

---

# 目次

はしがき *iii*

## 第 1 章 統計解析のねらいと準備 ..... 1

1-1 統計解析のねらい 2

1-2 SPSS を使って統計解析を行う手順 4

1-2-1 SPSS の起動とデータの入力 4

1-2-2 変数の定義 8

1-2-3 変数名と変数ラベル 8

1-2-4 変数のタイプ 10

1-2-5 値ラベル 14

1-2-6 欠損値 17

1-2-7 列と配置 18

1-2-8 測定 19

① 名義尺度 (nominal scale) 19

② 順序 / 順位尺度 (ordinal scale) 20

③ 間隔尺度 (interval scale) 20

④ 比率尺度 (ratio scale 比例尺度, 比尺度) 21

- 
- 1-2-9 データの保存と読み込み 22
    - (1) データの保存 22
    - (2) データの読み込み 25
      - ① エクセルで作成したデータファイルの読み込み 26
      - ② テキスト形式で作成したデータファイルの読み込み 28
      - ③ そのほかの形式で保存したデータを読み込む 29

## 第2章 度数分布と記述統計 ..... 31

### 2-1 度数分布 32

### 2-2 記述統計 35

#### 2-2-1 平均値 35

#### 2-2-2 最頻値と中央値 38

#### 2-2-3 分散と標準偏差 39

#### 2-2-4 標準偏差と正規分布 42

### 2-3 記述統計を SPSS で算出する 45

#### 2-3-1 標準化得点 45

#### 2-3-2 変数の計算—新たな変数の作成 46

#### 2-3-3 「度数分布表」から記述統計を算出する 48

#### 2-3-4 パーセンタイル 49

#### 2-3-5 歪度と尖度 50

#### 2-3-6 調和平均と幾何平均 51

### 2-4 クロス集計とカイ2乗検定 52

#### 2-4-1 クロス集計 52

#### 2-4-2 カイ2乗検定 55

#### 2-4-3 クロス集計表を提示するときの注意 60

#### 2-4-4 SPSS でのカイ2乗検定 60

## 第3章 相関と回帰 ..... 63

- 3-1 相関関係と因果関係 64
- 3-2 相関係数 65
  - 3-2-1 ピアソンの積率相関係数 66
  - 3-2-2 順位相関係数 70
  - 3-2-3 偏相関係数 73
- 3-3 SPSSでの操作 74
  - 3-3-1 ピアソンの積率相関係数の算出 74
  - 3-3-2 積率相関係数を用いるときの留意事項 80
  - 3-3-3 順位相関係数の算出 81
  - 3-3-4 偏相関係数の算出 85
- 3-4 回帰分析 87
  - 3-4-1 線形回帰モデル—現象の予測と要因の分析 87
  - 3-4-2 SPSSによる線形回帰分析 90
  - 3-4-3 出力の読み方 96
  - 3-4-4 モデルの比較 107
  - 3-4-5 ステップワイズ法 109
  - 3-4-6 質的変数と重回帰分析—ダミー変数の利用 111

## 第4章 類型化と分類 —判別分析とクラスター分析— ..... 117

- 4-1 判別分析 118
- 4-2 判別分析の実行 123

- 4-3 判別分析の出力 128
- 4-4 判別分析と重回帰分析 144
- 4-5 判別分析を行う上での留意事項 147
- 4-6 クラスタ分析 148
  - 4-6-1 階層的クラスタ分析 149
    - 4-6-1-1 東京23区の階層的クラスタ分析 151
    - 4-6-1-2 東京23区の階層的クラスタ分析の出力 159
  - 4-6-2 非階層的クラスタ分析 164

## 第5章 変数の縮約と潜在因子の発見 —主成分分析と因子分析— ..... 167

- 5-1 主成分分析 169
  - 5-1-1 主成分分析の実行 171
  - 5-1-2 主成分分析の出力 175
  - 5-1-3 主成分を使ったクラスタ分析 182
  - 5-1-4 主成分軸の回転 183
- 5-2 因子分析 186
  - 5-2-1 因子分析の実行 191
  - 5-2-2 因子分析の出力 198
  - 5-2-3 因子分析を行う上での留意点 207
- 5-3 因子と測定尺度 208
  - 5-3-1 測定尺度の作成 208
  - 5-3-2 測定尺度の信頼性 210
  - 5-3-3 信頼性分析の実行 212
  - 5-3-4  $\alpha$ 係数を用いるときの留意点 216

## 第6章 平均を比較する..... 219


- 6-1 独立したサンプルの T 検定 223
- 6-2 1 サンプルの T 検定 229
- 6-3 対応のあるサンプルの T 検定 232
- 6-4 グループの平均 234
- 6-5 一元配置分散分析 239
  - 6-5-1 等分散性の検定 240
  - 6-5-2 対比 242
  - 6-5-3 その後の検定 244
  - 6-5-4 一元配置分散分析の出力 246

## 補論：出力を他のソフトで編集する..... 255

参考文献 259

索引 261

率：第2章参照）で棄却できることを示している。要するに、すべての回帰係数が0になる確率はきわめて小さいということである。しかし、このことは、得られた回帰式で観測値を危険率5%未満で予測できるということを意味しているわけではない。ここでの有意確率は、危険率5%未満で帰無仮説を棄却でき、「すべての回帰係数は0ではない」という対立仮説を受容してよいことを示しているだけである。このところを間違えないようにしよう。得られた重回帰式が有効であるかどうかは、回帰係数の検定を行ってからでないと判断できない。そこで、次に以下の出力表（図表3-29）に目を向けることにしよう。



図表 3-29

「係数」の表にある「非標準化係数」(B) が得られた重回帰式の「定数項」(切片) と「回帰係数」である。重回帰分析の場合の回帰係数を一般に偏回帰係数と呼ぶ。これを一次関数の形で表現すると次のようになる。

$$\begin{aligned}
 & \text{老後幸福感得点} \\
 & = 13.007 + (-0.005) \times \text{年齢} + (-0.045) \times \text{世帯人数} + 0.002 \times \text{年間所得} \\
 & = 13.007 - 0.005 \times \text{年齢} - 0.045 \times \text{世帯人数} + 0.002 \times \text{年間所得}
 \end{aligned}$$

この重回帰式が意味するところは、老後幸福感得点は、年齢が1歳上がると0.005倍低下し、世帯人数が1人増加すると0.045倍低下し、年間所得が1万円増加すると0.002倍増加する、ということである。

例えば、年齢が70歳で、世帯人数が2人、年間所得が400万円であれば、老後幸福感の予測得点は以下のようになる。

$$A = -97.052 + 0.666 \times \text{年齢} + 6.061 \times \text{居住年数} + 3.466 \times \text{趣味の数} + 0.367 \times \text{通勤時間}$$

$$B = -74.558 + 0.439 \times \text{年齢} + 4.900 \times \text{居住年数} + 5.537 \times \text{趣味の数} + 0.432 \times \text{通勤時間}$$

これらの式に、先ほどの「年齢が58歳で居住年数が10年、趣味が4つあり、通勤時間は50分」の人のデータを入れると、 $A = 34.973$ 、 $B = 42.057$  となる。B の値の方が大きいので、この人は B 群に分類される。このように、分類関数を用いるときには、算出された値の大きい方に分類する。3 群以上の場合は最大値のグループに分類する。

図表4-21 の「ケースごとの集計」には、各ケースについて、「実際のグルー

ケースごとの統計

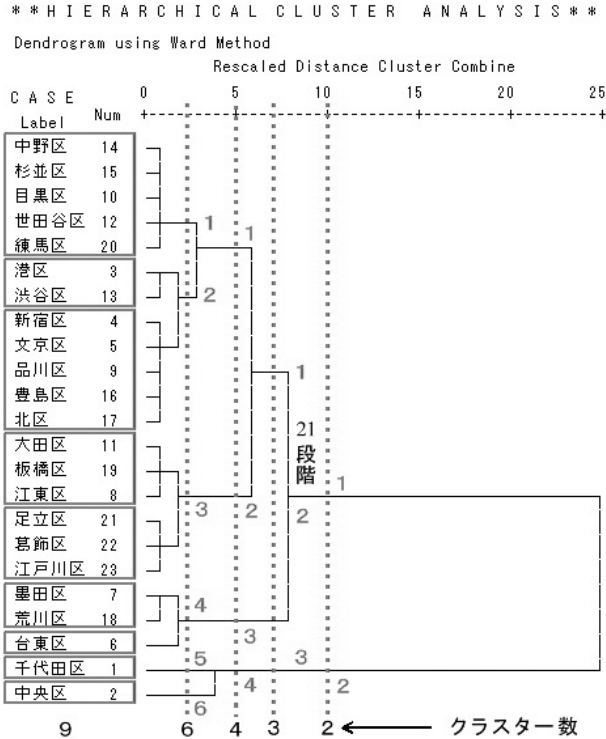
ケース番号	実際のグループ	条件確率		最大グループ*		事後確率		2番目のグループ*		判別得点
		子測グループ		P(D>d   G=e)	P(G=e   D=d)	重心への Mahalanobis の距離の2乗	グループ	P(G=g   D=d)	重心への Mahalanobis の距離の2乗	
		p	自由度							
1	1	.204	1	1.000	1.610	2	.000	31.123	3.424	
2	1	.463	1	.998	.538	2	.002	12.792	1.422	
3	1	.578	1	.999	.309	2	.001	14.094	1.599	
4	1	.772	1	1.000	.084	2	.000	21.156	2.445	
5	1	.116	1	.925	2.468	2	.075	7.501	.584	
6	1	.291	1	1.000	1.114	2	.000	28.788	3.210	
7	1	.806	1	1.000	.060	2	.000	20.752	2.400	
8	2	.179	1	.970	1.808	1	.030	8.792	-.810	
9	2	.891	1	1.000	.019	1	.000	19.776	-2.292	
10	2	.310	1	1.000	1.029	1	.000	28.347	-3.169	
11	2	.179	1	1.000	1.803	1	.000	31.953	-3.498	
12	2	.943	1	1.000	.005	1	.000	17.963	-2.083	
13	2	.283	1	.991	1.153	1	.009	10.473	-1.081	
14	2	.996	1	1.000	.000	1	.000	18.537	-2.151	
1	1	.181	4	1.000	6.252	2	.000	40.496		
2	1	.382	4	.991	4.185	2	.009	13.599		
3	1	.022	4	.966	11.402	2	.034	18.079		
4	1	.971	4	1.000	.523	2	.000	19.938		
5	1	.360	4	.914	4.357	2	.086	9.073		
6	1	.443	4	1.000	3.735	2	.000	32.919		
7	1	.360	4	1.000	4.954	2	.000	22.958		
8	2	.167	4	.871	6.473	1	.129	10.301		
9	2	.001	4	.999	19.625	1	.001	34.266		
10	2	.305	4	1.000	4.830	1	.000	33.951		
11	2	.026	4	1.000	11.027	1	.000	50.406		
12	2	.520	4	1.000	3.229	1	.000	18.702		
13	2	.009	4	.506	13.454	2	.494	13.505		
14	2	.026	4	.999	11.024	1	.001	25.062		

元のデータでは、Mahalanobis の距離の 2 乗は正準関数に基づきます。  
交差確認済みのデータでは、Mahalanobis の距離の 2 乗は観測値に基づきます。

\*\* 間違っ分れたケース

a. 交差確認は分析中のケースのみに実行されます。交差確認では、各ケースはそのケース以外のすべてのケースから得られた関数より分類されます。

図表 4-21



◀ 図表4-39

らである。したがって、クラスター数を検討する際には、そうした結合が生じる前の段階までのクラスター化の過程に目を向ければよいことになる。

以上のようなクラスター化の過程は「デンドログラム」として表現される(図表4-39)。デンドロ (dendro) というのはギリシャ語で樹木を意味する言葉で、デンドログラム (dendrogram) は樹状図とも呼ばれる。これがなんで樹木の形をした図なんだ、と思う人は、この図を右に90度回転させてみよう。上に並ぶ個々のケースが葉っぱに、クラスター化の過程を示す線で結ばれた部分が下へ行くほど太くなっていく枝に、そして、最終的に全部のケースが結合された部分は太い幹のように見えないだろうか。そう見えた人が(誰だか知らないが)、こうした図をデンドログラムと呼ぶようになったのが、この言葉の始まりである。

「クラスタ凝集経過工程」の第1段階で結合された14(中野区)と15(杉並



になってしまう。非階層的クラスタ分析が採用されるのは、一つにはそうした計算上の制約からである。そこで、計算不能にならないケース数までは階層的クラスタ分析を実行すればよいと言うこともできる。現在では中程度のパソコンでもかなりのケースの階層的クラスタ分析が可能と考えられるので、非階層的クラスタ分析については簡単に触れておくだけにする。

非階層的クラスタ分析の代表的なものはK-means法（K-平均法）である。SPSSでいう「大規模ファイルのクラスタ」分析もこの方法を採用している。K-means法のKというのはあらかじめ指定したクラスタの数のことである。K個のクラスタに分類するというを先に決めて、暫定的に構成されたクラスタの中心とケースとの距離を計算してそれぞれのケースを最も近いクラスタに所属させる。このとき、クラスタの中心として、そのクラスタに所属させたすべてのケースと暫定的な中心（重心）との距離の平均値（mean）を採用する。この方法がK-meansと呼ばれるのはそのためである。一度すべてのケースをK個の各クラスタに所属させたら、再度クラスタの中心を計算してケースの所属を見直す。この操作をすべてのケースについて繰り返す。各ケースと所属クラスタの中心との距離の合計が最小になったところで所属クラスタを確定する。距離の測り方には前にも述べたように様々なものがあるが、SPSSの「大規模ファイルのクラスタ」分析ではユークリッド距離を使っている。非階層的クラスタ分析は、何らかの根拠や必要からクラスタ数があらかじめ決められていて、ケース数も膨大で、クラスタを階層的にとらえる必要がないような場合に威力を発揮する方法といえる。

SPSSには、非階層的クラスタ分析の方法としてもう一つ「TwoStepクラスタ」分析というのを用意している。これも大規模ファイルのクラスタ分析に適した方法であるが、特徴的なことは、変数のタイプを問わないことである。間隔データや比率データのような連続データからなる変数、順序データの変数、名義データのようなカテゴリ変数も使える。そして、クラスタ数を自動的に決定するところや作図の出力が豊富なところも「階層クラスタ」や「大規模ファイルのクラスタ」とは異なるところである。「大規模ファイルのクラスタ」や「TwoStepクラスタ」は、ケース数が多くないからといって使えないわけではないから、機会を見て一度試してみたらよい。

合には有意確率が0.05未満になることが多く、帰無仮説が棄却されてしまう。そこで、大規模標本の場合には、この方法による適合度検定は有用ではないとされている。そのような時には、RMSEA (Root Mean Square Error of Approximation: 平均2乗誤差平方根) という検定方法を試してみるとよい。RMSEAは、出力された「適合度検定」の表にあるカイ2乗値と自由度を次の式に代入すれば得られる。

$$\text{RMSEA} = \sqrt{\left(\frac{\text{カイ2乗値}}{\text{自由度}} - 1\right) \div (\text{サンプル数} - 1)}$$

一般に、RMSEAが0.08未満であれば適合度は良好で、0.05未満なら文句なしと判断される。なお、カイ2乗値が自由度よりも小さいときにはRMSEAを0とみなす。RMSEAは標本規模に制約されないから小規模標本でも利用できる。ここでの例で言えば、カイ2乗値の24.180は自由度の25よりも小さいからRMSEAは0ということになる。SPSSでもカイ2乗値による適合度検定だけでなくRMSEAを出力してくれればよいのと思う。

図表5-39の「パターン行列」(因子パターン行列)は、ここで採用した直接オブリミン法やプロマックス回転のような斜交回転の場合に出力される回転

▼ 図表5-39

パターン行列<sup>a</sup>

	因子		
	1	2	3
私はクラブやグループ、団体のためにがんばっている	.946		
私は地域のためにがんばっている	.941		
私は社会や世の中のためにがんばっている	.874		
私を正しく評価できない人は、ろくな人物ではない		.878	
私は自分のことをなかなかの人間だと思っている		.873	
私は人と議論しても負けることが少ない		.790	
私にまかせておけば、うまくいくことが多い		.723	
私には良いところがたくさんある		.610	
私は子どものためにがんばっている			.846
私は友人に信頼されている			.800
私は家族の者に頼りにされている			.474

因子抽出法：最尤法

回転法：Kaiserの正規化を伴うオブリミン法

a. 4回の反復で回転が収束しました。

## 6-5-4 一元配置分散分析の出力

最初に出力されるのは「記述統計」である（図表6-32）。「グループの平均」を実行したときに出力された「報告書」にはなかった各グループの「平均値の信頼区間」が表示されている。

現在の給与

記述統計

	度数	平均値	標準偏差	標準誤差	平均値の 95% 信頼区間		最小値	最大値
					下限	上限		
1 25歳未満	83	\$25,314.94	\$4,224.578	\$463.708	\$24,392.48	\$26,237.40	\$18,150	\$40,800
2 25-29	154	\$38,476.62	\$15,244.107	\$1,228.405	\$36,049.80	\$40,903.45	\$21,900	\$91,250
3 30-39	92	\$45,084.95	\$21,600.983	\$2,252.058	\$40,611.51	\$49,558.38	\$20,850	\$110,625
4 40-49	68	\$32,920.88	\$20,023.380	\$2,428.191	\$28,074.19	\$37,767.57	\$16,950	\$135,000
5 50歳以上	76	\$24,565.13	\$7,448.973	\$854.456	\$22,862.97	\$26,267.29	\$15,750	\$65,000
合計	473	\$34,418.45	\$17,093.723	\$785.970	\$32,874.01	\$35,962.88	\$15,750	\$135,000

現在の給与

等分散性の検定

Levene 統計量	自由度1	自由度2	有意確率
28.216	4	468	.000

次に出力されるのは「等分散性の検定」結果である（図表6-33）。「有意確率」が0.000と小さく、「各グループの分散は等しい」という帰無仮説は棄却される。したがって、このデータを用いて分散分析を実行することは適切ではないことになる。そこで、分散分析によらずに、「平均値同等性の耐久検定」という恐ろしい表題の付いた「Brown-Forsythe」と「Welch」の検定結果の表からグループ間に有意差があるかないかを判断することにする（図表6-34）。表の下に「漸近的F分布」とあるのは、サンプルサイズ（ケース数）が大きくなると、それらの統計量はF分布に近づきますよ、という注記である。「有意」の欄を見ると、いずれの有意確率も0.000と小さいので、グループによって平均値に有意な差があると判断してよいことになる。

現在の給与

平均値同等性の耐久検定

	統計	自由度1	自由度2	有意
Welch	44.282	4	199.842	.000
Brown-Forsythe	29.251	4	250.687	.000

a. 漸近的 F 分布

「分散分析」の表に示されている1次の項の「重み付き」は、前節で実行した「グループの平均」で出力された「分散分析表」の中の「線型成分」と同