

## ИСПОЛЬЗОВАНИЕ НЕЙРОСЕТЕВЫХ МОДЕЛЕЙ ПРИ ДИАГНОСТИКЕ СИНДРОМА ЖИРОВОЙ ЭМБОЛИИ

Адамов В.Г., Гарипов И.И.

Донецкий национальный технический университет, г. Донецк  
кафедра автоматизированных систем управления

E-mail: mig1683@mail.ru

### Abstract

*Adamov V.G., Garipov I.I. Modeling neural networks at diagnostics of fatty embolism syndrome. In this article the questions of modeling neural networks are considered. Analysis of parameters for diagnostics of fatty embolism was performed. Optimum parameters of neural network are described. Neural network was tested with unknown data.*

**Общая постановка проблемы.** Одним из наиболее тяжелых осложнений механической травмы является синдром жировой эмболии, который сопровождается летальностью до 60% случаев. Высокая летальность, обусловлена поздней, а, в ряде случаев, только посмертной диагностикой этого осложнения и, как следствие, неадекватной медицинской помощью. Это свидетельствует о недостаточной эффективности существующей диагностики рассматриваемого заболевания. Использование компьютерных систем и, в частности, приложения, основанного на нейросетевом моделировании, могут повысить эффективность диагностики заболевания и уменьшить число неблагоприятных исходов.

**Постановка задач исследования.** Для выполнения диагностики синдрома жировой эмболии (СЖЭ) необходимо решить следующие основные задачи:

- выполнить комплексный анализ лабораторных, клинических и анамнестических показателей применяемых в диагностике СЖЭ, которые используются при обучении нейронной сети;
- определить алгоритм обучения;
- определить тип и параметры нейронной сети;
- обучить нейронную сеть на контрольном множестве;
- выполнить проверку сети на тестовом множестве.

**Решение задач и результаты исследований.** Для объективного анализа необходимо определить показатели, по которым можно выполнить диагностику СЖЭ. В литературных источниках [1,2] предложено использование порядка 70 параметров оценки состояния пациента при СЖЭ. Чрезвычайное разнообразие параметров побуждает систематизировать данные и выделить наиболее достоверные признаки, по которым формируется база знаний для обучения нейронной сети. На основе работы [2] выбраны следующие показатели: признаки ухудшения состояния после латентного периода, рентгенологическая картина легких, частота сердечных сокращений, частота дыхания, температура тела, состояние сознания, снижение сатурации, сроки и характер стабилизации переломов, содержание палочкоядерных нейтрофилов в лейкоформуле, величина жировой гиперглобулемии, содержание холестерина, наличие и качество догоспитальной помощи, длительность догоспитального периода, наличие поврежденной жировой клетчатки. Для обучения нейронной сети на основе экспертной оценки необходимо выделить показатели, значимо влияющие на диагноз, поскольку представленное число параметров затрудняет процесс обучения. Удобен для этого непараметрический критерий Вилкоксона-Манна-Уитни [3]. Порядок его вычисления следующий:

1. Расположить варианты обеих выборок в возрастающем порядке, т.е. в виде одного вариационного ряда и найти в этом ряду наблюдаемое значение критерия  $W_{набл}$  – сумму рангов для меньшей группы. Если численность групп одинакова, то сумму можно вычислять для любой из них.

2. Найти нижнюю критическую точку:

$$\omega_{нижн.кр.} = \left[ \frac{(n_m + n_b + 1)n_m - 1}{2} - z_{кр} \sqrt{\frac{n_m n_b (n_m + n_b + 1)}{12}} \right], \quad (1)$$

где  $n_m$  – число членов в меньшей выборке;

$n_b$  – число членов в большей выборке;

$z_{кр}$  – критическая точка, определена из функции Лапласа  $\Phi(z_{кр}) = (1-\alpha)/2$ ;

$\alpha$  – заданный уровень значимости = 0,001;

Для рассматриваемой задачи  $\omega_{нижн.кр.} = 2012$

3. Находим верхнюю критическую точку по формуле:

$$w_{верх.кр.} = (n_m + n_b + 1)n_m - w_{нижн.кр.} = 2739 \quad (2)$$

Если  $w_{нижн.кр.} < W_{набл} < w_{верх.кр.}$  – нет оснований отвергнуть нулевую гипотезу

Если  $W_{набл} < w_{нижн.кр.}$  или  $W_{набл} > w_{верх.кр.}$  – нулевую гипотезу отвергают (различия статистически значимы).

Используя данный критерий, разработан программный модуль определения информативных параметров. В качестве входных данных использованы показатели 98 пациентов с механической травмой опорно-двигательной системы. Результаты представлены на рис. 1.

Уровень значимости альфа <input type="text" value="0.001"/> $W_{нижн.кр.} 2012.46$ $W_{верх.кр.} 2739.54$ <input type="button" value="Ok"/>		
Параметры	W наблюдений	Информативность
Ухудшение состояния	3456.00	да
Тахикардия	2998.50	да
Уровень сатурации	1283.00	да
Лейкоцитоз	3038.00	да
Нейтрофилы	2967.50	да
Гиперглобулемия	3017.00	да
Холестерин	1776.50	да
Повреждение подкожножировой клетчатки	2529.00	нет
Длительность догоспитального периода	3041.00	да
Догоспитальная помощь	2078.00	нет
Оперативная стабилизация	1595.00	да
Скелетное вытяжение	2906.00	да
Гипертермия	3121.50	да
Частота дыхательных движений	3228.50	да
Неврологические нарушения	3562.00	да
Клинико-рентгенологические признаки	3206.00	да

Рисунок 1 - Информативность параметров

Применяя описанный подход, удалось избавиться от двух факторов (повреждение подкожножировой клетчатки и оказание догоспитальной помощи). По отобранным данным сформирована обучающая выборка. Поскольку в работе использованы разнородные входные факторы и их статистические характеристики сильно отличаются, то данные необходимо нормировать. Сначала выполняются линейные преобразования, затем

осуществляется нелинейная нормировка с сигмоидальным преобразователем. Данный подход позволяет повысить эффективность нормировки путем лучшего приближения данных к равномерному распределению, что повышает информативность обучающего примера.

При обучении нейронной сети использована стратегия обучения с учителем, поскольку сформированные обучающие выборки содержат входные и сопоставимые им выходные сигналы. В качестве архитектуры сети взята нейронная система называемая многослойный персептрон с обучающим алгоритмом Quickprop [4]. Его основным достоинством является простота реализации при высокой скорости сходимости и низких требованиях к погрешности вычисления градиента. Он не требует сложных вычислений и содержит элементы, предотвращающие заикливание в точке неглубокого минимума, возникающего в результате работы нейрона на фазе насыщения сигмоидальной кривой, где из-за близости к нулю производной функции активации процесс обучения практически прекращается.

В рассматриваемом алгоритме значения весов изменяются в соответствии с правилом:

$$\Delta w_{ij}(n) = \begin{cases} \alpha_{ij}(n) \Delta w_{ij}(n-1) & \text{для } \Delta w_{ij}(n-1) \neq 0 \\ \eta_0 \frac{\partial E}{\partial w_{ij}} & \end{cases} \quad (3)$$

$$\alpha_{ij}(n) = \min \left\{ \frac{S_{ij}(n)}{S_{ij}(n-1) - S_{ij}(n)}, \alpha_{\max} \right\}, \quad (4)$$

где  $S_{ij}(n) = \frac{\partial E(w(n))}{\partial w_{ij}}$  - вектор градиента ошибки;

$\alpha_{ij}(n)$  - коэффициент момента, константа  $\alpha_{\max}$  - максимальное значение

коэффициента момента, которая по предложению Фальмана принимается равной  $\alpha_{\max}=1.75$ ;

$\eta_0$  - коэффициент обучения (как правило,  $0.01 \leq \eta_0 \leq 0.6$ ), для решаемой задачи  $\eta_0$  принято равным 0.5

Настройка параметров обучения производится с целью повышения скорости и качества обучения (точности прогноза) и включает в себя определение способа измерения ошибки обучения, вида алгоритма обучения, а также критерия останова. Функция ошибки характеризует величину расхождения между требуемым (эталонным) выходом нейросети и полученным на определенной итерации процесса обучения. Мера разницы между известным выходом и вычисленным называется ошибкой обучения. Используя среднюю квадратичную меру ошибки, получим:

$$E = \frac{1}{SM} \sum_{i=1}^S \sum_{j=1}^M (y_j^i - d_j^i)^2 \quad (5)$$

где  $S$  - число обучающих пар,  $M$  - размерность выходного вектора;

$d$  - известный выходной вектор,  $y$  - вычисленный выходной вектор.

Задача обучения нейронной сети сводится к тому, чтобы ошибка обучения  $E$  стала меньше некоторого значения  $\varepsilon$  ( $E < \varepsilon$ ).

Момент прекращения обучения, т.е. момент, в который сеть считается обученной, определяется на основе значения ошибки обучения с помощью критерия останова.

Поскольку выбранный алгоритм использует нейронную сеть типа "многослойный персептрон", а при обучении используется градиентный метод, то в качестве активационной функции нейронов используется униполярная сигмоидальная функция (рис. 2), которая задается в виде:

$$f(x) = \frac{1}{1 + e^{-\beta x}} \quad (6)$$

где  $\beta$  – параметр, характеризующий крутизну функции;  $x$  – входной сигнал.




Рисунок 2 - Сигмоидальная активационная функция

Данная активационная функция выбрана для всех нейронов сети, следовательно, сеть носит однородный характер. Важным свойством сигмоидальной функции является ее дифференцируемость. Для униполярной функции имеем:

$$\frac{df(x)}{dx} = \beta f(x)(1 - f(x)) \quad (7)$$

Количество нейронов во входном слое обусловлено размерностью входного вектора  $x=14$ . Подобная ситуация и с выходным слоем, в котором количество нейронов принимается равным размерности ожидаемого вектора  $d=2$ . Серьезной проблемой остается подбор количества скрытых слоев и числа нейронов в них. Возникает необходимость в проведении экспериментов для определения структуры и параметров нейронной сети адекватной поставленной задачи. Для чего разработан программный модуль, позволяющий моделировать и обучать нейронную сеть. Эксперименты выполнялись на обучающем множестве. В табл. 1 представлены усредненные результаты 10-кратного запуска программного модуля.

Таблица 1. Определение параметров нейронной сети

Структура сети	Значение фиксированной точности $E=0,001$					
	$\beta=0.5$		$\beta=1$		$\beta=1.5$	
	$t_{обуч}$	$k_{эпох}$	$t_{обуч}$	$k_{эпох}$	$t_{обуч}$	$k_{эпох}$
14-14-2	1,3	92	1,1	72	5,3	376
14-8-2	0,9	82	0,8	76	2,5	239
14-4-2	0,6	76	0,8	92	1,7	185

Обучение выполняется с фиксированной точностью  $E=0.001$ , поскольку при заданном уровне ошибки сеть обучается за довольно короткий отрезок времени ( $t_{обуч}$ ), при этом достигается высокая точность обучения. Для решаемой задачи выбран параметр крутизны сигмоиды  $\beta=1$ , т.к. при нем сеть обучается с приемлемым числом эпох ( $k_{эпох}$ ). Что касается структуры сети, то в программном приложении использована следующая архитектура: 14 нейронов на 1-м слое, 8 – на втором и 2 – на третьем. Выбранная структура не допускает переобучения сети, а ее нейронов достаточно для обобщения полученных знаний. Структурная схема созданной нейронной сети показана на рис. 3.




Рисунок 3 - Структурная схема нейронной сети

На основе представленных программных модулей было разработано программное приложение, в среде Delphi 7, позволяющее выполнять диагностику СЖЭ.

Для экспериментального подтверждения эффективности выбранного алгоритма обучения проведены ряд тестов. Тестирование проводилось на компьютере с процессором Pentium III 650МГц и 128Мб оперативной памяти под управлением операционной системы Windows 98, в разработанной программе, в которой реализован алгоритм обучения многослойных сетей Quickprop, и среде MATLAB, в котором в качестве тестируемых алгоритмов обучения взят алгоритм trainrp, реализующий алгоритм RPROP, и trainscg, реализующий метод масштабируемых сопряженных градиентов.

Эффективность алгоритмов сравнивалась, путем измерения среднего времени, требуемого для решения конкретной задачи и по количеству циклов обучения. Данные характеристики могут существенно изменяться в зависимости от характера тестовой задачи, объема обучающих данных, размерности нейронной сети, используемого вычислительного оборудования, а также деталей реализации отдельных этапов алгоритма. В табл. 2 представлена краткая характеристика обучающего набора, предназначенная для сравнения алгоритмов и диагностики СЖЭ.

Таблица 2. Характеристики тестового набора

Название	Структура сети	Число обучающих наборов	Ошибка обучения
Embolia	14 – 14 – 8 – 2 logsig – logsig – logsig	98	0.001

Для всех алгоритмов созданы одинаковые "условия", что дало основание для получения объективных оценок. В табл. 3 представлены усредненные значения 10-кратного запуска программного модуля.

Таблица 3. Средние значения экспериментальных результатов

Программа	Среднее время обучения, с.	С.к.о времени обучения, с.	Среднее число эпох
Fatty Embolism	0,84	0,24	78,5
Mathlab trainrp	1,71	0,22	36
Mathlab trainscg	4,02	3,46	73,3

Из полученных результатов видно, что за наименьшее время обучилась нейронная сеть, реализованная в разработанной программе. По числу эпох на первом месте находится алгоритм RPROP, реализованный в Matlab, что позволяет определить лучшую реализацию алгоритма, в смысле выбора начальных значений и коэффициентов. В этом тесте, алгоритм Quickprop, показал свое превосходство над методом сопряженных градиентов. Программная реализация рассматриваемого алгоритма обучения в этом соревновании выглядела достойно, что оправдывает разработку, поскольку реализация алгоритма в пакете Matlab Neural Network Toolbox затруднена, т.к. разработанные в нем программы требуют поддержки ядра среды, что делает приложения громоздкими.

Выполнена проверка, способности нейронной сети работать с данными, которые не принимали участия при обучении и оценена ее способность к обобщению. В табл. 4 представлены нормированные значения, подаваемые на входы нейронной сети. Результаты работы обученной сети с данными контрольной выборки представлены в табл. 5, в которой D1 и D2 – желаемые выходные вектора; Y1 и Y2 – вычисленные выходные вектора.

Таблица 4. Данные, подаваемые на входы нейронной сети

Вход 1	Вход 2	Вход 3	Вход 4	Вход 5	Вход 6	Вход 7	Вход 8	Вход 9	Вход 10	Вход 11	Вход 12	Вход 13	Вход 14
0	0,76	0,83	0,22	0,1	0,65	0,16	0,04	1	0	0,88	0,49	0,15	1
0	0,99	0,87	0,19	0,39	0,38	0,17	0,04	1	0	0,8	0,46	0,05	0
0	0,91	0,92	0,35	0,29	0,59	0,34	0,04	1	0	0,87	0,48	0,39	0
1	0,82	0,91	0,19	0,12	0,79	0,38	0,05	1	0	0,79	0,34	0	0
1	0,59	0,45	0,29	0,28	1	0,17	0,04	0	0	0,95	0,46	0,72	0
1	0,66	0,81	0,32	0,18	1	0,36	0,04	0	0	0,94	0,58	0,78	0
1	0,45	0,51	0,29	0,21	1	0,24	0,04	0	0	0,81	0,52	0,76	0
1	0,51	0,59	0,31	0,58	1	0,29	0,04	0	0	0,83	0,71	0,88	0
1	0,61	0,63	0,28	0,48	1	0,05	0,04	0	0	0,9	0,42	0,86	0
1	0,44	0,56	0,12	0,28	1	0,29	0,04	0	0	0,87	0,48	0,79	0

Таблица 5. Результаты работы с данными контрольной выборки

Выход D1	Выход D2	Выход Y1	Выход Y2
0	1	0,037	0,963
0	1	0,031	0,968
0	1	0,032	0,968
0	1	0,035	0,964
1	0	0,975	0,025
1	0	0,97	0,03
1	0	0,976	0,024
1	0	0,976	0,024
1	0	0,976	0,024
1	0	0,975	0,025

Комбинация выходов нейронов 0-1 соответствует отсутствию заболевания, а 1-0 – его наличию. Как видно из полученных результатов нейронная сеть обучилась правильно, а результаты, полученные на тестовом множестве, свидетельствуют о том, что сеть способна к обобщению и правильной работе с неизвестными данными.

**Выводы.**

1. Установлены оптимальные параметры нейронной сети для решаемой задачи. Получены результаты тестирования на контрольной выборке, которые свидетельствуют о правильном обучении и проектировании нейронной сети.

2. Разработанная программа предоставляет помощь врачу травматологу при диагностике СЖЭ, способствует более эффективному лечению, что позволяет улучшить анатомические и функциональные результаты, уменьшить число осложнений и неудовлетворительных исходов.

**Литература**

1. Корнилов Н.В., Кустов В.М. Жировая эмболия. СПб.: Морсар АВ, 2001. – 287 с.
2. Калинин О.Г., Курапов Е.П., Гридасова Е.И. Синдром жировой эмболии при тяжелой травме // Травма.-2001.-№1.-Т2.-С79-85.
3. В.Е. Гмурман "Теория вероятностей и математическая статистика" - М.: Высш. шк., 2005. – 479 с.
4. Осовский С. Нейронные сети для обработки информации: Пер. с польского. М: Финансы и статистика, 344 с., 2004.