

Math-Net.Ru

All Russian mathematical portal

V. I. Glova, K. V. Anikin, A. S. Katasev,
M. A. Podol'skaya, Формирование базы знаний ме-
дицинской диагностической экспертной системы
на основе нечеткой нейронной сети,
Issled. Inform., 2007, Issue 12, 31–46

<https://www.mathnet.ru/eng/ipi183>


Use of the all-Russian mathematical portal Math-Net.Ru implies that
you have read and agreed to these terms of use

<https://www.mathnet.ru/eng/agreement>

Download details:

IP: 18.97.14.88

May 20, 2025, 15:28:06



ФОРМИРОВАНИЕ БАЗЫ ЗНАНИЙ МЕДИЦИНСКОЙ ДИАГНОСТИЧЕСКОЙ ЭКСПЕРТНОЙ СИСТЕМЫ НА ОСНОВЕ НЕЧЁТКОЙ НЕЙРОННОЙ СЕТИ

В. И. Глова, И. В. Аникин, А. С. Катасёв, М. А. Подольская

Введение

Глобальная информатизация стимулировала разработку в различных областях человеческой деятельности автоматизированных диагностических систем. Это, как правило, интеллектуальные системы, моделирующие процесс рассуждения эксперта при принятии им решения – экспертные системы (ЭС). Основным элементом ЭС является база знаний, представленная множеством правил, описывающих закономерности предметной области. Данные правила формулируются экспертом или формируются на основе интеллектуального анализа данных, включающих представительные примеры решения конкретной задачи при различных условиях.

В первом случае эксперт формализует свои знания, опыт и интуицию в рамках выбранной модели представления знаний. Это сложный процесс, требующий большой аналитической работы.

Второе направление связано с разработкой и применением новых математических методов, способных эффективно анализировать статистические данные и извлекать из них полезные знания при меньшем объеме работы эксперта. Использование данного подхода перспективно для формирования баз знаний экспертных систем в таких областях как медицина, промышленность, нефтяная отрасль и др.

Для всех из них характерны следующие особенности:

- увеличение объемов обрабатываемой информации;
- необходимость обработки разнотипной информации;
- её нечёткость, качественность и субъективный характер;
- отсутствие формальных подходов к решению задач;
- необходимость решать творческие задачи;
- многокритериальность задач в условиях нечёткости критериев.

Актуально создание интеллектуальных систем обработки информации, способных эффективно решать поставленные задачи в указанных условиях. Для этого предлагается использовать специально разработанную нечёткую нейронную сеть.

Цель работы: на примере медицинской предметной области показать возможность и эффективность использования предложенной модели для формирования баз знаний экспертных систем.

Обнаружение знаний в базах данных

Процессы формирования знаний связаны с вопросами интерпретации баз данных с целью извлечения скрытых в них закономерностей. Для этого применяется набор технологий *Knowledge Discovery in Databases* (KDD) – обнаружение знаний в базах данных [1]. Для этого требуется выполнить ряд последовательных этапов [5, 6]. На рисунке 1 представлена типовая схема процесса KDD.

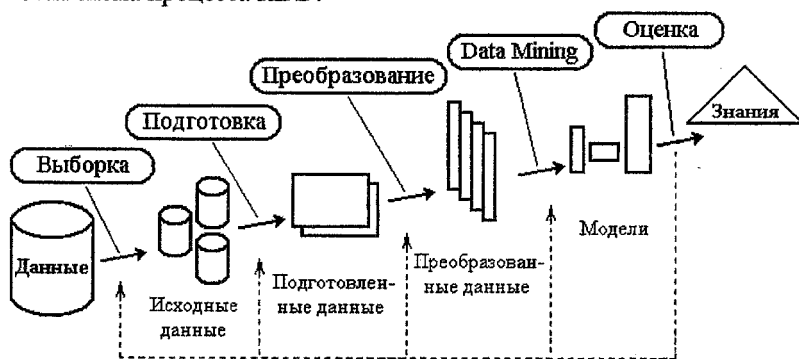


Рис. 1. Типовая схема процесса KDD

Выборка исходного набора данных. Данный этап основан на понимании и формулировке задачи анализа и заключается в создании наборов данных (обучающих выборок), на основании которых строится решение задачи.

Подготовка (предобработка) данных. Исходные данные могут содержать пропуски, шумы, аномальные значения, обладать избыточностью, недостаточностью и т.д. Кроме того, размерность исходного пространства может быть очень большой, и тогда желательно применение алгоритмов понижения размерности – отбор значимых (доминантных) признаков, отображение данных в пространство меньшей размерности и т.д.

Преобразование (трансформация) данных. Этот этап необходим для методов, требующих представления подготовленных данных в определённой форме. Преобразование данных осуществляется путём их сглаживания, агрегирования, обобщения, нормализации. В результате данные должны иметь как можно меньше атрибутов различного типа.

Data Mining – интеллектуальный анализ данных с помощью различных инструментальных средств. Это могут быть статистические пакеты, нейронные сети, эволюционные методы, а также гибридные модели, соче-

тающие в себе достоинства различных технологий. В данной работе используется гибридная модель – нечёткая нейронная сеть, сочетающая достоинства нейронных сетей и нечёткой логики.

Оценка (постобработка) данных – проверка построенных моделей и интерпретация полученных результатов. Для этого часто используют тестовую выборку данных. По разнице в точности между тестовой и обучающей выборками можно судить об адекватности построенной модели.

Рассмотренным этапом завершается цикл обнаружения знаний в базах данных. Окончательная оценка ценности добытого нового знания выходит за рамки анализа и может быть проведена только после претворения в жизнь решения, принятого на основе добытого знания, после проверки его на практике.

Как видно, в технологии Knowledge Discovery in Databases особое место занимает этап подготовки данных, от которого в наибольшей степени зависит успех обнаружения новых знаний. Это неизбежно в медицинской предметной области, где исходная выборка данных часто содержит случайные «выбросы», нетипичные и пропущенные значения, возможные ошибки ввода и т.п.

Подготовка обучающей выборки

Приведение данных к форме, пригодной для анализа с помощью нечёткой нейронной сети, является обязательным условием эффективности данного процесса.

Первым шагом является определение типов данных для выбора входных и выходных параметров нейронечёткой модели.

Медицинские данные характеризуются различной природой и изменены в различных количественных и качественных шкалах (рис. 2).

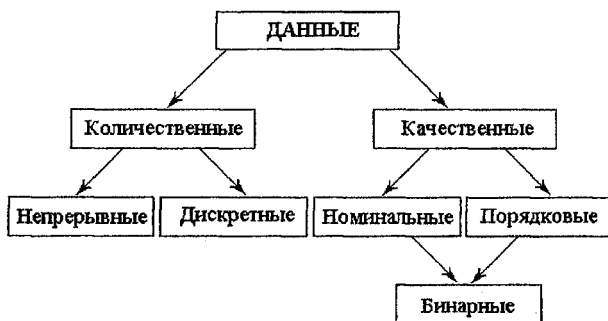


Рис. 2. Основные типы медицинских данных

Количественные данные получаются в результате измерения, как в непрерывных, так и в дискретных шкалах. Примерами непрерывных при-

знаков могут служить масса тела, рост, артериальное давление. Дискретными являются количество симптомов, возраст, стаж работы.

Качественные характеристики, как правило, закодированы и могут быть как совершенно самостоятельными и независимыми друг от друга (номинальные признаки), так и составлять последовательность, условно выражаемую количественно (порядковые признаки). Примером номинальных качественных признаков являются состояние мышц позвоночника, фасций, наличие деформаций. Порядковыми являются, например, тяжесть течения заболевания, качество компенсации, выраженность болевого синдрома, степень сложности методов лечения.

Особым видом качественных признаков являются бинарные, принимающие одно из двух возможных значений. Например, пол, наличие или отсутствие какого-либо заболевания.

После определения типов данных выделяются признаки, наиболее важные в контексте исследования, наиболее вероятно входящие в искомую зависимость. Для этого, как правило, используются статистические методы, основанные на применении корреляционного анализа [2], позволяющего быстро, хотя и приближённо, оценить влияние одного параметра на другой.

При использовании таких методов вычисляется коэффициент корреляции r , показывающий, в какой степени изменение значения одного признака сопровождается изменением другого в выборке данных. Значение коэффициента корреляции изменяется в диапазоне от -1 до 1 . При этом условно можно принять следующую классификацию силы корреляционной зависимости [11]:

$|r| \leq 0,25$ – слабая корреляция;

$0,25 < |r| < 0,75$ – умеренная корреляция;

$|r| \geq 0,75$ – сильная корреляция.

Выявление корреляции двух признаков ещё не означает присутствия причинно-следственной связи между ними. Корреляционный анализ устанавливает лишь наличие и силу статистической связи, и не говорит о её направлении. Однако уже само наличие связи даёт основание использовать более совершенные методы поиска знаний и закономерностей в изучаемых данных.

После выбора описывающих (доминантных) признаков изучаемые данные могут быть представлены в виде прямоугольной таблицы, где каждая строка представляет собой отдельный случай, объект или состояние изучаемого объекта, а каждый столбец – параметры, свойства или признаки всех исследуемых объектов.

Полученная таблица пока является слишком сырым материалом для применения методов интеллектуального анализа, поэтому данные, входящие в неё, необходимо предварительно обработать.

Любая реальная база данных обычно содержит ошибки, очень неточно определённые значения, соответствующие каким-то редким, исключительным ситуациям, и другие дефекты, которые могут резко понизить эффективность работы нечёткой нейронной сети. Такие записи необходимо отбросить, поскольку даже если подобные «выбросы» не являются ошибками, а представляют собой редкие исключительные ситуации, они всё равно вряд ли могут быть использованы, поскольку по нескольким точкам статистически значимо невозможно судить об искомой зависимости в данных.

После предварительной обработки данных можно приступить к подготовке обучающих выборок для нечёткой нейронной сети. Дальнейшая работа сводится к выбору исследователем групп входных и выходных параметров, обучение нечёткой нейронной сети, формирование правил принятия решений, их экспертная оценка.

Таким образом, можно выделить следующие этапы подготовки обучающих выборок для нечёткой нейронной сети (см. рис. 3).




Рис. 3. Этапы подготовки обучающих выборок

Дальнейшее использование нечёткой нейронной сети предполагает формирование правил принятия решений из данных в рамках нечётко-продукционной модели представления знаний.

Нечётко-продукционная модель представления знаний и структура нечёткой нейронной сети

Для описания и формализации зависимостей между значениями входных параметров (условиями) и назначаемым результатом (диагнозом)

используется нечётко-продукционная модель представления знаний, в которой правила R_j представлены в следующем виде [4]:

$$\begin{aligned} &\text{«ЕСЛИ } P_1^j \text{ есть } \tilde{A}_1^j (w_1^j) \text{ И } P_2^j \text{ есть } \tilde{A}_2^j (w_2^j) \text{ И ... И } P_n^j \text{ есть } \tilde{A}_n^j (w_n^j) \\ &\text{ТО Возможно получение результата } T_j \text{»} [CF^j] \end{aligned} \quad (1)$$

где $P^j = \{P_i^j\}$ – множество параметров, на которые накладываются ограничения в условиях правила R_j ;

$\tilde{A}^j = \{\tilde{A}_i^j\}$ – множество нечётких ограничений на параметры множества P^j – нечётких условий антецедента правила R_j ;

$w^j = \{w_i^j\}$ – веса нечётких ограничений \tilde{A}^j на параметры P^j , определяющие важность данных ограничений в правиле R_j ;

CF^j – степень достоверности сформированного правила R_j – уверенность эксперта в его универсальности (*CERTAINTY FACTOR*);

$T_j \in T$ – получаемый результат.

Для формирования правил в виде модели (1) разработана нечёткая нейронная сеть. Её задача – не просто сформировать систему правил, описывающих закономерности в данных, но и подобрать параметры функций принадлежности в правилах, аппроксимирующих нечёткие градации входных лингвистических переменных.

Структура нейронной сети определяется количеством входных, выходных параметров из обучающей выборки, числом градаций входов, а также алгоритмом логического вывода на модели (1). Первые три параметра задают количество нейронов в каждом слое нейронной сети, последний определяет число слоёв и их функциональность [7].

Рассмотрим нечёткую нейронную сеть, имеющую три выхода и два входа с тремя нечёткими градациями (см. рис. 4).

Здесь в нулевом слое содержится два P -нейрона, выполняющих функцию распределения входных сигналов по нейронам первого слоя.

В первом слое содержатся A -нейроны, количество которых $2 \cdot 3 = 6$. Данные нейроны моделируют нечёткие градации и образуют компоненты условных частей нечётких правил в виде « P есть \tilde{A}_i ».

Второй слой содержит $3^2 = 9$ $И$ -нейронов, каждый из которых определяет нечётко-продукционное правило в виде:

$$\text{«ЕСЛИ } P_1 \text{ есть } \tilde{A}_1 \text{ И } P_2 \text{ есть } \tilde{A}_2 \text{ ТО } T_j \text{»}.$$

Третий слой нейронной сети состоит из девяти *Сотр*-нейронов, на выходе которых рассчитываются комплексные оценки срабатывания сформированных правил. Каждый *Сотр*-нейрон напрямую связан со всеми выходами нейронной сети T_j . Величина связи определяет степень достоверности CF^j сформированного правила. Произведения выходов *Сотр*-

нейронов на их веса связи образуют общий коэффициент достоверности решения.

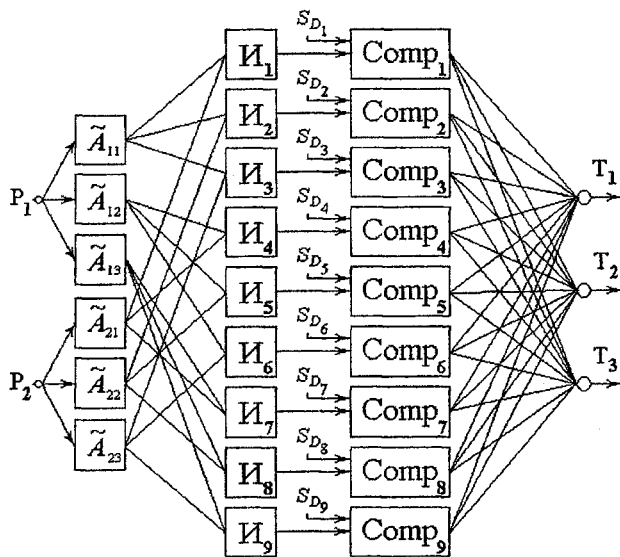


Рис. 4. Пример структуры нечёткой нейронной сети

В четвёртом слое содержатся три T -нейрона, на выходе которых вычисляются взвешенные нормированные оценки общего коэффициента достоверности решения.

Полная система правил, определяемая данной архитектурой нейронной сети, содержит $9 \cdot 3 = 27$ правил со своими коэффициентами достоверности и весами важности ограничений условных частей.

Для решения задачи аппроксимации функциональных зависимостей в данных нечёткими правилами продукции разработан программный комплекс «Нечёткая нейронная сеть» (*Fuzzy Neural Network*), реализованный в среде программирования Borland Delphi 6.0.

Достоинством системы является возможность описания зависимостей типа «количественный вход – бинарный выход» в виде нечётко-продукционных правил, что позволяет использовать её в медицинской предметной области, в которой изменения значений количественных параметров приводят к определённому результату. Использование программного комплекса определяется режимами его работы.

Работа нейронной сети в режиме обучения

Режим обучения нейронной сети предназначен для настройки параметров функций принадлежности, моделирующих нечёткие градации в правилах, с целью минимизации ошибки выхода сети.

Пусть для формализации нечётких градаций выбрана гауссова функция принадлежности. Тогда для параметрической адаптации модели к предъявляемым данным необходимо подстраивать два параметра функций принадлежности: c – центр, σ – крутизну.

Адаптация модели осуществляется в рамках алгоритма обучения нечёткой нейронной сети. Для этого минимизируется квадратичная сумма разностей между требуемыми t_i и полученными $U(t_i, Y)$ значениями выхода нейронной сети, усреднённая на N примерах:

$$F(Y) = \frac{1}{N} \sum_{i=1}^N (U(t_i, Y) - t_i)^2 \Rightarrow \min,$$

где Y – вектор параметров функций принадлежности. Вид функции $F(Y)$ целиком зависит от данных из обучающей выборки.

На рисунке 5 представлен пример процесса обучения ННС.




Рис. 5. Пример процесса обучения нейронной сети

Видно, что значение функции ошибки $F(Y)$ с течением времени стремится к своему минимуму. После обучения нечёткая нейронная сеть готова к генерации нечётких правил и представления их в удобном для пользователя виде.

Режим генерации и отбора значимых правил

Выше рассматривался пример ННС, в которой полную систему для каждого выхода составляли девять продукционных правил. В случае большего количества входов нейронной сети и их градаций мощность системы резко возрастает. Так, например, при четырёх входах сети с пятью нечёткими градациями будет сформировано $5^4 = 625$ правил. Такое количество требует их фильтрации и привлечения экспертов для оценки получаемых закономерностей.

Имеются следующие этапы выбора значимых правил:

- автоматическое исключение правил, не имеющих ни одного примера в обучающей выборке;
- выбор критериев отображения правил в ННС;
- экспертный отбор наиболее значимых из оставшихся правил.

На рисунке 6 показан один из этапов выбора значимых правил.

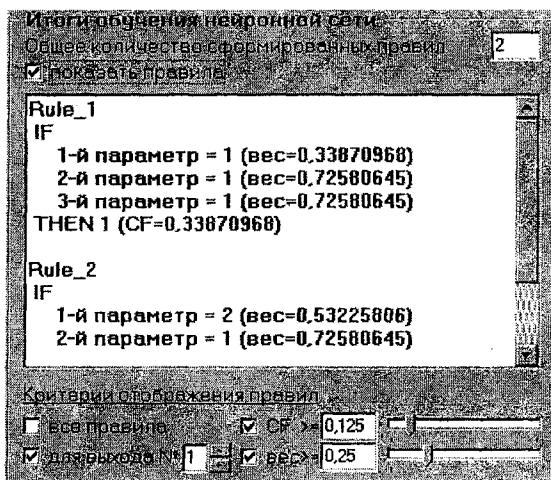


Рис. 6. Пример использования критериев отображения правил

Здесь в окне просмотра остались только два наиболее значимых правила, отвечающие установленным критериям отображения: веса условных частей правил не должны быть меньше 0,25, а достоверность каждого из них – не меньше 0,125.

Тестирование сети на контрольной выборке данных

Для оценки качества полученной модели необходимо протестировать обученную нейронную сеть на контрольной выборке данных. По разнице

в точности между тестовой и обучающей выборками можно судить об адекватности построенной модели.

Точность при тестировании определяется по формуле:

$$\varepsilon = \left(1 - \frac{|\Delta E|}{E_{обуч}} \right) * 100\% = \left(1 - \frac{|E_{обуч} - E_{тест}|}{E_{обуч}} \right) * 100\%,$$

где $E_{обуч}$ – ошибка выхода нейронной сети при обучении;

$E_{тест}$ – ошибка выхода нейронной сети при тестировании.

На рисунке 7 показан пример оценки качества обучения ННС, где точность $\varepsilon = 94,939\%$, что является приемлемым с точки зрения установленного критерия адекватности модели (80%).

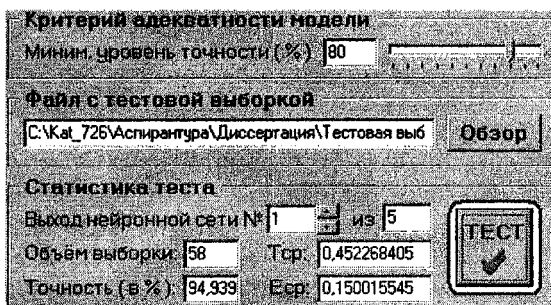


Рис. 7. Пример тестирования полученной модели

Обученная нейронная сеть является полноценной системой нечёткого логического вывода, с помощью которой, например, можно решать задачу классификации входных образов, т.е. отнесения их к некоторому классу, определяемому номером выходного нейрона с максимальным значением выхода.

Функционирование нечёткой нейронной сети

Рассмотрим процессы функционирования нечёткой нейронной сети на примере анализа медицинских данных. Одно из наиболее важных и значимых условий корректной диагностики состоит в выявлении факторов влияния возрастных характеристик пациента на риск возникновения у него тех или иных признаков заболевания. Для этого необходимо подготовить обучающую выборку и при помощи нечёткой нейронной сети сформировать систему правил, описывающих совокупное влияние входных параметров модели на её выходы.

Входами нейронной сети определим следующие параметры:

- 1 – возраст пациента на момент обследования (в годах);
- 2 – стаж заболевания (в годах);

3 – стаж динамических физических нагрузок (в годах);

Выходы нейронной сети:

1 – наличие грыжи межпозвонкового диска;

2 – наличие грыж Шморля;

3 – наличие гипертрофии жёлтой связки на изучаемом уровне;

4 – наличие протрузии межпозвонкового диска;

5 – наличие вакуум-феномена межпозвонкового диска.

Результаты корреляционного анализа показали возможность поиска значимых зависимостей в данной группе признаков (см. табл. 1).

Таблица 1. Коэффициенты взаимной корреляции параметров времени течения и выраженности дистрофического процесса поясничных межпозвонковых дисков обучающей выборки нечёткой нейронной сети.

входные параметры \ выходные параметры		выходные параметры				
		1	2	3	4	5
1	БЖ	0,01	0,34	0,41	0,58	0,43
	БМ	-0,15	-0,28	0,52	0,49	0,45
2	БЖ	0,05	0,06	0,42	0,55	0,46
	БМ	-0,04	-0,04	0,49	0,32	0,58
3	БЖ	0,41	0,09	0,53	0,62	0,44
	БМ	0,53	-0,1	0,45	0,54	0,52

Здесь БЖ – большие женщины, БМ – большие мужчины. Выделены статистически значимые показатели.

Фрагмент файла с данной обучающей выборкой представлен на рисунке 8, где первые три столбца содержат значения входных количественных параметров, последние пять – значения бинарных выходов.

49	7	8	1	0	1	0	0
49	7	8	0	0	1	0	0
49	8	10	0	0	0	1	0
49	8	10	0	0	0	1	0
49	8	10	0	0	0	0	0
50	15	20	0	1	1	0	1
50	15	20	0	0	1	1	1
50	15	20	0	0	1	1	1
50	15	20	0	0	0	0	1
50	15	20	0	0	0	0	1
50	5	30	0	1	1	1	0
50	5	30	0	0	1	1	0
50	5	30	0	0	1	0	0
50	5	30	0	0	0	0	0
51	2	15	0	0	0	1	0
51	2	15	0	0	0	0	0
51	2	15	0	0	0	0	0
51	0,5	35	0	1	0	1	0

Рис. 8. Фрагмент обучающей выборки

После подготовки обучающей выборки, определения структуры нейронной сети, задания параметров обучения и критериев его остановки создаётся готовая к обучению нечёткая нейронная сеть. Итогом её обучения является система достоверных правил следующего вида:

- ЕСЛИ «Возраст пациента» = «средний» ($w=0,51$)
 «Стаж заболевания» = «малый» ($w=0,73$)
 «Стаж динамических физич. нагрузок» = «малый» ($w=0,75$)
 ТО «Возможно наличие грыжи диска» ($CF=0,25$)
- ЕСЛИ «Возраст пациента» = «молодой» ($w=0,46$)
 «Стаж заболевания» = «малый» ($w=0,6$)
 «Стаж динамических физич. нагрузок» = «малый» ($w=0,69$)
 ТО «Возможно наличие грыж Шморля» ($CF=0,4$)
- ЕСЛИ «Возраст пациента» = «средний» ($w=0,48$)
 «Стаж заболевания» = «большой» ($w=0,45$)
 «Стаж динамических физич. нагрузок» = «большой» ($w=0,52$)
 ТО «Возможно наличие гипертрофии жёлтой связки» ($CF=0,47$)
- ЕСЛИ «Возраст пациента» = «средний» ($w=0,47$)
 «Стаж заболевания» = «большой» ($w=0,59$)
 «Стаж динамических физич. нагрузок» = «большой» ($w=0,61$)
 ТО «Возможно наличие протрузии межпозвонк. диска» ($CF=0,63$)
- ЕСЛИ «Возраст пациента» = «пожилой» ($w=0,71$)
 «Стаж заболевания» = «средний» ($w=0,48$)
 «Стаж динамических физич. нагрузок» = «средний» ($w=0,43$)
 ТО «Возможно наличие вакуум-феномена» ($CF=0,18$)

В данном случае входные параметры могли принимать три нечётких градации, соответствующие лингвистическим категориям типа «малый», «средний», «большой». Причём каждая нечёткая градация моделировалась треугольными функциями принадлежности, которые после обучения нейронной сети приняли вид, как показано на рис. 9.




Рис. 9. Пример формирования функций принадлежности

Здесь по оси абсцисс указан возраст пациента на момент обследования, ось ординат определяет степень принадлежности значений возраста к нечётким понятиям возрастной группы «молодой» (MF1), «средний» (MF2) и «пожилой» (MF3).

Рассмотренный пример использования нечёткой нейронной сети показал принципиальную возможность применения её для формирования системы правил из экспериментальных данных и построения базы знаний экспертной диагностической системы в медицине.

Построение базы знаний системы медицинской диагностики

Для построения базы знаний системы медицинской диагностики требуется алгоритм последовательных этапов анализа текущего во времени физиологического или патологического процесса. Это обусловлено потребностью в выработке системы правил, описывающих закономерности в медицинских данных на коротких отрезках течения патологического процесса. Лишь имея такое множество правил, можно принять правильное решение при различных вариантах течения одного и того же заболевания, например, длительного и осложнённого какими-то причинами, или, напротив, лёгкого и благополучного течения заболевания, при различных сроках и качествах его течения в половых, возрастных, профессиональных и прочих группах.

Следует иметь в виду, что как слишком глобальное усреднение процесса жизнедеятельности человека, так и расчленение его на бесконечное количество правил приводит к ошибке диагностики. В первом случае не подлежат анализу все тонкости течения патологического процесса, анализируются его начало и исход. Во втором случае вычисление вариантов взаимодействий множества функциональных систем даёт бесчисленное и этим предполагающее ошибку количество вариантов.

В процессе создания базы знаний диагностической системы в медицине важно определить и стандартизировать основные этапы сбора и анализа информации для обработки её с помощью нечёткой нейронной сети и выработки важных для врача правил.

Каждый из этапов является изолированным логическим процессом с измерением параметров, их анализом, принятием этапного решения. Такой анализ может быть проведён экспертом-медиком самостоятельно или при помощи ННС.

Прототипом интеллектуального анализа данных с применением нечёткой нейронной сети в медицине является алгоритм диагностического процесса, включающий следующие этапы:

- накопление в памяти верифицированных (достоверно подтверждённых) признаков, присущих конкретной патологии;
- сортировка их по различным признакам;
- вычисление и запоминание вероятностей следования одних событий за другими, происходящее бессознательно при большом количестве повторений подобных ситуаций;

- поиск у пациента характерных для конкретной патологии признаков или групп признаков;
- дифференциальное сравнение их с похожими признаками другой патологии;
- выбор одномоментного или текущего решения – постановка диагноза сразу или в результате наблюдения за пациентом;
- разработка тактики обследования и лечения пациента с построением опережающего прогноза результата лечения;
- наблюдение за развитием процесса в результате лечения;
- сравнение полученных и прогнозируемых результатов;
- коррекция диагноза и методов лечения при несовпадении результата и прогноза;
- прогноз близких и отдалённых результатов течения заболевания и результатов лечения.

Для проверки возможности применения нечёткой нейронной сети на всех этапах процесса медицинской диагностики использованы данные клинического, нейро-ортопедического, рентгенокомпьютерного томографического обследования 230 женщин в возрасте от 15 до 92 лет и 180 мужчин в возрасте от 16 до 81 года с различными синдромами поясничного остеохондроза (ПОХ) на стационарном этапе обострения и в стадии начинающейся ремиссии. Контрольную группу составили 20 женщин в возрасте от 20 до 70 лет и 20 мужчин в возрасте от 17 до 73 лет, никогда не страдавших поясничными вертеброгенными болями.

Клиническое нейроортопедическое обследование проведено по методике В.П. Веселовского, Я.Ю. Попелянского [3, 10]. Рентгеновская компьютерная томография проводилась на рентгеновском компьютерном томографе SOMATOM AR.NP spiral фирмы SIEMENS при сканировании с шагом 3/3 мм. Изучены количественные и качественные характеристики состояния структур позвоночно-двигательных сегментов, собственных мышц позвоночника и паравертебральных мышц на уровне LIII- SI по методике М.А. Подольской, З.Ш. Нуриева [8, 9].

Для получения системы нечётко-продукционных правил и их параметров измерено более 500000 количественных и качественных значений признаков течения поясничного остеохондроза по 822 параметрам. При помощи ННС проанализированы возможные варианты зависимости различных качественных и количественных признаков:

- влияние возраста, стажа заболевания, стажа физических нагрузок, возраста начала заболевания, времени развития и продолжительности обострения на степень дистрофического процесса в костных, хрящевых и мышечных структурах позвоночника;
- влияние степени дистрофического процесса в костных, хрящевых и мышечных структурах позвоночника на качество течения обострения по-

ясничных болей при остеохондрозе, качество компенсаторных процессов, длительность и полноту ремиссии;

- зависимость между морфологическими, антропологическими, дистрофическими процессами в позвоночнике, его мышцах и дисках и особенностями клинических синдромов ПОХ;

- зависимость особенностей клинических проявлений поясничного остеохондроза, механизмов развития обострения и компенсации от возраста и пола пациентов.

Подготовка обучающих выборок для ННС проведена в соответствии с описанной методикой. При этом учтено оптимальное количество входных и выходных параметров системы для численной и лингвистической интерпретации формируемых правил.

В результате обучения нейронной сети на более чем 100 обучающих выборках было получено более 500 правил, значимость которых подтверждена экспертами-вертеброневрологами высокой квалификации.

Выводы

Разработанная нечёткая нейронная сеть отвечает логике постановки диагноза экспертом и моделирует этапы его интеллектуальной деятельности, что приближает её к процессу постановки диагноза врачом-экспертом.

Данная модель является универсальной для решения прикладных медицинских задач. В отличие от экспертных систем, вырабатывающих рекомендации на основании имеющихся правил, нечёткая нейронная сеть получает правила принятия решений, формирующие базу знаний. Проверка сети на обучающих выборках из массивов медицинских данных позволила с большой точностью автоматизировать, а во многих случаях улучшить за счёт просчитывания скрытых закономерностей процесс диагностики в медицине.

Данные вертеброневрологического анализа послужили лишь многофакторной моделью, способной описать закономерности возникновения, развития, клинических особенностей заболевания, долгосрочного прогноза состояния пациентов. При соблюдении разработанных правил отбора информации, её стандартизации созданная модель может служить универсальным инструментом, способным в короткие сроки решать сложные экспертные задачи в медицине.

В большинстве случаев получаемые при помощи нечёткой нейронной сети правила совпадали с мнениями экспертов, что позволяет в дальнейшем использовать ННС самостоятельно. Подтверждена эффективность ННС в диагностическом процессе клинических проявлений остео-

хондроза позвоночника, возможность её использования в составе экспертных диагностических систем в медицине.

Заключение

Проведённое исследование показало актуальность использования искусственного интеллекта в вертеброневрологии. Применение нечётких нейронных сетей позволяет проводить многомерный анализ патологического процесса, находить его скрытые закономерности. Нечёткая нейронная сеть – универсальный математический аппарат для многофакторного анализа медицинских данных – инструмент для формирования баз знаний экспертных систем в данной предметной области.

Литература

1. Frawley M.J., Piatetsky-Shapiro G., Matheus C.J. Knowledge discovery in databases: An overview. *AI Magazine*, 1992. – P. 1-27.
2. Айвазян С.А., Енюков И.С., Мешалкин Л.Д. Прикладная статистика: Исследование зависимостей. – М.: Финансы и статистика, 1985.
3. Веселовский В.П. Практическая вертеброневрология и мануальная терапия. – Рига, 1991.
4. Глова В.И., Аникин И.В., Шагиахметов М.Р. Методы многокритериального принятия решений в условиях неопределённости в задачах нефтедобычи. Препринт 04П2. – Казань: / Изд-во Казан. гос. техн. ун-та, 2004.
5. Городецкий В.И., Самойлов В.В., Малов А.О. Современное состояние технологии извлечения знаний из баз и хранилищ данных (часть 1) // Новости искусственного интеллекта. – 2002. – № 3. – С. 3-12.
6. Городецкий В.И., Самойлов В.В., Малов А.О. Современное состояние технологии извлечения знаний из баз и хранилищ данных (часть 2) // Новости искусственного интеллекта. – 2002. – № 4. – С. 3-9.
7. Катасёв А.С. Нейронечёткая модель и программный комплекс формирования баз знаний экспертных систем: Дисс. на соиск. уч. степ. к-та техн. наук. – Казань, 2006.
8. Подольская М.А., Нурiev З.Ш. Компьютерно-томографическое исследование паравертебральных мышц на поясничном уровне при дистрофических вертеброгенных заболеваниях // Медицинская визуализация. – 2004. – № 4. – С. 127-136.
9. Подольская М.А., Нурiev З.Ш. Универсальная методика исследования собственных мышц позвоночника и паравертебральных мышц на поясничном уровне при дистрофических вертеброгенных заболеваниях методом рентгеновской компьютерной томографии. – Казань: КГМА. – 2003.
10. Попелянский Я.Ю. Вертебральные синдромы поясничного остеохондроза. – Казань: Издательство Казанского университета, 1974.
11. Реброва О.Ю. Статистический анализ медицинских данных. Применение пакета прикладных программ STATISTICA. – М.: МедиаСфера, 2003.