

rd-4. 標本の平均、母 平均

データサイエンス演習
(R システムを使用)

<https://www.kkaneko.jp/de/rd/index.html>

金子邦彦



アウトライン

1. 平均
2. 母集団と標本
3. 標本の平均値
4. 標本の分散値
5. 演習

1. 平均

平均



- 平均は、データの合計を、データの個数で割ったもの

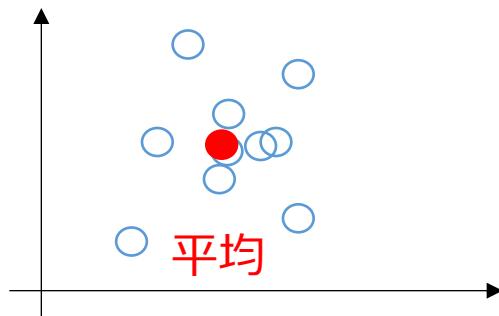
10, 40, 30, 40 の平均: $120 \div 4$ で 30

- 複数の値の組の平均を考えることもある

(10, 5), (40, 10), (30, 5), (40, 20) の平均:

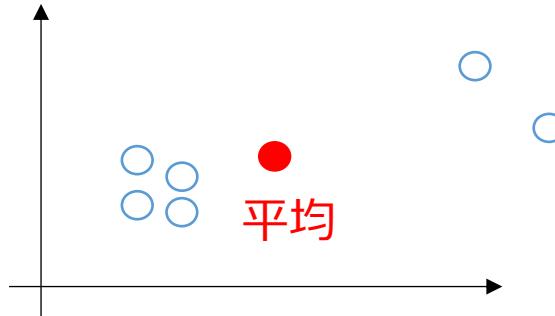
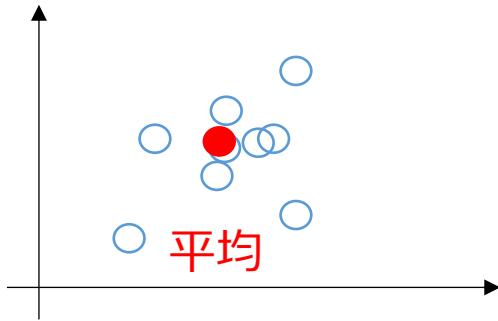
合計は 120 と 40. 4で割って (30, 10)

平均は、データ集合の代表とみることができる場合がある



計測に誤差があるとき、複数の計測を繰り返し、平均をとることで、誤差を軽減できることも

平均を使うときの注意点



このような平均に、
意味があるでしょうか？

データの分布によっては、平均では役に立たないこともある。
(平均は万能ではない)

2. 母集団と標本

母集団



母集団は、調査や研究の対象となる全体の集団のこと

- ・母集団の把握と理解が重要

(例) 人類全体、20歳以上の人類全体

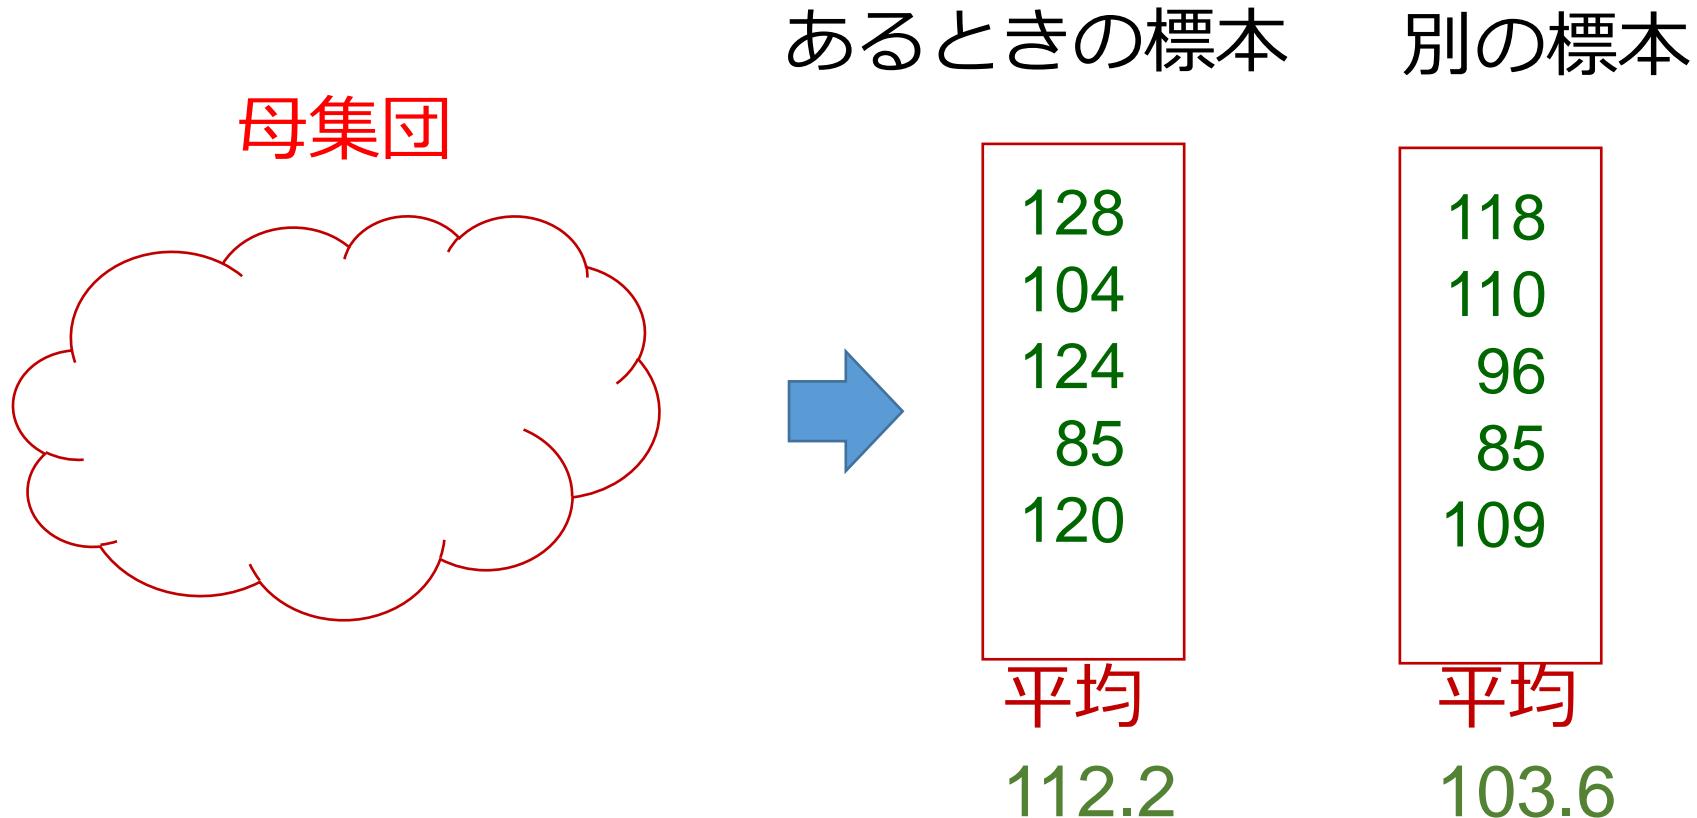
サンプリングと標本



- ・母集団全体を調べることが困難な場合、サンプリングを適切に行う
(例) 1000名をランダムに選ぶ
- ・サンプリングは、母集団から一部を選ぶこと。
- ・母集団全体を調べるのでなく、一部を調べることになる。
- ・標本は、サンプリングで選ばれたもののこと。



サンプリングと標本



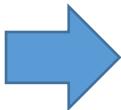
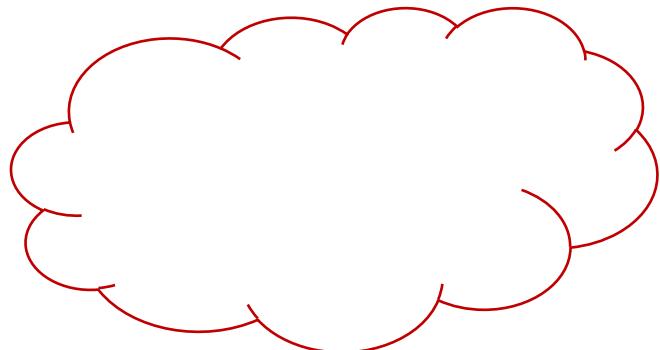
選ばれた標本によっては、
値が違い、平均なども異なってくる

十分な数の標本が必要



あるときの標本

母集団



128
104
124
85
120

- 標本の大きさが小さいと、結果の信頼性が下がる
- 十分な数の標本を得ることが重要
- 標本の大きさの決定は簡単に決めることができない
- 母集団の特徴、調査や研究の目的によって、適切な標本の大きさは変わることに注意しよう

まとめ



- ・ **母集団**：調査や研究の対象となる**全体の集団**

- ・ **サンプリング**：

母集団全体を調べることが困難な場合、母集団から一部を選ぶサンプリングを行う。

母集団の特徴や性質を推測することが可能となる。

- ・ **標本**：

標本は、母集団からサンプリングで選ばれた母集団の一部。

標本から得られたデータを分析し、母集団全体の性質や傾向を推測可能。

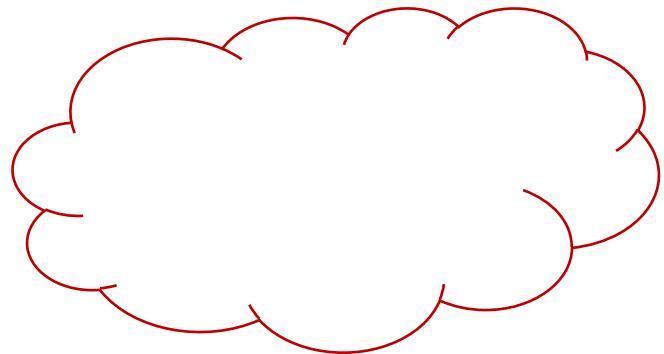
【注意点】十分な標本サイズの確保が必要。ランダムに選択するなどの考慮が重要。

3. 標本の平均値

今から行うことのイメージ



母集団



たくさんの標本



平均の算出



母平均の推定

母集団の平均を
母平均という

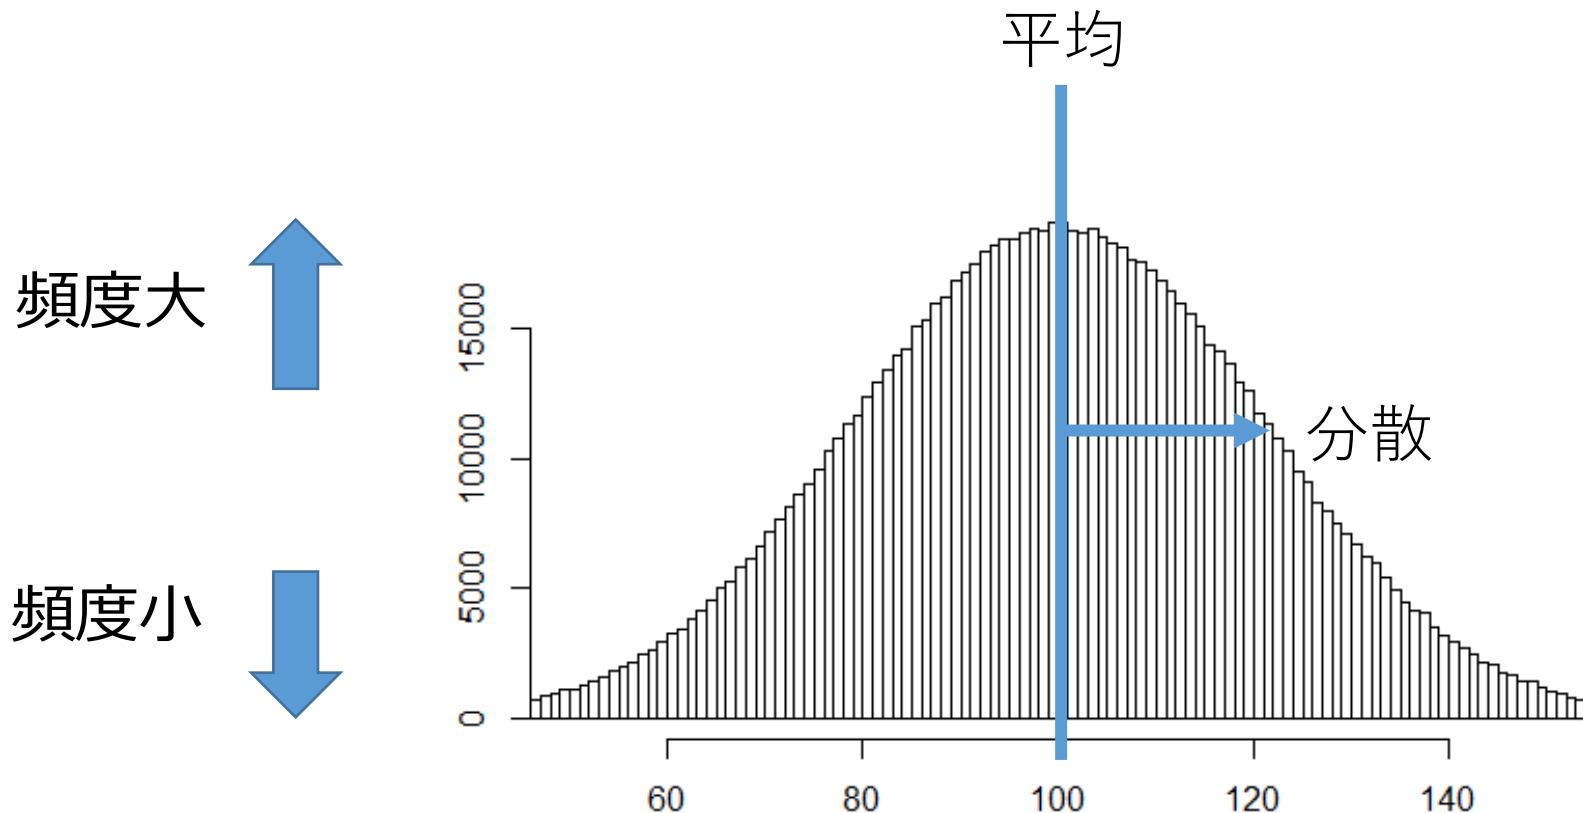
母平均の推定の精度を分析する
ために、母集団は正規分布である
と仮定

正規分布



正規分布は、平均と分散だけで頻度分布を考える。

分散は、データの散らばり度合を表す

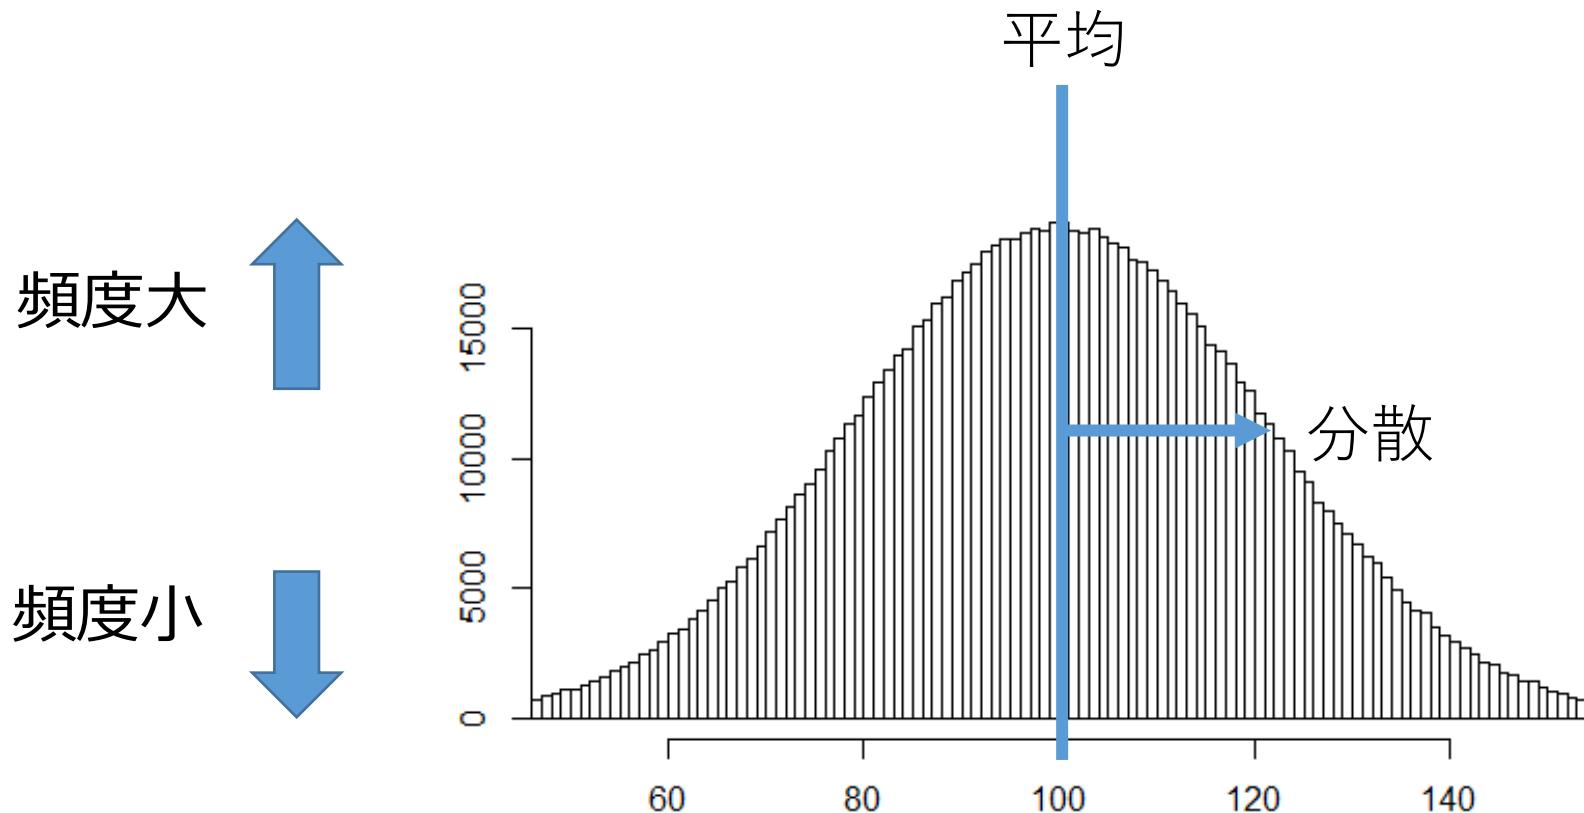


正規分布



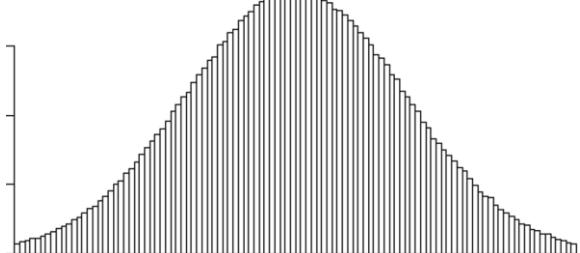
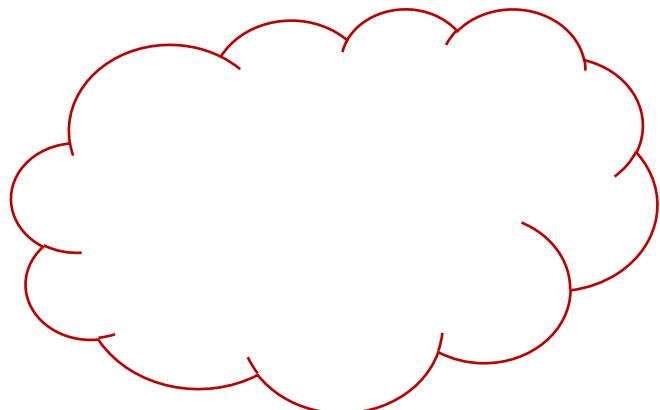
正規分布は、平均と分散だけで頻度分布を考える。

分散は、データの散らばり度合を表す



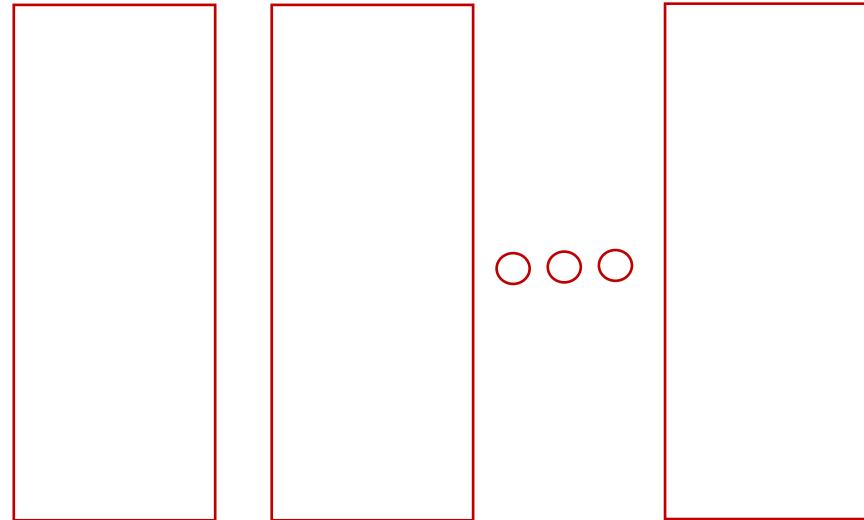
母集団は正規分布であるとし、標本の平均値を算出

母集団



正規分布

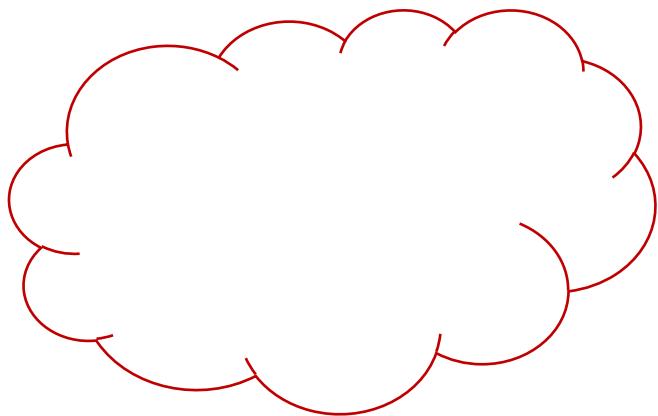
標本 (標本数は n)



平均 (n 個の数の平均)

母集団は正規分布であるとし、標本の平均値を算出

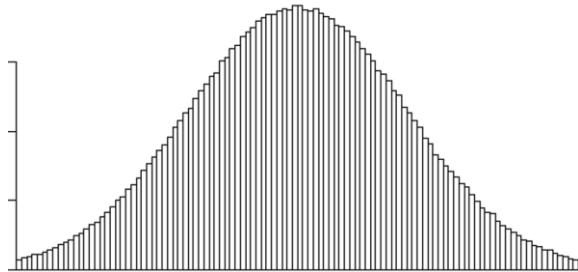
母集団



標本（標本数は n , $n = 5$ ）

128	80	118
104	80	110
124	126	96
85	122	85
120	79	109

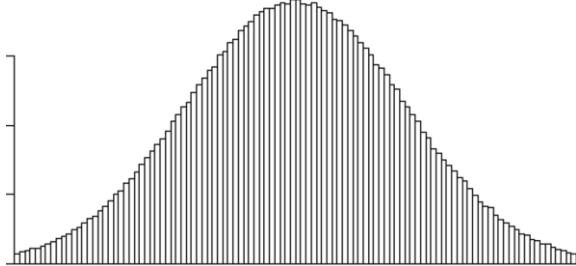
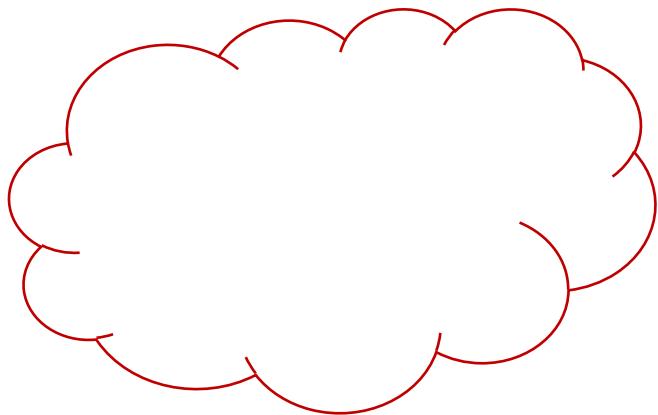
○○○



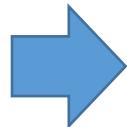
正規分布

母集団は正規分布であるとし、標本の平均値を算出

母集団



正規分布



標本（標本数は n , $n = 5$ ）

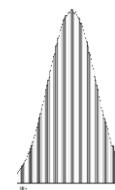
128	80	118
104	80	110
124	126	96
85	122	85
120	79	109

○○○

平均 112.2 平均 97.4 平均 103.6

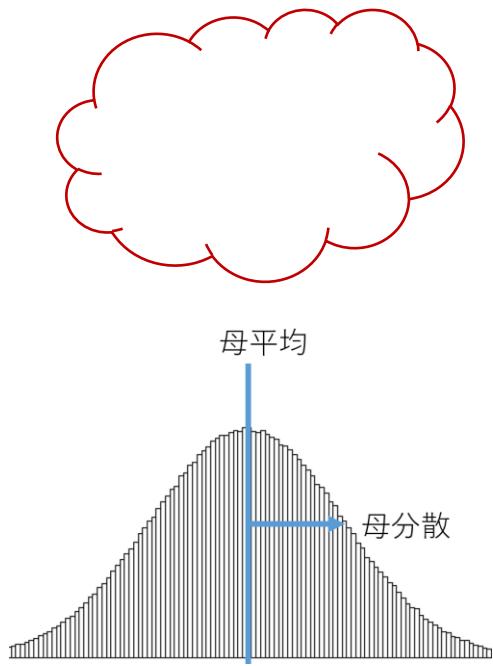


平均はばらつく。



母集団は正規分布であるとし、標本の平均値を算出

母集団



標本（標本数は n ）



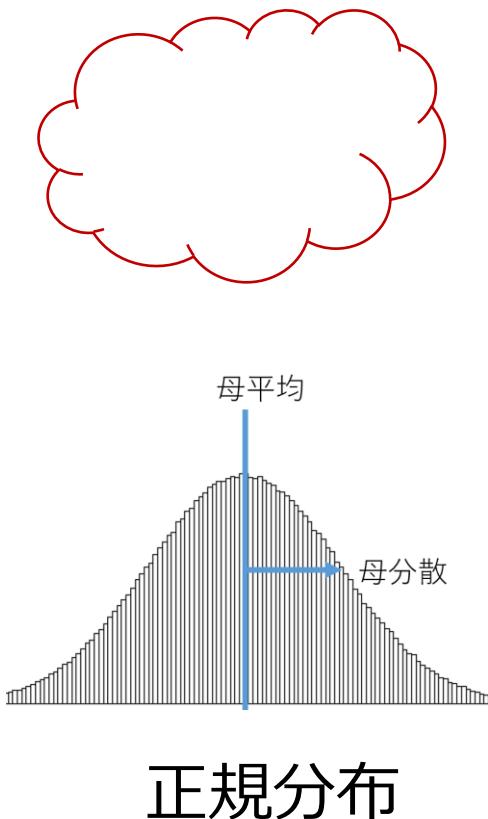
母集団が正規分布であるとき、この分布も正規分布

- この正規分布の平均 **<母平均>** に等しい
- この正規分布の分散 **<母分散> / n**

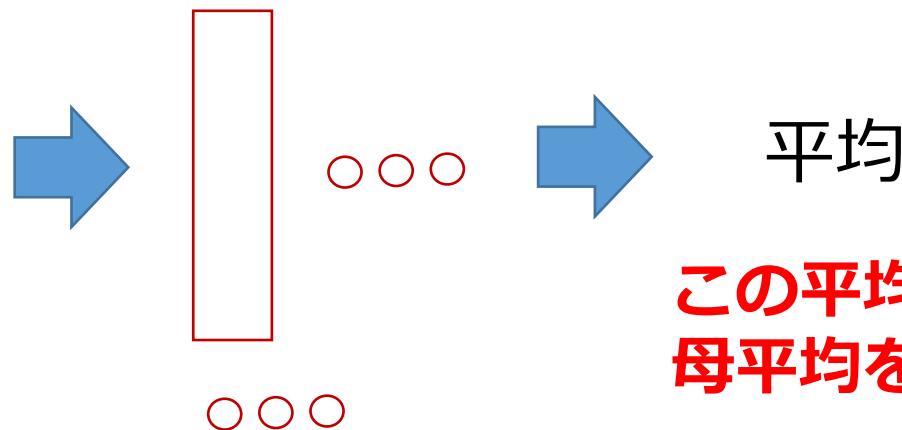
- 母集団の平均は、**母平均**という
- 母集団の分散は、**母分散**という

まとめ

母集団



標本（標本数は n ）



母分散が小さいほど精度がよい。 n が大きいほど精度がよい



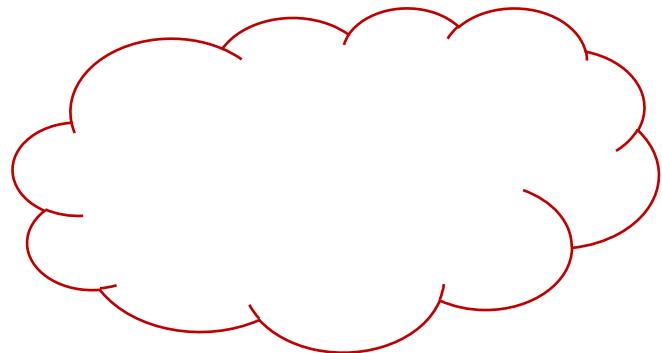
この正規分布の $\langle \text{分散} \rangle$ は、 $\langle \text{母分散} \rangle / n$

4. 標本の分散値

今から行うことのイメージ



母集団



たくさんの標本



不偏分散の算出



母集団の不偏分散を
知りたい

母集団の不偏分散の推定

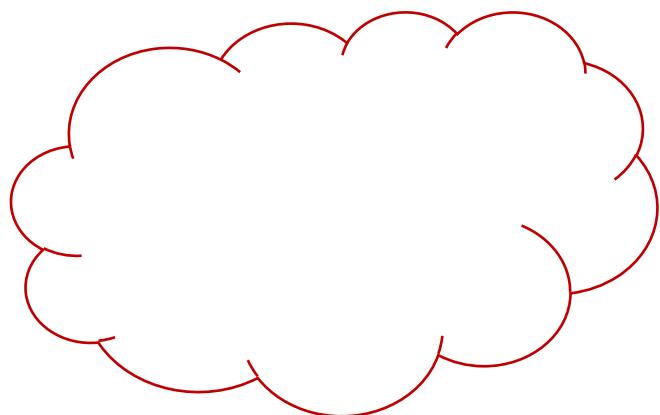
母不偏分散の推定の精度を分析する
ために、母集団は t 分布であると仮定
(t 分布は正規分布と少し異なる形)

- ・分散は、データの散らばり度合を表す
- ・母分散（母集団の分散）は、標本からは推定できないもの
- ・母分散の代わりに、不偏分散を用いる



標本の分散値を算出

母集団



t 分布

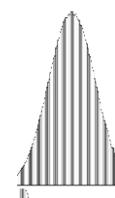
標本 (標本数は n , $n = 5$)

128	80	118
104	80	110
124	126	96
85	122	85
120	79	109

○○○

不偏分散 314.2 170.3 591.8

求まった値はばらつく。
・その分布の平均は、
元の母集団の不偏分散に等しい
・ n が大きいほど精度がよい



5. 演習

R のベクトル



ベクトルとは、データの並びのこと。
各要素に番号（添え字）がある。

- ・コンストラクタ（ベクトルデータの組み立て）
c や numeric など

```
> p <- c(100, 200, 300, 400)
> print(p)
[1] 100 200 300 400
> |
```

```
> p <- numeric(10)
> print(p)
[1] 0 0 0 0 0 0 0 0 0 0
> |
```

- ・添え字によるアクセス []

```
> print(p)
[1] 100 200 300 400
> p[1]
[1] 100
> p[2]
[1] 200
> p[3]
[1] 300
> p[4]
[1] 400
> |
```

R での平均と不偏分散



- 平均 mean

- 不偏分散 var

※ 不偏分散は、標本値のばらつきを表す値

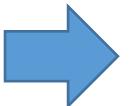
R での平均と不偏分散

128
104
124
85
120

118
110
96
85
109

80
80
126
122
79

127
72
111
82
81



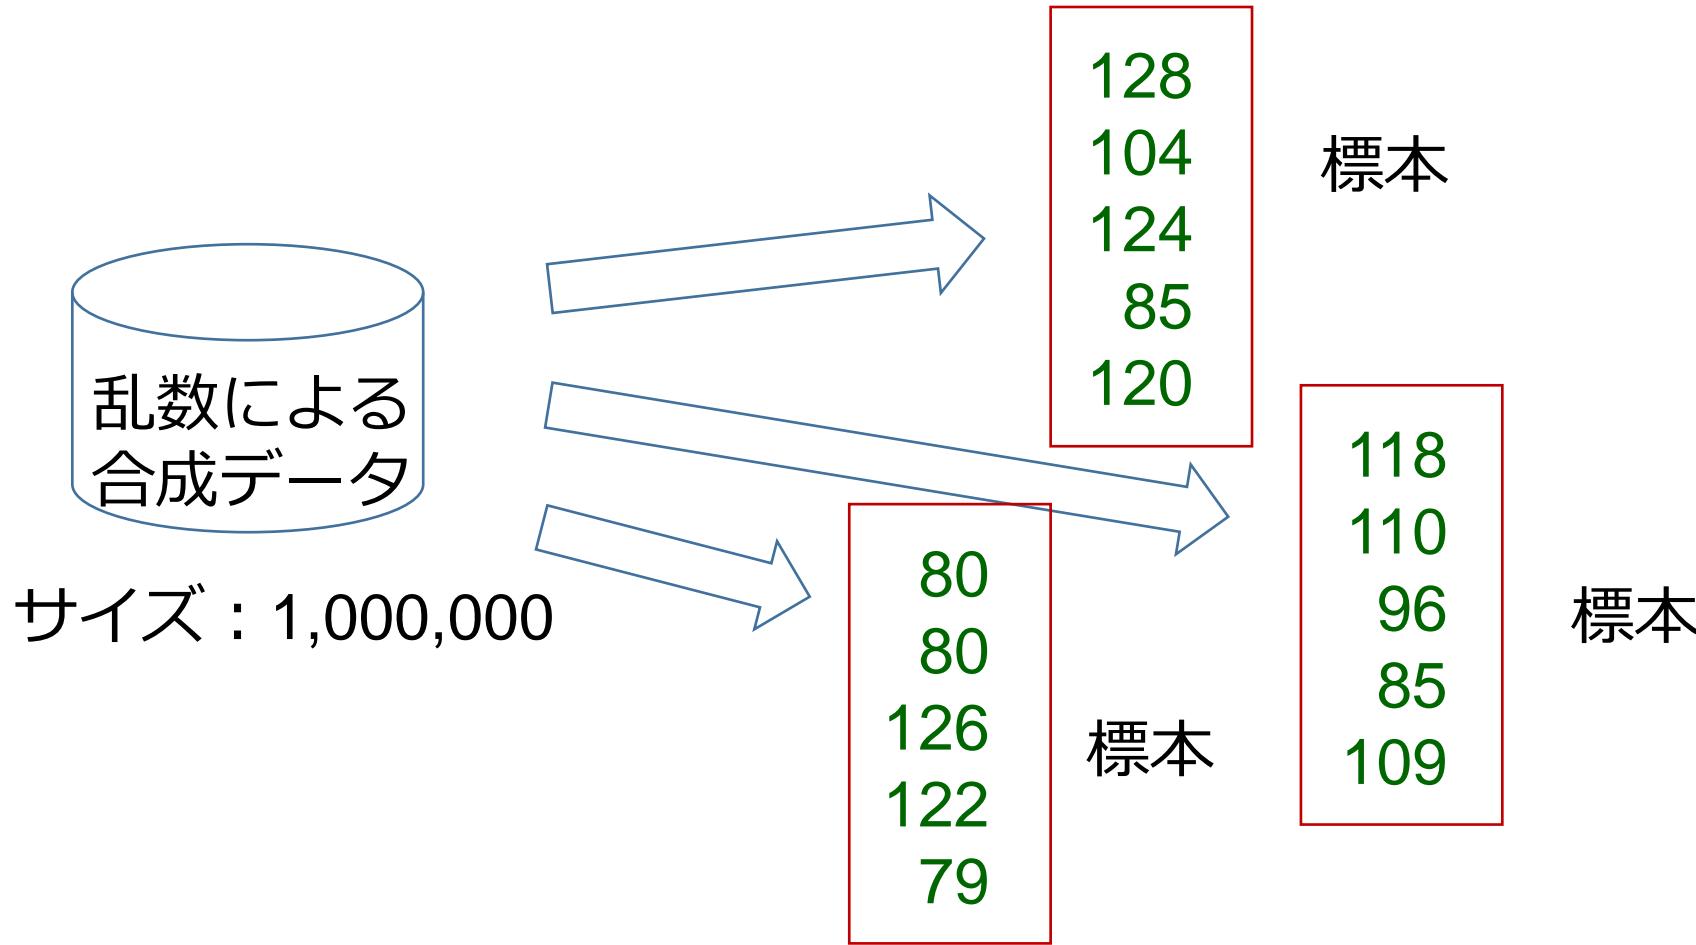
```
c1 <- c(128, 104, 124, 85, 120)
c2 <- c(118, 110, 96, 85, 109)
c3 <- c(80, 80, 126, 122, 79)
c4 <- c(127, 72, 111, 82, 81)
mean(c1)
mean(c2)
mean(c3)
mean(c4)
var(c1)
var(c2)
var(c3)
var(c4)
```

```
> c1 <- c(128, 104, 124, 85, 120)
> c2 <- c(118, 110, 96, 85, 109)
> c3 <- c(80, 80, 126, 122, 79)
> c4 <- c(127, 72, 111, 82, 81)
> mean(c1)
[1] 112.2
> mean(c2)
[1] 103.6
> mean(c3)
[1] 97.4
> mean(c4)
[1] 94.6
> var(c1)
[1] 314.2
> var(c2)
[1] 170.3
> var(c3)
[1] 591.8
> var(c4)
[1] 543.3
```



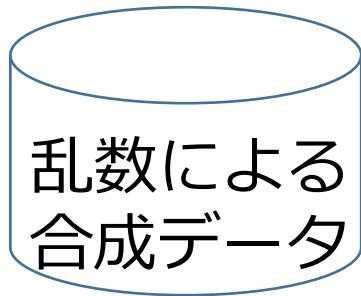
今から行うこと

「1,000,000個の中から
ランダムに標本を選ぶ」



今から行うこと

「1,000,000個の中から
ランダムに標本を選ぶ」

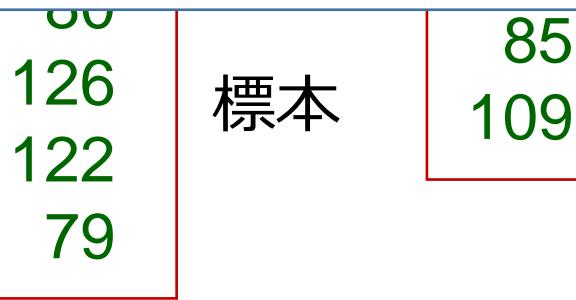


サイズ：1,000,000

128

Rでは
ベクトルデータ x の 1,000,000個の中から
ランダムに 5 個選びたいときは

`x[floor(runif(5, 1, 1000000+1))]`



合成データからランダムに5個選び標本を作る



サイズ 5
の標本

タイプ：数値

サイズ：1,000,000

```
> x[floor( runif(5, 1, 1000000+1) )]  
[1] 102 79 101 91 103  
> x[floor( runif(5, 1, 1000000+1) )]  
[1] 110 110 106 115 90  
> x[floor( runif(5, 1, 1000000+1) )]  
[1] 114 114 112 98 103  
>
```

毎回違う結果が出る

```
x <- round( rnorm(1000000, mean=100, sd=20) )  
x[floor( runif(5, 1, 1000000+1) )]  
x[floor( runif(5, 1, 1000000+1) )]  
x[floor( runif(5, 1, 1000000+1) )]
```

乱数による合成データの生成

標本を20個作り，各標本の平均や不偏分散を求める



合成データ
タイプ：数値
サイズ：1,000,000

サイズ5
の標本を
20個

各標本の
平均や
不偏分散

```
> print(m)
[1] 89.4 86.4 102.0 118.8 92.6 102.2
[7] 102.6 94.8 109.8 102.0 92.8 113.4
[13] 89.2 100.2 105.8 95.0 113.2 90.4
[19] 94.2 96.0
> print(v)
[1] 327.8 455.3 246.0 493.2 50.8 417.2
[7] 665.3 212.7 738.2 57.5 405.7 786.3
[13] 876.7 603.7 171.7 372.0 142.7 572.3
[19] 139.7 505.0
>
>
```

毎回違う結果が出る

```
x <- round( rnorm(1000000, mean=100, sd=20) )
m <- numeric(20)
v <- numeric(20)
for (i in 1:20) {
  s <- x[floor( runif(5, 1, 1000000+1) )]
  m[i] <- mean(s)
  v[i] <- var(s)
}
print(m)
print(v)
```

平均と不偏分散

合成データからランダムに
5個選び標本を作る

各標本の平均値を比べる



標本の例

128	118	80	127
104	110	80	72
124	96	126	111
85	85	122	82
120	109	79	81

標本 2 個の各平均値 112.2 103.6

総平均 : 107.9

標本 3 個の各平均値 112.2 103.6 97.4

総平均 : 104.4

標本 4 個の各平均値 112.2 103.6 97.4 94.6

総平均 : 101.95

各標本の不偏分散値を比べる



128	118	80	127
104	110	80	72
124	96	126	111
85	85	122	82
120	109	79	81

標本 2 個の各不偏分散値

314.2 170.3

その平均 : 242.25

標本 3 個の各不偏分散値

314.2 170.3 591.8

その平均 : 358.7667

標本 4 個の各不偏分散値

314.2 170.3 591.8 543.3

その平均 : 404.9

各標本の平均値や不偏分散値を集めて、平均をとる



→ サイズ 5 の標本を 20 個 → 各標本の平均値や不偏分散値 → 平均

```
x <- round( rnorm(1000000, mean=100, sd=20) )
m <- numeric(20)
v <- numeric(20)
for (i in 1:20) {
  s <- x[floor( runif(5, 1, 1000000+1) )]
  m[i] <- mean(s)
  v[i] <- var(s)
}
for (i in 1:20) { print( mean(m[1:i]) ) }
for (i in 1:20) { print( mean(v[1:i]) ) }
```

```
> for (i in 1:20) { print( mean(m[1:i]) ) }
```

[1] 89.4
 [1] 87.9
 [1] 92.6
 [1] 99.15
 [1] 97.84
 [1] 98.56667
 [1] 99.14286
 [1] 98.6
 [1] 99.84444
 [1] 100.06
 [1] 99.4
 [1] 100.5667
 [1] 99.69231
 [1] 99.72857
 [1] 100.1333
 [1] 99.8125
 [1] 100.6
 [1] 100.0333
 [1] 99.72632
 [1] 99.54

だんだんと
 100 に近づく

各標本の**平均値**を集めて
 平均を求める

```
> for (i in 1:20) { print( mean(v[1:i]) ) }
```

[1] 327.8
 [1] 391.55
 [1] 343.0333
 [1] 380.575
 [1] 314.62
 [1] 331.7167
 [1] 379.3714
 [1] 358.5375
 [1] 400.7222
 [1] 366.4
 [1] 369.9727
 [1] 404.6667
 [1] 440.9769
 [1] 452.6
 [1] 433.8733
 [1] 430.0063
 [1] 413.1059
 [1] 421.95
 [1] 407.0947
 [1] 411.99

だんだんと
 400 に近づく

各標本の**不偏分散値**を集めて
 平均を求める

ランダムなので、毎回違う結果が出る

```
> for (i in 1:20) { print( mean(m[1:i]) ) }
```

[1] 90
 [1] 94.3
 [1] 102.8
 [1] 101.7
 [1] 103.24
 [1] 103.7
 [1] 102.5714
 [1] 104.4
 [1] 105.9778
 [1] 105
 [1] 105.6909
 [1] 105.75
 [1] 106.1692
 [1] 105.5286
 [1] 106.0133
 [1] 106.175
 [1] 105.3529
 [1] 105.2
 [1] 105.7895
 [1] 106.97

だんだんと
100 に近づく

何度やっても同じ

各標本の**平均値**を集めて
平均を求める

```
> for (i in 1:20) { print( mean(v[1:i]) ) }
```

[1] 649
 [1] 571.15
 [1] 593
 [1] 500.075
 [1] 452.72
 [1] 410.9333
 [1] 449.4
 [1] 405.4375
 [1] 524.4222
 [1] 546.5
 [1] 519.6182
 [1] 502.7583
 [1] 473.9462
 [1] 468.8929
 [1] 511.3133
 [1] 489.8125
 [1] 480.7176
 [1] 463.9167
 [1] 461.0684
 [1] 457.33

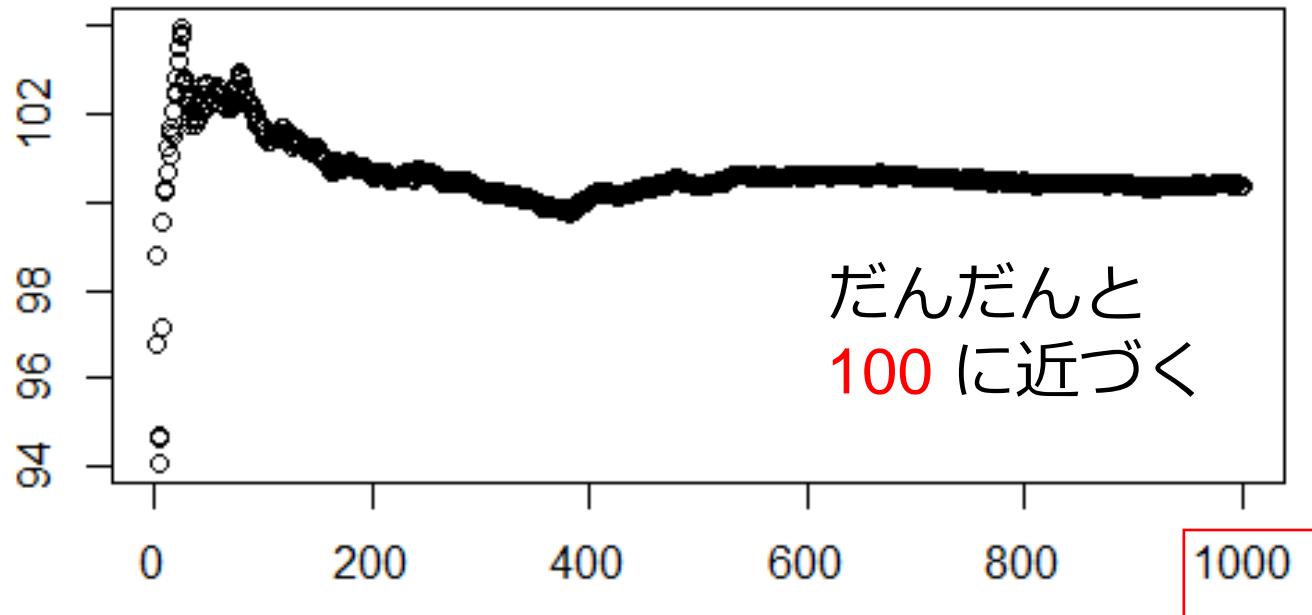
だんだんと
400 に近づく

何度やっても同じ

各標本の**不偏分散値**を集めて
平均を求める

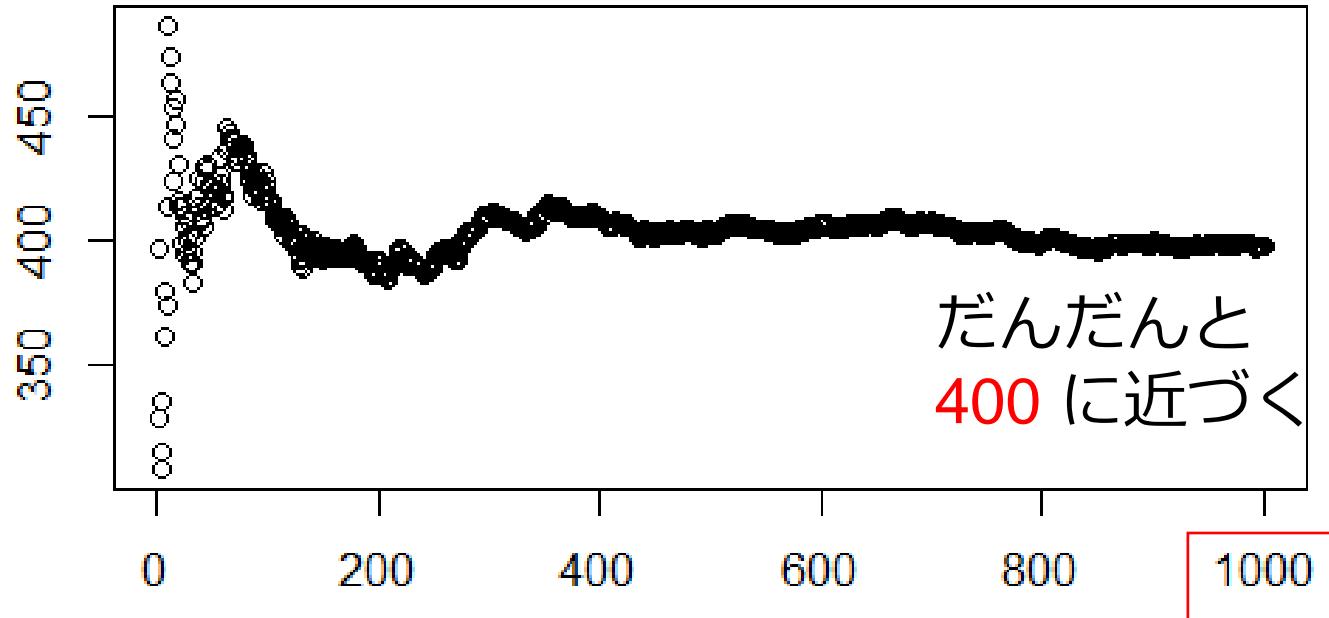
ランダムなので、毎回違う結果が出る

標本の個数を 20 から 1000 の間で変えて、
総平均を求めてみる



各標本の平均値を集めて総平均を求める

標本の個数を 20 から 1000 の間で変えて、
総平均を求めてみる



各標本の不偏分散値を集めて総平均を求める

標本の平均から母平均を推定



標本の平均から母平均を推定するときに気を付けること

- **標本の大きさ**

標本の大きさは、母平均の推定精度に大きく影響。標本の大きさが大きいほど精度が向上

- **誤差の認識**

標本の平均から母集団を推定する際は、必ず誤差が発生する（論文などに細かすぎる値を書かないこと）

- **サンプリングはランダムに**

母集団を正確に反映する標本を得ることが重要

- **母集団のデータの分布の確認**

正規分布か確認。統計手法では（t検定など）、正規分布を前提としている場合がある

- **外れ値の考慮**

外れ値は、平均値に大きく影響する。外れ値は取り除くか適切に書き換える