3. エコーステートネットワーク(ESN)[2]

基本モデル



$$\begin{cases} \boldsymbol{u}(t) = (u_1(t), u_2(t), \ldots, u_{N_u}(t))^{\mathrm{T}} \in \mathbb{R}^{N_u} \\ \boldsymbol{x}(t) = (x_1(t), x_2(t), \ldots, x_{N_x}(t))^{\mathrm{T}} \in \mathbb{R}^{N_x} \\ \boldsymbol{y}(t) = (y_1(t), y_2(t), \ldots, y_{N_y}(t))^{\mathrm{T}} \in \mathbb{R}^{N_y} \end{cases} \quad \begin{cases} W^{\mathrm{in}} = (w_{ij}^{\mathrm{in}}) \in \mathbb{R}^{N_x \times N_u} \\ W = (w_{ij}) \in \mathbb{R}^{N_x \times N_x} \\ W^{\mathrm{out}} = (w_{ij}^{\mathrm{out}}) \in \mathbb{R}^{N_y \times N_x} \end{cases}$$

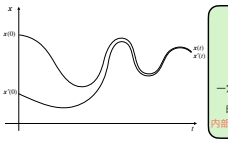
W^{out}のみを学習する → 計算量が小さい！

状態更新式

$$\begin{cases} \boldsymbol{x}(t+1) = \boldsymbol{f}\left(W^{\mathrm{in}}\boldsymbol{u}(t+1) + W\boldsymbol{x}(t)\right) \\ \boldsymbol{y}(t+1) = W^{\mathrm{out}}\boldsymbol{x}(t+1) \end{cases}$$

活性化関数：$f = \tanh$

エコーステートプロパティ (ESP)



$$\boldsymbol{x}(t) = f\left(W^{\mathrm{in}}\boldsymbol{u}(t) + W\boldsymbol{x}(t-1)\right) = \bar{F}(s_t(\boldsymbol{u}), \boldsymbol{x}(0))$$

$\bar{F}$：状態遷移関数，$s_t(\boldsymbol{u})$：時系列入力

$$\lim_{t\to\infty} ||\bar{F}(s_t(\boldsymbol{u}), \boldsymbol{x}(0)) - \bar{F}(s_t(\boldsymbol{u}), \boldsymbol{x}'(0))||^2 = 0$$

$f = \tanh$のとき，$\rho(W) < 1$で成り立つ！

学習則

リッジ回帰 $W^{\mathrm{out}} = YX^{\mathrm{T}}(XX^{\mathrm{T}} + \beta I)^{-1}$

Y：正解データの行列，X：内部状態の行列，β：正則化パラメータ

ESNのパラメータ

パラメータ	変数
入力次元	N_u
リザバー層のノード数	N_x
出力次元	N_y
入力結合重みのスケーリング	W^{in}
リザバー層のネットワークの結合密度	
スペクトル半径	$\rho(W)$
リッジ回帰の正則化パラメータ	β

4. ノイズを含むデータの予測

Lorenz方程式

$$\begin{cases} \dot{x} = \sigma(-x + y) \\ \dot{y} = -xz + rz - y \\ \dot{z} = -xy - wz \end{cases}$$

パラメータ：$\sigma = 10, w = 8/3, r = 28$

埋め込み次元：$m = 6$，遅れ時間：$\tau = 8$

観測ノイズとして加える

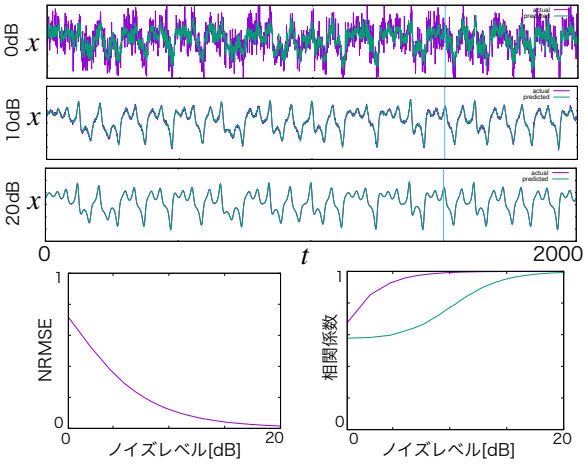
ノイズレベル：SN比[dB]

$$\frac{S}{N}[\mathrm{dB}] = 10\log_{10}\frac{v_S}{v_N}$$

v_S：元の信号の分散

v_N：ノイズの分散

時系列\ESNパラメータ	N_u	N_x	N_y	W^{in}	W 結合密度	$\rho(W)$	β
Lorenz方程式	6	200	1	[-0.1, 0.1]	2%	0.95	0.01



10dB程度まで正しく予測できる

→ノイズ量にスケーリングすれば

予測精度が向上する？

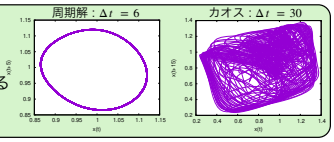
5. 時系列データの識別

Mackey-Glass方程式

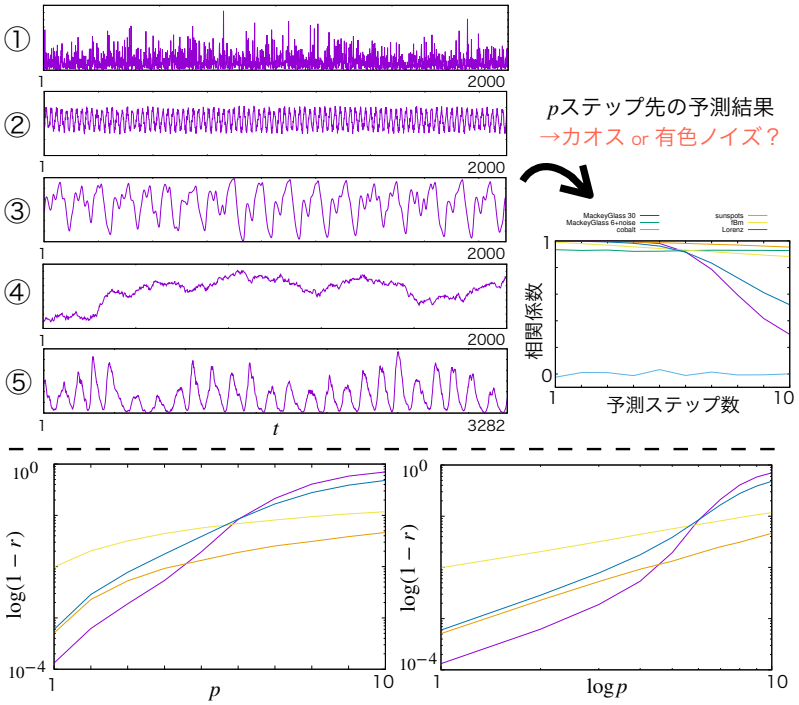
$$\frac{dx(t)}{dt} = \frac{a\,x(t-\Delta t)}{1 + x(t-\Delta t)^n} - b\,x(t)$$

パラメータ：$a = 0.2, b = 0.1, n = 10$

Δtによって応答が変化する



時系列\ESNパラメータ	N_u	N_x	N_y	W^{in}	W 結合密度	$\rho(W)$	β
① コバルト	1	200	1	[-0.1, 0.1]	2%	0.98	0.01
② MG周期解＋ノイズ	1	300	1	[-0.1, 0.1]	2%	0.98	0.01
③ MGカオス	1	300	1	[-0.1, 0.1]	2%	0.98	0.01
④ 非整数ブラウン運動	1	300	1	[-0.1, 0.1]	2%	0.98	0.01
⑤ 太陽黒点数[3]	1	300	1	[-0.1, 0.1]	2%	0.98	0.01



対数軸をとると，2つに分かれた

→太陽黒点数のデータは有色ノイズ？

デルタ相関図を確認する！[1]

6. まとめ・今後の課題

ノイズを含むデータの予測

・ノイズが大きいと予測精度が低下する．

→ノイズに頑健なESNのモデルを調査する．

時系列データの識別

・ランダム性，周期性は相関係数が一定となる．

・カオス性，有色ノイズは対数軸を取ると違いがわかる．

・太陽黒点数のデータは有色ノイズ

→デルタ相関を確認する．

参考文献

[1] 池口徹, 山田泰司, 小室元政, 産業図書, 2000.

[2] 田中 剛平, 中根了昌, 廣瀬 明, 森北出版, 2021.

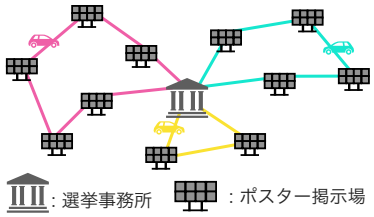
[3] 月ごとの太陽黒点数のデータ, (最終閲覧日: 2023年7月4日) https://www.sidc.be/silso/DATA/SN_ms_tot_V2.0.txt

公職選挙ポスター掲示問題においてグルーピング手法に関する調査

東京理科大学 池口研究室 M2 郭豊愷

1. 公職選挙ポスター掲示問題

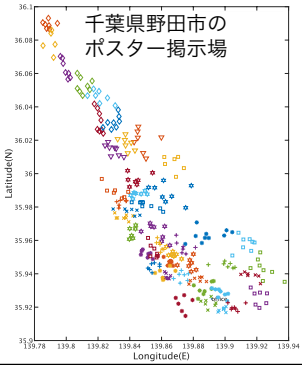
公職選挙におけるポスター掲示



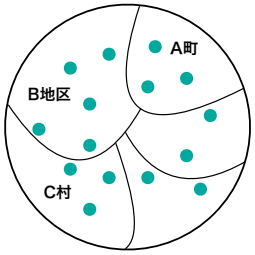
立候補者の情報を有権者に早く伝えるために
最適なポスター掲示巡回経路を構築する必要がある

2. 使用データとグルーピング方法

全ポスター掲示場を複数の車両に割り当てることが重要

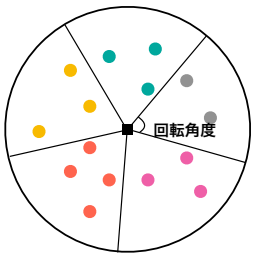


経験的なグループの分け方



土地勘によりグルーピングする

スイープ法[1]



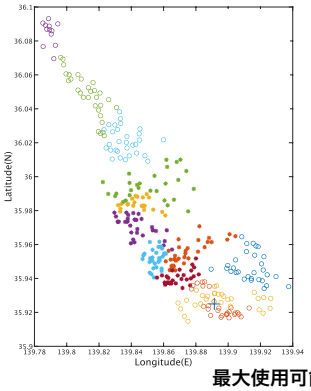
回転角度によりグルーピングする

3. グルーピングした結果および各グループの最適解

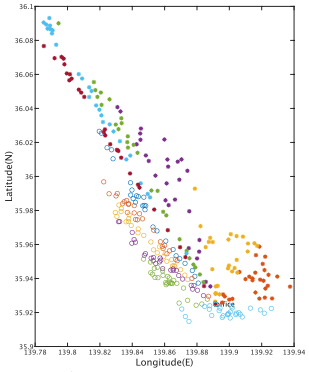
スイープ法: 各グループの掲示場数が同じ(27)とする

グルーピングの結果

経験的なグループ分け



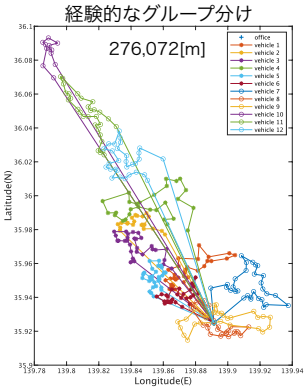
スイープ法



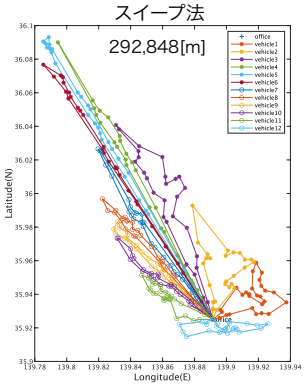
最大使用可能車両: 12台

各グループの最適解

経験的なグループ分け

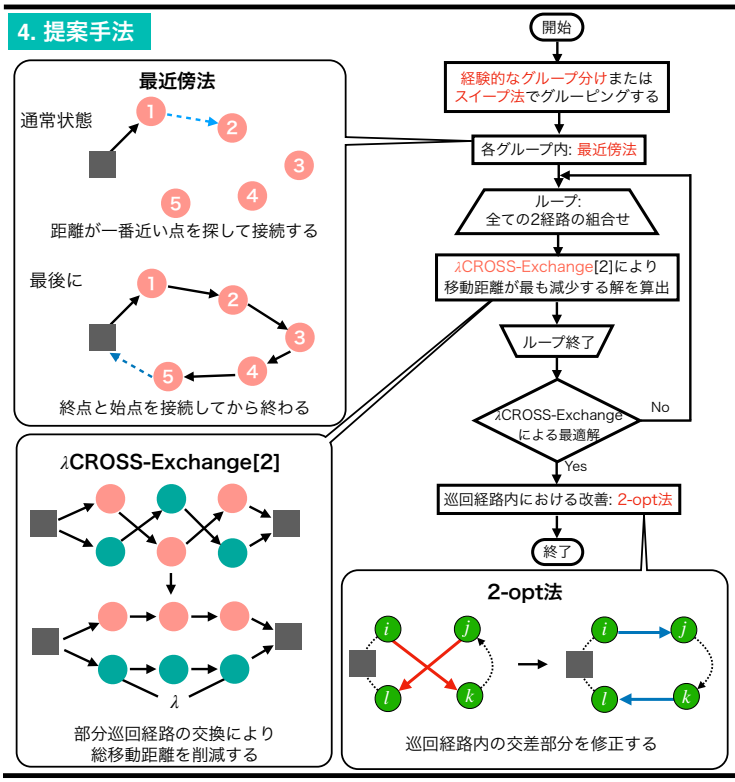


スイープ法



結果より，まだ改善する余地がある

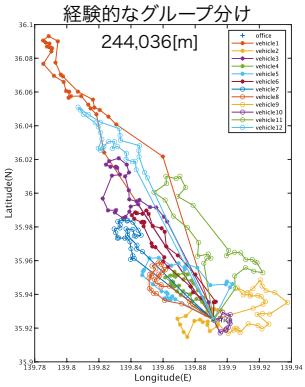
4. 提案手法



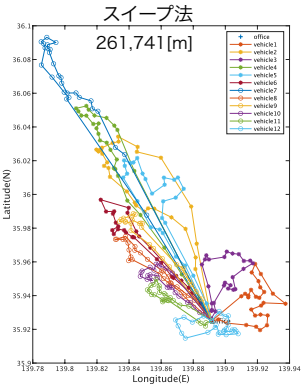
5. 実験と結果

提案手法により構築したポスター掲示巡回経路

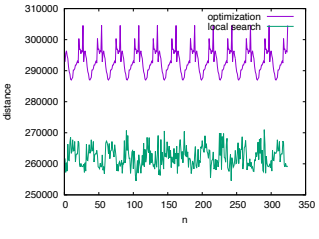
経験的なグループ分け



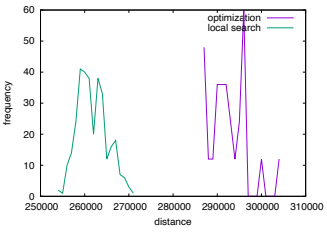
スイープ法



スイープ法で起始点nを変更したときの結果



結果の分布



6. まとめ

- **提案手法では各グループの最適解より総移動距離が短くなった**
- **現在の実験条件では，経験的なグループ分け型の性能が最も良い**

参考文献

[1] B. E. Gillet and L. R. Miller, *Operations Research*, Vol. 22, No. 2, pp. 340–350, 1974.
[2] E. Taillard et al., *Transportation Science*, Vol.31, No.2, pp.170–186, 1997.

D22

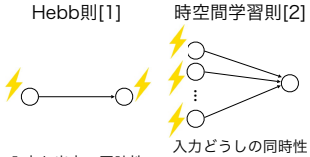
時空間学習則の時間履歴による パターン分離能力とシナプス荷重分布の関係の変化

東京理科大学 池口研究室 M2 塚本陽太

1. 背景

脳では2つの学習則が共存

Hebb則[1]　　時空間学習則[2]

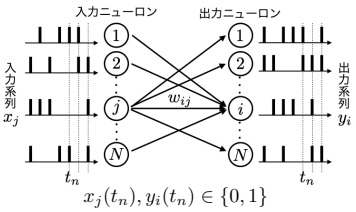


入力と出力の同時性　　入力どうしの同時性 ＋ 時間履歴

目的

時空間学習則における時間履歴の重要性
パターン分離能力とシナプス荷重の関係

2. ネットワーク



$$x_j(t_n), y_i(t_n) \in \{0,1\}$$

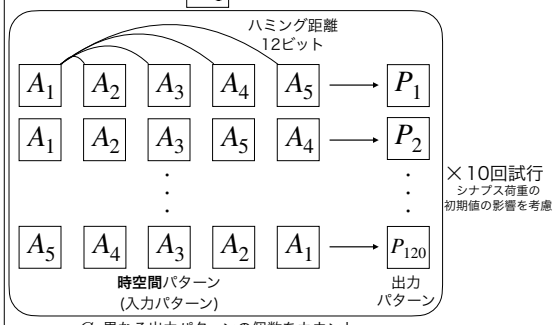
$$s_i(t_n) = \sum_{j=1}^{N} w_{ij}(t_n) x_j(t_n)$$ 入力の重み付け和

$$y_i(t_n) = F(s_i(t_n) - \eta)$$ η: 発火の閾値

$$F(u) = \begin{cases} 1 & u > 0 \\ 0 & u \leq 0 \end{cases}$$ 出力の決定

3. 入力系列

空間パターン　$A_1 = \{0,1,0,0,1,\cdots,1,0\}$　120ビット



C: 異なる出力パターンの個数をカウント
個数が多いほど分離能力が高い

4. 時空間学習則

空間一致性

$$I_{ij}(t_n) = w_{ij}(t_n)x_j(t_n) \sum_{k=1,k\neq j}^{N} w_{ik}(t_n)x_k(t_n)$$
$$\approx w_{ij}(t_n)x_j(t_n)s_i(t_n)$$

入力ニューロンが同時にどれくらい発火したかを定量化

時間履歴

$$J_{ij}(t_n) = \sum_{m=0}^{n} I_{ij}(t_m) \exp\left(-\frac{t_n - t_m}{\lambda}\right)$$

λ : 時定数

時間履歴あり[3]

$$w_{ij}(t_{n+1}) = \begin{cases} w_{ij}(t_n) + \Delta w & J_{ij}(t_n) > \theta_1 \\ w_{ij}(t_n) & \theta_1 \geq J_{ij}(t_n) \geq \theta_2 \\ w_{ij}(t_n) - \Delta w & J_{ij}(t_n) < \theta_2 \end{cases}$$

時間履歴なし[4]

$$w_{ij}(t_{n+1}) = \begin{cases} w_{ij}(t_n) + \Delta w & I_{ij}(t_n) > \theta_1 \\ w_{ij}(t_n) & \theta_1 \geq I_{ij}(t_n) \geq \theta_2 \\ w_{ij}(t_n) - \Delta w & I_{ij}(t_n) < \theta_2 \end{cases}$$

Δw : 学習率係数　　θ_1 : 増強の閾値　　θ_2 : 減弱の閾値

5. 分布の類似度

Histogram Intersection [5]

$$D_{HI}(P||Q) = \sum_x \min(P(x), Q(x))$$

L-pノルム

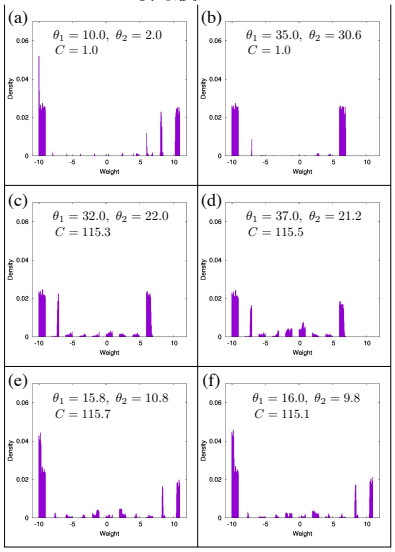
$$D_{L_p}(P||Q) = \left(\sum_x |P(x) - Q(x)|^p\right)^{1/p}$$

x : 確率変数　　$P(x), Q(x)$: 確率分布

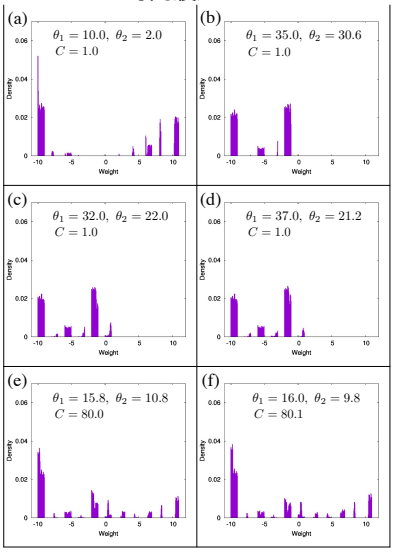
シナプス荷重分布の類似度を定量化

6. シナプス荷重分布

時間履歴あり



時間履歴なし



Histogram Intersection

	(a)	(b)	(c)	(d)	(e)	(f)
(a)	1.0	0.52	0.48	0.47	0.71	0.73
(b)		1.0	0.79	0.70	0.51	0.51
(c)			1.0	0.87	0.53	0.52
(d)				1.0	0.55	0.53
(e)					1.0	0.94
(f)						1.0

Histogram Intersection

	(a)	(b)	(c)	(d)	(e)	(f)
(a)	1.0	0.44	0.41	0.41	0.64	0.67
(b)		1.0	0.92	0.93	0.65	0.61
(c)			1.0	0.97	0.64	0.59
(d)				1.0	0.64	0.59
(e)					1.0	0.93
(f)						1.0

L-1ノルム

	(a)	(b)	(c)	(d)	(e)	(f)
(a)	0	0.95	1.04	1.06	0.58	0.54
(b)		0	0.41	0.61	0.98	0.98
(c)			0	0.26	0.94	0.96
(d)				0	0.91	0.94
(e)					0	0.13
(f)						0

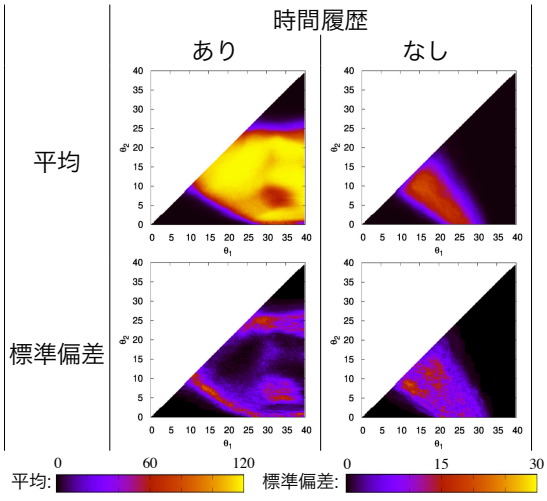
パターン分離能力による明確な差は見られない

L-1ノルム

	(a)	(b)	(c)	(d)	(e)	(f)
(a)	0	1.12	1.17	1.18	0.72	0.65
(b)		0	0.16	0.14	0.70	0.78
(c)			0	0.06	0.72	0.82
(d)				0	0.73	0.83
(e)					0	0.15
(f)						0

パターン分離能力 (低) 同士でも類似度に大きな差

7. パターン分離能力



時間履歴によりパターン分離能力が向上
初期状態への頑健性も向上

8. まとめ

時間履歴あり

パターン分離能力が高い場合と低い場合の
シナプス荷重分布の類似度に明確な差がない.
パターン分離能力が向上

参考文献

[1] D. O. Hebb, Oxford: Wiley, 1949.
[2] M. Tsukada et al., *Neural Networks*, **9**(8), 1357–1365, 1996.
[3] M. Tsukada et al., *Biol. Cybern.*, **92**(2), 139—146, 2005.
[4] H. Tsukada et al., *Front. Syst. Neurosci.*, **15**(11), 624353, 2021.
[5] M. J. Swain et al., *IJCV*, **7**(1), 11—32, 1991.

D05

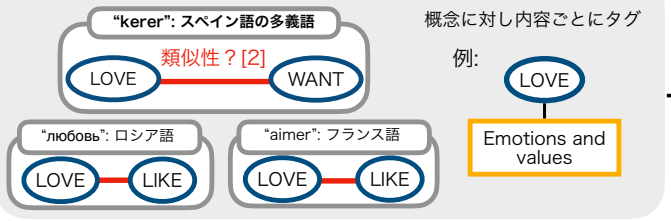
多義語ネットワークにおける中心頂点の調査

東京理科大学 池口研究室 M2 福家水月

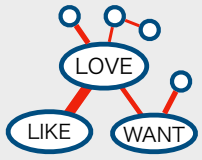
池口研究室

1. 背景・目的

CLICS^3[1] :多義語のデータベース



多義語ネットワーク



ネットワーク解析により
概念同士の関係の特徴抽出

これまでの研究[3]

語族毎の感情の中心頂点

GOOD WANT BAD LOVE

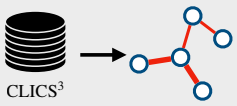
＋一部の語族で固有のハブ

→ 語族の特徴を抽出できる？

- **語族毎の中心頂点を調査**
- **感情の中心概念との違いを調査**

2. ネットワーク作成

重み付き隣接行列: A



A_{ij}：語族に所属する言語の数

有向重み付き隣接行列: P

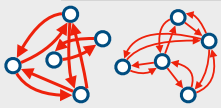


$$P_{ij} = \frac{A_{ij}}{\sum_{j=1}^{N} A_{ij}}$$

(N：頂点数)

j ← i jに対するiの類似度

有向重み付き隣接行列: P^n



$n = 2$　$n = 3$

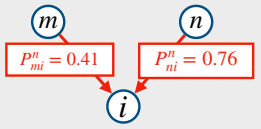
nの増加でP^n_{ij}は収束[3]

j ← i n個の頂点を介したjに対するiの間接的な類似度

語族毎にP^nを作成し中心頂点を比較

正規化強度 In_i

例:



$$\mathrm{In}_i = \frac{P^n_{mi} + P^n_{ni}}{N} = \frac{0.42 + 0.76}{2} = 0.59$$

3. 実験結果

有向重み付き隣接行列: P^n $(n = 1.0 \times 10^3)$

全ての語族

言語数	多義語数	頂点数	枝数
3,278	116,750	2,718	7,241,510

頂点	In_i ($\times 10^{-3}$)
TREE	3.33
HOLD	3.29
EARTH (SOIL)	3.27
TAKE	3.24
SKIN	3.20
GO	3.10
WOOD	3.03
MAN	2.79
SEIZE	2.77

タグ	In_iの合計 ($\times 10^{-1}$)
The body	1.04
Kinship	0.91
Basic actions and technology	0.79
Motion	0.71
The physical world	0.70
Spatial relations	0.65
Food and drink	0.54
Sense perception	0.45
Animals	0.40

感情の中心頂点: GOOD WANT BAD LOVE

オーストロネシア語族

言語数	多義語数	頂点数	枝数
39	3,834	1,421	1,934,933

頂点	In_i ($\times 10^{-3}$)
AND	5.26
WATER	5.20
CORRECT (RIGHT)	5.04
BE ALIVE	4.72
TREE	4.55
KILL	4.55
RICE PLANT	4.34
SKIN	4.28
SPEAK	4.28

タグ	In_iの合計 ($\times 10^{-1}$)
The body	1.30
Kinship	1.03
The physical world	0.82
Spatial relations	0.70
Basic actions and technology	0.62
Motion	0.62
Agriculture and vegetation	0.53
Food and drink	0.48
Sense perception	0.45

感情の中心頂点: GOOD WANT BAD LOVE

オーストロアジア語族

言語数	多義語数	頂点数	枝数
548	9,058	1,161	1,181,695

頂点	In_i ($\times 10^{-3}$)
DAUGHTER 1	5.75
FATHER'S SISTER	5.38
SON1	5.38
DAUGHTER 2	5.25
FATHER'S BROTHER	5.13
HAIR (BODY)	5.13
MOTHER'S SISTER	4.63
SON2	4.63
FEATHER	4.63

タグ	In_iの合計 ($\times 10^{-1}$)
Kinship	1.41
The body	1.12
Basic actions and technology	0.62
Spatial relations	0.62
Food and drink	0.62
Motion	0.60
The physical world	0.46
Animals	0.43
Clothing and grooming	0.40

感情の中心頂点: GOOD WANT BAD LOVE

感情の中心頂点が同じ場合でも異なる中心頂点

インド・ヨーロッパ語族

言語数	多義語数	頂点数	枝数
268	14,320	1,691	2,729,165

頂点	In_i ($\times 10^{-3}$)
WOOD	4.25
LEATHER	4.14
FUR	4.11
CARRY	4.01
EARTH (SOIL)	3.77
END (OF SPACE)	3.73
GO	3.56
MEAT	2.79
MAN	2.77

タグ	In_iの合計 ($\times 10^{-1}$)
The body	0.88
Basic actions and technology	0.84
Motion	0.83
Kinship	0.82
Spatial relations	0.78
The physical world	0.60
Food and drink	0.53
Sense perception	0.49
Animals	0.46

感情の中心頂点: BAD

タイ・カダイ語族

言語数	多義語数	頂点数	枝数
41	4,412	1,215	1,259,033

頂点	In_i ($\times 10^{-3}$)
SMOKE (IN HALE)	4.34
FEMALE	4.12
FATHER'S BROTHER	4.12
MOTHER'S SISTER	4.01
HAVE	3.91
MOTHER'S BROTHER	3.80
FATHER'S SISTER	3.80
LEAF	3.69
HIGH	3.69

タグ	In_iの合計 ($\times 10^{-1}$)
Kinship	1.22
The body	1.08
Basic actions and technology	0.75
Spatial relations	0.72
Food and drink	0.63
Agriculture and vegetation	0.59
Motion	0.51
The physical world	0.46
Sense perception	0.40

感情の中心頂点: なし

ナフ・タゲスタン語族

言語数	多義語数	頂点数	枝数
198	15,542	1,466	1,890,806

頂点	In_i ($\times 10^{-3}$)
HOUSE	5.45
HOLD	5.24
SEIZE	5.11
CATCH	4.99
AUNT	4.85
OUT-RIGGER	4.85
BOAT	4.80
LEARN	4.76
CANOE	4.55

タグ	In_iの合計 ($\times 10^{-1}$)
Kinship	0.99
Motion	0.97
The body	0.83
Basic actions and technology	0.80
The physical world	0.62
Spatial relations	0.60
Food and drink	0.52
Posession	0.49
Animals	0.46

感情の中心頂点: FEAR WANT

感情の中心頂点が異なるが，類似した中心頂点

4. まとめ・今後の課題

感情の中心頂点とは異なる語族毎の特徴を確認

今後の課題:

語族間の特徴と言語圏の地理的・文化的特徴との相関を調査

参考文献

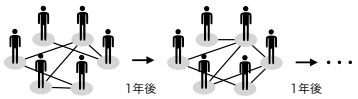
[1] J. M. List et al., https://clics.clld.org/, (Last visit Nov. 25th, 2021).
[2] A. Francois, *John Benjamin Publishing*, 163–215, 2008.
[3] 福家 他, IEICE NOLTA ソ大会, A-16, 2022.

A13 論文“Lyapunov exponents for temporal networks”の紹介

東京理科大学　池口研究室　B4　阿部賢一

1. はじめに

(例)人間関係



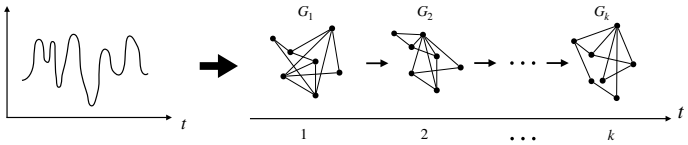
テンポラルネットワーク



テンポラルネットワークの性質を知りたい！

2. 目的

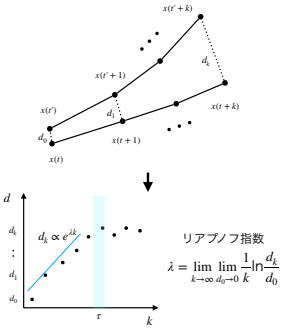
時系列データ → テンポラルネットワーク



時間変化を考慮したネットワーク

① 時系列の性質を保存したままテンポラルネットワーク化
② テンポラルネットワークのカオス性（リアプノフ指数）を調べる

リアプノフ指数



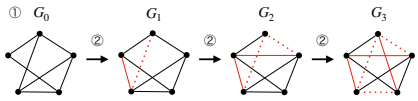
飽和時間 τ 以降
軌道間の距離は変化しなくなる

λ>0のとき　2つの軌道は離れる
→カオス性を持つ

3. 手法

3.1 時系列をテンポラルネットワークに変換する方法

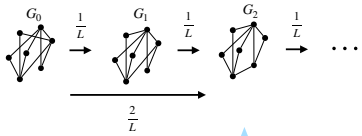
辞書ネットワーク[1][2]



生成方法

① G_0 をランダムに生成（ERモデル）
② 枝を以下の制約条件で繋ぎかえる
  1. 以前の反復で選ばれていない枝を選ぶ
  2. 以前の反復で枝が存在していない場所に付け替え

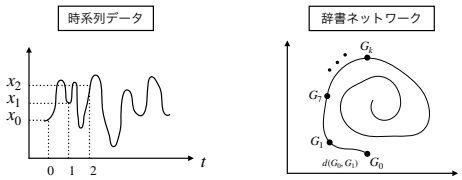
ネットワーク間の距離



辞書ネットワーク数Lで距離を正規化する

G_0 から G_L までの距離 $= 1$

辞書ネットワークと時系列データの対応



時系列データの差分 ∝ 辞書ネットワークの差分

↓

テンポラルネットワーク S を作成

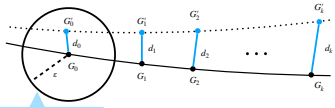
手順

(例)

時刻 t	(前の時刻との)差分	テンポラルネットワークS
0	なし	$S = \{G_0\}$
1	$\lvert x_1 - x_0 \rvert = \frac{2}{L}$	$S = \{G_0, G_2\}$
2	$\lvert x_2 - x_1 \rvert = \frac{1}{L}$	$S = \{G_0, G_2, G_1\}$ or $S = \{G_0, G_2, G_3\}$
⋮	⋮	⋮

3.2 リアプノフ指数の推定法

(1) Wolfの手法[3]



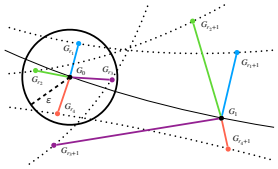
d_0は初期グラフ G_0 から閾値 ε 以内のグラフ G_0'との距離

平均膨張率　$l = \frac{1}{\tau}\sum_{k=1}^{\tau} \ln \frac{d_k}{d_{k-1}} = \frac{1}{\tau} \ln \frac{d_\tau}{d_0}$

G_0 の初期条件の数　w

ネットワークのリアプノフ指数 (Wolf法)　$\lambda^W = \frac{1}{w}\sum_{i=1}^{w} l(i)$

(2) Kantzの手法[4]



体積平均膨張率　$\Lambda(G_t) = \frac{1}{\tau} \ln \frac{\langle d_\tau \rangle_{volume}}{\langle d_0 \rangle_{volume}}$

G_0 の初期条件の数　w

ネットワークのリアプノフ指数 (Kantz法)　$\lambda^K = \frac{1}{w}\sum_{i=1}^{w} \Lambda(G_t^{(i)})$

4. 結果

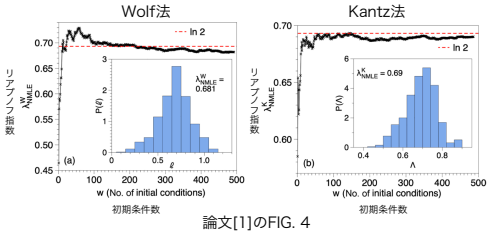
ロジスティック写像

$$x(t+1) = rx(t)(1 - x(t)),\ r = 4$$

↓

カオステンポラルネットワーク

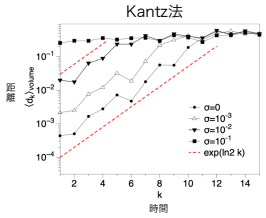
初期状態数とリアプノフ指数



論文[1]のFIG. 4

初期条件数w≈100でリアプノフ指数が収束する

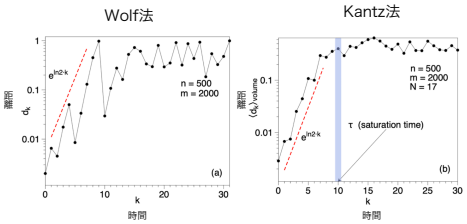
ノイズを付与したカオステンポラルネットワーク間の距離



論文[1]のFIG. 6

ノイズの大きさσによりτが減少する
σが大きい場合リアプノフ指数が検出できない

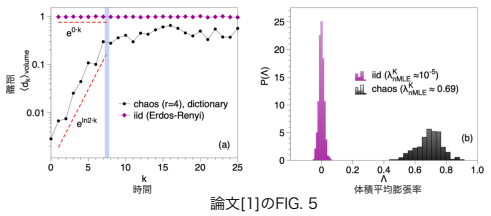
隣接したネットワーク間の距離



論文[1]のFIG. 3

飽和時間 $\tau \approx 10$
飽和時間 τ までの傾き=リアプノフ指数

独立同分布(iid)とカオステンポラルネットワークの比較



論文[1]のFIG. 5

独立同分布(iid)のリアプノフ指数 ≈ 0
ロジスティック写像のリアプノフ指数 ≈ 0.69

5. まとめ

- 時系列から辞書ネットワークを用いてテンポラルネットワークを作成
- テンポラルネットワークのカオス性の推定
- ロジスティック写像から生成したテンポラルネットワークのリアプノフ指数は0.69
  →カオス性がある

[参考文献]
[1] Annalisa Caligiuri, Victor M. Eguiluz, Leonardo Di Gino, Tobias Galla and Lucas Lacasa, “Lyapunov exponents for temporal networks,” Phys. Rev. E, Vol. 107, 044305, 2023.
[2] Lacasa, Lucas and Rodriguez, Jorge P. and Eguiluz, Victor M, “Correlations of network trajectories,” Phys. Rev. Res, Vol. 4, L042008, 2022.
[3] Alan Wolf and Jack B. Swift and Harry L. Swinney and John A. Vastano, “Determining Lyapunov exponents from a time series,” Physics D, Vol. 16, No. 3, pp. 285-317, 1985.
[4] Holger Kantz, “A robust method to estimate the maximal Lyapunov exponent of a time series,” Physics Letters A, Vol. 185, No. 1, pp. 77-87, 1994.

B13 交通流とNagel-Schreckenbergモデルの紹介

東京理科大学 池口研究室 B4 新井慎之介

1. 背景・目的



スムーズな交通

一定時間



渋滞

交通流をモデル化しシミュレートすることで
対策を考えられる

2. セルオートマトン(CA)

セルオートマトンで道路をモデル化



実際の道路

モデル化

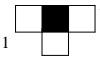
0：車両なし
1：車両あり

1	0	0	1

セルオートマトン

CAの理論

時刻 t
時刻 $t+1$

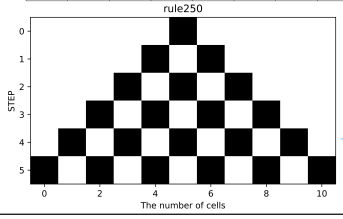


中心のセルの変化に注目し
次はどうなるか決める

時刻tでの3つのセルは$2^3=8$通りのパターンが存在し，それぞれに対して次の時刻での状態が白か黒か決まる．白黒の決め方は$2^8=256$通り．



ルール250での
セルの状態変化



ルール250で
5ステップ
実行した結果

3. Nagel-Schrekenberg(NaSch)モデル[1]

アルゴリズムの操作

1. 加速
$v_n \to \min(v_{n+1}, v_{\max})$

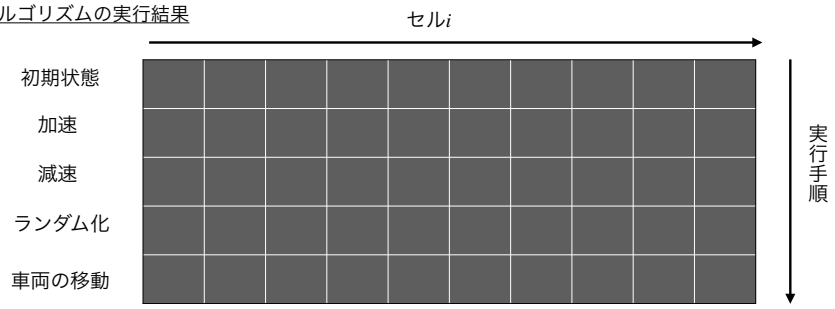
2. 減速
$v_n \to \min(v_n, d_{n-1})$

3. ランダム化
$\max(v_{n-1},0)$ 確率pで実行

4. 車両の移動
$x_n \to x_n + v_n$

v_n : n番目の車両の速度
x_n : n番目の車両の位置
d_{n-1}: 前方の車両との距離
$v_{\max}$: 最大速度
$v_{\max} = 5$

アルゴリズムの実行結果



論文の追試

密度

$$\rho = \frac{1}{T}\sum_{t=t_0+1}^{t_0+T} n_i(t)$$

流量

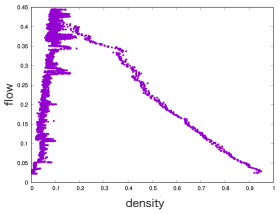
$$q = \frac{1}{T}\sum_{t=t_0+1}^{t_0+T} n_{i,i+1}(t)$$

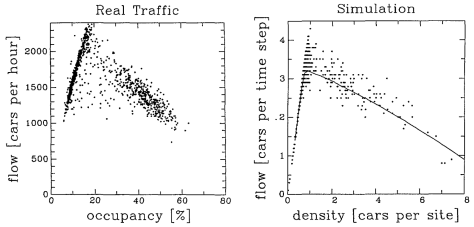
t_0: 過渡状態
T: タイムステップ数

$$n_i = \begin{cases} 1 & i\text{に車両あり} \\ 0 & i\text{に車両なし} \end{cases}$$

$n_{i,i+1}$: セルiと$i+1$の間に車両の移動があったか

$$n_{i,i+1} = \begin{cases} 1 & \text{移動あり} \\ 0 & \text{移動なし} \end{cases}$$





- 実際の交通データとよく似た結果を得ることができた．
- このモデルは実際の交通流を再現することができた．

4. NaSchモデルを多車線に拡張[2][3]

NaSchモデルは1車線だが，実際の道路を反映するために多車線について考えることが必要

車線変更について考える

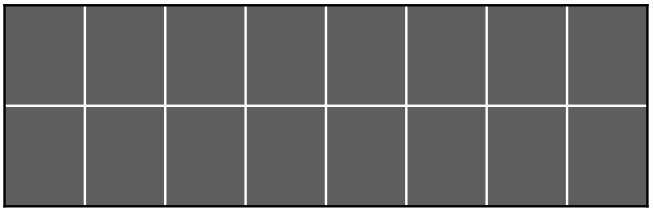
車線変更のルール

1. 車両が車線を変更できるエリアにいるか．
2. 車線変更によって速度が向上(密度が低下)するか．
3. 車線変更する先のセルが空いているか．
4. 移動先のセルの後ろが$V_{\max}$以上空いており，
自分のセルより前にV台以上の車両がいるか．

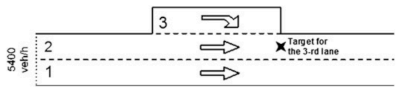
$V_{\max}$：車両の最大速度，V：車両の速度

車線変更の方法

偶数ステップでは右に，奇数ステップでは左に車線変更をする．



5. 交通流のシミュレーション



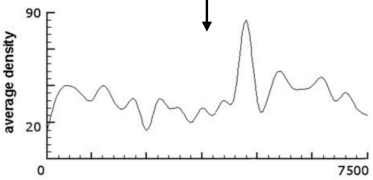
交通流(文献[2]図1)

シミュレーション状況

- 3車線→2車線の合流．
- 実際の道路をモデル化できるか．

結果

- シミュレータは実際の交通に近い振る舞いを示している．
- 文献[2]のモデルは交通シミュレータと同じような密度の値が出ている．



文献[2]のモデルで実行した結果(文献[2]図3)



既存のシミュレータ(文献[2]図4)

6. 結論

- このアルゴリズムを用いて，信号の制御や新しい道路の設置などの効果を見ることができる．
- マクロ的なモデルよりも単純で，リアルタイムに道路状況を推定することに有用である．

【参考文献】

【1】K. Nagel and M. Schrekenberg, *Journal de physique I*, Vol. 2, No. 12, pp. 2221–2229, 1992.

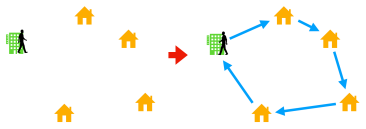
【2】A. Chechina et. al, *EPJ Web of Conferences*, Vol. 173, pp. 06003, 2018.

【3】M Trapeznikova et. al, *Mathematical Models and Computer Simulations*, Vol. 4, pp. 53—61, 2012.

A14 巡回セールスマン問題に対する近似解法のアルゴリズムの比較

東京理科大学 池口研究室 B4 市川健太

1.巡回セールスマン問題



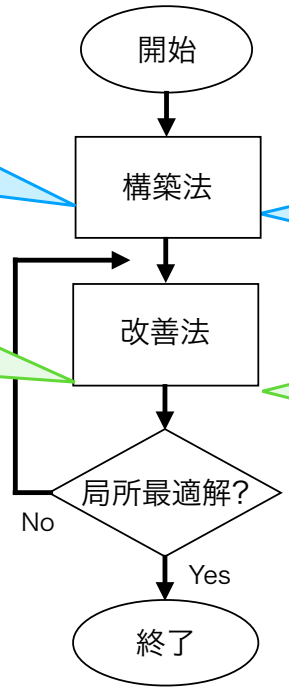
優れた近似解法

改良

LK法[1] → LKH法[2]

目的：LK法・LKH法の違いを調べることで，深く理解する．

2.LK法とLKH法の違い

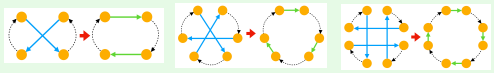


LK法

特徴：2,3-optを組み合わせることで
より多い枝の交換を実現しているため
多くの問題で最適解を早く求めることができる

初期巡回経路：ランダムに初期巡回経路を作成

基本動作：順次2,3-optと非順次4-opt



候補セット：長さが最小の枝5つ

候補セット…基本動作において追加する枝の候補となる枝

枝の削除

・長さがより大きい枝
・四番目以降を制限
これまでに求めた局所最適解に
共通する枝は削除してはいけない

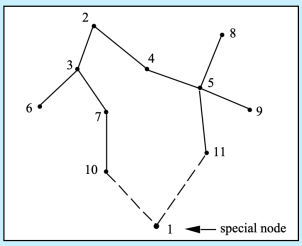
LKH法

特徴：LK法を改良したことで
より最適解に近い巡回経路をより早く求めることができる

初期巡回経路

α近似度を用いた構築法で初期巡回経路を作成

α近似度…最小1-treeにその枝を追加し，
1-treeにする過程で増加する長さ



最小1-tree（文献[2] 図4.1）

$\alpha(a,b)$を都市a,bを結ぶ枝のα近似度，
$c(a,b)$を都市a,bを結ぶ枝の長さとすると，

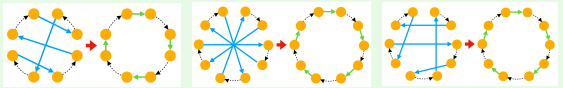
$\alpha(7,10) = 0$

$\alpha(6,10) = c(6,10) - c(7,10)$

$\alpha(1,7) = c(1,7) - c(1,11)$

基本動作：順次2,3,4,5-optと非順次4,5-opt

順次2,3-optと非順次4-opt



候補セット

長さとα近似度の性能比較（文献[2] 表4.1）

rank	c	α (π = 0)	Improved α
1	43.7	43.7	47.0
2	24.5	31.2	39.5
3	14.4	13.0	9.7
4	7.3	6.4	2.3
5	3.3	2.5	0.9
6	2.9	1.4	0.1
7	1.1	0.4	0.3
8	0.7	0.7	0.2
9	0.7	0.2	
10	0.3	0.1	
11	0.2	0.3	
12	0.2		
13	0.3		
14	0.2	0.1	
15			
16			
17			
18			
19	0.1		
20			
21			
22	0.1		
rank_{avg}	2.4	2.1	1.7

α近似度が最小の枝5つ

長さよりα近似度の方が，
最適解に枝が含まれるかの
指標として優れている．

枝の削除

・α近似度がより大きい枝
・一番目を制限
最良の巡回経路に含まれる枝は削除してはいけない

3.LKHの計算結果

ソースコードは文献[3] を使用

問題例	誤差率[%]	計算時間[s]
burma14	0.0000	0.00
ulysses16	0.0000	0.00
gr17	0.0000	0.00
gr21	0.0000	0.00
ulysses22	0.0000	0.00
gr24	0.0000	0.00
fri26	0.0000	0.00
bayg29	0.0000	0.00
bays29	0.0000	0.00
dantzig42	0.0000	0.00
swiss42	0.0000	0.00
att48	0.0000	0.00
gr48	0.0000	0.00
hk48	0.0000	0.00
eil51	0.0000	0.00
berlin52	0.0000	0.00
brazil58	0.0000	0.00
st70	0.0000	0.00
eil76	0.0000	0.00
pr76	0.0000	0.01
pr96	0.0000	0.02
rat99	0.0000	0.00
kroA100	0.0000	0.01
kroB100	0.0000	0.02
kroC100	0.0000	0.01
kroD100	0.0000	0.01
kroE100	0.0000	0.02

問題例	誤差率[%]	計算時間[s]
rd100	0.0000	0.00
eil101	0.0000	0.00
lin105	0.0000	0.00
pr107	0.0000	0.06
gr120	0.0000	0.01
pr124	0.0000	0.02
bier127	0.0000	0.01
ch130	0.0000	0.02
pr136	0.0000	0.05
gr137	0.0000	0.01
pr144	0.0000	0.23
ch150	0.0000	0.02
kroA150	0.0000	0.03
kroB150	0.0051	0.19
pr152	0.0000	0.33
u159	0.0000	0.00
si175	0.0009	4.40
brg180	0.0000	0.03
rat195	0.0143	0.09
d198	0.0000	0.36
kroA200	0.0000	0.03
kroB200	0.0000	0.01
gr202	0.0000	0.01
ts225	0.0000	0.03
tsp225	0.0000	0.02
pr226	0.0000	0.04
gr229	0.0007	0.22
gil262	0.0000	0.07
pr264	0.0000	0.10
a280	0.0000	0.01
pr299	0.0046	0.28
lin318	0.0000	0.14
linhp318	0.0000	0.05
rd400	0.0000	0.15

問題例	誤差率[%]	計算時間[s]
fl417	0.0000	2.41
gr431	0.0226	3.47
pr439	0.0067	0.85
pcb442	0.0000	0.06
d493	0.0025	2.70
att532	0.0102	0.87
ali535	0.0000	0.19
si535	0.0026	17.49
pa561	0.0000	0.32
u574	0.0027	0.38
rat575	0.0113	2.01
p654	0.0005	14.52
d657	0.0000	0.25
gr666	0.0148	3.12
u724	0.0010	1.13
rat783	0.0000	0.05
dsj1000	0.0001	20.53
pr1002	0.0001	1.79
si1032	0.0000	22.51
u1060	0.0060	62.49
vm1084	0.0273	20.25
pcb1173	0.0062	4.04
d1291	0.0056	5.94
rl1304	0.0683	12.69
rl1323	0.0035	6.26
nrw1379	0.0034	8.45
fl1400	0.1782	2996.36
u1432	0.0000	0.32
fl1577	0.0526	1042.88
d1655	0.0000	4.76
vm1748	0.0063	12.67
u1817	0.0932	63.61
u1889	0.0066	56.02
d2103	0.0157	135.57

問題例	誤差率[%]	計算時間[s]
u2152	0.0416	65.44
u2319	0.0000	0.44
pr2392	0.0000	0.62
pcb3038	0.0031	49.72
fl3795	0.1125	21810.13
fnl4461	0.0002	36.68
rl5915	0.0088	237.00
rl5934	0.0395	363.05
pla7397	0.0001	263.74
rl11849	0.0075	1842.93
usa1350	0.0023	2597.25
brd1405	0.0022	3357.50
d15112	0.0029	4033.10
d18512	0.0030	5956.40
pla33810	0.0132	495655.67
pla85900	0.0162	329067.05

4.まとめ

・初期巡回経路の作成をランダムでなく
することで，実行時間が短縮される．

・基本動作の拡張により，
より広い巡回経路の探索が可能になる．

・枝の追加・削除の基準を
長さからα近似度へ変えることで，
局所最適解が最適解に近くなる．

参考文献

[1] Lin Shen and Kernighan Brian W, “An effective heuristic algorithm for the traveling- salesman problem,” *Operations Research*, Vol. 21, No. 2, pp. 498–516, 1973.

[2] Helsgaun Keld, “An effective implementation of the Lin–Kernighan traveling sales- man heuristic,” *European Journal of Operational Research*, Vol. 126, No. 1, pp. 106–130, 2000.

[3] Keld Helsgaun,http://webhotel4.ruc.dk/ keld/, 最終閲覧日: 2023 年 08 月 06 日

B15

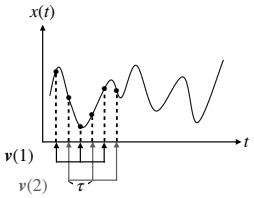
脳波データのアトラクタ再構成における適切な遅れ時間

東京理科大学 池口研究室 B4 関口真音

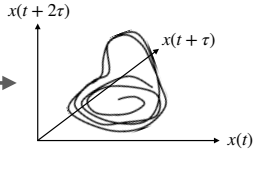
非線形問題解決重団 池口研究室 NONLINEAR DYNAMICAL SYSTEM

1. 背景

観測データ



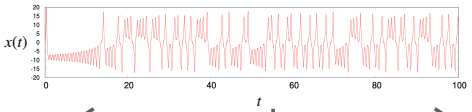
再構成アトラクタ



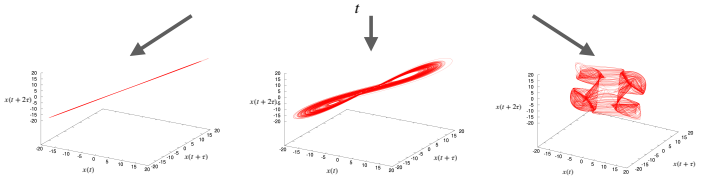
次元m，遅れ時間τの再構成ベクトル

$$\boldsymbol{v}(t) = (x(t), x(t+\tau), \cdots, x(t+(m-1)\tau))$$

2. 目的



適切なτの決定が重要

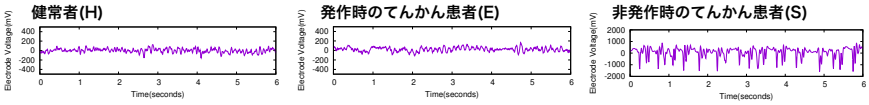


τが小さい　　τが適切 ⟶ 再構成　　τが大きい

自己相関関数と相互情報量より，適切な遅れ時間を求める

3. 脳波データ[1]

サンプリング周波数	173.61Hz
サンプリング時間	23.6s
1セットのデータ数	$n = 4097$
セット数	100



4. 遅れ時間の決定手法

主な遅れ時間値の設定法
- 自己相関関数[2]
- 再構成状態空間における結合確率密度[3]
- 相互情報量[4]

自己相関関数

$$R = \frac{\sum_{t=1+\tau}^{n} (X(t) - \bar{X}(t))(Y(t) - \bar{X}(t))}{\sum_{t=1}^{n} (X(t) - \bar{X}(t))^2}$$

Rが(i)最初に極小値をとるτ(ii)$1/e$となるτを再構成の遅れ時間とする

相互情報量

$$I(X,Y) = \sum_{i=1}^{M} \sum_{j=1}^{N} p(x_i, y_j) \log \frac{p(x_i, y_j)}{p(x_i)p(y_j)}$$

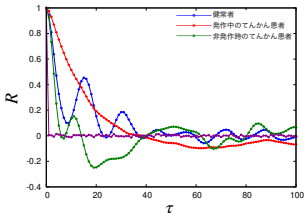
相互情報量が最初に極小値をとるτを再構成の遅れ時間とする

τ: 遅れ時間
$X(t)$: 時系列データ $(t = 1,2,\cdots,n)$
$\bar{X}(t)$: $X(t)$の平均
$Y(t) = X(t+\tau)$: 時間遅れデータ
x_i: $X(t)$の確率変数 $(i = 1,\cdots,M)$
y_j: $Y(t)$の確率変数 $(j = 1,\cdots,N)$
R: 自己相関関数
$p(x_i)$, $p(y_j)$: 確率分布
$p(x_i, y_i)$: $p(x_i)$と$p(y_j)$の同時確率分布
$I(X,Y)$: $X(t)$と$Y(t)$の相互情報量

5. 結果

自己相関関数

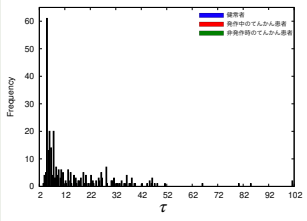
自己相関関数の変化



①健常者は，正の相関が大きい
②非発作時のてんかん患者は，負の相関が大きい

(i)最初に極小値をとるτ

遅れ時間の分布



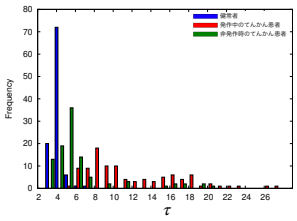
遅れ時間の平均と標準誤差

	H群	E群	S群
平均	8.32	26.06	11.04
標準誤差	11.79	16.54	8.32

遅れ時間の標準誤差が大きい

(ii)$1/e$となるτ

遅れ時間の分布



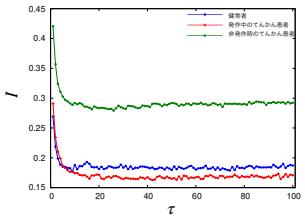
遅れ時間の平均と標準誤差

	H群	E群	S群
平均	3.91	11.55	6.04
標準誤差	0.62	4.90	3.74

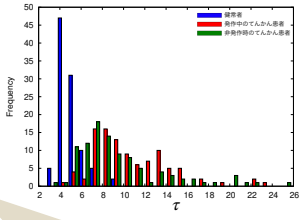
健常者は散らばりが小さい

相互情報量

相互情報量の変化



遅れ時間の分布



遅れ時間の平均と標準誤差

	H群	E群	S群
平均	4.71	10.28	9.27
標準誤差	1.10	3.69	4.32

非発作時のてんかん患者の相互情報量が大きい

健常者は散らばりが小さい

6. まとめ

健常者とてんかん患者の脳波データに対して，再構成時の最適な遅れ時間を得た．

自己相関関数の結果 -> $1/e$となるτを遅れ時間とするべき
相互情報量の結果 -> 非発作時のみ違いがある
遅れ時間の結果 -> 健常者のみ違いがある

7. 今後の方針

- 相関次元解析[3]
- リカレンスプロットと再帰定量的解析[5]

参考文献

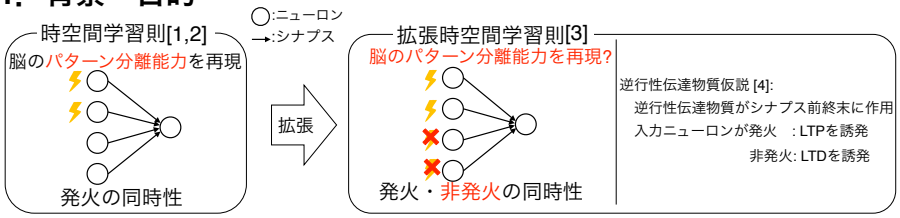
[1] 健常者とてんかん患者の脳波データ, http://www.meb.uni-bonn.de/epileptologie/science/physik/eegdata.html(最終閲覧日:2023年6月5日)
[2] A. M. Albano, J. Muench, C. Schwartz, and A. I. Mees, "Singular-value decomposition and the Grassberger-Procaccia algorithm," *Physical review A*, Vol. 38, No. 6, pp. 3017–3026, 1988.
[3] 池口徹, 山田泰司, 小室元政, "カオス時系列解析の基礎と応用", 産業図書, 2020.
[4] A. M.Fraser, "Reconstructing attractors from scalar time series: A comparison of singular system and redundancy criteria," *Physica D: Nonlinear Phenomena*, Vol. 3, No. 3, pp. 391–404, 1989.
[5] NorbertMarwanet.al, "Recurrence plots for the analysis of complex systems," *PhysicsReports*, Vol. 438, No. 5–6, pp. 237–329, 2007

A15

拡張時空間学習則のパターン分離能力

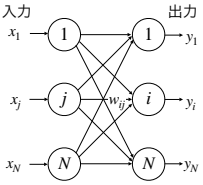
東京理科大学 池口研究室 B4 山本陽翔

1. 背景・目的



目的: 拡張時空間学習則のパターン分離能力を調査

2. ネットワーク



$x_j, y_i \in \{0,1\}$

w_{ij}: $i-j$のシナプス荷重

内部状態

$$s_i(t_n) = \sum_{j=1}^{N} w_{ij}(t_n)x_j(t_n)$$

出力

$$y_i(t_n) = F(s_i(t_n) - \eta)$$

$$F(x) = \begin{cases} 1 & x \geq 0 \\ 0 & x < 0 \end{cases}$$

η: 発火の閾値

3. 拡張時空間学習則[3]

発火の学習

x_j: 発火を1，非発火を0で表す

空間一致性

$$I_{ij}(t_n) = w_{ij}(t_n)x_j(t_n)\left\{\sum_{m=1,m\neq j}^{N} w_{im}(t_n)x_m(t_n)\right\}$$

時間履歴

$$J_{ij}(t_n) = \sum_{m=0}^{n} I_{ij}(t_m)\exp\left(-\frac{t_n - t_m}{\lambda}\right)$$

時間履歴なし

$$w_{ij}(t_{n+1}) = \begin{cases} w_{ij}(t_n) + \Delta w & I_{ij}(t_n) \geq \theta_1 \\ w_{ij}(t_n) & I_{ij}(t_n) < \theta_1 \end{cases}$$

時間履歴あり

$$w_{ij}(t_{n+1}) = \begin{cases} w_{ij}(t_n) + \Delta w & J_{ij}(t_n) \geq \theta_1 \\ w_{ij}(t_n) & J_{ij}(t_n) < \theta_1 \end{cases}$$

非発火の学習

$x_j^\dagger = 1 - x_j$: 発火を0，非発火を1で表す

空間一致性

$$I_{ij}^\dagger(t_n) = w_{ij}(t_n)x_j^\dagger(t_n)\left\{\sum_{m=1,m\neq j}^{N} w_{im}(t_n)x_m^\dagger(t_n)\right\}$$

時間履歴

$$J_{ij}^\dagger(t_n) = \sum_{m=0}^{n} I_{ij}^\dagger(t_m)\exp\left(-\frac{t_n - t_m}{\lambda}\right)$$

時間履歴なし

$$w_{ij}(t_{n+1}) = \begin{cases} w_{ij}(t_n) - \Delta w & I_{ij}^\dagger(t_n) \geq \theta_2 \\ w_{ij}(t_n) & I_{ij}^\dagger(t_n) < \theta_2 \end{cases}$$

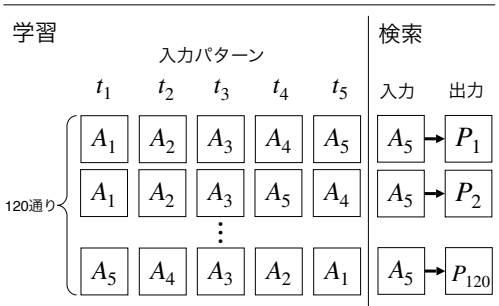
時間履歴あり

$$w_{ij}(t_{n+1}) = \begin{cases} w_{ij}(t_n) - \Delta w & J_{ij}^\dagger(t_n) \geq \theta_2 \\ w_{ij}(t_n) & J_{ij}^\dagger(t_n) < \theta_2 \end{cases}$$

λ: 時定数，Δw: 学習率，θ_1: LTPの閾値，θ_2: LTDの閾値

4. 実験手法

空間パターン $A_1 = \{0,1,0,\cdots,0,1\}$ 120ビット



$A_1 \cdots A_5$間のハミング距離: 10ビット

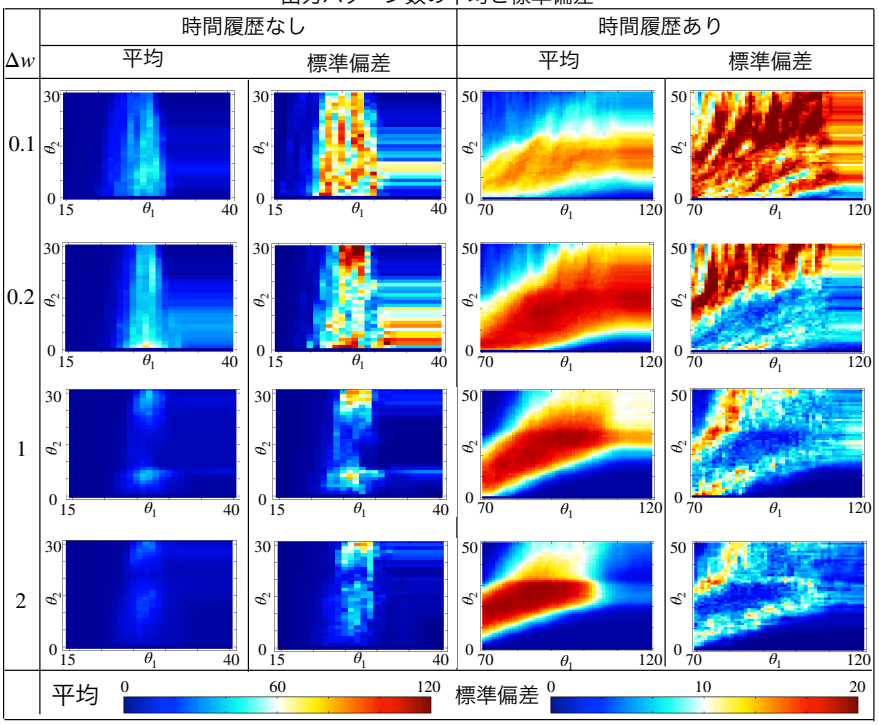
異なる出力パターンの数を調査

パターン数が多い :パターン分離能力が高い

少ない: パターン分離能力が低い

5. 結果

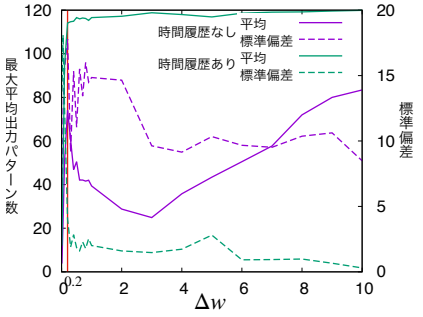
出力パターン数の平均と標準偏差



・時間履歴ありの方が平均出力パターン数が多い →**パターン分離能力が高い**

・平均出力パターン数が多いパラメータの標準偏差が小さい →**高いパターン分離能力へのロバスト性**

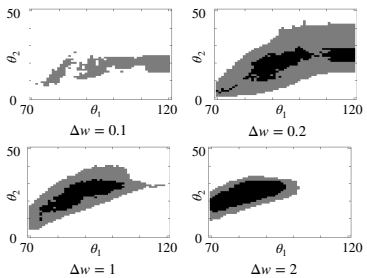
最大平均出力パターン数とその標準偏差の推移



・時間履歴の有無によらず，

$\Delta w = 0.2$のとき，出力パターン数が多い

時間履歴ありの出力パターン数の多い範囲



:84 (70%) 未満 :84 (70%) 以上 :108 (90%) 以上

・時間履歴ありでは，**$\Delta w = 0.2$のとき，出力パターン数が多い範囲が広い**

6. まとめ

・時間履歴なしよりも時間履歴ありの方がパターン分離能力が高く，ロバスト性がある

・時間履歴の有無によらず，$\Delta w = 0.2$のときパターン分離能力が高い

参考文献

[1] M. Tsukada, T. Aihara, H. Saito, and H.Kato, *Neural Network*, **9**(8), 1996.
[2] M. Tsukada and X. Pan, *Biological Cybernetics*, **92**(2), 2005.
[3] H. Tsukada, S. Nara, and M. Tsukada, "A Systematic Identification of the difference characteristics for Sequence Discrimination between Hebb and Extended Spatiotemporal Learning Rule," preprint, 2023.
[4] E. R. Kandel and T. J. O'dell, *Science*, **258**(5080),1992.

A16

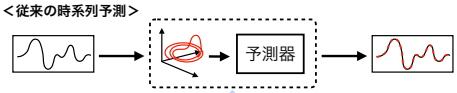
リザバーコンピューティングにおけるリザバー層のダイナミクス

東京理科大学 池口研究室 B4 吉田しおん

非線形問題解決集団 池口研究室 NONLINEAR DYNAMICAL SYSTEM

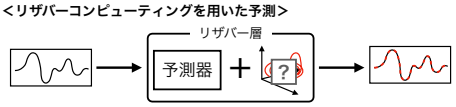
1. 背景・目的

＜従来の時系列予測＞



時系列を再構成して入力→予測精度向上

＜リザバーコンピューティングを用いた予測＞

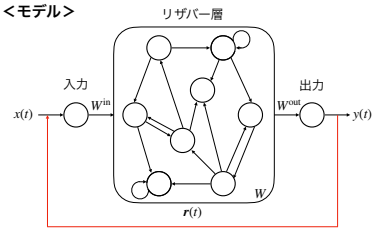


リザバー層では時系列を埋め込みで学習している?

リザバー層が埋め込みとなっているか
主成分分析，リアプノフスペクトラム解析より調査

2. リザバーコンピューティングのモデル

＜モデル＞



$$\begin{cases} x(t) \in \mathbb{R}^1 \\ r(t) = (r_1(t), \ldots, r_N(t))^T \in \mathbb{R}^N \\ y(t) \in \mathbb{R}^1 \end{cases} \quad \begin{cases} W^{in} \in \mathbb{R}^N \\ W \in \mathbb{R}^{N \times N} \\ W^{out} \in \mathbb{R}^{1 \times N} \end{cases}$$

W^{in}, Wは固定し，W^{out}のみ学習

＜状態更新式＞

- 1ステップ先予測

$$\begin{cases} x(t+1) = f(x(t)) \\ \boldsymbol{r}(t+1) = \tanh\left(W^{in}x(t+1) + W\boldsymbol{r}(t)\right) \\ y(t+1) = W^{out}\boldsymbol{r}(t+1) \end{cases}$$

- フリーラン予測

$$\begin{cases} \boldsymbol{r}(t+1) = \tanh\left(W^{in}W^{out}\boldsymbol{r}(t+1) + W\boldsymbol{r}(t)\right) \\ y(t+1) = W^{out}\boldsymbol{r}(t+1) \end{cases}$$

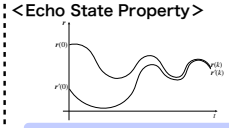
＜学習則＞

リッジ回帰

$$W^{out} = XR^{\mathrm{T}}(RR^{\mathrm{T}} + \beta I)^{-1}$$

X：目標時系列の行列，R：内部状態の行列，
β：正則化パラメータ

＜Echo State Property＞



十分時間経過すると入力に依存する値に収束

スペクトル半径

$$\rho(W) = \max_i(|\lambda_i|)$$

λ_i $(i = 1, \ldots, N)$：Wの固有値

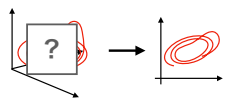
活性化関数がtanhのとき$\rho(W) < 1$とする
→ESPを満たすことが知られている

＜ハイパーパラメータ＞

N	リザバー層のノード数
W^{in}	入力強度
$\rho(W)$	リザバー層のスペクトル半径
p	リザバー層の結合密度
β	リッジ回帰の正則化パラメータ

3. 評価の指標

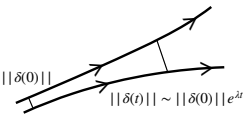
＜主成分分析＞



N次元力学系から損失を最小にして低次元化

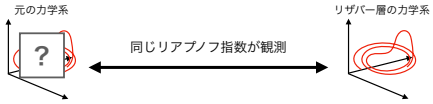
リザバー層のダイナミクスを2, 3次元空間で可視化できる

＜リアプノフ指数＞



$\lambda < 0$のとき
2つの軌道は近づく
$\lambda > 0$のとき
2つの軌道は離れる
→カオス性を持つ

＜リアプノフスペクトラム解析＞



リザバー層のダイナミクスは学習データの特徴を捉えている

4. ロジスティック写像の予測 [1]

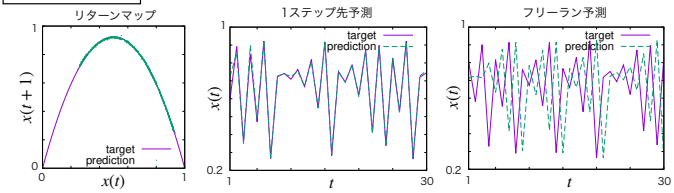
＜ロジスティック写像＞

$$x(t+1) = ax(t)(1 - x(t)) \triangleq f(x(t)) \qquad a = 3.7$$

N	W^{in}	$\rho(W)$	p	β	学習データ数	フリーラン回数
300	[-1, 1]	0.98	0.02	10^{-7}	1000	1000

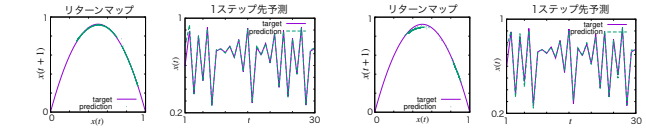
＜結果＞

フリーラン予測 成功例



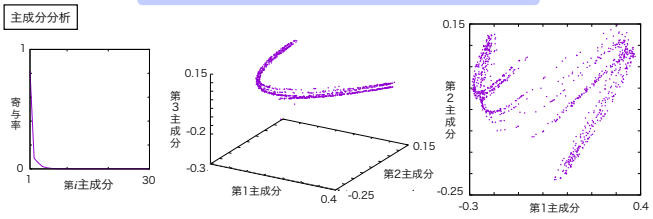
ロジスティック写像のリターンマップ上に予測値がプロット

フリーラン予測 失敗例



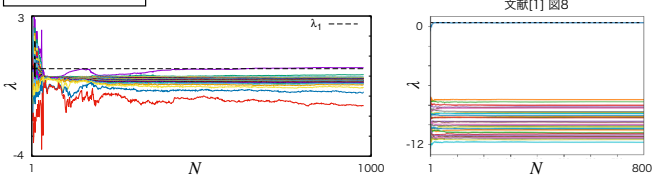
リターンマップ上に穴が存在しているが，1ステップ先予測は正確

主成分分析



放物線が見られる → リザバー層のダイナミクスはロジスティック写像の特徴を捉えている?

リアプノフスペクトラム

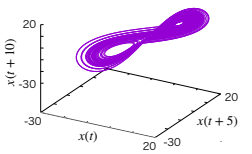


真値に近いリアプノフ指数が見られる→リザバー層のダイナミクスはロジスティック写像と同じ特徴を持つ?

5. ローレンツ方程式の予測 [2]

＜ローレンツ方程式＞

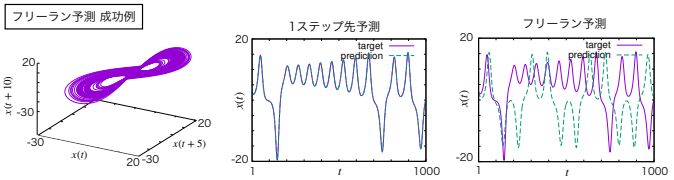
$$\begin{cases} \dot{x} = \sigma(-x + y) \\ \dot{y} = -xz + rz - y \Rightarrow \dot{x} \triangleq f(x(t)) \\ \dot{z} = -xy - wz \end{cases} \qquad \begin{matrix} \sigma = 10 \\ r = 28 \\ w = 8/3 \end{matrix}$$



N	W^{in}	$\rho(W)$	p	β	学習データ数	フリーラン回数
300	[-1, 1]	1.0	0.02	10^{-6}	1000	10000

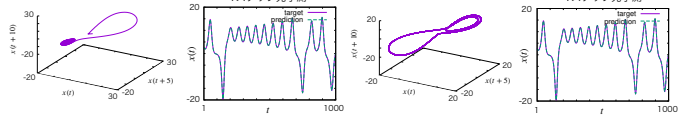
＜結果＞

フリーラン予測 成功例



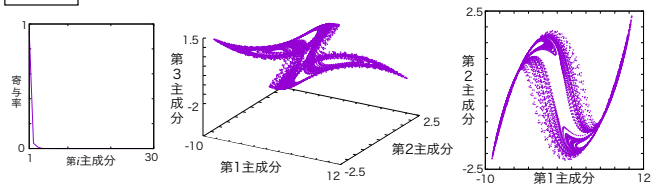
ローレンツ方程式のアトラクタを再現できている

フリーラン予測 失敗例



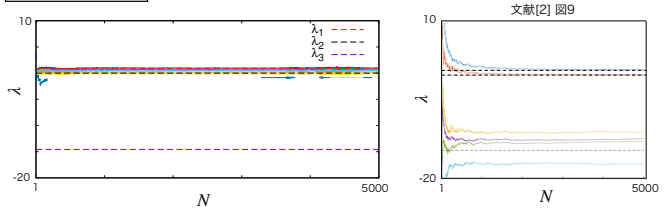
周期解や一定の値に収束しているが，1ステップ先予測は正確

主成分分析



ローレンツアトラクタ見られる → リザバー層のダイナミクスは埋め込みで学習している?

リアプノフスペクトラム



真値に近いリアプノフ指数が見られる→リザバー層のダイナミクスはローレンツ方程式と同じ特徴を持つ?

6. まとめ

リザバー層のダイナミクスに主成分分析，リアプノフスペクトラム解析を適用
→リザバー層は入力時系列を埋め込みで学習する可能性

[参考文献]
[1] Masato Hara and Hiroshi Kokubu, *Journal of Dynamics and Differential Equation*, pp. 1–26, 2022.
[2] Allen Hart, James Hook and Jonathan Dawes, *Neural Networks*, Vol. 128, pp. 234–247, 2020.

公職選挙ポスター掲示問題を解く手法に関する調査

東京理科大学 池口研究室 M2 郭豊愷

1. 公職選挙ポスター掲示問題

公職選挙におけるポスター掲示



ある自治体に対して，**複数のポスター掲示場**がある
どうやって**立候補者の情報を有権者に早く伝える**か

ただし，選挙活動に対して

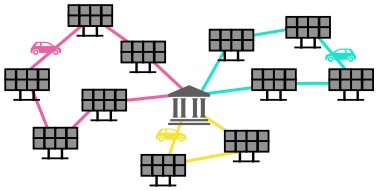


ポスター掲示時間は最大2週間だけ



ポスター掲示作業に
お金を出せない

最適なポスター掲示巡回経路を構築するために



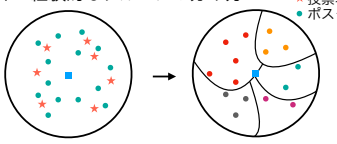
：選挙事務所　：ポスター掲示場

公職選挙ポスター掲示問題が提案される

2. グループ分けに対する最適解

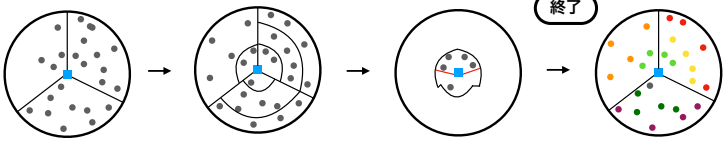
全ポスター掲示場を複数の車両に割り当てることが重要

方法1: 経験的なグループの分け方



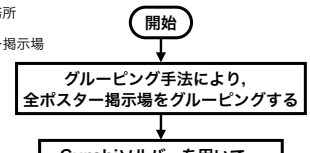
投票場の分布によりグルーピングする

方法2: 円形分割スキーム法[1]

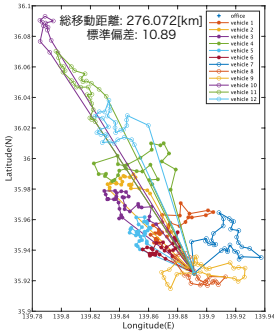


この例:
初期部分数=3

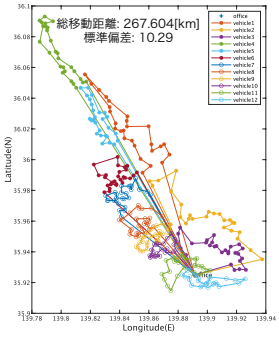
ポスター掲示場の空間分布によりグルーピングする



実験1~2: グルーピング手法で全ポスター掲示場を12のグループに割り当てて，各グループの最適経路を求める



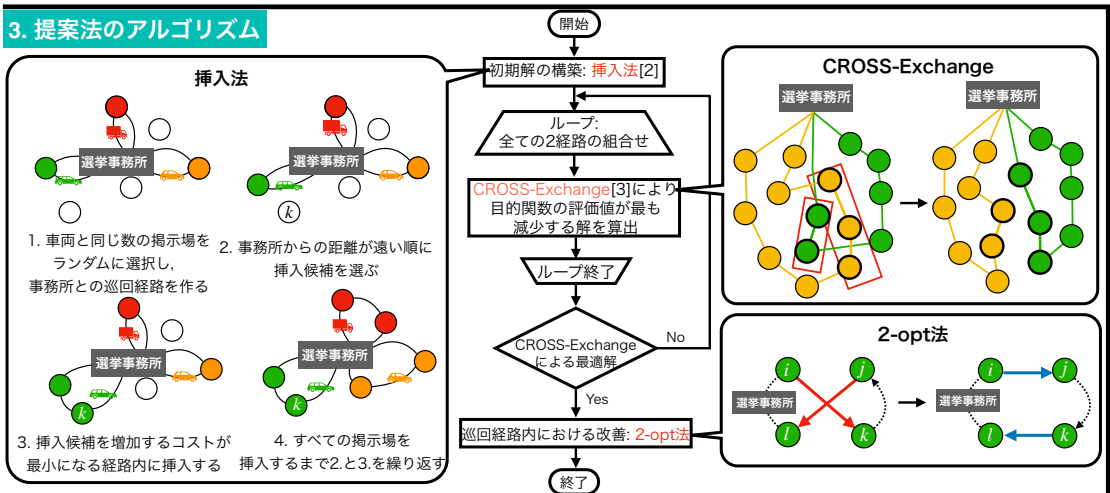
実験1: **経験的なグループの分け方**から得られた各グループを，巡回セールスマン問題として，Gurobiで構築した結果



実験2: **円形分割スキーム法**から得られた各グループを，巡回セールスマン問題として，Gurobiで構築した結果

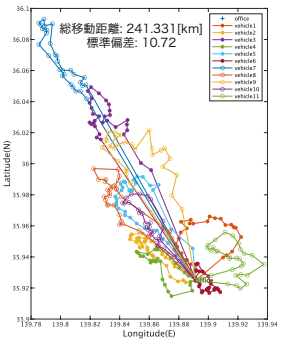
グループ分けによる最適解の計算結果が**最適ではない**

3. 提案法のアルゴリズム

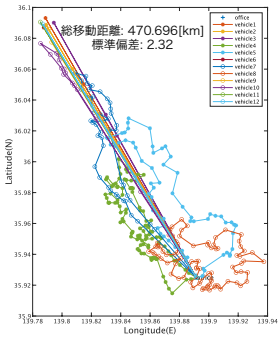


三つの目的関数を提案した: min-sum型目的関数: minimize 総移動距離　min-max型目的関数: minimize (maximum移動距離を持つ経路)
多目的関数: minimize p*総移動距離+(1-p)*車両移動距離の標準偏差

4. 実験と結果



実験4: 提案法のアルゴリズムにより求める巡回路の例(min-sum型目的関数)



実験5: 提案法のアルゴリズムにより求める巡回路の例(min-max型目的関数)

実験	方法	目的関数	総移動距離	標準偏差
実験1	経験的なグループ分け+巡回セールスマン問題としてGurobi	min-sum型	276.072[km]	10.89
実験2	円形分割スキーム法+巡回セールスマン問題としてGurobi (初期部分数: 3)	min-sum型	267.604[km]	10.29
実験3	円形分割スキーム法+巡回セールスマン問題としてGurobi (初期部分数: max)	min-sum型	293.071[km]	11.17
実験4	最遠挿入法+CROSS-Exchange+2-opt法 (30回平均)	min-sum型	241.331[km]	10.72
実験5	最遠挿入法+CROSS-Exchange+2-opt法 (30回平均)	min-max型	470.696[km]	2.32
実験6	最遠挿入法+CROSS-Exchange+2-opt法 (30回平均)	多目的関数	254.387km]	11.49

5. まとめ

- 実験4, 6の結果が実験1~3よりも良い.
- 実験4の結果を除いて，車両の移動距離の標準偏差が大きい.
- 提案したアルゴリズムを用いる場合，結果がlocal minimumに落ちたが，それに対する対策が必要.
- 対策として，**カオスダイナミックスを用いた解法**の開発を考える.

参考文献

[1] M. Haimovich & AHG. R. Kan, *Mathematics of operations Research*, Vol. 10, No. 4, pp. 527–542, 1985.
[2] 星野, 他. 電子情報通信学会論文誌 A, Vol. 90, No.5, pp. 431–441, 2007.
[3] E.Taillard, et al. *Transportation science*, Vol.31, No.2, pp.170-186, 1997.

8 論文 A multi-agent based cellular automata for intersection traffic control simulation の紹介

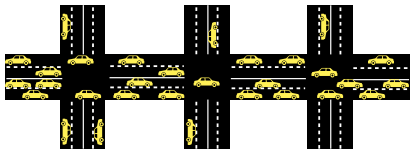
東京理科大学 池口研究室 B4 新井慎之介

1. 背景・目的

マルチエージェント

車両エージェント + 道路エージェント + 交差点エージェント

↓ セルオートマトン上で実現



マルチエージェントとセルオートマトンを組み合わせて交差点を含む道路を再現

2. セルオートマトン(CA)

CAの状態遷移

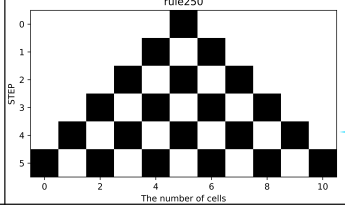
時刻 t
時刻 $t+1$

周りのセルの状態によって次の状態を決定

3つのセルは$2^3=8$通りのパターンが存在．各パターンに対して次の時刻の状態が決まる．

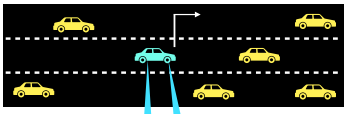


ルール250でのセルの状態変化



ルール250で5ステップ実行した結果

CAと交通モデリングの関係



前方車両の速度が遅い→車線変更をして速度を上げよう

車線変更先の後方車両の速度が速い→車線変更は少し待とう

周りの車両の動きを考慮して次の動作を決定することから，CAの理論を適用できる

※この例では1次元だが，モデルは2次元のCA

3.エージェントについて[1]

車両エージェント

車両追従ルール

1. パラメータの決定

$$V_{\max}=\begin{cases}V_{\max 1} & \text{交差点走行中}\\ V_{\max 2} & \text{交差点以外を巡航中}\end{cases}$$

$$d_{(i,t)}=X_{(i+1,t)}-X_{(i,t)}-1$$

$$p_d=\begin{cases}p_1 & \text{if } V_{(i,t)}=0\\ p_2 & \text{if } V_{(i,t)}\neq 0 \text{ and } V_{(i,t)}\leq V_{(i+1,t)}\\ \max\{\delta(V_{(i,t)}-V_{(i+1,t)})-\tau d_{(i,t)},0\} & \text{if } V_{(i,t)}\neq 0 \text{ and } V_{(i,t)}>V_{(i+1,t)}\end{cases}$$

$$a=\begin{cases}1\ [\text{cells/timestep}^2] & \text{if } V_{(i,t)}-V_{(i+1,t)}<3\\ 2\ [\text{cells/timestep}^2] & \text{if } V_{(i,t)}-V_{(i+1,t)}\geq 3\end{cases}$$

2. 加速

$$V_{(i,t+\frac{1}{3})}=\min\{V_{(i,t)}+1,V_{\max}\}$$

3. 減速

$$V_{(i,t+\frac{2}{3})}=\max\{V_{(i,t+\frac{1}{3})}-a,0\} \quad \text{if} \quad \text{rand}()<p_d$$

4. 前方車両との距離を考慮して速度を決定

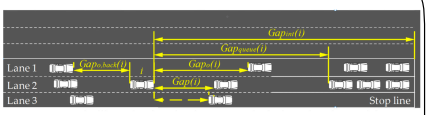
$$V_{(i,t+1)}=\begin{cases}\min\{V_{(i,t+\frac{2}{3})},d_{(i,t)}+V_{(i+1,t)}-t_{\text{headway}}\cdot V_{(i,t)}\} & \text{if } V_{(i+1,t)}\neq 0\\ \min\{V_{(i,t+\frac{2}{3})},d_{(i,t)}\} & \text{if } V_{(i+1,t)}=0\end{cases}$$

5. 位置の更新

$$X_{(i,t+1)}=X_{(i,t)}+V_{(i,t+1)}$$

$V_{\max}$：最大速度
t：時刻
$V_{(i,t)}$：車両iの速度
p_d：減速確率
a：減速値
$X_{(i,t)}$：車両iの位置

車線変更ルール



車線変更に必要なパラメータ(文献[1]図1)

任意の車線変更

$$\begin{aligned}Gap_{\text{queue}}(i) &> 30\\ Gap_{int}(i) &\geq 100\\ Gap_o(i) &> Gap(i)\\ Gap_{o,\text{back}}(i) &> V_{\max}\\ \text{rand}() &< p_c\end{aligned}$$

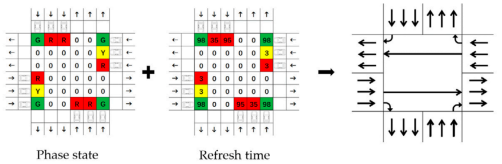
能動的な車線変更

$$\begin{aligned}Gap_{\text{queue}}(i) &> 30\\ Gap_{\text{int}}(i) &< 100\\ Gap_o(i) &> V_{\max}\\ Gap_{o,\text{back}}(i) &> V_{\max}\\ flag &= 1\\ \text{rand}() &< p_c\end{aligned}$$

必要な車線変更

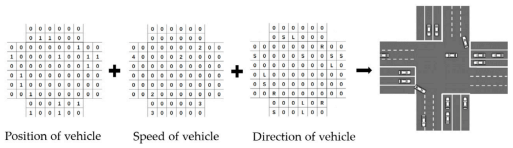
$$\begin{aligned}Gap_{\text{queue}}(i)\leq 30 \quad &\text{or} \quad Gap_{\text{int}}(i)\leq 30\\ Gap_o(i) &> V_{\max}\\ Gap_{o,\text{back}}(i) &> V_{\text{back}}\\ flag &= 1\end{aligned}$$

交差点エージェント



Phase state　Refresh time

信号の状態とサイクル時間の一例



Position of vehicle　Speed of vehicle　Direction of vehicle

交差点における道路状況の一例

道路エージェント

$$P(\chi)=\frac{(\lambda t)^{\chi}e^{-\lambda t}}{\chi!}$$

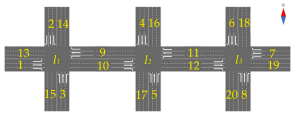
$P(\chi)$：時間間隔t内に到着する車の台数がχ台である確率

λt：時間間隔t内に車が到着する期待値

車両の到着確率を定義し，到着期待値を変更することで流量を変化させることができる．

4. シミュレーション

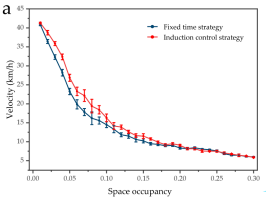
2つの信号戦略を比較
Fixed time strategy: 信号のサイクル時間を固定．
Induction control strategy: サイクル時間をWebsterのモデルにより動的に決定



シミュレーションを行う道路(文献[1]図3)

道路に発生する車両の情報			I_1 E	I_1 S	I_1 W	I_1 N	I_2 E	I_2 S	I_2 W	I_2 N	I_3 E	I_3 S	I_3 W	I_3 N
0-3000 タイムステップ	流入量（台数/時間）	直進		144	216	144		144		144	180	144		144
		左折		144	216	144		144		144	180	144		144
		右折		144	216	144		144		144	180	144		144
	実際の流入交通量（台数/時間）	直進	313	174	324	174	264	174	291	174	270	174	329	174
		左折	104	129	194	129	158	129	175	129	162	129	110	129
		右折	105	129	130	129	106	129	116	129	108	129	110	129
3000-5000 タイムステップ	流入量（台数/時間）	直進		180	432	180		180		180	360	180		180
		左折		180	432	180		180		180	360	180		180
		右折		180	432	180		180		180	360	180		180
	実際の流入交通量（台数/時間）	直進	544	108	778	108	583	108	791	108	648	108	799	108
		左折	181	162	387	270	292	162	395	270	216	162	399	270
		右折	182	270	131	162	97	270	132	162	216	270	133	162

E: 東からくる車両　S: 南からくる車両　W: 西からくる車両　N: 北からくる車両

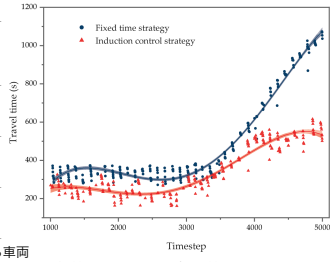


占有度が低いとき
→2つの戦略の差は小さい

占有度が高いとき
→Induction control strategyの方が交通効率が良い

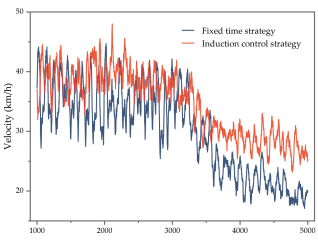
それ以上の占有率
→どちらの戦略も交通効率が悪い
→渋滞の発生

シミュレーション①
占有度を0.025ずつ増やしたときの速度と流量の変化(文献[1]図5)



横軸: タイムステップ，縦軸: 所要時間

シミュレーション②
運転経路(1 -I_1- 10 -I_2- 12 -I_3- 19)
を走行するのにかかる時間の変化を表した図



横軸: タイムステップ，縦軸: 所要時間

シミュレーション③
タイムステップと平均速度の関係を表した図

6. 結論

- マルチエージェントとCAモデルを結合し，複雑な道路交通システムに対応したモデルを構築．
- より多くの交通要素(歩行者や自転車など)を含むモデルへの拡張も可能．

【参考文献】
【1】W. Jinghui, L. Wei, J. Yajuan, Q. Shuangshuang and L. Jiawei, *Physica A: Statistical Mechanics and its Applications*, Vol. 584, 126356, 2021.

19

てんかん患者の脳波データに対する再帰定量化解析

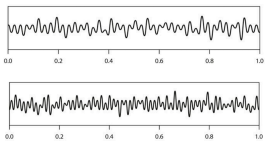
東京理科大学 池口研究室 B4 関口真音

1. 背景

健常者

てんかん患者

脳波データ



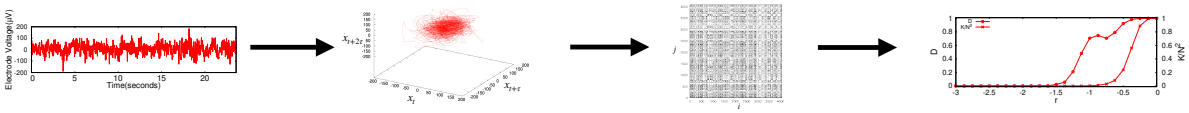
- 診断や予後予測に重要
- カオス性を持つ可能性が示唆されている

目的

非線形力学系理論に基づく
- 再構成パラメータの推定
- 決定論性の調査

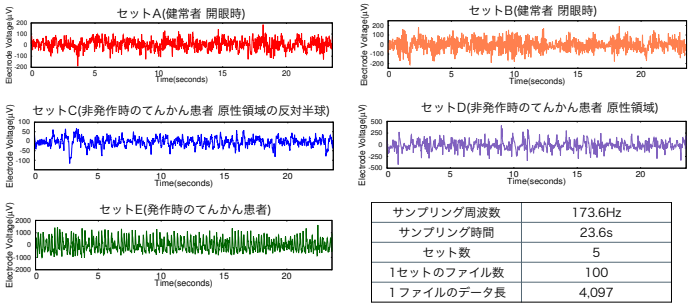
2. 解析手法

1.観測時系列 → 2.再構成アトラクタ → 3.リカレンスプロット[1] → 4. 決定論性評価DET[2]



3. 脳波データ[3]

観測時系列
$x_t \ (t = 1,2,\cdots,n)$



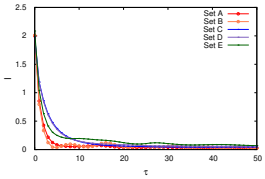
サンプリング周波数	173.6Hz
サンプリング時間	23.6s
セット数	5
1セットのファイル数	100
1ファイルのデータ長	4,097

4. 遅れ時間の推定

●相互情報量[4]を用いた手法

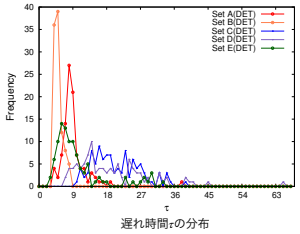
$$I = \sum_{i=1}^{L}\sum_{j=1}^{M} p(X_i, Y_j)\log\frac{p(X_i, Y_j)}{p(X_i)p(Y_j)}$$

$X_i = x_i$: 時系列データ
$Y_j = x_{j+\tau}$: 遅れ時間データ
$p(X_i, Y_j)$: X_i, Y_jが観測される確率
$p(X_i, Y_j)$: 同時確率



遅れ時間τを変化させたときの相互情報量

τを大きくし，最初に極小値を取る値を遅れ時間と推定



遅れ時間τの分布

セット	健常者		てんかん患者		
	A	B	C	D	E
平均	9.08	5.07	20.55	19.38	10.28
標準偏差	2.94	1.12	6.29	9.64	6.93

健常者と発作中のてんかん患者の分布と平均値は近い特性あり

5. 再構成次元の推定

●Caoの手法[5]

$$a(i,m) = \frac{\|\boldsymbol{v}_i(m+1) - \boldsymbol{v}_{n(i,m)}(m+1)\|}{\|\boldsymbol{v}_i(m) - \boldsymbol{v}_{n(i,m)}(m)\|}$$

$$E(m) = \frac{1}{n-m\tau}\sum_{i=1}^{n-m\tau} a(i,m)$$

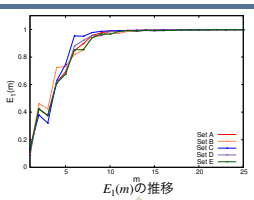
$$E_1(m) = E(m+1)/E(m)$$

$$E^*(m) = \frac{1}{n-m\tau}\sum_{i=1}^{n-m\tau} x_{i+m\tau} - x_{n(i,m)+m\tau}$$

$$E_2(m) = E^*(m+1)/E^*(m)$$

$a(i,m)$: 近傍の変化を測る指標
$E(m)$: $a(i,m)$の平均
$E_2(m)$: 決定論性か測る指標
$n(i,m)$: $\boldsymbol{v}_i(m)$の最近傍点インデックス

$E_1(m+1) - E_1(m) \leq \Theta$: 収束判定
Θ: 閾値

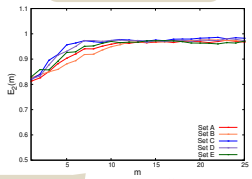


$E_1(m)$の推移

$E_1(m)$が収束を始めた値を再構成次元と推定

収束判定を変化させた最小埋め込み次元

Θ	健常者		てんかん患者		
	A	B	C	D	E
10^{-1}	4.56	3.75	3.81	3.64	2.23
10^{-2}	9.29	8.87	8.77	8.5	8.82
10^{-3}	15.23	15.23	12.36	13.3	16.71



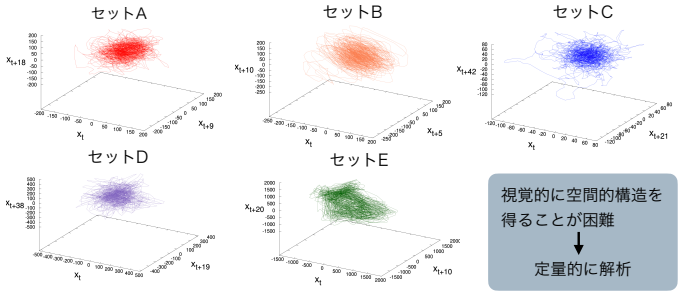
$E_2(m)$の推移

$E_2(m)$より脳波データはランダムではない
収束判定は$\Theta = 10^{-2}$が適切

$E_2(m) = 1$のときランダム

6. 再構成アトラクタ

次元m，遅れ時間τの再構成ベクトル
$$\boldsymbol{v}_t(m) = \left(x_t, x_{t+\tau}, \cdots, x_{t+(m-1)\tau}\right)$$

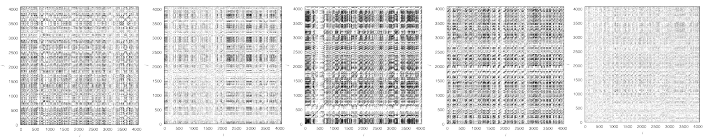


視覚的に空間的構造を得ることが困難
↓
定量的に解析

7. リカレンスプロット

$$P_{i,j} = \begin{cases} 1 & (\text{if } d_{i,j}^m \leq \theta_r) \\ 0 & (\text{otherwise}) \end{cases}$$

$d_{i,j}^m$: アトラクタ上の2点間距離
$d_{\max}^m$: 最大2点間距離
θ_r: 閾値$(\theta_r = 10^r \cdot d_{\max}^m)$



セットEに対して他のセットはパターンの変化がわかりやすい

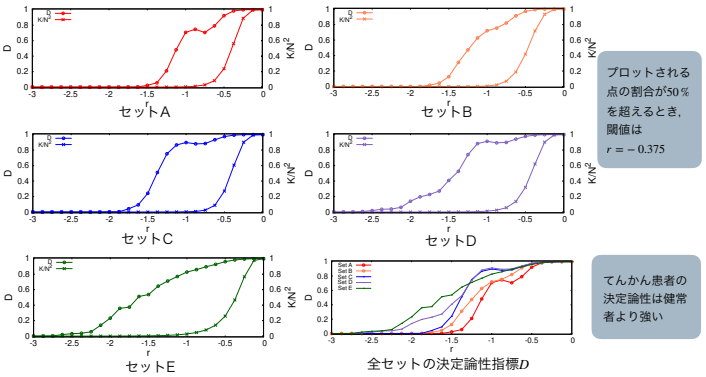
8. DET

● 再帰定量化解析の一つである決定論性評価指標

$$S(l) = \begin{cases} \sum_{j=2}^{N-l}(1-P_{i+l,j+l})\prod_{k=0}^{l-1}P_{i+k,j+k} & (i=1) \\ \sum_{i=2}^{N-l}\sum_{j=i+1}^{N-l}(1-P_{i-1,j-1})(1-P_{i+l,j+l})\prod_{k=0}^{l-1}P_{i+k,j+k} & (i \geq 2) \end{cases}$$

$$D = \frac{1}{K}\sum_{l=l_{\min}}^{N-1} lS(l) = \frac{\sum_{l=l_{\min}}^{N-1} lS(l)}{\sum_{l=1}^{N-1} lS(l)} \qquad N = n-(m-1)\tau$$

D: 決定論性指標
K: RPに打たれる点の総数
l: 斜め線の長さ
$l_{\min}$: 斜め線の最小の長さ
$S(l)$: 長さlの斜め線の数



プロットされる点の割合が50％を超えるとき，閾値は$r = -0.375$

てんかん患者の決定論性は健常者より強い

9.まとめ

時間遅延座標系に変換する際，適切な遅れ時間と再構成次元を推定
- 健常者とてんかん患者は近い特性を持つ

リカレンスプロットから決定論性を調査
- てんかん患者は健常者よりも決定論性が強い

参考文献

[1] J. -P. Eckmann, S. Oliffson Kamphorst, and D. Ruelle, "Recurrence plot of dynamical systems," *World Scientific SeriesonN onlinear Science Series A*, Vol. 16, pp. 441–446, 1995.
[2] N. Marwan, M. Carmen Romano, M. Thiel, and J. Kurths, "Recurrence plots for the analysis of complex systems," *Physics Reports*, Vol. 438, No. 5–6, pp. 237—329, 2007.
[3] 健常者とてんかん患者の脳波データ, http://www.meb.uni-bonn.de/epileptologie/science/physik/eegdata.html(最終閲覧日:2023年10月21日)
[4] A. M. Fraser, "Reconstructing attractors from scalar time series: A comparison of singular system and redundancy criteria," *Physica D: Nonlinear Phenomena*, Vol. 3, No. 3, pp. 391–404, 1989.
[5] L. Cao, "Practical method for determining the minimum embedding dimension of a scalar time series," *Physica D: Nonlinear Phenomena*, Vol. 110, Nos. 1–2, pp. 43–50, 1997.

4

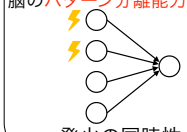
拡張時空間学習則のパターン分離能力とその頑健性

東京理科大学 池口研究室 B4 山本陽翔

1. 背景・目的

○:ニューロン
→:シナプス

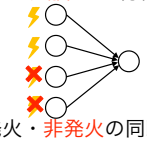
時空間学習則[1,2]
脳のパターン分離能力を再現



発火の同時性

拡張

拡張時空間学習則[3]
脳のパターン分離能力を再現できる？

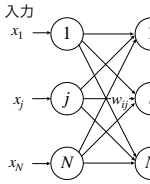


発火・非発火の同時性

逆行性伝達物質仮説 [4]:
逆行性伝達物質がシナプス前終末に作用
入力ニューロンが発火　:増強を誘発
非発火: 減弱を誘発

目的: 拡張時空間学習則のパターン分離能力とその頑健性を調査

2. ネットワーク



$x_j, y_i \in \{0,1\}$
w_{ij}: $i-j$のシナプス荷重

内部状態

$$s_i(t_n) = \sum_{j=1}^{N} w_{ij}(t_n)x_j(t_n)$$

出力

$$y_i(t_n) = F(s_i(t_n) - \eta)$$

$$F(x) = \begin{cases} 1 & x \geq 0 \\ 0 & x < 0 \end{cases}$$

η: 発火の閾値
t_n: 時刻

3. 時空間学習則[1,2]

x_j: 発火を1，非発火を0で表す

発火の空間一致性

$$I_{ij}(t_n) = w_{ij}(t_n)x_j(t_n)\left\{\sum_{m=1,m\neq j}^{N} w_{im}(t_n)x_m(t_n)\right\}$$

発火の時間履歴

$$J_{ij}(t_n) = \sum_{m=0}^{n} I_{ij}(t_m)\exp\left(-\frac{t_n - t_m}{\lambda}\right)$$

時空間学習則の重みの更新式

$$w_{ij}(t_{n+1}) = \begin{cases} w_{ij}(t_n) + \Delta w & J_{ij}(t_n) \geq \theta_1 \\ w_{ij}(t_n) & \theta_1 > J_{ij}(t_n) > \theta_2 \\ w_{ij}(t_n) - \Delta w & \theta_2 \geq J_{ij}(t_n) \end{cases}$$

λ: 時定数，Δw: 学習率，θ_1: 増強の閾値，θ_2: 減弱の閾値

4. 拡張時空間学習則[3]

$x_j^{\dagger} = 1 - x_j$: 発火を0，非発火を1で表す

非発火の空間一致性

$$I_{ij}^{\dagger}(t_n) = w_{ij}(t_n)x_j^{\dagger}(t_n)\left\{\sum_{m=1,m\neq j}^{N} w_{im}(t_n)x_m^{\dagger}(t_n)\right\}$$

非発火の時間履歴

$$J_{ij}^{\dagger}(t_n) = \sum_{m=0}^{n} I_{ij}^{\dagger}(t_m)\exp\left(-\frac{t_n - t_m}{\lambda}\right)$$

拡張時空間学習則の重みの更新式

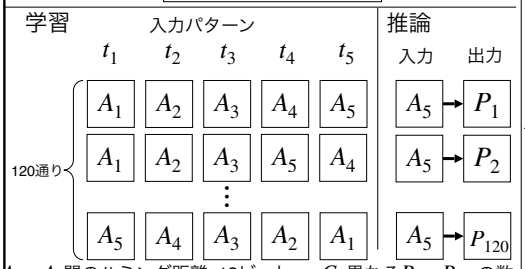
$$w_{ij}(t_{n+1}) = \begin{cases} w_{ij}(t_n) + \Delta w & J_{ij}(t_n) \geq \theta_1 \\ w_{ij}(t_n) & J_{ij}(t_n) < \theta_1 \end{cases}$$

$$w_{ij}(t_{n+1}) = \begin{cases} w_{ij}(t_n) - \Delta w & J_{ij}^{\dagger}(t_n) \geq \theta_2 \\ w_{ij}(t_n) & J_{ij}^{\dagger}(t_n) < \theta_2 \end{cases}$$

λ: 時定数，Δw: 学習率，θ_1: 増強の閾値，θ_2: 減弱の閾値

5. 実験手法

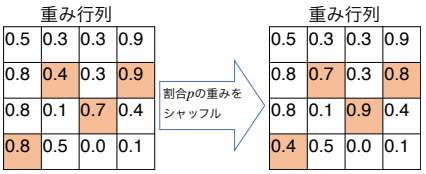
学習 → ネットワークの重みをランダムシャッフル → 推論



$A_1 \cdots A_5$間のハミング距離: 12ビット
C: 異なる$P_1 \cdots P_{120}$の数

空間パターン $A_1 = \{0,1,0,\cdots,0,1\}$ 120ビット

ランダムシャッフル



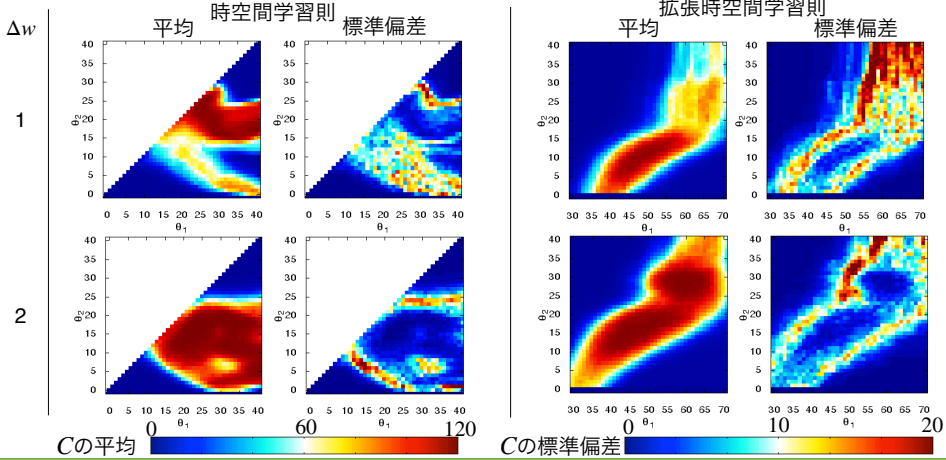
異なる出力パターン数 C

Cが大きい: パターン分離能力が高い
小さい: パターン分離能力が低い

Cが100を下回るときのpの値 p'

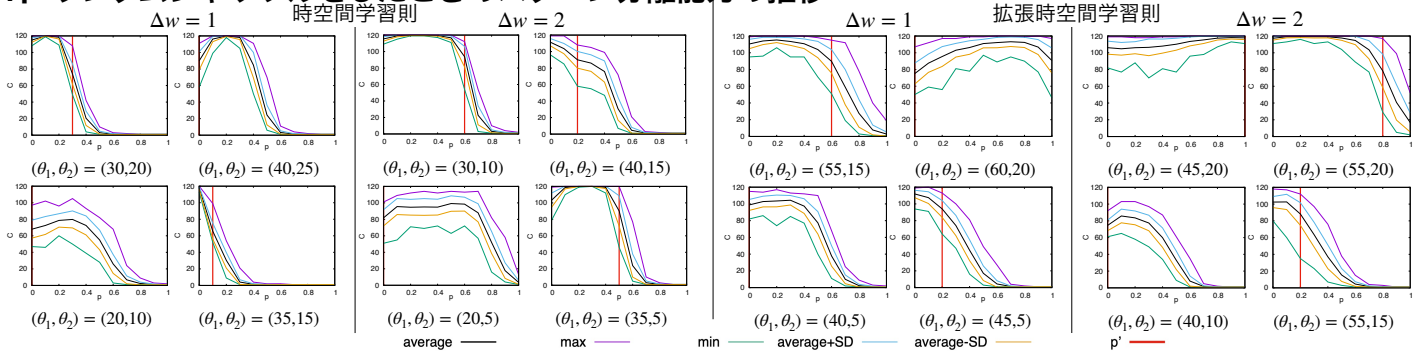
p'が大きい: パターン分離能力への頑健性が高い
小さい: パターン分離能力への頑健性が低い

6. パターン分離能力の比較



・Cの平均が大きい範囲に差があるが，Cの値に差は見られない → パターン分離能力に差はない
・Cの平均が大きいとき，Cの標準偏差が小さくなる → パターン分離能力への頑健性

7. ランダムシャッフルをしたときのパターン分離能力の推移



・時空間学習則より拡張時空間学習則の方がp'の最大値が大きい → 拡張時空間学習則の方がパターン分離能力への頑健性が高い
・学習率が大きい方がp'の最大値が大きい → 学習率が高い方がパターン分離能力への頑健性が高い

8. まとめ

・時空間学習則と拡張時空間学習則では，パターン分離能力に差がみられない
・拡張時空間学習則の方がパターン分離能力への頑健性が高い

参考文献

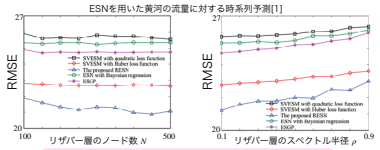
[1] M. Tsukada, T. Aihara, H. Saito, and H.Kato, *Neural Network*, **9**(8), 1996.
[2] M. Tsukada and X. Pan, *Biological Cybernetics*, **92**(2), 2005.
[3] H. Tsukada, S. Nara, and M. Tsukada, "A Systematic Identification of the difference characteristics for Sequence Discrimination between Hebb and Extended Spatiotemporal Learning Rule," preprint, 2023.
[4] E. R. Kandel and T. J. O'dell, *Science*, **258**(5080),1992.

15 ESNを用いたロジスティック写像の予測におけるパラメータの影響

東京理科大学 池口研究室 B4 吉田しおん

非線形問題解決手法 池口研究室 NONLINEAR DYNAMICAL SYSTEM

1. はじめに



ESNのパラメータによって予測精度が変化する



N	リザバー層のノード数
W^{in}	入力強度
ρ	リザバー層のスペクトル半径の大きさ
p	リザバー層の結合密度
β	リッジ回帰の正則化パラメータ

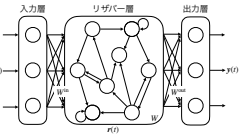
2. 目的

$a = 4.0$とするロジスティック写像の
フリーラン予測を行うための適切な
リザバー層のノード数，スペクトル半径を探索する

3. エコーステートネットワーク

● 学習フェーズ

・ESNの基本モデル[2]



$$\begin{cases} x(t) \in \mathbb{R}^{N_x} \\ \boldsymbol{r}(t) = (r_1(t), \ldots, r_N(t))^T \in \mathbb{R}^N \\ y(t) \in \mathbb{R}^{N_y} \end{cases} \quad \begin{cases} \boldsymbol{W}^{\text{in}} \in \mathbb{R}^{N \times N_x} \\ \boldsymbol{W} \in \mathbb{R}^{N \times N} \\ \boldsymbol{W}^{\text{out}} \in \mathbb{R}^{N_y \times N} \end{cases}$$

W^{in}, Wは乱数で決定し，W^{out}のみ学習

・状態更新式

$$\begin{cases} x(t+1) = f(x(t)) \\ \boldsymbol{r}(t+1) = \tanh\left(\boldsymbol{W}^{\text{in}} x(t+1) + \boldsymbol{W}\boldsymbol{r}(t)\right) \\ y(t+1) = \boldsymbol{W}^{\text{out}}\, \boldsymbol{r}(t+1) \end{cases}$$

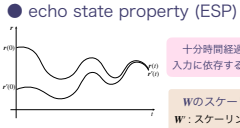
・学習則

リッジ回帰

$$\boldsymbol{W}^{\text{out}} = \boldsymbol{X}\boldsymbol{R}^{\mathrm{T}}(\boldsymbol{R}\boldsymbol{R}^{\mathrm{T}} + \beta \boldsymbol{I})^{-1}$$

X : 入力時系列の行列，R : リザバー状態の行列，
β : 正則化パラメータ

● echo state property (ESP)



$$\rho(\boldsymbol{W}) = \max_i(|\lambda_i|)$$

$\lambda_i\,(i = 1, \ldots, N)$: $\boldsymbol{W}$の固有値

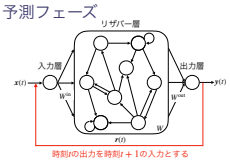
十分時間経過すると
入力に依存する値に収束

Wのスケーリング
$\boldsymbol{W}'$: スケーリング前の$\boldsymbol{W}$
要素w_{ij}'を乱数で決める
λ_i' : $\boldsymbol{W}'$の固有値

$$\boldsymbol{W} = \frac{1}{\max_i(|\lambda_i'|)}\rho \boldsymbol{W}'$$

活性化関数がtanhのとき$\rho(W) < 1$とする
→ESPを満たすことが知られている

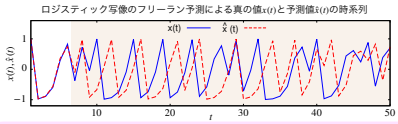
● 予測フェーズ



・状態更新式

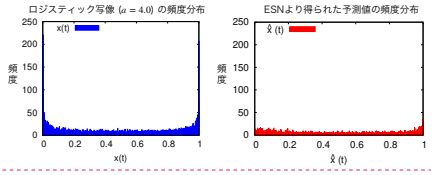
$$\begin{cases} \boldsymbol{r}(t+1) = \tanh\left(\boldsymbol{W}^{\text{in}}\boldsymbol{W}^{\text{out}}\boldsymbol{r}(t+1) + \boldsymbol{W}\boldsymbol{r}(t)\right) \\ y(t+1) = \boldsymbol{W}^{\text{out}}\boldsymbol{r}(t+1) \end{cases}$$

4. 実験の流れ



nステップ先予測値は異なり，僅かな差によって誤差が蓄積されてしまう．
→カオス性を持つ時系列のフリーラン予測は誤差で評価することができない

頻度分布の非類似度で予測精度を評価



● 分布の非類似度の指標

・Kullback-Leibler divergence (KLD) [4]

$$D_{KL}(P||Q) = \sum_x P(x)\log\frac{P(x)}{Q(x)}$$

$P(x)$: 入力した時系列の頻度分布
$Q(x)$: 予測より得た時系列の頻度分布
$R(x)$: $P(x)$と$Q(x)$の平均分布

・Jensen-Shannon divergence (JSD) [5]

$$D_{JS}(P,Q) = \frac{1}{2}\left(D_{KL}(P||R) + D_{KL}(Q||R)\right),\ R(x) = \frac{1}{2}\left(P(x) + Q(x)\right)$$

・$L2$ノルム

$$D_{L2}(P,Q) = \left(\sum_x |P(x) - Q(x)|^2\right)^{\frac{1}{2}}$$

5. 実験条件

● モデル力学系

・ロジスティック写像

$$x(t+1) = ax(t)(1 - x(t))$$

パラメータ: $a = 4.0$

● ESNのハイパーパラメータ

・変更するパラメータ

- リザバー層のノード数N : [20, 100] 刻み幅 10
- スペクトル半径の大きさρ : [0.95, 1.0] 刻み幅 0.01
  [1.0, 8.0] 刻み幅 0.1
- 乱数の種 : [0, 199]

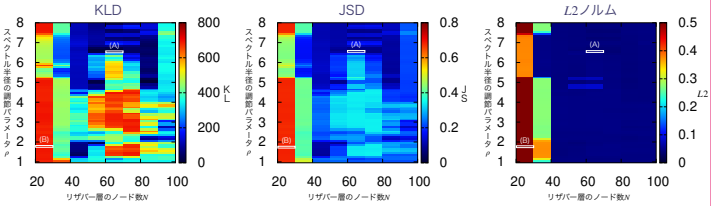
・固定するパラメータ

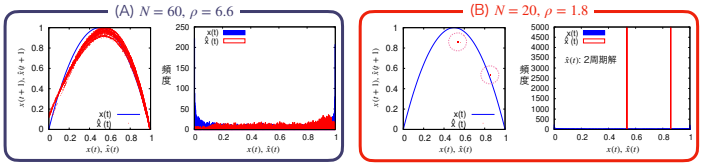
入力強度 W^{in}	リザバー層の結合密度 p	正則化パラメータ β	学習データ長 L	フリーラン数 L_f
$[-1, 1]$	0.02	10^{-7}	2,000	10,000

6. 実験結果

評価指標 (A) ○ (B) ×

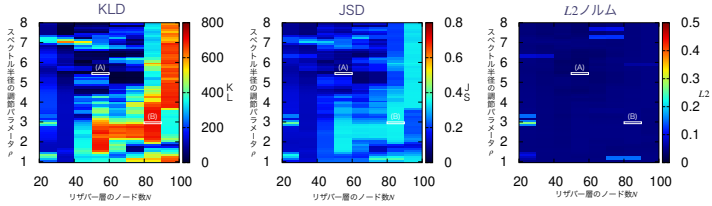
● 乱数の種 : 29

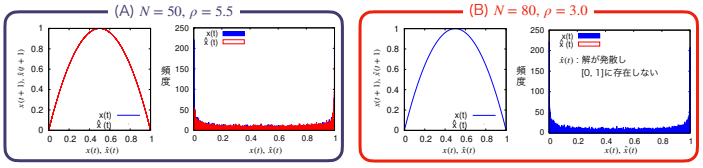




(A) 3つの指標 (KL, JS, $L2$) が比較的小さい値を取る→リターンマップ上に予測値がプロットされる
(B) 3つの指標 (KL, JS, $L2$) が比較的大きい値を取る→予測値は2周期解となっている

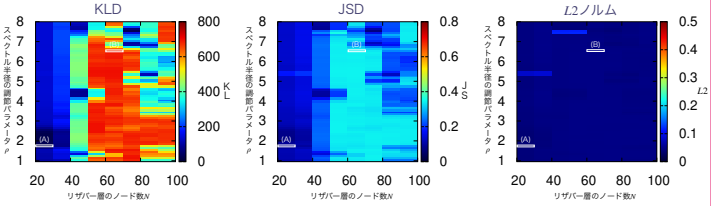
● 乱数の種 : 36

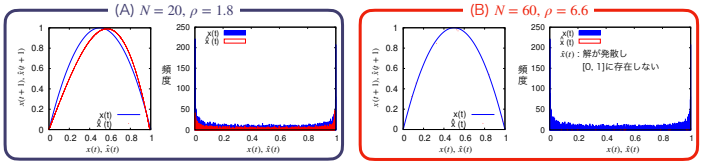




(A) 3つの指標 (KL, JS, $L2$) が比較的小さい値を取る→リターンマップ上に予測値がプロットされる
(B) KL, JS divergenceは比較的大きいが，$L2$ノルムは小さい値を取る→予測値は発散し[0, 1]に存在しない

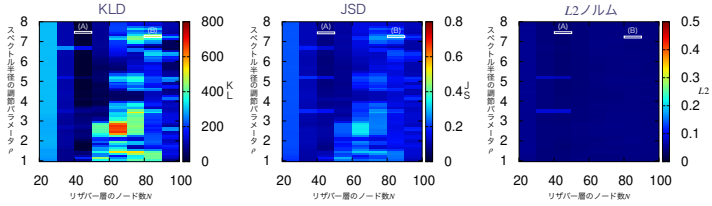
● 乱数の種 : 127

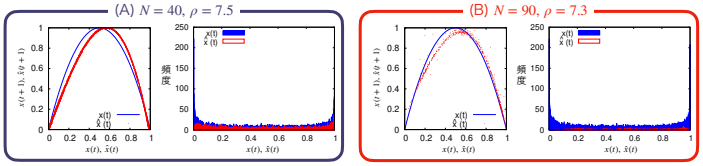




(A) 3つの指標 (KL, JS, $L2$) が比較的小さい値を取る→予測値はリターンマップに近い軌道にプロットされる
(B) KL, JS divergenceは比較的大きいが，$L2$ノルムは小さい値を取る→予測値は発散し[0, 1]に存在しない

● 乱数の種 : 162





(A) 3つの指標 (KL, JS, $L2$) が比較的小さい値を取る→予測値はリターンマップに近い軌道にプロットされる
(B) KL, JS divergenceは比較的大きいが，$L2$ノルムは小さい値を取る→予測値は途中から発散している

7. まとめ

・ESPを満たす条件を考慮しない場合 ($\rho(\boldsymbol{W}) > 1$) に予測が成功していることが多い→パラメータ$a = 4.0$のロジスティック写像を予測する際にはESPを満たさなくても良い
→時系列予測を行う際にESNが満たすべき性質のESPを考慮しない方が高い精度で予測できる可能性がある

・乱数の種によって，フリーラン予測が適切に行われるパラメータセットが異なる→乱数で構造を決定する$\boldsymbol{W}^{\text{in}}$, $\boldsymbol{W}$によって適切なパラメータが変化している
→高い精度で予測を行う際の$\boldsymbol{W}^{\text{in}}$, $\boldsymbol{W}$の構造に特徴がある？[6]

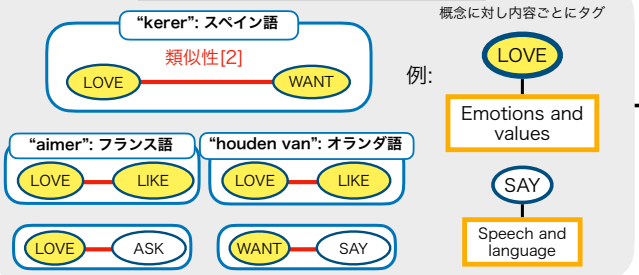
参考文献
[1] Decai Li, Min Han, and Jun Wang, *IEEE Transactions on Neural Networks and Learning Systems*, **23**, 5, pp. 787–799, 2012.
[2] Herbert Jaeger, *GMD Technical Report*, **148**, 13, 2001.
[3] Masato Hara and Hiroshi Kokubu, *Journal of Dynamics and Differential Equation*, pp. 1–26 2022.
[4] Solomon Kullback and Richard A Leibler, *The annals of mathematical statistics*, **22**, 1, pp. 79–86, 1951.
[5] Jianhua Lin, *IEEE Transactions on Information theory*, **37**, 1, pp. 145–151, 1991.
[6] Tsuyoshi Yoneda, preprint, 2023.

1 多義語ネットワークにおける中心感情と基本的感情の関係

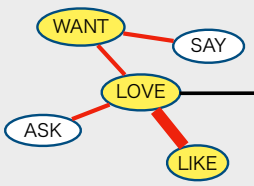
東京理科大学 池口研究室 M2 福家水月

1. 背景・目的

CLICS^3[1] :多義語のデータベース



多義語ネットワーク



ネットワーク解析により
概念同士の関係の特徴抽出

今回の調査

ネットワークにおける中心感情

↕ 比較

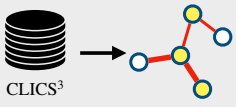
他分野における感情の指標

- Darwinの基本的感情[3]
- Ekmanの基本的感情[4]
- Spinozeの基本的感情[5]
- Natural Semantic Metalanguage[6]

中心感情との共通点・相違点を調査
中心感情の性質を明らかにする

2. ネットワーク作成

重み付き隣接行列: A



A_{ij} : 語族に所属する言語の数

有向重み付き隣接行列: P

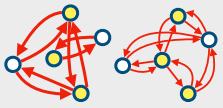


$$P_{ij} = \frac{A_{ij}}{\sum_{j=1}^{N} A_{ij}}$$

(N : 頂点数)

j ← i jに対するiの類似度

有向重み付き隣接行列: P^n



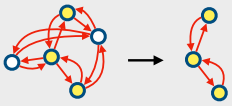
Pで隣接していない頂点同士にも枝を結ぶ

↓

間接的な類似性も定量化する

nの増加でP_{ij}^nは収束[7]

有向重み付き隣接行列: $Q^{(n)}$



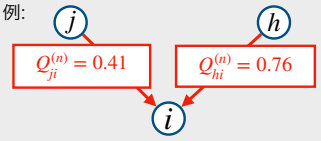
感情の頂点のみ抽出

中心感情の導出

3. 評価指標

強度 In_i

例:



$$\mathrm{In}_i = Q_{ji}^{(n)} + Q_{hi}^{(n)} = 0.42 + 0.76 = 1.18$$

中心感情

順位 r_i

強度In_iを大きい順に並べた際の頂点iの順位

例:

r_i	頂点 i	In_i ($\times 10^{-2}$)	
1	HAPPY	1.96	1.39
2	HATE	1.55	1.26
3	SAD	0.64	2.41>1.5
4	REGRET	0.43	1.43

中心感情と定義

4. 結果

心理学

Darwinによる基本的感情[3]

SADNESS / ANGER / HAPINESS / CONTEMPT / HATE / FEAR / SURPRISE

Ekmanによる基本的感情[4]

HAPINESS / SADNESS / ANGER / FEAR / SURPRISE / DISGUST

倫理学

Spinozaによる基本的感情[5]

PLEASURE / SAD / DESIRE

言語学

Natural Semantic Metalanguage[6]

→言語表現に必要な最低限の概念および文法のデータセット

GOOD / BAD / WANT / ⋮

共通項:

DESIRE ↔ WANT

"WANT"を感情として扱う

共通項: なし

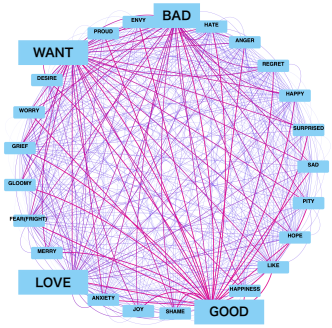
BAD: SADNESS / CONTEMPT / HATE / DISGUST / ⋮

GOOD: HAPINESS

基本的感情: 独立した感情
中心感情: 多くの類似点を持つ感情

包含される可能性

$Q_{ij}^{(n)}$ 1 — 0.002 — 0 edge



有向重み付き隣接行列: $Q^{(n)}$ $(n = 1.0 \times 10^3)$

r_i	頂点	In_i ($\times 10^{-2}$)
1	GOOD	4.49
2	WANT	3.81
3	BAD	3.55
4	LOVE	2.25
5	FEAR	1.25
6	GRIEF	1.21
7	LIKE	1.04
8	HAPPY	1.03
9	HATE	0.91
⋮		

共通項:

GOOD / BAD / WANT

言語ベースの感情解析で結果が共通する可能性

GOOD / BAD / WANT

→他分野と共通する場合がある

LOVE

→多義語ネットワーク独自の感情の指標

5. まとめ・今後の課題

多義語ネットワークにおける中心感情と他分野の基本的感情の比較

- **心理学の基本的感情: 異なる性質**
- **倫理学の基本的感情: "WANT"のみ共通**
- **Natural Semantic Metalanguage: "GOOD," "BAD," "WANT"**
- **多義語ネットワーク独自の中心感情: "LOVE"**

今後の課題:

言語別に多義語ネットワークを作成

↓

言語別の中心感情を調査

参考文献

[1] J. M. List et al., https://clics.clld.org/, (Last visit Nov. 25th, 2021).
[2] A. Francois, *John Benjamin Publishing*, 163–215, 2008.
[3] C. Darwin, *The expression of the emotions in man and animals*, (John Murray, 1872).
[4] P. Ekman, *Handbook of Cognition and Emotion*, 98, 45—60, 1999.
[5] B. Spinoza, *The ethics: ethica ordine geometrico demonstrata*, (The Floating Press, 2009).
[6] A. Wierzbicka, Natural semantic metalanguage, *The international encyclopedia of language and social interaction*, 1—7, 2015.
[7] 福家 他, IEICE NOLTA ソ大会, A-16, 2022.

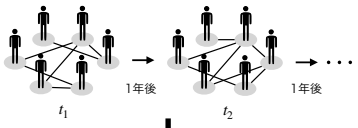
2

時系列のテンポラルネットワーク変換と解析

東京理科大学　池口研究室　B4　阿部賢一

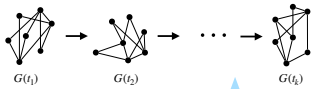
1. はじめに

(例)人間関係



時間変化を考慮したネットワーク

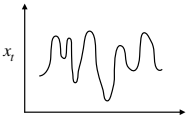
テンポラルネットワーク



テンポラルネットワークの性質を知りたい！

2. 方法

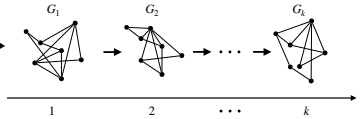
時系列データ



辞書ネットワーク

step 1

テンポラルネットワーク



時系列の性質を保存したままテンポラルネットワーク化

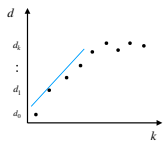
Wolfの手法

step 2

step 3

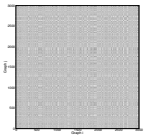
テンポラルネットワークのリカレンスプロットを調べる

リアプノフ指数



テンポラルネットワークのカオス性（リアプノフ指数）を調べる

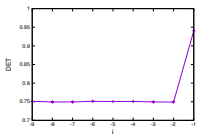
リカレンスプロット



step 4

リカレンスプロットから決定論性（DET）を調べる

DET



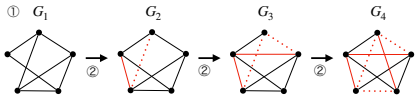
3.目的

- 時系列データの性質を保存してテンポラルネットワーク化
- テンポラルネットワークのカオス性，決定論性の測定

人と人のコンタクトネットワークのカオス性，決定論性の調査

4.テンポラルネットワーク変換

4.1辞書ネットワーク[1][2]



生成方法

① G_1 をランダムに生成（ERモデル）

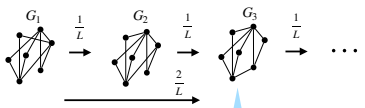
② 枝を以下の制約条件で繋ぎかえる

1. 以前の反復で選ばれていない枝を選ぶ
2. 以前の反復で枝が存在していない場所に付け替え

新たに繋がれる枝

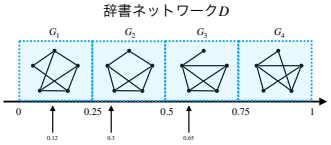
繋がりがなくなる枝

ネットワーク間の距離　G_p から G_q 間の距離 $\propto |p-q|$



辞書ネットワーク数Lで距離を正規化する

4.2 辞書ネットワークと時系列データの対応例



$D=\{G_1,G_2,G_3,G_4\}$, 時系列$\{X_1,X_2,X_3\}$がある場合

$X_1=0.3 \Rightarrow G_2$

$X_2=0.65 \Rightarrow G_3$

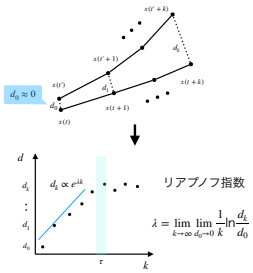
$X_3=0.12 \Rightarrow G_1$

$X_i=\{X_1,X_2,X_3\} \Rightarrow S=\{G_2,G_3,G_1\}$

時系列の状態値を辞書ネットワークDに対応させてテンポラルネットワーク S を作成

5.リアプノフ指数

5.1 リアプノフ指数



リアプノフ指数

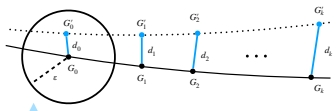
$\lambda = \lim_{k\to\infty}\lim_{d_0\to 0}\frac{1}{k}\ln\frac{d_k}{d_0}$

飽和時間 τ 以降
軌道間の距離は変化しなくなる

$\lambda>0$のとき　2つの軌道は離れる
→カオス性を持つ

5.2 リアプノフ指数の推定手法

Wolfの手法[3]



d_0は初期グラフG_0から閾値ε以内のグラフG_0'との距離

平均膨張率

$$l=\frac{1}{\tau}\sum_{k=1}^{\tau}\ln\frac{d_k}{d_{k-1}}=\frac{1}{\tau}\ln\frac{d_\tau}{d_0}$$

平均膨張率は初期グラフ1つにつき1つ求まる

G_0の初期条件の数　w

ネットワークのリアプノフ指数（Wolf法）

$$\lambda^W=\frac{1}{w}\sum_{i=1}^{w}l(i)$$

6. リカレンスプロットとDET

6.1 リカレンスプロット

$$R(x,y)=\begin{cases}1 & \left(d(G_x,G_y)<\epsilon_d\right)\\ 0 & (\text{otherwise})\end{cases}$$

$d(G_x,G_y)$: グラフG_x,G_y間の距離

D_{min} : グラフ間距離の最小値

D_{max} : グラフ間距離の最大値

ϵ_d : 閾値

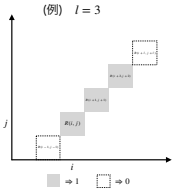
$\epsilon_d = D_{min}+(D_{max}-D_{min})\cdot p$

$p=2^i$

6.2 DET

$$P(l)=\sum_{i,j=1}^{N}(1-R(i-1,j-1))(1-R(i+l,j+l))\prod_{k=0}^{l-1}R(i+k,j+k)$$

(例)　$l=3$



$P(l)$: 長さlの対角線のヒストグラム

$$DET=\frac{\sum_{l=l_{min}}^{N}lP(l)}{\sum_{l=1}^{N}lP(l)}$$

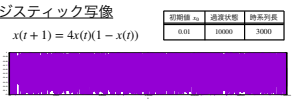
DETが大きい場合
→決定論性を持つ

7.実験用の時系列データ

ロジスティック写像

$x(t+1)=4x(t)(1-x(t))$

初期値 x_0	過渡状態	時系列長
0.01	10000	3000

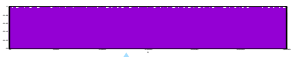


カオスニューロン[5]

$x(t+1)=k\,x(t)-\alpha f(x(t))+a$

$f(z)=\dfrac{1}{1+\exp(-z/\epsilon_z)}$

初期値 x_0	k	a	ϵ_z	α	時系列長
0.3	0.8	0.25	0.02	1	3000

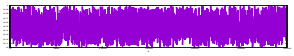


[0,1]の範囲になるようにmin-max正規化

ベルヌーイシフト写像[4]

$$x(t+1)=2x(t)\ (\mathrm{mod}\ ep)=\begin{cases}2x(t) & \left(0<x(t)<\frac{ep}{2}\right)\\ 2x(t)-ep & \left(\frac{ep}{2}\leqq x(t)<ep\right)\end{cases}$$

初期値 x_0	0.001
過渡状態	10000
時系列長	3000
ep	$1-10^{-9}$



ランダム時系列



実コンタクトデータ[6]

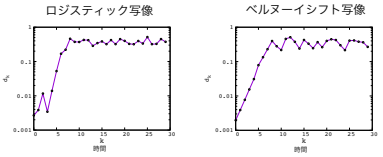
データ	時期・期間	人数	総コンタクト数
フランスの小学校	2009年10月(2日間)	242	125,773
フランスの高校	2011年12月(4日間)	126	28,561
	2012年11月(7日間)	180	45,047

8. 結果

8.1 リアプノフ指数

隣接したネットワーク間の距離の時間発展

ロジスティック写像　ベルヌーイシフト写像

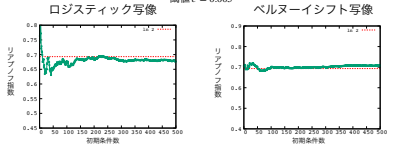


飽和時間 $\tau \approx 7$
飽和時間 τ までの傾き=リアプノフ指数

初期状態数とリアプノフ指数

閾値 $\epsilon = 0.005$

ロジスティック写像　ベルヌーイシフト写像

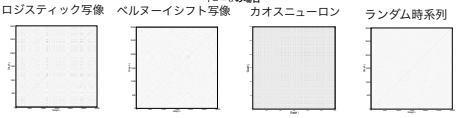


初期条件数w=150ほどでリアプノフ指数が収束
正しいリアプノフ指数（ln 2）が推定できる

8.2 リカレンスプロット

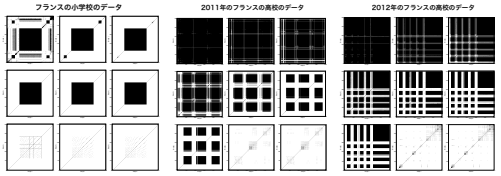
$i=-6$の場合

ロジスティック写像　ベルヌーイシフト写像　カオスニューロン　ランダム時系列

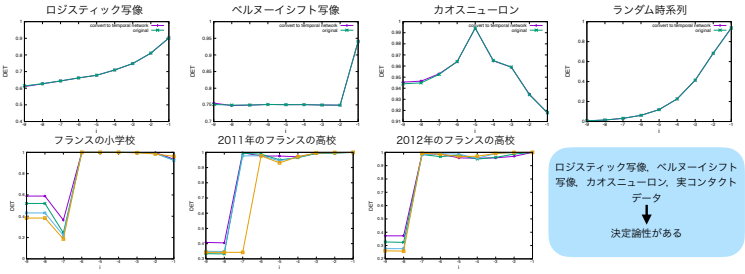


ランダム時系列は特徴がないがロジスティック写像，ベルヌーイシフト写像，カオスニューロンには特徴が現れる
実コンタクトデータでは高校の2つのデータで似た特徴が現れる
小学校と高校のデータは異なる特徴が現れる

実コンタクトデータ



8.3 DET



ロジスティック写像，ベルヌーイシフト写像，カオスニューロン，実コンタクトデータ
↓
決定論性がある

divはデータをテンポラルネットワークにするための分割数

9. まとめ

時系列からテンポラルネットワークを作成し，カオス性，決定論性を調べた

↓

テンポラルネットワークに変換したロジスティック写像，カオスニューロン，ベルヌーイシフト写像にカオス性と決定論性がある
実コンタクトデータに決定論性がある

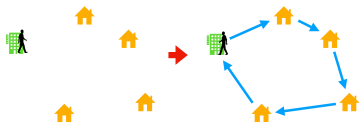
[参考文献]
[1] Annalisa Caligiuri, Victor M, Eguiluz, Leonardo Di Gino, Tobias Galla and Lucas Lacasa, "Lyapunov exponents for temporal networks," Phys. Rev. E, Vol. 107, 044305, 2023.
[2] Lacasa, Lucas and Rodriguez, Jorge P. and Eguiluz, Victor M, "Correlations of network trajectories," Phys. Rev. Res, Vol. 4, L042008, 2022.
[3] Alan Wolf and Jack B. Swift and Harry L. Swinney and John A. Vastano, "Determining Lyapunov exponents from a time series," Physics D, Vol. 16, No. 3, pp. 285-317, 1985.
[4] 池口 徹, "ディジタルコンピュータ上での非線形力学系の実装について," 電気通信学会 基礎・境界ソサイエティ Fundamentals Review, Vol. 14, No.3, pp. 229-238, 2021.
[5] 池口 徹, 山田泰司, 小笠元良, 合原一幸, カオス時系列解析の基礎と応用, 産業図書株式会社, 2000.
[6] Sociopatterns: http://www.sociopatterns.org (最終閲覧日 2023/12/15)

3

巡回セールスマン問題に対するカオスタブーサーチにおけるアルファ近接度の有効性

東京理科大学 池口研究室 B4 市川健太

1.巡回セールスマン問題



距離　vs　アルファ近接度[1]

カオスタブーサーチ[2][3]を用いて比較を行う.

目的：距離とアルファ近接度を比較し，TSPに対する有効性を調べる.

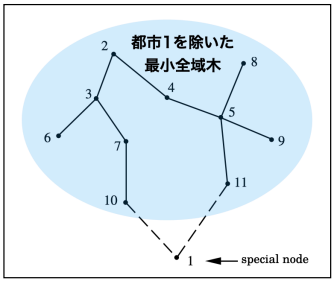
2.アルファ近接度

アルファ近接度…それぞれの枝に関して，最小1-treeをその枝を含んだ1-treeに変更する過程で増加する長さ.

TSPの優れた近似解法であるLKH法で用いられており，距離より巡回経路を考慮した近さの尺度.

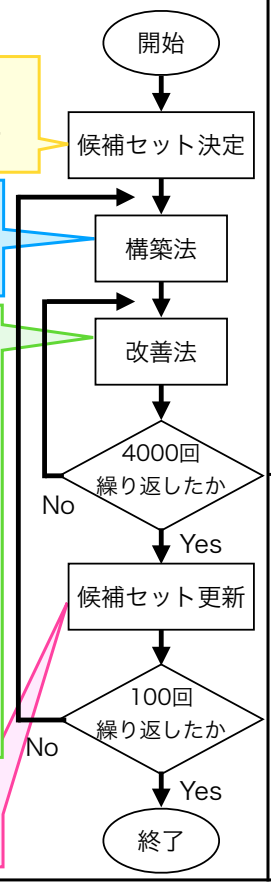
$\alpha(a,b)$を都市a,bを結ぶ枝のアルファ近接度,
$c(a,b)$を都市a,bを結ぶ枝の長さとすると,

$$\alpha(7,10)=0$$
$$\alpha(6,10)=c(6,10)-c(7,10)$$
$$\alpha(1,7)=c(1,7)-c(1,11)$$



最小1-treeの例

3.近似解法



候補セットの決定

それぞれの都市から枝を追加する際に候補となる枝.
今回は候補セットを距離が最小の枝5つで作成した場合と，アルファ近接度が最小の枝5つで作成した場合で比較する.

構築法

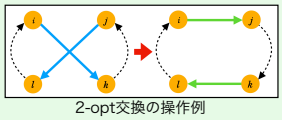
候補セットを用いた構築法で初期巡回経路を作成する.
最初に訪問する都市をランダムに決め,
以降は現在の都市の候補セットを優先して選択する.

改善法（カオスタブーサーチ）

以下の定義の通りに時刻tにおける出力を求め,

$x_i(t)>\frac{1}{2}$であれば，対応した2-opt交換を行い,

$t=t+1$とする.



2-opt交換の操作例

外部入力ξ

$$\xi_i(t+1)=\max_j\{\zeta_j(t+1)+\beta(t)(\Delta_{ij}(t)-F_r(t))\}$$

発火率制御η

$$\eta_i(t+1)=-W(t)\sum_{k=1,k\neq i}^{n}x_k(t)+W(t)$$

不応性ζ

$$\zeta_i(t+1)=k_r\zeta_i(t)-\alpha x_i(t)+R$$

出力x

$$x_i(t+1)=f\{\xi_i(t+1)+\eta_i(t+1)+\zeta_i(t+1)\}$$

候補セットの更新

巡回経路長がより小さい巡回経路を見つけた場合,
その巡回経路に含まれる枝を候補セットに追加する.

4.計算結果

※TSPLIB[4]の問題を使用,
結果の良い方をグレーでハイライト

問題例	誤差率[%]	
	距離	アルファ近接度
burma14	0.000	0.000
ulysses16	0.000	0.000
gr17	0.000	0.000
gr21	0.000	0.000
ulysses22	0.000	0.000
gr24	0.000	0.000
fri26	0.000	0.000
bayg29	0.000	0.000
bays29	0.000	0.000
dantzig42	0.000	0.000
swiss42	0.000	0.000
att48	0.000	0.000
gr48	0.000	0.000
hk48	0.000	0.000
eil51	0.000	0.000
berlin52	0.000	0.000
brazil58	0.000	0.000
st70	0.000	0.000
eil76	0.000	0.000
pr76	0.000	0.000
gr96	0.000	0.000
rat99	0.000	0.000
kroA100	0.000	0.000
kroB100	0.000	0.000
kroC100	0.000	0.000
kroD100	0.000	0.007
kroE100	0.034	0.000
rd100	0.000	0.000
eil101	0.000	0.000
lin105	0.000	0.000
pr107	0.000	0.000
gr120	0.000	0.039
pr124	0.000	0.000
bier127	0.000	0.005
ch130	0.000	0.049
pr136	0.040	0.096
gr137	0.076	0.002
pr144	0.036	0.015
ch150	0.008	0.000
kroA150	0.002	0.010
kroB150	0.066	0.168
pr152	0.001	0.000
u159	0.000	0.000
si175	0.007	0.003
brg180	0.000	0.308
rat195	0.267	0.478
d198	0.245	0.302
kroA200	0.079	0.244
kroB200	0.119	0.144

問題例	誤差率[%]	
	距離	アルファ近接度
gr202	0.096	0.087
ts225	0.085	0.067
tsp225	0.258	0.228
pr226	0.652	0.215
gr229	0.340	0.421
gil262	0.340	0.389
pr264	0.204	0.033
a280	0.071	0.220
pr299	0.368	0.267
lin318	1.105	0.734
linhp318	0.420	0.407
rd400	0.866	0.852
fl417	1.908	1.076
gr431	1.321	1.403
pr439	1.905	0.926
pcb442	0.783	0.838
d493	1.349	0.858
att532	1.613	1.396
ali535	2.224	0.931
si535	1.157	0.272
pa561	1.080	1.041
u574	1.718	1.258
rat575	1.420	1.330
p654	3.132	2.253
d657	1.443	1.435
gr666	2.239	1.702
u724	1.691	1.616
rat783	2.201	2.015
dsj1000	2.504	1.874
pr1002	2.819	2.456
si1032	0.217	0.044
u1060	2.991	2.803
vm1084	2.799	2.894
pcb1173	2.741	2.628
d1291	2.654	1.328
rl1304	5.961	3.054
rl1323	3.728	2.290
nrw1379	2.077	2.888
fl1400	6.579	3.502
u1432	3.010	3.110
fl1577	6.009	4.311
d1655	3.532	2.561
vm1748	4.449	3.342
u1817	2.848	2.499
rl1889	3.346	3.293
d2103	3.355	1.322
u2152	5.133	2.987
u2319	1.487	1.473
pr2392	4.765	4.320

5.まとめ

・アルファ近接度で候補セットを作成した場合の方が多くの都市数が大きい問題において結果が良かったため,
アルファ近接度は巡回経路を構築・改善するために用いる尺度として距離より優れている事が示された.

・都市数の多い問題について，距離・アルファ近接度共に誤差率が大きくなってしまったため,
最適なパラメータの調査が必要.

・距離で候補セットを作成した場合の方が結果が良かった問題について,
どのような特徴があるのかは現在調査中.

参考文献

[1] Helsgaun Keld, “An effective implementation of the Lin–Kernighan traveling sales- man heuristic,” *European Journal of Operational Research*, Vol. 126, No. 1, pp. 106-130, 2000.

[2] Mikio Hasegawa and Tohru Ikeguchi and Kazuyuki Aihara, “Solving large scale traveling sales- man problems by chaotic neurodynamics,” Neural Networks, Vol. 15, No. 2, pp. 271-283, 2002.

[3] Mikio Hasegawa and Tohru Ikeguchi and Kazuyuki Aihara, “Exponential and chaotic neurody- namical tabu searches for quadratic assignment problems,” Control and Cybernetics, Vol. 29, No. 3, pp. 773-788, 2000.

[4] G. Reinelt, “TSPLIB,” *ORSA Journal on Computing*, Vol. 3, No. 4, pp. 376-384, 1991.

統計的検定を用いた疑似乱数生成器の性能比較

池口 徹
東京理科大学工学部情報工学科
〒 125-8585 東京都葛飾区新宿 6-3-1

擬似乱数は，コンピュータゲーム，計算機実験，暗号分野，統計解析などの様々な場面で広く用いられる．例えば，コンピュータゲームでは，プレイヤーが毎回異なる体験をするために必要となる．また，計算機実験では，確率的な振舞いを再現するために必須である．さらに，暗号分野では，鍵生成やセッションの安全性確保に使用される．統計解析においては，仮説検定あるいはパラメータ推定などで用いられる．このように，擬似乱数はランダム性が必要な場面で広く利用され，重要な役割を果たしている．

しかし，擬似乱数を用いる際には注意すべき点がある．例えば，文献 [1] では，いくつかの注意点がリストされているが，もしこれら注意点を守らなければ，それが原因となって,「得られた結果が疑わしい論文を，図書館の書棚から抜きされば，書棚には拳が入るほどの隙間ができるだろう」ということも指摘されている．

この報告では，いくつかの疑似乱数生成アルゴリズムについて，乱数としてどの程度の性能を有するのかを統計的な検定方法を導入することにより比較する．具体的に用いた疑似乱数生成アルゴリズムは，整数ロジスティック写像 [2]，メルセンヌツイスタ [3]，C 言語に組込まれている `rand/srand` 関数，Numerical Recipies in C [1] で紹介されている三つの関数 `ran1`， `ran2`，`ran3` である．これらの擬似乱数生成アルゴリズムから発生させた数値列を 0, 1 の 2 値に変換した系列に対して，NIST SP800-22 [4] による検定を行った．その際，乱数系列を発生させるための計算時間も算出した．また，生成した擬似乱数系列に対して，排他的論理和演算 (XOR) を用いた後処理を施した場合に，どのように乱数の性能が変化するのかについても検討を行った．

その結果，メルセンヌツイスタが最も良い性能を示すことがわかった．また，整数ロジスティック写像の生成時間が最も短いこと，精度を調整することにより合格数を高くすることが可能であることも示された．さらに，後処理としての XOR の効果は，`rand/srand` 関数に対して最も高いことも明らかとなった．

参考文献

[1] W. H. Press, S. A. Teukolsky, W. T. Vetterling, and B. P. Flannery, “Numerical Recipes in C,” Cambridge University Press, Second Edition, Cambridge, USA, 1992. [日本語版] 丹慶勝市，奥村晴彦，佐藤俊郎，小林誠訳，“C 言語による数値計算レシピ,” 技術評論社，1993.

[2] S. Kanamaru, Y. Shimada, K. Fujiwara, and T. Ikeguchi, “Performance evaluation of chaotic random numbers generated from responses of integer logistic maps,” *Nonlinear Theory and Its Applications*, IEICE, Vol. 12, No. 3, pp. 489–499, 2021.

[3] M. Matsumoto and T. Nishimura, “Mersenne Twister: A 623-Dimensionally Equidistributed Uniform Pseudo-Random Number Generator,” *ACM Transactions on Modeling and Computer Simulation*, Vol. 8, No. 1, pp.3–30, 1998.

[4] L. Bassham, A. Rukhin, J. Soto, J. Nechvatal, M. Smid, and E. Barker, “A Statistical Test Suite for Random and Pseudorandom Number Generators for Cryptographic Application,” Special Publication (NIST SP), National Institute of Standards and Technology, Gaithersburg, MD, 2010.

謝辞

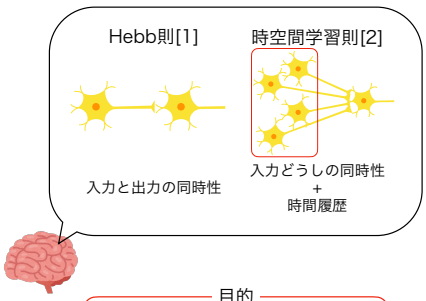
本研究は，JSPS 科研費 (JP20H00596，JP21H03514，JP22K18419) および東北大学電気通信研究所における共同研究プロジェクト研究 (R05/A13，R05/B13) による．

Hebb則と時空間学習則パターン分離能力の比較

P7

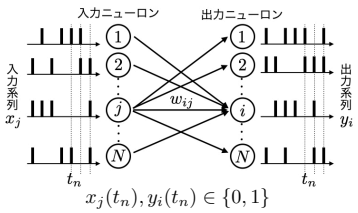
塚本陽太 東京理科大　塚田啓道 中部大　塚田稔 玉川大　池口徹 東京理科大

1. 背景



目的
入力パターンの類似性と
パターン分離能力の関係を調査

2. ネットワーク[3]



$$x_j(t_n), y_i(t_n) \in \{0,1\}$$

$$s_i(t_n) = \sum_{j=1}^{N} w_{ij}(t_n) x_j(t_n)$$ 入力の重み付け和

$$y_i(t_n) = F(s_i(t_n) - \eta)$$ η: 発火の閾値

$$F(u) = \begin{cases} 1 & u > 0 \\ 0 & u \leq 0 \end{cases}$$ 出力の決定

3. 学習則[4]

Hebb則

$$w_{ij}(t_{n+1}) = w_{ij}(t_n) + \Delta w x_j(t_n) y_i(t_n)$$

Δw: 学習率係数

Hebb±則

$$w_{ij}(t_{n+1}) = w_{ij}(t_n) + \Delta w g(x_j(t_n), y_i(t_n))$$

$$g(x,y) = \begin{cases} 1 & x = y = 1 \\ 0 & x = y = 0 \\ -1 & \text{otherwise} \end{cases}$$

時空間学習則

空間一致性

$$I_{ij}(t_n) = w_{ij}(t_n) x_j(t_n) \sum_{k=1, k\neq j}^{N} w_{ik}(t_n) x_k(t_n)$$
$$\approx w_{ij}(t_n) x_j(t_n) s_i(t_n)$$

入力ニューロンが同時にどれくらい発火したかを定量化

時間履歴

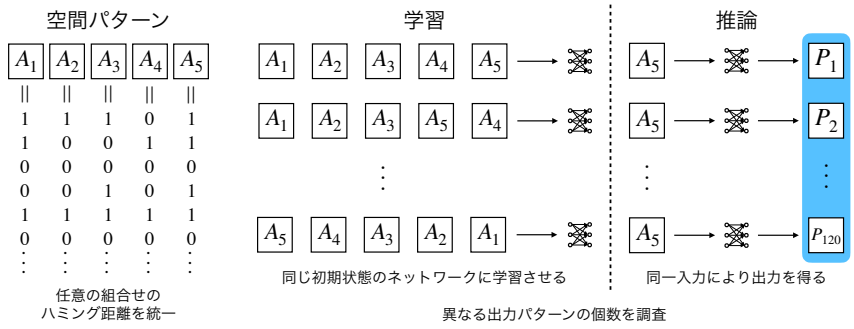
$$J_{ij}(t_n) = \sum_{m=0}^{n} I_{ij}(t_m) \exp\left(-\frac{t_n - t_m}{\lambda}\right)$$

λ: 時定数

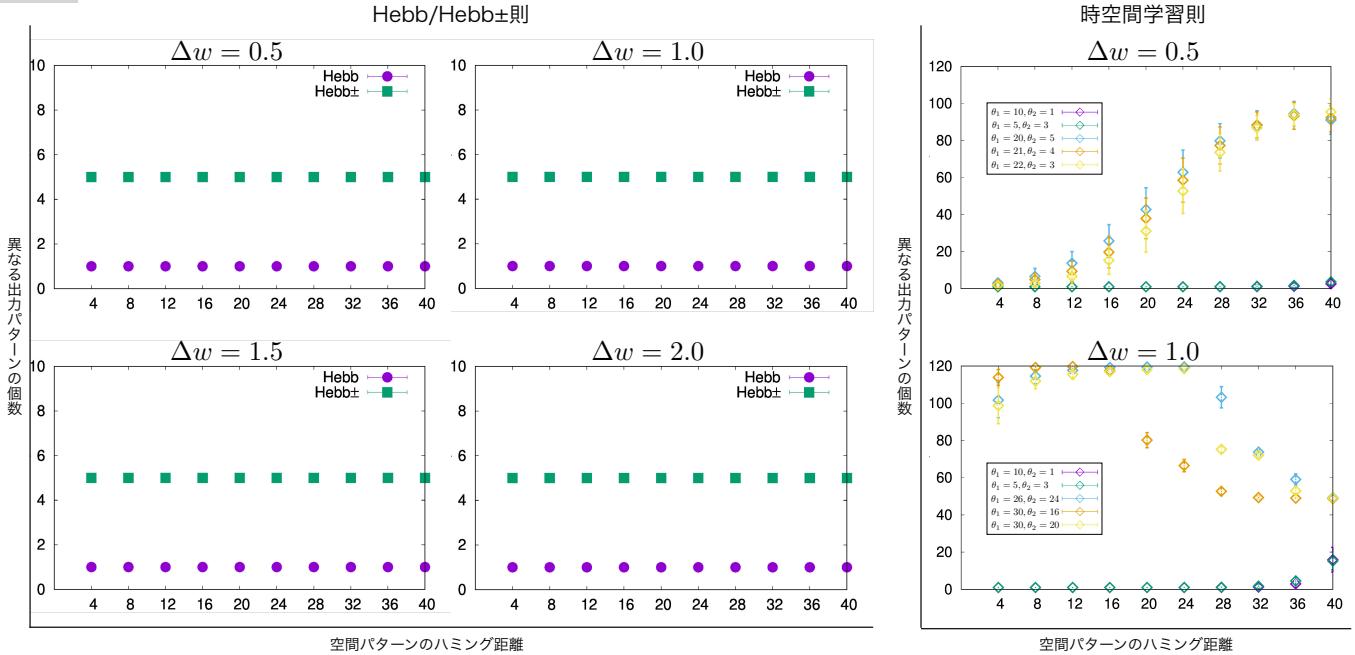
$$w_{ij}(t_{n+1}) = \begin{cases} w_{ij}(t_n) + \Delta w & J_{ij}(t_n) > \theta_1 \\ w_{ij}(t_n) & \theta_1 \geq J_{ij}(t_n) \geq \theta_2 \\ w_{ij}(t_n) - \Delta w & J_{ij}(t_n) < \theta_2 \end{cases}$$

θ_1: 増強の閾値　θ_2: 減弱の閾値

4. 実験



5. 結果



Hebb±則
パターン分離能力が極めて低い

Hebb則
全くパターン分離できない

時空間学習則
パラメータに応じて特定の類似度の入力に反応

参考文献

[1] D. O. Hebb, Oxford: Wiley, 1949.
[2] M. Tsukada et al., *Neural Networks*, **9**(8), 1357–1365, 1996.
[3] M. Tsukada et al., *Biol. Cybern.*, **92**(2), 139—146, 2005.
[4] H. Tsukada et al., *Front. Syst. Neurosci.*, **15**(11), 624353, 2021.

謝辞

本研究はJSPS科研費(JP20H04246, JP20H00596, JP21H03514, JP22K18419)および
東北大学電気通信研究所における共同プロジェクト研究(R05/A19, R05/B13)による.

P8

リザバー層の力学系に対する再帰定量化解析

○吉田 しおん　　池口 徹　　東京理科大学 工学部 情報工学科

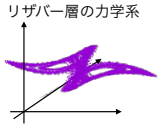
非線形問題解決集団 池口研究室 NONLINEAR DYNAMICAL SYSTEM

1. 背景・目的

Echo State Network: 高速かつ高精度に予測できる
→動作原理を明らかにする

予測対象の力学系 → 観測 → 入力時系列 → 入力 → リザバー層

リザバー層の力学系

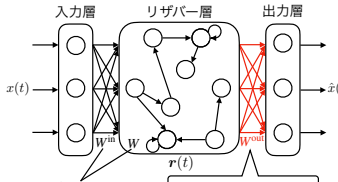


アトラクタ構造は高精度に予測するとき入力した力学系と類似することがある[1]

リザバー層の力学系の力学的特性を再帰定量化解析によって調査

2. Echo state network [2]

● 学習フェーズ

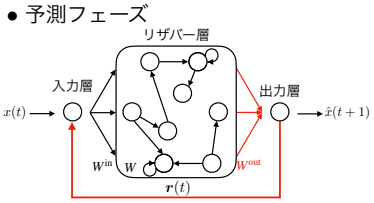


状態更新式

$$\begin{cases} \boldsymbol{r}(t+1) = \boldsymbol{f}\left(\boldsymbol{W}^{\mathrm{in}} x(t) + \boldsymbol{W}\boldsymbol{r}(t)\right) \\ \hat{x}(t+1) = \boldsymbol{W}^{\mathrm{out}} \boldsymbol{r}(t+1) \end{cases}$$

$x(t) \in \mathbb{R}^1$: 入力値
$\boldsymbol{r}(t) \in \mathbb{R}^N$: リザバー状態ベクトル
$\hat{x}(t) \in \mathbb{R}^1$: 予測値
$\boldsymbol{W}^{\mathrm{in}} \in \mathbb{R}^{N\times 1}$: 入力結合重み行列
$\boldsymbol{W} \in \mathbb{R}^{N\times N}$: リザバー結合重み行列
$\boldsymbol{W}^{\mathrm{out}} \in \mathbb{R}^{1\times N}$: 出力結合重み行列

● 予測フェーズ



$$x(t+1) = \hat{x}(t+1) = \boldsymbol{W}^{\mathrm{out}}\boldsymbol{r}(t+1)$$

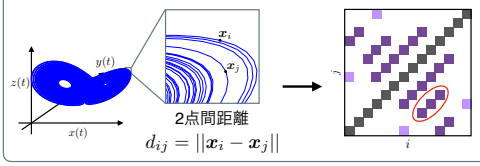
状態更新式

$$\boldsymbol{r}(t+1) = \boldsymbol{f}(\boldsymbol{W}^{\mathrm{in}}\boldsymbol{W}^{\mathrm{out}}\boldsymbol{r}(t) + \boldsymbol{W}\boldsymbol{r}(t))$$

$\boldsymbol{r}(t)$のみで表現: 自律系の力学系
→リザバー層の力学系

3. 再帰定量化解析

リカレンスプロット[3]



リカレンスプロットの画素値

$$P_{ij} = \begin{cases} 1 & (d_{ij} \le \theta) \\ 0 & (d_{ij} > \theta) \end{cases}$$

リカレンスレート

$$R = \frac{\text{プロットされた点の数}}{\text{全画素数}}$$

リカレンスレートを変化させる

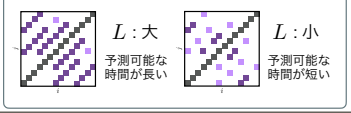
決定論性評価指標 DET[4]
→力学系の決定論性を評価

$$\mathrm{DET} = \frac{\text{斜め線を構成する点の数}}{\text{プロットされた点の数}} =$$



斜め線の長さの平均L[4]
→力学系の平均予測時間を評価

$$L = \frac{\text{斜め線の長さの合計}}{\text{斜め線の数}} =$$



4. 実験条件

・予測対象とした力学系

(1) ロジスティック写像

$$x(t+1) = 4x(t)(1-x(t))$$

(2) Lorenz方程式

$$\begin{cases} \dot{x} = 10(-x+y) \\ \dot{y} = x(28-z) - y \\ \dot{z} = xy - \frac{8}{3}z \end{cases}$$

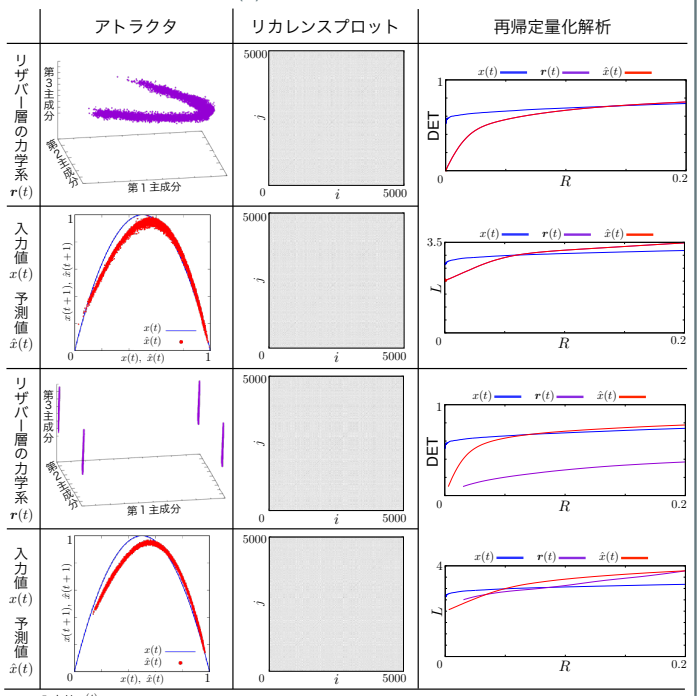
xのみ入力

・設定したESNのパラメータ

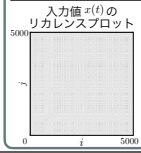
パラメータ	ロジスティック写像	Lorenz方程式
入力次元，出力次元	1	
リザバー層のノード数N	50	200
リザバー結合重み行列Wのスペクトル半径	0.98	
リザバー結合重み行列Wの構造	結合確率2%のランダムネットワーク	
学習データ数	1,000	2,000
フリーラン予測の数	10,000	

5. 結果

(1) ロジスティック写像



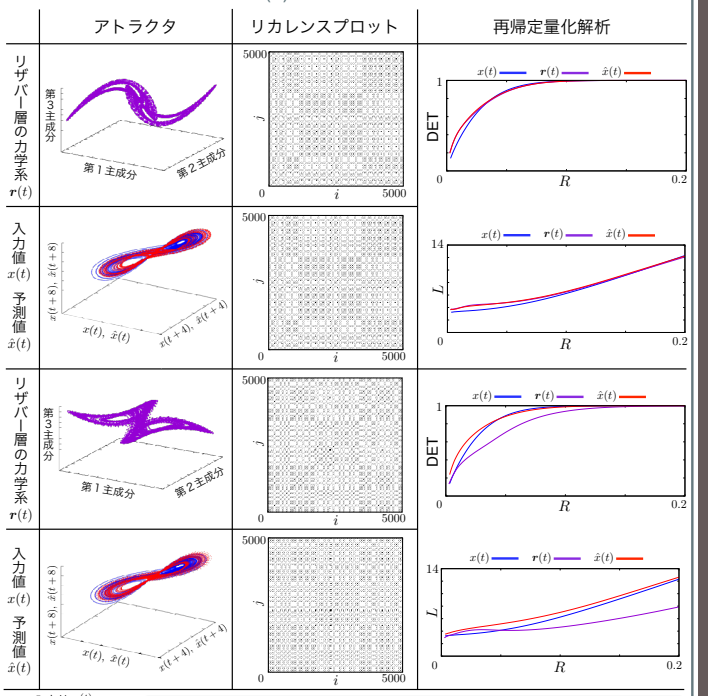
入力値$x(t)$のリカレンスプロット



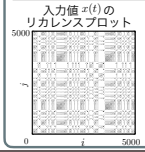
・リザバー層の力学系が入力値と類似したアトラクタ構造である場合
- リザバー層の力学系と予測値はどちらも入力値と同程度の値で推移している
- リザバー層の力学系と予測値は同じ値で推移している

・リザバー層の力学系が入力値と異なるアトラクタ構造である場合
- 予測値は入力値と同程度の値で推移している
- リザバー層の力学系のLは入力値と同程度だが，DETは入力値よりも低い

(2) Lorenz方程式



入力値$x(t)$のリカレンスプロット



・リザバー層の力学系が入力値と類似したアトラクタ構造である場合
- リザバー層の力学系と予測値のリカレンスプロットは入力値のリカレンスプロットと似た模様である
- リザバー層の力学系と予測値は同じ値で推移する場合とそうでない場合がある

→リザバー層の力学系は入力した時系列が持つ力学的特性と同じ特徴を持つとき高精度に予測できる

6. まとめ

高い予測精度を示すときのリザバー層の力学系，予測値のDET，斜め線の長さの平均Lは，入力値の結果と同程度の値で推移する
→リザバー層の力学系が入力した時系列が持つ力学的特性を引き継いでいるとき，高精度で予測できる

予測値は入力値と同程度で推移しているが，リザバー層の力学系は低い値で推移することがある
→リザバー層の力学系が入力した時系列が持つ力学的特性を引き継いでいない
その場合でも高精度で予測する→学習したW^{out}による影響？

謝辞

本研究の一部は，JSPS 科研費 (JP20H00596，JP21H03514, JP22K18419) および東北大学電気通信研究所における共同プロジェクト研究 (R05/A19, R05/B13) による．

参考文献

[1] 吉田しおん，池口徹，電子情報通信学会 技術研究報告，**123**，287，15–20，NLP2023-62，2023.
[2] H. Jaeger et.al., *GMD Technical Report*, **148**, 34, 2001.
[3] J. -P. Eckmann et al., *Europhys. Lett.*, **4**, 937–977,1987.
[4] N.Marwan et al., *Phys. Reports*, **438**, 5–6, 237–329, 2007.
[5] A. Hart, et al., *Neural Networks*, **128**, 234—246, 2020.
[6] M. Hara and H. Kokubu, *Journal of Dynamics and Differential Equation*, 1–26 2022.

P9

時空間学習則と拡張時空間学習則のパターン分離能力

○山本陽翔　池口徹
東京理科大学　工学部　情報工学科

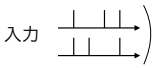
1. 背景・目的

○:ニューロン →:シナプス

時空間学習則[1,2]　拡張時空間学習則[3]



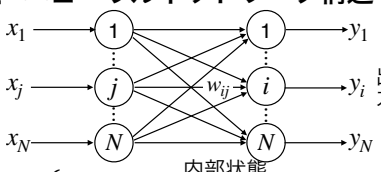
発火⚡の同時性　発火⚡・非発火✖の同時性



脳のパターン分離能力を再現

目的: パターン分離能力を調査

2. ニューラルネットワーク構造



$$x_j, y_i = \begin{cases} 1 & (\text{発火}) \\ 0 & (\text{非発火}) \end{cases}$$

$$s_i(t_k) = \sum_{j=1}^{N} w_{ij}(t_k) x_j(t_k)$$

w_{ij}: ijのシナプス荷重

η: 発火の閾値

t_k: 時刻

出力

$$y_i(t_k) = F(s_i(t_k) - \eta)$$

$$F(z) = \begin{cases} 1 & z \geq 0 \\ 0 & z < 0 \end{cases}$$

3. 時空間学習則[1,2]

発火の空間一致性

$$I_{ij}(t_k) = w_{ij}(t_k) x_j(t_k) \left\{ \sum_{q=1, q\neq j}^{N} w_{iq}(t_k) x_q(t_k) \right\}$$

発火の時間履歴

$$J_{ij}(t_k) = \sum_{m=0}^{k} I_{ij}(t_m) \exp\left(-\frac{t_k - t_m}{\lambda} \right)$$

時空間学習則の重みの更新式

$$w_{ij}(t_{k+1}) = \begin{cases} w_{ij}(t_k) + \alpha & J_{ij}(t_k) \geq \theta_1 \\ w_{ij}(t_k) & \theta_1 > J_{ij}(t_k) > \theta_2 \\ w_{ij}(t_k) - \alpha & \theta_2 \geq J_{ij}(t_k) \end{cases}$$

λ: 時定数,　α: 学習率,　θ_1: 増強の閾値,　θ_2: 減弱の閾値

4. 拡張時空間学習則[3]

$x_j^{\dagger} = 1 - x_j$: 発火を0,　非発火を1で表す

非発火の空間一致性

$$I_{ij}^{\dagger}(t_k) = w_{ij}(t_k) x_j^{\dagger}(t_k) \left\{ \sum_{q=1, q\neq j}^{N} w_{iq}(t_k) x_q^{\dagger}(t_k) \right\}$$

非発火の時間履歴

$$J_{ij}^{\dagger}(t_k) = \sum_{m=0}^{k} I_{ij}^{\dagger}(t_m) \exp\left(-\frac{t_k - t_m}{\lambda} \right)$$

拡張時空間学習則の重みの更新式

$$w_{ij}(t_{k+1}) = \begin{cases} w_{ij}(t_k) + \alpha & J_{ij}(t_k) \geq \theta_1 \\ w_{ij}(t_k) & J_{ij}(t_k) < \theta_1 \end{cases}$$

$$w_{ij}(t_{k+1}) = \begin{cases} w_{ij}(t_k) - \alpha & J_{ij}^{\dagger}(t_k) \geq \theta_2 \\ w_{ij}(t_k) & J_{ij}^{\dagger}(t_k) < \theta_2 \end{cases}$$

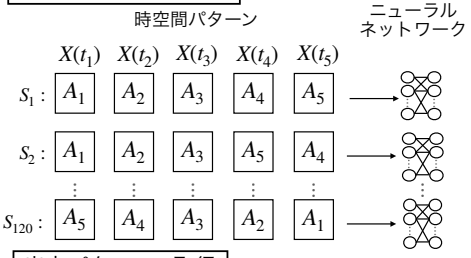
5. 実験手法

時空間パターンの作成

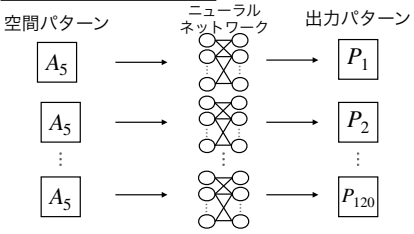
$A_1 = \{0,1,1,1,1,1,\cdots,1,1,0,0,0,0,0,\cdots,0\}$
$A_2 = \{1,0,1,1,1,1,\cdots,1,0,1,0,0,0,0,\cdots,0\}$
$A_3 = \{1,1,0,1,1,1,\cdots,1,0,0,1,0,0,0,\cdots,0\}$
$A_4 = \{1,1,1,0,1,1,\cdots,1,0,0,0,1,0,0,\cdots,0\}$
$A_5 = \{1,1,1,1,0,1,\cdots,1,0,0,0,0,1,0,\cdots,0\}$

60ビット　60ビット　ハミング距離（HD）が等しい

時空間パターンの学習

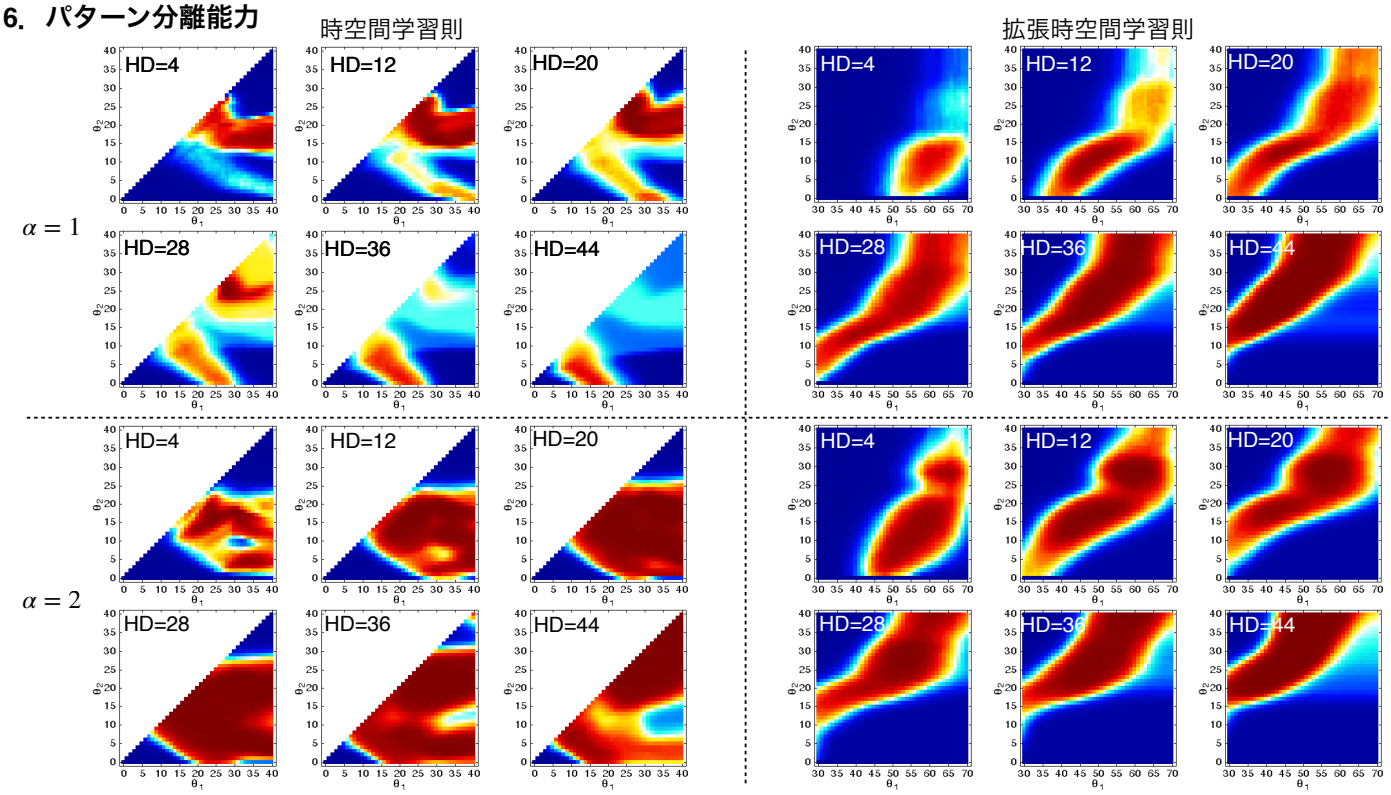


出力パターンの取得



異なる出力パターン数Cを調査

6. パターン分離能力



・ハミング距離によって出力パターン数Cが大きくなる閾値θ_1, θ_2の値が異なる　・学習率が大きいほうがハミング距離によってCが変化しにくい
・時空間学習則より拡張時空間学習則の方が学習率およびハミング距離によって出力パターン数Cが大きくなる閾値θ_1, θ_2の値が変化しにくい

7. まとめ

時空間学習則，拡張時空間学習則ともにパターン分離能力が高い
拡張時空間学習則はハミング距離によってパターン分離能力が変化しにくい

参考文献
[1] M. Tsukada, T. Aihara, H. Saito, and H.Kato, *Neural Network*, **9**(8), 1996.
[2] M. Tsukada and X. Pan, *Biological Cybernetics*, **92**(2), 2005.
[3] H. Tsukada, S. Nara, and M. Tsukada, "A systematic identification of the difference characteristics for sequence discrimination between Hebb and Extended Spatiotemporal learning rule," preprint, 2023.

謝辞　本研究の一部は，JSPS科研費JP20H00596，JP21H03514，JP22K18419および東北大学電気通信研究所における共同プロジェクト研究（R05/B13，R05/A19）の助成を受けた．

P10

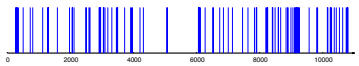
サロゲートデータを用いた点過程に対する因果性検出

澤田 和弥, 池口 徹 (東京理科大学)

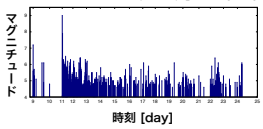
非線形問題解決集団 池口研究室 NONLINEAR DYNAMICAL SYSTEM

1. 背景

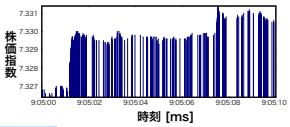
ニホンサルの前頭前野で観測された点過程 (スパイク列) [1]



地震のマーク付点過程 (MPP) [2011/03/11]



株式取引のMPP (TOPIX Core30)



従来の因果性検出手法と本研究の立ち位置

システム / データ形式	確率系	決定論的非線形力学系
時系列	Granger causality [2] Transfer entropy [3]	Convergent cross mapping (CCM) [4]
点過程	Transfer entropy [3]	スパイク列に対する提案手法[5]
マーク付点過程		マーク付点過程に対する提案手法

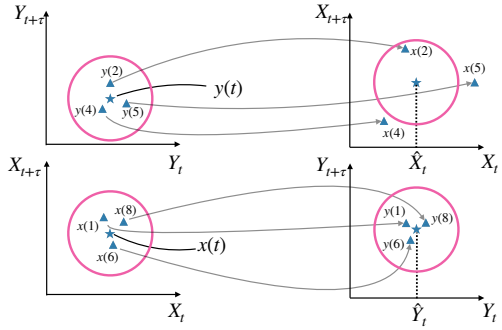
拡張

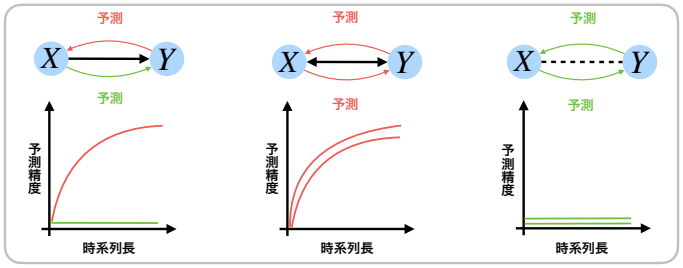
研究目的
非線形力学系から生成される点過程/マーク付点過程間の因果性検出手法の開発

2. Convergent cross mapping (CCM) [4]

in-sampleな相互予測精度によって因果性を検出する手法

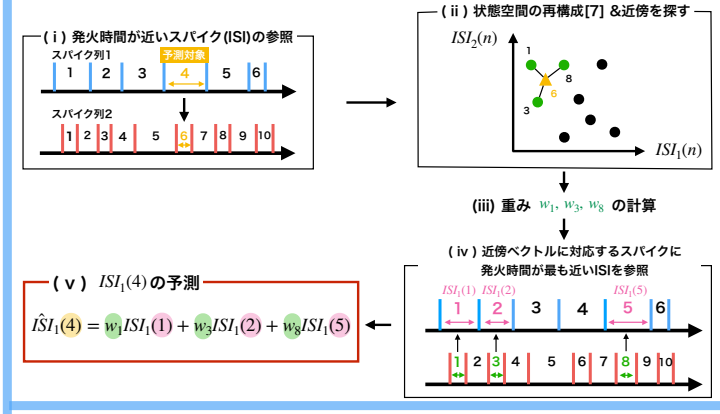
例 Y (原因) ⟶ X (結果)



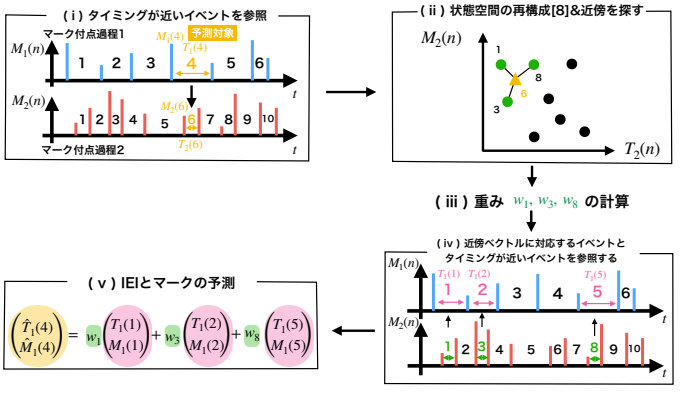


3. 提案手法 [5, 6]

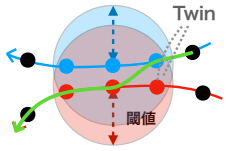
(a) 点過程 (スパイク列) (例: ISI_2 を用いた ISI_1 の予測)



(b) マーク付点過程 (例：マーク付点過程2の情報を使ってマーク付点過程1を予測)



4. Twin surrogate法 [9]



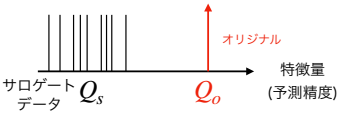
Twin=同じ近傍点を共有する点

次の時刻 or twinの次の時刻 へ

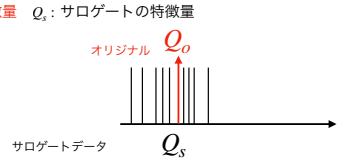
確率的に遷移する

非線形力学系の軌道は破壊されない

Q_o : オリジナルの特徴量　Q_s : サロゲートの特徴量



帰無仮説 H_0を棄却 →因果性がある



帰無仮説 H_0を棄却できない → 因果性があるとは言えない

5. 点過程生成モデル

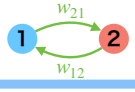
(a) 点過程 (スパイク列) (gap junctionで結合したIzhikevichモデル)[10, 11]

$$\begin{cases} \dot{v}_i = 0.04v_i^2 + 5v_i + 140 - u_i + I_i + \sum_{i\neq j, j=1}^{N} w_{ij}(v_j - v_i) \\ \dot{u}_i = a_i(b_i v_i - u_i) \end{cases}$$

$v_i \geq 30$ のとき

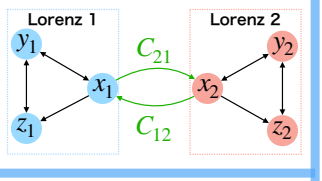
$v_i \leftarrow c_i$

$u_i \leftarrow u_i + d_i$



(b) MPP (結合Lorenzシステム)[12]

$$\begin{cases} \dot{x}_1 = \sigma_1(y_1 - x_1) + C_{12}(x_2 - x_1), \\ \dot{y}_1 = r_1 x_1 - y_1 - x_1 z_1, \\ \dot{z}_1 = -b_1 z_1 + x_1 y_1, \\ \dot{x}_2 = \sigma_2(y_2 - x_2) + C_{21}(x_1 - x_2), \\ \dot{y}_2 = r_2 x_2 - y_2 - x_2 z_2, \\ \dot{z}_2 = -b_2 z_2 + x_2 y_2 . \end{cases}$$



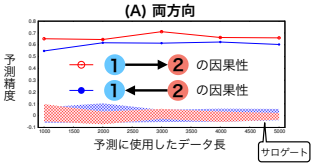
6. 結果

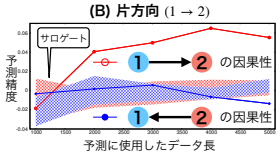
(a) 点過程 (スパイク列)

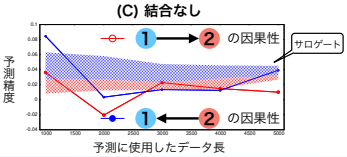
(A) 両方向　$w_{12} = w_{21} = 0.06$

(B) 片方向 (1 → 2)　$w_{12} = 0,\ w_{21} = 0.02$

(C) 結合なし　$w_{12} = w_{21} = 0$





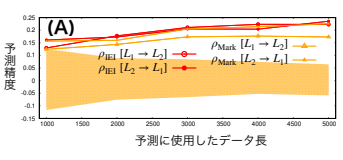


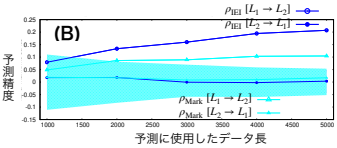
(b)マーク付点過程

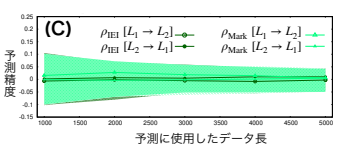
(A) 両方向　$C_{12} = C_{21} = 1.5$

(B) 片方向 ($L_1 \to L_2$)　$C_{12} = 0,\ C_{21} = 1.5$

(C) 結合なし　$C_{12} = C_{21} = 0$







参考文献

[1] S. Funahashi et al., *Cerebral Cortex*, **10**, 6, 535—551, 2000.
[2] C. W. Granger, *Econometrica*, **37** (3): 424–438, 1969.
[3] T. Schreiber, *Phys. Rev. Lett.*, **85** (2): 461–464, 2000.
[4] G. Sugihara et al., *Science*, **338** (6106): 496—500, 2012.
[5] K. Sawada et al., submitted to *Phys. Rev. E*.
[6] 澤田 他, 信学技報, **121** (436): 89–94, 2023.
[7] T. Sauer, *Phys. Rev. Lett.*, **72** (24): 3811—3814, 1994.
[8] K. Sawada et al., *J. of Signal Processing*, **25** (4): 127–131, 2021.
[9] M. Thiel et al., *EPL*, **75**: 535–541, 2006.
[10] E. M. Izhikevich, *IEEE Trans. on NN*, 14, 6, 1569—1572, 2003.
[11] 内木, 他, 信学論, J100-A, 5, 195—204, 2017.
[12] V. Anishchenko, et. al., *Phys. Rev. E*, **57** (1): 316–322, 1998.

謝辞

本研究は, JSPS科研費 JP22KJ2815, JP20H00596, JP21H03514, JP22K18419と東北大学電気通信研究所における共同プロジェクト研究(R05/A19, R05/B13)による.

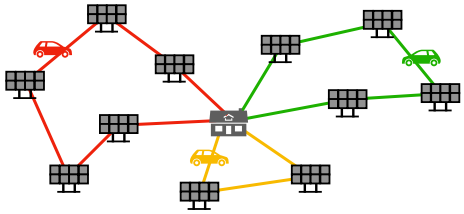
公職選挙ポスター掲示問題における初期解構築法の性能比較

○郭豊愷[1]　松浦隆文[2]　木村貴幸[2]　池口徹[1]
東京理科大学[1]　日本工業大学[2]

池口研究室

1. 公職選挙ポスター掲示問題

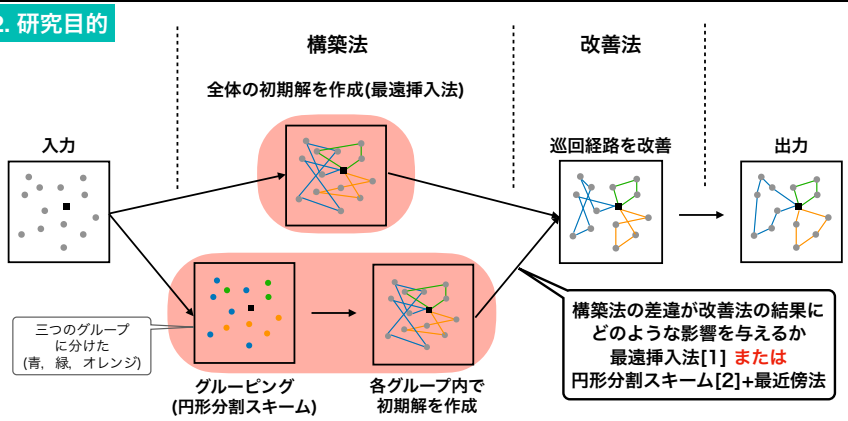
公職選挙におけるポスター掲示



：選挙事務所　　：ポスター掲示場

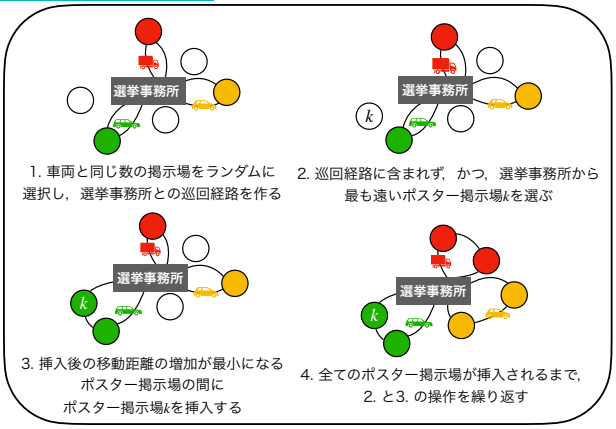
立候補者の情報を有権者に早く伝えるために
最適なポスター掲示巡回経路を構築する必要がある

2. 研究目的



3. 初期解の構築手法

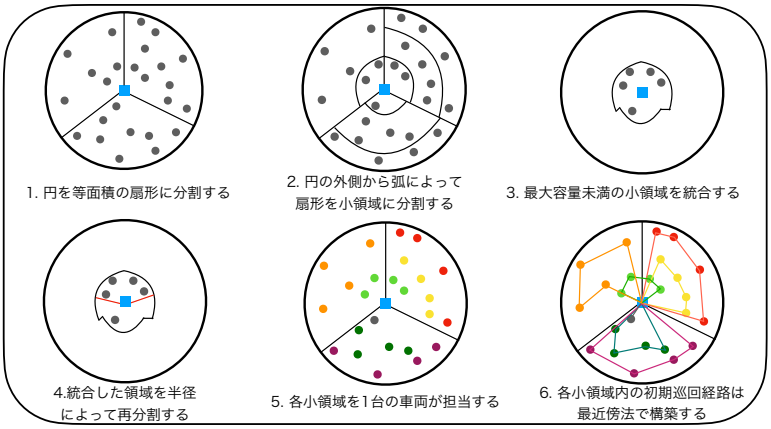
最遠挿入法[1]



1. 車両と同じ数の掲示場をランダムに選択し，選挙事務所との巡回経路を作る
2. 巡回経路に含まれず，かつ，選挙事務所から最も遠いポスター掲示場kを選ぶ
3. 挿入後の移動距離の増加が最小になるポスター掲示場の間にポスター掲示場kを挿入する
4. 全てのポスター掲示場が挿入されるまで，2. と3. の操作を繰り返す

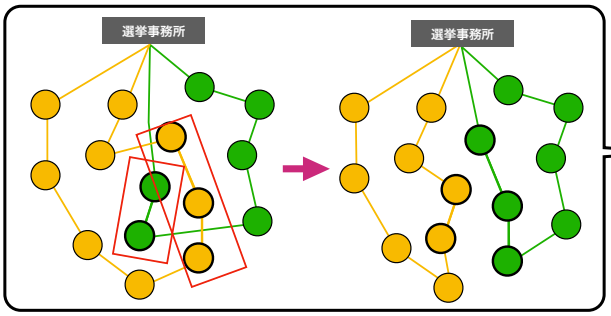
円形分割スキーム[2]

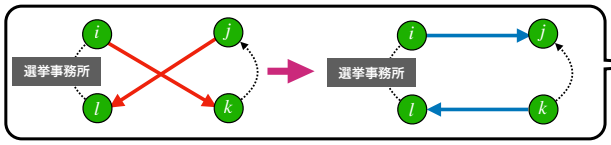
＊例は最大ポスター積載枚数を4枚とした場合

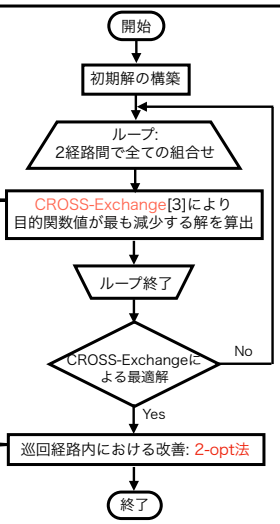


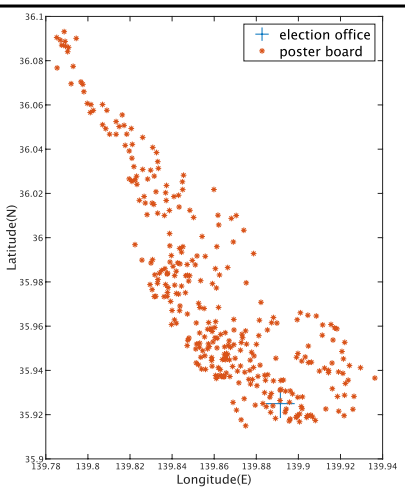
1. 円を等面積の扇形に分割する
2. 円の外側から弧によって扇形を小領域に分割する
3. 最大容量未満の小領域を統合する
4. 統合した領域を半径によって再分割する
5. 各小領域を1台の車両が担当する
6. 各小領域内の初期巡回経路は最近傍法で構築する

4. 実験データと提案法のアルゴリズム



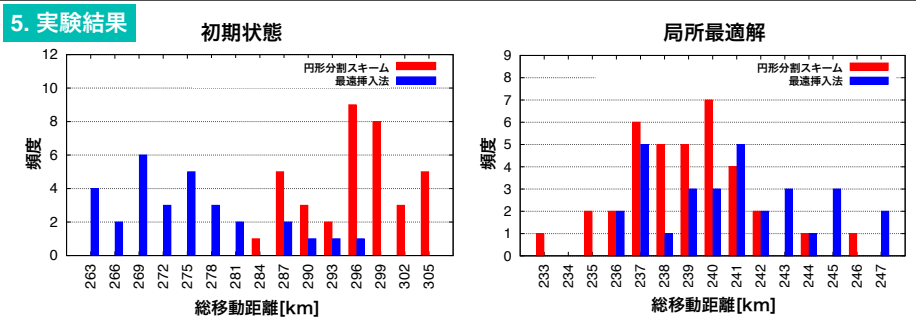






千葉県野田市のポスター掲示場配置

5. 実験結果



初期解構築では最遠挿入法が優れているが，
改善法を適用する場合は二つの方法には大きな差がない

6. まとめ

二種類構築法の差違が改善法の結果に
どのような影響を与えるかについて調査した

↓

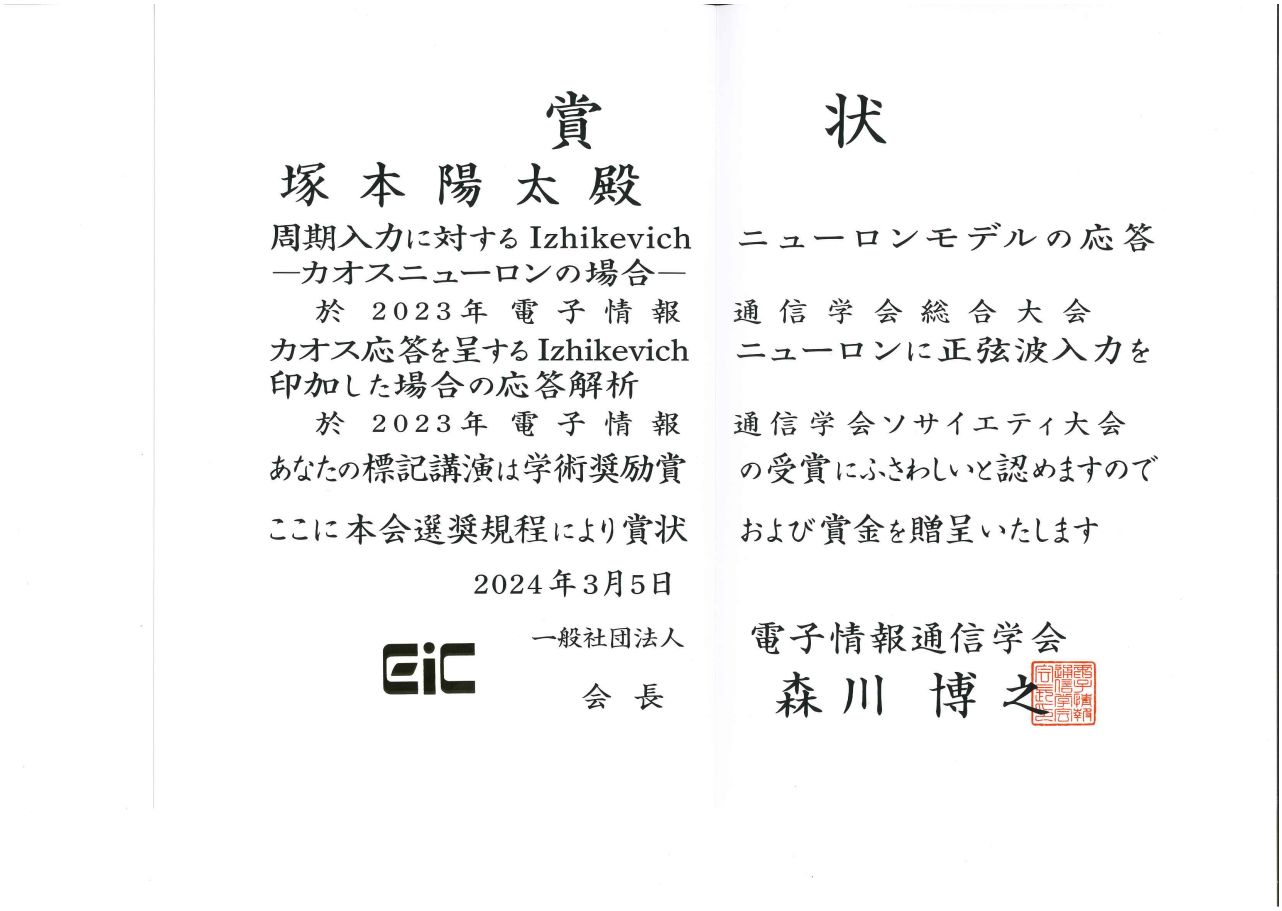
両方の結果が同じ程度となる

参考文献

[1] 星野, 他. 電子情報通信学会論文誌 A, Vol. 90, No.5, pp. 431–441, 2007.
[2] M. Haimovich and A. H. G. Rinnooy Kan, *Mathematics of Operations Research*, Vol. 10, No. 4, pp. 527–542, 1985.
[3] E.Taillard, et al., *Transportation Science*, Vol. 31, No. 2, pp. 170–186, 1997.

謝辞　本研究の一部は，JSPS 科研費 JP19K04907，JP22K04602，JP19K04395，JP23K04274，JP21H03514，JP22K18419 および東北大学電気通信研究所共同プロジェクト研究 R05/A19，R05/B13の助成を受けた．

受賞，その他



賞　状

塚本陽太殿

周期入力に対するIzhikevichニューロンモデルの応答
―カオスニューロンの場合―
於 2023年 電子情報通信学会総合大会

カオス応答を呈するIzhikevichニューロンに正弦波入力を印加した場合の応答解析
於 2023年 電子情報通信学会ソサイエティ大会

あなたの標記講演は学術奨励賞の受賞にふさわしいと認めますのでここに本会選奨規程により賞状および賞金を贈呈いたします

2024年3月5日

一般社団法人
電子情報通信学会
会長
森川博之

塚本陽太, 電気情報通信学会より 2023年度学術奨励賞受賞



表彰状

工学研究科 情報工学専攻
修士課程 2年
学籍番号：4622523

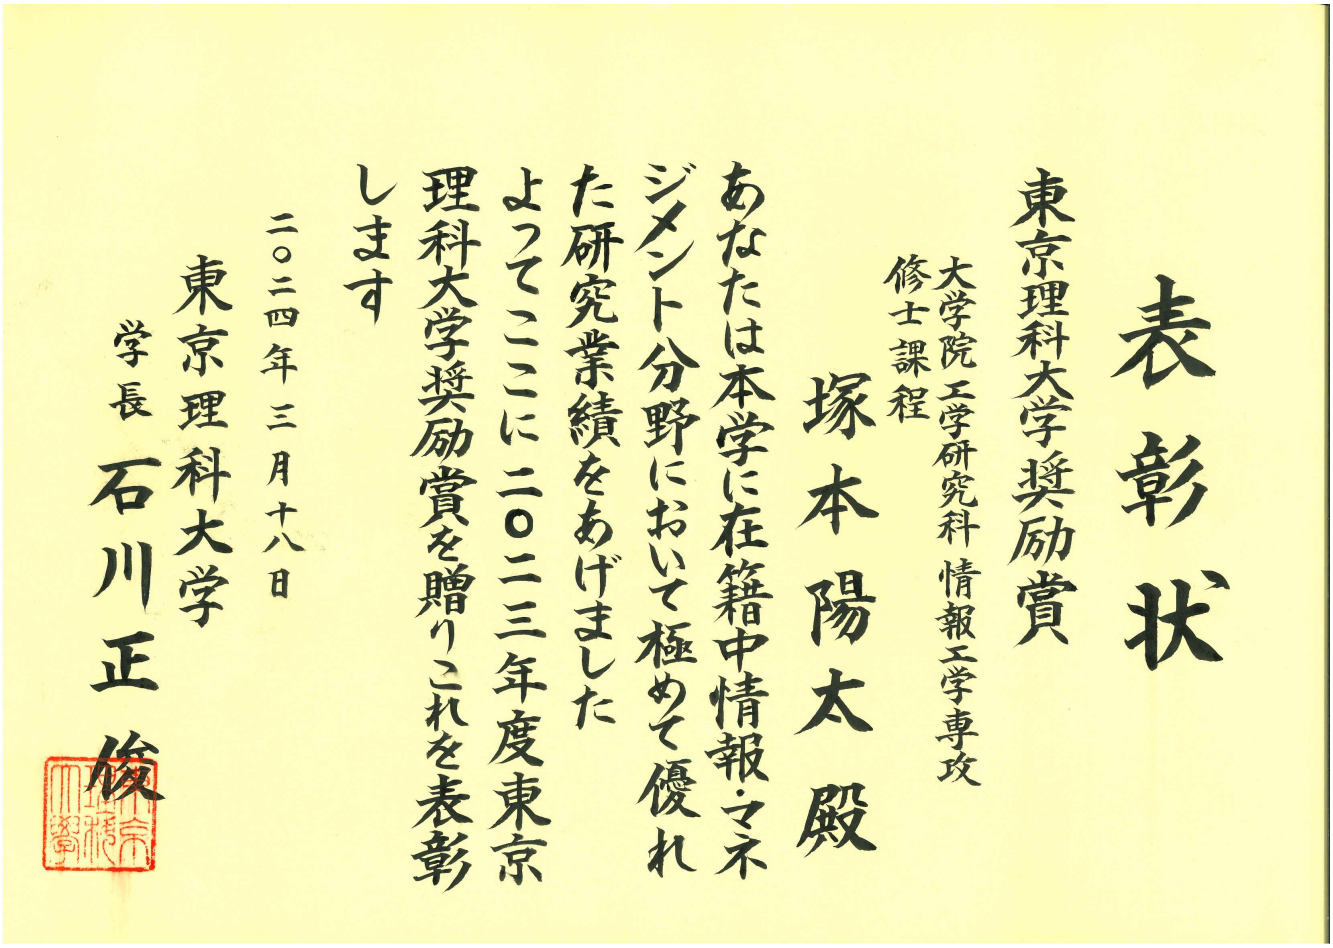
塚本　陽太 殿

あなたは学業・研究等の成果が特に優れていると
認められる者としてその功績を称えるとともに
今後のより一層の活躍を期待して表彰します

２０２４年３月７日

東京理科大学
学長　石川　正俊

塚本陽太, 東京理科大学より
2023年度 東京理科大学 学生表彰 受賞



表彰状

東京理科大学奨励賞

大学院工学研究科 情報工学専攻
修士課程
塚本陽太 殿

あなたは本学に在籍中情報・マネジメント分野において極めて優れた研究業績をあげました
よってここに二〇二三年度東京理科大学奨励賞を贈りこれを表彰します

二〇二四年三月十八日

東京理科大学
学長 石川正俊

塚本陽太, 東京理科大学より
2023年度 東京理科大学奨励賞 受賞