

Представлена функціональна структура системи нейросетевого розпізнавання образів об'єктів управління виробничого або соціального середовища по статистичній інформації та обґрунтована актуальність розробки підсистеми підтримки прийняття рішень на базі нейромережевої моделі подання знань. Для створення машини нейросетевого виведення запропонований метод підтримки прийняття класифікаційних рішень за допомогою самоорганізованого шару Кохонена

Ключові слова: система підтримки прийняття рішень, розпізнавання образів, моделі подання знань, нейронні мережі Кохонена

Представлена функциональная структура системы нейросетевого распознавания образов объектов управления производственной или социальной среды по статистической информации и обоснована актуальность разработки подсистемы поддержки принятия решений на базе нейросетевой модели представления знаний. Для создания машины нейросетевого вывода предложен метод поддержки принятия классификационных решений с помощью самоорганизующегося слоя Кохонена

Ключевые слова: система поддержки принятия решений, распознавание образов, модели представления знаний, нейронные сети Кохонена

УДК 004.8

DOI: 10.15587/1729-4061.2015.56429

РАЗРАБОТКА ПОДСИСТЕМЫ ПОДДЕРЖКИ ПРИНЯТИЯ РЕШЕНИЙ В СИСТЕМАХ НЕЙРОСЕТЕВОГО РАСПОЗНАВАНИЯ ОБРАЗОВ ПО СТАТИСТИЧЕСКОЙ ИНФОРМАЦИИ

Е. А. Арсирій

Доктор технических наук, доцент*

E-mail: arsiriy@te.net.ua

О. С. Маникаева

Аспирант*

E-mail: manikaeva@gmail.com

А. П. Василевская

Младший научный сотрудник**

E-mail: sauterelle@mail.ru

*Кафедра информационных систем***

Научно-исследовательская часть*

***Одесский национальный политехнический университет
пр. Шевченко, 1, м. Одеса, Украина, 65044

1. Введение

Современные вычислительные системы позволяют накапливать большие массивы разнородных статистических данных наблюдений за состоянием объектов управления из производственной или социальной среды. К сожалению, машинная форма представления таких данных содержит информацию, необходимую для экспертной оценки состояния объектов управления только в *неявном виде*, и для ее извлечения с целью принятия управленческого решения необходимо использовать специальные методы анализа. Так, например, для принятия решений по организации специализированного библиотечно-информационного обслуживания эксперту-аналитику необходимо оценить преимущественные интересы, требования и предпочтения читателей, используя статистические данные об их личном и образовательном уровне (пол, возраст, образование, специализация), активности (частота и цель посещений библиотеки, основание для выбора литературы), литературных предпочтениях (развлекательное, профессиональное и пр. чтение) [1].

А проведение полной экспертизы знаний выпускника учебного заведения с последующим формированием рекомендаций по специфике трудоустройства невозможно без оценки данных о качественном составе преподавателей, адекватности учебных программ и технологий проведения занятий требованиям практики, предварительном уровне подготовки обучаемых и др. [2]. В результате выделился класс задач, связанных с *распознаванием образов (РО)*, – подходом, позволяющим на основе анализа конечной совокупности наборов статистических данных наблюдений (признаков) за объектами (образами), построить *алгоритм*, способный для любого объекта (образа) выдать достаточно точный его образ (класс). Для измерения *точности* распознавания образов вводится некоторый функционал качества.


2. Анализ литературных данных и постановка проблемы

Известно, что РО определяется как отнесение получаемого образа к определенному классу с помощью


выделения существенных признаков, характеризующих этот образ, из общей массы несущественных признаков.

Образ представляется как набор из m наблюдений, каждое из которых можно рассматривать как точку x в m -мерном пространстве наблюдений (данных). Извлечение признаков описывается с помощью преобразования, которое переводит точку x в промежуточную точку y в q -мерном пространстве признаков, где $q < m$ [3]. Классификация – преобразование, которое отображает промежуточную точку y в один из классов r -мерного пространства решений (где r – количество классов) (рис. 1, а). При этом границы областей пространства решений, которые ассоциируются с определенным классом, формируются в процессе обучения. А точность решения задачи РО зависит от выбора множества признаков и классов, при котором обеспечивается компактное представление образов одного класса в пространстве признаков.


В тех случаях, когда имеющиеся наборы наблюдений недостаточно полны, неоднородны или искажены, применяют обучение распознавания образов на основе нейронных сетей (НС) – нейросетевое распознавание образов (НРО).



а



б



в

Рис. 1. Схема РО: а – классический подход; б – однородное НРО; в – неоднородное НРО

Системы НРО можно разделить на *однородные*, состоящие из единой, решающей задачу классификации, многослойной сети прямого распространения сигнала (Multilayer Perceptron), и *неоднородные*, включающие

две нейронные сети – кластеризации и классификации. При этом в однородных системах НРО нейронная сеть обучается с помощью «учителя» (алгоритм обратного распространения ошибки), а задача извлечения признаков для классификации выполняется нейронами скрытых слоев сети (рис. 1, б). В неоднородных системах НРО, обучаемых без учителя и с учителем соответственно, извлечение признаков выполняется самоорганизующейся кластеризационной сетью (рис. 1, в). Примерами неоднородных сетей являются сети векторного квантования (Learning Vector Quantization) и встречного распространения сигнала (Counterpropagation Network). Сети векторного квантования являются развитием самоорганизующихся сетей Кохонена и состоят из конкурирующего и линейного слоев [4]. Сети встречного распространения представляют собой двухслойную сеть со слоями Кохонена и Гроссберга [5].

Сложность проектирования однородных и неоднородных систем НРО для решения практических задач РО по статистической информации связана с необходимостью использования при построении обучающей выборки типа «данные наблюдений – набор признаков – номер класса» априорной информации о количестве классов и множестве признаков, относящихся к заданному классу. Полученные данные наблюдений для таких задач являются слабоструктурированными и неопределенными, потому что собираются из различных источников, интерпретируются с помощью различных и не всегда связанных шкал и часто противоречат друг другу. А экспертное решение об отнесении образа к определенному классу на основе анализа признаков таких данных является неоднозначным и зависит от квалификации лица, принимающего такое решение (ЛПР).

Для устранения перечисленных недостатков систем НРО и облегчения труда ЛПР, выполняющих анализ статических данных, с целью построения обучающей выборки для проведения экспертизы состояния объектов управления из производственной или социальной среды используют специальные программные системы – проблемно-ориентированные системы поддержки принятия решения (СППР). Такие СППР ориентированы на аналитическую обработку большого объема данных с целью получения необходимых для принятия решений, знаний и, как правило, состоит из подсистем ввода, хранения, анализа данных и принятия решений, объединенных между собой с помощью интерфейсных средств для ЛПР [6, 7]. В системах НРО существенной особенностью проектирования СППР является зависимость ее структуры от избранной нейросетевой модели представления знаний и, как следствие, ее способности к обучению и/или самообучению [8, 9]. Таким образом, моделирование действий ЛПР становится возможным благодаря наличию в структуре СППР *базы знаний* и ее *интеллектуального редактора, машины нейросетевого вывода и подсистемы объяснений*. При этом машина нейросетевого вывода генерирует алгоритм процесса решения на основе базы моделей нейронных сетей и предварительных оценок ЛПР. А средства подсистемы объяснений позволяет с помощью критерия качества оценить предлагаемое машиной вывода решение и учесть предпочтения ЛПР при формировании окончательного решения.

3. Цель и задачи исследования

Целью данного исследования является разработка подсистемы поддержки принятия решений в системе нейросетевого распознавания образов, что позволит снизить субъективность и повысить качество экспертных решений при построении обучающих выборок по статистическим данным наблюдений за состоянием объектов управления производственной или социальной среды.

Для достижения поставленной цели необходимо решить следующие задачи:

- разработать функциональную структуру проблемно-ориентированной системы нейросетевого распознавания образов и подсистемы поддержки принятия решений;
- для создания машины нейросетевого вывода разработать метод поддержки принятия классификационных решений с помощью самоорганизующегося слоя Кохонена;
- провести апробацию предлагаемой системы для поддержки принятия решений о классе инициализируемого проекта по охране труда на основе экспертных оценок текущего уровня организации и условий труда на предприятии.

4. Разработка функциональной структуры проблемно-ориентированной системы нейросетевого распознавания образов

На основе проведенного анализа систем НРО и структур СППР предложена функциональная структура проблемно-ориентированной системы НРО состоящая из трех подсистем: *подготовки* исходных данных для РО и *хранения* агрегированных данных, нейросетевых моделей и знаний об объекте управления производственной или социальной среды, а также *поддержки принятия решения* о его состоянии (рис. 2).

Подсистема подготовки исходных данных системы НРО построена по принципу ETL-систем (Extraction, Transformation Loading) [10] и содержит инструментальные средства:

- извлечения детализированных данных различных форматов из разнотипных информационных источников об объекте управления;
- агрегирования и преобразования данных в единый формат понятный ЛПП для проведения экспертизы состояния объекта управления;
- загрузки агрегированных данных (обучающих выборок) в хранилище данных.

Для разработки подсистемы подготовки проблемно-ориентированной НРО предложены модели детализированных данных D_j объекта управления в m -мерном пространстве наблюдений и агрегированных данных D_{Ai} в n -мерном пространстве признаков ($n < m$), которые формально задаются следующими кортежами:

$$D_{Dj} = \langle V_j, T_j, F_j, S_j, Q_j, Mt_j \rangle, j=1, m, \quad (1)$$

где $V_j, T_j, F_j, S_j, Q_j, Mt_j$ – значение, тип, формат, источник, оценка качества, метод трансформации данных j -го наблюдения.

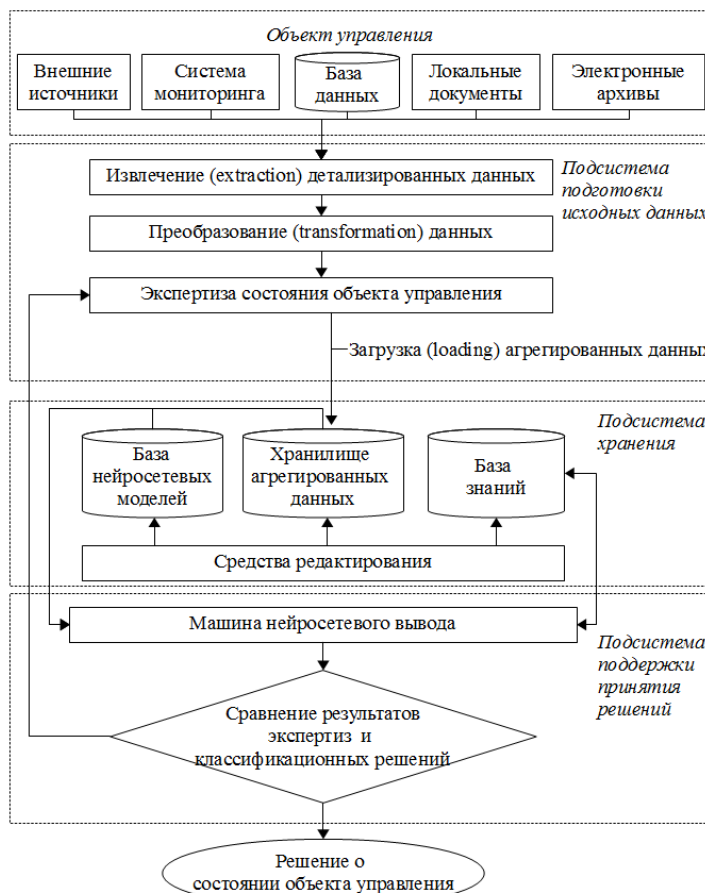


Рис. 2. Функциональная структура проблемно-ориентированной системы НРО

$$D_{Ai} = \langle X_i, P \rangle, i=1, n, \quad (2)$$

где X_i – значение i -го признака, полученное с помощью агрегирования (объединения) значений наблюдений V_j , преобразованных на основе метода трансформации Mt_j , при этом

$$X_i = \bigcup_{j=1}^{q_i} Mt_j(V_j) \text{ и } \sum_{i=1}^n q_i = m,$$

где P – значение результата экспертизы состояния объекта управления.

Экспертиза состояния объекта управления проводится ЛПП на основе анализа наборов агрегированных и преобразованных значений X_i из признакового пространства.

Подсистема хранения системы НРО состоит из хранилища агрегированных данных, баз нейросетевых моделей и знаний, а также средств их редактирования.

Хранилище агрегированных данных содержит специальным образом организованные в виде обучающих выборок (2) хронологические наборы данных наблюдений и оценок состояния объекта управления производственной или социальной среды.

База нейросетевых моделей содержит функции формирования шаблонов основных нейронных сетей таких как: прямого распространения сигнала (простейшие и многослойные перцептроны, линейные сети), сетей встречного и обратного распространения,

радиально-базисных сетей, самоорганизующихся слов и карт Кохонена и сетей векторного квантования.

Средства редактирования – это комплекс функций, позволяющих визуализировать, создавать (добавлять), редактировать, удалять и обучать и дообучать модели нейронных сетей из базы нейросетевых моделей, данные обучающих и контрольных выборок из хранилища агрегированных данных и проекты нейронных сетей из базы знаний.

База знаний включает готовые проекты нейронных сетей, для обучения и/или самообучения которых использованы три блока подсистемы хранения системы НРО. Это данные обучающих выборок о состояниях объекта управления из хранилища агрегированных данных, зависящий от условия решаемой задачи (цели обучения) шаблон нейронной сети и одна или несколько функций обучения из средств редактирования.

Для разработки машины нейросетевого вывода предложен метод поддержки принятия классификационных решений с помощью машинного обучения самоорганизующегося слоя Кохонена. Подробное описание метода приводится в 5-том подразделе данной статьи.

Блок сравнения результатов в системе НРО служит в качестве альтернативы, так называемой, подсистеме объяснений и предназначен для проверки качества экспертных оценок о состоянии объекта путем сравнения результатов экспертизы состояния объекта и классификационных решений полученных из машины вывода. В нем по всем примерам обучающей выборки рассчитываются ошибки классификации 1 и 2-го рода и их относительные доли истинно положительных случаев и истинно отрицательных случаев [11].

$$TPR = \frac{TP}{TP + FN} \cdot 100 \%, \quad (3)$$

где TPR – относительная доля истинно положительных случаев (True Positives Rate – TPR); TP – истинно положительные случаи (верно классифицированные положительные примеры); FN – положительные примеры, классифицированные как отрицательные (ошибка I рода).

$$FPR = \frac{FP}{TN + FP} \cdot 100 \%, \quad (4)$$

где FPR – относительная доля истинно отрицательных случаев (False Positives Rate – FPR); FP – отрицательные примеры, классифицированные как положительные (ошибка II рода); TN – истинно отрицательные случаи (верно классифицированные отрицательные примеры).

Значения ошибок (FN и FP) оценок ЛПП передаются ему для анализа и выполнения корректировки обучающей выборки, после которой выполняется возврат к машине нейросетевого вывода (рис. 2) с целью проведения еще одной итерации обучения.

5. Метод поддержки принятия классификационных решений с помощью самоорганизующегося слоя Кохонена

При разработке машины нейросетевого вывода проблемно-ориентированной системы НРО исполь-

зован предложенный метод поддержки принятия классификационных решений с помощью машинного обучения самоорганизующегося слоя Кохонена, сформированного на основе соответствующего шаблона из базы нейросетевых моделей (рис. 3).




Рис. 3. Нейросетевая модель W слоя Кохонена

Машинное обучение слоя Кохонена выполняется с помощью агрегированных данных обучающей выборки (2), которые извлекаются из хранилища в следующем виде:

$$D_A = \langle X, P \rangle = \left(\begin{matrix} X_{11} & X_{12} & \dots & X_{1n} \\ X_{21} & X_{22} & \dots & X_{2n} \\ \dots & \dots & \dots & \dots \\ X_{k1} & X_{k2} & \dots & X_{kn} \\ \dots & \dots & \dots & \dots \\ X_{N1} & X_{N2} & \dots & X_{Nn} \end{matrix} \right), \left(\begin{matrix} P_1 \\ P_2 \\ \dots \\ P_k \\ \dots \\ P_N \end{matrix} \right),$$

$$k = \overline{1, N}, \quad i = \overline{1, n}, \quad (5)$$

где N – количество векторов в выборке, n – количество признаков, а P_k – итоговая оценка (номер класса).

В основу машинного обучения слоя Кохонена положен процесс кластеризации k-го вектора X_{ki}, где i = $\overline{1, n}$, который предусматривает последовательное выполнение этапов *самоорганизации* нейронов вычислительного слоя Кохонена, *градуировки* элементов выходного вектора обучающей выборки и окончательной *маркировки* нейронов слоя Кохонена (рис. 4).

Этап 1. Классическая процедура самоорганизации вычислительного слоя Кохонена реализована с помощью итеративного алгоритма WTA (Winner Takes All) [12]. Согласно алгоритму WTA на вход слоя Кохонена (рис. 3) последовательно подаются значения векторов из обучающей выборки X_{ki}, i = $\overline{1, n}$, k = $\overline{1, N}$, где n – количество признаков, а N – количество векторов в выборке.

Целью самоорганизации является минимизация разницы расстояний:

$$d(x_{ki}, w_{ij}) \rightarrow \min d(x_{ki}, w_{ij}) \quad (6)$$

между элементами входных векторов x_{ki} и весовыми коэффициентами w_{ij} нейрона-победителя слоя Кохонена, по формуле корректировки:

$$w_{ij}(t+1) = w_{ij}(t) + \eta(t)[x_{ki} - w_{ij}(t)], \quad (7)$$

где η(t) – изменяемый во времени коэффициент шага коррекции.

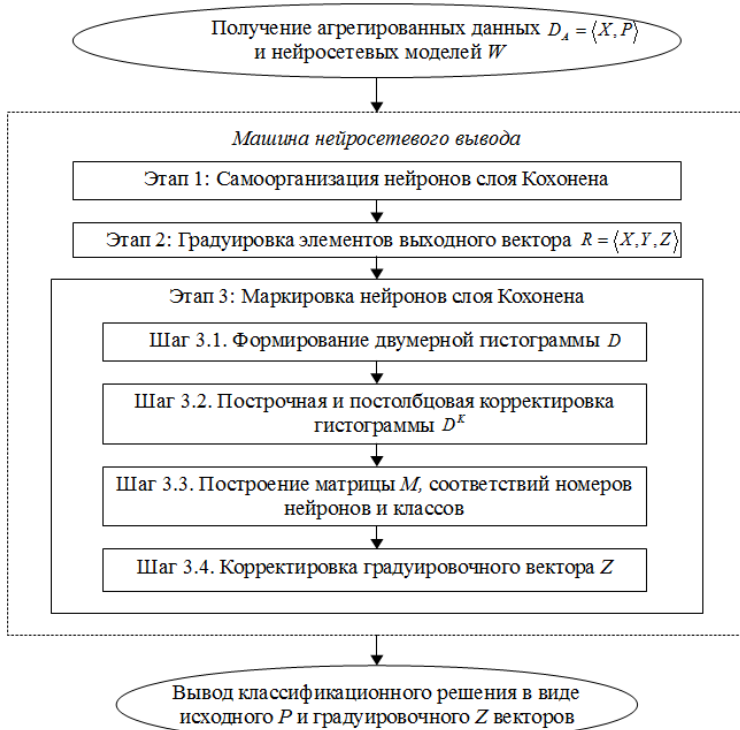


Рис. 4. Поддержка принятия решения в машине нейросетевого вывода

В качестве $\eta(t)$ обычно выбирается монотонно убывающая функция ($0 < \eta(t) < 1$). В качестве меры расстояния используется евклидово расстояние:

$$d(x_{ki}, w_{ij}) = \sqrt{\sum_{i=1}^n (x_{ki} - w_{ij})^2}. \tag{8}$$

Этап 2. При выполнении процедуры градуировки элементов выходного вектора обучающей выборки на вход самоорганизованного слоя Кохонена, последовательно подаются значения векторов из обучающей выборки X_{ki} . Где на основе (8) для каждого из них формируются значения вектора выходов Y_{kj} , $j = \overline{1, m}$, где m – число нейронов (классов). Порядковый номер нейрона-победителя j k -того вектора Y_{kj} присваивается в качестве значения k -му элементу градуировочного вектора Z_k . Таким образом, после выполнения процедуры градуировки имеем предварительное решение в следующем виде:

$$R_p = \langle X, Y, Z \rangle = \left\langle \begin{pmatrix} x_{11} & x_{12} & \dots & x_{1n} \\ x_{21} & x_{22} & \dots & x_{2n} \\ \dots & \dots & \dots & \dots \\ x_{k1} & x_{k2} & \dots & x_{kn} \\ \dots & \dots & \dots & \dots \\ x_{N1} & x_{N2} & \dots & x_{Nn} \end{pmatrix}, \begin{pmatrix} y_{11} & y_{12} & \dots & y_{1m} \\ y_{21} & y_{22} & \dots & y_{2m} \\ \dots & \dots & \dots & \dots \\ y_{k1} & y_{k2} & \dots & y_{km} \\ \dots & \dots & \dots & \dots \\ y_{N1} & y_{N2} & \dots & y_{Nm} \end{pmatrix}, \begin{pmatrix} z_1 \\ z_2 \\ \dots \\ z_k \\ \dots \\ z_N \end{pmatrix} \right\rangle, \tag{9}$$

$k = \overline{1, N}, i = \overline{1, n},$

где элементы матрицы X соответствуют формуле (5), элементы бинарной матрицы желаемых выходов Y формируются в результате обучения вычислительного слоя Кохонена и для k -го вектора $Y_{kj} = 1$, если

j – номер нейрона победителя и $Y_{kj} = 0$ – во всех остальных случаях, а элементы градуировочного вектора Z представляют собой порядковый номер нейрона-победителя j .

Этап 3. Для определения соответствия между значением итоговой оценки P_k (номер класса) (5) и значением номера нейрона победителя градуировочного вектора Z_k (9), предложена процедура маркировки нейронов слоя Кохонена номерами классов агрегированных данных обучающей выборки (5). Процедура маркировки требует выполнения 3-х шагов (рис. 4).

Шаг 3.1. Для всех примеров обучающей выборки формируем двумерную гистограмму $D_{l,j}$ (квадратную матрицу) попарных совпадений номеров нейронов и классов $Z_{kl} = P_{kj}$, где $l, j = \overline{1, m}$. Пример построения гистограммы $D_{l,j}$ на мнемокоде:

```

D=0; /*обнуление элементов матрицы*/
for l=1:m
    for j=1:size(Y,2) /*количество классов*/
        for k=1:size(Y,1) /*количество примеров обучающей выборки*/
            if ((P(k)=l) && (Z(k,l)==1))
                D(l,j)=D(l,j)+1;
            end
        end
    end
end
end
end
    
```

Шаг 3.2. Выполняем построчную и постолбцовую корректировку гистограммы $D_{l,j}$, оставляя без изменения только те значения элементов, которые удовлетворяют условию:

$$\begin{cases} \max(D_l) = \max(D_j), \\ l = j, \\ \max(D_j) < 0. \end{cases} \tag{10}$$

Остальные значения пересекающихся строки и столбца обнуляем. Пример построчно-постолбцовой корректировки гистограммы $D_{l,j}$ на мнемокоде:

```

for j=1:size(D,1)
    for l=1:size(D,1)
        if (D(l,j)==max(D(:,j))) &&
            (D(l,j)==max(D(l,:))) && (D(l,j)>0)
            D(:,j)=0;
            D(l,:)=0;
        end
    end
end
end
    
```

Как видим, корректировка двумерной гистограммы $D_{l,j}$ выполняется итерационно, пока в каждой строке и столбце останется только одно не нулевое значение. Результат корректировки записывается в $D_{l,j}^k$.

Шаг 3.3. Скорректированная двумерная гистограмма $D_{l,j}^k$ попарных совпадений преобразуется ма-

трицу $M_{k,l}$, $k = \overline{1,2}$ соответствий номеров нейронов и классов для всех примеров обучающей выборки:

```
M=0
for l=1:size(Dk,1)
  for j=1:size(Dk,1)
    if Dk(l,j)>0
      M(1,l)=1;
      M(2,l)=j;
    end
  end
end
```

Шаг 3.4. На последнем шаге выполняем окончательную корректировку градуировочного вектора Z с помощью матрицы соответствий номеров нейронов и классов. Далее на основе (5) и полученного вектора Z формируем классификационное решение в виде:

$$R_k = \langle X, P, Z \rangle = \left\langle \begin{pmatrix} x_{11} & x_{12} & \dots & x_{1n} \\ x_{21} & x_{22} & \dots & x_{2n} \\ \dots & \dots & \dots & \dots \\ x_{k1} & x_{k2} & \dots & x_{kn} \\ \dots & \dots & \dots & \dots \\ x_{N1} & x_{N2} & \dots & x_{Nn} \end{pmatrix}, \begin{pmatrix} p_1 \\ p_2 \\ \dots \\ p_k \\ \dots \\ p_N \end{pmatrix}, \begin{pmatrix} z_1 \\ z_2 \\ \dots \\ z_k \\ \dots \\ z_N \end{pmatrix} \right\rangle,$$

$$k = \overline{1, N}, \quad i = \overline{1, n}, \quad (11)$$

и передаем его в блок сравнения результатов (рис. 2) для проверки качества экспертных оценок P о состоянии объекта путем сравнения с решением Z

6. Аprobация системы НРО для задачи инициализации проектов охраны труда

Исследования показывают, что время и риски выполнения, стоимость и качество проектов охраны труда, реализуемых на украинских предприятиях, во многом зависят от их содержания, которое определяется ЛПР на стадии инициализации [13]. Решение об инициализации проектов охраны труда принимается на основе анализа текущего состояния уровня организации и условий труда на предприятии по группам факторов (признаков) [14].

Для отражения текущего уровня организации и условий труда на предприятии и поддержки принятия решений по инициализации проектов охраны труда используются детализированные данные, которые собираются из различных источников, агрегируются в группы и трансформируются в соответствии выделенными качественными и комплексными количественно-качественными признаками. Так, например, к группе «*организация труда*» относят качественные признаки, значения которых получают в результате проведения комплексной экспертизы по определению уровня организационных мероприятий по охране труда на предприятии. К таким признакам относятся качественно определяемые уровни технических и технологических средств труда, коллективных и индивидуальных средств защиты, материального и хозяйственно-бытового обеспечения, а также тяжести

и напряженности труда [15]. При проведении экспертизы для ЛПР разработана четырехбальная шкала, позволяющая оценить организацию труда на предприятии как: «отличную», «допустимую», «плохую» и «хаотичную».

К группе «*условия труда*» относят количественно-качественные признаки, оказывающие влияние на работоспособность и здоровье работника, значения, которых получают с помощью средств мониторинга производственной среды. К таким признакам относятся численно определяемые уровни аэрозольного, электромагнитного, акустического, химического и биологического воздействия, ионизирующего излучения, микроклимата, освещенности и вибрации. В результате анализа данных мониторинга в соответствии с предложенной шкалой, зависящей от уровня предельно допустимой концентрации исследуемого фактора, ЛПР оценивает состояние условий труда как: «оптимальное», «допустимое», «вредное», «опасное», «экстремальное».

Исследования детализированных данных мониторинга предприятия по группе условий труда показали, что такие данные являются слабоструктурированными и неопределенными, потому что собираются из различных источников, интерпретируются с помощью различных и не всегда связанных шкал и часто противоречат друг другу. А решение об оценке состояния условий труда на основе анализа таких данных, которое ЛПР принимает при проведении экспертизы, является неоднозначным и зависит от его квалификации. Поэтому было предложено использовать для поддержки принятия решений ЛПР по инициализации проектов охраны труда разработанную проблемно-ориентированную систему НРО.

Результаты апробации работы системы НРО при проведении комплексной экспертизы *уровня аэрозольного воздействия*, как одного из факторов условий труда влияющих на инициализации проектов охраны труда показаны на рис. 5. ЛПР определяет *общий уровень* аэрозольного воздействия на основе анализа преобразованных данных о дисперсионном составе, концентрации, времени воздействия и виде аэрозольных частиц, которые отображаются в специальной электронной опросной форме (рис. 5, 1). Полученные таким образом агрегированные данные D_A (рис. 5, 2) через хранилище поступают в машину нейросетевого вывода для проверки качества решения ЛПР. В результате выполнения этапов самоорганизации и градуировки формируется предварительное решение R_p (рис. 5, 3), которое передается на обработку Этапу 3. Для маркировки элементов градуировочного вектора Z из предварительного решения R_p формируется двумерная гистограмма D попарных совпадений номеров нейронов и классов (рис. 5, 4), выполняется ее построчная и постолбцовая корректировка (рис. 5, 5) с целью получения матрицы M соответствий номеров нейронов и классов (рис. 5, 6).

С помощью матрицы соответствий выполняется окончательная корректировка градуировочного вектора Z для формирования классификационного решения R_k (рис. 5, 7, DSS decision). Таким образом, ЛПР может сравнить свое решение и решение, предлагаемое машиной нейросетевого вывода, и в случае необходимости подкорректировать свое решение (рис. 2)

Кроме определения уровня аэрозольного воздействия разработанная система НРО использовалась для определения общих уровней электромагнитного, акустического, химического и биологического воздействия, ионизирующего излучения, микроклимата, освещенности и вибрации. Для сравнения решения ЛПР (Final level) и классификационного решения (DSS decision) с использованием (3) и (4) рассчитывались значения *TPR* и *FPR*. Результаты расчетов *TPR* и *FPR* для всех примеров обучающей выборки по всем определяемым уровням воздействия группы условий труда на предприятии до и после коррек-

тировки и показаны на рис. 6, а, б соответственно. Анализ расчетов значений ошибок 1 (рис. 6) и 2-го (рис. 7) рода до и после проведения корректировки показывает повышение относительной доли *TPR* в среднем на 20 % и снижение на 50 % *FPR* для всех групп условий труда. При этом после проведения корректировки решений ЛПР оценки *TPR* располагаются более равномерно для всех исследуемых уровней воздействия из группы условий труда (рис. 6). А снижение относительной доли истинно отрицательных случаев (*FPR*) особенно заметно для уровней химического и биологического воздействия (рис. 7).

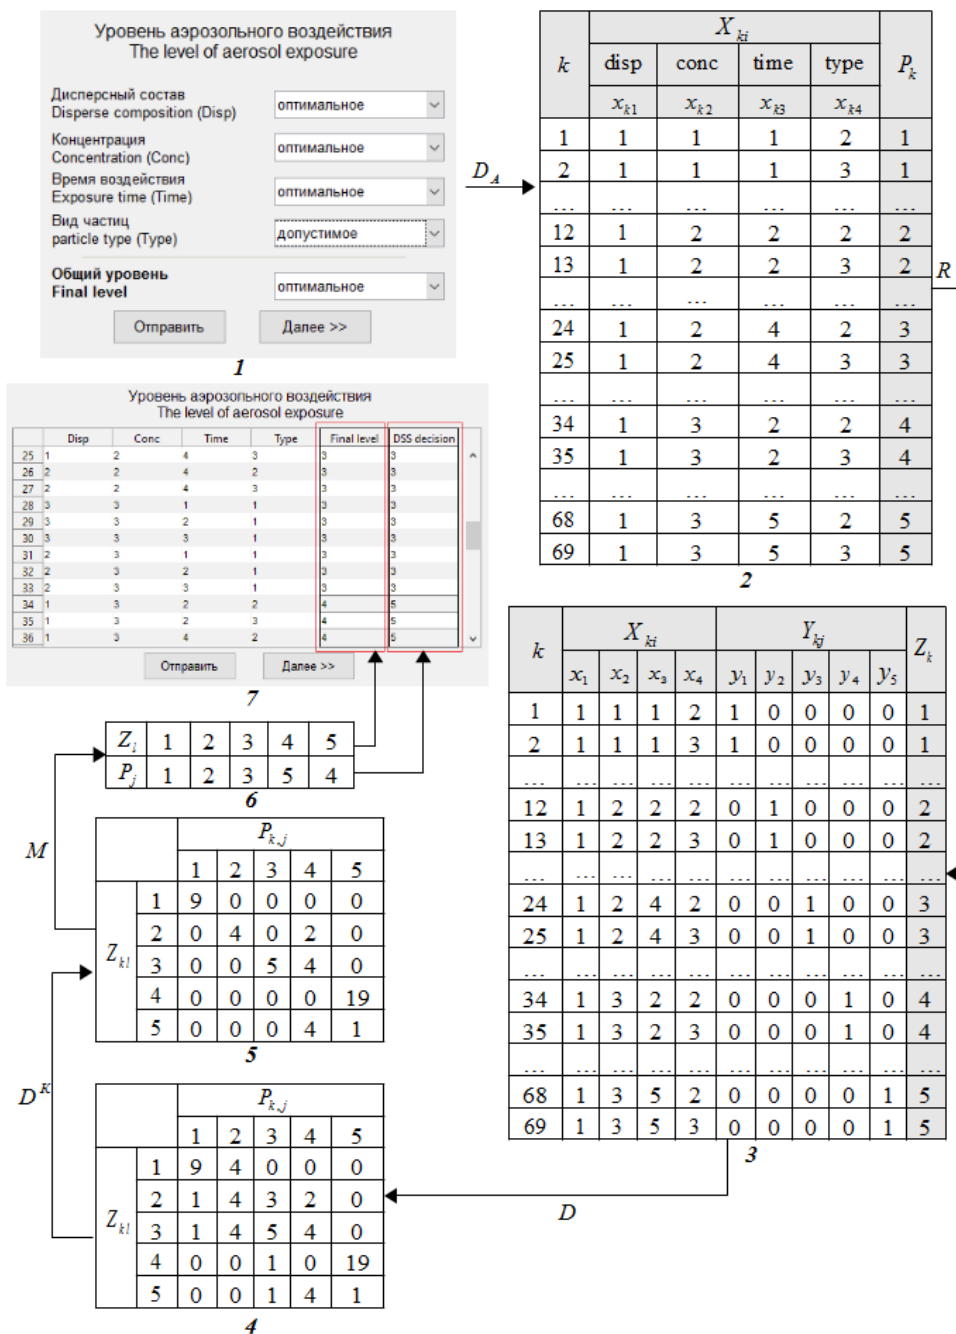




Рис. 5. Результаты апробации работы системы НРО: 1 – подсистема подготовки исходных данных; 2 – получение агрегированных данных из хранилища; 3 – результат процедуры градуировки элементов выходного вектора; 4 – формирование двумерной гистограммы; 5 – построчная и постолбцовая корректировка гистограммы; 6 – матрица соответствий номеров нейронов и классов; 7 – сравнение решений ЛПР и классификационных решений




а




б

Рис. 6. Сравнительные результаты по TPR: до – а и после – б корректировки



а



б

Рис. 7. Сравнительные результаты по FPR: до – а и после – б корректировки

7. Выводы

Таким образом, для разработки подсистемы поддержки принятия решений в системе нейросетевого распознавания образов, которая позволила снизить субъективность и повысить качество экспертных решений при построении обучающих выборок по статистическим данным наблюдений за состоянием объектов управления производственной или социальной среды, были решены следующие задачи.

1. Предложена функциональная структура системы НРО объектов управления производственной или социальной среды по статистической информации. В соответствии с предложенной структурой проблемно-ориентированная система НРО состоит из подсистем подготовки исходных данных для РО и хранения агрегированных данных, нейросетевых моделей и знаний об объекте управления производственной или социальной среды, а также поддержки принятия решения о его состоянии.

2. Разработана подсистема поддержки принятия решений на базе предложенного метода поддержки принятия классификационных решений с помощью самоорганизующегося слоя Кохонена.

3. Разработанный метод поддержки принятия классификационных решений предусматривает последовательное выполнение этапов самоорганизации нейронов вычислительного слоя Кохонена, градуировки элементов выходного вектора обучающей выборки и их окончательной маркировки.

4. Приведен пример реализации предлагаемой подсистемы для поддержки принятия решений о классе инициализируемого проекта по охране труда на основе экспертных оценок текущего уровня организации и условий труда на предприятии.

Использование разработанной подсистемы поддержки принятия решений в системах НРО по статистической информации позволяет выполнять корректировку решений ЛПР в соответствии с решениями машины нейросетевого вывода, и тем самым повысить относительную долю правильных экспертных оценок в среднем на 20 % и снизить на 50 % ложных оценок для ряда задач распознавания образов. В числе последних: определение условий труда на предприятии по уровням аэрозольного электромагнитного, акустического, химического и биологического воздействия, ионизирующего излучения, микроклимата, освещенности и вибрации.

Литература

1. Арсирий, Е. А. Нейросетевое распознавание образов читателей публичной библиотеки для организации специализированного библиотечного обслуживания [Текст] / Е. А. Арсирий, А. А. Саенко // Труды Одесского политехнического университета. – 2011. – № 1 (35). – С. 118–124.
2. Арсирий, Е. А. Нейросетевое формирование интегральной профес-сиональной характеристики в системе дистанционного обучения MOODLE [Текст] / Е. А. Арсирий, Е. Г. Жиленко // Труды Одесского политехнического университета. – 2009. – № 2 (32). – С. 161–166.

3. Хайкин, С. Нейронные сети: полный курс [Текст] / С. Хайкин; пер. с англ.; 2-е изд., испр. – М.: И. Д. Вильямс, 2006. – 1104 с.
4. Kohonen, T. Learning vector quantization [Text] / T. Kohonen // The Handbook of Brain Theory and Neural Networks. – Cambridge, MA : MIT Press, 1995. – P. 537–540.
5. Hecht-Nielsen, R. Counterpropagation networks [Text] / R. Hecht-Nielsen // Proceedings of the IEEE First International Conference on Neural Networks. – San Diego, CA : SOS Printing, 1987. – Vol. 2. – P. 19–32.
6. Трахтенгерц, Э. А. Компьютерная поддержка принятия решений [Текст] / Э. А. Трахтенгерц. – М.: Синтег, 1998. – 376 с.
7. Simon, H. A. The New Science of Management Decision [Text] / H. A. Simon. – N. J.: Prentice-Hall, 1977. – 175 p.
8. Druzdzel, M. J. Decision Support Systems [Text] / M. J. Druzdzel, R. R. Flynn // Encyclopedia of Library and Information Science. – New York, 2002. – Vol. 67, Suppl. 30. – P. 120–133. – Available at: <http://www.pitt.edu/~druzdzel/psfiles/dss.pdf>
9. Флах, П. Машинное обучение. Наука и искусство построения алгоритмов, которые извлекают знания из данных [Текст] / П. Флах – М.: ДМК Пресс, 2015. – 400 с.
10. Vassiliadis, P. Conceptual modeling for ETL processes [Text] / P. Vassiliadis, A. Simitsis, S. Skiadopoulos // Data Warehousing and OLAP (DOLAP'2002) ACM 5th Intl Workshop in conjunction with CIKM'02. – McLean, USA, 2002. – Available at: <http://web.cs.dal.ca/~acosgaya/csci7202/papers/p14-vassiliadis.pdf>
11. Статистические методы. Вероятность и основы статистики. Термины и определения. ГОСТ Р 50779.10-2000. [Электронный ресурс]. – Режим доступа: <http://protect.gost.ru/v.aspx?control=8&baseC=-1&page=0&month=-1&year=-%201&search=&RegNum=1&DocOnPageCount=%2015&id=130411&page%20K=%20A982F469-855A-4B0B-9443-710141B75665>
12. Kohonen, T. The self-organizing map [Text] / T. Kohonen // Proceedings of the IEEE. – 1990. – Vol. 78, Issue 9. – P. 1464–1480. doi: 10.1109/5.58325
13. Гогунський, В. Д. Управління ризиками в проектах з охорони праці як метод усунення шкідливих і небезпечних умов праці [Текст] / В. Д. Гогунский, Ю. С. Чернега // Східно-Європейський журнал передових технологій. – 2013 – Т. 1, № 10 (61). – С. 83–85. – Режим доступу : <http://journals.uran.ua/eejet/article/view/6783/5983>
14. Руководство по системам управления охраной труда [Текст]. МОТ-СУОТ 2001/ ILOOSH 2001. – Женева: Международное бюро труда, 2003. Режим доступа: http://www.ilo.org/wcmsp5/groups/public/@ed_protect/@protrav/@safework/documents/normativeinstrument/wcms_125017.pdf
15. Арсирий, Е. А. Автоматизация представления и извлечения декларативных знаний в цифровом макете предприятия при инициализации проектов охраны труда [Текст] / Е. А. Арсирий, С. Г. Антошук, О. С. Маникаева // Электротехнические и компьютерные системы. – 2015. – № 19 (95). – С. 266–271. – Режим доступа : <http://www.etks.opu.ua/?fetch=articles&with=info&id=719>