

UDC 519.254

Areshin S.O., Kutekhov D.O., Sudakov V.A. Application of supervised learning algorithms to solve the inventory management problem

Применение алгоритмов обучения с учителем для решения задачи управления запасами

Areshin Stanislav Olegovich

Graduate student.
federal state
budget educational institution
higher education "Moscow Aviation Institute (National Research University)"

Kutekhov Dmitry Olegovich

Graduate student.
federal state
budget educational institution
higher education "Moscow Aviation Institute (National Research University)"

Scientific director

Sudakov Vladimir Anatolievich Leading Researcher.

Doctor of Technical Sciences, IPM them. M.V. Keldysh RAS

Арешин Станислав Олегович

Студент магистратуры.

Федеральное государственное

бюджетное образовательное учреждение

высшего образования «Московский авиационный институт (национальный

исследовательский университет)»

Кутехов Дмитрий Олегович

Студент магистратуры.

Федеральное государственное

бюджетное образовательное учреждение

высшего образования «Московский авиационный институт (национальный

исследовательский университет)»

Научный руководитель

Судаков Владимир Анатольевич. Ведущий научный сотрудник.

Доктор технических наук, ИПМ им. М.В. Келдыша РАН

***Abstract.** A solution to the problem of asymmetric forecasting of fuel consumption at automobile filling stations using the gradient boosting algorithm is presented and a comparative analysis of the forecast results obtained by training the algorithm by minimizing the Mean Absolute Error and the Quantile Loss Function is carried out.*

***Keywords:** inventory management, consumption forecast, quantile regression, asymmetric forecast, gradient boosting.*

***Аннотация.** Представлено решение задачи несимметричного прогноза расхода топлива на автомобильных заправочных станциях с применением алгоритма градиентного бустинга и проведен сравнительный анализ результатов прогноза, полученных при обучении алгоритма путем минимизации Средней абсолютной ошибки и Квантильной функции потерь.*

***Ключевые слова:** управление запасами, прогноз расхода, квантильная регрессия, несимметричный прогноз, градиентный бустинг.*

Введение.

Управление запасами различных материальных ресурсов и товаров в настоящее время приобретают все большую актуальность для планирования деятельности, оценки и прогнозирования снабжения, сбыта, потребления, ценообразования, прибыли и других показателей. В общем случае решение данной задачи направлено на минимизацию затрат, связанных с заказом и хранением условного товара, а в математическом смысле его можно отнести к задачам оптимизации совокупности и взаимодействия различных показателей, оказывающих влияние на целевой результат, например, получение максимальной прибыли.

Для решения таких задач используются различные методологические подходы, разрабатываются экономические и математические модели [1, 2]. Следует отметить, что в последнее время все более активно применяют искусственный интеллект. Основная цель принятия решения при управлении запасами состоит в выборе стратегии пополнения запасов, то есть выявление набора правил, позволяющих определить для любого состояния запасов момент времени подачи заказа и объем заказа на пополнение запаса [3].

В таких задачах положительная и отрицательная ошибка имеют различные последствия с точки зрения решений, принимаемых на основе полученных прогнозов. Пример методов для несимметричного прогноза подробно описан в работе [4].

В настоящей работе рассматривается задача управления запасами на автомобильных заправочных станциях (АЗС). С точки зрения бизнеса, невыгодно постоянно хранить большие объемы топлива на АЗС, это крупные и необязательные вложения средств, особенно когда в собственности значительное количество станций. Однако, если топлива окажется недостаточно для потребителей, это приведет к сбоям в работе или остановке продаж и, как следствие, потере прибыли.

При постановке задачи принимаем, что для непрерывной работы АЗС необходимо построить прогноз расхода топлива на неделю вперед, чтобы заранее спланировать возможную доставку. Таким образом, должна быть решена задача регрессии. Данные представляют собой временной ряд для каждой отдельной АЗС (дата, час), временной интервал наблюдений 8 месяцев. Рассматривается прогноз расхода топлива для 63 заправочных станций. На рисунке 1 представлены наблюдения для одной АЗС.

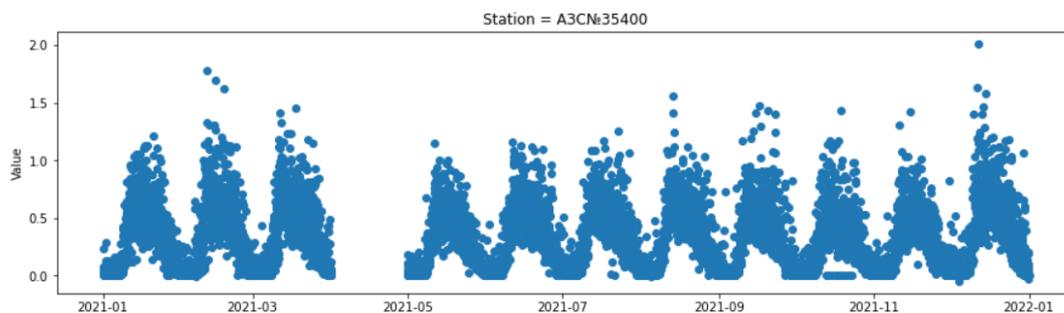


Рисунок 1. Пример данных для одной АЗС

Ряды являются циклическими, но имеют различную амплитуду, поэтому необходимо построить отдельные модели по каждому ряду.

Наиболее популярным подходом к прогнозированию временных рядов является статистический подход, например, модели ARMA, ARIMA, SARIMA, разновидности экспоненциального сглаживания, как, например, в работах [4, 5].

В данном исследовании мы предлагаем применить подход обучения с учителем, а именно, алгоритм градиентного бустинга CatBoost [6], как наиболее передовое решение в области классического машинного обучения. Кроме того, важным аспектом при выборе алгоритма являлось то, что алгоритм CatBoost поддерживает оптимизацию квантильной функции потерь, что позволяет построить квантильную регрессию [7] на основе ансамблирования деревьев.

Теоретическая часть.

Учитывая разные последствия положительной и отрицательной ошибки, в работе вводили несимметричную метрику качества прогноза, в основе которой лежит широко известная "Средняя абсолютная ошибка" (MAE):

$$MAE_{custom} = \frac{1}{n} \sum_{i=1}^n \begin{cases} 2 \cdot |y_{true_i} - y_{pred_i}|, & \text{if } y_{true_i} - y_{pred_i} \geq 0 \\ |y_{true_i} - y_{pred_i}|, & \text{else} \end{cases}$$

Метрика качества устроена так, что заниженный прогноз штрафует в 2 раза больше, так как при завышенном прогнозе владелец АЗС застрахован от потери прибыли в связи с нехваткой топлива.

Итак, решаемая задача – задача несимметричного прогноза, метрика качества также является несимметричной. В связи с этим предложено два подхода и проведен их сравнительный анализ.

Первый подход – оптимизация MAE функции потерь, его можно назвать классическим:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_{true_i} - y_{pred_i}|$$

Второй подход – оптимизация квантильной функции потерь:

$$\text{Quantile loss}(y_{true} - y_{pred}, \alpha) = \sum_{i=1}^n \begin{cases} \alpha \cdot (y_{true_i} - y_{pred_i}) & \text{if } y_{true_i} - y_{pred_i} \geq 0 \\ (\alpha - 1) \cdot (y_{true_i} - y_{pred_i}), & \text{else} \end{cases}$$

Преимущество второго варианта в том, что при обучении модели квантильная функция потерь по-разному штрафует за положительную и отрицательную ошибку в зависимости от выбранного уровня, что в свою очередь приближает полученный прогноз к условиям бизнеса. На рисунке 2 представлена зависимость штрафа квантильной функции потерь от уровня квантили и допущенной ошибки.

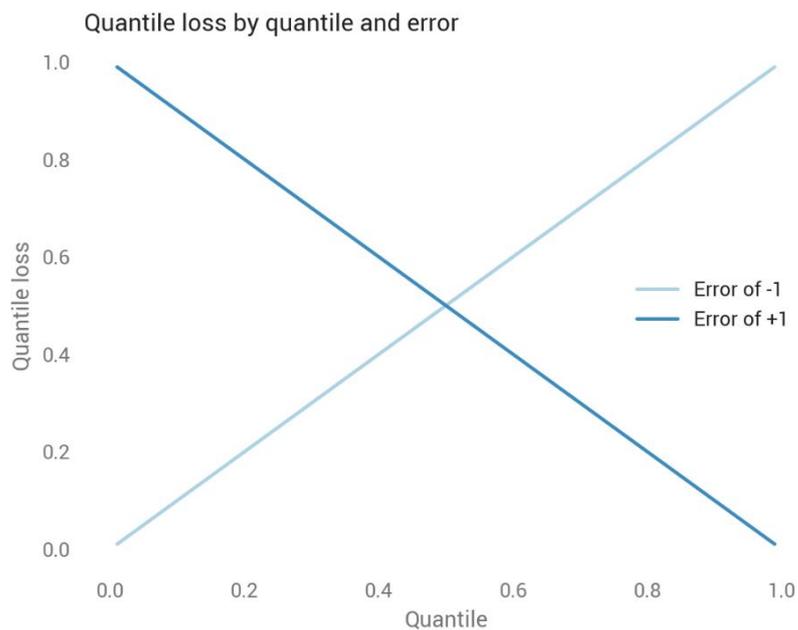


Рисунок 2. Работа квантильной функции потерь при истинном значении 0

Экспериментальная часть.

Данные представлены в excel формате, в виде сводных таблиц (час, дата). На языке программирования python реализован парсер данных в .csv формат, учитывая все найденные особенности хранения, такие как пропущенные часы, разные наименования одних и тех же станций, разные стартовые ячейки хранения таблиц на листах и так далее. Процесс предобработки данных в виде изображен в виде схемы на рисунке 2.

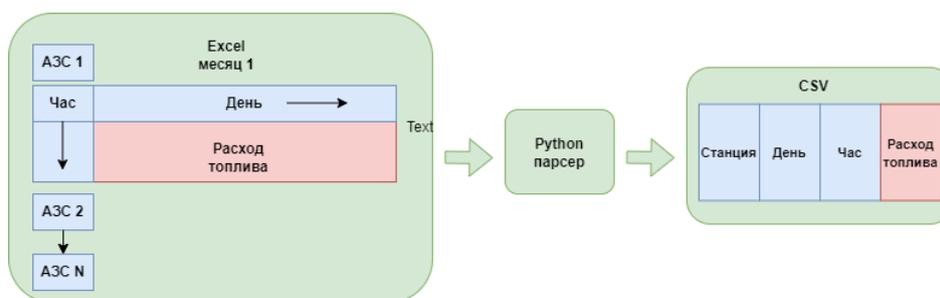


Рисунок 2. Схема обработки данных

Для генерации признакового пространства в качестве признаков использовали datetime признаки: месяц, день, день недели, период дня. Генерация таких признаков позволяет алгоритму выучить сезонность временного ряда для лучшего прогноза. Кроме того, для более стабильных результатов было решено также добавить лаги в качестве признаков модели. Чтобы корректно создать лаги, необходимо удалить три месяца, так как в данных отсутствует апрель. Лаги генерируются по дням, то есть каждый признак - это значение расхода топлива 7, 14, 21, 28, 35, 42, 49, 56 дней назад соответственно.

Реализованный функционал для генерации признакового пространства представлен ниже:

```
# функция генерации признаков из даты
def get_datetime_features(df):
    df_res = df.copy()
    df_res['Date'] = pd.to_datetime(df_res['Date'])
    df_res['month'] = df_res['Date'].dt.month
    df_res['day'] = df_res['Date'].dt.day
    df_res['weekday'] = df_res['Date'].dt.weekday
    df_res['day_period'] = (df_res['Hour'] % 24 + 4) // 4
    return df_res

# функция генерации лагов
def get_lag_features(df, lags):
    for i in lags:
        df[f'lag{i}'] = df.groupby('Station')['Value'].shift(i * 24)
    df.dropna(inplace=True)
    return df
```

Для построения модели была выделена валидационная выборка - предпоследняя неделя декабря. С помощью валидационной выборки отслеживаем переобучение модели, а также оптимизируем общие параметры. Соответственно, тестовая выборка - последняя неделя декабря.

В качестве базовой модели выбрана модель Catboost, обученная путем оптимизации MAE функции потерь. Для сравнения рассмотрены модели, обученные с квантильной функцией потерь с разными уровнями. Полученные результаты представлены в таблице 1.

Таблица 1

Результаты эксперимента

	Custom MSE val set	Custom MSE val set
MAE loss	0.44921	0.29760
Quantile loss (0.55)	0.41815	0.28290
Quantile loss (0.6)	0.39550	0.27510
Quantile loss (0.65)	0.37574	0.26932
Quantile loss (0.7)	0.36260	0.26766
Quantile loss (0.75)	0.35710	0.27459
Quantile loss (0.8)	0.35719	0.29342
Quantile loss (0.85)	0.36668	0.34208
Quantile loss (0.9)	0.39908	0.41471
Quantile loss (0.95)	0.47084	0.58346

Из результатов следует, что модели Quantile loss (0.55)– Quantile loss (0.95) превосходят базовую модель на валидационной выборке, однако, модели Quantile loss (0.85) – Quantile loss (0.95) получились сильно переобученными. Лучшая модель на валидационном датасете - Quantile loss (0.75), при этом модель Quantile loss (0.7) немного лучше на тестовой выборке. Был проведен дополнительный эксперимент обучения с различной валидационной выборкой, в результате которого лучшей была выбрана модель Quantile loss (0.7).

Заключение.

Таким образом, в работе показано, что оптимизация квантильной функции потерь позволяет получить наиболее адекватный прогноз в задачах с разными весами положительных и отрицательных ошибок по сравнению с оптимизацией классических функций потерь. На основе такого прогноза возможно выстраивание необходимой логистики для хранения достаточного объема топлива на АЗС без потерь прибыли, при этом исключив лишние вложения в простаивающие избыточные объемы.

References

1. Хоботов Е.Н., Методы решения задач управления многопродуктовыми запасами при случайном спросе // Известия Российской академии наук. Теория и системы управления. - 2011. - № 2. - С. 62 - 73.
2. Насриддинов М.Ш. Статистические задачи управления товарно - материальными запасами // Вестник технологического университета Таджикистана. - 2018 - № 2 (33). - С. 72 - 78.
3. Финаев В.И. В.И. Шкрибляк Н.В. Методы искусственного интеллекта в задачах управления запасами // Известия ЮФУ. Технические науки. – 2007 - № 5 – С. 85 – 89.
4. Баринаова О.В. Об одном методе прогнозирования временных рядов с несимметричным функционалом потерь // Математические методы распознавания образов. - 2005 - Т.12. - № 1. - С. 25 - 29.
5. Черных В.Ю., Стенина М.М. Прогнозирование нестационарных временных рядов при несимметричных функциях потерь // Машинное обучение и анализ данных. - 2015 - Т. 1. - № 14. - С. 1893 - 1909.
6. Документация библиотеки catboost. Электронный ресурс <https://catboost.ai/>. Дата обращения 24.03.2023
7. Носова М.Г. Квантильная регрессия и ее преимущества // Актуальные научные исследования в современном мире // 2019 - № 8 - 1 (52). - С. 93 - 96.