

27. Scaramuzza D., Fraundorfer F. Visual Odometry, *IEEE Robotics and Automation Magazine*, 2011, No. 12, pp. 80-92.
28. Konolige K., Agrawal M., Sol J. Large scale visual odometry for rough terrain, *Proc. Int. Symp. Robotics Research*, 2007.
29. Tardif J., Pavlidis Y., Daniilidis K. Monocular visual odometry in urban environments using an omnidirectional camera, *Proc. IEEE/RSJ Int. Conf. Intelligent Robots and Systems*, 2008, pp. 2531-2538.
30. Agostinho L. et al. A Practical Survey on Visual Odometry for Autonomous Driving in Challenging Scenarios and Conditions, *IEEE Access*, 2022, Vol. 10.

Соколов Сергей Михайлович – Федеральный исследовательский центр Институт прикладной математики им. М.В. Келдыша Российской академии наук; e-mail: sokolsm@list.ru; г. Москва, Россия; тел.: 84992207994; д.ф.-м.н.; профессор; г.н.с., зав. сектором.

Богуславский Андрей Александрович – Федеральный исследовательский центр Институт прикладной математики им. М.В. Келдыша Российской академии наук; e-mail: anbg74@mail.ru; г. Москва, Россия; тел.: 84992207994; д.ф.-м.н.; в.н.с.

Sokolov Sergey Mikhailovich – Keldysh Institute of Applied Mathematics Russian Academy of Sciences; e-mail: sokolsm@list.ru; Moscow, Russia; phone: +74992207994; dr. of math. and physics. sc.; professor; principal researcher, chief division.

Boguslavsky Andrey Alexandrovich – Keldysh Institute of Applied Mathematics Russian Academy of Sciences; e-mail: anbg74@mail.ru; Moscow, Russia; phone: +74992207994; dr. of math. and physics. sc.; leading researcher.

УДК 004.896; 303.732.4

DOI 10.18522/2311-3103-2025-2-140-150

Н.М. Чернышов, И.К. Романова-Большакова

МЕТОДИКА ИДЕНТИФИКАЦИИ ОБЪЕКТА ДЛЯ ИНТЕГРАЦИИ С РОБОТИЗИРОВАННЫМИ СИСТЕМАМИ

Целью исследования является разработка методики идентификации и определения местоположения объектов в условиях низкой видимости и возможного изменения их формы, с акцентом на извлечение деталей, созданных методом селективного лазерного спекания (SLS), из порошковой среды. В работе рассматриваются два принципиально разных подхода к формированию алгоритмов управления роботизированным манипулятором. Первый подход, доверительный, основан на предположении о минимальном смещении объекта в процессе манипуляций. Манипулятор движется по траектории, рассчитанной на основе предварительной трехмерной модели, без коррекции до момента захвата. Этот метод отличается высокой скоростью выполнения операции и минимальными вычислительными затратами. Однако он сопряжен с рисками: деформация объекта из-за сопротивления среды, смещение детали при контакте с инструментом, а также невозможность захвата при значительных отклонениях от номинального положения. Второй подход, осторожный, предполагает поэтапное удаление слоев порошка для визуализации объекта и корректировки траектории до захвата. Этот метод включает несколько этапов: удаление верхнего слоя среды до частичного обнажения детали, анализ данных для уточнения положения объекта, а также построение адаптивной траектории с учетом возможного смещения. Отдельное внимание в статье уделено генерации данных для обучения нейронных сетей, которые используются для идентификации объектов в условиях зашумленности. Рассмотрены два метода искусственного моделирования порошковых покрытий. Примитивный метод заключается в расширении вершин трехмерной модели вдоль нормалей с добавлением случайного шума. Усовершенствованный метод предполагает дифференцированное распределение порошка с учетом локальной кривизны поверхности. Последующие экспериментальные результаты показали, что обучение нейронной сети с использованием реальных данных имеет низкую эффективность. Точность распознавания составила 60–75%, что связано с малым объемом выборки и влиянием внешних факторов, таких как освещение и помехи. В то же время использование синтетических данных, подготовленных по представленной в исследовании методике, позволило повысить точность распознавания до 92%. Практическая значимость работы заключается в разработке методики поиска, обнаружения и определения детали, погруженной в порошок, что может быть использовано для автоматизации процессов постобработки на производствах, использующих селективное лазерное спекание. Разработанные решения адаптированы для интеграции в роботизированные системы,

работающие в условиях ограниченной видимости. Предложенные методы могут быть масштабированы на широкий спектр задач в аддитивном производстве и робототехнике, что делает их перспективными для внедрения в промышленные процессы.

Селективное лазерное спекание; обнаружение объектов; нейронная сеть; генерация данных; моделирование изменения объекта.

N.M. Chernyshov, I. K. Romanova-Bolshakova

OBJECT IDENTIFICATION METHOD FOR INTEGRATION WITH ROBOTIC SYSTEMS

The aim of the research is to develop a methodology for identifying and determining the location of objects under conditions of low visibility and potential changes in their shape, with a focus on extracting parts created using selective laser sintering (SLS) from a powder medium. The study examines two fundamentally different approaches to forming control algorithms for a robotic manipulator. The first approach, trust-based, is based on the assumption of minimal displacement of the object during manipulation. The manipulator moves along a trajectory calculated from a preliminary three-dimensional model without correction until the moment of capture. This method is characterized by high operational speed and minimal computational costs. However, it carries risks such as object deformation due to environmental resistance, displacement of the part upon contact with the tool, and the inability to capture the object if it deviates significantly from its nominal position. The second approach, cautious, involves the gradual removal of powder layers to visualize the object and adjust the trajectory before capture. This method includes several stages: removing the top layer of the medium to partially expose the part, analyzing data to refine the object's position, and constructing an adaptive trajectory considering possible displacement. Special attention in the article is given to data generation for training neural networks, which are used for object identification under noisy conditions. Two methods of artificial modeling of powder coatings are considered. The primitive method involves expanding the vertices of a three-dimensional model along their normals with the addition of random noise. The improved method proposes differentiated powder distribution considering local surface curvature. Subsequent experimental results showed that training a neural network using real data has low efficiency. Recognition accuracy ranged from 60% to 75%, which is attributed to the small sample size and the influence of external factors such as lighting and interference. At the same time, the use of synthetic data, prepared according to the methodology presented in the study, increased recognition accuracy to 92%. The practical significance of the work lies in the development of a methodology for searching, detecting, and identifying a part immersed in powder, which can be used to automate post-processing processes in industries utilizing selective laser sintering. The developed solutions are adapted for integration into robotic systems operating under conditions of limited visibility. The proposed methods can be scaled to a wide range of tasks in additive manufacturing and robotics, making them promising for implementation in industrial processes.

Selective laser sintering; object detection; neural network; data generation; object change modeling.

Введение. Детали, произведенные методом селективного лазерного спекания, как правило, нуждаются в комплексной постобработке, что значительно увеличивает стоимость производства. Из-за специфики производства после спекания деталь оказывается полностью погруженной в плотную массу порошкообразного материала. Помимо этого, все отверстия и полости детали заполнены порошком. Извлечение детали из формы для запекания и последующая ее очистка являются трудоемкими процессами, выполняемыми вручную сотрудниками производства, вынужденными использовать специальные средства защиты из-за негативного влияния на слизистые оболочки и кожный покров человека, оказываемого материалами, используемыми при производстве.

Одним из ключевых моментов, препятствующих автоматизации процессов постобработки при производстве методом селективного лазерного спекания, является обнаружение произведенной детали в массе порошка и определение ее местоположения для проведения дальнейших манипуляций. Заметным препятствием в этом процессе является недоступность детали для анализа при помощи инструментов видеоанализа после произведения процедуры спекания детали. Как следствие, невозможность обнаружения детали на начальном этапе приводит к невозможности построения строго заданной траектории манипулятора, необходимой для извлечения произведенной детали из формы для спекания.

Методология достижения видимости детали. Оценка окружающей среды является очень важной частью планирования извлечения объектов из сред любой плотности. В описываемом случае пространство, в условиях цеха, представлено спекающей установ-

кой и находящейся в ней формой для спекания, манипулятором и условной платформой, на которую необходимо поместить деталь для дальнейшей обработки. Важным условием является размещение извлекаемого объекта. Он погружен в толщу порошка с некоторым количеством порошкообразного материала (из которого и произведена деталь), покрывающего деталь сверху. Таким образом, объект оказывается недоступен для дистанционного анализа какими-либо датчиками, в том числе видеокамерой. Однако, если рассматривать деталь, произведенную посредством SLS, ее местоположение заранее известно, благодаря специфике производства. Впрочем, оно неизбежно будет изменено при проведении манипуляций с порошком из-за отсутствия крепления детали к чему-либо. Расположение детали в форме для спекания схематично представлено на рис. 1




Рис. 1. Расположение детали в толще порошка в форме для спекания.

Представленные условия приводят к необходимости рассмотрения стратегии достижения момента видимости детали в области видимости сенсоров для построения траектории захвата детали. В этом плане для достижения детали в нужных для захвата точках в общих чертах можно выявить два подхода: доверительный – прямое следование траектории, основанной на информации модели, с последующей коррекцией, осторожный – проведение манипуляций в пространстве до построения траектории извлечения.

В первом случае манипулятор движется строго по траектории, рассчитанной, исходя из заранее известной модели пространства, предполагая, что изготовленная деталь имеет точно определенное местоположение в пространстве и не меняет его до момента идентификации обратного. При этом при изначальном расчете могут быть обозначены не точки захвата объекта, а области, в рамках которых допускается вариативность в захвате. Поскольку деталь расположена внутри среды, на траектории манипулятора неизбежно происходит погружение в нее инструмента для захвата. После соприкосновения схвата манипулятора со средой, в которую погружена деталь, происходит смещение ее частиц, способное изменить местоположение детали. Доверительный подход строится на предположении о том, что смещение положения детали в пространстве либо отсутствует, либо пренебрежимо мало. Тогда траектория манипулятора может оставаться неизменной без значимого влияния на результат извлечения. Коррекция траектории допускается уже после предполагаемого успешного захвата детали, когда она появляется на поверхности и становится доступной для анализа. При этом допускается коррекция точек захвата, в том числе при помощи повторного захвата детали.

Доверительный подход имеет все основания стать верным решением, если масса детали, погруженной в среду является значительной в сравнении с перемещающейся массой окружающей среды, либо при допущении, что частицы, составляющие среду, имеют в ходе манипуляций малое перемещение и, как следствие, малое влияние на положение самой детали. В обратном случае смещение детали от номинального местоположения может привести к увеличению попыток успешных захватов или к случайному расположению детали в пространстве таким образом, что ее захват окажется невозможным, а отмеченные для захвата области недостижимыми [1]. Заметные ограничения в использовании метода привносят геометрические параметры извлекаемого объекта. Взаимодействие объекта захвата с окружающей его средой, а также дополнительное усилие, приложенное со стороны схвата, для преодоления сопротивления плотной среды, может привести к появлению дефектов объекта во время его извлечения. Именно это ограничение является критически важным для проведения работ по извлечению деталей, произведенных методом SLS.

Во втором случае, в случае осторожного подхода, предполагается удаление верхнего слоя среды, покрывающей деталь, до тех пор, пока не станет возможным анализ ее местоположения. Таким образом, траектория движения манипулятора носит строго плановый характер до момента появления части детали на поверхности до произведения попыток ее захвата. При этом важно понимать, что появление той или иной части детали на поверхности не гарантирует однозначной идентификации ее местоположения, что увеличивает время, затраченное на подготовку к извлечению.

Такой подход имеет ряд ограничений, связанных с параметрами среды, в которой находится объект. Так, осторожный подход лишен смысла в случае, если объект захвата находится в жидкой среде, не имеющей внешних ограничений. В случае, если жидкость наполняет некоторую емкость, есть возможность удаления части жидкости путем ее выкачивания насосом. Но при нахождении объекта в воде в природных условиях применение такого подхода не приведет к положительному результату.

Тем не менее, применительно к средам, схожим по параметрам к рассматриваемым в практической задаче, осторожный подход, наиболее вероятно, способен продемонстрировать результаты заметно лучше, чем доверительный. Благодаря предварительной диагностике местоположения детали и уменьшению сопротивления среды вероятность повреждения объекта захвата снизится [2]. Точность захвата при этом увеличивается, так как открывается больше возможностей для анализа местоположения объекта и коррекции траектории движения манипулятора. По этой причине в случае, если среда, в которую погружен объект, представляет собой порошок, осторожный подход должен рассматриваться в качестве основного.

Применительно к задаче извлечения детали из формы для спекания алгоритм реализации описываемого подхода выглядит следующим образом:

1. Манипулятор движется по намеченной заранее траектории к границе раздела сред.
2. Схватом манипулятора производится сдвигание слоя порошка, расположенного над деталью (местоположение детали сразу после спекания является известным). Этот шаг производится несколько раз, до появления первых частей извлекаемой детали на поверхность.
3. При появлении части детали на поверхность производится анализ ее местоположения. В случае однозначной идентификации местоположения объекта производится его извлечение. В противном случае производятся действия, описанные ниже.
4. Схватом манипулятора производится сдвигание массы порошка, расположенной рядом с деталью. Смещение порошка происходит с той стороны, которая способна предоставить наибольшее количество информации о местоположении детали. Координаты такой области рассчитываются до начала извлечения. Этот шаг выполняется рекурсивно до получения однозначного местоположения извлекаемой детали.
5. На основании полученной информации о детали (в ходе манипуляций ее местоположение неизбежно изменится в сравнении с первоначальным) строится скорректированная траектория манипулятора для захвата детали в определенных точках.
6. Корректируется обратная траектория манипулятора с деталью в схвате.
7. Производится захват объекта. При этом траектория манипулятора претерпевает незначительные изменения в случае, если в ходе достижения точек захвата произошло изменение местоположения детали. Коррекция траектории в этом случае производится в процессе достижения точек захвата.
8. Извлечение объекта. Манипулятор следует скорректированной траектории извлечения детали. При этом траектория может быть скорректирована в ходе извлечения в случае, если сопротивление, встречаемое со стороны среды во время извлечения, превышает допустимое расчетное.

Следование такому алгоритму извлечения детали из формы для спекания приведет к минимизации вероятности появления дефектов самой детали. Сравнение доверительного и осторожного подходов к формированию алгоритма извлечения детали показывает, что использование осторожной стратегии является более оправданной применительно к поставленной практической задаче и может быть приложено к большему числу примене-

ний. Доверительная же тактика является более опрометчивой и может быть применена при извлечении объектов из различных сред только в очень специфичных условиях, хотя и требует меньше затрат на проработку вариативности извлекаемых объектов. Условие того, что характеристики извлекаемого объекта могут говорить о возможном появлении дефектов объекта при взаимодействии со средой, ставит необходимость использования осторожного подхода в задаче извлечения широкой вариации хрупких объектов из сред с высокой плотностью.

Определение местоположения объекта. Одним из ключевых моментов в процессе извлечения детали из формы для спекания остается определение ее местоположения и, как следствие, точек на детали, в которых должен произойти предполагаемый захват [3]. Определение местоположения объекта может быть реализовано при помощи видеокамеры, установленной в рабочем пространстве манипулятора, и нейронной сети, позволяющей идентифицировать объект и определить ориентацию объекта в пространстве. Таким образом, задача определения местоположения и ориентации объекта может быть разбита на несколько пунктов:

1. Выявление объекта в форме для запекания.
2. Выделение образа объекта для получения видимого сечения произведенной детали.
3. Определение ориентации детали, исходя из полученных данных.

Проблема выявления объекта в форме может быть решена при помощи специально обученной нейронной сети. При этом, важно полагать, что за один цикл производства может быть произведено сразу несколько деталей, если того позволяют габаритные размеры деталей и спекающей установки. А, поскольку селективное лазерное спекание зачастую используется для прототипирования, важно отметить, что для каждого такого случая необходимо будет тренировать нейронную сеть заново. Тогда важным параметром нейронной сети, помимо качества определения объекта, будет являться скорость обучения.

Подготовка реальных данных. Поскольку множество деталей, которые можно произвести методом селективного лазерного спекания, достаточно велико, тренировка универсальной нейронной сети является бесполезным занятием – детали могут быть до смешения похожи, но при этом обладать совершенно различными прочностными характеристиками [4]. По этой причине подготовленную нейронную сеть необходимо обучать либо для каждой детали отдельно (в случае со спеканием единственной за один производственный цикл), либо для численно ограниченного набора деталей (одинаковых или различных) [5]. При этом габаритные ограничения формы для запекания играют важную роль, ограничивая количество производимых за один цикл деталей.

Подготовка данных для обучения нейронной сети является очень важной деталью, заметно влияющей на эффективность конечной системы распознавания [6]. В случае с производством деталей методом селективного лазерного спекания есть два способа сбора данных и генерации набора данных – использование реальных данных и искусственных.

Использование реальных данных имеет преимущество из-за того, что они получены с макета настоящей произведенной детали, со всеми ее изначальными изъянами, обусловленными наливанием порошка на поверхность и заполнением им всех отверстий и вогнутостей детали [7]. Также, для использования реальных данных можно провести предварительную подготовку изображений, предварительно выделив контур изображений при помощи методов обработки изображений.

Тем не менее, такой подход сталкивается с рядом трудностей. Во-первых, сбор данных с произведенной модели занимает значительное количество времени, так как для качественного обучения требуется достаточно много данных, а цикл производства одной детали может занимать до суток. Во-вторых, селективное лазерное спекание, как и множество других аддитивных технологий, зачастую используется для прототипирования и единичного производства [8]. В таком случае сбор данных увеличит время, затраченное на процесс, в несколько раз и, следовательно, стоимость разработки и прототипирования.

В свою очередь, генерация искусственных данных является более универсальным способом, применимым для различных типов производств и не требующим ручного труда. Однако, этот метод встречает ряд проблем, связанных с трудностью моделирования

налипших на деталь частиц порошка. Поскольку основным процессом в селективном лазерном спекании является наплавление порошка при помощи лазера, существующие работы на тему математического моделирования характеристик детали были направлены на исследование преобразований материала в ходе спекания, минуя процесс излишнего налипания порошка.

Методика генерации искусственных данных. Генерация порошка и искусственных припорошенных моделей – задача текущих исследований, которые проводятся в различных научных организациях по всему свету. Задача осложняется тем, что налипание имеет стохастический характер, а в ходе извлечения порошок неизбежно пересыпается, меняет местоположение. Таким образом, форма детали, с точки зрения записывающего устройства, заметно изменяется. На текущий момент в последних исследованиях встречается несколько подходов к генерации искусственных припорошенных моделей для тренировки нейронной сети, определяющей объект исследования.

На тему порошков в аддитивном производстве проведен широкий ряд исследований. Например, распределение брызг на форме для запекания и даже определение дефектов на лазерно-порошковой наплавке [9]. Тем не менее, распределение порошка на напечатанных деталях остается неисследованным.

Моделирование порошка на поверхностях печатных деталей схоже со скоплением снега на уличных объектах. Например, недавняя работа авторов [10] была проведена с использованием основной модели падения и скапливания снега [11] и управляемой упругопластической конститутивной модели с интегрированным гибридным методом материальных точек Эйлера-Лагранжа для моделирования снега. Частицы снега были описаны физически, в то время, как симуляторы твердых и жидких тел совместно симулировали широкий спектр поведения снега.

Генерация искусственных образов с использованием композиции не всегда требует трехмерной модели объекта. Булс [12] и его коллеги работали над генерацией груды объектов, используя метод композиции, путем захвата разных видов реальных объектов и их соединения в единое целое, однако результаты определения не были благоприятными – точность правильно обнаруженных объектов колебалась от 10% до 29% для различных объектов.

Двибеди, Мисра и Хеберт [13] представили другой подход, использующий композицию для быстрого синтеза данных для обнаружения объектов, отгаликивающийся от реальных изображений объектов и их окружения и автоматического извлечения масок объектов. Объекты помещались в сценарии с различными смесями для генерации итоговых данных. Лучший показатель эффективности был достигнут на уровне 50,8% в среднем при обучении на смеси реальных и искусственных изображений и тестировании на невидимом наборе данных.

Одним из достаточно эффективных способов генерации деталей с налипшим на их поверхность порошком является рандомизация доменов – простой метод обучения моделей исключительно на симулированных образах. Тобин и его коллеги сосредоточились на задаче обучения нейронных сетей с использованием рандомизации доменов для проведения локализации объектов для роботизированного захвата в беспорядочной среде [14]. Они обнаружили, что для ряда геометрических объектов они смогли натренировать детектор с точностью до полутора сантиметров в реальной среде, используя только симулированные данные, визуализированные только с помощью простых сгенерированных текстур.

Ражпура, Бажинов и Хедж показали, что при помощи трансферного обучения и рандомизации доменов можно эффективно натренировать детектор объектов практически только на смоделированных данных [15]. Они применили эту стратегию для определения упакованных продуктов, расположенных в холодильнике и получили 24% средней точности (mAP – mean average precision) при использовании 55 интересующих объектов и 17 отвлекающих объектов при тестировании. Нейросеть была обучена на 4000 искусственных образах.

Даниельчук с коллегами предложили метод автоматической генерации искусственных данных 50000 изображений глубины и 340000 масок объектов, используя симулированные кучи трехмерных моделей, для задачи сбора мусорных корзин [16]. Рандомизация

доменов была применена для трехмерных объектов, мест расположения камер и внутренних параметров камеры. Авторы изменили нейросеть Mas R-CNN для обучения на искусственных и реальных изображениях глубины и пришли к выводу, что сеть, обученная на искусственных образах, превзошла сеть, обученную на реальных изображениях глубины, основываясь на средней точности и среднем отклике.

Главным выводом предыдущих работ заключался в том, что рандомизация доменов была лучше с точки зрения производительности натренированной сети по сравнению с методом композиции [17]. К тому же, метод композиции требовал немного реальных данных, которые могут быть недоступны из-за разнообразия трехмерных печатных деталей, в то время, как все методы трехмерной печати требуют использования трехмерной модели объекта. Таким образом, использование рандомизации доменов для генерации искусственных образов для обучения было адаптировано для рассматриваемой практической задачи.

Однако, из-за порошка на печатных деталях их форма визуально отличается от трехмерных моделей, что может оказать влияние на производительность сети. Следовательно, существует потребность в методе, способном предоставить ряд припорошенных моделей с, как минимум, одной моделью, напоминающей припорошенную деталь. Подобные были предложены исследователями Лимом и Фамом [18]. В случае с покрытыми порошком деталями, другой жизнеспособной альтернативой использованию глубоких нейронных сетей определения объектов может стать управление идентификацией с использованием сопоставления облаков точек.

Примитивный метод генерирования порошка является простым подходом, включающим в себя случайное расширение вершин файла STL вдоль их нормалей. Шаги являются следующими:

1. Дискретизация STL-файла объекта до облака точек с помощью дисковой выборки Пуассона. Это было сделано для лучшего распределения точек, на которых создавался искусственный порошок.
2. Расчет средних габаритов путем суммирования длины, высоты и ширины ограничительной рамки объекта.
3. Задание диапазона значений размеров для случайного выбора на основе процентного содержания порошка, заданного пользователем. Это значение находится в диапазоне от 0 до 1.
4. Выбор случайного значения в диапазоне размеров для каждой вершины. Новая вершина будет растянута вдоль нормали вершины на это значение.
5. Перестроение треугольной сетки из облака точек, созданного из новых расширенных точек, используя метод перестроения поверхности Пуассона для получения припорошенной модели.

Примитивный метод генерирования порошка, используемый Тобином и коллегами, произвел ряд моделей. Значения степени покрытия порошком в 5%, 10% и 15% являются достаточно надежными, то есть по крайней мере один образец из этих значений образует экземпляр, напоминающий реальную покрытую порошком деталь.

Примитивный метод генерации порошка обрабатывает вогнутые и выпуклые области одинаково. Тем не менее, эмпирически можно заметить, что порошок имеет тенденцию скапливаться в вогнутых областях в большей степени. Основываясь на этом наблюдении, был предложен усовершенствованный метод генерации порошка, который добавляет порошок дифференцированно, в зависимости от локальной кривизны (выгнутости) поверхности, которая характеризуется выпуклой оболочкой объекта. Шаги являются следующими:

1. Дискретизация STL-файла объекта до облака точек с помощью дисковой выборки Пуассона.
2. Получение выпуклой оболочки объекта. Выпуклая оболочка представляет общую информацию о геометрии объекта, включая вогнутые и выпуклые области.
3. Поиск точки пересечения Q на выпуклой оболочке для каждой точки P облака точек, используя алгоритм пересечения лучей и треугольников Моллера-Трумбора.

4. Расчет длины и направления PQ, если P не совпадает с Q. Большая длина PQ означала, что интересующая точка была слишком далеко от выпуклой оболочки, что может означать, что эта точка может быть вогнутой и, следовательно, там может быть обнаружено больше порошка. Если P и Q совпадают, это означает, что точка лежит на поверхности выпуклой оболочки и может являться выпуклой точкой. Однако, поскольку реальные объекты также могут иметь порошок на выпуклых поверхностях, небольшое случайное значение было получено из единичного распределения и применено вдоль нормали P.

5. Перестроение треугольной сетки, полученной из облака новых расширенных точек, используя метод перестроения поверхности Пуассона, для получения покрытой порошком модели.

Оба метода используют одинаковые первый и последний шаги, заключающиеся в дискретизации STL-файла до облака точек и перестроении облака точек в сеть для получения поверхности, напоминающей реальные покрытые порошком детали. Однако усовершенствованный метод генерации порошка обрабатывает вогнутые и выпуклые области по-разному.

Результат эксперимента по сбору реальных данных. В качестве основной нейронной сети для определения объекта принята сеть Saffe сверточного типа [19]. Архитектурно в ней можно выделить несколько слоев: входной (изображение), слой свертки, слой выборки, полносвязный слой и выходной. Эксперимент ставит целью проверку эффективности определения объекта на изображении описанной нейронной сетью. При этом, данные для ее обучения собраны вручную путем видеосъемки процесса извлечения детали из формы. Для сбора данных была взята деталь, произведенная методом селективного лазерного спекания. Деталь была погружена в порошок в форму для спекания и покрыта слоем порошка поверх, подобно тому, как выглядит форма для спекания с порошком сразу после производства. Затем с помощью металлических пластин часть порошка была смещена в сторону. Шаги по смещению порошка производились до тех пор, пока деталь не появлялась на поверхности в достаточной для ее анализа степени. Те же действия производились с последовательным поворотом детали до получения набора из шести видеозаписей.

После получения видеоматериалов была произведена первичная обработка полученных данных – полученное видео было разделено на отдельные кадры, а затем из набора кадров были исключены не валидные (с плохим качеством, без детали на изображении). Эксперимент проводился трижды с одной и той же деталью, **что позволило обеспечить повторяемость условий и достоверность результатов.** При этом третья съемка была специально проведена для проверки качества обучения нейронной сети. В результате разбиения видеоматериалов на кадры был получен набор реальных данных в виде фотографий деталей, припорошенных в разной степени и находящихся в различной степени погружения в порошок.

К сожалению, данный метод не дал достаточного эффекта. Полученный набор данных оказался, во-первых, достаточно мал (около 2000 изображений для каждого сечения) для качественного обучения нейронной сети, во-вторых, характеризовался низким качеством из-за отсутствия учета внешних факторов, таких как различные помехи или освещенность, что создает проблему при переносе модели в реальные условия эксплуатации. Результаты работы описанной нейронной сети сильно варьировались в зависимости от формы и положения детали. К примеру, для детали, представленной ниже, вероятность определения отдельных сечений в припорошенном состоянии достигала 75% при удачном положении камеры. Пример такой детали представлен на рис. 2,а.

Однако, при рассмотрении деталей с меньшими различиями, но при этом не менее важными для захвата, сечений, показывают заметно меньший результат, в том числе потому, что округлые формы детали оказываются тяжело идентифицируемы в условиях покрытия порошкообразным материалом, коим наполнены детали в силу производства. В случае детали, представленной на рис. 2,б, эффективность определения и вовсе снизилась до 60%. При этом в случае рассмотрения сечения снизу вероятность падает до 15%, так как объект снизу является полым, при этом полость наполнена порошком. Таким образом, набор реальных данных, полученных в ходе видеосъемки деталей, погруженных в различных конфигурациях в порошок, показал низкую эффективность для обучения нейронной сети.




Рис. 2. Фотографии детали свободной от порошка и утопленной в него, используемые для обучения нейронной сети

Генерация искусственных данных. Низкая эффективность описанного ранее сбора реальных данных приводит к необходимости генерации искусственного набора данных для обучения нейронной сети, идентифицирующей объект на изображении. В таком случае важно учитывать, что определяемый объект может иметь геометрические отличия от эталонного в силу наличия налипшего порошка на поверхности.

Для первичной проверки работоспособности нейронной сети был создан набор искусственных изображений, основанных на трехмерной детали, подготавливаемой для производства методом SLS. Поскольку для качественного обучения необходима разная степень зашумленности изображения, подготовка такого набора данных была произведена в несколько этапов:

1. Подготовка видеоряда с трехмерной моделью детали. Выбранная сфера разделяется на 200 меридианов и 200 параллелей, в точках пересечения которых ведется фиксация вида детали. Элемент фиксации вида направлен перпендикулярно поверхности сферы к ее центру.
2. Разделение видеоряда на отдельные кадры, представляющие собой изображения видов детали с различных ракурсов.

Полученные изображения видов детали подвергаются дополнительной обработке в разной комбинации таких параметров, как масштаб (рис. 3,а), поворот (рис. 3,б), яркость (рис. 3,в), наличие шума на изображении (рис. 3,г).

Результатом проведения описанных шагов является набор данных из 100000 различных изображений одного объекта, представленного к автоматизированному извлечению манипулятором. При этом, количество сгенерированных данных может отличаться для каждой отдельной детали путем изменения параметров генерации в случае недостаточности данных для обучения нейронной сети.

При генерации искусственных данных также важным параметром является цвет детали и цвет фона, на котором она изображена [20]. Применительно к рассматриваемой в данной работе практической задаче это обстоятельство приносит дополнительные сложности. Объект, предлагаемый к извлечению, расположен в среде того же цвета, что осложняет выделение контуров объекта и, как следствие, определение его местоположения в пространстве. По этой причине для улучшения качества набора данных и, как следствие, качества обучения нейронной сети на искусственно созданных изображениях деталь и фон, на котором она расположена, имеют одну цветовую гамму и отличаются по цвету незначительно.

Для дальнейшей работы с реальными деталями необходимо провести обучение и проверку нейронной сети с измененными геометрическими характеристиками детали – наличием налипшего на нее порошка. Для этого был применен усовершенствованный метод.

Для составления набора данных для обучения была выбрана та же деталь, что использовалась для генерации набора без порошкообразных новообразований. При этом для составления разнообразного набора варьировалось как количество самих частиц, так и их размер. Поскольку в ходе спекания возможно спекание нескольких частиц между собой, на детали могут образовываться агломерации налипших частиц. Примеры полученных моделей для создания набора данных указаны на рис. 3,д.




Рис. 3. Примеры сгенерированных деталей, покрытых порошком

К полученным моделям покрытых порошком деталей были применены те же действия, что использовались при сборе данных с пустых моделей деталей. В результате был собран набор из 400000 измененных изображений припорошенной детали. Этого объема данных хватило для обучения нейронной сети обнаруживать деталь даже в сильноизмененном состоянии – с большим скоплением порошка на поверхности. В итоге вероятность обнаружения детали на изображении достигла 92%, чего вполне достаточно для определения детали на видеопотоке. Учитывая тот факт, что в пространстве происходят регулярные изменения как в освещенности детали, степени ее появления на поверхности, так и в составе объектов на изображении (в объектив неизбежно будут попадать те или иные части манипулятора), потеря объекта на 8% кадров принята в пределах допустимого.

Заключение. Разработанная методика поиска объекта и достижения видимости объекта на фиксирующей видеокамере показала свою работоспособность при рассмотрении детали в пространстве, соответствующем производству методом селективного лазерного спекания. При этом представлены возможные варианты использования как осторожного, так и доверительного подходов.

Описанная методика формирования порошкообразного материала на трехмерных моделях деталей в ходе проверки подтвердила свою работоспособность на высоком уровне. Дальнейшие изыскания насчет целесообразности использования метода формирования данных для обучения нейронной сети поиску детали на изображении показали высокую эффективность искусственной генерации данных в сравнении со сбором данных вручную с применением готовой детали.

Таким образом, применение подхода создания искусственного набора данных для обучения нейронной сети позволяет не только за короткое время получить необходимый набор данных, но и избежать влияния человеческого фактора на его качество. Использование таких методов может значительно ускорить процесс разработки и улучшить точность предсказаний, что в свою очередь повысит эффективность производства и снизит затраты на подготовку к производству новых деталей. Возможность генерировать синтетические наборы данных также открывает новые возможности для тестирования алгоритмов в различных сценариях без ограничений реальных данных. Такая гибкость позволяет разработчикам и технологам исследовать более широкий спектр условий и крайних случаев, что в конечном итоге приводит к созданию более надежных и адаптируемых моделей машинного обучения.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. *Waltermann R.D.* Method and system for locating objects, US7049960B2, 23 май 2006 г.
2. *Janabi-Sharifi F.* Collision: Modeling, simulation and identification of robotic manipulators interacting with environments, *J. Intell. Robot. Syst.*, May 1995, Vol. 13, Issue 1, pp. 1-44. DOI: 10.1007/BF01664754.
3. *Wojcienchowski C.R., Steele D.S., and Scudder H.J.* III. Device for method for manipulating a part, 4802195, 31 January 1989.
4. *Abbe E. and Sandon C.* On the universality of deep learning, *Advances in Neural Information Processing Systems*. Curran Associates, Inc., 2020, pp. 20061-20072.

5. Comprehensive system based on a DNN and LSTM for predicting sinter composition, *Appl. Soft Comput.*, October 2020, Vol. 95, pp. 106574. DOI: 10.1016/J.ASOC.2020.106574.
6. Ahmd W.A. Data preprocessing for neural networks, в *IEEE Students Conference, ISCON '02. Proceedings*, August 2002, 6-6. DOI: 10.1109/ISCON.2002.1214589.
7. Lopez E. et al. Evaluation of 3D-printed parts by means of high-performance computer tomography, *J. Laser Appl.*, June 2018, Vol. 30, Issue 3, pp. 032307. DOI: 10.2351/1.5040644.
8. Usher J.S. and Srinivasan M.K. Quality Improvement of a Selective Laser Sintering Process, *Qual. Eng.*, December 2000, Vol. 13, Issue 2, pp. 161-168. DOI: 10.1080/08982110108918638.
9. He K., Gkioxari G., Dollár P., u Girshick R. Mask R-CNN», 24 January 2018, *arXiv*: arXiv:1703.06870. DOI: 10.48550/arXiv.1703.06870.
10. Stomakhin A., Schroeder C., Chai L., Teran J., and Selle A. A material point method for snow simulation, *ACM Trans Graph.*, July 2011, Vol. 32, Issue 4, pp. 102:1-102:10, 3. DOI: 10.1145/2461912.2461948.
11. Moeslund T.B., Madsen C.B., Aagaard M., u Lerche D. Modeling Falling and Accumulating Snow. The Eurographics Association, 2005. DOI: 10.2312/vvg.20051008.
12. Buls E., Kadikis R., Cacurs R., u Ārents J. Generation of synthetic training data for object detection in piles, In: Eleventh International Conference on Machine Vision (ICMV 2018), March 2019, Vol. 11041, pp. 11041:1-11041:12. DOI: 10.1117/12.2523203.
13. Dwibedi D., Misra I., and Hebert M. Cut, Paste and Learn: Surprisingly Easy Synthesis for Instance Detection, 4 August 2017, *arXiv*: arXiv:1708.01642. DOI: 10.48550/arXiv.1708.01642.
14. Tobin J., Fong R., Ray A., Schneider J., Zaremba W., and Abbeel P. Domain randomization for transferring deep neural networks from simulation to the real world, *2017 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, September 2017, pp. 23-30. DOI: 10.1109/IROS.2017.8202133.
15. Rajpura P.S., Bojinov H., and Hegde R.S. Object Detection Using Deep CNNs Trained on Synthetic Images, 18 September 2017, *arXiv*: arXiv:1706.06782. DOI: 10.48550/arXiv.1706.06782.
16. Danielczuk M. et al. Segmenting Unknown 3D Objects from Real Depth Images using Mask R-CNN Trained on Synthetic Data, *2019 International Conference on Robotics and Automation (ICRA)*, May 2019, pp. 7283-7290. DOI: 10.1109/ICRA.2019.8793744.
17. Dehban A., Borrego J., Figueiredo R., Moreno P., Bernardino A., u Santos-Victor J. The Impact of Domain Randomization on Object Detection: A Case Study on Parametric Shapes and Synthetic Textures, *2019 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, November 2019, pp. 2593-2600. DOI: 10.1109/IROS40897.2019.8968139.
18. Lim J.X.-Y. u Pham Q.-C. Automated post-processing of 3D-printed parts: artificial powdering for deep classification and localisation, *Virtual Phys. Prototyp.*, May 2021, Vol. 16, Issue 3, pp. 333-346. DOI: 10.1080/17452759.2021.1927762.
19. Jia Y. et al. Caffe: Convolutional Architecture for Fast Feature Embedding, 20 June 2014, *arXiv*: arXiv:1408.5093. DOI: 10.48550/arXiv.1408.5093.
20. Taniguchi Y., Morimoto T., Nakada A., and Ohmi T. Data generating method, data generating device, and program, WO2006109709A1, 19 October 2006.

Чернышов Никита Михайлович – Московский государственный технический университет им. Н.Э. Баумана (национальный исследовательский университет); e-mail: chernyshov_nikita@mail.ru; г. Москва, Россия; тел.: +79154280911; аспирант.

Романова-Большакова Ирина Константиновна – Московский государственный технический университет имени Н.Э. Баумана (национальный исследовательский университет); e-mail: irina.romanova@bmstu.ru; г. Москва, Россия; тел.: +79645960579; д.т.н.; профессор; зам. заведующего кафедрой СМ7 – Робототехнические системы и мехатроника.

Chernyshov Nikita Mikhailovich – Bauman Moscow State Technical University; e-mail: chernyshov_nikita@mail.ru; Moscow, Russia; phone: +79154280911; graduate student.

Romanova-Bolshakova Irina Konstantinovna – Bauman Moscow State Technical University; e-mail: irina.romanova@bmstu.ru; Moscow, Russia; phone: +79645960579; dr. of eng. sc.; professor; deputy head of Department ME7 – Robotic Systems and Mechatronics.