

НЕЙРОСЕТЕВЫЕ ТЕХНОЛОГИИ NEUROTECHNOLOGIES

УДК 519.7

Л. А. Лютикова, канд. физ.-мат. наук, зав. отделом, e-mail: lylarisa@yandex.ru,

Е. В. Шматова, мл. науч. сотр., e-mail: lenavsh@yandex.ru,

Институт прикладной математики и автоматизации — филиала Федерального государственного научного учреждения "Федеральный научный центр "Кабардино-Балкарский научный центр Российской академии наук" (ИПМА КБНЦ РАН), г. Нальчик

Логический подход к коррекции результатов работы ΣΠ-нейронных сетей¹

Рассматривается метод построения логического корректора для работы ΣΠ-нейронных сетей при решении задач распознавания. Предлагается метод обнаружения неявных закономерностей по структуре ΣΠ-нейрона при котором повышаются адаптивные свойства распознающей системы. Утверждается, что комбинированный подход к организации работы распознающей системы повышает ее эффективность и позволяет в случае возникновения некорректного ответа ΣΠ-нейрона в качестве решения указать наиболее близкие по запрашиваемым признакам объекты.

Ключевые слова: логический анализ, анализ данных, алгоритм, ΣΠ-нейрон, обучающая выборка, деревья решений, корректирующие операции

Введение

Распознавание образов — это целый раздел теоретической информатики, разрабатывающий принципы и методы классификации, а также идентификации предметов, явлений, процессов, сигналов, ситуаций — всех тех объектов, которые могут быть описаны конечным набором некоторых признаков или свойств, характеризующих объект [1].

Существует ряд методов для решения данных задач, каждый из которых обладает как своими преимуществами, так и своими недостатками [2].

Комбинированный подход применяется, когда требуется скорректировать работу нескольких различных алгоритмов, каждый из которых безошибочно классифицирует лишь часть обучаемых объектов. Цель коррекции — сделать так, чтобы ошибки одних алгоритмов были скомпенсированы другими и качество результирующего алгоритма оказалось лучше, чем каждого из базовых алгоритмов в отдельности [1, 3, 4].

На практике существуют различные подходы к построению комбинированных корректирующих алгоритмов, сочетание которых дает практически значимые результаты [4—9].

В данной работе рассматривается подход, основанный на логическом анализе данных, используемый для коррекции работы ΣΠ-нейронной сети. ΣΠ-нейрон (сигма-пи-нейрон) является обобщением классической модели формального нейрона с линейной функцией суммирования $sp(x_1, \dots, x_n)$ входных сигналов.

Можно предположить, что правила опознавания объекта ΣΠ-нейронная сеть содержит в весовых коэффициентах, но правила эти не явные, и определить причину ошибки бывает затруднительно. Построение корректора для осуществления контрольных и корректирующих функций работы ΣΠ-нейрона предлагается с использованием методов логического анализа, позволяющего по весовым коэффициентам восстановить обучающую выборку, провести ее анализ, построить базу знаний, минимизировать ее и в случае ошибочной работы ΣΠ-нейрона скорректировать ответ относительно построенных правил. В статье рассматривается метод обнаружения в структуре ΣΠ-нейрона ранее не известных, практически полезных, доступных интерпретации знаний, необходимых для принятия решений.

¹ Работа выполнена при поддержке гранта РФФИ № 15-01-03381 и фундаментального научного проекта ОНИТ РАН.

Постановка задачи

Пусть $X = \{x_1, x_2, \dots, x_n\}$, $x_i \in \{0, 1, \dots, k_i - 1\}$, где $k_i \in [2, \dots, N]$, $N \in \mathbb{N}$, — множество признаков. $Y = \{y_1, y_2, \dots, y_m\}$ — множество объектов, каждый объект y_i характеризуется соответствующим набором признаков $x_1(y_i), \dots, x_n(y_i)$: $y_i = f(x_1(y_i), \dots, x_n(y_i))$.

Или пусть $X = \{x_1, x_2, \dots, x_n\}$, где $x_i \in \{0, 1, \dots, k_r - 1\}$, $k_r \in [2, \dots, N]$, $N \in \mathbb{Z}$ — обрабатываемые входные данные $X_i = \{x_1(y_i), x_2(y_i), \dots, x_n(y_i)\}$, $i = 1, \dots, n$, $y_i \in Y$, $Y = \{y_1, y_2, \dots, y_m\}$ — выходные данные:

$$\begin{pmatrix} x_1(y_1) & x_2(y_1) & \dots & x_n(y_1) \\ x_1(y_2) & x_2(y_2) & \dots & x_n(y_2) \\ \dots & \dots & \dots & \dots \\ x_1(y_m) & x_2(y_m) & \dots & x_n(y_m) \end{pmatrix} \rightarrow \begin{pmatrix} y_1 \\ y_2 \\ \dots \\ y_m \end{pmatrix}.$$

Вид функции $Y = f(x)$ не задан.

Пусть $\Sigma\Pi$ -нейрон представлен следующей структурой:

$$\text{sp}(x_1, \dots, x_n) = \sum w_i \prod x_i,$$

где $\{w_1, w_2, \dots, w_k\}$ — множество весов данного $\Sigma\Pi$ -нейрона, распознающего k элементов заданной предметной области $Y = \{y_1, y_2, \dots, y_k\}$, сформированной соответствующим набором признаков $\{X_1, \dots, X_k\}$. И пусть существует набор признаков $X_l \notin \{X_1, \dots, X_k\}$ такой, что результат работы $\Sigma\Pi$ -нейрона на данном запросе некорректен.

Будем говорить, что результат работы $\Sigma\Pi$ -нейрона некорректен, если:

1) он не опознал соответствующий запросу элемент, т.е.

$$\text{sp}(X_i) \neq y_i;$$

2) он опознал объект, не принадлежащий данной предметной области, т.е.

$$\text{sp}(X_i) = y_l, y_l \notin \{y_1, \dots, y_n\};$$

3) при запросе $X_j \notin \{X_1, X_2, \dots, X_k\}$ найден элемент, принадлежащий предметной области, но в обучающей выборке существует элемент с большим числом совпадающих признаков, т.е. $\text{sp}(X_i) = y_l, y_l \in \{y_1, \dots, y_n\}$, и существует y_j с соответствующим вектором признаков x_j такой, что

$$\dim |X_i - X_j| < \dim |X_i - X_l|,$$

где $\dim |X_l - X_i|$ — число несовпадающих признаков; X_l — вектор признаков y_l .

Необходимо построить функцию, которая при ошибке работы $\Sigma\Pi$ -нейрона сможет подобрать

наиболее близкий элемент или класс элементов из обучающей выборки по заданным признакам:

$$F(X_l): F(X_l) = y_i, y_i \in Y, \dim |X_l - X_i| \rightarrow \min.$$

Основные сведения о $\Sigma\Pi$ -нейронных сетях

$\Sigma\Pi$ -нейрон представляет собой *алгебраическую модель* нейрона, отражающую процессы обработки информации в аксо-дендритной системе нейрона [10–12], которая обладает лучшими способностями по аппроксимации зависимостей.

Один $\Sigma\Pi$ -нейрон в своем классическом варианте имеет полилинейную функцию суммарного сигнала

$$\text{sp}(X) = \text{out} \left(\theta + \sum w_k \prod_{i=1}^n x_i \right),$$

где θ — константа, out — функция вывода.

Обучить логико-арифметический $\Sigma\Pi$ -нейрон можно за один проход обучающей выборки.

В процессе обучения строится последовательность логико-арифметических $\Sigma\Pi$ -нейронов $\{\text{sp}_k(X)\}$, $\text{sp}_n(X) = \text{sp}_{\text{ngsp}}(X)$. Процесс построения рекуррентный:

1) вначале $\text{sp}_0(X) = 0$,

2) на k -м шаге $\text{sp}_k(X) = \text{sp}_{k-1}(X) + w_k \prod_{i \in \mathbf{i}_k^0} x_i$, где $\mathbf{i}_k^0 = \{i : x_{ki} = 1\}$. Вес w_k находится следующим образом:

$$w_k = \begin{cases} s_k - \text{sp}_{k-1}(X_k), & \text{если } \text{sp}_{n_{k-1}}(X_k) \neq y_k; \\ 0, & \text{если } \text{sp}_{n_{k-1}}(X_k) = y_k, \end{cases}$$

где s_k — произвольное значение, такое что $\text{sp}(s_k) = y_k$.

После N шагов искомым логико-арифметический $\Sigma\Pi$ -нейрон построен. Этот очень простой алгоритм обучения в случае, когда out — пороговая функция, был первоначально предложен Тимофеевым А. В. [13].

ПРИМЕР 1. Пусть в виде таблицы задана следующая предметная область:

x_1	x_2	x_n	y
0	0	1	2
0	1	0	4
0	1	1	8
1	1	1	128

Множество признаков X представлено следующими значениями:

$$X = \{X_1 = (0, 0, 1), X_2 = (0, 1, 0), X_3 = (0, 1, 1), X_4 = (1, 1, 1)\},$$

а множество объектов $Y = \{2, 4, 8, 128\}$.

В результате обучения по данным таблицы ΣП-нейрон будет иметь вид

$$\text{sp}(x_1, x_2, x_3) = 4x_2 + 2x_3 + 2x_2x_3 + 120x_1x_2x_3.$$

Введем запрос (1, 1, 0), который в точности не совпадает ни с одним из заданных наборов. Результат обученного ΣП-нейрона: $\text{sp}(1, 1, 0) = 4$. Действительно, объект "4" из множества Y совпадает с запросом в двух точках, но в двух точках с запросом совпадает и объект "128", причем этот объект выделяется во всей выборки значением переменной x_1 . Корректировку подобных результатов работы ΣП-нейрона можно провести с помощью логического анализа данных.

Логический подход к исследованию обучающей выборки построения решающей функции

В данном разделе рассматриваются логические методы анализа данных. Предлагается метод построения логической функции классификатора, рассматриваются ее свойства. Анализируются получаемые результаты [14, 15].

Данные, с которыми приходится иметь дело при решении задач распознавания, как известно, являются неполными, неточными, неоднозначными. Однако получаемые решения должны соответствовать закономерностям, явно и неявно присутствующим в рассматриваемой предметной области. Использование логических методов позволяет достаточно хорошо проанализировать данные, выделить существенные и несущественные признаки, выявить минимальный набор правил, необходимый для того, чтобы полностью восстановить исходные закономерности. В результате можно получить более компактное и надежное представление исходной информации, которая обрабатывается надежней и быстрее.

Будем говорить, что построенная система правил является полной, если она обеспечивает вывод всех решений в рассматриваемой области.

Группу объектов, выделенных по определенному признаку (группе признаков), будем называть классом.

Каждый объект может быть представителем одного или нескольких классов, каждый класс определяется набором однотипных признаков.

Для объяснения логической связи между понятиями предметной области будем использовать правило продукции, предложенное Э. Постом. В нашем случае правило продукции представляет собой подстановку следующего вида:

$$x_1(y_i) \& x_2(y_i) \& \dots \& x_n(y_i) \rightarrow P(y_i),$$

где $P(y) = \begin{cases} 1, & y = y_i; \\ 0, & \text{иначе,} \end{cases}$

$x_1(y_i), x_2(y_i), \dots, x_n(y_i)$ — конечное число признаков, характеризующих элемент y_i .

Это позволяет выразительно представить зависимости между объектом и его признаками:

$$\big\&_{j=1}^m x_j(y_i) \rightarrow P(y_i), i = 1, \dots, l; x_j(y_i) \in \{0, 1, \dots, k-1\},$$

где предикат $P(y_i)$ принимает значение "истина", т.е. $P(y_i) = 1$ в случае, если $y = y_i$, и $P(y_i) = 0$, если $y \neq y_i$. Или

$$\bigvee_{i=1}^n \bar{x}(y_j) \vee P(y_j), j \in [1, \dots, m].$$

Решающей функций назовем конъюнкцию всех решающих правил:

$$\big\&_{j=1}^m x_j(y_i) \rightarrow P(y_i), i = 1, \dots, l; x_j(y_i) \in \{0, 1, \dots, k-1\},$$

$$\text{или } f(X) = \big\&_{j=1}^m \left(\bigvee_{i=1}^n \bar{x}_i(y_j) \vee P(y_j) \right). \quad (1)$$

Функцию (1) можно интерпретировать следующим образом.

Если обучающую выборку, состоящую из k элементов, описать булевой функцией

$$F(x_1(y_i), \dots, x_n(y_i), P^\sigma(y_1), \dots, P^\sigma(y_n)),$$

где

$$P^\sigma(y_i) = \begin{cases} \overline{P(y_i)} & \text{при } \sigma = 0; \\ P(y_i) & \text{при } \sigma = 1, \end{cases}$$

то данная функция принимает значения "0" на наборах $(x_1(y_i), \dots, x_n(y_i), P^\sigma(y_1), \dots, \overline{P(y_i)}, \dots, P^\sigma(y_n))$ и "1" на всех остальных наборах, т.е. она допускает любые отношения между признаками и объектами, кроме отрицания объекта на множестве характеризующих этот объект признаков в обучающей выборке.

Функция (1) выражает зависимость между характеристиками объекта и самим объектом, находит все возможные классы в заданной области, вплоть до классов объектов, объединенных по единственному признаку, допускает включение новых правил продукции (модифицируема), при вводе значения любого объекта из исследуемой области определяет этот объект. Если вводимые данные точно не определены в области, по которой была построена функция, то функция определяет наиболее подходящий объект или классы объектов, идентифицируемые по части входных данных.

Все свойства функции (1) подробно рассмотрены в работе [16].

Поскольку функция — это дизъюнкция конъюнкций разной длины переменных, она может быть подвергнута сокращению.

Логическое описание класса K_j — это дизъюнкт решающей функции (1) состоящий из набора предикатов, характеризующих наличие или отсутствие какого-либо элемента, и переменных, характеризующих общие признаки для этих элементов.

В результате функция (1) будет состоять из переменных, сочетание которых не является характеристикой каких-либо классов или отдельных объектов, и объектной части (дизъюнктов), которые содержат предикаты объектов. Алгоритм построения объектной части решающей функции описан в работе [16].

Решающая функция для примера 1 будет иметь следующий вид:

$$f(X) = (\overline{x_1} \vee \overline{x_2} \vee \overline{x_3} \vee P(128)) \& \\ \& (x_1 \vee \overline{x_2} \vee \overline{x_3} \vee P(8)) \& \\ \& (x_1 \vee x_2 \vee \overline{x_3} \vee P(2)) \& (x_1 \vee \overline{x_2} \vee x_3 \vee P(4)) = \\ = \overline{x_1} \overline{x_2} \vee x_1 \overline{x_2} \vee x_1 \overline{x_3} \vee \overline{x_3} P(4) \vee \overline{x_2} P(2) \vee x_1 P(128) \vee \\ \vee P(128) P(8) P(2) x_3 \vee P(128) P(8) P(4) x_2 \vee \\ \vee P(4) P(8) P(2) \overline{x_1}.$$

Объектная часть функции представима следующими дизъюнктами:

$$f(X) = \overline{x_3} P(4) \vee \overline{x_2} P(2) \vee x_1 P(128) \vee \\ \vee P(128) P(8) P(2) x_3 \vee \\ \vee P(128) P(8) P(4) x_2 \vee P(4) P(8) P(2) \overline{x_1}.$$

При запросе, где вектор признаков представлен значениями (1, 1, 0), логическая функция выдаст следующий результат: $f(1, 1, 0) = P(4) \vee P(128)$.

В отличие от нейронной сети она в качестве ответа предложит объект "4" и объект "128".

В результате применения данного алгоритма, как и функции (1), мы получаем не единственный ответ, а возможные варианты, подходящие для данного запроса по соответствующим признакам. Анализ полученных результатов может быть подвергнут частотному анализу, процедуре взвешенного голосования или оценке эксперта. Эксперт может установить несколько порогов и соответственно ранжировать полученные закономерности по степени достоверности.

Выделение правил из обученной нейронной сети

В данной работе рассматривается ΣΠ-нейронная сеть, результатом обучения которой будет являться полином вида

$$\text{sp}(x_1, \dots, x_n) = w_0 + w_1 x_1 + w_2 x_2 + \dots + w_p x_1 x_2 \dots x_n,$$

где $\{w_1, w_2, \dots, w_k\}$ — множество весов данного ΣΠ-нейрона.

Обучающая выборка, по которой проводилась настройка весов, вообще говоря, может быть неизвестна. Требуется восстановить обучающую выборку, обнаружить логические закономерности и использовать их для корректировки результата работы исходного ΣΠ-нейрона.

Восстановление обучающей выборки по полиному — это, по сути, процедура, обратная обучению.

На нижнем уровне находятся переменные $\{x_1, x_2, \dots, x_n\}$. Все коэффициенты полинома (веса ΣΠ-нейрона) разбиваются на уровни в зависимости от числа переменных, входящих вместе с ним в слагаемое. То есть на первом слое веса с наименьшим числом переменных, на втором соответственно на одну переменную больше и т.д., в верхнем слое находятся все коэффициенты с наибольшим числом переменных. Элемент каждого верхнего уровня связан с соответствующими элементами нижнего слоя по общим переменным.

Веса первого слоя $\{w_1, w_2, \dots, w_r\}$ соответственно и есть объекты $\{y_1, y_2, \dots, y_r\}$ на каждом следующем слое $y_{k+1} = w_{k+1} + \sum y_i$, где i — индексы соответствующих объектов, переменные которых входят в качестве сомножителей в элемент на y_{k+1} .

ПРИМЕР 2. Пусть обученный ΣΠ-нейрон имеет следующий вид

$$\text{sp}(x_1, x_2, x_3) = 4x_2 + 2x_3 + 2x_2x_3 + 120x_1x_2x_3.$$

Восстановим объекты обучающей выборки и найдем обобщающие логические правила (рис. 1).

Построение неявных правил. Для построения по дереву неявных правил рассмотрим путь из каждой вершины y_k к каждой переменной x_i . Если такой путь существует, то множество вершин принадлежащих соответствующему пути, т.е. множество объектов, определяемых переменной, образуют класс по этой переменной x_i . Та-

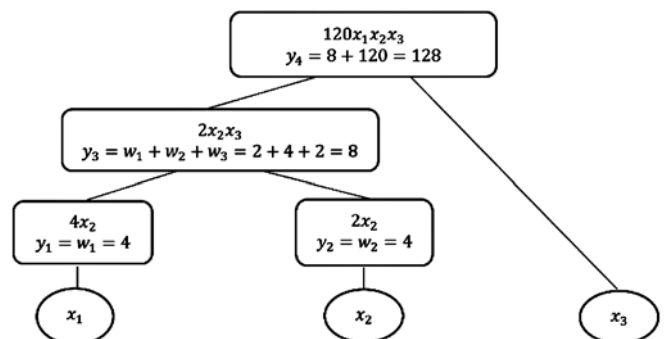


Рис. 1




Рис. 2

кой путь можно представить в виде логической формулы с помощью операции конъюнкции, т.е.

$$P(y_k) \& P(y_{k-1}) \& \dots \& P(y_i) \& x_i.$$

Если пути от заданной вершины y_k к вершине x_i не существует, то данный путь (класс объектов) определяется отрицанием соответствующей переменной. Совокупность всевозможных путей, как существующих, так и несуществующих, представима в виде дизъюнкции (рис. 2). Таким образом, можно полностью восстановить объектную часть логической функции (1).

Штриховой линией обозначены связи с отрицанием переменной.

$$f(X) = \overline{x_3}P(4) \vee \overline{x_2}P(2) \vee x_1P(128) \vee P(128)P(8)P(2)x_3 \vee P(128)P(8)P(4)x_2 \vee P(4)P(8)P(2)\overline{x_1},$$

что полностью совпадает с объектной частью функции (1).

ТЕОРЕМА. Пусть $X = \{x_1, x_2, \dots, x_n\}$, $x_i \in \{0, 1, \dots, k_i - 1\}$, где $k_i \in [2, \dots, N]$, $N \in \mathbb{N}$ — множество признаков. $Y = \{y_1, y_2, \dots, y_m\}$ — множество объектов, каждый объект y_i характеризуется соответствующим набором признаков $x_1(y_i), \dots, x_n(y_i)$, и пусть $\text{sp}(X) = Y$, тогда по соответствующей структуре $\text{sp}(X)$ можно получить все возможные решения на заданном пространстве данных.

Доказательство. Как было показано выше, по структуре нейрона можно восстановить обучающую выборку, для нее возможно построить логическую решающую функцию (1), которая строит полную систему правил для заданной предметной области.

Предложенная процедура построения неявных правил упрощает задачу.

Поскольку с помощью логической функции (1) можно провести полный анализ обучающей выборки и найти все возможные связи, то объектная часть логической функции может выступить в качестве корректора для $\Sigma\Pi$ -нейрона. В соответствии с предложенным выше алгорит-

мом корректор можно построить, опираясь на структуру самого $\Sigma\Pi$ -нейрона, даже не имея обучающей выборки.

В окончательном виде модель $\Sigma\Pi$ -нейрона вместе с его корректором имеет следующий вид:

$$Y = P(\text{sp}(X)) \vee f(X),$$

где $f(X)$ является корректором работы нейрона. Тогда наилучшее решение можно выбрать между результатом работы нейрона и корректором. Если ответ нейрона был правильным и объект, ранее не принадлежал обучающей выборке, то в силу простой модифицируемости функции $f(X)$, новое правило будет принято корректором и расширит базу знаний.

Заключение

В работе рассмотрены вопросы поиска логических закономерностей по структуре обученного $\Sigma\Pi$ -нейрона. Предложено совместное использование нейросетевых технологий и методов логического вывода как средства выявления логических закономерностей и представления более точного результата в задачах распознавания. Также рассмотрены преимущества логического анализа данных и построена логическая функция для выявления всех закономерностей исследуемой предметной области. Предложена процедура построения деревьев решений на основе обученного $\Sigma\Pi$ -нейрона, которая не предъявляет никаких требований к архитектуре, алгоритму обучения, входным и выходным значениям и другим параметрам сети. Построение дерева осуществляется по структуре нейрона, результат выявляет ряд скрытых логических закономерностей данных, строит логическую функцию, которая корректирует работу нейрона в случае неточных зашумленных данных, позволяя указать наиболее правдоподобные (близкие к эталонным) ответы в рамках сделанного запроса, а также легко модифицировать в случае правильного ответа нейрона, не предусмотренного обучающей выборкой. В результате существенно повышается качество автоматизированного решения интеллектуальных задач, надежность их функционирования, точность достижения верного решения за счет использования наиболее эффективных систем анализа исходных данных и разработки более точных методов их обработки.

Список литературы

1. Журавлев Ю. И. Об алгебраическом подходе к решению задач распознавания или классификации // Проблемы кибернетики. 1978. Т. 33. С. 5—68.

2. Флах П. Машинное обучение. Наука и искусство построения алгоритмов, которые извлекают знания из данных. М.: МДК Пресс, 2015. 400 с.
3. Воронцов К. В. Оптимизационные методы линейной и монотонной коррекции в алгебраическом подходе к проблеме распознавания // Журнал вычислительной математики и математической физики. 2000. Т. 40, № 1. С. 166—176.
4. Абламейко С. В., Бирюков А. С., Докукин А. А., Дьяконов А. Г., Журавлев Ю. И., Краснопрошин В. В., Образцов В. А., Романов М. Ю., Рязанов В. В. Практические алгоритмы алгебраической и логической коррекции в задачах распознавания по прецедентам // Журнал вычислительной математики и математической физики. 2014. Т. 54. № 12. С. 1979.
5. Тимофеев А. В., Косовская Т. М. Нейросетевые методы логического описания и распознавания сложных образов // Труды СПИИРАН, 27 (2013). С. 144—155.
6. Дюкова Е. В., Журавлев Ю. И., Прокофьев П. А. Методы повышения эффективности логических корректоров // Машинное обучение и анализ данных. 2015. Т. 1. № 11. С. 1555—1583.
7. Гридин В. Н., Солодовников В. И., Евдокимов И. А., Филипов С. В. Построение деревьев решений и извлечение правил из обученных нейронных сетей // Искусственный интеллект и принятие решений. 2013. № 4. С. 26—33.
8. Zhiting Hu, Xueze Ma, Zhengzhong Liu, Eduard Hovy, Eric Xing. Harnessing Deep Neural Networks with Logic Rules // Computer Science Learning. 2016. P. 2410—2420. arXiv: 1603.06318.
9. Alex Graves, Greg Wayne, Malcolm Reynolds, Tim Harley, Ivo Danihelka, Agnieszka GrabskaBarwinska, Sergio Gómez Colmenarejo, Edward Grefenstette, Tiago Ramalho, John Agapiou, et al. Hybrid computing using a neural network with dynamic external memory. Nature, 2016. № 538 (7626). P. 471—476.
10. Шибзухов З. М. О поточечно корректных операциях над алгоритмами распознавания и прогнозирования // Доклады РАН. 2013, Т. 450, № 1. С. 24—27.
11. Shibzukhov Z. M. Correct Aggregation Operations with Algorithms // Pattern Recognition and Image Analysis. 2014, Vol. 24, N. 3. P. 377—382.
12. Шибзухов З. М. О некоторых конструктивных и корректных классах алгебраических СП-алгоритмов // Доклады РАН, 2010. Т. 432, № 4. С. 465—468.
13. Тимофеев А. В., Пшибихов В. Х. Алгоритмы обучения и минимизации сложности полиномиальных распознающих систем // Известия АН СССР. Техническая кибернетика. 1974. № 7. С. 214—217.
14. Тимофеев А. В., Лютикова Л. А. Развитие и применение многозначных логик и сетевых потоков в интеллектуальных системах // Труды СПИИ РАН. Вып. 2, 2005. С. 114—126.
15. Лютикова Л. А., Шматова Е. В. Анализ и синтез алгоритмов распознавания образов с использованием переменного-значной логики // Информационные технологии. 2016. Т. 22, № 4. С. 292—297.
16. Лютикова Л. А. Использование математической логики с переменной значностью при моделировании систем знаний // Вестник Самарского государственного университета. Естественнонаучная серия. 2008. № 6 (65). С. 20—27.

L. A. Lyutikova, Head of the Department, e-mail: lylarisa@yandex.ru,

E. V. Shmatova, Junior Researcher, e-mail: lenavsh@yandex.ru,

Institute of Applied Mathematics and Automation of Kabardin-Balkar Scientific Centre of RAS
(IAMA KBSC RAS), Nalchik

A Logical Approach to the Correction of the Results of the Operation of $\Sigma\Pi$ -Neural Networks

The paper considers the method of constructing a logical corrector for the operation of $\Sigma\Pi$ -neural networks when solving recognition problems. A method is proposed for detecting implicit regularities, according to the structure of the $\Sigma\Pi$ -neuron, which can enhance the adaptive properties of the recognition system. It is argued that the combined approach to the organization of the recognition system increases its effectiveness and allows in cases of an incorrect response of the $\Sigma\Pi$ -neuron as a solution to indicate the objects closest to the requested attributes.

Keywords: logical analysis, data analysis, algorithm, $\Sigma\Pi$ -neuron, training sample, decision trees, corrective operations

References

1. Zhuravljov Ju. I. Ob algebraicheskom podhode k resheniju zadach raspoznavanija ili klassifikacii, *Problemy kibernetiki*, 1978, vol. 33, pp. 5—68 (in Russian).
2. Flah P. *Mashinnoe obuchenie. Nauka i isskustvo postroenija algoritmov, kotorye izvlekajut znaniya iz dannyh*, Moscow, MDK Press, 2015. 400 p. (in Russian).
3. Voroncov K. V. Optimizacionnye metody linejnoi i monotonnoj korrekcii v algebraicheskom podhode k probleme raspoznavanija, *Zhurnal vychislitel'noj matematiki i matematicheskoj fiziki*, 2000, vol. 40, no. 1, pp. 166—176 (in Russian).
4. Ablamejko S. V., Birjukov A. S., Dokukin A. A., D'jakonov A. G., Zhuravlev Ju. I., Krasnoproschin V. V., Obrazcov V. A., Romanov M. Ju., Rjazanov V. V. Prakticheskie algoritmy algebraicheskoj i logicheskoj korrekcii v zadachah raspoznavanija po precedentam, *Zhurnal vychislitel'noj matematiki i matematicheskoj fiziki*, 2014, vol. 54, no. 12, pp. 1979. (in Russian).
5. Timofeev A. V., Kosovskaja T. M. Nejrosetevye metody logicheskogo opisanija i raspoznavanija slozhnyh obrazov, *Trudy SPIIRAN*, 2013, 27, pp. 144—155 (in Russian).
6. Djukova E. V., Zhuravlev Ju. I., Prokof'ev P. A. Metody povyshenija jeffektivnosti logicheskikh korrektorov, *Mashinnoe obuchenie i analiz dannyh*, 2015, vol. 1, no. 11, pp. 1555—1583 (in Russian).
7. Gridin V. N., Solodovnikov V. I., Evdokimov I. A., Filipkov S. V. Postroenie derev'ev reshenij i izvlechenie pravil iz obuchennyh nejronnyh setej, *Iskusstvennyj intellekt i prinjatje reshenij*, 2013, no. 4, pp. 26—33.

8. Zhiting Hu, Xueze Ma, Zhengzhong Liu, Eduard Hovy, Eric Xing. Harnessing Deep Neural Networks with Logic Rules, *Computer Science Learning*. 2016. P. 2410–2420. arXiv: 1603.06318.
9. Alex Graves, Greg Wayne, Malcolm Reynolds, Tim Harley, Ivo Danihelka, Agnieszka GrabskaBarwinska, Sergio Gómez Colmenarejo, Edward Grefenstette, Tiago Ramalho, John Agapiou et al. Hybrid computing using a neural network with dynamic external memory, *Nature*, 2016, no. 538 (7626), pp. 471–476.
10. Shibzuhov Z. M. O potochechno korrektnyh operacijah nad algoritmami raspoznavanija i prognozirovanija, *Doklady RAN*, 2013, vol. 450, no. 1, pp. 24–27 (in Russian).
11. Shibzuhov Z. M. Correct Aggregation Operations with Algorithms, *Pattern Recognition and Image Analysis*, 2014, vol. 24, no. 3, pp. 377–382.
12. Shibzuhov Z. M. O nekotoryh konstruktivnyh i korrektnyh klassah algebraicheskikh $\Sigma\Pi$ -algoritmov, *Doklady RAN*, 2010, vol. 432, no. 4, pp. 465–468 (in Russian).
13. Timofeev A. V., Pshibihov V. H. Algoritmy obuchenija i minimizacii slozhnosti polinomial'nyh raspoznajushhih sistem, *Izvestija AN SSSR. Tehnicheskaja kibernetika*, 1974, no. 7, pp. 214–217 (in Russian).
14. Timofeev A. V., Ljutikova L. A. Razvitie i primenenie mnogoznachnyh logik i setevyh potokov v intellektual'nyh sistemah, *Trudy SPII RAN*, 2005, vyp. 2, pp. 114–126 (in Russian).
15. Ljutikova L. A., Shmatova E. V. Analiz i sintez algoritmov raspoznavanija obrazov s ispol'zovaniem peremennno-znachnoj logiki, *Informacionnye tehnologii*, 2016, vol. 22, no. 4, pp. 292–297 (in Russian).
16. Ljutikova L. A. Ispol'zovanie matematicheskoy logiki s peremennoj znachnost' pri modelirovanii sistem znaniy, *Vestnik Samarskogo gosudarstvennogo universiteta. Estestvennonauchnaja serija*, 2008, no. 6 (65), pp. 20–27 (in Russian).

УДК 004.93

С. В. Куликов, науч. сотр., e-mail: kulikov@deepmark.ru,
 О. С. Захаров, науч. сотр., e-mail: zakharov@deepmark.ru,
 Д. Ю. Андреев, ген. директор, e-mail: andreev@deepmark.ru,
 ООО "Лаборатория умных технологий", г. Пенза

Исследование возможности совместного применения нейросетевого преобразователя биометрия—код и глубокой сверточной нейронной сети в распознавании лиц¹

Проводится анализ возможности использования нейросетевых преобразователей биометрия—код (НПБК), отвечающих требованиям серии стандартов ГОСТ Р 52633, в задаче извлечения стабильного ключа из изображения лица. НПБК используется в качестве последнего слоя заранее обученной глубокой сверточной нейросетевой модели. По методике, соответствующей ГОСТ Р 52633.1—2009, проводится оценка показателей стабильности, уникальности и качества параметров, получаемых на выходе глубокой нейросетевой модели, для анализа возможности обучения НПБК на выходных параметрах глубокой нейросетевой модели. Проведено тестирование ряда конфигураций НПБК (соотношение числа нейронов и числа входов каждого нейрона), выбранных согласно ГОСТ Р 52633.5—2011, и сравнение полученных ROC-кривых с аналогичными кривыми, полученными для шаблонов на базе Евклидова расстояния и машин опорных векторов.

Ключевые слова: распознавание лиц, криптографический ключ, глубокая сверточная нейронная сеть, нейросетевой преобразователь биометрия-код, НПБК, машина опорных векторов, Евклидово расстояние, показатель уникальности, показатель стабильности, показатель качества, ROC-кривая

Введение

Глубокие сверточные нейронные сети в настоящий момент не имеют конкурентов в области распознавания лиц. Тем не менее, проблема извлечения стабильного ключа с высокой энтропией из изображения лица остается открытой, хотя необходимость использования глубокой нейронной сети в этой задаче и не вызывает сомнений.

Глубокие сверточные нейронные сети — специальный класс многослойных нейронных се-

тей, который наиболее широко применяется для распознавания изображений. Такие сети состоят из большого числа слоев, обычно — несколько десятков, и содержат среди прочих слои, применяющие к входным данным операцию свертки.

Существует класс задач, в которых требуется преобразовывать биометрический образ в код, обладающий свойствами криптографического ключа (*biometric encryption*). Возможность получения криптографического ключа из биометрических данных позволяет обеспечивать дополнительную безопасность и обезличенность при организации биометрических систем. В частности, в такой системе база персональных данных, в том числе биометрических, может быть орга-

¹ Работа выполнена при финансовой поддержке Фонда содействия инновациям (договор № 1554ГС1/24419).