

データマイニングを用いた市場品質監視システム

正員 堀 聡 (ものづくり大学)
正員 瀧 寛和 (和歌山大学)
非会員 鷲 尾 隆 (大阪大学)
非会員 元 田 浩 (大阪大学)

Applying Data Mining to Field Quality Watchdog Task

Satoshi HORI, Member (Institute of Technologists), Hirokazu TAKI, Member (Wakayama University), Takashi WASHIO, Non-member, Motoda Hiroshi, Non-member (Osaka University)

This article describes a watchdog program that discovers "meaningful" repair cases from a field service database. "Meaningful" cases are those judged worth probing further to prevent an epidemic of quality problems. Our system has employed the Apriori algorithm, a data mining technique which efficiently performs the basket analysis. Our system proves that this data mining technique is not only useful in knowledge discovery but is also capable of performing the database watchdog task. The Apriori algorithm automatically generates frequent itemsets from a large set of records. A frequent itemset is an arbitrary combination of values that appear more often than a threshold "minimum support." The algorithm often generates too many itemsets for quality engineers to review carefully in their daily work. Many itemsets don't provide sufficient information to investigate further. Hence, in order not to generate these valueless itemsets, the Apriori algorithm is modified in two ways. One way is "Basket analysis on objective and explanatory attributes", and the other is "Itemset reduction". The advantage of our method is demonstrated with some experimental results.

キーワード：市場品質管理, データマイニング, バスケット分析, アプリオリ アルゴリズム, 監視プログラム,

1. まえがき

電気製品の修理伝票が電子化され、毎日、数百数千の修理伝票が製造工場に電送されデータベースに蓄積されるようになった。これに伴い、修理伝票を分析し対策を講じるべき不良原因を抽出する市場品質監視システムへのニーズが高まってきた。我々は、データマイニングの一つであるバスケット分析に属性優先度を考慮する改良を加え、修理伝票から重大品質問題を発見するプログラムを開発した。本プログラムは、単に発見した事象を表示するだけでなく、その事象の故障率傾向や各々の修理伝票をユーザーに表示する。この表示機能により、計算機の特徴発見能力と、市場品質管理者の豊富な背景知識の二つを用いて、要対策品質問題を発見できるようになった。さらに、本開発によって、バスケット分析などデータマイニング技術が、新知識の発見だけでなく、多量のデータから異常事象を見つけ出す監視業務にも有功であることを示した。

まず、市場品質監視システムが必要となる背景とその開

発項目を述べる。また、本システムの基礎となる Apriori algorithm を簡単に紹介し、なぜこのバスケット分析手法が、市場品質監視に適しているかを明らかにする。

1.1 市場品質 市場品質は近年、顧客満足の向上の面だけでなく、アフターサービス費用削減の面からも、非常に重要視されている。製品品質の向上には、製品修理の状況から重要な品質問題をすばやく発見し、それを製造・設計部門にフィードバックする仕組みが必要である。製品が使用中に何らかの不具合が発生しメーカーが修理した場合、全ての修理内容は修理伝票として記録され、製造工場に伝達される。修理伝票には、概ね表 1 に示す情報が記載されている。

最近では、修理伝票が電子化され、毎日、数千の修理伝票を製造工場に電送し、関係データベース (Relational Database) に蓄積するシステムが整備されてきた。パーソナルコンピュータの出現で、市場品質管理部門では、何千件にもなる修理伝票を簡単に処理・分析することができるようになった。しかし、修理伝票には、多数の機種、様々な症状・原因が混在する。将来、多発しそうな品質問

伝票番号	修理日付
お客様名前	住所
サービスマンの名前	
製品型式名称	
製造番号	製造日付
症状	不良原因
修理部品	部位
...	

表 1 修理伝票に記載されている項目

題 (epidemic quality problem) を発見するためには、あらゆる機種・症状・原因の組み合わせに対してパレート分析などを実施する必要があり、従来の Excel などのスプレッドシートや、SQL(Structured Query Language) では、十分対応できない。そこで、重大品質問題を自動的に発見する市場品質監視システムへのニーズが高まってきた。

1.2 市場品質の監視 修理伝票の電子化にとまなない、数年前より、修理伝票分析データベースシステムは多くの工場で普及し、品質月次報告書の作成などのペーパーワークを大いに軽減した。しかしながら、重大な品質問題の第一報のほとんどは、全修理の一部しか経験しないサービスマンから工場に報告されている。全国の修理事例がデータベースに集められているにもかかわらず、従来のシステムでは品質問題を発見できなかった理由は、以下のようにまとめられる。

- (1) サービスマンは回路動作を理解しているので、ある交換部品の組み合わせ (P_i, P_j) が設計不良などの重要な原因で生じたかを推定でき、その重要度を判断できる。一方、SQL は人間が指定しない限り、ある交換部品の組み合わせ (P_i, P_j) が同時に交換されている事例が、多いかどうかを分析することはできない。人間がある仮説「部品 P_i と P_j の箇所が不良ではないか？」を与えた時に、SQL は、該当する修理件数を数え上げるだけである。
- (2) サービスマンは、設計変更・一般的故障率など多くの背景知識を持っている。したがって、彼らは故障の真の原因(部品不良か設計不良かなど)を推察し、その重大さを的確に判断できる。計算機は背景知識を持っていないので、発生頻度でしか重要性の判定ができない。

市場品質監視システムは、計算機が大量な修理伝票情報を縮約し、これを人間が背景知識を利用しながらレビューする事により、品質対策を講じるべき事象を発見しようとする物である。この時、計算機が実行すべきタスクは以下のように特徴付けられ、後に詳述するように、データマイニング⁽³⁾の一手法であるバスケット分析手法は、電気製品の市場品質を監視するのに適した手法であると判断した。

- (1) 定量的基準(例えば、同一箇所の不具合がヶ月 5 件以上の場合)で市場品質動向を漏れなく監

視する

⇒ minimum support(最小支持度)で指定された以上の出現頻度を持つアイテム集合を抽出する。

- (2) 部品変更・工作手順変更などの実行すべき品質対策が特定できる属性集合に関して、その値のパターンを抽出する

⇒ 関連属性値を修理伝票から取り出し、多頻度アイテム集合を抽出する。

そこで、我々は、高速にバスケット分析を行う Apriori algorithm⁽⁴⁾を利用することとした。しかしながら、Apriori algorithm は、非常に多くの重要でない多頻度アイテム集合(Frequent itemset)も生成する。そこで、我々は属性の優先度を利用して、無意味な多頻度アイテム集合の生成を抑制する工夫を Apriori algorithm に加え、市場品質監視プログラムを開発した。

次章でバスケット分析と Apriori algorithm を簡単に紹介し、市場品質問題に適用する際の問題点を述べる。3章で我々の「目的および説明属性に対するバスケット分析」アルゴリズムと開発した市場品質監視システムの概要を説明する。さらに、実際の修理伝票の分析結果を示し、本手法の有効性を述べる。

2. 品質監視問題へのバスケット分析手法の利用

バスケット分析は、元来スーパーマーケットの売り上げ情報を分析し、顧客の購買特徴を抽出することで注目を集めた手法である。具体的には、顧客がどの商品(item)を買ったかの記録(Record/Transaction)を解析し、出現頻度の多い商品の組み(即ち、多頻度アイテム集合:Frequent itemset)を取り出し、相関ルール(association rules)を抽出して購買特徴を発見しようとするものである。近年 Agrawal らにより、本バスケット分析を高速で処理する Apriori Algorithm⁽⁴⁾が開発され、本手法が各種分野に盛んに応用されるようになった。従来のデータベース検索言語(SQL)に比較して、本手法は、出現頻度の高い任意のアイテムの組み合わせを抽出できる点が、柔軟性が高く優位である。以下に Apriori Algorithm の概要を説明する。

2.1 Apriori Algorithm バスケット分析の概要を、スーパーマーケットの売り上げ記録を例題に説明する。ここで、売り上げ記録(Record/Transaction)は、ある顧客が購入した商品(item)の組みである。バスケット分析では、しきい値として minimum support(最小支持度、データベース中の出現頻度。以下 min-sup)と minimum confidence(最小信頼度。そのルールが真である度合い。以下 min-conf)を与える。

- (1) 多頻度アイテム集合を生成する。ここでは、多頻度アイテム集合は、min-sup よりも大きな出現頻度を持つ任意の商品の組みであり、例えば {bread, milk, coffee, ...}.
- (2) 多頻度アイテム集合より相関ルールを生成す

る。相関ルールは、 $A \Rightarrow B$ (ただし A, B, C はアイテム集合であり $A \cap B = \phi, A \cup B = C$)
例) $C = \{bread, milk, butter\}$ が多頻度アイテム集合で、かつ、"bread" を含むレコードに "milk" と "butter" が min-conf 以上出現した場合、相関ルール: $\{bread\} \Rightarrow \{milk, butter\}$ を得る。

Apriori algorithm は、効率的にこのバスケット分析を実行する。図 1 と以下に Apriori algorithm の概要を示す。

Step-1. 1 つの item のみを含む frequent 1-itemset を取り出す。

Step-2. apriori-gen 関数は、frequent k-1 itemset を引数として受け取り、データベースから全ての k-itemset を生成する。

Step-3. このループでは、上記で生成された k-itemset のうち、トランザクション t に含まれているものの頻度を 1 つ増す。

Step-4. min-sup 以上の出現頻度を持つ k-itemset を frequent k-itemset とする。

```

Step -1  $L_1 = \{\text{Frequent 1-item-sets}\};$ 
        for  $\{k = 2; L_{k-1} \neq \phi; k++\}$  do begin
Step -2  $C_k = \text{apriori-gen}(L_{k-1});$ 
        forall transactions  $t \in D$  do begin
           $C_t = \text{subset}(C_k, t);$ 
Step -3 forall candidates  $c \in C_t$  do
           $c.\text{count}++;$ 
        end
Step -4  $L_k = \{c \in C_k \mid c.\text{count} \geq \text{minsup}\}$ 
        end
        Answer =  $\bigcup_k L_k;$ 

```

図 1 Apriori Algorithm

2.2 品質監視問題とバスケット分析 従来のデータベース・クエリー (SQL) やパレート分析手法では、分析する対象として、「型名 X の症状に特異な傾向があるのではないか?」または、「ある部品の故障率が高いのではないか?」という仮説を与える必要がある。しかし、バスケット分析手法は、事前に型名や分析対象とする属性 (症状、故障箇所、または製造年月など) や属性値を指定せずに、即ち何らの仮説を与える必要がなく、自動的に出現頻度の高い任意の属性値の組み (多頻度アイテム集合) を抽出する。

しかし、小さな min-sup 値を設定し Apriori algorithm を修理伝票に適用した場合、非常に多くの多頻度アイテム集合が生成され、しかもそのほとんどが品質監視の観点から無意味であるという問題が生じた。具体的には、min-sup=5 としたとき、1479 枚の修理伝票から 759 個

もの多頻度アイテム集合が生成され、その多くは製品型名または交換部品の値が含まれていないなど、市場品質監視の観点から意味の無い物であった。

従来、出来るだけ有意義な相関ルールのみを抽出しようとする試みが幾つか提案されている。Srikant の item constraint⁽⁶⁾ は、分析対象となる値間の分類概念 (taxonomy) を導入し、価値のあるアイテム集合や相関ルールのみを生成しようとする手法である。また、松浦ら⁽⁵⁾ は、一定の確信度の下で最小限の事実から最大限の推定や予測を行う相関ルールを導く「相関ルールの抽出規範」を用いて、縮約された相関ルールを生成する手法を提案している。

スーパーマーケットの購入パターンの発見では、データ属性は「商品」のみであり、この商品属性の数多くの値 (bread, milk,...) の出現パターンを抽出しようとする物である。一方、修理伝票は、型名、症状、交換部品、顧客名など明確な意味を持つ多くの属性を持っている。市場品質監視では、品質対策に直結する不具合事象、即ち、指定された属性集合とその値のパターンを発見しようとする物である。従って有意義な多頻度アイテム集合を取り出すには、品質対策と修理伝票の属性の関係を活用する必要があるので、我々は、次章で述べるように伝票属性を目的属性と説明属性に分類した上で、バスケット分析を行う事とした。

3. 市場品質監視システム

多頻度アイテム集合は、データベース中に頻繁に出現する値 (アイテム) の組みであり、我々の問題の場合、頻度が高い故に重大品質問題である可能性のある事象と解釈できる。そこで、市場品質監視の場合は、できるだけ縮約され、かつ漏れの無い多頻度アイテム集合を抽出することが必要になる。また、アイテム集合だけでは、部品品質の解析や設計の見直しに着手するか否かの判断に十分な情報量ではないので、関連情報として故障確率のトレンドやワイブル関数などを提供する機能が必要となる。したがって、市場品質監視システムの開発課題は以下の 2 つとなる。

(1) 市場品質管理者が容易に判断できる程度に縮約され、且つ、品質対策を打つべき事象を漏れ無く取り出すアルゴリズム。

⇒ 目的属性と説明属性に分けて Apriori algorithm を適用することにより、生成されるアイテム集合のサイズを小さくする。

(2) 更なる調査 (部品品質の解析や設計の見直しなど) に着手するか否かの判断に十分な情報を提供する。

⇒ 各アイテム集合に対して、ボタン一つで関連修理伝票、その故障発生傾向やワイブル関数を提供するインターフェースを用意する。

3・1 目的属性と説明属性 修理伝票に記載されている情報のうち、市場品質監視に必要な項目（属性）は、型名、交換部品、症状、処置内容、製造年月などである。また、これら関連のある属性でも、型名、交換部品など必ず必要な項目と顧客名、製造年月日など相関が高ければ有用なヒントとなる項目に分けられる。

そこで、品質対策を取り得る設計・部品・工作に起因する不具合事象を特定するのに必要な情報は何か、その情報は修理伝票のどの属性から取り出す事が出来るかを整理し、修理伝票の属性を目的属性と説明属性に分類した。図2に、部品不良の判断（ある特定部品の品質に不具合があるか否かの判断）に必要な情報と、修理伝票上のデータとの関連を示す。部品不良の判断には、部品を特定する「メーカー名、品番」および「ロットID」とそのロットの不良率=件数/使用数が必要である。修理伝票の型名、諸元番号から、「部品適用表」を介してどの部品なのか特定できる（Ex. Model-A の C103 は、メーカー X の電解コンデンサ）。さらに、製造年月と工場の資材使用履歴より、その部品のロットIDも特定できる。不良件数は修理伝票より算出でき、部品の使用総数も適用表と生産台数より決定できる。同様に、設計・工作の判断に必要な修理伝票上の情報を整理すると表2のようになる。全ての対策に関連する修理伝票の属性を目的属性、どれか一つの対策に必要とされる属性を説明属性と分類した。「故障原因」に関しては、修理段階では十分な故障原因解析が出来ていない場合もある為、記入率の低さを考慮して説明属性とした。

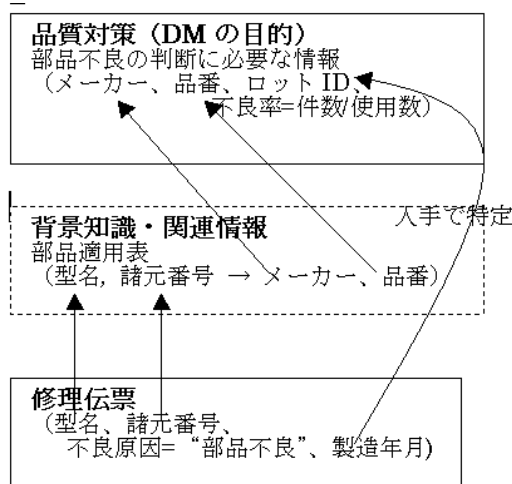


図2 品質対策と修理伝票属性の関係

このように、取るべき対策から修理伝票の属性を目的属性と説明属性に分類し、各々に対してバスケット分析を行い無意味なアイテム集合の生成を防ぐ事とした。さらに、生成された多頻度アイテム集合で、目的属性の値を共通に持つアイテム集合の和集合を取り、最終的な多頻度アイテム集合の数を極力小さくするようにした。

表2 目的属性と説明属性の決定

伝票属性	部品対策	工作対策	設計対策	属性種類
型名				目的
交換部品				目的
故障原因				説明
症状				説明
製造年月				説明
顧客名				説明

以下に示すように、本アルゴリズムは、目的属性のバスケット分析、説明属性のバスケット分析の二段階から成る。

目的属性のバスケット分析

STEP-1. N=1 から始める。

STEP-2. N 番目の目的属性からアイテム集合を生成する。

STEP-3. 次に、Step-2 で生成されたアイテム集合で N+1 番目の目的属性の値を含み、かつ出現頻度が min-sup 以上のものを抽出する。このように、各目的属性の値を少なくとも一つは持つようなアイテム集合を抽出する。

STEP-4. Step-2 に戻る。全ての目的属性を処理したら、生成したアイテム集合の集合 L_o を出力する。

説明属性のバスケット分析とアイテム集合の集約

STEP-5. 上記で生成された各アイテム集合 $l_o^k \in L_o$ の各要素に対して、以下の処理を行う。

STEP-5.1. $l_o^k = \{o_1, \dots, o_m\}$ を含むレコードを取り出す。ここで l_o^k は、k 番目の目的属性のアイテム集合。 o_i は、目的属性の値。

STEP-5.2. 上記レコードの説明属性からアイテム集合 $l_{e,1}^k, \dots, l_{e,n}^k$ を生成する。

STEP-5.3. 説明属性アイテム集合の和集合を結合する。

$$l^k = l_o^k \cup \bigcup_{i=1}^n l_{e,i}^k$$

3・2 システムの概要 図3に開発した市場品質監視システムの概要を示す。本システムは、毎週起動され直近4週間分の修理伝票を分析し、重大品質問題となりうる候補、即ち多頻度アイテム集合を生成する。

Step-1. 直近4週間分の修理伝票を修理伝票データベースから取り出す。

Step-2. 目的属性に対して Apriori algorithm を実行し、目的属性のアイテム集合 L_o を生成する。

Step-3. 次に、Step-2 で生成された L_o を含むレコードの説明属性に対して Apriori algorithm を実行し、目的属性と説明属性の両方の値を持つアイテム集合 L を生成する。

Step-4. 生成されたアイテム集合 L を表示する。この

結果表示インターフェースは、各アイテム集合毎に以下の追加情報をボタン一つで表示できる。

- (1) 修理伝票本体の表示
- (2) 過去一ヶ月の故障率傾向
- (3) ワイブル分布グラフ
- (4) 製造年月・修理年月相関表

図4に結果表示のインターフェース画面の例を示す。

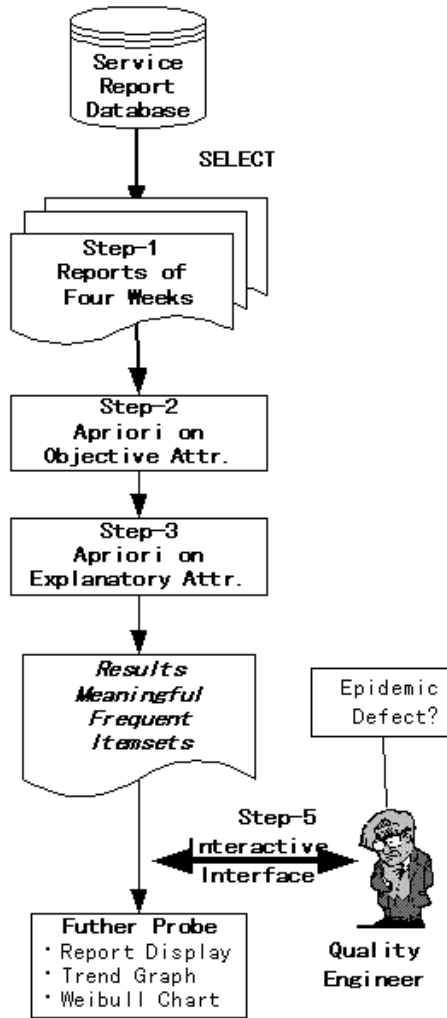


図3 Watchdogプログラムの概要

3.3 実験結果 一ヶ月分の修理伝票 1479 枚に対して、バスケット分析を行った。修理伝票の 6 個の属性(製品型名、顧客名、症状、故障原因、交換部品(リスト値)、製造年月)を用いた。この内、製品型名、交換部品を目的属性、他を説明属性とした。min-sup は 5 とした。その結果を表 3 に示す。表中 (a) は、上記 6 個の属性に対して単純に Apriori algorithm を適用した結果、(b) は、目的属性、説明属性毎に Apriori algorithm を適用した結果である。

表 3 に見るように、単純な Apriori algorithm では、あるアイテム集合 L の部分集合も必ず多頻度アイテム集合

として出力されこともあり、1479 件の修理伝票から 759 個のアイテム集合を生成した。一方、我々の手法では、目的属性を含まないアイテム集合を生成せず、また、STEP-5 に示したように目的属性の値を共通に持つアイテム集合の和集合を取り生成するアイテム集合の数を小さくしたので、わずか 28 個のアイテム集合に縮約されている。

さらに、事前にはわかっていない三件の重要品質問題(件数は 11 件から 6 件)の事案であるアイテム集合(型名・交換部品を含む)は、表 4 に示すように出力された。(a) の場合は 251 位、414 位、492 位と下位であり、人間が 759 個の出力結果からこれら三件に注目するには困難がある。しかし、我々の手法では 28 件中の 7 位、13 位、16 位であり(図 4 の星印)、短時間この出力結果を検討すれば、十分これら重大事例に気づくことができる。

この実験結果より、最小支持度 min-sup が小さい場合でも、我々の手法が数百、数千件に上る 4 週間分の修理伝票を少数のアイテム集合に縮約できることが示された。この縮約された結果を背景知識を持つ人間がレビューすれば、容易に重大事例を抽出できる。同一故障が 1 件ないし 2 件では偶発故障と区別できないため、通常、市場品質管理では 3 ないし 5 件以上発生する場合に、重大品質問題の可能性ありと判断し、さらなる分析を行う。従って、本システムの情報縮約能力は、市場品質監視の為のフィルターとして十分有効であると言える。

表 3 実験結果

	Freq.
分析対象の修理伝票数	1497
(a) 単純 Apriori のアイテム集合数	759
(b) 目的・説明属性に対する Apriori のアイテム集合数	28

表 4 重大事例の順位

事例 ID	件数	(a) での順位	(b) での順位 図 4 の星印
Case-A	11	251	7
Case-B	7	414	13
Case-C	6	492	16

4. 結論

前章の実験結果が示すように、修理伝票データベースからの重要な市場品質問題の発見において、従来の SQL などを用いた固定的分析手法に比して、バスケット分析手法の有効性を示した。また、品質対策の実行に必要な情報との関連から、修理伝票の属性を目的属性と説明属性に分けてバスケット分析をすることにより、単に Apriori を適用した場合に比べて、大きくアイテム集合の量を縮約できることを示した。本システムの目的が製品に内在する不具合を早期に見つけて、設計・製造にフィードバックすることである。通常、製品の製造期間は数ヶ月程度であり、その間に問題点を見つけて対策を打つ必要

がある。本システムは、現在ディスプレイモニタ工場の市場品質管理部門で実用化さ、毎週、直近4週間の伝票を分析するのに利用されている。工場の市場品質管理部門は、その出力結果を品質問題の有無を判断するために利用している。本システムは、従来のSQLベースのシステムに比べ、以下の観点から高い評価を得ている。

- 従来のベテランサービスマンに頼っていた属人的判断基準から、min-sup 値で定義される定量的基準で市場品質動向を監視できるようになった。
- 定量的基準に加え、故障率トレンド図やワイブル分析グラフなど客観的情報を同時に出力できるので、設計・製造部門へのフィードバックが迅速にできるようになった。

本システムの成功の原因は、Huber⁽⁷⁾がデータマイニング技術を評したように、本システムが“大量の修理伝票情報から、必要な情報を抽出し人間が利用しやすいサイズ・書式に縮約できた”からである。本システムを利用すれば、数千の伝票をレビューする代わりに数十のアイテム集合から、関連修理伝票や過去一年の故障傾向など関連情報を参照し、重要な市場品質を監視できるようになる。しかし、アイテム集合から最終的に設計や部品の変更が必要か否かを決定するためには、さらなる物理的検証実験と製品設計・製造と使用状況に関わる経験と深い知識が必要であることは言うまでもない。従って、市場品質監視は、計算機が得意な膨大なデータの検索機能と経験豊かな品質エンジニアの深い知識の連携によって初めて実効のあるものとなる。

(平成12年1月31日受付, 同13年9月9日再受付)

文 献

- (1) R.Agrawal, R.Srikant, "Fast algorithms for mining association rules", Proc. of 20th VLDB Conference, pp.487-499 (1994).
- (2) Y.Cai, N.Cerccone, J.Han, "Attribute-oriented induction in relational databases", Knowledge Discovery from Databases (Ed. Piatetsky-Shapiro) MIT Press, pp.214-228 (1991).
- (3) U.M.Fayyad, et. al. Ed., "Advances in knowledge discovery and data mining (1996).
- (4) 沼尾 ed., "(特集) 大規模データベースからの知識獲得", 人工知能学会誌, Vol.12, No.4, pp.496-549 (1997).
- (5) 松浦, 鷲尾, 元田, "データマイニングにおける推定・予測用相関ルールの抽出規範とその実装", 計測制御学会 システム/情報合同シンポジウム予稿集, pp.103-108 (仙台 1997).
- (6) R.Srikant, Q.Vu, R.Agrawal, "Mining association rules with item constraints", Proc. of 3rd Int'l Conf. on Knowledge Discovery and Data Mining, pp.67-73 (1997).
- (7) P.J.Huber, "From Larget to Huge: A Statistician's Reactions to KDD & DM", Proc. of 3rd Int'l Conf. on Knowledge Discovery and Data Mining, pp.304-308 (1997).

堀 聡 (正員) 1982年3月東京工業大学総合理工学研究科電子システム専攻修士課程了。同年4月三菱電機(株)入社、同社生産技術センター勤務。1988年PURDUE大電気工学科修士課程了。工学博士(東京工業大学)。2001年4月よりものつくり大学製造技能工芸学科助教授。知識工学、データベース、確率・統計の保守・診断およびアフターサービスへの応用に関する研究開発に従事。

瀧 寛 和 (正員) 1980年3月大阪大学基礎工学研究科物理系専攻修了。同年、三菱電機(株)入社。1986年(財)新世代コンピュータ技術開発機構に出向。1990年三菱電機(株)に帰任。1998年4月より和歌山大学システム工学部 教授。工学博士(大阪大学)。知識獲得、知能ロボット、設計エキスパートシステム、ウェアラブルインテリジェントメディアに関する研究に従事。

鷲尾 隆 (非会員) 1988年東北大学大学院原子核工学専攻博士課程修了。工学博士。同年マサチューセッツ工科大学原子炉研究所客員研究員。1990年(株)三菱総合研究所入社。1996年 退社。現在、大阪大学産業科学研究所助教授(知能システム科学研究部門)。原子力システムの異常診断手法に関する研究、定性推論に関する研究を経て、現在は人工知能の基礎研究、特に科学的知識発見、データマイニングなどの研究に従事。人工知能学会、計測自動制御学会、日本ファジイ学会、情報処理学会、AAAI、各会員。

元田 浩 (非会員) 1967年東京大学大学院原子力工学専攻修士課程終了。同年、日立製作所に入社。同社中央研究所、原子力研究所、エネルギー研究所、基礎研究所を経て平成7年退社。現在、大阪大学産業科学研究所教授(知能システム科学研究部門)。人工知能の基礎研究、とくに機械学習、知識獲得、知識発見、データマイニングなどの研究に従事。工学博士。1975年日本原子力学会奨励賞、1977、1984

年日本原子力学会論文賞、1989、1992、2001年人工知能学会論文賞受賞、2000年人工知能学会業績賞を受賞。人工知能学会、情報処理学会、日本ソフトウェア科学会、日本認知科学会、AAAI、IEEE Computer Society、各会員。

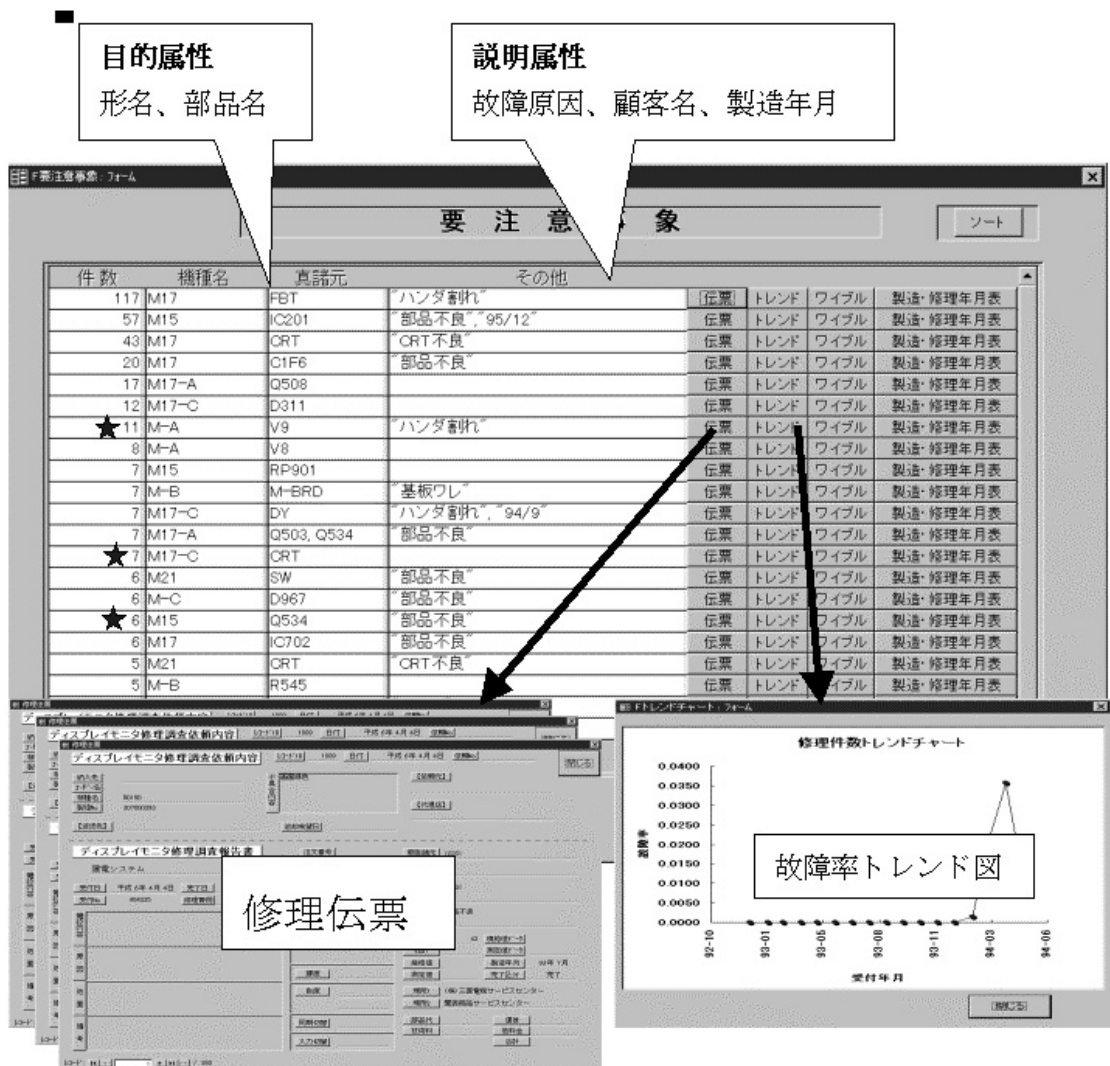


図4 結果の表示