

Ю. Н. Кульчин^{1, 2}, академик, д-р физ.-мат. наук, директор ИАПУ ДВО РАН, e-mail: kulchin@iacp.dvo.ru.

А. Ю. Ким¹, млад. науч. сотр., e-mail: ayukim@mail.ru.

Б. С. Ноткин^{1, 2}, канд. техн. наук, ст. науч. сотр., e-mail: boris_notkin@mail.ru.

А. Б. Люхтер³, канд. техн. наук, советник при ректорате, e-mail: 3699137@gmail.com

¹ ФГБУН Институт автоматике и процессов управления ДВО РАН, г. Владивосток,

² Дальневосточный федеральный университет, г. Владивосток,

³ Владимирский государственный университет, г. Владимир

Обработка сигналов распределенной волоконно-оптической сети для распознавания динамических образов с применением нейронных сетей

Рассматриваются способы, методы и алгоритмы обработки сигналов распределенной волоконно-оптической измерительной сети (РВОИС) и формирование с их помощью моделей образов в виде набора характерных признаков или главных компонент для совокупностей зарегистрированных состояний движущегося идентифицируемого объекта. Также предложено получение выборки примеров для обучения и тестирования нейронных сетей с помощью созданных программных модулей (генератора сенсорных данных и модуля преобразования данных). Анализ результатов исследований проведен в рамках разработки интеллектуальной распределенной информационно-измерительной системы (ИРИИС) на основе РВОИС для распознавания динамических образов.

Ключевые слова: нейронные сети, интеллектуальные информационно-измерительные системы, экспертные системы, модели образов, распознавание динамических образов

Введение

Бурное развитие современной техники в конце XX и начале XXI веков характеризуется разнообразием контролируемых процессов и измеряемых физических величин. При этом первостепенное значение приобретает мониторинг явлений, происходящих в условиях высоких скоростей их протекания, широком диапазоне изменения температуры и давления, а также других параметров окружающей среды. В связи с чем особое значение приобретает создание распределенных волоконно-оптических измерительных сетей (РВОИС) [1], способных не только обеспечить мониторинг состояния масштабных и многопараметрических систем и объектов в реальном времени, но и адаптироваться под конкретные воздействия окружающей среды. Именно эти два обстоятельства диктуют необходимость создания интеллектуальных распределенных информационно-измерительных систем (ИРИИС), в которых происходит сочетание достоинств РВОИС, способных со скоростью света собирать большие объемы данных, с достоинствами интеллектуальных экспертных систем [2], строящихся на нейросетевых принципах [3], способных обрабатывать эти большие массивы данных в реальном времени [4]. Поскольку скорость сбора РВОИС данных об объекте и время их обработки экспертной системой оказываются различными, возникает необходимость поиска способов, позволяющих уменьшить необ-

ходимый объем поступающей на вход системы обработки данных информации без искажения вычислительного результата, чтобы обеспечить реальное время их обработки. Поэтому целью данной работы стало выявление оптимальных и эффективных способов обработки больших массивов данных с использованием ИРИИС.

В основу подхода к уменьшению необходимого объема данных при мониторинге состояния объекта была положена процедура предварительного формирования модели образа (МО). Это позволяет сократить время обучения нейронных сетей и выполнить процесс распознавания (обработки) динамического образа объекта за один такт. С этой целью была разработана структурно-функциональная модель системы обработки данных ИРИИС (рис. 1), в которой процесс распознавания динамических образов объектов организован в виде последовательности взаимосвязанных функций: от сбора данных об объекте (блок I) до обработки (блок II).

Для извлечения значимой информации при формировании МО из полученных данных РВОИС и для проверки качества работы СОД ИРИИС были использованы многомерные статистические методы (метод главных компонент, снижение размерности признакового пространства, корреляционный анализ количественных переменных) в комплексе с многослойными нейронными сетями прямого распространения.

Способы сжатия данных для формирования моделей образов

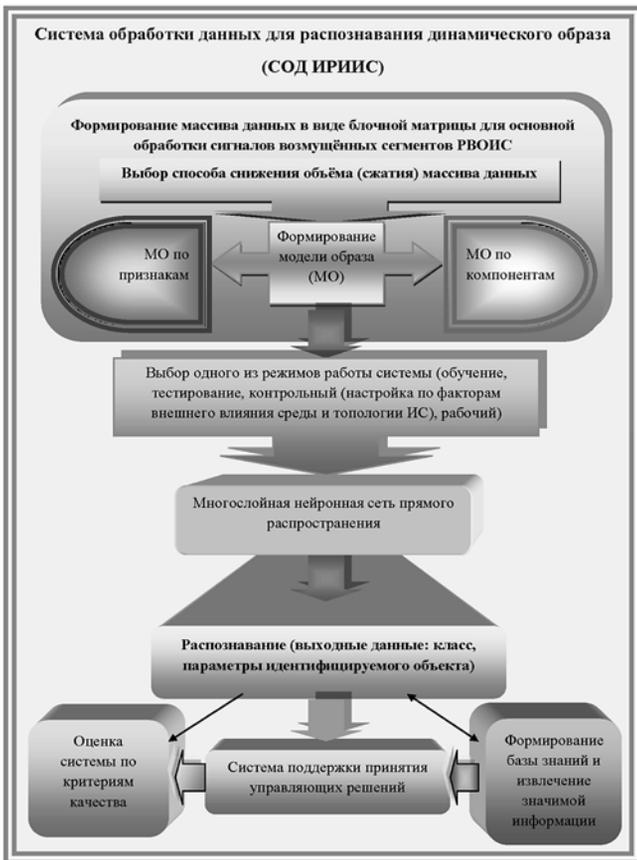


Рис. 1. Структурно-функциональная модель системы обработки данных ИРИИС для распознавания динамического образа

С помощью многослойных нейронных сетей прямого распространения происходит распознавание динамических образов с определением параметров движущихся идентифицируемых объектов после обучения на подготовленных выборках примеров массивов данных, полученных от РВОИС, которые прошли процедуру снижения объёма данных.

Одной из основных проблем, возникающих при функционировании ИРИИС на основе РВОИС, является возрастающий поток данных в течение времени опроса РВОИС и, в итоге, большие массивы данных, которые необходимо обрабатывать. Подбор преобразования для снижения объёма (сжатия) обрабатываемых массивов данных без существенной потери в них информативности позволяет ускорить процесс распознавания динамических образов.

Для создания алгоритмов сжатия данных РВОИС использовались два способа. Первый способ основан на методе главных компонент, а второй — на формировании набора характерных признаков объекта, регистрируемого по его воздействиям на РВОИС в процессе опроса системы. Так как метод главных компонент хорошо известен и описан в работах других авторов [5], то подробно остановимся на втором способе. При этом способе на основе полученных данных выделяют характерные признаки, по которым можно восстановить параметры самого регистрируемого объекта. Такой способ требует понимания как основных особенностей поведения (состояний) идентифицируемого объекта, так и знание того, какие параметры необходимо восстанавливать в процессе распознавания ИРИИС.

При проверке возможности применения способа сжатия данных путем выделения характерных признаков и последующего получения выборок примеров для различных видов движения идентифицируемых объектов использовали генератор сенсорных данных распределенной измерительной системы (РИС). Смоделированная сенсорная зона РИС в генераторе представлена в виде совокупности независимых измерительных линий (ИЛ), уложенных параллельно с заданным шагом (рис. 2). Такого

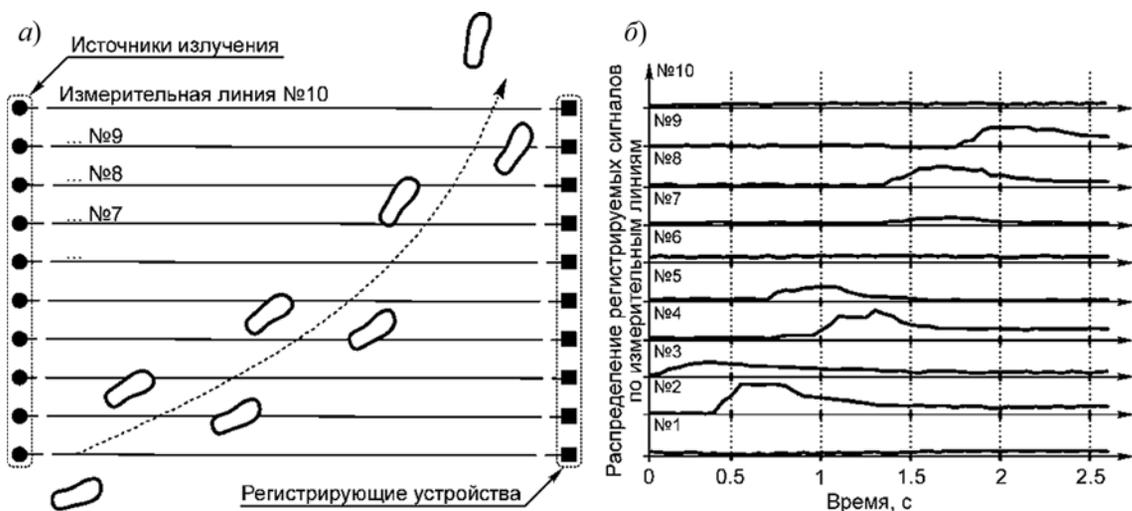


Рис. 2. Пример моделирования идущего в зоне мониторинга человека

Сведения об условных нарушителях периметра

| Условное обозначение класса | Представители | Траектория движения | Диапазон масс, кг | Диапазон скоростей, м/с |
|-----------------------------|--|---|-------------------|-------------------------|
| "Человек" | Человек: идущий, бегущий, хромающий | Линейная, дугообразная | 40...120 | 0,6...5 |
| "Авто" | Автомобиль, трактор | Линейная | 800...2000 | 2...15 |
| "ВелоМото" | Велосипед, мотоцикл, мотоцикл с коляской | Линейная | 50...250 | 2...10 |
| "Фауна" | Собака, корова, заяц | Линейная, дугообразная, зигзагообразная | 5...250 | 0,5...4 |

типа укладка ИЛ возможна при организации маскируемых волоконно-оптических охранных систем [6]. Поэтому в основу моделирования результатов функционирования измерительной системы были положены принципы, наиболее существенные при реализации такого рода систем охраны периметра. К ним относятся: давление на грунт в районе прокладки оптоволоконной; фактор упругости грунта; особенности воздействия в зависимости от типа, скорости, траектории движущегося объекта. Конечный вид регистрируемого сигнала определяется с учетом существенного вклада случайного фактора, имитирующего широкий спектр неучтенных при моделировании и часто случайных явлений, неизбежно присутствующих в реальных условиях (степень однородности грунта, глубина прокладки оптоволоконной, температурные флуктуации, вид обуви нарушителя, его походка и т. д.).

В последующих экспериментах по сгенерированным данным рассматривали 11 примеров условных нарушителей периметра, разбитых на четыре класса. Информация о них сведена в табл. 1. Масса, скорость и траектория нарушителя при моделировании каждого нового инцидента выбираются случайным образом. Пример моделирования идущего человека и регистрируемых при этом сигналов представлен на рис. 2. Измерительная часть системы, смоделированная в генераторе сенсорных данных РИС (рис. 2, а), состоит из измерительных линий ($n = 10$); шаг укладки $h = 20$ см. Частота регистрации данных $a = 20$ Гц.

Рис. 2, б иллюстрирует пример получаемых данных, на основе которых система должна принять решение о классе нарушителя, его скорости, массе и направлении движения.

Для реализации способа, основанного на выделении характерных признаков, необходимо иметь, кроме непосредственно самих сгенерированных данных измерительной сети, результат предобработки в целях выявления фактов воздействия на измерительные линии, т. е. для каждой измерительной линии необходимо определить моменты времени, в которые на нее оказано воздействие. Эти моменты

определяются по факту положительного приращения амплитуды, превышающего исходно заданный порог. Важно знать, в какие моменты объект "наступал" на измерительные линии.

Измерительные линии, на которых регистрируется хотя бы одно внешнее воздействие, будем считать "активными". А измерительные линии, на которых за время инцидента не наблюдают внешних воздействий объекта, называют "пассивными". Время инцидента — это время регистрации одного примера или одного множества данных.

Таким образом, матрица признаков формируется по всем примерам инцидентов, полученным с помощью генератора сенсорных данных РИС, и передается на вход нейронной сети. Полный набор выделенных признаков для распознавания движущегося объекта по сгенерированным данным представлен в табл. 2.

Выбранные способы сжатия данных не только использовались при обработке по сгенерированным данным, но и прошли дальнейшую проверку на реальных данных, которые получены с помощью созданного макета РВОИС охраны периметра, разработанного по типу смоделированной сенсорной зоны генератора РИС (рис. 2), и предварительно

Таблица 2

Признаки для распознавания движущегося объекта по сгенерированным данным

| Символы | Признаки |
|---------|---|
| P1 | Длительность инцидента |
| P2 | Число активных измерительных линий |
| P3 | Среднее арифметическое и среднее квадратичное отклонение количества воздействий на активные измерительные линии |
| P4 | Среднее арифметическое и среднее квадратичное отклонение максимальных амплитуд для активных измерительных линий |
| P5 | Среднее арифметическое и среднее квадратичное отклонение максимальных амплитуд для активных измерительных линий |
| P6 | Периодичность внешних воздействий на измерительную систему |
| P7 | Траектория движения нарушителя |
| P8 | Средняя квадратичная ошибка аппроксимации траектории движения нарушителя |
| P9—P12 | |
| P13 | |

Таблица 3

Признаки для распознавания движущегося объекта по реальным данным

| Символы | Признаки |
|--------------|---|
| P(1) | <i>Длительность</i> инцидента |
| P(2) | Число <i>активных</i> измерительных линий |
| P(3) | Суммарное <i>количество воздействий</i> по всем линиям за время мониторинга РВОИС |
| P(4) | Среднее квадратичное отклонение <i>числа воздействий</i> по линиям |
| P(5) | Среднее арифметическое значение <i>амплитуд воздействий</i> по всем линиям |
| P(6) | Среднее квадратичное значение <i>амплитуд воздействий</i> по всем линиям |
| P(7) | Средняя <i>периодичность</i> воздействий |
| P(8) | Среднее квадратичное отклонение <i>периодичности</i> воздействий |
| P(9)–P(12) | Коэффициенты полинома, описывающего <i>траекторию</i> движения объекта |
| P(13) | Средняя квадратичная ошибка аппроксимации <i>траектории</i> движения |
| P(14) | <i>Непрерывность</i> воздействия на ИЛ |
| P(15) | <i>Параллельность</i> воздействий на ИЛ |
| P(16) | <i>Одновременность</i> воздействий на РВОИС |
| P(17) | <i>Длина "пути"</i> |
| P(18) | <i>Направление</i> |
| P(19), P(20) | Взвешенные <i>"центры масс"</i> положения |

обработаны с помощью специально разработанного программного модуля преобразования данных.

Предварительно полученные реальные данные в виде временных рядов с ИЛ макета РВОИС проходили два этапа предобработки. На первом этапе происходит фильтрация скользящим средним [7] с заданным периодом (или сглаживающим интервалом) и децимация исходных данных в модуле преобразования данных. На втором этапе по полученным двум скользящим средним с разными периодами n_1 и n_2 , а именно по расхождению значений полученных функций в определенные моменты времени, устанавливают непосредственно временные интервалы возникновения воздействий на каждой ИЛ по превышению разницы между возмущениями допустимого заданного шумового порога u_0 . После двух этапов предобработки данных одним из двух

предложенных способов (методом главных компонент или выделением характерных признаков) формируют МО из главных компонент или признаков для последующего распознавания параметров идентифицируемого движущегося объекта. С помощью программного модуля преобразования данных, используя 200 примеров реально измеренных данных для различных вариантов поведения движущихся объектов двух типов (катящиеся и шагающие), дополнительно получили 10 000 альтернативных примеров, изменяя основные характеристики движущегося объекта (скорость, ускорение, массу и направление движения объекта), что обеспечило репрезентативность выборки примеров при обучении нейронной сети. При определении основных параметров идентифицируемого движущегося объекта по реальным данным используют выделенные признаки, представленные в табл. 3.

Сжатие массива данных приводит к формированию двух типов МО. Один тип получают нахождением главных компонент, а другой тип — выделением характерных признаков. Для реализации этих двух типов МО были созданы программы в среде MATLAB.

Результаты численного моделирования и обработки данных с применением нейронных сетей

Исследования по сгенерированным данным проводили в целях определения необходимого для выборки числа примеров измерений, получаемых от РВОИС, и допустимости сокращения размерности входного вектора нейронной сети при обработке, не вызывая при этом существенных потерь в качестве распознавания динамических образов ИРИИС. Результаты обработки многослойными нейронными сетями прямого распространения при тестировании на выборках примеров, которые не были использованы при обучении, представлены в табл. 4.

Здесь и далее во всех случаях для обучения нейронных сетей используется метод Левенберга—Марквардта (LMA) [8].

Таблица 4

Результаты обработки многослойными нейронными сетями по сгенерированным данным

| Расознаваемые параметры объекта | Значимые признаки | Ошибка, % (при использовании значимых признаков для расширенной выборки объектов) | | | |
|---------------------------------|--------------------------|---|---------------|--------------|--------------|
| | | 20 000 примеров | 1000 примеров | 500 примеров | 200 примеров |
| Масса, кг | 1, 3, 5, 6, 13 | 15,16 | 6,07 | 6,45 | 16,95 |
| Скорость, м/с | 1, 3, 5, 6 | 1,69 | 1,87 | 3,31 | 4,60 |
| Класс и направление движения | 3, 5, 6, 7, 8, 9, 11, 12 | 6,03 | 2,93 | 4,40 | 5,15 |

Для оценки способности системы выполнять поставленную задачу распознавания движущихся объектов был выработан критерий пригодности, значение которого рассчитывали при определении типа объекта (то есть его класса и направления движения) подобно коэффициенту корреляции Пирсона по формуле [9]

$$r_{xy} = \frac{n \sum_{i=1}^n (x_i \times y_i) - \left(\sum_{i=1}^n x_i \times \sum_{i=1}^n y_i \right)}{\sqrt{\left[n \sum_{i=1}^n x_i^2 - \left(\sum_{i=1}^n x_i \right)^2 \right] \times \left[n \sum_{i=1}^n y_i^2 - \left(\sum_{i=1}^n y_i \right)^2 \right]}}$$

x_i — значения независимой переменной (фактический номер типа объекта); y_i — значение зависимой переменной (номер объекта, полученный после распознавания его класса и направления движения нейронной сетью по признакам); n — число примеров.

Критерий пригодности для ограниченной выборки (представленной двумя классами ("человек" и "авто") и двумя вариантами поведения объекта ("нарушитель" и "беглец")) составил около 0,8 (рис. 3). Для расширенной выборки (три класса

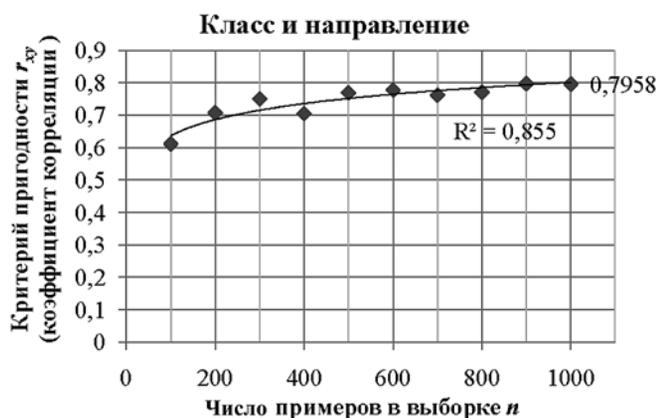


Рис. 3. Критерий пригодности системы для выполнения поставленной задачи для различного числа примеров ограниченной выборки

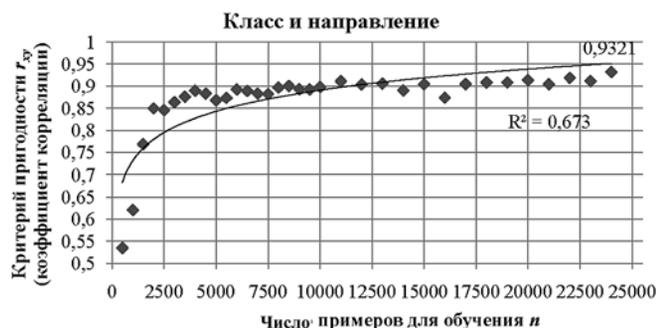


Рис. 4. Критерий пригодности системы для выполнения поставленной задачи для различного числа примеров расширенной выборки

("человек", "авто", "фауна") и три варианта поведения ("нарушитель", "беглец" и "гуляющий")) полученные результаты при оценке критериев качества работы системы имеют аналогичные тенденции к изменению и их значения достигают 0,9...0,95 с той лишь разницей, что для поддержания репрезентативности выборки число примеров существенно больше (рис. 4). Объекты сгруппированы под номерами по приоритету классов при распознавании. Ранжирование объектов по номерам помогает интерпретировать оценки критериев качества при анализе результатов распознавания.

Достоверность аппроксимации R^2 (коэффициент детерминации) отображает степень соответствия ожидаемых значений для линий тренда фактическим данным. Значение достоверности аппроксимации рассчитывалось в MS Excel автоматически. В нашем случае значения достоверности аппроксимации для ограниченной и расширенной выборок составили 0,855 и 0,673 соответственно.

Для подтверждения предположения, что число задаваемых признаков может быть уменьшено без существенного понижения качества распознавания, были проведены численные эксперименты и выделены наиболее значимые признаки. Отбор значимых признаков осуществлялся методом направленного перебора (метод ветвей и границ) [10]. Этот метод позволяет отсеять неперспективные планы (наборы сочетаний признаков) и перейти от полного перебора планов к сокращенному перебору. Общая постановка такой задачи имеет следующий вид:

$f(X) \rightarrow \min, X \in P, P$ — множество всех признаков;
 $f(X)$ — целевая функция, скалярная функция своих аргументов.

Приведем основные этапы алгоритма отбора значимых признаков.

1. Ранжирование признаков в порядке уменьшения ошибки распознавания системой параметров (масса, скорость) и типа (класс и направление) движущегося объекта, которая возникает в случае исключения одного признака из входного вектора нейронной сети.

Критерий пригодности системы, показанный на рис. 5, демонстрирует разную чувствительность системы на отсутствие отдельного признака при распознавании. Эксперименты проведены на расширенной выборке, состоящей из 20 000 примеров, использующихся для обучения нейронных сетей, и 5000 примеров при тестировании. Вначале после ранжирования оставляем n признаков, при отсутствии которых ошибка определения параметров выше или равна той, что была получена при распознавании по всем признакам.



Рис. 5. Критерий пригодности системы при отсутствии одного из признаков

На каждом i -м ($i = 0, 1, 2, \dots, n - 1$) шаге число признаков в подмножестве уменьшается на один условно "слабый" признак и остается $(n - i)$ признаков, из которых формируют подмножества P_i , где все признаки, кроме последнего, оставляют неизменными, а последний перебором меняют на ближайшие сокращенные признаки на $(i - 1)$ -м шаге. В итоге оставляют тот набор признаков, при котором ошибка определяемого параметра движущегося объекта является наименьшей на i -м шаге. Если выбор наименьшей ошибки затруднен, так как ошибки оказываются примерно равными с точностью до 0,1 % для разных подборов последних признаков в наборе признаков, то считают, что это альтернативные наборы, и на следующем шаге учитывают последние признаки всех этих наборов при переборе. Затем вычисляется нижняя граница возрастания ошибки параметра на i -м шаге $f(X_i)$ и сравнивается их сумма за i шагов с нижней границей целевой функции:

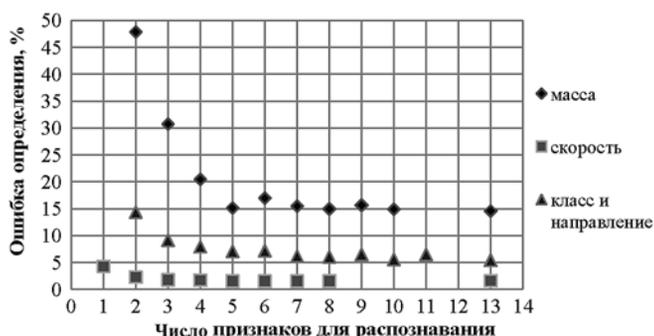
$$\sum_{k=0}^i f(X_k) \leq f(X).$$


Рис. 6. Ошибки определения параметров объекта в сравнении

2. При достижении целевой функцией заданного минимального значения для нижней границы фиксируется набор значимых признаков или альтернативные наборы.

3. Для полного анализа следующие шаги отбора признаков выполняют так же, как и раньше, но при этом находят превышение суммы для нижних границ возрастания ошибки определения параметра за i шагов над нижней границей целевой функции,

$$\text{т. е. } \sum_{k=0}^i f(X_k) - \min > 0.$$

Результаты использования данного алгоритма позволили установить, что для выполнения задачи достаточно использовать не весь набор выделенных признаков, а набор значимых признаков, которые указаны в табл. 4. Характер изменения ошибок определения параметров (массы, скорости, класса и направления) объекта и критерия пригодности от числа признаков можно видеть на рис. 6 и 7.

Результаты обработки многослойными нейронными сетями прямого распространения на выборках примеров, полученных по реальным данным, представлены в табл. 5.

По значениям ошибок определения параметров движущегося объекта в проведенных экспериментах подтверждается достаточная эффективность и приемлемая точность выполнения задачи распознавания динамических образов по МО в ИРИИС. В табл. 5 можно видеть, что класс и направление движения распознаются с ошибкой 0...0,01 %, т. е. практически безошибочно. При определении массы точность составила ~10 % по пяти признакам и ~12 % по девяти главным компонентам, а при нахождении длины пути она оказалась ~6,5 % по шести признакам и ~8 % по 19 главным компонентам. В табл. 5 полужирным шрифтом выделены наиболее удачные наборы признаков для определения массы и длины пути. Проведенные эксперименты показали преимущество способа, основанного на формировании МО по признакам, ввиду меньшего необхо-

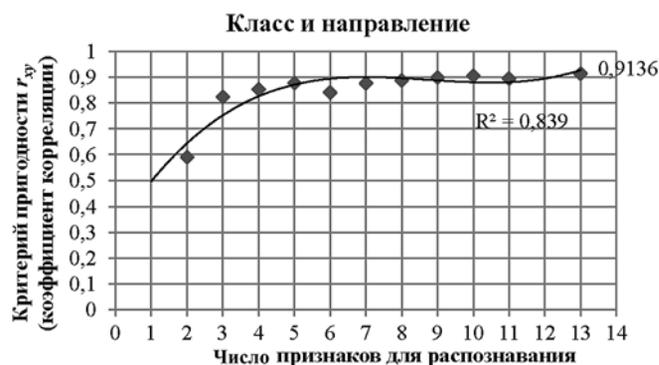


Рис. 7. Критерий пригодности системы при разном числе признаков

Результаты обработки многослойными нейронными сетями по реальным данным

| Параметр движущегося объекта | Ошибка по обучающей выборке (10 000 примеров), % | | Ошибка по тестовой выборке (200 примеров), % | | Значимые признаки | Число главных компонент |
|------------------------------|---|------------------------|---|------------------------|---|-------------------------|
| | По признакам | По главным компонентам | По признакам | По главным компонентам | | |
| Класс | 0,04 | 0,01 | 0 | 0 | 7,14 | 2 |
| Направление движения | 0 | 0 | 0 | 0 | 19,20 | 4 |
| Масса | 11,7967 10,7624 9,9818 10,2127 10,1200 | 14,3098 | 12,9418 11,0035 10,3132 9,7757 10,6965 | 11,9496 | 5,14 3,5,15 3,5,6,15 3,5,6,15,20 1,5,6,11,14,15 | 9 |
| Длина пути | 8,4706 8,1897 7,4447 6,8433 6,6221 6,7787 6,7539 | 7,5857 | 8,1024 8,1161 7,7145 7,0570 6,5462 6,8614 6,9505 | 7,7334 | 3,15 3,5,15 3,6,15,19 3,5,6,15,19 3,4,5,6,15,19 3,5,6,8,10,15,20 3,5,6,8,10,12,15,20 | 19 |

димого числа признаков, чем числа главных компонент для достижения примерно одинаковых ошибок при распознавании.

Заключение

Таким образом, в ходе проведения численных экспериментов проверена целесообразность и показана эффективность предлагаемых способов обработки данных как по сгенерированным данным, так и по реальным данным, полученным от макета РВОИС охраны периметра.

Выявлено, что для каждого определяемого параметра при распознавании существует оптимальное минимальное число признаков, при котором ошибка параметра отличается незначительно ($\leq 1\%$) от ее значения, получаемого при использовании полного набора выделенных признаков. Также установлено, что критерий пригодности системы для выполнения поставленной задачи достигает 0,91 и зависит от числа признаков. Критерии пригодности между собой отличаются незначительно (в пределах $\pm 0,02$) при использовании восьми признаков и более для идентификации движущегося объекта.

Работа выполнена при финансовой поддержке Министерства образования и науки Российской Федерации по постановлению П218, договор № 02.G25.31.0116 от 14 августа 2014 года между Открытым акционерным обществом "Центр судоремонта "Дальзавод"

и Министерством образования и науки Российской Федерации.

Список литературы

1. **Кульчин Ю. Н.** Распределенные волоконно-оптические измерительные системы. М.: Физматлит, 2001. 272 с.
2. **Джексон П.** Введение в экспертные системы (Introduction to Expert Systems). 3-е изд. М.: Вильямс, 2001. 624 с.
3. **Оссовский С.** Нейронные сети для обработки информации / Пер. с польск. И. Д. Рудинского. М.: Финансы и статистика, 2002. 344 с.
4. **Кульчин Ю. Н., Ким А. Ю.** Распознавание динамических образов распределенной информационно-измерительной системой сегментарного типа // Проблемы управления. 2006. № 5. С. 52–57.
5. **Айвазян С. А., Бухштабер В. М., Енюков И. С., Мешалкин Л. Д.** Прикладная статистика. Классификация и снижение размерности. М.: Финансы и статистика, 1989. 607 с.
6. **Кульчин Ю. Н., Ноткин Б. С., Ким А. Ю.** Волоконно-оптическая система охраны периметра: исследование возможности применения нейронных сетей // Сб. науч. Тр. 11-й Всерос. науч.-техн. конф. "Нейроинформатика 2009". Т. 2. М.: Изд-во МИФИ, 2009. С. 259–266.
7. **Грешилов А. А., Стакун В. А., Стакун А. А.** Математические методы построения прогнозов. М.: Радио и связь, 1997. 112 с.
8. **Marquardt D.** An Algorithm for Least-Squares Estimation of Nonlinear Parameters // SIAM Journal on Applied Mathematics. 1963. Vol. 11, N. 2. P. 431–441.
9. **Бендат Дж., Пирсол А.** Применения корреляционного и спектрального анализа. М.: Мир, 1983. 312 с.
10. **Токарев В. Л., Набродова И. Н.** Построение модели по разнотипным данным для информационно-измерительных систем // Управление, вычислительная техника и информационные технологии. Известия ТулГУ. Технические науки. 2013. Вып. 1. С. 280–285.

Yu. N. Kulchin^{1, 2}, Academician, Dr. Sc. (Phys.-Math),

"Director of the IACP FEB RAS, e-mail: kulchin@iacp.dvo.ru,

A. Yu. Kim¹, Junior Researcher, e-mail: ayukim@mail.ru,

B. S. Notkin^{1, 2}, Cand. of Eng. Sci., Senior Researcher, e-mail: boris_notkin@mail.ru;

A. B. Lyuhter³, Cand. of Eng. Sci., Adviser to the Rector's of the VISU, e-mail: 369913_7@gmail.com

¹ Institute of Automation and Control Processes, FEB RAS, Vladivostok 690041, Russia

² Far Eastern Federal University, Vladivostok 690950, Russia

³ Vladimir State University, 87 Gorky St., Vladimir 600000, Russia

Signal Processing System of DFMN Segmental Type for Recognition of Dynamic Images Using Neural Networks

Methods, techniques and algorithms for signal processing of distributed fiber-optic measuring network (DFMN) segmental type and the formation of their models using images as a set of characteristic features or principal component collections for the states of moving object are considered. We have invited to receive sample examples for training and testing of neural networks using generated software modules (sensory data generator and data conversion module). Analysis of the results of research carried out for the development of intelligent distributed information-measuring system based on DFMN segmental type for recognition of dynamic images. During the numerical experiments we checked and proved the expediency and effectiveness of the proposed methods, as on generated data so on real data obtained from the layout DFMN perimeter protection. Revealed, that for each defined parameter, there is an optimal minimum number of "features". The error of recognition is slightly different ($\leq 1\%$) of its value, which is obtained using a complete set of extracted features. It is also found that the system suitability criteria for the task reaches 0,91, and depends on the number of features.

Keywords: neural networks, intelligent information-measuring systems, expert systems, model images, recognition of dynamic images

References

1. **Kulchin Yu. N.** *Distributed fiber-optic measuring system*. M.: Fizmatlit. 2001. 272 p.
2. **Jackson P.** *Introduction to Expert Systems*. 3rd ed. M.: Williams, 2001. 624 p.
3. **Ossowski S.** *Neural networks for information processing* / Translated from the Polish by I. D. Rudinsky. M.: Finance and Statistics. 2001. 344 p.
4. **Kulchin Yu. N., Kim A. Yu.** Recognition of Dynamic Images Distributed Information-Measuring System Segmental Type. *Control Problems*. 2006. N. 5. P. 52–57.
5. **Aivazyan S. A., Bukhshtaber V. M., Eniukov J. S., Meshalkin L. D.** *Applied Statistics. Classification and reduction of dimension*. M.: Finance and Statistics. 1989. 607 p.
6. **Kulchin Yu. N., Notkin B. S., Kim A. Yu.** Fiber-optic perimeter security system: a study of the possibility of using neural networks. *Collection of scientific proceedings of the 11th All-Russia, n.-t. conf. "Neuroinformatics 2009"*. 2009. M.: MEPhI. Vol. 2. P. 259–266.
7. **Greshilov A. A., Stakun V. A., Stakun A. A.** *Mathematical methods of forecasting*. M.: Radio and communication, 1997. 112 p.
8. **Marquardt D.** An Algorithm for Least-Squares Estimation of Nonlinear Parameters // *SIAM Journal on Applied Mathematics*. 1963. Vol. 11, N. 2. P. 431–441.
9. **Bendat J., Piersol A.** *Applications of correlation and spectral analysis*. M.: Mir, 1983. 312 p.
10. **Tokarev V. L., Nabrodova I. N.** Construction of model for polytypic data for information-measuring systems. *Management, Computer Science and Information Technology. Izvestiya TSU. Engineering*. Tula, 2013. Is. 1. P. 280–285.

Адрес редакции:

107076, Москва, Стромьинский пер., 4

Телефон редакции журнала (499) 269-5510

E-mail: it@novtex.ru

Технический редактор *Е. В. Конова*.

Корректор *Т. В. Пчелкина*.

Сдано в набор 09.02.2015. Подписано в печать 24.03.2015. Формат 60×88 1/8. Бумага офсетная.

Усл. печ. л. 8,86. Заказ IT415. Цена договорная.

Журнал зарегистрирован в Министерстве Российской Федерации по делам печати, телерадиовещания и средств массовых коммуникаций.

Свидетельство о регистрации ПИ № 77-15565 от 02 июня 2003 г.

Оригинал-макет ООО "Авансед солюшнз". Отпечатано в ООО "Авансед солюшнз".

119071, г. Москва, Ленинский пр-т, д. 19, стр. 1.