

УДК 57.007; 004.8.032.26

*С.П. Алёшин*

Полтавский национальный технический университет имени Ю. Кондратюка,  
г. Полтава, Украина  
aleshsp@ukr.net

## Нейросетевое распознавание классов в пространстве физиологических признаков биосенсоров

Работа посвящена проблеме биосенсорного распознавания в пространстве физиологических (зрительных, слуховых, обонятельных и др.) признаков. Предложена методика комбинированного использования биосенсорных способностей живых существ, их ситуативной физиологической реакции на раздражители и обучения искусственных нейронных сетей для распознавания классов. В основе подхода лежит идея совместного обучения живых существ и искусственных нейронных сетей. Это позволяет трансформировать сложные рецепторные признаки биодетекторов в пространство простых поведенческих реакций. Приведен алгоритм построения моделей распознавания объектов в нейронной среде эмуляторов формата Statistika Neural Network.

### Введение

Природа наделила некоторые живые существа уникальными способностями, которых нет у человека, но которые хотелось бы человеку иметь. Например, обоняние собаки превосходит человека по чувствительности на семь порядков. Так, обученная собака улавливает запах объекта, если тот создает концентрацию порядка 700 молекул на один кубический сантиметр. Человек же реагирует на концентрацию не ниже 7 000 000 000 молекул на кубический сантиметр [1]. Речной рак очень чувствителен к уровню загрязненности воды и реагирует на это степенью собственной тахикардии [2]. Летучая мышь в абсолютной темноте летает и не сталкивается с препятствиями. Анчоус мигрирует в Мировом океане на тысячи километров, но всегда безошибочно возвращается на нерест в один и тот же район. Подобные примеры можно продолжить.

Иногда возникает практическая необходимость использовать некоторые из этих способностей для решения важных задач. Хотя сегодня и существуют технические средства, способные классифицировать запахи [3], [4], видеть в темноте, определять загрязненность воды, тем не менее, например, служебные собаки используются для распознавания по запаху различных опасных объектов [5]. Ведь стоимость такого устройства, как «Электронный нос» [4], значительно больше, чем стоимость содержания и обучения служебной собаки. Поэтому превзойти некоторые полезные способности живых существ малыми финансовыми или материальными затратами не всегда удается. Часто значительно дешевле использовать живые существа как биодатчики (БД) (или биосенсоры, биодетекторы), а по их поведению или физиологическим признакам принимать соответствующие решения.

При этом возникает проблема автоматической трансформации признакового пространства БД в пространство признаков принятия решения человеком или машиной. Ведь нам неизвестен словарь признаков и механизм принятия решения БД, например, речного рака, когда он классифицирует загрязненность воды. Однако очевидна связь качества воды и физиологической реакции рака (например, в виде тахикардии, что фикси-

руется на осциллограмме). Следовательно, повторяя опыт в различных средах, можно получить обучающую выборку для искусственной нейронной сети. Аналогично можно поступать при подготовке служебных собак, обучая их определенному поведению, одновременно отслеживая их реакцию, например, при помощи видеокамеры или иным способом [5]. И в этом случае есть возможность сформировать обучающую выборку данных для нейросети. Можно показать и ряд других похожих по сути примеров, которые отображают однотипные процедуры:

- рецепторное восприятие биосенсорами некоторого объекта за счет своих природных способностей;
- отображение этого восприятия на уровне некоторого рефлексивного образа;
- трансформация рефлексивного образа в набор физиологических или поведенческих признаков;
- многократное повторение первых трех процессов с целью нахождения устойчивых и похожих реакций.

Для построения автоматической системы принятия решений остается обучить искусственную нейронную сеть выбрать некоторое решающее правило и обеспечить требуемую надежность и точность принимаемых решений.

**Целью данной работы** является построение нейросетевой модели классификации объектов или их состояний по данным биосенсоров в пространстве вторичных (физиологических) признаков, инвариантной к физическим особенностям первичного (рецепторного) восприятия. В качестве инструмента моделирования выбран нейроэмулятор среды StatSoft в формате модуля Statistika Neural Network.

**Постановка задачи и методы исследования.** Пусть имеется некоторый объект, который воспринимается биосенсором в пространстве первичных признаков (рефлексов) и отображается в пространстве вторичных (физиологических) признаков. Биосенсор способен многократно повторять процессы восприятия и отображения одного пространства признаков в другое. Необходимо автоматизировать процедуру принятия решения о принадлежности исследуемого объекта к тому или иному классу с помощью обучаемой нейронной сети, путем построения модели СППР. При этом ошибки первого и второго рода (пропуск объекта и ложная тревога) должны быть не выше заданных.

## Формализация процедуры распознавания классов

С точки зрения формализации процесса распознавания объекта необходимо обеспечить отображение входного вектора данных сети на результат принятого решения с требуемой точностью, аппроксимирующее зависимость «рефлексы – поведение – вывод». В общем случае физиологические признаки и число классов объектов являются векторными величинами и связаны некоторой зависимостью:

$$|y^k| = F |x^m|, \quad (1)$$

где  $y$  – номер класса объекта;  $x$  – значение текущего признака;  $k$  – число классов;  $m$  – число признаков;  $F$  – функционал преобразования пространства рецепторных признаков в пространство рефлексов (физиологических, поведенческих признаков) и в пространство решений (состояний).

При таком подходе, принятых допущениях и условиях поиск отображения вида

$$F: X \rightarrow Y, X \subset \mathfrak{R}^m, Y \subset \mathfrak{R}^k$$

в нейросетевом формате сводится к модификации синаптического пространства нейро-

сети путем реализации итерационной процедуры в форме [7]:

$$w_{hq}^{(n)}(t) = w_q(t-1) + \Delta w_{hq}^{(n)}(t), \quad (2)$$

где  $w_q(t-1) = w_q(t) + \alpha \times \frac{\partial E(k)}{\partial w_q(t)}$ ;  $w$  – массив синаптических коэффициентов;  $q$  – номер

выхода нейрона в  $n$ -м слое;  $h$  – номер входа нейрона в  $n$ -м слое;  $n$  – номер слоя сети.

Для того чтобы допустимые ошибки были не выше заданных, воспользуемся правилом Байеса [6]. Будем считать, что алфавит классов описан, для каждого объекта  $b_j$  поставлено в соответствие множество признаков  $\{x_i\}_j$  и объект полностью ими определен. Анализ описания состояния объекта дает текущую информацию, на основании которой определяется апостериорная информация. Характер текущей и апостериорной информации определяется тем, какое решающее правило реализовано в классификаторе. Так как конечная цель заключается в построении модели с заданными точностными характеристиками, то целесообразно применить статистическое правило проверки гипотез для количественной оценки точности и реализовать его при построении нейросетевой модели. Воспользуемся правилом проверки гипотез для вычисления апостериорных вероятностей правильных решений [6], чтобы количественно измерить и обеспечить допустимые ошибки, что требуется по условию задачи:

$$h_{ij} = P(A_i \setminus x_j) = \frac{P(A_i)P(x_j \setminus A_i)}{\sum_{i=1}^M P(A_i)P(x_j \setminus A_i)}, i = 1, 2, \dots, M, \quad (3)$$

где  $A_i$  – класс объекта исследования,  $i = 1, 2, \dots, M$  ( $A_i$  – класс исследуемого объекта описан соответствующим набором признаков  $\{x_i\}$ );

$x_j$  – набор информативных признаков объекта исследования,  $j = 1, 2, \dots, N$ ;

$\{x_i\}_j$  – описание алфавита классов (для каждого объекта  $b_j$  поставлено в соответствие множество признаков  $\{x_i\}_j$  и объект полностью ими определен);

$\sum_{i=1}^M P(A_i)P(x_j \setminus A_i)$  – обобщенное распределение вероятностей значений признаков классов (состояний) исследуемого объекта.

Общую ошибку принятия решения о принадлежности класса определим по простому соотношению

$$\lambda_{ij} = 1 - h_{ij}, \quad (4)$$

где  $\lambda_{ij}$  – вероятность возникновения ошибки как решения отнесения  $j$ -го состояния объекта к  $i$ -му классу,  $i = 1, 2, \dots, M$ .

При определении ошибки классификации адекватного поведения биосенсора, результатом ошибочного решения считается событие, когда объект, принадлежащий к  $i$ -му классу, классифицируется как объект  $k$ -го класса. В нашем случае могут иметь место ошибки пропуска цели и ложной тревоги [6], что формально можно выразить в предельном случае суммарной вероятностью ошибок

$$U \text{ ош. общая} = U\{P(1, 0) + P(0, 1)\}, \quad (5)$$

где  $P(1, 0)$ ,  $P(0, 1)$  – совместные вероятности ошибок (перепутывание классов) класса ситуации (есть или нет искомый объект) и апостериорных вероятностей гипотез принад-

лежности ситуации к данному классу. Таким образом, обеспечение точности решения сводится к нахождению процедуры обеспечения заданного порогового значения  $U\{P(1, 0) + P(0, 1)\}$ . Так как законы распределения признаков и классов априори не известны, то целесообразно воспользоваться нейросетевыми методами классификации, которые инвариантны этим распределениям.

## Обоснование надежности нейросетевой классификации

Если проанализировать процессы модификации синаптического пространства нейросети согласно правилу (2) и поиск вероятностей гипотез принадлежности классов (3), то можно увидеть существенную внутреннюю общность процедур принятия решений по статистическому правилу перебора гипотез и модификации синаптического пространства искусственной нейронной сети. Действительно, функция правдоподобия  $P(x_j \setminus A_i)$  из выражения (3) представляет собой математический механизм сопоставления текущего набора признаков  $(x_j)$  с одним ( $i$ -м) состоянием объекта исследования. В нейронной сети одна эпоха обучения характеризуется подачей на вход сети всего набора признаков и заканчивается изменением и фиксацией всего имеющегося массива синаптических коэффициентов. Процедура обучения нейронной сети базируется на переборе всевозможных вариантов сочетаний весов синапсов, например, по алгоритму обратного распространения ошибки [7] в виде правила (3). А правило Байеса базируется на переборе всех гипотез принадлежности входных выборок разным классам. Ассоциативная память нейросети с каждой последующей эпохой отображает интегративное воздействие всей совокупности входных выборок [8]. В то же время в формуле (3) аналог ассоциативной памяти представляет обобщенное распределение вероятностей значений признаков принадлежности классам исследуемого объекта в виде  $\sum_{i=1}^M P(A_i)P(x_j \setminus A_i)$ . Другими словами, разовая модификация всех синапсов (одна эпоха обучения) в скрытых слоях сети под воздействием полной выборки в одном такте является своеобразной формой сопоставления текущего набора признаков (обучающей выборки) с некоторым состоянием весовых коэффициентов нейросети. Следовательно, логично предположить, что это своеобразный аналог функции правдоподобия  $P(x_j \setminus A_i)$  в нейросетевом формате. При этом для всех вариантов сопоставления наборов признаков возможным классам рассчитывается свое значение апостериорной вероятности. В нейронной сети также наблюдается процедура перебора всего множества реализаций признаков и сравнения их влияния на обобщенную целевую функцию путем фиксации ошибки обучения на контрольном и тестовом множествах.

На следующем этапе принятия решения по статистическому правилу (3) из всего массива найденных апостериорных вероятностей выбирается максимальное значение, которое подставляется в (4), минимизируя результирующую ошибку. Нейронная сеть в процессе обучения также отыскивает лучшее решение из всех возможных и работает по схожей аналогии со статистическим решающим правилом. Отличие состоит лишь в том, что если статистический алгоритм предполагает поиск максимума апостериорной вероятности в виде (3), то нейронная сеть в процессе обучения с учителем отыскивает минимум ошибки целевой функции в некотором метрическом формате, например, квадратичной формы вида

$$E(w) = \sum_{k=1}^P (d^k - y^k)^2,$$

где  $P$  – размерность вектора входных параметров;  $d^k$  – эталонный (желаемый) выход сети для  $k$ -го параметра;  $y^k$  – реальный выход сети для  $k$ -го параметра. С учетом выражения (4), есть все основания говорить об адекватности этих процедур поиска оптимального решения.

Следует также отметить, что важным условием общности статистического и нейросетевого подходов в оптимизации надежности принимаемых решений является то, что в том и другом случае необходимые данные для принятия решения извлекаются из множества прецедентов определенной размерности. Это позволяет сформировать достаточную статистику для статистического критерия или репрезентативную обучающую выборку для модификации синаптического пространства нейронной сети, что позволяет опираться на единую базу извлечения знаний – массив прецедентов. Проведенный анализ позволяет увидеть общность и единую логику минимизации ошибок с использованием статистического правила проверки гипотез принадлежности признаков классам и на основе обучения нейронной сети в пространстве синаптических весовых коэффициентов. Это позволяет сделать вывод о надежности решений на основе нейросетевых алгоритмов, которые в силу отмеченных особенностей не уступают традиционным методам математической статистики.

## Нейросетевая модель распознавания в среде StatSoft

Построим нейросетевую модель, которая по входному вектору заданной размерности определяла бы класс, к которому принадлежит исследуемый образ и давала бы оценку вероятности принятого решения. Другими словами, необходимо реализовать процедуру отнесения каждого предъявленного сети множества из словаря признаков (Var 1 – Var K) определенному классу из алфавита. Решим эту задачу в нейросреде StatSoft с помощью модуля Neural Networks [9]. Вызываем стартовую панель этого модуля командой Statistics из основного меню и во вкладке Quick данного диалогового окна в разделе Problem type выбираем задачу Classification. Командой Variables вызываем диалоговое окно Select input, output и записываем все переменные по списку (Var 1 – Var K). В рассматриваемой предметной области это множество примеров реакции живых существ на состояние исследуемого объекта. В разделе Select analysis выбираем опцию Intelligent Problem Solver, а в окне настройки этой процедуры на вкладке Quick в разделе Networks tested укажем количество тестируемых сетей. В диалоговом окне IPS Training In Progress по информации о времени исполнения алгоритма, значениям ошибок на обучающем, контрольном и тестовом множествах, путем сравнения их между собой, выберем сеть, анализируя строки информационного поля диалогового окна. В разделе Profile фиксируем топологию сети, предложенную встроенным конструктором сетей, а окна информационной панели отображают параметры производительности сети. Под производительностью в нашей задаче классификации следует понимать долю правильно классифицируемых наблюдений по отношению к общему числу наблюдений, что при достаточном объеме выборки приближает частоты наблюдений к вероятностям. В задачах классификации и предсказания нейроэмулятор Statistika Neural Network определяет вероятность принадлежности предъявленного образа к каждому из классов. Для практического применения часто используются значения производительности в диапазоне (0,9 – 0,97), что в данном контексте адекватно вероятности правильного решения.

Таким образом, сеть не только решает задачу распознавания классов, определяя номер класса, но и сопровождает каждое решение значением вероятности правильного

решения и вероятностями ошибочного решения на обучающем, контрольном и тестовом множествах примеров. Следовательно, обучение сети можно интерпретировать как оценки вероятности того, что объект принадлежит некоторому классу, что сеть фактически учится оценивать функцию плотности вероятности. При этом сеть по имеющимся данным самостоятельно назначает такие синаптические веса всем нейронам сети, при которых пространство признаков текущего состояния объекта совпадает с целевым или имеет допустимую по условию задачи ошибку несовпадения. В результате при нейросетевом моделировании принятия решений в задачах распознавания можно оценить вероятности классификации для каждого класса и выбрать наиболее приемлемый.

В качестве демонстрации нейросетевых моделей приведём примеры принятия решений в среде стандартных нейроэмуляторов [9], [10], где показана реализация таких базовых функций управления, как:

- формирование обучающего множества признаков для двух классов и для двух уровней диагностики;
- реализация процедуры диагностики на двух уровнях.

Последовательное их применение позволило получить искомую нейросетевую модель диагностирования состояния объекта:

→ (SNN – Kohonen 24:24 – 48:1) → (SNN – MLP 24:24 – 56 – 1:1) →  
 → (SNN – Kohonen 24:24 – 48:1) → (SNN – MLP 60:60 – 27 – 1:1) →

Во втором примере поставлены и решены три задачи моделирования системобразующих процессов в среде стандартных нейроэмуляторов Statistika Neural Network:

- а) сформировано обучающее множество признаков для четырех классов состояний объекта;
- б) реализована процедура диагностики его состояния по совокупности входных признаков;
- в) найдена функциональная зависимость между управляющими факторами и состояниями объекта.

Последовательное применение этих процедур позволило получить искомую нейросетевую модель прогнозирования поведения:

→ (SNN – Kohonen 24:24 – 48:1) → (SNN – MLP 53:53 – 27 – 4:1) →  
 → (SNN – RBF 28:28 – 56 – 4:1) →

## Выводы

1. Нейросетевое распознавание классов в пространстве физиологических признаков биосенсоров в среде нейроэмуляторов Statsoft способно обеспечивать гарантированные оценки классов объектов с ошибками не ниже заданных.

2. Научная новизна предлагаемого решения состоит в:

- обосновании применения нейронных сетей по новому назначению для автоматического преобразования пространства рецепторных признаков биосенсоров в пространство физиологических или поведенческих признаков, на основе обучения искусственных нейронных сетей с надежностью решений на уровне традиционных статистических решающих правил;

- в расширении области применения статистических решающих правил на обучающие процедуры нейронных сетей путем обоснования их информативной адекватности, что позволяет количественно обосновать надежность решений, принимаемых на основе моделей в среде эмуляторов StatSoft модуля Statistika Neural Network.

3. Практическая значимость данного исследования заключается в продуктивном использовании уникальных природных данных биодетекторов для автоматизации некоторых процессов (таможенный контроль, экологический мониторинг воды и др.) без существенных финансовых затрат.

## Литература

1. Райт Р.Х. Наука о запахах / Райт Р.Х. ; пер. с англ. – М. : Мир, 1966. – 224 с.
2. Режим доступа : [www.aquafilter.ru/](http://www.aquafilter.ru/) ; [domfilter.ru/](http://domfilter.ru/) ; [best-water.ru/](http://best-water.ru/).
3. Ганшин В.М. Химический наносенсор на свободные высшие жирные кислоты с люминесцентным откликом / В.М. Ганшин, Э.П. Зинкевич // Сенсорные системы. – 2002. – Т. 16, № 14. – С. 336-342.
4. Долгополов Н.В. «Электронный нос» – новое направление индустрии безопасности / Н.В. Долгополов // Мир и безопасность. – 2007. – № 4. – С. 54-59.
5. Гвахария О.Г. Криминалистическая одорология и теория информации / О.Г. Гвахария. // Криминалистика и судебная экспертиза. – Киев : РИО МВД УССР, 1972. – Вып. 9. – С. 189-192.
6. Барабаш Ю.Л. Коллективные статистические решения при распознавании / Барабаш Ю.Л. – М. : Радио и связь, 1983. – 224 с.
7. Хайкин С. Нейронные сети : полный курс / Хайкин С. ; пер. с англ. – [2-е изд.]. – М. : Издательский дом «Вильямс», 2006. – 1104 с.
8. Кохонен Т. Ассоциативная память / Кохонен Т. – Москва : Мир, 1980. – 240 с.
9. Ляхов А.Л. Техническая диагностика бортовых радиолокационных систем в среде Statistika Neural Network / А.Л. Ляхов, С.П. Алешин // Радіоелектронні і комп'ютерні системи. – 2010. – № 7(48). – С. 195-199.
10. Ляхов А.Л. Интеллектуальный анализ данных в прикладных экономических задачах / А.Л. Ляхов, С.П. Алешин // Науковий вісник Полтавського національного технічного університету. – 2009. – № 4(23). – С. 140-147.

### *С.П. Алешин*

#### **Нейромережне розпізнавання класів у просторі фізіологічних ознак біосенсорів**

Робота присвячена проблемі біосенсорного розпізнавання в просторі фізіологічних (зорових, слухових, нюхових та ін.) ознак. Запропоновано методику комбінованого використання біосенсорних здібностей живих істот, їх ситуативної фізіологічної реакції на подразники і навчання штучних нейронних мереж для розпізнавання класів. В основі підходу лежить ідея спільного навчання живих істот і штучних нейронних мереж. Це дозволяє трансформувати складні рецепторні ознаки біодетекторів в простір простих поведінкових реакцій. Наведено алгоритм побудови моделей розпізнавання об'єктів у нейронному середовищі емуляторів формату Statistika Neural Network.

### *S.P. Aleshin*

#### **Neural Network Pattern Recognition of Classes in the Space of Biosensors Physiological Characteristics**

The work is devoted to the biosensor recognition in the space of physiological (visual, auditory, olfactory, etc.) signs. The technique of the combined use of biosensing capabilities of living creatures, their situational physiological reactions and the training of artificial neural networks for recognition of classes is proposed. The approach is based on coeducation of living beings and artificial neural networks. This allows to transform the receptor complex of biotectors signs in the space of simple behaviors. An algorithm for constructing models of object recognition in a neural environment emulators of Statistika Neural Network is formed.

*Статья поступила в редакцию 31.05.2010.*