

FB1-2

マムダニ推論と合成した自動ルール作成型ファジィ推論法

Fuzzy Reasoning to Make Rules Automatically Combined with Mamudani Reasoning

江端 智一

八木 建史

石原 好之

戸高 敏之

Tomoichi EBATA, Tatehito YAGI, Yoshiyuki ISHIHARA and Toshiyuki TODAKA

同志社大学 工学部

Faculty of Engineering, Doshisha University

Abstract : This paper proposes Fuzzy Reasoning to make rules quickly and automatically by numerical functions and the centroid method in multivariable analysis. This Fuzzy Reasoning combined with a simple-type Mamdani Reasoning makes Fuzzy rules quickly, and this method is able to apply on various conditions. The effectiveness of this Reasoning is shown by simulations and experiments of driving a vehicle.

1. はじめに

人は日常生活において、自己の経験的な学習と、他者による教育的な学習を融合させることによって、多くの知識を獲得している。人が車のカーブ運転を学習するとき、人は全ての形状のカーブを実際に運転して学習する必要はない。いくつかのカーブの運転経験から、種々のカーブ運転に柔軟に対応できる。しかし、人命が危険になる状況を、経験による学習で補うことは不可能であり、教育による学習で補われることになる。

我々は、経験的な学習を行う自己学習型ファジィ推論の一手法として、CDF推論を提案した⁽¹⁾。この推論法は、マムダニ推論のように言語レベルの命令を全ての場合について作成する必要はなく、学習データから数値解析的に特徴点を自動抽出するので、高速に同定が完了する。その反面、学習データの条件に表れない領域では、正しい推論の実行ができなくなる。そこで、この推論法に教育的な学習法との融合を行う手法を提案する。

本研究では、走行車をモデルに用いて①高速学習同定が可能であるが、環境の変化の対応に弱いCDF推論を『経験的な学習』による推論、②環境の変化には強いが、ルール作成に時間のかかるマムダニ推論を『教育的学習』による推論と位置づけ、両者の合成を行うことによって、わずかな時間での同定が完了し、安定な推論が可能となることを確認した。

2. 推論の同定法

2-1 CDF推論の同定法

メンバーシップ関数に簡単な関数を用いることで、高速のシステム同定を実現する。同定法を以下に示す。

①入出力データ $(X_{11}, X_{12}, \dots, X_{1n}, Y_1)$ $i=1, 2, \dots, N$ を観測する。

②これらの中から同定用データとチェック用データを、それぞれ必要な個数選び出す。

③選び出した同定用データを、クラスタリング手法の重心法を用いて最初は2分割し、それぞれの群を R^k ($k=1,$

$2, \dots, m$) ($m < N$)とする。

④前件部メンバーシップ関数をそれぞれの群ごとに、指数関数を利用したモデルより決定する。メンバーシップ関数は群のデータの重心点で最も値が大きくなり、重心点から遠くなるにつれて値が小さくなる。群ごとのメンバーシップ関数は、最も近い群の同定用データが存在した地点で十分小さい定数になるように決定する。入力変数 $(X_1, X_2, \dots, X_n)$ 、第 k 群のデータ数を C_k 個とし、その群のデータの平均値を $(\bar{x}_1^k, \bar{x}_2^k, \dots, \bar{x}_n^k)$ 、第 k 群に最も近い第 k' 群の中の、最も第 k 群に近い同定用データを、 $(\bar{x}_{q1}^k, \bar{x}_{q2}^k, \dots, \bar{x}_{qn}^k)$ とすると、 μ^k は次式で与えられる。

$$\mu^k = \exp \left\{ -\sum_{i=1}^n (X_i - \bar{x}_i^k) / \alpha_k \right\} \quad (1=1, 2, \dots, N) \quad (1)$$

$$\alpha_k = -\sum_{i=1}^n (X_{qi}^k - \bar{x}_i^k) / \ln(\varepsilon) \quad (2)$$

ここで、 ε は十分小さい定数とする。

後件部メンバーシップ関数は、それぞれの群ごとのデータより回帰分析を行い線形モデルを立てる。 n 個の入力を持つモデルの場合 n 次元の回帰平面を立てる。また入力変数が多いときは単なる群ごとのデータの平均を使用する。 $\bar{y}^k$ は次式で与えられる。

$$\bar{y}^k = \sum_{s=1}^n (A_s X_{is}) + A_{n+1} \quad (3)$$

前件部、後件部をFig.3のように組み合わせ、システムの同定を終了する。なお、 μ^k ($k=1, 2, \dots, m$)は各データがそれぞれの群に属する度合、 $\bar{y}^k$ ($k=1, 2, \dots, m$)は各群の入力に対する推定値である。Fig.1、Fig.2にメンバーシップ関数のイメージ図を示す。推論値は次の式より得られる。

$$y_i^* = \frac{\sum_{k=1}^m \mu^k \cdot \bar{y}^k}{\sum_{k=1}^m \mu^k} \quad (4)$$

⑤推論結果とチェック用データを比較して、差が小さくなるうちは、分割数を1つ増して、④より再計算する。前回の推論結果と比較し、差が大きくなれば分割数を前回の値として、同定を終了する。




Fig.3 CDF推論の構成

2-2 CDF、マムダニ合成推論

CDF推論は学習データより作成されるので、学習した条件から大きくかけ離れた条件では、推論結果が予期せぬものとなることがある。そこで推論領域の一部、又は全体で、簡易なルールによるマムダニ推論をCDF推論と並列に実行し、それぞれの推論結果を合成する。これは、推論領域がCDF推論の適する境域から外れそうになったときに、マムダニ推論によってこれを押し戻す働きを意味する。

合成推論法として下記の手法を提案する。CDF推論法、マムダニ推論法、合成推論法の推論結果をそれぞれ Y_c^* 、 Y_m^* 、 Y とする。

2-2-1 MAX方式

最大値を用いる方法で、推論結果は下記の通りである。

$$Y^* = \text{Max}(Y_c^*, Y_m^*) \quad (5)$$

2-2-2 ハイブリッド方式⁽²⁾

推論領域全体 $\{U\}$ は、CDF推論が適する推論領域 $\{U_c\}$ とマムダニ推論が適する推論領域 $\{U_m\}$ とそれ以外の領域 $\{U'\}$ から成り立つと考える。推論結果はそれぞれの適する領域で結果に強く反映されるように組み合わせる。

$$\{U\} = \{U_c\} + \{U_m\} + \{U'\} \quad (6)$$

領域 U_c : $Y^* = Y_c^*$

領域 U_m : $Y^* = Y_m^*$

領域 U' : 領域 U_c からの距離を a 、領域 U_m からの距離を b としたとき

$$Y^* = \alpha Y_c^* + (1-\alpha) Y_m^* \quad \text{ただし } \alpha = b/(a+b) \quad (7)$$

3. シミュレーション環境・実験方法

実験は、シミュレーションと、実際の模型走行車の両方で行った。シミュレーションの学習用データはドライブシミュレータを使用し、オペレータが走行路を3次元

表示させた画面を見ながら運転を行い、必要なデータを取り込む。

3-1 走行車の加減速運転シミュレーション

スピード(SP)、残差距離(D)、操作量(ACC)、経過時間(T)のデータをサンプリング時間50[ms]で取り込む。走行車は最大速度100[cm/s]、最大加速度±30[cm/s²]とし、1000[cm]の距離を直進走行させる。

3-2 走行車のカーブ運転シミュレーション

Fig.4に示すような形状の走行路を走行させ、左右45度の側壁までの距離(Dl, Dr)、前輪舵角量(S)、単位時間あたりの操舵量(dS)、経過時間(T)をサンプリング時間100[ms]で取り込む。走行車は100[cm/s]の定速運転を行い、カーブ走行時の横滑り等はないものとする。




Fig.4 カーブ走行シミュレーション環境

3-3 走行車のカーブ運転実験

シミュレーションと同じ環境で、模型走行車を用いて実験を行った。模型走行車より超音波センサで取り込んだ距離データをコンピュータに送信し、操舵角を推論して送信する。Fig.5にシステム構成を示す。




Fig.5 模型走行車によるカーブ運転実験システム

3-4 実験方法

次にシミュレーション運転及び実証運転の実験の手順を示す。

- ①走行データをドライブシミュレータ、模型走行車を用い作成する。オペレータは3-1の実験においては、短時間でゴールに到達し停止するように操作し、3-2及び3-3の実験では、走行路の中央を安定に走行させる。
- ②データからCDF推論の同定を行う。
- ③合成推論の同定を行い、学習時と異なった走行環境でそれぞれの推論による走行の特性を調べる。

4. 走行車の加減速運転シミュレーション

Fig.6に学習時の走行データと、同じ環境でのCDF推論による走行結果を示す。学習時の初速度は0[cm/s]、残差距離は1000[cm]で、約300個の入出力データから約70個

の学習用データを選び出し同定を行った結果、最適な学習データの分割数は23となった。またFig.7には残差距離を900[cm]、初速度を70[cm/s]としたときのCDF推論による走行結果を示す。このように環境を若干変化させた場合でも、ほぼゴールで停止していることがわかる。Fig.8に任意の残差距離と速度の時に、この推論により進められる方向を示した推論ベクトルの分布図を示す。円は前件部メンバーシップ関数の分布を示す。以上より、学習データと異なる条件では、最適な推論が困難となることが分かる。




Fig. 6 加減速シミュレーション結果1
(残差距離 1000[cm] , 初速度 0[cm/s])




Fig. 7 加減速シミュレーション結果2
(残差距離 900[cm] , 初速度 70[cm/s])




Fig. 8 推論方向ベクトル分布図

5. 走行車のカーブ運転シミュレーション

実験時の環境は、Fig.4で示した走行路形状のカーブ角を変化させて、側壁に接触及び衝突せずにゴールに到着できた時を成功とする。成功の度合いを確認するために、推論による走行車の軌跡とセンターラインに囲まれた面積を、走行路全体の面積で割った値を運転誤差率と呼ぶこととする。またCDF推論、及び合成推論との比較検

討を行うため、mamダニ推論によるシミュレーションも行う。ここでは左センサ距離(Dl)、左センサ距離変化量(dDl)、右センサ距離(Dr)、右センサ距離変化量(dDr)、前輪舵角量(S)の5つの数値を入力し、単位時間あたりの操舵量(dS)を推論し出力する。学習データはカーブ角135度で作成した。Table 1にmamダニ推論によるカーブ走行用操舵量ルール表を示す。ルールはセンサ左右に同じものを用いるので、一方だけを示した。Table 2には、CDF推論に合成する簡易なmamダニ推論のルール表を示す。なおmamダニ推論は、簡易ファジィ推論を用いた。

Table 1 カーブ走行操舵量ルール表

距離 (40) (0) 距離変化	ZO なし	PS やや大きい	PB 大きい	操舵角
NB 負に大きい	NN BS	NP OS	PP BS	NN BS
NS 負	PB	PS	PS	NN BS
ZO なし		ZO		NN BS

Table 2 合成推論用ルール表

距離 (40) (0) 距離変化	ZO なし	PS やや大きい	PB 大きい
NB 負に大きい	PB	PS	
NS 負	PS		
ZO なし			ZO

Fig.9にCDF推論と合成推論(ハイブリッド方式)、及びmamダニ推論による180度カーブ運転時の走行軌跡を示す。またFig.10にdSの変化を示し、第1、2カーブの開始と終了地点をA,B,C,Dと示す。走行結果より、いずれの推論でもうまく走行が行われている。しかしdSは走行軌跡の旋回半径の変化量を決定するので、走行車内に人が乗っている場合、一般的に変化量が多いほど不快感が強くなり、乗り心地の点ではCDF推論、合成推論、mamダニ推論の順で優れていると言える。これは、mamダニ推論が距離の大小を確認してからdSの大きさを決定しているのに対して、CDF推論では学習走行時に学んだ入力値全体の微妙な変化からdSを決定しているために、全体的にdSの変化が小さくなるものと考察される。



Fig. 9 180度カーブ運転走行結果




Fig. 10 180度カーブ運転制御
操舵角変化量結果

Fig. 11にC D F推論、合成推論のハイブリッド方式とMAX方式を用いたときの60度カーブ運転時の走行軌跡を、Fig. 12に合成推論でのdSの変化を示す。C D F推論では側壁に衝突して走行不能に陥っている。また、合成推論法のMAX方式とハイブリッド方式を比較すると、MAX方式では、各推論値の最大値を取るため、全体的に大きな値を出す推論の影響が出やすく変化が急になることがある。また、振動が生じやすいことが確認された。これは推論領域の境界部で推論結果を互いの領域に押し合うためと考えられる。




Fig. 11 60度カーブ運転走行結果




Fig. 12 60度カーブ運転制御
操舵角変化量結果

Fig. 13にカーブ角を-180度から180度まで10度ずつ変化させたときの、C D F推論による運転誤差率を示す。走行途中で側壁に接触した角度はプロットしなかった。合成推論による結果をFig. 14に示す。MAX方式、ハイブリッド方式ともに全ての角度で成功し、運転誤差率は全て12[%]以内で納まっていることが確認された。マムダ

ニ推論では、操舵量を全体的に大きく推論させて全ての角度で成功させることができたが、dSの変化が大きく乗り心地の点で問題となることが確認された。




Fig. 13 C D F推論誤差結果




Fig. 14 合成推論誤差結果

6. 走行車のカーブ運転実験

模型自動車による実験を行った結果、超音波センサからのノイズが最大の問題となり、学習データ作成の際、変化量が非常に大きいデータを同定用データから削除し、距離変化量の影響を小さくしてC D F推論の同定を行った。結果は、マムダニ推論と比べ、合成推論法は蛇行運転が軽減され、比較的安定した走行が可能となった。

7. まとめ

学習データより自動的に高速にファジィ推論の同定を行うC D F推論を提案し、この推論に簡易なマムダニ推論を合成することにより、環境が変化しても安定な推論が可能となることを、走行車を用いて確認した。また、合成推論はそれぞれの推論領域を移行する際、なめらかに変化させるようなハイブリッド方式を用いることで、振動を押さえられることを確認した。今後、空間分割数の即時決定法、追加学習が可能となるC D F推論の同定法について検討を行う予定である。

最後に模型走行車のラジオコントロール装置と設計資料を提供していただいた、三和電子機器(株)の関係各位に感謝の意を表します。

- (1) 江端、他：重心法分割型ファジィ推論を用いた走行車の学習制御；平成元年電気関係学会関支連、G2-27
- (2) 松永、他：ファジィハイブリッド制御方式；平成元年電気関係学会関支連、G2-29

問い合わせ先：〒602 京都市上京区今出川烏丸東入

同志社大学工学部電気工学科 石原 好之

TEL 075-251-3764 FAX 075-251-3737