

КОРРЕЛЯЦИОННЫЙ И РЕГРЕССИОННЫЙ АНАЛИЗ

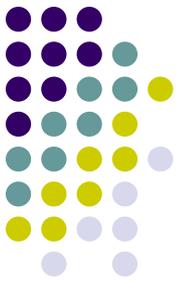
АНАЛИЗ ПАРНЫХ
ВЗАИМОСВЯЗЕЙ





Основные понятия

- **Статистическая** связь и ее отличие от **функциональной**.
- Связь как **синхронность** (согласованность) – корреляционный анализ.
- Связь как **зависимость** (влияние) – регрессионный анализ (причинно-следственные связи).
- **Парная связь** как частный случай множественной связи.
- Неучтенные факторы.



Этапы анализа

- Выявление наличия взаимосвязи между признаками
- Определение формы связи
- Определение силы (тесноты) и направления связи

Выявление наличия связи между признаками

Диаграммы рассеяния

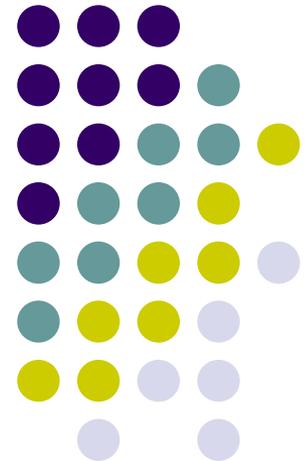
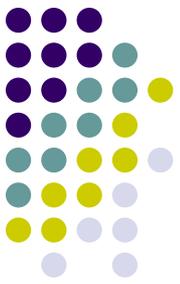


Диаграмма рассеяния (scatterplot)



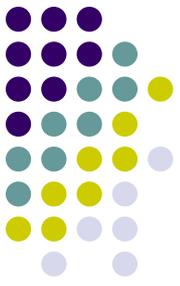


Направление связи

- В случае положительной функциональной СВЯЗИ –

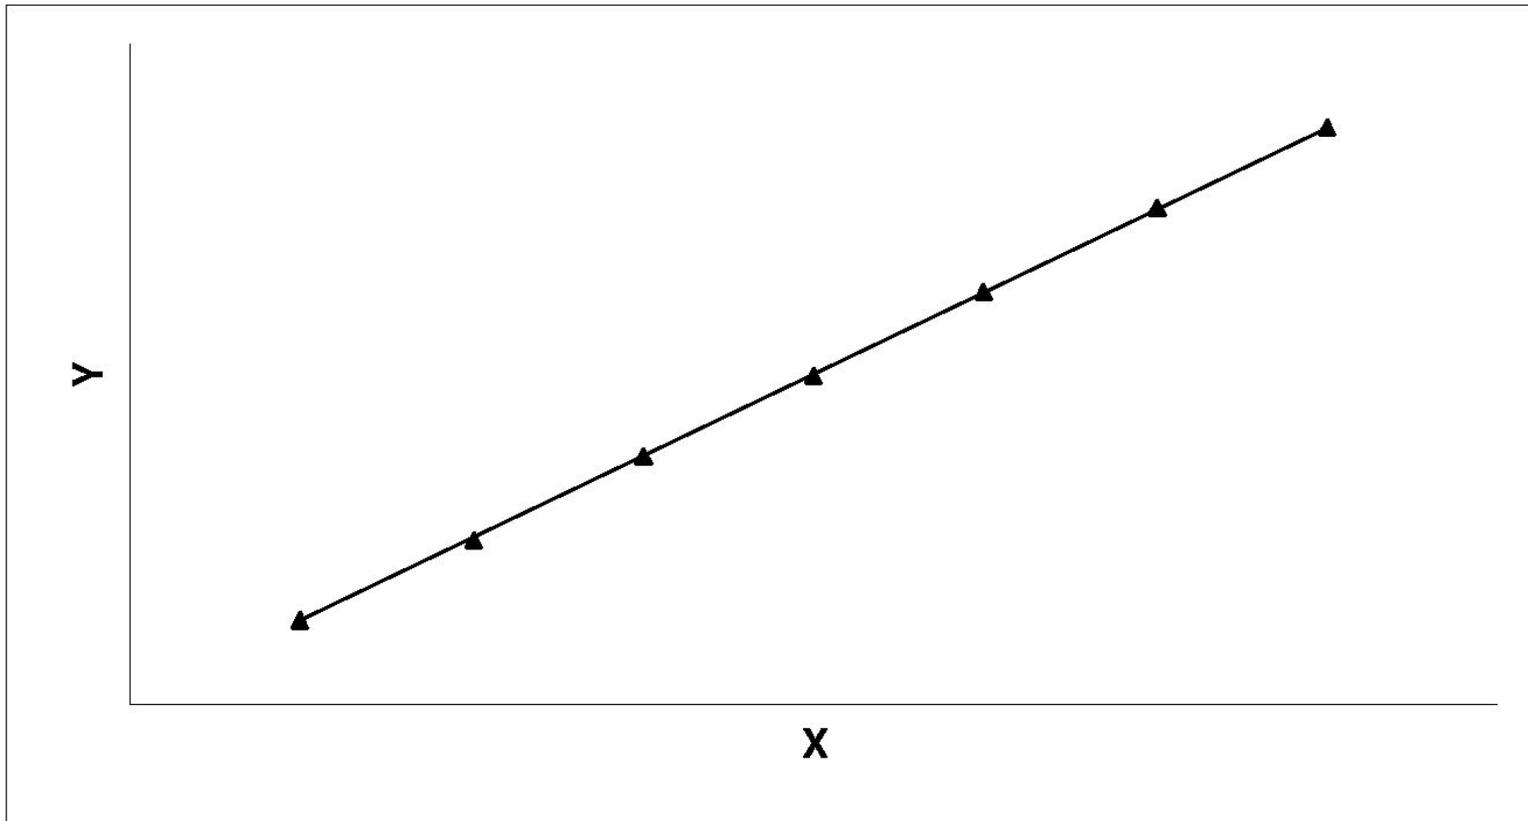
чем больше значения одного признака,
тем больше значения другого и

чем меньше значения одного признака,
тем меньше значения другого.



Направление связи

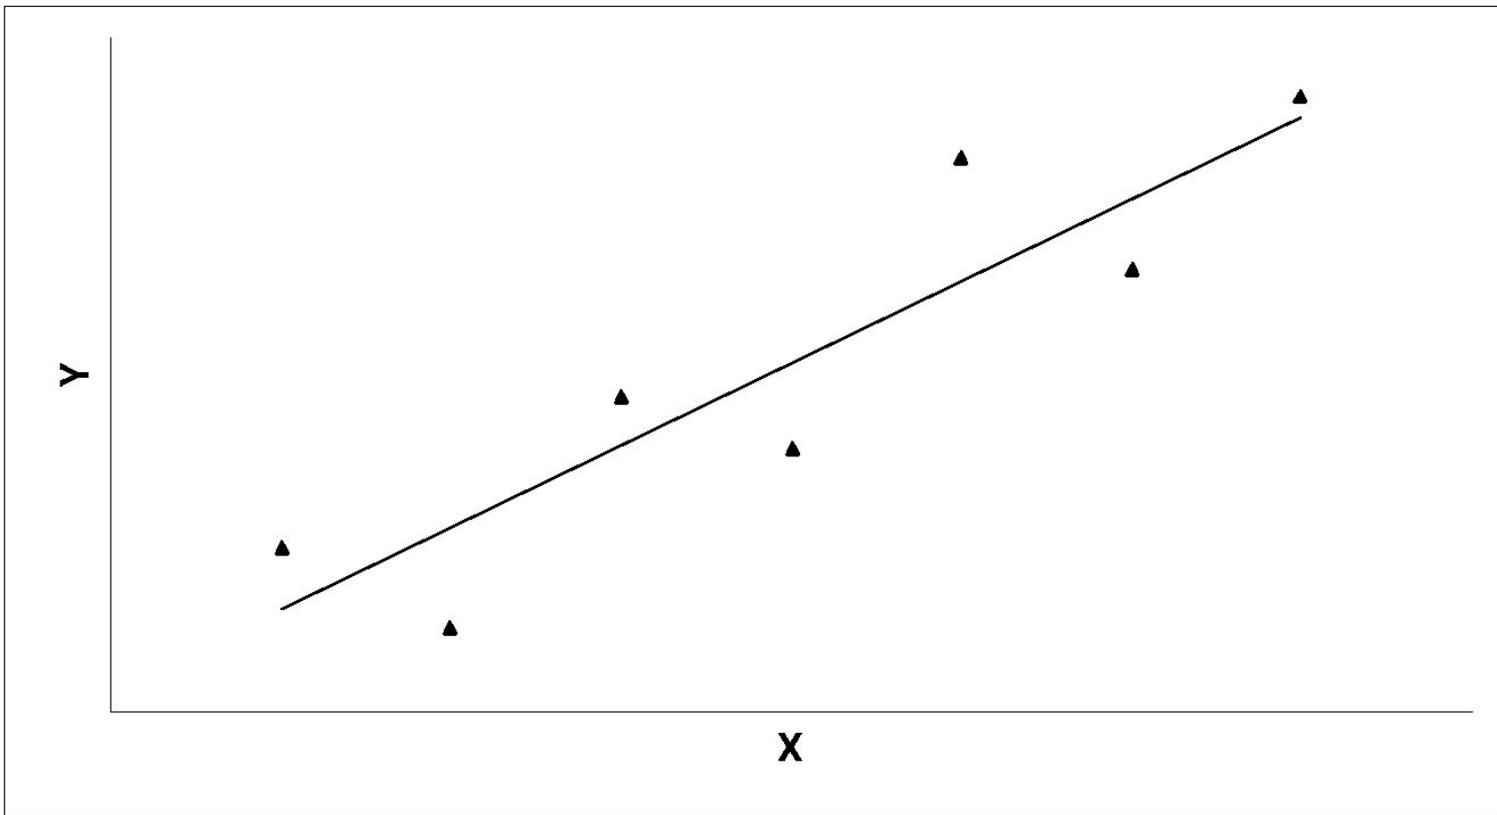
- Пример положительной функциональной связи между признаками X и Y .

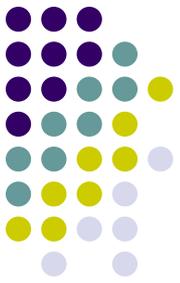




Направление связи

- Пример положительной статистической связи между признаками X и Y .





Направление связи

- В случае положительной статистической СВЯЗИ –

чем больше значения одного признака,
тем больше в среднем значения другого и

чем меньше значения одного признака,
тем меньше в среднем значения другого.

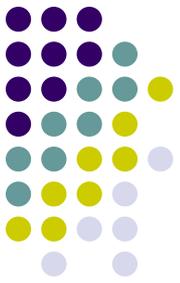


Направление связи

- В случае отрицательной функциональной связи –

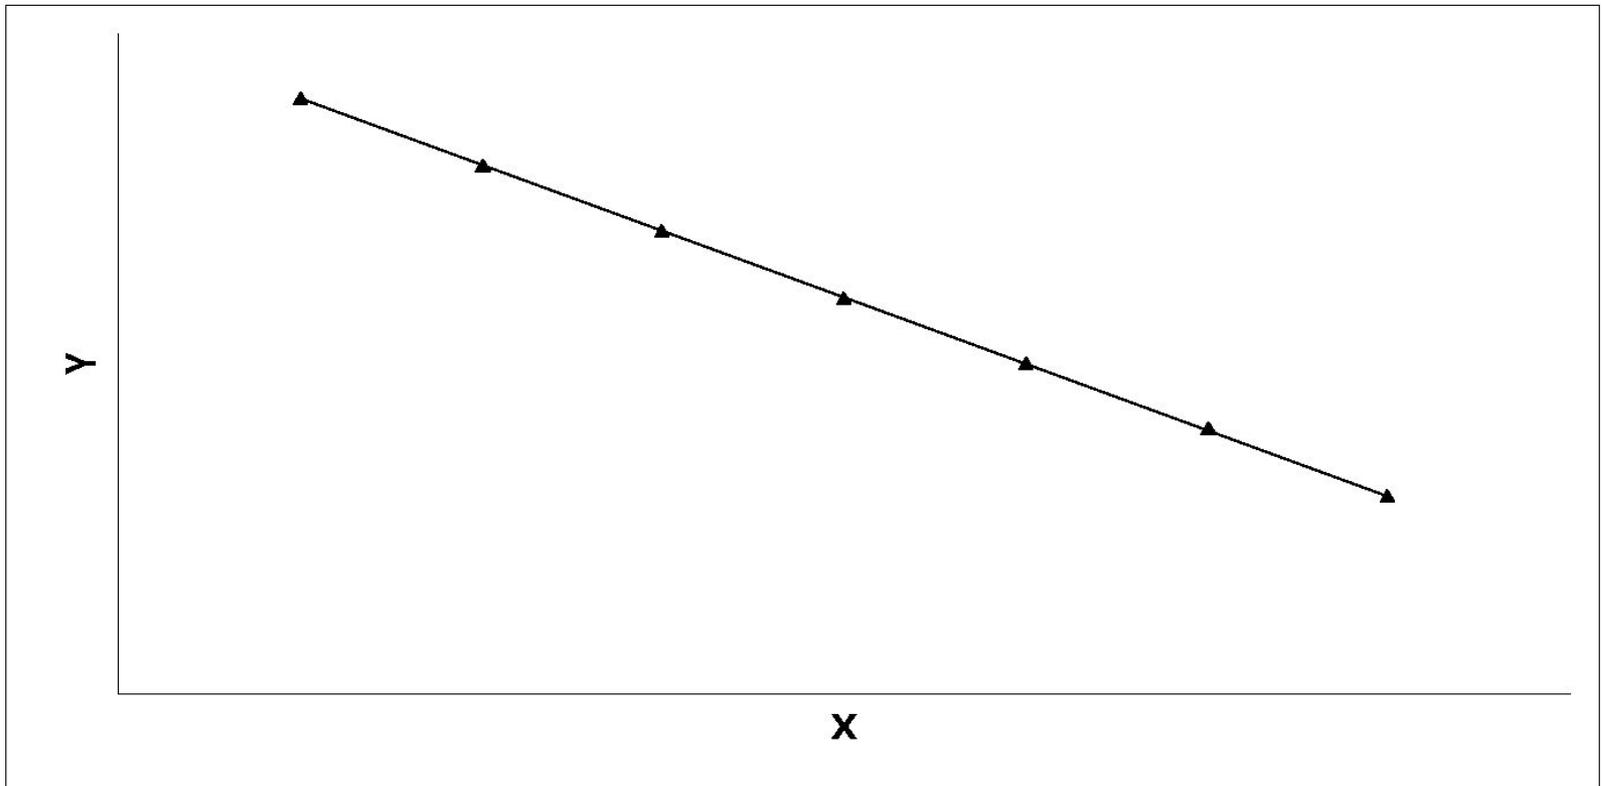
чем больше значения одного признака,
тем меньше значения другого и

чем меньше значения одного признака,
тем больше значения другого.



Направление связи

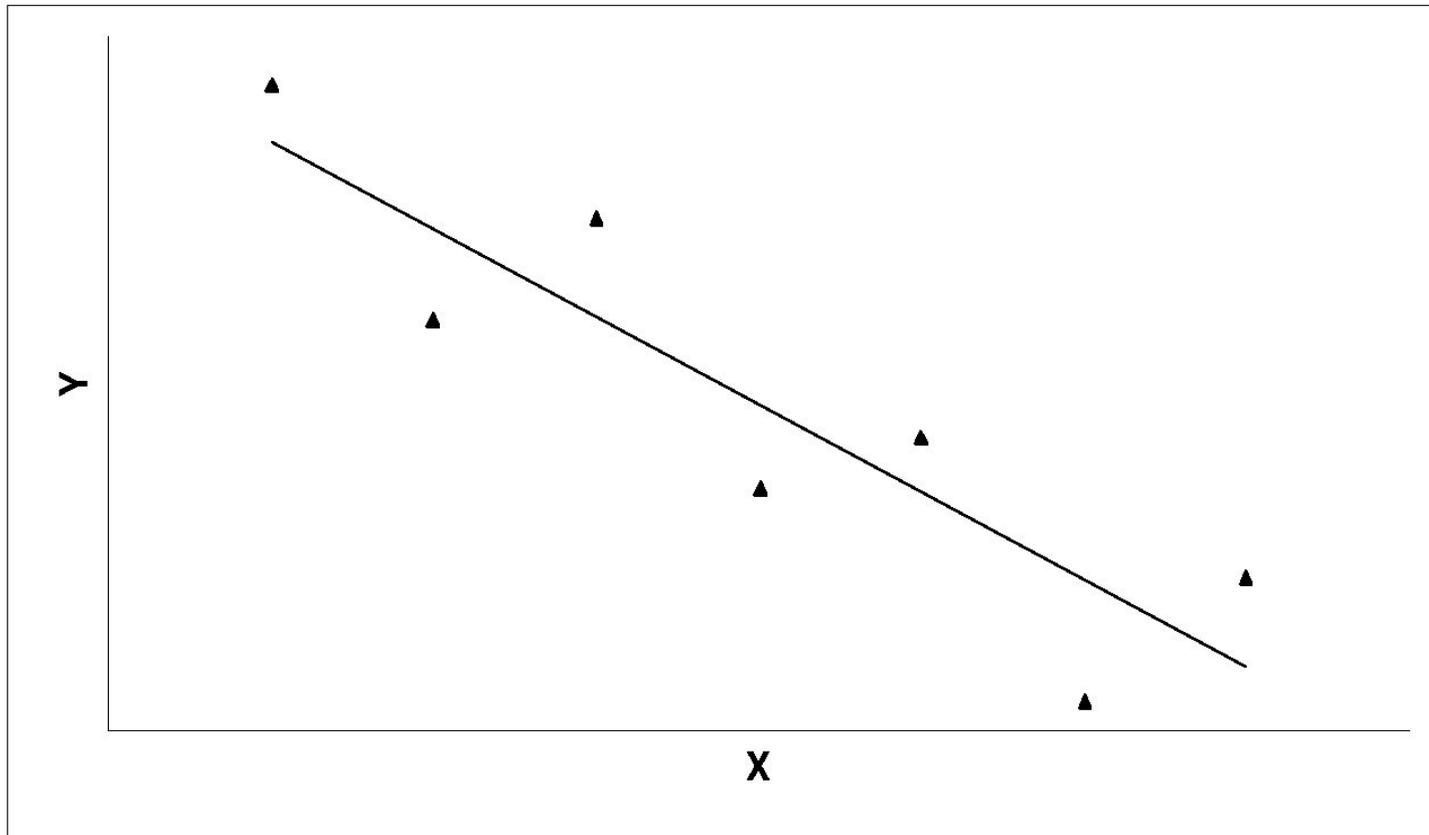
- Пример отрицательной функциональной связи между признаками X и Y .





Направление связи

- Пример отрицательной статистической связи между X и Y .





Направление связи

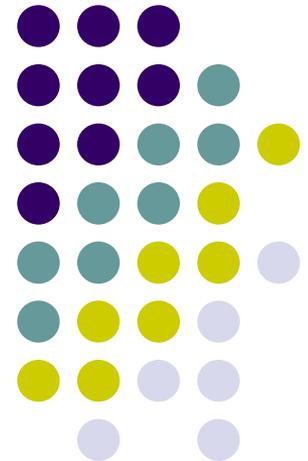
- В случае отрицательной статистической СВЯЗИ –

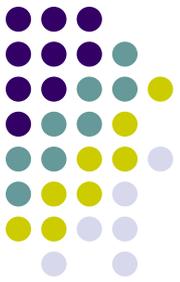
чем больше значения одного признака,
тем меньше в среднем значения другого и

чем меньше значения одного признака,
тем больше в среднем значения другого.

Подбор формы СВЯЗИ

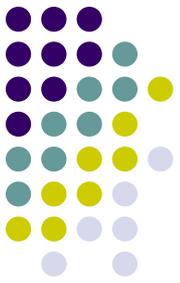
Линейная связь





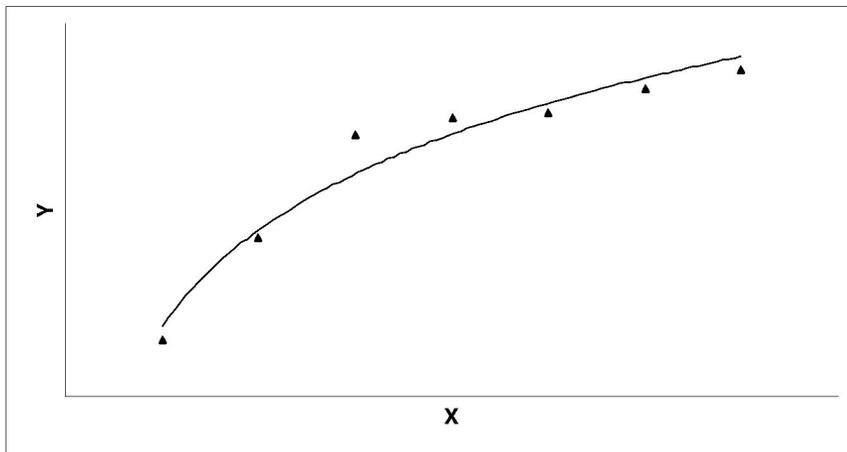
Форма связи

- *Почему прямая?*
- Поскольку наиболее простой формой зависимости в математике является прямая, то в корреляционном и регрессионном анализе наиболее популярны **линейные модели**.

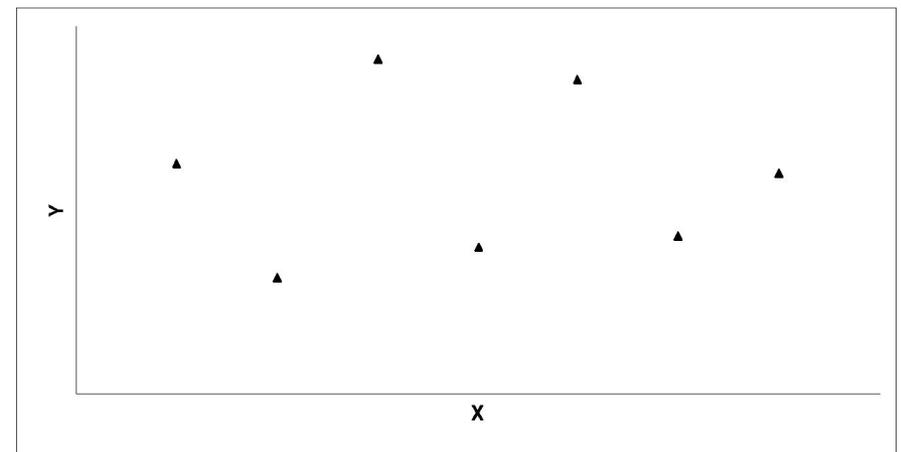


Форма связи

- Примеры нелинейной связи (рис. а) и отсутствия связи (рис. б) между признаками X и Y



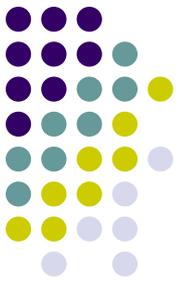
а



б

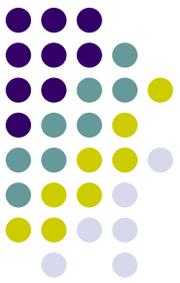
Форма связи – ?





Форма связи

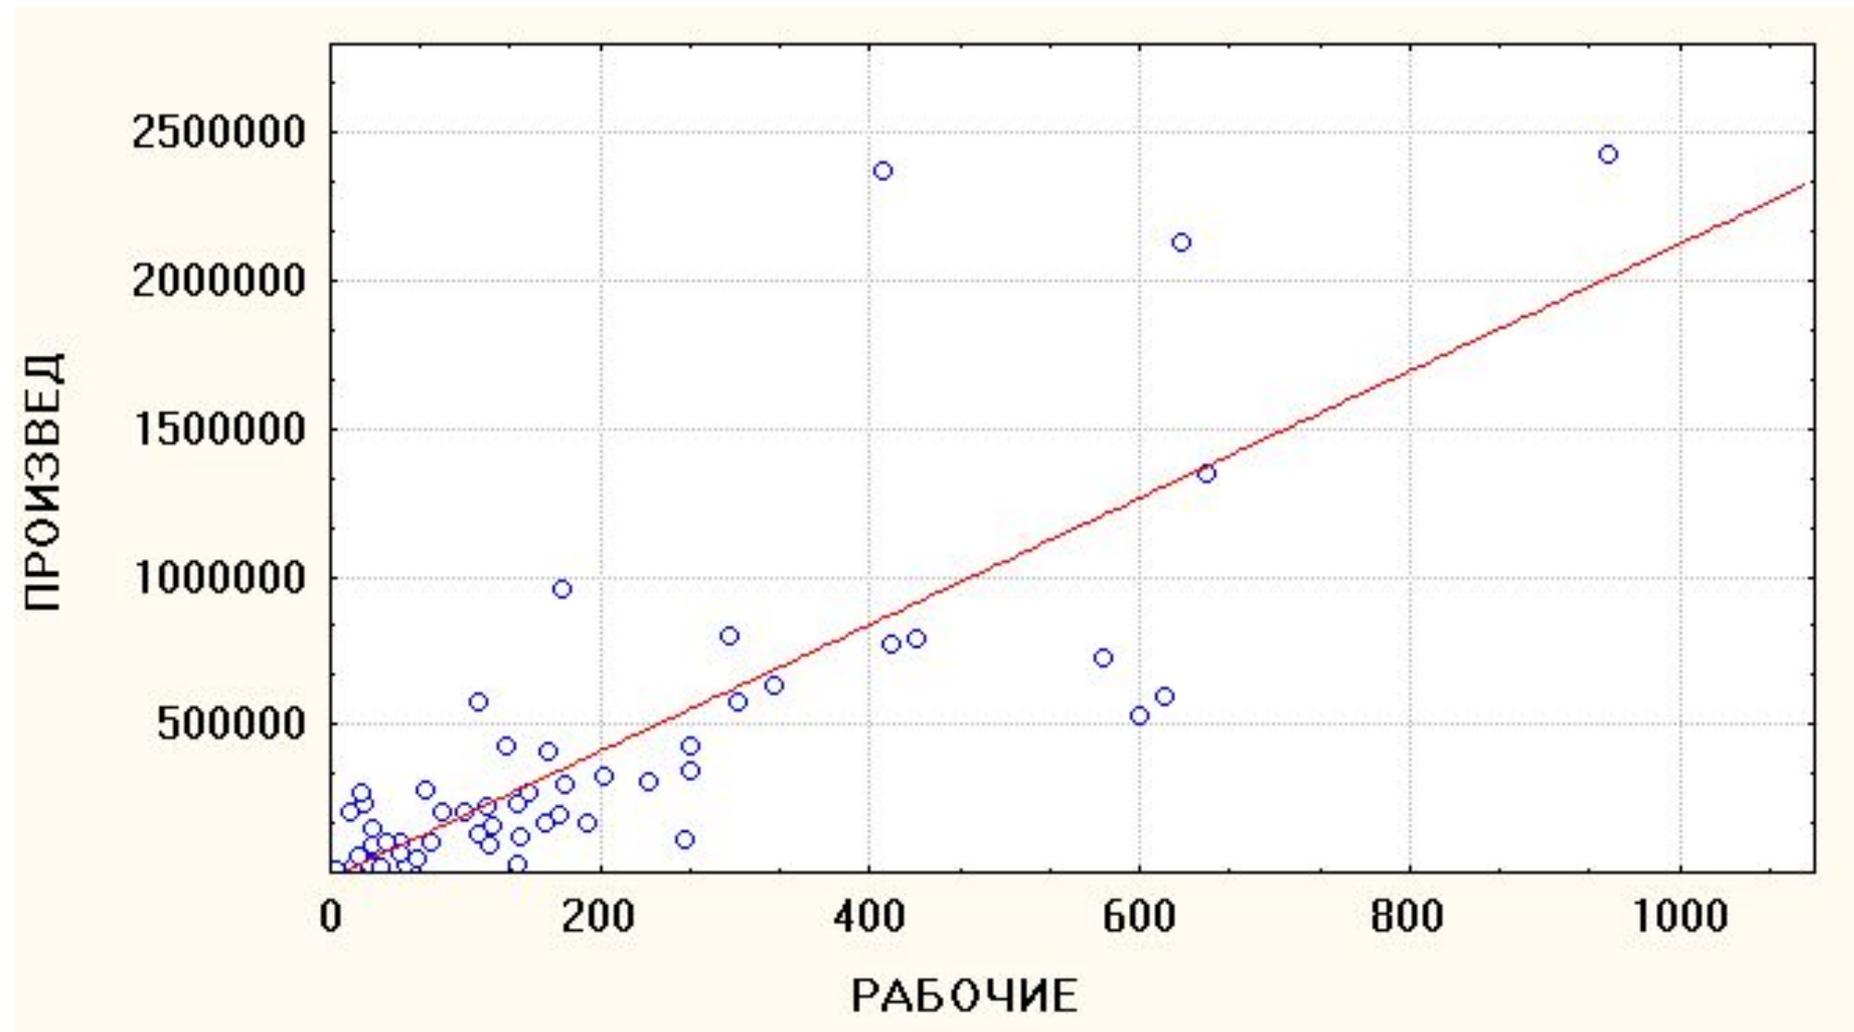
- Сколько прямых можно провести через облако точек на диаграмме рассеяния?
- Есть ли среди них наилучшая?
- Каким методом ее можно найти?



Форма связи

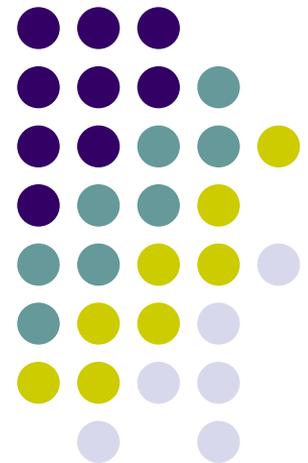
- **Метод наименьших квадратов** позволяет построить наилучшую прямую – **линию регрессии**.
- Сумма квадратов расстояний от точек до этой линии минимальна (по сравнению со всеми возможными линиями).

Линия регрессии

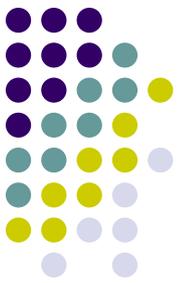


Коэффициент корреляции

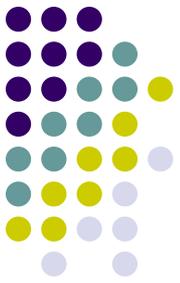
Мера тесноты линейной связи



Коэффициент корреляции

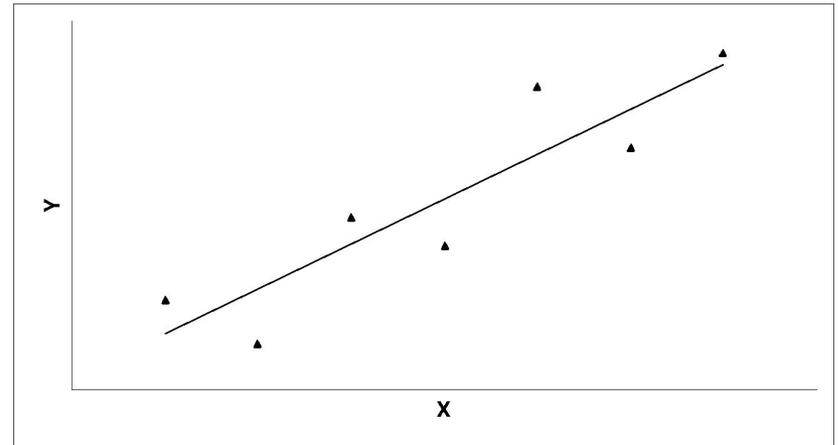
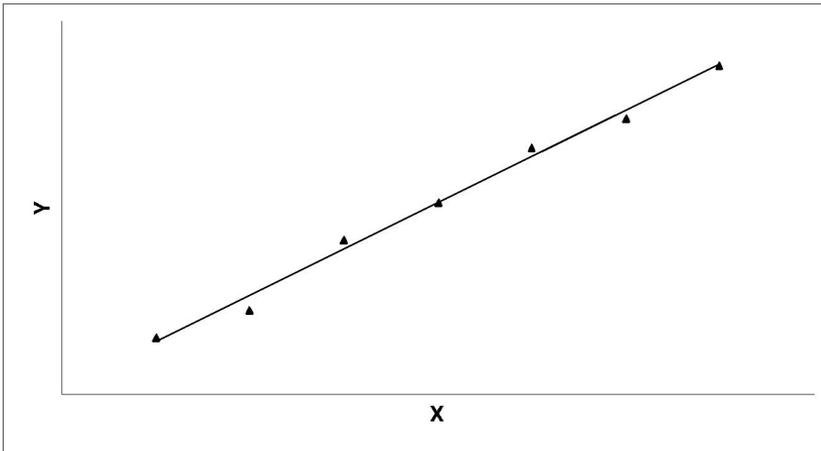


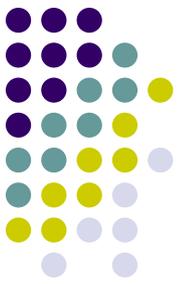
- Оказывается форма связи (линия регрессии) не дает ответа на вопрос о тесноте (силе) связи пары переменных.
- На вопрос о силе связи отвечает ***коэффициент парной корреляции***. Он показывает, насколько тесно две переменные связаны между собой.



Коэффициент корреляции

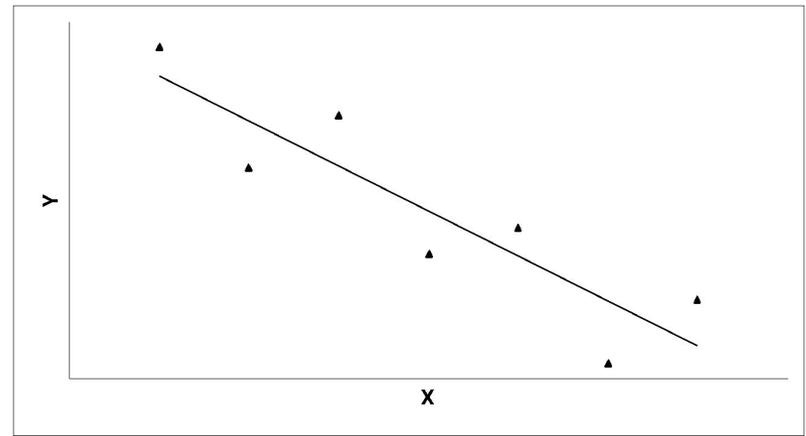
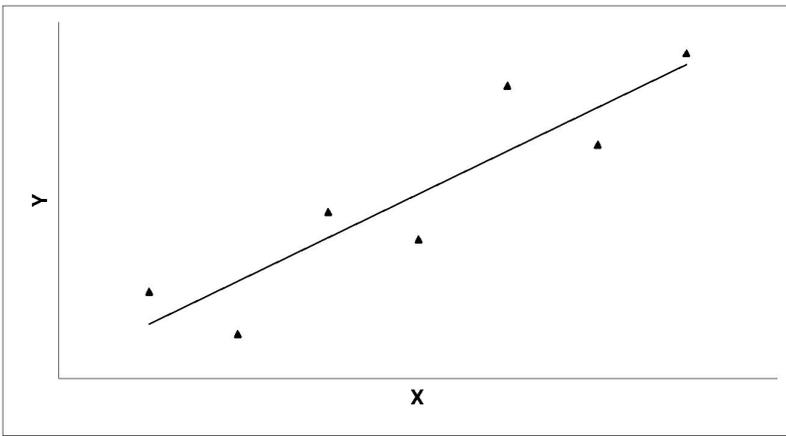
- На каком из двух графиков связь между признаками сильнее (теснее), т.е. какому из графиков соответствует более высокий коэффициент корреляции?

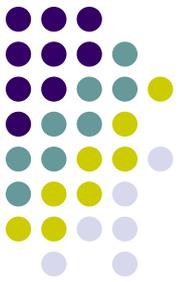




Коэффициент корреляции

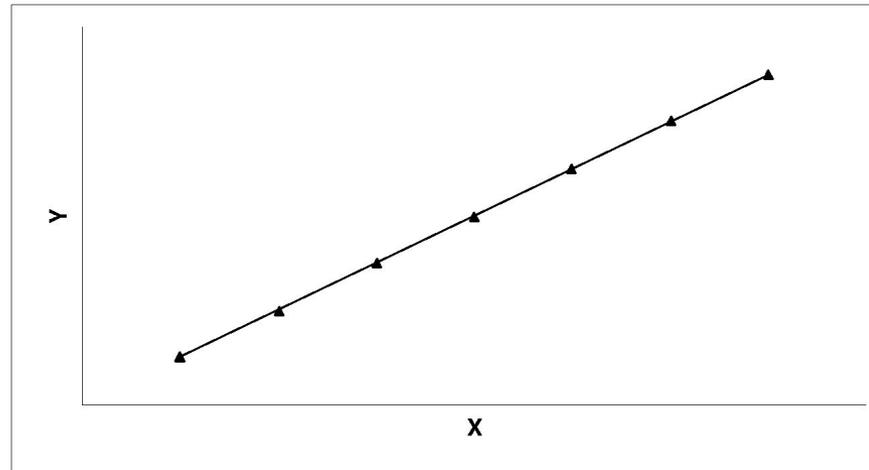
- Коэффициент парной корреляции r принимает значения в диапазоне от -1 до $+1$.
- Положительные значения коэффициента корреляции r свидетельствуют о положительной связи между признаками, отрицательные – об отрицательной связи.

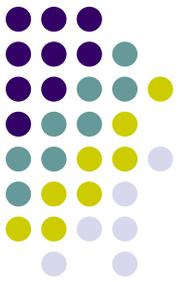




Коэффициент корреляции

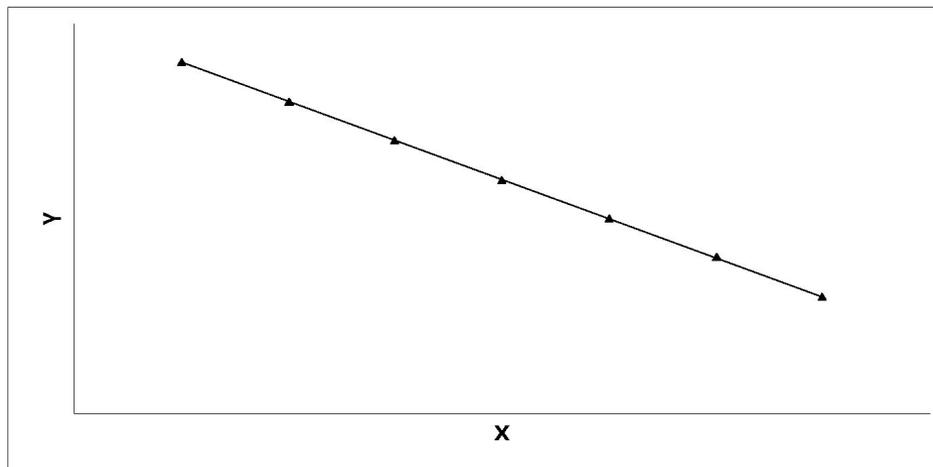
- Между двумя переменными существует **функциональная положительная линейная связь**.
- $r = ?$

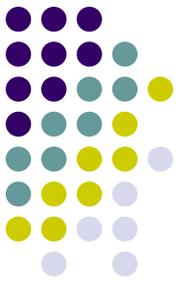




Коэффициент корреляции

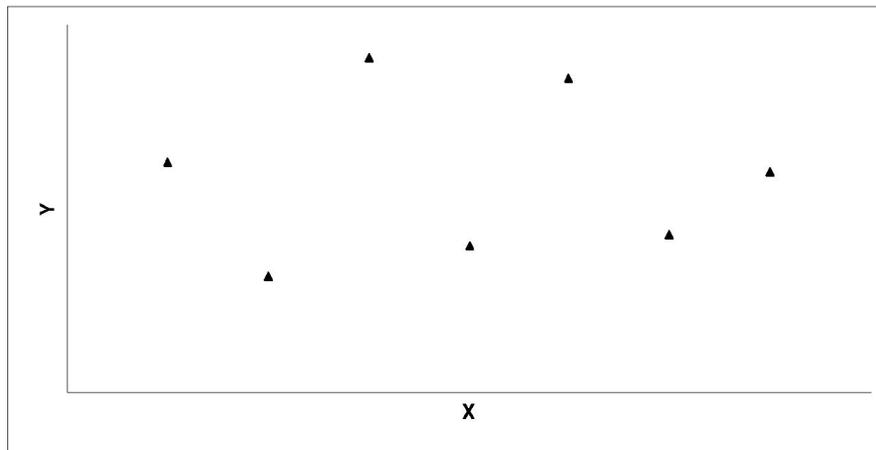
- Между двумя переменными существует **функциональная отрицательная линейная связь**.
- $r = ?$

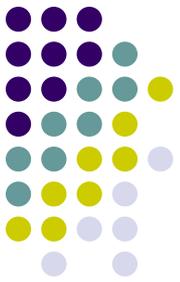




Коэффициент корреляции

- Переменные **линейно независимы**, т.е. на диаграмме рассеяния облако точек "вытянуто по горизонтали".
- $r = ?$

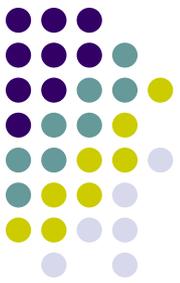




Коэффициент корреляции

- Визуально о силе связи можно судить по тому, насколько тесно расположены точки-объекты около линии регрессии.

Чем ближе точки к линии регрессии, тем сильнее связь.



Коэффициент корреляции

- Формула для вычисления парного коэффициента корреляции:

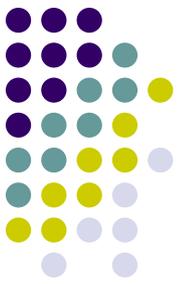
$$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}}$$



Коэффициент корреляции

- Коэффициент парной корреляции вычисляется для количественных признаков.
- Коэффициент корреляции симметричен, т.е. не изменяется, если X и Y поменять местами.
- Коэффициент корреляции является величиной **безразмерной**.
- Коэффициент корреляции **не изменяется при изменении единиц измерения** признаков X и Y .

Коэффициент детерминации



- Для интерпретации результатов корреляционного анализа обычно используется **коэффициент детерминации d** ($d = r^2$, выражается в %)
- Коэффициент детерминации показывает, насколько изменения зависимого признака объясняются изменениями независимого

Коэффициенты корреляции и детерминации



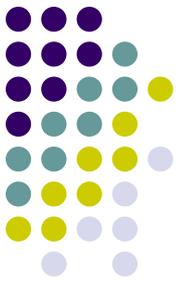
- Коэффициент детерминации принимает значения в диапазоне от 0% до 100%.
- Если две переменные функционально линейно зависимы, что можно сказать о коэффициенте детерминации?
- Чему при этом равен коэффициент корреляции?

Коэффициенты корреляции и детерминации

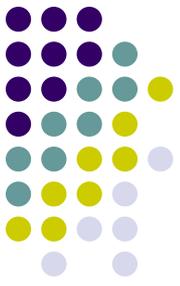


- Если две переменные линейно независимы, что можно сказать о коэффициенте детерминации?
- А о коэффициенте корреляции?

Коэффициенты корреляции и детерминации

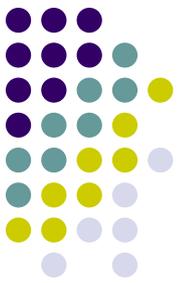


- Чем выше по модулю (по абсолютной величине) значение коэффициента корреляции, тем сильнее связь между признаками.
- Если $|r| > 0.7$, связь называется сильной; если $0,5 < |r| \leq 0,7$ – средней; если $|r| \leq 0,5$ – слабой.



Матрица корреляции

- Если объекты характеризуются несколькими признаками, можно построить ***матрицу корреляции***.
- По диагонали матрицы стоят ???
- Матрица симметрична, т.е. значения выше и ниже диагонали повторяются (т.к. $r_{xy} = r_{yx}$).
Почему?



Матрица корреляции

- Пример матрицы корреляции для трех признаков.

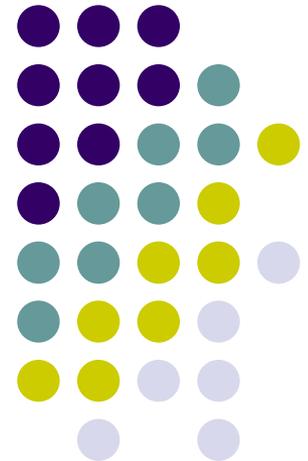
Correlations (INDUSTRY.STA)			
Marked correlations are significant at $p < ,05000$			
N=1060 (Casewise deletion of missing data)			
Variable	РАБОЧИЕ	ПРОИЗВЕД	ДВИГАТЕЛ
РАБОЧИЕ	1,00	0,52	0,43
ПРОИЗВЕД	0,52	1,00	0,30
ДВИГАТЕЛ	0,43	0,30	1,00



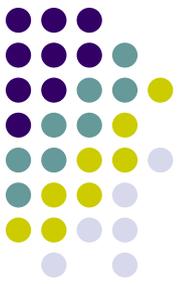
Матрица корреляции

- Некоторые коэффициенты в матрице корреляции показаны красным цветом.
- Это означает, что они являются ***статистически значимыми***.

Значимость коэффициента корреляции

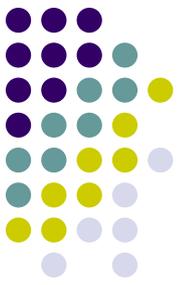


Статистическая значимость коэффициента корреляции



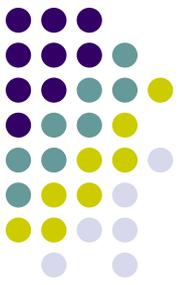
- Если коэффициент корреляции вычислен на основе выборки, то возможны две гипотезы:
 - он отражает связь, которая действительно существует в генеральной совокупности;
 - он объясняется случайным эффектом выборки, а в генеральной совокупности коэффициент корреляции равен нулю, т.е. (линейной) связи нет.
- Какая гипотеза верна?

Статистическая значимость коэффициента корреляции

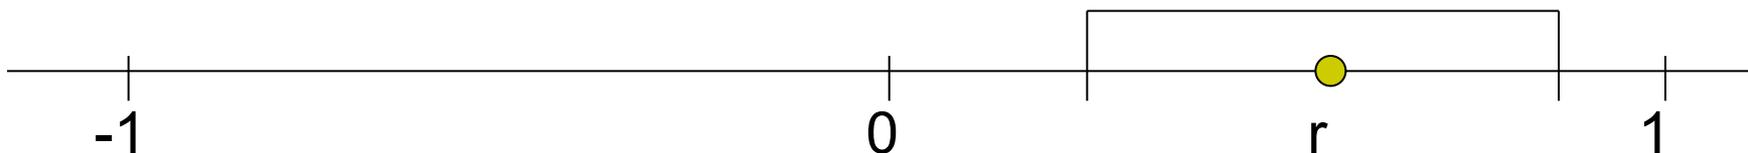


- Надо понять, *как далеко значение r от нуля.*
 - Для построения доверительного интервала вычисляется стандартная ошибка r .
 - Затем она умножается на параметр t , зависящий от доверительной вероятности P , чтобы найти предельную ошибку.
 - Наконец, строится доверительный интервал для возможных значений r в генеральной совокупности.
- Остается проверить, попадет ли нулевое значение в этот интервал.

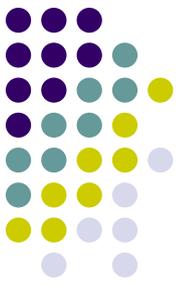
Статистическая значимость коэффициента корреляции



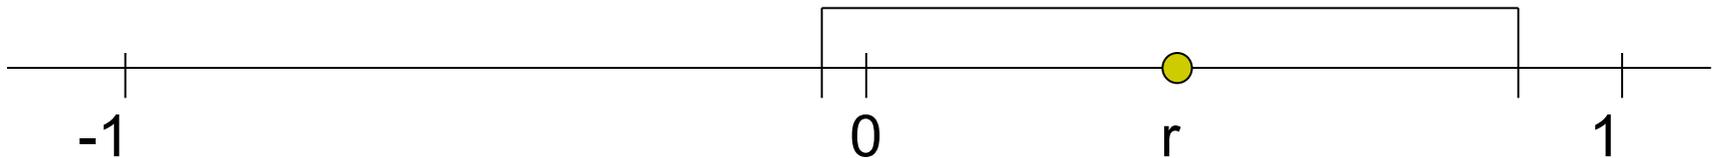
- Если ***ноль не попадет в доверительный интервал***, значит с высокой вероятностью в генеральной совокупности не может быть нулевого значения коэффициента корреляции, т.е. связь между признаками существует и в генеральной совокупности. В таком случае ***коэффициент корреляции является статистически значимым***.



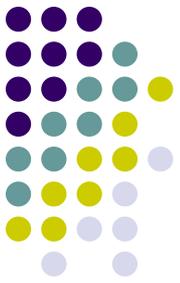
Статистическая значимость коэффициента корреляции



- Если ***ноль попадет в доверительный интервал***, значит с высокой вероятностью в генеральной совокупности может оказаться нулевая корреляция, т.е. отсутствие связи. В таком случае ***коэффициент корреляции является статистически незначимым***.

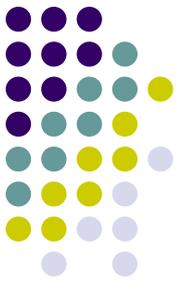


Статистическая значимость коэффициента корреляции



- На практике незначимые коэффициенты можно считать нулями и принимать во внимание только значимые.
- Величина коэффициента корреляции еще не гарантирует его значимости.

Статистическая значимость коэффициента корреляции



- Может ли большой коэффициент корреляции оказаться статистически незначимым?
При каких условиях?
- Может ли небольшой коэффициент корреляции оказаться статистически значимым?
При каких условиях?