

力学的情報処理に基づく自己組織的シンボル獲得モデルの設計

中村大介 (東京大学) 岡田昌史 (東京大学) 中村仁彦 (東京大学・CREST)

Design of Self-Organizing Symbol Acquisition Model based on Dynamics-based Information Processing System

Daisuke NAKAMURA (Univ. of Tokyo), Masafumi OKADA (Univ. of Tokyo),
Yoshihiko NAKAMURA (Univ. of Tokyo,CREST)

Abstract— It is important for intelligent systems to acquire symbols not in a top-down way but in a self-organizing way. We designed Dynamics-Based Self Organizing Map(DBSOM) that can not only acquire a topological preserving map but also generate a learned signal. In addition, we aim at developing Dynamics-based Information Processing System so that it can acquire symbols in a self-organizing way by means of DBSOM.

1. はじめに

シンボルを獲得・操作することは、ロボットの知的情報処理系の構築において重要な機能である。しかし従来の人工知能においては、ロボットがシンボルを自ら獲得するのではなく、トップダウンに与えられるのみであり、このために記号接地などの問題が生じた。そこで本研究ではロボットがシンボルを自己組織的に獲得するシステムの構築を目指す。具体的には、ダイナミカル自己組織化マップ (DBSOM) を開発し、これを用いてヒューマノイドの全身運動の類似性に基づいたシンボル獲得、学習運動の再生を実現する。

2. ダイナミカル自己組織化マップ

自己組織化マップ (Self-Organizing Map : SOM)¹⁾ は、高次元入力空間から低次元出力空間への写像を教師なし競合学習によって獲得するモデルである。この写像は位相保存性を持ち、時間情報を含まないデータのクラスタリングに応用可能である。SOMを時系列信号に拡張したものとして、リカレント自己組織化マップ (Recurrent SOM : RSOM)²⁾ などがあるが、これらは信号を積分した値を学習する構造となっている。そのため信号の時間情報が失われ、似た信号どうしの区別や、学習した信号の再生には適していない。そこで本研究では時間情報を学習し、学習信号の再生を可能とするダイナミカル自己組織化マップ (Dynamics Based SOM : DBSOM) を開発する。

DSOM は、2次元平面内に $L \times L$ のユニットを持つアレイ構造を持ち、個々のユニット i は時刻 k の入力 x_k から時刻 $k+1$ の入力の予測値 \hat{x}_{k+1} を予測するパラメータ行列 Θ_k^i を持つ多項式力学系³⁾ となっている。Fig.1 にこの構造を示す。簡単のためにユニットを1次元状に描いているが、実際は2次元アレイ構造であることに注意されたい。ここで、ユニット i が出力する予測値 \hat{x}_{k+1}^i は以下のように x_k の多項式で表される。

$$\hat{x}_{k+1}^i = \Theta_k^i \phi_k \quad (1)$$

ϕ_k は入力 x_k から m 次多項式ベクトルへの関数であ




Fig.1 Architecture of DSOM

り、 Θ_k^i は多項式の係数から構成される行列である。

$$\phi_k = \phi(x_k) \quad (2)$$

$$\phi(x) = [1, x_1, x_2, \dots, x_1 x_2, \dots, x_1^m, x_2^m, \dots, x_N^m]^T \quad (3)$$

このようなユニットからなるマップ全体の学習は、 Θ_k^i の値を以下の学習アルゴリズムに従って更新することによって行われる。

学習アルゴリズム

1) bmu の探索:
現時刻の段階で入力時系列信号を最もよく記憶し予測するユニットを探索する。このユニットを best-matching unit (bmu) と呼び、bmu ユニット b は以下で定義される。

$$b = \arg \min_i \sum_{j=k-k_0+1}^k \|x_j - \hat{x}_j^i\| \quad (4)$$

つまり、bmu は過去 k_0 個に渡って予測値と実際の入力との誤差の大きさの和を最小化するユニットである。

2) パラメータの更新:

bmu 周りのユニットについて、以下の時間更新を行う。

時間更新

予測系の多項式パラメータ Θ_k^i 、共分散行列 P_k^i を逐次最小二乗法によって更新し、予測値が実際の入力値に近づくようにする。

$$\Theta_{k+1}^i = \Theta_k^i + h_b^i e_k^i a_k^i \quad (5)$$

$$P_{k+1}^i = P_k^i - h_b^i \frac{P_k^i \phi_k \phi_k^T P_k^i}{1 + \phi_k^T P_k^i \phi_k} \quad (6)$$

$$P_{k+1}^i := P_{k+1}^i / \alpha \quad (7)$$

式(7)の $\alpha(0 < \alpha \leq 1)$ は忘却係数であり, 時間更新によって Θ の持つ過去の情報が保持される大きさを表す. また, 誤差ベクトル e_k^i , 学習ゲイン a_k^i , 近傍関数 h_b^i は以下のように定義される.

$$e_k^i = x_{k+1} - \hat{x}_{k+1}^i = x_{k+1} - \Theta_k^i \phi_k \quad (8)$$

$$a_k^i = \frac{\phi_k^T P_k^i}{1 + \phi_k^T P_k^i \phi_k} \quad (9)$$

$$h_b^i = \exp\left(-\frac{d^i}{2\sigma^2}\right) \quad (10)$$

$$\sigma = \alpha \exp\left(\beta \frac{t}{t_{max}}\right) \quad (11)$$

共分散行列 P_k は多項式ベクトル ϕ_k の履歴を $\Phi = [\phi_1 \phi_2 \dots \phi_k]$ として

$$P_k = (\Phi_k \Phi_k^T)^{-1} \quad (12)$$

に相当する. 式(10)の d^i はbmuからのユニット i の距離を示し, 近傍関数 h_b^i はbmuで最大値1をとり, d^i に関する単調減少関数であり学習の強さを示す. 学習範囲の広さを示す σ の値は学習時間 t が経過するにつれて減少していく.

以上の学習アルゴリズムに従ってパラメータの時間更新を逐次的に行うことで, 隣接するユニットは似た予測値を持つようになる.

3. ヒューマノイドの全身運動の学習

DBSOMにヒューマノイドの6つの全身運動を学習させた. 学習するのは20自由度の関節角の時系列データであり, これを直接学習するのは多項式の計算量が膨大になってしまうため, 特異値分解による主成分分析によって4次元に低次元化³⁾したものを学習させた. ユニットは 10×10 の2次元構造, 多項式の次数 $m = 3$ とした.

学習を終えたDSOMに3つの低次元化された信号(4次元)を入力したときの活性化状態をFig.2に示す. 格子の1マスはそれぞれ1つのユニットを指し, 各ユニットの活性化度 s^i は以下で定義する.

$$s^i = \frac{1}{1 + \sum_{j=k-k_0+1}^k \|x_j - \hat{x}_j^i\|} \quad (13)$$

つまり, 活性化度は蓄積誤差の逆関数であり, 値が大きいほど入力をよく予測していることに相当する. Fig.2を見るとそれぞれの入力について対応する活性化領域が獲得されていることが分かる. またFig.3の(1)に, それぞれのユニットが最も活性化された入力運動の種類を示す. 各点が各ユニットを示し, 点の種類が入力運動の種類を示す. 隣り合うユニットどうしは類似した

運動を記憶し, 類似性に基づいて入力運動が配置されていることが分かる. 類似性の高いものどうしの集合としてのシンボルが獲得されている. 次にFig.3の(2)にはsquat, punchに対するbmuが記憶する低次元化信号(4次元)から3次元を選び表示する. それぞれ初期値を与え, 式(1)に従って力学系として信号を出力した. それぞれのユニットにはアトラクタが形成され, 対応する周期出力が得られている. この周期出力を20次元に復元することでヒューマノイドの全身運動を再生し, 学習運動を再現していることを確認した.




Fig.2 Degree of activity of each motion

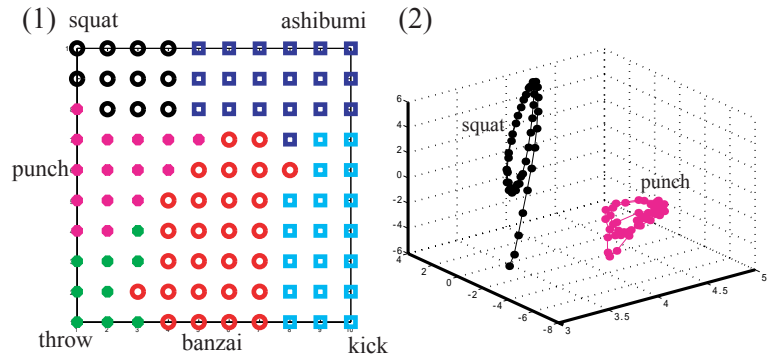


Fig.3 (1)Plot of motions that activated each unit : each point means each unit, and the type of points means input motions. (2)Trajectories generated by bmus of 'squat' and 'punch'

4. おわりに

シンボルを自己組織的に獲得するロボットの情報処理系の構築を目指し, 時系列信号の記憶・再生を可能とするダイナミカル自己組織化マップを開発した. またこれを用い, ヒューマノイドの複数の全身運動を学習し, 類似性に基づいたシンボルを獲得し, 運動再生を実現した.

参考文献

- 1) T. Kohonen: Self-Organization and Associative Memory, Spinger-Verlag, Berlin, Heidelberg, 1989.
- 2) T. Koskela, M. Varsta, J. Heikkonen, K. Kaski: Temporal Sequence Processing using Recurrent SOM, KES'98, 2nd Int. Conf. on Knowledge-Based Intelligent Engineering Systems, Adelaide, Australia, Vol 1., pp. 290-297, April 1998.
- 3) M. Okada, D. Nakamura and Y. Nakamura: "Hierarchical Design of Dynamics Based Information Processing System for Humanoid Motion Generation", Proceedings of the 2nd International Symposium on Adaptive Motion of Animals and Machines, Kyoto, March.4-8, SaP-III-1, 2003.