

Анализ *табл. 1* показывает, что результаты испытаний на контрольных выборках в рамках допустимой погрешности (около 3 %) практически совпадают с результатами экспертного оценивания, что позволяет сделать выводы о целесообразности использования полученных прогностических и диагностических правил для решения задач рационального управления лечебно-профилактическими мероприятиями при предупреждении и лечении тромбозов центральной вены сетчатки глаза и ее ветвей.

Заключение

Для прогнозирования и дифференциальной диагностики заболеваний сосудов глазного дна предложено использовать нейронные сети с макрослоями, использующие для диагностических заключений K групп информативных признаков и включающие в себя $K + 1$ макрослой, отличающиеся тем, что в каждом макрослое содержится столько нейронных сетей, сколько классов заболеваний выделяет нейронная сеть с макрослоями, а число нейронов в первом слое каждой нейронной сети K первых макрослоев определяется размерностью признакового пространства, закрепленного за данным макрослоем, в то время как число нейронов в нейронных сетях последнего макрослоя определяется числом групп информативных признаков, используемых для диагностики сосудистых патологий глазного дна.

Для того чтобы настроить нейронную сеть для прогнозирования и диагностики тромбоза вен сосудов сетчатки глаза и ее ветвей, необходимо провести дополнительный разведочный анализ в выделенных группах информативных признаков и получить нелинейные отображения для первого скрытого слоя нейронных сетей.

Проведены испытания разработанной автоматизированной системы на примере прогнозирования и дифференциальной диагностики степени тяжести тромбоза вен сосудов сетчатки глаза и ее ветвей. Исследования, проведенные на репрезентативных контрольных выборках, показали, что предлагаемые

правила прогноза и дифференциальной диагностики степени тяжести тромбозов центральной вены сетчатки глаза и ее ветвей обеспечивают уверенность в правильном принятии решений на уровне 0,9.

Исследования выполнены при поддержке федеральной целевой программы «Научные и научно-педагогические кадры инновационной России» на 2009-2013 гг., проект «Гибридные технологии анализа и классификации сложноструктурируемых изображений для медицинских приложений».

Список литературы:

1. Кацнельсон Л.А., Бунин А.Я., Форофонова Т.И. Сосудистые заболевания глаз. – М.: Медицина, 1990. 268 с.
2. Томакова Р.А., Филлист С.А., Брежнева А.Н. Спектральный анализ сегментов изображения глазного дна для количественной оценки сосудистой патологии // Биомедицинская радиоэлектроника. 2009. № 6. С. 15-18.

*Николай Алексеевич Корневский,
д-р техн. наук, профессор,
зав. кафедрой,
Римма Александровна Томакова,
канд. техн. наук, доцент,
Станислав Петрович Серегин,
д-р мед. наук, профессор,
кафедра биомедицинской инженерии,
Анатолий Федорович Рыбочкин,
д-р техн. наук, профессор,
кафедра конструирования и технологии
электронно-вычислительных средств,
ФГБОУ ВПО «Юго-Западный
государственный университет»,
г. Курск,
e-mail: kstu-bmi@yandex.ru*

А.А. Бурмака, И.И. Волков, В.А. Иванов, В.И. Серебровский

Вероятностные нейронные сети с макрослоями в системах поддержки принятия решений по дифференциальной диагностике сердечно-сосудистых заболеваний

Аннотация

Для повышения качества прогнозирования и диагностики ряда распространенных сердечно-сосудистых заболеваний предлагается использовать вероятностную нейронную сеть с макрослоями. В нейронной сети используются два макрослоя. В основе первого макрослоя лежит стандартная вероятностная сеть, построенная на байесовском формализме. Второй макрослой построен на основе нечеткой логики принятия решений и осуществляет классификацию по двум классам.

Сеть применяется для дифференциальной диагностики сердечно-сосудистых заболеваний. Оценка субъективных вероятностей альтернативных гипотез выражается либо в баллах, либо в процентах. При этом эксперт имеет возможность оценить вероятность нулевой гипотезы на фоне известных апостериорных вероятностей альтернативных гипотез.

В процессе дифференциальной диагностики сердечно-сосудистых заболеваний (ССЗ) возникает необходимость в оценке вероятностей альтернативных гипотез, которая выражается либо в баллах, либо в процентах. При этом эксперт имеет возможность оценить вероятность нулевой гипотезы на фоне известных апостериорных вероятностей альтернативных гипотез. Сравнение таких вероятностей дает ценную информацию при управлении как профилактическими мероприятиями, так и диагностическими исследованиями.

Например, сочетанное поражение артерий в различных бассейнах кровообращения обладает взаимоотношающим влиянием. Артериальная гипертензия оказывает значимое влияние на прогрессирование атеросклероза, развитие хронических нарушений мозгового кровообращения, ишемическую болезнь сердца. Таким образом, информация, в том числе и нечеткая, о наличии или отсутствии той или иной патологии

может быть использована лицом, принимающим решение (ЛПР), в качестве маркера при диагностике одного или нескольких заболеваний.

Структура принятия решения при выбранной схеме диагностики представлена на *рис. 1*. Она включает в себя совокупность независимых модулей классификации, которые анализируют одни и те же признаки, но заключения дают только по одному, специфичному для каждого модуля заболеванию. В качестве дополнительных признаков каждый модуль классификации использует заключения других модулей.

Достоинство такой структуры состоит в том, что она оказывается работоспособна при неработоспособности одного или нескольких модулей классификации, применяемых ЛПР при принятии решения. При этом ЛПР использует ту базу решающих правил, которая соответствует располагаемой им информации, т. е. фактическим пространством информативных при-

знаков и наличием работоспособных модулей.

Для реализации предложенной структуры целесообразно использовать вероятностные нейронные сети (PNN) с макро-слоями. В основе классификации в сети PNN лежит метод Байеса. Идея состоит в том, что для каждого образца можно принять решение на основе выбора наиболее вероятного класса из тех, которым мог бы принадлежать этот образец. Такое решение требует оценки функции плотности вероятностей для каждого класса. Эта оценка получается в результате обучения сети. Формальным правилом является то, что класс с наиболее плотным распределением в области неизвестного экземпляра будет иметь преимущество по сравнению с другими классами. Точно так же будет иметь преимущество и класс с высокой априорной вероятностью или высокой ценой ошибки классификации. Для двух классов А и В в соответствии с данным правилом выбирается класс А, если

$$h_A \cdot c_A \cdot f_A(x) > h_B \cdot c_B \cdot f_B(x), \quad (1)$$

где h – априорная вероятность; c – цена ошибки классификации; $f(x)$ – функция плотности вероятностей. Оценка стоимости ошибки классификации требует хорошего знания приложения, но во многих приложениях цена ошибки классификации и априорные вероятности выбираются одинаковыми для всех классов. Игнорирование цены ошибки и априорных вероятностей все же не избавляет от необходимости оценки функции плотности распределения вероятностей. Оценить эту функцию можно с помощью метода Парцена, в котором используется весовая функция, имеющая центр в точке, представляющей учебный образец. Такая весовая функция называется *функцией потенциала*, или *ядром*. Чаще всего в качестве ядра используется *функция Гаусса*.

В качестве архитектуры нейронной сети, выполняющей поставленную задачу, выбираем нейронную сеть блочного типа. Характерной особенностью такой сети является то, что каждый решающий модуль сети осуществляет классификацию с разделением на два класса: объект принадлежит к классу ω_i или объект не принадлежит к классу ω_i . Таким образом, в сети будем иметь столько решающих модулей, сколько классов предполагается выделить в исходных данных.

Структурная схема вероятностной нейронной сети, реализующая схему принятия решений (рис. 1), приведена на рис. 2. Кроме макрослоя PNN, сеть имеет макрослой FNN, работа которого основана на нечеткой логике принятия решений. В итоге каждый модуль классификации содержит последовательно соединенные блок PNN и блок FNN, на выходе которого выдается вероятность, по существу субъективная, принадлежности входного вектора к данному классу. Окончательное решение принимает ЛПР на основе анализа вероятностей, поступающих с выходов блоков FNN.

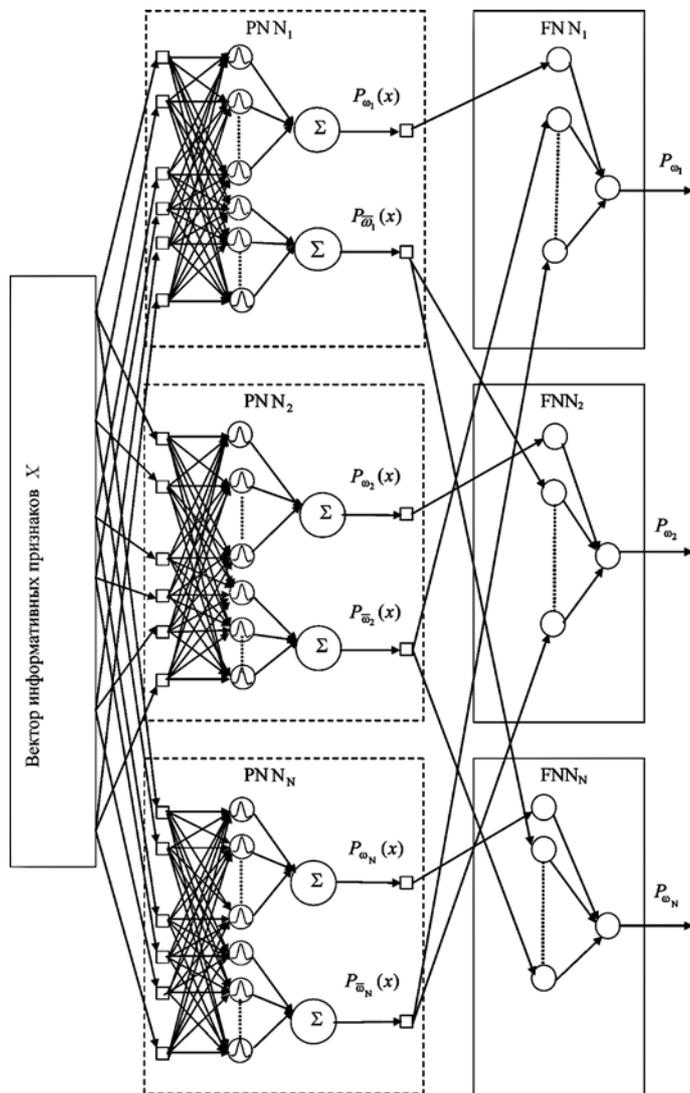


Рис. 2. Структурная схема вероятностной нейронной сети с макро-слоями

Слой суммирования в каждом модуле макрослоя PNN имеет два элемента – для класса ω_i и для класса $\bar{\omega}_i$. К любому элементу слоя суммирования идут связи только от элементов слоя образцов, принадлежащих соответствующему классу. Весовые значения связей, идущих от элементов слоя образцов к элемен-

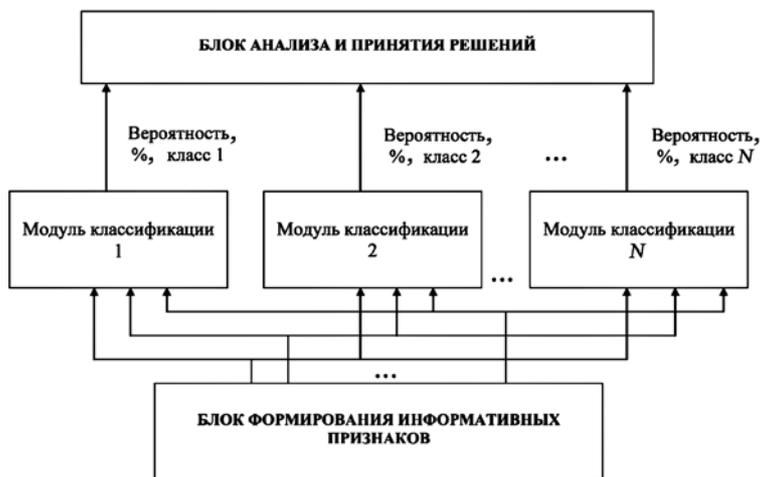


Рис. 1. Структура принятия решения в вероятностной нейронной сети с макро-слоями

там слоя суммирования, фиксируются равными 1. Элемент слоя суммирования просто суммирует выходные значения элементов слоя образцов. Эта сумма дает оценку значения функции плотности распределения вероятностей для совокупности экземпляров соответствующего класса.

В данном случае каждый входной набор данных имеет шесть признаков. Слой образцов имеет по одному элементу для каждого образца из обучающей выборки. Входной слой и слой образцов образуют полносвязную структуру в каждом модуле классификации PNN. Для входящих в элемент слоя образцов связей весовые значения устанавливаются равными элементам соответствующего вектора-образца. Выходы нейронов выходного слоя i -го блока макрослоя PNN для сети с шестьюкомпонентным вектором информативных признаков, структурная схема которой представлена на рис. 2, определяются как

$$P_{\omega_i} = \sum_{k=1}^{K_{\omega_i}} \exp \left\{ \frac{-\sum_{j=0}^5 (w_{\omega_i}^{jk} - x_j)^2}{\sigma_{\omega_i}^2} \right\} \quad (2)$$

$$P_{\bar{\omega}_i} = \sum_{k=1}^{K_{\bar{\omega}_i}} \exp \left\{ \frac{-\sum_{j=0}^5 (w_{\bar{\omega}_i}^{jk} - x_j)^2}{\sigma_{\bar{\omega}_i}^2} \right\} \quad (3)$$

где x_j – компоненты вектора неизвестного входного образца. В этом выражении используется квадрат евклидова расстояния от неизвестного экземпляра до элемента слоя образцов; значение σ задает ширину функции активности и оказывается очень важным, поэтому чаще всего оно подбирается в результате эксперимента.

В обучающей выборке содержится K элементов из N классов, для любого класса i справедливо равенство

$$K_{\omega_i} + K_{\bar{\omega}_i} = K. \quad (4)$$

Для сети PNN не требуется такого обучения, какое требуется для сетей с обратным распространением ошибок, так как все параметры сети PNN (число элементов и значения весов) определяются непосредственно обучающей выборкой.

Архитектура сети определяется структурой обучающей выборки:

- число входных элементов равно числу признаков (на рис. 2 их шесть);
- число элементов слоя образцов в каждом модуле классификации равно числу элементов в обучающей выборке K ;
- число элементов слоя суммирования в макрослое PNN равно удвоенному числу дифференцируемых классов $2N$.

После того как сеть построена, неизвестный экземпляр можно подать на вход сети и в результате прямого прохода через сеть на выходах модулей классификации появятся вероятности, соответствующие каждой дифференцируемой патологии.

На двух выходах каждого блока PNN _{i} макрослоя PNN присутствуют вероятность P_{ω_i} патологии ω_i и вероятность $P_{\bar{\omega}_i}$ патологии $\bar{\omega}_i$. При этом в общем случае $P_{\omega_i} + P_{\bar{\omega}_i} \neq 1$. Эти вероятности определяются соотношением и расположением в пространстве информативных признаков векторов обучающей выборки, а также выбранной шириной функций активации в уравнениях (2) и (3).

Окончательная субъективная вероятность дифференцируемой патологии определяется в блоке FNN, который является моделью экспертной оценки результатов, получаемых в макрослое PNN. Каждый модуль макрослоя FNN состоит из двух слоев. Первый слой имеет два нейрона, в первом из которых осуществляется вычисление субъективной вероятности наличия патологии ω_i , а во втором – субъективной вероятности отсутствия патологии $\bar{\omega}_i$. Каждый из нейронов первого слоя каждого модуля макрослоя FNN имеет N входов. Схема со-

единения выходов макрослоя PNN и входов макрослоя FNN построена таким образом, чтобы нечеткая операция, которая в них осуществляется, была аналогична операции сложения вероятностей или алгебраического сложения. Выполнение этого требования достигается тем, что на нейроны первого слоя модулей макрослоя FNN поступают свидетельства, подтверждающие одно и то же событие. Это значит, что на первый нейрон должна поступать информация, подтверждающая наличие патологии ω_i , а на второй нейрон – подтверждающая наличие патологии $\bar{\omega}_i$.

Второй слой модуля классификации макрослоя FNN содержит всего лишь один нейрон, который выполняет роль, аналогичную роль дефuzziфикатора в системе нечеткого логического вывода. Нечеткие операции, выполняемые в узлах FNN, при отсутствии или недостатке экспертных данных могут быть определены на основе методики, основанной на использовании генетических алгоритмов и описанной в [2].

Заключение

Предложенная вероятностная нейронная сеть с макрослоями была реализована в среде MATLAB и апробирована на скрининговых исследованиях сердечно-сосудистого риска. В исследование были включены находящиеся на лечении мужчины и женщины всех возрастов с относительно стабильным (вне обострения) состоянием здоровья и с установленным диагнозом основного заболевания на основании результатов стационарного обследования до периода проведения апробации технологии. В исследование не включали пациентов с неустановленным заболеванием и в состоянии обострения (нестабильности) заболевания.

Сравнение качества прогнозирования по показателю диагностической эффективности предложенной нечеткой нейросетевой модели и шкалы SCORE показали, что на одних и тех же контрольных выборках по классам атеросклероз, ишемическая болезнь сердца и инфаркт показатели диагностической эффективности предложенной модели в среднем на 5...10 % выше. Анализ полученных результатов показал, что статистические испытания на контрольных выборках позволяют рекомендовать полученные решающие правила и алгоритмы для практического использования.

Список литературы:

1. Терзиян В.Я., Витько А.В. Вероятностные метасети для решения задач интеллектуального анализа данных // Искусственный интеллект. 2002. № 3. С. 188-197.
2. Корневский Н.А., Филлист С.А., Черных Е.С. Автоматизированная система диагностики анемий на основе нечеткой логики принятия решений и алгоритмов генетического типа // Вестник новых медицинских технологий. 2006. Том XIII. № 2. С. 24-28.

*Александр Александрович Бурмака,
д-р техн. наук, профессор,
Иван Иванович Волков,
аспирант,*

*кафедра биомедицинской инженерии,
ФГБОУ ВПО «Юго-Западный
государственный университет»,*

*Виктор Афанасьевич Иванов,
д-р мед. наук, профессор,
зав. кафедрой медицины и логопедии,
Курский государственный университет,
Владимир Исаевич Серебровский,*

*д-р техн. наук, профессор,
проректор по учебной работе,
ФГБОУ ВПО «Курская государственная
сельскохозяйственная академия им. проф. И.И. Иванова»,
г. Курск
e-mail: kstu-bmi@yandex.ru*