

メタルール学習機構を持つルール洗練化システム

1D-10

橋恵昭 山口高平  
静岡大学 工学部

1 はじめに

筆者らは、専門書等から容易に得られるが、あまり有効ではない経験則が存在する問題領域において、過去のデータを参照しながら、その経験則を有効性の高い知識へと洗練化していくシステムを開発してきた。本稿では、実際に問題を解決するオブジェクトルールと、オブジェクトルールの実行を制御するメタルールを分離し、それぞれ学習を行なうシステムの枠組みについて述べる。

2 システムの構成

2.1 概観

システムの構成を図1に示す。

本システムは、まず、オブジェクトルールが適用されるべきDS(データセット)を選別するメタルールを学習し、さらにそのメタルールによって与えられるDSにおいて有効なオブジェクトルールを学習するシステムである。例えば、時系列DSを与えた場合、メタルールベースは、オブジェクトルールベースの適用時期を判断する。

経験則が適用されるべきDSに関する知識は専門書から得られないため、メタルールは、ルール帰納的学習の手法により学習される。

オブジェクトルールの学習には、経験則である初期(オブジェクト)ルールを利用し、メタルールにより与えられるDSにおいて有効性が向上するように、洗練化が行なわれる。

最終的に、“DS選別メタルールベース+洗練化(オブジェクト)ルールベース”を学習結果とする。

以下の項において、それぞれの過程について述べる。

2.2 ルール帰納的学習機構によるメタルールの学習

DSの選別を行なうメタルールを記述するための属性は、オブジェクトルールの世界に影響を与える別の世界から得る。これらの属性は、その別の世界の問題解決に使用するのではなく、システムが対象とする世界のオブジェクトルールの実行制御に使用する。

また、DS群と初期ルールベースを、ルール実行部にて与えて実行し、その結果をDS評価基準によって“成功”、“失敗”の各クラスに分ける。

メタルール記述用属性の値と上記のクラスを、ID3[1]を元にしたルール帰納的学習システムに与え、DSを分類する決定木を生成する。生成された決定木においては、その根節点から葉節点までのパスが、オブジェクトルールに対して適切なDSを選別するための“DS選別

メタルール”の条件部となる。

ただし、メタルール記述用属性が不十分であることから、完全な分類を行なうことはできない。また、分類された葉節点においても、学習用DSに対する過度適応を考慮する必要がある。そのため、現在は“一般的過ぎるルール(深さが2以下の葉節点)と、複雑であり適用されないルール(含まれるデータ数がその葉節点の深さ未満である葉節点)は除く”という基準を設けている。こうして、この基準を満たした葉節点の数のDS選別メタルールが得られる。

DS選別メタルールベースは、学習時においては、洗練化システムに与える学習用DSを選別をし、実行時においては、洗練化ルールに対して、その元になったルールの適用範囲を選別するように、未知DSを選別する。

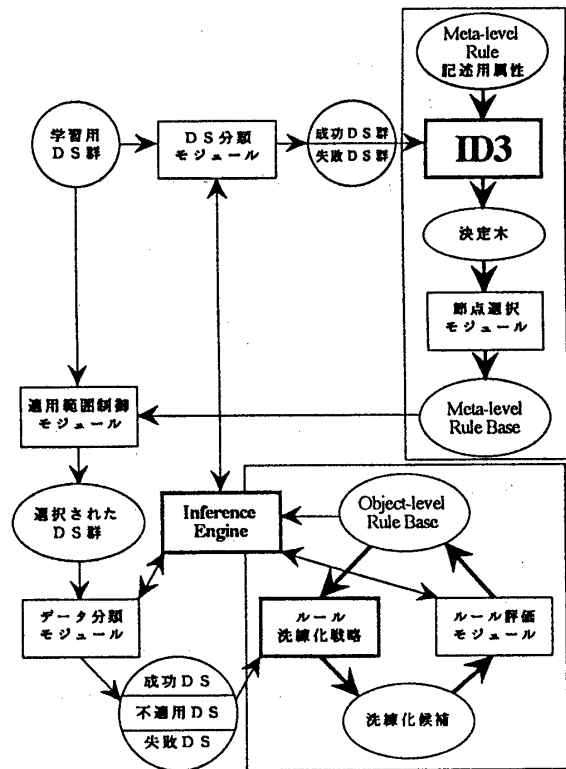


図1: システム構成

2.3 ルール洗練化によるオブジェクトルールの学習

ルール洗練化システムでは、ルールの実行結果を“成功”、“失敗”、“不適用”に分類し、これに基づいて、ルール中の定数記号を変数化する一般化戦略、変数記号を定数化する特殊化戦略、タスク、ドメインの性質を考慮したタスク、ドメイン戦略の4種類の戦略を繰り返す、適用しルールを洗練化する。洗練化の詳細は、紙面の都合上、文献[2][3]に委ねる。

## 3 ルール洗練化実験

本節では、株式市場テクニカル分析を例題として実験を行ない、本システムを評価する。

実験は、株式市場テクニカル分析の代表的な手法である“グランビルの法則”を初期オブジェクトルールとし、DS 範囲選別メタルルールを記述するための属性としては、主に株式市場ファンダメンタル分析などで用いられる属性を使用して行なった。評価には“株購入時の運用資金を 100 とした指数 (以下、運用指数、または単に指数と呼ぶ)”を用い、グランビルの法則は中長期の予測を目的としているため、3ヶ月後の運用指数の比較で性能を論じる。

表 1 に、未知データに対するルールの適用結果を示す。各実験に用いたデータは以下の通りである。

	学習用 DS の期間	未知 DS の期間	銘柄群
1	1985 Jan.1st	1986 Jan.1st	商業
	-1985 Dec.4th	-1987 Sep.1st	
2	1985 Jan.1st	1986 Jan.1st	金融、保険
	-1985 Dec.4th	-1987 Sep.1st	
3	1986 Jan.1st	1986 Jul.1st	商業
	-1986 Jun.4th	-1987 Sep.1st	

表 1: ルール洗練化実験結果

		適用数	運用指数		
			1ヶ月後	2ヶ月後	3ヶ月後
A) 初期オブジェクト ルールベース	1	273	102	106	110
	2	188	103	107	116
	3	161	99	102	104
B) メタルルールベース + 初期オブジェクト ルールベース	1	146	103	107	113
	2	172	103	108	116
	3	17	111	111	109
C) メタルルールベース + 洗練化オブジェクト ルールベース	1	98	111	112	116
	2	226	105	110	117
	3	11	105	108	113

過去に行なった洗練化のみを行なう学習システムの評価実験では、洗練化を行なっても未知 DS に対する性能は向上しないという結果に終わった.[3]

今回の実験においては、(A) と (B) の性能をみると、学習されたメタルルールは、初期オブジェクトルールが比較的有効な範囲を選別することができているといえる。

そして、(B) と (C) の比較では、いずれも洗練化ルールの方が良い性能を示しており、適切な DS を与えることにより、洗練化の効果が未知 DS に対しても、安定して現れるようになったといえる。

最終的に、システムへの入力である (A) と出力である (C) の性能の比較すると、今回の実験では、ある程度範囲が限定されてはいるが、未知 DS に対してもロバストで、しかも有効性の高いルールが得られたといえる。

## 4 考察

## 4.1 評価

洗練化のみを行なうシステムでルールの有効性を増すことができなかったことは、悪構造度の高い現実の問題領域においては、ルールの記述属性の不足、DS への過度適応などの問題の影響が非常に大きいことを示している。

本枠組みでは、メタルルールがオブジェクトルールの実行を制御することにより、前述の問題点に対処している。メタルルールの学習についても同じ問題が存在するが、実行制御というタスクに限定していえば、オブジェクトルールほど多くの属性を必要とせず、また、データ量が少なくなることが期待できる。従って、前述の問題点を完全に解決するまでには至っていないが、その影響による学習性能の劣化を抑制しているといえる。

実験結果は、属性の不足などにより学習性能が低く、しかも属性の獲得が困難であるような問題領域において、メタルルール学習機構を持つルール洗練化システムの枠組みが、有効である可能性を示唆している。

## 4.2 課題

本システムには、学習性能に影響するパラメータがいくつか存在する。主なものを挙げると、

- メタルルールの実行制御単位 (ルールベース / ルール)
- 洗練化ルールの淘汰基準
- DS への過度適応回避基準
- 学習用データの構成法

などがあり、今後、検討していく予定である。

## 5 おわりに

本稿では、株式市場分析を題材にして、メタルルール学習機構を持つルール洗練化システムを評価した。現在、種々のデータを用いて実験を行い、前節の課題の検討を進めている。

## 参考文献

- [1] Quinlan, J.R., Induction of Decision Tree, *Machine Learning*, 1, pp.81-106, (1986).
- [2] Yamaguchi, T., and Tachibana, Y., A Technical Analysis Expert System with a Knowledge Refinement Mechanism, *Proceedings of The first International Conference on AI Applications on Wall Street*, pp.86-91, (1991).
- [3] Yamaguchi, T., and Tachibana, Y., Unifying Rule Induction and Rule Refinement - Towards Discovering Anomaly from Granville's Law in a Stock Market Technical Analysis -, *Proceedings of '99 Korea / Japan Joint Conference on Expert Systems*, to be appeared, (1993).