

УДК 004.415.2

В.В. Шишкин, Д.И. Стенюшкин, А.В. Михеев

АВТОМАТИЗАЦИЯ ПРОЕКТИРОВАНИЯ НЕЙРОСЕТЕВЫХ КЛАССИФИКАТОРОВ

Шишкин Вадим Викторович, кандидат технических наук, доцент, окончил радиотехнический факультет Ульяновского политехнического института. Профессор кафедры «Измерительно-вычислительные комплексы» Ульяновского государственного технического университета, декан факультета информационных систем и технологий УлГТУ. Имеет статьи в области автоматизации проектирования промышленных изделий, а также интеллектуального анализа данных. [e-mail: shvv@ulstu.ru].

Стенюшкин Денис Игоревич, окончил факультет информационных систем и технологий УлГТУ. Аспирант кафедры «Измерительно-вычислительные комплексы» УлГТУ. Имеет статьи в области автоматизации проектирования промышленных изделий, а также интеллектуального анализа данных. [e-mail: denisstenyushkin@yandex.ru].

Михеев Александр Вячеславович, окончил факультет информационных систем и технологий УлГТУ. Аспирант кафедры «Измерительно-вычислительные комплексы» УлГТУ. Имеет статьи в области проектирования измерительно-вычислительной техники, а также интеллектуального анализа данных. [e-mail: sr.alex.anderson@gmail.com].

Аннотация

В статье описана система моделей и методов автоматизированного проектирования нейросетевых классификаторов, основанная на замкнутом цикле с обратной связью в виде анализа накопленного опыта. Цель такой системы – сокращение сроков проектирования классификаторов. В качестве формализма для описания накопленного опыта применено пространство, каждая точка которого соответствует набору параметров классификатора – пространство параметров. Данное пространство формируется параметрами, значение которых определяется на протяжении всего жизненного цикла классификатора: от постановки задачи до процесса эксплуатации. Выбранный формализм позволяет формулировать накопленный опыт и операции по его анализу в терминах множеств и операций над ними, что повышает наглядность и облегчает автоматизацию данных процессов. Анализ накопленного опыта, основанный на сравнении проекций точек пространства параметров на определенные направления, позволяет выявить проектные решения, пригодные для повторного применения. Такие решения включают архитектуры классификаторов, параметры архитектуры и веса входов нейронов. Использование отобранных значений параметров в качестве начальных при обучении и настройке нового классификатора позволило добиться сокращения времени, затрачиваемого на эти процессы, на 15%.

Ключевые слова: нейросетевые классификаторы, проектирование классификаторов, пространство параметров, замкнутый цикл проектирования.

AUTOMATED DESIGN OF ARTIFICIAL NEURAL NETWORK BASED CLASSIFIERS

Vadim Viktorinovich Shishkin, Candidate of Engineering, Associate Professor; graduated from the Faculty of Radio-Engineering at Ulyanovsk State Polytechnical Institute; Professor at the Measuring-Computing Complexes Department of Ulyanovsk State Technical University, Dean of the Faculty of Information Systems and Technologies at ULSTU, an author of articles in the field of automated design of industrial products and intellectual data analysis. e-mail: shvv@ulstu.ru.

Denis Igorevich Stenyushkin, graduated from the Faculty of Information Systems and Technologies at Ulyanovsk State Technical University; Post-Graduate Student at the Measuring-Computing Complexes Department of Ulyanovsk State Technical University, an author of articles in the field of automated design of industrial products and intellectual data analysis. e-mail: denisstenyushkin@yandex.ru.

Alexander Vyacheslavovich Mikheev, graduated from the Faculty of Information Systems and Technologies at Ulyanovsk State Technical University; Post-Graduate Student at the Measuring-Computing Complexes Department of Ulyanovsk State Technical University, an author of articles in the field of measuring-computing system design and intellectual data analysis. e-mail: sr.alex.anderson@gmail.com.

Abstract

The article describes a system of models and methods for automated design of neural network-based classifiers. The system bases on the closed design cycle with feedback in form of analysis of gathered experience. The system's goal is decrease of design process' time costs. Parameters space is utilized as a formal system for experience representation. Parameters space is a space of points that represent sets of classifiers' parameters. The space is constructed from parameters, which values are being specified through whole classifier's life cycle from specification up to operation. This formalism allows to formulate the experience and analysis operations performed over it in terms of sets and operations over them. This results into representation improvement and automation costs decrease. Experience analysis bases on comparison of parameters space points' projections on dedicated directions. It allows to detect classifier design solutions that are convenient to re-use. These solutions include classifier architectures, architectural parameters and neuron input weights. Using the detected parameters values as initial values in a new classifier's training and setting up process lead to time costs decrease of 15%.

Key words: artificial neural network-based classifiers, classifiers design, parameters space, closed design cycle

ВВЕДЕНИЕ

Задачи классификации возникают в процессе решения многих прикладных задач в различных областях техники: техническая диагностика, системы управления технологическими процессами, робототехника и т. д. К таким задачам, в частности, сводятся задачи ультразвуковой диагностики промышленных изделий.

Основным компонентом системы ультразвуковой диагностики служит классификатор, предназначенный для причисления обнаруженных во входных данных объектов к тому или иному классу [1]. В системах с автоматическим распознаванием дефектов классификатор является автоматической системой, выполняющей отображение множества входных объектов на множество классов объектов. Для построения классификаторов в настоящее время широко применяются искусственные нейронные сети различных архитектур [2, 3].

Проектирование нейросетевого классификатора (НСК), начиная с выбора архитектуры, наиболее подходящей для решения поставленной задачи, и заканчивая настройкой ее параметров, позволяющих достичь заданных эксплуатационных показателей, является сложной задачей. Причиной тому, помимо разнообразия архитектур и их вариаций, является сложность процесса подбора свободных параметров НСК, а также необходимость проведения процесса обучения. Эти два процесса требуют значительных временных и вычислительных ресурсов [4]. При этом не существует формального способа определения параметров архитектуры НСК [5]. С другой стороны, эффективность процесса проектирования и качество получаемого НСК напрямую влияют на сроки вывода новой системы на рынок, качество ее работы и коммерческую эффективность.

Существующие средства автоматизации проектирования НСК, такие как пакеты математического моделирования, специализированные фреймворки и т. д. [6, 7], позволяют автоматизировать процесс обучения НСК и процесс подбора его свободных параметров, что приводит к повышению эффективности процесса проектирования в целом. Вместе с тем, процесс выбора архитектуры НСК, а также учет и оценка накопленного опыта проектирования и применения НСК при решении различных задач не покрываются в достаточной мере существующими в настоя-

щее время средствами автоматизации. При этом объем данных, которые необходимо обрабатывать, очень высок: к примеру, журнал IEEE Transactions on Neural Networks and Learning Systems в 2013 году опубликовал более 180 новых исследований в данной области [8]. В результате, для этих процессов характерно существенное влияние на результат субъективных факторов, связанных с квалификацией, опытом и психо-эмоциональными особенностями проектировщика, а следовательно, и на результат проектирования НСК в целом.

Таким образом, актуальной является задача разработки САПР НСК, позволяющей, помимо обучения НСК и подбора значений их свободных параметров, в автоматизированном режиме накапливать, анализировать и использовать накопленный опыт для решения текущей задачи проектирования.

В настоящей статье изложены подход и система математических моделей САПР НСК, удовлетворяющей сформулированным требованиям.

1 Постановка задачи

При разработке подхода к автоматизированному проектированию НСК необходимо учитывать следующие основные требования, предъявляемые к нему:

1. Возможность учета накопленного опыта проектирования и применения НСК в различных задачах в виде набора фактов, выраженных в терминах некоторой формальной системы;
2. Возможность выражения постановки задачи на проектирование НСК в терминах той же системы;
3. Возможность использования накопленного опыта при решении текущей задачи на проектирование НСК с целью повышения эффективности процесса проектирования;
4. Возможность проведения полного цикла подбора свободных параметров, а также обучения НСК с целью достижения заданного уровня эксплуатационных параметров;
5. Возможность сравнения эффективности различных архитектур НСК при применении их в условиях текущей задачи.

Как видно, данный набор требований соответствует процессу проектирования с обратной связью в виде нака-

пливаемого опыта. Такая обратная связь позволит учитывать удачные и неудачные проектные решения и их последствия, что приведет к повышению эффективности процесса проектирования НСК. Описанный замкнутый цикл проектирования аналогичен циклу FRACAS, применяемому в процессах обеспечения безотказности авиационных бортовых информационных систем, и примененному авторами для автоматизации проектирования таких систем [9–11].

Опыт проектирования и применения НСК для решения различных задач должен накапливаться в виде фактов, отражающих различные параметры спроектированного и примененного НСК, а также достигнутые показатели точности распознавания. На основе такого множества параметров строится пространство параметров классификаторов. В таком пространстве каждому набору параметров классификатора соответствует одна и только одна точка.

Применение пространства параметров в качестве формальной системы описания фактов, характеризующих НСК, приводит к ряду преимуществ, важных для автоматизации процесса проектирования НСК:

1. Факты, характеризующие НСК, могут быть просто, наглядно, и при этом эффективно представлены в виде кортежей, описывающих положение точки в пространстве параметров;

2. Операции анализа накопленного опыта могут быть формально описаны в терминах операций над кортежами и их элементами;

3. В рамках пространства параметров НСК могут быть проведены исследования взаимного влияния различных параметров. Проведение таких исследований может, к примеру, основываться на методах кластерного анализа или корреляционного анализа, получающих наглядное толкование в терминах пространства параметров;

4. Неполные факты, характеризующие параметры НСК, также могут быть описаны в терминах пространства параметров, его подпространств и поверхностей в нем.

В рамках проведенного исследования пространство параметров применено для целей автоматизации проектирования НСК. В последующих разделах настоящей статьи описана процедура построения пространства параметров, а также модели и методы, применяемые для автоматизации проектирования.

2 ПРОСТРАНСТВО ПАРАМЕТРОВ НСК

Пространство параметров НСК представляет собой пространство, каждая точка которого соответствует одному и только одному набору параметров НСК. Каждый параметр соответствует одному измерению пространства. Параметры группируются таким образом, что каждая группа полностью заполняется на определенном этапе жизненного цикла НСК: постановка задачи, проектирование, эксплуатация. Каждая такая группа параметров соответствует подпространству пространства параметров. Параметры, формирующие пространство параметров НСК, с разбиением по группам представлены в таблице 1.

Смысловое значение каждого параметра ясно из таблицы, однако параметры *reqoverdetection*, *requnderdetection*

и *archparams* требуют дополнительных пояснений.

Параметры *reqoverdetection* и *requnderdetection* важны для тех областей применения, в которых, кроме непосредственно класса объекта, важно отнесение его к одной из групп: «дефект – не дефект», «свой – чужой» и т. д. В этом случае данные параметры позволяют оценить условную тяжесть последствий ошибок классификации.

Параметр *archparams*, в отличие от других параметров, имеющих скалярные значения, представляет собой вектор. Таким образом, он формирует дополнительное подпространство параметров архитектуры, вложенное в подпространство параметров проектирования.

Вид подпространства параметров архитектуры (размерность, перечень параметров, формирующих подпространство) определяется конкретной архитектурой НСК, т. е. для различных архитектур вид подпространства параметров архитектуры будет отличаться. К примеру, для многослойного перцептрона с одним скрытым слоем набор параметров архитектуры включает количество нейронов на каждом слое, вид функции активации и вектор весов входов нейронов.

Таким образом, для пространства параметров НСК имеем следующее определение:

$$SP = \{f_1, f_2, \dots, f_{\dim(SP)}\}, \quad (1)$$

где f_i точка, соответствующая определенному набору параметров НСК;

$\dim(SP)$ – размерность пространства.

f_i может быть представлена в виде кортежа в соответствии с формулой:

$$f = (v_{id}, v_{reqaccuracy}, v_{reqoverdetection}, v_{requnderdetection}, v_{reqtoper}, v_{dimin}, v_{dimout}, v_{field}, v_{uncertainty}, v_{typinput}, v_{architecture}, v_{archparams}, v_{trainingset}, v_{testingset}, v_{factaccuracy}, v_{factoper}, v_{factoverdetection}, v_{factunderdetection}), \quad (2)$$

где v_x – значение соответствующего параметра, и, для перцептрона с одним скрытым слоем,

$$v_{architecture} = (v_{ninput}, v_{nhidden}, v_{noutput}, v_{ninput}, v_{activation}, v_{nweights}). \quad (3)$$

Для размерности пространства имеем:

$$\begin{aligned} \dim(SP) = & \dim(id) \times \dim(reqaccuracy) \times \\ & \times \dim(reqoverdetection) \times \\ & \times \dim(requnderdetection) \times \\ & \times \dim(reqtoper) \times \dim(dimin) \times \\ & \times \dim(dimout) \times \dim(field) \times \\ & \times \dim(uncertainty) \times \\ & \times \dim(typinput) \times \dim(architecture) \times \\ & \times \dim(archparams) \times \dim(trainingset) \times \\ & \times \dim(testingset) \times \dim(factaccuracy) \times \\ & \times \dim(factoper) \times \dim(factoverdetection) \times \\ & \times \dim(factunderdetection), \end{aligned} \quad (4)$$

где $\dim(x)$ – размерность множества допустимых значений соответствующего параметра.

Таблица 1

Параметры, формирующие пространство параметров НСК

Группа	Наименование параметра	Обозначение параметра	Возможные значения
Постановка задачи	Обозначение НСК	id	Строка символов, условно обозначающая НСК
	Требуемая точность классификации	reqaccuracy	Вещественное число, заданный уровень точности распознавания классов в процентах
	Требуемый уровень ложных срабатываний	reqoverdetection	Вещественное число, заданный уровень ложных срабатываний в процентах
	Требуемый уровень пропусков	requnderdetection	Вещественное число, заданный уровень пропусков в процентах
	Требуемое время срабатывания	reqtoper	Вещественное число, требуемое время, за которое должна завершаться обработка входных данных в секундах
	Размерность входных данных	dimin	Целое число, размерность входного вектора данных
	Количество выделяемых классов	dimout	Целое число, количество классов, которые различает НСК. Специальное значение: dynamic – количество классов может изменяться
	Область применения	field	Элемент множества возможных областей применения НСК: ультразвуковая дефектоскопия, поиск объектов на изображениях и т. д.
	Допускается неопределенный ответ	uncertainty	Логический флаг (да/нет), обозначающий, может ли НСК допускать неопределенный ответ («не знаю», «неизвестный класс» и т. д.)
	Тип входных значений	typinput	Элемент множества типов входных значений: целочисленные, вещественные, бинарные.
Проектирование	Применяемая архитектура	architecture	Элемент множества архитектур НСК: перцептрон, карта Кохонена, ARTMAP и т. д.
	Вектор параметров архитектуры	archparams	Вектор параметров НСК, соответствующих данной архитектуре
	Обучающая выборка	trainingset	Ссылка на обучающую выборку для данного НСК в библиотеке обучающих выборок
	Тестовая выборка	testingset	Ссылка на тестовую выборку для данного НСК в библиотеке тестовых выборок
Эксплуатация	Достигнутая точность классификации	factaccuracy	Вещественное число, достигнутый уровень точности распознавания классов в процентах
	Достигнутое время срабатывания	facttoper	Вещественное число, достигнутое время, за которое завершается обработка входных данных в секундах
	Достигнутый уровень ложных срабатываний	factoverdetection	Вещественное число, достигнутый уровень ложных срабатываний в процентах
	Достигнутый уровень пропусков	factunderdetection	Вещественное число, достигнутый уровень пропусков в процентах

3 ПРОЦЕСС АВТОМАТИЗИРОВАННОГО ПРОЕКТИРОВАНИЯ НСК

Процесс автоматизированного проектирования НСК включает в себя следующие основные шаги:

1. Инициализация набора параметров проектируемого НСК. На данном шаге все параметры имеют пустые значения:

$$f = (\emptyset); \quad (5)$$

2. Формулировка задачи на проектирование НСК. На данном шаге формулируются требования к классификатору и устанавливаются значения параметров группы постановки задачи. С точки зрения пространства параметров это означает, что определяется положение точки в соответствующем подпространстве:

$$f = (v_{id}, v_{reqaccuracy}, v_{reqoverdetction}, v_{requnderdetction}, v_{reqtoper}, v_{dimin}, v_{dimout}, v_{field}, v_{uncertainty}, v_{typinput}); \quad (6)$$

3. Анализ и учет накопленного опыта. Данный шаг позволяет определить успешные проектные решения, которые могут быть повторно использованы для решения текущей задачи: архитектура, отдельные ее параметры или завершённый НСК. Значения параметров группы проектирования, включая параметры архитектуры, используются в качестве начальных значений соответствующих параметров проектируемого НСК:

$$f = (v_{id}, v_{reqaccuracy}, v_{reqoverdetction}, v_{requnderdetction}, v_{reqtoper}, v_{dimin}, v_{dimout}, v_{field}, v_{uncertainty}, v_{typinput}, v_{architecture}^0, v_{archparams}^0, v_{trainingset}^0, v_{testingset}^0), \quad (7)$$

где v_x^0 – заданное начальное значение соответствующего параметра НСК.

При отсутствии таких проектных решений начальные значения параметров устанавливаются проектировщиком на основе личного опыта;

4. Настройка, обучение НСК и выбор наиболее подходящей архитектуры. На данном шаге производится настройка параметров и обучение НСК. На основе результатов тестирования НСК определяется один, наилучшим образом решающий поставленную задачу. По результатам проделанной работы определяются значения параметров, входящих в группу проектирования. С точки зрения пространства параметров это означает, что определяется положение точки в подпространстве, включающем параметры данной группы:

$$f = (v_{id}, v_{reqaccuracy}, v_{reqoverdetction}, v_{requnderdetction}, v_{reqtoper}, v_{dimin}, v_{dimout}, v_{field}, v_{uncertainty}, v_{typinput}, v_{architecture}, v_{archparams}, v_{trainingset}, v_{testingset}); \quad (8)$$

5. Корректировка значений параметров в результате эксплуатации НСК. На данном шаге в процессе эксплуатации НСК в реальных производственных условиях отслеживаются фактически достигнутые значения эксплуатационных параметров. Соответствующие значения присваиваются параметрам НСК группы эксплуатации, и определяется положение точки в соответствующем подпространстве, и его вид соответствует формуле (2). С этого момента положение точки в пространстве параметров НСК определено полностью. В процессе эксплуатации значения параметров группы эксплуатации могут изменяться. Соответственно, изменяется положение точки в пространстве. Данный набор параметров НСК в дальнейшем может быть использован на шаге 3 в процессе решения задачи на проектирование другого НСК.

Таким образом, процесс проектирования НСК является замкнутым в полном соответствии с изложенными в разделе 2 настоящей статьи требованиями.

4 ПРОЦЕСС АНАЛИЗА НАКОПЛЕННОГО ОПЫТА

Процесс анализа накопленного опыта проектирования и эксплуатации НСК заключается в определении успеш-

ных проектных решений, пригодных к повторному применению в рамках решаемой задачи на проектирование НСК. Данный процесс включает следующие аспекты:

1. Поиск НСК, требования к которым аналогичны требованиям текущей задачи;
2. Определение проектных параметров, пригодных для повторного применения.

Первый аспект покрывается методом автоматического поиска в пространстве параметров НСК, второй оказывается переложенным на проектировщика.

Метод поиска в пространстве параметров НСК заключается в поиске точек, проекции которых на определенные направления находятся в заданных отношениях с проекцией точки, соответствующей проектируемому НСК, на те же направления. В рамках настоящей работы поиск сводился к поиску точек, для которых выражение (9) является истинным.

$$Prpf \geq Prpt, \quad (9)$$

где $Prpf$ – проекция проверяемой точки;

$Prpt$ – проекция точки, соответствующей решаемой задаче.

Проекция точек для целей анализа накопленного опыта строится на направления, соответствующие параметрам группы постановки задачи и группы эксплуатации в соответствии с кортежем (10).

$$Cnp = (reqaccuracy, reqoverdetction, recunderdetction, reqtoper, uncertainty, typinput, factaccuracy, facttoper, factoverdetction, factunderdetction). \quad (10)$$

Истинность выражения (9) определяется предикатом (11).

$$P(Prpf, Prpt) = (Prpf_{factaccuracy} \geq Prpt_{reqaccuracy}) \wedge (Prpf_{factoverdetction} \leq Prpt_{reqoverdetction}) \wedge (Prpf_{factunderdetction} \leq Prpt_{requnderdetction}) \wedge (Prpf_{facttoper} \leq Prpt_{reqtoper}) \wedge (Prpf_{uncertainty} = Prpt_{uncertainty}) \wedge (Prpf_{typinput} = Prpt_{typinput}), \quad (11)$$

где $Prpf_x, Prpt_x$ – значения соответствующих элементов проекций.

Точки f , чьи проекции удовлетворяют указанным условиям, содержат успешный опыт решения задач, аналогичных текущей задаче, который может быть использован повторно.

5 ПРОЦЕСС НАСТРОЙКИ И ОБУЧЕНИЯ НСК

Цель процесса настройки и обучения НСК – выбор архитектуры и параметров НСК, наилучшим образом обеспечивающих решение поставленной задачи классификации.

Задача подбора и обучения НСК представляет собой задачу оптимизации в следующей постановке:

$$a(x) \rightarrow \max_{x \in SP}, \quad (12)$$

где $a(x)$ – целевая функция, точность классификации как функция параметров НСК (при такой постановке задачи целевая функция должна быть максимизирована);

SP – пространство параметров НСК;

x – точка пространства SP .

В вычислении целевой функции участвует обучение НСК и его тестирование, после чего вычисляется непосредственно точность классификации. Порядок и способ изменения значений свободных параметров задается конкретным применяемым методом оптимизации.

В качестве метода оптимизации может быть выбран любой метод, позволяющий проводить оптимизацию с требуемой точностью функции с числом параметров, соответствующих размерности пространства SP , однако на его реализацию должно быть наложено следующее очевидное ограничение: алгоритм должен изменять только значения параметров группы проектирования. При этом значения параметров *architecture*, *trainingset* и *testingsset* не должны меняться. Кроме того, часть значений параметров вычисляется в процессе обучения НСК (например, веса входов нейронов). Также необходимо заметить, что, т. к. различные архитектуры НСК могут иметь различное число свободных параметров, для сокращения вычислительных затрат возможно применение различных методов оптимизации для различных архитектур.

Процесс настройки и обучения НСК должен быть проведен для каждой из выбранных архитектур. В результате будет получено распределение точности классификации по архитектурам, которое для наглядности может быть изображено в виде гистограммы. Архитектуры, точность классификации для которых превышает заданное значение, могут быть использованы при реализации НСК. Выбор между ними, кроме абсолютного значения достигнутой точности классификатора, может основываться на сравнительном быстродействии соответствующих алгоритмов, различных аспектах их реализации и других критериях.

6 ЭКСПЕРИМЕНТАЛЬНОЕ ИССЛЕДОВАНИЕ ПРЕДЛОЖЕННОЙ СИСТЕМЫ

Предложенная система моделей автоматизированного

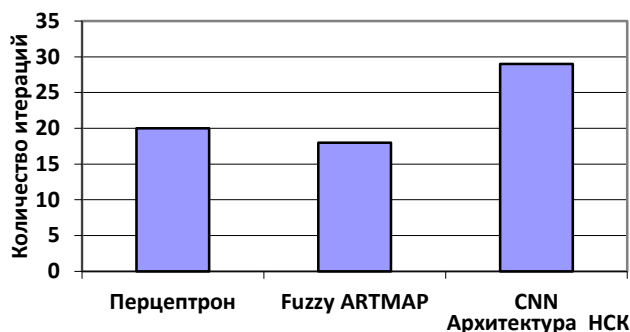


Рис. 1. Распределение количества итераций подбора значений параметров классификатора

проектирования НСК была апробирована в виде специализированной САПР НСК при проектировании НСК дефектов железнодорожных рельсов. Пространство параметров НСК наполнялось на основе имеющихся в распоряжении авторов сведений об опыте разработки различных НСК.

В качестве входных данных для НСК использовались двумерные массивы амплитуд ультразвукового сигнала, характерные для дефектов различных типов. Размер матрицы составил 20×80 элементов. В эксперименте участвовали объекты следующих классов: болтовое отверстие, горизонтальная трещина, вертикальная трещина. Требуемое значение точности распознавания составляло 80%, уровень ложных срабатываний – 5%, уровень пропуска – 0,5%. Время срабатывания – 5 с. Объем обучающей выборки составил 450 элементов (по 150 объектов каждого класса), объем тестовой выборки – 60 элементов (по 20 каждого класса).

В эксперименте в качестве контрольного процесса был взят процесс проектирования этого же НСК проектировщиком без применения специализированной САПР НСК. Проектировщик имел доступ к тому же банку данных по опыту проектирования и применения НСК и в работе использовал Matlab в качестве средства моделирования.

При анализе накопленного опыта проектирования НСК с применением разработанной САПР были выделены два проектных решения, пригодные к повторному применению: в одном случае в качестве НСК выступал перцептрон, в другом – сеть архитектуры Fuzzy ARTMAP. Начальные значения свободных параметров этих архитектур, использованные в процессе настройки и обучения НСК, были установлены в соответствии с данными проектными решениями. Кроме того, проектировщик, основываясь на личном опыте, добавил в эксперимент НСК, основанный на сверточной нейронной сети (CNN). Начальные значения параметров этого НСК были установлены проектировщиком. В качестве метода оптимизации применялся метод градиентного спуска.

Количество подбираемых параметров составило для перцептрона – более 700 000, для сети Fuzzy ARTMAP – более 384 000, для сети CNN – более 1 000 000.

Основные результаты эксперимента показаны на рисунках 1 и 2. На рисунке 1 показано распределение количества итераций подбора значений параметров

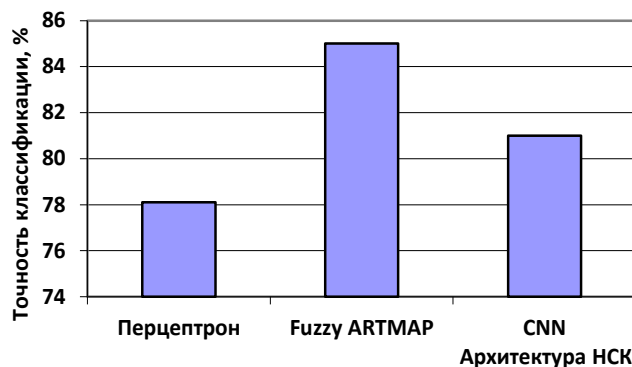


Рис. 2. Распределение достигнутой точности классификации, %

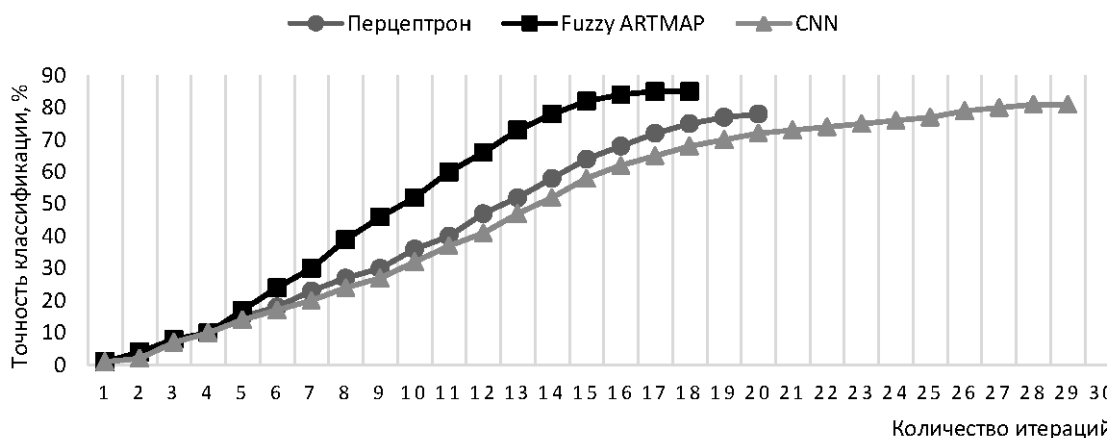


Рис. 3. Зависимость точности классификации для НСК от количества завершенных итераций подбора параметров

классификатора, потребовавшихся для достижения оптимума целевой функции. На рисунке 2 показано распределение достигнутой точности классификации по архитектурам НСК. Видно, что более быстро процесс оптимизации сошелся в случаях, когда начальные значения были заданы на основе опыта. Зависимость точности классификации каждого НСК от количества завершенных итераций цикла подбора параметров показана на рисунке 3.

Из представленных данных видно, что условиям поставленной задачи на проектирование удовлетворяют НСК архитектур Fuzzy ARTMAP и CNN. При этом сеть FuzzyARTMAP показала более высокий уровень точности классификации на представленных тестовых наборах, а процесс ее обучения завершился за меньшее количество итераций.

Аналогичные значения были получены проектировщиком, работавшим без применения САПР НСК. При этом важно, что применение САПР НСК позволило добиться существенного сокращения временных затрат по сравнению с применением существующих средств автоматизации за счет сокращения времени анализа накопленного опыта. Общие временные затраты и их структура показаны в таблице 2.

существенного сокращения времени, затрачиваемого на проектирование, по сравнению с существующими средствами проектирования.

Достоинством предложенной системы моделей является открытость для модификаций: необходимые изменения легко могут быть внесены как в пространство параметров НСК, так и в математическое обеспечение процесса обучения и настройки параметров классификаторов (алгоритмы обучения, методы оптимизации). Такая возможность позволит повышать эффективность предложенных моделей как за счет расширения для целей проектирования НСК в более узких и специфичных областях (например, ультразвуковой дефектоскопии сварных швов), так и за счет более эффективного применения вычислительных методов машинного обучения и оптимизации.

Предложенные методы могут быть расширены в части операций сравнения проекций. Применение для этих целей, вместо классических операций сравнения, интервальных оценок или аппарата нечеткой математики могло бы позволить еще более повысить эффективность процесса проектирования НСК и качество получаемых результатов за счет получения дополнительных проектных решений, пригодных к повторному применению.

Таблица 2

Структура временных затрат на проектирование НСК

	Общее время проектирования, ч	Формулирование задачи, ч	Анализ накопленного опыта, ч	Подбор параметров и обучение, ч
Проектирование без применения САПР НСК	202	8	90	104
Проектирование с применением САПР НСК	173	8	58	107

ЗАКЛЮЧЕНИЕ

Таким образом, предложенная система моделей автоматизированного проектирования НСК показала свою эффективность. Разработанная на ее основе специализированная САПР НСК позволила добиться суще-

Другое направление дальнейшего развития предложенных методов – расширение возможностей работы в условиях неполных данных о значениях эксплуатационных параметров НСК. Внедрение более эффективных средств обработки таких данных также могло бы повысить количество отбираемых проектных решений и приве-

сти к дополнительному повышению качества получаемых результатов и эффективности работы.

СПИСОК ЛИТЕРАТУРЫ

1. Tohka J. SGN-2506: Introduction to Pattern Recognition. Tampere: Tampere University of Technology, 2013. 88 p.

2. Saliba E., Dipanda A. An overview of Pattern Recognition // Wikiprogress.org. – URL : http://www.wikiprogress.org/images/An_overview_of_Pattern_Recognition.pdf (дата доступа: 08.05.2014).

3. Zhang G.P. Neural Networks for Classification: A Survey // IEEE Transactions on Systems, Man and Cybernetics – Part C: Applications and Reviews, Vol. 30, No. 4, November 2000. pp. 451–462.

4. Долинина О.Н. Метод генерации тестов для отладки баз знаний экспертных систем // Программная инженерия. – 2011. – № 5. – С. 40–48.

5. Bettayeb F., Benbartaoui H., Raouraou B. The reliability of the ultrasonic characterization of welds by the artificial neural network // 17th World Conference on Nondestructive Testing, 25–28 Oct. 2008, Shanghai, China. pp. 91–95.

6. Di Martino M., Hernandez G., Fiori M., Rernandez A. A new framework for optimal classifier design // Pattern Recognition, Vol. 46, Is. 8, Aug. 2013. pp. 2249–2255.

7. Yaman S., Chin-Hui L. A Flexible Classifier Design Framework Based on Multiobjective Programming // IEEE/ACM Transactions on Audio, Speech, and Language Processing, Vol. 16, Is. 4, May 2008. pp. 779–789.

8. 2013 Index. IEEE Transactions on Neural Networks and Learning Systems. Vol. 24 // IEEE Transactions on Neural Networks and Learning Systems, Vol. 24, No. 12, Dec. 2013. pp. 2121–2146.

9. Романов Ю.В., Шишкин В.В. Повышение эффективности процесса обеспечения безотказности бортового радиоэлектронного оборудования с использованием информационных технологий // Известия Самарского научного центра РАН. – 2009. – Т. 11, № 3(2) (29). – С. 520–525.

10. Шишкин В.В., Романов Ю.В., Мишин В.А. Повышение эффективности обеспечения безотказной работы бортового радиоэлектронного оборудования // Датчики и системы. – 2010. – № 4. – С. 25–28.

11. Шишкин В.В., Романов Ю.В., Стенюшкин Д.И. Разработка систем FRACAS для бортового оборудования с автоматизированным определением источников систематических отказов // Надежность. – 2013. – № 3 (46). – С. 24–30.

REFERENCES

1. Tohka J. SGN-2506: *Introduction to Pattern Recognition*. Tampere: Tampere University of Technology, 2013. 88 p.

2. Saliba E., Dipanda A. *An overview of Pattern Recognition*. Wikiprogress.org. Available at: http://www.wikiprogress.org/images/An_overview_of_Pattern_Recognition.pdf (accessed: 08.05.2014).

3. Zhang G.P. Neural Networks for Classification: A Survey. *IEEE Transactions on Systems, Man and Cybernetics – Part C: Applications and Reviews*. vol. 30, no. 4, November 2000, pp. 451–462.

4. Dolinina O.N. Metod generatsii testov dlya otladki baz znaniy ekspertnykh system [Test Generation Method to Debugging the Expert-System Knowledge Base]. *Programmnyaya inzheneriya* [Software Engineering], no. 5, 2011, pp. 40–48.

5. Bettayeb F., Benbartaoui H., Raouraou B. The reliability of the ultrasonic characterization of welds by the artificial neural network. *17th World Conference on Nondestructive Testing*, 25–28 Oct. 2008, Shanghai, China, pp. 91–95.

6. Di Martino M., Hernandez G., Fiori M., Rernandez A. A new framework for optimal classifier design. *Pattern Recognition*, vol. 46, Is. 8, Aug. 2013, pp. 2249–2255.

7. Yaman S., Chin-Hui L. A Flexible Classifier Design Framework Based on Multiobjective Programming. *IEEE/ACM Transactions on Audio, Speech, and Language Processing*, vol. 16, Is. 4, May 2008, pp. 779–789.

8. 2013 Index. *IEEE Transactions on Neural Networks and Learning Systems*. Vol. 24. *IEEE Transactions on Neural Networks and Learning Systems*, vol. 24, no. 12, Dec. 2013, pp. 2121–2146.

9. Romanov Yu.V., Shishkin V.V. Povysheniye effektivnosti protsessa obespecheniya bezotkaznosti bortovogo radioelektronnogo oborudovaniya s ispolzovaniyem informatsionnykh tekhnologiy [Effectiveness Increase of Reliability Control Process of Airborne Electronics by Using Information Technologies]. *Izvestiya Samarskogo nauchnogo tsentra RAN* [Proceedings of the Samara Scientific Centre of the Russian Academy of Sciences], 2009, vol. 11, no. 3(2) (29), pp. 520–525.

10. Shishkin V.V., Romanov Yu.V., Mishin V.A. Povysheniye effektivnosti obespecheniya bezotkaznoy raboty bortovogo radioelektronnogo oborudovaniya [Effectiveness Increase of Reliability Control of Airborne Electronics with Automated Identification of Sources of Systematic Failure]. *Datchiki i sistemi* [Sensors and Systems, Journal], 2010, no. 4, pp. 25–28.

11. Shishkin V.V., Romanov Yu.V., Stenyushkin D.I. Razrabotka sistem FRACAS dlya bortovogo oborudovaniya s avtomatizirovannym opredeleniyem istochnikov sistematicheskikh otkazov [Development of FRACAS Systems for Airborne Equipment with Automated Identification of Sources of Systematic Failures]. *Nadezhnost* [Dependability, Scientific-Technical Journal], 2013, no. 3 (46), pp. 24–30.