

ISSN 1816-0301 (Print)  
ISSN 2617-6963 (Online)  
УДК 004 [932.75'1+89]

Поступила в редакцию 15.10.2018  
Received 15.10.2018

Принята к публикации 18.01.2019  
Accepted 18.01.2019

## Экстраполирующее обучение нейронных сетей

Я. А. Бурый, Д. И. Самаль<sup>✉</sup>

Белорусский государственный университет информатики  
и радиоэлектроники, Минск, Беларусь  
<sup>✉</sup>E-mail: samal@bsuir.by

**Аннотация.** Рассматривается способ обучения нейронных сетей, согласно которому знания, содержащиеся в одной сети, используются для обобщения входных сигналов, соответствующих неизвестным ей классам, с целью обучения на них другой нейронной сети с более простой архитектурой.

Исследуется возможность применения реакции выходного сигнала обученной системы распознавания рукописных символов на предъявляемые ей изображения отсутствующих в исходной обучающей выборке символов с целью обобщения и последующей экстраполяции этой реакции в однозначно интерпретируемый выход другой системы в процессе ее обучения распознаванию новых классов.

Подобно тому как человек в процессе познания способен осваивать все более сложные понятия и быстрее обучаться новым знаниям в зависимости от объема уже усвоенной информации, а также сохранять в памяти знания, которые были получены ранее, предлагаемый способ позволяет использовать результат обобщения входного сигнала уже обученной системы для освоения новых знаний за более короткое время, а также повышать ее точность без необходимости повторения всего цикла обучения, а следовательно, без изменения усвоенных прежде знаний.

Представленный способ может применяться для оптимизации процесса обучения систем распознавания, увеличения точности уже обученных систем, а также для переобучения или дообучения их распознаванию новых классов без необходимости повторного обучения на исходном обучающем множестве.

**Ключевые слова:** нейронные сети, нейронная сеть свертки, распознавание изображений, распознавание символов, обучение нейронных сетей

**Для цитирования.** Бурый, Я. А. Экстраполирующее обучение нейронных сетей / Я. А. Бурый, Д. И. Самаль // Информатика. – 2019. – Т. 16, № 1. – С. 86–92.

---

## Extrapolating training of neural networks

Yaraslau A. Bury, Dmitry I. Samal<sup>✉</sup>

Belarusian State University of Informatics and Radioelectronics, Minsk, Belarus  
<sup>✉</sup>E-mail: samal@bsuir.by

**Abstract.** An approach for training neural networks is presented. The point is the knowledge contained in one network are used to generalize the input signals that are corresponded to classes what are unknown to it, in order to train them by another neural network with a simpler architecture.

The paper observes the possibility of using the output signal of a trained handwriting recognition system on the images what are presented to it and which are absent in the original training set of symbols. This training process is performing in order to generalize and then extrapolate the reaction to the uniquely interpreted output of another system during its training to those unknown classes.

Like a person in the process of studying what is able to perceive more and more complex concepts and learn new knowledge faster depending on already acquired information, as well as when learning new data – to keep in memory those that were obtained earlier, the approach allows us to use the result of input signal generalization from already trained system in the aim to perceive of new knowledge in a shorter time. Also it allows increasing

the accuracy of the recognition process without a necessity to repeat the entire training cycle, and therefore – without changing the previously acquired knowledge in the net.

The presented approach can be used to optimize the training process of recognition systems, increase the accuracy of already trained systems, and also to retrain or additional training them to new classes without the need to retrain the original training set.

**Keywords:** neural networks, convolutional neural network, character recognition, image recognition, neural networks training

**For citation.** Bury Y. A., Samal D. I. Extrapolating training of neural networks. *Informatics*, 2019, vol. 16, no. 1, pp. 86–92 (in Russian).

**Введение.** Подавляющее большинство известных на сегодняшний день алгоритмов обучения искусственных нейронных сетей направлено на модификацию внутренних параметров непосредственно обучаемой системы. При этом под обучением подразумевается процесс, в котором упомянутые параметры нейронной сети настраиваются посредством моделирования среды, в которой эта сеть функционирует. Тип обучения определяется способом подстройки этих параметров. Соответственно, само «обучение нейронной сети происходит посредством интерактивного процесса корректировки синаптических весов и порогов. В идеальном случае нейронная сеть получает знания об окружающей среде на каждой итерации процесса обучения» [1].

Следует отметить, что при условии существования подобной концепции обучения в живой природе как единственной и безальтернативной получение новых знаний биосистемой подразумевало бы необходимость полного цикла перенастройки весовых коэффициентов всякий раз, когда возникает необходимость в обучении новым данным. Это значит, что подобный механизм обучения живых существ чему-то принципиально новому должен занимать время, сопоставимое с тем, что затрачено на освоенные ранее паттерны поведения. Однако в реальности наблюдается несколько иная картина: в процессе обучения новому человек активно использует уже имеющиеся знания, что позволяет ему обучаться тем быстрее, чем более он осведомлен в области изучаемого явления. Например, музыканту значительно легче освоить новый прием игры на своем музыкальном инструменте, нежели тому, кто никогда к нему не прикасался. Также ребенок долго осваивает звуки речи, но, будучи им обучен, без труда и в скором времени способен к воспроизведению нового звука из другого языка, предъявленного ему впервые. В известной работе [2] отмечено, что «младенцы учатся относительно медленно, но затем способность к обучению постепенно “раскручивается”, и мы с вами осваиваем новое гораздо более эффективно, чем имеющиеся у нас данные позволили бы, например, современным архитектурам нейронных сетей». Нечто подобное можно наблюдать и в животном мире.

При проектировании обучающейся системы одним из ее важнейших параметров, имеющих значение с точки зрения применения на практике, является способность к обобщению поступающей на вход информации. «Под термином *обобщение* понимается способность получать обоснованный результат на основании данных, которые не встречались в процессе обучения» [1].

Искусственный интеллект или в рассматриваемом случае всего лишь его отдельная «подсистема» в виде конкретной нейросетевой структуры в любом случае «...опирается на биологические основы естественного интеллекта и пытается в той или иной мере моделировать мыслительные процессы живых существ» [3]. Исходя из того что естественные биосистемы способны производить эффективную реакцию в условиях незнакомой среды, а после процесса обучения быстрее осваивать новые знания, логично предположить существование наряду с интерполирующим способом, возникшим в процессе эволюции, экстраполирующего способа обучения в биологических нейронных сетях. Теоретически, особенно в больших базах знаний, это могло бы способствовать ускорению итогового процесса обучения ввиду того, что первичный обучающий этап мог бы происходить значительно реже, вплоть до одного раза.

**Постановка задачи.** Если обратить внимание на информацию, содержащуюся в «сыром» выходном сигнале нейронной сети при использовании классического позиционного кодирования, то этот выход фактически представляет собой вектор обратных значений к расстояниям до центров

известных ей кластеров и выражает некоторые относительные степени близости поданного на вход изображения к символам алфавита, которым обучена нейронная сеть.

Для определения целочисленного значения адреса в множестве  $N$  кластеров достаточно  $\log_2 N$  бит выходного сигнала системы распознавания, однако при позиционном кодировании, даже если значения выходов нейронов биполярны, в совокупном выходном сигнале системы уже будет содержаться значительно большее количество информации, равное  $N$  бит. Если же выходы системы распознавания представлены числами с плавающей запятой двойной точности, то количество информации, представленное совокупным выходом нейронной сети, равняется  $N \cdot 64$  бит (для формата типа *double*), что уже на порядок превышает необходимое количество информации для обеспечения возможности адресации классов распознаваемых образов.

Известно, что мозг разделен на функциональные, связанные между собой зоны, которые состоят из различных по структурам нейронных сетей. При этом в разных структурах хранится и обрабатывается разная информация [3]. Таким образом, гипотеза, подвергаемая исследованию в настоящей работе, может быть сформулирована следующим образом: в выходном сигнале нейронной сети, обученной распознавать символы алфавита  $A$  (условно называемой далее интерполятором), при предъявлении ей символов другого алфавита  $B$ , схожих по природе с представлениями символов алфавита  $A$ , будет содержаться избыточное количество полезной информации, которую можно однозначно интерпретировать в целях распознавания символов алфавита  $B$  без существенной потери точности с помощью другой нейронной сети (условно называемой далее экстраполятором). Следует отметить, что термин «экстраполирующая нейронная сеть» в данном случае не привязан к конкретным методам экстраполяции, используемым в прогнозировании, математической статистике и т. д. В рамках представленной статьи термины «экстраполятор» и «интерполятор» применительно к связке нейронных сетей являются абстрактными понятиями.

**Описание модели.** В качестве интерполятора была выбрана нейронная сеть свертки глубокого обучения с двумя сверточными слоями по 20 и 50 карт признаков, размером рецептивного поля  $5 \times 5$  нейронов и линейной функцией активации, двумя слоями подвыборки с размером рецептивного поля  $2 \times 2$  и двумя полносвязными слоями: одним, состоящим из 500 нейронов с полупериодической функцией активации, и вторым – из 50 нейронов с линейной функцией активации, которые являются выходом интерполятора. Размерность входного сигнала интерполятора –  $28 \times 28$ . Таким образом, сеть состояла из 18 950 нейронов и насчитывала 2 327 720 связей. Данная архитектура позволила достичь регулярной точности распознавания, близкой к 100 %, в серии экспериментов на обучающем множестве рукописных символов базы изображений MNIST [4].

Дополнительные классы образов – это исходные изображения символов обучающего множества, модифицированные в соответствии с единой заданной комбинацией преобразований. Обязательным условием возникновения нового дополнительного класса образов являлась его уникальность и очевидная несхожесть с другими классами, т. е. другими символами алфавита. В проведенной серии экспериментов в качестве упомянутых преобразований использовались комбинации функций зеркального отображения (относительно вертикальной оси) и поворота (на  $90$ ,  $180$  и  $270^\circ$ ).

Экстраполирующая нейронная сеть имела 50 входов и более простую структуру, включающую два полносвязных слоя: входной из 19 400 нейронов и выходной из 10 нейронов с линейной функцией активации. Сеть содержала 19 410 нейронов и 1 164 000 связей. Архитектура экстраполирующей нейронной сети была подобрана таким образом, чтобы количество связей в ней было меньше, чем у интерполирующей сети, примерно в целое количество раз (в данном случае – в два раза) для упрощения оценки разницы времени их обучения (рис. 1).

Обучение обеих нейронных сетей проводилось методом обратного распространения ошибки. Для этого было выбрано средство создания и обучения сверточных нейронных сетей глубокого обучения – фреймворк Caffe (URL: <http://caffe.berkeleyvision.org>), поддерживающий вычисления на GPU, а также алгоритмы стохастического градиентного спуска и пакетного обучения для ускорения вычислений.

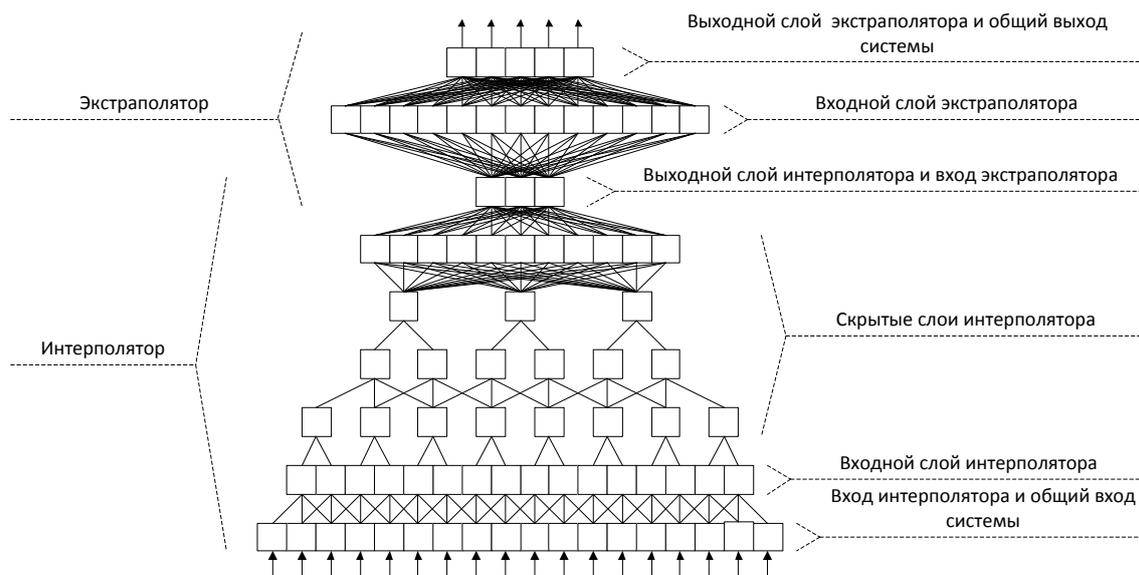


Рис. 1. Схематическое описание системы экстраполирующего обучения нейронной сети

**Результаты экспериментов.** Как уже упоминалось выше, для проверки исследуемой гипотезы была выбрана база изображений рукописных символов MNIST, которая де-факто является стандартным средством проверки алгоритмов распознавания и насчитывает 60 000 обучающих и 10 000 тестовых изображений. В серии более чем из 100 экспериментов для обучения интерполятора из обучающего множества выбирались различные комбинации классов в количестве от 2 до 9 с добавлением дополнительных классов, а также без их добавления (примеры отдельных комбинаций приведены в первом столбце табл. 1). На следующем шаге, после обучения интерполятора, проводилось обучение экстраполятора уже на всем исходном обучающем множестве: при предъявлении изображений обучающей выборки на вход интерполятора его «сырой» выход, полученный в результате прямого прохождения сигнала, предъявлялся на вход экстраполятора с последующим его обучением на соответствующее значение выхода, определенное номером символа исходного обучающего множества. При этом все остальные параметры обучения, кроме тех, которые определяют структуру нейронной сети, устанавливались одинаковыми для обеих сетей.

Таблица 1

Результаты обучения интерполятора

№	Базовые символы обучающей выборки	Наличие дополнительных символов в обучающей выборке	Количество изображений символов обучающей выборки	Среднеквадратическая ошибка на обучающей выборке	Точность на обучающей выборке, %	Среднеквадратическая ошибка на тестовой выборке	Точность на тестовой выборке, %
1	0, 1	есть	19 407	0,0020	99,99	0,0035	99,97
2	0, 1, 2	есть	43 239	0,0091	99,79	0,0140	99,51
3	0, 1, 2, 3	есть	67 763	0,0070	99,87	0,0127	99,60
4	0, 1, 2, 3, 4	есть	114 499	0,0208	98,91	0,0250	98,42
5	0, 1, 2, 3, 4, 5	есть	136 183	0,0238	98,59	0,0266	98,23
6	0, 1, 2, 3, 4, 5, 6	есть	148 019	0,0229	98,68	0,0273	98,14
7	0, 1, 2, 3, 4, 5, 6, 7	есть	173 079	0,0252	98,41	0,0298	97,78
8	0, 1, 2, 3, 4, 5, 6, 7, 8	есть	184 781	0,0254	98,39	0,0300	97,74
9	0, 1	нет	12 665	0,0018	99,99	0,0043	99,95
10	0, 1, 2	нет	18 623	0,0163	99,33	0,0133	99,56
11	0, 1, 2, 3	нет	24 754	0,0097	99,77	0,0116	99,66
12	0, 1, 2, 3, 4	нет	30 596	0,0020	99,99	0,0084	99,82
13	0, 1, 2, 3, 4, 5	нет	36 017	0,0030	99,98	0,0131	99,57
14	0, 1, 2, 3, 4, 5, 6	нет	41 935	0,0017	99,99	0,0155	99,40
15	0, 1, 2, 3, 4, 5, 6, 7	нет	48 200	0,0068	99,88	0,0185	99,14
16	0, 1, 2, 3, 4, 5, 6, 7, 8	нет	54 051	0,0037	99,96	0,0175	99,23

Количество итераций обучения в данной серии экспериментов для обеих нейронных сетей составляло 20 000 при размере обучающего пакета в 100 изображений независимо от количества символов в обучающих выборках при коэффициенте скорости обучения, равном 0,01.

В табл. 1 и 2 приведены результаты одного из срезов серии экспериментов, в котором символы для обучения интерполятора выбраны из списка всех символов обучающей базы, отсортированных в алфавитном порядке. В обеих таблицах одинаковые номера строк соответствуют одному и тому же эксперименту. Эксперименты оценивались в соответствии с работой [5].

Таблица 2

Результаты обучения экстраполятора

№	Среднеквадратическая ошибка на обучающей выборке			Точность на обучающей выборке, %			Среднеквадратическая ошибка на тестовой выборке			Точность на тестовой выборке, %		
	Все символы	Интерполированные символы	Экстраполируемые символы	Все символы	Интерполированные символы	Экстраполируемые символы	Все символы	Интерполированные символы	Экстраполируемые символы	Все символы	Интерполированные символы	Экстраполируемые символы
1	0,3029	0,1298	0,3140	54,00	91,46	44,54	0,2981	0,1157	0,3063	55,43	93,30	46,31
2	0,1565	0,0871	0,1710	87,38	96,32	85,01	0,1546	0,0844	0,1700	88,72	96,62	85,34
3	0,1099	0,0693	0,1277	93,94	97,39	91,51	0,1084	0,0630	0,1279	94,11	97,80	91,46
4	0,0856	0,0619	0,1030	96,33	97,94	94,63	0,0867	0,0594	0,1074	96,22	98,16	94,16
5	0,0712	0,0556	0,0852	97,46	98,30	96,18	0,0711	0,0514	0,0904	97,46	98,56	95,77
6	0,0691	0,0513	0,0953	97,60	98,62	95,45	0,0702	0,0540	0,0954	97,54	98,45	95,40
7	0,0565	0,0463	0,0833	98,56	98,96	96,89	0,0589	0,0495	0,0850	98,41	98,80	96,78
8	0,0430	0,0364	0,0763	99,12	99,29	97,55	0,0510	0,0448	0,0821	98,85	99,02	97,22
9	0,3320	0,1392	0,3476	44,73	90,21	32,80	0,3323	0,1274	0,3469	44,65	91,85	32,68
10	0,2309	0,1298	0,2337	73,26	89,99	66,31	0,2286	0,1228	0,2340	73,78	90,62	66,74
11	0,1708	0,0998	0,1901	85,38	94,17	79,45	0,1658	0,0971	0,1854	86,20	94,54	80,60
12	0,1255	0,0745	0,1546	92,11	96,73	87,24	0,1233	0,0730	0,1533	92,39	96,94	87,46
13	0,1098	0,0689	0,1399	93,96	97,32	89,01	0,1077	0,0716	0,1350	94,20	97,15	89,74
14	0,0925	0,0570	0,1340	95,71	98,12	90,20	0,0944	0,0658	0,1314	95,54	97,65	90,62
15	0,0660	0,0463	0,1108	97,82	98,78	93,84	0,0701	0,0563	0,1066	97,54	98,32	94,31
16	0,0437	0,0297	0,0873	99,05	99,35	96,18	0,0600	0,0529	0,0944	98,20	98,48	95,54

На рис. 2 графически представлены результаты обучения, полученные на тестовых выборках. Из графиков видно, что при увеличении общего количества символов в обучающей выборке с добавлением дополнительных символов достигаемая среднеквадратическая ошибка интерполятора ожидаемо несколько вырастает с соответствующим падением точности (линии *a* и *e* на рис. 2 соответственно). Это связано с тем, что рукописные символы, содержащиеся в базе MNIST, могут быть начертаны с наклонами и небольшими поворотами, приводящими к некоторой неоднозначности при отнесении таких изображений (как исходных, так и дополнительных, полученных на их основе) к тому или иному классу. При этом точность экстраполятора, наоборот, возрастает (линии *d* и *k* на рис. 2) и добавление дополнительных символов сказывается лучшим образом на его точности, что подтверждает изначальное предположение о зависимости итоговой точности экстраполятора от количества информации, содержащейся в интерполяторе.

Следует отметить, что остается открытым вопрос изучения зависимости «информационных емкостей» экстраполирующей и интерполирующей сетей для обеспечения стабильных результатов распознавания всей системы, который является темой дополнительного экспериментального изучения и будет освещен в последующих публикациях.

Несмотря на то что среднеквадратическая ошибка экстраполятора в каждом опыте при одинаковых параметрах процесса обучения стремится к соответствующей ошибке, полученной на интерполяторе, но не достигает ее, точность распознавания экстраполятора на символах, уже известных интерполятору, в какой-то момент начинает превышать точность интерполятора, что говорит о возможности повышения качества распознавания уже обученных систем путем экстра-

поляции содержащихся в них данных на эти же самые данные, так как экстраполятор опосредованно увеличивает общую глубину системы распознавания.

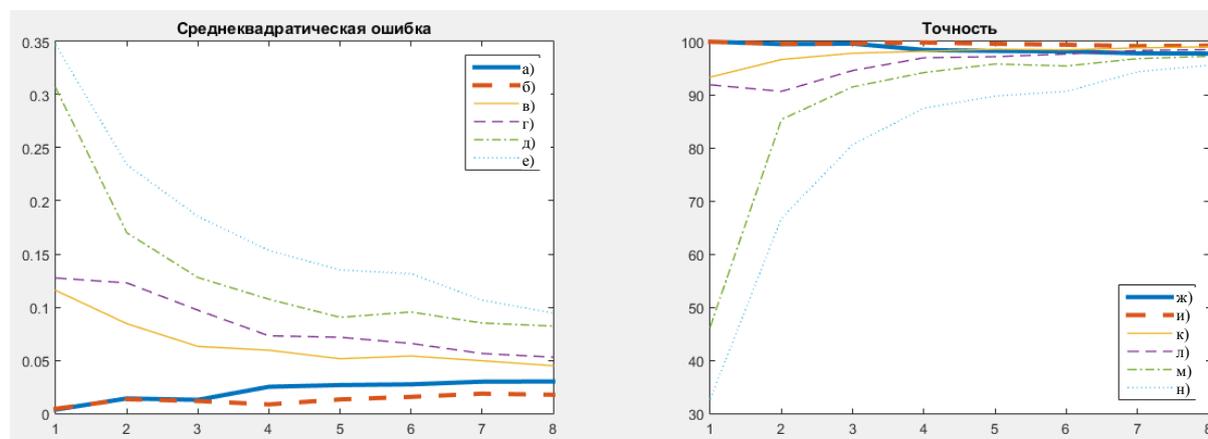


Рис. 2. Графическое представление результатов обучения, полученных на тестовых множествах изображений:

*a* – ошибка интерполятора, обученного с добавлением дополнительных символов; *b* – ошибка интерполятора, обученного без добавления дополнительных символов; *в* – ошибка экстраполятора на символах, известных интерполятору, обученному с добавлением дополнительных символов; *г* – ошибка экстраполятора на символах, известных интерполятору, обученному без добавления дополнительных символов; *д* – ошибка экстраполятора на символах, неизвестных интерполятору, обученному с добавлением дополнительных символов; *e* – ошибка экстраполятора на символах, неизвестных интерполятору, обученному без добавления дополнительных символов; *ж* – точность интерполятора, обученного с добавлением дополнительных символов; *и* – точность интерполятора, обученного без добавления дополнительных символов; *к* – точность экстраполятора на символах, известных интерполятору, обученному с добавлением дополнительных символов; *л* – точность экстраполятора на символах, известных интерполятору, обученному без добавления дополнительных символов; *м* – точность экстраполятора на символах, неизвестных интерполятору, обученному с добавлением дополнительных символов; *н* – точность экстраполятора на символах, неизвестных интерполятору, обученному без добавления дополнительных символов

Точность распознавания экстраполятора на символах, которые неизвестны интерполятору, с увеличением количества символов в обучающей выборке последнего также растет, однако не так быстро, как точность на известных символах, и в данном срезе серии достигает 97,55 и 97,22 % на обучающей и тестовой выборках соответственно. Однако эти значения не являются максимально достижимыми и вследствие стохастической природы процесса обучения варьируются от серии к серии даже на одних и тех же данных. Наивысшая точность, превышающая 98–99 %, на практике достижима при индивидуальном подходе к настройке параметров обучения отдельно для интерполятора и экстраполятора под конкретное множество изображений.

При заданных входных характеристиках системы время обучения интерполятора в среднем составило 440 с, а экстраполятора – 270 с на двух GPU-устройствах NVIDIA GeForce GT 650M. Отношение времени их обучения равно 1,63, что несколько меньше двух (отношения количества связей). Это связано с тем, что время обучения, кроме непосредственно расчетов, уходит также на операции обмена данными с GPU, которые имеют длительные дополнительные задержки, независимые от объемов пересылаемых данных.

**Заключение.** Полученные в ходе экспериментов результаты говорят об однозначном подтверждении исследуемой гипотезы и раскрывают возможные области применения экстраполирующего обучения нейронных сетей. Так как достижимая точность экстраполятора пропорциональна количеству информации, содержащейся в интерполяторе, представленный подход лучше подходит для оптимизации процесса обучения именно применительно к системам, обучаемым распознаванию большого количества классов, таких как изображения иероглифов, человеческих лиц, отпечатков пальцев и т. п. Он также будет полезен при необходимости увеличения точности распознавания или обучения распознаванию новых классов, когда переобучение и дообучение системы распознавания недоступны (например, если система поставляется в виде уже обученного модуля). В частности, исходная система, единожды обученная распознаванию десятков тысяч человеческих лиц, может быть использована в целях дообучения других систем распознавания под конкретные задачи, где количество лиц составляет

десятки или сотни, в рамках конструирования систем идентификации личности. Такое экстраполирующее обучение будет занимать намного меньше времени по сравнению с обучением исходной системы. Для особо сложных задач можно для обучения экстраполятора агрегировать выходную реакцию нескольких интерполяторов, а также создавать многоступенчатые иерархии экстраполирующих структур.

### Список использованных источников

1. Хайкин, С. Нейронные сети. Полный курс / С. Хайкин. – М., СПб., Киев : Вильямс, 2006. – 1104 с.
2. Николенко, С. Глубокое обучение. Погружение в мир нейронных сетей / С. Николенко, А. Кадурин, Е. Архангельская. – СПб. : Питер, 2018. – 480 с.
3. Головкин, В. А. Нейронные сети: обучение, организация и применение. Кн. 4 / В. А. Головкин ; под ред. А. И. Галушкина. – М. : ИПРЖР, 2001. – 256 с.
4. База изображений «The MNIST database of handwritten digits» [Электронный ресурс]. – Режим доступа: <http://yann.lecun.com/exdb/mnist>. – Дата доступа: 12.09.2018.
5. Монтгомери, Д. К. Планирование эксперимента и анализ данных : сокр. пер. с англ. В. А. Коптяева / Д. К. Монтгомери. – Л. : Судостроение, 1980. – 384 с.

### References

1. Haykin S. Neyronnyye seti. Polnyy kurs. *Neural Networks. Full Course*. Moscow, Saint Petersburg, Kiev, Vil'jams, 2006, 1104 p. (in Russian).
2. Nikolenko S., Kadurin A., Arhangel'skaja E. Glubokoye obucheniye. Pogruzheniye v mir neyronnykh setey. *Deep Learning. Immersion in the World of Neural Networks*. Saint Petersburg, Piter, 2018, 480 p. (in Russian).
3. Golovko V. A. Neyronnyye seti: obucheniye, organizatsiya i primeneniye. *Neural Networks: Training, Organization and Application*. Moscow, IPRZhR, 2001, 256 p. (in Russian).
4. Baza izobrazhenij "The MNIST database of handwritten digits". *Images dataset "The MNIST database of handwritten digits"*. Available at: <http://yann.lecun.com/exdb/mnist/> (accessed 12.09.2018).
5. Montgomeri D. K. Design and Analysis of Experiments. 9th edition. New York, John Wiley & Sons, Inc., 2017, 640 p.

### Информация об авторах

Бурый Ярослав Анатольевич, ассистент кафедры электронно-вычислительных машин, Белорусский государственный университет информатики и радиоэлектроники, Минск, Беларусь.  
E-mail: edidici@tut.by

Самаль Дмитрий Иванович, кандидат технических наук, доцент, доцент кафедры электронных вычислительных машин, Белорусский государственный университет информатики и радиоэлектроники, Минск, Беларусь.  
E-mail: samal@bsuir.by

### Information about the authors

Yaraslau A. Bury, Assistant of the Department of Electronic Computing Machines, Belarusian State University of Informatics and Radioelectronics, Minsk, Belarus.  
Email: edidici@tut.by

Dmitry I. Samal, Cand. Sci. (Eng.), Assoc. Prof. of the Department of Electronic Computing Machines, Belarusian State University of Informatics and Radioelectronics, Minsk, Belarus.  
Email: samal@bsuir.by