

На правах рукописи



Александрович Дмитрий Михайлович

**Анализ и прогнозирование данных мобильного оператора в виде
временных рядов**

Направление подготовки
09.04.01 Информатика и вычислительная техника
направленность – профиль Инженерия программного обеспечения и
информационных систем
программа академической магистратуры

АВТОРЕФЕРАТ
магистерской диссертации
на соискание квалификации (степени) магистра

Екатеринбург 2025

Работа выполнена в Федеральном государственном бюджетном образовательном учреждении высшего образования «Сибирский государственный университет телекоммуникаций и информатики» Уральского технического институт связи и информатики (филиал) в г. Екатеринбурге (УрТИСИ СибГУТИ)

Научный руководитель

Кусайкин Дмитрий Вячеславович

Кандидат технических наук, доцент кафедры
МЭС УрТИСИ СибГУТИ,

Рецензент

Будылдина Надежда Вениаминовна

Кандидат технических наук, доцент кафедры
ИТиМС УрТИСИ СибГУТИ,

Защита состоится «30» июня 2025 г. в 9 часов в Федеральном государственном бюджетном образовательном учреждении высшего образования «Сибирский государственный университет телекоммуникаций и информатики» Уральского технического институт связи и информатики (филиал) в г. Екатеринбурге (УрТИСИ СибГУТИ), г. Екатеринбург, ул. Репина, д. 15.

Секретарь Государственной аттестационной комиссии

Общая характеристика работы

Актуальность исследования

С ростом цифровизации и увеличением количества подключённых устройств, телекоммуникационные сети становятся всё более загруженными. Эффективное управление сетевыми ресурсами требует точного анализа и прогнозирования поведения пользователей и объёмов трафика. Одной из ключевых задач в этой области становится моделирование временных рядов, позволяющее выявить тренды, сезонные закономерности и предсказывать будущую нагрузку на инфраструктуру связи. Современные алгоритмы временного анализа, такие как STL-декомпозиция, модели Holt-Winters, SARIMA и Prophet, предоставляют мощный инструмент для оценки сетевой динамики как по количеству абонентов, так и по объёму потребляемого трафика.

Особую актуальность задача приобретает в условиях необходимости оперативного принятия решений при планировании пропускной способности, распределении ресурсов и оценке эффективности внедрения новых технологий связи (в частности, LTE и 5G). Точные прогнозы позволяют избежать перегрузок, минимизировать издержки и повысить качество обслуживания конечных пользователей. Анализ сетевого поведения может быть использован для выявления аномалий и отклонений в работе систем связи.

Объект исследования

Временные ряды, описывающие поведение телекоммуникационных систем.

Предмет исследования

методы анализа и прогнозирования сетевого трафика и количества абонентов с использованием современных математических моделей.

Цель работы

сравнительный анализ различных моделей прогнозирования временных рядов с последующим построением прогноза сетевых показателей, таких как объём трафика и количество абонентов, на основе реальных телеком-данных за 2023–2024 годы.

Задачи исследования

1. Исследовать основные методы временного анализа, применяемые для прогнозирования сетевых показателей.
2. Реализовать алгоритмы STL-декомпозиции, Holt-Winters, SARIMA, Prophet и их комбинации.
3. Построить краткосрочные прогнозы для различных метрик связи;
4. Провести сравнение полученных результатов по точности и интерпретируемости.
5. Визуализировать и интерпретировать структуру временных рядов (тренд, сезонность, шум).
6. Дать рекомендации по применению моделей в реальных условиях

эксплуатации телекоммуникационных сетей.

Теоретическая значимость работы состоит в расширении и конкретизации подходов к анализу и прогнозированию телекоммуникационных временных рядов с использованием современных методов статистического и интеллектуального моделирования. В работе обоснована применимость STL-декомпозиции как эффективного инструмента разложения исходного ряда на трендовую, сезонную и шумовую составляющие, что обеспечивает возможность более точной настройки прогностических моделей на каждом этапе.

Особое внимание уделено сравнению параметрических моделей SARIMA и Prophet с гибридным подходом STL + ARIMA. На основе анализа их прогностических свойств выявлены условия, при которых каждая из моделей демонстрирует наилучшие результаты. Это позволило уточнить положения теории временных рядов относительно сочетания методов декомпозиции и авторегрессионного анализа при наличии сложной сезонной структуры.

Дополнительно теоретическая значимость заключается в методическом обосновании выбора моделей с учётом характера данных: годовой и недельной сезонности, наличия нелинейных трендов, и влияния шумов. Представленные в работе методики могут быть использованы при разработке аналитических систем мониторинга телекоммуникационных сетей, а также в учебных курсах по анализу временных рядов и прикладной статистике.

Практическая значимость работы заключается в разработке и внедрении прикладных методов прогнозирования телекоммуникационных показателей, которые могут быть использованы операторами связи для повышения эффективности функционирования сетей LTE. Полученные в ходе исследования результаты позволяют решать актуальные задачи краткосрочного планирования нагрузки на сеть и распределения ресурсов в условиях динамически изменяющегося пользовательского поведения.

Разработанные модели и алгоритмы прогнозирования реализованы в программной среде Python с применением библиотек statsmodels и prophet, что обеспечивает их универсальность и удобство интеграции в существующие аналитические платформы операторов связи. Предложенные подходы позволяют не только повысить точность прогнозов, но и более гибко учитывать сезонные и трендовые компоненты, что особенно важно при высокочастотных колебаниях сетевого трафика и абонентской активности.

Результаты работы могут быть использованы в системах мониторинга и аналитики телеком-операторов, при разработке интеллектуальных систем поддержки принятия решений, а также в учебных курсах, связанных с анализом временных рядов, телекоммуникационными технологиями и прикладной аналитикой больших данных.

Методологической основой исследования является системный подход к анализу и прогнозированию временных рядов телекоммуникационных показателей, позволяющий учитывать сложную структуру данных,

включающую тренды, сезонность и случайные компоненты. В рамках этого подхода использовались современные методы математической статистики, обработки и декомпозиции временных рядов, а также алгоритмы машинного обучения для построения и сравнения прогностических моделей.

Для декомпозиции временных рядов использовался метод STL (Seasonal-Trend decomposition using Loess), позволяющий выделить трендовые, сезонные и остаточные компоненты с высокой гибкостью. Для прогнозирования тренда и шумов применялись авторегрессионные модели ARIMA. Также использовались расширенные модели SARIMA, учитывающие сезонность, и модель Prophet, основанная на аддитивной регрессии с заданной сезонной структурой.

Достоверность и обоснованность полученных результатов обеспечиваются применением проверенных и широко признанных методов анализа и прогнозирования временных рядов, таких как STL-декомпозиция, модели SARIMA, Prophet и ARIMA, реализованных с использованием современных вычислительных инструментов в языке программирования Python. Выбор моделей основывался на предварительном анализе структуры исходных данных, включая тестирование на стационарность, сезонность и наличие трендовых составляющих.

Каждая из моделей была протестирована на реальных телекоммуникационных данных за 2023–2024 гг., охватывающих показатели общего трафика и количества абонентов LTE.

Сравнительный анализ был проведён с едиными параметрами для всех моделей на одном и том же наборе данных, что исключает влияние внешних факторов на результаты. Повторяемость полученных результатов и их воспроизводимость с использованием типовых библиотек подтверждает надёжность выводов и обоснованность предложенных подходов.

Работа включает введение, три главы, заключение, список литературы из 51 источников. Общий объём – 98 страниц, включая 10 формул и 27 рисунков.

ОСНОВНОЕ СОДЕРЖАНИЕ РАБОТЫ

Введение

Во введении обоснована актуальность использования методов машинного обучения для задач прогнозирования телекоммуникационных показателей, в частности — количества абонентов и объёма трафика в сетях LTE. Сформулированы цель исследования, его задачи, объект и предмет, а также выдвинута гипотеза о возможности повышения точности краткосрочного прогноза путём применения статистических и гибридных моделей. Приведено краткое описание научной новизны и практической значимости полученных результатов, обозначена методологическая основа исследования.

В первой главе «Анализ трафика сетей сотовой связи»

представлен анализ предметной области и современных методов прогнозирования временных рядов. Проведён обзор статистических и машинных методов, включая авторегрессионные модели, метод скользящего среднего, модели экспоненциального сглаживания, метод Prophet и STL-декомпозицию. Также описаны особенности данных телекоммуникационных сетей, такие как сезонность, шумы и наличие тренда. Обоснован выбор моделей для дальнейшего исследования, а также рассмотрены существующие публикации, подтверждающие актуальность направления.

Во второй главе «Алгоритмы анализа временных рядов»

раскрыта методология построения моделей прогнозирования. Представлены теоретические основы моделей SARIMA, Prophet и STL+ARIMA, приведены их математические формулировки и логика работы. Особое внимание уделено процедуре STL-декомпозиции временного ряда на трендовую, сезонную и шумовую составляющие, с последующим моделированием тренда и шумов с помощью ARIMA. Также описан алгоритм работы Prophet, использующего аппроксимацию сезонности через разложение Фурье. Раздел включает описание используемых метрик качества прогноза и методов нормализации компонент.

В третьей главе «Результаты прогнозирования данных сетевого оператора»

изложены этапы практической реализации моделей и анализа результатов. Проведена обработка и визуализация реальных данных оператора связи за 2023–2024 годы, включая общий трафик и количество абонентов. Выполнено сравнение трёх подходов: SARIMA, Prophet и STL+ARIMA. Для каждой модели построены прогнозы на 90 дней, результаты сохранены и визуализированы. Сопоставлены трендовые, сезонные и шумовые компоненты, а также проведён анализ их средней сезонности по месяцам. Выявлены преимущества и ограничения каждого подхода при прогнозировании телекоммуникационных временных рядов.

ЗАКЛЮЧЕНИЕ

В заключении представлены ключевые результаты, полученные в процессе выполнения магистерской диссертации. Подтверждено, что применение методов интеллектуального анализа временных рядов позволяет существенно повысить точность краткосрочного прогнозирования телекоммуникационных показателей. Проведённый сравнительный анализ трёх подходов — SARIMA, Prophet и STL+ARIMA — показал, что каждый из них обладает своими преимуществами в зависимости от структуры данных.

Модель SARIMA продемонстрировала высокую точность при наличии чётко выраженной сезонности и тренда. Prophet показал удобство использования и высокую интерпретируемость, а также гибкость в учёте сезонных флуктуаций. Метод STL+ARIMA позволил эффективно моделировать компоненты временного ряда по отдельности, обеспечивая точную адаптацию к нестабильной сезонности и нестационарным шумам.

В ходе выполнения диссертационного исследования были получены как теоретические, так и практические результаты, направленные на решение задачи прогнозирования телекоммуникационных временных рядов. С теоретической точки зрения проведён подробный анализ существующих подходов к моделированию временных рядов, включая статистические методы, такие как ARIMA и SARIMA, модели компонентной декомпозиции STL, а также гибкий инструмент Prophet, использующий аппроксимацию сезонности через разложение по Фурье и автоматическое определение точек изменения тренда. Обоснована возможность повышения точности прогнозирования за счёт предварительного разложения временного ряда на составляющие и последующего применения специализированных моделей к каждой из них. Разработан подход, предполагающий использование STL-декомпозиции с прогнозом трендовой и шумовой составляющих с помощью модели ARIMA, а также проведено теоретическое сопоставление с моделями Prophet и SARIMA.

Практическая часть работы включает реализацию алгоритмов на языке Python с применением библиотек statsmodels, prophet, pandas, matplotlib и других инструментов обработки временных рядов. Были собраны и очищены реальные данные оператора связи за 2023 и 2024 годы, включающие значения суточного общего трафика и количества абонентов LTE. С использованием разработанного программного комплекса построены прогнозы на 90 дней вперёд, получены визуализации и оценены доверительные интервалы. Проведено сравнение моделей по качеству прогноза на основе метрик MAE, RMSE и визуального анализа остатков, сезонных и трендовых компонент. Установлено, что гибридная модель STL+ARIMA обеспечивает наиболее гибкое и устойчивое поведение в условиях изменяющейся сезонности, а Prophet отличается высокой интерпретируемостью и удобством при интеграции в прикладные задачи. Полученные результаты могут быть использованы операторами связи при планировании пропускной способности

сетей и ресурсном управлении, что подтверждает как научную, так и прикладную значимость проделанной работы.

СПИСОК РАБОТ, ОПУБЛИКОВАННЫХ АВТОРОМ ПО ТЕМЕ ДИССЕРТАЦИИ

Д.М. Александрович, Л. Н. Евдакова

Роль искусственного интеллекта в изменении образовательных траекторий и экономической мобильности

Министерство цифрового развития, связи и массовых
коммуникаций РФ Уральский технический институт связи и
информатики (филиал) ФГБОУ ВО

«Сибирский государственный университет телекоммуникаций и информатики» в
г. Екатеринбурге (УрТИСИ СибГУТИ), Россия

В статье рассмотрено влияние искусственного интеллекта на трансформацию образовательных траекторий и экономическую мобильность в условиях цифровой экономики. Проведен анализ ключевых технологий ИИ, их применения в образовании и влияния на персонализацию обучения. Особое внимание уделено изменениям в доступе к качественному обучению, развитию востребованных навыков и сокращению социального неравенства. Выявлены основные вызовы и перспективы внедрения ИИ, а также его экономический эффект в образовательной системе.

Ключевые слова: искусственный интеллект, персонализация обучения, образовательные технологии, экономическая мобильность, цифровая экономика, адаптивное обучение.

The Role of Artificial Intelligence in Transforming Educational Trajectories and Economic Mobility

Ministry of Digital Development, Communications and Mass
Communications of the Russian Federation Ural Technical Institute of Communications
and
Informatics (branch)

"Siberian State University of Telecommunications and Informatics" in
Yekaterinburg (UrTISI SibGUTI), Russia

The article examines the impact of artificial intelligence on the transformation of educational trajectories and economic mobility in the context of the digital economy. An analysis of key AI technologies, their applications in education, and their effects on personalized learning is presented. Special attention is given to changes in access to quality education, the development of in-demand skills, and the reduction of social inequality. The main challenges and prospects of AI implementation, as well as its economic impact on the educational system, are identified.

Keywords: artificial intelligence, personalized learning, educational technologies, economic mobility, digital economy, adaptive learning.

Введение

Современный мир переживает стремительную цифровизацию, которая затрагивает все сферы жизни, включая образование и экономику. Одной из ключевых технологий, определяющих развитие образования, становится искусственный интеллект (ИИ). Применение ИИ в образовательном процессе позволяет значительно повысить качество обучения, персонализировать подход к каждому обучающемуся и расширить доступ к образовательным ресурсам[1].

Развитие ИИ приводит к трансформации образовательных траекторий, позволяя адаптировать процесс обучения под индивидуальные потребности и способности студентов. В результате образовательные системы становятся более гибкими и эффективными, что напрямую влияет на экономическую мобильность — возможность людей улучшать свое социально-экономическое положение благодаря получению актуальных знаний и навыков. В данной статье будет рассмотрено влияние искусственного интеллекта на трансформацию образовательных траекторий, включая персонализацию и доступность обучения. Особое внимание будет уделено анализу изменений в экономической мобильности, вызванных внедрением ИИ, а также исследованию возможностей и вызовов, связанных с применением этих технологий в образовании.

Искусственный интеллект в образовании: концепции и примеры.

Искусственный интеллект (ИИ) — это технология, которая позволяет системам выполнять задачи, требующие интеллектуальных способностей, таких как обучение, анализ данных и принятие решений. В образовании ИИ используется для персонализации обучения, создания адаптивных образовательных платформ, автоматизации рутинных задач, анализа больших данных и разработки виртуальных обучающих сред. Примеры успешного применения включают платформы Duolingo и Khan Academy, которые подстраиваются под уровень учащегося, чат-боты для обратной связи, а также инструменты, проверяющие работы и выявляющие пробелы в знаниях. Это позволяет сделать обучение более доступным, эффективным и ориентированным на индивидуальные потребности студентов, снижая нагрузку на преподавателей и повышая вовлеченность учащихся[4].

Искусственный интеллект также способствует расширению образовательных возможностей в регионах с ограниченным доступом к качественному обучению. Онлайн-платформы с использованием ИИ помогают преодолевать географические и языковые барьеры, предоставляя доступ к материалам мирового уровня. Такие технологии позволяют людям из самых разных социальных слоев улучшать свои знания и навыки, что особенно важно в условиях цифровой экономики.

Кроме того, ИИ активно меняет подход к обучению, делая его более гибким и ориентированным на развитие навыков, востребованных на рынке труда. Благодаря анализу больших данных и прогнозированию индивидуальных потребностей студентов, образовательные программы становятся более адаптивными, а обучение — целенаправленным и результативным. Это открывает новые перспективы для формирования квалифицированной рабочей силы, готовой к вызовам будущего.

2. Изменение образовательных траекторий под влиянием ИИ.

Искусственный интеллект радикально трансформирует образовательные траектории, делая процесс обучения более индивидуализированным, доступным и эффективным. Применение ИИ способствует адаптации учебных материалов и методов к потребностям каждого учащегося, создавая возможности для глубокого погружения в изучаемую тему.

Персонализация обучения — один из главных эффектов внедрения ИИ. Образовательные платформы анализируют данные о прогрессе учащегося, определяют его

сильные и слабые стороны и предлагают соответствующие материалы и задания. Это позволяет студентам изучать темы в удобном для них темпе, уделяя больше времени сложным аспектам. Например, адаптивные платформы, такие как Khan Academy, подстраивают содержание курса под уровень знаний ученика, повышая эффективность обучения.

ИИ также расширяет доступ к образовательным возможностям. Благодаря онлайн-платформам и автоматизированным системам обучения качественное образование становится доступным не только в мегаполисах, но и в удалённых регионах. Это особенно важно для социально уязвимых групп, которым трудно получить доступ к традиционным формам обучения. Примером может служить использование ИИ для перевода образовательных материалов на разные языки, что помогает преодолевать языковые барьеры.

Развитие навыков, востребованных в цифровую эпоху, — ещё одно важное изменение, связанное с ИИ. Учащиеся получают возможность изучать программирование, анализ данных, навыки критического мышления и другие ключевые компетенции, интегрированные в современные образовательные программы. Кроме того, ИИ предоставляет автоматизированную обратную связь, позволяя студентам быстрее корректировать свои ошибки и улучшать результаты[3].

Эти изменения делают образовательные траектории более гибкими и ориентированными на успех каждого ученика. Однако они также требуют пересмотра подходов к обучению, а также технического оснащения и цифровой грамотности преподавателей и студентов

Влияние на экономическую мобильность.

Искусственный интеллект существенно влияет на экономическую мобильность, создавая новые возможности для улучшения социально-экономического положения через образование. Благодаря персонализации и доступности обучения, ИИ помогает людям быстрее адаптироваться к требованиям современного рынка труда, что особенно важно в условиях постоянной трансформации профессий и появления новых сфер занятости.

Одно из ключевых преимуществ внедрения ИИ в образование — повышение доступности качественного обучения. Студенты из разных социальных слоев, включая тех, кто сталкивается с финансовыми или географическими барьерами, получают возможность учиться онлайн, используя адаптивные платформы и автоматизированные системы. Это уменьшает разрыв между элитным и массовым образованием, помогая людям из менее привилегированных слоёв общества получить актуальные знания и навыки, необходимые для трудоустройства и карьерного роста.

ИИ также меняет рынок труда, способствуя появлению новых профессий, связанных с цифровыми технологиями, и стимулируя переквалификацию работников. Программы, основанные на ИИ, помогают людям осваивать востребованные навыки, такие как программирование, анализ данных или работа с искусственным интеллектом, что увеличивает их конкурентоспособность и доходы. Например, автоматизация рутинных задач позволяет сотрудникам сосредоточиться на более творческих и стратегических аспектах своей работы.

Однако применение ИИ в образовании сопровождается рисками, которые могут ограничить его влияние на экономическую мобильность. Среди них — цифровой разрыв, возникающий из-за неравномерного доступа к технологиям, а также недостаточная цифровая грамотность среди студентов и преподавателей[6].

В долгосрочной перспективе искусственный интеллект может стать мощным двигателем для экономической мобильности, если будет активно применяться для устранения барьеров к обучению, развития ключевых навыков и создания возможностей для карьерного роста.

Экономический эффект внедрения ИИ в образовательную систему.

Искусственный интеллект оказывает значительное влияние на эффективность образовательных процессов, что в свою очередь сказывается на экономике. Внедрение ИИ позволяет оптимизировать использование ресурсов, улучшить качество обучения и ускорить подготовку высококвалифицированных специалистов, что приводит к росту производительности труда и экономического потенциала общества.

Прежде всего, ИИ повышает эффективность образовательных процессов, заменяя или дополняя традиционные методы обучения. Адаптивные системы на основе ИИ подбирают материалы с учетом потребностей учащихся, снижая затраты времени на изучение тем, которые уже освоены, и концентрируясь на сложных аспектах. Это ускоряет обучение и позволяет студентам быстрее выходить на рынок труда, готовыми к реальным задачам.

Кроме того, ИИ автоматизирует рутинные задачи, такие как проверка домашних заданий, проведение тестов и анализ успеваемости студентов. Это снижает нагрузку на преподавателей, позволяя им уделять больше времени индивидуальной работе со студентами и разработке учебных программ. В долгосрочной перспективе такие изменения способствуют экономии ресурсов образовательных учреждений и увеличивают их производительность[2].

Влияние на экономическую продуктивность связано с повышением качества рабочей силы. Учащиеся, прошедшие подготовку с использованием ИИ, получают навыки, соответствующие современным требованиям рынка труда, такие как аналитическое мышление, умение работать с большими данными и решение сложных задач. Это приводит к росту их доходов, повышению уровня жизни и увеличению вклада в экономику.

Также ИИ открывает новые горизонты для масштабируемости образования. Онлайн-курсы и платформы с использованием ИИ могут охватить миллионы пользователей одновременно, предлагая доступ к качественному обучению независимо от географического местоположения. Это особенно актуально для развивающихся стран, где ограниченные ресурсы препятствуют созданию эффективных образовательных систем.

Однако важно учитывать, что внедрение ИИ требует значительных начальных инвестиций и наличия цифровой инфраструктуры. Отсутствие доступа к таким технологиям может усилить цифровое неравенство, что негативно скажется на общей экономической эффективности. Решение этих проблем требует координации усилий государства, бизнеса и образовательных организаций[5].

В перспективе искусственный интеллект способен стать ключевым фактором экономического роста через трансформацию образования. Создание квалифицированной рабочей силы, снижение образовательных барьеров и оптимизация затрат — всё это обеспечивает долговременный положительный эффект как для отдельных граждан, так и для общества в целом.

Заключение

Искусственный интеллект оказывает глубокое влияние на трансформацию образовательных траекторий и экономическую мобильность, становясь неотъемлемой частью образовательных систем в условиях цифровой эпохи. Благодаря персонализации, автоматизации процессов и расширению доступа к обучению, ИИ открывает новые возможности для развития личности, повышения квалификации и устранения барьеров к получению знаний.

Влияние ИИ на образование не ограничивается только учебным процессом. Оно распространяется на рынок труда, повышая конкурентоспособность работников и способствуя развитию ключевых навыков, востребованных в современной экономике. Эти изменения создают предпосылки для роста экономической мобильности и снижения

социального неравенства, особенно в развивающихся регионах.

Тем не менее, внедрение ИИ сопровождается вызовами, включая необходимость развития цифровой грамотности, устранения цифрового разрыва и создания равных условий для доступа к новым технологиям. Решение этих задач требует активного взаимодействия между государственными структурами, образовательными организациями и бизнесом.

Таким образом, искусственный интеллект не только трансформирует систему образования, но и становится инструментом для формирования экономически устойчивого и социально справедливого общества, где возможности обучения и профессионального роста доступны каждому.

Список литературы

1. Синицын А.В. Искусственный интеллект в образовании: проблемы и перспективы // Образование и наука. 2022. Т. 24, № 3. С. 15–28.
2. Johnson, D. The Role of Artificial Intelligence in Personalized Learning // Journal of Educational Technology. 2021. Vol. 38, No. 4. P. 45–59.
3. World Economic Forum. The Future of Jobs Report 2020. URL: <https://www.weforum.org/reports/the-future-of-jobs-report-2020>.
4. UNESCO. Artificial Intelligence in Education: Challenges and Opportunities. Paris: UNESCO, 2021. URL: <https://unesdoc.unesco.org>.
5. McKinsey & Company. How Artificial Intelligence is Reshaping Work and Education. 2022. URL: <https://www.mckinsey.com>.
6. Кузнецов И.И., Иванов О.Н. Цифровые технологии и их влияние на экономическую мобильность // Вестник экономики и права. 2021. № 5. С. 65–78.

Александрович Д.М., гр. МиВТ-31

Научный руководитель: к.п.н., доцент кафедры ЭС Новокшенова Р.Г.

Архитектура сетевого радиointерфейса GSM.

ARCHITECTURE OF THE GSM NETWORK RADIO INTERFACE.

The purpose of the essay is to learn about architecture of the GSM network radio interface.

The radio interface, also known as the air interface, is a critical component of the GSM network, enabling communication between mobile devices and network infrastructure. The GSM (Global System for Mobile Communications) radio interface architecture provides a structured framework for ensuring effective signal transmission and reception, seamless handovers, and consistent voice and data quality across various geographic regions.

Physical channels can be used to transmit speech, data or signaling information.

A physical channel may carry different messages, depending on the information that is to be sent. These messages are called logical channels [1].

Logical channels.

On Layer 1 of the OSI Reference Model, GSM defines a series of logical channels, which are made available either in an unassigned random access mode or in a dedicated mode assigned to a specific user. Logical channels are divided into two categories: traffic channels and signaling (control) channels [2].

Traffic Channels (TCH): This channel carries digitally encoded user's speech or data and has identical functions and formats on both the forward and reverse link.

a) Full Rate Traffic Channels (TCH/F): This channel carries information at a rate of 22.8 Kbps.

b) Half Rate Traffic Channels (TCH\H): This channel carries information at a rate of 11.4 Kbps.

8 Time Slots (1 Time Slot = 1 Physical Channel) of 577 μ s constitutes a 4.615 ms TDMA Frame. In GSM standard data on a time slot transmitted in bursts, so time slot is often expressed in BP (Burst Period). 1 BP represents 1 TS. TDMA frame (8 TS) further structured into Multiframe. There are two types of Multiframe, 26 TDMA Multiframe which consists 26 TDMA frames with duration of 120 ms and used to carry the channels like TCH, SACCH, FACCH and 51 TDMA Multiframe which consists 51 TDMA frames with duration of 234.5 ms and used to carry channels like FCCH, SCH, BCCH, CCCH, SDCCH, SACCH. These Multiframe further structured into superframe and Hyperframe.

i. SUPERFRAME: Superframe consists of 51*26 TDMA frames with a duration of 6.12 sec.

ii. HYPERFRAME: Hyperframe consists 2048 superframes (2048*51*26 TDMA frames) with duration of 3 hrs, 28 min, 53 secs and 760 ms [3].

Signaling channels.

The control and management of a cellular network demands a very high signaling effort. Even when there is no active connection, signaling information (for example, location update information) is permanently transmitted over the air interface. The GSM signaling channels offer a continuous, packet-oriented signaling service to MSs in order to enable them to send and receive messages at any time over the air interface to the BTS. Following ISDN terminology, the GSM signaling channels are also called Dm channels (mobile D channel). They are further divided into Broadcast Channel (BCH), Common Control Channel (CCCH) and Dedicated Control Channel (DCCH). The unidirectional BCHs are used by the BSS to broadcast the same information to all MSs in a cell [2].

Список источников:

1. GSM RAN Radio Network Features – authors: Ericsson AB 2016.
2. GSM – Architecture, Protocols and Services [Электронный ресурс] Режим доступа: <https://juelrana.wordpress.com/wp-content/uploads/2011/01/gsm.pdf> (Дата обращения: 02.11.2024)
3. GSM Architecture & Channels: Review Study [Электронный ресурс] Режим доступа: <https://ijoes.vidyapublications.com/paper/Vol20/02-Vol20.pdf> (Дата обращения: 02.11.2024)

АНАЛИЗ ТРАФИКА СЕТИ LTE НА ОСНОВЕ ДЕКОМПОЗИЦИИ ВРЕМЕННОГО РЯДА

Уральский технический институт связи и информатики (филиал) ФГБОУ ВО
«Сибирский государственный университет телекоммуникаций и информатики» в г.
Екатеринбурге
(УрТИСИ СибГУТИ), Россия

Ключевые слова: временной ряд, трафик сети LTE, STL, Holt-Winters, Census I, сезонность, тренд, декомпозиция.

В работе рассматривается задача декомпозиции временного ряда трафика мобильной сети LTE на структурные компоненты: тренд, сезонность и остатки (шум). Анализ проведён на основе данных оператора связи за 2023–2024 годы. Для выделения компонент использованы три метода: STL, Holt-Winters и Census I, реализованный в программном обеспечении Statistica. Проведено визуальное и количественное сравнение полученных компонент, включая нормализацию по z-оценке и агрегацию сезонности по календарным месяцам. Результаты показывают, что методы STL и Census I обеспечивают более устойчивое и интерпретируемое поведение тренда и сезонности по сравнению с моделью Holt-Winters, которая демонстрирует повышенную чувствительность к колебаниям. Представленный анализ может быть использован в качестве предварительного этапа при построении прогнозных моделей трафика сети LTE.

D.M. Aleksandrovich, D.V. Kusajkin

ANALYSIS OF LTE NETWORK TRAFFIC BASED ON TIME SERIES DECOMPOSITION

Ural Technical Institute of Communications and Informatics (branch) of the Siberian State
University of Telecommunications and Informatics in Yekaterinburg (UrTISI SibGUTI), Russia

Keywords: time series, LTE traffic, STL, Holt-Winters, Census I, seasonality, trend, decomposition.

The paper considers the problem of decomposing the time series of LTE mobile network traffic into structural components: trend, seasonality and residuals (noise). The analysis is based on data from the telecom operator for 2023-2024. Three methods were used to isolate the components: STL, Holt-Winters, and Census I, implemented in the Statistica software. A visual and quantitative comparison of the obtained components was carried out, including normalization by z-score and aggregation of seasonality by calendar months. The results show that the STL and Census I methods provide more stable and interpretable trend and seasonal behavior compared to the Holt-Winters model, which demonstrates increased sensitivity to fluctuations. The presented analysis can be used as a preliminary stage in building predictive models of LTE network traffic.

Современные сотовые сети стандарта LTE обеспечивают стремительно растущие объёмы мобильного интернет-трафика, что требует применения устойчивых и точных методов анализа для оценки и прогнозирования нагрузки на сеть. Одним из наиболее эффективных подходов в данной области является декомпозиция временных рядов, позволяющая разложить данные на структурные компоненты: тренд, сезонность и остатки (шумы). Такая предварительная аналитика служит основой, как для интерпретации

поведения системы, так и для построения прогностических моделей.

В работе [1] производится декомпозиция временного ряда трафика сети сотовой связи на компоненты, но только в рамках суток и только для сети 3G. Рассматривается эффективность нескольких статистических моделей для прогнозирования голосового трафика и трафика данных в мобильной сети. В [2] рассматривается декомпозиция временных рядов мобильного трафика на примере сети сотовой связи в Шанхае, производится извлечение закономерностей из различных компонентов исходного трафика и обнаружение аномальных событий. В исследовании использовались данные о мобильном трафике, полученные от 6400 базовых станций. Также актуальным является анализ временных рядов трафика мобильной сети методом глубокого машинного обучения [3], направленный на прогнозирование сложных закономерностей в данных.

Уникальность рассматриваемого в настоящей работе подхода заключается в комплексном сравнении методов декомпозиции на одном и том же наборе статистических данных мобильного трафика сети LTE. Это позволяет выявить устойчивые сезонные и трендовые закономерности, а также оценить поведение остаточных компонент при использовании различных моделей, что создаёт прочную основу для последующего построения прогностических решений.

В настоящей работе представлены результаты сравнительного анализа различных методов декомпозиции временного ряда трафика сети LTE одного мобильного оператора за двухлетний период (2023–2024 гг.). В рамках исследования использовались следующие методы: STL (Seasonal-Trend decomposition using Loess), модель экспоненциального сглаживания Holt-Winters, а также метод классической сезонной декомпозиции Census I, реализованный в программном обеспечении Statistica. Основное внимание уделяется сравнительному анализу результатов декомпозиции временного ряда, включая сравнение выделенных трендов, сезонных колебаний и остаточных компонент.

Временной ряд может быть описан как последовательность значений какого-либо процесса $Y(t_i) = \{y_1, y_2, \dots, y_N\}$, в известные моменты времени $t_i = iT$, $i = 0, N$, T – временной интервал. Декомпозиция временного ряда заключается в выделении составляющих ряда

$$Y(t_i) = m_{t_i} + s_{t_i} + r_{t_i},$$

где m_{t_i} – тренд, s_{t_i} – сезонная компонента, r_{t_i} – случайная компонента (шум, остаток).

Для выявления долгосрочной тенденции изменения объёмов трафика сети LTE были построены трендовые компоненты временного ряда с использованием трёх методов: STL-декомпозиции, модели экспоненциального сглаживания Holt-Winters и процедуры декомпозиции, реализованной в программной среде Statistica. Каждый из методов позволил по-своему интерпретировать развитие нагрузки на сеть в течение двух календарных лет.

STL-декомпозиция применялась с сезонным периодом 90 дней, что позволило выявить динамику тренда с высокой степенью устойчивости к выбросам. Метод продемонстрировал гибкость в адаптации к структуре данных и обеспечил плавное поведение трендовой компоненты, отражающее постепенный рост сетевого трафика.

Модель Holt-Winters была реализована в аддитивной форме с сезонным периодом в 365 дней, соответствующим годовому циклу. Тренд выделялся как разность между аппроксимированным рядом и сезонной компонентой, после чего дополнительно сглаживался 30-дневным скользящим средним. Это позволило устранить резкие колебания, характерные для оригинальной аппроксимации, и сделать тренд более интерпретируемым.

В модели Census I трендовая составляющая рассчитывается с использованием метода скользящего среднего, что обеспечивает высокую степень сглаживания и устойчивость к локальным флуктуациям. Этот подход позволил выявить устойчивую и наглядную трендовую динамику, соответствующую общей тенденции роста трафика.

Для обеспечения наглядного сопоставления трендовые компоненты, полученные

методами STL, Holt-Winters и Census I, приведены на рисунке 1.



Рисунок 1 - Сравнение трендовых компонент временного ряда, полученных методами STL, Holt-Winters и Census I

Как видно из рисунка 1, тренды, рассчитанные с использованием методов STL, Holt-Winters и Census I, имеют различный характер монотонности, но демонстрируют устойчивый рост трафика на протяжении всего анализируемого периода. Тренд, полученный методом Holt-Winters, оказался более чувствительным к краткосрочным колебаниям и характеризовался повышенной вариативностью, несмотря на дополнительное сглаживание. Это указывает на потенциальные ограничения метода при работе с данными, содержащими выраженные сезонные и нерегулярные компоненты.

Сезонная компонента временного ряда отражает регулярные колебания трафика, обусловленные поведенческими и календарными факторами, такими как дни недели, месяцы, праздничные периоды и сезонные изменения в активности пользователей.

Для обеспечения сопоставимости и объективного сравнения все три сезонные компоненты были нормализованы по z-оценке (рисунок 2). Это позволило напрямую сопоставить форму и изменчивость сезонных колебаний, устранив влияние различий в масштабе.




Рисунок 2 - Нормализованные сезонные компоненты, полученные методами STL, Holt-Winters и Census I

Метод STL применялся с сезонным периодом 90 дней, что позволило выявить

укоренившиеся внутригодовые циклы и устойчиво сгладить нерегулярные колебания. Использование режима *robust* обеспечило высокую устойчивость к выбросам и позволило отразить реальную сезонную структуру трафика без искажений.

Модель Holt-Winters, использованная с сезонным периодом 365 дней, продемонстрировала выраженную годовую цикличность с высокой амплитудой. В отличие от STL, эта модель более чувствительна к краткосрочным флуктуациям и может усиливать локальные сезонные изменения, особенно в присутствии нерегулярных выбросов.

Сезонная компонента, полученная в Statistica, также демонстрирует характерные циклы, однако с заметно меньшей амплитудой. Это связано с особенностями метода сглаживания, реализованного в Statistica.

Дополнительно была проведена агрегация сезонных значений по календарным месяцам, что позволило выявить характерные паттерны на протяжении года (рисунок 3). Анализ месячных средних сезонностей показал, что метод Holt-Winters фиксирует выраженное увеличение трафика в летние месяцы (июнь–август), тогда как методы STL и Census I демонстрируют более сглаженную и сдержанную динамику. Сезонность по результатам STL имеет минимальные значения в апреле и июле, а максимумы — в марте и сентябре. Метод Census I показывает слабовыраженные колебания, что может быть связано с высокой степенью сглаживания. Таким образом, согласованность результатов наблюдается лишь частично, и только метод Holt-Winters отчётливо фиксирует летний пик сезонности.




Рисунок 3 - Средняя нормализованная сезонность по месяцам для трёх методов

Остаточная компонента временного ряда отражает те колебания, которые не были объяснены трендом или сезонностью. Её анализ позволяет оценить уровень случайных или нерегулярных флуктуаций, что особенно важно для понимания стабильности модели и потенциальных источников неопределённости в трафике мобильной сети.

В рамках анализа случайной составляющей ряда были выделены остатки на основе всех трёх методов. В каждом случае шум рассчитывался как разность между исходным временным рядом и суммой трендовой и сезонной компонент, полученных соответствующим методом. Остаточные компоненты были нормализованы по z-оценке (рисунок 4).




Рисунок 4 - Сравнение нормализованных остатков по методам STL, Holt-Winters и Census I

Метод STL обеспечил наиболее равномерное распределение остатков с относительно небольшой амплитудой и не демонстрирует большого количества выраженных выбросов. В случае модели Holt-Winters, несмотря на сглаживание тренда, остаточная компонента характеризуется резкими колебаниями и аномальными выбросами. Остатки, полученные с использованием Census I, имеют характерный шумовой профиль с низкой амплитудой, равномерно распределённой вдоль временного ряда. Это может быть следствием алгоритмического подавления нерегулярных колебаний или высокой степени сглаживания в процессе декомпозиции. Тем не менее, по форме и динамике остатки Census I демонстрируют схожий характер с результатами STL, подтверждая стабильность выделения структурных компонент. Сравнительный анализ показал, что наибольшую дисперсию шума показал метод Census I, в то время как наибольшую дисперсию продемонстрировала модель Holt-Winters.

Таким образом, проведённый анализ временного ряда трафика сети LTE на основе данных за 2023–2024 годы позволил выделить основные структурные компоненты – тренд, сезонность и остатки с использованием трёх подходов: STL-декомпозиции, модели Holt-Winters и метода, реализованного в Statistica. Сравнение результатов показало, что каждая из методик обладает своими преимуществами и ограничениями при работе с суточными данными мобильного трафика.

Сопоставление нормализованных компонент позволило не только визуализировать различия между результатами методов, но и выявить устойчивые закономерности в поведении рассматриваемого трафика. Результаты показали, что на протяжении исследуемого периода наблюдается устойчивый рост нагрузки на сеть, а также имеется наличие повторяющихся сезонных паттернов, которые должны быть учтены при прогнозировании. Полученные компоненты могут быть использованы в дальнейшем при построении прогнозных моделей, адаптированных к особенностям поведения пользователей и специфике мобильной сети.

СПИСОК ЛИТЕРАТУРЫ

1. Kumar A., Singh R. Time Series Decomposition and Forecasting of Mobile Network Traffic. // MPRA Paper No. 92727, 2019.
2. M. Zhang, H. Fu, Y. Li, S. Chen, Understanding urban dynamics from massive mobile traffic data // IEEE Trans. Big Data, vol. 5, no. 2, 2019. – P. 266–278.
3. Wang Y., Wang Y., Liu X., Zhang Y. A Deep Learning Approach for Mobile Traffic Forecasting in Cellular Networks. // IEEE Transactions on Vehicular Technology, Vol. 72, No. 3, 2023. – P. 3587–3598.

