

Deep Belief Net を使った状況依存型予測器の学習 Learning of the situation-dependent predictor by use of Deep Belief Net

藤田徹也 (PY)[†], 荻野正樹[‡], 福家佐和[†], 浅田稔^{†‡}

Tetsuya Fujita(PY), Masaki Ogino, Sawa Fuke, and Minoru Asada

[†] 大阪大学大学院工学研究科知能・機能創成工学専攻

[‡]JST ERATO Asada Project

tetsuya.fujita@ams.eng.osaka-u.ac.jp

Abstract— We propose a situation-dependent predictor which can change prediction depending on the object's shape and the environment. In order for a robot to obtain the concepts by itself, we propose an attention model with which a robot decides what to attend and when to search a new object.

Keywords— Anticipation, Restricted Boltzmann Machine, Object Permanence

1 はじめに

認知発達ロボティクスの分野では、幼児の物体永続性に着目し、その振る舞いを実現するいくつかのモデルが提案されている [1] [2]。これらの研究は特定の環境内の特定の対象に対する注意のみを扱っている。しかし、注目対象の特徴が同じでも、環境が異なればその挙動は異なり、また逆に環境が同じでも対象が異なれば挙動は変化する。つまり実際の物体永続性、またより一般に様々な物理的因果性を獲得するためには多様な環境、多様な対象に対する予測ができることが必要である。

そこで本研究では、ニューラルネットワークの一種である Restricted Boltzmann Machine(以下 RBM) [4] [3] を用いた状況依存型予測器を提案する。状況依存型予測器とは、環境情報と注視対象の特徴を合わせた変数として「状況」を考え、状況と対象の挙動を統合する予測器である。本予測器が、各々の状況を踏まえ、様々な現象に対して、その予測に応じた注意が可能であることを示し、更に自律的に様々な因果性を獲得するための注意モデルを提案する。

2 RBM を用いた予測とその性能

2.1 RBM を用いた予測

RBM は表出層と隠れ層からなるニューラルネットワークの一種で、その特徴は連想記憶型ネットワークである点、そして自己組織化が可能である点にある。連想記憶型であるためノイズにロバストで、補完能力がある。この性質を利用し、予測器は現在の状況および注目物体の現在の状態と次状態への変化を学習する。これにより、現在の状況、状態のみから次状態を出力できるようにな

る。

状況に依存して予測を変化させるために、環境を学習する RBM(環境モジュール) と予測を学習する RBM(予測モジュール) の 2 種類の RBM を用意する。図 1 に予測器の全体像を示す。

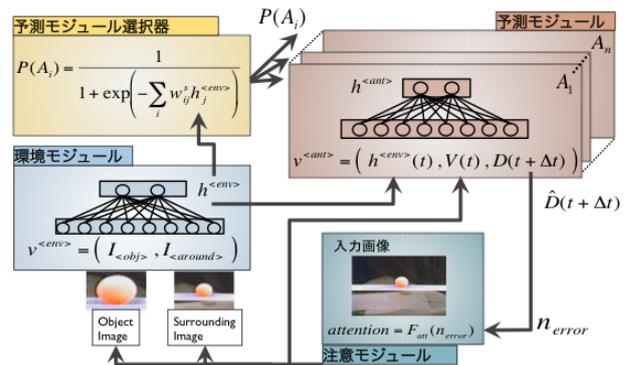


図 1: Model of situation-dependent predictor

2.2 予測器の概要

入力画像から注目物体を切り出し、物体画像とその周辺画像のエッジ情報を環境モジュールに入力する。RBM の隠れ層は特徴抽出器として機能するため、隠れ層の出力 $h^{<env>}$ は環境情報と物体情報の特徴を合わせた変数となる。以下これを「状況」と呼ぶ。

予測モジュールは前ステップから現在のステップへの挙動を学習するため、前ステップにおいて環境モジュールから得られた状況 $h^{<env>}(t - \Delta t)$ と、注目物体の速度 $V(t - \Delta t)$ 、そして前ステップから現在の位置への変位 $D(t)$ のデータセットを連想記憶として学習し、 $h^{<env>}(t), V(t)$ から $\hat{D}(t + \Delta t)$ を予測する。

注意モジュールは前ステップで得られていた $\hat{D}(t)$ と $D(t)$ の差 n_{error} から注意を維持するかを決定する。

2.3 実験と結果

図 2 に示す 3 状況 (ボールの水平、鉛直、振り子運動) について予測実験をおこなった。なお注目物体として予めボールを設定してある。

実験結果 (図 3) について、縦軸 Error Rate は予測と

実際の位置のずれを正規化したもので、横軸 Learning Times は全状況のデータセットを全て学習し1回の学習としている。凡例については、時間分割を示す線色と画面分割を示す線種を組み合わせ参照されたい。これより全てのRBMで予測が学習できていることがわかる。

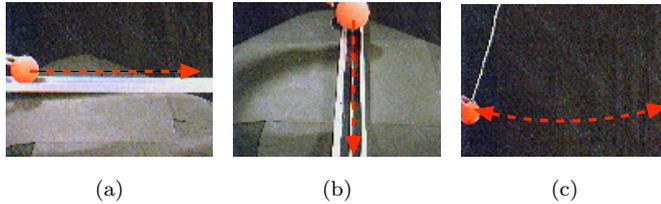


図 2: Situation of experiment

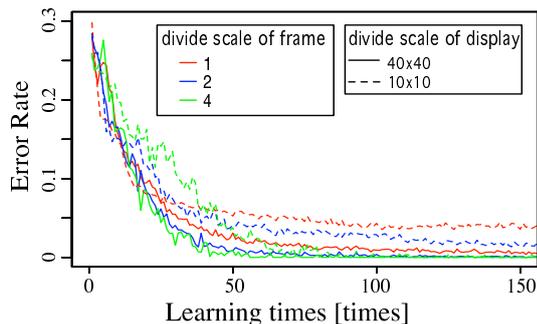


図 3: Error rate of experiment

3 注意に基づく予測とその性能

3.1 注意モジュールの設計

前述のような物体の運動予測モデルを学習するにあたり、事前に実験者が注目物体を与えずとも、ロボットが自発的に注意を向け入力値を求めることが望ましい。人において注意の遷移には解放、移動、保持の3つのステップがあり、注意をモデル化するにあたり、注意の保持と解放の指針が重要となる。すぐに学習でき予測が可能となるもの(静止状態など)やすでに学習が終了したもの、また挙動が完全にランダムで全く予想できないものからは注意を外すことが望ましい。そして、その挙動が規則的で、かつまだ完全に学習できていない物体に対して注意を維持する必要がある。

注意の保持について、注目物体の決定は顕著性マップ [5] を用いる。画面の中から色や明度、動きの点で顕著な部分に着目し着目点と同色の点の集合を注目物体とする。こうして切り出した画像を物体画像、物体中心で大きさが入力画像の縦横半分の画像を環境画像とする。

注意の解放について、予測モジュール群の正誤から求められる注意値がある閾値を下回れば注意を解放する

モデルを考案した。

3.2 実験と結果

結果の例を図4に示す。ここで黒枠が現在注意を向けている物体である。ボールの動く先を予測できていることがわかる。

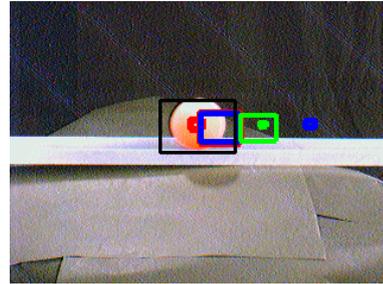


図 4: A prediction of horizontal motion

4 結言

本研究では、環境情報と物体情報の特徴を抽出した状況と物体の挙動を統合する、「状況依存型予測器」を提案した。ロボットは複数の環境におけるボールの運動の予測を、状況に応じて変化させることが可能となった。更に、RBMへの入力情報を選択する行動として注意メカニズムを考慮して実験をし、自発的に注目物体を決定しながら、その物理的因果性を獲得できる可能性を示唆した。

参考文献

- [1] M. Schlesinger (2003) "A lesson from robotics: Modeling infants as autonomous agents" Adaptive Behavior, Vol.2 No.2.
- [2] Andrew Lovett and Brian Scasselatti (2004) "sing a robot to reexamine looking time experiments" 4th International Conference on Development and Learning (ICDL).
- [3] Geoffrey E. Hinton et al (2006) "A fast learning algorithm for deep belief nets" Neural Comput., 18, 1527-1554.
- [4] Geoffrey E. Hinton (2007) "Learning multiple layers of representation" TRENDS in Cognitive Sciences, Vol.11 No.10, 428-434.
- [5] Laurent Itti and Nitin Dhavale and Frederic Pighin (2003) "Realistic avatar eye end head animation using a neurobiological model of visual attention" Proceedings of SPIE.