

帰納論理プログラミングにおける多重述語学習法*

1 C - 4

大導寺 牧子† 大和田 勇人† 溝口 文雄†

東京理科大学 理工学部‡

1 はじめに

近年帰納論理プログラミング(ILP)の枠組で効率良く学習するシステムが開発されているが、これらのシステムでは学習ターゲット(学習対象となる概念)が単一のものに限定される。実際の応用ではこのようなケースはまれで、複数の学習ターゲットを学習可能な枠組を提唱する必要がある。本稿ではこのような背景から、複数の学習ターゲットを処理する逐次型帰納学習法という方法を提案し、応用例として住宅間取りのレイアウト問題を取り上げ、本方法を評価することを目的とする。

2 逐次型帰納学習法

帰納論理プログラミングの枠組は、次のように定義できる。節あるいは確定節論理の述語のための定義を含む背景知識 B と、正と負の事例集合(真と偽の基底事実) \mathcal{E} が与えられるときに、背景知識と仮説が共に全ての正事例を包含し、負事例を一つも包含しない仮説 \mathcal{H} を見つけることが目的である。

例えば、以下のように正事例、負事例、背景知識を与え、学習ターゲットを述語 `has_wall` とすると、

$$\begin{aligned} \mathcal{E}^+ &= \left\{ \begin{array}{l} \text{has_wall(case1, living, south).} \\ \text{has_wall(case1, kitchen, east).} \\ \text{has_wall(case2, living, south).} \\ \text{has_wall(case2, kitchen, east).} \\ \text{has_wall(case3, living, south).} \\ \text{has_wall(case3, kitchen, east).} \\ \text{has_wall(case4, living, south).} \\ \text{has_wall(case5, living, east).} \\ \text{has_wall(case6, living, south).} \\ \text{has_wall(case6, kitchen, east).} \\ \text{has_wall(case7, living, south).} \\ \text{has_wall(case7, kitchen, east).} \end{array} \right. \\ \mathcal{E}^- &= \left\{ \begin{array}{l} \text{has_wall(case5, living, south).} \\ \text{has_wall(case4, kitchen, east).} \\ \text{has_wall(case5, kitchen, east).} \end{array} \right. \end{aligned}$$

*Multiple Predicate Learning on Inductive Logic Programming

†Makiko Daidoji, Hayato Ohwada and Fumio Mizoguchi

‡Faculty of Sci. and Tech. Science University of Tokyo

$$B = \left\{ \begin{array}{l} \text{area(case1, 43.78).} \\ \text{area(case2, 51.98).} \\ \text{area(case3, 58.58).} \\ \text{area(case4, 59.4).} \\ \text{area(case5, 62.7).} \\ \text{area(case6, 69.3).} \\ \text{area(case7, 72.6).} \end{array} \right.$$

得られる規則 \mathcal{H} は、以下のようであり、

```
has_wall(A, living, south) :- area(A, B), B < 59.4
has_wall(A, living, south) :- area(A, B), B >= 69.3
has_wall(A, kitchen, east) :- area(A, B), B < 58.58
has_wall(A, kitchen, east) :- area(A, B), B >= 69.3
```

背景知識が学習ターゲットを説明する因子となる。

レイアウト問題のように学習ターゲットが複数あり、学習ターゲット同士の関係に興味があるときには、初期に与えられる背景知識だけでなく学習ターゲット自身が説明因子とならなければならない。

そこで、本研究で提案する逐次型帰納学習法は、初期に与えられる背景知識と事例集合から得られた規則の中で、正事例を最も多く、正しく説明する規則を一つ選び背景知識として加え、説明された事例を除く。このようにして更新された背景知識と事例から再び規則を得る。すると、前回の学習で背景知識に加えられた規則を説明因子としても規則が得られることになる。

ここで、規則を選ぶ評価値として予測精度を用いる。予測精度は学習能力を評価するための手法であるクロスバリデーション法[2]で、「学習されたルールが真であると結論づけるデータが確かに真である割合」を表す *Predictive value(+)* とする。我々は本方法をレイアウト問題で設計知識を獲得するために用いる。この場合、ユーザーの条件に必ず適合する結論を得るようにした方がいいので、結論づけられるルールが確実に正しく推論されるこのパラメータを用いることとした。

得られた規則の予測精度はそれぞれ以下である。

```
Predictive value(+) for
has_wall(A, living, south) = 0.75
Predictive value(+) for
has_wall(A, kitchen, east) = 1.0
```

よって、予測精度の高い `has_wall(A, kitchen, east)` を選択し、背景知識に加える。更新された背景知識を用いて、同様に学習を行なうと、

```
has_wall(A, living, south) :-
```

```

has_wall(A, kitchen, east).
Predictive value(+) for
has_wall(A, living, south) = 0.86

```

が得られる。前回の学習における同規則の予測精度よりも高い予測精度をもつことがわかる。本方法を用いることで複数の学習ターゲットを関係付ける規則を導出し、同時に正しく正事例を説明することが可能となる。

3 アルゴリズム

本方法のアルゴリズムを示す。まず、初期に与えられる m 個の異なる述語 p_1, \dots, p_m のための事例集合 E と q_1, \dots, q_l の述語定義を含む背景知識 B_{cur} から、ターゲット述語 p_1, \dots, p_m 各々に対し学習を行ない、 E, B_{cur} に関して完全で無矛盾な仮説 H_{cur} を導く。最大の予測精度をもつ理論 T が一つ選択され、背景知識 B_{cur} に加えられる ($B_{next} := B_{cur} \cup T$)。同時に T が説明する事例 $E_{exp} = \{e \in E_{cur} \mid T \models e\}$ は消去される ($E_{next} := E_{cur} - E_{exp}$)。 E_{next}, B_{next} から H_{next} を導く。以降、この処理を繰り返す。

逐次型帰納学習法の処理のながれを図 1 に示す。

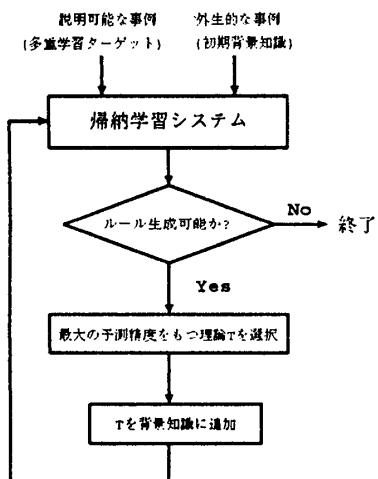


図 1: 逐次型帰納学習法アルゴリズム

4 レイアウト問題への適用実験

住宅の間取りにおいて、部屋を一つのオブジェクトと捉えると、各々のオブジェクトは、違うオブジェクトと「隣接する」、「壁をもつ」、「角をもつ」と説明できる。住宅の間取りに一般的に成り立つ規則をこれらを用いて説明することを考える。

適用実験として 149 の間取りの設計事例から、表 1 のデータを初期入力として用い、逐次型帰納学習を 28 回まで繰り返し行なった。尚、学習システムは数値を学習可能な GKS (GaKuShu)[1] を用いた。

表 1: 初期入力

Positive Example	Number of clauses
east_of(Case, Room1, Room2)	1647
south_of(Case, Room1, Room2)	1575
has_wall(Case, Room, Direction)	2400
corner(Case, Room, Direction)	877

Background Knowledge	Number of clauses
floor_space(Case, SpaceSize)	149
ent_direction(Case, Directon)	149

1 回目の学習で得られた規則の予測精度の分布と、28 回目の学習で得られた規則の予測精度の分布を図 2 に示す。

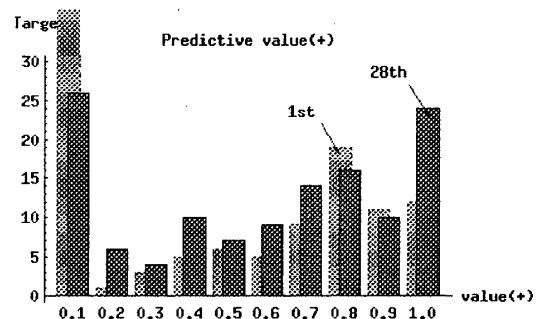


図 2: 予測精度の分布

1 回目の学習で得られる規則の予測精度は 0 ~ 0.1 が圧倒的に多く、正しい規則が多く導出されていない。しかし逐次的に学習された規則を背景知識に加えていくことで、その分正しい規則で説明される規則が増加するため、各規則に対する予測精度があがる。図 2 より、28 回目の学習では予測精度の高い規則が多く導出されるようになったといえる。

5 まとめ

帰納論理プログラミングの枠組で、複数の学習ターゲットを処理する逐次型帰納学習法を提案した。また、住宅間取りのレイアウト問題に適用させて、本方法が学習の精度を増加させながら複数の学習ターゲットを関係付ける規則の導出が可能であることを示した。

参考文献

- [1] F. Mizoguchi and H. Ohwada. Constrained relative least general generalization for inducing constraint logic programs. *New Generation Computing*, Vol. 13, pp. 335–368, 1995.
- [2] Robert S. Galen Sholom M. Weiss and Prasad V. Tadepalli. Maximizing the predictive value of production rules. *Artificial Intelligence*, Vol. 45, pp. 47–71, 1990.