

Воронежский институт МВД России
Кафедра информационной безопасности

МОДЕЛИ И АЛГОРИТМЫ НЕЙРОННЫХ СЕТЕЙ В ОБЕСПЕЧЕНИИ
РАСКРЫТИЯ ПРЕСТУПЛЕНИЙ, СОВЕРШЕННЫХ В СИСТЕМАХ
ДИСТАНЦИОННОГО БАНКОВСКОГО ОБСЛУЖИВАНИЯ

Учебно-методическое пособие

Воронеж

2018

ББК 32.811

Рассмотрено и одобрено на заседании кафедры информационной безопасности. Протокол № 4 от 21 ноября 2017 г.

Рассмотрено и одобрено на заседании методического совета института. Протокол № 4 от 18 декабря 2017 г.

Авторский коллектив: Бабкин А.Н., Баркалов Ю.М., Лунев Ю.С., Мельников А.В.

Рецензенты:

Цыганков В.К. – начальник отдела защиты информации ЦИТСиЗИ ГУ МВД России по Воронежской области подполковник внутренней службы;

Демченко Ю.П. – заместитель начальника информационного центра ГУ МВД России по Воронежской области, начальник отдела статистической информации и контроля, полковник внутренней службы.

Модели и алгоритмы нейронных сетей в обеспечении раскрытия преступлений, совершенных в системах дистанционного банковского обслуживания: учебно-методическое пособие [Электронный ресурс] / А.Н. Бабкин [и др.]. – Электр. дан. и прогр. – Воронеж : Воронежский институт МВД России, 2018. – 1 электр. опт. диск (CD-ROM) : 12 см. – Систем. требования: процессор Intel с частотой не менее 1,3 ГГц ; ОЗУ 512 Мб ; операц. система семейства Windows ; CD-ROM дисковод.

Работа предназначена для специалистов в области экономической безопасности, информационно-аналитических и экспертных систем. Может быть полезна адъюнктам, курсантам и студентам старших курсов соответствующих специальностей.

ISBN 978-5-88591-593-9

© Воронежский институт МВД России, 2018

СОДЕРЖАНИЕ

Введение	4
1. Основы кластерно-иерархического подхода к проблеме исследования расчетных операций в дистанционном банковском обслуживании.....	7
1.1. Кластерно-иерархические методы экспертизы.....	7
1.2. Кластеризация по категориальным признакам.....	8
1.3. Установление однородности объектов кластера.....	14
2. Решение прямой и обратной задач исследований расчетных операций на основе обучения нейронных сетей	19
2.1. Признаки противоправных действий	19
2.2. Альтернативный способ учета признаков противоправных действий методом анализа иерархий	23
2.3. Прогнозирование обобщенного показателя расчетной операции методом обучения нейронной сети	26
3. Классификация и кластеризация расчетных операций с помощью самоорганизующихся нейронных сетей	33
3.1. Метод экспертизы на основе ассоциативного обучения самоорганизующейся нейронной сети	33
3.2. Классификация расчетных операций на основе обучения персептрона	40
3.3. Кластеризация на основе самоорганизующейся нейронной сети в виде слоя Кохонена	42
4. Методы исследования расчетных операций в сфере дистанционного банковского обслуживания	51
4.1. Классификация нарушителей в сфере дистанционного банковского обслуживания	51
4.2. Модели нарушителей в сфере дистанционного банковского обслуживания	55
Заключение	58
Список использованных источников	59
Приложение А. Время проведения мошеннической операции в среде ДБО	

ВВЕДЕНИЕ

Экспертные системы широко используются в различных областях науки, техники и экономики благодаря универсальности общего методологического подхода к представлению и обработке знаний самого различного характера.

Проблемам теории и практики экспертных систем посвящены публикации отечественных ученых Н.В. Дилигенского [1], Б.Г. Литвака [2], и др. Среди публикаций зарубежных специалистов известны работы М. Кендалла [3], Т. Саати [4], С. Хайкина [5] и др. ученых.

В силу обнаруженных на практике принципиальных недостатков систем искусственного интеллекта (процессы разработки и «обучения» ЭС длительны и дорогостоящи; необходимость использования очень большого количества экспертов; узкая направленность) в последнее время все большее внимание привлекают системы статистической обработки информации.

Теоретической основой создания таких систем является многомерный статистический анализ. В частности, применению статистических методов в экспертизе посвящены работы ряда специалистов, среди которых М. Дж. Кендалл, А. Стьюарт [6], К. Эсбенсен [7] и др.

Связующим методологическим звеном между классической и современной теорией экспертных систем следует считать внедрение интеллектуальных способов обработки данных (data mining) [8, 9]. Data Mining (интеллектуальный анализ данных, глубинный анализ данных) — собирательное название, используемое для обозначения совокупности методов обнаружения в экспертных данных ранее неизвестных, нетривиальных, практически полезных и доступных интерпретации знаний, необходимых для принятия решений в различных сферах человеческой деятельности.

Среди различных методов data mining (кластеризация, нейронные сети, метод анализа иерархий, нечеткие множества, теория линейной множественной регрессии, генетические алгоритмы и т.д.) выделяется метод главных компонент (Principal component analysis) — один из способов уменьшить размерность множества экспертных данных, потеряв наименьшее количество информации [7 и др.].

В методологическом смысле теория экспертных систем близка кластерному анализу. Кластеризация осуществляется как на ранних этапах экспертного исследования (грубое разделение объектов на классы), так и в самом его конце, перед формированием заключения экспертизы. Теоретическим аспектам кластеризации посвящен ряд работ известных авторов: И.Д. Мандель [10], М. Жамбю [11], и др.

В первой главе данной работы рассматриваются основы кластерно-иерархического подхода к проблеме экспертизы, предложенного в работе [12]. Дано понятие кластеров и различные способы их формирования, уделено внимание ключевому понятию расстояния (метрики) между объектами экспертизы. Рассмотрена многоуровневая процедура обработки

характеристических векторов объектов — метод «кластерного сита». Анализируется методика кластеризации по категориальным признакам, при этом под категоризованными данными понимаются данные, представленные в виде частот наблюдений, попавших в некоторые категории (классы). Для установления однородности объектов кластера предложено использование критерия знаков и критерия Вилкоксона. Отмечено, что ключевым понятием в решении нечетко-множественных задач экспертизы является понятие функции принадлежности и рассмотрены некоторые подходы к определению этой функции. Определены различные формы расстояния (метрики) в нечетких множествах и анализируются различные алгоритмы кластеризации.

Вторая глава посвящена решению прямой и обратной задач экспертизы расчетных операций на основе обучения нейронных сетей. Даны понятия упомянутых задач и подчеркивается необходимость комплексного подхода к их решению. В работе [12] был обоснован принцип разделения характеристик расчетных операций на количественные, наличия и качественные признаки. Предложено дополнить известный набор признаков признаками критического риска и разработаны два подхода к их учету. Первый из них — расширение признакового пространства, а второй основан на методе анализа иерархий. Проведенный численный анализ показал эффективность обоих подходов.

Осуществлено прогнозирование обобщенного показателя нового объекта на основе решения обратной задачи экспертизы методом обучения нейронной сети. Для обучения двухслойной сети использован алгоритм Левенберга — Маркуардта и впервые применена процедура анализа весов — диаграмма Хинтона. Показано, что использование графического интерфейса пользователя GUI из пакета nntool языка MATLAB приводит к непредсказуемым значениям весов нейронной сети, и сделан вывод о переходе к разработанной программе адаптации весов с фиксированным уровнем смещений. Показана эффективность процедур групповой и последовательной адаптации нейронной сети, в том числе и с учетом признака противоположного действия.

Разрабатывается метод экспертизы на основе ассоциативного обучения самоорганизующейся нейронной сети. Введена вероятностная модель ассоциативного обучения, анализируется нейронная модель смешения оценок экспертов-нейронов. Данный метод экспертизы является альтернативным методу использования комплексного показателя аномальности расчетной операции и особенно эффективен в случае последовательного применения метода анализа иерархий и ассоциативного обучения.

Рассмотрена классификация расчетных операций с помощью персептрона как по всем признакам объекта, так и на основе выделения главных компонент. Показано, что для кластеризации расчетных операций целесообразно использовать самоорганизующуюся нейронную сеть в виде слоя Кохонена с конкурирующей функцией активации. Предложены методы тестирования результатов кластеризации. Расширены возможности кластеризации за счет применения карт Кохонена.

Построено пространство признаков расчетных операций в системах дистанционного банковского обслуживания и сформирована матрица референтных данных. Для заданного набора объектов определены векторы обобщенного показателя качества, нормированного стоимостного признака и комплексного показателя уровень аномальности. Для преодоления известного недостатка метода анализа иерархий (ограниченность числа объектов сравнения) предложена процедура разбиения группы объектов на классы и методика сшивания результатов анализа.

Осуществлена классификация расчетных операций в системах дистанционного банковского обслуживания с помощью персептрона в трехмерном и двумерном пространстве с визуализацией результатов. Показано, что персептрон эффективно разделяет операции и в многомерном пространстве и позволяет предсказать класс новых операций, не входивших в состав обучающего набора данных. Осуществлена кластеризация на три класса: по признакам обобщенного показателя аномальности операции, на основе использования метода главных компонент и на основе всех признаков расчетной операции. Показаны возможности расширенной кластеризации на основе одномерной карты Кохонена.

1. Основы кластерно-иерархического подхода к проблеме исследования расчетных операций в дистанционном банковском обслуживании

1.1. Кластерно-иерархические методы экспертизы

Анализ современного состояния теории экспертных систем [1, 2 и др.] и сделанный обзор методов кластерного анализа позволяет сделать вывод о принципиальной близости обеих теорий. Отметим лишь некоторые обстоятельства.

Родственность методов исследования. Действительно, в обеих областях формируется вектор признаков (характеристический вектор) и выбирается адекватная метрика. Далее исследуются свойства объектов в n -мерном пространстве признаков и оценивается принадлежность характеристического вектора некоторой области в этом пространстве (кластеризация) или вычисляется обобщенный показатель (экспертиза). В первом случае используется многомерное шкалирование, а во втором — одномерное. Однако и в некоторых задачах кластеризации также целесообразно переходить к одномерной шкале.

Иерархический характер исследований. В кластерном анализе известна большая группа собственно иерархических алгоритмов, среди которых выделяются агломеративные иерархические алгоритмы. Кроме того, представление результатов осуществляется с помощью специального графического средства — дендрограммы. В теории экспертных систем более распространен метод анализа иерархий. Однако в обоих случаях рассматривается одна и та же последовательность «цель — задачи (по уровням иерархии) — альтернативы».

Как в теории экспертных систем, так и в кластерном анализе существует большое количество эффективных методов. Однако, как следует из обзора литературы, выбор автором одного из них полностью определяет все направление дальнейших исследований. Практически не делается попыток объединения положительных свойств и процедур различных методов. Нам же представляется, что методология кластерного анализа (и экспертизы) должна иметь комплексный характер. Анализ современного состояния теории экспертных систем [1, 2] и сделанный выше обзор методов кластерного анализа позволяет сделать вывод о принципиальной близости обеих теорий. Отметим лишь некоторые обстоятельства.

Родственность методов исследования. Действительно, в обеих областях формируется вектор признаков (характеристический вектор) и выбирается адекватная метрика. Далее исследуются свойства объектов в m -мерном пространстве признаков и оценивается принадлежность характеристического вектора некоторой области в этом пространстве (кластеризация) или вычисляется обобщенный показатель (экспертиза). В первом случае используется многомерное шкалирование, а во втором — одномерное. Однако и в некоторых задачах кластеризации также целесообразно переходить к

одномерной шкале.

Иерархический характер исследований. В кластерном анализе известна большая группа собственно иерархических алгоритмов, среди которых выделяются агломеративные иерархические алгоритмы. Кроме того, представление результатов осуществляется с помощью специального графического средства — дендрограммы. В теории экспертных систем более распространен метод анализа иерархий. Однако в обоих случаях рассматривается одна и та же последовательность «цель — задачи (по уровням иерархии) — альтернативы».

Как в теории экспертных систем, так и в кластерном анализе существует большое количество эффективных методов. Однако, как следует из обзора литературы, выбор автором одного из них полностью определяет все направление дальнейших исследований. Практически не делается попыток объединения положительных свойств и процедур различных методов. Нам же представляется, что методология кластерного анализа (и экспертизы) должна иметь комплексный характер.

1.2. Кластеризация по категориальным признакам

В качестве категориальных переменных обычно выбирают переменные (признаки), которые принципиально не могут быть представлены в виде числовых значений. Иначе говоря, под категоризованными данными понимаются данные, представленные в виде частот наблюдений, попавших в некоторые категории (классы). Установление статистических связей, т.е. степени зависимости между упомянутыми признаками, выраженными в категоризованной форме, представляет собой важную теоретическую задачу.

Приведем следующий пример. При оценке степени предпочтительности инвестиционных проектов можно выделить три подхода к оценке: рейтинговая комплексная оценка эффективности финансово-хозяйственной деятельности; сравнение количества аналогичных рентабельных организаций; сравнение количества аналогичных платежеспособных организаций.

Заметим, что в двух последних случаях рассматриваются не абсолютные значения рентабельности или платежеспособности предприятия, выраженные численно (тогда задача становится одномерной), а выраженные качественно: «рентабельно — нерентабельно», «платежеспособно — неплатежеспособно» и т.д. Иначе говоря, при оценке взаимозависимости между двумя признаками решаются непараметрические задачи.

Пусть в генеральной совокупности классификация произведена на основании наличия некоторого признака R (например, организация рентабельна) и другого признака P (например, организация платежеспособна). Обозначим через \bar{R} отсутствие первого признака, а через \bar{P} — отсутствие второго. Тогда количества попаданий k аналогичных организаций в четыре

возможных подгруппы (ситуации) обозначим $q(A_i)$, где A_i — события, являющиеся произведениями $RP, R\bar{P}, \bar{R}P, \bar{R}\bar{P}$ соответственно. Эти ситуации могут быть представлены таблицей (табл. 1.3.1).

Напомним, что все эти ситуации возможны на практике: организация может быть рентабельной, но неплатежеспособной или наоборот. Наибольший интерес, разумеется, представляет случай RP , когда организация и платежеспособна, и рентабельна, и финансово устойчива — при этом, как правило, можно считать, что между признаками R и P существует определенная взаимосвязь, однако степень этой взаимосвязи меняется в зависимости от вида деятельности и объема инвестиций. Введем *показатель взаимосвязи* упомянутых величин

$$\lambda = \frac{[q(RP) + q(R\bar{P})][q(\bar{R}P) + q(\bar{R}\bar{P})]}{q(RP)k}. \quad (1.2.1)$$

Будем считать, что если $\lambda < 1$, величины R, P положительно связаны; если $\lambda = 1$ — не связаны; если $\lambda > 1$ — отрицательно связаны. Можно убедиться, что для рассматриваемых признаков R и P наблюдается первое неравенство.

Меры связи категоризованных данных. Обозначим общее количество объектов — k , а количество объектов, обладающих определенным свойством — $q(\cdot)$. После введения сокращенных обозначений

$$a_{11} = q(RP), \quad a_{12} = q(R\bar{P}), \quad a_{21} = q(\bar{R}P), \quad a_{22} = q(\bar{R}\bar{P}), \quad (1.2.2)$$

где

$$(a_{22} = k - (a_{11} + a_{12} + a_{21})),$$

коэффициент λ , характеризующий взаимосвязь признаков, примет вид

$$\lambda = \frac{(a_{11} + a_{12})(a_{21} + a_{11})}{ka_{11}}. \quad (1.2.3)$$

Таблица 1.2.1

Частоты произведения событий $RP, R\bar{P}, \bar{R}P, \bar{R}\bar{P}$

События	P	\bar{P}	Сумма
R	$q(RP)$	$q(R\bar{P})$	$q(R)$
\bar{R}	$q(\bar{R}P)$	$q(\bar{R}\bar{P})$	$q(\bar{R})$
Сумма	$q(P)$	$q(\bar{P})$	k

Разумеется, вместо рентабельности и платежеспособности могут использоваться и другие как экономические, так и технические показатели или их разновидности: наличие или отсутствие определенного свойства товара, мужской или женский пол в социологии и т.д.

Для того чтобы вводимая оценка зависимости была более согласованна с обычным коэффициентом корреляции, рассмотрим коэффициент категориальной корреляции

$$D = a_{11} - \lambda a_{11} = \frac{a_{11}a_{22} - a_{12}a_{21}}{k}. \quad (1.2.4)$$

Тогда для независимых признаков $D = 0$, а для положительной и отрицательной зависимости D примет знаки «+» или «-» соответственно.

Согласно Кендаллу [44] используем в задаче обработки категоризованных данных коэффициент связи:

$$Q = \frac{a_{11}a_{22} - a_{12}a_{21}}{a_{11}a_{22} + a_{12}a_{21}} = \frac{kD}{a_{11}a_{22} + a_{12}a_{21}}. \quad (1.2.5)$$

Этот коэффициент равен нулю, если признаки независимы ($D = 0$) и принимает значение +1 только тогда, когда $q(R\bar{P}) = q(\bar{R}P) = 0$, т.е. в случае полной связанности.

Возможно использование и четвертого показателя — коэффициента коллигации (сочетаемости) Y , связанного с коэффициентом связи Q выражением:

$$Q = \frac{2Y}{(1 + Y^2)}. \quad (1.2.6)$$

Предпочтительность того или иного показателя определяется свойствами конкретной генеральной совокупности.

Найдем в предположении независимости стандартные ошибки ранее рассмотренных коэффициентов, тогда получаем [66]:

$$\frac{de}{e} = \frac{d(q(R\bar{P}))}{q(R\bar{P})} + \frac{d(q(\bar{R}P))}{q(\bar{R}P)} - \frac{d(q(RP))}{q(RP)} - \frac{d(q(\bar{R}\bar{P}))}{q(\bar{R}\bar{P})}, \quad (1.2.7)$$

где

$$e = \frac{q(R\bar{P})q(\bar{R}P)}{q(RP)q(\bar{R}\bar{P})}, \quad (1.2.8)$$

откуда:

$$\frac{De}{e^2} = \sum_u \frac{Du}{u^2} + 2 \sum_{u,v} \left\{ \pm \frac{\text{cov}(u,v)}{uv} \right\}, \quad (1.2.9)$$

где u и v принимают значения $q(RP), q(R\bar{P}), q(\bar{R}P), q(\bar{R}\bar{P})$. Воспользуемся результатами, относящимися к мультиномиальному распределению, для которого:

$$D(q(RP)) = \frac{q(RP)(k - q(RP))}{k}, \quad \text{cov}(q(RP), q(R\bar{P})) = -\frac{q(RP)q(R\bar{P})}{k}.$$

Подставляя эти значения в (1.3.7), находим

$$De = e^2 \left(\frac{1}{q(RP)} + \frac{1}{q(R\bar{P})} + \frac{1}{q(\bar{R}P)} + \frac{1}{q(\bar{R}\bar{P})} \right). \quad (1.2.10)$$

После преобразований из (1.3.10) получаем:

$$DQ = \frac{1}{4} (1 - Q^2)^2 \left(\frac{1}{q(RP)} + \frac{1}{q(\bar{R}P)} + \frac{1}{q(R\bar{P})} + \frac{1}{q(\bar{R}\bar{P})} \right), \quad (1.2.11)$$

В этих формулах предполагается, как это принято в случае больших выборок, что в выборочных дисперсиях могут быть использованы сами наблюдаемые частоты вместо их математических ожиданий.

Определение связи в совокупностях данных. Введенные ранее коэффициенты определяют наличие связи между двумя признаками (R и P), однако наличие либо отсутствие связи может быть обусловлено некоторой причинной зависимостью от третьего признака (S). В этом случае рассмотрим связь R и P при условии, что S фиксированно. При этом количества попаданий в возможные подгруппы будут представлены в виде таблиц 1.2.2 и 1.2.3.

Таблица 1.2.2

Частоты событий $RP, R\bar{P}, \bar{R}P, \bar{R}\bar{P}$ при условии S

События	S		Сумма
	P	\bar{P}	
R	$q(RPS)$	$q(R\bar{P}S)$	$q(RS)$
\bar{R}	$q(\bar{R}PS)$	$q(\bar{R}\bar{P}S)$	$q(\bar{R}S)$
Сумма	$q(PS)$	$q(\bar{P}S)$	$q(S)$

Тогда коэффициент λ по аналогии с (1.3.1) для таблицы 1.2.2 примет вид

$$\lambda = \frac{[q(RPS) + q(R\bar{P}S)][q(\bar{R}PS) + q(\bar{R}\bar{P}S)]}{q(RPS)q(S)}, \quad (1.2.12)$$

или

$$\lambda = \frac{q(RS) \cdot q(PS)}{q(RPS) \cdot q(S)}, \quad (1.2.13)$$

где $q(RPS)$ — количество членов, обладающих всеми тремя признаками, $q(RS)$ и $q(PS)$ — число членов, обладающих признаками R и S , P и S соответственно, $q(S)$ — признаком S . Для таблицы 1.2.3 в выражениях (1.2.12, 1.3.13) необходимо заменить S на \bar{S} .

Частоты событий $RP, R\bar{P}, \bar{R}P, \bar{R}\bar{P}$ при условии \bar{S}

События	\bar{S}		
	P	\bar{P}	Сумма
R	$q(RPS)$	$q(R\bar{P}\bar{S})$	$q(R\bar{S})$
\bar{R}	$q(\bar{R}PS)$	$q(\bar{R}\bar{P}\bar{S})$	$q(\bar{R}\bar{S})$
Сумма	$q(PS)$	$q(\bar{P}\bar{S})$	$q(\bar{S})$

Так как связи определяются в подсовокупностях, они получили название частные связи. Можно также определить другие меры связи, например, коэффициент частной связи рассчитывать по формуле

$$Q_{RP/S} = \frac{q(RPS) \cdot q(\bar{R}\bar{P}\bar{S}) - q(R\bar{P}\bar{S}) \cdot q(\bar{R}PS)}{q(RPS) \cdot q(\bar{R}\bar{P}\bar{S}) + q(R\bar{P}\bar{S}) \cdot q(\bar{R}PS)}. \quad (1.2.14)$$

После введения сокращенных обозначений $a_{11} = q(RP\bar{S})$, $a_{12} = q(R\bar{P}\bar{S})$, $a_{21} = q(\bar{R}PS)$, $a_{22} = q(\bar{R}\bar{P}\bar{S})$ коэффициенты λ , D , Q , характеризующие взаимосвязь признаков примут вид (1.2.1), (1.2.3) и (1.2.4) соответственно.

Рассмотрим объединение двух совокупностей представленных в таблицах 1.2.2, 1.2.3, на примере коэффициента D . Если R и P независимы от S, \bar{S} в обеих совокупностях, то $D_{RP/S} = D_{RP/\bar{S}} = 0$ и (1.3.4) дает

$$D_{RP} = \frac{k}{q(S)q(\bar{S})} D_{RS} D_{PS}, \quad (1.2.15)$$

т.е. R и P не будут независимы во всей совокупности за исключением случая, когда S не зависит от R или от P или от обоих признаков в этой совокупности. Этот результат аналогичен случаю для частных корреляций.

Полученный результат показывает, что при объединении двух совокупностей $q(S)$ и $q(\bar{S})$ могут возникнуть кажущиеся связи, а действительные связи при этом могут оказаться скрытыми. Если R и S , P и S связаны, то следует интересный факт: если R и P положительно связаны в S и отрицательно связаны в \bar{S} , то D_{RP} может обратиться в нуль; это означает, что R и P предстанут независимыми во всей совокупности.

В случае, если R и P не будут независимы от S, \bar{S} , то после достаточно громоздких преобразований формула (1.2.16) примет вид

$$D_{RP} = \frac{k}{q(S)q(\bar{S})} D_{RS} D_{PS} + D_{RP/S} + D_{RP/\bar{S}}. \quad (1.2.16)$$

Проиллюстрируем полученные результаты на примерах.

1. Признаки R и P не связаны третьим признаком S . Пусть R означает рентабельность предприятия, а P - платежеспособность. Приведем количество предприятий, обладающих этими признаками (табл. 1.2.4):

$$\text{Имеем } q(RP) = \frac{q(R)q(P)}{k} = \frac{60 \cdot 30}{90} = 20, \text{ т.е. эти признаки можно}$$

считать независимыми.

Таблица 1.2.4

Частоты событий $RP, R\bar{P}, \bar{R}P, \bar{R}\bar{P}$ для множества предприятий

События	P	\bar{P}	Сумма
R	20	40	60
\bar{R}	10	20	30
Сумма	30	60	90

2. Предположим, что R и P объединены каким-то признаком S и частоты наличия и отсутствия этого признака расположились следующим образом (таблицы 1.3.5, 1.3.6, соответственно).

В группе событий, связанных с S , получаем:

$$Q_{RP/S} = \frac{16 \cdot 16 - 20 \cdot 8}{16 \cdot 16 + 20 \cdot 8} = \frac{96}{416} = 0,2307,$$

а в группе событий, связанных с \bar{S} получим:

$$Q_{RP/\bar{S}} = \frac{4 \cdot 4 - 2 \cdot 20}{4 \cdot 4 + 2 \cdot 20} = -\frac{24}{56} = -0,4285.$$

Очевидно, что R и P положительно связаны в группе S и отрицательно связаны в группе \bar{S} . При этом взаимное уничтожение этих связей может привести к независимости в объединенной группе.

Таблица 1.2.5

Частоты событий $RP, R\bar{P}, \bar{R}P, \bar{R}\bar{P}$ при условии S

События	S		Сумма
	P	\bar{P}	
R	16	20	36
\bar{R}	8	16	24
Сумма	24	36	60

Встречаются еще более парадоксальные случаи: две таблицы, имеющие связи одного знака, могут при объединении дать таблицу со связью противоположного знака. Во избежание подобных ситуаций, которые приводят к наличию большого количества таблиц и, как следствие, трудностям в обработке данных, необходимо уделять значительное внимание отбору группировочных (категоризирующих) признаков, хотя подобные случаи зачастую могут привести к весьма интересным результатам и новым группировкам.

Таблица 1.2.6

Частоты событий $RP, R\bar{P}, \bar{R}P, \bar{R}\bar{P}$ при условии \bar{S}

События	\bar{S}		
	P	\bar{P}	Сумма
R	4	20	24
\bar{R}	2	4	6
Сумма	6	24	30

1.3. Установление однородности объектов кластера

Начальное разбиение m -мерного пространства признаков на отдельные кластеры может осуществляться различными способами.

- Для сложных и ответственных проектов следует использовать рассмотренный выше метод категоризации данных, позволяющий осуществить кластеризацию по главным признакам.

- Для более простых задач достаточно ограничиться методикой вычисления евклидовых расстояний между векторами признаков (характеристическими векторами).

- На основе предварительной экспертизы, статистической обработки векторов оценок экспертов и вычисления их взаимно-корреляционной матрицы.

- На основе известных априори данных о соотношении некоторых признаков сравниваемых объектов.

- Путем комбинации перечисленных выше приемов или другими способами.

Однако после выполнения любой из перечисленных выше процедур требуется оценить степень близости (однородность) объектов в каждом кластере. Кардинальный ответ на этот вопрос дает вычисление обобщенной матрицы дисперсии характеристических векторов для каждого кластера как определителя корреляционной матрицы. Однако процедура эта довольно трудоемкая, а во многих случаях требуется оперативно найти приближенную оценку однородности объектов. Такая оценка тем более оправдана, поскольку

согласно предложенному нами кластерно-иерархическому подходу выделенные первоначально кластеры все равно будут подвергаться в дальнейшем «более тонкой» процедуре статистической обработки векторов оценок экспертов.

Для проверки гипотезы об однородности объектов экспертизы предложим использовать свободный от распределения статистики критерий знаков или критерий Вилкоксона.

Критерий знаков. Пусть для оценки однородности двух объектов выбрано m признаков: $x_1^{(1)}, x_2^{(1)}, \dots, x_m^{(1)}$ — для первого объекта; $x_1^{(2)}, x_2^{(2)}, \dots, x_m^{(2)}$ — для второго. Для критерия знаков ситуации

$$x_i^{(1)} > x_i^{(2)} \quad (1.3.1)$$

приписывается знак «+», или +1, а ситуации

$$x_i^{(1)} < x_i^{(2)} \quad (1.3.2)$$

— знак «-», или -1. В том случае, если соответствующие признаки не могут быть сопоставлены количественно, под символом «>» или «<» в формулах (1.3.1), (1.3.2) понимается «лучше» или «хуже». Если в качестве статистики критериев выбрать среднеарифметическое, то для однородных объектов она будет распределена около нуля.

Простые и чрезвычайно эффективные критерии перестановок для некоторых непараметрических гипотез могут быть получены путем использования рангов, отражающих соотношения порядка между наблюдениями. В настоящем разделе обсуждается использование самих порядковых статистик для построения свободных от распределения процедур для непараметрических задач. Затем рассматривается применение порядковых статистик в других (параметрических) ситуациях.

Полезный обзор литературы по порядковым статистикам был дан С. Уилксом¹. Так называемый критерий знаков для значения квантили непрерывного распределения был, по-видимому, первым из когда-либо использовавшихся свободных от распределения критериев.

Предположим, что функция распределения наблюдений есть $F(x)$ и что

$$F(X_p) = p, \quad (1.3.3)$$

так что X_p есть p -квантиль этого распределения, т.е. значение, ниже которого лежит $100p$ процентов распределения. Для любого p , $0 < p < 1$, значение X_p есть характеристика положения распределения. Мы хотим проверить гипотезу

$$H_0 : X_p = x_0, \quad (1.3.4)$$

где x_0 — некоторое заданное значение (если для удобства принять x_0 за начало отсчета, то мы хотим проверить равенство X_p нулю.)

Если имеется выборка из n наблюдений, то мы знаем, что выборочная функция распределения будет сходиться по вероятности к функции распределения наблюдений. Определим соотношение между порядковыми

¹ Уилкс С. Математическая статистика: пер. с англ. — М. : Наука, 1967. — 632 с.

статистиками $x_{(1)}, x_{(2)}, \dots, x_{(n)}$ и гипотетическим значением X_p , подлежащим проверке. Сосчитаем, сколько наблюдений в выборке попадает ниже x_0 , т.е. образуем статистику

$$S = \sum_{i=1}^n h(x_0 - x_{(i)}) = \sum_{i=1}^n h(x_0 - x_i), \quad (1.3.5)$$

где введена характеристическая функция

$$h(z) = \begin{cases} 1, & z > 0, \\ 0, & z < 0. \end{cases}$$

Статистика S считает число положительных значений среди разностей $(x_0 - x_i)$, и поэтому критерий, основанный на S , называется критерием знаков. Сразу видно, что S имеет биномиальное распределение, поскольку S есть сумма n независимых наблюдений над $(0-1)$ -случайной величиной $h(x_0 - x)$ с вероятностью

$$P\{h(x_0 - x) = 1\} = P\{x < x_0\}.$$

Обозначим $P\{x < x_0\} = P$. Гипотеза (1.4.4) сводится к

$$H_0: P = p, \quad (1.3.6)$$

и мы просто проверяем гипотезу о биномиальном параметре P . Нас могут интересовать односторонние или двусторонние альтернативы к гипотезе (1.3.6).

Если мы больше ничего не знаем относительно функции распределения $F(x)$, то интуитивно понятно, что мы не можем получить ничего лучшего, чем S , в качестве статистики критерия, и мы находим из биномиальной теории, что для односторонней альтернативы $H_1: P > p$ критическая область, состоящая из больших значений S , является равномерно наиболее мощной (РНМ), а для двусторонней альтернативы $H_2: P \neq p$ двусторонняя критическая область является равномерно наиболее мощной несмещенной (РНМН).

В наиболее важном для практики случае, когда $p = 1/2$ и мы проверяем медиану распределения, мы имеем для S симметричное биномиальное распределение и РНМН-критическая область против H_2 является симметричной.

Таким образом, при малом объеме выборки n таблицы биномиального распределения достаточны для определения как размера критерия знаков, так и для определения его мощности против любого конкретного альтернативного значения P , а следовательно, и его функции мощности для альтернатив H_1 или H_2 . Когда n возрастает, сходимость биномиального распределения к нормальному позволяет нам сказать, что

$$(S - np) / \{nP(1 - P)\}^{1/2}$$

имеет стандартное нормальное распределение. Если мы пользуемся поправкой на непрерывность, то это сводится к замене $|S - np|$ на $|S - np| - 1/2$ при выполнении критерия.

В случае медианы, когда мы проверяем гипотезу $P = 1/2$, сходимость к нормальности настолько быстрая, что здесь, скорее всего, вовсе не потребуются специальные таблицы, поскольку нам нужно только сравнить значение

$$\left(\left| S - \frac{1}{2}n \right| - \frac{1}{2} \right) / \left(\frac{1}{2}n^{1/2} \right) \quad (1.3.7)$$

с подходящим стандартным нормальным отклонением.

Критерий Вилкоксона. Наряду с критерием знаков для проверки гипотезы об однородности объектов в каждом кластере может быть использован критерий Вилкоксона. Отличие этих критериев состоит в следующем. В критерии Вилкоксона ситуациям, описываемым формулами (1.3.1), (1.3.2), приписываются значения 1 или 0 соответственно. Если в качестве статистики критериев выбрать среднее арифметическое, то для однородных объектов она будет распределена около 0,5.

Если мы хотим иметь возможность табулировать точное перестановочное распределение статистик критерия для любого n , мы должны исключить зависимость статистики критерия от наблюдаемых значений, которые являются случайными величинами, и это приводит нас к использованию ранговых критериев, которые особенно уместны здесь вследствие их инвариантности относительно монотонных преобразований наблюдаемых величин. Снова простейшая процедура состоит в том, чтобы просто заменить наблюдения x_i их рангами, т. е. упорядочить по величине $n_1 + n_2 = n$ наблюдений и заменить значение x_i его рангом X_i . Мы тогда получаем набор из n значений X_i , представляющий собой перестановку первых n натуральных чисел, из которых n_1 относятся к первой выборке и n_2 — ко второй.

Если ввести характеристическую функцию

$$h_{ij} = \begin{cases} 1, & \text{если } X_i > X_j, \\ 0, & \text{в противном случае} \end{cases},$$

то сумма инверсий рангов примет вид

$$Q = \sum_i \sum_{j>i} h_{ij}. \quad (1.3.15)$$

Поскольку выбранная статистика эквивалентна использованию среднего значения первой выборки \bar{x}_1 , ранговый критерий, получаемый из нее заменой наблюдений их рангами, эквивалентен использованию суммы рангов первой выборки

$$S = \sum_{i=1}^{n_1} X_i. \quad (1.3.16)$$

Далее мы ищем аналог статистики Q , более удобный для вычислений. Если гипотеза об однородности справедлива, следует, очевидно, ожидать, что наблюдения из первой и второй выборок будут хорошо перемешаны, так что ранги первой выборки не будут иметь никакой тенденции скапливаться у какого-нибудь или у обоих концов интервала от 1 до n . Определим статистику

U , которая считает, сколько раз элемент первой выборки превосходит элемент второй выборки, т. е.

$$U = \sum_{i=1}^{n_1} \sum_{j=1}^{n_2} h_{ij} . \quad (1.3.17)$$

Статистика U принимает значения от 0 до $n_1 n_2$.

Таким образом, мы можем пользоваться любой из статистик U и S , какая удобнее. Как с теоретической, так и с вычислительной точки зрения статистика U проще.

2. Решение прямой и обратной задач исследований расчетных операций на основе обучения нейронных сетей

2.1. Признаки противоположных действий

В теории и практике статистической экспертизы различают два основных подхода. Наиболее распространенной является *прямая задача* экспертизы, различным аспектам решения которой посвящены работы отечественных и зарубежных авторов (М. Кендэл [3], Б. Г. Литвак [2], Т. Л. Саати [4] и др.).

Методика экспертизы при решении прямой задачи достаточно подробно изложена в монографии [12]. Для каждого l -го объекта определяется комплексный нечетко-множественный показатель качества, который в упрощенном виде может быть записан в виде функционала

$$J_l = \sum_{j=1}^m \hat{V}_i \mu_j(\hat{x}_{ij}^{(l)}) \hat{x}_{ij}^{(l)}, \quad l = 1, 2, \dots, k, \quad (2.1.1)$$

где \hat{V}_i — нормированные весовые коэффициенты, $\mu_j(\hat{x}_{ij}^{(l)})$ — нечетко-множественные функции принадлежности, $\hat{x}_{ij}^{(l)}$ — нормированные признаки объекта экспертизы.

Общее выражение (2.1.1) конкретизируется с учетом *принципа разделения признаков* [12], согласно которому признаки разделяются по виду использованной информации и способам ее обработки на следующие категории: количественные, качественные, наличия, психофизиологической природы, стоимостные, внедренческие и т.д.

Приведем рабочую форму комплексного показателя аномальности в мультипликативной форме, ограничившись рассмотрением только признаков количественных, наличия и качественных:

$$J = \left[\hat{V}_{кол} \frac{\sum_j V_{j,кол} \hat{x}_j}{\sum_j V_{j,кол}} + \hat{V}_{нал} \frac{\sum_i V_{i,нал} \hat{x}_i}{\sum_i V_{i,нал}} + \hat{V}_{кач} \frac{\sum_l V_{l,кач} \bar{\hat{x}}_l}{\sum_l V_{l,кач}} \right] \times \left[\frac{\hat{V}_{цены} \hat{P}}{\hat{V}_{кол} + \hat{V}_{нал} + \hat{V}_{кач}} \right]. \quad (2.1.2)$$

Выбор групповых весовых коэффициентов $\hat{V}_{кол}, \hat{V}_{нал}, \hat{V}_{кач}$ позволяет установить требуемое соотношение между вкладами оценок количественных, качественных признаков и признаков наличия в комплексный показатель J . Знаменатель последнего сомножителя формулы (2.1.2) позволяет нормировать значение J таким образом, чтобы при достижении всеми признаками максимальных значений показатель J превращался в единицу.

Сложности при решении прямой задачи состоят в выполнении следующих этапов [12]:

- определение целей и задачи экспертизы в раскрытии неправомερных действий;
- применение принципа разделения признаков (выбор наиболее информативных признаков и исключение сильно коррелированных признаков);
- подбор группы экспертов и оценка степени их согласованности;
- оценка экспертами значений признаков x_{ij} ;
- определение весовых коэффициентов методом анализа иерархий Т. Саати;
- сложная процедура нормировки значений признаков и весовых коэффициентов, основанная на определении нормы в трех функциональных пространствах;
- при использовании нечетко-множественных форм комплексных показателей выбор соответствующих функций принадлежности $\mu(\hat{x}_i)$ для каждого из признаков и т.д.

Рассмотрим последовательно основные подгруппы признаков.

1. *Количественные признаки.* Для количественных $\bar{x}_{j, кол}$ и качественных $\bar{x}_{j, кач}$ признаков предполагается усреднение по количеству экспертов (верхняя черта над x). Однако в подавляющем числе ситуаций количественные признаки определяются однозначно из прайс-листов, технических описаний и другой документации. Поэтому, в отличие от качественных признаков, для количественных признаков усреднение, как правило, не требуется и в дальнейшем эти признаки можно обозначать просто $x_{j, кол}$. Кроме того, поскольку из текста обычно ясно, о каких признаках идет речь, сократим для краткости нижний индекс и будем записывать просто x_j .

Для того чтобы обеспечить однородный вклад различных слагаемых во взвешенную сумму, необходимо привести их значения к единому диапазону. Для этого введем следующую нормировку

$$\hat{x}_j = \frac{x_j}{x_{j, баз}}, \quad j = 1, 2, \dots, m, \quad (2.1.3)$$

где знаменатель — максимальное значение признака по всем объектам

$$x_{j, баз} = \max_l x_j^{(l)}, \quad l = 1, 2, \dots, k. \quad (2.1.4)$$

Нормированные таким образом значения признаков $\hat{x}_j \in [0, 1]$, $\forall j$. Максимальное значение нормированных признаков равняется единице, и можно показать, что выражение (2.1.3) удовлетворяет всем аксиомам нормы в пространстве R_0^m . С учетом последней нормировки получим выражение для первого слагаемого формулы (2.1.2), учитывающего влияние количественных признаков

$$J_{\text{кол}} = \left[\hat{V}_{\text{кол}} \frac{\sum_j V_{j,\text{кол}} \hat{x}_j}{\sum_j V_{j,\text{кол}}} \right]. \quad (2.1.5)$$

Приведенная в знаменателе сумма весовых коэффициентов $V_{j,\text{кол}}$ обеспечивает достижение слагаемым $J_{\text{кол}}$ значения единицы в том идеальном случае, когда для некоторого объекта все $\hat{x}_j = 1$.

2. *Признаки наличия.* Подмножество $\{x_{j,\text{нал}}\}$ признаков наличия (ПН) содержит признаки, которые характеризуют наличие или отсутствие некоторого свойства у объекта экспертизы. Например, наличие встроенной видеокамеры или радиоприемника у сотового телефона, наличие сенсорного экрана, наличие сертификата или лицензии и т.д.

Факт наличия или отсутствия j -го признака у объекта экспертизы обычно описывается характеристической функцией $\chi(x_j)$, принимающей значения 1 или 0 соответственно. В целях обеспечения единства описания слагаемых качества на основе формулы (2.1.2) при конструировании обобщенного показателя J , условимся присваивать переменной \hat{x}_j значение «1» в случае наличия j -го признака, и значение «0» — в случае его отсутствия.

С учетом изложенного получим выражение для составляющей показателя качества, учитывающей признаки наличия, в виде

$$J_{\text{нал}} = \left[\hat{V}_{\text{нал}} \frac{\sum_j V_{j,\text{нал}} \hat{x}_j}{\sum_j V_{j,\text{нал}}} \right]. \quad (2.1.6)$$

Нетрудно убедиться, что при выборе всех весовых коэффициентов $V_{j,\text{нал}}$, $\hat{V}_{\text{нал}}$ в формуле (2.1.6) равнозначными, т.е. равными единице, последнее соотношение дает просто относительную величину наблюдения признаков наличия.

3. *Качественные признаки (признаки положительного эффекта.* Обычно при решении задач экспертизы выбираются качественные признаки, увеличение числовых оценок которых ведет к росту комплексного показателя качества J . Такие признаки составляют подмножество $\{x_{r,\text{пэф}}\}$ признаков положительного эффекта (ППЭ). Например, удобство пользования, страна, фирма-изготовитель, внешний вид и т.д.

Получим выражение для составляющей показателя качества, учитывающей признаки качества, в виде

$$J_{\text{кач}} = \left[\hat{V}_{\text{кач}} \frac{\sum_j V_{j,\text{кач}} \hat{x}_j}{\sum_j V_{j,\text{кач}}} \right]. \quad (2.1.7)$$

Как и прежде (в случае признаков наличия), при выборе всех весовых коэффициентов $V_{j,кач}$, $\hat{V}_{кач}$ в формуле (2.1.7) равнозначными, т.е. равными единице, последнее соотношение принимает значение 1 при достижении всеми нормированными признаками оптимальных (единичных) значений.

4. *Признаки отрицательного эффекта.* Признаками *отрицательного эффекта* (ПОЭ) назовем признаки, при увеличении которых, наоборот, происходит уменьшение комплексного показателя (2.1.2). Поэтому для выбора наилучшего объекта экспертизы требуется уменьшение или ограничение вклада соответствующих слагаемых в показатель $J^{(k)}$. Одним из таких признаков является, естественно, цена объекта P . Поэтому остановимся вначале на втором слагаемом исходных формул (2.1.2), (2.1.3), которое будем условно называть функцией цены.

В отличие от формулы (2.1.4) выберем в качестве базового объекта для сравнения с другими объектами экспертизы объект с *минимальным значением признака* по группе сравниваемых объектов

$$x_{j,баз} = \min_l x_j^{(l)}, \quad l = 1, 2, \dots, k \quad (2.1.8)$$

(например, если в качестве признака рассматривается цена объекта, то $P_{баз} = \min P^{(l)}$). Тогда превышение значения j -го признака ПОЭ для l -го объекта над базовым значением будет характеризоваться нормированным признаком

$$\hat{x}_j = \frac{x_{j,баз}}{x_j}. \quad (2.1.9)$$

Например, цена объекта является признаком отрицательного эффекта, и для нее формула (2.1.12) принимает следующий вид

$$\hat{P}^{(k)} = \frac{P_{баз}}{P^{(k)}}. \quad (2.1.10)$$

Сравнивая между собой формулы (2.1.3), (2.1.4) и формулы (2.1.8), (2.1.9), видим, что при переходе от группы признаков положительного эффекта к группе признаков отрицательного эффекта меняется смысл базовых значений признаков: от максимальных по множеству k объектов экспертизы к минимальным.

Выбор групповых весовых коэффициентов $\hat{V}_{кол}$, $\hat{V}_{нал}$, $\hat{V}_{кач}$ позволяет установить требуемое соотношение между вкладами оценок количественных, качественных признаков и признаков наличия в комплексный показатель J . Показатели обладают значительной гибкостью учета соотношений между группами признаков и парциальными признаками за счет введения соответствующих множеств весовых коэффициентов.

2.2 Альтернативный способ учета признаков противоправных действий методом анализа иерархий

Признанным и наиболее научно обоснованным способом оценки весовых коэффициентов является метод анализа иерархий Т. Саати. В своей фундаментальной работе [4] Саати провел детальные статистические и психологические исследования обоснованности и надежности метода, основанного на теории нечетких множеств.

Рассмотрим последовательно в данном разделе два вопроса, связанных методом анализа иерархий, применительно к тематике данной работы.

Существо метода анализа иерархий с расширением его возможностей за счет введения процедуры прямого ранжирования с целью предотвращения одного из недостатков метода — необоснованного подавления весовых коэффициентов для менее значимых объектов экспертизы.

Альтернативный способ учета признаков противоправных действий методом анализа иерархий.

Существо метода анализа иерархий. Остановимся на проблеме определения вектора V весовых коэффициентов, называемого вектором приоритетов. В качестве основы построения алгоритма определения V выберем один из методов парных сравнений, являющийся ядром вычислений МАИ — метод, основанный на вычислении собственных значений

$$\Lambda = (\lambda_1, \lambda_2, \dots, \lambda_m) \quad (2.2.1)$$

и собственных векторов

$$V = (V_1, V_2, \dots, V_m) \quad (2.2.2)$$

матрицы парных сравнений W .

Плодотворные идеи, заложенные Т. Саати в основу метода, сталкиваются на практике с вычислительными особенностями нахождения множества V для обратно-симметрических матриц, а также с выбором исходной лингвистической шкалы. В итоге весовые коэффициенты V_i , соответствующие менее значимым признакам, оказываются резко заниженными по сравнению с другими методами оценки (метод парных сравнений Терстоуна, метод прямого ранжирования и т.д.) [12].

Рассмотрим элементы (признаки) x_1, x_2, \dots, x_m некоторого уровня иерархии. Требуется определить веса V_1, V_2, \dots, V_m влияния этих признаков на некоторый элемент следующего уровня. Основным инструментом будет матрица чисел, представляющих суждения о парных сравнениях.

Обозначим через ω_{ij} число, соответствующее значимости i -го элемента по сравнению с j -ым. Матрицу, состоящую из этих чисел, обозначим через W , т. е. $W = \{\omega_{ij}\}$. Естественно, что для оценки обратного отношения, т.е. величины

значимости V_j по сравнению с V_i , следует использовать обратную величину $\omega_{ji} = 1/\omega_{ij}$. Поэтому матрица W -обратно-симметричная. Если наше суждение верно при всех сравнениях, т.е.

$$\omega_{ik} = \omega_{ij} \omega_{jk} \quad (2.2.3)$$

для всех i, j, k , матрица W называется согласованной.

Рассмотрим вначале частный случай согласованной матрицы, когда сравнения основаны на точных измерениях, т. е. веса V_1, V_2, \dots, V_m известны. Такой случай соответствует реальной ситуации оценки количественных признаков (в отличие от оценки признаков качественных или признаков наличия). При этом

$$\omega_{ij} = V_i/V_j, \quad i, j = 1, 2, \dots, m, \quad (2.2.4)$$

и поэтому полугрупповое свойство (2.2.3) точно выполняется:

$$\omega_{ij} \omega_{jk} = \frac{V_i}{V_j} \frac{V_j}{V_k} = \frac{V_i}{V_k} = \omega_{ik}.$$

В итоге для случая полной согласованности матрицы парных сравнений W получается уравнение вида

$$WV = \lambda V, \quad (2.2.5)$$

т.е. уравнение для собственных чисел и векторов.

Все вышесказанное относилось к идеальному случаю, когда матрица W была полностью согласованной, т.е. выполнялось (2.2.3). Однако на самом деле такая ситуация может быть создана только искусственно. Дело в том, что, выбирая предпочтения основного признака x_1 (обычно ему присваивается первый номер) перед другими и заполняя первую строку матрицы W

$$w_{1j} = (\omega_{11}, \omega_{12}, \dots, \omega_{1m}),$$

мы автоматически определим и первый столбец из обратных величин

$$w_{i1} = (1/\omega_{11}, 1/\omega_{12}, \dots, 1/\omega_{1m})^T.$$

Если рассчитать остальные элементы принудительно, т.е. на основе формулы (2.2.3), то матрица окажется согласованной. Однако на практике эксперты выносят совершенно иные суждения при сравнении признаков, из которых ни один не совпадает с основным (первым).

Рассмотрим реальный случай экспертизы, при котором оценки ω_{ij} основаны не на точных измерениях, а на субъективных суждениях экспертов. В данном случае ω_{ij} будет отклоняться от «идеальных» отношений V_i/V_j , и поэтому уравнение (2.2.3) более не будет иметь места.

Поэтому Т. Саати сформулировал следующую задачу: если W -матрица значений ω_{ij} парных сравнений, то для приближенного нахождения вектора приоритетов нужно найти вектор V , который удовлетворяет уравнению

$$WV = \lambda_{max}V. \quad (2.2.6)$$

Так как малые изменения в ω_{ij} вызывают малое изменение λ_{max} , отклонение последнего от m можно считать мерой согласованности. Оно позволяет оценить близость полученной шкалы к основной шкале отношений, которую мы хотим использовать. Поэтому индекс согласованности выбирается в виде

$$ИС = (\lambda_{max} - m)/(m - 1) \quad (2.2.7)$$

и рассматривается как показатель «близости к согласованности». В общем случае, если это число $\leq 0,1$, мы можем быть удовлетворены суждениями.

На основе индекса согласованности ИС рассчитывается показатель отношения согласованности

$$ОС = ИС/СС, \quad (2.2.8)$$

где СС - значение согласованности случайной матрицы того же порядка.

Средние значения согласованности СС для случайных матриц разного порядка, полученные при случайном выборе количественных парных оценок относительной важности из шкалы 1/9, 1/8, 1/7, ..., 1, 2, ..., 9 и образовании обратно-симметричной матрицы, приведены в табл. 2.2.1.

Таблица 2.2.1

Значения согласованности случайных матриц различного порядка

Порядок матрицы	1	2	3	4	5	6	7	8	9	10
Случайная согласованность	0,00	0,00	0,58	0,90	1,12	1,24	1,32	1,41	1,45	1,49

В работах на основе обобщения опыта решения большого числа многокритериальных задач утверждается, что, для того чтобы парные сравнения можно было считать согласованными, величина ОС должна быть менее, чем 0,1. Если ОС выходит из этих пределов, то экспертам нужно пересмотреть задачу и проверить свои суждения. Отметим, что в матрицах больших размеров, начиная с 7-9 элементов, очень трудно добиться приемлемой согласованности.

В условиях обеспечения максимальной независимости экспертов (когда относительные оценки ω_{ij} не подгоняются искусственно под соотношение (2.2.3)) для получения оценок используется лингвистическая шкала. Наиболее распространенной является шкала, содержащая девять градаций оценок

относительной важности одного из признаков x_i , принимаемого в качестве основного (опорного) по сравнению с другими признаками x_j , $j=1,2,\dots$ (табл. 2.2.2).

С целью уменьшения упомянутых выше негативных особенностей численного нахождения весовых коэффициентов V_{mai} методом МАИ предложим *процедуру коррекции* этих коэффициентов, основанную на использовании линейной комбинации этих весовых коэффициентов с коэффициентами, определенными экспертами на основе *прямого ранжирования* V_{np} :

$$V_{\Sigma} = \gamma V_{mai} + (1 - \gamma) V_{np}, \quad (2.2.9)$$

где $\lambda \in [0,1]$ — коэффициент соотношения между оценками МАИ и прямым ранжированием.

Сущность прямого ранжирования состоит в выборе одного из признаков в качестве основного (опорный признак) и приписывании соответствующему весовому коэффициенту $V_{осн}$ значения единицы. Остальные коэффициенты выбираются меньшими в зависимости от усредненных оценок экспертов: $V_i \leq V_{осн}$. В итоге находится вектор весовых коэффициентов V_{Σ} линейного функционала качества J . При сравнении этого вектора с результатами численных расчетов исключительно по методу МАИ оказывается, что в большинстве случаев вектор V_{Σ} оказывается ближе к интуитивным представлениям о соотношении коэффициентов V_i .

2.3. Прогнозирование обобщенного показателя расчетной операции методом обучения нейронной сети

При сопоставлении характеристик нескольких расчетных операций в системе дистанционного банковского обслуживания и введении комплексного показателя уровня аномальности математическая модель сводится к модели множественной линейной регрессии. Для случая k расчетной операции, обладающих m признаками, модель множественной линейной регрессии примет вид

$$\begin{bmatrix} J_1 \\ J_2 \\ \dots \\ J_k \end{bmatrix} = \begin{bmatrix} x_{11} & x_{12} & \dots & \dots & x_{1m} \\ x_{21} & x_{22} & \dots & \dots & x_{2m} \\ \dots & \dots & \dots & \dots & \dots \\ \dots & \dots & \dots & \dots & \dots \\ x_{k1} & x_{k2} & \dots & \dots & x_{km} \end{bmatrix} \cdot \begin{bmatrix} V_1 \\ V_2 \\ \dots \\ V_m \end{bmatrix}, \quad (2.3.1)$$

где J_i — обобщенный показатель для i -го операции, x_{ij} — значение j -го признака для i -го операции, V_i — весовой коэффициент (коэффициент регрессии).

Во многих случаях необходимо решить обратную задачу экспертизы: зная обобщенные показатели качества известных операций J и матрицу X для нескольких известных образцов, определить множество весовых коэффициентов $\{V_i\}$, а затем использовать это множество для оценки показателей новых операций, т.е. осуществить их прогноз.

Нейронные сети являются мощным вычислительным инструментом для моделирования многих классов технических задач. Однако их серьезным недостатком является неоднозначность решений, обусловленная рядом причин (структура референтных данных, неправильный выбор вида сети, случайный выбор начальных условий) и приводящая иногда к заведомо неверным результатам. Поэтому в работе [14] сделан однозначный вывод о том, что при использовании нейронных сетей всегда необходимо иметь дополнительную тестовую программу, позволяющую хотя бы грубо оценить результаты моделирования. Для нашего класса задач наиболее надежным для проверки представляется применение метода гребневой регрессии.

Обучение нейронной сети по 5 известным образцам. Выдвинем вначале следующую *гипотезу*: поскольку при решении прямой задачи экспертизы используются два уровня весовых коэффициентов — парциальные $\{V_i\}$ и групповые $\{\hat{V}_{gp}\}$ [12], естественным подходом к решению обратной задачи является также применение двухслойной линейной сети (в дальнейшем мы убедимся в справедливости этой гипотезы).

Сформируем вначале двухслойную нейронную сеть прямой передачи сигнала с обратным распространением ошибки (*feed-forward backprop*), воспользовавшись средством GUI (Graphical User Interface) пакета *nntool* вычислительной среды MATLAB-7 (рис. 2.3.1).

Здесь первый слой — скрытый (*hidden*), второй слой — выходной (*output*); $W^{1,2}$ — матрицы весов первого и второго слоя; $b^{1,2}$ — постоянные сигналов смещений первого и второго слоя. Как показано на рисунке, в обоих слоях выбраны линейные функции активации *purelin*.




Рис. 2.3.1. Символическая схема двухслойной нейронной сети

Для обучения сети используем сформированные выше референтные данные. При калибровке нейронной модели могут применяться два подхода: обучение с учителем (train) и последовательная адаптация (adapt). В данном разделе выберем первый метод.

Для обучения сети используем алгоритм Левенберга-Маркуардта (Levenberg-Marquardt). После 5 шагов обучения квадрат среднеквадратической погрешности калибровки модели

$$\text{квадрат СКО} = \frac{1}{m} \sum_{i=1}^m (\delta J_i)^2 \quad (2.3.2)$$

снижается до пренебрежимо малой величины (рис. 2.3.2). При этом градиент принимает значение $2,27 \cdot 10^{-9}$, а коэффициент детерминации $R^2 = 0,994$.




Рис. 2.3.2. Качество обучения двухслойной нейронной сети с линейными функциями активации

Оценка обобщенных показателей отдельных банковских операций после настройки весовых коэффициентов и смещений нейронов имеет вид

$$J = (1,2305 \ 1,0438 \ 1,6811 \ 1,3898 \ 1,1592)^T. \quad (2.3.3)$$

Соответствующие абсолютные погрешности оценки обобщенных показателей $J_1 - J_5$ равны:

$$\begin{aligned} \delta J_1 &= 4,251 \cdot 10^{-2}, \quad \delta J_2 = 2,201 \cdot 10^{-4}, \quad \delta J_3 = 2,294 \cdot 10^{-5}, \\ \delta J_4 &= 1,775 \cdot 10^{-4}, \quad \delta J_5 = 1,942 \cdot 10^{-4}. \end{aligned} \quad (2.3.4)$$

После выполненной настройки веса и смещения нейронной сети примут вид

$$\begin{aligned} IW^{11} &= [2,7352 \ 0,9511 \ -3,2819 \ 2,9019], \quad IW^{21} = 0,1917, \\ b^1 &= 0,9051, \quad b^2 = -0,1018. \end{aligned} \quad (2.3.5)$$

Исходя из (2.3.12), сформируем обобщенный вектор весовых коэффициентов, объединив веса первого и второго нейронов:

$$W = (2,7352 \ 0,9511 \ -3,2819 \ 2,9019 \ 0,1917)^T, \quad (2.3.6)$$

и построим специфическую форму графического представления весов W — диаграмму Хинтона (рис. 2.3.3), воспользовавшись встроенной функцией $hinton(W)$ программы MATLAB.

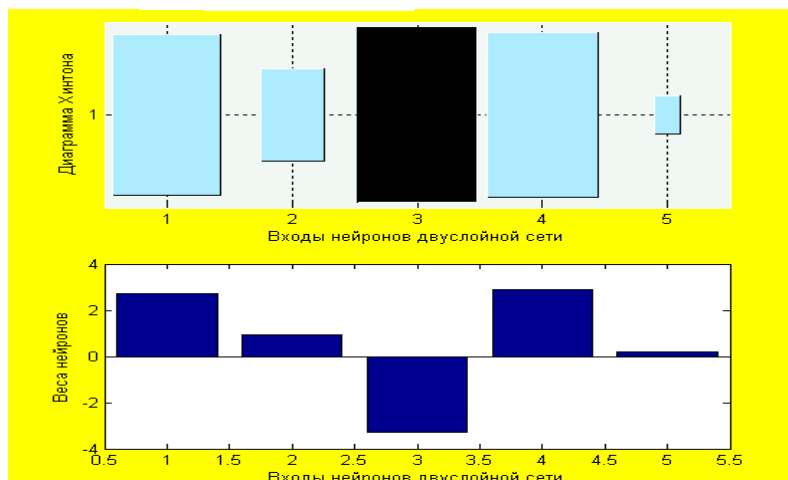


Рис. 2.3.3. Диаграмма Хинтона (верхний рисунок) и веса нейронов сети (нижний рисунок)

На диаграмме относительный вес W_i для i -ой синаптической ветви нейрона представляется прямоугольником, площадь которого пропорциональна весу. Положительные значения весов отображаются светлой закраской, отрицательные — темной. Как видим (см. рис. 2.3.3), все веса положительны, за исключением веса третьей ветви первого нейрона.

Оценим обобщенный показатель J_T аномальности новой расчетной операции, используя полученную после калибровки оценку весов и смещений двухслойной нейронной сети, с помощью процедуры моделирования *sim* пакета *nnTool* языка MATLAB. Характеристический вектор X_T этой банковской операции рассчитан по той же методике, которая применялась при определении матрицы, и имеет вид

$$X_T = (0,646 \quad 0,550 \quad 0,864 \quad 0,656)^T. \quad (2.3.7)$$

С учетом выражений (2.3.6), (2.3.14) вычислим значение показателя

$$J_T = X_T \cdot V = 1,309. \quad (2.3.8)$$

Сравнивая прогнозируемое в результате применения процедуры *sim* значение $\hat{J}_T = 1,3005$ с точным значением (2.3.8), убедимся, что относительная ошибка предсказания обобщенного показателя $\delta_J = 0,00649$, или менее 1%.

Нейронные сети являются мощным вычислительным инструментом для моделирования многих классов технических задач. Однако их серьезным недостатком является неоднозначность решений, обусловленная рядом причин (структура референтных данных, неправильный выбор вида сети, случайный

выбор начальных условий) и приводящая иногда к заведомо неверным результатам. Поэтому в работе [14] сделан однозначный вывод о том, что при использовании нейронных сетей всегда необходимо иметь дополнительную тестовую программу, позволяющую хотя бы грубо оценить результаты моделирования. Для нашего класса задач наиболее надежным для проверки представляется применение метода гребневой регрессии.

В рассматриваемом же случае мы имеем редкую для практики экспертизы удачную ситуацию, когда число доступных для обучения расчетных операций ($k = 5$) больше числа признаков ($m = 4$). Поэтому можно непосредственно воспользоваться методом наименьших квадратов (МНК), согласно которому весовые коэффициенты

$$V = (X^T \cdot X)^{-1} X^T J. \quad (2.3.9)$$

Используя референтные данные (2.3.7), (2.3.8), получим

$$\hat{V} = (0,665 \quad 0,213 \quad 0,123 \quad 0,999)^T \quad (2.3.10)$$

и найдем оценку показателя J_T

$$\hat{J}_T = X_T \cdot \hat{V} = 1,3087, \quad (2.3.11)$$

что подтверждает правильность результатов нейронного моделирования.

Проблема мультиколлинеарности. Проблема мультиколлинеарности векторов, входящих в матрицу референтных данных X , возникает в случае недостатка известных аномальных расчетных операций для обучения калибровочной модели ($k < m$). Покажем, что использование нейронной сети позволяет преодолеть эту проблему.

В отличие от предыдущего случая, используем ограниченное количество расчетных операции $k = 3$.

Для обучения сети используем алгоритм Левенберга-Маркуардта (*Levenberg-Marquardt*). После 4 шагов обучения квадрат среднеквадратической погрешности калибровки модели снижается до пренебрежимо малой величины (рис. 2.3.4). При этом градиент принимает значение $7,82 \cdot 10^{-11}$, а коэффициент детерминации $R^2 = 1,000$.

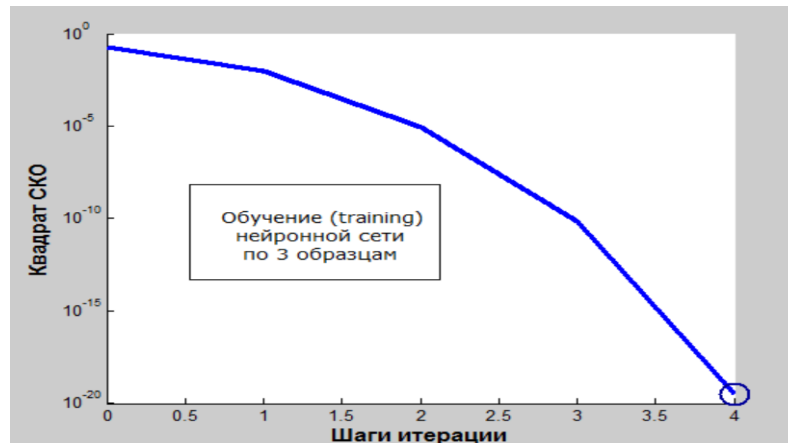


Рис. 2.3.4. Качество обучения двухслойной нейронной сети в условиях мультиколлинеарности

Оценка обобщенных показателей отдельных расчетных операций после настройки весовых коэффициентов и смещений нейронов имеет вид

$$\hat{J} = (1,273 \quad 1,044 \quad 1,681)^T. \quad (2.3.12)$$

Соответствующие абсолютные погрешности оценки обобщенных показателей $J_1 - J_3$ равны:

$$\delta J_1 = 2,329 \cdot 10^{-10}, \quad \delta J_2 = 1,565 \cdot 10^{-10}, \quad \delta J_3 = 9,090 \cdot 10^{-11}. \quad (2.3.13)$$

После выполненной настройки веса и смещения нейронной сети примут вид

$$IW^{11} = [0,8546 \quad -0,0504 \quad 0,4416 \quad 0,8781], \quad IW^{21} = 0,5526, \quad (2.3.14)$$

$$b^1 = 0,2748, \quad b^2 = -0,0623.$$

Оценим обобщенный показатель J_T аномальности новых расчетных операций, используя полученную после калибровки оценку весов и смещений двухслойной нейронной сети (2.3.14), с помощью процедуры моделирования *sim* пакета *nntool* языка MATLAB. В результате моделирования прогнозируемое значение $\hat{J}_T = 1,3701$.

Сравнивая прогнозируемое в результате применения процедуры *sim* значение $\hat{J}_T = 1,3701$ с точным значением, убедимся, что относительная ошибка предсказания обобщенного показателя $\delta_J = 0,0467$, или 4,7%.

Проверим полученный результат. В условиях недостатка образцов для обучения ($k < m$) уже нельзя воспользоваться формулой МНК, поскольку определитель

$$|X^T \cdot X| = 0$$

и вычислить даже первый сомножитель невозможно. Поэтому применим метод гребневой (ridge) регрессии [14], согласно которому используется модифицированная формула

$$V = (X^T \cdot X + \alpha I)^{-1} X^T J, \quad (2.3.15)$$

где I — единичная диагональная матрица, α — параметр регуляризации.

Последовательно уменьшая величину α , будем вычислять вектор весовых коэффициентов \hat{V} и оценивать относительную погрешность

$$\delta_V = \sqrt{[(\hat{V} - V)^T (\hat{V} - V)]} / \sqrt{V^T V}. \quad (2.3.16)$$

Получим следующие результаты:

Относительная погрешность оценки вектора весовых коэффициентов

α	0,1	0,01	0,001	10^{-6}	10^{-9}
δ_V	0,382	0,191	0,156	0,156	0,155

Как видим, наименьшее значение погрешности достигается при $\alpha = 10^{-9}$. Соответствующий этому α вектор весовых коэффициентов имеет вид

$$\hat{V} = (0,801 \quad 0,177 \quad 0,152 \quad 0,878)^T. \quad (2.3.17)$$

Перемножив характеристический вектор (2.3.14) тестовой операции и найденный методом гребневой регрессии вектор весов (2.3.24), получим

$$\hat{J}_T = X_T \cdot \hat{V} = 1,315, \quad (2.3.18)$$

что дает по сравнению с точным значением относительную погрешность 0,9 %.

Итак, двухслойная нейронная сеть позволяет эффективно прогнозировать значение обобщенного показателя аномальности операции после обучения по 5 известным образцам с погрешностью 0,67%, а после обучения по 3 образцам и преодоления проблемы мультиколлинеарности — 4,7%. Результаты численного моделирования дают возможность сделать следующие выводы: 1) использование нейронных сетей позволяет преодолеть проблему мультиколлинеарности, возникающую в случае недостатка известных образцов для обучения сети; 2) результаты нейронного моделирования всегда должны проверяться альтернативным способом, например методом гребневой регрессии.

3. Классификация и кластеризация расчетных операций с помощью самоорганизующихся нейронных сетей

3.1. Метод экспертизы на основе ассоциативного обучения самоорганизующейся нейронной сети

При оценке аномальности банковских операций в среде дистанционного банковского обслуживания принято [12] для каждой расчетной операции использовать обобщенный показатель качества в виде линейного функционала

$$J_k = \sum_{j=1}^m V_j x_{kj}, \quad k=1,2,\dots,K, \quad (3.1.1)$$

где k — номер одного из K сравниваемых объектов, x_{kj} — переменные (признаки) различной природы (количественные, качественные, стоимостные и др.), оценка которых дается экспертами; m — количество признаков, учитываемых при экспертизе.

При решении прямой задачи оценки аномальности определяются значения обобщенных показателей J_k для всех объектов, а затем выбирается один объект, для которого J_k принимает максимальное значение. В практике применения нейронных сетей такой методике соответствует встроенная функция *compnet* пакета *ntool* языка MATLAB, реализующая принцип «победитель получает все». Однако при этом информация о других расчетных операциях теряется.

Вместе с тем теория *самоорганизующихся нейронных сетей* предлагает иной методологический подход к задаче экспертизы, при котором сохраняется информация обо всех объектах, что позволяет рассмотреть их показатели в совокупности — принцип мягкого максимума (*softmax*), основанный на модели смешения оценок экспертов. Представляется, что такой подход позволяет получить более достоверные результаты экспертизы, особенно в случаях, когда характеристики объектов сильно различаются.

Целью данного раздела является развитие метода экспертизы, основанного на ассоциативном обучении нейронных сетей и являющегося альтернативой обычным методам решения прямой задачи экспертизы [12, 13]. Далее предложено построение двух вариантов самоорганизующихся нейронных сетей для оценки аномальности расчетных операций в среде дистанционного банковского обслуживания и проводится сравнительный анализ получаемых решений.

Вероятностная модель ассоциативного обучения. Как было отмечено ранее, совместная экспертиза нескольких однородных объектов приводит к математической модели линейной множественной регрессии. Рассмотрим задачу *регрессии*, в которой вектор-регрессор x порождает отклик, обозначаемый случайной переменной Z с реализацией z . Предположим, что генерация отклика z определяется следующей вероятностной моделью [111, 130].

1. Из некоторого наперед заданного распределения случайным образом выбирается вектор x .

2. Для заданного вектора x и некоторого вектора параметров $a^{(0)}$ выбирается k - е правило в соответствии с условной вероятностью $P(k | x, a^{(0)})$.

3. Для правила k ($k = 1, 2, \dots, K$) отклик модели является линейным по x с аддитивной ошибкой $e(k)$, моделируемой как случайная переменная с гауссовым распределением, имеющим среднее значение и дисперсию

$$M[e_k] = 0; \quad D[e_k] = 1. \quad (3.1.2)$$

Генерация переменной Z определяется условной вероятностью $P(Z = z | x, w_k^{(0)})$ для заданного вектора x и некоторого вектора весов нейрона $w_k^{(0)}$, где $k = 1, 2, \dots, K$.

Требуется, чтобы реализованные в этой модели вероятностные решения определяли модель, которая с увеличивающейся точностью определяет положение условного среднего значения отклика z в нелинейном многообразии, которое связывает входной вектор со средним значением выходного сигнала.

Итак, отклик Z может быть сгенерирован K различными способами в соответствии с K вариантами выбора эксперта (нейрона) k . Таким образом, условная вероятность генерирования отклика $Z = z$ для входного вектора x будет равна

$$P(Z = z | x, \theta^{(0)}) = \sum_{k=1}^K P(Z = z | x, w_k^{(0)}) \cdot P(k | x, a^{(0)}), \quad (3.1.3)$$

где $\theta^{(0)}$ — вектор параметров порождающей модели, обозначающий комбинацию $a^{(0)}$ и $\{w_k^{(0)}\}$.

Нейронная модель смешения оценок экспертов. Рассмотрим следующую конфигурацию нейронной сети (рис. 3.1.1). Такая сеть называется моделью *смешения мнений экспертов* и состоит из K нейронных сетей (модулей), обучаемых с учителем и называемых сетями экспертов, или просто *экспертами*. Интегрирующий элемент называется «сеть шлюза». Предполагается, что различные эксперты лучше всего работают в своих областях входного пространства согласно вероятностной порождающей модели множества входных данных.

В задаче линейной множественной регрессии каждая из сетей экспертов представляет собой линейный фильтр. Таким образом, выходной сигнал, производимый экспертом k , является скалярным произведением входного вектора x и вектора синаптических весов w_k данного нейрона, т.е.

$$u_k = w_k^T x, \quad k = 1, 2, \dots, K. \quad (3.1.4)$$

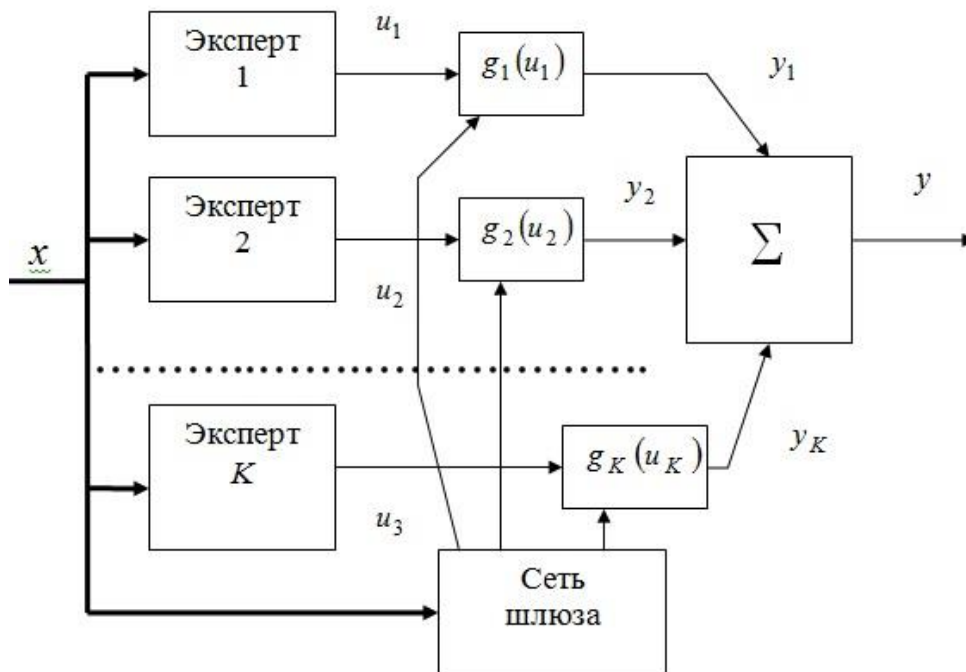


Рис. 3.1.1. Модель смешения оценок экспертов

Сеть шлюза содержит один слой из K нейронов, каждый из которых соответствует одному из экспертов. В отличие от экспертов нейроны сети шлюза являются нелинейными. Их функции активации имеют следующий вид:

$$g(k) = \frac{\exp(u_k)}{\sum_{j=1}^K \exp(u_j)}, \quad k = 1, 2, \dots, K, \quad (3.1.5)$$

где u_k — скалярные произведения (3.1.4).

Нормированное преобразование (3.1.5) является обобщением логистической функции активации для нескольких входов. В ней реализовано обобщение операции «победитель получает все», извлекающей максимальное значение. Поэтому функция активации вида (3.1.5) называется *softmax*. При этом линейная зависимость u_k от входного вектора x приводит к нелинейной зависимости выходного значения сети шлюза от x .

Для вероятностной интерпретации роли сети шлюза будем считать ее «классификатором», который отображает входной вектор x в значение мультиномиальной вероятности так, чтобы различные эксперты могли внести вклад в желаемый отклик. Использование функции активации *softmax* в сети шлюза гарантирует, что эти вероятности будут удовлетворять следующим условиям:

$$0 \leq g(k) \leq 1, \quad \forall k \quad (3.1.6)$$

и

$$\sum_{k=1}^K g(k) = 1. \quad (3.1.7)$$

Пусть u_k — выходной сигнал k -го нейрона (эксперта), тогда общий выход модели имеет вид:

$$y = \sum_{k=1}^K g_k(u_k), \quad (3.1.8)$$

где g_k — нелинейная функция x . Предполагая, что выбрано правило k вероятностной модели, выход эксперта u_k можно рассматривать как условное среднее значение переменной Z порождающей вероятностной модели:

$$M[Z|x, k] = u_k = w_k^T x, \quad k = 1, 2, \dots, K. \quad (3.1.9)$$

Обозначая символом μ_k условное среднее значение переменной Z , запишем:

$$\mu_k = u_k, \quad k = 1, 2, \dots, K. \quad (3.1.10)$$

Дисперсия переменной совпадает с дисперсией ошибки e_k . Тогда, используя равенство (3.1.2), приходим к соотношению

$$D[Z|x, k] = 1, \quad k = 1, 2, \dots, K. \quad (3.1.11)$$

Функция плотности распределения вероятностей переменной Z с учетом предположения о том, что выбрано k -ое правило вероятностной порождающей модели (т.е. эксперт k), может быть записана в следующем виде:

$$f_Z(z|x, k, \theta) = \frac{1}{\sqrt{2\pi}} \exp\left[-\frac{1}{2}(z - u_k)^2\right], \quad (3.1.12)$$

где θ — вектор, объединяющий параметры сети шлюза и параметры экспертов модели. Функция плотности вероятности переменной Z является смесью функций плотности вероятности

$$\{f_Z(z|x, k, \theta)\}_{k=1}^K,$$

где смешанные параметры θ определяются сетью шлюза. Поэтому можно записать следующее выражение:

$$f_Z(z|x, \theta) = \sum_{k=1}^K g_k f_Z(z|x, k, \theta) = \frac{1}{\sqrt{2\pi}} \sum_{k=1}^K g_k \exp\left[-\frac{1}{2}(z - u_k)^2\right]. \quad (3.1.13)$$

Распределение вероятности (3.1.13) называется *ассоциативной гауссовой моделью смешения*. Ассоциативная модель отличается от неассоциативной тем, что условное среднее значение μ_k и параметры смешения g_k не фиксированы — они являются функциями входного вектора x . Таким образом, ассоциативная гауссова модель смешения (3.1.13) является обобщением обычной гауссовой модели смешения.

Особенностями этой модели являются следующие:

1) выход y_k k -го эксперта является оценкой условного среднего значения случайной переменной для желаемого отклика z , вектора x и правила k вероятностной порождающей модели;

2) выход g_k сети шлюза определяет мультиномиальную вероятность того, что выход эксперта k соответствует значению $Z = z$ на основе знаний, полученных только от вектора x .

С учетом распределения вероятности (3.1.13) и заданного набора примеров обучения

$$\{(x_i, z_i)\}_{i=1}^N$$

задача сводится к адаптации условного среднего $\mu_k = y_k$ и параметров смещения g_k , $k = 1, 2, \dots, K$, таким образом, чтобы функция $f_Z(z|x, \theta)$ представляла собой хорошую оценку функции плотности вероятности среды данных обучения.

Формирование референтных данных с признаками общей инженерной оценки. В задачах многомерного статистического анализа под формированием референтных данных понимается определение матрицы X нормированных оценок m признаков размерности $(K \times m)$ и вектора J обобщенных показателей качества размерности $(K \times 1)$ всех сравниваемых K объектов.

Проведем далее сравнительную экспертизу операций в СДБО и представим матрицу референтных данных

$$X = \begin{bmatrix} 0,584 & 1,000 & 0,892 & 0,562 \\ 0,447 & 0,250 & 0,762 & 0,600 \\ 0,796 & 0,250 & 0,807 & 1,000 \\ 0,771 & 1,000 & 0,929 & 0,548 \\ 0,634 & 0,250 & 0,931 & 0,570 \end{bmatrix}, \quad (3.1.14)$$

где строки соответствуют последовательно рассматриваемым операциям, а столбцы — нормированным признакам: первый столбец — взвешенная сумма количественных признаков, второй — взвешенная сумма признаков наличия, третий — взвешенная сумма качественных признаков, четвертый — нормированный признак стоимости.

Альтернативный метод решения прямой задачи экспертизы. В работах [12, 13] была детально описана методика решения прямой задачи экспертизы, целью которой являлось выделение среди множества сравниваемых объектов *одного наилучшего объекта* по критерию максимума обобщенного показателя J . При использовании самоорганизующихся нейронных сетей такой задаче соответствует функция активизации сети *compet* языка MATLAB, реализующая принцип «победитель получает все».

Применим функцию активации *compet* к множеству показателей и представим полученные результаты графически (рис. 3.1.2).

В верхней части рис. 3.1.2 приведены значения показателя J , соответствующие выражению, а в нижней части — выходной сигнал нейронной сети при использовании функции активации *compet*. Как и следовало ожидать, только один (четвертый) нейрон «выиграл» в процессе конкурентной борьбы. Выходы сети, соответствующие другим нейронам, равны нулю.

Это вполне соответствует обычной методике решения прямой задачи экспертизы, поскольку целью ее являлось выявление единственного объекта с наилучшими показателями. Однако, как следует из нижней части рис. 3.1.2, информация о показателях других объектов экспертизы оказалась утерянной.

Для комментария данной ситуации сошлемся на мнение известного специалиста в области нейронных сетей С. Хайкина: «Жесткие решения, к сожалению, приводят к потере информации, в то время как мягкие решения ее сохраняют... это эмпирическое правило утверждает, что информация, содержащаяся во входном сигнале, может быть эффективно сохранена с вычислительной точки зрения до тех пор, пока система не будет готова к окончательному принятию решения или оценке параметра».




Рис. 3.1.2. Единственный выход сети при функции активации *compet*

Поэтому при формировании нейронной сети представляется целесообразным перейти от жесткой конкурирующей функции активации *compet* к конкурирующей функции активации с мягким максимумом *softmax* (в

пакете ПП *Simulink* языка MATLAB соответствующие блоки активации обозначены символами С и S) (рис. 3.1.3).

Применение процедуры ассоциативного обучения с нормализованной функцией активации *softmax* приводит к совершенно иной интерпретации решения прямой задачи экспертизы (нижняя часть рис. 3.1.3). Каждому из сравниваемых приборов соответствует выход сети y_k . Поскольку при процедуре *softmax* осуществляется своего рода выравнивание различных показателей и даже отрицательным показателям присваивается некоторое (хотя, и малое) положительное значение, назовем выходы y_k *толерантными обобщенными показателями качества* и обозначим G_k .

Действительно, на этом рисунке: 1) все показатели G_k , в отличие от исходных показателей качества J_k , приняли положительные значения; 2) полученные показатели G_k нормированы и сумма их равна единице; 3) сохранилась информация об остальных объектах, что позволяет лучше оценивать всю картину экспертизы; 4) показано, что даже второй объект, имеющий отрицательное значение показателя J_2 , имеет некоторое «право» на участие в экспертизе.

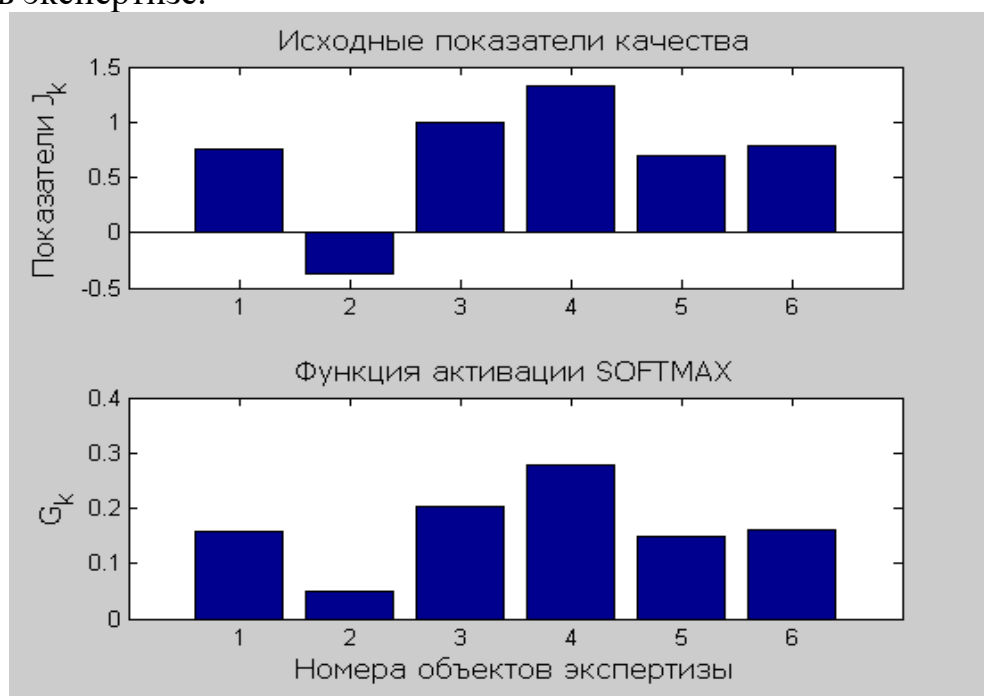


Рис. 3.1.3. Ассоциативное обучение с функцией активации *softmax*

Сравним нижние части рис. 3.1.2 и рис. 3.1.3. Качественное соотношение между объектами экспертизы сохранилось: по-прежнему наилучшим объектом остается четвертый прибор, а наихудшим — второй, т.е. выводы экспертизы остаются неизменными.

Предлагаемый метод ассоциативного обучения нейронных сетей является альтернативой обычному подходу к решению прямой задачи экспертизы,

изложенному в работах [12, 13]. Представляется, что особенно эффективным он окажется в случае больших разбросов характеристик сравниваемых объектов, в частности, признаки которых могут принимать отрицательные значения.

3.2. Классификация расчетных операций на основе обучения персептрона

Персептрон является одной из наиболее изученных нейронных сетей, дающей надежные результаты классификации множества характеристических векторов, подаваемых на его вход. Его теории и применению посвящен целый ряд работ [16, 17 и др.].

Характерной особенностью персептрона является наличие ненулевого смещения нейрона b^1 , обычно равного (-1). Функция активации персептрона нелинейна и имеет вид

$$f(z) = \begin{cases} 1, & z \geq 0, \\ -1, & z < 0. \end{cases} \quad (3.2.1)$$

Сигнал z на выходе сумматора со взвешенными элементами вектора входного сигнала (рис. 3.2.1) может быть представлен в эквивалентной форме воздействия расширенного вектора входного сигнала размерности $(m + 1)$, если включить в качестве элемента x_0 сигнал смещения:

$$z = \sum_{i=1}^m w_i x_i - v = \sum_{i=0}^m w_i x_i, \quad (3.2.2)$$

где $w_0 = v$, $x_0 = -1$.

Целью персептрона является классификация входного вектора

$$x = (x_1, x_2, \dots, x_m)^T$$

таким образом, чтобы отнести его к одному из двух классов Ω_1, Ω_2 . Персептрон отнесет вектор x к классу Ω_1 , если выходной сигнал z примет значение 1, или классу Ω_2 , если выходной сигнал z примет значение минус 1. Таким образом, персептрон разделяет m -мерное пространство входных сигналов на два подпространства, разделенные $(m-1)$ -мерной гиперплоскостью, уравнение которой имеет вид

$$\sum_{i=1}^m w_i x_i - v = \sum_{i=0}^m w_i x_i = 0. \quad (3.2.3)$$

Гиперплоскость (3.2.3) называется *решающей границей* (decision boundary). Если $m = 2$, то это — прямая линия, задаваемая уравнением

$$w_1 x_1 + w_2 x_2 - v = 0, \quad (3.2.4)$$

причем точка (x_1, x_2) , лежащая над этой прямой, относится к классу Ω_1 , а точка (x'_1, x'_2) , лежащая под этой прямой — к классу Ω_2 .

Предположим, что в начале процесса настройки веса нейрона в уравнении гиперплоскости (3.2.3) неизвестны, а на вход персептрона последовательно подаются обучающие сигналы $x(n)$, $n = 1, 2, \dots$, где

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

Неизвестные значения весов будут определяться в процессе обучения персептрона. Такой метод настройки называется «обучение с учителем». Обучение заключается в правильном отнесении сигналов $x(n)$ к классам Ω_1 или Ω_2 , несмотря на неизвестность весов уравнения (3.2.3).

По завершении процесса обучения персептрон должен правильно классифицировать поступающие на его вход сигналы, в том числе и те, которые отсутствовали в обучающей последовательности $x(n)$, $n = 1, 2, \dots$. В этом и заключается идея: обучение по заданному количеству известных образцов — классификация новых образцов.

Повторим, что множества векторов, для которых выходной сигнал принимает значения $+1$ или -1 должны быть линейно разделимы, т.е. лежат в различных подпространствах, разделенных гиперплоскостью (3.2.3).

В n -ый момент времени сигнал на выходе сумматора (см. рис. 3.2.1) определяется выражением

$$z(n) = \sum_{i=0}^m w_i(n)x_i(n) = w^T(n)x(n), \quad (3.2.5)$$

где

$$x(n) = [-1, x_1(n), x_2(n), \dots, x_m(n)]^T, \quad (3.2.6)$$

$$w(n) = [v(n), w_1(n), w_2(n), \dots, w_m(n)]^T. \quad (3.2.7)$$

Обучение персептрона заключается в сохранении вектора весов $w(n)$ согласно формулам

$$w(n+1) = \begin{cases} w(n), & \text{если } w^T(n)x(n) \geq 0 \text{ и } x(n) \in \Omega_1, \\ w(n), & \text{если } w^T(n)x(n) < 0 \text{ и } x(n) \in \Omega_2, \end{cases} \quad (3.2.8)$$

и коррекции в случаях

$$w(n+1) = \begin{cases} w(n) - \eta x(n), & \text{если } w^T(n)x(n) \geq 0 \text{ и } x(n) \in \Omega_2, \\ w(n) + \eta x(n), & \text{если } w^T(n)x(n) < 0 \text{ и } x(n) \in \Omega_1, \end{cases} \quad (3.2.9)$$

где параметр η при $0 < \eta < 1$ — шаг коррекции, а начальные значения вектора весов полагаются равными нулю:

$$w(0) = 0. \quad (3.2.10)$$

Формулы (3.3.8) и (3.3.9) можно представить в более компактном виде. Для этого введем эталонный сигнал $d(n)$:

$$d(n) = \begin{cases} +1, & \text{если } x(n) \in \Omega_1 \\ -1, & \text{если } x(n) \in \Omega_2. \end{cases} \quad (3.2.11)$$

Выходной сигнал персептрона может быть записан как

$$y(n) = \text{sgn}[w^T(n)x(n)]. \quad (3.2.12)$$

Тогда (3.3.8) и (3.3.9) принимают единый вид [91]:

$$w(n+1) = w(n) + [d(n) - y(n)]x(n), \quad (3.2.13)$$

где разность $d(n) - y(n)$ можно считать погрешностью между эталонным сигналом и фактическим выходным сигналом.

Сходимость алгоритма (3.3.13) доказана в ряде работ [70, 111], причем под сходимостью понимается выполнение условия

$$w(n_0) = w(n_0 + 1) = w(n_0 + 2) = \dots \quad (3.2.14)$$

где n_0 – последний шаг обучения.

По окончании обучения решающая граница персептрона определяется выражением [91]:

$$\sum_{i=0}^m w_i(n_0)x_i = 0, \quad (3.2.15)$$

а персептрон правильно классифицирует как сигналы, которые принадлежат к обучающей выборке $\{x_i(n)\}$, так и не входящие в это множество, но линейно разделимые.

3.3. Кластеризация на основе самоорганизующейся нейронной сети в виде слоя Кохонена

Рассмотрим самоорганизующуюся нейронную сеть, задача которой состоит в правильной группировке (кластеризации) поступающих на нее характеристических векторов объектов экспертизы. Сформируем с помощью пакета *Nntool* языка MATLAB слой Кохонена, архитектура которого показана на рис. 3.3.1.

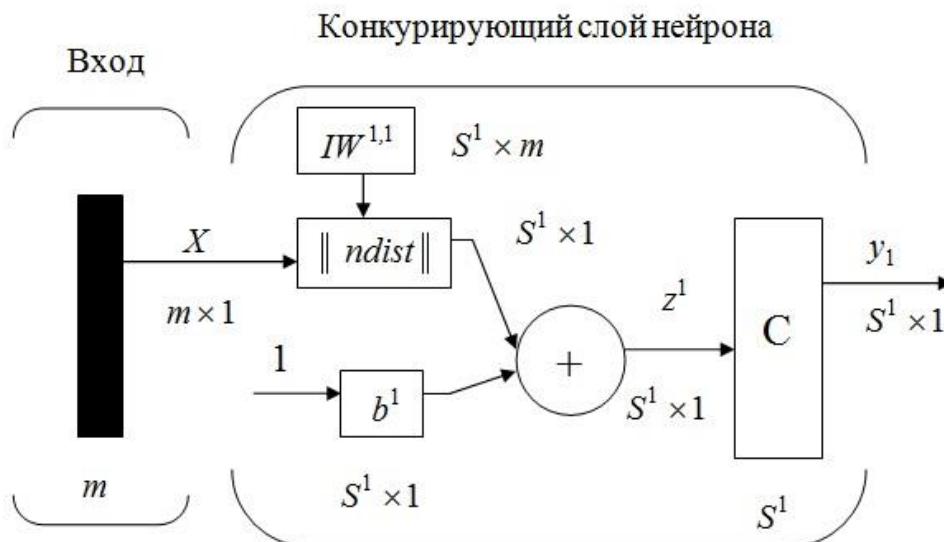


Рис. 3.3.1. Архитектура нейронной сети с конкурирующим слоем

На этом рисунке: заштрихованный прямоугольник — блок формирования входных данных X ; $W^{1,1}$ — веса нейронов первого слоя; b^1 — смещения нейронов первого слоя; S^1 — количество нейронов в первом слое; $\|ndist\|$ — встроенная функция «отрицательное евклидово расстояние» пакета *Nntool*; C — конкурирующая функция активации, реализуемая с помощью встроенной функции *compet* пакета *Nntool*.

Это пример слоя конкурирующего типа, поскольку в нем применена конкурирующая функция активации. Здесь использован блок *ndist* для вычисления отрицательного евклидова расстояния между вектором входа x и строками матрицы весов $W^{1,1}$.

Вход функции активации z^1 — это результат суммирования вычисленного расстояния с вектором смещения b^1 . Если все смещения нулевые, максимальное значение z^1 не может превышать 0. Нулевое значение z^1 возможно, только когда вектор входа x оказывается равным вектору весов одного из нейронов. Если смещения отличны от 0, то элементы вектора z^1 могут принимать также положительные значения.

Конкурирующая функция активации анализирует значения элементов вектора z^1 и формирует выходы нейронов, равные 0 для всех нейронов, кроме одного нейрона (победителя), имеющего на входе максимальное значение. Таким образом, вектор выхода слоя y^1 имеет единственный элемент, равный 1. Этот элемент соответствует нейрону-победителю, а остальные элементы равны 0. Такая активационная характеристика была предложена в работе.

Активационная характеристика устанавливается не на отдельный нейрон, а на слой, и поэтому такая активационная характеристика получила название *конкурирующей*. Номер активного нейрона r определяет ту группу (кластер), к которой наиболее близок входной вектор.

Правило обучения слоя Кохонена заключается в том, чтобы настроить нужным образом элементы матрицы весов $W^{1,1}$. Предположим, что нейрон r победил при подаче входа $x(n)$ на шаге самообучения n , тогда строка r матрицы весов корректируется в соответствии с этим правилом. В пакете *nntool* настройка параметров сети по правилу Кохонена реализована в виде М-функции *learnk*.

Нейрон-победитель и все нейроны, лежащие в пределах его окрестности, подвергаются адаптации, в ходе которой их векторы весов изменяются «в направлении» вектора x по правилу Кохонена:

$$w_i(n+1) = w_i(n) + \eta_i(n)[x - w_i(n)], \quad (3.3.1)$$

где через $\eta_i(n)$ обозначен параметр (коэффициент) скорости обучения i -го нейрона в его окрестности в n -ый момент времени (на n -ой итерации).

Итак, правило Кохонена представляет собой рекуррентное соотношение, которое обеспечивает коррекцию строки r матрицы весов добавлением взвешенной разности вектора входа и значения строки на предыдущем шаге. Вектор веса, наиболее близкий к вектору входа, модифицируется так, чтобы расстояние между ними стало еще меньше. В конечном счете, если в слое имеется достаточное количество нейронов, то каждая группа близких векторов окажется связанной с одним из нейронов слоя. В этом и заключается свойство самоорганизации слоя Кохонена.

Правило настройки смещений. Одна из проблем конкурирующего слоя состоит в том, что некоторые нейроны оказываются незадействованными (мертвые нейроны). Это проявляется в том, что нейроны, имеющие начальные весовые векторы, значительно удаленные от векторов входа, никогда не выигрывают конкуренции, независимо от того, как долго продолжается обучение.

Чтобы исключить такую ситуацию и сделать все нейроны чувствительными к поступающим на вход векторам, используются смещения (biases), которые позволяют нейрону стать конкурентным с нейронами-победителями. Это достигается положительным смещением, которое добавляется к отрицательному расстоянию удаленного нейрона. Соответствующее правило настройки, учитывающее нечувствительность мертвых нейронов, реализовано в пакете `nntool` виде М-функции `learncon` и заключается в следующем.

В начале процедуры настройки всем нейронам конкурирующего слоя присваивается одинаковый *параметр активности*

$$a_0 = \frac{1}{S}, \quad (3.3.2)$$

где S — количество нейронов конкурирующего слоя, равное числу кластеров. В процессе настройки М-функция `learncon` корректирует этот параметр таким образом, чтобы его значения для активных нейронов становились больше, а для неактивных нейронов — меньше. Формула для вектора приращений параметров активности имеет вид

$$\Delta a_i(n) = lr(y_i^1(n) - a_i(n)), \quad (3.3.3)$$

где n — номер итерации; lr — параметр скорости настройки; $y_i^1(n)$ — вектор, i -ый элемент которого равен 1, а остальные элементы равны 0.

Можно убедиться, что для всех нейронов, кроме нейрона-победителя, приращения отрицательны. Вектор параметров смещений связан с вектором параметров активности соотношением [70]

$$b(n) = \exp(1) ./ a(n), \quad (3.3.4)$$

где символами «точка с наклонной чертой» $./$ обозначена специфическая операция *rdivide* языка MATLAB (*right – array division*). Эта операция осуществляет поэлементное деление двух массивов. Из (3.3.4) следует, что смещение для нейрона-победителя уменьшится, а смещения для остальных нейронов увеличатся.

M-функция *learncon* использует следующее выражение для расчета приращений вектора смещений:

$$\Delta b = \exp(1 - \log(a)) - b. \quad (3.3.5)$$

Параметр скорости настройки *lr* по умолчанию равен 0.001, и его величина обычно на порядок меньше соответствующего значения для M-функции *learnk*. Увеличение смещений для неактивных нейронов позволяет расширить диапазон покрытия входных значений, и неактивный нейрон начинает формировать кластер.

Это дает следующие преимущества [70]. Если нейрон не выигрывает конкуренции, то его смещение в процессе обучения становится достаточно большим и он становится конкурентоспособным. Когда это происходит, его вектор весов начинает приближаться к некоторой группе (кластеру) векторов входа. Как только нейрон начинает побеждать, его смещение начинает уменьшаться. Таким образом, задача активации мертвых нейронов разрешается. Второе преимущество, связанное с коррекцией смещений, состоит в том, что они позволяют выровнять значения параметра активности и обеспечить «притяжение» приблизительно одинакового количества векторов входа.

Разделение объектов экспертизы на 3 класса. Создадим слой Кохонена с помощью M-функции *competlayer* (рис. 3.3.2).

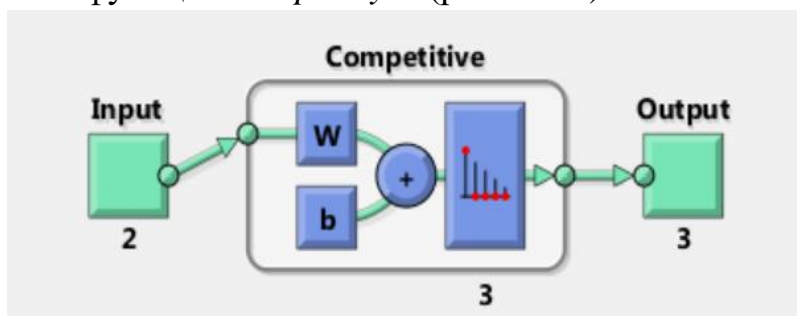


Рис. 3.3.2. Самоорганизующаяся сеть с тремя нейронами

Как видим, это слой конкурирующего типа, поскольку в нем применена конкурирующая функция активации. Номер активного нейрона i определяет группу (кластер), к которой наиболее близок входной вектор.

В предыдущем разделе для матрицы референтных данных 6 образцов расчетных операций с помощью встроенной функции `Nipals` языка `Mathcad` были определены счета МГК. Дополнив эти выражения элементами счетов для 7-го тестового образца, получим расширенные счета для 7 образцов:

$$t_1 = (0,301 \quad -0,957 \quad -0,083 \quad 0,743 \quad -0,071 \quad 0,067 \quad -0,198)^T, \quad (3.3.6)$$

$$t_2 = (0,353 \quad 0,249 \quad -0,453 \quad 0,108 \quad -0,221 \quad -0,037 \quad 0,771)^T. \quad (3.3.7)$$

В созданном М-файле языка `MATLAB` использованы, в частности, процедуры

```
net=newc[-3 3;-3 3],c,0,1);
net.trainParam.epochs=100;
net=train(net,P);
w=net.IW(1);w=cell2mat(w),
```

определяющие: количество кластеров (c); количество итераций ($epochs$); процедуру обучения ($train$), веса w настроенной нейронной сети.

Для счетов (3.3.6), (3.3.7) осуществим кластеризацию (рис. 3.3.3).

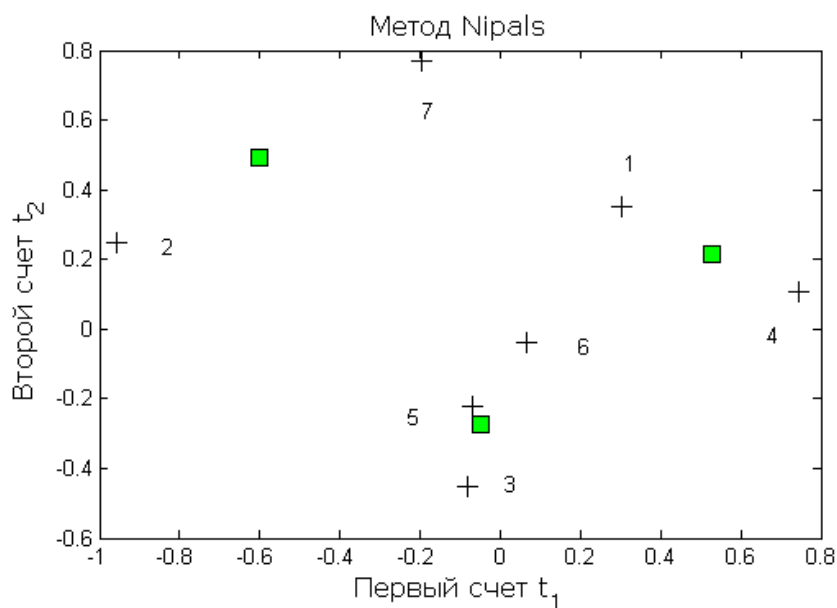


Рис. 3.3.3. Кластеризация объектов экспертизы на 3 кластера

На этом рисунке квадратными маркерами обозначены центры кластеров, а крестиками — данные образцов экспертизы. Как видим, к первому кластеру (аномальные операции) относятся образцы 1 и 4, ко второму кластеру (подозрительные операции) — образцы 3, 5, 6 к третьему кластеру (приемлемые операции) — образцы 2 и 7.

В начале процесса обучения активность различных нейронов в соответствии с формулой (3.3.2) устанавливается одинаковой, а в конце обучения третий нейрон наиболее активен (рис. 3.3.4).

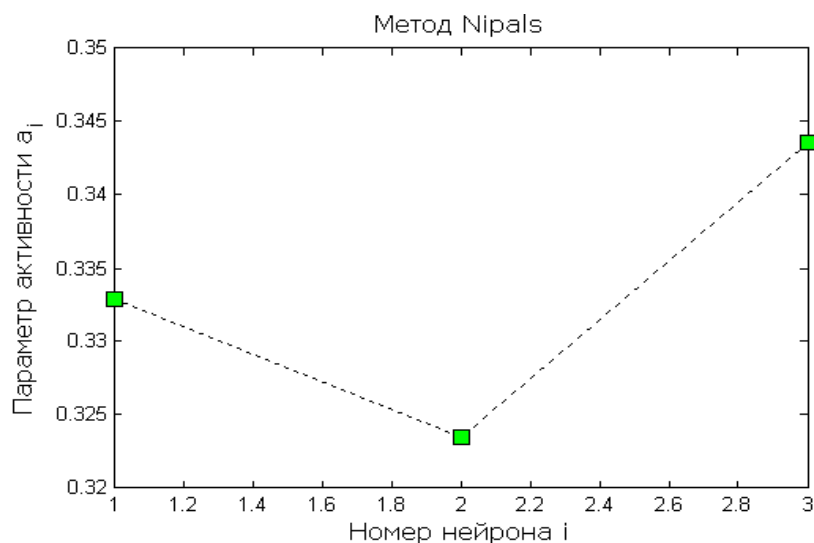


Рис. 3.3.4. Параметр активности различных нейронов

Выделение главных компонент методом SVD. Существо метода главных компонент состоит в разложении матрицы референтных данных X на произведение матриц «счетов» T и транспонированной матрицы «нагрузок» P :

$$X = TP^T + E, \quad (3.3.8)$$

где E — матрица остатков.

Как мы убедились, ограничение только двумя первыми векторами счетов t_1, t_2 дает возможность осуществить кластеризацию и представить взаимное расположение объектов графически (см. рис. 3.3.3).

Ранее в разделе 3.2 для выделения счетов t_1, t_2 использовалась итеративная процедура Nipals языка Mathcad, далее применим альтернативный подход — алгебраическую процедуру SVD (Singular Value Decomposition) языка MATLAB.

Затем применим разработанную программу (M-файл) конкурентного обучения к разделению множества референтных данных для 7 операций на 3 класса. Расширим референтную матрицу X , представленную в разделе 3.2 формулой (3.3.16), добавив данные тестового образца X_{np} (3.3.28):

$$X = \begin{pmatrix} 0,584 & 1,000 & 0,892 & 0,562 & 0,000 \\ 0,447 & 0,250 & 0,762 & 0,600 & -1,000 \\ 0,796 & 0,250 & 0,807 & 1,000 & 0,000 \\ 0,711 & 1,000 & 0,929 & 0,548 & 0,500 \\ 0,634 & 0,250 & 0,931 & 0,570 & 0,000 \\ 0,646 & 0,550 & 0,864 & 0,650 & 0,000 \\ 0,584 & 1,000 & 0,892 & 0,562 & -1,000 \end{pmatrix}. \quad (3.3.9)$$

В методе SVD обычным приемом [70] нахождения главных компонент является предварительное центрирование и нормировка (шкалирование) векторов-строк матрицы референтных данных (3.4.9). Воспользовавшись встроенной функцией *prestd* языка MATLAB, осуществим эти операции и получим

$$\hat{X} = \begin{pmatrix} -0,409 & 1,025 & 0,379 & -0,493 & 0,378 \\ -1,659 & -0,969 & -1,685 & -0,258 & -1,386 \\ 1,525 & -0,969 & -0,971 & 2,216 & 0,378 \\ 0,749 & 1,026 & 0,966 & -0,579 & 1,259 \\ 0,047 & -0,968 & 0,997 & -0,443 & 0,378 \\ 0,156 & -0,171 & -0,065 & 0,051 & 0,378 \\ -0,409 & 1,026 & 0,378 & -0,493 & -1,385 \end{pmatrix}. \quad (3.3.10)$$

Для нахождения матрицы счетов T и матрицы нагрузок P применим встроенную функцию *SVD*, согласно которой матрица X разлагается в произведение матриц U, S, V :

$$X = U \cdot S \cdot V. \quad (3.3.11)$$

Тогда матрица счетов $T = US$ и примет вид:

$$T = \begin{pmatrix} 0.8599 & 0.8054 & 0.2973 & 0.4622 & 0.2422 \\ -2.6685 & 1.0806 & -0.2826 & 0.3789 & -0.0662 \\ -0.8416 & -2.8777 & 0.5065 & -0.1127 & 0.0331 \\ 2.0733 & -0.0591 & 0.0492 & 0.3630 & -0.1836 \\ 0.4887 & -0.0731 & -1.3087 & -0.5616 & 0.0576 \\ 0.1128 & -0.3285 & -0.2013 & 0.2000 & -0.0482 \\ -0.0246 & 1.4523 & 0.9396 & -0.7298 & -0.0349 \end{pmatrix},$$

а матрица нагрузок примет вид

$$P = V = \begin{pmatrix} 0.3351 & -0.5845 & 0.2216 & -0.2979 & -0.6389 \\ 0.4490 & 0.3345 & 0.7849 & 0.2517 & 0.0843 \\ 0.6183 & 0.1395 & -0.2586 & -0.6138 & 0.3932 \\ -0.2288 & -0.6264 & 0.3680 & -0.1200 & 0.6367 \\ 0.5014 & -0.3668 & -0.3642 & 0.6758 & 0.1571 \end{pmatrix}.$$

Матрица S , содержащая квадратные корни $\sigma_i = \sqrt{\lambda_i}$ собственных значений матрицы $\hat{X} \hat{X}^T$, имеет вид

$$S = \begin{pmatrix} 3.6220 & 0 & 0 & 0 & 0 \\ 0 & 3.5104 & 0 & 0 & 0 \\ 0 & 0 & 1.7502 & 0 & 0 \\ 0 & 0 & 0 & 1.1788 & 0 \\ 0 & 0 & 0 & 0 & 0.3236 \\ 0 & 0 & 0 & 0 & 0 \end{pmatrix}.$$

Заметим, что полученные выражения для матриц U, S, V при подстановке их в формулу (3.4.11) приведут к восстановлению нормированной матрицы \hat{X} , а не исходной матрицы референтных данных (3.4.9). Тем не менее, упомянутая выше нормировка общепринята [70, 85], поскольку обеспечивает устойчивость алгоритма разложения и позволяет уменьшить вычислительные погрешности, сохраняя соотношения между различными объектами экспертизы.

После нахождения матрицы счетов T перейдем к задаче собственно кластеризации на основе разработанной программы на языке MATLAB, используя только первые два счета t_1, t_2 .

После 100 шагов настройки слоя Кохонена веса 2 нейронов с 2 входами примут следующие значения:

$$IW\{1,1\} = \begin{pmatrix} 1.1366 & 0.3603 \\ -0.6364 & -0.4256 \end{pmatrix}. \quad (3.3.12)$$

Чтобы исключить эффект «мертвых нейронов» и сделать все нейроны чувствительными к поступающим на вход векторам, используются смещения (biases), которые позволяют нейрону стать конкурентным с нейронами-победителями. Это достигается положительным смещением, которое добавляется к отрицательному расстоянию удаленного нейрона. Поэтому после 100 итераций все смещения положительны:

$$b\{1\} = (5,2921 \quad 5,5891)^T. \quad (3.3.13)$$

Как мы убедились, использование слоя Кохонена позволяет эффективно классифицировать объекты экспертизы на 3 (и более) класса в отличие от

использования персептрона с классификацией только на 2 класса. Кроме того, возможна классификация как на основе множества референтных данных X , так и на основе множества счетов T , определяемых при SVD -разложении матрицы X .

Выберем два кластера для счетов t_1, t_2 , характеризующих обобщенный показатель аномальности расчетных операций (1 — аномальные операции, 2 — приемлемые операции). На основе обучения слоя Кохонена определим центры кластеров (рис. 3.4.5).

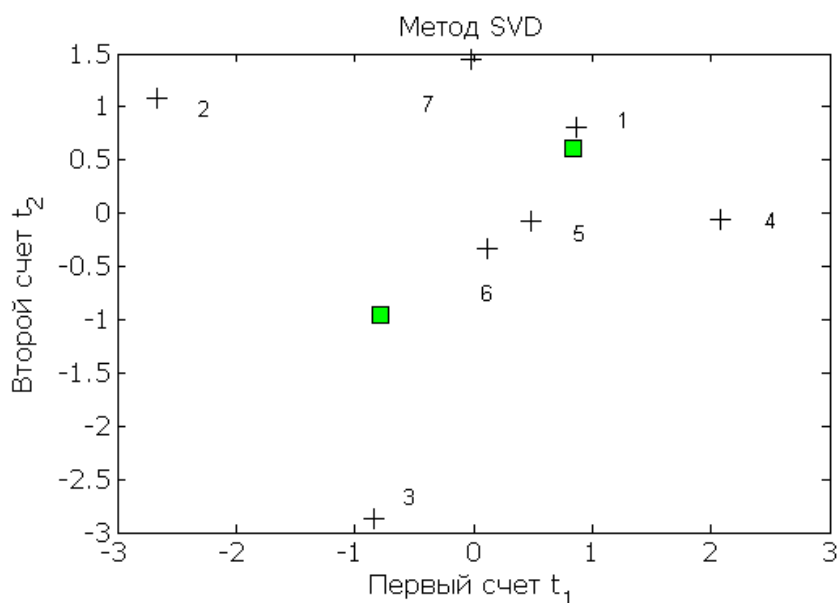


Рис. 3.4.5. Кластеризация 7 объектов экспертизы на 2 кластера

На этом рисунке квадратными маркерами обозначены центры кластеров, крестиками — значения счетов объектов экспертизы. Как видим, к объектам с аномальными значениями счетов относятся 1, 4, 5, 6, а к объектам с удовлетворительными значениями — 2, 3, 7.

Параметр активности при кластеризации на 2 кластера после 100 итераций принял для двух нейронов значения

$$a_1 = 0,533; \quad a_2 = 0,467. \quad (3.3.14)$$

Итак, существо предложенного выше подхода состоит в следующем: 1) использовать разложение SVD с нахождением матрицы счетов; 2) выделить два первых вектора счетов t_1, t_2 ; 3) применить кластеризацию на основе обучения слоя Кохонена; 4) построить графическое представление множества объектов экспертизы и кластеров на основе двух найденных векторов счетов, т.е. осуществить визуализацию.

4. Методы исследования расчетных операций в сфере дистанционного банковского обслуживания

4.1. Классификация нарушителей в сфере дистанционного банковского обслуживания

Практика борьбы с такого рода противоправными действиями в отношении финансовой сферы на современном этапе ее развития позволяет констатировать их целевую направленность на информационные процессы ее быстроразвивающегося сегмента – систем дистанционного банковского обслуживания (СДБО).

Практика эксплуатации СДБО дает основание считать, что хищение, целенаправленное изменение и блокирование информации этих систем в процессе противоправных действий может нанести значительный ущерб деятельности основных элементов финансовой сферы.

Огромный объем хранимой и обрабатываемой в СДБО информации, построение их на платформе распределенных вычислительных сетей и другие факторы обуславливают целый ряд уязвимостей этих систем к угрозам информационной безопасности.

Необходимость совершенствования организации защиты информации в СДБО в этих условиях очевидна.

Это предполагает разработку методической базы для исследования процессов функционирования СДБО в условиях обеспечения защищенности информации с целью обоснования мер защиты.

Анализ результатов исследований специалистов в области защиты информации позволяет констатировать, что проблемы обоснования мер защиты информации от несанкционированного доступа (НСД) к элементам информационной инфраструктуры банковской сферы являются актуальными для теории и практики информационной безопасности и требуют дальнейшего развития. Вместе с тем, следует отметить, что значительное количество публикаций в этой области посвящено лишь общим вопросам защиты информации от НСД к информации, содержащей коммерческую тайну. Различные методические аспекты этих вопросов отражены в большом числе работ известного специалиста в этой области А.П. Курило. В этих трудах разработан ряд основных положений организации противодействия угрозам информационной безопасности бизнеса, рассмотрен понятийный аппарат, сущность и особенности защиты информации в системах такого класса.

Однако отсутствие в этих работах детализированного описания противоправных действий в отношении такого специфического объекта как СДБО, не позволяет корректно осуществить процедуру формализации такого рода действий и, как следствие, сформировать адекватную их математическую модель, а, следовательно, и эквивалентную ей по адекватности математическую модель мер противодействия преступлениям в сфере ДБО. Поэтому представленный в данных работах методический аппарат не может быть

использовании в качестве инструмента для научного обоснования способов и средств защиты информации в СДБО.

Это обусловило глубокую проработку вопросов, связанных с формализацией угроз безопасности информации СДБО как следствия противоправных действий по несанкционированному доступу (НСД) к их информационным ресурсам. Как показывает анализ проблемы формализации такого рода процессов одним из направлений ее решения является использование методов функционального моделирования. Предпосылкой для применения данного методического аппарата является накопленная практика расследования преступлений в сфере компьютерной информации. В результате расследования такого рода противоправных действий установлены сценарии их реализации, а так же выявлены определенные закономерности в применении злоумышленниками вредоносного программного обеспечения. Конечное множество выполняемых при этом функций позволяет синтезировать функциональную модель всех возможных действий, осуществляемых с целью создания условий для практической реализации НСД к информации в СДБО с целью ее несанкционированного копирования, искажения и блокирования. Преобразование данной функциональной модели методами системного анализа [8] позволяет, в итоге, получить математические зависимости характеристик такого рода действий, позволяющих количественно оценивать как эффективность противоправных действий в отношении информации СДБО, так и эффективность мер защиты информации.

Таким образом, очевидно, что проблема оценки эффективности мер защиты информации от НСД в СДБО является чрезвычайно актуальной, а связанные с ней вопросы нуждаются в проработке как в научном, так и в практическом плане.

Предпосылкой решения данной проблемы является гипотеза о взаимнооднозначном соответствии между степенью детализации функциональной модели противоправных действий и адекватностью оценки эффективности мер защиты информации от НСД в этих системах.

В качестве показателя адекватности оценки эффективности мер защиты информации от НСД в СДБО предлагается использовать степень ΔI увеличения информативности формализованного представления множества:

$$F = \{f_k \mid k = 1, 2, \dots, K\}$$

функций, содержащихся в функциональной модели защиты информации от НСД в СДБО:

$$\Delta I = I_{(d)} - I_{(nd)}, \quad (4.1.1)$$

где $I_{(d)}$ – количество информации, содержащееся в детализированной функциональной модели защиты информации от НСД в СДБО;

$I_{(nd)}$ – количество информации, содержащееся в функциональной модели не подвергшейся процедуре детализации.

Определим величину ΔI в терминах метрики Хартли [9]. Для этого представим (1) в виде:

$$\Delta I = \log_2 |F_{(\partial)}| - \log_2 |F_{(нд)}|,$$

где $|F_{(\partial)}|$ – мощность множества функций, содержащихся в функциональной модели защиты информации от НСД в СДБО, полученной путем детализации функциональной модели противоправных действий в отношении информации СДБО:

$$F_{(\partial)} = \{f_{l(\partial)} \mid l = 1, 2, \dots, L\},$$

$|F_{(\partial)}|$ – мощность множества функций, содержащихся в функциональной модели защиты информации от НСД в СДБО, полученной на основе функциональной модели противоправных действий в отношении СДБО, не подвергшейся процедуре детализации:

$$F_{(нд)} = \{f_{m(нд)} \mid m = 1, 2, \dots, M\}.$$

Решение проблемы связано с реализацией следующей последовательности научных задач:

1. Анализ уязвимостей информации СДБО к угрозам НСД.
2. Обоснование показателя для оценки эффективности мер защиты информации от НСД в СДБО и показателя адекватности оценки эффективности мер защиты.
3. Разработка функциональной модели противоправных действий в отношении информации СДБО.
4. Формирование на основе функциональной модели противоправных действий в отношении информации СДБО соответствующей функциональной модели мер защиты информации от НСД в этих системах.
5. Разработка процедуры преобразования функциональной модели мер защиты информации от НСД в СДБО с целью формирования формализованного представления данной модели.
6. Разработка математической модели показателя эффективности мер защиты информации от НСД в СДБО.
7. Проведение вычислительных экспериментов по обоснованию направлений совершенствования мер защиты информации от НСД в СДБО.
8. Анализ адекватности оценки эффективности мер защиты информации от НСД в СДБО.

Изучение противоправных действий нарушителя в сфере дистанционного банковского обслуживания, предполагает моделирование действий нарушителя и ответной реакции системы, что позволит произвести анализ и предсказать поведение системы в определенных условиях.

Выделим две группы для моделирования нарушителей.

- *Нарушители при воздействии на вычислительные системы организаций (банков, платежных систем) предоставляющих услуги сферы дистанционного банковского обслуживания.*

- *Нарушители при воздействии на клиента дистанционного банковского обслуживания (клиент – пользователь услугами дистанционного банковского обслуживания)..*

В каждой группе выделим две категории нарушителей:

- организованные нарушители (преступные сообщества)
- одиночные нарушители.

Целью каждой категории нарушителей является незаконное получение денежных средств, с использованием специализированного (вредоносного) программного обеспечения.

Моделирование нарушителя при воздействии на вычислительные системы организаций (банков, платежных систем) предоставляющих услуги дистанционного банковского обслуживания.

Организованные нарушители (преступные сообщества), состав:

- организаторы (их задачей является общее руководство процессом незаконного получения денежных средств (стратегическое планирование), подбор «жертв» и исполнителей, обеспечение безопасности);
- исполнители.

Исполнители делятся на подкатегории:

- внутренние исполнители или инсайдеры – сотрудники организации предоставляющей услуги дистанционного банковского обслуживания, их задачей является сбор данных о системе дистанционного банковского обслуживания, использование уязвимостей систем защиты для незаконного получения денежных средств, проведение операций по незаконному переводу денежных средств, установка специализированного (вредоносного) программного обеспечения;

- консультанты - специалисты в определенных областях знаний, (технических, правовых) их задачей является тактическое планирование, консультация инсайдеров и организаторов. Консультации могут заключаться, в разработке действий направленных на использование штатных программных средств, в том числе с учетом уязвимостей систем защиты для незаконного перевода денежных средств;

- разработчики специализированного (вредоносного) программного обеспечения. Их задача - создание специализированного программного обеспечения, в том числе под конкретную платежную систему.

Специализированное программное обеспечение должно обеспечивать следующие функции:

- выполнение заданных алгоритмов для незаконного перевода денежных средств, в том числе по повышению прав доступа инсайдеров;
- сокрытие следов незаконного перевода денежных средств и действий инсайдеров;
- нарушение работы операционной системы «жертвы» после выполнения заданного алгоритма.

Специализированное программное обеспечение должно удовлетворять следующим условиям:

- не детектироваться существующим антивирусным программным обеспечением;
- минимизировать сохраняемые данные об его использовании;

- блокировать возможность обнаружения его использования администраторами системы и специалистами по безопасности.

Специалисты по получению денежных средств. Их задачей является обналичивание денежных средств или перевод их на легальные счета. Для реализации данных функций используются следующие методы:

- многократный перевод денежных средств на счета специально организованных фирм;
- перевод денежных средств на счета юридических лиц;
- вывод денежных средств за пределы РФ;
- обналичивание денежных средств с использованием дропов (дроппы – специально нанятые люди в обязанности которых входит обналичивание денежных средств).

Наибольший коэффициент вероятности быть, у внутренних исполнителей, инсайдеров, от 0,5, наименьший у организаторов и разработчиков специализированного вредоносного программного обеспечения. Для разработчиков 0,01, для организаторов 0,02.

4.2. Модели нарушителей в сфере дистанционного банковского обслуживания

Группа инсайдеров или одиночный инсайдер. В данном случае отсутствует внешний организатор. Могут прибегать к помощи консультантов. Специалист высокого уровня. С большой долей вероятности будут выявляться организованными нарушителями и привлекаться в качестве консультанта или внутреннего исполнителя, инсайдера. У одиночного нарушителя высокий коэффициент вероятности быть обнаруженным, может составлять примерно 0.8. Решающую роль в обнаружении одиночного нарушителя составляет профессионализм службы безопасности и самого нарушителя.

Для незаконного получения денежных средств одиночный нарушитель использует готовые программные решения. У одиночного нарушителя будут наблюдаться трудности с выводом денежных средств.

Организованные нарушители (преступные сообщества), состав:

- организаторы (их задачей является общее руководство процессом незаконного получения денежных средств (стратегическое планирование), утверждение «жертв», подбор исполнителей, обеспечение безопасности);
- исполнители.

Исполнители делятся на подкатегории:

«Разведчики» - специалисты по выявлению «жертв». В их обязанности входит сбор сведений о «жертве» таких как:

- структура организации;
- данные об используемом программном обеспечении;
- данные об используемом аппаратном обеспечении;
- данные об использовании средств защиты, в том числе наличия системы

двухфакторной аутентификации (Двухфакторная аутентификация - метод идентификации пользователя при помощи запроса аутентификационных данных двух разных типов, для систем дистанционного банковского обслуживания это как правило SMS подтверждения);

- проведение пробных проверок защиты.

«Разработчики специализированного (вредоносного) программного обеспечения». Их задача - создание специализированного программного обеспечения, в том числе под конкретную платежную систему и конкретного пользователя.

Специализированное программное обеспечение должно обеспечивать следующие функции:

- использовать возможности динамических элементов браузеров для скрытой установки вредоносного кода (динамические элементы браузера – активация исполнительного кода (JavaScript) при наведении указателя в определенные области рабочего окна браузера);

- выполнять последовательную установку кода и программного обеспечения по заданному алгоритму или по внешним командам;

- выполнение заданных алгоритмов для незаконного перевода денежных средств путем получения удаленного управления компьютером «жертвы» и получения учетных данных пользователя системы дистанционного банковского обслуживания;

- сокрытие следов незаконного перевода денежных средств;

- нарушение работы операционной системы «жертвы» после выполнения заданного алгоритма.

Специализированное программное обеспечение должно удовлетворять следующим условиям:

- не детектироваться существующим антивирусным программным обеспечением;

- минимизировать сохраняемые данные об его использовании;

- блокировать возможность обнаружения его использования администраторами системы и специалистами по безопасности;

- блокировать работу антивирусного программного обеспечения и брандмауэров.

В качестве специализированного программного обеспечения могут выступать легальные программные продукты, предназначенные для контроля работы пользователей (*Data Leak Prevention – системы предотвращения потери данных*) и легальные программные продукты для удаленного управления.

- «Распространители вредоносного программного обеспечения». В их задачу входит покупка или подготовка бот сетей, покупка или создание зараженных специализированным программным обеспечением сайтов.

- «Специалисты по специальным вопросам». В их задачу входит преодоление системы защиты двухфакторной аутентификации, для чего с помощью подложных доверенностей выпускаются дубликаты SIM карты с

номером телефона, к которому прикреплена система дистанционного банковского обслуживания.

- «Специалисты по получению денежных средств». Их задачей является обналачивание денежных средств или перевод их на легальные счета. Для реализации данных функций используются следующие методы:

- многократный перевод денежных средств на счета специально организованных фирм;
- перевод денежных средств на счета юридических лиц;
- вывод денежных средств за пределы РФ;
- обналачивание денежных средств с использованием дропов (дропы – специально нанятые люди в обязанности которых входит обналачивание денежных средств).

Выявит при данной схеме можно только дропов и отследить перемещение денежных средств, только в пределах СНГ.

Могут прибегать к информации расположенной на специализированных (закрытых) форумах и сайтах. Специалист разного уровня. У одиночного нарушителя высокий коэффициент вероятности быть обнаруженным. Для незаконного получения денежных средств одиночный нарушитель использует готовые программные решения.

Таким образом, для моделирования выявления нарушений в системе дистанционного банковского обслуживания необходим комплексный подход, учитывающий, как особенности функционирования платежных систем, так и действия нарушителей по преодолению защиты и незаконному получению денежных средств.

ЗАКЛЮЧЕНИЕ

Нейронные сети являются мощным вычислительным инструментом для моделирования многих классов технических задач. Однако их серьезным недостатком является неоднозначность решений, обусловленная рядом причин (структура референтных данных, неправильный выбор вида сети, случайный выбор начальных условий) и приводящая иногда к заведомо неверным результатам.

Предлагаемый метод ассоциативного обучения нейронных сетей является альтернативой обычному подходу к решению прямой задачи экспертизы. Представляется, что особенно эффективным он окажется в случае больших разбросов характеристик сравниваемых объектов, в частности, признаки которых могут принимать отрицательные значения.

Рассмотрено три варианта классификации расчетных операций: по 3 группам признаков (количественные, наличия, качественные); по обобщенному показателю качества $J_{кач}$ и признаку аномалии с визуализацией полученных результатов; по 4 группам признаков, включая стоимостной признак.

Графическое изображение (визуализация) множества векторов, подлежащих классификации, и разделяющей поверхности очень важно для характеристики исследуемого множества объектов экспертизы и принятия решений. Поэтому для практического использования следует рекомендовать второй из рассмотренных вариантов классификации — в двумерном пространстве по обобщенному показателю аномалии $J_{кач}$ и признаку обратной цены \hat{P} .

Из сопоставления разных подходов: кластеризации на основе обобщенного показателя аномалии, кластеризации по двум счетам t_1, t_2 метода главных компонент; кластеризации по всем признакам анализа операции — можно сделать следующие выводы.

Все способы правильно распределяют объекты по кластерам. Однако при сохранении основных итогов (выделение аномалий) результаты несколько отличаются. Это объясняется различным объемом и формами представления исходной информации.

Номера активных нейронов (кластеров) программа назначает произвольно. Таким образом, чтобы упорядочить номера кластеров по некоему признаку (например, качеству объектов), требуется воспользоваться дополнительной графической информацией.

С практической точки зрения предпочтительными являются первые два способа, основанные на кластеризации объектов в двумерном пространстве показателей $J_{кач}, \hat{P}$ или счетов t_1, t_2 метода главных компонент и анализе графической картины взаимного расположения объектов.

СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ

1. Дилигенский, Н. В. Нечеткое моделирование и многокритериальная оптимизация производственных систем в условиях неопределенности: технология, экономика, экология / Н. В. Дилигенский, Л. Г. Дымова, П. В. Севастьянов. — М. : Машиностроение – 1, 2004. — 397 с
2. Литвак, Б. Г. Экспертная информация: методы получения и анализа / Б. Г. Литвак. — М. : Радио и связь, 1982. — 184 с.
3. Кендалл, М. Дж. Статистические выводы и связи / М. Дж. Кендалл, А. Стьюарт. — М. : Наука, 1973. — 899 с.
4. Саати Т. Принятие решений: метод анализа иерархий: пер. с англ. / Т. Саати. — М. : Радио и связь, 1993. — 278 с.
5. Хайкин С. Нейронные сети: полный курс / С. Хайкин ; пер. с англ. — 2-е изд. — М. — СПб. — Киев : Вильямс, 2006. — 1104 с.
6. Кендалл, М. Ранговые корреляции / М. Кендалл. — М. : Статистика, 1975. — 220 с.
7. Эсбенсен, К. Анализ многомерных данных. Избранные главы: пер. с англ. / К. Эсбенсен; под ред. О.Е. Родионовой. — Черноголовка : Изд-во ИПХФ РАН, 2005. — 160 с.
8. Барсегян, А. А. Технология анализа данных: Data Mining, Text Mining, OLAP / А. А. Барсегян [и др.] — 2-е изд. — СПб. : БХВ — Петербург, 2007. — 384 с.
9. Witten, I. H. Data Mining: Practical Machine Learning Tools and Techniques / Ian H. Witten, Eibe Frank and Mark A. Hall. — 3-rd edition. — N.Y. : Morgan Kaufmann, 2011. — 664 p.
10. Мандель, И. Д. Кластерный анализ / И. Д. Мандель. — М. : Финансы и статистика, 1988. — 177 с.
11. Аксенов, С. В. Организация и использование нейронных сетей (методы и технологии) / С. В. Аксенов, В. Б. Новосельцев. — Томск : Изд-во НТЛ, 2006. — 128 с.
12. Жамбю М. Иерархический кластер-анализ и соответствия: пер. с франц. / М. Жамбю. — М. : Финансы и статистика, 1988. — 345 с.
13. Бухарин, С. В. Кластерно-иерархические методы экспертизы экономических объектов : монография / С. В. Бухарин, А. В. Мельников — Воронеж : Научная книга, 2012. — 276 с.
14. Бухарин, С. В. Статистические методы экспертизы технических и экономических объектов : монография / С. В. Бухарин, Д. А. Волков, А. В. Мельников, В. В. Навоев. — Воронеж : Научная книга, 2013. — 274 с.
15. Weisberg, S. Applied linear regression / S. Weisberg. — 3-rd edition. — New Jersey: John Wiley & Sons Inc., 2005. — 330 p.
16. Бухарин, С. В. Методы теории нейронных сетей в экспертизе технических и экономических объектов : монография / С. В. Бухарин, В.В.

Навоев. — Воронеж : Научная книга, 2015. — 274 с.

17. Галушкин, А. И. Нейронные сети: основы теории / А. И. Галушкин. — М. : Горячая линия Телеком, 2012. — 496 с.

18. Померанцев, А. Метод главных компонент / А. Померанцев. — М. : Российское хемометрическое общество, 2010. — 26 с. [Электронный ресурс]. — URL: <http://www.chemometrics.ru/materials/textbooks/pca.htm>.

19. Jolliffe, I. T. Principal Component Analysis, Series: Springer Series in Statistics / I. T. Jolliffe. — N.Y.: XXIX, Springer, 2002. — 487 p.

20. Kohonen, T. Self-organized formation of topologically correct feature maps / T. Kohonen // Biological Cybernetics. — 1982. — Vol. 43. — P. 59 — 69.

Время проведения мошеннической операции в среде ДБО

№ п/п	Наименование функции	Среднее значение времени реализации функции, с
1	2	3
1	Установка скимингового устройства	15
2	Получение учетных данных платежных карт пользователя с магнитной полосы и PIN-кода с использованием скимингового устройства	3
3	Установка вредоносного ПО на компьютеры управления POS- терминалов и банкоматов	10
4	Получение учетных данных платежных карт пользователя с использованием вредоносного ПО	15
5	Сбор данных об информационной среде сервиса «Клиент-Банк» объекта мошеннических действий	120
6	Проведение пробных компьютерных атак с целью сбора данных о реакции механизмов защиты информационной среды сервиса «Клиент- Банк» объекта мошеннических действий	120
7	Перенаправление пользователя сервиса «Клиент-Банк» на фишинговый сайт	10
8	Получение учетных данных пользователя сервиса «Клиент-Банк» путем использования фишингового сайта	30
9	Скрытая установка вирусного ПО для получение данных двухфакторной аутентификации, передаваемых посредством SMS-сообщений на телефон объекта мошеннических действий	2

Таблица 1
(продолжение)

1	2	3
10	Получение данных двухфакторной аутентификации, передаваемых посредством SMS-сообщений	9
11	Получение информации об особенностях функционирования механизмов ДБО	150
12	Получение информации об особенностях функционирования механизмов обеспечения безопасности ДБО	195
13	Исследование уязвимостей ПО на серверах ДБО для незаконного перевода денежных средств	195
14	Сбор данных о реакции системы защиты информации серверов ДБО путем проведения пробных компьютерных атак	93
15	Выявление уязвимостей ПО и механизма обеспечения безопасности серверов ДБО	128
16	Снятие дропом денежных средств в банкомате	15
17	Перевод денежных средств дропом на счет злоумышленника	30
18	«Покупка» оплаты товара клоном карты через терминал без осуществления покупки	14
19	Подключение мобильного банка на номер злоумышленника	23
20	Работа в мобильном банке от имени легитимного пользователя	18
21	Выбор онлайн-сервиса с минимальным уровнем проверки пользователя	103
22	Попытка совершения онлайн-покупок	40
23	Внедрение вредоносного ПО в информационную среду сервиса «Клиент-Банк» объекта мошеннических действий	2
24	Создание условий для совершения незаконного перевода денежных средств объекта мошеннических действий, работающего в сервисе «Клиент-Банк»	5
25	Незаконный перевод денежных средств объекта мошеннических действий от имени легитимного пользователя	15
26	Нарушение работоспособности операционной системы, обслуживающей информационную среду сервиса «Клиент-Банк» объекта мошеннических действий	1

Таблица 1
(продолжение)

1	2	3
27	Несанкционированный доступ к платежной системе с использованием учетных данных пользователя сервиса «Клиент-Банк»	15
28	Получение данных двойной аутентификации	30
29	Незаконный перевод денежных средств с использованием полученных данных	15
30	Активация режима удаленного доступа к мобильному устройству объекта мошеннических действий	6
31	Получение полного контроля над телефоном, управляемым ОС Android для отправки скрытых SMS-сообщений	2
32	Получение данных двухфакторной аутентификации передаваемых посредством SMS-сообщений для незаконного перевода денежных средств	6
33	Незаконный перевод денежных средств с использованием функций мобильного банка	10
34	Активация автоматического режима для незаконного перевода денежных средств с мобильного устройства объекта мошеннических действий	2
35	Незаконный перевод денежных средств с использованием сервиса «Мобильный банк» от имени легитимного пользователя путем отправки SMS-сообщений в автоматическом режиме	7
36	Установка вирусного ПО для использования уязвимостей ПО на серверах ДБО для незаконного перевода денежных средств	3
37	Активация специализированного вредоносного ПО для незаконного перевода денежных средств	0,3
38	Незаконный перевод денежных средств из процессингового центра банка-эквайера на счет злоумышленника	0,5
39	Заражение серверов ДБО специализированным вредоносным ПО предназначенным для незаконного перевода денежных средств	3
40	Незаконный перевод денежных средств с использованием уязвимостей ПО серверов ДБО и специализированного вредоносного ПО предназначенного для незаконного перевода денежных средств	1
41	Получение кодов доступа к зараженному банкомату	6

Таблица 1
(продолжение)

1	2	3
42	Выдача денежных средств из диспенсеров банкомата с использованием полученных кодов или команд управления	3
43	Получение доступа к зараженному POS-терминалу	3
44	Перевод денежных средств на счет злоумышленника с зараженного POS-терминала	14

Бабкин А.Н., Баркалов Ю.М., Лунев Ю.С., Мельников А.В.

Модели и алгоритмы нейронных сетей в обеспечении раскрытия преступлений,
совершенных в системах дистанционного банковского обслуживания

Воронежский институт МВД России