

データと予測

広島大学 AI・データイノベーション教育研究センター
稲垣知宏

目標

データとデータ間にある関係に基づいた予測について理解する

この授業で紹介すること

- 因果関係と予測
- ばらつきを最小にする直線

キーワード

因果関係、モデル化、最小 2 乗法

こんなことはありませんか？

出生数が過去最低を記録して少子化対策を急がないといけなと言われていたけど、将来のことなんて分かるのでしょうか？



データ間の関係と予測


データサイエンスの目的の一つは、対象としている問題に関する情報をデータから読み取ることです。

関係：あるデータと別のデータに関係があるのかないのか

予測：あるデータの変化が、別のデータをどう変えるのか
といったことを、データに基づいて分析します。


出生数の推移

出生数の推移 (1899-2021)



出生数の推移

出生数の推移 (1899-2021)




因果関係

どうして出生数は変化するのでしょうか？

出生数変化の原因は何なののでしょうか？

原因とそれによって生じる結果との関係を因果関係と呼びます。




因果関係

どうして出生数は変化するのでしょうか？

出生数変化の原因は何なのでしょうか？

原因とそれによって生じる結果との関係を**因果関係**と呼びます。



社会現象では、原因は一つとは限らず、さまざまな原因が絡み合うことで複合的にある結果を引き起こすことが一般的です。

例題


出生数に影響しそうな要因（出会いの機会、安定した就職先など）を、思いつく限り挙げてください。

解説


どの様な要因を挙げましたか。以下のいずれかに分類できますか。

- 景気に関する要因
 - ✓物価、雇用、収入など
- 人口に関する要因
 - ✓人口構成、婚姻数、離婚数など
- 政策に関する要因
 - ✓子育て支援、医療費の補助、奨学金など
- その他の要因
 - ✓干支、感染症、災害など

出生数に関わるさまざまな要因



出生数予測の単純なモデル



使えるデータをダウンロード

政府統計のポータルサイト

e-Stat : <https://www.e-stat.go.jp/>
からダウンロードできる、出生数と婚姻数のデータを利用することにします。




政府統計の総合窓口(e-Stat)
(<https://www.e-stat.go.jp/>)

出生数予測の単純なモデル

出生数を予測するのに、何年か前の婚姻数と関係しているのではないかと考えたとします。

何年前とするかは、ここでは、相関係数が大きくなるかどうかで決めることにします。

出生数を婚姻件数（1975-）



出生数予測の単純なモデル

出生数を予測するのに、何年か前の婚姻数と関係しているのではないかと考えたとします。

出生数を婚姻件数（1975-）

2000000

何年前の婚姻数と出生数の関係（相関の強さ）を示す。

- 相関係数が-1に近いとき：2つの尺度の一方を増やすともう一方は減る
- 相関係数が1に近いとき：2つの尺度の一方を増やすともう一方も増える

相関が強いのは？


ここで、10年間の出生数とそれと同じ年、1つ前の年、…、7つ前の年の婚姻数で相関係数を計算してみました。下表からは出生数と3年前の婚姻数の相関係数が大きい様です。

		婚姻数							
		同年	1年前	2年前	3年前	4年前	5年前	6年前	7年前
出生数	2012-2021		0.94068	0.94623	0.96916	0.93642	0.95329	0.95347	0.94797
	2011-2020	0.93626	0.93685	0.95606	0.94677	0.92798	0.947	0.93026	0.92006
	2010-2019	0.92331	0.96308	0.9403	0.94525	0.92313	0.91938	0.89082	0.91062
	2009-2018	0.97257	0.94888	0.95179	0.95696	0.91269	0.88982	0.88187	0.89309
	平均	0.94405	0.94737	0.9486	0.95454	0.92505	0.92737	0.91411	0.91794




散布図で確認

出生数（2012-2021）と婚姻数（2009-2018）




直線で近似

出生数（2012-2021）と婚姻数（2009-2018）




データ点の分布を直線で近似

データ点の分布を近似する直線($y=ax+b$)?




データ点の分布を直線で近似

直線($y=ax+b$)とデータ点のばらつきを求める。




データ点の分布を直線で近似

直線($y=ax+b$)とデータ点のばらつきを求める。




データ点の分布を直線で近似

直線($y=ax+b$)とデータ点のばらつきを求める。



データ点の分布を直線で近似

直線($y=ax+b$)とデータ点のばらつきを求める。



ばらつき

$$\sigma^2 = \frac{1}{n-2} \sum_{i=1}^n (y_i - ax_i - b)^2$$

最小 2 乗法：ばらつきを最小にする

傾き a :

$$a = \frac{(x \text{ と } y \text{ の 共分散})}{(x \text{ の 分散})}$$

切片 b :

$$b = (y \text{ の 平均値}) - a \times (x \text{ の 平均値})$$

最小 2 乗法：ばらつきを最小にする

傾き a :

$$a = \frac{(x \text{ と } y \text{ の 共 分 散})}{(x \text{ の 分 散})}$$

切片'

x の分散： $(x_i - (x \text{ の 平均 値}))^2$ の平均

y の分散： $(y_i - (y \text{ の 平均 値}))^2$ の平均

x と y の共分散：

$(x_i - (x \text{ の 平均 値})) (y_i - (y \text{ の 平均 値}))$ の平均

最小 2 乗法：ばらつきを最小にする

傾き a :

$$a = \frac{(x \text{ と } y \text{ の 共分散})}{(x \text{ の 分散})}$$

切片 b :

$$b = (y \text{ の 平均値}) - a \times (x \text{ の 平均値})$$

出生数を予想するモデル

$$\text{モデル：(出生数)} = a \times (\text{3年前の婚姻数}) + b$$

出生数の平均値 (2012-2021) : 944,000

婚姻数の平均値 (2009-2018) : 649,000

婚姻数の分散 (2009-2018) : 1,350,000,000

出生数と婚姻数の共分散 : 2,750,000,000


出生数の標準偏差
(分散の平方根) が
77,000程度ですので、
有効数字3桁で計算
しています。

$$a = \frac{2,750,000,000}{1,350,000,000} = 2.04$$


$$b = 944,000 - 2.04 \times 649,000 = -380,000$$

出生数を予想するモデル

出生数（2012-2021）と婚姻数（2009-2018）



出生数を予想するモデル



問題

最新の婚姻数を調べて、その3年後の出生数を予想しなさい。