

THE MANGA GUIDE TO

STATISTICS

SHIN TAKAHASHI
TREND-PRO, CO., LTD.



Занимательная статистика

Манга



マンガでわかる

統計学

高橋 信／著
トレンド・プロ／マンガ制作



Манга

Занимательная

СТАТИСТИКА

Син Такахаси

Перевод с японского

Захаровой Е. А., Коги Муцуми



Москва
Издательский дом «Додэка-ХХI»
2010

УДК 311

ББК 60.6

T15

Такахаси, Син.

- T15 Занимательная статистика. Манга / Син Такахаси ; пер. с яп. Захаровой Е. А., Коги Муцуми. — М. : Додэка-ХХI, 2010. — 224 с. : ил. — (Серия «Образовательная Манга»). — Доп. тит. л. яп. — ISBN 978-5-94120-244-7.
I. Захарова, Е. А., пер.

Если тебя интересует статистика, или тебе просто нужно как-то обработать данные, то «Занимательная статистика» поможет тебе преодолеть чувство, что «ты плохо знаешь математику». Этот иллюстрированный путеводитель легко и непринуждённо проведёт тебя по пути познания статистики. А полученные знания ты сможешь закрепить с помощью упражнений, без которых, как известно, не обходится ни одна книга по математике.

Последуй за всегда невозмутимым Ямamoto и ты увидишь, как он научит Руи:

- рассчитать среднее значение, медиану и стандартное отклонение результатов в боулинге;
- построить гистограмму цен на китайскую лапшу рамэн;
- определить вероятность получения проходного балла на экзаменах по математике;
- вычислить коэффициент Крамера, чтобы узнать, как предпочитают признаваться в любви юноши и девушки;
- узнать, как нормируются результаты тестов, когда учителя оценивают успеваемость.

Эти и другие примеры из реальной жизни позволят тебе с лёгкостью усвоить то, что многие находят трудным для понимания.

Если ты хочешь разобраться в статистике, но от обычных учебников статистики у тебя пухнет голова и клонит в сон, или если тебе просто нужно освежить забытые знания, пусть Ямamoto-сан и Руи будут твоими гидами.

Книга будет полезна учащимся старших классов средних школ и колледжей, студентам вузов, а также всем, кто интересуется статистикой и хочет, чтобы обучение было лёгким и увлекательным.

УДК 311

ББК 60.6

Все права защищены. Никакая часть этого издания не может быть воспроизведена в любой форме или любыми средствами, электронными или механическими, включая фотографирование, ксерокопирование или иные средства копирования или сохранения информации, без письменного разрешения издательства.

ISBN 978-5-94120-244-7 (рус.)

ISBN 978-4-27406-570-5 (яп.)

© Син Такахаси, Trend-Pro Co., LTD.

© Издательский дом «Додэка-ХХI», 2010

© Серия «Образовательная Манга»

Содержание

Предисловие	xiii
Пролог. Любовь и статистика	1
Глава 1. Разберёмся с типами данных	13
1. Количественные и качественные данные	14
2. Примеры качественных данных	20
3. Использование многовариантных ответов на практике	28
Упражнение	29
Ответ	29
Выводы	29
Глава 2. Знакомимся с количественными данными	31
1. Ряды распределения и гистограммы	32
2. Средняя величина	40
3. Медиана	44
4. Стандартное отклонение	48
5. Ряды распределения и величина интервала	54
6. Теория оценивания и описательная статистика	57
Упражнение	57
Ответ	58
Выводы	58
Глава 3. Знакомимся с качественными данными	59
1. Простые статистические таблицы	60
Упражнение	64
Ответ	64
Выводы	64
Глава 4. Нормированное отклонение и рейтинг успеваемости	65
1. Нормирование и нормированное отклонение	66
2. Свойства нормированного отклонения	73
3. Рейтинг успеваемости	74
4. Что такое рейтинг успеваемости?	76
Упражнение	78
Ответ	79
Выводы	80
Глава 5. Вычислим вероятность	81
1. Функция распределения плотности вероятности	82
2. Нормальное распределение	86
3. Стандартное нормальное распределение	89
Пример 1	95
Пример 2	97
4. Распределение хи-квадрат	99

5. Распределение Стьюдента	106
6. Распределение Фишера, или F-распределение	106
7. Распределения и Excel	107
Упражнение	108
Ответ	108
Выводы	109
Глава 6. Что может связывать две переменные	111
1. Коэффициент линейной корреляции	116
2. Коэффициент корреляции между данными разных типов	121
3. Коэффициент корреляции Крамера	127
Упражнение	138
Решение	139
Выводы	142
Глава 7. А что это за проверка гипотезы о независимости?	143
1. Проверка гипотезы	144
2. Проверка гипотезы о независимости	151
Объяснение	152
Упражнение	157
Размышление	158
Вывод	160
3. Нулевая и альтернативная гипотезы	170
4. Р-значение и порядок проверки	175
5. Проверка гипотезы о независимости и гипотезы об однородности	184
Упражнение	184
Решение	185
6. Как выразить словами вывод на основании проверки	187
Упражнение	188
Ответ	188
Выводы	189
Приложение. Попробуем вычислить с помощью Excel	191
1. Построение таблиц распределения	192
2. Вычисление среднего значения, медианы и стандартного отклонения	195
3. Построение простой статистической таблицы	197
4. Вычисление нормированного отклонения и рейтинга успеваемости	199
4.1. Вычисление нормированного отклонения	199
4.2. Вычисление рейтинга успеваемости	203
5. Вычисление вероятности стандартного нормального распределения	204
6. Вычисление значения х при распределении хи-квадрат	205
7. Вычисление коэффициента линейной корреляции	207
8. Проверка гипотезы о независимости	208
Предметный указатель	212

Предисловие

Данная книга — наглядное учебное пособие по статистике, которое, в первую очередь, предназначается тем, кому приходится заниматься анализом различных данных, а также тем, кто пока такой анализ не проводит, но хотел бы знать, что же такое статистика.

Автору также будет весьма приятно, если книга окажется интересной и для тех, кто уже изучал эту дисциплину.

Статистика — одна из областей математики, тесно связанная с жизнью и работой.

Если овладеть всеми премудростями этой науки, то можно, например:

- предусмотреть, сколько коробок жареной лапши будет продано в студенческом киоске, который планируется открыть на университете празднике;
- оценить вероятность успешной сдачи квалификационного экзамена;
- сравнить вероятность выздоровления, если принимать лекарство X и не принимать это лекарство.

Книга содержит 7 глав. За некоторым исключением, главы книги построены следующим образом:

- манга (комикс);
- объяснение, дополняющее мангу;
- упражнения и ответы;
- выводы.

Книга написана так, что читатель может усвоить материал, прочитав только мангу. А вот чтобы получить более глубокие знания, придётся прочитать и всё остальное.

Предел мечтаний автора — читатель, который, перевернув последнюю страницу книги, скажет: «Статистика — это так интересно! Но это ещё и полезно! Да это просто здорово!».

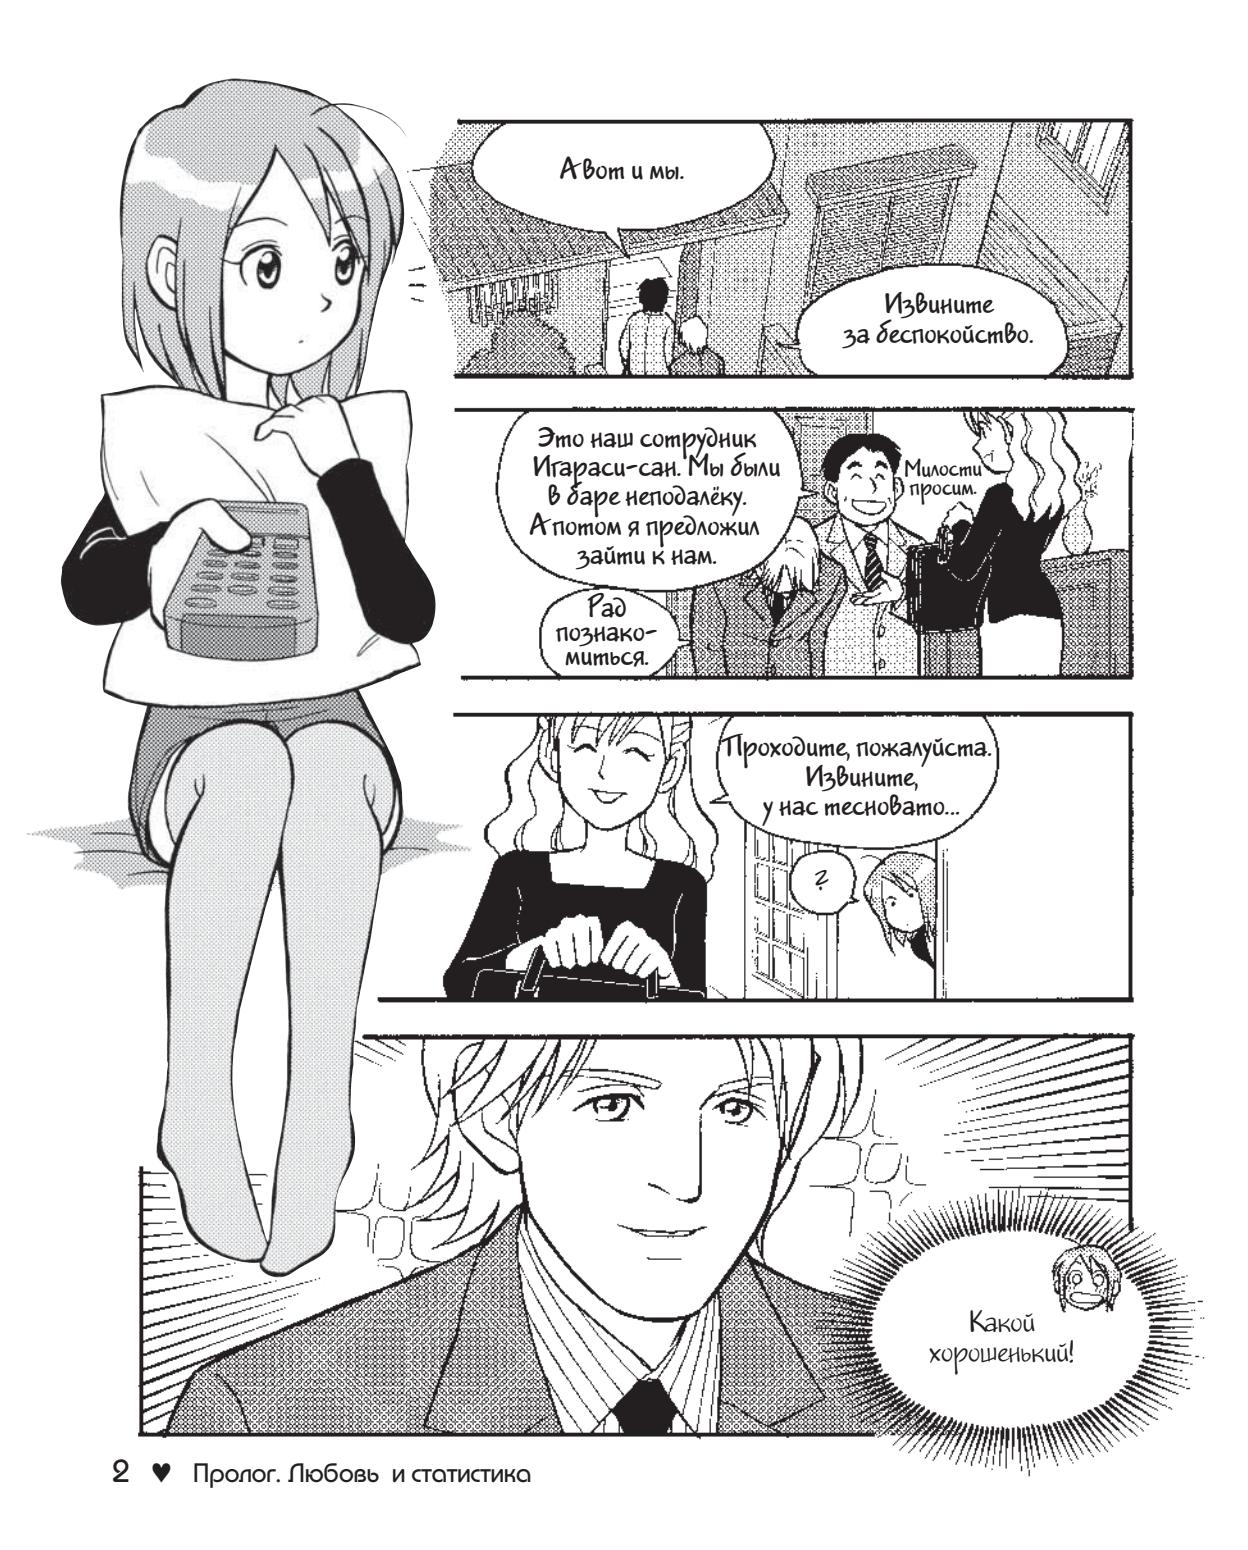
Я бесконечно благодарен всем сотрудникам редакции издательства Ohmsha за предоставленную мне возможность написать эту книгу, а также всем сотрудникам компании Trend-Pro. Я глубоко признателен г-ну Ре Акино, автору сценария, и г-ну Ироха Иноуэ, воплотившему этот сценарий в виде рисунков, за те титанические усилия, которые им пришлось приложить, чтобы на основе моей рукописи создать потрясающий комикс. Я также благодарен г-ну Фумитакэ Сакай (социологический факультет университета Риккё), советами которого я руководствовался во время работы над этой книгой.

Син Такахаси
Июль, 2004 год

Пролог

Любовь

и статистика



А вот и мы.

Извините
за беспокойство.

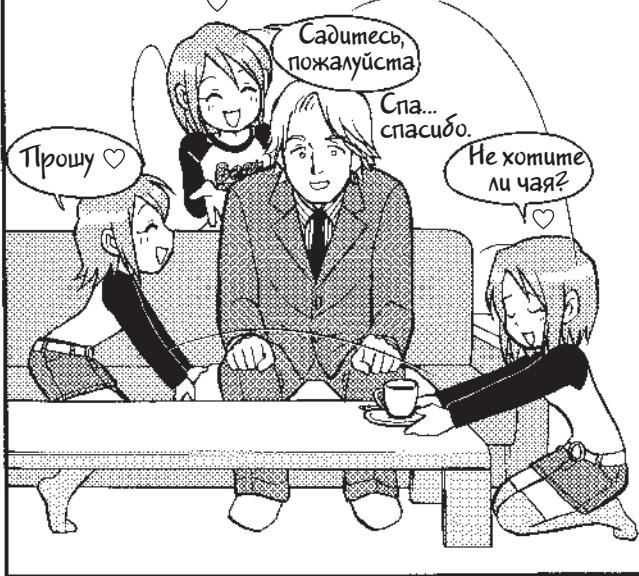
Это наш сотрудник
Игараси-сан. Мы были
в баре неподалёку.
А потом я предложил
зайти к нам.

Рад
познако-
миться.

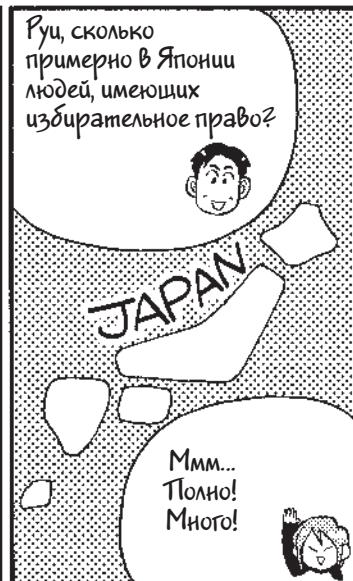
Милости
просим.

Проходите, пожалуйста.
Извините,
у нас тесновато...

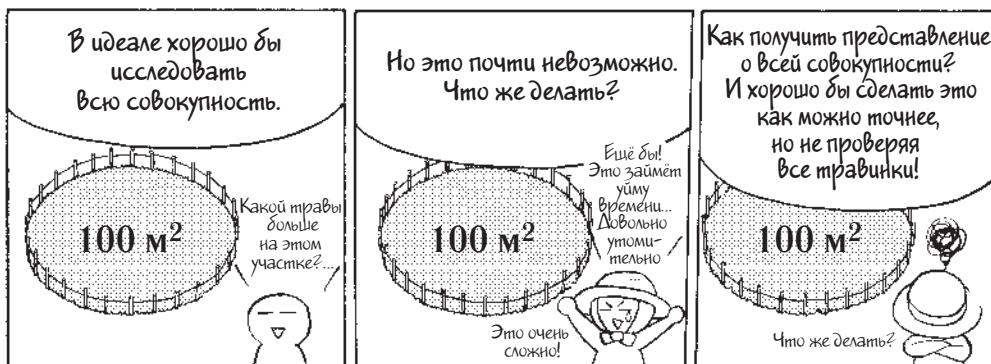
Какой
хорошенький!



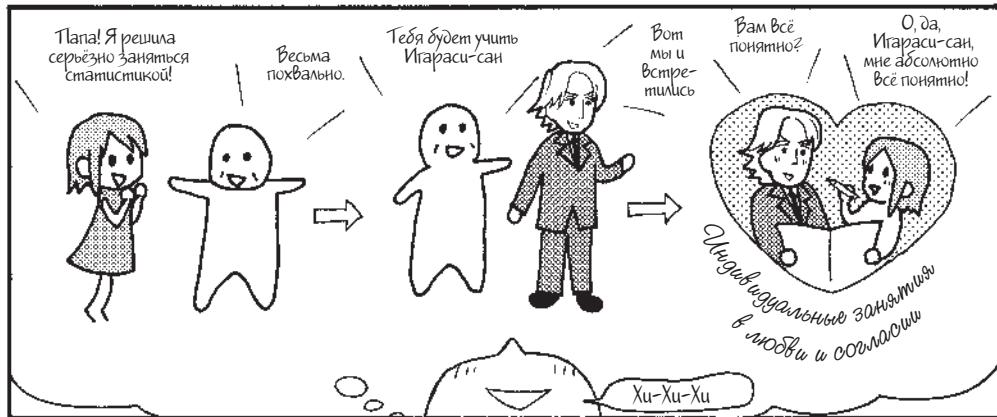
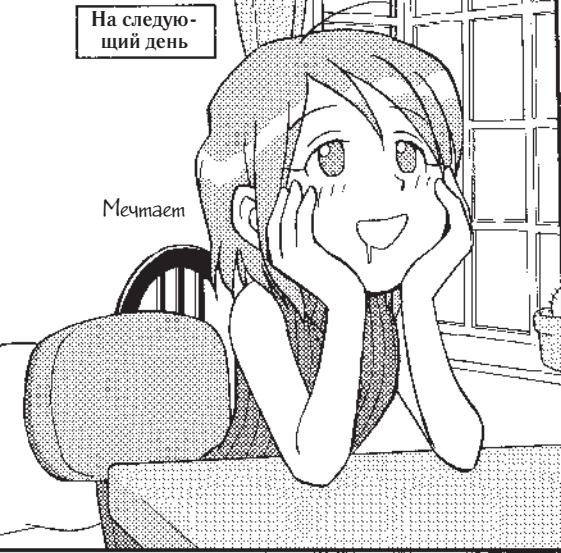


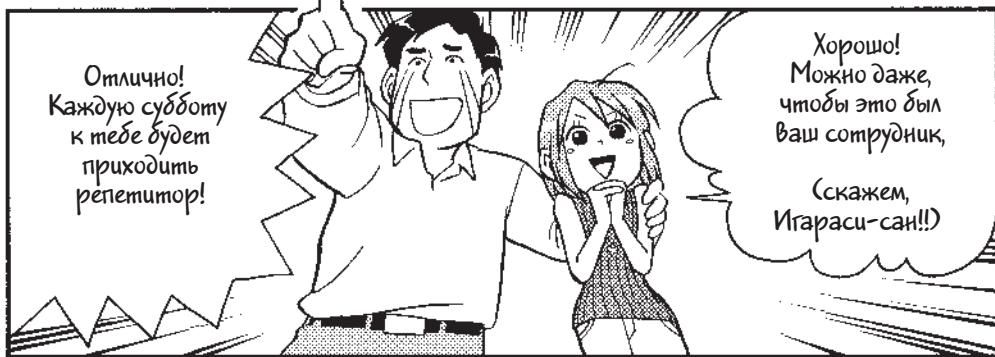


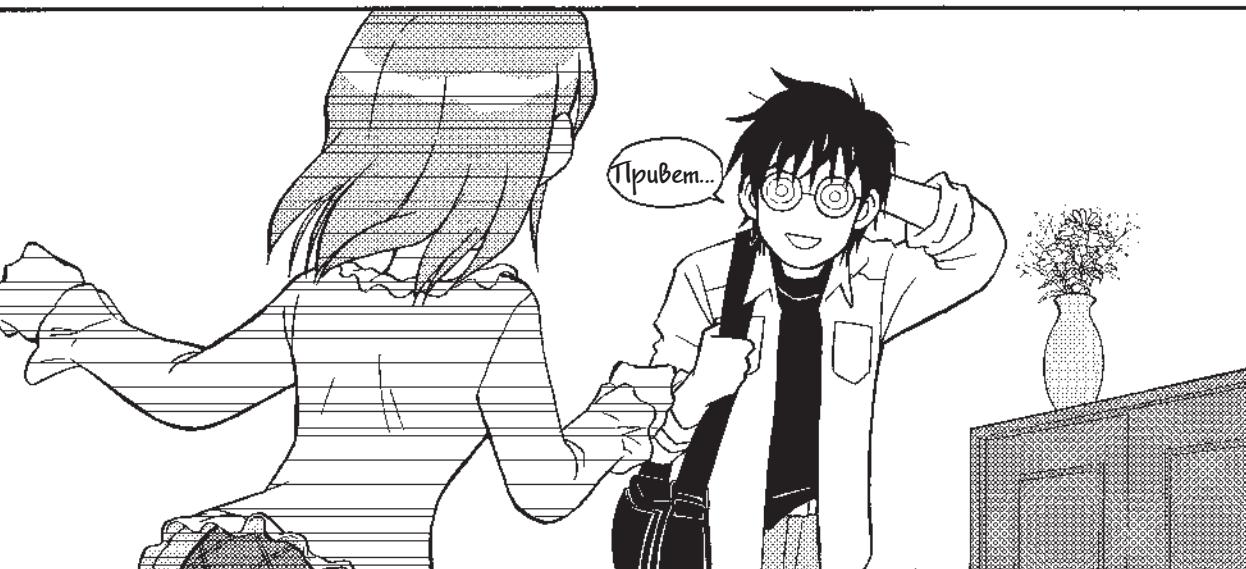
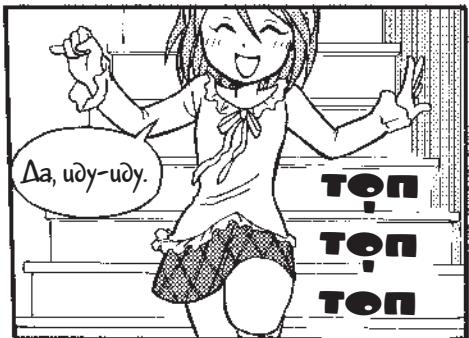


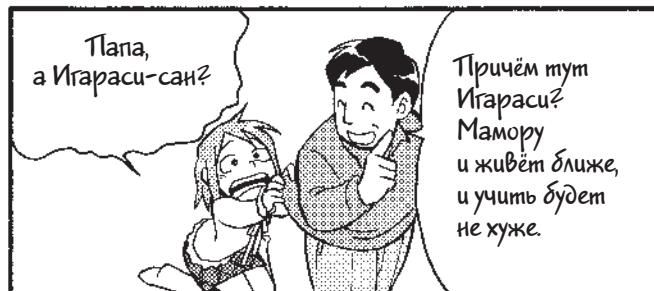


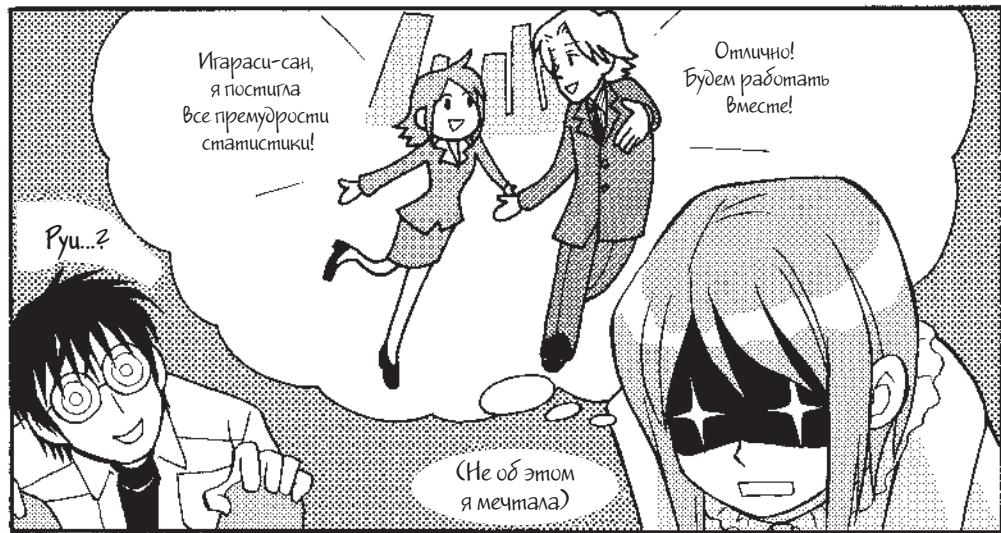
На следую-
щий день







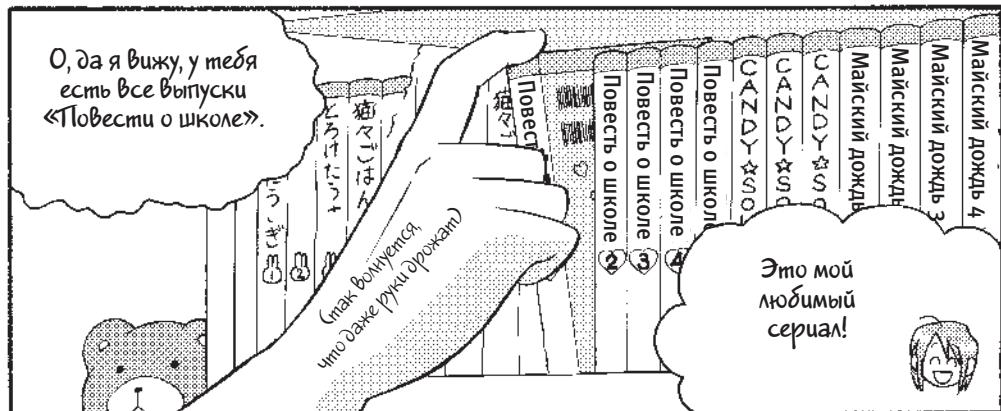
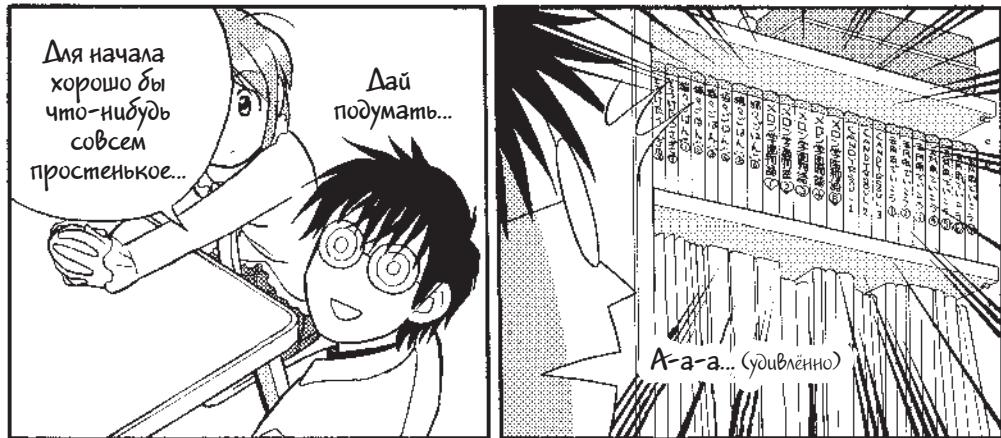
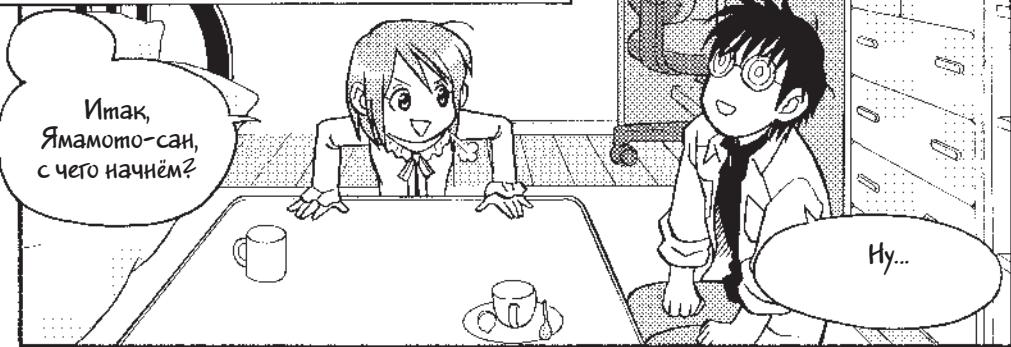


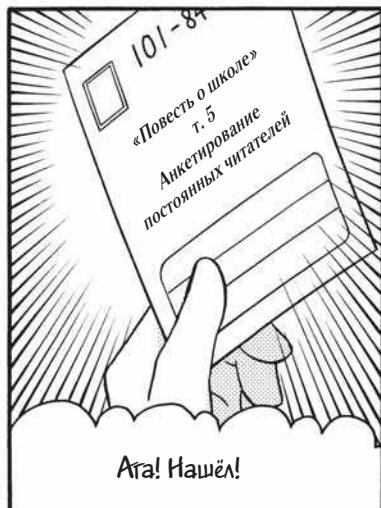


Глava 1

Разберёмся с типами данных

1. Количественные и качественные данные





★ Повесть о школе, т. 5 ★ Анкета постоянных читателей

Вопрос 1. Ваше мнение о 5-м томе «Повести о школе»?

1. Очень интересно
2. Довольно интересно
3. Так себе
4. Скучновато
5. Совершенно неинтересно

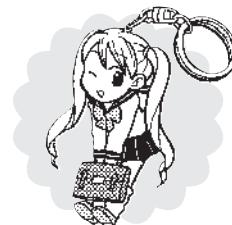
Вопрос 2. Ваш пол?

1. ж 2. м

Вопрос 3. Ваш возраст? ____ лет

Вопрос 4. Сколько выпусков журнала вы приобретаете в месяц? ____ шт

Среди участников
анкетирования
будут разыграны
30 брелоков
«Рина»!

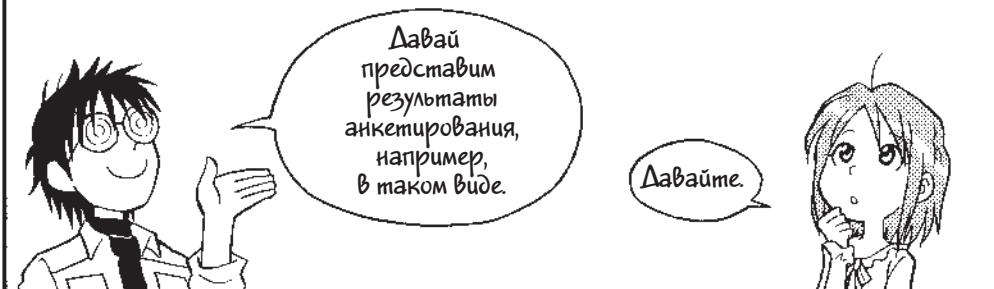


Спасибо за Ваши ответы. Ваше ценнное для нас мнение
мы учтём в последующих изданиях,
а также при разработке будущих проектов.

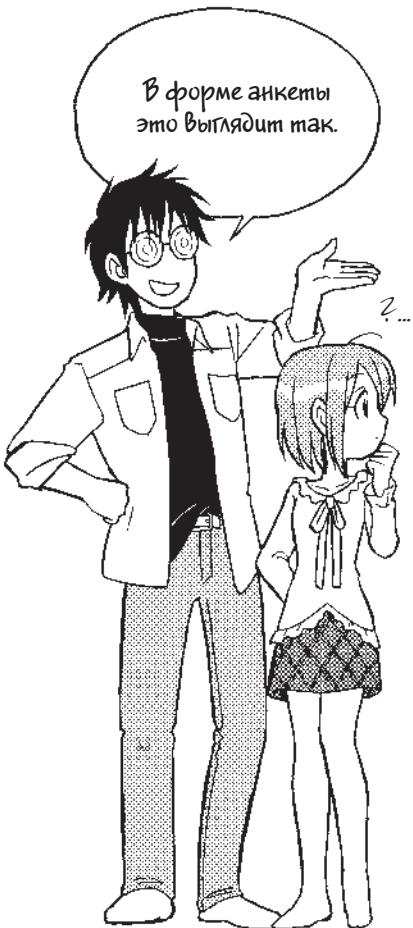


Анкета постоянных читателей

Респондент	Ваше мнение о «Новости о школе»	Пол	Возраст, лет	Кол-во приобретаемых в месяц выпусков, шт.
Ру	очень интересно	м	17	2
А	довольно интересно	м	17	1
Б	так себе	м	18	5
В	скучновато	м	22	7
Г	довольно интересно	м	25	4
Д	совершенно неинтересно	м	20	3
Е	очень интересно	м	16	1
Ж	довольно интересно	м	17	2
З	так себе	м	18	0
И	так себе	м	21	3
⋮	⋮	⋮	⋮	⋮







★ «Повесть о школе», т. 5 ★

Анкета постоянных читателей

Вопрос 1. Ваше мнение о 5-м томе «Повести о школе»?

- 1. Очень интересно
- 2. Довольно интересно
- 3. Так, *качественные данные*
- 4. Совершенно неинтересно

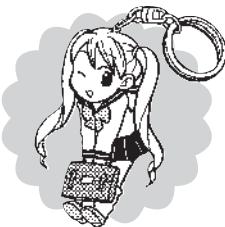
Вопрос 2. Ваш пол?

- 1. Ж.
- 2. М.

Вопрос 3. Ваш возраст? 17 лет

Вопрос 4. *Качественные данные* Журнала «Приобретаете в месяц? 2 шт

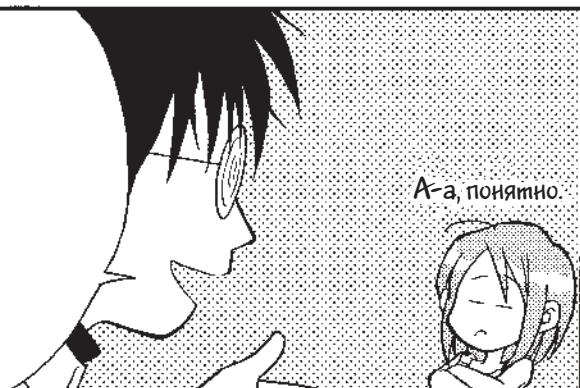
Среди участников
анкетирования
будут разыграны
30 брелоков
«Рина»!



Спасибо за Ваши ответы. Ваше ценное для нас мнение
мы учтём в последующих изданиях,
а также при разработке будущих проектов.

Качественные данные –
это данные, которые
нельзя измерить.

Количественные данные –
данные, которые
можно измерить.



2. Примеры качественных данных

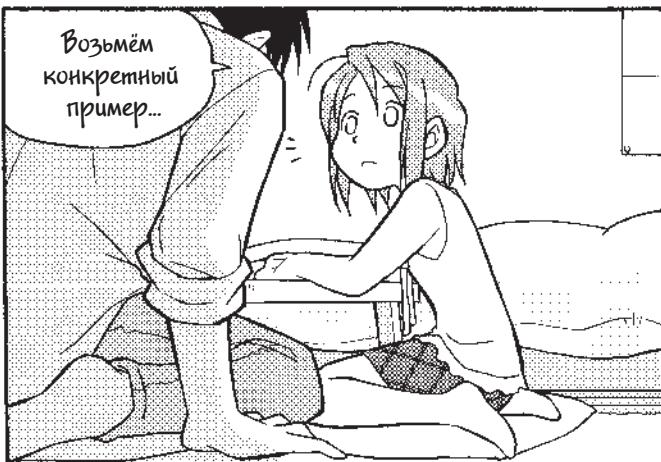
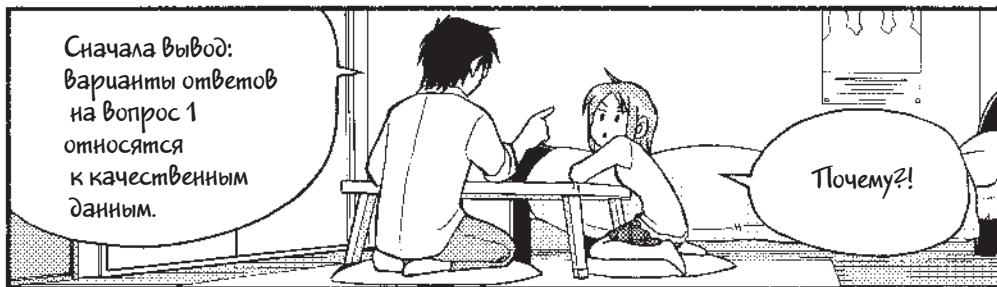


Почему-то мне кажется, что ответы на вопрос 1 не являются количественными данными.

Вопрос 1. Ваше мнение
«Повести о школе».
1. Очень интересно
2. Довольно интересно
3. Так себе
4. Скорее всего
5. Скорее всего нейтресно

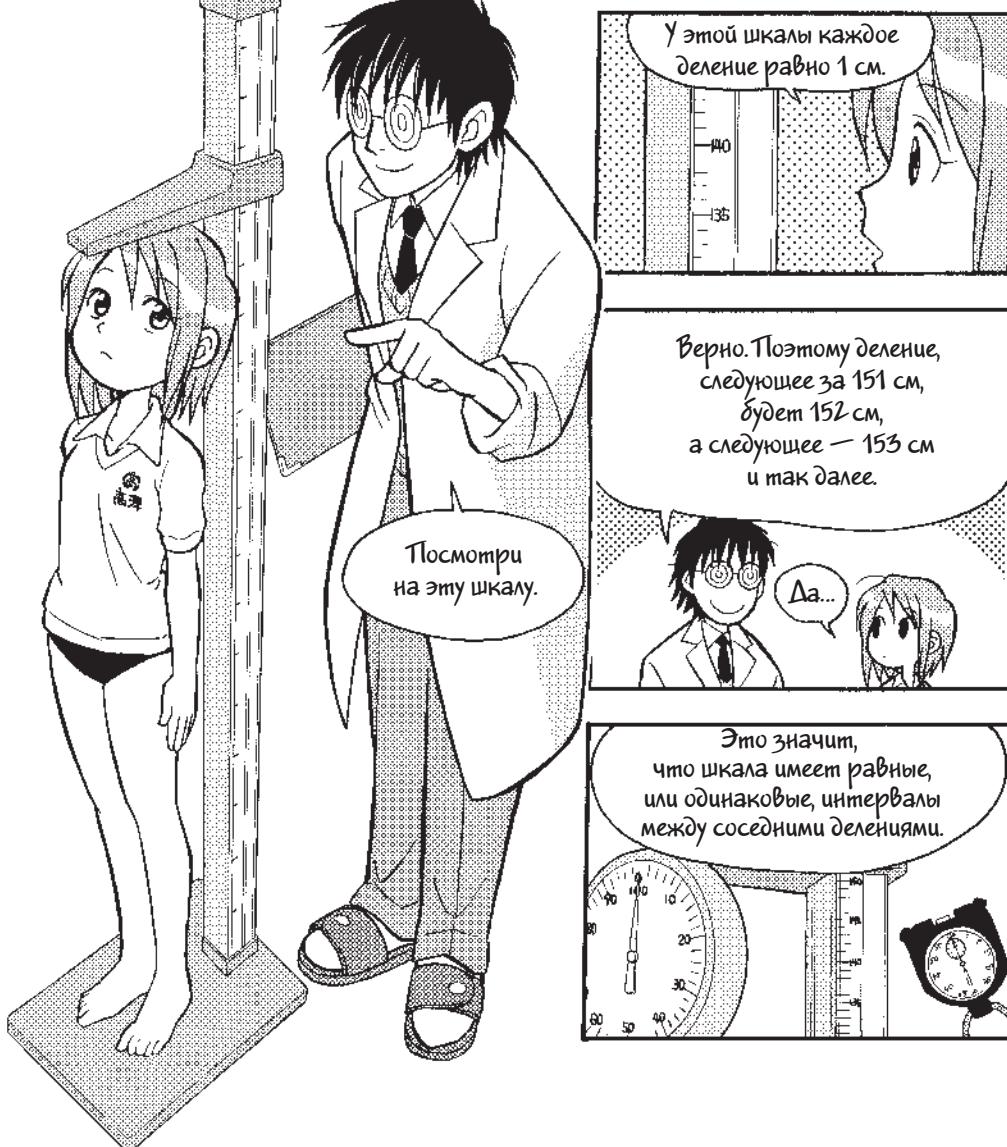
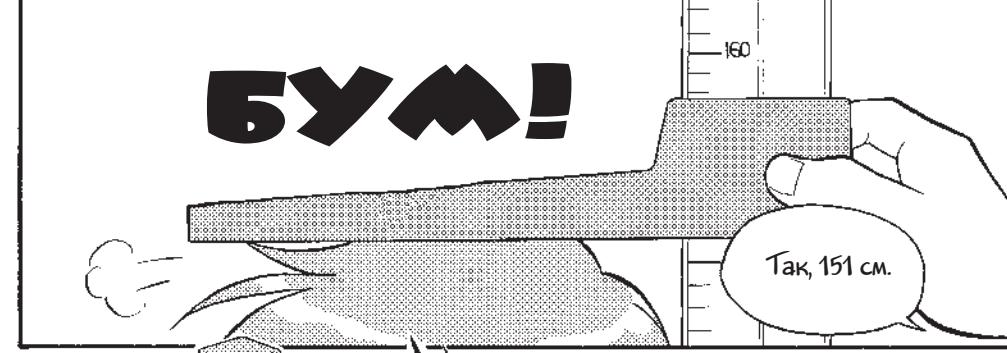


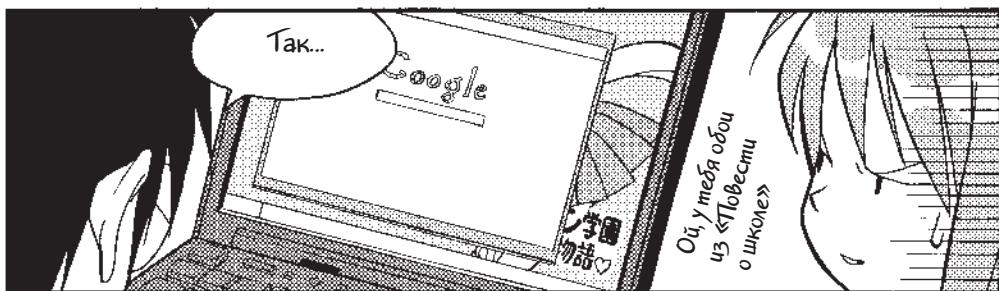
Ах, согласен?!
Тогда, может быть, объясните,
в чём тут дело.





БУМ!



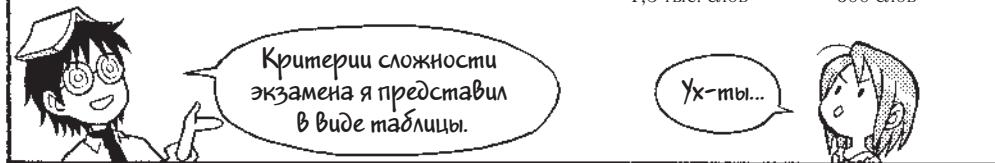




Критерии сложности экзамена Eiken

<http://www.eiken.or.jp/>

1-й уровень	2-й уровень	3-й уровень	4-й уровень	5-й уровень
Продвинутый, соответствует программе вуза; словарный запас примерно 10 – 15 тыс. слов	Соответствует программе средней школы; словарный запас примерно 5,1 тыс. слов	Соответствует программе 3-го года обучения средней школы; словарный запас примерно 2,1 тыс. слов	Средний, соответствует программе 2-го года обучения средней школы; словарный запас примерно 1,3 тыс. слов	Начальный, соответствует программе 1-го года обучения средней школы; словарный запас примерно 600 слов





«Повесть о школе», т. 5
Анкета постоянных читателей

Вопрос 1. Ваше мнение о 5-м томе «Повести о школе»?

1. Очень интересно
2. Довольно интересно
3. Так себе
4. Скучновато
5. Совершенно неинтересно

Вопрос 2. Ваш пол?
1. Женщина
2. Мужчина

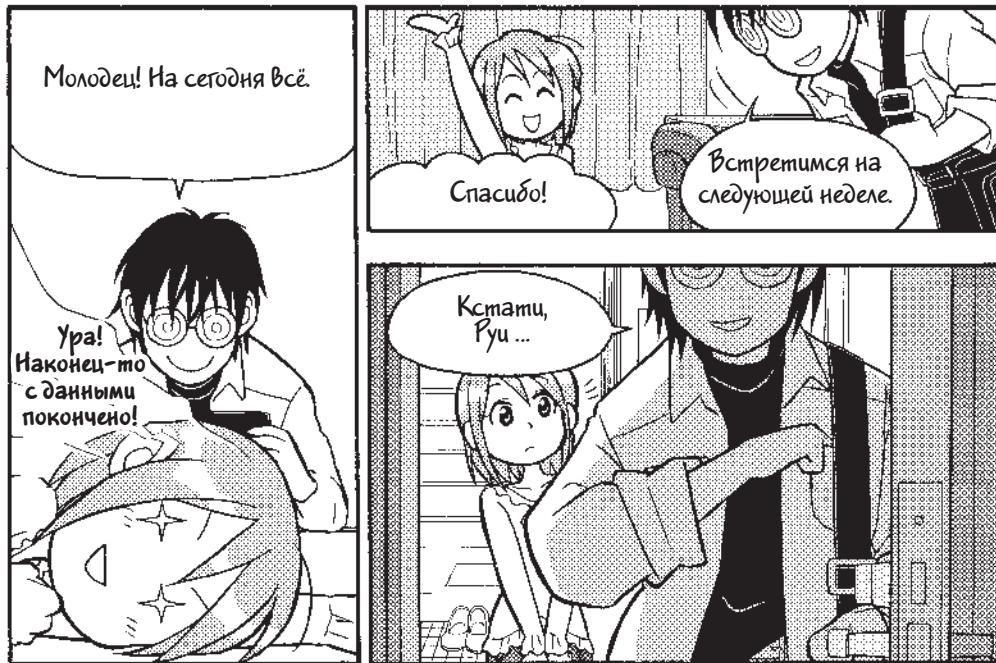
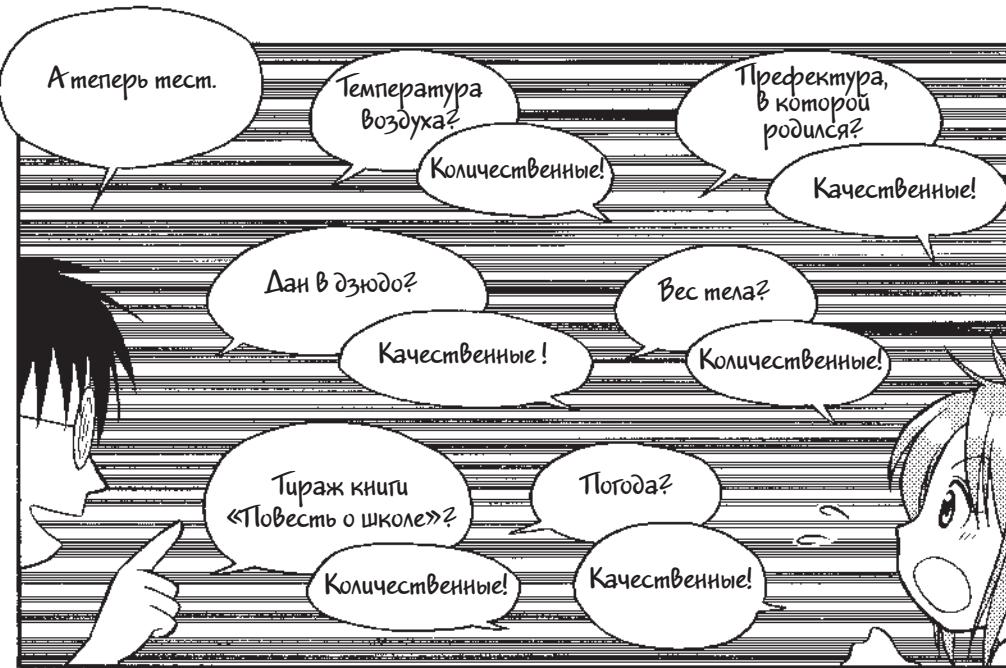
Вопрос 3. Ваш возраст? 17 лет

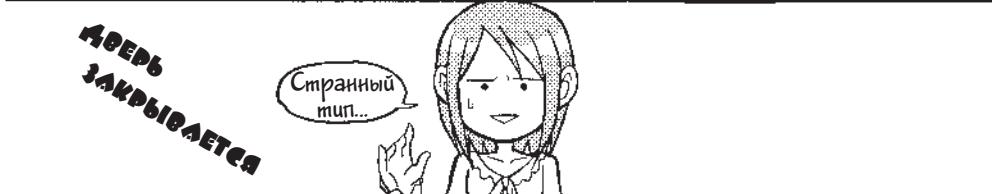
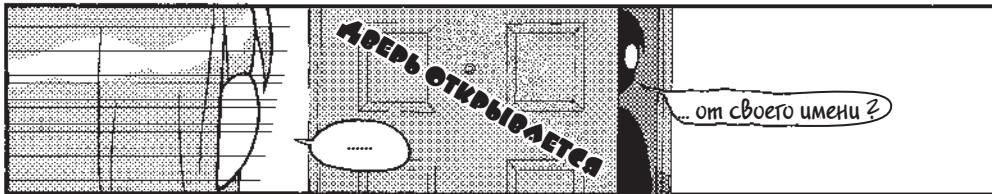
Вопрос 4. Сколько выпусков журнала вы приобретаете в месяц? 2 шт

Среди

Можно сказать, что интервалы между вариантами ответов на вопрос 1 равны?







3. Использование многовариантных ответов на практике

Как было показано, вопрос 1 анкеты постоянных читателей относится к качественным данным. Однако на практике, например при опросе потребителей, эти данные часто рассматриваются как количественные. Другими словами, возможны случаи, когда это может выглядеть так:

	балл
очень интересно	5
довольно интересно	4
так себе	3
скучновато	2
совершенно неинтересно	1

или так:

	балл
очень интересно	2
довольно интересно	1
так себе	0
скучновато	−1
совершенно неинтересно	−2

Существуют мир теории и мир практики, точнее, теоретический мир и реальный. Поэтому одни и те же данные могут рассматриваться и как количественные, и как качественные: всё зависит от того, где они используются — в теории или на практике.

Упражнение

Посмотрите на таблицу:

Респондент	Группа крови	Оценка вкусовых качеств спортивного коктейля X	Комфортная комнатная температура при работающем кондиционере, °C	Лучший результат бега на 100 м, с
А	В (III)	невкусно	25	14,1
Б	А (II)	вкусно	24	12,2
В	AB (IV)	вкусно	25	17,0
Г	O (I)	так себе	27	15,6
Д	A (II)	невкусно	24	18,4
...

Определите, к каким категориям данных относятся графы:

«Группа крови», «Оценка вкусовых качеств спортивного коктейля X»,
«Комфортная комнатная температура при работающем кондиционере»
и «Лучший результат бега на 100 м».

Ответ

«Группа крови» и «Оценка вкусовых качеств спортивного коктейля X»
относятся к качественным данным.
«Комфортная комнатная температура при работающем кондиционере»
и «Лучший результат бега на 100 м» относятся к количественным данным.

Выводы

Данные делятся на количественные и качественные.
Такие категории данных, как, например «Очень интересно», ...,
«Совершенно неинтересно» с точки зрения теории относятся
к качественным данным. Однако на практике эти же данные могут
рассматриваться и как количественные.

Глава 2

Знакомимся с количественными данными

1. Ряды распределения и гистограммы



** Рамэн — китайская лапша, блюдо ресторанов быстрого питания.





*Цены на рамэн в 50 лучших ресторанах
(от журнала «Вкусный рамэн. 50 лучших ресторанов»)*

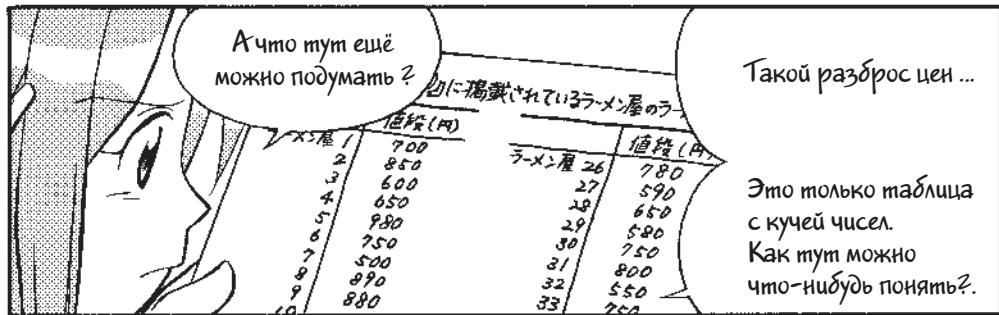
Ресторан	Цена, деньги	Ресторан	Цена, деньги
1	700	26	780
2	850	27	590
3	600	28	650
4	650	29	580
5	980	30	750
6	750	31	800
7	500	32	550
8	890	33	750
9	880	34	700
10	700	35	600
11	890	36	800
12	720	37	800
13	680	38	880
14	650	39	790
15	790	40	790
16	670	41	780
17	680	42	600
18	900	43	670
19	880	44	680
20	720	45	650
21	850	46	890
22	700	47	930
23	780	48	650
24	850	49	777
25	750	50	700

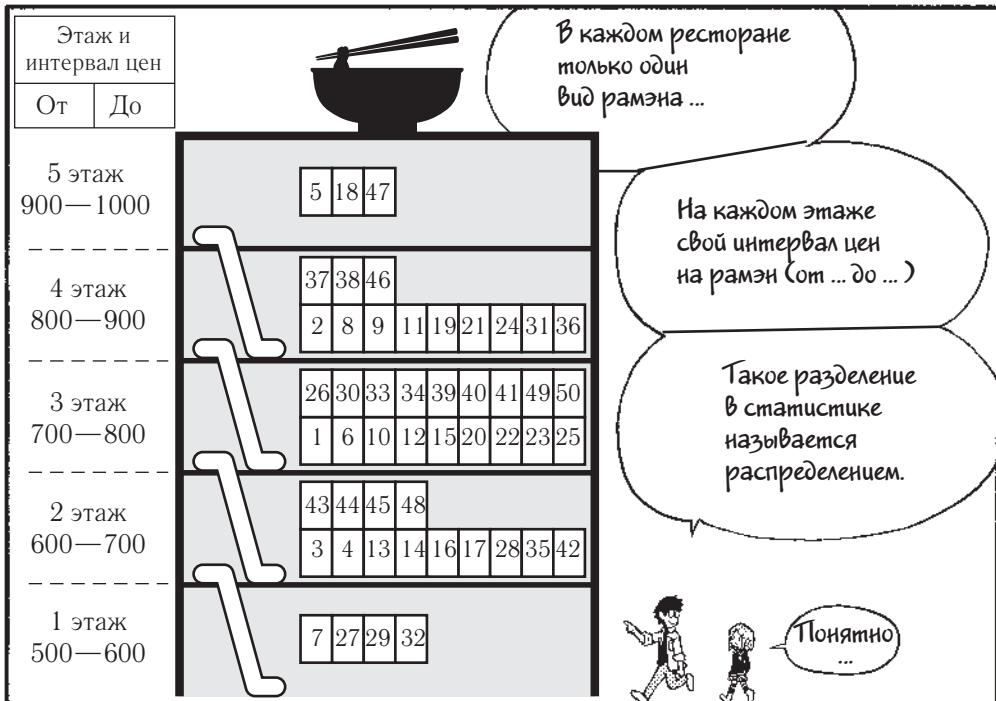
Для начала
я свёл в таблицу
цены на рамэн.



От обсуждения
ресторанов
плавно перешли
к занятию...
Всё-таки
странный тип...





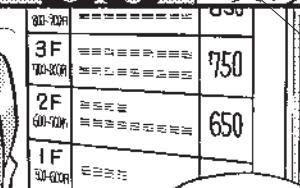




Это называется серединой интервала

(смеется)

Рестораны расположены по этажам в соответствии с ценами на рамэн.
На каждом этаже может быть разное количество ресторанов.



Действительно.

(Ямamoto-сан
в статусе сотрудницы,
сопровождающей
посетителей по этажам)



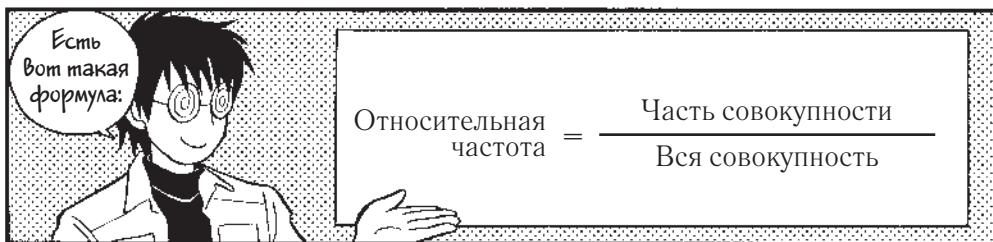
На 1-м этаже — 4,
на 2-ом этаже — 13,
и т.д.

Число ресторанов,
расположенных
на каждом этаже,
называют
частотой.



На 3-м этаже
больше всего
ресторанов —

Теперь вычислим
относительную частоту
ресторанов
на 3-м этаже!



*Распределение по цене
50 лучших ресторанов,
предлагающих вкусный рамэн*

Интервал цен	Середина интервала	Кол-во ресторанов, гостата	Кол-чество ресторанов, относительная гостата
500 ~ 600	550	4	0.08
600 ~ 700	650	13	0.26
700 ~ 800	750	18	0.36
800 ~ 900	850	12	0.24
900 ~ 1000	950	3	0.06
<i>Итого:</i>		50	1.00

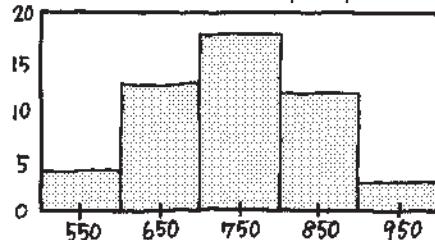


... по горизонтали (на оси x), откладывают переменные.
В нашем случае это будут цены на рамэн.
Ширина столбца равна величине интервала.
В середине столбца ставят значение, равное середине интервала.



Гистограммы построены на основе таблицы распределения 50 лучших ресторанов, предлагающих рамэн

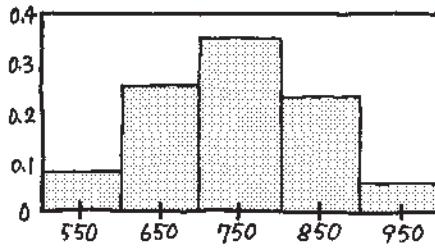
Гистограмма 1.
Частота (количество ресторанов)



По вертикали (оси y) отложены:
на верхнем рисунке — частота,
на нижнем рисунке — относительная частота



Гистограмма 2.
Относительная частота



2. Средняя величина

Мы недавно с девочками из моего класса ходили в боулинг...

Во время перерыва на чай

Удалось сбить хоть одну кеглю?



Что?!
Да я ...

Я очень
хорошо
играю
в боулинг!

74

Если все девочки класса, это довольно много, не так ли?



Да, 18 девочонок.
Поэтому мы
разделились
на три команды
по 6 человек.

Я
попутал.

Смотри,
вот таблица
результатов
игры.

(Быстро достает таблицу)

Команда	Количество кеглей
A	18
B	18
C	18



Результаты игры в боулинг

Команда А		Команда Б		Команда В	
Игрок	Очки	Игрок	Очки	Игрок	Очки
Руч-Руч	86	Томи	84	Синобу	929
Дэйн	78	Хаши	71	Юкии	77
Юми	124	Хана	108	Хитоми	59
Сиэрука	111	Мэй	85	Риоако	95
Моко	90	Канна	90	Май	70
Каэде	38	Асами	89	Козэ	88



Вы сражались командами. Это значит, что вы сражались за итоговый результат, набранный каждой командой. Верно?



Да, и что?

Средний результат равен общему количеству очков, набранному командой, деленному на число игроков в команде.



Команда А

$$\frac{86+73+124+111+90+38}{6} = \frac{522}{6} = 87$$

Команда Б

$$\frac{84+71+103+85+90+89}{6} = \frac{522}{6} = 87$$

Команда В

$$\frac{229+77+59+95+70+88}{6} = \frac{618}{6} = 103$$

Команда В
молодец!!

Значит,
среднее количество
очков в твоей команде,
Руи-Руи, равно 87.

А у тебя
было 86, так?



Так Вы
угостите меня
пирожным?

(злился)





Например,
средней величиной,
о которой я тебе
только что рассказывал.
Кстати, она называется
средней арифметической.

Кроме неё есть ещё
средняя геометрическая
и средняя гармоническая.
Формулы оставим на десерт,
а сами термины тебе придется
запомнить. Хорошо?



3. Медиана



Результаты игры в боуллинг					
Команда А		Команда Б		Команда В	
Игрок	Очки	Игрок	Очки	Игрок	Очки
Рю-Рю	86	Юти	84	Синобу	229
Дзюн	78	Харо	71	Юки	77
Юти	124	Хана	103	Хитоми	59
Сизука	111	Мэй	85	Рисако	95
Моко	90	Канна	90	Май	70
Казза	38	Аями	89	Козэ	88

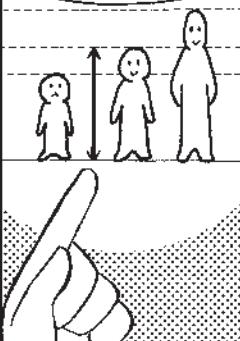
Давай посмотрим на команду В.

Как ты думаешь,

правильно ли считать средним результатом команды В 103 очка?



Медиана — значение, которое приходится на середину ряда, если расположить данные в порядке возрастания (или убывания).



Для начала попробуем расположить в ряд очки, набранные игроками каждой команды.



Команда А

38	73	86	90	111	124
----	----	----	----	-----	-----

Команда Б

71	84	85	89	90	103
----	----	----	----	----	-----

Команда В

59	70	77	88	95	229
----	----	----	----	----	-----

Ряд с нечётным числом элементов

-1041,6	-39,0	-5,7	60,4	77,3
---------	-------	------	------	------

медиана

Ряд с чётным числом элементов

-0,4	35,2	37,8	42,2	46,1	910,3
------	------	------	------	------	-------

Среднее значение этих двух элементов будет медианой

Если ряд состоит из нечётного числа элементов, медианой будет значение, находящееся точно посередине, ...

... а если ряд с чётным числом элементов, как в случае с боулингом, медианой будет среднее значение между 3-м и 4-м элементами.

А теперь попробуем вычислить медиану для команды В.



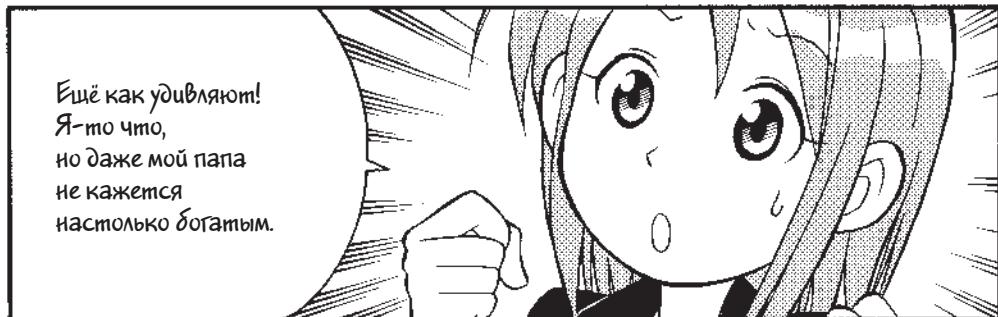
$$\frac{77 + 88}{2} = 82,5$$

Вот что получается.

Правильно!



* Меньше 3500 рублей.





4. Стандартное отклонение

Итак, давай
рассмотрим
результаты ...

... команд
АиБ.

Δαβαў.

Нарисуем шкалу...

Теперь для каждого игрока отмечим значение набранных им очков и напишем его имя.

A hand-drawn diagram of a protractor. The protractor is marked with numbers 0, 50, and 100. An arc is drawn from the 0 mark to the 100 mark. The angle between the 0 line and the arc is labeled '(pucyem)'.

Команда А

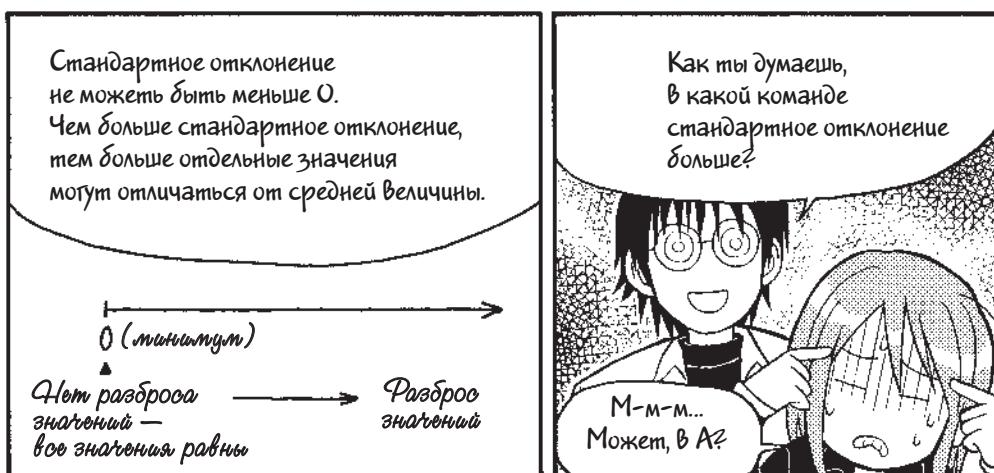
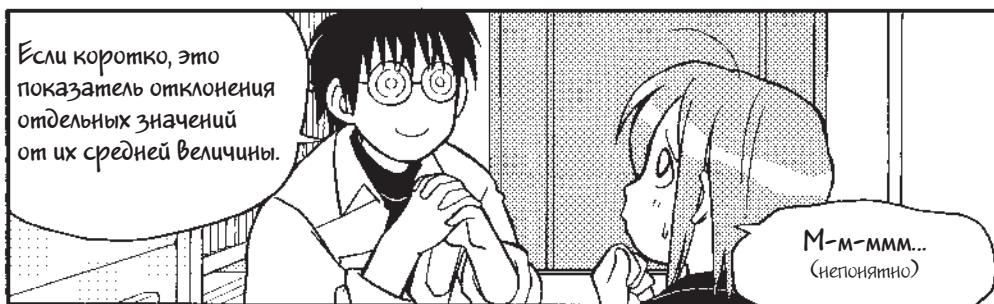
The diagram illustrates the vocal tract in phonation. It shows a horizontal line representing the oral cavity. Vertical dashed lines indicate the position of the lips, teeth, tongue, and palate. The glottis is shown as a narrow opening at the bottom center, with the vocal folds labeled 'Рыльца' (Vocal folds). The oral cavity is labeled 'Оральный канал'. The nasal cavity is labeled 'Носовой канал'. The diagram also includes labels for 'Средняя венерата' (Middle velum) and 'Слизистая оболочка' (Mucous membrane).

Команда Б

Средняя величина

Средняя величина
и для команды А,
и для команды Б
была равна 87,

но ситуация
на рисунке
(линии на шкале)
сильно различается,
верно?



Правильно!
А точная формула
имеет вид

И опять математика...

Стандартное
отклонение =

$$\sqrt{\frac{(i\text{-е значение} - \text{среднее значение})^2}{\text{кол-во значений}}}$$

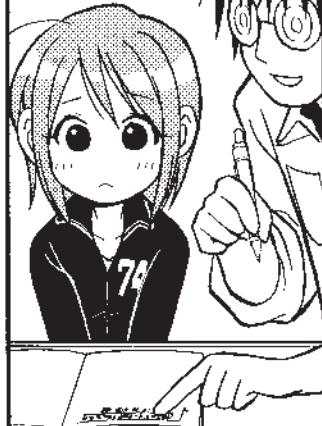
Да не переживай
ты так!
Всего-то и надо —
подставить
в эту формулу
конкретные числа.
Хочешь, попробуем
вместе?

Хочу.

Сначала команда А

Команда А

$$\begin{aligned}& \sqrt{\frac{(86-87)^2 + (73-87)^2 + (124-87)^2 + (111-87)^2 + (90-87)^2 + (38-87)^2}{6}} = \\& = \sqrt{\frac{(-1)^2 + (-14)^2 + 37^2 + 24^2 + 3^2 + (-49)^2}{6}} = \\& = \sqrt{\frac{1 + 196 + 1369 + 576 + 9 + 2401}{6}} = \\& = \sqrt{\frac{4552}{6}} = \\& = \sqrt{758.6\dots} = \\& \approx 27.5\end{aligned}$$



Так-то
наверно
и я смоту.

Тогда попробуй сама
посчитать стандартное
отклонение
для команды Б.





Готово!

Команда Б

$$\sqrt{\frac{(84-87)^2 + (71-87)^2 + (103-87)^2 + (85-87)^2 + (90-87)^2 + (89-87)^2}{6}}$$

$$= \sqrt{\frac{(-3)^2 + (-16)^2 + 16^2 + (-2)^2 + 3^2 + 2^2}{6}} =$$

$$= \sqrt{\frac{9 + 256 + 256 + 4 + 9 + 4}{6}} =$$

$$= \sqrt{\frac{538}{6}} =$$

$$= \sqrt{89,6\dots} =$$

$$\therefore 9,5$$

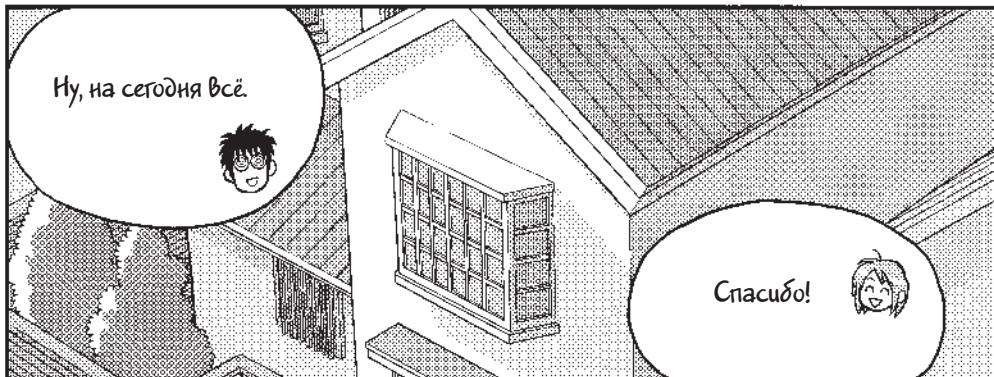
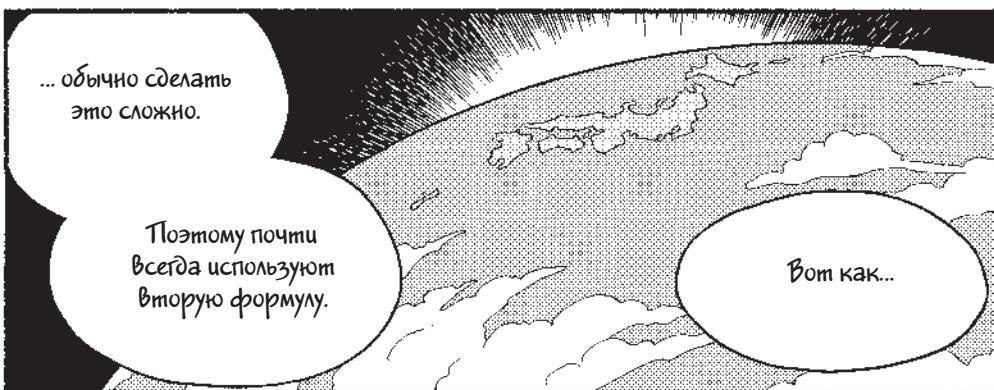
Правильно!
Видишь,
справилась
же!



Стандартное отклонение:
Команда А — 27,5
Команда Б — 9,5

На самом деле у всех игроков команды **Б** похожие результаты. Стандартное отклонение здесь меньше, чем в команде **А**.





5. Ряды распределения и величина интервала

Возможно, не все читатели до конца разобрались с понятиями «ряды распределения» и «гистограммы».

Поэтому автор предлагает еще раз рассмотреть таблицу на **стр. 38.**

Таблица 2.1. Распределение 50 лучших ресторанов, предлагающих вкусный рамэн (по цене на рамэн)

Интервалы цен, юань	Середина интервала	Количество ресторанов, частота	Кол-во ресторанов, относительная частота
500—600	550	4	0,08
600—700	650	13	0,26
700—800	750	18	0,36
800—900	850	12	0,24
900—1000	950	3	0,06
Всего:		50	1,00

Как следует из таблицы, величина интервала равна 100. Это значение не является стандартом в математике. Просто так захотел Ямamoto-сан. Решение о выборе интервала принимает тот, кто анализирует данные.

Не исключено, что среди читателей найдутся и такие, которым не дает покоя вопрос: «Ряды распределения, построенные на основе субъективных решений, неубедительны. Я не смогу показать их другим. Нет ли математического способа определения величины интервала?». Конечно, есть. Покажем, как можно вычислить величину интервала для **Табл. 2.1.**

Шаг 1

Количество интервалов определяется по формуле Стерджесса:

$$\text{Кол-во интервалов} = 1 + \frac{\log_{10} N}{\log_{10} 2},$$

где N — количество значений в совокупности.

$$1 + \frac{\log_{10} 50}{\log_{10} 2} = 1 + 5,6438\dots = 6,6438\dots \approx 7$$

Шаг 2

Величина интервала определяется по формуле:

$$\frac{\text{MAX} - \text{MIN}}{\text{Кол-во интервалов}},$$

где MAX — максимальное значение в совокупности,

MIN — минимальное значение в совокупности.

$$\frac{980 - 500}{7} = \frac{480}{7} = 68,5714\dots \approx 69$$

Ниже приведена таблица распределения 50 лучших ресторанов по цене на рамэн с величиной интервала, рассчитанной по формуле, данной на **Шаге 2**.

Таблица 2.2. Распределение 50 лучших ресторанов, предлагающих вкусный рамэн (по цене на рамэн)

Интервал цен, йены	Середина интервала	Количество ресторанов, частота	Количество ресторанов, относительная частота
500—569	534,5	2	0,04
569—638	603,5	5	0,10
638—707	672,5	15	0,30
707—776	741,5	6	0,12
776—845	810,5	10	0,20
845—914	879,5	10	0,20
914—983	948,5	2	0,04
Итого		50	1,00

Ну и как? Не исключено, что некоторым данная таблица может показаться менее убедительной, чем **Табл. 2.1**.

При этом могут возникнуть такие вопросы, как: «Почему величина интервала равна именно 69 юенам?», «И что это за формула, ну, этого, как его, Стер... ? Да я вообще такого не знаю!» и «Почему интервалы распределены таким непонятным образом?!». Кроме того, среди читателей найдутся и такие, которые не рискнут самостоятельно определить величину интервала.

Случай, когда распределение непонятно, даже если величина интервала определена математическим способом, встречаются довольно часто. И здесь уместно вспомнить то, о чем шла речь в начале этой главы: таблицы (ряды) распределения позволяют систематизировать данные наблюдения и интуитивно понять общую ситуацию. Следовательно, вполне достаточно выбрать такую величину интервалов, которая будет понятна тем, кто проводит статистический анализ.

6. Теория оценивания и описательная статистика

Объясняя Руи, что такое статистика, Игараси-сан определил её как науку, изучающую «большие совокупности однородных объектов на основании их выборочного исследования». Это не совсем так.

В статистике можно выделить два раздела: теорию оценивания и описательную статистику. В прологе речь шла о теории оценивания. Тогда что же такое описательная статистика? Это набор методов по упорядочиванию данных с целью наиболее простого и ясного восприятия этих данных. Можно считать, что описательная статистика рассматривает выборку как генеральную совокупность.

Возможно, такое определение кому-то покажется абстрактным и сложным для понимания. Поэтому приведём пример. Ямамото-сан вычислял среднее значение очков, набранное игроками команды Руи, и стандартное отклонение, чтобы представить положение в команде Руи в наглядном виде. Именно такая статистика и есть описательная.

Упражнение

Результаты забега на 100 метров приведены в следующей таблице:

Участник забега	Результат бега на 100 м, с
А	16,3
Б	22,4
В	18,5
Г	18,7
Д	20,1

Рассчитайте на основании этих результатов

- средний результат,
- медиану,
- отклонение.

Ответ

$$\text{Средний результат} = \frac{16,3 + 22,4 + 18,5 + 18,7 + 20,1}{5} = \frac{96}{5} = 19,2$$

Медиана:

16,3 18,5 18,7 20,1 22,4

Стандартное отклонение =

$$\begin{aligned} &= \sqrt{\frac{(16,3 - 19,2)^2 + (22,4 - 19,2)^2 + (18,5 - 19,2)^2 + (18,7 - 19,2)^2 + (20,1 - 19,2)^2}{5}} = \\ &= \sqrt{\frac{(-2,9)^2 + 3,2^2 + (-0,7)^2 + (-0,5)^2 + 0,9^2}{5}} = \\ &= \sqrt{\frac{20,2}{5}} = \\ &= \sqrt{4,04} = \\ &\approx 2,01 \end{aligned}$$

Выводы

- Чтобы «интуитивно» понять общую ситуацию с данными, строят ряды распределения.
- Величина интервала в рядах распределения определяется по формуле Стерджесса.
- Чтобы «математически» понять ситуацию с данными, вычисляют среднюю величину, медиану и стандартное отклонение.
- Если ряд распределения содержит слишком большие или слишком малые значения, рассчитывают медиану, а не среднюю величину.
- Стандартное отклонение — показатель, отражающий степень разброса (рассеяния) значений.

Глava 3

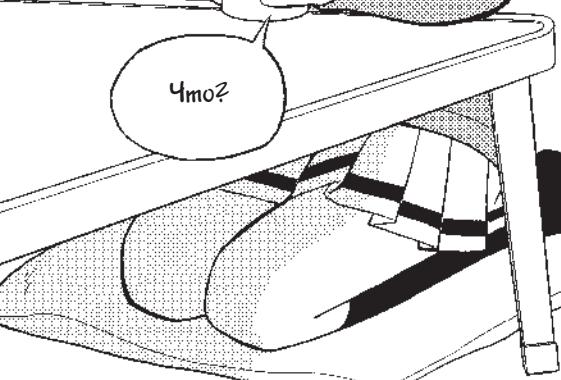
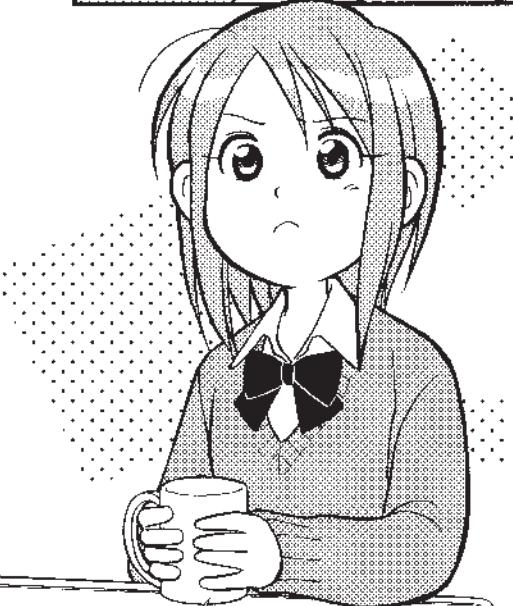
Знакомимся с качественными данными

1. Простые статистические таблицы

Надеюсь, ты помнишь,
что качественные
данные — это данные,
которые нельзя измерить?

Помню,
в общих чертах!

(ставит чашку)





(звук фанфар)
Вот такую!

Матроска
в клетку?...
Необычно.

Поэтому-то,
в нашем классе
было проведено
анкетирование.

Анкета. Нравится ли вам новая форма?

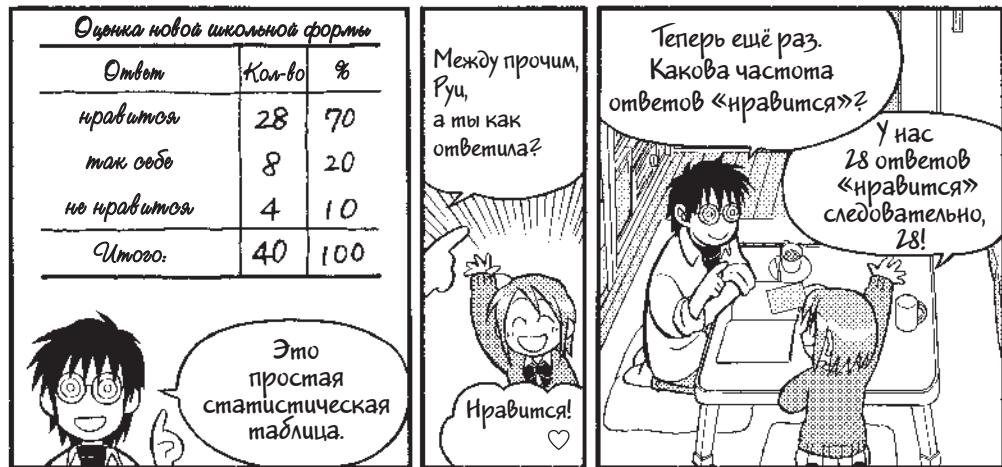
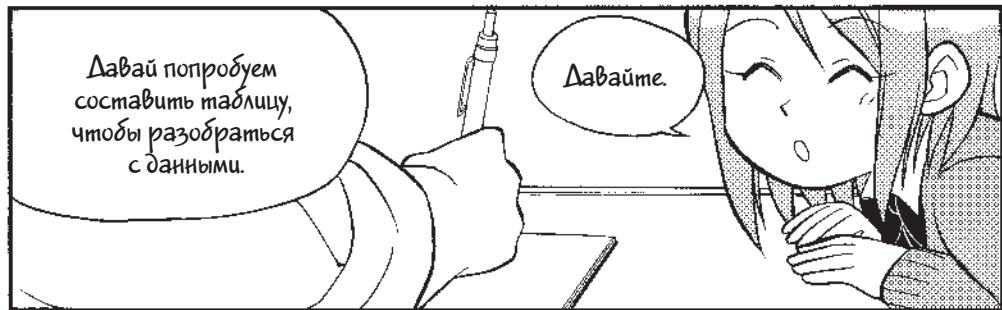
Новая форма...	Новая форма...	Новая форма...
1 нравится	16 так себе	31 так себе
2 так себе	17 нравится	32 так себе
3 нравится	18 нравится	33 нравится
4 так себе	19 нравится	34 не нравится
5 не нравится	20 нравится	35 нравится
6 нравится	21 нравится	36 нравится
7 нравится	22 нравится	37 нравится
8 нравится	23 не нравится	38 нравится
9 нравится	24 так себе	39 так себе
10 нравится	25 нравится	40 нравится
11 нравится	26 нравится	
12 нравится	27 не нравится	
13 так себе	28 нравится	
14 нравится	29 нравится	
15 нравится	30 нравится	

Вот
результаты.



О! Эта анкета —
отличный пример
качественных
данных!

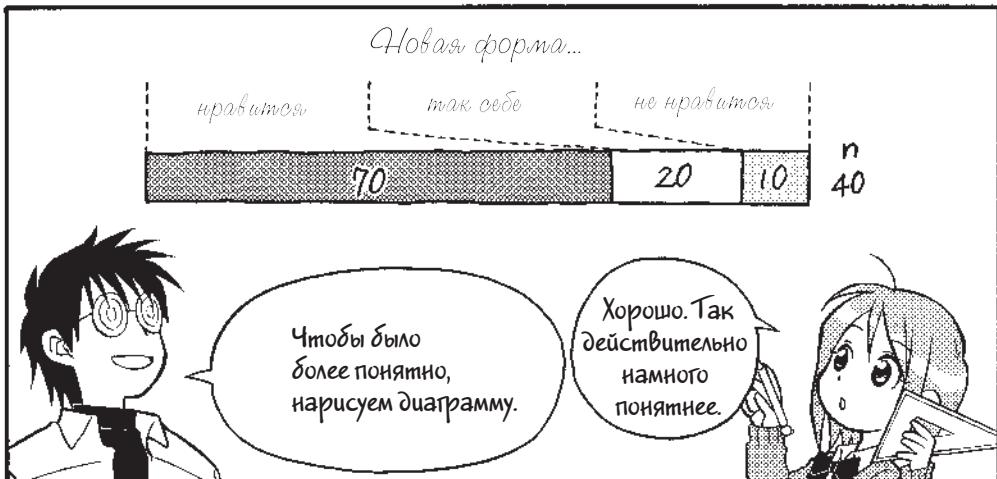
Ответы «нравится»,
«не нравится» —
это же
неизмеряемые данные,
не так ли?



Значит, процентное соотношение будет таким:

$\frac{28}{40} \times 100 = \frac{7}{10} \times 100 = 70 (\%)$

OK!



Упражнение

Одна газета провела анкетирование по вопросу, какая из двух политических партий победит на следующих выборах.

Результаты анкетирования приведены в виде следующей таблицы:

Респондент	Победит партия А или Б
1	победит Б
2	победит Б
3	победит Б
4	не знаю
5	победит А
6	победит Б
7	победит А
8	не знаю
9	победит Б
10	победит Б

Используя результаты анкетирования, постройте простую статистическую таблицу.

Ответ

Простая статистическая таблица выглядит так:

Оценка партии	Частота	%
Победит А	2	20
Не знаю	2	20
Победит Б	6	60
Итого	10	100

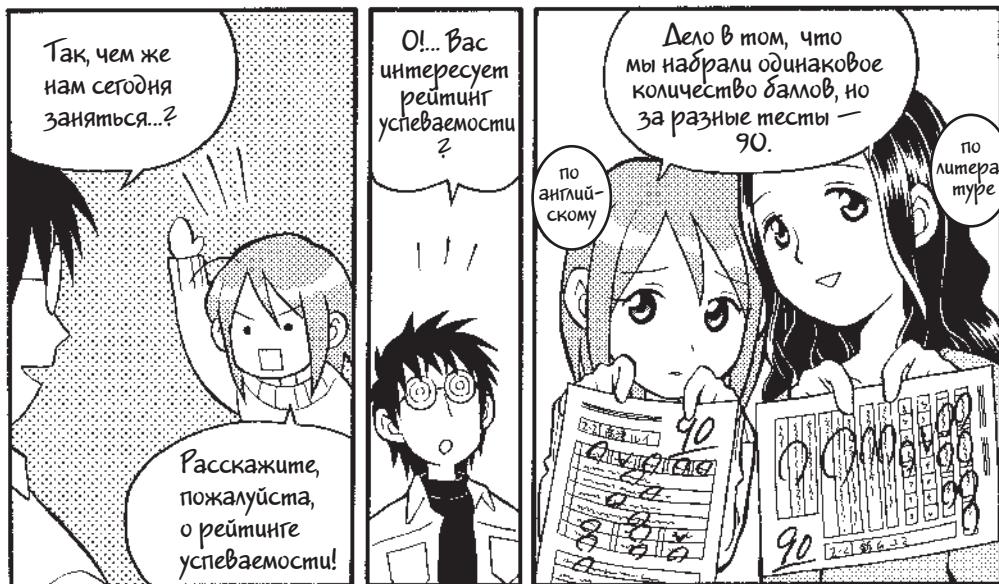
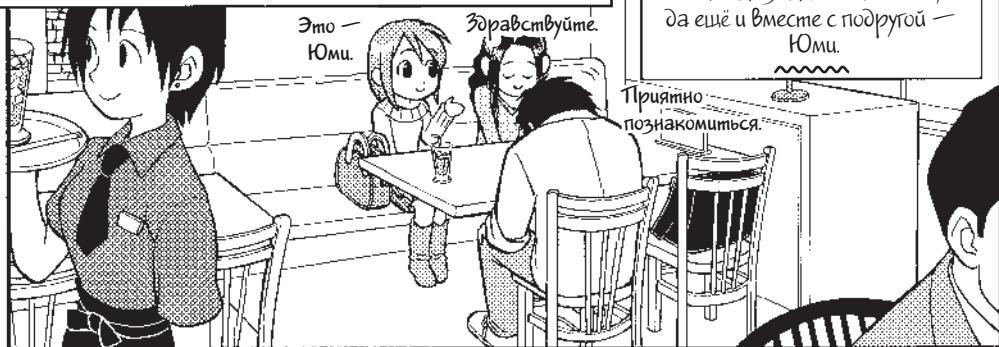
Выводы

- Чтобы понять общую ситуацию с данными, строят простые статистические таблицы.

Глава 4

Нормированное отклонение и рейтинг успеваемости

1. Нормирование и нормированное отклонение



Но почему-то
рейтинг успеваемости
по литературе у Юми выше,
чем у меня по-английскому.

Что это
с ней?

НИЖЕ

Почему?!

ВЫШЕ

Это потому, что
значимости баллов
по английскому языку
и по литературе
отличаются.

Почему?!

Было бы хорошо, если бы мы
знали результаты тестов
и других учеников, но...

Где же
их взять...

Вот они

Юми...

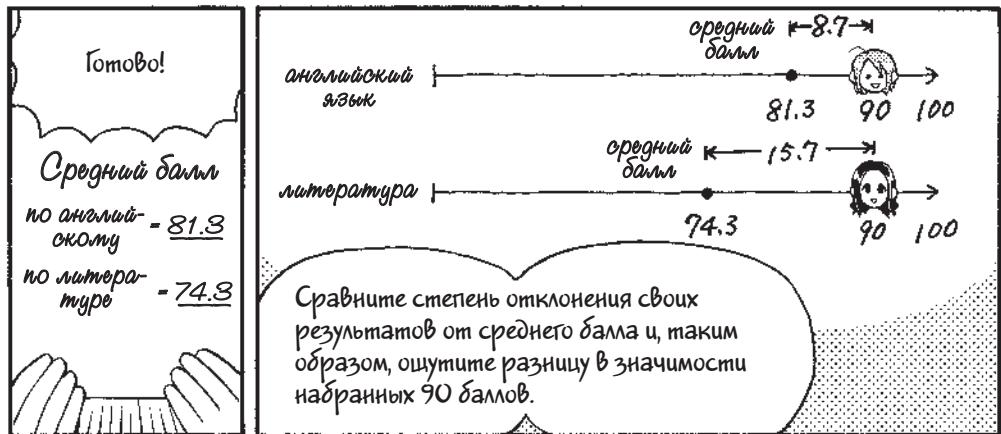
О-о?

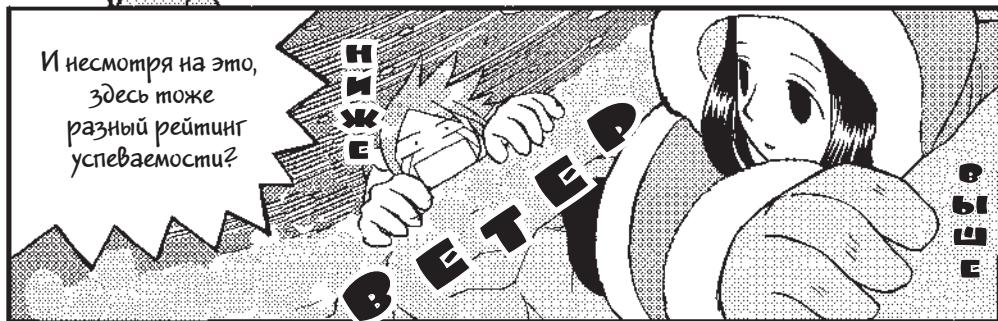
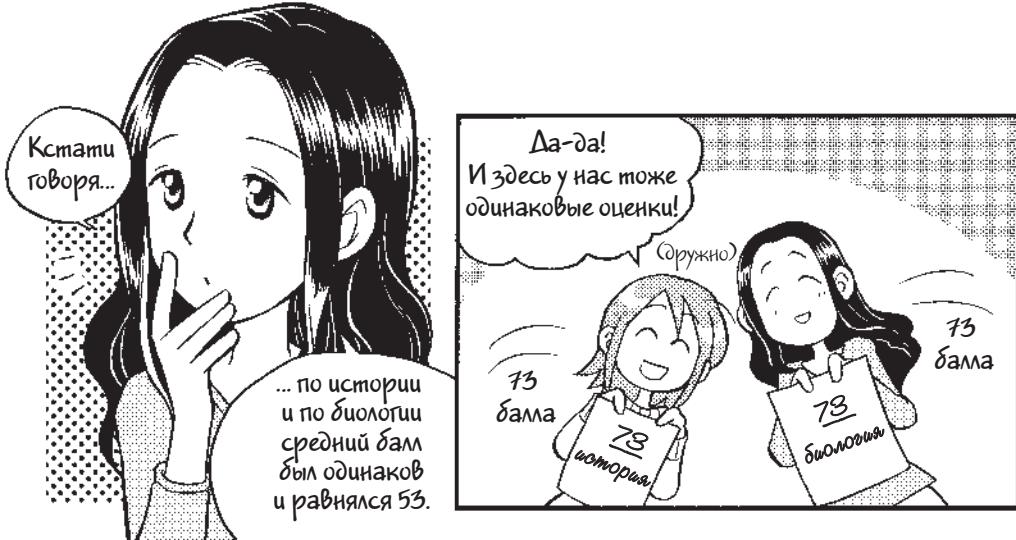
(чуть-чуть
шлет в сумочке)

Результаты тестов (максимальное количество баллов — 100)

Ученик	Английский язык	Литература	Ученик	Английский язык	Литература
Руя	90	71	З	67	85
Юми	81	90	И	87	93
А	73	79	К	78	89
Б	97	70	С	85	78
В	85	67	М	96	74
Г	60	66	Н	77	65
Д	74	60	О	100	78
Е	64	83	А	92	53
Ж	72	57	Ф	86	80

Все ясно





Ученик	История	Биология	Ученик	История	Биология
Ру	73	59	З	7	50
90.ми	61	73	И	53	41
А	14	47	К	100	62
Б	41	38	О	57	44
В	49	63	СМ	45	26
Г	87	56	Н	56	91
Д	69	15	О	34	35
Е	65	53	А	37	53
Ж	36	80	Р	70	68
<i>Средний балл:</i>	<i>53</i>	<i>53</i>			

Хотя отклонение от среднего результата одинаковое.

Угу, понятно.

А как насчёт стандартного отклонения по этим предметам?

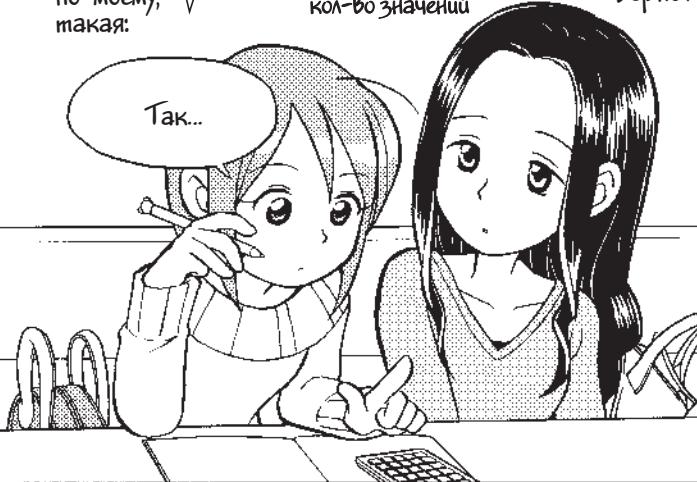
А-а!
Степень разброса значений!

Ну, Ру, ты забыла!

Формула, по-моему, такая:

$$\sqrt{\frac{(x_i - \bar{x})^2}{n}}$$

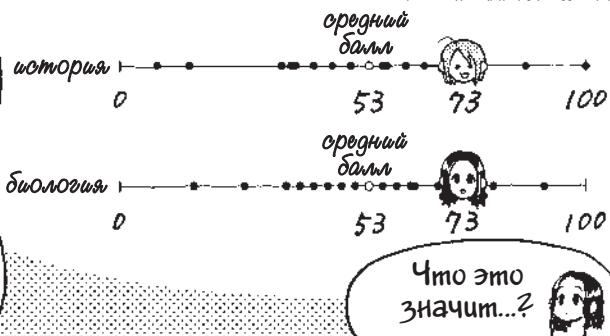
Верно?



Стандартное отклонение равно:
история = 22,7
биология = 18,3

Готово!

Чем меньше стандартное отклонение, тем меньше разброс данных, поэтому получается, что результаты теста по биологии у всех более-менее похожи в отличие от результатов теста по истории.



Если бы я готовился к поступлению в институт, я бы поднял на биологию, так как в тесте по биологии значимость балла выше, чем в тесте по истории.

Какие-то 1–2 балла могут существенно повлиять на конечный результат.





Нормирование проводят так:

$$\text{Нормированное отклонение} = \frac{\text{Значение} - \text{Среднее значение}}{\text{Стандартное отклонение}}$$



Нормированные отклонения образуют совокупность нормированных значений.



Применительно к тестам нормированное отклонение (оно же Z-показатель) имеет другое название — стандартизованный балл.

Согласны!



Результаты тестов по истории и биологии

Ученик	История	Биология
Руслан	73	59
Юлия	61	73
Анна	14	47
Борис	41	38
Василий	49	63
Григорий	87	56
Денис	69	15
Евгений	65	53
Женя	36	80
Зоя	7	50
Илья	53	41
Карина	100	62
Лена	57	44
Мария	45	26
Надежда	56	91
Ольга	34	35
Петр	37	53
Роман	70	68
Средний балл	53	53
Станд. отклонение	22.7	18.3

Нормированные отклонения

История	Биология
0.88	0.33
0.35	1.09
-1.71	-0.33
-0.53	-0.82
-0.18	0.55
1.49	0.16
0.70	-2.08
0.53	0
-0.75	1.48
-2.02	-0.16
0	-0.66
2.07	0.49
0.18	-0.49
-0.35	-1.48
0.13	2.08
-0.84	-0.98
-0.70	0
0.75	0.82
0	0
1	1

Нормированное отклонение
Руслан по истории

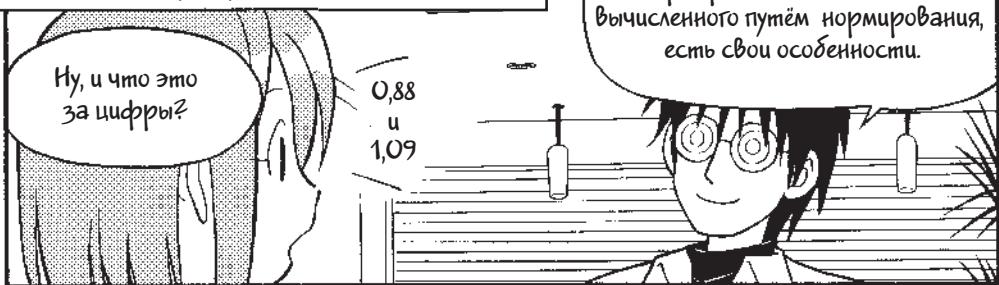
$$= \frac{78 - 53}{22.7} - \frac{20}{22.7} = 0.88$$

Да, так.

Нормированное отклонение
Юлия по биологии

$$= \frac{78 - 53}{18.3} - \frac{20}{18.3} = 1.09$$

2. Свойства нормированного отклонения



1. Независимо от максимального количества баллов, среднее значение нормированного отклонения (Z -показателя) всегда равно 0, а стандартное отклонение нормированных отклонений всегда равно 1.

2. В чём бы ни измерялась переменная, среднее значение её нормированных отклонений всегда равно 0, а стандартное отклонение нормированных отклонений всегда равно 1.

Можно сравнивать результаты тестов с максимальным количеством баллов, равным 100 и 200.

Можно также сравнивать количество ударов по воротам или угловых в футболе.

Нормированное отклонение позволяет понять значимость 73 баллов в тестах по истории и биологии

Вы опять об этом...
(плачут)

3. Рейтинг успеваемости

Рейтинг успеваемости (он же Т-показатель) рассчитывается на основе нормированного отклонения.

О-ооо...
(удивляется)

Формула такая:

Рейтинг успеваемости = Т-показатель =
= Нормированное отклонение $\times 10 + 50$

И правда,
используется
значение
нормированного
отклонения.

Попытаемся
вычислить
рейтинг
успеваемости
в ваших тестах.

Руи
(история) $0.88 \times 10 + 50 = 8.8 + 50 = 58.8$

Юрия
(биология) $1.09 \times 10 + 50 = 10.9 + 50 = 60.9$

Да-да,
такие цифры и были.

Нормированное
отклонение
имеет такие
свойства:

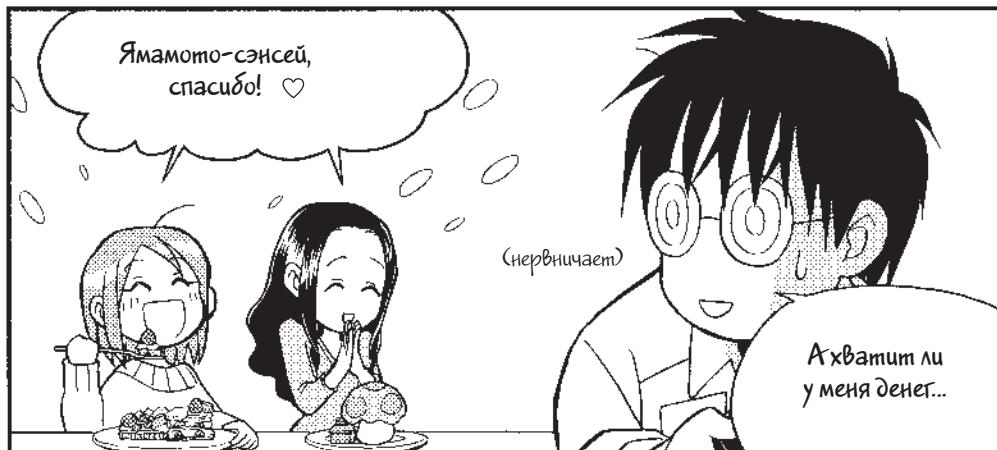


Нормированное отклонение (Z-показатель):

1. Независимо от максимального количества баллов, среднее значение нормированного отклонения (Z-показателя) всегда = 0, а стандартное отклонение нормированных отклонений всегда = 1.
2. В чём бы ни измерялась переменная, среднее значение её нормированных отклонений всегда = 0, а стандартное отклонение нормированных отклонений всегда = 1.

Рейтинг успеваемости (Т-показатель):

1. Независимо от максимального количества баллов, среднее значение рейтинга успеваемости (Т-показателей) всегда = 50, а квадратичное отклонение рейтингов успеваемости всегда = 10.
2. В чём бы не измерялась переменная, среднее значение рейтинга успеваемости всегда = 50, а стандартное отклонение рейтингов успеваемости всегда = 10.



4. Что такое рейтинг успеваемости?

В общем случае это Т-показатель, который вычисляется по формуле:

$$\begin{aligned} \text{T-показатель} &= \text{Нормальное отклонение} \times 10 + 50 = \\ &= \frac{\text{Значение} - \text{Среднее значение}}{\text{Стандартное отклонение}} \times 10 + 50. \end{aligned}$$

В классе Руи 40 учеников, и из них 18 девочек. Рейтинги успеваемости были приведены только для двух девочек. Если объектом исследования были бы все ученики класса, среднее значение и стандартное отклонение были бы совсем другими, и, естественно, рейтинги успеваемости Руи и Юми тоже были бы другими. Если бы рассчитывались рейтинги успеваемости всех учеников класса, показатель Руи был бы выше.

Результаты теста всех учеников представлены в Табл. 4.1. Обязательно попробуйте вычислить рейтинги успеваемости. Забегая вперёд, скажу что у Руи по истории он равен 59,1, а у Юми по биологии он равен 56,7.

Теперь представим, что одинаковые тесты проводились в двух классах. Сначала вычислили отдельно средний балл и стандартное отклонение для учеников 1-го класса, и затем на их основе рассчитали рейтинг успеваемости. То же проделали и для 2-го класса. Показатель успеваемости ученика А из 1-го класса был равен 57, и рейтинг успеваемости ученика Б из 2-го класса тоже был равен 57. На первый взгляд кажется, что у них одинаковые знания. Однако, такие необходимые для расчёта рейтинга успеваемости данные, как средний балл и стандартное отклонение, в 1-м и 2-м классах были разными. Следовательно, нельзя сравнивать рейтинги успеваемости этих двух учеников.

И еще один пример. Ученик **А** в апреле сдавал пробный экзамен на подготовительных курсах. Его рейтинг успеваемости был равен 54. Все лето **А** продолжал заниматься на других курсах. А в сентябре, чтобы убедиться, что его труды не пропали даром, он решил сдать еще один пробный экзамен, но уже на других курсах. На этот раз рейтинг успеваемости был 62. На первый взгляд кажется, что знания **А** улучшились. Но он сдавал пробные экзамены на разных курсах, и, следовательно, организаторы проведения экзамена в апреле и в сентябре были разные. Это, в свою очередь, означает, что средний результат и стандартное отклонение, т.е. показатели, необходимые для вычисления рейтинга успеваемости, в апреле и сентябре были разные, и, следовательно, нельзя сравнивать два значения рейтинга успеваемости **А**.

Ну как? Понятие показатель успеваемости довольно-таки сложное.

Таблица 4.1. Результаты теста по истории и биологии
(всех учеников класса Руи)

Девочка	История	Биология	Мальчик	История	Биология
Руи	73	59	а	54	2
Юми	61	73	б	93	7
А	14	47	в	91	98
Б	41	38	г	37	85
В	49	63	д	44	100
Г	87	56	е	16	29
Д	69	15	ж	12	57
Е	65	53	з	44	37
Ж	36	80	и	4	95
З	7	50	к	17	39
И	53	41	л	66	70
К	100	62	м	53	14
Л	57	44	н	14	97
М	45	26	о	73	39
Н	56	91	п	6	75
О	34	35	р	22	80
П	37	53	с	69	77
Р	70	68	т	95	14
			у	16	24
			ф	37	91
			х	14	36
			ц	88	76

Средний балл по всему классу	48,0	54,9
Стандартное отклонение по всему классу	27,5	26,9

Упражнение

В упражнении на стр. 57 приведены результаты бега на 100 метров.

Участник	Результат бега на 100 м, с
А	16,3
Б	22,4
В	18,5
Г	18,7
Д	20,1
Среднее значение	19,2
Стандартное отклонение	2,01

Проверьте с помощью этой таблицы:

1. Равно ли 0 среднее значение нормированных отклонений.
2. Равно ли 1 стандартное отклонение нормированных отклонений.

Ответ

1. Среднее значение нормированных отклонений =

$$\begin{aligned}
 &= \frac{\left(\frac{16,3 - 19,2}{2,01}\right) + \left(\frac{22,4 - 19,2}{2,01}\right) + \left(\frac{18,5 - 19,2}{2,01}\right) + \left(\frac{18,7 - 19,2}{2,01}\right) + \left(\frac{20,1 - 19,2}{2,01}\right)}{5} = \\
 &= \frac{\left\{ (16,3 - 19,2) + (22,4 - 19,2) + (18,5 - 19,2) + (18,7 - 19,2) + (20,1 - 19,2) \right\}}{2,01} = \text{упорядочили числитель} \\
 &= \frac{\left\{ 16,3 + 22,4 + 18,5 + 18,7 + 20,1 - 19,2 - 19,2 - 19,2 - 19,2 - 19,2 \right\}}{2,01} = \\
 &= \frac{\left\{ \frac{96 - 19,2 \times 5}{2,01} \right\}}{5} = \text{отдельно индивидуальные значения,} \\
 &\quad \text{отдельно средние значения } (-19,2). \\
 &= \frac{\left\{ \frac{96 - 96}{2,01} \right\}}{5} = \\
 &= \frac{0}{5} = \\
 &= 0
 \end{aligned}$$

2. Стандартное отклонение нормированных отклонений =

$$\begin{aligned}
 &= \sqrt{\frac{\left(\frac{16,3 - 19,2}{2,01} - 0\right)^2 + \left(\frac{22,4 - 19,2}{2,01} - 0\right)^2 + \left(\frac{18,5 - 19,2}{2,01} - 0\right)^2 + \left(\frac{18,7 - 19,2}{2,01} - 0\right)^2 + \left(\frac{20,1 - 19,2}{2,01} - 0\right)^2}{5}} = \\
 &= \sqrt{\frac{\left(\frac{16,3 - 19,2}{2,01}\right)^2 + \left(\frac{22,4 - 19,2}{2,01}\right)^2 + \left(\frac{18,5 - 19,2}{2,01}\right)^2 + \left(\frac{18,7 - 19,2}{2,01}\right)^2 + \left(\frac{20,1 - 19,2}{2,01}\right)^2}{5}} = \\
 &= \sqrt{\frac{\left\{ (16,3 - 19,2)^2 + (22,4 - 19,2)^2 + (18,5 - 19,2)^2 + (18,7 - 19,2)^2 + (20,1 - 19,2)^2 \right\}}{2,01^2}} = \text{упорядочили числитель} \\
 &= \sqrt{\frac{1}{2,01^2} \times \frac{(16,3 - 19,2)^2 + (22,4 - 19,2)^2 + (18,5 - 19,2)^2 + (18,7 - 19,2)^2 + (20,1 - 19,2)^2}{5}} = \\
 &= \frac{1}{2,01} \times \sqrt{\frac{(16,3 - 19,2)^2 + (22,4 - 19,2)^2 + (18,5 - 19,2)^2 + (18,7 - 19,2)^2 + (20,1 - 19,2)^2}{5}} = \\
 &= \frac{1}{Стандартное\ отклонение} \times Стандартное\ отклонение = \\
 &= 1
 \end{aligned}$$

Внимательно посмотрите на таблицу на стр. 78.

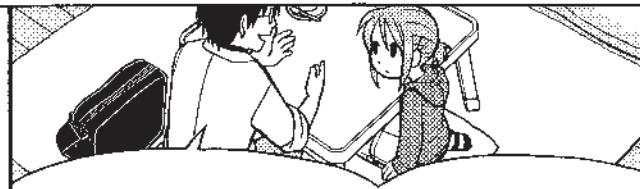
Выводы

- Нормирование (нормировка, стандартизация, нормализация), или Z-преобразование, — преобразование значений, проводимое на основе данных о степени разброса (рассеяния) и отклонения от среднего значения. Нормирование позволяет оценить значимость значений.
- Нормирование позволяет сравнивать различные переменные величины, например:
 - величины, имеющие разный размах (разность между максимальным и минимальным значениями);
 - величины, имеющие разные единицы измерения.
- Нормированные данные — нормированные отклонения отдельных значений.
- Рейтинг успеваемости рассчитывается по формуле Т-показателя на основе нормированного отклонения.

Глаза 5

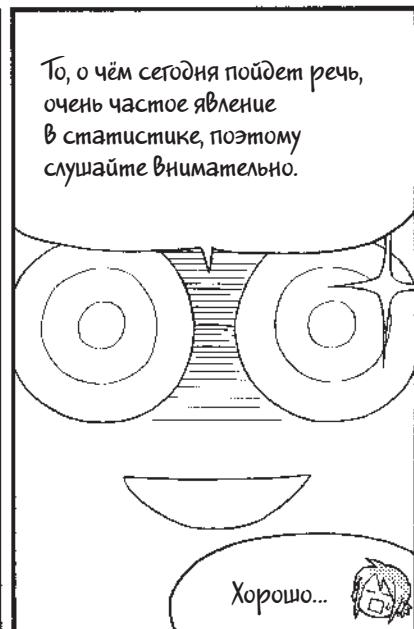
Вычислим вероятность

1. Функция распределения плотности вероятности



В статистике иногда говорят:
«вероятность чего-то меньше 0,05»

Сегодня я расскажу,
что нужно знать,
чтобы вычислить
вероятность чего-либо.



Результаты теста по аналитическому языку всех одиннадцатиклассников школ Центрального округа

Представим,
что все ученики
11-х классов
Центрального
округа ...

Ученик	Балл
1	42
2	91
...	:
10421	50
<i>Средний балл</i>	53
<i>Стандартное отклонение</i>	10

... сдавали экзамен
на подготовительных
курсах.

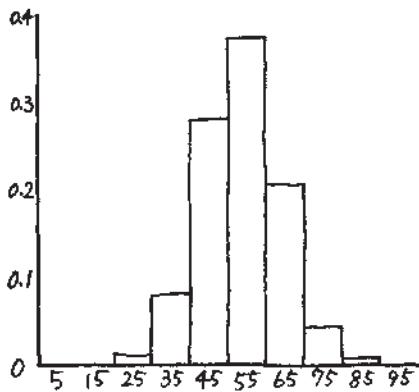
Вы сегодня
очень хорошо
подготовлены.

Ха-Ха-Ха.
Мы только
начали.

(перевернул
страницу)

Если эту таблицу
представить
в виде гистограммы,
то получим ...

*Гистограмма
«Результаты теста по аналитическому языку».
Величина интервала равна 10.*



О-о-о...
Действительно,
если нарисовать
гистограмму, можно
что-то
понять.

Потому что
наглядно.

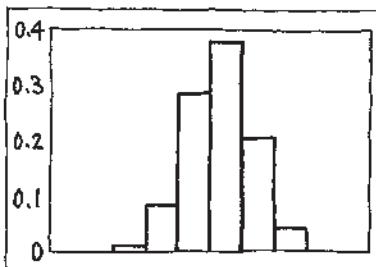
Что произойдет,
если на этой гистограмме
уменьшить величину
интервала?



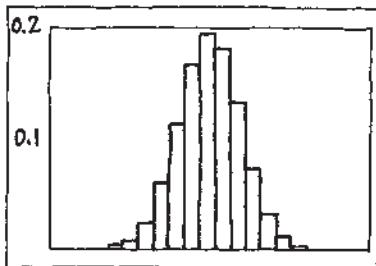
Ямато-сан
ученица

*Величина интервала и гистограмма
«Результаты теста по английскому языку»*

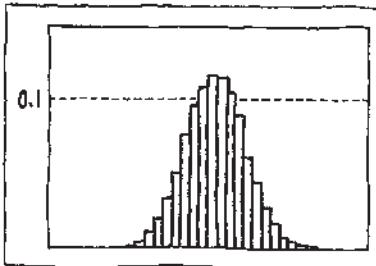
Величина интервала равна 10



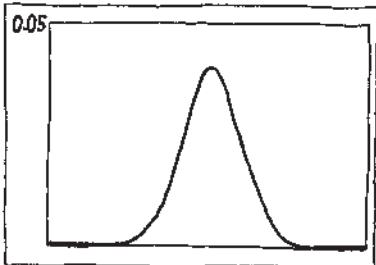
Величина интервала равна 5



Величина интервала равна 3

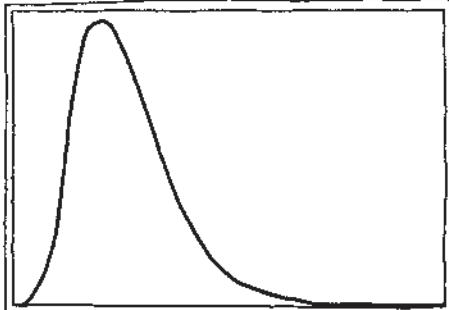
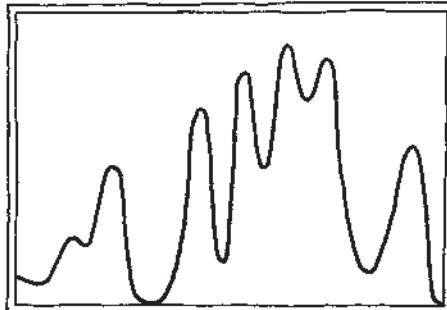


Кривая распределения



Если величина интервала на гистограмме стремится к нулю, то получается кривая распределения ...

... а функция, описываемая этой кривой, в статистике называется функцией распределения вероятностей.



Известно достаточно много форм кривых распределения.

Сегодня я расскажу о тех, которые используются наиболее часто.



Хорошо!

2. Нормальное распределение

$$f(x) = \frac{1}{\sqrt{2\pi} \times \text{Стандартное отклонение}} e^{-\frac{1}{2} \left(\frac{x - \bar{x}}{\text{Стандартное отклонение}} \right)^2}$$

где \bar{x} — средняя величина x (средняя арифметическая ряда)

Вот.

Что это ?!!



Это — часто встречающаяся в статистике функция распределения вероятности.

А что это за знак « e »?

Символ « e » — математическая константа, основание натурального логарифма; его иногда называют числом Эйлера или числом Непера.
 $e = 2,7182$.

ОСНОВАНИЕ



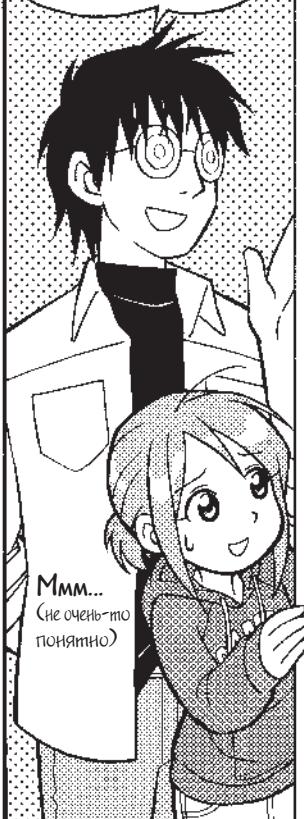
Можешь думать, что это как число π

Ну, тогда ладно...

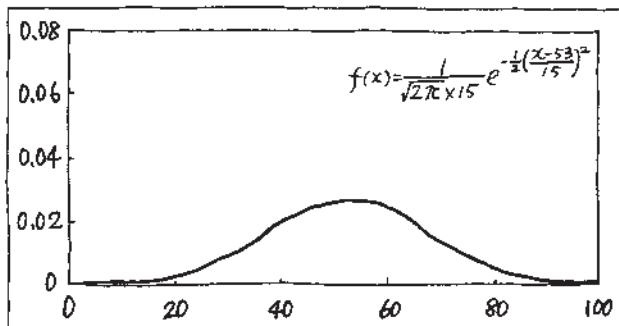
Фы...

График функции распределения вероятности имеет следующие свойства:

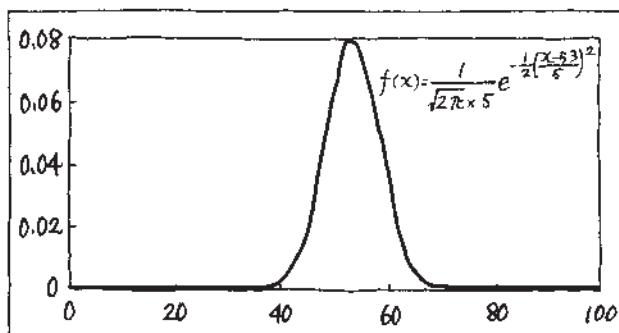
1. Кривая симметрична относительно центра распределения, который находится в точке, соответствующей среднему значению.
2. Функция зависит от среднего значения и от стандартного отклонения.



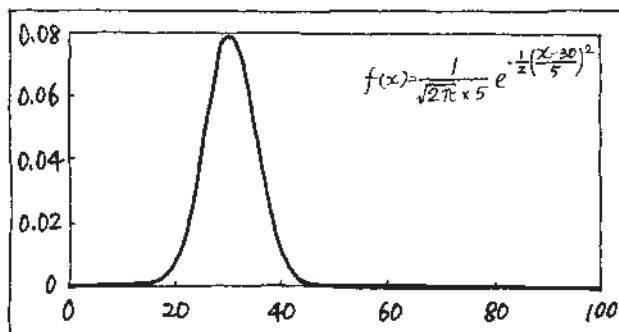
Среднее значение = 53, станд. отклонение = 15



Среднее значение = 53, станд. отклонение = 5



Среднее значение = 30, станд. отклонение = 5

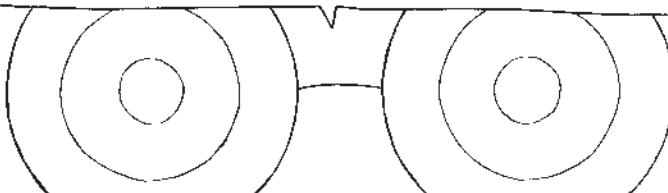


Послушай, существует правило, согласно которому ...

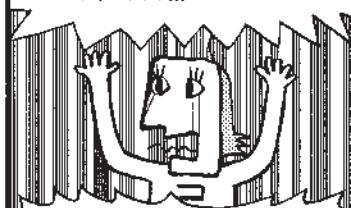


... распределение величины x при определенных значениях средней арифметической ряду (или среднего значения, \bar{x}) и стандартного отклонения называют нормальным распределением, если плотность распределения вероятностей выражается формулой

$$f(x) = \frac{1}{\sqrt{2\pi} \times \text{Ст.откл.}} e^{-\frac{1}{2} \left(\frac{x - \bar{x}}{\text{Ст.откл.}} \right)^2}$$



Чего ???!!! ~~~~~



... называют нормальным распределением... !?

Ничего не понимаю...

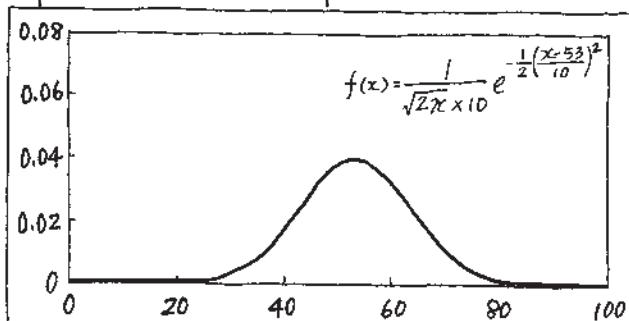


Правило довольно специфическое, поэтому просто запомни его.

Возьмём для примера предыдущий тест. Если кривая функции распределения вероятностей результатов теста по английскому имеет следующий вид...



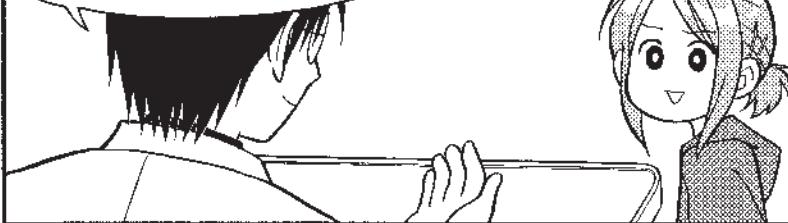
... то имеет место нормальное распределение при среднем балле 53 и стандартном отклонении 10.



Значит, результаты теста по английскому со средним баллом = 53 и стандартным отклонением = 10 распределяются по закону нормального распределения (или по нормальному закону).

А-а-а...
(поняла)

Вот как...



3. Стандартное нормальное распределение

Но это ещё не всё ...

А что же ещё?

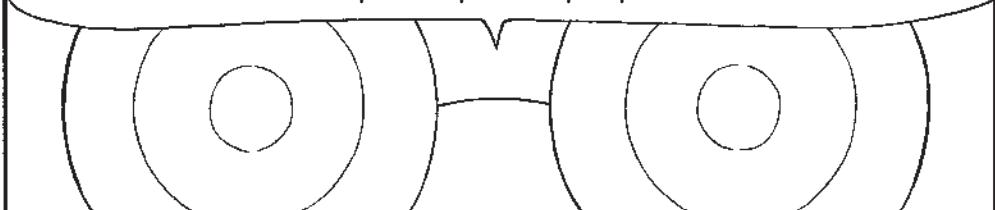


А если плотность распределения вероятностей выражается формулой

$$f(x) = \frac{1}{\sqrt{2\pi} \times \text{Ст.откл.}} e^{-\frac{1}{2} \left(\frac{x - \bar{x}}{\text{Ст.откл.}} \right)^2} = \frac{1}{\sqrt{2\pi} \times 1} e^{-\frac{1}{2} \left(\frac{x - 0}{\text{Ст.откл.}} \right)^2} = \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2} x^2}$$

то в статистике не говорят, что величина x имеет нормальное распределение при значении средней арифметической ряды = 0 и стандартном отклонении = 1.

Принято говорить, что величина x имеет стандартное нормальное распределение.

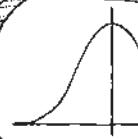


...!

Рассмотрим ещё раз
результаты теста
по английскому.



Предположим, что результаты теста
имеют нормальное распределение
при среднем значении = 53 балла
и стандартном отклонении = 10.



Ну, хорошо.

Ученик	Балл
1	42
2	91
:	:
10421	50
среднее значение	53
стандартное отклонение	10



Нормированное отклонение
-1.1
3.8
:
-0.3
0
1

$$\text{Стандартное отклонение} = \frac{50 - 53}{10} = \frac{-3}{10} = -0.3$$



Если это так, то после нормирования
результаты теста по английскому ...

Стандартное нормальное распределение

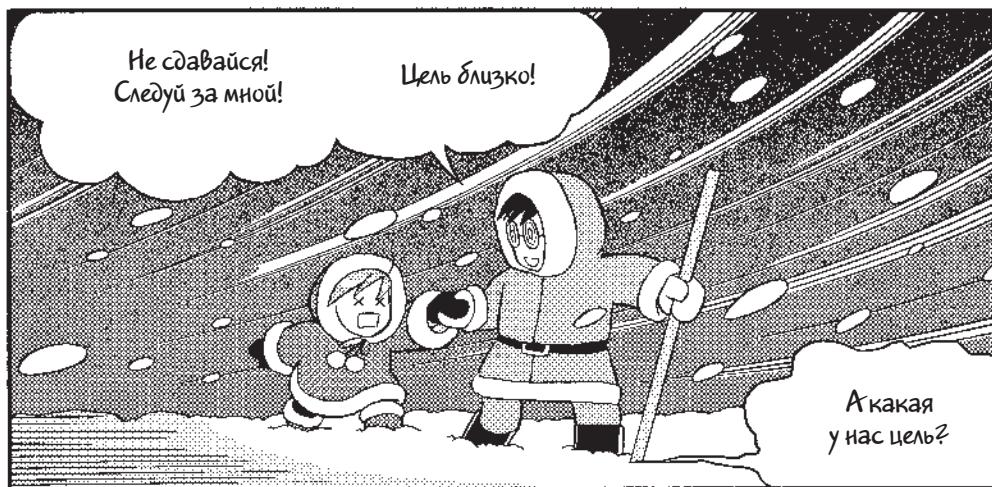
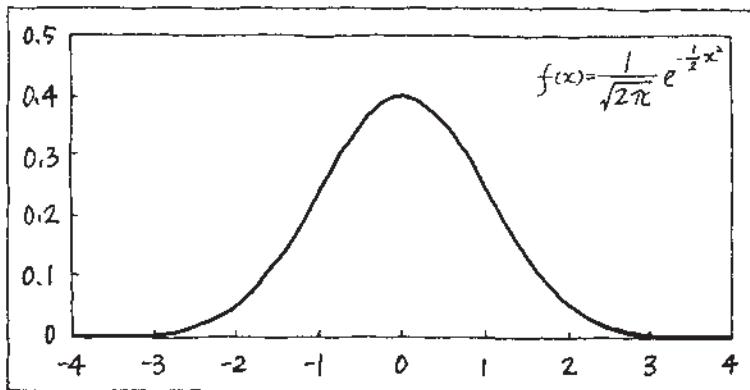
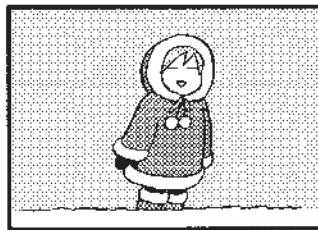
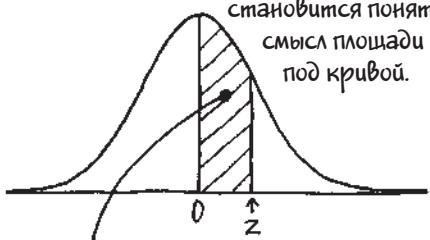


Таблица стандартного нормального распределения

Z	0,00	0,01	0,02	0,03	0,04	0,05	0,06	0,07	0,08	0,09
0,0	0,0000	0,0040	0,0080	0,0120	0,0160	0,0199	0,0239	0,0279	0,0319	0,0359
0,1	0,0398	0,0438	0,0478	0,0517	0,0557	0,0596	0,0636	0,0675	0,0714	0,0753
0,2	0,0793	0,0832	0,0871	0,0910	0,0948	0,0987	0,1026	0,1064	0,1103	0,1141
:	:	:	:	:	:	:	:	:	:	:
1,8	0,4641	0,4649	0,4656	0,4664	0,4671	0,4678	0,4686	0,4693	0,4699	0,4706
1,9	0,4713	0,4719	0,4726	0,4732	0,4738	0,4744	0,4750	0,4756	0,4761	0,4767
:	:	:	:	:	:	:	:	:	:	:



Из этой таблицы
становится понятен
смысъл плошади
под кривой.



сплошные
цифры...

Проснись, Руи!

Плошадь?
Что это значит?

О-о-ооо!
Ты жива!

ожила!



Z	0,00	0,01	0,02	0,03	0,04	0,05	0,06	0,07	0,08
0,0	0,0000	0,0040	0,0080	0,0120	0,0160	0,0199	0,0239	0,0279	0,0319
0,1	0,0398	0,0438	0,0478	0,0517	0,0557	0,0596	0,0636	0,0675	0,0714
0,2	0,0793	0,0832	0,0871	0,0910	0,0948	0,0987	0,1026	0,1064	0,1102
:	:	:	:	:	:	:	:	:	:
1,8	0,4641	0,4649	0,4656	0,4664	0,4671	0,4678	0,4686	0,4693	0,4699
1,9	0,4713	0,4719	0,4726	0,4732	0,4738	0,4744	0,4750	0,4756	0,4761
									0,4767

Пересечение строки 1,9 и столбца 0,06 ...

Правильно! Это площадь заштрихованной на графике области при $Z = 1,96$.

Забыл сказать:
и при нормальном распределении,
и при любом другом, площадь области,
ограниченной осью x и всей кривой распределения,
равна 1.

А теперь
главное блюдо
сегодняшнего дня.
Слушай внимательно.

О-о-о
Жду, не дождусь!

Площадь области,
ограниченной кривой стандартного
нормального распределения и осью x ,
равна доле и Вероятности.

Сейчас приведу два примера,
постарайся понять.

Пример 1

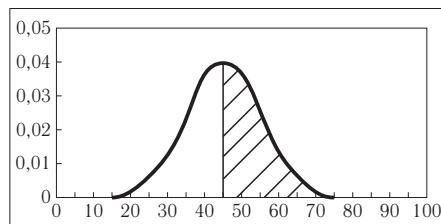


Все десятиклассники школ Восточного округа сдавали тест по математике. Когда им поставили оценки, стало ясно, что распределение результатов теста можно считать нормальным при среднем балле 45, и стандартном отклонении 10.

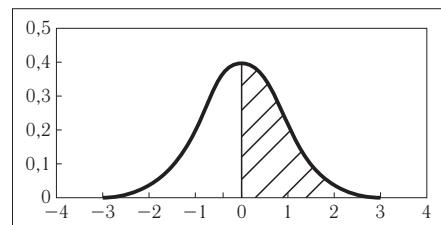
Теперь хорошенько подумай.

Следующие пять выводов имеют один и тот же смысл:

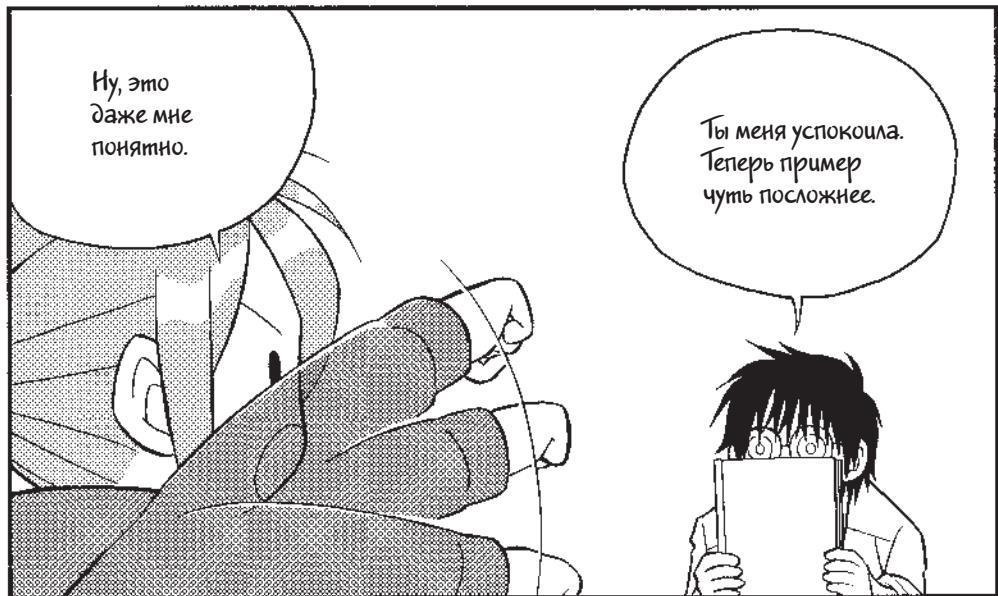
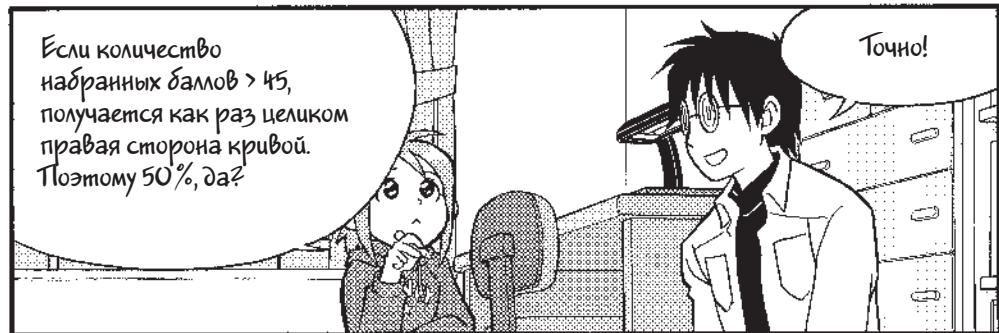
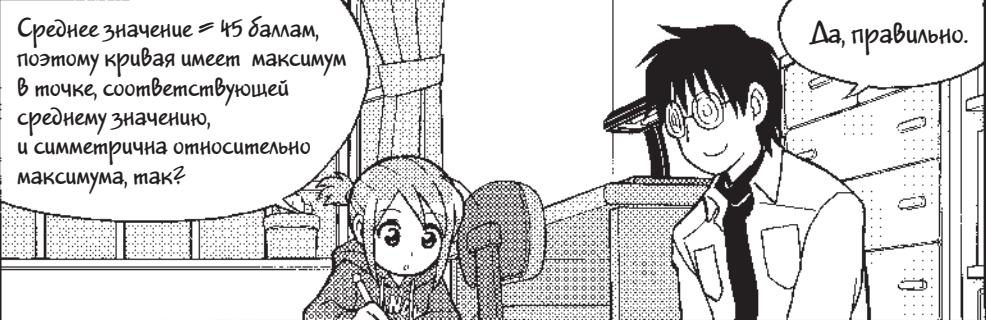
1. При нормальном распределении, когда среднее значение = 45 и стандартное отклонение = 10, площадь заштрихованной области = 0,5.



2. Доля учеников, чей результат был > 45 баллов, составляет 50% от общего числа участников теста.
3. Предположим, что из общего числа учеников произвольно выбрали одного. Вероятность того, что он набрал > 45 баллов, равна 50%.
4. Для стандартного нормального распределения, полученного после нормирования результатов теста, доля учеников с результатом > 0 составляет 50% от общего числа участников теста.



5. Предположим, что из общего числа учеников произвольно выбрали одного. При стандартном нормальном распределении, полученном после нормирования результатов теста по математике, вероятность того, что он набрал положительный балл, составляет 50%.

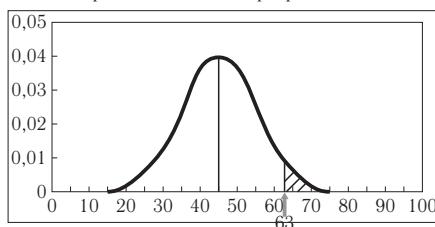


Пример 2

Все десятиклассники школ Восточного округа сдавали тест по математике. Когда им поставили оценки, стало ясно, что распределение результатов теста можно считать нормальным при среднем балле = 45 и стандартном отклонении = 10. Теперь напряги мозги. Как и в предыдущем примере, все следующие пять выводов имеют один и тот же смысл. Но на этот раз ты для начала прочти вывод 4.



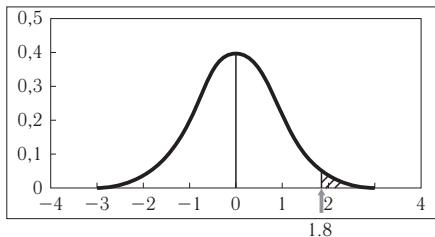
- При нормальном распределении, когда среднее значение = 45 и стандартное отклонение = 10, площадь заштрихованной на графике области = $0,5 - 0,4641 = 0,0359$.



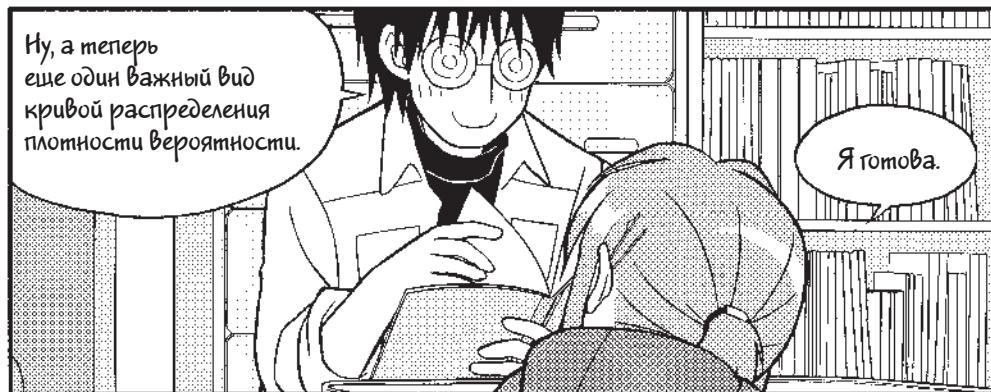
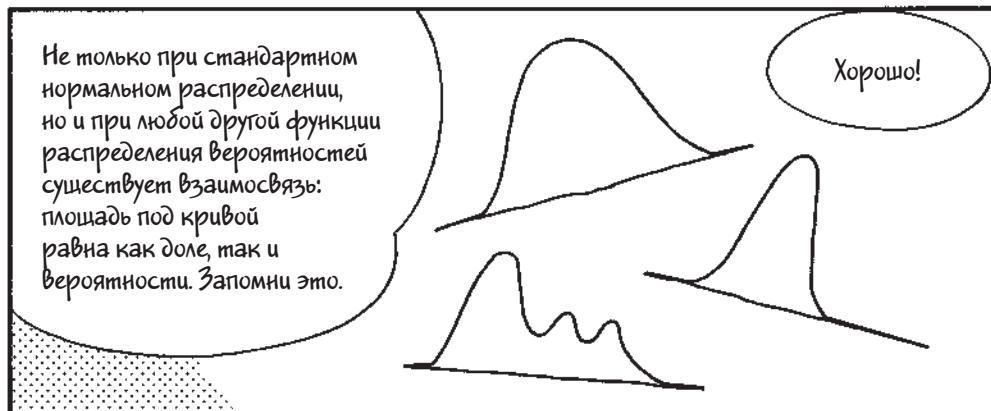
- Доля учеников, чей результат > 63 баллов, = $0,5 - 0,4641 = 0,0359$ или 3,59% от общего числа сдававших экзамен.
- Предположим, что из общего числа учеников был произвольно выбран один. Вероятность того, что он набрал > 63 баллов, = $0,5 - 0,4641 = 0,0359$ или 3,59%.
- При нормальном распределении доля учеников с нормированным отклонением

$$\text{балла} > 1.8 = \frac{18}{10} = \frac{63 - 45}{10} = \frac{\text{Значение} - \text{Среднее значение}}{\text{Стандартное отклонение}}$$

составляет 3,59% ($0,5 - 0,4641 = 0,0359$)
(см. Таблицу стандартного нормального распределения).



- Предположим, что оценки учеников после нормирования распределены по стандартному нормальному закону. Вероятность того, что нормированное отклонение произвольно выбранного ученика $> 1,8$ равна 3,59%.



4. Распределение хи-квадрат



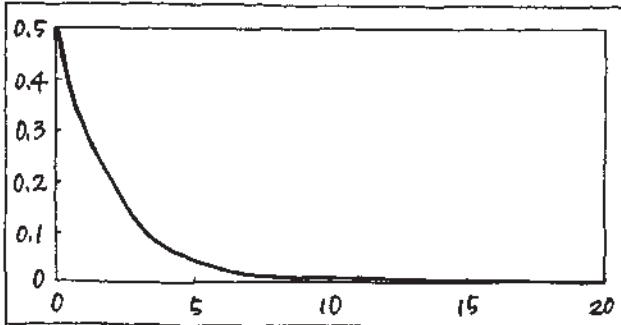
Если функция распределения вероятностей выражается формулой

$$f(x) = \begin{cases} \frac{1}{2^{\frac{n}{2}} \times \int_0^{\infty} x^{\frac{n}{2}-1} e^{-x} dx} \times x^{\frac{n}{2}-1} \times e^{-\frac{x}{2}} & \text{при } x > 0, \\ 0 & \text{при } x \leq 0, \end{cases}$$

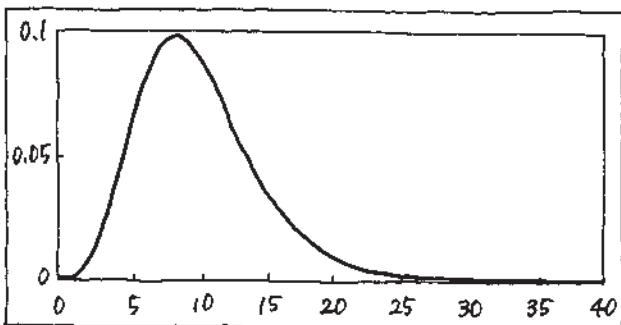
то в статистике говорят, что величина x имеет распределение хи-квадрат с числом степеней свободы n .



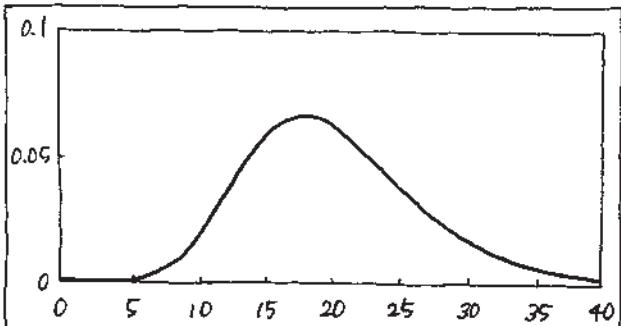
Число степеней свободы равно 2



Число степеней свободы равно 10



Число степеней свободы равно 20



В зависимости от числа степеней свободы форма графика совершенно меняется.





Так же, как существует таблица стандартного нормального распределения, есть и таблица для распределения хи-квадрат.

Таблица распределения хи-квадрат — это ...

... таблица, в которой указывается значение χ^2 (см. ось x на графике), соответствующее значению вероятности (которая, как мы знаем, равна площади и доле) заштрихованной области P .

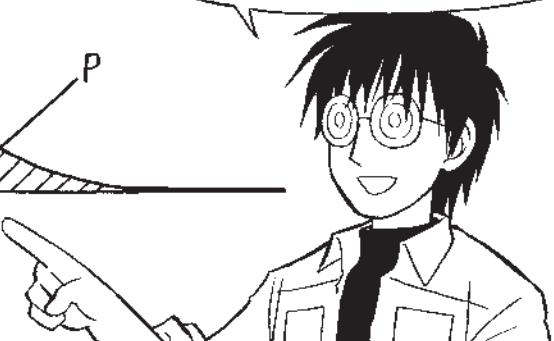
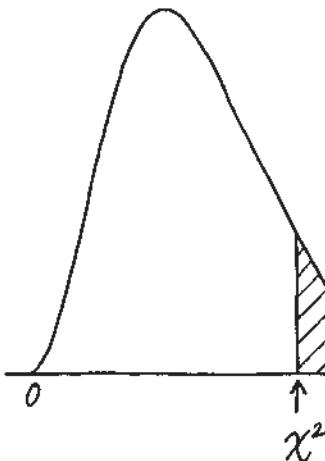




Таблица распределения хи-квадрат

P Степень свободы	0.995	0.99	0.975	0.95	0.05	0.025	0.01	0.005
1	0.000039	0.0002	0.0010	0.0039	3.8415	5.0239	6.6349	7.8794
2	0.0100	0.0201	0.0506	0.1026	5.9915	7.3778	9.2104	10.5965
3	0.0717	0.1148	0.2158	0.3518	7.8147	9.3484	11.3449	12.8381
4	0.2070	0.2971	0.4844	0.7107	9.4877	11.1433	13.2767	14.8602
5	0.4118	0.5543	0.8312	1.1455	11.0705	12.8325	15.0863	16.7496
6	0.6757	0.8721	1.2373	1.6354	12.5916	14.4494	16.8119	18.5475
7	0.9893	1.2390	1.6899	2.1673	14.0671	16.0128	18.4753	20.2777
8	1.3444	1.6465	2.1797	2.7326	15.5073	17.5345	20.0902	21.9549
9	1.7349	2.0879	2.7004	3.3251	16.9190	19.0228	21.6660	23.5893
10	2.1558	2.5582	3.2470	3.9403	18.3070	20.4832	23.2093	25.1881
:	:	:	:	:	:	:	:	:

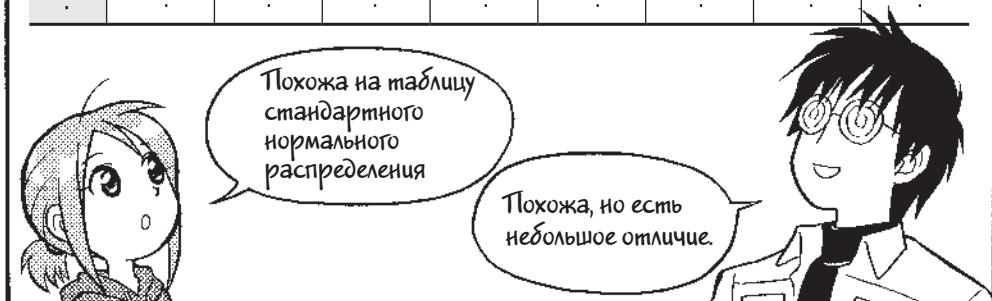


Таблица стандартного нормального распределения позволяет по значению координаты x (в пределах заштрихованной области) найти соответствующую вероятность.

Вероятность равна площади, или доле. Так?

А таблица распределения хи-квадрат позволяет по вероятности найти соответствующую координату на оси x .

Вот это значение!

В голове у меня полная каша!!!

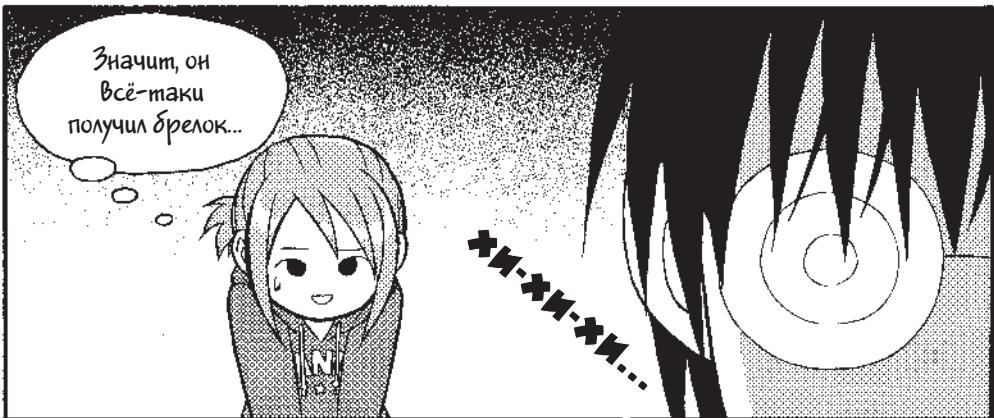
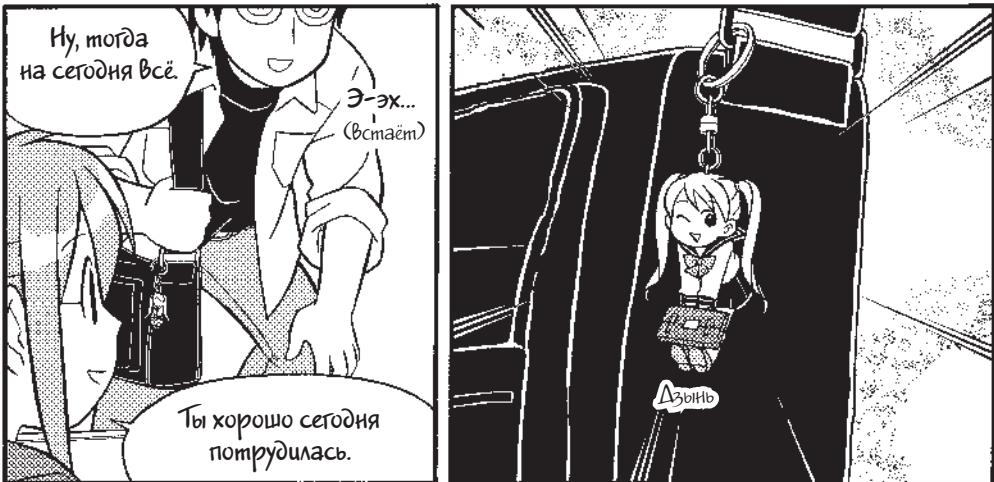
Ну подожди, не нервничай.

Давай посмотрим, какое будет значение, если число степеней свободы = 1 и $P = 0.05$.

	0.99	0.975	0.95	0.05	0.025	0.01
002	0.0010	0.0039	0.026	3.8415	5.0239	6.6349
201	0.0506	0.1026	0.147	7.3778	9.3484	9.2104
148	0.2158	0.3518	0.4877	9.4877	11.1433	11.3449
971	0.4844	0.71	1.05	12.837	14.4	16.0
5543	0.8312	1.14	1.45	17.53	19.0228	20.05
7	1.2373	1.63	2.16	20.05	22.00	23.70
9	1.6899	2.71	3.89	22.00	24.00	25.70
1	1.3444	1.97	2.63	24.00	26.00	27.70
8	0.9893	0.8721	0.77	26.00	28.00	29.70
0	1.2390	1.2373	1.2357	28.00	30.00	31.70

Значение, находящееся на пересечении строки «1», и столбца «0.05», ...

... будет 3.8415



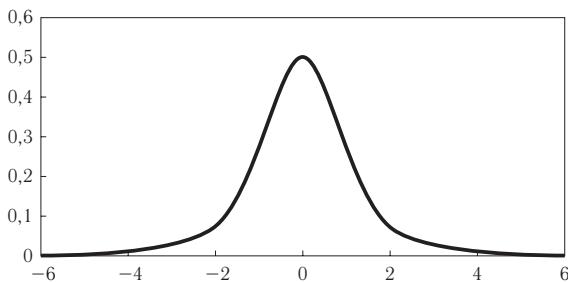
5. Распределение Стьюдента

В статистике часто используется и такая формула распределения вероятностей:

$$f(x) = \frac{\int_0^{\infty} x^{\frac{n+1}{2}-1} e^{-x} dx}{\sqrt{n\pi} \int_0^{\infty} x^{\frac{n}{2}-1} e^{-x} dx} \times \left(1 + \frac{x^2}{n}\right)^{-\frac{n+1}{2}}$$

где n — число степеней свободы. Если плотность распределения вероятностей можно выразить с помощью этой формулы, в статистике это означает, что величина x имеет распределение Стьюдента с числом степеней свободы n .

Распределение Стьюдента с числом степеней свободы 5



6. Распределение Фишера, или F-распределение

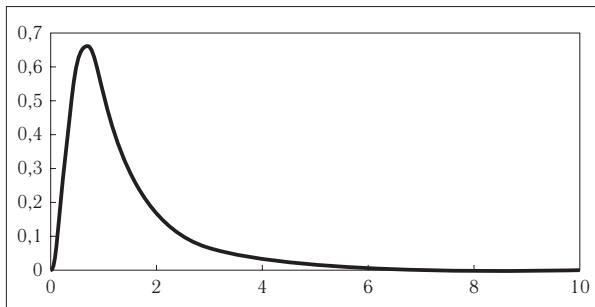
Не менее часто используется и такая функция распределения плотности вероятности:

$$f(x) = \begin{cases} \left(\int_0^{\infty} x^{\frac{n+m}{2}-1} e^{-x} dx\right) \times n^{\frac{n}{2}} \times m^{\frac{m}{2}} & \text{при } x > 0, \\ \left(\int_0^{\infty} x^{\frac{n}{2}-1} e^{-x} dx\right) \times \left(\int_0^{\infty} x^{\frac{m}{2}-1} e^{-x} dx\right) \times (nx + m)^{\frac{n+m}{2}} & \\ 0 & \text{при } x \leq 0, \end{cases}$$

где n и m — число степеней свободы величины x .

Если формула плотности распределения вероятности имеет такой вид, в статистике это означает, что x имеет F-распределение с числом степеней свободы n и m .

Случай, когда степень свободы $n = 10$, а $m = 5$



7. Распределения и Excel

До начала 90-х вычисление вероятности и значения x было настолько сложным и трудоёмким, что его можно было выполнить только с помощью таблиц стандартного нормального распределения и распределения хи-квадрат. Однако, по мере развития компьютерных технологий, необходимость в этих таблицах отпала, поскольку величины, которые указаны в таблицах, можно получить с помощью программы Excel.

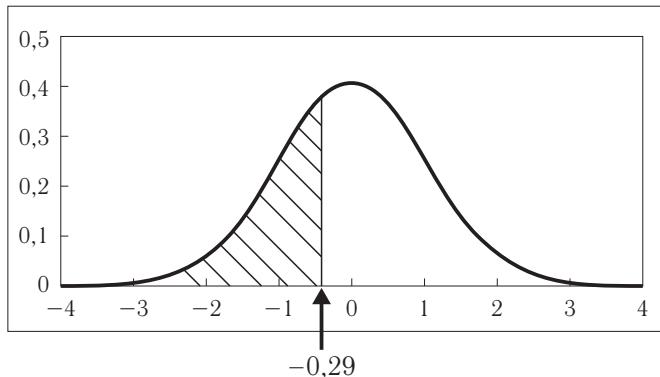
Таблица 5.1.

Распределение	Функция		Значение функции
	русский	английский	
Нормальное распределение*	НОРМРАСП НОРМОБР	NORMDIST NORMINV	Вероятность для заданного x Значение x для заданной вероятности
Стандартное нормальное распределение	НОРМСТРАСП НОРМСТОБР	NORMSDIST NORMSINV	Вероятность для заданного x Значение x для заданной вероятности
Распределение хи-квадрат	ХИ2РАСП ХИ2ОБР	CHIDIST CHIINV	Вероятность для заданного x Значение x для заданной вероятности
Распределение Стьюдента	СТЫОДРАСП СТЫОДРАСПОБР	TDIST TINV	Вероятность для заданного x Значение x для заданной вероятности
Распределение Фишера	FPACП FPACПОБР	FDIST FINV	Вероятность для заданного x Значение x для заданной вероятности

* Функция распределения вероятностей (речь идёт о нормальном распределении) зависит от таких параметров, как среднее значение и стандартное отклонение. Поэтому таблицу нормального распределения, даже при большом желании, невозможно составить. Но с помощью Excel можно сформировать таблицу, соответствующую таблице нормального распределения, что очень удобно.

Упражнение

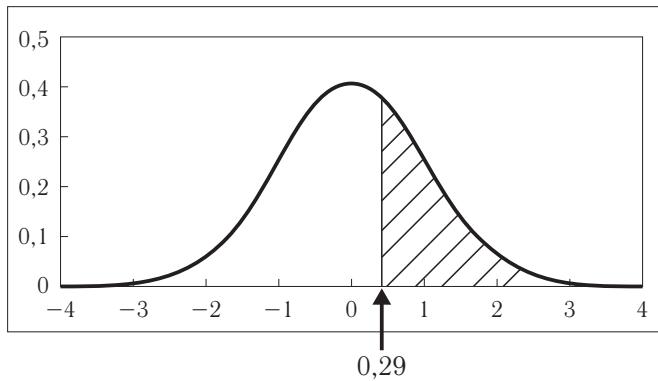
1. Используя таблицу стандартного нормального распределения на стр. 93, вычислите вероятность для заштрихованной на графике области.



2. Используя таблицу распределения хи-квадрат на стр. 103, вычислите значение χ^2 , если число степеней свободы равно 2, а $P = 0,05$.

Ответ

1. Искомая вероятность равна вероятности заштрихованной области.



Вероятность при $z = 0,29 = 0,2 + 0,09$, как следует из таблицы стандартного нормального распределения, равна 0,1141. Следовательно, искомая вероятность будет равна: $0,5 - 0,1141 = 0,3859$.

2. Как следует из таблицы распределения хи-квадрат, значение величины χ^2 , которое нужно найти, равно 5,9915.

Выходы

- К широко используемым видам функции распределения вероятностей можно отнести:
 - нормальное распределение;
 - стандартное нормальное распределение;
 - распределение хи-квадрат;
 - распределение Стьюдента;
 - распределение Фишера.
- Площадь области, ограниченной осью x и кривой распределения вероятностей, равна 1.
- Площадь области, ограниченной осью x и кривой распределения вероятностей, тождественна и доле, и вероятности.
- С помощью таблиц распределений или программы Excel можно вычислить:
 - вероятность при определенном значении x ;
 - значение x при определенном значении вероятности.

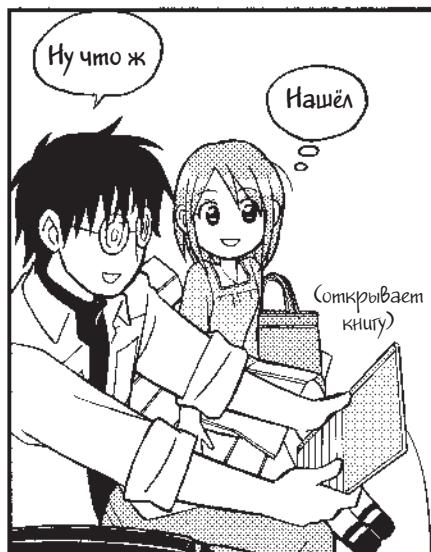
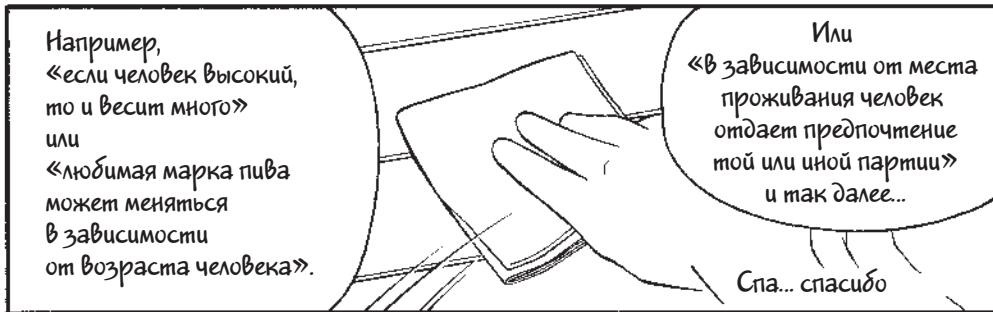
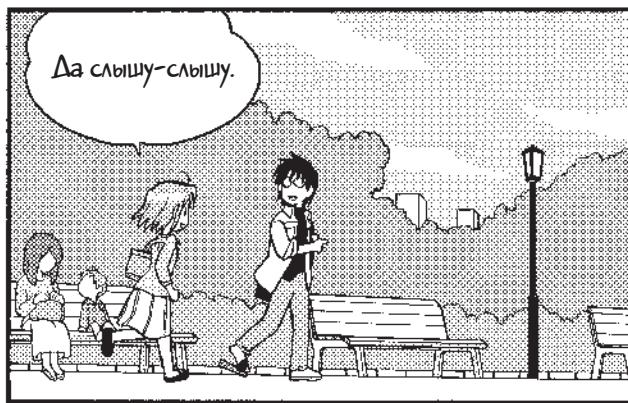
Глава 6

Что может связывать две переменные

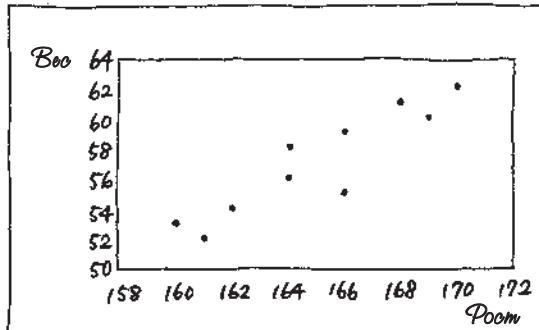
(кто-то идет, шаркая ногами)

На самом деле ...



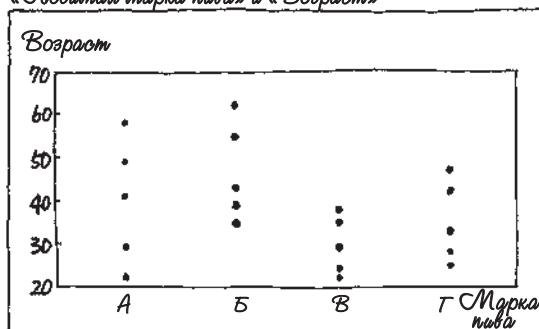


Маточная диаграмма «Рост» и «Вес»



Количественные данные
и количественные данные

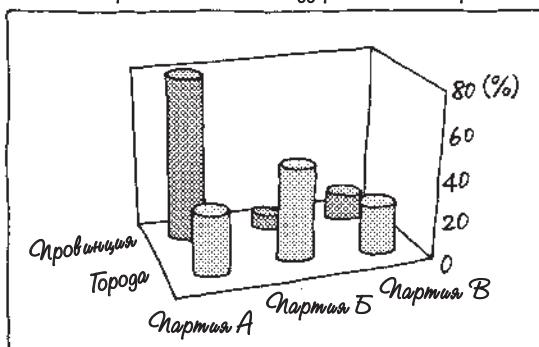
Маточная диаграмма
«Любимая марка пива» и «Возраст»



Количественные данные
и качественные данные

Когда
построишь диаграмму,
сразу ясно, есть или нет
взаимосвязь между
двумя переменными.

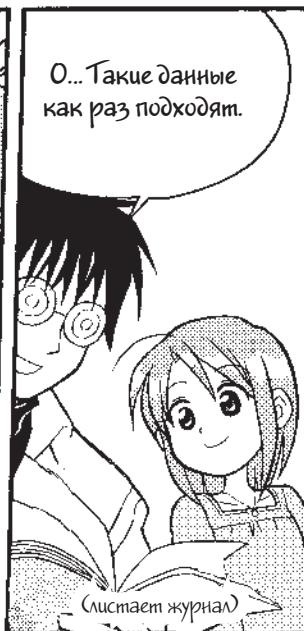
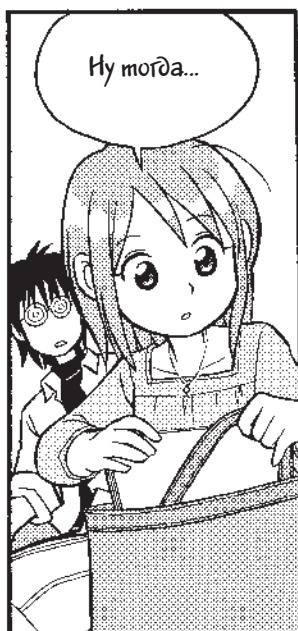
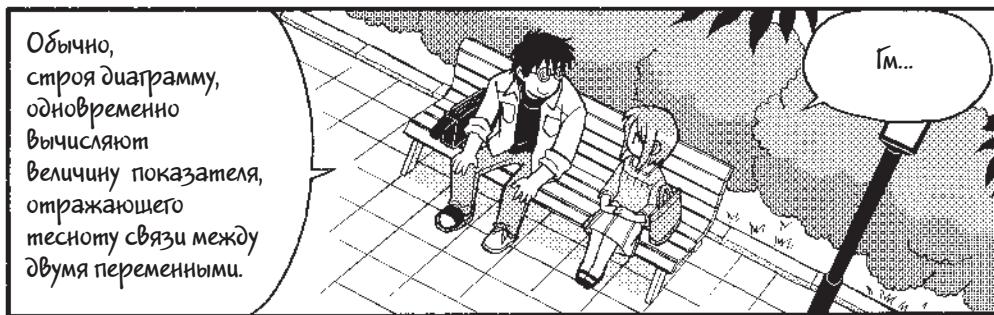
Столбиковая диаграмма
«Место проживания» и «Поддерживаемая партия»



Качественные
данные
и качественные
данные

Ага





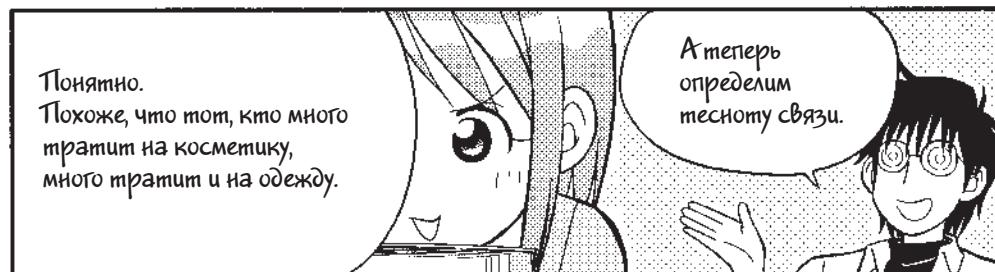
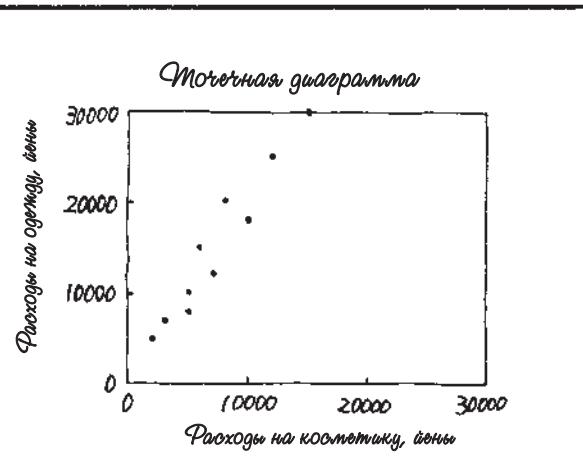
1. Коэффициент линейной корреляции



Расходы на косметику и Расходы на одежду (в месяц)

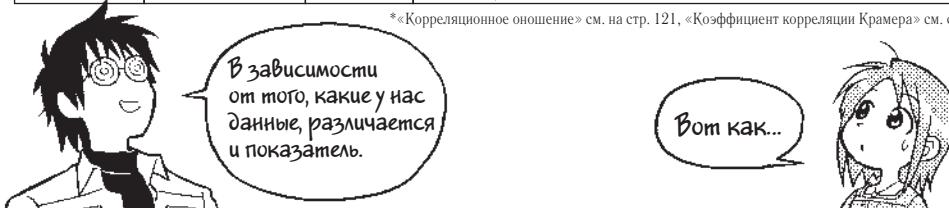
Ответы 10 женщин в возрасте от 20 до 29 лет

Респондент	Расходы на косметику, юань	Расходы на одежду, юань
А	3000	7000
Б	5000	8000
В	12000	25000
Г	2000	5000
Д	7000	12000
Е	15000	30000
Ж	5000	10000
З	6000	15000
И	8000	20000
К	10000	18000



Тип данных	Показатель	Значение	Формула
Количество- и количеств.	Коэффициент линейной корреляции	-1 ... 1	$\frac{\sum (x - \bar{x})(y - \bar{y})}{\sqrt{\sum (x - \bar{x})^2 \sum (y - \bar{y})^2}} = \frac{S_{xy}}{\sqrt{S_{xx} S_{yy}}}$
Количество- и качеств.	Корреляционное отношение	0 ... 1	Межгрупповая дисперсия Внутригрупповая дисперсия + Межгрупповая дисперсия
Качеств. и качеств.	Коэффициент корреляции Крамера	0 ... 1	$\sqrt{\frac{\chi_0^2}{n(\min\{\text{кол-во строк, кол-во столбцов}\}-1)}}$

*«Корреляционное оношение» см. на стр. 121, «Коэффициент корреляции Крамера» см. стр. 127.



Расходы на косметику и Расходы на одежду линейно зависимы.

$$\frac{\sum (x - \bar{x})(y - \bar{y})}{\sqrt{\sum (x - \bar{x})^2 \sum (y - \bar{y})^2}} = \frac{S_{xy}}{\sqrt{S_{xx} S_{yy}}}$$

... давай, не будем торопиться и вычислим всё не спеша.

Тоехали!

Спасибо!

Порядок вычисления коэффициента линейной корреляции (для определения тесноты связи между «расходами в месяц на косметику» и «расходами в месяц на одежду»)

Респондент	Расходы на косметику, йены	Расходы на одежду, йены	x	y	$x - \bar{x}$	$y - \bar{y}$	$(x - \bar{x})^2$	$(y - \bar{y})^2$	$(x - \bar{x})(y - \bar{y})$
А	3000	7000	-4300	-8000	18490000	64000000	34400000		
Б	5000	8000	-2300	-7000	5290000	49000000	16100000		
В	12000	25000	4700	10000	22090000	100000000	47000000		
Г	2000	5000	-5300	-10000	28090000	100000000	53000000		
Д	7000	12000	-300	-3000	90000	9000000	900000		
Е	15000	30000	7700	15000	59290000	225000000	115500000		
Ж	5000	10000	-2300	-5000	5290000	25000000	11500000		
З	6000	15000	-1300	0	1690000	0	0		
И	8000	20000	700	5000	490000	25000000	3500000		
К	10000	18000	2700	3000	7290000	9000000	8100000		
Сумма	73000	150000	0	0	148100000	606000000	290000000		
Ср. знач.	7300	15000				\downarrow	\downarrow	\downarrow	
	$\blacktriangleright \bar{x}$	$\blacktriangleright \bar{y}$				S_{xx}	S_{yy}	S_{xy}	

Итак,
подставим числа.

$$\frac{S_{xy}}{\sqrt{S_{xx} \times S_{yy}}} = \frac{290000000}{\sqrt{148100000 \times 606000000}} = 0.9680$$



Если воспользоваться
компьютером, всё
будет намного быстрее.

Коэффициент линейной
корреляции = 0,9680.



Когда между двумя переменными
существует тесная связь,
коэффициент корреляции приближается к ± 1 ,
а когда связь слабая, он приближается к 0.



Гм...

Этот результат
довольно близок к 1, т.е. между
расходами на косметику
и расходами на одежду
существует тесная связь, так?



Примерно так.

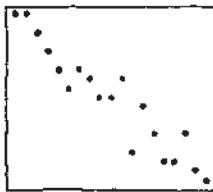
А когда коэффициент
корреляции
приближается к -1 ?



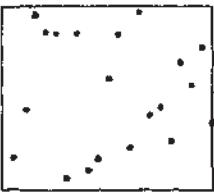
В том случае, когда увеличение
расходов на косметику
ведёт к уменьшению
расходов на одежду.



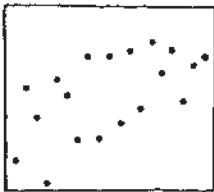
Коэффициент корреляции отрицательный



Корреляция отсутствует



Коэффициент корреляции положительный — связь есть



Коэффициент линейной корреляции ≈ -1

$= 0$

$\approx 0,5$

≈ 1



Когда коэффициент корреляции положителен, как в нашем случае, говорят, что «есть прямая зависимость», а если отрицателен — «обратная зависимость».

Если же коэффициент = 0, то говорят «зависимость отсутствует».

Поняла!



Кстати, кое-что ещё о коэффициенте линейной корреляции.

К сожалению, в статистике нет какого-то определённого значения коэффициента корреляции, выше которого две переменные считаются тесно связанными.

Как-то уклончиво ...



Критерии величины коэффициента линейной корреляции

Абсолютная величина коэффицента лин. корреляции		Вывод о степени взаимосвязи	Вывод о наличии взаимосвязи
1,0—0,9	⇒	Очень тесная	
0,9—0,7	⇒	Достаточно тесная	Есть
0,7—0,5	⇒	Слабая	
< 0,5	⇒	Очень слабая	Нет



Это для справки.

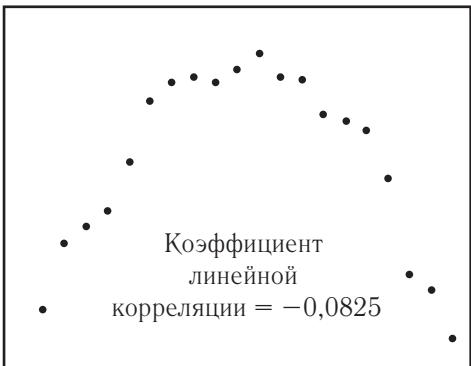


Примечание

До этого я говорил, что коэффициент линейной корреляции — это показатель тесноты связи между количественными данными. Строго говоря, это не совсем так. Коэффициент корреляции еще показывает, является эта зависимость линейной или нет.



Пример нелинейной зависимости



Например, эта диаграмма демонстрирует очевидную связь между двумя переменными. Но поскольку зависимость нелинейная, коэффициент линейной корреляции практически равен нулю.

2. Коэффициент корреляции между данными разных типов

Теперь, перейдём к следующей теме! Здесь есть данные о «возрасте» и «любимом бренде одежды».

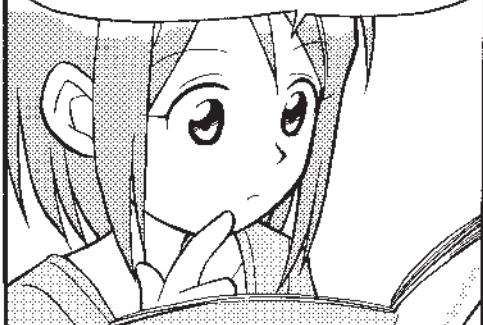


Это количественные и качественные данные.

Возраст и Любимый бренд одежды

Респондент	Возраст	Бренд
А	27	Benetton
Б	33	Zara
В	16	O'STIN
Г	29	Бапари
Д	32	Zara
Е	23	Benetton
Ж	25	Zara
З	28	Benetton
И	22	O'STIN
К	18	O'STIN
Л	26	Zara
М	26	Benetton
Н	15	O'STIN
О	29	Zara
П	26	O'STIN

Для случая, когда одни данные количественные, а другие качественные, вычисляется коорреляционное отношение, которое может принимать значения от 0 до 1.



А в этом случае приближение значения к 1 тоже свидетельствует о наличии тесной связи между данными?



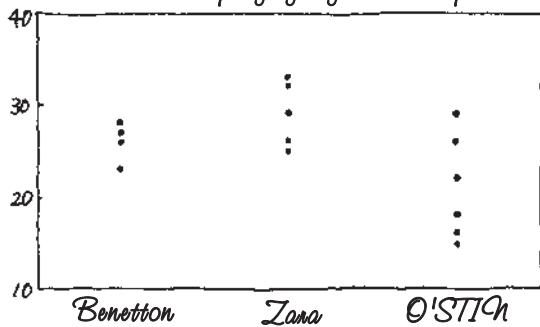
«Любимый бренд одежды» и «Возраст»



Benetton	Zara	O'STIN
23	25	15
26	26	16
27	29	18
28	32	22
	33	26
		29
Сумма	104	145
Среднее значение	26	29
		375
		25

Диаграмма

«Любимый бренд одежды» и «Возраст»



Следующим этапом будет построение диаграммы.

Ух ты!
Похоже,
что есть
взаимосвязь!

Ну тогда
вычислим
корреляционное
отношение.

Согласна!

Вычисление корреляционного отношения предусматривает выполнение нижеследующих шагов.



Шаг 1

Вычислить суммы стандартных отклонений для каждого столбца таблицы:

	(значение — среднее значение в столбце Benetton) ²	(значение — среднее значение в столбце Zara) ²	(значение — среднее значение в столбце O'STIN) ²
	$(23 - 26)^2 = (-3)^2 = 9$	$(25 - 29)^2 = (-4)^2 = 16$	$(15 - 21)^2 = (-6)^2 = 36$
	$(26 - 26)^2 = 0^2 = 0$	$(26 - 29)^2 = (-3)^2 = 9$	$(16 - 21)^2 = (-5)^2 = 25$
	$(27 - 26)^2 = 1^2 = 1$	$(29 - 29)^2 = 0^2 = 0$	$(18 - 21)^2 = (-3)^2 = 9$
	$(28 - 26)^2 = 2^2 = 4$	$(32 - 29)^2 = 3^2 = 9$	$(22 - 21)^2 = 1^2 = 1$
		$(33 - 29)^2 = 4^2 = 16$	$(26 - 21)^2 = 5^2 = 25$
			$(29 - 21)^2 = 8^2 = 64$
Сумма	14	50	160
	\downarrow S_{BB}	\downarrow S_{ZZ}	\downarrow S_{OO}

Шаг 2

Вычислить внутригрупповую дисперсию, показывающую как сильно отличаются данные в каждой категории, как сумму $S_{TT} + S_{CC} + S_{BB}$:

$$S_{BB} + S_{ZZ} + S_{OO} = 14 + 50 + 160 = 224$$

Шаг 3

Рассчитать межгрупповую дисперсию — меру разброса данных между категориями. Для этого надо найти стандартные отклонения средних значений от общего среднего значения, умножить их на количество данных в соответствующей графе и вычислить сумму полученных произведений, т. е.:

$$\begin{aligned} & \text{Кол-во значений Benetton} \times (\text{Ср. знач. Benetton} - \text{общее ср. знач.})^2 + \\ & + \text{Кол-во значений Zara} \times (\text{Ср. знач. Zara} - \text{общее ср. знач.})^2 + \\ & + \text{Кол-во значений O'STIN} \times (\text{Ср. знач. O'STIN} - \text{общее ср. знач.})^2 \end{aligned}$$

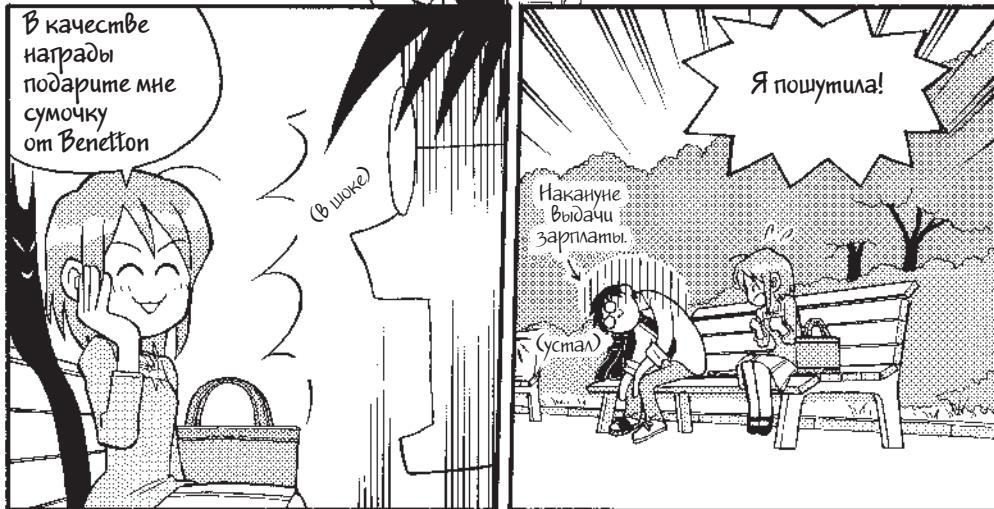
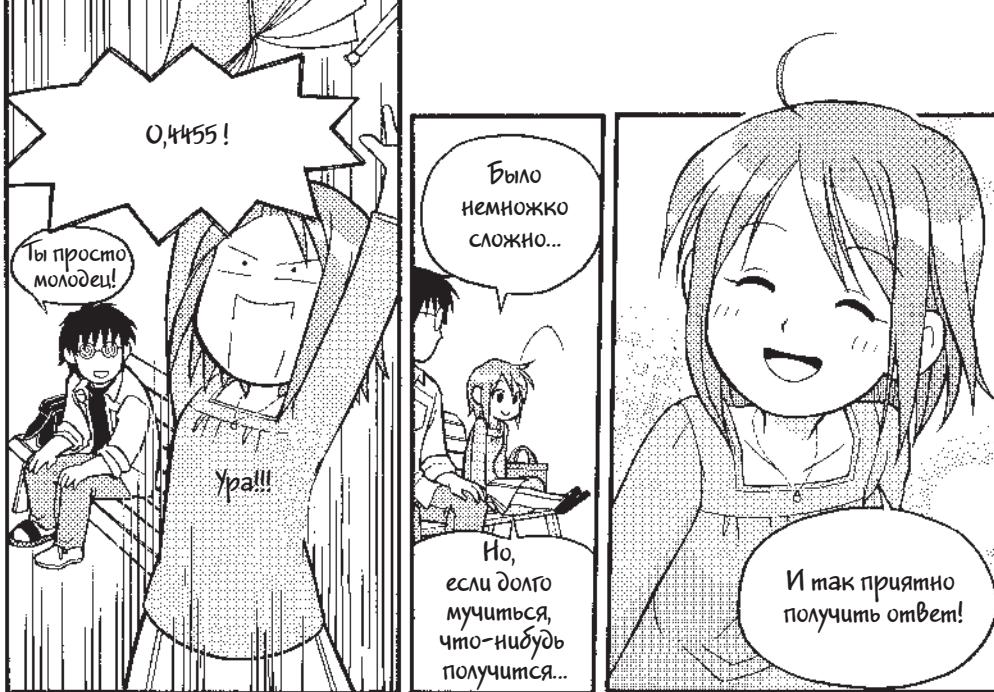
$$\begin{aligned} & 4 \times (26 - 25)^2 + 5 \times (29 - 25)^2 + 6 \times (21 - 25)^2 = \\ & = 4 \times 1 + 5 \times 16 + 6 \times 16 = \\ & = 4 + 80 + 96 = \\ & = 180 \end{aligned}$$

Шаг 4

Вычислить корреляционное отношение по формуле:

$$\frac{180}{224 + 180} = \frac{180}{404} = 0,4455$$



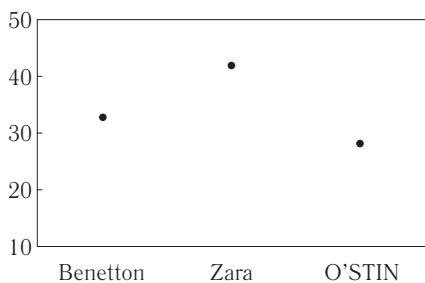


Как я уже говорил, корреляционное отношение может принимать значения от 0 до 1. Чем теснее взаимосвязь между двумя переменными, тем значение ближе к 1, чем слабее взаимосвязь, тем ближе к 0.

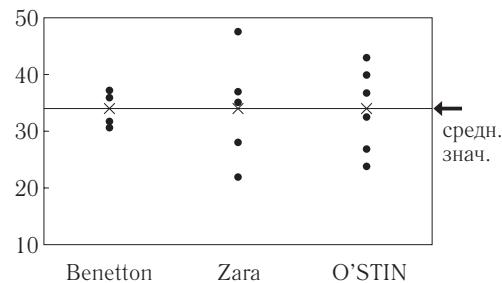


Диаграмма «Любимый бренд одежды» и «Возраст»

Корреляционное отношение = 1



Корреляционное отношение = 0



средн.
знач.

Корреляционное отношение = 1



Данные внутри каждой
группы одинаковы



Внутригрупповая дисперсия = 0

Корреляционное отношение = 0



Средние значения всех
групп одинаковы



Межгрупповая дисперсия = 0



К сожалению, в статистике нет кого-то определённого значения корреляционного отношения, свыше которого переменные считаются тесно связанными. Для справки приведём таблицу соответствия корреляционного отношения и степени взаимосвязи.

Критерии величины корреляционного отношения

Корреляционное отношение	Вывод о степени взаимосвязи	Вывод о наличии взаимосвязи
1,0—0,8	Очень тесная	Есть
0,8—0,5	Достаточно тесная	
0,5—0,25	Слабая	
< 0,25	Очень слабая	

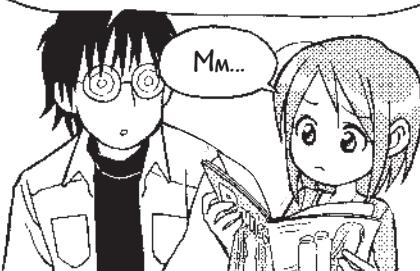
В нашем примере корреляционное отношение было равно 0,4455: значит связь слабая!



3. Коэффициент корреляции Крамера

Дальше...

Было бы здорово привести пример, который мог бы пояснить связь между качественными данными.



Ой! Как насчёт
вот этих данных?

Опросили
300 школьников!
Какой способ признания
в любви вы предпочитаете?

Опросили 300 школьников на тему
«какой способ признания в любви
вы предпочитаете?»



Однако женский
журнал проводит
странное анкетирование ...

Не
твоего
ума
дело!

Таблица взаимной сопряжённости «пола» и «способа признания в любви»

Пол респондента	Способ признания в любви, люди			Итого
	по телефону	по SMS	при встрече	
женский	34	61	53	148
мужской	38	40	74	152
Итого:	72	101	127	300

Это значит, что из 152 опрошенных молодых людей 74 хотели бы, чтобы им признавались в любви при встрече.

Таблица взаимной сопряжённости в %

Пол респондента	Способ признания в любви, %			Итого
	по телефону	по SMS	при встрече	
женский	23	41	36	100
мужской	25	26	49	100
Итого:	24	34	42	100

Это значит, что 49% опрошенных молодых людей хотели бы, чтобы им признавались в любви при встрече.

Такая таблица,
где две
переменные
перекре-
щиваются,
называется
таблицей
взаимной
сопряжён-
ности.



Вот как...
Девушки предпочитают,
чтобы им признавались
в любви «по SMS»,...

... а юноши
предпочитают, чтобы им
признавались в любви
«при встрече».

Похоже, что юноши и девушки предпочитают разные способы признания в любви.

Другими словами, есть взаимосвязь между «полом» и «способом признания».



Руц, ты меня слушаешь?

Да.
Конечно!!

Какой показатель характеризует степень связи между качественными данными?

Я знаю!
Это коэффициент корреляции Крамера!

Этот коэффициент называют либо коэффициент корреляции Крамера, либо коэффициент V Крамера, либо коэффициент независимости.

У меня голова кр...утом идёт.

Да нет, очень здорово у тебя получилось кр...утом.
(смутилась)

Не говори
ничего...

Вычисление коэффициента корреляции Крамера предусматривает выполнение следующих шагов:



Шаг 1

Построить таблицу взаимной сопряжённости. Величины в клетках, обведённых жирной чертой, называются **эмпирическими частотами**.

Пол респондента	Способ признания в любви			Итого
	по телефону	по SMS	при встрече	
женский	34	61	53	148
мужской	38	40	74	152
Итого:	72	101	127	300

Шаг 2

Выполнить вычисления, как показано в следующей таблице. Величины в обведённых клетках называются **теоретическими частотами**.

Пол респондента	Способ признания в любви			Итого
	по телефону	по SMS	при встрече	
женский	$\frac{148 \times 72}{300}$	$\frac{148 \times 101}{300}$	$\frac{148 \times 127}{300}$	148
мужской	$\frac{152 \times 72}{300}$	$\frac{152 \times 101}{300}$	$\frac{152 \times 127}{300}$	152
Итого:	72	101	127	300

Число опрошенных юношей × Число ответов «при встрече»

—————
Общее число опрошенных

Если между «полом» и «способом признания в любви» полностью отсутствует какая-либо связь, то отношение эмпирических частот в строках «женский» и «мужской» будет таким же, как отношение значений в строке «Итого» (см. Шаг 1).



Теоретические частоты, вычисленные на Шаге 2, отражают, каково было бы число соответствующих респондентов в случае полного отсутствия какой-либо связи между «полом» и «способом признания в любви».

Шаг 3

Вычислить:

$$\frac{\text{Эмпирическая частота} - \text{Теоретическая частота}}{\text{Теоретическая частота}}$$

Пол респон- дента	Способ признания в любви			Итого
	по телефону	по SMS	при встрече	
женский	$\frac{\left(34 - \frac{148 \times 72}{300}\right)^2}{\frac{148 \times 72}{300}}$	$\frac{\left(61 - \frac{148 \times 101}{300}\right)^2}{\frac{148 \times 01}{300}}$	$\frac{\left(53 - \frac{148 \times 127}{300}\right)^2}{\frac{148 \times 127}{300}}$	148
мужской	$\frac{\left(38 - \frac{152 \times 72}{300}\right)^2}{\frac{152 \times 72}{300}}$	$\frac{\left(40 - \frac{152 \times 101}{300}\right)^2}{\frac{152 \times 101}{300}}$	$\frac{\left(74 - \frac{152 \times 127}{300}\right)^2}{\frac{152 \times 127}{300}}$	152
Итого:	72	101	127	300



Чем больше разница между эмпирическими и теоретическими частотами, т.е. чем теснее связь между «полом» и «способом признания в любви», тем больше значения величин в клетках таблицы.

Шаг 4

Вычислить сумму величин в клетках таблицы на **Шаге 3**.

Иначе говоря, вычислить значение критерия согласия Пирсона (χ^2_0).

$$\begin{aligned}\chi^2_0 = & \frac{\left(34 - \frac{148 \times 72}{300}\right)^2}{\frac{148 \times 72}{300}} + \frac{\left(61 - \frac{148 \times 101}{300}\right)^2}{\frac{148 \times 101}{300}} + \frac{\left(53 - \frac{148 \times 127}{300}\right)^2}{\frac{148 \times 127}{300}} + \\ & + \frac{\left(38 - \frac{152 \times 72}{300}\right)^2}{\frac{152 \times 72}{300}} + \frac{\left(40 - \frac{152 \times 101}{300}\right)^2}{\frac{152 \times 101}{300}} + \frac{\left(74 - \frac{152 \times 127}{300}\right)^2}{\frac{152 \times 127}{300}} = \\ & = 8,0091\end{aligned}$$

Согласно Шагу 3, чем больше разница между эмпирическими и теоретическими частотами, т.е. чем теснее связь между «полом» и «способом признания», тем больше значение критерия согласия Пирсона (χ^2_0).



Шаг 5

Величина коэффициента корреляции Крамера вычисляется по формуле:

$$\sqrt{\frac{\chi_0^2}{n \times (\min\{\text{кол-во строк в таблице; кол-во столбцов в таблице}\} - 1)}},$$

где

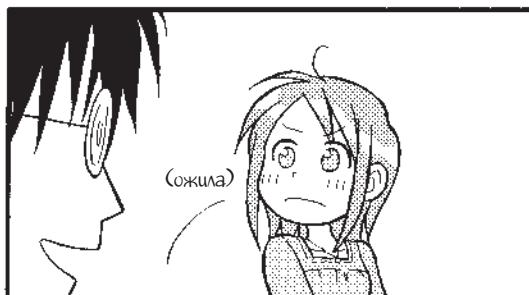
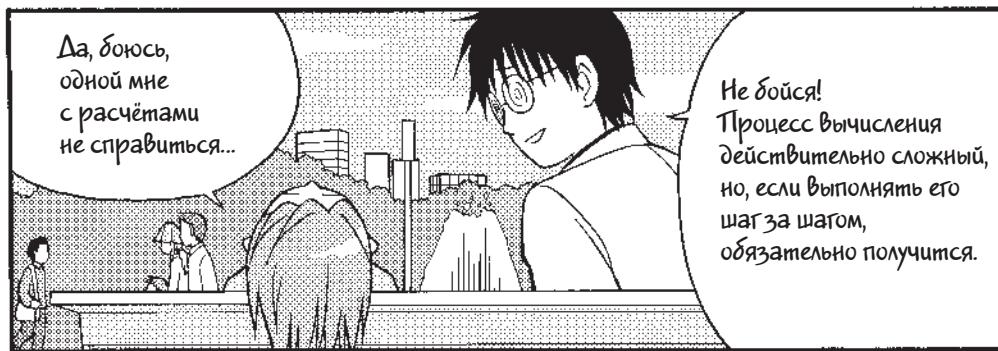
n — общее число единиц совокупности,

$\min\{a;b\}$ — из величин a и b надо взять меньшую.

$$\sqrt{\frac{8,0091}{300 \times (\min\{2, 3\} - 1)}} = \sqrt{\frac{8,0091}{300 \times (2 - 1)}} = \sqrt{\frac{8,0091}{300}} = 0,1634$$

Значит, коэффициент корреляции Крамера будет равен 0,1634, так?

Хватит...



Как я уже говорил, коэффициент корреляции Крамера может принимать значение от 0 до 1. Чем теснее связаны две переменные, тем ближе коэффициент Крамера к 1, а чем слабее связь, тем ближе к 0.



Таблицы взаимной сопряжённости «Пола» и «Способа признания в любви»

Величина коэффициента Крамера равна 1

Пол респондента	Способ признания в любви, %			Итого
	по телефону	по SMS	при встрече	
женский	17	83	0	100
мужской	0	0	100	100

Величина коэффициента Крамера равна 1 \iff Предпочтения девушек и юношей совершенно различаются.

Величина коэффициента Крамера равна 0

Пол респондента	Способ признания в любви, %			Итого
	по телефону	по SMS	при встрече	
женский	17	48	35	100
мужской	17	48	35	100

Величина коэффициента Крамера равна 0 \iff Предпочтения девушек и юношей одинаковы



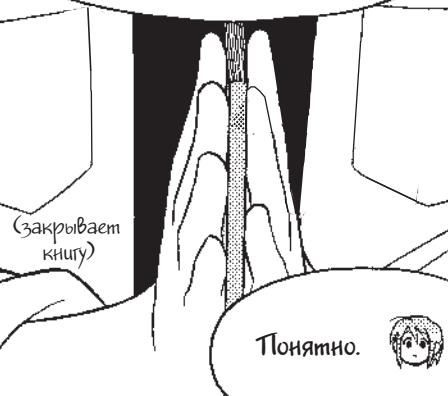
К сожалению, в статистике нет кого-то определённого значения коэффициента корреляции Крамера, свыше которого переменные считаются тесно связанными.

Для справки приведём таблицу соответствия коэффициента Крамера и степени взаимосвязи.

Критерии величины коэффициента корреляции Крамера

Коэффициент Крамера	Вывод о степени взаимосвязи	Вывод о наличии взаимосвязи
1,0—0,8	Очень тесная	Есть
0,8—0,5	Достаточно тесная	
0,5—0,25	Слабая	
< 0,25	Очень слабая	

Таким образом, можно сделать вывод, что данные в этом примере «очень слабо связаны».



На сегодня всё.



В конце сегодняшнего занятия я тебе говорил о коэффициенте корреляции Крамера. Нам это очень пригодится, когда на следующем занятии мы будем проводить проверку гипотезы о независимости.

Проверку независимости?

Проверка гипотезы о независимости — это способ, который часто используется при анализе результатов анкетирования.

Если ты усвоишь этот способ, можно считать, что основами статистики ты уже овладела.

Тогда следующий урок будет последним?

Ну,
в общем-то,
да.

Понято!

Упражнение

В последнее время положение дел в компании X, владеющей сетью семейных ресторанов, трудно назвать благополучным. Чтобы узнать пожелания клиентов, компания провела анкетирование, объектами которого стали произвольно выбранные жители Японии в возрасте старше 20 лет.

Результаты анкетирования представлены в виде следующей таблицы:

Респондент	Какую кухню Вы обычно заказываете в семейном ресторане?	Если после обеда будет предлагаться бесплатный напиток, Вы предпочтёте чай или кофе?
1	китайская	кофе
2	европейская	кофе
...
250	японская	чай

На основании этой таблицы был составлен один из вариантов таблицы взаимной сопряжённости:

Обычно заказываемая кухня	Предпочитаемый напиток		Итого
	Кофе	Чай	
Японская	43	33	76
Европейская	51	53	104
Китайская	29	41	70
Итого:	123	127	250

Вычислите коэффициент корреляции Крамера, чтобы установить взаимосвязь между «обычно заказываемой кухней» и «предпочитаемым напитком».

Решение

Шаг 1

Составим таблицу взаимной сопряжённости.

Обычно заказываемая кухня	Предпочитаемый напиток		Итого
	Кофе	Чай	
Японская	43	33	76
Европейская	51	53	104
Китайская	29	41	70
Итого:	123	127	250

Шаг 2

Вычислим теоретические частоты.

Обычно заказываемая кухня	Предпочитаемый напиток		Итого
	Кофе	Чай	
Японская	$\frac{76 \times 123}{250}$	$\frac{76 \times 127}{250}$	76
Европейская	$\frac{104 \times 123}{250}$	$\frac{104 \times 127}{250}$	104
Китайская	$\frac{70 \times 123}{250}$	$\frac{70 \times 127}{250}$	70
Итого:	123	127	250

Шаг 3

Вычислим:

$$\frac{\text{Эмпирическая частота} - \text{Теоретическая частота}}{\text{Теоретическая частота}}$$

Обычно заказываемая кухня	Предпочитаемый напиток		Итого
	Кофе	Чай	
Японская	$\left(43 - \frac{76 \times 123}{250}\right)^2$ $\frac{76 \times 123}{250}$	$\left(33 - \frac{76 \times 127}{250}\right)^2$ $\frac{76 \times 127}{250}$	76
Европейская	$\left(51 - \frac{104 \times 123}{250}\right)^2$ $\frac{104 \times 123}{250}$	$\left(53 - \frac{104 \times 127}{250}\right)^2$ $\frac{104 \times 127}{250}$	104
Китайская	$\left(29 - \frac{70 \times 123}{250}\right)^2$ $\frac{70 \times 123}{250}$	$\left(41 - \frac{70 \times 127}{250}\right)^2$ $\frac{70 \times 127}{250}$	70
Итого:	123	127	250

Шаг 4

Вычислим сумму величин в обведённых жирной чертой клетках таблицы на **Шаге 3**.

Иначе говоря,

вычислим значение критерия согласия Пирсона.

$$\begin{aligned}\chi^2_0 = & \frac{\left(43 - \frac{76 \times 123}{250}\right)^2}{\frac{76 \times 123}{250}} + \frac{\left(33 - \frac{76 \times 127}{250}\right)^2}{\frac{76 \times 127}{250}} \\ & + \frac{\left(51 - \frac{104 \times 123}{250}\right)^2}{\frac{104 \times 123}{250}} + \frac{\left(53 - \frac{104 \times 127}{250}\right)^2}{\frac{104 \times 127}{250}} \\ & + \frac{\left(29 - \frac{70 \times 123}{250}\right)^2}{\frac{70 \times 123}{250}} + \frac{\left(41 - \frac{70 \times 127}{250}\right)^2}{\frac{70 \times 127}{250}} \\ & = 3,3483\end{aligned}$$

Шаг 5

Вычисляем коэффициент корреляции Крамера по формуле:

$$\sqrt{\frac{\chi^2_0}{n \times (\min\{\text{кол-во строк в таблице; кол-во столбцов в таблице}\} - 1)}} = \sqrt{\frac{3,3483}{250 \times (\min\{3, 2\} - 1)}} = \sqrt{\frac{3,3483}{250 \times (2 - 1)}} = \sqrt{\frac{3,3483}{250}} = 0,1157$$

Выводы

- Коэффициент линейной корреляции является показателем тесноты связи между двумя количественными данными.
- Корреляционное отношение является показателем тесноты связи между количественными и качественными данными.
- Коэффициент корреляции Крамера является показателем тесноты связи между качественными данными.
- Перечисленные коэффициенты корреляции имеют следующие свойства:

Вид функции распределения вероятностей	Значение коэффициента корреляции		Отсутствие какой-либо связи между двумя переменными величинами	Переменные величины максимально тесно связаны
	max	min		
Коэффициент линейной корреляции	-1	1	0	-1 или 1
Корреляционное отношение	0	1	0	1
Коэффициент корреляции Крамера	0	1	0	1

- В статистике не существует какого-то определённого значения указанных коэффициентов корреляции, свыше которого переменные считаются тесно связанными.

Глава 7

А что это за проверка гипотезы о независимости?

1. Проверка гипотезы

Итак,
сегодня-
шнее
занятие...

Эй!
Почему бы не посмотреть
на меня!!

(Собирается)

Ну как!

(Тобка
шепчет)

Ох, извини.
Это новая форма?

Да! Это образец,
но Вам я покажу.

(Крутится)

О-о...
Тебе идёт.

Спасибо.

Ну, что
мы будем
сегодня
проходить?



Как ты думаешь,
какое будет значение
коэффициента
корреляции Крамера
для генеральной совокупности,
в которую входят
«все школьники Японии»?

М-м-м...
Откуда мне знать?...

К сожалению,
никто этого не знает.
Ответ можно дать
только при условии, ...

... что опросят
всех школьников
Японии.

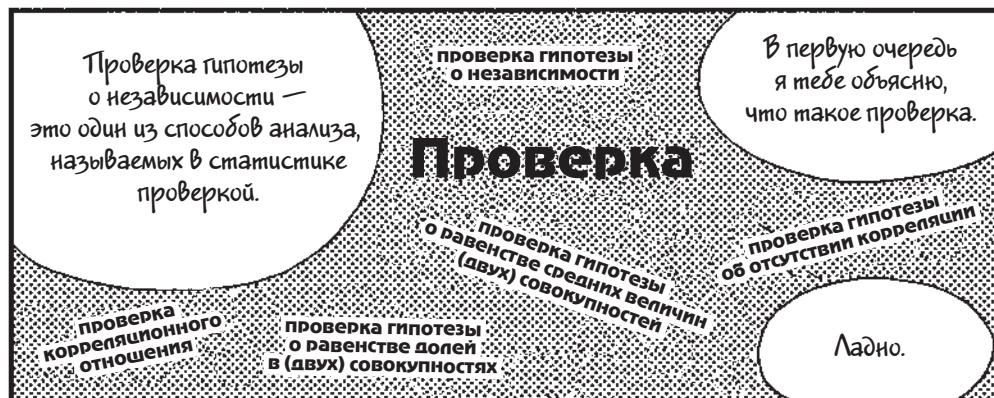
Понятно...

Это касается
не только данного примера.
Практически никогда
не удается определить
коэффициент корреляции
Крамера для всей
генеральной совокупности.

Поэтому, ...

... зная, что коэффициент корреляции Крамера, вычисленный на основе ответов, полученных от 300 школьников, произвольно выбранных из генеральной совокупности, равен 0,1634, считаем, что это значение соответствует коэффициенту корреляции Крамера для всей генеральной совокупности.





Проверка гипотезы — один из способов анализа, позволяющий на основе данных выборочной совокупности сделать вывод о справедливости гипотезы, которую выдвинул исследователь о генеральной совокупности.



Правильнее было бы сказать — это статистическая проверка гипотез.

А, вот это мне более понятно.



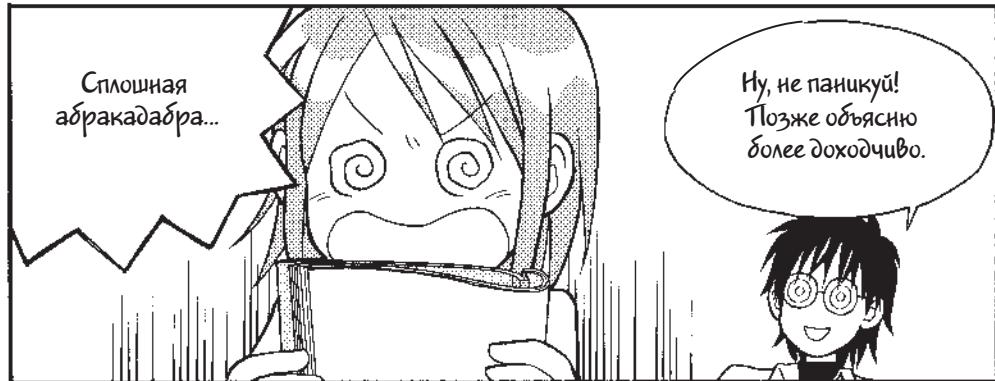
Есть разные виды проверяемых гипотез.

Гипотезы	Примеры проверяемых гипотез
	Примеры применения
О независимости	Проверяют, равняется ли нулю коэффициент корреляции Крамера между полом и способом признания в любви для генеральной совокупности.
О корреляционном отношении	Проверяют, равняется ли нулю корреляционное отношение между любимым брэндом одежды и возрастом для генеральной совокупности.
Об отсутствии корреляции	Проверяют, равняется ли нулю коэффициент линейной корреляции между расходами в месяц на косметику и расходами в месяц на одежду для генеральной совокупности.
О равенстве средних величин (двух) совокупностей	Проверяют, получают ли школьницы Токио и школьницы Осаки одну и ту же или разную сумму на карманные расходы. (Будьте внимательны: предполагаются две генеральные совокупности).
О равенстве долей в (двух) совокупностях	Проверяют, различается ли рейтинг кабинета министров среди избирателей, проживающих в городах, и избирателей из сельской местности. (Будьте внимательны: предполагаются две генеральные совокупности).



Порядок статистической проверки гипотез

Шаг 1.	Определить генеральную совокупность.
Шаг 2.	Сформулировать нулевую и альтернативную гипотезы.
Шаг 3.	Выбрать вид статистической проверки гипотезы.
Шаг 4.	Определить уровень значимости.
Шаг 5.	Вычислить фактическое значение выбранного статистического критерия на основе данных выборочной совокупности.
Шаг 6.	Проверить, входит ли вычисленное на Шаге 5 значение статистического критерия в критическую область.
Шаг 7.	Если фактическое значение выбранного статистического критерия (Шаг 6) входит в критическую область, делают вывод о том, что верна альтернативная гипотеза. В противном случае полагают, что нет оснований считать нулевую гипотезу ошибочной.



2. Проверка гипотезы о независимости

Объясню суть проверки гипотезы о независимости.
Сегодня — это главная тема.



Проверка гипотезы о независимости — один из способов анализа, проводимый с целью выяснить, не равен ли нулю коэффициент корреляции Крамера для генеральной совокупности.



Другими словами, это способ анализа, предполагающий наличие взаимосвязи между двумя переменными в таблице взаимной сопряжённости.

Поня-я-тно...

	34	61	53	148
	38	40	74	152
	72	101	127	

Проверка гипотезы о независимости называется также проверкой критерия согласия Пирсона χ^2 .

Опять этот χ^2 !
Ужасно...

Объяснение

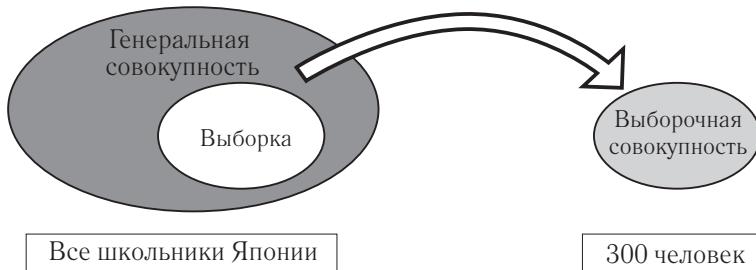
Критерий согласия Пирсона и распределение хи-квадрат



Перед тем, как объяснить проверку гипотезы о независимости на конкретном примере, расскажу о том, что лежит в основе такой проверки. Предположим, что провели следующее исследование (хотя в действительности это невозможно):

Шаг 1

Из генеральной совокупности, которой являются «школьники Японии», произвольно выбрали 300 человек.



Шаг 2

Среди выбранных 300 школьников провели анкетирование (см. стр. 127), а затем рассчитали величину критерия согласия Пирсона.

Шаг 3

Выбранных 300 школьников «вернули» в генеральную совокупность.

Шаг 3

Шаг 1 — Шаг 3 повторяли множество раз.

Функцией распределения критерия согласия Пирсона, полученной в этом исследовании, является распределение хи-квадрат с числом степеней свободы, равным 2, при условии, что коэффициент корреляции Крамера для генеральной совокупности «все школьники Японии» = 0. Другими словами, если коэффициент корреляции Крамера для генеральной совокупности «все школьники Японии» = 0, то критерий согласия Пирсона (χ^2_0) имеет хи-квадрат-распределение с числом степеней свободы, равным 2.

1. Способ вычисления критерия согласия Пирсона (χ^2_0) см. на стр. 130—133.
2. О распределении хи-квадрат с числом степеней свободы 2 см. на стр. 100.

Описанное выше исследование было проведено на самом деле, но с учётом следующих ограничений:



- Поскольку невозможно провести исследование среди всех школьников, живущих в Японии, считается, что генеральная совокупность «все школьники Японии» — это совокупность, состоящая из 10 000 человек, как указано в **Табл. 7.1**.
- Было сделано предположение, что коэффициент корреляции Крамера для совокупности «все школьники Японии» = 0. Другими словами, предположили, что ответы юношей и девушек на вопрос «Какой способ признания в любви вы предпочитаете?» (по телефону : по SMS : при встрече) одинаковы (см. стр. 135). Предположили также, что на основе **Табл. 7.1** была создана таблица взаимной сопряжённости.
- Исследования (Шаг 1 — Шаг 3) провели 20 тысяч раз.

Таблица 7.1. Какой способ признания в любви вы предпочитаете?
(все школьники Японии)

Респондент	Пол респондента	Способ признания в любви
1	ж	при встрече
2	ж	по телефону
...
10000	м	по SMS

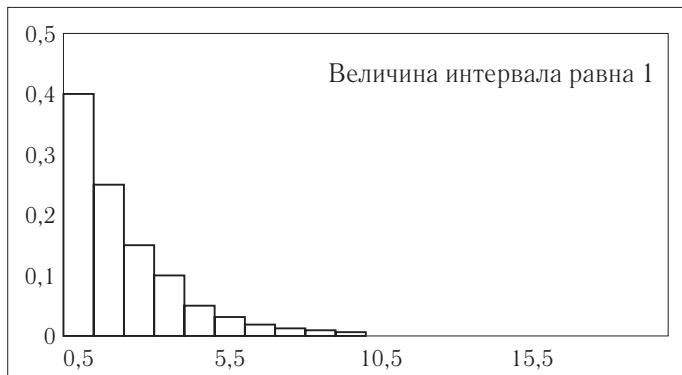
Таблица 7.2. Взаимная сопряжённость пола и способа признания в любви

Пол респондента	Способ признания в любви			Итого
	по телефону	по SMS	при встрече	
женский	400	1600	2000	4000
мужской	600	2400	3000	6000
Итого:	1000	4000	5000	10000

Таблица 7.3. Результаты исследования

Номер исследования	Критерий согласия Пирсона (χ^2_0)
1	0,8598
2	0,7557
...	...
20000	2,7953

Рис. 7.1. Гистограмма на основе данных Табл. 7.3



Действительно, Рис. 7.1 очень похож на график функции распределения вероятностей, когда число степеней свободы равно 2 (см. стр. 100). Нет сомнений, что величина критерия согласия Пирсона (χ^2_0) имеет хи-квадрат-распределение с числом степеней свободы 2. Это не имеет непосредственного отношения к исследованию, но я скажу вам одну очень важную вещь: число степеней свободы, равное 2, получается из выражения:

$$(2 - 1) \times (3 - 1) = 1 \times 2 = 2$$

два варианта:
девушки, юноши

три варианта:
по телефону, по SMS, при встрече



Почему такой страненный расчет? Ответ на этот вопрос выходит за рамки данной книги. Поэтому не беспокойтесь, если вы не до конца поняли этот способ расчёта.

Допустим, что коэффициент корреляции Крамера для совокупности «Все школьники Японии» = 0.

Другими словами, связи между полом и способом признания в любви не существует.

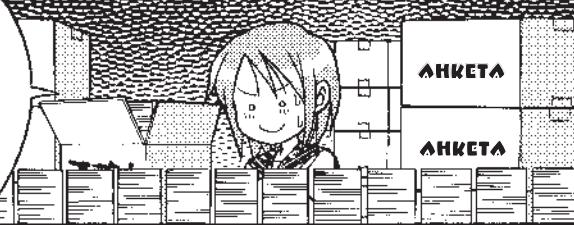
Предположим, что пропорции юношей и девушек предпочтений равны.



Возьмём анкеты 300 человек, выбранных из генеральной совокупности «Все школьники Японии»...



...затем следующие 300 человек, затем следующие, ... и так много раз.



Если вычислить величину критерия согласия Пирсона (χ^2_0), то окажется, ...

Найдём сумму клеток таблицы, вычисленных по формуле:
$$\frac{(\text{эмпирическая частота} - \text{теоретическая частота})^2}{\text{теоретическая частота}}$$



... что величина (χ^2_0) имеет распределение хи-квадрат с числом степеней свободы, равным 2!







Упражнение

Женский журнал «P-girls» решил провести опрос среди школьников по вопросу: «Какой способ признания в любви Вы предпочитаете?». Для этого кореспондент из всех школьников Японии произвольно выбрал 300 человек и провёл анкетирование. Результаты анкетирования представлены в виде следующей таблицы:

Респондент	Способ признания в любви	Возраст респондента	Пол респондента
1	при встрече	17	ж
2	по телефону	15	ж
... 300	по SMS	18	.. м

Таблица взаимной сопряжённости «пола» и «способа признания в любви»

Пол респондента	Способ признания в любви			Итого
	по телефону	по SMS	при встрече	
женский	34	61	53	148
мужской	38	40	74	152
Итого:	72	101	127	300

Выясните путём проверки гипотезы о независимости, больше ли 0 коэффициент корреляции Крамера между полом и способом признания в любви для генеральной совокупности «все школьники Японии». Другими словами, надо выяснить, есть ли взаимосвязь между полом и способом признания в любви. Предположим, что уровень значимости (объясню позже) равен 0,05.



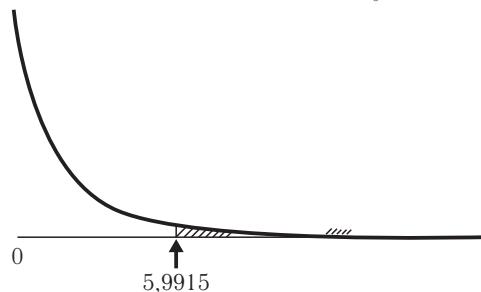


Размышление

Как уже было сказано (стр. 152—154), если коэффициент корреляции Крамера для генеральной совокупности «все школьники Японии» = 0, критерий согласия Пирсона (χ^2_0) имеет распределение хи-квадрат с числом степеней свободы, равным 2. Следовательно, если коэффициент корреляции Крамера = 0 для генеральной совокупности «все школьники Японии», вероятность того, что величина, полученная на основе данных, поступивших от случайно отобранных 300 школьников, будет, например, $> 5,9915$, равна 0,05. (см. Таблицу распределения хи-квадрат на стр. 103).



Рис. 7.2. Вероятность того, что $\chi^2_0 > 5,9915$.



Величина уже была вычислена и равняется 8,0091 (см. стр. 132).

Ну, как, не кажется ли вам, что величина слишком большая, хотя и вычислена на основе ответов, полученных от 300 человек, случайно выбранных из генеральной совокупности. Если поразмыслить, учитывая комментарий, данный на стр. 132, не естественно ли, что величина коэффициента корреляции Крамера для генеральной совокупности «все школьники Японии» > 0 ?

Не только в этом примере, но всегда при проверке гипотезы о независимости следует придерживаться следующей последовательности действий:

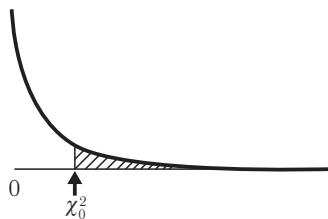
- 1) Сначала делают предположение, что коэффициент корреляции Крамера для генеральной совокупности = 0.
- 2) Затем рассчитывают величину χ^2_0 для выборочной совокупности.
- 3) Если χ^2_0 очень большой, делают вывод, что коэффициент корреляции Крамера для генеральной совокупности > 0 .



Это надо запомнить.

Добавлю кое-что к пункту 3. Чем больше величина χ^2_0 , тем меньше вероятность, т.е. площадь заштрихованной области на **Рис. 7.3**.

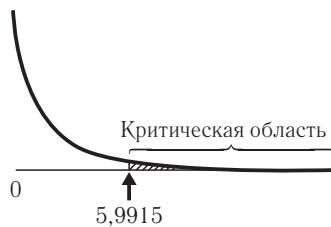
Рис. 7.3. Вероятность при определённом значении



Если при проверке гипотезы о независимости оказывается, что значение вероятности заштрихованной области меньше так называемого уровня значимости, делают вывод, что величина коэффициента корреляции Крамера для генеральной совокупности > 0 . Обычно в статистических исследованиях используют такой уровень значимости, как 0,05 или 0,01; выбор конкретного значения — прерогатива исследователя. Предположим, что выбрали значение уровня значимости, равное 0,05. В действительности, уровень значимости — это заштрихованная область на графике, показанном на **Рис. 7.3**.

При этом область, указанная на **Рис. 7.4**, называется критической областью.

Рис. 7.4. Критическая область при значении уровня значимости, равном 0,05





Выход

Порядок выполнения проверки

Шаг 1

Определяем генеральную совокупность.

Генеральная совокупность — это:

Все школьники Японии



В этом упражнении изначально определено, что генеральной совокупностью являются «Все школьники Японии». Поэтому нет необходимости выполнять Шаг 1.

Пример.

При проведении проверки гипотезы о равенстве долей в (двух) совокупностях (см. стр. 149) предполагалось, что генеральными совокупностями являются «избранные, проживающие в городах и в сельской местности». При этом необходимо уточнить, что подразумевается под городом — Токио и Осака? Или это столицы префектур? Решение этой проблемы остаётся за исследователем, поскольку это его прерогатива — определить, что будет представлять собой генеральная совокупность при проверке. Если чётко не выделить генеральную совокупность, при проведении любой проверки можно оказаться в ситуации: «Ой! Что же я хотел исследовать?!». Подобная ситуация наблюдается довольно часто, поэтому следует быть предельно внимательными.



Шаг 2

Выстраиваем нулевую и альтернативную гипотезы.

Нулевая гипотеза:

Коэффициент корреляции Крамера
для генеральной совокупности = 0.
«Пол» и «способ признания в любви»
не связаны.

Альтернативная гипотеза:

Коэффициент корреляции Крамера
для генеральной совокупности > 0.
«Пол» и «способ признания в любви»
связаны.



О нулевой и альтернативной гипотезах
расскажу позже.

Шаг 3

Выбирают вид гипотезы для статистической проверки.

Проведём проверку гипотезы о независимости.



В этом примере изначально решено было проводить проверку гипотезы о независимости. Поэтому нет необходимости выполнять Шаг 3. В действительности, когда проводят проверку, исследователь сам должен выбрать вид гипотезы с учётом целей анализа.

Шаг 4

Определяют уровень значимости.

Пусть уровень значимости будет равен 0,05.



Поскольку будет использоваться уровень значимости, равный 0,05, нет необходимости выполнять Шаг 4. В действительности при проведении проверки исследователь должен сам выбрать уровень значимости. Обычно это 0,05 или 0,01. Уровень значимости обозначается α (альфа).

Шаг 5

Вычисляют фактическое значение выбранного статистического критерия на основе данных выборочной совокупности.

Я собираюсь провести проверку гипотезы о независимости. Поэтому в качестве статистического критерия будет выступать критерий согласия Пирсона χ^2 . Для данного примера значение критерия Пирсона χ^2 уже вычислено и равно 8,0091 (см. стр. 132).



Выбранный статистический критерий — это формула, которая преобразует данные выборочной совокупности в одну величину. В зависимости от вида проверяемых гипотез выбираются разные критерии. В случае, когда проводят проверку гипотезы о независимости, критерием является величина, указанная выше, а в случае проведения проверки об отсутствии корреляции (см. стр. 149) критерием будет величина, рассчитываемая по формуле:

$$\frac{\text{линейный коэффициент корреляции}^2 \times \sqrt{\text{общее число единиц совокупности} - 2}}{\sqrt{1 - \text{линейный коэффициент корреляции}^2}}$$

Шаг 6

Выясняют, входит ли фактическое значение выбранного статистического критерия, вычисленное на Шаге 5, в критическую область.

Значение критерия согласия Пирсона χ^2_0 , который в данном примере является статистическим критерием, равняется 8,0091.

Так как уровень значимости равен 0,05, из Таблицы хи-квадрат-распределения (стр. 103) получаем, что критическая область больше, чем 5,9915.

Как следует из рисунка, значение выбранного статистического критерия входит в критическую область.



Критическая область меняется в зависимости от уровня значимости α . Если бы уровень значимости был бы равен 0,01, а не 0,05, то критическая область, как следует из Таблицы распределения хи-квадрат на стр. 103, была бы больше, чем 9,2104.

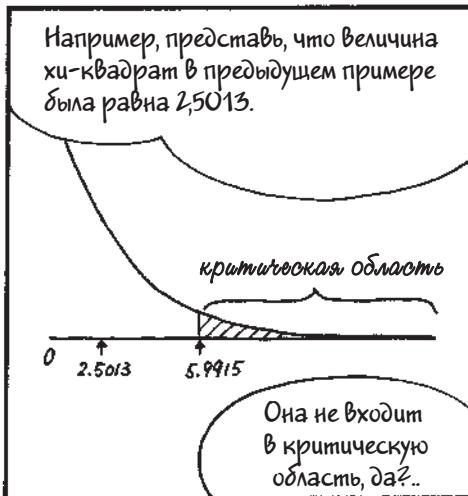
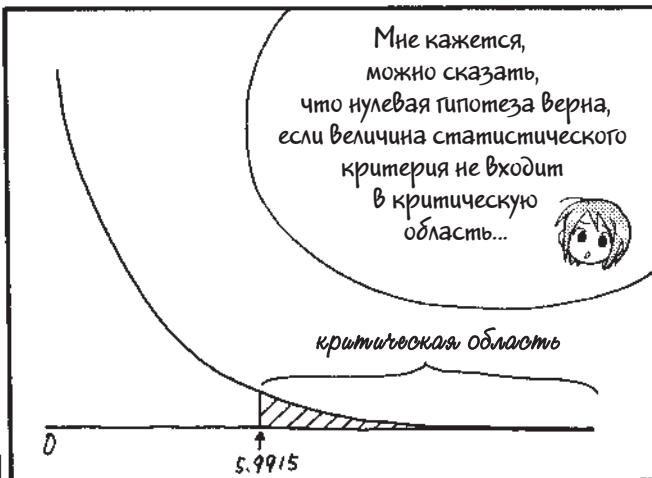
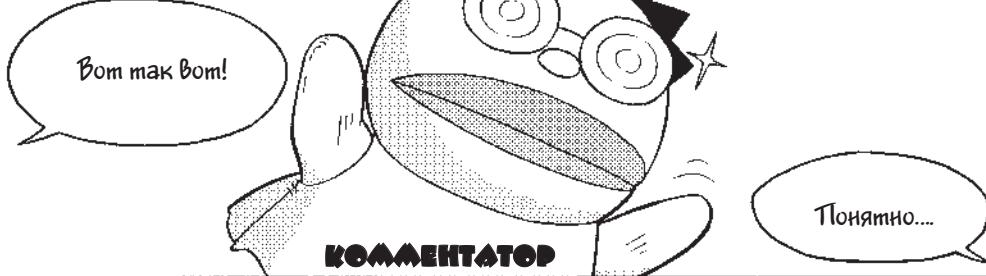
Шаг 7

Если значение статистического критерия входит в критическую область (Шаг 6), делают вывод, что «верна альтернативная гипотеза». В противном случае вывод таков: «нельзя утверждать, что нулевая гипотеза ошибочна».

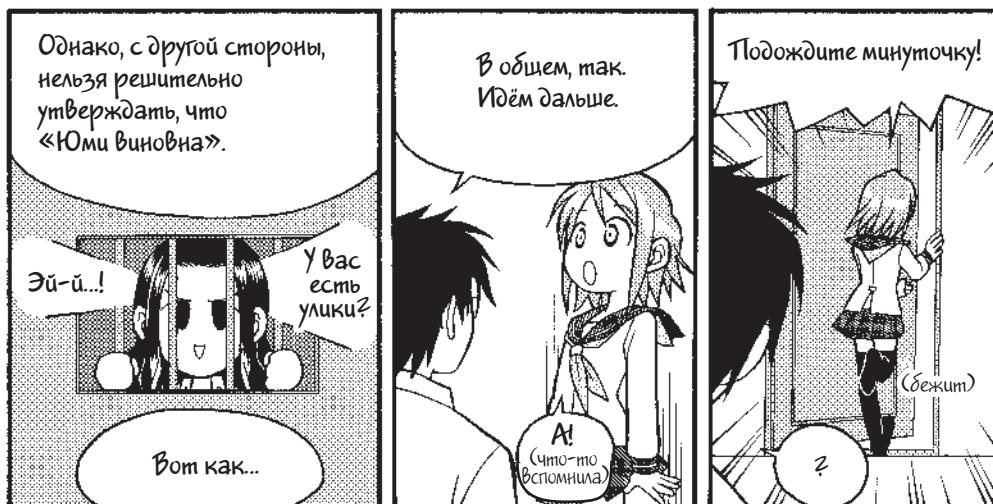
Значение выбранного статистического критерия
входит в критическую область. Следовательно,
верна альтернативная гипотеза —
Величина коэффициента корреляции Крамера
для генеральной совокупности > 0 .
«Пол» и «способ признания в любви» связаны!



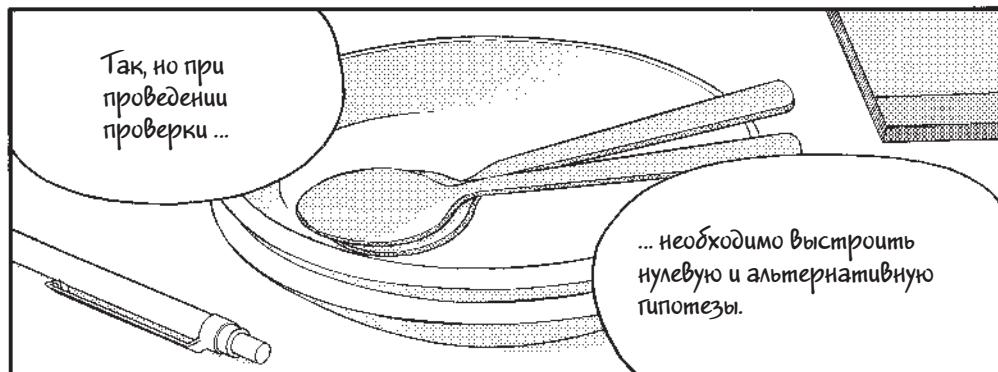
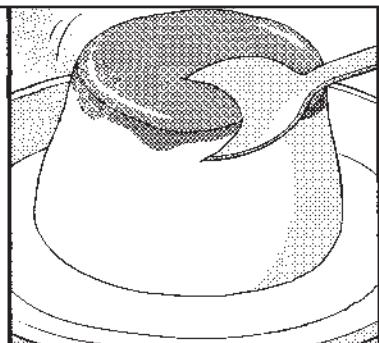
Даже если величина статистического критерия
входит в критическую область, нельзя на основе
проверки делать вывод, что
«альтернативная гипотеза **абсолютно верна**». Можему сделать лишь такой вывод: «хотелось бы
утверждать, что альтернативная гипотеза
абсолютно верна, но существует вероятность
($\alpha \times 100\%$) того, что верна нулевая гипотеза».







3. Нулевая и альтернативная гипотезы





Примеры проверяемых гипотез

Гипотезы	Примеры применения
О независимости	Проверяют, равняется ли нулю коэффициент корреляции Крамера между полом и способом признания в любви для генеральной совокупности.
О корреляционном отношении	Проверяют, равняется ли нулю корреляционное отношение между любимым брэндом одежды и возрастом для генеральной совокупности.
Об отсутствии корреляции	Проверяют, равняется ли нулю коэффициент линейной корреляции между расходами в месяц на косметику и расходами в месяц на одежду для генеральной совокупности.
О равенстве средних величин (двух) совокупностей	Проверяют, получают ли школьницы Токио и школьницы Осаки одну и ту же или разную сумму на карманные расходы. (Будьте внимательны: предполагаются две генеральные совокупности).
О равенстве долей в (двух) совокупностях	Проверяют, различается ли рейтинг кабинета министров среди избирателей, проживающих в городах, и избирателей из сельской местности. (Будьте внимательны: предполагаются две генеральные совокупности).

Вот таблица, которая нам уже знакома.
На основе этой таблицы я тебе всё и объясню.

Хорошо.

Проверка гипотезы о независимости

Нулевая гипотеза	Коэффициент корреляции Крамера между «полом» и «способом признания в любви» для генеральной совокупности = 0.
Альтернативная гипотеза	Коэффициент корреляции Крамера между «полом» и «способом признания в любви» для генеральной совокупности > 0.

Проверка гипотезы о корреляционном отношении

Нулевая гипотеза	Корреляционное отношение между «любимым брендом одежды» и «возрастом» для генеральной совокупности = 0.
Альтернативная гипотеза	Корреляционное отношение между «любимым брендом одежды» и «возрастом» для генеральной совокупности > 0.

Проверка гипотезы об отсутствии корреляции

Нулевая гипотеза	Коэффициент линейной корреляции между «расходами в месяц на косметику» и «расходами в месяц на одежду» для генеральной совокупности = 0.
Альтернативная гипотеза	Коэффициент линейной корреляции между «расходами в месяц на косметику» и «расходами в месяц на одежду» для генеральной совокупности ≠ 0. или Коэффициент линейной корреляции между «расходами в месяц на косметику» и «расходами в месяц на одежду» для генеральной совокупности > 0. или Коэффициент линейной корреляции между «расходами в месяц на косметику» и «расходами в месяц на одежду» для генеральной совокупности < 0.

Проверка гипотезы о равенстве средних величин (двух) совокупностей

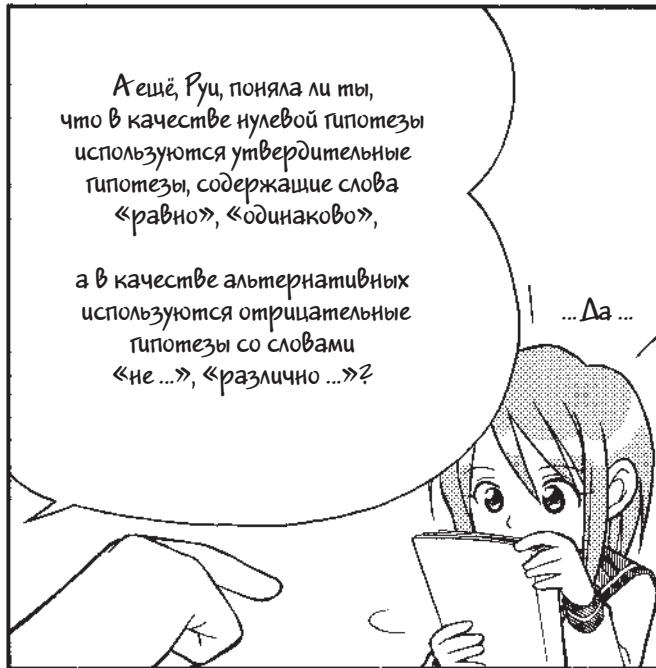
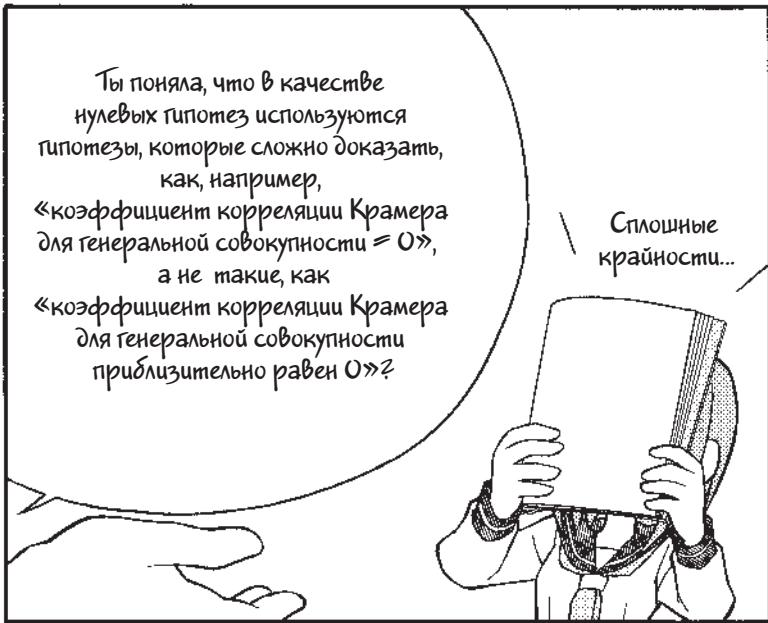
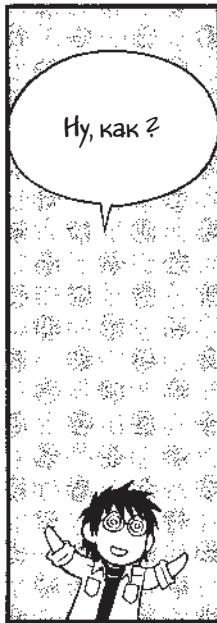
Нулевая гипотеза	«Суммы, получаемые на карманные расходы» школьницами Токио и школьницами Осаки, одинаковы.
Альтернативные гипотезы	«Суммы, получаемые на карманные расходы» школьницами Токио и школьницами Осаки, различны.
	«Сумма, получаемая на карманные расходы» школьницами Осаки, больше, чем сумма, получаемая школьницами Токио.
	«Сумма, получаемая на карманные расходы» школьницами Осаки меньше, чем сумма, получаемая школьницами Токио.

Проверка гипотезы о равенстве долей в (двух) совокупностях

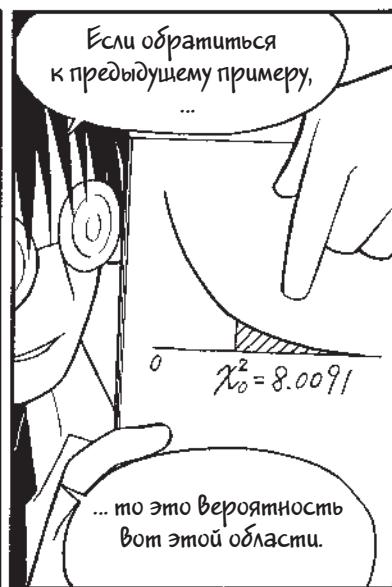
Нулевая гипотеза	Рейтинг кабинета министров среди избирателей, проживающих в городах и в сельской местности, одинаков.
Альтернативные гипотезы	Рейтинг кабинета министров среди избирателей, проживающих в городах и в сельской местности, различен.
	Рейтинг кабинета министров среди избирателей, проживающих в городах, выше, чем среди избирателей, проживающих в сельской местности.
	Рейтинг кабинета министров среди избирателей, проживающих в городах, ниже, чем среди избирателей, проживающих в сельской местности.

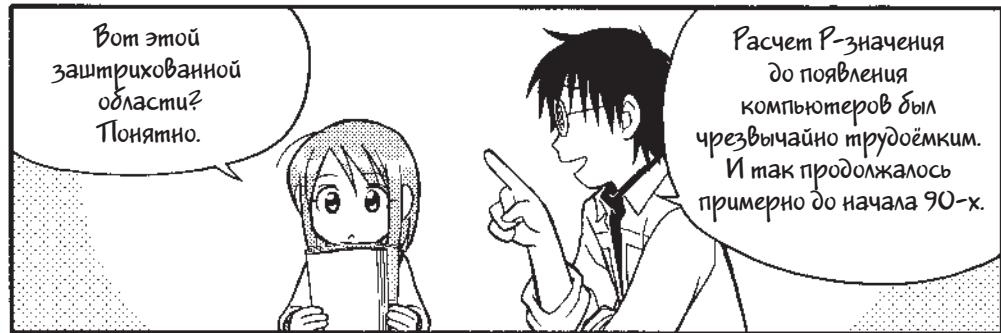
Понятно...





4. Р-значение и порядок проверки





Шаг 6

Выясняют, меньше ли Р-значение, соответствующее величине выбранного статистического критерия, вычисленного на **Шаге 5**, чем уровень значимости.

Уровень значимости равен 0,05.

Поскольку величина критерия согласия Пирсона равна 8,0091, Р-значение равно 0,0182 и, следовательно, $0,0182 < 0,05$.

Другими словами, Р-значение меньше, чем выбранный статистический критерий.



Как я уже говорил, Р-значение можно вычислить, используя функции Excel (но способ вычисления зависит от вида гипотезы).

Например, в Excel можно вычислить величину Р-значения для проверки гипотезы о независимости.

Подробное объяснение смотрите на стр. 208.

Шаг 7р

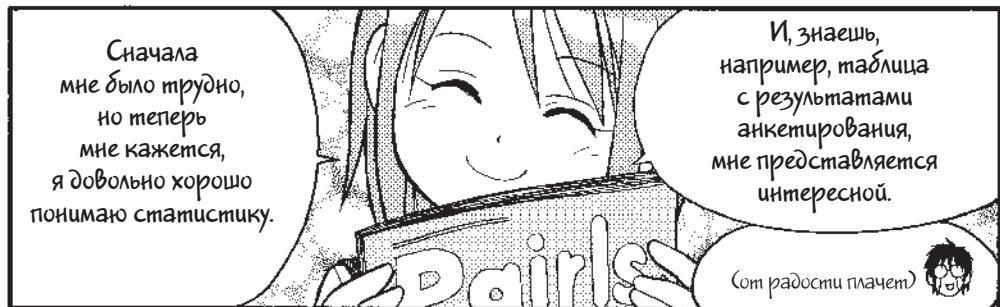
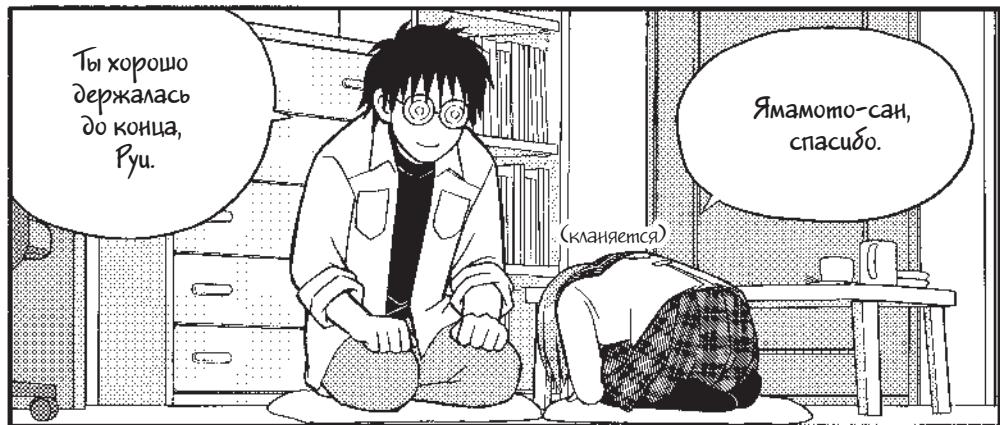
Если Р-значение меньше, чем уровень значимости (см. *Шаг 6р*), делают вывод, что «верна альтернативная гипотеза». В противном случае вывод такой: «нельзя утверждать, что нулевая гипотеза ошибочна».

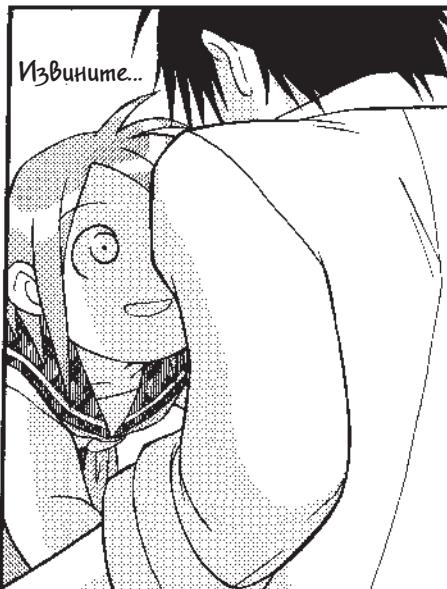
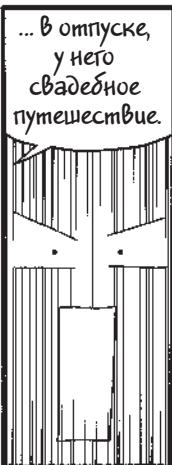
P-значение оказалось меньше уровня значимости.
Следовательно, верна альтернативная гипотеза:
«величина коэффициента корреляции Крамера
для генеральной совокупности > 0», т.е. «пол»
и «способ признания в любви» связаны!



Даже когда P-значение оказывается меньше уровня значимости, нельзя на основе проверки делать вывод, что «альтернативная гипотеза абсолютно верна». Можно сделать лишь такой вывод: «хотелось бы утверждать, что альтернативная гипотеза абсолютно верна, но существует вероятность ($\alpha \times 100\%$) того, что верна нулевая гипотеза».











Ямamoto-сан,
научите меня
ещё чему-нибудь!

И их занятия продолжились ...
... а может и нет.

5. Проверка гипотезы о независимости и гипотезы об однородности

Проверка гипотезы об однородности очень похожа на проверку гипотезы о независимости. Ниже приводится пример такой проверки. Попробуйте разобраться, в чём заключается разница между этими двумя проверками.

Упражнение

Женский журнал «P-girls» решил провести опрос школьников на тему «Какой способ признания в любви Вы предпочитаете:

- по телефону;
- по SMS;
- при встрече»?

Журнал выдвинул такую гипотезу:

Гипотеза:

пропорции ответов «по телефону» : «по SMS» : «при встрече» зависят от пола респондентов.

Чтобы выяснить, правильна ли эта гипотеза, журналист произвольно выбрал определённое число юношей и девушек из «всех школьников Японии» и провёл анкетирование. Результаты этого анкетирования приведены в следующей таблице:

Респондент	Способ признания в любви	Возраст респондента	Пол респондента
1	при встрече	17	ж
...
148	по SMS	16	ж
149	по телефону	15	м
...
300	по SMS	18	м

Таблица взаимной сопряжённости «пола» и «способа признания в любви»

Пол респондента	Способ признания в любви			Итого
	по телефону	по SMS	при встрече	
женский	34	61	53	148
мужской	38	40	74	152
Итого:	72	101	127	300

Проверьте правильность сформулированной гипотезы путём проверки гипотезы об однородности. Предположим, что уровень значимости равен 0,05.

Решение

1	Определим генеральную совокупность	Генеральных совокупностей будет две: «все школьницы Японии» и «все школьники Японии».
2	Сформулируем основную и противоположную гипотезы	Нулевая гипотеза: «пропорции предпочтительных способов признания в любви — по телефону : по SMS : при встрече — у школьниц и школьников одинаковы». Альтернативная гипотеза: «пропорции предпочтительных способов признания в любви — по телефону : по SMS : при встрече — у школьниц и школьников различны».
3	Выбираем вид гипотезы для статистической проверки	Проведём проверку гипотезы об однородности.
4	Определим уровень значимости	Пусть уровень значимости равен 0,05.
5	Вычислим фактическое значение выбранного статистического критерия на основе данных выборочной совокупности	В этом упражнении будет проведена проверка гипотезы об однородности. Следовательно, статистическим критерием будет критерий согласия Пирсона. Величина была уже вычислена и равна 8,0091 (см. стр. 132). Если нулевая гипотеза верна, критерий согласия Пирсона имеет распределение хи-квадрат с числом степеней свободы, равным $(2 - 1) \times (3 - 1) = 1 \times 2 = 2$.
6	Проверим, входит ли значение вычисленного на Шаге 5 статистического критерия в критическую область	Величина критерия согласия Пирсона, который является статистическим критерием, равна 8,0091. Так как уровень значимости = 0,05, критическая область, как следует из таблицы распределения хи-квадрат на стр. 103, больше 5,9915. Это значит, что значение статистического критерия входит в критическую область.
7	Если значение статистического критерия входит в критическую область (Шаг 6), делают вывод: «верна альтернативная гипотеза». Если нет, — «нельзя утверждать, что нулевая гипотеза ошибочна»	Значение статистического критерия входит в критическую область. Следовательно, верна альтернативная гипотеза: «пропорции предпочтительных способов признания в любви — по телефону : по SMS : при встрече — у школьниц и школьников различны».

Как вам? И упражнение, и ответ как две капли воды похожи на проверку гипотезы о независимости. Давайте уточним, чем же отличается проверка гипотезы о независимости от проверки гипотезы об однородности.

Во-первых, определённые нами генеральные совокупности разные. В проверке гипотезы о независимости генеральная совокупность только одна — «все школьники Японии», а в проверке гипотезы об однородности генеральных совокупностей две: «все школьницы Японии» и «все школьники Японии».

Во-вторых, нулевые и альтернативные гипотезы разные. При проверке гипотезы о независимости были сформулированы следующие гипотезы:

Нулевая гипотеза	Коэффициент корреляции Крамера для генеральной совокупности = 0 и, значит, «пол» и «способ признания в любви» не связаны.
Альтернативная гипотеза	Коэффициент корреляции Крамера для генеральной совокупности > 0 и, значит «пол» и «способ признания в любви» связаны.

а при проверке гипотезы об однородности были сформулированы гипотезы:

Нулевая гипотеза	Пропорции предпочтительных способов признания в любви — по телефону : по SMS : при встрече — у школьниц и школьников одинаковы.
Альтернативная гипотеза	Пропорции предпочтительных способов признания в любви — по телефону : по SMS : при встрече — у школьниц и школьников различны.

К тому же, гипотезы формулировались в разные моменты: в случае проверки гипотезы о независимости — после сбора данных, а в случае проверки гипотезы об однородности — до сбора данных. Однако, несмотря на очевидные различия на практике часто бывает так: собираются проводить проверку гипотезы о независимости, а на деле проводят проверку гипотезы об однородности или наоборот.
Будьте внимательны!

6. Как выразить словами вывод на основании проверки

Вывод, полученный на основании проверки, формулируется следующим образом:

Если величина статистического критерия входит в критическую область, делают вывод о том, что верна альтернативная гипотеза. В противном случае вывод таков: «нельзя утверждать, что нулевая гипотеза ошибочна».

На самом деле такие выражения для формулирования вывода не используются. Различные выражения, которые действительно используются для формулирования вывода, сделанного на основе результатов статистической проверки, приведены в Табл. 7.4.

Таблица 7.4. Выражения, используемые для формулирования выводов на основе проверки

Случай, когда величина статистического критерия входит в критическую область	Случай, когда величина статистического критерия не входит в критическую область
<ul style="list-style-type: none">● верна альтернативная гипотеза● альтернативная гипотеза значима● нулевая гипотеза отвергается	<ul style="list-style-type: none">● нельзя утверждать, что нулевая гипотеза ошибочна● нельзя отвергнуть нулевую гипотезу● нулевая гипотеза отклонена● нельзя утверждать, что нулевая гипотеза верна● нулевая гипотеза принимается

Выражения «гипотеза значима» и «гипотеза отвергнута» используются достаточно часто. Вместе с тем я специально использовал формулировки, которые, как правило, не используются. Объясняю почему. Я заметил, что среди начинающих изучать статистическую проверку гипотез, есть такие, которые часто говорят «гипотеза значима», причём не очень хорошо понимая, какой смысл имеет данное выражение. Очевидно, они используют это выражение только потому, что уверены в величине Р-значения и получили значение статистического критерия. Другими словами, они проводят статистическую проверку гипотез, не сформулировав чётко нулевую и альтернативную гипотезы. И, как мне кажется, генеральная совокупность также чётко не определена. Я раньше полагал, что не следует делать замечания начинающим постигать премудрости статистической проверки гипотез. Однако без чётко выстроенных гипотез невозможно сделать какой-либо вывод.

В связи с этим я использую такие выражения, как «верна альтернативная гипотеза» и «нельзя утверждать, что основная гипотеза ошибочна». Это позволит читателю понять и усвоить, что такое нулевая и альтернативная гипотезы.

Упражнение

Таблица взаимной сопряжённости (см. стр. 138).

Обычно заказываемая кухня	Предпочитаемый напиток		Итого
	Кофе	Чай	
Японская	43	33	76
Европейская	51	53	104
Китайская	29	41	70
Итого:	123	127	250

Выясните путём проверки гипотезы о независимости, больше ли 0 коэффициент корреляции Крамера между видом обычно заказываемой кухни и предпочитаемым напитком для генеральной совокупности «жители Японии старше 20 лет». Другими словами, есть ли взаимосвязь между видом обычно заказываемой кухни и предпочитаемым напитком? Пусть уровень значимости равен 0,01.

Ответ

1	Определим генеральную совокупность	Генеральной совокупностью будут «жители Японии старше 20 лет»
2	Сформулируем нулевую и альтернативную гипотезы	Основная гипотеза: «вид обычно заказываемой кухни и предпочитаемый напиток не связаны». Альтернативная гипотеза: «вид обычно заказываемой кухни и предпочитаемый напиток взаимосвязаны».
3	Выбираем вид гипотезы	Проведём проверку гипотезы о независимости.
4	Определим уровень значимости	Пусть уровень значимости равен 0,01.
5	Вычислим фактическое значение выбранного статистического критерия на основе данных выборочной совокупности	В этом упражнении будет проведена проверка гипотезы о независимости. Следовательно, статистическим критерием будет являться критерий согласия Пирсона. Величина была вычислена ранее и равна 3,34839 (см. стр. 141)
6	Проверим, входит ли значение вычисленного на Шаге 5 статистического критерия в критическую область	Величина критерия согласия Пирсона, являющегося статистическим критерием, равна 3,3483. Так как уровень значимости $\alpha = 0,01$, критическая область, как следует из таблицы распределения хи-квадрат на стр. 103, больше 9,2104. Это значит, что значение статистического критерия не входит в критическую область.
7	Если значение статистического критерия входит в критическую область (Шаг 6), делают вывод: «верна альтернативная гипотеза». Если нет — «нельзя утверждать, что нулевая гипотеза ошибочна».	Значение статистического критерия не входит в критическую область. Следовательно, нельзя утверждать, что нулевая гипотеза: «вид обычно заказываемой кухни и предпочитаемый напиток не связаны» ошибочна.

Выводы

- Проверка — один из способов анализа, который позволяет установить, правильна ли гипотеза, сделанная исследователем о генеральной совокупности на основе данных выборочной совокупности.
- Такая проверка называется статистической проверкой гипотез.
- Статистический критерий — формула, с помощью которой преобразуются данные выборочной совокупности.
- Обычно используются такие значения уровня значимости, как 0,05 или 0,01.
- Критическая область — область значений, соответствующая определённому уровню значимости.
- Проверка гипотезы о независимости — один из способов анализа, который позволяет выяснить, не равен ли 0 коэффициент корреляции Крамера для генеральной совокупности. Можно также сказать, что такой анализ позволяет выяснить, есть ли связь между двумя переменными в таблице взаимной сопряжённости.
- Если коэффициент корреляции Крамера для генеральной совокупности равен 0, величина критерия согласия Пирсона имеет распределение хи-квадрат.
- Р-значение в случае проверки гипотезы о независимости при условии, что нулевая гипотеза верна, — вероятность того, что критерий согласия Пирсона χ^2_0 больше или равен наблюдаемой величины.
- Сделать вывод о проверке можно на основании того, что:
 - 1) значение статистического критерия входит в критическую область, либо
 - 2) Р-значение меньше уровня значимости.
- Будь то проверка гипотезы о независимости или любая другая проверка, порядок проведения анализа один и тот же, при этом он предусматривает выполнение следующих действий:

Шаг 1	Определить генеральную совокупность.
Шаг 2	Сформулировать нулевую и альтернативную гипотезы.
Шаг 3	Выбрать вид статистической проверки гипотезы.
Шаг 4	Определить уровень значимости.
Шаг 5	Вычислить фактическое значение выбранного статистического критерия на основе данных выборочной совокупности.
Шаг 6	Проверить, входит ли вычисленное на Шаге 5 значение статистического критерия в критическую область.
Шаг 7	Если Р-значение меньше, чем уровень значимости (см. Шаг бр), то делают вывод о том, что верна альтернативная гипотеза. Если нет, то вывод «нельзя утверждать, что нулевая гипотеза ошибочна».
Шаг бр	Проверить, меньше ли Р-значение, соответствующее величине выбранного статистического критерия, вычисленного на Шаге 5, чем уровень значимости.

Приложение

**Попробуем
вычислить
с помощью
Excel**

В этой главе объясняется, как с помощью программы Excel:

1. Построить таблицу (ряд) распределения.
2. Вычислить среднее значение, медиану и стандартное отклонение.
3. Составить простую статистическую таблицу.
4. Вычислить нормированное отклонение и рассчитать Т-показатель.
5. Вычислить вероятность стандартного нормального распределения.
6. Вычислить значение х при распределении хи-квадрат.
7. Вычислить коэффициент линейной корреляции.
8. Проверить гипотезу о независимости.

Файлы Excel можно загрузить по адресу <http://www.dodeca.ru/books/33081.php>.

Читателю, не имеющему опыта работы в Excel, рекомендуется сначала попробовать вычислить среднее значение, медиану и стандартное отклонение (см. стр. 195).

1. Построение таблиц распределения

Используются данные со стр. 33.

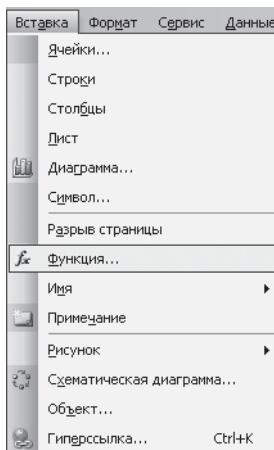
Шаг 1

Выберите ячейку J3.

1	А	В	С	Д	Е	F	Г	Н	I	J
	Ресторан	Цена, юань		Ресторан	Цена, юань		от	до	меньше	частота
2	ресторан 1	700		ресторан 26	780					
3	ресторан 2	850		ресторан 27	590		500	600	599	
4	ресторан 3	600		ресторан 28	650		600	700	699	
5	ресторан 4	650		ресторан 29	580		700	800	799	
6	ресторан 5	980		ресторан 30	750		800	900	899	
7	ресторан 6	750		ресторан 31	800		900	1000	999	
8	ресторан 7	500		ресторан 32	550					
9	ресторан 8	890		ресторан 33	750					
10	ресторан 9	880		ресторан 34	700					
11	ресторан 10	700		ресторан 35	600					
12	ресторан 11	890		ресторан 36	800					
13	ресторан 12	720		ресторан 37	800					
14	ресторан 13	680		ресторан 38	880					
15	ресторан 14	650		ресторан 39	790					
16	ресторан 15	790		ресторан 40	790					
17	ресторан 16	670		ресторан 41	780					
18	ресторан 17	680		ресторан 42	600					
19	ресторан 18	900		ресторан 43	670					
20	ресторан 19	880		ресторан 44	680					
21	ресторан 20	720		ресторан 45	650					
22	ресторан 21	850		ресторан 46	890					
23	ресторан 22	700		ресторан 47	930					
24	ресторан 23	780		ресторан 48	650					
25	ресторан 24	850		ресторан 49	777					
26	ресторан 25	750		ресторан 50	700					

Шаг 2

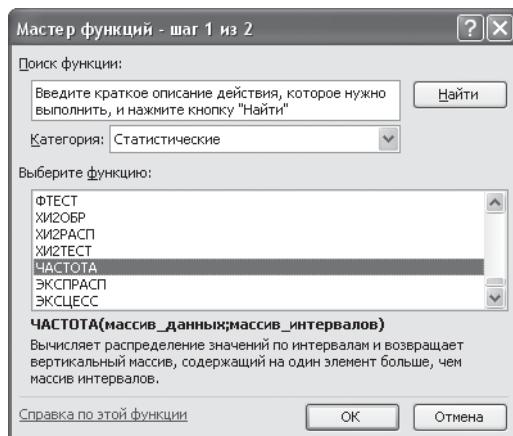
Выберите Вставка ▶ Функция.



Шаг 3

Выберите Статистические в строке Категория, а затем ЧАСТОТА* в графе Выберите функцию.

* FREQUENCY в английской версии Excel.



Шаг 4

Выделите нижеуказанную область и нажмите кнопку **OK**.

A	B	C	D	E	F	G	H	I	J
1	Ресторан	Цена, иены	Ресторан	Цена, иены					
2	ресторан 1	700	ресторан 26	780		от	до	меньше	частота
3	ресторан 2	850	ресторан 27	590		500	600	599	{6;599;13;17}
4	ресторан 3	600	ресторан 28	650		600	700	699	
5	ресторан 4	650	ресторан 29	580		700	800	799	
6	ресторан 5	980	ресторан 30	750		800	900	899	
7	ресторан 6	750	ресторан 31	800		900	1000	999	
8	ресторан 7	500	ресторан 32	550					

рест Аргументы функции ×

рест ЧАСТОТА

рест Массив_данных B2:E26 = {700;0;"ресторан 2"}
рест Массив_интервалов I3:I7 = {599;699;799;899;9}

рест = {4;13;18;12;3;0}

рест Вычисляет распределение значений по интервалам и возвращает вертикальный массив, содержащий на один элемент больше, чем массив интервалов.

рест

рест Массив_интервалов массив интервалов или ссылка на интервалы, в которых группируются значения из массива данных.

рест Справка по этой функции Значение: 4 OK Отмена

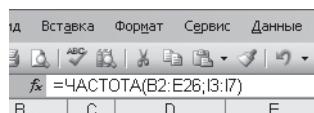
Шаг 5

Выделите ячейки, начиная с ячейки J3 и до ячейки J7.

G	H	I	J
от	до	меньше	частота
500	600	599	4
600	700	699	
700	800	799	
800	900	899	
900	1000	999	

Шаг 6

Щелкните мышью на области в строке формул.



Шаг 7

Нажмите комбинацию клавиш **Shift + Ctrl** и, удерживая ее в нажатом состоянии, нажмите клавишу **Enter**.

Шаг 8

Вычисление закончено!

G	H	I	J
от	до	меньше	частота
500	600	599	4
600	700	699	13
700	800	799	18
800	900	899	12
900	1000	999	3

2. Вычисление среднего значения, медианы и стандартного отклонения

Используются данные со стр. 41.

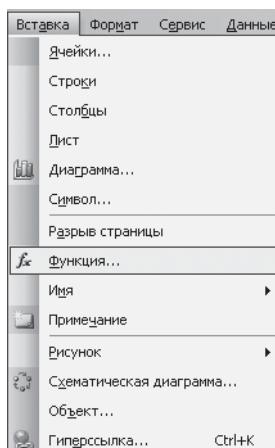
Шаг 1

Выберите ячейку B10.

A	B	C
1		Команда А
2	Руи-Руи	86
3	Дзюн	73
4	Юми	124
5	Сизука	111
6	Токо	90
7	Каэдэ	38
8		
9		
10	среднее	
11	медиана	
12	отклонение	
13		

Шаг 2

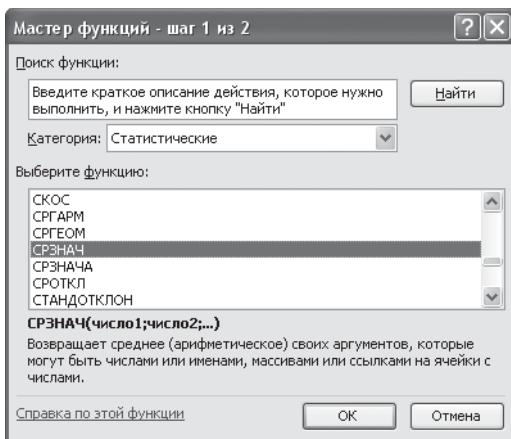
Выберите Вставка > Функция.



Шаг(3)

Выберите **Статистические** в строке **Категория**, и **СРЗНАЧ*** в графе **Выберите функцию**.

* AVERAGE в английской версии Excel.



Шаг(4)

Выделите нижеуказанную область и нажмите кнопку **OK**.

A	B	C	D	E	F	G	H	I	J	K
1		Команда А								
2	Руи-Руи	86								
3	Дзюн	73								
4	Юми	124								
5	Сизука	111								
6	Токо	90								
7	Каздз	38								
8										
9										
10	среднее	=AVERAGE(B2:B7)								
11	медиана									
12	отклонение									
13										
14										
15										
16										
17										
18										

The 'Аргументы функции' (Function Arguments) dialog box is open over the spreadsheet. It shows 'СРЗНАЧ' selected. The 'Число1' field contains 'B2:B7'. The 'Число2' field is empty. Below the fields is the description: 'Возвращает среднее (арифметическое) своих аргументов, которые могут быть числами или именами, массивами или ссылками на ячейки с числами.' At the bottom are 'Справка по этой функции' and 'Значение: 87' buttons, along with 'OK' and 'Отмена'.

Шаг(5)

Вычисление закончено!

A	B	
1	Команда А	
2	Руи-Руи	86
3	Дзюн	73
4	Юми	124
5	Сизука	111
6	Токо	90
7	Каздз	38
8		
9		
10	среднее	87
11	медиана	
12	отклонение	
13		

Шаг 6

Вычислите медиану и стандартное отклонение, выполняя последовательно Шаг 1 — Шаг 5. При вычислении медианы выберите **МЕДИАНА*** в графе **Выберите функцию**, а при вычислении стандартного отклонения — **СТАНДОТКЛОНП****.

* MEDIAN в английской версии Excel.

** STDEVP в английской версии Excel.

3. Построение простой статистической таблицы

Используются данные со стр. 61.

Шаг 1

Выберите ячейку F20.

	A	B	C	D	E	F	G	H
1		Новая форма...			Новая форма...			Новая форма...
2	1	нравится		16	так себе		31	так себе
3	2	так себе		17	нравится		32	так себе
4	3	нравится		18	нравится		33	нравится
5	4	так себе		19	нравится		34	не нравится
6	5	не нравится		20	нравится		35	нравится
7	6	нравится		21	нравится		36	нравится
8	7	нравится		22	нравится		37	нравится
9	8	нравится		23	не нравится		38	нравится
10	9	нравится		24	так себе		39	так себе
11	10	нравится		25	нравится		40	нравится
12	11	нравится		26	нравится			
13	12	нравится		27	не нравится			
14	13	так себе		28	нравится			
15	14	нравится		29	нравится			
16	15	нравится		30	нравится			
17								
18								
19						частота		
20					нравится			
21					так себе			
22					не нравится			
23								

Шаг 2

Выберите пункт **Вставка ▶ Функция**.

Шаг 3

Выберите **Статистические** в строке **Категория**, а затем **СЧЕТЕСЛИ*** в графе **Выберите функцию**.

* COUNTIF в английской версии Excel.

Шаг 4

Выделите указанную ниже область, напишите
нравится в графе Критерий и нажмите кнопку **OK**.

A	B	C	D	E	F	G	H	I
1	Новая форма...			Новая форма...				
2	Аргументы функции							
3	СЧЁТЕСЛИ							
4	Диапазон A2:H16				= {1;"нравится";0;16};			
5	Критерий нравится				=			
6	= 0							
7	Подсчитывает количество непустых ячеек в диапазоне, удовлетворяющих заданному условию.							
8								
9								
10								
11								
12	Критерий условие в форме числа, выражения или текста, который определяет, какие ячейки надо подсчитывать.							
13								
14								
15								
16								
17	Справка по этой функции		Значение:0		OK		Отмена	
18								
19					частота			
20				нравится	авится)			
21				так себе				
22				не нравится				
23								

Шаг 5

Вычисление
закончено!

A	B	C	D	E	F	G	H
1	Новая форма...			Новая форма...			Новая форма...
2	1	нравится	16	так себе	31	так себе	
3	2	так себе	17	нравится	32	так себе	
4	3	нравится	18	нравится	33	нравится	
5	4	так себе	19	нравится	34	не нравится	
6	5	не нравится	20	нравится	35	нравится	
7	6	нравится	21	нравится	36	нравится	
8	7	нравится	22	нравится	37	нравится	
9	8	нравится	23	не нравится	38	нравится	
10	9	нравится	24	так себе	39	так себе	
11	10	нравится	25	нравится	40	нравится	
12	11	нравится	26	нравится			
13	12	нравится	27	не нравится			
14	13	так себе	28	нравится			
15	14	нравится	29	нравится			
16	15	нравится	30	нравится			
17							
18							
19				частота			
20				нравится	28		
21				так себе			
22				не нравится			
23							

Шаг 6

Выполняя последовательно Шаг 1 — Шаг 5, подсчитайте частоту ответов «так себе» и «не нравится».

4. Вычисление нормированного отклонения и рейтинга успеваемости

Используются данные со стр. 72.

Функция для расчета нормированного отклонения в Excel есть, а функции для расчета рейтинга успеваемости (Т-показателя) нет.

Несмотря на это, можно довольно быстро вычислить рейтинг успеваемости, используя результат вычисления нормированного отклонения.

Поэтому в данной книге считается, что рейтинг успеваемости можно рассчитать в Excel.

4.1. Вычисление нормированного отклонения

Шаг 1

Выберите ячейку E2.

	История		Нормированное отклонение	Рейтинг успеваемости
2	Руи	73	Руи	
3	Юми	61	Юми	
4	А	14	А	
5	Б	41	Б	
6	В	49	В	
7	Г	87	Г	
8	Д	69	Д	
9	Е	65	Е	
10	Ж	36	Ж	
11	З	7	З	
12	И	53	И	
13	К	100	К	
14	Л	57	Л	
15	М	45	М	
16	Н	56	Н	
17	О	34	О	
18	П	37	П	
19	Р	70	Р	
20	Среднее	53		
21	Отклонение	22.7		

Шаг 2

Выберите Вставка ▶ Функция.

Шаг 3

Выберите Статистические в строке Категория, а затем НОРМАЛИЗАЦИЯ* в графе Выберите функцию.

* STANDARDIZE в английской версии Excel.

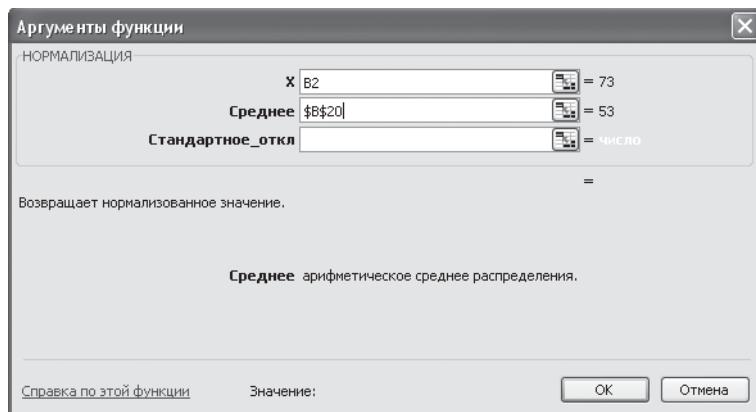
Шаг(4)

Выберите ячейку B2.

	A	B	C	D	E	F	G	H	I	J
1		История			Нормированное отклонение	Рейтинг успеваемости				
2	Руи	73		Руи	13АЦИЯ(B2)					
3	Юми	61								
4	А	14								
5	Б	41								
6	В	49								
7	Г	87								
8	Д	69								
9	Е	65								
10	Ж	36								
11	З	7								
12	И	53								
13	К	100								
14	Л	57								
15	М	45								
16	Н	56								
17	О	34								
18	П	37								
19	Р	70								
20	Среднее	53								
21	Отклонение	22.7								

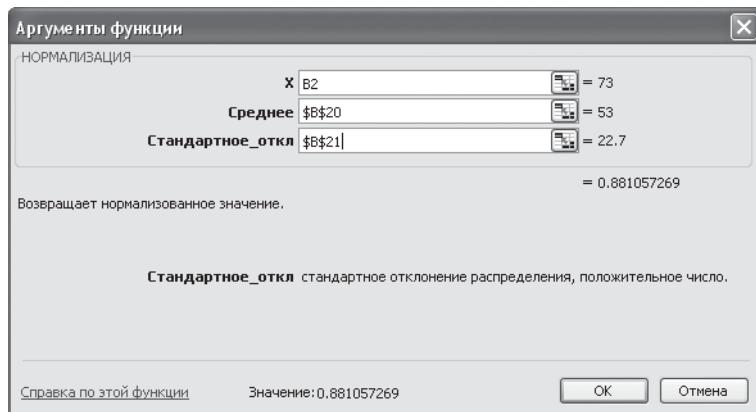
Шаг(5)

Выберите ячейку B20 в графе Среднее и нажмите клавишу F4.
Убедитесь, что B20 в графе Среднее превратилось в \$B\$20.



Шаг 6

Выберите ячейку **B21** в графе **Стандартное_откл** и нажмите клавишу **F4**. Убедитесь, что **B21** в графе **Стандартное_откл** превратилось в **\$B\$21** и нажмите кнопку **OK**.

**Шаг 7**

Убедитесь, что было вычислено нормированное отклонение Руи.

	A	B	C	D	E	F
1		История			Нормированное отклонение	Рейтинг успеваемости
2	Руи	73		Руи	0.88	
3	Юми	61		Юми		
4	А	14		А		
5	Б	41		Б		
6	В	49		В		
7	Г	87		Г		
8	Д	69		Д		
9	Е	65		Е		
10	Ж	36		Ж		
11	З	7		З		
12	И	53		И		
13	К	100		К		
14	Л	57		Л		
15	М	45		М		
16	Н	56		Н		
17	О	34		О		
18	П	37		П		
19	Р	70		Р		
20	Среднее	53				
21	Отклонение	22.7				
...						

Шаг 8

Подведите указатель мыши к правому углу ячейки E2, и как только он превратится в чёрный крестик, нажмите клавишу мыши и, удерживая её в нажатом состоянии, растяните область до ячейки E19; отпустите клавишу мыши.

D	E	F
	Нормированное отклонение	Рейтинг успеваемости
Руи	0.88	
Юми		
А		
Б		
В		
Г		
Д		
Е		
Ж		
З		
И		
К		
Л		
М		
Н		
О		
П		
Р		

Шаг 9

Вычисление нормированного отклонения закончено!

D	E	F
	Нормированное отклонение	Рейтинг успеваемости
Руи	0.88	
Юми	0.35	
А	-1.71	
Б	-0.53	
В	-0.18	
Г	1.49	
Д	0.70	
Е	0.53	
Ж	-0.75	
З	-2.02	
И	0.00	
К	2.07	
Л	0.18	
М	-0.35	
Н	0.13	
О	-0.84	
П	-0.70	
Р	0.75	

4.2. Вычисление рейтинга успеваемости

Шаг 10

Выберите ячейку F2 и «напишите» точно так же, как пишете текст в Word, выражение =E2*10+50, а затем нажмите клавишу Enter.

D	E	F
	Нормированное отклонение	Рейтинг успеваемости
Руи	0.88	=E2*10+50
Юми	0.35	
А	-1.71	
Б	-0.53	
В	-0.18	
Г	1.49	
Д	0.70	
Е	0.53	
Ж	-0.75	
З	-2.02	
И	0.00	
К	2.07	
Л	0.18	
М	-0.35	
Н	0.13	
О	-0.84	
П	-0.70	
Р	0.75	

Шаг 11

Повторите Шаг 8.

Шаг 12

Вычисление рейтинга успеваемости закончено!

D	E	F
	Нормированное отклонение	Рейтинг успеваемости
Руи	0.88	58.79
Юми	0.35	53.52
А	-1.71	32.85
Б	-0.53	44.72
В	-0.18	48.24
Г	1.49	64.95
Д	0.70	57.04
Е	0.53	55.28
Ж	-0.75	42.53
З	-2.02	29.77
И	0.00	50.00
К	2.07	70.67
Л	0.18	51.76
М	-0.35	46.48
Н	0.13	51.32
О	-0.84	41.65
П	-0.70	42.96
Р	0.75	57.47

5. Вычисление вероятности стандартного нормального распределения

Используются данные со стр. 93.

Шаг 1 Выберите ячейку **B2**.

	A	B
1	z	1.96
2	промежуточное значение	
3	площадь (= доля = вероятность)	

Шаг 2 Выберите **Вставка ▶ Функция**.

Шаг 3 Выберите **Статистические** в строке **Категория**, а затем **НОРМСТРАСП*** в графе **Выберите функцию**.

* NORMDIST в английской версии Excel.

Шаг 4 Выберите ячейку **B1** и нажмите кнопку **OK**.

Аргументы функции

НОРМСТРАСП

z [B1] = 1.96

= 0.975002105

Возвращает стандартное нормальное интегральное распределение.

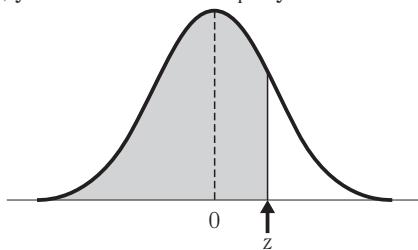
z - значение, для которого строится распределение.

Справка по этой функции Значение: 0.975002105

OK Отмена

Шаг 5

На самом деле функция **НОРМСТРАСП** предназначена для вычисления вероятности, указанной ниже на рисунке.



Поэтому «напишите» в ячейке В3
точно так же, как пишете в Word, выражение [=B2-0.5].

	A	B
1	z	1.96
2	промежуточное значение	0.975002
3	площадь (= доля = вероятность)	=B2-0.5

Шаг 6

Вычисление закончено!

	A	B
1	z	1.96
2	промежуточное значение	0.975002
3	площадь (= доля = вероятность)	0.475002

6. Вычисление значения x при распределении хи-квадрат

Используются данные со стр. 104.

Шаг 1

Выберите ячейку В3.

	A	B
1	P	0.05
2	степень свободы	1
3	хи-квадрат	

Шаг 2

Выберите Вставка ▶ Функция.

Шаг 3

Выберите **Статистические** в строке **Категория**,
а затем **ХИ2ОБР*** в графе **Выберите функцию**.

* CHIINV в английской версии Excel.

Шаг 4

Выберите ячейки B1 и B2 и нажмите кнопку **OK**.

	A	B	C	D	E	F	G	H	I
1	P	0.05							
2	степень свободы	1							
3	хи-квадрат	(B1;B2)							
4									
5									
6									
7									
8									
9									
10									
11									
12									
13									
14									
15									
16									
17									
18									
19									
20									
21									

Аргументы функции
ХИ2ОБР
Вероятность: B1 = 0.05
Степени_свободы: B2 = 1
 $= 3.841459149$

Возвращает значение обратное к односторонней вероятности распределения хи-квадрат.

Степени_свободы: число степеней свободы - число от 1 до 10^{10} , исключая 10^{10} .

Справка по этой функции

Значение: 3.841459149

OK

Отмена

Шаг 5

Вычисление закончено!

	A	B
1	P	0.05
2	степень свободы	1
3	хи-квадрат	3.841459

7. Вычисление коэффициента линейной корреляции

Используются данные со стр. 116

Шаг 1 Выберите ячейку **B14**.

A	B	C
1	Расходы на косметику, йены	Расходы на одежду, йены
2 А	3000	7000
3 Б	5000	8000
4 В	12000	25000
5 Г	2000	5000
6 Д	7000	12000
7 Е	15000	30000
8 Ж	5000	10000
9 З	6000	15000
10 И	8000	20000
11 К	10000	18000
12		
13		
14 Коэффициент линейной корреляции		

Шаг 2 Выберите **Вставка ▶ Функция**.

Шаг 3 Выберите **Статистические** в строке **Категория**, а затем **KOPPEЛ*** в графе **Выберите функцию**.

* CORREL в английской версии Excel.

Шаг 4 Выделите указанную ниже область и нажмите кнопку **OK**.

А Аргументы функции
B B
C C
D D
E E
F F
G G
H H
I I
J J
K K

	Расходы на косметику, йены	Расходы на одежду, йены
2 А	3000	7000
3 Б	5000	
4 В	12000	
5 Г	2000	
6 Д	7000	
7 Е	15000	
8 Ж	5000	
9 З	6000	
10 И	8000	
11 К	10000	
12		
13		
14 Коэффициент линейной корреляции	:B11;C2:C11)	
15		
16		
17		
18		
19		

Коэффициент линейной корреляции

Аргументы функции

КОРРЕЛ

Массив1: B2:B11
Массив2: C2:C11

Возращает коэффициент корреляции между двумя множествами данных.

Массив2 второго диапазона значений. Значениями могут быть числа, имена, массивы или ссылки с именами.

Справка по этой функции Значение: 0.968019613

OK Отмена

Шаг 5

Вычисление закончено!

A	B	C
1		Расходы на косметику, йены
2	А	3000
3	Б	5000
4	В	12000
5	Г	2000
6	Д	7000
7	Е	15000
8	Ж	5000
9	З	6000
10	И	8000
11	К	10000
12		
13		
14	Коэффициент линейной корреляции	0.968019613
15		

8. Проверка гипотезы о независимости

Используются данные со стр. 157.

Шаг 1

Выберите ячейку B8.

A	B	C	D	E
1	по телефону	по SMS	при встрече	Итого
2	ж	34	61	53
3	м	38	40	74
4	Итого	72	101	127
5				
6				
7	по телефону	по SMS	при встрече	
8	ж			
9	м			
10				
11				
12	P-значение			
13				

Шаг 2Напишите в ячейке B8 точно так же, как пишете в Word, выражение: $=E2*B4/E4$ и пока не нажимайте клавишу Enter.

A	B	C	D	E
1	по телефону	по SMS	при встрече	Итого
2	ж	34	61	53
3	м	38	40	74
4	Итого	72	101	127
5				
6				
7	по телефону	по SMS	при встрече	
8	ж	=E2*B4/E4		
9	м			
10				
11				
12	P-значение			
13				

Шаг 3

Подведите курсор к надписи Е2 в ячейке В8 и трижды нажмите кнопку F4. Убедитесь, что Е2 превратилось в \$E2, и пока не нажимайте клавишу Enter.

	A	B	C	D	E
1		по телефону	по SMS	при встрече	Итого
2	ж	34	61	53	148
3	м	38	40	74	152
4	Итого	72	101	127	300
5					
6					
7		по телефону	по SMS	при встрече	
8	ж	=\\$E2*B4/E4			
9	м				
10					
11					
12	Р-значение				
13					

Шаг 4

Подведите курсор к надписи В4 в ячейке В8, дважды нажмите клавишу F4 и убедитесь, что В4 превратилось в В\$4. Затем подведите курсор к надписи Е4 в ячейке В8, нажмите клавишу F4 и проверьте, превратилось ли Е4 в \$E\$4.

	A	B	C	D	E
1		по телефону	по SMS	при встрече	Итого
2	ж	34	61	53	148
3	м	38	40	74	152
4	Итого	72	101	127	300
5					
6					
7		по телефону	по SMS	при встрече	
8	ж	=\\$E2*B\$4/\\$E\$4			
9	м				
10					
11					
12	Р-значение				
13					

После этого нажмите клавишу Enter.

Шаг 5

Выберите ячейку В8, подведите указатель мыши к правому углу ячейки В8 и как только указатель примет вид черного крестика нажмите клавишу мыши. Удерживая клавишу мыши в нажатом состоянии, растяните область до ячейки D8, а затем отпустите клавишу мыши.

	A	B	C	D	E
1		по телефону	по SMS	при встрече	Итого
2	ж	34	61	53	148
3	м	38	40	74	152
4	Итого	72	101	127	300
5					
6					
7		по телефону	по SMS	при встрече	
8	ж	35.52			
9	м				
10					
11					
12	Р-значение				
13					

Шаг 6

Выделите ячейки B8–D8, подведите указатель мыши к правому углу ячейки D8 и как только он превратится в черный крестик нажмите клавишу мыши. Удерживая клавишу мыши в нажатом состоянии, растяните область до ячейки D9, а затем отпустите клавишу мыши.

A	B	C	D	E
1	по телефону	по SMS	при встрече	Итого
2	ж	34	61	53
3	м	38	40	74
4	Итого	72	101	127
5				
6				
7	по телефону	по SMS	при встрече	
8	ж	35,52	49,82666667	62,65333333
9	м			
10				
11				
12	Р-значение			
13				

Шаг 7

Выберите ячейку B12. После этого выберите **Вставка ▶ Функция**, а затем **Статистические** в строке **Категория** и **ХИ2ТЕСТ*** в графе **Выберите функцию**.

* CHITEST в английской версии Excel.

Мастер функций - шаг 1 из 2

Поиск функции:

Введите краткое описание действия, которое нужно выполнить, и нажмите кнопку "Найти".

Найти

Категория: Статистические

Выберите функцию:

ФИШЕРОБР
ФТЕСТ
ХИ2ОБР
ХИ2РАСП
ХИ2ТЕСТ
ЧАСТОТА
ЭКСПРАСП

ХИ2ТЕСТ(фактический_интервал;ожидаемый_интервал)

Возращает тест на независимость: значение распределения Хи-квадрат для статистического распределения и соответствующего числа степеней свободы.

Справка по этой функции

OK Отмена

Шаг 8

Выделите указанную ниже область и нажмите кнопку **OK**.

	A	B	C	D	E	F	G	H	I	J	K
1		по телефону	по SMS	при встрече	Итого						
2	ж		34								
3	м		38								
4	Итого		72								
5											
6											
7		по телефону									
8	ж		35,52								
9	м		36,48								
10											
11											
12	P-значение	D3:B8:D9)									
13											
14											
15											
16											
17											
18											
19											

Аргументы функции

Фактический_интервал [B2:D3] = {34;61;53;38;40;74};
 Ожидаемый_интервал [B8:D9] = {35,52;49,826666666}

= 0,01823258

Возвращает тест на независимость: значение распределения Хи-квадрат для статистического распределения и соответствующего числа степеней свободы.

Ожидаемый_интервал диапазон, содержащий отношение произведений итогов по строкам и столбцам к общему итогу.

[Справка по этой функции](#) Значение: 0,01823258

OK **Отмена**

Шаг 9

Вычисление закончено!

Проверьте, соответствует ли полученная величина P-значению на стр. 177).

	A	B	C	D	E
1		по телефону	по SMS	при встрече	Итого
2	ж		61	53	148
3	м		40	74	152
4	Итого	72	101	127	300
5					
6					
7		по телефону	по SMS	при встрече	
8	ж	35,52	49,826666667	62,653333333	
9	м	36,48	51,173333333	64,346666667	
10					
11					
12	P-значение	0,01823258			

Предметный указатель

α

α , 163, 166

Α

AVERAGE, функция, 196

С

CHIDIST, функция, 107
CHIINV, функция, 107, 205-206
CHITEST, функция, 210-211
CORREL, функция, 207
COUNTIF, функция, 197-198

Ε

Eiken, экзамен, 23-25

F

FDIST, функция, 107
FINV, функция, 107
FREQUENCY, функция, 193-194
FPACП, функция, 107
ФРАСПОБР, функция, 107
F-распределение, 106-107

М

Microsoft Excel, см. вычисления в Excel, функции Excel

Н

NORMDIST, функция, 107
NORMINV, функция, 107
NORMSDIST, функция, 107, 204
NORMSINV, функция, 107

Р

P-значение
альтернативная гипотеза, 175-179
гипотеза о независимости, 175
нулевая гипотеза, 175-179
проверка гипотезы, 163, 175-179, 189

С

STANDARDIZE, функция, 199-201

Τ

TDIST, функция, 107
TINV, функция, 107
Т-показатель, см. рейтинг успеваемости

В

V Крамера, см. Крамера коэффициент корреляции

Ζ

Z-показатель, см. нормированное отклонение
Z-преобразование, см. нормирование

Α

альтернативная гипотеза
P-значение, 175-179
коэффициент корреляции Крамера, 186
обзор, 170-174
определение, 174
примеры, 161, 171-173
проверка гипотезы о равенстве долей в совокупностях, 173
анкетирование, 4-6
качественные данные, 60-64
ограничения, 4-7
проверка независимости, 137, 208-211
таблицы распределения, 62-64

Β

вероятность, 81-109
F-распределение, 106-107
нормальное распределение, 86-89
определение, 82
распределение и Excel, 107-109
распределение Стьюдента, 106
распределение хи-квадрат, 99-105, 205-206
результаты теста, 83-84
соответствующая, 104
стандартное нормальное распределение, 89-98, 204-205

степень свободы, 99-108

выборка, см. выборочная совокупность

выборочная совокупность, 6, 7, 52, 57

вычисления в Excel, 191-211

коэффициент корреляции, 206-207
медиана, 195-196
нормированное отклонение, 74-80, 199-203
проверка гипотезы о независимости, 208-211
простая статистическая таблица, 197-198
распределение, 107-109
распределение хи-квадрат, 205-206
рейтинг успеваемости, 199-202
среднее значение, 195-196
стандартное нормальное распределение, 204-205
стандартное отклонение, 195-196
таблицы распределения, 192-195

Γ

генеральная совокупность
выборка, 52
коэффициент корреляции Крамера, 145-150, 157, 186
определение, 6
проверка гипотезы, 149, 186
стандартное отклонение, 52

- гистограммы
 величина интервала, 84, 85
 достоинства, 83
 обзор, 38-39
 переменные, 39
 примеры, 39, 83, 84, 154
 функция плотности вероятности, 83-84
- Д**
- данные
 измеряемые, см. *количественные данные*
 качественные, см. *качественные данные*
 количественные, см. *количественные данные*
 неизмеряемые, см. *качественные данные*
 разброс, 49, 58, 69, 70, 80
 диаграмма распределения
 ежемесячные расходы, 116-120
 корреляционное отношение, 122, 126
 примеры, 114, 116
 диаграмма цены, 33-39
 диаграммы
 корреляционное отношение, 126
 построение, 33-39
 расходы, 116-120
 столбиковая, 114
 теснота связи, 115
 точечная, см. *точечная диаграмма*
 доли совокупностей, 149
- З**
- зависимость
 корреляционное отношение, 117, 121-127
 линейная, 120
 нелинейная, 120
 относительная частота, 36-37, 39
 переменные, 112-115
 степень, 115, 116-120
 загрузка файлов Excel, 192
 значение
 Р-значение, 163, 175-179, 189
 медиана, 44-47
 значимость гипотезы, 187
- И**
- интервал, 39, 54-57, 84
 величина, 39, 54-57, 84
 формула Стерджесса, 55
- К**
- качественные данные, 14-29
 корреляционное отношение, 121
 обзор, 14-19
 определение, 19
 показатели, 117
 примеры, 20, 23-26
 результат исследования, 60-64
- создание таблиц, 60-64
 столбиковая диаграмма, 114
 точечная диаграмма, 114
 количественные данные, 14-29
 гистограммы, 38-39, 54, 58
 корреляционное отношение, 121
 медиана, 44-47
 обзор, 31-58
 описательная статистика, 57-58
 определение, 19
 показатели, 117
 примеры, 21-23, 26
 средняя величина, 40-43
 стандартное отклонение, 48-53, 70-79
 таблицы распределения, 32-39, 54-56, 58
 теория оценивания, 57-58
 точечная диаграмма, 114
КОРРЕЛ, функция, 207
 корреляционное отношение, 117, 121-127, 207
 корреляция, 115, 119
 коэффициент корреляции Крамера, см. Крамера
 коэффициент корреляции
 коэффициент линейной корреляции, 116-120, 206-207
 коэффициент независимости, см. *Крамера коэффициент корреляции*
 Крамера коэффициент корреляции, 127-138
 вычисление в Excel, 207
 альтернативная гипотеза, 186
 вычисление, 130-135, 141
 критерий величины, 136
 нулевая гипотеза, 168, 186
 показатель тесноты связи, 117, 129
 примеры, 127-136
 пропорции предпочтений, 155
 точность, 147
 критерий согласия Пирсона, 132, 152-155, 158
 символ, 103
 критическая область, 159, 165-167, 187
- Л**
- линейная зависимость, 120
- М**
- медиана
 вычисление в Excel, 195-196
 определение, 45
 применимость, 44
 примеры, 45-47
 межгрупповая дисперсия, 117, 124, 126
 многовариантные ответы, 28
- Н**
- наклон графика, 101
 неизмеряемые данные, см. *качественные данные*
 нелинейная зависимость, 120

- Непера число, 86
 нормализация, см. *нормирование*
НОРМАЛИЗАЦИЯ, функция, 199-201
 нормальное распределение, 86-91
 нормирование, 71-72
 нормированное отклонение, 65-80, 73, 199-202
 нормировка, см. *нормирование*
НОРМОБР, функция, 107
НОРМРАСП, функция, 107
НОРМСТОБР, функция, 107
НОРМСТРАСП, функция, 107, 204
 нульевая гипотеза
 Р-значение, 175-179
 для проверки корреляционного отношения, 172
 для проверки независимости, 172
 для проверки отсутствия корреляции, 172
 для проверки равенства долей в совокупностях, 173
 для проверки равенства средних величин совокупностей, 173
 коэффициент Крамера, 168, 186
 нельзя отвергнуть, 150, 167, 178, 179, 187
 обзор, 170-174
 описание, 174
 примеры, 167-174
 трудность доказательства, 174
- О**
- обратная зависимость, 119
 описательная статистика, 57-58
 опрос общественного мнения, 4-6
 ось у, 39
 ось х, 39, 102, 107, 109, 125
 отсутствие корреляции, 119
- П**
- переменные, 111-142
 гистограмма, 39
 зависимость, 112-115
 корреляционное отношение, 121-127
 коэффициент Крамера, 127-138, 141-142
 коэффициент линейной корреляции, 116-120
 степень связи, 115, 116-120
- Пирсона критерий согласия, см. *критерий согласия Пирсона*
 показатели
 качественные данные, 117
 коэффициент корреляции Крамера, 117, 129
 коэффициент линейной корреляции, 120
 проверка гипотез, 143-189
 Р-значение, 163, 175-179, 189
 альтернативная гипотеза, см. *альтернативная гипотеза*
 виды, 149, 171
 выводы, 187
- критерий согласия Пирсона, 151-160
 нульевая гипотеза, см. *нулевая гипотеза*
 о корреляционном отношении, 149, 171, 172
 о независимости, 149, 171
 о равенстве долей в совокупностях, 149, 171, 173
 о равенстве средних величин совокупностей, 149, 171, 173
 об однородности, 184-186
 об отсутствии корреляции, 149, 171, 172
 обзор, 144-150
 определение, 149
 порядок проведения, 150, 175-179
 примеры, 149, 168-174
 проверка критерия согласия Пирсона, 151-169
 проверка гипотезы о независимости, 151-161
 Р-значение, 175
 применимость, 137, 149
 примеры, 149, 171, 184-186
 сравнение с проверкой однородности, 186
 хи-квадрат, 151-169
 проверка статистических гипотез, см. *проверка гипотез*
 прогноз погоды, 82
 процентное отношение, 5, 37, 62, 64
 прямая зависимость, 119
- Р**
- разброс данных, 49, 58, 69, 70, 80
 распределение
 F, 106-107
 вычисление в Excel, 107-109
 нормальное, 86-91
 стандартное нормальное, 89-98, 204-205
 Стьюдента, 106
 хи-квадрат, см. *хи-квадрат распределение*
 рассеяние данных, см. *разброс данных*
 результаты тестов
 нормальное распределение, 86-89
 стандартное нормальное распределение, 89-98
 функция плотности вероятности, 83-84
 рейтинг успеваемости, 74-80, 199-203
 ряды распределения, см. *таблицы распределения*
- С**
- свободы степень, 99-108
 середина интервала, 36-39, 54, 56
 совокупность, см. *генеральная совокупность*
 среднее значение, см. *средняя*
 средние накопления, 46-47
 средняя
 арифметическая, 43, 73, 74
 вычисление в Excel, 195-196
 гармоническая, 43
 геометрическая, 43
 нормальное распределение, 87-89

- определение, 43
 примеры, 40-44
 стандартное нормальное распределение, 89-90
СРЗНАЧ, функция, 196
 стандартизация, см. *нормирование*
 стандартное нормальное распределение, 89-98,
 204-205
 стандартное отклонение, 48-53, 70-79
 вычисление в Excel, 195-196
 количественные данные, 48-53, 70-79
 нормальное распределение, 87-91
 совокупность, 52
 стандартное нормальное распределение, 89-90
 статистика
 описательная, 57-58
 определение, 4
 теория оценивания, 4-6
 степень свободы, 99-108
 степень тесноты связи, 115, 116-120
 Стерджесса формула, 55
 Стюдента распределение, 106
СТЫЮДРАСП, функция, 107
СТЫЮДРАСПОБР, функция, 107
СЧЕТЕСЛИ, функция, 197-198
- Т**
 таблица сопряжённости, 128, 130, 135, 151, 153,
 197-198
 таблицы распределения, 54-56, 192-195
 качественные данные, 60-64
 нормальное распределение, 107
 распределение хи-квадрат, 102-105, 205-206
 стандартное нормальное распределение, 92-93,
 104, 108
 таблицы сопряжённости, 128, 130, 135, 151, 153
 частота, 54-56
 теоретическая частота, 130, 131
 теория оценивания, 57-58
 типы данных, 13-29, 117
 точечная диаграмма, 116, 119, 120
- У**
 уровень значимости (α), 159, 163
- Ф**
 функции Excel
 AVERAGE, 196
 CHIDIST, 107
 CHIINV, 107, 205-206
 CHITEST, 210-211
 CORREL, 207
 COUNTIF, 197-198
- FDIST, 107
 FINV, 107
 FREQUENCY, 193-194
ФРАСП, 107
ФРАСПОБР, 107
NORMDIST, 107
NORMINV, 107
NORMMSDIST, 107, 204
NORMSINV, 107
STANDARDIZE, 199-201
TDIST, 107
TINV, 107
КОРРЕЛ, 207
НОРМАЛИЗАЦИЯ, 199-201
НОРМОБР, 107
НОРМРАСП, 107
НОРМСТОБР, 107
НОРМСТРАСП, 107, 204
СРЗНАЧ, 196
СТЫЮДРАСП, 107
СТЫЮДРАСПОБР, 107
СЧЕТЕСЛИ, 197-198
ХИ2РАСП, 107
ХИ2РАСПОБР, 107, 205-206
ХИ2ТЕСТ, 210-211
ЧАСТОТА, 193-194
 функция распределения плотности вероятности, 82-85, 99, 107, 109
- Х**
ХИ2РАСП, функция, 107
ХИ2РАСПОБР, функция, 107, 205-206
ХИ2ТЕСТ, функция, 210-211
 хи-квадрат, распределение, 99-105
 вычисление, 130-133
 вычисление х, 205-206
 описание, 99
 примеры, 99-105, 152
 степень свободы, 99-108
- Ч**
 частота
 описание, 36
 относительная, 36-37, 39
 таблицы распределения, 32-39
 теоретическая, 130, 131
 эмпирическая, 130, 131
ЧАСТОТА, функция, 193-194
- Э**
 Эйлера число, 86
 эмпирическая частота, 130, 131

Книги Издательского дома «Додэка-ХХI» можно заказать в торгово-издательском холдинге «АЛЬЯНС-КНИГА» наложенным платежом, выслав открытку или письмо по почтовому адресу: **123242, Москва, а/я 20** или по электронному адресу: **orders@aliants-kniga.ru**.

При оформлении заказа следует указать адрес (полностью), по которому должны быть высланы книги; фамилию, имя и отчество получателя. Желательно также указать свой телефон и электронный адрес.

Эти книги вы можете заказать и в Интернет-магазине: **www.aliants-kniga.ru**.

Оптовые закупки: тел. **(495) 258-91-94, 258-91-95**; электронный адрес
books@aliants-kniga.ru.

Син Такахаси

Занимательная статистика Манга

Подписано в печать 15.12.2009. Формат 70х90/16. Бумага офсетная.

Гарнитура «LiteraturnayaC», «JacobC». Печать офсетная.

Объём 14,0 п. л. Усл. п. л. 16,3.

Тираж 1500 экз. Код ОНМ03.

Издательский дом «Додэка-ХХI»

105318 Москва, а/я 70

Тел./факс: (495) 366-04-56, 366-11-55

E-mail: red@dodeca.ru

Web-сайт издательства: www.dodeca.ru

Интернет-магазин: www.aliants-kniga.ru

Отпечатано с готовых диапозитивов в ОАО «Щербинская типография»
117623, Москва, ул. Типографская, д. 10.