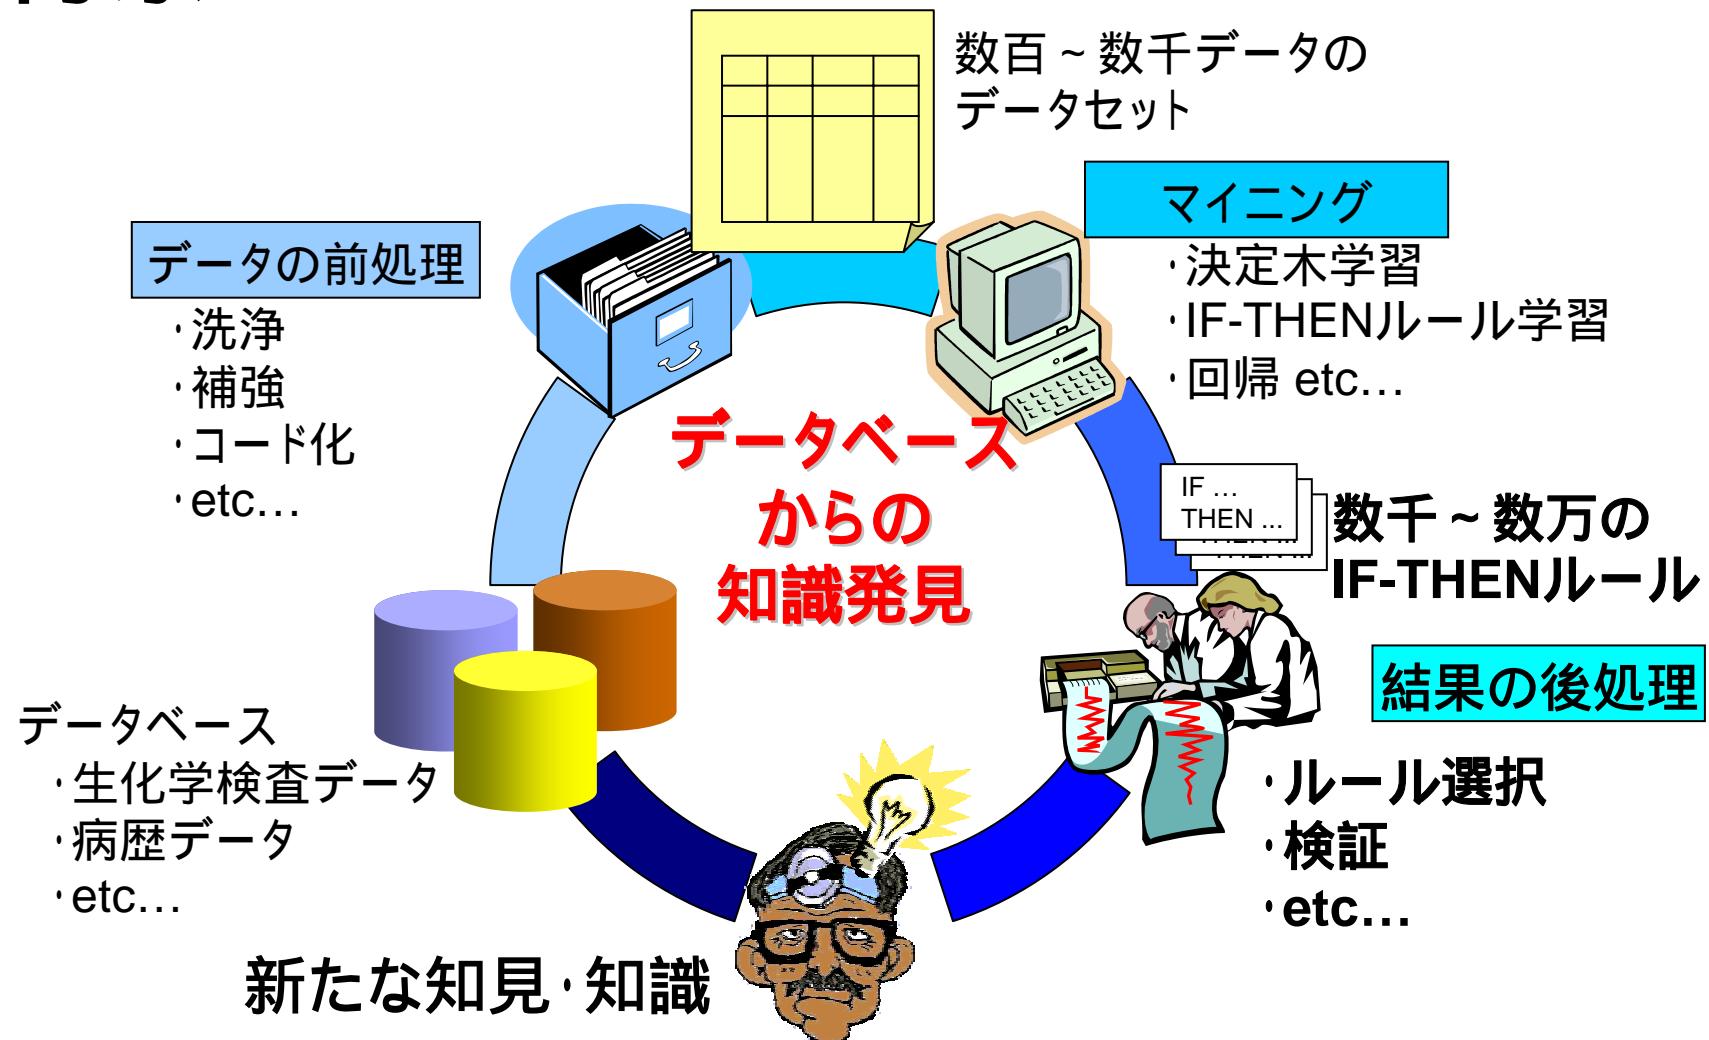




ルール評価支援ツールのための ルール評価モデル 構築アルゴリズムの評価

阿部 秀尚¹⁾ , 津本 周作¹⁾ , 大崎 美穂²⁾ , 山口 高平³⁾
島根大学医学部医学科医療情報学講座¹⁾
同志社大学工学部情報システムデザイン学科²⁾
慶應義塾大学理工学部管理工学科³⁾

背景



マイニングによって得られた膨大なルールを人間が全てを評価することは困難

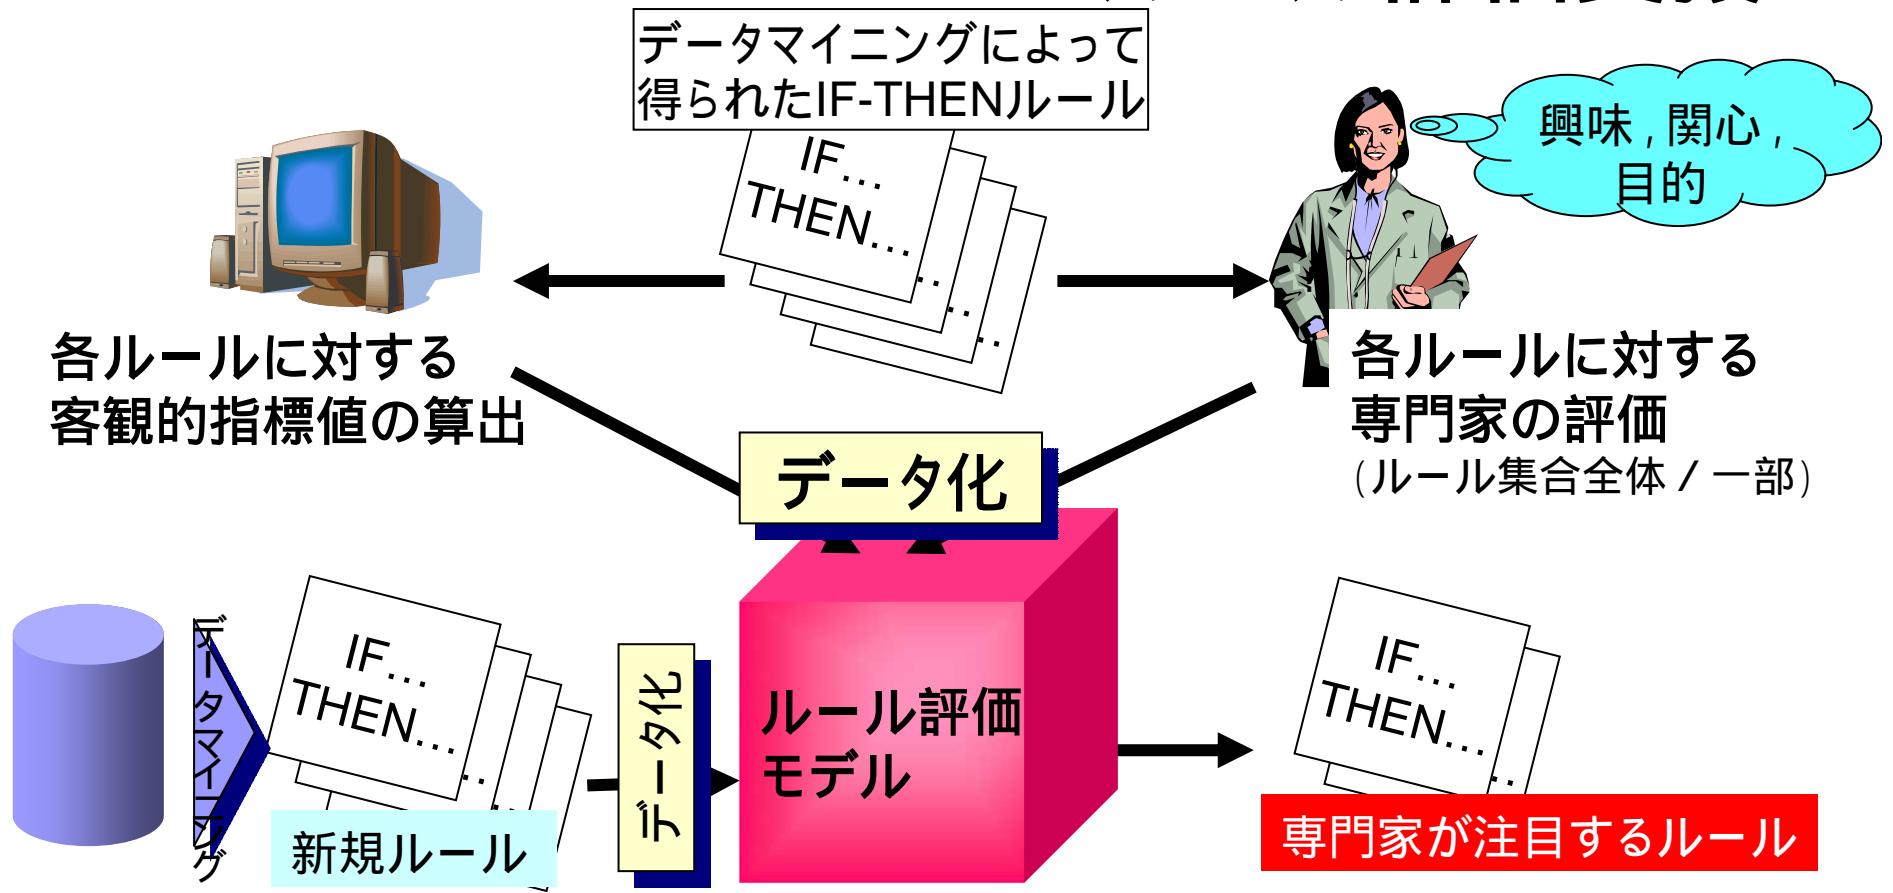
ルール評価支援と課題

- ルールの正答率や再現率などの評価値を利用したルール選択
- 専門家の興味や関心を推定する評価値(興味深さの指標)
 - ルールの評価値に基づく指標による興味の推定
 - ルールの類似度による興味の推定

- ルールの評価値(客観的指標と呼ぶ)が専門家の興味を単独の指標で表現するのは困難 [Ohsaki 04]
- 興味深さの指標が提案された領域以外で有効性は未検証

複数の客観的指標を組み合わせ、専門家の評価基準に適応するルール評価支援手法の開発

ルール評価モデル構築による ルール評価支援



客観的指標を組み合わせた合成関数(モデル)によって
専門家が注目するルールを選別する

ルール評価モデル構築アルゴリズム 比較実験

- 実際のデータマイニング結果での比較
 - 実データセットからIF-THENルールをマイニング
 - 専門家による評価と各客観的指標値をデータ化
- 各学習アルゴリズムの評価観点
 - 訓練データセット全体, Leave-One-Out検定での正解率・各クラスの正答率と再現率
 - 有効なルール評価モデル構築に必要な最低限の訓練データ数
 - 学習されたモデルの内容

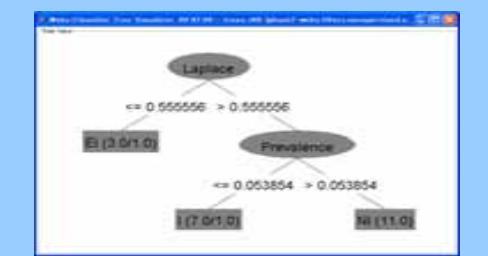
ルール評価モデル構築アルゴリズム比較実験

140事例の
髄膜脳炎に関する
6(2×3)種類の
診断鑑別データ



39種類の客観的
指標による評価
属性:客観的指標
属性値:客観的指標値

医師による評価
クラス:医師の評価
クラス値: I, NU, NI



- ・決定木
 - ・ニューラルネットワーク
 - ・線形回帰による分類
 - ・SVM etc.
- モデル構築**

各評価観点に
によるモデル構築
アルゴリズム
の評価

ruleID	Accuracy	Added_Value	...	YulesQ	YulesY	HumanExpert
Rule1	0.81	0.41	...	0.73	0.44	NI
Rule10	0.81	0.43	...	0.75	0.45	NI
Rule11	0.85	0.46	...	0.79	0.49	I
Rule12	0.84	0.56	...	0.87	0.58	I
Rule13	0.94	0.44	...	0.88	0.59	I
Rule14	0.81	0.43	...	0.75	0.45	NI
Rule15	0.84	0.55	...	0.86	0.57	NI
Rule16	0.91	0.58	...	0.91	0.65	NI
Rule17	0.81	0.61	...	0.89	0.61	NU

実験にて用いる客観的指標

IF-THENルール個々に対して、所与のデータとの関係で算出される値

対象とする客観的指標(計39)[Ohsaki 04]

- 確率に基づく指標(26指標)
 - Coverage, Prevalence, Precision, Recall, Support, Accuracy, Specificity, Lift, Leverage, Added Value, Relative Risk, Jaccard, Certainty Factor, Odds ratio, Yule's Q, Yule's Y, Kappa, Koelesgen's Interestingness, Brin's Interestingness, Brin's Conviction, GOI(一般性重視), Credibility, KSI, Laplace Correction, Collective Strength
- 統計検定量に基づく指標(3指標)
 - Chi-Square(True/Positiveだけの理論値との差, 4分表全ての理論値との差), Gini Gain
- 情報量に基づく指標(5指標)
 - Mutual Information, J-Measure, YLI1, YLI2, YZI, K-Measure
- 事例数に基づく指標(3指標)
 - coefficient, PSI, Cosine Similarity
- ルール間の差異に基づく指標(2指標)…条件節の差異を距離と仮定し評価値を計算
 - GBI, Peculiarity

実験対象の学習アルゴリズム

- 決定木: J4.8(C4.5のJava実装版)
- ニューラルネットワーク: 3層完全結合
 - BP学習のパラメータ: 学習率 = 0.3, 慣性項 = 0.2
 - 出力層: 各クラスに対応
- 線形回帰による分類: ClassificationViaLinearRegression
 - 線形回帰式: 各クラスに対して“1 vs. その他”的式を得る
 - 属性選択: AICに基づく貪欲探索法 (+ 線形結合を排除)
- SVM: Sequential Minimal Optimization [Platt98]
 - SVMによる3クラスの分類: 各クラスに対して“1 vs. その他”的モデルを得る
 - カーネル関数: 多項式カーネル
- OneR
 - 各指標値によって並び替え後, クラスの変更点を閾値とした条件節を持つルール集合を作成し, 最も正解率の高いルール集合を選択

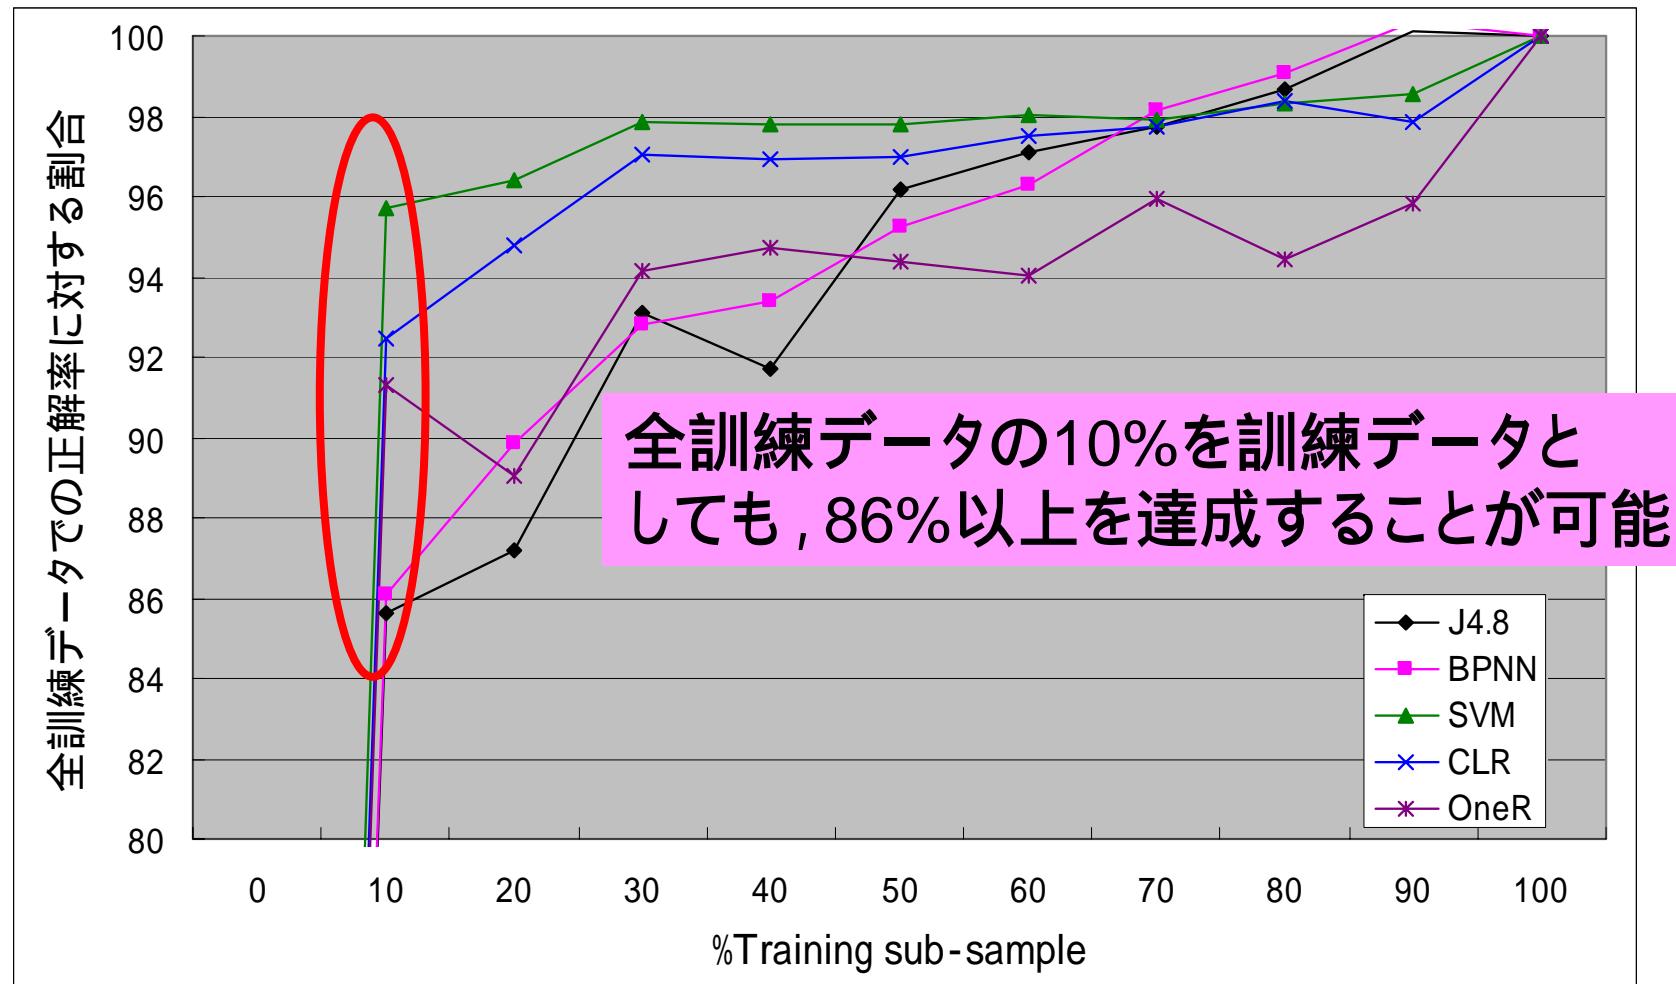
各学習アルゴリズムの実装にはWeka[Witten 00]を利用

学習アルゴリズムによるルール評価モデルの性能比較 (ルール数244, 'I'=48, 'NI'=187, 'NU'=9)

学習 アルゴリズム	正解率	訓練データでの評価					
		Recall			Precision		
		I	NI	NU	I	NI	NU
J4.8	85.7	41.7	97.9	66.7	80.0	86.3	85.7
BPNN	86.9	81.3	89.8	55.6	65.0	94.9	71.4
SVM	81.6	35.4	97.3	0.0	68.0	83.5	0.0
CLR	82.8	41.7	97.3	0.0	71.4	84.3	0.0
OneR	82.0	56.3	92.5	0.0	57.4	87.8	0.0
学習 アルゴリズム	正解率	Leave - One - Out(LOO)での評価					
		Recall			Precision		
		I	NI	NU	I	NI	NU
J4.8	79.1	29.2	95.7	0.0	63.6	82.5	0.0
BPNN	77.5	39.6	90.9	0.0	50.0	85.9	0.0
SVM	81.6	35.4	97.3	0.0	68.0	83.5	0.0
CLR	80.3	35.4	95.7	0.0	60.7	82.9	0.0
OneR	75.8	27.1	92.0	0.0	37.1	82.3	0.0

- BPNN, J4.8では77.5%以上の信頼性をもって85.7%以上の正解率を達成
(LOOで正解率が低いのは過学習の傾向があるため)
- 'NU'は非常に数の小さいクラスであるため、予測が困難

各学習アルゴリズムによる学習精度の推移 (対全訓練データでの学習精度)



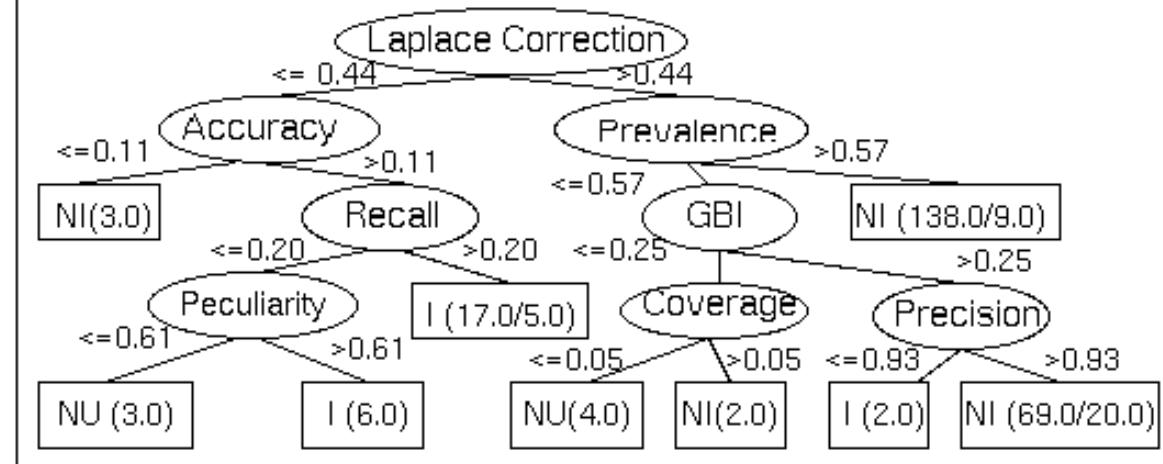
ルール評価モデル

(a) OneRによるルール集合

```

IF YLI1 < 0.02 THEN "I"
IF YLI1 >= 0.02 and YLI1 < 0.29 THEN "NI"
IF YLI1 >= 0.29 and YLI1 < 0.43 THEN "I"
IF YLI1 >= 0.43 and YLI1 < 0.44 THEN "NI"
IF YLI1 >= 0.44 and YLI1 < 0.55 THEN "I"
IF YLI1 >= 0.55 and YLI1 < 0.63 THEN "NI"
IF YLI1 >= 0.63 and YLI1 < 0.83 THEN "I"
IF YLI1 >= 0.83 THEN "NI"
  
```

(b) J4.8による決定木



線形回帰による分類

(c) による線形回帰式

$$\begin{aligned}
 \text{NU} = & 0.6202 * \text{Specificity} + \\
 & 0.6224 * \text{Accuracy} + \\
 & -1.1384 * \text{Leverage} + \\
 & -0.6895 * \text{RelativeRisk} + \\
 & 0.3704 * \text{CertaintyFactor} + \\
 & 0.5722 * \text{OddsRatio} + \\
 & 0.7656 * \text{BI} + \\
 & -0.222 * \text{Credibility} + \\
 & -0.3941 * \text{LaplaceCorrection} + \\
 & 0.7986 * \text{GiniGain} + \\
 & -0.0966 * \text{GBI} + \\
 & -0.8895
 \end{aligned}$$

$$\begin{aligned}
 \text{NI} = & 1.7173 * \text{Precision} + \\
 & -0.5063 * \text{Accuracy} + \\
 & 0.5673 * \text{RelativeRisk} + \\
 & -1.2718 * \text{CertaintyFactor} + \\
 & 0.5955 * \text{YulesQ} + \\
 & -0.4609 * \text{K-Measure} + \\
 & 0.4613 * \text{PSI} + \\
 & -0.4181 * \text{Peculiarity} + \\
 & 0.5302
 \end{aligned}$$

$$\begin{aligned}
 \text{I} = & -1.4417 * \text{Precision} + \\
 & -0.7286 * \text{Specificity} + \\
 & 0.4085 * \text{Lift} + \\
 & 0.6297 * \text{CertaintyFactor} + \\
 & -1.4477 * \text{CollectiveStrength} + \\
 & 1.5449 * \text{GiniGain} + \\
 & -0.5318 * \text{PSI} + \\
 & 0.4981 * \text{Peculiarity} + \\
 & 1.4872
 \end{aligned}$$

図中に示された値は正規化された指標値

まとめ・今後の課題

■ まとめ

- データマイニングの結果の後処理支援のためのルール評価モデル構築手法の比較
 - 正確性と信頼性を併せ持つルール評価モデルが構築可能
 - 有効なルール評価モデルに構築に最低限必要な訓練データは全体の約10%と見積もることができた
 - 学習アルゴリズムにより異なる指標を用いたモデルを構築

■ 今後の課題

- ルール評価モデル構築のための属性(客観的指標)集合の最適化: 属性構築や属性選択アルゴリズムの選定
- ルール評価モデル構築のための学習アルゴリズム選定