



薬学情報処理演習 第2回

# 表計算ソフトによる統計 処理



奥菌 透

コロイド・高分子物性学



# データの整理

参考文献: 東京大学教養学部統計学教室編  
「統計学入門」(東京大学出版会, 1991)

## □ 平均値と分散

- $N$  個の(数値)データ  $x_1, x_2, \dots, x_N$
- 平均値:  $\bar{x} = \frac{x_1 + x_2 + \dots + x_N}{N}$
- 分散:  $\sigma^2 = \frac{(x_1 - \bar{x})^2 + (x_2 - \bar{x})^2 + \dots + (x_N - \bar{x})^2}{N}$  ( $\sigma$ : 標準偏差)

## □ 度数分布

- 値  $X_1, X_2, \dots, X_n$  をとる度数(頻度):  $F_1, F_2, \dots, F_n$
- $\bar{x} = \frac{F_1 X_1 + F_2 X_2 + \dots + F_n X_n}{F_1 + F_2 + \dots + F_n}$        $N = F_1 + F_2 + \dots + F_n$
- $\sigma^2 = \frac{F_1 (X_1 - \bar{x})^2 + F_2 (X_2 - \bar{x})^2 + \dots + F_n (X_n - \bar{x})^2}{F_1 + F_2 + \dots + F_n}$

| 代表値 $X_i$ | 度数 $F_i$ |
|-----------|----------|
| 1         | 1        |
| 2         | 4        |
| 3         | 15       |
| 4         | 9        |
| 5         | 1        |

## □ チェビシェフの定理

$|x_i - \bar{x}| \leq \lambda \sigma$  ( $\lambda > 1$ ) を満たすデータの個数は  
 $N(1 - 1/\lambda^2)$  よりも大きい。


# データの分布

## 離散的なデータ

- 度数分布  $F_i$
- 確率  $f_i = F_i/N$

$$\bar{x} = \sum_{i=1}^n X_i f_i \quad \sigma^2 = \sum_{i=1}^n (X_i - \bar{x})^2 f_i$$


| 代表値 $X_i$ | 度数 $F_i$ |
|-----------|----------|
| 1         | 1        |
| 2         | 4        |
| 3         | 15       |
| 4         | 9        |
| 5         | 1        |



## 連続的なデータ

- 度数分布 → 分布関数  $F(x)$   
( $N \rightarrow \infty, \Delta x = X_{i+1} - X_i \rightarrow 0$ )
- 確率密度  $f(x) = F(x)/\tilde{N}$   
( $\tilde{N} = \int F(x)dx$ )

| 級              | $X_i$ | $F_i$ |
|----------------|-------|-------|
| $0 < x \leq 1$ | 0.5   | 1     |
| $1 < x \leq 2$ | 1.5   | 4     |
| $2 < x \leq 3$ | 2.5   | 15    |
| $3 < x \leq 4$ | 3.5   | 9     |
| $4 < x \leq 5$ | 4.5   | 1     |




$$\bar{x} = \int x f(x) dx \quad \sigma^2 = \int (x - \bar{x})^2 f(x) dx$$

# 正規分布(ガウス分布)

- 実験的に測定される量には“ばらつき”がある。  
ばらつき＝平均値からのずれは以下のガウス分布に従うことが多い。なぜか？

$$f(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{x^2}{2\sigma^2}} \quad (\sigma^2 : \text{分散})$$




## 中心極限定理

$n$  個の独立な確率変数  $u_i$  (分散  $s_i^2$  平均値0)  
からなる確率変数

$$x_n = (u_1 + u_2 + \cdots + u_n) / \sqrt{\sigma_n^2} \quad \sigma_n^2 = s_1^2 + s_2^2 + \cdots + s_n^2$$

は、 $n \rightarrow \infty$  で分散1, 平均値0の正規分布に従う。

- ばらつき＝多数の確率的事象の和



## 疑似乱数の生成

- コンピュータ上でランダムな数(乱数)を次々に生成し、ランダムなデータを作ることができる。エクセルでは RAND() という関数を用意されている。
- RAND()で生成される乱数は一様分布関数

$$f(x) = 1 \quad (0 \leq x < 1)$$

に従い、平均と分散は、

$$\bar{x} = \int_0^1 x f(x) dx = \frac{1}{2} \quad \sigma^2 = \int_0^1 (x - \bar{x})^2 f(x) dx = \frac{1}{12}$$

となるので、平均0の一様乱数(RAND()-0.5)を12個足し合わせたものは、近似的に、平均0分散1の正規分布に従う乱数(正規乱数)となっている。

# Excel での正規乱数発生方法

## □ データ分析ツールの利用 (関数ではない)

- データ/分析/データ分析/乱数発生

## □ 中心極限定理の応用


- (12個の一樣乱数の和) - 6
- =rand()+rand()+...+rand()-6.0


## □ 逆関数法

- =norm.inv(rand(),0,1)または  
=norm.s.inv(rand())を用いる
- 分布 $f(x)$ の累積分布を $F(x)$ とする

$$y = F(x) = \int_{-\infty}^x f(u) du$$


$$\frac{dy}{dx} = f(x), \quad dy = f(x) dx$$





## 演習課題



- 上記の3つの方法で、それぞれ $N$ 個の正規乱数を発生させる( $N = 10000$  程度)。
- 上で得られたデータに対する分布関数のグラフを描く。
  - 分析ツール(後述)を用いて、度数分布表を作る。
  - 規格化された分布関数のデータを計算する。
  - 得られた分布関数のデータをグラフに描き、理論曲線と比較する。
  - (余裕があれば)平均値と分散を計算し、理論値と比較する。




# データの作成

- 分析ツールを使って正規乱数を発生
- RAND()を使って12個の一樣乱数を足し合わせて正規乱数を生成
- 逆関数法により正規乱数を発生

| excel   | rand                   | inv.func            |
|---------|------------------------|---------------------|
| (分析ツール) | =rand()+...+rand()-6.0 | =norm.s.inv(rand()) |
| ...     | ...                    | ...                 |





# 度数分布表の作成

- エクセルで度数分布を作る方法はいろいろあるが、ここでは「分析ツール」を使う。これを使用可能とするには、**ファイル/オプション/アドイン/設定** で「分析ツール」を選択し「OK」をクリックする。
- データ区間(級)を作成する。
- 分析ツールを使う
  - **データ/分析/データ分析/ヒストグラム**
  - 入力範囲、データ区間を指定
  - 出力先を選択・指定

| データ区間 |
|-------|
| -4.5  |
| -4.3  |
| -4.1  |
| -3.9  |
| ...   |
| 4.3   |
| 4.5   |

# 分布関数データの作成

- 分析ツールで得られた度数分布表を用いる。
- 代表値、規格化された分布関数データを作成


規格化:  $\sum_n F_n \Delta x = \mathcal{N} \quad \Rightarrow \quad \sum_n f_n \Delta x = 1, \quad f_n = F_n / \mathcal{N}$

| データ区間 | 頻度               | 代表値 x      | 分布 f(x)     |
|-------|------------------|------------|-------------|
| -4.5  | 0                |            |             |
| -4.3  | 1                | =(A2+A3)/2 | =B2/\$B\$49 |
| ...   | ...              | ...        | ...         |
| 4.5   | 0                | ...        | ...         |
| 次の級   | 0                |            |             |
| 積分値   | =SUM(B2:B47)*0.2 |            |             |

$$f_n = F_n / \mathcal{N}$$


 $\mathcal{N}$ 

 $\Delta x$  : データ区間の増分値



# 理論曲線データの作成

## □ 正規分布のデータを作成する。

| 代表値 $x$ | 正規分布                        |
|---------|-----------------------------|
| -4.5    | =NORM.DIST(C3, 0, 1, FALSE) |
| ...     | ...                         |

- 関数NORM.DIST( $x, \bar{x}, \sigma^2, \text{FALSE}$ ) は $x$ の値に対する平均 $\bar{x}$  分散 $\sigma^2$  の正規分布  $f(x)$  の値を返す。
- NORM.S.DIST( $x, \text{FALSE}$ ) は NORM.DIST( $x, 0, 1, \text{FALSE}$ ) と同じ。
- 最後の引数がFALSEの場合、(密度)分布関数を、TRUEの場合、累積分布関数を返す。


# グラフの作成

## 分布関数のグラフ

- 横軸に代表値、縦軸に確率密度分布をとる。
- 理論値と度数分布から得られたデータを比較する。


### NORMAL DISTRIBUTION

— theory    ■ excel    ▲ rand    × inv.func



| 方法       | 平均       | 分散       |
|----------|----------|----------|
| theory   | 0        | 1        |
| excel    | -0.00982 | 1.007028 |
| rand     | 0.01078  | 1.019344 |
| inv.func | -0.02518 | 1.015754 |

データ数:  $N = 10000$



# 分析ツールを使わずに分布関数のデータを作成する。(補足)

- 元データの作成(データの作成参照)
- COUNTIF(範囲,検索条件)を使って累積度数分布を作成。規格化して累積分布関数を得る。
- 累積分布関数を微分して確率密度関数を得る。

|   | B        | C     | D    | E      | F    | G     |
|---|----------|-------|------|--------|------|-------|
| 1 | 正規乱数     | データ区間 | 累積度数 | 累積分布   | 代表値  | 確率密度  |
| 2 | -1.52061 | -4.5  | 0    | 0      |      |       |
| 3 | -1.37599 | -4.3  | 0    | 0      | -4.4 | 0     |
| 4 | 2.411254 | -4.1  | 0    | 0      | -4.2 | 0     |
| 5 | -0.64805 | -3.9  | 0    | 0      | -4   | 0     |
| 6 | 0.113184 | -3.7  | 0    | 0      | -3.8 | 0     |
| 7 | 0.397722 | -3.5  | 2    | 0.0002 | -3.6 | 0.001 |
| 8 | 0.260922 | -3.3  | 6    | 0.0006 | -3.4 | 0.002 |

**[D2]=COUNTIF(\$B\$2:\$B\$10001,"<="&C2)**

B列のデータのうちC2の値以下であるデータの数を返す。

**[E2]=D2/D\$47**

累積度数の最後の値(=全データ数)で割って規格化する。

**[G3]=(E3-E2)/0.2**

累積分布を微分する。0.2はデータ区間の増分値。