



経済統計分析 6 確率の基礎

第1回宿題について

- ▶ 答えが合わないのですけど?
 - ▶ ひょっとして違うデータを使っているかしら?
- ▶ 成長率(変化率)の定義
 - ▶ $(x_t - x_{t-1})/x_{t-1}$ が一般的. %表示にしてもよい.
- ▶ 記述統計の計算
 - ▶ 組込み関数を使うとよい. count, average, sumなど.
 - ▶ 標準偏差については, 「今回は」STDEVPを使います.
 - ▶ もちろん, 差をとって2乗して足して割ってもよいです.
- ▶ ローレンツカーブ
 - ▶ 各国を「階級値」と考えてもらいたかったところです.
 - ▶ 散布図を使って描きましょう.

今日のおはなし.

- ▶ 統計的推測 statistical inference へ向けての準備
 - ▶ 確率論の基礎用語
 - ▶ 確率分布, とくに正規分布
 - ▶ 条件付き分布
 - ▶ 標本分布

- ▶ 今日のタネ
 - ▶ 吉田耕作. 2006. 直感的統計学. 日経BP.
 - ▶ 中村隆英ほか. 1984. 統計入門. 東大出版会.

なにができるようになりたいか

- ▶ ある変数が他の変数に与える効果の大きさの数量化
 - ▶ 例:「統治状況」は一国経済の成長率に、平均的には、どれほど影響するのか?
 - ▶ 例:「統治状況」がいいところと悪いところでは経済成長率に差があるのか?
- ▶ でも、社会経済事象にはさまざまな要因が影響する
 - ▶ いくつかの事象は捨象せざるをえない
 - ▶ すべてのデータを集めることは不可能
- ▶ だから、観察されるデータに誤差や散らばりはつきもの
 - ▶ なんらかの意味での「でたらめさ randomness」がつきまとう
 - ▶ 例:経済成長率は「統治状況」だけに影響されるわけではない
 - ▶ 例:ある年の経済成長率のデータは特殊要因に左右されるかも
- ▶ 「でたらめさ」を扱う手法が必要 → 確率論.

確率論の考え方

▶ 確率論

- ▶ 「不確かさ」や「リスク」を扱うための数学的手法
- ▶ 将来起きうることを列挙し、それぞれの「起きやすさ」を数値で表現
- ▶ 「起きやすさ」って？

▶ 先験的(理論的)確率

- ▶ 起きうるものがいくつかあるとき、どれがとくに起きやすいと考える理由がないとき、それらの「起きやすさ」はすべて等しいと考えよう

▶ 経験的(実験的)確率

- ▶ これまでの経験や実験から、それぞれのできごとの起きる相対頻度が分かっており、一定の値に収束すると思われるとき、その収束先を「起きやすさ」と考えよう

▶ 主観確率

- ▶ 確信の度合い、信念などによって「起きやすさ」を主観的に割り振る
- ▶ 意思決定の前段階として位置づけられることが多い

事象, 根源事象

- ▶ 「起きうること」を全て挙げたとき,
 - ▶ 「起きうること」を一般に事象 event と呼ぶ
 - ▶ 根源事象: 相互に排他的で, それらの組合せによって他の「起きうること」を表現できるような事象
 - ▶ 標本空間 (Ω): 根源事象全てから成る集合.
 - ▶ 空事象 (ϕ): なにも起きないこと
- ▶ 例: サイコロ投げ
 - ▶ 事象: 「ピンの目が出る」「4以上の目が出る」「偶数の目が出る」.....
 - ▶ 根源事象: 「1」「2」「3」「4」「5」「6」
 - ▶ 標本空間: 「1か, 2か, 3か, 4か, 5か, 6の目が出る」
 - ▶ 空事象: なにも起きない

確率が満たすべき条件

▶ 確率が満たすべき条件

- ▶ 任意の事象 A に対して, $0 \leq \Pr(A) \leq 1$
- ▶ 標本空間と空事象に対して, $\Pr(\Omega) = 1, \Pr(\phi) = 0$.
- ▶ 相互に排他的な事象 A_1, A_2 に対して, $\Pr(A_1 \cup A_2) = \Pr(A_1) + \Pr(A_2)$

▶ 例:サイコロ投げの先験的確率

- ▶ 根源事象の確率はそれぞれ $1/6$:標本空間の確率が1だから.
- ▶ 事象 A を「4以上の目が出る」
- ▶ $\Pr(A_1) = \Pr(4) + \Pr(5) + \Pr(6) = 1/6 + 1/6 + 1/6 = 1/2$

▶ 確率の加法公式

- ▶ $\Pr(A_1 \cup A_2) = \Pr(A_1) + \Pr(A_2) - \Pr(A_1 \cap A_2)$
- ▶ ベン図を描こう

確率分布

▶ 確率変数

- ▶ 「でたらめ」の実現に応じてさまざまな値を取る変数
- ▶ 確率変数そのものを大文字, 実現値を小文字で書く習慣
- ▶ 例: さいころの出る目を X で表し, $\Pr(X=1) = 1/6$

▶ 確率分布

- ▶ 根源事象と, 対応する確率の一覧
- ▶ 例: サイコロ投げの確率分布

目	1	2	3	4	5	6
確率	1/6	1/6	1/6	1/6	1/6	1/6

- ▶ 例: 2個のサイコロ投げの確率分布

目	1, 1	1, 2	1, 3	1, 4	1, 5	1, 6	...	6, 5	6, 6
確率	1/36	1/36	1/36	1/36	1/36	1/36	...	1/36	1/36

- ▶ 連続変数のばあい, このような確率分布は考えにくい

累積確率分布, 確率密度

▶ 累積確率分布 c.d.f. (cumulative distribution function)

▶ 確率変数がある値より小さな値を取る確率 $f_X(x) = \Pr(X \leq x)$

▶ 例:サイコロ投げの累積分布関数

目	1	2	3	4	5	6
分布	1/6	2/6	3/6	4/6	5/6	1

▶ 確率密度 p.d.f. (probability density function)

▶ 連続関数のときだけ

▶ 累積分布関数の微分値 → 全区間について積分すると1

▶ 確率分布の棒グラフの高級な(?)やつだが, 1以上の値も取りうる

同時分布, 周辺分布

▶ 同時分布 joint distribution

- ▶ 2つ以上の確率変数があるとき, それらの実現値の組合せにたいする確率の一覧
- ▶ 例: 2枚前のスライド
- ▶ 例: 天気と通勤時間 (Stock and Watson, Table 2.2.)

	雨 ($X=0$)	晴れ ($X=1$)	
遅れる ($Y=0$)	0.15	0.07	
遅れない ($Y=1$)	0.15	0.63	

- ▶ 実現値の組合せが「事象」となるので, 同時確率の和が1

▶ 周辺分布 marginal distribution

- ▶ 同時分布が与えられたときに, 1つの変数だけに着目してえられる確率分布

条件付き分布

▶ 条件付き確率, 条件付き分布 conditional distribution

- ▶ 2つ以上の確率変数があるとき, ある確率変数の実現値を所与としたときの(ある確率変数で条件付けしたときの)他の変数の確率分布
- ▶ 例: 天気で条件付けたときの通勤時間の条件付き分布

	雨 (X=0)	晴れ (X=1)
遅れる (Y=0)		
遅れない (Y=1)		
	1	1

- ▶ 一般的には, 条件付き分布は, 条件付けた変数の関数となる

▶ 記法

- ▶ 同時確率: $\Pr(X = x, Y = y)$
- ▶ 条件付き確率: $\Pr(X = x | Y = y) = \Pr(X = x, Y = y) / \Pr(Y = y)$

ベイズの定理

- ▶ 条件付き確率と同時確率の関係

$$\Pr(X = x, Y = y) = \Pr(Y = y) \Pr(X = x | Y = y)$$

$$\Pr(X = x, Y = y) = \Pr(X = x) \Pr(Y = y | X = x)$$

- ▶ 左辺は同じものだから,

$$\Pr(Y = y) \Pr(X = x | Y = y) = \Pr(X = x) \Pr(Y = y | X = x)$$

- ▶ 両辺を割ってみると, ベイズの定理をえる

- ▶ 右辺と左辺で, 条件付けされている変数が入れ替わっていることに注意!
- ▶ $\Pr(Y = y) = \sum \Pr(Y = y | X = x_i) \Pr(X = x_i)$ という関係を使って変形できる

ベイズの定理の応用例

- ▶ ベイズ流の情報のアップデートの例
 - ▶ 右辺に入っている $\Pr(X)$ が事前確率
 - ▶ 左辺でもとまる $\Pr(X = x | Y = y)$ が事後確率
- ▶ ○×式の試験結果から、理解しているかどうかを推測
 - ▶ X : 答えが分かっているかどうか. 分かっていたら1, いなければ0
 - ▶ Y : 試験に正答すれば1, 間違えれば0
 - ▶ 仮定: $\Pr(Y = 1 | X = 1) = 1, \Pr(Y = 0 | X = 1) = 0$
 - ▶ 仮定: $\Pr(Y = 1 | X = 0) = 1/2, \Pr(Y = 0 | X = 0) = 1/2$
 - ▶ 右辺は $\Pr(X)$ の関数として表現できる
- ▶ たとえば, $\Pr(X = 1) = 1/2$ のとき, $Y = 1$ なら, $\Pr(X = 1 | Y = 1) = 2/3$
- ▶ 「正答した」という情報から「分かっている」確率が上方修正された

独立

▶ 独立 independent

- ▶ 2つの変数が独立であるとは, すべての起きうる値に対して, 条件付き分布が周辺分布に等しいことをいう.
- ▶ このとき, 条件付き分布の定義より, 同時分布は周辺分布の積
- ▶ 例:2つのサイコロ投げ
- ▶ 2つの確率変数は相関を持たない
- ▶ 片方の確率変数の実現値の情報が分かったとしても, もうひとつの確率変数の確率分布について新たな情報とならない

確率分布の特性値

- ▶ 確率分布がすでに分かっているとする
- ▶ 確率分布の特性値
 - ▶ 確率分布の状況の特徴付けるような数値
 - ▶ 確率分布の記述統計量といってもよい
 - ▶ よく使うのは(条件付き)平均と分散
- ▶ 確率分布の状況が分かっていないとき,
 - ▶ 特性値の値が、「統計的推測(推定)」のターゲットとなる
 - ▶ 一般に、手元にあるデータから確率分布を完全に復元するのは不可能
 - ▶ じっさい、「統計的推測」とは、分かっていない特性値を推測することといってもよい
 - ▶ 例:日本の平均賃金率. 学歴別の平均賃金率.

平均, 分散

▶ 平均 mean, average

- ▶ 確率を重みとする実現値の加重平均

$$\mu = E[Y] = \sum_{i=1}^k y_i \Pr(Y = y_i)$$

- ▶ 連続変数のばあいも, 加重平均みたいなもの (積分値)

▶ 分散 variance

- ▶ 確率分布の「広がり」「散らばり」を表す
- ▶ 各実現値から平均を引いたものの2乗和を確率で加重和したもの

$$\sigma^2 = \text{var}(Y) = E[(Y - \mu)^2] = \sum_{i=1}^k (y_i - \mu)^2 \Pr(Y = y_i)$$

▶ 標準偏差 standard deviation

- ▶ 分散の平方根

期待値

- ▶ 期待値 expected value
 - ▶ 一般に, 確率を重みとする加重平均のことを期待値と呼ぶ
 - ▶ 平均: 実現値の期待値
 - ▶ 分散: 平均を引いたものの2乗の期待値
 - ▶ が, ふつうに「期待値」というときには平均をさす

共分散, 相関係数

▶ 共分散 covariance

- ▶ 平均との差の積の期待値

$$\begin{aligned}\sigma_{XY} &= \text{cov}(X, Y) = E[(X - \mu_X)(Y - \mu_Y)] \\ &= \sum_{i=1}^k (x_i - \mu_X)(y_i - \mu_Y) \Pr(X = x_i, Y = y_i)\end{aligned}$$

- ▶ 2つの変数が同じ方向に動く傾向があるとき正の値
- ▶ 2つの変数が逆の方向に動く傾向があるとき負の値

▶ 相関係数 correlation coefficient

- ▶ 共分散を標準偏差の積で割ったもの
- ▶ 相関係数は-1より大きく, 1より小さい
- ▶ 相関係数がゼロであるとき, 「無相関」という
- ▶ 2つの変数が独立であるとき, 無相関 (逆は必ずしも成り立たない)

期待値の性質

▶ 期待値の線形性

- ▶ 確率変数 X, Y , 定数 a, b に対して以下が成り立つ
- ▶ $E[aX + bY] = a E[X] + b E[Y]$

▶ 分散の性質

- ▶ $\text{var}(aX + bY) = a^2\text{var}(X) + b^2\text{var}(Y) + 2 ab \text{cov}(X, Y)$