

法政大学学術機関リポジトリ
HOSEI UNIVERSITY REPOSITORY

進化的計算によるデジタルスパイクマップの合成

著者	濱口 智紀
出版者	法政大学大学院理工学研究科
雑誌名	法政大学大学院紀要. 理工学・工学研究科編
巻	59
ページ	1-5
発行年	2018-03-31
URL	http://doi.org/10.15002/00021569

進化的計算によるデジタルスパイクマップの合成

SYNTHESIS OF DIGITAL SPIKE MAPS BY THE EVOLUTIONARY ALGORITHM

濱口 智紀

Tomoki HAMAGUCHI

指導教員 斎藤利通

法政大学大学院理工学研究科電気電子工学専攻修士課程

This paper studies analysis and implement of Digital Dspike Maps(DSM). In order to visualize dynamics of spike-trains, we introduce the DSM. The DSM is a digital version of analog one-dimensional maps. The Dmap is related to various digital dynamical systems including cellular automata and dynamic binary neural networks, digital spiking neuron. In order to realization desired DSM, we present a simple evolutionary algorithm. It is a type of optimization algorithm inspired by biological mechanisms.

Key Words : Digital spike maps, Evolutionary algorithm

1. はじめに

本論文ではデジタルスパイクマップ (Digital Spike Maps 以下 DSM) [1]-[4] の解析, 及びハードウェア実装についての研究を行った. DSM は点の集合上で定義された差分方程式であり, スパイク列のダイナミクスを視覚化することができる. また, ロジスティックマップに代表されるようなアナログ一次元マップのデジタル版であるとも言える [5]. DSM はアナログ一次元マップを離散的に定義したものであるため, 有限個の定義域上に定義される. DSM はセルオートマトン (Cellular Automaton)[8]-[9] や動的バイナリニューラルネットワーク (Digital Binary Neural Networks)[15]-[18], 本論文で扱うデジタルスパイクングニューロン (Digital Spiking Neurons) 等, 様々なデジタルシステムと関係している [6]-[7]. DSM に関する研究は非線形システムの基礎研究であり, 関連する様々な工学的応用へ貢献できる.

また, 所望の DSM を実現するために, 簡素な進化的計算を用いた [10]. 進化的計算とは生物学的機構に着想を得た最適化アルゴリズムの一種である [11]-[14]. 本論文では SEA の探索の成功率や計算コストについても解析をする. 簡素化した単純なアルゴリズムのため, 様々な問題への活用につながる.

2. Digital Spike Maps

デジタルスパイクマップ (Digital Spike Maps 以下 DSM) を紹介する. DSM はロジスティックマップに代表されるようなアナログ一次元マップのデジタル版であると言える. n 番目のスパイク位相を x_n としたとき, x_n は実数値をとる. アナログマップは非周期的な振動 (カオス) や周期的な振動, 一定値への収束を起こす. 一方, DSM は n 番目のスパイク位相を θ_n としたとき, θ_n は離散値 $(1, 2, \dots, N)$ をとる. デジタルマップは必ず周期的な振動を起こす. アナログ一次元マップの定義域を離散化することで DSM が得られる.

図 1, 図 2 に DSM とスパイク列の例を示す. スパイク列は以下のように定義される.

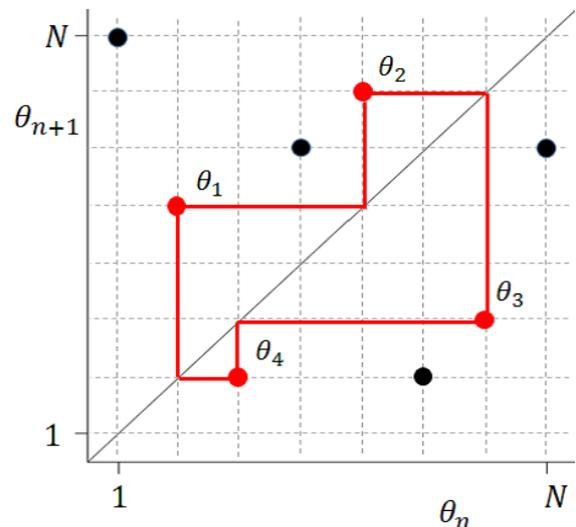


図 1 8 個の格子点の集合上に定義されたデジタルスパイクマップ. (赤点: PEP, 赤線: PEO, 黒点: EPP)

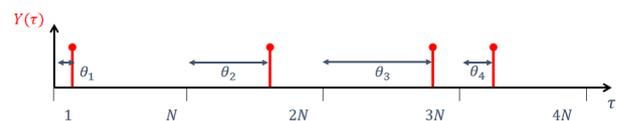


図 2 周期 4 の周期的スパイク列.

$$Y(\tau) = \begin{cases} 1 & \text{for } \tau = \tau_n \\ 0 & \text{for } \tau \neq \tau_n \end{cases} \quad \tau_n = \theta_n + (n - 1). \quad (1)$$

τ は離散化された時間とする. τ_n は n 番目のスパイク位置を示し, θ_n は n 番目のスパイク位相を示す. τ が τ_n であるとき, スパイクが発火 ($Y(\tau) = 1$) していると言える. 最初のスパイク列は $\tau_1 = \theta_1$ で与えられる. 離散化した時間上にスパイク列は発火するため, スパイク列は周期的になる場合がある. このようなスパイク列を周期的スパイク列 (Periodic Spike Train 以下 PST) と呼ぶ.

また, DSM は以下のように定義される.

$$\theta_{n+1} = f(\theta_n), \theta_n \in \{1, 2, \dots, N\} \equiv L_N \quad (2)$$

DSM は N 個の格子点の集合上で定義されている. 定義された領域 L_N は有限個の格子点からなるため, 定常状態は必ず周期的な振る舞いとなる. すなわち, DSM が視覚化できるスパイク列は PST のみとなる.

また, DSM の特性ベクトルは以下のように定義される.

$$d \equiv (d_1, \dots, d_N), d_i = Nf(l_i) \in \{1, 2, \dots, N\} \quad (3)$$

例として, 図 1 で示した DSM の特性ベクトルは以下のようになる.

$$d \equiv (8, 5, 2, 6, 7, 2, 3, 6) \quad (4)$$

DSM の基本的な定義を行う.

定義 1: ある点 $p \in L_N$ が $p = f^k(p)$ であり, かつ $f(p)$ から $f^k(p)$ とは異なるとき, 点 p は周期 k の周期点 (Periodic Point 以下 PEP) であると呼ぶ. 但し, f^k は f の k 回写像とする. また, PEP の系列 $\{p, f(p), \dots, f^{k-1}(p)\}$ は k 回写像の周期軌道 (Periodic Orbit 以下 PEO) と呼ぶ. 周期軌道は周期的スパイク列に対応している. 例として, 図 1 に示した 4 周期の PST は, 図 1 に示した 4 周期の PEO に対応していることを示している.

定義 2: ある点 $q \in L_M$ が PEO ではなく, かついずれかの周期的な点 p に k 回の写像で落ち込む場合 ($f^k(q) = p$), 点 q は最終的に周期点に落ち込む点 (Eventually Periodic Point 以下 EPP) と呼ぶ. また, 点 q が 1 回の写像でいずれかの周期的な点 p に落ち込む場合 ($f(q) = p$), 特に, 直接 EPP (Direct Eventually Periodic Point 以下 DEPP) と呼ぶ.

3. Digital Spike Maps の合成

所望の DSM を実現するために, 簡素な進化的計算を用いた DSM の合成を行う. DSM はその特性ベクトルが変わると, 特徴が大きく変わるが, 体系的でないため, 所望の特徴を持つ DSM の実現は困難である. そのため簡素な進化的計算を用いて, 所望の特徴を持つ DSM の実現を目指す.

進化的計算とは, 生物の生殖, 淘汰, 突然変異などの生物学的機構に着想を得た最適化アルゴリズムの一種である. 最適化アルゴリズムには進化的計算の他にも局所探索法, 粒子群最適化法 (Particle Swarm Optimization) などが挙げられる. 本論文では一例として, 貪欲法に基づく簡素な進化的計算 (Simple Evolutionary Algorithm 以下 SEA) を用いた最適化を行った. 貪欲法 (Greedy Algorithm) とは, 個体の評価値が良くなる方向にのみ進化する手法である. 本項で行う SEA の DSM への適用においては, 個体を DSM のマップベクトル, 最終的に残った個体が所望の特徴を持った DSM とする. また, SEA の探索の成功率や計算コストについても解析をする. 簡素化した単純なアルゴリズムのため, 様々な問題への活用に繋がると考える.

SEA の手順を以下に簡単に示す.

1. 次世代に残す個体の候補を作成する (生殖).
2. 個体の一部にランダムなパラメータの変化を与える (突

然変異).

3. 評価関数により評価し, 評価の良い個体の候補のみを残し (適者生存), 他を削除する (淘汰).

4. 残った評価の良い個体の候補を次世代の個体とする.

SEA はこれを繰り返すことにより最適な個体を探す. 但し, SEA における個体は DSM の特性ベクトル d である. g を世代としたとき, i 番目の個体 $\delta^i(g)$ は以下のように示す.

$$\begin{aligned} \delta^i(g) &= (\delta_1^i(g), \dots, \delta_N^i(g)), \\ i &\in \{1, 2, \dots, K(g)\}, \\ g &\in \{0, 1, 2, \dots, g_{max}\}, K(g) \leq K_{max} \end{aligned} \quad (5)$$

$K(g)$ は世代 g の個体の数とする. また, K_{max} は任意に設定する世代ごとの個体数上限を示す. g_{max} は任意に設定する SEA の世代数上限を示す.

個体の候補は評価関数 $F_c(\delta^i(g))$ によって評価される.

$$F_c(\delta^i(g)) \geq 0, i \in \{1, 2, \dots, K(g)\}. \quad (6)$$

$G_b(g)$ を世代 g における評価関数のグローバルベストとする.

以下に詳しい SEA のステップを示す.

Step1: 初期個体の設定

$g = 0$ とし, k 周期の PEO を持つ初期個体 $\delta^1(0)$ を用意する ($K(0) = 1$). 初期個体の評価を行い, $g = 0$ のグローバルベストを計算する: $G_b(0) = F_c(\delta^1(0))$.

Step2: 個体の候補の作製

i 番目の 4 周期の PEO を構成している成分について着目する. それらの成分の 1 つを $\{1, \dots, N\}$ のほかの整数値に変更する. これを繰り返し, 次の世代の個体の候補として, $k \times (N - 1) \times K(g)$ 個の候補を作製する. j 番目の候補を次のように示す: $\beta^j(g)$, $j \in \{1, \dots, k \times (N - 1) \times K(g)\}$.

Step3: 候補の評価 $k \times (N - 1) \times K(g)$ 個の候補の内, 4 周期の PEO を持たない候補については削除をする. 残った候補について, 評価関数 F_c によって評価を行う. グローバルベストは次のように更新される.

$$\begin{cases} G_b(g) \leftarrow F_c(\beta^j(g)) & \text{if } F_c(\beta^j(g)) < G_b(g) \\ G_b(g) \leftarrow G_b(g) & \text{otherwise} \end{cases} \quad (7)$$

グローバルベストの評価値を持つ個体の候補を新しい個体とする. グローバルベストが評価関数の最適値に到達した場合, 新しい個体を最適個体とし, アルゴリズムを終了する. グローバルベストが評価関数の最適値に到達していない場合, 個体数 $K(g)$ を新しい候補の数 K_N で更新する. 新しい候補の数 K_N が個体数上限 K_{max} を超えていた場合, グローバルベストの評価値を持つ個体の候補からランダムに新しい個体を選択する.

Step4: 突然変異

EPP を構成している成分について着目する. それらの成分の 1 つを $\{1, \dots, N\}$ のほかの整数値にランダムに変更する. これを全ての EPP 成分 ($N - k$) について施し, EPP の成分に変化を加える. この動作は全ての個体について突然変異率 MR で実行される.

Step5: 終了条件

世代 g を次世代に更新する: $g \leftarrow g + 1$. 世代 g が世代数上限 g_{max} に到達するまで Step2 に戻り繰り返す.

所望の特徴を持つ DSM の合成を行う。本論文では、例として自己相関の低い DSM の実現を目指す。自己相関は以下のように定義される。

$$R_{YY}(d) = \sum_{\tau=1}^p Y_p(\tau)Y_p(\tau+d) \text{ for } d \in \{0, \dots, p\} \quad (8)$$

評価関数 F_c は自己相関のセカンドピークとする。

$$F_c(d) = \max_d R_{YY}(d) \text{ for } d \in \{1, \dots, p-1\}, F_c(d) \geq 1 \quad (9)$$

但し、 d は p 周期の PEO を持つ DSM の特性ベクトルとする。自己相関のセカンドピークの最適値は 1 となる： $F_c = 1$ 。

SEA の条件は以下の様にした。

$$M = 32, k = 10, K_{max} = 30, g_{max} = 10, \\ MR \in \{0, 1, 5, 10, 30\}$$

本項では $MR = 0, 10$ の場合について、そのプロセスを確認する。

MR = 10 の場合

初期個体は以下の特性ベクトルを持つ DSM を用意した。

$$\delta(0) = (2, 3, 4, 5, 6, 7, 8, 9, 10, 1, 16, 9, 25, 14, 4, 6, 26, \\ 21, 17, 25, 26, 4, 17, 8, 7, 16, 21, 29, 6, 9, 23, 1)$$

図 3 に初期個体 ($g = 0$) の DSM を示す。自己相関は $F_c(d) = 9$ で $G_b(0) = 9$ とする。Step2 として、 $10 \times 31 \times 1$ の個体の候補を作製する。個体の候補を評価し、最も評価値の良かった個体を次世代の個体とする。 $g = 1$ の個体の特性ベクトルは以下の様である。

$$\delta(1) = (2, 3, 4, 5, 6, 25, 8, 9, 10, 1, 10, 1, 5, 29, 1, 26, 14, 14, \\ 10, 10, 8, 1, 20, 26, 20, 1, 29, 31, 4, 3, 10, 1)$$

図 4 に $g = 1$ の DSM を示す。グローバルベストは $G_b(1) = 6$ となる。

これを繰り返し、 $g = 6$ の個体の特性ベクトルは以下の様である。

$$\delta(6) = (5, 10, 17, 20, 1, 9, 24, 18, 5, 3, 18, 30, 9, 12, 27, 21, \\ 19, 2, 3, 16, 29, 27, 21, 16, 24, 13, 25, 13)$$

図 5 に $g = 6$ の DSM を示す。グローバルベストは $G_b(6) = 1$ となる。グローバルベストは最適値で、自己相関の低い DSM が合成できたと言える。世代に対するグローバルベストの推移を図 6 に示す。また、世代に対する個体数の推移を図 7 に示す。

MR = 0 の場合

$MR = 0$ は突然変異が起こらない設定となる。初期個体は以下の特性ベクトルを持つ DSM を用意した。

$$\delta(0) = (2, 3, 4, 5, 6, 7, 8, 9, 10, 1, 32, 11, 19, 11, 30, 9, 10, \\ 15, 4, 9, 3, 27, 26, 10, 6, 31, 32, 16, 26, 4, 21, 1)$$

図 8 に初期個体 ($g = 0$) の DSM を示す。グローバルベストは $G_b(1) = 9$ となる。世代数上限である $g = 10$ の個体の特性ベクトルは以下の様である。

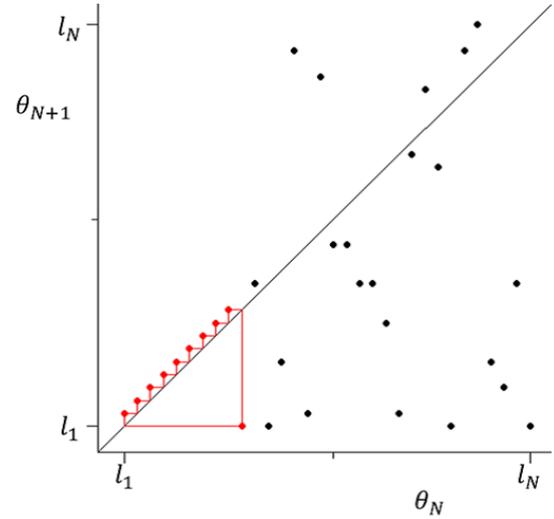


図 3 $g = 0, G_b(0) = 9$ の DSM ($MR = 10$ の場合).

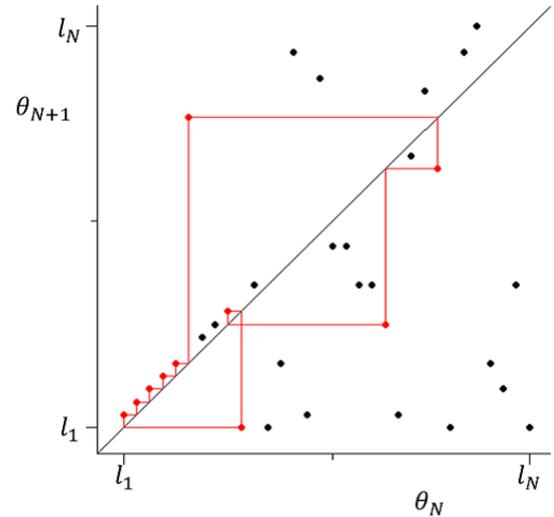


図 4 $g = 1, G_b(1) = 6$ の DSM ($MR = 10$ の場合).

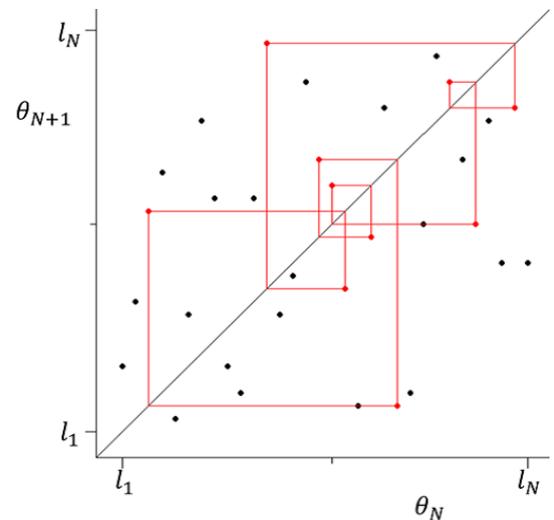


図 5 $g = 6, G_b(6) = 1$ の DSM ($MR = 10$ の場合).

$$\delta(10) = (2, 3, 4, 25, 6, 7, 8, 23, 10, 1, 32, 11, 19, 11, 30, 9, 10, \\ 15, 4, 9, 3, 27, 26, 10, 6, 31, 32, 16, 26, 4, 13, 1)$$

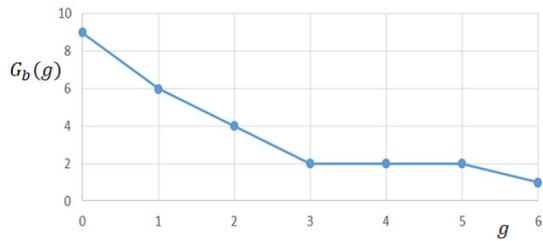


図 6 SEA のプロセス: グローバルベスト ($MR = 10$ の場合).

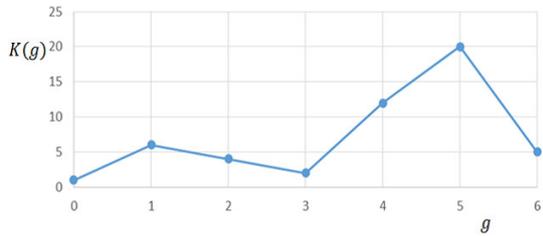


図 7 SEA のプロセス: 個体数 ($MR = 10$ の場合).

図 9 に $g = 10$ の DSM を示す. 世代数上限に達したが, グローバルベストは $G_b(10) = 2$ となり, 所望の DSM の実現ができなかった. 世代に対するグローバルベストの推移を図 10 に示す. また, 世代に対する個体数の推移を図 11 に示す. グローバルベストの推移, 及び個体数の推移から分かるように, $g = 4$ から作製される個体には変化がない. これは局所解, すなわち部分的な最適値に収束してしまったと考えられる. 原因としては, 突然変異が無いため, 個体に大きな変化が与えられなかったと推測される. 個体の候補は PEO を構成する成分のみを変更し, 作製する. EPP を構成する成分に対しては, 変化を与えない. そのために, 初期個体の EPP の成分が探索の成功に大きく影響する. 表 1 に突然変異率 MR に対する, 探索成功率, 平均世代数, 平均個体数を示す. なお, 平均世代数, 平均個体数は探索が成功した場合のみを対象にした. MR が 0 の場合は非常に成功率が低いことが分かる. また, MR を上げて, $MR = 5$ で探索成功率はほぼ上限に近付いた. 平均世代数, 平均個体数は MR の増加と共に減少した.

4. むすび

デジタルスパイクマップを紹介し, その合成を行った DSM のハードウェア実装に当たって, DSM の合成を行った. スパイクを基にしたアプリケーションを考えると, 所望の特徴を持つ DSM を用意する必要がある. DSM に簡素な進化的計算を適用することで, 所望の DSM の実現を行った. 進化的計算のパラメータ変更による探索の成功率や計算コストの変化についても触れ, 進化的計算の解析についても取り組んだ. 突然変異率が探索の成功率に大きく影響されることが分かった. DSM の合成は様々なスパイクを基にしたアプリケーションに繋がると考えられる. 用いた進化的計算はアルゴリズムを簡素化したもので, 様々な問題に対し適用できると考えられる.

今後の課題としては, 以下が挙げられる.

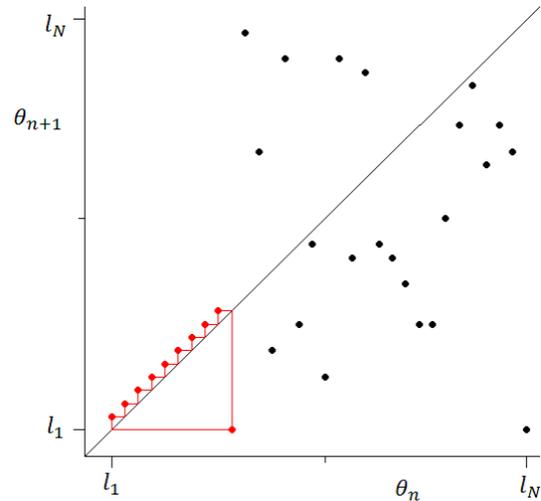


図 8 $g = 0, G_b(0) = 9$ の DSM ($MR = 0$ の場合).

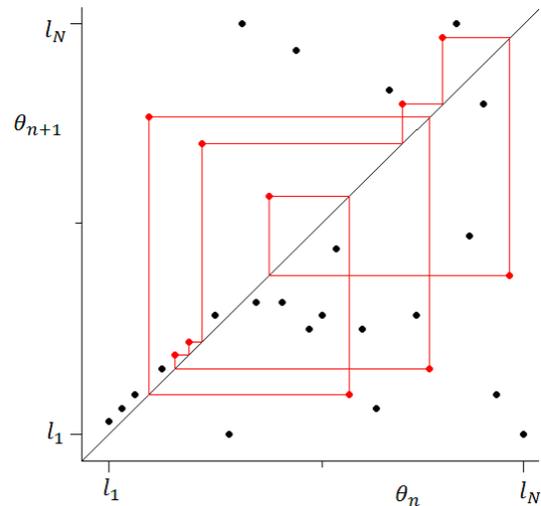


図 9 $g = 10, G_b(10) = 2$ の DSM ($MR = 0$ の場合).

1. 自己相関以外の評価関数を用いた DSM の合成
2. SEA のより詳細な解析
3. SEA の探索の成功率や計算コストの向上

参考文献

- 1) N. Horimoto and T. Saito, Analysis of digital spike maps based on bifurcating neurons, NOLTA, IEICE, 3, 4, pp. 596-605, 2012.
- 2) A. Matoba, N. Horimoto, and T. Saito, Basic dynamics of the digital logistic map, IEICE Trans. Fundamentals, E96-A, 8, pp. 1808-1811, 2013
- 3) H. Yamaoka and T. Saito, Steady-versus-transient plot for analysis of digital maps, IEICE Trans. Fundamentals, E99-A, 10, pp. 1806-1812, 2016.
- 4) T. Hamaguchi, K. Yamaoka, and T. Saito, Stability Analysis of Periodic Orbits in Digital Spiking Neurons, (A. Hirose et al. (Eds.): ICONIP 2016, Part II), LNCS 9948, pp. 334-341, 2016.
- 5) E. Ott, Chaos in dynamical systems, Cambridge,

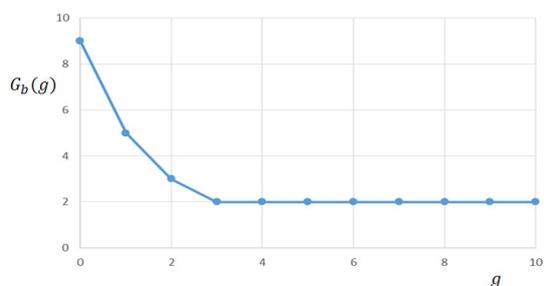


図 10 SEA のプロセス: グローバルベスト ($MR = 0$ の場合).

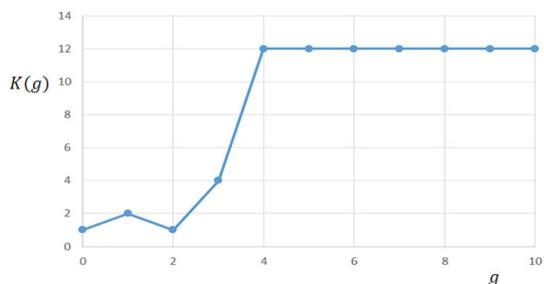


図 11 SEA のプロセス: 個体数 ($MR = 0$ の場合).

- 1993.
- 6) E. M. Izhikevich, Dynamical systems in neuroscience, MIT Press, 2006.
 - 7) S. R. Campbell, D. Wang, and C. Jayaprakash, Synchrony and desynchrony in integrate-and-fire oscillators, *Neural Comput.*, 11, pp. 1595-1619, 1999.
 - 8) L. O. Chua, A nonlinear dynamics perspective of Wolfram's new kind of science, I, II. World Scientific, 2005.
 - 9) W. Wada, J. Kuroiwa, and S. Nara, Completely reproducible description of digital sound data with cellular automata, *Physics Letters A* 306, pp. 110-115, 2002.
 - 10) T. Saito, K. Yamaoka, and T. Hamaguchi, Realization of desired digital spike-trains by a simple evolutionary algorithm, *NOLTA, IEICE, E8-N*, 4, pp. 267-278, 2017.

表 1 SEA の性能 (100 回試行).

MR	探索成功率	平均世代数	平均個体数
0	18	2.56	8.20
1	74	6.12	84.4
5	98	4.91	39.8
10	96	4.79	37.6
30	95	3.46	18.6

- 11) A. P. Engelbrecht, Fundamentals of computational swarm intelligence, Wiley, 2005.
- 12) W. Ertel, Introduction to Artificial Intelligence, Springer, 2009.
- 13) C. Couvreur and Y. Bresler, On the optimality of the backward greedy algorithm for the subset selection problem, *SIAM J. Matrix Anal. Appl.*, 21, 3, pp. 797-808, 2000.
- 14) K. Yamaoka and T. Saito, Realization of desired super-stable spike-trains based on digital spiking neurons, *Proc. IJCNN*, pp. 198-205, 2016.
- 15) K.L. Shi and H. Li, Optimized random PWM strategy based on genetic algorithms, *Proc. IEEE/IECON*, pp. 7-11, 2003.
- 16) R. Kouzuki and T. Saito, Learning of simple dynamic binary neural networks, *IEICE Trans. Fundamentals*, E96-A, 8, pp. 1775-1782, 2013.
- 17) J. Moriyasu and T. Saito, A cascade system of dynamic binary neural networks and learning of periodic orbit, *IEICE Trans. Inf. & Syst.*, E98-D, 9, pp. 1622-1629, 2015.
- 18) R. Sato and T. Saito, Simple feature quantities for learning of dynamic binary neural networks, (S. Arik et al. (Eds.): *ICONIP 2015, Part I*), LNCS 9489, pp. 226-233, 2015.