

Четыре кабинки: МИНИ-ИССЛЕДОВАНИЕ

Статистика настраивает модель. Симуляция создаёт эксперименты. Анализ данных помогает принять решение.

Встреча 12 часть 2

Доктор Игорь Клейнер



Четыре кабинки. Как их разделить?

Проблема: ограниченный ресурс, случайный спрос и разные потребности.

В час пик одна очередь может расти, другая кабинка простаивать, а доступная кабинка — быть занята не тем, кому она нужна. Нам нужно правило, которое уменьшает ожидание и не ломает справедливость.



Это не шутка, а настоящая research problem

У задачи есть литература, термины и модели.

**Potty parity: как проектировать туалеты так, чтобы
ожидание, доступность и справедливость были
разумно сбалансированы.**

Реальная статья 1

queueing theory + simulation

Нун, Lee, Park & Park (2019) показывают, что норматив “поровну кабинок” не гарантирует равное ожидание. Они используют теорию очередей и симуляцию для potty parity.

«The potty parity problem: Towards gender equality at restrooms in business facilities»

Реальная статья 2

данные для настройки модели

Gwynne et al. (2019) анализировали время проведенное в аэропорту: 502 наблюдения, мужские, женские и доступные туалеты. Это пример данных, без которых симуляция остаётся фантазией.

The toilet paper: Bathroom dwell time observations at an airport

Реальная статья 3

efficiency + fairness + safety

Farajollahzadeh & Hu (2025) исследуют potty parity как задачу эффективности и справедливости: unisex-решения не всегда автоматически лучшие.

«Potty Parity: Process Flexibility via Unisex Restrooms»,

Реальный учебный кейс 4

стадион как учебная лаборатория

**INFORMS teaching case “Potty Parity: Stadium Restroom Design”
предлагает студентам сравнивать разные планировки туалетов по
ожиданию и справедливост — почти как наш проект сегодня.**

DOI: [10.1287/ited.2023.0051ca](https://doi.org/10.1287/ited.2023.0051ca)

Сегодня – не просто еще одна задача про туалеты

Это задача про очереди и ресурсы.

ВИДИМАЯ ИСТОРИЯ

кабинки
очереди
посетители

МАТЕМАТИКА

случайный поток
ограниченный ресурс
правило обслуживания

В литературе это называется Potty Parity

Очереди в туалетах — тема в теории очередей, симуляции и оптимизации.



Учёные сравнивают конфигурации туалетов, время ожидания и справедливость доступа.

Наш исследовательский вопрос

Мы не ищем “идеальный туалет вообще”.

При доступных данных и предположениях: какая политика управления кабинками даёт разумный баланс ожидания и доступности?

Маршрут проекта

От наблюдений до решения

1

Данные

кто и когда приходит

2

Статистика

оценить параметры

3

Симуляция

проверить политики

4

Orange

понять результаты

5

Решение

выбрать осторожно

Вопрос

12.12 Вопрос



Что бы вы сделали с четырьмя кабинками?

2+2? 3+1? всё универсальное? доступная только по назначению?

Ответ

12.12 Ответ



Сначала не выбираем. Сначала собираем данные.

Без данных мы спорим вкусами и стереотипами. С данными мы можем сравнивать последствия решений.

Совет учителя

практический ориентир



**Если задача кажется смешной, проверьте:
может быть, это просто понятная версия
серьёзной задачи.**

Кейс MIT + Beth Israel

Та же логика, но в настоящей больнице.

Emergency Department:
пациенты приходят случайно,
ресурсы ограничены,
ожидание важно. Это уже не
игрушка, а operations research.



MIT thesis: Beth Israel ED

Clay W. Noyes, MIT ORC, 2008

Analysis and Optimization of the Emergency Department at Beth Israel Deaconess Medical Center via Simulation. Руководитель: Dimitris Bertsimas.

MIT ORC thesis list + handle: 1721.1/45396

Что было в данных?

Один год обезличенных данных ED Dashboard.

**Модель опиралась на данные пациентов и ресурсов
Emergency Department за 01.02.2005–31.01.2006.**

Что строили?

Не просто график, а виртуальный поток пациентов.

Многоклассовые пациенты, изменяющийся во времени поток arrivals, service times, beds, waiting room policy и ресурсы.

Как проверяли модель?

Симуляция должна быть похожа на реальность там, где реальность известна.

В thesis сравнивали simulated waiting times с наблюдаемыми данными. Без validation красивый what-if опасен.

Что проверяли через what-if?

Изменения системы сначала тестировали виртуально.

**Больше beds, меньше downtime между пациентами,
point-of-care lab testing. Комбинация изменений
дала прогноз $\approx 21\%$ снижения waiting time.**

Урок для нашего проекта

Мы делаем то же самое в учебном масштабе.

**Реальные наблюдения → статистика → симуляция →
validation → what-if → осторожное решение.**

Шаг 1. Сбор данных

Нельзя симулировать то, о чём мы ничего не измерили.

**Один визит = время прихода + категория + доступная
потребность + время обслуживания.**

Как выглядит сырой протокол

Никаких имён. Только то, что нужно модели.

arrival_time	group	accessible_need	service_time
12:03	M	0	71 сек
12:04	W	0	129 сек
12:08	W	1	181 сек
12:09	M	0	66 сек

Доступная потребность — отдельный признак

Это не “ещё один пол” и не украшение таблицы.

**Для решения нам важно знать, кто может
пользоваться обычной кабинкой, а кому нужна
доступная.**

20 минут наблюдений — это данные?

Да. Но плохая опора для решения.

МАЛО

попали в случайный тихий
момент
или в случайный пик

ЛУЧШЕ

разные дни
разные часы
разные события

Вопрос

12.13 Вопрос



Какие данные вы бы забыли собрать?

Подумайте о том, что понадобится симулятору.

Ответ

12.13 Ответ



Чаще всего забывают время обслуживания.

Без него мы знаем, когда люди пришли, но не знаем, как долго они занимают ресурс.

Советы бывалого аналитика

практический ориентир



Перед сложной моделью проверьте: в таблице есть ли все переменные, без которых модель не сможет жить.

Как приходят люди?

Теперь статистика входит в проект.

Мы не “придумываем поток”. Мы проверяем гипотезу о потоке и оцениваем параметры.

Считаем приходы по интервалам

Например, каждые 5 минут.

интервал	мужчины	женщины	всего
12:00–12:05	2	4	6
12:05–12:10	1	3	4
12:10–12:15	3	6	9
12:15–12:20	0	2	2

Пуассон — это гипотеза

Люди приходят случайно, но не обязательно одинаково весь день.

**Модель Пуассона удобна, но её нельзя назначать
указом преподавателя.**

Простая проверка

Для Пуассона среднее и дисперсия обычно похожи.

ЕСЛИ ПОХОЖИ

**модель может быть
разумным первым
приближением**

ЕСЛИ НЕ ПОХОЖИ

**есть пики, зависимость или
смещение режимов**

Один λ на весь день?

Часто это слишком грубо.

Лучше: утром один поток, в перерыв другой, после лекции третий.

Вопрос

12.14 Вопрос



Можно ли просто спросить ChatGPT: “это Пуассон?”

Что в таком ответе будет полезно, а что опасно?

Ответ

12.14 Ответ



ИИ может подсказать проверки, но не заменить сами данные.

Хороший промпт просит план проверки. Плохой промпт просит авторитетное “да/нет” без анализа.

Независимы ли потоки?

Мужчины и женщины могут приходить вместе после одного события.

**Если всплески происходят одновременно,
независимость потоков сомнительна.**

Два способа моделировать

Выбор зависит от данных.

НЕЗАВИСИМЫЕ ПОТОКИ

отдельный λ для M
отдельный λ для W

ОБЩИЙ ПОТОК

сначала “люди”
потом распределяем по
категориям

Стоп, проверяем!

Предположение — это часть модели, а не украшение текста.

Каждое важное предположение должно иметь хотя бы простую проверку.

Оцениваем параметры

Статистика превращает наблюдения во входы симуляции.

**60 мужчин за 2 часа → примерно 30 мужчин в час. 90
женщин → примерно 45 женщин в час.**

А время обслуживания?

Не спешим выбирать распределение наугад.

Сначала смотрим гистограмму и box plot. Иногда лучше брать реальные наблюдаемые времена.

Есть реальные данные о dwell time

В аэропортовом исследовании наблюдали 502 пользователей туалетов.



Такие данные нужны, чтобы настраивать инженерные и симуляционные модели.

Совет от Игоря

практический ориентир



Не пытайтесь “угадать красивое распределение”, если можно использовать эмпирическое распределение из данных.

Что мы получили перед симуляцией

что должно остаться в голове

интенсивности приходов

доли групп и доступной
потребности

распределение времени
обслуживания

ограничения и предположения

проверки, которым доверяем


Теперь строим виртуальный туалет

У системы есть события, очереди и правила.

**Приход → ожидание → вход в кабинку →
обслуживание → выход.**

Логика одного посетителя

Событийная симуляция



Наши данные: что означает каждая таблица

Сначала данные настраивают модель. Потом симуляция рождает новые данные для Orange.

Таблица	Одна строка =	Главные поля	Зачем нужна
observed_5min_counts.csv	5 минут наблюдения	time_start, men_count, women_count, accessible_need_count	Оцениваем частоту приходов λ и проверяем гипотезу о потоке.
observed_service_times.csv	один визит	group, service_time_seconds	Понимаем, сколько времени человек занимает кабинку.
simulation_results_orange.csv	виртуальный день при одной политике	policy, avg_wait_min, p95_wait_min, critical_queue	Анализируем в Orange: какая политика работает и когда.
policy_summary.csv	одна политика	средние ожидания, риск очереди, utilization	Финальная сводка для решения и обсуждения.

Пример строки наблюдений

Day 1 | 12:00 | men=4 | women=2 | accessible=0 | total=6

Это значит: в окне 12:00–12:05 пришли 6 человек. Из таких строк мы оцениваем параметры модели, а не «угадываем» их.

Новые входные данные для проекта

Сначала проверяем мир, потом строим симулятор

1. Приходы по 5 минутам

216 интервалов: мужчины, женщины, accessible-need.
Проверяем Пуассон и независимость потоков.

2. Время обслуживания

650 визитов: длительность пребывания в кабинке.
Проверяем экспоненциальную модель и оцениваем параметры.

учебные синтетические данные



Таблица приходов: один ряд — 5 минут

Так выглядит сырьё для проверки модели потока

day	start	end	men	women	access	total
1	12:00	12:05	2	5	2	9
1	12:05	12:10	2	2	0	4
1	12:10	12:15	0	3	1	4
1	12:15	12:20	1	6	0	7
1	12:20	12:25	1	4	0	5

Что означает строка?

Например: с 12:00 до 12:05 пришли 2 мужчины, 5 женщин и 2 посетителя, которым нужна доступная кабинка.

Главная проверка

Похожи ли такие числа на независимые пуассоновские потоки?

Проверка 1: приход похож на Пуассон?

Пуассон — естественная первая модель для числа событий в равных интервалах

H_0

число приходов за 5 минут
имеет распределение
 $\text{Poisson}(\lambda)$

$\hat{\lambda}$

оцениваем просто: среднее
число приходов за один 5-
минутный интервал

χ^2

сравниваем наблюдаемые
частоты с ожидаемыми по
Пуассону

$p\text{-value} > 0.05$ не доказывает Пуассон. Оно говорит: у нас нет достаточных оснований отвергнуть эту модель.

Результат: пуассоновская модель проходит

Для каждого потока p-value выше 0.05: модель не отвергаем

Поток	$\hat{\lambda}$ за 5 мин	$\hat{\lambda}$ в час	p χ^2
мужчины	1.931	23.17	0.9088
женщины	2.796	33.56	0.6341
accessible	0.296	3.56	0.6702

Вывод для модели

Используем постоянные λ для каждого потока: мужчины, женщины, accessible-need.

Теперь симулятор получает не “примерно”, а параметры, оценённые по данным.

Проверка 2: потоки независимы?

Если мужчины и женщины приходят вместе после лекции — независимости нет

H_0

число мужчин и число женщин в одном 5-минутном окне независимы

Тест

χ^2 -тест независимости по таблице частот: 0, 1, 2, 3, 4+ посетителей

Результат

T

$p = 0.5978$

также $r = 0.035$, $p = 0.6129$

Вывод: в этих данных нет заметной статистической связи между потоками. Для учебной модели считаем их независимыми.

Время в кабине: экспоненциальная модель

Теперь проверяем не приходы, а длительность обслуживания

H_0

время пребывания в кабине
имеет экспоненциальное
распределение

Параметр

сначала оцениваем
среднее время,
потом $\text{rate} = 1 / \text{mean}$

Тест

Kolmogorov–Smirnov:
сравниваем реальные
времена с экспонентой с
оценённым средним

Это удобная учебная модель очереди: просто, понятно и легко встроить в симулятор.

Результат: экспонента тоже проходит

Среднее время становится параметром обслуживания в симуляции

Группа	среднее	rate/min	p KS
мужчины	76.4 сек	0.786	0.4237
женщины	108.7 сек	0.552	0.9669
accessible	169.9 сек	0.353	0.3973

76 сек

мужчины: среднее время

109 сек

женщины: среднее время

p-value в KS-тесте выше 0.05 для всех групп: в этом учебном наборе экспоненциальная модель не отвергается.

Параметры, которые идут в симулятор

После статистики у нас появились входы модели, а не догадки

Параметр	Оценка	Как используется
λ мужчин	23.17 / час	генерирует мужской поток
λ женщин	33.56 / час	генерирует женский поток
λ accessible	3.56 / час	генерирует потребность в доступной кабинке
mean service M	76.4 сек	время обслуживания мужчин
mean service W	108.7 сек	время обслуживания женщин
mean service A	169.9 сек	время обслуживания accessible

Теперь можно честно сказать: симуляция настроена по проверенным учебным данным.

Теперь запускаем виртуальные дни


Один запуск — один возможный день. Нам нужны сотни и тысячи запусков



Важно: мы сравниваем не один удачный день, а распределение результатов по многим виртуальным дням.

После симуляции возвращаемся к анализу данных

Симулятор создаёт новый CSV, а Orange помогает понять результат



Итог этапа: все входные предположения проверены, параметры оценены, можно переходить к экспериментам с политиками.

Что значит “политика”?

Это не политика в смысле идеологии. Это правило обслуживания.

Кто имеет право занять какую кабинку? Есть ли приоритет? Можно ли использовать свободную кабинку другого типа?

Политика А

Жёсткое разделение: каждый идёт только в свой тип кабинки.

Правило: W → только женские; M → только мужская; accessible_need → только доступная. Плюс: просто и понятно. Минус: свободная “чужая” кабинка не помогает длинной очереди.

2 женские + 1 мужская + 1 доступная.

Политика В

Тоже жёсткое разделение, но другой баланс.

1 женская + 2 мужские + 1 доступная.

Политика С

Больше гибкости, но доступная кабинка защищена.

3 универсальные + 1 доступная зарезервирована.

Политика D

Гибкость с приоритетом.

3 универсальные + доступная кабинка может быть гибкой, но доступная потребность имеет приоритет.

Политика D — общая очередь + приоритет для доступной кабинки.

Все посетители стоят в **одной общей очереди** и могут пользоваться любой обычной свободной кабинкой.

Доступная кабинка тоже не простаивает зря: если человека с особыми потребностями нет, её может занять любой посетитель. Но если такой человек появляется, то **следующая освободившаяся доступная кабинка** отдаётся ему в приоритетном порядке.

Политика E

Максимальная гибкость.

4 универсальные кабинки — простое правило, но не всегда лучший ответ на fairness-вопрос.

Вопрос

12.17 Вопрос



Какая политика победит?

Не торопитесь. Ответ зависит от входных параметров.

Ответ

12.17 Ответ



Скорее всего, не одна навсегда.

Хорошее исследование часто отвечает: “эта политика лучше при таких условиях”.

Что значит “лучше”?

Один средний показатель может спрятать несправедливость.

Среднее ожидание мало, но один человек ждёт 20 минут — это уже проблема.

Метрики проекта

Смотрим не одну цифру, а картину.

метрика	зачем нужна
avg_wait	общее качество сервиса
p95_wait	длинный хвост ожиданий
accessible_wait	справедливость доступа
share_over_5	доля неприятных ожиданий
utilization	не простаивают ли ресурсы

Метрики проекта: что значит «лучше»?

В очередях среднее ожидание — только начало. Нас интересуют хвосты, fairness и загрузка ресурса.

Метрика	Что измеряет	Как читать результат
avg_wait_min	среднее ожидание всех посетителей	общая эффективность системы
p95_wait_min	95% посетителей ждут не дольше этого времени	длинные очереди и “плохие дни”
avg_accessible_wait_min	среднее ожидание тех, кому нужна доступная кабинка	справедливость для важной группы
p95_accessible_wait_min	хвост ожидания accessible-группы	защита от редких, но неприятных случаев
share_wait_over_5min	доля посетителей, ждавших больше 5 минут	понятный бизнес-порог: очередь стала проблемой
utilization	доля времени, когда кабинки заняты	не простаивают ли ресурсы и не перегружены ли они
critical_queue	1, если p95 общий или accessible > 5 минут	целевая переменная для логистической регрессии

Главная ловушка: маленькое среднее может скрывать большую очередь у части людей

Решение: сравниваем политики по нескольким метрикам, а не по одной цифре

Решение — это не только максимум эффективности

В реальных сервисах есть ограничения.

**Например: p95 ожидания доступной группы должен
быть не выше 5 минут.**

Стоп, проверяем симулятор

Большой запуск нельзя начинать с веры.

Сначала проверяем очевидные случаи.

Крайние случаи

Они ловят глупые ошибки быстрее красивых графиков.

ПОЧТИ НЕТ ЛЮДЕЙ

**очередь должна почти
исчезнуть**

ОЧЕНЬ МНОГО ЛЮДЕЙ

**система должна
захлебнуться**

Ещё две проверки

Они проверяют логику ресурсов.

ДОБАВИЛИ КАБИНКУ

**ожидание не должно расти
систематически**

λ мужчин = 0

мужской поток исчезает

Маленький ручной пример

4–5 посетителей можно проследить глазами.

Если ручной пример не сходится — тысяча дней не спасёт модель.

Совет эксперта

практический ориентир



**Миллион запусков неправильного симулятора
даёт очень уверенный неправильный ответ.**

План эксперимента

Один виртуальный день — это история. Тысячи дней — данные.

**Запускаем много дней для каждой политики и
разных уровней нагрузки.**


Честное сравнение

Хитрость: одинаковый виртуальный день для разных политик.

**Приходы и времена обслуживания одинаковые.
Меняется только правило кабинок.**

Что варьируем?

what-if analysis



Сценарии нагрузки

Тихий день, обычный поток, час пик, событие после лекции.

Симуляция позволяет проверить больше миров, чем мы можем построить в реальности.

Симуляция стала фабрикой данных

Теперь один ряд — один виртуальный день.

**Мы получаем таблицу, которую можно открыть в
Orange.**

Orange-ready таблица

Пример колонок результата.

policy	λM	λW	avg_wait	p95_wait	critical
A	30	45	3.8	9.4	1
C	30	45	2.1	5.2	1
D	30	45	1.8	4.6	0
E	30	45	1.7	4.3	0

Два анализа данных в одном проекте

Это очень важная идея урока.

**До симуляции анализируем реальные наблюдения.
После симуляции анализируем виртуальные
эксперименты.**


Возвращаемся в Orange

Теперь мы анализируем результаты симуляции.

**EDA → графики → регрессия → классификация →
решение.**

Box Plot по политикам

Какая политика даёт меньше ожидание?



Линейная регрессия

Цель: предсказать среднее ожидание.

**features: λM , λW , service times, accessible_share,
policy. target: avg_wait_min.**

Логистическая регрессия

Цель: предсказать проблему, а не минуты.

critical_queue = 1, если p95 ожидания превысил 5 минут.

Дерево решений можно добавить

Оно часто хорошо объясняет условия поломки.

**Например: если λW высокое и политика жёсткая —
риск очереди растёт.**

Вопрос

12.22 Вопрос



Зачем анализировать данные, если мы сами их сгенерировали?

Это не тавтология, если параметры и сценарии менялись системно.

Ответ

12.22 Ответ



Чтобы понять закономерности в большом пространстве сценариев.

Симуляция даёт много экспериментов. Анализ данных помогает увидеть, какие факторы действительно важны.

Не ищем вечного победителя

Ищем условия, при которых решение работает.

**При малой нагрузке почти все политики похожи.
При пиковой нагрузке различия становятся
видимыми.**

Возможный результат

Именно так звучит осторожный научный вывод.

НЕ ТАК

**“Политика D лучшая
всегда”**

А ТАК

**“В нашей модели D лучше
при высокой нагрузке и
ограничении на
доступность”**

Данные не принимают решение за нас

Они показывают цену разных решений.

**Выбор зависит от целей: среднее ожидание,
fairness, доступность, безопасность, архитектура.**

Совет от Игоря

практический ориентир



**Сначала задайте критерий успеха. Иначе
“лучшее решение” будет меняться вместе с
настроением докладчика.**

Чем симулировать?

У каждого инструмента свой лучший мир.

Arena	NetLogo	Python	Python + ИИ
процессы, очереди, ресурсы	агенты и emergent behavior	гибкая модель и CSV	быстрый прототип + объяснение
сильно для discrete-event	сильно для ABM	сильно для воспроизводимости	сильно для старта
минус: среда и лицензии	минус: не всё удобно	минус: нужен код	минус: обязательно проверять

Когда какой инструмент?

Короткое практическое правило.

**Arena — business/discrete-event systems. NetLogo —
агентные миры и emergent behavior. Python —
гибкость и воспроизводимость. Python + ИИ —
быстрый старт, но только после проверки.**

Что используем мы?

Для курса важна связка: ИИ + Python/HTML + CSV + Orange.

ИИ помогает написать прототип. Симулятор создаёт данные. Orange помогает студентам анализировать результат без тяжёлого программирования.

Интерактивное приложение

Увидим очередь как живой процесс.

Слева параметры, в центре кабинки и люди, справа метрики. Кнопка CSV отправляет результат в Orange.



Что умеет приложение

Один день — анимация. 100 дней — данные.

**Меняем λ , долю доступной потребности, service time
и политику кабинок.**

Главная кнопка: скачать CSV

Так симуляция становится частью курса по анализу данных.


Студент запускает виртуальные дни, экспортирует таблицу и исследует её в Orange.

От симулятора к данным

Теперь компьютер не просто показывает мультфильм — он создаёт таблицу для анализа

Один виртуальный день = одна строка CSV.
1000 дней = материал для Orange и мини-статьи.

Запускаем модель много раз
сохраняем метрики каждого дня
сравниваем политики A–E
строим выводы не по одному случайному примеру



⏸ Пауза

🔄 Сначала

Скорость

1x

5x

10x

20x

Политика

A

B



C

D

E

1 W + 2 M + 1 A. Одна женская, две мужские, одна доступная. A — только для тех, кому о...

12:10:52



2 в очереди	2 / 4 кабинок занято	7 обслужено	3 макс. очередь
37 с среднее ожидание	2:07 p95 ожидания	— ожидание A/A+	26.7 % загрузка

Кнопка CSV должна запускать эксперимент

Скачать CSV — это не “сохранить экран”, а выполнить 1000 виртуальных дней

1 выбрали параметры

λM , λW , доля A/A+,
средние времена
обслуживания, политика

2 запустили 1000 дней

пока модель бежит, графики
среднего ожидания
постепенно растут и
стабилизируются

3 получили CSV

одна строка = один
виртуальный день; файл
готов для Orange

Что лежит в CSV

Столбцы — это параметры модели и метрики одного виртуального дня

CSV preview: one row = one virtual day

day	policy	lambda_m	lambda_w	n_visitors	avg_wait_min	avg_wait_m_min	avg_wait_w_min	wait_accessible	p95_wait_min	max_queue
1	D	30	30	175	0.094	0.139	0.039	0.116	0.761	5
2	D	30	30	163	0.039	0.044	0.033	0.0	0.314	2
3	D	30	30	176	0.097	0.099	0.094	0.069	0.607	3
4	D	30	30	209	0.075	0.102	0.049	0.004	0.612	4
5	D	30	30	172	0.034	0.028	0.04	0.0	0.298	3
6	D	30	30	190	0.083	0.064	0.101	0.0	0.583	5

В файле `toilet_model_default_A_to_E_5000_days.csv`:

- политика A — 1000 виртуальных дней,
- B — 1000,
- C — 1000,
- D — 1000,
- E — 1000.

Итого 5000 строк / 5000 виртуальных дней.

Главная единица анализа: день, а не отдельный человек.
Мы сравниваем политики по множеству виртуальных дней.

Метрики проекта

Среднее ожидание — важно, но оно не рассказывает всю историю

avg_wait_min среднее ожидание всех посетителей

avg_wait_m / avg_wait_w отдельное ожидание мужчин и женщин

avg_wait_accessible ожидание A/A+ группы


p95_wait_min 95% ждут не дольше этого значения

share_wait_over5 доля людей, ждавших больше 5 минут

critical_queue день считается проблемным

1000 дней: оценки стабилизируются

Сначала график скачет, потом среднее ожидание становится устойчивее




Это и есть смысл Monte Carlo:
много повторений превращают случайные дни в устойчивые оценки.

каждый день немного другой
мы смотрим накопленное среднее
линии мужчин, женщин и A/A+ можно сравнить

What-if: меняем политику

При тех же параметрах сравниваем А, В, С, D, Е




Policy summary: 1000 virtual days per policy

policy	avg_wait_min	avg_wait_m_min	avg_wait_w_min	avg_wait_accessible_min	p95_wait_min	share_wait_over5	critical_queue
A	1.029	1.646	0.389	0.52	5.275	0.058	0.41
B	3.337	0.144	6.403	0.486	14.468	0.216	0.952
C	0.261	0.26	0.261	0.016	1.667	0.002	0.01
D	0.062	0.062	0.062	0.052	0.415	0.0	0.0
E	0.066	0.068	0.064	0.062	0.454	0.0	0.0

При симметричном потоке политика В проигрывает: две мужские кабинки и одна женская создают перекос.

Справедливость: смотрим по группам

Нам важно не только общее ожидание, но и ожидание A/A+




Хорошее общее среднее не должно прятать плохой опыт отдельной группы.

мужчины
женщины
A/A+ посетители
сравниваем отдельно

Критические дни

Иногда важен не средний день, а риск неприятного дня




critical_queue = 1, если p95 > 5 минут или A/A+ ожидание стало слишком ВЫСОКИМ.

это уже задача классификации
можно предсказывать риск
решение становится управленческим

What-if: нагрузка меняет ответ

Политики могут быть похожи при малой нагрузке и расходиться при высокой



Ищем не “победителя навсегда”, а условия, при которых решение работает.

Что делаем в Orange

Открываем CSV и превращаем симуляцию в обычный data analysis workflow

EDA

Data Table
Box Plot: policy → avg_wait
Scatter: load → wait
Distribution: p95

Regression

target: avg_wait_min
features: λ , service, policy
цель: понять факторы
не магия, а объяснение

Classification

target: critical_queue
Logistic Regression
Confusion Matrix
ROC / AUC

Orange: EDA перед моделями

Сначала смотрим данные глазами, а уже потом строим модель

Box Plot

policy → avg_wait_min
policy → p95_wait_min
policy →
avg_wait_accessible_min

Scatter Plot

$x = \lambda M + \lambda W$
 $y = \text{avg_wait_min}$
color = policy

EDA отвечает: где картина очевидна, а где нужно моделирование?

Variable

Filter...

- ☐ mean_service_a_sec
- ☐ n_visitors
- ☐ avg_wait_min
- ☐ avg_wait_m_min
- ☐ avg_wait_w_min
- ☐ avg_wait_accessible_min
- ☒ p95_wait_min
- ☐ max_queue
- ☐ share_wait_over5
- ☐ utilization
- ☒ critical_queue
- ☐ day


☐ Order by relevance to subgroups

Subgroups

Filter...

None

- ☒ policy
- ☒ critical_queue



Variable

Filter...

- ☐ mean_service_a_sec
- ☐ n_visitors
- ☒ avg_wait_min
- ☐ avg_wait_m_min
- ☐ avg_wait_w_min
- ☐ avg_wait_accessible_min
- ☐ p95_wait_min
- ☐ max_queue
- ☐ share_wait_over5
- ☐ utilization
- ☒ critical_queue
- ☐ day


☐ Order by relevance to subgroups

Subgroups

Filter...

None

- ☒ policy
- ☒ critical_queue



Variable

Filter...

C

 policy

N

 lambda_m

N

 lambda_w

N

 accessible_share

N

 mean_service_m_sec

N

 mean_service_w_sec

N

 mean_service_a_sec

N

 n_visitors

N

 avg_wait_min

N

 avg_wait_m_min

N

 avg_wait_w_min

N

 avg_wait_accessible_min

N

 p95_wait_min

N

 max_queue

N

 share_wait_over5

N

 utilization

C

 critical_queue

N

 day

☐ Sort categories by frequency

Distribution

Fitted distribution

None

Bin width

0.5

Smoothing

10

☐ Hide bars

Columns

Split by


C policy

☐ Stack columns

☐ Show probabilities


☐ Show cumulative distribution


☒ Apply Automatically



Линейная регрессия

Первый вопрос: что сильнее всего двигает среднее ожидание?





Linear Regression - Orange

File View Window Help

Name

Linear Regression

Parameters

☒ Fit intercept (unchecking it fixes it to zero)

Regularization

☒ No regularization

☐ Ridge regression (L2)

☐ Lasso regression (L1)

☐ Elastic net regression

Regularization strength:

Alpha: 0.0001

Elastic net mixing:

L1 0.58 : 0.42 L2

☒ Apply Automatically

5000 | 12 | 5000

Test and Score - Orange

File Edit View Window Help

☒ Cross validation

Number of folds: 5

☐ Stratified

☐ Cross validation by feature

☐ Random sampling

Repeat train/test: 10

Training set size: 66 %

☒ Stratified

☐ Leave one out

☐ Test on train data

☐ Test on test data


Model	R2
Linear Regression	0.506

Compare models by: Mean sq

Linear Regres...	
Linear Regression	

Table shows probabilities that the score for the model in the column. Small numbers show negligible.

5000 | 1x5000



Linear Regression - Orange

File View Window Help

Name: Linear Regression

Parameters: ☒ Fit intercept (unchecking it fixes it to zero)

Regularization:

- ☐ No regularization
- ☒ Ridge regression (L2) Regularization strength: Alpha: 0.0001
- ☐ Lasso regression (L1) Elastic net mixing: L1 0.58 : 0.42 L2
- ☐ Elastic net regression

☒ Apply Automatically

Data Table - Orange

File Edit View Window Help

Info: 12 instances (no missing data), 1 feature, No target variable, 1 meta attribute

Variables: ☒ Show variable labels (if present), ☐ Visualize numeric values, ☒ Color by instance classes

Selection: ☒ Select full rows

	name	coef
1	intercept	0.950948
2	lambda_m	0
3	lambda_w	0
4	accessible_share	0
5	mean_service_...	0
6	mean_service_...	0
7	mean_service_a...	0
8	policy=A	0.0780198
9	policy=B	2.3861
10	policy=C	-0.69024
11	policy=D	-0.888985
12	policy=E	-0.884893


Restore Original Order

коэффициенты показывают направление влияния
очередь нелинейна, поэтому модель не идеальна
но она объясняет, что важно

«Линейная регрессия что-то видит, но система очередей нелинейна. Поэтому одной прямой всё не объяснить».

Логистическая регрессия

Второй вопрос: будет ли день проблемным?




critical_queue = 1
если p95 > 5 минут или
A/A+ ожидание слишком
высокое

получаем вероятность риска
смотрим Confusion Matrix
ROC/AUC показывает качество
разделения

Логистическая регрессия

Второй вопрос: будет ли день проблемным?



critical_queue = 1
если $p95 > 5$ минут или
A/A+ ожидание слишком
высокое

critical_queue = 1

если выполняется хотя бы одно:

- $p95_wait_min > 5$ — 5% самых долго ждущих посетителей ждут больше 5 минут;
- $avg_wait_accessible_min > 5$ — посетители A/A+ в среднем ждут больше 5 минут.

Иначе:

critical_queue = 0.

Логистическая регрессия

Второй вопрос: будет ли день проблемным?

The screenshot shows the Orange3 data mining software interface. A workflow is set up with the following components:

- File** widget connected to two **Data** widgets.
- One **Data** widget connects to a **Distributions** widget.
- The other **Data** widget connects to a **Logistic Regression** widget, which has a yellow warning icon.
- The **Logistic Regression** widget connects to a **Test and Score** widget.

A **Select Columns - Orange** dialog is open, showing the following configuration:

- Ignored (10):** n_visitors, avg_wait_m_min, avg_wait_w_min, avg_wait_accessible_min, p95_wait_min, max_queue, share_wait_over5, utilization, day, avg_wait_m.
- Features (7):** lambda_m, lambda_w, accessible_share, mean_service_m_sec, mean_service_w_sec, mean_service_a_sec.
- Target (1):** critical_queue.

The **Test and Score - Orange** window is open, showing the following settings and results:

- Method:** Cross validation
- Number of folds:** 5
- Stratified:** ☐
- Cross validation by feature:**
- Random sampling:** ☐
- Repeat train/test:** 10
- Training set size:** 66 %
- Stratified:** ☒
- Leave one out:** ☐
- Test on train data:** ☐
- Test on test data:** ☐

Evaluation results for target (None, show average over classes)

Model	AUC	CA	F1	Prec	Recall
Logistic Regression	0.963	0.870	0.876	0.910	0.870

Compare models by: Area under curve ☐ Negligible diff.: 0.1

Logistic Regression

critical_queue

Logistic Regression

critical_queue

Logistic Regression

critical_queue

линейная регрессия плохо предсказывает точное время,
но классификация довольно хорошо умеет предупреждать: «сегодня система рискует сломаться».

Как читать результат

Данные не принимают решение — они показывают последствия

Не так

“Политика D всегда
лучшая.”

Правильно

“В нашей модели, при этих
параметрах, D даёт низкое
ожидание и защищает A/A+.”

Практический вывод по базовой модели

D и E близки по среднему ожиданию, но D явно задаёт приоритет A/A+

Policy summary: 1000 virtual days per policy

policy	avg_wait_min	avg_wait_m_min	avg_wait_w_min	avg_wait_accessible_min	p95_wait_min	share_wait_over5	critical_queue
A	1.029	1.646	0.389	0.52	5.275	0.058	0.41
B	3.337	0.144	6.403	0.486	14.468	0.216	0.952
C	0.261	0.26	0.261	0.016	1.667	0.002	0.01
D	0.062	0.062	0.062	0.052	0.415	0.0	0.0
E	0.066	0.068	0.064	0.062	0.454	0.0	0.0

Если нужна простая рекомендация для учебной модели: D — хороший компромисс между гибкостью и fairness.

В опасна при симметричных потоках
C уже сильно лучше A/B
D/E почти убирают очередь в базовом режиме

Из проекта получается статья

Структура уже почти готова

1. Research question

2. Literature review

3. Synthetic data + assumptions

4. Statistical tests

5. Simulation model

6. What-if results

7. Orange analysis

8. Limitations

Мини-статья не обязана быть большой. Она обязана честно описывать данные, модель, проверки и ограничения.

Промпт для статьи

ИИ помогает оформить исследование, но не должен выдумывать результаты

Сформулируй учебную статью в LaTeX по нашему проекту: обзор литературы, синтетические данные, проверки Пуассона и экспоненциального времени, симуляция A–E, CSV, what-if analysis, Orange EDA, linear regression, logistic regression, выводы и ограничения. Не делай абсолютных утверждений: все выводы привязаны к параметрам модели.

полный промпт лежит в student_article_prompt.md

Что сдаёт студент

Проект должен быть воспроизводимым

CSV данные симуляции для Orange

Скрин/графики what-if и 2–3 анализа

Orange workflow что подключено и какой target

Вывод при каких условиях политика хороша


Ограничения что модель не учитывает

Финал проекта

Симуляция стала мостом между статистикой и анализом данных

Статистика настроила модель.
Симуляция создала данные.
Orange помог понять результат.
Решение всё равно принимает человек.

это маленький research project
его можно расширять реальными данными
его можно оформить как ученическую статью



Из этого уже получается статья

Игрушечная, но по настоящей исследовательской логике.

**Вопрос → данные → статистика → симуляция →
проверка → результаты → ограничения.**

Учебное мини-исследование: симуляция очередей к четырём туалетным кабинкам

Учебный проект курса «Анализ данных в век ИИ»
Авторский черновик для студентов

2026

Аннотация

В работе показан полный учебный цикл анализа: обзор литературы по проблеме справедливого распределения туалетных ресурсов, генерация фиктивных наблюдений, проверка статистических предположений, оценка параметров, построение имитационной модели, проведение what-if анализа и анализ результатов с помощью моделей машинного обучения. Центральная задача: как распределить четыре кабинки между несколькими типами посетителей так, чтобы уменьшить ожидание и сохранить доступность A/A+ кабинки для тех, кому она нужна. Все данные в этой версии синтетические и предназначены для обучения.

1. Исследовательский вопрос

Пусть в общественном месте есть четыре кабинки. Посетители приходят случайно: мужчины, женщины и посетители, которым нужна доступная кабинка A/A+. Нужно выбрать политику использования кабинок. Мы сравниваем пять политик:

- A: две женские кабинки, одна мужская и одна строго доступная A;
- B: одна женская, две мужские и одна строго доступная A;
- C: три универсальные кабинки и одна строго доступная A;
- D: три универсальные кабинки и одна A+ с приоритетом для A/A+ посетителей;
- E: четыре универсальные кабинки.

Это не только бытовая задача. Математически это задача о случайном потоке, ограниченных ресурсах, очередях, политике обслуживания и fairness. Подобные задачи изучаются в operations research, queueing theory и simulation.

2. Короткий обзор литературы

Тема “potty parity” рассматривает равный доступ к туалетным ресурсам и различия во времени ожидания. Huh, Lee, Park and Park (2019) используют теорию очередей и симуляцию для сравнения ожидания мужчин и женщин в бизнес-объектах и показывают, что формальные нормы распределения кабинок не всегда дают равное ожидание. Gwynne et al. (2019) собрали данные о времени пребывания в туалетах аэропорта: 502 наблюдения, включая мужские, женские и доступные туалеты; такие данные важны для настройки моделей обслуживания. Учебный кейс INFORMS по stadium restroom design показывает, как использовать queueing и

fairness metrics для обсуждения разных layouts. Для статистической базы мы опираемся на стандартные идеи из вводных курсов вероятности и статистики, включая закон Пуассона, экспоненциальное распределение и закон больших чисел.

3. Данные и статистические предположения

В учебной версии мы используем синтетические наблюдения. Мы предполагаем:

1. число приходов мужчин и женщин за равные интервалы времени имеет распределение Пуассона;
2. потоки мужчин и женщин независимы;
3. время обслуживания в кабинке имеет экспоненциальное распределение;
4. часть посетителей имеет потребность в доступной кабинке.

Для проверки модели в учебном сценарии можно использовать:

- хи-квадрат goodness-of-fit test для проверки пуассоновского распределения числа приходов в одинаковых интервалах;
- тест независимости или корреляционный анализ для проверки связи между потоками мужчин и женщин;
- Kolmogorov-Smirnov test или QQ-plot для проверки экспоненциального распределения времени обслуживания.

Оценки параметров в базовой модели:

$$\lambda_M = 30 \text{ человек/час}, \quad \lambda_W = 30 \text{ человек/час}, \quad p_A = 0.06.$$

Средние времена обслуживания:

$$\mu_M = 76 \text{ сек}, \quad \mu_W = 109 \text{ сек}, \quad \mu_A = 170 \text{ сек}.$$

Для экспоненциального распределения параметр скорости равен $1/\mu$, если μ измерено в тех же единицах времени.

4. Имитационная модель

Один виртуальный день длится 180 минут. Для каждого потока генерируются времена прихода. Каждый посетитель получает тип, признак A/A+ и время обслуживания. Затем модель проигрывает события во времени: приход, ожидание, назначение кабинки, вход, выход. Главное правило корректности: одна кабинка не может одновременно обслуживать двух посетителей и не может быть одновременно занята и зарезервирована для другого человека.

5. CSV как результат симуляции

В симуляции одна строка файла CSV соответствует одному виртуальному дню. Пример структуры файла показан на рис. 1.

CSV preview: one row = one virtual day

day	policy	lambda_m	lambda_w	n_visitors	avg_wait_min	avg_wait_m_min	avg_wait_w_min	avg_wait_w_max	p95_wait_min	max_queue
1	D	30	30	175	0.004	0.130	0.039	0.116	0.761	5
2	D	30	30	163	0.018	0.044	0.033	0.0	0.114	2
3	D	30	30	176	0.003	0.009	0.006	0.009	0.607	3
4	D	30	30	209	0.015	0.107	0.009	0.004	0.612	6
5	D	30	30	172	0.014	0.036	0.04	0.0	0.708	4
6	D	30	30	190	0.003	0.004	0.011	0.0	0.503	5

Рис. 1: Пример CSV: одна строка - один виртуальный день.

6. What-if анализ

Мы запустили 1000 виртуальных дней для каждой политики A-E при базовых параметрах. Это даёт возможность сравнивать политики не по одному случайному дню, а по устойчивым средним.




Рис. 2: Среднее ожидание при базовых параметрах.

сированное разделение кабинок резко проигрывает универсальным и гибким схемам.




Рис. 5: What-if анализ: зависимость ожидания от общей нагрузки.

8. Анализ данных в Orange

Файл `toilet_model_whatif_orange_3500_runs.csv` можно открыть в Orange. Примеры анализа:

- **Data Table**: проверить столбцы и типы переменных;
- **Box Plot**: сравнить `avg_wait_min` по policy;
- **Scatter Plot**: посмотреть связь `lambda_m` + `lambda_w` с ожиданием;
- **Linear Regression**: предсказывать среднее ожидание;
- **Logistic Regression**: предсказывать событие `critical_queue`.

9. Линейная регрессия

Цель линейной регрессии: объяснить, какие факторы увеличивают среднее ожидание. Используются признаки: политика, интенсивности потоков, доля A/A+ и средние времена обслуживания.

Структура статьи

мини-исследование



Осторожный язык вывода

Это признак нормальной науки.

Не “мы доказали”. А “в нашей модели, при таких предположениях, получили...”.

Ограничения модели

что должно остаться в голове

учебные категории упрощают
реальный мир

потоки могут зависеть от событий

поведение людей может меняться


архитектура и безопасность не
сведены к очереди

результат требует проверки на реальных данных

Уголок библиофила

A Modern Introduction to Probability and Statistics


Dekking, Kraaikamp, Lopuhaä & Meester. Springer Texts in Statistics. Хорошая книга про “почему и как”, а не только рецепты.



Почему она здесь уместна?

В нашем проекте встретились почти все базовые идеи.

**Случайные величины, независимость, дискретные
распределения, Poisson process, оценивание
параметров, simulation и статистическое мышление.**




Как читать после урока?

Не как инструкцию по туалетам, а как фундамент.

**Ищите главы про дискретные случайные величины,
Poisson process, simulation и статистическое
оценивание. Это язык, на котором написана наша
модель.**

Весь маршрут урока

От мира к решению



Финальное summary

что должно остаться в голове

статистика настраивает входы

симуляция создаёт виртуальные эксперименты

анализ данных объясняет результаты

ИИ помогает, но не заменяет проверку

решение принимает человек

Вопрос

12.27 Финальный вопрос



Если данные для статьи сгенерированы симуляцией — это настоящая наука?

Хороший вопрос для финальной дискуссии.

Ответ

12.27 Финальный ответ



Да, если честно описаны данные, модель, проверки и ограничения.

Но симуляционная статья не говорит: “так устроен мир”. Она говорит: “в такой модели при таких предположениях получается вот это”.

Готовый проект урока

Что остаётся студенту после занятия.

**PPT + HTML-симуляция + CSV для Orange + статья +
промпты для ИИ.**
