

КРАТКОСРОЧНОЕ ПРОГНОЗИРОВАНИЕ В РЕЖИМЕ РЕАЛЬНОГО ВРЕМЕНИ С ИСПОЛЬЗОВАНИЕМ ЭКСПОНЕНЦИАЛЬНЫХ МЕТОДОВ

Шевцова П.Э.¹, Кочегурова Е.А.²

¹НИ ТПУ, ИШИТР, гр.8И21, студент, pes4@tpu.ru

¹НИ ТПУ, ИШИТР, к.т.н., доцент ОИТ

Аннотация

Проведен анализ применения моделей экспоненциального сглаживания для прогнозирования временных рядов в реальном времени. Рассмотрены преимущества и ограничения модели Холта-Винтерса, включая его вычислительную эффективность и адаптивность параметров к изменяющимся характеристикам исходных данных. Анализ влияния адаптивных и статических параметров на точность прогноза подтверждает эффективность метода для краткосрочного прогнозирования при минимальных вычислительных затратах.

Ключевые слова: экспоненциальное сглаживание, прогнозирование временных рядов, модель Холта-Винтерса, адаптивные параметры.

Введение

Прогнозирование параметров объектов и процессов по его ретроспективным значениям представляет собой важную задачу, которая находит применение в самых различных прикладных сферах – от промышленности до медицины.

Особенности современных задач прогнозирования во многом связаны с большими объемами данных, поступающих от GPS, мобильных устройств, датчиков IoT, фитнес-трекеров и других источников. Такие ВР анализируются как единое целое, что позволяет выявлять динамические изменения и тенденции процессов, лежащие в основе их прогностических свойств.

Краткосрочное прогнозирование, с горизонтом прогноза 1-3 значения, востребовано для предсказания эпидемических вспышек, природных явлений, чрезвычайных ситуаций, финансовых рынков, нагрузок в возобновляемой и традиционной энергетике, трафика в транспортных, социальных и технических сетях и пр [1].

Повышение эффективности прогнозирования в реальном времени требует баланса между увеличением точности и сокращением задержек. Оба параметра зависят от длины временного ряда (глубины предыстории) и выбора математической модели прогнозирования.

Глубина предыстории должна соответствовать динамике процесса, но её увеличение снижает оперативность прогноза. Решением может стать рекуррентное прогнозирование с использованием групп наблюдений, что обеспечивает компромисс между долговременной памятью, быстродействием и актуальной длиной ряда. Такой подход представляет собой важную и актуальную задачу для прогнозирования в реальном времени.

В соответствии с предлагаемым подходом необходимо решить следующие задачи:

- провести обзор и выбрать методы, удовлетворяющие требованиям реализации в реальном масштабе времени (РМВ).
- провести анализ типов динамических свойств ВР.
- разработать систему показателей эффективности прогноза.
- выполнить вычислительный эксперимент.

О методах прогнозирования

Методы краткосрочного прогнозирования можно классифицировать по различным признакам [2]. Формализованные методы прогнозирования (или модели) делят на статистические и структурные. Другой подход разделяет методы прогнозирования на параметрические (основанные на информации о распределении ВР) и непараметрические

(использующие информацию не статистического характера). А по степени использования предшествующих данных ВР методы разделяются на локальные и глобальные. Локальные опираются на шейплеты (целые образы из прошлого), а глобальные – на рекуррентный математический аппарат, учитывающий предшествующие данные в скрытой форме.

Особый класс моделей прогнозирования – гибридные методы, комбинирующие методы разных классов. И по разным оценкам [3] частота их использования превышает 20 %.

Прежде чем приступить к выбору методов прогнозирования, необходимо выделить ключевые характеристики ВР, отражающие их структуру и динамику. Основными компонентами ВР являются: тренд, сезонность, шум.

Тренд, как ключевая характеристика динамики ВР, отражает долгосрочное направление изменения динамики (рост, спад), или отсутствие тренда, т.е. стабильность. Сезонность характеризуется периодическими колебаниями, связанными с природными, социальными или технологическими факторами. Учёт сезонности особенно критичен для краткосрочного прогнозирования.

Шум – это случайные колебания и вызван шум ошибками измерений или внешними факторами. Для минимизации влияния шума применяются методы сглаживания, которые одновременно помогают выделить основные компоненты ряда (тренд и сезонность).

Выбор методов прогнозирования напрямую зависит от структуры временного ряда и особенностей задачи прогнозирования.

Таким образом, для прогнозирования ВР со сложной динамикой, включающей тренд, сезонность и шум, могут быть использованы такие методы, как экспоненциальное сглаживание Хольта-Винтерса или SARIMA. Однако, несмотря на эффективность и популярность алгоритмов ARIMA/SARIMA, они не имеют рекуррентной реализации, что ограничивает их применение в задачах прогнозирования в РМВ. В то же время, для некоторых экспоненциальных методов (например, Хольта-Винтерса) рекуррентная реализация возможна, что делает их более подходящими для использования в РМВ. Это обстоятельство обусловило выбор экспоненциальных алгоритмов, второго и третьего порядков для прогнозирования сложных динамических временных рядов в режиме реального времени.

Методология

Экспоненциальные методы прогнозирования обладают рядом преимуществ, таких как адаптивность и гибкость настройки, что делает их эффективными для краткосрочного прогнозирования. Но эти достоинства краткосрочного прогнозирования одновременно являются ограничением в долгосрочном прогнозировании и в гибридном прогнозировании в комбинации с другими методами.

Экспоненциальные методы прогнозирования основаны на присвоении различных весов данным, причём более новые наблюдения оказывают большее влияние на прогноз. Модели экспоненциального сглаживания можно разделить на три основных типа [4]:

Простое экспоненциальное сглаживание используется для прогнозирования временных рядов, которые не содержат тренда или сезонности.

$$\begin{aligned} L_t &= \alpha y_t + (1 - \alpha)L_{t-1} = L_{t-1} + \alpha(y_t - L_{t-1}), \\ \hat{y}_{t+1} &= L_t \end{aligned} \tag{1}$$

где

L_t – уровень ВР в момент времени t ;

y_t – фактическое значение в момент времени t ;

$\hat{y}_t$ – прогноз в момент времени t ;

α – параметр сглаживания ($0 \leq \alpha \leq 1$).

Метод Хольта (двойное экспоненциальное сглаживание) расширяет простое экспоненциальное сглаживание, добавляя компонент тренда, что позволяет прогнозировать данные с тенденцией роста или спада.

$$\begin{aligned}L_t &= \alpha y_t + (1 - \alpha) \cdot (L_{t-1} + T_{t-1}), \\T_t &= \beta \cdot (L_t - L_{t-1}) + (1 - \beta) \cdot T_{t-1}, \\ \hat{y}_{t+1} &= L_{t+1},\end{aligned}\tag{2}$$

где

T_t – оценка тренда на момент времени t ;

α и β – параметры сглаживания для уровня и тренда соответственно.

Метод Хольта-Винтерса (тройное экспоненциальное сглаживание) дополнительно учитывает сезонные колебания, что делает его подходящим для ВР с выраженной сезонностью.

$$\begin{aligned}L_t &= \alpha \cdot (y_t - S_{t-m}) + (1 - \alpha) \cdot (L_{t-1} + T_{t-1}), \quad L_0 = y_0, \\T_t &= \beta \cdot (L_t - L_{t-1}) + (1 - \beta) \cdot T_{t-1}, \\S_t &= \gamma \cdot (y_t - L_t) + (1 - \gamma) \cdot S_{t-m}, \\ \hat{y}_{t+1} &= L_t + T_t + S_{t+1-m},\end{aligned}\tag{3}$$

где

S_t – сезонная компонента на момент времени t .

m – длина сезонного периода.

α , β , γ – параметры сглаживания для уровня, тренда и сезонности соответственно.

Аддитивная модель (3) предполагает, что сезонность и тренд аддитивно влияют на уровень ВР. Существует также мультипликативная модель Хольта-Винтерса, в которой сезонность и тренд мультипликативно влияют на уровень ряда.

Следующий этап в технике прогнозирования – адаптация параметров сглаживания α , β , γ [5, 6]. При поступлении данных в РМВ целесообразна динамическая настройка параметров модели. В условиях РМВ метод рекуррентных оценок параметров может быть использован, поскольку обновляет параметры модели на каждом новом шаге ВР на основе ошибок прогнозирования на прошлом шаге. Этот подход полезен при поступлении данных последовательно, и модель, при этом, быстро адаптируется к изменениям.

Вычислительный эксперимент

Для оценки эффективности прогнозирования в РМВ выполнены вычислительные эксперименты с имитацией реального времени. Эксперименты предназначены для выявления прогностических свойств экспоненциальных алгоритмов для модельных и реальных ВР. Для этого было необходимо выбрать показатели оценки эффективности и задать ВР.

Метрики эффективности

Для оценки эффективности предсказания используются наиболее популярные показатели точности в процентном представлении [7].

MAPE – средняя абсолютная процентная ошибка

$$MAPE = \frac{100}{n} \sum_{i=1}^n |\hat{y}_{t+1} - y_{t+1}|.\tag{6}$$

MSPE – средняя квадратичная процентная ошибка

$$MSPE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_{t+1} - y_{t+1})^2} \cdot \frac{100}{|y_{\max} - y_{\min}|}.\tag{7}$$

Синтетические и реальные временные ряды

В качестве модельных использованы ВР с трендом и ВР комбинации тренда и сезонности.

Трендовый ВР включает 100 точек и задан следующим образом:

$$y1_t = a_0 + a_1 t + \varepsilon_t$$

Модельный ВР, включающий тренд и сезонность, определен формулой

$$y2_t = y1_t + A \cdot \sin\left(\frac{2\pi t}{T}\right).$$

В качестве реальных ВР были использованы данные фондового рынка, хранящиеся на открытом интернет-ресурсе «Kaggle».

Настройка методов и моделей прогнозирования

Для оценки эффективности экспоненциальных методов были выбраны следующие модели Холта и Холта-Винтерса с адаптивными и постоянными параметрами.

Методы с адаптивными параметрами, реализованные в данной статье, используют рекуррентную адаптацию параметров сглаживания на основе градиентного спуска. Таким образом, параметры сглаживания α , β , γ (для уровня, тренда и сезонности) переопределяются при каждом поступлении отсчета ВР с учетом формул рекуррентного обновления параметров и текущей ошибки прогноза.

Методы с постоянными параметрами, реализованные в данной статье, применяют постоянные значения параметров сглаживания на протяжении всего ВР.

Процесс обучения моделей производится параллельно с процессом прогнозирования, так как модель переопределяет параметры сглаживания после каждого предсказанного значения, обучаясь на ошибке между предсказанным и действительным значениями временного ряда.

Основные метрики прогнозирования приведены в табл. 1 для синтетических и реальных ВР с использованием выбранных методов прогнозирования.

Таблица 1. Метрики для спрогнозированных значений ВР

Метод прогнозирования (Модель)	MSPE	MAPE
Временные ряды синтетические		
Двойное экспоненциальное сглаживание (Модель Холта) с адаптивными параметрами - ВР с трендом	2.6999	2.9543
Тройное экспоненциальное сглаживание (Модель Холта-Винтерса) с адаптивными параметрами - ВР с сезонностью и трендом	4.4295	5.6536
Тройное экспоненциальное сглаживание (Модель Холта-Винтерса) с постоянными параметрами - ВР с сезонностью и трендом	5.2161	5.6374
Временные ряды реальные		
Тройное экспоненциальное сглаживание (Модель Холта-Винтерса) с адаптивными параметрами - ВР «Акции Google»	0.6943	1.8112
Тройное экспоненциальное сглаживание (Модель Холта-Винтерса) с постоянными параметрами - ВР «Акции Google»	0.5182	1.4003
Тройное экспоненциальное сглаживание (Модель Холта-Винтерса) с адаптивными параметрами - ВР «Акции Amazon»	0.9167	2.9470
Тройное экспоненциальное сглаживание (Модель Холта-Винтерса) с постоянными параметрами - ВР «Акции Amazon»	0.7072	4.4450

Визуализация результатов прогнозирования для синтетических ВР приведена на рис. 1.




Рис. 1. Результаты прогнозирования:

а) модель Холта с адаптивным параметрами,

б) модель Холта-Винтерса с постоянными и адаптивным параметрами

Обсуждение результатов

Цель исследований с использованием синтетических временных рядов состоит в изучении возможностей и получении предельных характеристик методов прогнозирования. Вычислительные эксперименты показали, что эффективность методов экспоненциального прогнозирования зависит от характера ВР и способа настройки параметров метода.

1. Модель Холта показала достаточно высокие результаты при прогнозировании трендового ВР. Значения метрик MSPE (2.69 %) и MAPE (2.95 %) находятся на приемлемом уровне, что означает хорошую адаптацию метода к трендовым данным. Однако при наличии сезонности результативность модели Холта снижается до 4–5 % при любом способе адаптации параметров модели.

2. Наличие сезонности в исходных данных снижает результативность прогнозирования. Так, результативность для модели Холта-Винтерса с постоянными и адаптивными параметрами снижается до 4–5 %, но тем не менее метрики так же находятся на приемлемом уровне.

Данная модель показывает достойные результаты на реальных данных, рис. 2, рис. 3. Но при этом, в случае адаптивных параметров не требуется изначально задавать оптимальные значения параметров сглаживания. А модель с постоянными параметрами критична к выбору этих значений, что является отдельной сложной задачей и не может быть реализуема в РМВ. На рис. 2 и 3 приведены результаты прогнозирования только для оптимальных значений постоянных параметров.




Рис. 2. Результаты прогнозирования; модель Холта-Винтерса для ВР акций Google: а) весь период, б) последние 100 значений




Рис. 3. Результаты прогнозирования; модель Холта-Винтерса для ВР акций Amazon а) весь период, б) последние 100 значений

Заключение

Проведенные исследования показали преимущества и ограничения экспоненциальных моделей для прогнозирования в РМВ.

Основным достоинством экспоненциальных моделей является наличие рекуррентных способов вычисления, что делает возможным их использование для прогнозирования в РМВ. Также к преимуществам этих методов можно отнести хорошую адаптацию к изменениям трендов и сезонных колебаний и малую затратность ресурсов.

Также к достоинствам методов можно отнести хорошую интерпретируемость параметров сглаживания, что повышает эффективность моделей экспоненциального сглаживания. Однако, эти параметры могут отрицательно влиять на точность прогноза из-за чрезмерного реагирования на локальные шумы. Еще одним ограничением модели Холта-Винтерса является отсутствие априорных данных о периоде сезонности.

В целом методы экспоненциального сглаживания позволяют с высокой точностью предсказывать изменения временного ряда при минимальных вычислительных затратах.

Адаптивные модели обеспечивают гибкость и способность реагировать на изменяющиеся характеристики временного ряда, однако в ряде случаев они могут быть подвержены сильному влиянию шума на прогноз, в то время как модели с постоянными параметрами более стабильны, но требуют подбора параметров сглаживания для обеспечения высокой точности прогноза.

Список использованных источников

1. Akhtar S., Shahzad S., Zaheer A. et al. Short-Term Load Forecasting Models: A Review of Challenges, Progress, and the Road Ahead – *Energies*. – 2023. – № 16 (10). – P. 4060.
2. Запорожцев И.Ф. Краткосрочное прогнозирование пространственно-временной изменчивости океанографических характеристик методами анализа многомерных временных рядов : дис. канд. техн. наук / И.Ф. Запорожцев. – Мурманск, 2016. – 183 с.
3. Parmezan A. Evaluation of statistical and machine learning models for time series prediction: Identifying the state-of-the-art and the best conditions for the use of each model / A. Parmezan, V. Souza, Batista G. // *Information Sciences*. – 2019. – Vol. 484. – P. 302-337.
4. Hyndman R.J., Athanasopoulos G. *Forecasting: Principles and Practice*. 3rd ed. : OTexts. – 2021. – 384 p.
5. Svetunkov I. Modern Exponential Smoothing: Innovations and Applications - *Journal: International Journal of Forecasting*. – 2022. – № 38(1). – P. 204-225.
6. Воевода А.А., Трошина Г.В. Рекуррентный метод оценивания параметра в динамическом объекте // *Автоматическое управление и идентификация*. – 2016. – 12 с.
7. Кочегурова Е.А. Гибридный подход для краткосрочного прогнозирования временных рядов на основе штрафного Р-сплайна и эволюционной оптимизации / Е.А. Кочегурова, Е.Ю. Репина, О.Б. Цехан // *Компьютерная оптика*. – 2020. – Т. 44, № 5. – С. 821-829.