

Исследование сверточных нейронных сетей в задаче классификации изображений радиоактивных отходов*

Архипов А.Е.

Фомин И.С.

Санкт-Петербургский политехнический университет
Петра Великого
г. Санкт-Петербург, Российская Федерация
arhipov.ae@edu.spbstu.ru

Центральный научно-исследовательский институт
робототехники и технической кибернетики
г. Санкт-Петербург, Российская Федерация
i.fomin@rtc.ru

Аннотация. Радиоактивное заражение окружающей среды происходит всегда очень быстро и масштабно. При этом причины возникновения заражения могут быть различными и нет гарантий, что они не возникнут вновь. Поэтому необходимо всегда быть готовыми предпринимать экстренные меры по ликвидации последствий радиоактивного заражения. На сегодняшний день наиболее эффективным и безопасным решением проблемы ликвидации РАО является захоронение, поэтому необходимо обеспечить компактность размещения РАО. Для этого зараженные отходы можно спрессовать или сжечь в специальных установках. Использование систем технического зрения с применением сверточных нейронных сетей позволит классифицировать материал РАО для определения сжигаемых или прессуемых объектов. Для проведения экспериментов о применимости CNN для данной задачи сформирован набор данных, содержащий изображения из открытых данных, а также собственными изображениями. Проведенные эксперименты подтверждают эффективность применения глубоких сверточных нейронных сетей для данной задачи. Наилучший результат классификации материала показала сеть InceptionV3 с точностью 89,58%. Наибольшую эффективность можно достичь при использовании предсказаний нескольких нейронных сетей, с помощью которых точность повысилась до 91,58%.

Ключевые слова: глубокое обучение, сверточные нейронные сети, классификация изображений, радиоактивные отходы.

ВВЕДЕНИЕ

История помнит не мало случаев, когда радиоактивные элементы тем или иным образом заражали окружающую среду. Особый след в истории оставила после себя катастрофа на Чернобыльской АЭС. Чтобы больше не допускать подобные случаи во всем мире предпринимаются особые меры по работе с радиоактивными элементами. Однако нельзя исключать ситуаций с очередным выбросом радиации в окружающую среду и нужно быть всегда готовым к ликвидации последствий радиоактивного заражения.

Работы по ликвидации последствий осложняются высокими требованиями к оборудованию в связи с мощным ионизирующим излучением. Появилось целое направление под названием экстремальная робототехника для создания роботов, функционирующих в условиях высоких

температур, ионизирующего излучения и т.д. Разумеется, современный подход к ликвидации последствий радиоактивного выброса должен быть реализован исключительно с использованием робототехнических средств. На сегодняшний день наиболее эффективным и безопасным решением проблемы ликвидации РАО является захоронение, поэтому необходимо обеспечить компактность размещения РАО в могильниках. Это можно делать с помощью прессования и сжигания РАО в специальных установках. При этом не все материалы могут быть сожжены или спрессованы, поэтому возникает задача сортировки материала отходов при проектировании процесса ликвидации РАО.

Оборудование по автоматизированной сортировке РАО должно быть защищено от ионизирующего излучения. Сегодня существует оборудование по сортировке твердых бытовых отходов, однако использование тех же методов сортировки и последующая защита оборудования от излучения могут оказаться дорогостоящими. Наиболее перспективным вариантом определения материала РАО может быть использование систем технического зрения. Для определения материала РАО достаточно иметь камеру и вычислительное устройство. Камера может быть расположена, например, над конвейерной лентой. Тогда после определения материала, объект распределяют в бокс к прессуемому/сжигаемому или другим объектам.

Таким образом, сортировка РАО с использованием глубокого обучения включает в себя получение изображений с камеры, обнаружение объекта, определение класса материала и отнесение его в ту или иную группу (сжигаемое, прессуемое и т.д.). Использование СТЗ позволило бы существенно сократить стоимость оборудования, а также упростить процесс сортировки. Однако необходимо провести исследования о применимости систем технического зрения для данной задачи.

МЕТОДЫ РЕШЕНИЯ ЗАДАЧИ

Современные системы технического зрения все чаще используют глубокое обучение для решения различных задач. Глубокое обучение – это класс алгоритмов машинного обучения, которые используют многоуровневое представление данных и извлечение признаков. Глубокие сверточные нейронные сети успешно применяются для

* Работа выполнена в рамках государственного задания № 075-01623-22-00 "Исследование методов создания самообучающихся систем видеонаблюдения и видеоаналитики на базе комплексирования технологий пространственно-временной фильтрации видеопотока и нейронных сетей №1021060307687-9-1.2.1"

Статья публикуется по рекомендации программного комитета Всероссийской научно-технической конференции "Пром-Инжиниринг", <https://icie-rus.org>

анализа изображений, поэтому имеет смысл применять данные методы. Для исследования выбраны следующие глубокие нейронные сети: VGG16 [1], InceptionV3 [2], NASNetMobile [3], SqueezeNet [4], DenseNet121 [5], MobileNetV2 [6], MobileNet [7].

Архитектура VGG состоит из последовательности сверточных слоев с размерами фильтров 3×3 , между которыми расположены промежуточные слои подвыборки. Для классификации полученных с помощью сверток признаков используются два полносвязных слоя. Обычно модели VGG имеют от 13 до 19 слоев. В работе использовалась VGG-16 в качестве тестовой модели, которая имеет 138 миллионов параметров и точность на ImageNet [8] 71,3%.

Архитектура SqueezeNet состоит из нескольких последовательных модулей, называемых fire, которые состоят из двух частей: сжимающей и расширяющей. Сжимающая часть представляет собой сверточный слой с фильтром 1×1 , а расширяющая часть представляет собой сверточные слои 1×1 и 3×3 соответственно. Количество слоев в сжимающей и расширяющей частях является настраиваемым гиперпараметром. SqueezeNet, используемая в работе, имеет около 1 миллиона параметров с точностью 57,5%. В то же время веса нейронной сети занимают всего 4,8 Мбайт.

Основная идея MobileNet заключается в том, что вместо использования обычных фильтров свертки 3×3 с подвыборкой операция разбивается на глубинно отделимую свертку фильтрами 3×3 с последующей точечной сверткой 1×1 . При достижении того же процесса фильтрации и комбинирования, что и при обычной пространственно разделимой свертке, новая архитектура требует меньшего количества операций и параметров. MobileNet состоит всего из 20 вышеописанных слоев. Таким образом, MobileNet имеет всего 4,2 миллиона параметров с точностью на ImageNet 70,4%.

В новой версии архитектуры MobileNetV2 авторы сократили количество вычислений сети за счет понижения числа каналов. Причем уменьшение количества каналов не приводит к потере полезной информации, что можно заметить по экспериментальным результатам. Теперь, с точностью на ImageNet 71,3%, архитектура имеет 3,5 миллиона параметров.

Архитектура DenseNet состоит из нескольких последовательных плотных (dense) блоков, в которых реализованы соединения от одного слоя ко всем последующим в пределах одного блока. Карты признаков между слоями не суммируются, а объединяются в один тензор. Такое решение не только предотвращает исчезновение градиентов, но и улучшает продвижение функций внутри нейронной сети и позволяет значительно сэкономить количество параметров. В этой работе использовалась сеть DenseNet-121, которая имеет 8М параметров и точность на ImageNet 75%.

Основная идея Inception заключается в том, что сеть извлекает информацию из разных масштабов изображения, используя сверточные ядра разного размера, и объединяет их для получения лучшего представления изображения. Основным отличием Inception-v3 от предыдущих версий является использование нормализации пакета, что позволяет повысить производительность и стабилизировать обучаемость сети. Inception-v3 имеет 24М параметров и точность на ImageNet 77,9%.

Разница между NASNetMobile и другими архитектурами заключается в методе разработки. Архитектура NASNetMobile была получена с помощью поиска нейронной архитектуры (neural architecture search). Алгоритм выбрал наиболее точную архитектуру для набора данных CIFAR-10 [9] путем перебора различных комбинаций слоев. В этой статье взята архитектура NASNetMobile, которая предназначена для мобильных устройств.

НАБОР ДАННЫХ

Существует схожая задача – сортировка твердых бытовых отходов (ТБО) с целью последующей переработки и вторичного использования. Определение материала объектов по изображениям позволило бы автоматизировать процесс сортировки мусора. Поэтому на сегодняшний день ведутся активные разработки методов для решения данной задачи. При решении задачи сортировки РАО имеет смысл использовать имеющиеся наработки с сортировки ТБО, потому что во многом РАО содержат те же категории, что есть в обычном мусоре, просто добавляется еще индекс заражения. В частности, сегодня существуют открытые наборы данных, которые также использовались в данной работе [10, 11, 12]. Однако данные наборы данных разрабатывались для переработки и повторного использования мусора, поэтому в них присутствуют в основном легко перерабатываемые материалы. При этом некоторые классы вообще отсутствуют, как например “дерево” и “текстиль”. А некоторые классы представлены менее характерными объектами для РАО, например “металл” в TrashNet [10] – это чаще всего жестяные банки или крышки, а для РАО класс “металл” может содержать строительные металлические элементы, металлические детали с мебели и т.д. Набор данных TrashNet был дополнен данными из наборов [11] и [12], а также собственными изображениями объектов и изображениями, полученными из поисковых систем.

Собственные изображения формировались двумя способами. Первый способ заключался в размещении одного или нескольких объектов на однородном фоне с равномерным освещением. При одном положении объекта съемка происходила с нескольких ракурсов. Объекты класса “текстиль” представляли собой ткани различного цвета, формы и размера. В среднем для каждого из 20 объектов класса “текстиль” выбиралось по 3 ракурса. После съемки во всех ракурсах положение объекта менялась, и съемка происходила заново. Таким образом для класса “текстиль” собрано 840 изображений. Аналогичным способом собраны данные других классов. Для класса “дерево” 946 изображений, для класса “картон” 51 изображение, для класса “пластик” 70 изображений, для класса “стекло” 7 изображений, для класса “металл” 38 изображений. Однако для обучающей выборки использовались только объекты классов “текстиль” и “дерево”. Изображения объектов других классов необходимы для тестовой выборки, чтобы протестировать нейронные сети на собственных изображениях.

Во время формирования данных производились промежуточные обучения нейронных сетей, чтобы выявить проблемные места собранных данных, которые необходимо устранить. При тестировании обученных нейронных сетей обнаружилось, что сети практически всегда правильно предсказывали собственные объекты из тестовой выборки классов “текстиль” и “дерево”, однако точность

предсказания собственных объектов других классов была низкой. Мы предположили, что это связано с фоном, так как он был однородным, но отличался по цвету от изображений изначального набора данных. Возможно, нейронная сеть выучила, что при таком фоне могут быть объекты только двух классов “текстиль” или “дерево”. Поэтому было необходимо выделить объекты на изображении и отделить их от фона.

Сначала сделана попытка избавиться от фона с помощью сегментации в цветовом пространстве HSV. Однако таким образом получалась некачественная сегментация схожих по цвету с фоном объектов. А также возникали большие проблемы с тенями объектов. Иногда тени выделялись, а иногда нет. Вторая попытка избавиться от фона осуществлялась с помощью метода Оцу [13]. Однако из-за проблем с тенями не удалось получить качественной сегментации. Третья попытка осуществлялась с помощью инструмента по удалению фона на изображениях [14]. Данный метод основан на использовании предварительно обученных нейронных сетей и состоит из следующих этапов:

1. С помощью обученной нейронной сети Faster-RCNN [15] на изображении выделяются обрамляющие прямоугольники с ключевыми объектами.

2. С помощью нейронной сети U²-Net [16], обученной на наборе данных DUTS [17], происходит сегментация прямоугольников. U²-Net создавалась для решения задачи обнаружения характерных объектов (Salient Object Detection). Суть задачи состоит в сегментации крупных объектов на изображении, поэтому эффективность работы сети не зависит от принадлежности объекта к какому-либо классу.

3. На этапе постобработки удаляются пиксели, прозрачность которых ниже определенного порога.

Так как сеть Faster-RCNN не обучена обнаруживать мусор на изображении, то ее использование в данной задаче бессмысленно. На вход сети U²-Net подавалось оригинальное изображение, а не обрамляющий прямоугольник. С помощью данного инструмента удалось получить качественную сегментацию мусора на изображении. После изменения фона решилась проблема с качеством классификации собственных объектов, не входящих в обучающую выборку.

Второй способ заключался в формировании изображений на разном фоне, чтобы исключить возможность появления вышеописанной проблемы. Способ получения изображений оставался аналогичным первому, за исключением разного фона. Изображения формировались только для класса “текстиль”. Таким образом было получено 1002 изображения.

Итоговый набор данных содержит 15038 изображений и состоит из объектов классов “картон”, “стекло”, “металл”, “бумага”, “пластик”, “текстиль”, “дерево”. Сформированный набор данных доступен по ссылке [18]. Класс “картон” содержит изображения различного цвета картонных коробок, скомканного и листового картона. Класс “бумага” содержит изображения газет, журналов, конвертов, этикеток, различного рода скомканных и рваных листов бумаги. Класс “пластик” содержит изображения окрашенных и прозрачных бутылок, крышек, пластиковых коробок. Класс “стекло” содержит изображения стеклянных бутылок различных цветов, бокалов, стаканов, а также битого стекла. Класс “металл” содержит изображения жестяных банок в нормальном и мятом виде, металлические болванки, небольшого размера металлические

предметы произвольной формы. Класс “дерево” содержит изображения древесины в различной форме: доски, фанера, бревна и т. д. Класс “текстиль” содержит изображения тканей разного цвета.

Тестовая выборка для каждого класса содержит собственные изображения для проверки работоспособности сетей на данных, приближенных к реальным. Распределение классов приведено на рис. 1 (синим цветом показано количество изображений в обучающей выборки, красным – в тестовой, зеленым – в валидационной).




Рис. 1. Распределение изображений по классам

РЕЗУЛЬТАТЫ ЭКСПЕРИМЕНТОВ

Все используемые нейронные сети были предобучены на наборе данных ImageNet. Это позволило сократить время на обучение, а также повысить надежность распознавания [19]. Обучение проводилось с ранней остановкой обучения, когда значение функции потерь на валидационной выборке значительно не меняется в течение нескольких эпох, то обучение прекращается. Это эффективнее использования фиксированного количества эпох, так как используемые архитектуры имеют большую разницу в количестве слоев и параметров, поэтому количество эпох обучения будет совершенно разным. В качестве метрик использовались точность и полнота. Точность – это отношение всех правильных прогнозов к общему числу всех предсказаний. Полнота – это доля истинно положительных классификаций. Полнота показывает, какую долю объектов, реально относящихся к классу, предсказали верно. Результаты приведены в табл. 1.

Таблица 1

Точность и полнота при тестировании различных сетей

Нейронная сеть	Точность, %	Полнота, %
DenseNet121	83,32	84,08
MobileNet	86,48	71,68
InceptionV3	89,58	87,56
MobileNetV2	82,04	81,85
VGG16	88,77	87,22
SqueezeNet	86,23	82,33
NASNetMobile	86,86	86,30

Можно заметить, что сети показывают относительно неплохую точность классификации. Также важно определить, насколько хорошо сети классифицируют каждый класс по отдельности. Для этого построен график (рис. 2), на котором линиями проведены точности нейронных сетей для все классов. Для каждого класса приведено значение наибольшей и наименьшей точности среди рассмотренных сетей.

ренных нейронных сетей. Можно заметить, что для некоторых классов разброс в точности довольно большой.

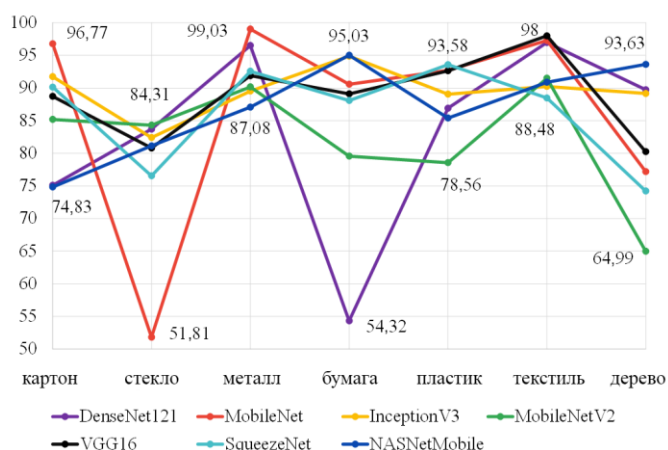


Рис. 2. Точность сетей по каждому классу

Из рисунка можно заметить, что некоторые сети, несмотря на неплохой средний показатель точности, хуже классифицируют некоторые отдельные классы, как например класс “стекло” имеет низкий показатель точности у сети MobileNet, или класс “бумага” у сети DenseNet121. При этом нельзя однозначно выделить класс, который сети хуже классифицируют. Что говорит о том, что представленные классы в наборе данных могут быть разделены между собой, а глубокие сверточные нейронные сети справляются с их классификацией. Однако с разной эффективностью сети могут классифицировать различные классы. Поэтому имеет смысл попробовать объединить предсказания сетей, чтобы получить наибольшую итоговую точность классификации.

Выбраны 3 комбинации сетей: в первом случае взяты все сети, во втором взяты 4 сети с наибольшей точностью предсказания, в третьем случае взяты 3 сети с наибольшей точностью. Для каждого класса рассчитывалась суммарная уверенность от всех нейронных сетей. Выбирается класс с наибольшей суммарной уверенностью. В табл. 2 приведены результаты точности с предсказаниями нескольких нейронных сетей.

Таблица 2

Точность предсказаний нескольких сетей одновременно

Количество сетей	Нейронные сети	Точность, %
7	Все	88,73
4	InceptionV3 DenseNet121 VGG16 NASNetMobile	90,65
3	InceptionV3 DenseNet121 VGG16	91,58

Можно заметить, что при использовании всех сетей точность не превосходит лучшие значения некоторых отдельных сетей. Использование трех наилучших сетей повысило точность классификации на 3% в сравнении с лучшим значением одной сети. Поэтому имеет смысл использовать одновременно несколько сетей.

При разработке системы технического зрения для классификации материалов необходимо понимать проблемные места данной задачи. Поэтому имеет смысл ана-

лизировать ошибки классификации нейронных сетей. Это может помочь правильно разделять классы между собой, а также выяснить какие классы сети путают между собой, чтобы в нужном направлении формировать набор данных для обучения. Для этого результаты работы сетей на тестовой выборке представлены в виде матрицы неточностей, приведенной на рис. 3. В данной матрице все предсказания сетей на тестовой выборке соотносятся с метками классов. Поскольку в данной ситуации интересуют проблемные места набора данных, а не отдельных сетей, то на рисунке приведена усредненная по всем сетям матрица. На матрице отображены нормализованные по классам предсказания сетей. В случае абсолютно правильной работы сетей все значения должны находиться на главной диагонали матрицы.

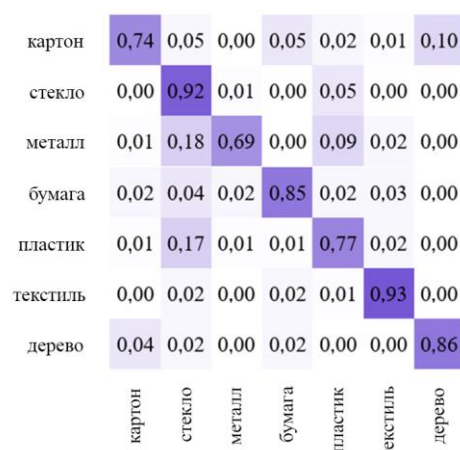


Рис. 3. Распределение изображений по классам

Из рисунка видно, что основные ошибки связаны с разделением металла, стекла и пластика между собой. Также стоит обратить внимание, что сети чаще отдают предпочтение классам стекло и пластик. Скорей всего, это связано с неравномерным распределением классов в обучающей выборке. В дальнейших разработках дисбаланс классов необходимо устранить.

Поскольку классификация материалов необходима в первую очередь для разделения прессуемых от сжигаемых материалов, то имеет смысл рассмотреть полученные результаты для бинарной классификации. Классы “картон”, “бумага”, “текстиль”, “дерево” отнесены к классу “сжигаемое”, а “стекло”, “металл”, “пластик” к классу “прессуемое”. В табл. 3 приведены пересчитанные точности сетей для двух описанных выше классов.

Таблица 3

Результат бинарной классификации

Сеть	Сжигаемое, %	Прессуемое, %	Усредненное, %
DenseNet121	98,90	93,96	96,43
MobileNet	88,45	98,09	93,27
InceptionV3	97,64	97,78	97,71
MobileNetV2	98,06	92,67	95,36
VGG16	96,12	98,61	97,36
SqueezeNet	94,52	96,13	95,32
NASNetMobile	95,28	96,69	95,99

Результаты, полученные в случае бинарной классификации, показывают гораздо большую точность. Если рассматривать разделение объектов именно на два класса, то задача значительно упрощается.

ЗАКЛЮЧЕНИЕ

По результатам проведенной работы можно судить об успешном использовании искусственных нейронных сетей в задаче классификации материалов РАО по изображению. Важно отметить, что представленные в работе классы сети в большинстве своем могли разделяться между собой. Нельзя однозначно выделить одну архитектуру, которая лучше справляется с данной задачей. При сравнении сетей отдельно по каждому классу, видно, что для некоторых классов лучше одна архитектура, а для некоторых другая.

В дальнейшем имеет смысл также рассмотреть вариант использования нескольких нейронных сетей для классификации методом голосования. Скорее всего, необходимо взвешивать голос каждой сети для разных классов, чтобы получить наиболее правильное решение в результате голосования.

При формировании обучающей выборки важно иметь данные со схожими условиями съемки и внешним видом объектов. Сформированный в работе набор данных содержит изображения объектов на однотонном фоне, причем чаще всего белом. Объекты также представлены без искажений, пыли, грязи и т. д. В реальных условиях объекты могут быть визуально неразличимы даже человеком. Поэтому ошибки в подобных ситуациях неизбежны.

ЛИТЕРАТУРА

1. Liu S. Very deep convolutional neural network based image classification using small training sample size / S. Liu, W. Deng // Asian Conference on Pattern Recognition (ACPR). – 2015. – P. 730-734.
2. Szegedy C. Rethinking the Inception Architecture for Computer Vision / C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, Z. Wojna // IEEE Conference on Computer Vision and Pattern Recognition (CVPR). – 2016. – P. 2818-2826.
3. Zoph B. Learning Transferable Architectures for Scalable Image Recognition / B. Zoph, V. Vasudevan, J. Shlens, Q. V. Le // IEEE Conference on Computer Vision and Pattern Recognition (CVPR). – 2018. – P. 8697-8710.
4. Iandola F.N. SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and <0.5MB model size / F. N. Iandola, S. Han, M. W. Moskewicz, K. Ashraf, W. J. Dally, K. Keutzer // International Conference on Learning Representations (ICLR). – 2017.
5. Huang G. Densely connected convolutional networks / G. Huang, Z. Liu, K. Q. Weinberger, L. van der Maaten // IEEE Conference on Computer Vision and Pattern Recognition (CVPR). – 2017. – P. 2261-2269.
6. Sandler M. MobileNetV2: Inverted residuals and linear bottlenecks / M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, L.-C. Chen // IEEE Conference on Computer Vision and Pattern Recognition (CVPR). – 2018. – P. 4510-4520.
7. Howard A.G. Mobilenets: Efficient convolutional neural networks for mobile vision applications – URL: <https://arxiv.org/pdf/1704.04861.pdf> (дата обращения 20.01.2022).
8. Russakovsky O. ImageNet large scale visual recognition challenge / O. Russakovsky, J. Deng, H. Su, J. Krause, S. Satheesh, S. Ma, Z. Huang, A. Karpathy, A. Khosla, M. Bernstein, A. C. Berg, Li Fei-Fei // International Journal of Computer Vision (IJCV). – 2015. – Vol. 115. – No. 3. – P. 211-252.

9. The CIFAR-10 Dataset – URL: <https://www.cs.toronto.edu/~kriz/cifar.html> (дата обращения 20.01.2022).

10. Trashnet Dataset – URL: <https://github.com/garythung/trashnet> (дата обращения 20.01.2022).

11. Garbage Classification – URL: <https://kaggle.com/asdasdasdasdas/garbage-classification> (дата обращения 20.01.2022).

12. Garbage Classification (12 classes) – URL: <https://kaggle.com/mostafaabla/garbage-classification> (дата обращения 20.01.2022).

13. Otsu N. A threshold selection method from gray-level histogram // IEEE Transactions on System Man Cybernetics. – 1979. – Vol. SMC-9. – No. 1. – P. 62-66.

14. Image Background Remove Tool – URL: <https://github.com/OPHoperHPO/image-background-remove-tool> (дата обращения 20.01.2022).

15. Ren S. Faster r-cnn: Towards real-time object detection with region proposal networks / S. Ren, K. He, R. Girshick, J. Sun // Neural Information Processing Systems 28 (NIPS 2015). – 2015.

16. Qin X. U²-Net: Going deeper with nested U-structure for salient object detection / X. Qin, Z. Zhang, C. Huang, M. Dehghan, O. R. Zaiane, M. Jagersand // Pattern Recognition. – 2017. – Vol. 106. – P. 107404.

17. Wang L. Learning to detect salient objects with image-level supervision / L. Wang, H. Lu, Y. Wang, M. Feng, D. Wang, B. Yin, X. Ruan // IEEE Conference on Computer Vision and Pattern Recognition. – 2017. – P. 136-145.

18. Dataset radioactive waste – URL: <https://github.com/arhipov-ae/Dataset-radioactive-waste> (дата обращения 20.01.2022).

19. Hussain M. A study on cnn transfer learning for image classification / M. Hussain, J. J. Bird, and D. R. Faria // Advances in Computational Intelligence. – 2019. – P. 191-202.

Research of Convolutional Neural Networks in the Problem of Classification of Images of Radioactive Waste

Arhipov A.E.

Peter the Great Saint-Petersburg Polytechnic University
Saint-Petersburg, Russian Federation
arhipov.ae@edu.spbstu.ru

Fomin I.S.

Russian State Scientific Center
for Robotics and Technical Cybernetics
Saint-Petersburg, Russian Federation
i.fomin@rtc.ru

Abstract. Radioactive contamination of the environment always occurs very quickly and on a large scale. At the same time, the causes of infection may be different and there is no guarantee that they will not occur again. Therefore, it is always necessary to be ready to take emergency measures to eliminate the consequences of radioactive contamination. To date, the most effective and safe solution to the problem of the elimination of radioactive waste is burial, therefore it is necessary to ensure the compactness of the placement of radioactive waste. To do this, contaminated waste can be compressed or burned in special installations. The use of vision systems with the use of convolutional neural networks will allow classifying the material of radioactive waste to determine incinerated or pressed objects. To conduct experiments on the applicability of CNN for this task, a dataset was

formed containing images from open datasets, as well as their own images. The conducted experiments confirm the effectiveness of using deep convolutional neural networks for this task. The best result of the classification of the material was shown by the InceptionV3 network with an accuracy of 89,58%. The greatest efficiency can be achieved by using the predictions of several neural networks, with the help of which the accuracy has increased to 91,58%.

Keywords: Deep learning, CNN, image classification, radioactive waste.

Библиографическое описание статьи

Архипов А.Е. Исследование сверточных нейронных сетей в задаче классификации изображений радиоактивных отходов / А.Е. Архипов, И.С. Фомин // Машиностроение: сетевой электронный научный журнал. – 2022. – Т.9, №2. – С. 39-44. DOI: 10.24892/RIJIE/20220207

Reference to article

Arhipov A.E., Fomin I.S. Research of convolutional neural networks in the problem of classification of images of radioactive waste, *Russian Internet Journal of Industrial Engineering*, 2022, vol.9, no.2, pp. 39-44. DOI: 10.24892/RIJIE/20220207