

1 節 データの分析

1 データと度数分布表

ねらい データは、整理することによって、全体の傾向や特徴を見やすくすることができます。データを整理する方法を学びます。


下の資料は、あるクラスを、電車で通学する生徒 20 人の A 班と、徒歩で通学する生徒 15 人の B 班に分けて、先月の読書時間の合計を調べたものである。

A 班 (単位 時間)

3	10	7	14	5	9	15	0	9	18
0	8	11	10	15	19	6	23	13	5

B 班 (単位 時間)

6	20	0	14	16	23	1	4	5	0
18	13	21	0	9					



このような資料を**データ**という。データは個々の値を並べただけでは、全体の傾向や特徴はわからない。特徴を調べるときは、目的に合わせて整理することが大切である。

度数分布表とヒストグラム

左下の表は、A 班のデータを、時間を 4 時間ずつの区間に分け、その区間に入る人数を調べてまとめたものである。


各区間を**階級**、各階級に入っているデータの値の個数を**度数**、階級の中央の値を**階級値**という。このように、各階級に度数を対応させた表を**度数分布表**という。

右下の図は、分布のようすを見やすくするために、A 班の読書時間の度数分布表から、階級の幅を底辺、度数を高さとする長方形をすきまなく並べたグラフである。このようなグラフを**ヒストグラム**という。

A 班の読書時間

時間の階級 (時間)	階級値 (時間)	度数 (人)
0 以上～ 4 未満	2	3
4 ～ 8	6	4
8 ～ 12	10	6
12 ～ 16	14	4
16 ～ 20	18	2
20 ～ 24	22	1
計		20

A 班の読書時間




度数分布表やヒストグラムに表すことで、A 班では、8 時間以上 12 時間未満の階級の度数が最も大きいことがわかる。

問 1 128 ページの B 班の読書時間を度数分布表にまとめ、ヒストグラムに表しなさい。また、度数の最も大きい階級を答えなさい。

B 班の読書時間

時間の階級 (時間)	階級値 (時間)	度数 (人)
0 以上～ 4 未満	2	
4～8	6	
8～12	10	
12～16	14	
16～20	18	
20～24	22	
計		



相対度数

A 班と B 班では、度数の合計が異なるので、各階級の度数をそのまま比べても違いがはっきりしない。

度数の合計が異なるときは、各階級の度数が、度数の合計に対してどのような割合であるか調べてみるとよい。

各階級の度数を度数の合計でわった値を**相対度数**といい、各階級に相対度数を対応させた表を**相対度数分布表**という。

A 班の読書時間の相対度数分布表は、右のようになる。

A 班, B 班の読書時間

時間の階級 (時間)	A 班		B 班	
	度数 (人)	相対 度数	度数 (人)	相対 度数
0 以上～ 4 未満	3	0.15		
4～8	4	0.20		
8～12	6	0.30		
12～16	4	0.20		
16～20	2	0.10		
20～24	1	0.05		
計	20	1.00		

問 2 上の B 班の読書時間の相対度数分布表を完成しなさい。また、16 時間以上 20 時間未満の階級では、A 班と B 班で、どちらの相対度数が大きいか答えなさい。

2 代表値

ねらい データ全体の特徴を表す数値の求め方や選び方について学びます。

データ全体の特徴を表す数値を**代表値**という。代表値には、平均値、中央値、最頻値などがある。

平均値と中央値

よく知られた代表値に平均値がある。**平均値**は、データの値の合計をデータの値の個数でわった値である。

◀ 平均値

$$= \frac{\text{データの値の合計}}{\text{データの値の個数}}$$

● A 班の読書時間の平均値を求めてみよう。

例 1
$$\frac{3+10+7+\dots+13+5}{20} = \frac{200}{20} = 10 \text{ (時間)}$$

問 3 128 ページの B 班の読書時間の平均値を求めなさい。

データの値を小さい順に並べたとき、中央の値を**中央値**という。ただし、データの値の個数が偶数のときは、中央にある 2 つの値の平均値を中央値とする。

◀ 中央値はメジアンともいう。

◀ 奇数のとき



中央値


偶数のとき



この 2 つの値の平均値が中央値

● A 班の読書時間の中央値を求めてみよう。

例 2 データの値を小さい順に並べると、次のようになる。




中央値は、10 番目と 11 番目の平均値である。

よって
$$\frac{9+10}{2} = 9.5 \text{ (時間)}$$

問 4 128 ページの B 班の読書時間を、値の小さい順に並べると次のようになる。B 班の読書時間の中央値を求めなさい。

→ p.140 復習問題 1



データのなかに、ほかの値とかけ離れた値がある場合がある。このようなときは、平均値よりも中央値の方がその値の影響を受けにくいので、代表値としては、平均値より中央値が適当である。

最頻値

度数分布表で、度数が最も大きい階級の階級値を**最頻値**という。最頻値はヒストグラムにおいて、最も高い長方形に対応する階級値である。

◀最頻値はモードともいう。また、データにおいて個数が最も多い値を最頻値ということもある。


● A 班の読書時間の最頻値を求めてみよう。

例 3 128 ページの A 班の読書時間の度数分布表で、度数が最も大きい階級は 8 時間以上 12 時間未満である。したがって、最頻値はその階級値の 10 時間である。


問 5 129 ページの問 1 でつくった度数分布表から、B 班の読書時間の最頻値を求めなさい。

● A 班と B 班について、読書時間の 3 つの代表値を比べてみよう。

例 4 A 班の読書時間の 3 つの代表値をヒストグラムに表すと、次の図のようになる。



問 6 例 4 にならって、B 班の読書時間の 3 つの代表値を、次のヒストグラムの に入れなさい。



3 四分位数と箱ひげ図

ねらい データの散らばりぐあいも、データ全体のもつ特徴の1つです。中央値をもとにして、データの散らばりぐあいを、数値や図で表すことを学びます。

四分位数と四分位範囲

データは、散らばりぐあいを考えることが大切な場合もある。データの散らばりぐあいは、代表値ではとらえられない。

データの値で

$$(\text{最大値}) - (\text{最小値})$$

を、そのデータの分布の**範囲**という。範囲を調べて、データの散らばりぐあいを比べてみよう。

下の表は、バスケットボール部のAさんとBさんの、最近10試合で成功したシュートの本数である。

Aさん (単位 本) Bさん (単位 本)

5	3	6	5	6	7	8	7	8	10	4	5	13	5	9	6	6	7	6	5
---	---	---	---	---	---	---	---	---	----	---	---	----	---	---	---	---	---	---	---

2人の成功したシュートの本数の範囲は、それぞれ

$$A \text{ さん } 10 - 3 = 7 \text{ (本)} \quad B \text{ さん } 13 - 4 = 9 \text{ (本)}$$

となる。範囲の値を比べると、散らばりぐあいはAさんよりBさんの方が大きいといえる。


範囲は、データのなかにほかとかけ離れた値がある場合、その値の影響を受けやすい。その影響を少なくしたものに、**四分位範囲**がある。四分位範囲は次のようにして求める。

- ① データの値を小さい順に並べ、中央値を境にして2つに分ける。
- ② 中央値を、**第2四分位数**という。
- ③ 最小値を含む方のデータの中央値を**第1四分位数**という。
- ④ 最大値を含む方のデータの中央値を**第3四分位数**という。
- ⑤ $(\text{第3四分位数}) - (\text{第1四分位数})$


が、四分位範囲である。

また、四分位範囲を2でわった値を**四分位偏差**という。


◀ データの値には、かならず最大値と最小値がある。



◀ 偶数のとき




奇数のとき



◀ 第3四分位数と第1四分位数の間に、データの個数のほぼ半分が含まれる。

● Aさんの成功したシュートの本数の四分位範囲を求めてみよう。

例 5 Aさんの成功したシュートの本数を、小さい順に並べかえると右のようになるから



第2四分位数 $\frac{6+7}{2} = 6.5$ (本)
 第1四分位数 5本
 第3四分位数 8本
 四分位範囲 $8 - 5 = 3$ (本)
 四分位偏差 $3 \div 2 = 1.5$ (本)


◀ 四分位偏差 = $\frac{\text{四分位範囲}}{2}$

問 7 Bさんの成功したシュートの本数の、四分位範囲、四分位偏差を求めなさい。また、AさんとBさんの四分位範囲を比べて、どちらの散らばりぐあいが大きいか答えなさい。

箱ひげ図

四分位数を用いて、データの散らばりぐあいを見やすく表すには、下のように長方形に線を添えた**箱ひげ図**を用いる。


◀ 第1四分位数、第2四分位数、第3四分位数をまとめて、四分位数という。



◀ 平均値を表す + をかかないこともある。

● Aさんの成功したシュートの本数の箱ひげ図をつくってみよう。

例 6 例5の結果から、箱ひげ図は次のようになる。



問 8 Bさんの成功したシュートの本数の箱ひげ図を、上の図に表しなさい。

→ p.140 復習問題②

4 分散と標準偏差

ねらい データの散らばりぐあいを、平均値をもとにして、1つの数値で表すことを学びます。

データの散らばりぐあいを、データの個々の値と平均値との差を用いて考えてみよう。

$$(\text{データの個々の値}) - (\text{平均値})$$

を**偏差**という。

次の表は、ある野球チームのA投手とB投手が、最近5試合で奪った三振の個数である。



(単位 個)

	1 試合目	2 試合目	3 試合目	4 試合目	5 試合目
A 投手	4	8	7	5	6
B 投手	10	2	9	6	3

平均値は、それぞれ

$$\text{A 投手} \quad \frac{4+8+7+5+6}{5} = \frac{30}{5} = 6 \text{ (個)}$$


$$\text{B 投手} \quad \frac{10+2+9+6+3}{5} = \frac{30}{5} = 6 \text{ (個)}$$

となり、等しくなる。しかし、三振の個数をヒストグラムに表すと、散らばりぐあいは異なる。

次に、A投手、B投手の三振の個数の偏差とその合計を求める。と下の表ようになる。

	1 試合目	2 試合目	3 試合目	4 試合目	5 試合目	計
A 投手の偏差	-2	2	1	-1	0	0
B 投手の偏差	4	-4	3	0	-3	0

◀三振の個数のヒストグラム



この表からわかるように、偏差の合計はどちらも0になるため、偏差の平均値でデータ全体の散らばりぐあいを表すことはできない。

そこで、偏差を2乗した値を考える。偏差の2乗は0以上の値になるので、合計が0に近いほど平均値からの散らばりぐあいが小さいといえる。

偏差の2乗の平均値を分散といい、 s^2 で表す。また、分散の正の平方根を標準偏差といい、 s で表す。

分散と標準偏差	
偏差	(データの個々の値)-(平均値)
分散	$s^2 = (\text{偏差})^2$ の平均値 $= \frac{(\text{偏差})^2 \text{の合計}}{\text{データの値の個数}}$
標準偏差	$s = \sqrt{s^2} = (\text{分散の正の平方根})$

分散や標準偏差は、データ全体の散らばりぐあいを表す数値である。

分散や標準偏差の値は、0に近いほどデータの個々の値が平均値の近くに分布していることを意味し、大きいほどデータの個々の値に平均値から離れたものが多いことを意味している。

● A 投手の三振の個数の分散、標準偏差を求めてみよう。

例 7 134 ページの A 投手が奪った三振の

個数から偏差の2乗の合計を計算

すると、右の表のようになる。

したがって、分散 s^2 は

$$s^2 = \frac{10}{5} = 2$$

標準偏差 s は

$$s = \sqrt{2} = 1.4142 \dots \approx 1.41 \text{ (個)}$$

A 投手	三振の個数	偏差	(偏差) ²
1 試合目	4	-2	4
2 試合目	8	2	4
3 試合目	7	1	1
4 試合目	5	-1	1
5 試合目	6	0	0
計	30	0	10

問 9 右の表を完成して、B 投手が奪った三振の個数の分散を求めなさい。また、標準偏差を、四捨五入して小数第2位まで求めなさい。

B 投手	三振の個数	偏差	(偏差) ²
1 試合目	10		
2 試合目	2		
3 試合目	9		
4 試合目	6		
5 試合目	3		
計	30		

問 10 A 投手と B 投手が奪った三振の個数の標準偏差を比べて、どちらの散らばりぐあいが大きいか答えなさい。

5 相関関係



ねらい 2つの数量の関係を図を使って調べてみます。また、その関係のどあいについて考えます。

散布図

たとえば、平均気温と電力使用量のように、互いに関係があると考えられる数量がある。このような2つの数量を組にしたデータについて考えてみよう。

2つの数量の関係は、それぞれの値の組を x 座標、 y 座標とする点として、平面上に表すことができる。このような図を**散布図**という。

右の図は、ある町の7月中の連続した20日間における日ごとの平均気温と1世帯あたりの電力使用量を散布図に表したものである。図中の点Pは、平均気温が 27.0°C で、電力使用量が 11.5kWh であることを表している。



相関関係


下の表は、20人の生徒について、先月の読書時間と、勉強時間、テレビ視聴時間、1日のメール発信回数の平均を調べたデータである。




読書(時間)	3	10	7	14	5	9	15	0	9	18	0	8	11	10	15	19	6	23	13	5
勉強(時間)	6	33	21	50	2	8	39	5	6	66	14	18	26	24	48	52	7	47	41	8
テレビ視聴(時間)	58	37	47	26	55	52	48	38	56	4	48	25	36	31	24	19	53	18	20	62
メール発信(回)	5	2	9	7	8	6	8	3	2	2	2	6	12	3	9	6	11	1	4	1

読書時間と勉強時間を散布図に表すと、右の図のようになる。


この散布図から、読書時間と勉強時間は、一方が増加すれば他方も増加する傾向があることがわかる。このとき、2つの数量の間には**正の相関関係**があるという。




右の㊦の図は、読書時間とテレビ視聴時間の散布図である。この散布図から、読書時間とテレビ視聴時間は、一方が増加すれば他方は減少する傾向があることがわかる。このとき、2つの数量の間には**負の相関関係**があるという。



また、右の㊧の図は、読書時間とメール発信回数の散布図である。読書時間とメール発信回数には、正の相関関係も負の相関関係もみられない。このとき、2つの数量の間には相関関係がないという。




2つの数量の間に相関関係があるとき、散布図の点が直線状に近づくほど相関関係が強いといい、直線状ではなく広く散らばるほど相関関係が弱いという。



問 11 次の表は、5人の生徒の、先月の読書時間と読んだ本の冊数を示したものである。散布図をつくり、読書時間と読んだ本の冊数には、どのような相関関係があるか答えなさい。

生徒	読書 (時間)	読んだ本 (冊)
a	5	2
b	8	6
c	9	4
d	12	8
e	11	5



6 相関係数

ねらい 相関関係は、散布図でとらえることができますが、数値で表すことができれば、さらに便利です。相関関係を数値で表すことを学びます。

相関係数の意味

相関関係を調べたい2つの数量を x, y とする。 x の偏差と y の偏差の積の平均値を **共分散** という。また、共分散を x の標準偏差と y の標準偏差の積でわった値を **相関係数** という。相関係数は記号 r で表す。

$$\begin{aligned} \leftarrow (\text{偏差}) &= \\ & (\text{データの個々の値}) \\ & \quad - (\text{平均値}) \end{aligned}$$

共分散と相関係数

共分散 x と y の偏差の積の平均値

$$\text{相関係数 } r = \frac{\text{共分散}}{(x \text{ の標準偏差}) \times (y \text{ の標準偏差})}$$


相関関係を数値で表すには、共分散や相関係数が用いられる。とくに、相関係数 r の値については、不等式

$$-1 \leq r \leq 1$$

が成り立ち、正の相関関係が強いほど 1 に近づき、負の相関関係が強いほど -1 に近づく。

プロ野球 12 チームについて、1 年間の勝利数 x と得点 y を調べたところ、共分散は 123.9、 x の標準偏差は 7.5、 y の標準偏差は 44.5 であった。これらを用いて相関係数 r は次のように求められる。

$$r = \frac{123.9}{7.5 \times 44.5} = 0.3712 \dots \approx 0.37$$



問 12 上のプロ野球 12 チームで、勝利数と失点数の相関係数は -0.73 、勝利数と得失点差の相関係数は 0.90 である。次の①、②から、正しいものを選びなさい。

- (1) 勝利数と失点数には
- ① 正の相関関係がある ② 負の相関関係がある
- (2) 勝利数と得点より、勝利数と得失点差の方が
- ① 正の相関関係が強い ② 正の相関関係が弱い



→ p.140 復習問題③

相関係数

● 読書時間と読んだ本の冊数の相関係数を求めてみよう。

例 8 137 ページの問 11 について、読書時間を x とし、読んだ本の冊数を y とする。

$$(x \text{ の平均値}) = \frac{5+8+9+12+11}{5} = 9 \text{ (時間)}$$

$$(y \text{ の平均値}) = \frac{2+6+4+8+5}{5} = 5 \text{ (冊)}$$

下の表のようにして計算すると

生徒	x	y	x の偏差	y の偏差	$(x \text{ の偏差})^2$	$(y \text{ の偏差})^2$	偏差の積
a	5	2	-4	-3	16	9	12
b	8	6	-1	1	1	1	-1
c	9	4	0	-1	0	1	0
d	12	8	3	3	9	9	9
e	11	5	2	0	4	0	0
計	45	25	0	0	30	20	20

$$x, y \text{ の共分散は } \frac{20}{5} = 4$$

$$x \text{ の標準偏差は } \sqrt{\frac{30}{5}} = \sqrt{6}$$

$$y \text{ の標準偏差は } \sqrt{\frac{20}{5}} = \sqrt{4} = 2$$

相関係数 r は

$$r = \frac{4}{\sqrt{6} \times 2} = \frac{\sqrt{6}}{3} = 0.816 \dots \approx 0.82$$

◀ 電卓などを用いて、求めるとよい。

問 13 次の表は、4 人の生徒の数学と英語の小テストの得点を示したものである。表を完成することにより、数学の得点 x と英語の得点 y の相関係数を求めなさい。

生徒	x	y	x の偏差	y の偏差	$(x \text{ の偏差})^2$	$(y \text{ の偏差})^2$	偏差の積
a	6	5					
b	7	5					
c	7	8					
d	8	10					
計							

復習問題

- ① 次の資料は、1年生の図書委員 8 人が 1 年間に学校の図書室から借りた本の冊数を調べたものである。

7 12 8 40 9 4 8 8


- (1) 借りた本の冊数の平均値、中央値を求めなさい。
 (2) 40 冊借りた生徒を除いて、残り 7 人が借りた本の冊数の平均値、中央値を求めなさい。

代表値


↩ p.130 例 1
 p.130 例 2

- ② 次のヒストグラムについて、対応する箱ひげ図を選びなさい。

ヒストグラム



箱ひげ図




箱ひげ図

↩ p.133 例 6

- ③ 次の散布図について、対応する相関係数を選びなさい。

散布図



相関係数

- ① 0.9 ② 0.5 ③ -0.8

相関関係, 相関係数

↩ p.137 問 11
 p.138 問 12