

РАСПОЗНАВАНИЕ И СОРТИРОВКА МУСОРА НА ОСНОВЕ НЕЙРОННОЙ СЕТИ С ОБУЧЕНИЕМ

Ишкинин Г.Г., студент,
Латыпов И.И., к.ф.-м.н., доцент
Бирский филиал УУНиТ, г. Бирск, Россия

Аннотация. В работе рассматривается и решается задача классификации объектов (на примере распознавания и сортировки отходов, производственного и бытового мусора) с использованием технологий искусственного интеллекта. Метод решения данной задачи – нейронные сети на основе глубокого обучения.

Ключевые слова: искусственный интеллект, нейронные сети, глубокое обучение.

Введение. Современные глубокие нейронные сети играют ключевую роль в развитии робототехники. В последнее время все больше и больше исследований направлено на создание и оптимизацию роботов, которые способны выполнять определенные задачи без участия человека. Одной из таких задач является очистка мусора. Стремительный рост производства отходов и негативное воздействие на окружающую среду делают эту задачу все более актуальной, особенно в городах и мегаполисах. В данной работе исследуется и решается проблема реализации модели робота для очистки мусора, основанная на глубоком обучении.

Изучаемая проблема. Современные технологии создают возможность создавать автономные устройства, которые способны не только выполнять простые задачи, но и более сложные, требующие применения разных алгоритмов и технологий. Одна из таких задач – это очистка мусора. Обычные пылесосы и щетки могут убирать пыль с ковров и полов, однако они не справляются с более сложными задачами по очистке мусора с улиц.

Одной из возможных технологий, которая может помочь в решении этой проблемы, является глубокое обучение. Глубокое обучение – это метод машинного обучения, который использует нейронные сети для обучения навыкам и возможностям, достигающим уровня человека и даже более высоких. Система глубокого обучения может использоваться для обучения робота воспринимать, анализировать и выделять мусор на различных поверхностях.

Реализация проекта по созданию робота для очистки мусора на основе глубокого обучения может быть достигнута благодаря технологиям компьютерного зрения и искусственного интеллекта. Для этого на робота устанавливаются несколько камер и датчиков, которые собирают информацию о мусоре. При помощи специализированных алгоритмов данные обрабатываются и используются для обучения нейронной сети, которая определяет различные типы мусора на основе своей формы, размеров и текстур.

Разработка роботов для очистки мусора на основе глубокого обучения - это потенциально эффективный способ борьбы с проблемой загрязнения окружающей среды. Роботы могут работать дольше, чем человек, не устают и не нагружают окружающую среду выбросами вредных веществ. Они также могут быстро и точно идентифицировать и собирать отходы, уменьшая, таким образом, риск засорения земли и водных ресурсов.

Одним из главных преимуществ использования таких роботов является повышение качества очистки территории от мусора. Роботы на основе глубокого обучения могут быстрее и точнее идентифицировать различные типы мусора, сортировать их и отправлять на переработку. Более эффективная работа роботов позволяет уменьшить количество отходов на свалках и облегчить процесс их переработки и утилизации.

Еще одним преимуществом разработки роботов для очистки мусора является потенциал для создания рабочих мест. Для производства, технического обслуживания и программирования роботов требуется высококвалифицированный персонал. Кроме того, на поиск мусора и его

утилизацию потребуется больше рабочих, что может привести к созданию новых рабочих мест.

Также стоит отметить, что многие страны уже начали активно использовать роботов для удаления мусора на территориях, где трудно или опасно для человека работать. Например, Норвегия успешно использует роботов для очистки на нефтяных платформах, а в Китае и Японии уже созданы роботы для очистки заброшенных территорий.

Однако, несмотря на большое количество преимуществ, нельзя не отметить и ряд проблем, которые стоят перед разработчиками роботов для очистки мусора. Одной из таких проблем является повышенная сложность распознавания различных типов мусора. Бывает, что роботы могут ошибаться и не сортировать мусор корректно, что негативно влияет на процесс утилизации и переработки отходов.

Кроме того, роботы нуждаются в постоянном техническом обслуживании и обновлении программного обеспечения, что может быть достаточно дорогостоящим процессом. Некоторые типы мусора также могут быть токсичными и представлять для роботов опасность.

Тем не менее, разработка роботов для очистки мусора на основе глубокого обучения имеет большой потенциал и перспективы для использования в масштабных и сложных проектах по очистке окружающей среды.

Модель и настройка алгоритма. В работе исследовались архитектуры ResNet50, VGG-11 и AlexNet. Был использован Softmax в качестве активации для последнего полностью связанного слоя и было произведено сравнение производительности трех архитектур. Исследование показало, что модифицированная модель AlexNet дает самую высокую точность теста и требует относительно небольшого времени на обучение. Поэтому была выбрана модифицированная модель AlexNet, изучение которой продолжались на двух моделях, использующих различные функции потерь и активации для последнего полностью подключенного слоя.

Базовая архитектура обеих моделей одинакова и представлена на рисунке 1. Сначала использовали базовую модель AlexNet, затем добавили нормализацию. Деактивировали два конволюционных слоя, содержащих 384 фильтра, поскольку в ходе экспериментов по обучению наблюдалась схожая точность тестов как с этими двумя слоями, так и без них. Таким образом, всего использовалось одиннадцать слоев.

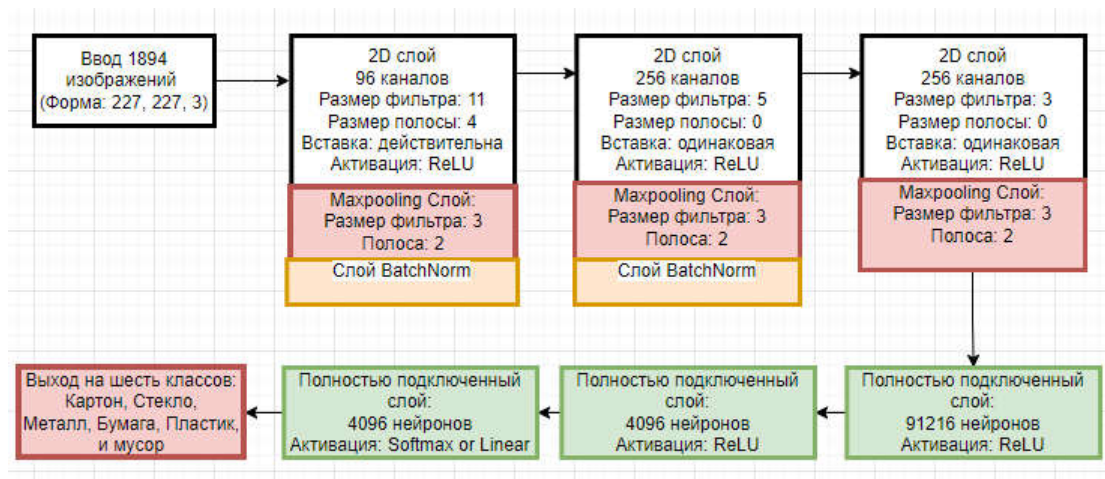


Рисунок 1. Архитектура базовой модели

В первой модели использовали Softmax в качестве функции активации для последнего полностью подключенного слоя и категориическую функцию потерь перекрестной энтропии, формула которой выглядит следующим образом.

$$L(z, \tilde{z}) = -\frac{1}{n} \sum_{j=0}^n \sum_{i=0}^n z_{i,j} \log(\tilde{z}_{i,j}),$$

где z – истинные значения меток классов, \tilde{z} – предсказанные значения меток классов, n – количество изображений.

Вторая модель, которую опробовали, использовала линейную функцию активации для последнего полностью подключенного слоя и категориическая функция потерь "петля", формула которой выглядит следующим образом:

$$L(z, \tilde{z}) = \max(z^T \tilde{z} - \max(1 - z) + 1, 0).$$

Перед началом моделирования и настройки алгоритма необходимо выполнить предобработку данных, которая включает в себя следующие шаги:

1. Сбор данных. Для обучения и тестирования модели нужно собрать данные, которые будут представлять объекты, которые необходимо очистить от мусора. Для этого можно использовать данные, полученные с помощью дронов или камер на специальных устройствах.

2. Аугментация данных. Данные не всегда могут быть идеальными, поэтому перед обучением модели необходимо провести аугментацию данных. Это может включать в себя изменение размера изображений, повороты, изменение контрастности и яркости, а также добавление шума.

3. Разделение выборки на обучающую и тестовую. Этот шаг позволяет оценить качество работы модели, используя данные, на которых модель не обучалась.

4. Нормализация данных. Нормализация данных важна, потому что она позволяет модели лучше обучаться. Например, изображения можно нормализовать, используя масштабирование или стандартизацию.

5. Создание меток. Для каждого объекта нужно создать метку, которая показывает, какой класс ему принадлежит. Например, есть два класса - мусор и не мусор.

6. Преобразование данных. Модели глубокого обучения часто используют тензоры, поэтому данные необходимо преобразовать в тензоры.

После выполнения предобработки данных необходимо обучить модель на тренировочных данных. Для этого выполняются следующие шаги:

1. Определение архитектуры модели. Это включает в себя выбор типа сети (например, сверточная нейронная сеть), количество слоев, количество нейронов в каждом слое и функции активации для каждого слоя.

2. Компиляция модели. На этом этапе необходимо выбрать оптимизатор, функцию потерь и метрики, которые будут использоваться для оценки качества работы модели.

3. Обучение модели на тренировочных данных. На этом этапе модель применяется к тренировочным данным, и каждая эпоха обучения заключается в

передаче данных через модель и настройке весов, чтобы минимизировать функцию потерь.

4. Оценка качества работы модели на тестовых данных. Для этого используются метрики, которые были выбраны при компиляции модели.

5. Настройка гиперпараметров модели. Гиперпараметры - это параметры, которые не определяются во время обучения, а задаются до его начала. Например, скорость обучения (learning rate), количество эпох обучения, размер батча и т.д.

После обучения модели на тренировочных данных необходимо выбрать оптимальные значения гиперпараметров и настроить параметры модели для достижения наилучших результатов на тестовых данных. Для этого используются следующие шаги:

1. Подбор гиперпараметров модели. Этот шаг включает в себя выбор оптимальных значений гиперпараметров, таких как скорость обучения, количество слоев, количество нейронов в каждом слое, размер батча и т.д. Разные гиперпараметры могут влиять на качество работы модели, поэтому этот шаг является важным для достижения наилучших результатов.

2. Настройка параметров модели. Этот шаг включает в себя настройку параметров модели, таких как веса, функции активации и т.д. Это может включать в себя изменение весов, добавление или удаление слоев и изменение функций активации для каждого слоя.

3. Оценка качества работы модели. На этом этапе модель оценивается на тестовых данных для определения качества ее работы.

4. Повторение процесса для достижения лучшей производительности. Если результаты не удовлетворяют требованиям, можно повторить процесс, начиная с подбора гиперпараметров, и настроить параметры модели еще раз до тех пор, пока не будет достигнута лучшая производительность.

Результаты моделирования. Комбинация линейной функции активации и петлевой функции потерь обеспечивает классификацию "максимум-максимум", и поэтому очень похожа на структуру SVM. SVM является

мощным инструментом при решении задач бинарной классификации, но в нашем проекте рассматривалась задача многоклассовой классификации. Поэтому использовали категориальную потерю петли, которая является расширением потери петли, используемой в SVM.

Для обеих моделей используем оптимизатор Adam и размер мини-партии 32. Точность обучения и тестирования двух наших моделей приведена в таблицах 1,2. В целом, наши модели имели тестовую точность, которая варьировалась от 70% до 80%, а модели, добавляющие частичное увеличение данных, достигли немного лучших результатов. Модель, использующая категориальные потери на петлях с частичным дополнением данных, достигла самого высокого результата - 79.94%.

Таблица 1. Точность обучения и тестирования 1 модели

Модель 1(Softmax)	Точность обучения	Точность тестирования	Количество попыток
Обычная модель	99,63%	74,57%	40
Добавление отсева	94,56%	72,04%	80
Добавление дополнения данных	78,04%	72,20%	30
Частичное дополнение данных	99,68%	79,46%	60

Таблица 2. Точность обучения и тестирования 2 модели

Модель 2(Linear)	Точность обучения	Точность тестирования	Количество попыток
Обычная модель	99.89%	72.67%	40
Добавление отсева	89.39%	69.04%	80
Добавление дополнения данных	74.97%	74.09%	30
Частичное дополнение данных	99.79%	79.94%	60

На Рисунке 2. приведено сравнение потерь при обучении и сходимость точности обучения моделей с частичным дополнением данных. В первые 30 попыток скорость сходимости потерь при обучении и точности обучения были

примерно одинаковыми для двух моделей. Сходимость в этот период, очевидно, была медленнее, чем у простых моделей. Поведение потерь при обучении и точности обучения напоминало поведение простых моделей во время во вторые 30 попыток, когда перешли к обычным моделям.

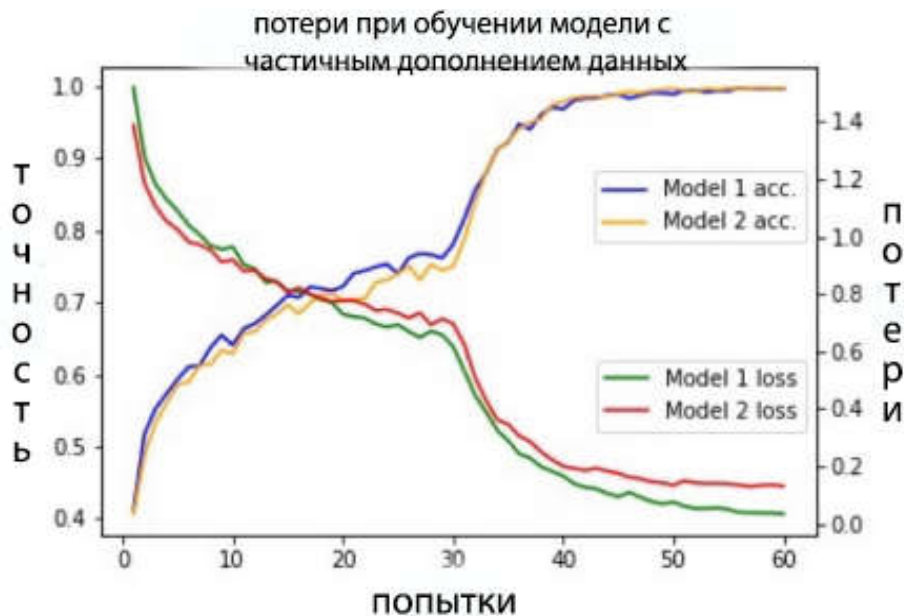


Рисунок 2. Потери при обучении модели с частичным дополнением данных

Вывод. Использование глубокого обучения в данном проекте, позволила получить более высокую производительность. Проект позволил моделировать и разработать робота, который способен очищать улицы от мусора с высокой точностью и эффективностью. Для развития данной идеи дальше будет необходимо проводить дополнительные исследования и эксперименты, вместе с тем, знания и навыки, полученные в процессе создания данного проекта, позволяют более осмысленно подойти к изучаемой проблеме и полнее использовать технологии искусственного интеллекта на основе нейронных сетей.

Литература

1. Николенко С. Глубокое обучение / С. Николенко, А. Кадурич, Е. Архангельская. СПб.: Питер, 2018. 480 с.

2. H. Ali, N. Ahmad, M. D. Ngali, and M. Najafian, "Performance Evaluation of Machine Learning Techniques for Waste Classification," *Sustainability*, vol. 10, no. 11, p. 4309, 2018.

3. J. Redmon et al. *You Only Look Once: Unified, Real-Time Object Detection*. (2016).

4. B. Singh et al. *Deep convolutional neural network for classification of garbage*. (2018).