

〈一般研究課題〉 人間と自律型ロボットの調和的な関係のための
「知覚性」の可視化手法の開発
助成研究者 中京大学 Pitoyo Hartono



人間と自律型ロボットの調和的な関係のための 「知覚性」の可視化手法の開発

Pitoyo Hartono
(中京大学)

Development of Visualization Method of Internal Characteristics of Autonomous Robots

Pitoyo Hartono
(Chukyo University)

Abstract :

The objective of this study is to develop a new hierarchical neural network model with a hidden layer that can be visualized. The developed neural network model is then implemented as a learner and controller for a physical robot. Through physical experiments, it is confirmed that the internal order that emerged from the learning process of the robot can be visualized, thus giving us intuitive understanding on the characteristics of the autonomous robot.

1. はじめに

昨今、産業以外の分野でのロボットの適用が盛んになりつつある。このようなロボットは工場のような整備された環境ではなく、時々刻々と変化する環境で動作する必要があるため、ロボットの動作戦略を完全に設計することは困難である。そのため、ロボットにある程度の自律性[1]が必要となる。ロボットの自律性の実現方法はさまざま存在するが、有効な方法の一つは動作戦略の学習[2,3]である。ロボットに学習能力があることで非整備な環境下で人間によって与えられたタスクを実行するための動作戦略を徐々に獲得することが可能であるため、ロボットの開発者は一からロボットの動作を設計する必要がないだけでなく、タスクや環境の変化にもロボットは適応することができる。ロボットに適用できる機械学習法も多く提案されているが、多層型パーセプトロン(MLP) [4]などの教師付の階層型ニューラルネットワークが最も盛んに用いられる。これらの

ニューラルネットワークの実装は容易であり、数学的にもその振る舞いは明確である。しかし、学習し終わった後、これらのニューラルネットワークの多くはblackboxとして扱うことが多い。つまり、学習によって形成された入出力関係が論理的に不明確であり、その論理性を抽出することは非常に困難である。このような、ニューラルネットワークをロボットの学習機として搭載する場合、学習によって得たロボットの動作戦略の論理性の理解をすることが難しくなり、その結果ロボットの利用性を低下させることになる。特に、安全性に関わるタスクにおいてはこのような自律ロボットの適用ができない。

本研究ではロボットに搭載可能な新しい階層型ニューラルネットワークの構築を行う。ここで提案するニューラルネットワークの中間層には2次元の格子状にニューロンを配置し、学習過程では入出力関係を正しく形成するための内部的な表現が自己組織化される。この中間層は2次元であるため、その内部構造の組織を可視化することができる。このニューラルネットワークをロボットに搭載、そのロボットのセンサー情報を入力とした場合、内部構造では、ある意味ロボットの「知覚性」が形成される。この知覚性を可視化することで、論理的ではないものの、学習によって動作戦略を獲得する自律ロボットの特性を直感的に理解することが可能となる。

本論文では、構築するニューラルネットワークの数学的な性質の説明後、計算機実験と物理環境下で動作するロボット実験の結果とその考察を報告する。

2. 可視化可能な階層型ニューラルネットワーク

本研究で開発する階層型ニューラルネットワークの概要を図1に示す。




図1 階層型ニューラルネットワークの概要

本研究ではRadial Basis Function Network (RBF)[5,6]を基に階層型ニューラルネットワークの構築を行った。RBFでは、入力ベクトルと中間ニューロンが持つ代表ベクトルとの距離によって各中間ニューロンの出力が決まるが、開発した新しいニューラルネットワークでは、中間ニューロン間の格子状での幾何学的距離も影響する。そのため、この本研究で開発したニューラルネットワークを、Restricted RBF (rRBF)と言う。

ここでは、入力 $X(t)$ において、勝者となる中間ニューロン win を以下に決定する。

$$\text{win} = \arg \min_j \|X(t) - W_j(t)\| \quad (1)$$

ここでは、 $W_j(t)$ は t 時間においての j 番目の中間ニューロンが持つ代表ベクトルを示す。
 i 番目の中間ニューロンの出力 $O_i^h(t)$ を式(2)で示す。

$$\begin{aligned} O_i^h(t) &= e^{-I_i^h(t)} \sigma(\text{win}, i, t) \\ I_i^h(t) &= \|X(t) - W(t)_i\|^2 \end{aligned} \quad (2)$$

式(2)の $\sigma(\text{win}, i, t)$ は自己組織化マップ(SOM)[7]でのベクトル更新で用いる近傍関数である。
 k 番目の出力ニューロンの値を式(3)に示す。

$$\begin{aligned} O_k(t) &= f(I_k(t)) \\ I_k(t) &= \sum_i v_{ik}(t) O_i^h(t) - \theta_k(t) \\ f(x) &= \frac{1}{1 + e^{-x}} \end{aligned} \quad (3)$$

ここでは、 v_{ik} は i 番目の中間ニューロンと k 番目の出力ニューロンの間の重みを示し、 θ_k は k 番目の出力ニューロンの閾値を示す。

学習過程では、以下の式(4)のエラー関数を減少させるために、中間層と出力層の間の重みと中間ニューロンが持つ代表ベクトルの更新を式(5)(6)で行う。

$$E(t) = \sum_k (O_k(t) - T_k(t))^2 \quad (4)$$

ここでは、 $T_k(t)$ は t 時間においての k 番目の出力に対する教師信号を示す。

$$v_{ik}(t+1) = v_{ik}(t) - \eta \frac{\partial E(t)}{\partial v_{ik}(t)} \quad (5)$$

$$w_{ij}(t+1) = w_{ij}(t) - \eta \frac{\partial E(t)}{\partial w_{ij}(t)} \quad (6)$$

式(5)の重み更新は、誤差逆伝搬法[4]と同様に計算できるが、式(6)での代表ベクトルの更新は式(7)に示す。

$$w_{ij}(t+1) = w_{ij}(t) + \eta \delta_i^h \sigma(\text{win}, i, t) (x_j(t) - w_{ij}(t)) \quad (7)$$

ここでは、 δ_i^h は i 番目の中間ニューロンに対する出力層からの一種のエラー情報と解釈することができ、数学的な導出は[8]に示す。

式(7)に示す更新則において、 $\delta_i^h > 0$ である場合、SOMと同様に代表ベクトルが更新され、 $\delta_i^h < 0$ においては、その逆方向に更新が行われる。ここから、rRBFの中間層で形成される構造がSOMで組

織化される位相構造と異なることが明らかである。

3. 実験

ロボットの実験を行う前に、rRBFに対しbenchmark問題を適用し、その振る舞いを確認した。




図2 Banana Data

まずは、図2に示すBanana Dataに関してrRBFの学習を行い、学習が終了した時点で中間層の可視化を行う(図3)。比較として、SOMにおいて同じデータを入力した場合にできる自己組織化マップも示す(図4)。rRBFにおいては、学習の目的としてはデータを二つのパターン(図2では異なる色として表す)の弁別である。

図3と図4からは、rRBFの内部に構成される構造と自己組織マップの構造が明らかにことなることがわかる。その主な理由は、SOMでは入力データの位相構造のみ反映されるに対し、rRBFでは入力データの位相構造だけでなく、ニューラルネットワークの学習性質が反映されている。つまり、rRBFではある意味弁別器の「知覚性」もマップとして表現されている。




図3 rRBF: Banana Data




図4 SOM: Banana Data

rRBFの動作確認を人工的なBanana Dataを用いて行なった後、rRBFをロボットに搭載し、実験を行う。ここでは、図5に示すe-puck(図5)を実機ロボットとして用い、実験の様子は図6に示す。



図5 E-puck




図6 実験の様子

ここでは、ロボットには8つの距離センサーがあり、図6に示す障害物のある環境下での状況を「危険」または「安全」の二つの状態に弁別することを学習する。学習後にできた内部状態の構造を図7に示す。

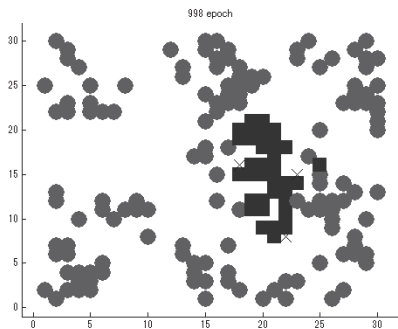


図7 rRBF: ロボット学習




図8 SOM: ロボット学習

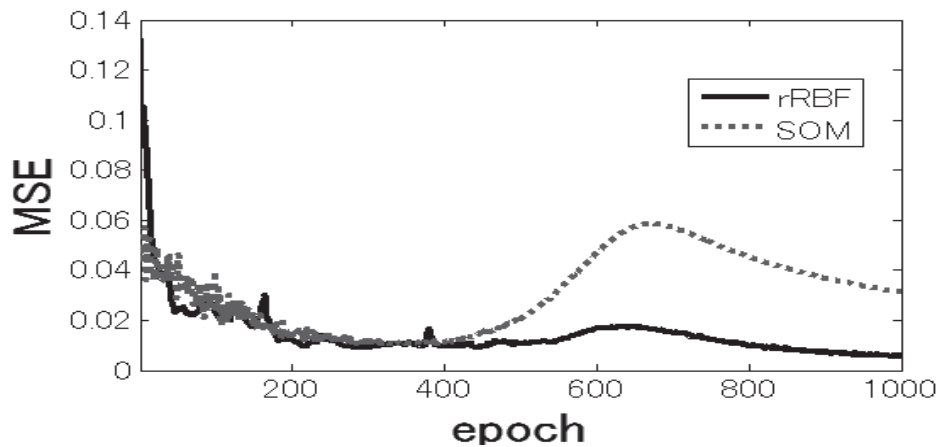


図9 学習曲線

図7と図8では、ロボットが危険な状況にある場合のニューロンの発火を青で示し、安全な場合は赤で示す。これらの図から明らかにrRBFの内部で構成される構造とSOMでの構造が異なる。図9は、rRBFの学習曲線と、中間層がSOMである階層ネットワークの学習曲線を示す。この図からは、rRBFの方がよく学習できることがわかる。

本研究では、「知覚性」の可視化により、論理的ではないものの、ある程度ロボットの動作戦略において直感的に理解することが期待できる。

4. 結論と今後の課題

本研究では、先ず内部組織が可視化可能な新しい階層型ニューラルネットワークを数学的に構築し、その基本動作の確認をすることができた。初期段階であるが、構築したニューラルネットワークを実機ロボットに搭載し、物理空間での学習の結果、形成されるロボットの「知覚性」の可視化も行うことができた。今後、様々な構造や学習法を用いたロボットにおいて、形成される「知覚性」の特性に関する考察を行うと共に、人間がより学習ロボットを直感的に理解できる内部組織の提示手法に関しても研究を行う。また、この手法を用いて初期実験で行った教師付学習を拡張し、能動的学習においても検討したい。

参考文献

- [1] G. Bekey, *Autonomous Robots*, The MIT Press, Cambridge (2005).
- [2] S. Nolfi and D. Parisi, *Learning to Adapt to Changing Environments in Evolving Neural Networks*, *Adaptive Behavior* Vol. 5, pp. 99-105 (1997).
- [3] P. Hartono, and S. Kakita, *Fast reinforcement learning for simple physical robots*, *Memetic Computing*, Vol. 1, No.4, pp. 305-313 (2009).
- [4] D. Rumelhart. and J. McClelland, *Learning Internal Representation by Error Propagation*, *Parallel Distributed Processing*, Vol.1, MIT Press, pp.318-362 (1984).
- [5] J. Moody and C. J. Darken, *Fast Learning in Networks of Locally Tuned Processing Units*, *Neural Computation*, Vol. 1, pp. 281-294 (1989).
- [6] T. Poggio and F. Girosi, *Networks for Approximation and Learning*, *Proceedings of IEEE*, Vol. 78, No, 9, pp. 1484-1487 (1990).
- [7] T. Kohonen, *Self-organized Formation of Topologically Correct Feature Maps*, *Biological Cybernetics*, Vol. 43, pp. 59-69 (1982).
- [8] P. Hartono, and T. Trappenberg, *Classificability-regulated Self-Organizing Map using Restricted RBF*, *Proc. IEEE Int. Joint Conf. on Neural Networks 2013* (accepted).