

Статистика 2

Семерикова Елена Вячеславовна, к.э.н.



- **1. Корреляция**
- **2. Линейная регрессия**
 - 2.1. Зачем: интерпретация и предсказание
 - 2.2. Качество регрессии (R^2)
 - 2.3. Связь: правда или ложь?





Дисперсия

- (лат. Рассеяние)
- В физике – разложение белого на различные цвета
- Variance
- Вариация
- Ковариация?



Коэффициенты корреляции

Качественные (порядковые) переменные:

- **Порядковые**
 - ранговый коэффициент корреляции Спирмена

Количественные переменные

- Коэффициент корреляции Пирсона




Коэффициент корреляции (Пирсона)

- Часто переменные бывают связаны друг с другом. Что их связывает? Как измерить данную связь?
- **Коэффициент корреляции** – мера взаимосвязи между количественными переменными X и Y
- Данный коэффициент обозначается как r_{XY} или r и получается при нормализации ковариации
- Есть два вида взаимосвязи переменных:
 - **Положительная:** при возрастании X растет Y
 - **Отрицательная:** при возрастании X уменьшается Y
- **Доступный диапазон значений: [-1; 1]**
 - $r = 1$ идеальная положительная корреляция (точки лежат на прямой с положительным наклоном)
 - $0 < r \leq 1$ положительная корреляция (точки лежат вокруг прямой с положительным наклоном)
 - $r = 0$ отсутствие корреляции
 - $-1 \leq r < 0$ отрицательная корреляция (точки лежат вокруг прямой с отрицательным наклоном)
 - $r = -1$ идеальная отрицательная корреляция (точки лежат на прямой с отрицательным наклоном)
- Вычисляется по формуле: $r_{XY} = \frac{\sum(x-\bar{x})(y-\bar{y})}{\sqrt{\sum(x-\bar{x})^2(y-\bar{y})^2}}$


$$r_{XY} = \frac{n \sum x_i y_i - \sum x_i \sum y_i}{\sqrt{n \sum x_i^2 - (\sum x_i)^2} * \sqrt{n \sum y_i^2 - (\sum y_i)^2}}$$

Коэффициент корреляции

- Коэффициент корреляции является мерой **линейной зависимости**
- Линейная = прямая линия
- **Диаграмма рассеяния** может быть использована для проверки того, является ли зависимость (примерно) линейной. Если она не является таковой, коэффициент корреляции использовать нельзя



Линейная




Нелинейная

- Следует остерегаться **выбросов** – точек, которые находятся далеко от других точек, они могут сильно влиять на r_{XY}


Диаграммы рассеяния

Коэффициент корреляции отрицательный




$r \approx -1$

Корреляция отсутствует




$r = 0$

Коэффициент корреляции положительный – связь есть




$r \approx 0,5$



$r \approx 1$



Примеры диаграмм рассеяния для различных коэффициентов корреляции



Пример: билеты в кино и фаст-фуд

- Нам известны цены обеда в фаст-фуд кафе и 2 билетов в кино в различных городах мира. Какова корреляция между ними?


$$r_{XY} = \frac{\sum(x-\bar{x})(y-\bar{y})/(n-1)}{\sqrt{\sum(x-\bar{x})^2/(n-1)}\sqrt{\sum(y-\bar{y})^2/(n-1)}} = \frac{cov(X,Y)}{S_X S_Y} = \frac{6,976}{(1,292)(6,337)} \approx 0,835$$

- Цены на фаст-фуд обед и билеты в кино положительно коррелируют. Это значит, что в городах с наиболее дорогими фаст-фуд обедами обычно самые дорогие билеты в кино, и наоборот. Однако, из этого не следует, что дорогой фаст-фуд является причиной или следствием из дорогих билетов в кино.

| | A | B | C | D | E | F | G |
|----|------------|------------|-------------|------------|------------|------------------------|---|
| 1 | Город | Цена обеда | Билеты в ки | (X-Хср)^2 | (Y-Уср)^2 | (X-Хср)(Y-Уср) | |
| 2 | Лос-Анджел | 5,99 | 32,66 | 1,022121 | 157,176369 | 12,674907 | |
| 3 | Цюрих | 7,62 | 28,41 | 6,974881 | 68,674369 | 21,885967 | |
| 4 | Нью-Йорк | 5,75 | 20 | 0,594441 | 0,015129 | 0,094833 | |
| 5 | Мадрид | 4,45 | 20,71 | 0,279841 | 0,344569 | 0,310523 | |
| 6 | Токио | 4,99 | 18 | 0,000121 | 4,507129 | 0,023353 | |
| 7 | Париж | 5,29 | 19,5 | 0,096721 | 0,388129 | 0,193753 | |
| 8 | Берлин | 4,39 | 18 | 0,346921 | 4,507129 | 1,250447 | |
| 9 | Москва | 3,7 | 16 | 1,635841 | 16,999129 | 5,273317 | |
| 10 | Рим | 4,62 | 18,05 | 0,128881 | 4,297329 | 0,744207 | |
| 11 | Варшава | 2,99 | 9,9 | 3,956121 | 104,509729 | 20,333547 | |
| 12 | | | Сумма | 15,03589 | 361,41901 | 62,784854 | |
| 13 | | | | | | | |
| 14 | | | | | | | |
| 15 | | | | Вычисления | | | |
| 16 | | | | Хср | 4,979 | =СРЗНАЧ(В2:В11) | |
| 17 | | | | Уср | 20,123 | =СРЗНАЧ(С2:С11) | |
| 18 | | | | n-1 | 9 | =СЧЁТ(В2:В11)-1 | |
| 19 | | | | Ковариация | 6,97609489 | =F12/E18 | |
| 20 | | | | Sx | 1,29253799 | =КОРЕНЬ(D12/E18) | |
| 21 | | | | Sy | 6,33700779 | =КОРЕНЬ(E12/E18) | |
| 22 | | | | r | 0,83480863 | =КОРРЕЛ(В2:В11;С2:С11) | |
| 23 | | | | | | | |



Линейная регрессия



- Возраст супругов
- По горизонтали - возраст мужа, по вертикали – жены.
- Прямая линия может быть описана линейной функцией:
 - $Y = \alpha + \beta X$
 - где α – точка пересечения с осью Y, β – наклон по оси Y при увеличении X на одну единицу
 - В нашем случае зависимость имеет вид: $Y = \alpha + 0,8X$
- В данном случае мы можем сделать вывод, что при возрасте мужа (X) выше на 1 год, возраст жены (Y) будет выше на 0,8 лет.
- β характеризует, насколько больше будет значение Y при X выше на 1 единицу



R-квадрат


- Можно заметить, что в первом примере облако точек лежало ближе к линии регрессии, чем во втором. *О чем это говорит?*
- Так происходит из-за того, что в первом случае взаимосвязь выше, чем в другом
- Данный факт можно проследить при помощи **R-квадрата**. Данная мера показывает, какую **долю дисперсии переменной Y объясняет переменная X**
- R-квадрат принимает значения в **диапазоне [0;1]**
- 0 – отсутствие взаимосвязи
- 1 – тесная взаимосвязь
- *Очень уж похоже на коэффициент корреляции...*



R-квадрат – та же корреляция?

- Возьмем для примера модель зависимости количества отдыхающих на пляже от количества солнечных дней.
- R^2 в ней равняется 0,865
- Коэффициент корреляции между X (количество солнечных дней лета) и Y (число отдыхающих) r равен 0,93
- $R^2 = 0,93 * 0,93 = 0,865$
- Вывод: **простая линейная регрессия связана с коэффициентом корреляции**. Оба коэффициента показывают взаимосвязь между количественными переменными (r_{XY} в квадрате = R^2)





I DON'T TRUST LINEAR REGRESSIONS WHEN IT'S HARDER TO GUESS THE DIRECTION OF THE CORRELATION FROM THE SCATTER PLOT THAN TO FIND NEW CONSTELLATIONS ON IT.

РАНЬШЕ Я ДУМАЛ,
ЧТО КОРРЕЛЯЦИЯ
ОБУСЛОВЛЕНА
ПРИЧИННОСТЬЮ




ПОТОМ Я
ПОСЕТИЛ УРОК
СТАТИСТИКИ И
ПОНЯЛ, ЧТО ЭТО
НЕ ТАК



ПОХОЖЕ, ЧТО УРОК
СТАТИСТИКИ ПОМОГ

ХМ, ВОЗМОЖНО




Корреляция и причинность

- Если понаблюдать за маленькими детьми, то можно заметить, что навыки чтения и размер обуви сильно коррелируют
- *Значит ли это, что увеличение размера ноги влечет за собой умение читать?*
- *Правда ли, что навыки чтения зависят от размера обуви?*
 - **Конечно же, это не так!**
 - Есть общая **связующая переменная** – возраст
- В данном случае идет речь о **мнимой (spurious) корреляции**




Мнимая корреляция



- Корреляция r не защищает от наличия общих нарушающих факторов
 - r измеряет силу и направление линейной зависимости X и Y




- причинно-следственная связь



Number of people who drowned by falling into a pool

correlates with

Films Nicolas Cage appeared in



Грустное резюме



Две количественные переменные – корреляция Пирсона
Порядковые переменные – коэффициент ранговой корреляции
Спирмена

- Корреляция ничего не скажет....
- И линейная регрессия тоже ☹️
- Причинно-следственную взаимосвязь еще попробуй докажи...




Многофакторная регрессия

$$y = \beta_0 + \beta_1 X_1 + \beta_2 \cdot X_2 + \dots + \beta_n X_n$$

- При добавлении новой переменной в регрессию, коэффициент перед «старой» переменной снижается

Бинарные переменные




$$y = \beta_1 + \beta_2 X + \beta_3 \cdot D$$

$D = 0$, если ...


$D = 1$, если ... (другое)

Ошибки регрессий:

- Смещенная выборка (напр., проблема самоотбора)
- Обратная взаимосвязь



- Неправильная функция (напр., парабола вместо прямой)
- Пропущенная переменная




Инструментальные переменные

- X зависит от Y,
- Y зависит от X


Выход:

- Переменная Z:
 - Влияет на X
 - Не связана (напрямую) с Y
- Можно оценить причинно-следственную связь
X → Y



В какую сторону причинно-следственная связь?

- Институты влияют на экономический рост
- Но и в богатых странах легче улучшать экономические институты



*Институты - не ВУЗы, а механизмы, по которым действовало общество

В какую сторону причинно-следственная связь?

- Институты влияют на экономический рост
- Но и в богатых странах легче улучшать экономические институты




Инструмент?

- *Асемоглу-Джонсон-Робинсон*: смертность европейских колонистов от местных болезней 500 лет назад
- - В колониях, где европейцы жить не могли (Африка), они не вкладывались в развитие норм. институтов
- -В колониях, где европейцы жить могли (Америка), они развивали такие же институты, как в Европе

Результат: институты влияют на рост


Как оценить мыслительные способности людей поминутно?

- Атмосферное давление меняется каждую минуту
- Оценить изменение в том, как хорошо человек мыслит в каждую минуту, довольно тяжело



Как оценить мыслительные способности людей поминутно?

- Атмосферное давление меняется каждую минуту
- Оценить изменение в том, как хорошо человек мыслит в каждую минуту, довольно тяжело




Метод?

- Авторы взяли данные по результатам прохождения популярной онлайн игры на логику (в каждый момент времени большое количество людей играло в нее)
- Нашли отрицательную корреляцию между правильными ответами и изменением атмосферного давления

Результат: атмосферное давление влияет на когнитивные способности



- Как оценить влияние пропаганды без ошибки самоотбора?



Метод?

- Руанда 1994: геноцит народа Тутси <- Хуту (0.5млн-1млн человек)
- Пропаганда: «Свободное радио тысячи холмов»
- Страна горная => радиоволны проходили не везде => где-то Хуту слушали пропаганду, где-то – нет

- Пропаганда Хуту против народа Тутси



3 группы деревни

- Первая категория – удаленные горные деревни, где радио не ловило.
- Вторая – радиоволны проходили свободно, пропаганда вещала на полную.
- И третья – деревни, где радио не ловило, но расположенные в шаговой доступности от деревень второй категории

Выяснилось, что с особой жестокостью хуту убивали тутси именно в деревнях третьей категории (и, ожидаемо, гораздо меньше убивали во второй, где радио не было).

Рост как мера качества жизни.

Эмпирические исследования


- Как сравнить благосостояние людей в странах (где нет данных о доходах)?

Метод?

- Рост - зеркало уровня развития (как, например, продолжительность жизни или детская смертность)

- Например, южные корейцы на несколько сантиметров (!) выше северных

- Brainerd (2008):
- В СССР качество жизни росло до 1960х гг., потом начало снижаться и даже отставать от США
- Переход к рынку улучшил ситуацию




- (Перссон-Тамбеллини, 2008)

- Демократизации приводят к увеличению темпов роста на 1% по сравнению с похожими странами, которые не демократизируются
- Переходы от демократии к диктатуре приводят к снижению темпов роста на 2%

- **Event studies:**

- Неожиданная смерть диктатора приводит к ускорению экономического роста




Черта оседлости и отношение к рынку

Эмпирические исследования




Е. Журавская, И. Гросфельд, А. Роднянский



- Влияние черты оседлости (отмененной в 1917 году) на формирование ценностей : отношение к рынку, к « чужим » и т.п.
- Культурные различия, сформированные за годы ее существования, не только сохранялись в течение 40 или 60 лет, но проявляются и сегодня.

Гулаг и рост городов

Эмпирические исследования




ГУЛАГ:

- бесплатная рабочая сила
- «обслуживание городов»
- строительство капитала близ городов

Т. Михайлова

- Влияние расстояния от ГУЛАГа до города на рост населенного пункта
- Результат: влияние ГУЛАГа имеет место до сих пор



Как измерить популяцию слонов?

Эмпирические исследования

- Ходить по джунглям и считать слонов дорого и неэффективно



Как измерить популяцию слонов?

Эмпирические исследования

- Ходить по джунглям и считать слонов дорого и неэффективно



Метод?

- «Прослушивать» слонов
- С помощью нейронной сети вычислить звуки слонов
- Бюджетный способ посчитать их количество



- Ш. Вебер:
- Расстояние между языками (по «похожести» слов)
- Торговля между странами (народами)

