

Горбаченко В.И., Кузнецов Р.Н., Кузнецова О.Ю., Соломаха А.А. Предварительное обучение нейронной сети для диагностики послеоперационных осложнений при желчекаменной болезни. // Проблемы информатики в образовании, управлении, экономике и технике: Сб. статей XVIII Междунар. научно-техн. конф. – Пенза: ПДЗ, 2018. – С. 53-57.

УДК 004.032.26

ПРЕДВАРИТЕЛЬНОЕ ОБУЧЕНИЕ НЕЙРОННОЙ СЕТИ ДЛЯ ДИАГНОСТИКИ ПОСЛЕОПЕРАЦИОННЫХ ОСЛОЖНЕНИЙ ПРИ ЖЕЛЧНОКАМЕННОЙ БОЛЕЗНИ

В.И. Горбаченко, Р.Н. Кузнецов, О.Ю. Кузнецова, А.А. Соломаха

PRELIMINARY LEARNING OF THE NEURAL NETWORK FOR THE DIAGNOSIS OF POSTOPERATIVE COMPLICATIONS IN CHOLELITHIASIS

V.I. Gorbachenko, R.N. Kuznetsov, O.Yu. Kuznetsova, A. A. Solomakha

Аннотация. На материале Пензенской областной клинической больницы имени Н.Н. Бурденко о пациентах с желчнокаменной болезнью исследованы нейросетевые методы для диагностики послеоперационных осложнений. Была подобрана оптимальная архитектура сети, ошибка которой составила 0,99 %.

Ключевые слова: прогнозирование послеоперационных осложнений, автоэнкодер, нейронные сети.

Abstract. On the material from the Penza regional clinical hospital named after N.N. Burdenko about patients with cholelithiasis, neural network methods for the diagnosis of postoperative complications are investigated. The optimal network architecture was chosen, the error of which was 0.99%.

Keywords: prediction of postoperative complications, autoencoder, neural network.

Желчнокаменная болезнь (ЖКБ) относится к наиболее распространенным заболеваниям в мире и занимает третье место после сердечно-сосудистых заболеваний и сахарного диабета [1]. Ранее был осуществлён отбор информативных признаков для прогнозирования осложнений при желчнокаменной болезни. Для обработки биомедицинских данных использовали нейросетевые методы. Известно, что нейронные сети имеют возможность обучаться и обобщать накопленные знания и используются для задач классификации образов, распознавания, идентификации, прогнозирования [2].

Для диагностики послеоперационных осложнений у больных ЖКБ использовали нейронные сети. Выходом нейросети являлся показатель наличия осложнений – 1, отсутствия осложнений 0.

С использованием инструмента Neural Networks Toolbox системы MATLAB были проведены исследования различных архитектур нейронной сети (рис. 1). Были исследованы различные архитектуры многослойного персептрона с использованием функции активации скрытых слоев гиперболический тангенс и алгоритма обучения Левенберга-Марквардта. Результаты исследования представлены в табл. 1.

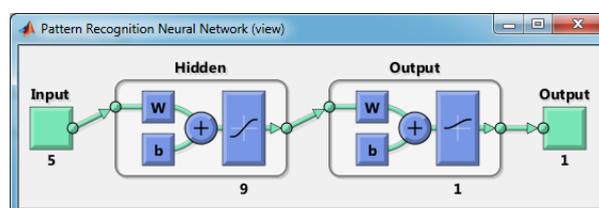


Рис. 1. Структура нейронной сети

Обобщенные результаты обучения нейронных сетей

Количество нейронов в скрытом слое	Правильно распознанных (%)
3	74,30
11	57,8
9	78,9
15	77,1
10	65,10
13	72,5
17	73,4

Из этого следует, что наиболее удачной архитектурой нейронной сети является 5-9-1. Лучшая производительность на проверочной выборке достигнута за 6 эпох обучения сети.

Эксперименты с многослойным персептроном показали, что этот тип сетей дает достаточно большую ошибку на представленных данных. Относительно невысокая точность работы сети объясняется небольшими различиями признаков примеров, соответствующих наличию и отсутствию осложнений, а также небольшим размером обучающей выборки. Можно предположить, что выявление в имеющемся обучающем наборе дополнительных "скрытых" признаков или "сжатие" признаков поможет повысить точность диагностики. Для повышения качества обучающих данных применено предварительное обучение сети с помощью автоэнкодера.

Автоэнкодер, или автокодировщик (англ. autoencoder), это нейронная сеть, выходной вектор которой равен входному вектору признаков [3-5]. Автоэнкодеры можно использовать для предварительного обучения сети, например, когда стоит задача классификации, а размеченных пар слишком мало [6] или для понижения размерности в данных для последующей визуализации.

Наиболее распространенный автоэнкодер – это сжимающий (undercomplete) автоэнкодер. Например, простейший трехслойный автоэнкодер имеет во входном и выходном слоях количество нейронов, равное количеству входов. А скрытый слой имеет меньшее количество нейронов. Автоэнкодер обучается без учителя, так чтобы выходные сигналы были равны входным. После обучения выходы скрытого слоя представляют собой нелинейно сжатые в пространство меньшей размерности входные данные. Такой автоэнкодер позволяет выделить в новом пространстве наиболее отличительные признаки. Причем автоэнкодер с нелинейными функциями активации выполняет более мощное сжатие данных, чем линейный метод главных компонент [3]. Возможно построение повышающего (overcomplete) автоэнкодера, у которого скрытый слой имеет большее количество нейронов, чем входной. Автоэнкодеры этого типа позволяют извлекать скрытые признаки из набора данных. Таким образом, автоэнкодер обучается выделять из входных данных общие признаки, которые кодируются в значениях весов сети. Чтобы повышающий автоэнкодер лучше выявлял скрытые зависимости, вводится регуляризация – требование разреженной активации нейронов скрытого слоя [3]. В случае сигмоидальной функции активации нейрон считается активным, если его выход близок к 1, и неак-

тивным, когда его выход близок к 0. Автоэнкодеры, для которых выполняется требование разреженной активации нейронов, называются разреженными автоэнкодерами (sparse autoencoder). В автоэнкодере выделяют кодер (encoder), преобразующий входные данные в данные скрытого слоя, и декодер (decoder), производящий обратное преобразование.

Для проверки возможности нейронной сети для диагностики послеоперационных осложнений с предварительным обучением автоэнкодера проводились экспериментальные исследования. Для этого применялось предварительное послойное "жадное" обучение нейронной сети [7]. Первый слой сети (рис. 2) настраивался с помощью автоэнкодера, второй слой softmax настраивался без использования автоэнкодера. Алгоритм является "жадным", так как слои настраиваются независимо друг от друга.

К первому необученному слою на время обучения подключался дополнительный выходной слой, в результате строился автоэнкодер. На вход автоэнкодера подавались данные для обучения. Веса необученного слоя и дополнительного слоя автоэнкодера обучались при помощи масштабированного метода сопряженных градиентов с использованием встроенных методов регуляризации Neural Networks Toolbox. Затем декодер автоэнкодера отключался, на вход сети подавался тот же набор данных, обученный первый слой не изменялся, выходной слой softmax обучался с учителем масштабированным методом сопряженных градиентов.

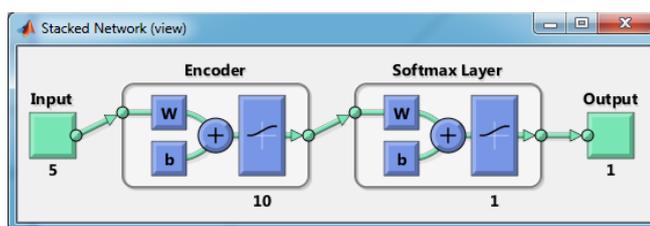


Рис. 2. Структура предварительно обучаемой сети

Далее вся сеть с предварительно настроенными слоями обучалась с учителем масштабированным методом сопряженных градиентов.

Результаты обучения представлены в табл. 2.

Таблица 2

Обобщенные результаты нейронной сети с предварительным обучением автоэнкодера

Количество нейронов в скрытом слое автоэнкодера	Правильно распознанных (%)
2	78
4	91,7
6	89,9
8	95,4
10	99,01

Наиболее удачной архитектурой нейронной сети с предварительным обучением автоэнкодера является архитектура с 10 нейронами в скрытом слое автоэнкодера. Данная нейронная сеть показала точность диагностики, равную 99,01%. Лучшая производительность на тестовой выборке достигнута за 1000 эпох. Из этого

следует, что нейронная сеть с предварительным обучением автоэнкодера дает меньшую ошибку при диагностике, чем классический многослойный персептрон.

Библиографический список

1. Головской Б.В. Новый диагностический синдром при хроническом бескаменном холецистите // Третий Всесоюзный съезд гастроэнтерологов: материалы съезда. М., 1984, Т. 1. С. 238–39.
2. Горбаченко В.И., Кузнецов Р.Н., Кузнецова О.Ю. Отбор информативных признаков для прогнозирования послеоперационных осложнений при желчнокаменной болезни // Проблемы информатики в образовании, управлении, экономике и технике: сборник статей XVI Международной научно-технической конференции, 2016. Пенза: Приволжский дом знаний, 2016. С. 91–97.
3. Гудфеллоу Я., Бенджио И., Курвиль Я. Глубокое обучение. М.: ДМК Пресс, 2018. 652 с.
4. Николенко С., Кадури А., Архангельская Е. Глубокое обучение. СПб.: Питер, 2018. 480 с.
5. Hinton G. E., Salakhutdinov R. R. Reducing the dimensionality of data with Neural Networks. Science, 2006, 28 July, vol. 313, no. 5786, pp. 504–507.
6. Автоэнкодеры в Keras, Часть 1: Введение // <https://habr.com/post/331382/>
7. Greedy layer-wise training of deep networks / Y. Benaio, P. Lamblin, D. Popovici, H. Larochelle // NIPS'06 Proceedings of the 19th International Conference on Neural Information Processing Systems Pages, 2006. P. 153–160.

Горбаченко Владимир Иванович

Пензенский государственный
университет,
г. Пенза, Россия
E-mail: gorvi@mail.ru

Gorbachenko V.I.

Penza State University,
Penza, Russia

Кузнецов Роман Николаевич

Пензенский государственный
университет,
г. Пенза, Россия

Kuznetsov R.N.

Penza State University,
Penza, Russia

Кузнецова Ольга Юрьевна

Пензенский государственный
университет,
г. Пенза, Россия
E-mail: ellekasandra@yandex.ru

Kuznetsova O.Yu.

Penza State University,
Penza, Russia

Соломаха Анатолий Анатольевич

Пензенский государственный
университет,
г. Пенза, Россия
E-mail: anatoly.solomakha@yandex.ru

Solomakha A.A.

Penza State University,
Penza, Russia