

全方向移動ロボットの異常行動検出

阿知波宏樹[†] 村上 和人[†]

[†] 愛知県立大学大学院情報科学研究科

愛知郡長久手町熊張

E-mail: [†](im081001@cis, murakami@ist).aichi-pu.ac.jp

あらまし 本論文では、全方向移動ロボットの異常を検出するための一手法を提案する。全方向移動ロボットの速さと角速度をコンピュータで目的地に至るまで時系列的に計算する。同時に、実際の速さと角速度をグローバルビジョンシステムを用いて取得する。次に、SVMに正常時の行動と異常時の行動を学習させ、正常行動と異常行動を識別する。提案手法をロボカップ小型リーグの環境に適用したところ、正常行動と特徴的な異常行動を学習させた場合に、約80%の検出精度が得られたことを報告する。

Abnormal Motion Detection of Omni-derectional Robot

Hiroki ACHIWA[†] and Kazuhito MURAKAMI[†]

[†] Graduate School of Information Science and Technology, Aichi Prefectural University

Kumabari, Nagakute-cho, Aichi-gun

E-mail: [†](im081001@cis, murakami@ist).aichi-pu.ac.jp

Abstract This paper proposes a method to abnormal motion detection of omni-derectional robot. The speed and the angle speed are calculated to the destination with the computer in the time series. And an actual speed and the angle speed of Omni-derectional Robot are acquired by using the global vision system. Next, normal motion and abnormal motion are studied to SVM, and a normal motion and the abnormal motion are identified. The proposal technique was applied to the circumstance of a RoboCup Small Size League. Then, it reports that the detection accuracy of about 80% was obtained when a normal action and the feature abnormal motion are studied.

1. はじめに

近年のロボットは自律型へ推移し、動作方向も前後左右だけでなく、状況に応じて360度どの方向へも動けるようになってきている。このように、状況に応じて動きを変えろボットに対してある場面での行動が、正常であるか異常であるかをいち早く判別できれば、深刻な問題が表れる前に対処が可能となり、全体に及ぼす影響を最小限に抑えることができると考えられる。熟練者は、異常発生とともに、その原因まで推定することができる。しかし、初心者は異常が発生したかどうか、また、それらの原因を推測することすら困難である。よって、異常検出システムを構築する必要性が考えられる。

産業用ロボットの動く方向が限られることを利用した異常検出法として、多数のカメラを配置し、固有空間法を用

いて異常を検出する研究事例が報告されている[1]。しかし、この手法では、全方向移動ロボットのように向きと進行方向が時々刻々と変化するような対象には適用できない。そこで、位置と向き(姿勢)が同時に変化するロボットでも、異常行動が検出可能な手法を提案する。

以下、本論文では、2章で全方向移動ロボットの異常行動と、異常行動を検出するために取得するパラメータ例を示し、3章でロボカップ小型リーグ環境に適用した実験例を示し、4章で提案手法の有効性について考察する。

2. 全方向移動ロボットの正常行動と異常行動

本論文では全方向移動ロボットの動きの異常に関してのみ取り扱うこととする。

図1にロボットの一例を示す。ロボットの車輪には、4軸のオムニホイールが使用され、360度どの方向へも移動

可能となっている。オムニホイールは、大きな車輪の周りに小さな車輪が複数付いた構造になっており、この小さな車輪が横向きの力を逃がすことによって、全方向移動、また回転を可能にしている。



図 1 ロボット

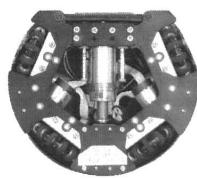


図 2 オムニホイール

これらのロボットは、摩擦、ロボットの個体差、外的要因が加わるため、状況に応じて速さ、向き、揺らぎも異なる。熟練者であれば、このような変化を視認することも可能だが、初心者では微小な速度変化を認識するのは困難であり、速さ、向きといったデータ取得して判断する必要があると考えられる。

ロボットの動きはロボットの上部にマーカーを付けることによって、ロボットの位置と向きを検出できる。しかし、全方向移動であるため、正常と異常の判断がつきにくい場合がある。

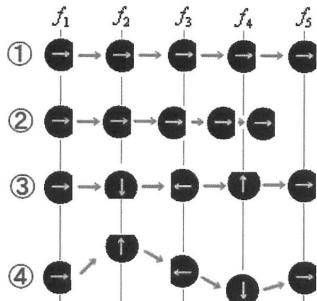


図 3 様々なロボットの動き

図 3 は、あるフレーム $f_1 \sim f_5$ におけるロボットの動きを示す。ここで、ロボット内に書かれた矢印はロボットの向き、ロボットの外に書かれた矢印はロボットの移動方向を示す。この①～④の動きの中で、どれが正常でどれが異常かということを一概に言つことはできない。なぜならば、全方向に動くことができるため、目的によって動きが変わるものからである。また、摩擦や個体差によっても動きが異なる。例えば、①のように動いて欲しいにもかかわらず、②～④のように動いてしまった場合は、異常が発生していると考えられる。そのため、状況に応じた動きを学習させる必要があると考えられる。

速度および角速度は、コンピュータで目的地に至るまで

時系列的に計算される。ある時刻におけるロボットの実速度は、ビジョンデータから得られる前フレームの位置と現在地との差分を取ることにより得られる。また、実角速度はロボットの向きの差分を取ることによって得られる。

そこで、異常行動を判別するために、次の 4 つのパラメータを取得する。

- ロボットに与える x 方向速度、 y 方向速度から得られる速さ
- ビジョンデータから得られる位置と直前フレームの位置差分によって得られる x 方向速度、 y 方向速度から得られる速さ
- ロボットに与える角速度
- ビジョンデータから得られる現フレームでの向きと前フレームでの向きとの差分によって求められる角速度

これら 4 つのパラメータを、非線形分離でマージンを最大にして分離を行う SVM を使用し、正常時と異常時におけるそれぞれの速さと角速度を SVM で学習させることによって判別を行う。

3. SVM を用いた正常行動と異常行動の分類実験

3.1 実験環境 — ロボカップ小型リーグ

ロボカップ小型リーグ [3] では、直径 18cm、高さ 15cm 以内のロボットを用いて 5.0m × 3.5m の大きさのサッカーフィールド上で 5 台対 5 台の試合を行う。フィールド全体を見渡すカメラ、あるいはロボット搭載カメラからの視覚情報をベースに、ロボットを協調動作させている。

ロボカップ小型リーグのシステム構成を図 4 に示す。フィールド上では、各チーム最大 5 台のロボットと、オレンジ色のゴルフボールを用いて試合が行なわれる。システムは大きく分けて、ビジョンシステム、ロボットシステム、ホストシステムの大きく 3 つに分けられる。

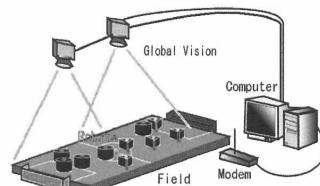


図 4 システム構成

カメラから入力された画像 (図 5) をルックアップテーブル方式で 8 色のカラー画像 (図 6) に変換した後、ラベリングを行ない、ロボット、ボールの位置を検出する。検出された位置をもとに、戦略プロセスで状況に応じてロボットの位置、方向を決定し、経路生成モジュールがそれぞれの

ロボットの経路を決定する。戦略と経路情報に基づいてロボットに与えるコマンドを生成し、無線を使ってロボットに送信する。コマンドに含まれる情報は、速度、相対進行方向、角速度、ドリブル装置の制御、キック装置の制御である。ホストシステムでは、画像入力からロボットへのコマンド送信までを 1/60 秒の周期で実行している。

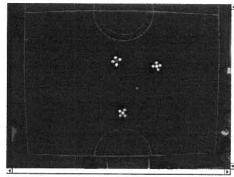


図 5 入力画像

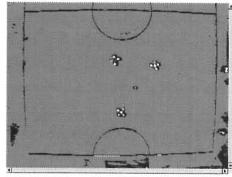


図 6 ラベリング画像

3.2 学習データの採取

SVM に学習させるために、次に示す行動パターンのデータ取得を行った。

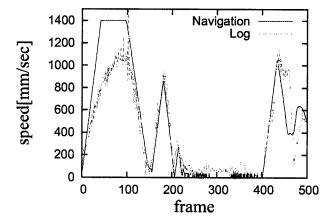
- 正常行動
- 特徴のある異常行動
 - 静止状態 = 速さ、角速度を与えて、実際の速さと角速度は 0 付近となる
 - タイヤのトルク不良 = 速さの振幅は小さくなり、角速度は一致しない
 - 暴走状態 = 速さは一致しているように見えるが、角速度の振幅は大きくなる
 - 特徴のない異常行動
 - 速さも角速度も、一致する場所と一致しない場所がある。

特徴のない異常行動は、電池の消耗、外的要因、何らかの要因によって制御がうまくいっていない場合を想定した。このような異常の場合、ロボットの行動に遅延が生じる場合がある。そこで、コンピュータからロボットに与えられる値と、フレーム差分による値のフレームに人工的な手を加え、ずらすことによって遅延を再現した。

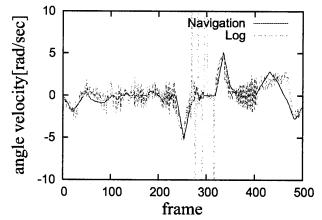
本来、数フレーム程度の情報を見ただけでは、その行動が正常であるか異常であるかの判断はつかない。そこで、特徴のある異常行動のデータ取得は、ロボットの配線を変えるなどハードウェアに変更を加え、人為的に異常行動を起こる状態にしてデータの取得を行った。

正常行動時のデータを図 7 に、ハードウェアに変更を加え取得した特徴のある異常行動時のデータを図 8～図 10 に、また、人工的に手を加えた特徴のない異常行動時のデータを図 11 に示す。データは、事前に取得したロボットの動きの時系列情報（ログデータ）を用い、障害物が存在しないという前提条件を付加して取得した。

ここで、実線（Navigation）はコンピュータからロボットに与えられる値、波線（Log）はフレーム差分から得られる計測値である。また、縦軸は（a）では速さ、（b）では角速度である。

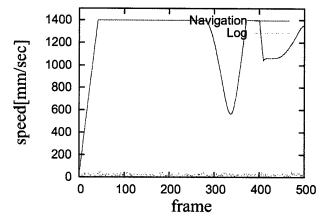


(a) 速さ

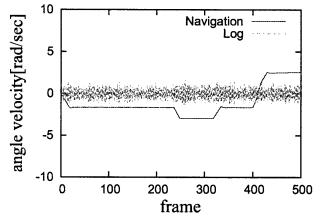


(b) 角速度

図 7 正常行動時の速さ・角速度

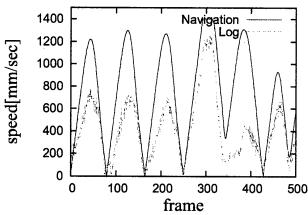


(a) 速さ

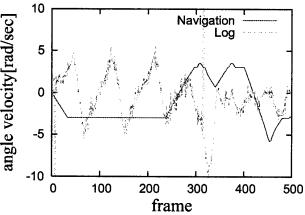


(b) 角速度

図 8 異常停止時の速さ・角速度

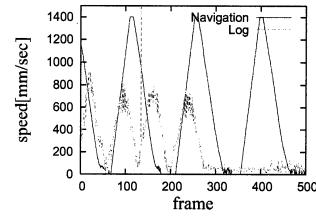


(a) 速さ

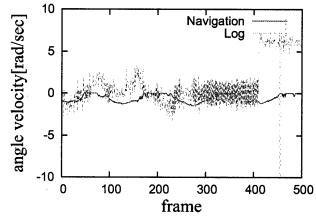


(b) 角速度

図 9 トルク異常時の速さ・角速度

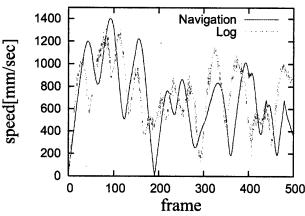


(a) 速さ

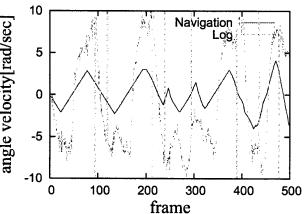


(b) 角速度

図 11 特徴のない異常行動時の速さ・角速度



(a) 速さ



(b) 角速度

図 10 暴走時の速さ・角速度

3.3 実験の前提条件

3.3.1 SVM の設定

SVM は TinySVM [4] の C-SVC と、RBF(Radical basis function) 関数 [2] をカーネル関数にしたものを用いた。RBF 関数は以下の特徴を持っているため、有効であると考えた。

- RBF 関数をカーネル関数に用いた C-SVC は非線形でありながら、分散パラメータをうまく調整すれば、カーネル関数を用いない場合と同程度の計算量で済む。
- 多項式関数や sigmoid 関数と違って、調整するパラメータが分散パラメータだけですむので調整しやすい。
- 多項式関数や sigmoid 関数のようにパラメータによっては有効でないということがなく、数学的な難しさがない。

正常行動の他に、特徴のある異常行動と特徴がない異常行動を学習させる。

3.3.2 学習データ

学習データ数は以下のとおりである。

- 正常行動 : 9000frame
- 特徴のある異常行動 : 9000frame
 - 静止状態
 - タイヤのトルク不良
 - 暴走状態
- 特徴のない異常行動 : 9000frame
- 速さも角速度も規則性がなく、ホストで計算された

動きとは異なった動きをする

ここで、学習データセットとして、以下に示す A～C を用意した。

- A 正常データ (9000frame) + 特徴のある異常行動 (9000frame)
- B 正常データ (9000frame) + 特徴のない異常行動 (9000frame)
- C 正常データ (9000frame) + 特徴のある異常行動 (6750frame) + 特徴のない異常行動 (2250frame)

すべての学習データセットは、18000frame のデータで構成されている。異常については、特徴のある異常行動であっても、特徴のない異常行動であっても、異常そのものを検出することが最終的な目標となる。そのために、学習データセット C では、正常行動、特徴のある異常行動（静止状態 2250frame、タイヤのトルク不良 2250frame、暴走状態 2250frame）、特徴のない異常行動で構成した。ただし、すべての学習は 2 クラス分類を行うものとし、学習させる際には、正常または異常のどちらかの値のみを与えた。

3.4 実験方法

3.3.2 で述べた学習データセット A～C による未学習データの分類を行った。未学習データは 3240frame を用意し、この未学習データを各学習データセットによる分類を行った際に、どの程度の精度で分類できたかを結果として示す。

3.5 実験結果

P, Q, R を次のように定める。

P SVM が正常であると判別したデータ

Q 実際に正常であるデータ

R 実際に正常であるデータを SVM が正常と判別したデータ

以上に従い、適合率、再現率、F 値を次のように計算する。

- 適合率 ($\frac{R}{P}$)

SVM が正常であると判別したデータのうち、実際に正常であるデータを SVM が正常と判別したデータ割合。

- 再現率 ($\frac{R}{Q}$)

実際に正常であるデータのうち、実際に正常であるデータを SVM が正常と判別したデータの割合。

- F 値 ($\frac{2R}{P+Q}$)

適合率と再現率の調和平均。

各学習データセットに対し、未学習データを分類した結果を表 1 に示す。

表 1 各学習データでの結果

データ	適合率 [%]	再現率 [%]	F 値 [%]
A	66.6	99.5	79.8
B	49.1	88.4	63.1
C	94.9	27.3	42.3

4. 考察

表 1 の実験結果を見ると、以下のことがいえる。

- 学習データ A

F 値は 79.8 %であり、高い検出精度を得られたといえる。

- 学習データ B

適合率が低くなった原因是、SVM の識別がソフトマージンであることが考えられる。特徴のない異常行動には、正常行動と区別がつきにくい部分（以下、ノイズという）が含まれておらず、識別面がノイズの影響を受けたと考えられる。

- 学習データ C

再現率が低くなった原因是、学習する異常行動の種類が多くなるためと考えられる。通常、SVM は 2 分類を行うが、学習データ C では、正常行動を含め、6 種類の行動を学習させている。このことが、再現率を下げていると考えられる。

以上より、次のことがいえる。

- 特徴のある異常行動のみを学習させた場合は、高い検出率を得ることができる

- 特徴のない異常行動を学習させた場合は、検出精度が低下する

特徴のある異常行動のみを学習させた場合は、図 8～図 10 に示したように、実際の速さ、角速度が、コンピュータからロボットに与えられる値と一致しない傾向がみられるため、正常クラスと異常クラスを上手く分割でき、良い結果が得られたと考えられる。

特徴のない異常行動を学習させた場合に検出精度が低下した理由は、図 11 より、ノイズが存在するためと考えられる。ソフトマージンによる識別では、分離時にノイズに影響されて、本来は正常クラスに属すべきデータが、異常と見なされてしまったと考えられる。そのために、再現率が低下し、F 値を下げる結果となつたと考えられる。

5. おわりに

本研究では全方位移動ロボットの例としてロボカップ小型リーグを取り上げ、SVM を用いて異常行動の検出を行った。

特徴のある異常行動を学習させた場合は約 80% の識別率を得ることができたが、特徴のない異常行動を学習させ

た場合は 63% の識別率となり、さらに特徴のある異常行動と特徴のない異常行動の両方を学習させた場合は 42% と一段と低い結果となった。

今後、システムの異常検出性能を向上させるためには、多段階に SVM を用いることによって、特徴のない異常行動の検出精度を増す必要がある。また、今回は障害物が存在しない環境で実験を行ったが、障害物の存在する環境で実験を行うことも必要である。そして、今回は考慮しなかつた処理時間についても計測し、ロボカップ試合環境下での実用を目指す予定である。

文 献

- [1] Hirokazu Seki, Yoichi Hori : "Detection of Abnormal Movement of Industrial Robot Based on Eigenspace Representation of image Sequense", Trans. on IEE Japan, Vol.123-D, No.7, pp.856-862, (2003)
- [2] Chih-Wei Hsu, Chih-Chung Chang, and Chih-Jen Lin : "A Practical Guide to Support Vector Classification", National Taiwan University, Taipei 106, Taiwan (2008)
- [3] <http://www.robocup.org>
- [4] <http://chasen.org/~taku/software/TinySVM/>