

回帰モデルに基づく言語・非言語指示パターンによる 移動ロボットのための制御則の獲得

Acquisition of control rules for a moving robot
by extraction of the patterns of verbal and non-verbal direction based on regression model

伊豆藏 拓也 *¹ 岡田 将吾 *² 西田 豊明 *¹
Takuya Izukura Syogo Okada Toyoaki Nishida

*¹京都大学情報学研究科知能情報学専攻
Graduate School of Informatics, Kyoto University

*²東京工業大学総合理工学研究科知能システム科学専攻
School of Science and Engineering, Tokyo Institute of Technology

In this paper, we propose the system which acquires control rules for a mobile robot by observing the interaction between an user and the robot. This system can learn the rules for controlling the robot according to user's verbal and non-verbal commands by segmenting continuous time-series data obtained from the direction behavior of human and action trajectory of robot. In addition, we propose a two layered regression model to control continuous variables such as moving speed and displacement. We set a robot navigation task for evaluating this system and calculated the accuracy rate of estimated robot's quantitative component. As the result of this experiment, we found that the regression model can output robot's continuous variables corresponding to command patterns.

1. はじめに

HRIを実現する重要な要素技術の一つに、人間の表出する言語・非言語指示情報をロボットが理解し、適切な行動制御を行える技術が挙げられる。言語情報は発話やテキストから得られ、相手と共通の認識を持つ意味や概念を容易に伝えることが可能である。一方非言語情報はジェスチャや視線などから得られ、空間や質・形状といった言語表現では表現しがたい量的な情報を相手に伝えることが可能である。本研究ではこれら双方のインタラクションに基づくロボット制御則を獲得する方法を提案する。

提案システムはロボットとユーザのインタラクションを観察し、ユーザの指示から言語・非言語情報の頻出パターンを教師なし学習によって検出し、それと対応するロボット駆動パターンを抽出して関連付けを行う。この結果、指示パターンの認識、対応したロボット駆動の生成が行える。本研究は、言語・非言語表現が意味する空間的・量的な概念と、ロボットの連続的な変数である駆動速度の間の関係を学習・獲得出来る回帰モデルを新規に提案・評価する事に焦点を当てる。この結果、従来研究で達成されたジェスチャシンボルと駆動シンボルの組み合わせの獲得だけでなく、駆動速度のような連続的な値とジェスチャシンボルの組み合わせが獲得出来る。

2. 関連研究

本研究で提案するシステムは、ユーザとロボット間の一連のインタラクション内容を WoZ の手法により観測し、その観測データを訓練データとしてロボット駆動の制御則を獲得する。この観点から、本研究におけるロボット行動則の学習は事例からの学習 [Argall 09] とみなすことができる。

Mohammad ら [Mohammad 09] は時系列データの頻出パターンを検知する手法として、RSST(Robust Singular Spectrum Transform) アルゴリズム, DGCMD(Distance Graph Constrained Motif Discovery) アルゴリズムを用い、さらに指

示者の指示とロボットの時間的因果関係を Granger Causality Analysis を用いて発見する手法を提案した。この手法はインタラクションの手法をジェスチャーに限定しており、言語を用いたインタラクションにおける学習までは行っていない。そこで岡田ら [岡田 10] は、指示者の言語・ジェスチャ指示パターンと、それに対するロボット駆動パターンの対をインタラクションデータから獲得する手法を提案している。この手法は、言語情報の発話区間に基づいてジェスチャパターンのセグメントを行うことで発話・ジェスチャによる指示パターンとアクションパターンの対を学習するというものである。本研究では [岡田 10] の手法を用いてジェスチャパターンのセグメンテーションを行う。

さらに、[Mohammad 09, 岡田 10] ではロボット駆動の量的な内容を推定することは行っていないが、速度量などの連続量をユーザのインタラクションから推定することはロボットがユーザの指示を理解するためには重要な要素技術である。そこでユーザの指示から得られる特徴を分離し、それらを回帰モデルの入力としたロボットの速度量を推定するモデルを新規に構築することで、実インタラクションを行う中でロボットが指示に応じて連続的な速度量を調節できるようになったことが本研究の貢献である。

3. システムの全体像

3.1 システムの概要

システムの概要を図 1 に示す。本研究ではジェスチャの軌跡を連続時系列データ、言語による発話指示を音声認識の結果得られたラベルデータとして獲得、またロボット駆動制御データをロボット駆動データの出力結果によって獲得する。

ジェスチャ指示パターンのセグメンテーションには [岡田 10] の時系列セグメンテーションアルゴリズムを利用し、言語ラベルの発生区間を基準にジェスチャのパターンを抽出し、言語とジェスチャのセットを作成する。さらにある言語・ジェスチャ指示に対応すると推定されるロボット行動データのパターンを、ロボット駆動制御パターンとして抽出し対応付ける。これらの言語・ジェスチャ・ロボット駆動パターンのセットデータ

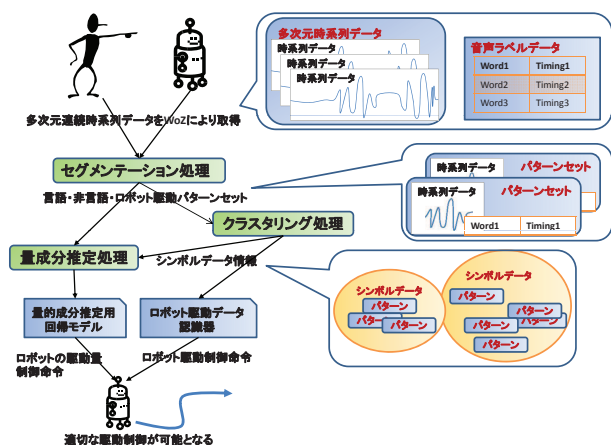


図 1: システムの概要

を1つのモチーフとみなす。

次にモチーフのジェスチャパターンに対してクラスタリングを行い、ジェスチャパターンの動向をクラスタリングによってまとめ、その1つのクラスターを1つのシンボルとして獲得する。行動生成段階ではこのシンボルと獲得されたジェスチャパターンの関係性を調べることで、もっともジェスチャパターンに近いシンボルデータに対応しているロボット駆動制御命令を出力することにより、インタラクションに対して適切なロボット制御が可能になる。

また、各シンボルのデータに対してロボット駆動の量成分を予測するための回帰モデルを構築する。これはシンボルデータの言語・非言語情報を入力、正解となるロボット駆動の量成分を出力とし、その対応関係を学習させたモデルである。学習の結果、ある言語・非言語指示が入力された場合に適切だと推測されるロボット駆動の量成分を出力する。以上の学習が終了した後、ユーザのインタラクションに対応したロボット駆動を行うことができるロボットコントローラを獲得できる。

3.2 実験を行うタスク環境の設定

本研究ではHRIをロボットナビゲーションタスクに限定した。ロボットナビゲーションタスクとは、ロボットが指示者の指示に従い決められた道順をたどり目的地へとたどり着くタスクのことである。実験環境内にはロボットと指示者のみがいる状況で、ロボットは決められたポジションからスタートする。また、ナビゲーションタスクを実行するロボットには移動機能を備えたカート型ロボットを使用した。このロボットは前進、後退、右回転、左回転、停止命令を行うことができ、停止命令以外はその速度も指定することができる。

ユーザのジェスチャ指示を動作系列データとして取得するために、手に3軸の加速度・地磁気センサーを装着する。また各系列データは50fpsで取得した。なお、本実験ではユーザの使用できるジェスチャの種類を予め設定せず、ユーザは任意のハンドジェスチャを用いてロボットに指示を出すことが出来る。この際、地磁気センサーの時系列における変化量をセンサーの移動量としてジェスチャの軌跡を獲得した。またユーザの言語指示における音声情報から発話区間を切り出し、音声認識から得られた発話内容を、本タスクで想定された単語セット(40種類、表1)のいずれかに割り当てるようにした。ロボットの駆動軌跡を取得するために、WoZの操作者によって操縦されたロボットの駆動ログデータを取得した。ログはコントローラから発せられる命令の内容、その可変速度が含まれる。

方向	動詞	程度・速度	その他
右	行つて	もっと	OK
左	来て	ちょっと	オッケー
前	おいで	もう少し	いいよ
後ろ	下がつて	ちょっとだけ	もう1回
まっすぐ	上げて	少し	じゃあ、
ここで	曲がつて	もう少し	はい、
そこで	向いて	ゆっくり	ください。
こっち	止まつて	急いで	くれる?
そっち	進んで	速く	スピード
そのまま	回つて	速めに	ストップ

表 1: 単語セット

4. システム構築に用いたアルゴリズム

4.1 パターン発見のアルゴリズム

本研究では、ジェスチャ指示の連続時系列データをパターン毎にセグメンテーション処理するアルゴリズムに[岡田 10]のモチーフディスカバリーアルゴリズムを利用し、モチーフとして得られたインタラクションデータをクラスタリングし得られたクラスターを、それぞれシンボルとして獲得する。

セグメンテーションの最初の段階として、本システムでは言語の発話区間付近にジェスチャパターンが存在していると仮定して探索範囲を絞り込んでパターンの発見を行うことにより、言語と非言語が共起するという仮説の下で、探索区間を絞り[Mohammad 09]のシステムの計算量よりも短い時間でパターンの探索を行えるようになる。モチーフディスカバリーは以下のアルゴリズムによって実現されている。

- Step1 言語ラベルを基準にデータ分割を行い、時系列データの動的傾向を観察し、傾向に変化がある(閾値を越えた変化量を検出する)までデータ分割の範囲を左右に広げる。
- Step2 傾向に変化が発生した際、その最も長い系列が傾向に変化が無い系列に挟まれている場合、その系列を取り出す。
- Step3 そうでなければ最も長い系列が伸びている方向へ探索範囲を広げて Step1 へ。

以上のステップを隣り合う言語ラベルの範囲にまで探索範囲が及ぶまで繰り返す。このアルゴリズムにより言語ラベルに対応する全てのジェスチャパターンが発見されたのち、ロボット駆動制御命令パターン探索に移る。

今回ロボット駆動データはロボットの駆動ログから取得するため、ある音声・ジェスチャパターンが発生してから次の音声・ジェスチャパターンが発生するまでの区間内に含まれる命令ログのデータをそのパターンに対応するアクション駆動データとして抽出した。

全ての言語・ジェスチャパターンに対してアクション駆動データが発見できれば終了となる。セグメンテーション処理で得られた、言語・非言語・ロボット駆動データのセットをクラスタリングアルゴリズムの入力とする。

4.2 パターンクラスタリングのアルゴリズム

4.1の処理後に得られるジェスチャの時系列パターンに対してクラスタリングを行う。今回実験を観測すると、指示にはビートジェスチャ[西田 09]が比較的多用された。ビートジェスチャの様に任意の繰り返し構造を含む場合、手招きの繰り返し数に限らずそれぞれのパターン間分散を小さくしたい。そこで本研究では[岡田 10]のアルゴリズムを引用し、同じ種類であるジェスチャパターンならば繰り返し構造の数に限らず類似度が高くなるように、エルゴード型HMMをジェスチャパターンの距離計算に用いた。以下に、その手順を示す。

- セグメントされた時系列パターン群の数 L だけエルゴード型の HMM を用意する。
- 各時系列データを各 HMM でそれぞれ学習する。HMM のパラメータ推定には EM アルゴリズムを用いる。
- L 個の HMM 動詞の Kullback-Leibler 距離を算出し、 $L \times L$ の距離行列 D を作成する。
- D に基づき階層的クラスタリングを行う。ここでクラス数はパラメータとして事前に設定する。
- 各クラスに分類されたデータ群から 1 つの HMM を学習して、これをジェスチャシンボルの認識器として用いる。

このシンボルごとの認識器で、新しいモチーフがどのクラスに属しているのかを判断することができる。

4.3 ロボット駆動制御のための量成分推定アルゴリズム

4.1 で得られる言語・非言語パターンと、ロボットの駆動制御の量成分との因果関係を推定する行動予測機を構築する。この行動予測機は言語・非言語パターンをそれぞれに無相関な説明変数とし、量成分をその予測値として回帰分析のモデルに射影している。以下では、時系列データと静的データの双方を説明変数として学習出来る、二段階の回帰モデルを提案する。この際、4.2 のクラスタリングによって得られたシンボル情報に基づいて、シンボルごとに回帰モデルを構築する。

4.3.1 量的成分抽出アルゴリズム

ジェスチャの加速度時系列データ、言語ラベルデータ、発話・ジェスチャ区間長、韻律平均量を回帰モデルの説明変数に入力した。またこのモデルが予測する目標変数はロボットの駆動命令の中の速度や移動量といった量成分である。従って、量的成分情報の測定値を y 、それを説明する変数を x_i 、各 x_i に掛かる未知の係数を a_i とすれば、回帰分析のモデルは

$$y = a_1x_1 + a_2x_2 + \dots + a_{N-1}x_{N-1} + a_Nx_N \quad (1)$$

と表すことができ、モチーフの数だけ式 (1) の y と x_1, \dots, x_N の対が得られ、それらのデータから未知の係数を推定する。

未知の係数を推定する方法としては最小二乗法を利用する。すなわち、各サンプリングデータ j が推定する値を、式 (1) から $f(X_j) = \sum_{i=1}^N a_i x_{ji}$ としたとき、 M 個のサンプリングモチーフデータに対する y_j と $f(X_j)$ の残差の平方和、つまり

$$J = \sum_{j=1}^M |y_j - f(X_j)|^2 \quad (2)$$

が最小になるように $f(X_j)$ の各係数 a_i を推定する。推定して得られた各係数 a_i を式 (1) に代入したものが、そのサンプリングデータに対する回帰モデルとなる。よって新たにモチーフが得られた際、モチーフデータの情報を説明変数として、この得られた回帰モデルに入力することで量的情報の予測値を得ることができる。

4.3.2 重回帰分析に入力するデータの定義

回帰モデルの説明変数がどのようにシステムに入力されるのかを定義する。発話・ジェスチャ区間長はフレーム数で表す。発話内容ラベルはあるモチーフの区間内でその単語が用いられた回数で表し、単語リストの数だけ説明変数を用意するが、そのラベル内で用いられていない単語の変数には 0 を入力

する。ジェスチャの加速度時系列データは各次元の時系列データの特徴を射影した個定数の係数群を用いる。韻律情報は時系列の平均値と最大値を用いる。

ここで、ジェスチャの加速度時系列データはモチーフごとに長さが異なり、直接ジェスチャの時系列データを回帰分析の説明変数に用いることは出来ない。また、単純にデータを平均化したものを時系列の特徴としてしまえば、その連続時系列データがどのような軌跡を描いているのかという情報が損なわれてしまう。よってデータ量を限定し、なおかつ時系列データの変移の情報が得られるような情報を取り出す必要がある。

そこで本研究では、ジェスチャの加速度時系列データの特徴を射影する説明変数の導出に AR モデル [Pandit 83] を用いることで、モチーフによって時系列の長さが異なる連続時系列データ変移の特徴を限られた数の係数に射影した。これは連続時系列のあるフレームにおける加速度は、前後のフレームの加速度に自己回帰的であることを利用している。つまり、モチーフの時系列データ内にあるフレームをその前後のフレームから予測し、得られた重み係数をモチーフの加速度時系列の特徴とした。式にして表すと、あるフレーム x_i の加速度を y_{x_i} 、前後のフレームの加速度を x_{i+t} 、各 x_{i+t} に掛かる重み係数を a_t をとして次式で表せる。

$$y_{x_i} = a_{-t}x_{i-t} + \dots + a_{-1}x_{i-1} + a_1x_{i+1} + \dots + a_jx_{i+t} \quad (3)$$

この式を式 (2) で解き、重み係数を a_{i+t} を求め、式 (1) の説明変数に入力する。

また、行動生成する際に予測すべき量的成分のデータは回帰モデルの教師データであるため、式 (1) の y に入力する。

以上のデータを式 (1) に入力することにより、量成分の推定を行うための係数が得られ、回帰モデルを構築することができる。

5. 評価実験

5.1 データ取得と正解データ作成

WoZ を用いて学習用データとテスト用データを別々に実験によって作成した。ナビゲーションタスクを学習用データ取得実験では 9 分 14 秒間行い、評価用データ取得実験では 4 分 23 秒間行った。その結果、本実験で確認された指示ジェスチャの種類は、前進・停止・右回転・左回転命令を表すものが確認され、後退命令は確認されなかった。

今回、正解データを獲得するために、ジェスチャデータは時系列区間を手動で切り出すことで評価し、ロボット駆動制御の量成分の正解値は実際に WoZ が制御した正解データの数値を使用した。

5.2 実験結果

本研究では [岡田 10] のモチーフディスカバリーを本研究に適用し、そのデータを入力としたロボット駆動制御の量成分推定アルゴリズムを新規に提案した。よって実験の評価は量成分の推定がどれくらいの精度で行われたのかを評価するため、あらかじめこちらで命令毎にクラスタリングした結果毎に回帰モデルを構築し、評価した。

また、ロボット駆動制御の量成分はデータ取得の際に変化量や数値の抽出が容易であった速度量について評価を行った。ここでいう速度量は今回は命令時の初速度と命令を受けたのちの終速度とした。

5.2.1 評価方法

正解率を計算することで速度量が正しく推定されたか評価する。推定量が正解データであるとみなせる基準を設ける必要




図 2: 説明変数を変更した場合の結果の比較. 横軸はどの AR モデルを選択したのかを表している.

があったため, 正しいデータと推定されたデータの誤差が 10% 以下のものを正解データとみなした. 正解率 AccuracyRate のを以下の式で算出する.

$$AccuracyRate = \frac{\text{正解データ数}}{\text{全駆動データ数}} \quad (4)$$

5.2.2 説明変数に関する評価

回帰モデルに説明変数として入力されている言語・非言語情報がどれほど正解率に寄与しているのかを評価する. 様々な条件で構築した回帰モデルの正解率を比較し, 図 2 に表す.

この図の見方としては縦軸が正解率, 横軸がどの AR モデルを選択したかを表している. AR モデルは前後いくつかの時系列データを参照するモデルであり, 図の横軸の数字は前後の時系列データをいくつ参照しているのか意味する. なお, この正解率は各命令毎の回帰モデルを構築し, その結果をマージした総合的な正解率を表している.

図 2 より言語ラベル情報のみの正解率が高いことより, この回帰モデルでは言語ラベルに係る重みが大きいことが分かる. 実際, 図 2 の右端の図は言語ラベル情報を除いた回帰モデルの結果だが, 正解率は大きく下がっている.

また, 全体的に終速度に比べ初速度の推定が低い結果が得られた. これは初速度というのは過去の命令の系列に依存しているが, 本研究で提案したシステムは過去のインタラクション情報を学習しないことが原因と考えられる. そこで, 過去の命令系列情報をも学習に取り入れた回帰モデルの構築がさらなる発展的課題と言える.

5.2.3 AR モデルの選択に関する評価

各命令について回帰モデルを構築した結果を評価し, 図 3 に表す. 図のように, 構築した回帰モデルごとに最適な変数数を持った AR モデルは異なっており, 良い AR モデルを選択することが良い回帰モデルの構築に必要な. 本研究では交叉検定 [Kohavi 95] を用いて, 学習データ取得時に正解率が最良となる AR モデルを選択する方法を採用した. 交叉検定を行いシステムを評価した結果を図 4 に表す.

この結果を見るに, 交叉検定を行った結果が最も良い AR モデルは, 独立なテストデータを用いて回帰モデルを評価した図 3 の場合でも比較的高い正解率を持つことが分かる. したがって, 学習時に交叉検定を行い最も性能が高い AR モデルを選択することで, 訓練データに適した回帰モデルを構築することが可能であることが分かった.

6. まとめ

本研究では, ユーザからロボットへの言語・非言語指示をパターンとして抽出し, ロボット駆動制御則と対応付け, 言語・非言語指示からロボット駆動制御則を推定する手法を提案し




図 3: 各命令毎の回帰モデルの評価. 左から停止, 前進, 左折, 右折命令の評価結果を表す.




図 4: 各命令毎に交叉検定を行った回帰モデルの評価. 左から停止, 前進, 左折, 右折命令の評価結果を表す.

た. また言語・非言語指示パターンの特徴を二段階の回帰分析の説明変数に射影することで, 量成分の推定を行う回帰モデルを構築し, 正解率を評価することで一定の成果を確認した.

将来的には, 過去の命令情報を参照できる回帰モデルを構築することで, 量成分推定を精緻化することを目指す.

参考文献

[Argall 09] Argall, B., Chernova, S., Veloso, M., and Browning, B.: A survey of robot learning from demonstration, *Robotics and Autonomous Systems*, Vol. 57, No. 5, pp. 469–483 (2009)

[Mohammad 09] Mohammad, Y., Nishida, T., and Okada, S.: Unsupervised simultaneous learning of gestures, actions and their associations for human-robot interaction, in *Intelligent Robots and Systems, 2009. IROS 2009. IEEE/RSJ International Conference on*, pp. 2537–2544 IEEE (2009)

[Pandit 83] Pandit, S. and Wu, S.: *Time series and system analysis with applications*, Wiley New York (1983)

[岡田 10] 岡田将吾, 伊豆蔵拓也, 名淵博人, 高橋徹, 西田豊明.: 言語・非言語情報を統合した指示パターンに対応するロボットの行動則獲得, AI チャレンジ研究会 (第 32 回), p. 9

[西田 09] 西田 豊明, 角 康之, 松村.: 社会知デザイン, オーム社 (2009)

[Kohavi 95] Kohavi, R.: A study of cross-validation and bootstrap for accuracy estimation and model selection, *International joint Conference on artificial intelligence*, Vol. 14, pp.1137–1145, (1995)