多次元データの処理分析　No.6

クラスター分析(2)

統計数理研究所
大隅　昇

6.　階層的分類法に関する若干の注意

前回は計量データを例にして、いくつかの階層的手法を紹介した。このとき、(個体)×(変数)の形で与えられたデータ行列をもとに、適当な距離または類似度を任意に定めて、クラスタリングを行った。しかし、この種の手法の最大の特徴は、もっと広範囲のデータの取り扱いが可能である点にある。つまり、n 個の分類対象の任意の対、i と j との対象間のつながりを表す距離・類似度が、単にある関連の度合を表す数量としてしか与えられない場合にも利用できるのである。この点はMDSと非常に類似している。たとえば好き嫌いの程度とか、布地の肌理の程度を感触で判断し、これを言葉で示すとか、調味料を味覚により順位づけするとか……、さまざまの場面でこうしたデータが現れる。こうした場合にえられる対象間の距離や類似度はきわめてあいまいなものとなり、メトリックな性質が保存されているかどうかも疑わしい。つまり、現実のデータは距離の公理を満足するようなうまいものばかりではないことが多い。こうしたデータが分析の対象として与えられた場合でも、クラスタリングは可能であろうか？ 答えは可で、ある種の方法はむしろこうした場面でこそ偉力を発揮するものすらある。その代表的なものはグラフ理論的な方法やMDSに近い考え方を利用する方法である。実はすでに紹介した Single-linkage 法(SL法)や Complete-linkage 法(CL法)などはその典型的なもので、名称自体がグラフ理論に関連してつけられたものである。心理学、社会学、生物学などの分野の研究の中にはこうしたものに関連したものも多く、1つの領域を形成している。こうした手法は分類自体よりも個体間の関係、親近性を樹木図やグラフ（たとえば Minimal Spanning Tree : MST）を借りて表現し、これを観察することで情報を引き出す点に主眼があるといってもよい。したがって、こうした記述情報から読みとる内容も精密なものではなく、大まかな見当をつける道具としての役割が重きをなす。もちろん、手法それぞれに限界があるのはいうまでもないことで、使い方には十分な注意がいる。

7.　クラスター数の目安

与えられた距離がユークリッド距離のようにメトリックな性質を持ち、しかも原則として(個体)×(変数)の原データ行列が利用できる、さらにクラスターの性格をある程度仮定できるとき、クラスター数の目安をつける方法がいくつか考えられる。1組のデータが与えられ、これを適当な算法で計算すると1つの答えがえられる。階層的分類法の答えは樹木図である。最後は1つのクラスター(つまり全データ)となってしまうので、利用者はクラスター数を適当に決めねばならない。しかし、なにか基準を用意してクラスター数の目安はつけられないものか。もちろん、クラスター数を決めることにそれほどこだわる必要があるかという問いに対して、明確に必要であると答える強い根

拠があるわけではない。むしろ利用者の目的に応じて適宜与えることが良い方策であることも多いであろう。しかし、分析にあたって、ある程度客観的にデータの傾向を知っておくことは大切であり、またこっそりと知っておく手段が欲しいというのも心情である。

まず「クラスターとは何か」をある程度きめてかかる必要があり、それによって基準がいろいろ考えられようが、ここではクラスター内のバラツキを、分散（あるいは平方和）のような簡単な統計量ではかることとし、次の分散比による基準を使うことにしよう（このほか、たくさんのものが提案されているが代表例としてここでは次の2つの基準を考える）。

（I） Beale の F 値

$$F(k_1,\ k_2)=\frac{R(k_1)-R(k_2)}{R(k_2)}\ /\ A\quad (k_1<k_2)$$

ここで、$R(k)$: クラスター数 k のときのクラスター内平方和の総和

$$A=\frac{n-k_1}{n-k_2}\left(\frac{k_2}{k_1}\right)^{\frac{2}{m}}-1$$

これを自由度が $d.f.=m(k_2-k_1),\ m(n-k_2)$ の F 分布とみて、F 値が有意のとき k_1 個から k_2 個にクラスター数を増やしたことに意味があるとし、k_2 個を採用する。 実際には検定そのものよりもクラスター数をかえたときの $F(k_1,\ k_2)$ の変化を追って値が大きく増えるところをさがすのである。この量の特徴は、クラスター数を変えたときの変化量を表していることと、次元数 m の情報が取り入れられている点にある。

（II） 分散比基準

$$C(k)=\left(\frac{BGSS}{k-1}\right)/\left(\frac{WGSS}{n-k}\right)$$

（ここで、$WGSS$ はクラスター内平方和の総和、$BGSS$ はクラスター間平方和を表す。）

データが与えられると、その全平方和（TSS）は、クラスター数を k としたとき、クラスター内平方和（$WGSS$）とクラスター間平方和($BGSS$)の和としてあらわせる。つまり、$TSS=WGSS+BGSS$ となるから、k をかえながら、$C(k)$ の値を追ってゆくと、ある k_1 から k_2 にかわったところで、その変化量が大きいところを、クラスター数が有意にかわったと判定することができる。分散分析の検定の考えを借用したものである。

性質が相異なる SL法、CL法の2つの方法を使って上の基準を比較してみよう。前述のようにこれらの方法はグラフ理論との関わりが強い方法であり、統計的な意味でのバラツキ、たとえば分散、

（表1）

日・曜日		時間		個体番号	入店者数(人/時)	売上金額(千円/時)	金銭出納機回数(回/時)	X_1、X_2、X_3 をカテゴリー化したデータ		
日	コード	時間	コード		X_1	X_2	X_3	X_1	X_2	X_3
12/13(月)	1	10	1	1	524	1343	332	1	1	1
	1	11	2	2	900	1998	456	2	2	2
	1	12	3	3	1728	2525	964	3	2	4
	1	13	4	4	1254	1971	676	2	2	3
	1	14	5	5	1211	2491	819	2	2	4
	1	15	6	6	1287	2494	730	2	2	3
	1	16	7	7	938	2375	714	2	2	3
	1	17	8	8	329	1369	379	1	1	1
12/17(土)	2	10	1	9	566	1489	318	1	1	1
	2	11	2	10	759	2624	514	2	2	2
	2	12	3	11	1114	1715	694	2	2	3
	2	13	4	12	1421	3454	929	3	3	4
	2	14	5	13	1577	3110	962	3	3	4
	2	15	6	14	1500	3683	1049	3	3	4
	2	16	7	15	·1146	3303	932	2	3	4
	2	17	8	16	336	837	292	1	1	1
	2	18	9	17	173	804	260	1	1	1
[illegible]	3	10	1	18	609	1138	317	1	1	1
	3	11	2	19	888	1508	446	2	2	2
	3	12	3	20	1724	2370	919	3	2	3
	3	13	4	21	1207	2152	712	2	2	3
	3	14	5	22	1222	3103	806	2	3	4
	3	15	6	23	1291	2460	892	2	2	4
	3	16	7	24	914	2080	655	2	2	3
	3	17	8	25	312	826	282	1	1	1
	3	18	9	26	225	651	198	1	1	1
平均 標準偏差 変動係数					$m_1=967.5$ $s_1=468.96$ $CV_1=0.485$	$m_2=2072.0$ $s_2=866.4$ $CV_2=0.418$	$m_3=624.9$ $S_3=269.1$ $CV_3=0.431$	$(X_1\geqq 650)=1$ $(650<X_1<1300)=2$ $(X_1\geqq 1300)=3$	$(X_2\leqq 1500)=1$ $(1500<X_2<3000)=2$ $(X_2\geqq 3000)=3$	$(X_3\leqq 400)=1$ $(400<X_3\leqq 600)=2$ $(600<X_3<800)=3$ $X_3\geqq 800)=4$

平方和、などを考えに入れたクラスター化の方法ではない。むしろ対象間の結合情報（結合している、いない）を頼りに分類を行うのである。つまりここでの試みはグラフ論的な手法によって作られるクラスター化の履歴を利用し、統計的なバラツキの基準を用いて評価する、両者の好ましい性質をうまくとり入れた折衷型、あるいはハイブリッドな方式とでも名づけられる考え方である。

すでに利用してきたデータに２つの方法を適用し、各クラスターごとに上の２つの基準を計算してまとめたものが（図１）である。単純な分散比 $C(k)$ はクラスター数が k_1 から k_2（ここでは $k_2=k_1+1$）に変化したときの変化量に意味がある。つまり大きく増加したときが有意であるとみなされ、クラスター数の候補となる。ＳＬ法では

(図2-a)SL法による分類(k=5)

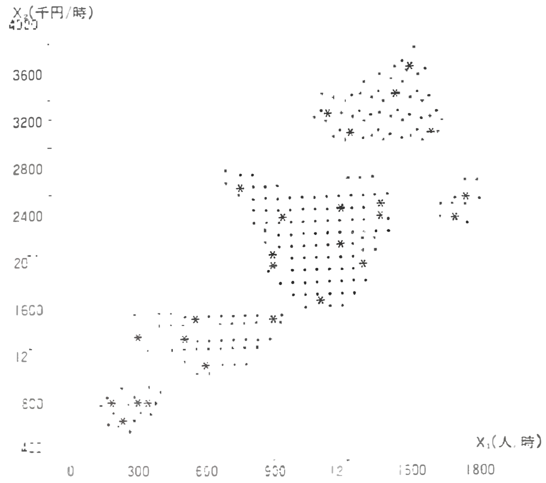

(図1)クラスター数kの目安

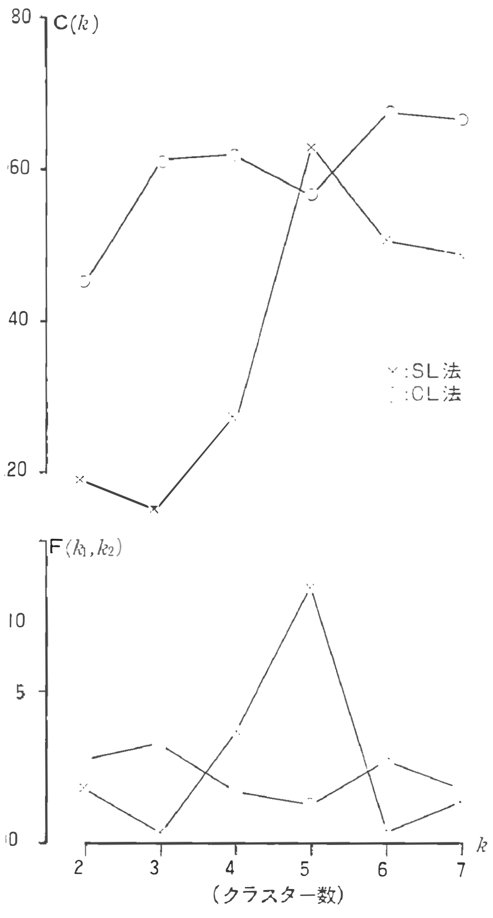

$k=5$、ＣＬ法では $k=3$ または６がそれに相当する。また、$F(k_1, k_2)$ はクラスター数が k_1 から k_2 にかわったときの変化量をとらえる値として調整されているので、値が大きくなったときの k を採用すればよい。ＳＬ法では $k=5$、ＣＬ法では $k=3$（または $k=6$）となる。

同一のデータに対して２つの手法の結果が異なるが、これは手法によって作られるクラスターが違っていることを示している。しかも、k にともなう基準値の推移が２つの方法で異なることからクラスター化の過程が異なることがわかる。分割のすべての可能な組み合わせを総当たりして求めたクラスターではないから手法が変われば結果が違うことはまぬがれない。しかし、手法が違っても同じようなクラスター数が選ばれるならばそれは相当しっかりした（塊状の意味での）クラスターがあることがわかるし、例のように手法によって少しずつ異なったクラスター数が選ばれるときには、クラスターの境界があいまいでクラスター化が難しいことを示しているといえよう。性質が両極端である方法をえらんで、同じ実験を行い比較するということが大切であり、それと同時にこうした目安を求めることが非常に重要であろうかと思う。念のために、２つの手法で判定されたクラスター数に相当する仕分けを比較すると両者の違いがよくわかる〔(図２)(a)、(b)〕。

(図2-b)CL法による分類(k=3, k=6)

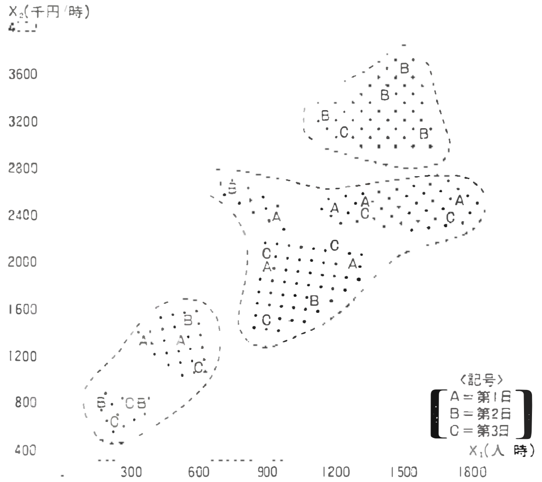

8.　分割型の手法による分類

計量的データで量が比較的多いとき、特定の加工を経たデータ（主成分得点、因子得点など）を分類するときなどは分割型の手法が利用できる。クラスター自体のとらえ方に変化があった階層的手法に対し、分割型の手法の多くは従来の多変量解析の応用であり、重点はむしろ算法の工夫にある。階層的手法では特殊な場合を除いては、同一算法を適用すれば同一データを使う限り解は同じである。これに対し、分割型手法ではそうならない上に、階層的手法とは別の制約がいろいろと起こってくる。

分割型の算法の基本は非常に簡単で次のように要約できる。

(1)　全データを適当な個数の群に分割する（初期分割）。あるいはクラスターの目安とする代表点（核という）をデータ空間内に与える（初期代表点の指定）。

(2)　群ごとの平均ベクトルを算出し個々のデータをもっとも近い平均ベクトルの群にわりあてる。あるいは、もっとも近い代表点に各個体を配置する（所属の決定、配置）。

(3)　各群の平均ベクトル、その他の統計量の更新。

(4)　クラスターのまとまりをはかる適当な基準を用意し、これを満たすまで計算を繰り返す（反復計算）。最後に基準の改良がみられなくなったら、えられた群をクラスターとして採用する。

この算法にどんな工夫をとり入れるかで、さまざまの手法が考えられているが共通の問題として次の点があげられる。

(1)　初期分割、初期代表点の選び方
(2)　各個体をクラスターに配置、再配置するときの方法と平均ベクトル更新の時期
(3)　クラスター・サイズの不均衡の手当ての方法
(4)　異常値に対する手当ての有無
(5)　クラスター数の決定法（固定か、可変か）
(6)　最適化の基準とそれを達成する算法

いずれも問題であるが(1)、(5)、(6)などは、とくに重要な鍵を握っている。たとえば、初期分割の与え方である。かりにクラスター数を k と定めたとしても、n 個の個体を k 個の空でない互いに重なりのない集団に分ける仕方、それを $S(n, k)$ とかくと、その総数は大変な数になる。$k=2$ として2分割を考えても $2^{n-1}-1$ 通りとなる。また、$S(10, 5)=179487$,　$S(20, 2)=524287$, $S(100, 3)\approx 8590\times 10^{46}$, ……といった具合いで、とても実用の計算可能な範囲内にはない。そこでふつうかりに k 個のクラスターがあるとして計算を始め、反復計算によって、しかるべきクラスター基準の最適化をはかるのである。まず簡単な例をみよう。

次のデータは $n=10$ の1次元（$m=1$）のデータである。これを次のようにして分類する。

x_1	x_2	x_3	x_4	x_5	x_6	x_7	x_8	x_9	x_{10}
4	5	4	9	1	10	6	5	0	2

①　まずクラスター数をかりに $k=3$ とする。

②　次に3個のかりのクラスターをどれにするか適当に選ぶ。この選び方は種々あるが、ここでは系統的にデータ番号1から順に {1, 2, 3, 1, 2, 3, ……} と番号をつけ、3つのクラスターを C_1, C_2, C_3 とかく。これがかりのクラスター（初期分割）となる。（図3）(a)はこれを実際に示したものである。

③　クラスターのまとまりの度合いをクラスタ

ー内平方和ではかることにする（これがクラスターの最適化の基準となる）。

全データの平均：$\overline{m}=\sum_{i=1}^{10}x_i/10$

$=(4+5+\cdots\cdots+2)/10=4.6$

クラスター C_1 の平均：m_1

$=(x_1+x_4+x_7+x_{10})/4=5.25$

クラスター C_2 の平均：m_2

$=(x_2+x_5+x_8)/3=3.67$

クラスター C_3 の平均：m_3

$=(x_3+x_6+x_9)/3=4.67$

全データ平方和：$TSS=\sum_{i=1}^{10}(x_i-\overline{m})^2$

$=\{(4-4.6)^2+(5-4.6)^2+\cdots\cdots+(2-4.6)^2\}=92.4$

クラスター内平方和

C_1 内の平方和：$S_1=\sum(x_i-m_1)^2$

（x_i は C_1 内のデータ）

$=(x_1-m_1)^2+(x_4-m_1)^2+(x_7-m_1)^2+(x_{10}-m_1)^2=26.75$

同様に

C_2 内の平方和：$S_2=\sum(x_i-m_2)^2=10.67$

C_3 内の平方和：$S_3=\sum(x_i-m_3)^2=88.08$

したがって、クラスター内平方和の総和 S_w は、

$S_w=S_1+S_2+S_3=88.08$　となる。

④　各クラスター内のデータの中から移動（配置がえ）の候補を1つえらぶ。かりにそれを第 j クラスター C_j 内の第 i 個体 x_i とする。この x_i を C_j 以外のクラスターに移動させてみて、S_w の値が現在以上に小さくなる（つまり改良される）か調べる。S_w 値が小さくなるときには x_i をそのクラスターに移動させる。例では C_1 内の x_1 を C_2 に移動させたとき S_w の改良があったので C_2 へ移す。

⑤　そして、平均と S_w を更新する。

$m_1=5.67,\ m_2=3.75,\ m_3=4.67$

$S_1=24.67,\ S_2=10.75,\ S_3=50.67$

$S_w=86.08\ (<88.08)$

となる（C_3 内には変化がないから値に変化はない）。

⑥　上の手順を順次繰り返すと、（表2）のようなクラスタリングの履歴表ができる。表には移動した個体番号と、そのときの所属構成（メンバーシップ・リスト）、平均の推移、平方和の推移をあげてある。この例では9回の反復の後 S_w に変化がみられなくなったので、計算を終了したことになる。

いくつかのステップを図で眺めても変化の様子がよくわかる[（図3）]。この方式で平均の更新時期を1個の移動ごとに行わないで、すべてを移動させた後に行うようにすると、また結果が少しずつ違ってくる（読者は電卓を使って試すとよい）。同じデータを $k=2$ として計算すると $m_1=2.2$,

（表2）$k=3$のときの計算結果

ステップ	移動した個体番号	（メンバーシップ・リスト）x_1	x_2	x_3	x_4	x_5	x_6	x_7	x_8	x_9	x_{10}	（平均の推移）m_1	m_2	m_3	（平方和の推移）S_1	S_2	S_3	$S_w(=S_1+S_2+S_3)$
0	（初期条件）	1	2	3	1	2	3	1	2	3	1	5.25	3.67	4.67	26.75	10.67	50.67	88.08
1	1	2	2	3	1	2	3	1	2	3	1	5.67	3.75	4.67	24.67	10.75	50.67	86.08
2	2	2	3	3	1	2	3	1	2	3	1	5.67	3.33	4.75	24.67	8.67	50.75	84.08
3	3	2	3	2	1	2	3	1	2	3	1	5.67	3.50	5.00	24.67	9.00	50.00	83.67
4	4	2	3	2	3	2	3	1	2	3	1	4.00	3.50	6.00	8.00	9.00	62.00	79.00
5	5	2	3	2	3	1	3	1	2	3	1	3.00	4.33	6.00	14.00	0.67	62.00	76.67
6	7	2	3	2	3	1	3	3	2	3	1	1.50	4.33	6.00	0.50	0.67	62.00	63.17
7	9	2	3	2	3	1	3	3	2	1	1	1.00	4.33	7.50	2.00	0.67	17.00	19.67
8	2	2	2	2	3	1	3	3	2	1	1	1.00	4.50	8.33	2.00	1.00	8.67	11.67
9	（最終解）7	2	2	2	3	1	3	2	2	1	1	1.00	4.80	9.50	2.00	2.80	0.50	5.30

m_2=7.0, S_w=34.8 で解となる。k=3 の最終解は k=2 のときのそれにくらべて、S_w は小さくなるが、これは当然で k を増やせば増やすほど S_w は減少する。これでは k の目安がえられないから再び前述の分散比を計算してみると、

$$\begin{cases} C(2)=13.241, & C(3)=57.519, \\ F(1,2)=0.4729, & F(2,3)=3.542, \end{cases}$$

以下減少

となって、確かに k=3 あたりが適当であることがわかる。

再び小売店のデータ例を引用しよう。上の方法で kをかえながら、クラスタリングを行い $F(k_1, k_2)$ を求めたところ、

$F(2, 3)=1.994$, $F(3, 4)=2.541$, $F(4,5)=1.150$, ……となったので、k=4 あたりが適当とみて、仕分けしたのが（図４）である。もちろん前の結果と一致するはずはないが、ＣＬ法の結果にやや近いことがわかる。

上の方法を k—means 法とよび、分割型手法の代表的なものである。ここでは最適化の基準として平方和を考えたが、他にも基準がいくつかある。しかし、その大部分は、従来多変量解析で利用されてきたものであり、各手法の特色は最適化をはかる算法にあるといってよい。よく使う基準としては、平方和の他に、行列式基準がある。これはクラスター内の平方和積和行列 W と、クラスター間の平方和・積和行列Bをつかって、$|W|$ の最小化, $|W^{-1}B|$ の最小化（これは判別分析の応用にほかならない）などを狙うものであるが、平方和基準との違いは、変数間の相関の情報をとり入れるかどうかの点にあるだけで、算法にはそれほど大差はない。こうした基準のどれがよいかということはデータの構造によって定まる問題であるから、データに潜む傾向を知ろうとするクラスター分析の狙いからすると、１つの矛盾点となり堂々めぐりとなってしまうのである。こうしたことから、分割型の手法を利用するときは、いきおい試行錯誤的な色彩が濃くなり、実験的要素が強くかかわりをもつ。たとえば、１日の計算で結論をつけるのではなく、何回も初期条件をかえては繰り返したり、データ量が多いときには、これをいくつかにランダム分割し、各々のわけたデータで分類を行い、それぞれの結果を比較しあう。あるいは分けた第１の群で判別関数を作り、他の群をそれによって判別してみる、といったいろいろな方法が考えられるが、このあたりの工夫の仕方が、分割類型手法を使いこなすコツといえよ

(図3)

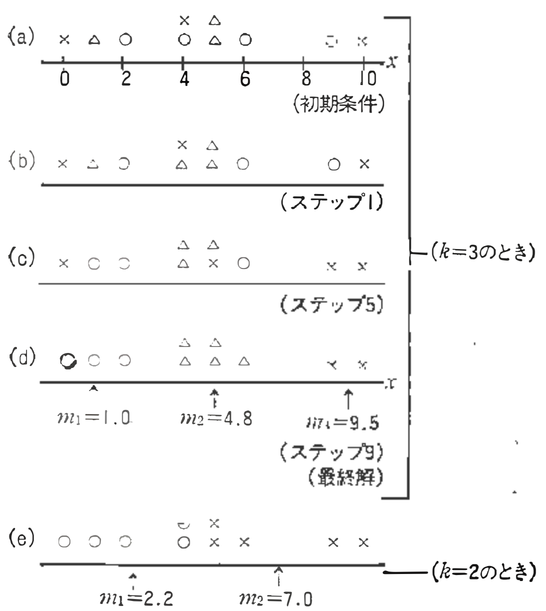

(図4) k-means法による分割の例

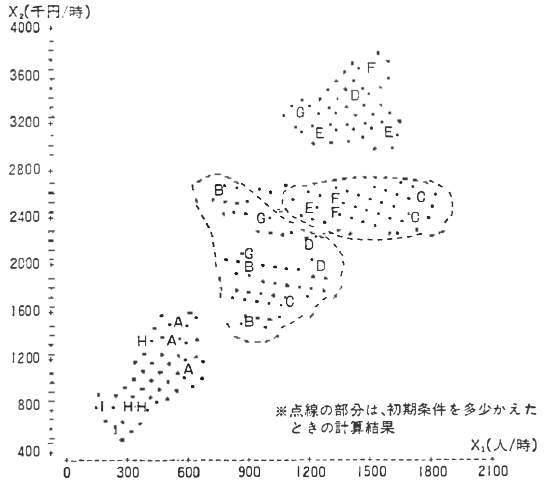

う。たとえば、上の例でも、初期条件を若干変えると、（図４）にみられるように、クラスターの構成が多少違ってくる。しかし、移動のないクラスターは、やはり構造のはっきりしたものであるとみることができる。現存のプログラム類はこうした点まで考慮して作成されたものは少ないので、利用者は注意がいるし、あるいは逆にこの処理の過程のうまい手順を工夫すると、それは１つのノウハウどなりうるわけで、この点が今後のこの種の手法の決め手の１つと思われるのである。

9. その他の分類法

社会調査デ--タのようにカテゴリカルなしかも量が比較的多いデータを取り扱う分類法は数が少ない。いきおい利用者は既存のプログラムに頼ってこうしたデータを処理することになるが、筆者の知る限りでは、階層的手法、分割型手法のある種のもの（Friedman–Rubin の方法、k-means 法など）がよく利用されている。しかし、こうした手法は本来、量の多いカテゴリカル・データの処理にはあまり適当とはいえないようである。

こうした中で、Morgan と Sonquist の考えたＡＩＤ (Automatic Interaction Detector) 法は若干の問題があるにせよ、検討する価値がある手法の１つである。国内におけるＡＩＤ法の使われ方が、発案者の本来の狙いとは異なったかなり偏ったものであったがために、誤解をされてきた面もある。原理は分散分析に類似したごく簡単なものである。

（表１）のデータのうち、日と時間とカテゴリー化した X_1, X_3（表１）を説明変数とし、このカテゴリー情報を使って、売上金額（外的基準）を分類することを考える。計算結果を観察しよう。（図５）は樹木図である。通常はこれをみて傾向を判断する。しかしこの図は何を意味するのか。いま、（入店者）対（売上金額）の散布図の中に４つの最終クラスター G_1, G_4, G_5, G_6 に対応して記号で仕分けする［（図６）］。同様に、分割の各段階で有意であるとして、分割のキーとして使用された時間と日の２つの説明変数と売上金額の散布図を作り、（図６）と同じ記号を使って各点を仕分けする［（図７）］。この２つの図を比較するとＡＩＤがなにを行っているのかかなりはっきり見えてくる。

① G_4：第１、３日の 11 時(2)〜16時(7) までは非常に類似したパターンをとる。

（図5）AIDの計算結果

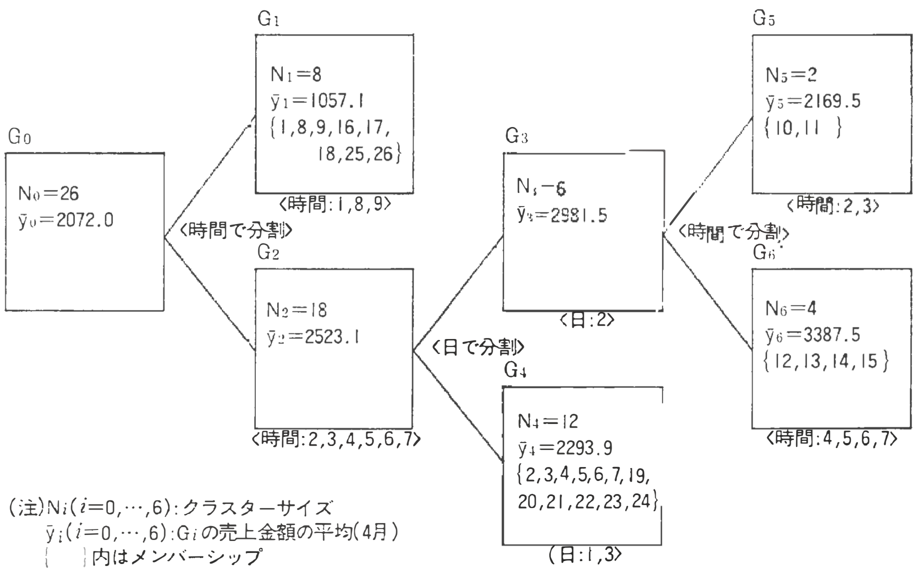

② G_5：第２日（土曜日）の11、12時のパターンは G_4 の一部である第１、３日の同時刻と全く逆の傾向にある（完全に交絡している）。

③ G_3：第２日の13時(4)～16時(7)も、G_4 の同時刻のパターンに対してほぼ逆に近い傾向を示す（やはり交絡の傾向がみられる）。

④ G_1：開店時（10時）、閉店時（17、18時）は個別の差はなく、こみにして考えていてよい。

つまり、ＡＩＤには、交絡化の傾向があると思われる説明変数群のカテゴリー間の絡みを、ある程度検出する機能があると思われる。したがって、きれいな線形関係にあって交絡現象のみられない説明変数群（カテゴリー化された入店者数 X_1 と金銭出納機の回数 X_3）は分割のキーとしては現れないのである。こうしたことから考えて、ＡＩＤは、数量化Ｉ類のように、各変数の完全加法モデルのような分析に入る前に、カテゴリー内の交絡を整理し、矛盾のない入力データの設計を行うときなどに活用できると思われる。実際ミシガン大学の統計システム OSIRIS-Ⅲでは、ＡＩＤとＭＣＡ（Multiple Classification Analysis：Ｉ類と同種の手法）との連結処理が可能である。国内では、こうした使い方の例はまだみられないが現在筆者のところでＩ類との連結処理を可能にするプログラム方式を検討中である。

10. むすび

クラスター分析の手法は階層的分類法や分割型手法に限ったものではない。むしろ、問題に応じていろいろの手法を組み合わせた使い方を工夫したり、あるいは問題に即応した独自の方法を開発することに妙味がある。異論もあろうが、何よりもまずデータに手をふれて自ら分析の過程で起こるさまざまの現象を観察することが第１で、その手続きの中に新たな方法論が展開される。クラスター分析は、実用に耐える方法がいまだ少なく、データ解析の道具として、まだまだ検討の余地はある。過剰な期待はもちろん慎まねばならないがデータに潜む特徴を具現化し、要約化する方法としては非常に期待が持てる道具でもある。あえて繰り返すならば、良薬となるか毒薬となるかは、すべて利用者の使い方にかかってくるわけで、いわば手探りのデータ解析心得といったものを身につける努力が不可欠であろう。

（第６研究部・第１研究室研究員）

(図6)AIDによる4つのクラスターの構成

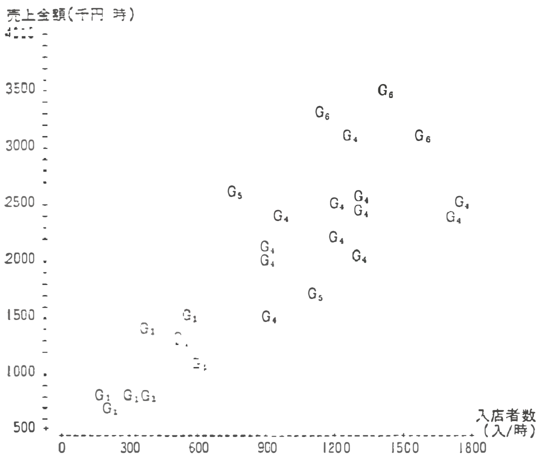

(図7)時間、日、売上金額の関係

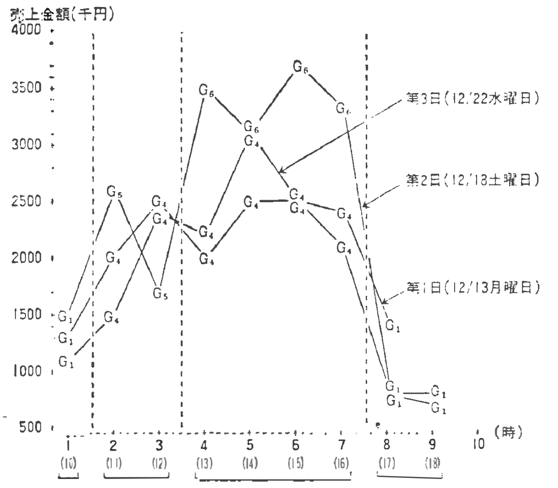

昭和51年12月27日第三種郵便物認可　毎月15日発行　広告月報　3月号　昭和53年3月15日発行　通巻215号

広告月報

ASAHI AD. MONTHLY 1978 3 NO.215 朝日新聞社

特集

制作マンからみた
新聞広告の可能性

MARCH

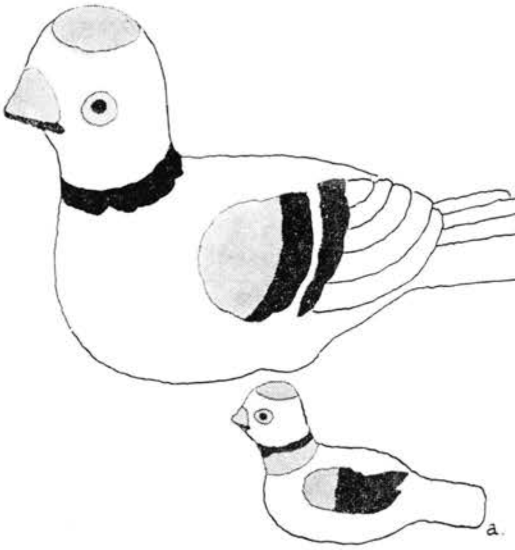

今月の主な内容

カット：麻生哲郎

昭和51年12月27日第三種郵便物認可　毎月15日発行　広告月報　3月号　昭和53年3月15日発行　通巻215号

朝日新聞社広告部

東京本社広告部
〒100　東京都千代田区有楽町2-6-1
03(212)0131

大阪本社広告部
〒530　大阪市北区中之島3-2-4
06(231)0131

西部本社広告部
〒802　北九州市小倉北区砂津1-12-1
093(531)1131

名古屋本社広告部
〒460　名古屋市中区栄1-3-3
052(231)8131

北海道支社広告課
〒060　札幌市中央区北二条西1-1
011(281)2131

定価　200円