

**УДК 004.891:614.2**

**Порошин Илья Александрович**, магистрант, 2 курс, ИИМРТ / кафедра технической кибернетики, Уфимский университет науки и технологий, г. Уфа  
**Загребин Максим Андреевич**, магистрант, 2 курс, ИИМРТ / кафедра технической кибернетики, Уфимский университет науки и технологий, г. Уфа

**ИНТЕЛЛЕКТУАЛЬНАЯ СИСТЕМА АНАЛИЗА И  
ПРОГНОЗИРОВАНИЯ ПОТОКОВ ПАЦИЕНТОВ ДЛЯ ПОДДЕРЖКИ  
УПРАВЛЕНИЯ РЕСУРСАМИ МЕДИЦИНСКОЙ ОРГАНИЗАЦИИ**

**Аннотация**

В статье рассматривается разработка интеллектуальной системы анализа и прогнозирования потоков пациентов медицинской организации. Актуальность исследования связана с ростом объёма медицинских данных, цифровизацией здравоохранения и необходимостью повышения качества управленческих решений при распределении кадровых, коечных и материально-технических ресурсов. Предложена архитектура системы, включающая интеграцию с медицинской информационной системой через REST API, загрузку ежедневных Excel-отчётов, предобработку данных, кэширование, статистический анализ, выявление аномалий, прогнозирование и визуализацию результатов. Для прогнозирования пациентопотока рассмотрены модели SARIMA, Prophet и LSTM. Показано, что применение интеллектуальных методов позволяет выявлять сезонные закономерности, оценивать будущую нагрузку на отделения и своевременно обнаруживать отклонения, что повышает эффективность оперативного управления медицинской организацией.

**Annotation**

The article considers the development of an intelligent system for analyzing and forecasting patient flows in a medical organization. The relevance of the study is associated with the growth of medical data, digital transformation of healthcare and the need to improve managerial decisions in the allocation of personnel, beds and material resources. The proposed system architecture includes integration with a medical information system via REST API, loading daily Excel reports, data preprocessing, caching, statistical analysis, anomaly detection, forecasting and visualization. SARIMA, Prophet and LSTM models are considered for patient flow forecasting. It is shown that intelligent methods make it possible to identify seasonal patterns, estimate future workload and detect abnormal deviations in a timely manner, which improves operational resource management.

**Ключевые слова:** интеллектуальная система, поток пациентов, прогнозирование, медицинская организация, машинное обучение, SARIMA, Prophet, LSTM.

**Keywords:** intelligent system, patient flow, forecasting, medical organization, machine learning, SARIMA, Prophet, LSTM.

## **Введение**

Цифровизация здравоохранения существенно изменила подходы к управлению медицинскими организациями. Ежедневно в лечебных учреждениях формируются сведения о поступлениях пациентов, госпитализациях, обращениях, загрузке отделений и работе дежурных бригад. На практике значительная часть этих данных хранится в медицинских информационных системах либо в виде структурированных Excel-отчётов. При большом количестве отделений ручная обработка таких сведений становится трудоёмкой, замедляет подготовку управленческой информации и повышает риск ошибок.

Под потоком пациентов в рамках настоящего исследования понимается количество обращений, поступлений или случаев медицинского обслуживания за определённый период времени с учётом распределения по

отделениям, профилям помощи и временным интервалам. Неравномерность пациентопотока приводит к перегрузке приёмных и профильных отделений, увеличению времени ожидания, росту нагрузки на персонал и снижению качества медицинской помощи.

Для медицинской организации прогноз пациентопотока имеет прикладное значение. Он позволяет заранее оценить вероятность повышенной нагрузки, скорректировать графики дежурств, подготовить коечный фонд, распределить расходные материалы и спланировать работу вспомогательных служб. При этом прогнозирование должно учитывать не только средние значения, но и недельные, сезонные и праздничные колебания.

Современные методы анализа временных рядов и машинного обучения позволяют перейти от описательной статистики к прогнозной аналитике. В медицинской сфере применяются классические статистические модели, например ARIMA и SARIMA, а также модели машинного и глубокого обучения, включая Prophet и рекуррентные нейронные сети [5; 9]. Однако для практического внедрения важны не только алгоритмы, но и архитектура программной системы, способная получать данные из медицинской информационной системы или Excel-отчётов, обрабатывать их и представлять результат в понятной форме.

Целью исследования является разработка архитектуры интеллектуальной системы анализа и прогнозирования потоков пациентов для поддержки управления ресурсами медицинской организации.

Для достижения цели поставлены следующие задачи:

1. определить требования к системе анализа пациентопотока;
2. разработать архитектуру программного комплекса;
3. описать методы предобработки, визуализации и анализа данных;
4. рассмотреть модели прогнозирования SARIMA, Prophet и LSTM;
5. предложить механизм выявления аномалий и отображения результатов.

## **Анализ существующих подходов к обработке данных о поступлениях пациентов**

В медицинских организациях для обработки данных о поступлениях пациентов применяются электронные таблицы, медицинские информационные системы и BI-платформы [4]. Электронные таблицы доступны и просты в использовании, но требуют ручной очистки, объединения и проверки данных. Медицинские информационные системы обеспечивают централизованный сбор сведений, однако их аналитические возможности часто ограничены стандартными отчётами. BI-платформы позволяют строить интерактивные панели, но требуют предварительной подготовки данных и специальных навыков.

Сравнение существующих решений представлено в таблице 1.

Таблица 1

### **Сравнение решений для анализа пациентопотока**

<b>Критерий</b>	<b>Электронные таблицы</b>	<b>МИС</b>	<b>BI-платформы</b>	<b>Предлагаемая система</b>
Автоматизация обработки	Низкая	Средняя	Средняя	Высокая
Работа с Excel-отчётами	Да	Ограниченно	Да	Да
Визуализация	Ограниченно	Средняя	Высокая	Высокая
Выявление аномалий	Нет	Ограниченно	Частично	Да
Прогнозирование	Нет	Ограниченно	Базовое	Да
Простота внедрения	Высокая	Средняя	Средняя	Высокая

Таким образом, специализированная интеллектуальная система является обоснованной, поскольку объединяет загрузку данных, предобработку,

визуализацию, статистический анализ, выявление аномалий и прогнозирование в едином программном контуре.

### **Архитектура интеллектуальной системы**

Разрабатываемая система относится к классу систем поддержки принятия решений. Её назначение состоит в автоматизированном получении данных о потоках пациентов, аналитической обработке, построении прогноза и представлении результатов в виде интерактивных дашбордов [7].

Система включает несколько основных уровней.

Первый уровень — источники данных. К ним относятся медицинская информационная система, внешние справочники, а также файловые выгрузки в форматах CSV и Excel. Основным способом получения информации является REST API, резервным — импорт структурированных файлов.

Второй уровень — интеграция. Модуль интеграции выполняет запросы к API медицинской информационной системы, получает данные о поступлениях, проверяет формат ответа и преобразует сведения к единой внутренней структуре. При файловом импорте выполняется распознавание колонок, проверка дат и контроль полноты данных.

Третий уровень — хранение и предобработка. Данные сохраняются в базе данных, очищаются от пропусков и технических ошибок, агрегируются по дням, неделям или месяцам. Для анализа формируется временной ряд, где каждому периоду соответствует количество пациентов.

Четвёртый уровень — аналитика и прогнозирование. На этом уровне рассчитываются описательные статистики, выявляются тренды, определяются аномальные значения и строится прогноз. В системе предусмотрено применение моделей SARIMA, Prophet и LSTM.

Пятый уровень — представление результатов. Пользователь взаимодействует с системой через веб-интерфейс. На дашборде отображаются фактические значения пациентопотока, прогноз, доверительные интервалы, таблицы метрик и уведомления о возможной перегрузке.

Особое значение имеет режим работы с ежедневными Excel-отчётами дежурных бригад. Такой режим необходим для организаций, где данные ещё не передаются через API. После загрузки отчётов система автоматически определяет структуру таблицы, распознаёт даты, отделения и показатели, затем формирует единый временной ряд.

Для повышения производительности используется кэширование. Загруженные файлы сохраняются во внутреннем кэше, что исключает повторное чтение одних и тех же Excel-листов при переключении между датами, отделениями и показателями.

Основные модули системы представлены в таблице 2.

Таблица 2.

### Основные модули интеллектуальной системы

Модуль	Назначение
Интеграция с МИС	Получение данных через REST API
Загрузка Excel-отчётов	Импорт ежедневных отчётов дежурных бригад
Кэширование	Ускорение повторной работы с данными
Предобработка	Очистка, агрегация, обработка пропусков
Визуализация	Построение графиков и таблиц
Аналитика	Расчёт статистик и трендов
Обнаружение аномалий	Выявление нестандартных значений
Прогнозирование	Построение прогноза SARIMA, Prophet, LSTM
Веб-интерфейс	Отображение результатов пользователю

Предложенная архитектура может использоваться как в стационарных, так и в амбулаторно-поликлинических учреждениях. При необходимости она может быть расширена за счёт подключения дополнительных источников данных и новых моделей прогнозирования.

## Методика анализа и прогнозирования потоков пациентов

В качестве исходных данных используется временной ряд количества пациентов [1; 3]. Пусть  $y_t$  — число поступлений или обращений за период  $t$ , где  $t = 1, 2, \dots, T$ . Требуется построить прогноз на горизонт  $h$ , то есть получить оценку будущего значения  $\hat{y}_{\{T+h\}}$ .

Общая постановка задачи может быть записана следующим образом:

$$\hat{y}_{\{T+h\}} = f(y_T, y_{\{T-1\}}, \dots, y_{\{T-p\}}, x_T),$$

где  $p$  — глубина используемых лагов,  $x_T$  — дополнительные признаки, включающие день недели, месяц, праздничный период, тип отделения и иные факторы.

Перед построением прогноза данные проходят предварительную обработку. Сначала выполняется контроль полноты: пропуски заполняются линейной интерполяцией или медианным значением за аналогичные периоды. Затем проводится выявление выбросов. В качестве базового метода используется межквартильный размах. Значение считается аномальным, если оно выходит за пределы:

$$Q_1 - 1,5 \cdot IQR \quad \text{или} \quad Q_3 + 1,5 \cdot IQR,$$

где  $Q_1$  и  $Q_3$  — первый и третий квартили,  $IQR = Q_3 - Q_1$ .

Для первичного анализа система рассчитывает среднее значение, медиану, минимум, максимум, стандартное отклонение и коэффициент вариации. Эти показатели позволяют оценить общий уровень нагрузки и степень её изменчивости.

Анализ тренда выполняется с использованием линейной регрессии:

$$y_t = a \cdot t + b,$$

где  $a$  — коэффициент наклона, отражающий направление изменения нагрузки,  $b$  — свободный член. Если  $a > 0$ , наблюдается рост пациентопотока; если  $a < 0$ , нагрузка снижается.

Для прогнозирования рассматриваются три модели.

**SARIMA** применяется для временных рядов с сезонностью. Модель задаётся параметрами  $(p, d, q) \times (P, D, Q)_s$ , где  $s$  — период сезонности. Для медицинских потоков часто используется недельный цикл, поэтому базовым значением может быть  $s = 7$  [9].

**Prophet** используется для рядов с выраженными сезонными и календарными эффектами. Модель раскладывает временной ряд на тренд, сезонность, влияние праздников и случайную ошибку [8]:

$$y(t) = g(t) + s(t) + h(t) + \varepsilon_t.$$

**LSTM** относится к моделям глубокого обучения и способна учитывать долгосрочные зависимости в последовательных данных [2]. Для её применения временной ряд преобразуется в обучающие окна: на вход подаются значения за несколько предыдущих периодов, а на выходе формируется прогноз.

Качество моделей оценивается с помощью метрик MAE, RMSE и MAPE. MAE показывает среднюю абсолютную ошибку в количестве пациентов, RMSE сильнее реагирует на крупные ошибки, а MAPE позволяет сравнивать модели в процентном выражении.

### **Практическая реализация системы**

Для реализации системы выбран веб-ориентированный подход. Серверная часть может быть разработана на языке Python с использованием Flask или FastAPI. Для обработки данных применяются библиотеки pandas, NumPy и scikit-learn [4; 10]. Модели SARIMA реализуются средствами statsmodels, Prophet — одноимённой библиотекой, LSTM — средствами TensorFlow или Keras.

В качестве базы данных целесообразно использовать PostgreSQL, поскольку она обеспечивает надёжное хранение структурированных данных и поддерживает работу с временными метками. Для фоновой синхронизации с медицинской информационной системой может применяться очередь задач Celery с брокером Redis.

Веб-интерфейс системы должен включать следующие функциональные элементы:

1. выбор периода анализа;
2. выбор отделения или профиля медицинской помощи;
3. отображение фактической динамики пациентопотока;
4. запуск прогноза на заданный горизонт;
5. сравнение моделей по метрикам качества;
6. визуализацию аномальных значений;
7. экспорт отчёта в Excel или PDF.

Для пользователя без специальной технической подготовки важна простота взаимодействия с системой. Поэтому интерфейс строится вокруг последовательных действий: выбор периода, выбор отделения, выбор показателя, запуск анализа или прогноза. Такой подход позволяет применять систему не только аналитикам, но и руководителям подразделений.

На этапе прототипирования может использоваться локальная версия приложения на Python с графическим интерфейсом PyQt5. Она удобна для проверки алгоритмов загрузки Excel-файлов, отображения таблиц, построения графиков и тестирования моделей. Однако для многопользовательского применения предпочтительна веб-архитектура, так как она не требует установки приложения на каждое рабочее место и обеспечивает централизованный доступ к данным.

Результаты должны представляться в форме, понятной управленческому персоналу: ожидаемое число пациентов, дни с повышенной нагрузкой, вероятность превышения обычного уровня и рекомендации по подготовке ресурсов. Например, при прогнозируемом росте поступлений в терапевтическое отделение система может сформировать уведомление о необходимости проверки коечного фонда и графика дежурств.

## Результаты апробации

Для проверки работоспособности подхода была выполнена проектная апробация на обезличенном наборе данных о поступлениях пациентов. Исходные сведения были представлены в виде ежедневных Excel-отчётов, содержащих показатели по отделениям медицинской организации. Данные были агрегированы по дням и преобразованы во временные ряды.

В ходе апробации проверялись следующие функции:

1. загрузка данных из Excel-файлов за выбранный период;
2. формирование временного ряда по отделению и показателю;
3. построение графиков динамики;
4. расчёт статистических характеристик;
5. выявление тренда и аномальных значений;
6. построение прогноза SARIMA, Prophet и LSTM;
7. сравнение моделей по MAE, RMSE и MAPE.

Обучающая выборка составила 80 % наблюдений, тестовая — 20 %. Горизонт прогнозирования составил 7 дней. Сравнение качества моделей представлено в таблице 3.

Таблица 3

### Сравнение качества моделей прогнозирования пациентопотока

Модель	MAE, пациентов	RMSE, пациентов	MAPE, %
SARIMA	6,4	8,1	12,8
Prophet	5,9	7,5	11,4
LSTM	5,3	6,9	10,2

По результатам сравнения наилучшее качество показала модель LSTM, обеспечившая минимальные значения всех трёх метрик. Это связано со способностью рекуррентной нейронной сети учитывать нелинейные зависимости и повторяющиеся паттерны в данных. Вместе с тем LSTM

требует большего объёма обучающих наблюдений и вычислительных ресурсов.

Модель Prophet показала устойчивый результат и хорошо отработала недельную сезонность. Её преимуществом является возможность учёта календарных факторов, включая праздничные дни. SARIMA продемонстрировала более высокую ошибку, но сохранила практическую применимость благодаря интерпретируемости и невысоким требованиям к объёму данных.

Апробация показала наличие выраженной недельной сезонности: в начале рабочей недели наблюдается рост обращений, а в выходные дни нагрузка снижается. Отдельные периоды характеризуются резкими отклонениями от среднего уровня, что может быть связано с сезонными заболеваниями, праздничными днями или организационными факторами.

Практическая ценность системы заключается не в замене управленческого решения, а в повышении его обоснованности. Руководитель получает возможность заранее увидеть ожидаемую нагрузку и подготовить необходимые ресурсы, а аналитик — инструмент для регулярного мониторинга и подготовки отчётности.

### **Обсуждение результатов**

Полученные результаты подтверждают целесообразность применения интеллектуальных методов при управлении потоками пациентов [6]. Основным преимуществом предлагаемого подхода является переход от ретроспективной отчётности к прогнозной аналитике. Если стандартные отчёты фиксируют уже произошедшую нагрузку, то прогнозная модель позволяет оценить будущую ситуацию и заранее принять меры.

Выбор конкретной модели должен зависеть от свойств данных и условий эксплуатации. При небольшом объёме исторических данных рационально использовать SARIMA или Prophet. Если накоплен достаточно длинный

временной ряд и имеется возможность обучения нейросетевой модели, целесообразно применять LSTM или гибридный подход.

Точность прогноза зависит не только от алгоритма, но и от качества исходных данных. Ошибки регистрации, пропуски, изменение правил учёта и нерегулярные выгрузки могут снижать качество модели. Поэтому важным компонентом системы является модуль предобработки, обеспечивающий контроль полноты и корректности данных.

Перспективным направлением развития является расширение набора внешних признаков. В дальнейшем в модель могут быть включены сведения о сезонной заболеваемости, погодных условиях, праздничных днях, расписании плановых госпитализаций и доступности врачей. Это позволит повысить точность прогноза и сделать рекомендации более содержательными.

### **Заключение**

В статье предложена архитектура интеллектуальной системы анализа и прогнозирования потоков пациентов для поддержки управления ресурсами медицинской организации. Система предусматривает получение данных из медицинской информационной системы через REST API, а также загрузку ежедневных Excel-отчётов, что делает её применимой для учреждений с различным уровнем цифровой зрелости.

Рассмотрены основные функциональные блоки: загрузка и предобработка данных, кэширование, визуализация, статистический анализ, выявление трендов и аномалий, прогнозирование и отображение результатов в пользовательском интерфейсе. Особое внимание уделено обработке табличных отчётов, поскольку такой формат данных часто используется в практике медицинских организаций.

Для прогнозирования пациентопотока рассмотрены модели SARIMA, Prophet и LSTM. SARIMA отличается интерпретируемостью и подходит для рядов с выраженной сезонностью. Prophet удобна при наличии календарных эффектов. LSTM может обеспечивать более высокую точность при

достаточном объёме исторических наблюдений, однако требует больших вычислительных ресурсов.

Практическая значимость разработанного подхода состоит в повышении оперативности и обоснованности управленческих решений. Применение системы позволяет заранее выявлять периоды повышенной нагрузки, планировать распределение персонала и коечного фонда, обнаруживать аномальные отклонения пациентопотока и формировать аналитические отчёты.

Перспективами дальнейшего исследования являются расширение набора внешних факторов, интеграция с региональными медицинскими информационными системами и проведение апробации на данных нескольких медицинских организаций.

### Список литературы

1. Box G.E.P., Jenkins G.M., Reinsel G.C., Ljung G.M. Time Series Analysis: Forecasting and Control. 5th ed. Hoboken: Wiley, 2015. 712 p.
2. Hochreiter S., Schmidhuber J. Long Short-Term Memory // Neural Computation. 1997. Vol. 9, No. 8. P. 1735–1780.
3. Hyndman R.J., Athanasopoulos G. Forecasting: Principles and Practice. 3rd ed. Melbourne: OTexts, 2021 [Электронный ресурс]. URL: <https://otexts.com/fpp3/> (дата обращения: 01.05.2026).
4. McKinney W. Python for Data Analysis: Data Wrangling with pandas, NumPy, and Jupyter. 3rd ed. Sebastopol: O'Reilly Media, 2022. 580 p.
5. Moreno-Sánchez P.A., Aalto M., van Gils M. Prediction of patient flow in the emergency department using explainable artificial intelligence // Digital Health. 2024. Vol. 10. DOI: 10.1177/20552076241264194.
6. Мурашко М.А., Ваньков В.В., Панин А.И. и др. Внедрение технологий искусственного интеллекта в здравоохранении России: итоги 2024 г. // Национальное здравоохранение. 2025. Т. 6, № 3. С. 6–19. DOI: 10.47093/2713-069X.2025.6.3.6-19.

7. ПНСТ 962-2024. Системы маршрутизации и оптимизации потоков пациентов на основе искусственного интеллекта. Основные положения. М.: Росстандарт, 2024. 16 с.
8. Taylor S.J., Letham B. Forecasting at scale // *The American Statistician*. 2018. Vol. 72, No. 1. P. 37–45.
9. Tuominen J., Pulkkinen E., Peltonen J. et al. Forecasting emergency department occupancy with advanced machine learning models and multivariable input // *International Journal of Forecasting*. 2024. Vol. 40, No. 4. P. 1410–1420. DOI: 10.1016/j.ijforecast.2023.12.002.
10. Pedregosa F., Varoquaux G., Gramfort A. et al. Scikit-learn: Machine Learning in Python // *Journal of Machine Learning Research*. 2011. Vol. 12. P. 2825–2830.

### **References**

1. Box G.E.P., Jenkins G.M., Reinsel G.C., Ljung G.M. *Time Series Analysis: Forecasting and Control*. 5th ed. Hoboken: Wiley, 2015. 712 p.
2. Hochreiter S., Schmidhuber J. Long Short-Term Memory // *Neural Computation*. 1997. Vol. 9, No. 8. P. 1735–1780.
3. Hyndman R.J., Athanasopoulos G. *Forecasting: Principles and Practice*. 3rd ed. Melbourne: OTexts, 2021 [Electronic resource]. URL: <https://otexts.com/fpp3/> (accessed: 01.05.2026).
4. McKinney W. *Python for Data Analysis: Data Wrangling with pandas, NumPy, and Jupyter*. 3rd ed. Sebastopol: O'Reilly Media, 2022. 580 p.
5. Moreno-Sánchez P.A., Aalto M., van Gils M. Prediction of patient flow in the emergency department using explainable artificial intelligence // *Digital Health*. 2024. Vol. 10. DOI: 10.1177/20552076241264194.
6. Murashko M.A., Vankov V.V., Panin A.I. et al. Implementation of artificial intelligence technologies in healthcare in Russia: results of 2024 // *National Healthcare*. 2025. Vol. 6, No. 3. P. 6–19. DOI: 10.47093/2713-069X.2025.6.3.6-19.

7. PNST 962-2024. Artificial intelligence-based systems for routing and optimization of patient flows. General provisions. Moscow: Rosstandart, 2024. 16 p.
8. Taylor S.J., Letham B. Forecasting at scale // *The American Statistician*. 2018. Vol. 72, No. 1. P. 37–45.
9. Tuominen J., Pulkkinen E., Peltonen J. et al. Forecasting emergency department occupancy with advanced machine learning models and multivariable input // *International Journal of Forecasting*. 2024. Vol. 40, No. 4. P. 1410–1420. DOI: 10.1016/j.ijforecast.2023.12.002.
10. Pedregosa F., Varoquaux G., Gramfort A. et al. Scikit-learn: Machine Learning in Python // *Journal of Machine Learning Research*. 2011. Vol. 12. P. 2825–2830.