

© ЧЕРНЫХ Е. М., ХАСАНОВА Н. М., КАРЯКИН А. А., КАРЯКИНА О. Е.

УДК 616:00

DOI: 10.20333/25000136-2024-3-83-90

Искусственная нейронная сеть в прогнозировании раннего функционального исхода после перенесенного инсульта

Е. М. Черных¹, Н. М. Хасанова¹, А. А. Карякин¹, О. Е. Карякина²¹Северный государственный медицинский университет, Архангельск 163000, Российская Федерация²Северный (Арктический) федеральный университет имени М.В. Ломоносова, Архангельск 163002, Российская Федерация

Цель исследования. Разработать и валидировать прогностические модели исхода инсульта в остром периоде с применением алгоритма искусственных нейронных сетей (ИНС).

Материал и методы. Использовали данные историй болезни 1617 пациентов с острым инсультом, средний возраст - 63,8±11,4 года (968 мужчин (59,9%) и 649 женщин (40,1%)). Алгоритм решал задачу мультиклассовой классификации по фактору «исход» - вероятность достижения определенного функционального состояния на момент выписки. Разрабатывали 2 модели для разных исходов: вероятность значения по NIHSS (National Institutes of Health Stroke Scale) для модели I и по mRs (modified Rankin scale) для модели II. Выделенные 9 предикторов соответствовали нейронам входного слоя ИНС. Для оценки качества моделей применяли показатели точности Accuracy, Precision, показатель чувствительности Recall, кросс-энтропию в качестве функции потерь, AUC (Area Under Curve) и методику кросс-валидации. Разработка прогностических моделей выполнялась в среде PyCharm Community на языке программирования Python.

Результаты. Обучающий набор составил 1294 (80 %) записей, тестовый и валидационный - по 162 (10 %) записей. Архитектура ИНС представляла многослойный перцептрон: входной слой с 9 нейронами, промежуточный, построенный по технологии плотных слоев Dense, выходной слой с одним нейроном. Максимальная точность (Precision) составила 84,86 % для I и 90,72 % для II модели, показатели AUC составили 90,43 % и 97,41 % для I и II моделей соответственно. 74,29 % для I и 84,56 % для II модели были лучшими значениями чувствительности. Минимальные значения функции потерь составили 51,36 % для I и 30,56 % для II модели.

Заключение. Были построены и обучены математические модели ИНС, позволяющие прогнозировать вероятность определенного функционального исхода у пациентов с острым инсультом. Алгоритм ИНС продемонстрировал высокую точность и хорошую чувствительность обеих моделей при решении задачи мультиклассовой классификации. Модель II (с оценкой исхода по mRS) более предпочтительна в прогнозировании раннего функционального исхода у пациентов с инсультом ввиду лучших показателей точности и чувствительности и меньших значений функции потерь.

Ключевые слова: инсульт, машинное обучение, искусственные нейронные сети, коморбидность, ранний функциональный исход, прогнозирование.

Конфликт интересов. Авторы декларируют отсутствие явных и потенциальных конфликтов интересов, связанных с публикацией настоящей статьи.

Для цитирования: Черных ЕМ, Хасанова НМ, Карякин АА, Карякина ОЕ. Искусственная нейронная сеть в прогнозировании раннего функционального исхода после перенесенного инсульта. *Сибирское медицинское обозрение.* 2024;(3):83-90. DOI: 10.20333/25000136-2024-3-83-90

An artificial neural network in prediction of early functional outcome after stroke

Е. М. Chernykh¹, N. M. Khasanova¹, A. A. Karyakin¹, O. E. Karyakina²¹Northern State Medical University, Arkhangelsk 163000, Russian Federation²Northern (Arctic) Federal University named after M.V. Lomonosova, Arkhangelsk 163002, Russian Federation

The aim of the research. To develop and validate prognostic models of stroke outcome in the acute period using an artificial neural network (ANN) algorithm.

Material and Methods. We used data from medical records of 1,617 patients with acute stroke, at the mean age of 63.8±11.4 years (968 men (59.9%) and 649 women (40.1%)). The algorithm solved the problem of multiclass classification based on the “outcome” factor: the probability of achieving a certain functional state at the time of discharge. Two models were developed for different outcomes: the probability of the value according to NIHSS (National Institutes of Health Stroke Scale) for model I and according to mRs (modified Rankin scale) for model II. The nine identified predictors corresponded to the neurons of the input layer of the ANN. To assess the quality of the models, the accuracy indicators Accuracy, Precision, the sensitivity indicator Recall, cross-entropy as a loss function, AUC (Area Under Curve) and the cross-validation technique were used. The development of predictive models was carried out in the PyCharm Community environment using the Python programming language.

Results. The training set consisted of 1,294 (80%) records, the test and validation sets each included 162 (10%) records. The architecture of the ANN was a multilayer perceptron: an input layer with 9 neurons, an intermediate layer built using the “Dense” dense layer technology, and an output layer with one neuron. The maximum precision was 84.86% for model I and 90.72% for model II, the AUC indicators were 90.43% and 97.41% for models I and II, respectively. The best sensitivity values were 74.29% for model I and 84.56% for model II. The minimum values of the loss function were 51.36% for model I and 30.56% for model II.

Conclusion. Mathematical ANN models have been built and trained to predict the probability of a certain functional outcome in patients with acute stroke. The ANN algorithm demonstrated high accuracy and good sensitivity of both models when solving the multiclass classification problem. Model II (with outcome assessment by mRS) is more preferable in predicting early functional outcome in patients with stroke due to better accuracy and sensitivity and lower loss function values.

Key words: stroke, machine learning, artificial neural networks, comorbidity, early functional outcome, prognosis.

Conflict of interest. The authors declare the absence of obvious and potential conflicts of interest associated with the publication of this article.

Citation: Chernykh EM, Khasanova NM, Karyakin AA, Karyakina OE. An artificial neural network in prediction of early functional outcome after stroke. *Siberian Medical Review.* 2024;(3):83-90. DOI: 10.20333/25000136-2024-3-83-90

Инсульт остается второй по значимости причиной смертности и третьей по значимости причиной смертности и инвалидности в мире. За последние десятилетия глобальная заболеваемость инсультом увеличилась на 70 %, распространенность - на 85 %, смертность - на 43 %, а показатель DALY (disability-adjusted life year) вырос вследствие инсульта на 32 %, особенно у лиц моложе 70 лет [1]. Помимо решения профилактических, лечебных и реабилитационных вопросов у пациентов с острыми нарушениями мозгового кровообращения (ОНМК) актуальным является возможность прогнозирования исходов инсульта.

Попытки предсказания исхода заболевания у пациентов с инсультом на основе создания прогностических моделей и шкал предпринимались с начала 70-х гг. прошлого столетия [2]. Разработка надежных прогностических моделей необходима для принятия определенных решений в клинической практике: адаптации планов лечения и реабилитации под конкретного пациента, проведения персонализированных мероприятий по вторичной профилактике [3].

Подход, используемый в моделях прогнозирования, предполагает выделение из существующего массива данных переменных – кандидатов в предикторы, из которых уже отбираются имеющие независимую связь с исходом [4]. Проанализировав данные литературных источников, можно выделить следующие группы факторов, которые использовались для выполнения прогноза:

- оценивающие состояние пациента на момент дебюта заболевания (уровень сознания, тяжесть неврологического дефицита по NIHSS (National Institutes of Health Stroke Scale), функциональный статус по mRS (modified Rankin scale));
- исходная коморбидная нагрузка (наличие сердечно-сосудистых заболеваний, сахарного диабета, повторность случившегося инсульта);
- определяемые средствами нейровизуализации (объем очага поражения, оценка состояния сосудов головного мозга, состояния пенумбры и проницаемости гематоэнцефалического барьера);
- определяемые методами функциональной диагностики (параметры ЭЭГ, полисомнографии, транскраниального дуплексного сканирования, диагностической транскраниальной магнитной стимуляции, соматосенсорных вызванных потенциалов).

Отдельную большую группу представляют биологические маркеры: нейрональные (нейронспецифическая енолаза, тау-протеин), глиальные (S100-β, глиальный фибриллярный кислый протеин, основной белок миелина), сывороточные показатели функции эндотелия (оксид азота, эндотелин-1), маркеры системы гемостаза (фибриноген), показатели системного воспаления (С-реактивный белок, провоспалительные цитокины), матриксные металлопротеиназы и каспазы [2, 5, 6, 7]. Чаще всего для построения прогностической модели применялось сочетание нескольких групп предикторов. Наиболее частая комбинация была представлена факторами пола, возраста, оценкой по NIHSS в дебюте заболевания, наличием

сердечно-сосудистых заболеваний и сахарного диабета (СД) [8].

Исходы в прогностических моделях отличались в зависимости от целей прогнозирования: оценивали вероятность выживаемости/летальности к определенному временному моменту или возможность хорошего/плохого функционального восстановления. Также модели имели различия по горизонту прогнозирования (оценка вероятности исхода в остром, раннем/позднем восстановительном периодах) и целевой группы (для использования у лиц конкретного возраста, половой принадлежности, с определенным видом инсульта, у пациентов, получивших лечение с использованием реперфузионных методик) [8, 9].

С переходом к использованию клинических данных на популяционном уровне и одновременно увеличением вычислительной мощности технических средств происходило изменение запроса на инструмент для обработки крупномасштабных данных, отвечающий современным требованиям. Появление больших объемов данных диктовало необходимость их обработки способами, отличными от методов классической статистики. Потенциалом для решения этой задачи обладали алгоритмы машинного обучения. Применение методов машинного обучения для диагностики инсульта или прогнозирования его исходов началось с 2000-х гг. [3, 9].

В 2006 г. в сравнительном обзоре, выполненном на основе немецкой базы данных Stroke Database, Linder et al. впервые пытались обосновать использование машинного обучения для прогнозирования исхода инсульта путем сравнения логистического регрессионного анализа и использования искусственных нейронных сетей (ИНС) [3]. Хотя авторы пришли к выводу, что использование логистической регрессии – «золотой» стандарт для построения прогностической модели, за истекшие 17 лет в качестве инструмента прогнозирования активно применяют ИНС, позволяющие выявлять закономерности и взаимосвязи, которые трудно обнаружить другим способом [3].

Несмотря на ежегодно появляющиеся новые сообщения о разработке прогностических моделей с использованием методов машинного обучения, задача прогнозирования исхода инсульта остается до конца нерешенной. Кроме требований, предъявляемых к самой прогностической модели (чувствительность и точность), методика прогнозирования предполагает малоинвазивность и простоту в применении на практике.

Цель исследования – разработать и валидировать прогностическую модель исхода инсульта в остром периоде с применением алгоритма ИНС.

Материал и методы

В качестве материала для разработки прогностической модели использовали сведения из историй болезни пациентов, госпитализированных по поводу острого инсульта и выписанных из неврологического отделения Регионального сосудистого центра (РСЦ) Архангельской областной клинической больницы (АОКБ) в период с 1 января 2017 по 31 декабря 2020 г. На их основе была создана компьютерная база данных с возможно-

стью проведения статистического анализа, который проводился с использованием пакетов «Microsoft Excel 2010» (США) и «Statistica 7.0» («StatSoft», США).

Предварительно были выполнены описательные статистики. С помощью одномерных логистических регрессий, результаты которых были представлены в виде отношений шансов (ОШ) с 95 % доверительным интервалом (ДИ) определяли связь наличия коморбидных заболеваний (артериальной гипертензии (АГ), церебрального атеросклероза (ЦА), ишемической болезни сердца (ИБС), фибрилляции предсердий (ФП), хронической сердечной недостаточности (ХСН), СД, онкозаболеваний) с выраженностью нарушений по NIHSS и mRS на момент выписки из стационара. Были выявлены связи между наличием ИБС, ФП, ХСН, АГ и более высоким баллом, но только для mRS при выписке, для других сопутствующих заболеваний и значений по NIHSS статистически значимые различия получить не удалось.

Для оценивания совместного влияния пар факторов «пол-возрастная группа», «пол-коморбидная нагруженность», «возрастная группа-коморбидная нагруженность» на функциональный исход инсульта (NIHSS, mRS) выполняли двухфакторный дисперсионный анализ, но статистически значимого взаимодействия также выявлено не было.

Традиционная многофакторная логистическая регрессионная модель, куда в качестве предикторов были включены пол, возраст, функциональный статус

(NIHSS, mRS) в дебюте инсульта, а также все вышеперечисленные сопутствующие заболевания, значимый прогностический результат не продемонстрировала.

Для продолжения работы над прогностической моделью было решено использовать методы машинного обучения на основе ИНС.

Чтобы достичь цели, поставленной перед прогностической моделью, требовалось решение задачи мультиклассовой классификации. Признаком, по которому происходила классификация, являлся фактор «исход». Интересующим исходом была вероятность достижения определенного функционального состояния пациента на момент выписки из стационара. Ввиду различия оценочных шкал по описываемым характеристикам функционального статуса разрабатывали 2 модели для разных исходов: вероятность значения по NIHSS для модели I и по mRS для модели II. Для повышения качества разрабатываемых моделей обе оценочные шкалы были преобразованы с перераспределением баллов на 3 градации. Основные характеристики для фактора «исход» представлены в таблице 1.

Отбор предикторов для анализа ИНС был осуществлен на основании анализа данных предыдущих исследований (1, 10, 11), а также по результатам ранее выполненных расчетов методами классической статистики (одномерных логистических регрессий). Выделенные 9 предикторов соответствовали 9 нейронам входного слоя ИНС (табл.2).

Таблица 1

Описательные характеристики показателей, использованных в качестве исхода для построения математических моделей

Table 1

Descriptive characteristics of indicators used as an outcome for constructing mathematical models

модель	оценочная шкала, применяемая для маркировки исхода	назначение оценочной шкалы	диапазон значений баллов (минимальный балл – лучшее значение)	преобразованные значения баллов оценочных шкал (3 градации)	интерпретация соответствующих значений градаций, получаемых в качестве исхода
I	NIHSS	оценка степени нарушения функции (выраженность неврологического дефицита)	0 - 42	менее 4 баллов - 1 5-22 балла - 2 более 22 баллов - 3	негрубый неврологический дефицит дефицит умеренной выраженности тяжелый неврологический дефицит
II	mRS	оценка степени нарушения жизнедеятельности	0 - 6	1,2,3 балла – 1 4 балла – 2 5 баллов – 3	пациент способен передвигаться «сидячий» пациент «лежачий» пациент

Таблица 2

Характеристики и количественная оценка предикторов

Table 2

Characteristics and quantification of predictors

№	описание	метрика
1	пол пациента	мужской - 1; женский - 0
2	возраст (годы)	числовое значение
3	количество сопутствующих заболеваний	числовое значение
4	фибрилляция предсердий	есть – 1; нет - 0
5	церебральный атеросклероз	есть – 1; нет - 0
6	хроническая сердечная недостаточность	есть – 1; нет - 0
7	ишемическая болезнь сердца	есть – 1; нет - 0
8	сумма баллов по mRS при поступлении	числовое значение
9	сумма баллов по NIHSS при поступлении	числовое значение

Качество полученных математических моделей оценивали с помощью показателей точности Accuracy и Precision. Были рассчитаны значения полноты-чувствительности (Recall) для каждой модели и значения функции потерь (Loss). Кросс-энтропия в качестве функции потерь показывала суммарную ошибку между классами значений исходов, полученных в ходе использования моделей. Также в качестве обобщающей метрики использовали AUC ROC (Area Under Curve – площадь под кривой, Receiver Operating Characteristic – рабочая характеристика приёмника) и методику кросс-валидации по 10 независимым выборкам [12, 13].

Разработка прогностических моделей выполняли в среде PyCharm Community на языке программирования Python с использованием свободно распространяемой библиотеки TensorFlow по традиционным алгоритмам машинного обучения. Обучение ИНС выполнено с применением технологии NVIDIA CUDA Deep Neural Network с последующим подбором гиперпараметров модели.

Обучение осуществлялось на стационарном компьютере со следующими техническими характеристиками: видео карта – Nvidia GeForce GTX 4090 (24Gb видео памяти), процессор – Intel i3500 (8 ядер, 32 потока, базовая частота 3.6GHz), оперативная память – DDR4 (128Gb памяти с частотой 3200MHz).

На проведение исследования получено положительное этическое заключение об одобрении пакета документов в рамках диссертационной работы «Совершенствование оказания помощи лицам пожилого и старческого возраста с когнитивными нарушениями после острых цереброваскулярных заболеваний, проживающих в Арктическом регионе» (Локальный этический комитет СГМУ, г. Архангельск, протокол заседания № 09/10 - 2 от 26.10.22).

Результаты и обсуждение

Для построения ИНС с целью прогнозирования исходов инсульта использовали данные историй болезни 1617 пациентов с острым инсультом в возрасте от 18 до 98 лет, средний возраст составил $63,8 \pm 11,4$ года (968 мужчин (59,9 %) и 649 женщин (40,1 %)).

Для выполнения работы исходная выборка была разделена на 3 части: обучающую, тестовую и валидационную. Обучающий набор составил 1294 (80 %) записей, тестовый набор и валидационный - по 162 (10 %) записей соответственно.

Первоначально для построения математических моделей ИНС проводился подбор гиперпараметров - элементов, позволяющих управлять процессом обучения модели, характеризующих архитектуру ИНС (количество слоев и нейронов в них, количество эпох обучения, функции активации, оптимизаторы). Для поиска наилучших гиперпараметров использовали автоматический метод Grid Search, предполагающий исходное задание наборов значений для каждого гиперпараметра, которые «перебирались» до нахождения оптимальной комбинации.

Наилучший результат в отношении показателей точности моделей показала комбинация в составе функций активации ReLU (Rectified Linear Unit) и оптимизатора Adam (adaptive moment estimation). Количество эпох обучения составило 1500.

Архитектура разрабатываемой ИНС соответствовала многослойному перцептрону (рис.1). Входной слой для каждой модели включал по 9 нейронов, соответствующих количеству выделенных предикторов. Промежуточный слой ИНС был построен по технологии плотных слоев Dense, содержащих от 32 до 64 нейронов (большее количество нейронов в слое не позволяло достигать показателей точности более 80 %). Выходной слой для каждой модели представлял собой один нейрон.

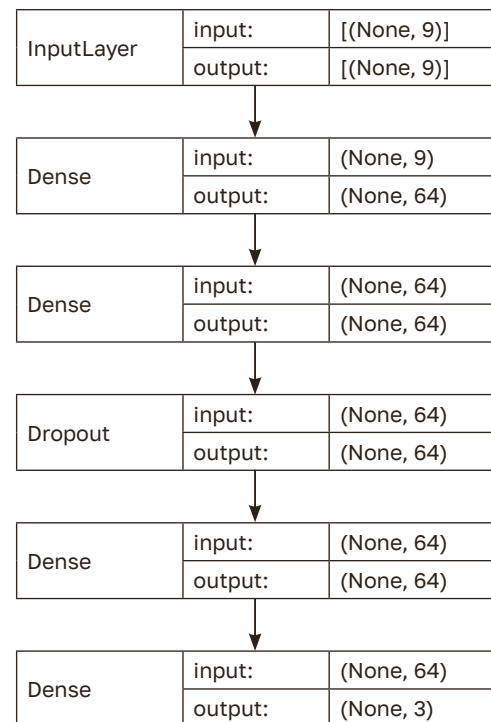


Рисунок 1. Архитектура ИНС для I и II моделей классификации.

Figure 1. ANN architecture for classification models I and II.

После обучения построенных моделей на валидационной выборке была проведена классификация по множественному (3) набору значений исхода. Основные метрики оценки классификаторов представлены в таблице 3.

Выполненная классификация позволила получить значения точности (precision) 79,87 %-75,45 %-84,86 % по результатам обучающей, тестовой и валидационных выборок соответственно для I модели и 88,96 %-88,66 %-90,72 % для II модели. Значения, полученные при использовании AUC ROC, показали 90,43 % для I модели и 97,41 % для II модели, что демонстрировало более высокий результат при использовании данной метрики, но тоже с выявлением лучших возможностей для решения задачи классификации для II модели.

Метрики оценки качества моделей классификации

Table 3

Metrics for assessing the quality of classification models

метрика	Модель I (NIHSS)	Модель II (mRS)
-----TRAIN-----		
loss	0.5136	0.3056
accuracy	0.7624	0.8638
precision	0.7987	0.8896
recall	0.7100	0.8414
auc	0.9267	0.9744
-----TEST-----		
loss	0.5256	0.3117
accuracy	0.7222	0.8580
precision	0.7545	0.8866
recall	0.7094	0.8209
auc	0.9189	0.9741
-----VALID-----		
loss	0.5353	0.3174
accuracy	0.7831	0.8518
precision	0.8486	0.9072
recall	0.7429	0.8456
auc	0.9288	0.9729
Cross validation scores	[0.9235 0.76408 0.825 0.935 0.9255 0.9375 0.875 0.882 0.9375 0.8775]	[0.8235 0.7647 0.625 0.8125 0.8125 0.9375 0.875 0.8125 0.9375 0.875]
Mean TEST scores	0.8388	0.8388
Mean TRAIN scores	0.8282	0.8282
Mean VAL scores	0.8486	0.8486
AUC	0.9043	0.9741

Были получены значения чувствительности (recall) 71,0 %-70,94 %-74,29 % для I и 84,14 %-82,09 %-84,56 % для II модели. Значения функции потерь составили 51,36 %-52,56 %-53,53 % для I и 30,56 %-31,17 %-31,74 % для II моделей соответственно.

Показатели точности (precision), чувствительности (recall) и обобщающей метрики AUC модели II (с оценкой исхода по mRS) имели большие значения по сравнению с I моделью (с оценкой исхода по NIHSS), а значения функции потерь были ниже для II модели, что говорит о более высоком качестве модели II.

Результаты разработанных моделей включены в структуру мобильного приложения для получения объективизированной оценки в отношении раннего функционального исхода на основе половозрастного и коморбидного статуса пациентов с инсультом в остром периоде (Свидетельство о государственной регистрации программы для ЭВМ № 2023662382, дата регистрации в Реестре программ для ЭВМ: 07.06.2023) [14].

На примере пациента из исследуемой когорты продемонстрирована возможность реализации программы в клинической практике в виде мобильного приложения (рис. 2).

Вопрос прогнозирования исхода инсульта с использованием математических моделей наиболее активно стал разрабатываться со второго десятиле-

тия нашего века. Одной из самых известных систем оценки является THE THRIVE Score, разработанная Alexander Flint и соавт. для прогнозирования долгосрочных неврологических исходов (90 дней) – хорошего восстановления или смертности - у пациентов, перенесших инсульт. Модель представлена в виде медицинского калькулятора в свободном доступе [15] и включает в качестве предикторов, влияющих на исход инсульта: возраст, NIHSS при поступлении, АГ, СД, ФП в анамнезе, также учитывается наличие окклюзии крупного сосуда и балл по шкале ASPECTS. Модификации модели подтверждались в крупных исследованиях с набором более 12000 пациентов и использовались для прогнозирования результатов после внутривенной тромболитической терапии, эндоваскулярного лечения инсульта или без данных методик [16].

В нашей модели, в отличие от THE THRIVE Score, исход оценивался в среднем к третьей неделе инсульта, что позволяет использовать результат для планирования реабилитационного маршрута. Набор сопутствующих заболеваний в качестве предикторов был схож относительно сердечно-сосудистых проблем (АГ, ФП), но в нашей модели не применялся СД, так как исходно заболевание не было выделено в качестве прогностически значимого.

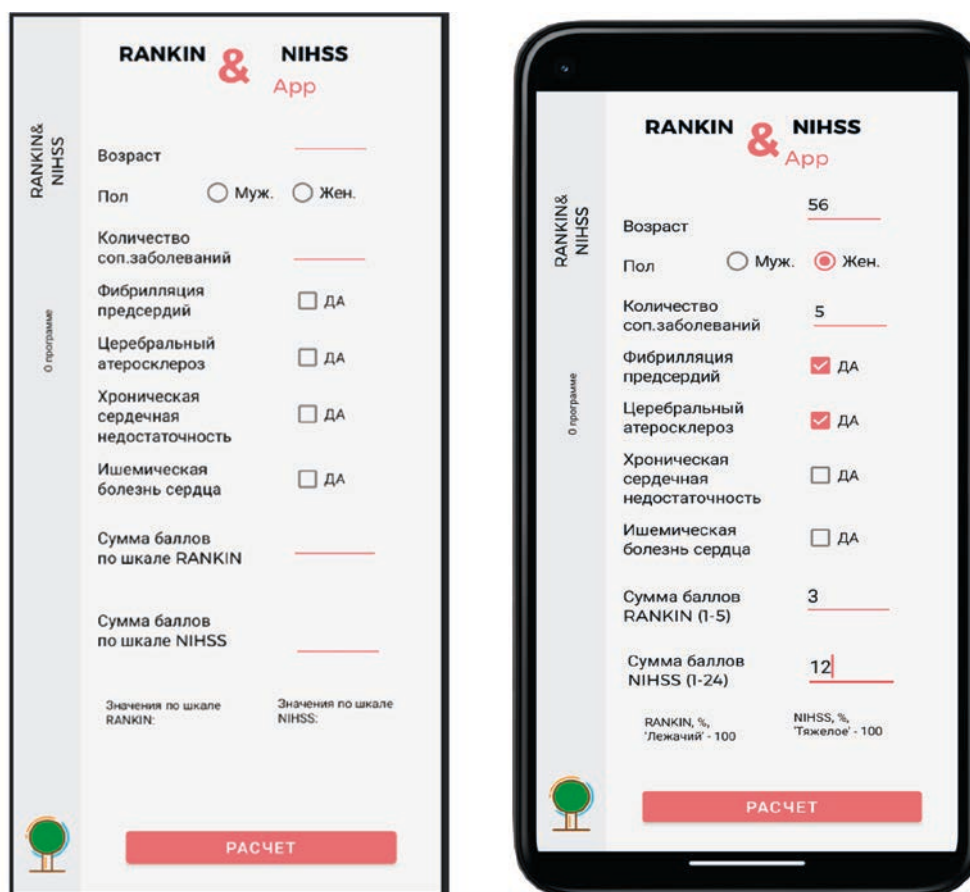


Рисунок 2. Пример использования мобильного приложения для прогнозирования исхода инсульта в остром периоде.

Figure 2. An example of using a mobile application to predict the outcome of stroke in the acute period.

При сравнении наших моделей с результатами работ коллективов отечественных авторов выявлено, что разработанные модели имели сходство в использовании таких предикторов, как пол и возраст, наличие ФП и ХСН [17], но отличались по набору других прогностических факторов, объектов оценки и оценочных средств.

Так, Л. А. Репина с соавт. для построения прогностической модели в качестве основных предикторов использовали результаты транскраниальной магнитной стимуляции [17]. А. М. Тынтерова с соавт. в качестве исхода оценивали как двигательное восстановление, так и когнитивную дисфункцию с оценкой по MoCA, а в качестве использованных предикторов стоит отметить латерализацию очага поражения и исходное когнитивное снижение, выявляемое с помощью опросника-информатора о снижении когнитивных функций у пожилых людей (IQCODE) [18].

Наше исследование носило ретроспективный характер, в отличие от двух вышеупомянутых работ, но это позволило включить в обучающую выборку гораздо большее количество значений, в отличие от коллег (1617 против 103 и 160 пациентов) [17, 18].

Проанализировав результаты ранее выполненных работ, можно сделать вывод об отсутствии универ-

сальной прогностической модели, что обуславливает предпосылки для продолжения совершенствования разработки моделей прогноза при инсульте с учетом динамически меняющейся структуры сопутствующей патологии, региональных особенностей предикторов, выявления новых факторов, оказывающих влияние на функциональный исход.

Обучение алгоритма нейронной сети целесообразно проводить на массивах данных конкретного региона с предварительным выделением предикторов, характерных для данного региона. Учитывая неравномерное распределение фоновых для инсульта заболеваний в зависимости от региона проживания [19, 20], вопрос влияния комбинации сопутствующих заболеваний у разных половозрастных групп на результат восстановления при инсульте требует дальнейшего изучения. В нашей работе предпринята попытка персонализированного подхода к использованию ИНС для прогнозирования раннего функционального исхода инсульта с учетом особенностей исходно выделенных предикторов. В свете растущего интереса к использованию алгоритмов машинного обучения в медицине может быть полезен штатный специалист по искусственному интеллекту, осуществляющий разработку моделей прогноза в клинической медицине на региональном уровне.

Заключение

Таким образом, в ходе нашего исследования была обучена и построена ИНС, позволяющая прогнозировать вероятность возникновения определенного функционального состояния у пациентов с инсультом в остром периоде.

В отсутствие значимых результатов при использовании методов классической статистики алгоритм ИНС продемонстрировал высокую точность и достаточную чувствительность обеих моделей при решении задачи мультиклассовой классификации. Исходя из более высоких значений показателей точности и чувствительности и меньших значений функции потерь для модели II (с оценкой исхода по mRS), данная модель может быть предпочтительна в прогнозировании раннего функционального исхода у пациентов с инсультом.

Литература / References

1. GBD 2019 Stroke Collaborators. Global, regional, and national burden of stroke and its risk factors, 1990-2019: a systematic analysis for the Global Burden of Disease Study 2019. *The Lancet Neurology*. 2021;20(10):795-820. DOI: 10.1016/S1474-4422(21)00252-0
2. Кадырова ИА, Миндубаева ФА, Гржибовский АМ. Систематический обзор методов прогнозирования исхода мозгового инсульта. *Экология человека*. 2015; (10):55-64. [Kadyrova IA, Mindubaeva FA, Grjibovski AM. Prediction of outcomes after stroke: a systematic review. *Human Ecology*. 2015; (10):55-64. (In Russian)] EDN UMDFIV
3. Daidone M, Ferrantelli S, Tuttolomondo A. Machine learning applications in stroke medicine: advancements, challenges, and future prospectives. *Neural Regeneration Research*. 2024;19(4):769-773. DOI: 10.4103/1673-5374.382228
4. Drozdowska BA, McGill K, McKay M, Bartlam R, Langhorne P, Quinn TJ. Prognostic rules for predicting cognitive syndromes following stroke: A systematic review. *European Stroke Journal*. 2021;6(1):18-27. DOI: 10.1177/2396987321997045
5. Тазартукова АД, Стаховская ЛВ. Прогнозирование отдаленных исходов мозгового инсульта. *Журнал неврологии и психиатрии им. С.С. Корсакова*. 2018;118(9-2):37-41. [Tazartukova AD, Stakhovskaya LV. Long-term outcome prediction in patients with stroke. *S. Korsakov Journal of Neurology and Psychiatry*. 2018;118(9-2):37-41. (In Russian)] DOI 10.17116/jnevro201811809237. EDN YOKZSP
6. Комарницкий ВС, Бодрова РА. Нейрореабилитация после церебрального инсульта: механизмы нейропластичности, биомаркеры исхода и инструменты оценки эффективности проводимых реабилитационных мероприятий (литературный обзор). *Евразийский союз ученых. Серия: медицинские, биологические и химические науки*. 2023;3-1(104):3-16. [Komarnitsky VS, Bodrova RA. Neurorehabilitation after a cerebral stroke: mechanisms of neuroplasticity, outcome biomarkers and tools for evaluating the effectiveness of ongoing rehabilitation measures (literature review). *Eurasian Union of Scientists. Series: Medical, Biological and Chemical Sciences*. 2023;3-1(104):3-16. (In Russian)] DOI 10.31618/ESU.2413-9335.2023.4.104.1.1781. EDN VKGXRF
7. Тынтерова АМ, Моисеева ЕМ, Голубев АМ, Шушарина НН. Роль эндотелинергических и нитроксидергических реакций в прогнозировании функционального исхода пациентов с различной степенью тяжести ишемического инсульта. *Общая реаниматология*. 2023; 19(5):13-20. [Tynterova AM, Moiseeva EM, Golubev AM, Shusharina NN. The role of endothelinergic and nitroxidergic reactions in predicting the functional outcome in patients with ischemic stroke of different severity. *General Reanimatology*. 2023; 19(5):13-20. (In Russian)] DOI 10.15360/1813-9779-2023-5-2354. EDN DQMBSN
8. Chen M, Qian D, Wang Y, An J, Meng K, Xu S, Liu S, Sun M, Li M, Pang C. Systematic Review of Machine Learning Applied to the Secondary Prevention of Ischemic Stroke. *Journal of Medical Systems*. 2024;48(1):8. DOI: 10.1007/s10916-023-02020-4
9. Лучинин АС. Прогностические модели в медицине. *Клиническая онкогематология. Фундаментальные исследования и клиническая практика*. 2023;16 (1):27-36. [Luchinin AS. Prognostic models in medicine. *Clinical O Basic Research and Clinical Practice*. 2023;16 (1):27-36. (In Russian)] DOI 10.21320/2500-2139-2023-16-1-27-36
10. Scrutinio D, Battista P, Guida P, Lanzillo B, Tortelli R. Sex Differences in Long-Term Mortality and Functional Outcome After Rehabilitation in Patients With Severe Stroke. *Frontiers in Neurology*. 2020;(11):84. DOI: 10.3389/fneur.2020.00084
11. Chen SD, You J, Yang XM, Gu HQ, Huang XY, Liu H, Feng JF, Jiang Y, Wang YJ. Machine learning is an effective method to predict the 90-day prognosis of patients with transient ischemic attack and minor stroke. *BMC Medical Research Methodology*. 2022;22(1):195. DOI: 10.1186/s12874-022-01672-z
12. Национальный стандарт Российской Федерации. Системы искусственного интеллекта в клинической медицине. Часть 5. Требования к структуре и порядку применения набора данных для обучения и тестирования алгоритмов. Дата введения 06.2022, дата актуализации 01.07.2023 Ссылка активна на 29.03.2024 [National standard of the Russian Federation. Artificial intelligence systems in clinical medicine. Part 5. Requirements for the structure and application of dataset for training and testing algorithms, date of introduction June 1, 2022, update date July 1, 2023, Accessed March 29, 2024 (In Russian)] <https://files.stroyinf.ru/Index/77/77593.htm>
13. Дудченко ПВ. Метрики оценки классификаторов в задачах медицинской диагностики. Молодежь и современные информационные технологии: Сборник трудов XVI Международной научно-практической конференции студентов, аспирантов и молодых ученых. Томск, 2019:164-165. [Dudchenko PV. Metrics for evaluating classifiers in medical diagnostic problems. Youth and modern information technologies: Collection of proceedings of the XVI International Scientific and Practical Conference of Students, Postgraduate Students and Young Scientists, Tomsk, 2019:164-165. (In Russian)] EDN ZBFNYT
14. Свидетельство о государственной регистрации программы для ЭВМ, РФ № 2023662382/ 07.06.2023. Бюл. № 6. Карякин АА, Хасанова НМ, Черных ЕМ, Карякина ОЕ. Программный модуль прогнозирования раннего функционального исхода острого нарушения мозгового кровообращения. Ссылка активна на 03.2024 [Certificate of state registration of a computer program, RU № 2023662382/June 7, 2023. Bull. № 6. Karyakin AA, Khasanova NM, Chernykh EM, Karjakina OE. Software module for predicting the early functional outcome of acute cerebrovascular accident. Accessed March 29, 2024 (In Russian)] https://elibrary.ru/download/elibrary_54049177_90861794.PDF, EDN VHFTSZ

15. THRIVE Score for Stroke Outcome. Accessed March 29, <https://www.mdcalc.com/calc/1706/thrive-score-stroke-outcome#creator-insights>

16. Flint AC, Chan SL, Edwards NJ, Rao VA, Klingman JG, Nguyen-Huynh MN, Yan B, Mitchell PJ, Davis SM, Campbell BC, Dippel DW, Roos YB, van Zwam WH, Saver JL, Kidwell CS, Hill MD, Goyal M, Demchuk AM, Bracard S, Bendszus M, Donnan GA. Outcome prediction in large vessel occlusion ischemic stroke with or without endovascular stroke treatment: THRIVE-EVT. *International Journal of Stroke*. 2023;18(3):331-337. DOI: 10.1177/17474930221092262

17. Репина ЛА, Романова ТВ, Повереннова ИЕ, Муртазина АХ. Прогностическая модель исхода ишемического инсульта. *Наука и инновации в медицине*. 2023;8(3):181-188. [Repina LA, Romanova TV, Poverenona IE, Murtazina AKh. A prognostic model for ischemic stroke outcome. *Science and Innovation in Medicine*. 2023;8(3):181-188. (In Russian)] DOI 10.35693/2500-1388-2023-8-3-181-188

18. Тынтерова АМ., Баранцевич ЕР, Шушарина НН, Хоймов МС. Персонализированный подход в оценке функционального исхода острого ишемического инсульта. *Физическая и реабилитационная медицина, медицинская реабилитация*. 2024;6(1):5-15. [Tynterova AM, Barantsevich ER, Shusharina NN, Khoymov MS. Personalized approach to assessing the functional result of acute ischemic stroke. *Physical and Rehabilitation Medicine, Medical Rehabilitation*. 2024;6(1):5-15. (In Russian)] DOI: <https://doi.org/10.36425/rehab623694>

19. Turana Y, Tengkwang J, Chia YC, Nathaniel M, Wang JG, Sukonthasarn A, Chen CH, Minh HV, Buranakitjaroen P, Shin J, Siddique S, Nailes JM, Park S, Teo BW, Sison J, Ann Soenarta A, Hoshide S, Tay JC, Prasad Sogunuru G, Zhang Y, Verma N, Wang TD, Kario K; HOPE Asia Network. Hypertension and stroke in Asia: A comprehensive review from HOPE Asia. *The Journal of Clinical Hypertension (Greenwich)*. 2021;23(3):513-521. DOI: 10.1111/jch.14099

20. Shao H, Yang S, Stoecker C, Fonseca V, Hong D, Shi L. Addressing Regional Differences in Diabetes Progression: Global Calibration for Diabetes Simulation Model. *Value Health*. 2019;22(12):1402-1409. DOI: 10.1016/j.jval.2019.08.007

Сведения об авторах

Черных Екатерина Михайловна, аспирант кафедры семейной медицины и внутренних болезней, Северный государственный медицинский университет, адрес: Российская Федерация, 163000, г. Архангельск, пр. Троицкий, д. 51, тел.: +7(921)2459699; e-mail: raduga0302@mail.ru, <https://orcid.org/0000-0002-6523-7071>

Хасанова Нина Минувалиевна, к.м.н., доцент кафедры семейной медицины и внутренних болезней, Северный государственный медицинский университет, адрес: Российская Федерация, 163000, г. Архангельск, пр. Троицкий, д. 51; тел.: +7 (911)5645611; e-mail: khasanovanina@rambler.ru, <https://orcid.org/0000-0003-0729-3726>

Карякин Алексей Андреевич, к.т.н., доцент, зав. кафедрой медицинской и биологической физики, Северный государственный медицинский университет, адрес: Российская Федерация, 163000, г. Архангельск, пр. Троицкий, д. 51, тел.: +7(981)5538293; e-mail: biophysica@yandex.ru, <https://orcid.org/0009-0002-4458-8702>

Карякина Ольга Евгеньевна, к.б.н., доцент кафедры биологии человека и биотехнических систем, Северный (Арктический) федеральный университет имени М.В. Ломоносова, адрес: Российская Федерация, 163002, г. Архангельск, наб. Северной Двины, д. 17, тел.: +7(911)5528836; e-mail: o.travnikova@narfu.ru, <https://orcid.org/0000-0003-0781-0164>

Author information

Ekaterina M. Chernykh, graduate student of the Department of Family Medicine and Internal Diseases, Northern State Medical University, Address: 51, Troitsky prospect, Arkhangelsk, Russian Federation 163000, Phone: +7(921)2459699; e-mail: raduga0302@mail.ru, <https://orcid.org/0000-0002-6523-7071>

Nina M. Khasanova, Cand. Med. Sci., Associate Professor of the Department of Family Medicine and Internal Diseases, Northern State Medical University; Address: 51, Troitsky prospect, Arkhangelsk, Russian Federation 163000, Phone: +7(911)5645611; e-mail: khasanovanina@rambler.ru, <https://orcid.org/0000-0003-0729-3726>

Aleksey A. Karyakin, Cand. Techn. Sci., Associate Professor, Head of the Department of Medical and Biological Physics, Northern State Medical University; Address: 51, Troitsky prospect, Arkhangelsk, Russian Federation 163000, Phone: +7(981)5538293; e-mail: biophysica@yandex.ru, <https://orcid.org/0009-0002-4458-8702>

Olga E. Karyakina, Cand. Biolog. Sci., Associate Professor, Department of Human Biology and Biotechnical Systems, M.V. Lomonosov Northern (Arctic) Federal University; Address: 17, emb. Northern Dvina, Arkhangelsk, Russian Federation 163002, Phone: +7(911)5528836; e-mail: o.travnikova@narfu.ru, <https://orcid.org/0000-0003-0781-0164>

Дата поступления: 04.04.2024
Дата рецензирования: 06.05.2024
Принято к публикации: 28.05.2024

Received 04 April 2024
Revision Received 06 May 2024
Accepted 28 May 2024