

Вестник Евразийской науки / The Eurasian Scientific Journal <https://esj.today>

2018, №4, Том 10 / 2018, No 4, Vol 10 <https://esj.today/issue-4-2018.html>

URL статьи: <https://esj.today/PDF/47ITVN418.pdf>

Статья поступила в редакцию 15.08.2018; опубликована 03.10.2018

**Ссылка для цитирования этой статьи:**

Артеменко М.В., Добровольский И.И., Щекина Е.Н., Пошибайлова А.В. Синтез antecedent production rules для медицинских экспертных систем логическими искусственными нейронными сетями // Вестник Евразийской науки, 2018 №4, <https://esj.today/PDF/47ITVN418.pdf> (доступ свободный). Загл. с экрана. Яз. рус., англ.

**For citation:**

Artemenko M.V., Dobrovolsky I.I., Shhekina E.N., Poshibaylova A.V. (2018). Synthesis of antecedent production rules for medical expert systems logical artificial neural networks. *The Eurasian Scientific Journal*, [online] 4(10). Available at: <https://esj.today/PDF/47ITVN418.pdf> (in Russian)

*Грант №13030ГУ/2018 (вн. номер 0040013) от 11.05.2018 конкурса «УМНИК»*

**УДК 004.891.3+004.032.26+61**

**ГРНТИ 28.23.(20+25)+76.13.15**

**Артеменко Михаил Владимирович**

ФГБОУ ВО «Юго-Западный государственный университет», Курск, Россия

Кафедра «Биомедицинской инженерии»

Кандидат биологических наук, доцент

E-mail: [Artem1962@mail.ru](mailto:Artem1962@mail.ru)

ORCID: <http://orcid.org/0000-0003-1037-8288>

РИНЦ: [https://elibrary.ru/author\\_profile.asp?id=202249](https://elibrary.ru/author_profile.asp?id=202249)

SCOPUS: <http://www.scopus.com/authid/detail.url?authorId=6602572239>

**Добровольский Илья Игоревич**

ООО «Хелп Медиком Групп», Курск, Россия

Младший научный сотрудник

Кандидат технических наук

E-mail: [Iia\\_dobr@mail.ru](mailto:Iia_dobr@mail.ru)

**Щекина Елена Николаевна**

ФГБОУ ВО «Юго-Западный государственный университет», Курск, Россия

Кафедра «Биомедицинской инженерии»

Аспирант, магистр

E-mail: [elenashchekina@mail.ru](mailto:elenashchekina@mail.ru)

**Пошибайлова Александра Валерьевна**

ГБУЗ «Городская больница 2», Белгород, Россия

Перинатальный центр

Врач-Неонатолог

ФГБОУ ВО «Юго-Западный государственный университет», Курск, Россия

Кафедра «Биомедицинской инженерии»

Аспирант

E-mail: [poshibailova@yandex.ru](mailto:poshibailova@yandex.ru)

**Синтез antecedent production rules для медицинских экспертных систем логическими искусственными нейронными сетями**

**Аннотация.** В настоящее время возрастают требования к оперативности принимаемых решений в условиях большого количества факторов, характеризующих возникающие ситуации. Особую актуальность это приобретает в условиях цифровой реальности таких областей как: социология, медицина, экология и т. п. Это обуславливает актуальность разработки и продуктивной эксплуатации автоматизированных систем поддержки принятия решений на основе существующих и разрабатываемых инновационных инструментариев искусственного интеллекта. Гетерогенность и мультимодальность структур данных, характеризующих объект управления, обуславливают результативность применения универсальной метрики. В качестве таковой предлагается использовать бинарную. Далеко не всегда анализируемые процессы позволяют достаточно быстро и четко формировать обучающие выборки требуемого объема и качества. Существующие достижения метода группового учета аргументов (МГУА) позволяют разрешать противоречие между большим количеством информативных признаков и небольшой обучающей выборки при разработке архитектуры искусственной логической нейронной сети. Рассматриваются два типа нейронов – «логический нейрон» и «логико-арифметический нейрон» (структуры, алгоритмы обучения, рекомендации по применению). Приведено описание настройки предлагаемой искусственной логической нейронной сети в целом. Представлены результаты экспериментальных исследований в клинической медицине на оценки риска летального исхода от тромбоэмболии при эндопротезировании. Представленные в данной статье результаты исследования возможностей применения самоорганизационных искусственных логических нейронных сетей в медицинских экспертных системах выполнены в продолжение более ранних исследований младшего научного сотрудника ООО «Хелп Медиком Групп» Добровольского И.И. (2015-2018 года).

#### **Вклад авторов.**

Артеменко Михаил Владимирович – внес существенный вклад в разработку методологии синтеза искусственной логической нейронной сети на основе МГУА подобной архитектуры, принимал участие в разработке и верификации алгоритма обучения представляемой сети; осуществлял коррекцию рабочих материалов статьи; одобрил окончательную версию статьи перед её подачей для публикации.

Добровольский Илья Игоревич – внес существенный вклад в подготовке материалов научных исследований (в том числе, к публикации). Изучил возможности существующих искусственных нейронных сетей для применения в составе медицинских экспертных сетей, предложил два типа элементарных искусственных нейронов, разработал программное обеспечение сети. Собрал и осуществил первичную обработку клинического материала по прогнозированию тромбоэмболии после эндопротезирования крупных суставов, выполнил синтез решающих классификационных правил на основе предлагаемой логической нейронной сети.

Пошибайлова Александра Валерьевна – осуществила написание статьи, аналитический обзор информационных источников по рассматриваемой проблематике; одобрила окончательную версию статьи перед её подачей для публикации.

Щекина Елена Николаевна – оказала участие в проверке адекватности полученных решающих правил на клиническом материале, получила эмпирические значения показателей качества – диагностические чувствительности, эффективности, специфичности; одобрила окончательную версию статьи перед её подачей для публикации.

**Ключевые слова:** медицинские экспертные системы; решающие продукционные правила; antecedent; искусственные логические нейронные сети; метод группового учета аргументов; прогнозирование тромбоэмболии

## Введение

Информатизация общества, прогрессирующее развитие цифровой реальности [1], обуславливает повышение требований к быстрой и адаптивной оценке ситуации в условиях гетерогенным образом представленной информации с целью оперативного принятия решения корректирующего или управляющего характера. Поскольку объем информации об объекте или процессе в данном случае превышает аналитические возможности одного человека и возрастают требования к качеству последствий принятого решения в информационном обществе с сетевой организацией регулирующих систем различных иерархических уровней, то развиваются компьютерные и информационные технологии проектирования и эксплуатации систем поддержки принятия решений (СППР) различной степени автоматизации [2, 3].

Одной из базовой составляющей СППР является база знаний, которая содержит решающие правила различных типов. Например: альтернативные, нечеткие, гибридные, продукционные, байесовские, фреймовые, семантические, лингвистические. Контент-анализ тенденций развития СППР, показал, что наибольшее распространение продукционные конструкции [4, 5], особенно в предметных областях, соответствующих конвергенциям гуманитарных и технических аспектов миропонимания – медицине, экологии, экономики, социологии [6, 7].

Указанные области характеризуются слабоопределенной и-или нечеткой как структурой данных, так и их описанием, и не возможностью строго соблюдения условия повторяемости эмпирических наблюдений (в силу однонаправленности стрелы времени Пригожина [8]). Эти недостатки компенсируются за счет значительного увеличения размерности признакового пространства для снятия возникающих неопределенностей.

В этом случае возникает противоречие между большим количеством прямых и латентных признаков, характеризующих состояние объекта (или процесса) управления и представленных в различных метрических пространствах, и необходимостью оперативного анализа и принятия решения для изменения такого. Оптимальное и результативное применение четких и нечетких правил вывода в решающих продукционных правилах баз знаний СППР, в этом случае, обуславливает повышенные требования к результативности условий активации классифицирующих продукций – анцендентов.

В практических приложениях теории искусственного интеллекта для решения подобных задач формирования баз знаний применяются искусственные нейронные и иммунные сети [9, 10]. Это происходит в связи с накоплением достаточного для обучения нейронных сетей количества информации (главным образом, представленной в общедоступных информационных базах данных компьютерных сетей – например, [11]).

Решение проблемы разномодальности признакового пространства представляется возможным в аспектах:

1. Использование нечетких искусственных нейронных сетей, обрабатывающих лингвистические переменные, в состав которых входят разномодальные признаки.
2. Применение преобразовательных к единой метрике методов, алгоритмов и процедур.
3. Применение лингвистико-образных переменных при анализе изображений [12].
4. Применение бутстреп-подходов (контрбутстреп) алгоритмов искусственного увеличения (уменьшения) объема обучающей выборки [13, 14, 15].
5. Применение искусственных иммунных сетей [16].

Первое направление подразумевает формирование кортежа диагностических информативных признаков [17].

Второе направление основывается на методах и алгоритмах метрических преобразований шкал представления информации в признаках, не обладающих свойствами взаимнообратных однозначных преобразований, что существенно затрудняет верификацию процесса принятия решений в дальнейшем.

Третье направление, в случае отсутствия явного элемента изображения (на рентгеновском снимке, фотографии и т. п.), предполагает синтез процедур по формированию некоторого латентного искусственного образа. Первые научно-практические изыскания в этом направлении проводятся в настоящее время – [12].

Четвертое направление предполагает существование верхней границы объема обучающей выборки в условиях «статистического парадокса» [18]: необходимый объем определяется статистическими методами (т. е., отсутствует, по сути, внешний критерий) возникает конфликт понятий: «отсутствие доказательств» и «доказательство отсутствия».

Пятое направление, согласно изученным доступных в открытой печати информационным источникам, не находит применение в практической медицине (если не считать исследования представленного в [19]), хотя работы в области обработки мега-данных, анализа временных рядов, обнаружение аномалий, диагностики неисправностей и распознавании образов в технических областях [20], позволяют ожидать прорыв в данном направлении в ближайшее время. Затрудняет применение искусственных иммунных сетей и отсутствие универсальных программных продуктов.

В проводимых ранее исследованиях (например, [4, 10, 21, 22]) показано, что наиболее оптимальной и универсальной шкалой представления признаков является бинарная метрика, определяющая присутствие (отсутствие) определенного признака у объекта исследования.

Поскольку, в этом случае, существенно возрастает объем множества признаков, то требует своего разрешения *актуальная научно-техническая задача* синтеза антецедентов решающих продукционных правила в форме логических функций от многих переменных в условиях превышения количества таковых над объемами обучающей выборки.

В настоящее время существует несколько подходов (методов, программных инструментариев), реализующих синтез логических функций в области решения классификационных задач: карты Карно (Вейча), Квайна, Квайна-Мак-Класки, Петрика [23]. Для случая однозначной импликации между значениями признаками и диагностируемыми классами применяются различные модификации ДСМ метода.

Однако, если количество объектов в обучающей выборки соизмеримо и-или меньше размерности признакового пространства, применение указанных методов вызывает существенные затруднения, если не применяются бутстреп-технологии [14, 24]. То же самое касается и подходов, предлагаемых в работах [25], касающихся использования искусственных нейронных сетей, в том числе логических [22]. Следует отметить, что, теоретически, искусственные логические нейронные сети позволяют реализовывать ДСМ-метод, используемый во многих экспертных систем второго поколения, построенных на основе автоматического порождения гипотез о зависимостях причинно-следственного характера в базах данных с неполной информацией, – типичным случаем медицинских проектных решений.

Между тем, в работе [22] показано, что эффективность применения логических нейронных сетей в настоящее время не высока, и поэтому они не получили распространение в экспертных системах. В указанной работе приводится сравнение трех типов архитектур

логических нейронных сетей для решения задачи классификации на основе бинарных векторов, представляющее признаковое пространство и делается вывод о наилучших классификационных свойствах полного набора.

Аналогичная ситуация наблюдалась в 70-ые годы 20 века, когда решалась проблема быстрой и адекватной структурно-параметрической идентификации функциональных связей в структурах данных зависимостей и классификации объектов в условиях многомерности признакового пространства и малых статистических объемов зашумленных обучающих выборок. В результате был разработан метод группового учета аргументов (МГУА) [26, 27], реализованный в различных прикладных гуманитарных и технических областях. В настоящее время функционирует портал [28], на котором постоянно представляются и обсуждаются достижения в данной области. Особенно много научно-практических посвящено исследованиям преимуществ и недостатков МГУА в биологии, экологии и медицине. Применение МГУА в сочетании с искусственными нейронными сетями (в том числе, нечеткими) рассматривается, например, в работах [27, 28]. Однако, вопросы проектирования искусственных нейронных логических сетей с архитектурно-подобной МГУА структурой остаются малоизученными, и являются актуальными.

Таким образом, целью исследования являлась разработка архитектуры и правил функционирования искусственной логической нейронной сети на основе самоорганизационных концепций метода группового учета аргументов для синтеза antecedентов продукционных правил классификационного типа, в условиях малых объемов обучающей и экзаменационных выборок и большого количества признаков логического типа.

Представленные далее результаты являются продолжением более ранних исследований младшего научного сотрудника ООО «Хелп Медиком Групп» Добровольского И.И. выполненных в 2015-2018 годах, результаты которых в обобщенном виде представлены в [29].

Для реализации цели решались задачи: выбора архитектуры и элементов искусственной логической нейронной сети, разработка метода обучения сети, проведение экспериментальных пилотных исследований и формирование предложений по применению полученных результатов исследования.

### Теоретическая часть


Принципы и технологии МГУА и нечеткого логического вывода обуславливают применение логических нейронных элементов сети (искусственных нейронов) с ограниченным и небольшим количеством входов. В этом случае, решается проблема необходимости бесконечного накопления обучающей информации для повышения качества распознавания (значения внешнего критерия стремятся к минимуму по мере итерационного увеличения сложности модели). Кроме того, ограничение на количество входных аргументов одного нейрона приближено к естественному интеллекту, который «одновременно удерживает» в оперативной обработке ограниченное количество информации об объектах, процессах или семантических группах (включая альтернативные решения). В простейшем элементарной основой сети является искусственный логический нейрон с двумя входами и одним выходом. Назовем такой нейрон «бинарным». (Функционирование нейронов с большим количеством входов определяется несущественной модификацией математического аппарата, но вызывает степенным образом возрастающую мощность вычислительных ресурсов).

Предлагается в сети применять искусственные логические бинарные нейроны типа:

1.  $NL$  – реализует логическую функцию над переменными  $a$  и  $b$  имеющие идентификаторы  $c$  и  $d$ , соответственно;

2. *NLA* – первоначально преобразуются бинарные переменные в действительные (с учетом гистограммы распределения), затем настраивается типовой искусственный нейрон с тремя входами, и, выполняется к бинарной метрики (логическим значениями). (Согласно рекомендациям Барского А.Б. [24] – на этапе обучения сеть «должна работать не с булевыми переменными на входе, а с действительными числами, имеющих семантическую нагрузку достоверности, вероятности, принадлежности, экспертной оценке и т. д.)».

Структуры нейронов представлены на рисунке 1.



а) логический бинарный нейрон типа NL; б) логический бинарный нейрон типа NLA

**Рисунок 1.** Схемы бинарных логических нейронов (разработаны авторами)

На рисунке 1 применены условные обозначения:  $Fb(a,b)$  – логическая функция от двух переменных;  $Fa(y)$  – функция активации;  $y_{ac}$  – выходной сигнал  $Fa(y)$ ;  $Pout$  – модуль формирования выходной строки  $OUT$  по  $y_{ac}$  (для *NL* нейрона) или  $LC$  (для *NLA* нейрона),  $c$  и  $d$ ;  $LChC$  – логико-числовой преобразователь, осуществляющий однозначное преобразование логических переменных  $a$  и  $b$  в действительные числа  $X, Y$  и произведение  $X \cdot Y$ ;  $a_1, a_2, a_3$  – множители, на которые накладываются ограничения вида:  $|\alpha_1| \leq 1, |\alpha_2| \leq 1, |\alpha_3| \leq 1, |\alpha_1 + \alpha_2 + \alpha_3| \leq 1$ ,  $\Sigma$  – арифметический сумматор.

Строка  $OUT$  формируется в виде аналога польской инверсной записи для логических функций вида  $UT = "(c)(d)\varphi\rho\pi"$  ( $\varphi$  – идентификатор логической функции между  $a$  и  $b$ ,  $\rho$  и  $\pi$  – идентификаторы логических функций над переменными  $a$  и  $b$ , обозначаемыми символами «1» и «0», соответственно). Например, если  $Fb(a,b) = \bar{a} \vee b$  и в качестве  $a$  используется  $x2$ ,  $b$  –  $x25$ , то  $OUT = "(2)(25)\vee 01"$ .

В результате настройки (обучения) характеристики нейрона и формируется строковая переменная  $OUT$ , обеспечивающая его функционирование в структуре сети.

Базовая архитектура интерактивной логической нейронной сети представлена на рисунке 2.

Процесс настройки обучения ЛНС МГУА осуществляется по следующему алгоритму:

1. Формируется обучающее множество  $\{Xt\}$  в виде матрицы  $Xt(m, n+1)$ , состоящей из  $m$  строк – примеров объектов и  $n$  столбцов: элементы матрицы – логические значения признаков;  $n+1$  столбец – идентификатор класса  $\omega_l$ . Элементы матрицы (строки) упорядочиваются по значениям  $\omega_l$ . Определяется количество классов  $L$ . Задается начальное значение индекса класса  $l=1$ .

2. Для класса  $\omega_l$  формируется  $\{\{X\} = \{X\}_{tr} \cup \{X\}_{ex}\}^{\omega_l} : x_{i,j} = xt_{i,j}, x_{i,n+1} = true$  если  $xt_{i,n+1} = \omega_l$  и  $x_{i,n+1} = false$  если  $xt_{i,n+1} \neq \omega_l / (i=1, \dots, m; j=1, \dots, n)$ ;  $x_{tr,k,j} = x2_{k,j}, x_{ex,k,j} = x2_{k-1,j} / j=1, \dots, n+1, k=1, \dots, \lfloor \frac{n}{2} \rfloor$ . Массив  $NS = \emptyset$ . Текущий (обрабатываемый) номер ряда  $k$  принимает значение 1.

3. Задаются начальные условия обучения: тип базового элемента-нейрона ЛНС МГУА ( $NL$  или  $NLA$ ); значение величины свободы выбора  $Mg$ ; тип критерия селекции лучших структур  $Ks$ ; пороговое значение критерия селекции («останова» алгоритма обучения)  $Kendp$ ; бразов)  $L$ ; максимальное количество рядов нейронов  $KR$  (с целью предотвращения перенасыщения ЛНС).

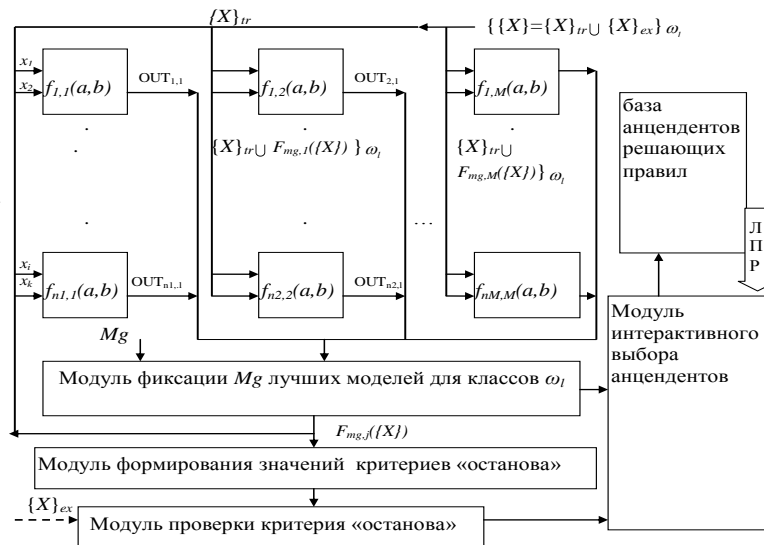


Рисунок 2. Базовая архитектура логической нейронной сети ЛНС МГУА (разработана авторами)

На схеме: ЛПР – лицо принимающее решение,  $\{X\} = \{X\}_{tr} \cup \{X\}_{ex} \omega_l$  – выборка значений признаков, разделенная методом Монте-Карло на две подвыборки  $\{X\}_{tr}$  – обучающая и  $\{X\}_{ex}$  – экзаменационная (значения признаков объекта  $z$  расположены в строках с индексом  $z$  матриц, в строчках с индексом «0» – идентификаторы признаков);  $f_{i,j}(a,b)$  –  $i$ -ый бинарный нейрон типа  $NL$  или  $NLA$  соответствующий  $j$ -му ряду сети, входами которого являются логические переменные  $a$  и  $b$ , выходом – строковая переменная  $OUT_{i,j}$ , вектор параметров  $\alpha_{i,j}$  (для  $NLA$  нейронов);  $Mg$  – величина, характеризующая свободу выбора (количество функций  $F_{mg,j}(X)$ ) ( $mg=1, \dots, Mg$ );  $F_{mg,j}(X)$  – логическая функция и ее аргументы из в строки  $OUT$ ;  $NS$  – массив, в котором фиксируются лучшие варианты параметров настроенной искусственной логической нейронной сети.

4.  $\{X\} = \{X\} / + / \{Z\}_{k-1}$ , где  $\{Z\}_{k-1}$  – множество значений  $Mg$  функций, выбранных на ряду  $k$  (здесь  $\{Z\}_0 = \emptyset$ , знаком «/+/» обозначена операция вставки множества  $\{Z\}_{k-1}$  между  $n$  и  $n+1$  столбцами множества  $\{X\}$ ). Если  $k > 1$ , то выполняются процедуры п.2 и изменяется значение  $n$ :  $n = n + Mg$ .

5. Для всех пар  $\{X\}_{tr}$  (кроме  $n+1$  столбца) осуществляется настройка (обучение) бинарного нейрона и импортирование значений  $OUT_{k,mg}$  ( $k$  – номер ряда,  $mg=1, \dots, Mg$ ) в «Модуль фиксации  $Mg$  лучших моделей для классов  $\omega_l$ ».

6. В «Модуле фиксации  $Mg$  лучших моделей для классов  $\omega_l$ » для каждого элемента  $OUT_{k,mg}$  вычисляются значения критериев селекции  $Ks_{k,mg}$ , по мере убывания которых осуществляется упорядочивание строковых переменных  $OUT_{k,mg}$ . Затем первые  $Mg$  строк  $OUT_k$  с наибольшими значениями  $Ks_{k,mg}$ :

- импортируются в массив  $NS$  таким образом, что:

$$NS_{Mg \cdot (k-1) + mg, 1} = 1, NS_{Mg \cdot (k-1) + mg, 2} = OUT_{k,mg}, NS_{Mg \cdot (k-1) + mg, 3} = Ks_{mg,k}, mg = 1, \dots, Mg;$$

- используются для формирования множества  $\{Z\}_k$ , вычисляя значения, указанные в соответствующей строке *OUT* логических функций над элементами  $\{X\}$ .

7. По данным массивов *NS* и  $\{X\}_{ex}$  определяется значение критерия «останова» *Kend*. Если  $(Kend < Kendp) \& (k < KR)$ , то, приняв  $k = k + 1$ , возвращаемся к п.4.

8. Из вариантов, сформированных итоговых логических функций (элементы массива *NS*, соответствующие последнему ряду), выбирается наилучший, в заданном пользователем режиме:

- режим 1: автоматический – с максимальным значением *Kend* (остальные – не рассматриваются и удаляются);
- режим 2: автоматический – формируются дополнительные элементы *NS*, с номерами в первом столбце и строковыми переменными во втором, представляющие собой последовательные дизъюнкции аргументов функций, представленных в *NS*;
- режим 3: интерактивный – исследователь-пользователь оставляет наиболее приемлемый для него, вариант на основе своего опыта и анализа информативности переменных, входящих в условие решающего правила.

9. Итоговый массив *NS* и соответствующее значение критерия *Kend* импортируются в «Базу итоговых логических функций» (массив *BDLF<sub>i</sub>*).

10. Если  $(l \geq L)$ , то процесс обучения искусственной логической нейронной сети заканчивается, иначе  $l = l + 1$  и переходим к п.2.

Включение в настройку ЛНС МГУА интерактивный режима позволяет объединять возможности естественного и искусственного интеллектов [9, 31] в процессе обучения. В процессе обучения сети предлагаются к применению следующие критерии:

- селекции *K<sub>s</sub>*, значения которых предлагается вычислять по одной из двух методик, определяемых на этапе начальной настройки ЛНС:
  - эффективности распознавания:

$$K_{sc} = \frac{kt}{kex}, \quad (1)$$

где *kex* – объем подвыборки  $\{X\}_{ex}$ , *kt* – количество правильно распознанных примеров-образов на  $\{X\}_{ex}$ .

- стабильности распознавания (по сути, аналог критерия регулярности [46,92]):

$$K_{sr} = \frac{kte + ktt}{ktr + kex}, \quad (2)$$

где *kte* – количество правильно распознанных примеров-образов в  $\{X\}_{tr}$  по функции, полученной на  $\{X\}_{ex}$ ; *ktt* – количество правильно распознанных примеров-образов в  $\{X\}_{ex}$  по функции, полученной на  $\{X\}_{tr}$ , *ktr* – объем  $\{X\}_{tr}$ .

Критерий *K<sub>sr</sub>* рекомендуется в случае небольших объемах обучающей и экзаменационной выборок.

Заметим, что итоговая логическая функция аппаратно или программно реализуется в виде дешифратора.



### Результаты экспериментальных исследований

В качестве апробации предлагаемого подхода была выбрана база знаний для СППР врача-хирурга, прогнозирующая риск летального исхода и уверенность в отсутствии такового (выздоровлении) при возможной тромбоэмболии в процессе операционного вмешательства – эндопротезирования крупных суставов. База данных включала в себя информацию историй болезни 410 пациентов Курской областной клинической больницы

Применяя ЛНС, синтезированы следующие antecedentes:

$$Fin(\{XO\})_{OutD} = [(x_{112} \wedge x_{126} \vee x_{128}) \vee x_{73}] \vee [x_{45} \wedge x_{47} \vee (x_{50} \vee x_{52} \vee x_{54} \vee x_{56} \vee x_{57} \vee x_{58} \vee x_{59} \vee x_{60} \vee x_{64} \vee x_{65} \vee x_{66} \vee x_{67} \vee x_{68} \vee x_{70} \vee x_{94}) \wedge x_9 \wedge x_{10} \wedge x_{36}] \wedge (x_{112} \vee x_{114} \vee x_{117} \vee x_{120}) \quad (3)$$

где antecedent  $Fin(\{XO\})_{OutD} = true$  соответствует высокой вероятности летального исхода  $OutD$ .

$$Fin(\{XO\})_{OutR} = \{x_{50} \wedge *x_{52} \vee +x_{53} \vee +x_{56} \vee +x_{60} \vee +x_{122}\} \vee + \frac{[x_{96} \vee x_{87} \vee x_3 \vee x_{12} \vee x_7 \vee x_{19} \vee x_{20} \vee x_{22} \vee x_{23} \vee x_{29} \vee x_{33} \vee x_{51} \vee x_{17} \vee x_{18} \vee x_{37} \vee x_{38} \vee x_{110} \vee x_{47}] \vee +}{\quad} \quad (4)$$

где antecedent  $Fin(\{XO\})_{OutR} = true$  соответствует высокой вероятности принадлежности состояния пациента кластеру  $OutR$  – «выздоровление».

В формулах  $X$  – это значения специализированных логических признаков, например:  $x_{43}$  – срок ТЭЛА (тромбоэмболия легочной артерии) >4 недель;  $x_{47}$  – клиника ТЭЛА – потеря сознания;  $x_{50}$  – анемия;  $x_{52}$  – ЭКГ-перфузия левого желудочка;  $x_{60}$  – локализация тромба – глубокие вены бедра;  $x_{64}$  – локализация тромба – вены таза;  $x_{110}$  – гиперкоагуляция;  $x_{112}$  – Д-Димер выше нормы;  $x_{126}$  – форма ТЭЛА – массивная;  $x_{128}$  – форма ТЭЛА – молниеносная.

Полученные результаты позволили сформировать решающие правила для базы знаний СППР для осуществления прогнозирования исходов тромбоэмболии при эндопротезировании.

В результате верификации (3) и (4) на клинически подтвержденном материале, получены следующие значения показателей качества, представленные в таблице 1.

Таблица 1

#### Диагностические показатели качества прогноза исходов тромбоэмболии при эндопротезировании

Группы сравнения		ДЧ	ДС	ДЭ	ПЗ <sup>+</sup>	ПЗ <sup>-</sup>	LR <sup>+</sup>	LR <sup>-</sup>
$OutD$	$OutR$	0,89	0,84	0,87	0,85	0,89	5,62	0,13

Составлена авторами

В таблице: ДЧ, ДС, ДЭ – диагностические чувствительность, специфичность; ПЗ<sup>+</sup>, ПЗ<sup>-</sup> – предсказательные значимости положительных и отрицательных результатов; LR<sup>+</sup>, LR<sup>-</sup> – отношения правдоподобия для положительного и отрицательного результатов.

Анализ показывает, что наблюдаются приемлемые для клиники значения показателей качества. Таким образом, полученные на основе предлагаемой искусственной ЛНС, antecedents вошли в состав решающих правил для СППР, позволив улучшить качество диагностического прогноза на 12-14 % по сравнению с существующими аналогами.

### Заключение

В процессе реализации цели исследования разработаны структура и режим обучения искусственной логической нейронной сети на основе бинарных нейронов и МГУА подобной

архитектуры, позволяющие синтезировать правила активации продукций для решающих правил на основе логических признаков. Проведенные испытания в реальных условиях подтвердили эффективность предлагаемого подхода к синтезу условий активации продукций с помощью самоорганизационной сети с применением бинарных логических нейронов.

Результаты проведенных исследований могут быть использованы при разработке автоматизированных интеллектуальных систем поддержки принятия решений для оперативного решения прогностико-классификационных задач и формирования адекватного решения о корректирующем или управляющем воздействии.

## ЛИТЕРАТУРА

1. Иванов В.В., Малинецкий Г.Г., Сиренко С.Н. Гуманитарно-технологическая революция и выбор будущего. Москва: ЛЕНАНЕД, 2018. 344 с.
2. Бабкин Э.А., Козырев О.Р., Куркин А.А., Визгунов А.Н. Информационные системы поддержки принятия решений. Нижний Новгород: национальный исследовательский университет «Высшая школа экономики». 2011. 269 с.
3. Перепелица Д.Г. Современные проблемы и тенденции развития автоматизированных систем поддержки принятия управленческих решений // Человеческий капитал. 2014. №4(64). С. 138-143.
4. Уздин Д.З. Новые меры близости, функции состояний и решающие правила в теории распознавания состояний (статистической классификации). Киев: Макс Пресс. 2016. 128 с.
5. Paul Goodwin and George Wright, Decision Analysis for Management Judgment, 3rd edition. Chichester: Wiley, 2004.
6. Башлыков А., Еремеев А. Основы конструирования интеллектуальных систем поддержки принятия решений в атомной энергетике. Москва: Инфра-М. 2017. 376 с.
7. Ефременко Д.В., Гиряева В.Н., Евсеева Я.В., «НБИЦ-конвергенция как проблема социально-гуманитарного знания» // Эпистемология и философия науки» 2012. № 4 (34). С. 112-129.
8. Пригожин И. и др. Синергетика. Антология. Москва: Центр гуманитарных инициатив. 2013. 408 с.
9. Осипов Г.С. Лекции по искусственному интеллекту. Москва: Книжный дом «ЛИБЕРКОМ». 2014. 272 с.
10. Cain G. (Ed.) Artificial Neural Networks: New Research Nova Science Pub Inc., NY, USA, 2017. 243 p.
11. Медицинские информационные базы данных // URL: <http://www.ctsguides.com>; [www.klasresearch.com](http://www.klasresearch.com); <http://www.softwareadvice.com/medical>.
12. Кобринский Б.А. и др. Интеллектуальные и информационные системы в медицине: мониторинг и поддержка принятия решений: сборник статей. Москва-Берлин: Директор-медиа. 2016. 529 с.
13. Artemenko M.V., Kalugina N.M., Dobrovolsky I.I. The formation of a set of informative features based on the functional relationships between the data structure field observations // European Journal of Natural History. 2016. №6. p. 43-48.
14. Artemenko M.V., Chernetskaia I.E., Kalugina N.M. and Shekina E.N. Bootstrap and counter-bootstrap approach for formation of the cortege of informative indicators by results of measurements // Journal of Physics: Conference series, Volume 998, Conference 1.
15. Шитиков В.К., Мاستицкий С.Э. Классификация, регрессия и другие алгоритмы ДАТА МИНИНГ с использованием Р. Тольяти: Институт экологии Волжского бассейна РАН. 2017. 351 с.

16. Чернышев Ю.О., Григорьев Г.В., Венцов Н.Н. Искусственные иммунные системы: обзор и современное состояние // Программные продукты и системы. 2014. № 14. стр. 136-142 DOI: 10.15827/0236-235X.108.136-142.
17. Артеменко М.В., Подвальный Е.С., Старцев Е.А., Метод комплексной оценки и выборка состава информативных признаков в задачах оценки состояния биотехнических систем // Биомедицинская радиоэлектроника. 2016. №9. С. 38-44.
18. Талев Н.С. Черный лебедь. Под знаком непредсказуемости. Москва: КоЛибри, Азбука-Аттику. 2017. 736 с.
19. Оболенский А.Н., Артеменко М.В., Корневский Н.А. Интегральное применение искусственных иммунных сетей и корреляционного анализа для выявления патологий в электрокардиосигнале // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2012. №2-3. С. 356-361.
20. Самигулина Г.А. Разработка интеллектуальных экспертных систем прогнозирования и управления на основе искусственных иммунных систем // Теоретическая информатика. 2009. Вып. 4. С. 15-22.
21. Фокин В.П., Дударев С.П. Сравнительный анализ архитектур логических нейронных сетей для классификации бинарных векторов // Успехи в химии и химической технологии. ТОМ XXX. 2016. № 4 (173) стр. 115-122.
22. Барский А.Б. Логические нейронные сети. Москва: Интернет-Университет Информационных Технологий. 2007. 352 с.
23. Сазонова Т.В., Христуло О.И., Богданов А.В. Обработка данных продукционных правил многомерного нечеткого регулятора с интервальной неопределенностью на основе последовательных уравнений и метода Квайна-Мак-Класки // Научно-технический вестник Поволжья. 2016. № 2. С. 163-166.
24. Шитиков В.К., Розенберг Г.С. Рандомизация и бутстреп: статистический анализ в биологии и экологии с использованием R. Тольятти: Кассандра, 2014. 314 с.
25. Li R.Y.M., Fong S., Chong R.W.S. Forecasting the reits and stock indices: group method of data handling neural network // Pacific Rim Property Research Journal. 2017. V. 23. № 2. p. 123-160.
26. Garg V. Inductive group method of data handling neural network approach to model basing sediment yield // Journal of Hydrologic Engineering – ASCE. 2015. V. 20. № 6. p. 60-140.
27. Ivakhnenko A.G., Savchenko E.A., Ivakhnenko G.A. GMDH algorithm for optimal model choice by the external error criterion with the extension of definition by model BIAS and ITS applications to committees and neural networks // Pattern Recognition and Image Analysis (Advances in Mathematical Theory and Applications). 2002. V. 12. № 4. p. 347-353.
28. GMDH [Electronic resource]. Model of access: <http://gmdh.net/>.
29. Добровольский И.И. Автоматизированная система прогнозирования и профилактики венозного тромбоза при эндопротезировании крупных суставов: диссертация ... кандидата технических: 05.11.17; [Место защиты: Орловский гос. ун-т им. И.С. Тургенева – Орел, 2018. – 191 с.
30. Bodyanskiy Y.V., Vynokurova E.A., Dolotov A.I. Self-learning cascade spring neural network for fuzzy clustering based on group method of data handling // Journal of Automation and Information Sciences. 2013. V. 45. № 3. p. 23-33.
31. Bostrom N., «Iskusstvennyj intellekt. Jetapy. Ugrozy. Strategii» «Mann, Ivanov i Ferber» 2016. 496 s.

**Artemenko Mihail Vladimirovich**

Southwest state university, Kursk, Russia  
E-mail: Artem1962@mail.ru

**Dobrovolsky Ilya Igorevich**

LLC «Help Medical Groups», Kursk, Russia  
E-mail: Ilya\_dobr@mail.ru

**Shhekina Elena Nikolaevna**

Southwest state university, Kursk, Russia  
E-mail: elenashchekina@mail.ru

**Poshibaylova Aleksandra Valer'yevna**

«Hospital 2», Belgorod, Russia  
Southwest state university, Kursk, Russia  
E-mail: poshibailova@yandex.ru

## **Synthesis of antecedent production rules for medical expert systems logical artificial neural networks**

**Abstract.** Now requirements to efficiency of the made decisions in the conditions of a large number of the factors characterizing the arising situations increase. It acquires special relevance in the conditions of digital reality of such areas as: sociology, medicine, ecology, etc. It causes relevance of development and productive operation of the automated systems of support of decision-making on the basis of the existing and developed innovative tools of artificial intelligence. The heterogeneity and a multimodality of structures of the data characterizing object of management cause effectiveness of application of a universal metrics. As that it is offered to use logical. Not always the analyzed processes allow to form quickly enough and accurately training selections of the required volume and quality. The existing achievements of the method of group method of data handling (GMDH) allow to resolve a contradiction between a large amount of informative signs and the small training selection when developing architecture of artificial logical neural network. Two types of neurons – "logical neuron" and "logiko-arithmetic neuron" are considered (structures, algorithms of training, the recommendation about application). The description of control of the offered artificial logical neural network in general is provided. Results of pilot studies in clinical medicine on estimates of risk of a lethal outcome from a thrombembolia at end oprosthes replacement are presented. The results of a research of opportunities of application of self-organizational artificial logical neural networks presented in this article in medical expert systems are executed throughout earlier researches of the junior researcher of LLC Help Medikom Group Dobrovolsky I.I. (2015-2018).

**Keywords:** the medical expert systems solving productional rules; an antecedent; artificial logical neural networks; a group method of data handling; forecasting of a thrombembolia