

基礎統計シテリ

- 教科書に準じて、問題を解くときに必要なことだけをまとめていきます。

テストは持込不可なので、公式等も覚記が必要です。

- 次のページから本文ですが、第一章はなににも内容のないただのイントロなのでやりません。
第二章からやっています。

[テスト情報]

- 重要語句 (教科書大字で、かつ講義資料で強調されているもの) の穴埋め問題がある可能性あり

- 計算量は少なめにする (データの個数を減らす) 予定。電卓も持込不可。

必ず出る {

- 母分散既知 σ^2 のときの母平均 μ の推定 (100% 信頼区間) $\rightarrow \bar{x} - Z_{1-\alpha/2} \cdot (\sigma/\sqrt{n}) \leq \mu \leq \bar{x} + Z_{1-\alpha/2} \cdot (\sigma/\sqrt{n})$
- 母分散未知 s^2 のときの母平均 μ の推定 (100% 信頼区間) $\rightarrow \bar{x} - t_{1-\alpha/2}(n-1) \cdot (s/\sqrt{n}) \leq \mu \leq \bar{x} + t_{1-\alpha/2}(n-1) \cdot (s/\sqrt{n})$

[注意]

最終的に重要なテーマは

- (正規分布に関する) 推定 $\rightarrow z$ 分布, t 分布, χ^2 分布を利用
- (正規分布に関する) 仮説検定 \rightarrow " "

です。

また、テストは上記の2つに拘る

- 確率 (バイズの定理 or 独立と無相関)

は出題されると予想されます。(あくまで予想です。)

他はあきらめましょう。

ですから、最初の方は、ある程度流し、9~12章を理解するようにして下さい。

9~12をやった、まに見るやうにしたい... と思います。

ただし、9~12章は結構難しいと、私もみりおゆうなかなたで、このシテリもちゃんと
雑さおかりにくりと思います。この辺は、流石 もう一方の素晴らしいシテリを参照して下さい。

一応断っておきますが、本シテリの内容に対して、まちがっても一切責任は負いません。

(by. 2010/17組 会計)

第2章. 1次元のデータ (P17~P40)

* "1次元" とは、データの種類が1種類ということ。例えば、A~Zの文字。

● 度数分布表とヒストグラム (P18~P20)

集められた膨大なデータをある程度のまとまりに分けて表やグラフにすることを目指す。

身長、体重 ⇒ 1次元
身長、体重 ⇒ 2次元 etc.

① P18の表より。

階級の代表値。基本的には、階級の中点の値

表 2.1 試験得点の度数分布表 (某大学の統計学)

全体(=373人)を1として、どれだけの割合でその階級にあるか (度数/全体)

階級	階級値	度数	相対度数	累積度数	累積相対度数
0点以上 10点未満	5	12	0.032	12	0.032
10 " 20 "	15	10	0.027	22	0.059
20 " 30 "	25	19	0.051	41	0.110
30 " 40 "	35	42	0.113	83	0.223
40 " 50 "	45	82	0.193	155	0.416
50 " 60 "	55	82	0.220	237	0.635
60 " 70 "	65	54	0.145	291	0.780
70 " 80 "	75	38	0.102	329	0.882
80 " 90 "	85	25	0.067	354	0.949
90 " 100点以下	95	19	0.051	373	1.000
合計		373	1.000		

観測値をある程度まとめたものにわけて、ここは10点ごとに分けている。

この階級にあるデータの個数

この階級の度数の合計

累積度数 ÷ 全体

試験得点の分布において、つねにこのような整った結果が得られるとはかぎらない。

P19のグラフより




図 2.1 試験得点のヒストグラム
度数分布がこのような形となることはむしろめずらしい。階級数、階級幅などをうまくとらねばならない。

・「階級」「度数」「相対度数」などの意味は、ほぼあきらかだろう。

・「階級の幅はどうするか？」は意外に難しい問題である。(広げるとヒストグラムが変な形になる)

→ 1つの解決策は、スチージェスの公式。

観測値の個数 n のとき、階級の数は



$$k \approx 1 + \log_2 n \quad \leftarrow \text{参考程度}$$

・階級の数を決める際には、階級値がきれいな値になるようにする。

* 度数分布表は、たぶん読めれば十分です。このページは飛ばして下さい。

● ヒストグラムの読みと (P20~26)

○ 単峰型と双峰型



↳ 2種類の異なる条件のグループがまざっているのでは?



(例えば、男性と女性を一緒に考えているなど)

↓ グループ分け [層別] する



2つの単峰型に分けられる。


○ 歪んだ分布



- P26~28. まづ内容「ローレンツ曲線」「測定尺度」は省略する。
余裕のある方は、ご自分ぞ。(範囲外では無く、面倒いからパスするということ)

- “歪んだ分布” に関しては、次の「代表値」のところで多少絡みます。

- 最初や最後の階級を用いている (テストの点数: 0~100 ← としている
所得: 0~1万円 ← としている)
ときは、その部分は点線とてきとうにや



※ ヒストグラムをかき足すことはあまり考えられないので、このページはだいたいでいいでしょう。

← これから「最和の山場」です。難しくはないので、しっかり理解に覚えましょう。

● 代表値 (P28~34)

○ 平均 (算術平均) : mean

ただの平均です。 \bar{x} で表す。観測値のとり値 x_1, x_2, \dots , その度数 f_1, f_2, \dots とする

$$\bar{x} = \frac{f_1 \cdot x_1 + f_2 \cdot x_2 + \dots + f_k \cdot x_k}{f_1 + f_2 + \dots + f_k} \quad (\leftarrow \text{常識})$$

※ 個々のデータがわからないとき (つまり、度数分布表のとき) は、 x_1, x_2 を階級値にすればよい (← 常識)

※ 開いているデータは、 μ とする / だいたいの階級値 x と f などで、かなり適当に対処する。

※ 他にも、幾何平均: $x_G = \sqrt[n]{x_1 \cdot x_2 \cdot \dots \cdot x_n}$

調和 " : $\frac{1}{x_H} = \frac{1}{n} \left(\frac{1}{x_1} + \frac{1}{x_2} + \dots + \frac{1}{x_n} \right)$ など試みる。

○ マedian (中央値) : median

要は、 n 個のデータを小さい順に並べたときの $\frac{n+1}{2}$ 番目のデータの値。

ex. 右の10個の数字: 1, 1, 1, 1, 2, 3, 4, 5, 16, 20 で平均は5.4, マedianは2.5

→ 平均は5.4だが、感覚的には1~2とか、それくらいが代表的な値。

つまり、この場合、平均よりマedianがわかりやすい。

n が偶数の
両側の値の平均

拡張↓

○ パーセンタイル (百分点)

観測値 (← 上のような数字) を、小さい順に並べた。

下から25% のところ ⇒ 第1百分点 Q_1

" 50% " ⇒ 第2 " Q_2 (= マedian)

" 75% " ⇒ 第3 " Q_3

○ モード (最頻値) : mode

要は、いちばん度数が大きいところの値。上の ex ではもちろん1。

● では、右に歪んだ分布では、上の3つの関係はどうなるか。

→ 平均 > マedian > モード。 になる (右に歪んだ分布)

←これも難しいが重要。後R使うことになります。

● 散らばりの尺度 (P35~39)

以下のデータ A, B, C を考える

A: 0, 3, 3, 5, 5, 5, 5, 7, 7, 10

B: 0, 1, 2, 3, 5, 5, 7, 8, 9, 10

C: 3, 4, 4, 5, 5, 5, 5, 6, 6, 7

これらのデータはすべて 平均, モーディアン, モード は 5 である。しかし分布は異なる。

→ 「散らばり」の違いの尺度は、次のようなものがある。

(i) レンジ (range)

分散の存在する範囲という。Aは0~10, Bは0~10, Cは3~7

こんなデータもつかわない。ムシクシ。

(ii) 四分位偏差

$Q = \frac{1}{2}(Q_3 - Q_1)$ つまり、25%ラインと75%ラインの差を2で割ったもの。

0~25%, 75%~100% という両端を除くことで、外れ値 (←異質すぎるデータ上の事例) もし 100 と仮定して、それらは外れ値) の影響を消した。

これもあまりよくない。

(iii) 平均偏差 → 省略。たぶん出ないでしょう。式は $d = \frac{1}{n} \{ |x_1 - \bar{x}| + |x_2 - \bar{x}| + \dots + |x_n - \bar{x}| \}$ 平均偏差

(iv) 標準偏差 と 分散

各観測値が平均からどれだけ離れた状態にあるかを偏差という。

分散は S^2 という記号で表す。

$$S^2 = \frac{1}{n} \{ (x_1 - \bar{x})^2 + (x_2 - \bar{x})^2 + \dots + (x_n - \bar{x})^2 \} = \frac{1}{n} \sum (x_i - \bar{x})^2$$

$$= \frac{1}{n} (x_1^2 + x_2^2 + \dots + x_n^2 - 2\bar{x} \cdot \sum_{i=1}^n x_i + n\bar{x}^2)$$

$$S^2 = \frac{1}{n} (x_1^2 + x_2^2 + \dots + x_n^2) - \bar{x}^2 = (\text{2乗した値の平均}) - (\text{平均の2乗})$$

これらのデータと単位をそろえるため10とすると、標準偏差 S が得る。

$$S = \sqrt{S^2}$$

※ 度数分布表から求めるとき (個々のデータの値がわからないとき) は、平均を求めるときと同様に、1つの階級ではすべて同じ値として求めればよい。

。変動係数

分布の中心の位置が異なるときは、標準偏差をもって分布の散らばりくみえて比較できない。

(∵ 各値が大きければ、標準偏差も大きくなり、たとえ散らばりが小さくても、大きさが直になる)

よって 変動係数 (coefficient of variation) と考える

$$C.V. = \frac{S_x}{\bar{x}} \quad \text{cf. 無次元量}$$

例. 1965年 → 所得平均 $\bar{x} = 26.6$ 万円, 標準偏差 $S = 7.5$ 万円

1975年 → " $\bar{x} = 117.5$ 万円, " $S = 23.8$ 万円

しかし、所得格差はむしろ広がっているわけではない。なぜなら

$$C.V. = 0.28 \rightarrow 0.20 \quad \text{である。}$$

。標準化

データを一次変換して、互いに比べやすくすることと考える。

$$z_i = \frac{x_i - \bar{x}}{S_x}$$

このように一次変換すると、 $\bar{z} = 0$, $S_z = 1$ となる。

平均と標準偏差が揃うので、あとは z の値を比較すればいい。

この変換を標準化という。 z を標準得点という。




ちなみに、 z に対してさらに、 $T_i = 10z_i + 50$ といふ T は、

いわゆる偏差値である。

第3章. 2次元のデータ (P41~66)

● 散布図と分割表 (P41~P47)

2次元のデータは、次のような、 x と y を軸にした散布図を書くのがいい。また、必ず書く。



(i) のように x, y に直線関係がない \rightarrow 相関関係なし。

(ii) " x, y に、一方の増加に伴いもう一方も増加する関係がある \rightarrow 正の相関関係

(iii) " x, y に " , もう一方は減少する " \rightarrow 負の "

しかし、一方が「質的データ」(性別、国籍など) の場合、上のような表がかけない。

おと、下のようなか表を書く。[これは向題になるのはたぶん稀なので、ムシもよい]

	日本人	留学生	合計
修士過程	2415	274	2.689
博士過程	2002	620	2.622
合計	4.417	894	5.311

← この列を 表頭 いう。

↑
この行を 表側 いう。

※ これは、だいたいわかるでしょう。それ以上でも以下でもありません。

● 相関係数 (p48~57)


※ ページの (i) ~ (iii) へはどのようないろいろな相関について。

その相関の強さを数値化するのを下相関係数。 ($-1 \leq r \leq 1$ である。 $|r|$ が大きい程、相関大)

● 相関係数:

$$r_{xy} = \frac{\sum (x_i - \bar{x})(y_i - \bar{y}) / n}{\sqrt{\sum (x_i - \bar{x})^2 / n} \cdot \sqrt{\sum (y_i - \bar{y})^2 / n}} = \frac{\text{共分散}}{\sqrt{x\text{の分散}} \cdot \sqrt{y\text{の分散}}}$$

● 共分散の説明



ある点 (x_i, y_i) について。

$(x_i - \bar{x})(y_i - \bar{y})$ は左のような符号付きの面積。

\bar{x}, \bar{y} によっておかれる4つの部分のうち、対角の2つに

多くの点があつれば、その値は大きくなり、4つの部分に

バラバラに分布する「符号付き」面積なのでうちけしあつて小さくなる。

◎ $r = \frac{\sum x_i y_i - n \bar{x} \bar{y}}{\sqrt{\sum x_i^2 - n \bar{x}^2} \sqrt{\sum y_i^2 - n \bar{y}^2}}$ と表せる。この方が重要

※ 0.7 とあれば、十分な相関がある。

※ r の値のみに頼るのではなく、散布図をみるべき。例えば $y = x \Rightarrow r = 0$ 。しかし、相関は明確にある。

※ r は外れ値の影響を受けやすいので、やはり散布図による異常値がないか check すべき。

外れ値があるときは、適当な層別も可能なことを考える。

○ 偏相関係数

例. x, y, z , 世帯人数 z , 消費 z とする

※ y と m の相関係数 $r_{12} = 0.823 \rightarrow$ 強い正の相関!

(しかし、消費 z の影響を除外した (= 同一の消費量とする) と...

偏相関係数 $\rightarrow r' = -0.714 \rightarrow$ 負の相関! (同じ消費、世帯では収入多 \rightarrow 人数少)

偏相関係数 [変数1と2の相関を、3を除いて考えた場合]

$$r_{12.3} = \frac{r_{12} - r_{13} \cdot r_{23}}{\sqrt{1 - r_{13}^2} \cdot \sqrt{1 - r_{23}^2}}$$

(r_{10}, \dots, r_{20} と z の相関係数)

※ この重要気もしますが、式を覚える必要はないので!

試験では諦めるのも一つの手。命がある人向け。

- 順位相関係数 r_s これも出る可能性はゼロではない、どちらかという
余りのある人向けかも。1つ目はカンタンにやってみただけ
さらっと押さえて次に進んでもいいと思います。

1. スピアマンの順位相関係数 r_s

n のデータとすると、

あるデータ x , y の 2つの指標に基づいて 順位づけられたときの順位を R_i, R'_i とする ($R_i = 1 \sim n$)
(人気調査: x が 男性から 1番好まれ、女性から 3番目に好まれるとき、 $R_i = 1, R'_i = 3$ など)

このとき

$$r_s = \frac{\sum (R_i - \frac{n+1}{2})(R'_i - \frac{n+1}{2})}{\sqrt{\sum (R_i - \frac{n+1}{2})^2} \sqrt{\sum (R'_i - \frac{n+1}{2})^2}} = \dots = 1 - \frac{6}{n^3 - n} \sum_{i=1}^n (R_i - R'_i)^2$$

2. ケンダル τ の順位相関係数 r_k

$$r_k = \frac{G - H}{n(n-1)/2}$$

G : " $R_i > R_j$ かつ $R'_i > R'_j$ " の " $R_i < R_j$ かつ $R'_i < R'_j$ " の数。
つまり、2つの指標で順位の上下が一致する組の数
 H : その逆となる組の数

※ P55 ~ P57: 時系列と自己相関 の内容は省略します。

たぶん出ないと思います。出たら教えてください。やる気のある人はどうぞ。

重要です。


● 回帰直線 (p58~64)

独立変数 x と従属変数 y の間に $y = bx + a$ という直線関係とみてはめることを考える。(= 回帰)

ここでは、その直線 (つり係数 a と b) どう決めるかを学ぶ。

決め方は「最小二乗法」による。

重要!! 「最小二乗法」... 右図の d_1, d_2, \dots, d_n の2乗の和が最小となるように直線を引く



これを a, b と考えると、求める a, b は、

$$L = \sum_{i=1}^n \{y_i - (bx_i + a)\}^2 \quad \text{--- ①}$$

↑ ↑
データ y_i 直線上の y

の L を最小にする a, b を求める。

① 式で a を偏微分して 0 とおくと、

$$na + (\sum x_i)b = \sum y_i \quad \text{--- ②}$$

② 式で b を偏微分して 0 とおくと、

$$(\sum x_i) \cdot a + (\sum x_i^2)b = \sum x_i y_i \quad \text{--- ③}$$

②か③を①と③と、

$$b = \frac{\sum x_i y_i - n \bar{x} \bar{y}}{\sum x_i^2 - n \bar{x}^2}, \quad a = \bar{y} - b \bar{x}$$

$$b = \frac{(\text{共分散})}{(\text{xの2乗和}) - n \times (\text{xの平均の2乗})}$$

$$a = (\text{yの平均}) - b(\text{xの平均})$$

こうして得られた直線を「回帰直線」という。

※ 上式からわかるように、各々のデータがわかれば、 $\sum x_i y_i$, $\sum x_i^2$, \bar{x} , \bar{y} がわかれば直線はひける。

※ λ パーセントはサブリミナルポイントです。最小二乗法... a, b の公式は直線偏微分や ②③ の連立方程式を、自分ですべて導き出すことができればいい。

決定係数

相関と回帰のつながりについて考える。

先程求めた b は

$$b = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum (x_i - \bar{x})^2}}$$

$$\left[\begin{array}{l} \leftarrow \sum (x_i - \bar{x})(y_i - \bar{y}) = \sum x_i y_i - n \cdot \bar{x} \bar{y} \\ \sum (x_i - \bar{x})^2 = \sum x_i^2 - n \cdot \bar{x}^2 \text{ を用いた} \end{array} \right]$$

とも表せる。

∴ 相関係数 $r = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum (x_i - \bar{x})^2} \sqrt{\sum (y_i - \bar{y})^2}}$ \rightarrow 決まるぞ

$$b = r \cdot \frac{\sqrt{\sum (y_i - \bar{y})^2}}{\sqrt{\sum (x_i - \bar{x})^2}} \quad \therefore b = r \cdot \frac{S_y}{S_x}$$

↑
この2つの公式は重要だ。
(公式と変換の両方)
「いいぞ」
P12の練習問題

∴ ∴ 前ページ d_i について

$$L = \sum d_i = \sum \{y_i - (bx_i + a)\}^2$$

$$= (1 - r^2) \cdot \sum (y_i - \bar{y})^2$$

が成り立つ。(計算はよくわかりません。たぶん上手に式変形すればできるんじゃないでしょうか)

つまり、相関係数 r について r^2 が大きい程 L は小さくなる (つまり d_i の和(誤差)も小さい)
この r^2 を 決定係数 といい、直線の当てはまり を表す。

※ P63~64 の内容: 平面の当てはめ、多項式回帰 は省略します。
難しい。面倒なので。出ないと思います。

○ 次のページに、2.3章の復習用の超簡単な練習問題をつけてみました。

いままでの説明は、ぶっちゃけ適当でいいので、それをやりつつ解き方を覚えるようにして下さい。

で、第1回レポート自問自答人はヤルじゃないですか。それっていいじゃないですか。

● 第2章 練習問題

① 10点満点のテストを5人が受けた。結果は下の通り。

2, 2, 5, 10, 3

(1) 平均は?

(2) メディアンは?

(3) モードは?

(4) レンジは?

(5) 分散は?

(6) 標準偏差は?


(5), (6)は有効1桁でよい。

(7) (イミダシ作業ではないけど)

データすべて標準化して同じ1頁に書き並べ、
平均と標準偏差が0と1になることを
確かめよう。
ほぼ

② 次の度数分布表を得た。(あるテスト)

階級	階級値	度数	累積度数
0~20 未満		25	
20~40 未満		15	
40~60 未満		5	
60~80 未満		10	
80~100 未満		5	
合計	—	60	—



(1) 表の空欄を埋めよう。

(3) ヒストグラムを右上に書け。

(2) 平均は?

③ 次の式を示せ。(式変形を確認せよ)

$$(1) \sum (x_i - \bar{x})^2 = \sum x_i^2 - n \cdot \bar{x}^2 \quad [\text{分散}]$$

$$(2) \sum (x_i - \bar{x})(y_i - \bar{y}) = \sum x_i y_i - n \cdot \bar{x} \bar{y} \quad [\text{共分散}]$$

↑

この2式はたいへん有用です。各々のデータの値がわかると

 $\sum x_i^2$ と $n \cdot \bar{x}$ さえもとれば「分散は求めらる」と意味するからです。


● 第3章 練習問題

- ① ある10点満点の2つの試験P, Qを10人の生徒が受験けたところ、下の結果を得た。

生徒No.	1	2	3	4	5	6	7	8	9	10
P試験の点数 x	10	8	4	3	6	1	0	2	5	7
Q " " y	10	9	4	5	8	3	3	4	7	8

次の設問に答えよ

- (1) 右表に点をプロットして散布図をつくれ。
- (2) 相関係数を求めよ
- (3) 決定係数を求めよ
- (4) 回帰直線を求めてグラフに引け。



★ (2) や (4) は、公式とその導き方方法も、第2章練習問題③を利用して考える方法もあります。後者に慣れることをオススメします。

※ や 難。てめえに。

- ② 最小二乗法から、回帰直線の係数 a, b を x や y の式で表現せよ。

- ③ 相関と回帰は、どう違うか説明せよ。

● 第4章 確率 (P67~P86)

※ 基本的な内容については省略し、「条件付確率」のみ扱う。

● 条件付確率 (P81~P83)

ある事象Bが起ったときに、事象Aが起る確率を、Aの条件付確率といい、 $P(A|B)$ と表す。

$$P(A|B) = \frac{P(A \cap B)}{P(B)} \quad \left(= \frac{\text{AもBもあまる確率}}{\text{Bが起る確率}} \right) \quad \leftarrow \text{あたり前の式。}$$

$$\left(\Leftrightarrow P(A|B) \cdot P(B) = P(A \cap B) \right)$$

● ベイズの定理 (P84~P85)

Aという結果に、 H_1, H_2, \dots, H_n という原因が考えられるとき、当然「Aのとき、 H_i である確率」を求めたい。しかし、つうは「 H_i のとき、Aである確率」を求めない。

$$P(H_i|A)$$

$$P(A|H_i)$$

↓

↓ 下の ベイズの定理 により、計算可能

$$\left(\begin{array}{l} \text{結果の原因} \\ \text{確率} \end{array} \right) P(H_i|A) = \frac{P(H_i) \cdot P(A|H_i)}{\sum_j P(H_j) \cdot P(A|H_j)} \quad \left(= \frac{(\text{原因} H_i \text{が起る確率}) \cdot (\text{原因} H_i \text{の下で} A \text{に起る確率})}{\text{上の積を各原因 } H_1 \sim H_n \text{ まで加えたもの}} \right)$$

$$= \frac{P(H_i \cap A)}{\sum_j P(H_j \cap A)} \quad \left(\leftarrow \text{この方が見やすい} \right)$$

※ 例題 1 とだけば、わかると思います。

(問) ← 画記や資料をのます。

ある製品がA社,B社,C社で製造されていて、どの社の製品が見分けがつかないとする。

	A社	B社	C社
市場シェア	50%	30%	20%
不良率	10%	20%	25%

購入した製品が不良品であった。それがA社、B社、C社である確率は？

↓

こんな楽勝ですよ？

ふつうに考えると、「市場全体に不良品がどれくらいあるか」を求めて、

市場全体に A社、B社、C社の不良品がどれだけあるか」を求めると、いいわけです。


そうすれば、 $\frac{B}{A}$ が、求める確率です。これといってるのが、ベイズの定理です。

一応、例題2定理によって解説します。(わかる人は、無視して次へ)

[答え]

まず、市場全体に、どれだけの割合で不良品があるかを考える。(下図参照)

$$P(\text{不良品}) = \underbrace{0.5 \times 0.1}_{\text{Aの不良品がある割合}} + \underbrace{0.3 \times 0.2}_{\text{Bの不良品がある割合}} + \underbrace{0.2 \times 0.25}_{\text{Cの不良品がある割合}} = 0.16 \dots \textcircled{1}$$



では、

A社の不良品である確率は、

$$P(\text{不良品} \cap \text{A社}) = 0.5 \times 0.1 = 0.05 \dots \textcircled{2}$$

①②より、ベイズの定理より、不良品がA社のものである確率は

$$P(\text{A社} | \text{不良品}) = \frac{0.05}{0.16} = \frac{5}{16}$$

同様に

$$P(\text{不良品} \cap \text{B社}) = 0.3 \times 0.2 = 0.06 \quad \text{よって} \quad P(\text{B社} | \text{不良品}) = \frac{0.06}{0.16} = \frac{6}{16}$$

$$P(\text{不良品} \cap \text{C社}) = 0.2 \times 0.25 = 0.05 \quad \text{よって} \quad P(\text{C社} | \text{不良品}) = \frac{0.05}{0.16} = \frac{5}{16}$$

以上より、不良品を見たら、 $\frac{5}{16}$ がA社、 $\frac{6}{16}$ がB社、 $\frac{5}{16}$ がC社なのだ。 //

※ これから先、example 2を用いることが増えるかと思いますが、これは、理論がやや面倒だった! かわりにくくても、実際には特殊な例が多く、それほど難しいことが多くあります。説明がわからなくても、具体例がわかればいいです。そんなもんです。

※ さらに、第4章、このくらいの例題ができればだいじょうぶです。

所詮は統計で使うための確率だし、(でして、この章の練習問題はありません)

● 第5章 確率変数 (187~188)

この章のポイントは、ちょっと教科書とはスタイルを変えてまとめます。

いままでのシナリオともちょっと雰囲気がちがいますが、お気遣いしないで下さい。

ちなみに、数Cの確率に関しては、完璧に理解してる人は、連続型だけならと確認すればOKです。

・ 本章のポイント

- 確率変数には、離散型と連続型がある。離散型は今まで扱ってきたようなもので、連続型は、期待値や分散などはどうなるか、結論から言うと、ほぼ同じになる。

○ まず、「離散」と「連続」について説明する。

・ 離散型の確率変数

例えば、サイコロの出目や人数など、値がとびとびの(自然数)値しかとれないものという。(棒グラフで表すようなもの)

・ 連続型の確率変数

例えば、電池の寿命や地雷のある場所など、実数の値をとるもの(時間とか、距離とか、数直線で表したり、線グラフで表せるもの)

(注)

「確率変数」とは、「 \sim 」がある確率と表現したときの「 \sim 」に ∞ 値のこと。

ちなみに、「A社である」など、数以外


のときは、例えば、A社 $\Rightarrow 1$, B $\Rightarrow 2$...

と対応づけて、変数という。

しかし、連続型については、具体例も使って説明してみる。

たとえば、全くRANDOMに地雷の埋め込まれた道を歩くとする。歩いた距離 x が変数である。

このように、randomな場合、 x 歩いたときに地雷をぶつ確率 $P(x)$ は、図1のような指数減少のグラフになるといわれているらしい。



(図1)

では、この指数関数はどのように表せるだろうか。 $y = A e^{-Bx}$ とおき、 A と B の関係を考えて。

全確率は1であるから、 $\int_0^{\infty} P(x) dx = 1$ である。

これを、

$$\int_0^{\infty} A \cdot e^{-Bx} dx = 1 \Leftrightarrow A \left[-\frac{1}{B} e^{-Bx} \right]_0^{\infty} = 1$$


$$\Leftrightarrow \frac{A}{B} = 1$$

ゆえに、 $A = B$ である。つまり、このとき、 $y = A \cdot e^{-Ax}$ と表せる。

※「歩くほど確率は上がるぞう!」とツッコミたい人は、勘違いしてます。上の文の「確率」は、さきほど歩いた距離に踏む確率で、累積確率にひっかけ。

累積確率 $P(x) = \int_0^x P(x) dx$ 参照。石図。

(x 歩いた距離)



○ 2回、このそれぞれについて、期待値と分散を考えます。

※ 期待値と分散の相加性
定義と意味をやることは
省略します。

・ まず、離散型について

$$E(x) = \sum x \cdot P(x) \quad \leftarrow \text{高校でやった通り}$$

※ 期待値です。これは全問題で使うので(2回)。

では、分散はどうするか。今更にお通しです。プロト No.5 にあるとおり、平均からのズレを考えます。

$$(\text{分散}) = \frac{\sum (x_i - \text{平均})^2}{n}$$

でした。今回の分散の定義は下式

$$V(x) = \sum (x - E(x))^2 \cdot P(x) \\ = E\{(x - E(x))^2\}$$

$P(x)$ という値を x の関数(αという)
と見ておくと、
それは分散(αという)か...
うまく説明できず、
系が得るべきと認めます。

具体例1つあげれば、わかってしまいます。

Ex. 次のような分布を考えたとき、期待値 $E(x)$ と 分散 $V(x)$ を求めよ

x	1	2	3	4	5	6
$P(x)$	$\frac{4}{10}$	$\frac{1}{10}$	$\frac{1}{10}$	$\frac{1}{10}$	$\frac{1}{10}$	$\frac{2}{10}$

$$E(x) = 1 \times \frac{4}{10} + 2 \times \frac{1}{10} + 3 \times \frac{1}{10} + 4 \times \frac{1}{10} + 5 \times \frac{1}{10} + 6 \times \frac{2}{10} = 3$$

$$V(x) = (3-1)^2 \times \frac{4}{10} + (3-2)^2 \times \frac{1}{10} + (3-3)^2 \times \frac{1}{10} + (4-3)^2 \times \frac{1}{10} + (5-3)^2 \times \frac{1}{10} + (6-3)^2 \times \frac{2}{10} = 4$$

※ 比較として... サイコロ振り($P = \frac{1}{6}$ でぜんぶいっしょ)

$$E(x) = 3.5 \text{ (当然)}$$

$$V(x) = \frac{35}{12}$$

... 上の1. はちがひが大きい
(平均は同じでも分散は異なる)

注: 教科書では $P(x)$ を 関数として $f(x)$ と表している。

では、連続型では、どうなるか。

→ Σ は Δ と Δ に代える記号。連続的に代える記号は... \int

7例.

連続型の期待値

$$E(x) = \int_{-\infty}^{\infty} x \cdot f(x) dx$$

* $f(x)$ は、前のページ、確率密度関数です。要は、その値 x での確率です。

連続型の分散

$$V(x) = \int_{-\infty}^{\infty} (x - \mu)^2 \cdot f(x) dx$$


($E(x)$ は定数ですから、これを μ と表す。
これ以後、断らず μ を使う時。)

具体例として、先程の地雷を踏むやつを考えます。

λ があるとき、 $f(x) = \lambda \cdot e^{-\lambda x}$ の確率で地雷を踏むというやつです。

* A が λ に代わると、
とくに意味はないです。

(数) λ が λ なら、 λ が λ なら、
でまはす。



積分範囲は、上の $\int_{-\infty}^{\infty}$ ではなく、

正しくは "定義域内" です。これは $x \geq 0$ です。

期待値は $E(x) = \int_0^{\infty} x \cdot \lambda e^{-\lambda x} dx = \lim_{x \rightarrow \infty} \left[-\left(\frac{1}{\lambda} + x\right) e^{-\lambda x} \right]_0^x = \frac{1}{\lambda}$

分散は $V(x) = \int_0^{\infty} \left(x - \frac{1}{\lambda}\right)^2 \cdot \lambda e^{-\lambda x} dx = \dots = \frac{1}{\lambda^2}$

です。部分積分は、どきどき。

つまり、どうやら $\sqrt{V(x)}$ は標準偏差と... 記号 σ で表します。(分散 σ^2 と書く)

○ 期待値と分散の性質

まず、最も重要なこと。分散を計算するとき、いちいち「各値と期待値、差をとって二乗して…」
とやるやつはほとんどいなくて、実際には、 $\times 2$ の平均 $N=5$ をやったように、 $(2 \text{ 乗の平均}) - (\text{平均の} 2 \text{ 乗})$
のようになっています。今回も同様に、

$$V(x) = E(x^2) - (E(x))^2 \quad (= (2 \text{ 乗の期待値}) - (\text{期待値の} 2 \text{ 乗}))$$

を使います。[証明省略。平均 $N=5$ と同じようにしてできます。教科書 p97 にのっています。]

ex. 上記、平均 $N=17$ の x を、この式でやると...

$$V(x) = \left\{ 1^2 \times \frac{4}{10} + 2^2 \times \frac{1}{10} + 3^2 \times \frac{1}{10} + 4^2 \times \frac{1}{10} + 5^2 \times \frac{1}{10} + 6^2 \times \frac{3}{10} \right\} - 3^2 = 4$$

つまり、期待値の性質について。(ともに、証明略。難しい証明ばかりです。人はぜひ。)

1. $E(ax+b) = a \cdot E(x) + b$ (a, b は定数)
2. $E(x+y) = E(x) + E(y)$ ← 独立性。

つまり、分散の性質について、

1. $V(ax+b) = a^2 \cdot V(x)$ (a, b は定数)
 ↳ この2つから、導かれます。
 $V(a) = 0$, $V(ax) = a^2 \cdot V(x)$
 (1 は、あたりまえですよね。平均がすべて定数なら、バラつきは0です。)
2. $V(x+y) \neq V(x) + V(y)$ ← こんなミスは犯してほしくないの？
 直ぐに訂正してあげます。

また、例によって、 Z のように標準化できます。

$$Z = \frac{x - E(x)}{\sqrt{V(x)}} \quad \text{このとき、必ず} E(Z) = 0, V(Z) = 1$$

※ モーメント、歪度、尖度、チェビシフの不等式は省略します。(できれば、チェビシフの不等式は、覚えておきたい。)
 モーメントはあんまりいいです。

第6章 確率分布 (P109~132)

先の章で学んだ観点から、実際に様々な確率分布モデルについて考える。

(本章では多くの確率分布について取り扱っているが、そのうち大切なものをこのように記す。)

● 離散型の確率分布 ① ~二項分布~ ← 離散型は、とてはコレを押さえること!!

成功の確率を p とし、失敗の確率を $q (=1-p)$ とする1回の試行を n 回行う。

このとき、成功が x 回 (つまり失敗は $n-x$ 回) 起こる確率 $f(x)$ は

$$f(x) = {}^nC_x \cdot p^x \cdot (1-p)^{n-x}$$

← これはあんなに人は、いせんね?
高次元レベルです。

↑
これは
"ベルヌーイ試行" とよぶ

この式による確率分布を、二項分布という。

二項分布の分布のようすは、 $n \cdot p$ の2つのパラメータで決まるので、その関数というくらいの意味で、


二項分布を $Bi(n, p)$ と表す。

(※ ちなみに、 $n=1$ のときは、ベルヌーイ分布とよぶ)

右に例として、2人ごっこ (勝つ確率 $\frac{1}{3}$) を

5回やったときの二項分布 $Bi(5, \frac{1}{3})$ を示す。

(左図が、グラフと表です。)



さて、この二項分布の期待値と分散を求めよう。

→ 証明はやや面倒なので、まず結果を示す

$$E(x) = np, \quad V(x) = npq$$

← 重要!

直観的理解: さて、1回につき p の確率で成功するのなら、 n 回では np 回成功するだろう。

分散は、確率のばらつきを示すので、 $p \cdot q$ の値は $p=q=\frac{1}{2}$ で Max. となり、

成功も失敗も等確率で起こるなら、それが結果もバラバラになりやすい。

(一応証明書はありますが、あんまり気にしないで下さい。)

$$E(x) = \sum_{x=0}^n x \cdot {}^nC_x \cdot p^x \cdot (1-p)^{n-x}$$

$$= np \cdot \sum_{x=0}^n {}^{n-1}C_{x-1} \cdot p^{x-1} \cdot (1-p)^{n-x}$$

$$= np \cdot \left(\sum_{y=0}^{n-1} {}^{n-1}C_y \cdot p^y \cdot (1-p)^{(n-1)-y} \right) \quad (y=x-1)$$

$$= np$$

→ 成功 np 、 y 回のベルヌーイ試行
の確率の総和 \Rightarrow 全確率 1

$$V(x) = E(x^2) - (E(x))^2 \text{ より、} E(x^2) \text{ を求める}$$

$$E(x^2) = \sum_{x=0}^n x^2 \cdot {}^nC_x \cdot p^x \cdot q^{n-x}$$

$$= np \sum_{y=0}^{n-1} (y+1) \cdot {}^{n-1}C_y \cdot p^y \cdot q^{(n-1)-y} \quad (\leftarrow \frac{d}{dz} \text{ と同じ、} y=x-1)$$

$$= np \left\{ \sum_{y=0}^{n-1} y \cdot {}^{n-1}C_y \cdot p^y \cdot q^{(n-1)-y} + \sum_{y=0}^{n-1} {}^{n-1}C_y \cdot p^y \cdot q^{(n-1)-y} \right\}$$

$$= np \left\{ (n-1) \cdot p \cdot \sum_{z=0}^{n-2} {}^{n-2}C_z \cdot p^z \cdot q^{(n-2)-z} + 1 \right\} \quad (\leftarrow z=y-1)$$

$$= np \{ (n-1)p + 1 \}$$

$$\therefore V(x) = np \{ (n-1)p + 1 \} - np^2 = np(1-p) = npq$$

● 離散型の確率分布② ~ ポアソン分布 ~ \Leftarrow 重なりはぐや低い。しかし、一読を薦めます。

二項分布において、 n が大き、 p が小さい。つまり、大量の観察により、稀な現象がある程度確認されるようなとき、二項分布は次のように上手に近似される。

$n \rightarrow \infty, p \rightarrow 0$, かつ $Ex = np \rightarrow \lambda$ (\Leftarrow つまり、期待値 np という性質を保ち、 $n \rightarrow \infty, p \rightarrow 0$ に近づける) の極限をとると。

$$nC_x \cdot p^x (1-p)^{n-x} \rightarrow \frac{e^{-\lambda} \cdot \lambda^x}{x!}$$

このように、


$$f(x) = \sum_x \frac{e^{-\lambda} \lambda^x}{x!}$$

に従う分布で、ポアソン分布という。

ポアソン分布のパラメータは λ のみであり $P_0(\lambda)$ と表す。

ポアソン分布の形は、右に歪んだような形になる ($\because n$ が大き、 p が小さい)

《イメージ図》



ポアソン分布、期待値と分散は次のようになる。

$$Ex = \lambda, \quad V(x) = \lambda$$

証明は、二項分布のときと同じようにやる。はい。

Ex については教科書 P115 上都在ってます。

$V(x)$ は、モーメント母関数というよくある手法で付録にってます。

これは、覚えておく。捨てて下さい。二項分布と、しっかりやるべきです。

● 連続型の確率分布① ~ 正規分布 ~ ← 最重要事項、絶対にマスターする!!


下のような期待値 μ 、分散 σ^2 (標準偏差 σ) を用いた、
確率密度関数による分布を、正規分布という。

$$f(x) = \frac{1}{\sqrt{2\pi} \sigma} \cdot \exp\left\{-\frac{(x-\mu)^2}{2\sigma^2}\right\} \quad (-\infty < x < \infty)$$

※ 周知 a とおいても構いませんが
 $\exp(f(x))$ は $e^{f(x)}$
のことです。

正規分布のパラメータは、^(平均) 期待値 μ 、分散 σ^2 であり、正規分布を $N(\mu, \sigma^2)$ と表す。

正規分布の期待値は μ 、分散は σ^2 である。



正規分布には以下の性質がある。


(a) X が正規分布 $N(\mu, \sigma^2)$ に従うとき、 $Y = aX + b$ は
 $N(a\mu + b, a^2\sigma^2)$ に従う。

※ μ は中心とす
左右対称な分布

(b) 標準化変数 $Z = \frac{X - \mu}{\sigma}$ (このとき、 Z は期待値 0、分散 1) は、
正規分布 $N(0, 1)$ に従う。これを $N(0, 1)$ を標準正規分布という。

※ (a), (b) より、任意の正規分布は、標準正規分布に帰着できる。
これゆえ、標準正規分布の密度関数 $f(z)$ と、累積分布関数 $\Phi(z)$
$$\Phi(z) = \int_{-\infty}^z \frac{1}{\sqrt{2\pi}} \exp(-x^2/2) dx$$

の値が与えられる。(教科書 p280、付表1は、 $1 - \Phi(z)$ と与えている)



(注1) 正規分布は複雑なので、別に自分で積分したいとはほしめん。そのかわりに、

“ $N(\mu, \sigma^2)$ が与えられたら、標準化を行い、 $N(0, 1)$ に帰着させ、付表を用いる” ことをやる。

(注2) あとで例題1つ出すので、そこでなんとかわかるといいます。

(注3) 正規分布に従う行列が多いこと。また、中心極限定理というやつにすると、ランダムな変数行に
ついては何か上手にやると必ず「変数の数が増えるとき正規分布にならっていく」とか、
正規分布の大切さ、一因。他にも、理論的な良さもある、はい。

(注4) 「3シグマ範囲」... $N(\mu, \sigma^2)$ において、 $\mu - 3\sigma \leq x \leq \mu + 3\sigma$ の範囲には、0.9973 の
確率である事象が入ることから、「事実上すべて」といった意味で用いる。

● 連続型の確率分布 ③ ~ 指数分布 ~ ← 重要はそれほどでもない。でもカンタン


これは、もうやりました。最初に連続型を説明したときの例です。

確率密度関数

$$f(x) = \lambda \cdot e^{-\lambda x} \quad (x \geq 0) \quad , \quad 0 \quad (x < 0)$$

(定義域を $-\infty \sim \infty$ にするたの表現)

で定義される確率分布です。



プロット No. 12 で見たように

$$E(x) = \frac{1}{\lambda} \quad , \quad V(x) = \frac{1}{\lambda^2}$$

※ 他の分布は省略。余裕のある人は

- ・ 超幾何分布 (離散型)
- ・ ガンマ分布 (連続型)

あたりをやるでもいいかも。

※ 各分布の E, V は、出せる覚える必要ないかも。

正規分布は、問題演習で理解すること。

● 第7章 多次元の確率分布 (P133~154)

本章、第5章。続きとして、2つの変数 X, Y があるときの
期待値 \times 分散 について考え、独立、無相関 について学ぶ。

で、この章は、本当に適当にやります。ただし、それはこの章が大切ではないとか、
テストに出ないとかじゃなくて、説明が面倒なわりには、結果は単純
であって、1つするからです。
では、始めましょう。

● 2次元の確率分布

2つの四面体 A, B があり、各面は $1 \sim 4$ が書かれている。2つは正四面体ではなく、

$$\begin{cases} A: 1 \rightarrow \frac{3}{10}, 2 \rightarrow \frac{5}{10}, 3 \rightarrow \frac{1}{10}, 4 \rightarrow \frac{1}{10} \\ B: 1 \rightarrow \frac{1}{10}, 2 \rightarrow \frac{2}{10}, 3 \rightarrow \frac{3}{10}, 4 \rightarrow \frac{4}{10} \end{cases}$$

の確率が出るとき、 $A \rightarrow x, B \rightarrow y$ が出る確率 $f(x, y)$ は、下表のようになる。

$B \backslash A$	1	2	3	4
1	0.03	0.05	0.01	0.01
2	0.06	0.10	0.02	0.02
3	0.09	0.15	0.03	0.03
4	0.12	0.20	0.04	0.04

このような $f(x, y)$ の分布を、同時確率分布という。

(とりあえず、こういうふうに2次元の分布があるとわかってほしい)

● 分散と相関係数

第5章で学んだように、分散には加法が成立しない。($V(x+y) \neq V(x) + V(y)$)

では、 $V(x+y)$ はどうなるかという。

$$V(x \pm y) = V(x) + V(y) \pm 2 \cdot \text{Cov}(x, y)$$

$$\text{ただし、} \text{Cov}(x, y) = E\{(x - E(x))(y - E(y))\} : \text{共分散}$$

共分散は、昔々、T.O.と、さんぽにかかっています。期待値は平均と同じようなものですね。

要は、 $(x$ の平均からズレ) \times (y の平均からズレ) の平均です。

[補足] $V(x+y) = V(x) + V(y) + 2\text{Cov}(x, y)$ の証明 (「も同じ」)

$$\begin{aligned} V(x+y) &= E\{(x+y)^2\} - (E(x+y))^2 \\ &= E(x^2 + 2xy + y^2) - (E(x) + E(y))^2 \\ &= E(x^2) - E(x)^2 + E(y^2) - E(y)^2 + 2(E(xy) - E(x)E(y)) \end{aligned}$$

よって、

$$\begin{aligned} E\{(x-E(x))(y-E(y))\} &= E(xy - xE(y) - yE(x) + E(x)E(y)) \\ &= E(xy) - E(y)E(x) - E(x)E(y) + E(x)E(y) \\ &= E(xy) - E(x)E(y) \end{aligned} \quad \left(\begin{array}{l} \leftarrow E(x), E(y) \text{ は定数.} \\ E(\text{定数}) = (\text{その定数}) \end{array} \right)$$

ゆえに、

$$V(x+y) = V(x) + V(y) + 2\text{Cov}(x, y) \quad \blacksquare$$

この証明中の式 $\boxed{\text{Cov}(x, y) = E(xy) - E(x)E(y)}$ は、計算上重要。

● 相関係数と無相関、及び独立。

相関係数 ρ_{xy} は (第3章) 定義したのと同様、次のように定義する

$$\text{相関係数 } \rho_{xy} = \frac{\text{Cov}(x, y)}{\sqrt{V(x)} \cdot \sqrt{V(y)}}$$

($-1 \leq \rho_{xy} \leq 1$, $|\rho_{xy}|$ が大きいと直線関係)

$\rho_{xy} = 0$ となるとき、 x と y が「無相関である」といふ。 ρ は分子 > 0 かつ

$$\rho = 0 \Leftrightarrow \text{Cov}(x, y) = 0 \Leftrightarrow E(xy) = E(x)E(y)$$

すなわち

$$\boxed{x \text{ と } y \text{ が無相関} \Leftrightarrow E(xy) = E(x)E(y) \quad (\Leftrightarrow \rho_{xy} = 0)}$$

一方、独立とは、 x の出方が y には影響せず、 y の出方が x には影響しないことである。

また、確率を勉強するときにもよく使います。たとえば、積の法則 $P(x, y) = P(x) \cdot P(y)$ が成り立つことと同値です。

よって、大切なのは、

$$\boxed{x \text{ と } y \text{ が独立} \Rightarrow E(xy) = E(x)E(y) \quad (\text{逆は不成立})}$$

つまり、

$$\boxed{x \text{ と } y \text{ が独立} \Rightarrow x \text{ と } y \text{ が無相関} \quad (\text{逆は不成立!})}$$

→ 例題 10 に出ていますので、checkして下さい。

※ 独立の数学的定義を飛ばしたのは、僕自身もあんなにわからず。自分で教 P143 と P137 をよく読んで下さい。

※ 第8章は、テスト範囲外(たぶん)なので、やりません。

● 第5,6章 練習問題

① 標準化による期待値(平均)は0, 分散は1になることを示せ。

② 赤玉が20, 白玉が80入っているつぼみ。n回、ボールを引いてはもとに戻す

試行を行う。このときx回赤玉が出る確率を $f(x)$ とする。

(1) この試行は何と呼ばれるか。また、確率密度関数 $f(x)$ を n と x の式で表せ。分布の名称も答えて。

(2) 期待値 $E(x)$ と 分散 $V(x)$ を求めよ。(公式を用いてよい。)

③ 「3シグマ範囲には0.9973の割合が当てはまる」とを示す。

すなわち、 $N(\mu, \sigma^2)$ なる正規分布の $\mu - 3\sigma \leq x \leq \mu + 3\sigma$ の範囲内の累積確率が約0.9973であることを示せ。教科書のp288, 付表1を用いよ。

<hint> まず、標準化し、付表を使えませんか。標準化(たとき、3シグマ範囲はどこからどこまででしょうか?)

④ <教科書p122の(例)>と同じです。

偏差値得点 T は、テストの実際の得点 x を標準化し、(それとする)

すなわち $T = 10x + 50$ としたものである。

(1) T の平均(期待値)と分散を求めよ。

(2) T は正規分布に従うとする。このとき、偏差値75以上の生徒の割合と、

偏差値50以上の生徒の割合を求めよ。付表1を用いよ。

● 第7章 練習問題

① 2つのつぼみ A, B の中に3個のボールをそれぞれ入れる。(入る確率は $\frac{1}{2}$ ずつ。)

このとき、 A に入るボールを X , B に入るボールの数を Y とするとき、 X と Y の同時確率分布を求めよ(←表にする)

X と Y が無相関だが独立でないことを示せ。

(教科書p153の問題7.3と同じ)

● 第9章 標本分布

まず初めに、母集団と標本、違いを説明する。

母集団... その統計の本来対象とする集団全体
標本... 母集団からランダムに選んだサンプル



私達は、母集団から選ばれる標本から、

母集団全体を推定することになる。

本章では、母集団と標本の関係について述べられている。

(ただし、結局はありテストに出る部分に限られている(もうな気を使う)のだ)

それらについてのみ解説する。

● 母集団と標本の平均と分散

平均と分散が重要なのは、

この2つが、正規分布・パラメータであるから。

母集団の平均、分散は、今まで通り

$$\mu = \int_{-\infty}^{\infty} x \cdot f(x) dx \quad \text{まだ定義、今は}$$

一方、標本は n 個、 X_1, X_2, \dots, X_n とあるとき

平均は $\bar{x} = \frac{1}{n} (X_1 + \dots + X_n)$ となり、今まで通りなのだ

標本分散 (s^2 で表す) は、今までは

$$s^2 = \frac{1}{n-1} \{ (X_1 - \bar{x})^2 + (X_2 - \bar{x})^2 + \dots + (X_n - \bar{x})^2 \}$$

となる。

これは、次の「不偏性」を保つための結果である (練習問題参照)

※ 不偏性

$$E(\bar{x}) = \mu, \quad E(s^2) = \sigma^2$$

すなわち、 $\left\{ \begin{array}{l} \text{標本の平均の平均} \\ \text{標本の分散の平均} \end{array} \right\}$ は、 $\left\{ \begin{array}{l} \text{母集団の平均} \\ \text{母集団の分散} \end{array} \right\}$ になること

※ 以後、表記の違いに注意!!

μ, σ^2, σ : 母集団の値

\bar{x}, s^2, s : 標本の値

基本的に、 \bar{x}, s^2 はわかっている。

μ, σ^2 など推定したい値

● パラメトリックとノン・パラメトリック ~ 次章以降のイントロとして読む ~

「母集団が $○○$ 分布に従う」とわかっているとき、その分布のパラメータ (例えば正規分布なら μ, σ , 二項分布なら n, p) がわかれば、全体がわかる。このような状況をパラメトリックという。

そうじゃなくて、母集団の従う分布がわかっていないとき、ノン・パラメトリックという。

今後、77%の問題で、正規分布を仮定する。つまり、パラメトリックを扱う。

その時、標本から母集団について推定したり、母集団に関する仮説を検定したりする。

※この章はあんまりよくわかりません。たぶん大丈夫です。

ただし、下の例題はテストに出そうかと言っていたので、それだけはちゃんと書いておこう。
(「あまのこ」可能性で、絶対出すとは言いませんが)

● 第9章練習問題

シケリ No. 27. a. 不偏分散、不偏性 $E(s^2) = \sigma^2$ を示せ。

この章の先は、

「得られた標本から母集団について推定する」

ことを意識して読んで下さい。

No.

29

Date

第10章 正規分布からの標本

得られた標本が、正規分布からのものであるとすると、比較的簡単に母集団の平均や分散を考慮することが出来る。(→平均と分散がわかれば、正規分布は一意に定まる)

詳しくは次章以降で学ぶので、本章ではいくつかの新定義を統計量として定義(7-1)、その分布を考えたくなる。よくわからなくても、先に進んでもいい。

● 標本平均 \bar{x} はどのような分布に従うか? ~ 母分散が既知のとき ~

標本 x_1, x_2, \dots, x_n が $N(\mu, \sigma^2)$ に従うとき、 \bar{x} はどうなるか。

$\bar{x} = \frac{1}{n}(x_1 + x_2 + \dots + x_n)$ であるので、これも正規分布に従う。

このとき、

$$E(\bar{x}) = \frac{1}{n} E(x_1 + x_2 + \dots + x_n) = \frac{1}{n} \times (n\mu) = \mu$$

$$V(\bar{x}) = \frac{1}{n^2} V(x_1 + x_2 + \dots + x_n) = \frac{1}{n^2} \times (n\sigma^2) = \frac{\sigma^2}{n}$$

である。つまり

\bar{x} は 平均 μ 、分散 $\frac{\sigma^2}{n}$ の正規分布に従う。

そこでこれを標準化した $z = \frac{\bar{x} - \mu}{\sigma/\sqrt{n}}$ は、 $N(0, 1)$ に従う。

※「だから何!？」といたいなら(もう)、 z とくらべて下さい。

これをもとに、「 μ 」を推定することになる。

・標本分散 s^2 と χ^2 乗分布

この部分の説明は難しです。

面倒な割には、理解しても、覚える方が早い。

定義 (χ^2 分布)

z_1, z_2, \dots, z_n は独立で、 $N(0,1)$ に従う変数とすると

$$\chi^2 = z_1^2 + z_2^2 + \dots + z_n^2$$

と定義した χ^2 が従う分布を、自由度 n の χ^2 分布と呼ぶ

そして、実は、 $s^2 = \frac{1}{n-1} \{ (x_1 - \bar{x})^2 + \dots + (x_n - \bar{x})^2 \}$

と χ^2 のように変形したとき

$$\frac{(n-1)s^2}{\sigma^2} = \left(\frac{x_1 - \bar{x}}{\sigma} \right)^2 + \dots + \left(\frac{x_n - \bar{x}}{\sigma} \right)^2$$

この左辺の値は、自由度 $n-1$ の χ^2 分布に従う。

※ これは母分散 σ^2 の推定にかかわる。重要です。

※ 表記法

$z = \frac{\bar{x} - \mu}{\sigma/\sqrt{n}}$ が従う $N(0,1)$ において、その点の上側の確率 α とする点 z_α と表す。

たとえば、その上側は 0.25% しか取れない点 $z_{0.025}$ と表す。

同様に、 χ^2 分布においては、 $\chi^2_\alpha(n)$ と表す。 n は自由度である。

この点 z_α 、教科書の表に記されている。

また t -値を出す。 $t_\alpha(n)$ も同じである。

・標本平均 \bar{x} はどのような分布に従うか? ~ 母分散未知のとき ~

母分散既知のとき $z = \frac{\bar{x} - \mu}{\sigma/\sqrt{n}}$ が $N(0,1)$ に従うことがわかっていて、

σ がわからない状況では、どうするか



→ $s^{(2)}$ を代用する!

定義 (t分布)

$$t = \frac{\bar{x} - \mu}{s/\sqrt{n}} \quad \text{で定義される } t \text{ は、自由度 } n-1 \text{ の } t\text{-分布に従う。}$$

※ $s^{(2)}$ は μ の推定に使います。

◎ 補足 (重要!) 標本平均の差の標本分布 (教科書 P204 ~)

2つの標本平均 \bar{x}, \bar{y} から、2つの母平均の差 $\mu_1 - \mu_2$ を考えるとき、

1. x と y の 2つの場合を考える

(a) 母分散 σ_1^2, σ_2^2 が既知のとき

(b) 母分散 σ_1^2, σ_2^2 が未知な場合 $\sigma_1^2 = \sigma_2^2$ と仮定するとき

(a) のとき

$$z = \frac{(\bar{x} - \bar{y}) - (\mu_1 - \mu_2)}{\sqrt{(\sigma_1^2/n) + (\sigma_2^2/n)}} \quad \text{が } N(0,1) \text{ に従う。}$$

(b) のとき

$$z = \frac{(\bar{x} - \bar{y}) - (\mu_1 - \mu_2)}{\sqrt{(\frac{1}{n} + \frac{1}{n})\sigma^2}} \quad \text{が 自由度 } n+m-2 \text{ の } t\text{-分布に従う}$$

この式を覚える必要はないです。テストに出すなら、どちらを使うかの判断が下せればよいという形式で出さると思います。

◎ 第10~12章は難しいです。本当はとて内容のあるところですが、

でも、シケプリという性質上、本当に最低限のことをやることにしました。

ですから、ここに書いてあることは絶対にマスターして下さい。

◎ P207, 208 の 標本分散の比の標本分布 も、テストに出るかもしれませんが、

もう大変なのでやめます。似た方がいいと思います。

第11章 推定 (区間推定のみ扱う。点推定は、よくわかんないで)

第10章で説明した通り、標本から母集団について推定する。

本章では、3つの区間推定について、マツグーしてほしい。

① 母分散 σ^2 が既知のとき、母平均 μ を推定する

② " 未知 "、"

③ (そもそも) 母分散 σ^2 を推定する。

※ 言葉の定義

例えば、母平均 μ を推定するとき、

95%の確率で μ がふくまれる区間は μ の 95% 信頼区間 となる。

① 母分散 σ^2 が既知のとき、母平均 μ を推定する。(信頼区間を求める)

標本平均 \bar{x} を標準化した Z は、 μ を用いて次のように表せる


$$Z = \frac{\bar{x} - \mu}{\sigma / \sqrt{n}} \quad \text{これは、これは } N(0,1) \text{ に従う。}$$

$N(0,1)$ は、95%の範囲になる α は、対称性より

$$-Z_{0.025} \leq \frac{\bar{x} - \mu}{\sigma / \sqrt{n}} \leq Z_{0.025}$$

μ について解く

$$\bar{x} - Z_{0.025} \left(\frac{\sigma}{\sqrt{n}} \right) \leq \mu \leq \bar{x} + Z_{0.025} \left(\frac{\sigma}{\sqrt{n}} \right)$$



② 母分散 σ^2 が未知のとき、母平均 μ を推定する

Z のかわりに t を用いる。

$$t = \frac{\bar{x} - \mu}{s / \sqrt{n}} \quad \text{は、自由度 } n-1 \text{ の } t \text{ 分布に従う}$$

t 分布も対称性を持ち、95%の範囲は、

$$-t_{0.025}(n-1) \leq \frac{\bar{x} - \mu}{s / \sqrt{n}} \leq t_{0.025}(n-1)$$

μ について解く

$$\bar{x} - t_{0.025}(n-1) \cdot \left(\frac{s}{\sqrt{n}} \right) \leq \mu \leq \bar{x} + t_{0.025}(n-1) \cdot \left(\frac{s}{\sqrt{n}} \right)$$

③ 上の2つは、似ているところがあるから、よくわかんないで。

「※」テストは出題
するよと知らせて
絶対に復習しろ
過程は導きださないと
思われる

③ 母分散を推定す

$\frac{(n-1)s^2}{\sigma^2}$ は χ^2 分布 (自由度 $n-1$) に従うことを利用.

χ^2 分布は対称性ではないので、 χ^2 は $0.025 \sim 0.975$ の範囲を考えると.

$$\chi^2_{0.025}(n-1) \leq \frac{(n-1)s^2}{\sigma^2} \leq \chi^2_{0.975}(n-1)$$

σ^2 は $0 < \sigma^2 < \infty$

$$\frac{(n-1)s^2}{\chi^2_{0.025}(n-1)} \leq \sigma^2 \leq \frac{(n-1)s^2}{\chi^2_{0.975}(n-1)}$$

以上の3つを「集約」して並列に推定します。これを表せば、イキザ「おおよそ」.

(Ex. 1)

座金の製造工場で、ある日に作られた座金の中から100個を抽出してその厚さを

測定したところ、平均 $\bar{x} = 2.346$ (mm) であった。また、この工場で作られた

座金の厚さの分散は既知 $\sigma^2 = (0.047)^2$ (mm²) とおいてよい。

母平均 μ の信頼係数 90% の信頼区間を求めよ。

[Ans]

標本平均 \bar{x} を標準化した z を用いて次のように表す

$$z = \frac{\bar{x} - \mu}{\sigma/\sqrt{n}} \quad \text{これは } N(0,1) \text{ に従う。}$$

$N(0,1)$ で 90% の範囲をとるには、対称性より上下 5% を捨てる

$$-z_{0.05} \leq \frac{\bar{x} - \mu}{\sigma/\sqrt{n}} \leq z_{0.05}$$

付表1より $z_{0.05} = 1.645$, さらに各値を代入して

$$-1.645 \leq \frac{2.346 - \mu}{0.047/\sqrt{100}} \leq 1.645$$

$$\therefore 2.338 \leq \mu \leq 2.354$$

よって、90% 信頼区間は $[2.338, 2.354]$.

(※ 直接、公式に代入してもOK!)

(Ex. 2)

先程の Ex. 1 の対称性を見る。

今回は、母分散はわかっておらず、標本分散 $s^2 = 100$ のサンプルから求めると、 $s^2 = (0.047)^2$ (mm) とおくとする。母平均 μ を推定せよ。(90%信頼区間を)

[Ans.]

$$t = \frac{\bar{x} - \mu}{s/\sqrt{n}} \quad (\text{自由度は } n-1) \quad \text{と考える。}$$

t分布にも対称性があるから(教科書でみてもいい)、上下5%ずつとする。

$$-t_{0.05}(n-1) \leq \frac{\bar{x} - \mu}{s/\sqrt{n}} \leq t_{0.05}(n-1)$$

$$\therefore -t_{0.05}(99) \leq \frac{2.346 - \mu}{0.047/\sqrt{100}} \leq t_{0.05}(99)$$

ここで、 $t_{0.05}(99) = 1.660$ とすると (← 付表 2 とかにのっている数字を使う。)

$$-1.660 \leq \frac{2.346 - \mu}{0.047/\sqrt{100}} \leq 1.660$$

1ポイント

$$\therefore \left[2.346 - 1.660 \times \frac{0.047}{\sqrt{100}}, 2.346 + 1.660 \times \frac{0.047}{\sqrt{100}} \right]$$

(Ex. 3) ある高校の1年生40名がモシをうけると、

($\bar{x} = 55$, $s^2 = 146.4$) だった。モシをうけた全受験生の分散 σ^2 の

95%信頼区間を求めよ。

→ 解答は RepAn 参照のこと

第12章 仮説検定

ある仮説(帰無仮説という) H_0 があるとき、それが正しい(妥当か)を否めて
 決めるにはどうすればよいだろうか。

↓

次のようにする。

1. 何らかの統計量を用いて、自分で決めた妥当性の
 基準(=有意水準という)にあてはまる区間(採択域という)
 を求める。

2. 仮説の下でその統計量を計算し、採択域にあてはまるかを check。

早速、例題をやります。慣れが肝心！

例5 仮説検定①(平均値の検定・母分散既知の場合)

【問題】 あるビール製造工場では、容器が 350ml の缶ビールが最も多く製造されている。
 ところが最近、どうも容量が設定値の 350ml とは異なることが多いとの報告が何回
 かあった。そこで、本当に要領が平均的に 350ml かどうかを検討するために、10
 本の缶ビールをランダムに取って容量を測ったところ、次のようなデータが得られ
 た。(単位: ml)

349.1 348.2 348.1 350.5 350.3 350.1 349.2 348.6 349.5 348.2

このデータから標本平均を計算すると、 $\bar{X} = 349.18$ となる。また、過去の経験から、
 缶ビールの容量の(母)分散は $\sigma^2 = (0.9)^2$ であることが分かっている。この結果か
 ら、「やはり平均的に 350ml ではない」と結論付けてよいだろうか？

確かにそう結論付けても良いように見える。しかし、データのばらつきを考えれば、たまたま
 平均が 350 を下回っただけではないか、と反論することも可能だろう。

仮説は当然 $H_0: \mu = 350\text{ml}$

使う統計量は、 \bar{X} , σ^2 から Z を考える。

$Z = \frac{\bar{X} - \mu}{\sigma/\sqrt{n}}$ がよいだろう。

有意水準を 0.05 とすることによって、

Z の 95% がふくまれる範囲は

$$-Z_{0.025} \leq Z \leq Z_{0.025}$$

付表1より、これは $-1.96 \leq Z \leq 1.96$ ①

↑
 今回の採択域

一方、仮説 $H_0: \mu = 350\text{ml}$ に対して計算すると

$$Z = \frac{349.18 - 350}{0.9/\sqrt{10}} = -2.88$$

この値は ① にふくまれない。つまり、 H_0 が正しい確率は

5% 以下であり、仮説が正しいとはいえない。

(H_0 は、有意水準 5% で棄却された。) ②

① かつ ②、つまり、 0.82ml くらいずれている、10本の平均でこれだけずれている

有意差があるといえる。

次は、母分散が未知の場合です。

さらに、少し悩んでいるのは、「〜が速い/否か」を判断する上で、先の問題ではズレは大小どちらでもよかったけど、今回は、速い方のズレは無視して、片側のみのズレを棄却したいということです。

例6 仮説検定②(平均値の検定・母分散未知の場合)

【問題】 陸上競技の選手である B さんは、100m 走で、平均で 12 秒より速く走れるといつて自慢している。B さんの友達は、このことを確認したかったので、B さんに時間をおいて 9 回走ってもらったところ、以下の記録を得た (単位: 秒)。

11.98 11.99 12.00 12.05 12.05 12.00 11.97 11.98 11.96

このデータの標本平均と標本分散は、それぞれ $\bar{X} = 11.997778$ 、 $s^2 = 0.00104438$ と計算できる。B さんは 100m を平均で 12 秒より速く走ることができると結論できるだろうか? 有意水準を 0.05 とし仮説検定を行いなさい。

B さんのタイムは正規分布に従うと仮定する。

帰無仮説 $H_0: \mu = 12$

対立仮説 $H_1: \mu < 12$

とする。(棄却すれば、12 秒より速いといえる)

このとき、 H_0 もとめて計算する

$$t = \frac{11.997778 - 12}{\sqrt{0.00104438} / \sqrt{9}} \approx -0.206$$

母分散が未知なので、t 検定

$$t = \frac{\bar{X} - \mu}{s / \sqrt{n}} \quad (\text{自由度 } n-1)$$

を用いる。

これは①にふくまれない。

つまり、

B さんは平均で 12 秒より速く走れるとは限りません。

今回の採択域は、

$$-t_{0.05}(8) < t < \infty$$

である。(5%で下側だけ棄却)

↑速いほう

$$t_{0.05}(8) = 1.86 \quad (\text{t 表より})$$

より

$$-1.86 < t \quad \dots \textcircled{1}$$

が採択域である。

これが解説です。

⑩ 第10章～12章 練習問題

① 母平均 $\mu_1 = 2$, 母分散 $\sigma_1^2 = 3$ の正規母集団から大きさ $m = 10$ の標本を、

母平均 $\mu_2 = 5$, 母分散 $\sigma_2^2 = 4$ の " から大きさ $n = 8$ の標本を

抽出する。二つの標本平均の差 $\Delta = \bar{X} - \bar{Y}$ は、どのような分布をとるか?

② 母分散 $\sigma^2 = 3$ である正規母集団から 9 個の標本をとり出したとき、

この標本の平均は $\bar{X} = 2$ であった。母平均 μ の 95% 信頼区間を求めよ。

(また、 $\bar{X} = 2$ かつ、6 個の標本による値だったとして、同じ μ の 95% 信頼区間を求めよ)

③ ある正規母集団から 9 個のサンプルをとり出した。

このサンプルについて、標本平均 $\bar{X} = 30$, 標本分散 $S^2 = 4$ を計算により得たとするとき

母平均の 95% 信頼区間を求めよ

④ ある正規母集団からの 10 個のサンプルについて、 $S^2 = 6$ があった。

母分散の 95% 信頼区間を求めよ

⑤ もう一度、シタリ No. 33-34 の Qx を復習して下さい。

⑥ ある教授が教室に来る時間について、開始時刻からのズレを遅れは +、早め来ると - と表した。下の表がある。

$\{-3, 0, -1, +2, 0, +4, +2, +6, 0, -1, +2, -1, +3\}$

この教授が定刻に来るという帰無仮説 $H_0: \mu = 0$ を有意水準 5% で

検定せよ。(ただし、対立仮説は $H_1: \mu \neq 0$ とし、両側検定にせよ)

⑦ 正規母集団について母分散 $\sigma^2 = 4$ がわかっている。このとき

25 個のサンプルをとったとき、標本平均 $\bar{X} = 14.6$ を得た。

このとき、母平均 $\mu = 15.0$ といえるか? どうか?

$H_0: \mu = 15.0$ を有意水準 5% で検定せよ。(両側検定でよい)

● 第2章練習問題の答え

①

(1) $\bar{x} = \frac{2+2+5+10+3}{5} = 4.4$

(2) 中央値は 3(3) 最頻値は 2

(4) $L \geq 3$ は $10-2 = 8$

(7) 標準化の公式

$$Z_i = \frac{x_i - \bar{x}}{s} \quad z \text{ 利用。}$$

与えられたデータは

$$-0.8, -0.8, 0.2, 1.86, -0.46$$

1:723.50ととき

$$\bar{z} = \frac{-0.8-0.8+0.2+1.86-0.46}{5} = 0$$

$$S_z = \sqrt{S_z^2}$$

$$= \sqrt{\frac{(-0.8)^2 + \dots + (-0.46)^2}{5} - 0^2}$$

$$= \sqrt{\frac{0.64+0.64+0.4+3.46+0.21}{5}}$$

$$= \sqrt{1.07} \approx 1$$

(5) [解1] P5 の上の式に代入

$$\begin{aligned} S^2 &= \frac{1}{5} \times \left\{ (2-4.4)^2 + (2-4.4)^2 + (5-4.4)^2 + (10-4.4)^2 + (3-4.4)^2 \right\} \\ &= \frac{1}{5} \times (5.76 + 5.76 + 0.36 + 31.36 + 1.96) \\ &= 9.04 \end{aligned}$$

[解2] P5 の下の式

$$S^2 = \frac{2^2 + 2^2 + 5^2 + 10^2 + 3^2}{5} - (4.4)^2$$

$$= 28.4 - 19.36$$

$$= 9.04 \quad \therefore S^2 = 9 \quad \leftarrow \text{断然ラ7。}$$

(6) 中値:

$$S = \sqrt{9.04} \approx 3$$

(本来の南数電卓や開平法を使うべきか?)


②

(1) 階級値はその階級の平均値。上から順に 10, 30, 50, 70, 90


累積度数は、その階級の度数の和。上から順に 25, 40, 45, 55, 60

$$(2) \bar{x} = \frac{10 \times 25 + 30 \times 15 + 50 \times 5 + 70 \times 10 + 90 \times 5}{60} = 35$$

(3)



。双峰型なので、層別を考えた方がいいところですね。たとえば、男女を層別に。



分けたら、それぞれ適切な分け方といえます。(他にもいろいろ、わけ方はあるでしょうが)

3

$$(1) \sum (x_i - \bar{x})^2 = \sum (x_i^2 - 2\bar{x} \cdot x_i + \bar{x}^2)$$

↑
定数

$$= \sum x_i^2 - 2\bar{x}(\sum x_i) + \bar{x}^2(\sum 1)$$

$$= \sum x_i^2 - 2\bar{x} \cdot n\bar{x} + \bar{x}^2 \cdot n \quad \left(\because \sum x_i \text{ は } n \text{ 個の要素の和, } \bar{x} \text{ は平均の定義より, } \bar{x} = \frac{\text{平均} \times \text{個数}}{n} \right)$$

$$= \sum x_i^2 - n \cdot \bar{x}^2$$

$$(2) \sum (x_i - \bar{x})(y_i - \bar{y}) = \sum (x_i y_i - \bar{x} \cdot y_i - \bar{y} \cdot x_i + \bar{x} \bar{y})$$

$$= \sum x_i y_i - \bar{x} \cdot \sum y_i - \bar{y} \cdot \sum x_i + \bar{x} \bar{y} \cdot \sum 1$$


$$= \sum x_i y_i - \bar{x} \cdot n\bar{y} - \bar{y} \cdot n\bar{x} + \bar{x} \bar{y} \cdot n$$

$$= \sum x_i y_i - n \cdot \bar{x} \bar{y}$$

●第3章練習問題の答え

1

(1), (4) 97.57



(4)

回帰直線: $y = a + bx$ とすると、

$$b = \frac{\sum xy - n\bar{x}\bar{y}}{\sum x^2 - n\bar{x}^2}, \quad a = \bar{y} - b\bar{x}$$

よって

$$b = \frac{353 - 10 \times 4.6 \times 6.1}{304 - 10 \times (4.6)^2} = 0.783 \dots$$

$$\therefore a = 6.1 - 0.78 \times 4.6 = 2.512$$

$$\text{ゆえに、回帰直線は } y = 0.78x + 2.51$$

(2)

$$r = \frac{\sum xy - n\bar{x}\bar{y}}{\sqrt{\sum x^2 - n\bar{x}^2} \cdot \sqrt{\sum y^2 - n\bar{y}^2}}$$

よって

$$\sum xy = 100 + 72 + 16 + 15 + 48 + 3 + 0 + 8 + 35 + 56$$

$$\therefore \sum xy = 353$$

$$\bar{x} = (10 + 8 + 4 + 3 + 6 + 1 + 0 + 2 + 5 + 7) \div 10$$

$$\therefore \bar{x} = 4.6$$

$$\bar{y} = (10 + 9 + 4 + 5 + 8 + 3 + 3 + 4 + 7 + 8) \div 10$$

$$\therefore \bar{y} = 6.1$$

$$\sum x^2 = 100 + 64 + 16 + 9 + 36 + 1 + 0 + 4 + 25 + 49$$

$$\therefore \sum x^2 = 304$$

$$\sum y^2 = 100 + 81 + 16 + 25 + 64 + 9 + 9 + 16 + 49 + 64$$

$$\therefore \sum y^2 = 433$$

よって

$$r = \frac{353 - 10 \times 4.6 \times 6.1}{\sqrt{304 - 10 \times 4.6^2} \cdot \sqrt{433 - 10 \times 6.1^2}} \approx 0.9651 \dots$$

(3) よって、決定係数は

$$r^2 \approx 0.931 \dots$$

2 解答省略。プリント No. 10 を参照。

(②から③までは、a, b の連立方程式なので、中2レベル)

3

(たぶん) 回帰は、一方が他方の原因であるという関係を指し、

相関は、因果がどちらからどちらにあるかよく判別できない(すなわち、ともに影響しあうような関係も含む) ような2つの変数の関係。

● 第5.6章練習問題の答え

- ① もとのデータの期待値を μ , 分散を σ^2 とする。このデータ x を標準化する。

$$z = \frac{x - \mu}{\sigma}$$

この新しい z には、期待値と分散を定義に従って求める。

(もとの x の期待値 μ と分散 σ^2 は定数であることを注意する。)

$$E(z) = E\left(\frac{x - \mu}{\sigma}\right)$$

$$= \frac{E(x) - \mu}{\sigma} \quad (\because E(ax+b) = aE(x) + b)$$

$$= 0 \quad (\because E(x) = \mu)$$

$$\text{また, } V(z) = V\left(\frac{x - \mu}{\sigma}\right)$$

$$= \frac{V(x)}{\sigma^2} \quad (\because V(ax+b) = a^2 V(x))$$

$$= 1 \quad (\because V(x) = \sigma^2)$$

この2つも、証明可能。

[補足]

(1) $E(ax+b) = a \cdot E(x) + b$ の証明

$$\begin{aligned} E(ax+b) &= \frac{1}{n} \sum_{i=1}^n (ax_i + b) \\ &= \frac{1}{n} (a \sum_{i=1}^n x_i + nb) \\ &= a \cdot E(x) + b \end{aligned}$$

(2) $V(ax+b) = a^2 \cdot V(x)$ の証明

$$\begin{aligned} V(ax+b) &= E\{(ax+b)^2\} - (E(ax+b))^2 \\ &= E(a^2x^2 + 2abx + b^2) - (aE(x) + b)^2 \\ &= a^2E(x^2) + 2abE(x) + b^2 \\ &\quad - a^2(E(x))^2 - 2abE(x) - b^2 \\ &= a^2[E(x^2) - \{E(x)\}^2] \\ &= a^2 \cdot V(x) \end{aligned}$$

② (1) このような試行をバリエーイ試行という。

n 回 X を 2 回 赤が出る確率は

$$f(x) = {}_n C_x \cdot \left(\frac{2}{10}\right)^x \cdot \left(\frac{8}{10}\right)^{n-x}$$

この分布は $X \sim$ 二項分布という

(2) 公式より

$$E(x) = \frac{1}{5}n$$

$$V(x) = \frac{4}{25}n$$

③ $N(\mu, \sigma^2)$ の標準正規分布を標準化すると $N(0, 1)$

となり、このとき $z = \frac{x - \mu}{\sigma}$ である。

$$\mu - 3\sigma \leq x \leq \mu + 3\sigma$$

$$\therefore \mu - 3\sigma \leq \sigma z + \mu \leq \mu + 3\sigma$$

$$\therefore -3 \leq z \leq 3$$

ゆえに、標準正規分布で $-3 \leq z \leq 3$ となる部分の確率は、

$$\text{教科書の表より } 1 - 2 \times 0.0043499 = 0.9913002$$

④ (1) Z の平均 (期待値) は 0、分散は 1 である。

$$E(10Z + 50) = 10 \cdot E(Z) + 50$$

$$= 50$$

$$V(10Z + 50) = 10^2 \cdot V(Z)$$

$$= 100$$

(2) 偏差値 75 以上

$$T \geq 75 \Leftrightarrow Z \geq 2.5$$

$$N(0, 1) \text{ で } Z = 2.5 \text{ となる確率は } 0.0062097 \text{ (0.6\%)} \\ \text{偏差値 50 以上 51 未満}$$

$\Leftrightarrow 0 \leq Z \leq 0.1$

$$\Leftrightarrow 0 \leq Z \leq 0.1$$

$$N(0, 1) \text{ で } Z \geq 0.1 \text{ となる確率は } 0.46017$$

$$Z \geq 0$$

$$0.5$$

$$\text{よって } 0.5 - 0.46017 = 0.03983 \text{ (4\%)} \\ \text{よって } 0.5 - 0.46017 = 0.03983 \text{ (4\%)}$$

● 第7章 練習問題の答え

①

同時確率分布 $f(x, y)$ は

$Y \backslash X$	0	1	2	3
$f(x, y)$				
1	$\frac{1}{8}$	0	0	$\frac{1}{8}$
2	0	$\frac{3}{8}$	$\frac{3}{8}$	0

上の表のようにする。

まず、無相関であることを

$$E(XY) = 0 \times \frac{1}{8} + 1 \times 0 + 2 \times \frac{3}{8} + 3 \times \frac{1}{8} + 4 \times \frac{3}{8} + 6 \times 0 = \frac{21}{8}$$

$$\text{つまり、} E(X) = 0 \times \frac{1}{8} + 1 \times \frac{3}{8} + 2 \times \frac{3}{8} + 3 \times \frac{1}{8} = \frac{12}{8}$$

$$E(Y) = 1 \times \frac{2}{8} + 2 \times \frac{6}{8} = \frac{14}{8}$$

$$\therefore \text{よって } \text{Cov}(X, Y) = \frac{21}{8} - \frac{12}{8} \times \frac{14}{8} = 0 \quad \therefore \text{無相関である}$$

● 第8章 練習問題の答え

まず、

何故、標本分散は n ではなく $n-1$ で割るのか、それは、標本分散の期待値が、母集団の分散になるためです。

$$\text{つまり、} S^2 = \frac{1}{n-1} \{ (x_1 - \bar{x})^2 + \dots + (x_n - \bar{x})^2 \} \quad \text{としたとき、} E(S^2) = \sigma^2 \quad \text{であることを示す。}$$

$$\hookrightarrow \sum_{i=1}^n (x_i - \bar{x})^2$$

(proof)

$$\begin{aligned} \sum_{i=1}^n (x_i - \bar{x})^2 &= \sum_{i=1}^n \{ (x_i - \mu) - (\bar{x} - \mu) \}^2 \\ &= \sum_{i=1}^n (x_i - \mu)^2 - 2(\bar{x} - \mu) \sum_{i=1}^n (x_i - \mu) + n(\bar{x} - \mu)^2 \\ &= \sum_{i=1}^n (x_i - \mu)^2 - n(\bar{x} - \mu)^2 \end{aligned}$$

$$\therefore E(S^2) = \frac{1}{n-1} \left\{ E \left\{ \sum_{i=1}^n (x_i - \mu)^2 \right\} - n E \{ (\bar{x} - \mu)^2 \} \right\}$$

$$= \frac{1}{n-1} \left\{ \sum_{i=1}^n E \{ (x_i - \mu)^2 \} - n \cdot \frac{1}{n^2} \cdot E \{ (x_i - \mu)^2 \} \right\}$$

$$= \frac{1}{n-1} (n\sigma^2 - \sigma^2) \quad \leftarrow E \{ (x_i - \mu)^2 \} = n \cdot \sigma^2$$

$$= \sigma^2$$

一方、独立性は、

たいてい

$$P(X=3, Y=1) = \frac{1}{8}$$

つまり

$$P(X=3) = \frac{1}{8}, \quad P(Y=1) = \frac{2}{8}$$

つまり

$$P(X=3, Y=1) \neq P(X=3) \cdot P(Y=1)$$

つまり

X, Y は独立でない。

● 第10章～12章 練習問題・答え

① ΣY^2 No. 31 参照.

$$Z = \frac{(\bar{x} - \bar{y}) - (\mu_1 - \mu_2)}{\sqrt{(\sigma_1^2/n)^2 + (\sigma_2^2/n)^2}} = \frac{(\bar{x} - \bar{y}) + 3}{\sqrt{(\frac{3}{10})^2 + (\frac{4}{8})^2}} \quad \text{※ 正規分布 } N(0,1) \text{ に従う。}$$

$$\Delta = \bar{x} - \bar{y} = \frac{\sqrt{34}}{10} Z - 3 \quad \text{※ 正規分布 } N(-3, \frac{34}{100}) \text{ に従う。}$$

(\therefore 変数 $X \sim N(\mu, \sigma^2)$ に従うならば、 $aX+b$ は $N(a\mu+b, a^2\sigma^2)$ に従う。)

② 母平均 μ を推定

$$Z = \frac{\bar{x} - \mu}{\sigma/\sqrt{n}} = \frac{2 - \mu}{3/\sqrt{9}} = 2 - \mu \quad \text{※ } N(0,1) \text{ に従う。 } 95\% \text{ 信頼区間は}$$

$$\therefore -Z_{0.025} \leq 2 - \mu \leq Z_{0.025}$$

$$\therefore 2 - Z_{0.025} \leq \mu \leq 2 + Z_{0.025}$$

$$\text{※ 表より } Z_{0.025} = 1.96 \quad \therefore 95\% \text{ 信頼区間は } 0.04 \leq \mu \leq 3.96$$

③ 母平均 μ を推定

$$t = \frac{\bar{x} - \mu}{s/\sqrt{n}} \quad \text{※ 自由度 } n-1 \text{ の } t \text{ 分布に従う。}$$

$$\therefore t = \frac{30 - \mu}{\sqrt{4}/\sqrt{9}} \quad \text{※ 自由度 } 8 \text{ の } t \text{ 分布に従う}$$

よって、求める 95% 信頼区間は

$$-t_{0.025}(8) \leq \frac{30 - \mu}{2/3} \leq t_{0.025}(8)$$

$$\therefore 30 - \frac{2}{3} \cdot t_{0.025}(8) \leq \mu \leq 30 + \frac{2}{3} \cdot t_{0.025}(8)$$

$$\text{※ 表より } t_{(8)0.025} = 2.306 \quad \therefore 28.46 \leq \mu \leq 31.54$$

[注] ②、③は、教 P226 の (11.39) 式、(11.43) 式に代入すればよい。

(②別解)

$$(11.39) \text{ 式に代入して } 2 - Z_{0.025} \cdot \frac{3}{\sqrt{9}} \leq \mu \leq 2 + Z_{0.025} \cdot \frac{3}{\sqrt{9}} \quad \text{※ 上下と同一}$$

(③別解)

$$(11.43) \text{ 式に代入して } 30 - \frac{\sqrt{4}}{\sqrt{9}} \cdot t_{0.025}(8) \leq \mu \leq 30 + \frac{\sqrt{4}}{\sqrt{9}} \cdot t_{0.025}(8) \quad \text{※ 上下と同一}$$

⑥ まず与えられた標本について

個数: $n=13$

標本平均: $\bar{x} = \frac{1}{13} \{(-3) + 0 + (-1) + 2 + \dots + (-1) + 3\} = 1$

標本分散: $s^2 = \frac{1}{12} \{(-3)-1\}^2 + (0-1)^2 + \{(-1)-1\}^2 + \dots + (3-1)^2\} = 6$

である。

母分散未知、割合があるから t 検定とする。

有意水準 5% の採択域は $-t_{0.025}(12) \leq t \leq t_{0.025}(12)$ である。

付表より、これは $-2.179 \leq t \leq 2.179 \dots \textcircled{1}$

一方、帰無仮説 $H_0: \mu=0$ のもとで求めた t の値は

$$t = \frac{\bar{x} - \mu}{s/\sqrt{n}} = \frac{1-0}{\sqrt{6}/\sqrt{13}} = \sqrt{2.166\dots} \approx 1.47152\dots \text{と大きい値}$$

これは $\textcircled{1}$ にあてはまらない。よって 帰無仮説は棄却される。

$$s^2 = \frac{1}{n-1} \cdot \sum (x_i - \bar{x})^2$$

$$s^2 = \frac{n}{n-1} V(x)$$

$$\therefore s^2 = \frac{n}{n-1} (E(x_i^2) - \{E(x_i)\}^2)$$

ともできる。この方が使いやすい

本例では

$$s^2 = \frac{13}{12} \left\{ \frac{(-3)^2 + 0 + (-1)^2 + \dots + 3^2}{13} - 1^2 \right\} = 6$$

⑦ 母分散がわかっているから $z = \frac{\bar{x} - \mu}{\sigma/\sqrt{n}}$ で検定する。

有意水準 5% の採択域は $-z_{0.025} \leq z \leq z_{0.025}$

付表より、これは $-1.96 \leq z \leq 1.96$

一方、帰無仮説 $H_0: \mu=15.0$ のもとで求めた z の値は

$$z = \frac{14.6 - 15.0}{4/\sqrt{25}} = -0.5$$

これは採択域にあてはまらない。よって 帰無仮説は棄却されない。