

# 健康統計学 第2回

今回は、尺度と度数分布（テキスト pp.5～pp.13）について学習します。

eラーニングへの登録をまだ済ませていない場合は、次回の授業までに済ませておくこと。

## テキスト

- 『やさしい保健統計学 改訂第4版』 縣 俊彦著 (南江堂)

## 今回の内容

1. [統計資料の尺度](#)
2. [資料の整理と度数分布表](#)
3. [度数分布図の作成](#)

# 統計資料の尺度

## 尺度とは

「尺度」(scale)とは、データの特徴に対して数値を対応させる基準のことです。特徴別のデータの種類ともいえます。

尺度によって、計算(加減乗除)ができる／できないや、用いることができる統計的手法が異なってきます。

| データの種類 | 尺度の種類 | 尺度の意味              | 例(学生)  | 可能な計算      |
|--------|-------|--------------------|--------|------------|
| 量的データ  | 比尺度   | 原点(0という値)と比率に意味がある | 身長     | +, -, ×, ÷ |
|        | 間隔尺度  | 値の間隔に意味がある         | 体温     | +, -       |
| 質的データ  | 順序尺度  | 順序に意味がある           | テストの順位 | あまりできない    |
|        | 名義尺度  | 区別することに意味がある       | 学籍番号   | できない       |

## 尺度の種類

### 量的データ(測れるデータ)

- 比尺度、または、比例尺度(ratio scale)
  - ゼロが「何もない」、つまり基点(原点)として特別な意味を持つ
    - 例) 時間(経過時間)、速度、身長、体重、血圧など
  - 比率(データの掛け算・割り算)に意味があるため、データの加減乗除(+ - × ÷)ができる
    - ほとんどの統計量が意味を持ち、用いることができる分析手法が多い
- 間隔尺度(interval scale)
  - データがとる値に等間隔が保証されている
    - 例) 温度、テストの点数、時刻、立位体前屈の測定値など測定・検査結果など
  - 0という値が「何もない」状態を意味していない(値のひとつにすぎない)
  - 差(データの引き算)に意味があるため、データの加減乗除(+ - )はできるが、比率に意味がない
    - 平均値、中央値、最頻値、標準偏差(データの偏り具合)といった統計量が意味を持つ

### 質的データ(測れないデータ)

- 順序尺度(ordinal scale)
  - 順序に意味がある(大小、順序、方向)
    - 例) 満足度、順位、等級、アンケート調査の項目など
  - 大小関係にのみ意味があり、差(データの引き算)には意味がない
    - 計算することはあまりできないが、中央値(順番に並べたときに中央に位置する値)が意味を持つ
  - 心理学や教育学の調査・研究では、便宜上、間隔尺度とみなしてデータ解析する場合がある
- 名義尺度、または、類別尺度(nominal scale)
  - 区別にのみ意味がある(いわゆる指標や分類)
    - 例) 性別、血液型、国籍、人種、色、模様、都道府県など
  - データが数値であっても順番に意味はない
  - 計算することはできない

## 連続量と離散量

---

- 連続量 (1.12, 2.04, 3.14,...)
  - 飛び飛びの値を取らずに、値が連続的に変化する量
  - 例) 温度、長さ、重さ、速さ
- 離散量 (1, 2, 3,...)
  - 飛び飛びに値が変化する量 (少数の値をとらない)
  - 例) 人数、点数、順位、満足度のような評価値
  - 「離散量 = 質的データ」とは限らない (点数のように間隔尺度のデータもある)

# 資料の整理と度数分布表

## 統計資料の整理

記述統計学では、統計資料（データ）をまとめて整理して、直感的に理解できるように視覚化したり、特徴を代表的な数値にまとめて、資料の全体像が理解できるようにします。

ここでは、基本的な資料の整理方法である、度数分布表とヒストグラムについて説明します。

## 度数分布表とは

度数分布表（frequency table）とは、データを大きさの順に並び変えいくつかの区分にまとめた表で、データ全体の分布（distribution）を把握するために用います。

## 度数分布表の作成手順

1. 階級数または階級幅を決める
2. 階級値および有効桁数を考え、階級の境界（どこで区切るか）を決める
3. 各階級の度数を数える
4. 階級と度数を元に、度数分布表を作成し、必要に応じて分布の形を見たりする

| 階級      | 階級値   | 度数  | 累積度数 | 相対度数  | 累積相対度数 |
|---------|-------|-----|------|-------|--------|
| 90～99   | 94.5  | 2   | 2    | 1.0   | 1.0    |
| 100～109 | 104.5 | 6   | 8    | 3.0   | 4.0    |
| 110～119 | 114.5 | 16  | 24   | 8.0   | 12.0   |
| 120～129 | 124.5 | 22  | 46   | 11.0  | 23.0   |
| 130～139 | 134.5 | 24  | 70   | 12.0  | 35.0   |
| 140～149 | 144.5 | 30  | 100  | 15.0  | 50.0   |
| 150～159 | 154.5 | 44  | 144  | 22.0  | 72.0   |
| 160～169 | 164.5 | 26  | 170  | 13.0  | 85.0   |
| 170～179 | 174.5 | 15  | 185  | 7.5   | 92.5   |
| 180～189 | 184.5 | 11  | 196  | 5.5   | 98.0   |
| 190～199 | 194.5 | 2   | 198  | 1.0   | 99.0   |
| 200～209 | 204.5 | 1   | 199  | 0.5   | 99.5   |
| 210～219 | 214.5 | 1   | 200  | 0.5   | 100.0  |
| 計       |       | 200 |      | 100.0 |        |

## 用語

- 階級 (class)
  - データを区切るときの区間
  - 各階級でとりうる最大の値を上限、最小の値を下限という
- 階級数
  - いくつの区間に区切るかの区間の数
  - 一般には10前後が目安（多すぎても少なすぎてもいけない）
  - どのように区切るかは、キリのいい値や経験などを元にする場合があるが、客観的な区切り方を検討する場合はスタージスの方法（後述）などを用いる
- 階級幅 (class interval)
  - データをいくつ刻みに区切るかの区切る値の幅

- 階級値 (class mark)

- 各階級の中央の値

$$\text{階級値} = \{ (\text{階級の上限}) + (\text{階級の下限}) \} / 2$$

- 度数 (frequency)

- 各階級に含まれるデータの数 (階級ごとの頻度)

- 累積度数 (cumulative frequency)

- 階級値の小さい(または大きい)ほうから、ある階級までの度数を合計した値
- 最後の階級での累積度数は度数の合計になる

- 相対度数 (relative frequency)

- 度数の合計に対する各階級の度数の比 (全体を 100%=1 または 100 とする)

$$\begin{aligned} \text{相対度数} &= (\text{その階級の度数}) / (\text{全体の度数}) \\ \text{または} \\ \text{相対度数} &= (\text{その階級の度数}) / (\text{全体の度数}) \times 100 \end{aligned}$$

- 累積相対度数 (relative cumulative frequency)

- 階級値の小さい(または大きい)ほうから、ある階級までの相対度数を合計した値
- つまり、ある階級までの度数の合計が全体の何%かを示す
- 最後の階級での値は 100%=1 または 100 になる

$$\begin{aligned} \text{累積相対度数} &= (\text{各階級の累積度数}) / (\text{全体の度数}) \\ \text{または} \\ \text{累積相対度数} &= (\text{各階級の累積度数}) / (\text{全体の度数}) \times 100 \end{aligned}$$

## 階級数の算出

階級数を算出するときに、経験やキリのいい数字ではなく、何らかの客観的な理由が必要となる場合に、使用される方法がいくつかある。

- スタージス (Starges) の方法

- データの数が  $n$  個のとき、常用対数  $\log_{10}$  を用いて算出

$$1 + (3.322) \log_{10} n = 1 + \frac{\log_{10} n}{\log_{10} 2}$$

- シャリエ (Charier) の方法: 標準偏差の 1/3

- フィッシャー (Fisher) の方法: 標準偏差の 1/4

## Excelで度数分布表を作成

表計算ソフトの「Microsoft Excel」を使って、度数分布表を作成する場合、関数を使わなくても、四則演算 (+ - \* /) だけでも作成できます。

しかし、データ数が多い場合に度数を求めたり、度数などの合計を求めるときには、関数を使えばデータを処理しやすくなります。

## 度数分布表の作成で使用する関数

- 合計は、**SUM**関数を利用します。

### SUM(合計を計算する)

- 書式 : SUM(数値1, 数値2, ...)
- 引数 : 数値1, 数値2, ... : 平均を計算するセルの範囲
- 例 : B1 ~ B10セルまでのセルの数値の平均値を計算する

```
=SUM(B1:B10)
```


- 「値が60以上のセル」のように、特定の条件を満たすセルの個数を数えるには、**COUNTIF**関数を使います。

### COUNTIF(指定された範囲のセルのうち、検索条件に一致するセルの個数を返す)

- 書式 : COUNTIF(範囲, 検索条件)
- 引数 : 範囲 : 個数を求めるセルの範囲
- 引数 : 検索条件 : 個数を求めるセルの検索条件
- 例 : W1 ~ W10セルまでで値が「80以上」のセルの個数を数える

```
=COUNTIF(W1:W10, ">=80")
```

COUNTIF関数を利用して数式をつくると、「40以上60未満の値があるセルの数」を求めることができます。ただし、COUNTIF 関数には条件は1つしか設定できないため、ひとつの数式でCOUNTIF 関数を2つ使います。



たとえば、C1 ~ C7セルに上の図のように点数の値が入力されているとします。そのときに、「40以上60未満の値があるセルの数」を求める場合は、次のような数式になります

```
=COUNTIF(C1:C7, ">=40")-COUNTIF(C1:C7, ">=60")
```

つまり、「40以上の値があるセルの数」と「60以上の値があるセルの数」の差を求めればよいわけです。

# 度数分布図の作成


度数分布表は、データを表にまとめて全体的な傾向を値から読み取ることができます。その一方で、値をしっかりと読み取らなければ全体像を想像することはできません。

度数分布図は、データの分布を視覚的（図的）にとらえることができ、ひと目でデータの状況を把握することができます。

## 度数分布図の種類

### ヒストグラム（histogram；柱状図）

- 横軸を階級幅によって等間隔に区切り、各階級の度数にあわせた高さの柱を描いたもの
- 柱の面積が度数に比例するように描く
- データが連続量の場合は、柱と柱は隙間をあけないよう並べて描く



### 度数多角形

- 階級値を横軸に、度数を縦軸にとった折れ線グラフ
- ヒストグラムの各上辺の中点を直線で結んだもの
- 度数多角形の両端は基線（横軸）につけて描く

### 度数曲線

- 度数多角形をなめらかな曲線で近似
- 曲線下部の面積が度数多角形の下部の面積あるいはヒストグラムの面積と一致するように描く

### 幹葉表示

- ヒストグラムでは、分布の形状はわかって、データの詳細を把握するのは難しい
- データをすべて提示しつつ、かつ、分布がわかる方法として、ターキー (J. W. Tukey) が開発した手法
  - 度数分布表の階級を幹 (stem)、度数のもとである値を葉 (leaf) として表現する

次のようなデータを

90, 98, 100, 103, 104, 106, 109, 110, 110, 112, 113, 113, 115, 116, 116, 118,  
121, 121, 125, 126, 127, 129, 129, 131, 133, 133, 136, 142, 143

幹葉表示で表すと、このようになります。

```
幹 | 葉
9* | 0 8
10* | 0 3 4 6 9
11* | 0 0 2 3 3 3 5 6 6 8
12* | 1 1 5 6 7 9 9
13* | 1 3 3 6
14* | 2 3
```

## Excelでヒストグラムを作成

表計算ソフトの「Microsoft Excel」には、直接ヒストグラムを作成する機能はありません。

そのため、縦棒グラフを利用して、**すべての階級の階級幅が同じ場合**のヒストグラムを作成します。

### 縦棒グラフの作成

eラーニングの画面からダウンロードできるExcelのファイルを利用してみます。「度数分布図の練習(1)」というシートで作成します。


次のようにして、縦棒グラフを作成してみましょう。

1. 「Ctrl」キーを押しながらマウスをドラッグして、B2～B15セルとD2～D15セルを範囲選択する

|    | A | B                          | C     | D   |
|----|---|----------------------------|-------|-----|
| 1  |   | 収縮期血圧(mmHg)の度数分布表(テキスト 9ペー |       |     |
| 2  |   | 階級                         | 階級値   | 度数  |
| 3  |   | 90～99                      | 94.5  | 2   |
| 4  |   | 100～109                    | 104.5 | 6   |
| 5  |   | 110～119                    | 114.5 | 16  |
| 6  |   | 120～129                    | 124.5 | 22  |
| 7  |   | 130～139                    | 134.5 | 24  |
| 8  |   | 140～149                    | 144.5 | 30  |
| 9  |   | 150～159                    | 154.5 | 44  |
| 10 |   | 160～169                    | 164.5 | 26  |
| 11 |   | 170～179                    | 174.5 | 15  |
| 12 |   | 180～189                    | 184.5 | 11  |
| 13 |   | 190～199                    | 194.5 | 2   |
| 14 |   | 200～209                    | 204.5 | 1   |
| 15 |   | 210～219                    | 214.5 | +   |
| 16 |   | 計                          |       | 200 |

2. 「挿入」タブの「グラフ」グループにある「縦棒」ボタンをクリックする
3. メニューから「2-D縦棒」の「2-D集合縦棒」を選択する






#### 4. グラフが作成される

作成できたら、グラフに次の設定をしてください。

- 凡例は表示を「なし」にする
- グラフのタイトルを設定する
- 縦軸の軸ラベルを「(人)」と設定する




#### 棒グラフからヒストグラムへ

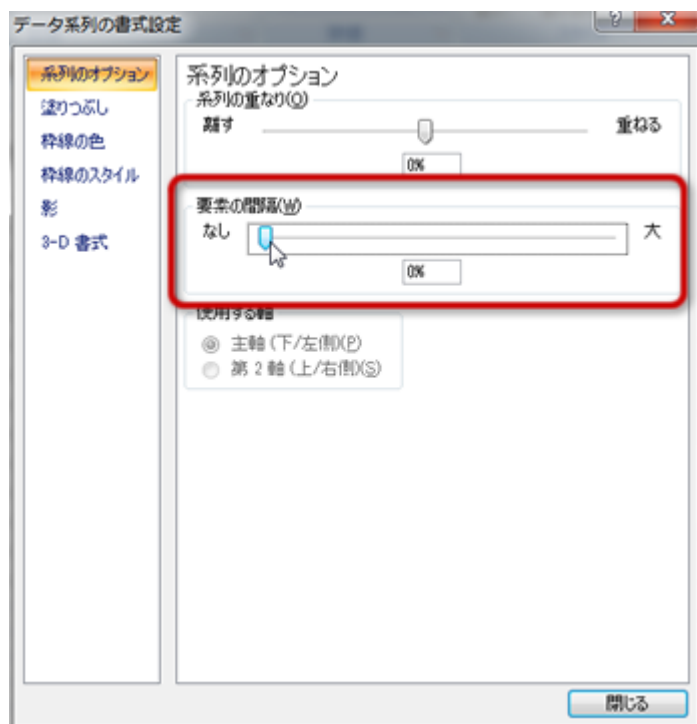
縦棒グラフのままでは、縦棒と縦棒の間に隙間があいてしまいます。

次のような設定をして、隙間をなくして、ヒストグラムの形にします。

1. グラフの縦棒部分をマウスで右クリックして、メニューから「データ系列の書式設定」を選択する



2. 「データ系列の書式設定」の書式設定が表示されたら、「系列オプション」の「要素の間隔」を「なし」(0%)に設定する



3. 「閉じる」ボタンをクリックすると、縦棒の隙間がなくなる