



ISSN: 2658–5782

Номер 2

2024

# МНОГОФАЗНЫЕ СИСТЕМЫ

[mfs.uimech.org](https://mfs.uimech.org)





## Модификация алгоритмов нейросетевого распознавания формы деталей УЭЦН при роботизации контрольной операции

Л.С. Салихов

Уфимский государственный нефтяной технический университет, Уфа

E-mail: [salihovlinar@mail.ru](mailto:salihovlinar@mail.ru)

За последние несколько десятков лет основной технологией нефтедобычи в России является механизированный способ, реализуемый за счет размещения в скважинах установки электроцентробежного насоса (УЭЦН). По причине удаленности месторождений нефтедобычи и экономической нецелесообразностью транспортировки отработавших свой рабочий ресурс установок, возникает простой и скапливание УЭЦН непосредственно рядом с месторождением. Для реализации возможности ремонта и возвращения работоспособности вышедшим из строя насосам предлагается разработка мобильного робототехнического модуля сортировки, дефектовки и хранения деталей УЭЦН, входящего в состав мобильного робототехнического комплекса по проведению ремонта установок. В статье рассматриваются современные методы проведения контроля формы деталей, реализуемые за счет использования нейронных сетей и машинного обучения, что позволит увеличить точность распознавания дефектов. На основе анализа различных методов контроля выявлены их недостатки, которые могут проявиться при использовании в разрабатываемом робототехническом модуле на этапе предварительной обработки. Для устранения выявленных недочетов предложено использовать дообучение нейросетевой модели непосредственно в ходе ее эксплуатации. По итогам анализа и проведенных компьютерных экспериментов определен оптимальный способ решения поставленной задачи в виде методики и алгоритмов модификации нейросетевого метода распознавания формы деталей УЭЦН, что позволило увеличить точность выявления наиболее распространенных дефектов.

**Ключевые слова:** нейросетевая модель, машинное обучение, распознавание объектов, ремонт УЭЦН, контроль формы, дефектовка

## Modification of algorithms for neural network-based shape recognition of ESP components in the automation of inspection operations

L.S. Salikhov

Ufa State Petroleum Technological University, Ufa

E-mail: [salihovlinar@mail.ru](mailto:salihovlinar@mail.ru)

In recent decades, the primary oil extraction technology in Russia has been the mechanized method, implemented by installing Electric Submersible Pump (ESP) units in wells. Due to the remote locations of oil fields and the economic impracticality of transporting units that have exhausted their service life, downtime and accumulation of ESPs occur directly near the fields. Given the possibility of repairing and restoring the functionality of failed pumps, the development of a mobile robotic module for sorting, defect detection and storage of ESP components is proposed. This module would be part of a mobile robotic complex for conducting repairs of the units. This article examines modern methods of shape inspection of components using neural networks and machine learning, which also improve defect recognition accuracy. Based on the analysis of various control methods, their disadvantages have been identified, which may manifest themselves when they are used in the developed robotic module at the preprocessing stage. To eliminate the identified shortcomings, it is proposed to use additional training of the neural network model directly during its operation. Based on the results of the analysis and conducted computer experiments, the optimal way to solve the problem was determined in the form of methods and algorithms for modifying the neural network method for recognizing the shape of ESP parts, which made it possible to increase the accuracy of detecting the most common defects.

**Keywords:** neural network model, machine learning, object recognition, ESP repair, shape inspection, defect detection

### 1. Введение

Согласно отчетам Министерства финансов Российской Федерации за последние годы нефтяные доходы составляют значительную часть федерального бюджета

та [1] и являются одной из наиболее прибыльных доходных статей страны. Одной из распространенных технологий добычи нефти является эксплуатация механизированных установок электрических центробежных

насосов (УЭЦН) [2]. Более двух третей всей нефтедобычи на освоенных месторождениях осуществляется с использованием УЭЦН, при этом большая их часть расположена в отдаленных регионах страны [3]. Одной из основных проблем, помимо отдаленности участков нефтедобычи и тяжелых климатических условий, с которой сталкиваются нефтедобывающие компании, является простой месторождения из-за преждевременного отказа УЭЦН, вызванного износом оборудования из-за различных примесей (соли, песок, парафин и другие). Основываясь на экономических аспектах целесообразности замены и ремонта УЭЦН можно отметить, что нефтедобывающим компаниям выгоднее складировать отработанные УЭЦН рядом с месторождением. Так как время работы УЭЦН относительно отработки всей скважины приблизительно определяется как 20 к 1 [4], а концентрация скважин на одном месторождении достигает нескольких сотен [5], то накопленные после демонтажа УЭЦН являются потенциальным запасом вновь реализуемого, после восстановительных процедур, оборудования. Поэтому в настоящее время актуальными становятся разработка и применение новых методов автоматизации ремонта УЭЦН, что позволит сократить простой скважин и сэкономить ресурсы нефтедобывающих компаний, а также повысить общую эффективность нефтедобычи. Поэтому было предложено разработать мобильный роботизированный модуль для осуществления ремонта УЭЦН непосредственно на месторождении.

В работе [6] авторами была проведена декомпозиция задач, итогом которой стала архитектура роботизированного модуля, включающая три функционально самостоятельных модуля: модуль предварительной подготовки деталей, модуль дефектовки и модуль хранения деталей УЭЦН. Для каждого модуля выделены наиболее затратные и трудоемкие операции, требующие специфического подхода при решении поставленных задач. Так, для модуля предварительной подготовки — это операция обработки (очистки) поступающих после разбора УЭЦН деталей и проведение входного контроля формы; для модуля дефектовки — контроль формы, выявление дефектов поверхности и определение отклонений размеров в соответствии с картой контроля, а для модуля хранения — логистика входного, внутреннего и выходного потоков, статистическая обработка данных, содержащихся в базе данных.

Модуль предварительной подготовки и обработки деталей представляет собой комплекс оборудования, в котором необходимо провести необходимые виды обработки входного потока и выполнить предварительную (грубую) дефектовку деталей УЭЦН (детали типа: аппарат направляющий, втулка защитная вала, колесо рабочее (рис. 1) и прочее). В качестве базового оборудования используются манипулятор с захватным устройством, автоматическая адаптивная мойка для очистки деталей, сушильный шкаф, а также программно-аппаратный комплекс выявления дефектов формы и веса деталей. В статье сжато приводится описание пред-

лагаемой модификации алгоритмов нейросетевого распознавания формы деталей при роботизации операции контроля, определяется вариант реализации в модуле предварительной подготовки.

В соответствии с предложенным подходом эффективность всего разрабатываемого модуля складывается из решения задач в каждом из этапов сортировки с целью увеличения производительности, снижения энергозатрат и автоматизации технологического процесса. Качественная обработка деталей с отбраковкой явного нарушения формы и массы позволит в целом сократить время обработки входного потока, так как более затратными по времени операциями являются операции контроля поверхностных дефектов и размеров. Благодаря предлагаемому подходу на указанные выше этапы попадут детали, не имеющие явных отклонений от технических требований согласно дефектационной карте.

## 2. Постановка задачи дефектовки деталей на этапе предварительной обработки

### 2.1. Влияние загрязненности на дефекты формы деталей УЭЦН

Одной из распространенных причин отказа работ УЭЦН является не только неисправность деталей ввиду явных дефектов, но и сильная загрязненность деталей. Типы и интенсивность загрязнений напрямую зависят от условий эксплуатации насосов: достаточно часто совместно с пластовыми водами происходит захват механических примесей в виде песка [7], изменение физических и химических параметров добываемой нефти приводит к возникновению и отложению солей [8], а простой между закачкой нефти приводят к асфальтосмолопарафиновым отложениям (АСПО) и образованию эмульсионных пленок [9]. Типы загрязнений и методы их ликвидации на деталях представлены в табл. 1.




Рис. 1. CAD-модель детали «Аппарат направляющий (ЭЦНМ 5-125)»

Таблица 1. Типы загрязнений деталей УЭЦН и методы очистки

Тип загрязненности	Методы очистки
Отложения солей	Использование химических растворов или кислот для растворения и удаления химических отложений
Асфальтосмолопарафиновые отложения	Комбинированные способы очистки с использованием тепловых методов вместе с химическими растворами
Парафиновое налипание	Промывка высокотемпературными растворами
Образование эмульсионных пленок	Химическое растворение с использованием специализированных растворов или растворителей. Промывка под высокими давлением и температурой
Песчано-глинистые отложения	Промывка под высоким давлением или ультразвуком
Коррозия	Электрохимический или ультразвуковой метод избавления от коррозии. Механическая чистка деталей

Загрязненность деталей часто имеет комплексный характер и сопровождается несколькими типами загрязнений, при этом интенсивность загрязнений может привести к невозможности деликатной очистки, так как попытки убрать такие сложные наслоения приводит к разрушению поверхности детали. Поэтому необходимо отсеивать подобные детали на этапе предварительной обработки и отправлять в брак.

После очистки и сушки деталей проводится анализ на выявление дефектов формы и массы. Если дефект формы и массы были выявлены, деталь отправляется в брак, в иных случаях, если целостность не нарушена, деталь направляется для дальнейшей дефектовки поверхности и размеров в следующий модуль.

## 2.2. Виды дефектов формы деталей УЭЦН и способы их диагностики

К дефектам формы деталей относятся отклонения от изначальной геометрической формы, от заданного профиля (сечения) детали, различные виды деформации и искривления, разрушение компонентов или детали в целом ввиду износа во время эксплуатации и воздействия загрязняющих факторов. Сравнительный анализ методов контроля соответствующих дефектов описан в табл. 2.

Дефекты формы могут также, как и загрязнения, иметь комплексный характер, поэтому необходимо рассмотреть возможность одновременного использования нескольких методов контроля для увеличения

Таблица 2. Сравнительный анализ перечня распознавания и контроля дефектов формы деталей

Метод контроля	Преимущества	Недостатки
С использованием датчиков координатно-измерительных машин (КИМ) – щупы	Простота внедрения и установки. Возможность определения формы сложных объектов	Времязатратное определение дефектов. Быстрый износ щупов по причине стирания головки щупа
Сопоставление с облаком точек САД-модели	Высокая точность определения формы объекта и возникшего дефекта	Крайне низкая скорость определения дефектов. Сопоставление облака точек с исследуемым объектом
Контроль формы по методу «световой щели»	Высокая скорость обнаружения дефектов. Низкая стоимость внедрения оборудования	Условность использования метода. Ограниченность в определении видов дефектов формы
Метод контроля формы при помощи сканирующей электронной микроскопии	Высокое разрешение изображения для обнаружения различных дефектов	Высокая стоимость оборудования
Доплеровская интерферометрия	Высокая точность измерений формы и деформаций	Высокая стоимость оборудования
Метод сопоставления с трехмерной идеальной САД-моделью	Высокая точность определения дефектов формы	Сопоставление исследуемого объекта с моделью
Метод контроля с использованием оборудования КИМ	Высокая точность и скорость определения дефектов деталей. Возможность работать со сложными типами деталей	Крайне большие габариты оборудования. Высокая стоимость оборудования и инструментов

скорости и точности определения дефектов. К предпочтительным методам контроля формы, выполняемым за счет специфического оборудования, относятся контроль формы объектов по методу «световой щели» и метод сопоставления с трехмерной идеальной CAD-моделью.

Для реализации предлагаемых методов контроля формы на этапе предварительной обработки деталей с целью увеличения производительности, точности и скорости распознавания дефектов наиболее эффективным способом реализации цифровой обработки полученных данных представляется использование нейросетевых методов контроля при модификации алгоритмов распознавания с учетом специфики решаемой задачи.

### 3. Методология контроля формы

Перед отправкой деталей в модуль дефектовки, с целью снижения его загрузки, необходимо отбраковать детали, имеющие явные дефекты: критические разрушения детали; деформации, не допускающие восстановительных работ; отсутствие функциональных и конструктивных частей детали. Для применения нейросетевых методов, как было показано выше, необходимо выбрать эффективный способ их модификации.

На сегодняшний день существует множество различных методов модификации нейронных сетей с целью увеличения скорости и точности распознавания. К таким методам относятся сверточные нейронные сети на базе операторов Собеля или Приютта [10], также параллельно рассматривалась возможность использования нечеткой логики для определения дефектов формы. Однако данные методы неприменимы на практике и в производстве ввиду высоких требований, предъявляемых к оборудованию, и сложности в практической реализации (эксперименты показали, что при малых смещениях объекта значительно падает точность распознавания). В связи с этим предлагаются более современные методы и подходы для решения задачи распознавания дефектов формы, в которых используются обученные и модифицированные нейронные сети, адаптированные для использования на реальных производствах.

#### 3.1. Анализ нейросетевых методик контроля формы

Одним из наиболее эффективных методов распознавания дефектных деталей представляется использование сверточных нейронных сетей с внедрением изменений, целью которых являются различные способы улучшения модели: уменьшение входных параметров, сокращение выборки с сохранением точности, оптимизация размера выборки для увеличения точности и прочее.

Так, в работе [11] продемонстрировано использование сверточных нейронных сетей для решения задачи распознавания конденсаторов, что позволило не только добиться высокой точности, но и высокой скорости распознавания, приближенной к эффективности

работы человека. Отличительной особенностью реализации является применение метода всего для 4-х классов, вследствие чего появилась возможность использования модели YOLO-v3 [12], способной обрабатывать изображения в реальном времени. Также была модифицирована классификационная модель с использованием MobileNet, что позволило уменьшить входные параметры, а значит увеличить скорость работы классификатора. Экспериментальная проверка модифицированной сверточной нейросети продемонстрировала точность ~95 %, что является достаточно высоким результатом для четырехклассовой модели.

В работе [13] представлены исследование и анализ различных нейросетевых моделей, целью которых было сравнение эффективности простых моделей с малым числом слоев и моделей с большим числом слоев. Результаты исследования показали, что модели с малым числом слоев не сильно отстают в показателях качества и точности по сравнению с большими моделями. Продолжение эта работа получила в [14], где показана модернизация модели ResNet с использованием архитектур Swin-B и Swin-T, демонстрирующая увеличение точности распознавания по сравнению с классическими вариантами модели без модернизации.

Таким образом, для проведения контроля дефектов формы деталей предлагается использовать нейронные сети, к которым применены модификации, позволяющие повысить скорость и точность распознавания таких дефектов формы, как формообразующие дефекты, сильное разрушение детали, искривления и отсутствие технологических элементов распознаваемого объекта.

### 4. Решение поставленной задачи модифицированным нейросетевым методом

Целью проведенной работы является генерация обучающей выборки на основе трехмерных CAD-моделей исследуемых объектов, что позволит выявить и обосновать модификации, необходимые для увеличения точности распознавания дефектов.

Для достижения поставленной цели предлагается следующая технология решения:

1. На основе чертежей, дефектационных карт и технологической документации выполнить создание идеальных CAD-моделей исследуемых объектов (Solidworks), моделей с различными типами дефектов.
2. Сформировать выборку из нескольких сотен изображений для дальнейшего обучения модели.
3. Обучить модель типа ResNet для классификации и контроля дефектов формы, провести проверку точности обученной модели.
4. Произвести модификацию модели на предобученной модели ImageNet и сравнить результаты с результатами, полученными на модели без модификации.

5. Оценить возможность использования предобученной модели для контроля реальных деталей и возможность ее дообучения в ходе работы с увеличением набора данных за счет расширения выборки объектов, прошедших предварительную дефектовку формы в роботизированном модуле.

Реализация предлагаемого подхода позволит улучшить качество модели и роботизированного модуля в целом, что позволит увеличить скорость работы модуля предварительной подготовки и разгрузить прочие модули для решения более приоритетных задач по сортировке, дефектовке и хранению деталей.

### 5. Результаты тестирования полученных нейросетевых моделей

Определение результатов тестирования модели целесообразно осуществлять на основе матрицы ошибок (Confusion matrix) (рис. 2), позволяющей оценить точность разработанной (применяемой) модели по нескольким параметрам:

- истинно-положительные объекты (True Positive) — объект представляет собой класс 1 и алгоритм идентифицирует как класс 1;
- ложно-положительные объекты (False Positive) — объект представляет собой класс 0, а алгоритм идентифицирует как класс 1;
- истинно-отрицательные объекты (True Negative) — объект представляет собой класс 0 и алгоритм идентифицирует как класс 0;
- ложно-отрицательные объекты (False Negative) — объект представляет собой класс 1, а алгоритм идентифицирует как класс 0.

Точность (или Precision) определяется как отношение числа истинно-положительных классификаций к общему числу положительных идентификаций:

$$Precision_{\text{(Точность)}} = \frac{TP}{(TP + FP)}$$

Таблица 3. Матрица ошибок нейросетевой модели без модификаций

	Колесо рабочее	Аппарат направляющий	
Колесо рабочее	40	13	0,75
Аппарат направляющий	12	35	

Таблица 4. Матрица ошибок нейросетевой модели с учетом модификаций

	Колесо рабочее	Аппарат направляющий	
Колесо рабочее	48	10	0,86
Аппарат направляющий	4	38	

	Actually Positive (1)	Actually Negative (0)
Predicted Positive (1)	True Positives (TPs)	False Positives (FPs)
Predicted Negative (0)	False Negatives (FNs)	True Negatives (TNs)

Рис. 2. Матрица ошибок (Confusion matrix)

Полнота (Recall) — доля истинно-положительных примеров:

$$Recall_{\text{(Полнота)}} = \frac{TP}{(TP + FN)}$$

Доля правильно классифицированных примеров называют также Accurasy:

$$ACC = \frac{TP + TN}{TP + TN + FP + FN}$$

В табл. 3 представлена матрица ошибок для модели без учета модификации.

В табл. 4 представлена матрица ошибок с учетом модификации.

На основе выбранных для тестирования деталей — колесо рабочее и аппарат направляющий — были разработаны трехмерные CAD-модели объектов, сформирована обучающая выборка, произведено обучение нейросетевой модели и проверка распознавания объектов моделью без учета модификаций и с учетом модификации, получены результаты точности. По результатам тестирования можно сделать выводы о том, что модификации выбранного метода позволяют увеличить точность модели на ~16 %, достигнутые значения удовлетворяет предъявляемым требованиям. Использование нейросети на предварительном этапе контроля изделий, качественная отбраковка деталей позволили сократить поток и загрузку прочих модулей, а также эффективно отсеивать явно бракованные детали.

По результатам тестирования классификационной модели сделано предположение о достижимости аналогичной точности при реальной работе роботизированного модуля с реализацией возможности дообучения на результатах выполненного контроля деталей.

## 6. Заключение

Выполненный в ходе работы анализ известных нейросетевых методов позволил сформировать оригинальный, новый подход для реализации технологии контроля и распознавания деталей УЭЦН, отличающийся повышенной эффективностью, достигаемой за счет модификации алгоритмов нейросетевого распознавания формы объектов. Показана необходимость дообучения полученной модели на реальных деталях, что потребует определенное время на этапе технической реализации робототехнического модуля контроля, но предоставит возможность продемонстрировать возросшие работоспособность и эффективность модели после ее модификации с учетом данных, полученных в ходе работы и результатов статистической обработки данных.

## Список литературы / References

- [1] Исполнение федерального бюджета и бюджетов системы Российской Федерации за 2022 год. М.: Минфин России. 2023. [Execution of the federal budget and budgets of the Russian Federation system for 2022] *Ispolnenie federal'nogo byudzheta i byudzhetov sistemy Rossijskoj Federacii za 2022 god.* [Moscow: Ministry of Finance of Russia] *Minfin Rossii.* 2023. [https://minfin.gov.ru/common/upload/library/2023/08/main/Ilustrirovanoe\\_izdanie\\_zh\\_2022\\_god.pdf](https://minfin.gov.ru/common/upload/library/2023/08/main/Ilustrirovanoe_izdanie_zh_2022_god.pdf)
- [2] Рудницкий С.В., Зацепин А.Ю., Демин Е.В., Ющенко Т.С. Перспективное скважинное оборудование для добычи сланцевой нефти баженовской свиты // ПРОНефть. Профессионально о нефти. 2021. Т. 6, № 1. С. 64–75. Rudnitsky S.V., Zatsepina A.YU., Demin E.V., Yushchenko T.S. Prospective artificial lift equipment for shale oil production from the Bazhenov formation. *PROneft. Professionally about oil.* 2021. Vol. 6, No. 1. Pp. 64–75 (in Russian). DOI: 10.51890/2587-7399-2021-6-1-64-75
- [3] Конторович А.Э., Эдер Л.В., Филимонова И.В., Мишенин М.В. Роль уникальных и крупных месторождений в нефтяной промышленности России: ретроспектива, современное состояние, прогноз // Энергетическая политика. 2016. № 2. С. 34–43. Kontorovich A.E., Eder L.V., Filimonova I.V., Mishenin M.V. The role of unique and large deposits in russian oil sector: retrospective analysis, current state and forecast. *Energy policy.* 2016. No. 2. Pp. 34–43 (in Russian). EDN: WXMMYV
- [4] Мотина С.И., Копейкин И.С. Техническая экспертиза промышленной безопасности эксплуатационных колонн нефтяных скважин. // Материалы Международной научно-технической конференции «Современные проблемы нефтегазового оборудования». 2019. С. 436–440. Motina S.I., Kopeikin I.S. Technical expertise of industrial safety of production columns of oil wells. *Materials of the International Scientific and Technical Conference «Modern problems of oil and gas equipment».* 2019. Pp. 436–440 (in Russian). EDN: QCPZZA
- [5] Галиев К.Р., Ямалиев В.У. Методы повышения безотказности УЭЦН в осложнённых условиях эксплуатации // Материалы Международной научно-технической конференции «Современные проблемы нефтегазового оборудования». 2019. С. 209–218. Galiev K.R., Yamaliev V.U. Methods for improving the operation reliability of electric centrifugal pump installation in complicated operating conditions. *Materials of the International Scientific and Technical Conference «Modern problems of oil and gas equipment».* 2019. Pp. 209–218 (in Russian). EDN: SMTDPL
- [6] Гиндуллин И.И., Лоншаков А.А., Салихов Л.С. Структура робототехнического модуля сортировки деталей // Завалишинские чтения: XVII Международная конференция по электромеханике и робототехнике (СПб., 18–19 апреля 2023 г.). Молодёжная секция: сб. докл.: в 2 ч. Ч. 1. СПб.: ГУАП, 2023. С. 41–44. Gindullin I.I., Lonshakov A.A., Salikhov L.S. [The structure of the robotic module for sorting parts] *Struktura robototekhnicheskogo modulya sortirovki detalej.* *Struktura robototekhnicheskogo modulya sortirovki detalej.* Zavalishinsky readings: XVII International Conference on Electromechanics and Robotics (St. Petersburg, April 18–19, 2023). Youth section. Vol. 2, No. 1. St. Petersburg: GUAP. 2023. Pp. 41–44 (in Russian).
- [7] Zhu H., Zhu J., Zhou Z., Rutter R., Forsberg M., Gunter S., Zhang H.-Q. Experimental Study of Sand Erosion in Multistage Electrical Submersible Pump ESP: Performance Degradation, Wear and Vibration // International Petroleum Technology Conference: Day 1 Tue, March 26, 2019. Paper Number: IPTC-19264-MS. DOI: 10.2523/iptc-19264-ms
- [8] Волошин А.И., Гусаков В.Н., Фахреева А.В., Докичев В.А. Ингибиторы для предотвращения солеотложения в нефтедобыче // Нефтяное хозяйство. 2018. № 11. С. 60–72. Voloshin A.I., Gusakov V.N., Fahreeva A.V., Dokichev V.A. Scaling prevention inhibitors in oil production. *Neftepromyslovoe delo.* 2018. No. 11. Pp. 60–72 (in Russian). DOI: 10.30713/0207-2351-2018-11-60-72
- [9] Bulgarelli N., Biazussi J., Verde W., Perles C., de Castro M., Bannwar A. Experimental investigation of the Electrical Submersible Pump's energy consumption under unstable and stable oil/water emulsions: A catastrophic phase inversion analysis // *Journal of Petroleum Science and Engineering.* 2022. Vol. 216. Paper 110814. DOI: 10.1016/j.petrol.2022.110814
- [10] Seif A., Salut M.M., Marsono M.N. A hardware architecture of Prewitt edge detection // 2010 IEEE Conference on Sustainable Utilization and Development in Engineering and Technology. 2010. Pp. 99–101. DOI: 10.1109/STUDENT.2010.5686999
- [11] Huang R., Gu J., Sun X., Hou Y., Uddin S. A rapid recognition method for electronic components based on the improved YOLO-V3 network // *Electronics.* 2019. Vol. 8, no. 8. Paper 825. DOI: 10.3390/electronics8080825
- [12] Tian Y., Yang G., Wang Z., Wang H., Li E., Liang Z. Apple detection during different growth stages in orchards using the improved YOLO-V3 model // *Computers and electronics in agriculture.* 2019. Vol. 157. Pp. 417–426. DOI: 10.1016/j.compag.2019.01.012
- [13] He K., Zhang X., Ren S., Sun J. Deep Residual Learning for Image Recognition // 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, NV, USA, 2016. Pp. 770–778. DOI: 10.1109/cvpr.2016.90
- [14] Liu Z., Mao H., Wu C.-Y., Feichtenhofer C., Darrell T., Xie S. A ConvNet for the 2020s // *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2022.* Pp. 11976–11986. DOI: 10.48550/arXiv.2201.03545

## Сведения об авторах / Information about the Authors

**Линар Суфьянович Салихов**  
Уфимский государственный нефтяной технический университет

**Linar S. Salikhov**  
Ufa State Petroleum Technological University  
[salihovlinar@mail.ru](mailto:salihovlinar@mail.ru)  
ORCID: 0009-0003-3703-4810