

ロボットによる物体押し動作における 環境ダイナミクス影響因子の推定法

Estimation of environmental dynamics affecting factors in pushing manipulation of object by a robot

稲葉 貴大 (静岡大) 正 小林 祐一 (静岡大) 金子 透 (静岡大)

Takahiro INABA, Shizuoka University
Yuichi KOBAYASHI, Shizuoka University
Toru KANEKO, Shizuoka University

In object pushing manipulation by camera mouted two-wheels-robot, we propose a way of extraction and estimation of element that affect behavior of object from image feature. We verify the way of object behavior estimation based on estimation of movement of feature points with respect to robot motion.

Key Words: Mobile Robot, Extract Visual Feature, Behavior Learning

1 はじめに

近年、自律型ロボットの災害現場での活躍が期待されている。災害現場にはロボットの運動を妨げる物体が多く存在し、ロボットはこれらの物体を操作し自身の行動範囲を拡大する必要がある。その為ロボットには目の前に存在する物体について、ロボットによって動かすことができる物かどうかやロボットの運動によってどのように運動するのか、どのような場合にその挙動を生成するのかなど、

物体の運動に関する情報を自律的に判断し記憶することが求められる。視覚センサを用いて物体を認識、識別する研究として文献 [1] がある。文献 [1] ではあらかじめ用意した画像を用いて教師なし学習を行った後、カメラに映った物体の認識を行っている。文献 [1] では、物体の運動に関する情報による識別を行うことはできない。また、実際に物体に力を作用させ、その際の物体の振る舞いにより物体を識別する研究として文献 [2] がある。文献 [2] ではロボットは物体を掴み、様々な角度から観察する。そのときに得られた情報を用いて、物体の分類を可能としている。しかし、ロボットが物体操作を達成するための識別ではなく物体をラベリングするための識別を行っている。

本研究では、ロボットのセンサ情報およびロボットの動作情報を用い、物体の押し動作において物体の挙動に影響する要素を画像特徴から抽出・推定する方法を提案する。

2 問題設定

単眼カメラを搭載した移動ロボットを用いて物体に対して押し動作を行い、得られた画像特徴とロボットの動作情報を用いて物体の挙動に影響する要素の抽出・推定を行う。使用するロボットは図 1 に示すような車輪移動型のロボットであり、無線式の単眼カメラを搭載する。ロボットの動作環境は段差の無い平面とし、平面上にはロボットによって押すことが可能な物体が存在する。ただし、物体の位置、大きさ、外見の情報は未知である。本研究で使用する物体を図 2 に示す。

ロボットは物体の中心部分や端部分などに対して直進や旋回など様々な動き方で押し動作を行い、その際に搭載カメラより得ら



Fig.1 Two-wheels-robot



Fig.2 Object

れた画像情報とロボットのモータ情報を用いて物体の挙動に影響する特徴点の抽出・推定を行う。

3 環境ダイナミクス影響因子の推定法

3.1 概略

まず最初に物体ロボットは物体に対して押し動作を行い、その際に搭載カメラよりロボットの動作前画像と動作後画像を取得する。繰り返し押し動作を行い画像群を取得後、それぞれの画像より画像特徴を取得する。画像特徴には SIFT(Scale Invariant Feature Transform)[3] を用いる。画像特徴の取得の際に特徴点の追跡を行い、特徴点毎にクラスタを作製する。その後、各クラスタ毎に、そのクラスタに属する特徴点群とロボットのモータデータに対して EM アルゴリズムを用いた NGnet[4] を適用し、各クラスタの特徴点群がモータデータに対しどのように動くかを推定する。次にクラスタ毎の特徴点に対して LDA(Liner Discriminant Anarysis) を行い、クラス所属確率を取得する。取得したクラス所属確率に対して CCA(Canonical Correlation Analysis) を行い、各クラスタに関して相関係数を取得する。その後、データの検証を行う。処理概要を図 3 に示す。

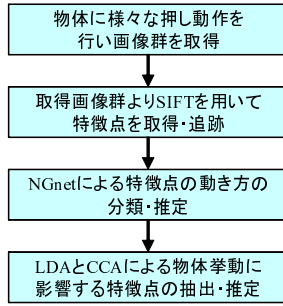


Fig.3 Outline of processing



Fig.4 Example of camera image

3.2 観測・行動データ収集条件

ロボットは物体に対して様々な押し動作を行い、搭載カメラよりロボットの動作前と動作後の画像を取得する。今回は物体の中心部分、および右端部分に対し様々な動き方で押し動作を行った。取得カメラ画像例を図4に示す。

ロボットの動作は右側モータの毎秒ステップ数 m_r と左側モータの毎秒ステップ数 m_l によって制御されるが、今回はパラメータ ϕ を用い、下式のように単純化する。

$$m_r = \frac{C}{2} - \phi \quad (1)$$

$$m_l = \frac{C}{2} + \phi \quad (2)$$

ここで C は定数である。図5(a)にロボットのモータデータの例を示す。得られた画像より時系列順に特徴点を抽出し、特徴点の画像上での x 座標 x と y 座標 y およびロボットの移動前画像と移動後画像でマッチングに成功した特徴点の x 方向移動量 Δx 、 y 方向移動量 Δy を取得する。また同時に各特徴点の128次元の特徴ベクトル $\mathbf{V} = [v_1, v_2, \dots, v_{128}]$ を取得する。図5(b)に画像からの特徴点の取得例および特徴点移動量例を示す。特徴点間のマッチングには MeanShift[5] を用いる。MeanShift はクラスタリング手法のひとりであり、クラスタ数を自動的に推定するものである。 \mathbf{V} に対して MeanShift を行う、似ている特徴点を同じクラスタに集めることでマッチングを可能とする。

3.3 NGnet による環境ダイナミクスの識別

MeanShift によって同じクラスタに集められた特徴点群の各々の移動量 $\Delta \mathbf{x} = [\Delta x \ \Delta y]$ は様々な動き方をしたものが混在している状態である。そこで混合ガウス分布を用いて特徴点の動き方の分類を行う。また、 ϕ と $\Delta \mathbf{x}$ に対して NGnet を用い、特徴点

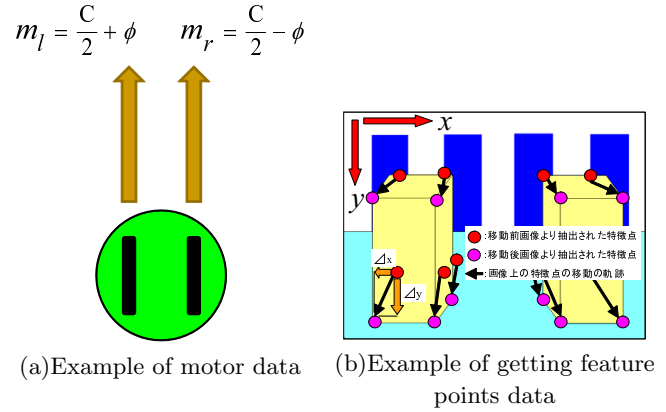


Fig.5 Example of collecting data

の動き方の推定を行う。混合ガウス分布の推定および NGnet のパラメータの更新には EM アルゴリズムを用いる。

3.4 LDA と CCA による影響因子の推定

$\Delta \mathbf{x}$ と分類された特徴点の動き方に対して LDA を行う。LDA はクラス間の分散を最大化するような教師ありの次元削減法である。全データ数を n 、全データの集合を $\Delta \mathbf{X} = \{\Delta \mathbf{x}^{(1)}, \Delta \mathbf{x}^{(2)}, \dots, \Delta \mathbf{x}^{(n)}\}$ 、 $\Delta \mathbf{X}$ の平均を $\overline{\Delta \mathbf{x}}$ とする。また、クラス数を C 、クラス i に属するデータ数を $n^{(i)}$ 、クラス i に属するデータ集合を $\Delta \mathbf{X}^{(i)} = \{\Delta \mathbf{x}_{(i)}^{(1)}, \Delta \mathbf{x}_{(i)}^{(2)}, \dots, \Delta \mathbf{x}_{(i)}^{(n^{(i)})}\}$ 、 $\Delta \mathbf{X}^{(i)}$ の平均を $\overline{\Delta \mathbf{x}^{(i)}}$ とする。とする。この時、クラス内分散 W とクラス間分散 B は下式で求められる。

$$W = \frac{1}{n} \sum_{i=1}^C \sum_{\Delta \mathbf{x} \in \mathbf{X}_i} (\Delta \mathbf{x} - \overline{\Delta \mathbf{x}^{(i)}})(\Delta \mathbf{x} - \overline{\Delta \mathbf{x}^{(i)}})^T \quad (3)$$

$$B = \frac{1}{n} \sum_{i=1}^C n^{(i)} (\overline{\Delta \mathbf{x}^{(i)}} - \overline{\Delta \mathbf{x}})(\overline{\Delta \mathbf{x}^{(i)}} - \overline{\Delta \mathbf{x}})^T \quad (4)$$

ここで $W^{-1}B$ の大きな固有値 $\lambda_1, \lambda_2, \dots, \lambda_{C-1}$ の固有ベクトルを $\{A_1, A_2, \dots, A_{C-1}\}$ とし、 $A = [A_1, A_2, \dots, A_{C-1}]$ とする。 $A^T \Delta \mathbf{X}$ により、 $\Delta \mathbf{X}$ を $C-1$ 次元の空間に次元削減する。また、この際に各データのクラス所属確率 $P(C|\Delta \mathbf{x}^{(i)})$ を取得する。

3.5 CCA

$P = [P^{(1)} \ P^{(2)} \ \dots \ P^{(n)}]^T$ と $\mathbf{X} = [x^{(1)} \ x^{(2)} \ \dots \ x^{(n)}]^T$ に対して CCA を行い相関係数 r を取得する。ここでの $P^{(i)}$ 、 $x^{(i)}$ は全特徴点 n 個の内 i 番目の特徴点のクラス確率 $P^{(i)} = P(C|\Delta \mathbf{x}^{(i)})$ と特徴点位置 $x^{(i)} = [x^{(i)} \ y^{(i)}]$ である。重み係数をそれぞれ $\mathbf{a} = [a^{(1)} \ a^{(2)} \ \dots \ a^{(n)}]$ 、 $\mathbf{b} = [b^{(1)} \ b^{(2)} \ \dots \ b^{(n)}]$ とすると、線形合成変量 U, V は下式で求められる。

$$U = \mathbf{aP} \quad (5)$$

$$V = \mathbf{bX} \quad (6)$$

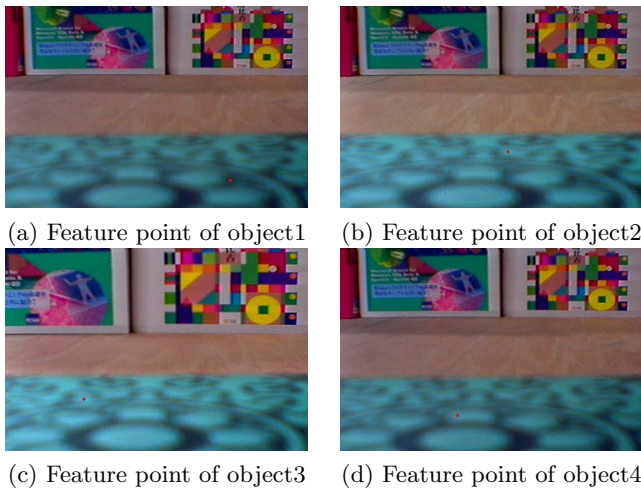


Fig.6 Feature points of object

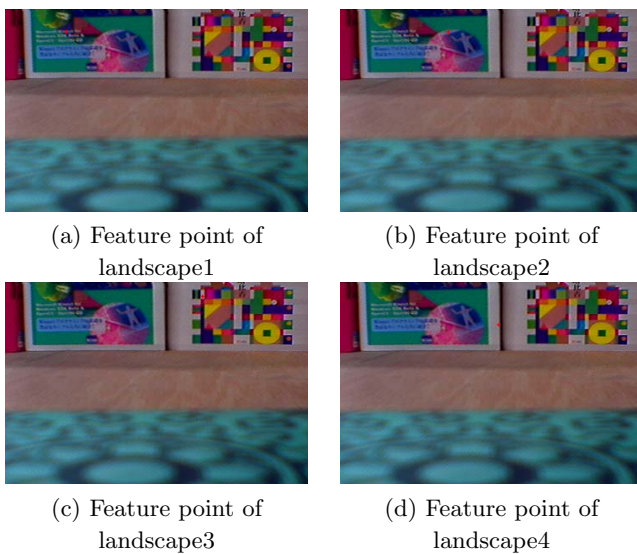


Fig.7 Feature points of landscape

合成変量の相関係数 r を最大にする a, b を求めることで r が求められる。 r が大きい特徴点が物体の挙動に影響する特徴点であると考えられる。

4 実験

一連の処理を行い、それぞれの処理において得られたデータについての検証を行う。今回の処理で得られた特徴点は物体特徴点 27 種類、背景特徴点 250 種類であった。物体特徴点、背景特徴点それぞれ 4 種類について検証を行う。図 6 に対象とする物体特徴点を、図 7 に対象とする背景特徴点を示す。赤い点で示されたものが特徴点である。

4.1 NGnet の結果

図 8 に物体特徴点の EMNGnet の結果を、図に背景特徴点の EMNGnet の結果を示す。白抜き丸は各特徴点のデータであり、丸の色はその特徴点の挙動がどのクラスに属しているかを示している。また、 \times マークは各クラス重心である。直線は各クラスデータを NGnet により関数近似した結果を示している。ここでは物体特徴点と背景特徴点の間に明確な差異を認めることができなかった。

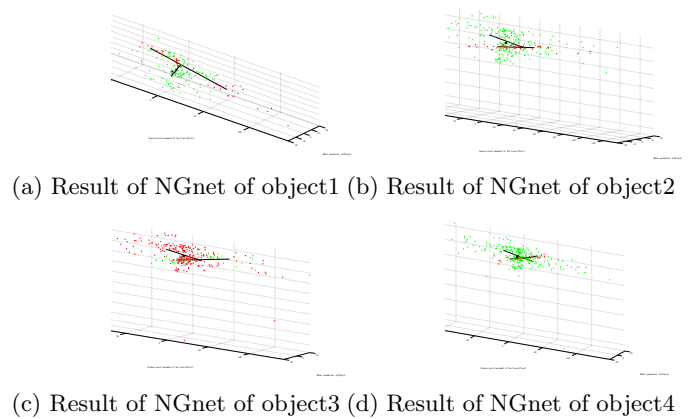


Fig.8 Result of NGnet of object

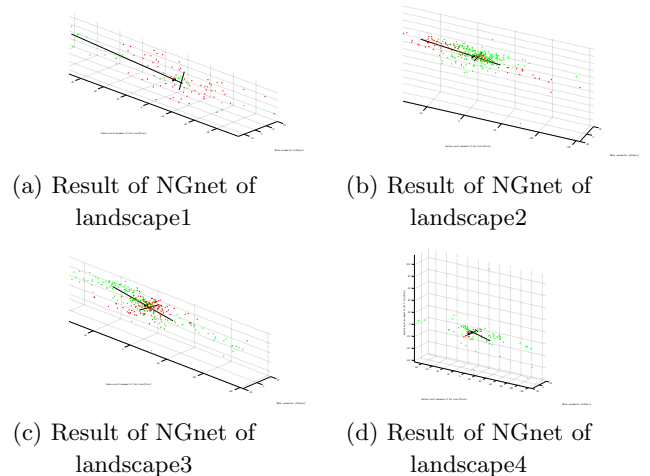


Fig.9 Result of NGnet of landscape

4.2 CCA の結果

図 10 に物体特徴点に対する、図 11 に背景特徴点に対する各特徴点の x 座標、 y 座標をプロットしたものを示す。プロットの色は特徴点の動き方のクラスを示す。表 1 に各特徴点に対し CCA を行った結果を示す。背景特徴点に関しては全体的に相関係数が低かったが、物体特徴点に関しては相対的に相関係数が高い物が認められた。物体特徴点に関して、表 1 より、相関係数は最小で 0.0804、最大 0.5432 と大きく幅があることが分かる。図 10 を見ると相関係数が最小である物体特徴点 4 は異なるクラスの特徴点が混在している状態であり、そのため相関係数が低くなったものと考えられる。また、相関係数が最大となる物体特徴点 3 に関しては、青色のクラスの密集している部分が存在するが、赤色のクラスが混在してはいない。そのため LDA によってクラスを明確に分けることができたため相関係数が高くなったものと考えられる。背景特徴点に関して、表 1 より、相関係数は最小で 0.1246、最大 0.3651 と物体特徴点と比較して相関係数の幅は小さくまた全体的に低いことが分かる。図 11 を見ると全ての特徴点のプロット図において 2 つのクラスが混在している状態である。そのため LDA によってクラスを明確に分けることが困難となり、相関係数が低くなったものと考えられる。

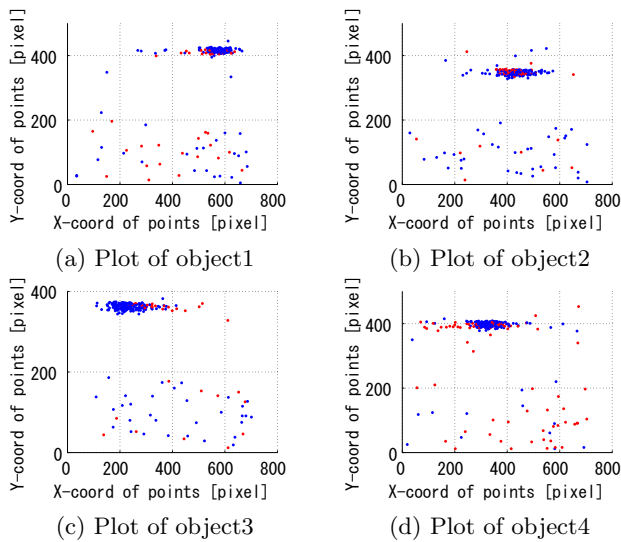


Fig.10 Plot of object

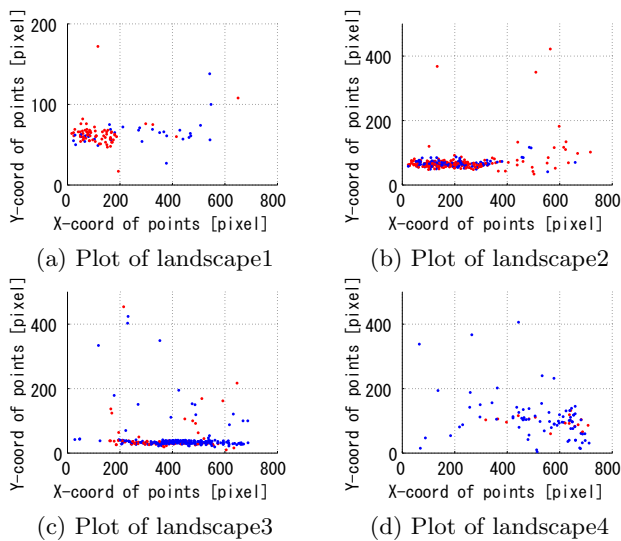


Fig.11 Plot of landscape

5 おわりに

ロボットのセンサ情報およびロボットの動作情報を用い、物体の押し動作において物体の挙動に影響する要素を画像特徴から抽出・推定する方法を提案した。処理したデータの検証を行い、物体の特徴点の中から物体の挙動に影響すると思われる特徴点の抽出に成功した。今後は抽出した特徴点にたいして実機実験を用いてどのように物体の挙動に影響するかを検証する。

謝辞

本研究の一部は中部電気利用基礎研究振興財団の助成を受けて行われた。

References

- [1] H. Madokoro, Y. Utsumi, K. Sato : “Scene Classification Using Unsupervised Neural Networks for Mobile Robot Vision,” Proc. Society of Instrument and Control Engineers (SICE) Annual Conference 2012, pp.1568-1573, 2012.
- [2] 中村友昭, 長井隆行, 岩橋直人 : “ロボットによる物体のマルチモーダルカテゴリゼーション”, 電子情報通信学会論文誌, Vol.J91-D, No.10, pp.2507-2518, 2008.

Table 1 Result of CCA

物体	
特徴点	相関係数
物体特徴点 1	0.3066
物体特徴点 2	0.2419
物体特徴点 3	0.5432
物体特徴点 4	0.0864
背景	
特徴点	相関係数
背景特徴点 1	0.3651
背景特徴点 2	0.2484
背景特徴点 3	0.1246
背景特徴点 4	0.1753

- [3] David G. Lowe : “Distinctive Image Features from Scale-Invariant Keypoints” , International Journal of Computer Vision , Vol.60, No.2, pp.91-110, 2004.
- [4] J. Moody , C. J. Darken: “Fast Learning in Networks of Locally Tuned Processing Units” , Neural Computation , Vol.1, pp.281-294, 1989.
- [5] Dorin Comaniciu, Peter Meer, Member, IEEE, Senior Member, IEEE : “Mean shift: A Robust Approach Toward Feature Space Analysis” , IEEE transactions on pattern analysis and machine intelligence , Vol.24, No.5, pp.603-619, 2002.