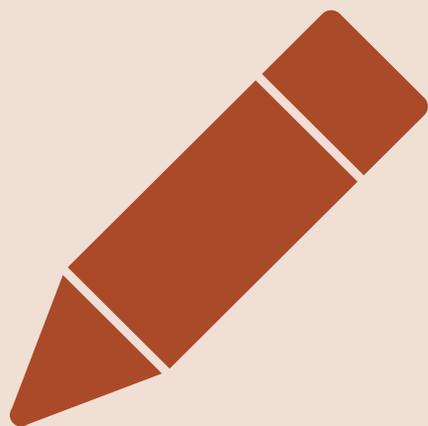


# ИССЛЕДОВАНИЕ

## Хахахахахакатон

---



1. Демидов Илья
2. Толстобров Артем
3. Екатерина Комкова
4. Озийгит Алекс
5. Нестеров Алексей
6. Худокормова Мария

# Мотивация

Повлиять на часть общества, которая не перестает нарушать ПДД, несмотря на множество штрафов.

# Исследовательский вопрос:

Взаимосвязаны ли характеристики клиентов и их автомобилей с характеристиками правонарушений и если да, то как?

## Гипотеза:

Доля рецидивистов\* среди богатых больше, чем среди бедных

\*рецидивист – человек, нарушивший ПДД более **одного** раза

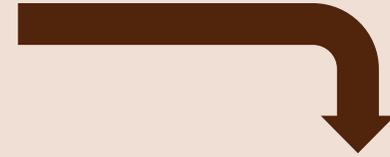
# Механизм

Для бедных



Человек нарушает ПДД и платит штраф

Для богатых



штраф является **значительной** суммой денег относительно заработка

штраф является **незначительной** суммой денег относительно заработка



Человек старается водить аккуратнее и не нарушает правила



Человек никак не отреагировал

# База данных

**97307**

штрафов, полученных  
клиентами Т-Банка

В период с 28.04.2024 по 28.05.2024

# Структура данных

## Количественные

- Возраст водителя
- Размер месячного дохода водителя
- Объем двигателя автомобиля
- Мощность двигателя
- Цена машины
- Год выпуска автомобиля
- Время совершения правонарушения

## Качественные

- Регион, в котором совершено правонарушение
- Пол водителя

# Доработка датасета

923

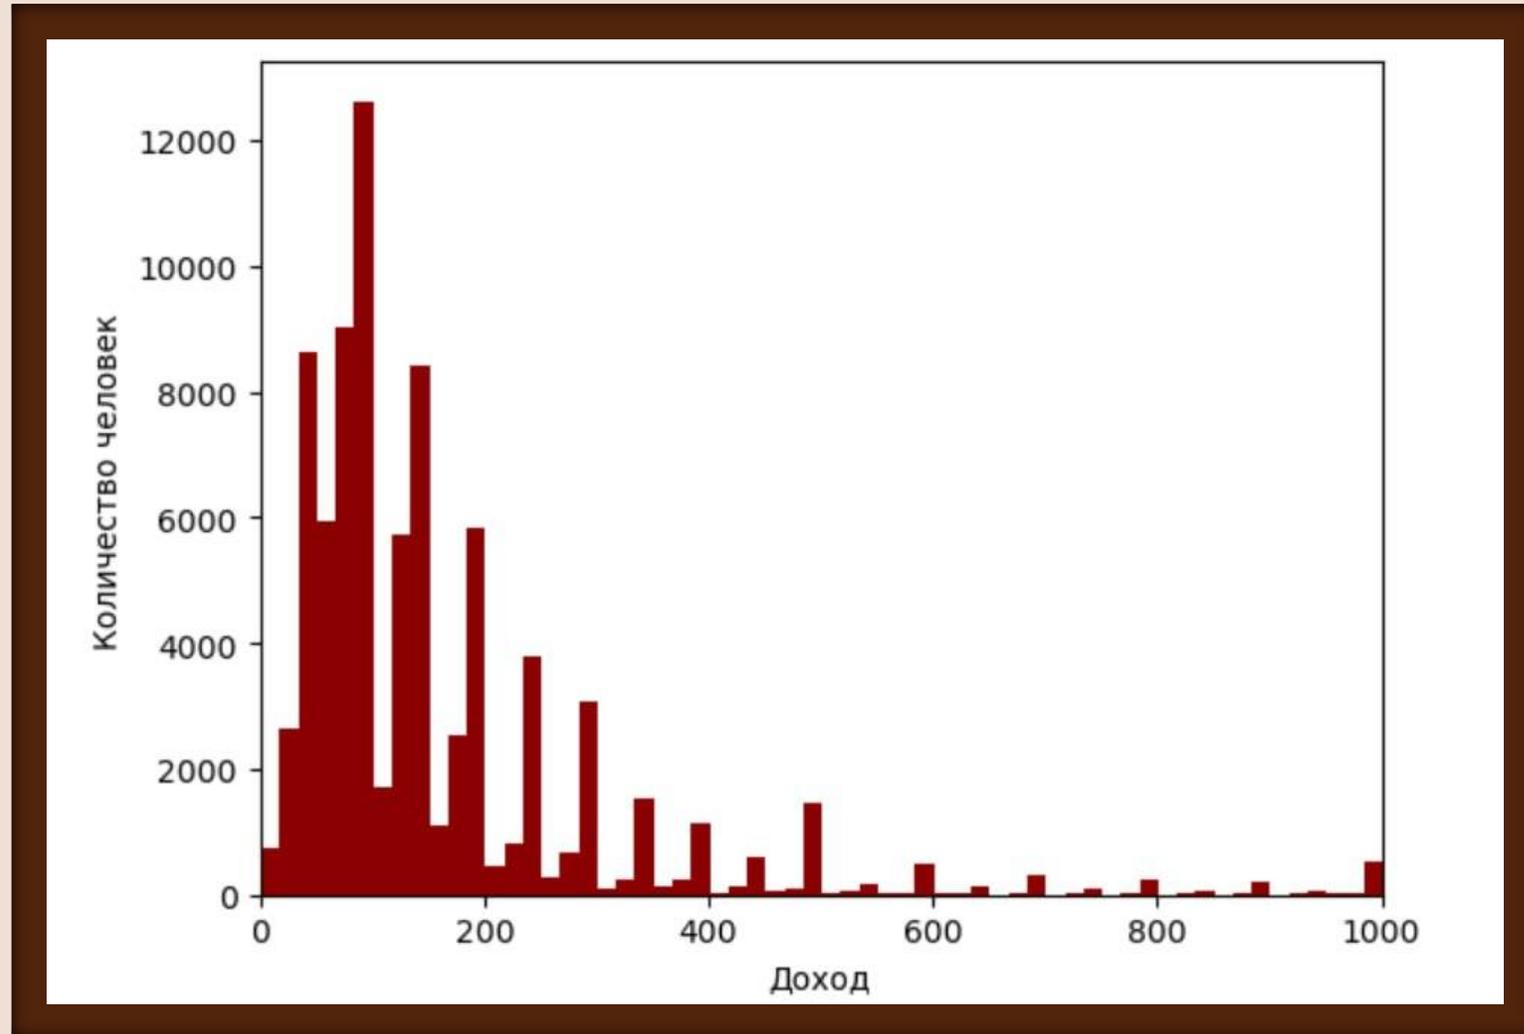
людей, у которых зарплата больше 1000 у.е.

13696

людей, которые были исключены по  
отсутствию/некорректности данных

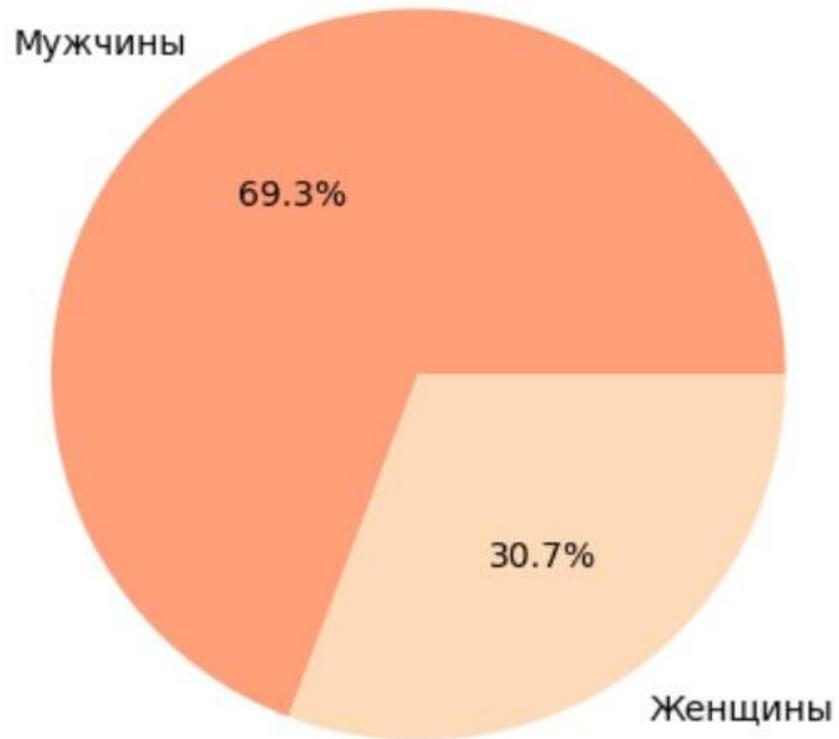
# Предварительный анализ

Объем  
выборки:  
**82415**



# Предварительный анализ

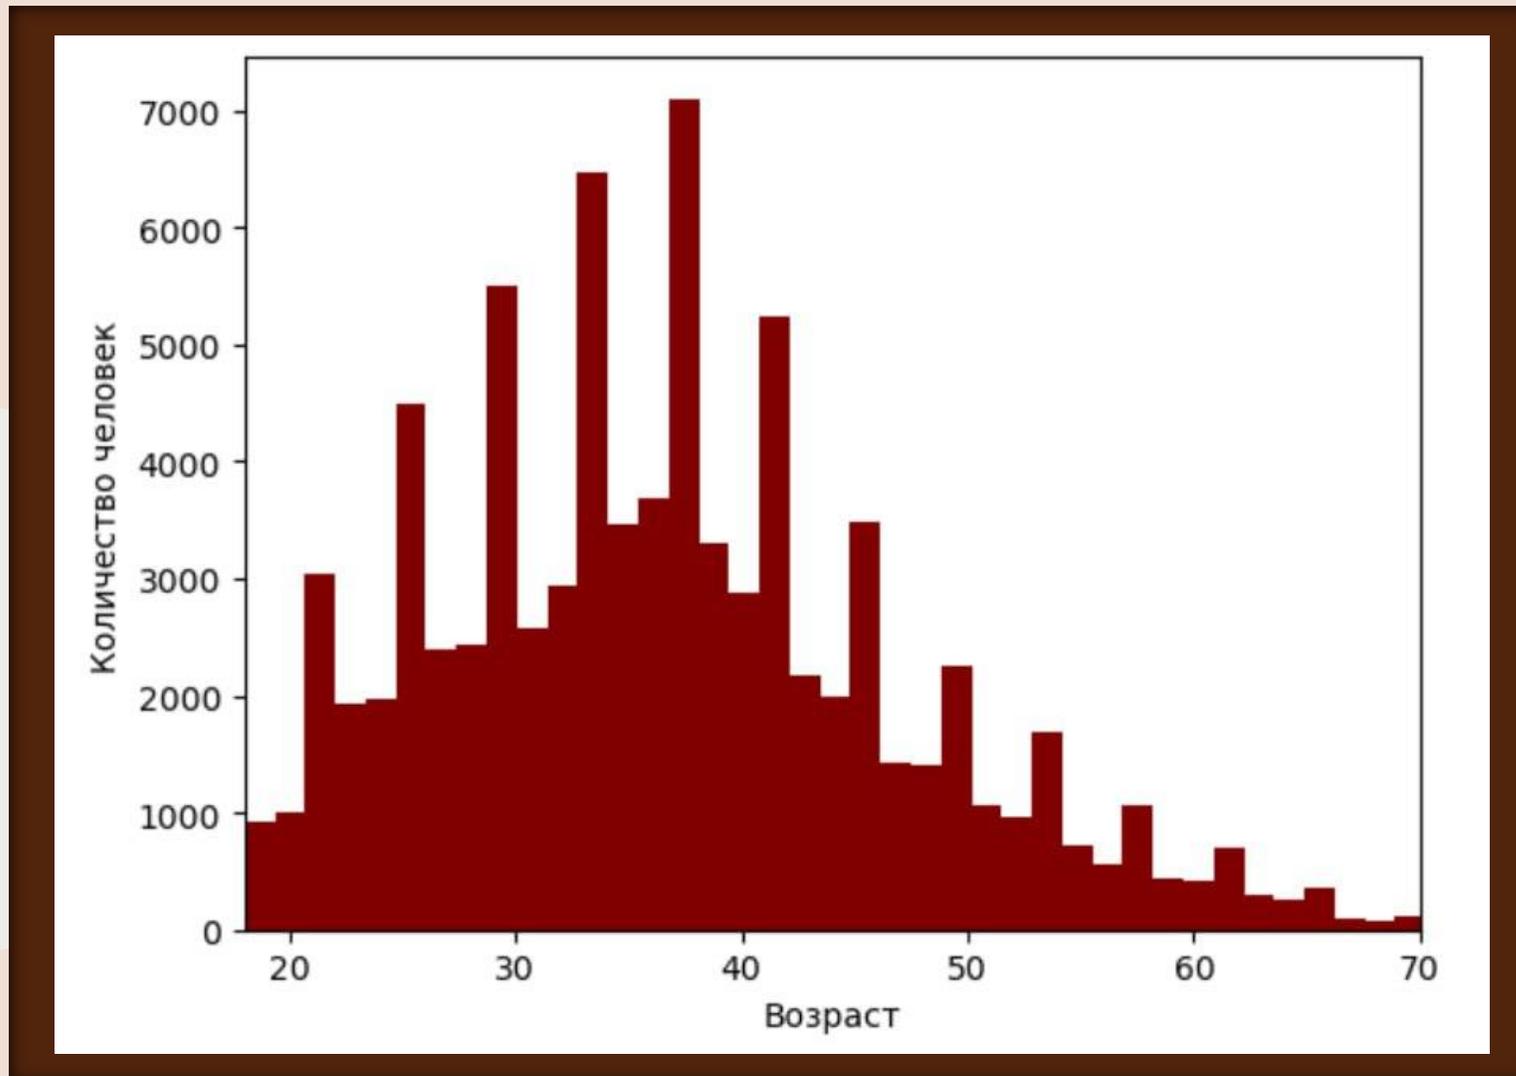
Распределение по полу



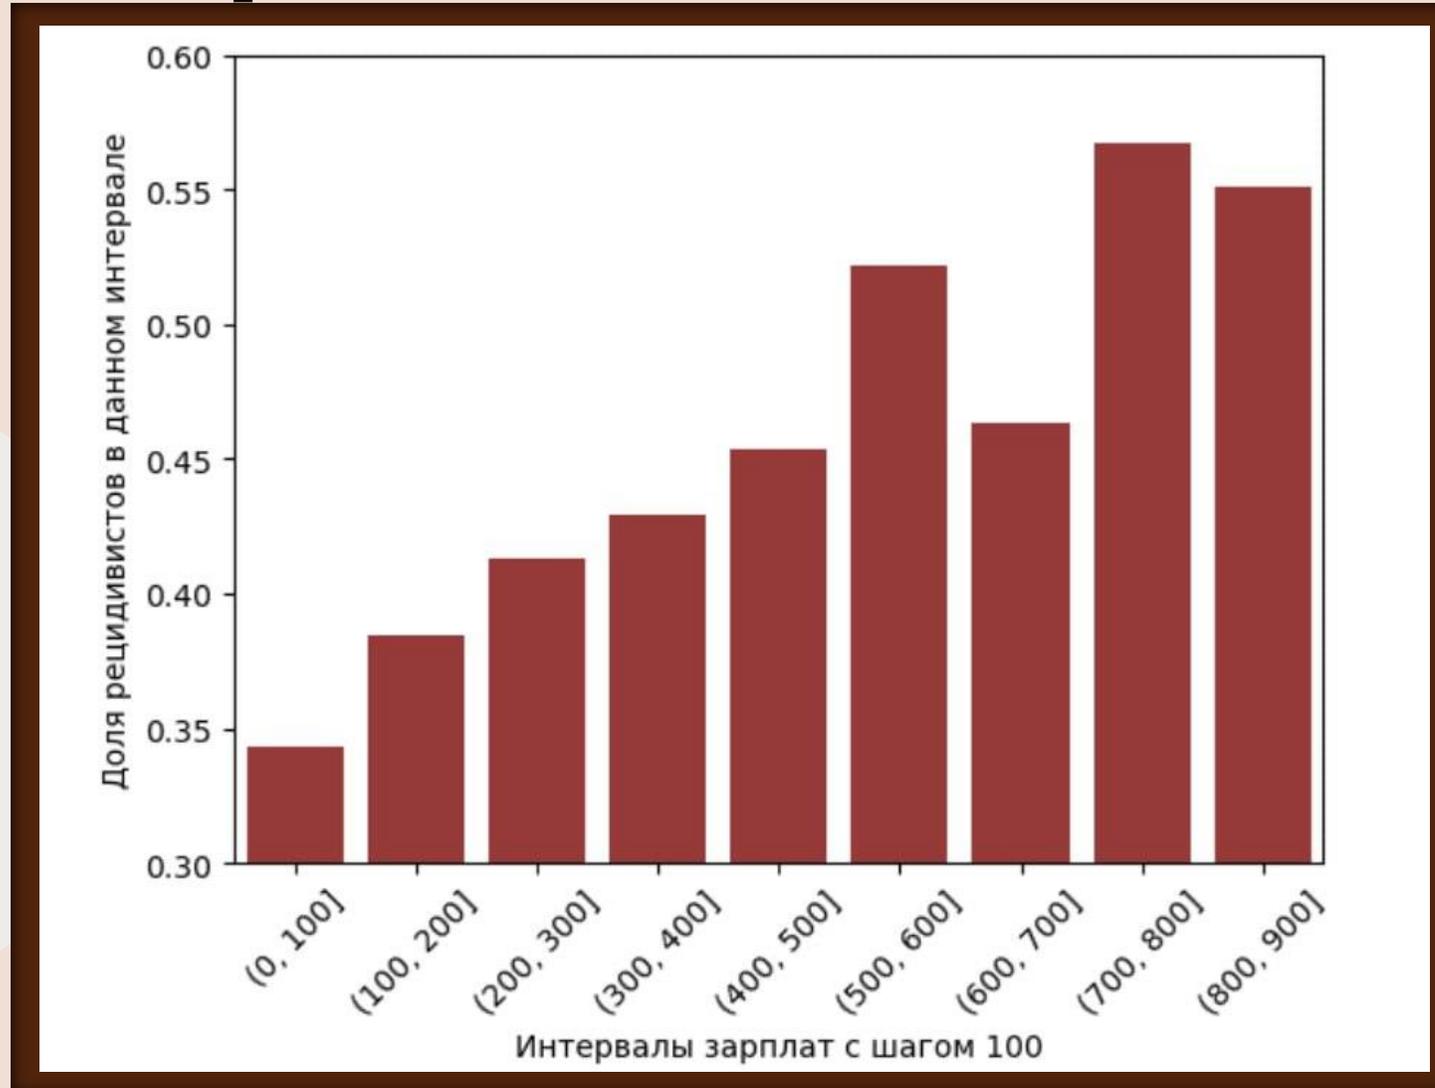
Распределение по региону



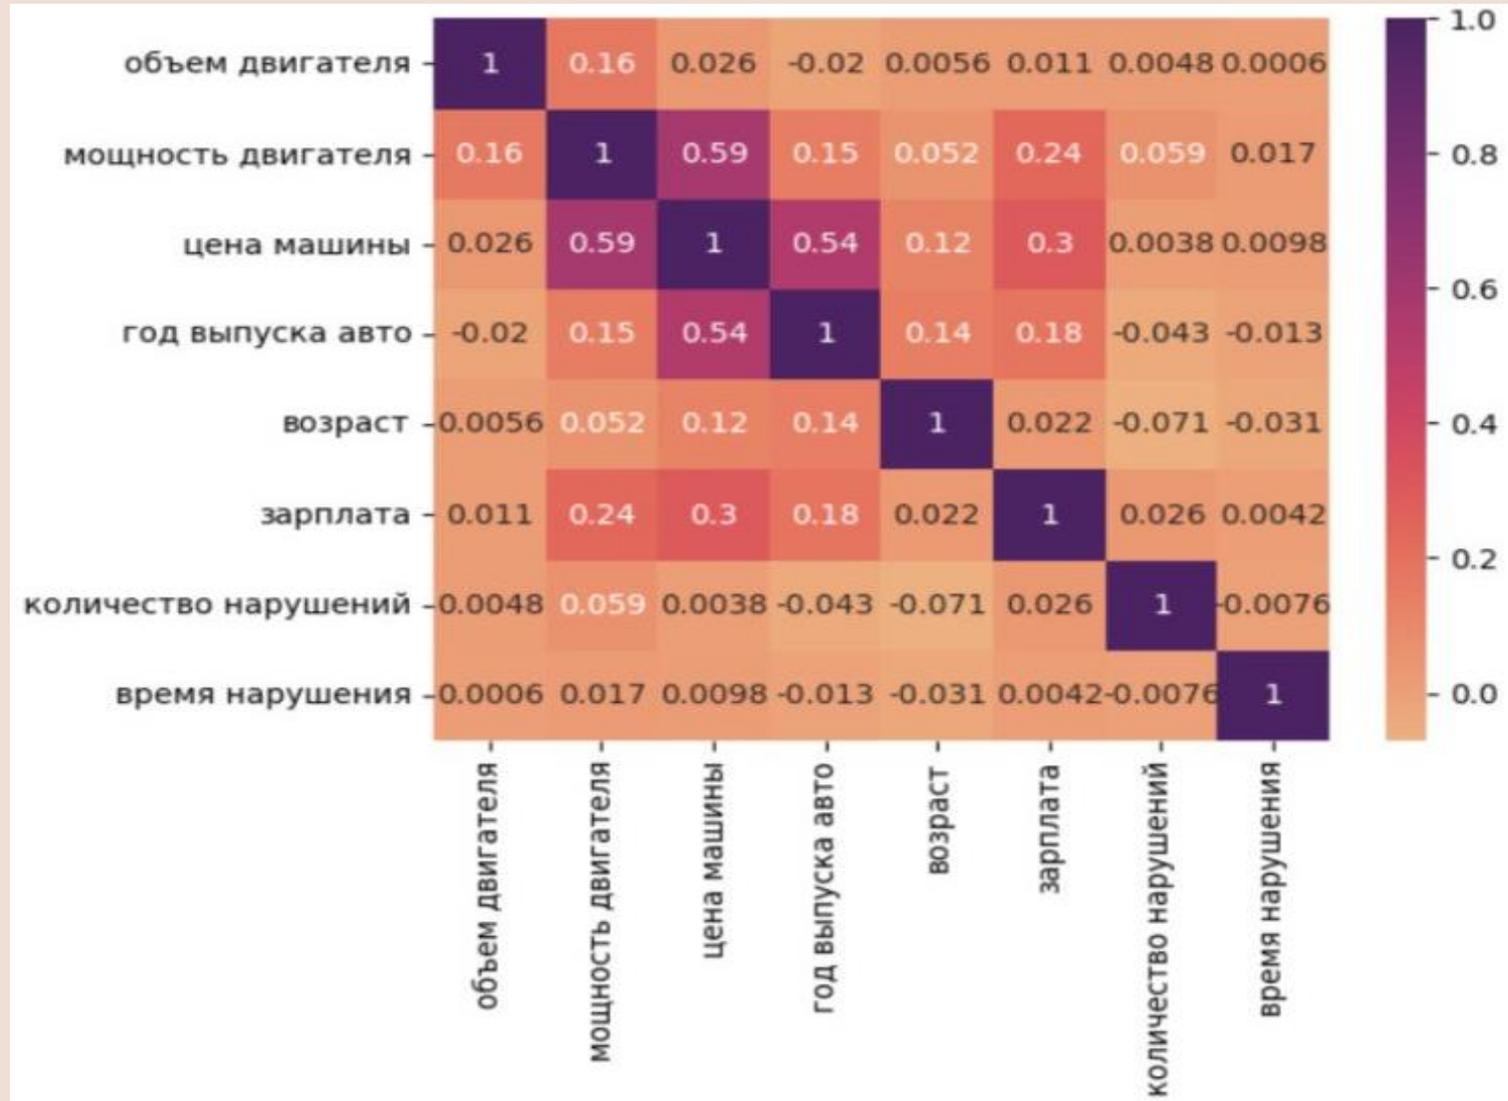
# Предварительный анализ



# Предварительный анализ



# Матрица корреляции



# Математическая модель

**H<sub>0</sub>**

Доли рецидивистов среди богатых и бедных совпадают

**H<sub>1</sub>**

Доля рецидивистов среди богатых больше, чем среди бедных

Статистическая  
значимость 0,01

# Метод

Хи-квадрат тест на  
независимость



# Ввод новых переменных

Определим богатых и бедных:

$N$  – граница по зарплате (в условных единицах)

Бедные: зарплата меньше  $N$

Богатые: зарплата больше  $N$

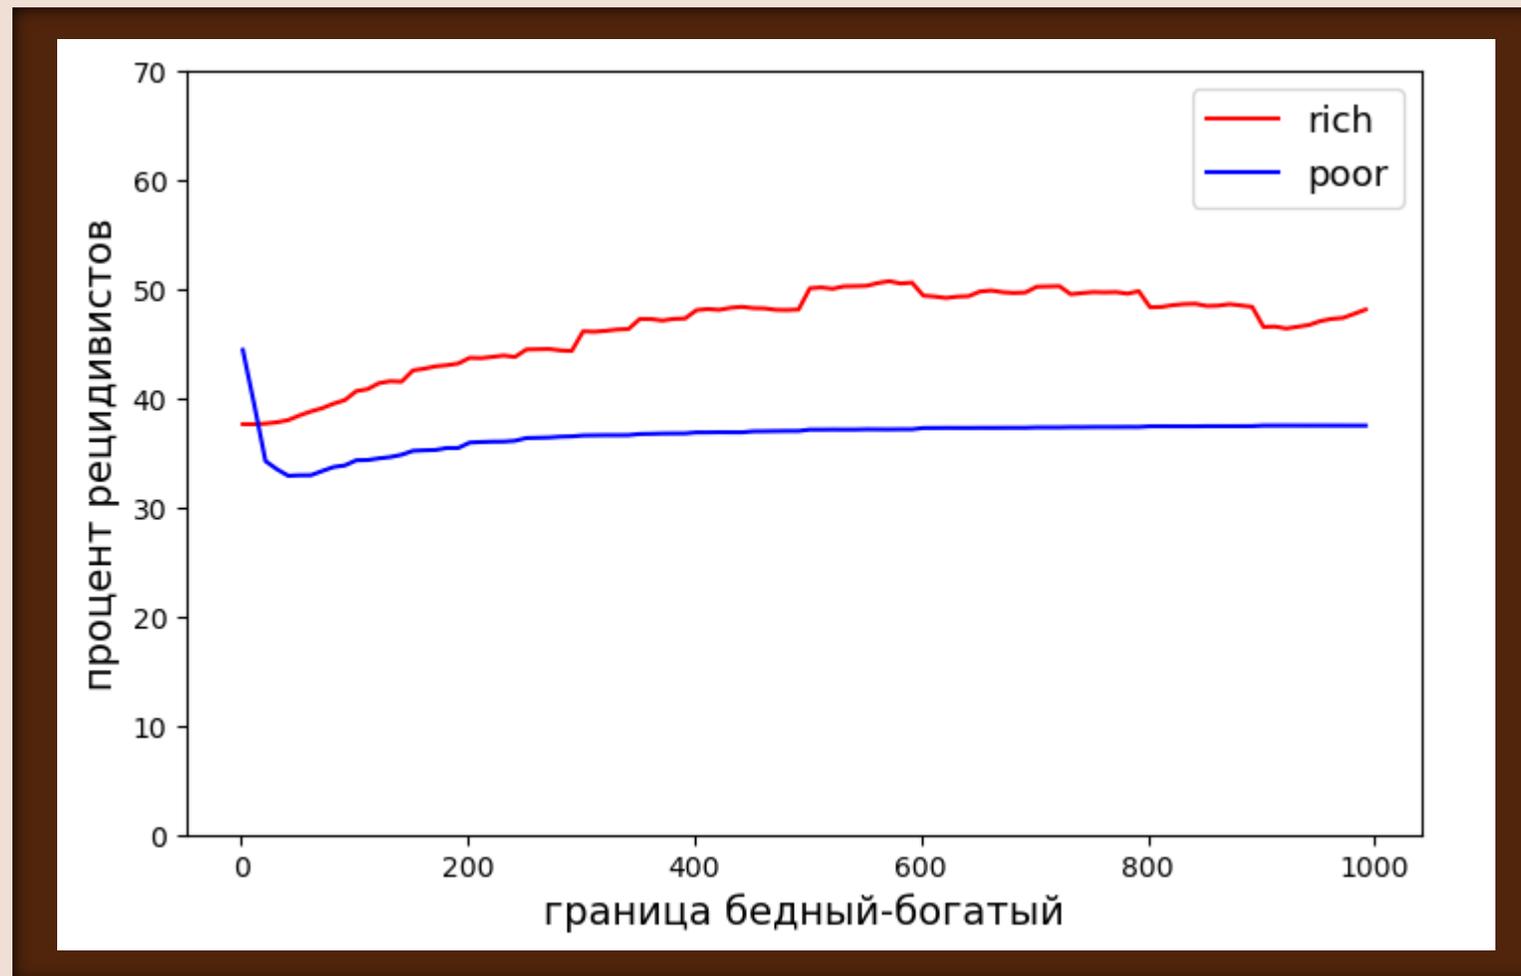
Переменная `flag`, которая:

= 0, если человек совершил только одно нарушение

= 1, если больше

Введем долю рецидивистов среди богатых и бедных

# Общая выборка



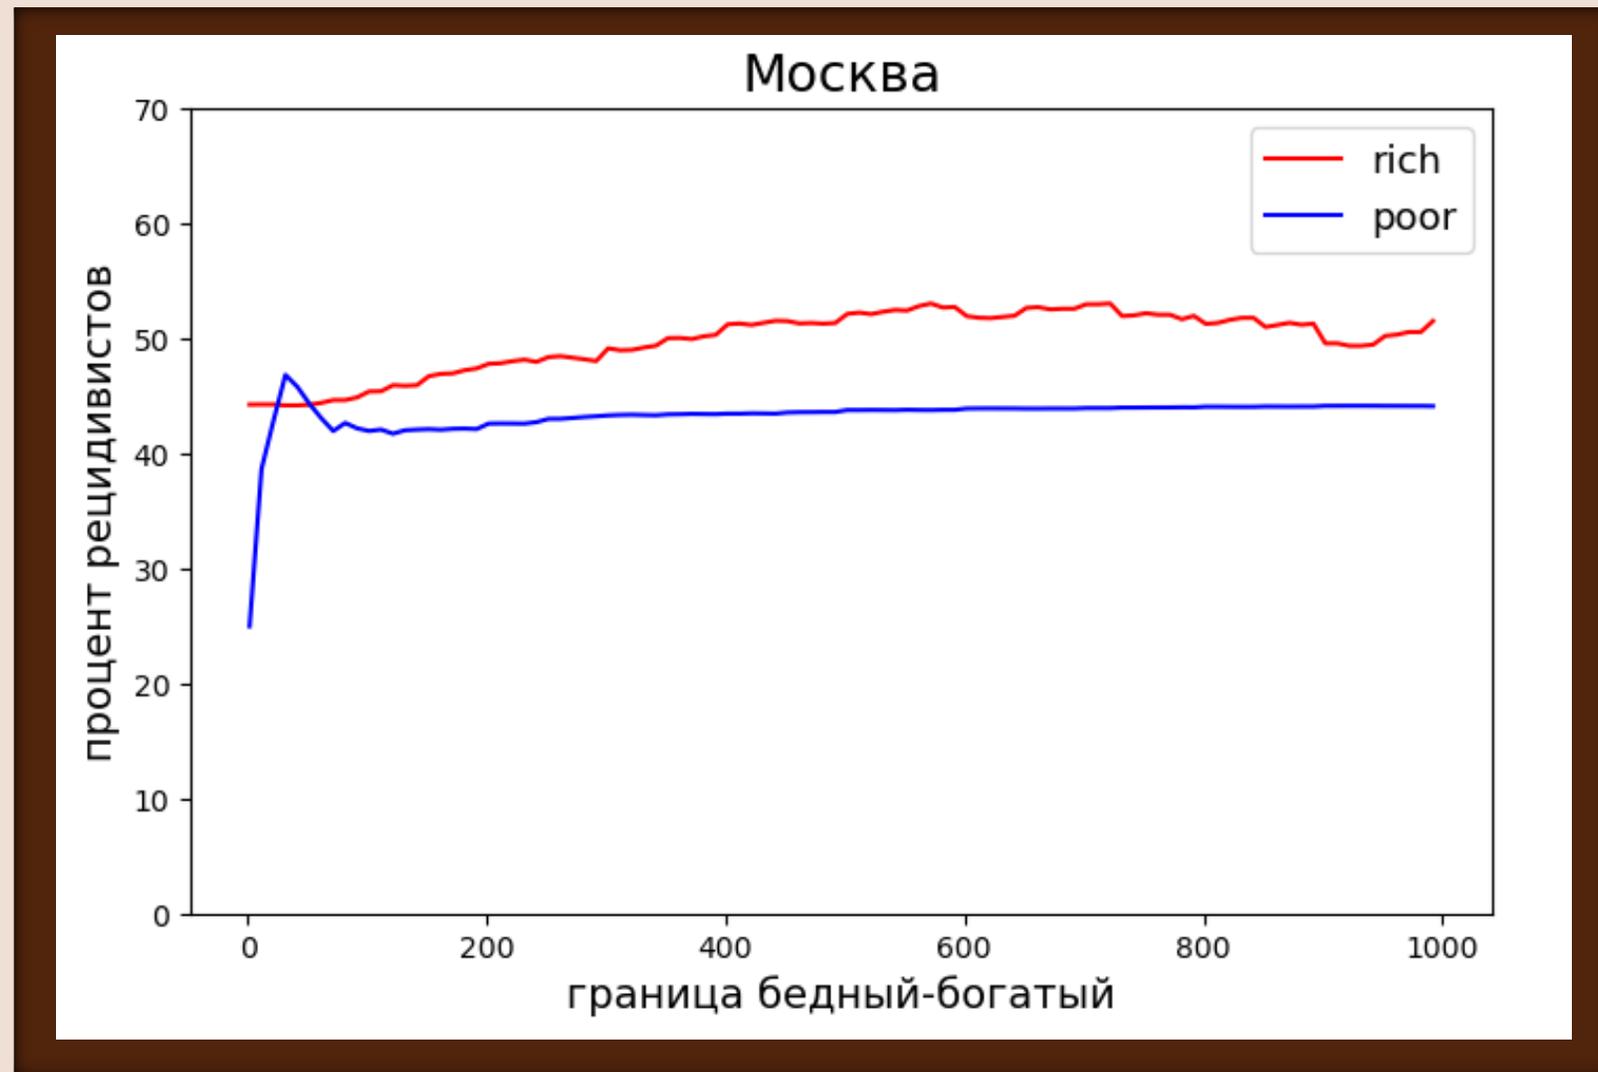
pvalue =  $2.7e^{-57}$  при  $N = 300$

# Проверка модели на устойчивость

## Алгоритм:

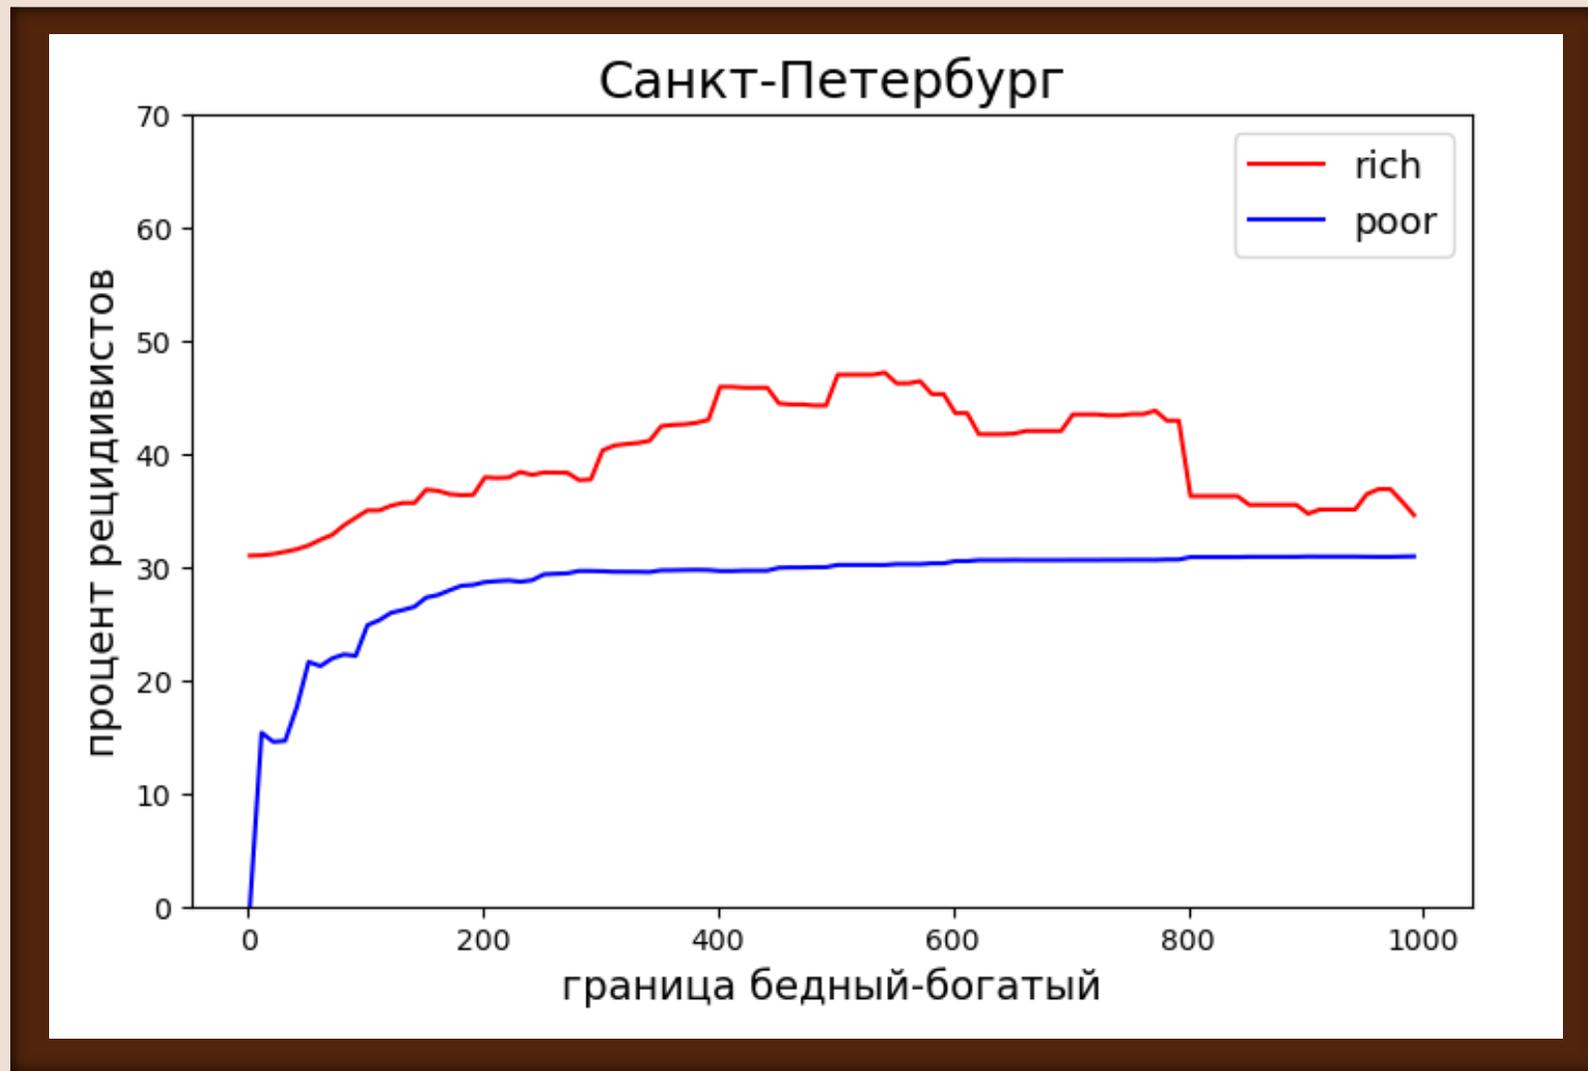
- Разделяем датасет на подвыборки
- Строим графики
- Анализ графиков

# Группы по региону



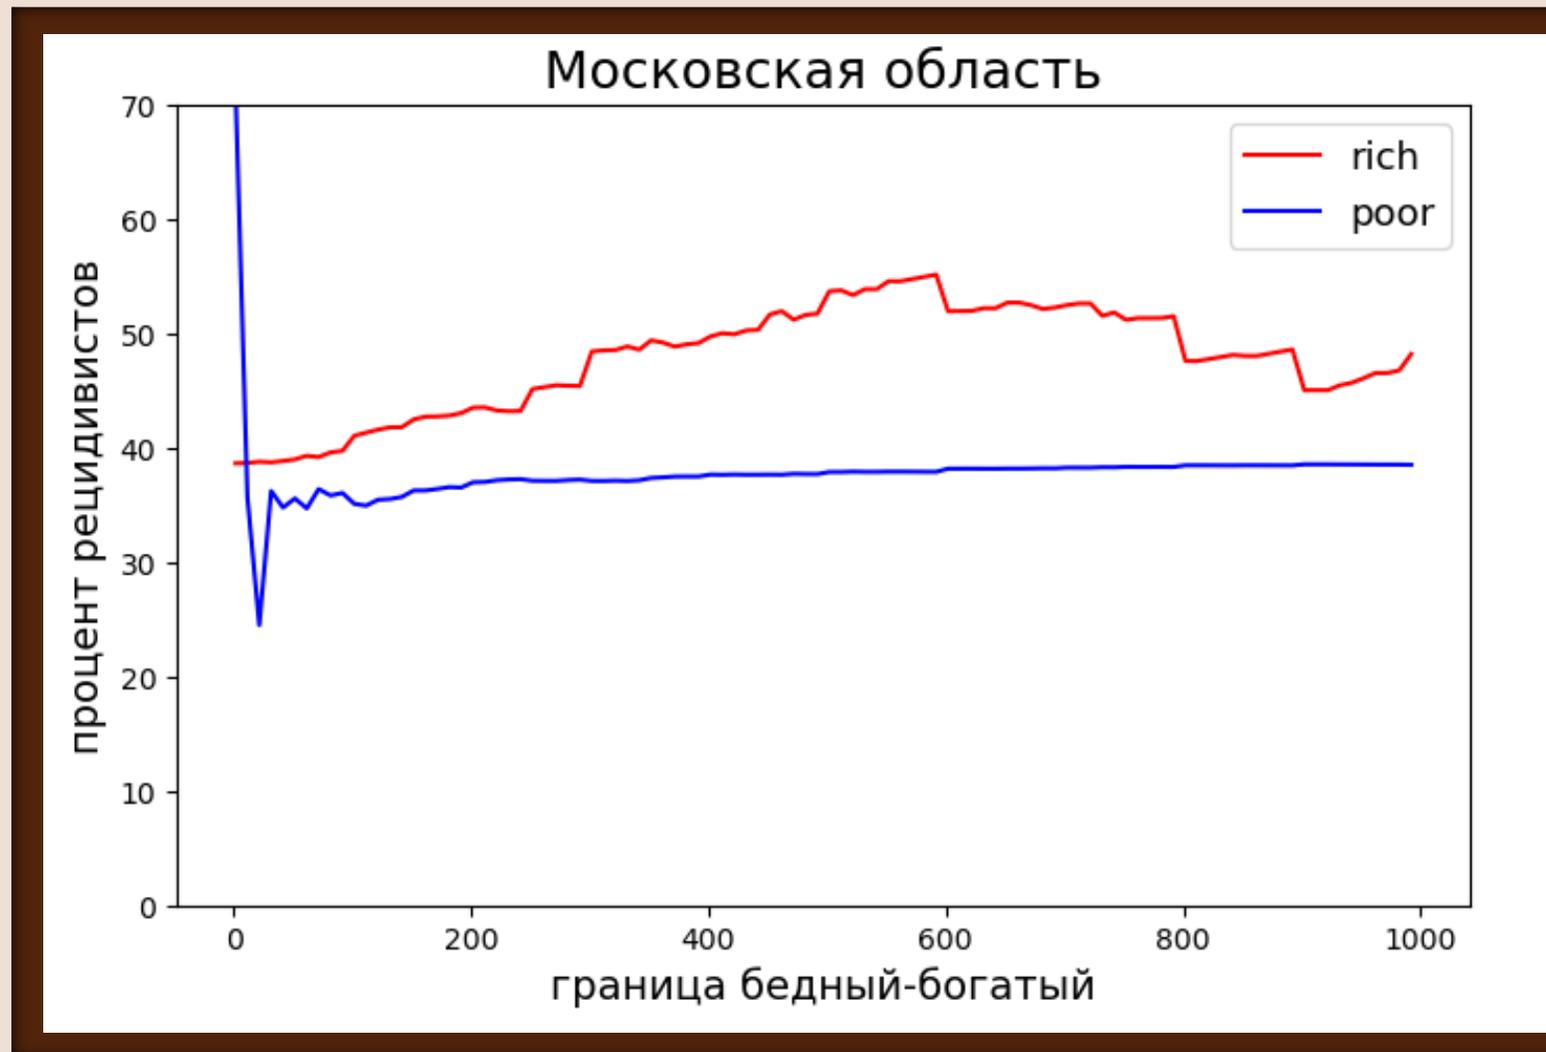
pvalue =  $3.2e-08$

# Группы по региону



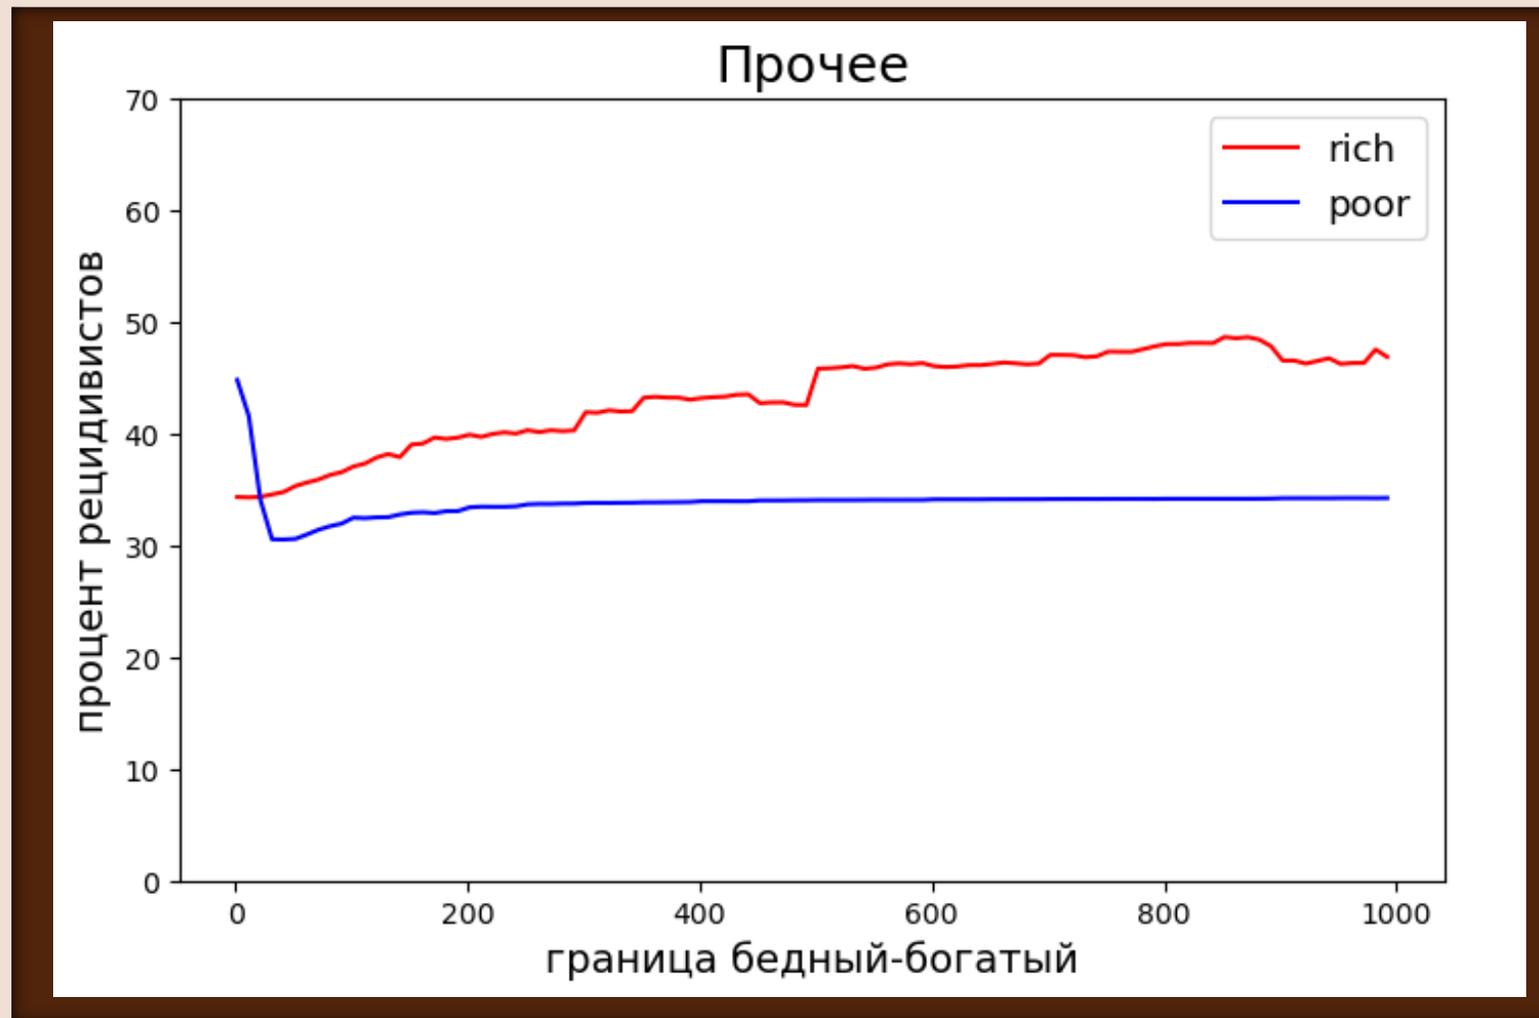
pvalue =  $7.2e-05$

# Группы по региону



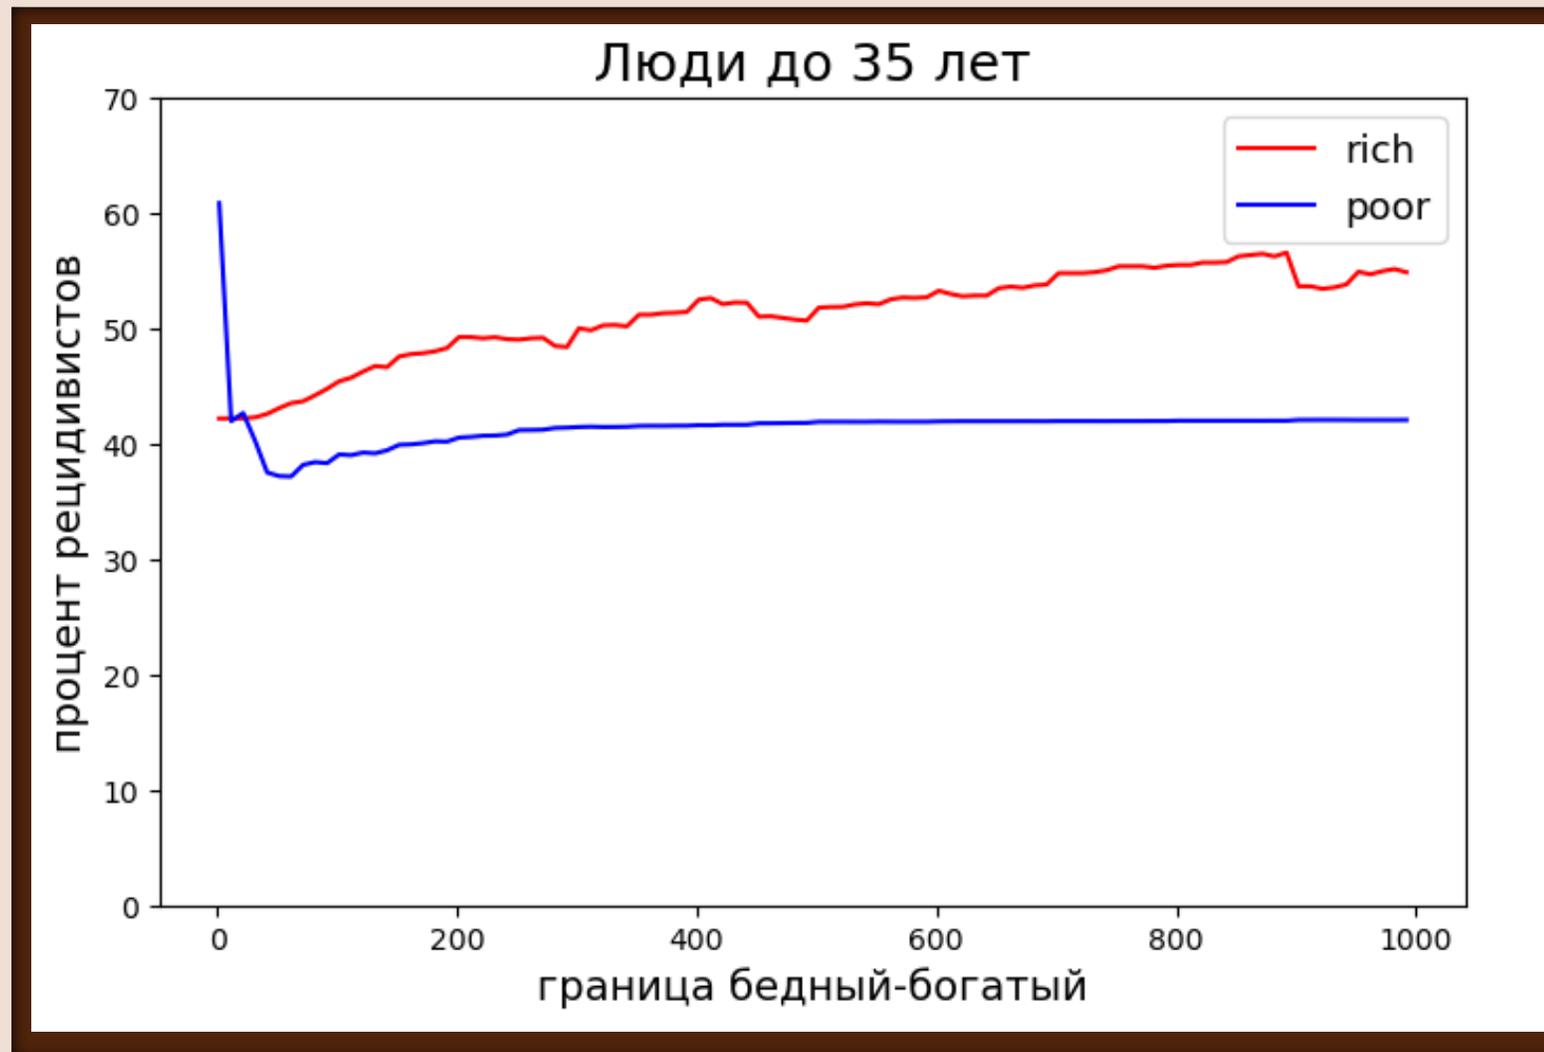
pvalue =  $2.0e-11$

# Группы по региону



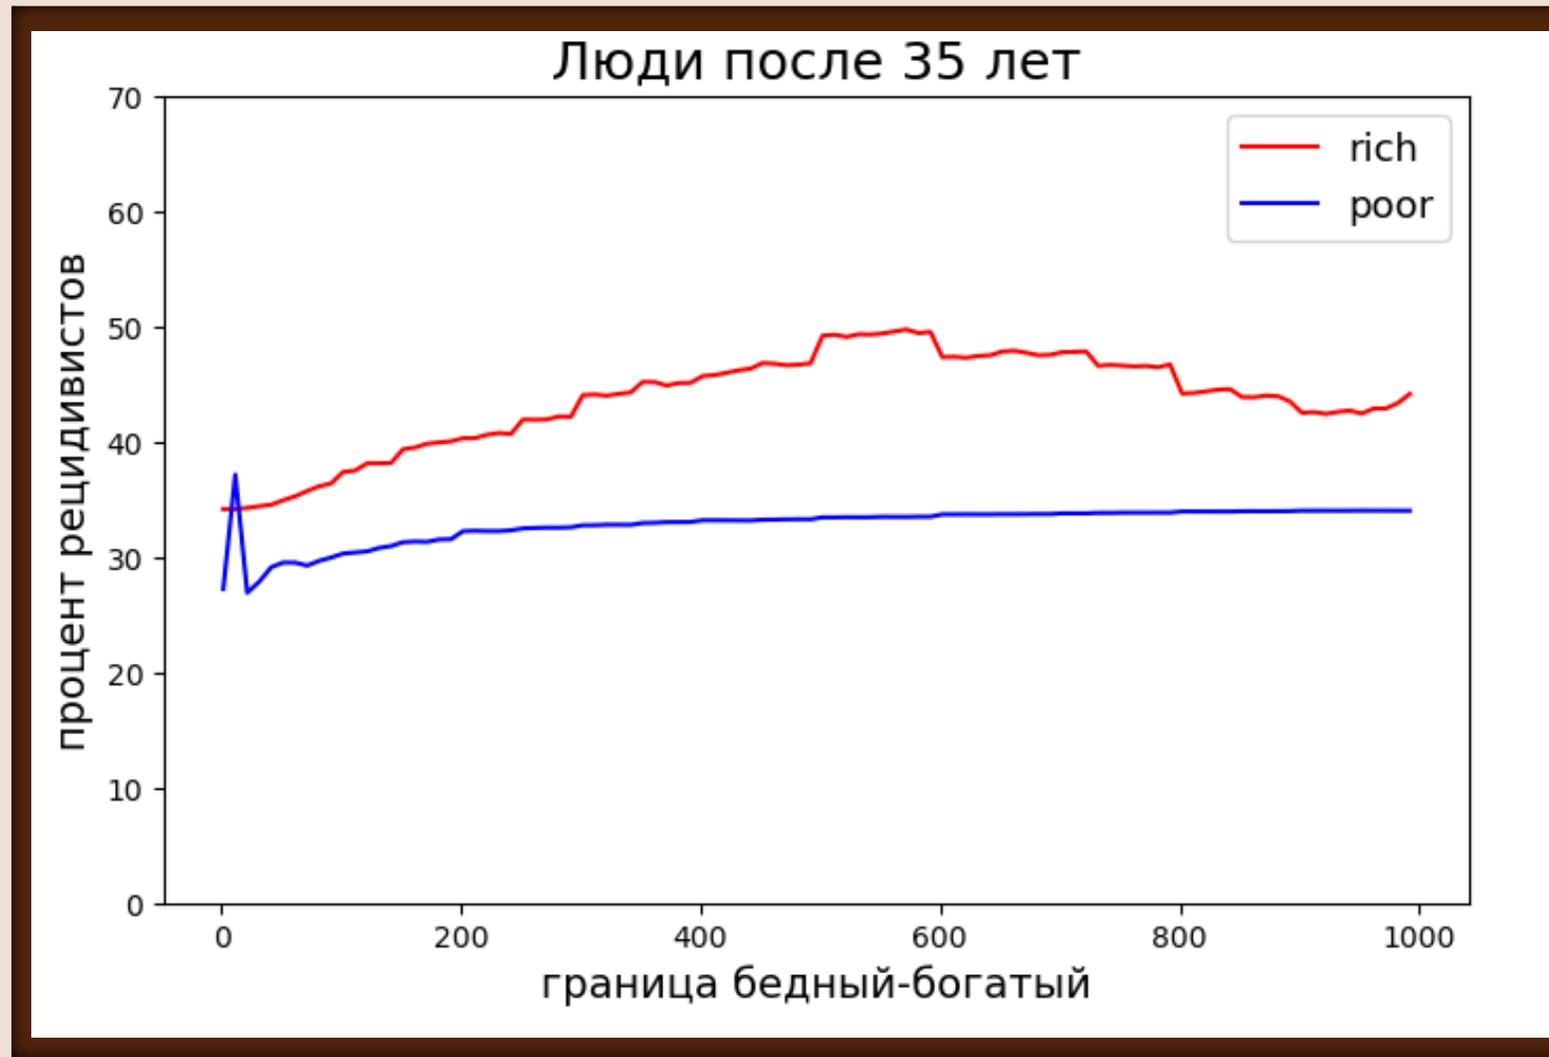
pvalue =  $1.5e-13$

# Группы по возрасту



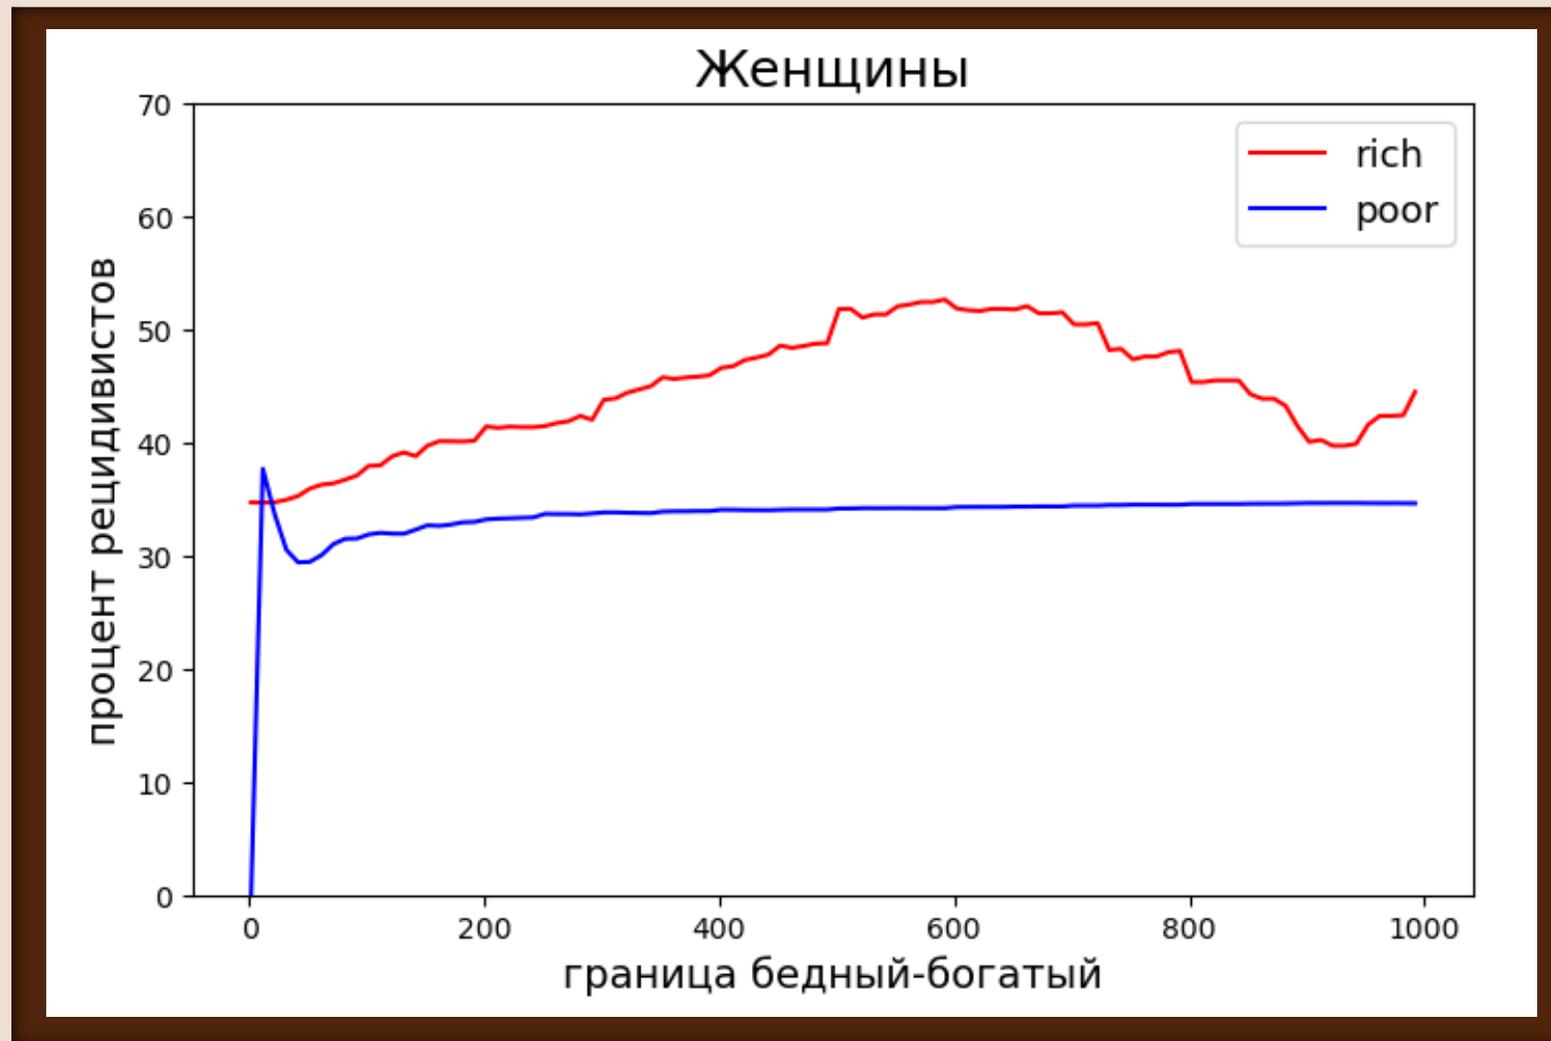
pvalue =  $2.8e-16$

# Группы по возрасту



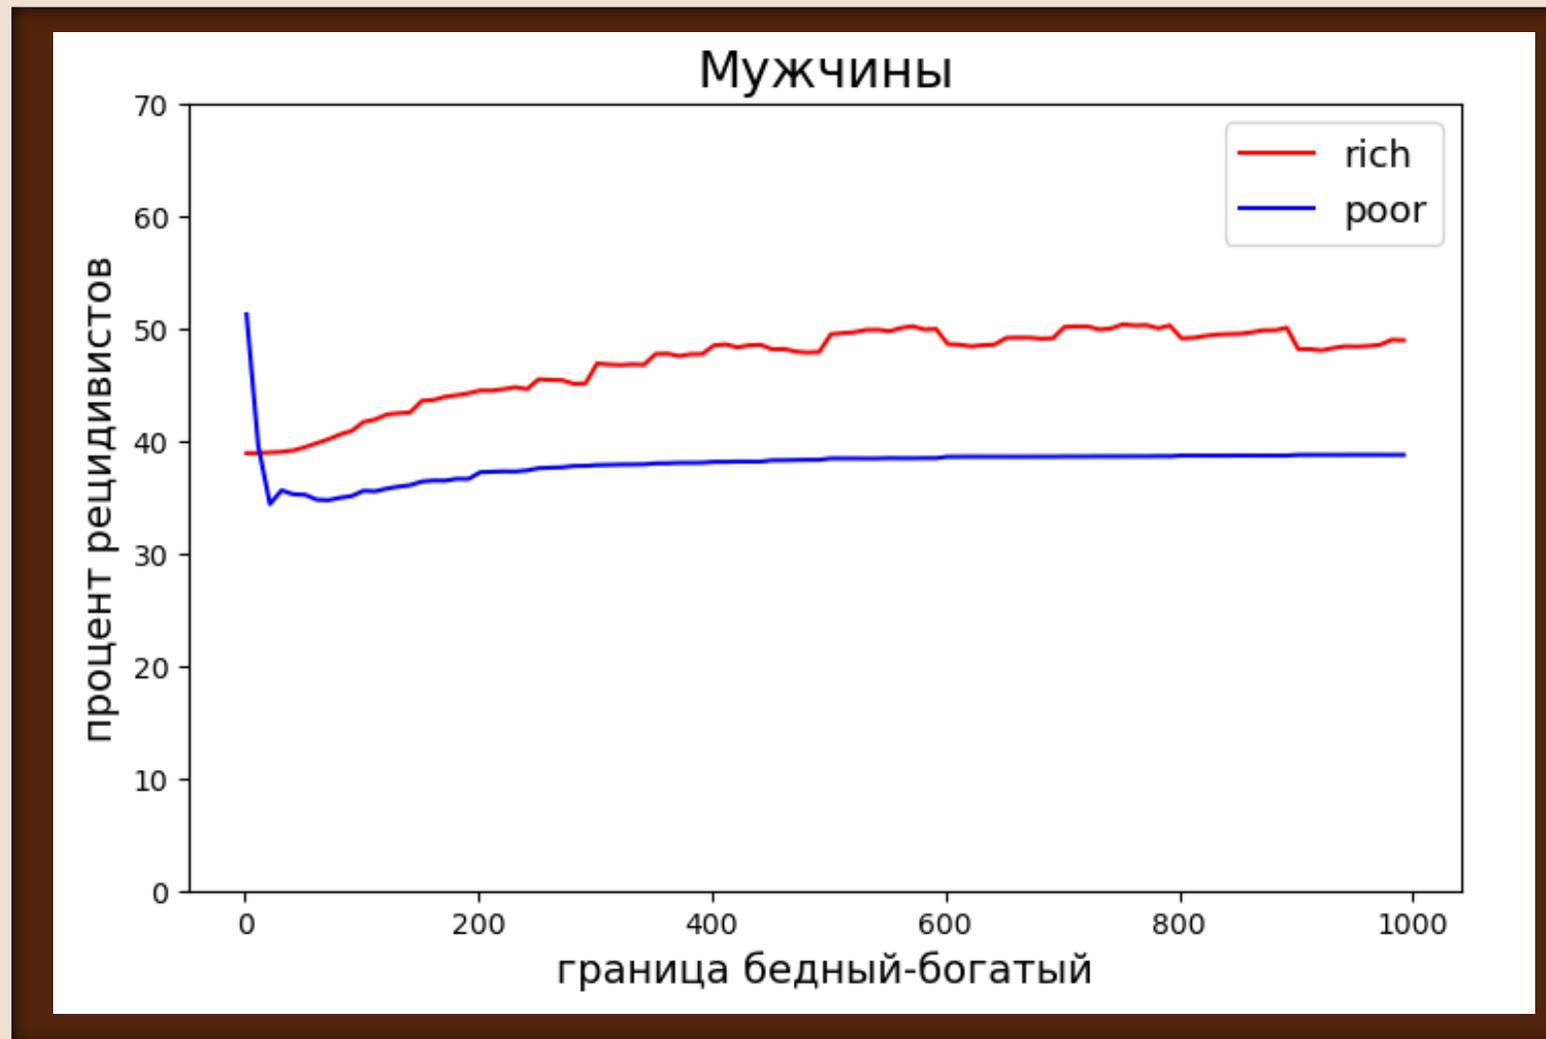
pvalue =  $4.1e-56$

# Группы по полу



pvalue =  $9.6e-18$

# Группы по полу



pvalue =  $4.9e-36$



# Гипотеза

## ПОДТВЕРДИЛАСЬ

и оказалась устойчивой на всех  
подвыборках

Доля рецидивистов среди богатых больше, чем  
среди бедных

# Ограничения и перспективы

- Только пользователи Т-Банка
- Ограниченный период времени
- Неполная выборка
- Не учитывается сезонность

- Использование данных из полного реестра штрафов по РФ
- Использовать целиком данные нескольких лет
- Учесть внешние факторы
- Оптимизировать систему штрафов, чтобы убрать различие между отношениями "богатых" и "бедных" к штрафам

# Альтернативные механизмы

богатые имеют более мощные машины,  
поэтому они чаще нарушают правила,  
которые ограничивают их вождение

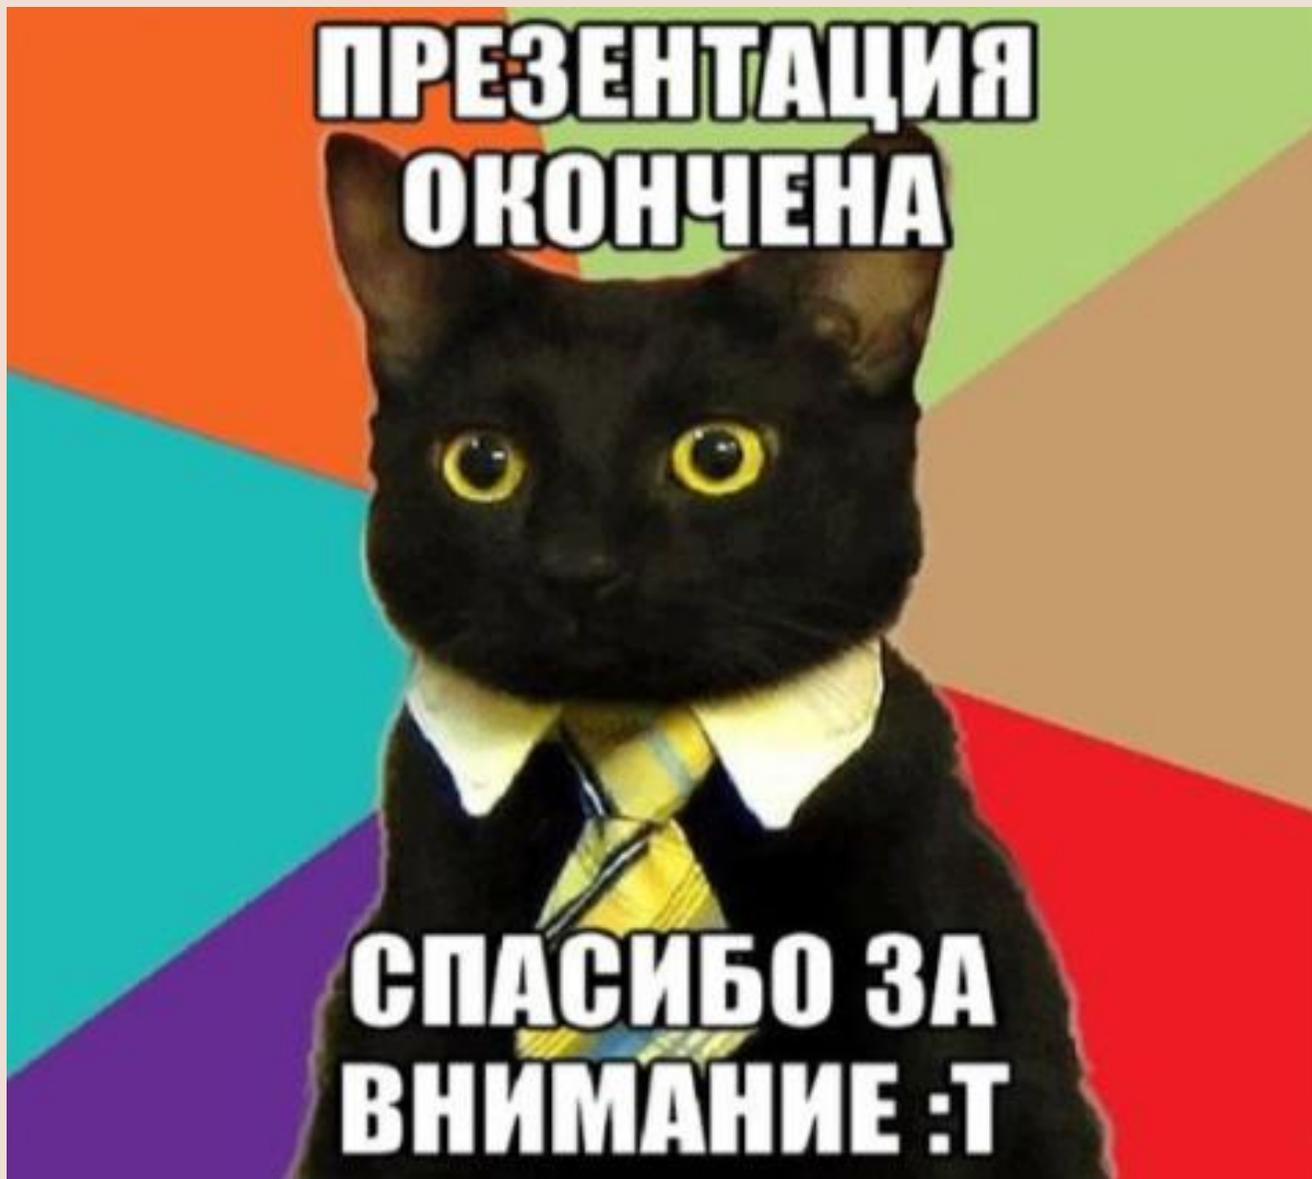
# Крутая бизнес идея

## Что хотим сделать?

оптимизировать систему штрафов, чтобы убрать различие между отношениями "богатых" и "бедных" к штрафам

## Как можно реализовать?

обновление сбора штрафов (система поощрения для получающих меньшее количество штрафов и санкции для часто получающих)



Спасибо

# Хи-квадрат тест на независимость

$$\chi^2 = \sum_{i=1}^k \frac{(x_i - m_i)^2}{m_i}$$

$M_i$  – ожидаемые величины

	богатые	бедные	общее число
рецидивисты	a	b	A+b
не рецидивисты	C	d	C + d
общее число	A+c	B+d	A+B+c+d

Например,  $m_1 = (a+c)(a+b)/(a+b+c+d)$

$X_i$ - наблюдаемые величины

$DF = (r-1)(c-1)$

$R$  – количество строк

$C$  – количество столбцов

$Df$  – количество степеней свободы

# Первая гипотеза

Люди с маленькой зарплатой чаще нарушают утром, чем вечером

# Анализ выборки

