

	A	B	C	D	E	F	G	H	I	J
1	年齢調整死亡率(直接法)及びSMRの計算									
2										
3				入力データ			年齢調整死亡率(直接法)の計算			SMRの計算
4	年齢階級	昭和60年モデル人口(千人)	全国人口(平成7年)	全国死亡数(平成7年)	福岡県推計人口(平成7年)	福岡県死亡数(平成7年)	福岡県死亡率(人口千対)	重み	死亡率×重み	期待死亡数
5		①	②	③	④	⑤	⑥	⑦	⑧	⑨
6							$\text{⑤} \div \text{④} \times 1,000$	$\text{①} \div \text{①}$ の合計	$\text{⑥} \times \text{⑦}$	$\text{③} \div \text{②} \times \text{④}$
7	0~4歳	8180	5949623	7040	236167	309	$=F7/E7*1000$	$=B7/\$B\25	$=G7*H7$	$=D7/C7*E7$
8	5~9歳	8338	6493110	1235	264385	46	$=F8/E8*1000$	$=B8/\$B\25	$=G8*H8$	$=D8/C8*E8$
9	10~14歳	8497	7424703	1184	310225	56	$=F9/E9*1000$	$=B9/\$B\25	$=G9*H9$	$=D9/C9*E9$
10	15~19歳	8655	8491929	3362	361329	118	$=F10/E10*1000$	$=B10/\$B\25	$=G10*H10$	$=D10/C10*E10$
11	20~24歳	8814	9765295	5087	395386	202	$=F11/E11*1000$	$=B11/\$B\25	$=G11*H11$	$=D11/C11*E11$
12	25~29歳	8972	8614403	4596	314347	161	$=F12/E12*1000$	$=B12/\$B\25	$=G12*H12$	$=D12/C12*E12$
13	30~34歳	9130	7968686	5129	294244	217	$=F13/E13*1000$	$=B13/\$B\25	$=G13*H13$	$=D13/C13*E13$
14	35~39歳	9289	7709028	6839	306913	263	$=F14/E14*1000$	$=B14/\$B\25	$=G14*H14$	$=D14/C14*E14$
15	40~44歳	9400	8916937	12814	364869	530	$=F15/E15*1000$	$=B15/\$B\25	$=G15*H15$	$=D15/C15*E15$
16	45~49歳	8651	10544944	24136	412540	991	$=F16/E16*1000$	$=B16/\$B\25	$=G16*H16$	$=D16/C16*E16$
17	50~54歳	7616	8867530	32946	325448	1275	$=F17/E17*1000$	$=B17/\$B\25	$=G17*H17$	$=D17/C17*E17$
18	55~59歳	6581	7912482	44732	296435	1750	$=F18/E18*1000$	$=B18/\$B\25	$=G18*H18$	$=D18/C18*E18$
19	60~64歳	5546	7445934	68310	288126	2841	$=F19/E19*1000$	$=B19/\$B\25	$=G19*H19$	$=D19/C19*E19$
20	65~69歳	4511	6373007	89089	249979	3718	$=F20/E20*1000$	$=B20/\$B\25	$=G20*H20$	$=D20/C20*E20$
21	70~74歳	3476	4674557	102443	187725	4162	$=F21/E21*1000$	$=B21/\$B\25	$=G21*H21$	$=D21/C21*E21$
22	75~79歳	2441	3276736	125428	128807	4915	$=F22/E22*1000$	$=B22/\$B\25	$=G22*H22$	$=D22/C22*E22$
23	80~84歳	1406	2293864	157863	92226	6187	$=F23/E23*1000$	$=B23/\$B\25	$=G23*H23$	$=D23/C23*E23$
24	85歳以上	784	1576179	229269	67300	9416	$=F24/E24*1000$	$=B24/\$B\25	$=G24*H24$	$=D24/C24*E24$
25	合計	$=SUM(B7:B24)$	$=SUM(C7:C24)$	$=SUM(D7:D24)$	$=SUM(E7:E24)$	$=SUM(F7:F24)$	$=F25/E25*1000$	$=SUM(H7:H24)$	$=SUM(I7:I24)$	$=SUM(J7:J24)$
26							↑ 粗死亡率	↑ 年齢調整死亡率(直接法)		
27										
28		SMR[⑤の合計÷⑨の合計]		$=F25/J25$						
29		SMRの分散		$=F25/J25^2$						
30										
31		SMRの95%信頼区間		$=D28-1.96*SQRT(D30)$	~		$=D28+1.96*SQRT(D30)$			
32		正規近似によるZ		$=ABS(F25-J25)/SQRT(J25)$						
33		正規近似による検定結果		$=IF(D34>2.578,"p<0.01",IF(D34>1.96,"p<0.05","n.s.))$						
34		ポアソン分布によるp		$=IF(J25<5,IF(F25<J25,POISSON(F25,J25,TRUE),1-POISSON(F25-1,J25,TRUE)),"")$						
35		ポアソン分布による検定結果		$=IF(D38<>"",IF(D38<0.005,"p<0.01",IF(D38<0.025,"p<0.05","n.s.)),"")$						
36										
37										
38										
39										
40										

【研修における例題回答】

【二項分布の特徴】

★9-A) これまで解説した正規、t、F分布はxが連続変数であったが、二項分布は下図の例(サイコロの目が出る確率)のように、 $x(0 \sim n)$ は整数しかとれないため、離散型の分布の代表である。しかし、nが大きくなると、確率変数 $\frac{x}{n}$ は連続型のように取り扱われることもある。




図9-1 サイコロの目が出る確率

表9 n=10の確率

x	$n \cdot C_x \cdot p^x \cdot q^{n-x}$
0	0.161506
1	0.323011
2	0.290710
3	0.155045
4	0.054266
5	0.013024
6	0.002171
7	0.000248
8	0.000019
9	0.000001
10	0.000000

▶9-B) 二項確率を $f(x)$ とすると、コンピュータでの計算は簡単である。

$$f(0) = (1-P)^n, f(i+1) = \frac{n-i}{i+1} \cdot \frac{P}{1-P} \cdot f(i) [i=0 \sim n-1]$$

ただし、n、Pがともに大きいと、計算精度が問題となる。手計算ではnが大きいと階乗!の計算は無理なので、二項係数 $n \cdot C_x$ の数値表が作られているほか、他の分布へのさまざまな変換が試みられてきた。

- ① 正規分布への近似: 二項分布で $P=Q=\frac{1}{2}$ でかつ $n \rightarrow \infty$ の連続型は正規分布となる。そこで、 $nP \geq 5$ (かつ $nQ \geq 5$) の時、二項分布を正規分布に近似させてよいとされている。
- ② 逆正弦変換: 多くの比率を扱う場合、 θ (ラジアン) $= \sin^{-1} \sqrt{P}$ と変換すると分散は $\frac{1}{4n}$ となり、確率とは無関係になる(詳しくは専門書)。
- ③ $nP < 5$ の場合については、詳しく後述する(p.76~)。

- ① $nP \geq 5 (nQ \geq 5)$ の場合 → 正規近似式による (1)
- ② $nP < 5$ の場合 → F検定式による (2)
- ③ $n \geq 50 (P \rightarrow 0)$ の場合 → ポアソン分布への近似 (3)

(1) $nP \geq 5 (nQ \geq 5)$ の場合 → 正規近似式による
 (IX-3)式を用いてもよいが、離散型である二項分布を連続である正規分布に近似させると、多少無理が生じてしまう。したがって、以下のようにイェーツ(Yates)の修正項 $-\frac{1}{2n}$ によって連続修正する。

$H_0: p_s = P$ のもとで、

$$z_0 = \frac{|p_s - P| - \frac{1}{2n}}{\sqrt{\frac{P(1-P)}{n}}} \sim N(0, 1^2) \quad \dots (IX-6)$$

※厳密に言えば、(IX-4)式にもイェーツの修正項 $\pm \frac{1}{2n}$ が必要であるが、nが十分に大きいという仮定のもとでは、0に近い修正しなくてもよい。

ところで、一般的に標本では陽性者x人の数は知られており、 $x = np_s$ であるから、(IX-6)式の分母・分子にnを乗じて、

$$z_0 = \frac{|x - nP| - 0.5}{\sqrt{nP(1-P)}} \sim N(0, 1^2) \quad \dots (IX-7)$$

となる。期待値 $nP \geq 5$ は計算済みなので、(IX-7)式の方が計算しやすい。

【例9-2】昭和58年の「学校保健統計」によると、小学校6年生の永久歯患者率は、X県全体で87.4%であった。A小学校では6年生54人中、罹患者は30人(55.6%)であったという。 $\alpha=0.05$ として検定しなさい。


- ① $nP = 54 \cdot 0.874 = 47.196 > 5$ であるから、正規近似式を用いてよい。
- ② H_0 : 標本比率=母比率のもとで、 $(n(1-P) = 6.804 > 5)$

$$z_0 = \frac{|30 - 47.196| - 0.5}{\sqrt{47.196 \cdot 0.126}} = 6.847 > z\left(\frac{0.001}{2}\right) = 3.291$$

したがってA小学校の罹患率率は、X県より有意に ($p < 0.001$) 低い。

(2) $nP < 5$ かつ $nQ < 50$ の場合 → F検定式による

2. 区間推定で述べたように標本数nが小さい場合、信頼区間が広くなりすぎて意味がない。しかし、検定では実例が多いにもかかわらず、F検定式による場合を明記してあるテキストは少ない。 H_0 : 標本比率=母比率として、図9-2、3のように、陽性者が $\begin{cases} x \text{人以下} \\ x \text{人以上} \end{cases}$ の片側確率を2倍して評価する。



- ① 陽性者がx人以下の場合、 $n_1 = 2(x+1)$, $n_2 = 2(n-x)$ であるから、 $F_t = \frac{n_2 P}{n_1 Q} > F_{\alpha}^{n_1} \left(\frac{Q}{2}\right)$ なら H_0 を棄却する。……(IX-8)
- ② 陽性者がx人以上の場合、 $n_1 = 2(n-x+1)$, $n_2 = 2x$ であるから、 $F_u = \frac{n_2 Q}{n_1 P} > F_{\alpha}^{n_1} \left(\frac{Q}{2}\right)$ なら H_0 を棄却する。……(IX-9)

【例9-3】非流行年の風疹抗体陽性率は、「伝染病流行予測調査事業」によって6歳女児で15.0%と予想された。B小学校1年女子25人中抗体陽性者が、
 a) 1人 } であった場合について、それぞれ $\alpha=0.05$ として検定しなさい。
 b) 8人 }
 ① $nP = 25 \cdot 0.15 = 3.75 < 5$ なので、正規近似式を使うことができない。




図9-4 F_{α} の分布

② $H_0: p_s = P, Q = 1 - P = 0.85$

a) の場合、 $n_1 = 2(1+1) = 4$, $n_2 = 2(25-1) = 48$ から、

$$F_t = \frac{48 \cdot 0.15}{4 \cdot 0.85} = 2.118 < F_{\alpha}^{n_1} \left(\frac{0.05}{2}\right) = 3.066$$

したがって、 H_0 を棄却できず、陽性者1人は有意に少ないとはいえない。

b) の場合、 $n_1 = 2(25-8+1) = 36$, $n_2 = 2 \cdot 8 = 16$

$$F_u = \frac{16 \cdot 0.85}{36 \cdot 0.15} = 2.519 < F_{\alpha}^{n_1} \left(\frac{0.05}{2}\right) = 2.528$$

したがって、 H_0 を棄却できず、陽性者8人は有意に多いとはいえない。

③ 念のため正規近似式でも検討してみる。

a) の場合、 $z_0 = 1.260 < 1.96$ で有意差なしと判定は変わらない。

b) の場合、 $z_0 = \frac{|8 - 3.75| - 0.5}{\sqrt{3.75 \cdot 0.85}} = 2.100 > z\left(\frac{0.05}{2}\right) = 1.96$

つまり、うっかり正規近似式を用いると、誤った判定を下すことになる。

(3) $nP < 5$ かつ $n \geq 50$ の場合 → ポアソン分布に近似させる

たとえば、市町村における死因別死亡率を考えると、nが大きいのに対してPは0とみなせるくらい、非常に小さくなっている。そこでまれな事象の確率分布である、ポアソン分布(Poisson distribution)に近似させる。

★補足9-C

ポアソン分布の確率 $P(x)$ は、平均 $m = nP$ として、

$$P(x) = \frac{e^{-m} \cdot m^x}{x!} \quad \dots (IX-10)$$

($x=0, 1, 2, \dots, n$) (e は自然対数の底 $= 2.71828 \dots$)

として求められる。ただし、両側でなく片側の確率である。

【例9-4】昭和54~63年の10年間において、全国男性の白血病死亡率は人口10万対49.7であった。間接法を用いて年齢調整を行うと、C町の男性(1万人)の期待死亡数は4.97人であったとする。C町の10年間の観察死亡数が、

- a) 1人である場合
 - b) 10人である場合
- について、それぞれ $\alpha=0.05$ として検定しなさい。

① 標準化死亡比(SMR) = $\frac{\text{観察値}}{\text{期待値}} \times 100$ であるから、補足9-D

a) では $SMR = \frac{1}{4.97} \times 100 = 20.1$, b) では $SMR = 201.2$ となる。

② $m = nP = 4.97 < 5$ かつ $n \geq 50$ のので、(IX-10)式を用いる。a) の場合、 $P(1)$ を求めただけでは下側確率にならないことに注意する。

$$P(0) = \frac{e^{-4.97} \cdot 4.97^0}{0!} = 0.006943 \quad P(1) = \frac{P(0) \cdot 4.97}{1} = 0.034507$$

③ 両側確率に直すため2倍する。つまり求める確率 p は、
 $p = 2 \cdot (P(0) + P(1)) = 2 \cdot 0.04145 = 0.0829$

したがって H_0 は棄却できず、全国に比べて SMR は低いとはいえない。

b) の場合、図9-5のように9人以下の確率 $\sum_{x=0}^9 P(x)$ を求め、1から引く。

$$\text{つまり、} p = 2 \cdot (1 - \sum_{x=0}^9 P(x)) = 2 \cdot 0.030753 = 0.061506$$

したがって H_0 は棄却できず、全国に比べて SMR は高いとはいえない。




図9-5 ポアソン分布の確率(m=4.97の場合)

④ ちなみに正規近似式で検定すると、

a) の場合、 $z_0 = 1.557 < 1.96$ で有意差なしと判定は変わらない。

b) の場合、 $z_0 = \frac{10 - 4.97 - 0.5}{\sqrt{4.97(1 - 0.000497)}} = 2.032 > z(\frac{0.05}{2}) = 1.96$

となり、正規近似式を用いた場合、誤った判断を下すことになる。

※ただし、SMRの判定に関しては、片側検定でよいとする考え方もある。

【ポアソン分布の特徴】

★9-C)ポアソン分布は、非常にまれな事象の確率で、離散型分布のひとつである。「馬にケラレテ死ぬ確率」が有名であるが、医学的データにも例が多い。二項分布で平均 $m = nP$ を一定にし、 $n \rightarrow \infty, P \rightarrow 0$ の極限型がポアソン分布であるが、 $nP < 5$ かつ $n \geq 50$ の場合、正規分布に近似できる。




図9-6 二項分布とポアソン分布との関係

医学的データで、ポアソン分布のよくあてはまる例として、工場や学校での負傷発生数、市町村での1年間のがん死亡数、先天異常の発生数、飲料水検査での大腸菌数を予測する最確数(MPN)等が知られている。

▶9-D) $nP \geq 5$ の場合、SMR(Standardized Mortality Ratio)の検定については、観察値 = O, 期待値 = $E = nP$ とおいて、

$$\textcircled{1} \text{ 正規近似式 } z_0 = \frac{O - E - 0.5}{\sqrt{E(1 - P)}} \sim N(0, 1^2) \quad \dots\dots (IX-11)$$

② $P \rightarrow 0, 1 - P \rightarrow 1$ から、(IX-11)式を2乗する。

$$z_0^2 = \frac{(O - E - 0.5)^2}{E} \sim \chi^2 \quad \dots\dots (IX-12)$$

自由度1のカイ2乗分布(p.84)に従うとみなしてよい。

つまり、ポアソン分布でもカイ2乗検定でも母比率Pが必要がない。

③ F検定式において、片方の自由度 $\rightarrow \infty$ と考えて検定してもよい。

【例9-4】b)は $n_1 = 19982 \rightarrow \infty, n_2 = 20$ で(IX-9)式から、

$$F_u = \frac{20 \cdot (1 - P)}{19982 \cdot P} = 2.013 < F_{\alpha}(\frac{0.05}{2}) = 2.085 \text{ と有意性は変わらない。}$$

第11章 多数の標準比率の比較

ただし、期待値 $F_i < 5$ の i をまとめるためには、(XI-2)式の方がよい。

【例11-3】職業別に肥満度を調べた結果は、表11-7のとおりであった。肥満者の割合は職業によって差が認められるか、 $\alpha = 0.05$ として検定しなさい。

表11-7 職業別肥満度の分布

	事務職	商業	農林業	鉱工業	計
肥満度 20%以上	150	70	60	100	380
20%未満	550	230	340	500	1620
計	700	300	400	600	2000
肥満者の割合(%)	21.4	23.3	15.0	16.7	19.0

H_0 : 肥満者の割合は職業別に差はない。自由度は $l - 1 = 3$ である。

$$\chi^2 = \frac{2000^2}{380 \cdot 1620} \left(\frac{150^2}{700} + \frac{70^2}{300} + \frac{60^2}{400} + \frac{100^2}{600} - \frac{380^2}{2000} \right) = 12.624 > \chi^2(0.01) = 11.345$$

したがって H_0 は棄却され、肥満者の割合は、職業別に有意差 ($p < 0.01$) が認められる。しかし、このままではどこに差があるかは明らかではない。図11-2に示すように 2×2 表の組み合わせの結果をまとめておくとよい。




図11-2 2×2 表の組み合わせ結果

(5) カイ2乗-傾向性の検定 $\leftarrow l$ が順序尺度の場合

解説しているテキストは少ない。例をあげて手順を説明する。

【例11-4】年齢階級別の陽性率を調査したら、表11-8のような結果を得たとする。年齢階級が進むにつれて、陽性率が上昇していることを証明したい。

表11-8 年齢階級別陽性率(%)

	20~29歳	30~39歳	40~49歳	計
陽性 A_j	38	50	30	118 (A)
陰性 $m_j - A_j$	162	150	70	382 (N-A)
計 m_j	200	200	100	500 (N)
陽性率 $p_j = m_j/A_j$	19.0	25.0	30.0	23.6 (p = A/N)
得点 x_j	-1	0	1	—

この場合、横の項目 j は年齢階級順に並んでいるので、自由に入れ替えることができない。そこで、(XI-4)式だけでなく、特別なカイ2乗検定式を用いる。

① 全体の χ^2 値を(XI-4)式から求める。

$$\chi^2 = \frac{500^2}{118 \cdot 382} \left(\frac{38^2}{200} + \frac{50^2}{200} + \frac{30^2}{100} - \frac{118^2}{500} \right) = 4.836 \quad df: R-1$$

※ここで $\chi^2 < \chi^2(0.05) = 5.991$ から、直ちに NS と判定しないこと。

② 帰帰による χ^2 値を次式から求める。(df=1) 表11-8から、

$$\left. \begin{aligned} \sum A_j &= A, & \sum A_j x_j &= 38 \cdot (-1) + 50 \cdot 0 + 30 \cdot 1 = -8 \\ \sum m_j &= N, & \sum m_j x_j &= 200 \cdot (-1) + 200 \cdot 0 + 100 \cdot 1 = -100 \\ x_j &= -1, 0, 1 & \sum m_j x_j^2 &= 200 \cdot 1 + 200 \cdot 0 + 100 \cdot 1 = 300 \end{aligned} \right\} \text{とおくと、} \quad df: R-1$$

$$\chi^2 = \frac{N(\sum A_j x_j - A \sum m_j x_j)^2}{A(N-A)(\sum m_j x_j^2 - (\sum m_j x_j)^2)} = \frac{500(500 \cdot (-8) - 118 \cdot (-100))^2}{118 \cdot 382(500 \cdot 300 - (-100)^2)} = 4.820 > \chi^2(0.05) = 3.841 (H_0: \text{帰帰による傾向が認められない、と考えればこのままでも有意差ありと判定してよいが、③の結果も考慮する。})$$

③ 図11-3のように、仮想的な帰帰直線からの偏りを χ_{11}^2 とする。 H_0 : 帰帰直線からの偏り(へだたり)はない、という仮定のもとで、

$$\chi_{11}^2 = \chi^2 - \chi^2 \sim \chi_{1-1}^2 \quad \dots\dots (XI-5)$$

$$\chi_{11}^2 = 4.836 - 4.820 = 0.016 < \chi^2(0.05) = 3.841$$

したがって H_0 は棄却できず、② から帰帰による傾向が認められるので、年齢階級が進むにつれて、陽性率は有意に ($p < 0.05$) 上昇する。▶補足11-F




図11-3 年齢階級別勝性率

(6) リジット解析(Ridit Analysis)

順序尺度(p. 3)である I について対照群と比較する場合である。たとえば、食事調査で、① 毎日、② 週4~6回、③ 週1~3回、④ あまり食べない等、順序をもつ例は医学的データには多い。しかし、解説しているテキストは少ない。

【例11-5】治療薬A、Bについて薬効試験を行った結果は、表11-9のとおりであった。両薬の効果に差が認められるか、 $\alpha=5\%$ として判定しなさい。

表11-9 薬効試験の例

	a) 著効	b) 有効	c) やや有効	d) 不変	e) 悪化	計	a)~c)	d)+e)
対照薬A	5	10	15	15	5	50	30	20
実験薬B	10	15	12	10	3	50	37	13
計	15	25	27	25	8	100	67	33

※(4)、(5)の場合は表を1方向に見たが、ここでは計が1方向にある。

A、Bの入れ替えは可能であるが、対照群が基準となるので表11-9のように書いた方がよい。(X-4)式によると、 $\chi^2=4.500 < \chi^2(0.05)=9.488$ である。

また、e)悪化のB薬の期待値は $50 \cdot 8/100=4 < 5$ なので、表11-9のようにa)~c)とd)+e)とに分割する。2x2表として(X-4)式を用いても、 $\chi^2=1.628 < \chi^2(0.05)=3.841$ と、有意差が認められないことに注意されたい。

表11-10 リジット解析の計算例

	1) 対照群	2) 1)/2	3) 累積度数	4) 2)+3)	5) 4)/n ₁	6) 実験群	7) 5)×6)
著効	5	2.5	0	2.5	0.05	10	0.50
有効	10	5.0	5	10.0	0.20	15	3.00
やや有効	15	7.5	15	22.5	0.45	12	5.40
不変	15	7.5	30	37.5	0.75	30	7.50
悪化	5	2.5	45	47.5	0.95	3	2.85
	n ₁ =50	—	50	50.0	1.00	n ₂ =50	19.25

そこでリジット解析を適応するが、手順は表11-10を参照のこと。

▶補足11-G

- ① 対照群の度数1)の半分を2)とする。
- ② 3)に累積度数(p.10)をとるが、はじめは0として通常より一段下げる。
- ③ 2)+3)を求め4)とする。累積度数について(各区分+次区分)/2でもよい。
- ④ 4)を対照群のn₁で割った値を5)とし、対照群の期待的な分布と考える。
- ⑤ 5)に実験群の各度数6)をかけて、7)の計を求める。

$$\left\{ \begin{array}{l} \text{実験群の平均リジット } \bar{R}_b \text{ は, } \bar{R}_b = \frac{7) \text{の計}}{n_2} = 0.385 \\ \text{対照群の平均リジット } \bar{R}_a \text{ は常に, } \bar{R}_a = 0.5 \left(\because \frac{\sum I_j \cdot 5}{n_1} = \frac{25}{50} \right) \end{array} \right.$$

- ⑥ 近似的に平均リジットの標準誤差(p.28) $s = \frac{1}{2\sqrt{3n_2}}$ である。

したがって、 $H_0: \bar{R}_A = \bar{R}_B$ のもとで、

$$z_0 = \frac{|\bar{R}_A - \bar{R}_B|}{s} = \sqrt{12n_2} |\bar{R}_A - \bar{R}_B| \sim N(0, 1^2) \quad \dots\dots (X-6)$$

を用いて検定する。(例11-5)では、

$$z_0 = \sqrt{12 \cdot 50} |0.5 - 0.385| = 2.817 > z \left(\frac{0.01}{2} \right) = 2.576$$

したがって $p < 0.01$ で H_0 を棄却でき、両群の分布に差が認められる。

- ⑦ ところで、両群の平均リジット $\pm s$ を表示してみると、図11-4のように実験群の方が左にシフトしている。表11-10では、「著効」を先にとったの

統計学の基礎 1, 2

目次	ページ
A. 統計的方法の概要	
1. 統計的な考え方	1
2. 特性値	1
B. 標本抽出法	
1. 有意抽出法	2
2. 確率抽出法	2
C. 確率分布	
1. 二項分布	3
2. ポアソン分布	3
3. 正規分布	3
4. t-分布	4
5. カイ2乗分布	4
6. F-分布	5
7. 二項分布の正規近似	5
D. 推定と検定	
1. 母数	6
2. 統計量	6
3. 点推定	6
4. 区間推定	6
5. 標本数の決定	7
6. 検定	7
7. 分布による仮説検定	8
E. 相関分析	
1. 相関係数 r の検定	10
2. 偏相関係数の検定	11
3. 平行性検定法	11
統計学演習問題	1-3
統計学 Example 1 (出題)	

統計学の基礎 1, 2

～統計分布による推定・検定法を中心として～


福岡県保健環境研究所 篠原志郎

A. 統計的方法の概要

1. 統計的な考え方

- 測定値にはバラツキ (Dispersion) がつきもの (誤差)
- そのバラツキには統計的な規則性がみられる (分布)
- 大数の法則: x が平均 μ , 分散 σ^2 の分布に従うとき, x がどんな分布であっても, 標本数 n の無作為標本 (Random sampling) による \bar{x} は正規分布 $N(\mu, \sigma^2/n)$ に n が大きくなるにつれて近づく (中心極限定理: 一般に, $n > 25$ で適用)
- 統計的推論に基づいて行動する (検定)

Fisher の 3 原則 + 1 (1935): 反復 (Replication), 局所管理 (Local control), 無作為化 (Randomization), 因子の組み合わせ (Factorial combination)



2. 特性値

母集団を知る手がかりとして, 母集団から取られた標本の度数分布表を作り, ヒストグラム等を描く. それによって分布の形や特徴がつかめるが, 更に, 数量化できれば, なお, 的確な情報を得ることができる. この数量的に表現された指標を特性値とよぶ.

1) 分布の中心を代表する指標

- ① 平均値
 - a. 算術平均値 $\bar{x} = \frac{x_1 + x_2 + \dots + x_n}{n} = \frac{1}{n} \sum_{k=1}^n x_k = \sum x/n$
 - b. 幾何平均値 $\bar{y} = \sqrt[n]{x_1 \cdot x_2 \cdot \dots \cdot x_n} = (x_1 \cdot x_2 \cdot \dots \cdot x_n)^{1/n}$
 - c. 調和平均値 $\bar{z} = \frac{1}{n} (\frac{1}{x_1} + \frac{1}{x_2} + \dots + \frac{1}{x_n}), x_1, x_2, \dots, x_n \neq 0$

- ② 中央値 $Me = (n+1)/2$ 番目の測定値 (n: 奇数 odd number)
 $= [n/2 \text{ 番目} + (n/2+1) \text{ 番目}] / 2$ (n: 偶数 even number)

- ③ モード (最頻値) $Mo =$ 最も度数の多い測定値

- ④ 最大値, 最小値

2) 分布の広がりの程度を代表する指標

- ① 分散 (不偏分散) $s^2 = \frac{1}{n-1} \sum_{k=1}^n (x_k - \bar{x})^2 = \frac{1}{n-1} \sum (x_k^2 - n\bar{x}^2)$
- ② 標準偏差 $s = \sqrt{s^2}$
- ③ 範囲 $R = x_{max} - x_{min}$
- ④ 変動係数 $CV = \frac{s}{\bar{x}} \times 100(\%)$

3) 正規性からのズレと異常

- ① ゆがみ具合 (歪度: Skewness) $\alpha_3 = \frac{\mu_3}{\sigma^3}, \mu_3 = E((X - \mu)^3), \alpha_3 > 0$ (分布が右に広がる)
- ② 尖り具合 (尖度: Kurtosis) $\alpha_4 = \frac{\mu_4}{\sigma^4} - 3, \alpha_4 > 0$ (トガリ型), μ_4 の推定 $= \frac{1}{n} \sum (x_i - \bar{x})^4, \sigma^4$ の推定 $= (\frac{1}{n} \sum (x_i - \bar{x})^2)^2 = (s^2)^2$

4) データのスクリーニング

- ① 異常データの検出 Grubbs, F.E. 法

B. 標本抽出法 (Sampling)


1. 有意抽出法・・・意図的に標本を抽出する方法

1) 典型法

母集団の特性値から母集団の相似形を意識して求めた抽出法

2) 割当法

母集団の特性値が同じ比率となるように選ぶ方法



2. 確率抽出法

1) 単純無作為抽出法 (Simple random sampling)

N個の要素の中から大きさ n の標本 x_1, x_2, \dots, x_n を非復元抽出して標本平均 \bar{x} を求める。

$$\bar{x} = \frac{1}{n} \sum x_i, E(\bar{x}) = \mu, V(\bar{x}) = \frac{N-n}{N-1} \frac{\sigma^2}{n}$$

2) 層別抽出法 (Stratified sampling)

母集団を k 個の層に分け、各層から標本を抽出する方法



$$\begin{aligned} \text{全平均 } \mu &= \sum_{i=1}^k p_i \mu_i, (p_1 + p_2 + \dots + p_k = 1, p_i = \frac{N_i}{N}) \\ \text{全分散 } \sigma^2 &= \sum p_i \sigma_i^2 + \sum p_i (\mu_i - \mu)^2 = \sigma_b^2 + \sigma_w^2 \\ \sigma_b^2 &= \sigma^2 - \sum p_i \sigma_i^2, \sigma_w^2 = \sum p_i \sigma_i^2 \end{aligned}$$


① 比例配分

k 個の層に分けられている母集団から、各層の大きさに比例した大きさの標本を抽出する方法、即ち、 $p_i = \frac{N_i}{N} = \frac{n_i}{n}$ 、標本平均 $\bar{x}_i = \sum p_i \bar{x}_i$ (\bar{x}_i は第 i 層からの標本平均)

$$\text{分散 } V(\bar{x}_i) = \sum p_i \frac{N_i - n_i}{N_i - 1} \frac{\sigma_i^2}{n} = \sum p_i \frac{\sigma_i^2}{n}$$

が成り立つ。即ち、単純ランダムサンプリングより層別抽出法が分散を小さくできる。

② 最適配分 (Neyman 配分)



$$\begin{aligned} n_i &= \frac{p_i \sigma_i}{p_1 \sigma_1 + p_2 \sigma_2 + \dots + p_k \sigma_k} \cdot n, (i = 1, 2, \dots, k) \text{ とおくと} \\ V(\bar{x}_i) &= \sum p_i^2 \frac{N_i - n_i}{N_i - 1} \frac{\sigma_i^2}{n_i} = \sum p_i^2 \frac{\sigma_i^2}{n_i} \text{ 最小 } \rightarrow \left(\frac{\sum p_i \sigma_i}{n} \right)^2 \end{aligned}$$

③ 多段抽出法

a. 二段抽出法：第 1 段階として全母集団から適当な大きさの中間的抽出集落 (クラスター) をいくつか抽出し、次に本来の調査個体を抽出する方法



母集団が N 個の要素からなる L 個のクラスターに分けられているとき、L 個のクラスターより l クラスター抽出し、抽出されたクラスターからそれぞれ n 個の標本を選び、標本平均 $\bar{x}_{(1)}, \bar{x}_{(2)}, \dots, \bar{x}_{(l)}$ を求め、

$$\begin{aligned} \bar{x} &= \frac{\bar{x}_{(1)} + \bar{x}_{(2)} + \dots + \bar{x}_{(l)}}{l}, E(\bar{x}) = \mu \text{ (母平均)} \\ V(\bar{x}) &= \frac{N-n}{N-1} \frac{\sigma_b^2}{l} + \frac{\sigma_w^2}{l} \\ \sigma_b^2 &= \frac{1}{L} \sum_{j=1}^L \sigma_j^2, \sigma_w^2 = \frac{1}{L} \sum_{j=1}^L (\mu_j - \mu)^2 \end{aligned}$$


C. 確率分布

1. 二項分布 (Binomial distribution) B (np, npq), q = 1 - p

二項定理によって、 $(p+q)^n = q^n + npq^{n-1} + \frac{n(n-1)}{2!} p^2 q^{n-2} + \dots + \frac{n(n-1)(n-2)\dots(n-k+1)}{k!} p^k q^{n-k} + \dots + np^{n-1} q + p^n$

二項分布とは離散型変数の分布で、表と裏、1と0のように2つのうちどちらかを選択する場合の確率分布である。この場合、 $p+q=1, p, q \geq 0$ である。例えば、n回のうちk回は事象Aが起き (確率p)、(n-k)回は事象A以外が起きる (確率: 1-p) 場合の確率を $P(k)$ とすると、 $P(k) = \binom{n}{k} p^k q^{n-k} = \frac{n!}{k!(n-k)!} p^k q^{n-k} = \frac{n(n-1)(n-2)\dots(n-k+1)}{k!} p^k q^{n-k}$

で示される。このとき、二項分布の平均値は np 、分散は $np(1-p) = npq$ 。




x	$nC_x p^x q^{n-x}$
0	0.161506
1	0.323011
2	0.290710
3	0.155045
4	0.054266
5	0.013024
6	0.002171
7	0.000248
8	0.000019
9	0.000001
10	0.000000

2. ポアソン分布 (Poisson distribution) P (λ)

ポアソン分布も離散型変数の分布で、例えば、交通事故や疾病による死亡数のような希に起こる事象の分布である。二項分布の平均値 np において、p が非常に小さく 0 に近く、n が大きい $np < 5$ の場合、このポアソン分布によく当てはまる。ポアソン分布の確率を $P(x)$ とすると、 $P(x) = e^{-\lambda} \frac{\lambda^x}{x!}, x = 0, 1, 2, \dots$ (ここに、 e (自然対数の底) = 2.71828...)

ポアソン分布の平均値 λ, 分散 λ である。

二項分布で平均 $m = np$ を一定にし、 $n \rightarrow \infty, p \rightarrow 0$ の極限型がポアソン分布であるが、 $np < 5$ かつ $n \geq 50$ の場合、正規分布に近似できる。



3. 正規分布 (Normal distribution) N (μ, σ²)

正規分布は連続型変数の分布である。最もよく使われる分布である。自然界の現象でこの正規分布が適用されるケースが非常に多い。正規分布の確率 (この場合、確率密度関数とい

う) $f(x)$ で示すと、 $f(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$, $-\infty < x < \infty$

また、正規分布を $N(\mu, \sigma^2)$ で表す。正規分布の平均値は μ 、分散は σ^2 である。正規分布のグラフは $x = \mu$ で左右対称である。正規分布関数は

$$F(x) = \int_{-\infty}^x f(x) dx = P(-\infty < X < x) = 1 - P(x \leq X)$$

分布形の面積が確率を表している。全面積は 1 である。 $z = (x - \mu) / \sigma$ の変換を施せば、 $N(\mu, \sigma^2)$ は $N(0, 1)$ に変わる。即ち、平均 0、分散 1 の正規分布である。これを標準 (標準) 正規分布という。

○正規確率紙

作成した分布が正規分布しているかどうかを調べるためのもので、正規分布に近ければ、それぞれの確率点を正規確率紙にプロットしたものが、ほぼ直線になる。より厳密に確かめるには χ^2 -分布による検定を行う。



自由度が n の t 分布の基本的な性質は以下のとおりである。

- ① 分布の全面積は 1 である
- ② $t = 0$ で極大値をとる
- ③ 分散は $\frac{n}{n-2}$ ($n > 2$)

確率密度関数は、ガンマ Γ 関数 (p. 36) を用いて、

$$y = \frac{\Gamma(\frac{n+1}{2})}{n\pi\Gamma(\frac{n}{2})} \left(1 + \frac{t^2}{n}\right)^{-\frac{n+1}{2}}$$

(※ n は自由度)



4. t-分布



標本平均 \bar{x} の分布は n が大きいときは $N(\mu, \sigma^2/n)$ に従う。 σ が未知のとき、 σ の代わりに標本分散 s^2 を使うことがよくある。しかし、標本数 $n \leq 25$ の場合、 $t = \frac{\bar{x} - \mu}{s/\sqrt{n}}$ は、自由度 $\nu = n - 1$ の t -分布に従う。 t -分布は $n \rightarrow \infty$ と正規分布に近づいていく。 t -分布のグラフは左右対称の分布である。

5. カイ 2 乗分布 (χ^2 -分布) (Chi-square distribution)

2 つ以上の選択しがあるケース、あるいは正規分布に従う変数 X の 2 乗 X^2 は χ^2 -分布に従う。 χ^2 -分布は自由度 ν をもち、 $\nu(0, 1, 2, \dots)$ の大きさで分布曲線が異なってくる。大きさ n の標本が正規母集団 (正規分布に従う母集団) から抽出されたものであるなら、そこから求められる変数、 $\frac{nS^2}{\sigma^2} = \frac{[(x_1 - \bar{x})^2 + (x_2 - \bar{x})^2 + \dots + (x_n - \bar{x})^2]}{\sigma^2} = \frac{\sum x_i^2 - n\bar{x}^2}{\sigma^2}$ は自由度 $\nu = n - 1$ の χ^2 分布に従う。


表の縦・横の項目に関連がない時、互いに「独立である」という。

平均 m 、分散 S^2 の母集団から大きさ n の標本を無作為抽出する時、 $\chi^2 = \frac{1}{S^2} \sum (x_i - m)^2 (\geq 0)$ は自由度 n のカイ 2 乗分布に従う。① 定義により上側確率しか存在しない。確率密度はガンマ関数を用いるが省略する。② n によって形が大きく異なり、 n が大きくなると左右対称に近くなる。



6. F-分布

標本分散 s^2 の検定によく用いられる分布である。例えば、分散が σ_1^2, σ_2^2 の 2 つの正規母集団から、大きさ m と n の標本を取ったとき、その標本分散を s_1^2 とすると、 $F = \frac{s_1^2/\sigma_1^2}{s_2^2/\sigma_2^2}$ は自由度 $\nu_1 = m - 1, \nu_2 = n - 1$ の F-分布に従うことが分かっている。これを使えば、分散の大きさの違いを比較検定することができる。



F 分布は左右対称でないので、正規分布や t 分布と異なり、棄却域も (図) に示すように、上側と下側で左右対称となっていない。

$$\text{しかし、} F_{\alpha/2}(\nu_1, \nu_2) = \frac{1}{F_{\alpha/2}(\nu_2, \nu_1)}$$

の関係が成立するので、等分散の検定の棄却域は、

$$\frac{U_1}{U_2} \geq F_{\alpha/2}(\frac{\nu_1}{\nu_2}), \quad \frac{U_1}{U_2} \leq F_{\alpha/2}(1 - \frac{\nu_1}{\nu_2}) = \frac{1}{F_{\alpha/2}(\frac{\nu_2}{\nu_1})}$$

つまり、 $\frac{U_1}{U_2} \geq F_{\alpha/2}(\frac{\nu_1}{\nu_2})$ 、または $\frac{U_1}{U_2} \leq \frac{1}{F_{\alpha/2}(\frac{\nu_2}{\nu_1})}$ の判定となるため、大きい方の不偏分散を分子として、上側確率だけで判定してよい。

また、 t 分布との関係は、 $\left\{t(\frac{\nu_1}{\nu_2})\right\}^2 = F_{\alpha/2}(\frac{\nu_1}{\nu_2})$ である。


二項確率を $f(x)$ とすると、コンピュータでの計算は簡単である。

$$f(0) = (1-P)^n, \quad f(i+1) = \frac{n-i}{i+1} \cdot \frac{P}{1-P} \cdot f(i) \quad (i=0 \sim n-1)$$

ただし、 n, P がともに大きいと、計算精度が問題となる。手計算では n が大きいと階乗! の計算は無理なので、二項係数 nC_r の数値表が作られているほか、他の分布へのさまざまな変換が試みられてきた。

① 正規分布への近似: 二項分布で $P=Q=1/2$ でかつ $n \rightarrow \infty$ の連続型は正規分布となる。そこで、 $nP \geq 5$ (かつ $nQ \geq 5$) の時、二項分布を正規分布に近似させてよいとされている。

② 逆正弦変換: 多くの比率を扱う場合、 θ (ラジアン) $= \sin^{-1} \sqrt{P}$ と変換すると分散は $\frac{1}{4n}$ となり、確率とは無関係になる。



7. 二項分布の正規近似

○二項分布において、 $p \leq 1/2$ のとき、 $np > 5$ ならば、正規分布に近似する。また、 $p > 1/2$ のときは $nq > 5$ ならば、正規分布に近似すると考えてよい。二項分布の平均値は np 、分散は npq であるから、標準化して、 $z = (x - np) / \sqrt{npq}$ にすると、

z は正規分布 $N(0, 1)$ に従う。即ち、平均 0、分散 1 の正規分布に従う。

○ z を更に、 n で割って、 $x = \frac{(x - np)}{\sqrt{npq}}$ は、割合 x/n が平均 p 、分散 pq/n の正規分布が使えることになる。

○ x が $N(\mu, \sigma^2)$ に従うなら、標本数 n のランダムサンプリングによる \bar{x} は $\bar{x} \sim N(\mu, \frac{\sigma^2}{n})$ であることがわかっている。これを \bar{x} の標本分布という。更に、 n がかなり大きい数、例えば、 $n \geq 50$ 、実用的には $n \geq 25$ なら、 x が正規分布していなくても平均 μ 、分散 σ^2 の分布でありさえすれば、 $\bar{x} \sim N(\mu, \frac{\sigma^2}{n})$ であることもわかっている。【中心極限定理とい

て 統計学では重要な法則の一つである。この法則があるため、あまり厳密な検証なしに \bar{x} の推定・検定ができるのである。】

D. 推定と検定

1. 母数 (Parameter)

母集団を特徴づける変量をさす。例えば、母集団が正規分布 $N(\mu, \sigma^2)$ に従うとき、この正規分布を決定づける変量 μ, σ を母数 (パラメータ) という。 μ, σ が分かれば、その母集団は既知と考える。母集団が二項分布 $B(n, p)$ に従うなら母数は p である。 p が決まれば、試行 n により二項分布は決まる。

2. 統計量 (Statistic)

母数を推定するために標本から得られる任意の量のことである。例えば、母集団から抽出された x_1, x_2, \dots, x_n は標本であるが、平均 $\bar{x} = (x_1 + x_2 + \dots + x_n) / n$ 、分散 s^2 、標準偏差 s などは、標本から計算された統計量である。そして、この統計量の分布が考えられる。

3. 点推定 (Point estimation)

一点で与えられる母数の推定を点推定という。例えば、母平均 μ の推定値として \bar{x} 、 Me 、 Mo 等を用いることができるが、どれが μ の良い推定値であるかは、多数の繰り返し実験のなかで、どの統計量の値が μ の代用値として適切であるかということである。良い推定量の基準として不偏推定量があげられる。不偏推定量は $E(x) = \mu$ と記す。 $E(x)$ は平均 \bar{x} の標本分布の平均のことで、期待値とよび、これが μ に等しいとき \bar{x} は μ の不偏推定量であるという。そのような不偏推定量がいっつかある場合、最小の分散をもつものが最も有効であると考える。例えば、 \bar{x} と Me は共に同じ母平均をもっている。しかし、 \bar{x} の標本分布の分散は σ^2 / n 、 Me の標本分布の分散は $\pi \sigma^2 / (2n)$ で、 σ^2 / n の方が小さい。従って、 \bar{x} の方が Me より有効な推定量といえる。また、分散 $s^2 = (\sum x_i^2 - n\bar{x}^2) / (n-1) = E(x^2) - \mu^2$ であることがわかっている。 s^2 は σ^2 の不偏推定量である。それゆえ、この s^2 を不偏分散とよんでいる。

4. 区間推定 (Interval estimation)

母数が与えられた2点の間に存在すると考える推定を区間推定という。一般に、推定の信頼度を95%あるいは99%に置く。その信頼度における推定区間を信頼区間という。この区間の両端を信頼限界値という。信頼度を高めようとするれば、推定区間は広くなる。

$\bar{x} \sim N(\mu, \frac{\sigma^2}{n})$ のとき、母平均 μ の95%信頼限界は $\bar{x} \pm 1.96 \frac{\sigma}{\sqrt{n}}$ 、真の平均 μ は、95%の信頼確率で、 $\bar{x} - 1.96 \frac{\sigma}{\sqrt{n}} < \mu < \bar{x} + 1.96 \frac{\sigma}{\sqrt{n}}$ の間に存在するといえる。

1) 正規分布による μ の区間推定

95%の信頼区間は

$$\bar{x} - 1.96 \frac{\sigma}{\sqrt{n}} < \mu < \bar{x} + 1.96 \frac{\sigma}{\sqrt{n}}$$

99%の信頼区間は

$$\bar{x} - 2.576 \frac{\sigma}{\sqrt{n}} < \mu < \bar{x} + 2.576 \frac{\sigma}{\sqrt{n}}$$

2) t-分布による μ の区間推定

$$\bar{x} - t_{n-1}(\alpha) \frac{s}{\sqrt{n}} < \mu < \bar{x} + t_{n-1}(\alpha) \frac{s}{\sqrt{n}}, \quad s = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2}$$

例えば、 $n = 21$ のとき、 $n-1 = 20$ 、t-分布95%値は2.086、99%値は2.845

3) 割合 p の区間推定

n 回の試行で事象 A が x 回起これば、割合の実現値 $\hat{p} = \frac{x}{n}$ 、 $n \rightarrow \infty$ のとき、 \hat{p} は $N(p, pq/n)$ に従うので、95%信頼区間は $\hat{p} \pm 1.96 \sqrt{\frac{pq}{n}}$

$$\hat{p} - 1.96 \sqrt{\frac{pq}{n}} < p < \hat{p} + 1.96 \sqrt{\frac{pq}{n}}, \quad q = 1 - p$$

99%信頼区間の場合は、1.96の代わりに2.576とすればよい。

5. 標本数の決定

1) 比率の場合

母集団の大きさが有限 N であるとき、比率 p の標準偏差 $\sigma_p = \sqrt{\frac{N-n}{N-1} \frac{p(1-p)}{n}}$ より、 p の95%信頼限界は p の代わりに \hat{p} を用いて、 $\hat{p} \pm 1.96 \sqrt{\frac{N-n}{N-1} \frac{\hat{p}(1-\hat{p})}{n}}$ 、従って、母数の推定誤差を d とすれば、 $\hat{p} \pm d$ と書けるので、 $n = \frac{N}{(\frac{d}{1.96})^2 \frac{N-1}{\hat{p}(1-\hat{p})} + 1} \approx \frac{N}{(\frac{d}{1.96})^2 \frac{1}{\hat{p}(1-\hat{p})} + 1}$

例えば、 $d = \hat{p} / 10$ 、即ち、母比率の10%とおくと、 $\hat{p} = 0.3$ なら $d = 0.03$

信頼度99%の場合は、1.96の代わりに2.576とする。 d は精度であるので適当に設定すればよい。

2) 平均値の場合

大きさ N の有限母集団の平均値 \bar{x} の標準偏差は $\sigma_{\bar{x}} = \sqrt{\frac{N-n}{N-1} \frac{\sigma^2}{n}}$ であるから、同様にして $d = 1.96 \sqrt{\frac{N-n}{N-1} \frac{\sigma^2}{n}}$ において、 $n = \frac{N}{(\frac{d}{1.96})^2 \frac{N-1}{\sigma^2} + 1}$

何らかの形で σ の値を推定して、 n を求める。精度 d を小さくすれば、 n は大きくなり、 σ が大きければ、 n も大きくなるのがわかる。

6. 検定

1) 仮説検定 (Test of hypothesis)

仮説検定とは、ある仮説の下で母集団の母数、例えば、母平均 μ 、母分散 σ^2 、母比率 p 等同士の比較あるいは母集団の母数と標本統計量、即ち、標本平均 \bar{x} 、標本分散 s^2 、標本比率 \hat{p} 等と比較し、確率分布による判定を行うことをさす。検定においては、まず、仮説を立て、設定したある確率の下でこの仮説が棄てられるかどうかを判定する。この設定した確率を有意水準または危険率という。

2) 有意水準 (Significant level)

仮説は棄てられることに有意な (偶然に起こったものとは認められない) 意味を積極的に含むものである。その意味で、帰無仮説といい、判定する確率を有意水準とよぶ。危険率という言葉は、この仮説が実は正しいにも拘わらず、誤ってそれを棄てる危険を犯す場合があり、その確率をさす。この誤りを第1種の過誤 (α)、生産者危険率、あわてもの誤りなどという。また、この仮説が実は正しくないにも拘わらず、誤って採用する危険も含んでいる。この誤りを第2種の過誤 (β)、消費者危険率、ぼんやりものの誤りなどという。この2つの誤り α, β は共に小さいことはないが、同時に最小にする方法はない。特に、 β に対する検定法がない。そこで、一般に、 $\alpha = 0.05$ (5%) あるいは 0.01 (1%) に設定した上で、 β を小さくするには標本の大きさ n を大きくする。

3) 両側検定と片側検定 (Two-tailed test, One-tailed test)

この仮説検定において、仮説を否定した場合は何を採用するかが問題になる。これが対立仮説である。例えば、薬効試験の場合、仮説は薬効なしとすれば対立仮説は薬効ありとなる。血圧降下剤試験であれば、薬効ありなら投与後、明らかに血圧は下がっていることになるから、投与前と投与後の母数には大小関係、即ち、母数に関する事前情報があることになる。母数に関する事前情報がない場合は仮説検定が両側検定となり、事前情報がある場合は片側検定が考えられる。

4) 検定手順

仮説検定の手順は次のように行う。

① 仮説 H_0 、対立仮説 H_1 を立てる。

② 仮説の下での標本統計量 z を計算する。

③ 有意水準 (または危険率) 5%に対応する分布値 $z(0.05)$ 、有意水準1%に対応する分布値 $z(0.01)$ を表より決定する。

④ $z < z(0.05)$ なら危険率5%で有意差は認められない。即ち、仮説は棄てられない。

⑤ $z(0.05) \leq z < z(0.01)$ なら危険率5%で有意差ありとする。即ち、仮説は棄却される。

⑥ $z \geq z(0.01)$ なら危険率1%で有意差ありとする。即ち、仮説は棄却される。

7. 分布による仮説検定

1) 平均値の検定 (分散 σ^2 未知, $n \leq 25$ のとき)

① 仮説 $H_0: \mu = \mu_0, H_1: \mu \neq \mu_0$

② 仮説の下では、

$$z = \frac{|\bar{x} - \mu_0|}{\sqrt{\frac{s^2}{n}}} \text{ は標準正規分布 } N(0,1) \text{ に従う。}$$

③ 正規分布 $N(0,1)$ の危険率 5% 点は

$z(0.05) = 1.96, 1\% \text{ 点 } z(0.01) = 2.576$

④ $z < 1.96$ なら危険率 5% で有意差は認められない。

⑤ $1.96 \leq z < 2.576$ なら危険率 5% で有意差あり。

⑥ $2.576 \leq z$ なら危険率 1% で有意差あり。

2) t-検定 (分散 σ^2 未知, $n < 25$ のとき)

① 仮説 $H_0: \mu = \mu_0, H_1: \mu \neq \mu_0$

② 仮説の下では、

$$t_0 = \frac{|\bar{x} - \mu_0|}{\sqrt{\frac{s^2}{n}}} \text{ は自由度 } (n-1) \text{ の } t \text{-分布に従う。}$$

③ 自由度 $(n-1)$ の t-分布表より、

$t_{n-1}(0.05), t_{n-1}(0.01)$ を求める。

④ $t_0 < t_{n-1}(0.05)$ なら危険率 5% で有意差は認められない。

⑤ $t_{n-1}(0.05) \leq t_0 < t_{n-1}(0.01)$ なら危険率 5% で有意差あり。

⑥ $t_{n-1}(0.01) \leq t_0$ なら危険率 1% で有意差あり。

3) 対応のある場合の検定

2つの標本群が同一人の投票前と投票後のようにデータ x_1 と y_1, x_2 と y_2 のように互いに対応関係があるとき、それぞれの差 $z_1 = x_1 - y_1, z_2 = x_2 - y_2, \dots, z_n = x_n - y_n$ をつくる。そして、 z_1, z_2, \dots, z_n について $\bar{z} = \frac{1}{n} \sum z_i, s^2 = \frac{1}{n-1} (\sum z_i^2 - n\bar{z}^2)$ を求める。以下は 2) t-検定を適用する。 ($n \leq 25$ のとき)

4) 2つの割合の差の検定 ($m, n \geq 5, p, q \geq 5$ のとき)

母集団 A: 母比率 p_1, \dots 標本数 m , 割合 \hat{p}_1

母集団 B: 母比率 p_2, \dots 標本数 n , 割合 \hat{p}_2

A, B 全体の母比率 $p = \frac{m\hat{p}_1 + n\hat{p}_2}{m+n}$ で推定する。このとき、

分散 $s^2 = p q (\frac{1}{m} + \frac{1}{n}), p+q=1, p, q \geq 0$ である。

① 仮説 $H_0: p_1 = p_2$, 対立仮説 $H_1: p_1 \neq p_2$

② 仮説の下では、 $z = \frac{|p_1 - p_2|}{\sqrt{p q (\frac{1}{m} + \frac{1}{n})}}$ は標準正規分布 $N(0,1)$ に従う。

③ $z < 1.96$ なら危険率 5% で有意差は認められない。

④ $1.96 \leq z < 2.576$ なら危険率 5% で有意差あり。

⑤ $2.576 \leq z$ なら危険率 1% で有意差あり。

5) 2つの平均値の差の検定 ($n < 25$ のとき)

母集団 A: 母平均 μ_1 , 母分散 σ_1^2, \dots 標本数 m , 平均 \bar{x}_1 , 分散 s_1^2

母集団 B: 母平均 μ_2 , 母分散 σ_2^2, \dots 標本数 n , 平均 \bar{x}_2 , 分散 s_2^2

① 仮説 $H_0: \mu_1 = \mu_2$, 対立仮説 $H_1: \mu_1 \neq \mu_2$

② 仮説の下では、 $\sigma_1^2 = \sigma_2^2$ のとき、

$$t = \frac{|\bar{x}_1 - \bar{x}_2|}{\sqrt{\frac{(m-1)s_1^2 + (n-1)s_2^2}{m+n-2} (\frac{1}{m} + \frac{1}{n})}}$$
 は自由度 $\phi = m+n-2$ の t-分布に従う。

③ 自由度 $m+n-2$ の t-分布表より $t(0.05), t(0.01)$ を求める。

④ $t < t(0.05)$ なら、危険率 5% で有意差は認められない。

⑤ $t(0.05) \leq t < t(0.01)$ なら、危険率 5% で有意差あり。

⑥ $t(0.01) \leq t$ なら、危険率 1% で有意差あり。

6) 独立性の検定 ($H_0: A, B$ 間に関連がない) 独立性の検定

① $k > 2$ の場合

	B_1	B_2	B_3	\dots	B_k	Total
A_1	n_{11}	n_{12}	n_{13}	\dots	n_{1k}	$n_{1.}$
A_2	n_{21}	n_{22}	n_{23}	\dots	n_{2k}	$n_{2.}$
Total	$n_{.1}$	$n_{.2}$	$n_{.3}$	\dots	$n_{.k}$	n

$$\chi^2 = \frac{n^2}{n_{1.}n_{2.}} \left(\frac{n_{11}^2}{n_{1.}n_{.1}} + \frac{n_{12}^2}{n_{1.}n_{.2}} + \frac{n_{13}^2}{n_{1.}n_{.3}} + \dots + \frac{n_{1k}^2}{n_{1.}n_{.k}} - \frac{n_{1.}^2}{n} \right)$$

$> \chi_{k-1}^2(\alpha)$ のとき A, B は独立ではない。

② $k = 2$ の場合

	B_1	B_2	Total
A_1	a	b	g
A_2	c	d	h
Total	e	f	n

$$\chi^2 = \frac{(ad - bc - n/2)^2 n}{efgh}$$

≥ 3.84 なら危険率 5% で有意差あり。
 ≥ 6.63 なら危険率 1% で有意差あり。

E. 相関分析

1. 相関係数 r の検定

1) 標本が1組 ($H_0: \rho = 0$ の場合)

$$r = \frac{S_{xy}}{\sqrt{S_{xx} \cdot S_{yy}}} = \frac{\sum (x - \bar{x})(y - \bar{y})}{\sqrt{\sum (x - \bar{x})^2 \cdot \sum (y - \bar{y})^2}} = \frac{\sum xy - n\bar{x}\bar{y}}{\sqrt{(\sum x^2 - n\bar{x}^2) \cdot (\sum y^2 - n\bar{y}^2)}}$$

$F_0 = \frac{(n-2)r^2}{1-r^2}$ は自由度 $v_1 = 1, v_2 = n-2$ の $F(\alpha)$ 分布に従う。ここに、 α は有意水準 $100\alpha\%$ である。

2) 標本が1組の場合 ($H_0: \rho = \rho_0$ の場合)

2次元正規母集団からの標本とみなす。

① Z変換 $r^* = \frac{1}{2} \ln \frac{1+r}{1-r}, \rho^* = \frac{1}{2} \ln \frac{1+\rho}{1-\rho}$ (\ln は e を底とする自然対数)

② $Z = \sqrt{n-3}(r^* - \rho^*)$ のとき $|Z| \sim N(0,1)$
 即ち、 $|Z| \geq 1.96$ のとき有意水準5%で仮説を棄却する。

③ r の95%信頼限界は

下限値 $r_1^* = r^* - \frac{1.96}{\sqrt{n-3}}$, 上限値 $r_2^* = r^* + \frac{1.96}{\sqrt{n-3}}$ を求め、
 $r_1 = \frac{1}{2} \ln \frac{1+r_1^*}{1-r_1^*}, r_2 = \frac{1}{2} \ln \frac{1+r_2^*}{1-r_2^*}$ を満たす r_1, r_2 を信頼下限、信頼上限とする。

即ち、 $r_1 = \frac{\exp(2r_1^*) - 1}{\exp(2r_1^*) + 1}, r_2 = \frac{\exp(2r_2^*) - 1}{\exp(2r_2^*) + 1}$

3) 標本が2組 ($H_0: \rho_1 = \rho_2$ の場合)

① $r_1^* = \frac{1}{2} \ln \frac{1+r_1}{1-r_1}, r_2^* = \frac{1}{2} \ln \frac{1+r_2}{1-r_2}$ を求める。

② $Z = \frac{r_1^* - r_2^*}{\sqrt{\frac{1}{n_1-3} + \frac{1}{n_2-3}}}$ (n_i は第 i 標本のデータ数, $i=1,2$)

$|Z| \geq 1.96$ なら有意水準5%で仮説を棄却する。即ち、母相関係数 $\rho_1 \neq \rho_2$ とする。あるいは、

$Z^2 = \frac{(r_1^* - r_2^*)^2}{\frac{1}{n_1-3} + \frac{1}{n_2-3}} \sim \chi^2_1(\alpha)$ 即ち、 Z^2 は自由度1の χ^2 分布に従う。

この $Z^2 \geq 3.84 (= 1.96^2)$ なら仮説を棄却する。

4) 標本が k 組 ($H_0: \rho_1 = \rho_2 = \dots = \rho_k$ の場合)



対立仮説 $H_1: \rho_i \neq \rho_j$ ($i \neq j$)

① $r_i^* = \frac{1}{2} \ln \frac{1+r_i}{1-r_i} (i=1,2,\dots,k)$

この χ^2_0 は $\chi^2_{k-1}(\alpha)$ 分布に従う。従って、自由度 $(k-1)$ の χ^2 分布の5%点を $\chi^2_{k-1}(0.05)$ とすると、
 $\chi^2_0 \geq \chi^2_{k-1}(0.05)$ のとき有意水準5%で仮説を棄却する。

② $\chi^2_0 = \sum_{i=1}^k (n_i - 3)r_i^{*2} - \frac{(\sum_{i=1}^k (n_i - 3)r_i^*)^2}{\sum_{i=1}^k (n_i - 3)}$

2. 偏相関係数の検定 (p変数の場合)

1) 偏相関係数 $r_{12.3}$ は変数3の値がすべて同一である個体の切断面内の変数1,2の間の相関である。

$r_{12.3} = \frac{r_{12} - r_{13}r_{23}}{\sqrt{(1-r_{13}^2)(1-r_{23}^2)}} = r$ とおく。

① 仮説 $H_0: \rho_{12.3} = 0$

$t = \frac{r\sqrt{n-3}}{\sqrt{1-r^2}}$ とおくと、 $|t| \geq t(n-3, 0.05)$ なら、5%で仮説を棄却する。
 $t(n-3, 0.05)$ は自由度 $n-3$ の両側5%点である。

注) 変数 x, y, z があって、 y の x に対する回帰式 $y' = a_1 + b_1 x$ を求める。残差 $d_{y1} = y - y'$ ($i=1,2,\dots,n$) が得られる。同様に、 z の x に対する回帰式 $z' = a_2 + b_2 x$ を求める。残差 $d_{z1} = z - z'$ ($j=1,2,\dots,n$) が求められる。残差の組 $(d_{y1}, d_{z1}), (d_{y2}, d_{z2}), \dots, (d_{yn}, d_{zn})$ について、単相関を求める。それを $r_{yz.x}$ で表すのである。

2) 偏相関係数 $r_{12.34}$ (4変数の場合)

$r_{12.34} = \frac{r_{12} - r_{13}r_{23} - r_{14}r_{24}}{\sqrt{(1-r_{34}^2)(1-r_{23.4}^2)}} = r$

$t = \frac{r\sqrt{n-4}}{\sqrt{1-r^2}}$ と置くと、 $|t| \geq t(n-4, 0.05)$ なら有意水準

5%で仮説を棄却する。

即ち、仮説 $H_0: \rho = \rho_{12.34} = 0$ を捨て、 $\rho_{12.34} \neq 0$ とするのである。

3. 平行性検定法

2組のデータ列 $(x_{s1}, x_{s2}, \dots, x_{sn})$ に対する $(y_{s1}, y_{s2}, \dots, y_{sn})$ と $(x_{t1}, x_{t2}, \dots, x_{tm})$ に対する $(y_{t1}, y_{t2}, \dots, y_{tm})$ を考える。2つの回帰直線

$Y_s = \bar{y}_s + b_s(x_s - \bar{x}_s)$
 $Y_t = \bar{y}_t + b_t(x_t - \bar{x}_t)$

結論から述べよう。次の分散分析表を作成する。

要因	SS	df	Ms
R (共有直線性)	S_R	1	V_R
D_p (非平行性)	S_{Dp}	1	V_{Dp}
$R \Sigma$ (全直線性)	$S_{R\Sigma}$	2	$V_{R\Sigma}$
e (残差)	S_e	$n+m-4$	V_e
Y (全体)	S_{yy}	$n+m-2$	-

仮説 H₀ : b_s=b_t (平行である) に対して、

$$F_{cal} = \frac{S_{DP}}{V_s} \sim F_{n+m-4}(\alpha) \text{ 即ち、} F_{cal} \text{ は自由度 } (1, n+m-4) \text{ の F 分布に従う。}$$

これにより、 $F_{cal} \geq F(1, n+m-4; \alpha)$ なら 100α% で仮説を棄却する。

即ち、 $b_s \neq b_t$

とする。2つの直線は平行ではないとする。 $F_{cal} < F(1, n+m-4; \alpha)$ なら平行とはいえない。

$$Y_s = \bar{y}_s + b_s(x_s - \bar{x}_s) \text{ において、} S_{xx_s} = \sum x_{si}^2 - \frac{(\sum x_{si})^2}{n}$$

$$S_{yy_s} = \sum y_{si}^2 - \frac{(\sum y_{si})^2}{n}, \quad S_{xy_s} = \sum x_{si}y_{si} - \frac{(\sum x_{si})(\sum y_{si})}{n}$$

$$b_s = \frac{S_{xy_s}}{S_{xx_s}}, \quad S_{R_s} = \frac{(S_{xy_s})^2}{S_{xx_s}} = b_s \cdot S_{xy_s}, \quad S_{e_s} = S_{yy_s} - S_{R_s} \quad (s \text{ の残差})$$

$$Y_t = \bar{y}_t + b_t(x_t - \bar{x}_t) \text{ についても同様に、} S_{xx_t} = \sum x_{ti}^2 - \frac{(\sum x_{ti})^2}{m}$$

$$S_{yy_t} = \sum y_{ti}^2 - \frac{(\sum y_{ti})^2}{m}, \quad S_{xy_t} = \sum x_{ti}y_{ti} - \frac{(\sum x_{ti})(\sum y_{ti})}{m}$$

$$b_t = \frac{S_{xy_t}}{S_{xx_t}}, \quad S_{R_t} = \frac{(S_{xy_t})^2}{S_{xx_t}} = b_t \cdot S_{xy_t}, \quad S_{e_t} = S_{yy_t} - S_{R_t} \quad (t \text{ の残差})$$

s、t の全体のデータで考える。即ち、s と t をプールする。

$$S_{xx} = S_{xx_s} + S_{xx_t}, \quad S_{yy} = S_{yy_s} + S_{yy_t}, \quad S_{xy} = S_{xy_s} + S_{xy_t}$$

$$b = \frac{S_{xy}}{S_{xx}}, \quad S_R = \frac{(S_{xy})^2}{S_{xx}} = b \cdot S_{xy}$$

$$S_{R\Sigma} = S_{R_s} + S_{R_t}, \quad S_{DP} = S_{R\Sigma} - S_R \quad (\text{非平行性})$$

$$S_{e} = S_{e_s} + S_{e_t} = S_{e_s} + S_{e_t}$$

$$V_e = \frac{S_e}{n+m-4}, \quad V_{DP} = \frac{S_{DP}}{1}, \quad V_{R\Sigma} = \frac{S_{R\Sigma}}{2}$$

F_{cal} で検定したものは、また、

$$t_{cal} = \frac{|b_s - b_t|}{\sqrt{V_s \left(\frac{1}{S_{xx_s}} + \frac{1}{S_{xx_t}} \right)}} \text{ が } t_{n+m-4}(\alpha) \text{ に従うことを利用することと同じになる。}$$

$t_{n+m-4}(\alpha)$ は自由度 $n+m-4$ の t 分布の α 点である。

以上

1998.11.20 & 12.9

統計学演習問題

問題1 小学生 5000人の都市で虫歯保有率 p を標本比率 P で推定するとして、その誤差 d を95%信頼度で5%以下にしたい。何人調査すればよいか？
<ヒント> pが不明であれば、p=0.5として標本の大きさ n を求めればよい。

1) ある地方で小学生 200人を無作為に選び、虫歯調査をしたら 137人が虫歯であった。この地方の小学生の虫歯保有率 p の95%信頼区間を求めよ。

問題2 次表は1985年、F県在住女性について栄養調査を実施し、その時得られた脂質栄養素摂取量(g)のデータである。

年齢	人口	調査数	平均摂取量	標準偏差	比例配分	最適配分
10代	70,000	8	56.9	11.5		
20	167,000	255	51.2	13.5		
30	140,000	1156	49.4	13.4		
40	139,000	1424	47.6	12.4		
50	110,000	1367	44.9	12.8		
60	85,000	532	43.6	12.2		
70	67,000	96	40.5	11.0		
Total	778,000	4838	46.9	13.0	4838	4838

1) 実際の調査では、母平均 μ の95%信頼区間はいくらか？

2) n=4838について、比例配分(Proportional allocation)で各年齢層の調査数を求めよ。

3) n=4838を最適配分(Neyman allocation)で各年齢層の調査数を求めよ。更に、実際の調査数の問題点を批評せよ。

問題3 ある電気メーカーは蛍光灯の新製法を開発した。新製品から25本を無作為に抽出し測定したら、平均寿命1160時間であった。従来の製品仕様書によれば、平均寿命は1130時間、標準偏差80時間であった。新製法によって寿命が延びたといえるか、有意水準5%で検定せよ？

問題4 ある製品の融点がA、B両社で異なるかどうかを調べるため、両社からそれぞれ9個ずつ製品をとって実験したところ次のようであった。この実験結果からA社とB社とでは融点が違うといえるか？ただし、A、B両社の融点の標本偏差はそれぞれ3.4であるとする。

A社	149	147	152	148	149	145	154	156	154
B社	148	149	144	140	139	145	137	151	148

問題5 2種類の薬剤の効果を比較するため、それぞれ10回ずつ実験したところ次のような得点があった。A、B薬剤の効果は同じと考えてよいか有意水準0.05で検定せよ。

A	5	8	7	6	6	7	7	8	5	6
B	7	6	5	4	8	5	5	6	3	4

問題6 次の数値はある製薬工場で錠剤をつくる工程から10分間隔で1粒宛100個の錠剤を抜き出して、その重さを測定して得られたものである。(単位mg)
下の表を完成させ、正規分布の当てはめ、その適合性を検定せよ。

256	254	262	267	261	247	244	245	250	253
237	251	249	250	244	239	260	240	231	251
255	249	253	260	250	259	245	265	254	263
266	256	252	237	250	249	260	247	259	242
259	244	275	251	248	249	258	229	263	255
235	255	259	253	255	239	246	247	243	262
257	241	254	248	241	254	257	270	239	259
267	253	244	242	234	251	270	239	237	245
234	234	260	255	242	266	247	260	256	243
253	242	249	257	251	239	245	236	259	252

階級値 x_i	観測度数 f_i	期待度数 np_i	$(f_i - np_i)^2 / np_i$
229.5			
233.5			
237.5			
241.5			
245.5			
249.5			
253.5			
257.5			
261.5			
265.5			
269.5			
273.5			
計	100	100.0	

問題7 次の資料は、スチール缶再資源化率(y)とアルミ缶再資源化率(z)の年次推移データである。

直線回帰式

$$y = \bar{y} + b_1(x - \bar{x}), \quad z = \bar{z} + b_2(x - \bar{x})$$

を求め、2つの資源率は同じ伸び率にあるとみて見てよいか？即ち、傾き b_1 、 b_2 が同じと見なして良いか検定せよ。

年(19-)x	89	90	91	92	93	94	95	96
y	-	44.8	50.1	56.8	61.0	69.8	73.8	77.3
z	42.5	42.6	43.1	53.8	57.8	61.1	65.7	70.2

問題8 ある地域の婦人54人について栄養調査を実施し、2種の摂取栄養素と血中コレステロール濃度を測定した。年齢(A)、蛋白質(P)、脂肪(F)、血中コレステロール(C)の相互の相関係数は次のとおりである。

蛋白質と脂肪の摂取量の影響を除いた年齢、血中コレステロールの相関はどの程度か？即ち、 $r_{AC \cdot PF}$ はいくらか。	P	A	P	F
	-0.4865			
	-0.5296	0.5784		
	0.4737	-0.4249	-0.3135	

問題9 ある種の降圧剤の一定濃度溶液を等分し、一方をそのまま(S)、他方に酸化剤を加え(T)1か月保存してから、それぞれの降圧作用 $mmHg$ を調べた。用量-反応(D-R)直線は平行しているか？

用量(1/10ml)	$x = \log$ 用量	ys	yt
2	0.301	12	20
3	0.477	17	25
5	0.699	29	38
7	0.845	40	49
10	1.000	44	55
15	1.176	56	66
20	1.301	59	75
30	1.477	72	82
合計	7.276	329	410
平均	0.9095	41.125	51.250

問題1. 次のデータ1~5(n=100)について下の階級値で度数分布表を作成し、棒グラフ(あるいはヒストグラム)をかきなさい。

データ1	データ2	データ3	データ4	データ5
15.26	15.43	15.56	15.44	15.48
15.12	15.29	15.31	15.73	15.41
15.23	15.39	15.51	15.37	15.21
15.34	15.54	15.32	15.43	15.21
15.39	15.81	15.16	15.41	15.70
15.16	15.54	15.48	15.21	15.32
15.25	15.67	15.44	15.46	15.27
15.37	15.21	15.53	15.19	15.30
15.44	15.27	15.28	15.27	15.26
15.39	15.32	15.55	15.34	15.64
15.33	15.39	15.50	15.40	15.57
15.18	15.27	15.31	15.65	15.33
15.47	15.24	15.50	15.20	15.23
15.73	15.60	15.29	15.27	15.33
15.43	15.20	15.40	15.57	15.35
15.46	15.48	15.28	15.61	15.51
15.26	15.14	15.38	15.34	15.29
15.36	15.38	15.31	15.22	15.37
15.52	15.26	15.25	15.23	15.40
15.42	15.32	15.38	15.45	15.36

度数分布表

no	階級下限値	階級上限値	度数
1	15.105	15.155	
2	15.155	15.205	
3	15.205	15.255	
4	15.255	15.305	
5	15.305	15.355	
6	15.355	15.405	
7	15.405	15.455	
8	15.455	15.505	
9	15.505	15.555	
10	15.555	15.605	
11	15.605	15.655	
12	15.655	15.705	
13	15.705	15.755	
14	15.755	15.805	
15	15.805	15.855	
	Total		100

統計演習.xls

統計学演習問題解答例

1998.11.20 / 12.9

問題1

1) 母集団(N)の虫歯保有率(母比率)pの95%信頼区間は2項分布の正規分布近似により、

$$\hat{p} - 1.96 \sqrt{\frac{N-n}{N-1} \cdot \frac{\hat{p}\hat{q}}{n}} < p < \hat{p} + 1.96 \sqrt{\frac{N-n}{N-1} \cdot \frac{\hat{p}\hat{q}}{n}}, \quad \hat{q} = 1 - \hat{p}$$

(無限母集団に対しては、 $\hat{p} - 1.96 \sqrt{\frac{\hat{p}\hat{q}}{n}} < p < \hat{p} + 1.96 \sqrt{\frac{\hat{p}\hat{q}}{n}}$)

誤差 d ≤ 0.05 であるから、

$$d = 1.96 \sqrt{\frac{N-n}{N-1} \cdot \frac{\hat{p}\hat{q}}{n}} \leq 0.05, \quad \text{仮に } \hat{p} = \hat{q} = 0.5 \text{ として, } \frac{N-n}{N-1} \cdot \frac{0.5^2}{n} \leq \left(\frac{0.05}{1.96}\right)^2$$

$$n \geq \frac{N}{\left(\frac{0.05}{1.96}\right)^2 (N-1) + 1} = \frac{1}{\left(\frac{0.05}{1.96 \times 0.5}\right)^2 \left(1 - \frac{1}{N}\right) + \frac{1}{N}} = 356.8, \quad \left(\frac{1}{N} \rightarrow 0 \text{ とすれば, } n \geq 384.2\right)$$

故に、N=5000 のとき、n ≥ 357 例以上調査すればよい。

2) p の 95% 信頼区間は $\hat{p} - 1.96 \sqrt{\frac{\hat{p}\hat{q}}{n}} \leq p \leq \hat{p} + 1.96 \sqrt{\frac{\hat{p}\hat{q}}{n}}$ で与えられる。

$$\hat{p} = \frac{137}{200} = 0.685 \quad \text{であるから,}$$

$$0.685 - 1.96 \sqrt{\frac{0.685 \times 0.315}{200}} \leq p \leq 0.685 + 1.96 \sqrt{\frac{0.685 \times 0.315}{200}}, \quad \therefore 0.621 \leq p \leq 0.749$$

即ち、この地方の小学生の虫歯保有率 p の 95% 信頼区間は 62.1% から 74.9% の間といえる。

問題2

年齢	人口	調査数	平均摂取量	標準偏差	比例配分	最適配分
10代	70,000	8	56.9	11.5	435	396
20	167,000	255	51.2	13.5	1,038	1,109
30	140,000	1,156	49.4	13.4	871	922
40	139,000	1,424	47.6	12.4	864	847
50	110,000	1,367	44.9	12.8	684	692
60	85,000	532	43.6	12.2	529	510
70	67,000	96	40.5	11.0	417	362
Total	778,000	4,838	46.9	13.0	4,838	4,838

1) 母平均 μ の 95% 信頼区間は平均摂取量(標本平均値)を \bar{x} , 標準偏差を σ とすれば

$$\bar{x} - 1.96 \cdot \frac{\sigma}{\sqrt{n}} \leq \mu \leq \bar{x} + 1.96 \cdot \frac{\sigma}{\sqrt{n}}, \quad 46.9 - 1.96 \cdot \frac{13.0}{\sqrt{4838}} \leq \mu \leq 46.9 + 1.96 \cdot \frac{13.0}{\sqrt{4838}}, \quad 46.5 \leq \mu \leq 47.3$$

2) $\rho_i = \frac{N_i}{N} = \frac{n_i}{n}, \quad N = 778,000, N_1 = 70,000, N_2 = 167,000, \dots, N_7 = 67,000$ より

$$n_i = \frac{N_i \times n}{N} \text{ で求めればよい}$$

3) 最適配分の場合は,

$$p_i = \frac{N_i}{N} \text{より, } n_i = \frac{p_i \sigma_i}{p_1 \sigma_1 + p_2 \sigma_2 + \dots + p_k \sigma_k} \cdot n \text{ として求めればよい. } \sigma_1 = 11.5, \sigma_2 = 13.5, \dots$$

問題3

標準偏差 σ が既知であるので、正規分布による検定法 (B¹-3, 7.の1) 参考) を使用する
 仮説は $H_0: \mu = 1130$ である $n = 25, \bar{x} = 1160, \sigma = 80$ より $z = \frac{\bar{x} - \mu_0}{\frac{\sigma}{\sqrt{n}}} = \frac{1160 - 1130}{\frac{80}{\sqrt{25}}} = \frac{30}{\frac{80}{5}} = \frac{30}{16} = 1.875 < 1.96$

故に、仮説は有意水準 5% で棄却され ^{ない} 即ち、新製法によって蛍光灯の平均寿命が延びたとは言えない。

問題4

2つの平均値の差の検定である。9¹-3の5)を参考にするが、この問題は標準偏差がともに既知であるので、正規分布による検定法を用いる。

一般に、
 変数 x が正規分布 $N(\mu, \sigma_1^2)$ に従い、変数 y が同じく $N(\mu_2, \sigma_2^2)$ に従うとき、
 合成変数 $x \pm y$ は正規分布 $N(\mu_1 \pm \mu_2, \sigma_1^2 + \sigma_2^2)$ に従うという性質が分かっている。
 従って、平均値についても変数 $\bar{x} \pm \bar{y}$ は正規分布 $N(\mu_1 \pm \mu_2, \frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2})$ に従う

注) 変数 $x + y$ も $x - y$ も分散は $\sigma_1^2 + \sigma_2^2$ となることに注意する

$$H_0: \mu_1 = \mu_2, \quad z = \frac{|\bar{x}_1 - \bar{y}_1|}{\sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}} = \frac{150.4 - 144.6}{\sqrt{\frac{4^2}{9} + \frac{3^2}{9}}} = 3.48 > 1.96.$$

故に、有意水準 (危険率) 5% で有意差が認められる。即ち、A社とB社とでは製品の融点に差があるといえる。

問題5

この問題では標準偏差が未知であるので、t-分布による平均値の差の検定 (9¹-3の5)) を適用する。

$$m = 10, \bar{x}_1 = 6.5, s_1^2 = \frac{1}{m-1} (\sum x_{1i}^2 - m\bar{x}_1^2) = \frac{1}{9} (433 - 422.5) = \frac{10.5}{9}$$

$$n = 10, \bar{x}_2 = 5.3, s_2^2 = \frac{1}{n-1} (\sum x_{2i}^2 - n\bar{x}_2^2) = \frac{1}{9} (301 - 280.9) = \frac{20.1}{9}$$

$$t = \frac{|\bar{x}_1 - \bar{x}_2|}{\sqrt{\frac{9 \times s_1^2 + 9 \times s_2^2}{m+n-2} (\frac{1}{m} + \frac{1}{n})}} = \frac{1.2}{\sqrt{0.34}} = 2.06 < 2.101 = t_{18}(0.05)$$

ここに、 $t_{\phi}(\alpha)$ は自由度 ϕ , 有意水準 α の t 分布値である。
 故に、有意差は認められない。

即ち、A, B の 2 種類の薬剤の効果は同じと考えられる。

問題6. Excel の関数 NORMDIST(x, 平均値, 標準偏差, TRUE) を用いて正規分布関数の値 (累積確率) を求める。

階級値	観測度数 f_i	累積度数	累積確率	累積期待値	期待度数 np_i	$(f_i - np_i)^2 / np_i$
229.5	2	2	0.02458	2.5	2.5	0.002
233.5	4	6	0.05874	5.9	3.4	
237.5	9	15	0.12225	12.2	6.3	
241.5	9	24	0.22298	22.3	10.1	
245.5	13	37	0.35924	35.9	13.6	
249.5	16	53	0.51642	51.6	15.7	
253.5	16	69	0.67106	67.1	15.5	
257.5	13	82	0.80080	80.1	13.0	
261.5	10	92	0.89365	89.4	9.3	
265.5	5	97	0.95031	95.0	5.6	
269.5	2	99	0.97979	98.0	3.0	
273.5	1	100	1.00000	100.0	1.3	
計	100	100			100.0	1.745

$$\text{全データの平均値 } \bar{x} = \frac{1}{n} \sum x_i = 251.09, \text{ 標準偏差 } s = \sqrt{\frac{1}{n-1} \sum (x_i^2 - n\bar{x}^2)} = 9.9586$$

Excel の分析ツールの基本統計量で求められる。
 検定 H_0 : 理論分布 (この場合、正規分布) に当てはまる (適合度の検定)


$$\chi_0^2 = \sum \frac{(f_i - np_i)^2}{np_i}, \text{ 自由度 } \phi = m - 1 - 2 = 6 \text{ の } \chi^2 \text{ 分布に従う}$$

$\chi_0^2 = 1.745 < \chi_0^2(0.05) = 12.592$, 故に正規分布に適合するという仮説を否定できない。
 即ち、正規分布すると考えられる。
 自由度のうち、3を差し引いたのは、条件が3つあるからである。一つは期待値の合計値を100に合わせたこと、平均値、標準偏差を使用したことによる。

適合度は $P(\chi_0^2 \geq 1.745) = 0.94159$ (94.1%) である。
 注) Excel の関数 CHIDIST(x, 自由度) = p (確率) を使用する。

問題6	Excelで ツール(T)→分析ツールのヒストグラムを使用									
256	254	262	267	261	247	244	245	250	253	
237	251	249	250	244	239	260	240	231	251	
255	249	253	260	250	259	245	265	254	263	
266	256	252	237	250	249	260	247	259	242	
259	244	275	251	248	249	258	229	263	255	
235	255	259	253	255	239	246	247	243	262	
257	241	254	248	241	254	257	270	239	259	
267	253	244	242	234	251	270	239	237	245	
234	234	260	255	242	266	247	260	256	243	
253	242	249	257	251	239	245	236	259	252	

軸	データ区間	頻度	累積%
	227.5	0	0.00%
1	231.5	2	2.00%
2	235.5	4	6.00%
3	239.5	9	15.00%
4	243.5	9	24.00%
5	247.5	13	37.00%
6	251.5	16	53.00%
7	255.5	16	69.00%
8	259.5	13	82.00%
9	263.5	10	92.00%
10	267.5	5	97.00%
11	271.5	2	99.00%
12	275.5	1	100.00%
合計		100	



列1		階級下界	累積度数	逆推定値	累積確率	理論累積数	理論度数
平均	251.09						
標準誤差	0.99585961						
中央値(メジアン)	251.5	231.5	2	230.6376	0.02458	2.5	
最頻値(モード)	259	235.5	6	235.6067	0.05874	5.9	3.4
標準偏差	9.958596104	239.5	15	240.7686	0.12225	12.2	6.3
分散	99.17363636	243.5	24	244.0562	0.22298	22.3	10.1
尖度	-0.599801532	247.5	37	247.7852	0.35924	35.9	13.6
歪度	-0.06320175	251.5	53	251.8396	0.51642	51.6	15.7
範囲	46	255.5	69	256.028	0.67106	67.1	15.5
最小	229	259.5	82	260.2058	0.8008	80.1	13
最大	275	263.5	92	265.0826	0.89365	89.4	9.3
合計	251.09	267.5	97	269.82	0.95031	95	5.6
標本数	100	271.5	99	274.2571	0.97979	98	3
信頼区間(95.0%)	1.976001873	275.5	100	#NUM!	0.99288	99.3	1.3

Sheet1の作図の手順(マウス指示:カーソルを左クリック)

1. 作図

E13

ツールバーからグラフウィザード

縦棒→次へ

データ範囲(D): C15からC26までドラッグ(左クリックを押したまま移動)→系列

名前(N): "錠剤の重さ"と入力

項目軸ラベルに使用(T): B15からB26までドラッグする

凡例 凡例を表示する(S)を空白にする

タイトルとラベル x/項目軸(C): "(単位:mg)"と入力

y/数値軸(V): "(度数)"と入力

データラベル 値を表示する(V): クリックした後完了をクリック

2. 編集作業

図が表示されるので図内にカーソルをおいてドラッグして配置を移動

図中のX軸の下の数値にカーソルを合わせる:右クリック

軸書式設定: フォント: サイズ(S:"6"とLOKをクリック

表示形式 数値小数点以下の桁数(D): "1"

図中のY軸の左の"度数"にカーソルを合わせる:右クリック

軸書式設定: 配置: 方向: 縦文字に合わせてOKをクリック

Sheet1


問題7の解答:		xに対するy(y=ax+b), xに対するz(z=a'x+b') の関係から回帰分析を行う							
dis-parallel	1	2	3	4	5	6	7	8	
x	89	90	91	92	93	94	95	96	
y	0	44.8	50.1	56.8	61.0	69.8	73.8	77.3	
z	42.5	42.6	43.1	53.8	57.8	61.1	65.7	70.2	
xx	7921	8100	8281	8464	8649	8836	9025	9216	
yy		2007.04	2510.01	3226.24	3721	4872.04	5446.44	5975.29	
zz	1806.25	1814.76	1857.61	2894.44	3340.84	3733.21	4316.49	4928.04	
xy	0	4032	4559.1	5225.6	5673	6561.2	7011	7420.8	
xz	3782.5	3834	3922.1	4949.6	5375.4	5743.4	6241.5	6739.2	
yz	0	1908.48	2159.31	3055.84	3525.8	4264.78	4848.66	5426.46	
1)	Ns	7	Nt	8				15	
	mean x	93	mean z	92.5		mean x+x	92.73		
	mean y	61.94286	mean z	54.6		mean y+z	58.03		
	SSx	60571.0	SSx	68492.0		SSx+x	129063.0		
	SSy	27758.06	SSz	24691.64		SSy+z	52449.7		
	SSxy	40482.7	SSxz	40587.7		SSxy+xz	81070.4		
	sxx: Sxxs	28 ①	sxx: Sxxt	42.0 ②		Sx+x	80.2065 ⑩		
	syy: Syyys	899.6371 ③	szz: Syyt	842.4 ④		Syy+Szz	1937.487 ⑨		
	sxy: Sxys	157.9 ⑤	szx: Sxyt	183.7 ⑥		Sxy+xz	353.5715 ⑪		
	bs	5.64 ⑤/①	bt	4.37 ⑥/②		b'	4.41 ⑪/⑩		
	Srs	890.44 ⑦	Srt	803.47 ⑧		SR	1558.64 ⑩=⑨ * ⑪/⑩		
	Ses	9.197 ③-⑦	Set	38.89 ④-⑧		SE	378.846 ⑪		
分散分析表									
2)	要因	SS	df	Ms	F	Sxx	70.0 ⑫=①+②		
	R(共有直線性) ⑬	1667.01	1			Syy	1742.0 ⑬=③+④		
	DP(非平衡性) ⑭-⑮	26.89	1	26.89	6.15	Sxy	341.6 ⑭=⑤+⑥		
	RΣ(全直線性) ⑯	1693.90	2			b	4.88 ⑯/⑫		
	e(残差) ⑰	48.10	11	4.37		Srσ	1693.9 ⑰=⑦+⑧		
	Y(全体) ⑱	1742.00	13			Se	48.087 ⑱=⑰-⑯		
						Se2	75.0 ⑲=⑱-⑯		
						⑩R共線性	1667.008 ⑲ * ⑱/⑲		

問題8の解答:						
	A	P	F		$r(AC \cdot F)$	0.381969
P	-0.4865				$r(AP \cdot F)$	-0.26039
F	-0.5296	0.5784			$r(CP \cdot F)$	-0.31444
C	0.4737	-0.4249	-0.3135		$r(AC \cdot PF)$	0.327422
	$r(AC)$	0.4737	$r(AP)$	-0.4865	$r(CP)$	-0.4249
	$r(AF)$	-0.5296	$r(AF)$	-0.5296	$r(CF)$	-0.3135
	$r(CF)$	-0.3135	$r(PF)$	0.5784	$r(PF)$	0.5784
	$r(AC \cdot F)$	0.381969	$r(AP \cdot F)$	-0.26039	$r(CP \cdot F)$	-0.31444

統計学 Example 1(1998.11.20)

データ 1	データ 2	データ 3	データ 4	データ 5
15.26 D	15.43 G	15.56 J	15.44 G	15.48 H
15.12 A	15.29 D	15.31 E	15.73 M	15.41 G
15.23 C	15.39 F	15.51 I	15.37 F	15.21 C
15.34 E	15.54 I	15.32 E	15.43 G	15.21 C
15.39 F	15.81 P	15.16 B	15.41 G	15.70 L
15.16 B	15.54 I	15.48 H	15.21 C	15.32 E
15.25 C	15.67 L	15.44 G	15.46 H	15.27 D
15.37 F	15.21 C	15.53 I	15.19 B	15.30 D
15.44 G	15.27 D	15.28 D	15.27 D	15.26 D
15.39 F	15.32 E	15.55 I	15.34 E	15.64 K
15.33 E	15.39 F	15.50 H	15.40 F	15.57 J
15.18 B	15.27 D	15.31 E	15.65 K	15.33 E
15.47 H	15.24 C	15.50 H	15.20 B	15.23 C
15.73 M	15.60 J	15.29 D	15.27 D	15.33 E
15.43 G	15.20 B	15.40 F	15.57 J	15.35 E
15.46 H	15.48 H	15.28 D	15.61 K	15.51 I
15.26 D	15.14 A	15.38 F	15.34 E	15.29 D
15.36 F	15.38 F	15.31 E	15.22 C	15.37 F
15.52 G	15.26 D	15.25 C	15.23 C	15.40 F
15.42 G	15.32 E	15.38 F	15.45 G	15.36 F

階級中央値	階級上限値	度数
15.13	15.155	2
15.18	15.205	6
15.23	15.255	11
15.28	15.305	15
15.33	15.355	14
15.38	15.405	15
15.43	15.455	11
15.48	15.505	8
15.53	15.555	6
15.58	15.605	4
15.63	15.655	3
15.68	15.705	2
15.73	15.755	2
15.78	15.805	0
15.83	15.855	1
100	TOTAL	



研究例1 障害児の発達評価に及ぼす療育経験の効果
 ... 2要因分散分析における主効果と交互作用の分析 ...

2 × 3 要因




図1




図2

データファイル作成 → 二要因分散分析の計算
 実際はSPSS, SAS等で処理する

変数	平方和(SS)	自由度(d.f)	平均平方(MS)	E(MS)
要因 A	$\sum E(R_{ij} - R_{i.})^2$	$k-1$	$\frac{\sum E(R_{ij} - R_{i.})^2}{k-1}$	$\frac{\sum E(n_{ij} - n_{i.})^2}{k-1}$
要因 B	$\sum E(X_{ij} - R_{.j})^2$	$n-1$	$\frac{\sum E(X_{ij} - R_{.j})^2}{n-1}$	$\frac{\sum E(n_{ij} - n_{.j})^2}{n-1}$
誤差	$\sum E(X_{ij} - R_{ij})^2$	$(n-1) \times (k-1)$	$\frac{\sum E(X_{ij} - R_{ij})^2}{(n-1)(k-1)}$	$\frac{\sum E(n_{ij} - n_{i.})(n_{ij} - n_{.j})}{(n-1)(k-1)}$
合計	$\sum E(X_{ij} - \bar{X})^2$	$n-1$		

周知の公式を併用するには平方平均を分母として比を計算すればよい。

分散分析表

S.V	S.S	d.f	M.S	F
A 療育者の水準 (3)	12.5920	2	6.2960	1.36 ns
B 障害の程度 (2)	217.9117	1	217.9117	47.21 **
A×B 交互作用	49.4274	2	24.7137	5.35 **
SUB 被験者	470.7770	102	4.6155	
計	750.7081	107		nsP<.10 *p<.05 **P<.01

検定値	解釈	実質中の解釈
p>.10	なし	有意でない
.05<p<.10	*	有意傾向である
p<.05	**	(5%水準で) 有意である
p<.01	***	(1%水準で) 有意である

(注) *pを有意に認むるときは補脚をとりよす。

相互作用の分析表

S.V	S.S	d.f	M.S	F
A at B1	55.9260	2	27.9630	6.06 **
A at B2	6.0934	2	3.0467	0.66 ns
B at A1	10.4832	1	10.4832	2.27 ns
B at A2	85.0956	1	85.0956	18.44 **
B at A3	171.7603	1	171.7603	37.21 **
SUB	470.7770	102	4.6155	
Total	750.7081	107		nsP<.10 *p<.05 **P<.01

研究例2 新生児期における非言語的な母子相互交渉 (ストライク)
 ... 相互相関係数による分析 ...

相関分析の基礎

◆ 2つの変数XとYについて、Xの値が決まればYの値が決まるというわけには行かないが、両者の間に直線的な関連性が認められるとき「XとYの間には相関関係がある」といい、相関関係の程度を示す数値を相関係数(ピアソンの偏置積率相関係数ともいう)という。相関係数は-1から+1の間の値を取る。以下に、体重と身長の関係について、相関係数を求める具体例を示す。





図3



身長	1	2	3	4	5	6	7	8	9	10
A	45	46	47	48	49	50	51	52	53	54
B	46	47	48	49	50	51	52	53	54	55
C	47	48	49	50	51	52	53	54	55	56
D	48	49	50	51	52	53	54	55	56	57
E	49	50	51	52	53	54	55	56	57	58
F	50	51	52	53	54	55	56	57	58	59
G	51	52	53	54	55	56	57	58	59	60
H	52	53	54	55	56	57	58	59	60	61
I	53	54	55	56	57	58	59	60	61	62
J	54	55	56	57	58	59	60	61	62	63
K	55	56	57	58	59	60	61	62	63	64
L	56	57	58	59	60	61	62	63	64	65
M	57	58	59	60	61	62	63	64	65	66
N	58	59	60	61	62	63	64	65	66	67
O	59	60	61	62	63	64	65	66	67	68
P	60	61	62	63	64	65	66	67	68	69
Q	61	62	63	64	65	66	67	68	69	70
R	62	63	64	65	66	67	68	69	70	71
S	63	64	65	66	67	68	69	70	71	72
T	64	65	66	67	68	69	70	71	72	73
U	65	66	67	68	69	70	71	72	73	74
V	66	67	68	69	70	71	72	73	74	75
W	67	68	69	70	71	72	73	74	75	76
X	68	69	70	71	72	73	74	75	76	77
Y	69	70	71	72	73	74	75	76	77	78
Z	70	71	72	73	74	75	76	77	78	79

$n=10, \bar{X} = 5.5, \bar{Y} = 50.5, n-1=9$
 $\sum(X - \bar{X})(Y - \bar{Y}) = 100 + 100 = 200$
 $r = \frac{\sum(X - \bar{X})(Y - \bar{Y})}{\sqrt{\sum(X - \bar{X})^2 \times \sum(Y - \bar{Y})^2}} = \frac{200}{\sqrt{110 \times 164}} = 0.9182$

◆ 相関係数には、単相関係数、偏相関係数、ノンパラメトリックの相関(ファイ係数、独立係数、相関比、順位相関など、いろいろある。
 ◆ ある集団における変数相互の相関関係を推定、または相関関係があるかどうかの検定を行うとき、その集団の一部を調べ結論を導くことがある。これが統計的推定であるが、以下の点に留意すること。

検定値	相関関係の推定	正の相関
-1	強い相関がある	-1
-1	強い相関がある	-1
-1	強い相関がある	-1
-1	強い相関がある	-1
0	相関関係がない	0

研究例 3 共同注意の行動的指標の構造

... 因子分析による検討 ...

	Factor 1	Factor 2	Factor 3	Factor 4	Factor 5
指差し表出 (マント)	.72088	.49878	.16296	-.01956	-.02134
指差し表出 (タクト)	.71253	.59841	.17314	-.06473	-.02429
指差し理解 (視野外)	.67195	.25194	.27132	.05555	.26265
指差し理解 (視野内対象)	.63312	.13239	.26745	.18487	.28929
referential looking (マント)	.64853	.37837	.23929	.28173	-.06464
指差し理解 (視野内方向)	.64441	.17548	.19503	.19189	.45989
referential looking (タクト)	.62539	.40390	.29513	-.27640	-.13820
指差し理解 (応答)	.62481	.32599	.25882	.03512	-.91879
referential looking (応答)	.53101	.21266	.37116	.13783	.05514
視線追従 (視野外)	.51140	.16929	.50666	.06444	.11928
追視 (視野外)	.30861	.23696	.27803	.21792	.29508
showing (応答)	.36555	.71812	.11052	.16192	.22861
showing (自発)	.31180	.70465	.16132	.28355	.17354
giving (応答)	.60511	.60736	.23184	.06852	.10480
giving (自発)	.54478	.57761	.24337	.06397	.12424
アイ・コンタクト	-.02746	-.06806	-.02257	-.01469	.04775
視線追従 (視野内対象)	.35113	.15912	.74130	.13832	.10343
視線追従 (視野内方向)	.28332	.21521	.70876	.14510	.20361
視線指示 (タクト)	.24197	.17567	.08206	.70725	-.04973
視線指示 (マント)	.11159	.08790	.09361	.68419	.09373
指差し理解 (手を見る)	-.09689	.00569	.11434	.35934	.12466
追視 (視野内)	.06942	.03974	.13294	.12232	.30594
高年齢	yo.0	n.6	6.4	4.6	4.3
年齢	yo.0	54.7	64.1	68.1	73.0

全被験者の素点データをもとに、バリマックス回転、主因子法による項目間の因子分析を行った結果、以下のように分類された。

- 第1因子：視覚対象を介した3者関係
(指差しの理解・指差し表出・交互凝視)
...11~19カ月の間に出現
- 第2因子：手に握った知覚的な対象を介した2者関係
(showing・giving)
...11カ月頃出現
- 第3因子：母子の2者関係に見られる視野内の視線追従
(視野内の視線追従)
...9カ月以降に出現
- 第4因子：発達初期に現れ、後に消えていく行動
(視線による指示・指さしたとき手を見る)
...5~11カ月の間に出現

<資料 4>

研究例 4 共同注意の成立時期

... クラスタ分析による検討 ...

予備調査1 外部基準との相関

次に、これらの共同注意行動と標準化された外部基準(遠城寺式発達検査)との相関(table.2)を見ると、出現時期の遅い行動ほど、外部基準との相関が高いことが分かる。これは、出現時期の遅い行動が下降することなく伸びていくのに比して、発達初期に現れる行動は、はじめから過渡率が高かったり、後に衰退していくからである。このことから、table.2の中で外部基準との相関が高い行動が、共同注意行動の発達の指標として妥当であると言えるが、一方で、外部基準との相関の低い初期の行動は、共同注意行動の前提となる行動と見ることが出来る。

table.2 外部基準との相関

	1	2	3	4	5
指差し理解(手を見る)	.61**	.61**	.61**	.61**	.61**
アイ・コンタクト	-.04	-.04	-.02	-.02	-.03
視線追従(マント)	.12**	.12**	.16**	.16**	.12**
視線追従(視野内)	.12**	.12**	.16**	.16**	.12**
視線追従(視野外)	.28**	.27**	.22**	.24**	.30**
視線追従(視野内方向)	.42**	.38**	.43**	.35**	.40**
視線追従(視野内対象)	.50**	.48**	.51**	.44**	.51**
視線追従(視野外方向)	.54**	.51**	.54**	.47**	.54**
showing(応答)	.53**	.51**	.58**	.45**	.55**
showing(自発)	.57**	.52**	.59**	.45**	.57**
giving(応答)	.55**	.52**	.58**	.45**	.57**
指差し理解(視野内)	.57**	.52**	.57**	.46**	.54**
指差し理解(視野外)	.58**	.55**	.58**	.46**	.54**
指差し理解(視野内対象)	.58**	.55**	.58**	.46**	.54**
視線追従(マント)	.55**	.51**	.57**	.47**	.53**
視線追従(視野内)	.55**	.51**	.57**	.47**	.53**
視線追従(視野外)	.56**	.52**	.58**	.47**	.54**
視線追従(視野内方向)	.56**	.52**	.58**	.47**	.54**
視線追従(視野内対象)	.56**	.52**	.58**	.47**	.54**
showing(自発)	.56**	.52**	.58**	.47**	.54**
giving(応答)	.56**	.52**	.58**	.47**	.54**
指差し理解(マント)	.56**	.52**	.58**	.47**	.54**
指差し理解(視野外)	.56**	.52**	.58**	.47**	.54**
指差し理解(視野内)	.56**	.52**	.58**	.47**	.54**
指差し理解(視野内対象)	.56**	.52**	.58**	.47**	.54**
視線追従(マント)	.56**	.52**	.58**	.47**	.54**
視線追従(視野内)	.56**	.52**	.58**	.47**	.54**
視線追従(視野外)	.56**	.52**	.58**	.47**	.54**
視線追従(視野内方向)	.56**	.52**	.58**	.47**	.54**
視線追従(視野内対象)	.56**	.52**	.58**	.47**	.54**

** : p < .01

予備調査2 指差し理解の発達過程




Fig.3 指さしの理解

指差し理解の発達メカニズム

- 1 生態学的メカニズム
(指差した指を見る)
- 2 幾何学的メカニズム
(視野内の方向を見る)
- 3 表象的メカニズム
(視野外の方向をみる)

◆ 因子分析の基本的な考え方

因子分析は、多変量データを集約的に記述し、その相関的構造を明らかにすることを目的とした多変量解析法の一つである。

その考え方は「相関」(correlation)に基づいている。すなわち、相関のある変数どうしはいっしょに動く。一方の値が大きくなれば規則的に他方の値も大きくなる(または小さくなる)という関係にある。ここで、どうしてそれらの変数がそう動くかを考えると、同じ「因子」に支配されているからと考えることができる。こうして変数間の相関関係に基づいて因子を探しにゆく。

◆ 一般的な手続き


A. 質問調査紙の作成と調査の実施

1. 質問項目の開発 (内容の収集、内容の選別、表現のチェック、逆転・ダミー)
2. 評定尺度の作成 (単極尺度か双極尺度か、ポイント数、文か数字)
3. 質問紙の編集 (フェースシート項目、項目の掲載順序、関連質問、謝辞など)
4. 対象者の確保 (項目数の2~5倍、実施期間、回答者の選定)
5. 調査の実施 (インフォームドコンセント、プライバシー保護、回収方法など)

B. 因子分析実行マニュアル

1. データファイルの作成 (回答のチェック、回答の得点化、入力、保存)
2. 基本統計量の計算と不良項目のチェック (ソフト起動、データ読み込み、実行)
3. 1回目の因子分析 (標準得点化、共通性の初期値設定、因子の抽出法、実行)
4. 2回目の因子分析 (因子抽出数と因子軸の回転法設定、実行)
5. 因子の解釈と命名 (所定の因子負荷量以上の項目をマーク、共通性の推定・命名)
6. 因子得点の利用 (因子得点を用いた分散分析、回帰分析、他のデータとの相関)

クラスタ分析の結果：完全連結法を使用した系統図 (デンドログラム)



◆ クラスタ分析とは、対象間の距離にもとづき、それらをいくつかの群(クラスター)に分類する手法。対象の分類基準(外部基準)がない場合の多変量解析法の一つとみなされる。生物学では、クラスタ分析は動物の分類に、医学では、病名とその進行状態を識別する時などに使われる。市場調査でも、類似した購買傾向を持つ人々を識別して、将来の販売戦略の目標をより効果的に定めるために使われる。

◆ 基礎知識および分析の実際は、SPSS (Professional Statistics) 等を参照のこと

ご記入されている方について

(1) 障害を持たれているお子さんと貴方とはどのような間柄にありますか？下の項目から、当てはまるものに○をつけてください。

- () 父親ノ () 母親 ヲ () 兄弟・姉妹ヨ
() 同居している親族 () 同居していない親族 () その他

(2) あなたの年齢をお書きください。 () 歳

お子さんについて

(3) お子さんは現在何歳ですか？ () 歳

(4) お子さんの性別をお答えください。 () 男 () 女

(5) 言語的な理解だけではなく、ジェスチャーや手話、サポート機器を用いても結構ですが、お子さんは対人的なコミュニケーションがどの程度可能ですか。当てはまると思う程度の () に○を付けてお答え下さい。

- () 自分の意志を相手に伝えたり、相手の言葉を理解することに難はない。
() 自分の意志を伝えることはできるが相手の言葉を理解することが難しい。
() 自分の意志を伝えることは難しいが、相手の言葉は理解できる。
() 自分の意志を伝えることも、相手の言葉を理解することもまだ難しい。

(6) あなたの目から見て、お子さんにはどのくらい注意や世話が必要であると思われるか？

- () 常時必要とする。
() 常時ではないが、頻繁に必要。
() 短時間なら目を離せるが、かなり必要。
() 危険な時や気づいた時以外は、あまり必要としない。
() 全然必要としない。

(7) お子さんの障害や問題について、療育手帳や身障者手帳をお持ちの方や、医学的な診断名が出されている場合、差しつかえなければ、その診断名をお答えください。(例：視覚障害、聴覚障害、ダウン症など。特に診断名のない方やご存知ない方は空白のままで結構です。)

()

遊び場所について

(8) 下に挙げる場所のうち、お子さんの主たる遊び場所はどこですか？第1位から第3位まで順位をつけて、数字をご記入ください。

1. 家の中
2. 家の周囲
3. 子どもの友達の家
4. 親戚・知人宅
5. 公園・広場
6. その他(具体的にお書き下さい。)

第1位 場所 ()

第2位 場所 ()

第3位 場所 ()

(9) 上記のような場所でお子さんが遊んでいる時、(遊びに行かせる場合)、あなたはどのようになさっていますか？また、なぜそのようにされるのか、理由がある場合にはどのような理由があるのか、差しつかえがなければ教えてください。

() いつも一緒につきそう(遊ぶ)。
(それは何故ですか？)

() 場所によって付き添う。
(どのような場所ですか？)
(それは何故ですか？)

() いつでも一人で遊びに行かせられる(遊ばせられる)。