解説

定性物理モデルの帰納的学習

Inductive Learning Approach to Qualitative Physics

溝口 文雄* *東京理科大学理工学部経営工学科

Fumio Mizoguchi* *Science University of Tokyo, Department of Industrial Administration

1. はじめに

物理系の挙動を推論したり，説明できる機構を計算機に持たせるという定性推論の研究は自律ロボットの設計や人とロボットとのコミュニケーションにおいて特に重要であり，我々はこの数年来，論理型言語 Prolog を用いた知識表現や定性推論の研究を行ってきた．具体的には，定性モデルの設計のための会話的モデル構築支援システムや定性推論を用いた診断ルールの生成などを，医療診断の分野を対象にして，システムの開発を行いながら進めてきた．これらの試みは，Prolog を用いての効率的制約処理系の実現と，一貫したシステム構築とを通じての，いわば，演繹的枠組みによる知識の獲得の研究を行ってきたといえる．そして，こうしたシステムは制約論理型言語および定性推論システムとしてツール化され，対象に関するモデルを準備すれば，そのモデルから定性的挙動が得られ，ルールを獲得することが可能である[10]．こうした経験に基づいたアプローチの次の段階は，いかにして定性モデルを作成するか学習であり，この枠組みを関係（制約）の概念のもとに帰納的に構築することが重要な課題となってくる．このための枠組みとして考えられるのが帰納的論理プログラミングであり，それを図1に示す．この図の中で本解説の対象となるのは帰納的論理プログラムであり，点線で示されている部分である．実線の部分は演繹的方法としてすでに確立した制約処理と定性推論のフレームワークで，本論の中では触れない[8][9]．

2. 定性推論におけるモデル化とその構造表現

定性推論の研究は基本的には，対象の定性モデル化，その推論システムおよび挙動の解釈により構成される．モデル化の方法には様々な方法があるが，基本的には次の四つの方法がある．すなわち，de Kleer & Brown による物理的

図1 本研究の枠組み

構造に基づくデバイス中心のアプローチ，Kuipersによる数学的な関係構造（add, mult, minusなどの定性的な制約関係を用いて変数間の関係を記述する）によるアプローチ[5]，Forbusらのプロセス中心のアプローチ，Consolidationによるアプローチである．本解説ではQSIM[5]の考え方を基本にする．それは，例えば対象が物理運動の場合，モデルを構成する上で明確な構造を導き出しにくい（逆に電気回路などには明確なデバイストポロジーによる表現が存在する）ので，定性的な制約関係によって変数間の関係を表現することが適しているからである．定性的な関係は，次のような制約によって記述される．

- $mon\_inc(A, B)$ (変数 A と B は，単調増加の関係である)
- $mon\_dec(A, B)$ (変数 A と B は単調減少の関係である)
- $deriv(A, B)$ (変数 A の微分は変数 B である)

そして，定性モデルは帰納学習におけるターゲット述語を $model$ ，制約を $C_i (i = 1, \dots, n)$ として，

$$model : -C_1, C_2, \dots, C_n.$$

の形式で表現される．この式は，制約 C_1 かつ C_2 かつ... C_n が成り立つならば，それが対象系の定性モデルとなることを示している．これらの制約は線形方程式，不等式として表記できるので制約論理プログラミングの概念が用いられる．さらに物理挙動などの外界からの情報を解釈してその

原稿受付 1994年11月8日

キーワード: Inductive Logic Programming, Qualitative Physics, Constraint Processing Qualitative Simulation, Knowledge System

〒278 野田市山崎2641

*Noda-shi, Chiba 278, Japan

図2 定性モデルの学習

定性的表現を得るために、定量情報を定性情報に変換する機構が何らかの形で備わっていなければならない。この機構は制約論理プログラミングと新しい機械学習の手法である帰納的論理プログラミング[7]の併用によって得られる。すなわち、制約論理プログラミングの形式で書かれた定性モデルを帰納論理プログラミングの枠組みを利用して導出するというのがここでの新しい視点である。これによって、従来の定性推論における三つの要素（定性モデル、定性シミュレーション、定性的挙動）は図2で示される関係で関連づけられることになる。

3. 帰納的論理プログラミング

帰納的論理プログラミング[7]は一般的には次のように定義される。

背景知識 K 、正例 ε^+ 、負例 ε^- が与えられている。ただし $K \models \varepsilon$ とする。このとき、 $K \wedge H \vdash \varepsilon^+$ 、 $K \wedge H \not\vdash \varepsilon^-$ であるような論理式の集合 H を見付けることが帰納的論理プログラミングの目的である。定性モデルの学習においては、 K が定性推論に関する規則、 ε^+ が挙動の観測結果、 ε^- が実際にあり得ない観測結果に対応する。

このアルゴリズムは論理プログラムの証明で使われる Resolution を逆にした推論規則である Inverting Resolution を基にして、与えられた背景知識に関して次第に例を一般化していく。すなわち、背景知識と例から一般的な論理式を導出する。これを定式化すると次のようになる。論理式 C_1 と C_2 がそれぞれ $((\overline{a_1} \vee \overline{a_2} \vee \dots) \vee e_1)$ と $((\overline{a_1} \vee \overline{a_2} \vee \dots) \vee e_2)$ で表現されるとする。ト $C \rightarrow lgg(C_1, C_2)$ なる式 C は C_1, C_2 より一般的である。ここで、 $lgg(C_1, C_2)$ は C_1 と C_2 より一般的な論理式のなかで最小なもの（最小一般化）を意味し、 $C = lgg(C_1, C_2)$ とすることができる。背景知識を考慮に入れた場合の最小一般化は相対最小一般化として定義され、正例 e_1, e_2 の相対最小一般化を求めるには、正例を論理式の帰結部にし、背景知識をその式の条件部に置く。そして、そのようにして構成された論理式の最小一般化がもとの正例の相対最小一般化となる。

Bratko の研究[3]においても Muggleton の提案した帰納的論理プログラミングが定性物理モデルの学習に応用されている。これに対して、本研究においては物理現象を捉える場合に、ある特定の形式化された見方で現象を扱うの

部分における時間ごとの観測値を背景知識とする

la (0.0, 111.6).	lb (0.0, 135.2).
la (1.0, 113.5).	lb (1.0, 133.3).
la (2.0, 115.6).	lb (2.0, 130.6).
:	:
fab (0.0, 33.4).	fba (0.0, 41.3).
fab (1.0, 36.6).	fba (1.0, 38.2).
fab (2.0, 38.7).	fba (2.0, 36.6).

QR理論による制約その他の表現を一階述語の表現で表わしたものを背景知識とする。

mon-inc (A, B) : -dir (A)=inc, dir (B)=inc.
 mon-inc (A, B) : -dir (A)=std, dir (B)=std.
 mon-inc (A, B) : -dir (A)=dec, dir (B)=dec.
 deriv (A, B) : -dir (A)=inc, plus (B).
 deriv (A, B) : -dir (A)=std, zero (B).
 deriv (A, B) : -dir (A)=dec, mins (B).

ただし、上記でdir (X) とはパラメーターXの変化傾向を plus (X), zero (X), mins (X) はそれぞれ $X > 0$, $X = 0$, $X < 0$ を表わす述語であり、すでに内部定義されているとする。

図3 入力

ではなく、より自然な見方（観測値）からの定性モデルの学習を行う。具体的には、Bratko らは定性的に解釈された観測データから定性モデルを得たが、本研究では定量情報を一般化制約集合として表現し、それにより得られた制約式をさらに一般化することで定性的に異なる状態を説明可能とする。さらには得られた定性値から背景知識を用いた帰納的手法により定性モデルを獲得することを目標とする。以下、システムの入出力の関係およびその内部機構について説明する。

4. 学習システムの入力と出力

まずシステムの入力と出力を示す。ここでの対象は Bratko らの研究で取り上げられている U-tube（U 管：U 字型にまがった管の中の液体の運動）である。各パラメータの時間ごとの観測値が入力として与えられるが、さらに定性モデルの基本要素となるべき制約集合も学習システムの入力情報とする。帰納的論理プログラミングでは前者が事例集合、後者が背景知識に相当し、いずれも論理式で記述される（図3）。

一方、出力は図4に示されるような論理式となる。論理式の帰結部には定性モデルを記述するのに必要な変数集合があり、条件部には定性モデルが充足しなければならない変数間の関係が記述されている。これらの関係の意味は背景知識ですでに定義されている。

出力値

途中経過では、それぞれの時区間で成り立つ定性モデルがつくられ、最終的には全ての時区間で成り立ちた一階述語論理形式の定性モデルが学習される。

```
model(La,Lb,Fab,Fba) :-
    minus(La,Lb),
    minus(Fab,Fba),
    deriv(La,Fba),
    deriv(Lb,Fab).
```

図4 出力

5. 制約による一般化

定量値を定性値に変換するための制約による一般化の手法を以下に示す。

5.1 観測値

入力されるデータは、時間 t の連続関数 $p(t)$ でありこれを観測値と呼ぶ。ただし、時間 T における観測値の値 V を $p(T, V)$ のように記述するとき、

$$p(t_i, v_i) \text{ と } p(t_{i+1}, v_{i+1}) \quad [i = 0, \dots, n-1]$$

は互いに隣接していなくてはならない。さらに、観測値は有限の時空間におけるものであり、時空間の設定は任意とする。

5.2 一般化制約集合

観測値が以下のように与えられたとする、

$$p(t_0, v_0), \dots, p(t_n, v_n) \quad (1)$$

このとき、 $p(t_{i-1}, v_{i-1})$, $p(t_i, v_i)$, $p(t_{i+1}, v_{i+1})$ と $p(t_i, v_i)$, $p(t_{i+1}, v_{i+1})$, $p(t_{i+2}, v_{i+2})$ [$i = 1, \dots, n-2$] で囲まれた二つの領域の共通部分が存在するとき式 (1) は時空間 $[t_0, t_n]$ において一般化可能であるという。

この定義は、複数の観測値を線形不等式に一般化するために用いられるもので、隣接する三つの観測値をそれらを囲む三角形領域として表現し、さらに複数の三角形領域を一般化する条件を示している。したがって、二つの領域に共通部分があるという条件が、隣接する観測値の変化が単調である場合に限って一般化できるということをいっている。

一般化可能な区間 (1) を線形制約により一般化することは次のように定式化される。区間の端点 (t_0, v_0) , (t_n, v_n) および (t_n, v_0) によって作られる一般化制約集合を

$$\begin{aligned} \lambda_0 t_0 + \lambda_n t_n &= T \\ \lambda_0 v_0 + \lambda_n v_n &= V \\ 0 &\leq \lambda_0 \leq 1 \\ 0 &\leq \lambda_n \leq 1 \end{aligned}$$

とする。これによって、複数の隣接する観測値が線形方程

Back Ground

```
add(A,B,C) mono_dec(A,B)
deriv(A,B) vari(A,B,C,...)
などの制約の定義
```

Fore Ground

制約による一般化より得られた定性的状態を一階述語論理の形式で表したものの集合

Negative

ありえない、もしくは無意味な状態の定義 (負の知識)

```
pendulum(A,B,C) :-
    comp(A,0),
    deriv(A,B),deriv(B,C),
    mono_dec(A,C),
    などの定性物理モデル
```

図5 帰納的方法

式、不等式として一般化される。このようにして求められた一般化制約集合をここでは便宜的に定性的状態と呼ぶ。

5.3 幾何的關係値

次に二つの隣接する定性的状態の間の関係を求めるために、幾何的性質 (相似性、対称性) を導入する。二つの隣接する定性的状態を S_1, S_2 とするとき、係数 a_t, a_u, b_t, b_u によって示される式

$$\begin{aligned} \forall (t_1, v_1) \in S_1, \forall (t_2, v_2) \in S_2 \\ t_2 &= a_t(t_1 - b_t) \\ v_2 &= a_v(v_1 - b_v) \end{aligned}$$

が成立するとき、これらの係数を幾何学的関係値という。幾何的關係値は、隣接する定性的状態の間の増加、反復、減衰といった挙動の変化を捉えることができる。

定性推論で用いられる U-tube の例は振動しないので、一般化制約集合を求めた段階で得られる定性的状態は一つしか存在しない。そのため、この例では幾何的關係値は意味がない。しかし、振動するような U-tube を扱う場合は定性的状態間の関係を把握する必要がある。後で述べる減衰振り子の挙動を記述する際には幾何的關係値を用いている。

6. 変数間の関係の学習

ここまでの過程により得られた定性的状態についての情報から定性物理モデルを得るために、正例、背景知識などを用いた帰納的な方法を利用する (図5)。

6.1 前景知識 (正例)

物理運動は、複数の系列 i の時間 T と変数 V の対である観測値 (定量値) $p_i(T, V)$ としてとらえられる。そして、この観測値から得られる複数の定性的状態 Qsp_i は次のように表現される。

$$Qsp_i(Ts_{i(j-1)}, Ts_{ij}, [Sign_{i(j-1)}], a_{i(j-1)}, b_{i(j-1)}). \\ (i = 1, \dots, n \quad (j = 1, \dots, m))$$

ここで、 Ts_{ij} は、ある時空間の始まり、もしくは終わりの時間を表す。また $Sign_{ij}$ は、 $leq(\leq)$, $geq(\geq)$, $equ(=)$

などの不等号表現で表され、 a_{ij} , b_{ij} とともに領域を表す制約である。

また、同系列の定性的状態間の関係として以下の表現 Rp_i が得られる。

$$Rp_i(Ts_{i(j-1)}, At_{i(j-1)}, Av_{i(j-1)}, Bt_{i(j-1)}, Bv_{i(j-1)}), \\ (i = 1, \dots, n \ (j = 1, \dots, m))$$

ここで用いられる At_{ij} , Av_{ij} などはいずれも制約による一般化の過程で計算された実数値であり、定量値として管理される。これらの論理式はいずれも最初に与えられた観測値 $p_i(T, V)$ より得られるものであり、次で説明する背景知識を使って定性モデルを生成するために利用される。このような情報を、背景知識と対照に前景知識 (Foreground) という。

6.2 背景知識

ここまでは、観測値は一般化制約集合に一般化されたが、最終的に必要な定性モデルを論理式として生成するために、背景知識を利用する。まず、制約集合を記号化するための抽象化の方法を定義する。

定義 1 (抽象化) 以下の規則にしたがって、制約論理プログラムを通常の論理プログラムに変換することを抽象化という。その変換を τ と表記する。

1. **制約集合の抽象化** 制約集合 C に対応する抽象項 S が割り当てられているとすると、 $C \xrightarrow{\tau} S$ であり、抽象項が割り当てられていないならば、 C を包含する、抽象項の割り当てられている最小の制約集合に対する抽象項 $S \in C$ を写像する。
2. **関数の抽象化** C_i の抽象化を S_i とし、関数 f の抽象項が f で与えられているならば、 $f(C_1, \dots, C_n) \xrightarrow{\tau} f'(S_1, \dots, S_n)$ である。
3. **その他** 上記以外は自分自身に写像される。

この抽象化を用いることによって、定性的状態を定義することができる。

定義 2 (定性的状態) 一般化制約集合 $C_i (i = 1, \dots, n)$ をその抽象項としての定性的状態 $S_i (i = 1, \dots, n)$ に写像することができる。すなわち

$$C_i \xrightarrow{\tau} S_i \quad (2)$$

この方法によって、一般化制約集合 C を定性的状態の変化傾向 $Dir(C) \in \{dec, std, inc\}$ に変換することが可能になる。このような変換を実施するための背景知識は次のようになる。

$$\begin{aligned} mon\_inc(A, B) &:- dir(A) = inc, dir(B) = inc. \\ mon\_inc(A, B) &:- dir(A) = std, dir(B) = std. \\ &\vdots \\ deriv(A, B) &:- dir(A) = inc, B > 0. \\ &\vdots \end{aligned}$$

定性モデルは、以上のような前景知識、背景知識から既存の帰納学習アルゴリズムにしたがって求めることができる。アルゴリズムは前景知識をサンプリングして徐々に一般化していくものと、逆に最も一般的な論理式から負事例を含まないように特殊化していくものがある。ここでは、前者の方法を採用しており、観測値の時間順序にしたがって一般化が実施され、最終的な定性モデルが構成される。なお、具体的なアルゴリズムについては参考文献などを参照されたい [11]。

7. 適用例

7.1 U-tube による比較

比較研究としての Bratko ら [3] のものを取り上げる。彼らの研究の対象は U-tube (U 管) であり、実用時間内に定性物理モデルを求めることに成功している。

それに対して、本研究では入力データに観測値 (定量値) を用い、その定量値を定性値に変換する機構を制約論理プログラミングの枠組みで構築した。そして、その結果得られた定性値から帰納学習過程によって最終的に目的とする定性物理モデルを得る。

入力データは la, lb (管 A および管 B の水位の高さ) fab, fba (管 A から管 B への流れ、および管 B から管 A への流れ) を表す時間ごとの定量値である。

```
attributes([la, lb, fab, fba]).
p(0.0, [111.6, 135.2, 33.4, 41.3]).
p(1.0, [113.5, 133.3, 36.6, 38.2]).
p(2.0, [115.6, 130.6, 38.7, 36.6]).
:      :      :
```

背景知識は、*mon_inc*, *mon_dec*, ... など、QSIM での制約をほぼすべて定義する。結果として、次の定性モデルが学習された。

```
model(T, LA, LB, FAB, FBA) :-
    minus(LA, LB),
    minus(FAB, FBA),
    deriv(LA, FAB),
    deriv(LB, FBA),
    NT=1.00*(T+1.00),
    NLA=0.86*(LA+34.24),
    NLB=0.86*(LB+33.17),
    NFAB=0.85*(FAB+11.00),
    NFBA=0.86*(FBA+11.13),
    model(NT, NLA, NLB, NFAB, NFBA).
```

このモデルは、線形方程式以外は定性推論でよく用いられる U-tube の定性モデルと一致する。線形方程式で示された定量的な変化を表す部分はここでは意味がない。それは Bratko らの研究での U-tube は 1 回の変動を表現したものであり、連続した変化を扱っていないからである。

表 1 に性能比較を載せる。我々の学習システムは Quintus Prolog Ver3.1.1 で実現されているが、Bratko らのシステ

表1 U-tube における性能比較

	本システム	Bratko らのシステム
事例数	4,000	10
背景知識	約 30	約 5,408
学習時間	約 23,700 [ms]	約 17,000 [ms]

表2 過程別の学習時間

制約一般化	幾何的關係	構造一般化	計
6,617 [ms]	8,316 [ms]	8,767 [ms]	23,700 [ms]

ムは C 言語で開発された学習システム GOLEM を用いている。ここでの比較項目は、入力データ（事例、背景知識）の数、学習時間（Sun SparcStation）についてである。

ここで、本システムの事例数が多いのは、入力データとして観測値（定量値）をそのまま使っているからである。この場合四つの変数 la, lb, fab, fba それぞれについて 1,000 のデータを入力している。それに対し Bratko らは QSIM 形式のデータによる 10 の事例を入力している。逆に、背景知識については、本研究において約 30、それに対し Bratko らは約 5,408 入力されている。それは、本研究での背景知識は論理プログラミングにおける論理式形式のものであり、Bratko らの場合は基底事例（変数なしのアトム）であることによるものである。

学習時間を比較すると、本システムは約 24 秒、Bratko らのものは約 17 秒である。しかし、これは実質的な帰納学習時間だけを比較しているわけではない。それは本研究における学習時間には表 2 での三つの過程での時間が含まれているからである。

表 2 で制約による一般化の過程は、入力値を定性的状態に変えるのに使われている。よって、実質的な学習時間はその時間を差し引いた残りの時間で約 17,083 [ms] となり、Bratko らとほぼ同等であるといえる。

7.2 画像から学習例

ここでは減衰振り子の例を取り上げて、ビデオカメラで入力された動画画像から定性モデルを生成する（図 6）。ビデオカメラから対象までの距離は約 100 [cm] とした。各実験ごとに、初期振り角など（この場合 30 度とされている）を定め、Unix マシン上でのウィンドウに十分に収まるように初期条件を設定する。

図 7 はビデオカメラから取り込まれた画像を Unix マシン上に表示したものである。

帰納的一般化はこの画像から得られる定量値データに対して行われる。図 8 は定量値をその性質に着目して定性化していくところである。

ここで定性化されたそれぞれの領域は、前述した定性的状態に相当するものである。得られた減衰振り子の定性モデルは次のようである。

図6 実験環境

図7 実画像表示

```

model(T,X,Y,THETA,L) :-
mon_inc(X,THETA),
deriv(Y,THETA),
NT = 1.00 * ( T + 0.00 ),
NX = 0.83 * ( X + 112.4 ),
NY = 0.97 * ( Y - 212.1 ),
NTHETA = 0.83 * ( THETA + 0.75 ),
NL = 1.00 * ( L + 0.00 ),
model(NT,NX,NY,NTHETA,NL).

```

減衰振り子のモデルは、各時間ごとに成り立つ変数間の関係と同一変数における変化傾向である幾何的關係値によって記述されている。ここでは、変数 X と変数 $THETA$ の間に定性逆比例 (mon_dec) の関係が成り立ち、変数 Y を定性時間微分 ($deriv$) したものが $THETA$ となること示される。またその変化傾向はパラメータがおおよそ 1 以下であることから減少傾向を示しているといえる。したがって、ここで得られた定性モデルは妥当なものといえる。なお、この実験における実行時間は 24,217 [ms] であった。

図8 帰納的一般化

8. おわりに

時間軸上の物体の挙動から挙動の定性モデルを生成するために帰納論理プログラミングに基づく学習法を解説した。特に、定量データを定性的状態の記述に変換する一般化法を中心に解説した。こういった試みは、物理的挙動などの外部情報をそのままセンサー系データとしてとらえ、一般化学習を行うことで、定性的な説明をつくり出すことを目的としている。従来の定性推論、知識表現の研究は、このような外部情報の扱いを無視しており、それがこういった研究の弱いところであった。これに対し、自律ロボットのような知能、行動、知覚などの統合システムを設計する場合には、低レベルのデータと高度な問題解決知識の融合を図らなければならない。数値、記号を統一的に処理できる制約論理プログラミングとさらに定量データから定性モデルを獲得するために帰納的論理プログラミングを用いるといった我々の試みは、まさにこのような点が動機となっている。その結果によると、制約論理プログラミングと帰納的論理プログラミングを融合することができ、こういった点が論理プログラミングの今後の可能性を示唆していると考えられる。

参考文献

- [1] C. Feng: "Inducing temporal fault diagnostic rules from a qualitative model," TIMLG, The Turing Institute, George House, 36 North Hanover St., Glasgow, UK, 1991.
- [2] B. Bhanu: "A Qualitative Approach to Dynamic Scene Under-

standing," IMAGE UNDERSTANDING, Vol.54, No.2, September, pp.184-205, 1991.

- [3] I. Bratko, S. Muggleton and A. Versek: "Learning Qualitative Models of Dynamic Systems," Proc. of the Eighth International Machine Learning Workshop, 1991.
- [4] W. Buntine: "Generalized Subsumption and its Application to Induction and Redundancy," Artificial Intelligence, vol.36, 1988.
- [5] B. Kuipers: "Qualitative Simulation," Artificial Intelligence, 29:289-338, 1986.
- [6] I. Mozetic and C. Holzbaur: "Integrating Numerical and Qualitative Models within Constraint Logic Programming," Logic Programming Proc. of the International Symposium, 1991.
- [7] S. Muggleton: "Inductive Logic Programming," New Generation Computing, vol.8, 1991.
- [8] 淵一博 (監修), 溝口文雄, 古川康一, 安西祐一郎 (共編): "制約論理プログラミング", 知識情報処理シリーズ別巻 1, 共立出版, 1989.
- [9] 淵一博 (監修), 溝口文雄, 古川康一, 安西祐一郎 (共編): "定性推論", 知識情報処理シリーズ別巻 1, 共立出版, 1989.
- [10] 溝口文雄, 大和田勇人: "制約に基づく一般化を用いた定性物理モデルの学習", 日本ソフトウェア科学会第8回論文集, pp.xx-xx, 1991.
- [11] 吉川, 大和田, 溝口: "定量情報からの定性物理モデルの帰納学習", 人工知能学会第6回全国大会, 講演番号 4-7, 1992.

溝口文雄 (Fumio Mizoguchi)

1941年7月15日生。1966年東京理科大学工学部工業化学科卒。1968年同大学大学院修士課程修了とともに同大学理工学部経営工学科助手となる。1987年教授となり、現在大学院研究科委員、工学博士。1994年6月Stanford大学のCenter for the Study on Language and

Information (CSLI) の上級研究員 (Senior Research Associate) となる。人工知能、認知科学およびソフトウェア工学の分野に興味をもつ。人工知能学会1992年度理事を務める。日本ソフトウェア科学会会員、日本認知科学会会員、情報処理学会会員、米人工知能学会などの会員。