

# 多重配列データと母数空間の構造

1977年9月16日

吉澤 正

山梨大学工学部計算機科学科

Tadashi Yoshizawa

Structure of Multiarray Data and Population Spaces

Ph.D. Thesis

Tōkyō University

green abstract



# はしがき

本論は、多重配列データと母数空間の構造に関する研究をまとめ、東京大学学位審査のために提出するものである。

本研究は、一応、統計学の範疇に属するものであるが、統計学の各種の立場や応用分野の見られる中で、統計情報工学ともいべき枠組の中で進められていくものである。

序論の1節「研究の背景」で述べるように、情報工学や行動諸科学といった学際的領域の発展と歩調を合わせて、各種の現象解析あるいは情報解析の統計的接手法の新らしさ開発が必要になっていく。例えば、従来の量的データ中心の解析手法に対して質的データの解析、連續量に対して離散データの解析、実験データや調査データに対して無作為化などの統計的管理の欠けた状況で得られた観察データの解析などがあげられよう。そこでは解析すべきデータの性格や構造の多様化がみられ、従来の統計学の再検討がその基盤からせまられている。

一般的にいって、データ解析のもっとも重要な目標の一つは、その現象を解明する確率モデルを構成することであろう。その目標のためには、誤差やバラツキの発生源、にくわびのぼつて確率モデルの妥当性の検討や、モデル構成の基本となる母数空間の構造の追求が必要となろう。同



時に、大量かつ多様な性格や構造を持つデータに対しては、その収集・検査・蓄積から各種の解析に至る幅広いデータ処理としての側面、すなむち、電子計算機の利用を前提としてのデータ処理システムや使用する算法の効率の研究も無視できない。

そのような立場から、数値計算における丸め誤差の確率モデル、粒子の混合問題における確率モデルとその応用、多重分割表での記述的数量化手法に対する確率モデルによる基礎付け、母数空間の構造の幾何学接近法による基礎的研究、多重分割表などの多重配列構造を持つデータと母数空間の研究、さらには、電子計算機による統計計算やデータ解析システムに関する研究等を行ってきし。

ここでは、多重配列の分解、とくに特異値分解の理論と多重分割表などの解析への応用、ならびに母数空間の構造への幾何学的接近法による研究について一応の成果が得られたと考え、「多重配列データと母数空間の構造」と題して報告する次第である。

1977年9月

吉澤 正



# 目 次

## はしがき

### 1. 序論

1.1 研究の背景

1.2 研究の概要

1.3 従来の研究及び文献

### 2. 多重配列構造を持つ線形母数空間

2.1 効果・交互作用

2.2 階層的モデル

2.3 内積の一一般化

### 3. 多重配列の特異値分解

3.1 算法

3.2 特異値分解の性質

### 4. 多重分割表への応用(I)

4.1 加法モデルと対数線形モデル

4.2 平方根モデル

### 5. 多重分割表への応用(II)

5.1 2重分割表における数量化

5.2 3重分割表における数量化とモデル

5.3 多重分割表における数量化

5.4 平方根分解

5.5 数値例

### 6. 多重配列の混合型分解

6.1 混合型分解

6.2 数値例

### 7. あとがき

## 謝辞

## 参考文献

## 付録



# 1. 序論

## 1.1 研究の背景

何らかの現象を統計的現象として解析するとの重要な目標の一つは、その現象の特性を一つのあるいは複数の確率変数として捉え、その確率変数の分布を把握することであろう。その目標は追求対象である現象を統計的あるいは確率的現象として説明する確率モデルを構成することともいえよう。

統計学の歴史から見れば、19世紀初頭以来、現象解析の統計的接近法の根本思想は大量データの観察によって現象の統計的規則性を見い出すという点にある。しかしながら、一つの現象を解析するにも一般的には多数の特性を同時にかつ多次元的に考慮する必要があり、これら特性の多次元分布を定めるとは限られた大きさの標本をもつてしては困難であり、場合によっては不可能に近い。

そこで、20世紀以後の統計学では、確率分布や標本分布論から始まり、実験計画法や標本調査法の進歩を伴って、いわゆる推測統計学、さらにはベイズ流推測等の統計的決定理論の発展をみた。そこでは、有限の大きさの標本にもとづく統計的推測の基礎を近代的確率論に求めるために、実験計画においてはいわゆる



Fisher の三原則：反復(replication); 無作為化(randomization); 局所管理(local control)を、標本調査法においては何らかの無作為抽出(random sampling)とデータ収集の基盤とする。さらに、解析の対象となる母集団の特性に対してある枠内の分布族を想定して、その分布族に対応する母数(parameters)についてのモデルあるいは仮説についての統計的推測を行うという形式を採用する。

一方、従来から因子分析法や多次元尺度構成法など独自の手法を発展させてきた心理学、社会学、医学等の行動諸科学をはじめ、現象解析への統計的接続の必要な分野が広まつて、上述の無作為化や無作為抽出の原則に従うとはみなせないデータ、いわば実験データや調査データに対して観察(observation)データと呼ばれるものの解析、あるいは量的データに対して質的カテゴリカルなデータの解析、量的であっても離散的データの解析が必要になっていく。

これらのデータ解析の場では、今後解析あるいは発展させねばならないものとして、以下に述べるような諸問題が生じていいと考えられる。

観察データの解析に確率論を応用する根拠をどこに求めるか。観察データを不完全な無作為抽出によるデータとみるなら、完全な無作為抽出の



場合と異なり、色々種の偏りを持つデータとなろう。その偏りをいかにとらえらるかも重要な問題であろう。

調査データを含めて、質的データの典型的場合である多重分割表の解析とそのモデル構成をいかに進めらるか。分散分析における母数モデルから類推のようない形で対数線形モデルや加法モデルの研究は色々程度の成果をあげてゐる。さらにデータの性格やデータの抽出過程の現実的多様性に応じて手法やその複雑性の研究が望まれる。分散分析の変量モデルに対応する多重分割表のモデルとその解析もその一つである。筆者等は多種粒子の混合問題での不完全混合状態の確率モデルの構成から出發して、多重分割表の変量モデルを考えている。そのモデルは品質管理での不完全管理状態、例えばロット内でも製品の不良率にムラがあるような状態の取り扱いにも通じるものがある。

上記の多重分割表をはじめ、一般にコンジョイント・メジャメント (conjoint measurement) データなどと呼ばれる多重配列構造を持つデータの解析手法をいかに発展せらるか。これに対して筆者は多重配列の特異値分解を考え、多重分割表の解析に応用していり、行列の特異値分解が多変量解析において重要な役割を果していり



のに対して、多重配列データの解析にその特異値分解が理論的基礎としても有効に利用されることが期待される。

主成分分析や回帰分析など従来の多変量解析手法では、いわゆるプロファイル(profile)データ、すなむち、多數の特性についての観測対象集合に関する行列構造のデータを扱うものであるが、上述の多重配列構造をはじめとして、各種の構造や性格を持つデータが出現している。例えば、枝分かれあるいは木構造を持つデータや、対象間の類似性を表す近接性(proximity)データ、対象間の優劣関係を表現する優越(dominance)データなど。このようなデータを対称とする数量化手法、最適尺度法、一対比較法などと含めて広い意味での多次元尺度構成法の現状は満足できるものではない。これらの手法は全般的にデータの記述的分析の段階にとどまっているが、それらの有効性や適用の限界を、それらの分野の実質科学的な経験の累積によって明らかにするとともに、実質科学に即して確率モデルの構成を通じて統計的推測も可能にすることによって追求していくことが不可欠である。

特性の分布型を追求すること。従来の統計手法や理論は連続量なら正規分布、離散量ならポアソン分布や二項分布というように、特



性の分布を比較的簡単なものに仮定して上で作られてはいるものが多く、それらが形式的に利用されるという弊害も生じてはいる。ある確率モデルが考えられるとき、そのモデルでの仮定から導かれる結果としての統計量がその現象を表面的にはよく説明することができる。しかし、それでいてはそのモデルの妥当性が保証されるわけではなく、別のモデルでも同じ現象を説明できるかもしれない。確率モデルについては、モデルの根本的仮定に立ち戻って徹底的に検討し追求する必要がある。すなはち、誤差やバラツキの発生源にできるだけさかのぼってモデルの妥当性を、諸特性の分布を追求することによって、検討することができる。物理現象や筆者なども研究している数値計算での丸め誤差の現象などでは、このような検討が比較的容易に行えることがあるが、それ以外の現象でもモデルの妥当性の追求を避けられないにはいかない。

最後に、データ処理としての側面に触れておこう。大量かつ構造的に複雑化してデータを扱うには、電子計算機を用いた良質のデータ処理、あるいはデータ解析のシステムが不可欠である。通常のデータ処理におけるデータの検査、データファイルの更新、分類(sorting)、報告書作成などのはかに、解析に用いられる算法の効率と異常データの統計



的検出が重要課題として指摘されるよう。例えば“多重配列データの解析”や“多次元尺度構成法”などの算法はプログラムの良し悪しによって著しく処理時間が異なる。異常データへの関心はその存在から以後の解析に影響を及ぼすためだけではない。従来の統計学が個々を捨象して集団の統計的性格の分析を主目的としたものに対し、集団の中で個の相対的立場をみな必要が高まっていることによる。集団の中で個で異なるものとしての異常データの検出とその適切な取り扱いはその意味で重要である。本論では、確率モデルからの流れ、あるいはモデルの不適合の要因となる個の追求という立場から異常データの検出を考える。



## 1.2 研究の概要

本研究は次の二部に分けることができる:

- (I) 多重配列構造を持つ母数空間と多重配列の特異値分解の研究;
- (II) 多重分割表データの解析等への応用.

以上のほか、(I)に関連する Riemann 構造を導入した母数空間の研究を附録として含む。

その概要を述べるためにあたって、多重配列構造を持つデータと母数の出所を示しておくことは本研究の応用の場を考える上で意義があろう。説明を簡潔にするために、寸法  $r \times s \times t$  の 3 重配列をとりあげ、それを  $A = (A_{ijk})$ ,  $\forall i \in \bar{r}, \forall j \in \bar{s}, \forall k \in \bar{t}$  と書く。ここで、 $\bar{r}, \bar{s}, \bar{t}$  は 3 つの指標  $i, j, k$  のそれぞれがともに名前あるいは番号の添字集合 (index sets) である。現実の応用の際には、多重配列の各要素とその添字集合は今までまでは物理的意味を持つが、3 重配列の出所を添字集合の異同によって 3 種に分類しておく。

(1) 添字集合  $\bar{r}, \bar{s}, \bar{t}$  がすべて異なる場合。その代表的な出所として、実験計画法での要因実験に対する多元配置型データと調査データのクロス集計としての多重分割表が挙げられる。とくに、後者は本論における主要な応用分野として取り扱われるものである。要因実験においては、 $\bar{r}, \bar{s}$  及び  $\bar{t}$  はそれぞれ別個の一つの因子に対する水準



の集合を示し、配列要素  $A_{ijk}$  は水準の組  $(i, j, k)$  ごとの実験の観測値として、あるいはモデルごとのその観測値に対する期待値として現われる。要因実験で扱われる通常のモデルは期待値として  $A_{ijk}$  に関する線形モデルである。多重分割表の場合、 $\bar{r}, \bar{s}$  及び  $\bar{t}$  はしばしば項目(item)と呼ばれる属性に対応し、 $i, j, k$  はそれらの項目を構成する排他的なカテゴリ(category)を意味する。添字要素の組合せのひとつひとつをセル(cell)といい、 $(i, j, k)$  セルなどとも書く。多重分割表の要素  $A_{ijk}$  は  $(i, j, k)$  セルに該当する観測対象の度数(以下セル度数ともいう)、何らかの確率分布を想定してモデルでのセル度数の期待値や各セルでの確率(セル確率)としての意味を持つ。多重分割におけるモデルとしては、セル度数の期待値に関する線形モデル(多重分割表の加法モデル)やその期待値の対数をとった母数に関する線形モデル(多重分割表の対数線形モデル)などが一般的なものとして研究されている。本論ではセル度数の平方根をとった多重配列の分解も論じる。多重配列構造のデータで、その添字集合が要因の水準や項目のカテゴリに応じて各セルごの値が観測されるようなものを多次元尺度構成法などでは conjoint measurement データと称するものもある。



(口) 添字集合  $\bar{\gamma}, \bar{\delta}, \bar{\tau}$  の二つが同一である場合. 例えば, 大学等の入学者選抜試験をとりあげよう.  $\bar{\gamma}$  と  $\bar{\delta}$  はともに入試の教科の集合, 例えば {国語, 社会, 外国語, 数学, 理科} を,  $\bar{\tau}$  は数年における年度を表すものとする. そのとき  $A_{ijk}$  は某年度における教科  $i$  と  $j$  の相関係数などとして出現する. そこでは数年度にわたる相関係数行列の構造の変化を分析することが問題となる. 一般に,  $\bar{\gamma}$  と  $\bar{\delta}$  もともに何らかの物の集合で, その集合に属する任意の二つの物の間の関係が直接あるいは間接に測定され, その測定が複数個の異質な集團で行われるような場合,  $A_{ijk}$  は某個集団で測定された  $i$  と  $j$  の物の間の関係を表す. その関係は類似性の度合や優劣の関係などというような場合がある.

(い) 添字集合  $\bar{\gamma}, \bar{\delta}, \bar{\tau}$  がすべて同一である場合.  $\bar{\gamma}, \bar{\delta}$ , 及び  $\bar{\tau}$  がいずれも同一の人間の集合を表し, 3人のあらゆる組について何らかの関係, 例えば3人組による作業の能率が測定されるとき, その測定値の並びが3重配列を表現する. また, マルコフ連鎖の拡張として,  $\bar{\gamma}, \bar{\delta}, \bar{\tau}$  を同一の状態の集合と考え, 状態  $i$  から  $j$  を経て  $k$  へ移る遷移確率を  $A_{ijk}$  とすることもできる.

多重配列構造を持つデータは上記のほかにも多様な出所があり,



それが“固有の性格”を有している。その解析およびモデル構成は、その出所である実質科学上の性格に即して行われるべきものであり、一般的な解析手法やモデルが“ありわけ”ではない。しかし、線形性を持つモデルや本論で示す多重配列のより種の分解定理が多重配列構造を持つデータの解析やそのモデル構成の重要な基礎になると考えられる。

さて、次項においてこの分野における従来の研究をその文献をひげて概観するのに統いて、2章では多重配列構造を持つ母数に対して各指標 $\beta$ とのベクトル空間のテンソル積を考え、後章の基礎となる諸概念の定義や性質を本論の立場から記述する。3章では行列、すなむら二重配列の特異値分解の拡張に相当する多重配列の特異値分解を論じ、4章及び5章で多重分割表を直接の対象とする応用を行う。6章では、多重配列の添字集合のいくつかが同じ物理的意味を持つ場合について、その分解と応用を論じる。附録では母数空間に基本計量テンソルを導入して母数空間を Riemann 空間とみなし、其分散安定化変換が存在するための必要十分条件をはじめ、二三の応用を論じる。以上が本論の基本的枠組であるが、以下に各章内の概要を述べる。

第2章では、 $m$ 重配列の構造を持つ母数空間と、各指標 $\beta$ とのベクトル空間  $V^{(i)}$ ,  $i = 1, 2, \dots, m$  のテンソル積  $V$  を考え、以後の章で必要とな



る基礎的概念を導入する。母数空間  $\Sigma$  の部分空間としての効果空間と母数  $A$  の因子効果あるいは交互作用が各ベクトル空間  $\Sigma^{(i)}$  で指定され、ベクトル  $\underline{u}^{(i)}$ ,  $i=1, 2, \dots, m$  に相対的な形式で定義される。2.1節では、その一般的定義にもとづく多重配列母数  $A$  の因子効果の表現,  $A$  の分解表現,  $A$  の平方和分解などに関する定理が与えられる。内容的には完全要因計画における分散分析とそのモデルからの類推によって理解されよう。2.2節では汎用性のためモデルとして階層的モデルや分解型モデルを論じる。それらは多重分割表のモデルの選択を行うときに重要なとなる。2.3節ではベクトル空間における内積の定義を一般化したときの問題点を注意する。後述の加法モデルや多重分割表における数量化手法の理論展開に必要となる。

第3章では、多重配列データを多重一次形式の係数と考え、その多重一次形式の最大化問題をとりあげ、それより多重配列の特異値分解を導く。多重一次形式は

$$\rho = \sum_{\lambda_1, \dots, \lambda_m} A_{\lambda_1, \lambda_2, \dots, \lambda_m} u_{\lambda_1}^{(1)} u_{\lambda_2}^{(2)} \cdots u_{\lambda_m}^{(m)}$$

で与えられる。ここで、 $A_{\lambda_1, \lambda_2, \dots, \lambda_m}$  は  $m$  重配列の要素,  $u_{\lambda_i}^{(i)}$  はベクトル  $\underline{u}^{(i)} \in \Sigma^{(i)}$  の要素である。この多重一次形式は、 $m$  次の相關関数、あるいは適当な条件の下で  $m$  次の相關係数としての統計的意味を



持つ。3.1節では、まず上述の最大化問題の解の存在と決定方程式を示す。次にその決定方程式を再帰的に用いる算法を定義し、その算法の有限性、その算法によって得られるベクトルの各ベクトル空間  $\mathbb{R}^{(i)}$  での正規直交性を示す。また、最大化問題の各種の拡張とその算法との関係を論じる。3.2節では、上述の算法から多重配列の特異値分解ともいべき分解表現が得られることを示し、その分解による多重配列の因子効果成分や平方和の分解に関する特異値分解の諸性質を示す。

第4章1節では、従来からの多重分割表に対する代表的モデルとして研究されていける加法モデルと対数線形モデルを本論の立場から検討する。とくに、加法モデルと特異値分解との密接な関係を指摘する。4.2節では多重分割表のセル度数あるいはセル確率の平方根をとった多重配列の線形モデルを論じる。

第5章では、特異値分解の直接的応用として、多重分割表における数量化手法と平方根分解を扱う。5.1節で従来の2重分割表における手法の基本的性質を整理し、5.2節において3重分割表における数量化をくわしく扱う。従来提案されていける手法が“加法モデル”によって理論的に扱えることを示し、新たな数量化手法の提案を行う。



5.3 節では一般の多重分割表における数量化について、数量化以前の問題として多重分割表の構造をさぐるモデルの選択が必要であり、分割表の周辺和から直接に推定される構造を持つ分解型モデルを中心とする数量化モデルを考えることが有効であることを指摘する。5.4 節では多重分割表のセル度数の平方根の配列についての特異値分解を平方根分解と呼び、多重分割表におけるモデルの選択に有効に利用できることを述べる。5.5 節では平方根分解を中心として、数值例によってこれまで述べた各種のモデルの比較を行う。ヒトに、平方根分解による各因子効果の平方和の表を用いるモデルの選択が有効であることを示す。

第6章では、ある対称性を持つ多重配列の要素を一次形式と二次形式の混合形式の係数とみなして、この混合形式の最大化問題とその応用に触れる。6.1 節ではその問題に対する決定方程式を示し、第3章の特異値分解と併行して議論が可能であることを指摘する。6.2 節では数值例を示して応用に触れる。

附録においては、母数空間の構造に関する本研究に属するものとして、Riemann 構造の導入された母数空間を扱う。その研究は、多重配列の特異値分解や多重分割表の平方根分解の研究の動機



を与え、かつ本研究全体の思想的背景でもある。附録1では、漸近的に正規分布に従う一致推定量を持つ多次元母数について、その漸近的分散共分散行列の逆行列を基本計量テンソルとすることによってその母数空間を Riemann 空間と考える。次に、重要な幾何学的不变量である Riemann-Christoffel 曲率テンソルの統計的意味付けが与えられる。すなむち、その曲率テンソルが消えることか、共分散安定化変換 (covariance stabilizing transformation) の存在のための必要十分条件となる。以下、いくつかの母数空間が定曲率空間となることが示され、測地距離の応用が論じられる。例えば、多項分布での確率の母数空間は正の定曲率空間となり、そこでの測地距離は第4章と第5章で用いられる Bhattacharya の距離となり。附録2では、一般に位置及び尺度母数を持つ確率分布に対する二次元母数空間は負の定曲率空間となり、測地距離が比較的簡単に表現されることが示される。



### 1.3 従来の研究及び文献

この節では本論に関連する従来の研究を文献によって概観する。本研究の直接的な基盤となる分野は、多重分割表に対するパラメトリックなモデルによるデータ解析と多重分割表を含むカテゴリカルデータに対する数量化あるいは最適尺度構成の研究分野である。

多重分割表に対するパラメトリックなモデルとそれによるデータ解析の研究はこの15年間に急速に進み、さらに発展を続けて来る。最近の主要な研究は次の三種類のモデルに沿って分類できよう。すなむち、対数線形モデル、線形モデル、混合モデルである。対数線形モデルについては、G. U. Yule, R. A. Fisher 以来、M. S. Bartlett, J. A. Roy, M. A. Kastenbaum を経て、I. J. Good, S. Kullback, M. W. Birch, L. A. Goodman, Y. M. Bishop, S. M. Fienberg, S. J. Haberman など多くの研究者があり、分割表の研究の主流ともいえよう。線形モデルや混合モデルは、K. Pearson, R. A. Fisher から H. O. Lancasterを中心とする流れがあり、特に線形モデルには J. E. Grizzle, C. F. Starmer, G. G. Koch 等の研究がある。その線形モデルは分散分析のモデルからの単純な類推であり、Lancaster による加法 (additive) モデルとは異なり。さて、分割表の研究は 1900 年当初 K. Pearson と G. U. Yule に



その立端緒を見ると分かる。Pearson (1900a, b) は有名なカイニ乗適合度検定を提案し、 $2 \times 2$  分割表に対する tetrachoric correlation coefficient を発展させていた。Pearson は分割表を多次元正規分布などの連續分布の離散化に対応する標本と見る立場をとり、その背景としての正規分布についての相關係数を推定することに興味があった。また、Pearson (1904) は、二つの確率測度の相違を測る尺度として、Pearson、あるいは後に Hellinger の名によって呼ばれる汎関数  $\phi^2$  を定義した。その  $\phi^2$  は

$$\phi^2 + 1 = \int (d\nu)^2 / d\mu = \int (d\nu/d\mu)^2 d\mu = \int \Lambda^2 d\mu$$

と定義される。ここで、 $\mu$  と  $\nu$  は二つの確率測度、 $\Lambda = d\nu/d\mu$  は  $\mu$  に関する  $\nu$  の Radon-Nikodym 導関数である。 $\phi^2$  は  $\Lambda$  の分散と解釈される。この汎関数が後に Hellinger の名で呼ばれるのは [例えば、Cramér (1946)]、Hellinger が一般の 2 次元分布関数  $F(x, y)$  について

$$\phi^2 + 1 = \iint_{-\infty}^{\infty} [dF(x, y)]^2 / [dG(x) dH(y)]$$

と置いて研究したことによる。ここで、 $G(x)$  と  $H(y)$  は  $F(x, y)$  の周辺分布である。2 次元離散分布を、二つの確率変数  $X$  と  $Y$  について

$$\Pr\{X=x_i, Y=y_j\} = p_{ij}$$



と書くなら、Hellinger の  $\phi^2$  は

$$\phi^2 = \sum_{i,j} p_{ij}^2 / (p_{i+} p_{+j}) - 1$$

となる。ここで、 $p_{i+} = \sum_j p_{ij}$ ,  $p_{+j} = \sum_i p_{ij}$  である。もし、この  $p_{ij}$  を 2 重分割表データの各セルでの標本確率とみなせば、上式の  $\phi^2$  は、いわゆる 2 重分割表の独立性について Pearson の  $\chi^2$  を標本の大さ  $N$  で割ったものにほかならない。その後この方向の研究は Lancaster などによって受け継がれり。

一方、Yule (1900, 1912) は  $2 \times 2$  分割表における二項目間の連関の強さを測る尺度 (measure of association) として、しばしば Yule の  $Q$  及び  $Y$  (あるいは  $w$ ) と記される二つの量を提案した。Yule は、Pearson と異なり、分割表を本来的に離散的データとして考えていくようである。また、上記の尺度が対数線形モデルの基本ともなる、 $2 \times 2$  分割表での cross product ratio の関数によるというある種の不変性を持つ。このようしたことから、対数線形モデル派ともいえる研究者群は歴史的に Yule をこの分野の研究の出発点とするようである [例えば、Fienberg (1975)]。

次に、Fisher (1922, 1924) は、データから母数が推定されたときの適合度検定の  $\chi^2$  統計量が漸近的に  $\chi^2$  分布に従うことの初の



証明を与えたこととはじめ、2重分割表についての現在の理論がその多くを彼の研究に依るほどどの寄与を残している。Fisherの貢献について、本論の立場では、次の二点を強調しておくべきと思われる。オーネは、3重分割表における高次の交互作用の基準を示唆して Bartlett (1935) の重要な研究を導いたことである。3重分割表での高次の交互作用の概念をどのように定式化するという問題につき、多重分割表におけるパラメトリックなモデルの発達を促したともいえる。オニは、Maung (1942) に引用されていよう、Hotelling (1936) による正準相關分析の考え方を2重分割表に適用したことである。これらについては、同じ考え方以前にも発表されているという説もあるが [例えば 西里 (1977) 参照]、実質的影響は Fisher による。この手法は分割表における数量化あるいは最適尺度法といわれる分野の基礎となり (第5章参照)。

前述した Bartlett (1935) は  $2 \times 2 \times 2$  分割表で 2 次交互作用が存在しないという概念の一つの定式化を示した。その後 20 年近い空白を経て、1951 年に入って Simpson (1951) は Bartlett の定式化が cross product ratio に關係し 必然的に乗法的モデルにつながることを示した。この立場は対数線形モデルへつながる。



一方, Lancaster は 3 重分割表について, Pearson の  $\chi^2$ , あるいはそれと同値な  $\chi^2$  の分解から, 2 次の交互作用非存在の別の定式化として加法モデルを提案した. その加法モデルは, 3 重分割表のセル確率を  $p_{ijk}$ ,  $i=1, \dots, r$ ,  $j=1, \dots, s$ ,  $k=1, \dots, t$  とすると, セル確率が

$$p_{ijk} = p_{ij} + p_{it+k} + p_{itk} p_{j+} + p_{+jk} p_{i+} - 2 p_{i+j} p_{j+k} p_{i+k}$$

という関係を満たすものとして表現されて. 加法モデル及びそれに伴う  $\chi^2$  の分解については 4.1 節で本論の立場から検討を加えよう. さらに, Lancaster (1960) は 交互作用概念の多次元分布への拡張を行っている. また, Bahadur (1961) と Lazarsfeld (1961) は  $2^m$  分割表についての分解表現を与えており, 両者は表現こそ違うが, 加法モデルと同値なものになっている.

再び, 対数線形モデルの流れに目を向けると, Bartlett による定式化が Roy と Kastenbaum (1956) に至って, 一般の  $r \times s \times t$  分割表に拡張されたことが特筆される. その後, Good (1963) によるエントロピー-最大化による分割表データの解析, Kullback (1959) による情報理論的接近が顕著なものとしてあげられる. そして, Birch (1963, 1964, 1965) による最大推定法による接近に至り, これが



までの比較簡単な仮説の検定を主体とする研究から、対数線形モデルによるモデル構成の方向の研究への門戸が開かれた。対数線形モデルは、セル確率  $p_{ijk}$  の対数について

$$\log p_{ijk} = \mu + \mu_i^{(1)} + \mu_j^{(2)} + \mu_k^{(3)} + \mu_{ij}^{(12)} + \mu_{ik}^{(13)} + \mu_{jk}^{(23)} + \mu_{ijk}^{(123)}$$

をその飽和型とし、右辺の項を種々に取捨選択して一連のモデルとして表現される。上式ではセル確率のかわりにセル度数の期待値を用いることが多い。例えば、 $\mu_{ijk}^{(123)}$  をゼロとして場合は Roy & Kastenbaum による 2 次交互作用（本論では 3 因子効果という用語を使うが）の非存在の定式化と同値である。対数線形モデルは、その後 Goodman (1964, 1969, 1970, 1971a,b), Bishop (1967, 1969) のほか、多くの研究者によって発展させられている。これらの成果は、Plackett (1964), McKinlay (1975) による総合報告とし、また Plackett (1974), Bishop, Fienberg & Holland (1975), Haberman (1974) よりて成書としてまとめられており。対数線形モデルに関する研究は数理統計学的基礎理論と適用範囲の拡大への努力に分けられる。前者については、Birch 以来分割表の標本抽出過程をアソンモデルや多項分布モデルに仮定した上で、十分統計量や最大推定法との関連における対数線形モデルの良い性質の追



求めるが中心である。標本抽出過程をより複雑なものにすれば、この種の研究は一段と難しくなり、簡単な前提での手法の実験的性の研究を含めて、今後の発展を待たなければならぬ。適用範囲あるいは応用性の拡大という後者の側面にも種々の研究があるが、本論に因縁あるモデルの選択の問題に触れておこう。 $m$ 重の分割表での対数線形モデルを考えると、分散分析モデルからの類推でゆかるように、多因子効果を含めて  $2^m$  つの効果・交互作用が考えられる。分割表の解析では事後的なモデル構成もしばしば必要となり、 $2^m$  つの因子効果の中から有意なものを選択しないといふ問題が生じる。形式的には  $2^m$  つの因子効果の組合せによって  $2^{(2^m)}$  つのモデルが可能である。そこで、2.2節で述べるように、階層的モデルや分解型(closed form)モデルの概念が必要となる。Bishop(1967)は階層的モデルでは最大推定が周辺和と観測値との期待値の推定値について一致させるという反復計算で得られる事を示した。また、Goodman(1970) 及び Bishop(1971) は 4 重分割表以下では分解型モデルでのセル確率の最大推定値が反復計算を要せずに陽の形に求まることを示し、さらに Goodman(1971b) は任意のモデルが分解型であるかどうかを判定する構成的算法を与えた。Haberman



(1974) はそれを再帰的算法に書き直している。

モデル選択の現実的な算法としては、Goodman (1971a) が重回帰分析における段階的変数選択の手法を応用して手順を提案している。また、最近我国では赤池 (1973) による情報量規準による選択の有向性が検証されつつある。情報量規準の一つの解釈としては竹内 (1976)，多重分割表への応用例としては吉澤・藤本 (1976) がある。オ5章では平方根分解によるモデル選択が言及される。

以上のはか、線形モデルの系統の研究には Grizzle, Starmer 及び Koch (1969) を中心としたものがあるが、単純な線形モデルであって、本論でのモデル構成の立場と多少異なる方向にもあるのでその詳細には触れない。なお、3重分割表での高次交互作用の非存在についての加法モデルと対数線形モデル (この場合は乗法モデルといってよい)との比較は Darroch (1974) にくわしい。分割表に関する文献リストが Killion & Zahn (1976) によって与えられている。

次に分割表における数量化手法の関係について述べる。ここでいう数量化手法は、多重分割表における名義尺度からいへば順序尺度の



特性である項目について、項目を構成するカテゴリを分類したり、その相互の関係を把握することを目的に、何らかの規準に従って各カテゴリに数値を付与しようとするものである。一般的なカテゴリカルなデータに対する数量化手法を含めて最適尺度法といわれることもある。この分野の文献大目録が西田(1977)によって作られている。その多くは、0-1データの行列が与えられたときに、行のカテゴリと列のカテゴリに同時に数値を付与して比較の尺度を作ろうとするものである。本論で興味のある多重配列データを扱う数量化には岩坪(1971, 1974)がある。そこでは3次の相關係数最大化の規準による数量化と相関比による数量化が提案されている。吉澤(1975)ではこれらの手法が分割表の加法モデルと密接な内容を持つことから指摘され、従来記述的手法として考えられていく分野へ確率論的モデルを持ち込むことによって推測的扱いとする試みがなされている。

多重分割表と実験計画法での要因実験以外の分野での多重配列データの研究はあまり多くないが、正準相關分析の拡張としてのKettenring(1971)の研究、3相因子分析についてのTucker(1964)があげられる。多重分割表でも潜伏構造分析としらべる Lazarsfeld & Henry(1968)の研究と前述の3相因子分析は、



本論における特異値分解と形式的類似性がある。



## 2. 多重配列構造を持つ線形母数空間

本章では、実数値  $m$  重配列の構造を持つ母数空間を配列の各指標に  
対応するベクトル空間のテンソル積と考え、効果・交互作用の概念とその諸  
性質、ならびに階層的モデルや分解型モデルなどの母数空間における典型  
的モデルについて論じる。

### 2.1 効果・交互作用

実数値  $m$  重配列の構造を持つ母数を  $A$  とし、その要素を

$$A_{\lambda_1 \lambda_2 \dots \lambda_m} \quad (\forall \lambda_i \in \bar{r}_i, \forall i \in \bar{m})$$

と書く。ここで、 $\bar{r}_i$  は配列のオイ指標の添字集合  $\{1, 2, \dots, r_i\}$ 、 $\bar{m}$  は  
オ1からオ  $m$  までの指標の番号の集合  $\{1, 2, \dots, m\}$  である。一般に正の整  
数  $n$  に対し、 $\bar{n}$  は  $n$  以下の正整数の集合を意味するものとする。配列  
 $A$  の全要素数を  $n$  と書く。明らかに

$$n = r_1 r_2 \dots r_m$$

である。この配列  $A$  を寸法  $r_1 \times r_2 \times \dots \times r_m$  の  $m$  重配列と呼び、例え  
ば  $2 \times 3 \times 5$  の 3 重配列、あるいは略して  $2 \times 3 \times 5$  配列などと書くことも  
ある。

配列の各指標に対して以下に述べる内積の定義された  $r_i$  次元のベクト  
ル空間（内積空間） $\Omega^{(i)}$  を考える。 $\Omega^{(i)}$  に属するベクトルを



$$\underline{u}^{(i)} = (u_{\lambda_i}^{(i)}), \quad v^{(i)} = (v_{\lambda_i}^{(i)})$$

あるいは、

$$\underline{\underline{u}}^{(i)} = (\underline{u}_{\lambda_i}^{(i)}), \quad \underline{\underline{v}}^{(i)} = (\underline{v}_{\lambda_i}^{(i)}), \dots$$

などと書く。さしあたって、各ベクトル空間  $\Omega^{(i)}$  ( $\forall i \in \bar{m}$ ) における内積は

$$(\underline{u}^{(i)}, \underline{v}^{(i)}) = \sum_{\lambda_i} u_{\lambda_i}^{(i)} v_{\lambda_i}^{(i)} \quad (2.1)$$

によって定義する<sup>†</sup>。

さて、実数値をとり、寸法  $r_1 \times r_2 \times \dots \times r_m$  の  $m$  重配列の全体から成る  $n$  次元実数空間  $R^n$  や Halmos (1958) の定義によると、 $m$  位のベクトル空間  $\Omega^{(i)}$  ( $\forall i \in \bar{m}$ ) のテンソル積（空間）と考える。そのテンソル積を

$$\Omega = \Omega^{(1)} \otimes \Omega^{(2)} \otimes \dots \otimes \Omega^{(m)} \quad (2.2)$$

と書く。上式の右辺については、まとめて

$$\otimes_{i=1}^m \Omega^{(i)} \quad (2.3)$$

と記すことがある。記号  $\otimes$  はベクトルの直積や行列の Kronecker 積にも用いられるが、その区別は文脈から明らかでない。Halmosによれば、テンソル積  $\Omega$  は  $\underline{u}^{(i)} \in \Omega^{(i)}$  ( $\forall i \in \bar{m}$ ) に関するあらゆる多重一次形式によって構成されるベクトル空間の双対空間として定義される。

---

<sup>†</sup>  $\sum_{\lambda_i}$  は  $\forall \lambda_i \in \bar{r}_i$  について和をとることを意味する。



$m$  位のベクトル  $\underline{u}^{(i)} \in \Omega^{(i)}$  ( $\forall i \in \bar{m}$ ) の直積と、 $n$  通りの積

$$u_{\lambda_1}^{(1)} u_{\lambda_2}^{(2)} \cdots u_{\lambda_m}^{(m)} \quad (2.4)$$

を要素とする  $n$  次元ベクトルで定義し、これを

$$\underline{u} = \otimes_{i=1}^m \underline{u}^{(i)} \quad (2.5)$$

と書く。 (2.4) の量は本来  $m$  位の添字を持つが、これを  $n$  次元ベクトルとみなすときへの記号を用いる。  $m$  重配列  $A$  などについて全体の要素をベクトルとして扱うときは必要に応じて  $\underline{A}$  と書く。添字の組  $(\lambda_1, \lambda_2, \dots, \lambda_m)$  の一次元的並べ方は、一定の規則に従いえすればよいが、ここでは列ごと (column-wise) の順を原則として採用する。また、ベクトルは、とくに断らなければ列ベクトルとし、ベクトルと行列の転置には ' を用いる。

### 任意の寸法の行列

$$U^{(i)} = (U_{k_i \lambda_i}^{(i)}), \quad (\forall i \in \bar{m})$$

の Kronecker 積を

$$U_{k_1 k_2 \cdots k_m \lambda_1 \lambda_2 \cdots \lambda_m} = U_{k_1 \lambda_1}^{(1)} U_{k_2 \lambda_2}^{(2)} \cdots U_{k_m \lambda_m}^{(m)} \quad (2.6)$$

を要素とし、添字  $(k_1, k_2, \dots, k_m)$  と  $(\lambda_1, \lambda_2, \dots, \lambda_m)$  を行及び列の指標とする行列  $U$  によって定義し、

$$U = U^{(1)} \otimes U^{(2)} \otimes \cdots \otimes U^{(m)} = \otimes_{i=1}^m U^{(i)} \quad (2.7)$$



と書く。添字の組  $(k_1, k_2, \dots, k_m)$  と  $(\lambda_1, \lambda_2, \dots, \lambda_m)$  は  $\underline{\lambda}$  や  $\underline{k}$  の場合と同様に列じて並べるものとする。

以下に、テンソル積空間や Kronecker 積の性質として本論で用いるものを補題として挙げておく。Halmos (1958) あるいは Haberman (1974) などの記述から容易に証明されるので、それらの補題の証明は省略する。なお、 $\bar{m}$  の部分集合を  $\alpha, \alpha', \dots$  などと書き、空集合を  $\emptyset$  と記す。集合については包含記号  $\subset$  や同値記号  $\equiv$  を必要に応じて用いる。また、指示関数(indicator)  $\chi_\alpha(i)$  を、 $i \in \alpha$  が含まれば 1, そうでなければゼロの値をとる関数、すなはち

$$\chi_\alpha(i) = \begin{cases} 1, & i \in \alpha \text{ のとき}, \\ 0, & i \notin \alpha \text{ のとき} \end{cases} \quad (2.8)$$

と定義する。

補題 2.1.  $\Omega^{(i)}$  の一つの直和分解を

$$\Omega^{(i)} = \omega_0^{(i)} \oplus \omega_1^{(i)} \quad (\forall i \in \bar{m}) \quad (2.9)$$

とする。そのとき、 $\Omega^{(i)}$  のテンソル積  $\Omega$  は次のように書ける：

$$\begin{aligned} \Omega &= (\omega_0^{(1)} \oplus \omega_1^{(1)}) \otimes (\omega_0^{(2)} \oplus \omega_1^{(2)}) \otimes \cdots \otimes (\omega_0^{(m)} \oplus \omega_1^{(m)}) \\ &= (\omega_0^{(1)} \otimes \omega_0^{(2)} \otimes \cdots \otimes \omega_0^{(m)}) \oplus (\omega_1^{(1)} \otimes \omega_0^{(2)} \otimes \cdots \otimes \omega_0^{(m)}) \\ &\quad \oplus \cdots \oplus (\omega_1^{(1)} \otimes \omega_1^{(2)} \otimes \cdots \otimes \omega_1^{(m)}) \end{aligned}$$



あるいは

$$\begin{aligned}\Omega &= \bigotimes_{i=1}^m (\omega_0^{(i)} \oplus \omega_1^{(i)}) \\ &= \bigoplus_{\alpha} \bigotimes_{i=1}^m \omega_{X_{\alpha}(i)}^{(i)}.\end{aligned}\quad (2.10)$$

すなはち、演算  $\otimes$  と  $\oplus$  について分配律が成立する。ここで、 $\alpha$  は  $\bar{m}$  の任意の部分集合であり、 $\bigoplus_{\alpha}$  は  $\bar{m}$  の  $2^m$  個のあらゆる部分集合についての直和を意味するものとする。

補題2.2. 補題2.1において  $\omega_0^{(i)}$  と  $\omega_1^{(i)}$  が直交するなら ( $\forall i \in \bar{m}$ )、(2.10) の各項

$$\bigotimes_{i=1}^m \omega_{X_{\alpha}(i)}^{(i)}$$

は異なる  $\alpha \subset \bar{m}$  について互いに直交する。

補題2.3. 任意の  $i \in \bar{m}$  について、 $\Omega^{(i)}$  の任意の部分空間を  $\omega^{(i)}$ 、その次元  $\dim(\omega^{(i)})$  を  $q_i$ 、かつ  $\omega^{(i)}$  のある基底を  $\{\underbrace{\omega}_{k_i^{(i)}}, \forall k_i \in \bar{q}_i\}$

とする。そのとき、基底間のあらゆる組のベクトルの直積の集合

$$S = \left\{ \bigotimes_{i=1}^m \underbrace{\omega}_{k_i^{(i)}}, \forall k_i \in \bar{q}_i, \forall i \in \bar{m} \right\} \quad (2.11)$$

を作れば、 $S$  はテンソル積

$$\omega = \bigotimes_{i=1}^m \omega^{(i)}$$

の基底となる。また、 $\omega$  の次元は



$$\dim(\omega) = \prod_{i=1}^m \dim(\omega^{(i)}) = \prod_{i=1}^m q_i \quad (2.12)$$

で与えられる。

注意. この補題で,  $q_i = r_i (\forall i \in \bar{m})$ , すなはち  $\omega^{(i)} \in \Omega^{(i)}$  のものとすれば,  $\Omega^{(i)}$  の基底  $\{\tilde{u}_i^{k_i(i)}, \forall k_i \in \bar{r}_i\}$  を与えて, テンソル積  $\Omega$  の基底

$$S = \left\{ \otimes_{i=1}^m \tilde{u}_i^{k_i(i)}, \forall k_i \in \bar{r}_i, \forall i \in \bar{m} \right\}$$

を作りうるが、逆にテンソル積  $\Omega$  で,  $S$  を基底とするベクトル空間として、定義することも可能である。

補題2.4. Kronecker積についても、補題2.1と同様に、分配律が成り立つ。すなはち

$$\begin{aligned} U &= \otimes_{i=1}^m (U_0^{(i)} + U_1^{(i)}) \\ &= \sum_{\alpha} \otimes_{i=1}^m U_{X_{\alpha}(i)}^{(i)} \end{aligned}$$

ここで、 $U_0^{(i)}$  と  $U_1^{(i)}$  は各レジストに同じ寸法の行列であり、 $\sum_{\alpha}$  は  $\bar{m}$  のあらゆる部分集合についての和を意味する。

補題2.5. Kronecker積  $U = \otimes_{i=1}^m U^{(i)}$  の階数 (rank) は

$$\text{rank } U = \prod_{i=1}^m \text{rank } U^{(i)} \quad (2.13)$$

で与えられる。二つの Kronecker 積。

$$U = \otimes_{i=1}^m U^{(i)}, \quad V = \otimes_{i=1}^m V^{(i)}$$



について、普通の行列積  $\mathbf{U}^{(i)} \mathbf{V}^{(i)}$  が可能なら ( $\forall i \in \bar{m}$ )

$$\mathbf{U} \mathbf{V} = \bigotimes_{i=1}^m (\mathbf{U}^{(i)} \mathbf{V}^{(i)}) \quad (2.14)$$

が成り立つ。 $\mathbf{U}$  の転置について、 $\mathbf{U}' = \bigotimes_{i=1}^m (\mathbf{U}^{(i)'}')$  が成り立つ。

以上の準備にもとづいて、本論で用いる‘効果’の概念を定義する。

定義2.1. 効果空間。あるベクトル  $\underline{u}^{(i)} \in \mathbb{U}^{(i)}$  ( $\forall i \in \bar{m}$ ) が与えられ、その  $\underline{u}^{(i)}$  が張る  $\mathbb{U}^{(i)}$  の部分空間を  $\text{span}(\underline{u}^{(i)})$  と書いて、これを  $W_0^{(i)}$  すなむち、

$$W_0^{(i)} = \text{span}(\underline{u}^{(i)}) \quad (2.15)$$

とする。また、 $W_0^{(i)}$  の  $\mathbb{U}^{(i)}$  に囲まれた直交補空間を  $W_1^{(i)}$  とする。このとき、 $\bar{m}$  の任意の部分集合  $\alpha$  に対し、

$$\mathbb{U}(\alpha) = \bigotimes_{i \in \alpha} W_{X_\alpha(i)}^{(i)} \quad (2.16)$$

によって与えられる  $\mathbb{U}$  の部分空間  $\mathbb{U}(\alpha)$  を  $\alpha$ -効果空間と定義する。

注意.  $\alpha$ -効果空間は部分集合  $\alpha$  のほかに、 $\underline{u}^{(i)}$  ( $\forall i \in \bar{m}$ ) の与え方に依存し、 $\mathbb{U}(\alpha | \underline{u}^{(i)})$  とでも書くべきところであるが、本章では  $\underline{u}^{(i)}$  が与えられたものとして  $\mathbb{U}(\alpha)$  とだけ書く。ただし、 $\underline{u}^{(i)}$  ( $\forall i \in \bar{m}$ ) はゼロベクトルではないものとする。

定理2.1. すべての  $\alpha \subset \bar{m}$  に対する  $\alpha$ -効果空間は  $\mathbb{U}$  の直交直和分解を与える。また、 $\alpha$ -効果空間  $\mathbb{U}(\alpha)$  の次元は



$$\dim(\Omega(\alpha)) = \prod_{i \in \alpha} (r_i - 1) \quad (2.17)$$

で与えられる。 $\prod_{i \in \alpha}$  は  $\alpha$  に含まれる  $i$  について積とし、 $\alpha$  が空集合なら 1 とする。

証明. 前者は補題 2.1 と 2.2 から明らかである。 $(2.15)$  で与えられる  $\omega_{\alpha}^{(i)}$  の次元は 1 であるから、補題 2.3 の  $(2.12)$  によると

$$\dim(\Omega(\alpha)) = \prod_{i=1}^m \dim(\omega_{\chi_{\alpha(i)}}^{(i)})$$

$$= \prod_{i \in \alpha} (r_i - 1)$$

となり、後者が証明される。 |

定義 2.2.  $\alpha$ -因子効果. 多重配列構造を持つ母数  $A$  をテンソル積  $\Omega$  に属するベクトルとすると、 $A$  の  $\alpha$ -効果空間  $\Omega(\alpha)$  の成分を（ベクトル  $\underline{u}^{(i)} (\forall i \in \bar{m})$  に相対的な） $A$  の  $\alpha$ -因子効果と定義する。これを  $B(\alpha)$  と書く。ここで、成分とは直交射影成分を意味する。

注意.  $B(\alpha)$  は  $A$  と同一の多重配列構造を持つ。 $B(\alpha)$  の一つの表現は次の定理で与えられる。

定理 2.2. 与えられたベクトル  $\underline{u}^{(i)} \in \Omega^{(i)} (\forall i \in \bar{m})$  について

$$U_0^{(i)} = \frac{1}{\underline{u}^{(i)}, \underline{u}^{(i)}} \underline{u}^{(i)} \underline{u}^{(i)'} \quad (2.18)$$

$$U_1^{(i)} = I_{r_i} - U_0^{(i)} \quad (2.19)$$

によって、 $r_i \times r_i$  の行列  $U_0^{(i)}$  と  $U_1^{(i)}$  を作る。ここで  $I_{r_i}$  は  $r_i \times$



$r_i$  の単位行列である。そのとき、任意の  $\alpha \subset \bar{m}$  について  $A$  の  $\alpha$ -因子効果  $B(\alpha)$  は次式で与えられる：

$$\tilde{B}(\alpha) = \left( \bigotimes_{i=1}^m U_{x_\alpha(i)}^{(i)} \right) \tilde{A}. \quad (2.20)$$

証明. 任意の  $i \in \bar{m}$  について、 $U_0^{(i)}$  と  $U_1^{(i)}$  は次の性質を持つ：

$$\left. \begin{array}{l} U_k^{(i)} = U_k^{(i)\prime} \\ U_k^{(i)} U_k^{(i)} = U_k^{(i)} \end{array} \right\}, \quad k = 0, 1 \quad (2.21)$$

$$U_0^{(i)} U_1^{(i)} = 0. \quad (2.22)$$

これらは  $U_0^{(i)}$  と  $U_1^{(i)}$  の定義式 (2.18) と (2.19) から、ただちに証明される。従って、 $U_0^{(i)}$  は  $\mathbb{L}^{(i)}$  における  $\mathcal{U}^{(i)}$  の張る部分空間  $\omega_0^{(i)}$  への射影変換行列（射影子, projector）に、 $U_1^{(i)}$  は  $\omega_0^{(i)}$  の直交補空間  $\omega_1^{(i)}$  への射影子になつてゐる〔例えば、Halmos (1958, p.73)〕。そこで、(2.20) の右辺の左の因子を  $U(\alpha)$ 、  
と置くと、 $U(\alpha)$  は対称かつ中等な行列となる。すなはち、

$$U(\alpha) = \bigotimes_{i=1}^m U_{x_\alpha(i)}^{(i)} \quad (2.23)$$

と置くと、 $U(\alpha)$  は対称かつ中等な行列となる。すなはち、

$$\left. \begin{array}{l} U(\alpha) = U(\alpha)', \\ U(\alpha) U(\alpha) = U(\alpha). \end{array} \right\} \quad (2.24)$$

(2.24) の二つの式は補題 2.5 から、(2.21) を用ひて、ただちに導かれる。従つて、 $U(\alpha)$  が  $\mathbb{L}$  における一つの射影子であり、それが  $\mathbb{L}$  から  $\alpha$ -効



果空間への射影子であることも示される(補題2.3の基底を用いてよい).

よって、(2.20)を得る。 |

定理2.3. 多重配列  $A$  はすべての因子効果の和として表わされる。

すなはち、

$$A = \sum_{\alpha} B(\alpha). \quad (2.25)$$

また、相異なる  $\alpha$  と  $\alpha' \subset \bar{m}$  に対して  $B(\alpha)$  と  $B(\alpha')$  は直交する。

すなはち、

$$\underbrace{B(\alpha)}_{\sim}' \underbrace{B(\alpha')}_{\sim} = 0. \quad (2.26)$$

証明. 定理2.1により、すべての  $\alpha$ -効果空間は凸の直交直和分解を与えるので、 $\alpha$ -因子効果の定義2.2から、(2.25)は明らかである。また、(2.23)と補題2.5を用ひて

$$\begin{aligned} T(\alpha)' T(\alpha') &= \left( \bigotimes_{i=1}^m T_{X_{\alpha}(i)}^{(i)} \right)' \left( \bigotimes_{i=1}^m T_{X_{\alpha'}(i)}^{(i)} \right) \\ &= \bigotimes_{i=1}^m \left( T_{X_{\alpha}(i)}^{(i)} T_{X_{\alpha'}(i)}^{(i)} \right) \end{aligned}$$

と書ける。 $\alpha \neq \alpha'$  のとき、 $X_{\alpha}(i) \neq X_{\alpha'}(i)$  となるものが存在し、その  $i$  に対しては(2.22)によつて上式の因子  $T_{X_{\alpha}(i)}^{(i)} T_{X_{\alpha'}(i)}^{(i)}$  がゼロとなる。よつて、 $T(\alpha)' T(\alpha') = 0$  であり

$$\underbrace{B(\alpha)}_{\sim}' \underbrace{B(\alpha')}_{\sim} = \underbrace{A'}_{\sim} T(\alpha)' T(\alpha') \underbrace{A}_{\sim} = 0$$

すなはち、(2.26)を得る。 |



定理2.4. 多重配列  $A$  の要素の平方和は、それぞれの因子効果の平方和の総和に等しい。すなはち、

$$\tilde{A}' \tilde{A} = \sum_{\alpha} \tilde{B}(\alpha)' \tilde{B}(\alpha) \quad (2.27)$$

証明. 定理2.3の(2.25)の表現と  $B(\alpha)$  との直交性(2.26)からすぐ  $(2.27)$  が導かれる。 |

以上の議論は完全要因計画における分散分析の母数型モデルにおける周知の概念を、ベクトル  $\underline{\mu}^{(i)} \in \mathbb{R}^{(i)}$  の取り方を任意にすらというまで、一般化して構成したものである。本節におけるベクトル  $\underline{\mu}^{(i)}$  を定数ベクトル、例えは、

$$u_{\lambda_i}^{(i)} = 1, \quad \forall \lambda_i \in \bar{r}_i, \quad \forall i \in \bar{m}, \quad (2.28)$$

とすれば、本節の定理2.2~4はそのまま分散分析モデルの定理となる。

なお、 $\bar{m}$  の部分集合  $\alpha$  を具体的に与えてとき、 $\{1, 2\}$ -因子効果、 $\{1, 2, 4\}$ -因子効果などと書く。 $\alpha$  に含まれる要素数を  $k$  とするととき、総称的に  $k$  因子効果と呼ぶことがある。分散分析モデルでは、しばしば、 $k=0, 1, 2, \dots$  に応じて 総平均、主効果、1次交互作用、…、あるいは 最高次交互作用 という用語を使うので、本論でも ときに流用することとなる。



## 2.2 階層的モデル

多重分割表や完全要因計画のモデルとして、多数の  $\alpha$ -効果空間のうち適当なものをとりあげ、それらの直和の部分空間に母数が含まれるという形式をとることが多い。多重配列の母数空間の  $\alpha$ -効果空間を規定する  $\bar{m}$  の部分集合  $\alpha$  の取り方は空集合中や  $\bar{m}$  自身を含めて  $2^m$  通りの場合がある。その全体は集合の包含関係を半順序とみなすことにによって  $m$  次元ブール束 (lattice) としての代数的構造を持つことはよく知られている。その構造を  $m$  が 2, 3, 4 の場合について図 2.1 に示しておこう。図 2.1 では、東に添えてある数字列が  $\bar{m}$  の部分集合を表し、直線が 2 つの部分集合の包含関係 (下のものか上のものを含む) を示す。ここでは、 $\alpha$  の適当な集合をクラスと呼ぶ。クラスを例示する場合は  $\{\{12\}, \{34\}\}$ , あるいは中の {} を省略して  $\{12, 34\}$  などと書く。

$\bar{m}$  の部分集合のあるクラス  $\mathcal{A}$  について、すべての  $\alpha \in \mathcal{A}$  に対する  $\alpha$ -効果空間の直和を  $\Sigma[\mathcal{A}]$  と書く。すなはち

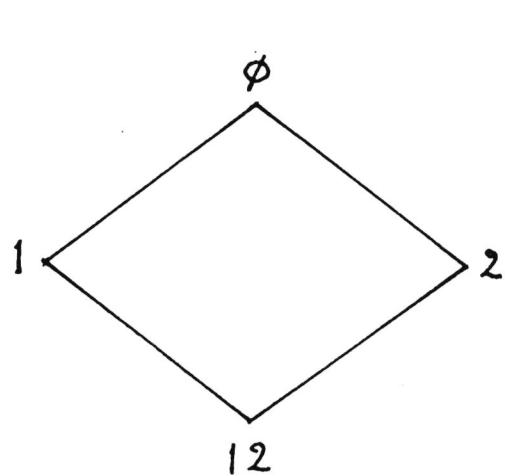
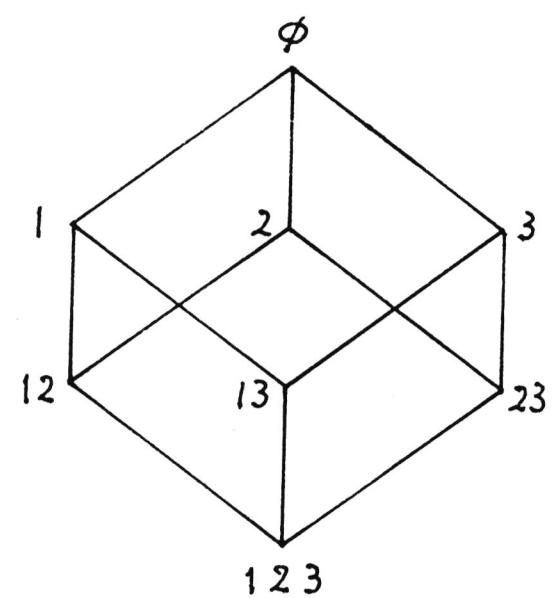
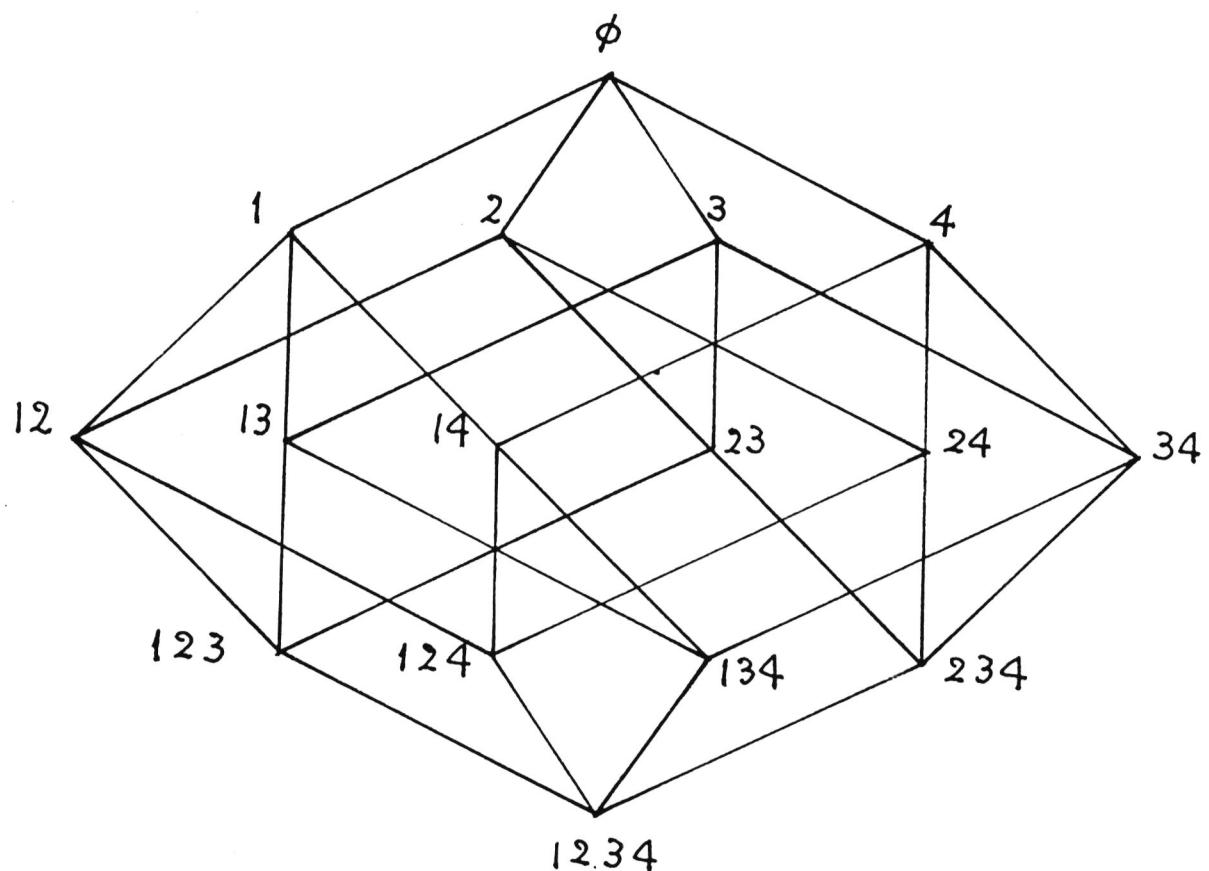
$$\Sigma[\mathcal{A}] = \bigoplus_{\alpha \in \mathcal{A}} \Sigma(\alpha) \quad (2.29)$$

である。ここでは、母数  $A$  に関するモデルを

$$A \in \Sigma[\mathcal{A}] \quad (2.30)$$

という形式で表現して、特殊なクラスとモデルとの関係を本論で述べ



(a)  $m=2$ (b)  $m=3$ (c)  $m=4$ 

Ex 2.1



要とする範囲で論じる。

定義 2.3. 生成クラス.  $\bar{M}$  の部分集合のクラス  $\mathcal{L}$  が次の条件を満たすとき、  
それを生成クラス(generating class)と呼ぶ: すなはち,  $\alpha, \alpha' \in \mathcal{L}$  の  
とき, もし  $\alpha \subset \alpha'$  なら  $\alpha = \alpha'$  が成立つ。

例 2.1. 以下の例では図 2.1 を参照されたい。

$$\mathcal{L} = \{34, 123, 124\}$$

は生成クラスである。 $\{23, 123, 124\}$  は生成クラスでない。

定義 2.4. 階層的クラス. 生成クラス  $\mathcal{L}$  によって生成されるクラス, すなはち  
 $\mathcal{L}$  の任意の要素のすべての部分集合からなるクラスを階層的クラスという。  
これを  $H(\mathcal{L})$  と書く。

例 2.2. 生成クラス

$$\mathcal{L} = \{12, 23\}$$

とすると、

$$H(\mathcal{L}) = \{\emptyset, 1, 2, 3, 12, 23\}$$

である。 $\{\emptyset, 1, 3, 12, 23\}$  は階層的でない。

なお、階層的クラス  $H(\mathcal{L})$  とその生成クラスによって、上の例では  
 $H(\mathcal{L}) = \{12/23\}$  のように、生成クラスの要素を斜線で区切って  
書く。



定義2.5. 階層的モデル. ある階層的クラスに対応するモデル:

$$A \in \Sigma[H(L)] \quad (2.31)$$

を階層的モデルという。

階層的モデルは非階層的モデルの場合より簡単な表現が可能である。

(2.31) のモデル表現を

$$\left. \begin{array}{l} A = \sum_{\forall \alpha \in H(L)} B(\alpha) \\ B(\alpha) \in \Sigma(\alpha) \end{array} \right\} \quad (2.32)$$

と書くこともできる。これに対し、生成クラス  $\mathcal{L}$  の各要素  $\alpha$  に対し

$$w(\alpha) = \bigoplus_{\forall \alpha' \subset \alpha} \Sigma(\alpha') \quad (2.33)$$

すなむち、 $w(\alpha)$  を  $\alpha$  に含まれるすべての部分集合  $\alpha'$  に関する  $\alpha'$ -効果空間の直和とし、(2.32) にかえて

$$\left. \begin{array}{l} A = \sum_{\forall \alpha \in \mathcal{L}} b(\alpha) \\ b(\alpha) \in w(\alpha) \end{array} \right\} \quad (2.34)$$

と表現することができる。一般に  $H(L)$  の要素数は  $L$  の要素にくらべてはるかに多くなるので (2.34) の表現は (2.32) より簡潔である。

例2.3. 生成クラスを例2.2 の  $\{12, 23\}$  とす。また、 $r \times s \times t$  の 3 重配列をヒリヤゲ、 $A$  の要素を  $A_{\kappa\lambda\mu}$ 、 $B(\alpha)$  と  $b(\alpha)$  につけ  $B_{\kappa\lambda\mu}^{(\alpha)}$  と  $b_{\kappa\lambda\mu}^{(\alpha)}$  と書く。そのとき、(2.32) の式は



$$A_{\kappa\lambda\mu} = B_{\kappa\lambda\mu}^{(0)} + B_{\kappa\lambda\mu}^{(1)} + B_{\kappa\lambda\mu}^{(2)} + B_{\kappa\lambda\mu}^{(3)} \\ + B_{\kappa\lambda\mu}^{(12)} + B_{\kappa\lambda\mu}^{(23)} \quad (\forall \kappa \in \bar{r}, \forall \lambda \in \bar{s}, \forall \mu \in \bar{t})$$

(2.34) の第1式は

$$A_{\kappa\lambda\mu} = b_{\kappa\lambda\mu}^{(12)} + b_{\kappa\lambda\mu}^{(23)} \quad (\forall \kappa \in \bar{r}, \forall \lambda \in \bar{s}, \forall \mu \in \bar{t})$$

となる。

(2.33) の  $\omega(\alpha)$  への  $\mathbb{Q}$  からの射影子は、 $\mathbb{Q}$  から  $\mathbb{Q}(\alpha)$  への射影子  $V(\alpha)$  [(2.23) 式] の和をヒントによって求められる。これを  $V(\alpha)$  とすると、

$$V(\alpha) = \sum_{\forall \alpha' \in H(\alpha)} V(\alpha') \\ = \bigotimes_{i=1}^m V_{X_\alpha(i)}^{(i)} \quad (2.35)$$

を得る。ここで、 $V_0^{(i)} = V_0^{(i)}$ ,  $V_1^{(i)} = I_{r_i}$ ,  $V_0^{(i)}$  は (2.18) で定義された  $\mathbb{Q}^{(i)}$  から  $\text{span}(\underline{u}^{(i)})$  への射影子である。そして、 $A$  の  $\omega(\alpha)$  への射影成分は

$$\tilde{b}(\alpha | V(\alpha)) = V(\alpha) \underset{\sim}{A} \quad (2.36)$$

によって求められる。ただし、 $V(\alpha)$  と  $V(\alpha')$  ( $\alpha \neq \alpha'$ ) は直交せず、(2.34) の  $b(\alpha)$  と (2.36) の  $b(\alpha | V(\alpha))$  によつて一意に決まるものとみなすことはできない。(2.32) の表現では  $B(\alpha)$  を (2.20) で与えることができる。(2.32) の第2式は (2.20) と同値である。



階層的モデルを採用する利点は、モデル表現の簡単化のほかに、モデルの部分空間  $\cup\{\alpha(\ell)\}$  を張る基底を簡単に求めることができること、多重分割表のセル確率をそのモデルのもとで推定する場合の都合のよさなどがある [例えば、Habermann (1974) 参照].

次に、生成クラス  $\mathcal{L}$  の分解可能性の概念を定義する.

定義2.6. 生成クラス  $\mathcal{L}$  がただ一つの集合要素から成り立つものには、 $\mathcal{L}$  が共通要素を持たない (disjoint な) 二つの分解可能なクラス  $\mathcal{L}_1$  と  $\mathcal{L}_2$  に分け、かつ  $\alpha_1 \in \mathcal{L}_1$ ,  $\alpha_2 \in \mathcal{L}_2$  が存在して

$$[\cup(\mathcal{L}_1)] \cap [\cup(\mathcal{L}_2)] = \alpha_1 \cap \alpha_2 \quad (2.37)$$

となるとき、生成クラス  $\mathcal{L}$  は分解可能であるといふ.

例2.4  $\{12\}$  は分解可能である (一つの集合要素からなる).

$$\mathcal{L}_1 = \{12, 23\}$$

は、分解可能な  $\{12\}$  と  $\{23\}$  やうなり、(2.37) の条件を満たすので分解可能な生成クラスである.

$$\mathcal{L}_2 = \{12, 13, 23\}$$

は分解可能でない.

$$\mathcal{L}_3 = \{34, 123, 124\}$$

は分解可能でない.



定義2.7. 分解型モデル. 分解可能な生成クラス $\mathcal{L}$ に対する階層的モデルを分解型(あるいは, closed form)モデルと呼ぶ.

定義2.8. 生成クラス $\mathcal{L}$ が空でない二つのクラス $\mathcal{L}_1$ と $\mathcal{L}_2$ に分解され

$$(\cup \mathcal{L}_1) \cap (\cup \mathcal{L}_2) = \emptyset \quad (2.38)$$

となるとき, その $\mathcal{L}$ に対するモデルを部分独立モデルという. とくに,  $\mathcal{L} = \{1, 2, \dots, m\}$ のときは, それに対するモデルを相互独立モデルといふ.

定義2.9. 生成クラス $\mathcal{L}$ のすべての要素の共通部分が空でないと, その共通部分を $\alpha_0$ とする. すなはち

$$\alpha_0 = \cap \mathcal{L} (\neq \emptyset)$$

そのとき,  $\mathcal{L}$ の各要素から $\alpha_0$ を除いたクラスに対するモデルを部分独立モデルであれば,  $\mathcal{L}$ に対するモデルを $\alpha_0$ について条件独立モデルと呼ぶ.

例2.5.  $m=3$ の場合について整理しておこう.  $\mathcal{L}$ が $\{1, 2, 3\}$ であるとき 相互独立モデル,  $\mathcal{L}$ が $\{1, 23\}, \{2, 13\}, \{3, 12\}$ のいずれかの場合 部分独立モデル,  $\mathcal{L}$ が $\{12, 13\}, \{12, 23\}, \{13, 23\}$ のいずれかのときは 条件独立モデルが作られる.  $\mathcal{L}$ が $\{12, 13, 23\}$ のときは 上記いずれのモデルでもなく 連関モデルと呼んでおく.  $\mathcal{L}$ が $\{123\}$ のときは, しばしば飽和モデルといわれる.



### 2.3 内積の一般化

多重分割表における加法モデルや Lancaster (1967) による多次元分布の正準表現に関するベクトル空間を論じるには、2.1節で用いた内積の定義 (2.1) を一般化しておく必要がある。そこで、多重配列のオレ指標に対応するベクトル空間  $\mathbb{U}^{(i)}$  における内積を次のように定義する：二つのベクトル  $\underline{u}^{(i)}, \underline{v}^{(i)} \in \mathbb{U}^{(i)}$  に対して、その内積を

$$\begin{aligned} (\underline{u}^{(i)}, \Sigma^{(i)} \underline{v}^{(i)}) &= \underline{u}^{(i)'} \Sigma^{(i)} \underline{v}^{(i)} \\ &= \sum_{\lambda_i, \lambda'_i} c_{\lambda_i \lambda'_i} u_{\lambda_i}^{(i)} v_{\lambda'_i}^{(i)} \quad (\forall i \in \bar{m}) \end{aligned} \quad (2.40)$$

とする。ここで、 $\Sigma^{(i)} = (c_{\lambda_i \lambda'_i}^{(i)})$  は  $r_i \times r_i$  の正値対称行列で  $\mathbb{U}^{(i)}$  とに与えられるものとする。現実的应用では  $\Sigma^{(i)}$  を対角行列にとることが多い。

2.1節にならって、

$$\underline{u} = \otimes_{i=1}^m \underline{u}^{(i)}, \quad \underline{v} = \otimes_{i=1}^m \underline{v}^{(i)}$$

とし、 $\Sigma^{(i)} (\forall i \in \bar{m})$  の Kronecker 積を  $\Sigma$  、すなむち

$$\Sigma = \otimes_{i=1}^m \Sigma^{(i)} \quad (2.41)$$

と置く。次の補題は補題2.5から容易に導かれる。

補題2.6. 次式が成立つ：

$$\underline{u}' \Sigma \underline{v} = \prod_{i=1}^m (\underline{u}^{(i)'} \Sigma^{(i)} \underline{v}^{(i)}). \quad (2.42)$$

補題2.7.  $\Sigma$  は正値対称行列である。



以上の補題から、 $\Sigma^{(i)}$  ( $\forall i \in \bar{m}$ ) のテンソル積空間  $\Sigma$  では、 $A, B \in \Sigma$  に対し、(2.41) の  $\Sigma$  を用いて

$$\underline{A}' \Sigma \underline{B} \quad (2.43)$$

によって、その内積を定義することができる。そこで、 $\underline{A}' \Sigma \underline{B} = 0$  となるとき、 $\underline{A}$  と  $\underline{B}$  は  $\Sigma$ -直交であるといふ。同様に、二つのベクトル  $\underline{u}^{(i)}, \underline{v}^{(i)} \in \Sigma^{(i)}$  が  $\underline{u}^{(i)'} \Sigma^{(i)} \underline{v}^{(i)} = 0$  となるとき、 $u^{(i)}$  と  $v^{(i)}$  は  $\Sigma^{(i)}$ -直交であるといふ。次に  $\Sigma^{(i)\frac{1}{2}}$  を次式を満足する  $r_i \times r_i$  の正則行列とする：

$$(\Sigma^{(i)\frac{1}{2}})' (\Sigma^{(i)\frac{1}{2}}) = \Sigma^{(i)} \quad (\forall i \in \bar{m}) \quad (2.44)$$

その存在は  $\Sigma^{(i)}$  の正直対称性の仮定から保証される。

$$\Sigma^{\frac{1}{2}} = \otimes_{i=1}^m (\Sigma^{(i)\frac{1}{2}}) \quad (2.45)$$

と置くと、

$$(\Sigma^{\frac{1}{2}})' (\Sigma^{\frac{1}{2}}) = \Sigma$$

となることは、補題 2.5 から明らかである。同様に、逆行列についても

$$\left. \begin{aligned} (\Sigma^{\frac{1}{2}})^{-1} &= \Sigma^{-\frac{1}{2}} = \otimes_{i=1}^m (\Sigma^{(i)-\frac{1}{2}}) \\ (\Sigma^{-\frac{1}{2}})' (\Sigma^{-\frac{1}{2}}) &= \Sigma^{-1} \end{aligned} \right\} \quad (2.46)$$

が成り立つ。

さて、テンソル積  $\Sigma$  に属する多重配列  $A$  を

$$\bar{A} = \Sigma^{\frac{1}{2}} \underline{A} \quad (2.47)$$



と変換し、 $\bar{A}$ の空間を $\bar{\Omega}$ とする。これを形式的に

$$\bar{\Omega} = \sum^{\frac{1}{2}} \Omega \quad (2.48)$$

と書き、同様の意味で

$$\bar{\Omega}^{(i)} = \sum^{(i)\frac{1}{2}} \Omega^{(i)} \quad (\forall i \in \bar{m}) \quad (2.49)$$

とすると、 $\bar{\Omega}$ は $\Omega^{(i)}$ のテンソル積である。 $\bar{\Omega}^{(i)}$ での内積は、任意の  
 $w^{(i)}, x^{(i)} \in \bar{\Omega}^{(i)}$ に対し、(2.49)の変換によってそれそれに對応する

$$\underline{w}^{(i)} = \sum^{-\frac{1}{2}} \underline{w}^{(i)} \quad (2.50)$$

$$\underline{x}^{(i)} = \sum^{-\frac{1}{2}} \underline{x}^{(i)}$$

から

$$(w^{(i)}, x^{(i)}) = \underline{w}^{(i)'} \underline{x}^{(i)} = \underline{w}^{(i)} \sum^{(i)} \underline{x}^{(i)} \quad (2.51)$$

となる。そこで、 $\bar{\Omega}$ と $\bar{A}$ について;  $w^{(i)} \in \bar{\Omega}^{(i)} (\forall i \in \bar{m})$ をとる  
ときの $\bar{\Omega}$ の $\alpha$ -効果空間、 $\bar{A}$ の $\alpha$ -因子効果を2.1節の議論に従って  
求めようとする。

いま、 $\underline{w}^{(i)} \in \bar{\Omega}^{(i)} (\forall i \in \bar{m})$ が与えられたとする。簡単のために

$$\underline{w}^{(i)'} \underline{w}^{(i)} = 1 \quad (\forall i \in \bar{m}) \quad (2.52)$$

としておく。この $\underline{w}^{(i)}$ から射影子

$$\left. \begin{aligned} W_0^{(i)} &= w^{(i)} w^{(i)'} \\ W_1^{(i)} &= I_{r_i} - W_0^{(i)} \end{aligned} \right\} \quad (2.53)$$



を定義しておく。定理2.2と2.3から

$$\tilde{A} = \sum_{\alpha} \left( \otimes_{i=1}^m W_{X_{\alpha}(i)}^{(i)} \right) \tilde{A}$$

を得る。上式  $\tilde{A} < \Sigma^{\frac{1}{2}} A$  [(2.47)式] を代入し、両辺に  $\Sigma^{-\frac{1}{2}}$  を乗じて、

$$A = \Sigma^{-\frac{1}{2}} \sum_{\alpha} \left( \otimes_{i=1}^m W_{X_{\alpha}(i)}^{(i)} \right) \Sigma^{\frac{1}{2}} A$$

を得る。3=2<sup>o</sup> (2.45), (2.46), (2.50) を用い、これらに  $\bar{U}_0^{(i)} + \bar{U}_1^{(i)}$  を

$$\begin{aligned} \bar{U}_0^{(i)} &= (\Sigma^{(i)})^{-\frac{1}{2}} \underline{w}^{(i)} \underline{w}^{(i)\prime} (\Sigma^{(i)})^{\frac{1}{2}} \\ &= \underline{u}^{(i)} \underline{u}^{(i)\prime} \Sigma^{(i)} \\ \bar{U}_1^{(i)} &= I_{r_i} - \bar{U}_0^{(i)} \end{aligned} \quad \left. \right\} \quad (2.54)$$

としておくと、

$$\tilde{A} = \sum_{\alpha} \left( \otimes_{i=1}^m \bar{U}_{X_{\alpha}(i)}^{(i)} \right) A \quad (2.55)$$

を得る。上式の各項を  $B(\alpha; \Sigma)$ , 3を用ひ

$$\tilde{B}(\alpha; \Sigma) = \otimes_{i=1}^m \bar{U}_{X_{\alpha}(i)}^{(i)} A \quad (2.56)$$

と置くと、 $B(\alpha; \Sigma)$  は  $\Sigma$  が  $\Sigma$ -直交であることを示す。従って、定理2.4の平方和分解は

$$\tilde{A}' \Sigma \tilde{A} = \sum_{\alpha} \tilde{B}(\alpha; \Sigma)' \Sigma \tilde{B}(\alpha; \Sigma) \quad (2.57)$$

に帰着する。

第3章以後では、多重配列  $A$  を  $\underline{u}^{(i)} \in \Sigma^{(i)}$  ( $\forall i \in \bar{m}$ ) についての多重一次



形式

$$\sum_{\lambda_1 \dots \lambda_m} A_{\lambda_1 \lambda_2 \dots \lambda_m} \underline{u}_{\lambda_1}^{(1)} \underline{u}_{\lambda_2}^{(2)} \dots \underline{u}_{\lambda_m}^{(m)} = \underline{\underline{A}}' \underline{\underline{u}} \quad (2.58)$$

の様数を考える。そのとき、 $A$ はテンソル積の双対(dual)空間の要素とみなされ、従って、 $\underline{\underline{u}}^{(i)}$ での内積を(2.40)で定義したときは、 $\underline{\underline{u}}$ の双対空間では $\Sigma$ の逆行列 $\Sigma^{-1}$ を用いて内積を定義することになる。そこで、

変換

$$\underline{\underline{\hat{A}}} = (\Sigma^{-\frac{1}{2}})' \underline{\underline{A}} \quad (2.59)$$

を(2.47)のかゆりに用いればこれまでの議論が平行して適用される。なむに、 $\underline{\underline{u}}^{(i)}$ と $\underline{\underline{w}}^{(i)}$ についてはこれまでどおりとなる[(2.50), (2.52)参照]。そして、(2.54)の $\bar{U}_0^{(i)}$ と $\bar{U}_1^{(i)}$ に対応して、 $\hat{U}_0^{(i)}$ と $\hat{U}_1^{(i)}$ と

$$\left. \begin{aligned} \hat{U}_0^{(i)} &= \Sigma^{(i)} \underline{\underline{u}}^{(i)} \underline{\underline{u}}^{(i)\prime} \\ \hat{U}_1^{(i)} &= I_{r_i} - \hat{U}_0^{(i)} \end{aligned} \right\} \quad (\forall i \in \bar{m}) \quad (2.60)$$

となると、(2.55)に対応して

$$\underline{\underline{\hat{A}}} = \sum_{\alpha} (\otimes_{i=1}^m \hat{U}_{x_{\alpha}(i)}^{(i)}) \underline{\underline{A}} \quad (2.61)$$

を得る。上式の各項を

$$\underline{\underline{B}}(\alpha; \Sigma^{-1}) = (\otimes_{i=1}^m \hat{U}_{x_{\alpha}(i)}^{(i)}) \underline{\underline{A}} \quad (2.62)$$

と置くと、 $\underline{\underline{B}}(\alpha; \Sigma^{-1})$ は基底 $\alpha$ についてかへに $\Sigma^{-1}$ 直交である。

従って、平方和の分解は

$$\underline{\underline{A}}' \Sigma^{-1} \underline{\underline{A}} = \sum_{\alpha} \underline{\underline{B}}(\alpha; \Sigma^{-1})' \Sigma^{-1} \underline{\underline{B}}(\alpha; \Sigma^{-1}) \quad (2.63)$$



という形式で行なわれる。すなはち、(2.50)の多重一次形式の値は、(2.59)

の変換と

$$\begin{aligned}\tilde{w} &= \bigotimes_{i=1}^m \tilde{w}^{(i)} = \bigotimes_{i=1}^m \Sigma^{(i)\frac{1}{2}} \tilde{u}^{(i)} \\ &= \Sigma^{\frac{1}{2}} \tilde{u}\end{aligned}$$

の変換によって、不变である。すなはち

$$\hat{A}' \tilde{w} = (\Sigma^{\frac{1}{2}} A)' \Sigma^{\frac{1}{2}} \tilde{u} = A' \tilde{u}$$

となる。

最後に、(2.54)の  $\bar{U}_0^{(i)}$  と (2.60) の  $\hat{U}_0^{(i)}$  の意味について注意にあらう。

$\bar{U}_0^{(i)}$  は 内積を (2.40) で定義された空間  $Q^{(i)}$  で ベクトル  $\tilde{u}^{(i)}$  の張り空間  $\text{span}(\tilde{u}^{(i)})$  への  $\Sigma^{(i)}$ -直交の方向への射影子になつてゐる。一方の  $\hat{U}_0^{(i)}$  は、 $\bar{U}_0^{(i)}$  を転置したもので、 $Q^{(i)}$  の双対空間において  $\text{span}(u^{(i)})$  に双対な部分空間に沿つて射影子になつてゐる。すなはち、 $\bar{U}_0^{(i)}$  と  $\hat{U}_0^{(i)}$  は 双対な射影子である [例えば、Halmos (1958)]。



### 3. 多重配列の特異値分解

この章では、二重の配列、すなはち行列の特異値分解の多重配列への拡張を試みる。与えられた多重配列の要素と係数とより多重一次形式の最大化問題から始めて、その問題の決定方程式を反復的に適用する算法を記述し、多重配列の分解表現を導く。その分解表現に対応する部分空間の次元や平方和の分解に触れ、特異値分解の諸性質を調べる。

#### 3.1 算法

前章で論じた母数空間としての $\mathbb{R}^n$ における効果空間や多重配列構造を持つ母数 $A$ の因子効果の定義は、ベクトル $\underline{\underline{u}}^{(i)} \in \mathbb{R}^{(i)}$ の選択に依存する形で一般的に与えられた。そこで、統計的に意味のあるベクトル $\underline{\underline{u}}^{(i)}$ の抽出法の一つとして、次の問題を考える。

問題1. 尺法 $r_1 \times r_2 \times \cdots \times r_m$  の $m$ 重配列 $A$ が与えられたとき、条件

$$\underline{\underline{u}}^{(i)'} \underline{\underline{u}}^{(i)} = \sum_{\lambda_i} \{ u_{\lambda_i}^{(i)} \}^2 = 1 \quad (\forall i \in \bar{m}) \quad (3.1)$$

のもとで

$$\begin{aligned} \rho &= A' \underline{\underline{u}} \\ &= \sum A_{\lambda_1 \lambda_2 \cdots \lambda_m} u_{\lambda_1}^{(1)} u_{\lambda_2}^{(2)} \cdots u_{\lambda_m}^{(m)} \end{aligned} \quad (3.2)$$

を最大にするベクトル $\underline{\underline{u}}^{(i)} \in \mathbb{R}^{(i)}$  ( $\forall i \in \bar{m}$ ) を求めること<sup>†</sup>。

<sup>†</sup> 記号で和をとる添字を省略したときは $A$ と $\underline{\underline{u}}$ の因子ごとに一致する添字について和をとるものとする。なお、 $\underline{\underline{u}} = \otimes_{i=1}^m \underline{\underline{u}}^{(i)}$  である。



ここでは、条件(3.1)を正規化条件、 $\rho$ を最高次相関関数と呼ぶ。また、 $\rho$ の上限を与える次の定理を示す。

定理3.1. 最高次相関関数  $\rho$  について、次の不等式が成り立つ：

$$\rho^2 \leq \underline{\underline{A}}' \underline{\underline{A}}. \quad (3.3)$$

等号が成立するのは、 $A$ が  $\underline{\underline{A}}$  に比例するとき、そのときに限る。

証明. Schwarz の不等式により、(3.2)から

$$\rho^2 \leq (\underline{\underline{A}}' \underline{\underline{A}}) (\underline{\underline{U}}' \underline{\underline{U}})$$

が成り立つ。正規化条件(3.1)により、補題2.6で  $\sum^{(i)} = I r_i (A_{i \in \bar{m}})$ 、 $\underline{\underline{U}} = \underline{\underline{U}}$  とすれば

$$\underline{\underline{U}}' \underline{\underline{U}} = 1 \quad (3.4)$$

となるので、以上より(3.3)が尊かれ。等号をとるための条件も Schwarz の不等式から明らかである。|

定理3.2. 問題1の解は存在する。また、その解は次の決定方程式の最大根に対応するベクトルを条件(3.1)で正規化したものである：

$$\left. \begin{aligned} \sum A_{\lambda_1 \lambda_2 \dots \lambda_m} U_{\lambda_2}^{(2)} U_{\lambda_3}^{(3)} \dots U_{\lambda_m}^{(m)} &= \rho U_{\lambda_1}^{(1)}, \\ \sum A_{\lambda_1 \lambda_2 \dots \lambda_m} U_{\lambda_1}^{(1)} U_{\lambda_3}^{(3)} \dots U_{\lambda_m}^{(m)} &= \rho U_{\lambda_2}^{(2)}, \\ \cdots & \\ \sum A_{\lambda_1 \lambda_2 \dots \lambda_m} U_{\lambda_1}^{(1)} U_{\lambda_2}^{(2)} \dots U_{\lambda_{m-1}}^{(m-1)} &= \rho U_{\lambda_m}^{(m)}. \end{aligned} \right\} \quad (3.5)$$



証明. 問題1の  $m$  個の正規化条件 (3.1) の Jacobian の階数は  $m$  で  
あり、ベクトル  $\mathbf{U}^{(i)}$  ( $\forall i \in \bar{m}$ ) のすべての要素が有界閉領域を動くことから  
問題1の解が存在し、かつ、その解が Lagrange 未定乗数法によって得ら  
れる決定方程式 (制約条件 (3.1) を含んで) の解で与えられることは既存の  
定理 [例えば、竹内 (1972, p.37) 参照] やら容易に証明される。ここで  
は 決定方程式 (3.5) を導出しておく。そこで、

$$\rho^* = \sum A_{\lambda_1 \lambda_2 \dots \lambda_m} u_{\lambda_1}^{(1)} u_{\lambda_2}^{(2)} \dots u_{\lambda_m}^{(m)} - \sum_{i=1}^m \frac{\mu_i}{2} \left( \sum \{ u_{\lambda_i}^{(i)} \}^2 - 1 \right)$$

と置く。ここで、 $\mu_i$  ( $\forall i \in \bar{m}$ ) は Lagrange 乗数である。 $\rho^*$  を変数  
 $u_{\lambda_i}^{(i)}$  ( $\forall \lambda_i \in \bar{\gamma}_i$ ,  $\forall i \in \bar{m}$ ) と乗数  $\mu_i$  ( $\forall i \in \bar{m}$ ) で偏微分して

$$\frac{\partial \rho^*}{\partial u_{\lambda_i}^{(i)}} = \sum A_{\lambda_1 \lambda_2 \dots \lambda_m} u_{\lambda_1}^{(1)} u_{\lambda_2}^{(2)} \dots u_{\lambda_m}^{(m)} - \mu_i u_{\lambda_i}^{(i)} = 0$$

$$\frac{\partial \rho^*}{\partial \mu_i} = \sum_{\lambda_i} \{ u_{\lambda_i}^{(i)} \}^2 - 1 = 0$$

を得る。ここで、今  $i$  は  $u$  の  $\lambda_i$  因子  $u_{\lambda_i}^{(i)}$  を除くことを意味する。そこで  
 $\sum \frac{\partial \rho^*}{\partial u_{\lambda_i}^{(i)}} u_{\lambda_i}^{(i)}$

と評価すれば、

$$\mu_i = \sum A_{\lambda_1 \lambda_2 \dots \lambda_m} u_{\lambda_1}^{(1)} u_{\lambda_2}^{(2)} \dots u_{\lambda_m}^{(m)} = \rho \quad (\forall i \in \bar{m}) \quad (3.6)$$

が得られ、決定方程式 (3.5) が導かれる。なお、(3.5) の式は  $\forall \lambda_i$   
 $\in \bar{\gamma}_i$  について考えられることに注意しておく。



決定方程式(3.5)の最大根を  $\rho_1$ ,  $\rho_1$ に対応するベクトルを  $\tilde{u}^{(i)}$  ( $\forall i \in \bar{m}$ ) と書く. このベクトル  $\tilde{u}^{(i)}$  ( $\forall i \in \bar{m}$ ) が得られたとき, それに用いた多重配列  $A$  の最高次交互作用, すなはち  $\bar{m}$ -因子効果を求め, それを  $\hat{A}$  とする. その  $\hat{A}$  を新しい  $m$  重配列として問題 1 を解く. この操作を反復する過程を次のように定義する.

算法 1.  $m$  重配列  $A$  が与えられたとする.

- $\hat{A} = A$  とする.
- $k = 1, 2, \dots$  について以下を反復する.
  - $\hat{A}^k$  のすべての要素がゼロなら反復を終了する.
  - $\hat{A}^k$  について決定方程式(3.5)を解く. その最大根を  $\rho_k$ , 対応するベクトルを  $\tilde{u}^{(i)}$  ( $\forall i \in \bar{m}$ ) とする. ベクトル  $\tilde{u}^{(i)}$  は正規化条件を満たすものとする.
  - $\tilde{u}^{(i)}$  ( $\forall i \in \bar{m}$ ) に関する  $\hat{A}^k$  の最高次交互作用を  $\hat{A}^{k+1}$  とする.

注意.  $\hat{A}^k$  は定理 2.2 の (2.20) を適用して

$$\hat{A}^{k+1} = \left( \bigotimes_{i=1}^m \hat{U}_i^{(i)} \right) \hat{A}^k \quad (3.7)$$

で求められる. これを  $\hat{B}(\bar{m})$  と書くこともある.  $\hat{U}_i^{(i)}$  は (2.19) に対応する射影子で,  $\hat{U}_i^{(i)}$  とともに, 条件 (3.1) により



$$\left. \begin{array}{l} \frac{k}{U_0^{(i)}} = \underbrace{\mathbf{U}^{(i)}}_{k} \underbrace{\mathbf{U}^{(i)'}_{\lambda_i}}_{k} \\ \frac{k}{U_1^{(i)}} = I_{r_i} - \underbrace{\mathbf{U}^{(i)}_{\lambda_i}}_{k} \underbrace{\mathbf{U}^{(i)'}_{\lambda_i}}_{k} \end{array} \right\} (\forall i \in \bar{m}, k=1,2,\dots) \quad (3.8)$$

で与えられる。なお、後の引用のために、 $\overset{k+1}{A}$  の添字 $i$ との定義式と  $\overset{k}{A}$ についての決定方程式を記しておく。

$$\overset{k+1}{A}_{\lambda_1 \lambda_2 \dots \lambda_m} = \sum \left[ \left( \delta_{\lambda_i \lambda'_i} - \underbrace{\mathbf{U}^{(1)}_{\lambda_i}}_{k} \underbrace{\mathbf{U}^{(1)'}_{\lambda'_i}}_{k} \right) \left( \delta_{\lambda_2 \lambda_2} - \underbrace{\mathbf{U}^{(2)}_{\lambda_2}}_{k} \underbrace{\mathbf{U}^{(2)'}_{\lambda'_2}}_{k} \right) \dots \right. \\ \left. \left( \delta_{\lambda_m \lambda'_m} - \underbrace{\mathbf{U}^{(m)}_{\lambda_m}}_{k} \underbrace{\mathbf{U}^{(m)'}_{\lambda'_m}}_{k} \right) \right] \overset{k}{A}_{\lambda'_1 \lambda'_2 \dots \lambda'_m} \quad (3.9)$$

ここで、 $\delta_{\lambda_i \lambda'_i}$  は Kronecker のデルタで  $\lambda_i = \lambda'_i$  のとき 1 で 3 の他 のときはゼロの値をとる。 $\sum$  は  $\lambda'_1, \dots, \lambda'_m$  についてとる。第  $k$  段の決定方程式は

$$\sum^k A_{\lambda_1 \lambda_2 \dots \lambda_m} \underbrace{\mathbf{U}^{(1)}_{\lambda_1}}_{k} \underbrace{\mathbf{U}^{(2)}_{\lambda_2}}_{k} \dots \underbrace{\mathbf{U}^{(m)}_{\lambda_m}}_{k} = p_k \underbrace{\mathbf{U}^{(i)}_{\lambda_i}}_{k} \quad (3.10)$$

$$(\forall \lambda_i \in \bar{Y}_i, \forall i \in \bar{m})$$

となる。

次に、算法 1 の有限性を示す。

定理 3.3. 任意の実数値配列  $A$  に対し、算法 1 は  $k$  について高々  $r$  回の反復で終了する。すなむち

$$\overset{r+1}{A}_{\lambda_1 \lambda_2 \dots \lambda_m} = 0 \quad (\forall \lambda_i \in \bar{Y}_i, \forall i \in \bar{m}) \quad (3.11)$$

となる。ここで、

$$r = \min (r_1, r_2, \dots, r_m) \quad (3.12)$$



である。

この定理の証明は以下の補題を示してから行う。

補題3.1. 任意の  $\underline{u}^{(i)} \in \mathcal{U}^{(i)}$  ( $\forall i \in \bar{m}$ ) に関する  $A$  の  $\alpha$ -因子効果  $B(\alpha)$  について、 $i \in \alpha$  なら次式が成り立つ：

$$\sum_{\lambda_i} B_{\lambda_1 \lambda_2 \dots \lambda_m}(\alpha) \cdot u_{\lambda_i}^{(i)} = 0 \quad (\forall i \in \alpha) \quad (3.13)$$

注意. (3.13) は  $\lambda_i$  を除く任意の指標の値で成立する。 (2.32) のようなモデル表現において (3.13) は 因子効果のパラメータに対する制約となることもできる。

証明.  $B(\alpha)$  を与える (2.20) の右辺の射影子

$$\bigotimes_{i=1}^m U_{X_\alpha(i)}^{(i)}$$

には、 $i \in \alpha$  なら  $U_1^{(i)}$  が含まれる。  $U_1^{(i)}$  の定義 (2.19) から

$$U_1^{(i)} \underline{u}^{(i)} = 0$$

となり、(3.13) が得られる。 |

補題3.2. 算法1で求められる  $\overset{k}{A}_{\lambda_1 \lambda_2 \dots \lambda_m} \overset{k}{\underline{u}}^{(i)}$ ,  $k = 1, 2, \dots$  について

$$\sum_{\lambda_i}^k A_{\lambda_1 \lambda_2 \dots \lambda_m} \overset{j}{u}_{\lambda_i}^{(i)} = 0 \quad (j < k) \quad (3.14)$$

及ぶ

$$\sum_{\lambda_i}^k \overset{k}{u}_{\lambda_i}^{(i)} \overset{j}{u}_{\lambda_i}^{(i)} = 0 \quad (j \neq k) \quad (3.15)$$

が 任意の  $j \in \bar{m}$  について成り立つ。

注意. (3.15) は 算法1によって  $\mathcal{U}^{(i)}$  に与れる正規直交系  $\{\overset{1}{\underline{u}}^{(i)}, \overset{2}{\underline{u}}^{(i)}, \dots,$



$\tilde{U}^{(i)}$  が得られることを示す。

証明. (3.15) は  $j$  と  $k$  について対称であるから、(3.14) と同様に  $j < k$  のときについて証明すれば十分である。証明は帰納法による。まず、 $j$  を固定する。 $k = j+1$  のとき、 $\tilde{A}^{j+1}$  は  $\tilde{A}^j$  に対する  $\tilde{U}^{(i)}$  ( $\forall i \in \bar{m}$ ) を用いたときの  $\bar{m}$ -因子効果であるから、補題3.1 によって (3.14) が成り立つ。次段での反復の決定方程式 (3.10) の両辺に  $\tilde{U}_{\lambda_i}^{(i)}$  をかけて  $\lambda_i$  について和をとる。左辺は、

$$\sum \left( \sum_{\lambda_i}^k A_{\lambda_1 \lambda_2 \dots \lambda_m} \tilde{U}_{\lambda_i}^{(i)} \right) \tilde{U}_{\lambda_1}^{(1)} \tilde{U}_{\lambda_2}^{(2)} \dots \tilde{U}_{\lambda_m}^{(m)} = \sum_{\lambda_i}^k p_k \tilde{U}_{\lambda_i}^{(i)} \tilde{U}_{\lambda_i}^{(i)}$$

したがって、(3.14) が成立すれば上式の左辺がゼロになり、その右辺がゼロ、すなはち、(3.15) を得る。よって、まず  $k = j+1$  のときは (3.14) と (3.15) が成立する。次に、 $k = j+1, \dots, k'$  まで (3.14) と (3.15) が成立すると仮定する。そのとき、(3.9) の  $k$  を  $k'$  に変え、その両辺に  $\tilde{U}_{\lambda_i}^{(i)}$  をかけて  $\lambda_i$  について和をとる。その左辺は

$$\sum_{\lambda_i}^{k'+1} A_{\lambda_1 \lambda_2 \dots \lambda_m} \tilde{U}_{\lambda_i}^{(i)}$$

である。右辺の因子で  $\lambda_i$  と  $\lambda'_i$  を添字に持つものをとり出して処理すると、

$$\begin{aligned} & \sum_{\lambda_i, \lambda'_i} \left[ (\delta_{\lambda_i \lambda'_i} - \tilde{U}_{\lambda_i}^{(i)} \tilde{U}_{\lambda'_i}^{(i)}) \tilde{A}_{\lambda'_1 \lambda'_2 \dots \lambda'_m} \tilde{U}_{\lambda'_i}^{(i)} \right] \\ &= \sum_{\lambda'_i} \tilde{A}_{\lambda'_1 \lambda'_2 \dots \lambda'_m} \tilde{U}_{\lambda'_i}^{(i)} - \left( \sum_{\lambda_i} \tilde{U}_{\lambda_i}^{(i)} \tilde{U}_{\lambda_i}^{(i)} \right) \left( \sum_{\lambda'_i} \tilde{U}_{\lambda'_i}^{(i)} \tilde{A}_{\lambda'_1 \lambda'_2 \dots \lambda'_m} \right) \end{aligned}$$

となる。仮定により、上式はゼロとなる。よって、 $j$  と  $k = k'+1$  の組に対し、



(3.14) が成り立ち、したがって (3.15) も成立する。以上の議論が特定の  $\gamma$  に依存しないことは明らかである。よって、補題が証明された。

定理 3.3 の証明。ベクトル空間  $\mathbb{U}^{(i)}$  の次元  $r_i$  の最小値である  $\gamma$  を越えて、 $A^{r+1}$  の要素でゼロでないものが存在すると仮定する。そこで、 $A^{r+1}$  について決定方程式 (3.10) を解けば、ゼロベクトルでない解  $\tilde{u}^{(i)} \in \mathbb{U}^{(i)}$  ( $\forall i \in \bar{m}$ ) が得られる。なぜなら、定理 3.2 によりその解が存在し、ゼロベクトルでは正規化条件 (3.1) を満たさないからである。補題 3.2 により、 $\tilde{u}^{(i)}, \dots, \tilde{u}^{(i)}, \tilde{u}^{(i)}$  は互いに直交する。ところが、 $r_i > \gamma$  に等しいベクトル空間  $\mathbb{U}^{(i)}$  では  $r+1$  口の互いに直交するベクトルは存在しない。よって、上記の仮定は矛盾を生じ、定理が証明された。

問題 1 はベクトル空間  $\mathbb{U}^{(i)}$  ( $\forall i \in \bar{m}$ ) のテンソル積  $\mathbb{U}$  において

$$\tilde{u} = \bigotimes_{i=1}^m \tilde{u}^{(i)}$$

の形式のベクトルで、与えられた多重配列  $A$  に相関関数の意味でもっとも近いものを求めていた。そこで、問題 1 は次の問題と同値であることが示される。

問題 2。問題 1 と同じ条件 (3.1)のもとで

$$\gamma = (\tilde{A} - P\tilde{u})'(\tilde{A} - P\tilde{u}) \quad (3.16)$$

を最小にすること。ここで、 $P$  を正としておく。



定理3.4. 問題1と問題2は同値である。すなはち、両者の解  $\underline{u}^{(i)}$  ( $\forall i \in \bar{m}$ ) は一致し、問題1の (3.2) の最大値  $\rho_1$  は問題2の解の  $\rho$  に一致する。ただし、両者の解が一意でなければ  $\underline{u}^{(i)}$  の一致性は向むけない。

証明. 任意の  $\underline{u}^{(i)} \in \Omega^{(i)} (\forall i \in \bar{m})$  に対し

$$\rho_1 \geq \underline{A}' \underline{u}.$$

ここで、 $\underline{u} = \bigotimes_{i=1}^m \underline{u}^{(i)}$  である。また、 $(\rho_1 - \rho)^2 \geq 0$  より、 $\rho_1^2 \geq 2\rho\rho_1 - \rho^2$  である。以上の不等式を用いて (3.16) を変形し

$$\begin{aligned} \gamma &= \underline{A}' \underline{A} - 2\rho \underline{A}' \underline{u} + \rho^2 \\ &\geq \underline{A}' \underline{A} - 2\rho \rho_1 + \rho^2 \\ &\geq \underline{A}' \underline{A} - \rho_1^2 \end{aligned}$$

を得る。等号の成り立つのは、 $\rho_1 = \underline{A}' \underline{u}$ 、かつ  $\rho = \rho_1$  のときに限る。よって、定理が証明された。 |

注意. 問題1の決定方程式 (3.5) の形から、 $\rho_1, \underline{u}^{(i)} (\forall i \in \bar{m})$  や (3.5) の解であるとき、 $\rho_1 = -\rho_1$  に、奇数個の i について  $\underline{u}^{(i)} = -\underline{u}^{(i)}$  に変えるのも (3.5) の解であることは明らかである。問題2の (3.16) でも  $\rho \underline{u}$  の形から同様のことかええる。問題1の  $\rho$  を最大にする要求から  $\rho_1$  は正とし、問題2でもそれに応じて  $\rho$  を正として扱う。

算法1では補題3.2の (3.15) が示すように互いに直交するベクトル群



$\underbrace{u^{(i)}}_{k}, k=1, 2, \dots, r (\forall i \in \bar{m})$  が得られる。逆に、すでに与えられた直交ベクトル群にさらに直交するという条件で  $A' \underbrace{u}_{k}$  を最大にすること問題を考えよう。

問題3. 各ベクトル空間  $\Omega^{(i)}$  で互いに正規直交する  $k-1$  ( $< r$ ) 個のベクトル

$$\underbrace{u^{(i)}}, \underbrace{u^{(i)}}, \dots, \underbrace{u^{(i)}}_{k-1} (\forall i \in \bar{m})$$

が与えられたとき、条件

$$\sum_{\lambda_i}^{\ell} u_{\lambda_i}^{(i)} u_{\lambda_i}^{(i)} = 0, \quad \ell = 1, 2, \dots, k-1 \quad (\forall i \in \bar{m}) \quad (3.17)$$

及び、条件 (3.1) のもとで、最高次相關関数  $A' \underbrace{u}_{k}$  (3.2) を最大にすくベクトル  $\underbrace{u^{(i)}}_{k} \in \Omega^{(i)} (\forall i \in \bar{m})$  を求めること。

定理3.5. 問題3の解は、

$$\underbrace{A}_k = \left( \otimes_{i=1}^m \underbrace{V_1^{(i)}}_{k-1} \right) A \quad (3.18)$$

で与えられる  $\underbrace{A}_k$  に対して問題1を解くこと、すなはち決定方程式 (3.10) を解くことによって与えられる。ここで、 $\underbrace{V_1^{(i)}}_{k-1}$  は

$$\underbrace{V_1^{(i)}}_{k-1} = I_{r_i} - \sum_{\ell=1}^{k-1} \underbrace{u^{(i)}}_{\ell} \underbrace{u^{(i)}}_{\ell}' \quad (\forall i \in \bar{m}) \quad (3.19)$$

で与えられる。

注意. (3.18) の  $\underbrace{A}_k$  は、算法1において決定方程式 (3.10) を解く部分を省略し、その代り段の反復で問題3での  $\underbrace{u^{(i)}}_{k} (\forall i \in \bar{m})$  が与えられた



とし、 $\underline{U}^{(i)}$  ( $\forall i \in \bar{m}$ ) に関する最高次交互作用を求めることが  $k-1$  回反復してどこに得られるものである。問題 3 で  $k=1, 2, \dots$  について再帰的に扱えば、算法 1 も直接にその解を与えることになる。もっとも、問題 3 で与えられたベクトル  $\underline{U}^{(i)}$ ,  $i=1, \dots, k-1$  は算法 1 の解である必要はない。

定理の証明に先立って二つの補題を示しておく。

補題 3.3. (3.18) の  $\underline{\underline{A}}^k$  は、漸化式

$$\left. \begin{aligned} \underline{\underline{A}} &= A \\ \underline{\underline{A}}^{l+1} &= \left( \otimes_{i=1}^m \frac{l}{U_1^{(i)}} \right) \underline{\underline{A}}^l, \quad l=1, 2, \dots, k-1 \end{aligned} \right\} \quad (3.20)$$

を解くことで得られる。ここで、 $\frac{l}{U_1^{(i)}}$  は  $\underline{U}^{(i)}$  を用いた射影子 (3.8) である ( $\forall i \in \bar{m}$ )。また、次の 2 式が成立する：

$$\otimes_{i=1}^m \frac{k-1}{U_1^{(i)}} = \left( \otimes_{i=1}^m \frac{k-1}{U_1^{(i)}} \right) \left( \otimes_{i=1}^m \frac{k-2}{U_1^{(i)}} \right) \cdots \left( \otimes_{i=1}^m \frac{1}{U_1^{(i)}} \right) \quad (3.21)$$

$$\frac{k-1}{U_1^{(i)}} \underline{U}^{(i)} = \underline{U}^{(i)} \quad (\forall i \in \bar{m}) \quad (3.22)$$

ここで、 $\underline{U}^{(i)}$  は条件 (3.17) を満たすベクトルである。

証明. 漸化式を解いて

$$\underline{\underline{A}} = \left( \otimes_{i=1}^m \frac{k-1}{U_1^{(i)}} \right) \left( \otimes_{i=1}^m \frac{k-2}{U_1^{(i)}} \right) \cdots \left( \otimes_{i=1}^m \frac{1}{U_1^{(i)}} \right) A$$

を得る。上式右辺の  $A$  にかかる因子が (3.19) の  $\frac{k-1}{U_1^{(i)}}$  の積に等しいことはその因子を展開すればすぐわかる。(3.22) は (3.19) の右辺に  $\underline{U}^{(i)}$



をかけて条件(3.17)を用いれば明らかである。|

注意.  $\tilde{A}$  の(3.20)の漸化式で求めても、与えられたベクトル  $\tilde{U}^{(i)}$ ,  $i=1, \dots, k-1$  の順序に依存しないことは(3.19)の  $\frac{k-1}{V_1}^{(i)}$  もう明らかである。また、 $\frac{k-1}{V_1}^{(i)}$  は  $\Sigma^{(i)}$  における  $\{\tilde{U}^{(i)}, i=1, \dots, k-1\}$  を基底とする部分空間の直交補空間への射影子になっている。

補題3.4. 条件(3.17)を満たす  $\tilde{U}^{(i)} (\forall i \in \bar{m})$  と(3.18)の  $\tilde{A}$  について、次式が成り立つ：

$$\begin{aligned} & \sum_{\lambda_1, \lambda_2, \dots, \lambda_m}^k U_{\lambda_1}^{(1)} U_{\lambda_2}^{(2)} \cdots \hat{U}_i^{(i)} \cdots U_{\lambda_m}^{(m)} \\ &= \sum_{\lambda_1, \lambda_2, \dots, \lambda_m} U_{\lambda_1}^{(1)} U_{\lambda_2}^{(2)} \cdots \hat{U}_i^{(i)} \cdots U_{\lambda_m}^{(m)} - \sum_{l=1}^{k-1} v_{il} \tilde{U}_{\lambda_i}^{(i)} \quad (\forall i \in \bar{m}) \end{aligned} \quad (3.23)$$

ここで、

$$v_{il} = \sum_{\lambda_1, \lambda_2, \dots, \lambda_m} \tilde{U}_{\lambda_i}^{(i)} U_{\lambda_1}^{(1)} U_{\lambda_2}^{(2)} \cdots \hat{U}_i^{(i)} \cdots U_{\lambda_m}^{(m)} \quad (3.24)$$

である。

証明. (3.23)の左辺は

$$(\tilde{U}^{(1)} \otimes \tilde{U}^{(2)} \otimes \cdots \otimes I_{r_i} \otimes \cdots \otimes \tilde{U}^{(m)})' \tilde{A}$$

と書ける。この式の  $\tilde{A}$  に(3.18)の右辺を代入して補題2.5を用いると

$$\begin{aligned} & (\tilde{U}^{(1)} \otimes \tilde{U}^{(2)} \otimes \cdots \otimes I_{r_i} \otimes \cdots \otimes \tilde{U}^{(m)})' \left( \otimes_{i=1}^m \frac{k-1}{V_1}^{(i)} \right) \tilde{A} \\ &= \left( \left( \tilde{U}^{(1)} \frac{k-1}{V_1}^{(1)} \right) \otimes \cdots \otimes \left( \frac{k-1}{V_1}^{(i)} \otimes \cdots \otimes \left( \tilde{U}^{(m)} \frac{k-1}{V_1}^{(m)} \right) \right) \right) \tilde{A} \end{aligned}$$

となる。そこで、(3.22)を用いて展開すれば(3.23)を得る。|



定理3.5の証明. 問題3の解が存在し、その解が Lagrange の未定乗数法を適用して得られることは問題1の場合と同じである。そこで、

$$\rho^* = \sum A_{\lambda_1 \lambda_2 \dots \lambda_m} u_{\lambda_1}^{(1)} u_{\lambda_2}^{(2)} \dots u_{\lambda_m}^{(m)} - \sum_{i=1}^m \sum_{l=1}^{k-1} (\gamma_{i,l} \sum_{\lambda_i}^l u_{\lambda_i}^{(i)} u_{\lambda_i}^{(i)}) - \frac{\mu_i}{2} \left( \sum \{ u_{\lambda_i}^{(i)} \}^2 - 1 \right)$$

と置く。ここで、 $\gamma_{i,l}$ ,  $\mu_i$  は Lagrange 乗数である。 $\rho^*$  が  $u_{\lambda_i}^{(i)}$  を偏微分して決定方程式を求めると、定理3.2の場合と同じように  $\mu_i$  は  $i$  に依らないことがわかり、

$$\sum A_{\lambda_1 \lambda_2 \dots \lambda_m} u_{\lambda_1}^{(1)} u_{\lambda_2}^{(2)} \dots u_{\lambda_m}^{(m)} - \sum_{l=1}^{k-1} \gamma_{i,l} u_{\lambda_i}^{(i)} = \rho u_{\lambda_i}^{(i)} \quad (\forall \lambda_i \in \bar{\gamma}_i, \forall i \in \bar{m}) \quad (3.25)$$

を得る。ここで、 $\gamma_{i,l}$  は (3.24) で与えられるものとなる。補題3.4によると、

(3.25) の左辺は (3.23) の左辺によって書きかえられ、決定方程式

$$\sum A_{\lambda_1 \lambda_2 \dots \lambda_m} u_{\lambda_1}^{(1)} u_{\lambda_2}^{(2)} \dots u_{\lambda_m}^{(m)} = \rho u_{\lambda_i}^{(i)}$$

を得る。上式は (3.10) にほかならない。よって、定理が証明された。|

問題3をさらに一般化して次の問題を考えることもできる。

問題4.  $\Omega^{(i)}$  の部分空間  $\omega^{(i)}$  ( $\forall i \in \bar{m}$ ) が指定されたとき、 $\underline{u}^{(i)}$  が  $\Omega^{(i)}$  の部分空間  $\omega^{(i)}$  に直交するという条件、及ぶ  $\underline{u}^{(i)}$  の正規化条件のもとで、最高次相關関数  $A' \underline{u}^{(i)}$  を最大にすること。

定理3.6.  $\omega^{(i)}$  への直交射影子  $V^{(i)}$  が与えられれば、問題4の解は



次式で与えられる  $\tilde{A}$  についての決定方程式 (3.10) の解で与えられると、

$$\tilde{A}^* = \left( \bigotimes_{i=1}^m (I_{r_i} - V^{(i)}) \right) A \quad (3.26)$$

ただし、 $V^{(i)}$  の階数は  $r_i$  より小さいものとする。

注意. 部分空間  $W^{(i)}$  の正規直交基底  $\{\tilde{u}^{(i)}_l\}, l=1, \dots, k_i - 1\}$  を与えられれば、問題 4 は問題 3 と  $k_i$  が  $i$  に依存する点を異にする。実は、定理 3.5 は 2 番目の  $k \leq k_i$  について  $i$  によって与えられるベクトルの個数を変えても成立する。部分空間の指定から  $\tilde{u}^{(i)}$  の制約条件

$$C^{(i)'} \tilde{u}^{(i)} = 0 \quad (\forall i \in \bar{m}) \quad (3.27)$$

という形で与えられることが多い。ここで、 $C^{(i)}$  は  $r_i \times k_i$  の行列である。

そのときは射影子  $V^{(i)}$  を

$$V^{(i)} = C^{(i)} (C^{(i)'} C^{(i)})^{-} C^{(i)'} \quad (3.28)$$

で与えればよい。ここで、 $X^-$  は  $X$  の一般化行列を意味する。

定理 3.6 の証明は定理 3.5 の場合と並行して議論で行えるので省略する。



### 3.2 特異値分解の性質

算法1は、 $m \geq 2$ の場合には行列の特異値分解を漸化的に表現したものにはかならず、一般には多重配列の分解を与えるものである。多重配列に対する因子効果の概念を用いてその事情を明らかにする。

まず、算法1で得られる多重配列  $\tilde{A}^k$  に対し、ベクトル  $\tilde{U}_{\alpha}^{(i)}$  ( $\forall i \in \bar{m}$ ) に相対的な  $\alpha$ -因子効果を  $\tilde{B}(\alpha)$  と書き、(2.20) にならって、これを

$$\tilde{B}(\alpha) = \left( \otimes_{i=1}^m \tilde{U}_{\alpha(i)}^{(i)} \right) \tilde{A}^k \quad (\forall \alpha \subset \bar{m}) \quad (3.29)$$

で定義する。ここで、

$$\begin{aligned} \tilde{U}_0^{(i)} &= \tilde{U}^{(i)} \tilde{U}^{(i)\top} \\ \tilde{U}_1^{(i)} &= I_{r_i} - \tilde{U}_0^{(i)} \end{aligned} \quad \left. \right\} \quad (3.30)$$

である。2.1節の最後に触れのように、 $\bar{m}$  の部分集合  $\alpha$  の要素数によって、 $\tilde{B}(\alpha)$  についても 1 因子効果、2 因子効果などとまとめることがある。また、

$$\tilde{A}^{k+1} = \tilde{B}(\bar{m})$$

であることに注意しておく。

算法1で得られる直交系  $\tilde{U}^{(i)}$ ,  $k=1, 2, \dots, r$  とそれによって定義される  $\tilde{A}^k$  の因子効果の特徴は次の定理が成り立つことである。

定理 3.7.  $\tilde{A}^k$  の 1 因子効果が消える。すなはち、 $\alpha \subset \bar{m}$  の 1 つの要素から成る部分集合  $\{j\}$  であるとき、



$$\overset{k}{\underset{j=1}{\sum}} B(\{j\}) = 0 \quad (\forall j \in \bar{m}) \quad (3.31)$$

となる。

証明,  $\alpha = \{j\}$  のとき, (3.29) で定義された  $\overset{k}{\underset{j=1}{\sum}} B(\{j\})$  は

$$\begin{aligned} \overset{k}{\underset{j=1}{\sum}} B(\{j\}) &= (\overset{k}{\underset{i=1}{\sum}} U_i^{(1)} \otimes \cdots \otimes I_{r_j} \otimes \cdots \otimes \overset{k}{\underset{i=1}{\sum}} U_i^{(m)}) \overset{k}{\underset{j=1}{\sum}} A \\ &\quad - (\overset{k}{\underset{i=1}{\sum}} U_i^{(1)} \otimes \cdots \otimes \overset{k}{\underset{i=j}{\sum}} U_i^{(j)} \otimes \cdots \otimes \overset{k}{\underset{i=1}{\sum}} U_i^{(m)}) \overset{k}{\underset{j=1}{\sum}} A \end{aligned}$$

と書ける。これを要素ごとに書いてまとめると

$$\begin{aligned} \overset{k}{\underset{j=1}{\sum}} B_{\lambda_1 \lambda_2 \cdots \lambda_m}(\{j\}) &= \overset{k}{\underset{i=1}{\sum}} u_{\lambda_1}^{(1)} \cdots \overset{k}{\underset{i=m}{\sum}} u_{\lambda_m}^{(m)} \left( \sum \overset{k}{\underset{j=1}{\sum}} A_{\lambda_1 \lambda_2 \cdots \lambda_m} \overset{k}{\underset{i=1}{\sum}} u_{\lambda_1}^{(1)} \cdots \overset{k}{\underset{i=j}{\sum}} u_{\lambda_j}^{(j)} \cdots \overset{k}{\underset{i=1}{\sum}} u_{\lambda_m}^{(m)} - g_k u_{\lambda_j}^{(j)} \right) \end{aligned}$$

となり、この式の右辺の括弧内は決定方程式 (3.10) からゼロとなる。よって、定理を得る。 |

次に、与えられた多重配列  $A$  の分解表現を  $\overset{k}{\underset{j=1}{\sum}} A$  の因子効果を用いて示す。前述の定理 3.6 によって  $\overset{k}{\underset{j=1}{\sum}} A$  の 1 因子効果が消えるので、部分集合  $\alpha$  をこれに含まれる要素数で分類し、要素数  $s$  の  $\alpha$  のクラスを  $\mathcal{S}_s$  としておく。

定理 3.8. 与えられた  $m$  重配列  $A$  を算法 1 によって、次のように分解することができる。これを特異値分解といふ。

$$\begin{aligned} \overset{k}{\underset{j=1}{\sum}} A &= A, \\ \overset{k}{\underset{j=1}{\sum}} A &= \overset{k}{\underset{j=1}{\sum}} B(\phi) + \sum_{s=2}^{m-1} \sum_{\forall \alpha \in \mathcal{S}_s} \overset{k}{\underset{j=1}{\sum}} B(\alpha) + \overset{k+1}{\underset{j=1}{\sum}} A, \quad k=1, 2, \dots, r. \end{aligned} \quad (3.32)$$



証明. 算法1の定義から  $\overset{k+1}{A}$  は  $\overset{k}{B}(\bar{m})$  であり, 定理3.6で1因子効果が消える. そして,  $\overset{k}{A}$  に定理2.3を適用すれば (3.32) の表現を得る. |

注意.  $\overset{k}{A}$  の主効果に相当する  $\overset{k}{B}(\phi)$  の要素は

$$\overset{k}{B}_{\lambda_1 \lambda_2 \dots \lambda_m}(\phi) = p_k \overset{k(1)}{U}_{\lambda_1} \overset{k(2)}{U}_{\lambda_2} \dots \overset{k(m)}{U}_{\lambda_m} \quad (3.33)$$

と書ける.  $m=2$  のとき, (3.32) は

$$\begin{aligned} A &= \sum_{k=1}^r \overset{k}{B}(\phi) \\ &= \sum_{k=1}^r p_k \overset{k(1)}{U}_{\lambda_1} \overset{k(2)}{U}_{\lambda_2} \end{aligned} \quad (3.34)$$

となり, 行列  $A$  の特異値分解に行かなければ (例えば, Forsythe & Moler (1967) 参照). この3重配列の場合を拡張すると, 一見

$$A = \sum_{k=1}^r p_k \overset{k(1)}{U}_{\lambda_1} \overset{k(2)}{U}_{\lambda_2} \overset{k(3)}{U}_{\lambda_3}$$

となりそうであるが, 一般には不可能である. 3重配列の場合は2因子効果が消えない. 補題2.3のあとに注意として述べるように, 一般に  $\mathbb{U}^{(i)}$  の基底  $\{\overset{k_i(i)}{U}, \forall k_i \in \bar{r}_i\}$  について,  $S = \{\otimes_{i=1}^m \overset{k_i(i)}{U} \mid \forall k_i \in \bar{r}_i, \forall i \in \bar{m}\}$  の  $n$  位のベクトル空間の基底となり,  $m$  重配列  $A$  はその一次結合として表現でき. そのことを要素ごとに書けば

$$A_{\lambda_1 \lambda_2 \dots \lambda_m} = \sum_{k_1} \dots \sum_{k_m} p_{k_1 \dots k_m} \overset{k_1(1)}{U}_{\lambda_1} \dots \overset{k_m(m)}{U}_{\lambda_m} \quad (3.35)$$

となる.  $A$  の  $\alpha$ -因子効果は上式右辺の  $n$  位を適当に分類してまとめ



ものになつてゐる。算法1で求めたベクトル  $\tilde{U}^{(i)}$ ,  $k=1, \dots, r \in \Omega^{(i)}$  の基底の一部とさうと,  $k_1 = \dots = k_m = k$  の項が  $\tilde{B}(\phi)$  に一つずつ対応し,  $\tilde{B}(1)$  は  $k_1 = \dots = k_m = 1$  で  $k_1$  のまゝ  $r_1$  項から  $\tilde{B}(\phi)$  を除いた  $r_1 - 1$  項が,  $\tilde{B}(\bar{m})$  には  $k_1, k_2, \dots, k_m$  が含まれて 2 以上 の項  $(r_1 - 1)(r_2 - 1) \cdots (r_m - 1)$  項が対応する。このような対応は (3.29) の  $\tilde{B}(\alpha)$  の定義から行うことができる。さらには、後述の定理3.10を参考されたい。

次に, (3.22) の分解表現に対応する平方和分解の定理を示す。

定理3.9. 与えられた  $m$  重配列  $A$  の平方和を, 算法1の結果を用いて, 次のように段階的に分解することができる:

$$\tilde{A}^k \tilde{A}^k = P_k^2 + \sum_{s=2}^{m-1} \sum_{\alpha \in S_s} \tilde{B}(\alpha)' \tilde{B}(\alpha) + \tilde{A}^{k+1} \tilde{A}^{k+1} \quad (3.36)$$

$$k = 1, 2, \dots, r$$

ここで,  $\tilde{A} = \tilde{A}^r$  である。

証明. 定理2.3 から異なる  $\alpha$  と  $\alpha'$  に対して

$$\tilde{B}(\alpha)' \tilde{B}(\alpha') = 0 \quad (3.37)$$

が成り立つ ( $k \neq 1$  のときも定理2.3のときと同じように証明される)。

よって, (3.32) の右辺の内積を整理し,  $\tilde{B}(\phi)' \tilde{B}(\phi)$  について (3.33) を  $\tilde{U}^{(i)}$  の正規化条件で変形して, (3.36) を得る。 |



この定理からただちに次の系を得る.

系3.1  $\rho_k^2$  の上限は次の不等式で与えられる:

$$\rho_k^2 \leq \underbrace{A'}_{\text{A}} \underbrace{\frac{k}{A}}_{\text{A}}, \quad k = 1, 2, \dots, r. \quad (3.38)$$

等号が成立するのは、 $\underbrace{A}_{\text{A}}$  があるベクトル  $\underline{u} = \bigotimes_{i=1}^m \underline{u}^{(i)}$  に比例するとき、そのときに限る.

注意. この系は定理3.1に対応する. 証明は (3.36) の各項が非負であることから明らかであるので省略する.

本節の以上の議論は算法1で得られる正規直交系  $\{\underline{u}^{(i)}\}$  にもとづくものである. それに対して、それぞれのベクトル空間  $\mathbb{U}^{(i)}$  で配列  $A$  と無関係に正規直交系を与えた場合は、(3.32) と (3.36) で 1 因子効果の項を加えることによって、配列  $A$  及び その平方和の段階的な分解が与えられる. ここでは、任意に与えられた正規直交系  $\{\underline{u}^{(i)}\}$  に対して (3.29) の  $\tilde{B}(\alpha)$  の定義に対応する  $\mathbb{U}$  の部分空間  $\mathbb{W}(\alpha)$  を定義してその部分空間の次元を求めておこう. 前節の問題3のときと同様に考え、 $A$  を  $\tilde{A}$  に射影する射影子を (3.18) によって

$$\bigotimes_{i=1}^m \bigcap_{j=1}^{k-1} \mathbb{V}_j^{(i)} \quad (3.39)$$

とし、 $A$  を  $\tilde{B}(\alpha)$  に射影する射影子は (3.29) によって

$$\bigotimes_{i=1}^m \bigcap_{j=1}^k \mathbb{U}_{x_\alpha(i)}^{(i)} \quad (3.40)$$



とする。ここで、 $\sum_{i=1}^{k-1} V_i^{(i)}$  は (3.19) で、 $\sum_0^k V_0^{(i)}$  と  $\sum_1^{k-1} V_1^{(i)}$  は (3.30) で与えられていたものである。よって、 $A \in \sum_{\alpha}^k (\alpha)$  に射影する射影子は (3.39) と (3.40) の積、すなはち、

$$\left( \bigotimes_{i=1}^m \frac{k}{U_{X_\alpha(i)}} \right) \left( \bigotimes_{i=1}^m \frac{k-1}{V_1^{(i)}} \right) = \bigotimes_{i=1}^m \left( \frac{k}{U_{X_\alpha(i)}} \frac{k-1}{V_1^{(i)}} \right) \quad (3.41)$$

となる。そこで、 $\sum_{\alpha}^k (\alpha)$  を  $\Sigma$  から (3.41) の射影子によって射影される  $\Sigma$  の部分空間と定義する。 $\sum_{\alpha}^k (\alpha)$  の次元について次の定理が導かれ。

定理 3.10. それぞれのベクトル空間  $\Sigma^{(i)}$  で任意に与えられた正規直交系  $\{\underline{u}_1^{(i)}, \dots, \underline{u}_k^{(i)}\}$  ( $\forall i \in \bar{m}$ ) について射影子 (3.41) で規定された  $\Sigma$  の部分空間  $\sum_{\alpha}^k (\alpha)$  の次元は、任意の  $\alpha \in \bar{m}$  に関する

$$\dim(\sum_{\alpha}^k (\alpha)) = \prod_{i \in \alpha} (r_i - k) \quad (3.42)$$

で与えられる。

証明.  $\sum_{\alpha}^k (\alpha)$  の定義から、その次元は射影子 (3.41) の階数で与えられる。補題 2.5 やう

$$\text{rank} \left[ \bigotimes_{i=1}^m \left( \frac{k}{U_{X_\alpha(i)}} \frac{k-1}{V_1^{(i)}} \right) \right] = \prod_{i=1}^m \text{rank} \left( \frac{k}{U_{X_\alpha(i)}} \frac{k-1}{V_1^{(i)}} \right).$$

一方、 $\frac{k}{U_{X_\alpha(i)}} \frac{k-1}{V_1^{(i)}}$  はそれぞれの定義 (3.30), (3.19) より

$$\frac{k}{U_{X_\alpha(i)}} \frac{k-1}{V_1^{(i)}} = \begin{cases} \frac{k}{V_1^{(i)}} = I_{r_i} - \sum_{i=1}^k \underline{u}_i^{(i)} \underline{u}_i^{(i)\top}, & i \in \alpha \text{ のとき}, \\ \frac{k}{U_0} = \underline{u}_0^{(i)} \underline{u}_0^{(i)\top}, & i \notin \alpha \text{ のとき} \end{cases} \quad (3.43)$$

となり、その階数は



$$\text{rank} \left( \begin{smallmatrix} k & V_{\alpha(i)}^{(i)} & V_1^{(i)} \\ U_{\alpha(i)}^{(i)} & 1 & 1 \end{smallmatrix} \right) = \begin{cases} r_i - k, & i \in \alpha \text{ のとき}, \\ 1, & i \notin \alpha \text{ のとき} \end{cases} \quad (3.44)$$

で与えられ、よって、(3.42)を得る。

注意. 要因計画のモデルでは  $\tilde{W}(\alpha)$  の次元を平方和  $\tilde{B}(\alpha)^T \tilde{B}(\alpha)$  の自由度 (degrees of freedom) と呼ぶ。算法 1 を用いる場合は総平均に相当する  $p_k$  を最大にし、主効果に相当する  $\tilde{B}(\{j\}) (\forall j \in \bar{m})$  をゼロにするようにベクトル  $\tilde{U}^{(i)}$  を求めている。その場合、 $p_k^2$  に対する自由度は  $\tilde{U}^{(i)}$  の数学的に独立なパラメータの個数を加えて

$$\sum_{i=1}^m r_i - m k + 1 \quad (3.45)$$

とすべきであろう。これは 総平均と 1 因子効果の平方和に対する自由度をまとめたものともいえる。

最後に、多重配列の一般的分解表現である (3.35) の右辺の  $n$  項のうち、特異値分解 (3.32) によって消える  $\tilde{B}(\{j\})$ ,  $\forall j \in \bar{m}$  に相当する項数を示しておこう。それは  $\alpha = \{j\}$ ,  $\forall j \in \bar{m}$  に対する  $\tilde{W}(\alpha)$  の次元数に等しい。そのことは射影子 (3.41) や (3.35) の右辺にかけ算によつてわかる。 $k = 1, 2, \dots, r$  についての  $\dim(\tilde{W}(\{j\}))$  ( $\forall j \in \bar{m}$ ) の和は簡単な計算で求まる。シグマは  $r_1 = \dots = r_m = r$  としてこの結果のみを示しておく。求める項数は



$$m \frac{r(r-1)}{2}$$

となる。これに対する全項数は  $r^m$  であり、 $m=2$  のときは  $r$  項のみが残り、(3.34) の行列の特異値分解の項数に一致する。 $m$  と  $r$  のいくつかの値について、上記の数を表3.1 に示しておく。

表 3.1.

$m$	$r$	$r^m$	$mr(r-1)/2$	残り
2	$r$	$r^2$	$r^2 - r$	$r$
3	2	8	3	5
3	5	125	30	95
3	10	1000	135	865
4	2	16	4	12
4	5	625	40	585



## 4. 多重分割表への応用 (I)

前章までに論じた多重配列の分解と多重分割表データの解析のためのモデルとの関係を述べる。また、多重分割表における従来の主要なモデルである加法モデルと対数線形モデルをとりわけ、次に平方根モデルを論じる。

### 4.1. 加法モデルと対数線形モデル

多重分割表に関する研究では、その項目間の高次の交互作用をどういうモデルで表現するかが、1.3節で述べたように、長らく問題にされてきている。その問題から代表的なモデルとして、対数線形モデル(log-linear model)や加法モデル(additive model)が生まれている。ここでは、 $r \times s \times t$  分割表をとりわけ、これらのモデルと前章までに論じた多重配列構造を持つ母数空間との関係を調べる。

$r \times s \times t$  分割表のセル度数、対応するセル確率、及びセル度数の期待値をそれぞれ

$$x_{ijk}, p_{ijk}, m_{ijk}, \\ (\forall i \in \bar{r}, \forall j \in \bar{s}, \forall k \in \bar{t})$$

と書く。これらの量の周辺和を示すのに

$$x_{ij+} = \sum_k x_{ijk}, \quad x_{i++} = \sum_j x_{ij+}, \quad x_{+++} = \sum_i x_{i++}$$



のように和をとる添字の位置に + をつける。セル度数の総和  $x_{+++}$  をとくに  $N$  とする。小文字の  $n$  はセルの総数  $r \cdot s \cdot t$  に用いる。

本節では、セル確率  $p_{ijk}$  ( $\forall i \in \bar{r}$ ,  $\forall j \in \bar{s}$ ,  $\forall k \in \bar{t}$ ) を基本的な母数として以下のモデルの記述に用いる。セル確率は非負で、

$$p_{+++} = 1 \quad (4.1)$$

すなむち、総和が 1 である。

さて、本節で論じる加法モデルは多重配列母数  $A$  を

$$A = (p_{ijk}) \quad (\forall i \in \bar{r}, \forall j \in \bar{s}, \forall k \in \bar{t}) \quad (4.2)$$

としてときの、対数線形モデルは  $A$  を

$$A = (\log p_{ijk}) \quad (\forall i \in \bar{r}, \forall j \in \bar{s}, \forall k \in \bar{t}) \quad (4.3)$$

として場合の線形モデルに行かならない。次節ではセル確率の平方根を母数とする平方根モデル、すなむち

$$A = (\sqrt{p_{ijk}}) \quad (\forall i \in \bar{r}, \forall j \in \bar{s}, \forall k \in \bar{t}) \quad (4.4)$$

の場合を扱う。

a) 加法モデル 3種の添字に対応するベクトル空間  $\Sigma^{(1)}$ ,  $\Sigma^{(2)}$ , および  $\Sigma^{(3)}$  における内積を次のような対角行列を重み  $w$  とし (2.40) で定義する。

$$\left. \begin{aligned} \Sigma^{(1)} &= \text{diag } (p_{i++}) \\ \Sigma^{(2)} &= \text{diag } (p_{+j+}) \end{aligned} \right\} \quad (4.5)$$



$$\Sigma^{(3)} = \text{diag}(\bar{p}_{r+s}) \quad |$$

以下、2.3節の後半の議論に従って、まず、(2.59)の変換を用い、

$$\hat{A}_{ijk} = \frac{\bar{p}_{ijk}}{\sqrt{\bar{p}_{i+r}} \sqrt{\bar{p}_{j+s}} \sqrt{\bar{p}_{k+t}}} \quad (\forall i \in \bar{r}, \forall j \in \bar{s}, \forall k \in \bar{t}) \quad (4.6)$$

とおく。この $\hat{A}$ に対する因子効果を定義するベクトル $\underline{w}^{(1)}, \underline{w}^{(2)}, \underline{w}^{(3)}$

と

$$\left. \begin{array}{l} w_i^{(1)} = \sqrt{\bar{p}_{i+r}} \quad (\forall i \in \bar{r}) \\ w_j^{(2)} = \sqrt{\bar{p}_{j+s}} \quad (\forall j \in \bar{s}) \\ w_k^{(3)} = \sqrt{\bar{p}_{k+t}} \quad (\forall k \in \bar{t}) \end{array} \right\} \quad (4.7)$$

とす。この $\underline{w}^{(1)}, \underline{w}^{(2)}, \underline{w}^{(3)}$ の変換(2.50)によるベクトル $\underline{u}^{(1)}, \underline{u}^{(2)}, \underline{u}^{(3)}$ である。

$$u_i^{(1)} = 1 \quad (\forall i \in \bar{r}), \quad u_j^{(2)} = 1 \quad (\forall j \in \bar{s}), \quad u_k^{(3)} = 1 \quad (\forall k \in \bar{t}) \quad (4.8)$$

と、すべての要素が1にならうことが特徴である。

このように定義された $\{\hat{A}, \underline{w}^{(1)}, \underline{w}^{(2)}, \underline{w}^{(3)}\}$ あるいは $\{A = (p_{ijk}), \underline{u}^{(1)}, \underline{u}^{(2)}, \underline{u}^{(3)}, \Sigma^{(1)}, \Sigma^{(2)}, \Sigma^{(3)}\}$ によって構成される一連のモデル(2.2節、(2.30)参照)を $r \times s \times t$ 分割表の加法モデルと呼ぶ。そこで、 $\hat{A}$ の $\alpha$ -因子効果を $\hat{B}(\alpha)$ 、 $\hat{B}(\alpha)$ と(4.6)によって $\bar{p}_{ijk}$ の分解に変換したもの $B(\alpha)$ と書いて、それらの表現を示しておこう。



ここで、記述の簡単のために、

$$g_{ijk} = p_{i++} p_{+j+} p_{++k} \quad (4.9)$$

とかき、 $\alpha = \phi, \{1\}, \{12\}, \{123\}$  などに対する略式に  $\hat{B}(\phi)$ ,  $\hat{B}(1)$ ,  $\hat{B}(12)$ ,  $\hat{B}(123)$  と書く。 $\alpha$ -因子効果の定義(2.20)を適用して次式を得る：

$$\hat{B}(\phi) = (\sqrt{g_{ijk}}) \quad (4.10)$$

$$\hat{B}(1) = \hat{B}(2) = \hat{B}(3) = 0 \quad (4.11)$$

$$\left. \begin{array}{l} \hat{B}(12) = (p_{ij+} p_{++k} / \sqrt{g_{ijk}}) - \hat{B}(\phi) \\ \hat{B}(13) = (p_{i+k} p_{+j+} / \sqrt{g_{ijk}}) - \hat{B}(\phi) \\ \hat{B}(23) = (p_{+jk} p_{i++} / \sqrt{g_{ijk}}) - \hat{B}(\phi) \end{array} \right\} \quad (4.12)$$

$$\hat{B}(123) = \hat{A} - \hat{B}(12) - \hat{B}(13) - \hat{B}(23) - \hat{B}(\phi) \quad (4.13)$$

ここで、 $(\sqrt{g_{ijk}})$  などは 3 重配列であることを示す。 $(4.11)$  で 1-因子効果が消えることは、 $\hat{A}$  についての決定方程式(3.5)や(4.7)のベクトル  $w^{(1)}, w^{(2)}, w^{(3)}$  で満たされることを示す。そのとき

$$g = \sum_{i,j,k} \hat{A}_{ijk} w_i^{(1)} w_j^{(2)} w_k^{(3)} = 1 \quad (4.14)$$

となる。これは(4.10)の導出に使われている。次に、 $\hat{B}(\alpha) \in B(\alpha)$  に(2.62)を用いて変換する。実は  $\hat{B}(\alpha)$  の各要素に  $\sqrt{g_{ijk}}$  をかければよい。(2.62)によれば、 $B(\alpha)$  は  $B(\alpha; \Sigma^{-1})$  と書くべきであ



るが、ここでは簡単に  $B(\alpha)$  としておく。次式を得る：

$$B(\Phi) = (g_{ijk}) = (p_{i++} p_{+j+} p_{++k}), \quad (4.15)$$

$$\left. \begin{aligned} B(12) &= ((p_{ij+} - p_{i++} p_{+j+}) p_{++k}), \\ B(13) &= ((p_{ik+} - p_{i++} p_{+k+}) p_{+j+}), \\ B(23) &= ((p_{jk+} - p_{+j+} p_{++k}) p_{i++}) \end{aligned} \right\} \quad (4.16)$$

$$\begin{aligned} B(123) &= (p_{ijk} - p_{ij+} p_{++k} - p_{ik+} p_{+j+} \\ &\quad - p_{jk+} p_{i++} + 2 g_{ijk}). \end{aligned} \quad (4.17)$$

以上の式から

$$\hat{A} = \sum_{\alpha} \hat{B}(\alpha), \quad (4.18)$$

あらわす、

$$A = (p_{ijk}) = \sum_{\alpha} B(\alpha) \quad (4.19)$$

を確定めることは容易であろう。

そもそも加法モデルは 3重分割表での 3因子効果（2次交互作用）が存在しないということを表現するためを考えられたもので [Lancaster (1951)]、(4.17) の  $B(123)$  の効果をゼロとおいて得られるモデルである。このモデルを  $H_a$  と書くと、

$$H_a: p_{ijk} = p_{ij+} p_{++k} + p_{ik+} p_{+j+} + p_{jk+} p_{i++} - 2 g_{ijk}. \quad (4.20)$$



平方和  $\hat{A}'\hat{A}$  あるいは  $\hat{A}'\Sigma^{-1}\hat{A}$  の分解は (2.63) から

$$\hat{A}'\hat{A} = \hat{A}'\Sigma^{-1}\hat{A} = \sum_{\alpha} \hat{B}(\alpha)' \Sigma^{-1} \hat{B}(\alpha) \quad (4.21)$$

で与えられる。ここで、 $\Sigma$  は  $n \times n$  の行列である

$$\Sigma = \Sigma^{(1)} \otimes \Sigma^{(2)} \otimes \Sigma^{(3)} = \text{diag}(g_{ijk}) \quad (4.22)$$

である。(4.21) は次のように書ける:

$$\begin{aligned} \sum_{i,j,k} \frac{p_{ijk}^2}{p_{i++} p_{+j+} p_{++k}} &= 1 + \sum_{i,j} \frac{(p_{ij+} - p_{i++} p_{+j+})^2}{p_{i++} p_{+j+}} \\ &\quad + \sum_{i,k} \frac{(p_{i+k} - p_{i++} p_{++k})^2}{p_{i++} p_{++k}} \\ &\quad + \sum_{j,k} \frac{(p_{+jk} - p_{+j+} p_{++k})^2}{p_{+j+} p_{++k}} \\ &\quad + \sum_{i,j,k} \frac{(p_{ijk} - a p_{ijk})^2}{p_{i++} p_{+j+} p_{++k}} \end{aligned} \quad (4.23)$$

ここで、 $a p_{ijk}$  は

$$a p_{ijk} = p_{ij+} p_{++k} + p_{irk} p_{+j+} + p_{rjk} p_{i++} - 2 g_{ijk} \quad (4.24)$$

として定められる。(4.23) の分解は、よく知られている Lancaster (1951) による  $\chi^2$  の分割にほかならない。実際、(4.23) の左辺から右辺の 1 を引いて  $N (= \chi_{++})$  倍したものは、その  $p_{ijk}$  を推定値

$$\hat{p}_{ijk} = x_{ijk}/N$$

で置きかえれば、いわゆる相互独立性の検定における  $\chi^2$  にほかならぬ



ii. その  $\chi^2$  は

$$\begin{aligned}\chi^2 &= N \left( \sum_{i,j,k} \frac{\hat{p}_{ijk}^2}{\hat{p}_{i+r} \hat{p}_{j+s} \hat{p}_{k+t}} - 1 \right) \\ &= \sum_{i,j,k} \frac{(x_{ijk} - \hat{m}_{ijk})^2}{\hat{m}_{ijk}} \quad (4.25)\end{aligned}$$

と書かれる。ここで、 $\hat{m}_{ijk} = N \hat{p}_{i+r} \hat{p}_{j+s} \hat{p}_{k+t}$  である。

モデル  $H_a$  のほかに各種の階層的モデルを考えることができると、2.2節の記法に従って、階層的クラスを  $\{1/2/3\}, \{12\}, \{12/23\}$  とすると、それらに応じたモデル

$$H_1: p_{ijk} = p_{i+r} p_{j+s} p_{k+t} \quad (4.26)$$

$$H_2: p_{ijk} = p_{i+r} p_{j+s} p_{k+t} \quad (4.27)$$

$$H_{3a}: p_{ijk} = p_{i+r} p_{j+s} p_{k+t} + p_{r+j} p_{i+r} - p_{i+r} p_{j+s} p_{k+t} \quad (4.28)$$

などと得られる。 $H_1$  を分割表の相互独立モデル、 $H_2$  を部分独立モデルという。 $H_2$  は  $H_1$  と同様に添字の入れかえによって三通りのモデルとなる。 $H_3$  は、いわゆる加法モデルでの条件独立モデルともいえようか、普通、分割表での条件独立モデルは

$$H_{3c}: p_{ijk} = \frac{p_{ij} p_{ik}}{p_{i+r}} \quad (4.29)$$

の形式のものをいう。非階層的モデルとして、 $B(13)=0$  となる



を考えると、(4.16)から

$$P_{i+k} = P_{i+\tau} P_{\tau+k} \quad (4.30)$$

を得る。このモデルを周辺独立モデルといふことがある。なお、以上の議論はより多重の分割表に拡張されることに注意しておこう。

b) 対数線形モデル 対数線形モデルは、多重配列  $A$  を

$$A = (\log p_{ijk}), \quad (4.31)$$

ベクトル  $\mu^{(1)}, \mu^{(2)}, \mu^{(3)}$  を (4.8) のようにすべての要素に 1 を与えたものとし、2.1, 2.2 節の記述に従って定義されたものである。その飽和型は

$$\log p_{ijk} = \mu + \mu_i^{(1)} + \mu_j^{(2)} + \mu_k^{(3)} + \mu_{ij}^{(12)} + \mu_{ik}^{(13)} + \mu_{jk}^{(23)} + \mu_{ijk}^{(123)} \quad (4.32)$$

と表現される。このモデルは実験計画法における零回実験での母数モデルと同形式であるが、セル確率の総和が 1 という制約 (4.1) が附加されており、従って、総平均に相当する  $\mu$  はその制約を満足するよう決められる。

加法モデルでの  $H_0$  に対応する 3 因子効果非存在のモデルは (4.32) から  $\mu_{ijk}^{(123)}$  を除いたものであり、階層的モデルであるから、その別表現として

$$\log p_{ijk} = \alpha_{ij} + \beta_{ik} + \gamma_{jk} \quad (4.33)$$

と書いてもよい [ (2.34) 参照]。また、乗法的表現として



$$H_m: p_{ijk} = \theta_{ij} \phi_{ik} \psi_{jk} \quad (4.34)$$

としても同値である [Darroch (1962, 1974)]. これをモデル  $H_m$  とする. (4.32) の右辺の因子効果を適当に取捨選択して各種のモデルを作りうることは 2.2 節で述べた通りである (例 2.5 参照). 階層的クラス  $\{1/2/3\}, \{12\}, \{12/23\}$  に応じて前述の  $H_1, H_2, H_{3c}$  のモデルが得られる. 加法モデルでは  $\{12/13\}$  に対して  $H_{3a}$  (4.28) が得られ、真か異なっている.

加法モデルの  $H_a$  と対数線形モデルの  $H_m$  との比較は Darroch (1974) によってなされている. モデルの一般的性質としては両者を比べて長短があるが、近似的には  $H_a$  が成り立てば  $H_m$  も簡単にされることが示されており.

以上のモデルの実際のデータにもとづく検定や母数の推定問題の精密な議論は、分割表データの標本抽出過程に即して確率モデルを構成することによって行われる. 各セルの度数がそれぞれ独立に母数  $m_{ijk}$  のポアソン分布に従うというポアソンモデル、大きさ  $N$  の標本の無作為抽出と言える多項分布モデル (あるいは部分的な表との多項分布モデル)、及びある条件付のポアソンモデルが取り扱いの比較的簡単な一般的確率モデルとして考えられる. これらの確率モデルのもとでは、対数



線形モデルが十分統計量、最大推定法、尤度比検定などとの関係で秀れた性質を持っている [Birch (1963), Habermann (1974)].

ここではその詳細は論じないが、対数線形モデルの階層的モデルではその生成クラスに対応するセル度数の周辺和、例えば、生成クラスが  $\{12, 13, 23\}$  なら、 $x_{ij+}, x_{i+k}, x_{++k}$  の組が最小完備十分統計量となり、期待値  $m_{ijk}$  の推定値  $\hat{m}_{ijk}$  の周辺和をそれらに一致させると、この条件でそのモデルの最大推定が行われる。尤度比検定からは、検定統計量

$$G^2 = 2 \sum x_{ijk} \log \frac{x_{ijk}}{\hat{m}_{ijk}} \quad (4.35)$$

が得られ、前述の確率モデルのもとで漸近的に  $\chi^2$  分布に従う。

ここで、 $\hat{m}_{ijk}$  は各モデルのもとでの推定値であり、 $\chi^2$  の自由度はそのモデルの部分空間の次元に等しい。分解型モデル（定義 2.7）に対しては対応する周辺和から陽にセル確率の推定値が得られる。

例えば、 $H_{3C}$  に対して

$$\begin{aligned} \hat{p}_{ijk} &= \frac{(x_{ij+}/N) \cdot (x_{i+k}/N)}{(x_{i++}/N)} \\ &= \frac{x_{ij+} x_{i+k}}{N x_{i++}} \end{aligned} \quad (4.36)$$



が最大推定値となる。分解型でないモデルに対してはそれから何らかの反復計算が必要である。

現実には、標本抽出過程は複雑多様であり、オ1章で述べたような観察データを解析したいことが多い。標準的な手法の各種の標本抽出過程での頑健性の研究は今後の重要な課題であろう。

なお、加法モデルの利用や別の観察からの問題点についてはオ5章で述べる。



## 4.2 平方根モデル

多重分割表に対し、そのセル確率あるいはセル度数の期待値の平方根を母数とする母数空間における第2章の記述に従う線形モデルを平方根モデル、あるいは平方根線形モデルと呼ぶ。すなはち、 $\gamma_1 \times \gamma_2 \times \cdots \times \gamma_m$  の  $m$  重分割表のセル度数、対応するセル確率、及びセル度数の期待値をそれとし、 $x_{\lambda_1 \lambda_2 \cdots \lambda_m}$ ,  $p_{\lambda_1 \lambda_2 \cdots \lambda_m}$ ,  $m_{\lambda_1 \lambda_2 \cdots \lambda_m}$  ( $\forall \lambda_i \in \bar{\gamma}_i$ ,  $\forall i \in \bar{m}$ ) とする。ここではセル確率を用い、多重配列の母数  $A$  を

$$A = (\sqrt{p_{\lambda_1 \lambda_2 \cdots \lambda_m}}) \quad (4.37)$$

とおく。各指標に対すベクトル空間  $\Omega^{(i)}$  におけるベクトル  $\underline{u}^{(i)}$  を

$$u_{\lambda_i}^{(i)} = 1 \quad (\forall i \in \bar{\gamma}_i, \forall i \in \bar{m}) \quad (4.38)$$

であらわすと採用し、それによって  $\Omega^{\alpha}$  の  $\alpha$ -効果空間  $\omega(\alpha)$ ,  $A$  の  $\alpha$ -因子効果  $B(\alpha)$ , 及び各種のモデル

$$A \in \Omega[\alpha] \quad (4.39)$$

を規定する。ここで  $\Omega[\alpha]$  は 2.2 節の記述に従い、 $\bar{m}$  の部分集合のクラス  $\alpha$  について

$$\Omega[\alpha] = \bigoplus_{\alpha \in A} \Omega(\alpha) \quad (4.40)$$

で与えられる [ (2.29), (2.30) 参照 ]. (4.38) のようにベクトル  $\underline{u}^{(i)}$  をあらかじめ与えておく、(4.37) の多重配列に特異値分解を適用するこ



とについては次章で検討する。

ある種の平方根変換は分散安定化変換 (variance stabilizing transformation) といしばしば論じられていろ [例えば, Rao (1973)] や, ここで平方根モデルを導入した理由の一つは分散安定化変換にある。セル度数をポアソン分布に従う確率変数とみなすポアソンモデルではセル度数の平方根が漸近的に分散が  $1/4$  の正規分布に従うとみなされるので, 分散分析での母数モデルからの類推で多重分割表を解むことができるとか可能である。多重分割表のデータとセル確率とパラメータヒカル多項分布によるものとする多項モデルでは次のように考えられる。二つの多項分布間の相違を測る量として Hellinger distance [例えば, Rao (1973, p.352)] がある。多重分割表の場合, モデルとの分布  $\{P_{\lambda_1 \lambda_2 \dots \lambda_m}\}$  と経験分布  $\{x_{\lambda_1 \lambda_2 \dots \lambda_m} / N\}$  を考えると, その量は

$$\cos^{-1} \sum \sqrt{\frac{x_{\lambda_1 \lambda_2 \dots \lambda_m}}{N} \cdot P_{\lambda_1 \lambda_2 \dots \lambda_m}} \quad (4.41)$$

で与えられる。これは, より一般に二つの分布間で定義され Bhattacharya divergence [Bhattacharya (1946)] の一例になつており, (4.41) は Bhattacharya の距離とすることもある。この距離の意味づけは付録でも与えられるが, 二項分布の



逆正弦変換の一般化になっている。あるモデルのもとで、(4.41)を最小にする母数の推定は、Pearsonの $\chi^2$ , Neymanの修正 $\chi^2$  [Neyman (1949)], Kullback-Leibler 判別情報量 [Kullback (1959)] などによる推定とともに、適当な正規条件の下で一致かつ有効推定量を与える<sup>†</sup>。いま、多重配列 $\mathbf{Y}$ を

$$\mathbf{Y} = (\sqrt{x_{\lambda_1 \lambda_2 \dots \lambda_m} / N}) \quad (4.42)$$

とおくと、(4.41)は (4.37) と (4.42) によて

$$\cos^{-1}(\tilde{\mathbf{Y}}' \tilde{\mathbf{A}}) \quad (4.43)$$

と書け、これを最小にすることは、逆余弦関数の性質から、明らかに $\tilde{\mathbf{Y}}' \tilde{\mathbf{A}}$ を最大にすることになる。この事実によって、平方根モデルでの分析が以下に述べるよう簡単になる。

また、 $\mathbf{Y}$ と $\mathbf{A}$ については セル確率の総和が 1 であることが (4.1),

$$\tilde{\mathbf{Y}}' \tilde{\mathbf{Y}} = \tilde{\mathbf{A}}' \tilde{\mathbf{A}} = 1 \quad (4.44)$$

であり、 $\mathbf{A}$ の推定値 $\hat{\mathbf{A}}$ についても

$$\hat{\mathbf{A}}' \hat{\mathbf{A}} = 1 \quad (4.45)$$

---

<sup>†</sup> Rao (1961, 1962, 1963) の意味で一次の有効性を持つ。Rao の定義による二次の有効性については必ずしも差があるか、現実的応用で問題にされうほどではないと思われる。



と制約を置く。そのとき

$$(\underline{Y} - \hat{\underline{A}})'(\underline{Y} - \hat{\underline{A}}) = 2 - 2\underline{Y}'\underline{A}' \quad (4.46)$$

が成り立つので、 $\underline{Y}'\underline{A}'$ を最大にすらかわりに、上式の右辺を最小、すなはち最小二乗法として考えられる。

さて、モデル (4.39) と制約 (4.45) のもとで (4.41) を最小にする解は、簡単な計算から

$$\hat{\underline{A}} = \frac{1}{\lambda} \sum_{\alpha \in \mathcal{A}} \hat{B}(\alpha) \quad (4.47)$$

で与えられる。ここで、 $\hat{B}(\alpha)$  は

$$\hat{B}(\alpha) = \left( \bigotimes_{i=1}^m T_{X_\alpha(i)}^{(i)} \right) \underline{Y} \quad (4.48)$$

すなはち、(2.20) で定義される  $\underline{Y}$  の  $\alpha$ -因子効果であり、入は

$$\lambda = \left( \sum_{\alpha \in \mathcal{A}} \hat{B}(\alpha)' \hat{B}(\alpha) \right)^{1/2} \quad (4.49)$$

で与えられる。このときの Hellinger distance (4.41) は  $\cos^{-1}\lambda$  となる。一方、多項分布モデルの前提のもとでは

$$\chi^2 = 4N(\cos^{-1}\lambda)^2 \quad (4.50)$$

が漸近的に  $\chi^2$  分布に従うことが知られている [例えば、Rao (1973)] ので、モデル (4.39) の検定が可能である。その  $\chi^2$  の自由度は定理 2.1 を用いて次式で与えられる:

$$d.f. = n - \sum_{\alpha \in \mathcal{A}} \left( \prod_{i \in \alpha} (r_i - 1) \right). \quad (4.51)$$



ここで、平方根モデルの特徴を述べておこう。オーナーに、飽和モデルにおける各因子効果への分解が容易なことである。対数線形モデルではゼロの対数が無限大にならという問題が生じ、多重分割表ではセル度数の一部がゼロ(zero-cell)にならんとも稀でない。

オニに、対数線形モデルでは、モデルレジストにセル確率を反復計算によって推定しかつ検定統計量を計算しなおるので、モデルの選択、あるいは有意な因子効果の抽出が面倒であるのに対し、平方根モデルでは、飽和モデルで因子効果ごとの平方和の表を一度作っておけば、一連の検定を行うことができる。オニは、これは欠点であろうが、対数線形モデルにおける分解型(closed form)モデルのように、独立、条件独立といったモデルの確率論的解釈が困難な点である。この点に関しては平方根モデルを使っており程度の見込をつけながらそこで選択されたモデルに近い分解型の乗法モデルを検定すればよからう。多重分割表データの解析の重要な目標の一つは与えられたデータから適切なモデルを構成することであるが、モデルの選択はきめめて事後的な分析であらんとに注意しなければならぬ。したがって、一つのモデルや手法にこだわらんではなく、幅広い観点からデータの分析にあたることが肝心であろう。



## 5. 多重分割表への応用(II)

オ3章で述べた多重配列の特異値分解を多重分割表データの解析に応用する。まず、2重分割表に対する数量化手法から始め、3重分割表に対する数量化手法の型を整理して、それらと加法モデルとの関連を論じる。次に、一般の多重分割表に対する数量化手法として分解型モデルからの流れを表現することなどを考え、最後に平方根分解の応用を論じる。

### 5.1 2重分割表における数量化

多重分割表に対する数量化手法は、1.3節で述べたように、実質的には Fisher が正準相關分析の考え方を2重分割表に適用したことによって発明された。ここでいう分割表の数量化手法は、optimal scaling method (最適尺度法) の一つと考えられるところである。この分野の文献には西田 (1977) に詳しい。

2重分割表の数量化問題は次のように述べられる。

問題5.  $r \times c$  分割表のセル確率  $p_{ij}$  ( $\forall i \in \bar{I}, \forall j \in \bar{C}$ ) が与えられたとき、条件

$$\sum_i p_{i+} x_i = 0; \quad \sum_j p_{+j} y_j = 0; \quad (5.1)$$

$$\sum_i p_{i+} x_i^2 = 1; \quad \sum_j p_{+j} y_j^2 = 1 \quad (5.2)$$

の下で、



$$\rho = \sum_{i,j} p_{ij} x_i y_j \quad (5.3)$$

を最大にする  $x_i (\forall i \in \bar{r})$  と  $y_j (\forall j \in \bar{c})$  を求めること。

この種の数量化の目的は、本来名義尺度の項目の各カテゴリに  $x_i (\forall i \in \bar{r})$  と  $y_j (\forall j \in \bar{c})$  という数値を付与して、カテゴリの分類あるいは比較を行うことにある。同様の目的のためには広津(1973, 1976)による多重比較の観察からの手法があるが、そこでは項目ごとにカテゴリ間の類似性の比較が行われるのでに対し、問題5では二項目に対して同時に数量化する点が大きく異なる。

問題5の条件(5.1)は、各項目  $x_i (\forall i \in \bar{r})$  と  $y_j (\forall j \in \bar{c})$  という値をどう離散的確率変数  $X$  と  $Y$  とみなすかを、 $X$  と  $Y$  の期待値がゼロであるという制約を表す、条件(5.2)は  $X^2$  と  $Y^2$  の期待値が 1、条件(5.1)と合わせて  $X$  と  $Y$  の分散が 1 と解釈される。したがって、(5.3)の  $\rho$  は  $X$  と  $Y$  の相関係数を意味することになる。

この問題に対して次のような事実はすでによく知られている[例えば、Kendall & Stuart (1961) 参照]。また、決定方程式は

$$\left. \begin{aligned} \sum p_{ij} y_j &= \rho p_{i+} x_i & (\forall i \in \bar{r}), \\ \sum p_{ij} x_i &= \rho p_{j+} y_j & (\forall j \in \bar{c}) \end{aligned} \right\} \quad (5.4)$$

で与えられる。(5.4)の最大特異値  $\rho_1$  は 1 で、対応するベクトルは単位



ベクトルに比例するものである。そのベクトルは条件(5.1)を満たす；すな  
に大きな特異値と対応するベクトルが問題5の解となる。さらに、 $k=3$ 以後  
の特異値も求めていまし、それらを  $\rho_k$ 、対応するベクトルを  $x_i^{(k)}, y_j^{(k)}$ ,  $k=2, 3, \dots$   
とする。そのとき、いわゆる Fisher の恒等式

$$p_{ij} = p_{i+} p_{+j} \left( 1 + \sum_{k=2}^{\min(r,c)} \rho_k x_i^{(k)} y_j^{(k)} \right) \quad (5.5)$$

$$(\forall i \in \bar{r}, \forall j \in \bar{c})$$

及び、平方和分解

$$\sum_{i,j} \frac{p_{ij}^2}{p_{i+} p_{+j}} = 1 + \sum_{k=2}^{\min(r,c)} \rho_k^2 \quad (5.6)$$

を得る。 (5.6) の右辺の 1 を左辺に移項して両辺を  $N$  倍すると、いわゆ  
る 2 重分割表における独立性の検定統計量  $\chi^2$  の分解が得られる：

$$\chi^2 = N \left( \sum_{i,j} \frac{p_{ij}^2}{p_{i+} p_{+j}} - 1 \right) = N \sum_{k=2}^{\min(r,c)} \rho_k^2 \quad (5.7)$$

ここで、 $N$  は 分割表データ ( $x_{ij}$ ) が与えられたときのセル度数の総和で  
ある。

以上の事実は、行列

$$A = \begin{pmatrix} p_{ij} \\ \sqrt{p_{i+} p_{+j}} \end{pmatrix} \quad (5.8)$$

に対する特異値分解によって導かれるものにほかならない。このことは前章  
の加法モデルの項で述べたことから容易に理解されよう。 (5.8) の特異値分  
解で上記の  $x_i^{(k)}, y_j^{(k)}$  に対して、  $\sqrt{p_{i+}} x_i^{(k)}, \sqrt{p_{+j}} y_j^{(k)}$  が計算されることになる。



## 5.2 3重分割表における数量化とモデル

本節では、従来提案されている3重分割表の数量化手法の理論的基礎付けを与え、それらの手法の拡張を検討する<sup>†</sup>。

a) 数量化の形式 3重分割表に対する記法は第4章と同じとする。ここでは、 $r \times s \times t$  分割表における数量化として、次の三通りの場合を扱う：

$$(A) i \leftarrow u_i (\forall i \in \bar{r}), j \leftarrow v_j (\forall j \in \bar{s}), k \leftarrow w_k (\forall k \in \bar{t});$$

$$(B) (i, j) \leftarrow u_{ij} (\forall i \in \bar{r}, \forall j \in \bar{s}), k \leftarrow w_k (\forall k \in \bar{t});$$

$$(C) [(i, j) \leftarrow v_{ij} (\forall j \in \bar{s}), (i, k) \leftarrow w_{ik} (\forall k \in \bar{t})] (\forall i \in \bar{r}).$$

これらを上記の順にA型、B型、およびC型数量化と呼ぶことにする。後二者については項目の組合せによってそれが3通りの変形がある。A型はそれを他の項目ごとにそれを構成するカテゴリによる実数値を付与するものである。B型は、オ1項目とオ2項目を複合してrsのカテゴリ $(i, j)$  ( $\forall i \in \bar{r}, \forall j \in \bar{s}$ ) から成るひとつの中目のみなし、その項目とオ3項目との2重分割表における数量化にはならない。C型数量化はオ1項目の各カテゴリごとに  $s \times t$  分割表がありと見て、カテゴリ $i \in \bar{r}$  ごとに2重分割表における数量化を行おうというものである。

岩坪(1974)は A型に対して次の相関係数を定義して量の最大化

<sup>†</sup> 本節の内容は吉澤(1975)に報告されている。



を規準とする数量化を、およびB型に対しては $\Sigma_k$ に関する相関比の最大化を規準とする数量化を提案している。この種の数量化手法を含めて一般に最適尺度法や多次元尺度構成法といわれる分野では各手法の根底に確率論的モデルを想定してモデルのデータへの適合性を議論することが困難である。ここでは、3重分割表の数量化手法と前述の多重配列の特異値分解及び加法モデルとの関連を指摘して、数量化手法の基礎的理論を構成する。

b) 加法モデルの拡張と3次相関係数による数量化 离散的確率変数 $X, Y, Z$ を想定し、分割表のセル確率をこれらの変数の同時分布と見なすものと解釈する。すなわち、

$$p_{ijk} = \Pr(X=u_i, Y=v_j, Z=w_k) \quad (\forall i \in \bar{I}, \forall j \in \bar{S}, \forall k \in \bar{T}).$$

岩坪(1974)による3次の相関係数の最大化を規準とするA型の数量化は、制約条件、

$$\sum_i p_{i++} u_i = 0, \quad \sum_j p_{++j} v_j = 0, \quad \sum_k p_{++k} w_k = 0, \quad (5.9)$$

$$\sum_i p_{i++} u_i^2 = 1, \quad \sum_j p_{++j} v_j^2 = 1, \quad \sum_k p_{++k} w_k^2 = 1 \quad (5.10)$$

の下で、確率変数 $X, Y, Z$ の3次の相関係数を最大にする、すなわち、

$$\rho = \sum_{i,j,k} p_{ijk} u_i v_j w_k \rightarrow \max \quad (5.11)$$

とする $\{u_i\}$ ,  $\{v_j\}$ , および $\{w_k\}$ を求めるものである。 $(5.9)$ と $(5.10)$ は確率変数 $X, Y, Z$ のそれらの期待値がゼロ、分散が1という統



計的意味を持つ。岩坪(1974)はこの問題の決定方程式を導出し、 $\gamma^2$  が有界であること、および不等式

$$\gamma^2 < \sum_{i,j,k} \frac{p_{ijk}^2}{p_{i++} p_{+j+} p_{++k}} \quad (5.12)$$

が成り立つことを示している。

一方、この問題は第3章における問題3や定理3.5、および第4章で述べた加法モデルの性質から次の定理として述べるよう解釈される。

定理5.1. 条件(5.9)と(5.10)の下で、3次の相關係数  $\rho$  (5.11) を最大にする問題は、同じ条件の下で

$$\rho = \sum_{i,j,k} (p_{ijk} - \alpha p_{ijk}) u_i v_j w_k \quad (5.13)$$

を最大にする  $\{u_i\}$ ,  $\{v_j\}$ ,  $\{w_k\}$  を求める問題と同値である。ここで、 $\alpha p_{ijk}$  は(4.24)で与えられるものである。

注意. (5.13)の右辺の因子  $p_{ijk} - \alpha p_{ijk}$  は 4.1 節で述べたように3重分割表での加法モデルにおける最高次交互作用(3因子効果)の成分にはならない。

証明.  $\Sigma^{(1)}, \Sigma^{(2)}, \Sigma^{(3)}$  が(4.5)と同様に与えれば、(5.9)は各ベクトル  $u = (u_i)$ ,  $v = (v_j)$ ,  $w = (w_k)$  がそれぞれ単位ベクトルと重みつきで直交していることを意味する。そして 2.3 節で述べた内積の一般化と 3.1 節



の問題3に適用すれば定理3.5からくじらく本定理を得る。 |

この定理5.1から定理3.1及び定理3.4に対応するものとして次の定理が得られり。証明は定理5.1と同様に内積の定義に注意して定理3.1及び定理3.4の証明をそれぞれ用ひればよいので省略する。

定理5.2. 3次の相関係数について、次の不等式が成り立つ：

$$\rho^2 \leq \sum_{i,j,k} \frac{(p_{ijk} - \alpha p_{ijk})^2}{p_{i++} p_{+j+} p_{++k}} \quad (5.14)$$

等号が成立するのは、あら  $\{u_i\}$ ,  $\{v_j\}$ ,  $\{w_k\}$  に対して,  $p_{ijk} - \alpha p_{ijk}$  が  $p_{i++} p_{+j+} p_{++k} u_i v_j w_k$  に比例するとき、そのときに限る。

注意. 不等式 (5.14) や (5.12) より,  $\rho^2$  の精密な評価をえてこうじに注意されん。 (4.23) やもそのことは明らかである。

定理5.3. 制約条件 (5.9) と (5.10) の下で、3次の相関係数  $\rho$  を最大にするには、同じ条件の下で、

$$Q = \sum_{i,j,k} \frac{(p_{ijk} - \alpha p_{ijk} - \rho g_{ijk} u_i v_j w_k)^2}{g_{ijk}} \quad (5.15)$$

を最小にする問題と同値であら。 ここと

$$g_{ijk} = p_{i++} p_{+j+} p_{++k} \quad (5.16)$$

ヒカル。



注意. 以下の式が長くなるときは  $g_{ijk}$  の記法を用いよ。なお、定理3.4のあととの注意に述べたように  $g, u_i, v_j, w_k$  の符号の任意性を除く、

定理5.1からわかるように、3次相関係数の最大化と規準とする数量化は、加法モデルにおける3因子効果だけが問題になる。そのことを次の定理として述べておく。

定理5.4. 3次の相関係数  $g$  (5.11) が 条件 (5.9) と (5.10) のもとで恒等的にゼロになるとための必要十分条件は 加法モデルでの3因子効果が存在しないことである。

注意. 4.1節で述べた階層的モデル  $H_1, H_2, H_{3a}, H_4$  は皆  $g$  がゼロにならための十分条件にはならない。

証明. (4.17) によて  $p_{ijk} - \alpha p_{ijk}$  は 加法モデルでの3因子効果の要素である。よって、(5.14) の不等式から、ただちに定理を得る。 |

以上の議論によって、このA型数量化が 加法モデルで定義される3因子効果 (4.17) の一部を抽出するものであることが明らかとなつた。したがって、その3因子効果を4.1節にならして  $B(123)$  と書くと、この数量化が意味のあるものであるかどうかは、 $B(123)$  が存在して、それ自身が量的にも意味があり、かつ、



$$B(123) = \sum_{ijk} u_i v_j w_k \quad (5.17)$$

というモデルがほぼ成り立つかどうかという点に依存しよう。加法モデルの各種のモデルに (5.17) の右辺の項を加えた形式のモデルの検定については後述 (予想) する。

なお、不等式 (5.14) の等号の成り立つ分割表の例を示しておこう。

例 5.1.  $2 \times 2 \times 2$  分割表.  $r=s=t=2$  の場合は二つの条件 (5.9)

と (5.10) やら  $\{u_i\}$ ,  $\{v_j\}$ ,  $\{w_k\}$  は行号を除いて一意に決まってしまう。す

なむち、

$$u_1 = \sqrt{\frac{p_{2++}}{p_{1++}}}, \quad v_1 = \sqrt{\frac{p_{+2+}}{p_{+1+}}}, \quad w_1 = \sqrt{\frac{p_{++2}}{p_{++1}}}$$

と正くすれば、

$$u_2 = -\sqrt{\frac{p_{1++}}{p_{2++}}}, \quad v_2 = -\sqrt{\frac{p_{+1+}}{p_{+2+}}}, \quad w_2 = -\sqrt{\frac{p_{++1}}{p_{++2}}}$$

となる。このとき、3因子効果が (5.17) を満たすことを直接計算によつても、3因子効果の次元  $(r-1)(s-1)(t-1)$  が二の場合 1 であることをからも示され、不等式 (5.14) で等号が成り立つ場合であることをやめかかる。

例 5.2. 1卓集中型分割表. 一つのセルを除いて残りのセルの確率が一定であらうような特殊な分割表を 1卓集中型と呼ぶ。そのセル確率を



$$p_{ijk} = \frac{1}{N} (1 + d \delta_{ia} \delta_{jb} \delta_{kc}) \quad (5.18)$$

とかく、 $i=j$ 、 $N=rst+d$ 、 $d$ は定数、 $\delta_{ia}$ などは Kronecker のデルタとす。観測されたセル度数でみれば、ある一つのセル  $(a, b, c)$  だけが  $1+d$  となり、残りのセルは 1 の値をとる分割表である。この場合、

$$p_{ijk} = a p_{ijk} + \frac{d(N-2d)}{N^3} (r \delta_{ia}-1) (s \delta_{jb}-1) (t \delta_{kc}-1)$$

と表現できることが確かめられる。

c) 相関比による数量化に対するモデル 岩坪(1974)は一つの項目について相関比最大化の規準による数量化を提案している。第三項目をとりあげ、数量化を記号的に

$$k \leftarrow w_k \quad (\forall k \in \bar{F})$$

とする。相関比はある確率変数  $Z$  について  $Z$  の何らかの条件つき期待値の分散と  $Z$  自身の分散との比を意味する。そこで、条件

$$\sum_k p_{++k} w_k = 0 \quad (5.19)$$

の下で、

$$\eta^2 = \frac{\sum_i \sum_j p_{ij+} \left( \sum_k \frac{p_{ijk}}{p_{ij+}} w_k \right)^2}{\sum_k p_{++k} w_k^2} \quad (5.20)$$

を最大にする  $\{w_k\}$  を求めろ。この考え方を相関比最大化の規準による数量化という。



この数量化は、実は、単純なB型数量化にすぎないことがわかる。オ  
ー項目とオニ項目を複合して、 $rs$ 個のカテゴリ  $(i, j)$  ( $\forall i \in \bar{r}, \forall j \in \bar{s}$ )  
からなる新しい項目を作ろ。与えられた3重分割表をその複合項目ヒ  
三項目による  $(rs) \times t$  の2重分割表と考える。そこで、5.1節の2重分割  
表に対する数量化をB型数量化として用いらんとする。その数量化  
は次のようである：条件

$$\sum_{i,j} p_{ij} + u_{ij} = 0; \quad \sum_k p_{r+k} w_k = 0; \quad (5.21)$$

$$\sum_{i,j} p_{ij} + u_{ij}^2 = 1; \quad \sum_k p_{r+k} w_k^2 = 1 \quad (5.22)$$

の下で、

$$\rho = \sum_{i,j,k} p_{ijk} u_{ij} w_k \quad (5.23)$$

を最大にする  $\{u_{ij}\}$  と  $\{w_k\}$  を求めるシビ。これに対する決定方程式  
は (5.4) と本質的に同じで

$$\left. \begin{aligned} \sum_k p_{ijk} w_k &= \rho p_{ij} + u_{ij}, \\ \sum_i p_{ijk} u_{ij} &= \rho p_{r+k} w_k \end{aligned} \right\} \quad (5.24)$$

と与えられる。 (5.24) から  $u_{ij}$  を消去すると

$$\sum_{k=1}^t \left( \sum_{i,j} \frac{p_{ijk}}{p_{r+k}} \cdot \frac{p_{ijk'}}{p_{ij'}} \right) w_{k'} = \rho^2 w_k \quad (5.25)$$



という固有方程式が得られる。これが相関比  $\eta^2$  (5.20) の最大化に對する決定方程式に行かはるにはことは容易に示される。

したがって、相関比最大化を基準とする数量化の諸性質は 5.1 節で述べた 2 重分割表の性質から導かれる。ここでは次の定理だけを示しておこう。証明は省略する。

定理 5.5. (5.20) の相関比  $\eta^2$  について次の不等式が成立す：

$$\begin{aligned} \eta^2 &\leq \sum_{i,j,k} \frac{(p_{ijk} - p_{ij} + p_{ik})^2}{p_{ij} + p_{ik}} \\ &= \sum_{i,j,k} \frac{p_{ijk}^2}{p_{ij} + p_{ik}} - 1. \end{aligned} \quad (5.26)$$

以上の考察から、相関比最大化の標準による数量化が意味を持つのは、セル確率について、モデル

$$H_r: p_{ijk} = p_{ij} + p_{ik} (1 + \rho u_{ij} w_k) \quad (5.27)$$

が成立立つようなどきでありといえよう。なお、B 型数量化としては、添字の入れかえによって

$$(B') (i, k) \leftarrow w_{ik} (\forall i \in \bar{r}, \forall k \in \bar{t}), j \leftarrow v_j (\forall j \in \bar{s})$$

$$(B'') (j, k) \leftarrow v_{jk} (\forall j \in \bar{s}, \forall k \in \bar{t}), i \leftarrow u_i (\forall i \in \bar{r})$$

という形式を考えられ、それそれに對応するモデル



$$H_{r'}: p_{ijk} = p_{i+k} p_{j+} (1 + \rho w_{ik} v_j) \quad (5.28)$$

$$H_r: p_{ijk} = p_{j+k} p_{i++} (1 + \rho v_{jk} u_i) \quad (5.29)$$

を考えることができる。これらは部分独立モデルからの流れを抽出している。

d) 条件付独立性からの数量化とそのモデル 一つの変数Xの値が与えられ、条件のもとでYとZが独立である場合、すなはち、条件付独立モデル

$$H_{3C}: p_{ijk} = \frac{p_{i+j} p_{i+k}}{p_{i++}} \quad (5.30)$$

を中心にして、いくつかの数量化手法を考えることができる。まず、このモデルが  $i \in \bar{r}$  のいくつかのカテゴリにすべて成立しないとき、そのカテゴリの部分集合を  $\bar{r}'$  とする。各々の  $i \in \bar{r}'$  について  $\{p_{ijk}\}$  を  $j$  と  $k$  について  $s \times t$  の2重分割表と考え、C型の数量化を行なうことができる。すなはち、 $\forall i \in \bar{r}'$  に対して、条件

$$\sum_j p_{ij} v_{ij} = 0; \quad \sum_k p_{i+k} w_{ik} = 0; \quad (5.31)$$

$$\sum_j p_{ij} v_{ij}^2 = 1; \quad \sum_k p_{i+k} w_{ik}^2 = 1 \quad (5.32)$$

の下で、

$$S_i = \sum \frac{p_{ijk}}{p_{i++}} v_{ij} w_{ik} \longrightarrow \max \quad (5.33)$$

となる  $\{v_{ij}\}, \{w_{ik}\}$  を求める。これに対するモデルを



$$H_d: p_{ijk} = \frac{p_{ij} + p_{ik}}{p_{i+}} (1 + p_i v_{ij} w_{ik}) \quad (\forall i \in \bar{r}) \quad (5.34)$$

としておこう。

e) 加法モデルの一般化. これまで述べた数量化手法では (5.9), (5.24), (5.31) のように数値を付与されて想定された確率変数の期待値がゼロであるという制約が置かれていた. それらの制約は, それぞれの添字に対応するベクトル空間に付与すべき数値ベクトルに対して重みつきで直交する単位ベクトル  $(1, 1, \dots, 1)'$  をあらかじめ想定していること, したがってその単位ベクトルに相対的な最高次の交互作用に対する成分のみが数量化の対象となるという卓で重要な意味を持つ. しばしば, これらの制約は位置に関する制約, あるいは位置条件といわれる. 一方, 分散が 1 であるという (5.10) のような条件は尺度に関する制約, あるいは尺度条件といわれる. 尺度条件は, ベクトル空間 (2.3 節の意味で) の内積の定義に即していれば, 右辺の 1 は本質的な制約ではない.

ここでは, これまでのモデルを一般化して, 位置の制約の意味と別の観点から論じておこう. モデルを

$$H_g: p_{ijk} = p_{ijk}^0 + \sum g_{ijk} u_i v_j w_k$$

とする. ここで,  $\{p_{ijk}^0\}$  は与えられるセル確率  $\{p_{ijk}\}$  とは無関係に設定しても, あるいは加法モデルでの  $p_{ijk}$  のようにセル確率



$\{p_{ijk}\}$  から作られるものとしてもよい。二つの離散分布  $\{p_{ijk}\}$  と  $\{p_{ijk}^0\}$  の相違を  $\sum p_{ijk} u_i v_j w_k$  でみたと考へてもよい。このモデルのパラメータ  $\{u_i\}$ ,  $\{v_j\}$ ,  $\{w_k\}$  については以下に条件を付加する。  
まず、尺度条件

$$(C1) \quad \sum_i p_{i++} u_i^2 = \sum_j p_{+j+} v_j^2 = \sum_k p_{++k} w_k^2 = 1 \quad (5.35)$$

については前述のようにあまり議論のないところでもある。Hgにおける  $u_i v_j w_k$  という積の形からも何らかの尺度条件が必要であり,  $\{u_i\}$ ,  $\{v_j\}$ ,  $\{w_k\}$  について対称的な条件を置くかわりに  $p_{ijk}$  パラメータについて追加されていふともいえ。

次に、セル確率の総和が 1 であるという要求から,  $\{p_{ijk}^0\}$  については

$$(C2) \quad \sum_{i,j,k} p_{ijk}^0 = 1 \quad (5.36)$$

となる。これまでの位置条件を

$$(C3) \quad \sum_i p_{i++} u_i = \sum_j p_{+j+} v_j = \sum_k p_{++k} w_k = 0 \quad (5.37)$$

としておく。セル確率の総和が 0 というところには, モデル Hg では

$$\sum_{i,j,k} p_{ijk}^0 u_i v_j w_k = 0$$

であることは、つまり C3 のかわりに

$$(C4) \quad \sum_i p_{i++} u_i = 0 \quad (5.38)$$

という条件だけを選んで考えられる。



以上の制約条件を一部の組合せで含めた三つのモデルを検討しよう。

$$Hg_1: p_{ijk} = p_{ijk}^o + \rho g_{ijk} u_i v_j w_k,$$

制約条件 C1, C2, C3;

$$Hg_2: p_{ijk} = p_{ijk}^o + \rho g_{ijk} u_i v_j w_k,$$

制約条件 C1, C2, C4;

$$Hg_3: p_{ijk} = p_{ijk}^o + \rho g_{ijk} u_i v_j w_k,$$

制約条件 C1, C2.

各モデルの構造を決定する規準として、以下のモデルで、それがどの  
の制約条件のもとで

$$Q = \sum_{i,j,k} \frac{(p_{ijk} - p_{ijk}^o - \rho g_{ijk} u_i v_j w_k)^2}{g_{ijk}} \rightarrow \min \quad (5.39)$$

という規準を採用する。この規準は

$$\rho = \sum_{i,j,k} (p_{ijk} - p_{ijk}^o) u_i v_j w_k \rightarrow \max \quad (5.40)$$

と同値である。これらのモデルに対する決定方程式は次のようになります。

$Hg_1$  の場合:

$$\left. \begin{aligned} & \sum_{j,k} \{ (p_{ijk} - p_{ijk}^o) - p_{i++} (p_{+jk} - p_{+jk}^o) \} v_j w_k = \rho p_{i++} u_i \\ & \sum_{i,k} \{ (p_{ijk} - p_{ijk}^o) - p_{+j+} (p_{i+k} - p_{i+k}^o) \} u_i w_k = \rho p_{+j+} v_j \\ & \sum_{i,j} \{ (p_{ijk} - p_{ijk}^o) - p_{++k} (p_{ij+} - p_{ij+}^o) \} u_i v_j = \rho p_{++k} w_k \end{aligned} \right\} \quad (5.41)$$



$H_{q_2}$  の場合:

$$\left. \begin{aligned} & \sum_{j,k} \{(p_{ijk} - p_{ijk}^0) - p_{i+r}(p_{+jk} - p_{+jk}^0)\} v_j w_k = g p_{i+r} u_i \\ & \sum_{i,k} (p_{ijk} - p_{ijk}^0) u_i w_k = g p_{+j+r} v_j \\ & \sum_{i,j} (p_{ijk} - p_{ijk}^0) u_i v_j = g p_{r+k} w_k \end{aligned} \right\} \quad (5.42)$$

$H_{q_3}$  の場合:

$$\left. \begin{aligned} & \sum_{j,k} (p_{ijk} - p_{ijk}^0) v_j w_k = g p_{i+r} u_i \\ & \sum_{i,k} (p_{ijk} - p_{ijk}^0) u_i w_k = g p_{+j+r} v_j \\ & \sum_{i,j} (p_{ijk} - p_{ijk}^0) u_i v_j = g p_{r+k} w_k \end{aligned} \right\} \quad (5.43)$$

これらの決定方程式を比較することによって,  $\{u_i\}$ ,  $\{v_j\}$ ,  $\{w_k\}$  の位置条件の違いが決定方程式のどの部分へ影響するかが明らかであろう. 逆に  $\{p_{ijk}\}$  と  $\{p_{ijk}^0\}$  とが適当な関係にあるれば, (5.42) や (5.43) の解が条件 C3 を満たすことがわかる. 例えば, 2変数周辺和が比較一一致する場合, ではある

$$p_{ij+r} = p_{ij+r}^0, \quad p_{i+r+k} = p_{i+r+k}^0, \quad p_{+jk} = p_{+jk}^0 \quad (5.44)$$

となるとき, (5.41) と (5.42) はそれぞれ (5.43) に帰着する. したがって, (5.44) が満たされない, (5.43) の解は  $H_{q_3}$  に含まれていなければ制約 C3 を満たさなくなる. 次に

$$p_{ijk}^0 = p_{i+r} p_{+jk}^0, \quad p_{ijk}^0 = p_{+j+r} p_{i+r}^0, \quad p_{ijk}^0 = p_{r+k} p_{ij+r}^0 \quad (5.45)$$



を満たすときは、(5.41)が次のようにならう：

$$\left. \begin{aligned} \sum_{j,k} (p_{ijk} - p_{i\tau\tau} p_{jk}) v_j w_k &= \varphi p_{i\tau\tau} u_i, \\ \sum_{i,k} (p_{ijk} - p_{ij\tau} p_{ik\tau}) u_i w_k &= \varphi p_{ij\tau} v_j, \\ \sum_{i,j} (p_{ijk} - p_{i\tau\tau} p_{jk\tau}) u_i v_j &= \varphi p_{i\tau\tau} w_k. \end{aligned} \right\} \quad (5.46)$$

これは、岩坪(1974, p.61)が導出した3次の相関係数を標準とした数量化の決定方程式にほかならない。加法モデルで3因子効果を除いたモデルを  $p_{ijk}^0$  とすれば(5.44)を満たす。(5.45)は満たされるとかぎらないが、(5.41)の  $p_{ijk}^0$  へ代入し条件C3を用いれば、(5.41)は(5.46)の形に変形される。

なお、条件独立モデルを使って

$$p_{ijk}^0 = \frac{p_{ij\tau} p_{ik\tau}}{p_{i\tau\tau}} \quad (5.47)$$

となるが、(5.44)の式1と式2を満たす。したがって、このときは(5.32)を解けば、その解は条件C3を満たす。 $\{p_{ijk}^0\}$  の候補としては、多くのものが考えられるが、加法モデルや乗法モデルに由来するものを表5.1と表5.2に示す。

表5.1と5.2に示された次元や自由度は9項目で説明する。

土) 乗法モデル。3次の相関係数の最大化を標準とした数量化は3項目間の同時関連性、すなはち3因子効果を  $u_i v_j w_k$  のような積の形で



抽出する手法であるといつてよい。a) 項では加法モデルによって定義される3因子効果  $p_{ijk} - \alpha p_{ijk}$  との数量化手法との関連が指摘されている。

一方、分割表の代表的モデルである乗法モデルあるいは対数線形モデルによって定義される3因子効果を利用することも考えられる。4.1節で述べたように、対数線形モデルの階層的モデルは標本抽出過程のあらゆる仮定の下ではその最大推定量がいくつかの周辺和を含むせりといふ形で比較的容易に求められ、例えば、3因子効果非存在のモデル  $\mu_{ijk}^{(123)} = 0$  [(4.32) 参照] のセル確率の推定値は、 $\hat{m}p_{ijk}$  と書くと

$$p_{ij+} = \hat{m}p_{ij+}, \quad p_{i+k} = \hat{m}p_{i+k}, \quad p_{+jk} = \hat{m}p_{+jk} \quad (5.48)$$

の関係にある。そこで、モデル  $H_g$  における  $p_{ijk}^o$  を  $\hat{m}p_{ijk}$  にとって、上式 (5.48) は (5.44) に相当し、(5.29) の規準のもとで決定方程式 (5.43) を解けば条件 C3 を満足する  $\{u_i\}, \{v_j\}, \{w_k\}$  が得られる。

乗法的なモデルを拡張していければ、 $H_g$  のかわりに

$$H_n: \quad p_{ijk} = \rho p_{ijk}^o u_i v_j w_k \quad (5.49)$$

という形式のモデルを考えることができる。 $\{p_{ijk}^o\}$  は  $\{p_{ijk}\}$  を無関係に設定されたものであってよい。母数  $\rho, \{u_i\}, \{v_j\}, \{w_k\}$  は尺度条件 C1 と次式を満たすものとする：

$$\sum_{i,j,k} \rho p_{ijk}^o u_i v_j w_k = 1. \quad (5.50)$$



一般的にいって、乗法的なモデルでは最小二乗法的な規準より、Kullback の情報量 [Kullback (1959)] を利用したほうが便利である。

そこで、モデル  $H_n$  に対して、規準

$$\sum_{i,j,k} p_{ijk}^* \log \frac{p_{ijk}^*}{\varphi p_{ijk}^* u_i v_j w_k} \rightarrow \min \quad (5.51)$$

によって  $H_n$  の構造を決定するにしよう。その決定方程式は

$$\left. \begin{array}{l} \varphi \sum_{j,k} (p_{ijk}^* v_j w_k) u_i = p_{i++} \\ \varphi \sum_{i,k} (p_{ijk}^* u_i w_k) v_j = p_{+j+} \\ \varphi \sum_{i,j} (p_{ijk}^* u_i v_j) w_k = p_{++k} \end{array} \right\} \quad (5.52)$$

ただし、この解に対し、

$$n p_{ijk} = \varphi p_{ijk}^* u_i v_j w_k$$

とおくと、(5.52) は

$$n \hat{p}_{i++} = p_{i++}, \quad n \hat{p}_{+j+} = p_{+j+}, \quad n \hat{p}_{++k} = p_{++k} \quad (5.53)$$

と書ける。対数線形モデルではセル確率の推定値  $\hat{p}_{ijk}$  が

$$\hat{p}_{i++} = p_{i++}, \quad \hat{p}_{+j+} = p_{+j+}, \quad \hat{p}_{++k} = p_{++k}$$

の関係を持つてしまうので、 $\varphi = u_i = v_j = w_k = 1$  とし、 $p_{ijk}^*$  を

この  $\hat{p}_{ijk}$  にとれば (5.52) も満たされる。その解が (5.51) を最小

にするかどうかは保留しても、 $H_n$  は普通の乗法モデルに帰着してしまう。



$p_{ijk}^o$  が周辺和の閑数にとも場合でも

$$p_{ijk}^o = \frac{p_{+jk} p_{i+k} p_{ij+}}{p_{i++} p_{+j+} p_{++k}} \quad (5.54)$$

ところは、 $p_{ijk}^o$  は乘法モデル  $H_m$  での一つの推定値  $\hat{m}p_{ijk}$  とは異なり、ある程度の意味で残る。Darroch (1962, 1974) や Lancaster (1971) で議論されていよう、「Perfect two-variable marginal probabilities」を持つ分割表の場合、  
すなはち、条件

$$\sum_i \frac{p_{ij+} p_{i+k}}{p_{i++}} = p_{+j+} p_{++k} \quad (5.55)$$

が、添字を入れかえん三通りの場合について、成り立つとき、(5.64) は  $\hat{m}p_{ijk}$  に一致する。そして、(5.54) の  $p_{ijk}^o$  を用いるモデル  $H_n$  は「imperfection」の程度、すなはち (5.65) の成り立たない程度を示す数量化のモデルといつてもよいであろう。

9) モデルの検定および選択。一般に、統計的モデルめりには仮説の検定は、「より広いモデル  $G$  の中にて限定されたモデル  $H$  が成立するとなはれどか」という形式で行われる。Good (1973) は、モデルに含まれる数学的に独立な母数の個数をそのモデルの次元  $\dim(\cdot)$  とし、モデル  $G$  の中のモデル  $H$  の検定の自由度を

$$df(H|G) = \dim(G) - \dim(H) \quad (5.56)$$



と定義することを提案していり。2.2節で述べた一般的モデル(2.30)

の次元は

$$\dim(H) = \sum_{\alpha \in A} \dim(\Omega(\alpha)) \quad (5.57)$$

で与えられ。ここで、 $\Omega(\alpha)$ は母数空間 $\Omega$ での $\alpha$ -効果空間、

$A$ は  $\Omega$ の部分集合の任意のクラスであり、そのモデルが

$$H: A \in \bigoplus_{\alpha \in A} \Omega(\alpha),$$

である。 $\Omega(\alpha)$ のある直和空間に母数が含まれるという形式のものであることに注意しておこう。そこで、より広いモデルを母数空間 $\Omega$ 全体にとれば

$$G: A \in \Omega$$

かつ

$$\dim(G) = n$$

と書ける。ここでこの $G$ の中で $H$ の検定の自由度を(5.56)で求めるものとする。とくに

表5.1と表5.2では本節で扱ったモデルを一般的にモデル $H_g$

$$H_g: p_{ijk} = p_{ijk}^o + g_{ijk} u_i v_j w_k$$

とし、 $p_{ijk}^o$ の各種の場合と $H_g$ の次元、および

$$G: \sum_{i,j,k} p_{ijk} = 1$$

というもっとも広いモデルの中での $H_g$ の検定の自由度を表にまとめて



より、このとき、 $\dim(G)$  は  $rst - 1$  である。

実際の検定は、これまで述べた標本抽出過程のポアソンモデルや多項モデルの仮定のもとでは、

$$\chi^2 = \sum_{i,j,k} \frac{(x_{ijk} - \hat{m}_{ijk})^2}{\hat{m}_{ijk}}, \quad (5.58)$$

$$G^2 = 2 \sum_{i,j,k} x_{ijk} \log \frac{x_{ijk}}{\hat{m}_{ijk}}, \quad (5.59)$$

あるいは Hellinger distance (4.41), Freeman-Tukey (1950) による統計量などを用いることができる。ここで  $\{x_{ijk}\}$  は 3 軸分割表のセル度数、 $\hat{m}_{ijk}$  は各モデルの下での  $x_{ijk}$  の期待値の推定値である。対数線形モデルでは上記の検定統計量が漸近的に  $\chi^2$  分布に従う。しかし、加法モデルや数量化のため  $g(u_i v_j w_k)$  のような項を追加したモデルでは、(4.5) での  $\Sigma^{(1)}$ ,  $\Sigma^{(2)}$ ,  $\Sigma^{(3)}$  の定義からわかるようにセル確率自体を用いて内積を定義して因子効果を抽出するという事実から、 $\chi^2$  や  $G^2$  が漸近的に  $\chi^2$  分布に従うとは言えない。近似的に  $\chi^2$  分布を用いて検定を行っても経験的にはとんでもないかえはないか、注意を要するところである。

モデルの選択については、1.3 節で述べるように、対数線形モデルについての Goodman (1971) の方式や情報量現率 (AIC) の利用 [



吉沢・藤本(1976) 参照] などによって行うことができるよう。従来の  
数量化手法は、何らかの規準を満たすように、何をすべき数値を作  
り出すだけであって、そこでは与えられたデータに対する適合性がよ  
のか悪いのかを判断することができない。近似的にいって、これまで  
に示したモデルの適合性を検定するのによつて数量化の妥当性に  
対する一つの判断基準が与えられたという点に本節の理論の意味  
があると思われる。



### 5.3 多重分割表に対する数量化手法

前節では3重分割表に対する数量化手法とそのモデルを詳しく扱った。そこでのA型、B型、C型という数量化の形式は一般の多重分割表ではさらに複雑になる。しかし、B型やC型の数量化が2重分割表のA型数量化に帰着しようとするとき、一般的な多重分割表においても複合項目を考えることによってより少ない指標の配列の問題に帰着させられることもある。

一方、多重分割表に対する数量化手法として最高次相関係数の最大化を基準として各項目ごとに数量化するものはあまり有効とは思えない。その理由は、3重分割表のときと同様に、最高次交互作用の一部を抽出する意味を持ち、それがノイズを含みやすい高次の交互作用の不安定さの影響を受けてしまう。もっとも、高次の交互作用は異常にセル度数がかけ上大きくしていうようなときは、数量化としての意味より異常データの検出という目的に使用されるときがある。

ところで、一般的な多重分割表に対しては、確率論的に解釈しやすい相互独立モデル、部分独立モデル、あるいは条件独立モデルを中心として、それらの一つが適合するならそのモデル空間の中での数量化を行う、逆に、あるいは不適合なモデルの空間からのずれを数量化し、ときに異常値



の検出手段として利用するという方向が望ましいと思われる。

4.1節では加法モデルと多重配列の特異値分解との関連を述べた。

前節の加法モデルと数量化の関係は、得られたベクトル  $\tilde{u} = (u_i)$ ,  $\tilde{v} = (v_j)$ ,  $\tilde{w} = (w_k)$  にさらに直さうるベクトルを特異値分解によって得られるとして示している。一般的には定理3.8によって多重配列が分解され、高次の交互作用がその次元とともに大きく残っていなければ意味があらかもしれない。しかし、数量化の観点からの实用性には疑問が残る。



## 5.4 平方根分解

本節では、与えられた  $m$  重配列のセル度数を  $x_{\lambda_1 \lambda_2 \dots \lambda_m}$  とすとき、その平方根を要素とする  $m$  重配列

$$A = (\sqrt{x_{\lambda_1 \lambda_2 \dots \lambda_m}}) \quad (5.60)$$

の特異値分解に簡単に触れ、次節での数値例による検討の準備とする。この分解を平方根分解と呼ぶ [吉澤(1974)]。4.2 節で述べた平方根線形モデルはポアソンモデルなどでの分散安定化変換の効果をねらいとし、分散分析の母数モデルと同様の線形モデルであって、次節での数値例で示すように、多重分割表データの平方根分解によるモデルの選択は対数線形モデルや加法モデルの場合とほとんど同じ結論を導く。その点に関しては、平方根線形モデルは事情が異なり、 $\alpha$ -因子効果の定義の相違が他のモデルとの間に相当に現われてくる。

平方根分解は、上述のように、(5.60)の特異値分解であり、第3章の諸定理が直接に適用される。定理3.6によつて分解の各段での1因子効果が消える点を除くと、モデルの検定や選択には4.2節で平方根線形モデルについて述べた手法が利用できる。平方根線形モデルではセル確率の平方根を要素とする配列を取つて、ここでは次節の数値例や実用上の観察から (5.60) のようにセル度数の平方根を用ひるので、(4.50)の修正を示しておこう。



特異値分解の第1段で得られるベクトル  $\underline{U}^{(i)} (\forall i \in \bar{m})$  についての (5.60) の  $A$  の  $\alpha$ -因子効果を  $B(\alpha)$  とする。階層的（非階層的でもよいか）モデルに對する  $\bar{m}$  の部分集合  $\alpha$  のクラスを  $\mathcal{N}$  とする。そのとき、

$$\lambda = \left( \frac{1}{N} \sum_{\alpha \in \mathcal{N}} \underline{B}(\alpha)' \underline{B}(\alpha) \right)^{1/2} \quad (5.61)$$

とし、

$$D^2 = 4N (\cos^{-1} \lambda)^2 \quad (5.62)$$

を求める。この  $D^2$  が近似的に  $\chi^2$  分布に従うとモデルの検定に用ひる。

(5.61) と (4.49) の相違は  $1/N$  の因子の有無である。 $D^2$  の自由度は、

1因子効果が消えることから  $\underline{B}(\phi)' \underline{B}(\phi)$  に対して

$$\sum_{i=1}^m r_i - m + 1 \quad (5.63)$$

を割り当て、 $\alpha$  が空でない平方和には

$$\prod_{\alpha \in \mathcal{N}} (r_i - 1) \quad (5.64)$$

して、 $\mathcal{N}$  に含まれる  $\alpha$  についての総和を  $n$  から引いて求める。 $n$  はセル総数  $r_1 \times r_2 \times \dots \times r_m$  である。

4.2 節の終りに平方根線形モデルの特徴をあげたが、そのオーヒオニの特徴は平方根分解にも同様である。対数線形モデルの検定で (5.59) の  $G^2$  や (5.58) の  $\chi^2$  を用ひるには  $\hat{m}_{ijk}$  の計算がモデルジヒに必要であり、その都度  $G^2$  などもその式によって計算しなくてはならぬ。



ii. 平方根分解では次節で示すように一回の特異値分解によって平方和の表を作成すれば、回帰分析における変数選択 [例えば、奥野他(1969)参照] のような考え方で因子効果の選択が可能となり、それがこのモデルに対する  $D^2$  の計算もきわめて簡単である。一方、加法モデルでの平方和分解は、3重分割表の場合について (4.23) 式で示したようになり、例えば 3 因子効果が存在しないというモデル  $H_0$  に対する平方和

$$\sum_{i,j,k} \frac{(p_{ijk} - \alpha p_{ijk})^2}{p_{i+} p_{j+} p_{k+}}$$

は、いわゆる  $\chi^2$  検定統計量 (5.58) の

$$\sum_{i,j,k} \frac{(p_{ijk} - \alpha p_{ijk})^2}{\alpha p_{ijk}}$$

には一致しない。これに対し (5.60) の  $D^2$  は (5.58) の  $\chi^2$  や (5.59) の  $G^2$  と漸近的には同一の分布に従うものになってい。また、多重一次形式 (3.2) の  $\tilde{A}' \tilde{U}$  の最大化は、

$$u_{\lambda_1}^{(1)} u_{\lambda_2}^{(2)} \cdots u_{\lambda_m}^{(m)} = \sqrt{p_{\lambda_1 \lambda_2 \cdots \lambda_m}}$$

とおくことによって、相互独立モデルの方向への Hellinger distance の最小化とみなすことができる。相互独立モデルの方向への何らかの距離の最小化は Darroch (1974) が指摘している加法モデルと



対数線形モデルがともに持つ性質である。次節に示すように、平方根分解、加法モデル、及び対数線形モデルが類似性を持つのは、その性質による。3重分割表における3因子効果非存在の加法モデルは近似的に3の対数線形モデルを満たすことは Darroch(1974)に示されている。



## 5.5 數値例

平方根分解による多重分割表モデルの選択を中心に、これまで述べた加法モデルや対数線形モデルとの比較検討を二三の現実のデータを用いて行う。数値計算は山梨大学工学部計算機科学科のFACOM 230-45Sにより、FORTRAN プログラムの倍精度計算を使用した。第3章の算法1を中心として加法モデル、平方根線形モデル、及び平方根モデルが統一的に扱える機能を持つプログラムを作製したほか、対数線形モデル用には別途にプログラムを用意した。

多重配列データやテンソル積のプログラム上の取扱いは、プログラムの巧拙によって計算所要時間が著しく異なってくらうので注意を要する。我々のプログラムでは(3.29)による因子効果

$$\tilde{B}(\alpha) = \left( \bigotimes_{i=1}^m \tilde{J}_{x_{\alpha}(i)}^{(i)} \right)^k \tilde{A} \quad (5.65)$$

をすべての反復  $k=1, 2, \dots$  とすべての  $\alpha \in \bar{\mathcal{M}}$  について求めるようにしたのでこの計算にもっとも気を付ければならない。決定方程式(3.5)の解法かもう一つの要点であるが、これについては単純な反復計算によつてもセル数が1000程度までは経験的に实用上の問題はあまりない。(5.65)の右辺の括弧内は  $n \times n$  の行列、 $\tilde{A}$  は元ベクトルとして普通の行列とベクトルの内積をとると、プログラミングは簡単であるが、 $n^2$  に比例する時間がかかる。



その括弧内の行列はそもそもテンソル積の構造を持ってるので、高速フーリエ変換(FFT)の算法のように、多重配列の指標ごとに処理していくべきである。そうすれば  $n \log n$  に比例する時間で済む。さらに  $\bar{U}_j^{(i)}$  や  $\bar{U}_i^{(i)}$  の構造を利用するとそれに比例する時間に短縮される。 $(5.65)$  の計算のプログラム全体に占める時間は圧めて大きく、もっともまだいいプログラムで  $8 \times 9 \times 10$  の配列について 40 分程度かかるものが、上述の工夫によって 40 秒に短縮された例がある。

- a) 入試データ. ある大学の工学部の入学者選抜試験は 5 教科について行われ、うち 1 教科(社会)は 5 科目のうち 1 科目を選択して受験することになっている。その 5 科目を A, B, C, D, E とする。選択科目については問題の難易等によるあらゆる意味の不公平が生じかねない。この問題について吉澤・藤本(1976)によると対数線形モデルを用いて解析が報告されているが、ここではそこで使用された二種の  $5 \times 4 \times 2$  の 3 重分割表を用いて各種のモデルの適合性を調べる。表 5.3 と表 5.4 にその分割表のデータを示す。項目は、両者とも、科目(5 カテゴリ), 年度(4), 合否(合格と不合格の 2 カテゴリ)である。表 5.3 は実際の合格判定による科目 × 年度 × 合否の分割表である。一方、表 5.4 は選択のある教科を除いて残り 4 教科の総合による合格判定を行ったときの比較用の分割表である。



まず、表5.3と表5.4に対する平方根分解、平方根線形モデル、加法モデル(1)、及び加法モデル(2)による要因別の平方和分解の様子を、それぞれ表5.5a~dと表5.6a~dに示す。加法モデル(2)は4.1節の記述に従ってセル確率(相対度数)を用いたもので、加法モデル(1)は $\chi^2$ の分解になりますようにしたものである。セル度数を $x_{ijk}$ とすると、加法モデル(1)は

$$\frac{N x_{ijk}}{\sqrt{x_{i++} x_{+jk} x_{++k}}}$$

要素ごとに配列について特異値分解を行なうことに相当する。表5.5と表5.6の上の見出しは左から、FACTOR(要因 $\alpha$ )、DIM( $\alpha$ -効果空間の次元)、S.S.( $\alpha$ -因子効果に対する平方和)，以上が特異値分解のオ1段，以下は特異値分解のオ2段以後について繰り返される。また、平方根線形モデルを除いて1因子効果は理論どおりに消えてること、平方根分解と平方根線形モデルのオ1段での平方和の合計は5761でデータの総和に等しいこと、加法モデルでの $\alpha$ -効果(総平均)に対する平方和はモデル(1)で5761、モデル(2)で1と予想どおりであることが観測される。

次に、3重分割表に対する8ヒタリの階層的モデルに対する検定統計量の値を平方根分解( $D^2$ )、加法モデル[(4.23)の分解による $\chi^2_a$ ]、対数線形モデル( $\chi^2$ と $G^2$ )について、表5.5と表5.6に対して表5.7と表5.8に示す。表5.7と表5.8の最後の三欄は、モデルの検定の自由度、その自由



度と対数線形モデルでの $\chi^2$ による下側確率、情報量規準(AIC)の値である。赤池(1973)による情報量規準は

$$AIC = G^2 - 2 \times \text{自由度}$$

で計算され、その値が小さいモデルは相対的に妥当なモデルと判断しようという規準である。加法モデルではモデルから除かれる要因に対する平方和を加えうることによってその $\chi^2_a$ が計算される。例えば、階層的モデル 12/13 に対しては要因として {23} - と {123} - 効果が除かれ表5.7では

$$31.00 + 5.09 = 36.09$$

が $\chi^2_a$ の値となる。平方根分解の $D^2$ は(5.62)、対数線形モデルの $\chi^2$ と $G^2$ はそれそれ(5.58)と(5.59)による。

表5.7と表5.8で、対数線形モデルに対する $\chi^2$ と $G^2$ がほぼ等しいのは当然としても、 $D^2$ と $\chi^2_a$ ともかなり近い値を示しているのは注目に値しよう。なお、階層的モデルは2.2節で述べたようにその生成グラフで記号的に示されていく。 $1/2/3$ は相互独立、 $1/23$ ,  $2/13$ ,  $3/12$ は部分独立、 $12/13$ ,  $12/23$ ,  $13/23$ は条件独立、 $12/13/23$ は連関モデルといわれる。結論としては表5.7ではいずれの階層的モデルも採択されず、表5.8では $12/13$ 、すなわち科目ごとに年度と否否は独立というモデルが一応採用される。この結論だけで、選択科目間の不公平さを云々



するには早急に方をとる。しかし、選択のあり教科を除いたときの分割表（表5.4）にみられる構造性、すなはち、科目ごとに年度と合否が独立という構造性が、その教科を加えることによってみだされていふことは確かである。

以上、平方根分解、加法モデル、及び対数線形モデルの三者から似たような傾向を持つものに対し、平方根線形モデルはそれらとは異なる様相を示す。平方根モデルの定義から1因子効果が消えない。階層的モデルの選択を行えば、形式的には前三者のとおり同じモデルが選択されますが、その解釈は条件独立モデルといふような確率論的にすっきりしたものにはならない。一方で、平方根線形モデルではオ2項目の主効果（{12}-因子効果）が小さいといふことは、{12}-因子効果は存在するにもかかわらず、主効果としては無視できる、すなはち、非階層的なモデルを考えてもよいことを意味する。現実には、非階層的モデルは利用しがたいが、階層的モデルでなければ主効果が無視できるなら、例えば、部分独立モデル

$$p_{ijk} = p_{i++} p_{+jk}$$

に対し、 $p_{i++}$  が  $i$  に依存しないというようなモデルを導くので、その意味は大きい。実際、表5.3や表5.4のデータではオ2項目（年度）の周辺和はそれほど変動しないという事実が平方根をとることによる



- 尤に強く現われたと解釈されよう。

b) モデルの段階的選択. Goodman (1971) は、前述のように、対数線形モデルによるモデル構成のための段階的選択手続の一例を検討している。ここでは、Goodman が用いてデータに平方根分解を適用し、その平方和の分解表とともにモデルの選択を試みる。

データを表5.9に示す。 $2 \times 2 \times 2 \times 3$  の4重分割表である。このデータは洗剤の消費者テストによるものであろうが、ここではその詳細に触れず、モデルの選択のみに限って分析しよう。なお、Goodman の使用した項目記号は  $T \times U \times P \times S$  であり、例えば、ここで要因 134 と書くことは {TPS} に対応する。

平方根分解による平方和の分解の結果を表5.10にまとめり。最後の欄はそれまでの平方和と対応する因子効果の次元（いわゆる平方和の自由度）で割ったもので、1次元あたりの平方和と呼ぶ。ここでは、表5.10をもとに、階層的モデルの選択を行う。表5.11に一部の階層的モデルに対する  $D^2$ 、Goodman の計算による  $G^2$  [Goodman の記号は  $\chi^2$ ]、自由度、及び

$$AICR = D^2 - 2 \times \text{自由度}$$

による情報量規準の値を示す。ここでも  $D^2$  と  $G^2$  はよく類似している。前述のように、いわゆる階層的モデルについて  $D^2$ ,  $G^2$  あるいは情報



量規準を計算するとは実用的でない。とくに、対数線形モデルではモデルごとにセル度数の期待値を反復計算によって推定しなければならない。そこで、Goodman (1971) は重回帰分析における変数選択の手続を利用して二通りの手順を試みた。オ1は、すべての2因子効果を含むモデルから出発して変数増減法 [例えば、奥野他 (1971) 参照] の考え方を適用するもの、オ2は、すべての3因子効果を含むモデルから出発して変数減少法を適用するものである。もうモデル  $H_1$  のもとでの  $G^2$  と  $G^2(H_1)$  を書くと、 $H_1$  の中でのそれに含まれるモデル  $H_2$  の検定は

$$G^2(H_2 | H_1) = G^2(H_2) - G^2(H_1)$$

による  $\chi^2$  検定を用いる。ただし有意となれば先に進む。これが Goodman の方法である。この方法は  $\chi^2$  検定の有意水準の取り方に依存する。この手続に対し、平方根分解を用いれば、またオ1に、 $G^2$  のかわりに  $D^2$  を用いてみると完全に Goodman と同じ手順をふむことができる。この場合は同一の結論が得られ、モデルごとの反復計算が不要である分だけ簡単になる。オ2に二つのモデルの比較に AICR を用いる点を変更する。これは二つのモデルの間に階層性がなくても利用できるが、ここで階層的モデルの比較であり、上述の  $G^2(H_2 | H_1)$  を用ひるとあまり違はない。実際、有意水準を 5% 程度にとったときのオ1の手順と



同じ結論が得られる。一般のデータについて常にオ1とオ2の手順が同一の結論を与えるわけではないが、一つだけのモデルを選択してそれを絶対的にいいモデルと考えるわけではないので、実用上の差はないと思われる。オ3は手続の出発点となりモデルの決定方針を回帰分析のときのようにゼロまではすべての因子効果を含むモデルヒトランシヤ考えらる。表5.10を見れば、{中}-因子効果のつきにはただちに{23}-因子効果が選択され、{中}と出発点に立たんヒヤよさそうである。しかし、一般には、Goodmanの出発点のとり方で十分であらう。

平方根分解の良さは次の点にもある。いま、2因子効果ヒテ{23}だけを含むモデル  $1/23/4$  に対し次にとりいれらべき因子効果を選べばどうか。そのとき、 $D^2$  の算出式から  $D^2$  の減少については平方和最大(残りの因子), AICRについては次元ごとに平方和を比較するによってただちに選ぶべき因子効果が決定される。この場合、AICRについては1次元の中からは{13}と、2次元の中からは{14}と選ぶことになる。したがってモデル  $13/23/4$  と  $14/23$  の AICR  $-13.83$  と  $-14.09$  を比較し  $14/23$  のほうをめぐかによいと考えられる。

この方針を{中}-因子効果(独立モデル)から出発して徹底的に使用すると図5.1に示すように{中, 23, 14, 234, 13, 123}の川原に選択され、そ



のときの AICR の値は -17.66 となる。非階層的モデルとしてはこれが採用されよう。もし、階層的モデルを選択したいならば、 $\{ \emptyset, 23, 14, 234, 23, 123 \}$  の生成クラス  $\{ 14/234/123 \}$  を考え、このクラスの部分集合について AICR を計算して選ぶことができる。もう一度、増加法または減少法の考え方従って選択してもよい。その結果、 $\{ 14/123 \}$  が選択され、そのときの AICR は -15.53 となる。表 5.11 の中からそのほかの場合の AICR をみかせよう。表 5.11 の  $G^2$  の欄の \*EP は Goodman の論文に与えられていいらしいものである。その \*EP に相当する値、及び上述の手続きで選択されたモデル  $\{ 14/123 \}$  のセル期待値などの対数線形モデルでの分析を付録 3 に示しておく。

上述の算法を一般化することは容易であり、その効率性も期待される。実際の応用においては、一つの規準や算法による最良のモデルを選ぶのではなく、それに近い良さを示す相当数のモデルを抽出して解析者に提示する必要がある。



表5.1 モデル  $H_g$  における  $p_{ijk}^o$  の候補 (1)

	$p_{ijk}^o$	次元	自由度
I	$q_{ijk}$	$2(r+s+t)-8$	$rst-2(r+s+t)+7$
	$p_{i++}p_{+jk}$	$st + 2r+s+t-7$	$(r-1)(st-1)-(r+s+t-5)$
II	$p_{+j+p_{i+k}}$	$rt + r+2s+t-7$	$(s-1)(rt-1)-(r+s+t-5)$
	$p_{++k}p_{ij+}$	$rs + r+s+2t-7$	$(t-1)(rs-1)-(r+s+t-5)$
III	$p_{+j+p_{i+k}} + p_{++k}p_{ij+} - q_{ijk}$	$rs+rt+s+t-6$	$r(s-1)(t-1)-(r+s+t-5)$
	$p_{i++}p_{+jk} + p_{++k}p_{ij+} - q_{ijk}$	$rs+st+r+t-6$	$s(r-1)(t-1)-(r+s+t-5)$
	$p_{i++}p_{+jk} + p_{+j+p_{i+k}} - q_{ijk}$	$st+rt+r+s-6$	$t(r-1)(s-1)-(r+s+t-5)$
IV <sub>a</sub>	$p_{i++}p_{+jk} + p_{+j+p_{i+k}} + p_{++k}p_{ij+} - 2q_{ijk}$	$rs+st+rt-5$	$(r-1)(s-1)(t-1) - (r+s+t-5)$

表5.2 モデル  $H_g$  における  $p_{ijk}^o$  の候補 (2)

	$p_{ijk}^o$		
III	$p_{ij+p_{i+k}}/p_{i++}$	$rs+rt+s+t-6$	$r(s-1)(t-1)-(r+s+t-5)$
	$p_{ij+p_{jk}}/p_{+j+}$	$rs+st+r+t-6$	$s(r-1)(t-1)-(r+s+t-5)$
	$p_{+jk}p_{i+k}/p_{++k}$	$st+rt+r+s-6$	$t(r-1)(s-1)-(r+s+t-5)$
IV <sub>m</sub>	$m p_{ijk}$	$rs+st+rt-5$	$(r-1)(s-1)(t-1) - (r+s+t-5)$



表5.3 入試<sup>テ</sup>-タ(5教科)

## 合格者

科 目	'73	'74	'75	'76	+
A	3	3	4	2	12
B	29	28	31	31	119
C	200	196	125	130	651
D	153	162	195	224	734
E	65	61	95	63	284
+	450	450	450	450	1800

## 不合格者

科 目	'73	'74	'75	'76	+
A	12	16	13	5	46
B	104	101	100	86	391
C	371	394	315	287	1367
D	363	364	405	360	1492
E	172	190	146	157	665
+	1022	1065	979	895	3961

表5.4 入試<sup>テ</sup>-タ(4教科)

## 合格者

科 目	'73	'74	'75	'76	+
A	3	2	4	2	11
B	28	25	32	31	116
C	180	189	130	135	634
D	176	178	207	219	780
E	63	56	77	63	259
+	450	450	450	450	1800

## 不合格者

科 目	'73	'74	'75	'76	+
A	12	17	13	5	47
B	105	104	99	86	394
C	391	401	310	282	1384
D	340	348	393	365	1446
E	174	195	164	157	690
+	1022	1065	979	895	3961



表5.5 平方和分解表(表5.3のデータ)

## a) 平方根分解

FACTOR	DIM	S.S.	DIM	S.S.
0	1	5733.129	1	4.871
1	4	0.0	3	0.0
2	3	0.0	2	0.0
3	1	0.0	0	0.0
12	12	13.533	6	2.443
13	4	5.834	0	0.0
23	3	1.190	0	0.0
123	12	7.314	0	0.0

## b) 平方根線形モデル

FACTOR	DIM	S.S.	DIM	S.S.
0	1	4459.875	1	3.541
1	4	1057.721	3	0.0
2	3	2.799	2	0.0
3	1	195.229	0	0.0
12	12	14.807	6	1.332
13	4	23.288	0	0.0
23	3	2.408	0	0.0
123	12	4.873	0	0.0

## c) 加法モデル(1)

FACTOR	DIM	S.S.	DIM	S.S.
0	1	5761.	1	19.732
1	4	0.0	3	0.0
2	3	0.0	2	0.0
3	1	0.0	0	0.0
12	12	54.427	6	11.266
13	4	22.701	0	0.0
23	3	5.093	0	0.0
123	12	30.999	0	0.0

## d) 加法モデル(2)

FACTOR	DIM	S.S.	DIM	S.S.
0	1	1.	1	0.003
1	4	0.0	3	0.0
2	3	0.0	2	0.0
3	1	0.0	0	0.0
12	12	0.0094475	6	0.002
13	4	0.0039405	0	0.0
23	3	0.0008840	0	0.0
123	12	0.0053809	0	0.0



表5.6 平方根分解表(表5.4のデータ)

## a) 平方根分解

FACTOR	DIM	S.S.	DIM	S.S.
0	1	5732.644	1	1.951
1	4	0.0	3	0.0
2	3	0.0	2	0.0
3	1	0.0	0	0.0
12	12	13.625	6	0.371
13	4	11.210	0	0.0
23	3	1.199	0	0.0
123	12	2.322	0	0.0

## b) 平方根線形モデル

FACTOR	DIM	S.S.	DIM	S.S.
0	1	4452.071	1	1.074
1	4	1066.851	3	0.0
2	3	2.572	2	0.0
3	1	200.801	0	0.0
12	12	13.278	6	0.122
13	4	21.325	0	0.0
23	3	2.907	0	0.0
123	12	1.196	0	0.0

## c) 加法モデル(1)

FACTOR	DIM	S.S.	DIM	S.S.
0	1	5761.	1	.6.926
1	4	0.0	3	0.0
2	3	0.0	2	0.0
3	1	0.0	0	0.0
12	12	54.427	6	1.792
13	4	43.081	0	0.0
23	3	5.093	0	0.0
123	12	8.718	0	0.0

## d) 加法モデル(2)

FACTIR	DIM	S.S.	DIM	S.S.
0	1	1.	1	0.001
1	4	0.0	3	0.0
2	3	0.0	2	0.0
3	1	0.0	0	0.0
12	12	0.009475	6	0.000
13	4	0.0074781	0	0.0
23	3	0.0088401	0	0.0
123	12	0.0015132	0	0.0



表5.7 モデルの選択 (表5.3のデータ)

モデル	D <sup>2</sup>	X <sub>a</sub> <sup>2</sup>	X <sup>2</sup>	G <sup>2</sup>	DF	PROB.	AIC
1/2/3	111.67	113.22	113.22	111.94	31	100.0	49.94
1/23	106.89	108.13	107.40	106.87	28	100.0	50.87
2/13	88.26	90.52	88.63	88.21	27	100.0	34.21
3/12	57.40	58.79	56.00	56.84	19	100.0	18.84
12/13	34.04	36.09	33.56	33.10	15	99.6	3.10
12/23	52.64	53.70	50.92	51.77	16	100.0	19.77
13/23	83.49	85.42	83.09	83.13	24	100.0	35.13
12/13/23	29.27	31.00	28.68	28.35	12	99.6	4.35

表5.8 モデルの選択 (表5.4のデータ)

モデル	D <sup>2</sup>	X <sub>a</sub> <sup>2</sup>	X <sup>2</sup>	G <sup>2</sup>	DF	PROB.	AIC
1/2/3	113.61	111.32	111.32	112.52	31	100.0	50.52
1/23	108.80	106.23	105.48	107.45	28	100.0	51.45
2/13	68.65	68.24	67.51	68.14	27	100.0	14.14
3/12	58.98	56.89	54.84	57.43	19	100.0	19.43
12/13	14.09	13.81	12.93	13.05	15	39.2	-16.95
12/23	54.17	51.80	50.14	52.35	16	100.0	20.35
13/23	63.85	63.14	62.53	63.07	24	100.0	15.07
12/13/23	9.29	8.72	8.94	9.01	12	29.2	-14.99



表5.9  $2 \times 2 \times 2 \times 3$  分割表

P=1, S=1

U	X= 1	2
1	19	57
2	29	63

P=2, S=1

U	X= 1	2
1	29	49
2	27	53

P=1, S=2

U	X= 1	2
1	23	47
2	33	66

P=2, S=2

U	X= 1	2
1	47	55
2	23	50

P=1, S=3

U	X= 1	2
1	24	37
2	42	68

P=2, S=3

U	X= 1	2
1	43	53
2	30	42



表 5.10 平方根分解による平方和

FACTOR	DIM	S.S.	S.S./DIM
0	1	997.3548	
1	1	---	
2	1	---	
3	1	---	
4	2	---	
12	1	0.2267	0.2267
13	1	0.9734	0.9734
14	2	1.5349	0.7675
23	1	5.1372	5.1372
24	2	0.2556	0.1278
34	2	0.0595	0.0298
123	1	0.6570	0.6570
124	2	0.3758	0.1879
134	2	0.0284	0.0142
234	2	1.2594	0.6297
1234	2	0.1375	0.0688
TOTAL	24	1008.	



表5.11 モデルの検定

MODEL	D <sup>2</sup>	G <sup>2</sup>	DF	AICR
1/2/3/4	42.73	42.93	18	6.73
すべての2因子効果	9.84	9.85	9	-8.16
すべての3因子効果	0.55	0.74	2	-3.45
1/4/23	22.07	22.35	17	-11.93
4/13/23	18.17	17.99	16	-13.83
14/23	15.91	16.25	15	-14.09
2/3/14	36.55	*	16	4.55
1/234	15.76	*	11	-6.24
4/123	14.62	*	14	-13.38
14/234	9.60	*	9	-8.40
14/123	8.47	*	12	-15.53
234/123	8.31	*	8	-7.69
14/234/123	2.17	*	6	-9.83



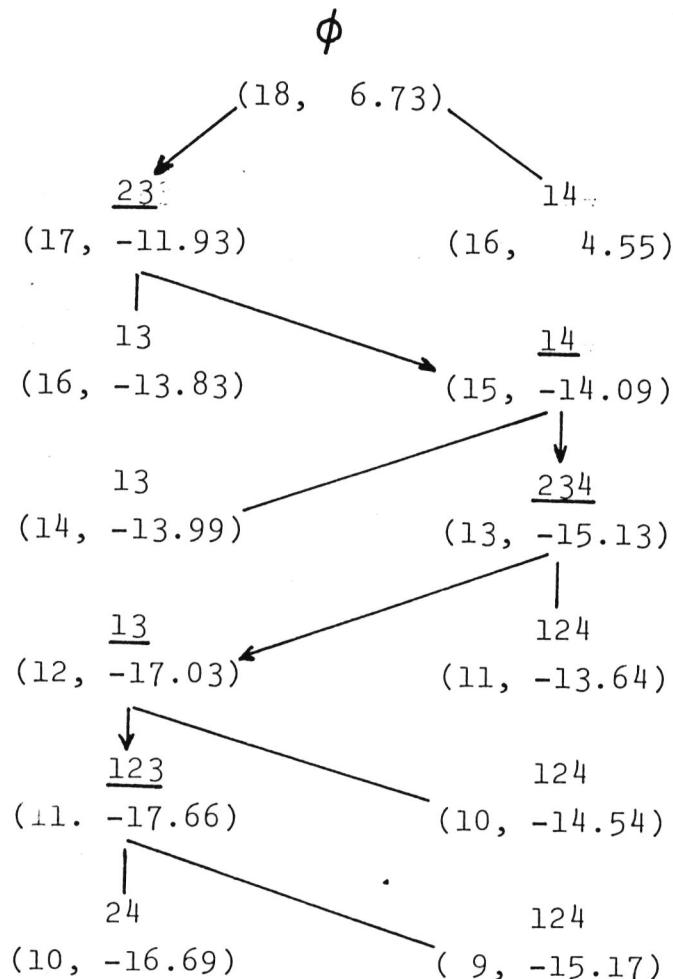


図5.1 非階層的モデルの選択

$\phi$  は 独立モデル  $1/2/3/4$  に相当する。  
 括弧の上に要因  $\alpha$ 、アンダーラインの下に  $\alpha$ -効果をヒリ入れられ、矢印の方向に進む。  
 括弧内にはそこまでにヒリ入れた因子効果によるモデルの検定の自由度と AICR を示す。



## 6. 多重配列の混合型分解

オ2章からオ5章までの議論は  $m$  と  $n$  の異なる項目を背景にして得られる  $m$  重配列を対象としたものであった。オ1章で多重配列の出所として述べた二つの項目が同一のものである場合、例えば同一の変数群に対する相関係、数行列や分散共分散行列が複数組ある場合など、その多重配列の要素を一次形式と二次形式の混合した形式の係数とみなすことによって、ここで混合型分解と称する多重配列の分解が可能となる。本章では混合型分解と特異値分解との関係、その算法、および簡単な数値例を示す。

### 6.1 混合型分解

ここでは、寸法  $r \times s \times s$  の3重配列をヒリオケ<sup>1</sup>、その要素を

$$A_{ijk} \quad (\forall i \in \bar{r}, \forall j \in \bar{s}, \forall k \in \bar{s}) \quad (6.1)$$

とする。添字  $j$  と  $k$  は同一の項目のカテゴリ、あるいは同一の変数群に属する変数に対応するものとする。この3重配列  $A$  についてオ2とオ3の添字に関する対称性、すなはち

$$A_{ijk} = A_{ikj} \quad (\forall i \in \bar{r}, \forall j, k \in \bar{s}) \quad (6.2)$$

を仮定する。そこで、次の問題を考える。

#### 問題 6. 制約条件



$$\left. \begin{array}{l} \sum_i u_i^2 = 1 \quad (\forall i \in \bar{r}); \\ \sum_j v_j^2 = 1 \quad (\forall j \in \bar{s}) \end{array} \right\} \quad (6.3)$$

の下で、混合形式

$$\rho = \sum_{i,j,k} A_{ijk} u_i v_j v_k \quad (6.4)$$

を最大にする  $u_i$  ( $\forall i \in \bar{r}$ ) と  $v_j$  ( $\forall j \in \bar{s}$ ) を求めること。

第3章において問題1から定理3.1と3.2を尊き、さらに算法1を提示してこれに関する諸定理と証明したのと、まったく並行な議論によって問題6から3重配列  $A$  の分解表現をうることができ。まず、次の二つの定理を示す。証明は定理3.1と3.2の場合と同様であるので省略する。

定理6.1. (6.4)の混合形式  $\rho$  について、次の不等式が成立立つ：

$$\rho^2 \leq \sum A_{ijk}^2. \quad (6.5)$$

等号が成立するのは、 $A_{ijk}$  の添字によらず  $u_i v_j v_k$  に比例するとき、そのときに限る。

定理6.2. 問題6の解は存在する。また、その解は次の決定方程式の  $\rho$  の最大根に対応するベクトル  $\underline{u} = (u_i)$ ,  $\underline{v} = (v_j)$  を (6.3) で正規化したものである：

$$\left. \begin{array}{l} \sum_{j,k} A_{ijk} v_j v_k = \rho u_i \quad (\forall i \in \bar{r}); \\ \sum_{i,j} A_{ijk} u_i v_j = \rho v_k \quad (\forall k \in \bar{s}). \end{array} \right\} \quad (6.6)$$



(6.6) の決定方程式の数値解法は いろいろ考えられますが、問題 1 に対する  
決定方程式 (3.5) を用ひたときも可能である。この場合、(3.5) を

$$\left. \begin{array}{l} \sum_{j,k} A_{ijk} v_j w_k = g u_i \quad (\forall i \in \bar{r}), \\ \sum_{i,k} A_{ijk} u_i w_k = g v_j \quad (\forall j \in \bar{s}), \\ \sum_{i,j} A_{ijk} u_i v_j = g w_k \quad (\forall k \in \bar{s}) \end{array} \right\} \quad (6.7)$$

と書く。 $A_{ijk}$ に図3.5の対称性(6.2)から(6.7)の解でよ

$$v_j = w_j \quad (\forall j \in \overline{S})$$

となり、(6.5)の解と一致することができる。そこで、算法 $i$ に対して次の算法を定義する。

算法2. 対称性(6.2)を持つ3重配列( $A_{i;j;k}$ )が与えられたとする。

- $\hat{A}_{ijk} = A_{ijk}$  とする.
  - $l = 1, 2, \dots$  について以下を反復する.
    - $\hat{A}_{ijk}$  がすべてゼロなら反復を終了する.
    - $\hat{A}_{ijk}$  について決定方程式 (6.6) を解く. その最大根を  $\varphi_l$ , 対応するベクトルを  $\hat{u}^l = (u_i)$ ,  $\hat{v}^l = (v_j)$  とする. ベクトルは (6.3) を満たすように正規化する.
    - $A_{ijk}^{l+1} = \hat{A}_{ijk} - u_i \sum_i^l \hat{A}_{ijk} u_i - v_j \sum_j^l \hat{A}_{ijk} v_j - v_k \sum_k^l \hat{A}_{ijk} v_k + 2\varphi_l u_i v_j v_k$ . (6.8)



注意. (6.8) で計算される  $\hat{A}_{ijk}^{l+1}$  は  $\hat{A}_{ijk}^l$  の 3 因子効果に相当する。  
 $\hat{A}_{ijk}^l$  の  $\alpha$ -因子効果を  $\hat{B}_{ijk}^l(\alpha)$  と書き, (3.29) にならって, 次のように定義  
できよう:

$$\left. \begin{aligned} \hat{B}_{ijk}^l(\phi) &= \beta_e \hat{u}_i \hat{v}_j \hat{v}_k; \\ \hat{B}_{ijk}^l(12) &= \hat{v}_k \sum_k \hat{A}_{ijk}^l \hat{v}_k - \beta_e \hat{u}_i \hat{v}_j \hat{v}_k; \\ \hat{B}_{ijk}^l(13) &= \hat{v}_j \sum_j \hat{A}_{ijk}^l \hat{v}_j - \beta_e \hat{u}_i \hat{v}_j \hat{v}_k; \\ \hat{B}_{ijk}^l(23) &= \hat{u}_i \sum_i \hat{A}_{ijk}^l \hat{u}_i - \beta_e \hat{u}_i \hat{v}_j \hat{v}_k. \end{aligned} \right\} \quad (6.9)$$

そのとき

$$\hat{A}_{ijk}^{l+1} = \hat{A}_{ijk}^l - \hat{B}_{ijk}^l(12) - \hat{B}_{ijk}^l(13) - \hat{B}_{ijk}^l(23) - \hat{B}_{ijk}^l(\phi) \quad (6.10)$$

と書け, 3 因子効果に相当する形になつて, 1 因子効果に相当する項が消えるのも算法 1 と同じで, (6.9) でその辺が述べられていいといえる. ここで,

$$\hat{B}_{ijk}^l(12) = \hat{B}_{ikj}^l(13) \quad (6.11)$$

となりや,  $\hat{B}_{ijk}^l(12)$  や  $\hat{B}_{ijk}^l(13)$  それぞれには  $j$  と  $k$  についての対称性はない. オ 2 と オ 3 指標とは同等のものであつから, {12}-因子効果と {13}-因子効果を区別する本質的な理由はないからや, 特異値分解との対応のため  $k$ -軸分離しておく. (6.11) から {12}-と {13}-因子効果のそれぞれの平方和が一致することは明らかである.

算法 2 は対称性 (6.2) を持つ 3 重配列に対し算法 1 と同じことであつた



ら、第3章における定理3.3以下の定理や補題に述べられておりましたが、ゆず  
かな字句の修正で算法2にも適用される。おもな性質だけを示しておこう。

定理6.3. 算法2は  $\min(r, s)$  回の反復で終了する。すなはち

$$A_{ijk} = 0 \quad (\forall i \in \bar{r}, \forall j, k \in \bar{s}) \quad (6.12)$$

となる。

補題3.1に詳しい、例えば

$$\sum_i^l B_{ijk}(12) \cdot u_i = \sum_j^l B_{ijk}(12) \cdot v_j = 0$$

となるように、 $B_{ijk}(\alpha)$ について  $i \in \alpha$  なら  $u_i$   $j \in \alpha$  なら  $v_j$ ,  $3 \in \alpha$  なら

$v_k$ との積和がゼロになることがわかる。補題3.2の(3.15)に対応する  
次の性質は重要な。

定理6.4. 算法2で得られるベクトル  $\{\tilde{u}_1, \tilde{u}_2, \dots\}$ ,  $\{\tilde{v}_1, \tilde{v}_2, \dots\}$

はそれが直交系となる。すなはち、

$$\sum_i^l \tilde{u}_i \tilde{u}_{i'} = 0, \quad \sum_j^{l'} \tilde{v}_j \tilde{v}_{j'} = 0 \quad (l \neq l'). \quad (6.13)$$

この定理から次の問題が簡単に処理される。

問題7.  $n$  次元、 $s$  次元ベクトル空間  $\mathbb{R}^{(1)}$  と  $\mathbb{R}^{(2)}$  でそれぞれ正規直  
交する  $l-1$  個ずつのベクトル  $\{\tilde{u}_1, \dots, \tilde{u}_{l-1}\}$  と  $\{\tilde{v}_1, \dots, \tilde{v}_{l-1}\}$  が与えられ  
たとき、条件

$$\sum_i^{l'} \tilde{u}_i u_i = \sum_j^{l'} \tilde{v}_j v_j = 0, \quad l' = 1, 2, \dots, l-1, \quad (6.14)$$



及び、条件(6.3)のもとで、混合形式

$$\varphi = \sum_{i,j,k} A_{ijk} u_i v_j v_k$$

を最大にすうべべトル  $\underline{u} = (u_i)$  と  $\underline{v} = (v_j)$  を求めること。

定理3.5に対応して次の定理を得る：

定理6.5. 問題7の解は

$$\hat{A}_{ijk} = \sum_{i',j',k'} V_{ii'}^{(1)} V_{jj'}^{(2)} V_{kk'}^{(2)} A_{i'j'k'} \quad (6.15)$$

で与えられ、 $\hat{A}_{ijk}$ について問題6を解くこと、すなはち決定方程式(6.6)を解くことによって与えられ、ここで、

$$\left. \begin{aligned} V_{ii'}^{(1)} &= \delta_{ii'} - \sum_{l'=1}^{l-1} \hat{u}_i \hat{u}_{i'} & (\forall i, i' \in \bar{r}), \\ V_{jj'}^{(2)} &= \delta_{jj'} - \sum_{l'=1}^{l-1} \hat{v}_j \hat{v}_{j'} & (\forall j, j' \in \bar{s}) \end{aligned} \right\} \quad (6.16)$$

で与えられる。

注意 (6.15) の  $\hat{A}_{ijk}$  は次の漸化式でも求められる：

$$\begin{aligned} \hat{A}_{ijk} &= A_{ijk}; \\ \hat{A}_{ijk} &= \hat{A}_{ijk} - B_{ijk}(12) - B_{ijk}(13) - B_{ijk}(23) - B_{ijk}(11) - B_{ijk}(22) \\ &\quad - B_{ijk}(3) - B_{ijk}(\phi), \quad l' = 1, 2, \dots, l-1. \end{aligned}$$

(6.17)には1因子効果に相当する  $B_{ijk}(1)$ ,  $B_{ijk}(2)$ ,  $B_{ijk}(3)$  の項が入っているが、(6.10)と(6.17)の相違である。問題7で与えられんべ

トルはからずしても決定方程式(6.6)を満足していない。そこで $\alpha$ -因子



効果は、 $\beta_{\ell'}$  で

$$\text{とし} \quad \beta_{\ell'} = \sum_{i,j,k}^{\ell'} A_{ijk} u_i v_j v_k \quad (6.18)$$

$$B_{ijk}(\phi) = \beta_{\ell'} u_i v_j v_k, \quad (6.19)$$

$$\left. \begin{aligned} B_{ijk}(1) &= v_j v_k \sum_{i,k}^{\ell'} A_{ijk} u_i v_k - \beta_{\ell'} u_i v_j v_k, \\ B_{ijk}(2) &= u_i v_k \sum_{i,k}^{\ell'} A_{ijk} u_i v_k - \beta_{\ell'} u_i v_j v_k, \\ B_{ijk}(3) &= u_i v_j \sum_{i,j}^{\ell'} A_{ijk} u_i v_j - \beta_{\ell'} u_i v_j v_k, \end{aligned} \right\} (6.20)$$

及ぶ

$$\left. \begin{aligned} B_{ijk}(12) &= v_k \sum_k^{\ell'} A_{ijk} v_k - B_{ijk}(1) - B_{ijk}(2) - B_{ijk}(\phi), \\ B_{ijk}(13) &= v_j \sum_j^{\ell'} A_{ijk} v_j - B_{ijk}(1) - B_{ijk}(3) - B_{ijk}(\phi), \\ B_{ijk}(23) &= u_i \sum_i^{\ell'} A_{ijk} u_i - B_{ijk}(2) - B_{ijk}(3) - B_{ijk}(\phi) \end{aligned} \right\}$$

で求められる。 $(6.9)$  と  $B_{ijk}(\phi)$  だけが変化する。 $(6.21)$

以上のはが、算法1に対する定理3.6, 3.7, 及び3.8, さらには系3.1, 定理3.9が、算法2に適用される。

定理6.6. 算法2で得られる  $A_{ijk}$  に対する (6.20) の 1 因子効果はゼロである。

定理6.7. 対称性 (6.2) を持つ  $r \times s \times s$  の 3 重配列  $A$  が算法2によると、次のように分解できる。これを混合型分解と呼ぶ。

$$A_{ijk} = B_{ijk}(\phi) + B_{ijk}(12) + B_{ijk}(13) + B_{ijk}(23) + \sum_{l=1}^{l+1} A_{ijk}, \quad (6.22)$$



ここで,  $\hat{A}_{ijk} = A_{ijk}$  となる.  $\hat{B}_{ijk}(\alpha)$  は (6.9) で与えられる.

定理 6.8. 前定理の分解表現 (6.22) に対し, 平方和分解

$$\begin{aligned}\sum (\hat{A}_{ijk})^2 &= \beta_\ell^2 + \sum (\hat{B}_{ijk}(12))^2 + \sum (\hat{B}_{ijk}(13))^2 \\ &\quad + \sum (\hat{B}_{ijk}(23))^2 + \sum (\hat{A}_{ijk})^2,\end{aligned}\quad \ell = 1, 2, \dots, \min(r, s) \quad (6.23)$$

が得られる.

注意.  $\hat{A}_{ijk}$  の  $\alpha$ -因子効果  $u_i v_j v_k$  に直すところによると, また,

$$\sum_{i,j,k} (\hat{B}_{ijk}(12))^2 = \sum_{i,j} \left( \sum_k \hat{A}_{ijk} v_k - \beta_\ell u_i v_j \right)^2$$

と変形することもできる.  $\hat{B}_{ijk}(13)$  と  $\hat{B}_{ijk}(23)$  についても同様である.

系 6.1. 次の不等式が成り立つ:

$$\beta_\ell^2 \leq \sum_{i,j,k} (\hat{A}_{ijk})^2. \quad (6.24)$$

等号が成り立つのには  $\hat{A}_{ijk}$  が  $u_i v_j v_k$  に比例する形のとき, それが限る.

平方和の自由度, あるいは  $\hat{A}_{ijk}$  に対する因子効果  $\hat{B}_{ijk}(\alpha)$  における数学的に独立なパラメータの個数については, (6.2) の対称性から, 次のように考えられる.  $A_{ijk}$  全体では (6.2) の対称性から

$$r s (s+1)/2 \text{ 個}$$

が独立である. 以下,  $\beta, u_i v_j v_k$  に対しては条件 (6.3) から



$$1 + r - 1 + s - 1 = r + s - 1,$$

以下,  $\dot{B}_{ijk}(12)$  と  $\dot{B}_{ijk}(13)$  は (6.11) から一方のみを考えればよく,  
独立なものは

$$(r-1)(s-1) \text{ 個},$$

$\dot{B}_{ijk}(23)$  は  $j, k$  についての対称性もあり

$$(s-1)s/2 \text{ 個}$$

が独立である。 $\dot{B}_{ijk}(123)$ , または  $\dot{A}_{ijk}$  については

$$(r-1)(s-1)s/2 \text{ 個}$$

が独立である。ここで、恒等式

$$\frac{rs(s+1)}{2} = (r+s-1) + (r-1)(s-1) + \frac{s(s-1)}{2} + \frac{(r-1)(s-1)s}{2}$$

に注意しあらう。以上の考え方を  $\dot{A}_{ijk}$  に適用して次の結果を得る。  
(6.25)

各平方和  $P_l^2$ ,  $\left\{ \sum_{i=1}^l \dot{B}_{ijk}(12)^2 + \sum_{i=1}^l \dot{B}_{ijk}(13)^2 \right\}$ ,  $\sum_{i=1}^l \dot{B}_{ijk}(23)^2$ ,  
 $\sum_{i=1}^l \dot{B}_{ijk}(123)^2$  は対称, その自由度を  $r+s-2l+1$ ,  $(r-l)(s-l)$ ,  
 $(s-l)(s-l+1)/2$ ,  $(r-l)(s-l)(s-l+1)/2$  と考えてよろしくある。



## 6.2 数値例

本節では、混合型分解の簡単な数値例を示す。前節で述べたように、多重配列の混合型分解は、算法2を用いて行われる。決定方程式(6.6)を解く反復解法は何もありか考えられ、また、第3章で述べた算法1の決定方程式を解くことによって可能である。実際には二・三の数値算法を試みたが、ここではその詳細は省略する。实用上、特異値分解のプログラム(5.5節参照)を用いれば十分である。

表6.1に $5 \times 5 \times 4$ の3重配列のデータを示す。このデータは入試の5教科についての年度ごとの相關係數行列( $5 \times 5$ )を4年分並べたものである。対称性を表示するため、6.1節の記号と異ってオ1とオ2項目の添字が一致するデータになっている。このデータでは、教科の一次結合ごとの分散(標準化されたデータでの)を年度ごとに求め、年度についての重み付きの分散和を最大にできるよう各の一次結合の係数と年度の重みを同時に求める、というのが混合形式2の最大化問題(問題6)の意味である。この意味で主成分分析[例えば、奥野他(1971)参照]の拡張になつていい。

表6.2に、混合型分解と特異値分解とを行ったときの平方和の分解の結果を示す。実際は、4段の分解ができるがオ2段まで



を示した。すなはち  $\beta_1 = 4.61, \beta_2 = 0.22, \beta_3 = 0.12, \beta_4 = 0.06$  である。

$\beta_1$ に対するベクトルは 教科に対して  $(.32, .42, .48, .48, .51)'$ 、年度に対して  $(.51, .52, .45, .51)$  である。教科に対する上記のベクトルは主成分分析でのオ1固有ベクトルに相当し、年度ごとの相関行列のオ1固有ベクトルの一様の平均になっている。年度に対するベクトルを見るとオ3年度だけがその重みが小さく、その年度の特異性を示している。

表6.2では {12} の効果、すなはち教科間の交互作用に相当する平方和が大きくなっていることが重要なである。このデータではオ2段以後の分解は丁度意味を持たない。主成分分析の観点からは、教科間の交互作用の項は、相関行列からオ1主成分の影響を除したものである。したがって、その交互作用項をさらに分解してオ2主成分に相当するものを抽出していくことか意味があろう。このような分析を戦略における大企業の多年にわたる財務指標間相関行列についても試みていいが、年度間の変動はそれほど大きくはない、二二の例と同じような事情にある。これ以上の分析は主成分分析と同じようになるので、その詳細は省略しよう。



表6.1 4年度分 相関係数行列

Z=1

Y	X= 1	2	3	4	5
1	1.0	0.230	0.283	0.170	0.218
2	0.230	1.0	0.367	0.248	0.396
3	0.283	0.367	1.0	0.409	0.481
4	0.170	0.248	0.409	1.0	0.532
5	0.218	0.396	0.481	0.532	1.0

Z=2

Y	X= 1	2	3	4	5
1	1.0	0.290	0.324	0.195	0.240
2	0.290	1.0	0.301	0.275	0.369
3	0.324	0.301	1.0	0.441	0.374
4	0.195	0.275	0.441	1.0	0.579
5	0.240	0.369	0.374	0.579	1.0

Z=3

Y	X= 1	2	3	4	5
1	1.0	0.162	0.176	0.154	0.196
2	0.162	1.0	0.309	0.203	0.336
3	0.176	0.309	1.0	0.334	0.355
4	0.154	0.203	0.334	1.0	0.421
5	0.196	0.336	0.355	0.421	1.0

Z=4

Y	X= 1	2	3	4	5
1	1.0	0.228	0.246	0.162	0.218
2	0.228	1.0	0.352	0.343	0.412
3	0.246	0.352	1.0	0.425	0.377
4	0.162	0.343	0.425	1.0	0.552
5	0.218	0.412	0.377	0.552	1.0

XとYはともに教科、又は年度をあらわす。



表6.2 平方和の分解表

FACTOR	DIM	S.S.	DIM	S.S.
0	1	21.266	1	0.050
1	4	0.0	3	0.0
2	4	0.0	3	0.0
3	3	0.0	2	0.0
12	16	7.623	9	0.029
13	12	0.012	6	0.003
23	12	0.012	6	0.003
123	48	0.105	18	0.021



## 7. あとがき

多重分割表データの解析に応用することを主目的として、多重配列構造を持つ母数空間の構造を追求し、多重配列の特異値分解を提示してその性質を調べてきた。多重分割表への応用としては、平方根分解の結果を分割表におけるモデル選択に有効に使用できることを示し、また、多重分割表における数量化手法と加法モデルとの関係を明らかにして、行列における特異値分解が、いばれば行列の固有値問題をヒントして、多変量解析の重要な理論的基礎となっていきるよう、今後、多重配列構造を持つデータの解析とその理論に、多重配列の特異値分解が役立つことが期待される。例えば、1.3節で触れた Tucker による 3 相因子分析と Lazarsfeld による潜在構造分析は多重配列形式のデータのある種の分解を目的とするものである。補題 2.3 のあたりの注意や (3.35) 式で示したように、多重配列  $A$  はベクトル空間  $\mathcal{U}^{(i)} (A \in \bar{\mathcal{M}})$  に適当な基底  $\{\tilde{u}_{k_i}^{(i)}, \forall k_i \in \bar{r}_i\}$  をとって

$$A_{\lambda_1 \lambda_2 \dots \lambda_m} = \sum_{k_1} \dots \sum_{k_m} g_{k_1 \dots k_m} u_{\lambda_1}^{(1)} \dots u_{\lambda_m}^{(m)} \quad (7.1)$$

と表現することができる。この式の右辺は、 $A$  のセル総数  $n$  に等しいだけの項があり、その  $n$  項のうち特殊なものだけを取り出して配列  $A$  が分解されるというようなモデルは、一般に  $A$  のセル数  $n$  が大きいとき



には、的確期待でないであります。潜在構造分析のモデルは、 $A$ を多重分割表のセル確率として

$$A_{\lambda_1 \dots \lambda_m} = \sum_k p_k \tilde{u}_{\lambda_1}^{(1)} \dots \tilde{u}_{\lambda_m}^{(m)}$$

と書けますという形式になります [Goodman (1974) を参照]。このモデルでは  $k$  は一つの潜在的なグルーフに応応するものとし、グルーフ内では、セル確率  $p_k$

$$\tilde{u}_{\lambda_1}^{(1)} \tilde{u}_{\lambda_2}^{(2)} \dots \tilde{u}_{\lambda_m}^{(m)}$$

という形で表われされます、すなはち、グルーフごとに項目間が相互に独立でありますと仮定しています。さらにグルーフの数も不明とし、それも推定の対象とする。現実にそのようなモデルが意味があるかは別にしても、推定されたベクトル  $\tilde{u}_i^{(c)} (A_i \in \bar{m})$  に対する本論での定義による因子効果などの意味を考察してみる必要がある。

また、3相因子分析では、(7.1) の  $k_1, \dots, k_m$  の動く範囲をできるだけ小さく、かつ、添字によらず一定にしておき、何らかの手段でベクトル  $\tilde{u}_i^{(c)}$  を推定しようとする。Tucker の方法では、少し指標ごとに何らかの形で单纯な固有値問題としてベクトル  $\tilde{u}_i^{(c)}$  を求まように持っていく。これに対して、最小二乗的

$$\sum_{\lambda_1 \dots \lambda_m} (A_{\lambda_1 \dots \lambda_m} - \sum_{k_1 \dots k_m} p_{k_1 \dots k_m} \cdot u_{\lambda_1}^{(1)} \dots u_{\lambda_m}^{(m)})^2 \rightarrow \min.$$



を標準として、特異値分解のように似た決定方程式を導いて解くといふことも不可能ではない。以上のように、潜在構造分析や3相因子分析などと本論での特異値の実質的関係の追求は今後の課題の一つであろう。

さて、Riemann空間の構造を持つ母数空間の研究を含めて、本論では母数空間 자체の構造に焦点をしぼってきく。しかし、母数空間は統計的推測問題と一体の関係にあり、とくに、多重分割表では標本抽出過程の確率モデルと切り離して考えられなければならない。多重分割表の多くの研究は、多項分布モデル、ときにはポアソン分布モデルを当然のこととして用いる。それに対してあまりに複雑な確率モデルを考えても多くの成果は期待できないが、これまでの各種の手法の異なりモデルの下でのえ質験性の研究の観点からも、種々の確率モデルを考える必要がある。また、多重分割表の構造性をとぐる計数統形モデルや加法モデルは、分散分析モデルでいう母数モデル(ANOVA Model I)の考え方をとっている。Fienberg (1975) も指摘しているように、多重分割表への変量モデルなどの導入も重要な課題であろう。筆者は化学工学における粒子の混合問題 [吉澤・新藤(1977)] と



多重分割表との関連からこの種の課題の研究をはじめよう。

なお、特異値分解は数値解析における多変数関数の近似問題とも関係があるろうと思われるなどなど、残された興味ある問題も少くはない。特異値分解の算法の数値解析的面からの報告も、プログラミング上の工夫についてし述べておけにとどめよう。

解かれり問題より、さらに生じり問題のほうや多いのは学問の世界の常である。これまでに得られた成果の上に、それを次の課題と今後とも一層追求してゆきたいと考えている。



## 謝 辞

本研究にあたっては、實に多くの方々からの御指導や助言、  
あるいは直接間接の協力を与えられました。

東京大学名誉教授、現電気通信大学教授・恩師森口繁一先生には、在学中に始まり、先生の助手として、また東京大学データ処理センター(現教育用計算機センター)在職中の上長として、現在に至るまで絶えず御指導を頂いてきました。そもそも母数空間の研究は学部卒業研究として森口先生の示唆を頂いたのが始まりで、今日まで続いているものである。統計学以外にも数値解析、あるいは計算機科学の面についても先生の御指導を忘れることが出来ません。

東京大学教授奥野忠一先生には、多変量解析の研究を通じて、また、本研究をまとめるにあたって、ひとかげならぬ御指導を受けました。

また、山梨大学工学部計算機科学科重永実、田中正次、赤尾洋二、野崎昭弘各教授をはじめ、藤本洋子助手、井内稔、技官、大学院生志村健一君、そのほか全教職員の方々には、日頃、直接的には研究に対する貴重な意見、あるいは協同研究



者としての討論を通じて、間接的には研究に適した環境の提供によって、この5年間の気ままな研究を許して頂いた。

さらに、東京大学教授伊理正夫先生をはじめ、審査にあたられた先生方からは、予備審査の段階より貴重な御意見を頂いた。東京大学工学部計数工学科教務室の方々には在学中より何かと御世話を頂き、今回もまた事務的な面倒をみて頂いた。

ここに記して、深甚の謝意を表する次第である。



## 参考文献

- Akaike, H. (1973). Information theory and an extention of the maximum likelihood principle. 2nd. International Symposium on Information Theory, B.N. Petrov and F. Csaki eds., Academai Kiado Budapest, 267-281.
- Bahadur, R.R. (1961). A representation of the joint distribution of responses to N dichotomous items. In H. Solomon ed., Studies in Item Analysis and Prediction. Stanford University Press.
- Bartlett, M.S. (1935). Contingency table interactions. J. Roy. Stat. Soc. Supplement, 2, 248-252.
- Bhattacharya, A (1946). On a measure of divergences between two multinomial populations. Sankhya, 7, 401-406.
- Birch, M.W. (1963). Maximum likelihood in three-way contingency tables. J. Roy. Stat. Soc., B, 25, 220-233.
- Birch, M.W. (1964). The detection of partial association, I: The 2x2 case. J. Roy. Stat. Soc., B, 26, 313-324.
- Birch, M.W. (1965). The detection of partial association, II: The general case. J. Roy. Sta. Soc., B, 27, 111-124.
- Bishop, Y.M.M. (1967). Multidimensional contingency tables: cell estimates. Unpublished Doctoral Dissertation, Dept. of Stat. Harvard University, Cambridge, Massachusetts.
- Bishop, Y.M.M. (1969). Full contingency tables, logits, and split contingency tables. Biometrics, 25, 383-400.
- Bishop, Y.M.M. (1971). Effects of collapsing multidimensional contingency tables. Biometrics, 27, 545-562.
- Bishop, Y.M.M., Fienberg, S.E. and Holland, P.W. (1975). Discrete Multivariate Analysis: Theory and Practice. M.I.T. Press, Cambridge, Massachusetts.
- Cox, D.R. (1972). The analysis of multivariate binary data. J. Roy. Stat. Soc., C, 21, 113-120.
- Cramer, H. (1946). Mathematical Methods of Statistics. Princeton University Press, 424.
- Darroch, J.N. (1962). Interactions in multi-factor contingency tables. J. Roy. Stat. Soc., B, 24, 251-263.
- Darroch, J.N. (1974). Multiplicative and additive interaction in contingency tables. Biomrtrika, 61, 207-214.
- Fienberg, S.E. (1975). Comment on "The observational study—A review. J. Amer. Stat. Assoc., 70, 521-523.
- Fisher, R.A. (1922). On the interpretation of  $\chi^2$  from contingency tables and the calculation of p. J. Roy. Stat. Soc., 85, 87-94.
- Fisher, R.A. (1924). The conditions under which  $\chi^2$  measures the discrepancy between observation and hypothesis. J. Roy. Stat. Soc., 87, 442-450.
- Forsythe, G.E. and Moler, C. (1967). Computer Solution of Linear Algebraic Equations. Prentice Hall, Englewood Cliffs, N.J.
- Freeman, M.F. and Tukey, J.W. (1950). Transformations related to the angular and the square root. Ann. Math. Statist., 21, 607-611.
- Good, I.J. (1963). Maximum entropy for hypothesis formulation, especially for multidimensional conyigency tables. Ann. Math. Statist., 34, 911-934.
- Goodman, L.A. (1964). Interactions in multidimensional contingency tables. Ann. Math. Statist., 35, 632-646.
- Goodman, L.A. (1969). On partitioning of  $\chi^2$  and detecting partial association in three-way contingency tables. J. Roy. Stat. Soc., B, 31, 486-498.



- Goodman, L.A.(1970). The multivariate analysis of qualitative data: J. Roy. Stat. Soc., 65, 226-256.
- Goodman, L.A.(1971a). The analysis of multidimensional contingency tables: stepwise procedures and direct estimation methos for building models for multiple classifications. Technometrics, 13, 33-61.
- Goodman, L.A.(1971b). Partitioning of  $\chi^2$ , analysis of marginal contingency tables, and estimation of expected frequencies in multidimensional contingency tables. J. Amer. Statist. Assoc., 66, 339-344.
- Goodman, L.A.(1974). Exploratory latent structure analysis using identifiable and unidentifiable models. Biometrika, 61, 215-231.
- Grizzle, J.E. Starmer, C.F. and Koch, G.G.(1969). Analysis of categorical data by linear models. Biometrics, 25, 489-504.
- Haberman, S.J.(1974). The Analysis of Frequency Data. University of Chicago Press, Chicago, Il.
- Halmos, P.R.(1958). Finite Dimensional Vector Spaces. 2nd. ed., Van Nostrand, Princeton, N.J.
- Hellinger, E.(1909). Neue Begründung der Theorie quadratischer Formen von unendlichvielen Veränderlichen. J. Reine Angew. Math., 136, 210-271.
- Hotelling, H.(1936). Relations between two sets of variables. Biometrika, 28, 321-377.
- 岩坪秀一(1971). 多次元質的データ構造の解析—重相関係数による数量化—.  
電子技術総合研究所叢報 35. 7.
- 岩坪秀一(1974). 3-way 離散データを分類する二つの方法—相関比と3次相  
関係数による数量化—. 行動計量学, 2, 54-65.
- Kendall, M.G. and Stuart, A.(1961). The Advanced Theory of Statistics, Vol.2. Charles Griffin and Co., London.
- Kettenring, J.R.(1971). Canonical analysis of several sets of variables. Biometrika, 58, 433-451.
- Killion, R.A. and Zahn, D.A.(1976). A bibliography of contingency table literature: 1900 to 1974. Int. Stat. Rev., 44, 71-112.
- Kullback, S.(1959). Information Theory and Statistics. John Wiley and Sons, New York.
- Lancaster, H.O.(1951). Complex contingency tables treated by the partition of  $\chi^2$ . J. Roy. Stat. Soc., B, 13, 242-249.
- Lancaster, H.O.(1960). On test of independence in several dimensions. J. Austral. Math. Soc., 1, 241-254.
- Lancaster, H.O.(1969). The Chi-squared Distribution. John Wiley and Sons, New York.
- Lazarsfeld, P.F.(1961). The algebra of dichotomous systems. In H. Solomon ed., Studies in Item Analysis and Prediction. Stanford University Press.
- Lasarsfeld, P.F. and Henry, N.W.(1968). Latent Structure Analysis. Houghton.
- Maung, K.(1942). Measurement of association in a contingency table with special reference to the pigmentation of hair and eye colours of Scottish school children. Ann. Eugen. London, 11, 189-223.
- McKinlay, S.M.(1975). The design and analysis of the observational study—A review. J. Amer. Statist. Assoc., 70, 503-520.
- Neyman, J.(1949). Contribution to the theory of the  $\chi^2$  test. Proc. of the First Berkeley Symposium, 239-274.
- 西里静彦(1977). 尺度法とその周連領域：文献目録に見る最近の動向(1). 行動計量学, 4, 74-95.



奥野忠一, 芳賀敏郎, 久米均, 吉澤正(1971). 多変量解析法. 日科技出版社, 430.

- Pearson, K.(1900a). On the criterion that a given system of deviations from the probable in the case of a correlated system of variables is such that it can reasonably supposed to have arisen from random sampling. Philos. Mag., Series 5, 50, 152-172.
- Pearson, K.(1900b). Mathematical contributions to the theory of evolution. VII: On the correlation of characters not quantitatively measurable. Philos. Trans. Roy. Soc. London, A, 195, 1-47.
- Pearson, K.(1904). Mathematical contributions to the theory of evolution. XIII: On the theory of contingency and its relation to association and normal correlation. Drap. Co. Mem., Biom. Ser. No.1.
- Plackett, R.L.(1969). Multidimensional contingency tables: A survey of models and methods. Bull. Inter. Statist. Inst., Vol.43, Book 1, 133-142.
- Plackett, R.L.(1974). Analysis of Categorical Data. Hafner, New York.
- Rao, C.R.(1961). Asymptotic efficiency and limiting information. Proc. Fourth Berkeley Symposium, 1, 531-546.
- Rao, C.R.(1962). Efficient estimates and optimum inference procedures in large samples (with discussion). J. Roy. Stat. Soc., B, 24, 46-72.
- Rao, C.R.(1963). Criteria of estimation in large samples. Sankhya A, 25, 189-206.
- Rao, C.R.(1973). Linear Statistical Inference and its Application. 2nd. ed., John Wiley and Sons, New York.
- Roy, S.N. and Kastenbaum, M.A.(1956). On the hypothesis of no interaction in multiway contingency table. Ann. Math. Statist., 27, 749-757.
- Simpson, E.H.(1951). The interpretation of interaction in contingency table. J. Amer. Statist. Assoc., 69, 971-976.
- 竹内啓(1976). 情報統計量の分布とモデルの適切さの規準. 数理科学, 1976年3月号, 12-18
- Tucker, L.R.(1964). The extension of factor analysis to three dimensional matrices. Contributions to Mathematical Psychology. Holt, Rinehart and Winston, Inc.
- 吉澤正(1974). 分割表における平方根分解. 第2回日本行動計量学会総会発表論文抄録集, 80-81.
- 吉澤正(1975). 分割表における数量化モデル—その理論的検討—. 行動計量学, 3, 1-11.
- 吉澤正(1976). 交互作用概念の一般化と多重配列の特異値分解. 行動計量学, 4, 32-43.
- 吉澤正, 藤本洋子(1976). 入学者選抜試験における選択科目の解析. 山梨大学工学部研究報告, 27, 108-115.
- 吉澤正, 新藤久和(1977). 混合状態の記述とベーチニア分布. 品質, 7, 130-136.



- Yule, G.U.(1900). On the association of attributes in statistics:  
With illustrations from the material from The Childhood Society.  
Philos. Trans. Roy. Soc. London, A, 194, 257-319.
- Yule, G.U.(1912). On the methods of measuring association between  
two attributes. J. Roy. Stat. Soc., 72, 579-642.



# 附錄 1

Memorandum TYH-2

A Geometry of Parameter Space  
and its Statistical Interpretation

Tadashi Yoshizawa

November 2, 1971

at Department of Statistics  
Harvard University  
Cambridge, Massachusetts, U.S.A.



## 0. Abstracts

The space which is composed of the parameters of a distribution, the parameter space, may be considered as a Riemannian space by introducing an appropriate metric under some conditions. Invariant quantities in a geometry have very important meanings in its application to various fields of science. It is shown that a necessary and sufficient condition for existence of covariance stabilizing transformation is that the Riemann-Christoffel curvature tensor calculated from the metric is zero. Some population spaces with constant Gaussian curvatures which are immersed in higher dimensional Euclidean spaces and the concept of distance in population spaces are discussed with examples. Finally the relations between this geometry and Fisher's information matrix or the other definitions of distance or divergence between two distributions are mentioned.



## 1. Introduction

In this paper we consider a parameter space as a Riemannian space by introducing a fundamental tensor of the metric and discuss the statistical meanings of various invariant quantities in the Riemannian space. The inverse of a covariance matrix of a real-valued random vector whose asymptotic distribution is a Normal distribution is used as a fundamental tensor of the metric in section 2.

In section 3, the Riemann-Christoffel curvature tensor which is a typical invariant quantity in a Riemannian space is interpreted. It is shown that the condition for existence of a covariance stabilizing transformation is that all components of the Riemann-Christoffel curvature tensor are zeros, and that a condition given by Holland (1971) in two dimensional case is equivalent to our condition.

In section 4, by calculating Gaussian curvatures of some parameter spaces, it is shown that parameter spaces of a multinomial distribution and one dimensional normal distribution have positive and negative constant Gaussian curvatures respectively. Since a Riemannian space with a constant curvature may be interpreted as a fundamental hyperquadric of a higher (by one) dimensional Euclidean space, the coordinates of the Euclidean space in which the Riemannian space is immersed are given.

In section 5, it is shown that a statistic with asymptotically constant variance is formed by a transformation associated with geodesics in the parameter space. Such



transformations are given with respect to the same examples as in section 4. Finally in section 6, the relation between this geometry and Fisher's information matrix is discussed.

Details of tiresome calculations will be given in the appendices.

The idea that a parameter space may be regarded as a Riemannian space by introducing an appropriate metric has been proposed by Rao (1945) and Yoshizawa (1962) using Fisher's information matrix. Rao gave a solution for geodesics in the case of a parameter space composed of the parent mean and standard deviation of a normal distribution in more complicated form than ours and tried to use it for testing in large samples without noticing its asymptotically constant variance. Yoshizawa, at the suggestion of Professor Moriguti, gave some examples of spaces with constant Gaussian curvatures and discussed their statistical meanings.

Recently Holland (1971) considered an asymptotic concept of a covariance stabilizing transformation and gave a necessary and sufficient condition for its existence. The author studied this problem again receiving impetus from Holland's paper.



## 2. Introduction of a fundamental tensor of the metric

Let  $x_n$  and  $\theta$  be a real valued p-dimensional random vector with coordinates  $x_n^i$  and a p-dimensional parameter with coordinates  $\theta^i$ , respectively. This vector parameter,  $\theta$ , varies over  $D$ , an open, simply connected region of  $R^P$ . Finally, assume that  $\sqrt{n}(x_n - \theta)$  has an asymptotic multivariate Normal distribution with zero mean vector and a non-singular covariance matrix, i.e.

$$(1) \quad \mathbb{E}[\sqrt{n}(x_n - \theta)] \rightarrow N(0, \Sigma(\theta))$$

where  $\Sigma(\theta)$  is positive definite for all  $\theta \in D$ .

Let  $\theta'$  be a new p-dimensional coordinate system transformed one to one by

$$(2) \quad \theta' = f(\theta).$$

It is easily seen that  $\sqrt{n}(f(x_n) - f(\theta))$  has an asymptotic multivariate Normal distribution with zero mean vector and a non-singular covariance matrix, i.e.

$$(3) \quad \mathbb{E}\sqrt{n}[f(x_n) - f(\theta)] \rightarrow N(0, \Sigma'(\theta))$$

where

$$(4) \quad \Sigma'(\theta) = (\frac{\partial \theta'}{\partial \theta}) \Sigma(\theta) (\frac{\partial \theta'}{\partial \theta})$$

and  $(\frac{\partial \theta'}{\partial \theta})$  means the Jacobian matrix of the transformation (2) under conditions that all partial derivatives  $\partial \theta'^i / \partial \theta^k$  exist and that the Jacobian is not zero (see Holland [1971]).

Let  $g^{ij}$  and  $g'^{ij}$  denote the elements of  $\Sigma(\theta)$  and  $\Sigma'(\theta)$  respectively. We may rewrite (4) as



$$(5) \quad g'^{ij} = g^{kl} \frac{\partial \theta^i}{\partial \theta^k} \frac{\partial \theta^j}{\partial \theta^l}$$

where Einstein summation convention\* is used. We shall use this convention hereafter. From (5) it is seen that  $g'^{ij}$  is a contravariant tensor of the second order.

Let  $g_{ij}$  be components of the inverse matrix  $\Sigma(\theta)$ , i.e.

$$(6) \quad g^{ij} g_{kj} = \delta_k^i$$

where  $\delta_k^i$ 's are Kronecker deltas. Since it is seen from (5) and (6) that the law of transformation of  $g_{ij}$  to  $g'^{ij}$  is

$$(7) \quad g'^{ij} = g_{kl} \frac{\partial \theta^k}{\partial \theta^i} \frac{\partial \theta^l}{\partial \theta^j}$$

$g_{ij}$  is a covariant tensor. It is also positive definite.

Therefore we may take formally as the basis of the metric of a parameter space, a space of parameter  $\theta$ , a real fundamental quadratic form

$$(8) \quad \phi = g_{ij} d\theta^i d\theta^j .$$

The tensor  $g_{ij}$  is called the fundamental tensor of the metric. If element of length  $ds$  is defined by

$$ds^2 = g_{ij} d\theta^i d\theta^j$$

noticing that  $g_{ij}$  is positive definite, from (7) it is seen that  $ds^2$  is invariant under the transformation (2). This definition of  $ds$  may be acceptable as an extension of the concept of concentration matrix by Dempster [1969]. When  $\theta$

---

\* When the same letter appears in any terms as a subscript and superscript, it is understood that this letter is summed up for all the values, say  $p$ , which this letter takes.  $k$  and  $l$  in (5) are the examples of such letters, called dummy indecies.



is a mean vector of a multivariate Normal distribution with constant  $\Sigma$  this distance is no more than Mahalanobis' generalized distance (Mahalanobis [1936]).

Invariant quantities in a geometry have very important meanings in its application. In the following chapters we will discuss statistical meanings of several geometrical concepts in parameter space as a Riemannian space.

### 3. Riemann-Christoffel curvature tensor and covariance stabilizing transformation

Holland [1971] defined a covariance stabilizing transformation  $f$  as a set of functions (2) which satisfies

$$(10) \quad g^{ij} \frac{\partial \theta^k}{\partial \theta^i} \frac{\partial \theta^\ell}{\partial \theta^j} = \delta_\ell^k .$$

We may rewrite this condition as

$$(11) \quad g_{ij} \frac{\partial \theta^i}{\partial \theta^k} \frac{\partial \theta^j}{\partial \theta^\ell} = \delta_\ell^k .$$

from (6).

A space which has  $\delta_\ell^k$  as the fundamental tensor of the metric is called a Euclidean space. Therefore the condition (10) or (11) for existence of a covariance stabilizing transformation may be replaced by the condition that a Riemannian space be Euclidean. Since it is well known that the latter condition is that the Riemann-Christoffel curvature tensor vanishes (e.g. see Veblen [1933], pp 69-71), we obtain the following theorem.



Theorem 1: The necessary and sufficient condition that a covariance stabilizing transformation exists is that all components of the Riemann-Christoffel curvature tensor are equal to zero, i.e.

$$(12) \quad R_{hijk} = 0,$$

where

$$(13) \quad R_{hijk} = \frac{\partial}{\partial \theta^j} [ik, h] - \frac{\partial}{\partial \theta^k} [ij, h] + \{_{ij}^{\ell}\} [hk, \ell] - \{_{ik}^{\ell}\} [hj, \ell],$$

$$(14) \quad [ij, k] = \frac{1}{2} \left( \frac{\partial g_{ik}}{\partial \theta^j} + \frac{\partial g_{jk}}{\partial \theta^i} - \frac{\partial g_{ij}}{\partial \theta^k} \right),$$

$$(15) \quad \{_{ij}^{\ell}\} = g^{\ell k} [ij, k].$$

$[ij, k]$  and  $\{_{ij}^{\ell}\}$  are called Christoffel 3-index symbols of the first and second kinds, respectively.

In the definition (6) we find that the components of Riemann-Christoffel curvature tensor satisfy the following identities:

$$(16) \quad \begin{aligned} R_{hijk} &= -R_{ihjk}, \\ R_{hijk} &= -R_{hikj}, \\ R_{hijk} &= R_{jkhi}, \end{aligned}$$

and

$$(17) \quad R_{hijk} + R_{hjki} + R_{hkij} = 0.$$

The number of independent components of Riemann-Christoffel curvature tensor is at most  $p^2(p^2-1)/12$  due to the identities (16) and (17). In the two dimensional case

$$R_{1212} = R_{2121} = -R_{1221} = -R_{2112}$$



and the other components are zero. Therefore we may write the condition (12) in two dimensional case as

$$(18) \quad R_{1212} = 0.$$

The equivalence between (18) and the condition obtained by Holland [1971] will be shown in Appendix A.

#### 4. Gaussian curvature and space with a constant curvature

Gaussian curvature defined as

$$(19) \quad K = \frac{R_{hijk}}{g_{hj}g_{ik}-g_{hk}g_{ij}}$$

has an important role in Riemannian geometry. In particular a p-dimensional Riemannian space with constant Gaussian curvature can be immersed in p+1 dimensional Euclidean space and can be interpreted as a fundamental hyperquadric of the Euclidean space. The hyperquadric is defined by

$$(20) \quad \sum_{\alpha=1}^{p+1} c_{\alpha} (z^{\alpha})^2 = \frac{1}{K},$$

where  $c_{\alpha}$ 's are plus or minus one according to the character of the fundamental form and  $z^{\alpha}$ 's are a set of solutions of the equations

$$(21) \quad \frac{\partial^2 z^{\alpha}}{\partial \theta^i \partial \theta^j} - \frac{\partial z^{\alpha}}{\partial \theta^h} \{^h_{ij}\} = -K g_{ij} z^{\alpha}, \quad (\alpha=1, \dots, p+1)$$

(See Eisenhart [1926]). The left-hand of the above equation (21) is called covariant differentiation with respect to a tensor  $g_{ij}$  and denoted by  $z^{\alpha},_{ij}$



Example 1: A parameter space of means of a p-dimensional Normal distribution with constant covariance matrix  $\Sigma$ .

The fundamental tensor of the metric is the inverse of  $\Sigma$ . It is obvious that this space is Euclidean since the fundamental tensor is constant and it may be diagonalized by simple transformation. Of course,  $K$  is zero in this case.

Example 2: The trinomial distribution

Let  $nT_n$  have a trinomial distribution. The parameter space,  $D$ , is given by:

$$D = \{(\begin{matrix} \theta^1 \\ \theta^2 \end{matrix}): \theta^1 > 0 \text{ and } \theta^1 + \theta^2 < 1\}.$$

Standard theory implies that

$$\mathbf{E}[\sqrt{n}(T_n - \theta)] \rightarrow N(0, \Sigma(\theta))$$

where

$$\Sigma(\theta) = \begin{pmatrix} \theta^1(1-\theta^1) & -\theta^1\theta^2 \\ -\theta^1\theta^2 & \theta^2(1-\theta^2) \end{pmatrix}.$$

Therefore, the fundamental tensor of the space is given as follows:

$$(g_{ij}) = \Sigma(\theta)^{-1} = \begin{pmatrix} \frac{1-\theta^2}{\theta^1(1-\theta^1-\theta^2)} & \frac{1}{1-\theta^1-\theta^2} \\ \frac{1}{1-\theta^1-\theta^2} & \frac{1-\theta^1}{\theta^2(1-\theta^1-\theta^2)} \end{pmatrix}$$



Holland [1971] showed that there exists no covariance stabilizing transformation in this case and Yoshizawa [1962] obtained the Gaussian curvature as

$$K = \frac{1}{4}.$$

This space has a positive constant Gaussian curvature and may be regarded as a sphere in a three dimensional Euclidean space. The coordinates of the Euclidean space are obtained as a set of solutions as follows:

$$(22) \quad z^1 = 2\sqrt{\theta^1}, \quad z^2 = 2\sqrt{\theta^2}, \quad z^3 = 2\sqrt{\theta^3},$$

where  $\theta^3 = 1 - \theta^1 - \theta^2$  (See Appendix B). From (20) the equation of the sphere is

$$(23) \quad (z^1)^2 + (z^2)^2 + (z^3)^2 = 4,$$

that is,

$$\theta^1 + \theta^2 + \theta^3 = 1.$$

This fact gives a convenient interpretation of the parameter space of a trinomial distribution.

The results obtained here can be extended to the parameter space of the multinomial distribution (See Appendix B).

Example 3: The Normal distribution  $N(\mu, \sigma^2)$

Let  $\theta^1$  and  $\theta^2$  be the mean  $\mu$  and variance  $\sigma^2$  respectively. The fundamental tensor of the metric is given as follows:

$$g_{11} = \frac{1}{\theta^2}, \quad g_{12} = g_{21} = 0, \quad g_{22} = \frac{1}{2(\theta^2)^2}$$



The only one independent components of the Riemann-Christoffel curvature  $R_{1212}$  is

$$R_{1212} = -\frac{1}{4(\theta^2)^3},$$

and Gaussian curvature is

$$K = \frac{R_{1212}}{g_{11}g_{22}-g_{12}g_{21}} = -\frac{1}{2}.$$

Therefore no covariance stabilizing transformation exists.

Since this space has a negative constant Gaussian curvature it may be regarded as a hyperbolic surface in a three dimensional Euclidean space. The coordinates of the Euclidean space are given as

$$(24) \quad \begin{aligned} z^1 &= \frac{\theta^1}{\sqrt{\theta^2}} = \frac{\mu}{\sigma}, \\ z^2 &= \frac{(\theta^1)^2 - 2}{2\sqrt{2}\sqrt{\theta^2}} + \frac{\sqrt{\theta^2}}{\sqrt{2}} = \frac{\mu^2 - 2}{2\sqrt{2}\sigma} + \frac{\sigma}{\sqrt{2}}, \\ z^3 &= \frac{(\theta^1)^2 + 2}{2\sqrt{2}\sqrt{\theta^2}} + \frac{\sqrt{\theta^2}}{\sqrt{2}} = \frac{\mu^2 + 2}{2\sqrt{2}\sigma} + \frac{\sigma}{\sqrt{2}}, \end{aligned}$$

solving the equations (21) and comparing the fundamental forms of the Euclidean space and of the Riemannian space.

The equation of the hyperbolic surface is given by

$$(25) \quad (z^1)^2 + (z^2)^2 - (z^3)^2 = -2.$$



### 5. Distance and geodesics

The distance between two points in a parameter space has a meaning as a kind of measure for the difference or divergence between two distributions. The distance may be naturally defined as the arc of geodesic curve between two points due to the theory of Riemannian geometry. The elements of length  $ds$  is defined by (9) and the arc of geodesic curve is given by the solution of the following equations:

$$(26) \quad \frac{d^2\theta^\ell}{ds^2} + \{\ell_{jk}\} \frac{d\theta^j}{ds} \frac{d\theta^k}{ds} = 0.$$

These equations are Euler's equations of the integral

$$s = \int_{t_1}^t \sqrt{g_{ij} \frac{d\theta^i}{dt} \frac{d\theta^j}{dt}} dt$$

where  $t$  is a parameter which defines real curve. Along the geodesic we have

$$(27) \quad g_{ij} \frac{d\theta^i}{ds} \frac{d\theta^j}{ds} = 1.$$

If we put new coordinates associated with the geodesic passing through the particular point  $\theta_0$  such that

$$(28) \quad \theta',i = \left( \frac{d\theta^i}{ds} \right)_0 s$$

the arc of the geodesic may be expressed as

$$(29) \quad s^2 = (g_{ij})_0 \theta',i \theta',j .$$



Notice that this form may be interpreted as an extension of Mahalanobis' generalized distance. Moreover if we transform  $\theta^i$  to  $\theta''^i$  such that  $\theta''^1$  will express the arc of the geodesic, the fundamental form of  $\theta''^i$  is reduced to

$$(30) \quad \phi = (d\theta''^1)^2 + g_{\alpha\beta}'' d\theta''^\alpha d\theta''^\beta \quad (\alpha, \beta=2, \dots, p)$$

(See Eisenhart [1926], p. 57). From the form (30) it is seen that if we use the transformation  $\theta''^1$  we may get a transformation of random variables which obeys asymptotical Normal distribution with unit variance. Therefore

$$ns^2(x_n : \theta_0)$$

will obey Chi-square distribution of one degree of freedom asymptotically. Then we have

Theorem 2: Under the assumption (1) substituting  $\theta_0$  in  $\theta$

$$(31) \quad ns^2(x_n : \theta_0)$$

asymptotically obeys Chi-square distribution of one degree of freedom, where  $s(\theta : \theta_0)$  is the geodesic given as the solution (26) using the inverse of the asymptotic variance of  $\sqrt{n} x_n$  as a fundamental tensor.

It is known that the equation (27) may reduce to

$$(32) \quad \frac{d^2 z^\alpha}{ds^2} = - \kappa z^\alpha$$



with respect to the coordinates  $z^\alpha$  of the Euclidean space in which a Riemannian space with a constant Gaussian curvature is immersed. There are two cases to be considered according to the sign of  $K$ .

1°.  $K > 0$ . In this case we have

$$(33) \quad \sum_{\alpha} c_{\alpha} (z^{\alpha} - z_o^{\alpha})^2 = \frac{4}{K} \sin^2 \frac{\sqrt{K}s}{2},$$

where  $z_o^{\alpha}$  is the value of  $z^{\alpha}$  at a point  $\theta_o$ . From (20) we may rewrite (33) as

$$(34) \quad K \sum_{\alpha} c_{\alpha} z^{\alpha} z_o^{\alpha} = \cos \sqrt{K} s.$$

2°.  $K < 0$ . Similarly we have

$$(35) \quad \sum_{\alpha} c_{\alpha} (z^{\alpha} - z_o^{\alpha})^2 = - \frac{4}{K} \sinh^2 \frac{\sqrt{-K}s}{2},$$

$$(36) \quad K \sum_{\alpha} c_{\alpha} z^{\alpha} z_o^{\alpha} = \cosh \sqrt{-K}s.$$

Example 4: The trinomial distribution of the example 2.

From the example 2, the arc of geodesic is given by:

$$(37) \quad s = 2 \cos^{-1} \left( \sqrt{\theta_1^1 \theta_o^1} + \sqrt{\theta_2^2 \theta_o^2} + \sqrt{\theta_3^3 \theta_o^3} \right),$$

substituting (22) and  $K = 1/4$  in 34. In the case of multinomial distribution we have

$$(38) \quad s = 2 \cos^{-1} \sum_{\alpha} \sqrt{\theta_{\alpha}^{\alpha} \theta_o^{\alpha}}$$

The half of  $s$  has been introduced as a measure of divergence by Bhattacharyya [1942].



From theorem 2 it is seen that the asymptotic variance of

$$(39) \quad 2\cos^{-1} \sum_{\alpha} \sqrt{\hat{\theta}^{\alpha} \theta^{\alpha}}$$

is 1, where  $\hat{\theta}^{\alpha}$  is the usual maximum likelihood estimator of  $\theta^{\alpha}$ .

Example 5: The Normal distribution of the example 3

Since the Gaussian curvature K is negative constant  $-1/2$ , substituting (24) in (33), we obtain the arc of geodesic as follows:

$$(40) \quad s = \sqrt{2} \cosh^{-1} \frac{(\mu - \mu_o)^2 + 2(\sigma^2 + \sigma_o^2)}{4\sigma\sigma_o}.$$

The statistic associated with the geodesic is

$$(41) \quad \sqrt{n}s(\bar{x}_n, S_n^2; \mu_o, \sigma_o^2) = \sqrt{2n} \cosh^{-1} \frac{(\bar{x} - \mu_o)^2 + 2(S_n^2 + \sigma_o^2)}{4\sqrt{S_n^2}\sigma_o}$$

and by the theorem 2 it has asymptotic unit variance, where  $\bar{x}_n$  and  $S_n^2$  are the sample mean and variance respectively.

## 6. Fisher's information

Fisher's information matrix in several parameters are defined by:

$$(42) \quad I^{ij} = E \left( \frac{\partial \log L}{\partial \theta^i} \frac{\partial \log L}{\partial \theta^j} \right)$$

where L is the likelihood function of parameters  $\theta^i$  (Fisher [1921]). It is easily shown that  $I^{ij}$  is a covariant tensor under transformations of parameters. Rao [1945] and



Yoshizawa [1962] used  $I^{ij}$  as the fundamental tensor of a parameter space. The inverse of the matrix  $I^{ij}$  gives the lower bound of the variance of the estimators  $\theta$  under some regularity condition by Rao-Cramer inequality. The fundamental tensors of the metric in the examples here are quite the same as Fisher's information matrix and they are rather easily calculated directly from (42) or from the following formula equivalent to (42) in the case that maximum likelihood estimators are used:

$$I^{ij} = -E \left( \frac{\partial^2 \log L}{\partial \theta^i \partial \theta^j} \right).$$

Anyway this geometry of parameter spaces is concerned with asymptotic variance and the limit of this method should be considered in this point.

Finally notice that the various definitions of distance or divergence between two distributions, e.g. Kullback's divergence [1959] and Matusita's [1955], are often locally equivalent to Fisher's information.



References

- Bhattacharyya, A. (1942) "On a measure of divergence between two multinomial populations" Sankhyā, Vol. 7, 401-6.
- Dempster, A.P. (1969) Continuous Multivariate Analysis Addison-Wesley, Reading, Massachusetts.
- Eisenhart, L.P. (1926) Riemann Geometry, Princeton University Press, Princeton.
- Eisenhart, L.P. (1940) An Introduction to Differential Geometry with Use of the Tensor Calculus, Princeton University Press, Princeton.
- Fisher, R.A. (1921) "On the mathematical foundations of theoretical statistics", Phil. Trans. Roy. Soc. A, 222, 309-368.
- Holland, P.W. (1971) "On the possibility of a multivariate extension of the variance stabilizing transformations", Memorandum NS-143 Harvard University, Cambridge, Massachusetts.
- Kullback, S. (1959) Information Theory and Statistics, John Wiley & Sons, New York.
- Mahalanobis, P.C. (1936) "On the generalized distance in Statistics", Proc. Nat. Inst. Sc. Ind., 2, 49-55.
- Matusita, K. (1955) "Decision rules, based on the distance, for problems of fit, two samples, and estimation" Ann. Math. Stat., Vol. 26, pp. 631-640.
- Rao, C.R. (1945) "Information and the accuracy attainable in the estimation of statistical parameters", Bulletin of the Calcutta Math. Soc., Vol. 37, 81-91.
- Veblen, O. (1933) Invariants of Quadratic Differential Forms, Cambridge University Press, London.
- Yoshizawa, T. (1962) "Information-distances in parameter spaces" (in Japanese). Unpublished graduation thesis at University of Tokyo.



Appendix A: A proof of the equivalence between Holland's theorem and the theorem 1 in this paper.

Holland's condition for existence of a covariance stabilizing transformation in two dimensional case is

$$(A-1) \quad \frac{\partial}{\partial \theta^2} \left[ \frac{1}{\det(A)} \left\{ a_{11} \left( \frac{\partial a_{11}}{\partial \theta^2} - \frac{\partial a_{12}}{\partial \theta^1} \right) + a_{21} \left( \frac{\partial a_{21}}{\partial \theta^2} - \frac{\partial a_{22}}{\partial \theta^1} \right) \right\} \right] \\ = \frac{\partial}{\partial \theta^1} \left[ \frac{1}{\det(A)} \left\{ a_{12} \left( \frac{\partial a_{11}}{\partial \theta^2} - \frac{\partial a_{12}}{\partial \theta^1} \right) + a_{22} \left( \frac{\partial a_{21}}{\partial \theta^2} - \frac{\partial a_{22}}{\partial \theta^1} \right) \right\} \right],$$

where  $A$  is any matrix  $(2 \times 2)$  that satisfies

$$(A-2) \quad A' A = \Sigma(\theta)^{-1}$$

Our condition (12) is reduced to

$$(A-3) \quad K = \frac{R_{1212}}{g} = 0$$

in two dimensional case and Gaussian curvature  $K$  may be written as follows:

$$(A-4) \quad K = \frac{1}{2\sqrt{g}} \left[ \frac{\partial}{\partial \theta^1} \left( \frac{g_{12}}{g_{11}\sqrt{g}} \frac{\partial g_{11}}{\partial \theta^2} - \frac{1}{\sqrt{g}} \frac{\partial g_{22}}{\partial \theta^1} \right) \right. \\ \left. + \frac{\partial}{\partial \theta^2} \left( \frac{2}{\sqrt{g}} \frac{\partial g_{12}}{\partial \theta^1} - \frac{1}{\sqrt{g}} \frac{\partial g_{11}}{\partial \theta^2} - \frac{g_{12}}{g_{11}\sqrt{g}} \frac{\partial g_{11}}{\partial \theta^1} \right) \right],$$

(See Eisenhart (1940), p. 154 Ex. 10) We will prove that (A-4) is equivalent to (A-3) using the form (A-4).



We may assume that  $A(\theta)$  is an upper triangular matrix without loosing generality. Then the components of  $A$  are expressed as follows:

$$(A-5) \quad \begin{aligned} a_{11} &= \sqrt{g_{11}}, \\ a_{12} &= \frac{g_{12}}{\sqrt{g_{11}}}, \quad a_{21} = 0, \\ a_{22} &= \sqrt{g_{22} - \frac{g_{12}^2}{g_{11}}} = \sqrt{\frac{g}{g_{11}}}. \end{aligned}$$

Partially differentiating the both sides of (A-5), we obtain

$$(A-6) \quad \begin{aligned} \frac{\partial a_{11}}{\partial \theta} &= \frac{1}{2\sqrt{g_{11}}} \frac{\partial g_{11}}{\partial \theta}, \\ \frac{\partial a_{12}}{\partial \theta} &= \frac{1}{\sqrt{g_{11}}} \frac{\partial g_{12}}{\partial \theta} - \frac{1}{2} \frac{g_{12}}{g_{11}\sqrt{g_{11}}} \frac{\partial g_{11}}{\partial \theta}, \\ \frac{\partial a_{22}}{\partial \theta} &= \frac{1}{2\sqrt{\frac{g_{11}}{g}}} \left( \frac{\partial g_{22}}{\partial \theta} - \frac{2g_{12}}{g_{11}} \frac{\partial g_{12}}{\partial \theta} + \left( \frac{g_{12}}{g_{11}} \right)^2 \frac{\partial g_{11}}{\partial \theta} \right), \end{aligned}$$

where  $\theta$  may take either  $\theta^1$  or  $\theta^2$ . Substituting (A-5) and (A-6) in (A-1), and using  $\det(A) = \sqrt{g}$  we rewrite (A-1) as



$$\begin{aligned}
 & \frac{\partial}{\partial \theta^2} \left[ \frac{1}{\sqrt{g}} \sqrt{g_{11}} \left( \frac{1}{2\sqrt{g_{11}}} \frac{\partial g_{11}}{\partial \theta^2} - \frac{1}{\sqrt{g_{11}}} \frac{\partial g_{12}}{\partial \theta^1} + \frac{g_{12}}{2g_{11}\sqrt{g_{11}}} \frac{\partial g_{11}}{\partial \theta^1} \right) \right. \\
 & = \frac{\partial}{\partial \theta^1} \left[ \frac{1}{\sqrt{g}} \left\{ \frac{g_{12}}{\sqrt{g_{11}}} \left( \frac{1}{2\sqrt{g_{11}}} \frac{\partial g_{11}}{\partial \theta^2} - \frac{1}{\sqrt{g_{11}}} \frac{\partial g_{12}}{\partial \theta^1} + \frac{1}{2} \frac{g_{12}}{g_{11}\sqrt{g_{11}}} \frac{\partial g_{11}}{\partial \theta^1} \right) \right. \right. \\
 & \quad \left. \left. - \sqrt{\frac{g}{g_{11}}} \frac{1}{2} \sqrt{\frac{g_{11}}{g}} \left( \frac{\partial g_{22}}{\partial \theta^1} - \frac{2g_{12}}{g_{11}} \frac{\partial g_{12}}{\partial \theta^1} + \left( \frac{g_{12}}{g_{11}} \right)^2 \frac{\partial g_{11}}{\partial \theta^1} \right) \right\} \right]
 \end{aligned}$$

After simple algebra we get

$$\begin{aligned}
 & - \frac{\partial}{\partial \theta^2} \left[ \frac{1}{\sqrt{g}} \left( \frac{\partial g_{12}}{\partial \theta^1} - \frac{\partial g_{11}}{2\partial \theta^2} - \frac{g_{12}}{2g_{11}} \frac{\partial g_{11}}{\partial \theta^1} \right) \right] \\
 & = \frac{\partial}{\partial \theta^1} \left[ \frac{1}{2\sqrt{g}} \left( \frac{g_{12}}{g_{11}} \frac{\partial g_{11}}{\partial \theta^2} - \frac{\partial g_{22}}{\partial \theta^1} \right) \right].
 \end{aligned}$$

It is easily seen that the above equation is equal to K=0.



### Appendix B: The multinomial distribution

Let the likelihood of a multinomial distribution be

$$(B-1) \quad L = \frac{n!}{\prod_{i=1}^{p+1} x_i!} \prod_{i=1}^{p+1} \theta_i^{x_i},$$

where  $\theta$ 's are  $p+1$  parameters and  $x$ 's are random variables.

Notice that we use subscripts for parameters in order not to confuse superscripts and squares, etc. The first  $p$  parameters are used for the coordinates of the population space since

$$(B-2) \quad \sum \theta_i = 1$$

1°. Fundamental tensor of the metric.

By calculating Fisher's information matrix, the fundamental tensor of the metric is given as below:

$$(B-3) \quad (g_{ij}) = \begin{pmatrix} \frac{\theta_1 + \theta_{p+1}}{\theta_1 \theta_{p+1}} & \frac{1}{\theta_{p+1}} & \frac{1}{\theta_{p+1}} & \dots & \frac{1}{\theta_{p+1}} \\ \frac{1}{\theta_{p+1}} & \frac{\theta_1 + \theta_{p+1}}{\theta_2 \theta_{p+1}} & \frac{1}{\theta_{p+1}} & \dots & \frac{1}{\theta_{p+1}} \\ \vdots & \vdots & \ddots & & \vdots \\ \vdots & \vdots & & \ddots & \vdots \\ \frac{1}{\theta_{p+1}} & \frac{1}{\theta_{p+1}} & \ddots & \ddots & \frac{\theta_p + \theta_{p+1}}{\theta_p \theta_{p+1}} \end{pmatrix}.$$

The covariance matrix of the usual estimators  $x_i/n$ , i.e., the inverse of  $(g_{ij})$  is



$$(B-4) \quad (g^{ij}) = \begin{vmatrix} \theta_1(1-\theta_1) & -\theta_1\theta_2 & \dots & -\theta_1\theta_p \\ -\theta_1\theta_2 & \theta_2(1-\theta_2) & \dots & -\theta_2\theta_p \\ \vdots & \vdots & \ddots & \vdots \\ -\theta_p\theta_1 & -\theta_p\theta_2 & \dots & \theta_p(1-\theta_p) \end{vmatrix}.$$

2°. Christoffel's 3 index symbols.

From (B-3) Partial derivatives of  $g_{ij}$  are

$$(B-5) \quad \frac{\partial g_{ij}}{\partial \theta_k} = \begin{cases} \frac{1}{\theta_{p+1}^2} - \frac{1}{\theta_i^2}, & i=j=k, \\ \frac{1}{\theta_{p+1}^2}, & \text{otherwise,} \end{cases}$$

From the definition (14) and (15) Christoffel's 3 index symbols of the first kind are

$$(B-6) \quad [ij,k] = \begin{cases} \frac{1}{2} \left( -\frac{1}{\theta_i^2} + \frac{1}{\theta_{p+1}^2} \right), & i=j=k, \\ \frac{1}{2} \frac{1}{\theta_{p+1}^2}, & \text{otherwise,} \end{cases}$$

and Christoffel's 3 index symbols of the second kind are



$$(B-7) \quad \{^{\ell}_{ij}\} = \begin{cases} \frac{\theta_{\ell}}{2\theta_{p+1}}, & i \neq j, \\ \frac{\theta_{\ell}}{2} \left( \frac{1}{\theta_i^2} + \frac{1}{\theta_{p+1}} \right), & i=j, \neq i, \\ \frac{\theta_i}{2\theta_{p+1}} - \frac{1-\theta_i}{2\theta_i}, & i=j=\ell. \end{cases}$$

### 3°. Riemann-Christoffel curvature tensor

In two dimensional case, i.e. in the case of the trinomial distribution, Riemann-Christoffel curvature tensor is from (13)

$$\begin{aligned} (B-8) \quad R_{1212} &= \frac{\partial}{\partial \theta_1} [22,1] - \frac{\partial}{\partial \theta_2} [21,1] + \{^{\ell}_{21}\} [12,\ell] - \{^{\ell}_{22}\} [11,\ell] \\ &= \frac{1}{\theta_3^3} - \frac{1}{\theta_3^3} + \frac{\theta_1}{2\theta_3} \frac{L}{2\theta_3^2} + \frac{\theta_2}{2\theta_3} \frac{1}{2\theta} \\ &\quad - \frac{\theta_1}{2} \left( \frac{1}{\theta_2} + \frac{1}{\theta_3} \right) \frac{1}{2} \left( - \frac{1}{\theta_1^2} + \frac{1}{\theta_3^2} \right) - \left( \frac{\theta_2}{2\theta_3} - \frac{1-\theta_2}{2\theta_2} \right) \frac{1}{2\theta_3^2} \\ &= \frac{1}{4\theta_1\theta_2\theta_3}. \end{aligned}$$

Therefore

$$(B-9) \quad K = \frac{R_{1212}}{g} = \frac{1}{4}.$$

In p dimensional case it is seen from the identities (16) that  $R_{hijk}$  is equal to zero if  $h = i$  or  $j = k$ . Under the condition  $h \neq i$  and  $j \neq k$ , noticing that

$$\frac{\partial}{\partial \theta_j} [ik,h] - \frac{\partial}{\partial \theta_k} [ij,h] = 0$$



$R_{hijk}$ 's are calculated as follows:

$$(B-10) \quad \left\{ \begin{array}{l} \circ h=j, i \neq k \\ R_{hihk} = \frac{1}{4\theta_{p+1}\theta_h} \\ \circ h \neq j, i=k \\ R_{hiji} = R_{ihij} = \frac{1}{4\theta_{p+1}\theta_i} \\ \circ h=j, i=k \\ R_{hihi} = \frac{1}{4} \left\{ \left( \frac{1}{\theta_i} + \frac{1}{\theta_{p+1}} \right) \left( \frac{1}{\theta_h} + \frac{1}{\theta_{p+1}} \right) - \frac{1}{\theta_{p+1}^2} \right\} \end{array} \right.$$

Therefore it is easily seen that Gaussian curvature

$$(B-11) \quad K = \frac{R_{hijk}}{g_{hj}g_{ik}-g_{hk}g_{ij}} = \frac{1}{4} .$$

4°. Coordinates of a Euclidean space in which the population space of multinomial distribution is immersed.

Let  $z^\alpha$  denote the coordinates of the Euclidean space.  $z^\alpha$ 's are given as a set of solutions of (21), i.e.

$$\frac{\partial^2 z^\alpha}{\partial \theta_i \partial \theta_j} - \sum_{h=1}^p \frac{\partial z^\alpha}{\partial \theta_h} \{ {}^h_{ij} \} = - \frac{1}{4} g_{ij} z^\alpha .$$

It is easily seen that a set of solutions is given as

$$z^\alpha = c\sqrt{\theta_\alpha} , \quad \alpha=1, \dots, p+1 .$$



Appendix C: The normal distribution  $N(\mu, \sigma^2)$

Let  $\theta^1$  and  $\theta^2$  be  $\mu$  and  $\sigma^2$  respectively. We shall use  $\theta_1$  and  $\theta_2$  for  $\theta^1$  and  $\theta^2$  because of practical convenience in algebra.

1°. Fundamental tensor of the metric

Standard theory implies that

$$(C-1) \quad \Sigma(\theta) = \begin{pmatrix} \theta_2 & 0 \\ 0 & 2\theta_2^2 \end{pmatrix} = (g^{ij}) .$$

Therefore the fundamental tensor of the metric is

$$(C-2) \quad g_{11} = \frac{1}{\theta_2^2}, \quad g_{12} = g_{21} = 0, \quad g_{22} = \frac{1}{2\theta_2^2} .$$

2°. Christoffel's 3 index symbols.

Since partial derivatives by  $\theta_1$  and  $\theta_2$  are zeros except that

$$(C-3) \quad \frac{\partial g_{11}}{\partial \theta_2} = -\frac{1}{\theta_2^2}, \text{ and } \frac{\partial g_{22}}{\partial \theta_2} = -\frac{1}{\theta_2^3} ,$$

from (14) and (15) Christoffel's 3 index symbols of the first and second kinds are as follows:

First kind:

$$(C-4) \quad \begin{aligned} [11,1] &= 0, \\ [11,2] &= \frac{1}{2\theta_2^2}, \\ [12,1] &= [21,1] = -\frac{1}{2\theta_2^2}, \\ [12,2] &= [21,2] = 0, \\ [21,1] &= 0, \\ [22,2] &= \frac{-1}{2\theta_2^3}, \end{aligned}$$



Second kind:

$$\begin{aligned}
 \{^1_{11}\} &= 0, \\
 \{^2_{11}\} &= 1, \\
 (C-5) \quad \{^1_{21}\} &= \{^1_{12}\} = -\frac{1}{2\theta_2}, \\
 \{^2_{12}\} &= \{^2_{21}\} = 0, \\
 \{^1_{22}\} &= 0, \\
 \{^2_{22}\} &= -\frac{1}{\theta_2}.
 \end{aligned}$$

### 3°. Riemann-Christoffel curvature tensor

Substituting (C-4) and (C-5) in (13), we obtain

$$\begin{aligned}
 R_{1212} &= \frac{\partial}{\partial \theta_1}[22,1] - \frac{\partial}{\partial \theta_2}[21,1] \\
 &\quad + \{^1_{21}\}[12,1] + \{^2_{21}\}[12,2] - \{^1_{22}\}[11,1] - \{^2_{22}\}[11,2] \\
 &= -\frac{1}{\theta_2^3} + (\frac{-1}{2\theta_2})(\frac{-1}{2\theta_2^2}) - (\frac{1}{\theta_2})(\frac{1}{2\theta_2^3}) \\
 &= -\frac{1}{4\theta_2^3}.
 \end{aligned}$$

Therefore no covariance stabilizing transformation exists.

Gaussian curvature becomes

$$K = \frac{R_{1212}}{g} = -\frac{1}{2},$$

where  $g$  is the determinant of  $(g_{ij})$ .



4°. Coordinates of a Euclidean space in which the population space is immersed.

Let  $z^\alpha$  denote the coordinates of the Euclidean space. From (21)  $z^\alpha$  must satisfy the following equations:

$$\left\{ \begin{array}{l} \frac{\partial^2 z^\alpha}{\partial \theta_1^2} - \frac{\partial z^\alpha}{\partial \theta_2} = \frac{z^\alpha}{2\theta_2}, \\ \frac{\partial^2 z^\alpha}{\partial \theta_1 \partial \theta_2} + \frac{1}{2\theta_2} \frac{\partial z^\alpha}{\partial \theta_1} = 0, \\ \frac{\partial^2 z^\alpha}{\partial \theta_2^2} + \frac{1}{\theta_2} \frac{\partial z^\alpha}{\partial \theta_2} = \frac{z^\alpha}{4\theta_2}. \end{array} \right.$$

From the third equation it is seen that  $z^\alpha$  must be of the form

$$\frac{f(\theta_1)}{\sqrt{\theta_2}} + g(\theta_1) \sqrt{\theta_2}$$

where  $f$  and  $g$  are some functions of only  $\theta_1$ . Substituting it in the first and second equations, it is seen that  $f(\theta_1)$  and  $g(\theta_1)$  must satisfy

$$\frac{d^2 f}{d\theta_1^2} = g, \quad \frac{dg}{d\theta_1} = 0.$$

Therefore  $z^\alpha$  must be of the form

$$\frac{a_\alpha \theta_1^2 + b_\alpha \theta_1 + d_\alpha}{\sqrt{\theta_2}} + 2a_\alpha \sqrt{\theta_2}.$$



Since the fundamental form of the Euclidean space is of the form

$$c_1(dz^1)^2 + c_2(dz^2)^2 + c_3(dz^3)^2$$

where  $c_1, c_2$  and  $c_3$  are plus or minus one, comparing it with the fundamental form of the Riemannian space

$$\frac{1}{\theta_2}(d\theta_1)^2 + \frac{1}{2\theta_2^2}(d\theta_2)^2$$

we obtain that  $c_1=c_2=-c_3=1$  and that

$$z^1 = \frac{\theta_1}{\sqrt{\theta_2}},$$

$$z^2 = \frac{\theta_1^2 - 2}{2\sqrt{2}\sqrt{\theta_2}} + \frac{\sqrt{\theta_2}}{\sqrt{2}},$$

$$z^3 = \frac{\theta_1^2 + 2}{2\sqrt{2}\sqrt{\theta_2}} + \frac{\sqrt{\theta_2}}{\sqrt{2}}.$$

It is easily seen that the coordinates satisfy (20), i.e.

$$(z^1)^2 + (z^2)^2 - (z^3)^2 = \frac{1}{K} = -2.$$

### 5°. Transformation by geodesic

It is seen from (24) that the arc of geodesic from  $(\mu_o, \sigma_o^2)$  to  $(\mu, \sigma^2)$  is

$$s = \sqrt{2} \cosh^{-1} \frac{(\mu - \mu_o) + 2(\sigma^2 + \sigma_o^2)}{4\sigma\sigma_o}.$$



By the law of transformation (5), if we use  $s$  as a transformation it follows that

$$g^{11} = \sigma^2 \left( \frac{\partial s}{\partial \mu} \right)^2 + 2\sigma^4 \left( \frac{\partial s}{\partial (\sigma^2)} \right)^2 \\ = \sigma^2 \left( \frac{\partial s}{\partial \mu} \right)^2 + \frac{\sigma^2}{2} \left( \frac{\partial s}{\partial \sigma} \right)^2.$$

Since partial derivatives  $s$  by  $\mu$  and  $\sigma$  are

$$\frac{\partial s}{\partial \mu} = \sqrt{2} \frac{1}{\sinh \frac{s}{\sqrt{2}}} \cdot \frac{2(\mu - \mu_0)}{4\sigma\sigma_0}, \\ \frac{\partial s}{\partial \sigma} = \sqrt{2} \frac{1}{\sinh \frac{s}{\sqrt{2}}} \frac{4\sigma^2 - [(\mu - \mu_0)^2 + 2(\sigma^2 + \sigma_0^2)]}{4\sigma_0\sigma^2},$$

it is seen that

$$g^{11} = 1.$$

This fact shows that theorem 2 is certainly valid in this case.



# 附録 2

Memorandum TYH-3

## A Geometrical Interpretation of Location and Scale Parameters

Tadashi Yoshizawa

November 9, 1971

at Department of Statistics  
Harvard University  
Cambridge, Massachusetts, U.S.A.



## 1. Introduction

Conditions for existence of a covariance stabilizing transformation and transformations of parameters which gives statistics with unit variance asymptotically were found in the memorandum TYH-2 [1971].

In this memorandum a geometrical interpretation of location and scale parameters is given after the Normal distribution's case exhibited in the memorandum TYH-2.

It is shown that the two dimensional space of location and scale parameters has negative constant Gaussian curvature if the space is considered as a Riemannian's using Fisher's information as the fundamental tensor of the metric, so that the space is expressed on a hyperbolic surface in three dimensional Euclidean space.

Moreover the geodesic distance between two points is given in the similar form as in the Normal case, and it gives statistics with unit variance asymptotically.

## 2. Fundamental tensor of the parameter space

Consider a frequency function

$$(1) \quad dF(x) = f\left(\frac{x-\alpha}{\beta}\right) d\left(\frac{x-\alpha}{\beta}\right), \quad \beta > 0,$$

where the parameter  $\alpha$  locates the distribution and  $\beta$  is a scale parameter. We rewrite (1) as



$$(2) \quad dF = \exp\{g(y)\}dy = \exp\{g(y)\}dx/\beta$$

where  $y = (x-\alpha)/\beta$ ,  $g(y) = \log f(y)$ .

In sample of size  $n$  the logarithm of the likelihood function is

$$(3) \quad \log L(x|\alpha, \beta) = \sum_{i=1}^n g(y_i) - n \log \beta.$$

(3) yields the likelihood equations

$$(4) \quad \frac{\partial \log L}{\partial \alpha} = -\frac{1}{\beta} \sum_{i=1}^n \left( \frac{\partial g}{\partial y} \right)_{y=y_i} = 0,$$

$$\frac{\partial \log L}{\partial \beta} = -\frac{1}{\beta} \left\{ \sum_{i=1}^n y_i \left( \frac{\partial g}{\partial y} \right)_{y=y_i} + n \right\} = 0.$$

Under regularity conditions, solution of (4) gives the ML estimators  $\hat{\alpha}$  and  $\hat{\beta}$ . We now assume that for all permissible values of  $\alpha$  and  $\beta$

$$(5) \quad E \left( \frac{\partial \log L}{\partial \alpha} \right) = 0.$$

$$E \left( \frac{\partial \log L}{\partial \beta} \right) = 0.$$

Fisher's information matrix is given as follows:

$$(6) \quad -\frac{n}{\beta^2} E \begin{pmatrix} g'' & g''y \\ g''y & g''y^2 - 1 \end{pmatrix},$$

from which the variances and covariance may be determined by inversion (See Kendall & Stuart [1967], p. 63).



Consider the space of the location and scale parameters as a Riemannian's by introducing the fundamental tensor of the metric

$$(7) \quad (g_{ij}) = \frac{1}{\beta^2} \begin{pmatrix} a & c \\ c & b \end{pmatrix}$$

where  $a = -E(g'')$ ,  $b = E(g''y^2 - 1)$ , and  $c = E(g''y)$  from (6).

Notice that  $a$ ,  $b$ , and  $c$  are constants, and that  $c$  is vanished if the distribution (1) is symmetric about  $\alpha$ . Even for asymmetrical distributions, we can make the off-diagonal term in (7) zero by a simple change of origin such that

$$(8) \quad z = y - \frac{c}{a}.$$

This change of origin corresponds to the transformation of parameters such that

$$(9) \quad \begin{cases} \alpha' = \alpha + \frac{c}{a}\beta, \\ \beta' = \beta. \end{cases}$$

In this case the fundamental tensor of the metric (7) is transformed to

$$(10) \quad (g'_{ij}) = \frac{1}{\beta^2} \begin{pmatrix} a & 0 \\ 0 & \frac{G}{a} \end{pmatrix}$$

where  $G = ab - c^2$ , since the law of transformation of the fundamental tensor is given as

$$g'_{ij} = g_{kl} \frac{\partial \theta^k}{\partial \theta'^i} \frac{\partial \theta^\ell}{\partial \theta'^j}$$

where  $\theta^1 = \alpha$ ,  $\theta^2 = \beta$ ,  $\theta'^1 = \alpha'$ ,  $\theta'^2 = \beta'$  (See Yoshizawa [1971]).



### 3. Gaussian curvature

When the off-diagonal terms in the fundamental tensor are zeros, Gaussian curvature of the space is easily calculated by the following formula:

$$K = -\frac{1}{2} \frac{1}{\sqrt{g}} \left[ \frac{\partial}{\partial \theta^1} \left( \frac{1}{\sqrt{g}} \frac{\partial g_{22}}{\partial \theta^1} \right) + \frac{\partial}{\partial \theta^2} \left( \frac{1}{\sqrt{g}} \frac{\partial g_{11}}{\partial \theta^2} \right) \right],$$

where  $g = g_{11}g_{22}$ . In the case of (10),  $g_{ij}$  does not depend on  $\theta^1 (= \alpha)$ . Then we obtain

$$\begin{aligned} K &= -\frac{1}{2} \frac{\beta^2}{\sqrt{G}} \cdot \frac{\partial}{\partial \beta} \left( \frac{\beta^2}{\sqrt{G}} \cdot \frac{\partial}{\partial \beta} \left( \frac{a}{\beta^2} \right) \right), \\ &= -\frac{1}{2} \frac{\beta^2}{\sqrt{G}} \frac{\partial}{\partial \beta} \left( -\frac{2a}{\sqrt{G}\beta} \right). \end{aligned}$$

So we find that

$$(11) \quad K = -\frac{a}{G}$$

Since  $a$  and  $G$  are positive, it is seen that the parameter space of location and scale parameters has a negative constant Gaussian curvature. Notice that Gaussian curvature is invariant under the transformation of the parameters.

Example 1: The Normal distribution  $N(\mu, \sigma^2)$

Yoshizawa [1971] showed that the Gaussian curvature of the space is negative constant  $-1/2$ , using  $\mu$  and  $\sigma^2$  as coordinates. If we use  $\mu$  and  $\sigma$  instead of  $\mu$  and  $\sigma^2$ , the fundamental tensor (7) is given as

$$(12) \quad (g_{ij}) = \frac{1}{\sigma^2} \begin{pmatrix} 1 & 0 \\ 0 & 2 \end{pmatrix} .$$



Of course,  $K$  is invariant under this transformation.

Example 2: The Gamma distribution

Consider the Gamma distribution

$$(13) \quad dF(x) = \frac{1}{\Gamma(p)} \left( \frac{x-\alpha}{\beta} \right)^{p-1} \exp \left\{ -\frac{(x-\alpha)}{\beta} \right\} d\left(\frac{x-\alpha}{\beta}\right),$$
$$\alpha \leq x < \infty; \quad \beta > 0; \quad p > 2.$$

In this case the fundamental tensor (7) is given as

$$(14) \quad (g_{ij}) = \frac{1}{\beta^2} \begin{pmatrix} \frac{1}{p-2} & 1 \\ 1 & p \end{pmatrix}.$$

From (11) it is seen that

$$(15) \quad K = -\frac{1}{2},$$

$$\text{since } G = \frac{p}{p-2} - 1 = 2/(p-2).$$

4. An interpretation of the space as a hyperbolic surface

A two dimensional Riemannian space with negative constant Gaussian curvature may be expressed as a hyperbolic surface in a three dimensional Euclidean space. The coordinates of the Euclidean space and the expression of the hyperbolic surface can be obtained by the method used by Yoshizawa [1971].

The equations for the coordinates  $z$  are as follows:



$$(16) \quad \left\{ \begin{array}{l} \frac{\partial^2 z^\alpha}{\partial \alpha^2} - \frac{a^2}{Gy} \cdot \frac{\partial z^\alpha}{\partial \beta} = \frac{a^2}{Gy^2} z^\alpha , \\ \frac{\partial^2 z^\alpha}{\partial \alpha \partial \beta} + \frac{1}{\beta} \frac{\partial z}{\partial \alpha} = 0 , \\ \frac{\partial^2 z}{\partial \beta^2} + \frac{1}{\beta} \frac{\partial z}{\partial \beta} = \frac{1}{\beta^2} z^\alpha . \end{array} \right.$$

Solving the above equation (16) and comparing the fundamental forms of the Euclidean space and of the Riemannian space, we obtain the following as a set of coordinates:

$$(17) \quad \begin{aligned} z^1 &= \frac{\sqrt{a}\alpha}{\beta} , \\ z^2 &= \frac{\frac{a}{2}\sqrt{\frac{a}{G}}\alpha^2 - \frac{1}{2}\sqrt{\frac{G}{a}}}{\beta} + \frac{1}{2}\sqrt{\frac{G}{a}}\beta , \\ z^3 &= \frac{\frac{a}{2}\sqrt{\frac{a}{G}}\alpha^2 + \frac{1}{2}\sqrt{\frac{G}{a}}}{\beta} + \frac{1}{2}\sqrt{\frac{G}{a}}\beta . \end{aligned}$$

Then the equation of the hyperbolic surface becomes

$$(18) \quad (z^1)^2 + (z^2)^2 - (z^3)^2 = -\frac{G}{a} .$$

Notice that the right hand of the above equation is the reciprocal of Gaussian curvature (11).

Since  $\beta$  is positive

$$z^3 > 0 ,$$

and at the bottom of the hyperbolic surface

$$z^1 = z^2 = 0 ,$$

$$z^3 = \sqrt{\frac{G}{a}} ,$$



this point corresponds  $\alpha=0$  and  $\beta=1$ .

Since from (17)

$$(19) \quad z^3 - z^2 = \frac{1}{2\beta} \sqrt{\frac{\theta}{a}} ,$$

$\alpha$  changes on the curve cut by the plane (19) if  $\beta$  is fixed.

It is easily seen that the curve is a parabolic.

### 5. Geodesic distance

The distance between two points is naturally measured by the arc of the geodesic which is easily given as

$$s = \sqrt{\beta} \cosh^{-1} \frac{a^2(\alpha-\alpha_0)^2 + G(\beta^2 + \beta_0^2)}{2G\beta\beta_0}$$

by the same method used in Yoshizawa [1971]. If we have maximum likelihood estimates  $\hat{\alpha}$  and  $\hat{\beta}$  of  $\alpha$  and  $\beta$  respectively, we get a statistics with asymptotic unit variance such that

$$s = \sqrt{\frac{G}{a}} \cosh^{-1} \frac{a^2(\hat{\alpha}-\alpha)^2 + G(\hat{\beta}^2 + \beta^2)}{2G\hat{\beta}\beta}$$

where  $\alpha$  takes the value  $\alpha'$  of (9) if the change of origin (8) occurs. This fact is a direct result of the theorem 2 of Yoshizawa [1971].

#### Example 3: The Gamma distribution

From example 2, in the case of the Gamma distribution we have

$$a = \frac{1}{p-2} , \quad g = \frac{2}{p-2} .$$

Then we obtain



$$s = \sqrt{2} \cosh^{-1} \frac{\frac{1}{p-2}(\alpha - \alpha_0)^2 + 2(\beta^2 + \beta_0^2)}{4\beta\beta_0}$$

The fact that  $s$  is the same as in the case of the Normal distribution if  $p$  is three, is a reasonable result.

References

Kendall, M. G. & Stuart, A. [1967] The Advanced Theory of Statistics, 2nd. Edition, Hafner Publishing Company, New York.

Yoshizawa, T. [1972], "A Geometry of Parameter Space and Its Statistical Interpretation", Memorandum TYH-2, Harvard University, Cambridge, Massachusetts.



## 付録 3

### 多重分割表モデル選択についての補足

5.5 節数値例 b) モデルの段階的選択において述べた手続きについて補足しておく。122~125頁では表5.9のデータについて平方根分解により因子ごとの平方和への分解を表5.10に与え、その表を用いて逐次的に進めらるモデル選択の手順を示して（図5.1、表5.11参照）。そこでは、モデル {14/123} が AICR の観点からは最も良いと結論した。また、表5.11で \*EPとして与えられた対数線形モデルでの  $G^2$  の値を我々のプログラムで求めた結果を下の表に示しておこう。対数線形モデルについてもすべての項目を含む階層的モ

表付3.1 表5.11の補足

MODEL	D <sup>2</sup>	G <sup>2</sup>	DF	AICR	AIC
2/3/14	36.55	37.04	16	4.55	5.04
1/234	15.76	15.37	11	-6.24	-6.63
4/123	14.62	14.51	14	-13.38	-13.49
14/234	9.60	9.42	9	-8.40	-8.58
14/123	8.47	8.55	12	-15.53	-15.45
234/123	8.31	7.75	8	-7.69	-8.25
14/234/123	2.17	2.35	6	-9.83	-9.65

モデルの中ではモデル {14/123} を選択するのが妥当であろう。

次に、選択されたモデル {14/123} でのセル期待値の推定値に



つれて検討しておこう。表5.9の4重分割表でのセル期待値を  
 $m_{ijkl}$   $i=1, 2, j=1, 2, k=1, 2, l=1, 2, 3$  と書くと、対数線形モデルでこのモデル {14/123} は

$$m_{ijkl} = m_{i++k} \cdot m_{ijk+} / m_{i+++}$$

という関係が成り立つことを意味する。すなむち、第1項目をえたとき、第4項目に対して 第2と第3項目が独立であるというモデルである。4.1節 b) で述べた条件のもとで、このモデルでのセル期待値の最大推定値は

$$\hat{m}_{ijkl} = x_{i++k} x_{ijk+} / x_{i+++}$$

で与えられる。ここで、 $x_{ijkl}$  はもとの分割表のデータである。一方、平方根分解でのセル期待値の推定値は、それを  $\bar{m}_{ijkl}$  と書くと、

$$\bar{m}_{ijkl} = \frac{N}{\lambda^2} \sum_{\alpha \in K} \{B_{ijkl}(\alpha)\}^2$$

で与えられる。ここで、 $B_{ijkl}(\alpha)$  は平方根分解での $\alpha$ 因子効果の  $ijkl$  成分、入は (5.61) で定義した量、 $N$  は分割表データの総和  $x_{++++}$ 、 $K$  はモデル {14/123} に対するクラス {中, 1, 2, 3, 12, 13, 23, 14, 123} である。 $\hat{m}_{ijkl}$  と  $\bar{m}_{ijkl}$  は 5.5 節の始めに述べた汎用プログラムで計算される。表付3.2 にこれらの値とデータ  $x_{ijkl}$  及び



$$c_{ijkl} = \frac{(\hat{m}_{ijkl} - x_{ijkl})^2}{\hat{m}_{ijkl}}$$

を並べて示す。 $c_{ijkl}$  の総和はやはり  $\chi^2$  統計量であり、 $D^2$  や  $G^2$  とほぼ等しい値をえる。 $\hat{m}_{ijkl}$  と  $\bar{m}_{ijkl}$  は  $\pm 0.5$  に近い値をもつていて、 $x_{ijkl}$  によく適合している。本文で論じたように（82頁、114～116頁参照）、平方根分解によるモデル構成は確率論的解釈に難易がかるか、対数線形モデルの近似として考えることができる。また、この例のように平方根分解によるモデル選択の結果を利用して対数線形モデルでのモデル選択を容易にすることができる。

なお、データのモデルからの残差に相当する  $c_{ijkl}$  は異なったセルの間でいかにも無相関というとはできないか、異常なセル度数の検出に役立つことわかる。経験的には残差のヒストグラムから異常に小さな値が検討を要するものとなるか、理論的取り扱いは今後の課題である。



表 3.2 セル期待値の推定

i (T)	j (U)	k (P)	l (S)	$x_{ijkl}$	$\bar{m}_{ijkl}$	$\hat{m}_{ijkl}$	$c_{ijkl}$
1	1	1	1	19	18.5	18.6	.009
2	1	1	1	57	49.0	48.9	1.338
1	2	1	1	29	29.7	29.3	.003
2	2	1	1	63	68.4	68.3	.416
1	1	2	1	29	34.4	33.5	.614
2	1	2	1	49	54.7	54.5	.547
1	2	2	1	27	22.5	22.5	.879
2	2	2	1	53	50.7	50.3	.145
1	1	1	2	23	22.4	22.5	.010
2	1	1	2	47	47.9	48.0	.022
1	2	1	2	33	35.1	35.5	.178
2	2	1	2	66	67.4	67.1	.018
1	1	2	2	47	40.1	40.6	.997
2	1	2	2	55	53.7	53.5	.043
1	2	2	2	23	27.1	27.3	.682
2	2	2	2	50	49.5	49.4	.008
1	1	1	3	24	25.4	24.9	.030
2	1	1	3	37	43.4	44.1	1.132
1	2	1	3	42	39.0	39.2	.204
2	2	1	3	68	61.7	61.6	.673
1	1	2	3	43	44.0	44.8	.074
2	1	2	3	53	48.9	49.1	.316
1	2	2	3	30	30.5	30.1	.001
2	2	2	3	42	44.8	45.3	.242

