

КОМПЬЮТЕРНОЕ МОДЕЛИРОВАНИЕ COMPUTER SIMULATION HISTORY

УДК 004.942

DOI 10.52575/2687-0932-2024-51-3-643-656

Моделирование и прогнозирование показателей динамики заболевания жителей Красноярского края коронавирусом COVID-19 на примере отдельного ЛПУ

¹ Шеломенцева И.Г., ² Ченцов С.В., ¹ Краснораменская И.С.

¹ Красноярский государственный медицинский университет им. проф. В.Ф. Войно-Ясенецкого
Россия, 660022, г. Красноярск, ул. Партизана Железняка, 1

² Сибирский федеральный университет
Россия, 660041, Красноярск, проспект Свободный, 79
E-mail: inga.shell@yandex.ru

Аннотация. Принятие обоснованных решений в здравоохранении требует наличия информации о распространении эпидемий. Большинство существующих моделей прогнозирования распространения COVID-19 фокусируются на национальном или региональном уровне, данное исследование предлагает решение для прогнозирования на уровне отдельных лечебно-профилактических учреждений (ЛПУ). Целью данного исследования является разработка и оценка точности моделей прогнозирования динамики ключевых локальных показателей распространения COVID-19 на уровне отдельного лечебно-профилактического учреждения, которые позволят оптимизировать распределение медицинских ресурсов. В работе использованы методы регрессионного анализа, экспоненциального сглаживания, долгосрочной кратковременной памяти (LSTM), деревья решений XGBoost, модель Prophet. Для построения моделей использованы данные о заболеваемости коронавирусом Красноярской краевой больницы с марта 2020 по декабрь 2023. Исследованные модели позволяют оценить динамику распространения коронавирусной инфекции в отдельно взятом лечебно-профилактическом учреждении, что позволит использовать технологии балансировки нагрузки и распределения ресурсов как внутри лечебно-профилактического учреждения, так и между другими ЛПУ.

Ключевые слова: COVID-19, регрессионная модель, экспоненциальные модели, библиотека Prophet, LSTM, машинное обучение, прогнозирование

Для цитирования: Шеломенцева И.Г., Ченцов С.В., Краснораменская И.С. 2024. Моделирование и прогнозирование показателей динамики заболевания жителей Красноярского края коронавирусом COVID-19 на примере отдельного ЛПУ. Экономика. Информатика, 51(3): 643–656. DOI 10.52575/2687-0932-2024-51-3-643-656

Modeling and Forecasting of COVID-19 Dynamics in Krasnoyarsk Krai Residents Using a Single Healthcare Institution as an Example

¹ Inga G. Shelomentseva, ² Sergej V. Chentsov, ¹ Irina S. Krasnoramenskaja

¹ Prof. V.F. Voino-Yasenetsky Krasnoyarsk State Medical University
1 Partizan Zheleznyak ave, Krasnoyarsk 660022, Russia

² Siberian Federal University, 79 Svobodny ave, Krasnoyarsk 660041, Russia
E-mail: inga.shell@yandex.ru

Abstract. Making informed decisions in healthcare requires information about the spread of epidemics. While most existing models for forecasting COVID-19 spread focus on national or regional levels, this

study proposes a solution for prediction at the level of individual healthcare institutions (LHIs). The aim of this research is to develop and evaluate the accuracy of models that predict the dynamics of key local indicators of COVID-19 spread within a single LHI, ultimately aiding in optimizing the allocation of medical resources. This research employs methods of regression analysis, exponential smoothing, long short-term memory (LSTM), XGBoost decision trees, and the Prophet model. Data on COVID-19 cases from the Krasnoyarsk Regional Hospital from March 2020 to December 2023 was utilized for model construction. The investigated models allow for assessing the dynamics of coronavirus infection within a single LHI, enabling the implementation of load balancing and resource allocation technologies both within the LHI and across other LHIs.

Keywords: COVID-19, Regression model, Exponential models, Prophet library, LSTM, Machine learning, Forecasting

For citation: Shelomentseva I.G., Chentsov S.V., Krasnoramenskaja I.S. 2024. Modeling and Forecasting of COVID-19 Dynamics in Krasnoyarsk Krai Residents Using a Single Healthcare Institution as an Example. *Economics. Information technologies*, 51(3): 643–656. DOI 10.52575/2687-0932-2024-51-3-643-656

Введение

Использование математических моделей позволяет прогнозировать спрос на разнообразные ресурсы в системах здравоохранения с учетом эпидемиологических процессов, демографических изменений и обеспечивает эффективное управление ресурсами. Среди методов оптимизации медицинских ресурсов можно выделить статистические методы, имитационные модели и системы балансировки нагрузки, исходя из локальных моделей прогнозирования. Статистические модели, опирающиеся на официальные статистические данные и применяющие разнообразные математические и статистические методы для их обработки, отличаются проверенными временем методиками, обеспечивающими достоверность и надежность прогнозов. Однако их зависимость от данных прошлых периодов снижает эффективность в периоды пандемий и эпидемиологических вспышек [Омельяновский и др., 2020]. Имитационные модели, применяемые для оптимизации бизнес-процессов путем имитации объектов или процессов, отличаются долговечностью и точностью прогнозов, но требуют значительных вычислительных ресурсов и основательной подготовки, включающей в себя несколько подходов [Шалаева, 2020]. Системы балансировки нагрузки основаны на технологии балансировки с интегрированными графами и выбранным ядром оптимизации, что делает их универсальными и применимыми к любым ресурсам [Lacasa, 2020]. Однако методика не гарантирует нахождения абсолютного оптимального решения, так как не охватывает все возможные варианты.

При этом для задач краткосрочного и среднесрочного прогнозирования развития маркетинговых, экономических и эпидемиологических ситуаций широко используются модели временных рядов [Захаров, Балыкина, 2021]. Например, модели временных рядов успешно применяются для прогнозирования развития инфекционных заболеваний сезонного гриппа [Adhikari, Agrawal, 2013; Yin et al., 2020; Lee, Agrawal, Choudhary, 2017], для прогнозирования развития течения ковидной инфекции [Hu et al., 2020; Fanelli, Piazza, 2020; Petropoulos, Makridakis, 2020].

В качестве моделей и методов временных рядов при этом используются статистические методы для предсказания количества смертей, количества коек и аппаратов интенсивной терапии [IHME COVID-19 Forecasting Team, 2021], методы экспоненциального сглаживания для предсказания количества смертей от COVID-19 [Petropoulos, Makridakis, 2020], сети LSTM, модели линейной регрессии и XBoost [Zhang et al., 2021], методы обработки временных рядов Facebook's Prophet [Taylor, 2018].

В отличие от большинства моделей, прогнозирующих распространение COVID-19 на уровне стран или регионов, данное исследование предлагает подход, позволяющий прогнозировать распространение инфекции на уровне конкретных лечебно-

профилактических учреждений (ЛПУ). В условиях пандемии коронавируса остро встала задача оптимизации использования медицинских ресурсов. Для принятия обоснованных решений требуется глубокое понимание динамики распространения вируса. Исследование направлено на моделирование этой динамики на локальном уровне, анализируя ключевой показатель распространения эпидемии – количество заболевших.

Материалы и методы

В качестве материалов исследования выступают данные о заболеваемости новой коронавирусной инфекцией (COVID-19) КГБУЗ ККБ № 2, поликлиники № 2 в период с марта 2020 года до декабря 2023 года. Данные были взяты из таблицы NASA, расположенной на портале КГБУЗ ККБ № 2, доступ к которой имеется у всех медицинских работников данной организации. Данные ведутся с момента регистрации первых заболевших новой коронавирусной инфекцией с марта 2020 года по сегодняшний день.

Данные выгружаются в общедоступную для медицинских работников данной организации таблицу NASA, в которой отображаются данные о заболевшем – ФИО, дата рождения, ФИО и дата рождения контактных, адрес фактического места проживания, дата забора мазка, номер мазка, дата открытия листа нетрудоспособности, при его наличии, исход заболевания – выздоровление, госпитализация, смерть. Пациенты, госпитализированные в стационар, выделяются в таблице цветом.

Забор мазка на COVID-19 осуществляется у любого пациента, обратившегося с симптомами ОРВИ. В основном это происходит в условиях кабинета неотложной помощи, либо бригадой СМП, которая выезжает на вызовы к пациентам с признаками ОРВИ. За каждым пациентом, у которого лабораторно подтверждено заболевание, устанавливается дистанционное наблюдение на 7 дней с момента забора мазка на НКВИ.

Исходные данные в периоде с марта 2020 по декабрь 2023 визуализированы на рис. 1 в виде графика динамики заболеваемости, на котором можно наблюдать несколько волн коронавирусной инфекции среди пациентов Красноярской краевой клинической больницы.




Рис. 1. График заболеваемости коронавирусной инфекцией пациентов Красноярской краевой клинической больницы в динамике
Fig. 1. Graph of the incidence of coronavirus infection in patients of the Krasnoyarsk Regional Clinical Hospital in dynamics

Математические модели на базе временных рядов характеризуются тем, что объект исследования упорядочен во времени, а класс решаемых задач представлен задачами классификации и прогнозирования (1). Преимуществом использования моделей временных рядов является получение дополнительных сведений об объекте за счет упорядочения информации во временной шкале, недостатком их использования – ограниченность данных, которые должны быть измерены строго последовательно и в одинаковых промежутках времени.

$$y_{T+d} = f(y_0, y_1, \dots, y_T, \theta, d), \quad (1)$$

где

y_0, y_1, \dots, y_T – действительные значения объекта исследования, измеренные через одинаковый временной интервал;

θ – параметры модели временного ряда;

D – горизонт прогнозирования, $d \in 1 \dots D$.

Основными понятиями теории временных рядов являются понятия тренда, сезонности, цикла, шума и стационарности. Тренд – это долгосрочная устойчивая тенденция, которая показывает общее направление изменения данных с течением времени. Сезонность – параметр, который отражает периодические колебания в данных – ежедневные, еженедельные, месячные или годовые. Понятие цикла отличается от понятия сезонности тем, что отражает долгосрочные изменения во временных рядах, длительностью от нескольких лет, до нескольких десятилетий. Шум – это случайный компонент в данных, который не имеет никакой закономерности, причиной которого могут быть ошибки или неучтенные факторы. Стационарность – это свойство временного ряда, когда его среднее значение и дисперсия остаются постоянными со временем. В стационарном временном ряду отсутствует тренд (линейное или нелинейное изменение среднего значения ряда со временем), сезонность и изменение дисперсии ряда [Криворотько и др., 2020].

При использовании регрессионных моделей на основе авторегрессии и автокорреляции большое значение имеет стационарность исследуемого ряда данных. Стационарность временного ряда можно проверить с помощью различных методов. Первым из них является визуальный анализ, при котором необходимо построить график ряда и оценить наличие тренда или изменения дисперсии. Другой метод – использование статистических тестов, таких как тесты Дики – Фуллера (Dickey-Fuller test), тест КПСС (KPSS test) и тест Адфулла (Augmented Dickey-Fuller test), которые проверяют стационарность временного ряда по наличию единичных корней. Также эффективным методом является разложение ряда на тренд и остатки: если остатки не обнаруживают систематического поведения, то это может указывать на стационарность ряда. Наконец, расчёт статистических метрик, таких как среднее и дисперсия по разным подинтервалам, поможет определить постоянство этих характеристик с течением времени и, соответственно, стационарность ряда [Криворотько и др., 2020]. В случае, если временной ряд не является стационарным, можно применить различные методы преобразования, например, дифференцирование или логарифмирование, преобразование Фурье.

Существует три основных подхода к прогнозированию временных рядов: модели фильтрации, которые включают вейвлет-декомпозицию, экспоненциальное сглаживание, модель Хольта – Винтерса и фильтр Калмана, регрессионные модели, которые включают модели ARIMA, SARIMA, ARMA, модель Серфлинга, модели машинного обучения, которые включают байесовские сети, основанные на скрытых марковских моделях, и рекуррентные нейронные сети [Криворотько и др., 2020]. Анализ литературы определяет еще несколько моделей, используемых авторами для прогнозирования на базе временных рядов – модели линейной регрессии и XBoost, библиотеку временных рядов Prophet.

Среди моделей фильтрации в исследовании представлены модели экспоненциального сглаживания и модель Хольта – Винтерса. Для расчета простой скользящей средней для

расчета следующего члена ряда используется среднее от предыдущих n значений (2). Для расчета взвешенной скользящей средней используется формула для расчета простой скользящей средней, при этом наблюдениям придаются разные весовые коэффициенты, которые в сумме дают 1, и более поздние наблюдения имеют больший вес. Такой подход отражает точку зрения, при которой более поздние наблюдения более актуальны при построении тренда, нежели более ранние (3):

$$\hat{y}_t = \frac{1}{k} \sum_{n=0}^{k-1} y_{t-n}, \quad (2)$$

$$\hat{y}_t = \sum_{n=1}^k w_n y_{t-n}, \quad (3)$$

где

\hat{y}_t – прогнозируемое значение временного ряда;

y_t – текущее значение временного ряда;

w_n – вес слагаемого временного ряда, чем более позднее наблюдение, тем выше весовой коэффициент.

Расширением взвешенной скользящей средней является экспоненциальное сглаживание, при котором учитываются все наблюдения, и веса уменьшаются экспоненциально, начиная с самых поздних (4) [Wei et al., 2023]

$$\hat{y}_t = \alpha * y_t + (1 - \alpha) * \hat{y}_{t-1}, \quad (4)$$

где

\hat{y}_t – прогнозируемое значение временного ряда;

\hat{y}_{t-1} – предыдущее модельное значение;

y_t – текущее значение временного ряда;

α – вес, который определяет скорость экспоненциального сглаживания – чем меньше альфа, тем сильнее сглаживается ряд.

Кроме экспоненциального сглаживания существует двойное и тройное экспоненциальное сглаживание. При двойном экспоненциальном сглаживании для предсказания, кроме уровня ряда l , используется еще одна компонента – тренд b (5)-(7). При тройном экспоненциальном сглаживании, кроме уровня ряда l и тренда b , используется сезонная компонента – сезонность s [Wei et al., 2023]. Сезонность характеризуется периодом – временем, по прошествии которого начинаются повторения колебаний:

$$l_t = \alpha y_t + (1 - \alpha)(l_{t-1} + b_{t-1}), \quad (5)$$

$$b_t = \beta(l_t - l_{t-1}) + (1 - \beta)b_{t-1}, \quad (6)$$

$$\hat{y}_t = l_t + b_t, \quad (7)$$

где

\hat{y}_t – прогнозируемое значение временного ряда;

l_t – текущее значение временного ряда;

b_t – текущее значение тренда временного ряда;

α и β – веса экспоненциального сглаживания.

Расширением подхода экспоненциального сглаживания является модель Хольта – Винтерса (Holt-Winters), которая для прогнозирования использует компонент уровня ряда α , компонент тренда b и компонент сезонности s (8)-(10) [Xian et al., 2023]. Компонент сезонности характеризуется длиной периода, после которого начинают повторяться колебания временного ряда.

$$\hat{y}_{min_z} = \alpha_{z-1} + b_{z-1} + s_{z-T} - m \cdot d_{t-T}, \quad (8)$$

$$\hat{y}_{min_z} = \alpha_{z-1} + b_{z-1} + s_{z-T} + m \cdot d_{t-T}, \quad (9)$$

$$d_t = \gamma |y_t - \hat{y}_t| + (1 - \gamma)d_{t-T}, \quad (10)$$

где T – длина сезона, d – предсказанное отклонение.

Кроме статистического подхода, используются регрессионные модели AR(p) – модель авторегрессии с параметром лага p , MA(q) – модель регрессии со скользящим средним с порядком скользящего окна q , ARMA(p,q) – модель регрессии с параметром лага p и s

порядком скользящего окна q , SARMA(p, q, P, Q) – модель ARMA с добавлением сезонных авторегрессионных компонент P и сезонных компонент Q , модель ARIMA, включающая в себя кроме вышеописанных компонент порядок разности d и использующая (11)-(14) [Xian et al., 2023]

$$y_t = \alpha + \theta_1 y_{t-1} + \theta_2 y_{t-2}, \dots, \theta_p y_{t-p} + \varepsilon_t, \quad (11)$$

$$y_t = \alpha + \gamma_1 \varepsilon_{t-1} + \gamma_2 \varepsilon_{t-2}, \dots, \gamma_p \varepsilon_{t-p} + \varepsilon_t, \quad (12)$$

$$y_t = \alpha + \theta_1 y_{t-1} + \theta_2 y_{t-2}, \dots, \theta_p y_{t-p} + \gamma_1 \varepsilon_{t-1} + \gamma_2 \varepsilon_{t-2}, \dots, \gamma_p \varepsilon_{t-p} + \varepsilon_t, \quad (13)$$

$$y_t = \alpha + \theta_1 y_{t-1} + \theta_2 y_{t-2}, \dots, \theta_p y_{t-p} + \theta_{s1} y_{t-s} + \theta_{s2} y_{t-2s}, \dots, + \theta_{ps} y_{t-ps} + \gamma_1 \varepsilon_{t-1} + \gamma_2 \varepsilon_{t-2}, \dots, \gamma_p \varepsilon_{t-p} + \gamma_s \varepsilon_{t-s} + \gamma_{2s} \varepsilon_{t-2s}, \dots, \gamma_{qs} \varepsilon_{t-qs} + \varepsilon_t, \quad (14)$$

$\alpha, \theta_i, \gamma_i$ – параметры модели.

ARIMA, или AutoRegressive Integrated Moving Average, представляет собой метод прогнозирования будущих тенденций на основе исторических данных временных рядов. Эта модель является регрессионным анализом, где каждая буква в названии ARIMA имеет определенное значение: AR (AutoRegressive) – этот компонент модели учитывает влияние предыдущих значений переменной на ее текущее значение, I (Integrated) – этот компонент подразумевает применение дифференцирования к исходным данным, что преобразует временной ряд в стационарный, MA (Moving Average) – этот компонент моделирует зависимость между текущим наблюдением и ошибками модели скользящего среднего, которая представляет собой среднее значение предыдущих ошибок [Xian et al., 2023]. Для проверки стационарности ряда в рамках исследования использовался тест Дики – Фуллера, а для преобразования ряда в стационарный ряд – преобразование Бокса-Кокса.

Сеть LSTM (Long Short-Term Memory – долговременная краткосрочная память) является рекуррентной нейронной сетью, предназначенной для фиксации долгосрочных зависимостей в последовательных данных [Luo et al., 2021]. Сети LSTM состоят из ячеек, которые имеют специальную структуру и отвечают за долговременное хранение информации. Ячейка памяти сети LSTM включает в себя три вида вентилях: входной клапан контролирует входной поток информации в базовую ячейку, клапан забывания контролирует процесс сброса информации, выходные ворота контролируют поток долгосрочной информации, который выходит из ячейки памяти. Выходной сигнал клапанов лежит в диапазоне от 0 до 1, где 0 означает блокировку, а 1 – полное прохождение информации через клапан – (15)-(18). Преимуществами сетей LSTM является улучшенная способность изучать последовательные и долгосрочные зависимости. Недостатками сетей LSTM является вычислительная сложность и вероятность переобучения

$$f_t = \sigma(\omega_f \cdot [h_{t-1}, x_t] + b_f), \quad (15)$$

$$i_t = \sigma(\omega_i \cdot [h_{t-1}, x_t] + b_i), \quad (16)$$

$$o_t = \sigma(\omega_o \cdot [h_{t-1}, x_t] + b_o), \quad (17)$$

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t, \quad (18)$$

где f_t, i_t, o_t – клапаны забывания, выходные и входные ворота, σ – сигмоида, ω_y – веса соответствующего клапана, h_{t-1} – результат вычислений в предыдущий момент времени, x_t – текущий входной вектор, b_y – нейроны смещения, C_t – текущее и предыдущее состояния ячейки памяти, \tilde{C}_t – кандидат на состояние ячейки, * – поэлементное умножение векторов.

XGBoost является реализацией ансамблевого обучения на базе деревьев решений, использующей методологию оптимизации градиентного спуска и минимизацию функции потерь при помощи структурного подхода, различных методов регуляризации и большого набора настраиваемых гиперпараметров [Zhang et al., 2021]. При обучении XGBoost использует жадный алгоритм поиска для оптимизации своей древовидной структуры и поддерживает параллельные вычисления.

Prophet является библиотекой прогнозирования временных рядов, которая основывается на аддитивной модели, которая моделирует тренд при помощи кусочно-линейной функции, а сезонность – с помощью рядов Фурье (19) [Papastefanopoulos et al., 2020]. Преимуществом использования данной модели является ее устойчивость к выбросам, сезонности и наличию аномальных данных

$$y(t) = g(t) + s(t) + h(t) + \varepsilon(t), \quad (19)$$

где $g(t)$ – параметры тренда, $s(t)$ – параметры сезонности, $h(t)$ – аномальные данные, $\varepsilon(t)$ – ошибки.

Каждый из описанных подходов и моделей прогнозирования на базе временных рядов имеет свое преимущество: линейные модели обеспечивают простоту конечных приложений, LSTM эффективен для моделирования долгосрочных зависимостей, Prophet обеспечивает гибкость в работе с сезонностью.

Вычислительный эксперимент

В качестве критериев для оценки эффективности каждой модели временных рядов были использованы критерии MAE (среднее абсолютное отклонение между предсказанными и фактическими значениями) и MSE (среднее квадратичное отклонение между предсказанными и фактическими значениями). Оценка моделей по указанным критериям производилась на период с сентября 2023 по декабрь 2023 включительно, а оценка качества прогноза производилась путем сравнения с реальными данными на период с января по май 2024.

Параметр α экспоненциального сглаживания исследовался в диапазоне от 0.05 до 0.5, было установлено, что значение $\alpha = 0.3$ обеспечивает наилучшие результаты сглаживающего эффекта. При таком значении α полученные данные экспоненциального сглаживания наиболее близко соответствуют исходным данным (рис. 2).

Параметры α и β двойного экспоненциального сглаживания исследовались в диапазоне 0.02 до 0.9, было установлено, что параметры $\alpha = 0.9$ и $\beta = 0.05$ обеспечивают наилучшие результаты сглаживающего эффекта. При таком значении параметров полученные данные наиболее близко соответствуют исходным данным (рис. 2).

При использовании модели Хольта – Винтерса для подбора оптимального набора параметров использовался сокращенный сопряженный градиент Ньютона (TNCG) – алгоритм оптимизации, который использует итерационный метод сопряженных градиентов для минимизации квадратичной модели целевой функции. Алгоритм TNCG подобрал следующие параметры: компонент уровня ряда $\alpha = 0.00994$, компонент тренда $b = 0.01141$ и компонент сезонности $s = 0.03316$.

Для обучения модели Хольта – Винтерса использовалась кросс-валидация на скользящем окне, которая использует обучающие отрезки ряда для построения прогнозов на n шагов вперед, расширяя выборку на следующие n шагов и строя новый прогноз, перестраивая модель с учетом расширенной обучающей выборки. В результате получается несколько прогнозов и ошибок, соответствующих разным тестовым отрезкам временного ряда. Сглаживание исходных данных при помощи использования модели Хольта – Винтерса представлено на рис. 2.

Сглаживание исходных данных при помощи использования модели ARIMA представлено на рис. 3. Для преобразования ряда к стационарному виду использовалось преобразование Бокса-Кокса, проверка ряда на стационарность осуществлялась при помощи теста Дики – Фуллера.

Полученная модель ARIMA показала дисперсию ошибок модели равной 0.1797, и проверка остатков ряда на автокорреляцию при помощи теста Ljung-Box показала значение автокорреляции равной 0.02, что демонстрирует состоятельность модели ARIMA.

В рамках данной работы также были исследованы модель решающих деревьев XGBoost и модель линейной регрессии. Эти модели хорошо работают для небольшого

количества признаков в случае необходимости быстро построить прогноз, так как экспоненциальные модели не дают большой глубины прогноза, а модели ARIMA требуют частого переобучения на новых данных. Модель XGBoost представлена на рис. 4.

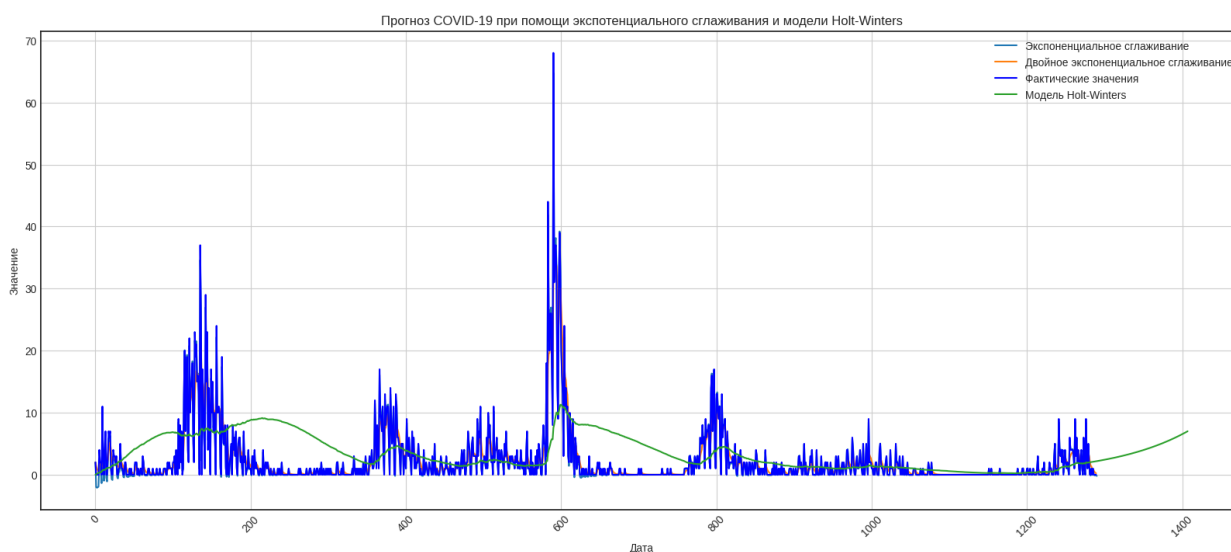


Рис. 2. Прогнозирование заболеваемости коронавирусной инфекцией пациентов Красноярской краевой клинической больницы в динамике при помощи моделей экспоненциального сглаживания, двойного экспоненциального сглаживания, модели Хольта – Винтерса
Fig. 2. Predicting the incidence of coronavirus infection in patients of the Krasnoyarsk Regional Clinical Hospital in dynamics using exponential smoothing models, double exponential smoothing, Holt Winters model




Рис. 3. Прогнозирование заболеваемости коронавирусной инфекцией пациентов Красноярской краевой клинической больницы в динамике при помощи модели ARIMA
Fig. 3. Predicting the incidence of coronavirus infection in patients of the Krasnoyarsk Regional Clinical Hospital in dynamics using the ARIMA model

Нейронные сети были представлены моделью LSTM, а также исследовалась библиотека временных рядов Prophet. Модель LSTM анализировалась с различными гиперпараметрами: количество нейронов в LSTM-слое варьировалось от 10 до 128, длина последовательности временного ряда – от 10 до 30, в качестве оптимизатора был выбран

оптимизатор Adam, в качестве функции ошибки – критерий MSE, количество эпох обучения равнялось 100. В модели Prophet был отключен параметр, учитывающий праздничные дни, тип тренда задан как линейный, максимальное количество точек изменения тренда варьировалось от 10 до 30, сезонность учитывалась по всем параметрам. Результаты применения этих методик представлены на рис. 5 и 6.

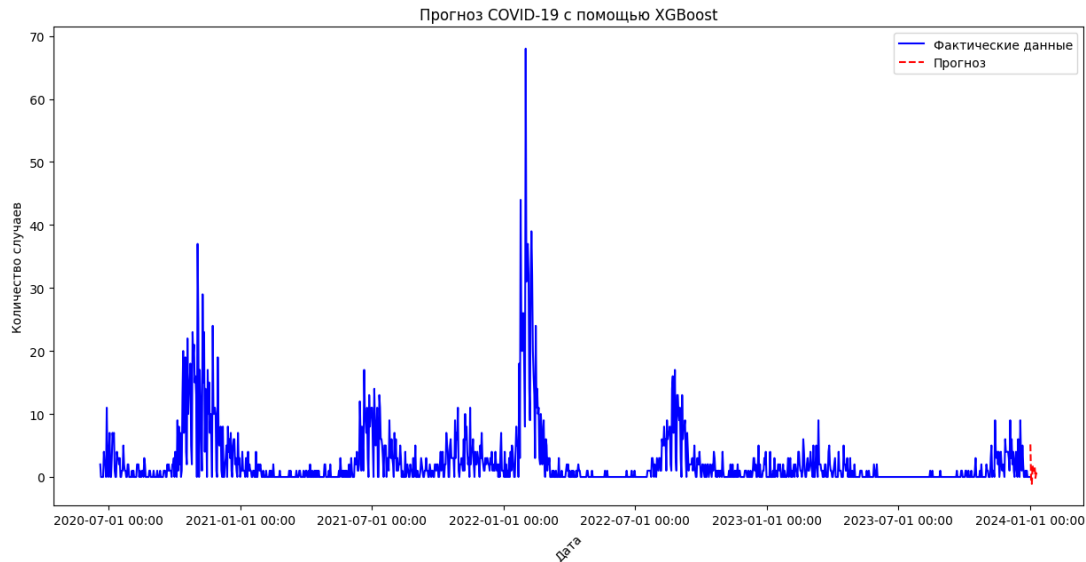


Рис. 4. Прогнозирование заболеваемости коронавирусной инфекцией пациентов Красноярской краевой клинической больницы в динамике при помощи модели XGBoost
Fig. 4. Predicting the incidence of coronavirus infection in patients of the Krasnoyarsk Regional Clinical Hospital in dynamics using the XGBoost model

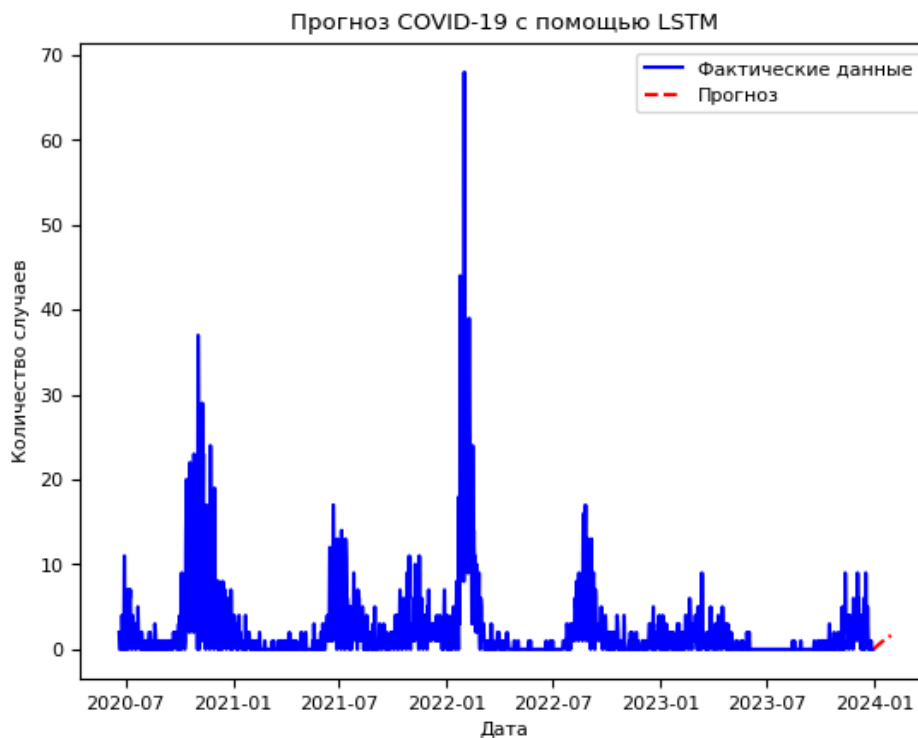


Рис. 5. Прогнозирование заболеваемости коронавирусной инфекцией пациентов Красноярской краевой клинической больницы в динамике при помощи модели LSTM
Fig. 5. Predicting the incidence of coronavirus infection in patients of the Krasnoyarsk Regional Clinical Hospital in dynamics using the LSTM model




Рис. 6. Прогнозирование заболеваемости коронавирусной инфекцией пациентов Красноярской краевой клинической больницы в динамике при помощи библиотеки Prophet

Fig. 6. Predicting the incidence of coronavirus infection in patients of the Krasnoyarsk Regional Clinical Hospital in dynamics using the Prophet library

В табл. 1 представлены результаты вычислительного эксперимента применения выбранных моделей для экспериментальных данных. Минимальное значение критерия MSE, равное 2,39, показала модель Хольта – Винтерса, максимальное значение критерия MSE, равное 7,88, показала модель Prophet. Критерий MAE всех моделей лежит в диапазоне от 1 до 2, при этом минимальный критерий MAE показывает модель Хольта – Винтерса.

Таблица 1

Table 1

Результаты вычислительного эксперимента применения выбранных моделей для экспериментальных данных
 The results of a computational experiment using selected models for experimental data

	MAE	MSE
Holt-Winters	0,97	2,395
ARIMA	1,13	2,62
Linear regressions	1,68	3,70
XGBoost	2,00	3,45
LTSM	1,49	3,36
Prophet	1,48	7,88

В таблице 2 представлены результаты прогнозирования разработанных моделей на 10, 30 дней и на 128 дней. Реальные значения при этом равны по одному зарегистрированному случаю на 10 января 2024 года и на 1 февраля 2024 года, и 3 зарегистрированных случая на 7 мая 2024.

Ближе всего значения к реальным данным показала модель Хольта – Винтерса (2, 2 и 4 случая соответственно). Ближе всего значения к реальным данным при прогнозировании на краткосрочный период (10 и 30 дней) показала экспоненциальная модель и модель ARIMA, однако при долгосрочном прогнозировании значения уменьшены в сравнении с истинными. Прогнозируемы значения, полученные при помощи моделей Linear regressions

и XGBoost, а также LSTM и Prophet хоть лежат в нужном диапазоне, но отличаются более низкой точностью в сравнении с реальными данными.

Таблица 2
Table 2

Результаты прогнозирования исследуемых моделей на 10, 30 дней и на 128 дней
The results of forecasting the studied models for 10, 30 days and 128 days

Модель	Прогноз на 10 дней	Прогноз на 30 дней	Прогноз на 128 дней
Экспоненциальное сглаживание	1,79	0,99	0,04
Двойное экспоненциальное сглаживание	-0,04		
Holt-Winters	2,10		
ARIMA	0,74	0,54	0,39
Linear regressions	-0,87	-1,78	-1.10
XGBoost	0,27	-0,03	0,90
LSTM	0,39	0,66	8,64
Prophet	0,53	0,50	0,35

Результаты и их обсуждение

В результате проведенного исследования построены несколько моделей временных рядов для прогнозирования заболеваемости коронавирусной инфекцией на примере отдельного ЛПУ. Для проверки качества моделей использовались критерии MAE и MSE, а также сравнивались результаты модельного прогнозирования с реальными данными. Было установлено, что модель Хольта – Винтерса демонстрирует наилучшую точность при моделировании динамики локальных ключевых показателей распространения эпидемии коронавируса на всех периодах прогнозирования. Модель показала минимальное значение критерия MSE (2,39) и MAE (1), а также наиболее точно среди представленных моделей предсказывала реальные данные в краткосрочной и долгосрочной перспективе. Несмотря на то, что экспоненциальная модель и модель ARIMA показали лучшую точность при прогнозировании на краткосрочный период (10 и 30 дней), их прогнозируемые значения при долгосрочном прогнозировании оказались заниженными. Модель LSTM показала большую точность среди своих результатов при долгосрочном прогнозировании. Линейная регрессия и XGBoost привлекают своей скоростью обработки данных и простотой использования, однако они уступают в точности как краткосрочного, так и долгосрочного прогноза. Модель Prophet для достижения высокой точности прогнозирования нуждается в наличии четко выраженных каникулярных и сезонных паттернов в данных, которых, вероятно, не хватало в исследуемом наборе данных.

Ключевой целью исследования было изучение эффективности инструментов прогнозирования на базе временных рядов, чтобы обеспечить их готовность к внедрению в практику медицинских учреждений и широкому применению. Исследователи стремились получить данные о том, насколько эффективно эти инструменты способны справляться с прогнозированием спроса на ресурсы, планированием стратегических мер по предотвращению заболеваний и оптимизацией распределения персонала на локальном уровне лечебно-профилактического учреждения.

Авторы предлагают особое внимание уделить изучению возможностей трех классов моделей прогнозирования: Хольта – Винтерса, LSTM и ARIMA. Модель Хольта – Винтерса может показать свою эффективность как в прогнозировании спроса на медицинские ресурсы, например, на тест для определения РНК коронавируса (SARS-CoV-2), так и для оптимизации распределения медицинского персонала и ресурсов в периоды эпидемий. Модель LSTM, в свою очередь, является ценным инструментом для раннего выявления

трендов распространения заболеваний, где точность прогноза менее важна, чем выявление тренда, что позволит медицинским работникам своевременно принимать необходимые меры по их предотвращению. В то же время модель ARIMA должна оказаться наиболее эффективной для оптимизации распределения медицинского персонала и ресурсов в периоды эпидемий, например, во время пандемии. Модель экспоненциального сглаживания показала результаты, аналогичные модели ARIMA, но она менее универсальна, больше зависит от конкретных данных, поэтому эту модель можно использовать для проверки результатов краткосрочного прогнозирования при помощи других методов.

Модели временных рядов имеют ряд преимуществ в своем использовании: эти модели позволяют оценить исследуемый процесс в динамике, тогда как стандартные методики планирования медицинских ресурсов опираются на статистические данные о численности населения или потребности в медицинских ресурсах, позволяют учитывать региональные особенности заболеваемости, так как COVID-19 не распространяется равномерно, могут быть интегрированы с другими источниками данных, например, с данными о погоде или вакцинации, что может обеспечить более точный прогноз.

Список литературы

- Захаров В.В., Балыкина Ю.Е. 2021. Балансовая модель эпидемии COVID-19 на основе процентного прироста. Информатика и автоматизация, 20(5): 1034–1065.
- Криворотько О.И., Кабанихин С.И., Зятков Н.Ю., Приходько А.Ю., Прохошин Н.М., Шишленин М.А. 2020. Математическое моделирование и прогнозирование COVID-19 в Москве и Новосибирской области. Сибирский журнал вычислительной математики, 23(4): 395–414.
- Омельяновский В.В., Семёнова Т.В., Лукьянцева Д.В., Федяев Д.В., Шалаева Е.А. 2020. Разработка методики расчета потребности во врачебных кадрах в здравоохранении Российской Федерации с использованием математической модели. Фармакоэкономика. Современная фармакоэкономика и фармакоэпидемиология, 13(4): 427–437.
- Adhikari R., Agrawal R.K. 2013. An introductory study on time series modeling and forecasting. arXiv preprint arXiv:1302.6613.
- ИМЭ COVID-19 Forecasting Team. 2021. Modeling COVID-19 scenarios for the United States. Nature medicine, 27(1): 94–105.
- Fanelli D., Piazza F. 2020. Analysis and forecast of COVID-19 spreading in China, Italy and France. Chaos, Solitons & Fractals, 134: 109761.
- Grober T., Grober O., Savchenko O. 2020. An innovative approach to the study of the model of a medical institution. In E3S web of conferences, 210:11002.
- Hu Z., Ge Q., Li S., Jin L., Xiong M. 2020. Artificial intelligence forecasting of covid-19 in China. arXiv preprint arXiv:2002.07112.
- Lacasa L., Challen R., Brooks-Pollock E., Danon L. 2020. A flexible method for optimising sharing of healthcare resources and demand in the context of the COVID-19 pandemic. PLoS ONE, 15(10): e0241027.
- Lee K., Agrawal A., Choudhary A. 2017. Forecasting influenza levels using real-time social media streams. IEEE International Conference on Healthcare Informatics (ICHI): 409–414.
- Luo J., Zhang Z., Fu Y., Rao F. 2021. Time series prediction of COVID-19 transmission in America using LSTM and XGBoost algorithms. Results in Physics, 27: 104462.
- Papastefanopoulos V., Linardatos P., Kotsiantis S. 2020. COVID-19: a comparison of time series methods to forecast percentage of active cases per population. Applied sciences, 10(11): 3880.
- Petropoulos F., Makridakis S. 2020. Forecasting the novel coronavirus COVID-19. PloS one. 15(3): e0231236.
- Taylor S.J., Letham B. 2018. Forecasting at scale. The American Statistician, 72(1): 37–45.
- Wei W., Wang G., Tao X., Luo Q., Chen L., Bao X., Liu Y., Jiang J., Liang H., Ye L. 2023. Time series prediction for the epidemic trends of monkeypox using the ARIMA, exponential smoothing, GM (1, 1) and LSTM deep learning methods. Journal of General Virology, 104(4): 001839.
- Xian X., Wang L., Wu X., Tang X., Zhai X., Yu R., Qu L., Ye M. 2023. Comparison of SARIMA model, Holt-winters model and ETS model in predicting the incidence of foodborne disease. BMC Infectious Diseases, 23(1): 803.

- Yin R., Luusua E., Dabrowski J., Zhang Y., Kwoh C.K. 2020. Tempel: time-series mutation prediction of influenza A viruses via attention-based recurrent neural networks. *Bioinformatics*, 36(9): 2697–2704.
- Zhang L., Bian W., Qu W., Tuo L., Wang Y. 2021. Time series forecast of sales volume based on XGBoost. In *Journal of Physics: Conference Series*, 1873 (1): 012067.

References

- Zaharov V.V., Balykina Ju.E. 2021. Balansovaja model' jepidemii COVID-19 na osnove procentnogo prirosta [COVID-19 Epidemic Balance Model Based on Percentage Growth] *Informatika i avtomatizacija [Informatics and Automation]*, 20(5): 1034–1065.
- Krivorot'ko, O.I., Kabanihin, S.I., Zjat'kov, N.Ju., Prihod'ko, A.Ju., Prohoshin, N.M., Shishlenin, M.A. 2020. Matematicheskoe modelirovanie i prognozirovanie COVID-19 v Moskve i Novosibirskoj oblasti [Mathematical Modeling and Prediction of COVID-19 in Moscow and Novosibirsk Oblast]. *Sibirskij zhurnal vychislitel'noj matematiki [Siberian Journal of Computational Mathematics]*, 23(4): 395–414.
- Omel'janovskij, V.V., Semjonova, T.V., Luk'janceva, D.V., Fedjaev, D.V., Shalaeva, E.A. 2020. Razrabotka metodiki rascheta potrebnosti vo vrachebnyh kadrah v zdavoohranenii Rossijskoj Federacii s ispol'zovaniem matematicheskoy modeli. [Development of a methodology for calculating the need for medical personnel in healthcare of the Russian Federation using a mathematical model]. *Farmakojekonomika. Sovremennaja farmakojekonomika i farmakojepidemiologija [Farmakoeconomika. Modern Pharmacoeconomics and Pharmacoepidemiology]*, 13(4): 427–437.
- Adhikari R., Agrawal R.K. 2013. An introductory study on time series modeling and forecasting. *arXiv preprint arXiv:1302.6613*.
- IHME COVID-19 Forecasting Team. 2021. Modeling COVID-19 scenarios for the United States. *Nature medicine*, 27(1): 94–105.
- Fanelli D., Piazza F. 2020. Analysis and forecast of COVID-19 spreading in China, Italy and France. *Chaos, Solitons & Fractals*, 134: 109761.
- Grober T., Grober O., Savchenko O. 2020. An innovative approach to the study of the model of a medical institution. In *E3S web of conferences*, 210:11002.
- Hu Z., Ge Q., Li S., Jin L., Xiong M. 2020. Artificial intelligence forecasting of covid-19 in China. *arXiv preprint arXiv:2002.07112*.
- Lacasa L., Challen R., Brooks-Pollock E., Danon L. 2020. A flexible method for optimising sharing of healthcare resources and demand in the context of the COVID-19 pandemic. *PLoS ONE*, 15(10): e0241027.
- Lee K., Agrawal A., Choudhary A. 2017. Forecasting influenza levels using real-time social media streams. *IEEE International Conference on Healthcare Informatics (ICHI)*: 409–414.
- Luo J., Zhang Z., Fu Y., Rao F. 2021. Time series prediction of COVID-19 transmission in America using LSTM and XGBoost algorithms. *Results in Physics*, 27: 104462.
- Papastefanopoulos V., Linardatos P., Kotsiantis S. 2020. COVID-19: a comparison of time series methods to forecast percentage of active cases per population. *Applied sciences*, 10(11): 3880.
- Petropoulos F., Makridakis S. 2020. Forecasting the novel coronavirus COVID-19. *PLoS one*. 15(3): e0231236.
- Taylor S.J., Letham B. 2018. Forecasting at scale. *The American Statistician*, 72(1): 37–45.
- Wei W., Wang G., Tao X., Luo Q., Chen L., Bao X., Liu Y., Jiang J., Liang H., Ye L. 2023. Time series prediction for the epidemic trends of monkeypox using the ARIMA, exponential smoothing, GM (1, 1) and LSTM deep learning methods. *Journal of General Virology*, 104(4): 001839.
- Xian X., Wang L., Wu X., Tang X., Zhai X., Yu R., Qu L., Ye M. 2023. Comparison of SARIMA model, Holt-winters model and ETS model in predicting the incidence of foodborne disease. *BMC Infectious Diseases*, 23(1): 803.
- Yin R., Luusua E., Dabrowski J., Zhang Y., Kwoh C.K. 2020. Tempel: time-series mutation prediction of influenza A viruses via attention-based recurrent neural networks. *Bioinformatics*, 36(9): 2697–2704.
- Zhang L., Bian W., Qu W., Tuo L., Wang Y. 2021. Time series forecast of sales volume based on XGBoost. In *Journal of Physics: Conference Series*, 1873 (1): 012067.

Конфликт интересов: о потенциальном конфликте интересов не сообщалось.

Conflict of interest: no potential conflict of interest related to this article was reported.



Поступила в редакцию 18.06.2024

Received June 18, 2024

Поступила после рецензирования 03.09.2024

Revised September 03, 2024

Принята к публикации 06.09.2024

Accepted September 06, 2024

ИНФОРМАЦИЯ ОБ АВТОРАХ

INFORMATION ABOUT THE AUTHORS

Шеломенцева Инга Георгиевна, кандидат технических наук, доцент кафедры медицинской кибернетики и информатики, Красноярский государственный медицинский университет им. проф. В.Ф. Войно-Ясенецкого, г. Красноярск, Россия

Inga G. Shelomentseva, Candidate of Technical Sciences, Associate Professor of the Department of Medical Cybernetics and Informatics, Prof. V.F. Voino-Yasenetsky Krasnoyarsk State Medical University, Krasnoyarsk, Russia

Ченцов Сергей Васильевич, доктор технических наук, профессор, профессор кафедры систем автоматизации, автоматизированного управления и проектирования, Сибирский федеральный университет, г. Красноярск, Россия

Sergej V. Chentsov, Doctor of Technical Sciences, Professor, Professor of the Department of Automated Control Systems, Automated Management, and Design, Siberian Federal University, Krasnoyarsk, Russia

Краснораменская Ирина Сергеевна, магистрант кафедры медицинской кибернетики и информатики, Красноярский государственный медицинский университет им. проф. В.Ф. Войно-Ясенецкого, г. Красноярск, Россия

Irina S. Krasnoramenskaja, Master's student of the Department of Medical Cybernetics and Informatics of Prof. V.F. Voino-Yasenetsky Krasnoyarsk State Medical University, Krasnoyarsk, Russia