

結合デジタルマップの周期軌道について

On periodic orbits from a coupled digital map

木嶋 佑堅¹

Yuken Kijima

齋藤 利通¹

Toshimichi Saito

法政大学大学院 理工学研究科 電気電子工学専攻¹

Department of Electrical and Electronic Engineering, Faculty of Science and Engineering, Hosei University

1 はじめに

デジタルマップの結合系である、結合デジタルマップの基本動作を考察する。

2 本論

デジタルマップ (Dmap) は、点の集合で定義されるデジタル力学系である。初期値とパラメータに依存して、様々な周期軌道を呈する。定義域が有限の点からなるので、定常状態は必ず周期軌道となる。応用例として、スパイクニューラルネットやデジタル通信が挙げられる。本稿では Dmap を結合させた、結合デジタルマップ (CDM)[1] の基本動作を考察する。CDM は、多彩な現象を呈する Globally Coupled Map [2] の簡素なデジタル版である。まず、アナログマップの式を以下に示す。

$$\begin{aligned} \phi_{n+1} &= h(\phi_n) \\ h(\phi_n) &= \begin{cases} (1+a)\phi_n & (0 \leq \phi_n < \frac{1}{4}) \\ (1-a)(\phi_n - \frac{1}{2}) + \frac{1}{2} & (\frac{1}{4} \leq \phi_n < \frac{3}{4}) \\ (1+a)(\phi_n - 1) + 1 & (\frac{3}{4} \leq \phi_n < 1) \end{cases} \end{aligned} \quad (1)$$

ここで、 ϕ_n は n 番目の状態変数であり、 $0 \leq \phi_n < 1$ 、 $2 < a < 3$ である。これを N 個の点で離散化すると、Dmap が得られる。

$$\phi_{n+1} = f(\phi_n) \equiv Q(h(\phi_n)), \quad Q(\phi) = \frac{1}{N} \text{INT} \left(N\phi + \frac{1}{2} \right) \quad (2)$$

ただし、 $\phi_n \in \{0/N, \dots, (N-1)/N\}$ である。図 1 に、Dmap の例を示す。図 1(1) は、初期値 $\phi_0(1) = 19/32$ の 6 周期軌道である。以下、簡単のため、初期値の分母を省略する。図 1(2) は、初期値 $\phi_0(2) = 12$ の 3 周期軌道である。CDM は、2 つの Dmap を結合することで得られ、次式によって定義される。

$$\begin{aligned} \phi_{n+1}(1) &= Q((1-\varepsilon)f(\phi_n(1) + \varepsilon f(\phi_n(2))) \\ \phi_{n+1}(2) &= Q((1-\varepsilon)f(\phi_n(2) + \varepsilon f(\phi_n(1))) \end{aligned} \quad (3)$$

CDM を、 $\Phi_{n+1} = F(\Phi_n)$ 、 $\Phi_n \equiv (\phi_n(1), \phi_n(2))$ とする。 $X = F^k(X)$ であり、 $F(X)$ から $F^k(X)$ が全て異なるとき、 X を周期 k の周期点、 $\{F(X), \dots, F^k(X)\}$ を周期軌道という。ただし、 F^k は F の k 回合成写像である。

CDM の周期軌道は様々なパターンがあるが、本稿では典型例を 2 つ紹介する。1 つ目の例を図 2(1) に示す。この周期軌道は、初期値が 19 の 6 周期軌道 (図 1(1)) と、初期値が 12 の 3 周期軌道 (図 1(2)) の結合によってできている。周期軌道は、 $[(19, 12), (21, 12), (21, 9), (26, 10), (24, 12), (20, 4), (14, 10), (26, 21), (7, 9), (29, 27),$

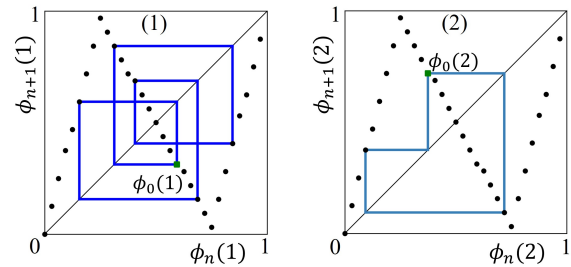


図 1 Dmap の典型例 ($a = 2.85, N = 32$)
(1) 6 周期軌道, $\phi_0(1) = 19$, (2) 3 周期軌道, $\phi_0(2) = 12$

(14, 19), (12, 19), (12, 21), (9, 21), (10, 26), (12, 24), (4, 20), (10, 24), (21, 26), (9, 7), (27, 29), (19, 14)] となる。周期軌道の $\phi_n(1)$ 成分と $\phi_n(2)$ 成分は、同じ要素から構成され、位相がずれている。その要素は、結合前の Dmap の 6 周期点と 3 周期点に加え、結合前の周期軌道に含まれないものを含んでいる。2 つ目の例を図 2(2) に示す。2 つ目の例は、初期値が 10 の 6 周期軌道と、初期値が 22 の 6 周期軌道の結合によってできている。この 2 つの 6 周期軌道は、図 1(1) の初期値のみ変更したものである。周期軌道は、 $[(10, 22), (8, 24), (6, 26), (11, 21)]$ となる。 $\phi_n(1)$ 成分と $\phi_n(2)$ 成分は、異なる要素から構成されている。その要素は、結合前の Dmap の 6 周期点と結合前の周期軌道に含まれないものを含んでいる。

3 むすび

Dmap を結合した CDM の基本動作を調べた。詳細な解析と、FPGA によるハードウェア実装が課題である。

参考文献

- [1] 木嶋, 齋藤, 信学技報, CCS2021-19.
- [2] 金子, 津田, 朝倉書店, 1996.

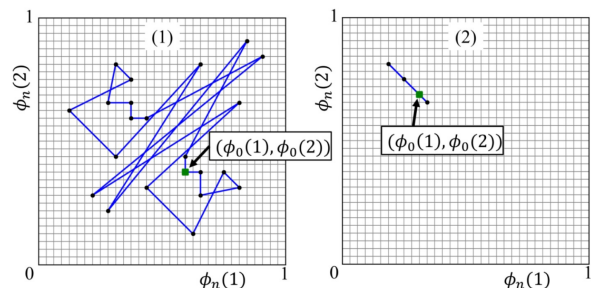


図 2 CDM の典型例 ($a = 2.85, N = 32, \varepsilon = 0.85$)
(1) 22 周期軌道, $(\phi_0(1), \phi_0(2)) = (19, 12)$
(2) 4 周期軌道, $(\phi_0(1), \phi_0(2)) = (10, 22)$

ファン・デル・ポール回路を用いた雑音誘起位相同期実験

Experiment on noise-induced synchronization in Van der Pol circuit

林泰輝 石村憲意 徳田功
Taiki Hayashi Kazuyoshi Ishimura Isao T. Tokuda

立命館大学大学院理工学研究科機械システム専攻
Graduate School of Science and Engineering, Ritsumeikan University

1. まえがき

複数の結合されていない振動子に共通の雑音を加えることで位相が揃う現象を雑音誘起位相同期と呼ぶ[1]。安田らは雑音同期を自然環境に応用することを目指して、環境ノイズを FitzHugh-Nagumo モデルに印加するシミュレーションを行ったが、実機実験は行っていない[2]。本研究では、環境ノイズとして自然界に存在する環境音に着目し、ファン・デル・ポール回路で実験を行なった。複数のマイクで環境音を録音し、それぞれの信号を回路に印加する場合、マイクの位置によって、録音信号には差異が生じる。録音信号同士にどの程度相関がある場合に位相同期が達成されるのか、実機実験を行い検討する。

2. 実験方法

防音箱内でスピーカーからホワイトノイズを再生し、マイクで5回録音する。ただしスピーカーに対して、マイクは毎回少しずつ(1mm, 3mm, 10mm, 20mm, 30mm ずつの5種類)平行移動して設置し計測する。このように録音したノイズ信号を実機のファン・デル・ポール回路に入力する。実験後、図1(右)のように入力ノイズ波形の重ね合わせを行い、回路の出力波形と比較する。雑音誘起位相同期が達成されているかを、同期指標を用いて定量的に検証する。




図1 ファン・デル・ポール回路と波形の重ね合わせ

3. 実験結果

マイクを異なる位置に置いて録音したノイズ同士の相関係数を図2(上)に示す。距離が1mmの場合の相関はおおよそ0.96と高いが、距離が30mmまで離れると、相関は0.71程度まで下がる。これより、マイクの移動距離が大きいほど、ノイズ同士の相関が低くなるのがわかる。

このようにして録音されたノイズ信号を実機のファン・デル・ポール回路に入力したときに得られた同期指標を図2(下)に示す。距離が1mmの場合、0.90と高いレベルで同期しているが、距離が30mmに離れると同期指標は0.72まで下がる。同期指標は、相関係数に比例して単調減少することがわかる。

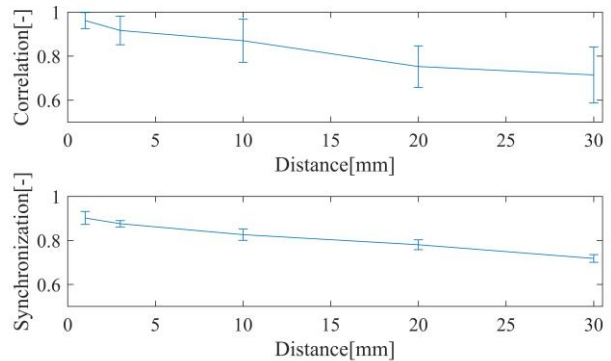


図2 相関係数と同期指標




図3 同期指標の時間推移

1mmおよび30mmずつマイクを動かしたときの同期指標の時間推移を図3に示す。距離が1mmの場合、ノイズ印加直後に同期指標はほぼ1となり、その後は高いレベルの同期が維持されていることが確認できる。時折同期が外れても、すぐに同期状態を回復している。対して距離が30mmの場合、同期と非同期が短い間隔で繰り返され、同期していない状態が長く継続することがわかる。

以上の結果よりマイクの移動距離が短く、ノイズの相関が高い場合に、雑音誘起位相同期を確認することができた。

4. 参考文献

- [1] Jun-nosuke Teramae and Dan Tanaka, "Robustness of the Noise-Induced Phase Synchronization in a General Class of Limit Cycle Oscillators," *Phys Rev Lett*, 93(20):204103, 2004.
- [2] Hiroyuki Yasuda and Mikio Hasegawa, "Natural Synchronization of Wireless Sensor Networks by Noise Induced Phase Synchronization Phenomenon," *IEICE Transactions on Communications*, 96(11):2749-2755, 2013.

シミュレータを用いる初期値がわずかに違う 2 種類の解の軌道間の距離から位相反転波動の特性を調査する手法の開発

Development of Investigating Method for Characteristics of Phase-Inversion Waves by Using Distances between Two Kinds of Solution Orbit by Initial Values with Small Differences

永井佳輔 山内将行

Keisuke Nagai Masayuki Yamauchi

広島工業大学

Hiroshima Institute of Technology

1. まえがき

自然界では、目に見えるイワシの大群のようなものから目に見えない物まで、様々な物が同期し一体となって動いていると言われている。また、通信システムなどにも同期現象は利用されており、同期現象は重要な現象の一つと言える。発振器をインダクタで梯子状や環状などに結合したシステムにおいても同期現象は観測され、同期状態が伝搬する波動現象^[1]など、様々な同期現象が観測されている。

本研究では、van der Pol 発振器を梯子状に結合した系の、同期状態の変化が伝搬し続ける現象である位相反転波動が存在する状態において、わずかな初期値の差異がどのようなか spice を用いて観測、及び調査を行う。

2. 回路モデル

図 1 に示すように、van der Pol 発振器を 5 つ、インダクタで梯子状に結合し spice を用いて解析を行う。非線形負性抵抗を構成する OPamp は TL082 とし、 R_1 及び R_2 は $8.2k\Omega$ とする。また、 R_3 は $1.8k\Omega$ とする。各発振器のインダクタ L 、及びキャパシタ C は、 $50mH$ 及び $6.7nF$ とする。また、発振器の結合に用いるインダクタ L_C は $300mH$ とし、インダクタ L_C の内部抵抗を示す R_4 は 10Ω とする。

3. シミュレーション結果

本研究では、初期値セット A として、 OSC_k (ただし、 $k=2\sim 5$) の発振器の C の初期電圧 $v_{k,A}(0)$ を $5.0000V$ 、 L の初期電流 $i_{Lk,A}(0)$ を $5.0000mA$ 、結合の L_C の初期電流 $i_{Lc1,A}(0)$ (ただし、 $n=2\sim 4$) を $5.0000mA$ 、 OSC_1 の $v_{1,A}(0)$ を $-5.0000V$ 、及び $i_{L1,A}(0)$ を $-5.0000mA$ 、 $i_{Lc1,A}(0)$ を $-5.0000mA$ とし、位相反転波動を発生させる。次に、初期値セット B として、 OSC_1 の C の初期電圧値 $v_{1,B}(0)$ を $-5.0001V$ 、 OSC_k (ただし、 $k=2\sim 5$) の C の初期電圧値 $v_{k,B}(0)$ を $5.0001V$ とする。ただし、初期電流値は、初期値セット A と同値とする。 OSC_k (ただし、 $k=1\sim 5$) における初期値から m 回目の計算ステップにおける解軌道間の瞬時距離 $D_k(m)$ を式(1)で導出する。

$$D_k(m) = \sqrt{(v_{k,A}(m) - v_{k,B}(m))^2 + (i_{Lk,A}(m) - i_{Lk,B}(m))^2} \quad (1)$$

ただし、spice が可変ステップ長で計算を行うため、本研究では計算するステップ幅を $10ns$ と決め、 $10ns$ ごとの計算結果を m 回目の計算結果として検出することとする。

初期値セット A を代入し、spice を利用してシミュレートした結果を図 2 に示す。図 2 は、上から順に v_{1+v2} 、 v_{2+v3} 、 v_{3+v4} 、及び v_{4+v5} の計算をした結果を時間軸に沿って描いたグラフを縦に重ねて表示している。この結果から、位相反転波動が伝搬し続けていることが解る。




図 1. 回路モデル




図 2 初期値セット A を与えた時の位相反転波動




図 3 初期の距離を基本とした瞬時疑似リアプノフ指数(IQLEI)

次に、初期値の誤差 $D_k(0)$ を基本とした m 回目の誤差の拡大率を式(2)として設定する。この値を「初期の距離を基本とした瞬時疑似リアプノフ指数(IQLEI)」と呼ぶ。

$$IQLEI(m) = \ln \left| \frac{D(m) - D(0)}{t(m)} \right| \quad (2)$$

位相反転波動が伝搬する中 OSC_3 と OSC_5 の $IQLEI$ がどのように振舞うか、それぞれ図 3(a)と図 3(b)に示す。概ね-5 から-20の間で変化していることがわかる。

4. 結論

本研究では、van der Pol 発振器を 5 つ、インダクタで梯子状に結合した回路において、僅かに誤差のある 2 種類の初期値を用いて位相反転波動を発生させ、 $IQLEI$ を用いて誤差が拡大するかしないかを観測した。 $IQLEI$ が負の値をとっているため、位相反転波動が存在しても、初期の誤差は収束する方向に動いているのではないかと考えられる。

謝辞

本研究は JSPS 科研費 20K11984 の助成を受けたものです。

文献

[1] M. Yamauchi, M. Wada, Y. Nishio and A. Ushida, "Wave Propagation Phenomena of Phase States in Oscillators Coupled by Inductors as a Ladder," IEICE Trans. on Fundamentals vol. E82-A, no. 11, pp. 2592-2598, Nov. 1999.

感染症ダイナミクスの遅延フィードバック制御 — 処理遅延が与える影響 —

Delayed feedback control of infectious disease dynamics: influence of processing delay

櫻井雄太¹

Yuta Sakurai

小西啓治¹

Keiji Konishi

岩本哲^{1,2}

Tetsu Iwamoto

原尚之¹

Naoyuki Hara

大阪府立大学¹

Osaka Prefecture University

日本学術振興会特別研究員 DC²

Research Fellow of Japan Society for the Promotion of Science

1 はじめに

感染状況が報道されるまでに一定程度の時間 $\tau \geq 0$ を要し、その情報に応じて人々が行動変容を行う「感染症ダイナミクス」では、感染者数に自励振動が誘発される [1]. この振動のピークは、医療体制へ負担をもたらす要因に相当する。そこで筆者らは、このモデル [1] に遅延フィードバック制御 (DFC) を導入することで、感染者数の振動が抑制できることを確認した [2]. しかし、この制御法では、感染状況のデータの取得に時間遅れがない ($\tau = 0$) ことを想定しており、潜伏期間などの遅れを有する感染症には、その実装が不可能であった。一方、遅延ダイナミクスを扱う研究分野では、データ取得に要する「処理遅延」を考慮した研究も存在する [3]. 本報告では、この処理遅延に伴う遅延フィードバック制御を、感染症ダイナミクス [1] に適用する。特に、この処理遅延が振動の抑制に与える影響を調査する。

2 感染症ダイナミクスと遅延フィードバック制御

DFC を適用した感染症ダイナミクス [1] は

$$\dot{x}(t) = \left[\frac{\beta}{1 + \alpha x(t - \tau)} \{1 - x(t)\} - \mu + u(t) \right] x(t),$$

$$u(t) = K \{x(t - T_p - T) - x(t - T_p)\},$$

で記述される (図 1 参照). $x(t) \geq 0$ は感染者密度, $\beta \geq 0$ は感染率, $\mu \geq 0$ は回復率を表す. $\tau \geq 0$ と $\alpha \geq 0$ は、それぞれ感染状況が報道を通して人々に伝わるまでの時間と、その報道に対する人々の行動変容の感度を表す。また、 $u(t) \in \mathbb{R}$ は DFC の制御信号であり、 $K \geq 0$ はゲイン, $x(t - T_p)$ は処理時間 $T_p \geq 0$ だけ過去の感染者密度である。DFC では、 $x(t - T_p)$ とその時刻から更に $T \geq 0$ だけ過去の感染者密度 $x(t - T_p - T)$ との差分に比例した制御入力 $u(t)$ を決定する。ここで、平衡点 $x_{EE}^* := \frac{\beta - \mu}{\beta + \mu\alpha}$ は、 $\beta < \mu$ であれば不安定、 $\beta > \mu$ かつ $\tau \in [0, \tau_c)$ であれば安定となる。ただし、 τ_c は

$$\tau_c = \frac{\beta(1 + \alpha) \left\{ \pi - \arccos \left(\frac{\beta}{\mu\alpha} \right) \right\}}{(\beta - \mu) \sqrt{(\mu\alpha)^2 - \beta^2}},$$

で与えられる [1]. $\tau = \tau_c$ の Hopf 分岐で x_{EE}^* が不安定化し、 $x(t)$ は振動する。 x_{EE}^* の特性式は次式で表される。

$$s + \frac{\beta - \mu}{1 + \alpha} \left(1 + \frac{\mu\alpha}{\beta} e^{-s\tau} \right) + K \frac{\beta - \mu}{\beta + \mu\alpha} e^{-sT_p} (1 - e^{-sT}).$$





図 1 遅延フィードバック制御システム



(a) $T_p = 0$

(b) $T_p = \tau$

図 2 平衡点 x_{EE}^* の安定領域 ($K = 2$)

3 数値シミュレーション

$\beta = 0.7, \mu = 0.3, \alpha = 15$ に設定すると、 $\tau_c = 10.88$ で Hopf 分岐が生じる。処理遅延の有無が平衡点 x_{EE}^* の安定性に与える影響を調べる。 $T_p = 0$ および $T_p = \tau$ とした $\tau - T$ 空間での安定領域 (灰色) をそれぞれ図 2(a),(b) に示す。 $\tau = \tau_c$ (図 2: 破線) の右側の安定領域は、感染者数の振動が DFC で抑制できる領域である。処理遅延の影響により、この領域は大幅に狭くなっていることがわかる。この結果は、DFC で安定化が可能となる「制御パラメータ T の範囲」と「状況が伝わるのに要する時間 τ の範囲」が、処理遅延によって制限されることを示唆している。

4 まとめ

遅延フィードバック制御によって安定化できる領域が、処理遅延の影響で小さくなることを確認した。本研究の一部は、科研費 (21H03513) の助成を受けたものである。

参考文献

- [1] H. Zhang *et al.*, Physica D, vol. 241, pp. 1512–1517, 2012
- [2] 櫻井 他, 自動制御連合講演会, 2A1-4, 2021
- [3] W. Zou *et al.*, Phys. Rev. Lett., vol. 111, p. 014101, 2013

不感帯のある簡素な積分発火型発振回路のノイズ誘起位相同期 Noise-induced phase synchronization in simple integrate-and-fire oscillators with dead zone

中山翔太¹ 高田明雄¹
Shota Nakayama Akio Takada
函館工業高等専門学校¹
National Institute of Technology, Hakodate College

坪根 正²
Tadashi Tsubone
長岡技術科学大学²
Nagaoka University of Technology

1. まえがき

互いに結合していない発振器同士がノイズによって同期することが知られており[1]、無線センサネットワーク[2]の省電力化等に有効な一手法として、周囲環境に存在するノイズを使った同期法が提案されている[3]。同様に、ニューロンの単純なモデルとして知られる積分発火型発振回路においてもノイズ誘起同期が報告されている[4,5]。しかしながら、外部から加えるノイズは、同期を促すトリガとして作用する一方、確率的に同期を妨げる場合も起こりうる。そこで、ロバストなノイズ誘起同期を目的とし、本研究では後者の影響を抑制する回路を試作し、先行研究の回路[4,5]に組み込んだ実験を行った。

2. 実験

実験に用いた発振回路を図1に示す。この回路は、コンデンサを充電し、その端子間電圧 V が閾値電圧 V_{th} に達した瞬間に放電する（ここでは発火と呼ぶ）という動作を繰り返す。また、先行研究からは、発振周期よりやや短い時間間隔で揺らぐトリガパルスの印加が同期に有効であることが示されていることから[4]、本研究では、ホワイトノイズから帯域通過フィルタを通して得た有色ノイズを基にして、時間間隔が揺らいだ負のトリガパルスを生成し、それを閾値となる直流電圧に加えたもの $V_{th}[4]$ を共通の閾値信号として二つの発振器に加えた。得られたトリガパルスの時間間隔を図2に示す。なお、二つの発振器の自走発振周波数には0.5%程度の違いがあるものとした。以上の回路動作に関する電圧 V および V_{th} の時間変化を模式的に表したものを図3に示す。

発振器の位相同期を目的として印加するノイズが確率的に同期を妨げるため、発振器が発火した瞬間から一定時間に外部信号の影響を受けず発火を防止する回路を組み込んだ。




図2.有色ノイズから得られるパルスの間隔のヒストグラム




図3. 電圧 V および V_{th} の時間変化

表1. 同期割合

ノイズなし	ノイズあり	
	不感帯なし	不感帯あり
0.4%	18.0%	34.7%

3. 結果および考察

本研究では、位相同期の判定基準として、発火直後の大きな瞬時値の変化に着目し、時間軸上で隣接する二つの発火の時間差が T の0.1%未満にある場合に位相同期が起こっているとみなした場合の結果を表1に示す。ノイズが最適化されておらずその効果が十分に大きいとはいえないが不感帯回路の有効性は確認できたと考えられる。

謝辞

本研究の一部は科研費（19K04415）の助成を受けた。

参考文献

- [1] J. Teramae and D. Tanaka, *Phys. Rev. Lett.* 93, 204103, 2004
- [2] I. Akyildiz, W. Su, Y. Sankarasubramaniam and E. Cayirci, *Computer Networks*, 38, pp. 393–422, 2002.
- [3] H. Yasuda and M. Hasegawa, *IEICE Trans. Commun.*, E96B, pp. 2749–2755, 2013.
- [4] 川俣優二, 坪根 正, *信学技報*, vol. 117, no. 505, NLP2017-112, pp. 57-60, 2018
- [5] Y. Kawamata and T. Tsubone, *The 2018 IEEE Workshop on Nonlinear Circuit Networks (NCN2018)*, 7PM2-4, pp.45-48, 2018.




図1. 不感帯を有する積分発火型発振回路

時変変圧器によるテブナン等価回路の出力特性変換における動作点

Operating Points on Output Characteristic Transformation of Thevenin's Equivalent Circuits

Based on Time-Variable-Transformer

山本謙太¹ 河嶋信彦² 久門尚史² イスラム マーフズル² 和田修己²
Kenta Yamamoto Nobuhiko Kawashima Takashi Hisakado Mahfuzul Islam Osami Wada

京都大学工学部 電気電子工学科¹
Undergraduate School of Electrical and Electronic Engineering, Kyoto University
京都大学大学院工学研究科 電気工学専攻²
Department of Electrical Engineering, Kyoto University

1 はじめに

双方向コンバータのマクロな変換特性を表すモデルとして、時変変圧器が用いられている [1]。本稿では、直流の時変変圧器の時変 2 ポート回路としての性質を利用し、テブナン等価回路にて表される電源を異なるテブナン等価回路に写像することについて考える。

2 時変変圧器による特性変換

時変変圧器は式 (1) に示す 2 ポート特性を有する [1]。

$$\begin{pmatrix} v_1(t) \\ i_1(t) \end{pmatrix} = \begin{pmatrix} 1/\alpha(t) & 0 \\ 0 & \alpha(t) \end{pmatrix} \begin{pmatrix} v_2(t) \\ i_2(t) \end{pmatrix} \quad (1)$$

式 (1) から、ポート間の電力保存を表す式 (2) を得る。

$$v_1 i_1 = v_2 i_2 \quad (2)$$

式 (2) は 4 次元空間 (v_1, i_1, v_2, i_2) 上における変換特性の制約条件となる。次に、式 (3) のテブナン等価電源を 1 次側に接続し、式 (1) の 2 ポート特性により 2 次側にて式 (4) に示す出力特性を実現することについて検討する。

$$v_1 = e_1 - r_1 i_1 \quad (3)$$

$$v_2 = e_2 - r_2 i_2 \quad (4)$$

式 (3), (4) において、 e_1, e_2 は内部起電力、 r_1, r_2 は内部抵抗を表す。

3 変換の非線形性と線形変圧器・線形ジャイレータ

式 (2), (3) より (v_1, v_2, i_2) 空間における動作領域は式 (5) になり、図 1(a) 中の 2 次元曲面で表される。

$$v_1(v_1 - e_1) + v_2 i_2 r_1 = 0 \quad (5)$$

これに式 (4) の制約を与えると動作点の集合は 1 次元多様体となり、 v_1-v_2 関係は式 (6)、 v_1-i_2 関係は式 (7) となる。

$$v_1(v_1 r_2 - e_1 r_2) - v_2(v_2 r_1 - e_2 r_1) = 0 \quad (6)$$

$$v_1(v_1 - e_1) - i_2(i_2 r_1 r_2 - e_2 r_1) = 0 \quad (7)$$

図 1(a) において式 (4) は緑色の平面、式 (6), (7) は赤色の曲線に相当する。2 次側において式 (4) の出力特性を実現するためには、動作点が図 1(a) 中の曲線上に維

持されるように $\alpha(t)$ をフィードバック制御すればよい。

式 (6), (7) の v_1-v_2 関係および v_1-i_2 関係は非線形であるが、 $r_1 = r_2 e_1^2 / e_2^2$ を満たすとき、各式は式 (8), (9) のように因数分解できる。

$$\left(v_2 - v_1 \sqrt{\frac{r_2}{r_1}} \right) \left(v_2 - e_2 + v_1 \sqrt{\frac{r_2}{r_1}} \right) = 0 \quad (8)$$

$$\left(i_2 - \frac{e_2}{r_2} + \frac{v_1}{\sqrt{r_1 r_2}} \right) \left(i_2 - \frac{v_1}{\sqrt{r_1 r_2}} \right) = 0 \quad (9)$$

式 (8), (9) において第 1 因子は線形変圧器 (LT)、第 2 因子は線形ジャイレータ (LG) であり、そのときの特性は図 1(b) になる。

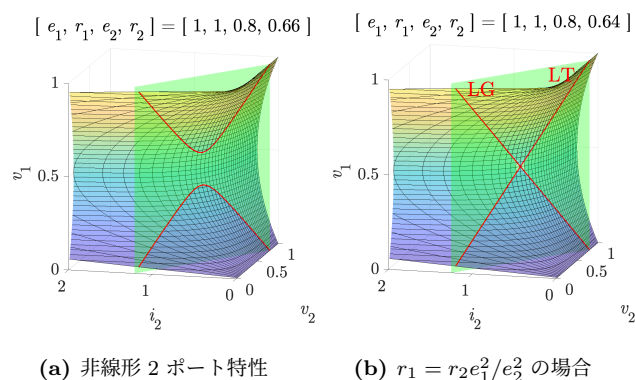


図 1: 式 (5) の多様体と式 (4) との共通部分

図 1 から、一般的な変換条件では非線形な 2 ポート特性となるものの、線形変圧器 (LT) および線形ジャイレータ (LG) のペアが非線形 2 ポート特性を特徴づけており、2 次側の動作点に対応する 1 次側の動作点が 2 個存在することがわかる。

4 まとめ

時変変圧器を用いた写像によりテブナン等価回路の出力特性を変換する場合、非線形な写像によりこの変換が実現されること、この変換の特徴として線形変圧器と線形ジャイレータのペアが存在し、それぞれに対応した動作点が 2 個存在することを明らかにした。

参考文献

- [1] D.Kiss, T.Hisakado, T.Matsushima, and O.Wada, IEEE Trans. PE, Vol. 34, pp. 8230-8240, Nov. 2018.

単方向結合双安定系を用いた リザーバーコンピューティングの状態変化検出に関する一検討

A Study on State Change Detection in Reservoir Computing Using Unidirectionally Coupled Bistable Systems

青木 勇磨
Yuma Aoki

引原 隆士
Takashi Hikihara

京都大学大学院 工学研究科 電気工学専攻
Department of Electrical Engineering, Kyoto University

1. はじめに

人工ニューラルネットワークに基づく機械学習手法の1つであるリザーバーコンピューティング (RC) [1] は、単純なネットワーク構造を有しているため、物理実装に適する [2]。物理実装された RC における課題に、RC の故障検出が挙げられる。故障が検出されなければ、RC の解は疑われないまま信用される。故障があることを検出できれば、故障したまま RC の再学習が可能で自己修復が可能となる。自己修復の実現のためには故障の検出が不可欠となる。本報告では単方向結合された双安定系を RC とする。校正モードにおいて RC の状態の変化が検出できるか否かを検討する。

2. 単方向結合双安定系

本報告で対象とする RC を図 1 に示す。RC は、単方向結合双安定系であり、図中の数字は各ノードの番号を示している。各ノードは同一であり、一方向に結合している。 $\epsilon_1, \epsilon_2, \epsilon_3$ は外部入力であり、各ノードにそれぞれ入力される。この系の挙動は次式で表される。

$$\begin{aligned} \dot{x}_1 &= -x_1 + I_{s1} \tanh(x_1) - I_{c1} \tanh(x_3) - \epsilon_1 \\ \dot{x}_2 &= -x_2 + I_{s2} \tanh(x_2) - I_{c2} \tanh(x_1) - \epsilon_2 \\ \dot{x}_3 &= -x_3 + I_{s3} \tanh(x_3) - I_{c3} \tanh(x_2) - \epsilon_3 \end{aligned} \quad (1)$$

式 (1) は文献 [3] を参考にし、各パラメータを $I_{s1} = I_{s2} = I_{s3} = 2, I_{c1} = I_{c2} = I_{c3} = 1$ とする。この系は、初期条件に応じて自励振動し、ノード間で一方向に振動伝搬が生じる。振動は周期的であるが、非線形性により正弦波ではない。外部入力がない場合、系の振動は対称であり、外部入力が増加すると、対称性が崩れ、振動の周波数が変化する [3]。本報告では、校正モードにおいて非対称性を検知することにより、パラメータの変化、すなわち故障検出を行おうというものである。ここでは、ノード 2 と 3 の結合係数の変化により対称性が失われるという設定とする。式 (1) において、 ϵ_2 の変化は \dot{x}_2 に影響を与える。そしてノード 3 の $I_{c3} \tanh(x_2)$ の項に影響を与え、ノード 2 と 3 の見かけの結合係数が変化する。つまり、ノード 2 と 3 の結合係数の変化はノード 2 で ϵ_2 が変化するということを見ることが出来る。これを校正モードで検出する。




図 1: RC モデル。

3. パラメータ変動が与える振動特性の変化

ここでは、パラメータ変動時の外部入力 ϵ に対する振動周波数の変化に着目する。図 2 に、式 (1) の系において $I_{c3} = 1, 0.95, 0.9$ と変化させた場合について、外部入力に対する振動周波数の変化を示す。ここで、外部入力は $\epsilon_1 = \epsilon_2 = \epsilon_3 = \epsilon$ とする。図 2 の黒線は、 $I_{c3} = 1$ の場合の外部入力に対する周波数変化である。これは文献 [3] の結果と一致する。外部入力が大きくなるにつれて振動周波数が低下し、 $\epsilon = 0.465$ 付近で系は振動しなくなる。図 2 は I_{c3} の値を小さくすると外部信号に対する周波数が低下し、 $I_{c3} = 0.95$ の場合 $\epsilon = 0.414$ 付近、 $I_{c3} = 0.9$ の場合 $\epsilon = 0.364$ 付近で系が振動しなくなる。図 3 に $I_{c3} = 0.9, \epsilon = 0.3$ の場合の各ノードの振動挙動を示す。図 3 より、 I_{c3} の減少に伴う周波数の低下は、 I_{c3} の減少により結合が弱くなり、ノード 2 の振動がノード 3 に伝わりづらくなり、ノード 3 の状態遷移時間が増加したためであると考えられる。すなわち、パラメータが変化することにより、各ノードの振動が同一ではなくなる。以上のことから、 ϵ_2 がその他の外部入力 ϵ_1, ϵ_3 と異なる場合、ノード 2 と 3 の見かけの結合係数が変化し、自励周波数が変化する事が考えられる。この様に、自励周波数のパラメータ依存性は、RC の校正モードとして故障検出に使える可能性があり、再学習実行への指標となることが期待できる。




図 2: 外部入力に対する自励周波数変化 ($I_{c3} = 1, 0.95, 0.9$).




図 3: 振動挙動 ($I_{c3} = 0.9, \epsilon = 0.3$)

4. おわりに

単方向結合双安定系からなる RC において、系の自励振動の周波数が変化する事を用いて、校正モードを実現できる可能性があることを示した。

今後は、単方向結合双安定系からなる RC 内において RC の状態変化の検出について検討したい。

参考文献

- [1] 田中剛平, 電子情報通信学会, **102** (2), 108–113 (2019).
- [2] G. Tanaka *et al.*, *Natural Networks*, **115**, pp.100–123 (2019).
- [3] Visarath In *et al.*, *J. Appl. Phys.*, **107**, 014506 (2010).

結合非線形振動子の過渡特性の吸引領域に基づく検討

A Study on Transient Dynamics of The Coupled Nonlinear Oscillators Based on Basin of Attraction

馬場達也¹

引原隆士¹

Tatsuya Baba

Takashi Hikihara

京都大学大学院 工学研究科 電気工学専攻¹

Department of Electrical Engineering, Kyoto University

1 はじめに

リザーブコンピューティング (RC) は、結合振動子の物理現象を利用することで、高速、省電力な情報処理の実現が期待される [1]。RC は入力信号に対する過渡応答を利用して情報処理を行うことから、結合振動子の処理能力について動力的な観点からの解明が不可欠である。力学系の過渡特性の評価には、吸引領域を用いた定性的な解析が用いられる。しかし、この方法は高次元系において適用が難しい。これに対して、高次元系においても適用可能な過渡特性の解析手法として、アトラクタ遠方における吸引領域の分布特性を用いる方法が提案されている [2]。

本報告では、アトラクタ近傍の吸引領域特性に基づいた過渡特性の定量化を行い、非線形振動子の分岐特性に関連づけて結合振動子の解の振る舞いを考察する。

2 吸引領域に基づく過渡特性の定量化

固定点で表される単純なアトラクタを複数持つ離散時間力学系を対象とする。あるアトラクタ A に対して、 A を中心とした半径 r の球面 S_r 上の点が、そのアトラクタの吸引領域 $\rho(A)$ に含まれる確率を $P(r)$ とする。 r の増加に伴い、 S_r は他のアトラクタの吸引領域を含むようになり、 $P(r)$ は 1 から減少する。

ここで、 $P(r) = 0.9$ となる最小の r を r_{basin} とする。アトラクタから r_{basin} 以上離れた点を出発点とする解は吸引領域境界の影響を受けやすくなり、他のアトラクタへの遷移が生じる摂動の大きさの指標となる。以下、数値計算はモンテカルロ法により $P(r)$ を近似して実行した。

3 Duffing 振動子の過渡特性の解析

2 重井戸ポテンシャルを持つ減衰強制 Duffing 振動子

$$\ddot{x} + \delta \dot{x} - x + x^3 = F \sin \omega t \quad (1)$$

に関して解析を行う。ここで、 x は変位、 δ は減衰係数、 F で結合された近傍の振動子からの励振を受けた振幅、また ω は励振周波数を表す。 $(\delta, \omega) = (0.15, 1.2)$ とする。式 (1) は周期 $2\pi/\omega$ のストロブ写像によって離散時間力学系として評価できる。

F が近傍の振動子からの摂動を受けることを前提とし、まず F に対する 1 パラメータ分岐特性を図 1 に示す。 $F = 0.196, 0.212$ でサドルノード分岐が生じ、ヒステリシス特性が現れる。また、 $F = 0.196, 0.212, 0.215$ で周期倍分岐が生じ、周期倍分岐を繰り返してカオスに至る。

F に対する r_{basin} の変化を図 2 に示す。サドル・ノード分岐点の近くでは、もともと存在するアトラクタの r_{basin} 近傍に新しいアトラクタが生じる場合に r_{basin} が大きく減少する。周期倍分岐点では、分岐点に近づくにつれて r_{basin} は大きく減少し、新たに生じるアトラクタの r_{basin} もサドル・ノード分岐によって生じたアトラクタより小さい値となる。この結果、 F の摂動によって動作点が r_{basin} を飛び越えて、別のアトラクタへ近づく確率が高くなる。

4 おわりに

アトラクタ近傍の吸引領域特性に基づく過渡特性の評価によって、非線形振動子の分岐特性から結合振動子の解の振る舞いについて検討した。分岐点近傍の吸引領域の変化によって、結合振動子での状態遷移が発生しうることを示した。今後、結合振動子でアトラクタ間の遷移が発生する条件と、確定的な解に収束する条件についてさらに検討を進め、RC の理解を進めたい。




図 1: 1 Parameter Bifurcation Diagram.




図 2: Result of r_{basin} Characteristics against F .

参考文献

- [1] 犬伏正信, 吉村和之, 電子情報通信学会誌, Vol.102 (No.2), pp.114–120 (2019).
- [2] J. C. Sprott and A. Xiong, Chaos, **25** (8), 083101 (2015).

リザーバーコンピューティングにおける 時間発展のばらつきの定量化に関する考察

A Study on Quantification of Deviation in Time Evolution of Reservoir Computing

矢野 正大[†]
Tadahiro Yano

引原 隆士^{††}
Takashi Hikihara

京都大学 工学部 電気電子工学科[†]
Undergraduate School of Electrical and Electronic Engineering, Kyoto University

京都大学大学院 工学研究科 電気工学専攻^{††}
Department of Electrical Engineering, Kyoto University

1. はじめに リザーバーコンピューティング (RC) は、時系列情報処理に適した機械学習の一つである [1]. RC モデルは入力部, リザーバー部, 出力部から構成される. 入力情報はリザーバー部により非線形変換され, 高次元の特徴空間に写像される. 出力はリザーバー部の動的状態の線形結合で与えられる. 目標値と同じ出力が得られるように, この結合係数のみを簡単なアルゴリズムを用いて学習する [2]. 近年, リザーバー部のハードウェア化が検討されているが, 一般に RC に適した力学構造は未だ明らかではない [2]. 以上の観点から, 学習を達成した RC のリザーバー部が持つ力学的特徴を明らかにすることにより, リザーバー部の構成決定に示唆を得ようとするものである. 本報告では, RC においてリザーバー部が示す力学的特徴を求める手法を検討する. まず状態のばらつきを定量化する手順を示し, 次にその手法を適用した結果を考察する.

2. リザーバー状態のばらつきの定量化 リザーバー状態のばらつきを評価するため, 時系列の埋め込み次元を求める手法を適用する [3].

- RC から取り出されたリザーバー部の状態 $\{x_i(k)\}_{i=1}^N$ より k ステップ, $k+1$ ステップにおける仮想ノードの状態変数 $\{x_i(k)\}_{i=1}^N$, $\{x_i(k+1)\}_{i=1}^N$ を得る. ただし, $k = 1, 2, \dots, K_2$ とする.
- i_0 番目のノード $x_{i_0}(k)$ と最も値の近いノードを $\{x_i(k)\}_{i=1}^N$ から K 個取り出し, $x(k) = (x_{i_0}(k), x_{i_1}(k), \dots, x_{i_K}(k))$ とする.
- それぞれのノードについて $k+1$ ステップにおける値 $x(k+1) = (x_{i_0}(k+1), x_{i_1}(k+1), \dots, x_{i_K}(k+1))$ との差をとり, $v(k) = x(k+1) - x(k)$ を求める.
- $v(k) = (v_{i_0}(k), v_{i_1}(k), \dots, v_{i_K}(k))$ について分散を求める. すなわち, $E_{i_0}(k) = \frac{1}{K+1} \sum_{j=0}^K \|v_{i_j}(k) - \hat{v}(k)\|^2$ を求める. ただし, $\hat{v}(k) = \frac{1}{K+1} \sum_{j=0}^K v_{i_j}(k)$ とする.
- $i_0 = 1, 2, \dots, N$ について同様に分散を求め, その平均値をとる. すなわち, $E(k) = \frac{1}{N} \sum_{i_0=1}^N E_{i_0}(k)$ は, k から $k+1$ ステップ間におけるノードの時間発展に関するばらつきを表す. 以降並進誤差と呼ぶ.
- $k = 1, 2, \dots, K_2$ について同様に $E(k)$ を求め, 各ステップ間における並進誤差 $\{E(k)\}_{k=1}^{K_2}$ を得る.
- シミュレーション結果と考察 2節の手法において, 各パラメータは $K = 4, N = 40, k = 50, 51, \dots, K_2, K_2 = 300$ とする. また, 今回 RC には入力データとして $s = 0.005 - 0.008$ の範囲で生成したホワイトノイズを与える. 図 1 に, 入力の値に応じた並進誤差の推移を示す. 横軸に各ステップ間の入力の差の絶対値, 縦軸に並進誤差を取っている. この相関係数は 0.41 であった. この値は, 入力値の変動とリザーバー部の変動の間に相関があることを意味する. 高い計算性能を示す他のリザーバー

部において同様に並進誤差と入力の間を調べることで, リザーバー部に要求される挙動の特徴が抽出できる. 次に, 並進誤差と学習精度の関係を調べる. 図 2 に $\|d(k) - y(k)\|$, $\|d(k+1) - y(k+1)\|$ を並進誤差に対して描いたものを示す. 図より $\|d(k+1) - y(k+1)\|$ が大きくなる状態, $\|d(k+1) - y(k+1)\| \geq 0.003$ となる状態は, 並進誤差が 0.01 以上となる領域では観測されない. これは並進誤差が 0.01 以上となる領域においてリザーバー部の計算性能が高いことを示す. RC が有効に機能した他のリザーバー部について並進誤差と計算性能に因果関係を求めることにより, リザーバー部を設計する際の指標が得られる可能性がある.

4. おわりに 本報告では, リザーバー状態の時間発展から学習のばらつきに関する力学的特性を定量化する手法を検討した. その結果, 入力データの挙動と, リザーバー部の挙動の間に正の相関が観測された. また, 並進誤差がある程度大きな領域において高い計算性能が保たれていたことから, 並進誤差はリザーバー部を評価する指標となる可能性がある.

参考文献

- [1] 田中剛平ほか, リザーバーコンピューティング, (森北出版株式会社, 2021). [2] 田中剛平, リザーバーコンピューティングの概念と最近の動向, 電子情報通信学会誌, 102(2), 108-113(2019). [3] 宮野尚弥ほか, 時系列解析入門, (株式会社 サイエンス社, 2020).




図 1 入力と並進誤差の関係




図 2 並進誤差と NRMSE の関係

離散単語認識におけるカオスニューラルネットワーク リザーバーのパラメータの影響

Effects of Network Parameters of Chaotic Neural Network Reservoir on Discrete Word Recognition

辻 孟¹ 堀尾 喜彦¹
Takeru Tsuji Yoshihiko Horio

東北大学 電気通信研究所¹
Research Institute of Electrical Communication, Tohoku University

1 まえがき

カオスニューラルネットワークリザーバー(CNNR)[1-3]の時系列予測タスクによる性能やダイナミクスの評価は行われているが[4], 時系列分類や認識に対する詳細な評価は行われていない. そこで本稿では, その第一歩として, 離散単語認識における CNNR のパラメータの影響を詳細に評価する.

2 カオスニューラルネットワークリザーバー

CNNR のリザーバー層内の i 番目のカオスニューロン[5]は以下で与えられる.

$$x_i(t+1) = kx_i(t) + \sum_{i=1}^M W_{il}^{\text{in}} u_l(t+1) + \sum_{j=1}^N W_{ij} f(x_j(t)) - \alpha f(x_i(t)) + \theta, \quad (1)$$

$$y_i(t+1) = f(x_i(t+1)), \quad (2)$$

$$f(x) = \frac{1}{1 + \exp(-x/\epsilon)}. \quad (3)$$

ここで, $x_i(t), y_i(t)$ は, それぞれ, 時刻 t での内部状態と出力, W_{il}^{in} は l 番目の入力 $u_l(t)$ からの結合重み, W_{ij} は内部結合重み, k, α は不応性のパラメータ, M は外部入力数, N はリザーバー層内ニューロン数, θ は外部バイアス, $f(\cdot)$ は出力関数, ϵ はゲインパラメータである. 以下, $k = 0, \alpha = 0$ の時の場合を GNNR と呼ぶこととする.

3 シミュレーション実験

文献[3]に従い, 0 から 9 の雑音無し音声の 12 チャンネル分のメル周波数ケプストラム係数を入力 $u_l(t)$ ($t = 1, 2, \dots, 1839$ (最初の 100 steps は過渡状態期間))として, 離散単語認識のシミュレーションを行う. この際, $\theta = 0, M = 12$, 出力層ニューロン数 $P = 10$ とし, $W_{ij}, W_{il}^{\text{in}}$ の結合率は 20%, それらの値と各ニューロンの初期値は, $[-1, 1]$ のランダム値とする. 以下では, N, k, α, ϵ の値を変化させ, それらの影響を総合的に評価する. ここで, N の値は, 10 から 90 まで 10 刻み, 100 から 500 までは 100 刻みで, k の値は 0 から 0.9 までを 0.1 刻みで変化させ, 最大値を 0.99 とする. また, α については, 値を 0 から 0.09 まで 0.01 刻み, 0.1 から 1 までは 0.1 刻みで, ϵ の値は, 0.01 から 0.09 までを 0.01 刻みで, 0.1 から 0.9 までを 0.1 刻みで, 1 から 2 の間を 0.2 刻みで変化させる. なおスペクトル半径 ρ は, $\rho = 3.98\epsilon$ となるように調整する. 出力結合重み W_{pi}^{out} ($p = 1, 2, \dots, 10$)は, 各単語に対して 1 つのニューロンが対応するように線形回帰で, バッチ学習する.

図 1 に CNNR と GNNR の N に対する正答率の, $x_i(0)$

を 30 回変えた時の平均値の最大値を示す. 図 2 は, k, α, ϵ の 1 つを変化させた時の $N = 100$ の CNNR の正答率を示す. ここで, $k = 0.99, \alpha = 0.3, \epsilon = 1.2$ の時に最大の正答率が得られたため, パラメータを 1 つずつ変化させる際には, ほかのパラメータは上記の値に固定した.




図 1: N に対する正答率の平均値の最大値の変化




図 2: k, α, ϵ に対する CNNR ($N = 100$)の正答率の変化

図 1 より, CNNR は小規模でも高い認識性能を示すことが分かる. 一方, 図 2 より, k が大きくなるにつれて正答率は向上するが, α と ϵ は, 認識性能に大きな影響を与えないことが分かる.

4 おわりに

CNNR の離散単語認識性能とパラメータの関係を評価した. 今後は, 他の時系列分類・認識タスクにおける k の影響とそのからくりを明らかにする.

本研究は JSPS 科研費 20H00596, 21K18303 及び東北大学電気通信研究所共同研究プロジェクトの助成を受けた.

参考文献

- [1] T. Tassy, Y. Horio, 信学総大, N-1-2, 2018
- [2] Y. Horio, *IJCNN*, vol.18, no.4, pp. 17-22, 2019.
- [3] 井上理哲人 他, 信学技報., NLP2019-103, pp.95-98, 2020
- [4] K. Fukuda, et al. *NOLTA, IEICE*, vol.12, no.4, pp.639-661, 2021
- [5] K. Aihara, *Phys. Lett. A*, vol.144, no.6-7, pp.333-340, 1990

Dropout と Batch Normalization の効果の検証

Examining the Effects of Dropout and Batch Normalization

代 美月¹
Mizuki Dai

神野 健哉¹
Kenya Jin'no

東京都市大学 情報工学部 知能情報工学科¹
Department of Intelligent System, Faculty of Information Technology, Tokyo City University

1 まえがき

ニューラルネットワーク (NN) の学習を効果的に行うことを目的として、過剰適合を抑制する Dropout[1](Drop)、内部の共変量シフトを抑制させ学習効率を高める Batch Normalization [2](BN) が提案されている。本稿では CNN を対象として、Drop と BN の効果の検証を試みた。


2 Dropout と Batch Normalization

一般的な NN の目的関数は非凸関数であるため、無数の局所解が存在する。これら局所解が過剰適合の原因である。NN の学習では目的関数の微分値情報に基づいた勾配法で学習が行われるためこのような局所解に囚われやすく、局所解から脱出することは困難である。このような問題を解決するために提案された手法が Drop[1] である。Drop は学習時に確率的にパラメータを間引くという非常に簡素な手法であるが、その効果は非常に大きく過剰適合を抑制する効果が大きい一方、学習時間が長くなるという問題がある。

学習効率を向上させる手法として BN が提案 [2] されている。訓練データと予測データの入力の分布に偏りがあると学習が上手くいかないことが多いため一般的に入力データは平均 0、分散 1 に標準化されることが多い。しかしながら近年の NN のように非常に深く多層化された場合、その内部の各層において入力の偏りが生じうる。このため各層毎の入力の分布を白色化させることで学習の効率化を目指した方法が BN である。BN を使用することで L2 正則化や Drop などの必要性が減少する [2] とされており、Drop の利用を削減することで学習の高速化が望める。本稿ではこれら Drop と BN の効果について CIFAR-10[3] を対象とし図 1 の CNN を用いた。この基本構造に Drop は Activation の前に、BN は Conv2D


```
input = Input(shape=(32,32,3))
x = Conv2D(64, kernel_size=(3, 3), padding='same')(input)
x = Activation('relu')(x)
x = Conv2D(128, kernel_size=(3, 3), padding='same')(x)
x = MaxPooling2D(pool_size=(2,2))(x)
x = Activation('relu')(x)
x = Conv2D(256, kernel_size=(3, 3), padding='same')(x)
x = MaxPooling2D(pool_size=(2,2))(x)
x = Activation('relu')(x)
x = Conv2D(512, kernel_size=(3, 3), padding='same')(x)
x = MaxPooling2D(pool_size=(2,2))(x)
x = Activation('relu')(x)
x = Conv2D(1024, kernel_size=(3, 3), padding='same')(x)
x = MaxPooling2D(pool_size=(2,2))(x)
x = Activation('relu')(x)
x = GlobalAveragePooling2D()(x)
x = Dense(class_num, activation='softmax')(x)
```

図 1 Baseline CNN の構造




val_acc:78.94%
(a) baseline

val_acc:82.93%
(b) BN のみ



val_acc:85.57%
(c) Drop のみ



val_acc:88.74%
(d) BN + Drop

図 2 CIFAR-10 での精度の変化

の前に配置しこれらの有無での分類性能を検討する。実験結果を図 2 に示す。一般的に BN を用いれば Drop は不要と言われるが、双方を効果的に使用することで CNN のみで 88.57% の認識率が得られた。

3 まとめ

Drop と BN の効果を CIFAR-10 で検討した。今後はより効果的な学習法について検討を行う。

謝辞

本研究の一部は JSPS 科研費 JP19K12163, JP20K11978 の助成、および東北大学電気通信研究所共同プロジェクト研究によるものです

参考文献

- [1] N. Srivastava, G. Hinton, A. Krizhevsky, I. Sutskever, R. Salakhutdinov, "Dropout: A Simple Way to Prevent Neural Networks from Overfitting," Journal of Machine Learning Research, vol. 15, no. 1, pp. 1929 - 1958, 2014.
- [2] S. Ioffe, C. Szegedy, "Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift," Proc. ICML 2015, PMLR, vol. 37, pp. 448-456, 2015. <https://arxiv.org/abs/1502.03167>
- [3] <https://www.cs.toronto.edu/~kriz/cifar.html>

Auto Encoderによる顔の向き変換

Transformation of Face Direction with Auto Encoder

岡本紗季¹
Saki Okamoto

神野健哉¹
Kenya Jin'no

東京都市大学 知識工学部 知能情報工学科¹
Department of Intelligent Systems, Faculty of Knowledge Engineering, Tokyo City University

1 まえがき

ニューラルネットによる顔画像の加齢予測を目指していたが、顔の向きによりばらつきが生じる問題が発生した。これを解決するため顔の向きの変換を試みる。顔の向きを変換させる手法には、敵対的生成ネットワーク (GAN) による方法が提案されている [1]。本研究では GAN よりも単純な手法を用いて顔の向きを変換させ、生成画像の精度向上を目指す。

2 Auto Encoder(AE)[2]

画像変換を行う手法として、AEに着目した。AEには畳み込みニューラルネットワーク (CNN) の構造を持たせる。CNNは画像の特徴を抽出することができる。このCNN構造を有したAEは画像に含まれる特徴量を抽出し、潜在変数空間内に特徴ごとのクラスターが形成される。図1にモデルを示す。




図1 Auto Encoder(AE)

3 実験

AEで顔の向きを変化させられるかどうかを確認するために実験を行う。実験では図1のように入力画像をCNNで縮小させながら特徴を抽出する通常のAEで実験を行った。さらに図2のように各段階の特徴を加算させる Contracting Path (Concat) を導入した場合、そして内部の共変量シフトを抑制させられる Batch Normalization (Batch) を導入した場合について実験を行った。




図2 Contracting Pathを含んだAE

学習データとして80枚、テストデータとして20枚用意し、横向きの顔を入力すると、正面の顔が出力されるように学習をさせる。表1に実験結果の出力の平均二乗

誤差 (MSE)、処理時間、パラメータ数を示す。

表1 AEによる変換結果

手法	MSE(学習)	MSE(テスト)	処理時間 [sec]	パラメータ数
AE	0.00334	0.047	55.83	1,386,434
AE+Concat	0.00034	0.017	55.79	2,078,658
AE+Concat+Batch	0.00021	0.015	91.96	2,082,502

表1に示すように、AEにConcatとBatchを取り入れた際に高い精度が得られた。これは各解像度での特徴量を保存できるConcatが有効に働き、重みがBatchで正規化されたことによると考えられる。

次にシステムのパラメータ数を削減させる実験を行う。パラメータ数を削減させるために一般的な畳み込みであるConv2Dを簡略化したSeparableConv2Dを導入する。SeparableConv2Dは通常の畳み込みでのパラメータをチャンネルごとに一樣にすることでパラメータ数の削減が実現できる。この結果を表2に示す。

表2 AEのパラメータ数と性能

畳み込み	MSE(学習)	MSE(テスト)	処理時間 [sec]	パラメータ数
Conv2D	0.00021	0.015	91.96	2,082,502
SeparableConv2D	0.00025	0.017	80.27	1,440,758

表2の結果が示すようにSeparableConv2Dを使用した場合、パラメータが簡略されたためMSEはテスト時でも0.002しか上昇しなかったが、パラメータ数は約30%削減し、処理時間も約13%短縮した。

4 まとめ

AEで抽出した少ない特徴で、横向きの顔を正面に向きを変換した。ConcatとBatchを取り入れることで、精度が向上することを確認した。さらにパラメータを削減しても性能がほとんど低下しないことも確認した。今後は、特徴点を抽出することで様々な種類の顔画像の向きを変換することを目指す。

謝辞

本研究の一部は JSPS 科研費 JP19K12163, JP20K11978 の助成、および 東北大学 電気通信研究所 共同プロジェクト研究によるものです。

参考文献

- [1] Ting-Chun Wang, Arun Mallya, Ming-Yu Liu, "One-Shot Free-View Neural Talking-Head Synthesis for Video Conferencing", Proc. CVPR2021, arXiv:2011.15126, 2021.
- [2] G.E. Hinton, R. Salakhutdinov, "Reducing the dimensionality of data with neural networks", Science, vol. 313, pp. 504-507, 2006.

新たなクラスター評価基準を用いたデータのラベル推定

Estimating Data Label Using The New Cluster Evaluation Criterion

元木 竜平¹
Ryuhei Motoki

神野 健哉²
Kenya Jin'no

東京都市大学知識工学部情報通信工学科¹

Department of Information and Communication Engineering, Faculty of Knowledge Engineering, Tokyo City University

東京都市大学情報工学部知能情報工学科²

Department of Intelligent System, Faculty of Information Technology, Tokyo City University

1 まえがき

教師あり学習では入力データに所望ラベルを付与しなければならない。また、精度の高い出力をするためには大量のデータが必要になる。本研究では少ないラベル付きデータのみで、ラベルなしデータのラベル推定を行う手法を提案する。

2 提案手法

すべてのデータは positive か negative のいずれかに分類できるとし、入力データは一部の positive データのみにラベルが付与されており、残りのデータのラベルは不明である場合を考える。図 1 に入力データの例を示す。赤円はラベル付き positive データ、グレーの円はラベルなしデータである。ラベルなしデータのラベルを推定するため、まず、ラベルなしデータをすべて negative データと仮定し、SVM で分離超平面を求める。このとき、positive クラスに重み付けし、ラベル付き positive データが誤分類されないようにする。図 2 に SVM で得られた分離超平面によるラベル付け結果を示す。赤円と青円がそれぞれ positive, negative の予測結果である。次に、分離超平面に最も近い negative と予測したデータを positive に置き換えて分離超平面を再び求める。これを繰り返し、SVM の分離超平面を移動させる。




図 1 入力データ




図 2 分離超平面例

各分離超平面の分類結果を修正フィッシャー評価基準で評価する。これはフィッシャー評価基準 [1] を式 (1) の RBF カーネルを用いて拡張したもので、式 (2) で算出される。

$$\phi(x, y) = \exp(-\gamma \|x - y\|^2), \gamma = \frac{1}{2\sigma^2} \quad (1)$$

$$F = \frac{\frac{1}{n_P^2} \sum_{x_i \in P} \sum_{x_j \in P} \phi(x_i, x_j)}{\frac{1}{n_P \times n_N} \sum_{x \in P} \sum_{y \in N} \phi(x, y)} + \frac{\frac{1}{n_N^2} \sum_{y_i \in N} \sum_{y_j \in N} \phi(y_i, y_j)}{\frac{1}{n_P \times n_N} \sum_{x \in P} \sum_{y \in N} \phi(x, y)} \quad (2)$$

x, y はデータ, P, N は positive, negative クラス, n_P, n_N は positive, negative と予測したデータ数をそれぞれ表している。この修正フィッシャー評価基準値が最大になったときの分類結果を採用する。

3 実験

いくつかのデータセットで、PNU classification [2] と性能比較を行った。訓練データには 10 個のラベル付きデータと 300 個のラベルなしデータが含まれ、特徴量は 0 から 1 で正規化し、50 回試行した。それぞれの手法での分類精度を表 1 に示す。「Spambase」以外では提案手法の分類精度が高かった。

表 1 それぞれの手法を用いた各データセットに対する 50 回の平均の分類精度

データセット	提案手法	PNU classification
Banana		
d=2	71.0	69.9
Phoneme		
d=5	69.8	67.5
Magic		
d=10	74.8	68.3
Spambase		
d=57	65.7	72.8

4 まとめ

少数かつ単一のラベル付きデータのみでデータのラベル推定を行う修正フィッシャー評価基準を提案した。実験から提案手法が PNU classification よりも一部のデータセットにおいて有効であることを確認した。今後は提案手法をより多様なデータに適用させることが課題である。

謝辞

本研究の一部は JSPS 科研費 JP19K12163, JP20K11978 の助成、および東北大学電気通信研究所共同プロジェクト研究によるものです。

参考文献

- [1] Tharwat Alaa, Gaber Tarek, Ibrahim, Abdelhameed, and Hassanien Aboul Ella, "Linear discriminant analysis: A detailed tutorial," AI Communications, vol. 30, pp. 169-190, 2017. DOI: 10.3233/AIC-170729
- [2] Tomoya Sakai, Marthinus Christoffel du Plessis, Gang Niu, and Masashi Sugiyama, "Semi-supervised classification based on classification from positive and unlabeled data," Proc. ICML2017, vol. 70, pp. 2998-3006, 2017.

Proposal of the GAN with a convex learner

Hirotsada Honda¹

Faculty of Information and Networking for Innovation and Design, Toyo university

1 Introduction

This study proposes a method of the GAN that is realized with a convex learner.

2 Terms and notations

Hereinafter, the notation \mathcal{M}_1 denotes a set of probability measures on \mathbb{R}^p , and $\mathcal{G}_n \subset \mathcal{M}_1$ denotes a set of probability measures realized by a convex learner with n parameters (e.g., convex neural network [2]). In the following, $C(X)$ denotes a set of contiguous functionals in a Banach space X . For a convex function $f(x)$, its conjugate function is defined by

$$f^*(y) = \sup_{x \in \mathbb{R}^p} \langle x, y \rangle - f(x).$$

3 Formulation

Although we have many variants of the GAN to date, we herein focus on the original setup of the GAN by Goodfellow et al. [1], which is often referred to as the *min-max GAN*. In the min-max GAN, the objective function can be represented as follows:

$$\min_G \max_D E_{\vec{x} \sim p_{data}} [\log(D(\vec{x}))] + E_{\vec{z} \sim p_z} [\log(1 - \log(D(G(\vec{z})))]. \quad (1)$$

Indices G and D in (1) represent the generator and discriminator, respectively; p_{data} denotes the probability density of the dataset; p_z is the measure of the latent variable; and \vec{z} is the draw of the latent variable. The notation $E_{\vec{x} \sim p_{data}}$ indicates the expectation with respect to \vec{x} drawn from the distribution of the dataset, and $E_{\vec{z} \sim p_z}$ is the expectation concerning latent variable \vec{z} . The definition of JS-divergence is expressed as follows:

$$D_{JS}(\mu \parallel \nu) \equiv \frac{1}{2} \left[D_{KL} \left(\mu \parallel \frac{\mu + \nu}{2} \right) + D_{KL} \left(\nu \parallel \frac{\mu + \nu}{2} \right) \right].$$

Now, its Fenchel-Rockafeller duality [3] reads

$$D_{JS}(\mu \parallel \nu) = \sup_{\phi \in Lip} E_{\mu} [\phi(x)] + \int_{\{x | e^{\phi(x)} < 2\}} [\log(2 - e^{\phi(x)})] d\nu(x).$$

4 Proposed method

Our formulation here reads as follows.

$$\begin{aligned} & \min_G D_{JS}(\mu_G \parallel \mu_0), \\ & \text{s.t. } \mu_G \in \mathcal{G}_n. \end{aligned} \quad (2)$$

By introducing notations $\hat{\mu}_0$ that denotes the empirical distribution of the dataset and

$$H(\mu) \equiv \begin{cases} D_{JS}(\mu \parallel \hat{\mu}_0) & (\mu \in \mathcal{G}_n), \\ +\infty & (\mu \notin \mathcal{G}_n), \end{cases}$$

problem (2) can be equivalently represented as

$$\min_{\mu \in \mathcal{G}_n} H(\mu). \quad (3)$$

We also consider the corresponding dual problem [4]:

$$\sup_{p \in C(\mathbb{R}^p)} [-H^*(p)] = \beta. \quad (4)$$

Then, we shall construct the sequences of solutions $\{\mu_n\}_n \subset \mathcal{M}_1$ and $\{p_n\}_n \subset C(\mathbb{R}^p)$ to (3) and (4), respectively.

For problem (3), we apply the gradient projection method with the learner prescribed. Note that \mathcal{G}_n is considered as convex for any $n \in \mathbb{N}$. Thus, a measure $\{\mu_n\}_n \subset \mathcal{G}_n$ that attains $H(\mu_n) = \beta$, i.e., $D_{JS}(\mu_n \parallel \mu_0) = \beta$. For problem (4), we construct a solution sequence $\{p_n\}_n \subset C(\mathbb{R}^p)$ by the gradient projection method as well. As $H(\mu)$ is convex with respect to μ , we can observe that $H^*(p)$ is convex with respect to p . Now, we obtain the error estimate of the objective function of problem (3).

5 Main result

Theorem 1. *Let $\bar{\mu} \in \mathcal{M}_1$ be the optimal solution to problem (3). Then, with a certain positive constant γ , we have*

$$\gamma^{-1} c \|u_n - \bar{u}\| \leq H(u_n) + H^*(p_n). \quad (5)$$

Note that the right-hand side of (5) tends to 0 as $n \rightarrow \infty$.

参考文献

- [1] Goodfellow, I., et al., Generative Adversarial Nets, Proc. NeurIPS 2014(2014).
- [2] Bengio, Y. et al., Convex neural networks, Proc. NeurIPS 2005 (2005), 123–130.
- [3] Rockafeller, R. T., Convex analysis, Princeton University Press, Princeton .
- [4] Zeidler, E., Nonlinear Functional Analysis and its Applications III, Springer-Verlag, New York.

カオス時系列予測に対する カオスニューラルネットワークリザーバーの性能調査

An analysis of the chaotic neural network reservoir for estimating chaotic time series

齋東龍也
Tatsuya Saito

藤田実沙
Misa Fujita

中京大学工学部 電気電子工学科
Department of Electrical and Electronic Engineering, School of Engineering, Chukyo University

1 まえがき

ニューラルネットワークを用いて時系列を学習する方法の一つにリカレントニューラルネットワーク (RNN) が存在する。RNN は内部のニューロンにおいて、現在の時刻の情報だけでなく、過去の時刻の情報も用いる。しかし、学習が複雑である、時間がかかるなどの問題が存在する。この問題を解決する方法として、リザーバーコンピューティング (RC) [1] が存在する。RC は図 1 のような構造をしており、全ての結合重みを学習させるのではなく、リザーバー層と出力層をつなぐ結合重みのみを学習させる。これにより、学習の実装が容易になる、学習時間を短縮できるなどのメリットが生まれる。また、その応用であるカオスニューラルネットワークリザーバー (CNNR) が既に提案されている [2]。

本稿では、カオス時系列予測タスクにおける通常の RC と CNNR の性能を比較し、どちらが本タスクに適しているか調査する。




図 1 リザーバーコンピューティングの例

2 カオスニューラルネットワークリザーバー (CNNR)

CNNR は図 1 におけるリザーバー層のニューロンのモデルがカオスニューロンモデル [3] であるものを指す。最初に入力層とリザーバー層の結合重み W_{in} 、リザーバー層内の結合重み W_{res} 、リザーバー層と出力層の結合重み W_{out} をランダムに設定する。その後、 W_{in} と W_{res} を固定し、 W_{out} は勾配降下法や線形回帰などの簡単なアルゴリズムで学習を行う。また、リザーバー層内の結合はスパースとする。リザーバー層の更新式は式 (1)、(2) で与えられる。

$$z(t+1) = W_{in}u(t+1) + W_{res}x(t) + kz(t) - \alpha x(t) + \theta \quad (1)$$

$$x(t+1) = f(z(t+1)) \quad (2)$$

また、出力層の更新式は式 (3) で与えられる。

$$y(t+1) = g(W_{out}x(t+1)) \quad (3)$$

ここで、 t は時刻、 z と x はリザーバー層のニューロンの内部状態と出力、 u は外部入力、 y は出力、 k は減衰係数、 α は正のパラメータ、 θ はバイアス、 f と g は活性化関数である。

3 実験

CNNR によるカオス時系列予測の性能を評価するために、平均を除去し、絶対値の最大値が 1 程度になるよう事前に前処理を行ったローレンツ方程式の時系列を用いた。実験は通常の RC と CNNR で比較を行った。また、性能評価に二乗平均平方根誤差 (RMSE) を用いた。どちらもリザーバー層のニューロン数は 500、 W_{in} 、 W_{res} 、 W_{out} の初期値は $[-1:1]$ の一様乱数で設定、結合はランダム、教師データの長さは 10000 とし 50 step 分の予測を行った。通常の RC では $k = 0, \alpha = 0, \theta = -0.40, f(x) = \tanh(x), g(x) = x$ 、CNNR では $k = 0.9, \alpha = 0.2, \theta = -0.10, f(x) = 1/(1 + \exp(-x/0.01)), g(x) = x$ とした。結果を表 1 に示す。

表 1 RC と CNNR の性能比較

	RC	CNNR
RMSE	0.1598	0.0988

4 結論

RC と CNNR のカオス時系列における性能を評価するためにローレンツ方程式を用いて時系列予測を行った。RC より CNNR の方が RMSE が小さく性能が良いという結果が得られた。理由の一つにハイパーパラメータが RC より多く細かく設定できるからだと考えられる。

本研究は JSPS 科研費 JP20K23332 の助成を受けたものである。また、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 (R02/A31) による。

参考文献

- [1] 田中剛平, 中根了昌, 廣瀬明, “リザーバーコンピューティング,” 森北出版, 2021.
- [2] 福田佳祐ら, 信学技報, NLP2019-102, pp. 89-94, 2019.
- [3] K. Aihara et. al., Phis. Lett. A, 144(6-7): 333-340, 1990.

周期入力に対する Izhikevich ニューロンモデルの応答 —Fast Spiking ニューロンの場合—

Responses of the Izhikevich Neuron Model to Periodic Inputs

—In Case of Fast Spiking Neurons—

塚本陽太¹

Yota Tsukamoto

對馬帆南²

Honami Tsushima

池口徹^{1,2}

Tohru Ikeguchi

東京理科大学 工学部¹

Faculty of Engineering, Tokyo University of Science

東京理科大学 大学院工学研究科²

Graduate School of Engineering, Tokyo University of Science

1 はじめに

我々は既に、Izhikevich ニューロンモデルが Regular Spiking を呈する際の正弦波入力に対する応答を調査している [1, 2]。その結果、周期応答と準周期応答が発生することを報告した。我々の脳には、興奮性ニューロンと抑制性ニューロンが存在する。抑制性ニューロンは、Izhikevich ニューロンモデルの Fast Spiking (FS) ニューロンとして再現可能である。そこで本稿では、抑制性ニューロンの一つである FS ニューロンの周期入力に対する応答を調査したので報告する。

2 数値実験

本稿では、Izhikevich ニューロンモデル [3] のパラメータを FS ($a = 0.1, b = 0.2, c = -65, d = 2$) に設定する。数値計算にはオイラー法 (時間ステップ 0.01) を用いて、発火時刻を線形内挿により推定した [4]。また、周期入力を正弦波 $I(t) = I_{DC} + I_{AC} = I_{DC} + A \sin(2\pi/T)t$ とする。 $I_{DC} = 10$ とし、 I_{AC} の振幅 A 、周期 T を変化させた際の、Izhikevich ニューロンモデルの応答を定量的に調査した。評価には、ISI (Interspike Interval) に対する多様度指数 $R = m/n$ [5, 6] を用いた。ただし、ISI の総数を n 、ISI の種類数を m とする。周期応答 ($n \gg m$) の場合、 $R \approx 0$ となる。また、非周期応答 ($n \approx m$) の場合、 $R \approx 1$ となる。本稿では、ISI を小数第 10 位までの精度とした。時刻 $0 \leq t < 5,000$ を過渡状態として排除し、 $5,000 \leq t \leq 15,000$ の発火時系列から多様度指数を計算した。正弦波の振幅を $0 \leq A \leq 10$ 、周期を $1 \leq T \leq 1,000$ の範囲で変化させ、多様度指数を調べた結果を図 1 に示す。図 1 の横軸と縦軸は正弦波の周期 T と振幅 A 、カラーバーは多様度指数の値である。周期応答の領域と非周期応答の領域は、 T が大きくなるにつれて $A = 6$ 付近に収束していることが分かる。

次に、非周期応答となる場合について、ストロボ観測点を用いて調査した。図 1 で $A = 2.5$ 、 $T = 200$ と設定した場合 ($R = 1$) のストロボ観測点を図 2 に示す。横軸と縦軸は Izhikevich ニューロンモデルの膜電位 v と回復変数 u である。図 2 より、曲線が出現することが分かる。即ち、アトラクタはトーラスであり、応答は準周期的である。本来、アトラクタがトーラスの場合は、閉曲線がプロットされるが、Izhikevich ニューロンモデルは瞬時リセットを含むため、閉曲線とならない。




図 1: Izhikevich ニューロンモデル (FS) の多様度指数 R の結果




図 2: 非周期応答 ($A = 2.5$, $T = 200$) の場合のストロボ観測点

3 まとめ

本稿では、Izhikevich ニューロンモデルが FS ニューロンとなる場合の正弦波入力に対する応答を調査した。多様度指数を用いた調査により、周期応答と非周期応答の存在を確認した。また、ストロボ観測点を用いた解析により、非周期応答が準周期応答であることが分かった。なお、本研究の一部は、JSPS 科研費 JP20H000596, JP21H03514 の助成を受けた。

参考文献

- [1] Tsukamoto et al., *NLSW2021*, NLSW-54, 2021.
- [2] Tsukamoto et al., submitted to *NOLTA, IEICE*, 2021.
- [3] Izhikevich, *IEEE TNN*, 14(6), 1569–1572, 2003.
- [4] Izhikevich, *Phil. Trans. R. Soc. A*, 368(1930), 5061–5070, 2010.
- [5] 杉浦 他, 信学技報, 113(116), 43–48, 2013.
- [6] 内木 他, 信学論 A, J100-A(5), 195–204, 2017.

サブグラフ中心性を用いたネットワークのリンク予測法の検討

A Method of Link Prediction in Temporal Networks Using Subgraph Centrality

滝田 蒼馬¹
Soma Takita

島田 裕²
Yutaka Shimada

埼玉大学 工学部 情報システム工学科¹

埼玉大学大学院 理工学研究科²

1 はじめに

人間同士のコミュニケーションは、時間変化する人と人の関係を一定時間ごとにグラフで表したテンポラルネットワークで表現することができる。ある時刻までに観測されたテンポラルネットワークに対して将来発生する頂点間の辺を予測する問題はリンク予測問題と呼ばれ、様々な研究が行われている。文献 [1] では、辺の発生頻度、コミュニティ構造、固有ベクトル中心性 (以下、EC と呼ぶ) というネットワークの構造的特徴を組み合わせることで、高い精度で辺の出現を予測する手法が提案されている。

本稿では、EC とは異なる観点からネットワーク中の頂点の中心性を測るサブグラフ中心性 (以下、SC と呼ぶ) [2] を EC の代わりに用いることで予測精度が向上するかどうかを調べた結果を報告する。

2 リンク予測手法

単位時間ごとに観測された人と人の対面関係を、人を頂点、2 頂点間の対面関係を辺とするネットワークで表現する。ある時刻 t でのネットワークを $\Gamma^{(t)}$ ($t = 1, 2, \dots, N_t$) とする。ただし、 N_t は観測終了時刻である。文献 [1] の手法では、開始時刻を t_0 、幅を T とする時間窓を考え、この時間窓内のネットワーク $\Gamma^{(t_0)}, \Gamma^{(t_0+1)}, \dots, \Gamma^{(t_0+T-1)}$ を用いて頂点 i, j 間の辺の発生しやすさを表す量 $S_{i,j}^{(t_0)}$ を $S_{i,j}^{(t_0)} = F_{i,j}^{(t_0)} + \beta C_{i,j}^{(t_0)} + E_{i,j}^{(t_0)}$ によって求める。ここで、 $F_{i,j}^{(t_0)}$ は時間窓 $[t_0, t_0 + T - 1]$ における頂点 i, j 間の辺の発生頻度によって決まる値、 $C_{i,j}^{(t_0)}$ はコミュニティ構造によって決まる値、 $E_{i,j}^{(t_0)}$ は EC によって決まる値、 β ($0 < \beta < 1$) はパラメータである。 $C_{i,j}^{(t_0)}$ は頂点 i, j が同一コミュニティに属する場合 $\rho (> 1)$ 、そうでない場合 1 である。また、時刻 t での頂点 i の EC を $e_i^{(t)}$ としたとき、 $E_{i,j}^{(t_0)} = \sum_{t=t_0}^{t_0+T-1} \gamma^{(t_0+T-1)-t} [e_i^{(t)} + e_j^{(t)}]$ ($0 < \gamma < 1$) である。提案法では、EC の代わりに SC [2] を用いて頂点 i, j 間の辺の発生しやすさを $\tilde{S}_{i,j}^{(t_0)} = F_{i,j}^{(t_0)} + \beta C_{i,j}^{(t_0)} + G_{i,j}^{(t_0)}$ によって求める。ここで、 $G_{i,j}^{(t_0)} = \sum_{t=t_0}^{t_0+T-1} \delta^{(t_0+T-1)-t} [\log s_i^{(t)} + \log s_j^{(t)}]$ ($0 < \delta < 1$) であり、 δ はパラメータ、 $s_i^{(t)}$ は時刻 t での頂点 i の SC を表す。予測精度は文献 [1] と同様に求める。具体的には、予測対象のネットワークから辺が存在する頂点对 (i, j) と存在しない頂点对 (i', j') の組を無作為に選び、 $\tilde{S}_{i,j}^{(t_0)} > \tilde{S}_{i',j'}^{(t_0)}$ となる回数 μ_{gr} および $\tilde{S}_{i,j}^{(t_0)} = \tilde{S}_{i',j'}^{(t_0)}$ となる回数 μ_{eq} を求める。これを用いて予測精

度を $A_{t_0} = (\mu_{gr} + 0.5\mu_{eq})/R$ によって求める。ただし、 R は (i, j) と (i', j') の組の総数である。実験では $t_0 = 1, 2, \dots, N_t - T + 1 - \tau_{\max}$ に対して時間窓 $[t_0, t_0 + T - 1]$ ごとに $\tilde{S}_{i,j}^{(t_0)}$ を求め、 τ 時刻後のネットワーク $\Gamma^{(t_0+T-1+\tau)}$ 中の辺の予測精度の平均 \bar{A} を求めた。ここで、 τ の最大値 τ_{\max} を 5 とした。




図 1. 提案法と従来法の予測精度の比

3 結果

SC を用いた提案法の予測精度 \bar{A}_p と文献 [1] の従来法の予測精度 \bar{A}_c の比 (\bar{A}_p/\bar{A}_c) を求めた結果を図 1 に示す。実験では、博物館来場者の対面記録データ [3] を単位時間 L 秒ごとに区切りテンポラルネットワークへと変換した。その際、 $L = 60, 300, 600, 1800$ とした。

図 1 から、 $L = 60$ の場合に 2% から 5% 程度精度が向上したことがわかる。また、 $L = 1800$ のとき、 $\tau = 1 \sim 3$ において提案法の予測精度が 10% から 15% 程度高いことがわかる。

4 まとめ

本稿では、SC を用いたリンク予測手法を提案し、その性能を従来法と比較した。その結果、SC を用いることで予測精度が向上することを確認した。今後は、提案法におけるパラメータの設定法についても検討する予定である。

本研究は JSPS 科研費 18K18125, 21K12093, JP21H03508 の助成を受けたものである。

参考文献

- [1] N. Ibrahim, L. Chen, *Appl. Intell.*, **42**, 738–750 (2015)
- [2] E. Estrada, *et al.*, *Phys. Rev. E*, **71**, 056103 (2005)
- [3] L. Isella, *et al.*, *J. Theor. Biol.*, **271**, 166–180 (2011)

興奮性シナプス後電位のロングテール性による リキッドステートマシンへの性能の影響

Ability of Liquid State Machines with long-tailed excitatory postsynaptic potentials

松元唯吹¹
Ibuki Matsumoto

信川創¹
Sou Nobukawa

千葉工業大学 情報工学科¹
Department of Computer Science, Chiba Institute of Technology

1 はじめに

Liquid State Machine(LSM)は、実際の脳の特徴を踏まえたリザバコンピュティングモデルで、スパイクニューラルネットワークを用いてモデル実装されることが多い [1]。研究では LSM の性能向上を目指して、特徴量の増加やシミュレーション時間の延長、リッジ回帰の正則化パラメータの変更を行ってきた。脳の情報伝達は複数のニューロンがスパイクを介することによって行われ、最近の研究では、興奮性シナプス後電位 (EPSP) の分布はロングテール性を持つことが知られている。その分布のうち、シナプス結合強度が強いものは、スモールワールドネットワーク、一方、弱いものはランダムネットワークを構成する。この EPSP の二重性は多様な時間スケールのダイナミクスを生み出し LSM の性能向上が期待できる [2]。よって、本研究ではこのシナプス荷重の二重性に着目し、スモールワールド性の違いによる時系列予測の精度の評価を行った。

2 手法

本研究で使用したスパイクニューラルネットワークの LIF モデルは次式で定義する。

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

$$\text{if } v \geq V_{thr} \text{ mV, then } v(t) \rightarrow V_r \quad (2)$$

(1) 式の τ_m は膜時定数、 V_L は漏れ電流、 V_E は興奮性シナプス電流、 V_I は抑制性シナプス電流、 I_{ex} は入力電流であり、(2) 式の V_{thr} はしきい値、 V_r はリセット値である。また、本研究では、Watts and Strogatz(1998)によって提案された方法に従ってスモールワールドネットワークを構築した。平均次数が $2K$ である N 個のノードでリング状格子を作成する。各ノードはいずれも K 個の最近傍ノードに結合している。そして、グラフ内の各エッジについて確率 β でノードを再結合する。

抑制性ニューロン 2000 個、興奮性ニューロン 10000 個用意し、興奮性ニューロンはさらに 50 個の興奮性ニューロン集団に分ける。(1) 式の入力項 I_{ex} にカオス時系列である (3) 式の MackeyGlass 方程式を使用する。

$$\frac{dx}{dt} = \frac{0.2x(t-32)}{1+x(t-32)^{10}} - 0.1x(t) \quad (3)$$

前シナプス神経細胞がスパイクを起こしたときの後シナプス神経細胞の膜電位を興奮性シナプス後電位 (EPSP) という。実際の脳の EPSP は 1mV 以下と極めて小さいが、EPSP 全体の分布をみると 10mV 程度まで右に裾をひいたロングテール分布になっている。多数の EPSP はランダムネットワークを、少数の 10mV 程度の EPSP

はスモールワールドネットワークを構成している。この二重のシナプス結合が存在するネットワークにおいて、ニューロン同士の再結合確率 β を $0.2, 0.4, 0.6, 0.8, 1.0$ にしたときの発火率を 1s のシミュレーションによって出力する。カオス時系列の入力がスモールワールド性とランダム性をもつ二重のネットワークに与えられたときのニューロン集団の発火率を LSM の特徴量とし、リッジ回帰によって学習を行う。訓練データに対する予測の精度の評価は NRMSE(normalized root-mean-square error) を使って求めた。

3 結果

表 1 に LIF モデルに入力した実際のデータと学習後の訓練データに対する予測を比較し NRMSE を求めた結果を示す。

表 1 β を変化させたときの NRMSE の計算結果

β	0.2	0.4	0.6	0.8	1.0
NRMSE	0.3173	0.4144	0.4055	0.8055	1.1380

表 1 に示すように β の値が大きくなる、すなわちランダムネットワークに近づくにつれて予測精度が下がった。また、NRMSE の結果より、今回構築した LSM は訓練データに対しては当てはまりの良い予測を行うことができた。

4 おわりに

本研究では、EPSP のロングテール性と二重性を利用したリキッドステートマシンによる時系列予測の評価を行った。その結果、情報伝達がスパイクを介して行われ、かつ、スモールワールドネットワーク性が強いほど予測精度が良かった。シナプス結合がスモールワールドネットワークに近づくると特異なスパイクパターンが生じ複雑性が向上することが今回の結果に表れたと考えられる [2]。また、一部の予測精度が不十分であったため、さらに精度を上げることが今後の課題である。スモールワールド性の違いによる訓練データに対する予測精度を調べることができたので、未知のデータに対する予測精度向上を目指して研究を進めたい。

参考文献

- [1] Tatsuro Sakaguchi and Naoki Wakamiya. Consideration on liquid structure contributing to discrimination capability of liquid state machine. *Nonlinear Theory and Its Applications, IEICE*, Vol. 11, No. 1, pp. 36–59, 2020.
- [2] Sou Nobukawa, Haruhiko Nishimura, and Teruya Yamanishi. Temporal-specific complexity of spiking patterns in spontaneous activity induced by a dual complex network structure. *Scientific reports*, Vol. 9, No. 1, pp. 1–12, 2019.

概日リズムを反映した脳波の機能的結合の評価

Evaluation of Functional Connectivity of EEG Reflecting Circadian Rhythms

安田義熙¹
Yoshiki Yasuda

飯沼佑太¹
Yuta Iinuma

信川創¹
Sou Nobukawa

西村治彦²
Haruhiko Nishimura

千葉工業大学 情報工学科¹
Department of Computer Science, Chiba Institute of Technology
兵庫県立大学 情報科学研究科²
Graduate School of Applied Informatics, University of Hyogo

1 はじめに

近年の研究から、概日リズムの乱れは健康状態や精神状態に問題を引き起こすことが知られている。したがって、概日リズムの乱れの程度を推定することは医学的にも病状の理解をするにあたって重要である。そこで、概日リズムを反映した脳波より、その複雑性をフラクタル解析や Multi-Scale Entropy などを用いて分析する取り組みがある [1, 2]。局所的な脳活動の複雑性は、様々な領野間の大域的な神経相互作用が反映される。そのため、部位特異的な神経相互作用の特定が困難である。そこで本研究では、個々の領野間神経相互作用が反映される機能的結合の分析を試みる。機能的結合では、領野間の神経相互作用に伴う同期に着目するため、昼と夜でどの領野間の同期度に差異が生まれるのかを推定することが出来る。実験方法としては、脳波を 8 箇所から測定し、位相同期指標の一つであり空間分解能の高い Phase Lag Index (PLI) を用いることで、被験者の昼と夜における脳波の特徴を抽出し、分析を行う。

2 手法

2.1 対象

脳波の測定は、千葉工業大学情報工学科にて、Medical Computer Systems 社製の 8ch ワイヤレス脳波アンプ「NB1-EEG8」を使用して行った。被験者は健康な若い男性 9 名 (20~22 歳) であり、計測開始前に全員からインフォームドコンセントを取得した。本実験は、千葉工業大学の倫理委員会の承認を得て実施した。

2.2 脳波

測定箇所は、拡張国際 10-20 法に準拠する電極配置より 8 電極 (F3, F4, C3, C4, P3, P4, Po3, Po4) にて測定した。計測時の被験者は安静閉眼として、13:00 と 19:00 において測定を行った。サンプリング周波数は 121.37Hz とした。各被験者から測定した脳波データから 60 秒分取り出し 2-30Hz のバンドパスフィルタをかけた。PLI では、与えるデータ長が長くなると値が小さくなり、データ長が短いと周波数成分の遅い変化を捉えることができない。これらのトレードオフから、PLI の算出にあたって、epoch 長を 5 秒とした。また着目する周波数帯域は、 δ 帯域 (2-4Hz)、 θ 帯域 (4-8Hz)、 α 帯域 (8-13Hz)、 β 帯域 (13-30Hz) とする。

2.3 Phase Lag Index

PLI とは、2 つの電極から測定された脳波より、各周波数帯域ごとの時系列データの位相差分布の非対称性から機能的結合を推定する位相同期指標である。

3 結果

測定した脳波より算出した各帯域での昼と夜における 3 試行の PLI 値をそれぞれ平均化し、対標本 t 検定を用いて比較した (図 1 を参照)。暖色は昼の PLI 値が高

く、寒色は夜の PLI 値が低いことが示されている。図 1 では、 θ 帯域の C3-Po3 と C4-P4、 β 帯域の F3-P3 と P4-Po4 の電極ペアで昼のほうが PLI 値が高く、 δ 帯域の C3-Po4 と C4-P4、 θ 帯域の C4-P3 の電極ペアでは夜のほうが PLI 値が低い様子が確認できる ($p < 0.05$)。

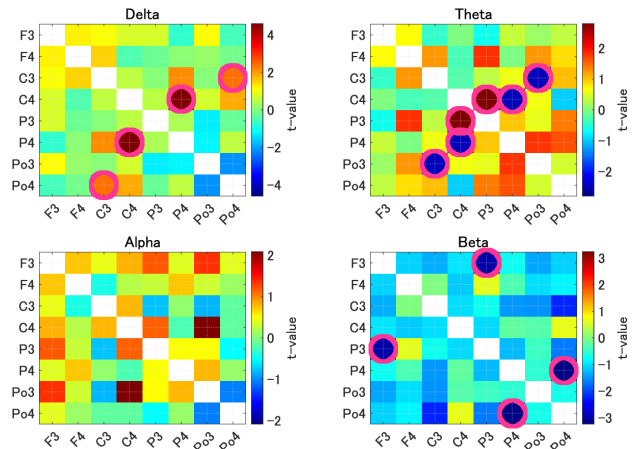


図 1 δ 帯域、 θ 帯域、 α 帯域、 β 帯域における昼と夜の PLI 間の対標本 t 値。マゼンダ色の丸で囲われている箇所は算出された t 値に対応する p 値が $p < 0.05$ である電極ペアを示している。

4 おわりに

本研究では、概日リズムを反映した脳波の機能的結合の分析を、測定した脳波より各周波数帯で PLI を算出することで行った。その結果、 δ 帯域、 θ 帯域においては、機能的結合が昼に増加し、夜に減少していることが見られた。 β 帯域においては、機能的結合が夜に増加し、昼に減少していることが見られた。今後は、Weighted PLI や他の解析を用いてより詳細な解析を行い、概日リズムを反映した脳波について分析を進める。また、実際に概日リズムに乱れを起こしている被験者の脳波を測定し、健常者との比較を行う予定である。

謝辞

本研究は JSPS 研究費 基盤研究 (C)(20K11976:H.N.) と公益財団法人 柏森情報科学振興財団 研究助成 (K32-571:S.N.) の助成を受けた。

参考文献

- [1] Pierpaolo Croce, et al. Circadian rhythms in fractal features of EEG signals. *Frontiers in Physiology*, Vol. 9, p. 1567, 2018.
- [2] Yuta Iinuma, et al. Estimation of circadian rhythms using complexity analysis with temporal scale dependency in electroencephalogram signals. In *Proceedings of 2021 IEEE 20th ICCI* CC*.

ネットワークモチーフによる力学系の時系列分類法の一検討

An evaluation of time series classification method in dynamical systems with network motifs

川口雅斗, 加藤秀行

Masato Kawaguchi and Hideyuki Kato

大分大学 理工学部

Faculty of Science and Technology, Oita University

1 まえがき

近年, 複雑ネットワーク理論の観点から力学系の解を解析する手法がいくつか提案されている. その一つが Xu らによって提案されたものである. この手法は力学系が示す様々な解を分類できる可能性が示唆されている. この手法は非対称リカレンスプロットを用いるが変換後のネットワーク解析では無向ネットワークとして解析を行っているため, 解の幾何学的構造を正確にとらえられていない可能性を孕んでいる. そこで, 本研究では, 対称なりカレンスプロット作成手法を導入することを提案し, これにより力学系の解分類が可能かを検討したのでその結果を報告する.

2 解析手法と実験条件

本研究では, Xu らの手法 [1] と同様に力学系のアトラクタから重みなし無向ネットワークを作成し, このネットワークをグラフ理論におけるネットワークモチーフを用いて力学系の解分類を行う. Xu らの手法では, ネットワーク作成において, リカレンスプロットを作成する. このリカレンスプロットには, いくつかの作成手法があるが, Xu らが用いた手法によるリカレンスプロットは非対称となり, 後のネットワーク解析において対称化が必要となるため, アトラクタの幾何学的構造を正確にとらえられていない可能性がある.

一方で, 対称なりカレンスプロットを作成する手法として, 適当な閾値 θ を定め, アトラクタ上の 2 点間距離 $D(i, j)$ が $D(i, j) < \theta$ となる場合, 第 (i, j) 画素を黒色にする手法がある [2]. この手法は対称なりカレンスプロットを作成可能であるが, 距離の閾値をパラメータとして与えるため, 黒色画素の数の制御が困難である. この黒色画素の数はネットワークにおける枝の数の本数に対応する. 枝の本数はネットワークにおける最も重要な統計量であるため, その本数を制御できることが望ましい.

そこで本研究では, 文献 [3] の手法を導入することを提案する. この手法では黒色にする画素の数 k をパラメータとして与え, 全ての $D(i, j)$ の値が小さな順に k 個の画素を黒くする. そのため, 力学系の種類に関わらず黒色画素数, すなわちネットワークの枝数を指定することができ, 対称化を必要としない. このようにして得られたネットワークにおける 4 ノードネットワークモチーフ (図 1) の出現数を調べ, 出現頻度順に並べることで解の分類を行う. 本実験では, 100 個の異なる初期値から得られたデータに対し上述の手法を適用し, 得られたモチーフの出現数の平均値を各モチーフ出現数とし, 各力学系の解に対して, 出現頻度の順番を調査した. 以降これを Motif Rank Profile




図 1: 4 ノードネットワークモチーフ

表 1: モチーフ出現順一覧

系と解	MRP	系と解	MRP	系と解	MRP
レスラー 2 周期	ABCF	レスラー カオス ($c = 9.0$)	ABCFDE	$\sin(3t/25)$ +WGN(0dB)	ADBCEF
レスラー 3 周期	ABCF	レスラー カオス ($c = 18.0$)	ABCFDE	$\sin(3t/25)$ +WGN(10dB)	ADBCEF
レスラー 6 周期	ABCF	ローレンツ カオス	ABCFDE	$\sin(3t/25)$ +WGN(20dB)	ADBCEF
レスラー 8 周期	ABCF	マッケイ・グラス カオス	ABCFDE	$\sin(3t/25)$ +WGN(30dB)	ADBCEF

(MRP) と呼ぶ. 検証に用いた力学系とその解の種類, 結果を表 1 に示す.

3 結果

図 1 より, 周期解の場合, MRP は ABCF となり, D, E は出現しないことがわかる. カオス解の場合, 力学系の種類によらず MRP は ABCFDE となった. さらに, 正弦波にノイズを加えたものの場合, MRP はノイズ強度によらず ADBCEF となることが確認された. 以上により, 本手法においてこれら 3 種類の力学系の解を分類可能であることが示された.

4 まとめ

本報告では, Xu らの手法 [1] に文献 [3] のリカレンスプロット作成手法を適用し, 3 種類の力学系の解についての有効性を検証し, その有効性を確認した. 今後は非自律系や離散力学系においても有効であるかを検証する予定である.

本研究の一部は, JSPS 科研費 JP20H00596, JP21H03514, JP21K2050, JP21H05163 の助成を受けたものである.

参考文献

- [1] X Xu et al. *PNAS*, **105(50)**:19601 2000.
- [2] 合原 一幸他. カオス時系列解析の基礎と応用. 産業図書, 2000.
- [3] J P. Zbilut et al. *Physics Letters A*, **297**:173 2002.
- [4] 増田 直紀, 今野 紀雄. 複雑ネットワーク基礎から応用まで. 近代科学社, 2010.

バイナリニューラルネットの2目的最適化について

On biobjective optimization of binary neural networks

阪 健人¹
Kento Saka

齋藤 利通¹
Toshimichi Saito

法政大学大学院 理工学研究科 電気電子工学専攻¹

Electrical and Electronics Department, Faculty of Science and Engineering, Hosei University

1 はじめに

バイナリニューラルネットに関する2つの目的関数を導入し、2目的最適化問題を考える。

2 本論

バイナリニューラルネット (BNN) の定義式を示す:

$$x_i(t+1) = \begin{cases} \operatorname{sgn}\left(\sum_{j=1}^N w_{ij}x_j(t)\right) & \text{for } t = nN + i \\ x_i(t) & \text{for } t \neq nN + i \end{cases}$$

$$\operatorname{sgn}(x) = \begin{cases} +1 & \text{if } x \geq 0 \\ -1 & \text{if } x < 0 \end{cases}$$

$$\text{ab. } \mathbf{x}^{n+1} = \mathbf{F}_D(\mathbf{x}^n), \mathbf{x}^n \equiv (x_1^n, \dots, x_N^n)^\top, x_i^n = x_i(nN) \quad (1)$$

ただし、 $x_i(t) \in \{-1, +1\}, i \in \{1, \dots, N\}$ は離散時刻 t における i 番目の2値状態変数である。非同期に時間発展し、 N 回毎に \mathbf{x}^n が更新される。相互結合パラメータ $w_{ij} (i \neq j)$ は3値 $\{-1, 0, +1\}$ とし、自己フィードバックパラメータ w_{ii} は整数とする。本稿では、 M 個の所望記憶を不動点として埋め込む:

$$\mathbf{s}^l \equiv (s_1^l, \dots, s_N^l)^\top, s_i^l \in \{-1, +1\}, l = 1 \sim M \quad (2)$$

以下の条件を満たすとき、所望記憶の銘記が保証される。

$$w_{ii} \geq \max_l \left(-\sum_{j \neq i} w_{ij} s_i^l s_j^l \right) + 1 \quad (3)$$

ここで、2つの目的関数を導入する。1つ目の目的関数は所望記憶の一樣安定性を評価し、2つ目の目的関数は相互結合のスパース性を評価する:

$$F_1(\mathbf{W}) = 1 - \frac{\min_l (N_D(l))}{(2^N)/(2M) \text{ 以下の最大の整数}} \quad (4)$$

$$N_D(l) = l \text{ 番目の所望記憶に落ち込む初期値数}$$

$$F_2(\mathbf{W}) = 1 - \frac{w_{ij} = 0 \text{ の数 } (i \neq j)}{N^2 - N}$$

これらを用いて、2目的最適化問題を定義する:

$$\begin{aligned} &\text{Minimize } \mathbf{F}(\mathbf{W}) = (F_1, F_2) \in S_O, \text{ subject to } \mathbf{W} \in S_p \\ &S_O \equiv \{(F_1, F_2) | 0 \leq F_1 \leq 1, 0 \leq F_2 \leq 1\} \\ &S_p \equiv \{\mathbf{W} | w_{ij} \in \{-1, 0, +1\}, i \neq j, w_{ii} \in \text{integers}\} \end{aligned} \quad (5)$$

ただし、 S_O は目的関数空間、 S_p はパラメータ空間である。例題として以下の所望記憶の銘記を考える。

$$\begin{aligned} \mathbf{s}^1 &= (-1, -1, -1, -1, -1, -1, -1, -1) = -\mathbf{s}^6 \\ \mathbf{s}^2 &= (-1, -1, -1, -1, +1, +1, +1, -1) = -\mathbf{s}^7 \\ \mathbf{s}^3 &= (-1, -1, -1, +1, +1, +1, +1, +1) = -\mathbf{s}^8 \\ \mathbf{s}^4 &= (-1, -1, +1, +1, +1, -1, -1, -1) = -\mathbf{s}^9 \\ \mathbf{s}^5 &= (-1, +1, +1, +1, +1, +1, -1, -1) = -\mathbf{s}^{10} \end{aligned} \quad (6)$$

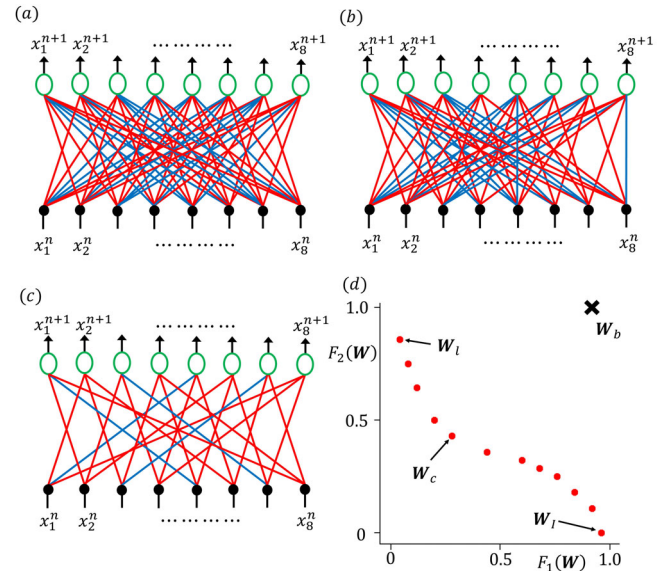


図1 BNNと2目的最適化の結果。(a) \mathbf{W}_b , (b) \mathbf{W}_l , (c) \mathbf{W}_c . 赤線は $w_{ij} = +1$, 青線は $w_{ij} = -1$, 無結合は $w_{ij} = 0$. (d) 目的関数空間. 赤点は2目的問題の解.

相関学習に基づく方法 [1] で得られた結合行列 \mathbf{W}_b のネットワークを図1(a)に示す。 $F_1(\mathbf{W}_b) = 1 - \frac{2}{25}, F_2(\mathbf{W}_b) = 1 - \frac{0}{56}$ となる。次にスパース化によって得られた \mathbf{W}_l を図1(b)に示す。 $F_1(\mathbf{W}_l) = \frac{1}{25}, F_2(\mathbf{W}_l) = \frac{48}{56}$ である。 \mathbf{W}_l をさらにスパース化して得られた \mathbf{W}_c を図1(c)に示す。 $F_1(\mathbf{W}_c) = \frac{7}{25}, F_2(\mathbf{W}_c) = \frac{24}{56}$ となる。そして、 \mathbf{W}_b を限界までスパース化すると単位行列 $\mathbf{W}_I (F_1(\mathbf{W}_I) = \frac{24}{25}, F_2(\mathbf{W}_I) = \frac{0}{56})$ が得られる。本稿では、 $w_{ij} = w_{ji}$ を満たす全てのネットワークについて評価し、2目的最適化を行った [2]。その結果を図1(d)に示す。 \mathbf{W}_b から相互結合のスパース性を増加させると、所望記憶の一樣安定性は増加した。そこからさらにスパース性を増加させるとスパース性と安定性はトレードオフの関係となった。

3 むすび

BNNにおいて、所望記憶の一樣安定性と相互結合のスパース性に関する2目的最適化を行った。リカレントニューラルネットの多目的学習への発展などが課題である。

参考文献

- [1] T. Saito, T. Togawa, Proc. IEEE/SMC (2021) 2419.
- [2] 阪, 齋藤, 信学技報, CCS2021-20.

基礎セルオートマトンに基づく音楽合成に向けて

Toward music synthesis based on elementary cellular automata

小島 航¹
Wataru Kojima

齋藤 利通¹
Toshimichi Saito

法政大学 理工学部 電気電子工学科¹
Electrical and Electronics Department, Faculty of Science and Engineering, Hosei University

1 はじめに

音楽合成への応用を目指して、基本セルオートマトンから簡素な音楽を作成する。

2 本論

基本オートマトン (ECA, [1]) は時間、状態、空間が離散的な力学系であり、単純なルールに従って様々な時空間パターンを呈する。工学的応用として、音声データ記述、画像処理、音楽生成 [2] [3] などが挙げられる。本稿では、Wolfram Tones[2] を参考とした音楽合成への基礎固めを行う。まず、ECA は以下のように定義される。

$$x_i^{t+1} = F(x_{i-1}^t, x_i^t, x_{i+1}^t) \quad (1)$$

ここで、 $x_i^t \in \{0, 1\}$, $i \in \{1, \dots, N\}$. x_i^t は離散時刻 t , 空間位置 i の 2 値状態変数である。本稿では、リング結合を用いるので、 $x_0^t = x_N^t$, $x_{N+1}^t = x_1^t$ とする。また、 F は 3 入力 1 出力のブール関数である。この 8 つの出力の 10 進数表示をルール番号 (RN) とする。

周期 T で同じパターンを繰り返す周期解を用いて、音楽生成を行う。出力 1 (黒色セル) に対応した音程をメロディーと定義し、セル数 $N = 12$ とする。1 オクターブ分の音程を表現するために、各セル間の音程を半音とし、各音程の位置は固定とする。リズムは 4/4 拍子で 4 小節分のメロディーを生成する。1 つのセルを 4 分音符の長さとし、 $1 \leq t \leq 16$ である。また、スケールはメジャー、ナチュラルマイナーの 24 種から選択する。

メロディー生成アルゴリズムは以下のように定義される。ここで度数とは、ある音程がスケールにおいて何番目に位置するかを示すものである。

Step. 1: ルールを変化させて、周期 $T = 16$ に近い周期解を探索する。中心に近く、選択したスケールに対応した音をメロディーの初期値 $t = 1$ とする。

Step. 2: t が偶数で現在と次の音程が同一である場合、次のセルまで音を伸ばす (シンコペーション)。この処理は 1 小節につき一度だけ行う。

Step. 3: 選択したスケールに対応する三和音コードを検索し、一度、三度、五度の優先順位でメロディーを生成する。ただし同一音は除く。コード構成音が重複する場合、中心に近く、より距離の近いメロディーを生成する。該当コードが無い場合、最も近い黒セルの音を生成する。

Step. 4: それが小節の最初のメロディーであれば、それをルート音とした三和音コードを生成する。

Step. 5: $t \rightarrow t+1$ とし、Step. 2 に戻り、4 小節分のメロディーが生成されるまで繰り返す。

以下に生成されたメロディーの典型例を示す。時空間パターンの上には、時間軸に対応するように楽譜を記した。図 1 に例 (a) を示す。これは、2 小節以降の全ての小節の始まりにシンコペーションが生じたパターンである。図 2 に、例 (b) を示す。これは、小節の始まりと小節の途中でシンコペーションが生じたパターンである。




図 1 メロディー例 (a) (RN=125, F メジャー)




図 2 メロディー例 (b) (RN=137, G シャープマイナー)

3 むすび

本稿では、ECA の周期軌道を簡素なメロディーに変換するアルゴリズムを定義した。また、典型的な例を示し、表現的な尺度から分類を行った。今後の課題として、より多様な音楽の生成と、その定量的評価が挙げられる。

参考文献

- [1] S. Wolfram, Reviews of Modern Physics (1983) 601.
- [2] <https://tones.wolfram.com>
- [3] 小島航, 齋藤利通, 信学技報 CCS2021-18.

PSO による多層ニューラルネットワークの学習

Training Multilayer Neural Networks with PSO

高頭 陸¹
Riku Takatou

神野 健哉²
Kenya Jin'no

東京都市大学 知識工学部 情報通信工学科¹

Department of Information and Communication Engineering, Faculty of Knowledge Engineering, Tokyo City University

東京都市大学 情報工学部 知能情報工学科²

Department of Intelligent System, Faculty of Information Technology, Tokyo City University

1 まえがき

本稿では粒子群最適化法 (PSO) [1] による多層ニューラルネットワーク (MNN) のパラメータの学習を試みる。

2 背景

MNN のパラメータの学習は一般的に目的関数の微分値に基づく勾配法に基づいた方法で学習が行われる。MNN の目的関数は非凸関数であり、無数の局所解、プラトー、鞍点が存在するため目的関数の最適解に勾配法で到達することは困難である。しかしながら局所解は最適解近傍に存在していることが示唆 [2] されており、また MNN が十分大量なニューロンで構成される場合には確率的勾配降下法で最適解に収束できることも報告 [3] されている。これらの結果から大量のニューロンで構成されたシステムでは勾配法に基づく学習が成功することが示唆されているため、近年の MNN では深層化し、構成するニューロン数が増加している。一方、ニューロン数の増加に伴い、必要とするメモリ量は増加し、これに伴い学習時間の増加なども発生している。

一方、少ないニューロン数で MNN による優れた認識機能等を実現することはエッジコンピューティングなどの観点からは非常に重要である。そこで少ないニューロン数においても目的関数の最適解に収束させるため、目的関数の微分値情報を必要としない PSO [1] で MNN のパラメータの学習を試みる。

3 PSO による学習

PSO は目的関数の最適値を与えるパラメータを複数の粒子が互いに情報をやりとりしながらパラメータ空間内を探索するアルゴリズム [1] であり、目的関数の微分値を必要としないメタヒューリスティック解法の一つである。この PSO を用いて MNN のパラメータの学習を行う。線形分離不可能な 2 次元のデータの 2 クラス分類 1) ExOR、2) circle、3) moons の 3 種で実験を行なった。データの座標をニューロンの入力層に与え、出力層は 2 クラスを one-hot 表現で表す。中間層のニューロン数を変化させる。中間層は relu 関数、出力層は softmax 関数を用いた。比較のため MNN を、2 値相互エントロピーを adam で最適化しパラメータを学習させた。PSO は正解精度を評価関数に用いた。図 1 は moons で中間層のニューロン数が 3 個の場合の精度の変化である。PSO は粒子数を 4 個とした。少数の中間層では PSO は MNN の学習より高い精度を得られた。しかし PSO は粒子が




図 1 精度の更新毎の変化

収束しているため精度が改善しなくなっており改善が必要である。

4 まとめ

少ないニューロンで構成した MNN のパラメータの学習を PSO で行なった。中間層数を増加させ、多クラス分類にした場合に関して今後考える。

謝辞

本研究の一部は JSPS 科研費 JP19K12163, JP20K11978 の助成、および東北大学電気通信研究所共同プロジェクト研究によるものです

参考文献

- [1] J. Kennedy, R. Eberhart, "Particle Swarm Optimization". Proc. ICNN 1995, pp. 1942–1948, 1995. doi:10.1109/ICNN.1995.488968
- [2] A. Choromanska, M. Henaff, M. Mathieu, G. B. Arous, Y. LeCun, "The Loss Surfaces of Multilayer Networks," Proc. AISTATS 2015, pp. 192–204, 2015. <https://arxiv.org/abs/1412.0233>
- [3] Z. A-Zhu, Y. Li, Z. Song, "A Convergence Theory for Deep Learning via Over-Parameterization," Proc. ICML, PMLR vol. 97, pp. 242–252, 2019. <https://arxiv.org/abs/1811.03962>

確率的結合を有する確率的粒子群ネットワークの探索性能について

Search Performance of Stochastic Particle Swarm Optimization Networks with Stochastic Connection

小西俊行¹
Toshiyuki Konishi

中野秀洋¹
Hidehiro Nakano

東京都市大学大学院 総合理工学研究科 情報専攻¹
Division of Informatics, Graduate School of Integrative Science and Engineering, Tokyo City University

1 まえがき

本稿では Particle Swarm Optimization(PSO) アルゴリズム [1] の並列計算環境への実装を考慮し, PSO のネットワーク化による解の多様性の向上を目的とした PSON-SC (PSO Networks with Stochastic Connection)[2] と, 収束速度と計算効率を上げた SPSON (Stochastic PSO)[3] を組み合わせた SPSON-SC を提案する. 既存のアルゴリズムの解探索性能を維持しつつ, 回路規模及び, 計算量の削減を図れることを示す.

2 提案手法: SPSON Networks with Stochastic Connection; SPSON-SC

提案手法の SPSON-SC では, 母集団を複数のサブ SPSON に分割する. 各サブ SPSON は独立に解空間を探索し, サブ SPSON 間の最良解情報を保持するメモリ (g best 情報メモリ) と確率的に結合する. g 番目のサブ SPSON ($SPSON_g$) の i 番目の粒子は, 速度ベクトル v_{gi} , 位置ベクトル x_{gi} , 自身の探索過程の最良の位置ベクトル pb_{gi} を持ち, $SPSON_g$ は属する粒子群の探索過程における最良解ベクトル (Local best solution; lb_g) を持つ. また, g best 情報メモリはサブ SPSON 間における最良解ベクトル gb を保持する.

SPSON-SC には, lb_g を参照し, 独立して解空間の探索を行う局所探索モードと, g best 情報メモリと通信し, gb を参照する大域探索モードがある. 各サブ SPSON はイタレーション毎にあらかじめ設定した切り替え確率 (Switching Rate; SR) により, いずれかの探索モードで動作する. $SPSON_g$ における粒子 i の j 次元目の速度と位置の更新式を式 (1), 式 (2) に示す.

$$v_{gij}^{t+1} = \begin{cases} c_1 r_1 (pb_{gij}^t - x_{gij}^t) + c_2 r_2 (gb_j^t - x_{gij}^t) & \text{if } r_3 < SR \\ c_1 r_1 (pb_{gij}^t - x_{gij}^t) + c_2 r_2 (lb_j^t - x_{gij}^t) & \text{otherwise} \end{cases} \quad (1)$$

$$x_{gij}^{t+1} = x_{gij}^t + v_{gij}^{t+1} \quad (2)$$

ここで, c_1, c_2 は加速度係数, r_1, r_2, r_3 は $[0,1]$ の一様乱数を表す.

3 結果及び考察

PSON-SC と SPSON-SC の性能比較を行う. 実験の環境のパラメータを表 1 に示す.

表 1 実験環境

	PSON-SC	SPSON-SC
試行回数	100	
実行回数 (t_{max})	10000	
次元数 (D)	30	
総サブ PSO 数	9	
粒子数/サブ PSO	4	
ω	0.3, 0.5, 0.7, 0.9	-
c_1	0.4, 0.6, ..., 1.8	1.8, 1.9, ..., 2.3
c_2	0.4, 0.6, ..., 1.8	1.8, 1.9, ..., 2.3
SR	$\frac{1}{9}, \frac{1}{27}, \dots, \frac{1}{81}$	

ベンチマーク問題は CEC'13 を用い, F_1 (Sphere function) は単峰性問題, F_2 (Rastrigin function) は多峰性問題を表し, 最良評価値はいずれも 0 である.

各手法において良好な結果を示したパラメータにおける, 実行回数毎の探索の様子を図 1, 2 に示す. 図の横軸は実行回数, 縦軸は評価値である.




図 1 F_1 (PSON-SC: $\omega=0.5, c_1=c_2=1.6, SR=\frac{1}{9}$, SPSON-SC: $0.7, c_1=c_2=1.6, SR=\frac{1}{63}$, SPSON-SC: $c_1=c_2=1.9, SR=\frac{1}{9}$)

図 2 F_2 (PSON-SC: $\omega=0.7, c_1=c_2=2.0, SR=\frac{1}{27}$)

図 1 より, 単峰性問題では PSON-SC は最良値の発見が早く, SPSON-SC はその後収束している. 一方, 図 2 より, 多峰性の問題に対して, SPSON-SC は PSON-SC と比べて, 同等あるいは若干良い性能を示している.

4 むすび

本稿では SPSON を用いたネットワークに基づく, SPSON-SC を提案し, 基本的な探索性能を評価した. 今後の課題として, 並列計算ハードウェアへの実装と, 回路量, 計算量の比較実験, さらに, 他のメタヒューリスティクス手法との性能の比較検証などが挙げられる.

参考文献

- [1] J.Kennedy, et.al., Proc. ICNN, 1942-1948, 1995.
- [2] T. Sasaki, et. al., IEICE Trans. Fund., E100-A, 4, 996-1007, 2017.
- [3] H. Qi, et. al., Int. J. Therm. Sci., 46, 7, 649-661, 2007.

動的な繋がりを考慮したネットワークに対する 免疫配置手法の性能調査

Performance evaluation of an immunity placement method for dynamical connected social network

鈴木紗衣¹
Sae Suzuki

足立淳¹
Jun Adachi

木村貴幸²
Takayuki Kimura

日本工業大学大学院 工学研究科 電子情報メディア工学専攻¹
Graduate School of Electronics, Information and Media Engineering, Nippon Institute of Technology
日本工業大学 基幹工学部 電気電子通信工学科²
Department of Electrical, Electronics and Communication Engineering, Faculty of Fundamental Engineering,
Nippon Institute of Technology

1 まえがき

近年、新型コロナウイルスなどのウイルスが各国に拡散しており、これらのウイルスの拡散抑制が求められている。このため、ウイルスの拡散を防ぐ手法として種々の免疫配置手法が提案されている [1]。これらの中でランダムウォーク免疫配置手法 [2] は、接続状態の動的な変化を考慮しない静的なネットワークに対してのみ評価がなされていた [3]。そこで本稿では、動的な接続変化を考慮したネットワークに対して、ランダムウォーク免疫配置手法を適用した際の感染の抑制効果を調査した。

2 ネットワークモデル

本稿では静的ネットワークモデルとして BA モデル [4] と動的なネットワークとしてテンポラルネットワーク [5] を用いた。

3 免疫配置手法

感染拡大を抑制する方法として一定のノードに対し免疫を配置する免疫配置手法がある [1]。免疫を配置されたノードは、隣接ノードを介して感染することはなく感染症の拡大を抑制する。本稿では、ランダムウォーク免疫配置手法 [3] による感染拡散の抑制を試みる。手順を以下に示す。

1. ネットワーク上の免疫を有さないノードをランダムに 1 つ選択する。
2. 選択したノードと隣接ノードのうち、最も高い次数を有するノードを記憶する。
3. 選択したノードから隣接するノードへランダムウォークを R 回繰り返し、最も高い次数を有するノードを記憶する。
4. 記憶した中から最も高い次数を有するノードへ免疫を配置する。また、最も高い次数を有するノードが複数記憶されている場合、ランダムに免疫を配置するノードを決定する。
5. 指定した免疫配置割合まで手順 1 から 4 を繰り返す。手順 3 を除いた手法は改良知人免疫配置手法 (IAM)[1] と呼ばれる。

4 感染伝播モデル

本稿のモデルとしてまず、ネットワーク上のノードの中から 1 つをランダムに選択し、これを感染ノードとした。次に、感染したノードはエッジを介して隣接する感染のないノードへ一定の確率でウイルスを感染させた。全ての感染ノードが隣接ノードに感染処理を終えるまでを 1 日と定義し、360 日間これを繰り返した。また、新たに感染したノードは次の日から感染伝播を可能とした。感染から 4 日経過した感染ノードは未感染の状態へ戻した。


5 評価指標

このテンポラルネットワークに対する免疫配置手法の感染の抑制効果を調査するために、評価指標として感染密度 d [2] を採用した。感染密度 d は次式によって定義される (式 (1))。式 (1) において、 N はノード数、 n_{inf} は感染ノード数を表す。

$$d = n_{inf}/N, \quad (1)$$

6 数値実験

本実験では、BA モデル [4] とテンポラルネットワーク [5] に対してランダムウォーク免疫配置手法を適用した際の感染伝播モデルの影響を調査した。本実験では、BA モデルにおけるウイルスの感染確率を 50% とした。また、動的なデータを用いるためテンポラルネットワークでは最大接触回数で接触回数を正規化し感染率を用いた。免疫配置割合は全ノードに対して 0 から 60% の間で変化させた。BA モデルとテンポラルネットワークのそれぞれの感染密度を図 1 に示す。



(a) BA モデル

(b) テンポラルネットワーク

図 1: 各ネットワークにおける 100 回平均した感染密度の推移
図 1 において横軸は免疫を配置する割合、縦軸は感染密度を表す。図 1 より、IAM とランダムウォーク免疫配置手法は、BA モデルとテンポラルネットワークに対して感染の抑制効果があることを確認した。BA モデルは全体に対して 35% の免疫を配置することで約一年後に感染症が終息することを確認した。また、テンポラルネットワークでは、より少ない免疫配置率で終息させることが可能な結果となった。これらの結果はネットワーク構造が大きく関係していると考えられる。

7 まとめ

本稿では、BA モデルとテンポラルネットワークに対してランダムウォーク免疫配置手法を適用した際の感染伝播モデルによる感染密度の推移を調査した。動的なネットワークでは、接触回数の頻度によって感染率を決定した。数値実験より、テンポラルネットワークにおいて免疫配置は感染の抑制に効果的である結果となることを確認した。その理由として、ネットワーク構造の違いが感染の抑制に影響すると思われるが、どの程度終息に影響するかは明らかになっていない。そこで今後の課題として、ネットワーク構造が異なる種々の動的なネットワークを対象として手法の評価を行う予定である。

参考文献

- [1] K. Motoyoshi, et al., *Journal of Tokyo University of Information Science*, Vol. 15, No. 2, pp. 1–11, 2012.
- [2] M. Mabe, et al., *Journal of Signal Processing*, Vol. 21, No. 4, pp. 159–162, 2017.
- [3] Y. Iiduka, et al., *IEICE*, pp. 1–17, 2020.
- [4] A.-L. Barabasi, et al., *science*, Vol. 286, pp. 509–512, 1999.
- [5] <http://www.sociopatterns.org/datasets/high-school-contact-and-friendship-networks/> (access 2022/1/4).

マーク付点過程に対する重み付き Visibility Graph

A Study on Weighted Visibility Graph for Marked Point Processes

森 太紀[†]
Taiki Mori

對馬 帆南^{††}
Honami Tsushima

スヴィリドヴァ ニーナ^{†,††}
Nina Sviridova

池口 徹^{†,††}
Tohru Ikeguchi

[†] 東京理科大学 工学部 情報工学科, ^{††} 東京理科大学 大学院工学研究科 情報工学専攻

1 はじめに

時系列を複雑ネットワークに変換して解析する手法の1つに Visibility Graph (VG) 法 [1] がある。従来の VG 法では、その多くがデータの時間間隔が一定である時系列 (Equally sampled Time Series, 以下 ETS) に対して適用されている [2]。しかし、実世界のデータの多くは、時間間隔が一定ではないマーク付点過程 (Marked Point Process, 以下 MPP) として観測される。即ち、VG 法の MPP への適用可能性を検討することも重要である。例えば、地震情報の MPP と、その時間間隔を一定にした ETS に対して VG 法を適用すると、得られたネットワークの解析結果が類似することも報告されている [3]。これはネットワークに変換した際に MPP の時間間隔情報が欠落したためである。そこで本稿では、VG 法を MPP に適用する際、時間間隔情報をどのようにネットワークに反映すべきかについて検討した結果を報告する。

2 実験手法

本稿では、MPP を修正ベルヌーイ写像 [4] より作成した。具体的には、以下の2種類の手法により作成する。1つ目の手法では、修正ベルヌーイ写像の値を作成する MPP の時間間隔に割り当てる手法である (Values to Inter Event Interval, 以下 V-IEI)。修正ベルヌーイ写像の時刻 n における状態値を $x(n)$ とすると、作成する MPP の i 番目のイベント発生時刻 t_i は $t_i = \sum_{j=1}^i x(j)$ となる。2つ目の手法では、修正ベルヌーイ写像の状態値 $x(n)$ と $x(n+1)$ を接続する線が 0.5 と交わる時刻を MPP のイベント発生時刻とする (内挿)。いずれの手法においても作成した MPP のデータ数は 2,000 とし、マーク値 m_i は区間 $[0, 1]$ の一様乱数で決定した。また、各手法を用いて 100 個の MPP を作成した後、各 MPP のマーク値が同じで時間間隔を 1 とした ETS を作成する。作成した MPP と ETS に対し、VG 法を用いて重み付きネットワークを作成した。

本稿では、MPP の i 番目のイベントがネットワークにおける頂点 v_i となる。その際、MPP 上での i 番目のイベントと j 番目のイベント間距離 $l_{ij} = \sqrt{(t_i - t_j)^2 + (m_i - m_j)^2}$ を用いて、頂点 v_i, v_j 間の重みを決定した。具体的には $w_{ij} = l_{\min}/l_{ij}$ とした。なお、重みを $w_{ij} = l_{ij}/l_{\max}$ とした場合 [5] の結果と比較した。ただし、 l_{\max}, l_{\min} は l_{ij} の最大値、最小値である。

3 実験結果

解析に使用したネットワーク構造を定量化する指標として、重み付き平均頂点間距離 L_w [6] と4種類の重み付きクラスタ係数 $C_w^{(Z)}, C_w^{(L)}, C_w^{(B)}, C_w^{(O)}$ [7-10] を用い

た。本稿では、 $L_w, C_w^{(Z)}$ の平均値を 95%信頼区間と共に示す (表 1, 2)。

表 1: 提案法を時系列に適用した結果

手法	時系列	L_w	$C_w^{(Z)}$
V-IEI	MPP	0.033±0.003	0.011±0.001
	ETS	0.988±0.003	0.373±0.000
内挿	MPP	0.281±0.003	0.152±0.001
	ETS	0.988±0.003	0.373±0.000

表 2: 文献 [5] の手法を時系列に適用した結果

手法	時系列	L_w	$C_w^{(Z)}$
V-IEI	MPP	0.747±0.045	0.007±0.004
	ETS	0.813±0.044	0.005±0.000
内挿	MPP	0.765±0.045	0.003±0.004
	ETS	0.823±0.044	0.005±0.000

表 1, 2 より、提案法を適用した場合、 L_w と $C_w^{(Z)}$ において MPP と ETS から作成されるネットワークの間には有意差があることが分かる。この傾向は $C_w^{(B)}$ 以外のクラスタ係数でも同様であった。一方、文献 [5] の重み付けを用いた場合、 L_w と $C_w^{(Z)}$ において MPP と ETS から作成したネットワークの間に有意差はない。これらの結果から、提案法は MPP の時間間隔情報を適切に重み付きネットワークに反映できていると考えられる。

4 まとめ

本稿では、修正ベルヌーイ写像を用いて MPP を作成した。次に、得られた MPP を重み付きネットワークに変換する手法を提案した。その結果、提案法を適用することで、MPP の時間間隔情報がネットワーク構造に反映されることがわかった。なお、本研究の一部は、JSPS 科研費 JP19K14589, JP20H00596, JP21H03514 の助成を受けたものである。

参考文献

- [1] L. Lacasa, et al., *PNAS*, **105**, 13, 4972–4975, 2008.
- [2] J. B. Elsner, et al., *Geo. Res. Lett.*, **35**, 16, 2009.
- [3] B. Aguilar-San Juan, and L. Guzman-Vargas, *E. Phys. J. B*, **86**, 11, 1–10, 2013.
- [4] Y. Aizawa, and T. Kohyama, *PTP*, **71**, 4, 847–850, 1984.
- [5] M. Zhang, et al., *Sci. Rep.*, **11**, 1, 1–12, 2021.
- [6] X. J. Xu, et al., *Int. J. Mod. Phys. C*, **17**, 04, 521–529, 2006.
- [7] B. Zhang, and S. Horvath, *Stat. Anal. Gen. Mol. Biol.*, **4**, 1, 2005.
- [8] L. Lopez-Fernandez, et al., *Proc. of 1st Int. Workshop on MSR 2004*, 101–105, 2004.
- [9] A. Barrat, et al., *PNAS*, **101**, 11, 3747–3752, 2004.
- [10] J. P. Onnela, et al., *PRES*, **71**, 6, 065103, 2005.

Colexification ネットワークにおける感情とハブ

Emotions and hubs in a network of colexification

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

近年 colexification に基づく感情分類の研究が注目を集めている [1]. colexification とは単一の単語が複数の概念を意味する現象である [2]. 例えばスペイン語において, “malo” という単語は “BAD (悪い)” と “SEVERE (厳しい)” の二つの概念を意味し, colexification を呈する. ある言語において, colexification を呈する複数の概念は意味が類似する傾向にある. このような観点から, 概念を頂点, 2つの概念から colexification を呈する言語の数を枝の重みとした重み付きネットワーク (図 1) を用いることで, 概念間の類似性に基づいた言語の特徴を調べる研究が行われている [1].

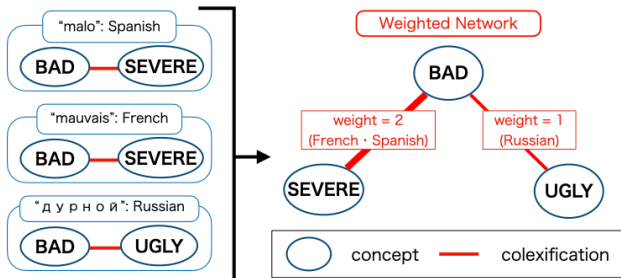


図 1: colexification ネットワークの作成例

文献 [1] では, このような colexification ネットワーク上でランダムウォークを適用した際の, 任意の頂点ペア間における n ステップ後の遷移確率を求めることで, 感情を表す概念間の類似性を調査している. しかし, 文献 [1] では $n = 1, \dots, 5$ の場合しか考慮されていない. そこで本稿では, ステップ数 n を増やした際の, ネットワークの構造の変化について調査した結果を報告する.

2 ネットワークの作成法

まず, 文献 [1] と同様に, 3,061 の言語における colexification を収録したデータベース CLICS³ [2] を用いて, colexification ネットワークを作成する. ここで, 頂点 i と j を繋ぐ枝の重みを W_{ij} とする. 次に, ランダムウォークを用いて隣接していない概念間の間接的な繋がりを考慮したネットワークを作成する. ランダムウォークは枝で繋がる頂点間を遷移確率行列 $P = [P_{ij}]$ に基づいて移動する手法である. ここで, $P_{ij} = W_{ij} / \sum_{k=1}^N W_{ik}$, N を頂点数とする. また, n ステップ後の遷移確率行列を P^n とする. 文献 [1] では, $B^{(n)} = \sum_{s=1}^n P^s$ を重み付き隣接行列とするネットワークから, 代表的な感情の概念と, その概念を繋ぐ枝のみを抽出したネットワーク $C^{(n)}$ を作成している. その際, 全ての頂点ペア (i, j) に対して $C_{ij}^{(n)} \neq 0$ を満たす n の最小値が 5 であったことから, $C^{(5)}$ で表されるネットワークにおける, 感情を表す概念のコミュニティ構造を調査している. しかし, $n = 5$ の場合, 感情を表す概念間を繋ぐ経路上に現れる頂点 (概念) の数は高々 5 つであり, 6 ステップ以上離れた頂点 (概念) の影響は考慮されていない.

3 数値実験

本稿では, 感情を表す概念間を繋ぐ経路上に現れる, 感情以外を表す概念に対応する頂点の数を増加させるため, ランダムウォークのステップ数を 1,000 まで増加させた. また, 作成するネットワークにおいてステップ数を増やした結果を枝の重みに反映させるため, P^n を重み付き隣接行列とするネットワークを作成した. また, P^n から代表的な感情の概念と, その概念を繋ぐ枝のみを抽出したネットワーク $Q^{(n)}$ を作成した. 作成したネットワーク $Q^{(n)}$ を図 2 の上段に, ネットワーク $Q^{(n)}$ における枝の重みの分布を下段に示す.

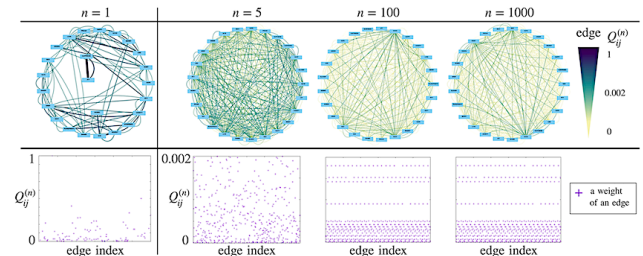


図 2: ネットワーク $Q^{(n)}$ と枝の重み分布

図 2 から, n の増加に伴ってネットワークの枝の重みが一定値に収束する傾向が見られる. また, 図 2 下段より, $Q^{(n)}$ において同じ重みを持つ枝の集合が存在していることがわかる. どのような枝が集合を構成するかを確認したところ, 同じ頂点に向かう枝であることがわかった. また, 重みの大きい順に “GOOD”, “WANT”, “BAD”, “LOVE” であること, これらの 4 つの頂点に向かう枝の重みは, 他の枝の重みに比べて大きいことを確認した. さらに, これらの 4 つの頂点は, 感情を表す概念のうち, 感情以外を表す概念に対応する, より多くの頂点と隣接していることも確認した. ネットワークにおいて, 他の頂点と比べて隣接する頂点が多い頂点はハブと呼ばれることから, これらの 4 つの頂点は, colexification ネットワークにおいてハブであることが示された.

4 まとめ

本稿では, colexification ネットワークを作成する際に用いるランダムウォークのステップ数を増加させることで生じる, ネットワーク構造の変化について調査した. その結果, colexification ネットワークにおいて, ハブとなっている感情を表す概念に対応する頂点が存在することが確認された.

本研究の一部は, JSPS 科研費 JP21H03514, JP20H00596, JP19K01653, JP18K12701, JP21H03508 の助成を受けたものである.

参考文献

- [1] J. C. Jackson, *et al.*, *Science*, Vol. 366, No. 6472, pp. 1517–1522, 2019.
- [2] J. M. List, *et al.*, <https://clics.clld.org/>, (Last visit Dec. 3rd, 2021).

脈波データを用いた再構成パラメータの設定について

A study on reconstruction parameters for transforming photoplethysmogram into time-delay coordinate system

澤田和弥¹
Kazuya Sawada

スヴィリドヴァ ニーナ¹
Nina Sviridova

島田裕²
Yutaka Shimada

池口徹¹
Tohru Ikeguchi

東京理科大学¹

埼玉大学²

1 はじめに

観測時系列を遅延座標系に変換し、非線形力学系のアトラクタを再構成する手法は、力学系の特性を把握する上で必要不可欠である [1, 2]. しかし、遅延座標系を用いる際には、適切な再構成次元と時間遅れを設定する必要がある. 特に、実データを解析する際は、必要十分かつ可能な限り小さい再構成次元と可能な限り小さい時間遅れが望ましい. 我々は既に、数理モデルの真のアトラクタと観測時系列から再構成したアトラクタ上の2点間距離分布間の距離を計算することで適切な再構成パラメータを推定する手法を提案している [3]. また、再構成アトラクタ上の2点間距離分布のエントロピーを最大化する再構成パラメータは、真のアトラクタと再構成アトラクタ上の2点間距離分布間の距離を最小化する再構成パラメータと概ね一致することも示している [4]. 本稿では、人の指先から計測した脈波データ [5, 6] に対して、再構成次元、時間遅れを変化させ、再構成アトラクタ上の2点間距離分布のエントロピーを計算し、適切な再構成パラメータの検討を行ったので報告する.

2 解析対象データ

本稿では、人の指先からパルスオキシメータ (東京デバイス 汎用 心拍センサ IWS920 開発キット「パルス・ラボ」 [7]) によって LED 光を用いて非侵襲に計測した光電脈波の時系列データを解析対象とした. その際、「東京理科大学 人を対象とする医学研究の実施及び倫理に関する規定」に従い、実験手順などを被験者に十分説明し、同意を得たのちに室温約 24 °C の快適な環境下かつ安静状態で約 5 分間計測した. また、本稿で用いたデータは、22 歳の健康な女性のデータであり、計測時のサンプリング間隔は 1/409.6 秒、解析に使用した時系列データのサンプリング間隔は 10/409.6 秒とした.

3 数値実験

本稿では、脈波データを遅延座標系に変換する際、再構成次元 m 、時間遅れ τ を 1~30 の範囲で変化させ、再構成アトラクタ上の2点間距離分布のエントロピーを計算した [4]. その際、データ点数は 5,000 点用い、2点間距離分布の階級数は、Freedman-Diaconis の法則に従って決定した [8]. 結果を図 1 に示す. 図 1 から、時間遅れ τ が比較的小さい領域では、エントロピーは小さい値となっている. 一方、時間遅れ τ が大きくなるにつれて、エントロピーは大きい値となっている.

4 まとめ

本稿では、人の指先から計測した脈波の時系列データを遅延座標系に変換する際、再構成パラメータを網羅的




図 1 再構成次元、時間遅れを変化させた際の再構成アトラクタ上の2点間距離分布のエントロピー

に変化させ、再構成アトラクタ上の2点間距離分布のエントロピーを計算した. その結果、時間遅れ τ が小さい範囲では、エントロピーが比較的小さい値を取り、時間遅れ τ が大きい範囲では、エントロピーが比較的大きい値を取ることがわかった.

本研究の一部は、JSPS 科研費 (Nos. JP19K14589, JP20H00596, JP21H03508, JP21H03514) の援助を受けて行われた.

参考文献

- [1] F. Takens, in *Dynamical Systems and Turbulence*, eds. D. A. Rand and L.-S. Young, **898**, 366–381, 1981.
- [2] T. Sauer, et. al., *Journal of Statistical Physics*, **65**, 3, 579–616, 1991.
- [3] K. Sawada, et. al., submitted to *NOLTA, IEICE*, 2021.
- [4] 澤田 他, 信学技報, **121**, 307, 96–99, 2021.
- [5] I. Tsuda, et. al., *International Journal of Bifurcation and Chaos*, **2**, 2, 313–324, 1992.
- [6] N. Sviridova and K. Sakai, *Chaos, Solitons & Fractals*, **77**, 53–63, 2015.
- [7] 東京デバイス 汎用心拍センサ IWS920 開発キット「パルス・ラボ」<https://tokyodevices.com/items/188> [accessed 2021/12/21].
- [8] D. Freedman and P. Diaconis, *Zeitschrift für Wahrscheinlichkeitstheorie und verwandte Gebiete*, **57**, 4, 453–476, 1981.

ユーザ属性に着目した バイクシェアリングシステム利用履歴データの解析

Analysis on usage history with user attribute in a bicycle sharing system

對馬 帆南
Honami Tsushima

池口 徹
Tohru Ikeguchi

東京理科大学
Tokyo University of Science

1 まえがき

バイクシェアリングシステム (BSS) で生じる自転車の過不足台数を調整するために、我々は複数の自転車回収車を用いた自転車再配置問題の提案とその問題に対する発見的解法の開発に取り組んでいる [1, 2]. その際、ランダムにポートを配置したオリジナルの問題例を用いて、性能評価を行ったが、実際の BSS における再配置作業の効率的な戦略を提案するためには、実際のポート配置や利用履歴情報を組み込むことが重要となる. そこで我々は、BSS の実際の利用履歴データを点過程と捉えることで解析を行い、平日と週末の利用パターンに差がないことなどを明らかにした [3, 4]. 実際の BSS では、様々なユーザ属性が利用履歴と併せて記録されている. そこで本稿では、ユーザ属性の中でも特に定期所有情報に着目することで利用履歴を解析した結果を報告する.

2 統計的な解析

本稿では、2017 年のシカゴ [5] の利用履歴データを解析した結果を報告する. 利用履歴データには、自転車を借りたポートの ID と日時、返却したポートの ID と日時、ユーザ属性が含まれる. ユーザー属性は定期利用、非利用の 2 種類がある. 本稿では、自転車の貸出と返却が行われた時間を点過程として扱い、ラスタプロット、変動係数 (C_V)、局所変動係数 (L_V) を用いて、各ポートにおける自転車の貸出と返却のイベントの発生パターンがどのように振舞うか調査した. C_V と L_V を求めるために、まず、inter-event-intervals (IEIs) を求める. あるポートで i 番目にイベントが発生した時間を t_i 、次にそのポートでイベントが発生した時間を t_{i+1} とする. i 番目の IEI を $T_i = t_{i+1} - t_i$ と定義すると、IEI を用いて、 C_V , L_V は $C_V = \sqrt{1/(n-1) \sum_{i=1}^n (T_i - \bar{T})^2 / \bar{T}}$, $L_V = 1/(n-1) \sum_{i=1}^{n-1} 3(T_i - T_{i+1})^2 / (T_i + T_{i+1})^2$ と定義される. n は IEI の数を示し、 \bar{T} は IEI の平均を示す. C_V は全ての IEI の変動を示し、 $C_V = 0$ であれば、自転車の貸出・返却の発生は規則的に発生していることを示す. 一方、 $C_V = 1$ であれば、ポアソン過程となる. また、 L_V とは、局所的な変動を測る指標である、 $L_V = 0$ であれば自転車の貸出・返却の発生は規則的に発生し、 $L_V = 1$ であれば、IEI はポアソン過程となる.

はじめに、8 月の第一水曜日 (平日) と第一土曜日 (週末) の貸出ラスタプロットを図 1 に示す. 横軸は時間 (分) を示し、縦軸はポート ID を示している. 図 1 より、定期利用者の平日の利用パターンは朝夕の通勤時間帯に多くの自転車が利用され、週末は通勤の時間帯にはピークがないパターンであることわかる. 一方、定期非利用者は平日、週末共に通勤の時間帯にピークはなく、昼す

ぎから利用が増加する傾向にある. 次に、表 1, 2 に、 C_V , L_V の平均値 μ_C , μ_L の 95% 信頼区間を示す. 表 1 より、平日、週末共に、ユーザ属性を考慮しない場合、定期利用、定期非利用の全てについて 1 より大きい値をとっている. 一方、表 2 より、ユーザ属性を考慮しない場合と定期利用の場合は、平日、週末全て 1 に近づき、特に、定期利用の場合は、1 に近い値を取ることがわかった.




図 1 ラスタプロット

表 1 C_V の信頼区間

	平日	週末
ユーザ属性考慮なし	$1.64 \leq \mu_C \leq 1.75$	$1.62 \leq \mu_C \leq 1.72$
定期利用	$1.66 \leq \mu_C \leq 1.77$	$1.48 \leq \mu_C \leq 1.56$
定期非利用	$1.36 \leq \mu_C \leq 1.45$	$1.59 \leq \mu_C \leq 1.71$

表 2 L_V の信頼区間

	平日	週末
ユーザ属性考慮なし	$1.11 \leq \mu_L \leq 1.16$	$1.23 \leq \mu_L \leq 1.28$
定期利用	$1.08 \leq \mu_L \leq 1.12$	$1.15 \leq \mu_L \leq 1.19$
定期非利用	$1.63 \leq \mu_L \leq 1.71$	$1.63 \leq \mu_L \leq 1.71$

3 まとめ

本稿では実際の BSS の利用パターンについてユーザ属性に着目した解析を行った. その結果、ラスタプロットから定期利用者と定期非利用者の自転車の利用のパターンは異なること、また、局所変動係数の結果から、定期利用者の平日の自転車の利用パターンは 1 に近い値を取ることがわかった. 本研究の一部は、JSPS 科研費 JP20H000596, JP21H03514 の援助を受けた.

参考文献

- [1] H. Tsushima, et al., *J. of Signal Processing*, **22**(4), pp. 157-160, 2018.
- [2] H. Tsushima et al., *App. Sci.*, **11**(16), 7749, 2021.
- [3] H. Tsushima et al., *NLSW2021*, NLSW-32, 2021.
- [4] H. Tsushima et al., submitted to *NOLTA, IEICE*, 2021.
- [5] Divvy system data.
<https://www.divvybikes.com/system-data>.