

Таблица 2. Сравнение результатов оценки погрешности одометров для различных размеров робота

	Результат	Результат J. Collins
Mean Square Error NN	0,165	0,17
Relative error	3,36%	1,20%
Dataset dimension	161	90
Robot dimension	6 см X 6 см	30 см X 30 см
Пройденное расстояние	1,7 м	5 м

ошибке обучения нейронной сети относительная погрешность одометров в данных экспериментах выше чем в [6] даже с учетом меньшего пройденного расстояния. Это согласуется с факторами, сильно влияющими на робота малых размеров. Однако в сравнении с погрешностью одометров (8–10 %) относительная погрешность позиции робота по данным нейронной сети (3 %) дает более точный результат. Уточнение позиции робота в три раза улучшит точность построения карты и навигации мобильного робота.

Заключение. В результате проведенного исследования были получены характеристики механики для конкретного реального робота. На основании данных характеристик проведена калибровка подсистем управления и позиционирования робота для решения задачи локализации. Для уточнения позиции робота и повышения качества и надежности информации, выдаваемой подсистемой локализации, был предложен нейросетевой модуль. Результаты экспериментов доказали успешность предложенного подхода, особенно в продольном направлении, где ошибка наиболее существенна. Однако в данном подходе имеется ряд недостатков, таких как: необходимость настройки нейросетевого модуля для конкретного робота и окружающей среды, требование к производительности бортового оборудования робота, необходимость использования внешнего видеорежистратора для оценки реальной позиции робота. В дальнейшем для решения данных проблем планируется создание интеллектуальной системы позиционирования, которая смогла бы адаптироваться во время работы к параметрам робота, внешней среды и использовала для оценки позиции, кроме одометров, другие сенсоры робота.

Признательность. Данная работа выполнена при поддержке гранта Ф11-ЛИТ003 Белорусского республиканского фонда фунда-

ментальных исследований и гранта ГБ 11/117 Министерства образования Республики Беларусь.

СПИСОК ЦИТИРОВАННЫХ ИСТОЧНИКОВ

1. Fox, D. Markov localization for mobile robots in dynamic environments / D. Fox, W. Burgard, S. Thrun // Journal of Artificial Intelligence Research (JAIR). – 1999. – P. 391–427.
2. Montemerlo, M. Fast-SLAM2.0: An Improved Particle Filtering Algorithm for Simultaneous Localization and Mapping that Provably Converges / M. Montemerlo, S. Thrun, D. Kollerand, B. Wegbreit // In Proc. Of the Int. Confs. On Artificial Intelligence (IJCAI). – 2003. – P. 1151–1156.
3. Kleeman, L. Odometry Error Covariance Estimation for Two Wheel Robot Vehicles // Technical Report MECSE-95-1, Department of Electrical and Computer Systems Engineering. – Monash University, 1995.
4. Martinelli, A. Estimating the Odometry Error of a Mobile Robot during Navigation / A. Martinelli, R. Siegwart // In Procs. Of European Conf. on Mobile Robots, 2003.
5. Borenstein, J. Measurement and correction of systematic odometry errors in mobile robot / J. Borenstein, L. Feng, // IEEE Transactions on Robotics and Automation. – 1996. – № 12(6). – P. 869–880.
6. Haoming, X. Estimating the Odometry Error of a Mobile Robot by Neural Networks / Xu Haoming, John James Collins. // In Proc. of International Conference on Machine Learning and Applications, 2009.
7. Siegwart, R. Introduction to Autonomous Mobile Robots / R. Siegwart, I. Nourbakhsh // The MIT Press, 2004.
8. Zhang, Z. A flexible new technique for camera calibration // IEEE Transactions on Pattern Analysis and Machine Intelligence. – 2000. – № 22(11). – P. 1330–1334.

Материал поступил в редакцию 07.12.11

KASYANIK V.V., DUNETS A.P. Estimation of odometers error of mobile robot by neural networks

One of the most important problems in robotics is determination the accuracy location of the robot – the problem of localization. This issue is important because information about the exact location of the robot is required to navigate, build path, etc. This article considers the approach of using of a neural network to estimate the odometry error in the mobile robot localization based on the odometers.

УДК 004.8.032.26

Головко В.А., Войцехович Г.Ю., Мاستыкин А.С., Апанель Е.Н.

НЕЙРОННЫЕ СЕТИ ДЛЯ ДИАГНОСТИКИ ТРАНЗИТОРНЫХ ИШЕМИЧЕСКИХ АТАК

Введение. В настоящее время все больше возрастает тенденция проектирования систем искусственного интеллекта на основе нейронных сетей, искусственных иммунных систем, эволюционного программирования и других, биологически инспирированных подходов. Использование методов искусственного интеллекта широко применяется и в медицине. Каждый год в журналах появляется более 500 академических публикаций по применению искусственных нейронных сетей в медицинских приложениях [1]. Согласно публикуемой литературе, искусственные нейронные сети являются эффек-

тивным средством для автоматической диагностики заболевания и помогают врачу принять адекватное решение. Медицинская диагностика является сложной задачей, которая зависит от квалификации доктора и поэтому во многих случаях очень субъективна.

Сложность также состоит в том, что заболевание, как правило, определяется большим числом факторов и симптомов. К сожалению, медицинские работники очень часто не обладают достаточным опытом в диагностике многих заболеваний. Недостаточная квалификация медицинских работников увеличивает смертность среди паци-

Войцехович Геннадий Юрьевич, аспирант кафедры интеллектуальных информационных технологий Брестского государственного технического университета.

Беларусь, БрГТУ, 224017, г. Брест, ул. Московская, 267.

Мастыкин Александр Сергеевич, к.м.н., старший научный сотрудник Республиканского научно-практического центра неврологии и нейрохирургии.

Апанель Елена Николаевна, к.м.н. Республиканского научно-практического центра неврологии и нейрохирургии.

Беларусь, РНПЦ неврологии и нейрохирургии, 220114, г. Минск, ул. Ф. Скорины, 24.

ентов. Так, например, диагностика транзиторных ишемических атак (ТИА) врачами первой помощи была правильной лишь в 30% случаев. В то время как автоматическая система поддержки принятия решений в медицинской диагностике позволяет повысить качество диагностирования и избавить врача от рутинной работы.

Для рассматриваемого класса заболеваний большое значение имеет оперативное обнаружение, позволяющее предотвратить катастрофическое развитие ситуации и помогающее доктору поставить адекватный диагноз. Задачи оперативного обнаружения транзиторных ишемических атак являются трудноформализуемыми, для них невозможно или очень сложно формализовать процесс принятия решений. Основным подходом в медицинских учреждениях для диагностики таких заболеваний является нейропсихологическое тестирование, которое зависит от квалификации врача и очень часто приводит к неадекватному диагнозу.

Поэтому эффективным средством для автоматической диагностики таких заболеваний являются нейросетевые методы для обработки биомедицинских данных. Методы, основанные на искусственных нейронных сетях, являются подходящим средством для решения трудноформализуемых задач и, как будет показано ниже, позволяют повысить качество диагностирования и, соответственно, помочь врачу поставить адекватный диагноз.

Существуют различные методы диагностики ТИА: нейропсихологическое тестирование (neuropsychological testing), статистические подходы, методы искусственного интеллекта [3-8]. Основным подходом в медицинских учреждениях для первичной диагностики транзиторных ишемических атак (ТИА) является визуальная инспекция и нейропсихологическое тестирование, которые зависят от квалификации врача и очень часто приводят к неадекватному диагнозу. Так, например, диагностика транзиторных ишемических атак (ТИА) врачами первой помощи является корректной лишь в 30% случаев [9]. Параметрами для диагностики являются тестирование речи (внезапное затруднение понимания речи), соматической чувствительности, вегетативные нарушения (внезапное появление односторонней слабости мускулатуры лица или конечностей) и т.д. Основным недостатком такого подхода является зависимость от квалификации врача и низкая точность первичной диагностики. Статистические подходы требуют наличия больших баз данных, что нередко является большим препятствием на пути создания системы диагностики. К методам искусственного интеллекта относятся нейронные сети, генетический алгоритм, нечеткая логика или их комбинации. Эти технологии характеризуются высокой точностью и менее требовательны к размеру базы данных в сравнении со статистическими алгоритмами. По этой причине методы искусственного интеллекта могут быть подходящим инструментом для диагностики и классификации подтипов ТИА. В данной статье для диагностики ТИА предлагается нейросетевая модель. Нейросетевые методы используются для уменьшения времени диагностики и числа ошибочных диагнозов, а также для помощи доктору в принятии решения. Эффективность предлагаемой нейросетевой модели в диагностике транзиторных ишемических атак иллюстрируется результатами экспериментов.

Статья организована следующим образом. Во 2-м разделе приводится краткий обзор работ схожей тематики. Общая информация о транзиторных ишемических атаках представлена в 3-м разделе. В 4-м разделе описываются исходные данные. Предлагаемая нейросетевая модель для диагностики ТИА подробно описана в 5-й, 6-й и 7-й частях. В 8-м разделе приводятся и обсуждаются результаты экспериментов.

Существующие подходы. В настоящее время существует множество подходов для предварительной диагностики ТИА.

Один из статистических подходов для диагностики транзиторных ишемических атак описан в [4]. Авторы применили многомерную логистическую регрессию, используя ROC (receiver operating characteristic curves) анализ, для создания клинической системы диагностирования ТИА. Для этого была использована база данных из West Glasgow Stroke Registry, которая содержала информацию приблизительно о 225 000 пациентов. После регрессионного анализа

были выделены 9 переменных с соответствующими коэффициентами регрессии: возраст, головные боли, двоение в глазах, обмороки, приступы, речевые нарушения, односторонняя слабость в конечностях, изменения на лице, история ТИА. Для вычисления критерия ТИА значения всех коэффициентов регрессии суммируются. При использовании ROC кривых ТИА идентифицировалась, если значение критерия превышало 6.1. Такая система правильно идентифицировала 85% пациентов с цереброваскулярными отклонениями и 54% с нецереброваскулярными. Основным недостатком такого подхода является необходимость иметь большую базу данных.

Нейронные сети в задаче диагностики ишемических заболеваний описываются в [6]. Предлагаемые модели были разработаны для быстрой диагностики ТИА в соответствии со следующими выходными значениями: нормальное состояние, ТИА в левой сонной артерии, правой сонной артерии и др. Исходными данными являлись анкеты пациентов, в 6 секциях которых содержалась следующая информация: потеря или изменение речи, потеря зрения, зрительные двоения, нечувствительность или дрожь, паралич или слабость, головокружения или потеря равновесия. Каждый входной образ состоял из цифр 0 или 1 из анкеты. Для каждой секции анкеты использовался многослойный перцептрон. Так, например, сеть для зрительных двоений состояла из 4 входных и 5 выходных нейронов. Три выхода соответствовали случаю "нет события" и оставшиеся 2 – удар (stroke) или ТИА.

В [7-8] описывается пример применения генетического алгоритма для отбора признаков-предикторов с наиболее выраженным дифференциально-диагностическим потенциалом и последующей классификацией с помощью многослойного перцептрона для прогнозирования тромбоэмболических ударов. Архитектура нейронной сети состоит из 20 входных нейронов, 10 скрытых и 10 выходных нейронов. В качестве входных данных были использованы следующие параметры: гипертония, диабет, миокардия, холестерин в крови и др. Выходные нейроны отображают различные категории заболеваний: ТИА, левая гемиплегия, афазия, правая гемипарестезия, дисфагия и квадриплегия. Точность прогнозирования составляет 78.52% на обучающей выборке и 90.61% – на тестовом множестве.

Рассмотренные выше подходы отличаются друг от друга используемыми входными и выходными данными, а также базами данных пациентов. Поэтому трудно сравнивать эффективность различных подходов.

В следующих разделах рассматривается нейросетевая диагностическая система для предварительной диагностики ТИА. Эффективность предлагаемой нейросетевой системы для диагностики транзиторных ишемических атак иллюстрируется результатами экспериментов.

Транзиторные ишемические атаки. Транзиторно-ишемическая атака (ТИА) на нормальное кровоснабжение головного мозга – это самостоятельная гетерогенная нозологическая единица, которая характеризует предынсультное состояние [10]. Основная задача состоит в раннем обнаружении ТИА, для того чтобы предупредить последующие серьезные нарушения мозгового кровообращения. В общем случае транзиторно-ишемические атаки можно разделить на три подтипа ТИА и класс НОРМА: 1) атеротромботический подтип (СубТИА1); 2) кардиоэмболический подтип (СубТИА2); 3) гипертензивный подтип (СубТИА3); 4) норма (НОРМА).

После эпизода ТИА риск развития инсульта существенно возрастает. Так, например, у 4-5% пациентов инсульт развивается в течение 2 дней, а у 11% – в течение 7 дней после эпизода ТИА. Поэтому пациенты после ТИА должны детально обследоваться в самые кратчайшие сроки (в течение 24 часов), чтобы предотвратить дальнейшее негативное развитие болезни, которое может привести к острому инульту.

Таким образом, своевременное выявление ТИА позволяет предотвратить сложные и часто необратимые последствия заболевания.

Исходные данные для диагностики. Входные данные для обучения и тестирования нейронных сетей были предоставлены 5-й городской клинической больницей г. Минска. Они представляют со-

бой набор из 38 медицинских показателей для 114 пациентов, у которых имелись симптомы ТИА. Таким образом, в качестве входных данных используется 38-размерный вектор, который характеризует исходные данные (признаки и симптомы) пациента, такие как возраст, хронический бронхит, диастолическое давление и т.д. [10]. В качестве выходных данных используется 4-мерный вектор, где 4 это количество классов ТИА плюс нормальное состояние.

Эти показатели и величины их градаций представлены в таблице 1. Исходное множество данных содержало 28 образов первого подтипа (ТИА1), 25 образов подтипа 2 (ТИА2), 27 образов третьего подтипа (ТИА3) и 34 образа нормального состояния (без ТИА).

Таблица 1. Структура исходных данных

№	Наименование параметра	Величина градаций
1	Возраст	6
2	Пол	2
3	Место жительства	5
4	Образование	4
5	Профессия	4
6	Конфликты по работе и с администрацией	3
7	Смена места жительства за послед. 10 лет	5
8	Смена профессии за последние 10 лет	7
9	Особенности ночного сна	4
10	Бессонница	3
11	Наследствен. по патологии сосудов мозга	3
12	Наследственность по другим заболеваниям	3
13	Артериальная гипертензия	4
14	Диастолическое давление	3
15	Аускультация сердца	5
16	Границы сердца	3
17	Изменения на ЭКГ	3
18	Боли в области сердца	4
19	Нарушения сердечного ритма	4
20	Хронический бронхит	3
21	Хронический гепатохолестит	3
22	Хрон. гастрит, язв. болезнь желудка	4
23	Почечнокаменная болезнь	3
24	Остеохондроз шейный	4
25	Метеозависимость	5
26	Употребление алкоголя	3
27	Курение (количество)	3
28	Курение (возраст)	4
29	Работоспособность	3
30	Раздражительность повышенная	3
31	Снижение памяти (степень)	3
32	Снижение памяти (время появления)	3
33	Снижение остроты зрения (степень)	3
34	Снижение остроты зрения (время появления)	4
35	Зрительные нарушения	3
36	Головные боли	4
37	Головные боли (время появления)	4
38	Головокружение	4

Собранные данные о пациентах с различными заболеваниями ТИА составляют обучающую выборку для диагностической нейросетевой системы.

Нейросетевая диагностическая система. Рассмотрим нейросетевую систему распознавания транзиторных ишемических атак. Данная система основывается на двух различных нейронных сетях. В качестве входного вектора выступают описанные выше 38 параметров, содержащие данные о пациенте. Выходными данными нейросетевой системы является 4-размерный вектор, где 3 выхода соответствуют подтипам ТИА и один – нормальному состоянию. Обработка входных данных осуществляется в 2 этапа. Первый этап

соответствует выделению наиболее информативных признаков (feature selection). Один из наиболее важных вопросов, касающихся входных данных, является следующий: какие входные параметры действительно полезны и оказывают наибольшее влияние на результат диагностики? Часто в аналогичных системах для выделения наиболее информативных признаков используется генетический алгоритм [7]. В данной работе для выделения наиболее значимой информации из исходных данных и уменьшения размерности входных данных предлагается использовать нелинейный метод главных компонент (NPCA), с помощью которого входные 38-размерные векторы преобразуются в 12-размерные выходные векторы.

На втором этапе обработки данных производится классификация ТИА. Сжатые на предыдущем шаге данные, содержащие наиболее важную информацию из входного множества, используются как входная информация на втором этапе обработки информации. Для классификации ТИА используется многослойный перцептрон (MLP). Многослойный перцептрон обрабатывает сжатое пространство образов для определения класса ТИА или нормального состояния. Выходной слой включает 4 нейрона: 3 для каждого класса патологии и один для нормального состояния.

Таким образом, нейросетевая диагностическая система состоит из двух нейронных сетей: одна для реализации нелинейного метода главных компонент (для этих целей используется рециркуляционная нейронная сеть, RNN), вторая представляет собой многослойный перцептрон (рис. 1).

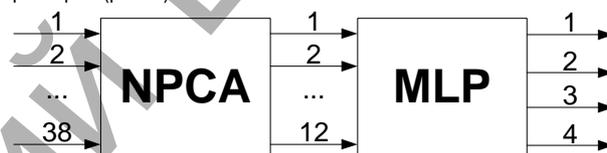


Рис. 1. Структура диагностической системы

Перед подачей данных на вход NPCA они преобразуются в соответствии со следующими выражениями:

$$x_i^k = \frac{x_i^k - \mu(x_i)}{\sigma(x_i^k)}, \quad (1)$$

$$\mu(x_i) = \frac{1}{L} \sum_{k=1}^L x_i^k, \quad (2)$$

$$\sigma(x_i^k) = \frac{1}{L} \sum_{k=1}^L (x_i^k - \mu(x_i))^2, \quad (3)$$

где L – размерность обучающей выборки.

После обучения нейросетевая система способна распознавать транзиторные ишемические атаки на образах, не входивших в обучающую выборку.

Нелинейная рециркуляционная нейронная сеть. Рассмотрим нелинейную рециркуляционную нейронную сеть (RNN), которая является аналогом нелинейного метода главных компонент (рис. 2). Она представляет собой трехслойный перцептрон, который осуществляет нелинейное сжатие данных. Как видно из рисунка, нейронные элементы распределены по 3-м слоям. Скрытый слой осуществляет сжатие входных данных.

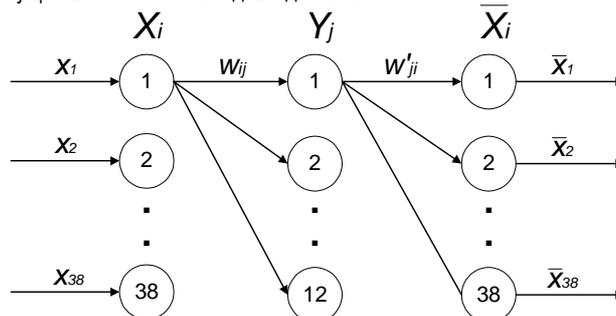


Рис. 2. Рециркуляционная нейронная сеть

При использовании метода главных компонент возникает вопрос, какое наименьшее число компонент выбрать, сохранив при этом максимум информативности. Для определения необходимого количества главных компонент используем эмпирический метод на основе критерия информативности:

$$I = \frac{\lambda_1 + \lambda_2 + \dots + \lambda_p}{\lambda_1 + \lambda_2 + \dots + \lambda_n} = \frac{\sum_{i=1}^p \lambda_i}{\sum_{i=1}^n \lambda_i}, \quad (4)$$

где n – размерность входного вектора,

λ_i – собственные значения главных компонент, которые равняются их дисперсии.

Построив график зависимости информативности от числа главных компонент, можно определить подходящее количество главных компонент (рис. 3).

Как следует из рисунка, количество главных компонент, необходимых для достаточной информативности сжатых данных, равняется 12.

Рассмотрим зависимость выходных значений от входных данных для рециркуляционной нейронной сети.



Рис. 3. График зависимости информативности от числа главных компонент

Значение j -го элемента скрытого слоя определяется в соответствии со следующим выражениями:

$$y_j = F(S_j), \quad (5)$$

$$S_j = \sum_{i=1}^{38} w_{ji} \cdot x_i, \quad (6)$$

где F – функция активации; S_j – взвешенная сумма j -го нейрона; w_{ji} – весовой коэффициент между i -ым нейроном входного и j -ым нейроном скрытого слоя; x_i – i -й входной элемент.

Значения нейронных элементов выходного слоя определяются следующим образом:

$$\bar{x}_i = F(S_i), \quad (7)$$

$$S_i = \sum_{j=1}^{12} w'_{ji} \cdot y_j. \quad (8)$$

где w'_{ji} – весовой коэффициент между j -ым нейроном скрытого и i -ым нейроном выходного слоя; \bar{x}_i – i -ый выходной элемент.

Для обучения нелинейной RNN использовался алгоритм обратного распространения ошибки с процедурой ортогонализации Грамма-Шмидта. В соответствии с ним весовые коэффициенты модифицируются по следующим выражениям:

$$w_{ij}(t+1) = w_{ij}(t) - \alpha \cdot \gamma_j \cdot F'(S_j) \cdot x_i, \quad (9)$$

$$w'_{ji}(t+1) = w'_{ji}(t) - \alpha \cdot (\bar{x}_i - x_i) \cdot F'(S_i) \cdot y_j, \quad (10)$$

где γ_j – ошибка j -го скрытого элемента:

$$\gamma_j = \sum_{i=1}^{38} (\bar{x}_i - x_i) \cdot F'(S_i) \cdot w'_{ji}, \quad (11)$$

и $F'(S_j)$ – производная нелинейной функции активации по взвешенной сумме.

Весовые коэффициенты в скрытом слое ортонормируются в соответствии с процедурой Грамма-Шмидта:

1) Первый вектор вычисляется как:

$$w'_1 = \left[\frac{w_{11}}{|w_1|}, \frac{w_{21}}{|w_1|}, \dots, \frac{w_{n1}}{|w_1|} \right], \quad (12)$$

где

$$|w_1| = \sqrt{w_{11}^2 + w_{21}^2 + \dots + w_{n1}^2}. \quad (13)$$

2) Следующий весовой вектор определяется по следующим рекуррентным формулам:

$$w_i = w_i - \sum_{j=1}^{i-1} (w_i^T \cdot w'_j) \cdot w'_j, \quad (14)$$

$$|w_i| = \sqrt{w_{1i}^2 + w_{2i}^2 + \dots + w_{ni}^2}, \quad (15)$$

$$w'_i = \left[\frac{w_{1i}}{|w_i|}, \frac{w_{2i}}{|w_i|}, \dots, \frac{w_{ni}}{|w_i|} \right], \quad (16)$$

где $i=2..12$.

После обучения нелинейная рециркуляционная нейронная сеть способна осуществить ортогональное сжатие входного множества данных.

Многослойный перцептрон. Как уже упоминалось выше, архитектура нейронной сети для распознавания ТИА, используемая в данной статье, представляет собой многослойный перцептрон с 12 входными нейронами, 5 скрытыми и 4 выходными нейронными элементами. В качестве функции активации для каждого элемента скрытого и выходного слоя использовалась сигмоидная функция. Число входных элементов соответствует размерности сжатых данных, а число выходных нейронов соответствует числу классов ТИА и нормальному состоянию. Количество элементов в скрытом слое определялось экспериментальным путем. Для обучения многослойного перцептрона использовался алгоритм обратного распространения ошибки. Выходными значениями многослойного перцептрона являются числа в диапазоне от 0 до 1, которые характеризуют *вероятность развития соответствующего класса ТИА*.

Результаты экспериментов. Рассмотрим отображение входного пространства образов на плоскость двух первых главных компонент. На рис. 4 графически представлена классификационная картина разделения клинических случаев по подтипам ТИА с применением нелинейной RNN. Из рисунка видно, что данные, принадлежащие разным типам атак, распределены по разным областям.

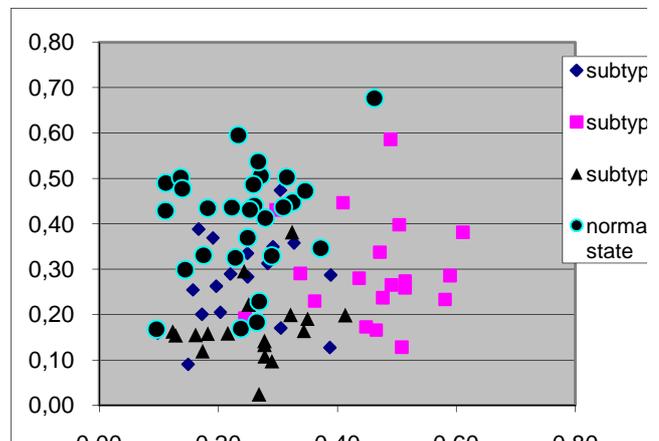


Рис. 4. Данные, обработанные нелинейной RNN

Отображение входного пространства образов для нормального состояния и транзиторных ишемических атак в трехмерном пространстве показано на рис. 5.

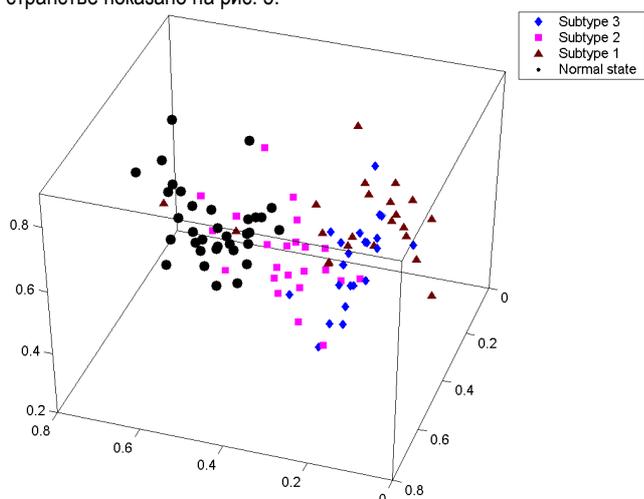


Рис. 5. Отображение входного пространства образов на 3 главные компоненты

Все пространство исходных образов было разделено на 2 группы: обучающую и тестовую выборки. Точность распознавания составляет до 100% на обучающей выборке и 78% на тестовых образах (таблица 2).

Таблица 2. Точность распознавания

Число образов в обучающей выборке	Число образов в тестовой выборке	Точность распознавания на обучающей выборке	Точность распознавания на тестовой выборке
90	24	100%	78%

Распределение вероятностей в зависимости от типа атаки для 10 пациентов, которые не входили в обучающую выборку, представлено в таблице 3.

Таблица 3. Распределение вероятностей

Пациент	ТИА 1	ТИА 2	ТИА 3	Норма
1	18.1%	0.1%	13.6%	68.2%
2	6.4%	0%	93.6%	0%
3	5.1%	12.1%	64.5%	18.3%
4	3.6%	72.6%	23.8%	0%
5	1.1%	96.0%	2.8%	0.1%
6	94.4%	0.6%	4.2%	0.8%
7	9.6%	16.8%	0.1%	73.4%
8	15.2%	1.6%	1.5%	81.7%
9	20.8%	10.0%	0%	69.2%
10	8.7%	0.4%	24.1%	66.7%

Для оценки качества распознавания ТИА воспользуемся следующими характеристиками:

- FP (false positives) – количество образов с нормальным состоянием, классифицированных как ТИА. Они характеризуют ложные срабатывания;

- FN (false negatives) – количество образов с ТИА, классифицированных как нормальные. Они характеризуют необнаружение эпилептической активности (ложный пропуск);
- TP (true positives) – количество правильно классифицированных образов с ТИА;
- TN (true negatives) – количество правильно классифицированных нормальных образов.

Тогда чувствительность, которая характеризует вероятность правильной классификации образов с ТИА

$$TPR = Se = \frac{TP}{TP + FN} = \frac{TP}{P} \quad (17)$$

Специфичность (мощность критерия) – вероятность правильной классификации нормальных (без ТИА) образов:

$$Sp = \frac{TN}{TN + FP} \quad (18)$$

Точность классификации, характеризующая качество работы системы в целом:

$$ACC = \frac{TP + TN}{TP + TN + FP + FN} = \frac{TP + TN}{P + N} \quad (19)$$

Значения статистических параметров, которые характеризуют качество классификации, рассчитанные на результатах распознавания не входивших в обучающую выборку образов, показаны в таблице 4.

Таблица 4. Значения статистических параметров

Статистические параметры	Значения
Специфичность	89%
Чувствительность	73%

Значительное расхождение точности распознавания на двух выборках (обучающей и тестовой) получается из-за того, что объем обучающей выборки является недостаточным для качественного обучения нейросетевой системы. Поэтому возникает дилемма, как при малом объеме обучающей выборки обучить нейросетевую систему качественной классификации транзиторных ишемических атак. Для этого необходимо искусственно генерировать новые образы в обучающую выборку для увеличения ее размерности. Предлагается следующий алгоритм для увеличения размерности обучающей выборки:

- рециркуляционная нейронная сеть обучается на исходных образах;
- в наименее информативную составляющую полученного в скрытом слое сжатого вектора (12-я компонента) вносится случайная погрешность в пределах 30%;
- после внесения погрешности производится восстановление соответствующих образов;
- новые образы сопоставляются с одним из классов ТИА при помощи обученного на исходных данных многослойного перцептрона. При этом сгенерированные образы, которые не имеют четкой принадлежности к какому-либо классу, удаляются. Затем сгенерированные образы помещаются в обучающую выборку, а исходные данные – в тестовую.

Нейронные сети обучаются на сгенерированных образах и проверяются на исходном множестве (тестовом).

Схематично данная процедура изображена на рис. 6.

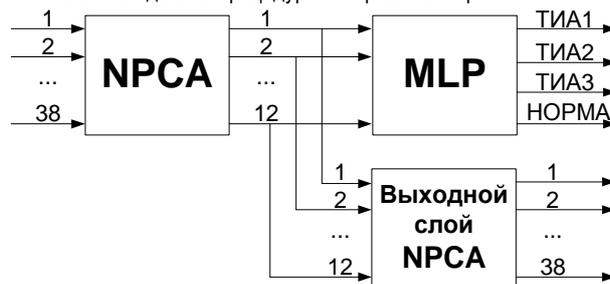


Рис. 6. Генерация новых образов

Таблица 5. Примеры исходных и восстановленных образов

Параметр	Пациент 1		Пациент 2		Пациент 3	
	Исходные данные	Восстановленные данные	Исходные данные	Восстановленные данные	Исходные данные	Восстановленные данные
Возраст	3	3	3	2	5	5
Пол	2	2	2	2	2	1
Место жительства	2	1	2	1	4	4
Образование	1	1	2	2	3	3
Профессия	1	1	3	2	3	2
Конфликты по работе и с администрацией	2	2	2	2	2	2
Смена места жительства за послед. 10 лет	1	2	1	1	1	1
Смена профессии за последние 10 лет	1	2	7	7	8	8
Особенности ночного сна	2	2	2	1	3	3
Бессонница	2	2	2	2	3	2
Наследствен. по патологии сосудов мозга	2	1	1	1	2	2
Наследственность по другим заболеваниям	1	1	3	2	1	2
Артериальная гипертензия	1	2	1	1	2	2
Диастолическое давление	1	1	1	2	2	2
Аускультация сердца	1	1	3	3	2	1
Границы сердца	1	2	2	2	2	2
Изменения на ЭКГ	1	1	1	1	2	2
Боли в области сердца	1	1	3	2	2	1
Нарушения сердечного ритма	1	1	4	4	1	1
Хронический бронхит	2	2	2	2	2	2
Хронический гепатохолецистит	1	1	2	1	2	1
Хрон. гастрит, язв. болезнь желудка	1	2	2	2	1	1
Почечнокаменная болезнь	1	1	1	1	2	2
Остеохондроз шейный	1	1	2	2	2	2
Метеозависимость	2	2	5	4	1	1
Употребление алкоголя	1	1	2	2	1	1
Курение (количество)	1	1	1	1	1	2
Курение (возраст)	1	2	1	1	1	1
Работоспособность	2	2	3	3	3	2
Раздражительность повышенная	2	1	3	1	2	2
Снижение памяти (степень)	1	1	3	1	2	2
Снижение памяти (время появления)	1	1	3	3	2	2
Снижение остроты зрения (степень)	1	1	2	2	2	2
Снижение остроты зрения (время появления)	1	1	2	1	3	2
Зрительные нарушения	1	1	2	2	1	1
Головные боли	2	3	4	4	2	2
Головные боли (время появления)	2	2	2	2	2	1
Головокружение	1	1	2	1	2	2

При помощи данной процедуры было сгенерировано 1000 новых образов, которые относятся к различным типам ТИА. Примеры исходных и восстановленных образов представлены в таблице 5. Результаты тестирования системы с использованием сгенерированных образов представлены в таблице 6.

Таблица 6. Результаты распознавания с использованием сгенерированных образов

Число образов в обучающей выборке	Число образов в тестовой выборке	Точность распознавания на обучающей выборке	Точность распознавания на тестовой выборке
1000	114	98%	92,2%

Как следует из таблицы, точность распознавания транзиторных ишемических атак значительно возросла.

Значения чувствительности и специфичности для случая со сгенерированными данными приведены в таблице 7.

Таблица 7. Значения статистических параметров

Статистические параметры	Значения
Специфичность	90%
Чувствительность	97,1%

Модель с высокой чувствительностью часто дает истинный результат при наличии ТИА (корректно обнаруживает заболевание). Наоборот, модель с высокой специфичностью чаще дает истинный результат при отсутствии ТИА (корректно обнаруживает отсутствие заболевания). Если рассуждать в терминах медицины – задачи диагностики заболевания, где модель классификации пациентов на больных и здоровых называется диагностическим тестом, то получится следующее. Чувствительный диагностический тест проявляется в гипердиагностике – максимальном предотвращении пропуска больных. Специфичный диагностический тест диагностирует только доподлинно больных. Это важно в случае, когда, например, лечение больного связано с серьезными побочными эффектами и гипердиагностика пациентов является нежелательной.

Рассмотрим анализ двух вариантов обнаружения ТИА при помощи ROC-кривой. ROC-кривая получается следующим образом. Для каждого значения порога отсека, которое меняется от 0 до 1 с шагом dx (например, 0,01), рассчитываются значения чувствительности Se и специфичности Sp . В качестве альтернативы порогом может являться каждое последующее значение примера в выборке. Затем строится график зависимости, где по оси Y откладывается чувствительность Se , а по оси X – ошибка 2-го рода, которая является величиной противоположной специфичности и характеризует вероятность неправильной классификации нормальных образов (вероятность ложных срабатываний):

ROC-кривые для обоих случаев представлены на рис. 7.

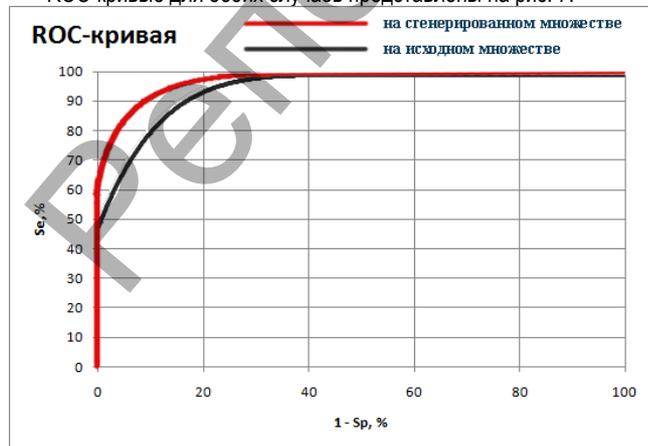


Рис. 7. ROC-кривые на сгенерированном и исходном множествах

Для идеального классификатора график ROC-кривой проходит через верхний левый угол, где точность правильной классификации ТИА составляет 100% (идеальная чувствительность), а ошибка 2-го рода равна нулю. Поэтому чем ближе кривая к верхнему левому углу, тем выше предсказательная способность модели. Наоборот, чем меньше изгиб кривой и чем ближе она расположена к диагональной прямой, тем менее эффективна модель. Диагональная линия соответствует "бесполезному" классификатору, т.е. полной неразличимости двух классов.

При визуальной оценке ROC-кривых расположение их относительно друг друга указывает на их сравнительную эффективность. Кривая, расположенная выше и левее, свидетельствует о большей предсказательной способности модели. Так, на рис. 7 две ROC-кривые совмещены на одном графике. Видно, что модель "на сгенерированном множестве" обладает большей предсказательной способностью.

Заключение. В работе рассмотрен подход к построению системы классификации подтипов транзиторных ишемических атак, который базируется на нейросетевых технологиях. В основу положена идея представления входного пространства образов в виде главных компонент, для повышения качества обработки и скорости функционирования программы. Был предложен подход, основанный на интеграции нелинейной РНС и многослойного перцептрона. В целом результаты показали, что возможности и потенциал систем, основанных на связке рециркуляционной сети и многослойного перцептрона, достаточно велики. Поэтому, продолжая работу в этом направлении, можно ожидать улучшения основных показателей функционирования систем такого типа.

Главное преимущество использования нейросетевого подхода заключается в возможности распознавать новые ТИА, неиспользуемые в обучающей выборке, а также скорость работы.

Наиболее трудные моменты, которые выявились в ходе решения поставленной задачи:

- нечеткость входных множеств, т.е. отсутствие выраженных границ между рассматриваемыми классами атак;
- ограниченность исходных данных. С накоплением данных о новых пациентах, вероятно, процент правильного распознавания будет расти.

В любом случае цель разработанной системы диагностики – это предварительный анализ состояния пациента, базирующийся на легкодоступных анамнестических данных, получение которых не требует дорогих и времязатратных исследований. Система позволяет определить наиболее вероятный вектор развития патологии в кратчайшие сроки, что очень важно для выбранных заболеваний. Таким образом, предварительные исследования дают возможность доктору понять симптоматику пациента уже при первом обследовании, уменьшая таким образом временной интервал между началом обследования пациента и назначением лечебно-профилактических действий. Это и есть клинический смысл предварительной дифференциальной диагностики, нацеленной на предотвращение возникновения эпизода ТИА с акцентом на определении наиболее вероятного вектора развития патологического процесса.

СПИСОК ЦИТИРОВАННЫХ ИСТОЧНИКОВ

1. Paulo, J. Lisboa The use of artificial neural networks in decision support in cancer / J. Lisboa Paulo, Azzam Taktak // A systematic review, Neural networks 19. – 2006. – P. 408–415.
2. McNeill, A. How Accurate Are Primary Care Referral Letters For Presumed Acute Stroke? // Scottish Medical Journal. – V. 53. – № 4. – 2008. – P. 11–12.
3. Easton, J. Definition and evaluation of transient ischemic attack. Stroke // Journal of the American Heart associations, 2009.
4. Dawson, J. A recognition tool for transient ischemic attack. – 2009. – P. 43–49.
5. Lisboa, P. A review of evidence of health benefit from artificial neural networks in medical intervention // Neural networks 15. – 2002. – P. 11–39.

6. Barnes, R. Neural networks for ischemic stroke / R. Barnes, J. Toole, J. Nelson, V. Howard // Journal of stroke and cerebrovascular diseases. – Vol. 15. – No. 5. – 2006. – P. 223–227.
7. Shanthi, D. Input feature selection using hybrid neuro-genetic approach in the diagnosis of stroke disease / D. Shanthi, Dr.G. Sahoo, Dr.N. Saravanan // IJCSNS International Journal of Computer Science and Network Security. – Vol. 8. – No. 12. – 2008. – P. 99–107.
8. Shanthi, D. Designing an artificial neural network model for the prediction of thrombo-embolic stroke / D. Shanthi, Dr.G. Sahoo, Dr.N. Saravanan. // International journal of biometric and bioinformatics. – Vol. 8. – No.1. – 2008. – P. 10–18.
9. McNeill, A. How Accurate Are Primary Care Referral Letters For Presumed Acute Stroke? // Scottish Medical Journal. – V. 53. – № 4. – 2008. – P. 11–12.
10. Мастыкин, А.С. Нейросетевой подход к решению проблемы предотвращения атак на нормальное кровоснабжение мозга // А.С. Мастыкин, В.В. Евстигнеев, В.А. Головкин, Е.Н. Апанель, Г.Ю. Войцехович // Доклады Академии наук Беларуси. – 2010. – Т.54 – № 5. – С. 81–90.

Материал поступил в редакцию 30.01.12

GOLOVKO V.A., VAITSEKHOVICH H.U., MASTYKIN A.S., APANEL E.N. Neural networks for diagnostics transient ischemic attack

In this paper the neural network model for transient ischemic attacks recognition have been addressed. The proposed approach is based on integration of the NPCA neural network and multilayer perceptron. The dataset from clinic have been used for experiments performing. Combining two different neural networks (NPCA and MLP) it is possible to produce efficient performance in terms of detection and recognition transient ischemic attacks. The main advantages of using neural network techniques are the ability to recognize "novel" TIA attack instances, quickness and ability to assist the doctor in making decision.

УДК 004.89

Гречка А.В., Головкин В.А.

ИНТЕЛЛЕКТУАЛЬНАЯ СИСТЕМА ФОРМИРОВАНИЯ РАСПИСАНИЯ РАБОЧИХ СМЕН ДЛЯ ОПЕРАТОРОВ ЦЕНТРА ОБСЛУЖИВАНИЯ ВЫЗОВОВ

Введение. Основной задачей теории расписаний (ТР) является разработка методов синтеза расписаний работы обслуживающих систем. Одно из наиболее актуальных применений теории расписаний – календарное планирование и регулирование производственных процессов.

Теория расписаний довольно специфична и имеет ряд особенностей, в отличие от других наук, занимающихся сходными проблемами. Во-первых, для неё характерно огромное разнообразие теоретических моделей, вытекающее из разнообразия реальных моделируемых процессов, так как проблема оптимальной организации протекающих во времени процессов имеет глобальный характер и возникает практически во всех сферах человеческой деятельности. Второй особенностью является комбинаторная природа исследуемых моделей и решаемых оптимизационных задач, которая обуславливает высокую комбинаторную сложность их решения. И, в-третьих, для теории расписаний характерна высокая актуальность решаемых задач, ввиду их ярко выраженной прикладной направленности.

При всём этом теория расписаний занимается вполне теоретическими проблемами, разработкой наиболее общих и универсальных методов решения возникающих в ней оптимизационных задач.

В большинстве ситуаций оптимальное расписание может быть найдено в результате перебора конечного множества возможных вариантов. Основное затруднение состоит в том, что число таких вариантов обычно оказывается исключительно большим и растёт, по меньшей мере, экспоненциально с ростом размерности задачи. Среди задач теории расписаний можно выделить полиномиально разрешимые и NP-сложные. Для каждой полиномиально разрешимой задачи известен по крайней мере один эффективный алгоритм ее решения, трудоёмкость которого ограничена сверху некоторым полиномом от длины записи исходной информации задачи. Для NP-сложных задач такие алгоритмы неизвестны и, по всей видимости, не существуют [4].

Алгоритмы построения расписаний без проведения полного или частичного перебора вариантов являются решающими эвристическими правилами и играют важную роль в прикладной теории расписаний. Однако эвристические алгоритмы основаны на приеме, который называется «снижением требований». Он заключается в отказе от поиска оптимального решения и нахождения вместо этого «хорошего решения» за приемлемое время. Методы, применяемые для построения алгоритмов такого типа, сильно зависят от специфики задачи [3]. Универсального алгоритма не существует.

Использование только математических методов теории

расписаний в большинстве случаев неприменимы для прикладных задач, так как имеют ряд недостатков: такие модели не позволяют учитывать многие факторы, влияющие на ход производства, которые для разных предприятий могут быть индивидуальны; использование только математических методов ограничивается невозможностью быстрого реагирования на возникающие ситуации, требующие немедленной корректировки планов и т.д. [2].

Для исключения недостатков подобных разработок возможно использовать эволюционные методы, которые позволили бы получать оптимальные решения проблем реальных производственных ситуаций за малое время. При решении такие методы рассматривают систему планирования как чёрный ящик, когда на входе задаются различные значения параметров планирования, после чего оценивается эффективность получаемых расписаний с точки зрения ключевых показателей эффективности. На основе анализа существующих разработок в области эволюционных методов перспективным решением сложных комбинаторных задач оптимизации является гибридное использование генетического и муравьиного алгоритмов. Это позволит существенно улучшить систему оперативного планирования, тем самым сократив время получения оптимальных или приемлемых производственных расписаний [2].

Описание работы. Основная идея работы – создание интеллектуальной системы формирования расписания рабочих смен для операторов центра обслуживания вызовов (ЦОВ). При составлении расписания необходимо решить 2 проблемы: с одной стороны, оптимизировать работу ЦОВа как системы массового обслуживания, с другой стороны расписание рабочих смен как минимум должно удовлетворять нормам трудового законодательства, кроме того, необходимо учесть ряд субъективных факторов, которые определяют «хорошее» для операторов расписание.

Данная система состоит из 3-х подсистем, поэтапно решающих последовательность задач:

1. Прогноз нагрузки на ЦОВ: определяем предполагаемое количество вызовов в каждые полчаса указанного месяца.
2. Формирование карты смен: упорядочиваем во времени определенное количество смен таким образом, чтобы наиболее оптимально покрыть предполагаемую нагрузку.
3. Составление расписания: назначаем операторов (телефонистов) на смены так, чтобы минимизировать сумму и дисперсию численно выраженных нежелательных факторов (для телефонистов) расписания.

Гречка А.В., магистрант кафедры интеллектуальных информационных технологий Брестского государственного технического университета.

Беларусь, БрГТУ, 224017, г. Брест, ул. Московская, 267.

Физика, математика, информатика