Метод формирования исходных данных для обучения интеллектуальных информационных систем, реализующий нейросетевые модели

A method of generating initial data for training intelligent information systems implementing neural network models

Белокопытов / Belokopytov M.
Марк Львович
(Hommer1990@mail.ru)
кандидат технических наук.
ФГБВОУ ВО «Военно-космическая академия имени А. Ф. Можайского» МО РФ
(ВКА им. А. Ф. Можайского),
начальник научно-исследовательской лаборатории.
г. Санкт-Петербург

Пономарева / Ponomareva E.
Элина Викторовна
(elipon@mail.ru)
ВКА им. А. Ф. Можайского,
младший научный сотрудник
научно-исследовательской лаборатории.
г. Санкт-Петербург

Протасова / Protasova A.
Арина Валерьевна
(vka@mil.ru)
ВКА им. А. Ф. Можайского,
младший научный сотрудник
научно-исследовательской лаборатории.
г. Санкт-Петербург

Митряев / Mitryaev G.
Геннадий Андреевич
(vka@mail.ru)
кандидат технических наук.
ВКА им. А. Ф. Можайского,
начальник научно-исследовательской лаборатории.
г. Санкт-Петербург

Ключевые слова: интеллектуальные информационные системы – intelligent information systems; экспертные системы – expert systems; исходные данные – initial data; нейронная сеть – neural network.

В научной статье рассматривается возможность формирования исходных данных для обучения интеллектуальных информационных систем на основе нейросетевых моделей. В качестве варианта обучения нейронной сети использован способ, основанный на реализации метода рандомизации.

The scientific article considers the possibility of generating initial data for training intelligent information systems based on neural network models. As a variant of neural network training, a method based on the implementation of the randomization method is used.

Введение

Современные тенденции, определяющие необходимость оперативного выявления кризисных ситуаций для выработки эффективных управленческих решений, особенно в военной сфере, формируют дополнительные требования к системе информационно-аналитического обеспечения. Сложность реализуемых в процессе принятия решения моделей, аккумулирующих в себе знания значительного числа экспертов в различных предметных областях, высокая степень неопределенности и значительный объем информации, подлежащий обработке, определяют необходимость пересмотра реализованных способов обработки информации.

Реализуемые в настоящее время преобразования в системе информационно-аналитического обеспечения органов военного управления ориентированы на реализацию интеллектуальных информационных систем, позволяющих автоматизировать не только процессы подготовки информации для принятия решений, но и сложные процессы выработки решений [1]. Значительными потенциальными возможностями для реализации этих целей обладают нейросетевые технологии обработки данных, нашедшие широкое применение при решении задач распознавания как визуальных, так и звуковых образов объектов. При этом возможность их реализации применительно к задачам, связанным с идентификацией образов состояний сложных, частично наблюдаемых системных процессов, которыми зачастую являются объекты контроля в военной сфере, требует обоснования и разработки соответствующего методического аппарата.

Разработка метода формирования исходных данных для обучения интеллектуальных информационных систем, реализующего нейросетевые модели

Достоверная и своевременно добытая информация в современных условиях выступает в качестве одного из важнейших факторов, определяющих преимущества при принятии решения. Однако, сложность и многофакторность управленческих процессов, реализуемых в Вооруженных Силах Российской Федерации (ВС РФ), требования к качеству информационного обеспечения в условиях возрастающей динамики и изменения оперативной обстановки требуют реализации эффективных информационных систем, обеспечивающих сбор и обработку необходимой информации в интересах решения стоящих управленческих задач. Потребность в решении сложных информационных задач обусловила появление значительного числа специализированных интеллектуальных информационных систем (ИИС).

ИИС представляют собой компьютерную модель интеллектуальных возможностей человека в целенаправленном поиске, анализе и синтезе информации об окружающей действительности для получения о ней новых знаний и решения на их основе различных прикладных задач [2].

К отличительным возможностям ИИС можно отнести следующие:

– способность накапливать знания об исследуемых объектах и явлениях, инициировать процессы получения новых знаний;

– пополнение знаний с помощью логического вывода, отражающего закономерности в исследуемых явлениях, получение обобщенных знаний на основе более частных знаний и возможность логически планировать свою деятельность (вычислительный процесс);

– взаимодействие с оператором на языке, максимально приближенном к естественному;

– интерпретация результатов проведенных вычислений, сформированных выводов по результатам решения расчетно-аналитических задач;

– информационная поддержка пользователя на основе знаний, которые хранятся в памяти и логических средств рассуждений, которые присущи системе.

Наибольшую практическую реализацию среди ИИС получили экспертные системы (ЭС) в виде программ, реализующих алгоритмы действий экспертов при решении аналитической задачи в некоторой прикладной предметной области. Основу реализуемого системой алгоритма решения практической задачи составляет эвристика, представляющая собой знание, приобретенное человеком по мере накопления практического опыта решения проблем. Эвристика формирует базу знаний, используемую ИИС для построения цепочки рассуждений в ходе принятия решения в уникальных ситуациях предметной области.

Исходя из реализованного способа формирования решения ЭС могут быть разделены на два класса [3]:

– аналитические (ориентированы на выбор решений из множества известных альтернатив (состояний));

– синтетические (генерируют неизвестные решения (формируют возможные состояния)).

Аналитические ЭС нашли широкое применение в различных практических областях. Модель, описывающая возможные варианты состояний объекта контроля, реализованная в органах военного управления (ОВУ), в большинстве случаев определяется конечным множеством состояний и идентифицирующих их признаков и может быть представлена в виде матрицы, общий вид которой представлен на рисунке 1.

На рисунке через b_{ir} обозначен весовой коэффи-

		Признаки определяющие возможное состояние (p_i)					
		p_1	p_2	…	p_i	…	p_I
Состояния	S_1	b_{11}	b_{21}	…	b_{i1}	…	b_{I1}
	S_2	b_{12}	b_{22}	…	b_{32}	…	b_{I2}
	…			…		…	
	S_r	b_{1r}	b_{2r}	…	b_{ir}	…	b_{Ir}
	…			…		…	
	S_R	b_{1R}	b_{2R}	…	b_{3R}	…	b_{IR}

Рис. 1. Модель состояний объекта контроля в матричном виде

циент, определяющий значение признака для идентификации состояния объекта контроля.

Следует отметить, что опыт, связанный с практическим применением аналитических ЭС, позволил выявить ряд присущих им недостатков, не позволяющих их эффективно использовать в динамично изменяющихся условиях обстановки.

В качестве основных недостатков, присущих ЭС и определяющих возможные ошибки при их практическом применении, чаще всего выделяют следующие [3]:

– субъективный подход к определению весовых коэффициентов значимости факторов, определяющих возможные состояния объектов контроля;

– неспособность системы адаптироваться к изменениям предметной области.

Кроме того, значительная часть реализованных в настоящее время ЭС, ориентированных на идентификацию состояний частично наблюдаемых объектов контроля, основана на реализации так называемых «поверхностных знаний», описывающих явные зависимости, выявленные экспертами в процессе наблюдения объекта и представленные в виде формализованных взаимосвязей между отдельными событиями и фактами в рассматриваемой предметной области. Такие системы, как правило, лишены возможностей, связанных с реализацией «глубинных знаний», представляющих собой абстракции, аналогии, схемы, отображающие структуру и природу процессов, протекающих в анализируемой предметной области. Данное обстоятельство обусловлено отсутствием универсальных методик, позволяющих выявлять глубинные и неявные структуры знаний для последующей работы с ними.

Другое ограничение, определяющее возможность практической реализации ЭС в военной сфере, связано с выполнением условий по полноте и точности исходных информационных признаков, поступающих на вход системы обработки. Система контроля функционирует в условиях частичной наблюдаемости, вследствие чего при высокой интенсивности изменения обстановки количество известных признаков оказывается недостаточным для принятия обоснованного решения о текущем состоянии, т.е. возрастает неопределенность принятия решения. В большинстве случаев данную неопределенность можно разделить на две категории:

– недостаточно полное знание предметной области;

– недостаточная информация о конкретной ситуации (состоянии).

Возможности устранения данных недостатков связаны с разработкой и внедрением информационно-аналитических структур самообучающихся интеллектуальных систем (индуктивные системы, дедуктивные системы, нейронные сети, системы, основанные на прецедентах и т.п.) [4].

Среди самообучающихся ИИС наибольшую практическую реализацию получили нейронные сети (НС). Возможности их практической реализации обусловлены значительным расширением вычислительных возможностей компьютеров. В современных условиях НС развиваются как раздел теории искусственного интеллекта, в котором для обработки информации, представленной в виде набора входных сигналов, используются явления, аналогичные происходящим в нейронах живых существ. Т.е. НС представляет собой модель вычислительного процесса, реализованного в виде сети с конечным числом слоев, состоящих из однотипных вычислительных элементов (аналогов нейронов с различными типами связей между слоями) и ориентированных на решение конкретной прикладной задачи.

Важнейшая особенность нейросетевых технологий, определяющая ее преимущества перед другими, состоит в обеспечении параллельной обработки информации всеми звеньями, что существенно позволяет ускорить процесс принятия решения в условиях значительного количества межнейронных связей [5]. Реализованная в НС способность к обучению и накоплению знаний формирует черты искусственного интеллекта. Натренированная на ограниченном множестве данных сеть способна обобщать полученную информацию и показывать приемлемые результаты на данных, не использовавшихся ранее в процессе обучения.

Нейросетевые модели (НСМ) нашли широкое применение для решения широкого спектра практических задач. Значительная доля реализованных в практической сфере решений, основанных на нейросетевых технологиях, связана с распознаванием образов визуальных и звуковых объектов. Широкую практическую реализацию получили программные модули, обеспечивающие поиск фотографий известных лиц в социальных сетях, а также решение задач, связанных с распознаванием голоса. Это объясняется наличием и доступностью достаточного количества фактических исходных данных для обучения НС. Однако отсутствие систематизированного массива исходных данных, описывающего статистику ситуаций в исследуемой предметной области, не позволяет реализовать процедуру обучения НС для решения практических задач в отдельных предметных областях и сферах деятельности. По этой причине схожие по своему содержанию задачи распознавания образа состояния объектов, описанного в виде модели, представленной на рис. 1, остаются зачастую практически нереализованными.

Подход к формированию обучающего набора исходных данных для реализации нейросетевой технологии при решении практических задач в военной сфере в условиях наличия эталонной модели состояний объекта контроля может быть основан на моделировании возможных вариантов исходных данных [6]. При этом степень адекватности данного процесса реальной действительности будет основываться на полноте знаний о степени неопределенности, связанной с неполнотой и ошибками в распознавании отдельных

информационных признаков подсистемой добывания информации. Обобщенная схема методики реализации нейросетевой модели для идентификации состояния объекта контроля в условиях его частичной наблюдаемости представлена на рис. 2.

Практическая реализация этапа, связанного с подготовкой исходных данных, представляет собой наибольшую трудность для практической реализации НСМ. В соответствии с представленной на рис. 2 схемой для формирования обучающей выборки требуются значительные объемы систематизированных статистических данных, описывающих состояния объекта мониторинга. При этом объем обучающей выборки в значительной степени определяется спецификой решаемой задачи распознавания (т.е. зависит от числа факторов (признаков), описывающих возможные состояния объекта мониторинга, число самих состояний и т.д.). Зачастую требуемый объем обучающейся выборки не может быть обеспечен вследствие недостаточной проработки реализованных в ОВУ механизмов систематизированного накопления информации. По этой причине первый из представленных вариантов обучения НС не может быть реализован.

В качестве альтернативного варианта обучения НС может быть использован способ, основанный на реализации метода рандомизации для формирования требуемого объема выборки исходных данных. Он основан на знании эталонной модели, описывающей возможные состояния объекта мониторинга (рис. 2), а также знании специфических особенностей функционирования подсистем добывания и передачи информации, которая определяется неопределенностью данных, поступающих в систему обработки.

Неопределенность поступающих данных, как правило, определяется следующими факторами [7]:

1) возможные ошибки, связанные с распознаванием признаков, характеризующих состояния объекта в соответствии со сформированной моделью (рис. 2);

2) неполнота данных, характеризующих текущее состояние объекта контроля, возникающая вследствие ограниченных возможностей средств сбора информации и необходимости обеспечения требуемой оперативности принятия решения;

3) неполнота данных, обусловленная противодействием противника (маскировка проводимых действий и намерений, а также дезинформация).

Учет степени данной неопределенности позволяет смоделировать возможные отклонения данных, поступающих в систему обработки, от эталонных состояний, представленных в сформированной модели состояний объекта мониторинга.

Качественное значение данной неопределенности определяется сущностью решаемой задачи. В качестве ее количественного показателя может выступать среднестатистическое значение неполноты данных или среднестатистическая доля отклонений от эталонных образов.

Возможность реализации метода рандомизации для формирования требуемого объема выборки исходных данных, необходимой для обучения НС, может быть продемонстрирована на следующем примере.

В соответствии с представленной на рис. 2 моделью число возможных состояний некоторого объекта

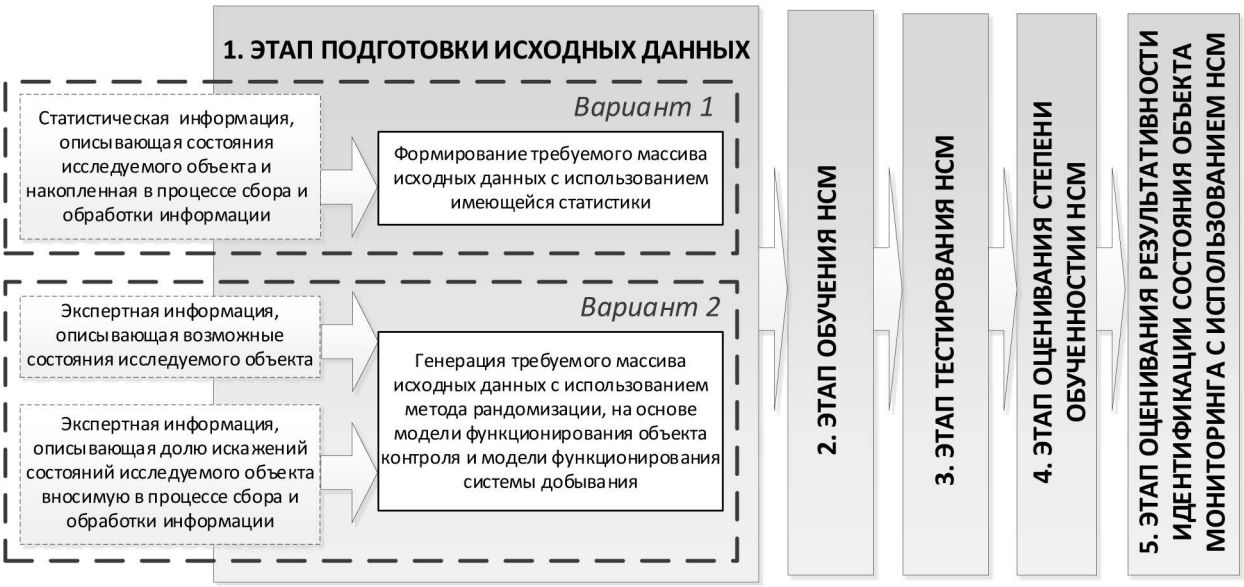

Рис. 2. Обобщенная схема методики реализации нейросетевой модели для идентификации состояния объекта контроля в условиях его частичной наблюдаемости

контроля будем считать равным S=5 с идентификацией каждого состояния на основе 12 информационных признаков. Эталонная модель возможных состояний объекта контроля может быть представлена в виде матрицы, для удобства восприятия значения элементов которой представлены в виде $x_i \in [0,1]$ (1 – признак проявляется при нахождении объекта в заданном состоянии; 0 – в противном случае).

Если допустить, что среднестатистическая доля отклонений значений признаков, регистрируемых системой обработки, от эталонных образов состояний может составлять до 30 % из-за наличия описанных выше неопределенностей в функционировании системы добывания, то возможные наборы исходных данных могут быть реализованы на основе генерации набора всевозможных «мутаций» эталонных значений. Каждый набор данных может содержать до 30 % искажений эталонного образа одного из возможных состояний объекта контроля. Практическая реализация описанных преобразований, может быть продемонстрирована на примере использования встроенных функций приложения «Excel».

Схема реализации этапа генерации исходных данных на основе предложенного метода рандомизации значений представлена на рис. 3.

Общая последовательность выполнения рандомизации исходных данных для обучения НС в соответствии с предлагаемой методикой включает следующие основные этапы:

1. Формализованное описание множества состояний объекта на заданном признаковом поле.

2. Определение количественных показателей, характеризующих неполноту исходных данных и долю искаженной информации, поступающих в систему обработки наборах данных.

3. Формирование требуемого для обучения нейросетевого двумерного массива данных *(M*x*N)*, где M – число генерируемых наборов данных, а N – число признаков, характеризующих возможное состояние объекта мониторинга в соответствии с заданной моделью эталонных состояний. Значения признаков формируются как независимые нормально распределенные случайные величины. Число M определяется исходя из требуемого объема обучающей выборки. Применительно к рассматриваемой задаче формируемые случайные величины изменяются в интервале .

1. Формирование трансформирующей модели для последующего преобразования эталонной модели состояний объекта мониторинга. На данном этапе осуществляется нормирование и преобразование сформированного набора случайных величин в соответствии с долей вносимых искажений. В соответствии с выбранной в условии задачи долей возможных искажений эталонных состояний (30 %) каждому элементу сформированного множества данных присваивается значение 1 – если его величина больше 0.7, в противном случае – 0. В дополнение к сформированному множеству данных формируется случайная последовательность нормально распределенных целых значений, изменяющихся в интервале , где S – число возможных состояний некоторого объекта, которое применительно к рассматриваемому примеру составляет S=5. Длина формируемой последовательности M представляет собой число генерируемых наборов данных.

2. Формирование набора исходных данных для обучающей выборки посредством внесения изменений в эталонную модель состояний объекта мониторинга. Данное преобразование выполняется на 4 шаге в соответствии со схемой последовательности действий при реализации этапа генерации исходных данных, представленной на рис. 3. В соответствии со сформированной трансформирующей моделью происходит преобразование модели эталонных состояний объектов мониторинга. Изменению на противоположное значение подлежат те элементы эталонного набора данных, для которых соответствующий элемент трансформирующего набора данных равен 1. В последующем сформированный набор исходных данных может быть использован в качестве обучающей выборки для НС.

В настоящее время ресурсы глобальной сети «Интернет» содержат значительное количество готовых программных решений, связанных с реализацией НСМ. Предложенные программные решения позволяют реализовывать многослойные НС, использующие различные механизмы обучения и организации межнейронных связей.

Одним из приемлемых способов обучения НС является способ обучения «с учителем» (так называемое управляемое обучение), так как оператор, участвующий в обучении, имея информацию об эталонном образе состояния, подвергшемся «мутации» на этапе подготовки исходных данных, может контролировать решения, принимаемые НС. Нейронной сети предъявляются значения входных и выходных сигналов, а она по определенному алгоритму подстраивает веса синаптических связей. В процессе обучения производится корректировка весов сети по результатам сравнения фактических выходных значений с входными, которые были известны заранее.

Исходя из всего вышеизложенного, предложенный метод рандомизации исходных данных для формирования обучающей выборки НС создает условия для их практической реализации в автоматизированных системах обработки информации ВС РФ.

В качестве одного из способов обучения НС при решении подобного рода задач может быть использован метод, предложенный Ф. Розенблаттом, который заключается в итерационной подстройке матрицы весов, обеспечивающей последовательное уменьшение ошибки в выходных векторах.

Пусть имеется набор пар векторов $(x^a, y^a), a = 1...p$, называемый обучающей выборкой. НС можно считать

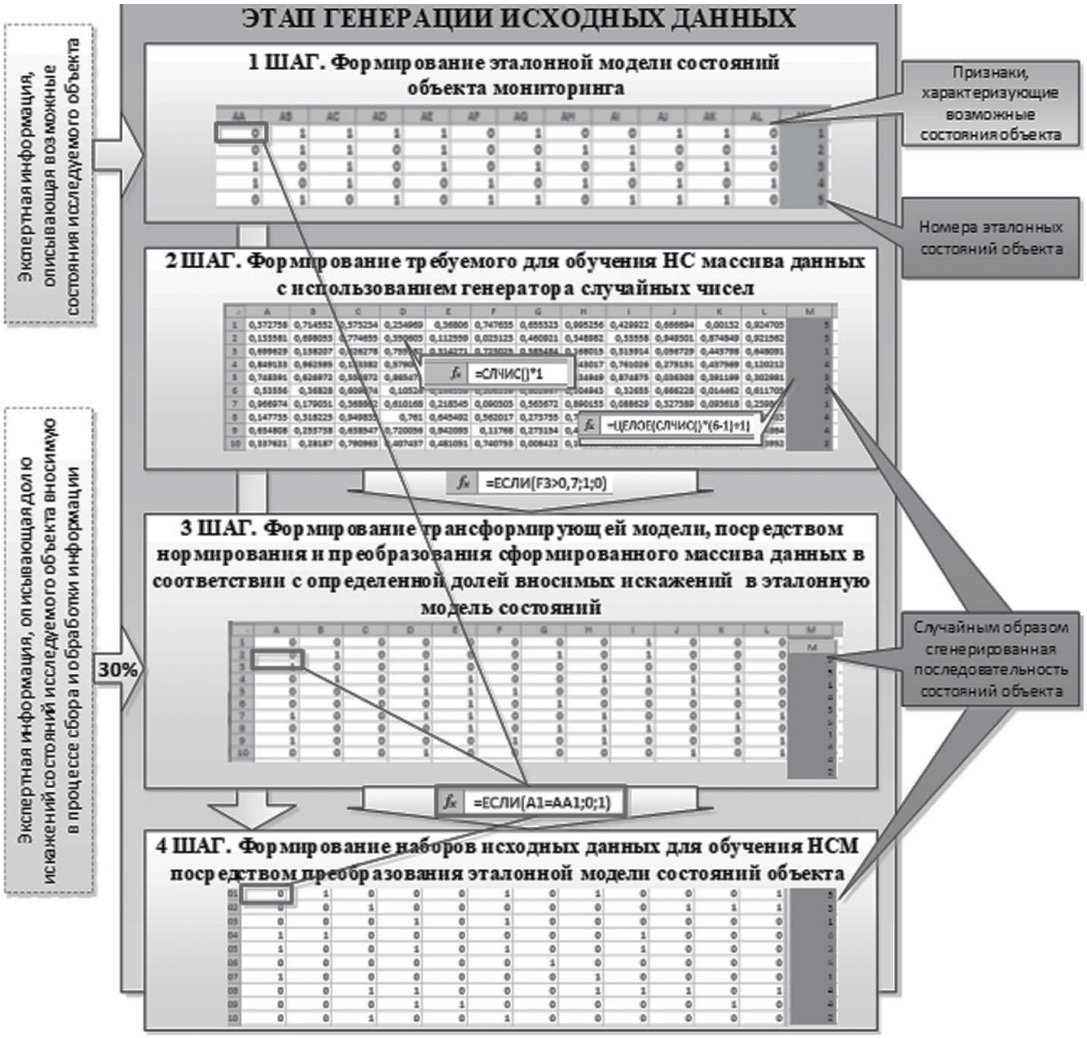

Рис. 3. Схема реализации этапа генерации исходных данных на основе метода рандомизации для обучения НС

обученной на данной обучающей выборке, если при подаче на входы сети каждого вектора x^a на выходах всякий раз получается соответствующий вектор y^a. Обобщенный алгоритм реализации метода Ф. Розенблатта включает следующие этапы:

1) начальные значения весов всех нейронов $W(t=0)$ полагаются случайными;

2) НС предъявляется входной образ x^a, задаваемый в виде вектора значений признаков состояния объекта, в результате чего формируется выходной образ в виде вектора состояния объекта $\tilde{y}^a \neq y^a$;

3) вычисляется вектор ошибки $\delta^a = (y^a - \tilde{y}^a)$, допускаемой НС на выходе. Изменение вектора весовых коэффициентов в области малых ошибок должно быть пропорционально ошибке на выходе и равно нулю, если ошибка равна нулю;

4) вектор весов модифицируется с использованием выражения $W(t+\Delta t) = W(t) + \eta x^a (\sigma^a)^T$, где $0 < \eta < 1$ – темп обучения;

5) этапы 1 – 3 повторяются для всех обучающих векторов. Один цикл последовательного предъявления всей выборки называется эпохой. Обучение завершается по достижении одного из следующих результатов:

– итерации сойдутся, т.е. вектор весов перестает изменяться;

– полная просуммированная по всем векторам абсолютная ошибка станет меньше некоторого малого значения.

Апробация предложенного метода рандомизации исходных данных при формировании обучающей выборки НС, проведенная на основе решения описанной

выше типовой задачи, позволила получить приемлемые результаты автоматизации процесса распознавания состояния объектов по их изображениям.

Результаты проведенного эксперимента, полученные при управлении долями искажений, вносимых в моделируемые значения наборов исходных данных, используемых при обучении НС, представлены на рис. 4.

Полученные результаты свидетельствуют о явной зависимости качества решения задачи от степени неопределенности, вызванной неполнотой или недостоверностью исходного набора значений показателей, поступающих на вход ИИС. При этом реализация нейросетевых технологий в процессе распознавания образа состояния объекта в условиях данной неопределенности может быть обеспечена с использованием описанного метода рандомизации исходных данных для обучения НС.

Значительные методологические трудности в реализации предложенного метода при решении отдельных практических задач в военной сфере связаны с выявлением степени данной неопределенности. Кроме того, выбор оптимальной НС для решения конкретной прикладной задачи требует проведения дополнительных исследований, связанных с оцениванием результативности решения задачи распознавания.

Заключение

Таким образом, разработан метод формирования исходных данных для обучения ИИС военного назначения, реализующих нейросетевые модели. Особого внимания при реализации данного метода в интересах автоматизации процесса распознавания состояний объектов мониторинга заслуживает проблема переобучения НС. Она связана со слишком долгим обучением НС при недостаточном числе обучающих примеров. Однако в ряде случаев возникает потребность в переобучении связанная с тем, что выбор обучающего (тренировочного) множества является случайным.

В качестве рекомендуемого способа недопущения потребности в переобучении НС, с использованием предложенного способа рандомизации исходных данных для обучения, предлагается использовать деление обучающей выборки на два множества (обучающее и тестовое). Тестовое множество недопустимо к использованию при обучении, а может использоваться исключительно для проверки качества функционирования НС при распознавании образа состояния. При этом обучение НС должно быть прекращено при снижении точности прогноза в ходе оценивания качества ее функционирования на тестовом множестве.

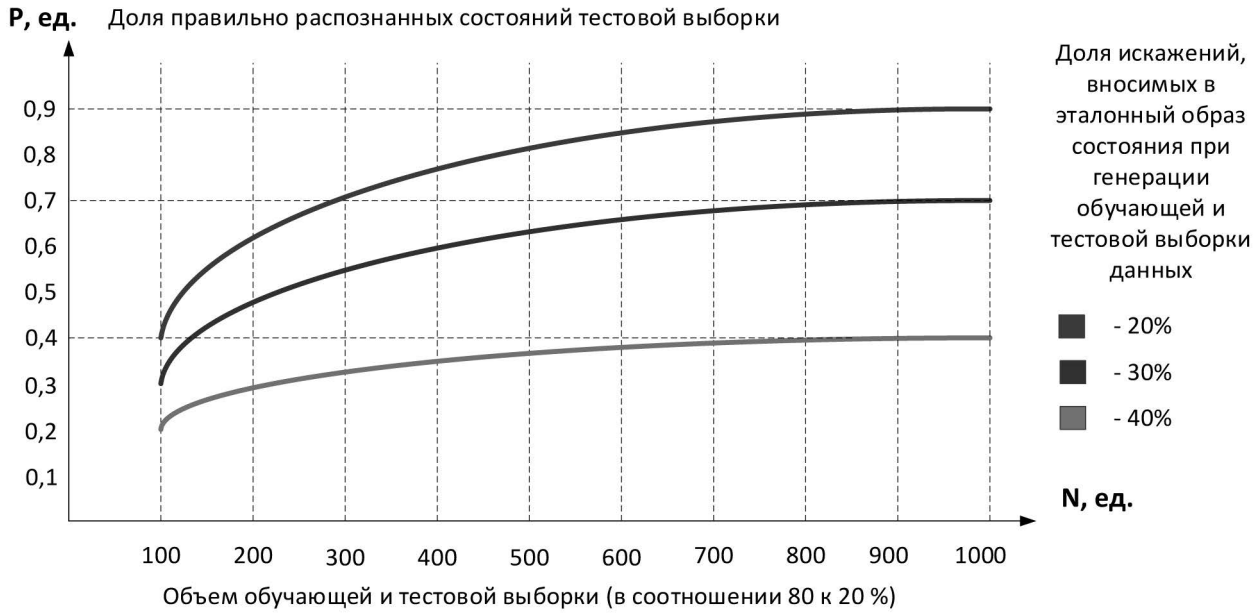

Рис. 4. Результаты решения задачи распознавания состояния объекта на основе НС, обученной с использованием метода рандомизации исходных данных

Литература

1. Приказ Министра обороны РФ № 725 дсп от 17 декабря 2018 г. «Об утверждении Порядка взаимодействия ОВУ и органов информационного обеспечения ВС РФ по подготовке и распространению информации о кризисных ситуациях, чрезвычайных ситуациях, чрезвычайных происшествиях и иных событиях в ВС РФ, имеющих общественную значимость в средствах массовой информации». – М.: МО РФ. – 2018.

2. Концепция Единого информационного пространства Вооруженных Сил Российской Федерации [Электронный ресурс] / Утверждена начальником ГШ ВС РФ 16 декабря 2004 г. // Военно-научные публикации. – Режим доступа: http://militaryarticle.ru [дата обращения 03.05.2022], свободный. – Загл. с экрана.

3. Назаров, А. В. Нейросетевые алгоритмы прогнозирования и оптимизации систем / А.В. Назаров, А.И. Лоскутов. – СПб.: Наука и Техника, 2003. – 384 с.

4. Флегонтов, А. В. Система интеллектуальной обработки данных / А.В. Флегонтов, В.В. Фомин // Известия Российского государственного педагогического университета им. А.И. Герцена. – 2013. – № 154. – С. 41–48.

5. Финн, В. К. Искусственный интеллект: идейная база и основной продукт / В.К. Финн // Труды 9-ой национальной конференции по искусственному интеллекту, Тверь, 8–11 сентября 2004. – 2004. – Т. 1. – С. 11–20.

6. Яковлев, Е. Л. Модель оценивания вычислительной сложности интеллектуального распознавания объектов на изображениях на борту БЛА / Е.Л. Яковлев // Интеллектуальные технологии на транспорте. – 2018. – № 3. – С. 27–31.

7. Шапиро, Л. Компьютерное зрение / Л. Шапиро, Дж. Стокман. – М.: Бином. Лаборатория знаний, 2006. – 752 с.