

ПРОГНОЗИРОВАНИЕ НЕСТАЦИОНАРНЫХ ВРЕМЕННЫХ РЯДОВ НА ОСНОВЕ КОГНИТИВНЫХ ТЕХНОЛОГИЙ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

FORECASTING OF NON-STATIONARY TIME SERIES BASED ON COGNITIVE ARTIFICIAL INTELLIGENCE TECHNOLOGIES

**M. Mazurov
A. Slipchenko**

Summary. The main properties of stationary and non-stationary time series are given. The properties of the basic ARIMA program for forecasting stationary time series are given. The main methods of forecasting non-stationary time series, which are most used at the present time, are described. These are the following forecasting methods: 1. Transformational methods of forecasting large time series; 2. Cognitive forecasting methods based on the use of cognitive maps; 3. Forecasting methods based on the use of a sliding window. An example of forecasting non-stationary time series on the stock exchange is given.

Keywords: forecasting, stationary, non-stationary time series, transformer forecasting methods, cognitive methods, sliding window method.

Мазуров Михаил Ефимович

Доктор физико-математических наук, профессор,
Российский экономический
университет имени Г.В. Плеханова
mazurov37@mail.ru

Слипченко Алексей Вячеславович

Аспирант, Российский экономический
университет имени Г.В. Плеханова
alexey.slipchenko@yandex.ru

Аннотация. Приведены основные свойства стационарных и нестационарных временных рядов. Приведены свойства базовой программы ARIMA для прогнозирования стационарных временных рядов. Приведено описание основных методов прогнозирования нестационарных временных рядов, наиболее используемых в настоящее время. Это следующие методы прогнозирования: 1. Трансформерные методы прогнозирования больших временных рядов; 2. Когнитивные методы прогнозирования, основанные на использовании когнитивных карт; 3. Методы прогнозирования на использовании скользящего окна. Приведен пример прогнозирования нестационарного временного ряда на фондовой бирже.

Ключевые слова: прогнозирование, стационарные, нестационарные временные ряды, трансформерные методы прогнозирования, когнитивные методы, метод скользящего окна.

Прогнозирование временных рядов в естественных науках: от климатологии до биологии, экономики требует анализа данных со сложными временными зависимостями. Современные методы машинного обучения помогают находить скрытые паттерны в таких данных, но их эффективность зависит от правильного выбора архитектур и методов обработки. В настоящее время технологии прогнозирования получили значительное развитие благодаря использованию нейронных сетей и машинных методов искусственного интеллекта. Цель данной работы — представление современных технологий прогнозирования временных рядов.

Временные ряды можно разделить на стационарные и нестационарные. В настоящее время большинство практически важных временных рядов в банковской сфере, на фондовой бирже являются нестационарными. Стационарные временные ряды сохраняют постоянные статистические свойства со временем.

Нестационарные временные ряды отличаются переменными статистическими свойствами. На них сильно

влияют тренды или сезонность. Стационарность — ключевое свойство ряда, необходимое для использования большинства «классических» методов прогнозирования. Если данные не стационарны, анализ может быть неточным или вообще не привести к результатам.

Единой классификации методов прогнозирования не существует. При математическом моделировании используют методы: статистические, динамические, линейные, нелинейные, оптимизационные.

Перечислим наиболее известные в настоящее время модели прогнозирования стационарных временных рядов. Наиболее широко используемой является модель ARIMA [1]. ARIMA расшифровывается как «авто регрессионное интегрированное скользящее среднее», — это широко используемый статистический метод прогнозирования временных рядов. Он объединяет три ключевых компонента для моделирования данных:

1. Авторегрессия (AR). Учитывает зависимость между текущим наблюдением и определённым количеством предыдущих наблюдений.

2. Интегрирование (I). Преобразует данные временного ряда в стационарный, то есть делает его статистические характеристики (среднее, дисперсия) постоянными со временем. Обычно для этого к ряду применяют операцию разности один или несколько раз.
3. Скользящее среднее (MA). Моделирует ошибку между реальным наблюдением и прогнозируемым значением, используя комбинацию значений ошибок предыдущих шагов.

Общая формула для несезонной модели ARIMA выглядит ARIMA (p, q) таким образом:

$$y_t = c + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q},$$

где y_t — стационарный временной ряд в момент времени t ;

c — постоянная или среднее значение временного ряда;

$\phi_1, \phi_2, \dots, \phi_p$ — авторегрессионные параметры;

ε_t — погрешность белого шума в момент времени t ;

$\theta_1, \theta_2, \dots, \theta_q$ — параметры скользящего среднего.

Параметры p, q в ARIMA (p, q) обозначают: p — порядок авторегрессии; q — порядок скользящей средней. Имеется ряд вариантов модели

Классическая модель ARIMA накладывает существенные ограничения в исследовательский процесс, что проявляется в следующих моментах:

1. Чувствительность к не стационарности и структурным изменениям: Модель предполагает стационарность ряда, что требует предварительного преобразования данных, включая дифференцирование, которое при избыточном применении может привести к пере дифференцированию;
2. Отсутствие адаптации к резким структурным сдвигам: ARIMA не учитывает внезапные изменения динамики временного ряда, такие как экономические кризисы;
3. Ограниченная способность к моделированию сложных паттернов: Линейная структура ARIMA не позволяет адекватно улавливать нелинейные зависимости в данных.

Рассмотрим современные методы прогнозирования нестационарных временных рядов с использованием когнитивных технологий искусственного интеллекта.

LSTM (Long short-term memory). Это «долгая краткосрочная память», разновидность архитектуры рекуррентных нейронных сетей [2]. Архитектура этой нейронной сети сама решает, что «запомнить», а что «забыть»

на каждом временном шаге. LSTM хорошо приспособлена к обучению на задачах классификации, обработки и прогнозирования временных рядов в случаях, когда важные события разделены временными лагами с неопределённой продолжительностью и границами.

LSTM — это тип нейронной сети, который умеет запоминать важную информацию из прошлого, даже если она появилась давно [2]. При предсказании погоды LSTM запомнит, что дожди в регионе обычно длятся три дня, и учтет это, даже если между событиями прошло много времени. Это достигается за счет специальных «ворот», которые решают, какую информацию сохранить, а какую забыть. LSTM используется, например, для прогнозирования землетрясений или моделирования роста популяций. Современные модификации модели включают: 1. Attention-LSTM: добавляет механизм внимания по аналогии с трансформерами для выделения ключевых временных точек. Используется в прогнозировании урожайности, где важно учитывать критические периоды роста растений. 2. Bidirectional LSTM: анализирует данные в прямом и обратном направлениях, что полезно для реконструкции пропущенных значений в экологических данных.

Прогнозирование нестационарных временных рядов с помощью трансформеров

Трансформером принято называть в общем смысле, нечто преобразующее или преобразующееся. В последнее время появились методы анализа временных рядов, основанные на использовании трансформеров. Первоначально трансформеры использовались для анализа и прогнозирования текстовых файлов, содержащих определенные последовательности элементов. Положительным свойством трансформеров является возможность их идентификации из больших массивов данных. Это свойство трансформеров может быть полезно для анализа и прогнозирования больших данных [3–6]. Трансформеры могут быть использованы для прогнозирования временных рядов благодаря своей способности находить сложные взаимосвязи между значениями в длинных последовательностях. Для обучения трансформеров могут быть использованы большие объёмы временных рядов, что является полезным свойством трансформеров. Трансформеры позволяют выделить близкие по свойствам последовательности данных и затем перейти к параллельному исследованию выделенных последовательностей. Дадим более подробное описание имеющихся типов трансформеров.

Трансформеры это нейросети, которые анализируют данные не по порядку, а сразу целиком, выделяя самые важные связи между точками данных. Их главный инструмент — механизм внимания, фокусирующийся на ключевых элементах последовательности. Среди

трансформерных моделей для прогнозирования явлений в естественных науках могут быть особенно полезны следующие три вида архитектур:

1. Temporal Fusion Transformer (TFT). Объединяет разные типы данных (например, температуру, влажность и время года) для прогнозирования. Модель умеет выделять, какие факторы важны в конкретный момент. Например, для предсказания урожая TFT учтет и погоду, и исторические данные о почве благодаря разделению данных на три категории: статические (географические координаты, тип почвы), временные (погода, время года) и динамические признаки, изменяющиеся во времени переменные, например, уровень загрязнения).
2. Informer. Создан для работы с очень длинными временными рядами (например, десятилетиями наблюдений за солнечной активностью). Informer упрощает вычисления, фокусируясь только на самых информативных точках данных, что ускоряет прогнозирование.
3. Autoformer. Специализируется на данных с повторяющимися паттернами, например, сезонными колебаниями температуры. Autoformer автоматически находит циклы (вроде суточных или годовых) и разделяет данные на «тренд» (общее направление) и «сезонность» (периодические изменения).

Методы прогнозирования с помощью когнитивных карт

Прогнозирование с помощью когнитивных карт основано на методологии когнитивного моделирования, которая позволяет анализировать и прогнозировать развитие ситуаций, учитывая причинно-следственные связи между факторами [7–9].

Когнитивные карты являются основой сознания, интеллекта и мышления человека. Когнитивная составляющая мозга человека организована в виде когнитивной карты. Когнитивные карты в упрощенной схематизированной форме нашли применение для исследования слабоструктурированных и недостаточно четко определенных экономических систем. Когнитивная карта строится экспертным путём в виде ориентированного знакового графа. Вершины графа определяются как концепты, а дуги определяют причинно-следственные отношения, вес которых отражает силу влияния факторов. Достоинством когнитивных карт является возможность использования информационных сведений, предоставляемых экспертами.

С помощью когнитивных карт решаются задачи: 1. Выявление структуры причинных связей между элементами системы; 2. Оценка последствий воздействия на факторы или изменения характера связей; 3. Построение прогнозов развития ситуации на основе вычисленных влияний факторов. Когнитивные карты применяются в различных областях банковского дела, на фондовой бирже, в различных отраслях бизнеса.

Приведем пример когнитивной карты для анализа экономической деятельности фирмы, показанный на рис. 1.

Прогнозирование нестационарных временных рядов методом скользящего окна, основанное на использовании характерных повторяющихся участков временного ряда фигур-аттракторов

На прогнозировании ФВР путем использования характерных повторяющихся участков временного ряда основан метод скользящего или движущегося окна. Повторяющиеся участки временного ряда являются участками самоподобия. Такие участки имеются практически у всех временных рядов. При этом, чем больше длина




Рис. 1. Когнитивная карта для анализа экономической деятельности фирмы

временного ряда, тем больше он имеет участков самоподобия. Повторяющиеся участки временного ряда связаны с наличием хаотической динамики временного ряда. В хаотической динамике их принято называть аттракторами [10]. На фондовой бирже повторяющиеся фигуры ФВР принято называть фигурами технического анализа.

Прогнозирование нестационарных временных рядов методом скользящего окна

Прогнозирование НВР производится следующим образом: 1) выделение участка ФВР в последнем окне; 2) расчет корреляции фигуры в последнем окне и предшествующих участках временного ряда. Блок-схема алгоритма для прогнозирования нестационарных временных рядов методом движущегося окна показана на рис. 2.

В качестве прогнозных значений используются значения временного ряда, следующие непосредственно за областью значений топологически близкого отрезка, то есть для прогноза используется «хвост» близкого отрезка. Если близких отрезков несколько, то для прогнозирования используется среднее арифметическое значений «хвостов» близких отрезков.

Пример использования скользящего окна для прогнозирования производства электрооборудования показан на рис. 3.

Приведем пример вычислительного эксперимента для расчета повторяющихся фигур-аттракторов временного ряда на примере исследования временного ряда стоимости акций ПАО «Сбербанк» для одного из периодов времени. Для временного ряда рассматриваемого периода времени 85 дней характерен растущий тренд. Результаты визуализированы на рис.4.

Приведем перечень фигур, характерных для временного ряда акций ПАО Сбербанк».

Можно заметить, что фигуры 2, 3 и 4 являются составными частями друг друга, в то время как фигуры 1 и 5 являются зеркальным отражением друг друга.

Заключение

Дано описание методов прогнозирования нестационарных временных рядов, основанных на использовании: 1. Трансформерные методы прогнозирования больших временных рядов; 2. Когнитивные методы прогнозирования, основанные на использовании когнитивных карт; 3. Методы прогнозирования на использовании скользящего окна. Приведены примеры прогнозирования нестационарных временных рядов на фондовой бирже.




Рис. 2. Блок-схема алгоритма для прогнозирования нестационарных временных рядов методом движущегося окна




Рис. 3. Пример использования скользящего окна для прогнозирования объема производства электрооборудования




Рис. 4. Темп прироста котировок акций ПАО «Сбербанк», размер скользящего окна 3 дня




Рис. 5. Перечень фигур, характерных для временного ряда акций ПАО «Сбербанк»

ЛИТЕРАТУРА

1. Айвазян С.А. Прикладная статистика. Основы эконометрики. Том 2. М.: Юнити-Дана, 2001. 432 с.
2. Hochreiter S., & Schmidhuber J. (1997). Long short-term memory. Neural Computation.
3. Schlag Imanol, Irie Kazuki, Schmidhuber Jürgen . «Linear Transformers Are Secretly Fast Weight Programmers». ICML 2021. Springer. p. 9355–9366
4. Lim B., et al. (2021). Temporal Fusion Transformers for Interpretable Multi-horizon Time Series Forecasting. International Journal of Forecasting.
5. Zhou H., et al. (2021). Informer: Beyond Efficient Transformer for Long Sequence Time-Series Forecasting. Proceedings of AAAI.
6. Wu H., et al. (2021). Autoformer: Decomposition Transformers with Auto-Correlation for Long-Term Series Forecasting. Advances in Neural Information Processing Systems (NeurIPS).
7. Мазуров М.Е. Идентификация математических моделей нелинейных динамических систем: монография. М.: ЛЕНАНД, 2019. 284 С.
8. Ярушкина Н.Г. Интеллектуальный анализ временных рядов. Учебное пособие. М.: Форум, 2018. 701 с.
9. Бэстенс Д.Э., Берг В.М., Вуд Д. Нейронные сети и финансовые рынки: принятие решений в торговых операциях М.: ТВП, 1997. 236 с.
10. Такенс Ф. Обнаружение странных аттракторов в турбулентности. В Д.А. Рэнд и Янг Л.-С. (ред.). Динамические системы и турбулентность, Конспекты лекций по математике, Springer-Verlag.1981. Т. 898. С. 366–381.

© Мазуров Михаил Ефимович (mazurov37@mail.ru); Слипченко Алексей Вячеславович (alexey.slipchenko@yandex.ru)

Журнал «Современная наука: актуальные проблемы теории и практики»