

重要な顧客層および相関ルール発見のための 繰返し購買パターンを考慮した相関ルールマイニング

裴 明 花[†] 谷 口 伸 一^{††}
原 隆 浩[†] 西 尾 章 治 郎[†]

近年、多くの企業において、相関ルールマイニングを用いて顧客戦略の検討を行うことが一般的となっている。現況では、相関ルールマイニングと顧客の分析がそれぞれ独立に行われており、両者の結果を統合的に解釈することが困難となっている。そこで本論文では、相関ルールマイニングにおいて、重要な相関ルールの発見と顧客の分析を同時に満たすことを目的とする。具体的には、相関ルールを抽出する際に、同じ購買パターンを繰り返すロイヤルティの高い顧客層を発見し、かつ、リピート率の導入により、その購買パターンを表す相関ルールを同時に発見する。さらに、実データを用いた評価実験により、提案アプローチがロイヤルティの高い顧客層を発見できることを示す。

Association Rule Mining Considering Repetition in Purchase to Discover Important Association Rules and Loyal Customers

MINGHUA PEI,[†] SHINICHI TANIGUCHI,^{††} TAKAHIRO HARA[†]
and SHOJIRO NISHIO[†]

Recently, it has become popular in many enterprises to use association rule mining to contrive the customer strategies. However, processes for association rule mining are currently performed independently of those for customer analysis. Thus, it is difficult to give an integrative explanation based on the results of both processes. In this paper, we address an issue to achieve both the mining of important rules and the customer analysis at the same time. Specifically, we propose an approach of adapting a new criterion, called R-repeat, to association rule mining process, and that of discovering a customer class who repeat particular purchase patterns while extracting association rules. Furthermore, we represent experimental results to verify that the customer class discovered has high loyalty.

1. はじめに

近年、経済の成熟化と景気後退などの影響により、企業経営において新規の顧客の獲得が難しく、費用も増大している。そのため、新規顧客を獲得することよりも、既存顧客からの売上げを拡大することが重視されている。つまり、顧客の特性を識別し、顧客を「差別化」するサービスが求められている¹⁾。そこで、データマイニングが有力な手法となる。

データマイニングとは大量のデータから有用なパターンやルールを発見するためのデータ分析または知

識探索のプロセスである。特に、相関ルールマイニングは顧客プロフィールデータまたは販売データからアイテム間の関連を発見することができるため、データマイニングの重要な手法の一つと考えられている。これまでのデータマイニング研究は、主に正確なモデルを立てる技術^{2),3)} や、ルールの発見技術⁴⁾⁻⁶⁾ に焦点を当てている。ここで、相関ルールマイニングを企業の経営戦略に利用する場合、抽出されたルールの解釈および分類を助ける方法も必要となる。たとえば、販売データから抽出される一連の相関ルールは、いずれもユーザが指定した閾値以上のサポート率と確信度を持っているが、少数であるが価値のあるルールを発見するには、閾値をより低い値に指定しなければならない。その結果、多くのルールが抽出され、その中に価値のあるルールもサポート率と確信度の順番で現れるとは限らない。

一方、経営戦略を立案する際に参考にするため、販

[†] 大阪大学情報科学研究科マルチメディア工学専攻
Department of Multimedia Engineering, Graduate
School of Information Science and Technology, Osaka
University

^{††} 滋賀大学経済学研究科経営学専攻
Department of Business Administration, Graduate
School of Economics, Shiga University

売データを用いて顧客をグループ化する手法が重要と考えられている．その代表的な手法として RFM 分析などが知られている．しかし，現況では，相関ルールマイニングと顧客分析手法は，それぞれ独立して個別に適用されており，両者の結果を統合的に解釈することは容易ではない．したがって，顧客グループの特徴を考慮して，ルールの有意性を自動的に分析できるようになると，ルール抽出の結果から経営戦略を立案しようとする経営者には有効である．

そこで本論文では，重要な相関ルールの抽出と顧客の分析を同時に実行するために，顧客の購買パターンに対する繰返し行動に着目する．ルール抽出の際に，リピート率と呼ぶ新しい評価基準を導入することにより，サポート率の計算に少しの計算を加えることで，特定の購買パターンの繰返しを表す相関ルールを発見できる．さらに，ルールを発見する処理と並行して，その繰返しを行っているロイヤルティの高い顧客層を発見できる．また，本論文では，実データを用いた評価実験により，提案アプローチを用いて発見した顧客層がロイヤルティの高い顧客層であることを検証する．

以下では，まず 2 章で，相関ルールについて説明し，その問題点を説明する．3 章では，リピート率を定義し，サポート率とリピート率に基づいて相関ルールをグループ化する手法について述べる．4 章では，実データを用いた評価実験により，ルールの繰返しに注目して発見したリピータと呼ぶ顧客が高いロイヤルティを持つことを示す．5 章で提案アプローチの考察を行い，6 章で関連研究について述べる．最後に，7 章で本論文の結論と今後の課題について述べる．

2. 相関ルールとその問題点

2.1 相関ルール

相関ルールとは，アイテム集合 X, Y により， $X \rightarrow Y$ で記述された関係である．ここで， $X, Y \subset I$ ， $X \cap Y = \phi$ ， I はアイテム集合である．たとえば，小売店の販売データを用いたバスケット分析において，パンを買った人がミルクを同時に買う可能性が高いという事実は「パン \rightarrow ミルク」のように表される．式の左側を前提部，右側を結論部と呼ぶ．前提部と結論部はアイテム集合である． m 個のアイテムの組合せで生成された相関ルールの数は $\sum_{k=2}^m \binom{m}{k} (2^k - 2)$ 個となる⁷⁾．そこで大量の無意味なルールを生成せず，効率的に有用なルールを抽出するために，Agrawal らはサポート率と確信度を用いる Apriori アルゴリズムを提案した⁸⁾．サポート率は，式 (1) のように全トランザクション数に対する，あるルールの前提部と結論

部を同時に含むトランザクションの割合である．確信度は，式 (2) のように，あるルールの前提部を含むトランザクションのうち結論部も同時に含むトランザクションの割合である．サポート率がある閾値以上であるアイテム集合を頻出アイテム集合という．

$$\begin{aligned} \text{サポート率} \\ &= \frac{X \text{ と } Y \text{ をともに含むトランザクション数}}{\text{全トランザクション数}} \end{aligned} \quad (1)$$

$$\begin{aligned} \text{確信度} \\ &= \frac{X \text{ と } Y \text{ をともに含むトランザクション数}}{X \text{ を含むトランザクション数}} \end{aligned} \quad (2)$$

Apriori アルゴリズムは，まずサポート率の逆単調性を利用して，すべての頻出アイテム集合を求める．具体的には，アイテム数の少ない組合せから多い方へ調べ，閾値以上のサポート率を持つ頻出アイテム集合だけを抽出する．さらに，その中から閾値以上の確信度を持つ相関ルールを生成する．つまり，Apriori アルゴリズムは，ユーザの指定した閾値（最小サポート率と最小確信度）以上のサポート率と確信度を持つ相関ルールを有意な相関ルールと見なす．

2.2 相関ルールマイニングの問題点

相関ルールマイニングを企業の販売データに適用することで，経営戦略の立案などに有効であると考えられている．しかし，実データを用いて相関ルールを抽出する際，商品とデータの特徴などに大きな影響を受ける．たとえば，本研究では，中堅製菓小売業社の専門販売店の POS データを対象としているが，このようなデータでは，単一種類の商品に対する購買データが約 50% となり，異なる種類の同時購買データがさほど多くないという特徴がある．この場合，サポート率と確信度を用いて抽出された相関ルールのうち，サポート率の高いルールのほとんどは既知の事実である．それ以外の価値のある相関ルールを見つけるには，最小サポート率と最小確信度の閾値を下げなければならない．その結果，多くの相関ルールが抽出され，その中には多くの無意味なルールが含まれてしまう⁹⁾．したがって，閾値以上のサポート率と確信度を持つ相関ルールに対しても，ルールの有意性を判断することが難しい．さらに，商品のカテゴリによって，顧客の購買行動も異なる．たとえば，本や CD などの商品に対して，商品 A \rightarrow 商品 B という購買パターンは存在するが，顧客個体の購買行動から見た場合，今回商品 A と商品 B を買った顧客は次に商品 A, B ではなく，他の商品を買うだろう．しかし，消耗品類の商品，たとえば食品などに対しては，購買パターンに対する繰返

しが存在する．すなわち，日常的に形成された商品購買への習慣が存在する．このような情報は製造業者の経営戦略においては特に重要である．しかし，サポート率と確信度だけの評価基準は，ある顧客による繰返し購買を考慮していない．極端な例では，100,000 件のトランザクションデータの中で，1 万人が 1 回ずつ商品 A と商品 B を同時に購入して生じた 10,000 トランザクションと，1 千人が平均 10 回ずつ商品 A と商品 B を同時に購入して生じた 10,000 トランザクションを同様に扱ってしまう．

そこで，抽出されたルールを解釈する際に，顧客の購買行動を考慮することが有効であると考えられる．一般的に，発生確率の高い（サポート率が高い）ルールが，繰返される可能性も高いため，それに反したルールには何らかの原因が隠れている．したがって，購買パターンに対する繰返しを考慮することにより，サポート率が高くてもあまり顧客に繰返されないルール，およびサポート率が低くても（閾値以上）顧客に繰返されるルールを発見することが有用である．しかし，現況では，相関ルールマイニングと RFM 分析などの顧客分析は，それぞれ独立して行われるため，このような重要なルールを効率的に発見することは容易ではない．

3. リピート率を用いた相関ルールマイニング

本研究では，2.2 節で述べたような，サポート率が高くてもあまり顧客に繰返されないルール，およびサポート率があまり高くなくても顧客に繰返されるルールを効率的に発見するために，相関ルールのリピート率という評価基準を新たに導入する．本章では，リピート率の定義およびリピート率を用いた相関ルールマイニングの方法について述べる．

リピート率

$$\begin{aligned} & \text{アイテム集合 } X \text{ と } Y \text{ をともに含む} \\ & \frac{\text{繰返しによるトランザクション数}}{\text{アイテム集合 } X \text{ と } Y \text{ をともに含む}} \\ & \text{全トランザクション数} \\ & = \frac{|T'|}{|T|} \end{aligned} \quad (3)$$

3.1 対象 POS データと構築システム

本研究で用いた POS データは，約 31 万件のトランザクションを持ち，総サイズが約 66 万のレコードとなる．販売データには顧客を識別可能な暗号化されたコードが付加されている．このようなデータを用いて，前処理を行い^{(10),(11)}，図 1 で示したようなスキーマ構造となるリレーショナルデータベースを SQL

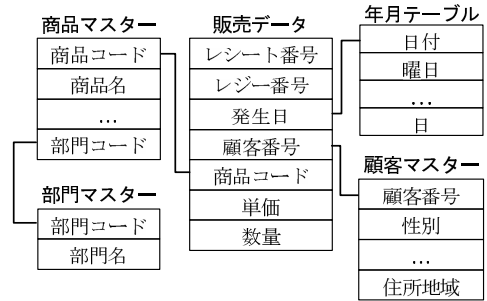


図 1 POS データのデータ構造
Fig. 1 Database structure for POS data.

Server2000 によって構築し，Web ベースのシステムに基づいて実験を行った．ユーザが時期などのパラメータとサポート率および確信度の閾値を指定すると，システムは分析データを抽出し，条件を満たすすべての相関ルールを抽出する．実験では，平均約 10 秒で，相関ルールマイニングの処理を実行できた．なお，構築したデータベースでは，1 回の購買行動であるトランザクションを構成するアイテム集合に対して，共通の識別子（顧客識別 ID）を付与した．これにより，各トランザクションと，それを発生した顧客を識別できる．

3.2 リピート率

相関ルール $X \rightarrow Y$ において，アイテム集合 X と Y をともに含むトランザクション集合を T ($T \subseteq I$) と表し，そのうち，顧客の相関ルール $X \rightarrow Y$ に対する繰返しによって生じたトランザクション集合を T' ($T' \subseteq I$) と表す．たとえば， X と Y の同時購買によるトランザクションの集合 T に，顧客 a による 3 回のトランザクション $ta_1, ta_2, ta_3 \in T$ が含まれる場合，1 回目以降の ta_2, ta_3 が顧客 a の繰返しによって生じたトランザクションとなる， T' はこのような顧客の X と Y の同時購買に対する繰返しによって生じたトランザクションの集合である． T' に含まれるトランザクション数は， X と Y をともに含むトランザクションの数から X と Y の同時購買を行った顧客の人数（ $\text{Customer}(X, Y)$ ，1 回目に購買されたトランザクション数）を引いたものと等しい ($|T'| = |T| - |\text{Customer}(X, Y)|$)．ここで，相関ルール $X \rightarrow Y$ のリピート率を式 (3) に示すように，アイテム集合 X と Y を含むトランザクション集合 T の中で， X と Y の同時購買の繰返しによるトランザクションの集合 T' の割合と定義する．

サポート率は相関ルールの一般性を示すように，リピート率は相関ルールの顧客に対する特殊性を示す．すなわち，サポート率が高いほど，相関ルールが顧客に対して一般的な購買パターンであり，多くの顧客の

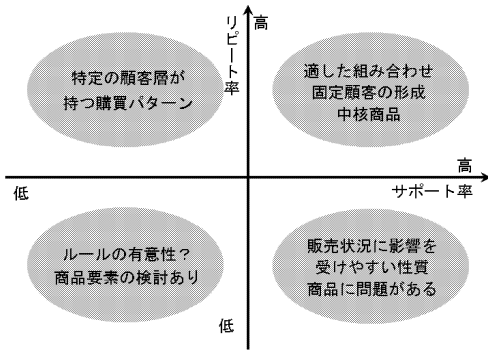


図 2 相関ルールの分類

Fig. 2 Classification of association rules.

選好的な購買パターンであると考えられる。一方、リピート率が高いほど、相関ルールが顧客に対して特殊性を持つ購買パターンであり、顧客の購買行動における習慣性を表している。したがって、相関ルールを抽出する際、サポート率と確信度の組合せはルールの一般性を判別するには効果的であるが、その結果を解釈するには、サポート率とリピート率を組み合わせ、購買パターンと顧客個体の購買行動を考慮することが効果的である。

3.3 リピート率を用いた相関ルールマイニング

リピート率を用いた相関ルールマイニングでは、まず従来の手法と同様に、サポート率と確信度が閾値以上であるルールを抽出する。その際、同時にルールのリピート率を計算しておく。次に、サポート率とリピート率のそれぞれに対して、高低を分ける閾値を設定し、抽出したルールを、図 2 のように 4 つのグループに分類する。したがって、本研究において発見したいルールは第 2 と 4 象限に抽出される。このように、リピート率を用いたマイニングは、従来の手法に対して、繰返しのトランザクションをカウントする程度の少ない計算を加えるだけで実現できる。

ここで、本研究では、定性的な評価および実データを用いたルール抽出結果の調査から、相関ルールの各グループを以下のように解釈した。

- (1) サポート率、リピート率とも高いルール：
このようなルールは、一般的な顧客需要に適した商品の組合せにおいて生じる特徴がある。すなわち、この購買パターンは多くの顧客に支持されているとともに固定顧客を形成している。その製造小売業の中核商品であることが多い。
- (2) サポート率は低いが、リピート率が高いルール：
このようなルールはサポート率が低いため、従来のデータマイニングにおいて見過ごされる可

能性がある。しかし、ルールのリピート率が高いことにより、この購買パターンが繰返されていることが分かる。したがって、このグループのルールは、少数ではあるが特定の顧客層を持つ購買パターンであるという性質を持っている。この顧客層はロイヤルティが高い場合が多い。

- (3) サポート率もリピート率も低いルール：
このルールに含まれる商品の要素を検討する必要がある。もし、商品開発者の意図と異なる場合は、同時に購買される要素および繰返しのない原因となる要素などを検討することにより、商品の問題を見出すことに役立つ。
- (4) サポート率は高いが、リピート率が低いルール：
このルールに含まれる商品は、販売状況に影響を受けやすい傾向を持つが、前提部あるいは結論部の商品に問題がある場合が多い。たとえば、年次行事に係る商品は販売期間が短いためリピート率は小さい。それ以外の場合、このグループの相関ルールに共通して現れる商品に問題があることを示す。

3.4 実データを用いた分類結果の考察

3.1 節で述べた POS データに対して、リピート率を適用した相関ルールマイニングを行い、相関ルールの分類を行った。たとえば、春期（2003 年 2 月 15 日から 4 月 20 日）の POS データから抽出した 34 個のルールにおいて、サポート率およびリピート率の高低を分ける閾値は、それぞれ 1% と 10% に設定した。その結果、第 1 象限から第 4 象限のグループに、それぞれ 2, 10, 19, 3 個のルールが分類された。

マイニング結果を調べると、従来のサポート率と確信度だけで区別できないルールがいくつか存在した。たとえば、サポート率が 0.87%、確信度が 58.7%、リピート率が 0% のルールと、サポート率が 0.86%、確信度が 45.69%、リピート率が 20.75% のルールが存在し、これらを別グループに分類することができた。また、サポート率が低いルール集合から、リピート率の高いルールを発見することで、顧客に重視されるルールを抽出することができた。具体的には、春期のルールにおいて、いくつかの季節商品が自家用として購買されるだけでなく、それらの商品の組合せの中から贈り物によく利用されるパターンが、サポート率は低くリピート率が高いルールとして抽出された。さらに、本実験では、売上げデータや相関ルールのサポート率などの数値の分析では発見できなかった異常点を持つ商品を見つけた。この商品といくつかの商品間の組合せのルールは、近いサポート率（平均 0.74%）と

確信度（平均 59%）を持っていた．ここで、この商品を含む相関ルールに現れた他の商品から構成される相関ルールは、高いリピート率（平均 16.4%）となったが、この商品を含むルールだけは非常に低いリピート率（春期では 0%）となっていた．この現象について調べた結果、この商品は、ルールの組合せとなる他の商品と同じ意図で開発されたが、顧客に好ましくない要素を持っていたことが分かった．具体的には、「菓子に含まれる果物には大きな種があるため、食べにくかった」というような消費段階で現れる問題があった．そのため、顧客の初期購入は多いが、繰返し購買はあまりないという結果になっていた．

ここで、リピート率は、顧客の繰返し行動に着目して、導入した評価基準であるため、リピート率を適用するには次の 2 つの条件を満たす必要がある．1 つは、実行者である顧客の個体を識別できることである．もう 1 つは、顧客にその行為対象（たとえば、商品）に対する継続的なニーズが存在することである．本論文では、製菓小売業社の POS データに対してリピート率を用いた相関ルールマイニングを適用したが、それ以外にも通信販売会社における顧客の閲覧履歴および購買履歴データの分析など、様々な応用が考えられる．

4. リピータ顧客層の発見と RFM 分析による顧客グループとの比較

本章では、まず従来の RFM 分析について説明する．次に本論文における顧客のロイヤルティを説明し、ロイヤルティの比較方法を提案する．その後、ルールのリピータ顧客層を定義し、ロイヤルティの高い顧客層であるという仮説を立てる．最後に、リピータ顧客層のロイヤルティを評価するために、リピータ顧客層と RFM 分析における顧客グループの比較を行う．

4.1 RFM 分析

RFM 分析は、1960 年代に米国でさかんに研究された顧客分析手法であり、顧客をグループ化することにより、ロイヤルティの高い顧客を発見し、顧客の差別化対応を目的としている¹²⁾．将来の顧客を予測することに優れているため、ダイレクトメールなどにおける経営戦略のサポートに用いられる．RFM 分析では、顧客について次の側面から分析を行う．

- R (recency) : 一番最近買い物にきた日はいつか?
- F (frequency) : 今までに何回購入 (来店) しているのか?
- M (monetary) : 今までにどのぐらいの金額を購入しているのか?

RFM 分析では、顧客を R, F, M においてスコア

表 1 RF に基づく顧客分類

Table 1 Customer classification based on RF.

RF	Fs	Fa	Fb
Rs	ファン客	満足客	試食客
Ra	不満発生客	事情発生客	無関心客
Rb	不信客	不満客	非定着客

リングし、顧客を各セルにグループ化する．スコアリングは 3 段階、5 段階、7 段階などの方法があるが、本論文では、対象とするデータ規模を考慮したうえで、3 段階を採用した．まず、直近の来店日によって顧客データをソートし、3 等分により R 値のスコア付けを行った．現在より日付が一番近かったグループに 3 点、次は 2 点、一番遠かったものに 1 点を付けた．次に F 値に対しては、1 度しか来店していない顧客と 2 回以上来店している顧客は大きく異なると考え、来店回数が 1 である顧客の F 値を 1 点とし¹²⁾、残る顧客を来店頻度によってソートして 2 等分した．来店頻度の高いグループの F 値に 3 点、低いグループに 2 点を付けた．M に対しては、購入金額によりソートして 3 等分し、購入金額の高低順に 3 点から 1 点のスコア付けを行った．この結果、表 1 に示すように、R, F に基づいて顧客を 9 つのグループに分けることができる．ここで、R および F の添字の s, a, b はそれぞれスコアの高中低を表している．一般に、来店日が直近であるほど再来店の可能性が高いという事実、および、購買頻度と再来店可能性との正の相関を考慮して、各セルの顧客に対して次のような解釈ができる¹³⁾．

ホットなグループ (Rs)

- ファン客 (Rs-Fs) : 購買頻度が高く、直近に来店もしている．このような顧客を店のファンという．
- 満足客 (Rs-Fa) : 直近に来店しており、購買頻度も増加しつつある．ファン客へと育成できる可能性が高い顧客である．
- 試食客 (Rs-Fb) : 直近に来店はしているが購入回数が 1 回、つまり新規客である．

ウォームなグループ (Ra)

- 不満発生客 (Ra-Fs) : これまでファン客だったが、何らかの理由で店に不満を感じ、足が遠のいている顧客である．再度の来店を促す必要がある．
- 事情発生客 (Ra-Fa) : 何らかの事情が発生し、購入頻度が増えかける前に足が遠のいている顧客である．ホットなグループに引き上げる必要がある．
- 無関心客 (Ra-Fb) : 以前に 1 度購入しただけで、再来店していない顧客である．何か対策をとらなければ、今後再来店する可能性は少ないといえる．

表 2 RF による顧客グループとその対策

Table 2 Communication strategy to the customer classes based on RF.

RF	Fs	Fa	Fb
Rs	季節の挨拶 誕生日プレゼント 特別セール招待	ニュースレター バースデーレター 限定セール招待	サンキューレター 特典付き特売 セール案内
Ra	季節の挨拶 ニュースレター アンケート	特売セール案内 イベント案内	特売セール案内 イベント案内
Rb	電話調査・訪問	何もしない	何もしない

表 3 RM に基づく顧客分類

Table 3 Customer classification based on RM.

RM	Ms	Ma	Mb
Rs	プラチナ客	ゴールド客	シルバー客
Rab	一般客		

表 4 FM に基づく顧客分類

Table 4 Customer classification based on FM.

FM	Ms	Ma	Mb
Fs	プラチナ客	ゴールド客	一般客
Fa	ゴールド客	シルバー客	
Fb	新規客		

クールなグループ (Rb)

- 不信客 (Rb-Fs): 過去に不満発生客だったが, 何らかの理由で完全に店から離反してしまった顧客である. 離反した原因を突き止めることにより再発防止策を検討する必要がある.
- 不満客 (Rb-Fa): 過去に事情発生客だったが, 何らかの理由で店から離反してしまった顧客である. 不信客よりは, 再来店する可能性はある.
- 非定着客 (Rb-Fb): 過去に試しの購入をしたが, 結局定着しなかった顧客である. 元々他の店舗の顧客の可能性が高い.

以上の各顧客グループに対して, 表 2 のようなグループごとのコミュニケーション戦略をとることができる.

同様に, R, M に基づいて, 表 3 のように顧客を 4 つのグループに分けることができる¹³⁾. さらに, F, M に基づいた顧客のグループ分けを表 4 に示す. それぞれのグループの各セルの顧客に対して, 次のような解釈ができる.

RM に基づくグループ

- プラチナ客 (Rs-Ms): 売上げ貢献が高く, 再来店する可能性も高い顧客である.
- ゴールド客 (Rs-Ma): 売上げ貢献がある程度高く, 再来店可能性も高い顧客である.
- シルバー客 (Rs-Mb): 売上げ貢献は低い, 高い再来店の可能性を持つ顧客である.
- 一般客 (Rab): 再来店の可能性を判定できない

顧客である (RF グループでは, 来店頻度 F を考慮して判定する).

FM に基づくグループ

- プラチナ客 (Fs-Ms): 購入頻度が高く, 売上げ貢献も高い顧客である.
- ゴールド客 (Fa-Ms, Fs-Ma): 購入頻度または売上げ貢献が高い顧客である.
- シルバー客 (Fa-Ma): 購入頻度および売上げ貢献がある程度高い顧客である.
- 一般客 (FaFb-Mb): 購入頻度はある程度高いが, 売上げ貢献は少ない顧客である.

4.2 顧客ロイヤルティ

顧客ロイヤルティとは, 商品やサービスに愛着を持ち, その商品やサービスの提供者と繰返し取引することにこだわる意欲である^{14),15)}. ロイヤルティの高い顧客は, 高い満足度を示し¹⁶⁾, 次のような特性を持つ.

- 繰返し購入してくれる.
- 競合他社の誘いに乗らない.
- 第三者に勧めてくれる.

これらの行動そのものが「愛着の証」であると考えられることができる. 購買履歴データからは第三者に勧めてくれることを検証することができないが, 本論文では, 一定の期間にわたって, 継続的に購入してくれる顧客は競合他社の誘いに乗りにくいと想定し, 購買行動の継続性から顧客層のロイヤルティを比較することが可能であると考えた.

そこで, 購買行動の継続性を表すために, 顧客グループに対して, 来店確率と呼ぶ指標を定義する. 特定期間中のある顧客グループの来店確率を, その期間中に少なくとも 1 回以上来店した顧客人数の, そのグループ全体の人数に対する割合とする. 本論文では, 1 年間で月単位で区切り, 各月において来店確率を求め, 各グループの動向を考察する. ここで, 来店確率が平均的に高い顧客グループの顧客ロイヤルティも高いと考え, 来店確率を用いて顧客ロイヤルティを比較する.

4.3 リピータ顧客層

顧客の差別化や囲い込み戦略が重要視される近代では, ロイヤルティの高い顧客をいかに効率良く抽出するかが重要な課題になっている. 本研究では, 顧客分析として, 商品や購買行動に一定の傾向を示す, ロイヤルティの高い顧客層の発見を目的とする. ここで, 3 章では, リピート率を用いて特定の顧客に繰返されるルール発見できた. 本節では, その繰返しを行う顧客に着目し, そのロイヤルティおよび抽出方法につ

いて議論する。

特定のルールを繰り返している顧客は、商品や購買行動に習慣を持ち、またロイヤルティが高いという2つの性質も持っている。まず、このような顧客は、単に消耗品を繰り返し購入するというだけではなく、その購買パターンに含まれる商品の組合せに好みがあり、この組合せ購買に習慣を持つ傾向があると考えられる。たとえば、パンとミルクを同時に購入する顧客は多くいるが、一部の顧客はパンとミルクを朝食とするため、同時購入を繰り返している。これらの顧客はこの組合せ購買に対する習慣があるといえる。このような顧客は一般に来店頻度が高く、ロイヤルティが高いため、その顧客層の発見が顧客分析に有用であると考えられる。

このような顧客層を発見するために、本論文ではリピータ顧客層を定義する。バスケット分析において、相関ルール $X \rightarrow Y$ は商品 X と Y を同時に購入しているという購買パターンを表している。ここで、商品 X と Y の同時購入を2回以上行った顧客をルール $X \rightarrow Y$ のリピータと呼び、ルール R_i のすべてのリピータからなる集合を R_i -repeaters と表す。サポート率と確信度が閾値以上である N 個の相関ルール (R_1, R_2, \dots, R_N) を抽出した場合、 N 個の相関ルールにおけるルールのリピータの集合をリピータ顧客層と呼び、 R -repeater と表す (R -repeater = $\{R_1$ -repeaters $\cup R_2$ -repeaters $\cup \dots \cup R_N$ -repeaters $\}$)。リピータ顧客層の抽出は、相関ルールを抽出する際に、リピータを記録していくことで容易に実現できる。

ここで、リピータ顧客層を抽出する際、ルール自体が無意味(サポート率があまりに低くて、偶然の可能性が高いルールなど)であれば、そのルールの繰返しも無意味であると考えられる。そのため、本論文では、サポート率と確信度が閾値以下のルールを無意味なルールとし、それらのルールに対する繰返しを無視している。

4.4 RFM 分析と相関ルールマイニングの比較

RFM 分析は、分析対象(顧客)の状態を分類し、顧客への対応を差別化させることを目的としている。RFM 分析の特徴は下記のとおりである。

- 長所: ダイレクトメール、ダイレクト電話などのプロモーション対象顧客の特定に活用され、追加販売、顧客の満足度の向上や顧客の囲い込みには有益な成果が得られている。
- 短所: 経営戦略に応用するうえで、同一グループ(セル)内のすべての顧客を同様に扱うため、別の分析を行わない限り商品に対する購買傾向を

考慮できない。各セルの顧客に対してドリルダウン分析を行っても、各セルからサポート率の高い同じルールは抽出されるが、一部の顧客に繰り返されるルールは、サポート率が低いいため抽出されない。

一方、相関ルールマイニングは、アイテムの特性による分類を行い、商品に関する購買傾向の分析や、顧客属性による顧客分析ができる。商品と商品の関連や、商品と顧客の関連を見つけられるため、主に商品陳列、販促活動、商品開発に応用される。相関ルールマイニングの特徴は下記のとおりである。

- 長所: 単純な統計手法では発見できない関連を見つけられる。顧客属性との関連から拡張し、同じ属性を持つ顧客の獲得を可能にする。
- 短所: 発見した相関関係の有意性の判断とルールの解釈が難しい。さらに、本論文の対象データでは、顧客全体の年齢分布が40代から60代に集中しており、相関ルールにおける顧客の年齢層の差異があまりなかったため、顧客の年齢層を考慮した戦略を適用できない。

本論文で提案したリピータ率は、相関ルールマイニングの際に、顧客人数を集計することでサポート率と並行して求めることができる。そのため、相関ルールマイニングに対して少しの計算を追加することにより、購買パターンにおける顧客の行動の違いを発見できる。さらに、マイニング処理と並行して、リピータ顧客層を抽出できる。その結果、従来のRFM分析と相関ルールマイニングの短所を解消できる。

4.5 リピータ顧客層とRFM分析における顧客グループとの比較

上述のようにリピータ顧客層は、商品や購買行動に習慣があるという性質とロイヤルティが高いという性質を持っている。これは、特定の購買パターンを繰り返す顧客は、商品の組合せ購買に習慣があり、さらに、商品のブランドや店舗に対して愛着心を持っている場合が多いためである。一方、RFM分析においては、「ファン客」や「プラチナ客」のようなスコアの高い顧客層はロイヤルティが高く、「非定着客」や「一般客」のようなスコアの低い顧客層はロイヤルティが低いとされる。そこで、本論文では、ロイヤルティを表す指標として来店確率を用いて、リピータ顧客層とRFM分析における顧客グループとのロイヤルティを定量的に比較評価する。このとき、リピータ顧客層が、R, Fグループの「ファン客」、R, Mグループの「プラチナ客」およびF, Mグループの「プラチナ客」のような優良顧客と同等の来店確率を持てば、ロイヤルティ




図 4 春期 RF グループとリピータ顧客層

Fig. 4 Repeaters and RF classes from spring's customers.





図 3 春期における顧客の RF 分布

Fig. 3 Customers' distribution based on RF in spring.




図 5 春期 RM グループとリピータ顧客層

Fig. 5 Repeaters and RM classes from spring's customers.

の高い顧客層であると判断できる。

実験データには、2002 年 12 月から 2003 年 11 月までの POS データを用いた。この POS データのもととなる製菓会社において、大部分の商品は季節限定品であるため、相関ルールおよびリピータ顧客層は季節ごとに抽出した、条件を同じにするために RFM 分析でも、季節ごとにグループ化を行った。その一例として春期（2003 年 2 月 15 日から 4 月 20 日）の顧客 3,958 人の販売データを用いて、顧客のグループ化を行った際の、R、F における各セルの分布を図 3 に示す。また、この期間において、閾値以上のサポート率と確信度を持つすべての相関ルールに対して、リピータ顧客層を抽出すると、79 人となった。

ここで、顧客分析は、POS データなどの履歴情報を用いて、将来の戦略を立案するために実行するものである。したがって、分析時期に依存して、分析の効果が影響を受ける可能性がある。そこで、その影響を検証する一例として、春期のリピータ顧客層と R、F による各顧客グループについて、1 年間にわたって来店確率を求めた結果を図 4 に示す。

同様に、春期におけるルールのリピータ顧客層と R、M および F、M による各顧客グループに対して 1 年間にわたって来店確率を求めた結果を図 5 と図 6 に

示す。

この結果から、春期のデータから抽出したリピータ顧客層は、年間を通じて高い来店確率（50%の期間で 0.6 以上）を維持していることが分かる。一方、R、F 分析における「ファン客」、「不信客」、「不満発生客」は年間の 50%、「満足客」、「事情発生客」、「不満客」は年間の 17%の期間において 0.6 以上の高い来店確率となっている。R、M 分析における「プラチナ客」は年間の 50%、「ゴールド客」は年間 17%の期間において 0.6 以上の来店確率となっている。F、M 分析における「プラチナ客」、「ゴールド客」は年間の 50%、「ゴールド客」、「シルバー客」、「新規客」は 17%の期間において 0.6 以上の来店確率となっている。ここで、RFM 分析に用いたデータが春期のみで 2 カ月間であったため、R、F 分析において「不信客」や「不満客」と判断された顧客が、実際はその後高い頻度で来店していた。したがって、RFM 分析のグループ化の精度は、分析に用いるデータの期間と分析時期に大きく依存することが分かる。

次に、参考として、2002 年 12 月からの 1 年間の販売データに基づいて、RFM 分析のグループ分けとリピータ顧客層の抽出を行った。図 7、図 8、図 9 は、年




図 6 春期 FM グループとリピータ顧客層

Fig. 6 Repeaters and FM classes from spring's customers.

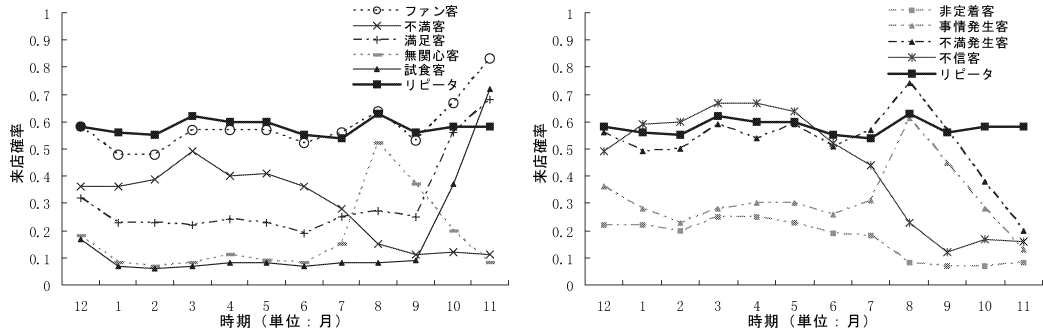


図 7 年間 RF グループとリピータ顧客層

Fig. 7 Repeaters and RF classes from one year's customer.




図 8 年間 RM グループとリピータ顧客層

Fig. 8 Repeaters and RM classes from one year's customer.

間におけるリピータ顧客層（リピータ）と、1年間の販売データに基づいて正確にグループ化された RFM 分析による各顧客グループを比較した結果である。ここで、顧客層の比較を春期と年間において行ったのは、分類の精度の観点からは、季節ごとが相関ルール抽出の最適期間であり、年間が RFM 分析の最適期間であるためである。

この結果から、リピータ顧客層は、年間を通じて高い来店確率（33%の期間で 0.6 以上）を維持していることが分かる。R, F 分析における「ファン客」は年間

の 25%、「不信客」は年間の 25%の期間において 0.6 以上の高い来店確率となっている。また「不信客」はその期間が上半期にあり、下半期の来店確率は非常に低くなっている。R, M 分析における「プラチナ客」は年間の 25%、F, M 分析における「プラチナ客」は年間の 25%の期間において 0.6 以上の来店確率となっている。

以上の結果から、リピータ顧客層は、RF グループの「ファン客」、RM グループの「プラチナ客」および FM グループの「プラチナ客」のような優良顧客層と同等かそれ以上の高い来店確率を持ち、ロイヤルティの高い顧客層であることが確認できる。ここで、来店確率の高い顧客は、将来においても継続して来店する可能性が高いと考えられる。顧客を新規獲得するためのコストは顧客を維持するためのコストの 5 倍になるといわれている。そのため、新顧客の獲得だけでなく、既存顧客、特に上述のようなロイヤルティの高い顧客の維持が重要である。

次に、ルールのリピータ顧客層が、RFM 分析の各グループにどのように分布しているかを調べた。図 10, 図 11, 図 12 は、春期におけるリピータ顧客層の、RFM 分析における分布を表す。この結果から、リピータ




図9 年間 FM グループとリピータ顧客層
Fig.9 Repeaters and FM classes from one year's customer.




図10 リピータの RF 分布
Fig.10 Repeaters' distribution in RF classes.




図11 リピータの RM 分布
Fig.11 Repeaters' distribution in RM classes.




図12 リピータの FM 分布
Fig.12 Repeaters' distribution in FM classes.

高いロイヤルティを持っていることが分かった。たとえば、RF グループの「一般客」に属しているリピータ顧客層は、58.3%の期間において 0.6 以上の来店確率を維持していた。これは、R、F、M による顧客グループの抽出では、一部の来店確率の高い顧客に低スコアを与えてしまうことを示している。一方、商品に関する購買習慣を考慮するリピータ顧客層には、このような顧客も含まれていると考えられる。その結果、先述のように、リピータ顧客層は、RFM 分析による分類と同等かそれ以上の高い来店確率（ロイヤルティ）の顧客層を抽出できている。

3章で述べたように、リピート率を導入したことで、相関ルールと消費者の関連が明らかになる。その結果、商品群と顧客像を結びつけ、購買パターンに対する繰返し行動を考慮したルールの解釈ができる。さらに、本章のリピータ顧客層の抽出により、ロイヤルティの高い個々の顧客に対して、嗜好に合った新商品の紹介を送付するなど、差別化経営戦略の展開が可能となる。

5. 考 察

RFM 分析は顧客全体を R、F、M によってグループ化するのに対して、リピータ顧客層は顧客の一部であり、ロイヤルティの高いすべての顧客が含まれるものではない。ここで、RFM 分析は主にダイレクトメール (DM) およびダイレクト電話 (DT) のような方法で顧客獲得と顧客維持を行うのに対して、リピータ顧客層は購買行動に習慣があり、高いロイヤルティを持つことから、商品や購買特性を考慮した顧客維持戦略 (たとえば、顧客別の商品サンプルの配布、興味のありそうな新商品案内など) に応用できるものと考えられる。最近では、製品サービスの市場飽和にともない、顧客は大量かつ無関係の宣伝やサービス案内情報に慣れてしまい、無視することが多くなっている。そこで、個々の顧客が必要とする情報や興味のある情報

タの多くは、RFM 分析による「ファン客」や「プラチナ客」のような優良顧客であるが、「不信客」、「不満客」、「一般客」などのように RFM のスコアの低い顧客層も含まれている。そこで、後者に含まれるリピータ顧客について調べたところ、RFM 分析のスコアの低いグループに属しているにもかかわらず、おおむね

を、いかにして提供するかが重要と考えられている。本論文のアプローチによって抽出したリピート顧客層に対して、リピート率を用いて抽出した関連ルールをもとに経営戦略を立てることで、ロイヤルティの高い顧客に対する、商品や購買パターンを考慮した差別化サービスを提供できるものとする。上述のように、リピート顧客は顧客全体のごく一部となる場合もあるが、立案した戦略をその一部の顧客に直接適用することもできるし、同様の特性を持つ他の顧客へ適用することも可能である。さらに、ロイヤルティの高い顧客のプロフィールデータや関連情報を分析することにより、ロイヤルティの高い顧客になる潜在的な傾向を見つけ、その育成プロセスに応用することもできる。

一方、リピート率の定義では、1人の顧客が繰返し行動を非常に多く行うような場合でも、ルールが高いリピート率を示す可能性がある。本論文では、外れ値の検出を特に行っていないが、いくつかの状況では、外れ値に対する注意が必要となる。たとえば、トランザクションデータ数が少ない場合、少数のデータがリピート率に与える影響が大きいため、外れ値の影響を強く受ける。同様に、サポート率またはリピート率が非常に低い場合も、外れ値が分析結果に影響を与える可能性が高い。本研究では、外れ値の原因となる顧客はリピート顧客として抽出すべきであるが、関連ルールの抽出の際には排除することが妥当と考える。その具体的な方法には、従来のデータマイニングにけるアプローチを利用できる^{8),17),18)}。

6. 関連研究

関連ルールマイニングについて、これまでに多くの研究が行われている。文献 8) の Apriori アルゴリズムの提案に続いて、多くの派生アルゴリズムが提案された。文献 4) では、階層構造を考慮したアイテム集合から関連ルールを抽出するアルゴリズムが提案された。文献 5) では、効率的に系列パターンを発見できる GSP アルゴリズムが提案された。これらのアルゴリズムの開発は、主に各種のパターンの発見や、実行性能の向上を目的している。

抽出された関連ルールの有効性を向上させるために、文献 17) において、 χ^2 を使った独立検定を応用し、明らかに価値のないルールを取り除く方法が提案された。文献 6) では、相関係数によりルールの負の相関を判断する方法³⁾ を用いて、最小興味度を導入し、正の相関ルールと負の相関ルールを同時に抽出できるアルゴリズムが提案された。これらの研究では、パラメータの導入により有意性のないルールを枝刈りすることを

目的としている。このほかに、関連ルールの抽出結果の解釈をサポートするために、関連ルールの視覚化に関する研究が行われている^{19),20)}。

最近では、人工データを用いた提案アルゴリズムの評価だけでなく、実データを用いた評価に関する研究が多く行われている。文献 2) では、顧客の行動の変化と、変化の尺度を定義し、顧客行動の変化のパターンを発見する手法が提案された。その後、インターネットショッピングに関する事例研究によって評価が行われている。

上述の研究は、主にアルゴリズムの性能の向上と様々なマイニング手法の提案に着目している。一方、RFM 分析に基づいた顧客分析も多く行われている。文献 21) では、RFM モデルと顧客生涯価値との関連について議論されている。文献 22) では、RFM 分析に基づいて、小売業などの特定のサービスに適した顧客グループ化を行う手法についての研究が行われている。しかし、いずれも顧客の属性に基づいた分析であり、商品や購買パターンとの関連は考慮していない。

本論文のような関連ルールマイニングを顧客分析に応用する研究は、これまでに多くは行われていない。文献 23) では、関連ルールマイニングにより、顧客満足度を分析する手法が提案されている。この手法では、あらかじめ顧客に対して、「満足」または「不満足」という満足度の特性を付ける。まず、満足度の特性を持つ顧客グループと全顧客グループのそれぞれを対象とし、関連ルールのサポート率を求める。このとき、Anand らが定義した興味尺度 (interestingness measure)¹⁸⁾ を利用して、関連ルールを「不満足」との関連性の高低順にランキングする。このランキング結果を視覚化して、パターンを識別する。次に、業種、年齢、教育レベル、労働環境、最小子供の年齢、結婚状況という社会属性に基づいて、 χ^2 分析を行い、顧客をプロファイリングする。さらに、不満足顧客に対して、スコアリングを行い、「不満足」と関連する要素を発見する。興味尺度により発見したルールは特徴ルール (characteristic rule) と呼ばれ、特徴と要素を関連付けることができる。特に、保険会社や銀行では、特徴ルールの抽出結果を顧客分析に応用するが多い。しかし、この手法では、関連ルールのサポート率をグループごとに求める必要があるため、データの規模が大きくなると、効率が悪くなり、ルールの見逃しと冗長性の発生の可能性が高くなる。一方、本論文が対象とする POS データは、顧客の性別、年齢と大体の地域に関する情報を持っているが、仕事、教育、家庭に関する情報はないため、顧客をプロファイリング

するには情報が不十分であり、上記の顧客分析手法は適用できない。本論文の提案手法では、相関ルールに対する新たな評価基準としてリピート率を導入することにより、大きな計算を追加することなく、相関ルールに顧客の購買行動を反映し、結果の解釈を行い、顧客分析に応用することができる。そのため、データ規模の制限はない。

7. おわりに

本論文では、相関ルールマイニングにおいて、顧客の分析と重要な相関ルールの抽出を同時に満たすことを目的として、リピート率という新しい評価基準を導入した。サポート率とリピート率を用いて、抽出した相関ルールを顧客の購買行動の違いに基づいて4つのグループに分類した。これにより、特定の購買行動を繰り返すロイヤルティの高い顧客層の発見と、その購買行動を表す相関ルールの抽出を同時に実現できる。

さらに本論文では、ルールのリピート顧客層と伝統的なRFM分析手法による顧客グループを比較することにより、その顧客層が高いロイヤルティを持つことを検証した。

本論文では、実データを用いた実証実験により、リピート率の導入が有効であることを確認したが、この結果は、単一カテゴリーのブランド商品の販売データという特徴や、データ量などの制限に影響を受ける可能性がある。そのため、今後は様々な実データを用いた実証実験により、提案手法の有効性を検証する必要がある。

謝辞 本研究の一部は、文部科学省21世紀COEプログラム「ネットワーク共生環境を築く情報技術の創出」および文部科学省特定領域研究(18049050)の研究助成によるものである。ここに記して謝意を表す。

参考文献

- 1) Peppers, D. and Rogers, M.: ONE to ONE マーケティング, ダイアモンド社 (1995).
- 2) Song, H., Kim, J. and Kim, S.: Mining the Change of Customer Behavior in an Internet Shopping Mall, *Expert System with Application*, Vol.21, No.3 (2001).
- 3) Han, J. and Micheline, K.: *Data Mining: Concepts and Techniques*, Morgan Kaufmann Publishers (2000).
- 4) Srikant, R. and Agrawal, R.: Mining Generalized Association Rules, *Proc. VLDB*, pp.407-419 (1995).
- 5) Srikant, R. and Agrawal, R.: Mining Sequential Patterns: Generalizations and Performance

- Improvements, *Proc. 5th Int. Conf. on Extending Database Technology*, pp.3-17 (1996).
- 6) Wu, X., Zhang, C. and Zhang, S.: Efficient Mining Both Positive and Negative Association Rules, *ACM Transaction on Information Systems*, Vol.22, No.3, pp.381-405 (2004).
- 7) 福田剛志, 森本康彦, 徳山 豪: データサイエンス・シリーズ・データマイニング, 共立出版 (2001).
- 8) Agrawal, R. and Srikant, R.: Fast Algorithms for Mining Association Rules, *Proc. VLDB*, pp.487-499 (1994).
- 9) Michael, J.A. and Linoff, B.G. (著), 江原 淳, 佐藤栄作 (共訳): データマイニング手法, 海文堂出版 (1999).
- 10) 古川康一: データマイニング法 2001 春学期. <http://bruch.sfc.keio.ac.jp/course/DM01/>
- 11) 株式会社インタスコープ. <http://www.interscope.co.jp/datamining/dp01.html>
- 12) Blattberg, R.C., Thomas, J.S. and Getz, G. (著), 小川孔輔, 小野譲司 (監訳): 顧客資産のマネジメント, ダイアモンド社 (2002).
- 13) Hughes, A.M.: How to Succeed with RFM Analysis a Case Study, Database Marketing Institute. <http://www.dbmarketing.com/article/Art106.htm>
- 14) Hollowell, R.: The Relationships of Customer, Customer Loyalty, and Profitability: An Empirical Study, *IJSIM*, Vol.7, No.4, pp.27-42 (1996).
- 15) Raju, J., Srinivasan, S.V. and Lal, R.: The Effects of Brand Loyalty on Competitive Price Promotional Strategies, *Management Science*, Vol.36, No.3, pp.276-304 (1990).
- 16) Lam, S., Shankar, V., Erramilli, M.K. and Murthy, B.: Investigating the Interrelationships Among Customer Value, Customer Satisfaction, Switching Costs and Customer Loyalty, *JAMS*, Vol.32, No.3, pp.293-311 (2004).
- 17) 福田剛志, 森下真一: 相関ルールの可視化について, 電子情報通信学会技術報告, Vol.95, No.81, pp.41-48 (1995).
- 18) Anand, S.S., Hughes, J.G., Bell, D.A. and Patrick, A.R.: Tackling the Cross-sales Problem Using Data Mining, *Proc. 1st Pacific-Asia Conf. on KDD*, pp.331-343 (1997).
- 19) Hofmann, H., Siebes, A. and Wilhelm, A.: Visualizing Association Rules with Interactive Mosaic Plots, *Proc. 6th ACM SIGKDD*, pp.227-235 (2000).
- 20) Zhao, K. and Liu, B.: Visual Analysis of the Behavior of Discovered Rules, *Proc. Workshop on Visual Data Mining*, pp.59-64 (2001).
- 21) Fader, P., Bruce, H. and Ka, L.: RFM and CLV: Using Iso-value Curves for Customer

Base Analysis, *Journal of Marketing Research*, Vol.42, No.4, pp.415-430 (2005).

- 22) Marcus, C.: A Practical yet Meaningful Approach to Customer Segmentation, *Journal of Consumer Marketing*, Vol.15, No.5, pp.494-504(11), Emerald Group Publishing (1998).
- 23) Bloemer, J., Brijs, T., Swinnen, G. and Vanhoof, K.: Using Association Rules in Customer Satisfaction Studies to Identify Latent Dissatisfied Customers, *ESOMAR Publication Series*, ISBN 92-831-1274-1, pp.102-110 (1998).

(平成 17 年 12 月 22 日受付)

(平成 18 年 9 月 14 日採録)



裴 明花 (学生会員)

2005 年滋賀大学大学院経済学研究科博士前期課程修了。同年大阪大学大学院情報科学研究科博士後期課程に入学し、現在に至る。データマイニング、ウェブマイニングの研究

に興味を持つ。



谷口 伸一 (正会員)

1976 年静岡大学工学部電気工学科卒業。1996 年京都大学博士 (工学) 取得。1993 年滋賀大学経済学部情報管理学科助教授、2005 年より同大学院教授となり、現在に至る。データベースシステム、データマイニング、ユビキタスシステムに興味を持ち、社会システムにおけるデータベースの応用として企業情報のデータマイニングに基づくマーケティング戦略を共同研究するとともに、国交省の支援事業としてユビキタス観光システムの実証実験を推進している。電子情報通信学会、日本データベース学会の各会員。



原 隆浩 (正会員)

1995 年大阪大学工学部情報システム工学科卒業。1997 年同大学院工学研究科博士前期課程修了。同年同大学院工学研究科博士後期課程中退後、同大学院工学研究科情報システム工学専攻助手、2002 年同大学院情報科学研究科マルチメディア工学専攻助手、2004 年より同大学院情報科学研究科マルチメディア工学専攻助教授となり、現在に至る。工学博士。1996 年本学会山下記念研究賞受賞。2000 年電気通信普及財団テレコムシステム技術賞受賞。データベースシステム、分散処理に興味を持つ。IEEE, ACM, 電子情報通信学会、日本データベース学会の各会員。



西尾章治郎 (フェロー)

1975 年京都大学工学部数理工学科卒業。1980 年同大学院工学研究科博士後期課程修了。工学博士。京都大学工学部助手、大阪大学基礎工学部および情報処理教育センター助教授、大阪大学大学院工学研究科情報システム工学専攻教授を経て、2002 年より同大学院情報科学研究科マルチメディア工学専攻教授となり、現在に至る。2000 年より大阪大学サイバーメディアセンター長、2003 年より大阪大学大学院情報科学研究科長を併任。この間、カナダ・ウォータールー大学、ビクトリア大学客員。データベース、マルチメディアシステムの研究に従事。現在、Data & Knowledge Engineering 等の論文誌編集委員。本会理事を歴任。電子情報通信学会フェローを含め、ACM, IEEE 等 8 学会の会員。