

О.С. Маникаева, Е.А. Арсирий, А.П. Василевская

**МАШИННОЕ ОБУЧЕНИЕ САМООРГАНИЗУЮЩЕГОСЯ
СЛОЯ КОХОНЕНА В СИСТЕМАХ НЕЙРОСЕТЕВОГО
РАСПОЗНАВАНИЯ ОБРАЗОВ
ПО СТАТИСТИЧЕСКОЙ ИНФОРМАЦИИ**

Аннотация. При построении систем нейросетевого распознавания образов для принятия решения о состоянии производственной или социальной среды по статистической информации предложено использовать методику машинного обучения на основе кластеризации входного набора признаков, которая предусматривает последовательное выполнение процедур самоорганизации нейронов вычислительного слоя Кохонена, градуировки элементов выходного вектора обучающей выборки и окончательной маркировки нейронов вычислительного слоя Кохонена.

Ключевые слова: машинное обучение, распознавание образов, нейронные сети векторного квантования, самоорганизующиеся слои Кохонена.

Введение. В настоящее время при построении систем информационно-аналитической обработки данных с целью получения не только стандартных отчетов, но и построения правил, зависимостей, тенденций, прогнозов (т.е. извлечения знаний) выделился класс задач связанных с распознаванием состояния (образов) производственной или социальной среды по статистической информации. К примерами таких задач можно отнести: организацию специализированного информационного обслуживания читателей публичной библиотеки в соответствии с оценкой их преимущественных интересов [1], разработку индивидуальной программы переподготовки специалистов на основе оценки их теоретических знаний и практических навыков, а также с учетом требований заказчика [2] или извлечение декларативных знаний по группам организации и условиям труда в цифровом макете предприятия при инициализации проектов по охране труда [3]. Для решения перечисленных и им подобных задач распознавания образов (РО) используется *машинаное обучение* – подход, позволяющий на основе *анализа* конечной совокупности объектов (образов), называемой

обучающей выборкой, построить алгоритм, способный для любого объекта (образа) выдать достаточно точный его образ (класс). Для измерения точности РО вводится некоторый функционал качества.

Актуальность исследований. 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 $q < m$ [4]. 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). Системы НРО можно разделить на однородные, состоящие из единой многослойной сети прямого распространения (Multilayer Perceptron), обучаемой с учителем, при этом задача извлечения признаков выполняется нейронами скрытых слоев сети (рис. 1.б) и неоднородные, состоящие из двух сетей кластеризации (извлечения признаков) и классификации, обучаемых без учителя и с учителем соответственно (рис.1.в). Примерами неоднородных сетей являются сети векторного квантования (Learning Vector Quantization), которые являются развитием самоорганизующихся сетей Кохонена и состоят из конкурирующего и линейного слоев [5], а также сети встречного распространения (Counterpropagation Network) сигнала, представляющие собой также двухслойную сеть со слоями Кохонена и Гроссберга [6].

Сложность построения однородных и неоднородных систем НРО для решения практических задач РО по статистической инфор-

мации 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.

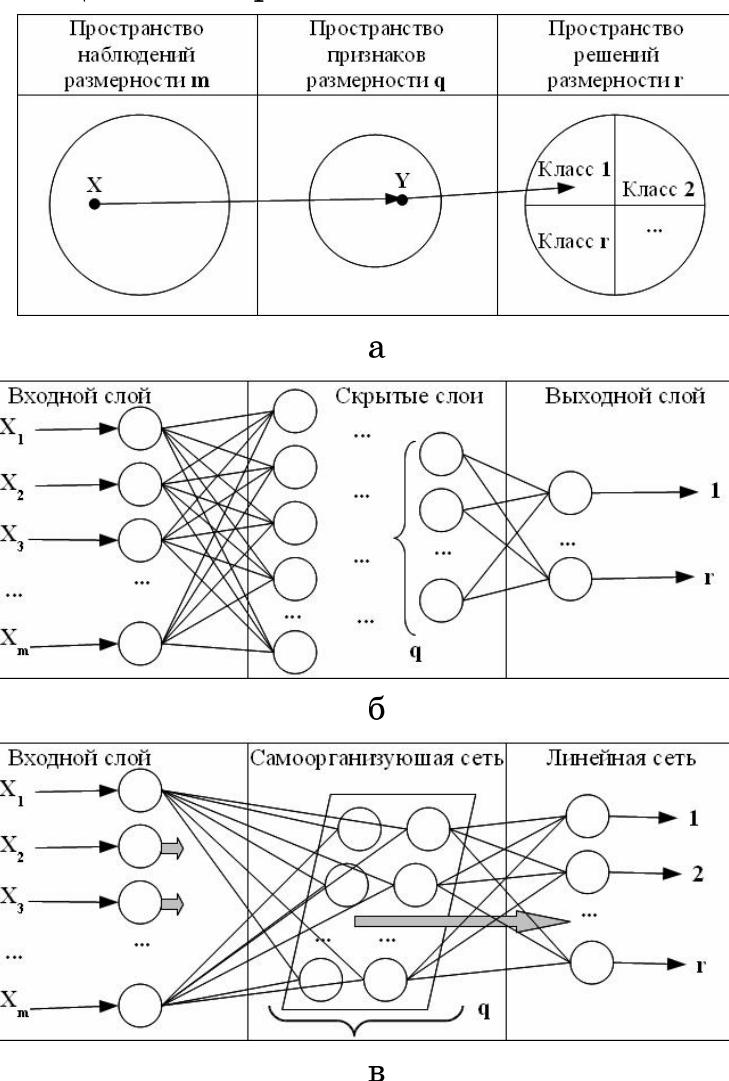


Рисунок 1 – Схема РО: классический подход (а);
однородное НРО(б); гибридное НРО(в)

Постановка задачи исследований. Для устранения перечисленных проблем при построении систем НРО для решения задачи распо-

знания состояния производственной или социальной среды по статистической информации предложено использовать методику машинного обучения на основе кластеризации входного набора признаков, которая предусматривает последовательное выполнение процедур самоорганизации нейронов вычислительного слоя Кохонена, градуировки элементов выходного вектора обучающей выборки и окончательной маркировки нейронов вычислительного слоя Кохонена. Реализация процедуры автоматизированной маркировки нейронов самоорганизованного слоя Кохонена позволяет определить формальное соответствие между значением экспертной оценки номера класса и значением номера нейрона победителя градуировочного вектора и, тем самым, снизить субъективность и повысить качество экспертных решений при построении обучающих выборок.

Методика машинного обучения самоорганизующегося слоя Кохонена. Предложенная методика машинного обучения самоорганизующегося слоя Кохонена состоит из 4-х этапов (рис. 2). Рассмотрим их содержание на примере задачи инициализации проекта по охране труда с помощью оценки текущего уровня организации и условий труда на предприятии.

Этап 1: Воспользовавшись предварительно структурированной и представленной в виде электронных опросных форм информацией (набор признаков и оценочных шкал), отражающей уровень организации и условий труда на предприятия, эксперт (инспектор по охране труда) проводит оценку предварительного состояния производственной среды по группам факторов. Так например, к группе «условия труда» относят количественно-качественные факторы, оказывающие влияние на работоспособность и здоровье работника, значения, которых получают с помощью средств мониторинга производственной среды. К таким факторам 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, эксперт оценивает состояние условий труда как: «оптимальное», «допустимое», «вредное», «опасное», «экстремальное»



Рисунок 2 – Методика машинного обучения
самоорганизующегося слоя Кохонена

Электронная опросная форма для проведения предварительной комплексной экспертизы на примере определения уровня аэрозольного воздействия (АВ), как одного из факторов определяющих состоя-

ние производственной среды показана на рисунке 3, а результаты экспертизы в виде X_{ki}, P_k , показаны в таблице 1

Экспертиза текущего состояния предприятия... – X
Организация труда Условия труда

Уровень аэрозольного воздействия
The level of aerosol exposure

Дисперсный состав
Disperse composition (Disp) оптимальное

Концентрация
Concentration (Conc) оптимальное

Время воздействия
Exposure time (Time) оптимальное

Вид частиц
particle type (Type) допустимое

Общий уровень
Final level оптимальное

Отправить Далее >>

Рисунок 3 – Электронная опросная форма для проведения экспертизы уровня АВ

Таблица 1

Экспертная оценка уровня АВ

k	Уровень составляющих фактора x_{ki}				Final level P_k
	disp	conc	time	type	
	x_{k1}	x_{k2}	x_{k3}	x_{k4}	
1	1	1	1	2	1
2	1	1	1	3	1
...
12	1	2	2	2	2
13	1	2	2	3	2
...
24	1	2	4	2	3
25	1	2	4	3	3
...
34	1	3	2	2	4
35	1	3	2	3	4
...
68	1	3	5	2	5
69	1	3	5	3	5

Этап 2: Для автоматизации проверки качества предварительной экспертизы предложено проводить кластеризацию данных экспертных оценок X_{ki} с помощью самоорганизующегося слоя Кохонена [5-6].

Процесс кластеризации X_{ki} предусматривает последовательное выполнение процедур самоорганизации нейронов вычислительного слоя Кохонена, градуировки элементов выходного вектора обучающей выборки и окончательной маркировки нейронов слоя Кохонена (рис.4).

Процедура самоорганизации 2.1. Классическая процедура самоорганизации вычислительного слоя Кохонена реализована с помощью итеративного алгоритма WTA (Winner Takes All) [5]. Согласно которого на вход слоя Кохонена (рис. 4) 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.

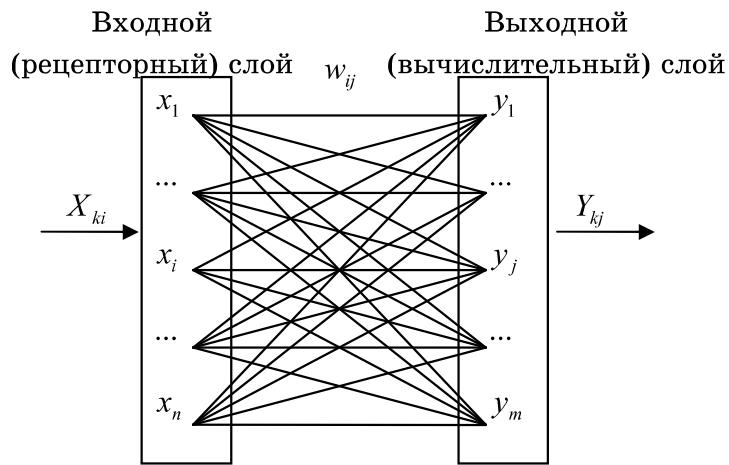


Рисунок 4 – Топология сети Кохонена

Целью самоорганизации является минимизация разницы расстояний:

$$d(x_{ki}, w_{ij}) = \min d(x_{ki}, w_{ij}) \quad (1)$$

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

$$w_{ij}(t+1) = w_{ij}(t) + \eta(t)[x_{ki} - w_{ij}(t)] \quad (2)$$

где, $\eta(t)$ - изменяемый во времени коэффициент шага коррекции.

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

$$d(x_{ki}, w_{ij}) = \sqrt{\sum_{i=1}^n (x_{ki} - w_{ij})^2} \quad (3)$$

Процедура градуировки 2.2. При выполнении процедуры градуировки элементов выходного вектора обучающей выборки на вход предварительно самоорганизованного слоя Кохонена последовательно подаются значения векторов из обучающей выборки X_{ki} , где для каждого из них на основе (1) вычисляются значения вектора выходов Y_{kj} , $j = \overline{1, m}$, где m – число нейронов (классов). При этом для каждого k -го вектора из обучающей выборки все значения элементов вектора Y_{kj} равны 0, кроме нейрона-победителя, значение которого равно 1.

Порядковый номер нейрона-победителя j присваивается в качестве значения i -му элементу градуировочного вектора Z_k . Вид результатов процедуры градуировки X_{ki}, Y_{kj}, Z_k при автоматизации извлечения знаний эксперта при проверке качества проведения экспертизы для определения уровня АВ показан в таблице 2.

Таблица 2

Результаты процедуры градуировки

	X_{ki}				Y_{kj}					Значения градуировочного вектора Z_k
k	x_1	x_2	x_3	x_4	y_1	y_2	y_3	y_4	y_5	
1	1	1	1	2	1	0	0	0	0	1
2	1	1	1	3	1	0	0	0	0	1
...
12	1	2	2	2	0	1	0	0	0	2
13	1	2	2	3	0	1	0	0	0	2
...
24	1	2	4	2	0	0	1	0	0	3
25	1	2	4	3	0	0	1	0	0	3
...
34	1	3	2	2	0	0	0	1	0	4
35	1	3	2	3	0	0	0	1	0	4
...
68	1	3	5	2	0	0	0	0	1	5
69	1	3	5	3	0	0	0	0	1	5

Процедура маркировки 2.3. Для определения соответствия между значением итоговой оценки P_k (номер класса) из таблицы 1 и значением номера нейрона победителя градуировочного вектора Z_k , предложена процедура маркировки нейронов слоя Кохонена номерами классов из таблицы предварительной экспертной оценки. Процедура маркировки состоит из 3-х шагов (рис.2).

Шаг 2.3.1. Для всех примеров обучающей выборки формируем двумерную гистограмму $D_{l,j}$ (квадратную матрицу) попарных совпадений номеров нейронов и классов $Z_{kl} = P_{kj}$, где $l, j = \overline{1, m}$. Вид гистограммы $D_{l,j}$, для примера определения уровня АВ, показан в табл.3.

Таблица 3

Двумерная гистограмма $D_{l,j}$

		Номер класса $P_{k,j}$				
		1	2	3	4	5
Номер нейрона Z_{kl}	1	9	4	0	0	0
	2	1	4	3	2	0
	3	1	4	5	4	0
	4	0	0	1	6	19
	5	0	0	1	4	1

Шаг 2.3.2. Выполняем построчную и постолбцовую корректировку гистограммы $D_{l,j}$, оставляя без изменения только те значения элементов, которые удовлетворяют условию:

$$\begin{cases} \max(D_l) = \max(D_j) \\ l = j \\ \max(D_{lj}) > 0 \end{cases} \quad (4)$$

Остальные значения пересекающихся строк и столбца – обнуляем. Описанная процедура построчно - постолбцовой корректировки двумерной гистограммы выполняется итерационно, пока в каждой строке и столбце останется только одно не нулевое значение Результат корректировки гистограммы $D_{l,j}$, для примера определения уровня АВ, показан в табл. 4.

Таблица 4

Результат построчно-постолбцовой корректировки гистограммы $D_{l,j}$

		Номер класса $P_{k,j}$				
		1	2	3	4	5
Номер нейрона Z_{kl}	1	9	0	0	0	0
	2	0	4	0	0	0
	3	0	0	5	0	0
	4	0	0	0	0	19
	5	0	0	0	4	0

Шаг 2.3.3. На последнем шаге процедуры маркировки нейронов слоя Кохонена скорректированная двумерная гистограмма $D_{l,j}$ попарных совпадений преобразуется в таблицу соответствий номеров нейронов и классов для всех примеров обучающей выборки, вид которой для примера определения уровня АВ, показан (табл. 5).

Таблица 5

Окончательная маркировка номера нейрона на основе класса

Z_l	1	2	3	5	4
P_j	1	2	3	4	5

Этап 3: На основе полученной таблицы соответствий номеров нейронов и классов для проверки качества экспертных оценок по всем примерам обучающей выборки рассчитываются ошибки 1 и 2-го рода и их относительные доли истинно положительных случаев и истинно отрицательных случаев [7-8].

$$TPR = \frac{TP}{TP + FN} \cdot 100\% \quad (5)$$

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).

$$FPR = \frac{FP}{TN + FP} \cdot 100\% \quad (6)$$

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).

Сравнительные значения TPR и FPR рассчитанные при проверке качества экспертных оценок для всех примеров обучающей выборки по всем группам условий труда на предприятии, состояние производственной среды которого оценивается, показаны на рис.5.

Этап 4: Неудовлетворительные значения оценок эксперта (FPR) передаются ему для анализа и выполнения корректировки обучающей выборки, после которой выполняется возврат к этапу 2 (рис. 2) с целью проведения еще одной итерации обучения.

Анализ значений ошибок 1 (рис. 5) и 2-го (рис. 6) 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. Особенно снижение FPR заметно для уровней химического и биологического воздействия (рис. 6).

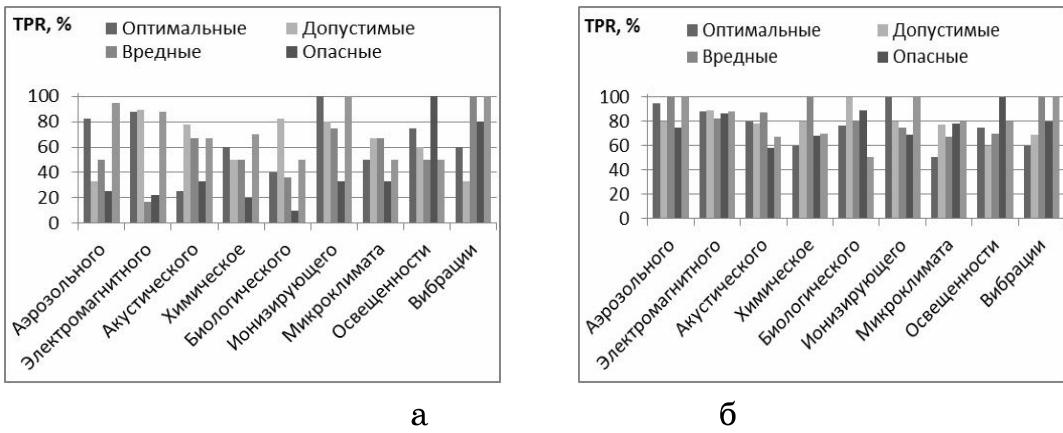
Выводы. Таким образом, апробация разработанной методики машинного обучения на основе кластеризации входного набора признаков с использованием маркировки нейронов конкурирующего слоя

Кохонена и возможностью проверки качества обучения и корректировки обучающей выборки показала повышение относительной доли правильных экспертных оценок на 20% и снижение на 50% ложных оценок по всем группам условий труда.

Для подтверждения целесообразности использования только конкурирующего слоя Кохонена вместо сложных неоднородных сетей векторного квантования или втречного распространения при построении систем нейросетевого распознавания образов для принятия решения о состоянии производственной или социальной среды по статистической информации был проведен ряд экспериментальных исследований. Так, на рисунке 7 и 8 показаны значения ошибок первого и второго рода при использовании на этапе 2 предлагаемой методики для первой и второй итерации сети векторного квантования LVQ.

Моделирование выполнялось с помощью функций библиотеки NNTools пакета Matlab. Сеть LVQ состоит из двух слоев первого – конкурирующего и второго – линейного. При создании LVQ требуется прямое задание соотношения кластеров первого слоя с целевыми классами второго. Это вынуждает эксперта использовать некоторую априорную информацию о состоянии исследуемой производственной или социальной среды. Как видим, использование сети LVQ позволило повысить только на 5% относительную долю правильных экспертных оценок (рис.7) и снизить на 20% относительную долю ложных оценок (рис. 8) в среднем по всем группам условий труда. Это соответственно на 15% и 30% хуже чем при аналогичном использовании одного конкурирующего слоя Кохонена.

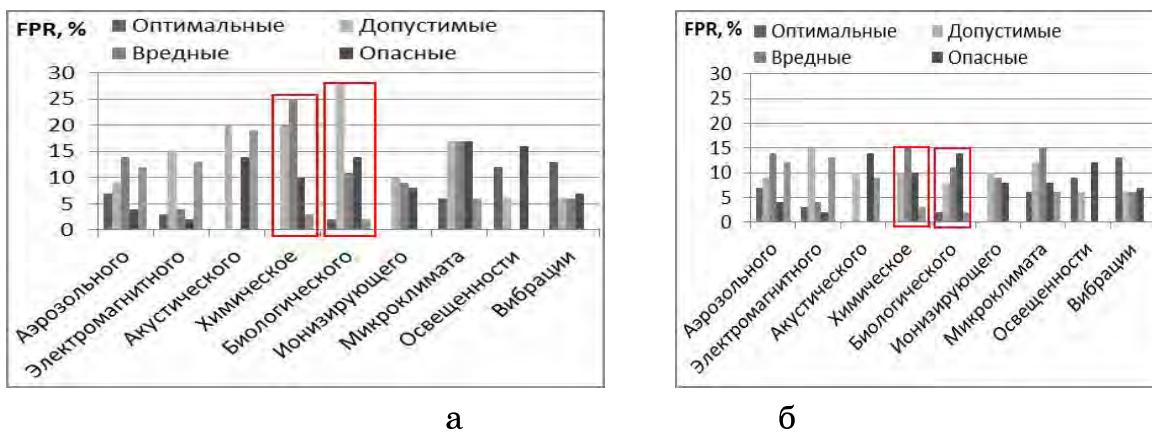
Кроме того, проведенные эксперименты показали, что использование передложенной методики машинного обучения самоорганизующегося слоя Кохонена при построении систем нейросетевого распознавания образов для решения практических задач оценки состояния производственной и социальной среды позволяет снизить требования к предварительной обработке данных из обучающих выборок и к квалификации лица принимающего решения при анализе этих данных.



а

б

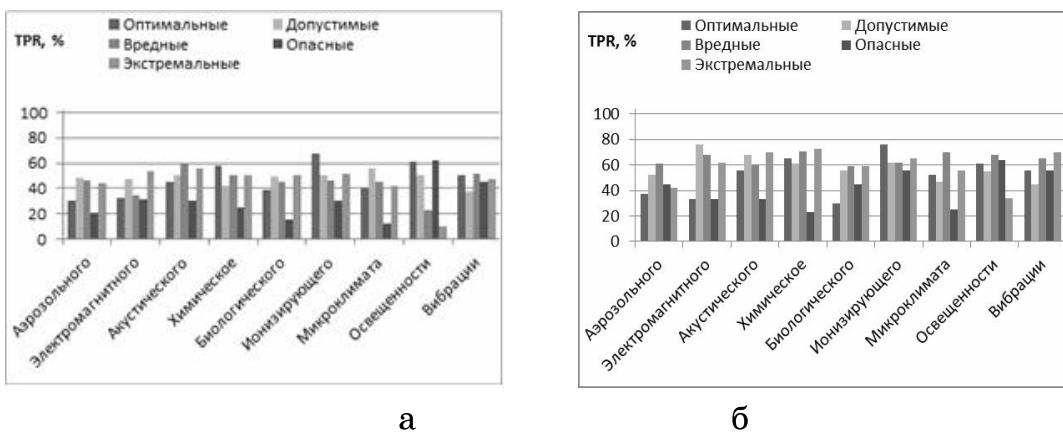
Рисунок 5 – Сравнительные результаты по ТРР до (а) и после (б) корректировки



а

б

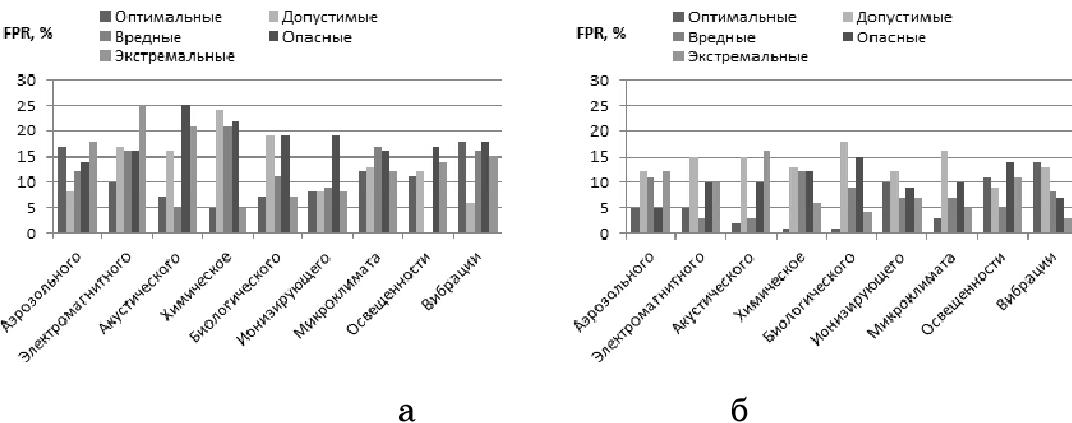
Рисунок 6 – Сравнительные результаты по FPR: до – а и после – б корректировки



а

б

Рисунок 7 – Показатели качества экспертных оценок ТРР до (а) и после (б) корректировки, при использовании гибридной классификации с помощью сети LVQ



а

б

Рисунок 8 – Показатели качества экспертизы оценок FPR до (а) и после (б) корректировки, при использовании гибридной классификации с помощью сети LVQ

ЛИТЕРАТУРА

1. Арсирий Е.А. Нейросетевое распознавание образов читателей публичной библиотеки для организации специализированного библиотечного обслуживания/ Арсирий Е.А , Саенко А.А // Труды Одес. политех. Ун-та. – 2011. – Вып.1(35). С.118-124.
2. Арсирий Е.А. Нейросетевое формирование интегральной профессиональной характеристики в системе дистанционного обучения MOODLE/ Арсирий Е.А , Жиленко Е.Г. // Труды Одес. политех. Ун-та. – 2009. – Вып.2/32. С.161-166.
3. Арсирий Е.А. Автоматизация представления и извлечения декларативных знаний в цифровом макете предприятия при инициализации проектов охраны труда /Арсирий Е.А., Антощук С.Г., Маникаева О.С. //Электротехнические и компьютерные системы – 19(95), 2015.С.266-27
4. Хайкин С. Нейронные сети: полный курс // М.: ООО “И.Д. Вильямс”— С. Хайкин: 2-е изд., испр., пер. с англ. / Под ред. Н.Н. Куссуль. 2006. С. 1104.
5. Кохонен Т. Самоорганизующиеся карты [Текст] / Т. Кохонен; пер. 3-го англ. изд. – М. : БИНОМ Лаборатория знаний, 2008. – 655с
6. Уоссерман Ф. Нейрокомпьютерная техника: Теория и практика [Текст] /Ф. Уоссерман ; пер. с англ. – М. : Мир, 1992. – 240 с.
7. Паклин Н. Логистическая регрессия и ROC-анализ – математический аппарат. [Электронный ресурс]. Режим доступа: <http://www.basegroup.ru/library/analisis/regression/logistic> (дата доступа 25.04.2015).
8. Davis J., Goadrich M. The Relationship Between Precision-Recall and ROC Curves // Proc. Of 23 International Conference on Machine Learning, Pittsburgh, PA, 2006.