

УДК 004.896

КЛАССИФИКАЦИЯ И ПРОГНОЗИРОВАНИЕ СТРУКТУР ИНТЕГРИРОВАННЫХ СИСТЕМ БЕЗОПАСНОСТИ НА ОСНОВЕ НЕЙРОННОГО МОДЕЛИРОВАНИЯ

В. А. Дурденко*, А. А. Рогожин**

*Воронежский государственный университет

**Воронежский институт МВД России

Поступила в редакцию 20.01.2017 г.

Аннотация. В статье реализован метод классификации и прогнозирования структур интегрированных систем безопасности на основе моделирования предварительно обученного персептрона.

Ключевые слова: классификация, прогнозирование, экспертиза, интегрированная система безопасности, нейронная сеть, метод, персептрон.

Annotation. In article the method of classification and prediction of the structures of the integrated security systems based on modeling of pre-trained perceptron is realized.

Keywords: classification, prediction, assessment, the integrated security system, neural network, method, perceptron.

ВВЕДЕНИЕ

В работе [3] показана эффективность использования метода погружения численной задачи оценки структур интегрированных систем безопасности (ИСБ) с учетом показателей надежности и качества функционирования в экспертную оболочку в классе DMS (Data Mining System), представленную нечетко-множественным методом анализа иерархий и ассоциативным обучением нейронной сети.

В настоящей статье для классификации вышеупомянутых структур ИСБ с учетом комплексного показателя «качество-цена» и прогнозирования свойств новой структуры ИСБ, а также визуализации полученных результатов предлагается использовать специфическую нейронную сеть – однослойный персептрон с одним нейроном. Выбор персептрона согласно теории нейронных сетей обусловлен тем, что он обеспечивает линейное разделение любых нелинейных множеств,

т. е. обеспечивает «линейную сепарабельность», является так называемым «линейным классификатором». Однако для эффективного использования однослойного персептрона требуется его «обучение с учителем».

Результаты классификации и прогнозирования структур ИСБ на основе моделирования предварительно обученного персептрона не должны противоречить результатам, полученным в [3], на основании чего можно будет сделать вывод об эффективности предложенного метода.

АЛГОРИТМ ОБУЧЕНИЯ ПЕРСЕПТРОНА

Синаптические веса персептрона w_1, w_2, \dots, w_m можно адаптировать итеративным методом. Например, для настройки весовых коэффициентов можно использовать алгоритм, основанный на коррекции ошибок – алгоритм сходимости персептрона [2, 5].

Чтобы построить алгоритм обучения персептрона, основанный на коррекции ошибок, рассмотрим модифицированную модель

© Дурденко В. А., Рогожин А. А., 2017

нейрона (см. рис. 1) с функцией активации *hardlim*.

В этой модели порог *b* рассматривается, как синаптический вес связи w_0 с фиксированным входным сигналом +1. Таким образом, это можно описать расширенным входным вектором размерности $m + 1$:

$$x(n) = [+1, x_1(n), x_2(n), \dots, x_m(n)]^T, \quad (1)$$

где n – номер итерации. Аналогично определяется расширенный вектор весовых коэффициентов размерности $m + 1$:

$$w(n) = [b(n), w_1(n), w_2(n), \dots, w_m(n)]^T. \quad (2)$$

В итоге выход линейного сумматора можно записать в более компактной форме, не выделяя отдельного слагаемого, связанного со смещением:

$$z(n) = \sum_{i=0}^m w_i(n)x_i(n) = w^T(n)x(n), \quad (3)$$

где $w_0(n)$ – пороговое значение $b(n)$.

На n -ой итерации следующее уравнение

$$w^T x = 0 \quad (4)$$

определяет гиперплоскость в m -мерном пространстве, которая является поверхностью решений для двух различных классов сигналов входа.

Чтобы персептрон функционировал правильно, два класса – ϖ_1 и ϖ_2 , должны быть *линейно-разделимыми*. Это означает, что для правильной классификации поверхность решений должна представлять собой гиперплоскость. В случае линейно неразделимых классов персептрон не применим.

Предположим теперь, что входные переменные персептрона принадлежат двум линейно-разделимым классам. При этом подм-

ножество векторов обучения X_1 приводит к классу ϖ_1 , а X_2 – к классу ϖ_2 . Это значит, что существует такой вектор весовых коэффициентов w , для которого истинны следующие утверждения:

- 1) для любого входного вектора x , принадлежащего классу ϖ_1 ,

$$w^T x > 0; \quad (5)$$

- 2) для любого входного вектора x , принадлежащего классу ϖ_2 ,

$$w^T x \leq 0. \quad (6)$$

При определенных таким образом подмножествах X_1 и X_2 обучающего множества X задача обучения персептрона сводится к нахождению такого вектора весов w , для которого выполняются оба неравенства (5) и (6).

В упрощенном виде алгоритм адаптации вектора весовых коэффициентов персептрона заключается в следующем. Если n -й элемент $x(n)$ обучающего множества правильно классифицирован с помощью весовых коэффициентов $w(n)$, вычисленных на n -ом шаге алгоритма, то вектор весов не корректируется:

$$w(n+1) = w(n), \text{ если } w^T x(n) > 0 \text{ и } x(n) \in \varpi_1, \quad (7)$$

$$w(n+1) = w(n), \text{ если } w^T x(n) \leq 0 \text{ и } x(n) \in \varpi_2.$$

В противном случае вектор весов персептрона корректируется:

$$w(n+1) = w(n) - \eta(n)x(n),$$

если $w^T x(n) > 0$ и $x(n) \in \varpi_2$,

$$w(n+1) = w(n) + \eta(n)x(n),$$

если $w^T x(n) \leq 0$ и $x(n) \in \varpi_1$.

где интенсивность настройки вектора w на шаге n определяется *параметром скорости*

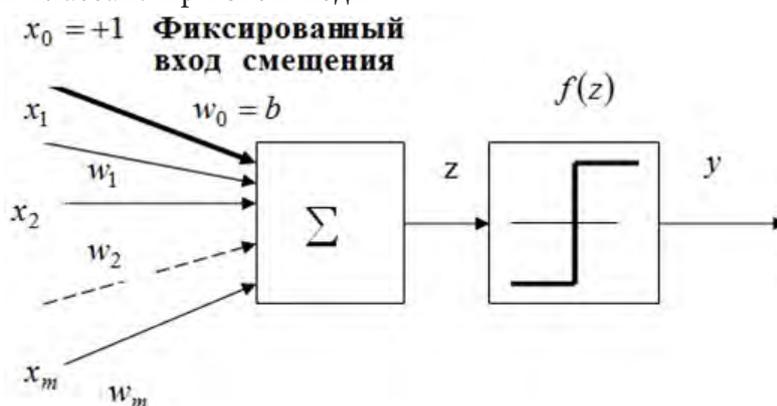


Рис. 1. Модифицированная модель нейрона с расширением вектора входов дополнительным входом смещения w_0

обучения $\eta(n)$. Если $\eta(n) = \eta > 0$, где η не зависит от номера итерации n , этот алгоритм называется *правилом адаптации с фиксированным приращением*.

1. КЛАССИФИКАЦИЯ СТРУКТУР ИСБ С УЧЕТОМ КОМПЛЕКСНОГО ПОКАЗАТЕЛЯ «КАЧЕСТВО-ЦЕНА»

Графическое изображение (визуализация) множества векторов, подлежащих классификации и разделяющей поверхности очень важно для характеристики исследуемого множества объектов экспертизы и принятия управленческих решений. При моделировании нейронной сети в виде персептрона обычно применяется функция активации с жесткими ограничениями *hardlim*, которая возвращает выход нейрона равным 1, если вход достигнет порогового значения, в иных случаях равным 0.

В работе [3] был рассмотрен только количественный признак эффективности выполнения целевой функции, принимающий после использования метода МАИ значения S_k . Введем теперь и второй признак – признак цены $P(price)$, исходные значения которого представлены в 6-ом столбце табл. 1.

Признак цены является признаком отрицательного эффекта, поэтому введем для него нормировку согласно методике работы [1]:

$$\hat{P}_k = P_{\min} / P_k, \quad (9)$$

где P_{\min} – цена самого дешевого объекта экспертизы. Для него, соответственно, нормированное значение признака цены равно 1,0. Для более дорогих объектов значения \hat{P}_k будут менее 1, поэтому назовем его *признаком обратной цены*.

Осуществим нормировку исходной цены объектов (см. 6 столбец таблицы 1) согласно формулы (9):

$$\hat{P} = (0,476 \ 0,471 \ 0,493 \ 0,539 \ 0,465 \ 0,482 \ 1,000 \ 0,450)^T. \quad (10)$$

Для классификации объектов экспертизы используем описанную выше специфическую нейронную сеть – персептрон. В отличие от применения пакета *ntool* и удобного графического интерфейса GUI, для дальнейшего исследования потребовалась разработка программы на языке MATLAB (так называемого М-файла) [4].

Сформируем новый персептрон с двумя входами и функцией активации *hardlim*:

```
net = perceptron('hardlim', 'learnprn');
net = configure(net,X,T)
```

и подадим на ее вход последовательность двумерных векторов «цена-качество» для различных структур, объединив результаты вектора (14), полученного в работе [3], и вектора (10):

Таблица 1

Анализ эффективности сравниваемых структур ИСБ

№ структуры ИСБ	Неработоспособная подсистема f_k	Эффективность выполнения целевой функции	Обозначения и ранги упорядоченных систем		Стоимостная оценка структуры ИСБ, у.е.
1	1	3,3	S_5	5	86000
2	2	3,5	S_4	4	87000
3	3	4,1	S_3	3	83000
4	4	3,1	S_6	6	76000
5	5	4,3	S_2	2	88000
6	6	2,2	S_7	8	85000
7	7	1,4	S_8	9	41000
8	–	5,0	S_1	1	91000

$$X = \begin{pmatrix} 0,476 & 0,471 & 0,493 & 0,539 & 0,465 & 0,482 & 1,000 & 0,450 \\ 0,165 & 0,207 & 0,344 & 0,158 & 0,461 & 0,072 & 0,042 & 0,753 \end{pmatrix}^T. \quad (11)$$

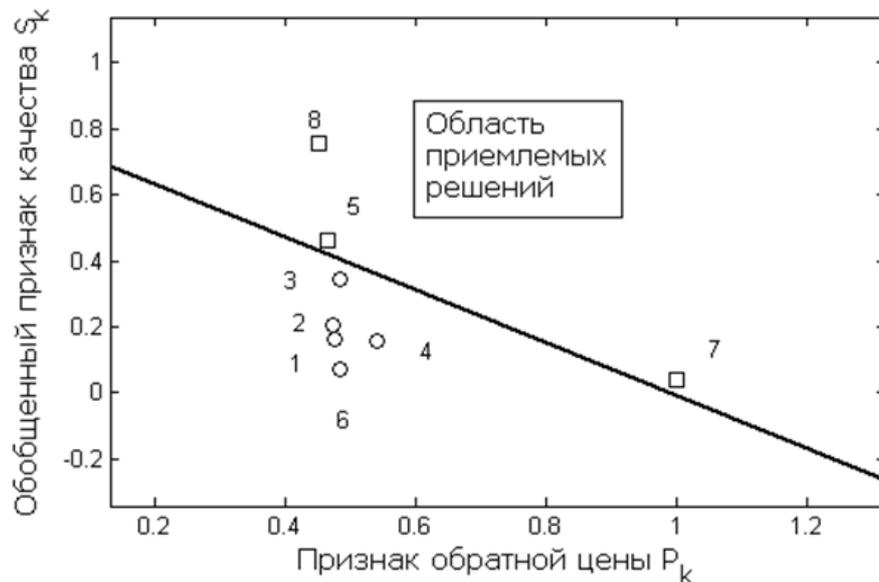


Рис. 2. Классификация объектов экспертизы на основе нейронной сети – персептрона

Для разделения множества объектов на два класса и построения разделяющей поверхности (в нашем случае – прямой линии) требуется задать вектор цели T , содержащий элементы 1 или 0 по принципу: 1 – объект относится к области приемлемых решений, 0 – не относится.

Выберем вектор цели в следующем виде

$$T = (0 \ 0 \ 0 \ 0 \ 1 \ 0 \ 1 \ 1), \quad (12)$$

предполагая, что к области приемлемых решений должны относиться не только объекты 5 и 8 с наилучшими показателями качества, но и объект 7, имеющий почти в два раза меньшую стоимость (см. столбец 6 таблицы 1).

В нашем случае обучение персептрона произошло всего за 2 цикла с вектором ошибок $(0 \ 0 \ 0 \ 0 \ 0 \ 0 \ 0 \ 0)^T$. При этом вектор весов и смещение примут вид:

$$\begin{aligned} iw(1,1) &= (4,0420 \ 5,0840)^T, \\ b(1) &= -4. \end{aligned} \quad (13)$$

Итак, результаты классификации с помощью персептрона оказались правильными, и поверхность раздела согласно (13) является разделяющей прямой

$$L = 4,0420x_1 + 5,0840x_2 - 4. \quad (14)$$

После нескольких шагов адаптации нейронной сети получим следующую картину

расположения двумерных векторов объектов экспертизы относительно разделяющей прямой (см. рис. 2).

Как видим, персептрон правильно разделил объекты экспертизы на два класса согласно заданному вектору цели (12). Визуализация свойств объектов позволяет экспертам принять более обоснованные решения, чем просто использование данных исходной базовой задачи экспертизы ИСБ (см. табл. 1).

2. ПРОГНОЗИРОВАНИЕ ПОКАЗАТЕЛЕЙ НОВОЙ СТРУКТУРЫ ИСБ

Предложим следующий метод прогнозирования состояния нового объекта ИСБ. После обучения персептрона по множеству входных воздействий X с целевой функцией T были определены веса и смещения нейрона (13) и найдена разделяющая прямая (14). Определим состояние новой структуры ИСБ, воспользовавшись функцией моделирования `sim` языка MATLAB и внесем следующее дополнение в алгоритм программы [4]:

% Вставка тестовой структуры

$z = [0.5; 0.45]$

% Оценка принадлежности тестовой структуры

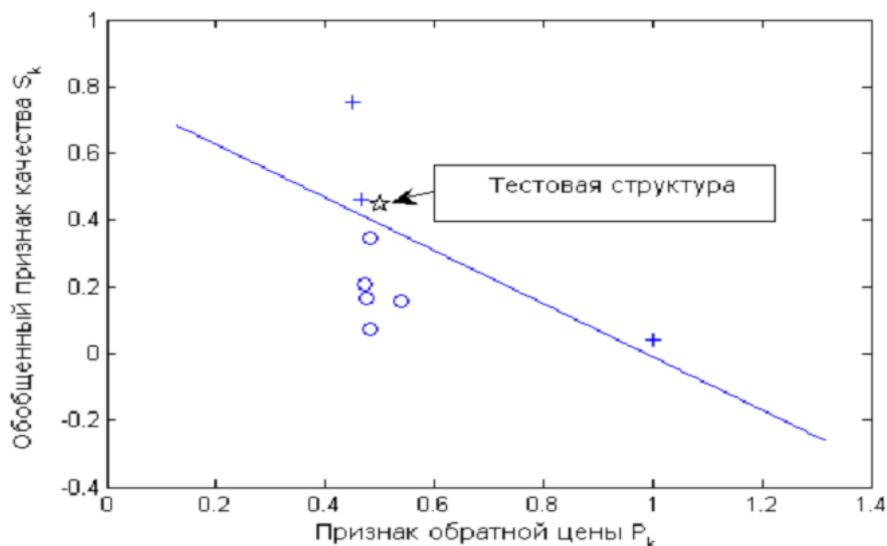


Рис. 3. Прогнозирование состояния нового объекта экспертизы

```
% к области предпочтительных решений
%(1 – принадлежит; 0 – не принадлежит)
Z1 = sim(net,z)
Z1
hold on
plotpv(z,[1])
```

Характеристическое число $Z1$ примет значение 1, что свидетельствует о принадлежности признаков тестовой структуры области приемлемых решений, а сама тестовая структура отобразится «звездочкой» (см. рис. 3).

В статье рассматриваются только двумерные входные воздействия (11) и процессы классификации и прогнозирования легко поясняются соответствующими графическими изображениями. Однако характеристическое число $Z1$ имеет существенно большее значение, чем просто визуализация упомянутых процессов. При увеличении количества признаков объекта более 3 ($m > 3$) мы уже не будем иметь возможности наблюдать визуально процессы классификации и прогнозирования. Однако число $Z1$ можно найти при использовании упомянутой процедуры `sim` и в многомерном случае. Особенно важным является тот факт, что проверка принадлежности новой структуры области приемлемых решений будет осуществляться по всем m подобластям m -мерного пространства. Поэтому предложенный выше метод прогнозирования состояния нового объекта экспертизы на основе

моделирования (`sim`) предварительно обученного персептрона имеет значительно более широкую область применения, чем показано в рассмотренном выше примере.

ЗАКЛЮЧЕНИЕ

В статье обоснована целесообразность применения специфической нейронной сети – персептрона и показана эффективность ее применения для классификации упомянутых структур ИСБ. Синаптические веса персептрона w_1, w_2, \dots, w_m адаптируются итеративным способом на основе алгоритма, основанного на коррекции ошибок. Для классификации структур ИСБ с различными функциональными возможностями выбрано два признака: показатель эффективности и стоимостный показатель. После их нормировки использована нейронная сеть (персептрон) с функцией активации `hardlim` и осуществлена классификация с построением разделяющей поверхности. К области приемлемых решений отнесены две структуры ИСБ с наилучшими функциональными возможностями и третья – с наименьшей стоимостью.

После обучения персептрона по множеству известных структур с целевой функцией T были определены веса и смещения нейрона и найдена разделяющая прямая. Для прогноза состояния новой структуры ИСБ предло-

жено воспользоваться функцией моделирования *sim* языка MATLAB и найти значения характеристического числа (1 – объект с приемлемыми свойствами, 0 – нежелательный объект). Такая процедура может быть распространена на случай объектов с большим числом признаков ($m > 3$), хотя визуализация результатов возможна только при $m \leq 3$.

Таким образом, в работе предложен эффективный метод классификации и прогнозирования структур интегрированных систем безопасности на основе моделирования предварительно обученного персептрона. Предложенный метод предназначен для совершенствования решения класса вычислительных задач оценки и сравнения технических объектов ИСБ как по чисто техническим характеристикам, так и по показателям «качество-цена».

СПИСОК ЛИТЕРАТУРЫ

1. Бухарин С. В. Кластерно-иерархические методы экспертизы экономических объектов: монография / С. В. Бухарин, А. В. Мельников – Воронеж : Изд-во «Научная книга», 2012. – 276 с.
 2. Медведев В. С. Нейронные сети. Matlab 6 / В. С. Медведев, В. Г. Потемкин. – М. : ДИАЛОГ-МИФИ, 2002. – 496 с.
 3. Рогожин А. А. Коррекция результатов анализа иерархий функциональных возможностей интегрированных систем безопасности методом ассоциативного обучения нейронной сети / А. А. Рогожин, А. В. Мельников, С. А. Мальцев // Вестник Воронежского института МВД России. – Воронеж : 2016. – № 1. – С. 52–61.
 4. Рогожин А. А. Программа прогнозирования и классификации обобщенных показателей качества приборов и структур интегрированных систем безопасности / А. А. Рогожин, С. А. Мальцев, В. В. Навоев. – Москва: Федеральная служба по интеллектуальной собственности (РОСПАТЕНТ), 2016. – Свидетельство о государственной регистрации программы для ЭВМ от 21 июля 2016 г. № 2016618112.
 5. Хайкин С. Нейронные сети: полный курс / С. Хайкин: Пер. с англ. – 2-ое изд. – М. – СПб. – Киев : Вильямс, 2006. – 1104 с.
- Дурденко Владимир Андреевич** – д-р техн. наук, профессор кафедры информационных технологий управления, Воронежский государственный университет.
Тел.: (473) 2-208-909
E-mail: dva_viis@mail.ru
- Рогожин Александр Александрович** – преподаватель кафедры вневедомственной охраны Воронежского института МВД России.
Тел.: (473) 200-52-84
E-mail: raa_tsbs@list.ru
- Durdenko Vladimir A.** – Doctor of Technical Sciences, Professor, Department of information technology management, Voronezh State University.
Tel.: (473) 2-208-909
E-mail: dva_viis@mail.ru
- Rogozhin Alexander A.** – Lecturer, Department of private security, Voronezh Institute of the Ministry of the Interior of Russia.
Tel.: (473) 200-52-84
E-mail: raa_tsbs@list.ru