

МАТЕМАТИЧЕСКАЯ МОДЕЛЬ ИНТЕЛЛЕКТУАЛЬНОЙ СИСТЕМЫ ПРОГНОЗИРОВАНИЯ ИНСУЛЬТА И ЕЁ РЕАЛИЗАЦИЯ НА БАЗЕ ГИБРИДНОГО НЕЙРОСЕТЕВОГО АЛГОРИТМА РЕКУРРЕНТНОГО ТИПА

MATHEMATICAL MODEL OF AN INTELLIGENT STROKE PREDICTION SYSTEM AND ITS IMPLEMENTATION BASED ON A HYBRID NEURAL NETWORK ALGORITHM OF RECURRENT TYPE

V. Maslennikov

Summary. The task of binary classification based on the use of a connected complex of recurrent neural networks with a modified architecture of LSTM (Long Short-Term Memory) and GRU (Gated Recurrent Units) is considered in order to predict the possibility of a stroke in the human brain. The aim of the work is to obtain mathematical algorithms that determine the principles of functioning of neural network modules to search for patterns in data containing information about patients who have been diagnosed for stroke, as well as the software implementation of neural network modules as a single intelligent system. Obtaining mathematical algorithms is carried out on the basis of a conceptual analysis of experimental studies on the development of binary classifiers using recurrent algorithms for intelligent prediction, and individual structural and parametric aspects of artificial neural networks of a recurrent type. The software implementation is performed using the TensorFlow machine learning library. Mathematical algorithms of neural network modules are obtained in the form of systems of equations that model the concept of internal short-term memory to find the correlation in data between the values of quantitative and categorical variables. The results of the software implementation of an intelligent system using training, validation and test samples, formed on the basis of a set from a machine learning data repository, are presented.

Keywords: artificial intelligence, mathematical modeling, deep learning, recurrent neural networks, stroke prediction, binary classifier.

Масленников Владимир Владимирович

Институт информационных технологий
Российский технологический университет МИРЭА
Москва
vldmsn@yahoo.com

Аннотация. Рассматривается задача бинарной классификации на основе применения связанного комплекса рекуррентных нейронных сетей с модифицированной архитектурой LSTM (Long Short-Term Memory) и GRU (Gated Recurrent Units) с целью прогнозирования возможности возникновения инсульта в головном мозге человека. Целью работы является получение математических алгоритмов, определяющих принципы функционирования нейросетевых модулей для поиска закономерностей в данных, содержащих информацию о пациентах, у которых проводилась диагностика на наличие инсульта, а также программная реализация нейросетевых модулей в виде единой интеллектуальной системы. Получение математических алгоритмов осуществляется на основе концептуального анализа экспериментальных исследований по разработке бинарных классификаторов с применением рекуррентных алгоритмов интеллектуального прогнозирования, и отдельных структурно-параметрических аспектов искусственных нейронных сетей рекуррентного типа. Программная реализация выполняется при помощи библиотеки машинного обучения TensorFlow. Получены математические алгоритмы нейросетевых модулей в виде систем уравнений, моделирующих концепцию внутренней краткосрочной памяти, для нахождения корреляционной зависимости в данных между значениями количественных и категориальных переменных. Приведены результаты программной реализации интеллектуальной системы с использованием обучающей, валидационной и тестовой выборок, сформированных на основе набора из репозитория данных машинного обучения.

Ключевые слова: искусственный интеллект, математическое моделирование, глубокое обучение, рекуррентные нейронные сети, прогнозирование инсульта, бинарный классификатор.

Введение

С начала 90-х годов и по настоящее время продолжается новая эпоха искусственного интеллекта, характеризующаяся отклонением от идеи реализации мышления человека за счёт применения технических методов и сосредоточением на самостоятельных направлениях, например, как искусственные нейронные сети, компьютерное зрение, распознавание

и синтез речи, обработка естественного языка. Также термин «искусственный интеллект» заменяется на более конкретные: интеллектуальные системы, машинное обучение, глубокий анализ данных, генетические алгоритмы, конечные автоматы и другие понятия [1]. Стремительное развитие машинного обучения, увеличение массивов данных разного типа и появление технологий, предоставляющих возможность обеспечивать хранение, доступность и обработку этих данных, спо-

способствовали возникновению нового специализированного направления, которое ориентировано на создание и использование интеллектуальных систем в сфере здравоохранения [2, 3]. На текущий момент одним из немаловажных вопросов является разработка системы для решения задачи прогнозирования инсульта.

Инсульт, как острое нарушение кровоснабжения головного мозга, представляет собой одно из самых распространённых и опасных заболеваний. По статистике в мире ежегодно регистрируется около 15 миллионов подобных случаев, из которых более 5 миллионов заканчиваются смертельным исходом, а остальные — инвалидностью различной степени тяжести [4, 5], в том числе с патологией речи, когнитивными нарушениями, психическими расстройствами или проявлением тетраплегии [6]. При этом восстановительным лечением не всегда удаётся достигнуть ожидаемых положительных результатов ввиду того, что в процессе реабилитации важную роль играют не только назначенный курс терапии в зависимости от степени поражения головного мозга, но и возраст самого пациента, поскольку это один из основных критериев, влияющих на возможность регенерации организма. По этим причинам встаёт острая необходимость в узкоспециализированном медицинском программном средстве раннего предупреждения о риске возникновения инсульта.

С точки зрения машинного обучения, прогнозирование любого заболевания — это задача бинарной или мультиклассовой классификации, то есть задача отнесения каждого объекта набора данных (в частности, пациента) к одной из заданных категорий на основе значений его признаков (в частности, показателей состояния здоровья). В настоящем исследовании используется подход бинарной классификации с выходным результатом в виде двух взаимоисключающих классов, определяющих либо наличие склонности к инсульту, либо её отсутствие.

Для установления класса объекта существует множество готовых алгоритмов и методов, например: метод опорных векторов, дерево решений и случайный лес, наивный байесовский метод, метод k-ближайших соседей и другие [7–9]. Однако стандартные алгоритмы и методы не всегда эффективны вследствие получения неточного прогноза, что обуславливается существованием характерных для каждого алгоритма недостатков. В частности, при использовании наивного байесовского метода не учитывается статистическая зависимость случайных величин, фигурирующих в выражении для апостериорной вероятности принадлежности объекта к классу, метка которого зафиксирована в целевом признаке. Чтобы решить эту проблему, требуется проведение дополнительных преобразований векторов

признаков в вид, позволяющий снизить влияние их зависимости на точность получаемых результатов.

Для нивелирования влияния недостатков перечисленных алгоритмов и методов на количество ложноположительных и ложноотрицательных прогнозов, в данной работе предлагается комбинированный нейросетевой алгоритм, основанный на объединении долгой краткосрочной памяти и стробируемых рекуррентных единиц, а также на добавлении отдельного модуля полносвязной рекуррентной нейронной сети.

Таким образом, взаимодействие с искусственными нейронными сетями рекуррентного типа позволит не только значительно снизить склонность к переобучению, уменьшить число ошибок в классификационных решениях, чувствительность к выбросам и пропускам в данных, но и повысить при этом процент прогностической значимости результатов предсказаний, то есть увеличить процент предсказаний с истинно положительным или истинно отрицательным результатами.

1. Теоретическая часть

1.1. Теоретические аспекты разведочного анализа данных

Разведочный анализ — это процесс предварительного изучения данных, основная задача которого заключается в определении свойств и выявлении общих закономерностей анализируемой информации. Такое исследование помогает выполнять углублённый анализ данных, выдвигать гипотезы, уточнять возможности применения каких-либо математических методов и моделей.

К фундаментальным методам проведения разведочного анализа относятся: корреляционный анализ с целью поиска коэффициентов, превышающих по величине некоторые пороговые значения, анализ распределений переменных, визуализация количественных данных и другие.

Любой набор данных возможно представить в качестве табличной структуры — датафрейма, столбцы которого являются количественными (численными) или категориальными признаками.

Если говорить о количественных признаках, стоит отметить, что в данных этого вида могут содержаться выбросы — значения, которые сильно отличаются от большинства в наборе, то есть выходят за рамки общей тенденции, присутствующей в данных. Идентификация такого рода артефактов критически необходима, так как они не только влияют на общую стандартную ва-

риацию и распределение данных, но и, например, указывают на наличие ранее неизвестного явления, искажают статистические показатели ввиду существенной чувствительности описательной статистики к выбросам, а также мешают обучению алгоритма и, как следствие, вызывают смещение в оценке точности модели [10]. По этим причинам обработка выбросов позволяет предотвратить ошибки при предварительном анализе информации и повысить точность результатов исследования.

Для оценки степени линейной связи количественных признаков наиболее часто применяется метод параметрической корреляции Пирсона. Такой подход позволяет проводить глубокий анализ и использовать полученные результаты при проверке гипотез. Согласно работе [11], для заданных выборок $x = (x_1, x_2, \dots, x_n)$ и $y = (y_1, y_2, \dots, y_n)$ из генеральной совокупности некоторой предметной области коэффициент корреляции Пирсона вычисляется как:

$$r_{xy} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} = \frac{cov(x, y)}{\sigma_x \sigma_y},$$

$$r_{xy} \in [-1, 1], \quad (1)$$

где \bar{x}, \bar{y} — выборочные средние;
 σ_x, σ_y — стандартные отклонения для x и y .

При этом выборки x, y считаются линейно зависимыми, если $|r_{xy}| = 1$, и линейно независимыми в случае $|r_{xy}| = 0$.

Чем ближе значение коэффициента корреляции Пирсона по модулю к единице, тем качественнее и достовернее линейная модель. Однако в действительности феномен полной взаимосвязи двух признаков практически невозможен. Наоборот, в большинстве случаев значение коэффициента корреляции Пирсона может быть как значительно меньше единицы, так и приблизительно равно нулю. Последнее прослеживается в контексте слабой ассоциации, что в соответствии с [12] указывает на регрессию к среднему.

Оценить взаимозависимость категориальных признаков можно, применив критерий согласия Пирсона [13]. Данный непараметрический метод позволяет установить статистическую значимость различий между относительными характеристиками двух признаков. Критерий представляется формулой:

$$\chi_c^2 = \sum_{i=1}^n \frac{(O_i - E_i)^2}{E_i}, \quad (2)$$

где O_i — реальное значение признака;
 E_i — ожидаемое значение признака.

Также немаловажным этапом разведочного анализа является определение взаимосвязи бинарных категориальных и количественных признаков. В тех случаях, когда одно значение признака измеряется в номинальной дихотомической шкале, а другое в шкале интервалов и отношений, используется точечно-бисериальный коэффициент корреляции [14]. Поскольку в данном виде корреляции дихотомия отражает подлинную природу дискретного признака, знак её коэффициента определяется произвольно и лежит в диапазоне от -1 до $+1$. Точечно-бисериальная корреляция вычисляется как:

$$r_{pbis} = \frac{\bar{x}_1 - \bar{x}_0}{\sigma_x} \sqrt{\frac{n_1 n_0}{n(n-1)}}, \quad r_{pbis} \in [-1, 1], \quad (3)$$

где \bar{x}_1 — среднее значение признаков, у которых номинальный признак у равен 1;

\bar{x}_0 — среднее значение признаков, у которых номинальный признак у равен 0;

σ_x — стандартное отклонение всех значений по x ;

n_1 — количество признаков, у которых номинальный признак у равен 1;

n_0 — количество признаков, у которых номинальный признак у равен 0;

n — объём выборки.

1.2. Теоретическое описание модели интеллектуальной системы автоматического прогнозирования инсульта

Рассматриваемая далее математическая архитектура системы автоматического прогнозирования инсульта опирается на специфику построения и параметризации искусственных нейронных сетей рекуррентного типа [15–17]. Рекуррентные нейронные сети RNN (Recurrent Neural Networks) являются классом сетей с внутренней памятью, где связи между элементами образуют направленную последовательность. RNN основываются на концепции реализации краткосрочной памяти в нейронных сетях, когда на вход нейрона вместе с информацией о текущем состоянии системы подаётся информация о предыдущем состоянии этого нейрона. Данное решение исходит из предположения о том, что значение на выходе нейрона учитывает влияние всех факторов, включая предыдущее состояние нейрона, и на следующем шаге передаётся с накопленными «знаниями» в будущее состояние нейрона. При этом срок действия такой памяти и её влияние на текущее состояние нейрона зависит строго от ве-

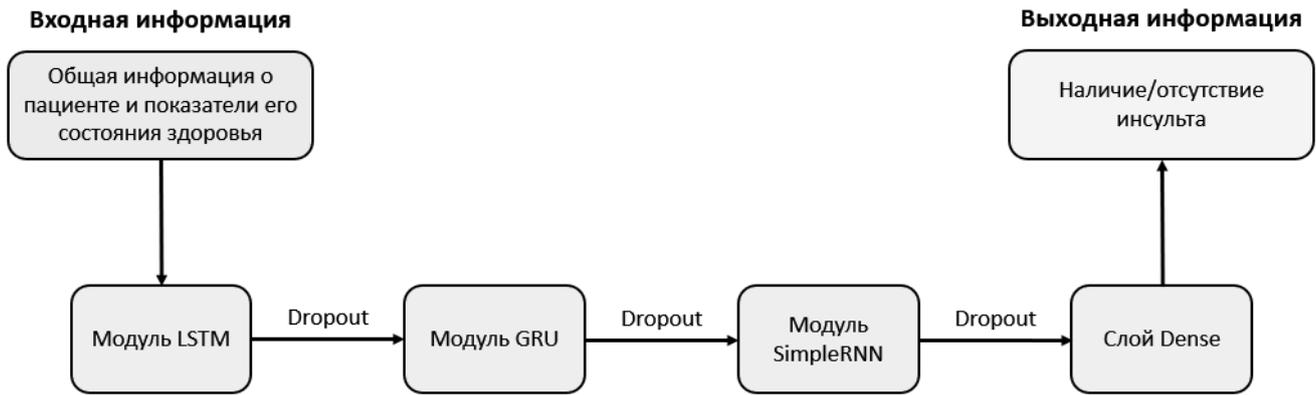


Рис. 1. Структурная схема интеллектуальной системы автоматического прогнозирования инсульта

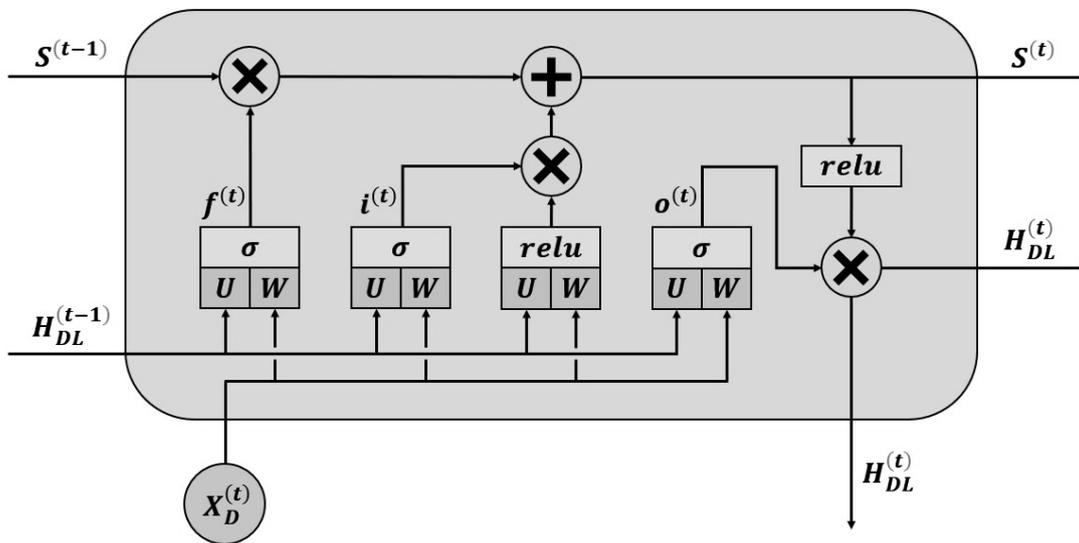


Рис. 2. Структурная схема модуля LSTM-сети с вентилями забывания

совых коэффициентов. В работе [15] отмечается, что подобный подход обладает негативной особенностью в виде проблемы исчезающего (взрывного) градиента, при которой сохранение памяти осуществляется лишь на коротком временном отрезке и, как следствие, происходит быстрая потеря информации — цикличность умножения сигнала на значение коэффициента меньше 1 и применение функции активации нейрона приводит к постепенному затуханию сигнала с ростом количества этих циклов.

Для моделирования интеллектуальной системы предлагается использование гибридной конфигурации нейронной сети, состоящей из последовательно располагающихся модулей долгой краткосрочной памяти LSTM (Long Short-Term Memory), стробируемых рекур-

рентных единиц GRU (Gated Recurrent Units), простой полносвязной сети SimpleRNN и выходного полносвязного слоя Dense (рисунок 1). Кроме того, дополнительно применяется метод Dropout, реализующий регуляризацию нейронных сетей.

Традиционная LSTM-сеть с вентилями забывания является нейронной сетью с тремя входными и выходными каналами [18], два из которых предназначены для обмена данными в формате «вход-выход», а остальные замкнуты попарно для циклического обмена данными (рисунок 2). Внутри модуля LSTM содержится два потока информации, связанные между собой четырьмя полносвязными нейронными сетями. Каждый нейронный слой обладает одинаковым количеством нейронов, равным размеру выходного потока и потока памяти.

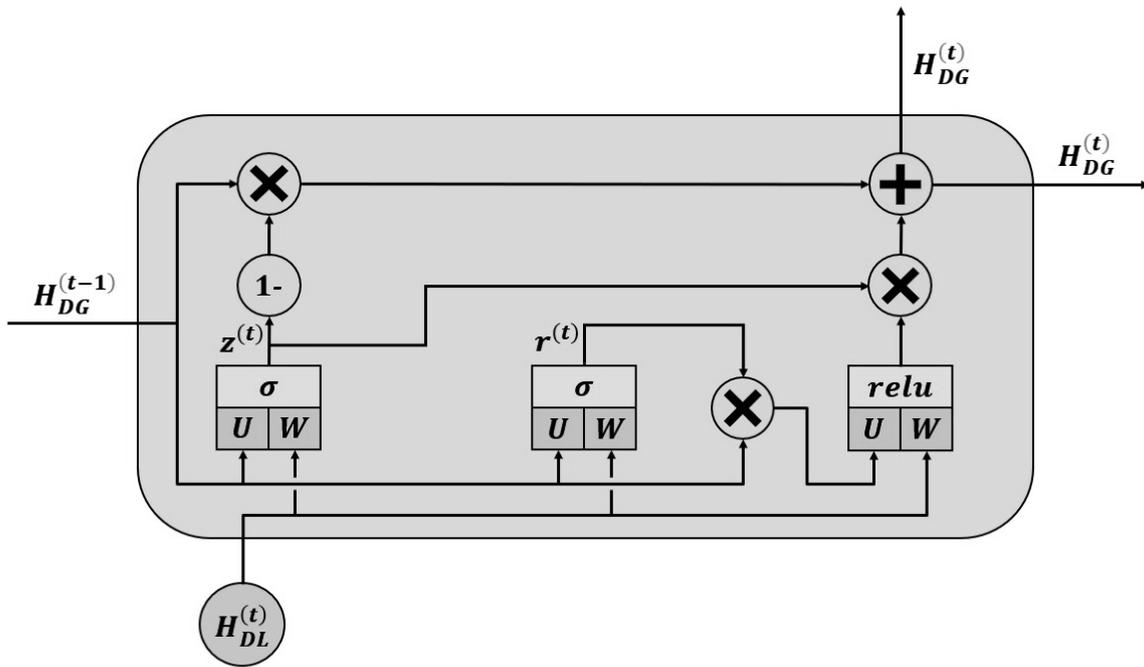


Рис. 3. Структурная схема модуля GRU-сети

На вход LSTM-сети подаётся набор векторов $(X_n^{(1)}, X_n^{(2)}, \dots, X_n^{(n)})$ при $X_D^{(n)} = (x_1, x_2, \dots, x_m)$, где x_i ($i = 1, m$) — признак набора данных. Тогда формальное описание модуля с обнулением компонент внутреннего состояния $S^{(t-1)}$ можно задать следующей совокупностью уравнений:

$$Net_{LSTM} = \begin{cases} f^{(t)} = \sigma(W^{(f)} X_D^{(t)} + U^{(f)} H_{DL}^{(t-1)} + b_f) \\ i^{(t)} = \sigma(W^{(i)} X_D^{(t)} + U^{(i)} H_{DL}^{(t-1)} + b_i) \\ o^{(t)} = \sigma(W^{(o)} X_D^{(t)} + U^{(o)} H_{DL}^{(t-1)} + b_o) \\ S^{(t)} = i^{(t)} \odot \phi(W^{(s)} X_D^{(t)} + U^{(s)} H_{DL}^{(t-1)} + b_s) + f^{(t)} \odot S^{(t-1)} \\ H_{DL}^{(t)} = o^{(t)} \odot \phi(S^{(t)}) \end{cases}, \quad (4)$$

при

$$\sigma(z) = \frac{1}{1 + e^{-z}}, \quad (5)$$

где $X_D^{(t)}$ — входной вектор;
 $S^{(t)}$ — вектор состояний;
 $H_{DL}^{(t)}$ — выходной вектор;
 $f^{(t)}$ — вектор вентиля забывания;
 $i^{(t)}$ — вектор входного вентиля;
 $o^{(t)}$ — вектор выходного вентиля;
 W, U — матрицы параметров;
 \odot — произведение Адамара;
 b — вектор смещения;

t — номер шага;

σ — функция активации на основе сигмоиды;

ϕ — функция активации на основе линейного выпрямителя ReLU;

z — взвешенная сумма входов нейрона.

В LSTM и последующих модулях, в дополнение к рекуррентной сигмоидной активационной функции, для уменьшения физического времени обучения нейронных сетей за счёт использования меньшего объёма вычислительных ресурсов и инактивации некоторых нейронов применяется линейный выпрямитель ReLU:

$$\phi(z) = \begin{cases} z, & z \geq 0 \\ 0, & z < 0 \end{cases} \quad (6)$$

Реализация сети стробируемых рекуррентных единиц GRU, изображённой на рисунке 3, исходит из принципов построения предыдущего модуля, но с меньшим числом параметров и операций для вычисления $H_{DG}^{(t)}$, поскольку данный механизм характеризуется отсутствием выходного вентиля $o^{(t)}$.

Для Net_{GRU} целесообразно ввести описание дополнительных фильтров обновления $z^{(t)}$ и сброса состояния $r^{(t)}$. Вектор вентиля обновления принимает вид:

$$z^{(t)} = \sigma(W^{(z)} H_{DL}^{(t)} + U^{(z)} H_{DG}^{(t-1)} + b_z) \quad (7)$$

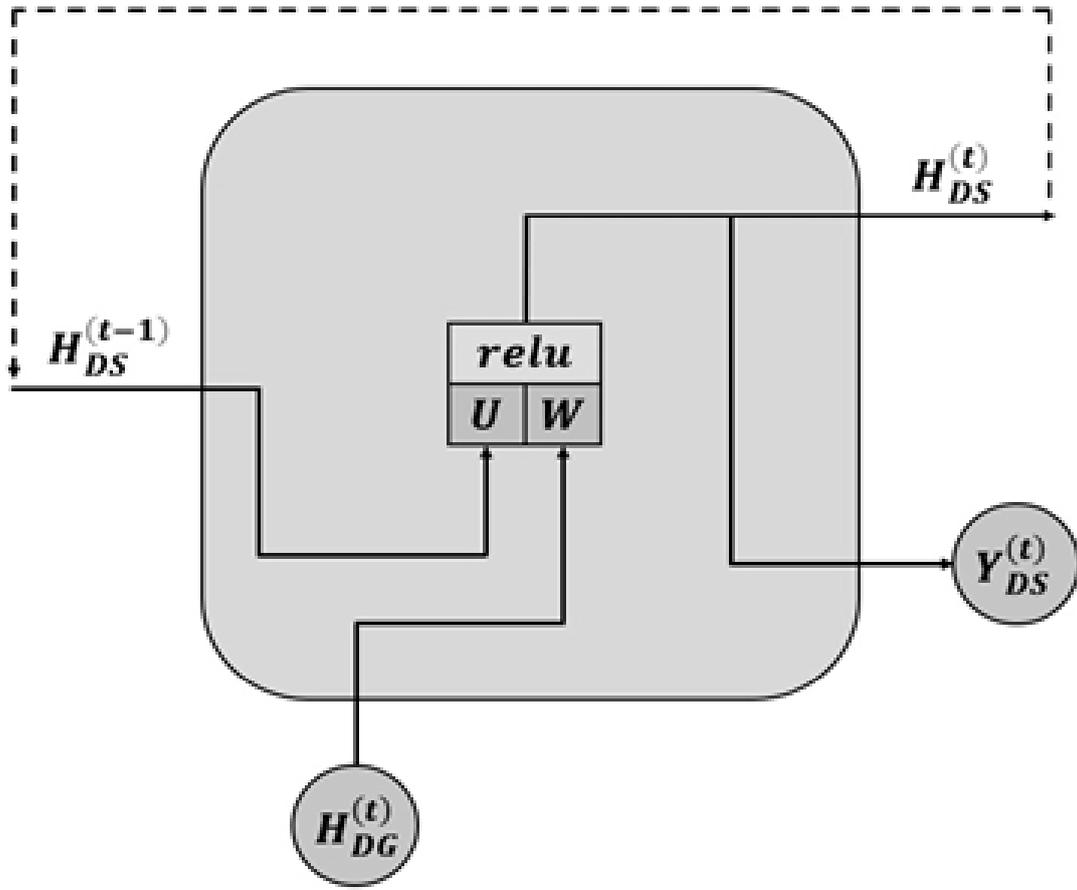


Рис. 4. Структурная схема модуля простой рекуррентной сети Элмана

В аналогичном виде записывается вектор вентиля сброса:

$$r^{(t)} = \sigma \left(W^{(r)} H_{DL}^{(t)} + U^{(r)} H_{DG}^{(t-1)} + b_r \right) \quad (8)$$

Выходное значение $H_{DG}^{(t)}$ вычисляется на основе промежуточного значения $\tilde{H}_{DG}^{(t)}$, которое при помощи вентиля сброса состояния (8) определяет условия исключения значений предыдущего шага $H_{DG}^{(t-1)}$:

$$\tilde{H}_{DG}^{(t)} = \phi \left(W^{(H)} H_{DL}^{(t)} + U^{(H)} (r^{(t)} \odot H_{DG}^{(t-1)}) + b_H \right) \quad (9)$$

Исходя из предложенных уравнений векторов $z^{(t)}$, $r^{(t)}$ и промежуточного значения $\tilde{H}_{DG}^{(t)}$ (7) — (9), общую формулировку расчёта выходного вектора модуля Net_{GRU} можно представить в качестве системы:

$$Net_{GRU} = \begin{cases} z^{(t)} = \sigma \left(W^{(z)} H_{DL}^{(t)} + U^{(z)} H_{DG}^{(t-1)} + b_z \right) \\ r^{(t)} = \sigma \left(W^{(r)} H_{DL}^{(t)} + U^{(r)} H_{DG}^{(t-1)} + b_r \right) \\ \tilde{H}_{DG}^{(t)} = \phi \left(W^{(H)} H_{DL}^{(t)} + U^{(H)} (r^{(t)} \odot H_{DG}^{(t-1)}) + b_H \right) \\ H_{DG}^{(t)} = (1 - z^{(t)}) \odot H_{DG}^{(t-1)} + z^{(t)} \odot \tilde{H}_{DG}^{(t)} \end{cases}, \quad (10)$$

где $H_{DL}^{(t)}$ — входной вектор;
 $H_{DG}^{(t)}$ — выходной вектор;
 $z^{(t)}$ — вектор вентиля обновления;
 $r^{(t)}$ — вектор вентиля сброса;
 W, U — матрицы параметров;
 \odot — произведение Адамара;
 b — вектор смещения;
 t — номер шага;
 σ — функция активации на основе сигмоиды;
 ϕ — функция активации на основе линейного выпрямителя ReLU.

Заключительный модуль является простой рекуррентной сетью Элмана [19], состоящей из трёхслойной нейронной сети с дополнительным набором специализированных контекстных блоков. Скрытый слой соединяется с контекстными блоками с единичным весом. В соответствии с заданными правилами обучения на каждом временном шаге на вход сети подаётся информация, проходящая напрямую к выходному слою, при этом предыдущие значения скрытого слоя сохраняются в контекстных блоках фиксированными обратными связями, что позволяет сети сохранять своё текущее состояние. С учётом вектора

$H_{DG}^{(t)}$, полученного при обработке данных в модуле GRU, в общем виде вышесказанное интерпретируется как:

$$Net_{SRNN} = \begin{cases} H_{DS}^{(t)} = \phi \left(W^{(H)} H_{DG}^{(t)} + U^{(H)} H_{DS}^{(t-1)} + b_H \right), \\ Y_{DS}^{(t)} = W^{(Y)} H_{DS}^{(t)} + b_Y \end{cases}, \quad (11)$$

где $H_{DG}^{(t)}$ — вектор входного слоя;
 $H_{DS}^{(t)}$ — вектор скрытого слоя;
 $Y_{DS}^{(t)}$ — вектор выходного слоя;
 W, U — матрицы параметров;
 b — вектор смещения;
 ϕ — функция активации на основе линейного выпрямителя ReLU.

Модуль простой рекуррентной сети Элмана с указанием векторов для входного и скрытого слоёв представлен на рисунке 4.

В процессе обучения нейронных сетей на вход каждого нейрона подаётся большое число признаков, что оказывает воздействие на повышение сложности оценки влияния каждого из них. Это приводит к эффекту «совместной адаптации признаков», когда ошибки одних нейронов сглаживаются правильными значениями других, в результате чего ошибки накапливаются на выходе сети и обучение останавливается в локальном минимуме с достаточно большой ошибкой.

Для снижения влияния указанного эффекта применяется исключение (Dropout) некоторой части нейронов за счёт регуляризации нейронных сетей, уменьшающей переобучение предотвращением сложных коадаптаций отдельных нейронов на тренировочной выборке данных во время обучения.

Нейроны исключаются из сети с вероятностью p (т.е. происходит выключение нейрона). Следовательно, вероятность того, что нейрон останется в сети, равна $q = 1 - p$. Исключение нейрона означает, что при любых данных, подающихся на вход, или параметрах, возвращается 0. Также стоит отметить, что вероятность выключения каждого нейрона всегда одинакова. По этой причине при условии того, что $h(\mathbf{z}) = W\mathbf{z} + b$ есть линейная проекция входного τ -мерного вектора \mathbf{z} на u -мерное пространство выходных значений и $a(h)$ — функция активации, то использование исключения к данной проекции на этапе обучения представляется в форме изменённой функции активации:

$$f(h) = Da(h), \quad (12)$$

где D в общем виде определяет $(X^{(1)}, X^{(2)}, \dots, X^{(v)})$ как v -мерный вектор случайных величин $X^{(i)}$, распределённых в соответствии с законом Бернулли.

Учитывая все возможные выходные значения k , распределение вероятностей $X^{(i)}$ представляется в виде:

$$f(k; p) = \begin{cases} p, k = 1 \\ 1 - p, k = 0 \end{cases} \quad (13)$$

Если нейроны исключаются из сети с вероятностью $p = P(k = 1)$, а в ином случае остаются рабочими, то при условии $p = P(X^{(i)} = 0)$ применение метода Dropout к i -му нейрону можно описать как:

$$O^{(i)} = X^{(i)} \frac{a \left(\sum_{k=1}^{\tau} W^{(k)} \mathbf{z}^{(k)} + b \right)}{q} = \begin{cases} \frac{a \left(\sum_{k=1}^{\tau} W^{(k)} \mathbf{z}^{(k)} + b \right)}, X^{(i)} = 1 \\ 0, X^{(i)} = 0 \end{cases}, \quad (14)$$

где $X^{(i)}$ — случайная величина, распределённая по закону Бернулли;

\mathbf{z} — входной вектор;
 W — матрица параметров;
 b — вектор смещения;
 q — вероятность включённого нейрона;
 a — функция активации.

Так как на этапе обучения нейрон остаётся в сети с вероятностью q , то на этапе тестирования требуется эмулировать поведение ансамбля нейронных сетей, использованного в обучении. Чтобы избавиться от периодического изменения сети для проведения тестирования, в (14) применяется подход «обратного исключения», позволяющий одновременно описать модель и запускать обучение с тестированием, изменяя только коэффициент Dropout. В данном случае функция активации умножается на коэффициент только на этапе обучения сети, где коэффициент равен обратной величине вероятности того, что нейрон останется активным $1/(1 - p) = 1/q$. Исходя из вышесказанного, применение метода Dropout на этапе тестирования отражается формулой:

$$O^{(i)} = a \left(\sum_{k=1}^{\tau} W^{(k)} \mathbf{z}^{(k)} + b \right), \quad (15)$$

\mathbf{z} — входной вектор;
 W — матрица параметров;
 b — вектор смещения;
 a — функция активации.

Таблица 1. Описание признаков исходного датафрейма

Признак	Описание
gender	пол пациента
age	возраст пациента
hypertension	наличие/отсутствие гипертонии
heart_disease	наличие/отсутствие заболевания сердца
ever_married	пациент состоит/не состоит в браке
work_type	вид занятости
residence_type	место проживания
avg_glucose_level	средний уровень глюкозы в крови
bmi	индекс массы тела (body mass index)
smoking_status	статус курения пациента
stroke	пациент перенёс/не переносил инсульт

Заключительным компонентом в структуре системы является полносвязный слой Dense, состоящий из нейронов, соединённых синапсами с элементами входного тензора [20] по его последнему индексу. При условии того, что размерность индекса равна dim , а параметры обучения задаются матрицей W и вектором b , то внутри слоя выполняется линейное преобразование:

$$m_{...j} = \sum_{i=0}^{dim-1} M^{int}_{...i} W_{ij} + b_j, \quad (16)$$

где M^{int} — промежуточная входная матрица.

Предлагаемый подход математического моделирования отражает ключевые принципы и параметрические аспекты функционирования системы прогнозирования инсульта на уровне составных элементов и межмодульного взаимодействия. При этом необходимо отметить, что данный подход в полной мере основывается на фундаментальной концепции работы нейросетевых алгоритмов, ориентированных на решение задач в области аналитики и бинарной прогностики. Отличительная особенность подхода заключается в использовании линейного выпрямителя, существенно повышающего скорость сходимости стохастического градиентного спуска ввиду линейного характера и отсутствия насыщения функции. Дополнительное введение промежуточных слоёв исключения после каждого модуля позволяет устранить возникновение эффекта переобучения нейронной сети.

2. Экспериментальная часть

Экспериментальные исследования в области проведения разведочного анализа данных, а также реализации и тестирования модели интеллектуальной системы выполнены в среде разработки Jupyter Notebook и с применением высокоуровневого языка программирования Python версии 3.10.

2.1. Разведочный анализ экспериментального набора данных

Обеспечение прогноза высокой точности требует наличия большого объёма систематизированной и корректно обработанной информации, соответствующей тематике решаемой задачи.

В рамках исследования имеется предварительно подготовленный датафрейм [21], представляющий собой генеральную совокупность из 5110 объектов с набором признаков, указанных в таблице 1. Каждый признак представляет собой количественное, либо категориальное значение с общей информацией о пациенте или показателе его состояния здоровья. Зависимость между признаками объекта однозначно определяет принцип получения истинно положительного/отрицательного теста на инсульт. Следует отметить, что данное утверждение не всегда подразумевает существование закономерности между всеми признаками и может ограничиваться лишь их частью.

Основу набора данных составляют категориальные признаки «gender», «hypertension», «heart_disease», «ever_married», «work_type», «residence_type», «smoking_status» и показатель (индикатор) инсульта «stroke». Поскольку при построении модели машинного обучения все признаки должны быть числовыми, в датафрейме значения категориальных признаков кодируются в соответствующий формат. Признаки «age», «avg_glucose_level», «bmi» являются количественными непрерывными переменными.

Визуализация характеристики распределения данных реализуется при помощи диаграммы размаха. На рисунке 5 изображены диаграммы, отражающие результаты проверки количественных признаков исходного набора данных на наличие выбросов. При этом сверху каждой диаграммы приведено название

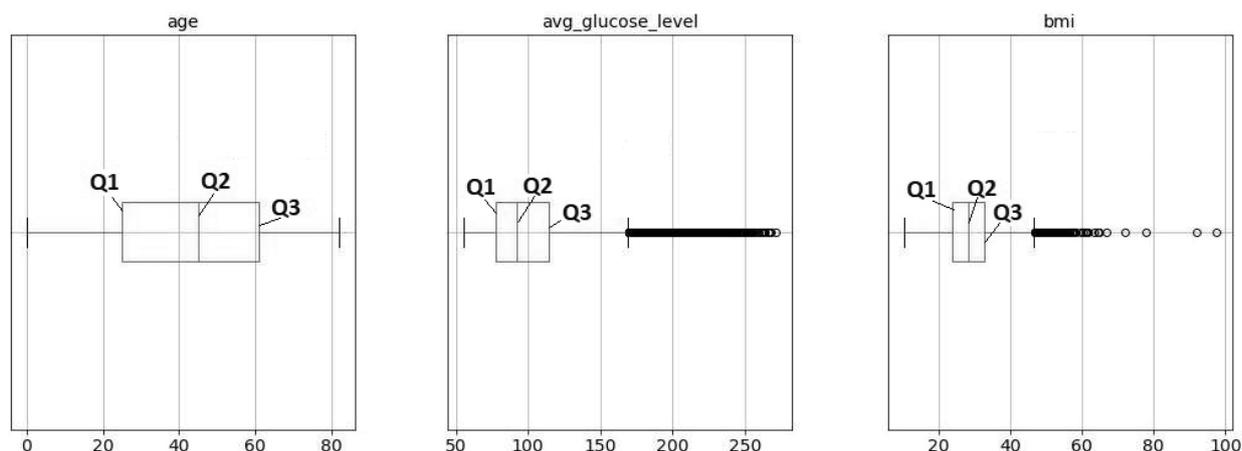


Рис. 5. Результаты проверки данных на наличие выбросов, представленных на диаграммах размаха

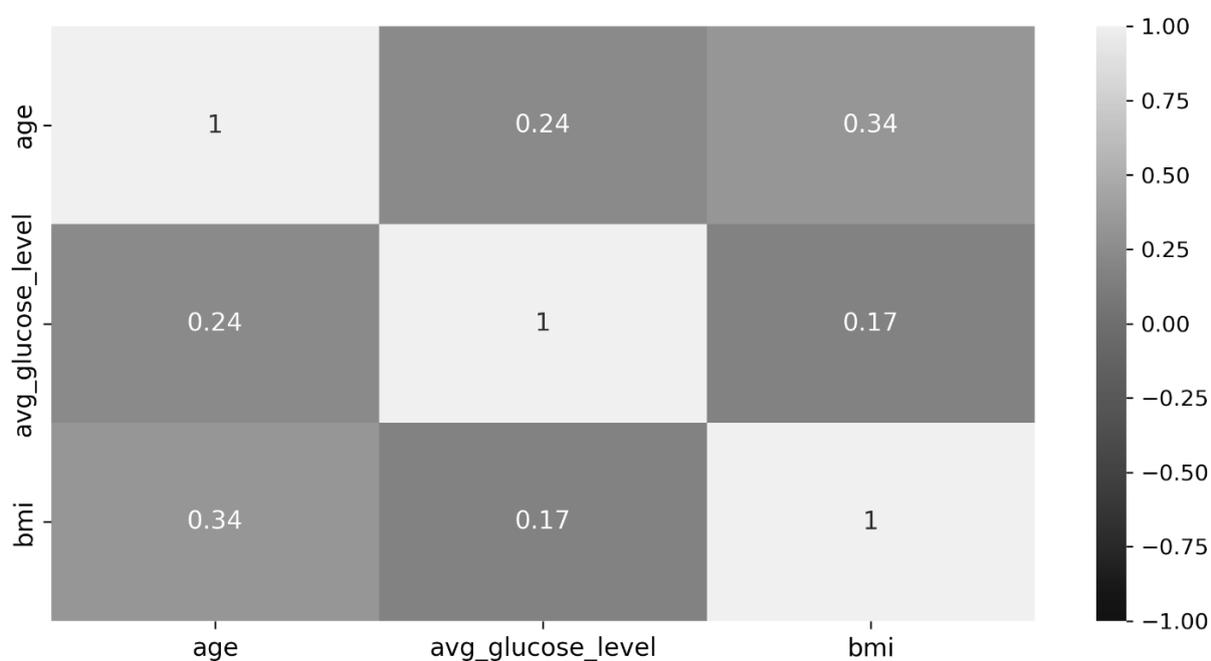


Рис. 6. Тепловая карта матрицы параметрической корреляции Пирсона

признака, а снизу по оси x показан диапазон значений признака.

Каждая диаграмма демонстрирует разбиение данных на несколько частей: слева от первого квартиля $Q1$ располагается первая четверть значений (25% элементов), слева от второго квартиля $Q2$ или медианы располагается ровно половина значений (50% элементов) и слева от третьего квартиля $Q3$ располагается три четверти значений (75% элементов). Видно, что со стороны правого «уса», равного 1.5 межквартильного размаха, на средней и нижней диаграммах точками отмечены

искомые артефактные значения, но не все из них считаются выбросами. Причиной тому являются диапазоны допустимых значений в контексте рассматриваемых показателей. Например, среднее содержание глюкозы в плазме крови может достигать около 300 мг/дл, в то время как максимальный уровень по диаграмме «avg_glucose_level» равен 272 мг/дл. Однако для индекса массы тела «bmi» два крайних правых значения 92 кг/м² и 98 кг/м² заметно отличаются от общего диапазона значений, располагающихся до 80 кг/м², что указывает на отсутствие совпадения с реальными данными. В связи с этим их следует исключить из исходного набора.

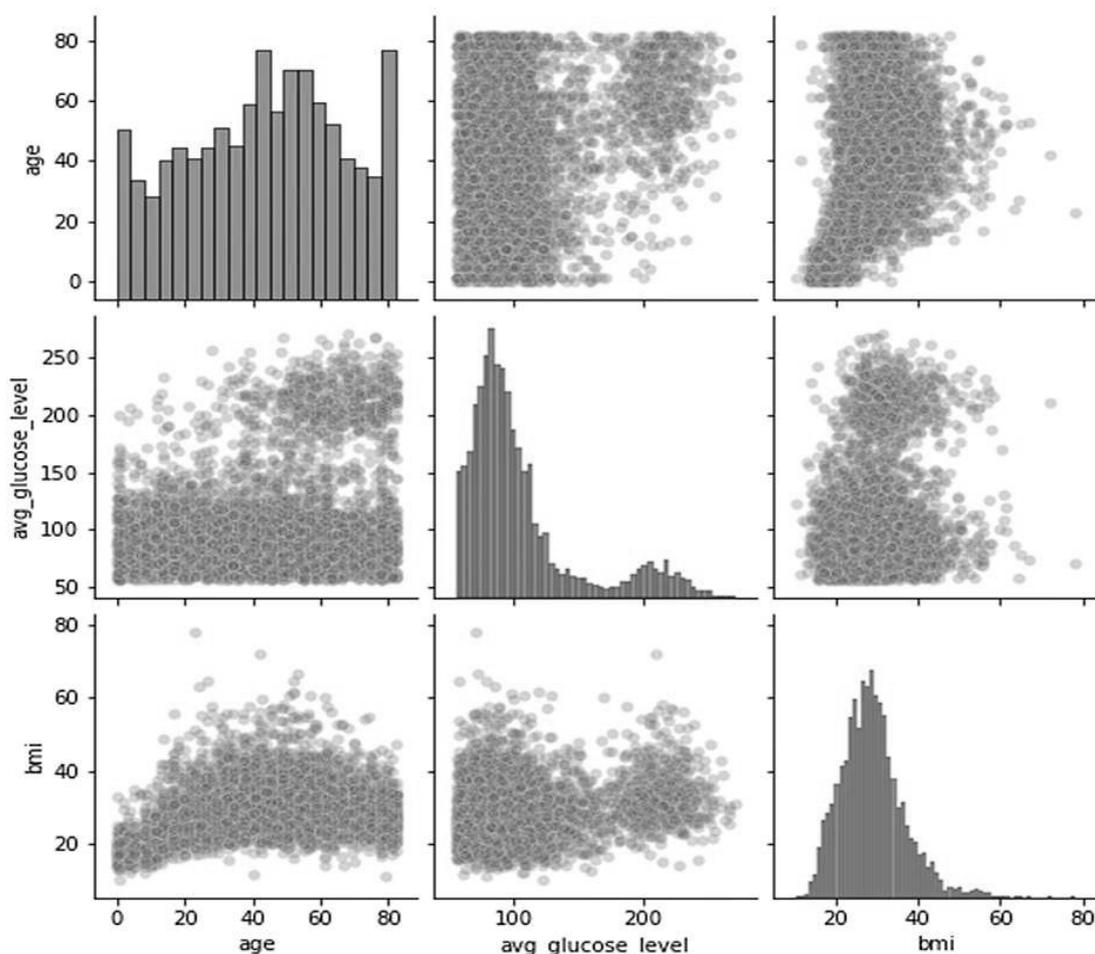


Рис. 7. Иллюстрация попарных отношений и общего распределения данных количественных признаков в матричном представлении

При вычислении значений коэффициента корреляции Пирсона (1) для нескольких случайных величин итоговые значения заносятся в двумерную матрицу и в целях удобства восприятия визуализируются в форме тепловой карты.

На рисунке 6 приведена тепловая карта для количественных признаков рабочего датафрейма.

Матрица, представленная на рисунке 6, показывает, что ни одно из вычисленных значений коэффициента корреляции Пирсона не превышает значение 0.5. Интерпретация этого явления по шкале Чеддока [22] указывает на слабую прямую линейную зависимость между средним уровнем глюкозы и возрастом, индексом массы тела и средним уровнем глюкозы, а также умеренную прямую линейную зависимость между индексом массы тела и возрастом обследуемого. Действительно, на сегодняшний день в медицине отсутствует аргументированное доказательство влияния возраст-

ной когорты и индекса массы тела на степень содержания глюкозы в плазме крови человека. Вместе с тем последняя из трёх перечисленных связей частично подтверждается на практике в исследовании [23], где отмечается тенденция небольшого роста индекса массы тела у молодых поколений.

Для проверки полученных выше выводов используется определение статистической значимости [24] с целью оценки того, происходит ли событие вследствие случайности. Статистическая значимость является ключевым результатом проверки гипотезы и количественной оценки надёжности связи. Если результат статистически значим, то его получение за счёт случайных событий или флуктуаций маловероятно. Нахождение уровня значимости основывается на применении статистического критерия [25], включающего в себя формулу расчёта, правило определения числа степеней свободы, теоретическое распределение степеней свободы и правило соотнесения эмпирического значе-

Таблица 2. Значения показателя статистической значимости для каждой комбинации категориальных признаков выборки, рассчитанные по критерию согласия Пирсона

	gender	hypertension	heart_disease	smoking_status	stroke
gender	0	0.299	0	0	0.789
hypertension	0.299	0	0	0	0
heart_disease	0	0	0	0	0
smoking_status	0	0	0	0	0
stroke	0.789	0	0	0	0

Таблица 3. Значения коэффициента точечной бисериальной корреляции для каждой комбинации числовых и бинарных категориальных признаков выборки

	hypertension	heart_disease	ever_married	residence_type	stroke
age	0.276	0.263	0.679	0.014	0.245
avg_glucose_level	0.121	0.113	0.104	-0.012	0.088
bmi	0.162	0.049	0.344	0.002	0.041

Таблица 4. Значения показателя статистической значимости для каждой комбинации числовых и бинарных категориальных признаков выборки, рассчитанные на основе значений коэффициента точечной бисериальной корреляции

	hypertension	heart_disease	ever_married	residence_type	stroke
age	0	0	0	0.311	0
avg_glucose_level	0	0	0	0.366	0
bmi	0	0	0	0.859	0.002

ния критерия для определения достоверности вероятности альтернативной гипотезы. В соответствии с [25] вводится пороговый уровень значимости $\alpha = 0.05$. Результат статистически значим только тогда, когда показатель значимости p -value ниже порогового значения, то есть p -value $< \alpha$.

Итоговые расчёты показывают следующее:

- ♦ для пары признаков «avg_glucose_level» и «age»: p -value = $9.068235083797374e-67 < \alpha$;
- ♦ для пары признаков «bmi» и «avg_glucose_level»: p -value = $7.327012032075809e-38 < \alpha$;
- ♦ для пары признаков «bmi» и «age»: p -value = $1.940754919910037e-140 < \alpha$.

Как видно, значения показателя значимости p -value во всех случаях очень малы, поэтому нет оснований утверждать, что между этими признаками нет статистически подтверждённой взаимосвязи. Факт того, что корреляция Пирсона $r \leq 0.34$ оказалась значима, может быть обоснован работой с выборкой большого объёма.

Рассмотренные выше зависимости наглядно продемонстрированы на парном графике рисунка 7, где диагональные графики являются гистограммами распре-

делений признаков, а остальные представляют собой диаграммы рассеяния для указанных пар признаков.

Результаты расчётов значений показателя значимости на основании критерия согласия Пирсона (2) приведены в таблице 2. Значения показателя значимости p -value для выбранных категориальных признаков в большинстве случаев также не превышают стандартный уровень значимости $\alpha = 0.05$, что подтверждает статистическую связь категориальных признаков.

В таблице 3 и таблице 4 приведены результаты вычисления точно-бисериального коэффициента корреляции r_{pbis} (3) между числовыми и бинарными категориальными значениями признаков, а также показателя значимости p -value.

По обеим таблицам видно, что несмотря на достаточно низкую корреляционную зависимость большей части признаков, показатель p -value $< \alpha$, что доказывает статистическую значимость их соотношения.

Наблюдения, полученные эмпирическим методом в ходе проведения разведочного анализа на основе оценки корреляционно-статистических показателей

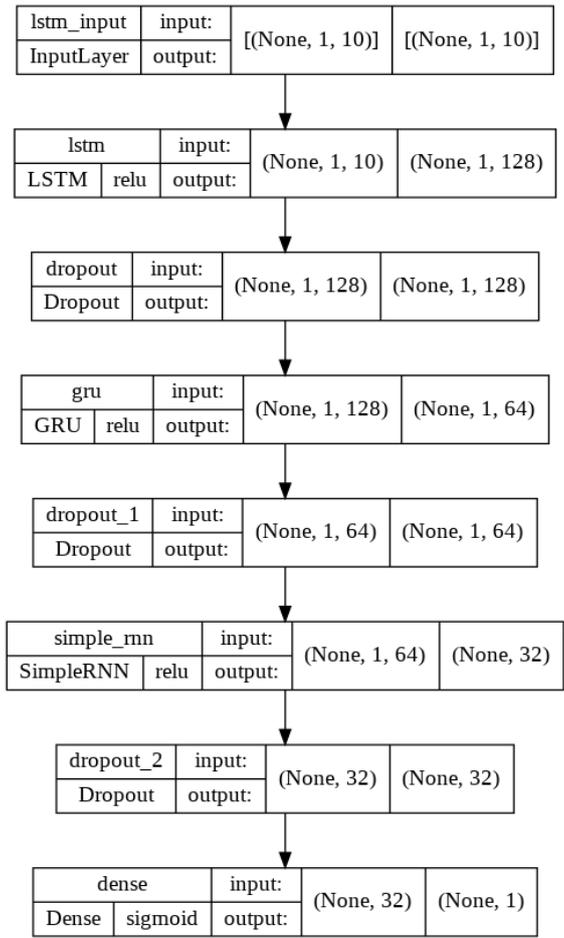


Рис. 8. Структурная схема скомпилированной нейросетевой модели

зависимости признаков датафрейма, позволяют сделать заключение о целесообразности и актуальности применения полного набора признаков в процессах обучения, валидации и тестирования разрабатываемого нейросетевых алгоритма машинного обучения, ориентированного под решение рассматриваемой классификационной задачи. При этом необходимо отметить, что вероятность возникновения инсульта не может определяться исключительно единичным влиянием на организм какого-либо из вышеперечисленных факторов, ввиду рассмотренных статистико-математических особенностей данных и основополагающих закономерностей методов поиска оптимальных решений с помощью искусственного интеллекта, и должна рассчитываться с учётом комплексного воздействия их исчерпывающей совокупности.

18.2.2. Программная реализация и тестирование модели интеллектуальной системы с использованием экспериментального набора данных

При рассмотрении математической модели с точки зрения её программной реализации следует ак-

центировать внимание на возможностях библиотеки TensorFlow с позиции объединения вычислительной алгебры методов оптимизации для упрощённого вычисления математических выражений, а именно:

- ◆ наличие функции для определения, оптимизации и вычисления математических выражений при помощи тензоров;
- ◆ поддержка программирования глубоких нейронных сетей и методов машинного обучения;
- ◆ использование масштабируемой функции вычислений для работы с наборами данных разного типа;
- ◆ формирование динамического графа вычислений с отслеживанием изменения данных и поддержкой автоматического дифференцирования в процессе выполнения операций с тензорами.

Архитектура интеллектуальной системы формируется на базе модуля Keras из библиотеки TensorFlow. Основополагающим элементом представляемой структуры является предопределённый класс последовательной модели «Sequential», представляющей

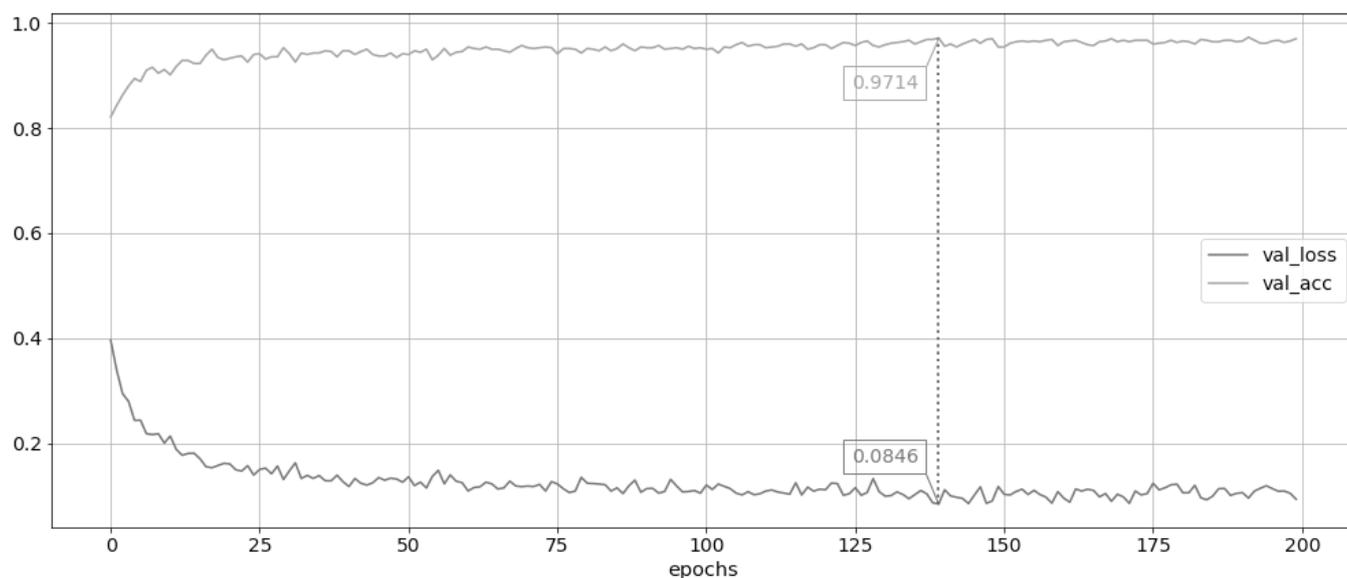


Рис. 9. Графики оценки функции потерь и точности на валидационной выборке

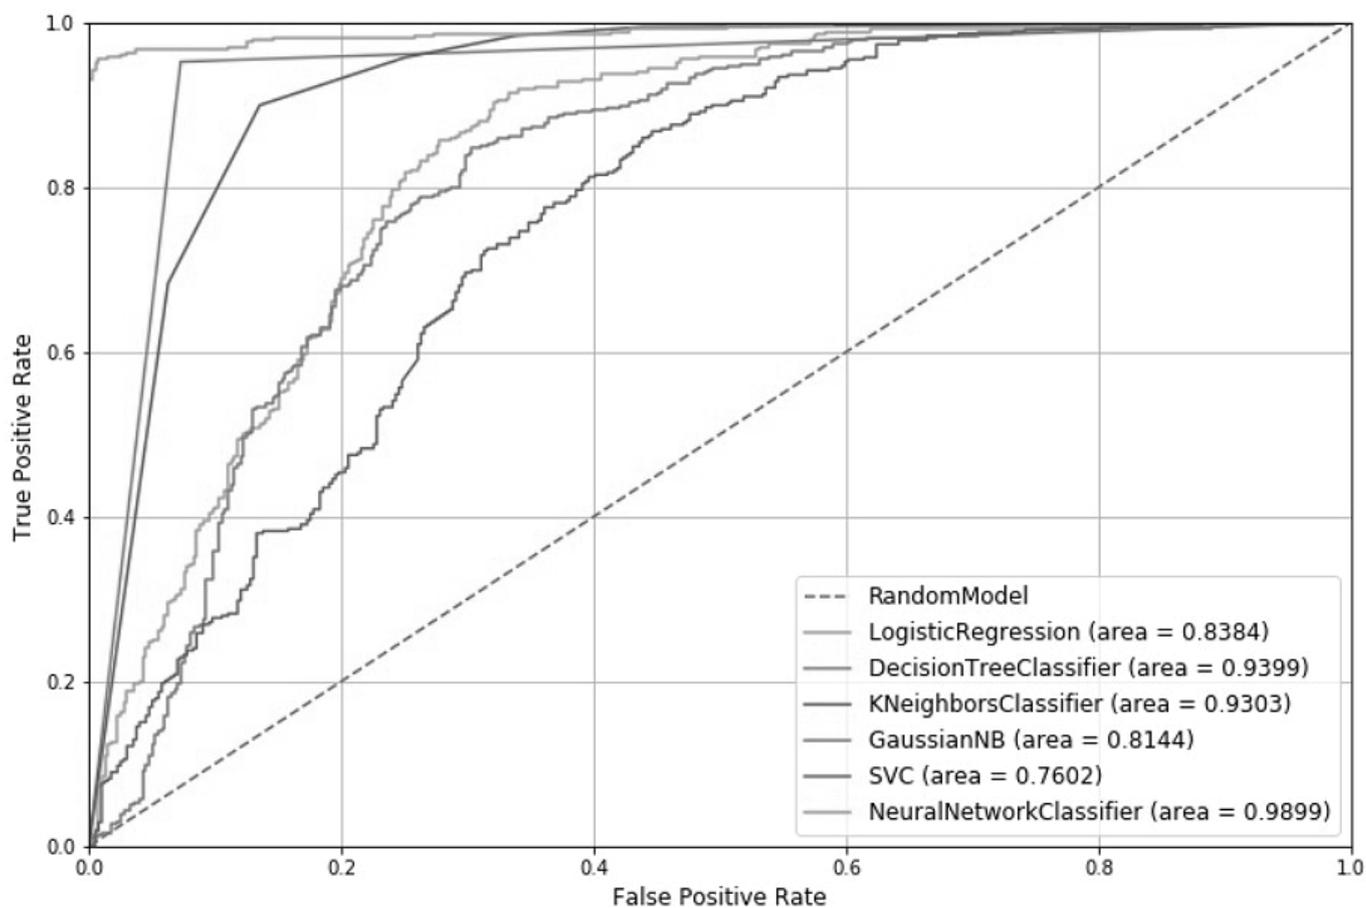


Рис. 10. ROC-кривые для разных моделей машинного обучения на этапе валидации

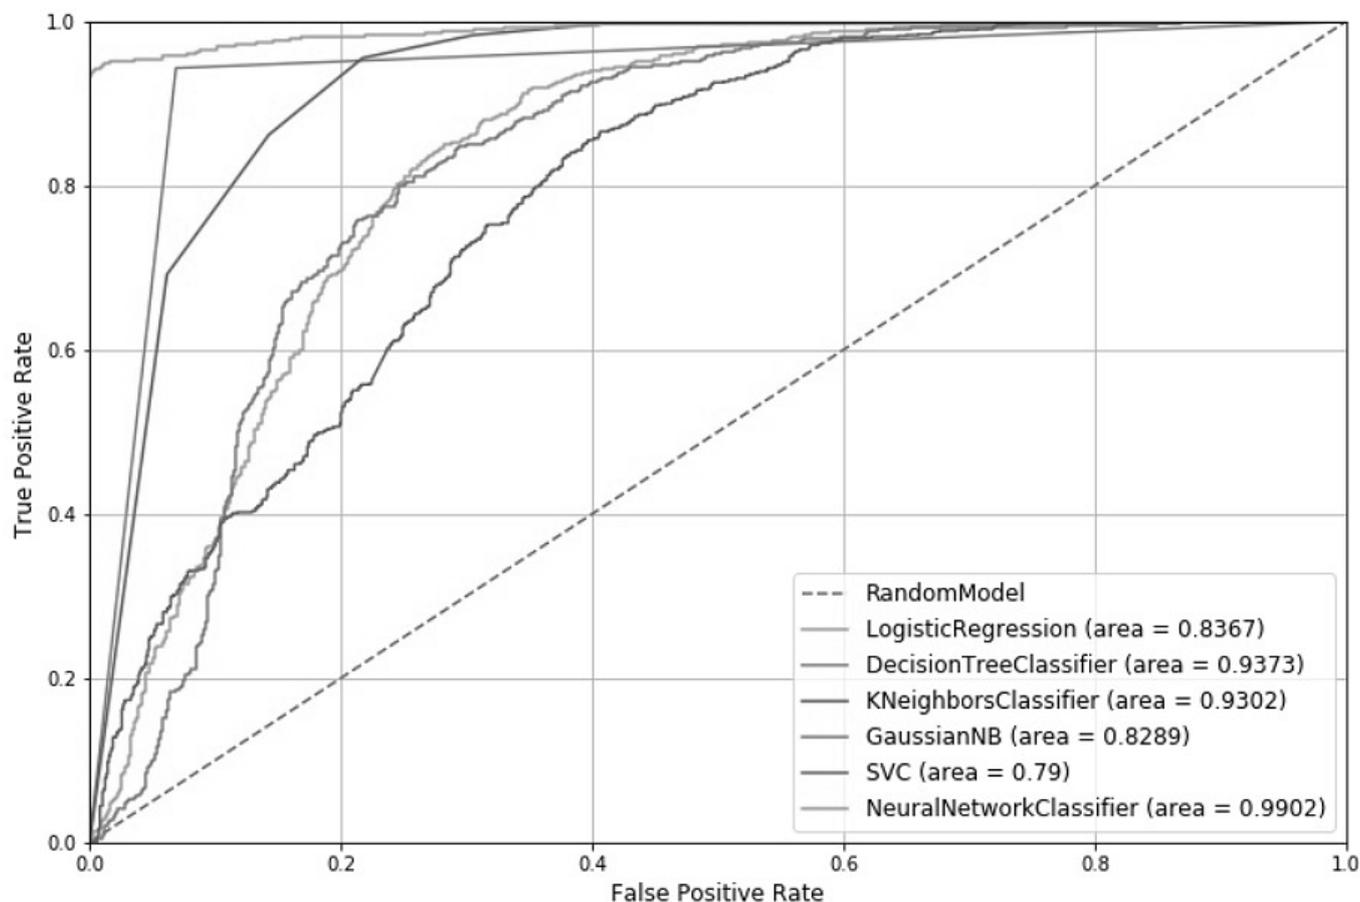


Рис. 11. ROC-кривые для разных моделей машинного обучения на этапе тестирования

собой линейный стек различных слоёв. Поскольку модели необходимо иметь строгое понимание того, какую размерность данных ожидать на входе, первый слой LSTM-сети предполагает получение информации о размерности данных через аргумент *input_shape*. Также дополнительно указывается размерность выходного пространства *units = 128* и функция активации *activation = 'relu'*.

Далее следует чередование слоя исключения Dropout (с долей входных блоков, равной 0.2) со слоями GRU и SimpleRNN. При этом размерность выходного пространства на уровне стробируемых рекуррентных единиц в два раза меньше, чем у первого слоя, а на уровне полносвязной рекуррентной нейронной сети в два раза меньше, чем у предыдущего слоя. Функция активации во всех случаях остаётся неизменной.

Размерность выходного пространства полносвязного слоя Dense равна единице. В качестве аргумента активации передаётся сигмоидная логистическая функция *activation = 'sigmoid'*.

Перед компиляцией модели инстанцируется оптимизатор «Adam». Коэффициент скорости обучения *learning_rate* устанавливается равным 0.002. С целью уменьшения влияния произвольности выбора начальных весов на результаты для функции потерь *loss* аргументом передаётся бинарная перекрёстная энтропия [26].

Структурная схема скомпилированной нейросетевой модели с указанием числа нейронов и функции активации для каждого слоя изображена на рисунке 8.

Обучение модели проводится в течение 200 эпох с количеством образцов на обновление градиента, равным 32. Параметр для преждевременной остановки обучения не задаётся. Графики, представленные на рисунке 9, показывают, что лучшие оценки по метрике точности и функции потерь на валидационной выборке данных достигаются на 140 эпохе, в частности, значение потерь составляет 0.0846, а значение точности — 0.9714.

Определение качества работы нейросетевой модели осуществляется путём построения ROC-кривой и вычисления площади под кривой AUC-ROC, которые сравнива-

ются с такими же характеристиками качества бинарной классификации стандартных алгоритмов машинного обучения (рисунки 10 и 11). На графиках обоих рисунков видно, что рассчитанная площадь для дерева решений приблизительно соответствует площади для метода k-ближайших соседей. Данное наблюдение также прослеживается для логистической регрессии и гауссовского наивного байесовского алгоритма. Метод опорных векторов показывает самое низкое качество — площадь под кривой на этапе валидации составляет 0.7602, а на этапе тестирования — 0.79. При этом результаты оценки работы предлагаемой нейросетевой модели значительно превышает качество стандартных классификаторов и достигает значения около 0.99 на каждом из этапов.

Заключение

В настоящем исследовании представлена разработанная автором модель специализированной системы раннего предупреждения о риске возникновения инсульта у человека. Функциональные возможности

системы основаны на применении интеллектуального анализа данных и прогностического подхода в условиях бинарной классификации, реализация которых достигается благодаря использованию совокупности алгоритмических особенностей искусственных нейронных сетей рекуррентного вида, что позволило снизить степень предрасположенности к переобучению и значительно повысить процент прогностической значимости результатов предсказаний модели.

В перспективе дальнейшего исследования возможна модификация системы, допускающая внедрение в исходную архитектуру дополнительного блока, отвечающего за решение задачи прогнозирования вероятности возникновения заболевания сердца, в результате чего в исходную генеральную совокупность данных добавится новый признак. Такое усовершенствование позволит взаимодействовать с этим признаком как с ключевым фактором при принятии решения системой относительно инсульта и последующей постановке на основе данного решения окончательного диагноза врачом-неврологом.

ЛИТЕРАТУРА

1. Марголин, И.Д. Основные этапы развития искусственного интеллекта / И.Д. Марголин, Н.П. Дубовская // Молодой ученый. — 2018. — № 20 (206). — С. 23–26.
2. Куракова, Н.Г. Технологии искусственного интеллекта в медицине и здравоохранении: позиции России на глобальном патентном и публикационном ландшафте / Н.Г. Куракова, Л.А. Цветкова, О.В. Черченко // Врач и информационные технологии. — 2020. — № 2. — С. 81–100. — DOI 10.37690/1811-0193-2020-2-81-100.
3. Мелдо, А.А. Искусственный интеллект в медицине: современное состояние и основные направления развития интеллектуальной диагностики / А.А. Мелдо, Л.В. Уткин, Т.Н. Трофимова // Лучевая диагностика и терапия. — 2020. — № 1(11). — С. 9–17. — DOI 10.22328/2079-5343-2020-11-1-9-17.
4. World Stroke Organization. [Электронный ресурс]: <https://www.world-stroke.org/> (дата обращения: 04.09.2022).
5. World Health Organization | Regional Office for the Eastern Mediterranean. [Электронный ресурс]: <http://www.emro.who.int/index.html> (дата обращения: 04.09.2022).
6. Шамаева, В.С. Личностный профиль пациента с тетраплегией / В.С. Шамаева, Ф.С. Васильева // Человеческий капитал. — 2021. — № 5(149). — С. 139–145. — DOI 10.25629/НС.2021.05.14.
7. Musin, K. Machine learning algorithms in the prediction of conflicts in clinical classification of genetic variants / K. Musin, A. Gaidel // CEUR Workshop Proceedings: 6, Samara, 26–29 мая 2020 года. — Samara, 2020. — P. 179–182.
8. Label self-advised support vector machine (LSA-SVM)-automated classification of foot drop rehabilitation case study / S.A. Abboud, S.H. Abdullah, A. Al-Jumaily [et al.] // Biosensors. — 2019. — Vol. 9. — No 4. — P. 114. — DOI 10.3390/bios9040114.
9. Application of Computer simulation results and machine learning in the analysis of microwave radiothermometry data / M.V. Polyakov, I.E. Popov, A.G. Losev, A.V. Khoperskov // Mathematical Physics and Computer Simulation. — 2021. — Vol. 24. — No 2. — P. 27–37. — DOI 10.15688/mpcm.jvolsu.2021.2.3.
10. Лютикова, Л.А. Обнаружение выбросов в данных машинного обучения / Л.А. Лютикова // Актуальные проблемы информатизации образования: опыт, проблемы, перспективы развития: Сборник материалов международной научно-практической конференции, Черкесск, 24–25 января 2020 года. — Черкесск: Библиотечно-издательский центр Северо-Кавказской государственной академии, 2020. — С. 93–98.
11. Comparison of pearson correlation coefficient and distance correlation in correlation power analysis on digital multiplier / J. Kundrata, A. Baric, D. Fujimoto, Y. Hayashi // 2020 43rd International Convention on Information, Communication and Electronic Technology, MIPRO 2020 — Proceedings: 43, Opatija, 28 сентября — 02 2020 года. — Opatija, 2020. — P. 146–151. — DOI 10.23919/MIPRO48935.2020.9245325.
12. Mental Models // FS.Blog. [Электронный ресурс]: <https://fs.blog/regression-to-the-mean> (дата обращения: 16.09.2022).
13. Мещерякова, Т.В. Статистическая обработка эмпирических данных функционирования автоматизированных систем / Т.В. Мещерякова, М.Е. Фирюлин // Охрана, безопасность, связь. — 2019. — Т. 3. — № 4(4). — С. 110–116.
14. Баврина, А.П. Современные правила применения корреляционного анализа / А.П. Баврина, И.Б. Борисов // Медицинский альманах. — 2021. — № 3(68). — С. 70–79.

15. Jabir, B. RNN- and CNN-based weed detection for crop improvement: an overview / B. Jabir, L. Rabhi, N. Falih // Foods and Raw Materials. — 2021. — Vol. 9. — No 2. — P. 387–396. — DOI 10.21603/2308–4057–2021–2–387–396.
16. Masalimov, K.A. Application of LSTM neural networks for diagnostics of the state of nodes of metal-cutting machines / K.A. Masalimov, R.A. Munasypov // Системная инженерия и информационные технологии. — 2021. — Vol. 3. — No 2(6). — P. 26–34. — DOI 10.54708/26585014_2021_32626.
17. Study on Prediction Model of HIV Incidence Based on GRU Neural Network Optimized by MHP SO / X. Li, J. Wang, J. Li [et al.] // IEEE Access. — 2020. — Vol. 8. — P. 49574–49583. — DOI 10.1109/ACCESS.2020.2979859.
18. Нейросети — это просто (Часть 4): Рекуррентные сети // MQL5. [Электронный ресурс]: <https://www.mql5.com/ru/articles/8385> (дата обращения: 26.09.2022).
19. Elshamy, M.M.M. Evaluation of the elastic modulus of pavement layers using different types of neural networks models / M.M.M. Elshamy, A.N. Tiraturyan, E.V. Uglova // Advanced Engineering Research. — 2021. — Vol. 21. — No 4. — P. 364–375. — DOI 10.23947/2687–1653–2021–21–4–364–375.
20. ML: Тензоры в Keras // QuData. [Электронный ресурс]: https://qudata.com/ml/ru/NN_Base_Keras.html (дата обращения: 03.10.2022).
21. Kaggle. [Электронный ресурс]: <https://www.kaggle.com/fedesoriano/stroke-prediction-dataset> (дата обращения: 08.10.2022).
22. Попова, А.М. Исследование экономических задач с помощью элементов теории корреляции / А.М. Попова // Вопросы педагогики. — 2021. — № 1–1. — С. 200–203.
23. Аистов, А.В. Динамика индекса массы тела российских мужчин и женщин: возраст-период-когорта / А.В. Аистов, Е.А. Александрова, Ф.Г. Гарипова // Демографическое обозрение. — 2021. — Т. 8. — № 1. — С. 44–80. — DOI 10.17323/demreview.v8i1.12393.
24. Di Leo, G. Statistical significance: p value, 0.05 threshold, and applications to radiomics-reasons for a conservative approach / G. Di Leo, F. Sardanelli // European Radiology Experimental. — 2020. — Vol. 4. — No 1. — P. 18. — DOI 10.1186/s41747–020–0145-y.
25. Ekström, Joakim., On Statistical Criteria: Theory, History, and Applications., 2012.
26. TensorFlow. [Электронный ресурс]: https://www.tensorflow.org/api_docs/python/tf/keras/losses/BinaryCrossentropy (дата обращения: 20.10.2022).

© Масленников Владимир Владимирович (vldmsn@yahoo.com).

Журнал «Современная наука: актуальные проблемы теории и практики»



МИРЭА — Российский технологический университет