

データ解析基礎

第10回 回帰分析(その2)

回帰分析の復習

2

- 二つの変数 X と Y の関係を調べる .
- 相関係数 ($r = S_{XY} / S_X S_Y$)
 - X と Y のあいだの1次の関係を表す指標
 - 1と-1のあいだの値をとり , 0のとき無相関 .
- 回帰直線 ($Y = a + b X$)
 - データ Y と X から予測される Y の平均2乗誤差を最小にする直線

$$b = \frac{S_{XY}}{S_X^2} = \frac{N \sum X_i Y_i - (\sum X_i)(\sum Y_i)}{N(\sum X_i^2) - (\sum X_i)^2} \quad a = \bar{Y} - b \bar{X}$$

相関係数が0であるかどうかの検定

3

- 例題

- 数学と化学の成績に相関があるか否かを知りたい。

- 設定する仮説

- 帰無仮説 $H_0 : \rho = 0$

- 対立仮説 $H_1 : \rho \neq 0$

ρ : 真の相関係数

r : データの相関係数

相関係数が0であるかどうかの検定

4

- 帰無仮説の下で標本（つまりデータ）の相関係数 r がどのような分布に従うかがわかれば，いままでと同じように棄却域が設定できる。

- 天下りの的であるが，帰無仮説の下で，次の量が t 分布に従うことが知られている。

$$t = \frac{r}{\sqrt{(1 - r^2) / (N - 2)}} \quad (\text{自由度は } N - 2)$$

- あとは，いままで同じやり方。

例題：

5

- 66人の学生について調査したところ，化学と数学の成績の相関係数は0.60であった．相関の有無を有意水準5%で検定せよ．

- step1：

- 前ページの式に値を代入すると，検定統計量は

$$t = 0.60 / \sqrt{(1 - 0.60^2) / (66 - 2)}$$

$$= 0.60 / \sqrt{0.64 / 64} = 6$$

例題の解答

6

- step 2:

- 有意水準5%の場合，自由度64の t 分布の限界点はおよそ ± 2 ．

- step 3:

- 上で求めた統計量は棄却域に含まれるので，帰無仮説は棄却される．

- つまり，「相関がある」という結論が得られる．

相関係数がcに等しいかどうかの検定

7

- 帰無仮説が $r = c$ となる検定はどうやればよいか？
- FisherのZ変換と呼ばれる方法がある。
 - 詳細は省略．おおまかなステップは以下の通り．
 1. Z変換の表を使って， r から Zr に変換する．
 2. 同様にして， c を Zc に変換する．
 3. 次の値が標準正規分布に従うことを使って検定，推定を行なう．

$$z = \frac{Zr - Zc}{1 / \sqrt{N - 3}}$$

二つの母集団における相関係数の比較

8

- 関連のない標本の場合：
 - 数学と化学の成績の相関係数は男女の間で違うか？
- 次の量が標準正規分布に従うことを使って検定する．

$$z = (Zr_1 - Zr_2) / \sqrt{\frac{1}{N_1 - 3} + \frac{1}{N_2 - 3}}$$

- Zr_1, Zr_2 は，相関係数 r_1 と r_2 にZ変換を施したもの．
- N_1, N_2 は， r_1 と r_2 を計算するのに用いたデータ数．

相関係数の比較

9

- 関連のある標本の場合
 - 「数学と物理の成績の相関」と「数学と化学の成績の相関」が等しいかどうかを共通の学生に対して調べる。
- 三つの変数 X, Y, Z について「 X と Y の相関係数 ρ_{XY} 」と「 X と Z の相関係数 ρ_{XZ} 」が等しいかどうかは、次の量が自由度 $N - 3$ の t 分布に従うことを使って検定する。

$$t = \frac{(r_{XY} - r_{XZ}) \sqrt{(N - 3)(1 + r_{YZ})}}{\sqrt{2(1 + 2r_{YZ}r_{XY}r_{XZ} - r_{YZ}^2 - r_{XY}^2 - r_{XZ}^2)}}$$

例題：

10

- 「数学と物理」「数学と化学」の成績の相関係数を比較したい。100人の学生について三科目の成績の相関係数を求めたところ、数学と物理は0.5、数学と化学は0.25、物理と化学は0.1であった。
- 以下の仮説について有意水準5%の検定を行なえ。
 - 帰無仮説：二つの相関係数は等しい。
 - 対立仮説：「数学と物理」の方が大きい。
- 略解：
 - 検定統計量は2.18。限界点は約1.66。よって棄却。

2変数の確率分布

11

- 二つの変数の組の確率分布
 - 2次元の空間の上に確率密度関数 $p(x, y)$ を描く .
xyが作る平面上に高さをもったグラフをかく .
したがって , 体積が確率を表すことになる .

2次元正規分布

12

- 2次元正規分布の確率密度関数は次式で与えられる .

$$p(\mathbf{x}) = \frac{1}{2\pi |D|^{1/2}} \exp\left(-\frac{1}{2} (\mathbf{x} - \boldsymbol{\mu})^T D^{-1} (\mathbf{x} - \boldsymbol{\mu})\right)$$

- 2次元正規分布の性質
 - X, Y の分布 (周辺分布) はそれぞれ正規分布 .
 - X を固定したときの Y の条件付き分布が正規分布 .
 - Y を固定したときの X の条件付き分布が正規分布 .
 - 条件付き分布の分散は X (or Y)の値によらず一定 .
 - Y (or X) の条件付き分布の平均値は直線上に並ぶ .

母集団の線形回帰式

13

- 第2回の講義での回帰分析はデータに基づいていた。

- データに関する回帰直線の方程式 $Y = a + bX$ は

$$\hat{Y} = b(X - \bar{X}) + \bar{Y}$$

と書き直せる。

$$\text{ただし, } b = \frac{S_{XY}}{S_X^2}$$

- これを2次元正規分布の立場から見直してみる。

母集団の線形回帰式

14

- 前ページの回帰直線に対応する母集団の回帰直線は,

$$Y = B(X - \mu_X) + \mu_Y$$

となる。

- B は母集団に対する相関係数 \times SD比 $(\rho_{XY} \frac{\sigma_Y}{\sigma_X})$

- μ_X, μ_Y は母集団 X, Y の平均。

母集団の線形回帰

15

- 前ページの二つの式を比較したとき，
 - \bar{X} と \bar{Y} は，それぞれ μ_X , μ_Y の不偏推定量，
 - b は， B の不偏推定量，という関係にある．
- したがって，データから求めた回帰式は「母集団の回帰式の不偏推定量」である，といえる．

回帰直線の傾きが0であるかどうかの検定₁₆

- B が0であれば， Y の予測値は X によらず μ_Y になる．
 - それは X と Y が無相関であることを示す．
 - 実際， $B = \rho_{XY} \sigma_Y / \sigma_X$ より， $B=0$ と $\rho_{XY}=0$ は同値．
- したがって， $B=0$ を検定するには $\rho_{XY}=0$ を検定すればよい．
 - 相関係数が0であるかどうかの検定は既出．

予測誤差の不偏推定量

17

- データに関する平均2乗予測誤差の定義（復習）

$$D = \text{sqrt}(\Sigma (Y_i - \hat{Y}_i)^2 / N)$$

（「データと予測値の差の2乗」の平均の平方根）

- では，母集団の予測誤差の不偏推定量はどうか？
 - X given という条件での Y の2乗誤差と解釈できる．
「 X が一定時の Y のばらつき」にほかならない．
 - 平均2乗誤差は「 X が与えられた条件の下での Y の標準偏差」であるといえる．

条件付き分布の標準偏差

18

- (X, Y) が2次元正規分布に従うという仮定の下では， Y の条件付き標準偏差は X の値に依存しない．
- その値を $\sigma_{Y|X}$ とかけば，それは母集団全体に共通する予測誤差として使える．
- 誤差の標準偏差の不偏推定量は
$$\sigma_{Y|X} = \text{sqrt}\left(\frac{1}{N-2} \Sigma (Y_i - \hat{Y}_i)^2\right)$$
で与えられる．
 - この値を使うとデータの信頼区間を求められる．

例題

19

- 2次元正規分布に従っている母集団から，ランダムに15対のデータを取得したところ以下の値が得られた．

#	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
X	2	3	3	5	5	5	6	6	6	7	7	7	7	8	10
Y	3	3	4	7	3	5	7	6	9	5	7	8	10	9	8

1. データの線形回帰式を求めよ．
2. 係数 B が0であるかどうかを有意水準5%で検定せよ
3. $\sigma_{Y|X}$ を推定せよ．
4. $X=6$ に対する Y の予測値を求めよ．
5. 4.で求めた Y の予測値の上下2の範囲に含まれる近似的な確率を求めよ．

例題の解答 1.

20

- X, Y の平均，分散，共分散を求めると，

$$\bar{X} = 5.8, \bar{Y} = 6.27, S_X^2 = 4.03, S_Y^2 = 5.13, S_{XY} = 3.39$$

- したがって，

- 傾き $b = 3.39 / 4.03 = 0.841$ ，

- 切片 $a = 6.27 - 0.841 * 5.8 = 1.39$

となる．

例題の解答 2.

21

- 仮説 $B = 0$ を検定するには、相関係数について

- 帰無仮説： $\rho = 0$

- 対立仮説： $\rho \neq 0$

を検定すればよい。

- 相関係数は、

$$r = S_{XY} / S_X S_Y = 3.39 / \sqrt{4.03 \times 5.13} = 0.745$$

例題の解答 2. (続き)

22

- 帰無仮説の下で、以下の統計量が自由度13 (=15 - 2) の t 分布に従うことから、

$$t = r / \sqrt{(1 - r^2) / (N - 2)}$$

$$= 0.745 / \sqrt{0.445 / 13} = 4.03$$

- 自由度13の t 分布の数表から5%の限界点は2.16 .

- したがって、帰無仮説は棄却される .

- すなわち、傾き B は0ではないと結論される .

例題の解答 3.

23

- データのXのそれぞれに対して回帰式をあてはめてYの予測値を求め、予測誤差を計算すると、以下の表が得られる。

#	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
X	2	3	3	5	5	5	6	6	6	7	7	7	7	8	10
Y	3	3	4	7	3	5	7	6	9	5	7	8	10	9	8
\hat{Y}	3.07	3.91	3.91	5.59	5.59	5.59	6.43	6.43	6.43	7.28	7.28	7.28	7.28	8.12	9.80
Error	-0.07	-0.91	0.09	1.41	-2.59	-0.59	0.57	-0.43	2.57	-2.28	-0.28	0.72	2.72	0.88	-1.80

- これより、予測誤差の不偏推定量は

$$\begin{aligned}\sigma_{Y|X} &= \text{sqrt}(\text{誤差の2乗和}) / (N - 2) \\ &= \text{sqrt}(34.21 / 13) = 1.62\end{aligned}$$

例題の解答 4. および 5.

24

- 上の表より $X = 6$ に対するYの予測値は 6.43。
- 確率を計算するため、もとのデータを標準正規分布の空間に変換する必要がある。
- 先に求めた標準偏差を用いて標準化すると、
$$z = (2 - 0) / 1.62 = 1.23$$
- 1.23より上側の部分の累積確率を標準正規分布を数表から読みとると、0.10935 である。

例題の解答（続き）

25

- したがって，求める確率は

$$P = 1 - 0.10935 \times 2 = 0.7813.$$

- 以上より，
 - $X = 6$ のときには，約78%の確率で Y の値は， 6.43 ± 2 の区間に含まれることになる．
 - ここでの議論は，厳密な信頼区間ではなく，あくまで近似的に計算しているにすぎないことに注意．

重回帰分析

26

- 重回帰分析
 - 説明変数が二つ以上ある場合の回帰分析のこと
 - 複数の変数を X_1, \dots, X_m を使って，別の変数 Y を以下のようにして予測する．
$$Y = b_0 + b_1 X_1 + \dots + b_m X_m$$
- 以下で議論する問題
 - 係数 b_i をどのようにして推定するか？
 - 決定係数はどのようにして求めるか？
 - 予測誤差の分散不偏推定量はどうやって求めるか？

係数の決定方法

27

- 基本的考え方は単純回帰の場合と同じ。
 - データと予測値の2乗誤差を最小化する。
 - + 微係数が0になる点を探す
 - + 幾何学的に考える。
- 幾何学的方法
 - n 個のデータについて, それぞれ回帰式を表すと,
$$Y_1 = b_0 + b_1 X_{11} + \dots + b_m X_{1m} + e_1$$
$$Y_2 = b_0 + b_1 X_{21} + \dots + b_m X_{2m} + e_2$$
$$Y_n = b_0 + b_1 X_{n1} + \dots + b_m X_{nm} + e_n$$

係数の決定方法

28

- これを行列とベクトルを使って書き直すと
$$y = Xb + e$$
となる。ここで, $|e|^2$ を最小化すればよい。
- 射影変換の知識を使うと, $|e|^2$ を最小化する b の値は
$$b = (X^T X)^{-1} X^T y$$
として求められる。

決定係数と誤差の分解

29

- 決定係数 R^2 :

- Y の変動のうち, X_1, \dots, X_m の変動で説明できる部分の割合

$$R^2 = \frac{\sum (\hat{Y}_i - \bar{\hat{Y}})^2}{\sum (Y_i - \bar{Y})^2} = 1 - \frac{\sum (Y_i - \hat{Y}_i)^2}{\sum (Y_i - \bar{Y})^2}$$

- この式からわかるように, Y の変動の平方和は
(説明される変動の平方和) + (誤差の平方和)
という形に分解できる (ピタゴラスの定理).

予測誤差の不偏推定量

30

- 予測誤差の不偏推定量は次のように与えられる .

$$\sigma_{Y|X} = \text{sqrt}\left(\frac{1}{N-p} \sum (\hat{Y}_i - Y_i)^2 \right)$$

p は係数 b_i の数 (説明変数の数 + 1)である .

- 例 : 説明変数が一つの場合は ,
- 定数項 a と傾き b の二つのパラメータがあるので ,

$$\sigma_{Y|X} = \text{sqrt}\left(\frac{1}{N-2} \sum (\hat{Y}_i - Y_i)^2 \right) \quad (\text{復習})$$

例題：

31

• システムの入出力関係の同定

二つの入力を与えると一つの出力を出すシステムを考える。いま、8組の入力を与えたときの出力を調べたところ、次の結果が得られた。入力から出力を推定する回帰式を求めよ。

$$Y = b_0 + b_1 X_1 + b_2 X_2$$

#	1	2	3	4	5	6	7	8
X1	2	4	6	3	5	1	4	5
X2	1	5	3	2	4	2	3	1
Y	1.54	-6.68	3.14	0.08	-2.01	-4.33	-1.28	7.04

例題の解答

32

• ベクトルと行列の設定

$$y = \begin{bmatrix} 1.54 \\ -6.68 \\ 3.14 \\ 0.08 \\ -2.01 \\ -4.33 \\ -1.28 \\ 7.04 \end{bmatrix} \quad X = \begin{bmatrix} 1 & 2 & 1 \\ 1 & 4 & 5 \\ 1 & 6 & 3 \\ 1 & 3 & 2 \\ 1 & 5 & 4 \\ 1 & 1 & 2 \\ 1 & 4 & 3 \\ 1 & 5 & 1 \end{bmatrix}$$

例題の解答

33

• 行列の計算

$$X^T X = \begin{bmatrix} 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 \\ 2 & 4 & 6 & 3 & 5 & 1 & 4 & 5 \\ 1 & 5 & 3 & 2 & 4 & 2 & 3 & 1 \end{bmatrix} \begin{bmatrix} 1 & 2 & 1 \\ 1 & 4 & 5 \\ 1 & 6 & 3 \\ 1 & 3 & 2 \\ 1 & 5 & 4 \\ 1 & 1 & 2 \\ 1 & 4 & 3 \\ 1 & 5 & 1 \end{bmatrix}$$
$$= \begin{bmatrix} 8 & 30 & 21 \\ 30 & 132 & 85 \\ 21 & 85 & 69 \end{bmatrix}$$

例題の解答

34

• 行列の計算

$$(X^T X)^{-1} = \begin{bmatrix} 8 & 30 & 21 \\ 30 & 132 & 85 \\ 21 & 85 & 69 \end{bmatrix}^{-1} = \begin{bmatrix} 1.0167 & -0.1539 & -0.1199 \\ -0.1539 & 0.0599 & -0.0270 \\ -0.1199 & -0.0270 & 0.0842 \end{bmatrix}$$
$$X^T \mathbf{y} = \begin{bmatrix} 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 \\ 2 & 4 & 6 & 3 & 5 & 1 & 4 & 5 \\ 1 & 5 & 3 & 2 & 4 & 2 & 3 & 1 \end{bmatrix} \begin{bmatrix} 1.54 \\ -6.68 \\ 3.14 \\ 0.08 \\ -2.01 \\ -4.33 \\ -1.28 \\ 7.04 \end{bmatrix} = \begin{bmatrix} -2.50 \\ 11.14 \\ -35.78 \end{bmatrix}$$

例題の解答

35

- 以上より，求めるべき係数ベクトルは

$$\begin{aligned} \mathbf{b} &= (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{y} = \begin{bmatrix} 1.0167 & -0.1539 & -0.1199 \\ -0.1539 & 0.0599 & -0.0270 \\ -0.1199 & -0.0270 & 0.0842 \end{bmatrix} \begin{bmatrix} -2.50 \\ 11.14 \\ -35.78 \end{bmatrix} \\ &= \begin{bmatrix} 0.0328 \\ 2.0184 \\ -3.0149 \end{bmatrix} \end{aligned}$$

つまり， $b_0 = 0.0328$ ， $b_1 = 2.0184$ ， $b_2 = -3.0149$
という結果が得られた．

誤差の評価

36

- データと誤差を比較してみると，

#	1	2	3	4	5	6	7	8
Y	1.54	-6.68	3.14	0.08	-2.01	-4.33	-1.28	7.04
\hat{Y}	1.05	-6.97	3.1	0.06	-1.93	-3.98	-0.94	7.11
Error	0.49	0.29	0.04	0.02	-0.08	-0.35	-0.34	-0.07

- これより，平均 2 乗誤差は $D = 0.267$

- データ Y の分散は 16.258 であるから，決定係数は，
 $R^2 = 1 - 0.267^2 / 16.258 = 0.996$
- 予測データの分散 16.187 を使っても同じ結果になる．
 $R^2 = 16.187 / 16.258 = 0.996$

重回帰分析の難しさ

37

- 現実の問題では教科書どおりにうまく処理ができないことが多い。
- しばしば生じる問題として以下のものが挙げられる。
 - 理論との乖離
 1. 誤差が無相関でない。
 2. 誤差の分散が一定でない。
 - 手続き上の問題
 1. 異常値をどのようにして取り除くか？
 2. 説明変数をどのようにして選ぶか？

説明変数の選び方

38

- 説明変数の組み合わせ
 - 説明変数の候補が10個あれば，説明変数の選び方は全部で1023通りある。
 - これらすべてを比較するのは非効率である。
- 先験的な情報による絞り込み
 - 確実に関係している変数を選び，選択肢を減らす。
 - 例えば，上の場合で，変数3個を事前に固定すれば，選び方は127通りに減る。

説明変数の選び方

39

- 変数の順序付けの利用
 - 変数に順序がついている場合は，少ない数から初めて順次増やし，一定の条件で増加を停止させる．
- 「説明力」による変数の追加
 - 説明力が大きな変数を順次追加していく．
 - 説明力の小さな変数を減らしていく方法もある．

説明変数の選び方

40

- 予備検定の利用
 - 係数 $B_i = 0$ という帰無仮説を検定し，それが棄却されれば説明変数として採用する．
- 基準量に基づくモデルの選択
 - 一定の評価関数を設け，その値を最大化（最小化）するモデルを選ぶ．

基準量の基づく説明変数の選択

41

- 基準量として決定係数を用いる場合
 - これはうまくいかない。
説明変数を増やせば、決定係数は必ず増加する。
- 自由度を修正した決定係数の利用
 - 自由度が増えた分、決定係数の増加分を割り引く。
- 情報量基準の利用
 - AIC, MDL などの情報量基準を用いる。

情報量基準に基づくモデル選択

42

- 赤池情報量(AIC: Akaike's Information Criterion)
 - 説明される変数 Y の真の確率分布とモデルの確率分布との距離(KL-divergence)の漸近的な不偏推定量
$$AIC = -2 \log L(Y | \hat{\theta}) + 2p$$
 - L : 尤度関数
 - $\hat{\theta}$: 最尤推定量
 - p : パラメータ数
- AICが最小になるモデルを選択すれば、真の確率分布に最も近いモデルを選ぶことができる。

回帰分析におけるAIC基準

43

- 回帰分析の場合

- 回帰分析の仮定を用いると，最終的に

$$AIC' = n \log (D^2) + 2 m$$

を評価関数として用いればよいことになる．

n : データ数

m : パラメータ数

D^2 : 平均2乗誤差

変数選択に関わるその他の問題

44

- 変数の多重共線性

- 説明変数が相互に関係している場合
(極端な例として， $X_2 = 2 X_1$ の場合)
- 行列式の値が0に近づき，推定が不安定になる．
一方の変数を除去する．

- 非線形関係の取り扱い

- X と Y の間の関係が線形でない場合
変数変換を行ない線形性を向上させる．