

④ ガリシア文字 β と ε
 $b \rightarrow \beta$ (ベータ)
 $e \rightarrow \varepsilon$ (エプシロン)

📖 ノート1 母集団に対する仮定：統計モデル

(1) 統計モデル

これは、研究者が母集団に対して想定するモデル。

例1：t検定

① ダミー変数

分類を表す質的変数(名義尺度変数)に便宜的に0, 1, ...のように数値を与えコード化した変数。


$$x_i = \begin{cases} 1 & \text{if } i\text{th person is } \begin{matrix} \text{女性} & A \\ \text{日本人} & 1 \end{matrix} \\ 0 & \text{if } i\text{th person is not } \begin{matrix} \text{女性} & A \\ \text{日本人} & 1 \end{matrix} \end{cases}$$

※1か0のものを指示変数 Indicator variable と呼ぶ。

② 線形モデル


$$y_i = \beta_0 + \beta_1 x_i + \varepsilon_i$$

$$= \begin{cases} \beta_0 + \beta_1 + \varepsilon_i & (\text{グループ1}) \\ \beta_0 & + \varepsilon_i & (\text{グループ2}) \end{cases}$$



④ 統計モデルの把握

① 図 (幾何的な理解)



② 数式 (代数的な理解)

③ $y_i = \beta_0 + \varepsilon_i$ (グループ0) = y_i

= $\beta_0 + \varepsilon_i$

④ $y_i = \beta_0 + \beta_1 + \varepsilon_i$ (グループ1) = y_i

= $\beta_0 + \beta_1 + \varepsilon_i$

この③と④を統合させずに表現することはできない。

⑤ $y_i = \beta_0 + \beta_1 x_i + \varepsilon_i$

$$x_i = \begin{cases} 0 & \text{グループ0} \\ 1 & \text{グループ1} \end{cases}$$



質問 ダミー変数はいつも0と1なんですか？

この他の組み合わせも可能です。ただ、係数の解釈が変わります。例えば、次の例では β_0 は全体の平均、 β_1 は平均から上下に男女がどのくらい離れるかを表します。

$$x_i = \begin{cases} 1 & \text{if } i\text{th person is } \text{---} \\ -1 & \text{if } i\text{th person is not } \text{---} \end{cases}$$

$$y_i = \begin{cases} \beta_0 + \beta_1 + \varepsilon_i \\ \beta_0 - \beta_1 + \varepsilon_i \end{cases}$$

例2：単回帰分析

① 概要

これは「予測変数 (x) と応答変数 (y) が一次直線と基本とする関係にある」と想定する統計モデル。

② 線形モデル

注

$$y_i \sim N(\beta_0 + \beta_1 x_i, \sigma^2)$$

x_i の値に依存

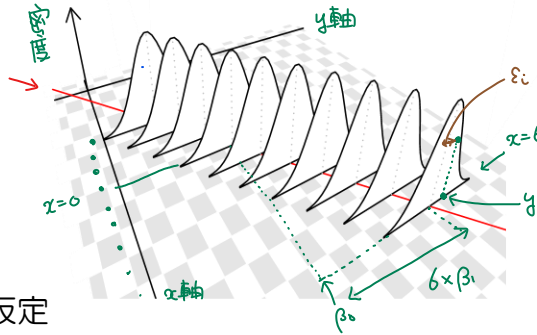
$$y_i = \beta_0 + \beta_1 x_i + \varepsilon_i$$

誤差項

「番目の」 x の値

$$\varepsilon_i \sim N(0, \sigma^2)$$

① 分散: 添え字 i に依存しない!
 ② 平均: 常にゼロ!
 (例: σ^2 を意味する $\varepsilon_i = 0$ の値と $\varepsilon_i = \varepsilon_j$ の値は、今回は、 i にかかわらず σ^2)



$x_i = 6$ の頂上から「番目の」 x の値より「どのくらい」離れたところの ε_i 、 ε_j の「番目の」独立性を述べ

(2) 仮定

【標本の抽出の仕方に関する仮定】

- ① 独立性の仮定: 各要素は互いに独立
 - ② 同一分布の仮定: 標本は同じ分布から抽出
 - ③ 無作為性の仮定: 標本はランダムに抽出
- $$y_i \sim N(\beta_0 + \beta_1 x_i, \sigma^2)$$
- i.i.d


【母集団の姿に関する仮定】

- ① 正規性の仮定: 母集団の分布は正規分布
- ② 分散の等質性の仮定: ~~母集団~~ 母集団の分散は同じ x_i の値に関係なく.

④ 誤差項 Error Term


① 赤い直線

これは、母集団の構造的な傾向



② 茶色の矢印

これは赤い直線から外れた「誤差」



④ 正規分布

これは、誤差が μ と σ^2 と生じる分布。
 \Rightarrow 誤差項が従う分布として仮定する。

④ 分布を表現可能な形

(i) $y_i = \beta_0 + \beta_1 x_i + \varepsilon_i$
 $\varepsilon_i \sim N(0, \sigma^2)$

(ii) $y_i \sim N(\mu_i, \sigma^2)$
 $\mu_i = \beta_0 + \beta_1 x_i$

(iii) $y_i \sim N(\beta_0 + \beta_1 x_i, \sigma^2)$


ノート2 統計量：回帰係数の点推定（最小二乗法）

(1) 最小二乗法 Least Squares Method

これは、二乗基準 で測ったデータと直線の適合の悪さ（残差）を最小化することで点推定値を出す方法。
 ↑
 $\hat{\beta}_0$ と $\hat{\beta}_1$ の値

① 残差 Residuals

これは、予測の誤差のこと。



↑ 1番目の観測値の残差
 $e_i = y_i - \hat{y}_i$
 $= y_i - (\hat{\beta}_0 + \hat{\beta}_1 x_i)$
 ↑ y_i のデータに対する予測値
 ↑ 1番目の観測値
 ↑ 人間が提案回帰直線から作った予測値

② 損失関数 Loss function

これは、適合の悪さを測る関数。一般的な単回帰では残差平方和 Residual Sum of Squares を損失関数とする。

$$L(\hat{\beta}_0, \hat{\beta}_1) = \sum_{i=1}^n e_i^2 = (e_1^2 + e_2^2 + e_3^2 + \dots + e_n^2)$$

この二つの組 $\hat{\beta}_0$ と $\hat{\beta}_1$ を
 とかえり、かえりかえた中から
 最も距離が小さいものを選ぶ

$$= \sum_{i=1}^n [y_i - (\hat{\beta}_0 + \hat{\beta}_1 x_i)]^2$$

(2) 最小二乗推定量

これは、最小二乗法で求めた点推定量のこと。単回帰モデルの場合は、次のような結果になる。

① 傾き

$$\hat{\beta}_1 = \frac{s_{xy}}{s_x^2} = \frac{x \text{ と } y \text{ の共分散}}{x \text{ の分散}}$$

$$= r_{xy} \frac{s_y}{s_x} = x \text{ と } y \text{ の相関係数} \times \frac{y \text{ の標準偏差}}{x \text{ の標準偏差}}$$

② 切片


$$\hat{\beta}_0 = \bar{y} - \hat{\beta}_1 \bar{x}$$

③ 誤差


$$\hat{\sigma}^2 = \frac{1}{n-2} \times \sum_{i=1}^n e_i^2$$

$$= \frac{1}{n-2} \times \sum_{i=1}^n [y_i - (\hat{\beta}_0 + \hat{\beta}_1 x_i)]^2$$

① 母集団の直線と標本の直線



③ 統計量




$$y_i = \hat{\beta}_0 + \hat{\beta}_1 x_i + e_i$$

赤: 人間には見えない値
 緑: 人間が計算して提案推測する値

限られたデータは見えない人間が、
 どうやって赤い直線の候補となり、
 緑色の直線 ($\hat{\beta}_0, \hat{\beta}_1$ の値) を提案するの?

① 最小二乗法の基本的なアイデア


(K-21) 悪い例 (K-22) 良い例



「良い悪い」を判別基準として、
 「損失」として、各点から直線までの
 「距離」を考へる。
 e 平方ユークリッド距離 (= 垂直距離)

よって、「距離」が一番短い直線を選ぼう! と考へるのだから、
 「最小二乗法」なので。
 e 二乗基準で測った距離を最小化する手法。

① 平均と回帰直線の関係



どちらも点線の長さで二乗基準で最小化

① 回帰係数 $\hat{\beta}_1$

$$\hat{\beta}_1 = r_{xy} \times \frac{S_y}{S_x}$$

(i) 相関(高) $\rightarrow \hat{\beta}_1$ (高)

$$\hat{\beta}_1 = r_{xy} \times \frac{S_y}{S_x}$$





(ii) $S_y > S_x \rightarrow \hat{\beta}_1$ (高)

yの分散がxの分散より大きければ、傾きは大きくなる。






$$\hat{\beta}_1 = r_{xy} \times \frac{S_y}{S_x}$$

(3) 回帰係数と相関係数の関係

① 相関係数 $r_{xy} = 1$



② 相関係数 $r_{xy} = .7$



📖 ノート3 統計量：点推定と推定量の性質

(1) 点推定

① 点推定

母集団に想定した統計モデルのパラメータの値がどのような値なのか点 (統計量一つ) で推定する統計的推測。

② 推定量 Estimator

これは、点推定に採用される統計量のこと。

③ 推定量の作り方

これには、様々な方法が考案されている。

(例1) モーメント法

★ (例2) 最小二乗法

(例3) 最尤推定法

(2) 推定量の選択基準I: 小標本特性

これは、標本を何度も何度も繰り返しとった場合に生じるメリットのこと (サンプルサイズは小さくてもよい)。

「ヒストグラムを精密なものとした時」

① 不偏性 unbiasedness

これは、その推定量の期待値が母パラメータに一致すること。不偏性を持つ推定量を不偏推定量という。

① (注) $\bar{x} \rightarrow \mu$ の不偏推定量

$\hat{\beta}_0 \rightarrow \beta_0$ "

$\hat{\beta}_1 \rightarrow \beta_1$ "

② 有効性 Efficient estimator

これは、不偏性を持つ推定量の中で分散が最小のもののこと。有効性を持つ推定量を有効推定量という。


問) なぜ最小二乗法が求め

$\hat{\beta}_0$ と $\hat{\beta}_1$ の値を、母集団の推定値として信じていいの?

① 標本 ② 母集団




③ 統計量 ④ 標本分布




答) 最小二乗推定量には、「不偏性」を中心とする望ましい性質があるから。

⑤ 点推定の2つのステップ

(1) 標本から多数統計量を作る




(2) バストなものを採択




⑥ 不偏推定量

① 標本 ② 母集団



⑦ 有効性



① 分散の種類

(1) (標本)分散

母集団の分散 σ^2

不偏性 P!! たい!

標本抽出

分散 O

計算が面倒!

σ²おとす 小標本の分散

$$S^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$$

(3) 推定量の選択基準 II: 大標本特性

これは、サンプルサイズ n の大きい標本を採ったときに生まれるメリットのこと。

① 漸近的な不偏性 asymptotic unbiasedness
これは、サンプルサイズが大きいとき、その推定量の期待値が母パラメータに一致すること。

② 標本分散は、「漸近的な不偏性」はもつが、「不偏性」はもたない!

② 一致性
これは、サンプルサイズが大きいとき、推定量と母パラメータに差が生じる確率は極めて小さくなること。

(2) 不偏分散

母集団の分散 σ^2

不偏 O!!

計算が面倒!

分散 O!!

$$S'^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2$$

③ 漸近的有効性 asymptotic efficiency
これは、サンプルサイズが大きいときに、不偏推定量の中で最小分散となること。

(4) 分散と不偏分散

① 分散
これは、漸近的な不偏性を持つが不偏性は持たない。

$$S^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 = \hat{\sigma}_1^2$$

② 注 ばらつきを生じさせているのは、1つ目の data point だけだから、2つ目のデータ (= (b)) だと区別する。

② バイアス Bias

② 不偏分散 Unbiased variance
これは、不偏性を持ち、当然漸近的な不偏性も持つ。

$E[\hat{\sigma}^2]$: $\hat{\sigma}^2$ の期待値 (重心).

$$S'^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2 = \hat{\sigma}_2^2$$

① $E[\hat{\sigma}_1^2] - \sigma^2 \neq 0 \leftarrow$ バイアス有!

② $E[\hat{\sigma}_2^2] - \sigma^2 = 0 \leftarrow$ バイアスなし!

④ 回帰分析

(問1) HOW MUCH?
 $\beta_0, \hat{\beta}_1$ はどのくらい?
 → 最小乗法 (1-12)
 → 理由: 不偏性 (1-13)

(問2) WHETHER?
 $\hat{\beta}_1$ は 0 に等しいと
 見なして良いのか?
 (1-14)

④ 仮説検定のまとめ

📖 ノート4 分析の評価1: 係数の推定値の正確さの評価

👉 分析を評価する三つの軸


- (評価軸1) 係数の推定値の正確さを評価
- (評価軸2) 作った統計モデルの正確さを評価
- (評価軸3) 想定した統計モデルの適切さを評価

(1) 回帰係数の検定

① 帰無仮説と対立仮説

$H_0: \beta_1 = 0$

$H_1: \beta_1 \neq 0$




② 検定統計量 t

👉 t 値 (回帰係数の検定における検定統計量)

$$t = \frac{\hat{\beta}_1 \text{ 「}\beta_1\text{の推定値」}}{\hat{\sigma}_{\hat{\beta}_1} \text{ 「}\beta_1\text{の推定値」の標準誤差の推定値}}$$

$$\hat{\sigma}_{\hat{\beta}_1} = \sqrt{\frac{1}{n-2} \times \frac{SS_e}{SS_x}}$$

	点推定値	標準誤差	t value	Pr(> t)	
$\hat{\beta}_0$	-0.49	0.08	= -6.30	1.13e-06	***
$\hat{\beta}_1$	1.02	0.15	= 6.66	4.63e-07	***



β_1 の t 値から標準誤差
 の標準誤差が、


$\sigma_{\hat{\beta}_1}$
 対して、これを人間が
 推定したものを、
 $\hat{\sigma}_{\hat{\beta}_1}$ と表す。

(2) 回帰係数の信頼区間

$$[\hat{\beta}_1 - t_c \times \hat{\sigma}_{\hat{\beta}_1}, \hat{\beta}_1 + t_c \times \hat{\sigma}_{\hat{\beta}_1}]$$

	点推定値	下限	上限
$\hat{\beta}_0$	-0.49	-0.65	-0.33
$\hat{\beta}_1$	1.02	0.70	1.33

④ 信頼区間の統計量



100回に95回は
 β_0 という真の値を含む
 区間を作った!

② 三つのタイプの区間

① β たちの信頼区間


$$y_i = \hat{\beta}_0 + \hat{\beta}_1 x_i + e_i$$

-0.65 ~ -0.33 0.70 ~ 1.33

② \hat{y} の信頼区間


$$y_i = \hat{\beta}_0 + \hat{\beta}_1 x_i + e_i$$

$e_i \hat{y}_i$



③ y の予測区間

$$y_i = \hat{\beta}_0 + \hat{\beta}_1 x_i + e_i$$



(3) 予測値の95%信頼区間 図の破線の区間

標本を繰り返し抽出した時、点 x_p に対してこの範囲を設けておけば100回に95回、 μ_p を含むだろう、という区間。

$$\left[\hat{y}_p - t_c \times \hat{\sigma}_{\hat{y}_p}, \hat{y}_p + t_c \times \hat{\sigma}_{\hat{y}_p} \right]$$

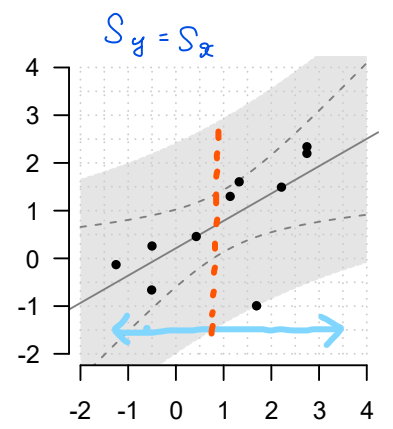


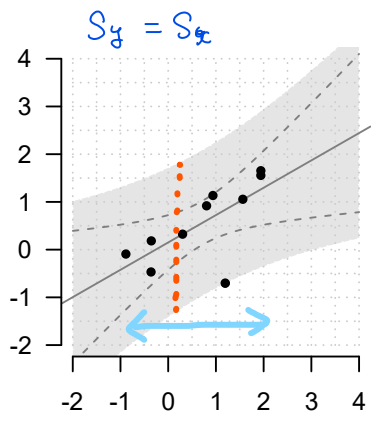
$$\hat{\sigma}_{\hat{y}_p} = \sqrt{\frac{SS_e}{n-2} \times \left[\frac{1}{n} + \frac{(x_p - \bar{x})^2}{SS_x} \right]}$$

(4) データの予測区間 図の灰色の区間

標本を繰り返し抽出した時、点 x_p に対してこの範囲を設けておけば100回に95回、 μ_p を含むだろう、という区間。

$$\left[y_p - t_c \times \hat{\sigma}_{y_p}, y_p + t_c \times \hat{\sigma}_{y_p} \right]$$

$$\hat{\sigma}_{y_p} = \sqrt{\frac{SS_e}{n-2} \times \left[1 + \frac{1}{n} + \frac{(x_p - \bar{x})^2}{SS_x} \right]}$$



③注 右のデータは、
「1-2」の $r_{xy} = 0.7$
このデータについて、
予測区間と
信頼区間を求めた。

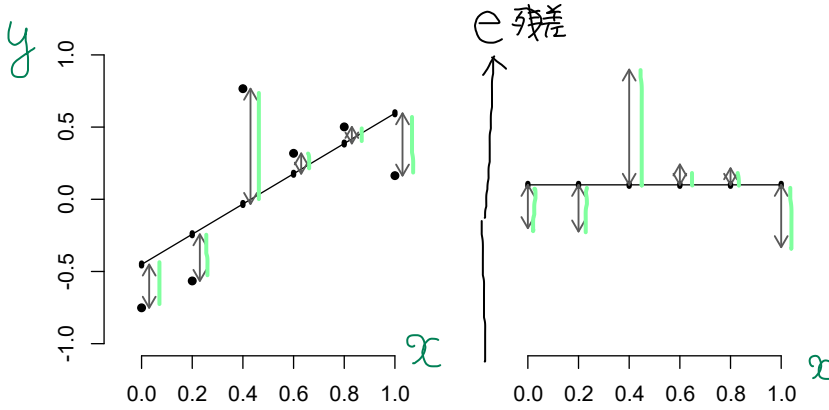
より安定した推論を行いたいのなら、
 x に関しては幅広く取り!

作りあげた直線がどのくらい
データにフィットしているのか考える。

ノート5 分析の評価2: 作った統計モデルの正確さを評価

(1) 残差プロット

これは、 x_i の値と残差 e_i の関係をプロットした散布図。



(2) 残差の性質

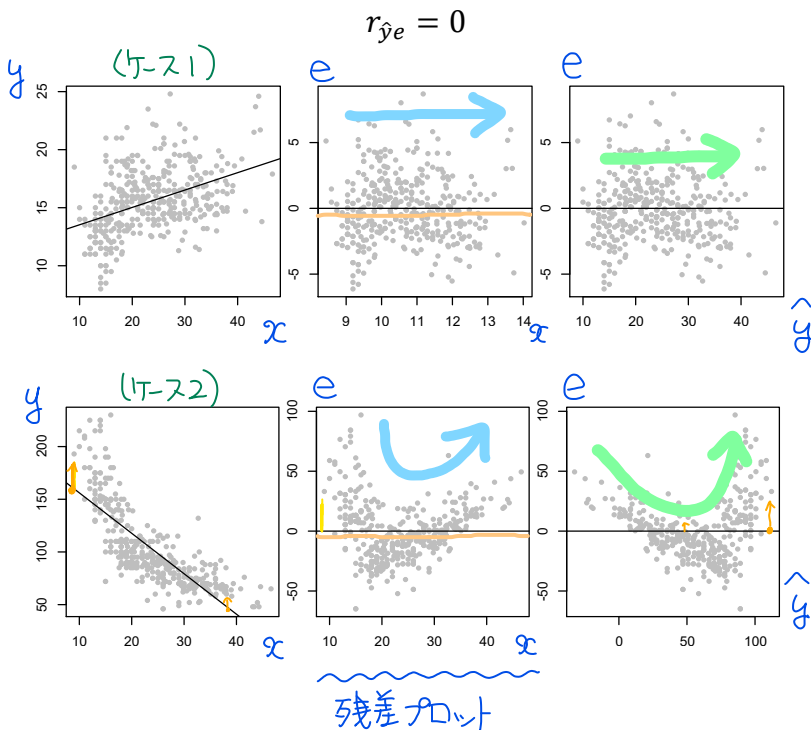
① 独立変数と残差の相関

独立変数 x と残差 e の相関 r_{xe} は、必ずゼロになる。

$r_{xe} = 0$ ← 右肩上がりでも！
右肩下がりでもひい！

② 予測値と残差の相関


予測値 \hat{y} と残差 e の相関 $r_{\hat{y}e}$ は、必ずゼロになる。



(3) 変数の直交分解



② yの分散の分解

① yの分散




これは、回帰直線と
引こうが引くまいが"
データをとら決まり量

② \hat{y} の分散



③ eの分散



④ 決定係数と相関係数

$r_{y\hat{y}}$: yと \hat{y} の相関係数

$$(r_{y\hat{y}})^2 = R^2$$

① 分散の分解 (一般的な場合)

$$s_{a+b}^2 = s_a^2 + 2s_{ab} + s_b^2$$

$(a+b)^2 = a^2 + 2ab + b^2$ のような関係がある!

② 分散の分解 (aとbが無相関の時)

$$s_{a+b}^2 = s_a^2 + 0 + s_b^2$$

なかな子!

③ 従属変数yの分散の分解

無相関!

$$y = \hat{y} + e$$

$s_y^2 = s_{\hat{y}}^2 + s_e^2$
 yの分散 = 予測値の分散 + 残差の分散

(4) **決定係数** Coefficient of determination

これは独立変数がどれだけ従属変数の値を決定するかを示す指標。別名：分散説明率 Proportion of variance accounted for

= 直線(研究者が推定したモデル)が、どのくらいデータにフィットするかの R^2 を表す指標

考えろ

$$s_y^2 = s_{\hat{y}}^2 + s_e^2$$

↓ 両辺を s_y^2 で割る.

$$1 = \frac{s_{\hat{y}}^2}{s_y^2} + \frac{s_e^2}{s_y^2}$$

↓ 移項する.

$$\frac{s_{\hat{y}}^2}{s_y^2} = 1 - \frac{s_e^2}{s_y^2} = (\text{決定係数}).$$

$$\text{決定係数 } R^2 = 1 - \frac{s_e^2}{s_y^2}$$

この値が大きいほど、作成した直線は、データにフィットしていると言える。

$$0 \leq R^2 \leq 1$$

① 回帰分析の仮定


ノート6 分析の評価3: 想定した統計モデルの適切さの評価 (回帰診断法)

(1) 標本抽出

- ① 独立
- ② 同一分布
- ③ 無作為

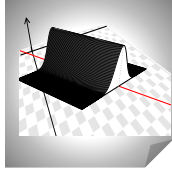
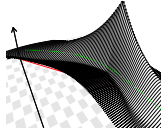
(2) 母集団

- ① 正規分布
- ② 分散が均一



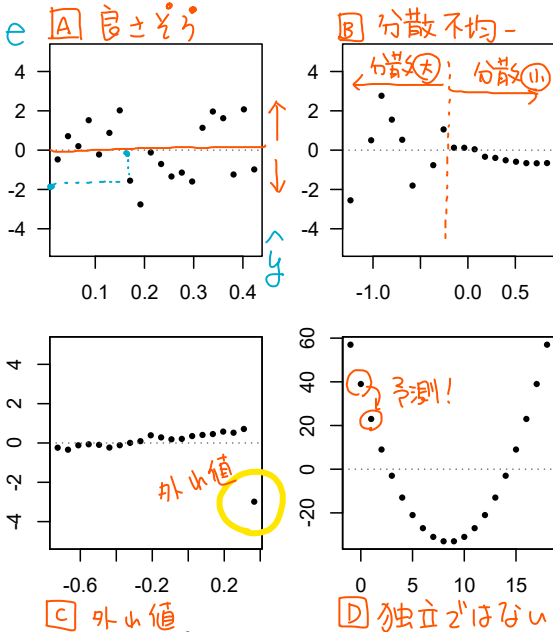
母集団に対する仮定の検証

ノート1の(2)の仮定たちが間違っている可能性はないの? 例えば、母集団に直線+正規分布の関係を想定してきたけど、その仮定って正しかったの?


(1) 残差プロット Residual plot

横軸に予測値 \hat{y}_i 、縦軸に残差 $e_i = y_i - \hat{y}_i$ を取った散布図。



(2) 正規Q-Qプロット Normal quantile-quantile plot

横軸に標準正規分布の分位点を、縦軸に残差を標準化し小さい順に並べたものの分位点を取った散布図。



直線状

⇒ 正規性に
疑念はなげ

標準正規分布の
分位点 = 理想的な

逸脱が有り

⇒ 正規性の仮定に
疑念が生



① 分位点

(参考) Lec2 順序統計量

① 離散的なとき




② 連続的なとき



② QQプロットの発想

① 標準化: 標偏何個分?



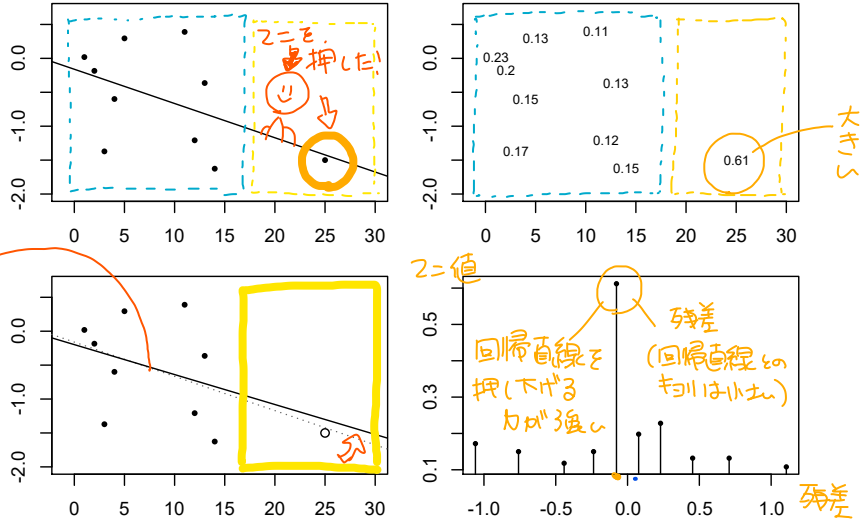
② 標準正規分布と1-1対比較

④ 2=値の直観的意味

x軸方向において、
外れ値は、2=値の点
(=過疎地にいる点)は、
「2=」を「押しあげろ/
押し下げろ」のように
回帰直線に強い影響
を与える。

(3) てこ値 leverage

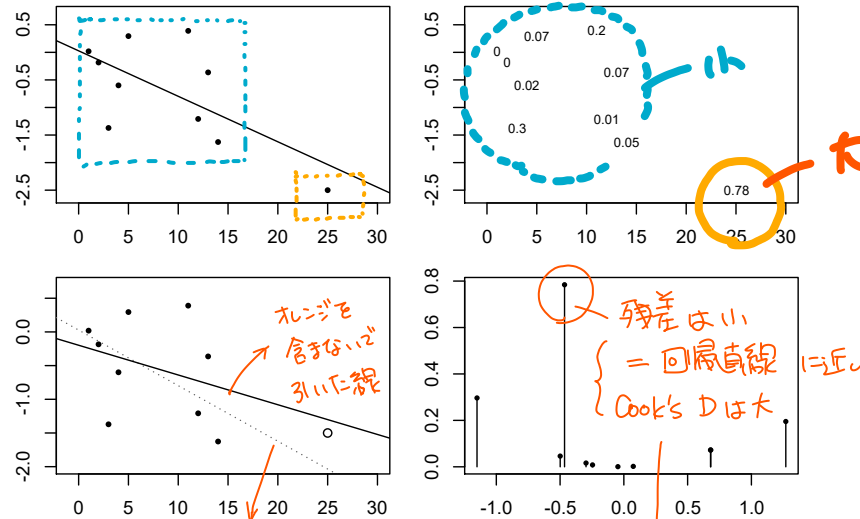
i 番目の観測値の回帰係数への影響度を表した指標。この
値が大きいものは外れ値の候補となる。



$$h_i = \frac{1}{n} + \frac{(x_i - \bar{x})^2}{\sum_{i'=1}^n (x_{i'} - \bar{x})^2}$$

(4) クックの距離 Cook's distance

i 番目の観測値を除いて推定した場合に得られる回帰係数の
値と、全観測値に基づく回帰係数のずれを表す指標。



オレンジを含めず引いた線

$$D_i = \frac{1}{p} r_i^2 \frac{h_i}{1 - h_i}$$

$D_i > 0.5$: i 番目の観測値は「影響力が大きめ」
 $D_i > 1.0$: i 番目の観測値は「特異に大きな影響力」

資料

資料4-1 最小二乗法による点推定

$$L(\hat{\beta}_0, \hat{\beta}_1) = \sum_{i=1}^n [y_i - (\hat{\beta}_0 + \hat{\beta}_1 x_i)]^2$$

① $\hat{\beta}_0$ に関して偏微分を行う

$$\begin{aligned} \frac{\partial}{\partial \hat{\beta}_0} L(\hat{\beta}_0, \hat{\beta}_1) &= \frac{\partial}{\partial \hat{\beta}_0} \sum_{i=1}^n [y_i - (\hat{\beta}_0 + \hat{\beta}_1 x_i)]^2 \\ &= \sum_{i=1}^n \frac{\partial}{\partial \hat{\beta}_0} [y_i - \hat{\beta}_0 - \hat{\beta}_1 x_i]^2 \\ &= \sum_{i=1}^n \frac{\partial}{\partial \hat{\beta}_0} [y_i^2 - y_i \hat{\beta}_0 - y_i \hat{\beta}_1 x_i - \hat{\beta}_0 y_i + \hat{\beta}_0^2 + \hat{\beta}_0 \hat{\beta}_1 x_i \\ &\quad - \hat{\beta}_1 x_i y_i + \hat{\beta}_1 x_i \hat{\beta}_0 + \hat{\beta}_1^2 x_i^2] \\ &= \sum_{i=1}^n \frac{\partial}{\partial \hat{\beta}_0} [(y_i^2 - 2\hat{\beta}_1 x_i y_i + \hat{\beta}_1^2 x_i^2) + 2\hat{\beta}_0(-y_i + \hat{\beta}_1 x_i) + \hat{\beta}_0^2] \\ &= \sum_{i=1}^n \left\{ 0 + \frac{\partial}{\partial \hat{\beta}_0} [2\hat{\beta}_0(-y_i + \hat{\beta}_1 x_i)] + \frac{\partial}{\partial \hat{\beta}_0} \hat{\beta}_0^2 \right\} \\ &= \sum_{i=1}^n \{2(-y_i + \hat{\beta}_1 x_i) + 2\hat{\beta}_0\} \\ &= \sum_{i=1}^n \{2(-y_i + \hat{\beta}_1 x_i)\} + 2n\hat{\beta}_0 \end{aligned}$$

したがって、 $\frac{\partial}{\partial \hat{\beta}_0} L(\hat{\beta}_0, \hat{\beta}_1) = 0$ となるのは、 $\sum_{i=1}^n \{2(-y_i + \hat{\beta}_1 x_i)\} + 2n\hat{\beta}_0 = 0$ のとき。

$$\begin{aligned} \hat{\beta}_0 &= \frac{1}{n} \sum_{i=1}^n (y_i - \hat{\beta}_1 x_i) \\ &= \frac{1}{n} \sum_{i=1}^n y_i - \hat{\beta}_1 \frac{1}{n} \sum_{i=1}^n x_i \\ &= \bar{y} - \hat{\beta}_1 \bar{x} \end{aligned}$$

② $\hat{\beta}_1$ に関して偏微分を行う

$$\begin{aligned}
 \frac{\partial}{\partial \hat{\beta}_1} L(\hat{\beta}_0, \hat{\beta}_1) &= \frac{\partial}{\partial \hat{\beta}_1} \sum_{i=1}^n [y_i - (\hat{\beta}_0 + \hat{\beta}_1 x_i)]^2 \\
 &= \sum_{i=1}^n \frac{\partial}{\partial \hat{\beta}_1} [(y_i^2 - 2\hat{\beta}_0 y_i + \hat{\beta}_0^2) - 2\hat{\beta}_1(x_i y_i - \hat{\beta}_0 x_i) + \hat{\beta}_1^2 x_i^2] \\
 &= \sum_{i=1}^n \left\{ 0 - \frac{\partial}{\partial \hat{\beta}_1} [2\hat{\beta}_1(x_i y_i - \hat{\beta}_0 x_i)] + \frac{\partial}{\partial \hat{\beta}_1} \hat{\beta}_1^2 x_i^2 \right\} \\
 &= \sum_{i=1}^n \{-2x_i(y_i - \hat{\beta}_0 - \hat{\beta}_1 x_i)\} \\
 &= \sum_{i=1}^n \{-2x_i(y_i - \bar{y} - \hat{\beta}_1 \bar{x} - \hat{\beta}_1 x_i)\} \\
 &= \sum_{i=1}^n \{-2x_i[(y_i - \bar{y}) - \hat{\beta}_1(x_i - \bar{x})]\} \\
 &= -2 \sum_{i=1}^n \{x_i(y_i - \bar{y})\} + 2\hat{\beta}_1 \sum_{i=1}^n \{x_i(x_i - \bar{x})\}
 \end{aligned}$$

したがって、 $\frac{\partial}{\partial \hat{\beta}_1} L(\hat{\beta}_0, \hat{\beta}_1) = 0$ となるのは、 $-2 \sum_{i=1}^n \{x_i(y_i - \bar{y})\} - 2\hat{\beta}_1 \sum_{i=1}^n \{x_i(x_i - \bar{x})\}$ のとき。

$$\begin{aligned}
 \hat{\beta}_1 &= \frac{\sum_{i=1}^n \{x_i(y_i - \bar{y})\}}{\sum_{i=1}^n \{x_i(x_i - \bar{x})\}} \\
 &= \frac{\sum_{i=1}^n x_i y_i - n\bar{x}\bar{y}}{\sum_{i=1}^n x_i^2 - n\bar{x}^2} \\
 &= \frac{\frac{1}{n} \sum_{i=1}^n x_i y_i - \bar{x}\bar{y}}{\frac{1}{n} \sum_{i=1}^n x_i^2 - \bar{x}^2} \\
 &= \frac{s_{xy}}{s_x^2}
 \end{aligned}$$