

ПЛАТФОРМА iOk ДЛЯ АВТОМАТИЧЕСКОГО ПОИСКА И АНАЛИЗА ОБЪЕКТОВ НА ИЗОБРАЖЕНИЯХ С ИСПОЛЬЗОВАНИЕМ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА В ИЗУЧЕНИИ НАНЕСЕННЫХ КАТАЛИЗАТОРОВ

© 2023 г. А. В. Нартова^{a, b, *}, А. В. Матвеев^b, М. Ю. Машуков^b, В. А. Белоцерковский^b,
Н. Н. Санькова^{a, b}, В. Ю. Кудинов^b, А. Г. Окунев^b

^aФГБУН ФИЦ Институт катализа им. Г.К. Борескова СО РАН,
просп. Акад. Лаврентьева, 5, Новосибирск, 630090 Россия

^bФГАОУ ВО Новосибирский национальный исследовательский государственный университет,
ул. Пирогова, 1, Новосибирск, 630090 Россия

*e-mail: nartova@catalysis.ru

Поступила в редакцию 22.11.2022 г.

После доработки 01.02.2023 г.

Принята к публикации 01.03.2023 г.

В работе представлена платформа iOk, объединяющая веб-сервис ParticlesNN и Telegram-боты DLgram и No Code ML для автоматического поиска и анализа объектов на изображениях с использованием искусственного интеллекта. Платформа позволяет работать с любыми видами изображений (электронная, зондовая, оптическая микроскопия, фотографии) любого качества без предварительных обработок. Пользователи имеют возможность самостоятельно обучать нейронную сеть на своих изображениях. Результат распознавания изображений — объекты, их площадь и размеры, а также положение на изображении. Сервисы находятся в свободном доступе, при этом для их использования навыки программирования не требуются. Платформа iOk — удобный для пользователей инструмент для работы с любыми видами изображений по автоматическому поиску объектов и определению их параметров.

Ключевые слова: глубокое машинное обучение, искусственный интеллект, микроскопия, анализ изображений, анализ частиц

DOI: 10.31857/S045388112304010X, EDN: RRIKTW

ВВЕДЕНИЕ

Гетерогенные катализаторы в своем подавляющем большинстве представляют собой композиты, компоненты которых являются объектами нанометровых размеров. В частности, самые распространенные катализаторы — нанесенные системы, в которых частицы активного компонента сформированы на поверхности пористой матрицы носителя [1]. Одна из важнейших характеристик каталитической системы — активность, определяемая как количество оборотов реакции

на одном активном центре в единицу времени (“turnover frequency” (TOF)) [1]. Для расчета TOF необходимо иметь информацию о количестве активного компонента, доступного для реагентов, которое можно рассчитать, зная размеры частиц активного компонента. Для определения размеров частиц широко используют различные методы микроскопии: все виды электронной микроскопии, и, прежде всего, просвечивающую электронную микроскопию (ПЭМ), и все виды сканирующей зондовой микроскопии (СЗМ), в частности, сканирующую туннельную микроскопию (СТМ) [1, 2]. Традиционно анализ изображений проводится в ручном режиме с применением программных продуктов ImageJ/Fiji [3], WSxM [4] и др. и, как правило, требует измерения сотен частиц для получения достоверных значений средних размеров частиц или построения гистограмм распределения частиц по размерам. Процесс требует значительных временных затрат и содержит

Сокращения и обозначения: TOF — количество оборотов реакции на одном активном центре в единицу времени (turnover frequency); ПЭМ — просвечивающая электронная микроскопия; СЗМ — сканирующая зондовая микроскопия; СТМ — сканирующая туннельная микроскопия; TP — количество предсказанных контуров, совпавших с объектами (размеченными оператором контурами) (true positive); FP — предсказанные контуры, которые не имеют размеченных контуров (false positive); FN — размеченные контуры, которые не распознаны нейросетью (false negative).

элемент субъективности, так как результат зависит от опыта исследователя, выполняющего анализ.

В связи с важностью описанной задачи и ее трудоемкостью поиск подходов к автоматизированному поиску и измерению объектов на микроскопических изображениях является весьма актуальной проблемой, для решения которой в настоящее время активно применяются методы глубокого машинного обучения или искусственного интеллекта [5–24]. Основная идея заключается в следующем. Нейронная сеть обучается на наборе изображений, размеченных специалистом (“обучающий набор данных”). С помощью обученной нейронной сети в дальнейшем можно распознавать объекты на изображениях, подобные размеченным при формировании такого набора данных. Основными недостатками большинства приведенных в литературе решений по использованию искусственного интеллекта для анализа микроскопических изображений является их высокая специфичность (применимость к определенному виду изображений, например, когда контрастные объекты хорошо различимы на однородном фоне) и сложность использования, зачастую пользователь обязан обладать определенными навыками программирования [22]. Наибольшее развитие получили работы, направленные на анализ биологических объектов, что связано с распространенностью и социальной значимостью данных задач. Так, сервис Cellpose [8] для клеточной сегментации предлагает пользователям обучить модель распознавания на своих объектах. Такой подход значительно повышает универсальность сервиса. Однако надо заметить, что принципиальной особенностью поиска типов клеток является акцент на морфологии объектов, в то время как, применительно к гетерогенному катализу, наиважнейшее значение имеет точность определения размеров.

Ранее мы решили задачу распознавания частиц на микроскопических изображениях с использованием глубокого машинного обучения для сканирующей зондовой микроскопии [12, 15] и просвечивающей электронной микроскопии [24]. Одним из ключевых результатов нашей работы стало создание веб-сервиса ParticlesNN (<http://particlesnn.nsu.ru/>). Сервис доступен для всех пользователей из любой точки мира посредством сети Интернет, при этом процедура поиска и определения размеров частиц полностью автоматизирована: для получения результата достаточно загрузить тестовое изображение без дополнительных обработок. Однако ParticlesNN обеспечивает надлежащий результат лишь в случае, когда изображения похожи на те, которые были выбраны для формирования набора данных для обучения этой нейронной сети.

Для расширения диапазона объектов, пригодных для распознавания, необходимо предоставить возможность обучения нашей нейросети пользователем на его собственных изображениях. Данная задача реализована в виде Telegram-ботов DLgram (https://t.me/nanoparticles_nsk) и No Code ML (https://t.me/nsu_ml_bot). Для удобства пользователей все разработанные сервисы собраны на одной платформе iOk (iok.nsu.ru).

В настоящей работе представлена платформа iOk, объединяющая веб-сервисы ParticlesNN и Telegram чат-боты DLgram и No Code ML для автоматического анализа объектов на изображениях с использованием глубокого машинного обучения. Платформа позволяет работать с любыми видами изображений (электронная, зондовая, оптическая микроскопии, фотографии) и анализировать изображения любого качества без предварительных обработок, получая информацию о размере и координате каждого идентифицированного объекта на анализируемом изображении.

ЭКСПЕРИМЕНТАЛЬНАЯ ЧАСТЬ

Обучение нейронной сети и распознавание изображений проводится на графическом кластере НГУ. Для функционирования каждого из индивидуальных сервисов выделен один из графических ускорителей NVIDIA Tesla V-100.

В случае веб-сервисов ParticlesNN и чат-бота DLgram использовали нейронную сеть Cascade Mask-RCNN [25] с библиотекой *mmdetection* [26], располагающей необходимым инструментарием для обучения нейросети и инференса ее результатов, в случае сервиса No Code ML — нейросеть ConvNeXt.

При формировании набора данных для обучения нейронных сетей разметку изображений проводили в программе LabelMe [27], размещенной в общем доступе. Файлы с контурами разметки имеют формат json и расширение *.json. Разметка объектов в данной программе выполняется вручную оператором с использованием контуров — полигонов или фигур правильной формы, например, окружностей. Также программа LabelMe применяется для корректировки контуров пользователем после распознавания нейросетью (если такая корректировка необходима) и формирования отчетов — таблиц с данными о каждом распознанном объекте.

Качество обучения сети определяется следующими способами:

1) Mean average precision (mAP) [28] с набором пороговых значений [0.5, 0.55, 0.6, 0.65, 0.7, 0.75, 0.8, 0.85, 0.9 и 0.95] применяется в качестве количественной метрики для объектов, предсказанных нейросетью. Метрика определяет перекрытие предсказанных (prediction) и размеченных

(ground truth) оператором контуров. Значение mAP, равное 0 (или 0%), соответствует низкому уровню предсказания, тогда как mAP близкий к 1 (или 100%) указывает на попиксельное перекрытие предсказанных и размеченных контуров. Значения mAP выдаются нейросетью автоматически по результатам обучения с использованием инструмента COCO API tool [29].

2) Проверка точности (Precision) и полноты (Recall) предсказаний нейросети производится по формулам:

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}},$$

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}},$$

где TP – true positive – количество предсказанных контуров, совпавших с объектами (размеченными оператором контурами, ground truth), FP – false positive – предсказанные контуры, которые не имеют размеченных контуров; FN – false negative – размеченные контуры, которые не распознаны нейросетью. Чем лучше нейросеть предсказывает частицы, тем ближе эти показатели к единице, т.е. к 100%.

3) Проверка расхождения результатов определения размеров объектов на основе распознавания изображения нейронной сетью и результатов ручного определения тех же параметров. Данная проверка очень важна с точки зрения практического применения сервисов в исследовательской работе в качестве инструмента, которому можно доверять.

Сервис ParticlesNN, разработанный нами ранее, является веб-сервисом. Сервисы DLgram и No Code ML используют Telegram-мессенджер как платформу для интерфейса.

Для формирования наборов данных для обучения нейросети и распознавания были выбраны микроскопические изображения нанесенных катализаторов (Pt, Pd и т.д.) на пористых (оксид алюминия, оксид титана, углеродный материал Сибунит) и планарных носителях (высокоориентированный пиролитический графит). Образцы готовили по методикам, описанным в работах [1] (пористые системы) и [2] (планарные системы).

Изображения сканирующей туннельной микроскопии были получены на сканирующем туннельном микроскопе SPM 100 VT (“RHK Technology”, Трой, Мичиган, США) в режиме постоянного тока с использованием Pt-Ir-игл (RHK). Изображения анализировали с помощью пакетов программ XPMPro 2.0 (RHK) и WSxM (“Nanotec Electrónica”, Мадрид, Испания) [4].

Изображения просвечивающего электронного микроскопа были получены на приборе JEM-2010 (“Jeol Co.”, Япония) с разрешением по решетке

0.14 нм и ускоряющим напряжением 200 кВ. Ручное измерение размеров частиц проводили в программе ImageJ [3].

РЕЗУЛЬТАТЫ И ИХ ОБСУЖДЕНИЕ

ParticlesNN

Для решения задач поиска и определения размеров частиц активного компонента в нанесенных катализаторах на изображениях сканирующей зондовой микроскопии (прежде всего, сканирующей туннельной микроскопии) и просвечивающей электронной микроскопии нами был создан сайт ParticlesNN (<http://particlesnn.nsu.ru/>).

Подробности формирования наборов данных, обучения нейронной сети и оценки качества распознавания приведены в работах [15, 24]. На рис. 1 представлены примеры СТМ- (рис. 1а, 1б) и ПЭМ-изображений (рис. 1г, д) и результаты распознавания частиц на этих изображениях на сайте ParticlesNN. Особенностью формирования набора данных с изображениями ПЭМ было введение двух классов объектов: “face” – частицы, которые хорошо видны на фоне носителя; “bottom” – частицы, идентификация которых затруднена либо из-за неоднородности фона (носителя), либо из-за перекрытия проекций частиц.

В табл. 1 приведены метрики моделей, используемых для распознавания частиц на изображениях СЗМ (модель “STM MMDetection Nanopart v.3.2”) и ПЭМ (модель “TEM images processing v.1.1”). Из данных табл. 1 видно, что mAP и Recall для ПЭМ и СЗМ-моделей близки. А вот Precision для ПЭМ чуть ниже, чем для СЗМ. Это связано с тем, что наличие частиц класса bottom приводит к росту false positive, т.е. ошибочно предсказанных частиц, так как частицы класса bottom близки к артефактам ПЭМ-изображения, таким как затемнение фона в местах сгущения носителя. Однако высокая контрастность частиц активного компонента, обычно металла, на фоне пористого носителя, обычно оксида, на изображениях ПЭМ обеспечивает высокую точность определения размеров частиц нейросетью, как результат, расхождение с ручным определением составляет всего ~2%. В случае же СЗМ-изображений сложный профиль частиц и вклад формы иглы приводят к увеличению расхождения результатов определения размеров нейросетью и оператором до 5%. При этом такой точности достаточно, для того чтобы использовать данную модель в исследовательской работе.

Процедура распознавания объектов на сайте ParticlesNN полностью автоматизирована. Пользователь просто загружает свое изображение, выбирает нужную модель и запускает обработку. Результат выдается в виде изображения с распознанными объектами, файла формата json с




Рис. 1. Микроскопические изображения: а — исходное СТМ-изображение; б — результат распознавания СТМ-изображения на сайте ParticlesNN (розовым выделены граничные частицы); в — результат распознавания сервисом DLgram; г — исходное ПЭМ-изображение; д — результат распознавания ПЭМ-изображения на сайте ParticlesNN (зеленые объекты — частицы класса face; синие объекты — bottom); е — результат распознавания сервисом No Code ML.

распознанными контурами и таблиц с описанием каждого найденного объекта (площадь и проекционный диаметр). По результатам работы нейросети выдается отчет, в котором приводятся статистические параметры: количество частиц, средний проекционный диаметр и стандартное отклонение, а также доля занимаемой частицами площади и плотность частиц в расчете на 1000 пикселей или на nm^2 (важно в случае СЗМ), автоматически строится гистограмма распределения частиц по размерам. Файл в формате json может быть открыт в программе LabelMe, в которой пользователь может откорректировать результат распознавания,

если есть такая необходимость, в ручном режиме — убрать ошибочно определенные объекты, добавить нераспознанные, при необходимости откорректировать размеры — и сгенерировать новые таблицы для статистического анализа данных, воспользовавшись командой Calculate Stat.

На сайте реализованы дополнительные опции, а именно, исключение из статистического анализа граничных частиц (рис. 1б) и объединение в статистическом анализе нескольких изображений по выбору оператора.

Как указывалось ранее, исходя из принципов применения глубокого машинного обучения для

Таблица 1. Метрики моделей распознавания объектов на изображениях ПЭМ и СЗМ

Метрики	ПЭМ		СЗМ	
	ParticlesNN	No Code ML	ParticlesNN	DLgram
mAP	0.253	0.303	0.279	Не определяется
Precision	0.84	1.0	0.93	1.0
Recall	0.79	0.85	0.78	0.84
Расхождение с ручным измерением, %	2.1	3.8	4.8	21.7

распознавания объектов на микроскопических изображениях очевидно, что результат, полученный на сайте ParticlesNN для изображений пользователей, будет зависеть от того, насколько похожи эти изображения на использованные при разметке набора данных для обучения. Для повышения универсальности сервиса необходимо предоставить пользователю возможность обучать нейросеть самостоятельно на своих объектах.

Сервис DLgram

Важной особенностью сервиса DLgram, реализованного в варианте чат-бота Telegram (группа Nanoparticles, https://t.me/nanoparticles_nsk), является как раз такая возможность — тренировка нейросети на изображениях пользователя. При этом в данном сервисе подразумевается, что обучение ведется по единственному изображению, на котором размечаются не все объекты. Пользователь может влиять на результат обучения, меняя следующие параметры:

- *a 8* — *augmentation* — превращает каждый размеченный объект в 8 (или сколько укажет пользователь) измененных объектов, визуально близких к исходному. Повышает качество тренировки нейросети. Эмпирический параметр;

- *e 100* — число эпох. В течение каждой эпохи нейросеть видит все частицы. Чем больше размеченных объектов, тем меньше требуется эпох для удовлетворительного обучения. Эмпирический параметр;

- *t 0.3* — *threshold* — порог срабатывания, степень уверенности нейронной сети. Число от 0 до 1. Если порог близок к нулю, то в качестве распознанных объектов включаются все предположения нейронной сети. Как правило, значительная часть этих предположений являются *false positive*, ошибочно определенными объектами. Если порог близок к 1 — сеть выдает только те предположения, в которых она уверена, однако часть существующих объектов может оказаться ниже порога срабатывания и не войти в предсказание.

Для начала пользователям предлагается воспользоваться базовыми параметрами. Определение mAP в случае сервиса DLgram не предусмот-

рено, результат обучения можно оценить, рассчитав Precision/Recall по формулам, приведенным выше, и сопоставлением с результатами ручного анализа.

Рассмотрим алгоритм обучения нейросети на фотографии гранул алюмоплатинового катализатора. На рис. 2а приведена фотография, на которой гранулы одинаковой формы и размера хорошо отделены друг от друга. В программе LabelMe с использованием правильной фигуры “окружность” размечена одна-единственная гранула. Фактически эта единственная гранула и составляет весь массив данных для обучения нейросети. После этого файл в формате json был загружен в чат DLgram, запущено обучение с базовыми параметрами, и получен результат распознавания (рис. 2б). Из рис. 2 видно, что все гранулы идентифицированы, а Precision и Recall равны 1.

На рис. 3а представлена фотография тех же гранул, однако в данном случае количество гранул увеличено, большое число гранул контактирует друг с другом, и часть гранул имеет неправильную форму. В этом случае разметки единственной гранулы недостаточно. Для повышения качества обучения нейросети пользователям предлагается выделить область изображения, обозначаемую как *сгор*, и разметить все объекты внутри и на границе данной области, как показано на рис. 3а (для разметки также использовались окружности). Набор данных в данном случае состоит из 12 размеченных объектов. После чего json-файл был загружен в чат-бот, автоматически запустилось обучение нейросети и распознавание всех оставшихся объектов на изображении. На рис. 3б приведен результат распознавания, из которого видно, что нейросеть не опознала всего 11 гранул из 392. И это те гранулы, которые сильно отличались по форме от размеченных. Всего распознана 381 гранула, Precision = 1, Recall = 0.97.

Чат-бот выдает результат распознавания в виде файла с изображением с размеченными контурами и файла в формате json, который может быть открыт в программе LabelMe. Как упоминалось выше, в этой программе можно не только скорректировать неправильно распознанные контуры, но и сформировать отчет о каждом контуре в




Рис. 2. Фотография гранул алюмоплатинового катализатора: а — изображение с разметкой; б — результат автоматического анализа изображения в сервисе DLgram.




Рис. 3. Фотография контактирующих гранул алюмоплатинового катализатора: а — изображение с разметкой (зеленым выделен сгор); б — результат автоматического анализа изображения в сервисе DLgram.

виде таблицы, в которой будут указаны в пикселях: площадь каждого идентифицированного объекта, проекционный диаметр и положение в пределах изображения как X Center и Y Center.

На рис. 4 показана разметка СТМ-изображения, приведенного на рис. 1а, для обучения нейронной сети через сервис DLgram. В этом случае набор данных состоит из 9 объектов-частиц. Несмотря на то, что Precision/Recall достаточно высоки (рис. 1в), расхождение в определении размеров частиц составило более 20% (табл. 1), что является неприемлемым. Таким образом, в данной ситуации использованный набор данных недостаточен, и DLgram не подходит для работы с подобными изображениями.

Из приведенных примеров видно, что сервис DLgram очень хорошо работает для однородных по форме и размерам объектов [30]. При этом раз-

метка занимает не больше нескольких минут, а результат позволяет использовать автоматическое распознавание в научной работе. Уже готовую модель обучения можно применять для распознавания объектов на подобных изображениях. Таким образом, единожды проведя разметку и обучение нейросети, исследователь может в дальнейшем пользоваться результатами обучения для работы со своими файлами.

Сервис No Code ML

В ситуации, когда объекты на изображении, подлежащие распознаванию, отличаются по форме и размеру, есть неоднородности фона и затруднения, связанные с перекрыванием объектов, ограничиться разметкой даже нескольких десятков контуров для тренировки нейросети не удаст-

ся. Для повышения качества распознавания необходимо формирование полноценного набора данных, учитывающего все особенности изображений. Только тогда можно добиться высокого уровня идентификации объектов нейросетью. Именно такие случаи типичны для данных ПЭМ применительно к каталитическим системам.

Для решения подобных задач был создан сервис No Code ML (https://t.me/nsu_ml_bot), позволяющий пользователям обучать сегментационную нейросеть Cascade Mask-RCNN со скелетом ConvNeXt на собственном наборе данных любого размера. На этапе формирования набора данных пользователь имеет возможность повлиять на результат распознавания объектов на изображениях. Кроме того, пользователю предлагается выбрать уровень обучения: “Начальный”, “Средний” или “Опытный”. Количество эпох в каждом уровне обратно пропорционально количеству обучающих изображений. Для обучающего набора данных из 4-х изображений количество эпох на уровне “Начальный” составляет 20, на уровне “Средний” – 100, на уровне “Опытный” – 500. При этом есть выбор, продолжить обучение или начать заново – True (продолжать обучение)/False (начать обучение заново). Обучение на каждом уровне можно запускать многократно, постепенно увеличивая количество эпох и, тем самым, улучшая его качество. По результату обучения формируется модель, которая в дальнейшем может использоваться в исследовательской работе для распознавания аналогичных изображений. Результат работы нейросети, как и в случае DLgram, выдается в виде изображения с разметкой и файла json.

В качестве примера для распознавания частиц активного компонента катализаторов на пори-




Рис. 4. СТМ-изображение, размеченное в программе LabelMe для сервиса DLgram (красный контур – стоп, зеленые контуры – частицы).

стых носителях на ПЭМ-изображениях был собран набор данных из 60 снимков ПЭМ, на которых размечены 2932 частицы, еще 12 снимков с 421 размеченной частицей использованы для оценки качества обучения (табл. 2).

В табл. 2 представлены метрики (mAP) обучения нейронной сети для разных уровней обучения. Из приведенных значений видно, что нейросеть достигает близких значений mAP после 10 циклов обучения на начальном уровне, 7 цик-

Таблица 2. Метрики обучения нейронной сети в сервисе No Code ML на разных уровнях обучения

Номер обучения	Уровень обучения					
	начальный		средний		опытный	
	суммарное количество эпох	mAP	суммарное количество эпох	mAP	суммарное количество эпох	mAP
1	2	0.188	3	0.222	16	0.301
2	4	0.214	6	0.260	32	0.301
3	6	0.233	9	0.278	48	0.303
4	8	0.237	12	0.243		
5	10	0.247	15	0.237		
6	12	0.260	18	0.248		
7	14	0.227	21	0.281		
8	16	0.246				
9	18	0.229				
10	20	0.272				

лов на среднем уровне и 1 цикла на опытном уровне. При этом mAP в No Code ML выше достигнутого в модели для ПЭМ на сайте ParticlesNN. Выбор уровня обучения и количества обучений на каждом уровне является компромиссом между качеством и временем обучения. У пользователя всегда есть возможность дообучить нейронную сеть на имеющемся наборе данных.

На рис. 1е показан пример изображения ПЭМ, распознанного с применением созданной модели. По результатам распознавания Precision = 1, Recall = 0.85. Расхождение среднего размера частиц в No Code ML с ручным определением составляет 3.8%, что несколько больше, чем в сервисе ParticlesNN, но по-прежнему невелико. Таким образом, сервис No Code ML также подходит для использования в исследовательской работе при рутинном анализе изображений ПЭМ.

Начиная работу с платформой iOk.nsu.ru исследователи, работающие с данными микроскопии, полученными для нанесенных катализаторов, могут воспользоваться сервисом ParticlesNN. Если результат будет неудовлетворительным, следует перейти на сервис DLgram. Если и в этом случае результат не будет соответствовать ожиданиям, можно обратиться к сервису No Code ML. Для удобства пользователей для всех сервисов подготовлены инструкции, а также есть обратная связь с командой поддержки сервисов.

ЗАКЛЮЧЕНИЕ

В настоящей работе представлена платформа iOk.nsu.ru, объединяющая веб-сервис ParticlesNN и Telegram-боты DLgram и No Code ML, предназначенные для автоматического поиска объектов на изображениях с использованием искусственного интеллекта. Платформа позволяет работать с любыми видами изображений (электронная, зондовая, оптическая микроскопии, фотографии) и осуществлять поиск объектов и определение их параметров (площадь, размеры, координаты) на изображениях любого качества без предварительных обработок. У пользователя есть возможность самостоятельно обучить нейронную сеть под свои задачи и тем самым достигать необходимого качества распознавания, что делает платформу iOk универсальным инструментом в работе с изображениями. Результаты распознавания предоставляются в виде изображений с распознанными объектами, файла с контурами в формате json, с опцией получения отчетов в виде таблиц с указанием характеристик для каждого идентифицированного объекта. Оператор может корректировки результата автоматического распознавания в ручном режиме.

Платформа iOk разработана для рутинного анализа изображений — поиск объектов, опреде-

ление размеров, статистический анализ неограниченного массива данных. Применительно к гетерогенному катализу автоматизация поиска и определения размеров частиц на микроскопических изображениях повышает объективность анализа и за счет увеличения массива данных делает возможным анализ тонких эффектов, как-то: изучение неоднородности частиц по образцу; отслеживание статистических тенденций в зависимости от условий обработок образцов и т.д.

Платформа iOk доступна для всех пользователей по всему миру через сеть интернет, при этом не требуются навыки программирования. Таким образом, iOk — универсальный и ориентированный на пользователя инструмент для работы с любыми видами изображений с целью поиска объектов и определения их параметров.

БЛАГОДАРНОСТИ

Авторы выражают благодарность Л.М. Ковтуновой за приготовление нанесенных катализаторов на пористых носителях, а также коллегам из ИК СО РАН, и, в частности, Е.Ю. Герасимову за получение изображений методом ПЭМ.

ФИНАНСИРОВАНИЕ

Работа выполнена при финансовой поддержке Российского научного фонда, проект 22-23-00951 (<https://rscf.ru/project/22-23-00951/>).

КОНФЛИКТ ИНТЕРЕСОВ

Авторы заявляют об отсутствии конфликта интересов, требующего раскрытия в данной статье.

СПИСОК ЛИТЕРАТУРЫ

1. *Nartova A.V., Kovtunova L.M., Khudorozhkov A.K., Shefer K.I., Shterk G.V., Kvon R.I., Bukhtiyarov V.I.* // Appl. Catal. A: Gen. 2018. V. 566. P. 174.
2. *Смирнов М.Ю., Вовк Е.И., Нартова А.В., Калинин А.В., Бухтияров В.И.* // Кинетика и катализ. 2018. Т. 59. № 5. С. 631. (*Smirnov M.Y., Vovk E.I., Nartova A.V., Kalinkin A.V., Bukhtiyarov V.I.* // Kinet. Catal. 2018. 59. P. 653–662.)
3. *Schindelin J., Arganda-Carreras I., Frise E., Kaynig V., Longair M., Pietzsch T., Preibisch S., Rueden C., Saalfeld S., Schmid B., Tinevez J.-Y., White D.J., Hartenstein V., Eliceiri K., Tomancak P., Cardona A.* // Nat. Methods. 2010. V. 9. P. 676.
4. *Horcas I., Fernandez R., Gomez-Rodriguez J.M., Colchero J., Gomez-Herrero J., Baro A.M.* // Rev. Sci. Instrum. 2007. 78. P. 013705.
5. *Krizhevsky A., Sutskever I., Hinton G.* / In Proceedings of the Annual Conference on Neural Information Processing Systems (NIPS 2012), Lake Tahoe, NV, USA, 3–8 December 2012. P. 1.

6. Liu W., Anguelov D., Erhan D., Szegedy C., Reed S., Fu C.-Y., Berg A.C. / Lecture Notes in Computer Science. Eds. Leibe B., Matas J., Sebe N., Welling M., Cham, Switzerland: Springer, 2016. V. 9905. P. 21.
7. He K., Gkioxari G., Dollar P., Girshick R. / In Proceedings of the 2017 IEEE International Conference on Computer Vision (ICCV), Venice, Italy, 22–29 October 2017. P. 2980.
8. Stringer C., Michaelos M., Pachitariu M. // Nature Methods. 2021. V. 18. № 1. P. 100.
9. Moen E., Bannon D., Kudo T., Graf W., Covert M., Valen D. // Nat. Methods. 2019. V. 16. № 12. P. 1233.
10. Caicedo J., Goodman A., Karhohs K., Cimini B., Ackerman J., Haghighi M., Heng C., Becke T., Doan M., McQuin C., Rohban M., Singh S. // Nat. Methods. 2019. V. 16. № 12. P. 1247.
11. Kudinov V.Yu., Mashukov M.Yu., Maslova E.A., Orishchenko K.E., Okunev A.G., Matveev A.V. / Proceedings-2020 Science and Artificial Intelligence Conference, S.A.I.ence, Novosibirsk, Russia, 2020. 9303201. 2020. P. 17.
12. Okunev A.G., Mashukov M.Y., Nartova A.V., Matveev A.V. // Nanomater. 2020. V. 10. № 7. P. 1285:1.
13. Fu G., Sun P., Zhu W., Yang J., Cao Y., Ying-Yang M., Cao Y.A. // Opt. Lasers Eng. 2019. V. 121. P. 397.
14. Berg S., Kutra D., Kroeger T., Straehle C., Kausler B., Haubold C., Schiegg M., Ales J., Beier T., Rudy M., Eren K., Cervantes J., Xu B., Beuttenmueller F., Wolny A., Zhang C., Koethe U., Hamprecht F., Kreshuk A. // Nat. Methods. 2019. V. 16. P. 1226.
15. Okunev A.G., Nartova A.V., Matveev A.V. / In Proceedings of the International Multi-Conference on Engineering, Computer and Information Sciences (SIBIRCON), Novosibirsk, Russia, 21–27 October 2019. P. 0940.
16. Zhu H., Ge W., Liu Z. // Appl. Sci. 2019. V. 9. P. 3312.
17. Liu Y., Xu K., Xu J. // Appl. Sci. 2019. V. 9. P. 3127.
18. Feng S., Zhou H., Dong H. // Mater. Des. 2019. V. 162. P. 300.
19. Yang T., Xiao L., Gong B., Huang L. // In Proceedings of SPIE, Optoelectronic Imaging and Multimedia Technology VI. Eds. Dai Q., Shimura T., Zheng Z., International Society for Optics and Photonics: Bellingham, WA, USA, 2019. V. 11187. P. 1118718.
20. Ziatdinov M., Dyck O., Maksov A., Li X., Sang X., Xiao K., Unocic R., Vasudevan R., Jesse S., Kalinin S.V. // ACS Nano. 2017. V. 11. P. 12742.
21. Modarres M.H., Aversa R., Cozzini S., Ciancio R., Leto A., Brandino G.P. // Sci. Rep. 2017. V. 7. P. 13282.
22. Qu E.Z., Jimenez A.M., Kumar S.K., Zhang K. // ACS Macromolecules. 2021. V. 54. P. 3034.
23. Monchot P., Coquelin L., Guerroudj K., Feltin N., Delvallée A., Crouzier L., Fischer N. // Nanomater. 2021. V. 11. P. 968.
24. Nartova A.V., Mashukov M.Yu., Astakhov R.R., Kudinov V.Yu., Matveev A.V., Okunev A.G. // Catalysts. 2022. V. 12. № 2. P. 135:1.
25. Cai Z., Vasconcelos N. // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Salt Lake City, USA, June 18–22, 2018. P. 6154.
26. mmdetection [Электронный ресурс]. Электрон. дан. (11 файлов). URL: <https://github.com/open-mmlab/mmdetection>, свободный. Яз. англ. (дата обраш. 26.02.2021).
27. Wada K. Labelme: Image Polygonal Annotation with Python [Электронный ресурс]. GitHub repository. Электрон. дан. (16 файлов). 2016. URL: <https://github.com/wkentaro/labelme>, свободный. Яз. англ. (дата обраш. 20.01.2021).
28. Everingham M., Van Gool L., Williams C.K.I., Winn J., Zisserman A. // Int. J. Comput. Vision. 2010. V. 88. № 2. P. 303.
29. COCO API – Dataset. Available online: <https://github.com/cocodataset/cocoapi> (accessed on 01.06.2020).
30. Матвеев А.В., Машуков М.Ю., Нартова А.В., Санькова Н.Н., Окунев А.Г. // Физико-химические аспекты изучения кластеров, наноструктур и наноматериалов. 2021. Т. 13. С. 300.

iOk Platform for Automatic Search and Analysis of Objects on Images Using Artificial Intelligence in the Study of Supported Catalysts

A. V. Nartova^{1, 2, *}, A. V. Matveev², M. Y. Mashukov², V. A. Belotserkovskii², N. N. Sankova^{1, 2}, V. Y. Kudinov², and A. G. Okunev²

¹Borekov Institute of Catalysis SB RAS, Lavrentiev Ave. 5, Novosibirsk, 630090 Russia

²Novosibirsk State University, Pirogov St. 1, Novosibirsk, 630090 Russia

*e-mail: nartova@catalysis.ru

iOk platform for automatic search and analysis of objects on images using artificial intelligence is presented. iOk platform combines web-service ParticlesNN and cloud services DLgram and No Code ML, which use Telegram messenger as interface. Platform allows working with any types of images (electron, probe, optical microscopy, photography) of any quality without preprocessing. Users can train the neural network by itself on their own images. The results of image recognition are objects, its areas, sizes and position on image. Presented services are in free access, no coding skills are required. iOk Platform is a user-friendly tool for the work with any type of images for automatic search of the objects and determination of their parameters.

Keywords: deep machine learning, artificial intelligence, microscopy, image analysis, particle analysis