

ファジイ論理プログラムの帰納による数値属性の予測

1K-03

吉田 浩幸[†]

[†]名古屋工業大学大学院工学研究科

犬塚 信博[‡]

[‡]名古屋工業大学共同研究センター

1はじめに

近年、論理プログラミングの枠組みにおいて帰納学習を行う帰納論理プログラミング(ILP:Inductive Logic Programming)に関する研究が盛んに行われている。

ILPは背景知識から事例を説明する論理プログラムを帰納する。論理プログラムで記述した背景知識を学習システムが利用でき、また帰納されたプログラムを知識として読むことができるところが大きな長所である。しかし、数値属性を効率よく扱えない、また数値を予測する問題も扱えないという短所もある。

その解決法の一つとして、帰納ファジイ論理プログラミング(IFLP:Inductive Fuzzy Logic Programming)を提案してきた[1]。これは、ファジイ論理プログラミングを応用した帰納システムで、連続真理値を扱った論理プログラムにより背景知識を柔軟に記述することが可能となる。このIFLPはILPと同様に正負事例から帰納学習し、また学習した仮説を用いて未知事例を正負に分類する。

本研究では、ファジイ論理プログラミングを用いて数値属性を連続的な真理値として扱いながら、正負ではなく連続的な真理値を持つ概念を帰納し、これによって数値属性を予測する帰納学習法を提案する。

2 ILP と IFLP

ILPは論理プログラミングの枠組みで帰納学習を行うシステムである。一般に論理プログラミングでは、 a, b_1, \dots, b_n をリテラルとすると $a \leftarrow b_1 \wedge b_2 \wedge \dots \wedge b_n (n \geq 0)$ という形式の論理式(ホーン節)を扱う。その取り得る真理値は0または1である。

この枠組みでILPの目的は、論理プログラム B 、帰納の目標述語の基礎例の集合 E^+, E^- に対して、

$$B \cup H \models e^+, \forall e^+ \in E^+$$

$$B \cup H \not\models e^-, \forall e^- \in E^-$$

を満たす論理プログラムの仮説 H を求めることである。このとき論理プログラム B を背景知識と呼び、 E^+ の元を正事例、 E^- の元を負事例と呼ぶ。

IFLPはファジイ論理プログラミングの枠組みのもとで帰納学習を行う。ファジイ論理プログラミングには異なる枠組みが提案されているが、ここでは安井らの提案するファジイ論理プログラミング[2]をベースにILPを拡張している。

ファジイ論理プログラムはホーン節のファジイ集合と定義され、ファジイ集合とは、その帰属度合いが0から1までの連続的な数値(メンバシップ値)を取ること

ができる要素の集合である。ファジイ論理プログラムではホーン節のメンバシップ値によって節の連続真理値(または単に真理値)を表す。

これによりファジイ論理プログラム A と連続真理値付きの論理式 $e/\mu(e$ は通常の論理式、 μ は連続真理値)に対し、帰結関係 $A \models e/\mu$ を定義できる[1]。すなわち、 $A \models e/\mu$ は A の最小ファジエルブランモデルが e に μ 以上の真理値を与えることを意味する。

これにより背景知識を柔軟に記述すること可能となるのがその特徴である。また数値属性を0から1までの真理値としてマッピングし、扱うことができる。

IFLPによる分類問題はファジイ論理プログラムの背景知識 B 、正事例集合 E^+ 、負事例集合 E^- に対して、

$$B \cup H \models e^+/\mu^+, \forall e^+ \in E^+$$

$$B \cup H \not\models e^-/\mu^-, \forall e^- \in E^-$$

を満たすファジイ論理プログラムの仮説 H を求める。ここで μ^+, μ^- は正負事例の連続真理値を制限するパラメータで $0 \leq \mu^-, \mu^+ \leq 1$ である。ここでは E^+ と E^- を μ^+, μ^- の境界で分離する H を求めることが目的であり、実験によってこれを示してきた。

3 連続真理値の予測

本研究ではこのIFLPを連続した真理値を予測するように拡張する。これは全事例に0から1までの連続真理値を与え、その真理値と同程度満たす仮説を求めるというものである。

事例のファジイ集合 E の元 e の真理値を $\mu(e)$ とする

$$B \cup H \models e/\mu(e) - \Delta\mu, \forall e \in E$$

$$B \cup H \not\models e/\mu(e) + \Delta\mu, \forall e \in E$$

となるファジイ論理プログラムの仮説 H を求めることが目的である。ここで $\Delta\mu$ は満たすべき真理値の許容範囲である。

提案手法では分類問題のような正負事例ではなく、連続真理値付きの事例集合から帰納が行われるため、負事例という概念はなくなる。また学習された仮説により未知事例に正負を予測(分類)するのではなく、提案手法では真理値を予測することが目的となる。

4 真理値帰納アルゴリズムと実装

提案手法では、[1]と同様にトップダウンILPシステムであるFOILのアルゴリズムを拡張することで、ファジイ論理を扱えるようにする。そのアルゴリズムの概要を図1に示す。ここで $gain$ とは情報利得のことと、提案手法では連続真理値を扱うように拡張した。

FOILと同様に $gain$ の値が最大となるリテラルを節に追加することにより節を生成する。本手法では言語ヘッジを持つリテラルを許す。言語ヘッジとは連続真

```

1 Initialization
2 theory := a null program
3 foreach  $e_i/\mu(e_i) \in E$   $\mu_{\text{covered}}(e_i) = 0$ 
4 While  $\exists i [\mu_{\text{covered}}(e_i) < \mu(e_i) - \Delta\mu]$ 
5 clause := head ←
6 While  $\exists i [\mu_{\text{covered}}(\text{clause})(e_i) > \mu(e_i) + \Delta\mu]$ 
7 Find a literal  $l$  by using gain
8 Add  $l$  to the body of clause
9 EndWhile
10 Add clause to theory
11 foreach  $e_i$   $\mu_{\text{covered}}(e_i) :=$ 
     $\max(\mu_{\text{covered}}(e_i), \mu_{\text{covered}}(\text{clause})(e_i))$ 
12 EndWhile

```

E : 事例集合 $\mu(e)$: 事例 e が持つ真理値
 $\mu_{\text{covered}}(e)$: 事例 e が満たしている真理値
 $\mu_{\text{covered}}(\text{clause})(e)$: clause によって満たされる事例 e の真理値

図 1: 提案する帰納アルゴリズム

理値を変更するために、リテラルの前に付加される修飾詞で *very* 等がある。ファジィ論理プログラムではアトム a と言語ヘッジ h に対し ha の形式をリテラルとする。本実装では、あるリテラルに言語ヘッジを付加する場合、その真理値は元の真理値の n 乗 ($n > 0$) となるような言語ヘッジを新たに定義した。 n の値を動的に変化させ、*gain* 最大の n を探索することで、最適な言語ヘッジを見つけている。これにより表現力を持つ仮説空間の効率的探索が可能となり、真理値予測の精度を向上させるものとなる。

5 数値予測問題と学習結果

数値予測問題は目標の数値属性の値を 0 から 1 までの真理値にマッピングし、その真理値と同程度満たす仮説を帰納することで数値属性の予測に応用できる。

前節で提案した帰納アルゴリズムを実装して、これを CTIL(Continuous Truth values Inductive Learner) とした。これによって帰納した仮説を用いて未知事例に対して真理値を導出することで数値予測を行い、実際の値と比較することで仮説の精度を評価する。

実験は UCI の機械学習データベースにある abalone (データ数 4177, 属性数 8) を用い、 $\Delta\mu$ の値を事例 e が持つ真理値 $\mu(e)$ に対して 5%, 10%, 15%, 20%, 25% と変化させ、それぞれに対して言語ヘッジの有無の場合について、10-fold Cross Validation 法で実験を行った。

一般的に数値予測の精度評価には平均二乗誤差 (MSE: Mean Squared Error) が用いられ、それは

$$MSE = \frac{\sum(\text{実際値} - \text{予測値})^2}{\text{データ数}}$$

で定義される。MSE はデータセットに依存しているので、ここではそれを正規化した

$$\text{相対 } MSE = \frac{MSE}{\text{テストデータの分散}}$$

を精度評価としている。またここでは Regression Tree を用いた学習による手法 [3] と比較する。

Regression Tree は基本的構造は決定木と同様である

表 1: 実験結果(相対平均二乗誤差)

$\Delta\mu$	5%	10%	15%	20%	25%
hedge なし	0.610	0.567	0.586	0.548	0.542
hedge あり	0.612	0.574	0.492	0.534	0.588
Regression			0.539		
石井 [3]			0.515		

いずれも 10-fold Cross Validation による結果

が、数値属性を予測するところが異なる。ここで比較実験として挙げる理由は、本手法と同様に Regression Tree は構造的なルールを出力するためである。

表 1 に $\Delta\mu$ と言語ヘッジに対する CTIL の結果および Regression Tree の結果を示す。その結果、 $\Delta\mu$ が 15% で言語ヘッジがあるときに最もよい精度をあげている。

この結果から、 $\Delta\mu$ の値が小さい場合は、仮説が事例に特化され、言語ヘッジある場合に特にその傾向が強くなり精度がよくない。また $\Delta\mu$ が大きい場合には、言語ヘッジがないときは適度に仮説が一般化されているが、あるときは一般化され過ぎるためあまりよくない。CTIL では、言語ヘッジある場合は最適な言語ヘッジを探索するため学習用のデータに特化される可能性が高いが、適切な $\Delta\mu$ の値を設定することで良い結果が得られ、Regression Tree の手法と比較しても CTIL は良い結果が得られることが確認できる。

6 おわりに

本稿では、IFLP を拡張することによって数値予測可能な ILP システムのアルゴリズムを提案した。このシステムを CTIL として実装し、Regression Tree による手法を比較実験を行い本手法を評価した。その結果、CTIL は Regression Tree による手法と同等の結果が得られることが確認できた。

CTIL では論理プログラムの仮説が出力されるため表現力があり人間が理解することが可能で、また人間の書いた背景知識を加えることができるので、さらなる精度の向上が期待できる。

今回の実験では回帰分析用のデータセットを用いているため、論理プログラムの特徴を活かした問題設定とは言えない。そのため今後の課題としては、論理プログラムのデータ構造を活かした問題に対して本手法を適用し有効性を考察する必要がある。

参考文献

- [1] D. Shibata, N. Inuzuka, S. Kato, T. Matsui and H. Itoh, "An Inductive Algorithm Based on Fuzzy Logic Programming," PAKDD-99 , LNAI 1574, Springer (1999).
- [2] 安井浩之, 向殿政男, "Lukasiewicz の含意を用いたファジィ論理プログラミングに関する考察", 日本ファジィ学会論文誌, Vol.8, No.5 pp.863-878 (1996).
- [3] 石井拓, 森本康彦, 森下真一, "区間・領域分割を用いた Regression Tree の構成", 信学技報 AI97-43 (1997).