



<https://doi.org/10.24060/2076-3093-2020-10-3-198-204>

Нейронные сети для прогнозирования динамики развития заболеваний

Хасанов Анвар Гиниятович — д.м.н., профессор, кафедра хирургических болезней, orcid.org/0000-0001-5870-8894

Шайбаков Данис Габдинурович — к.м.н., кафедра хирургических болезней

Жернаков Сергей Владимирович — д.т.н., профессор, кафедра электроники и биомедицинских технологий

Меньшиков Алексей Михайлович — к.м.н., главный врач

Бадретдинова Фларид Фуатовна — к.м.н., кафедра акушерства и гинекологии ИДПО, orcid.org/0000-0003-3632-6021

Суфияров Ильдар Фанусович — д.м.н., профессор, кафедра хирургических болезней, orcid.org/0000-0001-8688-8458

Сагадатова Юлия Рязовна — кафедра хирургических болезней, orcid.org/0000-0002-2922-7087

А.Г. Хасанов^{1,2,}, Д.Г. Шайбаков², С.В. Жернаков³, А.М. Меньшиков¹, Ф.Ф. Бадретдинова^{1,2}, И.Ф. Суфияров², Ю.Р. Сагадатова²*

¹ Городская клиническая больница № 8, Россия, Республика Башкортостан, Уфа

² Башкирский государственный медицинский университет, Россия, Республика Башкортостан, Уфа

³ Уфимский государственный авиационный технический университет, Россия, Республика Башкортостан, Уфа

* **Контакты:** Хасанов Анвар Гиниятович, e-mail: hasanovag@mail.ru, тел.: +7 (927) 310-01-06

Аннотация

Введение. В настоящее время наблюдается широкое внедрение компьютерных технологий в медицину. Медицинская нейроинформатика позволяет анализировать задачи диагностики и прогнозирования различных заболеваний с помощью нейросетей. Актуальность применения искусственных нейронных сетей объясняется их востребованностью и практичностью в использовании.

Материалы и методы. На наш взгляд, наглядным примером возможности изучения вопросов прогнозирования течения заболевания является рожистое воспаление. В данной работе произведена обработка данных ретроспективного исследования историй болезней пациентов, получавших стационарное лечение на базе ГБУЗ РБ ГКБ № 8 г. Уфы в период 2006–2015 гг. для решения задачи прогнозирования рожистого воспаления с использованием современных статистических пакетов программ и среды моделирования MATLAB.

Результаты и обсуждение. Результаты сравнительного анализа показали, что в качестве архитектуры нейросети наиболее целесообразно выбрать 3-слойную рекуррентную сеть прямого распространения. В рассматриваемом случае оптимальная структура нейросети имеет вид: 27–6–1 (т.е. используется 27 нейронов на входе, 6 — в скрытом слое, 1 нейрон в выходном слое). Наилучшая сходимость процесса обучения сети обеспечивается при использовании квазиньютоновского алгоритма и алгоритма сопряженных градиентов. При оценке эффективности нейросетевого прогнозирования динамики развития рожистого воспаления был осуществлен сравнительный анализ с рядом классических методов: экспоненциального сглаживания, скользящего среднего, метода наименьших квадратов, метода группового учета аргумента.

Заключение. Применение предложенных в работе нейросетевых методов прогнозирования динамики развития рожистой патологии, основанного на аппроксимации и экстраполяции процессов изменения анамнеза пациента на фиксированных отрезках временного окна (в пределах «скользящего временного окна»), позволяет эффективно решать задачи прогнозирования.

Ключевые слова: нейронные сети, электронная обработка информации, рожа, прогнозирование, нейрон, рекуррентная сеть, автоматизированное принятие решений

Для цитирования: Хасанов А.Г., Шайбаков Д.Г., Жернаков С.В., Меньшиков А.М., Бадретдинова Ф.Ф., Суфияров И.Ф., Сагадатова Ю.Р. Нейронные сети для прогнозирования динамики развития заболеваний. Креативная хирургия и онкология. 2020;10(3): 198–204. <https://doi.org/10.24060/2076-3093-2020-10-3-198-204>

Neural Networks in Forecasting Disease Dynamics

Anvar G. Hasanov^{1,2,*}, Danis G. Shaybakov², Sergey V. Zhernakov³, Aleksey M. Men'shikov¹, Flarida F. Badretdinova^{1,2}, Ildar F. Sufiyarov², Julija R. Sagadatova²

¹ City Clinical Hospital No. 8, Ufa, Russian Federation

² Bashkir State Medical University, Ufa, Russian Federation

³ Ufa State Aviation Technical University, Ufa, Russian Federation

* **Correspondence to:** Anvar G. Hasanov, e-mail: hasanovag@mail.ru, tel.: +7 (927) 310-01-06

Abstract

Introduction. In recent years, computer technologies are more and more widely used in medicine. Thus, medical neuroinformatics solves diagnostic and forecasting tasks using neural networks.

Materials and methods. Using the example of erysipelas, the possibility of forecasting the course and outcome of the disease is demonstrated. A retrospective study of the medical histories of patients treated for erysipelas at the Ufa Clinical Hospital No.8 during 2006–2015 was carried out. Modern statistical packages and the MATLAB environment were used.

Results and discussion. The conducted comparative analysis showed a 3-layer recurring network of direct distribution to be the most suitable neural network architecture. The optimal structure of the neural network was found to be: 27–6–1 (i.e. 27 neurons are used at the entrance; 6 — in a hidden layer; 1 — in the output layer). The best convergence of the network learning process is provided by the quasi-Newton and conjugated gradient algorithms. In order to assess the effectiveness of the proposed neural network in predicting the dynamics of inflammation, a comparative analysis was carried out using a number of conventional methods, such as exponential smoothing, moving average, least squares and group data handling.

Conclusion. The proposed neural network based on approximation and extrapolation of variations in the patient's medical history over fixed time window segments (within the 'sliding time window') can be successfully used for forecasting the development and outcome of erysipelas.

Keywords: neural networks, digital information processing, erysipelas, forecasting, neuron, recurrent network, automated decision-making

For citation: Hasanov A.G., Shaybakov D.G., Zhernakov S.V., Men'shikov A.M., Badretdinova F.F., Sufiyarov I.F., Sagadatova J.R. Neural Networks in Forecasting Disease Dynamics. *Creative Surgery and Oncology*. 2020;10(3): 198–204. <https://doi.org/10.24060/2076-3093-2020-10-3-198-204>

Anvar G. Hasanov — Dr. Sci. (Med.), Prof., Department of Surgical Diseases, orcid.org/0000-0001-5870-8894
Danis G. Shabayakov — Cand. Sci. (Med.), Department of Surgical Diseases
Sergey V. Zhernakov — Dr. Sci. (Engineering), Prof., Department of Electronic and Biomedical Technologies
Aleksey M. Menshikov — Cand. Sci. (Med.), Chief Doctor
Flarida F. Badretdinova — Cand. Sci. (Med.), Department of Obstetrics and Gynecology for Advanced Professional Education, orcid.org/0000-0003-3632-6021
Ildar F. Sufiyarov — Dr. Sci. (Med.), Prof., Department of Surgical Diseases, orcid.org/0000-0001-8688-8458
Yulia R. Sagadatova — Department of Surgical Diseases, orcid.org/0000-0002-2922-7087

Введение

Быстрое развитие медицины, огромный поток поступающей информации об этиологии, патогенезе заболеваний диктуют правила для поиска новых методов обработки полученных результатов. В таких условиях важно уметь находить нужную информацию и принимать правильные решения, от которых будут зависеть течение и исход заболевания. Широкое внедрение компьютерных технологий, создание программных обеспечений позволяют анализировать задачи диагностики и прогнозирования различных заболеваний. Одним из перспективных направлений медицинской нейробиологии являются нейронные сети (НС). Актуальность применения искусственных нейронных сетей объясняется их востребованностью и практичностью в использовании.

Впервые о нейронных сетях заговорили в 1943 году, когда У. Маккалог и У. Питтс создали первую математическую модель нейронной сети. Практическая модель при помощи компьютера была создана в 1957 году Ф. Розенблаттом. С тех пор нейронная сеть стала активно применяться в различных сферах жизни общества и в науке [1–4].

Принцип работы НС основан на алгоритмах работы биологических нейронных сетей. Поступающие в искусственные нейроны сигналы суммируются, преобразуются и выдают нужный результат. НС можно обучать, указывая обобщающие параметры для выборки, чтобы она показывала корректные результаты. К тому же по скорости и запоминанию информации НС могут даже превосходить человеческий мозг.

В зависимости от количества нейронов НС подразделяются на однослойные, настроенные на выполнение простейших команд, и многослойные, обладающие большей вычислительной способностью. На их основе создаются различные автоматизированные системы диагностики, системы распознавания текста, системы анализа и прогнозирования, системы автоматической классификации и сверки информации.

Вопросы прогнозирования становятся актуальными, когда имеем дело с хроническими рецидивирующими заболеваниями или наблюдается определенная стадийность течения воспаления. Несмотря на то что в мире существует огромное количество методик прогнозирования, нет единого автоматизированного механизма, который позволил бы осуществить указанную задачу в короткие сроки. Более того, индивидуальные особенности организма больного, возраст, динамика развития заболевания и другие показатели делают невозможным применение данных методик на практике. Необходимо также учитывать объем статистического материала (малая выборка), потерю информации, пропуски данных и т. д. В итоге результат прогноза может быть недостоверен. В качестве примера можно привести острый аппендицит, возникающий как катаральное воспаление и переходящий во флегмонозную, гангренозную формы воспаления. Аналогично в отношении острого холецистита (катаральная форма переходит во флегмонозную, далее в гангренозную форму). В клинической практике

очень трудно проследить переход одной формы воспаления в другую.

На наш взгляд, наглядным примером возможности изучения вопросов прогнозирования течения заболевания является рожистое воспаление. Согласно общепринятой классификации рожистого воспаления (Черкасов В.Л., 1986) выделяют эритематозную, эритемо-буллезную, эритемо-геморрагическую и буллезно-геморрагическую формы воспаления [2, 5–9]. Ряд авторов выделяют еще флегмонозную и некротическую формы рожистого воспаления. При этом у части больных отмечается четкая стадийность течения процесса т.е. переход поверхностных форм воспаления в более глубокие со значительным повреждением мягких тканей конечностей и увеличением числа летальных исходов. У некоторых больных инфекционный процесс останавливается на уровне эритематозной или эритематозно-буллезной формы воспаления. С указанных позиций вопросы прогнозирования течения рожистого воспаления являются актуальными [9, 10]. Многолетние исследования в области нейросетевого прогнозирования привели к созданию большого количества публикаций [8–16]. Однако эти исследования не содержат детального описания математических моделей прогнозирования различных заболеваний. Данные работы содержат лишь единичные рекомендации использования нейронных сетей, а также алгоритмы их обучения, наглядные примеры.

Постановка задачи

Пусть имеется временной ряд, последние N отсчетов которого принимают вид:

$$Y(t-N+1), Y(t-N+2), \dots, Y(t), \quad (1)$$

где Y — вектор контролируемых параметров двигателя; t — дискретное время.

Задача прогнозирования в нейросетевом базисе сводится к построению нейросетевой модели (предиктора), позволяющей найти значения вектора Y в момент времени $t+1$ по предшествующим N значениям временного ряда, т.е.

$$Y(t+1) = f[Y(t), Y(t-1), \dots, Y(t-N+1)], \quad (2)$$

где $f(\bullet)$ — некоторая нелинейная вектор — функция, которую требуется оценить с помощью НС.

Достоверность прогноза можно оценить по следующему выражению:

$$\|\epsilon_{t+1}\| = \|\hat{Y}_{t+1} - Y_{t+1}\|, \quad (3)$$

где \hat{Y}_{t+1} — прогнозируемое значение, вычисленное НС для момента времени $t+1$; Y_{t+1} — реальное значение вектора Y в этот же момент времени; ϵ_{t+1} — ошибка прогноза.

Достоинствами НС являются:

- способность фильтрации посторонних шумов. После обучения НС способны воспринимать только нужную информацию;
- во время работы НС непрерывно находятся в состоянии самообучения, что лежит в основе их адаптации;

- быстрое выполнение команд за короткое время;
- возможность анализировать несколько параметров одновременно;
- возможность работы с большим объемом данных;
- удобны в использовании.

Материалы и методы

В данной работе произведена обработка данных ретроспективного исследования историй болезней пациентов, получавших стационарное лечение на базе ГБУЗ РБ ГКБ № 8 г. Уфы в период 2006–2015 гг. для решения задачи прогнозирования рожистого воспаления с использованием современных статистических пакетов программ и среды моделирования MATLAB. Использовалась рекуррентная (динамическая) НС, реализующая зависимость вида (2).

На рисунке 1 приведена архитектура рекуррентной НС, где Z^{-1} — элемент временной задержки на один такт Δt ; N — число элементов задержки (размер «временного окна»); $y_i(t+1)$ — прогнозируемое (на один шаг вперед) значение параметра $y_i(t)$.

Рассмотрим более детально описание способа прогнозирования динамики развития рожистого воспаления, построенной на основе экстраполирующих функций $y_i(t)$ как функции времени:

$$y_i(t) = f(t), \quad (4)$$

где t — текущее время. Реализация данного подхода в нейросетевом базисе осуществляется следующим образом:

- выделяется временной интервал (интервал наблюдения), который является обучающей выборкой для НС (t — вход нейронной сети; параметры y_1, y_2, \dots, y_n пациента — ее выходы);
- задается шаг прогноза — $T_{\text{прогн.}}$ с учетом требований к прогнозу (краткосрочный, среднесрочный, долгосрочный прогноз);
- после процесса обучения НС на интервале наблюдения ($T_{\text{набл.}}$) вычисляются прогнозируемые значения $y_i(t+T_{\text{прогн.}})$, для этого на вход НС подается значение времени ($t+T_{\text{прогн.}}$);
- далее процесс прогнозирования повторяется в режиме реального времени.

Исходные данные

Анамнез пациента в обучающей выборке включает в себя (табл. 1): Y_1 — пол пациента; Y_2 — место проживания; Y_3 — возраст; Y_4 — время от начала з/б (ч); Y_5 — тяжесть состояния; Y_6 — форма выявления; Y_7 — сезон; Y_8 — локализация; Y_9 — D-димер, мкг/мл; Y_{10} — лейкоциты крови; Y_{11} — местная температура (холодная зона); Y_{12} — лихорадочный период (сутки); Y_{13} — сопут. ССЗ; Y_{14} — органы дыхания и др.

Результаты и обсуждение

Выбор архитектуры НС

Как видно из результатов сравнительного анализа, в качестве архитектуры НС наиболее целесообразно выбрать 3-слойную рекуррентную сеть прямого распространения.




Рисунок 1. Архитектура рекуррентной НС
Figure 1. Architecture of a recurrent neural network

Выбор структуры НС

Результаты экспериментальных исследований НС приведены на рисунке 2, откуда следует, что минимальная ошибка обучения НС на интервале наблюдения, содержащем 12 отсчетов, обеспечивается при числе нейронов скрытого слоя равном шести.

Итак, в рассматриваемом случае оптимальная структура НС имеет вид: 27–6–1 (т.е. используется 27 нейронов на входе, 6 — в скрытом слое, 1 нейрон в выходном слое). Как видно из рисунка 2, при дальнейшем увеличении количества нейронов в скрытом слое сверх шести качество ее работы ухудшается, что объясняется эффектом «переобучения». В качестве «временного окна», формирующего прогнозируемый ряд, целесообразно задать 17 элементов.

Выбор алгоритма обучения

Лучше всего сходимость процесса обучения сети обеспечивается при использовании квазиньютоновского алгоритма и алгоритма сопряженных градиентов.

Оценка эффективности решения задачи прогнозирования с помощью НС

При оценке эффективности нейросетевого прогнозирования динамики развития рожистого воспаления был осуществлен сравнительный анализ с рядами классических методик: экспоненциального сглаживания, скользящего среднего, метода наименьших квадратов, метода группового учета аргумента.

При этом прогноз по методу скользящего среднего осуществлялся по формуле:

$$y_{t+1} = \frac{1}{N} \sum_{b=0}^N y_{t-b+1}, \quad (5)$$

где N — число предшествующих периодов, входящих в скользящее среднее; y_t — фактическое значение в момент времени t ; y_{t+1} — прогнозируемое значение в момент времени $(t+1)$.

| T | Y1 | Y2 | Y3 | Y4 | Y5 | Y6 | Y7 | Y8 | Y9 | Y10 | Y11 | Y12 | Y13 | Y14 | Y15 |
|------|----|----|----|-----|----|----|----|----|----|-----|-----|-----|-----|-----|-----|
| 2006 | 1 | 1 | 50 | 744 | 4 | 4 | 1 | 2 | 3 | 3 | 3 | 3 | 5 | 1 | 1 |
| 2006 | 2 | 1 | 68 | 720 | 3 | 4 | 1 | 1 | 3 | 3 | 2 | 3 | 4 | 1 | 1 |
| 2006 | 1 | 1 | 49 | 48 | 2 | 2 | 1 | 4 | 2 | 1 | 2 | 3 | 2 | 0 | 0 |
| 2006 | 2 | 1 | 74 | 192 | 2 | 3 | 3 | 1 | 3 | 1 | 1 | 2 | 3 | 1 | 0 |
| 2006 | 1 | 1 | 28 | 120 | 2 | 3 | 1 | 1 | 3 | 1 | 1 | 1 | 2 | 0 | 1 |
| 2006 | 1 | 1 | 54 | 168 | 3 | 4 | 1 | 3 | 3 | 2 | 1 | 3 | 5 | 0 | 0 |
| 2006 | 2 | 1 | 83 | 144 | 2 | 3 | 1 | 2 | 2 | 2 | 2 | 2 | 3 | 1 | 0 |
| 2006 | 1 | 1 | 57 | 288 | 3 | 5 | 1 | 3 | 2 | 2 | 2 | 3 | 4 | 1 | 0 |
| 2006 | 2 | 1 | 78 | 96 | 3 | 4 | 1 | 1 | 3 | 1 | 1 | 1 | 3 | 1 | 0 |
| 2006 | 2 | 1 | 19 | 24 | 1 | 1 | 1 | 4 | 2 | 2 | 1 | 1 | 1 | 0 | 0 |
| 2006 | 2 | 1 | 52 | 38 | 2 | 4 | 3 | 1 | 3 | 1 | 2 | 1 | 3 | 1 | 0 |
| 2006 | 1 | 2 | 49 | 96 | 1 | 1 | 1 | 2 | 3 | 2 | 1 | 1 | 2 | 0 | 0 |
| 2006 | 2 | 1 | 39 | 288 | 2 | 5 | 1 | 1 | 3 | 2 | 2 | 1 | 2 | 0 | 0 |
| 2006 | 1 | 1 | 54 | 72 | 2 | 4 | 1 | 3 | 3 | 2 | 1 | 1 | 3 | 0 | 0 |
| 2006 | 1 | 1 | 51 | 168 | 2 | 1 | 2 | 3 | 3 | 2 | 1 | 1 | 2 | 0 | 0 |
| 2006 | 1 | 1 | 79 | 8 | 2 | 1 | 2 | 4 | 3 | 2 | 1 | 1 | 2 | 1 | 0 |
| 2006 | 1 | 1 | 27 | 28 | 2 | 1 | 3 | 2 | 3 | 1 | 1 | 1 | 1 | 1 | 1 |
| 2006 | 2 | 2 | 83 | 48 | 2 | 1 | 1 | 3 | 3 | 2 | 1 | 1 | 3 | 1 | 0 |
| 2006 | 1 | 1 | 58 | 48 | 2 | 1 | 1 | 2 | 3 | 1 | 1 | 1 | 2 | 1 | 0 |
| 2006 | 1 | 1 | 35 | 24 | 1 | 1 | 1 | 2 | 3 | 1 | 1 | 1 | 1 | 0 | 1 |
| 2006 | 2 | 1 | 66 | 24 | 2 | 1 | 1 | 1 | 3 | 1 | 1 | 1 | 1 | 0 | 0 |
| 2006 | 2 | 2 | 63 | 96 | 2 | 3 | 1 | 1 | 3 | 2 | 2 | 1 | 2 | 1 | 0 |

Таблица 1. Фрагмент обучающей выборки по результатам анамнеза пациента
Table 1. Fragment of the training sample based on a patient's medical history

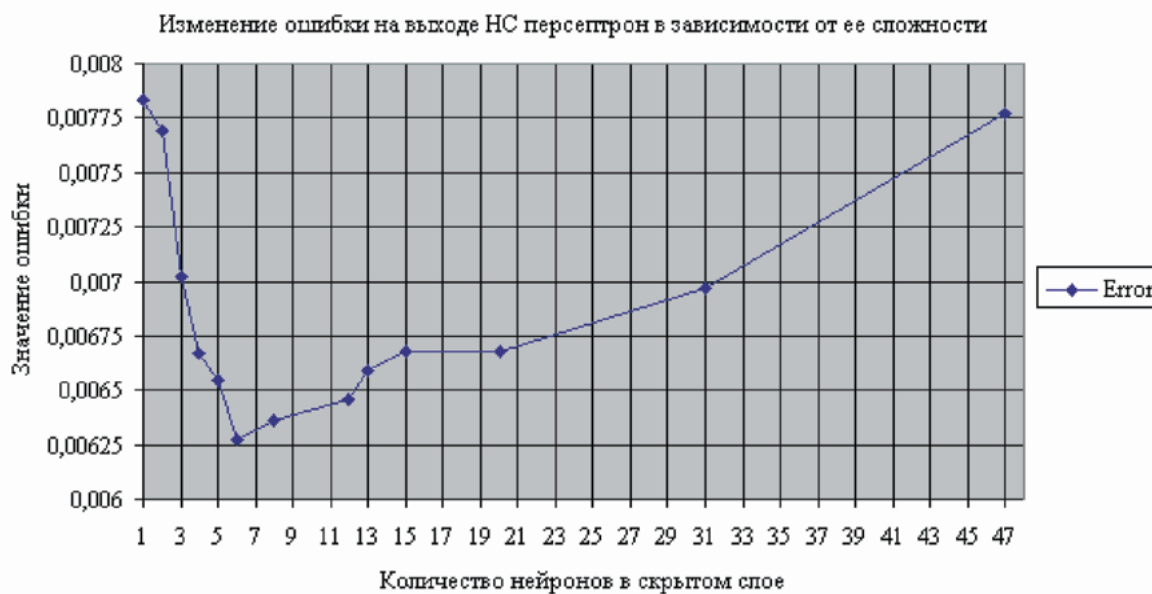


Рисунок 2. Зависимость ошибки обучения НС от числа нейронов скрытого слоя
Figure 2. Dependence of the learning error of the neural network on the number of neurons in the hidden layer

Для прогноза по методу экспоненциального сглаживания применялось выражение:

$$y_{t+1} = y_t + \alpha(A_t - y_t) = \alpha \cdot A_t + (1-\alpha) \cdot y_t, \quad (6)$$

где y_{t+1} — предсказанное значение параметра на основе предыдущего значения y_t , скорректированного с учетом погрешности прогноза $A_t - y_t$ и весового коэффициента α ($0 < \alpha < 1$). Экспериментальные исследования ре-

шения задачи прогноза с помощью метода наименьших квадратов показали, что экстраполирующая функция $f(t)$ может быть выбрана в виде полинома девятого порядка. На рисунке 3 показана поверхность $Y = f(t)$, построенная с помощью среды моделирования MATLAB, где $Y = (Y_{10}, Y_{11})^T$, а время $t \in [2008; 2011]$ соответствует годам исследования.

Последующий рост степени полинома практически не гарантирует уменьшения погрешности аппроксимации функции $Y = f(t)$.

На рисунке 4 приведены результаты сравнительного анализа нейросетевого и классических методов прогнозирования динамики развития рожистого воспаления для наиболее значимого параметра: местного осложнения. Здесь: CC_{ER} — прогнозное значение, вычисленное на основе метода скользящего среднего; $ЭC_{ER}$ — прогнозное значение, вычисленное с использованием метода экспоненциального сглаживания; MNC_{ER} — прогнозное значение, вычисленное с использованием метода наименьших квадратов; $MGUA_{ER}$ — прогнозное значение, вычисленное с использованием метода группового учета аргумента; NS_WORDA_{ER} — прогнозное значение, вычисленное с использованием нейронной сети Ворда; NS_VER_{ER} — прогнозное значение, вычисленное с использованием вероятностной нейронной сети; PTR_{ER} — прогнозное значение, вычисленное с использованием рекуррентной нейронной сети.

Результаты сравнительного анализа работы классических и нейросетевых методов прогнозирования динамики развития рожистого воспаления приведены в таблице 2 и на рисунке 4.

Посмотрев на результаты таблицы 2 и рисунка 4, мы можем убедиться, что НС и метод группового учета аргумента дают точные результаты в прогнозировании рожистой патологии.

Если сравнивать такие методы прогнозирования, как нейросетевой и метод наименьших квадратов, то мы можем заметить, что достоверность первого будет выше соответственно в 2,60, 1,95 и 9,81 раза. Такого рода погрешность прогнозирования, основанная на методе скользящего среднего, выше по сравнению с нейросетевыми методами в 17,73, 13,00 и 66,98 раза соответственно; а для метода экспоненциального сглаживания погрешность прогнозирования снова выше по сравнению с нейросетевыми методами в 11,75, 8,81 и 41,95 раза соответственно. Погрешность метода группового учета аргумента оказалась приемлемой и не уступала нейросетевым методам. Это означает, что данный метод может быть использован в качестве альтернативы наряду с нейросетевыми методами.

Заключение

С учетом вышесказанного можно сделать заключение, что применение представленного в работе нейросетевого метода прогнозирования динамики развития рожистой патологии, основанного на аппроксимации и экстраполяции процессов изменения анамнеза пациента на фиксированных отрезках временного окна (в пределах «скользящего временного окна»), дает возможность эффективно решать задачи прогнозирования.

Информация о конфликте интересов. Конфликт интересов отсутствует.

Информация о спонсорстве. Данная работа не финансировалась.

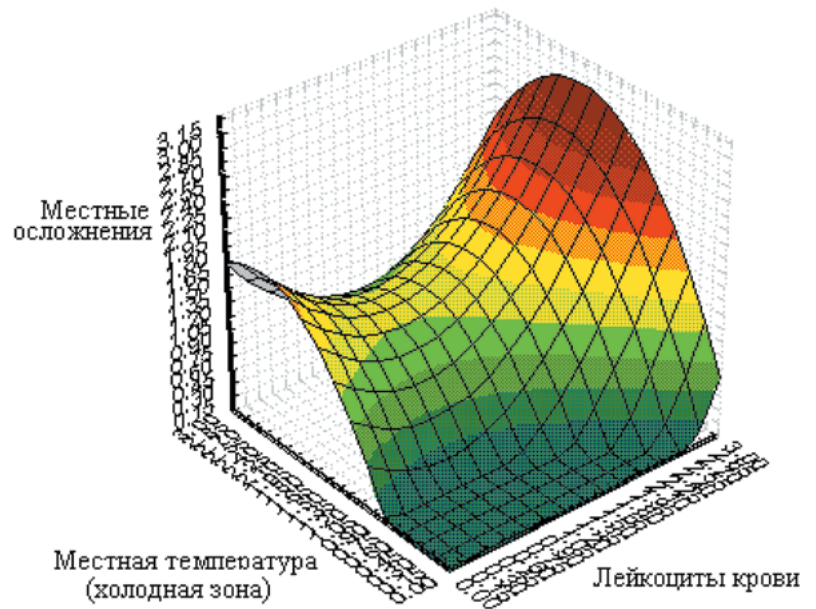


Рисунок 3. Графическое представление функции $Y = f(t)$
Figure 3. Graphical representation of the function




Рисунок 4. Результаты прогноза динамики развития рожистого воспаления
Figure 4. Prediction results of the development of erysipelas

| Сравнительный анализ методов прогноза | | | | | | | |
|---------------------------------------|-------|-------|--------|---------|-------------|-----------|--------|
| N | CC_ER | ЭC_ER | MNC_ER | MGUA_ER | NS_WORDA_ER | NS_VER_ER | PTR_ER |
| Ошибка прогноза (%) | 13,33 | 8,81 | 1,95 | 0,59 | 0,75 | 1,00 | 0,21 |

Таблица 2. Сравнительный анализ методов прогноза
Table 2. Comparative analysis of forecasting methods

Список литературы

- 1 Кравченко В.О. Методы использования искусственных нейронных сетей в медицине. Устойчивое развитие науки и образования. 2018;6:266–70.
- 2 Глухов А.А., Бражник Е.А. Современный подход к комплексному лечению рожистого воспаления. Фундаментальные исследования. 2014;10:411–5.
- 3 Яхьяева Г.Э. Нечеткие множества и нейронные сети. М.: БИНОМ; 2012.
- 4 Aggarwal C.C. Neural networks and deep learning: a textbook. Springer; 2018. DOI 10.1007/978-3-319-94463-0 ISBN 978-3-319-94462-3
- 5 Айвазян С.А., Енюков И.С., Мешалкин Л.Д. Прикладная статистика. Классификация и снижение размерности. М.: Финансы и статистика; 1989.
- 6 Черкасов В.Л. Рожь. Л.: Медицина; 1986.
- 7 Цвиль М.М. Анализ временных рядов и прогнозирование. Ростов-на-Дону; 2016.
- 8 Seybold U., Stubbe H., Draenert R., Bogner J.R. Erysipelas. MMW Fortschr Med. 2018;160(10):37–40. DOI: 10.1007/s15006-018-0580-3
- 9 Karakonstantis S. Is coverage of *S. aureus* necessary in cellulitis/erysipelas? A literature review. Infection. 2020;48(2):183–91. DOI: 10.1007/s15010-019-01382-7
- 10 Жернаков С.В., Шайбаков Д.Г. Прогнозирование развития рожистой патологии на основе нейронных сетей. В кн: Нейрокомпьютеры и их применение: тезисы докладов XVII Всероссийской научной конференции. М.; 2019. С. 297–9.
- 11 Kriegeskorte N., Golan T. Neural network models and deep learning. Curr Biol. 2019;29(7):R231–6. DOI: 10.1016/j.cub.2019.02.034
- 12 Фаустова К.И. Нейронные сети: применение сегодня и перспективы развития. Территория науки. 2017;4:83–7.
- 13 Мустафаев А.Г. Использование нейросетевых технологий в задачах медицинской диагностики. Вестник компьютерных и информационных технологий. 2019;6:32–8. DOI: 10.14489/vkit.2019.06.pp.032-038
- 14 Волчек Ю.А., Шишко О.Н., Спиридонова О.С., Мохорт Т.В. Положение модели искусственной нейронной сети в медицинских экспертных системах. Juvenis Scientia. 2017;9:4–9. DOI: 10.15643/jscientia.2017.9.001
- 15 Pérez J., Cabrera J.A., Castillo J.J., Velasco J.M. Bio-inspired spiking neural network for nonlinear systems control. Neural Netw. 2018;104:15–25. DOI: 10.1016/j.neunet.2018.04.002
- 16 Хайкин С. Нейронные сети: полный курс. М.: Вильямс; 2016.

References

- 1 Kravchenko V.O. Methods of using of artificial neural networks in medicine. Sustainable development of science and education. 2018;6:266–70 (In Russ.).
- 2 Glukhov A.A., Brazhnik E.A. Modern approach to the comprehensive treatment of erysipelas. Fundamental research. 2014;10:411–5 (In Russ.).
- 3 Yakheva G.E. Fuzzy sets and neural networks. Moscow: BINOM; 2012 (In Russ.).
- 4 Aggarwal C.C. Neural networks and deep learning: a textbook. Springer; 2018. DOI 10.1007/978-3-319-94463-0 ISBN 978-3-319-94462-3
- 5 Ayvazyan S.A., Enyukov I.S., Meshalkin L.D. Practical statistics. Classification and dimensionality reduction. Moscow: Finansy i statistika; 1989 (In Russ.).
- 6 Cherkasov V.L. Erysipelas. Leningrad: Meditsina; 1986 (In Russ.).
- 7 Tsvil M.M. The time series analysis and forecasting. Rostov-on-Don; 2016 (In Russ.).
- 8 Seybold U., Stubbe H., Draenert R., Bogner J.R. Erysipelas. MMW Fortschr Med. 2018;160(10):37–40. DOI: 10.1007/s15006-018-0580-3
- 9 Karakonstantis S. Is coverage of *S. aureus* necessary in cellulitis/erysipelas? A literature review. Infection. 2020;48(2):183–91. DOI: 10.1007/s15010-019-01382-7
- 10 Zhernakov S.V., Shaibakov D.G. Prediction of erysipelas development based on neural networks. In: Neurocomputers and their use: abstracts of the XVII All-Russian scientific conference. Moscow; 2019:297–9 (In Russ.).
- 11 Kriegeskorte N., Golan T. Neural network models and deep learning. Curr Biol. 2019;29(7):R231–6. DOI: 10.1016/j.cub.2019.02.034
- 12 Faustova K.I. Neural networks: use today and future development. Territoriya nauki. 2017;4:83–7 (In Russ.).
- 13 Mustafaev A.G. Neural network technology in tasks of medical diagnostics. Vestnik komp'uternykh i informatsionnykh tekhnologii. 2019;6:32–8 (In Russ.). DOI: 10.14489/vkit.2019.06.pp.032-038
- 14 Volchek Y.A., Shyshko V.M., Spiridonova O.S., Mokhort T.V. Position of the model of the artificial neural network in medical expert systems. Juvenis Scientia. 2017;9:4–9 (In Russ.). DOI: 10.15643/jscientia.2017.9.001
- 15 Pérez J., Cabrera J.A., Castillo J.J., Velasco J.M. Bio-inspired spiking neural network for nonlinear systems control. Neural Netw. 2018;104:15–25. DOI: 10.1016/j.neunet.2018.04.002
- 16 Haykin S. Neural Networks: A Comprehensive Foundation. Moscow: Williams; 2016 (In Russ.).