



> Конспект > 5 урок > Предсказание диапазонов цен

> Оглавление

> [Оглавление](#)

> [Мотивация предсказания диапазонов](#)

> [Классическая регрессия](#)

> [Отличие среднего и медианы](#)

> [Медианная регрессия](#)

Пример получения оценки коэффициентов

> [Квантильная регрессия](#)

Пример использования

Некоторые библиотеки с квантильной регрессией:

> [Резюме](#)

> Мотивация предсказания диапазонов

- Проще выбрать конкретную точку внутри диапазона.
- В случае если модель ошибается в конкретной точке, диапазон может "покрыть" идеальное предсказание.
- Проще верифицировать предсказание у бизнеса.

> Классическая регрессия

В общем случае считаем, что целевая переменная $\mathbf{y} = \{y_1, y_2, \dots, y_n\}$ линейно зависит от регрессоров $\mathbf{X} = \{x_1, x_2, \dots, x_m\}$ с весами $\boldsymbol{\beta} = \{\beta_1, \beta_2, \dots, \beta_m\}$ и случайной ошибкой $\epsilon = \{\epsilon_1, \epsilon_2, \dots, \epsilon_n\}$. Если тема незнакома, можно [почитать больше тут](#).

Запишем **модель** в векторном виде:

$$\mathbf{y} = \mathbf{X} \cdot \boldsymbol{\beta} + \epsilon$$

Тогда оценка $\hat{\mathbf{y}}$ выглядит следующим образом:


$$\hat{\mathbf{y}} = \mathbf{X} \cdot \hat{\boldsymbol{\beta}}$$

Предполагаем, что от регрессоров зависит **среднее значение \mathbf{y}** .

Функционал качества, который используется при поиске оценки коэффициентов — сумма квадратов разностей наблюдаемого значения и оценки целевой переменной:

$$Q(\hat{\boldsymbol{\beta}}) = \sum_i (y_i - \hat{y}_i)^2 \rightarrow \min$$

> Отличие среднего и медианы



Унимодальное распределение

Мода — наиболее частое значение в выборке.

Медиана — квантиль порядка $\frac{1}{2}$, т. е. значение, которое делит распределение на две равновероятные части.

Среднее — среднее арифметическое выборки.

> Медианная регрессия

В отличие от обычной регрессии в медианной предполагается, что от регрессоров зависит **медиана y** :

$$Med(\mathbf{y}|\mathbf{X}) = \mathbf{X} \cdot \boldsymbol{\beta}$$

Уравнение для оценки \hat{y} остаётся таким же, но оценки коэффициентов находятся путём **минимизации суммы модулей отклонений**:

$$Q(\hat{\boldsymbol{\beta}}) = \sum_i |y_i - \hat{y}_i| \rightarrow \min$$

Оценки коэффициентов вычисляются при помощи численных методов.

Пример получения оценки коэффициентов

$Med(y_i|x_i) = x_i \cdot \beta$ — наша **модель** с одним коэффициентом

$\hat{y}_i = x_i \cdot \hat{\beta}$ — прогнозируемое значение


$$Q(\hat{\boldsymbol{\beta}}) = \sum_{i=1}^3 |y_i - \hat{y}_i| \rightarrow \min$$

Необходимо найти $\hat{\beta}$.

| y | x |
|----------|----------|
| 1 | 1 |
| 2 | 3 |
| 5 | 8 |

$$\begin{aligned} Q(\hat{\boldsymbol{\beta}}) &= |y_1 - \hat{y}_1| + |y_2 - \hat{y}_2| + |y_3 - \hat{y}_3| = \\ &= |1 - 1 \cdot \hat{\beta}| + |2 - 3 \cdot \hat{\beta}| + |5 - 8 \cdot \hat{\beta}| \rightarrow \min_{\hat{\beta}} \end{aligned}$$

$Q(\hat{\boldsymbol{\beta}})$ не дифференцируемая, кусочно-линейная функция. Можно изобразить её на графике, раскрыв модули.



Очевидно, что оптимальное значение $Q(\hat{\beta})$ принимает при $\hat{\beta} = 0.625$

> Квантильная регрессия

Обобщение случая медианной регрессии. Говорят о квантильной регрессии порядка τ , где τ — **квантиль распределения**.

Медианная регрессия аналогична квантильной регрессии порядка $\tau = 0.5$.

Запишем **модель** квантильной регрессии в предположении о том, что квантиль порядка τ линейно зависит от регрессоров:

$$q(\mathbf{y}|\mathbf{X}) = \mathbf{X} \cdot \boldsymbol{\beta}^\tau$$


Зависимость для разных квантилей может быть разной.

Для поиска оценок коэффициентов используется **минимизация асимметричной суммы модулей отклонений**:


$$Q(\hat{\boldsymbol{\beta}}) = \sum_i w_i \cdot |y_i - \hat{y}_i| \rightarrow \min, \text{ где } \text{веса } w_i:$$

$$w_i = \begin{cases} 1 - \tau, & y_i < \hat{y}_i \\ \tau, & y_i \geq \hat{y}_i \end{cases}$$

Пример использования



На графике предсказания LTV (lifetime value) по максимальному балансу на счёте изображены линии регрессии для $\tau = \{0.1, 0.5, 0.9\}$. Их наклоны сильно различаются и зависят от квантилей — это будет использоваться в предсказании диапазонов цен.



Нанесём среднее на график

Представим следующую ситуацию: мы предсказываем величину, которая изменяется от -1 до 1, при этом есть **лицо, принимающее решение** в зависимости от знака предсказания.

В таком случае можно потерять часть хороших предсказаний, которые находятся слева (в отрицательной части) около нуля при том, что доверительный интервал покрывает и некоторый отрезок справа от нуля.

Таким образом, можно влиять на принятие решения ответственным лицом: результат может быть разным, когда оперируют конкретными точками и диапазонами.

Некоторые библиотеки с квантильной регрессией:

- Catboost
- LightGBM

> Резюме

1. Вспомнили про регрессию, посмотрели на то, что такое медианная и квантильная регрессии.
2. Выяснили, что с помощью данных моделей можно предсказывать диапазоны цен для товаров.
3. Следует помнить про модели прогнозирования временных рядов.