

N. D. Polyakhov, D. Ph. Nguyen, V. B. Vtorov, V. E. Kuznetsov, I. A. Prikhodko, A. D. Stotskaia
Saint Petersburg Electrotechnical University «LETI»

A COMPARATIVE STUDY OF THE EFFECTIVENESS OF PI- AND ROBUST CONTROLLERS IN THE DESIGN OF HIGH-ACCURACY TRACKING SYSTEMS

In the article the problem of achieving the best velocity error constant in the design of a high-accuracy tracking system with an elastic two-mass electromechanical object is investigated. A typical two-loop structure with an internal speed system and an external tracking loop with a proportional controller is considered. The main efforts are aimed at obtaining the best robust dynamics of the speed system. For this purpose, the robust control based on H_∞ -theory has been used. In order to demonstrate the advantages of a system with robust control, a tracking two-loop comparison system with a PI controller in the internal loop is designed on the basis of the cascade control principle. The stability of the tracking system is investigated with the aim of finding the highest velocity error constant, at which the robustness is preserved without regard to variations in the parameters of the electromechanical object. Robustness is qualitatively estimated by means of preserving the dynamic performance measures while changing the parameters of the electromechanical object – the rigidity of mechanical coupling between the motor and the mechanism driven by it, as well as the moment of inertia of the second mass in a two-mass system. Comparative modeling has shown that the tracking system with a robust controller copes effectively with disturbances (both deterministic and random processes), and demonstrates the improved dynamic accuracy in the reproduction of test signals (both stepped and sinusoidal).

PI-, PID²-controller, robust control

УДК 004.93'1

А. Н. Кококулин, А. И. Тур, А. А. Южаков

Пермский национальный исследовательский политехнический университет

Вопросы применения нейронных сетей при разработке автоматов по приему тары

Приводятся результаты разработки оригинального автомата по приему тары на основе IoT и нейронных сетей. Эти автоматы должны выполнять возложенные на них функции (распознавать контейнеры – бутылки ПЭТ и алюминиевые банки), быть безопасными (не подвергать опасности здоровье и материальные ценности пользователя), но и в то же время обладать низкой ценой производства и обслуживания (из-за низкой рентабельности деятельности по сбору контейнеров в текущих условиях рынка). По традиции данные машины разрабатываются на базе контроллеров IoT и одноплатных компьютеров. Они имеют весьма ограниченные память и вычислительные возможности, однако позволяют использовать для реализации проекта различные специализированные устройства (камеры, сканеры штрих-кода, спектрометры и прочее). Для снижения себестоимости была предпринята попытка отказаться от дорогостоящей электроники, используя только визуальное распознавание объекта на основе нейронных сетей. Для этого были выбраны и обучены некоторые из наиболее популярных сетей, основанных на нейросетевой надстройке Keras над фреймворком Tensorflow и Caffe: LeNet, AlexNet, SqueezeNet, проведены сравнительные тесты и сделаны выводы.

Автомат по приему тары, нейронная сеть, сверточная нейронная сеть, переработка

Reverse vending machine (дословно «обратный торговый автомат», автомат по приему тары, RVM) – это автомат, позволяющий людям возвращать пустые контейнеры (бутылки ПЭТ (полиэтилентерефталат) и алюминиевые банки) для напитков для переработки. Обычно автомат устроен таким образом, чтобы возвращать конечному пользователю сумму, эквивалентную сто-

имости сданной тары. Это и делает его «реверсивным» торговым автоматом – вместо того, чтобы пользователь вкладывал деньги и получал продукт, он помещает продукт в автомат и получает за это денежное вознаграждение. Другими словами, это – автоматизированный способ сбора, сортировки и обработки использованной тары. «Обратные торговые автоматы» особенно распро-

странены в регионах с законами об утилизации. Машины распознают каждый материал собранной тары, сортируют и уплотняют в «пакеты», готовые к переработке. Благодаря компактности, получаемой в результате такого подхода, стоимость каждого пакета выше, чем неуплотненного мусора такого же объема, что позволяет снизить затраты на логистику. «Пакеты» поступают на заводы по переработке вторичного сырья, где проходят мойку и измельчение для дальнейшего использования собранных материалов при производстве новой тары. Автоматы по приему тары служат основой системы переработки материалов в Европе и Соединенных Штатах. Они собирают от 70 до почти 100 % всей тары для напитков, возвращаемой для переработки [1].

Для решения проблемы мошенничества система включает в себя несколько проверок безопасности, выполняемых RVM. Например, большинство машин контролируют следующие параметры тары:

- материал контейнера (например, с помощью ИК-спектрометра);
- форму контейнера;
- штрих-код.

Эти три основные процедуры контроля делают любую попытку мошенничества совершенно невозможной, в то же время делая RVM слишком дорогостоящим. Например, цены на оборудование для ReWend 800 Reverse Vending Recycling Machine будут составлять более 7 000 евро за каждый автомат [2].

Благодаря современным технологиям компьютерного зрения можно разработать еще один вид эффективных и недорогих RVM, имеющих схожую функциональность и высокую защиту от мошенничества. Это актуально для российской действительности, потому что у нас не закреплено на законодательном уровне возвращение стоимости контейнера после его использования. Однако, обеспечив автоматическую обработку пластмассовых и металлических отходов в сочетании с другим механизмом экономической мотивации конечных пользователей – системой скидок и бонусов в крупных торговых сетях, за каждый переработанный контейнер можно предоставлять неденежное вознаграждение для пользователя (скидку, бонусные баллы и т. п.). Кроме того, прибыль владельца RVM измеряется стоимостью переработанного пластика и металла, и при больших расходах на логистику она будет очень мала [3], [4]. По этой причине проект создания ори-

гинальной RVM и сопутствующие задачи можно считать актуальными для местных органов власти.

Дизайн автомата по приему тары. Человек помещает пустую бутылку в принимающее отверстие. Горизонтальная система подачи позволяет пользователю вставлять контейнеры только по одному за раз. В RVM контейнер проверяется и идентифицируется (сопоставляется с базой данных), после чего автомат принимает решение о принятии или отказе от предложенного образца. Зарубежные автоматы используют распознавание материала и/или сканер штрих-кода вместе с некоторыми онлайн-овыми или локальными базами данных штрих-кодов [5] (пример подобного автомата представлен на рис. 1).



Рис. 1

Это приводит к увеличению стоимости RVM из-за установки в автомат ИК-спектрометра и сканера штрих-кодов, а также расходов на дополнительную электронику, из-за чего процесс распознавания становится более сложным, поскольку требуется ежедневная синхронизация базы данных для обработки новых штрих-кодов для новых типов контейнеров. Мы разработали другой метод идентификации, основанный на распознавании объектов с нейронными сетями, используя крошечное устройство контроллера IoT (Raspberry PI 3) [6]–[8] с экраном, камерой, некоторыми датчиками, сервоприводами и потратив менее 100 дол. на систему управления. Этот подход не зависит от выборочных обновлений баз данных. Нейронная сеть обучается на фотографиях банок и ПЭТ-бутылок различных форм и определяет основные функции, необходимые для классификации. Благодаря этой особенности любое новое изображение ПЭТ-бутылки может быть

идентифицировано как совокупный класс ПЭТ-бутылок, если контейнер обладает соответствующими свойствами. Банки обрабатываются аналогичным образом и могут быть идентифицированы совокупно как класс банок. Даже если контейнер механически поврежден и имеет нестандартную форму (незначительно отличающуюся от эталонной), он может быть идентифицирован как один из описанных классов. Также нейронная сеть обучается выявлять попытки мошенничества при сдаче контейнера схожей формы (включая стеклянные бутылки), попытки вандализма (огонь в отсеке идентификации) и возможные действия, способные привести к травмам (рука в отсеке идентификации). Во всех описанных случаях сервопривод автомата не открывает створки приемника. Получившаяся система автономна и способна обрабатывать любые типы контейнеров.

После успешного распознавания контейнер переходит из отсека идентификации через отверстия в соответствующую корзину с помощью сервопривода. В одной нашей модели RVM одноразовый контейнер предварительно измельчается и уплотняется, чтобы избежать утечки возможных остатков жидкости и увеличить емкость хранилища.

RVM оснащен системой обратной связи для уведомления логистического центра о заполнении приемника и о некоторых событиях безопасности.

После идентификации контейнера и его обработки RVM пользователю предлагается выбор бонусов, перечисленных на экране. Выбранная позиция создает QR-код, который можно сканировать с помощью смартфона пользователя через соответствующее приложение. Таким образом, операции верхнего уровня делегируются смартфону, включая аутентификацию пользователя, вход в веб-портал торговой сети для запроса бонусов и т. д. Таким образом разделяется и распределяется функциональность и уменьшается взаимодействие пользователя с RVM. Основными преимуществами являются информационная безопасность аутентификации пользователей и обмена данными, независимость от соединений GPRS/3G для RVM, отсутствие неудобного датчика или физических клавиатур на передней панели RVM [9].

Распознавание емкостей по средствам нейронной сети. Подход «глубокого обучения» – самый продвинутый уровень нейронных сетей. Современные исследователи могут использовать

мощные специализированные аппаратные средства с большим количеством данных для обучения машин. Это открывает много возможностей для обучения сетей с десятками скрытых слоев, которые способны к иерархическому обучению, где простые понятия изучаются на более низких уровнях, и более сложные абстрактные модели – на более высоких уровнях сети. Сверточные нейронные сети (Convolutional neural networks, CNN) автоматически «узнают» об отличительных чертах из изображений, последовательно складывая сверточные уровни друг на друга. Сегодня именно CNN – самый мощный классификатор изображений в области машинного зрения [10], [11].

Алгоритмы машинного обучения делятся на 2 типа:

- с учителем;
- без учителя [12], [13].

В случае обучения с учителем CNN представляется как набор входных данных и ожидаемых выходных. Затем алгоритм пытается изучить шаблоны, которые могут быть использованы для автоматического сопоставления входных данных с их правильным целевым выходом: алгоритм машинного обучения пытается максимально точно угадать правильный ответ, и если это не получается, то «учитель» перенастраивает его для достижения более точного ответа при следующей попытке. Таким образом, цель CNN в области классификации изображений состоит в том, чтобы принимать наборы изображений и идентифицировать шаблоны, которые могут применяться для отличия различных классов изображений по форме объекта друг от друга.

В нашей работе представлены некоторые подходы к компьютерному зрению и обработке изображений, а также их применению к проблеме автоматического распознавания пустых перерабатываемых контейнеров. Рассмотренные нейронные сети спроектированы как скрипт Python, загружаемый после срабатывания датчика появления контейнера в отсеке идентификации и получения снимка от установленной там камеры. Два основных параметра для нейронных сетей – путь к файлу модели ожидаемых объектов и путь к обрабатываемому изображению распознаваемого объекта.

Пакет функций Python содержит множество методов для извлечения функций из изображений. Чтобы обнаружить объекты в OpenCV и удалить

ложные срабатывания, обычно практика настраивает параметры функции `cv2.detectMultiScale()`. Но нет никакой гарантии, что такие параметры будут работать для всех изображений. Это делает пакетную обработку изображений для обнаружения объекта сложной, так как могут быть получены некорректные результаты либо из-за ложного обнаружения объектов, либо из-за их необнаружения по причине плохого выбора параметров в исходной базе изображений. Подобное происходит, потому что данная функция основывается на быстрых каскадных классификаторах Хаггиса, обеспеченных OpenCV (т. е. детекторами Виолы–Джонса). Требуется изучить другие механизмы обнаружения объектов, которые бы показывали стабильные положительные результаты, были переносимы и удобны в случае их одновременного использования: локальные инвариантные дескрипторы, гистограмму ориентированных градиентов, модели деформируемых деталей, примеры моделей с применением методов глубокого обучения и т. п. [10], [14].

Список доступных методов и фреймворков ограничен особенностями используемых контроллеров IoT и одноплатных компьютеров (они имеют ограничения по памяти и вычислительным возможностям). Применить все нейронные сети невозможно, и было принято решение использовать некоторые из наиболее популярных сетей, основанных на надстройках Keras над Tensorflow и Caffe: LeNet; AlexNet; SqueezeNet.

Кроме того, у авторов есть первая реализация алгоритмов обнаружения объектов на основе дескриптора изображения гистограммы ориентированных градиентов (HOG) и метода опорных векторов (SVM), с которых и следует начать.

Стоит отметить, что цель исследования состоит в том, чтобы ограничить изображение внутри RVM тремя возможными классами: бутылкой из ПЭТ, банкой из алюминия и «попыткой мошенничества» (все, что не соответствует первым двум). С учетом того, что банки или бутылки можно согнуть или помять, тем самым изменив их форму, соответствующие изображения были включены в учебные и тестовые комплекты.

Гистограмма ориентированных градиентов. Подобно гистограммам ориентации краев и локальным инвариантным дескрипторам (таким, как SIFT), HOG работает на градиентах яркости

изображения. Основная идея алгоритма состоит в предположении о том, что внешний вид и форма объекта в области изображения могут быть описаны распределением градиентов яркости. Однако в отличие от SIFT, вычисляющего гистограмму по ориентации краев в небольших локализованных областях изображения, HOG вычисляет эти гистограммы на плотной сетке с равномерно распределенными ячейками. Кроме того, эти ячейки могут также перекрываться и контрастироваться, чтобы повысить точность дескриптора.

HOG успешно используется во многих областях компьютерного зрения и машинного обучения, но особенно эффективен для обнаружения людей на изображениях. В данном случае было принято решение применить дескриптор изображения HOG и линейный SVM, чтобы узнать их возможности в обнаружении изображений бутылок и банок, предполагая, что для этих целей изображения контейнеров должны быть одинаково ориентированы и масштабированы.

Но неожиданно этот метод показал незначительные результаты в наших наборах данных даже после нескольких попыток настройки. Нам кажется, что это особенность метода. Мы используем 2D-изображение, преобразованное в вектор 1D, как дескриптор. Таким образом, цилиндрическая форма бутылок и банок могла привести к подобным значениям градиентов для повторения последовательностей длины длительного периода в дескрипторе. У метода SVM есть серьезный недостаток – даже один ошибочный пример может испортить весь класс, став ссылочным вектором, из-за чего сумма ложных положительных и ложных отрицательных результатов будет недопустимой.

Сеть LeNet. Другой подход был основан на LeNet Keras и Tensorflow. Эта сеть автоматически распознает отличительные признаки (фильтры) из изображений в результате последовательной укладки сверточных слоев друг на друга и поэтапного повышения точности распознавания [15].

Каждое входное изображение в обучающем наборе изменено на 28×28 пикс., а затем проходит через несколько скрытых слоев. Таким образом, вектор функции имеет длину 784 (28×28) пикс. – это количество узлов во входном слое.

Скрытые слои – это неконтролируемая ограниченная машина Больцмана (Restricted Boltzmann Machine, RBM), в которой выходные данные каждого RBM в скрытом слое используются в качестве входных данных для следующего [15].

Таблица 1

Класс образца	Номер образца	LeNet – 6 классов	
		model_6_28.model	
		Правильность	Точность распознавания, %
ПЭТ	1	1	91
	2	1	92
	3	1	85
	4	1	86
	5	1	91
Банки	6	0	82
	7	0	67
	8	1	63
	9	1	69
	10	0	53
Другое	11	1	55
	12	1	83
	13	1	98
	14	1	93
	15	1	98
Правильность, %			80

Видимый выходной уровень содержит вероятности вывода для каждой метки класса. В качестве общей классификации выбирается выходной узел с наибольшей вероятностью. Существует возможность сортировать вероятности вывода и выбирать в пределах некоторого диапазона все метки классов, имеющие наибольшую вероятность, – поэтому можно найти наиболее вероятные метки классов и таким образом выполнять мягкие решения.

Подготовив несколько типов моделей, протестировали их на нескольких изображениях контейнеров. Одна из моделей содержала 6 классов:

- ПЭТ-бутылки;
- банки;
- стеклянные бутылки;

- огонь;
- рука человека;
- различный мусор.

Мы полагали, что точность распознавания должна быть лучше, если вручную разделить все возможные объекты на классы, которые настолько разнообразны, насколько это возможно. Результаты показаны в табл. 1.

С другой стороны, можно попытаться создать парные модели для LeNet, каждая из которых обучается по двум классам: «ПЭТ-бутылки – не ПЭТ-бутылки» и «банки – не банки». Оба сценария Python для соответствующих моделей можно запускать одновременно и получать некоторые результаты из выходных уровней. Такая обработка распознавания идеально подходит для наших целей: у разрабатываемого RVM есть два отверстия – для ПЭТ-бутылок и банок соответственно. При попадании бутылки в камеру распознавания банок ее нужно определить как «неправильный объект», а затем предложить пользователю удалить ее из камеры. Аналогично – при помещении банки в камеру распознавания бутылок.

В ходе тестов было выявлено, что это «двойное» приложение LeNet показывает лучшие результаты, чем 6-классовое приложение на тех же образцах тестирования (табл. 2).

Сеть AlexNet. AlexNet – более сложная CNN, чем LeNet. Изображения, используемые для обучения сети, изменяются до размера 224×224 пикс. и передаются скрытым слоям. Это обеспечивает более подробное изучение моделей, чем при образцах 28×28 пикс. в LeNet. AlexNet – это

Таблица 2

Класс образца	Номер образца	LeNet – 2 класса			
		can sharpen.model		pet 56.model	
		Правильность	Точность распознавания, %	Правильность	Точность распознавания, %
ПЭТ	1	1	98	1	91
	2	1	96	1	76
	3	1	96	1	69
	4	1	91	1	67
	5	1	58	1	99
Банки	6	0	84	0	70
	7	0	99	1	92
	8	1	99	1	64
	9	1	88	1	88
	10	1	74	1	58
Другое	11	1	72	1	98
	12	1	99	1	99
	13	1	96	1	98
	14	1	99	1	98
	15	1	99	1	98
Правильность, %		87		93	

нейронная сеть с 60 млн параметров и 500 тыс. нейронов, состоящая из пяти сверточных слоев, часть из которых сопровождаются слоями максимального объема и двумя глобально связанными уровнями с заключительным softmax с 1000 путями. Для ускорения обучения использовались ненасыщающие нейроны и очень эффективная реализация сверточных сетей. Чтобы уменьшить переобучение в глобально связанных слоях, был применен новый метод регуляризации, который оказался очень эффективным [11], [16].

Первый сверточный слой фильтрует входное изображение $224 \times 224 \times 3$ пикс. с 96 ядрами размером $11 \times 11 \times 3$ пикс. с шагом 4 пикс. (расстояние между приемными центрами полей соседних нейронов на карте ядра). Второй сверточный слой принимает в качестве входного сигнала выход первого сверточного слоя и фильтрует его с 256 ядрами размером $5 \times 5 \times 48$ пикс. Третьи, четвертые и пятые сверточные уровни соединены друг с другом без любого объединения вмешательства или уровней нормализации. Третий сверточный слой имеет 384 ядра размером $3 \times 3 \times 256$ пикс., соединенных с (нормированными, объединенными) выходами второго сверточного слоя, четвертый – 384 ядра размером $3 \times 3 \times 192$ пикс., а пятый – 256 ядер размером $3 \times 3 \times 192$ пикс. Полностью связанные слои имеют 4096 нейронов каждый.

Очевидно, что эта CNN обеспечивает лучшую точность, чем LeNet с сопоставимой скоростью распознавания Raspberry PI 3 (табл. 3). Временная задержка обучения здесь не рассматривается, потому что модель обучается на современном ПК с возможностями GPU CUDA.

Таблица 3

Класс образца	Номер образца	AlexNet	
		bottles	another.model
		Правильность	Точность распознавания, %
ПЭТ	1	1	91
	2	1	92
	3	1	85
	4	1	86
	5	1	91
Банки	6	0	82
	7	1	69
	8	1	63
	9	1	69
	10	1	53
Другое	11	1	55
	12	1	83
	13	1	98
	14	1	93
	15	1	98
Правильность, %		93	

Сеть Squeeze Net. Исследования по глубоким нейронным сетям были сосредоточены главным образом на повышении точности. Для заданного уровня точности обычно можно идентифицировать множество глубоких нейронных сетей (Deep neural networks, DNN), которые достигают этого уровня точности (табл. 4).

Таблица 4

Класс образца	Номер образца	SqueezeNet	
		bottles	another.model
		Правильность	Точность распознавания, %
ПЭТ	1	1	100
	2	1	100
	3	1	100
	4	1	100
	5	1	100
Банки	6	0	95
	7	0	100
	8	1	100
	9	1	100
	10	1	100
Другое	11	1	100
	12	1	100
	13	1	100
	14	1	100
	15	1	100
Правильность, %		87	

Имея примерно такую же точность распознавания, меньшие архитектуры DNN предлагают по крайней мере два преимущества:

- требуют канал меньшей пропускной способности для экспорта новой модели из облака в автономный автомат;
- более целесообразны для развертывания на ПЛИС и других аппаратных средствах с ограниченной памятью [16].

Чтобы обеспечить эти преимущества, предлагаем архитектуру DNN под названием SqueezeNet [11]. SqueezeNet достигает точности уровня AlexNet на ImageNet с числом параметров, кратным 50. Кроме того, с помощью методов сжатия модели можно сжать SqueezeNet до размеров менее 0.5 Мбайт (в 510 раз меньше, чем AlexNet).

Результатом проделанной работы стала оценка нескольких подходов к распознаванию и классификации изображений и их применение для распознавания и сортировки пустых контейнеров в автомате по приему тары. Самое точное решение было обработано CNN AlexNet, но почти такая же точность получена с моделями LeNet после нескольких улучшений.

Это исследование не было ограничено изучением CNN и возможностью переноса на устройства IoT. Мы пытались понять, как предварительная обработка изображения и улучшение данных наборов обучения и тестирования могли влиять на точность распознавания и после нескольких экспериментов пришли к следующим выводам:

– обучение LeNet может быть более эффективным, если использовать размер учебных образов 56×56 пикс. и более;

– применение двух моделей LeNet каждого из 2 классов более эффективно, чем одиночная модель из 3–6 классов;

– предварительная обработка обучающих образов (увеличения резкости) может улучшить распознавание только для модели банок, состоящей из двух классов, но в то же время уменьшает точность для аналогичной модели ПЭТ-бутылок. Эти две модели должны настраиваться по-разному.

СПИСОК ЛИТЕРАТУРЫ

1. Reverse vending 101: a beginner's guide. URL: <https://www.tomra.com/en/collection/reverse-vending/reverse-vending-news/2017/how-does-a-reverse-vending-machine-work> (дата обращения 30 дек. 2017).
2. Cost of a Deposit Return Reverse Vending Machine. URL: <http://www.zerowastescotland.org.uk/sites/default/files/reverse%20v%20-%20CFE%20response.pdf> (дата обращения 30 дек. 2017).
3. Огрель Л. Д. Оценка накопления, сбора и переработки отходов ПЭТФ в России // Экол. вестн. России. 2012. № 4. С. 26–31.
4. New German Deposit Law shakes up industry // Business. 2003. Vol. 256, № 2. P. 4.
5. Lasoff M. A. An RV by any other name // Waste Age. 2000. Vol. 31, № 7. P. 34.
6. Слива М. В. Использование миникомпьютера Raspberry PI для преподавания основ робототехники // Культура, наука, образование: проблемы и перспективы: материалы III Всерос. науч.-практ. конф. Нижневартовск: Нижневарт. гос. ун-т, 2014. Нижневартовск, 2014. С. 326–328.
7. Линев Ф. А., Киселева С. Д. Интернет вещей на основе Raspberry PI / Молодежный науч.-техн. вестн. 2015. № 5. С. 22.
8. Сергеева А., Кривандин С. Одноплатный компьютер Raspberry PI: от учебного пособия до промышленного контроллера / Компоненты и технологии. 2016. Т. 4, № 177. С. 96–102.
9. Kokoulin A. N., Tur A. I., Yuzhakov A. A. Convolutional neural networks application in plastic waste recognition and sorting // Proc. of the 2018 IEEE Conf. of

Rus. Young Researchers in El. and Electron. Engin. (2018 ElConRus). Saint Petersburg: Saint Petersburg Electrotechnical University «LETI». SPb., 2018. P. 1118–1122.

10. Rosebrock A. Practical Python and OpenCV + Case Studies. URL: <https://www.pyimagesearch.com/2016/11/20/Python-OpenCV/> (дата обращения 30 дек. 2017).

11. SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and <0.5 Mb model size / I. F. Forrester, Han Song, Moskewicz W. Matthew et al. // ICLR'17 conf. proc. Toulon: World Scientific Publishing Co, 2017. P. 207–212.

12. Хижняков Ю. Н. Алгоритмы нечеткого, нейронного и нейро-нечеткого управления в системах реального времени: учеб. пособие. Пермь: Изд-во Перм. нац. исслед. политехн. ун-та, 2013. 156 с.

13. Хижняков Ю. Н. Современные проблемы теории управления: учеб. пособие. Пермь: Изд-во Перм. нац. исслед. политехн. ун-та, 2015. 237 с.

14. Rosebrock A. Histogram of Oriented Gradients and Object Detection. URL: <https://www.pyimage-search.com/2014/11/10/histogram-oriented-gradients-object-detection/> (дата обращения 30 дек. 2017).

15. LeCun Y., Bottou L., Haffner P. Gradient-based learning applied to document recognition // Proc. of the IEEE. 1998. № 86(11). P. 2278–2324.

16. Krizhevsky A., Sutskever I., Geoffrey E. Hinton, ImageNet Classification with Deep Convolutional Neural Networks. URL: <https://papers.nips.cc/paper/4824-image-net-classification-with-deep-convolutional-neural-networks.pdf> (дата обращения 30 дек. 2017).

A. N. Kokoulin, A. I. Tur, A. A. Yuzhakov
Perm National Research Polytechnic University

THE QUESTIONS OF APPLYING ARTIFICIAL NEURAL NETWORKS IN DEVELOPING A MACHINE FOR ACCEPTING CONTAINERS

The paper describes the results of developing an original reverse vending machine on the basis of IoT and neural networks. These automatic machines shall perform the assigned functions (to recognize containers – bottles of PET and aluminum cans), to be safe (not to endanger health and the property of the user), but at the same time to be cost-effective in terms of production and service. These machines are commonly developed on the basis of IoT controllers and single-board computers. They have very limited memories and computing capabilities, however allow to use a big list of specialized devices for project implementation (cameras, barcode scanners, spectrometers, etc.). For lowering the price cost an attempt to abandon the use of expensive electronics was made, by using only visual recognition of an object on the basis of neural networks. Some of the most popular networks based on Keras were selected for this purpose and trained over Tensorflow and Caffe: LeNet, AlexNet, SqueezeNet. Comparative tests were carried out and conclusions were drawn.

Reverse vending machine, artificial neural networks, convolutional neural network, recycling