

Rで始めるデータサイエンス③

Rを使って
区間推定

1. ネジが沢山！長さは？ ～区間推定
2. 長さは規格に準拠？ ～標本平均
3. 区間推定の数理 ～確率分布
4. Rで区間推定 ～場合分け

ネジの長さを調べたい

物凄く沢山のネジ
(L 個)



それぞれの長さは x_i
($i = 1, 2, \dots, L$)




全部の平均 = $\frac{x_1 + x_2 + \dots + x_L}{L}$
を知りたい



全部 (L 個) を調査したい
けど、多過ぎて無理！

ネジを無作為に抽出する

物凄く沢山
全部は調査できない！



数個を抽出 (n 個)
少数なら調査できる！

無作為に
抽出する



$$\text{標本の平均} = \frac{19+18+20+17}{4} = 18.5$$

抽出するたびに 値がバラつく

物凄く沢山
全数調査は無理！



数個を抽出 (n 個)
調査できるが
値がバラバラ*

無作為に
抽出

標本平均1 = 19.5

標本平均2 = 17.5

標本平均3 = 18.5

⋮ ⋮

*値が確率的に変動する

全数調査できたら 平均 はどの 範囲？

物凄く沢山
全数調査は無理！

数個を抽出 (n 個)
1 回だけ標本調査する



無作為に抽出

標本の平均
標本の分散

下限 < 全数の平均 < 上限
95%の信頼区間
(下限と上限を知りたい)

「区間推定」にできること

物凄く沢山
全数調査は無理！

数個を抽出 (n 個)
1 回だけ標本調査する

無作為
に抽出

標本の平均
標本の分散

区間推定に
できること

下限 < 全数の平均 < 上限
95%の信頼区間
(下限と上限を知りたい)

「区間推定」の例

全数調査して
平均を知りたい
(分散 σ^2 は既知※)

↓ 無作為
に抽出

標本調査の結果
標本の個数 n
標本の平均 \bar{X}



下限 < 全数の平均 < 上限
95%の信頼区間

↑ 区間推定の結果

下限は $\bar{X} - 2.0 \sigma / \sqrt{n}$
上限は $\bar{X} + 2.0 \sigma / \sqrt{n}$

※何故、こうなるかを学習します

※分散が未知の場合は後ほど説明

区間推定の例

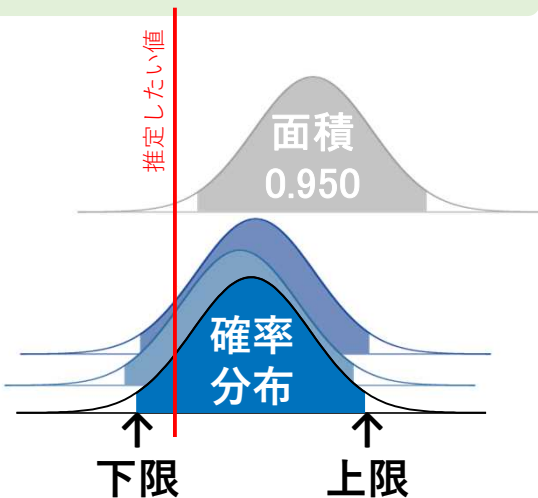
「95%の信頼区間」とは？

下限 < 推定したい値 < 上限


区間推定を100回
繰り返したら...




そのうち 95 回は
推定したい値が
この区間内に入る




正規分布 $N(0, \sigma^2)$ の場合



$\pm 1.96 \sigma$ 95.0%の信頼区間



$\pm 2.00 \sigma$ 95.4%の信頼区間



$\pm 1.00 \sigma$ 68.3%の信頼区間

Rで始めるデータサイエンス③

Rを使って 区間推定

1. ネジが沢山！長さは？ ～区間推定
2. 長さは規格に準拠？ ～標本平均
3. 区間推定の数理 ～確率分布
4. Rで区間推定 ～場合分け

規格に準拠しているか？（1/4）

- 規格の下で、長さ **20** のネジを生産している
- これまでは、平均 20、**標準偏差は 1 だった**

※ネジの長さは正規分布すると仮定



- 機械を刷新したら、長さが変わったようだ
- 無作為に 36 個抽出したら、その平均が **20.5** だった（規格より 0.5 長い）
- 長さ 20 という **規格に準拠しているか？**

標準偏差はこれまでと同じ 1 である

規格に準拠しているか？（2/4）

標本の個数 $n = 36$ **全数の標準偏差** $\sigma = 1$

標本の平均 $\bar{X} = 20.5$ ※ネジの長さは正規分布すると仮定

- 平均が 20.5 なので、規格より 0.5 長い
- どの 36 個を抽出するかで、平均はバラつく
- バラツキの範囲を求めよう

下限は $20.5 - 2/\sqrt{36} = 20.2$

上限は $20.5 + 2/\sqrt{36} = 20.8$


$\bar{X} - 2.0 \sigma / \sqrt{n}$

$\bar{X} + 2.0 \sigma / \sqrt{n}$

先ずは使ってみましょう

規格に準拠しているか？ (3/4)

20.2 < 全数の平均 < 20.8
 下限 上限



規格より長くなっている
 ※ 抽出の数を増やせば
 範囲はもっと狭くなる

規格に準拠していない

規格に準拠しているか？ (4/4)

全数の長さの
 平均を知りたい
 (標準偏差は $\sigma = 1$)
 長さは正規分布すると仮定

無作為
 に抽出

標本の個数 36
 標本の平均 20.5

点として推定

20.2 < 全数の平均 < 20.8
 95%の信頼区間

区間として推定

下限は $20.5 - 2/\sqrt{36} = 20.2$
 上限は $20.5 + 2/\sqrt{36} = 20.8$

※何故こうなるかは、後ほど説明

区間を絞って精度を上げるには？

ネジを大量生産する機械を刷新したら、
ネジが長くなった気がする。

5個を無作為に抽出して区間推定したら、
 20 ± 1 (mm) だった (区間幅が ± 1)。

区間幅を ± 0.1 未満とするには、
何個を抽出する必要があるか？ 但し、標準偏差は $\sigma = 1.12$ とする

全数の平均 $\mu = 20 \pm 1$
↓
 ± 0.1 未満にしたい

区間を絞って精度を上げるには？

n 個を無作為に抽出して区間推定して、
 20 ± 0.1 とするには、

$$20 + 2\sigma/\sqrt{n} < 20 + 0.1 \quad \text{但し、標準偏差は } \sigma = 1.12 \text{ とする}$$

が必要なので、

$$2\sigma/\sqrt{n} < 0.1$$

$$n > \left(\frac{2 \times 1.12}{0.1} \right)^2 = 501.8 \quad \text{502 個 以上を調べる 必要がある!}$$

効果10倍、努力100倍

下限 < 全部の平均 < 上限

95%の信頼区間



区間推定の結果

標本数を n とする

区間の幅は
ルート n に
反比例する

下限は $\bar{X} - 2\sigma/\sqrt{n}$

上限は $\bar{X} + 2\sigma/\sqrt{n}$

幅を 1/10 にするには
100倍の標本調査が必要

区間推定の例

Rで始めるデータサイエンス③

Rを使って 区間推定

1. ネジが沢山！長さは？ ～区間推定
2. 長さは規格に準拠？ ～標本平均
3. 区間推定の数理 ～確率分布
4. Rで区間推定 ～場合分け

信頼区間、母平均、母分散

母集団の全てを調べて
母平均 μ を知りたい

母集団は正規分布すると仮定

母分散 σ^2 は既知※

下限 < 母平均 μ < 上限

95%の信頼区間

↓ 無作為
に抽出



標本調査の結果

標本の個数 n

標本の平均 \bar{X}

下限は $\bar{X} - 1.96 \frac{\sigma}{\sqrt{n}}$
上限は $\bar{X} + 1.96 \frac{\sigma}{\sqrt{n}}$

※母分散が未知の場合は後ほど説明


信頼区間は確率分布で決まる

$$\bar{X} - 1.96 \frac{\sigma}{\sqrt{n}} < \mu < 1.96 \frac{\sigma}{\sqrt{n}} + \bar{X}$$

$$-1.96 \frac{\sigma}{\sqrt{n}} < \mu - \bar{X} < 1.96 \frac{\sigma}{\sqrt{n}}$$

$$-1.96 < \frac{\mu - \bar{X}}{\sigma/\sqrt{n}} < 1.96$$

↑
この値の確率分布



下限 < 母平均 μ < 上限

95%の信頼区間

下限は $\bar{X} - 1.96 \frac{\sigma}{\sqrt{n}}$
上限は $\bar{X} + 1.96 \frac{\sigma}{\sqrt{n}}$

母分散 σ^2 は既知のとき
 X は正規分布すると仮定

データの標準化とは？

平均 μ
分散 σ^2/n の
正規分布に従う

正規分布 $N(\mu, \sigma^2/n)$

確率変数 \bar{X}

X が正規分布するならば
 \bar{X} も正規分布する




データの標準化

平均 0
分散 1 の
正規分布に従う

標準正規分布 $N(0,1)$

$$\frac{\bar{X} - \mu}{\sqrt{\sigma^2/n}}$$

標準正規分布 $N(0,1)$



区間幅が \sqrt{n} に反比例する理由

n 個の平均

$$E[X] = \frac{X_1 + X_2 + \dots + X_n}{n} = \bar{X}$$

n 個の平均の分散

$$\begin{aligned} V[\bar{X}] &= V\left[\frac{X_1 + X_2 + \dots + X_n}{n}\right] \\ &= \frac{V[X_1 + X_2 + \dots + X_n]}{n^2} \\ &= \frac{V[X_1] + V[X_2] + \dots + V[X_n]}{n^2} \\ &= \frac{\sigma^2}{n} \end{aligned}$$

$$\frac{X_1 + X_2 + \dots + X_n}{n} \rightarrow \mu$$

根拠
!

標本平均 \bar{X} は
平均が μ
標準偏差が σ/\sqrt{n}
の正規分布に従う

中心極限定理による
(n が大きいとき)

➡ \bar{X} の標準偏差は σ/\sqrt{n}

➡ \bar{X} は μ に収束 ($n \rightarrow \infty$)

Rで始めるデータサイエンス③

Rを使って
区間推定

1. ネジが沢山！長さは？ ～区間推定
2. 長さは規格に準拠？ ～標本平均
3. 区間推定の数理 ～確率分布
4. Rで区間推定 ～場合分け

場合分け

	母集団 全ての個体、正規分布		標本 無作為に抽出した n 個	
	母平均	母分散	標本平均	標本分散
場合1	推定する	既知	データから計算	不要
場合2		未知	データから計算する	

	母集団 × 2つ※ 全ての個体、正規分布		標本 × 2つ 無作為に抽出した m 個と n 個	
	母平均の差	母分散	標本平均	標本分散
場合3	推定する	既知	データから計算	不要
場合4		未知	データから計算する	

※ 2標本問題と呼ばれる


場合 1

	母集団 全ての個体、正規分布		標本 無作為に抽出した n 個	
	母平均 μ	母分散 σ	標本平均 \bar{X}	標本分散
場合 1	推定する	既知	データから計算	不要

$$-z_{\alpha}^* \leq \frac{\mu - \bar{X}}{\sigma/\sqrt{n}} \leq z_{\alpha}^*$$

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$$

↑
標準正規分布 $N(0,1)$ に従う



z_{α}^* は両側 α 点
信頼度 $100(1 - \alpha) \%$

信頼度90% $\rightarrow \alpha = 0.10 \rightarrow z_{0.10}^* = 1.64$
 信頼度95% $\rightarrow \alpha = 0.05 \rightarrow z_{0.05}^* = 1.96$
 信頼度99% $\rightarrow \alpha = 0.01 \rightarrow z_{0.01}^* = 2.58$

数式表現のまとめ (1/2)

$$-z_{\alpha}^* \leq \frac{\mu - \bar{X}}{\sigma/\sqrt{n}} \leq z_{\alpha}^* \quad \Rightarrow \quad \left| \frac{\mu - \bar{X}}{\sigma/\sqrt{n}} \right| \leq z_{\alpha}^*$$

↑
両側
 α 点

↑
標準化

$$\bar{X} - z_{\alpha}^* \frac{\sigma}{\sqrt{n}} \leq \mu \leq \bar{X} + z_{\alpha}^* \frac{\sigma}{\sqrt{n}}$$

100(1 - α) % の
信頼区間

$$\mu \in \left[\bar{X} - z_{\alpha}^* \frac{\sigma}{\sqrt{n}}, \bar{X} + z_{\alpha}^* \frac{\sigma}{\sqrt{n}} \right]$$

数式表現のまとめ (2/2)


$$-z_{\alpha}^* \leq \frac{\mu - \bar{X}}{\sqrt{\sigma^2/n}} \leq z_{\alpha}^*$$



Z は標準正規分布
 $N(0,1)$ に従う



$$Z = \frac{\mu - \bar{X}}{\sigma/\sqrt{n}} \sim N(0,1)$$



$$P\left\{\left|\frac{\mu - \bar{X}}{\sigma/\sqrt{n}}\right| \leq z_{\alpha}^*\right\} = 1 - \alpha$$

両側 α 点


場合2

	母集団 全ての個体、正規分布		標本 無作為に抽出した n 個	
	母平均 μ	母分散	標本平均 \bar{X}	標本不偏分散 $\hat{\sigma}^2$
場合2	推定する	未知	データから計算	

$$-t_{n-1,\alpha}^* \leq \frac{\mu - \bar{X}}{\hat{\sigma}/\sqrt{n}} \leq t_{n-1,\alpha}^*$$



自由度 $n-1$ の t 分布 に従う



$$\hat{\sigma}^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$$

$t_{n-1,\alpha}^*$ は両側 α 点
信頼度 $100(1 - \alpha) \%$

$$t_{9,0.05}^* = 2.262 \quad (n = 10)$$

$$t_{19,0.05}^* = 2.093 \quad (n = 20)$$

母平均の信頼区間（まとめ）

$100(1 - \alpha) \%$


場合1（母分散が既知）

$$\mu \in \left[\bar{X} - z_{\alpha}^* \frac{\sigma}{\sqrt{n}}, \bar{X} + z_{\alpha}^* \frac{\sigma}{\sqrt{n}} \right]$$


場合2（母分散が未知）

$$\mu \in \left[\bar{X} - t_{n-1, \alpha}^* \frac{\hat{\sigma}}{\sqrt{n}}, \bar{X} + t_{n-1, \alpha}^* \frac{\hat{\sigma}}{\sqrt{n}} \right]$$


Rで区間推定 pnorm



> pnorm(-1, mean=0, sd=1)
[1] 0.1586553




> pnorm(+1, mean=0, sd=1)
[1] 0.8413447



> pnorm(+1) - pnorm(-1)
[1] 0.6826895

mean=0, sd=1
のときは省略可


Rで区間推定 `qnorm`



青い部分の面積が指定した値となるときの横軸の値

```
> qnorm(0.1586553)
[1] -0.9999998
```

```
> qnorm(pnorm(-1))
[1] -1
```



```
> alp <- 0.05
> qnorm(alp/2)
[1] -1.959964
```

両側α点 z_{α}^* は `qnorm($\alpha/2$)` で計算

場合1 ネジの長さは同じか？

今までは、平均 19 mm でネジを生産していた。
標準偏差は 2 mm だった。

機械を刷新したら、長くなったようなので、
調べて欲しい。

機械を刷新した後（無作為に抽出したサンプル）
ネジの長さは、{20, 21, 21, 19, 24}



母平均 μ の信頼区間 95% を示す
ここで、母標準偏差 $\sigma = 2$ とする

場合1

データを準備
 標本の数 $n = 5$
 標本平均 $\bar{X} = 21$
 母標準偏差 $\sigma = 2$

両側 α 点 $z_{\alpha}^* = 1.96$
 ($\alpha = 0.05$ で 95%)
 $\Delta = z_{\alpha}^* \frac{\sigma}{\sqrt{n}} = 1.75$

95%の信頼区間
 $\mu \in [\bar{X} - \Delta, \bar{X} + \Delta]$
 $= [19.2, 22.8]$

今までは 19 だったが、刷新後は長くなった

R のプログラム

```
x <- c(20, 21, 21, 19, 24)
n <- length(x)
xbr <- mean(x)
sgm <- 2
```

```
alp <- 0.05
z <- -qnorm(alp/2)
dlt <- z*sgm/sqrt(n)
```

```
c(xbr-dlt, xbr+dlt)
[1] 19.24695 22.75305
```

場合2 ネジの長さは同じか？

今までは、平均 19 mm でネジを生産していた。
 なお、標準偏差は測定していないので不明。

機械を刷新したら、長くなったようなので、
 調べて欲しい。

機械を刷新した後（無作為に抽出したサンプル）
 ネジの長さは、{20, 21, 21, 19, 24}



母平均 μ の信頼区間 95% を示す
 この場合、標本標準偏差 $\hat{\sigma}$ を使う

場合2

データを準備

標本の数 $n = 5$

標本平均 $\bar{X} = 19 + 2$

標本標準偏差 $\hat{\sigma} = 1.87$

両側 α 点 $t_{n-1, \alpha}^* = 2.78$

($\alpha = 0.05$ で 95%)

$\Delta = t_{n-1, \alpha}^* \frac{\hat{\sigma}}{\sqrt{n}} = 2.32$

95%の信頼区間

$\mu \in [\bar{X} - \Delta, \bar{X} + \Delta]$
 $= [18.7, 23.3]$

今までは19で、刷新後の **+2** はバラツキの範囲内

R のプログラム

```
x <- c(20, 21, 21, 19, 24)
```

```
n <- length(x)
```

```
xbr <- mean(x)
```

```
sgm <- sd(x)
```

```
alp <- 0.05
```

```
z <- -qt(alp/2, n-1)
```

```
dlt <- z*sgm/sqrt(n)
```

```
c(xbr-dlt, xbr+dlt)
```

```
[1] 18.67706 23.32294
```

場合2 別解

R の特長を活かした 超簡単なプログラム

たったこれだけ

```
> x <- c(20, 21, 21, 19, 24)
```

```
> t.test(x, mu=19)
```



One Sample t-test

```
data: x
```

```
t = 2.3905, df = 4, p-value = 0.07513 ← p値
```

```
alternative hypothesis: true mean is not equal to 0
```

95 percent confidence interval:

18.67706 23.32294

```
sample estimates:
```

```
mean of x      21
```

95%の信頼区間
を一瞬で計算
 $\mu \in [18.7, 23.3]$

まとめ

- 今までは、長さが平均で **19** となる様に生産していた
- 機械を刷新したら、長さが変わったようだ
- 5個を抽出して測ったら **{20, 21, 21, 19, 24}** だった
- これらの平均は **21** なので、今までとの「**差は +2**」
- これでは、規格を満たさないのでは？

長さの平均は無作為に5個を抽出する度にバラつくが、

場合1 (母分散が **既知**) では、規格の基準**19** が、信頼区間である **[19.2, 22.8]** の範囲**外** なので、**長さの差が無い** とは言えない


場合2 (母分散が **未知**) では、規格の基準**19** が、信頼区間である **[18.7, 23.3]** の範囲**内** なので、**長さの差が無い** と言える

帰無仮説

場合1 では、規格の基準**19** が、信頼区間である **[19.2, 22.8]** の範囲**外** なので、

長さには差がありそう
(帰無仮説は **棄却**される)


※ 長さの差は「有意」である。



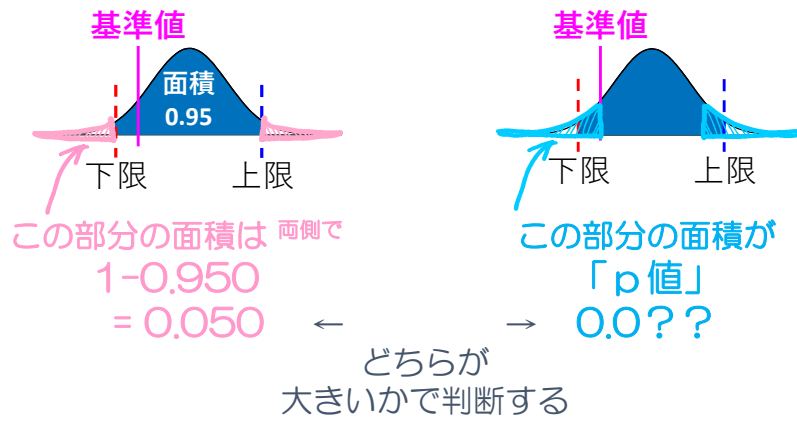
場合2 では、規格の基準**19** が、信頼区間である **[18.7, 23.3]** の範囲**内** なので、

長さには差が無さそう
(帰無仮説は **採択**される)

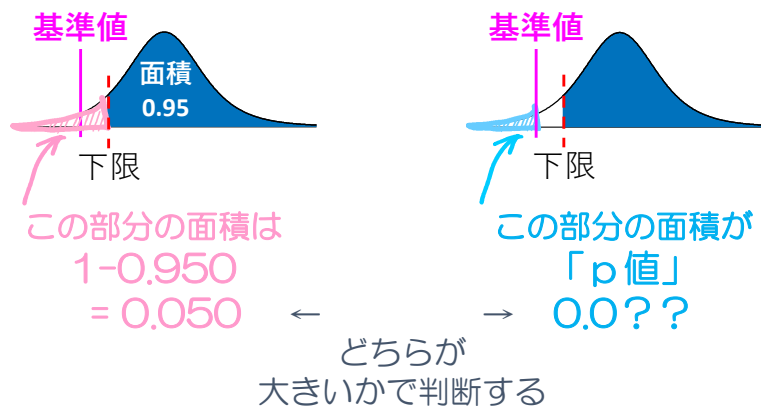
※ nが小さすぎるかも。長さが同じとまでは言えない。



「p 値」



「片側検定」



2標本問題

場合3

	母集団×2つ 全ての個体、正規分布		標本×2つ 無作為抽出した m 個と n 個	
	母平均の差 $\mu_1 - \mu_2$	母分散 σ_1^2 と σ_2^2	標本平均 \bar{X}_1 と \bar{X}_2	標本分散
場合3	推定する	既知	データから計算	不要

$$\bar{X}_1 = \frac{1}{m} \sum_{i=1}^m X_{1,i} \quad \bar{X}_2 = \frac{1}{n} \sum_{i=1}^n X_{2,i}$$

母平均の差 $\mu_1 - \mu_2$ の $100(1 - \alpha)\%$ の信頼区間

$$\mu_1 - \mu_2 \in \left[\bar{X}_1 - \bar{X}_2 - z_{\alpha}^* \sqrt{\frac{\sigma_1^2}{m} + \frac{\sigma_2^2}{n}}, \bar{X}_1 - \bar{X}_2 + z_{\alpha}^* \sqrt{\frac{\sigma_1^2}{m} + \frac{\sigma_2^2}{n}} \right]$$

場合4

	母集団×2つ 全ての個体、正規分布		標本×2つ 無作為抽出した m 個と n 個	
	母平均の差 $\mu_1 - \mu_2$	母分散 σ_1^2 と σ_2^2	標本平均 \bar{X}_1 と \bar{X}_2	合併 標本分散 $\hat{\sigma}^2$
場合3	推定する	未知	データから計算	

$$\hat{\sigma}^2 = \frac{1}{m+n-2} \left\{ \sum_{i=1}^m (X_{1,i} - \bar{X}_1)^2 + \sum_{i=1}^n (X_{2,i} - \bar{X}_2)^2 \right\}$$


母平均の差 $\mu_1 - \mu_2$ の $100(1 - \alpha)\%$ の信頼区間

$$\mu_1 - \mu_2 \in \left[\bar{X}_1 - \bar{X}_2 - t_{m+n-2, \alpha}^* \sqrt{\frac{\hat{\sigma}^2}{m} + \frac{\hat{\sigma}^2}{n}}, \bar{X}_1 - \bar{X}_2 + t_{m+n-2, \alpha}^* \sqrt{\frac{\hat{\sigma}^2}{m} + \frac{\hat{\sigma}^2}{n}} \right]$$

付録1

Rをインストールする

Rをダウンロード (1/2)

<https://cran.r-project.org/> 



CRAN

[Mirrors](#)

[What's new?](#)

[Search](#)

About R

[R Homepage](#)

[The R Journal](#)

The Comprehensive R Archive Network

Download and Install R

Precompiled binary distributions of the base system and contributed packages, **Windows and Mac** users most likely want one of these versions of R:

- [Download R for Linux \(Debian, Fedora/Redhat, Ubuntu\)](#)
- [Download R for macOS](#)
- [Download R for Windows](#) 

R is part of many Linux distributions, you should check with your Linux package management system in addition to the link above.

Source Code for all Platforms

[base](#)

Binaries for base distribution. This is what you want to [install R for the first time.](#) 

Rをダウンロード (2/2)



CRAN

[Mirrors](#)

[What's new?](#)

[Search](#)

R-4.2.1 for Windows

[Download R-4.2.1 for Windows \(79 megabytes, 64 bit\)](#) 

[README on the Windows binary distribution](#)
[New features in this version](#)

This build requires UCRT, which is part of Windows since Windows 10 and Windows Server 2016. On older systems, UCRT has to be installed manually from [here](#).

R-4.2.1-win.exe (78.7MB) を入手して実行する



このアイコンをクリック
するとRが動く

Rを動かしてみる

RGui (64-bit) - [R Console]

ファイル 編集 閲覧 その他 パッケージ ウィンドウ ヘルプ

R version 4.2.1
Copyright (C) 2022
Platform: x86_64

R は、自由なソフトウェアの
一定の条件に従えば、
配布条件の詳細に関

R は多くの貢献者による共同プロジェクトです。
詳しくは 'contributors()' と入力してください。
また、R や R のパッケージを出版物で引用する際の形式については
'citation()' と入力してください。

'demo()' と入力すればデモをみることができます。
'help()' とすればオンラインヘルプが出ます。
'help.start()' で HTML ブラウザによるヘルプが
'q()' と入力すれば R を終了します。

```
> r=2
> pi*r^2
[1] 12.56637
>
```

赤文字を入力すると
紺文字の答えがでた

国立大学法人
長岡技術科学大学 Iwahashi
Nagasaki University of Technology

47

Rで計算してみる

```
> r=2
> pi*r^2
[1] 12.56637
```

$r = 2$
 πr^2

☞ Rに入力：赤文字
☞ Rの出力：紺文字

記号「<-」は代入

```
> r <- c(2, 3, 4)
> pi*r^2
[1] 12.56637 28.27433 50.26548
```

$r = [2 \ 3 \ 4]$
 πr^2

```
> pi*r^2 -> a
> mean(a)
[1] 30.36873
```

$a = \pi r^2$
 $E[a]$

> sum(a)/3
[1] 30.36873

国立大学法人
長岡技術科学大学 Iwahashi
Nagasaki University of Technology

48

統計量を計算してみる

データ $x \leftarrow c(1, 2, 3, 4)$ $x_i, i=1,2,3, \dots, n$

平均 $\text{mean}(x)$
2.5

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n x_i$$

不偏分散 $\text{var}(x)$
1.666667

$$\hat{\sigma}_x^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{X})^2$$

標準偏差 $\text{sd}(x)$
1.290994

$$\hat{\sigma}_x = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{X})^2}$$


プロットしてみる (1/3)

データ y をプロットしたい
 $y = [0 \ 1 \ 2 \ 4 \ 8]$



$y \leftarrow c(0,1,2,4,8)$
 $\text{plot}(y)$

R に入力



プロットしてみる (2/3)

x と y の **散布図** をみたい

$x = [0 \ 1 \ 2 \ 4 \ 8]$

$y = [0 \ 1 \ 2 \ 4 \ 8]$




`x <- c(0,1,2,4,8)`

`y <- c(0,1,2,4,8)`

`plot(x,y)`


R に入力



プロットしてみる (3/3)

-5 から 5 までの範囲の
標準正規分布


`curve(dnorm, -5,5)`



0 から 2π までの範囲で
cos をプロット

`plot(cos, 0, 2*pi)`

R に入力



付録2

カイ自乗分布 と ティー分布

各種統計量の確率分布

全データ

母平均 μ
母分散 σ^2
正規分布

無作為
に抽出

標本のデータ

標本の
平均

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$$

標本の
不偏分散

$$\hat{\sigma}^2 = \sum_{i=1}^n \frac{(X_i - \bar{X})^2}{n-1}$$

\bar{X} は正規分布
(平均 μ , 分散 σ^2/n)

$\frac{\bar{X} - \mu}{\sigma/\sqrt{n}}$ は
平均 0, 分散 1 の正規分布

$\frac{\bar{X} - \mu}{\hat{\sigma}/\sqrt{n}}$ は
自由度 $n-1$ のティール分布

$\frac{(n-1)\hat{\sigma}^2}{\sigma^2}$ は
自由度 $n-1$ のカイ自乗分布

各種統計量の区間推定

$1-\alpha$ の確率で
以下の区間に入る

$$\mu \in \left[\bar{X} - z_{\alpha}^* \frac{\sigma}{\sqrt{n}}, \bar{X} + z_{\alpha}^* \frac{\sigma}{\sqrt{n}} \right]$$

\bar{X} は正規分布に従う
(平均 μ , 分散 σ^2/n)



$\frac{\bar{X} - \mu}{\sigma/\sqrt{n}}$ は
平均 0, 分散 1 の正規分布

$$\mu \in \left[\bar{X} - t_{n-1, \alpha}^* \frac{\hat{\sigma}}{\sqrt{n}}, \bar{X} + t_{n-1, \alpha}^* \frac{\hat{\sigma}}{\sqrt{n}} \right]$$



$\frac{\bar{X} - \mu}{\hat{\sigma}/\sqrt{n}}$ は
自由度 $n-1$ のティー分布

$$\sigma^2 \in \left[\frac{(n-1)\hat{\sigma}^2}{\chi_{n-1, \frac{\alpha}{2}}^2}, \frac{(n-1)\hat{\sigma}^2}{\chi_{n-1, 1-\frac{\alpha}{2}}^2} \right]$$



$\frac{(n-1)\hat{\sigma}^2}{\sigma^2}$ は
自由度 $n-1$ のカイ自乗分布

正規分布から誘導される分布

$$Z_1, Z_2, \dots, Z_n \sim N(0,1)$$



Z_i は標準正規分布に
従う独立な確率変数

$$Y = Z_1^2 + Z_2^2 + \dots + Z_n^2 \text{ のとき}$$



Y は自由度 n の
カイ自乗分布に従う

$$Y \sim \chi_n^2$$

$$X \sim N(0,1), Y \sim \chi_n^2 \text{ のとき}$$



T は自由度 n の
ティー分布に従う

$$T = \frac{X}{\sqrt{Y/n}} \sim t_n$$

様々な分布と密度関数

正規分布 $X \sim N(\mu, \sigma)$ $\Rightarrow f(x|\mu, \sigma) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{(x-\mu)^2}{2\sigma^2}\right)$

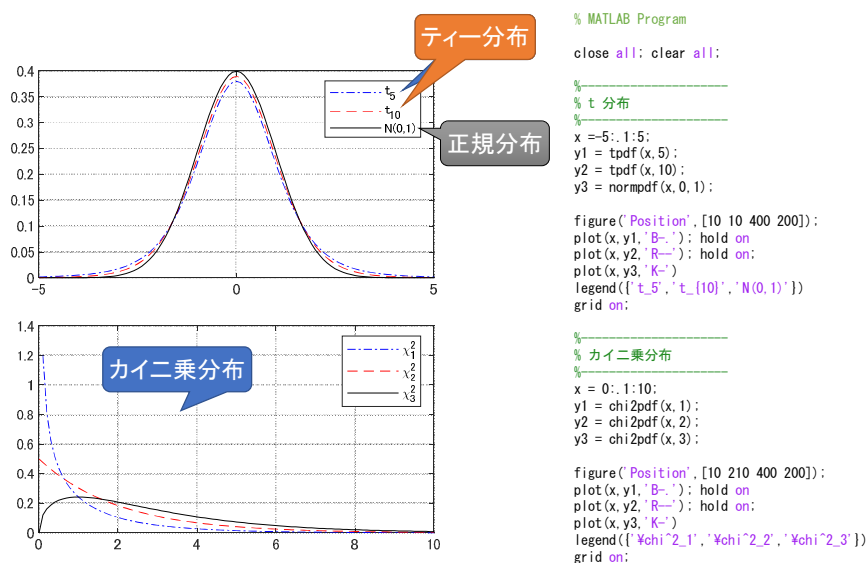
自由度 n の
カイ自乗分布 $X \sim \chi_n^2$ $\Rightarrow f(x|n) = \frac{1}{2^{\frac{n}{2}} \Gamma(\frac{n}{2})} x^{\frac{n}{2}-1} \exp\left(-\frac{x}{2}\right)$

$$\Gamma(x) = \int_0^{\infty} e^{-t} t^{x-1} dt \quad (\text{ガンマ関数})$$

自由度 n の
ティー分布 $X \sim t_n = \frac{N(0,1)}{\sqrt{\chi_n^2/n}}$ $\Rightarrow f(x|n) = \frac{1}{\sqrt{n} B\left(\frac{n}{2}, \frac{1}{2}\right)} \left(1 + \frac{x^2}{n}\right)^{-\frac{n+1}{2}}$

$$B(x, y) = \int_0^1 t^{x-1} (1-t)^{y-1} dt \quad (\text{ベータ関数})$$

様々な分布と密度関数



初版： 2022年8月

制作： 岩橋政宏

所属： 長岡技術科学大学