

7 データの分析 [数学 I]

出題傾向 と対策

「データの分析」は、数学の本流からは切り離された分野で、他の分野の学習をしながら自然に出会うということが少ないため、どうしても「疎遠」になりがちである。問題演習を通して基本用語の定義・意味を1つ1つしっかり理解し、記憶していくことが肝要である。

センター試験攻略のポイント

① データ

実験、調査から得られた結果をデータという。また、そこで測った数量を**変量**といい、文字 x, y などで表す。

ある集団の傾向・特徴を調べることが**データの分析**の目的である。以下においては、変量 x の n 個の値を小さい順に並べた

$$x_1, x_2, x_3, \dots, x_n \quad \dots(*)$$

というデータについて考える。(n をこのデータ(*)の大きさという。)

② 代表値

(1) 変量 x の平均値は

$$\bar{x} = \frac{x_1 + x_2 + x_3 + \dots + x_n}{n} \quad \dots \begin{array}{l} \text{総和} \\ \text{個数} \end{array}$$

「エックスバー」と読む

$$= \frac{1}{n} \sum_{k=1}^n x_k$$

〈注意〉「数列」(数学B)を学んでいる人は、上のようにシグマ記号 Σ を使うとデータの分析における様々な量を簡潔に表すことができる。ぜひ積極的に使おう。本書では今後、 Σ 記号を使わない表現と使う表現を併用する。


(2) (*)において中央の順位にくる値を x の**中央値**(メジアン)といい、本書では今後、記号 \tilde{x} (「エックスチルダ」と読む)で表す。

〈注意〉上記以外の代表値である「最頻値」については、⑦「度数分布」で触れる。

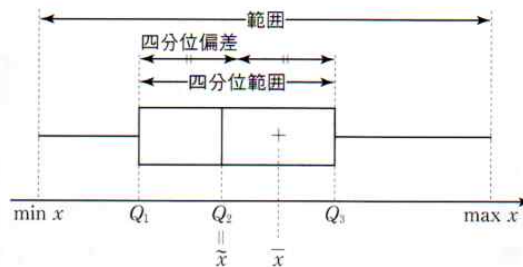
③ データの散らばり

平均値、中央値だけではわからない「データの散らばり」について考える。

(1) データを、小さい順に並べて4等分するときの境界に位置する変量の値を**四分位数**(Quartile)という。つまり、中央値=第2四分位数(Q_2)を境に同じ個数ずつの2グループに分けたとき、左、右各々のグループの中央値をそれぞれ**第1四分位数**(Q_1)、**第3四分位数**(Q_3)という。データの大きさが10のときは次のようになる。



(2) 最小値($\min x$)、最大値($\max x$)、および四分位数(Q_1, Q_2, Q_3)を用いて、データの分布・散らばりを把握することを**五数要約**といい、次の箱ひげ図で視覚化できる。



箱ひげ図には、上のように平均値を「+」の記号で書き入れることもある。

④ 偏差

変量 x からその平均値 \bar{x} を引いて得られる**偏差**： $x - \bar{x}$ を用いてデータの散らばりを表すことを考える。

(1) 偏差の2乗の平均値を変量 x の**分散**といい、 s_x^2 と表す。すなわち

$$s_x^2 = \frac{1}{n} \sum_{k=1}^n (x_k - \bar{x})^2 \quad \dots \text{偏差平方の平均}$$

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

分散が大きいほど、データの散らばりが大きいと考えられる。

(2) 分散は、次のように計算することもできる。


$$s_x^2 = \overline{x^2} - (\bar{x})^2 \quad \leftarrow (2 \text{ 乗の平均}) - (\text{平均の} 2 \text{ 乗})$$

(3) 分散の平方根をとってもとの変量と単位を揃えたものを**標準偏差**といい、 s_x と表す。

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

⑤ データの相関

- (1) ある集団における2つの変量 x, y の関係を調べるには、座標平面上に点 (x, y) をとって得られる散布図(相関図)を描くとよい。



- (2) x, y の偏差どうしの積 $(x-\bar{x})(y-\bar{y})$ の平均値を共分散といい、 s_{xy} で表す。すなわち

$$s_{xy} = \frac{1}{n} \sum_{k=1}^n (x_k - \bar{x})(y_k - \bar{y})$$

$$= \frac{1}{n} \{ (x_1 - \bar{x})(y_1 - \bar{y}) + (x_2 - \bar{x})(y_2 - \bar{y}) + \dots + (x_n - \bar{x})(y_n - \bar{y}) \}$$

これを x, y の標準偏差の積で割ったものが x と y の相関係数 r_{xy} である。すなわち

$$r_{xy} = \frac{s_{xy}}{s_x s_y}$$

相関係数の値は、 $-1 \leq r_{xy} \leq 1$ の範囲にある。 r_{xy} が $+1$ に近いときは、偏差どうしの積の値が正に偏っている。つまり、 x の増加にともない y も増加する傾向が強い。このとき x, y の間には正の相関があるという。逆に r_{xy} が -1 に近いとき、 x の増加にともない y は減少する傾向が強く、負の相関があるという。また、 r_{xy} が 0 に近いときは「相関がない」という。

⑥ 変量の変換

- (1) 変量 x と、それから作られる別の変量の平均値、分散、標準偏差の関係は次の通り。(a, b は定数)

変量	平均値	分散	標準偏差
x	\bar{x}	s_x^2	s_x
ax	$a\bar{x}$	$a^2 s_x^2$	$ a s_x$ …①
$x+b$	$\bar{x}+b$	s_x^2	s_x …②
$ax+b$	$a\bar{x}+b$	$a^2 s_x^2$	$ a s_x$ …③

〈注意〉 x, y の相関係数は、上記①~③の変換を施しても (a が正ならば) 変化しない。

- (2) 変量 x の平均値 \bar{x} を求める際、平均値に近そうに計算しやすい値 X を選び、 $x-X$ の平均値を用いて \bar{x} を求めると簡便である。

$$\bar{x} = \frac{1}{n} \sum_{k=1}^n (x_k - X) + X \quad \dots \text{前記②を利用}$$

$$= \frac{(x_1 - X) + (x_2 - X) + \dots + (x_n - X)}{n} + X$$

このとき X を仮平均という。

- (3) 変量 x から、その平均値と標準偏差を用いて作られる変量 $z = \frac{x - \bar{x}}{s_x}$ は、前記①~③より $\bar{z} = 0$ 、

$s_z = 1$ を満たす。このような変量の変換を基準化もしくは標準化という。

この基準化された z を用いて任意の平均値・標準偏差をもつ変量を作ることができる。たとえば $Z = 10z + 50$ は、③より $\bar{Z} = 50$ 、 $s_z = 10$ を満たす変量である。テストにおける得点 x をこのように変換して得られる変量 Z が、受験生お馴染みの偏差値である。

⑦ 度数分布

- (1) データの大きさ n が大きいとき、変量の値を同じ幅(階級の幅)のいくつかの区間(階級)に分け、各階級に対してその区間に入っているものの個数(度数)を対応させた度数分布を考えるとよい。これを表にしたものを度数分布表という。また、各階級値の n に対する割合 $\frac{\text{度数}}{n}$ を相対度数という。

各階級には、実際には異なる値が含まれているが、その違いを無視し、全ての値が階級の真ん中の値(階級値)をとるものとみなせば様々な計算を簡略化できる。

〈例〉 通学時間(単位:分)階級の幅:20

データの大きさ:50

階級 以上~未満	階級値	度数	相対度数
0~20	10	3	0.06
20~40	30	14	0.28
40~60	50	23	0.46
60~80	70	8	0.16
80~100	90	2	0.04

- (2) 度数を棒グラフで表したものをヒストグラムという。
- (3) 度数が最大である階級の階級値を最頻値(モード)という。上の例では、最頻値は50である。

基本編 センター試験の必出項目を check!

【解答 p.10】

以下、小数の形で解答する場合、指定された桁数の一つ下の桁を四捨五入し、解答せよ。途中で割り切れた場合、指定された桁まで①にマークすること。

1 平均値

目標時間 2分

下の表は、あるクラスの生徒 10 人に対して行われた国語と英語の小テスト(各 10 点満点)の得点をまとめたものである。

生徒番号	1	2	3	4	5	6	7	8	9	10	平均値
国語	9	10	4	7	10	5	5	7	6	7	A
英語	9	9	8	6	8	B	8	9	C	7	8.0

10 人の国語の得点の平均値 A は $\square{\text{ア}}.\square{\text{イ}}$ 点である。また、生徒 6 と生徒 9 の英語の得点 B, C は、関係式 $B + C = \square{\text{ウエ}}$ を満たす。

(13 年本試・改)

2 仮平均

目標時間 3分

ゲームに参加した 15 人の得点は

33 44 30 38 29 26 43 23 28
34 33 26 36 30 27

であった。この 15 人の得点の平均値は

$\square{\text{アイ}}.\square{\text{ウ}}$ 点である。

(11 年本試・改)

3 中央値(その1)

目標時間 1分

あるクラスの生徒 10 人に対して行われた国語の小テスト(10 点満点)の得点は次の通りであった。

9 10 4 7 10 5 5 7 6 7

このデータを値の小さいものから順に並べて考えることにより、国語の得点の中央値は

$\square{\text{ア}}.\square{\text{イ}}$ 点である。

(13 年本試・改)

4 中央値(その2)

目標時間 4分

10 名からなるあるクラスで実施した 100 点満点の英語のテストの得点は

43 55 A 64 36 48 46 71 65 50

であった。ただし、A は 0 以上 100 以下の整数とする。

(1) A を除く 9 人の得点の中央値は $\square{\text{アイ}}$ 点である。

(2) $A = 47, 53$ のとき、10 人の得点の中央値はそれぞれ $\square{\text{ウエ}}$ 点, $\square{\text{オカ}}.\square{\text{キ}}$ 点である。

(3) 10 人の得点の中央値として $\square{\text{ク}}$ 通りの値があり得る。

(09 年本試・改)

5 四分位数

目標時間 2分

あるクラスで、女子 10 人と男子 9 人に対して数学のテストを行った。女子の得点 x と男子の得点 y をそれぞれ値の小さいものから順に並べると次のようになった。

x : 50 51 54 56 65 67 71 72 75 79

y : 45 47 50 51 59 60 62 79 96

データの第 1 四分位数, 第 2 四分位数(中央値), 第 3 四分位数を Q_1, Q_2, Q_3 と表すと、変数 x については

$Q_1 = \square{\text{アイ}}, Q_2 = \square{\text{ウエ}}, Q_3 = \square{\text{オカ}}$

である。また変数 y については

$Q_1 = \square{\text{キク}}.\square{\text{ケ}}, Q_2 = \square{\text{コサ}},$

$Q_3 = \square{\text{シス}}.\square{\text{セ}}$

である。

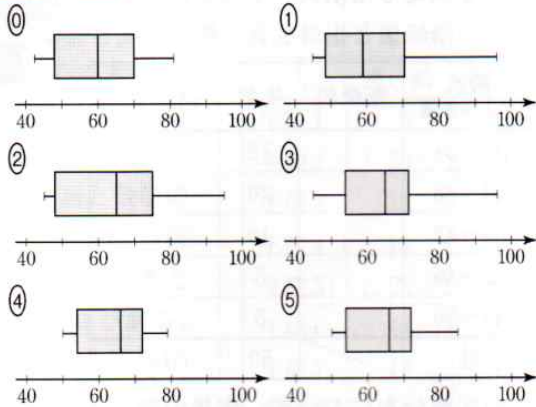
6 箱ひげ図

目標時間 3分

5 のデータを下の表のようにまとめた。5 の結果も用いて表を完成させよ。

	女子(x)	男子(y)
最小値		
第 1 四分位数(Q_1)		
中央値(Q_2)		
第 3 四分位数(Q_3)		
最大値		
範囲		
四分位範囲		

この表をもとに、 x のデータ、 y のデータを表す箱ひげ図を、下の①～⑤から選ぶと、順に **ア**、**イ** となる。



7 偏差・分散

目標時間 2分

生徒番号	国語 x	偏差 $x - \bar{x}$	偏差平方 $(x - \bar{x})^2$
1	9		
2	10		
3	4		
4	7		
5	10		
6	5		
7	5		
8	7		
9	6		
10	7		
平均値	$\bar{x} = 7.0$	ア 、 イ	ウ 、 エ

上の表はあるクラスの生徒10人に対して行われた国語のテストの結果をまとめたものであり、点数 x の平均値 \bar{x} を求めると

$$\bar{x} = 7.0$$

であった。これをもとに表を完成させると、偏差の平均値は **ア**、**イ**、偏差平方の平均値は **ウ**、**エ** である。また、変数 x の分散、標準偏差は、それぞれ

$$s_x^2 = \text{オ}、\text{カ}, s_x = \text{キ}、\text{ク}$$

である。

8 分散

目標時間 2分

大きさ6のデータがあり、変数 x の値は

5 0 2 5 6 3

である。このデータの平均値は $\bar{x} = \text{ア}$ 、**イ** であり、分散は $s_x^2 = \text{ウ}$ 、**エオ** である。

9 散点図・相関係数

目標時間 5分


あるクラスの生徒6人が、数学と英語のテスト(いずれも100点満点)を受けた。数学の得点 x 、英語の得点 y をまとめると下の表のようになった。 (x, y) の各組に対応する点を下の座標平面に「 \bullet 」として書き入れ、散点図を作れ。なお、 x, y の平均値 \bar{x}, \bar{y} はすでに求めて表に書き込んである。

生徒番号	数学 x	英語 y	$x - \bar{x}$	$y - \bar{y}$	$(x - \bar{x})(y - \bar{y})$
1	43	55			
2	50	48			
3	53	60			
4	55	70			
5	64	58			
6	65	69			
平均値	55	60	0	0	アイ

上の表を完成させることにより、 x の偏差 $x - \bar{x}$ と y の偏差 $y - \bar{y}$ の積の平均値を求めると **アイ** となる。また、 x の分散、 y の分散、 x と y の共分散は、それぞれ

$$s_x^2 = \text{ウエ}, s_y^2 = \text{オカ}, s_{xy} = \text{キク}$$


である。よって、 x と y の相関係数は、 $r_{xy} = \text{ケ}$ 、**コサ** である。




10 相関図

目標時間 1分


次の散布図(相関図)で表される分布における、 x と y の相関係数 r の値 \square ア \sim \square エとしてもっとも近いものを、下の① \sim ⑥から1つずつ選べ。




$r = \square$ ア



$r = \square$ イ



$r = \square$ ウ



$r = \square$ エ

- ① -1 ② -0.7 ③ -0.3 ④ 0
 ⑤ 0.3 ⑥ 0.7 ⑦ 1

11 変数の変換

目標時間 4分

2つの変数 x, y があり、それぞれの平均値、分散は

$$\bar{x} = 4.0, s_x^2 = 0.4, \bar{y} = 8.0, s_y^2 = 2.0$$

とする。

- 変数 x を使って新しい変数 t を $t = 5x + 30$ で定めると、変数 t の平均値、分散はそれぞれ $\bar{t} = \square$ アイ、 $s_t^2 = \square$ ウエとなる。
- 変数 y を使って新しい変数 u を $u = y - \square$ オで定めると、変数 u の平均値は0になる。
- 変数 y を使って新しい変数 v を $v = \sqrt{\frac{\square}{\square}} y$ で定めると、変数 v の分散は x の分散と同じになる。
- x と y の相関係数を r_{xy} とし、(1)の t と(2)の u の相関係数を r_{tu} とする。このとき、次の① \sim ③のうち \square ク が成り立つ。

- ① $r_{tu} = r_{xy}$ ② $r_{tu} > r_{xy}$ ③ $r_{tu} < r_{xy}$

(06年本試・改)

12 度数分布

目標時間 3分

あるクラブの50人に対して、右手の握力 x (単位kg)を測定した結果、下の度数分布表を得た。

表中の階級値と相対度数の欄を完成させよ。

階級 以上～未満	階級値	度数	相対度数
30～34		10	
34～38		20	
38～42		10	
42～46		5	
46～50		5	
計		50	1.0

この度数分布において、階級の幅は、 \square ア kgである。階級値を用いて x の平均値を求めると

$$\bar{x} = \square$$
イウ (kg)



である。また、このデータの中央値は \square エオ kgであり、最頻値は \square カキ kgである。

13 ヒストグラム

目標時間 2分

⑫のデータのヒストグラムを右図の中に完成させよ。

また、⑫のデータを表した箱ひげ図としてもっとも適切なものは、次の① \sim ④のうち \square ア である。



【解答 p.16】

制限時間 9分

1 右の表は、あるクラスの生徒9人に対して行われた英語と数学のテスト(各20点満点)の得点をまとめたものである。ただし、テストの得点は整数値である。また、表の数値はすべて正確な値であり、四捨五入されていないものとする。

	英語	数学
生徒1	9	15
生徒2	20	20
生徒3	18	14
生徒4	18	17
生徒5	A	8
生徒6	18	C
生徒7	14	D
生徒8	15	14
生徒9	18	15
平均値	16.0	15.0
分散	B	10.00
相関係数	0.500	

以下、小数の形で解答する場合、指定された桁数の一つ下の桁を四捨五入し、解答せよ。途中で割り切れた場合、指定された桁まで①にマークすること。


(1) 生徒5の英語の得点Aは アイ 点であり、9人の英語の得点の分散Bの値は ウエ . オカ である。また、9人の数学の得点の平均値が15.0点であること、英語と数学の得点の相関係数の値が0.500であることから、生徒6の数学の得点Cと生徒7の数学の得点Dの関係式

$$C + D = \text{キク}$$

$$C - D = \text{ケ}$$

が得られる。したがって、Cは コサ 点、Dは シス 点である。

(2) 9人の英語と数学の得点の散布図(相関図)として適切なものは セ である。 セ に当てはまるものを、次の①~③のうちから一つ選べ。



(3) 生徒10が転入して来たので、その生徒に対して同じテストを行ったところ、英語が16点、数学が15点であった。次の ソ , タ , チ に当てはまるものを、下の①~⑧のうちから一つずつ選べ。ただし、同じものを2回以上選んでもよい。

転入前における9人の生徒について、英語の得点の平均値を m 、英語の得点の標準偏差を s 、英語と数学の得点の相関係数を r とする。また、転入後における10人の生徒の英語の得点の平均値を m' 、英語の得点の標準偏差を s' 、英語と数学の得点の相関係数を r' とする。このとき、


$$\frac{m'}{m} = \text{ソ}, \quad \frac{s'}{s} = \text{タ}, \quad \frac{r'}{r} = \text{チ}$$

である。

- ① -1 ② 0 ③ 1
 ④ $\frac{9}{10}$ ⑤ $\left(\frac{9}{10}\right)^2$ ⑥ $\frac{3\sqrt{10}}{10}$
 ⑦ $\frac{10}{9}$ ⑧ $\left(\frac{10}{9}\right)^2$ ⑨ $\frac{\sqrt{10}}{3}$

(14年本試・改)

2 ある高等学校のAクラスには全部で20人の生徒がいる。次の表は、その20人の生徒の国語と英語のテストの結果をまとめたものである。表の横軸は国語の得点を、縦軸は英語の得点を表し、表中の数値は、国語の得点と英語の得点の組み合わせに対応する人数を表している。ただし、得点は0以上10以下の整数値をとり、空欄は0人であることを表している。たとえば、国語の得点が7点で英語の得点が6点である生徒の人数は2である。



また、右の表は、Aクラスの20人について、上の表の国語と英語の得点の平均値と分散をまとめたものである。ただし、表の数値はすべて正確な値であり、四捨五入されていない。

	国語	英語
平均値	B	6.0
分散	1.60	C

以下、小数の形で解答する場合、指定された桁数の一つ下の桁を四捨五入し、解答せよ。途中で割り切れた場合、指定された桁まで①にマークすること。

- (1) Aクラスの20人のうち、国語の得点が4点の生徒は 人であり、英語の得点が国語の得点以下の生徒は 人である。
- (2) Aクラスの20人について、国語の得点の平均値Bは . 点であり、英語の得点の分散Cの値は . である。
- (3) 国語の得点の中央値は . 点であり、英語の得点の第1四分位数は . 点である。

- (4) Aクラスの20人のうち、国語の得点が平均値 . 点と異なり、かつ、英語の得点も平均値6.0点と異なる生徒は 人である。

Aクラスの20人について、国語の得点と英語の得点の相関係数の値は . である。

- (5) 英語のテストで採点ミスが見つかった、国語が5点である生徒の英語の成績は、正しくは5点が1人、6点が3人、7点が4人であった。得点を修正した後、次の3つの値は修正前と比べてどのようになったか。 、、 に当てはまるものを、下の①～③のうちから1つずつ選べ。

英語の得点の平均値は 。

英語の得点の分散は 。


国語の得点と英語の得点の相関係数は 。

- ① 変化しない ② 増加する
③ 減少する ④ どうなるかわからない

(12年本試・改)

3 ある都市におけるある年の月ごとの最低気温を变量 x , 最高気温を变量 y とする。ただし、単位は $^{\circ}\text{C}$ とし、最低気温と最高気温は、一日の最低気温と最高気温について月ごとに平均をとり、小数第1位を四捨五入したものとする。

次の図は、变量 x と变量 y の散布図(相関図)である。



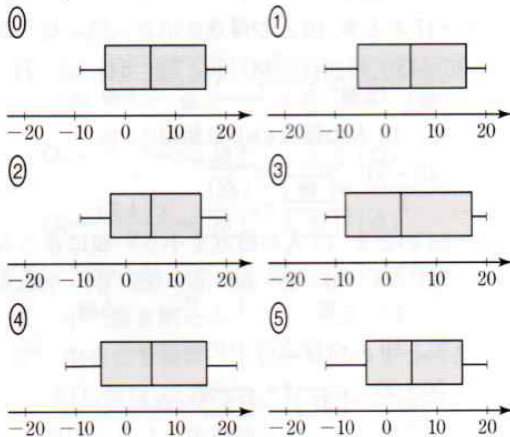
以下、小数の形で解答する場合は、指定された桁数の一つ下の桁を四捨五入し、解答せよ。途中で割り切れた場合は、指定された桁まで①にマークすること。

(1) 1月から12月までの变量 x は次のとおりであった。

-12 -9 -3 3 10 17 20 19 15 7
1 -8 (単位は $^{\circ}\text{C}$)

变量 x の平均値は、 $\bar{x} = \text{ア}.\text{イ}^{\circ}\text{C}$, 中央値は $\text{ウ}.\text{エ}^{\circ}\text{C}$ である。

また、变量 x の分布を表した箱ひげ図は次の①~⑤のうち オ である。



(2) 1月から12月までの12か月を、变量 x が 0°C 未満の四つの月からなる A グループと、 0°C 以上の八つの月からなる B グループとに分けて分析したところ、A グループにおける变量 y の平均値は 6.0°C で、B グループにおける变量 y の平均値は 21.5°C であった。このとき、1月から12月までの变量 y の平均値は $\text{カキ}.\text{ク}^{\circ}\text{C}$ である。

变量 x と变量 y の相関図のデータの中で、入力ミスが見つかった。变量 x の値が 7°C , 变量 y の値が 30°C となっている月の变量 y の値は、正しくは 18°C であった。

(3) この誤りを修正すると、变量 y の平均値は $\text{ケ}.\text{コ}^{\circ}\text{C}$ 減少する。また、变量 y の分散は サ する。そして、 x と y の相関係数は シ する。ただし、 サ と シ については、当てはまるものを、次の①~②のうちから一つずつ選べ。

- ① 修正前より増加 ① 修正前より減少
- ② 修正前と一致

(4) 修正後のデータをもとに、気温の単位を摂氏(単位 $^{\circ}\text{C}$)から華氏(単位 $^{\circ}\text{F}$)に変更した。すなわち、新しい变量 $X(^{\circ}\text{F})$, $Y(^{\circ}\text{F})$ を

$$X = \frac{9}{5}x + 32, \quad Y = \frac{9}{5}y + 32$$

によって定めた。


变量 X の平均値は、 $\bar{X} = \text{スセ}.\text{ソ}$ である。变量 x , X の標準偏差をそれぞれ s_x , s_X とすると、 $\frac{s_X}{s_x} = \text{タ}.\text{チ}$ である。

と、 $\frac{s_X}{s_x} = \text{タ}.\text{チ}$ である。

x と y の相関係数、 X と Y の相関係数をそれぞれ r_{xy} , r_{XY} とすると $\frac{r_{XY}}{r_{xy}} = \text{ツ}.\text{テ}$ である。

(i) $A \leq 48$ のとき


10人の得点を小さい順に並べると



よって10人の得点の中央値は②と同じく49点

(ii) $A \geq 55$ のとき

下のようになるから中央値は $\frac{50+55}{2} = 52.5$ (点)




(iii) $49 \leq A \leq 54$ のとき

③と同様に、中央値は50とAの平均 $\frac{50+A}{2}$


である。これは $A=49, 50, \dots, 54$ に応じて6個の値をとり、全て49より大きく52.5より小さい。

以上(i)~(iii)より、中央値として考えられる値は全部で $1+1+6=8$ (通り)

5 x について




$Q_2 = \frac{65+67}{2} = 66$ (点) ← 中央値 \bar{x} でもある



$Q_1 = 54$ (点), $Q_3 = 72$ (点)

y について



$Q_2 = 59$ (点)



$Q_1 = \frac{47+50}{2} = 48$ (点), $Q_3 = \frac{62+79}{2} = 70$ (点)

$Q_3 = \frac{62+79}{2} = 70$ (点)

参考 四分位数を求める手順は次の通りです。

- 1° 中央値を求める。これが Q_2 である。
- 2° 中央値を境に、下位、上位の2つのグループ(同じ個数)に分ける。元のデータの大きさが奇数のときは、中央値をとる1つを除いた2グループに分ける。
- 3° 下位グループの中央値、上位グループの中央値を求める。これらがそれぞれ Q_1, Q_3 である。

6 下表のようになる。

	女子(x)	男子(y)
最小値	50	45
第1四分位数(Q_1)	54	48.5
中央値(Q_2)	66	59
第3四分位数(Q_3)	72	70.5
最大値	79	96
範囲	29	51
四分位範囲	18	22

(範囲) = (最大値) - (最小値)

(四分位範囲) = $Q_3 - Q_1$

を用いている。このデータを表す箱ひげ図は、




である。

参考 ・箱ひげ図を選ぶとき、たとえば次のようにします。

x と y とで顕著に違うものとして「最大値」と「範囲」が挙げられます。この2つに注目すると、 y を表すものは①、②、③に絞られ、四分位数 Q_1, Q_2, Q_3 も考えると、①が正しいことがわかります。 x については、残りの④、⑤の中から最大値が79である④を選びます。念のため、四分位数などもチェックしておきましょう。

- ・上表の(*)部のことを「五数要約」といいます。
- ・箱ひげ図に関して、女子の得点 x を例として説明を加えます。



左のひげ「—」, 箱の左「 Q_1 」, 箱の右「 Q_3 」

「 \bar{x} 」, 右のひげ「—」の部分には、それぞれ Q_2 」

れ全体の約 $\frac{1}{4}$ の人数が分布していることとなります。

箱ひげ図には平均値($\bar{x}=64$ となります)を「+」で書き入れることもあります。

7 各生徒の偏差および偏差平方は下のようになる。

生徒番号	国語 x	偏差 $x-\bar{x}$	偏差平方 $(x-\bar{x})^2$
1	9	2	4
2	10	3	9
3	4	-3	9
4	7	0	0
5	10	3	9
6	5	-2	4
7	5	-2	4
8	7	0	0
9	6	-1	1
10	7	0	0
平均値	7.0	0.0	4.0

偏差 $x-\bar{x}$ の平均値は $\boxed{0}$ ア . $\boxed{0}$ イ

偏差平方の平均値は

$$\frac{1}{10}(4+9+9+9+4+4+1) = \frac{40}{10} = \boxed{4}$$
 ウ . $\boxed{0}$ エ

x の分散 s_x^2 とは、偏差平方の平均値であり

$$s_x^2 = \boxed{4}$$
 オ . $\boxed{0}$ カ

x の標準偏差は

$$s_x = \sqrt{s_x^2} = \sqrt{4.0} = \boxed{2}$$
 キ . $\boxed{0}$ ク

参考 偏差 $x-\bar{x}$ の平均値は、 x のとる値を x_1, x_2, \dots, x_n として

$$\frac{1}{n} \sum_{k=1}^n (x_k - \bar{x}) = \frac{1}{n} \sum_{k=1}^n x_k - \frac{1}{n} \cdot n\bar{x} = \bar{x} - \bar{x}$$

より、つねに0となります。

8
$$\bar{x} = \frac{5+0+2+5+6+3}{6} = \frac{21}{6}$$

$$= \boxed{3}$$
 ア . $\boxed{5}$ イ

$$s_x^2 = \overline{x^2} - (\bar{x})^2 \quad \leftarrow (2 \text{ 乗の平均}) - (\text{平均の} 2 \text{ 乗})$$

$$= \frac{25+0+4+25+36+9}{6} - \left(\frac{21}{6}\right)^2$$

$$= \frac{99}{6} - \frac{441}{6^2} = \frac{594-441}{6^2} = \frac{17}{4}$$

$$= \boxed{4}$$
 ウ . $\boxed{25}$ エオ

参考 • 平均値 \bar{x} の値が整数でないので、各偏差の値も整数でなくなります。そこで、分散の公式：

$$(\text{分散}) = (2 \text{ 乗の平均}) - (\text{平均の} 2 \text{ 乗})$$

を用いました。

• 分散の公式を証明します。変数 x が x_1, x_2, \dots, x_n の n 個の値をとるとき、 x の分散は

$$s_x^2 = \frac{1}{n} \sum_{k=1}^n (x_k - \bar{x})^2 \quad \leftarrow \text{偏差平方の平均値}$$

$$= \frac{1}{n} \sum_{k=1}^n \{x_k^2 - 2\bar{x}x_k + (\bar{x})^2\}$$

$$= \frac{1}{n} \sum_{k=1}^n x_k^2 - 2\bar{x} \cdot \frac{1}{n} \sum_{k=1}^n x_k + \frac{1}{n} \cdot n(\bar{x})^2$$

x^2 の平均値

$$= \overline{x^2} - 2\bar{x} \cdot \bar{x} + (\bar{x})^2$$

$$\therefore s_x^2 = \overline{x^2} - (\bar{x})^2$$

• 分散を、公式を用いず定義に従って求めると、次のようになります。

$$s_x^2 = \frac{1}{6} \left\{ \left(5 - \frac{7}{2}\right)^2 + \left(0 - \frac{7}{2}\right)^2 + \left(2 - \frac{7}{2}\right)^2 + \left(5 - \frac{7}{2}\right)^2 + \left(6 - \frac{7}{2}\right)^2 + \left(3 - \frac{7}{2}\right)^2 \right\}$$


$$= \frac{1}{6 \cdot 4} (9+49+9+9+25+1) = \frac{102}{6 \cdot 4} = \frac{17}{4}$$

$$= 4.25$$

本問においては、公式を用いる場合と所要時間はあまり変わりませんが、状況に応じて2つの方法を使い分けられるようにしましょう。

9 表と散布図を完成させると、次のようになる。

生徒番号	x	y	$x-\bar{x}$	$y-\bar{y}$	$(x-\bar{x})(y-\bar{y})$
1	43	55	-12	-5	60
2	50	48	-5	-12	60
3	53	60	-2	0	0
4	55	70	0	10	0
5	64	58	9	-2	-18
6	65	69	10	9	90
平均値	55	60	0	0	$\boxed{\text{アイ}}$



$$\boxed{\text{アイ}} = \frac{1}{6} (60+60-18+90) = \frac{192}{6} = \boxed{32}$$
 アイ (点)

$$s_x^2 = (x - \bar{x})^2 \text{ の平均値}$$

$$= \frac{1}{6}(144 + 25 + 4 + 81 + 100) = \frac{354}{6} = \boxed{59} \text{ ウエ}$$

$$s_y^2 = (y - \bar{y})^2 \text{ の平均値}$$

$$= \frac{1}{6}(25 + 144 + 100 + 4 + 81) = \boxed{59} \text{ オカ}$$

← 同じ値

x と y の共分散 s_{xy} とは、 $(x - \bar{x})(y - \bar{y})$ の平均値に他ならないから

$$s_{xy} = \boxed{\text{アイ}} = \boxed{32} \text{ キク}$$


$$\therefore r_{xy} = \frac{s_{xy}}{s_x s_y}$$

$$= \frac{32}{\sqrt{59} \sqrt{59}} = \frac{32}{59} = 0.542 \dots$$

小数第2位までが問われているから、小数第3位を四捨五入して

$$r_{xy} = \boxed{0} \text{ ケ} . \boxed{54} \text{ コサ}$$


参考 • 「相関係数」の意味について簡単に説明します。



偏差の積 $(x - \bar{x})(y - \bar{y})$ の平均値は大きくなる。
同符号ゆえ積は正
 x が大きいとき y も大きい傾向にある。

したがって、相関係数 r_{xy} の値が大きい(+1に近い)ほど、 x の増加にともない y も増加する傾向が強くなります。このことを、「 x と y の間に正の相関がある」といいます。上記と逆のことを「負の相関がある」といいます。

10 相関係数は、散布図の点が右上がりの直線近くに並ぶほど1に近く、右下がりの直線近くに並ぶほど-1に近くなる。




$$r = 0.7$$

$$\boxed{\text{ア}} = \boxed{0} \text{ ア}$$


$$r = 0$$

$$\boxed{\text{イ}} = \boxed{0} \text{ イ}$$



$$r = -0.7$$


$$\boxed{\text{ウ}} = \boxed{0} \text{ ウ}$$



$$r = 0.3$$

$$\boxed{\text{エ}} = \boxed{0} \text{ エ}$$

注意 • 「相関係数」は、変量 x 、 y の散布図における直線的な関係の強さを表します。たとえば右の散布図において相関係数はほぼ0ですが、「 x と y は無関係である」とは言えませんね。



• 変量 x と y の間に「相関関係がある」からといって、 x と y の間に「因果関係がある」とは限りません。たとえば、別の変量 z が x 、 y 双方に影響を与え、その結果として x と y の間に相関が生まれた可能性も考えられますね。

参考 相関係数 r が $-1 \leq r \leq 1$ を満たすことは、次のようにして証明されます。技巧を駆使しますから、観賞する気分でどうぞ。

変量 x 、 y の組として (x_1, y_1) 、 (x_2, y_2) 、 \dots 、 (x_n, y_n) があるとき、 x 、 y の偏差をそれぞれ $X_k = x_k - \bar{x}$ 、 $Y_k = y_k - \bar{y}$ とおくと、 x と y の相関係数 r_{xy} は

$$r_{xy} = \frac{s_{xy}}{s_x s_y} = \frac{\frac{1}{n} \sum_{k=1}^n X_k Y_k}{s_x s_y}$$

(以下、 $\left[\sum_{k=1}^n \right]$ を「 Σ 」と記す)

$$\frac{1}{n} \sum \left(\frac{X_k}{s_x} \pm \frac{Y_k}{s_y} \right)^2$$

$$= \frac{1}{s_x^2} \cdot \frac{1}{n} \sum X_k^2 \pm 2 \cdot \frac{1}{n} \frac{\sum X_k Y_k}{s_x s_y} + \frac{1}{s_y^2} \cdot \frac{1}{n} \sum Y_k^2$$

$$= \frac{s_x^2}{s_x^2} \pm 2r_{xy} + \frac{s_y^2}{s_y^2} \text{ (複号同順)}$$

部分は0以上だから

$$2 \pm 2r_{xy} \geq 0 \quad \text{よって} \quad -1 \leq r_{xy} \leq 1$$

$$\text{また, } r_{xy} = \frac{\frac{1}{n} \sum X_k Y_k}{\sqrt{\frac{1}{n} \sum X_k^2} \sqrt{\frac{1}{n} \sum Y_k^2}} = \frac{\sum X_k Y_k}{\sqrt{\sum X_k^2} \sqrt{\sum Y_k^2}}$$

と $r_{xy}^2 \leq 1$ より

$$(\sum X_k Y_k)^2 \leq (\sum X_k^2)(\sum Y_k^2)$$

これは、「コーシー・シュワルツの不等式」と呼ばれる有名不等式の一般形です。

11 (p. 3 ⑥の公式を用います。)

$$(1) \bar{t} = 5x + 30 = 5\bar{x} + 30 = 5 \cdot 4 + 30 = \boxed{50}^{\text{ア}}$$

$$s_t^2 = 5^2 \cdot s_x^2 = 5^2 \times 0.4 = \boxed{10}^{\text{ウ}}$$

$$(2) \boxed{\text{オ}} \text{ を } a \text{ とおくと } u = y - a$$

$$\bar{u} = \bar{y} - a = \bar{y} - a$$

これと、 $\bar{u} = 0$, $\bar{y} = 8.0$ より

$$0 = 8 - a \quad a = \boxed{8}^{\text{エ}}$$

$$(3) \frac{\sqrt{\boxed{\text{カ}}}}{\boxed{\text{キ}}} \text{ を } b (> 0) \text{ とおくと } v = by$$

$$s_v^2 = b^2 s_y^2$$

これと、 $s_v^2 = s_x^2 = 0.4$, $s_y^2 = 2.0$ より

$$0.4 = b^2 \cdot 2 \quad b^2 = 0.2 = \frac{1}{5}$$

$$b = \frac{1}{\sqrt{5}} = \frac{\sqrt{\boxed{\text{カ}}}}{\boxed{\text{キ}}}$$

(4) 変数を変換しても相関係数は変化しないから

$$r_{tu} = r_{xy} \quad \text{よって } \boxed{\text{ク}} = \boxed{0}^{\text{オ}}$$

参考 • p. 3 ⑥の公式のうち、分散に関する公式は覚えづらいかもしれませんね。直観的に説明するなら、次の通りです。

公式①：分散は偏差を2乗して得られるので、 x を定数 a 倍した ax の分散は、もとの x の分散の a^2 倍になる。

公式②：分散は変数の平均値からの隔り(偏差)によって定まる。 x に定数 b を加えて $x+b$ にしたとき、変数の各値と平均値はともに b ずつ増加するから、「隔り」は変化しない。よって、分散も変わらない。

• p. 3 ⑥の公式を証明します。

x_1, x_2, \dots, x_n の n 個の値をとるときを考え、 a ,

b は定数とする。「 $\sum_{k=1}^n$ 」を「 Σ 」と書くと

$$\overline{ax} = \frac{1}{n} \sum ax_k = a \cdot \frac{1}{n} \sum x_k = a\bar{x}$$

$$\overline{x+b} = \frac{1}{n} \sum (x_k + b) = \frac{1}{n} \sum x_k + \frac{1}{n} \cdot nb = \bar{x} + b$$

$$\therefore \overline{ax+b} = \overline{ax} + b = a\bar{x} + b$$

$$s_{ax}^2 = \frac{1}{n} \sum (ax_k - \overline{ax})^2$$

$$= \frac{1}{n} \sum (ax_k - a\bar{x})^2 = a^2 \cdot \frac{1}{n} \sum (x_k - \bar{x})^2 = a^2 s_x^2$$

$$s_{x+b}^2 = \frac{1}{n} \sum \{(x_k + b) - (\bar{x} + b)\}^2$$

$$= \frac{1}{n} \sum \{(x_k + b) - (\bar{x} + b)\}^2 = \frac{1}{n} \sum (x_k - \bar{x})^2$$

$$= s_x^2$$

$$s_{ax+b}^2 = \frac{1}{n} \sum (ax_k + b - \overline{ax+b})^2$$

$$= \frac{1}{n} \sum (ax_k + b - a\bar{x} - b)^2 = \frac{1}{n} \sum (ax_k - a\bar{x})^2$$

$$\therefore s_{ax+b}^2 = s_{ax}^2 = a^2 s_x^2$$

標準偏差については、上記の両辺に対して平方根をとればよい。

次に、2つの変数 x, y の組として $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$ があるとき、 x を用いて変数 $z = ax + b$ を作り、 $z_k = ax_k + b$ とすると、 z と y の共分散は

$$s_{zy} = \frac{1}{n} \sum (z_k - \bar{z})(y_k - \bar{y})$$

$$= \frac{1}{n} \sum \{(ax_k + b) - (a\bar{x} + b)\}(y_k - \bar{y})$$

$$= a \cdot \frac{1}{n} \sum (x_k - \bar{x})(y_k - \bar{y}) = a s_{xy}$$

よって、 z と y の相関係数は

$$r_{zy} = \frac{s_{zy}}{s_z s_y} = \frac{a s_{xy}}{|a| s_x s_y}$$

$\therefore a > 0$ のとき $r_{zy} = r_{xy}$

($a < 0$ のときは $r_{zy} = -r_{xy}$ となる。)

つまり、相関係数は変数を①～③のように変換しても (a が正ならば) 変化しない。

12

階級 以上～未満	階級値	度数	相対度数
30～34	32	10	0.2
34～38	36	20	0.4
38～42	40	10	0.2
42～46	44	5	0.1
46～50	48	5	0.1
計		50	1.0

階級の幅は

$$34 - 30 = \boxed{4}^{\text{ア}} \text{ (kg)}$$

↑
38 - 34 などでもよい。

握力 x の平均値は

$$\begin{aligned} \bar{x} &= \frac{\text{総和}}{\text{個数}} \\ &= \frac{1}{50} (32 \cdot 10 + 36 \cdot 20 + 40 \cdot 10 + 44 \cdot 5 + 48 \cdot 5) \cdots \text{①} \\ &= \frac{1}{5} (32 + 72 + 40 + 22 + 24) \\ &= \frac{190}{5} = \boxed{38}^{\text{イウ}} \text{ (kg)} \end{aligned}$$

x の値の小さい方から 25 番目と 26 番目はいずれも階級 34～38 に属するから、 x の中央値は

$$\tilde{x} = \text{階級 34～38 の階級値} = \boxed{36}^{\text{エオ}} \text{ (kg)}$$

度数が最大である階級は 34～38 だから、 x の最頻値は、階級 34～38 の階級値 $\boxed{36}^{\text{カキ}}$ kg である。

参考 • ①式を書きかえると、次のようになります。

$$\begin{aligned} \bar{x} &= 32 \cdot \frac{10}{50} + 36 \cdot \frac{20}{50} + 40 \cdot \frac{10}{50} + 44 \cdot \frac{5}{50} + 48 \cdot \frac{5}{50} \\ &= 32 \times 0.2 + 36 \times 0.4 + 40 \times 0.2 + 44 \times 0.1 \\ &\quad + 48 \times 0.1 \end{aligned}$$


↑
階級値 × 相対度数の総和

つまり、平均値は初めから相対度数を用いて求めることもできるわけです。ただし、「0.2」などの小数が現れるので得策とは限りませんが。

- 度数分布で与えられているデータの代表値(平均値, 中央値, 最頻値)は、各階級に属する変量の値が全てその階級の階級値をとると仮定して考えます。もちろん実際の変量の値はそれとは多少異なるのですが、このようにすることで計算処理が簡略化できますね。

13

このデータのヒストグラムは下図の通り。



また、このデータの「五数要約」を考えると

$\min x$ …階級 30～34 にある。

Q_1 …小さい方から 12 番目と 13 番目を考えて、階級 34～38 にある。

\tilde{x} … $\boxed{12}$ より、階級 34～38 にある。

Q_3 …大きい方から、12 番目と 13 番目を考えて、階級 38～42 にある。

$\max x$ …階級 46～50 にある。

これらの条件を全て満たすものを選んで

$$\boxed{\text{ア}} = \boxed{0}^{\text{ア}}$$

注意 $\min x = 30$ を満たしている ①, ② の中から選びたくなった人もいるかもしれませんが、しかし、データを度数分布にまとめたものからわかることは、最小値 $\min x$ が「階級 30～34 のどこかにある」ことだけであり、その階級の下限界: 30(kg) が最小値になるとは限りません。

参考 図に示したように、ヒストグラムと箱ひげ図を対応づけて考えられるようにしておきましょう。

• (3)の [ソ] では、「平均値は変化しない」と直観的に判断してしまいましたが、このことを計算で示すと次の通りです。

生徒 1, 2, ..., 10 の英語の得点をそれぞれ x_1, x_2, \dots, x_{10} とすると

$$m' = \frac{x_1 + x_2 + \dots + x_9 + x_{10}}{10}$$

$$= \frac{(x_1 + x_2 + \dots + x_9) + x_{10}}{10}$$

← 生徒 1~9 の得点の総和

$$= \frac{m \times 9 + m}{10} = \frac{10m}{10} = m$$

• 逆に、(3)の [タ], [チ] を、次のように直観的に答えてしまうことも可能です。生徒 10 が加入しても、平均値、偏差平方の総和、偏差の積の総和に変化はない。変わるのは人数(データの大きさ)が 9 人 → 10 人と増えることのみ。よって

標準偏差は $\sqrt{\frac{\square}{9}} \rightarrow \sqrt{\frac{\square}{10}}$ と $\frac{\sqrt{9}}{\sqrt{10}}$ 倍になり、

相関係数 $\frac{\frac{\square}{9}}{\sqrt{\frac{\square}{9}} \sqrt{\frac{\square}{9}}}$ は、データの大きさ「9」が

約分されて消えるので、10 人に増えても変化しない。

• 上で述べた相関係数の特性は、次のように一般化して覚えておく価値があります。

2 つの変数 x, y の組として $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$ があるとき、 x と y の相関係数 r_{xy} は $(\sum_{k=1}^n)$ を Σ と書くとして

$$r_{xy} = \frac{\frac{1}{n} \sum (x_k - \bar{x})(y_k - \bar{y})}{\sqrt{\frac{1}{n} \sum (x_k - \bar{x})^2} \sqrt{\frac{1}{n} \sum (y_k - \bar{y})^2}}$$

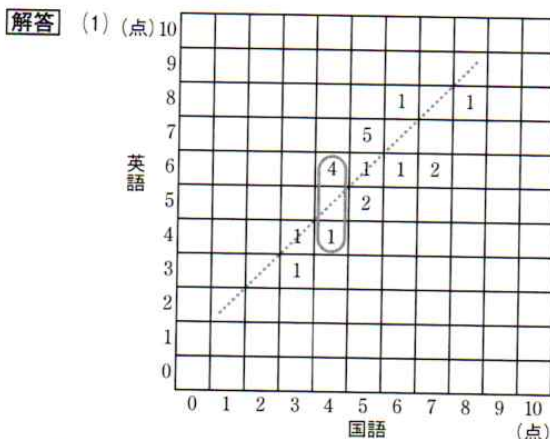
$$= \frac{\sum (x_k - \bar{x})(y_k - \bar{y})}{\sqrt{\sum (x_k - \bar{x})^2} \sqrt{\sum (y_k - \bar{y})^2}}$$

← 偏差の積の総和

← 偏差平方の総和

2 やや難

着眼 散布図(相関図)と似た機能をもつ“相関表”が与えられています。この表の意味をしっかりと読み取った上で、必要に応じて国語のみ、英語のみの分布も明示しておきましょう。



国語の得点が 4 点である生徒数は、上図 \bigcirc の人数を求めて

$$1 + 4 = \boxed{5} \text{ (人)}$$

英語の得点が国語の得点以下の生徒数は、上図より下の人数を考えて

$$1 + 1 + 2 + 1 + 2 + 1 = \boxed{8} \text{ (人)}$$

(2) 国語の得点 x のみに注目してまとめると、次のようになる。

x	3	4	5	6	7	8	計
人数	2	5	8	2	2	1	20

よって、 x の平均値は

$$B = \bar{x} = \frac{3 \cdot 2 + 4 \cdot 5 + 5 \cdot 8 + 6 \cdot 2 + 7 \cdot 2 + 8 \cdot 1}{20} \leftarrow \begin{matrix} \text{総和} \\ \text{個数} \end{matrix}$$

$$= \frac{6 + 20 + 40 + 12 + 14 + 8}{20} = \frac{100}{20}$$

$$= \boxed{5} \cdot \boxed{0} \text{ (点)}$$

英語の得点 y のみに注目してまとめると、次のようになる。

y	3	4	5	6	7	8	計
人数	1	2	2	8	5	2	20

よって y の分散は

$$s_y^2 = \frac{1}{20} \{ 1 \cdot (3-6)^2 + 2 \cdot (4-6)^2 + 2 \cdot (5-6)^2$$

$$+ 5 \cdot (7-6)^2 + 2 \cdot (8-6)^2 \}$$

$$= \frac{9 + 8 + 2 + 5 + 8}{20} \leftarrow \begin{matrix} \text{偏差平方の和} \\ \text{個数} \end{matrix}$$


$$= \frac{32}{20} = \boxed{1} \cdot \boxed{60} \text{ カキ}$$

(3) 国語の得点が下から 10 番目の生徒と 11 番目の生徒はいずれも 5 点だから、国語の得点 x の中央値 \tilde{x} は

$$\tilde{x} = \boxed{5} \cdot \boxed{0} \text{ (点)}$$

英語の得点が下から5番目の生徒は5点、下から6番目の生徒は6点だから、英語の得点 y の第1四分位数は

$$\frac{5+6}{2} = \boxed{5} \text{ (点)}$$



上図において、影の部分以外にある人数を数えて $\boxed{シ} = \boxed{5}$ (人)

x と y の偏差の積 $(x-\bar{x})(y-\bar{y})$ は、図の影の部分にある生徒については全て0である。よって x と y の共分散は

$$s_{xy} = \frac{\text{アイウエオ} \leftarrow \text{上の表を参照}}{6+4+2+2+6} = 1$$

よって、 x と y の相関係数は

$$r_{xy} = \frac{1}{\sqrt{1.6}\sqrt{1.6}} = \frac{1}{1.6} = \frac{5}{8} = \boxed{0} \text{ ス. } \boxed{625} \text{ センタ}$$

- (5) 英語
- 7点: 5人 → 4人
 - 6点: 1人 → 3人
 - 5点: 2人 → 1人

上の得点修正において、得点が変わったのは2人であり、右図のように変化した。よって英語の得点合計に変化はないから、英語の得点の平均値は変わらない。

$$\therefore \boxed{チ} = \boxed{6}$$

得点が変わった2人について、その偏差平方は、いずれも

$$1^2 \rightarrow 0^2$$

と減少したから、 y の分散 s_y^2 、すなわち偏差平方の平均値は減少する。すなわち

$$\boxed{ツ} = \boxed{2}$$

x と y の相関係数 $r_{xy} = \frac{s_{xy}}{s_x s_y}$ において、国語の得点変化はないから s_x は不変。上記より s_y は減少。

前記の2人について、国語の得点は $\bar{x} = 6$ と一致しているの、 x と y の偏差の積は得点修正の前、後いずれにおいても0である。したがって、 x と y の共分散 s_{xy} も変化しない(符号は正)。以上より、 r_{xy} は増加するから $\boxed{テ} = \boxed{0}$ テ

参考 • データの大きさが20であるとき、四分位数は次のようになります。(下記において、 $x_1 \leq x_2 \leq \dots \leq x_{20}$ とする。)

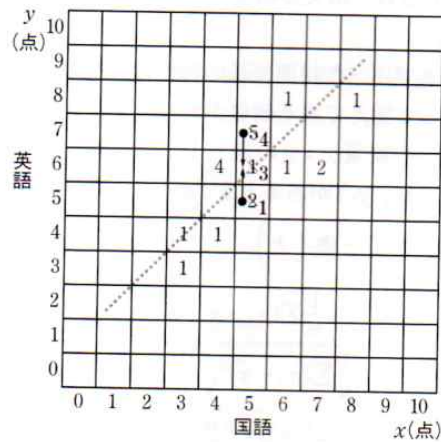
$$Q_2 = \bar{x} = \frac{x_{10} + x_{11}}{2}$$

$$Q_1 = \frac{x_5 + x_6}{2} \quad Q_3 = \frac{x_{15} + x_{16}}{2}$$

- (4)の図では、 x 、 y の平均値を表す影の部分によって右上、左上、右下の4つの領域に分けられ、そのうち右上の左下だけに生徒が分布しています。これらの生徒については、 x と y の偏差の積は全て正となりますから、 x と y の相関係数は正である(つまり正の相関がある)ことがわかります。

これぞセンター流 解法!

(5)の解答では、相関係数の各要素: s_x , s_y , s_{xy} の変化をきちんと調べましたが、もっと直観的、視覚的に答えることもできます。



もともとこの分布では、上図点線のまわりにデータがかなり集まっていたのですが、得点の修正によりさらにその傾向が強まったことがわかります。よって、相関係数は増加するはずですよ。

3 標準

着眼 データが散布図によって与えられています。前半の大半は x , y 各々について考えれば解答できます。(3), (4)では平均値などの定義と意味


を理解しているかどうかが問われます。

解答 (1) x の平均値は

$$\frac{1}{12}(-12-9-3+3+10+17+20+19+15+7+1-8)$$

$$= \frac{60}{12} = \boxed{5}^ア \cdot \boxed{0}^イ (^{\circ}\text{C})$$

x の値を小さい順に並べると、次の通り。



小さい方から6番目と7番目(上図のウ)を用いて、 x の中央値は

$$\tilde{x} = \frac{3+7}{2} = \boxed{5}^ウ \cdot \boxed{0}^エ (^{\circ}\text{C})$$

次に四分位数を求める。下位6個のグループ、上位6個のグループそれぞれにおいて、小さい方から3番目と4番目(上図のオ、カ)を用いて、第1四分位数 Q_1 、第3四分位数 Q_3 は

$$Q_1 = \frac{-8-3}{2} = -5.5 (^{\circ}\text{C}), \quad Q_3 = \frac{15+17}{2} = 16 (^{\circ}\text{C})$$

変数 x の五数要約は

$$\min x = -12, \quad Q_1 = -5.5, \quad \tilde{x} = 5.0, \quad Q_3 = 16$$

$$\max x = 20$$

これに適する箱ひげ図を選んで

$$\boxed{オ} = \boxed{0}^オ$$

(2) A グループにおける y の和は

$$6.0 \times 4 = 24 (^{\circ}\text{C})$$

B グループにおける y の和は

$$21.5 \times 8 = 172 (^{\circ}\text{C})$$

よって、1月から12月までの y の平均値は

$$\bar{y} = \frac{24+172}{12} \leftarrow \begin{array}{l} \text{総和} \\ \text{個数} \end{array}$$

$$= \frac{196}{12} = \frac{49}{3} = 16.333\dots$$

小数第2位を四捨五入して

$$\bar{y} = \boxed{16}^カキ \cdot \boxed{3}^ク (^{\circ}\text{C})$$

(3) y の値の1つを 30°C から 18°C に変えると、 y の総和は $30-18=12 (^{\circ}\text{C})$ 減少する。

よって、 y の平均値は

$$\frac{12}{12} = \boxed{1}^ケ \cdot \boxed{0}^コ (^{\circ}\text{C}) \text{ 減少する。}$$


修正前 $\bar{y} = 16.3 (^{\circ}\text{C})$ から大きく隔っていた $30 (^{\circ}\text{C})$ が、修正後には $\bar{y} = 16.3 - 1.0 = 15.3 (^{\circ}\text{C})$ に近い 18°C になったので、その分偏差平方は減少す

る。他の月についての偏差平方の合計はあまり変わらないから、12か月分の平方偏差の総和は減少する。よって、 y の分散も減少する。

$$\therefore \boxed{サ} = \boxed{0}^カ$$

$(x, y) = (7, 30)$ だった点を $(x, y) = (7, 18)$ に移すと、散布図上の点は、移動前よりもある直線の近くに集まる。よって、 x と y の相関係数は増加して1に近づく。

$$\therefore \boxed{ス} = \boxed{0}^シ$$



(4) $X = \frac{9}{5}x + 32$ より、 X と x の平均値に関して、

$$\bar{X} = \frac{9}{5}\bar{x} + 32 = \frac{9}{5} \times 5.0 + 32 = \boxed{41}^スセ \cdot \boxed{0}^ソ (^{\circ}\text{F})$$

標準偏差については

$$s_X = \frac{9}{5}s_x \quad \therefore \frac{s_X}{s_x} = \frac{9}{5} = \boxed{1}^タ \cdot \boxed{8}^チ$$

変数変換をしても相関係数は変わらないから

$$r_{XY} = r_{xy} \quad \text{つまり} \quad \frac{r_{XY}}{r_{xy}} = \boxed{1}^ツ \cdot \boxed{0}^テ$$

参考 • (1)で x の平均値を求める際に、仮平均は使いませんでした。値の符号が正、負にまたがっているのうまうま消し合ってくれることが予想されたからです。見方によっては「0」を仮平均として選んでいると言えなくもありません。

• (2)で y の平均値を求める式は、次のように書くこともできます。

$$\bar{y} = \frac{6.0 \times 4 + 21.5 \times 8}{12}$$

$$= 6.0 \times \frac{1}{3} + 21.5 \times \frac{2}{3}$$

これは4個の平均値6.0と、8個の平均値21.5を、それぞれの個数に比例した“重み” $\frac{1}{3}$, $\frac{2}{3}$ を掛けて加えたもので、「加重平均」と言われたりします。

• (4)で用いた変数変換時の公式は、(できれば、理由を理解した上で)記憶してしましましょう。