

---

## ИНФОРМАТИКА

---

УДК 519.673

Посвящается 70-летию Игоря Борисовича Петрова

# МОДЕЛИРОВАНИЕ ЭПИДЕМИЙ: НЕЙРОСЕТЬ НА ОСНОВЕ ДАННЫХ И SIR-МОДЕЛИ<sup>1)</sup>

© 2023 г. О. И. Криворотко<sup>1,\*</sup>, Н. Ю. Зятьков<sup>1</sup>, С. И. Кабанихин<sup>1</sup>

<sup>1</sup> 630090 Новосибирск, пр-т Акад. Коптюга, 4,  
Институт математики им. С.Л. Соболева СО РАН, Россия

\*e-mail: o.i.krivorotko@math.nsc.ru

Поступила в редакцию 22.05.2023 г.  
Переработанный вариант 22.05.2023 г.  
Принята к публикации 26.06.2023 г.

Ранее был предложен метод построения начального приближения для решения обратной задачи акустики градиентным методом на основе сверточной нейронной сети, обученной предсказывать распределение скоростей в среде по волновому отклику (И.Б. Петров, А.С. Станкевич, А.В. Васюков, Докл. РАН, 2023). Показано, что нейронная сеть, обученная на откликах от простых слоистых структур, может быть успешно использована при решении обратной задачи для существенно более сложной модели. В настоящей статье мы изложим алгоритмы обработки данных об эпидемиях и пример применения нейронных сетей для моделирования распространения COVID-19 в Новосибирской области, основанный только на данных. Построена нейросеть NN-COVID-19, которая использует данные об эпидемии. Показано, что нейронная сеть на порядок лучше, чем SEIR-HCD, предсказывает распространение COVID-19 на 5 дней. При появлении нового штамма (Омикрон) после переобучения нейросеть способна предсказать распространение эпидемии более точно. Отметим, что нейросеть использует не только эпидемиологические данные, но и социальные (праздники, введение и соблюдение ограничительных мер и т.п.). Предложенный подход позволяет уточнять математические модели. Сравнение кривых, построенных по SEIR-HCD модели и нейронной сетью, показывает, что графики решения прямой задачи практически совпадают с графиками, построенными нейросетью. Это позволяет уточнить коэффициенты дифференциальной модели. Библ. 19. Фиг. 12. Табл. 2.

**Ключевые слова:** эпидемиология, временные ряды, машинное обучение, глубокое обучение, обработка данных, рекуррентные нейронные сети, полно связные нейронные сети, COVID-19, прогнозирование.

**DOI:** 10.31857/S0044466923100095, **EDN:** MCDEIS

## 1. ВВЕДЕНИЕ

Нейросети Data driven обучаются на основе большого количества данных и могут использоваться для решения обратных задач, а также для построения математических моделей. Для этого сначала собирают достаточно представительный набор данных о процессе, который затем обрабатывается и приводится к единому формату для обучения нейросети. В процессе обучения нейросеть настраивает веса и параметры, с целью минимизировать ошибку предсказания. После обучения нейросети ее качество проверяется на валидационных и тестовых данных. Подобный подход использовался для построения ежемесячных прогнозов вероятности наступления рецессии в США в течение следующих 6, 12 и 24 мес. в зависимости от текущих макроэкономических и финансовых факторов (см. [1]).

<sup>1)</sup>Работа выполнена при поддержке Математического Центра в Академгородке, соглашение с Минобрнауки РФ № 075-15-2022-281.

Нейросети Data driven могут помочь получить уравнение, которое описывает данный процесс, а также уточнить существующие модели и уравнения (SEIR-HCD). Это можно сделать с помощью методов глубокого обучения, таких как автоэнкодеры (см. [2]) или генеративно-состязательные сети (см. [3]), которые могут выявлять скрытые закономерности в данных и создавать математические модели на основе этих закономерностей. Наряду с Data driven следует упомянуть и Physics Informed нейросети, при конструировании и обучении которых используют и учитывают физические законы, ограничения и связи между различными параметрами. В настоящей работе предпринята попытка комбинирования этих подходов.

Отметим работы, в которых анализируются и сравниваются Data driven и Physics Informed подходы к обучению нейросетей. В [4] обсуждаются преимущества и недостатки обоих подходов и предлагается новый подход, который комбинирует физические законы и данные для более точного предсказания.

В [5] сравниваются Data driven и Physics Informed подходы на примере реальных промышленных задач и дается вывод, что комбинация обоих подходов может дать наилучший результат.

В [6] сравниваются различные алгоритмы машинного обучения для предсказания содержания органического углерода в почве и дается вывод, что комбинация Physics Informed и Data driven подходов может дать наилучший результат.

В [7] представляется метод Sparse Identification of Nonlinear Dynamical Systems (SINDy), который использует Data driven подход для идентификации уравнений, описывающих динамику системы. В статье “Data-Driven Discovery of Partial Differential Equations” также представляется метод Data driven подхода для идентификации уравнений, описывающих динамику системы, включая уравнения в частных производных. Такие методы могут быть полезны для решения обратных задач и получения уравнений из экспериментальных данных.

Подробный обзор математических моделей описания распространения эпидемий приведен в [8]. В [9] предложен метод построения начального приближения для решения обратной задачи акустики на основе сверточной нейронной сети, обученной предсказывать распределение скоростей в среде по волновому отклику. Показано, что нейронная сеть, обученная на откликах от простых слоистых структур, может быть успешно использована при решении обратной задачи для существенно более сложной модели.

В [10] предложен подход глубокого обучения для прогнозирования количества зараженных и умерших от COVID-19 за период 1–4 нед. в нескольких районах США. Рекуррентная нейронная сеть с так называемой долгой краткосрочной памятью (LSTM) обучается на нескольких выборках временных рядов одновременно. Результаты показали, что добавление индекса активности населения в качестве переменной и использование нескольких выборок для обучения сети повышают эффективность прогнозирования. Результаты прогноза имеют точность и пространственные закономерности, аналогичные стандартной ансамблевой модели, используемой в качестве эталона.

В [11] проведены прогнозирование вспышки и анализ распространения пандемии COVID-19 с использованием нейронной сети. Архитектура нейронной сети была разработана для прогнозирования последствий вспышки пандемии в Катаре, Испании и Италии. Официальные статистические данные, собранные в этих странах до 6 июля 2021 г., были использованы для подтверждения и тестирования модели прогнозирования. Чувствительность модели была проанализирована с использованием среднеквадратичной ошибки (RMSE). Моделирование COVID-19 показало эффективность мер, принятых правительствами и медицинскими организациями для смягчения последствий пандемии.

В [12] проведено исследование заболеваемости COVID-19 в Приморском крае в 2020–2022 гг., в которой показано, что способ моделирования ранговых распределений с учетом периодичности процесса заболеваемости находится в рамках общего тренда исследований развития пандемического процесса.

В настоящей статье излагаются алгоритмы обработки эпидемиологических данных и применения нейросетей на примере распространения COVID-19 в Новосибирской области. В работе построена нейросеть NN-COVID-19, которая использует эпидемиологические и социологические (праздники, введение и соблюдение ограничительных мер) данные об эпидемии. Показано, что нейронная сеть на порядок лучше описывает ожидаемое количество выявленных заболевших и подключенных к ИВЛ на ближайшие 5 дней, чем модель SEIR-HCD (см. [13, 14]). При появлении нового штамма (Омикрон) требуется переобучение, после которого нейросеть (на примере штамма Кентавра) демонстрирует приемлемые прогнозы.

Статья организована следующим образом. В разд. 2 изложены алгоритмы получения и обработки исходных данных. В разд. 3 описан алгоритм построения и обучения нейронной сети. В разд. 4 приведены результаты численных расчетов и выводы.

## 2. ИСХОДНЫЕ ДАННЫЕ И ИХ ОБРАБОТКА

### 2.1. Источники получения исходных данных и их описание

Большая часть данных по Новосибирской области была получена из открытых источников путем автоматизированного сбора и структурирования (парсинг) с сайтов:

1) сайт РБК с ежедневными новостными сводками об эпидемиологической ситуации COVID-19 в Новосибирской области (количество протестированных, зараженных, выздоровевших, умерших, госпитализированных и т.д.): <https://nsk.rbc.ru/nsk/story/5e30678d9a7947df0c919a7a>,

2) сайт компании Инвитро с данными о проценте населения с количеством поздних антител IgG к вирусу SARS-CoV-2: [https://www.invitro.ru/l/invitro\\_monitor/](https://www.invitro.ru/l/invitro_monitor/),

3) сайт компании Яндекс с данными об индексе самоизоляции в Новосибирске: <https://yandex.ru/company/researches/2020/podomam>,

4) данные о количестве захоронений умерших от COVID-19 в Новосибирске (предоставлены директором Центра по взаимодействию с органами власти и индустриальными партнерами Новосибирского государственного университета, к.ф.-м.н. А.Н. Люлько).

Собранные исходные данные опубликованы на сайте <https://covid19-modeling.ru/data>.

На фиг. 1 показаны некоторые необработанные исходные данные для Новосибирской области, которые использовались для последующего преобразования и применения к ним методов машинного обучения.

### 2.2. Обработка исходных данных

Первичная обработка данных, представленных в виде временных рядов:

1) заполнение недостающих значений в данных с помощью линейной интерполяции,

2) замена экстремальных значений интерполированием (удаление выбросов в данных),

3) сглаживание данных (экспоненциальная скользящая средняя) – более зашумленные данные (4) и (6) были сглажены 14-дневной экспоненциальной скользящей средней; менее зашумленные данные (3) и (7) сглажены 7-дневной экспоненциальной скользящей средней.

Результат обработки показан на фиг. 2.

## 3. СТРУКТУРА МОДЕЛИ НЕЙРОННОЙ СЕТИ

Важнейшим условием эффективной работы NN-COVID-19 является устранение несбалансированности данных (большие всплески в отдельных интервалах) на основе логарифмирования (см. [15]).

### 3.1. Обучающие признаки для машинного обучения

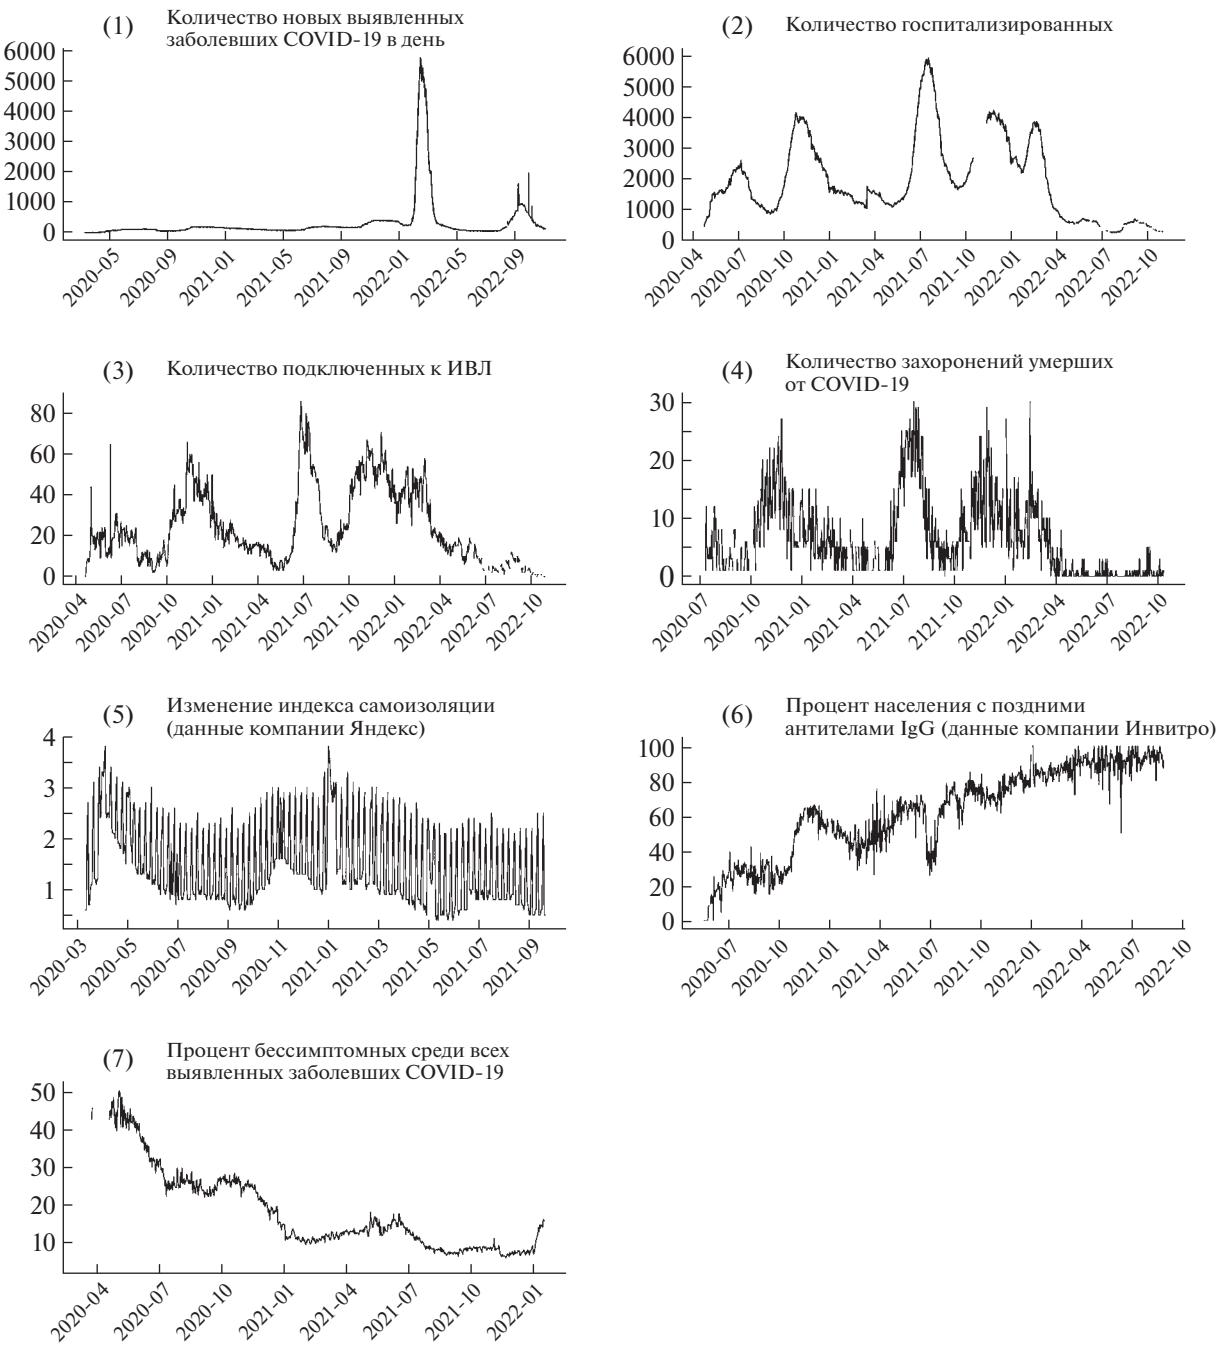
Каждая вспышка новой волны коронавируса характеризуется изменением эпидемиологических и социально-экономических параметров. Для учета появления новых штаммов (Дельта, Омикрон, Кентавр), порождающих резкое повышение количества заболевших, использовалось логарифмическое преобразование данных (1)–(4).

Для обучения нейронной сети были сгенерированы дополнительные данные: логарифмические приращения за 3, 7 и 14 дней данных (1)–(4). На фиг. 3 показаны полученные временные ряды (признаки) для новых выявленных, критических и захороненных в результате COVID-19 в Новосибирской области.

Дополнительно использовались следующие обучающие признаки для обучения:

- Праздничные и выходные дни. Бинарный временной ряд, заполненный значениями 0 или 1 : 1 – праздничный или выходной, 0 – остальные дни.

- Сезонность: 7 бинарных временных рядов. Первый ряд понедельник: 1, если текущий день понедельник, 0 – в остальных случаях. Аналогично для остальных 6 дней недели.



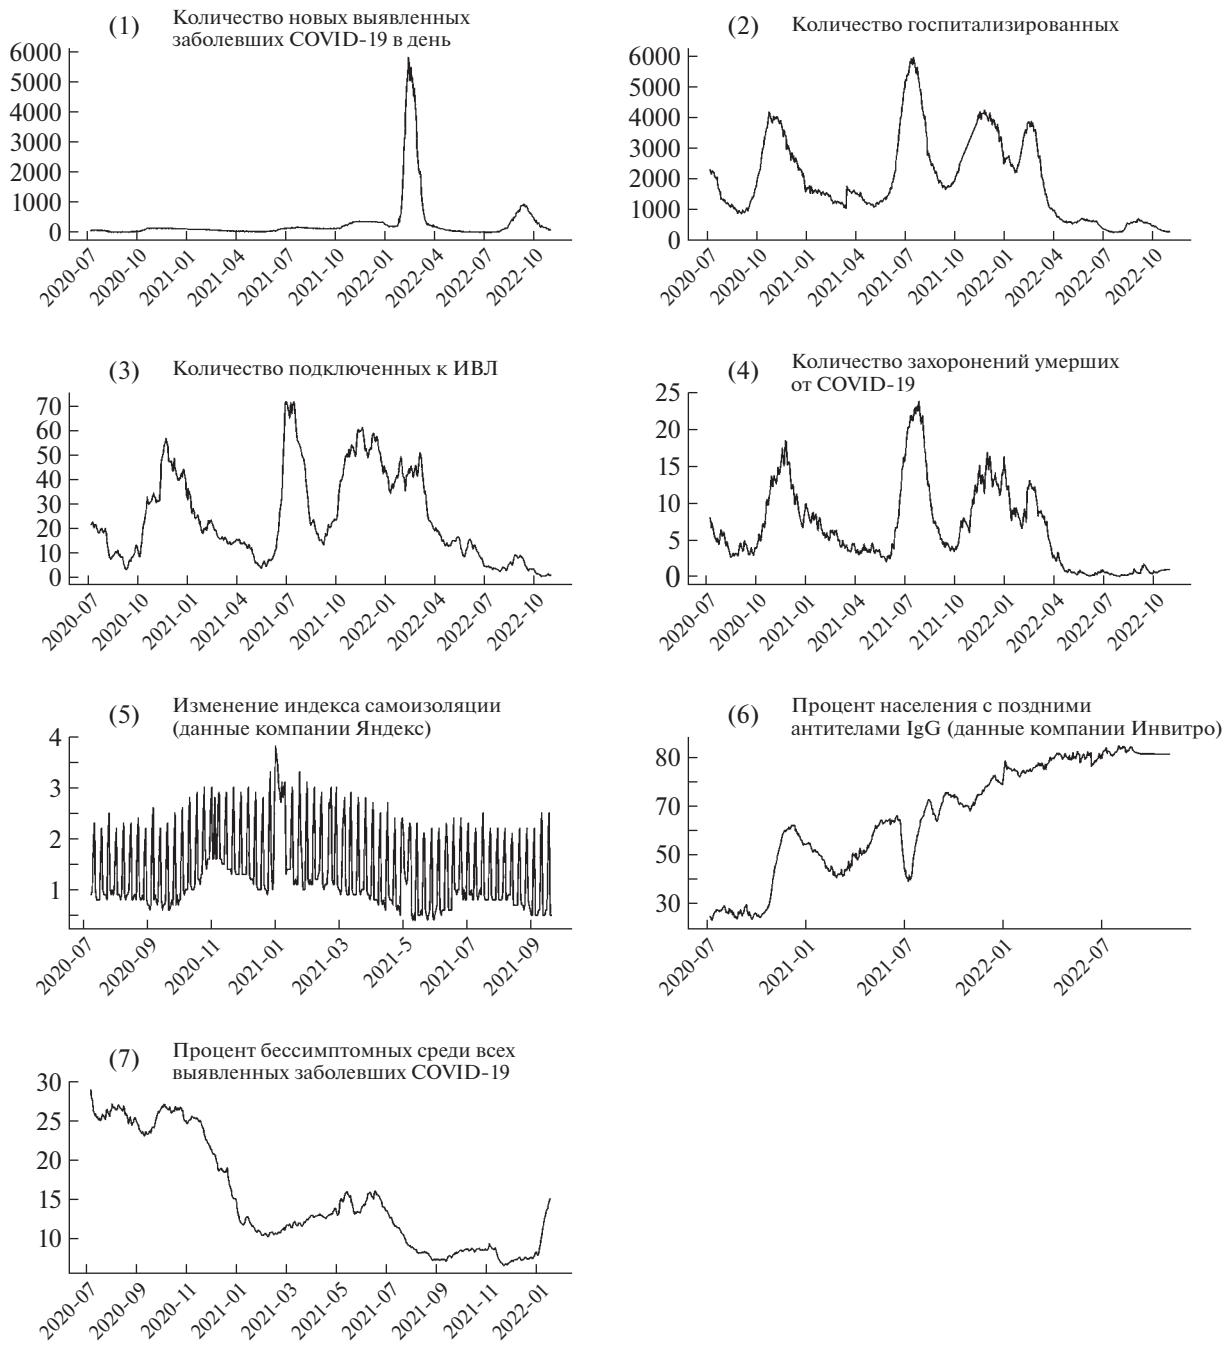
**Фиг. 1.** Исходные необработанные данные заболеваемости COVID-19 в Новосибирской области.

- Ограничительные меры в регионе: 2 бинарных временных ряда. Для первого ряда 1 – введены ограничения в текущий день, 0 – остальные дни. Для второго ряда 1 – отмена некоторых ограничений, 0 – остальные дни.

В табл. 1 указаны даты введения основных ограничений и их отмены с 2020 по 2022 г.

### 3.2. Целевые функции построения прогноза распространения эпидемии

Для обучения нейронной сети выбраны две целевые функции: (1) – количество новых выявленных заболевших COVID-19, (3) – подключенных к аппаратам ИВЛ в текущий день, графики которых представлены на фиг. 2. Обозначим их в виде вектор-функции  $\mathbf{f}(t) = \{\mathbf{f}_1(t), \mathbf{f}_2(t)\}$ . Выбор

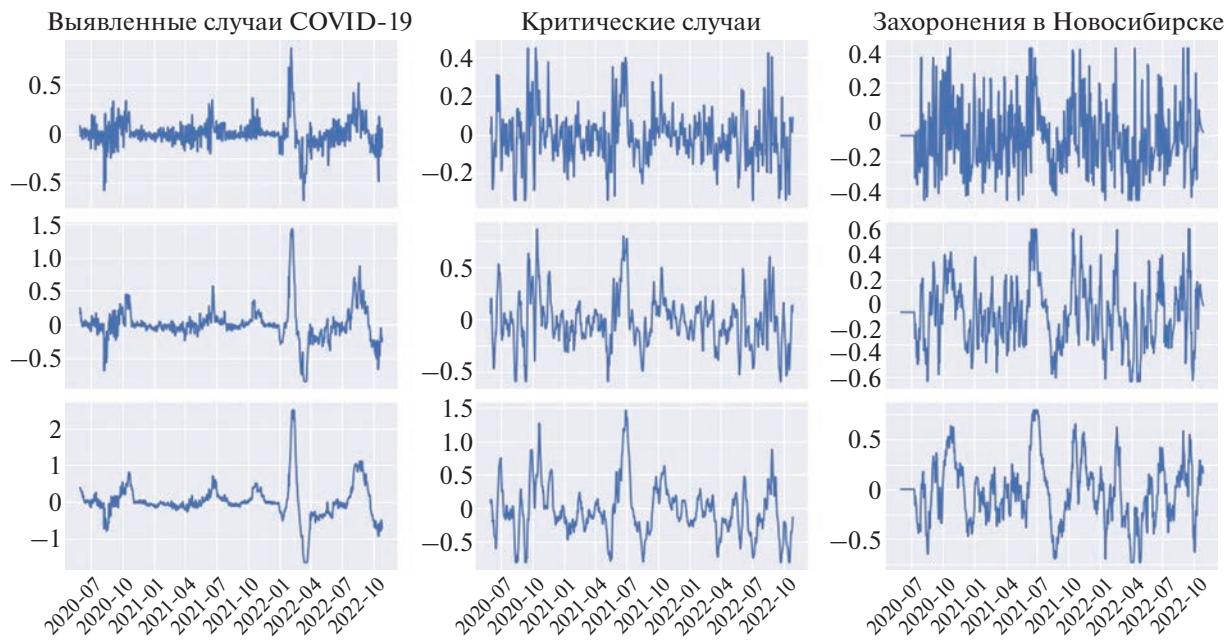


Фиг. 2. Обработанные данные распространения COVID-19 в Новосибирской области.

данных показателей интересен для оптимизации введенных ограничительных мер и уменьшения нагрузки на систему здравоохранения региона.

Для устранения асимметричности в распределении целевых данных  $f(t+1), \dots, f(t+5)$  (прогноз по количеству новых заболевших COVID-19 в следующие 5 дней, прогноз по количеству человек, подключенных к аппарату ИВЛ в следующие 5 дней) используется следующее преобразование:

$$\begin{aligned} F(t+1) &= \ln(f(t+1)+1) - \ln(\text{SMA}(f(t), 7)+1), \\ &\dots \\ F(t+5) &= \ln(f(t+5)+1) - \ln(\text{SMA}(f(t), 7)+1). \end{aligned} \quad (1)$$

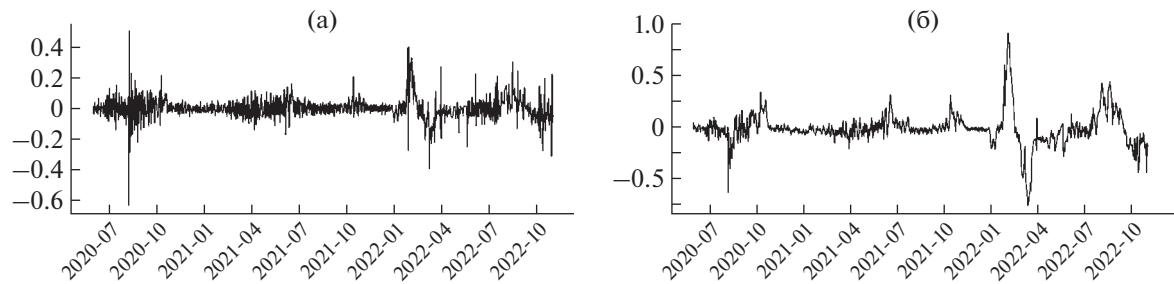


**Фиг. 3.** Сгенерированные дополнительные данные: дневные приращения для новых выявленных, критических и захороненных в Новосибирской области за 3 (первая строка), 7 (вторая строка) и 14 (третья строка) дней.

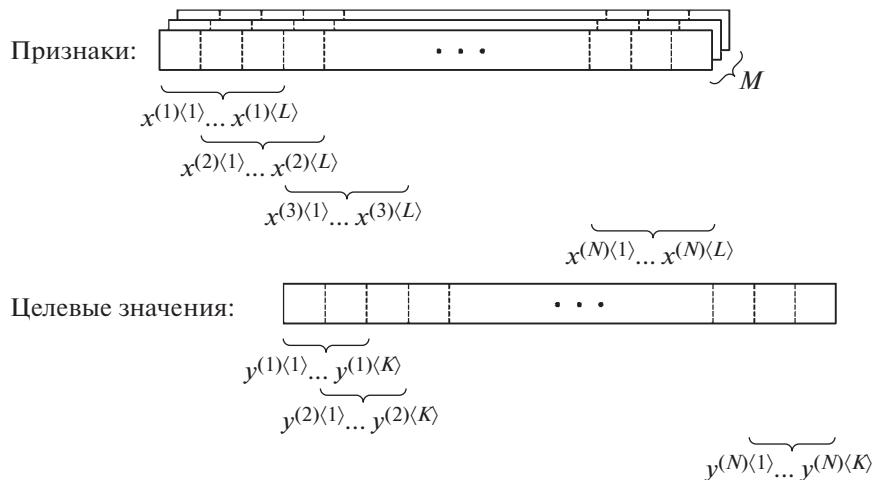
Здесь  $SMA(f(t), 7) = \sum_{j=1}^7 f(t-j)/7$  – 7-дневная простая скользящая средняя от целевых данных  $f(t)$ , применяемая с целью уменьшения зашумленности в данных. Для сравнения на фиг. 4а показано логарифмическое преобразование  $\ln(f(t+1) + 1) - \ln(f(t) + 1)$  без использования скользящей средней. На фиг. 4б показано логарифмическое преобразование  $\ln(f(t+1) + 1) - \ln(SMA(f(t), 7) + 1)$  с использованием простой скользящей средней.

**Таблица 1.** Список ограничений и послаблений с 2020 по 2022 г., а также даты их введения

Дата	Карантинные меры
18 марта 2020	Университеты начали удаленные занятия. Каникулы в школах с 18.03 по 01.04
28 марта 2020	Приостановлены все массовые, развлекательные, общественные мероприятия
31 марта 2020	Усилены меры против коронавируса (социальная дистанция, самоизоляция)
27 апреля 2020	Указ губернатора об обязательном ношении масок в магазинах
12 мая 2020	Возобновление работы продовольственных рынков во всех населенных пунктах кроме областного центра. Разрешено заниматься спортом на улице, соблюдая социальную дистанцию. Разрешены прогулки без посещения общественных мест, детских площадок группам не более двух человек или семьям, живущим вместе
8 июня 2020	Возобновление работы некоторых непродовольственных магазинов
6 июля 2020	Открытие летних веранд в кафе и ресторанах
15 июля 2020	Открытие торговых центров
10 августа 2020	Открытие бассейнов и ресторанов
1 сентября 2020	Начало учебного года (школы, университеты)
23 октября 2020	Начало школьных каникул и возобновление удаленного режима в учебных заведениях
31.12.2020–10.01.2021	Новогодние праздники
01–10.05.2021	Майские праздники



**Фиг. 4.** Логарифмическое преобразование  $\ln(f(t+1) + 1) - \ln(f(t) + 1)$  для новых выявленных заболевших COVID-19 без использования скользящей средней (а) и с использованием простой скользящей средней (б).



**Фиг. 5.** Схема построения набора данных и обучающих меток для обучения нейронной сети.

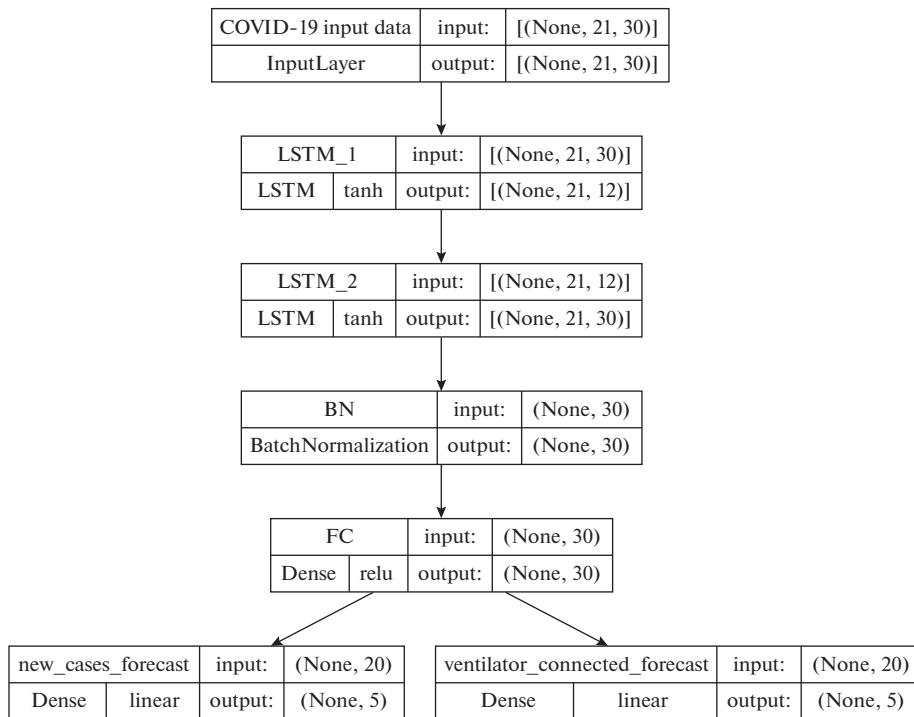
Ввиду монотонности используемых функций для преобразования временных рядов в (1) возможно восстановление 5-дневных прогнозов  $f(t+1), \dots, f(t+5)$  по интересующим эпидемиологическим характеристикам с помощью преобразований

$$\begin{aligned} f(t+1) &= \exp[F(t+1) + \ln(\text{SMA}(f(t), 7) + 1)] - 1, \\ &\dots \\ f(t+5) &= \exp[F(t+5) + \ln(\text{SMA}(f(t), 7) + 1)] - 1. \end{aligned}$$

### 3.3. Архитектура нейронной сети

Для обучения нейронной сети формируется  $N$  наборов данных в виде набора  $M$  временных рядов (количество признаков) размерности  $L$  каждый, как показано на фиг. 5. Параметр  $L$  является гиперпараметром и определяет ширину временного окна, которое рассматривается для формирования прогноза. Используя образец данных размерности  $L \times M$ , формируется прогноз размерности  $K$ . В качестве меток для обучения используются следующие  $K$  значений целевого временного ряда, следующие за образцом данных размерности  $L$ .

На фиг. 6 приведена архитектура нейронной сети, состоящая из рекуррентных и полно связанных слоев. Рекуррентные слои нейронной сети в дополнение к анализу пространства признаков способны анализировать пространство времени в данных. Входной слой сети адаптирован для получения на вход  $M = 23$  временных рядов с шириной временного окна  $L = 14$  дней. Далее данные входного слоя трансформируются через два рекуррентных слоя LSTM (Long short-term memory – долгая краткосрочная память) (см. [16]) с использованием dropout-регуляризации

**Фиг. 6.** Архитектура нейронной сети.

(см. [17]). Над выходными данными второго LSTM слоя проводится пакетная нормализация (см. [18]). Далее полученные преобразованные данные трансформируются с использованием полносвязанного слоя с 20 нейронами и применением функции активации ReLU (см. [19]). Нейронная сеть имеет два выхода. Первый и второй выходы адаптированы для формирования прогнозов по количеству новых заболевших COVID-19 и количеству больных, подключенных к аппаратам ИВЛ на 5 дней вперед. Преобразование данных в выходные для каждого прогноза осуществляется с помощью полносвязанного слоя.

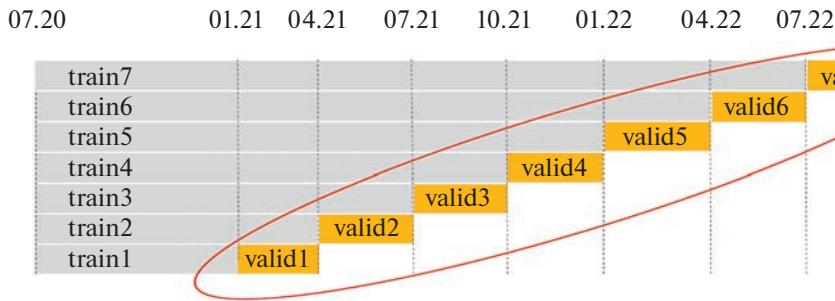
Используемые в численных экспериментах гиперпараметры модели нейронной сети приведены в табл. 2.

#### 3.4. Кросс-валидация

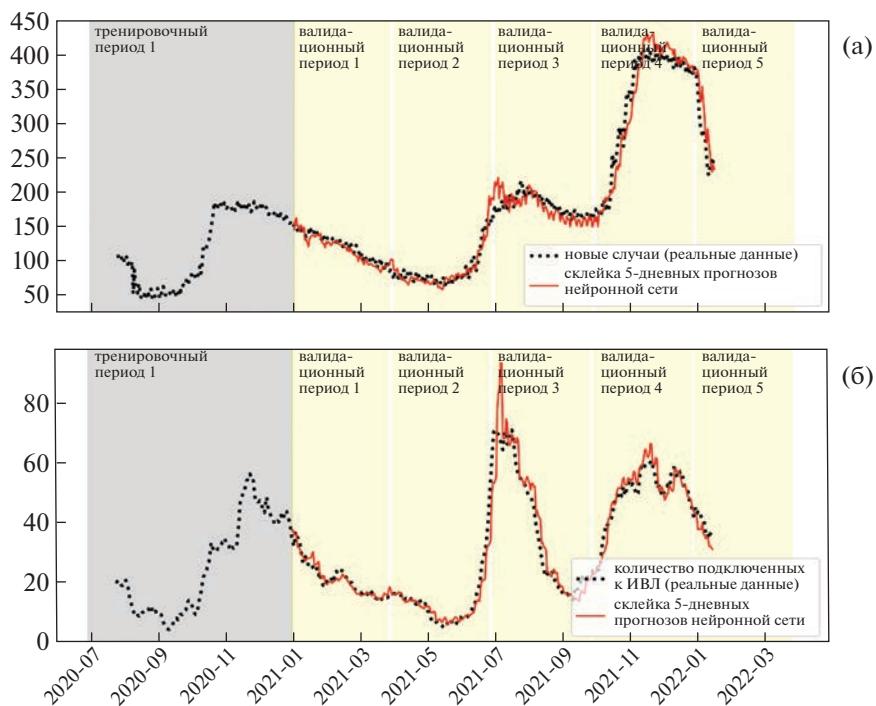
Нейронная сеть обучалась на данных с 2020-07-01 по 2021-01-01 и далее каждые три месяца обучалась снова с учетом дополнительных накопившихся за эти три месяца данных. Валидация модели осуществлялась в течение следующих трех месяцев после обучения. На фиг. 7 показана схема кросс-валидации модели, где серыми блоками обозначены периоды обучения модели, а желтыми обозначены периоды истинных значений (1) и (3), которые не участвовали в обучении

**Таблица 2.** Гиперпараметры модели нейронной сети

Параметр	Значение
Количество дней прогноза	$K = 5$ дней
Временное окно (количество используемых дней для получения прогноза)	$L = 14$ дней
Число обучающих признаков	$M = 23$
Коэффициент спуска в градиентном методе	0.001
Размер батча (обучающих примеров, которые передаются модели одновременно для обработки во время одной итерации обучения)	20
Количество эпох (итераций работы градиентного метода для одного набора данных)	100



**Фиг. 7.** Схема кросс-валидации модели нейронной сети.



**Фиг. 8.** Сравнение новых заболевших COVID-19 (а) и подключенных к ИВЛ в Новосибирской области (б) (черные точки) с результатами моделирования с помощью нейронной сети (красная линия).

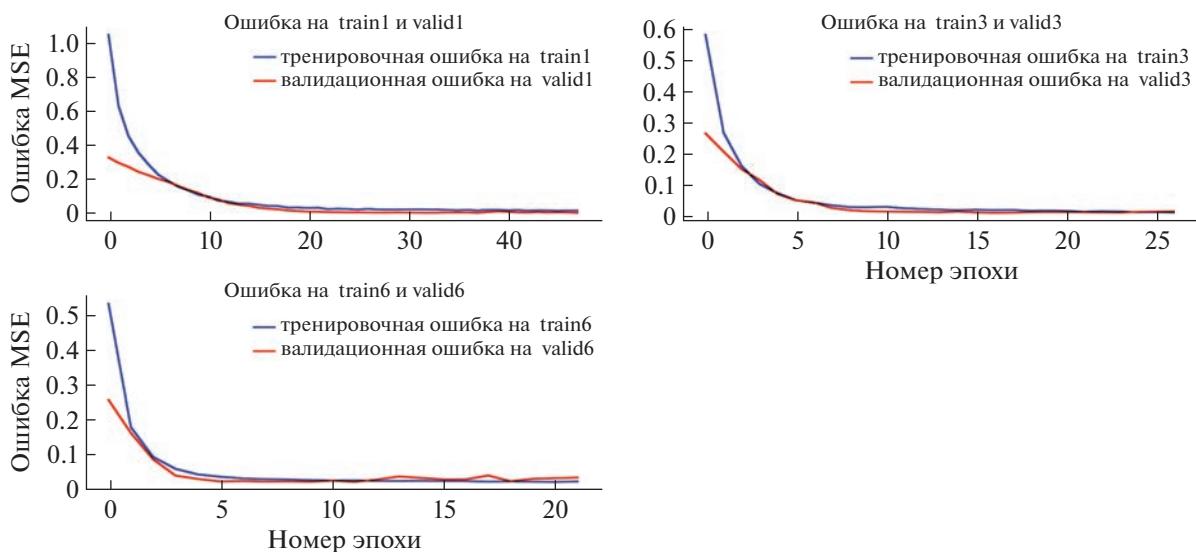
нейронной сети. Валидация обученной модели заключалась в сравнении реальных данных и предсказаний NN-COVID-19. После проведения семи итераций обучения-валидации данные, полученные на валидационных периодах valid1-valid7 (отмечены желтым цветом на фиг. 7), объединяются и сравниваются с истинными значениями.

#### 4. РЕЗУЛЬТАТЫ ЧИСЛЕННЫХ РАСЧЕТОВ

##### 4.1. Моделирование на валидационных периодах

Нейронная сеть была обучена для построения краткосрочных 5-дневных прогнозов количества новых заболевших COVID-19 и подключенных к аппарату ИВЛ. Для обучения сети делать более долгосрочные прогнозы необходим приемлемый набор обучающих примеров по вспышкам COVID-19, что в рамках одного региона недостижимо.

На фиг. 8 показаны результаты кросс-валидации модели (см. п. 3.4) на периоде с 2021-01-01 по 2022-01-15 (желтые области на графиках). На фиг. 8а представлена склейка 5-дневных про-



**Фиг. 9.** Среднеквадратичная ошибка на тренировочных train1, train3 и train6 (синяя кривая) и соответствующих валидационных данных valid1, valid3 и valid6 (красная кривая) по мере обучения нейронной сети.

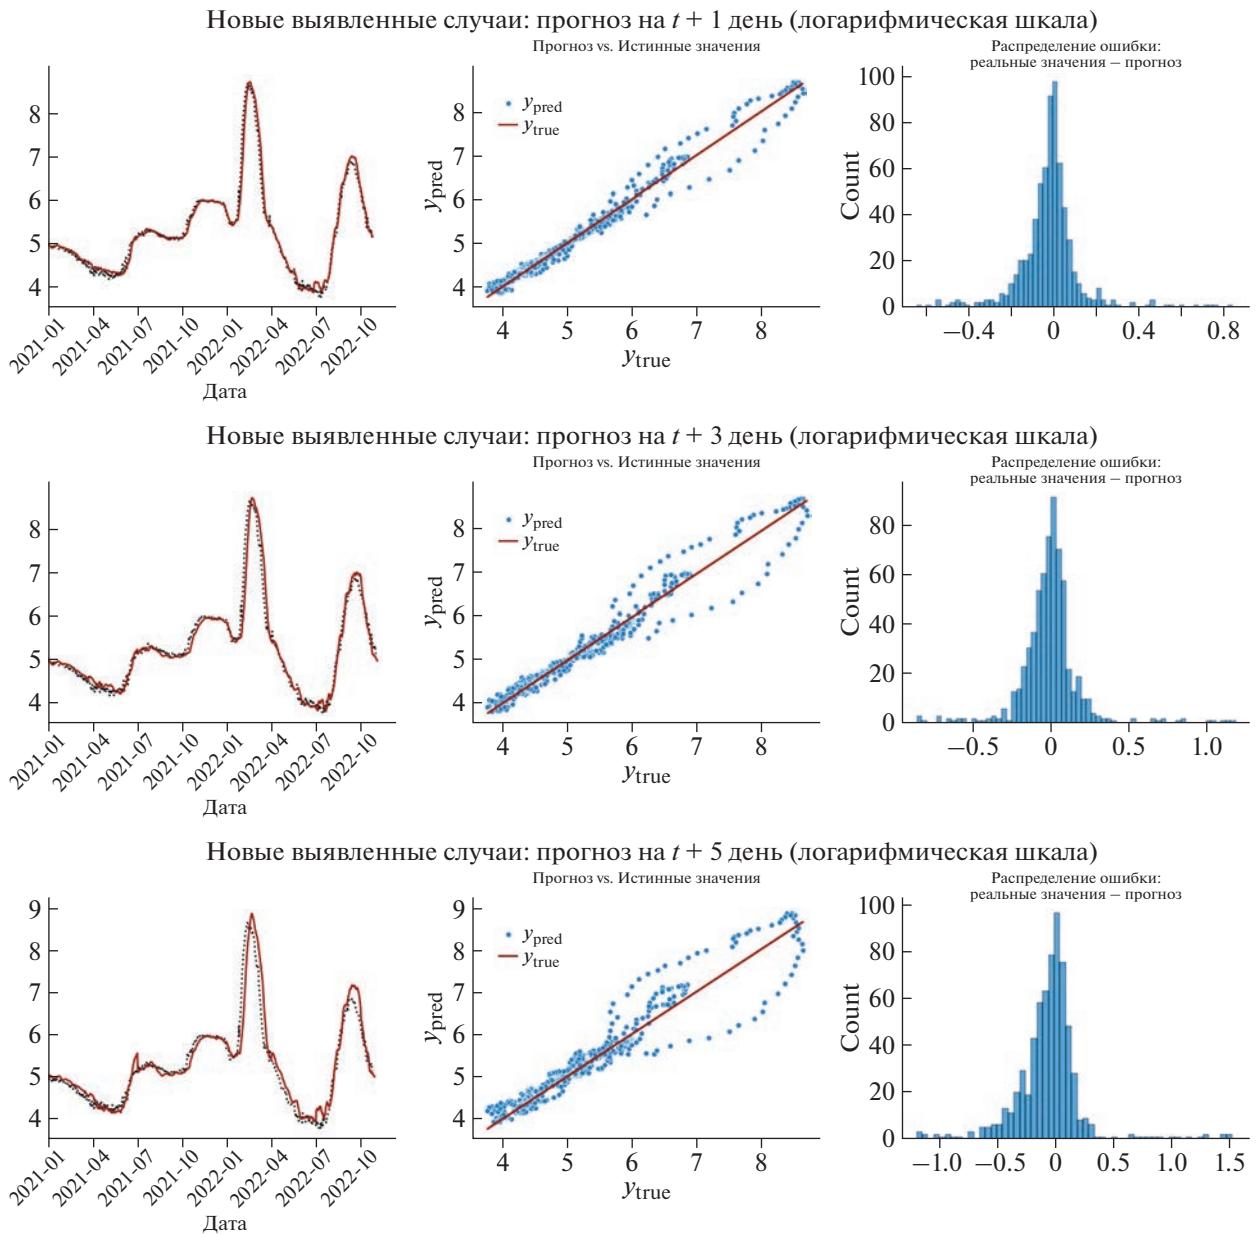
гновов новых заболевших COVID-19 в Новосибирской области, полученных с помощью обученной нейронной сети (красная кривая). Черными точками обозначены реальные данные новых заболевших COVID-19 в Новосибирской области. На фиг. 8б представлена склейка 5-дневных прогнозов количества больных COVID-19, подключенных к ИВЛ в Новосибирской области, полученные с помощью обученной нейронной сети (красная кривая). Черными точками обозначены реальные данные количества больных COVID-19, подключенных к ИВЛ в Новосибирской области. Показано хорошее соответствие с реальными данными на указанном промежутке с близкими по своей природе вспышками заболевания.

На фиг. 9 приведены кривые среднеквадратичных ошибок на различных тренировочных и соответствующих им валидационных периодах из фиг. 7. Отметим, что по мере обучения нейронной сети на тренировочных периодах и снижения среднеквадратичного отклонения прогнозных значений от истинных (синие кривые), ошибка на соответствующих валидационных периодах также снижается (красные кривые), что подтверждает эффективность выбранных данных и архитектуры нейронной сети.

На фиг. 10 приведено сравнение прогнозов новых заболевших COVID-19 в день  $t + 1$ ,  $t + 3$  и  $t + 5$  с истинными значениями. Использована логарифмическая шкала. Чем ближе синие точки расположены к красной линии на центральных графиках, тем выше точность прогноза. При увеличении времени прогноза среднеквадратичная ошибка увеличивается (графики в центре и справа на фиг. 10), хотя в абсолютных значениях ошибка не сильно заметна (графики слева), погрешность достигает 2%.

Аналогично на фиг. 11 показано сравнение прогнозов количества индивидуумов, подключенных к ИВЛ в дни  $t + 1$ ,  $t + 3$  и  $t + 5$  с истинными значениями. Среднеквадратичная ошибка для данного показателя при увеличении дней прогноза больше (центральные и правые графики), однако абсолютные значения модельных предсказаний близки к истинным (графики слева).

В результате получена высокая точность совпадения прогнозов нейронной сети на данных вне выборки с реальными данными для временного промежутка с 2021-01-01 по 2022-01-01 и с 2022-08-01 по 2022-10-01 и приемлемая точность совпадения прогнозов нейронной сети на данных вне выборки с реальными данными для промежутка с 2022-01-01 по 2022-08-01. Снижение точности на периоде с 2022-01-01 по 2022-08-01 можно объяснить появлением вспышки штамма "Омикрон". Скорость роста эпидемиологических показателей была высока и не встречалась ра-

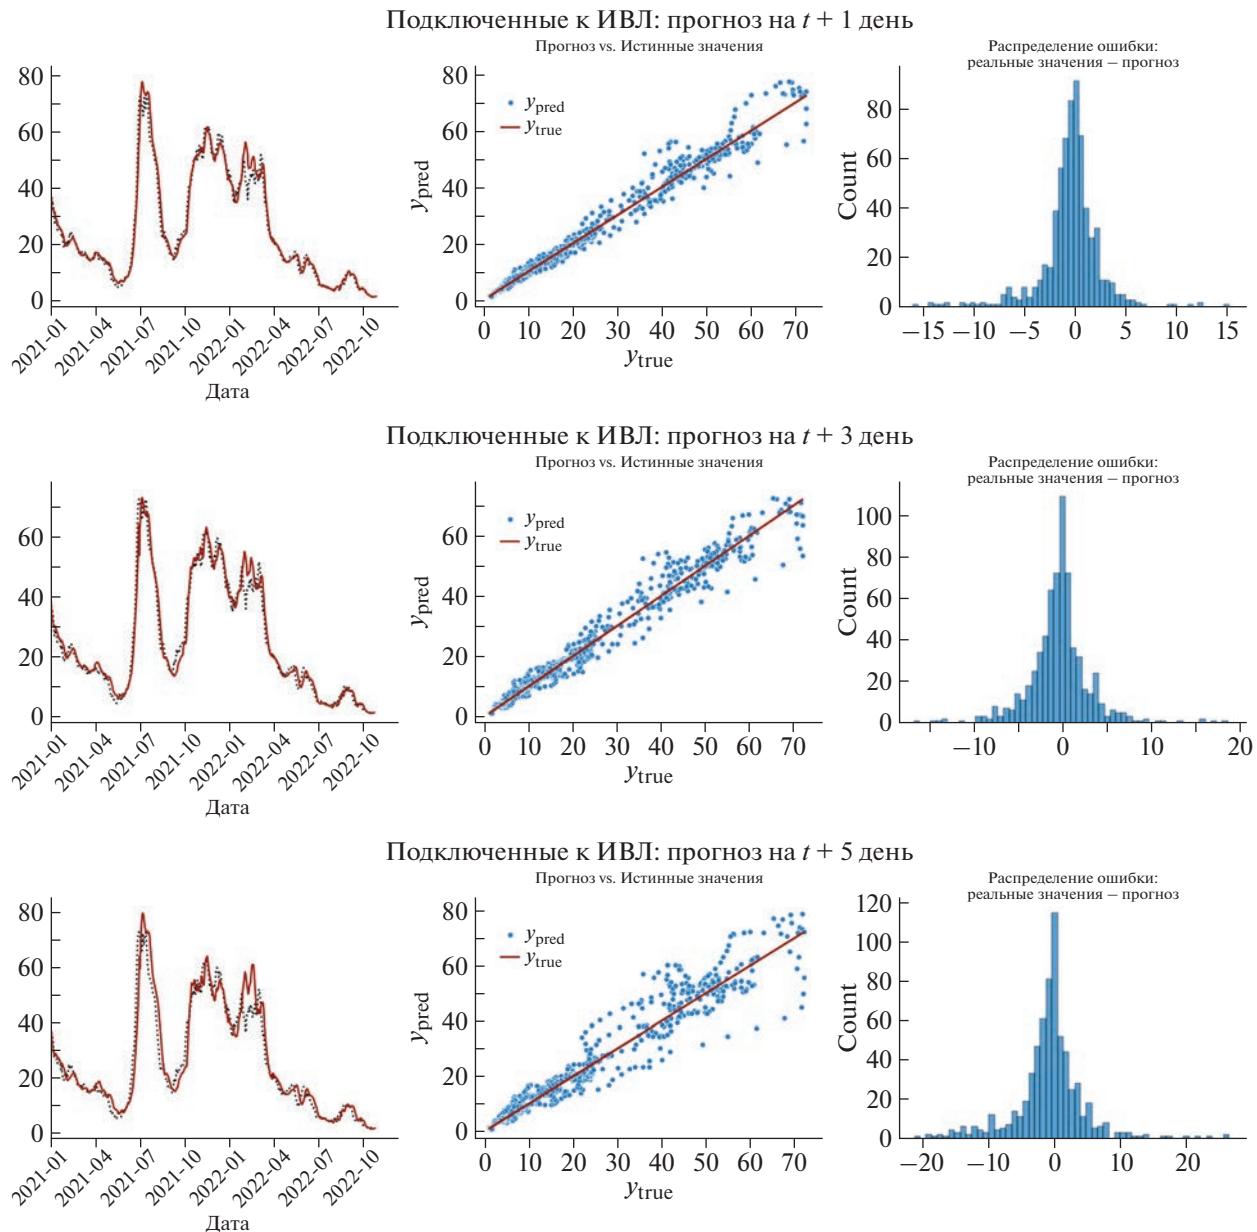


**Фиг. 10.** Сравнение прогноза нейронной сети (красная линия слева) новых заболевших COVID-19 в дни  $t + 1$ ,  $t + 3$  и  $t + 5$  с истинными значениями (черные точки слева). На среднем рисунке красная линия представляет собой зависимость истинных значений новых заболевших COVID-19 по отношению к себе. Синие точки обозначают зависимость спрогнозированных нейронной сетью значений по отношению к истинным. Разность истинных значений и полученных прогнозов отображена справа.

нее в данных, на которых обучалась нейронная сеть. Однако после дообучения нейронной сети с учетом данных контагиозности штамма “Омикрон” точность прогнозов модели вновь стала высокой при прогнозировании штамма “Кентавр” на периоде с 2022-08-01 по 2022-10-01.

#### 4.2. Сравнение с моделью SEIR-HCD

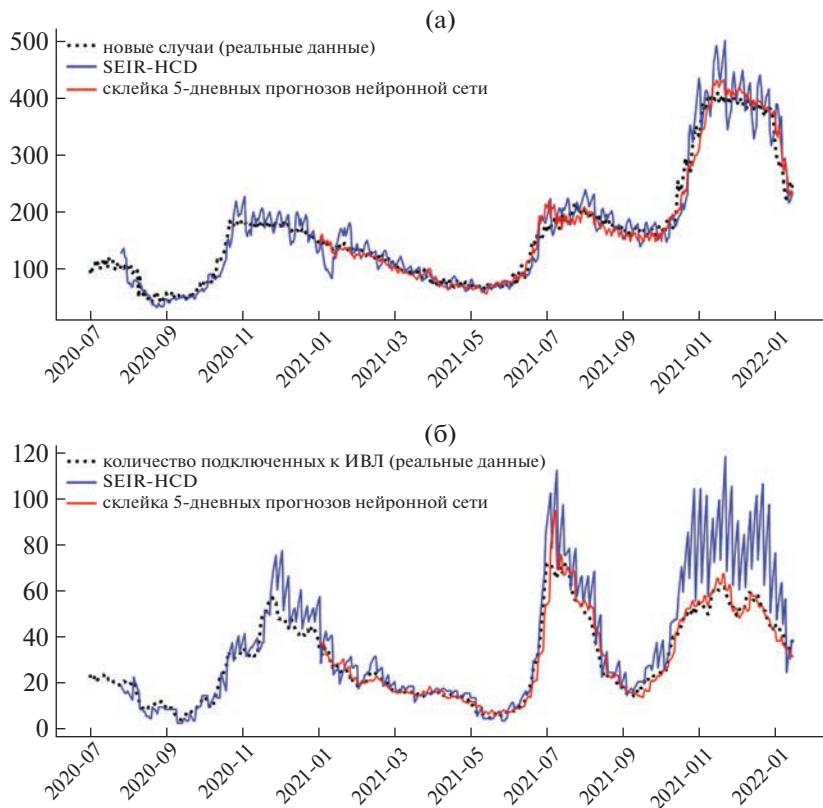
В [13, 14] была модифицирована дифференциальная SEIR-HCD модель распространения COVID-19 в регионах Российской Федерации, описываемая системой семи обыкновенных дифференциальных уравнений, связанных законом действующих масс. На фиг. 12а показано срав-



**Фиг. 11.** Сравнение прогноза нейронной сети количества подключенных к аппарату ИВЛ в дни  $t+1$ ,  $t+3$  и  $t+5$  с истинными значениями.

нение моделирования и краткосрочных базовых сценариев ежедневных заболевших COVID-19 (черные точки), полученных нейронной сетью (красная линия) с результатами модели SEIR-HCD (синяя линия). На фиг. 12б показано сравнение моделирования и сценариев динамики количества больных COVID-19, подключенных к аппарату ИВЛ в Новосибирской области (черные точки), полученных моделью нейронной сети (красная линия) с результатами модели SEIR-HCD (синяя линия).

Показано преимущество модели нейронной сети перед классической дифференциальной моделью SEIR-HCD на краткосрочном периоде прогнозирования ожидаемых критических случаев, нуждающихся в подключении аппарата ИВЛ (фиг. 12б).



**Фиг. 12.** Сравнение новых заболевших COVID-19 (а) и подключенных к аппарату ИВЛ в Новосибирской области (б), полученных с помощью применения модели нейронной сети (красная линия) и модели SEIR-HCD (синяя линия). Черными точками обозначены реальные данные.

### ЗАКЛЮЧЕНИЕ

Построенная нейронная сеть NN-COVID-19, основанная на обработке реальных данных о распространении COVID-19 в Новосибирской области, показала полное совпадение с SEIR-HCD моделью до появления штамма Омикрон. После добавления для обучения реальных данных по Омикрону (с 01.2022 до 04.2022) NN-COVID-19 смогла предсказать динамику штамма Кентавр.

В течение трех месяцев после обучения нейросеть NN-COVID-19 предсказывает ожидаемое количество заболевших COVID-19 и подключенных к ИВЛ с точностью до 10%, в то время как модель SEIR-HCD должна обновлять параметры каждые 5 дней, что по времени примерно совпадает со временем обучения нейронной сети. Таким образом, нейронная сеть NN-COVID-19 демонстрирует 18-кратное преимущество перед SEIR-HCD с точки зрения времени вычислений.

### СПИСОК ЛИТЕРАТУРЫ

1. Zyatkov N., Krivorotko O. Forecasting recessions in the US economy using machine learning methods // The 17th International Asian school-seminar “Optimization problems of complex systems” (OPCS). 2021. P. 139–146.  
<https://doi.org/10.1109/OPCS53376.2021.9588678>
2. Chen S., Guo W. Auto-encoders in deep learning – a review with new perspectives // Mathematics 2023. V. 11. P. 1–54.
3. Jie Gui, Zhenan Sun, Yonggang Wen, Dacheng Tao, Jieping Ye. A review on generative adversarial networks: algorithms, theory, and applications // IEEE Transact. on Knowledge and Data Engineer. 2023. V. 35. № 4. P. 3313–3332.
4. Ling J., Jones R., Templeton J. Physics-informed machine learning: A new paradigm for computational mechanics // Comput. Meth. Appl. Mech. Engineer. 2016. V. 309. P. 209–233.

5. Leyva-Vallina M., Nagy Z. Data-driven vs. physics-based modeling: A comparison from an industrial perspective // Chemic. Engineer. Sci. 2018. V. 182. P. 80–93.
6. Huang Y., Zhang J., Yang X., Drury C.F., Reynolds W.D., Tan C.S. Comparing the performance of machine learning algorithms for predicting soil organic carbon stocks in different land use systems // Geoderma. 2020. V. 375. P. 114448.
7. Brunton S.L., Proctor J.L., Kutz J.N. Discovering governing equations from data by sparse identification of non-linear dynamical systems // Proceed. Nation. Acad. Sci. 2016. V. 113. № 15. P. 3932–3937.
8. Криворотько О.И., Кабанихин С.И. Математические модели распространения COVID-19. Препринт Ин-та матем. им. С.Л. Соболева СО РАН. 2022. № 300. 63 с.
9. Петров И.Б., Станкевич А.С., Васюков А.В. О поиске начального приближения в задаче волновой инверсии с помощью сверточных нейронных сетей // Докл. АН, 2023.
10. Nikparvar B., Rahman M.M., Hatami F., et al. Spatio-temporal prediction of the COVID-19 pandemic in US counties: modeling with a deep LSTM neural network // Sci. Rep. 2021. V. 11. P. 21715.
11. Shawaqfah M., Almomani F. Forecast of the outbreak of COVID-19 using artificial neural network: Case study Qatar, Spain, and Italy // Result. Phys. 2021. V. 27. P. 104484.
12. Гузев М.А., Никитина Е.Ю. Динамика “имперских хвостов” на примере коронавирусной инфекции // Дальневосточный матем. журн. 2022. Т. 22. № 1. С. 38–50.
13. Криворотько О.И., Кабанихин С.И., Зятков Н.Ю., Приходько А.Ю., Прохоршин Н.М., Шишленин М.А. Математическое моделирование и прогнозирование COVID-19 в Москве и Новосибирской области // Сиб. журн. вычисл. матем. 2020. Т. 23. № 4. С. 395–414.
14. Krivorotko O.I., Zyatkov N.Y. Data-driven regularization of inverse problem for SEIR-HCD model of COVID-19 propagation in Novosibirsk region // Eurasian J. Math. and Comput. Appl. 2022. V. 10. Iss. 1. P. 51–68.
15. Chen T., Guestrin C. XGBoost: A scalable tree boosting system. In Proceedings of the ACM SIGKDD international conference on knowledge discovery and data mining // ACM. 2016. P. 785–794.
16. Hochreiter S., Schmidhuber J. Long short-term memory // Neural Computat. 1997. V. 9. № 8. P. 1735–1780.
17. Srivastava N., Hinton G., Krizhevsky A., Sutskever I., Salakhutdinov R. Dropout: A simple way to prevent neural networks from overfitting // J. Mach. Learn. Res. 2014. V. 15. № 1. P. 1929–1958.
18. Ioffe S., Szegedy C. Batch normalization: Accelerating deep network training by reducing internal covariate shift // Inter. Conf. Mach. Learn. 2015. V. 37. P. 448–456.
19. Nair V., Hinton G.E. Rectified linear units improve restricted Boltzmann machines // Proceed. of the 27th Inter. Conf. Mach. Learn. (ICML-10). 2010. P. 807–814.