

4 Q - 4

事例からのルール獲得における中間仮説抽出手法

秋葉 泰弘 金田 重郎
NTT 情報通信網研究所

1 はじめに

ID3 等の診断型ルール獲得アルゴリズムで獲得された知識は、論理的には積和標準型とみなせる。しかし、人間は背景知識を用いて推論を積み重ねて判断するため、獲得された知識を 1 段の積和標準型を用いて表現すると、ルールの持つ意味が理解困難となる場合がある。

そこで、事例から 2 段のルールを生成し、この 1 段目の結論を中間仮説として人間に提示して知識獲得を支援する手法を提案する。本手法は、例外を除去した事例から 1 段のルールを獲得するステップと、1 段ルールを 2 段化するステップから構成され、記述量が(準)最小化された 2 段ルールを生成するように例外事例を決定する。これにより、例外事例の影響を抑えた 2 段ルールの獲得が期待される。

2 準備

Definition 1 (notation)

(1) 論理変数をアルファベットの大文字で表す。

(2) 論理関数をアルファベットの小文字で表す。

(3) 論理関数 f に対して、 $\&$ を \times に、 or を $+$ に置き換えて出来る整式で、論理関数 f を表現する。

一例 —

論理式

$$A \& B \& C or A \& D or E$$

を整式

$$ABC + AD + E$$

で表現する。

Definition 2 (weak division)

論理関数 f, g に対して、論理関数 q, r が存在して、論理関数 f を論理関数 g で代数的に除法をした時に、商が論理関数 q で剩余が論理関数 r であるとする。この時、論理関数 f は、論理関数 g で weak division 可能であると言う。

一例 —

論理関数 $ABC + AD + E$ は、論理関数 $BC + D$ で weak division 可能である。

Definition 3 (広義の kernel)

論理関数 f が、weak division 可能な論理関数であってかつ、代数式として既約な多項式とみなせる時、論理式 f を(狭義の) kernel という。また、論理関数 f が、weak division 可能な論理関数であってかつ、代数式として単項式としてみなせる論理関数である時、論理式 f を pseudo kernel と言う。さらに、(狭義の) kernel と pseudo kernel を総称して、広義のカーネルと言う。

一例 —

論理関数 $ADF + ADG + AE + BF + BG + CF + CG$ は狭義の kernel として $DF + DG + E$ と $F + G$ を持ち、pseudo kernel としては AD, AF 等を持つ。

Definition 4 (MDL 原理)

「ルールの記述量とそのルールの例外の記述量」(以下この量を $\#$ 値と呼ぶ。) の和が最小になるルールが、未知事例に対する決定能力を最大とする。

3 問題とその解決アルゴリズム

problem 1

n 個のクラス $\{C_i\}_{1 \leq i \leq n}$ に分類される事例集合 \mathcal{D} から MDL 原理を満たす 2 段ルールを求める。

基本方針

次の処理(*)により、事例集合 \mathcal{D} の任意の部分集合 \mathcal{S} に対応する 2 段ルールを生成し、その 2 段ルールとその 2 段ルールの例外事例(補集合 $\bar{\mathcal{S}}$ の部分集合)の中から、MDL 原理を満たす 2 段ルールを探索する。(以下探索 I と呼ぶ。)

処理(*)

部分集合 \mathcal{S} から ID3 により各クラス C_i を説明する 1 段ルールを生成し、その各 1 段ルールの広義の kernel 集合 K_i ($1 \leq i \leq n$) から任意の kernel を選び、2 段ルールの候補 1 を生成する。さらに、残りの各 1 段ルールの広義の kernel から任意の kernel を選び、2 段ルールの候補 2 を作る。以降この操作を可能な限り試行し、最後の候補を部分集合 \mathcal{S} に対する 2 段ルールの候補にする。あらゆる広義の kernel の組合せに対する 2 段ルールの候補の中で、ルール記述量最小の 2 段ルールを探索し(以下探索 II と呼ぶ。)、それを部分集合 \mathcal{S} に対する 2 段ルールとする。

例えば、クラス C_1 に対する 1 段ルールが

$$f = ADF + ADG + AE + BF + BG + CF + CG$$

である時、 f の kernel $DF + DG + E$ を選んで、

$$\text{kernel1} = DF + DG + E \quad (1)$$

と置き、 f を kernel1 で weak division し、

$$f = A(\text{kernel1}) + BF + BG + CF + CG \quad (2)$$

と変形し、式(1)を 1 段目の候補とし、式(2)を 2 段目の候補 1 とする。次に f の kernel $F + G$ を選んで、 f の kernel $F + G$ を選んで、

$$\text{kernel2} = F + G \quad (3)$$

と置き、 f を kernel2 で weak division し、

$$f = A(\text{kernel1}) + B(\text{kernel2}) + C(\text{kernel2}) \quad (4)$$

と変形し、式(1)と式(3)を 1 段目の候補 2 とし、式(4)を 2 段目の候補 2 とする。これ以上試行が出来ないので、1 段目の候補 2 を最終的な 1 段目の候補、2 段目の候補 2 を最終的な 1 段目の候補とする。また、部分集合 \mathcal{S} に対する 2 段ルールにより説明されない集合 $\bar{\mathcal{S}}$ の要素を部分集合 \mathcal{S} に対する 2 段ルールの例外事例とする。

[†]Two-stage rule induction using MDL principle

Yasuhiro Akiba, Shigeo Kaneda

NTT Network Information Systems Laboratories




図1. 各処理の関係

一般に、探索I及び探索IIを全探索すると組合せ的爆発を起こすので、次の様なヒューリスティクを提案する。

—探索Iに対するヒューリスティク—

探索の始点を全事例集合Dとし、濃度がDの濃度より1小さい部分集合にのみ探索を進め、その中で||値が探索始点の||値より小さいものがあれば、その集合を探索の始点として先と同様の操作を繰り返すと言う様に探索を深めていき、出来なくなったら探索を終る。

—探索IIに対するヒューリスティク—

ルールの記述量を一番減らす(狭義の)kernelを優先的に採用し、weak division可能でなくなったら、探索をやめる。

4 アルゴリズムの評価

データセット1: 扶養家族に係わる控除金額決定事例 128事例

データセット2: ISDN問診ESからの事例 84事例

を基に次の5項目についてアルゴリズムの性質を評価した。

項目1: 記述量の減少傾向

データセット1、2を本アルゴリズムに通したところ、記述量を三分の一から二分の一削減

項目2: 記述量最小化によるノイズ除去動作

データセット1 128事例からランダムに選択した3事例にクラスのノイズを混入して、本アルゴリズムに通したところ、ノイズをほぼ正確に除去可能

表1. ノイズ除去結果

ノイズ除去	非ノイズ除去	
3個	0個	2ケース
2個	1個	2ケース
2個	0個	5ケース
0個	0個	1ケース

項目3: ノイズ除去による未知事例に対する正当率の推移

データセット1中から75%をランダムに抽出し、ID3と本アルゴリズムで各々ルールを生成し、先の残りの25%でテストしたところ、前者は80%の正解率であるのに対し、後者は92%

項目4: トレーニングデータのノイズの有無による中間仮説の違い

データセット1 128事例からランダムに選択した3事例にクラスのノイズを混入したデータセットと生のデータセット1を各々本アルゴリズムに通したところ、出力された中間仮説はほぼ同一

表2. データの差異による中間仮説の違い

トレーニングデータ	生成された中間仮説				
	k1	k2	k3	k4	k5
データセット1	○	○	○	○	
データセット1の75%		○	○		
データセット1に 3つクラスノイズ 混入(その1)	○	○	○	○	
データセット1に 3つクラスノイズ 混入(その2)	○	○	○	○	○

k1: 20歳又は配偶者 / 子どもで80歳

k2: 別居又は同居健常者

k3: 扶養対象同居障害者

k4: 扶養対象同居健常者

k5: 配偶者又は子供

項目5: 生成された中間仮説(2段ルールの1段目のルール)の妥当性

データセット1を本アルゴリズムに通したところ、所得税法上意味のある中間仮説(2段ルールの1段目)をある程度生成

5 おわりに

従来のルールインダクション(ID3)により専門家に判りやすいルールを、中間仮説を生成することにより生成した。また、本アルゴリズムは、ノイズをほぼ正確に除去可能であった。

参考文献

- [1] Brayton R.K., McMullen C.(1982) : "The decomposition and factorization of Boolean expressions", in Proc Int. Symp. Circ. Syst.(ISCAS-82), Rome, May 1982. Algorithms for VLSI Synthesis.
- [2] Quinlan, J.R. (1986): "Induction of decision trees", Mach. Learning 1, 81-106
- [3] Quinlan J.R., Rivest R.L. (1989): "Inferring Decision Trees Using the Minimum Description Length Principle", Information and Computation 80, 227-248.