

2025年度春学期

統計学

第7回

データの関係を知る(2)

— 回帰と決定係数



関西大学総合情報学部
浅野 晃

回帰分析とは🤔

回帰分析とは

多変量データがあるとき
ある変量の変化を他の変量の変化で
[説明]する方法

説明? 🤔

回帰分析とは

緯度と気温のデータを例にとると

相関分析

「緯度が上がると、気温が下がる」という
傾向があることを見いだす

緯度と気温について、「どちらからどちらへ」という方向は考えない

回帰分析

「緯度から気温が計算で求められる」と考える
緯度が1度上がると、気温が○℃下がる

回帰分析とは

緯度が上がるから気温が下がると考える
緯度が1度上がると、気温が $\bigcirc^{\circ}\text{C}$ 下がる

各都市の気温は、緯度から計算で求められるという[モデル]を考える


※前回の「(学年を無視すれば)成績が体格から推測できる」というのも、
「成績が体格から計算で求められるというモデル」としてはあり。
(学年を無視することが妥当かどうかは別)

統計学では、気温の分散は、緯度によって[説明]されるという
そして、そのモデルでどの程度説明がつくかを考える

※「モデルを考える」のは、科学の考え方そのものといえます。

説明変数・被説明変数

気温は緯度によって説明される(というモデル)




線形単回帰 🤔

線形単回帰

気温の分散は緯度によって
説明される


どう説明される? どういうモデルか?



散布図上で直線の関係がある、
というモデルを考える

線形単回帰

散布図上で直線の関係がある



$$y = a + bx ?$$

直線の式は $y = ax + b$ と習ったような 🤔

どちらも正解です

$y = ax + b$ 降幕(こうべき)順

$y = a + bx$ 昇幕(しょうべき)順

$$y = a + bx ?$$

降幕(こうべき)順は $y = ax + b$ ただちに1次関数とわかる

何次関数かすぐわかる $y = ax^2 + bx + c$ これは2次関数


昇幕(しょうべき)順は
説明変数を付け加えていくことができる $y = ax + b_2x_2 + b_3x_3 + \dots$
気温 緯度 標高 海からの距離 ...

説明変数が2つ以上ある場合を[重回帰]という

統計学では、昇幕順を使うことが多い


線形単回帰

$$y = a + bx \text{ という式で表される関係}$$




パラメータの決定

$x = x_i$ のとき モデルによれば $y = a + bx_i$ 実際は y_i



パラメータの決定

すべての x_i について、^{の2乗} 差の合計が最小になるように a, b を決める



L が最小になる a, b を求める

- 偏微分による方法(付録1)
- 「2次関数の最大・最小」による方法(付録2)

付録に収録してある数式の展開は、試験の範囲には含みません。


今から、「偏微分による方法」の考え方
(数式そのものではなくて考え方)を説明します。

「偏微分」による方法

$$L = \sum_{i=1}^n \{y_i - (a + bx_i)\}^2$$

a, b の2次関数

が最小になる a, b を求める




a だけの関数と考えて微分

b だけの関数と考えて微分

微分? 🤔

微分？



a だけの関数と考えると微分

微分は、傾きを求める計算

底では微分=0

b についても同じ、底では微分=0

底で L が最小だから、
これらから a, b を求める

計算はともかく結論は

- 偏微分による方法(付録1)
- 「2次関数の最大・最小」による方法(付録2)

$$b = \frac{\sigma_{xy}}{\sigma_x^2}$$

σ_{xy} ← x, y の共分散
 σ_x^2 ← x の分散

$$a = \bar{y} - b\bar{x}$$

$\bar{y}$ ← y の平均
 $\bar{x}$ ← x の平均

最小二乗法

$$b = \frac{\sigma_{xy}}{\sigma_x^2}$$

$$a = \bar{y} - b\bar{x}$$

$$L = \sum_{i=1}^n \{y_i - (a + bx_i)\}^2$$

を最小にしたので【最小二乗法】

$$y = a + \textcircled{bx}$$

【回帰方程式】あるいは【回帰直線】


← 【回帰係数】

ところで

$$y = a + bx$$

$$a = \bar{y} - b\bar{x}$$

から $y - \bar{y} = b(x - \bar{x})$




線形単回帰の結果を使う💡

緯度と気温(前回の講義)の例で

散布図上に回帰直線をひく

緯度を x , 気温を y として回帰直線 $y = a + bx$ を求めると

$$\rightarrow b = -0.850, a = 44.60$$



散布図上に回帰直線をひく

緯度を x , 気温を y として回帰直線 $y = a + bx$ を求めると

$$\rightarrow b = -0.850, a = 44.60$$

回帰直線は $y = 23.35$ を通る


横軸の位置($y = 5$)のとき x の値は

$$y = a + bx \text{ より } x = \frac{y - a}{b}$$

$y = 5$ を代入すると

$$x = (5 - 44.60) / (-0.850) = 46.59$$

計算結果と図が合っていることを
たしかめましょう



求めた回帰直線を使って

緯度35.0度の都市の気温は何°Cかを推定する


緯度を x , 気温を y として回帰直線 $y = a + bx$ を求めると

$$\rightarrow b = -0.850, a = 44.60$$

$y = a + bx$ に $x = 35.0$ を代入すると

$$44.60 + (-0.850) \times 35.0 = 14.85 \text{ (°C)}$$

計算結果と図が合っている
ことをたしかめましょう




求めた回帰直線を使って

表の中にある大阪市(緯度34.68度)の気温を推定

$y = a + bx$ に $x = 34.68$ を代入

$44.60 + (-0.850) \times 34.68 = 15.12$ (°C)




決定係数と「説明」🤔

残差

a, b が求められて、回帰直線が確定したとき

x_i に対する、回帰直線による y の推定値 $\hat{y}_i = a + bx_i$



残差と決定係数

残差は、回帰方程式を使って y_i を推定したときの、
推定によって表現できなかった部分

残差について、次の関係がなりたつ(付録3)

$$\sum d_i^2 = (1 - r_{xy}^2) \sum (y_i - \bar{y})^2$$

残差 相関 相関係数の2乗
 係数 [決定係数]



決定係数の意味

$$\sum d_i^2 = (1 - r_{xy}^2) \sum (y_i - \bar{y})^2 \text{ より}$$


$$1 - r_{xy}^2 = \frac{\sum d_i^2 / n}{\sum (y_i - \bar{y})^2 / n}$$

決定係数
残差の2乗の平均
y の偏差の2乗の平均 = y の分散

決定係数の意味

$$1 - r_{xy}^2 = \frac{\sum d_i^2 / n}{\sum (y_i - \bar{y})^2 / n}$$

決定係数
残差の2乗の平均
y の偏差の2乗の平均 (y の分散)



決定係数の意味と「説明」

$$1 - r_{xy}^2 = \frac{\sum d_i^2 / n}{\sum (y_i - \bar{y})^2 / n}$$


決定係数
回帰直線からのばらつき
y のもとのばらつき

決定係数 = 回帰直線によるばらつきの縮小の度合い
 = 回帰直線によって、ばらつきの何%が「説明」できたか

決定係数の意味と「説明」

相関係数 = 0, すなわち 決定係数 = 0 のとき

回帰直線に対する y のばらつき




回帰直線に対する y のばらつきは

もとの y の分散と まったく変わらない

「回帰直線のまわりに散らばっている」と説明したところで、
 全く説明になっていない

決定係数の意味と「説明」

相関係数 = 0.7 すなわち 決定係数 $\doteq$ 0.5 のとき




回帰直線に対する y のばらつきは
もとの y の分散 に比べて半分になっている

「回帰直線のまわりに散らばっている」と
説明したことで、
もとの y の分散の半分を説明した

決定係数の意味と「説明」

相関係数 = 0.9 すなわち 決定係数 $\doteq$ 0.8 のとき




回帰直線に対する y のばらつきは
もとの y の分散 に比べて20%に減っている

「回帰直線のまわりに散らばっている」と
説明したことで、
もとの y の分散の80%を説明した

ところで, 前回の講義で
言いかけていたことですが💬💧

「中くらいの相関」とは



相関係数0.5
決定係数0.25


回帰直線ではもとの y の分散の
25%しか説明できていない

相関係数0.7
決定係数0.49

回帰直線でもとの y の分散の
50%を説明している


こちらのほうが, 中くらいの相関関係
(分散の説明という意味では)

緯度と気温の例で



決定係数0.712

平均付近に密集して
いると不安定




決定係数0.949

平均から離れた個体がある
と安定する

注意すべき例

こういう分布だと



相関係数や回帰直線は
どんなデータであっても計算
「できてしまう」ことに注意

得られた回帰直線は、
それが意味のあるものかどうか、
よく考えましょう。