

# Содержание

<b>От издательства .....</b>	<b>10</b>
<b>Часть I. ЯН .....</b>	<b>11</b>
<b>Глава 1. Введение в причинность (каузальность) .....</b>	<b>12</b>
Зачем беспокоиться? .....	12
Наука о данных уже не та, что была раньше (или наконец-то стала таковой).....	12
Отвечая на вопросы другого рода .....	14
Когда ассоциация ЯВЛЯЕТСЯ причинно-следственной связью .....	15
Смещение .....	21
Ключевые идеи .....	28
<b>Глава 2. Рандомизированные эксперименты .....</b>	<b>29</b>
Золотой стандарт .....	29
В школе «на удаленке».....	31
Идеальный эксперимент.....	34
Механизм распределения .....	35
Ключевые идеи .....	36
<b>Глава 3. Обзор статистик: самое опасное уравнение .....</b>	<b>37</b>
Стандартная ошибка наших оценок .....	41
Доверительные интервалы .....	42
Тестирование гипотез .....	48
P-значения .....	53
Ключевые идеи .....	55
<b>Глава 4. Графовые причинно-следственные (каузальные) модели .....</b>	<b>57</b>
Рассуждая о причинности .....	57
Ускоренный курс по графовым моделям .....	59
Смещение, вызванное спутывающими факторами (ошибка спутывания, confounding bias) .....	66
Смещение из-за отбора (ошибка отбора, selection bias) .....	69
Ключевые идеи .....	74
<b>Глава 5. Поразительная эффективность линейной регрессии .....</b>	<b>75</b>
Все, что вам нужно, – это регрессия .....	75
Теоретические аспекты регрессии .....	79
Регрессия для неслучайных данных.....	81
Смещение, вызванное опущенной переменной или спутывающим фактором (omitted variable bias или confounding bias) .....	85
Ключевые идеи .....	89

<b>Глава 6. Регрессия, обученная на сгруппированных данных, и регрессия с дамми-переменными</b> .....	91
Регрессия, обученная на сгруппированных данных .....	91
Регрессия с дамми-переменными .....	97
Ключевые идеи .....	105
<b>Глава 7. Помимо спутывающих переменных</b> .....	106
«Хорошие» контрольные переменные .....	106
Преимущественно вредные контрольные переменные .....	113
Плохие контрольные переменные – смещение из-за отбора .....	119
Плохой COP-эффект .....	124
Ключевые идеи .....	130
<b>Глава 8. Инструментальные переменные</b> .....	131
Обход смещения, возникшего из-за опущенной переменной .....	131
Квартал рождения человека и влияние образования на заработную плату .....	135
Коэффициент регрессии 1-го этапа .....	137
Коэффициент короткой регрессии .....	140
Инструментальные переменные, созданные вручную .....	141
Несколько инструментальных переменных .....	143
Ключевые идеи .....	148
<b>Глава 9. Несоблюдение требований и LATE</b> .....	149
Погружаемся в разнородный мир .....	149
Локальный средний эффект воздействия (local average treatment effect – LATE) .....	155
Влияние на вовлеченность .....	158
Ключевые идеи .....	161
<b>Глава 10. Матчинг (сопоставление объектов тестовой и контрольной групп)</b> .....	162
Что же в конце концов делает регрессия? .....	162
Субклассификационная оценка .....	166
Матчинг-оценка .....	167
Смещенность матчинг-оценки .....	174
Проклятие размерности .....	178
Ключевые идеи .....	180
<b>Глава 11. Оценка склонности (Propensity Score)</b> .....	181
Психология роста .....	181
Оценка склонности .....	186
Взвешивание по склонности .....	188
Прогнозирование оценки склонности .....	190
Стандартная ошибка .....	194
Распространенные проблемы с оценкой склонности .....	196
Сопоставление по оценке склонности (propensity score matching) .....	200
Ключевые идеи .....	201
<b>Глава 12. Получение оценок с двойной робастностью</b> .....	203
Не кладите все яйца в одну корзину .....	203

Получение оценок с двойной робастностью .....	206
Ключевые идеи .....	212
<b>Глава 13. Метод разности разностей</b> .....	213
Три рекламных щита на юге Бразилии .....	213
Метод разности разностей (difference in differences – DiD) .....	215
Непараллельные тренды .....	221
Ключевые идеи .....	223
<b>Глава 14. Панельные данные и фиксированные эффекты</b> .....	224
Параллельные тренды .....	225
Контролируйте то, что вы не видите .....	226
Фиксированные эффекты .....	230
Визуализация фиксированных эффектов .....	236
Фиксированные эффекты для периодов времени .....	239
Когда панельные данные вам не помогут .....	240
Ключевые идеи .....	241
<b>Глава 15. Синтетический контроль</b> .....	242
Один удивительный математический трюк, позволяющий узнать то, что невозможно узнать .....	242
У нас есть время .....	245
Синтетический контроль в виде линейной регрессии .....	248
Не экстраполируйте .....	251
Делаем вывод .....	256
Ключевые идеи .....	262
<b>Глава 16. Разрывной регрессионный дизайн</b> .....	263
Алкоголь убивает вас? .....	264
Оценка RDD .....	267
Взвешивание с помощью ядерной функции .....	271
Эффект овчины и нечеткий RDD .....	274
Тест Маккрари .....	278
Ключевые идеи .....	282
Дополнительное чтение .....	283
<b>Часть II. ИНЬ</b> .....	285
<b>Глава 17. Курс по прогнозным моделям</b> .....	286
Машинное обучение в промышленности .....	287
Ускоренный курс по машинному обучению .....	292
Перекрестная проверка .....	295
Прогнозы и политики .....	297
Политика на основе одного признака .....	297
Политика на основе модели машинного обучения .....	302
Тонкая настройка политики .....	307
Ключевые идеи .....	310
Дополнительное чтение .....	311

<b>Глава 18. Гетерогенные эффекты воздействия и персонализация .....</b>	<b>312</b>
От прогнозов к анализу причинно-следственных связей .....	312
От АТЕ к CATE .....	314
Прогнозирование чувствительности .....	318
Ключевые идеи .....	327
Дополнительное чтение .....	328
 <b>Глава 19. Оценка качества причинно-следственных (каузальных) моделей .....</b>	 <b>329</b>
Чувствительность по диапазонам прогнозов модели .....	333
Кривая накопленной чувствительности (cumulative sensitivity curve) .....	337
Кривая накопленного выигрыша (cumulative gain curve) .....	341
Принимаем дисперсию во внимание .....	344
Ключевые идеи .....	347
Дополнительное чтение .....	347
 <b>Глава 20. Модели «Подключи и пользуйся» .....</b>	 <b>349</b>
Формулировка проблемы .....	349
Преобразование зависимой переменной .....	351
Случай непрерывного воздействия .....	357
Нелинейные эффекты воздействия .....	363
Ключевые идеи .....	364
Дополнительное чтение .....	365
 <b>Глава 21. Метамоделли .....</b>	 <b>367</b>
S-модель .....	368
T-модель .....	372
X-модель .....	376
Ключевые идеи .....	380
Дополнительное чтение .....	380
 <b>Глава 22. Несмещенное/ортогональное машинное обучение .....</b>	 <b>382</b>
Машинное обучение для мешающих параметров .....	384
Теорема Фриша–Во–Ловелла .....	385
Теорема Фриша–Во–Ловелла на стероидах .....	388
Оценивание CATE с помощью двойного машинного обучения .....	393
Непараметрическое двойное/несмещенное машинное обучение .....	394
Что такое непараметрическая оценка? .....	398
Ненаучное двойное/несмещенное машинное обучение .....	402
Возможно, потребуется больше эконометрики! .....	409
Ключевые идеи .....	411
Дополнительное чтение .....	412
 <b>Глава 23. Проблемы, связанные с гетерогенностью эффекта и нелинейностью .....</b>	 <b>413</b>
Эффекты воздействия для бинарного результата .....	413
Симулируем данные .....	416
Непрерывное воздействие и нелинейность .....	425

Ключевые идеи .....	429
Дополнительное чтение .....	430
<b>Глава 24. Сага о разности разностей</b> .....	431
1. Рождение: многообещающие панельные данные .....	433
2. Смерть: проблемы из-за гетерогенности эффекта .....	441
Изменение эффекта воздействия с течением времени .....	443
Дизайн анализа событий .....	452
3. Просветление: гибкая функциональная форма .....	455
Ключевые идеи .....	463
Дополнительное чтение .....	464
<b>Глава 25. Синтетическая разность разностей</b> .....	466
Ревизия метода разности разностей .....	470
Ревизия метода синтетического контроля .....	473
Синтетическая разность разностей .....	477
Временная гетерогенность эффекта и постепенная адаптация .....	489
Оценивание плацебо-дисперсии .....	495
Ключевые идеи .....	500
Дополнительное чтение .....	501
<b>Приложение 1. Устранение смещения с помощью ортогонализации</b> .....	502
<b>Приложение 2. Устранение смещения с помощью оценки склонности</b> .....	518
<b>Приложение 3. Когда прогнозирование не работает</b> .....	537
<b>Приложение 4. Когда прогнозные метрики опасны для причинно-следственных моделей</b> .....	563
<b>Приложение 5. Конформный вывод для синтетического контроля</b> .....	568
<b>Словарь</b> .....	586
<b>Предметный указатель</b> .....	592

# От издательства

## ***Отзывы и пожелания***

Мы всегда рады отзывам наших читателей. Расскажите нам, что вы думаете об этой книге – что понравилось или, может быть, не понравилось. Отзывы важны для нас, чтобы выпускать книги, которые будут для вас максимально полезны.

Вы можете написать отзыв на нашем сайте [www.dmkpress.com](http://www.dmkpress.com), зайдя на страницу книги и оставив комментарий в разделе «Отзывы и рецензии». Также можно послать письмо главному редактору по адресу [dmkpress@gmail.com](mailto:dmkpress@gmail.com); при этом укажите название книги в теме письма.

Если вы являетесь экспертом в какой-либо области и заинтересованы в написании новой книги, заполните форму на нашем сайте по адресу [http://dmkpress.com/authors/publish\\_book/](http://dmkpress.com/authors/publish_book/) или напишите в издательство по адресу [dmkpress@gmail.com](mailto:dmkpress@gmail.com).

## ***Список опечаток***

Хотя мы приняли все возможные меры для того, чтобы обеспечить высокое качество наших текстов, ошибки все равно случаются. Если вы найдете ошибку в одной из наших книг, мы будем очень благодарны, если вы сообщите о ней главному редактору по адресу [dmkpress@gmail.com](mailto:dmkpress@gmail.com). Сделав это, вы избавите других читателей от недопонимания и поможете нам улучшить последующие издания этой книги.

## ***Нарушение авторских прав***

Пиратство в интернете по-прежнему остается насущной проблемой. Издательство «ДМК Пресс» очень серьезно относится к вопросам защиты авторских прав и лицензирования. Если вы столкнетесь в интернете с незаконной публикацией какой-либо из наших книг, пожалуйста, пришлите нам ссылку на интернет-ресурс, чтобы мы могли применить санкции.

Ссылку на подозрительные материалы можно прислать по адресу электронной почты [dmkpress@gmail.com](mailto:dmkpress@gmail.com).

Мы высоко ценим любую помощь по защите наших авторов, благодаря которой мы можем предоставлять вам качественные материалы.

## ***Благодарность***

Издательство «ДМК Пресс» выражает искреннюю благодарность Дмитрию Колодезеву и Аслану Байрамкулову за неоценимую помощь в подготовке русскоязычного издания книги. Ваши знания, опыт и поддержка сыграли важную роль в создании качественного и доступного перевода. Спасибо за ваш вклад в популяризацию знаний!

ЧАСТЬ I



ЯН

# Глава 1

.....

## Введение в причинность (каузальность)

### Зачем беспокоиться?

Прежде всего вы можете задаться вопросом: зачем мне это? А вот зачем:

### Наука о данных уже не та, что была раньше (или наконец-то стала таковой)

Harvard Business Review назвал профессию data scientist самой сексуальной профессией XXI века <https://hbr.org/2012/10/data-scientist-the-sexiest-job-of-the-21st-century>. И это не было пустым заявлением. Вот уже десять лет профессия data scientist находится в центре внимания. Зарботная плата специалистов по искусственному интеллекту не уступала зарплатам суперзвезд спорта <https://www.economist.com/business/2016/04/02/million-dollar-babies>. В поисках славы и богатства сотни молодых специалистов вступили в то, что казалось неистовой золотой лихорадкой, чтобы как можно быстрее получить должность в сфере data science. Вокруг всей этой шумихи возникли целые новые отрасли. Чудесные методы обучения могут сделать вас специалистом по data science, не требуя от вас ни одной математической формулы. Специалисты-консультанты пообещали миллионы, если ваша компания сможет раскрыть потенциал данных. ИИ или машинное обучение называют новым электричеством, а данные – новой нефтью.

Все это время экономисты пытались ответить, каково истинное влияние образования на заработок, биостатистики пытались понять, приводят ли насыщенные жиры к более высокому риску сердечного приступа, а психологи

стремились понять, действительно ли слова поддержки приводят к более счастливому браку. Между тем мы забыли о тех, кто все это время занимался «старомодной» наукой с использованием данных. Если быть до конца честными, data science – не новая область. Мы просто узнали о ней только сейчас благодаря огромному количеству бесплатного маркетинга, предоставленного средствами массовой информации.

Если использовать аналогию Джима Коллинза, представьте, что вы наливаєте себе кружку любимого ледяного пива. Если вы сделаете это правильно, почти вся кружка будет занята пивом, однако наверху будет слой пены толщиной в один палец. Эта кружка похожа на data science.

Что здесь пиво? Статистические основы, научная любознательность, страсть к сложным задачам. Все это доказало свою ценность в течение сотен лет.

Что здесь пена? Нереалистичные ожидания, которые в конечном итоге исчезнут.

Эта пена может исчезнуть быстрее, чем вы думаете. Как пишет The Economist, «те же самые консультанты, которые предсказывают, что ИИ изменит мир, также сообщают, что настоящим менеджерам в реальных компаниях трудно внедрить ИИ, и энтузиазм по поводу него остывает. Светлана Сикуляр из исследовательской фирмы Gartner утверждает, что 2020 год может стать годом, когда мода на ИИ начнет спускаться по склону “цикла хайпа”, подробно описанного ее компанией. Инвесторы начинают понимать, что нужно проснуться и прыгнуть с подножки: исследование европейских стартапов в области ИИ, проведенное венчурным фондом ММС, показало, что 40 % из них, похоже, вообще не используют ИИ».

Что мы как специалисты по data science – или, еще лучше, как «просто» ученые – должны делать во время всего этого помешательства? Если вы сообразительны, вы научитесь игнорировать пену с самого начала. Мы здесь собрались из-за пива. Математика и статистика всегда были полезными, и вряд ли они прекратят свое существование сейчас. Изучайте именно то, что делает вашу работу ценной и еще раз ценной, а не новый блестящий инструмент, которым никто не научился пользоваться.

И последнее, но не менее важное: помните, что коротких путей не существует. Знания в области математики и статистики ценны именно потому, что их трудно приобрести. Если бы все могли это сделать, избыточное предложение привело бы к снижению его цены. Так что **наберитесь мужества!** Изучите их как можно лучше. И черт возьми, почему бы нет? Получайте удовольствие, поскольку мы приступаем к этому квесту **только для смелых и честных.**



«Соберись, неженка!»,  
«Поднапрягись, мягкотелый!» – фраза используется, чтобы в шутливой или подбадривающей форме сказать кому-то быть сильнее в какой-то ситуации

## Отвечая на вопросы другого рода

Машинное обучение в настоящее время очень хорошо отвечает на вопросы предсказательного характера. Как написали Аджай Агравал, Джошуа Ганс и Ави Голдфарб в книге «Prediction Machines», «новая волна искусственного интеллекта на самом деле приносит нам не интеллект, а важнейший компонент интеллекта – прогноз». Мы можем реализовать массу всяких красивых вещей с помощью машинного обучения. Единственное требование состоит в том, чтобы мы формулировали наши задачи как задачи прогнозирования. Хотите перевести с английского на португальский? Тогда создайте модель машинного обучения, которая предсказывает предложения на португальском языке при наличии предложений на английском языке. Хотите распознавать лица? Тогда создайте модель машинного обучения, которая предсказывает наличие лица на картинке. Хотите построить беспилотный автомобиль? Тогда создайте модель машинного обучения, которая спрогнозирует поворот руля, давление на тормоз и газ, основываясь на изображениях и данных датчиков автомобиля.

Однако машинное обучение не является панацеей. Оно может творить чудеса в условиях жестких ограничений и все же может с треском провалиться, если данные немного отклоняются от того, к чему привыкла модель. Приведу еще один пример из книги «Prediction Machines»: «во многих отраслях низкие цены связаны с низкими продажами. Например, в гостиничном бизнесе цены низкие, когда нет туристического сезона, и высокие, когда спрос резко возрастает, а отели заполнены. Учитывая эти данные, наивная прогнозная модель может предположить, что повышение цены приведет к увеличению количества проданных номеров».

Машинное обучение, как известно, плохо справляется с такой проблемой, как обратная причинно-следственная связь. Его просят отвечать на вопросы типа «что, если», которые экономисты называют контрфактическими. Что произойдет, если я укажу другую цену вместо той, которую сейчас прошу за свой товар? Что произойдет, если я сяду на диету с низким содержанием сахара вместо диеты с низким содержанием жиров, на которой я сижу? Если вы работаете в банке, выдавая кредит, вам придется выяснить, как изменение кредитной линии изменит ваш доход. Или, если вы работаете в органах местного самоуправления, вам могут предложить выяснить, как улучшить систему школьного образования. Стоит ли давать планшеты каждому ребенку, потому что так велит эра цифровых знаний? Или вам следует построить старомодную библиотеку?

В основе этих вопросов лежит поиск причин и следствий, которые мы хотим понять. Вопросы о причинно-следственных связях пронизывают повседневные задачи, например нам нужно выяснить, как увеличить продажи. А еще они играют существенную роль в очень личных и важных для нас дилеммах: должен ли я ходить в дорогую школу, чтобы добиться успеха в жизни (влияет ли образование на заработок)? Снижает ли иммиграция мои шансы на получение работы (приводит ли иммиграция к росту безработицы)? Дежурные выплаты бедным снижают уровень преступности? Не важно, в какой

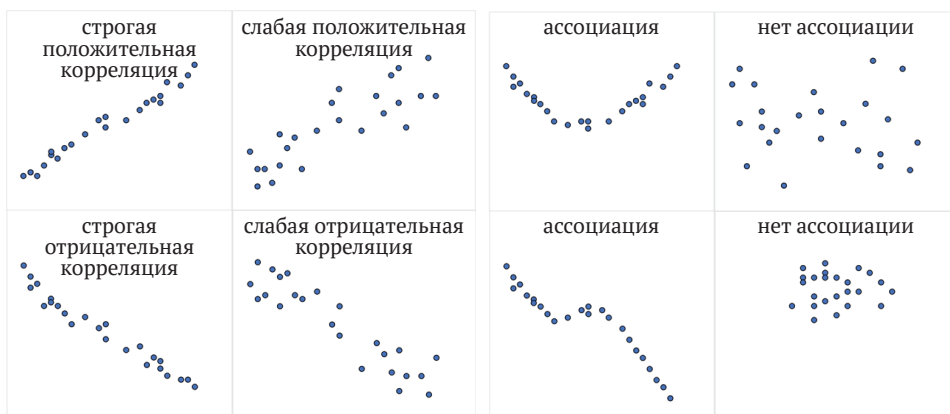
области вы работаете. Очень вероятно, что вам приходилось или придется отвечать на тот или иной вопрос о причинно-следственных связях. К сожалению для машинного обучения, пытаясь ответить на эти вопросы, мы не можем полагаться на прогнозы, основанные на корреляции.

Ответить на такой вопрос сложнее, чем думает большинство людей. Ваши родители, вероятно, неоднократно повторяли вам, что «ассоциация<sup>1</sup> – это не причинно-следственная связь» («ассоциация – это не каузация»). Но на самом деле объяснить, почему это так, немного сложнее. Именно этому и посвящено введение в анализ причинно-следственных связей (также мы будем называть его причинно-следственным анализом, каузальным анализом). Что касается остальной части данной книги, то она будет посвящена выяснению того, как превратить ассоциацию в причинно-следственную связь (каузацию).

## Когда ассоциация ЯВЛЯЕТСЯ причинно-следственной связью

Интуитивно мы как бы понимаем, почему ассоциация не является причинно-следственной связью. Если кто-то скажет вам, что школы, которые выдают своим ученикам планшеты, демонстрируют более высокие результаты

<sup>1</sup> Обратите внимание, что здесь и далее Матеус использует термин «ассоциация», а не «корреляция». Термины «ассоциация» и «корреляция» используются для описания того, существует ли связь между двумя случайными величинами. Оба термина можно использовать для анализа связи между случайными величинами с помощью диаграммы рассеяния. Корреляция количественно определяет связь между двумя случайными переменными, используя число от  $-1$  до  $1$ , но ассоциация не использует конкретное число для количественной оценки связи. Корреляция может только сказать нам, имеют ли две случайные величины линейную связь, в то время как ассоциация может сказать нам, имеют ли две случайные величины линейную или нелинейную связь. Поэтому нулевая корреляция между двумя переменными может нередко ввести в заблуждение, поскольку она скрывает тот факт, что вместо этого существует нелинейная связь. – *Прим. перев.*



успеваемости, чем школы, которые не выдают планшеты, вы можете на это быстро заявить, что, вероятно, школы, выдающие планшеты, богаче. Таким образом, в этих школах успеваемость будет выше, чем в среднем, даже без выдачи планшетов. В силу этого мы не можем сделать вывод, что предоставление планшетов детям во время занятий приведет к повышению их успеваемости. Можно лишь сказать, что планшеты в школе ассоциированы с высокой успеваемостью, измеренной по результатам экзамена ENEM<sup>1</sup>. Приведем ящичковые диаграммы для иллюстрации связи между наличием планшетов и успеваемостью, которая измерена в количестве баллов, полученных на экзамене ENEM.

```
import pandas as pd
import numpy as np
from scipy.special import expit
import seaborn as sns
from matplotlib import pyplot as plt
from matplotlib import style

style.use("fivethirtyeight")

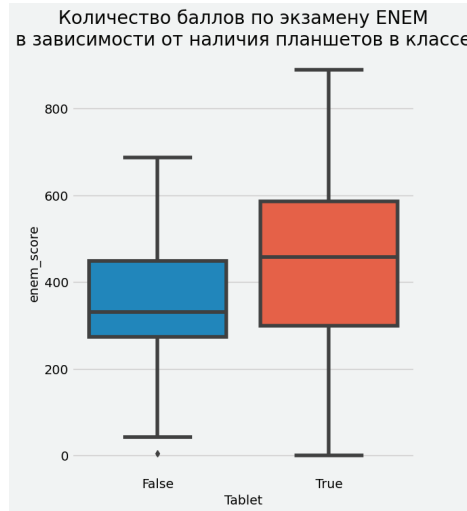
np.random.seed(123)
n = 100
tuition = np.random.normal(1000, 300, n).round()
tablet = np.random.binomial(
    1, expit((tuition - tuition.mean()) /
             tuition.std())).astype(bool)
enem_score = np.random.normal(200 - 50 * tablet + 0.7 * tuition, 200)
enem_score = (enem_score - enem_score.min()) / enem_score.max()
enem_score *= 1000

data = pd.DataFrame(dict(enem_score=enem_score,
                        Tuition=tuition,
                        Tablet=tablet))

plt.figure(figsize=(6,8))
sns.boxplot(y="enem_score",
            x="Tablet",
            data=data).set_title("Количество баллов по экзамену ENEM\n"
                                "в зависимости от наличия планшетов в классе")

plt.show()
```

<sup>1</sup> ENEM (Exame Nacional do Ensino Medio) является необязательным стандартизированным бразильским национальным экзаменом, который оценивает старшеклассников в Бразилии. ENEM – самый важный экзамен такого рода в Бразилии: в 2016 году было зарегистрировано более 8.6 млн кандидатов. Он является вторым по величине в мире после Национального вступительного экзамена в высшие учебные заведения Китая.



Чтобы выйти за рамки простой интуиции, давайте сначала введем некоторые обозначения. Это будет наш повседневный язык, позволяющий рассуждать о причинности. Представьте, что речь идет об общепринятом языке, который мы будем использовать для идентификации других смелых и честных воинов причинно-следственного анализа, и он станет боевым кличем в предстоящих битвах.

Пусть  $T_i$  – получение лечения  $i$ -м объектом.

$$T_i = \begin{cases} 1, & \text{если объект } i \text{ получил лечение} \\ 0 & \text{в противном случае} \end{cases}.$$

Лечение здесь не обязательно должно быть приемом лекарства или чем-то, связанным с медициной. Наоборот, это просто термин, который мы будем использовать для обозначения некоторого вмешательства, воздействия, эффект от которого хотим выяснить. Здесь мы будем использовать термины «лечение», «воздействие», «вмешательство» в качестве синонимов. В нашем случае лечение или воздействие заключается в выдаче планшетов студентам. Здесь же отметим, что иногда для обозначения лечения или воздействия будет использоваться  $D$  вместо  $T$ .

Пусть  $Y_i$  – наблюдаемое (фактическое) значение результирующей переменной для элемента  $i$ . Результирующая переменная – это интересующая нас переменная. Ее еще можно назвать переменной результата, зависимой переменной. Мы хотим выяснить, влияет ли на нее лечение. В нашем примере с планшетами результирующей переменной будет академическая успеваемость.

Вот тут-то все и становится интересным. **Фундаментальная проблема анализа причинно-следственных связей** состоит в том, что мы никогда не сможем наблюдать один и тот же объект, который подвергся воздействию

и остался без воздействия. Это как будто у нас – две расходящиеся дороги, и мы можем выяснить, что нас ждет впереди только на той дороге, по которой пойдем. Как в стихотворении Роберта Фроста:

*В осеннем лесу, на развилке дорог,  
Стоял я, задумавшись, у поворота;  
Пути было два, и мир был широк,  
Однако я раздвоиться не мог,  
И надо было решаться на что-то.*

Чтобы разобраться в этой проблеме, мы будем много говорить о **потенциальных результатах (potential outcomes)**. Они являются потенциальными, потому что на самом деле их не было. Они обозначают, **что произошло бы** в случае, если бы было оказано какое-либо воздействие. Мы иногда называем потенциальный результат, который произошел, фактическим, а тот, который не произошел, контрфактическим.

Что касается обозначений, мы введем дополнительный индекс:

- $Y_{0i}$  – потенциальный результат для объекта  $i$ , который не подвергся воздействию;
- $Y_{1i}$  – потенциальный результат для **того же самого** элемента  $i$ , который подвергся воздействию.

Потенциальные результаты можно записать в виде функций  $Y_i(t)$ , так что будьте внимательны.  $Y_{0i}$  может стать  $Y_i(0)$ , а  $Y_{1i}$  может стать  $Y_i(1)$ .

Здесь в большинстве примеров мы будем использовать индексную нотацию.



Вернемся к нашему примеру.  $Y_{1i}$  – это академическая успеваемость ученика  $i$ , если он или она посещает класс, в котором выдают планшеты. Получит или не получит ученик планшет, это не имеет значения для  $Y_{1i}$ . Нет никакой разницы. Если ученик получит планшет, мы сможем наблюдать  $Y_{1i}$ . Если

ученик не получит планшет, мы сможем наблюдать  $Y_{0i}$ . Обратите внимание, что в последнем случае результат  $Y_{1i}$  по-прежнему определен, мы просто не можем увидеть его. В данном случае речь идет о контрфактическом потенциальном результате.

Исходя из потенциальных результатов, мы можем определить индивидуальный эффект воздействия:

$$Y_{1i} - Y_{0i}.$$

Конечно, из-за фундаментальной проблемы причинно-следственного вывода мы никогда не сможем определить индивидуальный эффект воздействия, поскольку наблюдаем только один из потенциальных исходов. На данный момент давайте сосредоточимся на чем-то более простом, чем оценка индивидуального эффекта воздействия. Давайте сосредоточимся на **среднем эффекте воздействия (average treatment effect)**, который определяется следующим образом:

$$ATE = E[Y_1 - Y_0],$$

где  $E[...]$  – математическое ожидание. Другой более простой для оценки величиной является **средний эффект воздействия для тех, кто подвергся воздействию (average treatment effect on the treated)**<sup>1</sup>:

$$ATT = E[Y_1 - Y_0 | T = 1].$$

Теперь я знаю, что мы не можем увидеть оба потенциальных результата, но просто ради аргументации давайте предположим, что можем. Представьте, что бог причинно-следственного вывода удовлетворился многочисленными статистическими битвами, в которых мы поучаствовали, и наградил нас божественными способностями видеть потенциальные альтернативные результаты. Обладая такими возможностями, мы собираем данные по 4 школам. Мы знаем, раздавали ли они планшеты своим ученикам, а также их баллы по некоторым ежегодным академическим тестам. Здесь раздача планшетов – это воздействие, таким образом,  $T = 1$ , если школа предоставляет своим детям планшеты.  $Y$  – количество баллов, полученное по итогам теста.

```
pd.DataFrame(dict(
    i=[1, 2, 3, 4],
    Y0=[500, 600, 800, 700],
    Y1=[450, 600, 600, 750],
    T=[0, 0, 1, 1],
    Y=[500, 600, 600, 750],
    TE=[-50, 0, -200, 50],
))
```

<sup>1</sup> Термины «индивидуальный эффект воздействия», «средний эффект воздействия», «средний эффект воздействия для тех, кто подвергся воздействию» мы могли бы заменить на синонимы «индивидуальный эффект лечения», «средний эффект лечения», «средний эффект лечения для тех, кто подвергся лечению» соответственно.

	i	Y0	Y1	T	Y	TE
0	1	500	450	0	500	-50
1	2	600	600	0	600	0
2	3	800	600	1	600	-200
3	4	700	750	1	750	50

В реальном мире нам неизвестны эти значения (это контрфактические результаты)

Разберем первую строку таблицы.

Вы – руководство школы  $i = 1$ , в которой не выдали планшеты ( $T = 0$ ). Записываем успеваемость  $Y_0(0) = 500$ .

А что, если бы в школе выдали планшеты, какой была бы успеваемость? В реальной жизни вы не знаете. Записываем успеваемость  $Y_1(0) = \text{NaN}$ . Впрочем, если вы наделены божественными способностями, то знаете. Записываем успеваемость  $Y_1(0) = 450$ .

Разберем третью строку таблицы.

Вы – руководство школы  $i = 3$ , в которой выдали планшеты ( $T = 1$ ). Записываем успеваемость  $Y_1(1) = 600$ .

А что, если бы в школе не выдали планшеты, какой была бы успеваемость? В реальной жизни вы не знаете. Записываем успеваемость  $Y_0(1) = \text{NaN}$ . Впрочем, если вы наделены божественными способностями, то знаете. Записываем успеваемость  $Y_0(1) = 800$ .

Здесь  $ATE$  будет средним значением последнего столбца, т. е. средним значением эффекта воздействия:

$$ATE = (-50 + 0 - 200 + 50)/4 = -50.$$

Это означало бы, что планшеты снижают успеваемость студентов в среднем на 50 баллов.  $ATT$  здесь будет средним значением последнего столбца, когда  $T = 1$ :

$$ATT = (-200 + 50)/2 = -75.$$

Это говорит о том, что в школах, которые подверглись воздействию, планшеты снизили успеваемость учащихся в среднем на 75 баллов. Конечно, мы никогда не сможем этого узнать. В действительности приведенная выше таблица выглядела бы следующим образом:

```
pd.DataFrame(dict(
    i=[1, 2, 3, 4],
    Y0=[500, 600, np.nan, np.nan],
    Y1=[np.nan, np.nan, 600, 750],
    T=[0, 0, 1, 1],
    Y=[500, 600, 600, 750],
    TE=[np.nan, np.nan, np.nan, np.nan],
))
```

Конец ознакомительного фрагмента.

Приобрести книгу можно

в интернет-магазине

«Электронный универс»

[e-Univers.ru](http://e-Univers.ru)