



С. Н. Тесленко

*Харьковский национальный
медицинский университет*

© С. Н. Тесленко

**ПРИМЕНЕНИЕ НЕЙРОННЫХ СЕТЕЙ ДЛЯ ОЦЕНКИ
ТЯЖЕСТИ СОСТОЯНИЯ БОЛЬНЫХ
С ТРАВМАТИЧЕСКИМИ ПОВРЕЖДЕНИЯМИ
ПОДЖЕЛУДОЧНОЙ ЖЕЛЕЗЫ**

Резюме. В работе на основании 223 случаев травмы поджелудочной железы предложено три модели нейронных сетей для оценки тяжести состояния пациентов. Одна — для экспресс-анализа и две — для расширенной оценки. Общая точность, специфичность и чувствительность для всех систем составила более 90%.

Ключевые слова: травма поджелудочной железы, нейронные сети, оценка тяжести.

Вступление

Диагностика и оценка тяжести состояния больных с травмами поджелудочной железы (ПЖ) является сложной задачей как в дооперационном, так и в послеоперационном периоде. Существующие системы оценки тяжести пострадавшего сложны в практическом применении и не всегда могут быть использованы. Многие авторы указывают на необходимость разработки и внедрения простых и доступных оценочных шкал [1, 2, 3].

Материалы и методы

Мы проанализировали результаты хирургического лечения 223 больных с травмами ПЖ, которые были оперированы с 1980 по 2009 год в г. Харькове и Харьковской области. На этой основе была создана компьютерная база данных. Задачи классификации в пакете ST Neural Network решались с помощью сетей следующих типов: многослойного персептрона, радиальной базисной функции и линейной сети.

Для классификации использовалась выходная номинальная переменная «кластер», которая принимала три возможных значения (1,2,3), соответствующая степеням тяжести состояния пострадавших (1 — тяжелое состояние без угрозы для жизни; 2 — тяжелое состояние с угрозой для жизни пациента; 3 — критическое состояние с сомнительным выживанием).

Результаты исследования и их обсуждение

Для экспресс-анализа в качестве входных параметров тяжести состояния пациентов использовались семь переменных: систолическое давление, пульс, шоковый индекс, гемоглобин, возраст, наличие сочетанных и черепно-мозговых травм. При этом номинальные переменные «наличие сочетанных травм» и «наличие черепно-мозговых травм» брались в бинарном представлении (есть-нет).

Моделирование проводилось на 223 наблюдениях (минимально необходимое количество наблюдений N растет с количеством используемых входных переменных как $2^N = 2^7 = 128$). Вся выборка случайным образом разбивалась на обучающее

(112), контрольное (56) и тестовое (55) множества. Обучающее множество служило для обучения нейронной сети, контрольное — для независимой проверки, а тестовое использовалось для окончательной оценки после завершения работы. Кроме того, после завершения численных экспериментов осуществлялась прогонка всей базы данных через полученную сеть для окончательной проверки ее характеристик.

Первичный отбор сетей для анализа осуществлялся с использованием автоматического конструктора сетей и мастера по построению сетей (Intelligent Problem Solver). В данной работе наиболее перспективным типом сетей оказался многослойный персептрон, для которого и проводился поиск оптимальной с точки зрения задачи классификации нейросети. Наилучшая сеть выбиралась по оптимальному соотношению таких характеристик, как минимальная ошибка, значение качества классификации на тестовой и контрольной выборках, количество входов.

Численные эксперименты показали, что все входные переменные в различных комбинациях, кроме переменной «наличие черепно-мозговых травм», можно использовать для получения нейронных сетей с высоким качеством классификации (около 80%). Однако наиболее удачной оказалось нейросеть с четырьмя переменными на входе: систолическое давление, пульс, наличие сочетанных травм и возраст. Она содержит 4 входных, 7 скрытых и 3 выходных элементов. Архитектура нейросети представлена на рис. 1.

Выходная переменная «кластер» является номинальной с тремя возможными значениями (кодирование один-из- N). Вопрос принадлежности наблюдений к соответствующему классу решается принятием порогов принятия и отвержения. В нашем случае эти пороги выбирались равными 0 и 1 соответственно. Это подразумевает, что принадлежность к классам («кластер») определяется по наивысшей активации нейронов.

Обучение многослойного персептрона осуществлялось с помощью итерационного алгоритма обратного распространения. Процесс обучения последовательно проходит ряд так называемых




Рис. 1. Архитектура трехслойного персептрона

эпох, на каждой из которых на вход сети подается поочередно весь набор обучаемых данных. На основании вычисленных ошибок корректировались веса сети. Для того чтобы не допустить эффекта переобучения (сеть хорошо работает на обучаемом множестве, но неспособна обобщить полученные закономерности новых данных), на каждой эпохе применялась кросс-проверка на основе контрольного множества.

Для обучения методом обратного распространения устанавливаются управляющие параметры алгоритма. Значения этих параметров зависят от конкретной задачи, поэтому они выбирались на основе численных экспериментов. Так, величина скорости обучения, которая задает величину шага при изменении весов, была равна 0,05, что обеспечивало точную сходимость алгоритма. Для лучшего прохождения алгоритмом локальных минимумов коэффициент инерции выбирался большим (0,85). С целью уменьшения вероятности попадания в локальный минимум и уменьшения эффекта переобучения применялось изменение порядка наблюдений от эпохи к эпохе.

Наглядно процесс обучения представлен на графике изменения среднеквадратической ошибки для обучающего и контрольного (кросс-проверка) множеств (рис. 2).




Рис. 2. График обучения многослойного персептрона

В результате обучения была получена нейронная сеть со среднеквадратической ошибкой равной 0,2 и общей точностью классификации на

контрольном множестве 91%. Для оценки качества классификации полученной после обучения сети был сделан прогон всего набора данных (232 наблюдения). Более детальные результаты классификации на контрольной выборке и всего множества приведены в табл. 1.

Таблица 1

Кластеры	Контрольная выборка			Все множество		
	первый	второй	третий	первый	второй	третий
Всего	34	12	10	133	52	38
Правильно	33	8	10	124	41	36
Неверно	1	4	0	9	11	2
% правильных	94	75	100	93	80	95
Общая точность, %	91			90		

Приведенные данные показывают совпадение результатов и позволяют говорить о высокой адекватности модели классификации.

Рассмотрим также вопрос сбалансированности набора исходных данных. Поскольку при обучении сеть минимизирует общую погрешность, то большое значение играют пропорции, в которых представлены данные разных кластеров, т.е. сеть может искажать результаты классификации в пользу группы (кластера) с наибольшим числом наблюдений. Для проверки данного соображения размер наибольшего кластера (первый) за счет случайной выборки был уменьшен до 50 наблюдений. Проведенная классификация показала отсутствие значимых результатов по сравнению с полученными ранее.

Таким образом, для экспресс-оценки степени тяжести пострадавших получена нейронная сеть на основе многослойного персептрона с высокой точностью классификации. В модели используются четыре входных переменных: пульс (1), систолическое давление (2), наличие сочетанных травм (3), возраст (4), где в скобках указаны их ранги, полученные из анализа весовых коэффициентов сети.

В тех случаях, когда в медицинском учреждении имеется система для проведения экспресс-анализов, можно использовать расширенную оценку тяжести, включающую дополнительно в качестве входных переменных данные лабораторных анализов (клинический анализ крови и мочи, коагулограмма, биохимические исследования). В нашем случае это всего 21 показатель.

Отбор входных переменных и понижение размерности представляют большие трудности в нейросетевом моделировании. Для этих целей в качестве метода понижения размерности обычно используют метод главных компонент (линейный, нелинейный) или генетический алгоритм. В данной работе оказалось возможным провести предварительный отбор переменных исходя из экспертных оценок в предметной области и стан-

дартных статистических критериев. После чего проводились эксперименты с различными комбинациями входов и типов сетей. Как и в случае экспресс-анализа, наиболее перспективными оказались сети на основе многослойного персептрона. А среди входных переменных наиболее информативные с точки зрения задачи классификации оказались 14 следующих показателей:

- возраст пациента,
- наличие сочетанных травм,
- наличие черепно-мозговой травмы,
- частота пульса,
- артериальное систолическое давление,
- шоковый индекс (комбинированный параметр, представляющий собой отношение частоты пульса к систолическому давлению),
- показатели клинического анализа крови:
 - гемоглобин,
 - лейкоциты,
 - палочкоядерные нейтрофилы,
 - сегментоядерные,
- из показателей клинического анализа мочи — уровень белка,
- из показателей коагулограммы:
 - время рекальцификации,
 - а также показатели биохимического анализа крови:
 - общий белок,
 - мочевины,
 - общий билирубин.

Дальнейший анализ осуществлялся в соответствии с описанной выше процедурой для экспресс-анализа. Оказалось, что наилучшие сети получались при комбинации пяти «базовых» входных переменных (гемоглобин, мочевины, частота пульса, артериальное систолическое давление, шоковый индекс) с другими.

В качестве примера приведем результаты по нейронной сети, построенной на «базовых» переменных. Ее архитектура приведена ниже на рис. 3

После обучения была получена нейронная сеть со среднеквадратической ошибкой равной 0,19 и общей точностью классификации на контрольном множестве 92,8% (рис. 4).




Рис.3. Архитектура трехслойного персептрона с «базовыми» входными переменными

Результаты классификации на контрольной и тестовой выборках приведены в табл. 2. Прогон сети на всем наборе данных (232 наблюдения) показал совпадающие результаты (общая точность 92%).

Таблица 2

Результаты классификации на контрольной и тестовой выборках

Кластеры	Контрольная выборка			Тестовая выборка		
	пер- вый	вто- рой	тре- тий	пер- вый	вто- рой	тре- тий
Всего	30	16	10	41	6	9
Правильно	27	16	9	37	6	8
Неверно	3	0	1	4	0	1
% правильных	90	100	90	90,2	100	89
Общая точность, %	92,8			91,1		

С точки зрения более точной классификации и определения влияния каждой из входных переменных на классификацию объектов интерес представляет нейронная сеть, построенная на основе «базовых» переменных с добавлением к ним других. С точки зрения оптимальности по числу входов имеет смысл ограничиться тремя дополнительными переменными. Наилучшей оказалась комбинация «базовых» переменных с переменными «возраст», «наличие сочетанных травм» и «наличие черепно-мозговой травмы». Архитектура нейронной сети с такой комбинацией входных переменных представлена на рис. 5.

Использование большего количества входных переменных позволило уменьшить среднеквадратическую ошибку до 0,09 и увеличить общую точность классификации на контрольном (тестовом) множестве до 96,4% (96%). Кроме того, по большому числу входных переменных можно судить о роли каждой переменной в принадлежности к классам. Ранжирование переменных было сделано на основе весовых коэффициентов и уровней активации (рис. 6). Они представлены в таком порядке: артериальное систолическое




Рис.4. График обучения многослойного персептрона с «базовыми» входными переменными.




Рис. 5. Архитектура трехслойного перцептрона с восемью входными переменными

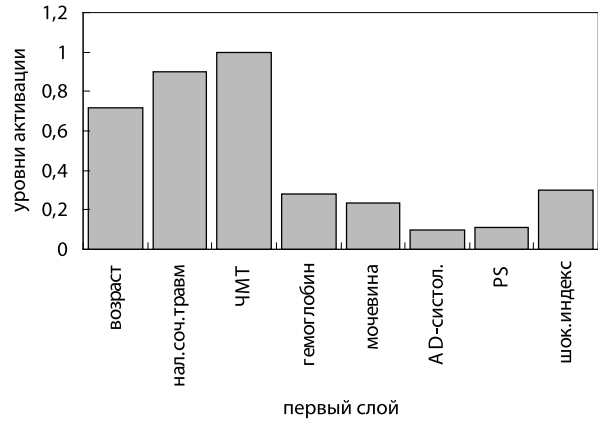


Рис. 6. Уровни активации на первом слое.

давление (1), частота пульса (2), мочевины (3), гемоглобин (4), шоковый индекс (5), возраст пациента (6), наличие сочетанных травм (7), наличие черепно-мозговой травмы (8).

Выводы

Предложены три модели нейронных сетей для оценки тяжести состояния с травматическими повреждениями ПЖ. Одна для экспресс-анализа и две — для расширенной оценки тяжести. Все они показали высокую степень адекватности модели классификации, низкую среднеквадратичную ошибку и очень высокую точность класси-

фикации (общая точность, специфичность и чувствительность >90%). На основе анализа весовых коэффициентов и уровней активации элементов сети сделаны выводы о степени влияния каждой из переменной на принадлежность к соответствующему классу. При выборе модели нейронной сети для практического применения, очевидно, стоит использовать самую простую (экспресс, общая точность 90%). Учет возможных ошибок в клинико-биохимических анализах (порядка 10%) делает нецелесообразным использование расширенных моделей с большей точностью (94—96%).

ЛИТЕРАТУРА

1. Афендулов С.А. Лечение деструктивного посттравматического панкреатита / С.А. Афендулов, В.Е. Жилин, В.П. Баранов // Труды I Московского международного конгресса хирургов. — Москва, 1995. — С. 227—228.
2. Васютков В.Я. Панкреатит, обусловленный травмой поджелудочной железы / В.Я. Васютков, З.М. Мурашева //

Труды I Московского международного конгресса хирургов. — Москва, 1995. — С. 218—219.

3. Молитвословов А.Б. Этиология, патогенез, клиника, диагностика и лечение посттравматического панкреатита / А.Б. Молитвословов, А.В. Филин // Хирургия. — 1994. — №4. — С. 10—12.

ВИКОРИСТАННЯ
НЕЙРОННИХ МЕРЕЖ ДЛЯ
ОЦІНКИ ТЯЖКОСТІ СТАНУ
ХВОРИХ
ІЗ ТРАВМАТИЧНИМИ
УШКОДЖЕННЯМИ
ПІДШЛУНКОВОЇ ЗАЛОЗИ

С. Н. Тесленко

APPLICATION OF NEURAL
NETWORKS TO ASSESS THE
SEVERITY OF PATIENTS
WITH TRAUMATIC INJURIES
OF THE PANCREAS

S. N. Teslenko

Резюме. У роботі на підставі 223 випадків травми підшлункової залози, запропоновано три моделі нейронних мереж для оцінки тяжкості стану хворих. Одна — для експрес-аналізу та дві — для поширеної оцінки. Загальна точність, специфічність та чутливість для всіх систем складала більше ніж 90%.

Ключові слова: травма підшлункової залози, нейронні мережі, оцінка тяжкості.

Summary. In work, on the basis of 223 cases of a trauma of pancreas, it is offered three models of neural networks for estimation of severity of injury. One for the express analysis and two for expanded estimation. The general accuracy, specificity and sensitivity for all systems has made more than 90%.

Key words: trauma of pancreas, neural networks, an estimation of severity of injury.