

УДК 519.764

К. Р. Ахметзянов, А. А. Южаков

Пермский национальный исследовательский политехнический университет

## Оптимизация архитектуры нейронной сети для сортировки групп мусора

*Представлены результаты проведенных экспериментов по разработке нейронной сети для классификации пластиковых бутылок и алюминиевых банок. Нейронная сеть является частью умного контейнера – устройства для автоматизированного сбора и сортировки мусора. Этот контейнер состоит из трех емкостей (для сбора бутылок, банок и прочего), исполнительного механизма сортировки и микрокомпьютера RaspberryPi. При разработке нейронной сети необходимо учитывать ограничения вычислительных мощностей этого микрокомпьютера с высокой скоростью обработки изображений при любых углах наклона предмета и любых расстояниях до предмета. Также нейронная сеть должна правильно классифицировать мятые бутылки и банки. В статье представлены результаты ранее проведенных экспериментов по выбору нейронной сети среди AlexNet, SqueezeNet и MobileNet. Наибольшей точности достигла нейронная сеть MobileNet. Однако недостатком этой нейронной сети является необходимость создания большой обучающей выборки для точного распознавания мятых бутылок и банок. На создание такой обучающей выборки со всеми возможными вариантами мятостей потребовалось бы огромное количество времени. В статье приводится описание оригинальной идеи нейронной сети, а также поиска оптимальной архитектуры этой нейронной сети как ручным перебором, так и автоматически.*

### Классификация объектов, нейронные сети, сверточные нейронные сети, глубокое обучение, компьютерное зрение, сортировка отходов, RaspberryPi

Экологическая проблема в России безусловно актуальна. Ежегодно в нашей стране на полигонах скапливается 6.3 млрд т пластика, из них 1.5 тыс. т пластиковых бутылок [1]. Необходимо перерабатывать этот пластик, а не накапливать его. На заводах по переработке пластика его переплавляют. Температура плавления у каждого вида пластика своя, поэтому важно еще на этапе сбора мусора его рассортировать. Предлагается создание «умного» контейнера, который будет предварительно сортировать пластиковые бутылки, алюминиевые банки и прочий мусор в различные емкости. Этот контейнер должен удовлетворять следующим требованиям: быть дешевым и проводить сортировку в режиме реального времени (время принятия решения на сортировку одного предмета менее 1 с). «Умный» контейнер состоит из исполнительных механизмов сортировки, трех емкостей для мусора, микрокомпьютера RaspberryPi [2], который будет обрабатывать входную информацию (изображения), и устройства для получения информации (веб-камера).

В качестве математического аппарата обработки информации были выбраны сверточные нейронные сети, так как они показывают хорошие результаты классификации изображений [3].

**Предварительный эксперимент по выбору нейронных сетей.** При эксперименте проводилось обучение нескольких сверточных сетей [4]: AlexNet [3], SqueezeNet [5] и MobileNet [6]. Эти сети были выбраны из-за ограничений по вычислительным ресурсам микрокомпьютера RaspberryPi. Их обучение проводилось на выборке, состоящей из фотографий 500 банок, 500 бутылок и 10 000 прочих предметов. Проверка на выборке, состоящей из фотографий 150 банок, 150 бутылок и 2000 прочих предметов, показала, что все три сети достигают примерно одной и той же точности распознавания – 98 %. Для выбора только одной архитектуры нейронной сети была проведена дополнительная проверка на небольшой выборке, состоящей из фотографий 10 банок, столько же бутылок и прочих предметов. Наибольшую точность на этой выборке показала сверточная сеть MobileNet (93 %). Дальнейшие эксперименты проводились именно для нее.

В ходе эксперимента выявлено, что выборки нерепрезентативны, так как при проверке в режиме онлайн с помощью веб-камеры сверточная сеть неправильно классифицирует предметы, которые расположены не вертикально, далеко от камеры, освещены мерцающей лампой. Для уве-

личения точности распознавания сети MobileNet были проведены дополнительные эксперименты по увеличению обучающей выборки в два раза посредством добавления в выборку измененных исходных изображений [7] (такая технология увеличения данных называется data augmentation [8]–[10]). С исходными изображениями проводились следующие преобразования: поворот, отражение по горизонтали (horizontal flipping), гауссовский шум, отступ (padding), удаление части изображения (erasing), вырезание части изображения (cropping), масштабирование (scale). При повороте на случайный угол от  $-60^\circ$  до  $60^\circ$  достигнута точность 78 %, при гауссовском шуме – 66 %, при отступе – 73 %, удалении части изображения – 66 %, вырезании части изображения – 72 %, масштабировании – 71 %. Самую высокую точность дал поворот на случайный угол от  $-60^\circ$  до  $60^\circ$  (78 %). Однако даже при обучении сверточной нейронной сети на такой увеличенной выборке нейронная сеть неспособна правильно классифицировать предметы с различными геометрическими изменениями (мятостями). Также к недостаткам сверточных сетей можно отнести необходимость большой обучающей выборки для точного распознавания.

Дальнейшие исследования были направлены на разработку сети, которая бы устраняла означенные недостатки. Обучение и проверка разрабатываемых сетей проводились на других выборках, которые будут описаны далее.

#### **Описание обучающей и тестовой выборки.**

Новая обучающая выборка состоит из фотографий 700 бутылок и 700 банок, снятых на одном и том же фоне, а также 6000 фотографий прочих предметов. Бутылки и банки сфотографированы в разных ракурсах, и в новой обучающей выборке присутствуют как ровные, так и мятые бутылки и банки.

Для новой тестовой выборки сделаны фотографии с различным уровнем освещения, фона, наклона и расстояния до бутылок и банок. Новая тестовая выборка состоит из фотографий 800 банок, 800 бутылок, 100 прочих предметов.

Дальнейшие эксперименты проводились для этих новых выборок.

На новой проверочной выборке обученная нейронная сеть MobileNet достигает точности распознавания 20.67 %.

**Подход к построению оригинальной нейронной сети.** Недостатком существующих нейронных сетей является необходимость большого ко-

личества данных для обучения. В частности, для классификации с помощью нейронной сети геометрически деформированных предметов (например, мятых бутылок и банок) необходимо сделать фотографии этих бутылок и банок со всеми возможными видами мятости, для чего потребуется большое количество времени. Поэтому требуется разработать иной подход и взгляд на процесс обучения нейронной сети.

Для создания этого нового подхода была разработана концепция эйдетического искусственного интеллекта, которая заключается в изучении процесса познания окружающего мира.

Сверточная нейронная сеть оперирует двумя каналами восприятия окружающей среды – формой и цветом. Разрабатываемая концепция подразумевает использование третьего канала: соотношения данного предмета с окружающим миром (место этого предмета). При переходе от концепции к созданию нейронной сети третий канал появляется при поиске взаимосвязей между соседними кадрами во время видеосъемки выбранного предмета. Научная проблема заключается в поиске архитектуры нейронной сети и нейрона для решения описанной задачи. Как показывают проведенные эксперименты, сверточная нейронная сеть не справляется с этой проблемой.

Разработанная оригинальная нейронная сеть состоит из двух частей – сверточной и рекуррентной нейронных сетей. В качестве сверточной части нейронной сети была взята сеть AlexNet, так как она состоит из небольшого количества сверточных слоев и с ней легко проводить эксперименты по модификации нейронной сети. В качестве рекуррентной нейронной сети была взята сеть LSTM [11]. Проверка обученной нейронной сети показала, что предлагаемая нейронная сеть способна правильно классифицировать предметы только на том же фоне, что и в обучающей выборке.

В дальнейшем разрабатываемая нейронная сеть была модифицирована и ее сверточная часть была разделена на две ветви, после которых был поставлен блок абсолютной разности, т. е. сеть была построена в концепции сямской сети [12] (технология one-shot learning [13]). Реализация сети в этой концепции позволяет векторам изображений, получаемых на выходе сети, группироваться в некоей области пространства (векторы одного класса предметов) и расходиться как можно

дальше (векторы разных классов предметов). Проверка такой сети показала, что она способна правильно классифицировать предметы на разных фонах, но появляется дополнительное требование к сети – хорошее освещение распознаваемого предмета. Для обучения предлагаемой нейронной сети требуется меньшее количество данных, хотя она все же не способна правильно классифицировать мятые бутылки и банки.

На рис. 1 изображена общая схема предлагаемой нейронной сети.

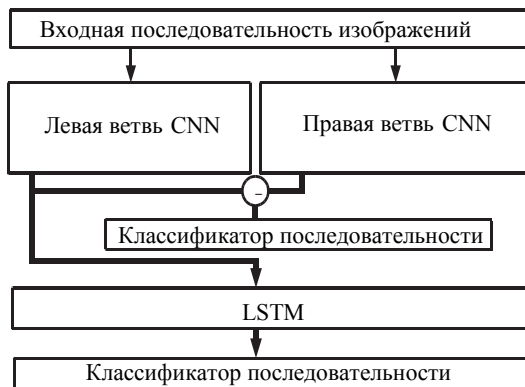


Рис. 1

На рис. 2 представлена изначальная архитектура AlexNet, на рис. 3 – ее облегченная версия, у которой два последних полносвязных слоя (по 4096 выходных нейронов в каждом) заменены на сверточный слой (размер свертки  $1 \times 1$ , количество фильтров 1024), следом за которым идет полносвязный слой (количество нейронов 256). Такая облегченная версия нейронной сети уменьшает количество параметров (а следовательно, количество потребляемой памяти), и при этом точность распознавания остается такой же.

Пояснения к обозначениям на рис. 2 и 3: data – входные данные (трехканальные изображения размером  $224 \times 224$  пикс., нейронная сеть работает с тензорами, поэтому данные имеют три измерения (глубина, высота и ширина)); числа рядом со стрелками – глубина тензора, ширина и высота; conv – сверточный слой (глубина тензора – количество фильтров сверточного слоя); relu – функция активации; norm – нормализации по порциям данных (batch), на которых обучается нейронная сеть (используется для увеличения точности распознавания); pool – группирование по максимуму (max pooling) (используется для уменьшения размерности тензора и увеличения робастности нейронной сети); fc – полносвязный слой.

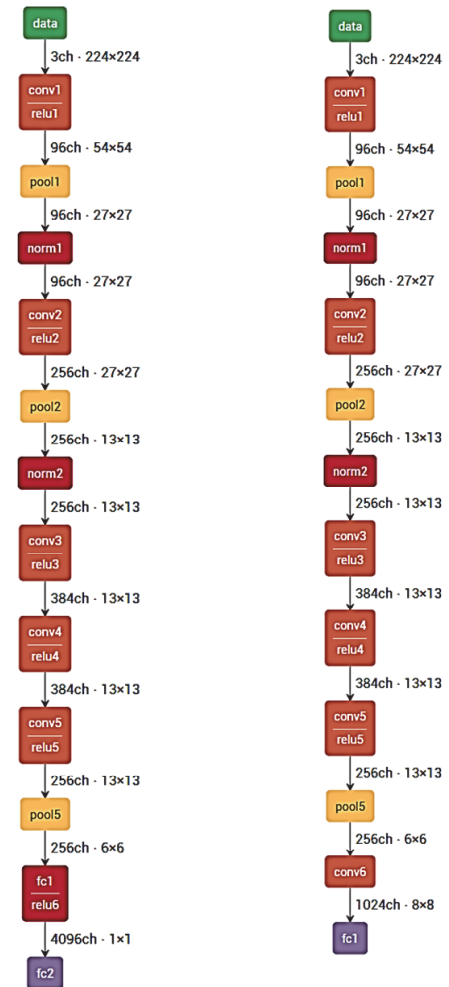


Рис. 2

Рис. 3

Левая и правая ветвь сверточной нейронной сети (рис. 1) состоит из сетей, архитектура которых изображена на рис. 3. Вектор, получаемый после полносвязного слоя fc1, подается в нейронную сеть LSTM.

**Автоматический поиск модифицированной архитектуры.** Гиперпараметрическая оптимизация проводилась по следующим параметрам: алгоритм оптимизации нейронной сети (SGD, Adam, Rmsprop), скорость обучения (от 0 до 1), количество фильтров в первом сверточном слое (от 48 до 184), во втором (от 128 до 512), в третьем (от 192 до 768), в четвертом (от 192 до 768), в пятом (от 128 до 512), в шестом (от 512 до 2048).

После проведения эксперимента по автоматическому поиску гиперпараметров для своей нейронной сети были получены следующие параметры. В качестве оптимального оптимизатора нейронной сети выбран SGD (метод наискорейшего градиентного спуска) со скоростью обучения 0.467. В первой свертке содержится 96 фильтров, во второй – 128, в третьей – 288, в четвертой – 576,

Таблица 1

Название эксперимента	Номер архитектуры	Номер эпохи максимума	Максимум точности	Потребляемая память, Мбайт	Количество параметров
Уменьшение сети	1	4	0.065	71.680	6 634 500
	2	3	0.076	104.448	15 350 788
	3	3	0.065	122.880	20 003 588
	4	3	0.062	117.760	18 676 100
	5	4	0.066	93.184	12 253 188
	6	5	0.072	93.184	12 252 164
	7	–	–	–	52 556 804
	8	5	0.059	121.856	19 829 508
	9	–	–	–	19 829 124
	10	–	–	–	77 631 876

Таблица 2

Название эксперимента	Номер архитектуры	Номер эпохи максимума	Максимум точности	Потребляемая память, Мбайт	Количество параметров
Дублирование шестой свертки	11	3	0.075	103.424	15 025 156
	12	3	0.116	107.520	16 074 756
	13	3	0.090	111.616	17 124 356
	14	3	0.063	115.712	18 173 956
Дублирование пятой свертки	15	2	0.179	103.376	14 565 636
	16	3	0.104	103.424	15 155 716
	17	3	0.104	106.496	15 745 796
Дублирование четвертой свертки	18	1	0.137	108.544	16 335 876
	19	2	0.162	104.448	15 303 044
	20	2	0.128	109.568	16 630 532
	21	2	0.079	114.688	17 958 020
Дублирование второй свертки	22	4	0.064	119.808	19 285 508
	23	2	0.105	105.472	15 614 212
	24	3	0.095	111.616	17 252 868
	25	2	0.074	117.760	18 891 524
Дублирование первой свертки	26	–	–	–	20 530 180
	27	1–2	0.065	68.608	5 915 748

в пятой – 256, в шестой – 1024. На проверочной выборке достигнута точность 35.43 %.

Для поиска оптимальной архитектуры предлагаемой нейронной сети также проводился ручной перебор возможных гиперпараметров сети, который будет описан далее.

**Ручной поиск модифицированной архитектуры.** Для поиска гиперпараметров и поиска архитектуры нейронной сети вручную был проведен ряд экспериментов: уменьшение изначальной нейронной сети посредством постепенного удаления последних слоев; увеличение исходной нейронной сети дублированием сверточных слоев (от двойного до пятерного дублирования); объединение архитектур, на которых была достигнута самая высокая точность; комбинирование дублирований нескольких сверточных слоев; уменьшение и увеличение количества слоев в различных сверточных слоях.

В общей сложности были протестированы 70 различных архитектур. Часть из этих архитек-

тур не удалось проверить на тестовой выборке, так как размер выходного тензора получался отрицательным. В сравнительных таблицах по этим экспериментам представлен номер архитектуры, эпохи, на которых была достигнута максимальная точность, значение максимальной точности, количество потребляемой нейронной сетью памяти, количество параметров нейронной сети.

Для первого эксперимента по уменьшению нейронной сети, результаты которого представлены в табл. 1, было проведено 10 проверок различных архитектур.

Максимальная точность (7.64 %) была достигнута после удаления последнего сверточного слоя и последнего слоя группирования по максимуму (max pooling).

Для второго эксперимента по дублированию сверточных слоев, результаты которого представлены в табл. 2, было проведено 17 проверок различных архитектур. Поскольку третий сверточный слой в исходной нейронной сети и так про-

Таблица 3

Название эксперимента	Номер архитектуры	Номер эпохи максимума	Максимум точности	Потребляемая память, Мбайт	Количество параметров
Объединение архитектур с самыми высокими точностями	28	1	0.091	120.832	19 630 980

Таблица 4

Название эксперимента	Номер архитектуры	Номер эпохи максимума	Максимум точности	Потребляемая память, Мбайт	Количество параметров
Комбинирование дублирований нескольких сверток	29	1–2	0.054	116.736	18 581 380
	30	2	0.091	110.592	16 942 724
	31	2	0.068	111.616	17 253 892
	32	2	0.099	114.688	17 991 300

Таблица 5

Название эксперимента	Номер архитектуры	Номер эпохи максимума	Максимум точности	Потребляемая память, Мбайт	Количество параметров
0.5 от первой свертки	33	1	0.085	100.352	14 240 772
0.75 от первой свертки	34	3	0.085	101.376	14 403 204
1.5 от первой свертки	35	2	0.101	102.400	14 849 892
2.0 от первой свертки	36	2	0.065	103.424	15 161 220

дублирован, то для него не проводились эксперименты по дублированию.

Максимальная точность для пятой свертки достигнута при тройном дублировании (11.63 %), для четвертой, третьей и второй – при двойном дублировании (11.63, 17.9 и 16.22 % соответственно), для первой свертки из-за появляющейся отрицательной размерности тензора возможно только двойное дублирование, при котором достигнута точность 6.5 %.

Был проведен эксперимент по объединению архитектур с дублированием сверточных слоев, которые дали самую высокую точность (двойное дублирование всех слоев, кроме первого и последнего, так как для последнего слоя применяется тройное дублирование, для первого – нет дублирования, поскольку оно приводит к отрицательной размерности тензора на выходе нейронной сети), результаты которого представлены в табл. 3.

Для этого эксперимента достигнута точность 9.06 %.

Далее был проведен эксперимент по попеременному удалению дублирования из сети, которая тестировалась в предыдущем эксперименте (т. е.

сначала удален один дубль для последнего слоя, далее – для второго, затем – для третьего, и т. д.), результаты которого представлены в табл. 4.

Максимальная точность достигнута при дублировании всех слоев, кроме пятого (9.86 %).

Поскольку максимальная точность при всех комбинациях дублирований, рассмотренных в этой статье, была достигнута при двойном дублировании пятого сверточного слоя (17.9 %), то все последующие эксперименты проведены именно для архитектуры с дублированием пятого сверточного слоя.

Проведены 4 эксперимента по уменьшению и увеличению количества фильтров в первом сверточном слое, результаты которых представлены в табл. 5.

Максимальная точность достигнута при полуторном увеличении исходного количества фильтров первой свертки (10.07 %).

Проведены 4 эксперимента по увеличению и уменьшению количества фильтров во втором сверточном слое, а также дополнительно еще 2 эксперимента по уменьшению количества фильтров, результаты которых представлены в табл. 6.



Таблица 6

Название эксперимента	Номер архитектуры	Номер эпохи максимума	Максимум точности	Потребляемая память, Мбайт	Количество параметров
0.125 от второй свертки	62	1	0.064	96.256	13 252 772
0.25 от второй свертки	61	2	0.087	97.280	13 440 324
0.5 от второй свертки	37	2	0.157	98.304	13 815 428
0.75 от второй свертки	38	3	0.136	100.352	14 190 532
1.5 от второй свертки	39	2	0.113	104.448	15 315 844
2.0 от второй свертки	40	1	0.076	107.52	16 066 052

Таблица 7

Название эксперимента	Номер архитектуры	Номер эпохи максимума	Максимум точности	Потребляемая память, Мбайт	Количество параметров
0.5 от третьей свертки	41	4	0.068	97.280	13 459 524
0.75 от третьей свертки	42	3	0.067	99.328	14 012 580
1.5 от третьей свертки	43	2	0.121	105.472	15 671 748
2.0 от третьей свертки	44	1	0.076	110.592	16 777 860

Таблица 8

Название эксперимента	Номер архитектуры	Номер эпохи максимума	Максимум точности	Потребляемая память, Мбайт	Количество параметров
0.125 от четвертой свертки	64	3	0.076	94.208	12 629 940
0.25 от четвертой свертки	63	2	0.084	95.232	12 906 468
0.5 от четвертой свертки	45	2	0.133	97.280	13 459 524
0.75 от четвертой свертки	46	6–10	0.066	99.328	14 012 580
1.5 от четвертой свертки	47	5	0.063	105.472	15 671 748
2.0 от четвертой свертки	48	2	0.083	110.592	16 777 860

Максимальная точность достигнута при двойном уменьшении исходного количества фильтров второй свертки (15.72 %).

Проведено 4 эксперимента по уменьшению и увеличению количества фильтров в третьем сверточном слое, результаты которых представлены в табл. 7.

Максимальная точность достигнута при полуторном увеличении исходного количества фильтров третьей свертки (12.14 %).

Проведено 4 эксперимента по увеличению и уменьшению количества фильтров в четвертом сверточном слое, а также дополнительно еще 2 экс-

перимента по уменьшению количества фильтров, результаты которых представлены в табл. 8.

Максимальная точность достигнута при двойном уменьшении исходного количества фильтров четвертой свертки (13.25 %).

Проведено 4 эксперимента по увеличению и уменьшению количества фильтров в пятом сверточном слое, а также дополнительно еще 2 эксперимента по уменьшению количества фильтров, результаты которых представлены в табл. 9.

Максимальная точность достигнута при двойном уменьшении исходного количества фильтров пятой свертки (13.94 %).

Таблица 9

Название эксперимента	Номер архитектуры	Номер эпохи максимума	Максимум точности	Потребляемая память, Мбайт	Количество параметров
0.125 от пятой свертки	66	2	0.074	96.256	13 275 172
0.25 от пятой свертки	65	2	0.063	97.280	13 459 524
0.5 от пятой свертки	49	2	0.139	99.328	13 828 228
0.75 от пятой свертки	50	3	0.086	100.352	14 196 932
1.5 от пятой свертки	51	6	0.060	104.448	15 303 044
2.0 от пятой свертки	52	2	0.076	107.52	16 040 452

Таблица 10

Название эксперимента	Номер архитектуры	Номер эпохи максимума	Максимум точности	Потребляемая память, Мбайт	Количество параметров
0.5 от шестой свертки	53	3	0.122	100.352	14 139 524
0.75 от шестой свертки	54	6	0.063	100.352	14 352 580
1.5 от шестой свертки	55	3	0.076	103.424	14 991 748
2 от шестой свертки	56	1	0.154	104.448	15 417 860
2.5 от шестой свертки	67	1	0.0849	106.496	15 843 972
3.0 от шестой свертки	68	1	0.1079	108.544	16 270 084

Таблица 11

Название эксперимента	Номер архитектуры	Номер эпохи максимума	Максимум точности	Потребляемая память, Мбайт	Количество параметров
0.5 от седьмой свертки	57	2	0.107	82.944	9 715 60
0.75 от седьмой свертки	58	3	0.106	92.160	12 140 548
1.5 от седьмой свертки	59	3	0.088	119.808	19 415 812
2 от седьмой свертки	60	1	0.229	138.24	24 265 988
2.5 от седьмой свертки	69	2	0.094	156.672	29 116 164
3.0 от седьмой свертки	70	–	–	–	33 966 340

Проведены 4 эксперимента по увеличению и уменьшению количества фильтров в шестом сверточном слое, а также дополнительно еще 2 эксперимента по увеличению количества фильтров, результаты которых представлены в табл. 10.

Максимальная точность достигнута при двойном увеличении исходного количества фильтров шестой свертки (15.41 %).

Проведены 4 эксперимента по увеличению и уменьшению количества фильтров в седьмом свер-

точном слое, а также дополнительно еще 2 эксперимента по увеличению количества фильтров, результаты которых представлены в табл. 11.

Максимальная точность достигнута при двойном увеличении исходного количества фильтров седьмой свертки (22.89 %).

Из всех экспериментов по уменьшению и увеличению количества фильтров максимальная точность было достигнута при двойном увеличении фильтров в седьмой свертке (22.89 %).

Из результатов экспериментов видно, что существует оптимальное количество фильтров в каждом сверточном слое; при меньшем количестве фильтров нейронная сеть переобучается, при большем количестве – недообучается.

В статье представлены различные варианты архитектур нейронных сетей для классификации пластиковых бутылок, алюминиевых банок и прочих предметов. Нейронные сети обучались на относительно небольшой выборке (700 фотографий банок, столько же – бутылок и 6000 фотографий прочих предметов), все предметы в этой выборке расположены на одном и том же фоне. Проверка проводилась на фотографиях предметов, сделанных на различных фонах, при разных углах наклона, на разных расстояниях от предмета до камеры и с различными геометрическими деформациями предметов (мятостями). Проведены эксперименты по поиску архитектуры сети, достигающей на этой выборке максимальной

точности распознавания. Поиск архитектур проводился для собственной оригинальной архитектуры с помощью автоматического метода гиперпараметрической оптимизации и ручного перебора архитектур. На новой проверочной выборке нейронная сеть MobileNet достигает точности распознавания 20.67 %, при автоматическом поиске архитектуры точность увеличилась на 15 % и достигла 35.43 %, при ручном поиске архитектуры точность относительно точности MobileNet увеличилась на 2 % и достигла 22.9 %.

Дальнейшие направления исследований:

1. Модификация функции потерь, которая в процессе обучения нейронной сети оптимизируется.

2. Модификация исходной сверточной сети для увеличения способности сети кластеризировать получаемые векторы изображений.

Исследование выполнено при финансовой поддержке Правительства Пермского края в рамках научного проекта № С-26/174.6.

## СПИСОК ЛИТЕРАТУРЫ

1. Чердак: наука, технологии, будущее. URL: <https://chrdrk.ru/news/podschitano-obshchee-kolichestvo-plastika> (дата обращения 02.03.2019).

2. Raspberry Pi – teach, learn, and make with Raspberry Pi. URL: <https://www.raspberrypi.org/> (дата обращения 02.03.2019).

3. Krizhevsky A., Sutskever I., Hinton G. E. ImageNet classification with deep convolutional neural networks // Proc. of the 25<sup>th</sup> Intern. Conf. on Neural Information Proc. Systems. (NIPS'12). Lake Tahoe, Nevada, USA. 2012. Vol. 1. P. 1106–1114.

4. Ахметзянов К. Р., Южаков А. А. Сравнение сверточных нейронных сетей для задач сортировки мусорных отходов // Изв. СПбГЭТУ «ЛЭТИ». 2018. № 6. С. 27–32.

5. SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and <0.5 MB model size / F. N. Iandola, S. Han, M. W. Moskewicz, K. Ashraf, W. J. Dally, K. Keutzer // arXiv препринт arXiv:1602.07360, 2016. URL: <https://arxiv.org/pdf/1602.07360.pdf> (дата обращения 02.03.2019).

6. MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications / A. G. Howard, M. Zhu, B. Chen, D. Kalenichenko, W. Wang, T. Weyand, M. Andreetto, H. Adam // arXiv препринт arXiv:1704.04861, 2017. URL: <https://arxiv.org/pdf/1704.04861.pdf> (дата обращения 02.03.2019).

7. Ахметзянов К. Р., Южаков А. А. Увеличение точности сверточной нейронной сети за счет возрастания количества данных // Нейрокомпьютеры: разработка, применение. 2018. № 7. С. 14–19.

8. Wang J., Perez L. The effectiveness of data augmentation in image classification using deep learning. URL: <http://cs231n.stanford.edu/reports/2017/pdfs/300.pdf> (дата обращения 02.03.2019).

9. Vasconcelos C. N., Vasconcelos B. N. Convolutional neural network committees for melanoma classification with classical and expert knowledge base image transforms data augmentation // arXiv препринт arXiv:1702.07025, 2017. URL: <https://arxiv.org/pdf/1702.07025.pdf> (дата обращения 02.03.2019).

10. Random erasing data augmentation / Z. Zhong, L. Zheng, G. Kang, S. Li, Y. Yang // arXiv препринт arXiv:1708.04896, 2017. URL: <https://arxiv.org/pdf/1708.04896.pdf> (дата обращения 02.03.2019).

11. Hochreiter S., Schmidhuber J. Long short-term memory // Neural Computation. 1997. Vol. 9, № 8. P. 1735–1780.

12. Koch G., Zemel R., Salakhutdinov R. Siamese neural networks for one-shot image recognition. URL: <https://www.cs.cmu.edu/~rsalakhu/papers/oneshot1.pdf> (дата обращения 02.03.2019).

13. Li F.-F., Fergus R., Perona P. One-shot learning of object categories // IEEE Transactions on Pattern Analysis and Machine Intelligence. 2006. Vol. 28, № 4. P. 594–611.



K. R. Akhmetzyanov, A. A. Yuzhakov  
Perm national research polytechnic university

## NEURAL NETWORK ARCHITECTURE OPTIMIZATION FOR WASTE GROUP SORTING

*The results of experiments on the development of neural network architecture to classify plastic bottles, aluminum cans and other objects are presented in the paper. The neural network is part of a smart container – a device for automated collection and waste sorting. This container consists of three waste cans (for collecting bottles, cans and other objects), the sorting actuator and RaspberryPi microcomputer. When developing a neural network, it is necessary to take into account the limitations of the computing power of this microcomputer with a high speed of image processing at any inclination and any distances to the object. Also, the neural network must properly classify crushed bottles and cans. The article presents the results of previous experiments conducted on the choice of a neural network among AlexNet, SqueezeNet and MobileNet. MobileNet neural network has achieved the highest accuracy. But the disadvantage of this neural network is the need to create a large training set for accurate recognition of crushed bottles and cans. The creation of such a training set with all the possible crushes would have required an huge amount of time. The article describes the original idea of the neural network, as well as the search for the most optimal architecture of this neural network, both manually and automatically.*

**Object classification, neural networks, convolutional neural networks, deep learning, computer vision, waste sorting, RaspberryPi**

---

УДК 519.7+681.51

Т. Л. Качанова, Б. Ф. Фомин  
Санкт-Петербургский государственный электротехнический  
университет «ЛЭТИ» им. В. И. Ульянова (Ленина)

## Внутрисистемные взаимодействия по модели «подобия» (теория)

*Излагается теория внутрисистемных отношений (взаимодействий) по модели подобия между собственными качествами системы, а также актуализация этой теории. В первой части статьи, посвященной теоретическим вопросам взаимодействий, методами физики открытых систем исследованы структурные инварианты взаимодействий по подобию, возникающие в условиях неравновесных ограничений и метастабильности. Отдельно рассмотрены типы, формы и способы осуществления двухчастичных взаимодействий по моделям подобия и псевдоподобия. Для моделей подобия установлены и исследованы все возможные виды взаимодействий собственных качеств системы, раскрывающие тождественность смыслов механизмов этих качеств: синхронную, синфазную синхронную, асинхронную, сходство частных аспектов. Для моделей псевдоподобия введены и исследованы двухчастичные взаимодействия, проявляющие моменты различия в системе. Определены способы и варианты включения этой модели в модель собственного качества третьего участника взаимодействия и исследованы возникающие при этом локальные системные механизмы обратной связи, действующие на центр порядка третьего участника. Положения и выводы теории внутрисистемных взаимодействий по моделям подобия и псевдоподобия актуализированы в проекте «Социальная напряженность в округах и регионах России».*

**Открытые системы, физика открытых систем, собственные качества систем, модели взаимодействий, взаимодействие по подобию, типы и формы взаимодействия по подобию**

Физика открытых систем (ФОС) возникла на базе статистической физики и синергетической парадигмы [1], [2]. Открытые системы в ФОС – математические динамические модели. Предмет ФОС представляет теория сложности, а сверхза-

дачу – научное понимание взаимосвязи сложности систем и законов природы.

В середине 1990-х гг. возникло новое направление ФОС, в рамках которого идет становление киберфизической парадигмы познания открытых си-