



# 計量経済学

## 6. 回帰分析による統計的推測 II 仮説を検証する

やない ゆうき  
矢内 勇生



<https://yukiyanai.github.io>



[yanai.yuki@kochi-tech.ac.jp](mailto:yanai.yuki@kochi-tech.ac.jp)



# このトピックの目標

- 回帰分析で「統計的検定」と「統計的推定」を行うための準備を整える
  - ▶ 母集団における回帰直線と標本の回帰直線を区別する
  - ▶ 回帰分析の帰無仮説と対立仮説を理解する
- 回帰分析で仮説を検証する方法を理解する
  - ▶ 回帰係数の統計的検定手続きを理解する
  - ▶ 「統計的に有意」の意味を理解する

# 母集団の回帰直線と 標本の回帰直線

# 回帰分析による推定

- データから作った散布図への直線（平面）の当てはめは、標本データの要約
- 興味があるのは母集団の特徴
- ★ どのような方法で、標本から母集団を推定する？

# 統計モデルをつくる

- 自分が観察しているデータが生み出される過程をモデル化する
  - ▶ データ生成過程 (data generating process; DGP)
  - ▶ モデル：目的に応じた現象の単純化
    - 本質的に「正しくない」
    - 「正しいかどうか」ではなく、「役に立つかどうか」で評価する

“All models are wrong, but  
some are useful.”

–*George E. P. Box*

Cf. Box, George. 1976. [“Science and Statistics.”](#) *Journal of the American Statistical Association*, 71(356): 791-799.

# 単回帰

- 母集団における単回帰

$$Y_i = \alpha + \beta X_i + \varepsilon_i$$

- $\alpha, \beta$  : パラメタ, 母数 (推定の対象)
- $\varepsilon$  : 誤差 (error)
  - 説明変数以外で応答変数に影響を与えるもの
  - 平均すると0

# 誤差をモデル化する

- 誤差  $\varepsilon$  の分布を以下のように**仮定**する
  - ▶  $\varepsilon_i \sim \text{Normal}(0, \sigma)$ 
    - 誤差の平均は 0
    - 誤差は、1つの正規分布から生み出される
      - ◆ 誤差の標準偏差  $\sigma$  は、 $i$  によらず一定

# 単回帰モデル

- 単回帰モデル：単回帰が想定するDGP
  - ▶ まず、 $X_i$  ( $i = 1, 2, \dots$ )の値が決まる
  - ▶ 次に、 $Y_i$  ( $i = 1, 2, \dots$ )の値が以下のように決まる

$$Y_i \sim \text{Normal}(\mu_i, \sigma)$$

$$\mu_i = \alpha + \beta X_i$$

# 単回帰モデルの書き換え

- 以下のような表記が使われることも多い（意味はどれも同じ）

- ▶ 別表記 (1)

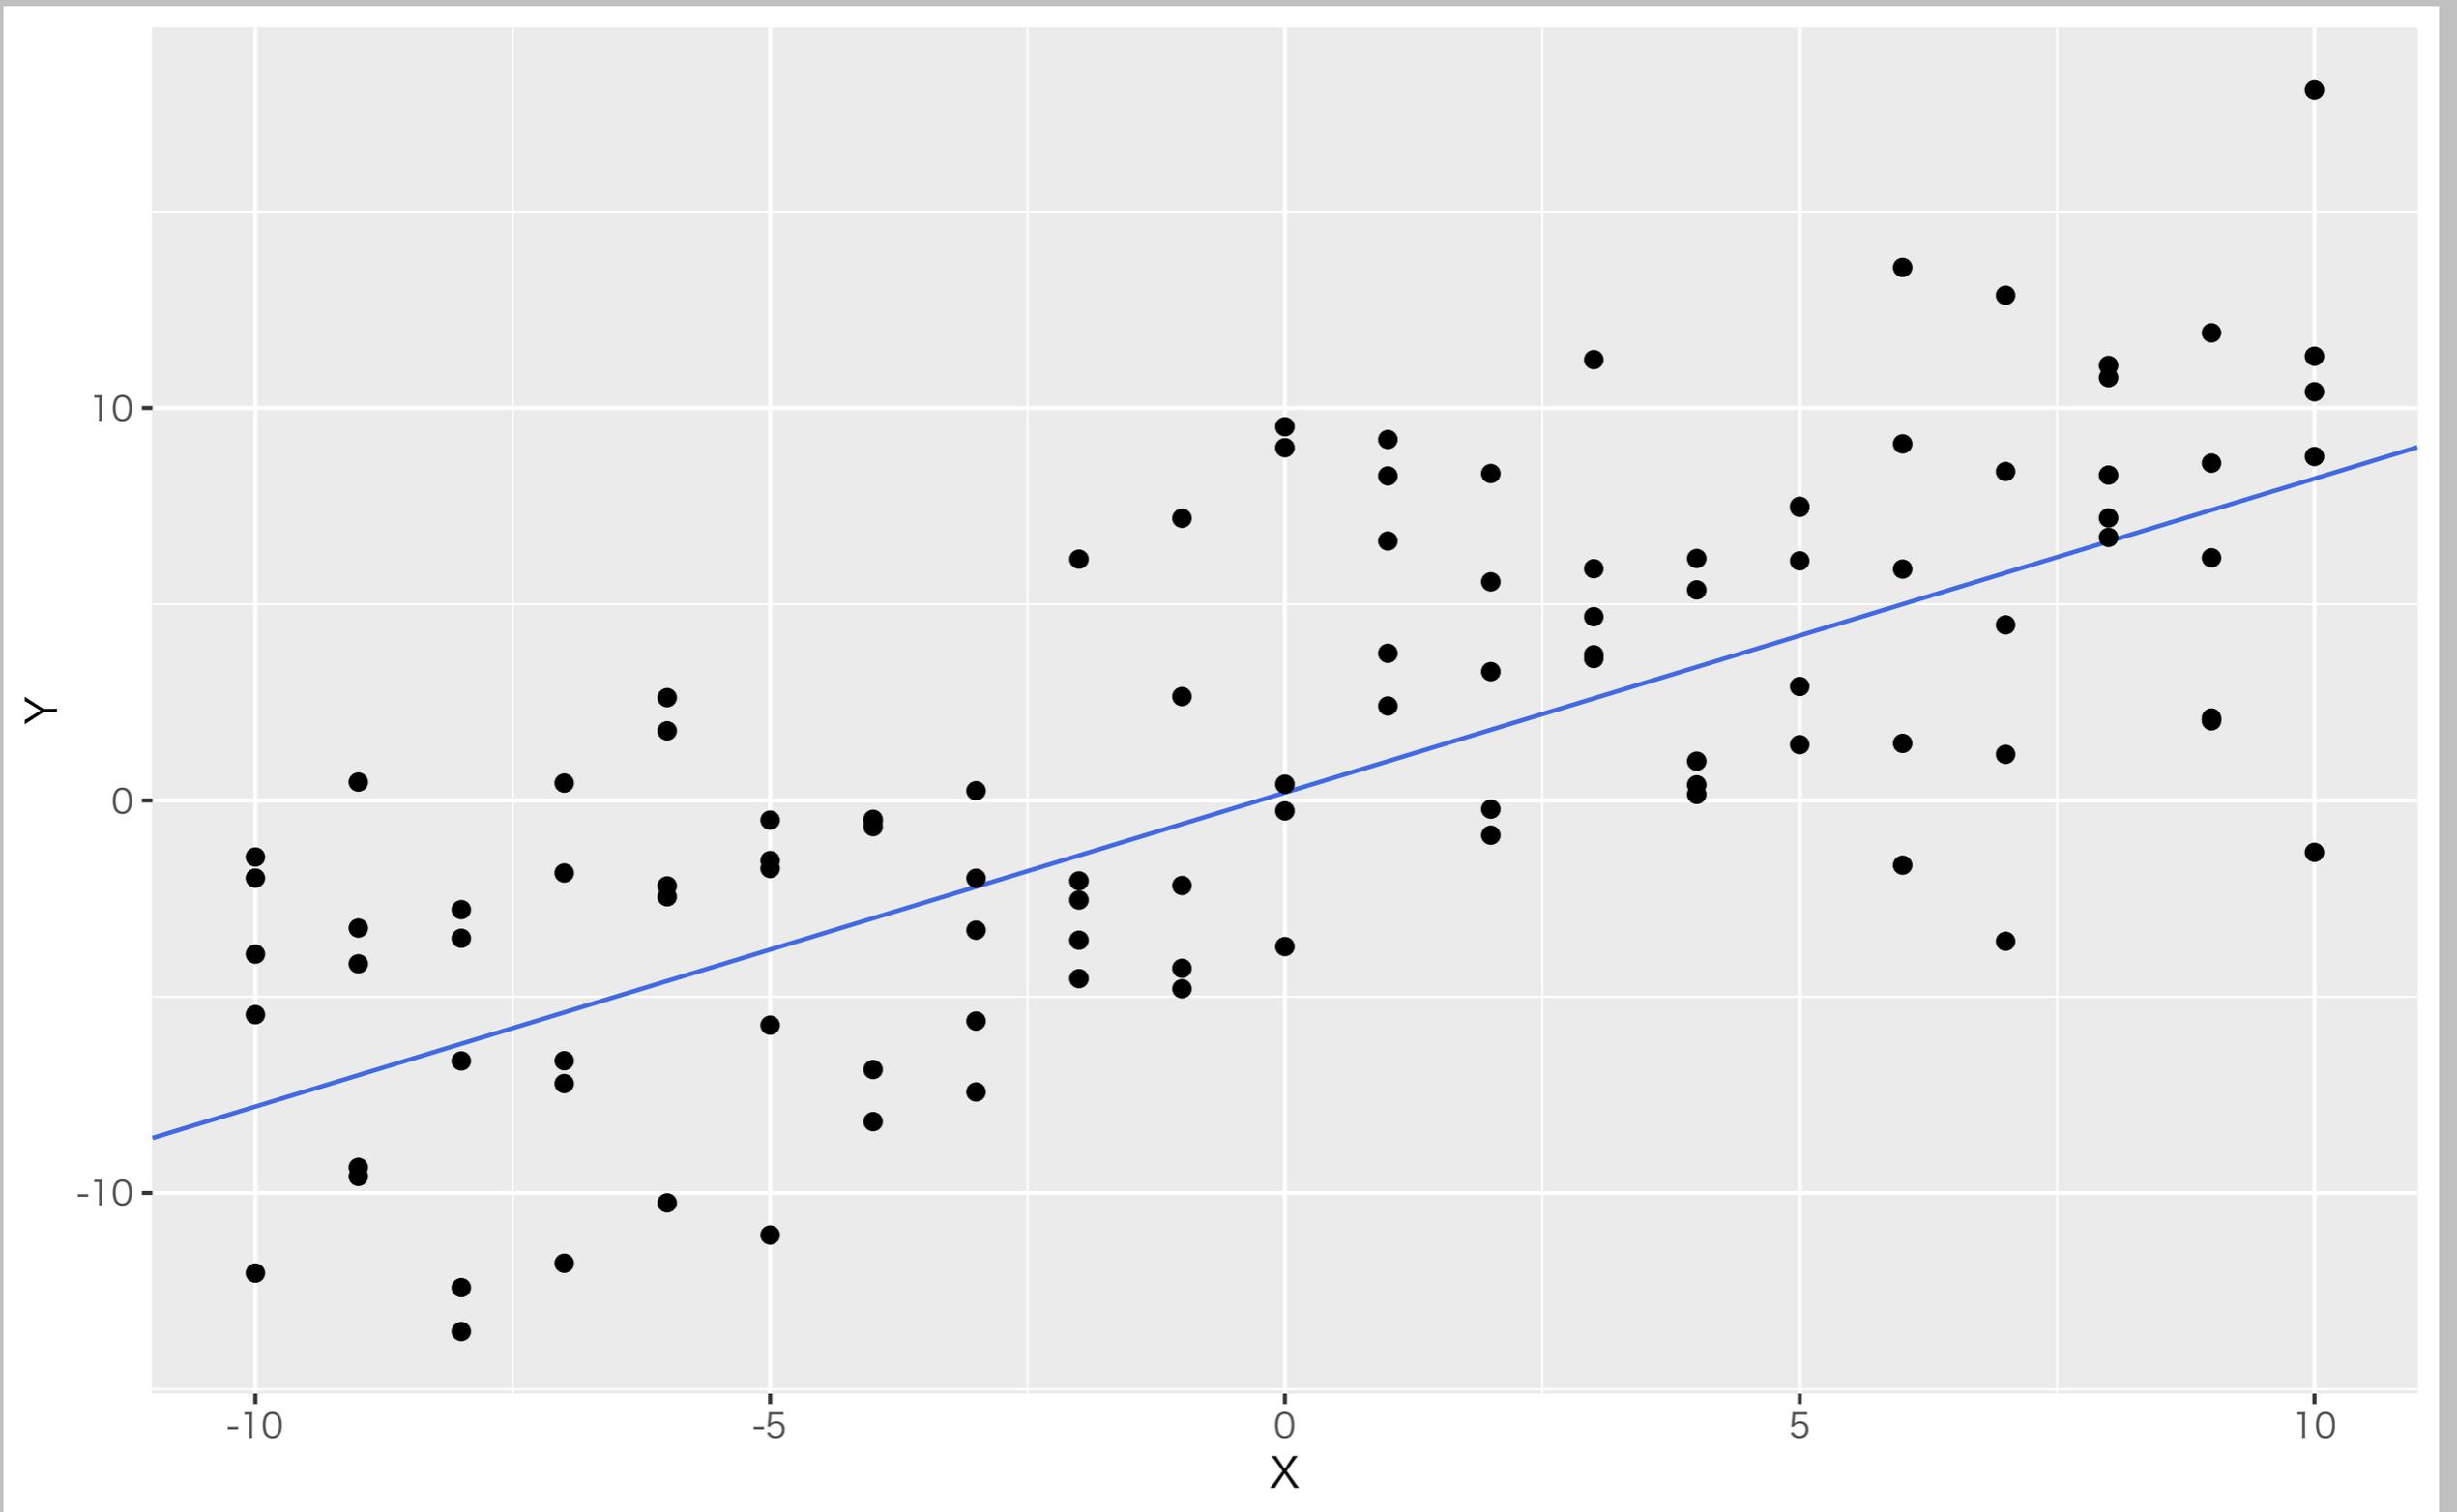
$$Y_i \sim \text{Normal}(\alpha + \beta X_i, \sigma)$$

- ▶ 別表記 (2)

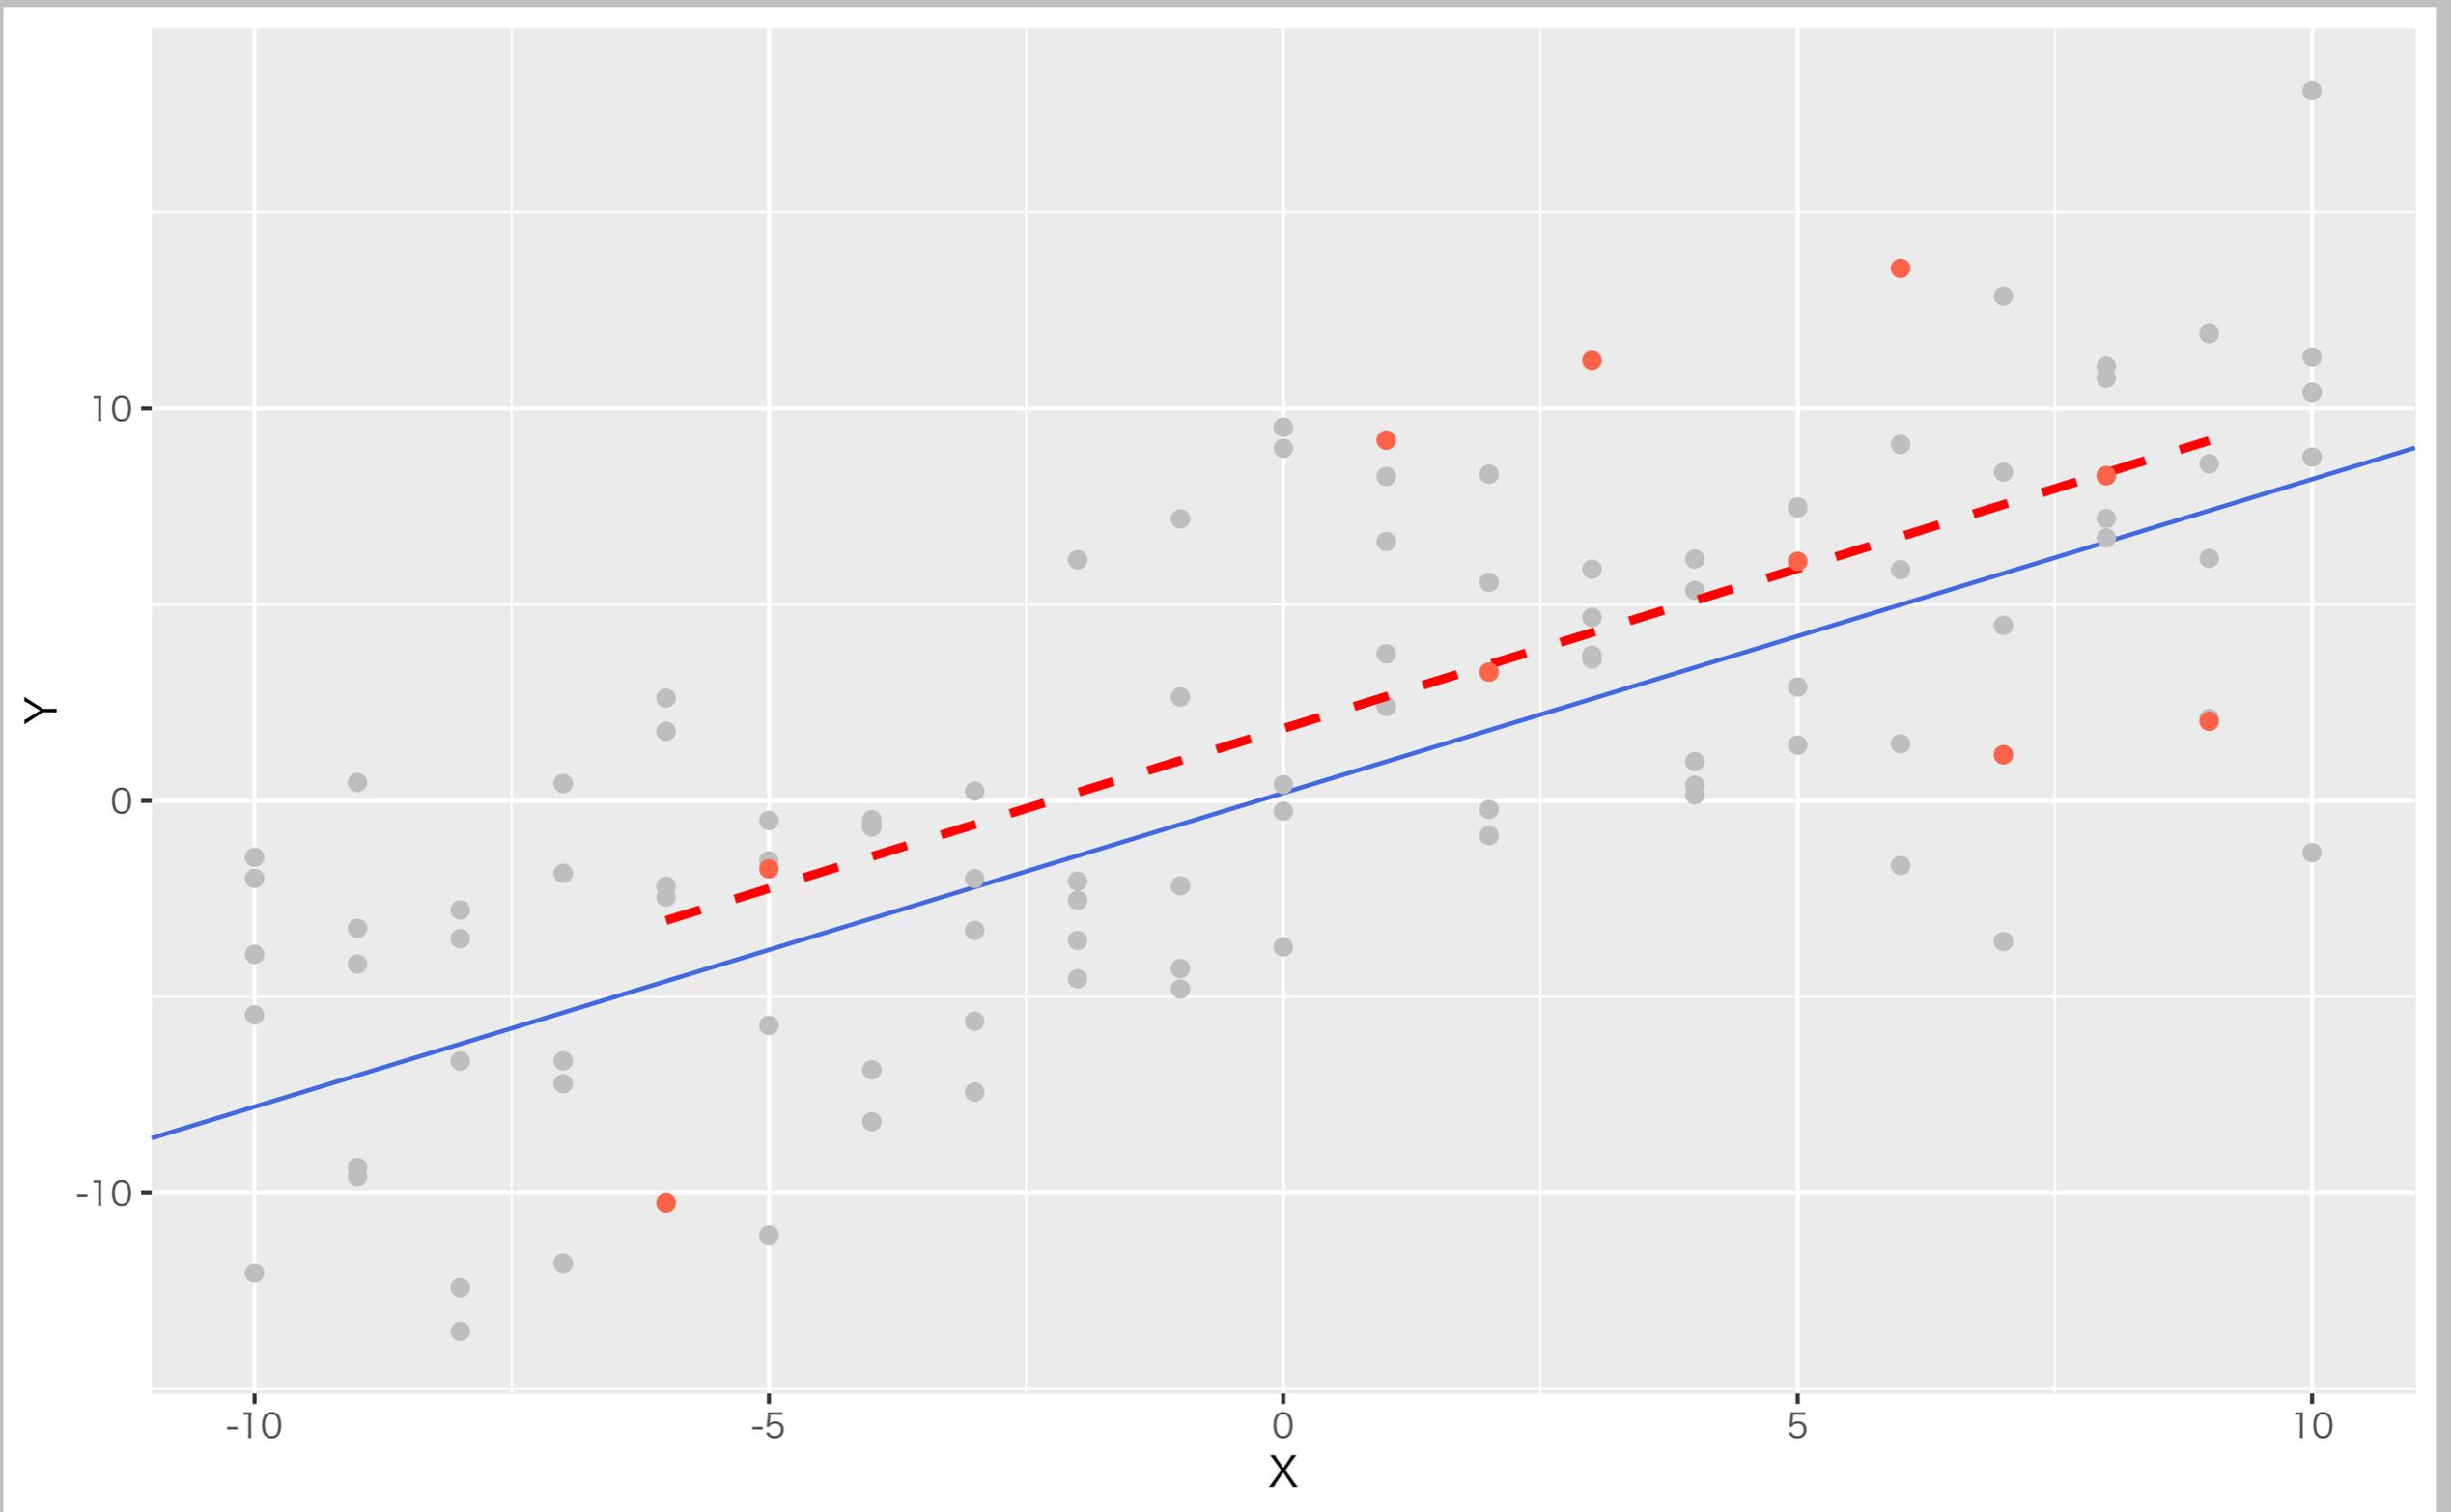
$$Y_i = \alpha + \beta X_i + \varepsilon_i$$

$$\varepsilon_i \sim \text{Normal}(0, \sigma)$$

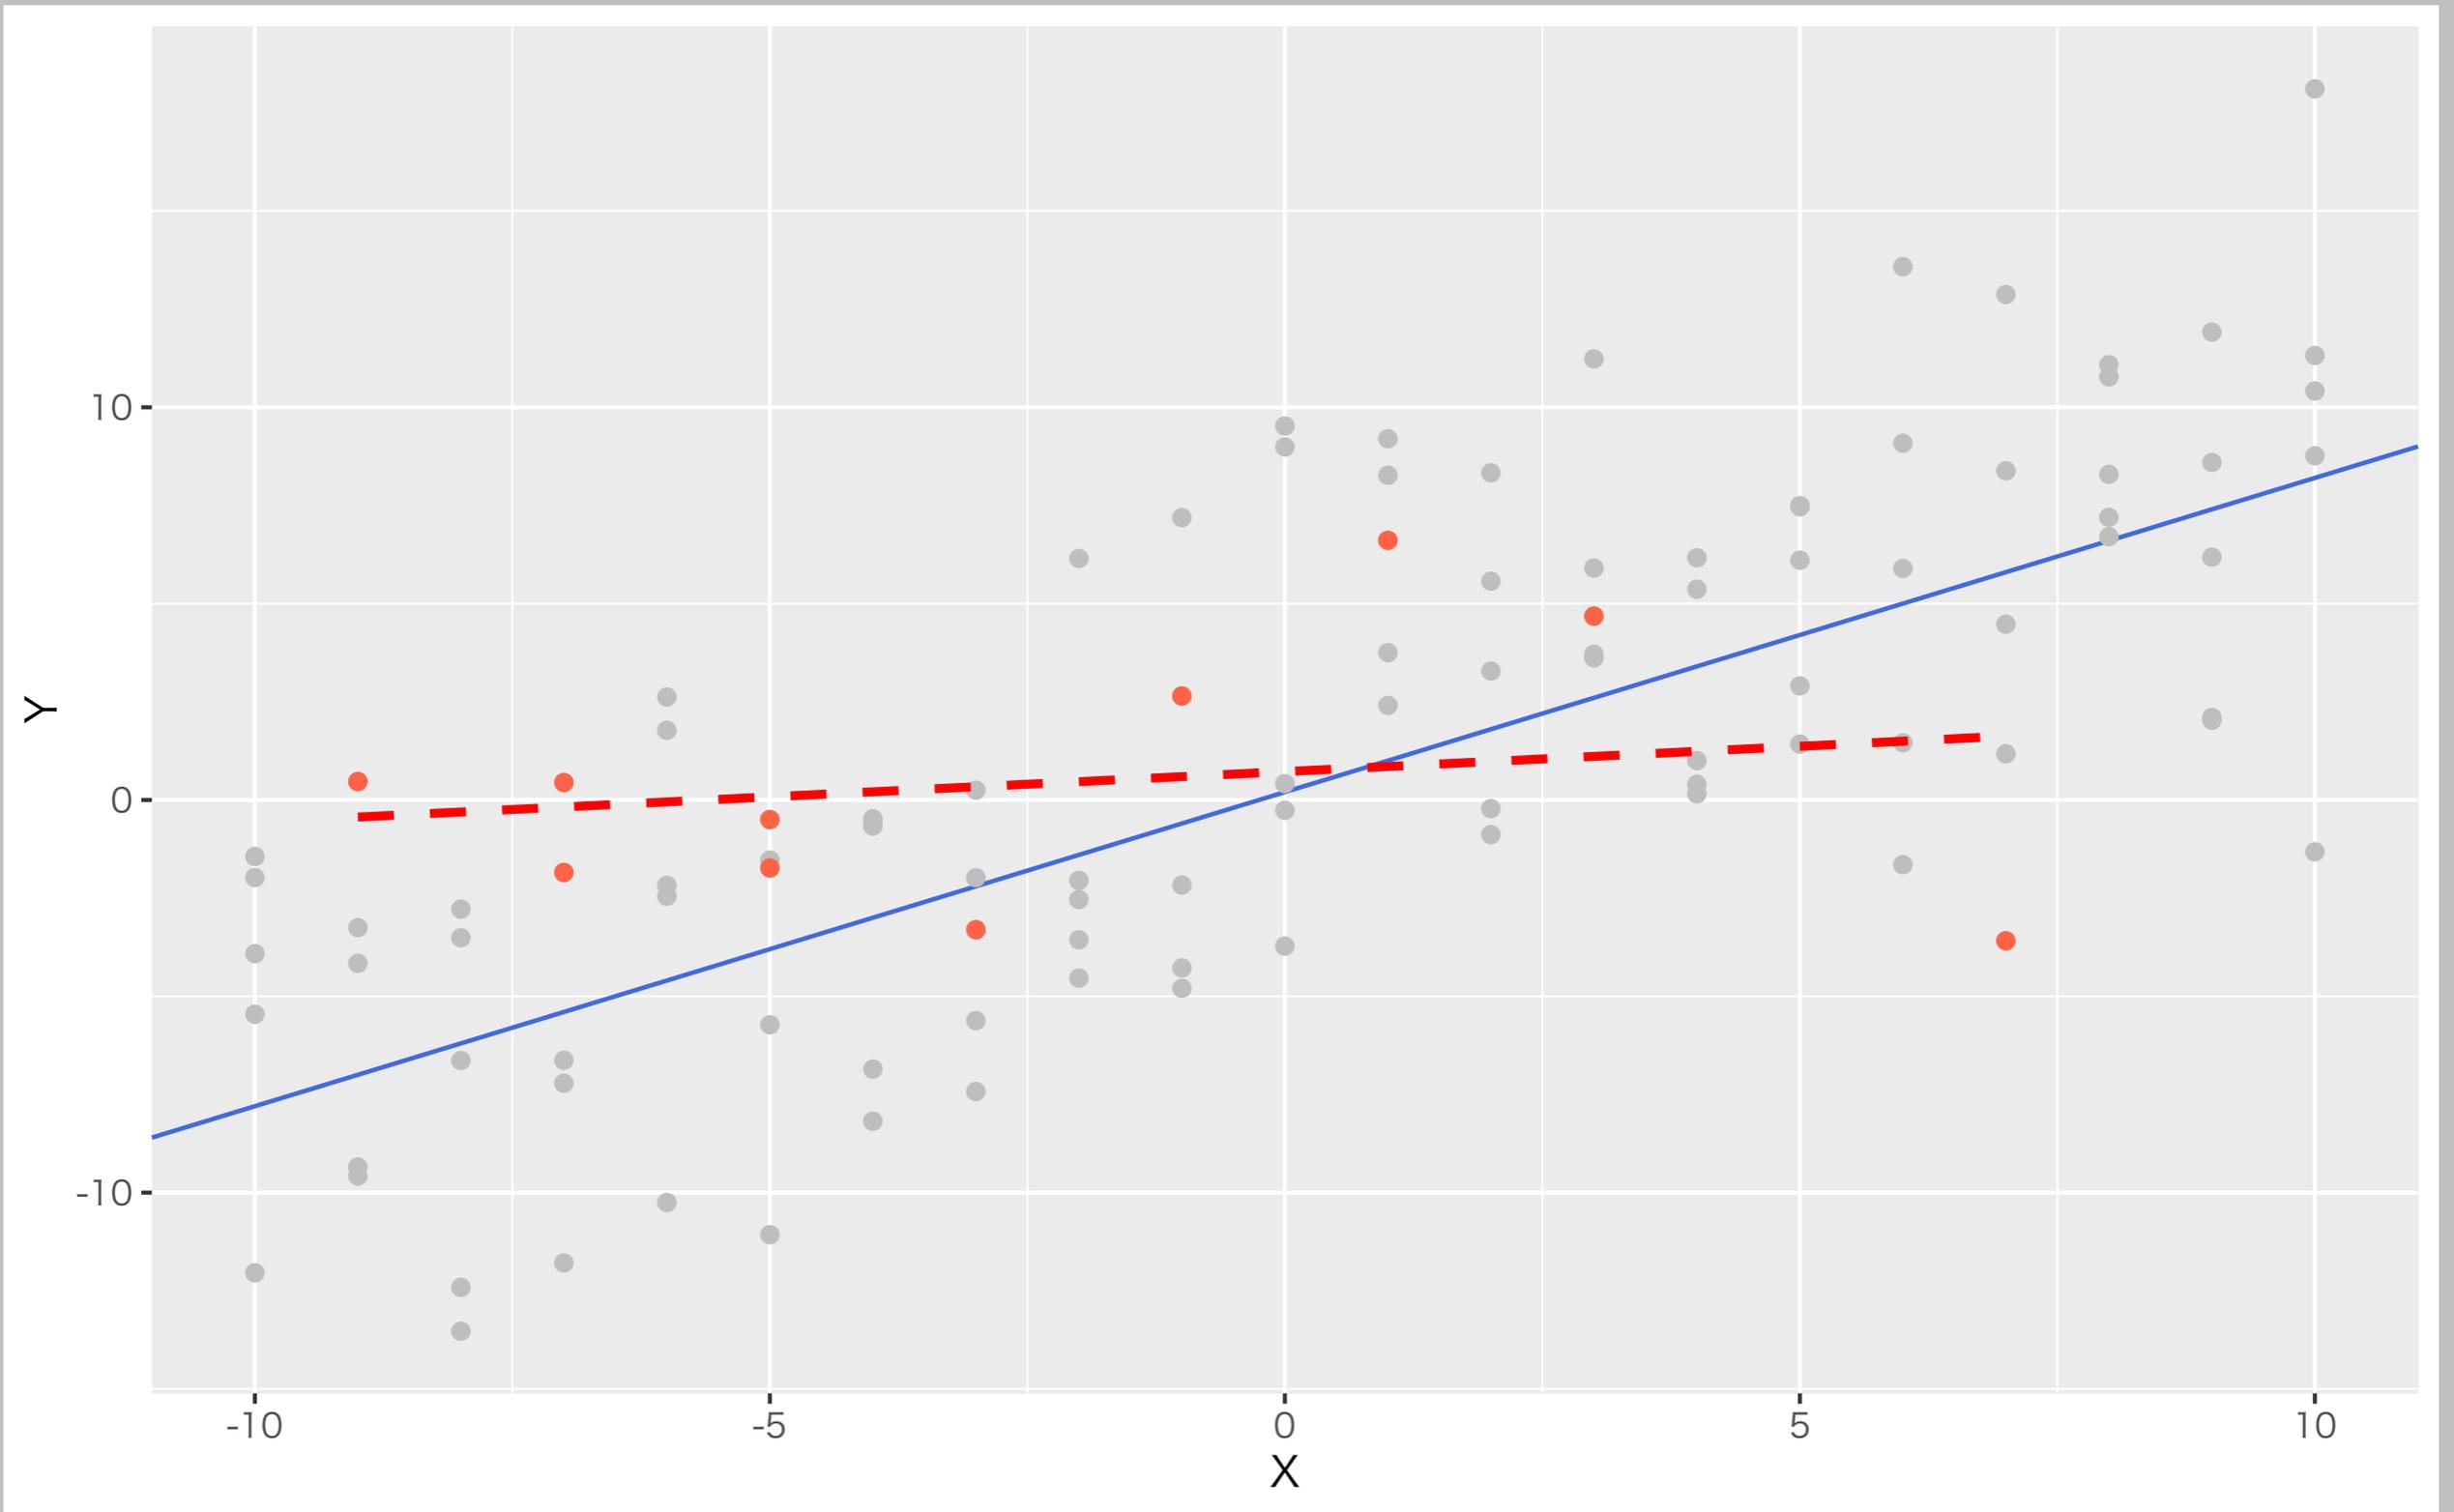
# 母集団の回帰直線



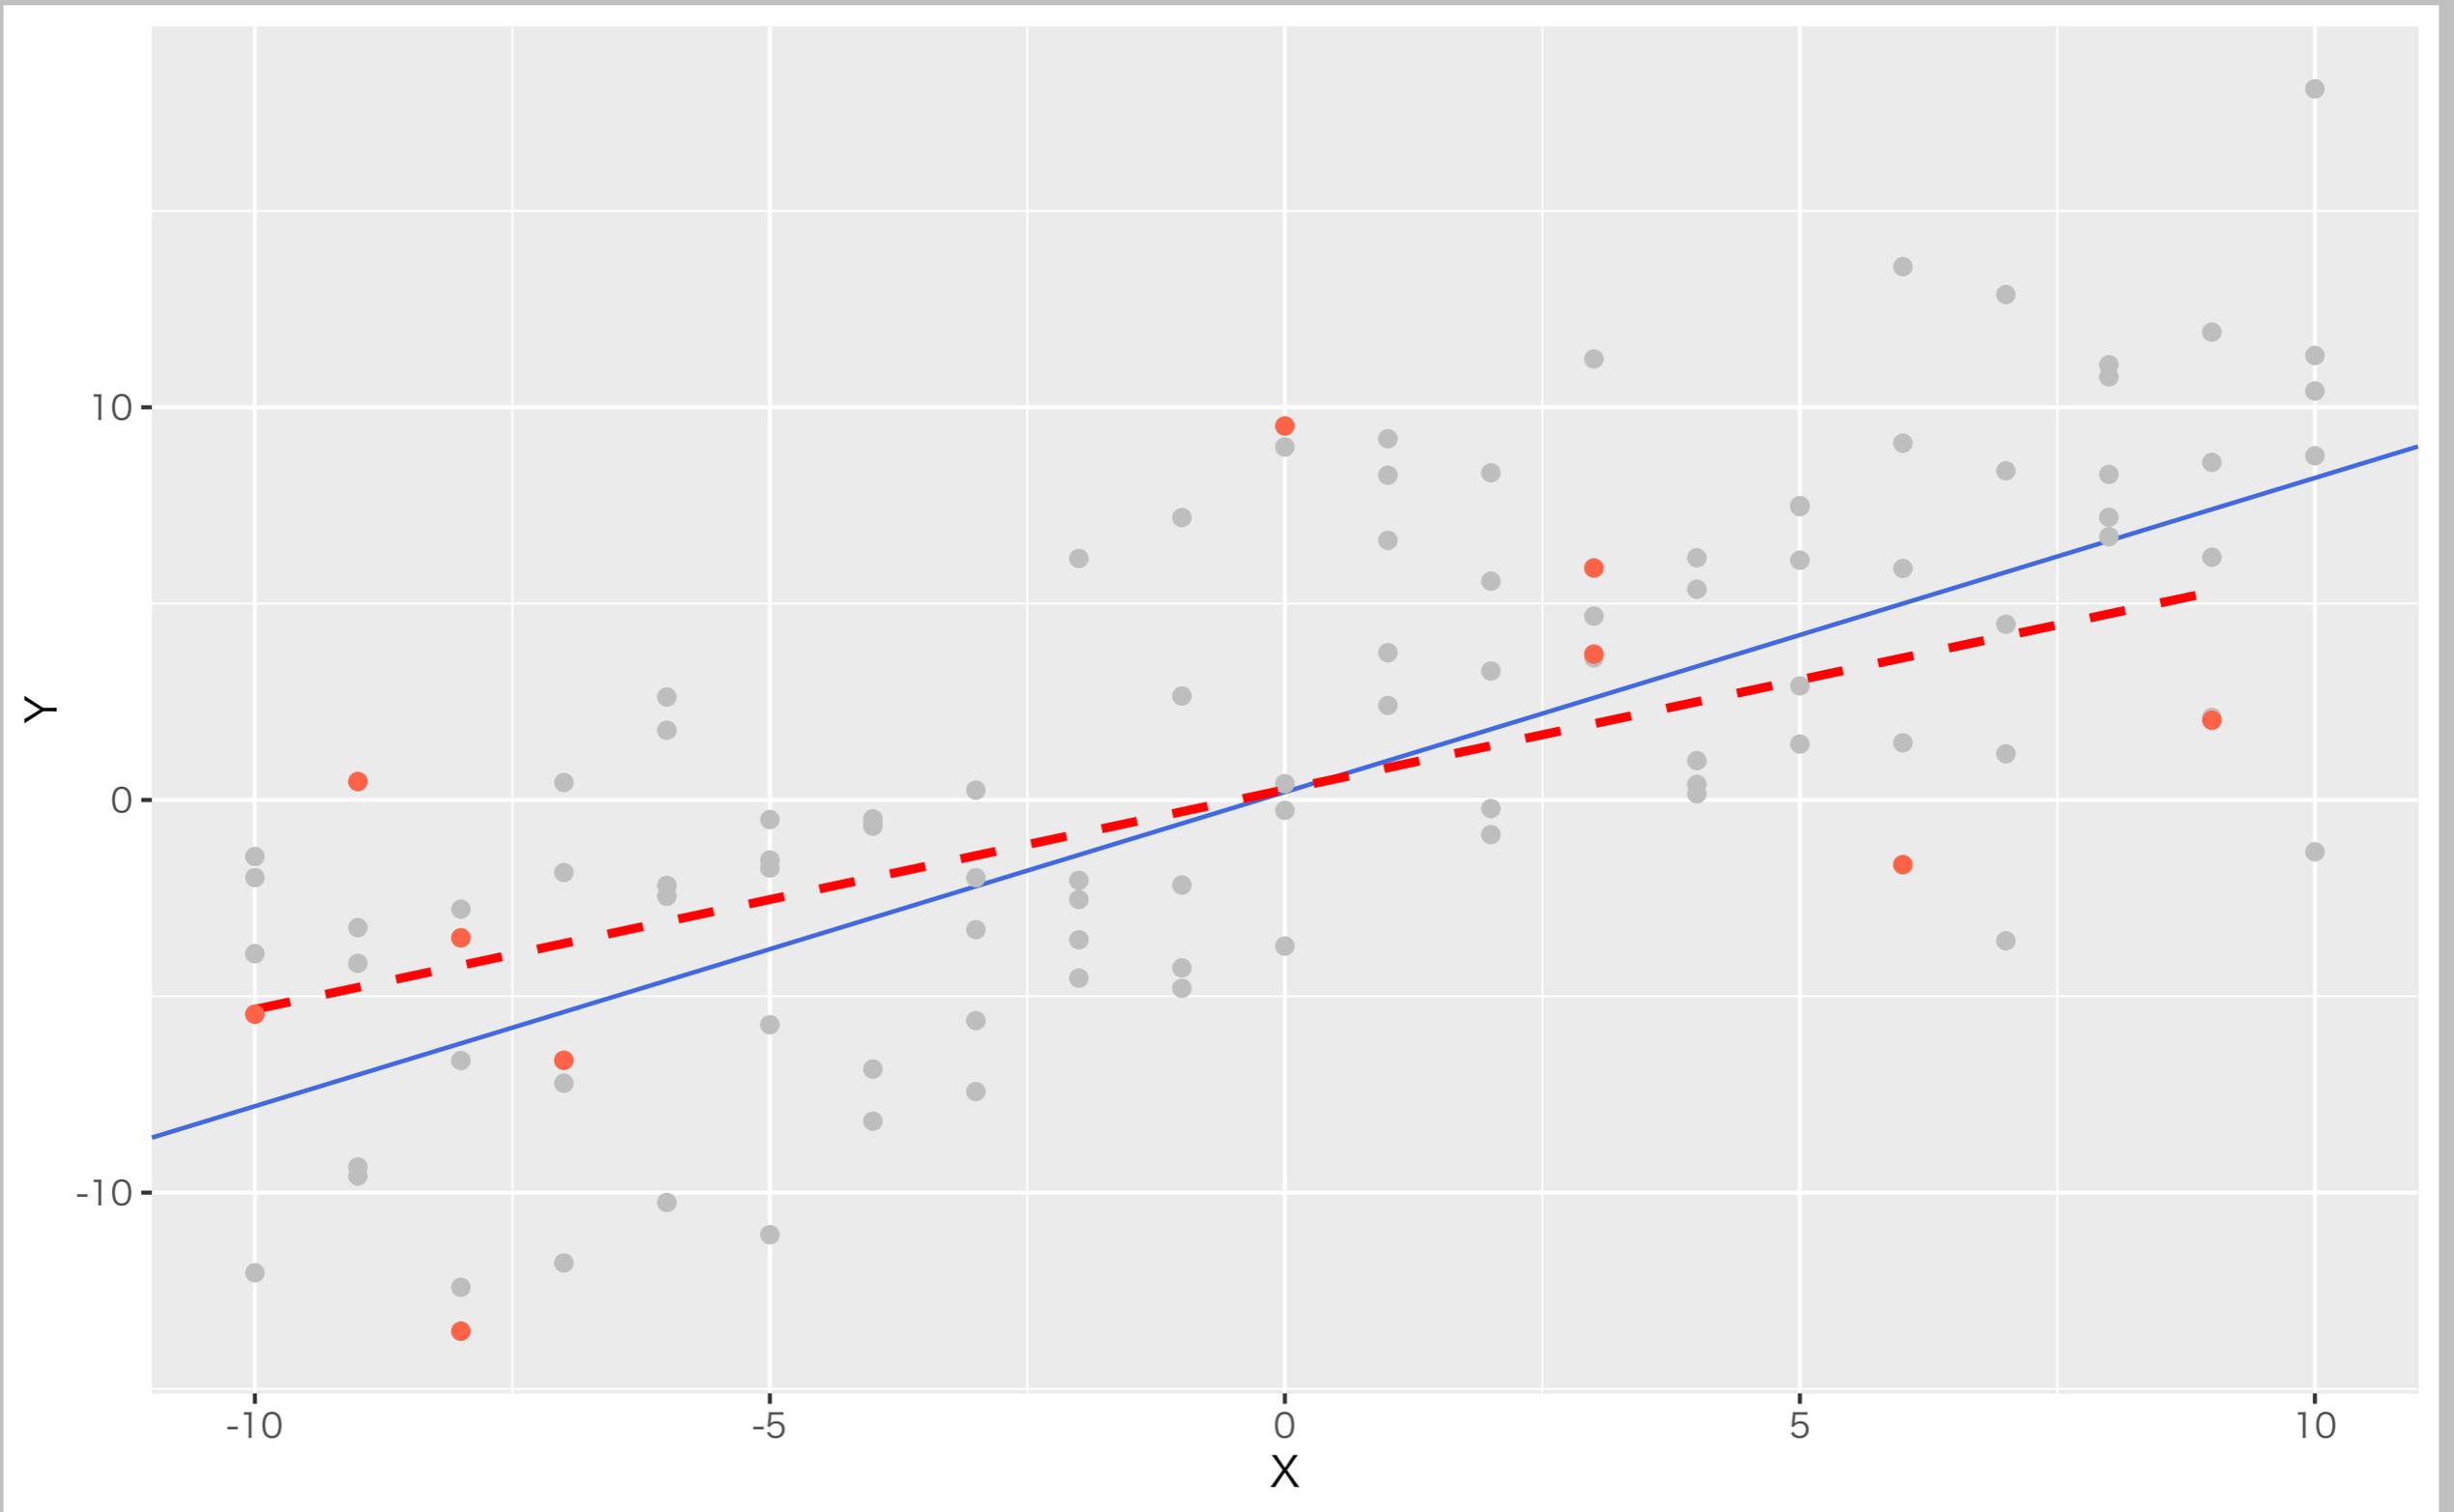
# 標本の回帰直線 (1)



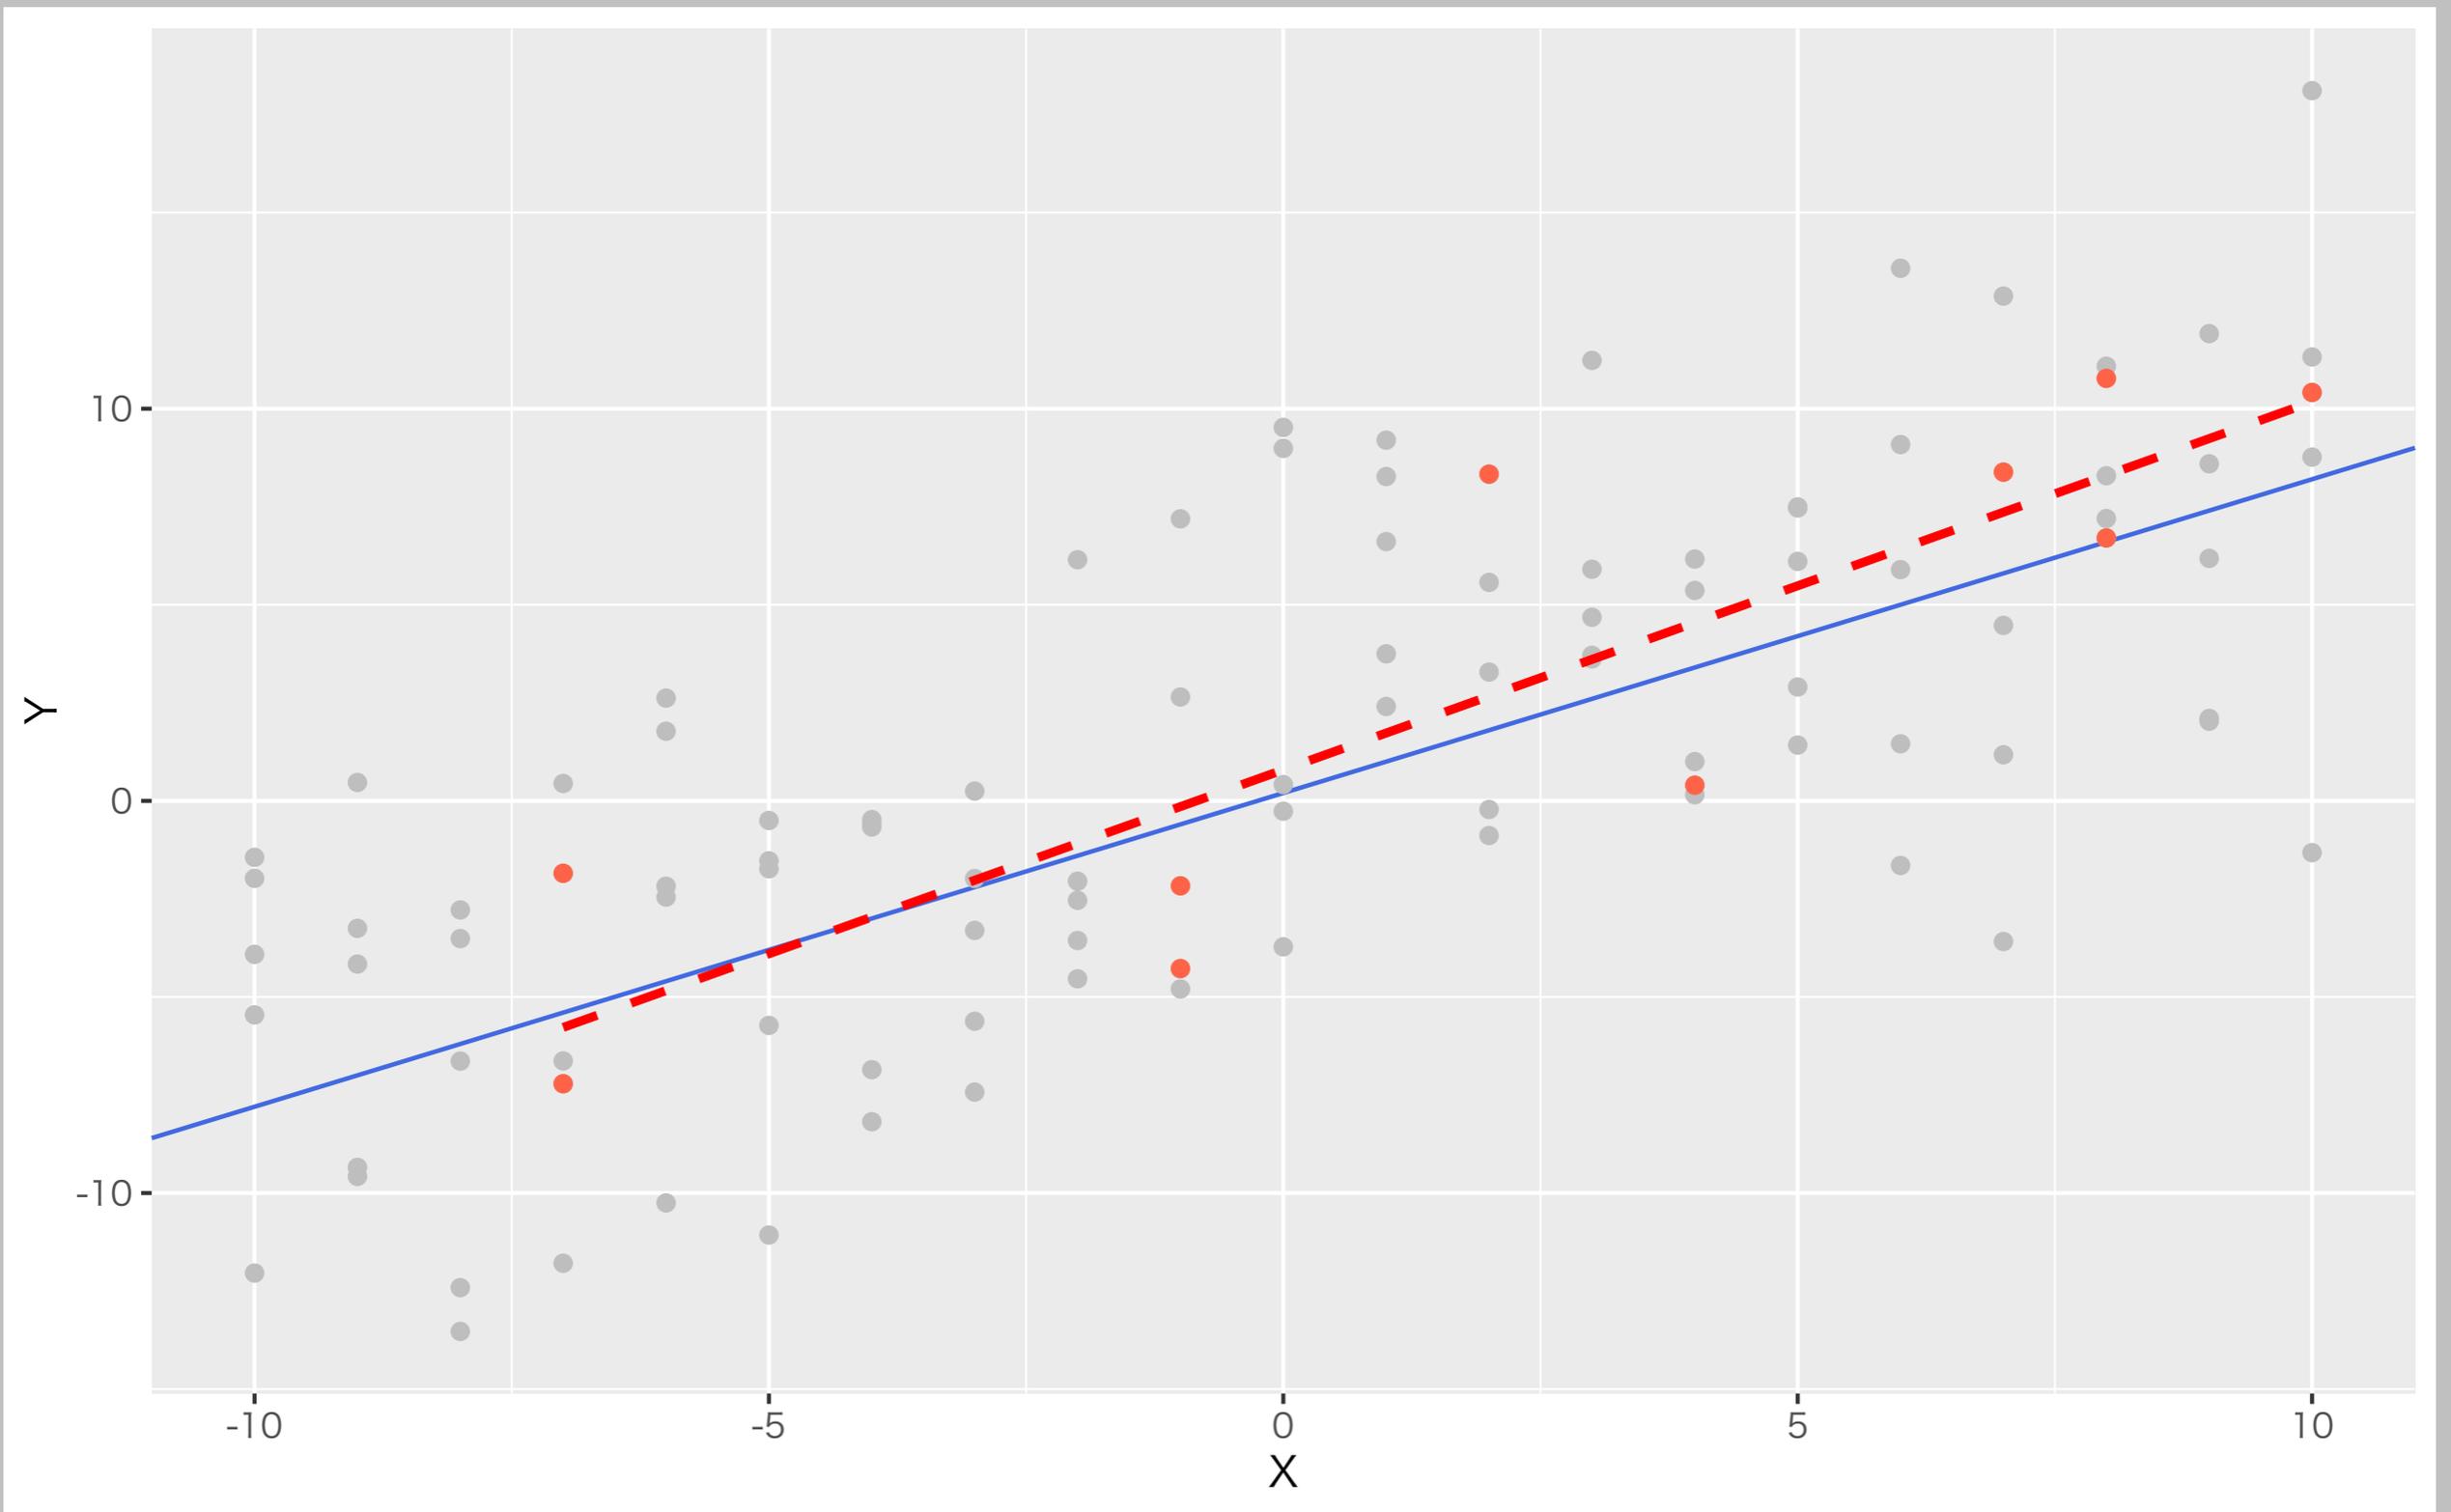
# 標本の回帰直線 (2)



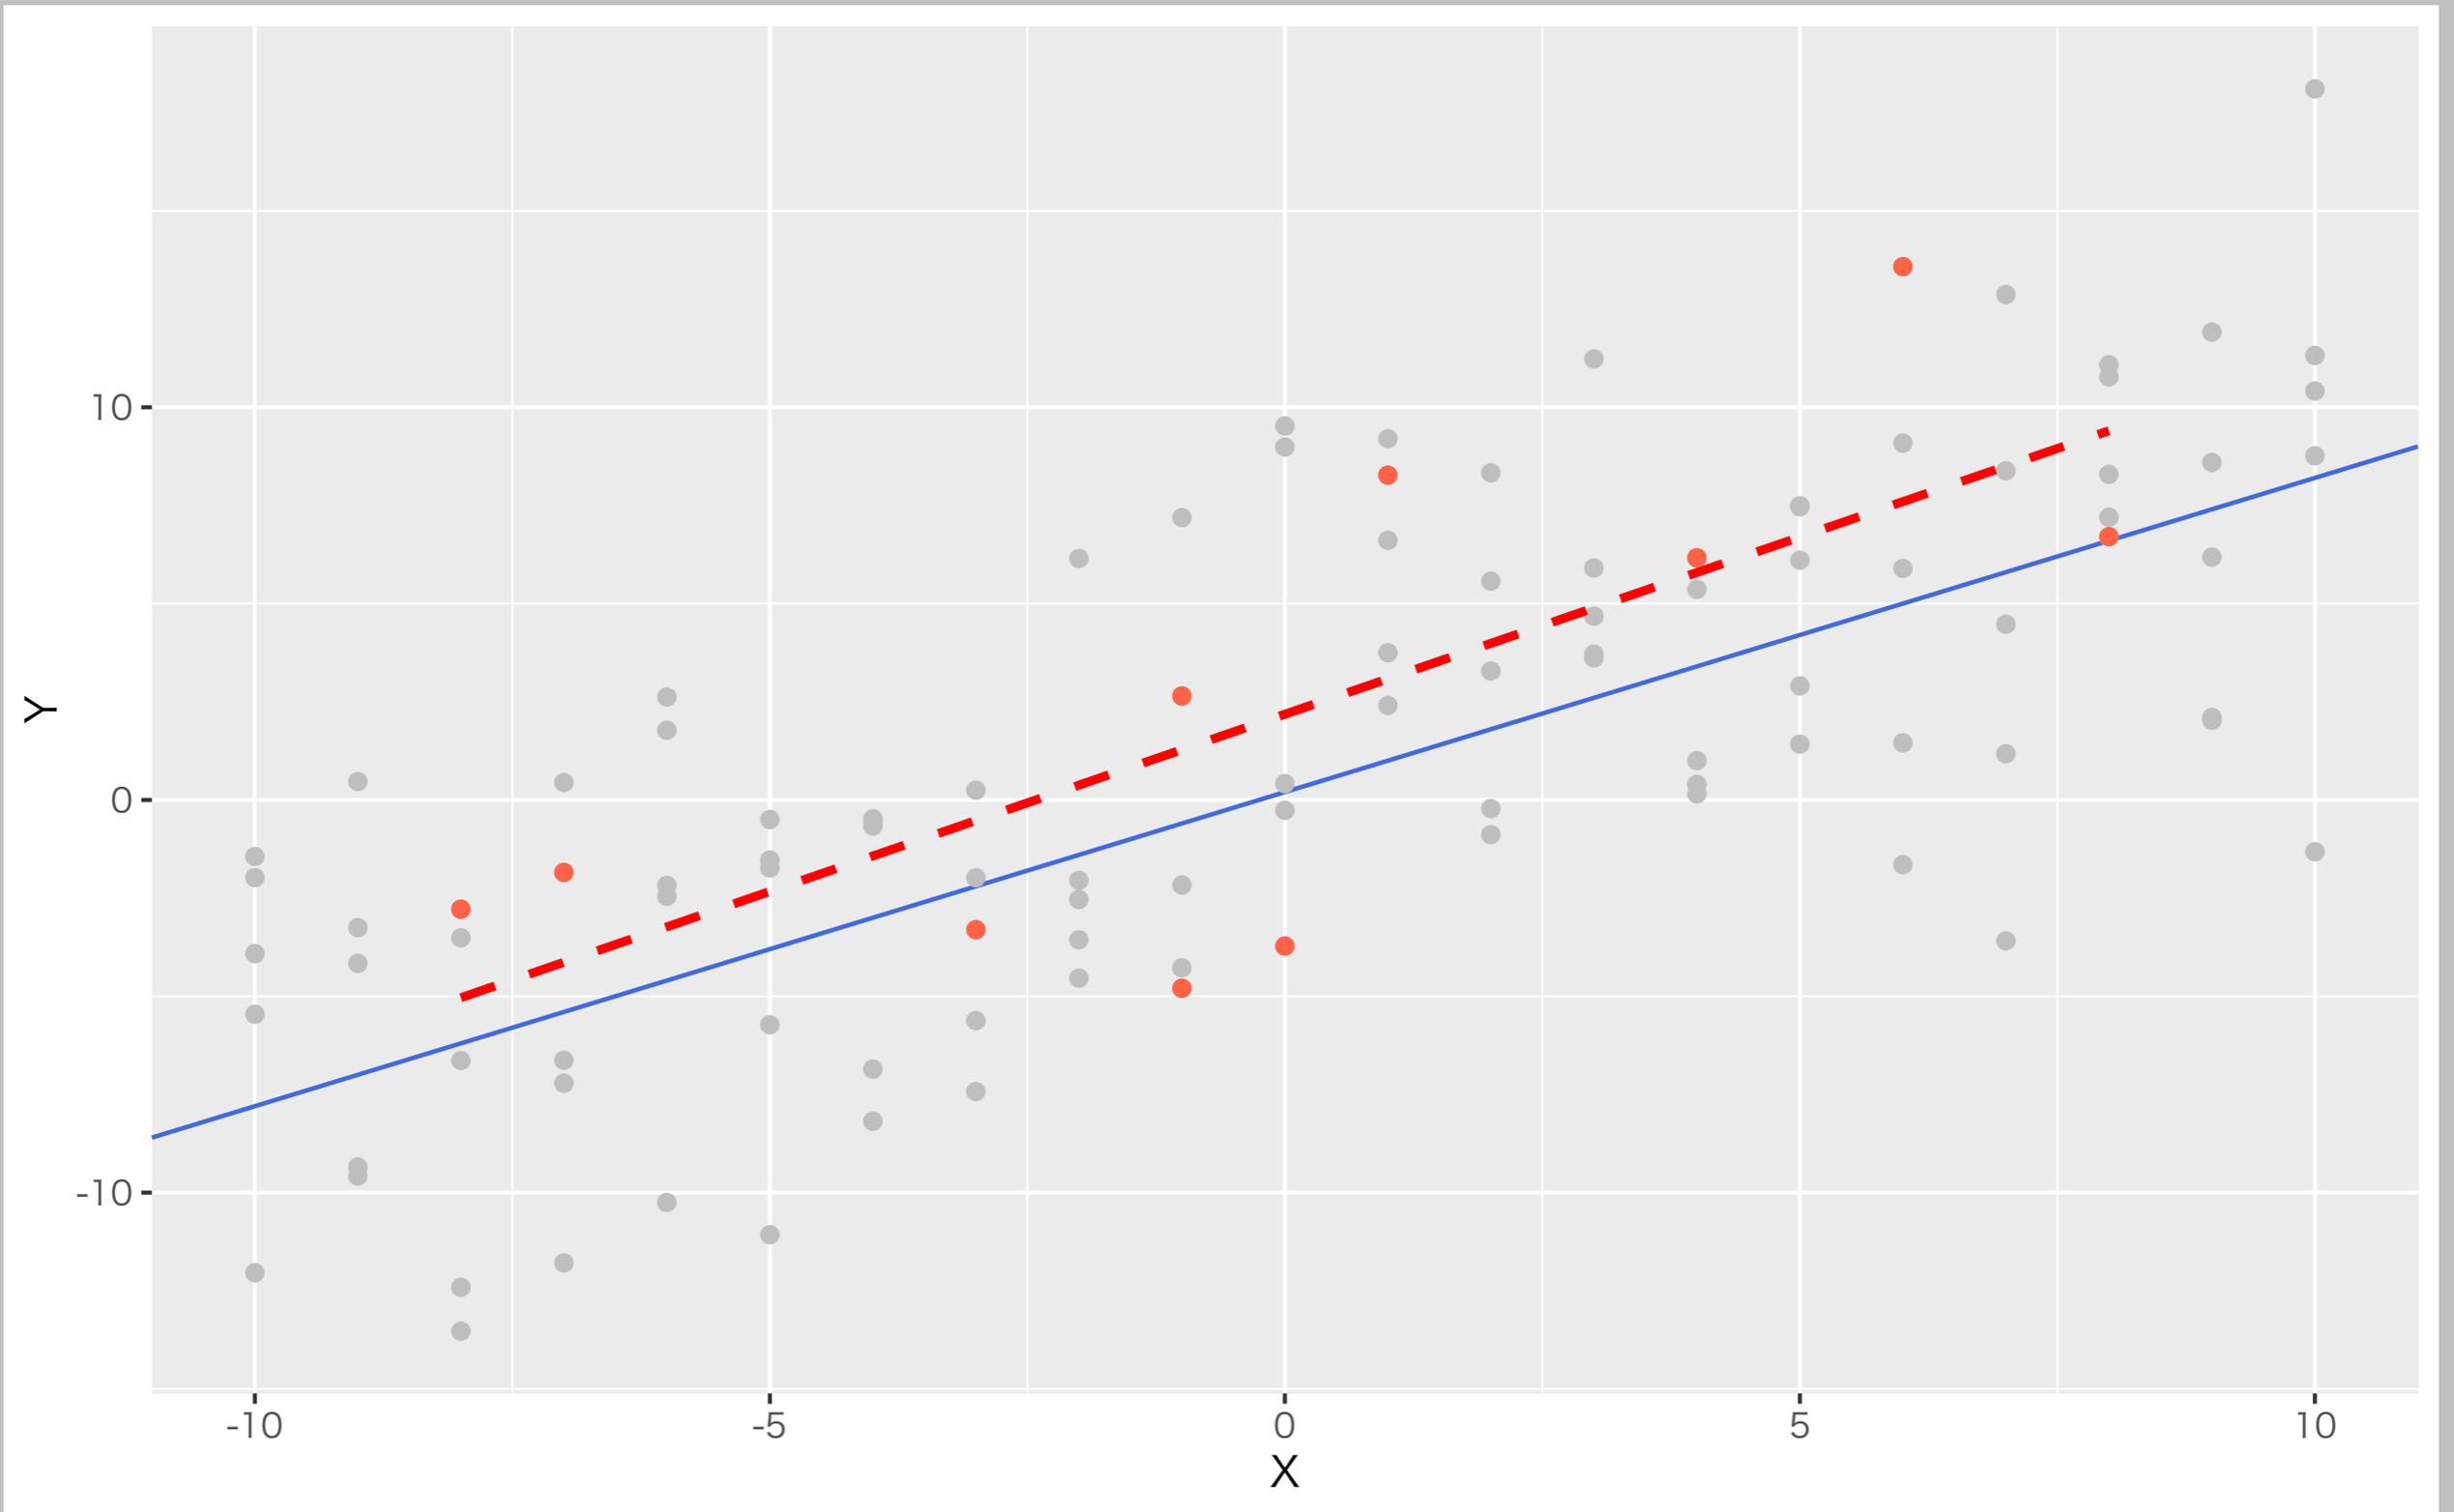
# 標本の回帰直線 (3)



# 標本の回帰直線 (4)



# 標本の回帰直線 (5)



# 最小二乗法による母数の推定：単回帰の場合

- 標本データを使い、最小二乗法によって求めた回帰係数  $a, b$  は、単回帰モデルに登場する  $\alpha, \beta$  の点推定値
- 最小二乗推定量は以下の望ましい性質をもつ
  - ▶ 不偏性 (unbiasedness) :  $E[a] = \alpha, E[b] = \beta$
  - ▶ 一貫性 (consistency) : 標本サイズを無限大にすると、推定値は母数に一致する

# 重回帰

- 母集団における重回帰

$$Y_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \cdots + \beta_K X_{iK} + \varepsilon_i$$

- $\beta_k$  : パラメータ, 母数 (推定の対象) 、  $k = 0, 1, 2, \dots, K$

- $\varepsilon$  : 誤差

▶  $\varepsilon_i \sim \text{Normal}(0, \sigma)$

# 重回帰モデル

- 重回帰モデル：重回帰が想定するDGP
  - ▶ まず、 $X_{ik}$  ( $i = 1, 2, \dots; k = 0, 2, \dots, K$ )の値が決まる
  - ▶ 次に、 $Y_i$  ( $i = 1, 2, \dots$ )の値が以下のように決まる

$$Y_i \sim \text{Normal}(\mu_i, \sigma)$$

$$\mu_i = \beta_0 + \beta_1 X_{i1} + \dots + \beta_K X_{iK}$$

# 最小二乗法による母数の推定：重回帰の場合

- 標本データを使い、最小二乗法によって求めた回帰係数  $b_0, b_1, \dots, b_K$  は、 $\beta_0, \beta_1, \dots, \beta_K$  の推定値である
  - ▶ 不偏性： $\mathbb{E}[b_k] = \beta_k$  ( $k = 0, 1, 2, \dots, K$ )
  - ▶ 一貫性

# 回帰分析の 帰無仮説と対立仮説

# 何のために回帰分析を行うのか

- 目的：理論（理論仮説）を検証したい
  - ▶ そのために作業仮説を用意する
  - ▶ 回帰分析で検証可能な作業仮説を用意する
    - 1つの応答変数
    - 1つ以上の説明変数
    - 説明変数が応答変数に与える影響についての仮説
      - ◆ 例：「 $X$  が  $Y$  を増加させる」

# 帰無仮説と対立仮説

- 帰無仮説：「説明変数は応答変数に影響を与えない」
- 対立仮説：「説明変数が応答変数に影響する」
  - ▶ 自分が「正しい」ことを示したい理論の作業仮説を対立仮説にする
- 統計的検定（方法は後で説明する）で帰無仮説が棄却されたとき、「作業仮説が統計的に正しい」と判断する
  - ▶ 作業仮説が正しいと考えられるので、操作化がうまくできていれば、理論仮説の蓋然性が高まる
    - 操作化（作業仮説と理論仮説の類似度）が重要

# 単回帰の場合

- モデル：  $Y_i \sim \text{Normal}(\alpha + \beta X_i, \sigma)$
- 検証する仮説
  - ▶ 帰無仮説：  $\beta = 0$
  - ▶ 対立仮説：  $\beta \neq 0$

# 重回帰の場合 (1) 包括的検定

- モデル：  $Y_i \sim \text{Normal}(\beta_0 + \beta_1 X_{i1} + \dots + \beta_K X_{iK}, \sigma)$
- 検証する仮説のパターン
  - ▶ 帰無仮説：  $\beta_1 = \beta_2 = \dots = \beta_K = 0$
  - ▶ 対立仮説： 「 $\beta_1, \beta_2, \dots, \beta_K$  のうち、少なくとも1つについて  $\beta_k \neq 0$ 」

# 重回帰の場合 (2) 個別的検定

- モデル：  $Y_i \sim \text{Normal}(\beta_0 + \beta_1 X_{i1} + \dots + \beta_K X_{iK}, \sigma)$
- 検証する仮説のパターン2

	$\beta_1$ の仮説	$\beta_2$ の仮説	...	$\beta_K$ の仮説
▶ 帰無仮説：	$\beta_1 = 0$	$\beta_2 = 0$	...	$\beta_K = 0$
▶ 対立仮説：	$\beta_1 \neq 0$	$\beta_2 \neq 0$		$\beta_K \neq 0$

- 実際は、すべての  $k$  について仮説を立てて検証するわけではなく、理論における「原因」とみなされるものについてのみ個別に仮説を検証する

# 「影響がない」を検証する???

- 通常、「影響がない」は帰無仮説
  - ▶ 「影響がない」を対立仮説にすると、帰無仮説「影響がある」は棄却できない（検証する対象が無限にある）
  - ▶ 「影響がない」という帰無仮説を棄却できなくても、それは「影響がない」ことを意味しない
    - 「影響がある」という証拠が見つからないだけ
    - 「証拠の不在」は「不在の証拠」ではない！
- ★ 「影響がない」ことを主張する理論は、（これまで勉強してきた）統計的分析では検証不可能

# 回帰分析による 統計的検定と推測

# 回帰分析における仮説検定

- 回帰分析では、説明変数が応答変数に影響を与えているかどうかに関心がある
  - 帰無仮説：説明変数の影響はない（影響が0である）
  - 対立仮説：説明変数の影響がある（影響が0ではない）

# 単回帰の例

- 単回帰モデル：  $Y_i \sim \text{Normal}(\alpha + \beta X_i, \sigma)$ 
  - ▶ 帰無仮説：  $\beta = \tilde{\beta}$
  - ▶ 対立仮説：  $\beta \neq \tilde{\beta}$
- 標本  $(y, x)$  から求めた回帰直線：  $\hat{y}_i = a + bx_i$

# 推定値のばらつき

•  $b$ :  $\beta$  の点推定量

▶  $b$  の値は標本によってばらつく

▶ 標本ごとに異なる  $b$  の標準偏差：標準誤差 (SE)

$$\text{SE}(b) = \sqrt{\frac{\hat{V}_1}{N}}$$

$$\hat{V}_1 = \frac{\frac{1}{N} \sum_{i=1}^N [(x_i - \bar{x})^2 e_i^2]}{\left[ \frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2 \right]^2}$$

ただし、 $e_i$  は残差： $e_i = y_i - \hat{y}_i = y_i - (a + bx_i)$

▶ 詳しくは、西山ほか (2019) 『計量経済学』 (有斐閣) : 第4章を参照

# 推定量 $b$ の分布

$$\frac{b - \tilde{\beta}}{\text{SE}(b)} \sim t(N - K - 1)$$

- ▶  $\tilde{\beta}$  : 帰無仮説が想定する  $\beta$ 
  - 帰無仮説が正しいなら、 $\mathbb{E}[b] = \tilde{\beta}$
- ▶  $t(N - K - 1)$  : 自由度  $N - K - 1$  の  $t$  分布
  - $N$  : 標本サイズ
  - $K$  : 説明変数の数 (切片は含まない)

# $t$ 統計量を用いた仮説検定

$$t \text{ 統計量} : T = \frac{b - \tilde{\beta}}{\text{SE}(b)}$$

- 特定の有意水準のもとで、自由度  $N - K - 1$  の  $t$  分布の臨界値  $c$  を求め、

$$|T| > |c|$$

となるとき、帰無仮説を棄却する

# $t$ 統計量を用いた仮説検定 (続)

- 帰無仮説が  $\beta = 0$  (つまり、 $\tilde{\beta} = 0$ ) のとき、

$$T = \frac{b - \tilde{\beta}}{\text{SE}(b)} = \frac{b}{\text{SE}(b)}$$

- この  $T$  の値は、Rで回帰分析結果に t value または statistic として表示される
- 有意水準が5パーセントのとき、検定の臨界値は約2
  - ▶ よって、係数を標準誤差で割った値の絶対値が2より大きければ、有意水準5%で帰無仮説を棄却する

# Rで回帰分析

- `lm()` 関数を使う

- ▶ 例、`myd` という名前のデータセット (データフレーム, `tibble`) に含まれる変数を使い、`y` を `x1` と `x2` に回帰する

```
fit <- lm(y ~ x1 + x2,  
         data = myd)
```

# summary() による結果の表示

- `lm()` で推定した後、`summary()` で結果を確認する
- 例：`summary(fit)`
  - ▶ Estimate: パラメタの点推定値
  - ▶ Std. Error: 標準誤差 (推定の不確実性)
  - ▶ t value:  $t$  検定で使う検定統計量
  - ▶  $\text{Pr}( > |t| )$ :  $p$  値

# summary() による結果の表示 (続)

```
> summary(fit1)

Call:
lm(formula = voteshare ~ experience, data = HR1996)

Residuals:
    Min       1Q   Median       3Q      Max
-38.334 -10.007  -2.207   8.593  67.393

Coefficients:
            Estimate Std. Error t value Pr(>|t|)
(Intercept)  16.0070     0.4608   34.74  <2e-16
experience   22.8274     0.7891   28.93  <2e-16

Residual standard error: 13.28 on 1259 degrees of freedom
Multiple R-squared:  0.3993,    Adjusted R-squared:  0.3988
F-statistic: 836.8 on 1 and 1259 DF,  p-value: < 2.2e-16
```

# broom::tidy() で結果を確認する

- broom パッケージの `tidy()` 関数でも結果を確認できる
- 以下のようにすると、95パーセント信頼区間も表示できる (95パーセント以外にするには、`conf.level` を変える)

```
tidy(fit,  
     conf.int = TRUE,  
     conf.level = 0.95)
```

# broom::tidy() で結果を確認する (続)

```
> tidy(fit1, conf.int = TRUE)
# A tibble: 2 x 7
  term          estimate std.error statistic  p.value  conf.low  conf.high
<chr>          <dbl>    <dbl>    <dbl>    <dbl>    <dbl>    <dbl>
1 (Intercept)    16.0     0.461     34.7 5.66e-186  15.1     16.9
2 experience     22.8     0.789     28.9 1.68e-141  21.3     24.4
```

# Rで信頼区間を求める

- `lm()` を実行した後、`confint()` 関数を使うと、係数の信頼区間を求めることができる。

## ▶ 例

- 95%信頼区間 : `confint(fit)`
- 50%信頼区間 : `confint(fit, level = 0.5)`
- 68%信頼区間 : `confint(fit, level = 0.68)`

- ▶ 上のコマンドを実行すると、信頼区間の下限値と上限値が表示される

# 信頼区間の図示

- ggplot2 を使えば、以下のものが図示できる
  - ▶ 回帰直線 + 95%信頼区間

```
geom_smooth(method = "lm")
```

- ▶ 回帰直線 + 89%信頼区間

```
geom_smooth(method = "lm", level = 0.89)
```

- ▶ 回帰直線のみ

```
geom_smooth(method = "lm", se = FALSE)
```

# 信頼区間

- 回帰分析による点推定値は、1つの標本（データ）から得られたもの
- ➔ 母数に一致するとは限らない（実際の標本サイズは有限なので）
- 統計量はばらつく（シミュレーションで確認する！）
  - 標準誤差：統計量のばらつき
- ➔ 信頼区間を求める！

# 信頼区間の意味 (1)

- 95%信頼区間とは何か？

- ▶ よくある**誤解**：「得られた信頼区間に、真の値が入っている確率が95%」

- ▶ 「真の値」があるなら、「得られた信頼区間に、真の値が入っている確率」は、

- 100% (実際に入っている)

または

- 0% (入っていない)

しかあり得ない

# 信頼区間の意味 (2)

- では、95%信頼区間とは何なのか？
  1. データを生成する (新たに観測する)
  2. データを分析する
  3. 95%信頼区間を求める
- 95%信頼区間：上の1~3までを何度も何度も繰り返し行くと、そのうち95%は「真の値を含む信頼区間」が得られるだろう

# 信頼区間の信頼度 (1)

- 信頼区間の長さ

- ▶ 信頼度が高いほど区間が長くなる
- ▶ 信頼度が低いほど区間が短くなる

- なぜ？

- ▶ 区間を長くすれば、取りこぼしの確率が小さくなる
- ▶ 区間を短くすれば、取りこぼしの確率は大きくなる

# 信頼区間の信頼度 (2)

- では、信頼区間は長い方がいいのか？

▶ **No!**

- ▶ 同じ信頼度で、信頼区間が短いほうが推定の不確かさが小さい
- ▶ 信頼区間の長さ：標準誤差に依存
  - 標準誤差が大きい：信頼区間が長い
  - 標準誤差が小さい：信頼区間が短い

統計的に有意とは？

# 統計的に有意とは？(1)

- 「統計的に有意」な結果を見せられたとき、私たちはどのように反応すべきか？
  - ▶ 「**だから何？**」 「統計的に有意だと**何が嬉しいの？**」
- 統計的に有意：効果が0ではない
  - ▶ 「ゼロでない効果」には色々ある
    - 計量経済学に関する自習時間を1日10時間増やすと、期末試験の点数が5点上がる
    - 計量経済学に関する自習時間を1日に10分増やすと、期末試験の点数が25点上がる

# 統計的に有意とは？(2)

- 効果が「ゼロではない」と信じるに足る証拠がある
  - ▶ それだけ！
- 「ゼロではない」 ≠ 重要
- 研究においては、「重要である」ことを示すことが求められる
  - ▶ 実質的重要性 (substantive significance) を示すことが必要 (**浅野・矢内 2018: pp. 165-168** を参照)
- **係数の値そのもの (効果量, effect size) を議論することが絶対に必要！！！！**

# やってはいけない (1)

- 「統計的に有意であること」を論文（あるいは統計分析の）の結論のように書いてはいけない！
  - ▶ 統計的に有意であることは、分析結果の一部に過ぎない
  - ▶ そこから「論文で扱っている特定の研究対象について」何が言えるのか掘り下げ、リサーチクエスチョンに答える必要がある
- **結論は、リサーチクエスチョン (RQ) に対する答え**



# ダメな例を改善する：パターン1

- RQ: 「計量経済学」の成績を上げるにはどうしたらいいか？
- 理論：「Rを使いこなすと、成績が上がる」
- 作業仮説：「Rを1時間以上利用する日数が増えると、成績（100点満点）が上昇する」
- 回帰分析で検証：統計的に有意
  - ▶ 使用日数が1日増えるごとに、点数が1点上がる
  - ▶ 1Qは60日ある：最大で60点成績アップが可能
  - ▶ 分析の結論：「Rの使用日数は成績を上げる」
- 結論：「計量経済学」の成績を上げるためには、1時間以上Rを使う日をできるだけ増やせばよい

★ 読者：！！！！

# ダメな例を改善する：パターン2

- RQ: 「計量経済学」の成績を上げるにはどうしたらいいか？
- 理論: 「Rを使いこなすと、成績が上がる」
- 作業仮説: 「Rを1時間以上利用する日数が増えると、成績（100点満点）が上昇する」
- 回帰分析で検証: **統計的に有意**
  - ▶ 使用日数が1日増えるごとに、点数が0.05点上がる
  - ▶ 1Qは60日ある: 最大で3点成績アップが可能
  - ▶ 分析の結論: 「Rの使用日数を増やしても成績は**あまり変わらない**」
- 結論: Rを1時間以上使う日数を増やしただけでは「計量経済学」の成績をよくするのは難しいので、他の方法を考える必要がある

矛盾しない!

★ 読者: ...

# 効果がないことを証明できる？

- 効果がないことを証明したいとき、 $\beta = 0$  という帰無仮説が保留（受容）されることは証拠として使える？

➡ 使えない！

- （通常の）統計的仮説検定の方法では、効果がない証拠を見つけることは不可能（以下のいずれかの方法が必要）
  - ▶ 同等性の検定 (test of equivalence) を実施する
  - ▶ ROPE [region of practical equivalence] というものを設定し、ベイズ統計分析を実行する

# やってはいけない (2)

- 「影響がない」ことを（これまで習った）統計分析の結論として述べてはいけない
  - ▶ 通常の統計的検定の枠組みでは、「影響がない」ことは示せない
    - 「神がいる」という証拠がないことは、「神がいない」ことの証明にはならない
- **結論は、以下の3つのうちのどれか：**
  - ▶ 「意味のある影響がある（統計的に有意で実質的にも有意）」
  - ▶ 「影響はある（統計的に有意）が実質的には無意味」
  - ▶ 「影響があるという証拠がない（統計的に有意ではない）」

# 次のトピック

回帰分析の応用