

自己組織化的にシンボルの獲得を行うロボットの力学的情報処理

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)

Dynamics Based Information Processing System which obtains symbols by self-organization

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

Abstract— We have proposed Dynamics Based Information Processing System(DBIPS) which designs information processing system of humanoid robot with dynamical systems. In this paper, we develop DBIPS to obtain symbols by self-organization. In precise we design Dynamical Self-Organizing Map(DSOM) which clusters time series signal in consideration of time-differential information.

Key Words: Dynamical Self-Organizing Map, Recursive Least-Squares Method, Dynamics Based Information Processing System

1. はじめに

ロボットの知的情報処理の新しいアプローチとして力学的情報処理¹⁾やミメシスモデル²⁾の構築が行われてきた。前者では力学系の持つ実時間性や、身体運動との親和性の高さを活かしてヒューマノイドの全身運動を連続的に遷移させるシステムを構築した。また後者では運動パターンを統計的に抽象化し、原始シンボルと呼ぶ記号として表し、更に原始シンボル同士の関係性を記述する空間が構成された。

本研究では力学的な情報処理と記号的な情報処理を統一的に扱うためのアプローチの第一歩として、自己組織的にシンボルを獲得する力学的情報処理系を構築し、ヒューマノイドロボットに実装することを目指す。本稿では、シンボル獲得のための機構としてダイナミカル自己組織化マップを提案する。

2. ダイナミカル自己組織化マップ

一般的な自己組織化マップ(SOM)³⁾は時間情報を含まないデータ分布のクラスタリングに用いられ、これを時間情報を含む時系列信号のクラスタリングに拡張したものにリカレント自己組織化マップ(RSOM)がある⁴⁾。RSOMは時系列信号のクラスタリングが可能であるものの、各ユニットが記憶する情報は信号のIIRフィルタリング後の値に相当し、信号の時間微分情報は加味されない。このため、同じような空間分布を持つ時系列信号の区別が困難である。そこで本稿では時間微分情報を加味したクラスタリングを行うために、ダイナミカルSOM(DSOM)を考案する。DSOMの各ユニットは多項式で表現される予測系を持ち、現時刻の入力値から次時刻の入力の予測値を学習する。

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。Fig.1にこの様子を示す。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




Fig.1 Architecture of DSOM

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 個分の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.

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

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

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

(7) 式の α ($0 < \alpha \leq 1$) 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.

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

$$= x_{k+1} - \Theta_k^i \phi_k \quad (9)$$

$$a_k^i = \frac{\phi_k^T P_k^i}{1 + \phi_k^T P_k^i \phi_k} \quad (10)$$

$$h_b^i = \exp\left(-\frac{d^i{}^2}{2\sigma^2}\right) \quad (11)$$

$$\sigma = \alpha \exp\left(\beta \frac{t}{t_{max}}\right) \quad (12)$$

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

$$P_k = (\Phi_k \Phi_k^T)^{-1} \quad (13)$$

に相当する. (11) 式の 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, また 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. 時系列クラスタの自己組織化

DSOM に複数の時系列信号を学習させる実験を行った. 学習させる時系列信号は Fig.2 に示す 3 つの 3 次元周期信号である. ユニツトは 9×9 の 2 次元構造とした.

学習を終えた DSOM に 3 つの信号を入力したときの活性状態を Fig.3 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.

$$s^i = \frac{1}{1 + \sum_{j=k-k_0+1}^k \|x_j - \hat{x}_j^i\|} \quad (14)$$

つまり, 活性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.3 を見ると, DSOM が 3 つの信号を別々にクラスタリングしていることが分かる. これは, DSOM が学習によって 3 つのクラスタを自己組織化した結果である. 各クラスタは各時系列を指し示し, この意味でクラスタは各信号のシンボルである.




Fig.2 Time series to learn




Fig.3 Degree of activity

4. おわりに

本研究ではシンボルを自己組織的に獲得するための機構としてダイナミカル自己組織化マップを提案した. また, 実際に複数の時系列を学習させ, クラスタが自己組織化される様子を確認した. 以後シンボルを自己組織化するこの機能をヒューマノイドに実装することを目指す.

参考文献

- 1) 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.
- 2) 稲邑哲也, 谷江博昭, 中村仁彦: "運動パターンの認識/生成の単一モデルとそれにもとづく離散的階層化による行動知能の集積", 第17回人工知能学会全国大会論文予稿集, pp.3D4-04(CD-ROM), 2003.
- 3) T. Kohonen: Self-Organization and Associative Memory, Spinger-Verlag, Berlin, Heidelberg, 1989.
- 4) 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.