数理解析研究所講究録
1504巻 2006年 136-149

消費者DATAから情報を得る方法

Methods to mine the knowledge from the purchased consumer data

流通科学大学・商学部　野口 博司[1]　　神戸大学・海事科学部　磯貝 恭史[2]
Hiroshi Noguchi, Faculty of Commerce, University of Marketing and Distribution Sciences[1]
Takafumi Isogai, Faculty of Maritime Sciences, Kobe University[2]

要旨

流通業界では，POS等の消費者購買dataから，売れ筋商品の傾向を発見し，また優良顧客を発掘する方法について研究している．この時代の要請に呼応して，我々は，大量のdatabaseからbusinessに役立つ情報を得るための方法について研究を行った．本報告は，購買dataの分析に有効とされている数量化の方法，correspondence analysis，market basket analysisを取り上げて，実用面からどのような目的の時にどの手法が有効であるかを比較検討する．そして，今後の活用の留意点を提言する．特にcorrespondence analysisにおいては、反応数の少ない項目を含む行と列の同時布置を行う際に、その重みを調整する距離尺度のあり方について提案する．

Keywords: 数量化３類，correspondence analysis，market basket analysis，decision tree，data mining，positioning methods.

１．はじめに

business現場では，顧客記録のdatabaseが普及して、売れ筋商品の傾向や優良顧客を発見するための手法について研究がなされている．しかし，必ずしも、data 解析の専門家がその研究に取り組んでいるとは限らず，結果が興味を引くものであれば，各手法のもつ解法特性を理解せずに，その結果を信じている．各手法には，それぞれ特性があり，その特性をよく理解した上で，その解析の結果を考察していく必要があると考える．そこで，我々は，これら顧客購買dataを扱う代表的な手法を取り上げて，実用面の立場から，同じdataからでも，どのような結論が導けるかを示す．また，各手法間の特性について比較を行い，今後の活用上での留意点を提言する．

２．研究方法について

２．１　購入dataの収集とその内容について

神戸の大学生2,3回生 42人を対象にして，「午後から数人の談話会を開催することを前提として，　a convenience storeでどのようなsnack菓子と飲み物を購入するかを模擬実験してもらった．予算金額は1500円である．購入された延べ品目は，snack菓子は，ﾎﾟﾃﾄﾁｯﾌﾟｽ，ﾎﾟｯｷｰ，ｸｯｷｰ，ﾁｮｺﾚｰﾄ，ｹｰｷ，ﾋﾞｽｹｯﾄ，ﾊﾟﾝ，和菓子，ｱﾗﾚの９品目であった．飲み物は，紅茶，ｺｰﾗ，ｼﾞｭｰｽ，ｺｰﾋｰ，日本茶，ｳｰﾛﾝ茶，ﾐﾙｸ，ｽﾎﾟｰﾂ飲料の８品目である．得られたdataを表１に示す．表１で，１となっているのは，被験者が購入した品目であり，０は購入しなかった品目である．１番多かった品目数は，８品目であり，１番少なかったのは，２品目であった．

次に今回検討の対象とした解析法を示す．

表1　今回の実験で得たデータ

	コーヒー	紅茶	コーラ	ジュース	日本茶	ウーロン茶	スポーツ飲料	ミルク	チョコレー	ポテトチップス	アラレ	パン	ビスケット	ケーキ	クッキー	和菓子	ポッキー	性別
藤田	1.0	1.0	1.0	1.0	0.0	0.0	0.0	0.0	0.0	1.0	0.0	0.0	1.0	1.0	0.0	0.0	1.0	1.0
伊藤	1.0	1.0	1.0	1.0	0.0	0.0	0.0	0.0	0.0	1.0	0.0	0.0	0.0	0.0	1.0	0.0	1.0	1.0
赤木	1.0	0.0	1.0	1.0	0.0	0.0	0.0	1.0	0.0	1.0	0.0	0.0	0.0	0.0	1.0	0.0	1.0	1.0
江尻	0.0	0.0	1.0	0.0	0.0	0.0	0.0	0.0	0.0	1.0	0.0	0.0	0.0	0.0	0.0	0.0	1.0	1.0
谷村曜	0.0	1.0	0.0	0.0	0.0	1.0	0.0	1.0	1.0	1.0	0.0	0.0	0.0	1.0	1.0	0.0	0.0	2.0
森	0.0	0.0	0.0	0.0	1.0	0.0	1.0	0.0	0.0	1.0	0.0	1.0	0.0	0.0	0.0	0.0	1.0	1.0
新井	0.0	1.0	1.0	0.0	0.0	0.0	0.0	0.0	1.0	1.0	0.0	0.0	0.0	0.0	1.0	1.0	0.0	1.0
小澤	1.0	0.0	0.0	0.0	0.0	0.0	0.0	1.0	0.0	1.0	0.0	0.0	0.0	1.0	0.0	0.0	1.0	1.0
滝下	0.0	0.0	0.0	1.0	0.0	0.0	0.0	0.0	0.0	1.0	0.0	0.0	0.0	0.0	0.0	0.0	1.0	1.0
瀧岡	0.0	0.0	0.0	1.0	0.0	0.0	1.0	0.0	1.0	1.0	0.0	0.0	0.0	0.0	0.0	0.0	1.0	1.0
野田	1.0	0.0	0.0	1.0	0.0	0.0	0.0	0.0	0.0	1.0	0.0	0.0	0.0	1.0	1.0	0.0	0.0	1.0
橋本	0.0	0.0	0.0	1.0	0.0	1.0	0.0	0.0	1.0	1.0	0.0	0.0	0.0	0.0	1.0	0.0	1.0	1.0
近藤	0.0	1.0	1.0	0.0	0.0	0.0	0.0	0.0	1.0	1.0	0.0	0.0	0.0	0.0	1.0	0.0	0.0	1.0
八木	1.0	0.0	1.0	0.0	0.0	0.0	0.0	0.0	0.0	1.0	0.0	1.0	0.0	0.0	0.0	0.0	1.0	1.0
大塚布佐子	0.0	1.0	0.0	0.0	0.0	1.0	0.0	0.0	0.0	1.0	0.0	0.0	1.0	1.0	0.0	0.0	1.0	2.0
穴吹	0.0	1.0	0.0	1.0	0.0	0.0	0.0	0.0	0.0	1.0	0.0	0.0	0.0	1.0	0.0	0.0	0.0	1.0
鈴木	0.0	0.0	0.0	1.0	0.0	0.0	1.0	0.0	1.0	1.0	0.0	0.0	0.0	0.0	1.0	0.0	0.0	1.0
國宝	1.0	1.0	0.0	1.0	0.0	0.0	0.0	0.0	0.0	1.0	0.0	0.0	0.0	1.0	0.0	0.0	1.0	1.0
長濱	0.0	0.0	0.0	0.0	0.0	1.0	0.0	0.0	0.0	1.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	1.0
天野	0.0	1.0	1.0	0.0	0.0	0.0	0.0	0.0	0.0	1.0	0.0	0.0	0.0	0.0	0.0	0.0	1.0	1.0
明尾	0.0	0.0	0.0	1.0	1.0	0.0	0.0	1.0	1.0	1.0	1.0	1.0	0.0	0.0	0.0	0.0	0.0	1.0
岩本	0.0	0.0	0.0	1.0	1.0	0.0	0.0	0.0	1.0	1.0	1.0	0.0	0.0	1.0	0.0	0.0	0.0	1.0
中堤	0.0	1.0	1.0	1.0	0.0	0.0	0.0	0.0	0.0	1.0	0.0	0.0	0.0	1.0	0.0	0.0	0.0	1.0
井村	0.0	0.0	0.0	1.0	0.0	0.0	0.0	0.0	0.0	1.0	0.0	0.0	1.0	0.0	1.0	0.0	1.0	2.0
松崎	0.0	1.0	1.0	1.0	0.0	0.0	0.0	0.0	1.0	1.0	0.0	0.0	0.0	0.0	1.0	0.0	1.0	1.0
水田	0.0	1.0	1.0	0.0	1.0	0.0	0.0	0.0	0.0	1.0	0.0	0.0	0.0	0.0	0.0	1.0	1.0	1.0
佐藤	0.0	1.0	1.0	0.0	0.0	0.0	0.0	0.0	0.0	1.0	0.0	0.0	0.0	0.0	1.0	0.0	1.0	1.0
岡本	1.0	0.0	1.0	0.0	0.0	1.0	0.0	0.0	0.0	1.0	0.0	0.0	0.0	0.0	1.0	0.0	1.0	1.0
平田	0.0	1.0	1.0	0.0	0.0	0.0	0.0	0.0	0.0	1.0	0.0	0.0	0.0	0.0	0.0	0.0	1.0	1.0
村中	1.0	0.0	0.0	0.0	1.0	0.0	0.0	0.0	0.0	0.0	0.0	1.0	1.0	1.0	0.0	1.0	0.0	1.0
大滝	0.0	1.0	0.0	0.0	0.0	1.0	0.0	0.0	0.0	1.0	0.0	0.0	1.0	0.0	1.0	0.0	1.0	2.0
長畑	0.0	0.0	1.0	0.0	0.0	0.0	0.0	0.0	0.0	1.0	0.0	1.0	0.0	1.0	0.0	0.0	1.0	1.0
森下	0.0	1.0	0.0	1.0	1.0	0.0	0.0	0.0	1.0	1.0	0.0	0.0	0.0	1.0	0.0	1.0	0.0	2.0
岡内	0.0	1.0	0.0	0.0	0.0	0.0	0.0	0.0	1.0	0.0	0.0	0.0	1.0	0.0	1.0	0.0	1.0	2.0
石黒	0.0	1.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	1.0	0.0	0.0	0.0	1.0	1.0	0.0	0.0	1.0
内田	1.0	0.0	1.0	0.0	0.0	0.0	0.0	0.0	1.0	1.0	0.0	0.0	1.0	0.0	0.0	0.0	1.0	1.0
有吉	1.0	1.0	0.0	0.0	0.0	0.0	0.0	0.0	1.0	1.0	0.0	0.0	1.0	0.0	0.0	0.0	0.0	1.0
西口	0.0	1.0	1.0	0.0	0.0	0.0	0.0	0.0	1.0	1.0	0.0	0.0	0.0	0.0	1.0	0.0	1.0	1.0
畑岡	0.0	0.0	1.0	1.0	0.0	0.0	0.0	0.0	1.0	1.0	0.0	0.0	0.0	0.0	1.0	0.0	0.0	1.0
中尾	1.0	0.0	0.0	0.0	0.0	1.0	0.0	0.0	1.0	1.0	0.0	0.0	0.0	0.0	1.0	0.0	0.0	2.0
竹元	1.0	0.0	0.0	0.0	1.0	0.0	0.0	0.0	0.0	1.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	1.0
浅田	1.0	0.0	0.0	1.0	0.0	0.0	0.0	1.0	1.0	0.0	0.0	1.0	0.0	0.0	0.0	0.0	0.0	1.0

2．2　検討した解析法について

今回，検討対象にした解析方法は，消費者購買 data で，1番よく活用されている下記の三つである．即ち，

(1)数量化法による購入品目の pattern 分析

(2)correspondence analysis による snack 菓子と飲み物の関係

(3)market basket analysis による 購入品目間の関連である pattern の抽出，即ち data mining である．

3．数量化法と correspondence analysis について

(1)数量化法と(2)correspondence analysis についてであるが，分割表や林の数量化法との数値理論的な関係は，既に，磯貝・野口の「特異値分解とその応用」[1]で報告してあるので，数量化法についての説明は省略する．本報告では、correspondence analysis における反応の少ない項目を含む行と列との同時布置を行う際の調整方法について提言したいので，correspondence analysis の距離尺度[2]については、説明することにする．

3．1　correspondence analysisの距離尺度について

correspondence analysisの距離尺度を述べる前に，まず特異値分解について説明する．
n×p行列Xが与えられた時，Xの列 vector についての内積を考える時に，n×nの正定符号行列Mをおく．そして，Xの行 vector について内積を考える時にp×pの正定符号行列Nとおいて，重みとして与えられている重み付きのEuclid内積を考えることにする．
この時，一般化特異値分解とは，rank r （r≤p）の data 行列n×pのXが与えられた時，X＝UD_pV^T と分解されることを言う．ここで，D_p=diag(d_1, d_2,…, d_r) ($d_1 \geq d_2 \geq \cdots \geq d_r$) であり，$U^TMU=I_r$，$V^TNV=I_r$を満たす．即ち，Uはn×r，$D_p$はr×r，$V^T$はr×pの行列である．

そこで，m×tの確率行列$P=(p_{ij})$が与えられた時，次の式を計算して，このQの特異値分解を求めることにする．

$$Q=R^{-1/2}PC^{-1/2} \qquad \{R=diag(p_{1.},p_{2.},\cdots,p_{m.}),C=diag(p_{.1},p_{.2},\cdots,p_{t})\}. \tag{1}$$

Qの持つrankをr＋1と考えて，$S=Q^TQ$のspectral 分解を求める．

$$Q^TQ=\tilde{V}\Lambda\tilde{V}^T, \qquad \Lambda=diag(\lambda_0,\lambda_1,\cdots,\lambda_r),\ \lambda_0\geq\lambda_1\geq\cdots\geq\lambda_r>0$$
$$\tilde{V}=(\tilde{v}_0,\cdots,\tilde{v}_r),\ \tilde{V}^T\tilde{V}=I_{r+1} \tag{2}$$

ここで，$\sqrt{\lambda_i}=\rho_i$ $\{\tilde{D}=diag(\rho_0,\rho_1,\cdots,\rho_r)\}$とおき，

$$\tilde{U}=Q\tilde{V}\tilde{D}^{-1} \tag{3}$$

とおけば，Qの特異値分解は次の(4)式となる．

$$Q=\tilde{U}\tilde{D}\tilde{V}^T,\ \tilde{U}=(\tilde{u}_0,\tilde{u}_1,\cdots,\tilde{u}_r),\ \tilde{U}^T\tilde{U}=I_{r+1} \tag{4}$$

そこで，$U=R^{-1/2}\tilde{U}, V=C^{-1/2}\tilde{V}$と変換すると，

$$R^{-1}PC^{-1}=R^{-1/2}QC^{-1/2}=R^{-1/2}\tilde{U}\tilde{D}\tilde{V}^TC^{-1/2}=U\tilde{D}V^T \tag{5}$$

ここで$\tilde{D}=diag(\rho_0,\rho_1,\cdots,\rho_r)$，$\rho_0=1\geq\rho_1\geq\cdots\geq\rho_r>0$であり，Rは基準化条件$U^TRU=I_{r+1}$を満たし，Cも$V^TCV=I_{r+1}$の基準化条件を満たす．このとき，P＝($p_{ij}$)の確率分布において，ρはP＝($p_{ij}$)の確率分布のIとJについての２つの実数値確率変数f(I)とg(J)の相関係数に相当する．そして，ρが最大になるようなscore x，yのscore・vectorが特異値ρ_K (K=1, 2, …, r) に対応する固有vector u_Kと v_Kの(u_i, v_j) (K=1, 2, …, r)となる．即ち，行列の固有値問題にして表現すると$R^{-1}Py=\rho x$，$C^{-1}Px=\rho y$ であり，これらK次元での図示表現は，自明な解 $\rho_0=1$，$x_0=1_m$，$y_0=1_t$ を取り除き，上からK番目までの解を用いることになる．

$$U_K\tilde{D}_K=F,\ \{F^T=(f_1:f_2:\cdots:f_t)\} \ (6), \qquad V_K\tilde{D}_K=G,\ \{G^T=(g_1:g_2:\cdots:g_m)\} \ (7)$$

となる．(6)式のFは主成分分析の$U_QD_{p(q)}$の主成分得点に対応する．Fの行 vector f_i^Tの布置におけるf_iのEuclid相当の距離関係$\|f_i-f_j\|$は，m個の行 vector 中に対応する第i行 vector と第j行 vector の Euclid 距離関係

$$\{\sum_{s=1}^{t}\left(\frac{p_{is}}{p_{i.}\sqrt{p_{.s}}}-\frac{p_{js}}{p_{j.}\sqrt{p_{.s}}}\right)^2\}^{\frac{1}{2}} \tag{8}$$

を近似する．

Gは共分散型bi-plot$D_{p(2)}V^T{}_{(2)}$に対応する．そして，Gの行 vector g_j^Tの布置におけるg_jのEuclid距離相当の関係$\|g_i-g_j\|$は，t個の列 vector 中に対応する第i列 vector と第j列 vector の Euclid 距離関係

$$\{\sum_{s=1}^{m}\left(\frac{p_{si}}{p_{i.}\sqrt{p_{s.}}}-\frac{p_{sj}}{p_{.j}\sqrt{p_{s.}}}\right)^2\}^{\frac{1}{2}} \tag{9}$$

を近似する.

(c)(d)を，共にBenzecriのχ^2(chi-square)距離という.

F，G間の関連を調べることは、FとGとの行vector間の内積情報を取ることであり，即ち，行・列間の分布間距離を比べていることになる．この考えはPearsonのχ^2統計量の考え方と一致する．即ち，correspondence analysisは，主成分分析やbi-plotのような行列の近似を目的としたものとは異なる.行･列間の分布間距離をEuclid距離と同じ扱いで,correspondence analysisを用いるならば，用いるdata行列Xの入出力項目の単位（例えば金額や得点で全て示せるとか）を揃えておく必要がある.

4．解析結果

4．1　数量化法の結果について

表1のdataから購入品目間の関係がpatternとして現れないか数量化法で解析した.

(1) 固有値と固有vector

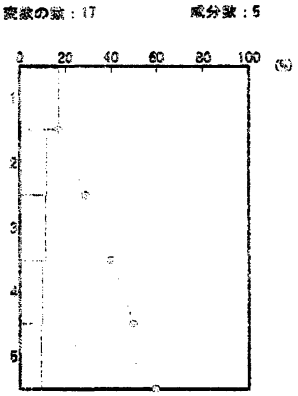

No	固有値	寄与率	累積寄与率
1	0.363	0.171	0.171
2	0.252	0.118	0.289
3	0.236	0.111	0.400
4	0.209	0.098	0.498
5	0.199	0.094	0.592
6	0.161	0.076	0.667
7	0.148	0.070	0.737
8	0.133	0.062	0.799
9	0.109	0.051	0.851
10	0.079	0.037	0.888
11	0.073	0.034	0.922
12	0.059	0.028	0.950
13	0.042	0.020	0.969
14	0.027	0.013	0.982
15	0.024	0.011	0.993
16	0.014	0.007	1.000

図1　固有値の出方

求めた固有値は図1である．通常，数量化法の固有値の出方はなだらかであるが，今回の解析結果もなだらかであり，patternがまとまる傾向はなさそうである.

表2　固有vectorの表

変数名	成分1	成分2	成分3	成分4	成分5
ｺｰﾋｰ	0.078	-0.146	-0.275	-0.402	0.101
紅茶	-0.241	-0.243	0.145	0.211	-0.161
ｺｰﾗ	-0.206	-0.146	0.307	-0.266	-0.237
ｼﾞｭｰｽ	0.112	0.253	0.007	0.086	-0.335
日本茶	0.498	-0.207	0.123	0.226	0.209
ｳｰﾛﾝ茶	-0.258	0.151	-0.503	0.208	0.495
ｽﾎﾟｰﾂ飲料	0.191	0.555	0.435	-0.006	0.347
ﾐﾙｸ	0.221	0.135	-0.422	-0.246	-0.241
ﾁｮｺﾚｰﾄ	0.049	0.288	-0.016	0.283	-0.054
ﾎﾟﾃﾄﾁｯﾌﾟｽ	-0.073	0.059	0.040	0.005	-0.003
ｱﾗﾚ	0.374	0.095	-0.175	0.268	-0.257
ﾊﾟﾝ	0.422	-0.031	0.004	-0.409	0.201
ﾋﾞｽｹｯﾄ	-0.113	-0.228	-0.104	0.025	0.386
ｹｰｷ	0.105	-0.271	-0.192	0.129	-0.179
ｸｯｷｰ	-0.273	0.205	-0.034	0.158	-0.054
和菓子	0.168	-0.423	0.229	0.294	0.165
ﾎﾟｯｷｰ	-0.168	0.010	0.199	-0.335	0.083

表2は，各成分の固有値に対する固有vectorの表である．これより，成分1は＋に日本茶と

お腹が膨れるようなﾊﾟﾝ，ｱﾗﾚが関係し，成分２は＋にｽﾎﾟｰﾂ飲料、－に和菓子となる．しかし，これらの購入 pattern の学生数は少なく特異な傾向である．その他の成分の意味については判明できなかった．

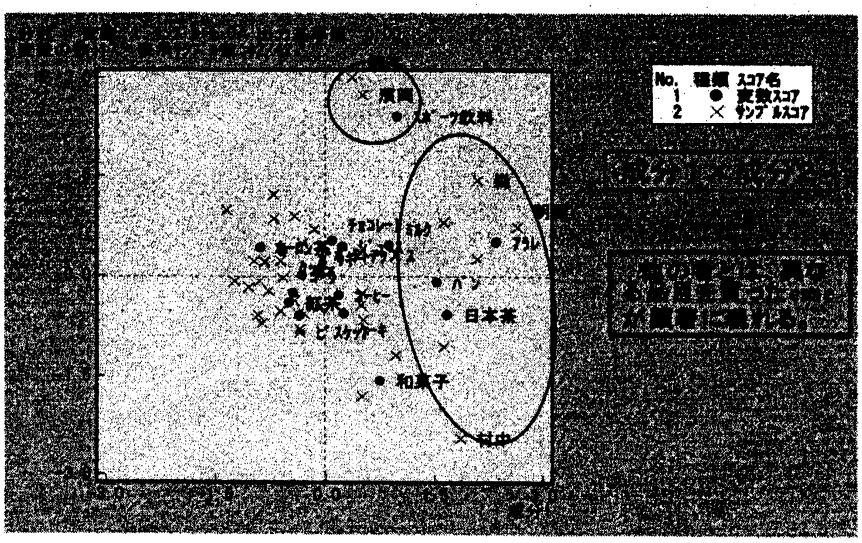

図２　品目(変数 score)と購入者(氏名 score)のＭａｐ

図２は成分１と成分２における購入者と購入された品目の score を同時布置にした図であるが，前述のように，他の者と異なる品目を購入した学生とその品目が外側に現れている．

(2)数量化法の特性について

以上より，数量化法の特性は

①従来から言われているように，特異な反応をする data に対して，非常に感度が高い．従って，特異な品目を購入する消費者の抽出には向くといえる．

②逆に，平均的に多い pattern 傾向を抽出するのには不適といえる．

③一般的に各成分の意味づけは難しいことが多く，各成分は数理理論上異なる成分を抽出しているにも拘わらず，固有 vector は重複して各成分に出てくる傾向にある．

４．２　品目間の独立性の検定結果(χ^2 検定)について

表３　品目間の関係表

変数名	ｺｰﾋｰ	紅茶	ｺｰﾗ	ｼﾞｭｰｽ	日本茶	ｳｰﾛﾝ茶	ｽﾎﾟｰﾂ飲料	ﾐﾙｸ	ﾁｮｺﾚｰﾄ	ﾎﾟﾃﾄﾁｯﾌﾟｽ	ｱﾗﾚ	ﾊﾟﾝ	ﾋﾞｽｹｯﾄ	ｹｰｷ	ｸｯｷｰ	和菓子	ﾎﾟｯｷｰ
ｺｰﾋｰ	-	3.055	0.000	0.000	0.086	0.086	1.615	1.816	1.235	1.615	1.050	0.875	1.235	0.223	0.438	0.138	0.000
紅茶	3.055	-	2.299	0.962	1.222	0.076	2.937	1.736	0.004	0.264	1.909	6.364*	0.877	1.462	0.795	1.329	0.127
ｺｰﾗ	0.000	2.299	-	1.167	2.800	2.800	2.423	1.211	0.667	2.423	1.575	0.259	1.287	3.008	0.656	0.092	5.477*
ｼﾞｭｰｽ	0.000	0.962	1.167	-	0.000	2.800	0.748	0.681	1.186	0.120	2.800	0.259	1.287	0.928	0.032	0.576	0.656
日本茶	0.086	1.222	2.800	0.000	-	1.680	0.646	0.045	0.020	0.646	10.500**	5.600*	0.124	0.557	6.300*	10.832**	2.800
ｳｰﾛﾝ茶	0.086	0.076	2.800	2.800	1.680	-	0.646	0.045	0.020	0.646	0.420	1.400	0.494	0.022	2.800	0.884	0.000
ｽﾎﾟｰﾂ飲料	1.615	2.937	2.423	0.748	0.646	0.646	-	0.437	0.920	0.249	0.162	0.957	0.760	1.448	0.120	0.340	0.120
ﾐﾙｸ	1.816	1.736	1.211	0.681	0.045	0.045	0.437	-	0.898	1.415	2.906	3.065	1.335	0.217	0.019	0.597	0.681
ﾁｮｺﾚｰﾄ	1.235	0.004	0.667	1.186	0.020	0.020	0.920	0.898	-	0.920	3.088	0.148	0.036	2.366	2.973	0.166	5.567*
ﾎﾟﾃﾄﾁｯﾌﾟｽ	1.615	0.264	2.423	0.120	0.646	0.646	0.249	1.415	0.920	-	0.162	7.239**	4.751*	0.009	0.120	2.126	0.748
ｱﾗﾚ	1.050	1.909	1.575	2.800	10.500**	0.420	0.162	2.906	3.088	0.162	-	2.188	0.494	0.356	1.575	0.221	2.800
ﾊﾟﾝ	0.875	6.364*	0.259	0.259	5.600*	1.400	0.957	3.065	0.148	7.239**	2.188	-	0.026	0.019	5.250*	0.414	0.146
ﾋﾞｽｹｯﾄ	1.235	0.877	1.287	1.287	0.124	0.494	0.760	1.335	0.036	4.751*	0.494	0.026	-	0.198	0.116	0.102	1.287
ｹｰｷ	0.223	1.462	3.008	0.928	0.557	0.022	1.448	0.217	2.366	0.009	0.356	0.019	0.198	-	3.008	0.751	2.683
ｸｯｷｰ	0.438	0.795	0.656	0.032	6.300*	2.800	0.120	0.019	2.973	0.120	1.575	5.250*	0.116	3.008	-	0.576	0.032
和菓子	0.138	1.329	0.092	0.576	10.832**	0.884	0.340	0.597	0.166	2.126	0.221	0.414	0.102	0.751	0.576	-	1.865
ﾎﾟｯｷｰ	0.000	0.127	5.477*	0.656	2.800	0.000	0.120	0.681	5.567*	0.748	2.800	0.148	1.287	2.683	0.032	1.865	-
性別	1.371	1.909	6.300*	0.700	0.034	9.909**	0.646	0.045	0.968	0.646	0.420	1.400	7.906**	0.557	2.800	0.221	0.000

さて，数量化の 0-1 反応 data を cross 集計して pattern の傾向を探るのが correspondence analysis である．そこで，個々の品目間の関係を表３のように求めた．即ち，correspondence analysis の特性を検討するに当たって，飲み物と食べ物(snack 菓子)の関連を探ることとした．

飲み物と食べ物(snack 菓子)の関係を cross 集計すると表４のようになった．

表４　飲み物と食べ物の cross 集計表

飲み物/ｽﾅｯｸ菓子	ﾁｮｺﾚｰﾄ	ﾎﾟﾃﾄﾁｯﾌﾟｽ	ｱﾗﾚ	ﾊﾟﾝ	ﾋﾞｽｹｯﾄ	ｹｰｷ	ｸｯｷｰ	和菓子	ﾎﾟｯｷｰ
ｺｰﾋｰ	4	12	0	3	4	5	5	1	8
紅茶	8	19	0	0	5	8	10	3	12
ｺｰﾗ	6	18	0	2	2	3	9	2	14
ｼﾞｭｰｽ	9	17	2	2	2	7	8	1	9
日本茶	3	6	2	3	1	3	0	3	2
ｳｰﾛﾝ茶	3	7	0	0	2	2	5	0	4
ｽﾎﾟｰﾂ飲料	2	3	0	1	0	0	1	0	2
ﾐﾙｸ	3	4	1	2	0	2	2	0	2

表４より，ﾎﾟﾃﾄﾁｯﾌﾟｽはよく購入され，その時の飲み物は紅茶，ｺｰﾗ，ｼﾞｭｰｽ，ｺｰﾋｰとなる．次いでﾎﾟｯｷｰがよく購入され，飲み物はｺｰﾗ，紅茶となる．逆にあまり購入されないのはｱﾗﾚ，ﾊﾟﾝ，和菓子であり，ｱﾗﾚの時の飲み物はｼﾞｭｰｽ，日本茶となる．ﾊﾟﾝのときはｺｰﾋｰ，日本茶となり，和菓子は日本茶，紅茶となっているが，これらは極めて例数が少ない．

表５は、表４を元に飲み物の品目と食べ物の品目とにおいて関係があるのかを χ^2 検定した結果を示している．

表５　飲み物と食べ物において個々品目間の独立性の検定結果（χ^2 検定）

飲み物/ｽﾅｯｸ菓子	ﾁｮｺﾚｰﾄ	ﾎﾟﾃﾄﾁｯﾌﾟｽ	ｱﾗﾚ	ﾊﾟﾝ	ﾋﾞｽｹｯﾄ	ｹｰｷ	ｸｯｷｰ	和菓子	ﾎﾟｯｷｰ
ｺｰﾋｰ	1.235	1.615	1.050	0.875	1.235	0.223	0.438	0.138	0.000
紅茶	0.004	0.264	1.909	6.364*	0.877	1.462	0.795	1.329	0.127
ｺｰﾗ	0.667	2.423	1.575	0.259	1.287	3.008	0.656	0.092	5.477*
ｼﾞｭｰｽ	1.186	0.120	2.800	0.259	1.287	0.928	0.032	0.576	0.656
日本茶	0.020	0.646	10.500**	5.600*	0.124	0.557	6.300*	10.832**	2.800
ｳｰﾛﾝ茶	0.020	0.646	0.420	1.400	0.494	0.022	2.800	0.884	0.000
ｽﾎﾟｰﾂ飲料	0.920	0.249	0.162	0.957	0.760	1.448	0.120	0.340	0.120
ﾐﾙｸ	0.898	1.415	2.906	3.065	1.335	0.217	0.019	0.597	0.681

各項目間では，ｱﾗﾚの時の飲み物は日本茶であり，和菓子の時も日本茶という関係は存在する結果となっている．しかし，例数は少ない．

ここで，全体の行の食べ物項目と列の飲み物項目との項目間が独立であるかどうかの検定を行った．行の数は 8，列の数は 9 であり，自由度 56 となり，χ_0^2 統計量＝51.185 となる．Ｐ値上側 0.657 で，全体の飲み物項目と食べ物項目間の頻度の出方においては独立であるという仮説は棄却されない．即ち，食べ物と飲み物においては関連がないとなる．

correspondence analysis の実施は，本来 χ^2 検定が有意になった場合に用いるべきであると考えるが，一般的には，このことは考慮されなく解析されている場合が多い．

4．3　correspondence analysis の結果について

χ^2 値では有意にならなかったが，correspondence analysis を実施した．その結果が表６である．表７は，食べ物品目と飲み物品目間の分布間距離を示す２次元までの score を求めたものである．この score は，３．１節の(8)および(9)式の距離尺度に相当する．

(1) 固有値と次元 score について

表６　Correspondence Analysis の解析結果

要約

次元	特異値	要約イナーシャ	カイ2乗	有意確率	イナーシャの寄与率		信頼特異値	
					説明	累積	標準偏差	相関 2
1	.323	.104			.593	.593	.067	-.054
2	.180	.032			.183	.776	.051	
3	.145	.021			.119	.895		
4	.116	.013			.077	.972		
5	.050	.003			.014	.986		
6	.043	.002			.011	.997		
7	.023	.001			.003	1.000		
要約合計		.176	51.185	.657[a]	1.000	1.000		

a. 自由度56

表７　元の Correspondence Analysis における各次元の score

購入品	1次元	2次元	層別
4ｺｰﾋｰ	0.087	-0.148	飲み物
1紅茶	0.348	-0.438	飲み物
2ｺｰﾗ	0.307	0.148	飲み物
3ｼﾞｭｰｽ	-0.121	0.229	飲み物
5日本茶	-1.616	-0.587	飲み物
6ｳｰﾛﾝ茶	0.623	0.052	飲み物
8ｽﾎﾟｰﾂ飲	-0.082	1.182	飲み物
7ﾐﾙｸ	-0.815	0.938	飲み物
dﾁｮｺﾚｰﾄ	-0.138	0.356	食べ物
aﾎﾟﾃﾄﾁｯﾌﾟ	0.083	0.039	食べ物
iｱﾗﾚ	-2.656	0.246	食べ物
gﾊﾟﾝ	-1.411	0.688	食べ物
fﾋﾞｽｹｯﾄ	0.405	-0.874	食べ物
eｹｰｷ	-0.200	-0.367	食べ物
cｸｯｷｰ	0.551	0.190	食べ物
h和菓子	-0.998	-1.503	食べ物
bﾎﾞｯｷｰ	0.325	0.102	食べ物

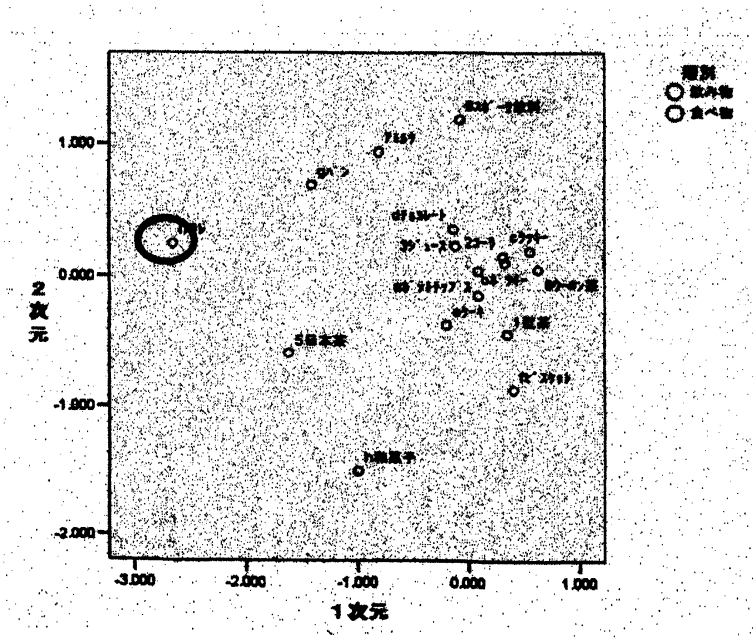

図３　元の Correspondence Analysis における飲み物と食べ物の同時布置

表７の各品目の score について，同時布置を描いたのが図３である．ﾎﾟﾃﾄﾁｯﾌﾟｽと紅茶やｺｰﾗ

は近く，ﾎﾞｯｷｰもその近くにある．独立性の検定では有意にならなかったが，表３で，品目間の関係があるとみなしたものは、やはり布置においても近い位置関係にある．しかし，各品目間においては，有意となったｱﾗﾚと日本茶との位置や和菓子の位置等は離れている．また、ｱﾗﾚの購入の際には日本茶とｼﾞｭｰｽとが同時購入されているにも拘わらず外側に現れて，反応数の少ないcaseの特徴として，数量化法と似た結果が，correspondence analysisにも表れている．

そこで，我々は，反応数を調整して，行と列とを同時布置で比較できるためのcorrespondence analysis距離尺度を提言する．

即ち，correspondence analysisの図示表現を，主成分分析またはbi-plot表現のような行列の近似を目的とするものに近づけるためには，座標表現を行うための行列として

$F = R^{1/2} U_K D_K$ ，$G = C^{1/2} V_K D_K$ を採用した．

即ちFの行vector f_i^Tの布置におけるf_iのEuclid相当の距離関係$\| f_i - f_j \|$は

$$\{\sum_{s=1}^{t}(\frac{p_{is}}{\sqrt{p_{i.}}\sqrt{p_{.s}}}-\frac{p_{js}}{\sqrt{p_{j.}}\sqrt{p_{.s}}})^2\}^{\frac{1}{2}} \qquad (10)$$

とおき，Gの行vector g_j^Tの布置におけるg_jのEuclid相当の距離関係$\| g_i - g_j \|$として

$$\{\sum_{s=1}^{m}(\frac{p_{si}}{\sqrt{p_{.i}}\sqrt{p_{s.}}}-\frac{p_{sj}}{\sqrt{p_{.j}}\sqrt{p_{s.}}})^2\}^{\frac{1}{2}} \qquad (11)$$

とおく．(10)，(11)式の分母を見て判るように，これは行と列とを反応数に応じて同じ重みで調整した距離尺度となっており，行と列は同じ距離にて同時に比較可能となる．

表８　我々が提言した距離尺度における各次元のscore

購入品	1次元	2次元	層別
4ｺｰﾋｰ	0.033	-0.056	飲み物
1紅茶	0.164	-0.207	飲み物
2ｺｰﾗ	0.135	0.065	飲み物
3ｼﾞｭｰｽ	-0.054	0.101	飲み物
5日本茶	-0.454	-0.165	飲み物
6ｳｰﾛﾝ茶	0.175	0.015	飲み物
8ｽﾎﾟｰﾂ飲料	-0.014	0.208	飲み物
7ﾐﾙｸ	-0.191	0.220	飲み物
dﾁｮｺﾚｰﾄ	-0.050	0.129	食べ物
aﾎﾟﾃﾄﾁｯﾌﾟｽ	0.045	0.021	食べ物
iｱﾗﾚ	-0.346	0.032	食べ物
gﾊﾟﾝ	-0.299	0.146	食べ物
fﾋﾞｽｹｯﾄ	0.095	-0.205	食べ物
eｹｰｷ	-0.642	-0.118	食べ物
cｸｯｷｰ	0.204	0.070	食べ物
h和菓子	-0.184	-0.277	食べ物
bﾎﾞｯｷｰ	0.139	0.044	食べ物

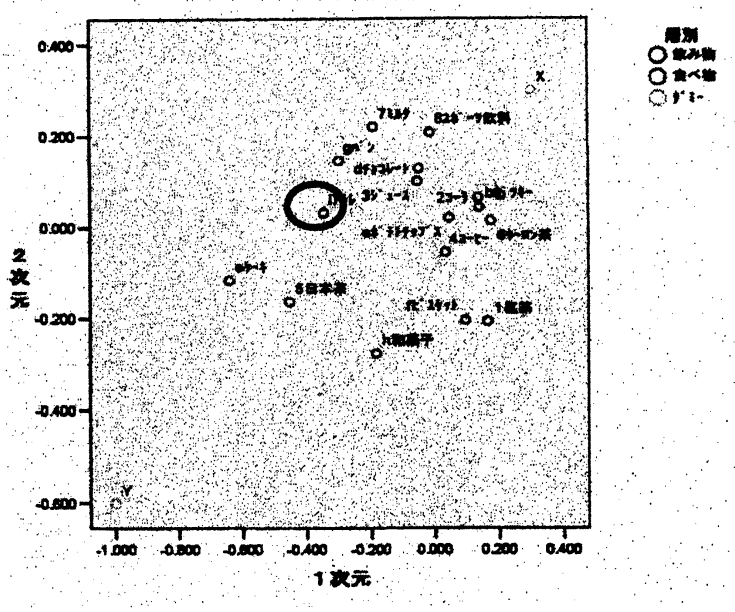

図４　我々が提言するcorrespondence analysisの距離尺度での同時布置

表８は，我々が提言した距離尺度の式(10)，(11)で求めたcorrespondence analysisの各品目

の２次元までの score を求めたものである．図４は，表８の同時布置を図示したものである．
○ｱﾗﾚの位置を見て判るように，ｱﾗﾚは反応数が少なかったので，元の方法では外側にあったが，その反応数により同じ weight で調整した我々の提言式を用いると，図３に比べて中の方へ移動している．そして，同時購入された日本茶とｼﾞｭｰｽと近くなり，その距離の balance が取れていることが判る．反応数が多いﾎﾟﾃﾄﾁｯﾌﾟｽとｺｰﾗの関係も図３に比べてより接近している．

今回の事例では，食べ物と飲み物の項目間の関係が有意でなかったが，χ^2 検定で従属関係がいえる事例においては，我々が提言した距離尺度により，関係のある品目はより近く，ないものはより遠くになると考えている．今後は，χ^2 検定で有意となる多品目間において我々の距離尺度の有効性を検証したい．

(2) correspondence analysis の特性について

以上より，correspondence analysis の特性をまとめると，

①固有値の出方は，数量化の方法よりも差がついて出る．今回の data 例では χ^2 検定は有意ではなかったので，飲み物と snack 菓子の関係は独立となった．

②しかし χ^2 検定で有意とならなくても，数量化法よりも全体的な項目間の傾向が出易い．χ^2 統計量に対応する固有値が導かれるので，行と列の関係が統計的に有意かが明確にできる．そして，独立であっても項目間の関係は同時布置に再現され易いので有用といえる．

③また，我々が提言した距離尺度にて同時布置を導けば，元の correspondence analysis の距離に比べて，反応数に応じた重みが均等化されるので，行も列も同じ距離にて比較することができる．より品目間の位置関係を視覚的に捉えるのに有効となる．

④平均的な傾向と特異な場合の関係も同時に表れるので，購入 data から何らかの情報を得るのには向いていると考えられる．

⑤逆に，χ^2 統計量が独立でも，あたかも関係があるかのように結果を見てしまう危険もある．

以上は，消費者購買 data から全体的な傾向を抽出する解析法であった．次に部分的な傾向を抽出方法として，今話題の market basket analysis を実施する．

４．４　market basket analysis の結果について

(1)　market basket analysis について

market basket analysis は特定の顧客が買う品物間の関連を測ることを言う．market basket と言う呼び名は，顧客が食料品店で shopping cart の「market basket」に一緒に入れた商品群はどのようなものになるかを探ることから生まれた data mining の一つの技法である．

(2)　相関 rule について

market basket analysis[3]では，全 data を取り扱う model の概念はなく，data set の部分集合，例えば，変数の部分集合，観測値の部分集合に注目していくことから始まる．

まず pattern から，商品(項目)間の関連を捉える相関 rule について説明する．

pattern[4]とは，database 項目に関する２値の data 行列において，行として transaction，列として項目を置き，pattern が

$$\alpha = (\mathrm{Age} < 30 \wedge \mathrm{Income} > 100)$$

$$\wedge : \mathrm{AND}$$

$$\beta = (\mathrm{Gender} = \mathrm{male} \vee \mathrm{Education} = \mathrm{High})$$

$$\vee : \mathrm{OR}$$

なら，相関 rule として，$\alpha \rightarrow \beta$ なら，α と β が一緒に発生すると定義する．即ち，α が起れば，

βも起ると考える．" if α occurs, then β also occurs, if condition, then result." である．ここで，patternを定式化する．

(a) 2値変数$A_1, A_2, \cdots, A_p$としたとき，項目A_iが発生 $\Leftrightarrow$ $A_i = 1$とおくと，patternの定義は，

$$\text{pattern } A = (A_{j1} = 1 \wedge, \cdots, \wedge A_{jk} = 1) \tag{12}$$

相関rule $A \rightarrow B$は，$$(A_{j1} = 1 \wedge, \cdots, \wedge A_{jk} = 1) \rightarrow A_{jk+1} \tag{13}$$

となる．この時の$k+1$をorder(位数、順位)と呼ぶ．

例：位数3の相関rule(Milk∧Tea) →Biscuits

(b)評価尺度としては，(14)式の支持度と(15)式の信頼度を定める．

支持度 $$\text{support}\{A \rightarrow B\} = \frac{N_{A \rightarrow B}}{N} \tag{14}$$

$N_{\bullet}$：pattern$_{\bullet}$を持つtransactionの個数

N ：transactionの全個数

信頼度 $$\text{confidence}\{A \rightarrow B\} = \frac{N_{A \rightarrow B}}{N_{A \rightarrow A}} = \frac{\text{support}\{A \rightarrow B\}}{\text{support}\{A\}} \tag{15}$$

$$\text{Lift}\{A \rightarrow B\} = \frac{\text{confidence}\{A \rightarrow B\}}{\text{support}\{B\}} = \frac{\text{support}\{A \rightarrow B\}}{\text{support}\{A\}\text{support}\{B\}} \tag{16}$$

(c)softwareとしてのAprioriの計算原理は，

・頻出item集合(最小支持度を越えるitem集合)を見つける．

・頻出item集合を用いて相関ruleを求める．

・計算原理は，頻出item集合(最小支持度を越えるitem集合)の任意の部分集合は再び頻出item集合である．

(3) Apriori アルゴリズムについて

(a)ここで，C_k：大きさkの候補item集合，L_k：大きさkの頻出item集合，とする．

Joint Step：L_{k-1}を自分自身とjoinして，C_kを生成する．

Prune Step：頻出でない任意の(k－1)-item集合はk-item集合の部分集合にはなれない．

(b)相関ruleを求める．

Step 1：各頻出item集合mに対して、それをすべての方法で2つの空でない部分集合 s, m-sに分割する．

Step 2：rule 候補 s ⇒ (m-s)に対する信頼度を求める．もしこの値が最小信頼度よりも大きいか等しければ，それを相関ruleとする．

(c)上記の(14)，(15)式から，支持度及び信頼度を計算する．

(d)相関ruleにおいて，支持度の高いpatternを発見する．

(4) 表1データのMarket basket analysisの結果について

第1段階：表1の購入品を記号化して，表9のようにする．

表９　表１の data の購入品を記号化して品目の多い順に並べた data

	a	b	1	2	3	c	d	4	e	f	5	6	g	7	h	8	i		
	ﾎﾟﾃﾄﾁｯﾌﾟｽ	ﾎﾟｯｷｰ	紅茶	ｺｰﾗ	ｼﾞｭｰｽ	ｸｯｷｰ	ﾁｮｺﾚｰﾄ	ｺｰﾋｰ	ｹｰｷ	ﾋﾞｽｹｯﾄ	日本茶	ｳｰﾛﾝ茶	ﾊﾟﾝ	ﾐﾙｸ	和菓子	ｽﾎﾟｰﾂ飲料	ｱﾗﾚ		
藤田	1.0	1.0	1.0	1.0	1.0	0.0	0.0	1.0	1.0	1.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	8	ab1234ef
伊藤	1.0	1.0	1.0	1.0	1.0	1.0	0.0	1.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	7	ab123c4
赤木	1.0	1.0	0.0	1.0	1.0	1.0	0.0	1.0	0.0	0.0	0.0	0.0	0.0	1.0	0.0	0.0	0.0	7	ab23c47
谷村瞳	1.0	0.0	1.0	0.0	0.0	1.0	1.0	0.0	1.0	0.0	0.0	1.0	0.0	1.0	0.0	0.0	0.0	7	a1cde67
明尾	1.0	0.0	0.0	0.0	1.0	0.0	1.0	0.0	0.0	0.0	1.0	0.0	1.0	1.0	0.0	0.0	1.0	7	a3d5g7i
松崎	1.0	1.0	1.0	1.0	1.0	1.0	1.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	7	ab123cd
森下	1.0	0.0	1.0	0.0	1.0	0.0	1.0	0.0	1.0	0.0	1.0	0.0	0.0	0.0	1.0	0.0	0.0	7	a13de5h
水田	1.0	1.0	1.0	1.0	0.0	0.0	0.0	0.0	0.0	0.0	1.0	0.0	0.0	0.0	1.0	0.0	0.0	6	ab125h
新井	1.0	0.0	1.0	1.0	0.0	1.0	1.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	1.0	0.0	0.0	6	a12cdh
橋本	1.0	1.0	0.0	0.0	1.0	1.0	1.0	0.0	0.0	0.0	0.0	1.0	0.0	0.0	0.0	0.0	0.0	6	ab3cd6
大塚布佑	1.0	1.0	1.0	0.0	0.0	0.0	0.0	0.0	1.0	1.0	0.0	1.0	0.0	0.0	0.0	0.0	0.0	6	ab1ef6
国宝	1.0	1.0	1.0	0.0	1.0	0.0	0.0	1.0	1.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	6	ab134e
岩本	1.0	0.0	0.0	0.0	1.0	0.0	1.0	0.0	1.0	0.0	1.0	0.0	0.0	0.0	0.0	0.0	1.0	6	a3de5i
岡本	1.0	1.0	0.0	1.0	0.0	1.0	0.0	1.0	0.0	0.0	0.0	1.0	0.0	0.0	0.0	0.0	0.0	6	ab2c46
村中	0.0	0.0	0.0	0.0	0.0	0.0	0.0	1.0	1.0	1.0	1.0	0.0	1.0	0.0	1.0	0.0	0.0	6	4ef5gh
大滝	1.0	1.0	1.0	0.0	0.0	1.0	0.0	0.0	0.0	1.0	0.0	1.0	0.0	0.0	0.0	0.0	0.0	6	ab1cf6
内田	1.0	1.0	0.0	1.0	0.0	0.0	1.0	1.0	0.0	1.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	6	ab2d4f
西口	1.0	1.0	1.0	1.0	0.0	1.0	1.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	6	ab12cd
森	1.0	1.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	1.0	0.0	1.0	0.0	0.0	1.0	0.0	5	ab5g8
小澤	1.0	1.0	0.0	0.0	0.0	0.0	0.0	1.0	1.0	0.0	0.0	0.0	0.0	1.0	0.0	0.0	0.0	5	ab4e7
	a	b	1	2	3	c	d	4	e	f	5	6	g	7	h	8	i		
濱岡	1.0	1.0	0.0	0.0	1.0	0.0	1.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	1.0	0.0	5	ab3d8
野田	1.0	0.0	0.0	0.0	1.0	1.0	0.0	1.0	1.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	5	a3c4e
近藤	1.0	0.0	1.0	1.0	0.0	1.0	1.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	5	a12cd
八木	1.0	1.0	0.0	1.0	0.0	0.0	0.0	1.0	0.0	0.0	0.0	0.0	1.0	0.0	0.0	0.0	0.0	5	ab24g
錦木	1.0	0.0	0.0	0.0	1.0	1.0	1.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	1.0	0.0	5	a3cd8
中塩	1.0	0.0	1.0	1.0	1.0	0.0	0.0	0.0	1.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	5	a123e
井村	1.0	1.0	0.0	0.0	1.0	1.0	0.0	0.0	0.0	1.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	5	ab3cf
佐藤	1.0	1.0	1.0	1.0	0.0	1.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	5	ab12c
長畑	1.0	1.0	0.0	1.0	0.0	0.0	0.0	0.0	1.0	0.0	0.0	0.0	1.0	0.0	0.0	0.0	0.0	5	ab2eg
岡内	0.0	1.0	1.0	0.0	0.0	1.0	1.0	0.0	0.0	1.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	5	b1cdf
有吉	1.0	0.0	1.0	0.0	0.0	0.0	1.0	1.0	0.0	1.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	5	a1d4f
畑岡	1.0	0.0	0.0	1.0	1.0	1.0	1.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	5	a23cd
中澤D	1.0	0.0	0.0	0.0	0.0	1.0	1.0	1.0	0.0	0.0	0.0	1.0	0.0	0.0	0.0	0.0	0.0	5	acd46
浅田	0.0	0.0	0.0	0.0	1.0	0.0	1.0	1.0	0.0	0.0	0.0	0.0	1.0	1.0	0.0	0.0	0.0	5	3d4g7
穴吹	1.0	0.0	1.0	0.0	1.0	0.0	0.0	0.0	1.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	4	a13e
天野	1.0	1.0	1.0	1.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	4	ab12
平田	1.0	1.0	1.0	1.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	4	ab12
石黒	1.0	0.0	1.0	0.0	0.0	1.0	0.0	0.0	1.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	4	a1ce
江尻	1.0	1.0	0.0	1.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	3	ab2
滝下	1.0	1.0	0.0	0.0	1.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	3	ab3
竹元	1.0	0.0	0.0	0.0	0.0	0.0	0.0	1.0	0.0	0.0	1.0	0.0	0.0	0.0	0.0	0.0	0.0	3	a4
長濱	1.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	1.0	0.0	0.0	0.0	0.0	0.0	2	a6

第２段階：表１０より各購入品の単独の支持度を求める.

表１０　各購入品別の全体に対する支持度

TID	TID
ab1234ef	a3c4e
ab123c4	a12cd
ab23c47	ab24g
a1cde67	a3cd8
a3d5g7i	a123e
ab123cd	ab3cf
a13de5h	ab12c
ab125h	ab2eg
a12cdh	b1cdf
ab3cd6	a1d4f
ab1ef6	a23cd
ab134e	acd46
a3de5i	3d4g7
ab2c46	a13e
4ef5gh	ab12
ab1cf6	ab12
ab2d4f	a1ce
ab12cd	ab2
ab5g8	ab3
ab4e7	a4
ab3d8	a6

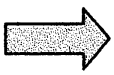

記号	Itemset	C_1, L_1	支持度
a	ﾎﾟﾃﾄﾁｯﾌﾟｽ	39	0.929
b	ﾎﾟｯｷｰ	24	0.571
1	紅茶	20	0.476
2	ｺｰﾗ	18	0.429
3	ｼﾞｭｰｽ	18	0.429
c	ｸｯｷｰ	18	0.429
d	ﾁｮｺﾚｰﾄ	17	0.405
4	ｺｰﾋｰ	14	0.333
e	ｹｰｷ	13	0.310
f	ﾋﾞｽｹｯﾄ	8	0.190
5	日本茶	7	0.167
6	ｳｰﾛﾝ茶	7	0.167
g	ﾊﾟﾝ	6	0.143
7	ﾐﾙｸ	5	0.119
h	和菓子	4	0.095
8	ｽﾎﾟｰﾂ飲料	3	0.071
i	ｱﾗﾚ	2	0.048
		42	

表１０より，学生の談話会では，aﾎﾟﾃﾄﾁｯﾌﾟｽの支持度は 0.929 であり，aﾎﾟﾃﾄﾁｯﾌﾟｽは殆ど購入

されることが解る.

第２段階： 相関 rule, 一つの品目Ａ→Ｂの支持度を求める.

表１０　相関 rule 支持度

記号	内容	N
a	ﾎﾟﾃﾄﾁｯﾌﾟｽ	39
b	ﾎﾟｯｷｰ	24
1	紅茶	20
2	ｺｰﾗ	18
3	ｼﾞｭｰｽ	18
c	ｸｯｷｰ	18
d	ﾁｮｺﾚｰﾄ	17
4	ｺｰﾋｰ	14
e	ｹｰｷ	13

Itemset	$C_2.L_2$	支持度	Itemset	$C_2.L_2$	支持度
ab	23	0.590	1d	8	0.400
a1	19	0.487	14	3	0.150
a2	19	0.487	1e	8	0.400
a3	17	0.436	23	6	0.333
ac	16	0.410	2c	9	0.500
ad	13	0.333	2d	6	0.333
a4	12	0.308	24	5	0.278
ae	12	0.308	2e	4	0.222
b1	11	0.458	3c	9	0.500
b2	14	0.583	3d	9	0.500
b3	9	0.375	34	6	0.333
bc	9	0.375	3e	6	0.333
bd	6	0.250	cd	9	0.500
b4	8	0.333	c4	5	0.278
be	4	0.167	ce	3	0.167
12	11	0.550	d4	3	0.176
13	7	0.350	de	3	0.176
1c	10	0.500	4e	3	0.214

aﾎﾟﾃﾄﾁｯﾌﾟｽが購入されると，bﾎﾟｯｷｰの支持度 0.590, 同様に，1 紅茶 0.487, 2 ｺｰﾗ 0.487, 3 ｼﾞｭｰｽ 0.436, c ｸｯｷｰ 0.410 である．他に，bﾎﾟｯｷｰが購入されると，2 ｺｰﾗ 0.583, 1 紅茶 0.458 の支持度となる．これらの pattern は，表４の cross 集計の結果と同じようになっている.

第３段階：相関 rule, 二つの品目Ａ，Ｂが購入されるとＣが購入されるという支持度を求める.

表１１　相関 rule A,B→Ｃの支持度

記号	内容	N
a	ﾎﾟﾃﾄﾁｯﾌﾟｽ	39
b	ﾎﾟｯｷｰ	24
1	紅茶	20
2	ｺｰﾗ	18
3	ｼﾞｭｰｽ	18
c	ｸｯｷｰ	18
d	ﾁｮｺﾚｰﾄ	17
e	ｹｰｷ	13

支持率の MAX導出

Itemset	$C_2.L_2$	Itemset	$C_2.L_2$
ab	23	1d	8
a1	19	14	3
a2	19	1e	8
a3	17	23	6
ac	16	2c	9
ad	13	2d	6
a4	12	24	5
ae	12	2e	4
b1	11	3c	9
b2	14	3d	9
b3	9	34	6
bc	9	3e	6
bd	6	cd	9
b4	8	c4	5
be	4	ce	3
12	11	d4	3
13	7	de	3
1c	10	4e	3

Itemset	$C_3.L_3$	前提	支持度	Itemset	$C_3.L_3$	前提	支持度
ab1	11	b1⇒e	1.000	b2d	1	—	—
ab2	14	b2⇒e	1.000	b2e	1	—	—
ab3	9	b3⇒e	1.000	b3c	5	bc⇒3	0.556
abc	9	bc⇒e	1.000	b3d	3	bd⇒3	0.500
abd	5	bd⇒e	0.833	b3e	1	—	—
abe	3	be⇒e	0.750	bcd	3	bd⇒e	0.500
a12	11	12⇒e	1.000	bce	0	—	—
a13	7	13⇒e	1.000	bde	0	—	—
a1c	8	1c⇒e	0.727	123	4	23⇒1	0.667
a1d	7	1d⇒e	0.875	12c	6	2c⇒1	0.667
a1e	7	1e⇒e	0.875	12d	4	2d⇒1	0.667
a23	6	23⇒e	1.000	12e	2	2e⇒1	0.500
a2c	9	2c⇒e	1.000	13c	1	—	—
a2d	4	2d⇒e	0.667	13d	2	13⇒d	0.286
a2e	3	2e⇒e	0.750	13e	5	3e⇒1	0.833
a3c	7	3c⇒e	0.778	1cd	6	cd⇒1	0.667
a3d	8	3d⇒e	0.889	1ce	2	ce⇒1	0.667
a3e	6	3e⇒e	1.000	1de	2	de⇒1	0.667
acd	8	cd⇒e	0.889	23c	4	23⇒c	0.667
ace	3	ce⇒e	1.000	23d	2	2d⇒3	0.333
ade	2	de⇒e	0.667	23e	2	2e⇒3	0.500
b12	8	b1⇒2	0.727	2cd	5	2d⇒c	0.833
b13	4	13⇒b	0.571	2ce	0	—	—
b1c	6	bc⇒1	0.667	2de	0	—	—
b1d	3	bd⇒1	0.500	3cd	4	cd⇒3	0.444
b1e	2	be⇒1	0.500	3ce	1	—	—
b23	3	23⇒b	0.500	3de	2	de⇒3	0.667
b2c	5	2c⇒b	0.556	cde	1	—	—

表１１より，bﾎﾟｯｷｰと１紅茶，bﾎﾟｯｷｰと２ｺｰﾗ，bﾎﾟｯｷｰと３ｼﾞｭｰｽ，bﾎﾟｯｷｰとｃｸｯｷｰが購入された時は，aﾎﾟﾃﾄﾁｯﾌﾟｽの支持度が1.000で必ず購入される．また，１紅茶と２ｺｰﾗ，１紅茶と３ｼﾞｭｰｽ，２ｺｰﾗと３ｼﾞｭｰｽ，２ｺｰﾗとｃｸｯｷｰ，３ｼﾞｭｰｽとｅｹｰｷ，ｃｸｯｷｰとｅｹｰｷが購入された時も，aﾎﾟﾃﾄﾁｯﾌﾟｽの支持度が1.000で必ず購入されるというpatternが見つけられる．これらのpatternは，表４からでは得られない．

以下同様にして，market basket analysisでは、組合せを多くして，新たなpatternを探索することができる．

別の段階：例数は少ないが，特異な購入品であるｈ和菓子に着目してpatternを考える．

表１２　和菓子に着目したpatternの表

記号	Item	N
a	ﾎﾟﾃﾄﾁｯﾌﾟｽ	39
b	ﾎﾟｯｷｰ	24
1	紅茶	20
2	ｺｰﾗ	18
3	ｼﾞｭｰｽ	18
c	ｸｯｷｰ	18
d	ﾁｮｺﾚｰﾄ	17
4	ｺｰﾋｰ	14
e	ｹｰｷ	13
f	ﾋﾞｽｹｯﾄ	8
5	日本茶	7
6	ｳｰﾛﾝ茶	7
g	ﾊﾟﾝ	6
7	ﾐﾙｸ	5
h	和菓子	4
8	ｽﾎﾟｰﾂ飲料	3
i	ｱﾗﾚ	2

TID	TID
ab1234ef	a3c4e
ab123c4	a12cd
ab23c47	ab24g
a1cde67	a3cd8
a3d5g7i	a123e
ab123cd	ab3cf
a13de5h	ab12c
ab125h	ab2eg
a12cdh	b1cdf
ab3cd6	a1d4f
ab1ef6	a23cd
ab134e	acd46
a3de5i	3d4g7
ab2c46	a13e
4ef5gh	ab12
ab1cf6	ab12
ab2d4f	a1ce
ab12cd	ab2
ab5g8	ab3
ab4e7	a4
ab3d8	a6

Itemset		前提	支持度
5h	3	h⇒5	0.750
ah	3	h⇒a	0.750
1h	3	h⇒1	0.750
a1h	3	1h⇒a	1.000

１紅茶とｈ和菓子が購入されるとaﾎﾟﾃﾄﾁｯﾌﾟｽの支持度は1.000となり必ず同時に購入される．また，ｈ和菓子が購入されると，５日本茶，aﾎﾟﾃﾄﾁｯﾌﾟｽ，１紅茶の支持度は0.750のpatternとなる．表４の結果に，加えて他の品目が加わり新たな情報を得ることができる．

このようにmarket basket analysisを用いれば，組合せを幾つも考えて，支持度の高いpatternを探索していくことができる．そして，ある品目間の相関ruleには，その関連性が理解できる場合と，理解できない場合とが出てくる．data miningでは，後者の発見が大切なわけであるが，偽相関のような場合も考えられ，更に深く考察することを忘れてはならない．

(5) market basket analysisの特性について

以上より，market basket analysisの特性をまとめると，

①二つ以上の同時購買に対する他の品目の購買関連を探るのに適している．

②部分最適解をいろんな切口から求められ，新しい組合せによるpattern の発見に役立つ．

③そして，既成の関係や概念を捨てなければならないような結果が多く出てくる．従って，結果については仮説実験を行い，確認する必要がある．

④部分の最適解であるので，既成の概念を逸脱することが多い．従って，短期的な傾向であるとも考えられるので，常に傾向の変化が生じることにも注意を払う必要がいる．

4．まとめ

消費者の購買 data から，どのような情報が得られるか，各手法の特性を活かして行う解析のあり方について検討した．その結果，

①特異な購買 pattern を抽出するのには数量化３類が有効である．

②行列間の関連(snack 菓子と飲み物，商品とその購入者の特徴等)を mapping して考察するのには correspondence analysis がよい．しかし，correspondence Analysis は，結局，行と列間の内積の情報を取っていることであり，χ^2 統計量の考え方と同じである．従って，行と列間の関係が有意となる case に適用するのが好ましい．よく correspondence analysis の適用例として紹介されている Greenace(1984)の喫煙習慣の例[5]は χ^2 統計量が有意とならなく不適切な例である．適切な適用例[6]は他にもあるので，今後はそのような例を紹介すべきである．また，行と列の項目で，項目に反応する例数が極端に少ない場合などには，今回提言した我々の行と列とを同じ重みで調整した距離尺度を用いるのがよい．提言した距離尺度を用いれば，行と列とを同じ距離尺度で同時に比較できる．

③品目の組合せが多い場合については，その相関有無の pattern 情報を抽出するのには，market basket analysis が適する．しかし，その関係の因果については，仮説を置いて確認を行うことも忘れてはならない．安易に結果を利用すると短期的な現象にしかすぎない場合もあるので注意が必要である．market basket analysis は部分解であり，その部分解から関連する次の解を得る姿勢が大切である．

今後は，行と列間の関連がある事例において，我々が提言している correspondence analysis の距離尺度が有効性であることを確認したい．また，ある商品を購入する顧客層を特定化していく decision tree[7]による分類手法も加えて，market basket analysis と decision tree との組合せによる行と列間の関連付け法と correspondence analysis による行と列間の捉え方法との違いについての研究を進めていきたい．

参考文献

[1]Isogai.T and Noguchi.H., " Singular value decomposition and the application", Journal of Social Science Research, Osaka University, No.40, (1992),pp.63-101.

[2]Benzecri,J.P., "Statistical analysis as a tool to make patterns emerge from data", In Methodologies of Pattern Recognition (Watanabe.S, ed, New York: Academic (1969)), pp.35-60.

[3]Pralo Giudici., "Applied Data Mining", Principles of Data Mining MIT Press, Cambridge MA, Wiley, (2003).

[4]Hand, Mannila and Smyth, "Principles of Data Mining, MIT Press, Cambridge MA, (2001).

[5]Greenace,M.J., "Theory and Application of correspondence analysis", London, Academic,(1984).

[6]Hair, Anderson, Tatham, Black,, " Multivariate Data Analysis", Fifth Edition, Prentice Hall, (1998).

[7]Rissanen.J., "Stochastic complexity in learning", Jr. Computer System and Sciences,55(1), (1997), pp.89-95.