

ИНФОРМАЦИОННО-ИЗМЕРИТЕЛЬНЫЕ И УПРАВЛЯЮЩИЕ СИСТЕМЫ

УДК 004.896:621.865

РОБОТИЗИРОВАННЫЙ КОМПЛЕКС СОРТИРОВКИ ТВЁРДЫХ БЫТОВЫХ ОТХОДОВ

Статья поступила в редакцию 04.05.2019, в окончательной варианте – 30.05.2019.

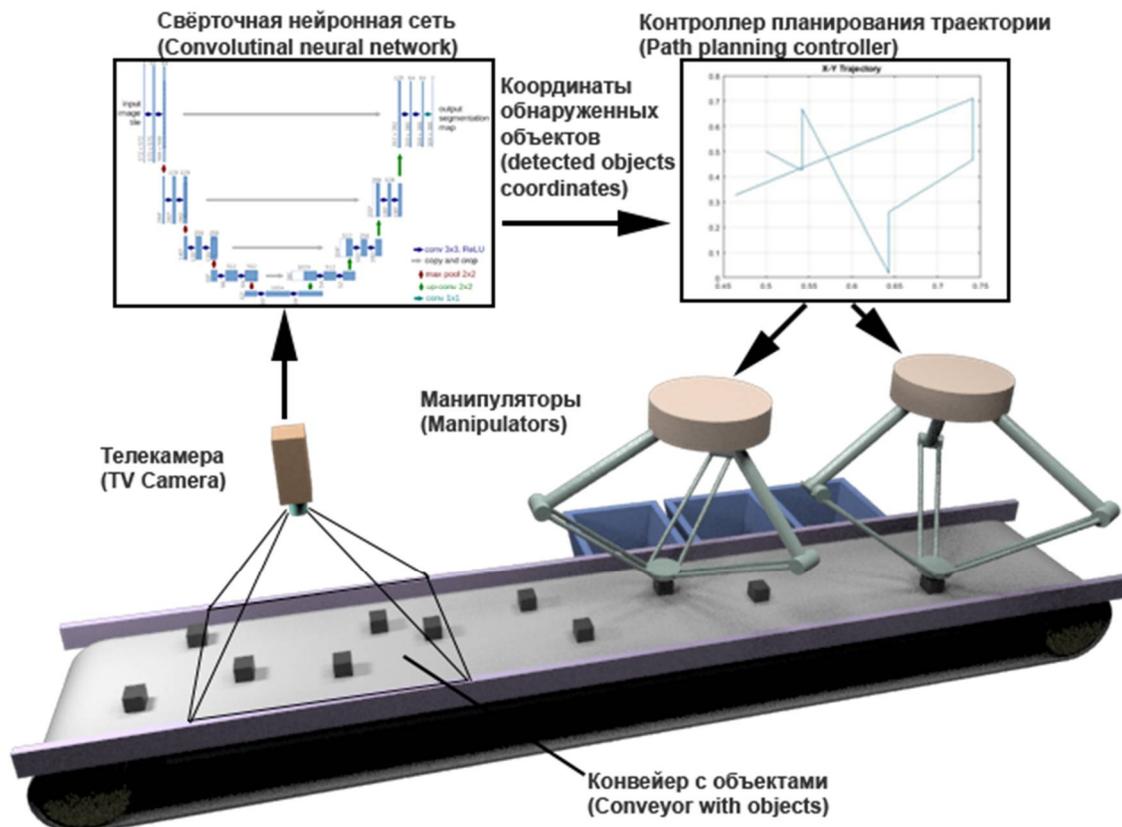
Гемуев Шамиль Шамилевич, Московский государственный технический университет имени Н.Э. Баумана, 105007, Российская Федерация, г. Москва, ул. 2 Бауманская, 5, бакалавр, e-mail: shamilgemuev@mail.ru

Воротников Сергей Анатольевич, Московский государственный технический университет имени Н.Э. Баумана, 105007, Российская Федерация, г. Москва, ул. 2 Бауманская, 5, кандидат технических наук, e-mail: vorotn@bmstu.ru

Статья посвящена разработке роботизированного комплекса, осуществляющего детектирование и изъятие фракций твёрдых бытовых отходов в рамках работы мусороперерабатывающего завода, построенного по конвейерному типу. Комплекс позволяет заменить человека на опасной и монотонной работе, повысить качество сортировки мусора, обеспечить непрерывность процесса сортировки. Описана схема роботизированного комплекса и структура системы управления им. Показана реализация системы технического зрения с использованием сверточной нейронной сети в среде MATLAB Neural Network Toolbox, обоснован выбор архитектуры сети. Разработана модель роботизированного комплекса в среде MATLAB Simulink и проведено ее исследование. Определены параметры зоны сервиса манипулятора, соответствующие требованиям технологического процесса. Получены зависимости коэффициента пропуска объектов от плотности их расположения на конвейерной ленте и ее скорости, а также от максимальных скорости и ускорения манипулятора. Представлен алгоритм сбора распознанных объектов и проведено его исследование.

Ключевые слова: мусороперерабатывающий завод, роботизированный комплекс, система технического зрения, искусственная нейронная сеть, манипулятор, управление, математическое моделирование

Графическая аннотация (Graphical annotation)



ROBOTIC COMPLEX FOR SORTING OF MUNICIPAL SOLID WASTE

Gemuev Shamil Sh., Bauman Moscow State Technical University, 5 2nd Baumanskaya St., Moscow, 105007, Russian Federation,
student, e-mail: shamilgemuev@mail.ru

Vorotnikov Sergey A., Bauman Moscow State Technical University, 5 2nd Baumanskaya St., Moscow, 105007, Russian Federation,
Cand. Sci. (Engineering), e-mail: vorotn@bmstu.ru

The article was received by editorial board on 04.05.2019, in the final version – 30.05.2019.

The article is devoted to the development of a robotic complex that detects and withdraws municipal solid waste fractions within a waste recycling plant built by a conveyor type. The complex allows replacing a person from dangerous and monotonous work, improving the quality of garbage sorting, and ensuring the continuity of the sorting process. The scheme of the robotic complex and the structure of its control system are described. The implementation of the vision system using a convolutional neural network in the MATLAB Neural Network Toolbox environment is shown, the network architecture is selected. A model of a robotic complex in the MATLAB Simulink environment has been developed and its research has been conducted. The parameters of the manipulator service area, which meet the requirements of the technological process, are determined; the dependences of the loss factor of objects on the density of their location on the conveyor belt and its speed, as well as the maximum speed and acceleration of the manipulator are obtained. An algorithm for the collection of recognized objects is presented and its study has been conducted.

Keywords: waste processing plant, robotic complex, vision system, artificial neural network, manipulator, control, mathematical modeling

Введение. В настоящее время в мире производится до 5,5 миллионов тонн отходов в день [20], и это количество продолжает непрерывно расти. Поэтому вопрос переработки мусора является одним из важнейших и актуальнейших, стоящих перед человечеством в последние десятилетия. В России каждый год производится около 6,2 млрд тонн отходов [2]. При этом количество твердых бытовых отходов (ТБО) составляет около 63 млн т/год, что соответствует в среднем 445 кг на человека [2]. Проблема «избавления» от отходов наиболее актуальна для крупных населенных пунктов.

Существует несколько основных способов утилизации ТБО: захоронение на свалках; сжигание; переработка, т.е. превращение отходов во вторичное сырьё. Последний способ, помимо снижения загрязнения окружающей среды, позволяет получать дополнительную выгоду за счёт выработки электроэнергии (в том числе производства биогаза), перепродажи полученного сырья и пр.

Основные объёмы мусора вывозятся на свалки, которых в России насчитывается более 13 тысяч, и их число постоянно увеличивается [3]. Доля перерабатываемого мусора в России составляет в среднем 10–15 %, причем для ТБО она не превышает 4 %. При этом приходится учитывать, что предварительная сортировка мусора (особенно населением) пока еще не получила широкого распространения в городах России. Поэтому существует проблема снижения трудозатрат на переработку «несортированного» мусора, увеличения степени извлечения из него «полезных» объектов. Целью данной статьи является разработка системы автоматизация решения указанных задач.

Общая характеристика предметной области. Завершающим этапом жизненного цикла любого изделия является его утилизация и переработка. Переработка отходов документально известна с IV в. до н.э., когда восстанавливались сломанные орудия, посуда, а также металлические изделия. Одним из стимулов к этому была нехватка ресурсов и их дороговизна [9].

Переломный момент в переработке отходов наступил в конце XX в. в результате совместного действия следующих факторов: удорожание используемой энергии; необходимость массовой утилизации накопившихся изделий электронной техники с закончившимся сроком эксплуатации (из-за поломок, морального устаревания и пр.); широкое использование в быту изделий из пластмасс, которые медленно разрушаются в естественных условиях; разработка эффективных технологий извлечения из отходов драгоценных и редкоземельных металлов [10].

С целью переработки мусора в России проектируются, строятся и эксплуатируются специальные заводы, в том числе использующие элементы автоматизации. Далее мы для определенности будем рассматривать некоторый типичный для России мусороперерабатывающий завод. В составе ТБО, поступающих на завод, бумага и картон составляют в среднем 35 %, пищевые отходы – 41 %, пластмассы – 3 %, стекло – 8 %, металлы – 4 %, текстиль и другое – 9 % [1]. Переработка ТБО на заводе такого типа содержит несколько этапов, на каждом из которых фильтруется (осуществляется извлечение) своего типа отходов (рис. 1, а). На первом этапе из мусора удаляются металлические объекты с помощью магнитного (или электромагнитного) и вихретокового сепараторов.

Далее происходит сортировка (отделение) объектов из стекла с использованием центрифуги. Также с помощью специального засасывающего устройства фильтруются лёгкие летучие фракции бумаги и картона.

Оставшаяся часть ТБО измельчается в шредере до размеров 8–12 см.

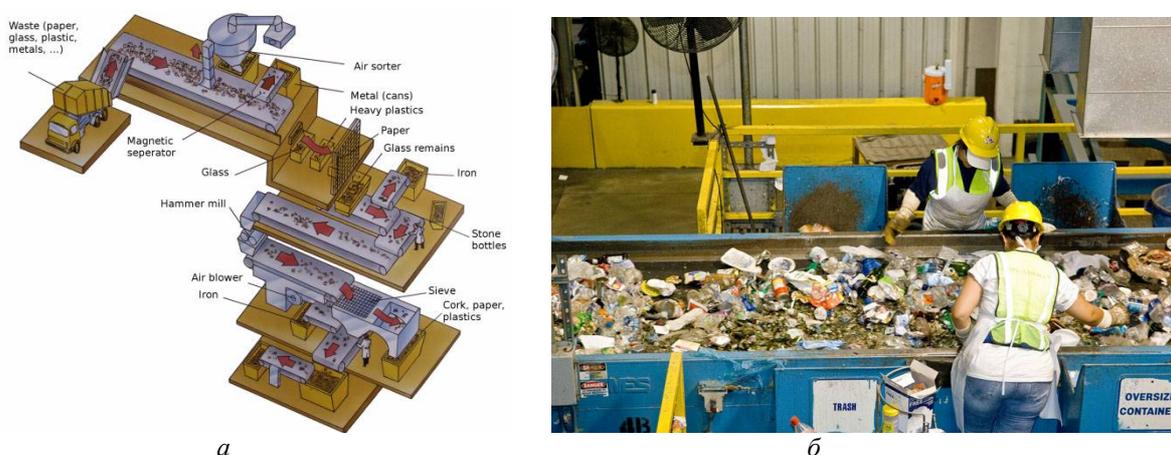


Рисунок 1 – Мусороперерабатывающий завод: схема (а), участок ручной сортировки (б)

Однако этапы, приведенные выше, не позволяют полностью отсортировать ТБО, а главное, извлечь из него «полезные объекты».

Поэтому на мусороперерабатывающих заводах обычно используется этап ручной отбора, в рамках которого поиск и сортировку определённого типа мусора осуществляют люди на конвейере (рис. 1, б). Этап ручной отбора может выполняться на разных участках, например, при разделении отходов из пластика или элементов электроники и т.п. Отметим, что при правильной переработке последних удастся извлечь для последующего использования до 80 % содержащихся в них полудрагоценных и редкоземельных материалов [10].

Однако процессы ручной разборки мусора достаточно трудоемки. Кроме того, при этом может происходить «пропуск» объектов персоналом. Поэтому конкретной целью данной статьи является разработка роботизированного комплекса (РК) для мусороперерабатывающего завода, предназначенного для автоматического детектирования и извлечения из ТБО объектов, относящихся к категории радиоэлектронных изделий.

Структура роботизированного комплекса детектирования и сортировки (РКДС). Разрабатываемый РКДС устанавливается над конвейерной лентой, по которой проходят ТБО (рис. 2, а). Структура системы управления РКДС содержит два логических уровня: уровень детектирования и сортировочный уровень (рис. 2, б).

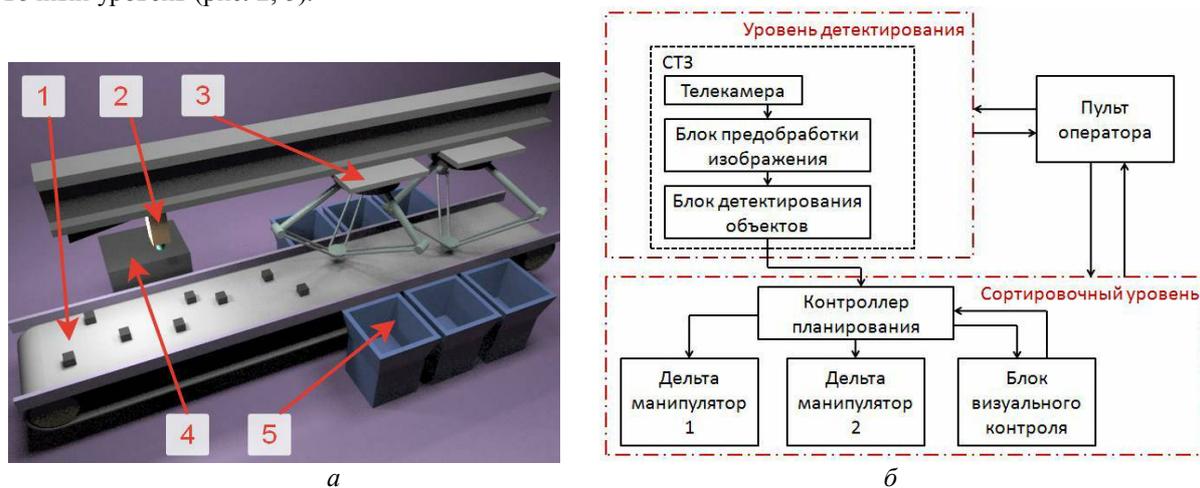


Рисунок 2 – а – схема роботизированного комплекса: 1 – конвейерная лента, 2 – СТЗ, 3 – манипуляторы, 4 – пульт оператора, 5 – контейнеры отсортированных отходов; б – структура системы управления РКДС

На уровне детектирования используется система технического зрения (СТЗ): объект «2» на рисунке 1. Она включает в себя вертикально расположенную над конвейером «1» телекамеру и блок предварительной обработки изображений, осуществляющие запись и визуальную обработку содержимого конвейера в существующих условиях освещения и при заданной скорости его движения. Задачи сегментации и распознавания изображений ТБО решаются в блоке детектирования объектов. Здесь происходит идентификация класса объекта, а также определяются координаты его геометрического центра (как центра, описывающего объект прямоугольника).

Основу сортировочного уровня составляют контроллер планирования, блок визуального контроля и группа исполнительных устройств. В качестве последних предлагается использовать два быстродействующих дельта-манипулятора «3», расположенных последовательно вдоль конвейера. При таком расположении исключается вероятность столкновения манипуляторов при работе, и, кроме того, в случае пропуска объекта первым манипулятором задействуется второй для устранения допущенной ошибки. Задачей контроллера является планирование траектории манипуляторов для обеспечения сбора распознанных объектов и их переноса в контейнеры «5» в условиях движения ленты конвейера. Также контроллер распределяет эти объекты между манипуляторами так, чтобы обеспечить их равномерную загрузку и не допустить пропусков. Блок визуального контроля поддерживает цикл работы манипуляторов, осуществляет поиск незахваченных объектов и задачу изображения рабочей зоны на пульт оператора «4».

Непосредственное управление РКДС осуществляется с пульта оператора. На нем также отображаются основные рабочие параметры РКДС, статистика сбора ТБО манипуляторами и др.

Система технического зрения. Основным элементом РКДС является СТЗ, позволяющая детектировать объекты в рабочей зоне и определять их принадлежность к соответствующему классу ТБО. На данном этапе наиболее актуальным является детектирование объектов электроники, аккумуляторных батарей и мобильных телефонов, содержащих ценные редкоземельные металлы. Заметим, что в общем случае рабочая зона СТЗ содержит различные ТБО и в целом, является существенно недетерминированной. Выбор параметров телекамеры поддается традиционному алгоритму расчёта и определяется геометрией рабочей зоны и климатическими требованиями. В то же время определение структуры блоков предобработки и детектирования (рис. 2, б) является гораздо более сложной задачей. Наряду с применением методов машинного обучения при обработке изображений [4] в рамках данной статьи предлагается данные блоки строить на основе технологии искусственных нейронных сетей (ИНС). Анализ различных топологий этих сетей применительно к задаче идентификации объектов известного класса на изображении недетерминированной сцены показал, что для этого целесообразно использовать свёрточные (или конволюционные) нейронные сети [21].

Конволюционный слой представляет собой набор фильтров, каждый из которых производит операцию свёртки дискретных функций изображения f и скользящего окна g :

$$(f * g)[n] = \sum_{m=-\infty}^{\infty} f[m]g[n - m],$$

где набор коэффициентов окна индивидуален для каждого слоя. Частным случаем конволюционного слоя является, например, фильтр Собеля [13].

В качестве функции активации сети в данной работе используется нелинейная функция ReLU (*rectified linear unit*). При сильной положительной активации нейрона она позволяет сохранять градиент, что эффективно при обучении ИНС методом обратного распространения ошибки.

При выборе архитектуры свёрточной ИНС часто используется подход, называемый «*transfer learning*» [12, 19]. Он основан на использовании готовой, уже натренированной (обученной) нейронной сети, с заменой ее полносвязных конечных слоёв, отвечающих за классификацию по высокоуровневым признакам. Дообучение этой видоизменённой сети проводится разработчиками на своем, достаточно ограниченном наборе изображений.

В качестве готовой ИНС в работе используется AlexNet – сеть, разработанная в 2012 г. Александром Кризевским [8]. Она была обучена на наборе данных с 1,2 миллионами изображений и 1000 различными классами с точностью распознавания 84,7 % (рис. 3). Конволюционные слои в данной сети служат для выделения низко- и высокоуровневых признаков на изображении, а полносвязные слои в конце служат для классификации изображения по найденным наборам признаков.

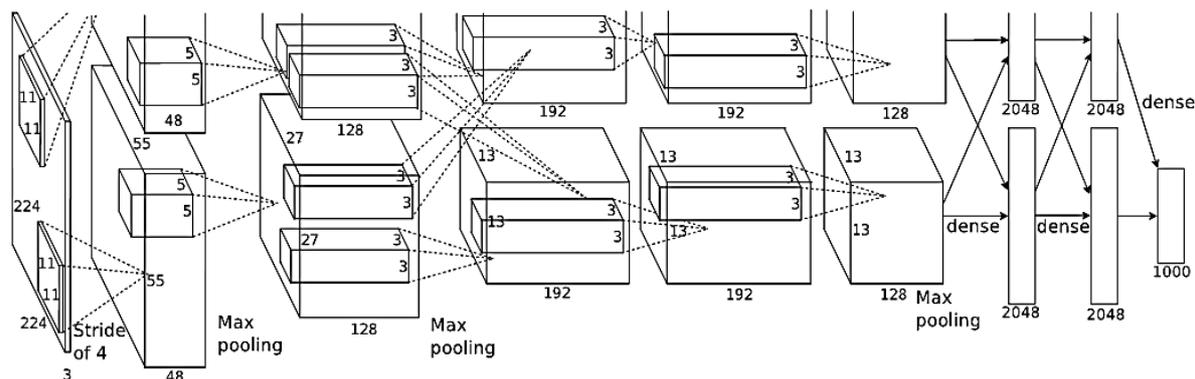


Рисунок 3 – Архитектура сети AlexNet [8]

Для дообучения ИНС была создана база изображений, содержащая изображения объектов, как желаемых классов, так и других, которые могут быть обнаружены на конвейере. Это необходимо для соблюдения баланса между классами, чтобы ИНС помимо желаемых объектов видела также другие, училась их различать. В итоге набор данных содержал 11 классов (рис. 4):

- цилиндрические батарейки/аккумуляторы форматов AA, AAA;
- аккумуляторы телефонов;
- батарейки-таблетки;
- картон;
- электроника, платы;
- стекло, тара;
- металл, жесть;
- бумага;
- сломанные телефоны;
- пластик, упаковка;
- прочий мусор.



а



б

Рисунок 4 – Примеры фотографий объектов разных классов из тренировочной базы изображений: электронные компоненты (а), пластик (б)

При обучении ИНС была применена техника искажения изображений путем их аффинного преобразования (сдвига, поворота, отражения). Такой подход позволяет избежать переобучения сети (чтобы она запоминала не конкретные пиксели изображения, а целые паттерны) [8].

Первый этап обучения заключался в тренировке корректной классификации изображений из базы данных (рис. 5). Этап дообучения ИНС осуществлялся для датасета из 484 изображений и составил 30 эпох (полных циклов прогона базы данных через сеть). По времени это заняло 35 минут при обучении на ПЭВМ с CPU Intel Core i5-2430M 2.40GHz с 8 Гб оперативной памяти. Использовался алгоритм оптимизации Adam с размером минибатча 64 изображения. Начальный коэффициент обучения равнялся 0,000025 со снижением в 2 раза каждые 8 эпох. В результате была достигнута средняя точность классификации объектов – 83,67 %.

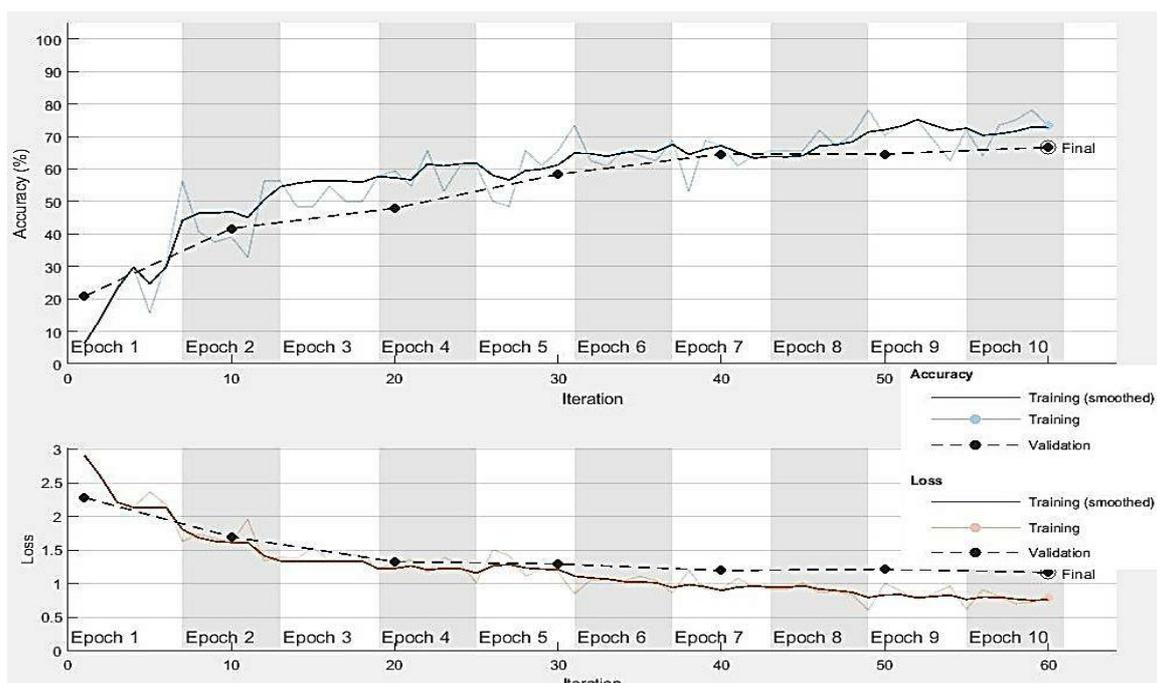


Рисунок 5 – Процесс обучения нейросети

Для оценки точности классификации объектов ИНС для тестовой части датасета помимо среднего значения часто используют *ковариационную матрицу* (рис. 6). Она показывает соответствие действительного класса (строки) предсказанному классу (столбцы). Правильно классифицированные классы расположены по диагонали матрицы (синие), ложные классификации помечены розовым; это позволяет определить, предсказание каких классов вызывает наибольшие затруднения для ИНС. Как следует из рисунка 6, наибольшее количество ложных классификаций было у класса «стекло».

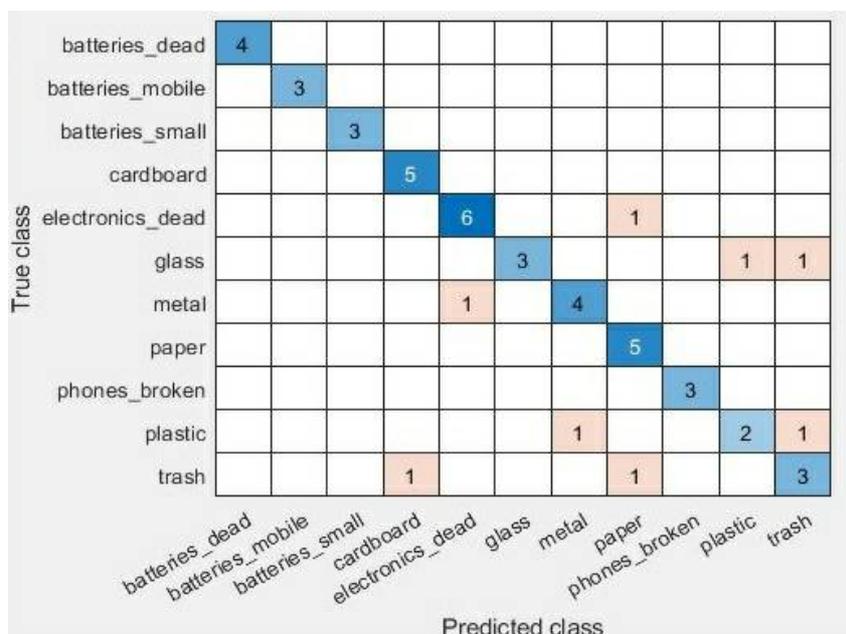


Рисунок 6 – Матрица ковариации для тестовой выборки

Второй этап обучения состоит в обучении ИНС непосредственно детектированию объектов, т.е. поиску объекта на изображении и указанию его положения (либо координатами центра описывающего его прямоугольника, либо попиксельным выделением всего изображения объекта). Были опробованы две популярные архитектуры ИНС для детектирования объектов:

- архитектура Faster R-CNN [17, 18], являющаяся модернизацией конволюционной нейронной сети (в нашем случае, AlexNet). Выходом этой сети являются координаты центра описываемого вокруг объекта прямоугольника и номер класса, которому принадлежит найденный объект;
- архитектура U-Net (рис. 7), отличающаяся от стандартных архитектур. У нее нет полносвязных слоёв, и она имеет форму буквы U. Данная архитектура позволяет получать на выходе попиксельное выделение найденных объектов [14].

В нейронной сети Faster R-CNN изображение проходит через свёрточные слои. Затем методами машинного обучения выделяются области изображения, которые предположительно могут являться объектами классов. После этого производится классификация областей и отсеивание тех из них, в которых вероятность принадлежности к классу ниже установленного порога.

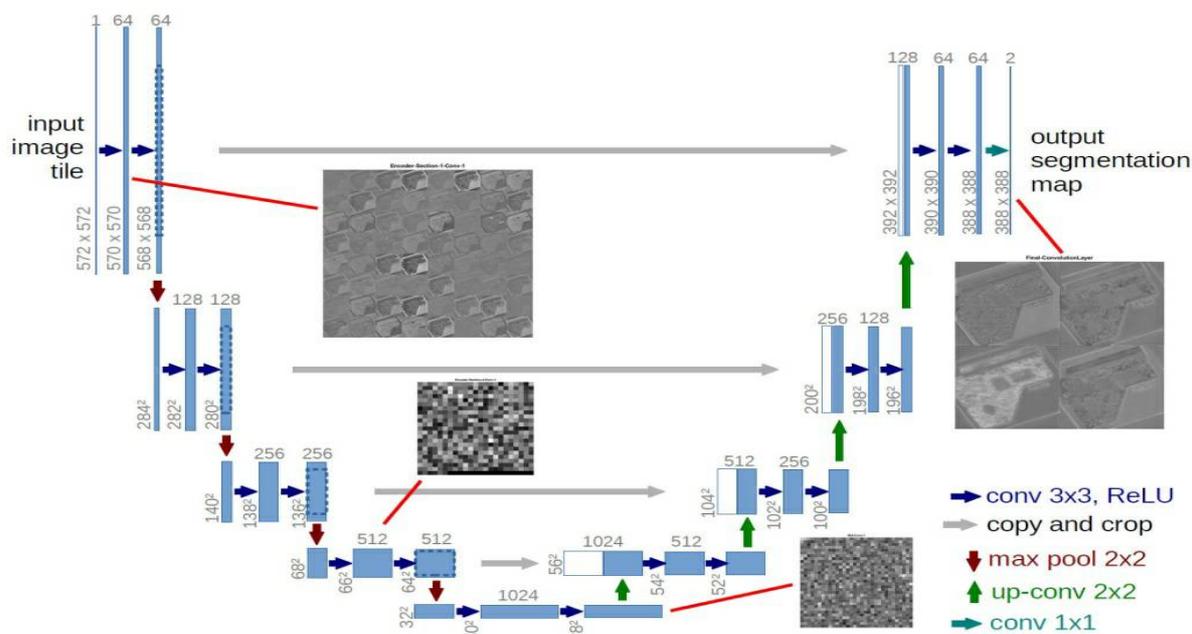


Рисунок 7 – Архитектура U-Net для детектирования и классификации объектов на изображении (показан результат работы некоторых слоев сети для тестового изображения)

Подготовка базы изображений для архитектуры U-Net является более трудоёмкой задачей. Причина – для тренировочных изображений, помимо самих изображений, требуются также маски объектов, находящихся на каждом изображении. Вследствие этого, а также учитывая значительное время обучения ИНС, количество классов в базе изображений было сокращено до 4-х: электроника, телефоны, батареи телефонов, а также фон (все, что не относится к первым трем классам).

Длительность обучения сети для датасета из 74 изображений составила 130 эпох. По времени это соответствовало 25 часам на ПЭВМ с CPU Intel Core i5-2430M 2.40GHz; 8Гб оперативной памяти. Использовался алгоритм оптимизации SGDM с размером минибатча 8 изображений. Начальный коэффициент обучения равнялся 0,025 со снижением в 2 раза каждые 10 эпох. Точность детектирования объектов составила 45,5 %.

На рисунке 8 приведены результаты работы ИНС: на «а» – для тестового изображения; «б» – выходные изображения сети, являющиеся масками для каждого из распознанных сетью классов. Видно наличие шума, однако достигнуто достаточно чёткое разделение объекта «электроника» и фона. Полученные изображения требуют дополнительного улучшения, в частности, обработки медианным фильтром. Результатом является идентификатор класса объекта, его размер, координаты X, Y геометрического центра, а также ориентация объекта в рабочей зоне, просматриваемой СТЗ (рис. 8, в).

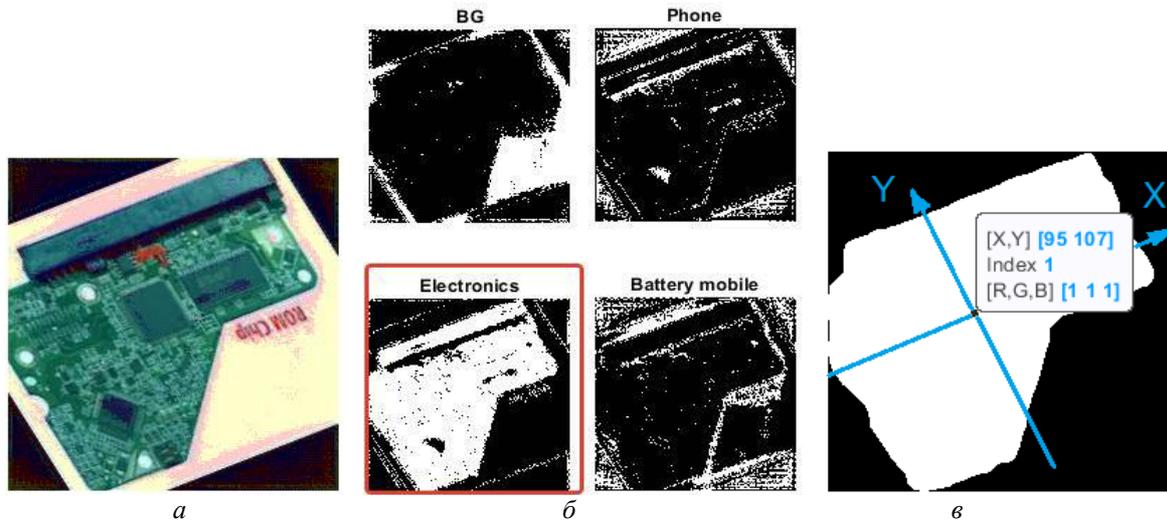


Рисунок 8 – Распознавание объектов сетью U-Net: исходное изображение (а), выход сети для каждого из классов (б), обработанное изображение с координатами объекта (в)

Полученные на уровне детектирования РКДС данные в виде класса и координат центра распознанного объекта передаются на сортировочный уровень системы управления, где контроллер планирования формирует последовательность сбора объектов манипуляторами.

Вероятно, более высокую точность детектирования можно получить, если дальнейшую тренировку нейронной сети проводить на изображениях из ресурса Google Colaboratory. В то же время более правильным является улучшение качества датасета изображений для тренировки сети в условиях, приближенных к реальным. Отметим также, что данная нейросеть обучалась на изображениях, где представлены крупные объекты, для того, чтобы она смогла запомнить текстуру объектов. В таком же формате установленная телекамера будет видеть объекты на конвейере. На небольших объектах нейросеть не испытывалась, и таких примеров нет в датасете.

Манипуляторы РКДС. Для разрабатываемой системы необходимо было выбрать манипулятор с учетом высоких требований по быстродействию. После анализа известных кинематических схем было предложено использовать *дельта-манипулятор* параллельной структуры [15] (рис. 9). Он имеет высокие динамические характеристики: быстродействие – до 300 захватов в минуту, скорость перемещения захватного устройства – 10 м/с, а также позволяет сохранять пространственную ориентацию захватного устройства при его движении [6].

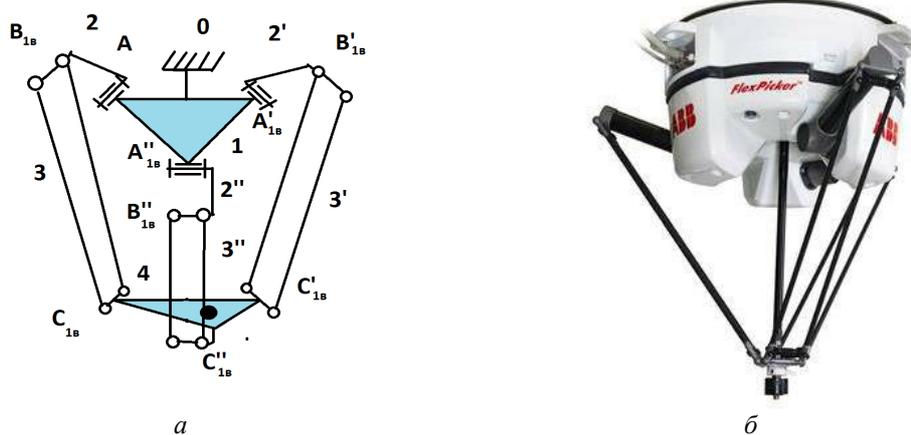


Рисунок 9 – Дельта-манипулятор: типовая кинематическая схема (а), пример промышленного решения (ABB FlexPicker, б)

С целью определения количества необходимых манипуляторов в РКДС и их параметров (зоны сервиса, максимальной скорости и ускорения захватного устройства), а также допустимой скорости движения конвейера и плотности расположения объектов в зоне обслуживания необходимо было построить физическую модель дельта-манипулятора и варьировать ее параметры, анализируя полученные результаты (рис. 10). Данная модель позволяет задавать управляющие воздействия и считывать сигнал как на валу приводов «3», так и на захватном устройстве «8».

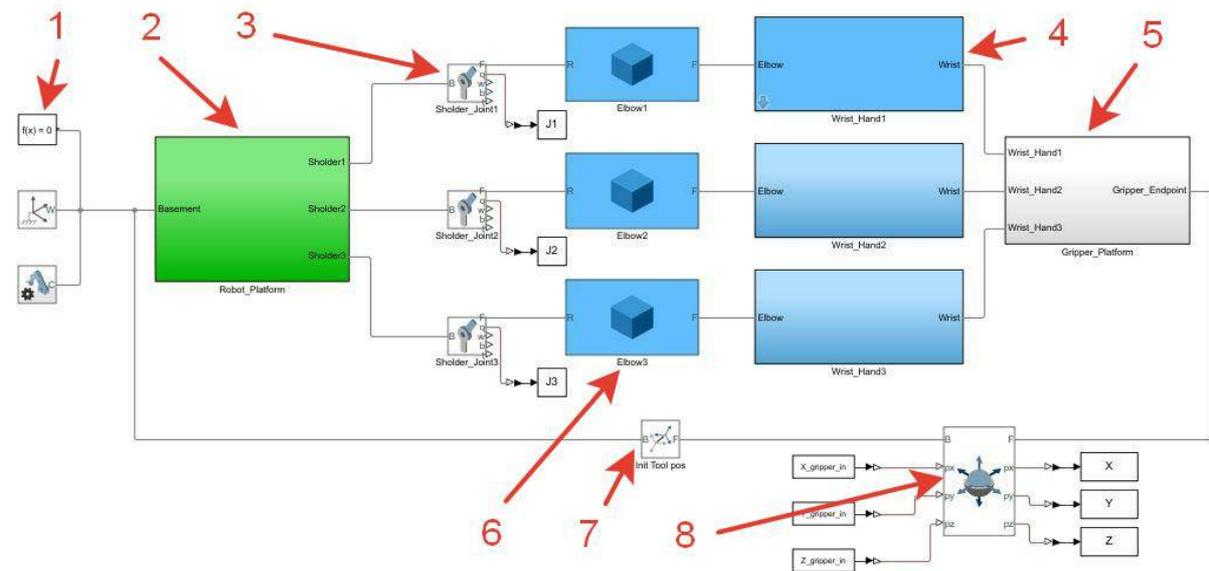


Рисунок 10 – Модель дельта-манипулятора в Matlab Simulink Sinscape: 1 – система координат робота; 2 – геометрия платформы и приводы манипулятора; 3 – сочленение приводов; 4 – парные «предплечья» робота; 5 – геометрия захватного устройства; 6 – «плечевые» звенья; 7 – система координат захватного устройства; 8 – кинематическая пара захватного устройства

Целью моделирования являлось определение допустимых параметров РКДС для выполнения следующих условий:

- зона сервиса манипулятора должна включать в себя рабочую область размером $1 \times 1 \times 0,3$ м, необходимую для перекрытия полной ширины конвейера и возможности переноса объектов с конвейера в емкости-сборники без задевания других объектов на конвейере;
- пропуск («незахват») обнаруженных СТЗ объектов в рабочем цикле манипулятора должен быть сведен к минимуму;
- допустимые значения внутренних параметров РКДС (в частности, максимальной скорости и ускорения захватного устройства) и его внешних параметров (скорости конвейера и плотности расположения объектов на нем) должны минимизировать пропуск обнаруженных объектов при заданной производительности завода в целом.

В результате моделирования была получена зона сервиса (обслуживания) манипулятора, имеющая достаточно сложную форму (рис. 11).

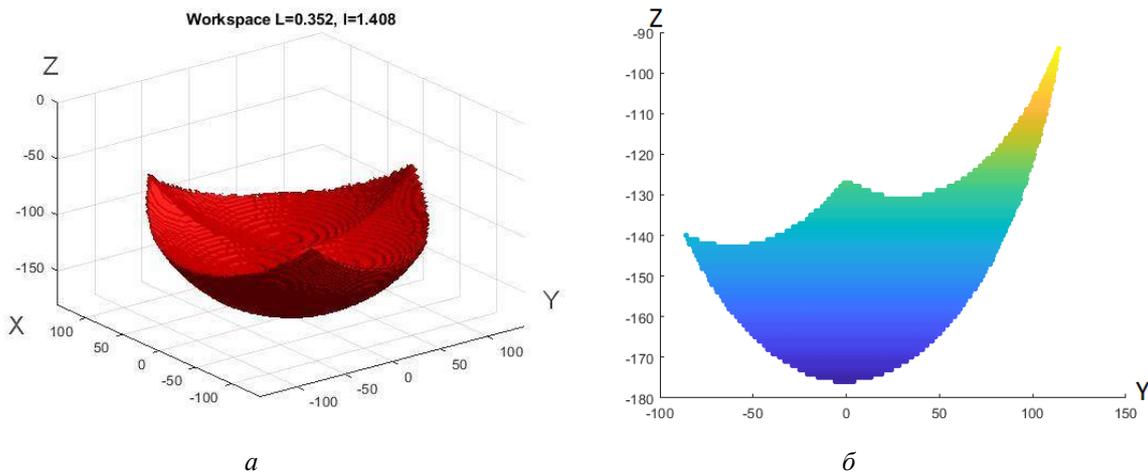


Рисунок 11 – Зона сервиса манипулятора РКДС: объемное представление (а), срез вдоль плоскости YOZ (б)

Зона сервиса симметрична относительно оси OZ и разделена на три одинаковых сектора вдоль этой оси, соответствующих трем тягам параллельной структуры манипулятора. Ограничения зоны сервиса являются положения, когда тяги либо максимально вытянуты, либо максимально сложены. Так-

же зону ограничивают критические (допустимые) углы сгиба между звеньями. Эффективной зоной манипулятора, позволяющей вписать рабочую область заданного размера, является область между -178 см и -140 см по оси OZ (рис. 11, б), поскольку она имеет максимальный охват и отсутствие пустот («мертвых зон» внутри обслуживаемой области).

Для определения необходимой скорости и ускорения движения манипулятора, максимальной скорости конвейера и допустимой плотности расположения объектов при моделировании в качестве критерия использовался коэффициент пропуска K_{loss} (равный количеству пропущенных объектов в единицу времени). Для этого было проведено моделирование 2025 последовательностей процедуры сбора объектов манипулятором, при которых указанные параметры варьировались в заданных пределах.

В результате была получена следующая зависимость K_{loss} от наиболее сильно влияющих на него переменных: плотности расположения объектов и максимального ускорения манипулятора (рис. 12). Изменения остальных параметров в пределах проведенного исследования не приводили к значительному увеличению K_{loss} .

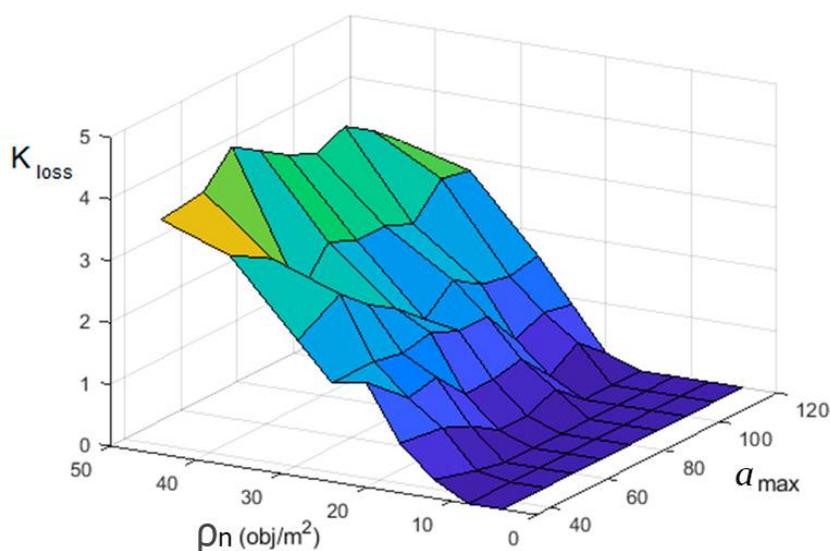


Рисунок 12 – Зависимость коэффициента пропуска объектов K_{loss} от плотности расположения объектов ρ_n и максимального ускорения a_{max} при максимальной скорости захватного устройства $v_{max} = 5 \frac{м}{с}$ и скорости конвейера $v_{konv} = 0,4 \frac{м}{с}$

В общем случае линеаризованная функция зависимости коэффициента пропуска K_{loss} в точке минимального значения этого коэффициента при $a_{max} = 50 \frac{м}{с^2}$, $v_{max} = 5 \frac{м}{с}$, $\rho_n = 12 \frac{об}{м^2}$, $v_{konv} = 0,4 \frac{м}{с}$ от максимального ускорения a_{max} и скорости v_{max} захватного устройства, скорости конвейера v_{konv} и плотности расположения объектов ρ_n примет вид:

$$K_{loss} = -0,02a_{max} - 0,1v_{max} + 3,5v_{konv} + 0,1\rho_n + 0,2.$$

Данное выражение позволяет оценить эффективность работы всего РКДС при заданных параметрах, рассчитать необходимую скорость и ускорение манипулятора, а также определить необходимое число манипуляторов РКДС на конвейере (рис. 2, а). Анализ этой зависимости дает возможность распределить работу между манипуляторами с целью их более равномерной занятости, при которой достигается гарантированный захват объектов с поверхности конвейера.

Таким образом, оптимальный режим работы манипулятора достигается при $a_{max} = 50 \frac{м}{с^2}$, $v_{max} = 5 \frac{м}{с}$, $\rho_n = 12 \frac{об}{м^2}$, $v_{konv} = 0,4 \frac{м}{с}$. Для этих значений в конструкции манипулятора можно использовать приводы умеренной мощности при сохранении высоких показателей скорости захвата объекта и достигнуть нулевого коэффициента пропуска.

Алгоритм сбора распознанных объектов. Предложенная модель (рис. 10) позволяет разработать и исследовать алгоритм сбора распознанных объектов с конвейерной ленты. Предварительно в модели производится эмуляция работы СТЗ, для чего перед рабочей зоной манипулятора на конвейере генерируются произвольно расположенные объекты с заданной плотностью и известными координатами их геометрических центров.

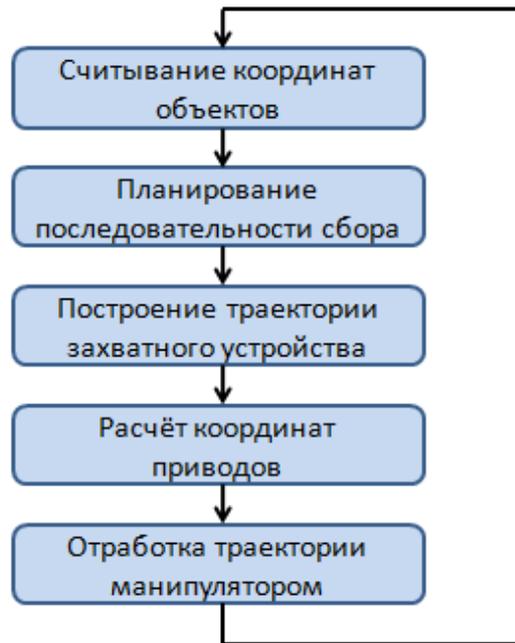


Рисунок 13 – Алгоритм сбора объектов с конвейерной ленты

Рассмотрим последовательность этапов алгоритма (рис. 13):

- контроллер планирования (рис. 2, б), имея список обнаруженных объектов, рассчитывает последовательность их сбора с конвейера. Определяется приоритет объектов – первыми собираются те, которые раньше всего выйдут из рабочей зоны. При этом просчитывается, успеет ли манипулятор захватить данный объект, если нет – объект игнорируется, т.е. на манипулятор не подаются исполнительные команды;
- сформировав последовательность сбора, контроллер планирования строит траектории перемещения захватного устройства манипулятора.
- сформированная последовательность перемещения захватного устройства путем решения обратной кинематической задачи пересчитывается в необходимые координаты поворота приводов манипулятора;
- манипулятор отрабатывает сформированные последовательности операций.

Примечание. Как отмечалось, если манипулятор не захватывает объект, аналогичные действия выполняет второй манипулятор, расположенный далее по ходу конвейера (рис. 2).

Выполненное исследование зависимости K_{loss} от параметров работы позволяет рассчитать предполагаемую загрузженность манипуляторов и определить их необходимое количество, что в свою очередь позволяет распределить объемы работы между манипуляторами и добиться их равномерной занятости с гарантированным захватом объектов.

В результате моделирования данного алгоритма были получены графики траектории движения захватного устройства манипулятора при осуществлении сбора объектов (рис. 14).

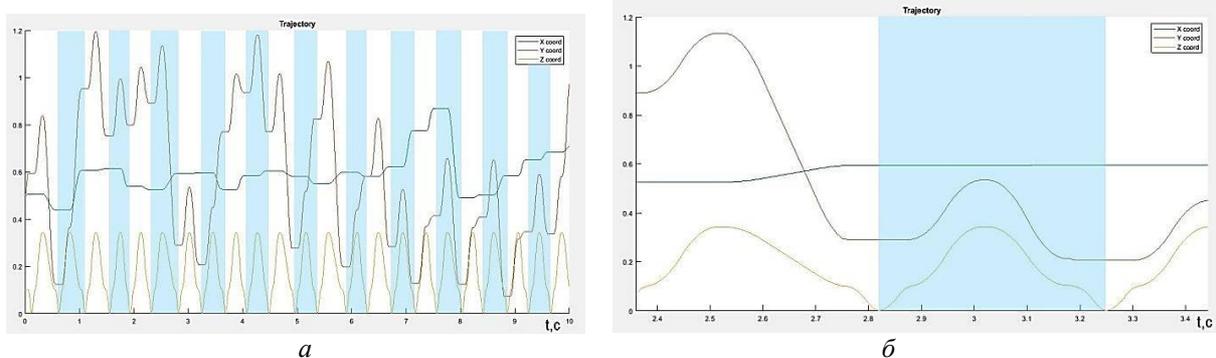


Рисунок 14 – Траектория перемещения захватного устройства при моделировании сбора 23-х объектов в течение 10 с (а) и за 2 цикла сбора по 0,4 с (б). По вертикальной оси отложены координаты X, Y, Z, каждой из которых соответствует свой график

Циклы обозначены чередующимися вертикальными полосами. Траектория захватного устройства в проекциях на оси OX , OY и OZ отложена по оси ординат, временная шкала отложена по оси абсцисс. Вид траекторий в осях $X-Y$ и $X-Y-Z$ приведен на рисунке 15.

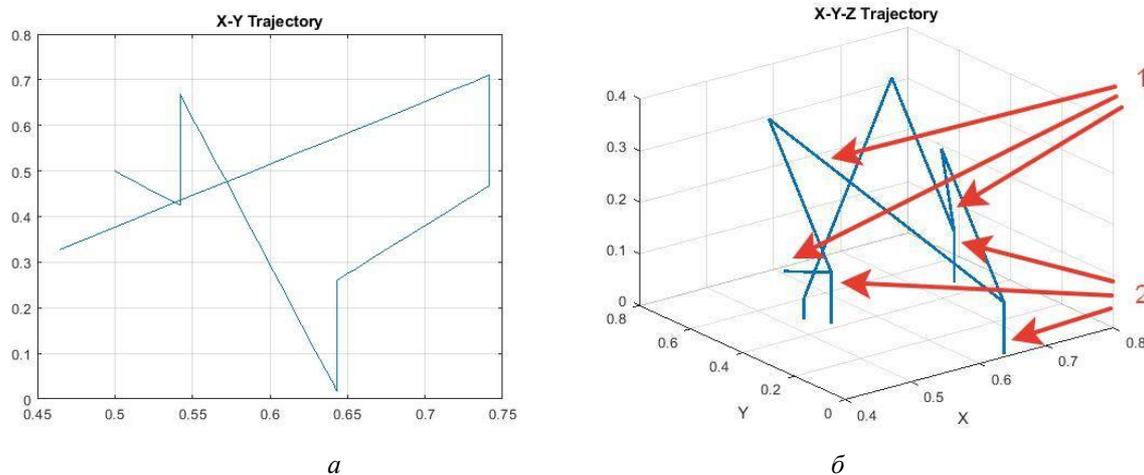


Рисунок 15 – Траектория перемещения захватного устройства манипулятора за 3 цикла сбора в осях: *a* – $X-Y$; *б* – $X-Y-Z$, где 1 – фаза наведения, 2 – фаза захвата

Полученные графики хорошо иллюстрируют циклическую работу алгоритма управления манипулятором и перемещения его захватного устройства. Подъем объекта с конвейерной ленты происходит вдоль оси OZ , перемещение в плоскости ленты – вдоль осей OX и OY . Каждый цикл захватное устройство манипулятора подходит к точке над объектом и опускается для его захвата. Затем осуществляется подъем выбранного объекта вверх и его доставка до одного из контейнеров (соответственно классу объекта). Новый цикл начинается с перемещения к следующему объекту из списка обнаруженных с помощью СТЗ.

Выводы. В результате выполнения данной работы получена общая схема РКДС и структура его системы управления. Предложено использовать иерархическую систему управления, включающую следующее: 1) уровень детектирования с СТЗ, выполняющей обнаружение объектов; 2) сортировочный уровень, осуществляющий планирование захвата и собственно захват обнаруженных объектов, их транспортировку в контейнеры.

Предложена структура СТЗ на основе двух сверточных нейронных сетей: AlexNet для классификации изображений и U-Net для детектирования объектов на изображении. Представлены коэффициенты обучения, алгоритмы оптимизации и результаты обучения ИНС, на примере объектов четырех классов. Показан фрагмент датасета (набора) изображений, использованного для тренировки ИНС. Приведен пример работы СТЗ при детектировании электронных компонентов на тестовом изображении.

Разработана модель дельта-манипулятора и определены его основные параметры. Описана зависимость коэффициента пропуска объектов манипулятором от скорости конвейера, плотности размещения объектов, а также максимальных значений скорости и ускорения манипулятора. Показано, что при плотности появления объектов до 12 об/с и скорости конвейера до 0,4 м/с, несмотря на варьирование скорости и ускорения манипулятора, потери объектов сводятся к нулю. Представлен алгоритм сбора объектов с конвейерной ленты и получены графики перемещения захватного устройства манипулятора при сборе распознанных объектов с конвейерной ленты.

Предложенный в статье РКДС позволяет заменить людей, выполняющих монотонный труд в опасной и вредной для жизнедеятельности среде. Комплекс способен выполнять сортировку ТБО круглосуточно, увеличивая время работы мусороперерабатывающего завода минимум в 2 раза. С внедрением такого решения также повысится качество сортировки и будет осуществлена оптимизация процесса переработки в целом. В конечном счете это приведет к повышению рентабельности работы завода.

Библиографический список

1. Инфографика. Пути отходов // Вокруг света. – 2012. – № 7. – С. 22.
2. Образование отходов производства и потребления по видам экономической деятельности по Российской Федерации // Федеральная служба государственной статистики : крат. стат. сб. – Москва : Росстат, 2018 – 522 с.
3. Росприроднадзор. Доклад «О ходе работ по выявлению и понуждению к ликвидации мест несанкционированного размещения твердых бытовых отходов в 2012 году». – Режим доступа: http://rpn.gov.ru/sites/all/files/documents/doklady/doklad_na_nevskiy_kongress-dlya_zhigileya.doc, свободный. – Заглавие с экрана. – Яз. рус. (дата обращения 10.04.2019).

4. Садыков С. С. Распознавание наложенных реальных плоских объектов по безразмерным признакам контуров их изображений / С. С. Садыков, Я. Ю. Кульков // Прикаспийский журнал: управление и высокие технологии. – 2016. – № 4 (36). – С. 10–20.
5. Сироткин И. А. Нейросетевая система управления манипулятором доильного робота / И. А. Сироткин, С. А. Воротников // Прикаспийский журнал: управление и высокие технологии. – 2018. – № 1 (41). – С. 205–215.
6. ABB Robotics. IRB 360 FlexPicker. Product specification. – Режим доступа: <https://new.abb.com/products/robotics/ru/Industrial-robots/irb-360>, свободный. – Заглавие с экрана. – Яз. рус. (дата обращения 10.04.2019).
7. Agnieszka Mikołajczyk. Data augmentation for improving deep learning in image classification problem / Agnieszka Mikołajczyk, Michał Grochowski // 2018 International Interdisciplinary PhD Workshop (IIPHDW). – May 2018. – P. 117–122. DOI: 10.1109/IIPHDW.2018.8388338.
8. Alex Krizhevsky. ImageNet Classification with Deep Convolutional Neural Networks / Alex Krizhevsky, Ilya Sutskever, Geoffrey E. Hinton. – 17 November 2013. – P. 1–9.
9. Black Dog Publishing Recycle: a source book. – London, UK : Black Dog Publishing, 2006.
10. Bleiwas D. "Obsolete Computers, "Gold Mine," or High-Tech Trash? Resource Recovery from Recycling" (PDF) / D. Bleiwas // USGS. – March 4, 2019. – P. 1–4.
11. Gershman, Brickner & Bratton, Inc. American Chemistry Council. The Evolution of Mixed Waste Processing Facilities 1970-Today. – 2015. – 62 p.
12. Hoo-Chang Shin. Deep Convolutional Neural Networks for Computer-Aided Detection: CNN Architectures, Dataset Characteristics and Transfer Learning / Hoo-Chang Shin, Holger R. Roth, Mingchen Gao et al. // IEEE Transaction on Medical Imaging. – 2016. – P. 1285–1298.
13. Irwin Sobel. History and Definition of the Sobel Operator / Irwin Sobel. – Режим доступа: <https://ru.scribd.com/document/271811982/History-and-Definition-of-Sobel-Operator>, свободный. – Заглавие с экрана. – Яз. англ. (дата обращения 10.04.2019).
14. Olaf Ronneberger. U-Net – Convolutional networks for biomedical image segmentation / Olaf Ronneberger, Philipp Fischer, Thomas Brox // Computer Vision and Pattern Recognition. – 2015. – P. 234–241.
15. Raymond Clavel. Conception d'un robot parallele rapide à 4 degrés de liberté. These # 925 / Raymond Clavel. – EPFL, 1991. – 146 p.
16. Recycling through the ages: 1970s. Plastic Expert. – 30 July 2014. – Retrieved 7 March 2015.
17. Ross Girshick. Fast R-CNN / Ross Girshick // Microsoft research. – 2015. – P. 1–9.
18. Shaoqing Ren. Faster R-CNN. Towards real-time object detection with region proposal networks / Shaoqing Ren, Kaiming He, Ross Girshick Jian Sun // Microsoft Research. – 2015. – P. 1–14.
19. West Jeremy. Spring Research Presentation: A Theoretical Foundation for Inductive Transfer / West Jeremy, Ventura Dan, Warnick Sean. – Brigham Young University, College of Physical and Mathematical Sciences, 2017. – Archived from the original on 2007-08-01. Retrieved 2007-08-05.
20. What a Waste 2.0: A Global Snapshot of Solid Waste Management to 2050. – Режим доступа: <http://datatopics.worldbank.org/what-a-waste/>, свободный. – Заглавие с экрана. – Яз. англ. (дата обращения 10.04.2019).
21. LeCun Y. Backpropagation Applied to Handwritten Zip Code Recognition / Y. LeCun, B. Boser, J. S. Denker, D. Henderson, R. E. Howard, W. Hubbard and L. D. Jackel // Neural Computation. – 1989. – № 1 (4). – P. 541–551.

References

1. Infografika. Puti otkhodov [Infographics. Ways of waste]. *Vokrug sveta* [Around the world], 2012, no. 7, pp. 22.
2. Obrazovaniye otkhodov proizvodstva i potrebleniya po vidam ekonomicheskoy deyatelnosti po Rossiyskoy Federatsii [Formation of production and consumption waste by type of economic activity in the Russian Federation]. *Federalnaya sluzhba gosudarstvennoy statistiki* [Federal State Statistics Service]. Moscow, Rosstat, 2018. 522 p.
3. Rosprirodnadzor. Doklad «O provedenii rabot po vyyavleniyu i snizheniyu sprosna na bytovyye otkhody v 2012 godu» [Rosprirodnadzor. Report "On the progress of work to identify and compel the elimination of places of unauthorized disposal of municipal solid waste in 2012"]. Available at: http://rpn.gov.ru/sites/all/files/documents/doklady/doklad_na_nevskiy_kongress-dlya_zhigileya.doc (accessed 10.04.2019).
4. Sadykov S. S., Kulkov I. Yu. Raspoznavaniye nalozhennykh realnykh ploskikh obyektov po bezrazmernym priznakam konturov ikh izobrazheniy [Recognition of superimposed real flat objects on the dimensionless signs of the contours of their images]. *Prikaspiyskiy zhurnal: upravlenie ivysokie tekhnologii* [Caspian Journal: Control and High Technologies], 2016, no. 4 (36), pp. 10–20.
5. Sirotkin I. A., Vorotnikov S. A. Neyrosetevaya sistema upravleniya manipulyatorom doilnogo robota. [The network control system of manipulator of a milking robot]. *Prikaspiyskiy zhurnal: upravlenie ivysokie tekhnologii* [Caspian Journal: Control and High Technologies], 2018, no. 1 (41), pp. 205–215.
6. ABB Robotics. IRB 360 FlexPicker. Product specification. Available at: <https://new.abb.com/products/robotics/ru/Industrial-robots/irb-360> (accessed 10.04.2019).
7. Agnieszka Mikołajczyk, Michał Grochowski. Data augmentation for improving deep learning in image classification problem. *2018 International Interdisciplinary PhD Workshop (IIPHDW)*, May 2018, pp. 117–122. DOI: 10.1109/IIPHDW.2018.8388338.
8. Alex Krizhevsky, Ilya Sutskever, Geoffrey E. Hinton. *ImageNet Classification with Deep Convolutional Neural Networks*, 17 November 2013, pp. 1–9.
9. Black Dog Publishing Recycle: a source book. London, UK, Black Dog Publishing, 2006.
10. Bleiwas D. "Obsolete Computers, "Gold Mine," or High-Tech Trash? Resource Recovery from Recycling" (PDF). *USGS*, March 4, 2019, pp. 1–4.

11. Gershman, Brickner & Bratton, Inc. American Chemistry Council. *The Evolution of Mixed Waste Processing Facilities 1970-Today*, 2015. 62 p.
12. Hoo-Chang Shin, Holger R. Roth, Mingchen Gao et al. Deep Convolutional Neural Networks for Computer-Aided Detection: CNN Architectures, Dataset Characteristics and Transfer Learning. *IEEE Transaction on Medical Imaging*, 2016, pp. 1285–1298.
13. Irwin Sobel, History and Definition of the Sobel Operator. Available at: <https://ru.scribd.com/document/271811982/History-and-Definition-of-Sobel-Operator> (accessed 10.04.2019).
14. Olaf Ronneberger, Philipp Fischer, Thomas Brox. U-Net – Convolutional networks for biomedical image segmentation. *Computer Vision and Pattern Recognition*, 2015, pp. 234–241.
15. Raymond Clavel. Conception d'un robot parallele rapide à 4 degrés de liberté. These # 925. *EPFL*, 1991. 146 p.
16. *Recycling through the ages: 1970s. Plastic Expert*, 30 July 2014, Retrieved 7 March 2015.
17. Ross Girshick. Fast R-CNN. *Microsoft research*, 2015, pp. 1–9.
18. Shaoqing Ren, Kaiming He, Ross Girshick Jian Sun. Faster R-CNN. Towards real-time object detection with region proposal networks. *Microsoft Research*, 2015, pp. 1–14.
19. West Jeremy, Ventura Dan, Warnick Sean. *Spring Research Presentation: A Theoretical Foundation for Inductive Transfer*. Brigham Young University, College of Physical and Mathematical Sciences, 2007, Archived from the original on 2007-08-01, Retrieved 2007-08-05.
20. What a Waste 2.0: A Global Snapshot of Solid Waste Management to 2050. Available at: <http://datatopics.worldbank.org/what-a-waste/> (accessed 10.04.2019).
21. LeCun Y., Boser B., Denker J. S., Henderson D., Howard R. E., Hubbard W. and Jackel L. D. Backpropagation Applied to Handwritten Zip Code Recognition. *Neural Computation*, 1989, no. 1 (4), pp. 541–551.

УДК 621.311.24 (06)

ОСОБЕННОСТИ ЭЛЕКТРОМЕХАНИЧЕСКОГО УПРАВЛЕНИЯ КОМПЛЕКСНОЙ СИЛОВОЙ ЭНЕРГЕТИЧЕСКОЙ УСТАНОВКОЙ С ВЕТРОЭНЕРГЕТИЧЕСКИМИ УСТАНОВКАМИ ВИХРЕВОГО ТИПА

Статья поступила в редакцию 15.05.2019, в окончательном варианте – 28.05.2019.

Костюков Владимир Александрович, Южный федеральный университет, 347900, Российская Федерация, г. Таганрог, ул. Шевченко, 2,
кандидат технических наук, доцент, e-mail: wkost-einheit@yandex.ru
Медведев Михаил Юрьевич, Южный федеральный университет, 347900, Российская Федерация, г. Таганрог, ул. Шевченко, 2,
доктор технических наук, профессор, e-mail: medvmihal@sfedu.ru
Полюянович Николай Константинович, Южный федеральный университет, 347900, Российская Федерация, г. Таганрог, ул. Шевченко, 2,
кандидат технических наук, доцент, e-mail: nik1-58@mail.ru

Рассматриваются возможности стабилизации частоты вращения ротора вертикально-осевой ветроэнергетической установки, которая может входить в качестве элемента в комплексную силовую энергетическую установку для дополнительного и аварийного электропитания надводных робототехнических комплексов. С этой целью в работе предлагается использовать метод стабилизации угловой скорости путем управления положением подвижного элемента конструкции рассматриваемой установки. Получен соответствующий закон регулирования угловой скорости вращения ротора. Проведено моделирование уравнений системы стабилизации частоты вращения ротора при аperiodическом ветровом возмущении. Показано, что построенный регулятор способен эффективно парировать влияние ветровых возмущений. Синтезирован регулятор, позволяющий осуществлять стабилизацию частоты вращения ротора ветроэнергетической установки вихревого типа с использованием изменяемых элементов геометрии ветроэнергетической установки. Регулятор способен поддерживать значение угловой скорости ротора при ветровых возмущениях с амплитудой аperiodической составляющей не более 2,5 м/с при длительности переходного процесса не более 6 секунд. Это достигается при значительном динамическом диапазоне изменения управляющей величины h . Использование данного способа регулирования скорости ротора ветроэнергетической установки позволит значительно повысить адаптивность системы управления в отношении её выходных характеристик; существенно расширить динамический диапазон регулирования момента на роторе ветроэнергетической установки, а также повысить робастность указанных характеристик к внешним ветровым и внутренним конструкционным параметрическим возмущениям.

Ключевые слова: вихревая ветроэнергетическая установка, аэродинамический момент, ротор, изменяемые элементы геометрии, ветровые возмущения, стабилизация, частота вращения ротора