

Интернет-журнал «Отходы и ресурсы» <https://resources.today>
Russian Journal of Resources, Conservation and Recycling

2024, Том 11, № 2 / 2024, Vol. 11, Iss. 2 <https://resources.today/issue-2-2024.html>

URL статьи: <https://resources.today/PDF/04INOR224.pdf>

DOI: 10.15862/04INOR224 (<https://doi.org/10.15862/04INOR224>)

2.3.3. Автоматизация и управление технологическими процессами и производствами (технические науки)

Ссылка для цитирования этой статьи:

Прокашев, В. А. Возможности улучшения применения компьютерного зрения в сортировке твёрдых коммунальных отходов / В. А. Прокашев // Отходы и ресурсы. — 2024. — Т. 11. — № 2. — URL: <https://resources.today/PDF/04INOR224.pdf> DOI: 10.15862/04INOR224

For citation:

Prokashev V.A. Opportunities for improving the use of computer vision in municipal solid waste sorting. *Russian Journal of Resources, Conservation and Recycling*. 2024;11(2): 04INOR224. Available at: <https://resources.today/PDF/04INOR224.pdf>. (In Russ., abstract in Eng.) DOI: 10.15862/04INOR224

УДК 658.567.1 (004.896)

Прокашев Виталий Андреевич

ФГАОУ ВО «Национальный исследовательский технологический университет «МИСИС», Москва, Россия
Аспирант

E-mail: vitalyaprocashev@gmail.com; vitalya-procashev@yandex.ru

ORCID: <https://orcid.org/0009-0005-6793-7257>

Возможности улучшения применения компьютерного зрения в сортировке твёрдых коммунальных отходов

Аннотация. В представленной статье исследуются возможности улучшения применения оптической сортировки твердых коммунальных отходов на конвейерных лентах с использованием технологий компьютерного зрения и машинного обучения в целях замещения линий ручной сортировки. Подчеркивается актуальность улучшения сортировки отходов. Данная работа расширяет понимание применения компьютерного зрения в области утилизации отходов и предлагает практические рекомендации для их внедрения в промышленные процессы.

В работе рассматриваются текущие подходы в сортировке твердых коммунальных отходов, анализируется их эффективность, исследуется потенциал улучшения процессов управления отходами и повышения эффективности переработки на основе недавних исследований в данной области. Рассмотрено наиболее популярное применяемое в сортировке оборудование и его особенности.

Также проводится обобщение морфологического состава отходов, выделяется минимальная и максимальная возможные доли каждого класса отходов в потоке переработки. На основании этих данных выделены достаточные доли изображений в каждой категории для обучения сверточной нейросети в целях классификации отходов.

Рассматриваются прикладные исследования в части детектирования и классификации объектов отходов на конвейерных лентах с использованием известных архитектур нейросетей. Анализ показал, что большинство решений опираются на архитектуры 2018 года, при этом эталонная точность классификации более современных архитектур, например OmniVec, на 17 % выше, на схожие порядки выше и эффективность детектирования. На результирующую

точность классификации значительно влияет аугментация изображений в наборе изображений для обучения нейросети — ее наличие может повысить точность от 10 до 15 %. Определен минимальный набор данных для обучения, который должен составлять порядка 2 000 изображений ввиду того, что после дальнейшего увеличения количества точность начинает выходить на плато.

Ключевые слова: твердые коммунальные отходы; компьютерное зрение; сверточные нейронные сети; детектирование объектов; классификация; сортировка; морфологический состав

Введение

За 2022 г. среднестатистический россиянин оставил после себя 312,6 кг отходов — почти килограмм в день¹, по данным Росстата, в 2021 году российская экономика сгенерировала 8,5 млрд тонн отходов.² Подавляющее большинство в этой статистике — промышленные отходы — например, горная порода, отходы химических производств и пр. Горнодобывающая промышленность, производит основную часть отходов — 7,7 млрд тонн из них $\frac{3}{4}$ — это угольная промышленность. Мусор, который коммунальные службы вывозят на свалки или специальные перерабатывающие заводы, называют твердыми коммунальными отходами (ТКО, до 2015 года такой класс отходов именовали твердыми бытовыми отходами — ТБО), и он составляет около 1 % от всех отходов.

Таких отходов в России ежегодно получается около 50 млн тонн. Количество бытового мусора растет: за двадцать лет объем ТКО вырос вдвое. Согласно отчету счетной палаты³, в России 93 % таких отходов утилизируется на полигонах, а 7 % перерабатывается. В странах с развитой переработкой перерабатывается от 25 до 30 % ТБО, а 30–50 % компостируется. В этих странах на полигоны идет значительно меньшая часть: от 1 % до 45 %.

По данным российской газеты⁴, от общего объема перерабатывается 15 % стекла, 14 % полимеров, 13 % органики, 11 % макулатуры, 3 % металлов.

Существует федеральный проект по переработке отходов⁵, его цели в цифрах: к 2030 научиться сортировать все виды отходов, а также перерабатывать половину от ТБО; обрабатывать 25 % от промышленных отходов; сделать вторсырье конкурентным на рынке и увеличить его долю в выпускаемой продукции.

¹ Газета “Ведомости”, август 2023 — URL: <https://www.vedomosti.ru/ecology/esg/articles/2023/08/16/990327-rossiyane-stali-vibrasivat-menshe-musora> (Дата обращения: 01.05.2024).

² Данные Росстата за 2021 год — URL: https://rosstat.gov.ru/storage/mediabank/oxr_otxod1-okved2.xls (Дата обращения: 01.05.2024).

³ Отчет о результатах экспертно-аналитического мероприятия «Анализ выполнения мероприятий, обеспечивающих экологическую безопасность Российской Федерации, в части ликвидации объектов накопленного вреда и формирования комплексной системы обращения с твердыми коммунальными отходами», Счетная палата Российской Федерации, 2020 — URL: <https://ach.gov.ru/upload/iblock/41b/41b02dc50697e6fc57ec2f389a8b68f0.pdf> (Дата обращения: 01.05.2024).

⁴ “Сколько вторсырья получается выделять из бытового мусора” информационное агентство RG — URL: <https://rg.ru/2022/01/19/skolko-vtorsyria-poluchaetsia-vydeliat-iz-bytovogo-musora.html> (Дата обращения: 01.05.2024).

⁵ Министерство природных ресурсов и экологии Российской Федерации, “Федеральный проект по переработке отходов” от 2014 года — URL: https://www.mnr.gov.ru/activity/np_ecology/federalnyy-proekt-kompleksnaya-sistema-obrashcheniya-s-tverdymi-kommunalnymi-otkhodami/ (Дата обращения: 01.05.2024).

Таким образом, помимо понятной пользы для экологии и сохранения природных ресурсов, актуальность развития переработки ТКО, и, в частности, направления сортировки на определенных стадиях, также подкрепляется федеральным проектом.

Сейчас ТКО разделяются на разные категории с помощью комбинации ручной и автоматической сортировки. Обычно этапами разделения на продвинутых предприятиях являются: механическое просеивание, магнитная сепарация, оптическая сортировка и ручная сортировка в конце процесса, которая как раз может быть автоматизирована с использованием технологий компьютерного зрения и манипуляторами. Различные категории перерабатываемых материалов и ожидаемый уровень их чистоты часто определяются в договорных минимальных технических требованиях, заключенных с конечными покупателями и местными властями. Чтобы быть эффективным в конкурентной и меняющейся среде, процесс сортировки должен обеспечивать хорошее соотношение между чистотой сортируемого материала и стоимостью его переработки. Он также должен быть гибким для обращения с новыми отходами и новыми типами вторичной переработки.

В настоящее время контроль чистоты отсортированного вторсырья достигается количественно путем ручного отбора проб и сортировки отходов в конце сортировочных линий и качественно с помощью визуального контроля человеком упакованных выходных материалов. Помимо того, что эта задача мешает процессу сортировки, она требует много времени, и результаты достигаются после того, как охарактеризованные отходы будут упакованы в тюки. Можно подчеркнуть, что сейчас нет массовых эксплуатируемых решений, позволяющих узнать в режиме реального времени характеристики отходов на любой стадии процесса, при этом технологии компьютерного зрения уже на том этапе развития, который позволяет подобное решение создать и внедрить.

Целью данного исследования является анализ опыта применения компьютерного зрения для сортировки ТКО, работ других исследователей, посвящённых сортировке и переработки ТКО, выявление возможностей для совершенствования существующих методов сортировки и переработки.

Материалы и методы

Материалами данного исследования являются: публикации посвященные методам сортировки твердых коммунальных отходов; исследования, касающиеся прикладного применения компьютерного зрения и машинного обучения в классификации твердых коммунальных отходов; исследования и открытые репозитории с кодом по реализации компьютерного зрения. При исследовании применялись логические методы анализа, обобщения и синтеза, статистические методы.

Основная часть

1. Как сейчас проводится сортировка

Предварительная сортировка является одним из основных подходов в обращении с ТКО. В настоящие дни основные методы сортировки в подавляющем большинстве включают в себя элемент ручной сортировки. К ручной сортировке добавляют дополнительные автоматизации, например, применяют барабанные сепараторы как в горно-обогатительной промышленности, которые отделяют отходы бумаги и пленки, а также магнитную сепарацию, при которой выделяются определенные виды металла [1].

Методы сортировки и выделения из них ресурсов для повторного использования можно разбить на основании способа предварительной подготовки отходов: с измельчением или без измельчения. Также методы можно рассматривать по характеру разделения: аэросепарация,

механическая, магнитная и гидравлическая сепарации. Наибольшее распространение получили: магнитная сепарация для выделения металлов и аэросепарация для выделения легких фракций. Во время ручной сортировки распознавание материалов производится визуально и разделение на фракции осуществляется вручную. В основном, ручной сортировке подвергается материал класса грохочения +200 мм и +300 мм. Возможности одной линии сортировки, различаются в зависимости от состава ТКО и в целом составляют около 3 т/час. Эффективность данной сортировки во многом зависит от организации процессов на предприятии. При автоматизированной сортировке какие-то дополнительные операции (подача потока ТКО на ленту, предсортировка по крупности, измельчение) механизированы, но распознавание в основном все еще осуществляется человеком [2].

Ручная предсортировка необходима на линиях по производству вторичного топлива RDF (от англ. «refuse derived fuel») для выделения инертных материалов, что влечет за собой соответствующие издержки трудовых ресурсов. Авторы исследования по извлечению RDF из ТКО отмечают, что человек не может опознать объект в потоке с размерами менее 5 см, что приводит к потере значащей доли конечного продукта, как в случае топлива, так и при выявлении другого вторсырья [3].

На линиях автоматической сортировки ТКО процесс сортировки отходов происходит без участия персонала. В основном, в базе автоматической сортировки лежит использование оптических сенсоров для определения материалов путем облучения потока отходов излучением с разной длиной волны от и последующего спектрального анализа отраженного излучения от материала.

Методы оптической сортировки в зависимости от диапазонов используемых электромагнитных излучений подразделяются на рентгенофлуоресцентный анализ и рентгеновскую трансмиссию (с длиной волны 10^{-12} – 10^{-9} м), лазерно-искровую эмиссионную спектроскопию (с длиной волны 10^{-9} – $4 \cdot 10^{-7}$ м), спектроскопию в видимой области (с длиной волны $4 \cdot 10^{-7}$ – $8 \cdot 10^{-7}$ м), ближнюю инфракрасную спектроскопию (или БИК с длиной волны $8 \cdot 10^{-7}$ – $3 \cdot 10^{-5}$ м), терагерцевую спектроскопию (с длиной волны $3 \cdot 10^{-5}$ – $3 \cdot 10^{-3}$ м) [4].

Ручная сортировка осуществляется на конвейерных лентах: когда оператор видит объект определенного класса, он перемещает его в бак соответствующей категории. Замещение такой сортировки автоматизацией подразумевает применение камер, которые передают изображение на компьютер или облачный сервер, на которых работает обученная нейронная сеть — она выделяет границы объектов в кадре, определяет их класс и передает соответствующий сигнал манипулятору. Манипуляторы в данном случае осуществляют работу по переносу объекта за человека. В качестве манипуляторов применяются в основном пневматические ввиду их большей скорости работы, подобный манипулятор изображен на рисунке 1.

В одной из работ подробно разбирался механизм работы сортировки на базе подобных манипуляторов и было произведено исследование двух подходов «взять и разместить» объект и «взять и бросить» объект. В подходе «взять и разместить» время сортировки одного объекта составляло от 0,3 до 0,55 секунд, а в подходе «взять и бросить» от 0,25 до 0,43 секунд. Таким образом, в подходе «взять и бросить» обрабатывается больше предметов, пригодных для вторичной переработки за единицу времени, а также расширяется эффективный диапазон роботов, делая доступные контейнеры, расположенными за пределами их первоначальной рабочей области [5]. В части использования подобных систем также стоит упомянуть проект Института теплофизики имени С.С. Кутателадзе Сибирского отделения РАН (Новосибирск).⁶

⁶ Результаты работы первого российского робота-сортировщика мусора, Аналитический центр “Эксперт”, 2023 — URL: <https://expert-ural.com/archive/nomer-6-9-875/poyavilis-rezultati-raboti-pervogo-rossiyskogo-robota-sortirovshika-musora.html> (Дата обращения: 01.05.2024).



Рисунок 1. Пневматический манипулятор, применяемый для сортировки на конвейерных лентах (фото с сайта, URL: <https://spectrum.ieee.org/ai-guided-robots-are-ready-to-sort-your-recyclables>)

При распознавании объектов на изображениях играет роль не только их цвет, форма, варианты деформации, а также этикетки. Если при обучении нейросети заложить известные сведения о тарах конкретных продуктов, благодаря их этикетки возможно определить, что бутылка изготовлена из пластика определенного класса, что позволит определить дальнейшую стадию переработки для пластика данного вида [6]. Другое дело встает вопрос актуализации обученной нейросети при обновлении дизайна тар и появлении новых.




Рисунок 2. Обобщенная схема разделения ТКО с применением оптической сортировки на основе компьютерного зрения (разработано автором)

Системы сортировки на современных фабриках всегда комбинированные и имеют несколько этапов. На рисунке 2 изображен обобщённый пример подобной схемы, с выделением возможных стадий сортировки с использованием компьютерного зрения и пневматических манипуляторов.

Как видно из рисунка 2, на входе проводится предварительная сортировка — в мусоре могут содержаться какие-то неожиданные объекты, которые не были включены в обучающую выборку нейросети ввиду большой редкости и для которых нет возможности разделения какими-либо другими методами. На этой стадии возможно сделать детектирование особых, крупных объектов, но в любом случае манипуляции, скорее всего, придется совершать человеку. Далее наклонный валковый щеточный сепаратор отделяет картон, бумагу и текстиль от тяжелых фракций: стекла, металла и пластика, затем бумага, картон и текстиль сортируются на соответствующие группы с использованием системы компьютерного зрения.

Ниже на смешанной линии находится стеклоломатель — стекло крошится на мелкодисперсную фракцию и сваливается на нижнюю конвейерную ленту, далее путем магнитной сепарации отделяются ферромагнитные металлы, потом неферромагнитные путем воздействия на них индукционного сепаратора. В итоге, на линии остается пластик, и с помощью системы компьютерного зрения он разделяется на соответствующие категории [6].

Стоит отметить, что для надлежащего использования подобных схем важно небольшое содержания в ТКО пищевых и растительных отходов (порядка 5–7 %), на данный момент доля органических отходов в потоке переработки в России в среднем составляет 28 %.⁷ Органические отходы загрязняют сырье и делают его малопригодным для вторичного использования и более сложным для распознавания. Поэтому крайне желательно на бытовом уровне прийти хотя бы к бинарной сортировке на органику и потенциальное вторсырье.

2. Морфологический и компонентный состав твёрдых коммунальных отходов и критерии их сортировки

Для обучения нейросети, чтобы проводить сортировку с использованием компьютерного зрения, важно понимать морфологический состав ТКО. Знания о составе может помочь подобрать оптимальное соотношение изображений для обучающей выборки. В России состав ТКО жилых районов разнится по регионам и зависит от сезонности. Можно найти множество подсчетов с различными методиками и объемами выборки [7–9].

Сведения о граничном составе той или иной категории позволит определить достаточный объем изображения для категории, чтобы обученный алгоритм мог работать одинаково хорошо вне зависимости от сезонности и региона.

Рассчитывать долю изображений категорий для обучающей выборки можно как среднюю долю по каждой категории, нормированную на 100 %, согласно формуле:

$$p_i = \frac{\bar{c}_i}{\sum_{i=1}^n \bar{c}_i} \cdot 100 \%, \quad (1)$$

где p_i — доля изображений категории в обучающей выборке; $\bar{C}_i$ — усредненная доля категории по массе.

При обобщении данных из указанных выше источников можно выделить категории и их состав в процентном соотношении по массе, а также рассчитать необходимую долю изображений в выборке, что представлено в таблице 1.

⁷ Органические отходы Самарской области, 2024 — URL: <https://ecostr.ru/novosti/organicheskie-othody-samarskoj-oblasti/> (Дата обращения: 01.05.2024).

Таблица 1

**Морфологический состав ТКО в % по массе
и необходимая доля изображений в обучающей выборке в %**

Категория	Доля категории по массе от и до, %	Доля изображений в обучающей выборке, %
Бумага и картон	5–32	16
Пищевые отходы	26–45	30
Пластмассы	3–17	9
Металлы	2–7	4
Стекло	1–12	6
Текстиль	2–7	4
Кожа и резина	1–5	3
Дерево	2–9	5
Несортируемые отходы, отсев и прочее	7–51	25

Составлено автором

Стоит отметить, что в общем потоке переработке встречаются довольно ценные компоненты в виде электроники и бытовой техники, из которых можно извлечь пусть и не самым простым способом редкоземельные элементы, цветные металлы, и отдельные неповрежденные микросхемы. Среди электроники стоит выделить отдельную категорию — батарейки и аккумуляторы.

Согласно Роспотребнадзору аккумуляторы составляют около 0,25 % от объёма всего собираемого в мегаполисах мусора⁸, но несмотря на малую долю на них приходится до 40 % токсичных веществ, попадающих в окружающую среду вместе с ТКО.⁹ Поэтому ввиду ценности электроники и опасности батареек эти категории также целесообразно включать в выборку для автоматизированной сортировки в предварительном этапе.

Таблица 2

Категоризация отходов по типу формы и пористости

Категория отходов	Средняя плотность (кг м ⁻³)	Среднеквадратичное отклонение (кг м ⁻³)	Тип формы	Пористость
Гофрированный картон	756	105	Плоская	0,902
Многослойный картон	822	46	Призматическая	0,953
Плоский картон	892	188	Плоская	0,907
Газеты, журналы	1 004	117	Плоская	0,894
Смешанная бумага	967	101	Плоская	0,870
Битое стекло	2 584	197	Кубическая	0,769
Целое стекло			Цилиндрическая	0,896
РЕТ (Полиэтилентерефталат)	1 339	78	Призматическая	0,978
HDPE (Полиэтилен высокой плотности)	971	30	Призматическая	0,965
Пластиковые пленки/пакеты	697	51	Плоская	0,966
Смешанный пластик (PP)	873	41	Призматическая	0,960
Черные металлы	7 030	525	Цилиндрическая	0,987
Цветные металлы	1 957	290	Цилиндрическая	0,978

На основе данных исследования [10]

⁸ Чем опасны батарейки. ФБУЗ «Центр гигиенического образования населения» Роспотребнадзора. — URL: <https://cgon.rospotrebnadzor.ru/naseleniyu/zdorovyy-obraz-zhizni/chem-opasny-batareyki/> (Дата обращения: 01.05.2024).

⁹ Отрабатывшая батарейка как опасный отход. Отходы и окружающая среда. — URL: https://zaobt.ru/wp-content/uploads/2015/06/Otrabotavshaya_batarejka_kak_opasnyj_otxod.pdf (Дата обращения: 01.05.2024).

В одной из работ, были определены типичный состав, объемная плотность и плотность материала на основе взвешивания в воде и воздухе, а также размер частиц для нескольких категорий усредненных городских отходов Квебека, обычно встречающихся в смешанных потоках переработки, на основе отбора пробы в 302 кг вторсырья. Был определен тип формы каждой категории и рассчитана пористость как $1 - \frac{\text{объемная плотность}}{\text{плотность материала}}$. В таблице 2 приведены данные по различным категориям отходов в выборке [10].

Данные по типу формы материалов можно использовать как подкласс для определения более точных категорий при построении модели нейронной сети для классификации и могут помочь эффективно организовать стадии сортировки вторсырья, подобрать параметры сортирующего оборудования.

3. Оборудование, используемое для оптической сортировки твёрдых коммунальных отходов

Компания TOMRA Sorting Solutions, является мировым лидером по производству сортировочных установок под различными торговыми марками. Технологии компании применяются в различных отраслях: горнодобывающей, пищевой и сортировке отходов.¹⁰

В качестве детекторов у данного оборудования применяются лазеры различных длин волн и соответствующие сенсоры, которые работают в инфракрасном, видимом и рентгеновском диапазоне. Для классификации/выделения нужных объектов используются как классические алгоритмы компьютерного зрения, так и на основе искусственных нейронных сетей и машинного обучения. На основе последнего как раз работают установки для сортировки отходов в купе с лазерными и инфракрасными сенсорами. В решениях для горнодобывающей отрасли наиболее часто классификация происходит в рентгеновском спектре и с применением электромагнитных сенсоров. Разделение в таком оборудовании осуществляется за счет: инерции материалов, свободного падения (гравитационное разделение), применения пневматической сортировки (импульсных потоков воздуха).

Похожее оборудование для горнодобывающей промышленности и сортировки отходов также производит фирма STEINERT.¹¹

Важно отметить, что данное оборудование, хоть и высокотехнологичное и позволяет осуществлять сортировку на высокой скорости, достаточно дорогостоящее и крупногабаритное, в нем не встречаются манипуляторы, производящие захват с конвейерной ленты нужных объектов и до сих пор на большинстве предприятий есть линии ручной сортировки.

Решение для замещения линий ручной сортировки, в котором представлены манипуляторы, производящие захват и перенос объектов в нужные категории на основе компьютерного зрения с использованием нейросети, есть у компании ZenRobotics.¹² Манипуляторы также оснащены тактильными сенсорами, сигнализирующими о надежности захвата предмета. Получение данных об объектах осуществляется с помощью лазерных сканеров (в том числе и 3D-сканеров), спектрометров и др. детекторов. В распознавании определяются: величина, форма и цвет предмета, его вещественный состав и физические свойства [11].

¹⁰ Компания TOMRA. URL: <https://www.tomra.com/> (Дата обращения: 01.05.2024).

¹¹ Компания STEINERT. URL: <https://steinertglobal.com/> (Дата обращения: 01.05.2024).

¹² Решение компании ZenRobotics. URL: <https://www.terex.com/zenrobotics/robots/fast-picker> (Дата обращения: 01.05.2024).

Был предложен способ сортировки мусора, в котором выполняется захват предметов манипуляторами с конвейера и российскими учеными, в котором применяются аналогичные сканеры и детекторы. Захват сортируемых предметов манипуляторами осуществляется за счет детекторов кода этих меток, также конвейер освещается ультрафиолетом, а метки на сортируемом потоке окрашиваются флуоресцентной краской.¹³

4. Разработка, конфигурирование и обучение нейронных сетей для классификации ТКО

Обучение нейронной сети обнаружению объектов в потоке переработки представляет собой нетривиальную задачу. Эта от части сложнее, чем распознавание лиц на фотографии. Это обусловлено почти бесконечным множеством возможных вариантов деформации перерабатываемых материалов, которые должна уметь распознавать система. Кроме того, существует проблема сбора достаточного количества качественных данных, необходимых для обучения.

Существует множество реализаций нейросетей для разных задач, но все они основаны на общих принципах. Архитектура нейронных сетей — это описание структуры и организации нейронной сети, которое включает в себя количество слоёв, число нейронов в каждом из них, функции активации, методы оптимизации и другие параметры, определяющие, каким образом сеть будет обрабатывать входные данные и формировать выходные результаты. С каждым годом появляются новые архитектуры, исследователи и инженеры публикуют их на тематических ресурсах с общим доступом к коду. Модель нейронной сети — имплементация какой-то базовой архитектуры, она конфигурируется под решаемую задачу. При имплементации в модель может добавляться дополнительная логика, конкретизироваться параметры обучения и работы.

Базовые сущности и операции в нейросетях реализованы в прикладной библиотеке tensorflow¹⁴ для языка программирования Python. С практической точки зрения, можно переиспользовать какую-либо архитектуру с открытым доступом, реализовав ее с использованием упомянутого tensorflow в Python, адаптировав под решаемую задачу. Для задач компьютерного зрения применяются сверточные нейросети, которые специально предназначены для задач классификации изображений, детектирования объектов на изображениях, выделении границ объектов. В данном разделе рассмотрены работы по применению различных архитектур сверточных нейросетей в задачах по переработке ТКО.

Распространенные алгоритмы для классификации и детектирования можно разделить на два типа: традиционные алгоритмы ML (machine learning) и DL (deep learning). Традиционные алгоритмы ML требуют в качестве входных данных выделенные вручную визуальные признаки, в то время как алгоритмы DL могут автоматически извлекать скрытые признаки из необработанных изображений. Благодаря своим преимуществам в надежности и комплексном автоматизированном обучении DL стал преобладающим алгоритмом в компьютерном зрении, позволяющим сортировать твердые отходы.

Помимо визуальных данных для классификации можно использовать и другие. Например, в одном из исследований китайских ученых из национального института Гонконга предполагалось оценивать фотографии самосвалов с отходами на наличие в составе инертных и неинертных материалов, и в соответствии с этим составом осуществлять приемку.

¹³ Патент RU 2 624 288 C1 2017.07.03. Способ сортировки мусора // Патент России № 2016117281. 2016. Бюл. № 19. / Пак Ю.А.

¹⁴ TensorFlow — открытая программная библиотека для машинного обучения. URL: <https://www.tensorflow.org/> (Дата обращения: 01.05.2024).

Применялся комбинированный метод: была обучена сверточная нейронная сеть с архитектурой DenseNet169 для работы с изображениями, которая выдавала решение на основе визуальных данных по составу и уровню заполненности кузова, а также веса материала в грузовике (взвешивался до и после разгрузки). Основная задача заключалась в разделении на 2 класса: поступил грузовик с долей инертных материалов больше или меньше 50 %. Итоговый ответ выдавал классификатор на основе метода опорных векторов, который принимал на вход решение обученной нейросети, вес грузовика и уровень залегания материала. Данные для обучения собирались на въезде грузовиков, непрерывно происходила оценка веса самосвалов, глубины залегания материала в кузове и делались фотографии кузова сверху. Материал в грузовиках оценивался человеком и для обучения фиксировалось его итоговое решение на какую стадию переработки направлять материал. Решения нейросети в 94 % случаев совпадали с решениями человека, но не определялось ошибался ли человек — его решения принималось за истину [12].

Кроме приемки материала из грузовиков существуют и другие сценарии, в которых людям-экспертам приходится делать выводы о чем-либо только по внешнему виду. Эта практика неэффективна, трудоемка, опасна и может быть подорвана усталостью или неряшливостью работника. Аналогичные подходы вполне могут эффективно применяться на этапе приемки ТРО на предприятиях по переработке отходов в РФ ввиду того, что точность сопоставима с решениями людей-инспекторов, но при этом хорошо бы также отдельно оценить на сколько часто ошибаются сами инспекторы — возможно, стоило собирать решения по одной пробе от нескольких инспекторов и считать истинной наиболее часто встречающуюся оценку.

Существует множество практик внедрения компьютерного зрения для сортировки отходов на конвейерных лентах. В качестве примера можно взять исследование по классификации потока ТКО со значительным содержанием алюминиевой банки компании PortiK. В работе решения применялась сверточная нейронная сеть архитектуры Faster R-CNN вместе с ResNet-101. Для обучения модели для каждого класса отходов использовалось по 1 000 изображений. В ходе эксплуатации в реальном времени принятие решения о классификации занимало менее чем 1 секунда, что важно для промышленной эксплуатации. Система состояла из цветной матричной камеры, конвейерной ленты и рампы светодиодного освещения над конвейером. Для обеспечения хорошего компромисса между объемом анализируемых данных и качеством изображения предлагаемое решение основано на анализе изображений, а не на анализе видео. Система была настроена с глубиной резкости 20 мм и частотой получения изображений 1 Гц для анализа материала на конвейере, движущегося со скоростью 0,4 м/с, с перекрытием 50 % между последовательными изображениями, разделение материала на классы осуществлялось с помощью шарнирного рычага. По итогу, алюминиевые банки обнаруживались с точностью 91,2 %, что впоследствии привело к снижению количества банок в потоке переработке до менее чем 1 %. Точность определения других категорий отходов составляла 80,2 %. Точность оценивалась как прецизионность или отношение числа верно сделанных предсказаний (классификаций) к числу их истинных классов и отражает вероятность предсказания обученной модели. После прогона 5 образцов ТКО в рабочих условиях в течение 8 часов, итоговая погрешность составила ± 5 % [13].

Примерно по аналогичной схеме, но с более продвинутой нейронной сетью YOLOv3 китайские инженеры соорудили систему распознавания и сортировки мелких частей цветных металлов в потоке лома. Точность классификации алюминиевых отходов составила 90 %, а медных 86 % при работе с YOLOv3 в чистом виде. При применении аугментации¹⁵ на изображениях и надстройках нейросети исследователям удалось повысить точность до 95 % для

¹⁵ Аугментация — намеренное искажение изображений в обучающей выборке, чтобы ее разнообразить.

алюминиевых и 88 % для медных, всего для обучения модели использовалось 4 968 размеченных изображений [14].

В одном из исследований с помощью сверточной нейронной сети с использованием не сложной архитектуры DenseNet121 и обучении на 2 527 изображений для классификации на 6 категорий: картон, бумага, пластик, алюминиевая и металлическая тара, стекло и «прочие отходы» в условно промышленной эксплуатации удалось достичь точности в 95 % [15].

Но данное исследование имеет свои недостатки — из примеров, приведенных авторами, можно увидеть, что изображения были сделаны на белом столе в хорошем качестве при одном освещении, в лабораторных условиях, объекты на изображениях были чистыми и практически не деформированы.

Последующая оценка точности проводилась на таких же изображениях, что вызывает сомнения при работе такой модели в реальных условиях переработки с такой точностью.

Китайские ученые провели обзор научных исследований касательно применения в сортировке отходов классификации на основе компьютерного зрения с использованием сверточных нейронных сетей.

Можно сказать, что по состоянию на 2022 год большинство решений способно классифицировать отходы с точностью от 80 до 95 %, в зависимости от условий и наличия дополнительных подстроек [16].

Наиболее распространенные, используемые в прикладных исследованиях для классификации изображений ТКО архитектуры сверточных нейронных сетей представлены в таблице 3, также в данной таблице приведена их чистая точность (без использования аугментаций и подстроек) на основе набора данных ImageNet и год их появления.¹⁶

Таблица 3

**Архитектуры сверточных нейронных сетей, которые использовались
в исследованиях по классификации ТКО, их чистая точность и год появления**

Архитектура сверточной нейросети	Чистая точность, %	Год появления
AlexNet	58,9	2012
ResNet	75,3	2015
ResNet-50	78,8	2015
MobileNet (v2)	74,7	2017
Inception	77,1	2008
DenseNet-169	76,2	2017
Xception	79,0	2016
VGGNet-16	78,8	2014

Составлено автором¹⁷

В таблице 4 представлены данные по распространённым архитектурам нейросетей, используемых в исследованиях для детектирования объектов с ТКО, представлен год их появления и оценена по метрике box mAP на основе набора данных COCO.¹⁸

¹⁶ Набор данных для обучений искусственных нейронных сетей для классификации ImageNet <https://www.image-net.org/about.php> (Дата обращения: 01.05.2024). Считается также эталоном для сравнения их точностей.

¹⁷ Данные по чистой точности взяты с сайта <https://paperswithcode.com/sota/image-classification-on-imagenet> (Дата обращения: 01.05.2024). На нем же можно найти ссылки на конкретные исследования и оценки по другим параметрам и с применением подстроек.

¹⁸ Набор данных для обучений искусственных нейронных сетей для детектирования объектов COCO <https://cocodataset.org/#home> (Дата обращения: 01.05.2024). Считается также эталоном для сравнения.

Метрика mAP (Mean Average Precision) считается как:

$$mAP = \frac{1}{n} \sum_{k=1}^{k=n} AP_k, \quad (2)$$

где n — количество классов для детектирования, k -конкретный класс; AP_k — средняя прецизионность точности определения класса k (или отношение истинно определенных классов k ко всем предсказаниям класса k).

Box mAP представляет собой то, на сколько точно нейросеть выделяет в квадрат объект нужного класса на изображении без отклонений (отрезание областей объекта, выделение лишних вокруг объекта или смещения зоны предсказания) по сравнению с ручным выделением объекта в квадрат без отклонений человеком на наборе данных. Если нейросеть выделит точно такую же область как и человек, тогда box mAP будет равен 100 при условии всегда верного определения нужных классов.

Таблица 4

Архитектуры сверточных нейронных сетей, которые использовались в исследованиях по детектированию объектов ТКО, их оценка box mAP и год появления

Архитектура сверточной нейросети	box mAP	Год появления
R-CNN	–	2014
Faster R-CNN	34,9	2015
Mask R-CNN	39,8	2017
RetinaNet	40,8	2017

Составлено автором¹⁹

Можно заметить, что используемые модели нейросетей, которые применялись в рассмотренных выше недавних исследованиях, появились с 2012 по 2017 годам, но с 2017 по 2024 появилось много новых моделей, которые эффективнее предыдущих. Это должно быть связано с тем, что при появлении новой архитектуры происходит задержка по времени перед ее использованием в прикладной задаче и проведении соответствующего прикладного исследования. В качестве новых лидеров можно привести OmniVec для задач классификации с чистой точностью 92,4 % [17] и CO-DETRs для задач детектирования объектов с показателем box mAP в 66 [18]. Также у все более новых моделей увеличивается скорость обучения и эффективность по другим метрикам.

Важно отметить влияние размера обучающей выборки и наличие аугментации в изображениях на результирующую точность (отношение числа истинно верных положительных и отрицательных предсказаний ко всем предсказаниям) нейросети. Согласно одному из исследований для нейросети с архитектурой Inception V4 наличие аугментации на обучающем и тестовом наборе данных может повысить итоговую точность на 15 %, а для ResNet-152 на 10 %.

Наличие же аугментации только на обучающей выборке увеличивает точность не так значительно [19]. На рисунке 3 представлены графики зависимости точности α (какая доля из объектов классифицируется истинно верно) от размера обучающей выборки n .

Можно увидеть, что кривые зависимостей с аугментациями на выборках лежат выше кривых без аугментаций — соответственно применяя аугментацию можно достичь больших показателей точности.

¹⁹ Данные по оценке mAP взяты с сайта <https://paperswithcode.com/sota/object-detection-on-coco> (Дата обращения: 01.05.2024). На нем же можно найти ссылки на конкретные исследования и оценки по другим параметрам и с применением подстроек.




Рисунок 3. Зависимость итоговой точности α (какая доля из объектов классифицируется истинно верно) от размера выборки изображений для обучения n в зависимости от применения аугментации в выборках для Inception V4, ResNet-152 и ResNet-161 [19]

Заключение и выводы

В работе была подчеркнута актуальность совершенствования сортировки отходов ввиду того, что в России значительная часть отходов утилизируется на полигонах и только 7 % перерабатывается, что оказывает весомое негативное влияние на экологию.

На большинстве предприятий по сортировке отходов существуют линии ручной сортировки, которые могут быть автоматизированы с применением компьютерного зрения на основе машинного обучения и сверточных нейронных сетей. Потенциально на таких линиях возможно автоматизировать выделение текстиля, бумаги, картона, различных видов пластика и других материалов. Также возможно и целесообразно выделять особо ценные компоненты на предсортировке вроде электроники и особо опасные — такие как, литиевые источники питания.

Было также рассмотрено популярное оборудование компаний TOMRA и STEINERT, используемое для оптической сортировки твёрдых коммунальных отходов в сочетании другими типами датчиков. Разделение на категории в нем осуществляется в основном за счет импульсного потока воздуха, инерции материалов и гравитации. Данное оборудование высокотехнологичное и позволяет осуществлять сортировку на высокой скорости, но достаточно дорогостоящее и крупногабаритное. Оборудование компании ZenRobotics в качестве разделения использует пневматические манипуляторы с применением компьютерного зрения и как раз предназначено для автоматизации линий, на которых осуществляется ручная сортировка.

На основании ряда исследования было произведено обобщение морфологического состава твёрдых коммунальных отходов. Так как состав ТКО отличается по регионам и зависит от сезонности, для каждой категории были выделены минимальная и максимальная возможные доли в потоке переработки. На основании этих данных были выделены достаточные доли изображений в каждой категории для будущего обучения сверточной нейросети для классификации, также для каждого материала были выделены преобладающие типы форм, которые можно использовать как подкласс для определения конкретных категорий при построении модели нейронной сети для классификации и подобрать параметры сортирующего оборудования.

Касательно реализации классификации ТКО с помощью компьютерного зрения с применением сверточных нейронных сетей, в последних найденных работах использовались архитектуры нейросетей появившиеся до 2018 года — это должно быть связано с тем, что при

появлении новой архитектуры происходит задержка во времени перед ее использованием в прикладных задачах и проведении соответствующих исследований. На данный момент появились уже новые архитектуры, которые показывают эталонную оценку точности классификации на 17 % выше (OmniVec) и более точно детектируют объекты (например, CO-DETRs, показатель mAP у которого на 60 % больше), чем наивысшая эталонная оценка архитектур в рассмотренных исследованиях. Соответственно при выборе архитектуры сверточной нейросети для будущего исследования следует выбрать наиболее эффективную из современных.

На результирующую точность классификации значительно влияет аугментация изображений в наборе изображений для обучения нейросети — наличие аугментации может повысить точность на 10–15 %. Для большей эффективности можно также разнообразить варианты аугментации. Также на результирующую точность влияет и сам объем обучающей выборки — начиная с 2000 изображений точность классификации начинает выходить на плато, поэтому такой объем можно условно считать минимальным для решения прикладной задачи.

Важно отметить, что во многих работах ограничивались задачей классификации с упрощенными условиями работы: изображения были собраны в лабораторных условиях — материалы на них слабо и неестественно деформированы и практически чистые. Из этого можно сделать вывод, что следует собирать изображения в производственных условиях, чтобы получить наиболее релевантно обученную нейросеть. Существует вполне весомое ограничение компьютерного зрения при классификации материалов схожего внешнего вида, но оно может в значительной мере нивелироваться, если рассчитывать на распознавание этикеток производителей и иметь данные о материале упаковок (например, конкретный вид пластика тары определенного производителя) — данное свойство в целом можно заложить при обучении нейронной сети и соответствующе разметить данные.

Отсутствие полных, доступных для совместного использования наборов изображений с отходами, произведенных в реальных условиях, которые могли бы быть использованы заинтересованными исследователями для обучения своих моделей, является проблемой. Лишь в нескольких исследованиях для обучения и оценки моделей использовались общедоступные наборы данных, при этом данные наборы были далеки от производственных условий — поэтому исследователям важно делиться своими данными в целях развития прикладного применения технологий.

В качестве дальнейшего исследования можно воспроизвести сверточную нейронную сеть на основе наиболее эффективных современных архитектур, обучить ее с применением аугментации на основе достаточных данных, собранных с действующего российского предприятия, на котором осуществляется конвейерная сортировка ТКО, а также выявить на предприятии потребности в автоматизации конкретных линии сортировки для наиболее релевантного решения.

ЛИТЕРАТУРА

1. Обзор систем сортировки твердых коммунальных отходов / А.Е. Карелин, А.В. Кожемяченко, М.А. Лемешко. // Инженерный вестник Дона. — 2022. — № 7. URL: <http://www.ivdon.ru/ru/magazine/archive/n7y2021/7064>.
2. Анализ методов сортировки твердых бытовых отходов / И.В. Ламзина, В.Ф. Желтобрюхов, И.Г. Шайхиев. // Вестник технологического университета. — 2015. — Т. 18, № 5. — С. 244–247.

3. Перспективы использования комплекса оптико-механической сортировки с целью извлечения энергетического потенциала ТБО / К. Вюнш, Я.И. Вайсман, В.Н. Коротаев, Д.Л. Борисов // Вестник ПНИПУ. Урбанистика. — 2013. — № 3. — С. 138–145.
4. Анализ методов сортировки твердых бытовых отходов / Галкина О.А., Г.В. Ильиных, К. Вюнш // Вестник ПНИПУ. Прикладная экология. Урбанистика. — 2014. — № 13. — С. 127–139.
5. Robotic Pick-and-Toss Facilitates Urban Waste Sorting / F. Raptopoulos, M. Koskinopoulou, M. Maniadakis. // Conference: 2020 IEEE 16th International Conference on Automation Science and Engineering (CASE). — 2020. DOI: <https://doi.org/10.1109/CASE48305.2020.9216746>.
6. AI Takes a Dumpster Dive: Computer-vision systems sort your recyclables at superhuman speed / J. Calaiaro // IEEE Spectrum. — July 2022. — vol. 59, no. 7. — pp. 22–27. DOI: <https://doi.org/10.1109/MSPEC.2022.9819884>.
7. Определение морфологического состава твердых коммунальных отходов на территории Петрозаводского городского округа / Лебедева, К.А., Графов К.А. // Студенческий научный электронный журнал, StudArctic forum. — 2018. — № 2(10). С. 4. URL: <https://saf.petrso.ru/journal/article.php?id=3005>.
8. Определение морфологического состава твердых бытовых отходов и степени их токсичности в условиях Самарской области России / Васильев А.В., Кондратьев А.Ф. // Известия Самарского научного центра Российской академии наук. — 2020. — 2 т. 22. DOI: <https://doi.org/10.37313/1990-5378-2020-22-2-51-54>.
9. Морфологический состав твердых коммунальных отходов / А.В. Сотнезов, В.А. Зайцев, Н.П. Тарасова // Безопасность в техносфере. — 2015. — Том 4 № 4. DOI: <https://doi.org/10.12737/14429>.
10. Physical properties of recyclable materials and implications for resource recovery / Tanguay-Rioux F., Héroux M., Legros R. // Waste Management 136. — 2021. — pp. 195–203. DOI: <https://doi.org/10.1016/j.wasman.2021.10.007>.
11. Zenrobotics recyclerbot sorting using machine learning / Lukka T.J., Tossavainen T., Kujala J.V., Raiko T. // Proceedings of the International Conference on Sensor-Based Sorting (SBS). — 2014. — pp. 1–8. URL: <https://users.ics.aalto.fi/praike/papers/SBS14.pdf>.
12. Looking beneath the surface: A visual-physical feature hybrid approach for unattended gauging of construction waste composition / Junjie Chen, Weisheng Lu, Fan Xue // Department of Real Estate and Construction, The University of Hong Kong, Pokfulam Road, Hong Kong, China. — 2021. Doi: <https://doi.org/10.1016/j.jenvman.2021.112233>.
13. PortiK: A computer vision based solution for real-time automatic solid waste characterization — Application to an aluminium stream / Remi Cuingnet, Yannik Ladegaillerie, Jerome Jossent, et al. // Waste Management 150. — 2022. — С. 267–279. DOI: <https://doi.org/10.1016/j.wasman.2022.05.021>.
14. Research on the process of small sample non-ferrous metal recognition and separation based on deep learning / Song Chen, Zhili Hu, Chao Wang, et al. // Waste Management 126. — 2021. — С. 266–273. DOI: <https://doi.org/10.1016/j.wasman.2021.03.019>.

15. Recycling waste classification using optimized convolutional neural network / Wei-Lung Maoa, Wei-Chun Chenb, Chien-Tsung Wang, et al. // Resources, Conservation & Recycling 164. — 2021. DOI: <https://doi.org/10.1016/j.resconrec.2020.105132>.
16. Computer vision for solid waste sorting: A critical review of academic research, Department of Real Estate and Construction / Weisheng Lu, Junjie Chen // Waste Management 142. — 2022. — pp. 29–43. DOI: <https://doi.org/10.1016/j.wasman.2022.02.009>.
17. OmniVec: Learning robust representations with cross modal sharing / S. Srivastava, G. Sharma // TensorTour Inc. — 2023. DOI: <https://doi.org/10.48550/arXiv.2311.05709>.
18. DETRs with Collaborative Hybrid Assignments Training / Z. Zong, G. Song Y. Liu // SenseTime Research. — 2023. DOI: <https://doi.org/10.48550/arXiv.2211.12860>.
19. A survey on Image Data Augmentation for Deep Learning / Shorten, C., Khoshgoftaar, T.M. // Journal of Big Data. — 2019. — № 60. DOI: <https://doi.org/10.1186/s40537-019-0197-0>.

Prokashev Vitalii Andreyevich

National University of Science and Technology «MISiS», Moscow, Russia

E-mail: vitalyaprocashev@gmail.com; vitalya-procashev@yandex.ru

ORCID: <https://orcid.org/0009-0005-6793-7257>

Opportunities for improving the use of computer vision in municipal solid waste sorting

Abstract. This article explores the possibilities of improving the application of optical sorting of municipal solid waste on conveyor belts using computer vision and machine learning technologies in order to replace manual sorting lines. Also the relevance of improving waste sorting is emphasized. This work expands the understanding of the application of computer vision in the field of waste management and offers practical recommendations for its implementation in industrial processes.

The paper reviews current approaches to sorting municipal solid waste, analyzes their effectiveness, and explores the potential for improving waste management processes and increasing recycling efficiency based on recent research in this area. The most popular equipment used in sorting and its features are considered.

A generalization of the morphological composition of waste is carried out, and the minimum and maximum possible shares of each class of waste in the recycling stream are identified. Based on this data, sufficient proportions of images in each category are selected to train a convolutional neural network for waste classification.

Applied research in terms of detection and classification of waste objects on conveyor belts using well-known neural network architectures is considered. The analysis showed that most solutions are based on 2018 architectures, while the reference classification accuracy of more modern architectures, such as OmniVec, is 17 % higher, and detection efficiency is similar orders of magnitude higher. The resulting classification accuracy is significantly affected by image augmentation in the set of images for training the neural network — its presence can increase accuracy by 10 to 15 %. The minimum training data set has been determined, which should be about 2 000 images due to the fact that after a further increase in the number, the accuracy does not change significantly.

Keywords: municipal solid waste; computer vision; convolutional neural networks; object detection; classification; sorting; morphological composition