

ОГЛАВЛЕНИЕ

Предисловие	3
К читателю	5
Часть I. Вероятность и статистическое моделирование	7
Глава 1. Характеристики случайных величин	7
§ 1. Функции распределения и плотности	7
§ 2. Математическое ожидание и дисперсия	10
§ 3. Независимость случайных величин	12
§ 4. Поиск больных	13
Задачи	14
Решения задач	15
Ответы на вопросы	17
Глава 2. Датчики случайных чисел	19
§ 1. Физические датчики	19
§ 2. Таблицы случайных чисел	20
§ 3. Математические датчики	21
§ 4. Случайность и сложность	22
§ 5. Эксперимент «Неудачи»	24
§ 6. Теоремы существования и компьютер	26
Задачи	26
Решения задач	27
Ответы на вопросы	29
Глава 3. Метод Монте-Карло	30
§ 1. Вычисление интегралов	30
§ 2. «Правило трех сигм»	31
§ 3. Кратные интегралы	32
§ 4. Шар, вписанный в k -мерный куб	35
§ 5. Равномерность по Вейлю	36
§ 6. Парадокс первой цифры	37
Задачи	38
Решения задач	39
Ответы на вопросы	41

Глава 4. Показательные и нормальные датчики	42
§ 1. Метод обратной функции	42
§ 2. Распределения экстремальных значений	43
§ 3. Показательный датчик без логарифмов	45
§ 4. Быстрый показательный датчик	46
§ 5. Нормальные случайные числа	50
§ 6. Наилучший выбор	52
Задачи	54
Решения задач	54
Ответы на вопросы	57
Глава 5. Дискретные и непрерывные датчики	58
§ 1. Моделирование дискретных величин	58
§ 2. Порядковые статистики и смеси	60
§ 3. Метод Неймана (метод исключения)	64
§ 4. Пример из теории игр	66
Задачи	67
Решения задач	68
Ответы на вопросы	69
Часть II. Оценивание параметров	71
Глава 6. Сравнение оценок	72
§ 1. Статистическая модель	72
§ 2. Несмещенност и состоятельность	73
§ 3. Функции риска	76
§ 4. Минимаксная оценка в схеме Бернулли	78
Задачи	79
Решения задач	80
Ответы на вопросы	83
Глава 7. Асимптотическая нормальность	84
§ 1. Распределение Коши	84
§ 2. Выборочная медиана	86
§ 3. Выборочные квантили	87
§ 4. Относительная эффективность	89
§ 5. Устойчивые законы	91
Задачи	93
Решения задач	94
Ответы на вопросы	98
Глава 8. Симметричные распределения	99
§ 1. Классификация методов статистики	99
§ 2. Усеченное среднее	100
§ 3. Медиана средних Уолша	102
§ 4. Робастность	103
Задачи	106
Решения задач	106
Ответы на вопросы	109
Глава 9. Методы получения оценок	110
§ 1. Вероятностная бумага	110

§ 2. Метод моментов	112
§ 3. Информационное неравенство	114
§ 4. Метод максимального правдоподобия	116
§ 5. Метод Ньютона и одношаговые оценки	119
§ 6. Метод спейсингов	122
Задачи	123
Решения задач	124
Ответы на вопросы	127
Глава 10. Достаточность	129
§ 1. Достаточные статистики	129
§ 2. Критерий факторизации	130
§ 3. Экспоненциальное семейство	132
§ 4. Улучшение несмешанных оценок	133
§ 5. Шарики в ящиках	134
Задачи	140
Решения задач	141
Ответы на вопросы	144
Глава 11. Доверительные интервалы	145
§ 1. Коэффициент доверия	145
§ 2. Интервалы в нормальной модели	146
§ 3. Методы построения интервалов	151
Задачи	155
Решения задач	156
Ответы на вопросы	158
Часть III. Проверка гипотез	159
Глава 12. Критерии согласия	160
§ 1. Статистический критерий	160
§ 2. Проверка равномерности	161
§ 3. Проверка показательности	164
§ 4. Проверка нормальности	167
§ 5. Энтропия	170
Задачи	175
Решения задач	175
Ответы на вопросы	178
Глава 13. Альтернативы	180
§ 1. Ошибки I и II рода	180
§ 2. Оптимальный критерий Неймана–Пирсона	183
§ 3. Последовательный анализ	187
§ 4. Разорение игрока	190
§ 5. Оптимальная остановка блуждания	193
Задачи	195
Решения задач	195
Ответы на вопросы	197

Часть IV. Однородность выборок	199
Глава 14. Две независимые выборки	200
§ 1. Альтернативы однородности	200
§ 2. Правильный выбор модели	201
§ 3. Критерий Смирнова	202
§ 4. Критерий Розенблatta	203
§ 5. Критерий ранговых сумм Уилкоксона	204
§ 6. Принцип отражения	209
Задачи	214
Решения задач	215
Ответы на вопросы	217
Глава 15. Парные повторные наблюдения	219
§ 1. Уточнение модели	219
§ 2. Критерий знаков	220
§ 3. Критерий знаковых рангов Уилкоксона	222
§ 4. Зависимые наблюдения	227
§ 5. Критерий серий	229
Задачи	231
Решения задач	232
Ответы на вопросы	236
Глава 16. Несколько независимых выборок	237
§ 1. Однофакторная модель	237
§ 2. Критерий Краскела—Уоллиса	237
§ 3. Критерий Джонкхиера	245
§ 4. Блуждание на плоскости и в пространстве	248
Задачи	253
Решения задач	254
Ответы на вопросы	257
Глава 17. Многократные наблюдения	259
§ 1. Двухфакторная модель	259
§ 2. Критерий Фридмана	260
§ 3. Критерий Пейджа	263
§ 4. Счастливый билетик и возвращение блуждания	265
Задачи	269
Решения задач	270
Ответы на вопросы	271
Глава 18. Сгруппированные данные	273
§ 1. Простая гипотеза	273
§ 2. Сложная гипотеза	276
§ 3. Проверка однородности	280
Задачи	282
Решения задач	282
Ответы на вопросы	286
Часть V. Анализ многомерных данных	287
Глава 19. Классификация	288
§ 1. Нормировка, расстояния и классы	289

§ 2. Эвристические методы	291
§ 3. Иерархические процедуры	294
§ 4. Быстрые алгоритмы	297
§ 5. Функционалы качества разбиения	299
§ 6. Неизвестное число классов	307
§ 7. Сравнение методов	309
§ 8. Представление результатов	311
§ 9. Поиск в глубину	311
Задачи	313
Решения задач	313
Ответы на вопросы	315
Глава 20. Корреляция	317
§ 1. Геометрия главных компонент	317
§ 2. Эллипсоид рассеяния	322
§ 3. Вычисление главных компонент	324
§ 4. Линейное шкалирование	326
§ 5. Шкалирование индивидуальных различий	332
§ 6. Нелинейные методы понижения размерности	337
§ 7. Ранговая корреляция	343
§ 8. Множественная и частная корреляции	347
§ 9. Таблицы сопряженности	350
Задачи	352
Решения задач	353
Ответы на вопросы	356
Глава 21. Регрессия	357
§ 1. Подгонка прямой	357
§ 2. Линейная регрессионная модель	360
§ 3. Статистические свойства МНК-оценок	363
§ 4. Общая линейная гипотеза	368
§ 5. Взвешенный МНК	372
§ 6. Парадоксы регрессии	376
Задачи	382
Решения задач	383
Ответы на вопросы	386
Часть VI. Обобщения и дополнения	387
Глава 22. Ядерное стгаживание	388
§ 1. Оценивание плотности	388
§ 2. Непараметрическая регрессия	392
Глава 23. Многомерные модели сдвига	399
§ 1. Стратегия построения критериев	399
§ 2. Одновыборочная модель	399
§ 3. Двухвыборочная модель	406
Глава 24. Двухвыборочная задача о масштабе	411
§ 1. Медианы известны или равны	411
§ 2. Медианы неизвестны и неравны	414

Глава 25. Классы оценок	417
§ 1. L -оценки	417
§ 2. M -оценки	419
§ 3. R -оценки	423
§ 4. Функция влияния	426
Глава 26. Броуновский мост	428
§ 1. Броуновское движение	428
§ 2. Эмпирический процесс	429
§ 3. Дифференцируемые функционалы	430
Приложение. Некоторые сведения из теории вероятностей и линейной алгебры	435
Раздел 1. Аксиоматика теории вероятностей	435
Раздел 2. Математическое ожидание и дисперсия	435
Раздел 3. Формула свертки	437
Раздел 4. Вероятностные неравенства	437
Раздел 5. Сходимость случайных величин и векторов	438
Раздел 6. Предельные теоремы	439
Раздел 7. Условное математическое ожидание	440
Раздел 8. Преобразование плотности случайного вектора	441
Раздел 9. Характеристические функции и многомерное нормальное распределение	442
Раздел 10. Элементы матричного исчисления	444
Таблицы	449
Литература	456
Обозначения и сокращения	460
Предметный указатель	462

ПРЕДИСЛОВИЕ

Перед Вами, уважаемый читатель, итог размышлений автора о содержании начального курса математической статистики. Настоящая книга — это, в первую очередь, множество занимательных примеров и задач, собранных из различных источников. Задачи предназначены для активного освоения понятий и развития у читателя навыков квалифицированной статистической обработки данных. Для их решения достаточно знания элементов математического анализа и теории вероятностей (краткие сведения по теории вероятностей и линейной алгебре даны в приложении).

Акцент делается на наглядном представлении материала и его неформальном пояснении. Теоремы, как правило, приводятся без доказательств (со ссылкой на источники, где их можно найти). Наша цель — и осветить практически наиболее важные идеи математической статистики, и познакомить читателя с прикладными методами.

Первая часть книги (гл. 1–5) может служить введением в теорию вероятностей. Особенностью этой части является подход к освоению понятий теории вероятностей через решение ряда задач, относящихся к области статистического моделирования (имитации случайности на компьютере). Ее материал, в основном, доступен школьникам старших классов и студентам 1-го курса.

Вторая и третья части (гл. 6–13) посвящены, соответственно, оценкам параметров статистических моделей и проверке гипотез. Они могут быть особенно полезны студентам при подготовке к экзамену по математической статистике.

Четвертая и пятая части (гл. 14–21) предназначаются, в первую очередь, лицам, желающим применить статистические методы для анализа экспериментальных данных.

Наконец, шестая часть (гл. 22–26) включает в себя ряд более специальных тем, обобщающих и дополняющих содержание предыдущих глав.

Собранный в книге материал неоднократно использовался на занятиях по математической статистике на механико-математическом факультете МГУ им. М. В. Ломоносова.

Автор будет считать свой труд небесполезным, если, перелистив книгу, читатель не потеряет к ней интереса, а захочет ознакомиться

Что за польза от книги без картинок и разговоров?

Льюис Кэрролл,
«Приключения Алисы
в стране чудес»

Ей сна нет от французских
книг, а мне от русских
больно спится!

Фамусов в «Горе от ума»
А. С. Грибоедова

Никогда не теряй из виду,
что гораздо легче многих
не удовлетворить, чем
удовольствоваться.

Козьма Прутков,
«Мысли и афоризмы»

с теорией и приложениями статистики как по этому, так и по другим учебникам.

При работе над книгой образцом для автора была популярная серия книг для школьников Я. И. Перельмана. Хотелось, по возможности, использовать живую форму изложения и стиль, характерный для этой серии.

Я благодарен моим коллегам по лаборатории Математической статистики МГУ им. М. В. Ломоносова М. В. Козлову и Э. М. Кудлаеву за прочтение рукописи этой книги и полезные замечания.

M. Лагутин

К ЧИТАТЕЛЮ

В книге Д. Пойа «Математическое открытие» (см. [62] в списке литературы) выделены *три принципа обучения*. Первым (и важнейшим) из них является

Стимулирование

Надо заинтересовать учащегося, убедить в полезности изучения предмета. Для успешности учебы необходимо четкое представление о том, зачем нужна сообщаемая информация.

Приведем мнение по этому вопросу известного героя детективного жанра (ведь восстановление по частностям общей картины есть также и задача математической статистики).

«Мне представляется, что человеческий мозг похож на маленький пустой чердак, который вы можете обставить, как хотите. Дурак натащит туда всякой рухляди, какая попадется под руку, и полезные, нужные вещи уже некуда будет всунуть, или в лучшем случае до них среди всей этой завали и не докопаешься. А человек толковый тщательно отбирает то, что он поместит в свой мозговой чердак. Он возьмет лишь инструменты, которые понадобятся ему для работы, но зато их будет множество, и все он разложит в образцовом порядке. Напрасно люди думают, что у этой маленькой комнатки эластичные стены и их можно растягивать сколько угодно. Уверяю вас, придет время, когда, приобретая новое, вы будете забывать что-то из прежнего. Поэтому страшно важно, чтобы ненужные сведения не вытесняли собой нужных.»

А. Конан Дойл, «Этюд в багровых тонах»

Математическая статистика — один из наиболее часто используемых в приложениях разделов математики. На результаты практически любого научного эксперимента влияют неучтенные в модели факторы, накладывается случайный шум. Методы математической статистики, как правило, позволяют наиболее полно и надежно извлекать полезную информацию из зашумленных данных. В книгу включены многочисленные примеры применения статистических методов для решения практических задач.

Чтобы побудить читателя глубже изучить теорию вероятностей, на языке которой формулируются статистические теоремы, многие главы завершаются вероятностным парадоксом или занимательным экспериментом.

Основа, подлинное содержание всякого познания доставляется именно наглядной концепцией мира, которая может быть добыта лишь нами самими и отнюдь не может быть как-либо преподана извне.

Артур Шопенгауэр,
«Афоризмы
житейской мудрости»

Студент — это не гусь, которого надо нафаршировать, а факел, который нужно зажечь.

То, что вы были вынуждены открыть сами, оставляет в вашем уме дорожку, которой вы можете снова воспользоваться, когда в этом возникнет необходимость.

Г. Лихтенберг,
«Aphorismen», Berlin,
1902–1906

При изложении математического рассуждения мастерство заключается в умении дать образованному читателю возможность сразу, не заботясь о деталях, схватить основную идею; последовательные дозы должны быть такими, чтобы их можно было глотать «с ходу»; в случае неудачи или если бы читатель захотел что-либо проверить, перед ним должна стоять четко ограниченная маленькая задача (например, проверить тождество; две пропущенные тривиальности могут в совокупности образовать непреодолимое препятствие).

Дж. Литтвуд,
«Математическая смесь»

Всякое человеческое познание начинается с созерцаний, переходит от них к понятиям и заканчивается идеями.

И. Кант,
«Критика чистого разума»

Следующим принципом обучения является

Активность

По-настоящему разобраться в некоторой теории можно лишь самостоятельно решая задачи из данной области. Пассивного чтения даже хорошего учебника, увы, недостаточно для подлинного овладения предметом.

Каждая глава этой книги (за исключением дополнительных глав 22–26) содержит задачи (с решениями). Они обычно упорядочены по сложности, самые трудные отмечены звездочкой. Автор надеется, что читатель попробует решить некоторые из заинтересовавших его задач или, хотя бы, разберет решения, так как в них содержится значительная часть материала. Кроме того, по ходу изложения встречаются контрольные вопросы, ответы на которые приведены в конце соответствующей главы.

Возможность активного усвоения материала во многом определяется стилем его изложения.

Наконец, третий принцип — это соблюдение последовательности фаз обучения

Исследование → формализация → усвоение

Важно начинать новую тему с содержательных примеров, чтобы можно было «потрогать руками», прочувствовать ситуацию. Можно попробовать придумать какой-нибудь способ решения проблемы лишь на основе здравого смысла. Если он на самом деле окажется бесполезным, то это лишь подтвердит важность теории, позволяющей получить приемлемое решение.

Абстрактные определения становятся по-настоящему понятны лишь тогда, когда они используются при решении конкретных задач в различных моделях. В книге «Теория катастроф» В. И. Арнольд пишет:

«Абстрактные определения возникают при попытках обобщить «наивные» понятия, сохранив их основные свойства. Теперь, когда мы знаем, что эти попытки не приводят к реальному расширению круга объектов (для многообразий это установил Уитни, для групп — Кэли, для алгоритмов — Черч), не лучше ли в преподавании вернуться к «наивным» определениям? (...) Пуанкаре подробно обсуждает методические преимущества наивных определений окружности и дроби в «Науке и методе»: невозможно усвоить правило сложения дробей, не разрезая, хотя бы мысленно, яблоко или пирог.»

При написании этой книги автор старался следовать указанным принципам обучения. Вероятно, какие-то методические приемы окажутся полезными преподавателям статистики, хотя, безусловно справедливо утверждал Козьма Прutков, что

У всякого портного свой взгляд на искусство!

ВЕРОЯТНОСТЬ И СТАТИСТИЧЕСКОЕ МОДЕЛИРОВАНИЕ

ГЛАВА 1

ХАРАКТЕРИСТИКИ СЛУЧАЙНЫХ ВЕЛИЧИН

В основе математической статистики лежит теория вероятностей. Аксиоматика теории вероятностей была разработана А. Н. Колмогоровым (опубликована в 1933 г.). Читателю, возможно, известны такие основные понятия этой теории, как независимость событий или математическое ожидание случайной величины. Тем не менее, будет полезно напомнить самое необходимое для дальнейшего изложения (см. также приложение П1^{*)} и учебники [19], [39], [90] в списке литературы).

Вероятность — это важнейшее понятие в современной науке особенно потому, что никто совершенно не представляет, что оно означает.

Берtrand Рассел, из лекции, 1929 г.

Читал ли что-нибудь?
Хоть мелочь?

Репетилов
в «Горе от ума»
А. С. Грибоедова

§ 1. ФУНКЦИИ РАСПРЕДЕЛЕНИЯ И ПЛОТНОСТИ

Пример 1. Измерим время ξ от первого включения до перегорания электрической лампочки.

Пример 2. Подбросим монетку. Если она упадет гербом вверх, будем считать, что $\xi = 1$, иначе положим $\xi = 0$.

Сперва аз да буки, а там и науки.

Обобщая эти примеры, представим, что проводится эксперимент, результат которого (действительное число ξ) зависит от случая. Как охарактеризовать *случайную величину* ξ , дать вероятностный закон ее поведения?

Допустим, что возможно повторить эксперимент несколько раз. Обозначим через ξ_1, \dots, ξ_n полученные при этом значения. Тогда для произвольной точки x на прямой можно подсчитать ν_n — количество значений, попавших левее x (рис. 1).

Предположим, что существует некоторое число, к которому будет приближаться частота ν_n/n при неограниченном увеличении n . Естественно рассматривать это число как *вероятность* того, что ξ не больше, чем x . Обозначим эту вероятность через $P(\xi \leq x)$. (Формальные определения понятий вероятности и случайной величины приведены в П1.)

Пример 3. На рис. 2 показан график частоты появлений буквы «а» в стихотворении М. Ю. Лермонтова «Бородино». Размах

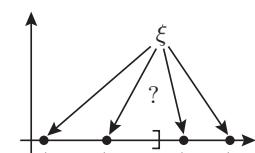


Рис. 1

P: Probabilitas (лат.) — Вероятность.

^{*)} П1 обозначает ссылку на раздел 1 приложения.

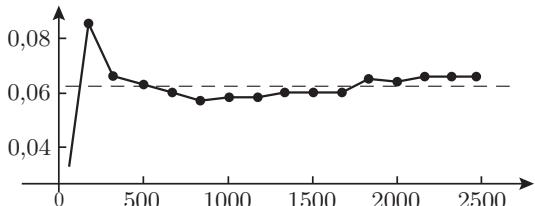


Рис. 2

колебаний частоты быстро уменьшается, она стабилизируется на уровне чуть большем, чем 0,06. В таблице приведены вероятности, с которыми встречаются в большом по объему тексте буквы русского алфавита, включая «пробел» между словами (данные взяты из [92, с. 238]). Отметим, что итоговая частота появлений буквы «а» в стихотворении «Бородино», равная $162/2461 \approx 0,066$, лишь незначительно отличается от соответствующей вероятности 0,062.

—	о	е, ё	а	и	т	н	с
0,175	0,090	0,072	0,062	0,062	0,053	0,053	0,045
р	в	л	к	м	д	п	у
0,040	0,038	0,035	0,028	0,026	0,025	0,023	0,021
я	ы	з	ь, ъ	б	г	ч	й
0,018	0,016	0,016	0,014	0,014	0,013	0,012	0,010
х	ж	ю	ш	ц	щ	э	ф
0,009	0,007	0,006	0,006	0,004	0,003	0,003	0,002

Зафиксируем n и рассмотрим поведение частоты ν_n/n при изменении «границы» x (см. рис. 1). При сдвиге точки x вправо, количество значений ξ_1, \dots, ξ_n , оказавшихся левее x , будет увеличиваться. Поэтому вероятность $\mathbf{P}(\xi \leq x)$ (как предел частоты) будет неубывающей функцией от x , которая стремится к 1 при $x \rightarrow +\infty$ и стремится к 0 при $x \rightarrow -\infty$.

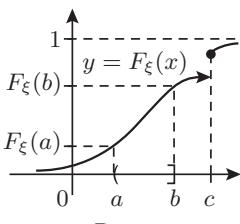


Рис. 3

Определение. Функция $F_\xi(x) = \mathbf{P}(\xi \leq x)$ называется *функцией распределения* случайной величины ξ .

Зная $F_\xi(x)$, можно найти вероятность попадания ξ в любой промежуток $(a, b]$ на прямой (рис. 3):

$$\mathbf{P}(a < \xi \leq b) = \mathbf{P}(\xi \leq b) - \mathbf{P}(\xi \leq a) = F_\xi(b) - F_\xi(a).$$

Если функция распределения $F_\xi(x)$ имеет разрыв в точке c , то величина скачка $F_\xi(c) - F_\xi(c-)$ равна

$$\mathbf{P}(\xi = c) = \mathbf{P}(\xi \leq c) - \mathbf{P}(\xi < c).$$

Вопрос 1.

Как это доказать формально, используя свойство непрерывности из П1?

Случайные величины мы будем задавать с помощью функций распределения.

Определение. Случайная величина η равномерно распределена на отрезке $[0, 1]$, если

$$F_\eta(x) = \begin{cases} 0 & \text{при } x \leq 0, \\ x & \text{при } 0 < x < 1, \\ 1 & \text{при } x \geq 1. \end{cases}$$

Такое распределение соответствует выбору точки наудачу из отрезка $[0, 1]$, поскольку для любых $0 \leq a < b \leq 1$ вероятность попадания значения η в отрезок $[a, b]$ равна его длине $b - a$ (рис. 4).

Определение. Случайная величина τ называется показательной с параметром $\lambda > 0$, если

$$F_\tau(x) = \begin{cases} 0 & \text{при } x \leq 0, \\ 1 - e^{-\lambda x} & \text{при } x > 0. \end{cases}$$

График функции распределения $F_\tau(x)$ приведен на рис. 5.

Показательное распределение можно использовать для описания времени эксперимента из примера 1.

Определение. Если существует такая функция $p_\xi(x) \geq 0$, что для произвольных $a < b$

$$\mathbf{P}(a \leq \xi \leq b) = \int_a^b p_\xi(x) dx,$$

то говорят, что случайная величина ξ (или ее распределение вероятностей) имеет плотность $p_\xi(x)$ (рис. 6).

Когда плотность существует, ее можно найти дифференцированием функции распределения:

$$p_\xi(x) = \frac{d}{dx} F_\xi(x) = \lim_{\Delta x \rightarrow 0} \frac{F_\xi(x + \Delta x) - F_\xi(x)}{\Delta x}.$$

Таким образом, плотностью равномерной величины η является функция $I_{[0,1]}$ (здесь и далее I_A обозначает индикатор множества A : $I_A(x) = 1$ при $x \in A$, $I_A(x) = 0$ при $x \notin A$), а плотностью показательной величины τ служит $p_\tau(x) = \lambda e^{-\lambda x} I_{[0,+\infty)}$ (рис. 7).

Не у всякой случайной величины есть плотность. Например, ее нет у дискретных (принимающих конечное или счетное*) число значений) величин. Такова определяемая ниже бернуlliевская случайная величина.

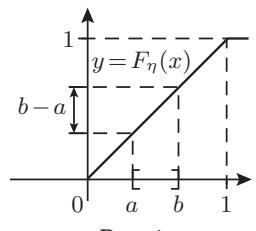


Рис. 4

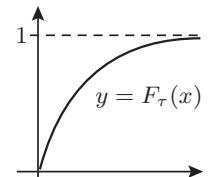


Рис. 5

Вопрос 2.
Чему равна $\mathbf{P}(\tau > 3/\lambda)$ точно и приближенно?

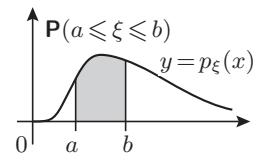


Рис. 6

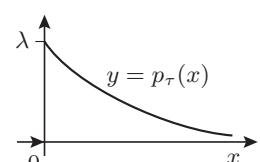


Рис. 7

Я. Бернули
(1654–1705), швейцарский математик.

*¹) Множество называют счетным, если его элементы можно перенумеровать натуральными числами.

Определение. Случайная величина ζ имеет *распределение Бернульли с вероятностью «успеха» p* ($0 \leq p \leq 1$), если она принимает значения 0 и 1 с такими вероятностями: $\mathbf{P}(\zeta = 0) = 1 - p$ и $\mathbf{P}(\zeta = 1) = p$.

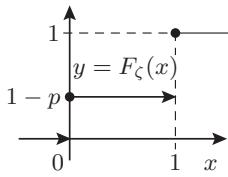


Рис. 8

Вопрос 3.

Как выглядит график функции распределения дискретной случайной величины ξ , принимающей значения $x_1 < x_2 < \dots$ с соответствующими вероятностями p_1, p_2, \dots ?

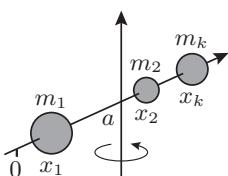


Рис. 9

§ 2. МАТЕМАТИЧЕСКОЕ ОЖИДАНИЕ И ДИСПЕРСИЯ

Не всегда требуется полная информация о случайной величине ξ , выражаяющаяся в ее функции распределения $F_\xi(x)$. Иногда достаточно знать, где располагается область «типичных» значений ξ . Одной из важных характеристик «центра» этой области является математическое ожидание.

Проблема. На тонком стержне (числовой прямой) в точках с координатами x_k находятся массы m_k (рис. 9). Где следует выбрать точку a крепления стержня к вертикальной оси, чтобы минимизировать *момент инерции* относительно нее $I_a = \sum (x_k - a)^2 m_k$?

Оказывается, точку крепления стержня надо поместить в *центр масс* $c = \sum x_k m_k / \sum m_k$ (см. задачу 1). Вероятностными аналогами центра масс c и момента инерции относительно него I_c служат математическое ожидание и дисперсия.

Определение. Для дискретной случайной величины ξ , принимающей значения x_1, x_2, \dots с соответствующими вероятностями p_1, p_2, \dots , математическим ожиданием называется число

$$\mathbf{M}\xi = \sum_k x_k p_k. \quad (1)$$

Например, для бернульевской случайной величины ζ имеем

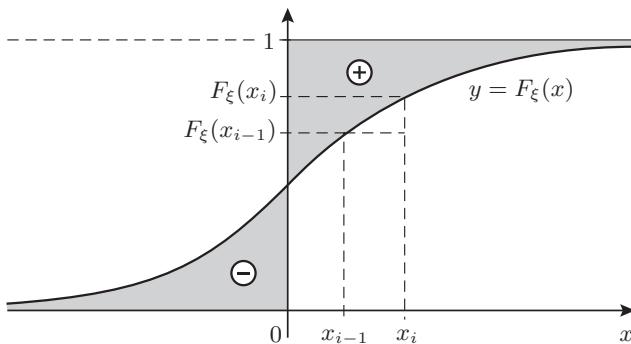
$$\mathbf{M}\zeta = 0 \cdot (1 - p) + 1 \cdot p = p.$$

Определение. Когда у случайной величины ξ есть плотность $p_\xi(x)$, ее математическое ожидание вычисляется по формуле

$$\mathbf{M}\xi = \int_{-\infty}^{+\infty} x p_\xi(x) dx. \quad (2)$$

Для показательной случайной величины τ нетрудно подсчитать, интегрируя по частям, что

$$\mathbf{M}\tau = \int_0^{\infty} x \lambda e^{-\lambda x} dx = \frac{1}{\lambda} \int_0^{\infty} y e^{-y} dy = \frac{1}{\lambda} \left[0 + \int_0^{\infty} e^{-y} dy \right] = \frac{1}{\lambda}.$$



Оба приведенных выше определения являются частными случаями следующего определения математического ожидания как интеграла Стильтьеса.

Определение. Для случайной величины ξ с функцией распределения $F_\xi(x)$ математическим ожиданием называется

$$\mathbf{M}\xi = \int_{-\infty}^{+\infty} x F_\xi(dx) = \lim_{D \rightarrow 0} \sum_i x_i [F_\xi(x_i) - F_\xi(x_{i-1})],$$

где $D = \max |x_i - x_{i-1}|$ — диаметр разбиения.

Общее определение $\mathbf{M}\xi$ как интеграла Лебега приведено в приложении П2.

Рисунок 10 иллюстрирует геометрическое представление математического ожидания как разности площадей закрашенных областей со знаком «+» и знаком «-». Действительно, интегральная сумма в определении $\mathbf{M}\xi$ совпадает с суммой площадей (с учетом знака x_i) прямоугольников с шириной x_i и высотой $F_\xi(x_i) - F_\xi(x_{i-1})$. При измельчении разбиения она приближается к площади (с учетом знака) закрашенной области.

Геометрическое представление дает другой способ подсчета математического ожидания $\mathbf{M}\tau$ показательной случайной величины (см. рис. 5):

$$\mathbf{M}\tau = \int_0^{\infty} \mathbf{P}(\tau > x) dx = \int_0^{\infty} [1 - F_\tau(x)] dx = \int_0^{\infty} e^{-\lambda x} dx = \frac{1}{\lambda}.$$

Для случайной величины ξ , принимающей только целые неотрицательные значения: $\mathbf{P}(\xi = k) = p_k$, $k \geq 0$, геометрическое представление величины $\mathbf{M}\xi$ (рис. 11) объясняет следующую формулу:

$$\mathbf{M}\xi = \sum_{k=0}^{\infty} \mathbf{P}(\xi > k).$$

Замечание. Математическое ожидание определено не для всякой случайной величины. Возможна ситуация, когда на рис. 10 и площадь области со знаком «+», и площадь области со знаком «-»

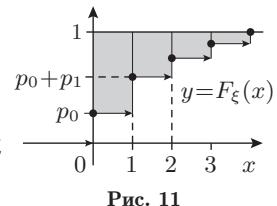


Рис. 11

О. Коши (1798–1857),
французский математик.

равны ∞ . В этом случае возникает неопределенность вида $\infty - \infty$. Например, для закона Коши с плотностью $p_\xi(x) = 1/[\pi(1+x^2)]$ каждая из площадей есть

$$\int_0^\infty x p_\xi(x) dx = \frac{1}{\pi} \int_0^\infty \frac{x}{1+x^2} dx = \frac{1}{2\pi} \int_0^\infty \frac{dy}{1+y} = \frac{1}{2\pi} \ln(1+y) \Big|_0^\infty = \infty.$$

Следовательно, $\mathbf{M}\xi$ не существует, несмотря на то, что 0 – центр распределения (плотность $p_\xi(x)$ симметрична относительно 0).

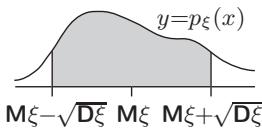


Рис. 12

Вопрос 4.

Как получить формулу (4) с помощью свойств математического ожидания из приложения П2?

Вы давиче его мне исчисляли свойства, но многие забыли? — Да?

Чацкий в «Горе от ума»

А. С. Грибоедова

[В слове «давеча»
сохранена авторская
орфография.]

Обсудим теперь понятие **дисперсии** случайной величины.

Как правило, помимо $\mathbf{M}\xi$ бывает важно знать величину типичного «разброса» значений ξ вокруг среднего. Мерой этого «разброса» может служить *стандартное отклонение* $\sqrt{\mathbf{D}\xi}$ (рис. 12), где дисперсия $\mathbf{D}\xi$ определяется формулой

$$\mathbf{D}\xi = \mathbf{M}(\xi - \mathbf{M}\xi)^2,$$

т. е. $\mathbf{D}\xi$ – это среднее квадрата отклонения ξ от $\mathbf{M}\xi$.

Для вычисления дисперсии полезно равенство

$$\mathbf{D}\xi = \mathbf{M}\xi^2 - (\mathbf{M}\xi)^2. \quad (4)$$

Для примера вычислим дисперсию бернуlliевской случайной величины ζ . Прежде всего, заметим, что ζ^2 и ζ одинаково распределены. Поэтому $\mathbf{M}\zeta^2 = \mathbf{M}\zeta = p$ и $\mathbf{D}\zeta = p - p^2 = p(1 - p)$.

§ 3. НЕЗАВИСИМОСТЬ СЛУЧАЙНЫХ ВЕЛИЧИН

Обычно вероятностную модель необходимо построить не для одного эксперимента, а для серии опытов. В этом случае нередко можно предполагать отсутствие взаимного влияния разных опытов друг на друга, их независимость.

Определение. Случайные величины ξ_1, \dots, ξ_n называются *независимыми*, если для любых $a_i < b_i$ ($i = 1, \dots, n$)

$$\mathbf{P}(a_i < \xi_i \leqslant b_i, i = 1, \dots, n) = \prod_{i=1}^n \mathbf{P}(a_i < \xi_i \leqslant b_i).$$

В частности, если все $a_i = -\infty$, то для произвольных x_1, \dots, x_n

$$\mathbf{P}(\xi_1 \leqslant x_1, \dots, \xi_n \leqslant x_n) = F_{\xi_1}(x_1) \cdot \dots \cdot F_{\xi_n}(x_n). \quad (5)$$

Независимые равномерно распределенные на отрезке $[0, 1]$ случайные величины η_1, \dots, η_n можно считать координатами случайного вектора, равномерно распределенного в n -мерном единичном кубе. Действительно, равенство

$$\mathbf{P}(\eta_i \leqslant b_i, i = 1, \dots, n) = (b_1 - a_1) \cdot \dots \cdot (b_n - a_n),$$

где $0 \leq a_i < b_i \leq 1$, означает, что вероятность попадания точки (η_1, \dots, η_n) в произвольный параллелепипед с параллельными осям координат ребрами и находящийся целиком внутри единичного куба равна его объему (рис. 13 при $n = 3$). На самом деле, параллелепипед можно заменить на любое множество A , для которого определено понятие n -мерного объема.

Говорят, что бесконечная последовательность $\{\xi_i\}$ образована независимыми случайными величинами, если свойство независимости выполняется для любого конечного набора из них.

Определение. Последовательность независимых бернуlliевских случайных величин ζ_1, ζ_2, \dots с одинаковой вероятностью «успеха» p называют испытаниями (или однородной схемой) Бернуlli.^{*)}

В заключение параграфа приведем интуитивно понятное утверждение, которое часто применяется при доказательстве статистических теорем.

Лемма о независимости. Пусть ξ_1, \dots, ξ_{n+m} — независимые случайные величины; f и g — борелевские функции (см. приложение П2) на \mathbb{R}^n и \mathbb{R}^m соответственно. Тогда случайные величины $\eta_1 = f(\xi_1, \dots, \xi_n)$ и $\eta_2 = g(\xi_{n+1}, \dots, \xi_{n+m})$ независимы.

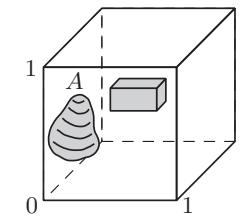


Рис. 13

Доказательство этой леммы можно найти, например, в [48, с. 53].

§ 4. ПОИСК БОЛЬНЫХ

Применим элементарную теорию вероятностей к решению одной проблемы выявления больных (см. [82, с. 254]).

Во время второй мировой войны всех призывников в армию США подвергали медицинскому обследованию. Реакция Вассермана позволяет обнаруживать в крови больных сифилисом определенные антитела. Р. Дорфманом была предложена простая методика, на основе которой необходимое для выявления всех больных число проверок удалось уменьшить в 5 раз!

МЕТОДИКА. Смешиваются пробы крови k человек и анализируется полученная смесь (рис. 14). Если антител нет, то этой одной проверки достаточно для k человек. В противном случае кровь каждого человека из этой группы нужно исследовать отдельно, и для k человек всего потребуется $k + 1$ раз провести анализ.

ВЕРОЯТНОСТНАЯ МОДЕЛЬ. Предположим, что вероятность обнаружения антител p одна и та же для всех n обследуемых, и результаты анализов для различных людей независимы, т. е. моделью является последовательность из n испытаний Бернуlli с вероятностью «успеха» p .

Допустим для простоты, что n делится нацело на k . Тогда надо проверить n/k групп обследуемых. Пусть X_j — количество

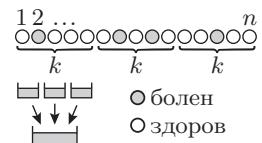


Рис. 14

^{*)} Если у каждой случайной величины ζ_i своя вероятность «успеха» p_i , то схему называют неоднородной.

проверок, потребовавшихся в j -й группе, $j = 1, \dots, n/k$. Тогда

$$X_j = \begin{cases} 1 & \text{с вероятностью } (1-p)^k \text{ (все } k \text{ человек здоровы),} \\ k+1 & \text{с вероятностью } 1 - (1-p)^k \text{ (есть больные).} \end{cases}$$

Обозначим общее число проверок $X_1 + \dots + X_{n/k}$ через Z . Задача заключается в том, как для заданного значения p^*) определить размер группы $k_0 = k_0(p)$, минимизирующий $\mathbf{M}Z$.

Согласно формуле (1) находим

$$\mathbf{M}X_j = 1 \cdot (1-p)^k + (k+1) \cdot [1 - (1-p)^k] = k+1 - k(1-p)^k.$$

Отсюда по свойствам математического ожидания (П2) имеем

$$\mathbf{M}Z = \mathbf{M}X_1 + \dots + \mathbf{M}X_{n/k} = \frac{n}{k} \mathbf{M}X_1 = n \left[1 + 1/k - (1-p)^k \right].$$

Положим $H(x) = 1 + 1/x - (1-p)^x$ при $x > 0$.

Для близких к нулю значений p минимум функции $H(x)$ достигается в точке x_0 , где x_0 — наименьший из корней уравнения $H'(x) = 0$, т. е. уравнения

$$1/x^2 + (1-p)^x \ln(1-p) = 0. \quad (6)$$

Его нельзя разрешить явно относительно x . Поэтому, используя формулу $(1-p)^x \approx 1 - px$ при малых p , заменим $H(x)$ на функцию $\tilde{H}(x) = 1 + 1/x - 1 + px = 1/x + px$, имеющую точку минимума $\tilde{x}_0 = 1/\sqrt{p}$, причем $\tilde{H}(\tilde{x}_0) = 2\sqrt{p}$. Для $p = 0,01$ получаем $\tilde{x}_0 = 10$ и $\tilde{H}(\tilde{x}_0) = 1/5$, т. е. $\mathbf{M}Z \approx n/5$.^{**)}

Вопрос 5.

Чем плох слишком большой размер группы?

Вопрос 6.
Какая ошибка допущена на рис. 15 в изображении графика функции $H(x)$ при малых p ?

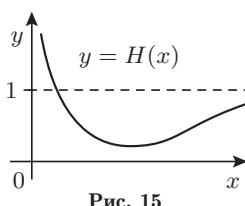


Рис. 15

Не пропускайте их, они еще не раз пригодятся в дальнейшем!

Я занимался до сих пор решением ряда задач, ибо при изучении наук примеры полезнее правил.

И. Ньютон,

«Всеобщая арифметика»

ЗАДАЧИ

1. Докажите, используя свойства математического ожидания (П2), что функция $f(a) = \mathbf{M}(\xi - a)^2$ при $a = \mathbf{M}\xi$ имеет минимум, равный $\mathbf{D}\xi$.
2. Случайные величины η_1, \dots, η_n независимы и равномерно распределены на отрезке $[0, 1]$. Вычислите $\mathbf{M}\bar{\eta}$ и $\mathbf{D}\bar{\eta}$ среднего арифметического $\bar{\eta} = \frac{1}{n}(\eta_1 + \dots + \eta_n)$.
3. Для случайных величин из задачи 2 найдите функцию распределения $F_{\eta_{(n)}}(x)$, $\mathbf{M}_{\eta_{(n)}}$ и $\mathbf{D}_{\eta_{(n)}}$, где $\eta_{(n)} = \max\{\eta_1, \dots, \eta_n\}$.
4. Обозначим через ν число «неудач» до появления первого «успеха» в схеме Бернулли с параметром p . Вычислите $\mathbf{M}\nu$.
УКАЗАНИЕ. Примените формулу (3).
5. Рассмотрим следующую стратегию поиска больных. Все обследуемые разбиваются на пары. Если объединенная проба крови не содержит антител, то оба здоровы. В противном случае исследуется кровь первого из них. Если этот человек здоров, то другой должен быть болен, и в таком случае достаточно двух

^{*)} Это значение можно оценить с помощью частоты выявления заболевания в предыдущих обследованиях.

^{**) Асимптотика x_0 и $H(x_0)$ при $p \rightarrow 0$ исследуется в задаче 6.}

тестов. Если же первый оказался больным, то кровь второго также должна быть подвергнута анализу, и поэтому потребуется три теста. Выясните, при каких значениях вероятности p обнаружения заболевания у отдельного обследуемого данная стратегия будет в среднем экономичнее индивидуальной проверки.

- 6*** Пусть $x_0 = x_0(p)$ — наименьший из корней уравнения (6). Докажите, что $x_0 \sim 1/\sqrt{p}$ и $H(x_0) \sim 2\sqrt{p}$ при $p \rightarrow 0$.^{*)}

РЕШЕНИЯ ЗАДАЧ

- 1.** С учетом свойств математического ожидания (см. приложение П2) и формулы (4) находим, что функция

$$f(a) = \mathbf{M}[\xi^2 - 2a\xi + a^2] = \mathbf{M}\xi^2 - 2a\mathbf{M}\xi + a^2 = (a - \mathbf{M}\xi)^2 + \mathbf{D}\xi$$

есть квадратный трехчлен с минимумом в точке $a = \mathbf{M}\xi$.

- 2.** Согласно формуле (2) $\mathbf{M}\eta_1 = \int_0^1 x dx = 1/2$. (Это можно понять и без вычислений: плотность $p_{\eta_1}(x) = I_{[0, 1]}$ симметрична относительно прямой $x = 1/2$.)

Далее, в силу следствия из П2 имеем $\mathbf{M}\eta_1^2 = \int_0^1 x^2 dx = 1/3$.

Применяя формулу (4), получаем, что $\mathbf{D}\eta_1 = 1/3 - 1/4 = 1/12$.

Наконец, согласно свойствам математического ожидания и дисперсии из приложения П2 запишем:

$$\mathbf{M}\bar{\eta} = \frac{1}{n} (\mathbf{M}\eta_1 + \dots + \mathbf{M}\eta_n) = \mathbf{M}\eta_1 = \frac{1}{2},$$

$$\mathbf{D}\bar{\eta} = \frac{1}{n^2} (\mathbf{D}\eta_1 + \dots + \mathbf{D}\eta_n) = \frac{1}{n} \mathbf{D}\eta_1 = \frac{1}{12n}$$

(во второй строке использована независимость случайных величин η_1, \dots, η_n).

Обратим внимание на то, что случайные величины η_1 и $\bar{\eta}$ имеют одинаковое математическое ожидание, но дисперсия у $\bar{\eta}$ в n раз меньше. Эти соотношения, очевидно, выполняются и для произвольных независимых одинаково распределенных случайных величин $\varepsilon_1, \dots, \varepsilon_n$ с конечной дисперсией. Такая модель используется для описания ошибок измерения.

- 3.** Максимум из случайных величин η_1, \dots, η_n не превосходит x тогда и только тогда, когда все η_i не больше, чем x (рис. 16), поэтому

$$F_{\eta_{(n)}}(x) = \mathbf{P}(\eta_{(n)} \leq x) = \mathbf{P}(\eta_1 \leq x, \dots, \eta_n \leq x).$$

Растолковать прошу.

Репетилов
в «Горе от ума»
А. С. Грибоедова

Семь раз отмерь, а один — отрежь.

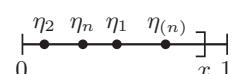


Рис. 16

^{*)} Здесь $f(p) \sim g(p)$ означает, что $f(p)/g(p) \rightarrow 1$.

В силу независимости случайных величин η_i из формулы (5) для $x \in [0, 1]$ выводим, что

$$F_{\eta(n)}(x) = \mathbf{P}(\eta_1 \leq x) \cdot \dots \cdot \mathbf{P}(\eta_n \leq x) = [\mathbf{P}(\eta_1 \leq x)]^n = x^n.$$

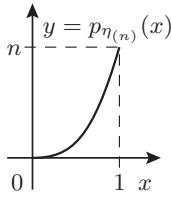


Рис. 17

График соответствующей плотности

$$p_{\eta(n)}(x) = dF_{\eta(n)}(x)/dx = nx^{n-1}I_{[0,1]}$$

изображен на рис. 17 (для $n > 2$).

Применяя формулу (2), вычисляем

$$\mathbf{M}\eta_{(n)} = \int_0^1 x nx^{n-1} dx = n \int_0^1 x^n dx = \frac{n}{n+1}.$$

Замечание. Интуитивно ясно, что длины отрезков, на которые делят $[0, 1]$ взятые наудачу n точек, распределены одинаково (см. задачу 7 из гл. 10). Поэтому самая правая из точек будет находиться в среднем на расстоянии $1/(n+1)$ от 1. [Однако, наименьший из отрезков разбиения имеет длину порядка $1/n^2$ (задача 4 из гл. 4).]

Наконец, $\mathbf{M}\eta_{(n)}^2 = \int_0^1 x^2 nx^{n-1} dx = n/(n+2)$, откуда в силу соотношения (4) находим, что

$$\mathbf{D}\eta_{(n)} = n/(n+2) - [n/(n+1)]^2 = n/[(n+1)^2(n+2)].$$

Замечание. Дисперсия $\mathbf{D}\eta_{(n)}$ с ростом n убывает намного быстрее, чем дисперсия $\mathbf{D}\bar{\eta}$: порядок малости первой есть $1/n^2$, второй — $1/n$. Это связано с тем, что плотность $p_{\eta_1}(x) = I_{[0,1]}$ имеет разрыв в точке $x = 1$.

4. Вероятность p_k того, что до первого «успеха» в схеме Бернулли будет ровно k «неудач», в силу независимости испытаний равна $q^k p$, где $q = 1 - p$ (рис. 18). Это так называемое *геометрическое распределение*.* Случайная величина ν дает пример дискретной случайной величины, имеющей счетное множество значений: $\mathbf{P}(\nu = k) = p_k$, $k \geq 0$. Суммируя геометрическую прогрессию, находим $\mathbf{P}(\nu > k) = p_{k+1} + p_{k+2} + \dots = q^{k+1}p(1 + q + \dots) = q^{k+1}$. Применяя формулу (3), получаем $\mathbf{M}\nu = q + q^2 + q^3 + \dots = q/p$.
5. Пусть Y_j — число проверок, потребовавшихся для j -й пары обследуемых ($j = 1, 2, \dots, n/2$), $q = 1 - p$. Тогда

$$Y_j = \begin{cases} 1 & \text{с вероятностью } q^2 \text{ (нет больных),} \\ 2 & \text{с вероятностью } qp \text{ (первый здоров, второй болен),} \\ 3 & \text{с вероятностью } (pq + p^2) = p \text{ (в противном случае).} \end{cases}$$

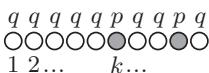


Рис. 18

*) Вероятности p_k образуют геометрическую прогрессию.