

# Методы распознавания и обработки изображений в процессе строительства нефтяных и газовых скважин\*

С. А. Усилин<sup>1,II</sup>, В. В. Арлазаров<sup>1,II</sup>, Д. Н. Путинцев<sup>1,II</sup>, И. А. Тарханов<sup>1</sup>

<sup>1</sup> Федеральное государственное учреждение «Федеральный исследовательский центр «Информатика и управление» Российской академии наук», г. Москва, Россия

<sup>II</sup> ООО «Смарт Энджинс Сервис», г. Москва, Россия

**Аннотация.** В работе представлен обзор современных методов анализа больших данных и обработки изображений, а также технологий искусственного интеллекта применительно к задаче обеспечения безопасности при строительстве нефтяных и газовых скважин. Рассматриваются способы распознавания типовых аварийных ситуаций при бурении нефтяных и газовых скважин, методы принятия решений и выдача рекомендаций в процессе строительства скважин, технологии автоматизации контроля соблюдения техники безопасности и организации автоматического постоянного визуального контроля технологических процессов. Представлен обзор современных методов машинного обучения, используемых в процессе решения задач локализации, ориентации и распознавания ключевых структурных объектов на изображениях и видеопоследовательностях. Отдельное внимание уделено способам оптимизации с вычислительной точки зрения рассмотренных алгоритмов и организация периферийных (граничных) вычислений.

**Ключевые слова:** нефтяные и газовые скважины, распознавание аварийных ситуаций, прихват колонн бурительных труб, методы принятия решений, автоматизированный контроль технологических процессов, распознавание образов, нейронные сети, периферийные вычисления.

DOI 10.14357/20718632200102

## Введение

При возведении сложных технических систем, к которым относятся нефтяные и газовые скважины, одним из ключевых элементов является своевременное распознавание осложнений и аварийных ситуаций (процессов, отличающихся от штатных и требующих адекватного реагирования), возникающих в процессе выполнения работ. Наибольшие проблемы в своевременном автоматизированном обнаружении и определении предаварийных ситуаций возникают непосредственно в системе, в ходе работ по её строительству.

Основными задачами, позволяющими предотвратить возникновение таких чрезвычайных осложнений, являются:

- распознавание типовых аварийных ситуаций при бурении нефтяных и газовых скважин (в частности, прихватав колонн бурительных труб и прочих аномалий);
- принятие решений и выдача рекомендаций с учетом большого количества разноплановых факторов и исходных данных;
- автоматизированный контроль соблюдения техники безопасности в процессе возведения нефтяных и газовых скважин;

\* Работа выполнена при частичной финансовой поддержке РФФИ в рамках научных проектов №19-29-09092 и 19-29-09066.

– организация автоматического постоянного визуального контроля технологических процессов в процессе сооружения нефтяных и газовых скважин с возможностью алармирования при возникновении внештатной ситуации;

– решение задач локализации, ориентации и распознавания ключевых структурных объектов на изображениях и видеопоследовательностях;

– организация периферийных (граничных) вычислений в автоматизированной системе контроля процесса строительства нефтяных и газовых скважин.

В данной работе нами будут рассмотрены современные методы анализа больших данных (включая цифровые изображения и видеопоследовательности) и методы искусственного интеллекта, позволяющие решить перечисленные выше задачи.

## **1. Прогнозирование прихвата колонны**

Прихват колонны бурильных труб является одним из самых тяжелых видов аварий в бурении нефтяных и газовых скважин и оказывает существенное влияние на эффективность процесса бурения и стоимость скважины. Прогнозирование прихвата на стадии проектирования и в процессе бурения скважин позволяет минимизировать риск возникновения прихвата за счет выбора оптимального способа предупреждения для конкретных геолого-технических условий. В 70–80-е гг. XX в. советскими учеными (А.К. Самогоем, А.Г. Аветисовым, Н.Н. Кошелевым, Н.Г. Аветисяном, М.М. Ахмадуллиным, С.Р. Хлебниковым) были разработаны подходы к распознаванию, прогнозированию и предупреждению прихватов колонн на основе статистических методов путем последовательной диагностической процедуры [1, 2]. Данные работы заложили основу для современных методов предсказания прихватов бурильных труб [3–7], которые опираются на теорию нечеткой логики, нейронные сети. В качестве входных данных такие алгоритмы обычно используют различные параметры режимов бурения, глубину скважины, момент вращения, давление на стояке бурового насоса, диаметр долота, геометрию компоновки низа бурильной колонны, а также и параметры бу-

рового раствора, в том числе реологические. Например, американскими учеными Хьюстонского университета и компании Халлибертон разработан метод прогнозирования дифференциального и механического прихватов бурильных труб методами нечеткой логики и нейронной сети в сочетании с моделью дискриминантного анализа [5]. Позднее иранские ученые развили предложенную теорию добавив идею активного обучения, чем существенно увеличили точность прогнозирования возникновения дифференциального прихвата [7]. Несомненная важность этой работы состоит в том, что в ней применяется нормализация входных данных, за счет чего повышается точность модели.

Российскими исследователями в 2019 году была разработана уникальная искусственная нейронная сеть для прогнозирования возникновения прихватов, отличительной особенностью которой является то, что полученная нейронная сеть прогнозирования легко может адаптироваться к новым данным, что часто происходит при бурении скважин на новых месторождениях [8]. В предложенной работе алгоритм в режиме реального времени сравнивает показатели телеметрии с соответствующими показателями на ранее проанализированных обучающих инцидентах. Алгоритм автоматически определяет уровень «сходства» аномалии для того, чтобы произвести своевременное алармирование.

## **2. Распознавание аномалий, принятие решений и выдача рекомендаций**

Помимо решения узких специализированных задач, методы искусственного интеллекта используются при прогнозировании аномальных ситуаций в целом. Работа [9] является характерным примером такого подхода. Предложенный в данной работе алгоритм сравнивает телеметрию, получаемую в режиме реального времени в процессе бурения с историческими данными, содержащими буровую телеметрию 80 скважин, пробуренных ранее на 19 месторождениях. Модель выполняет сравнение временных рядов, используя агрегированную статистику и классификацию повышения градиента.

Существенный вклад в развитие автоматизации строительства нефтяных и газовых систем внес российский исследователь Ф.Н. Абу-Абед. В частности, им предложен метод автоматического обнаружения предаварийных ситуаций в процессе промышленного бурения нефтяных скважин на основе большого количества разноплановых факторов и исходных данных [10–17]. В работах данного автора применяется кластеризация данных и последующее прогнозирование на основе нейронных сетей. В качестве входного набора данных автором использованы статистические данные об авариях (как источник данных была использована библиотека программного обеспечения станции геолого-технологического исследования). В качестве выходного сигнала выбирались два состояния текущей ситуации: «штатная ситуация» и «предаварийная ситуация». Работа автора охватывает все возможные виды аварий и некоторые осложнения в целом (газо-, нефте- и водо-проявление и выбросы, поглощения бурового и тампонажного раствора, прихват бурового инструмента, обвал стенок скважины) без детализации причин их возникновения. При этом предлагается несколько различных подходов к архитектуре финального классификатора предаварийной ситуации (далее – «ПАС», Рис. 1).

### 3. Автоматизация контроля производственного процесса и соблюдения техники безопасности

При решении задачи автоматического контроля производственного процесса и соблюдения техники безопасности в процессе сооружения нефтяных и газовых скважин основным инструментом являются системы теле- и видеонаблюдения (Closed Circuit Television, CCTV; Video Surveillance Systems, VSS). Такие системы используются уже на протяжении десятков лет, приобретая с каждым годом все больше и больше интеллектуальных функций [18–20]. Современные системы видеонаблюдения помимо функций видеofиксации и видеоархива обладают интеллектуальными функциями регистрации событий нарушения периметра и проникновения в опасные зоны, обнаружения оставленных без присмотра предметов, а также контроля соблюдения техники безопасности. Важной составляющей современных систем видеонаблюдения является детекция чрезвычайных ситуаций. На сегодняшний день опубликовано много работ о детектировании фактов возгорания и задымления на основе анализа видео [21–24]. Система видеонаблюдения может быть источником

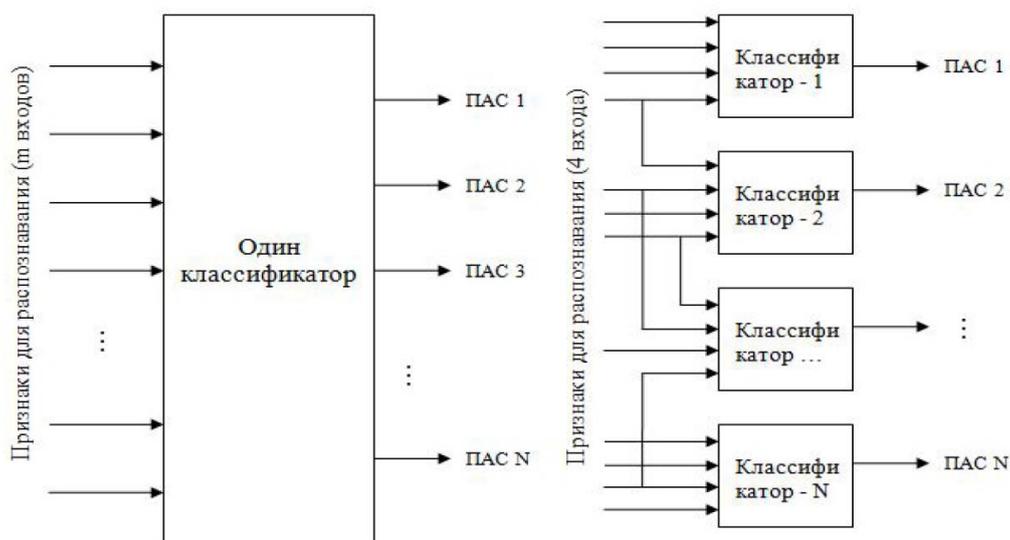


Рис. 1. Варианты построения нейросетевого классификатора

слева – универсальный классификатор для всех ПАС, справа – специализированные классификаторы для каждой ПАС

информации о причинах возникновения пожара, о развитии его очага, об эвакуации людей, что особенно важно при сооружении крайне огнеопасных объектов. В интеллектуальном варианте обеспечения противопожарной безопасности более высокого уровня функции контроля за системой автоматического пожаротушения могут опираться на видеоданные для управления системой автоматического пожаротушения и «страховать» ее от выброса огнетушащего состава в результате ложных срабатываний, а значит – сохранять жизнь и здоровье людей. Дополнительно видеоналитика может использоваться для профилактики нарушений пожарной безопасности: выявлять ситуации блокирования противопожарных проходов и подъездов, обнаруживать неправильное складирование, регистрировать факты курения и использования открытого огня вне разрешенных зон. Система видеонаблюдения может выполнять функции контроля за технологическим процессом производства или сама являться частью этого технологического процесса [25–31].

Таким образом, современные системы видеоналитики и контроля производственного цикла непосредственно опираются на отдельные алгоритмы компьютерного зрения и распознавания образов. Несмотря на специфичность исследуемой прикладной области, большинство целевых ключевых объектов распознавания известны и изучены исследователями: распознавание транспортных средств, людей, некоторые элементы одежды и пр. На сегодняшний день алгоритмы и методы, решающие задачу локализации и классификации (расознавания) объектов на изображениях и видеопоследовательностях, разделяется на 4 категории [32]:

1) методы, базирующиеся на сопоставлении с шаблоном локализуемого объекта (для каждого целевого объекта генерируется шаблон, который затем используется для вычисления некоторого функционала “похожести” для каждого возможного положения локализуемого объекта на изображении) [33–35];

2) методы, основанные на некоторой априорной информации о целевых объектах (рассматривают задачу детектирования объектов как задачу проверки множества гипотез, построенных по целевому объекту) [36];

3) object-based image analysis, получил широкое применение в задачах анализа спутниковых снимков (большинство таких алгоритмов содержат 2 шага: сегментация изображения и классификация сегментов) [37];

4) методы, построенные на машинном обучении, большинство которых рассматривают задачу детектирования объектов как задачу классификации регионов изображения [38–41].

В следующем разделе нами будут рассмотрены современные подходы к решению задачи локализации, ориентации и распознавания ключевых структурных объектов на изображениях и видеопоследовательностях.

#### **4. Локализация, ориентации и распознавания ключевых объектов**

В настоящее время внимание научного сообщества сконцентрировано именно на методах, базирующихся на алгоритмах машинного обучения. Привлекательность этого подхода очевидна: требуемый результат может быть достигнут при достаточном количестве обучающих прецедентов без разработки узкоспециализированных алгоритмов. Несмотря на то, что существует огромное количество различных методов машинного обучения, в промышленных распознающих системах наиболее часто встречаются следующие подходы: метод поиска объектов Виолы и Джонса [42] и свёрточные нейронные сети [43]. Столь широкое применение данные алгоритмы получили благодаря универсальности и способности решать задачи широкой предметной области. При этом хорошо известно, что метод Виолы-Джонса обеспечивает быстрое нахождение объекта на изображении, а алгоритмы, основанные на использовании свёрточных нейронных сетей, отлично справляются с задачами классификации объектов на изображении. Поэтому научным сообществом для решения задач локализации и классификации объектов все чаще используется такой каскадный классификатор, где бинарный классификатор Виолы-Джонса эффективно решает локализации заданных типовых объектов, а затем, с помощью свёрточной нейронной сети производится детализо-

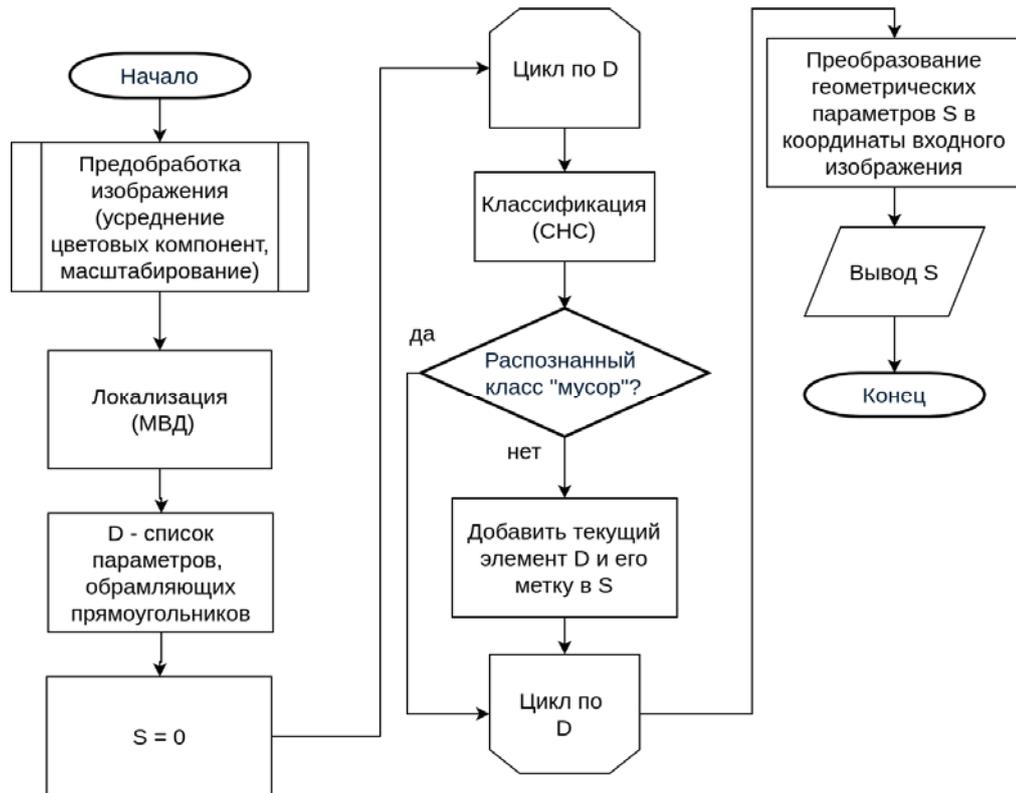


Рис. 2. Алгоритм каскадного классификатора, использующий метод Виолы-Джонса («МВД») для локализации объекта с последующим распознаванием с помощью сверточной нейронной сети («СНС»)

ванная классификация ответа [44,45]. Алгоритм такого решения представлен на Рис. 2.

Отдельное внимание уделим современным тенденциям развития сверточных нейронных сетей (ключевой инструмент распознавания разнородных объектов на изображениях и видеопоследовательностях). Здесь важно отметить, что вектор современных исследований в области искусственных нейронных сетей повернулся в сторону построения архитектур нейронных сетей, решающих конкретную прикладную задачу. Если ранее основной упор ученых всего мира был сделан на разработку универсальных классифицирующих сетей (например AlexNet [46], ZF Net [47], VGG Net [41], Inception [48–51], ResNet [52] или YOLO [53,54]), которые принципиально отличаются между собой количеством, последовательностью и размеров соответствующих сверточных слоев, то в настоящее время все большее внимание уделяется специальным архитектурам искусственных нейронных сетей, в которых помимо классических сверточных и полносвяз-

ных слоев возникают специальные кастомные слои, решающие конкретные прикладные задачи. Примером таких сетей является HoughNet [55] (содержит несколько слоев быстрого преобразования Хафа для эффективного решения задачи поиска пучков прямых и точек схода на изображениях).

Как видно из представленного материала, различные автоматизированные системы активно применяются в различных областях цикла при строительстве нефтяных и газовых скважин. При этом практически все такие системы обладают «умными» датчиками, которые способны передавать данные на специальные серверы и получать в ответ управляющие сигналы. Однако из-за широких масштабов таких систем, а также за счет активного исследования на предмет залежей нефти и газа отдаленных и труднодоступных мест, передача данных в облако или центр обработки данных вызывает существенные трудности в нефтегазовой отрасли. В связи с этим одним из важнейших направлений развития высокопроизводительных автоматизированных систем, при-

меняемых в процессе строительства нефтяных и газовых скважин, является применение принципов периферийных (граничных) вычислений (Edge Computing). Суть данного подхода заключается в переносе ряда механизмов анализа и реагирования на данные с «умных» устройств непосредственно на эти устройства (то есть в место, где эта телеметрия снимается, и, собственно, данные производятся). Обычно при реализации принципа Edge Computing устройства снабжаются малоформатными энергоэффективными вычислителями. Основными механизмами, которые переносятся на такие периферийные устройства, являются алгоритмы обработки изображений и видеопоследовательностей, а также методы распознавания объектов. В этой связи основной упор современных исследователей сделан на механизмы ускорения искусственных нейронных сетей.

## 5. Механизмы оптимизации выполнения искусственных нейронных сетей

В настоящее время существует несколько подходов к оптимизации скорости выполнения искусственных нейронных сетей. Первый из них заключается в использовании целочисленной арифметики, позволяющей ускорить распознавание на современных энергоэффективных процессорах [56–58]. Вычисления в вещественном типе данных заменяются вычислениями в целых числах, которые являются менее трудоемкими. Другим подходом к повышению быстродействия является модификация структуры нейронной сети. Например, есть ряд работ, посвященных оптимизации времени работы сверточных слоев [59–63]. Для этого применяются сепарабельные аппроксимации сверточных фильтров, которые могут быть эффективно вычислены. Часть этих методов [59–61] изменяют алгоритмы обучения с целью получения сверточных фильтров, которые можно подвергнуть аппроксимации без значительных потерь качества, а часть методов [62] аппроксимируют пространство эффективных фильтров каждой конкретной задачи, что не только позволяет добиться лучшего итогового качества нейронной сети, но и может снижать эффекты, связанные с переобучением, за счет

уменьшения числа параметров сети. Альтернативное решение предложено в [63]. Авторы уменьшают количество реально вычисляемых параметров сверточных слоев, а недостающие значения аппроксимируются на основе уже вычисленных. Обучение такой нейронной сети выполняется итерационно, при этом количество задействованных параметров постепенно уменьшается. Разрабатываются эффективные реализации нейронных сетей, подходящие для исполнения на центральных процессорах, графических процессорах [64] и на программируемых пользователем вентильных матрицах (FPGA) [65–67]. Кроме того, можно уменьшить число активных нейронов, заменив одну нейронную сеть на систему нейронных сетей, представляющую собой составной классификатор [68, 69], состоящий из ансамбля классификаторов нижнего уровня и выбирающей нейронной сети. При этом финальное решение принимается нейросетью-классификатором нижнего уровня, который был определен выбирающей нейронной сетью. В результате время работы распознавания гарантированно сокращается, в то время как качество остается неизменным. Еще одно направление оптимизации нейронных сетей – нейронные сети, реализованные в виде аналоговых схем. Основными преимуществами таких искусственных нейронных сетей относительно сетей, реализованных в виде цифровых блоков, являются высокая скорость обработки информации, высокая плотность расположения элементов (цифровые блоки, как правило, имеют больший размер, чем аналоговые схемы, на которых реализованы те же операции), простота реализации функций особого вида (например, функций класса сигмоид) [70]. Однако при реализации аналоговых сетей возникают и характерные проблемы: снижение точности вычислений и сложность в долгосрочном хранении весовых коэффициентов и организации операций аналогового умножения. Снижение точности вычислений обусловлено различиями параметров компонентов, входящих в состав вычислительных блоков, наличием у этих блоков нелинейностей (в том числе насыщения), зависимостью их параметров от температуры, влиянием тепловых и электромагнитных шумов, искажающих полезный сигнал, а также ограни-

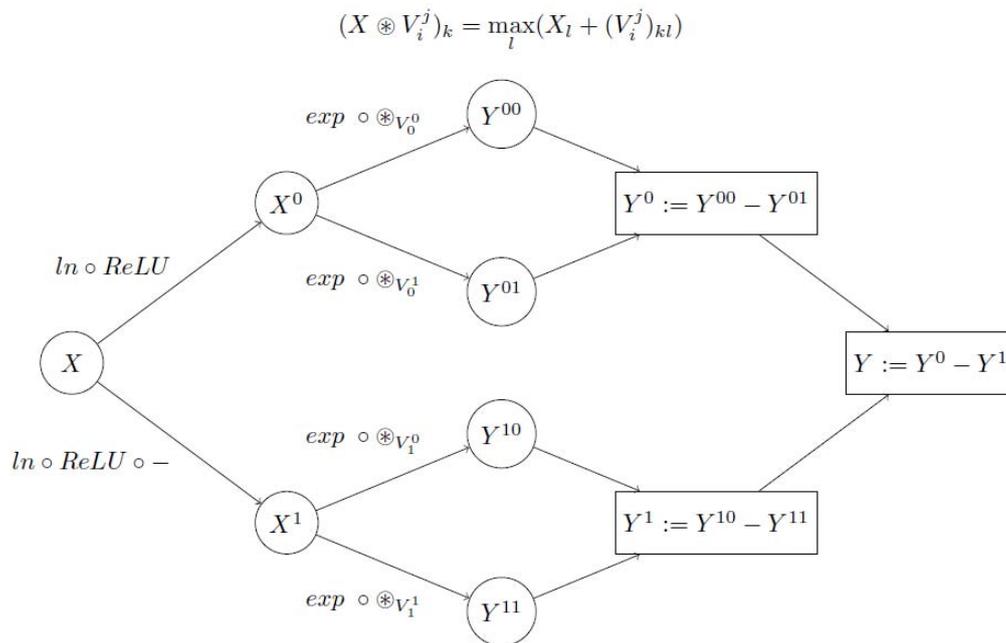


Рис. 3. Структуры биполярного морфологического слоя с входным вектором X и матрицей весов  $V_i^j$  (символ «o» обозначает композицию функций) [76]

ченной точностью хранимых весов. В аналоговом нейроне веса могут храниться с использованием резисторов, ПЗС-ячеек, конденсаторов и ячейках EEPROM [71]. В интегральных схемах может применяться реализация переменного резистора в виде схемы с двумя МОП-транзисторами, но дискретные значения длины и ширины канала транзисторов могут вызвать эффект квантования значения веса. Продвинуться в решении проблемы хранения весовых коэффициентов могут помочь развивающиеся в настоящее время мемристоры [72].

Кроме того, возобновились исследования в области дендритных морфологических нейронных сетей. Разрабатываются новые методы обучения для существующих моделей [73]. Рассматриваются способы применения этих моделей в реальных задачах на примере расшифровки электроэнцефалограмм [74]. Была предложена новая модель DenMo-Net [75], в которой используются нейроны, выполняющие операции эрозии и дилатации.

Авторы показали, что трехслойная модель такой архитектуры (Рис. 3) превосходит по качеству трехслойные модели с классическими

нейронами. Развитие морфологических нейронных сетей – созданная российскими учеными уникальная биполярная морфологическая модель [76]. Новая модель биполярного морфологического нейрона включает в себя только вычислительно простые операции внутри нейрона (сложение, вычитание и максимум), организованные в четыре вычислительных пути, которые отражают возбуждающие и тормозящие связи. Функции активации между слоями нейронов могут выполнять произвольные вычислительные операции, включая умножение. В биполярной морфологической модели они включают дополнительно операции логарифмирования и потенцирования. Такая модель нейрона способна выполнять аппроксимацию классического нейрона, чем выгодно отличается от других существующих моделей морфологического нейрона.

### Заключение

Таким образом, современные методы обработки изображений и распознавания образов, анализа больших данных находят свое применение при строительстве нефтяных и газовых скважин. При этом ключевой задачей, где при-

меняются такие технологии, является задача обеспечения безопасности при строительстве и эксплуатации нефтяных и газовых скважин. Тем не менее, несмотря на большое количество научных работ в рассматриваемой предметной области, при строительстве и эксплуатации нефтяных и газовых скважин существует большое количество задач, которые в настоящий момент не автоматизированы за счет применения технологий распознавания изображений и видеоданных.

## Литература

1. Самой А.К. Предупреждение и ликвидация прихватов труб при бурении скважин. М.: Недра, 1979. 182 с.
2. Аветисов А.Г., Самой А.К., Ахмадуллин. М.М. Прогнозирование, предупреждение и ликвидация прихватов с использованием статистических методов. Обзорная информация. Серия: Бурение. М.: ВНИИОЭНГ, 1978. 48 с.
3. Albaiyat I. Implementing artificial neural networks and support vector machines in stuck pipe prediction. 2012.
4. Chamkalani A. и др. Support vector machine model: a new methodology for stuck pipe prediction // SPE Unconventional Gas Conference and Exhibition. 2013.
5. Murillo A. и др. Pipe sticking prediction and avoidance using adaptive fuzzy logic modeling // SPE Production and Operations Symposium. 2009.
6. Alshaiikh A. и др. Machine Learning for Detecting Stuck Pipe Incidents: Data Analytics and Models Evaluation // International Petroleum Technology Conference. 2019.
7. Naraghi M.E., Ezzatyar P., Jamshidi S. Prediction of drilling pipe sticking by active learning method (ALM) // J. Pet. Gas Eng. Academic Journals, 2013. Т. 4, № 7. С. 173–183.
8. Кодиров Ш.Ш., Шестаков А.Л. Разработка искусственной нейронной сети для прогнозирования прихватов колонн бурильных труб // Вестник Южно-Уральского государственного университета. Серия: Компьютерные технологии, управление, радиоэлектроника. Федеральное государственное бюджетное образовательное учреждение высшего образования ЮУрГУ, 2019. Т. 19, № 3.
9. Gurina E. и др. Application of machine learning to accidents detection at directional drilling // J. Pet. Sci. Eng. Elsevier, 2020. Т. 184. С. 106519.
10. Abu-Abed F. Development of Tools for the Analysis of Pre-Emergency Situations on the Drilling Rig Based on Neural Network Technologies // E3S Web Conf. 2018.
11. Абу-Абед Ф.Н. Надежность объектов нефтегазодобывающей промышленности // Газовая промышленность. Общество с ограниченной ответственностью Камелот Пабблишинг, 2015. № S720. С. 107–111.
12. Абу-Абед Ф.Н. Автоматизированная система обнаружения предаварийных ситуаций на объектах нефтегазодобывающей промышленности // Каротажник. Международная Ассоциация научно-технического и делового сотрудничества по..., 2015. № 5. С. 48–61.
13. Абу-Абед Ф.Н. Снижение риска при строительстве газовых скважин на базе нейросетевой модели // Газовая промышленность. Общество с ограниченной ответственностью Камелот Пабблишинг, 2014. № S712. С. 100–102.
14. Абу-Абед Ф.Н. Обнаружение предаварийных ситуаций в процессе промышленного бурения нефтяных скважин. Тверь, 2011.
15. Домира Р.В., Абу-Абед Ф.Н. Применение средств моделирования нейросетей для анализа предаварийных ситуаций на буровых // Программные продукты и системы. Закрытое акционерное общество Научно-исследовательский институт..., 2010. № 3.
16. Абу-Абед Ф.Н. Разработка средств моделирования нейросетей // Вестник Тверского государственного технического университета. Федеральное государственное бюджетное образовательное учреждение высшего образования ТвГУ, 2005. № 7. С. 125–129.
17. Абу-Абед Ф.Н., Борисов Н.А. Проблемы и решения разработки средств автоматизации поддержки деятельности оператора буровой установки // Информатика, управление и системный анализ. 2016. С. 85–96.
18. Haering N., Venetianer P.L., Lipton A. The evolution of video surveillance: An overview // Mach. Vis. Appl. 2008.
19. Ben Mabrouk A., Zagrouba E. Abnormal behavior recognition for intelligent video surveillance systems: A review // Expert Systems with Applications. 2018.
20. Гвоздек М. Справочник по технике для видеонаблюдения. Планирование, проектирование, монтаж. Техносфера, 2010. 545 с.
21. Töreyn B.U. и др. Computer vision based method for real-time fire and flame detection // Pattern Recognit. Lett. 2006.
22. Muhammad K., Ahmad J., Baik S.W. Early fire detection using convolutional neural networks during surveillance for effective disaster management // Neurocomputing. 2018.
23. Zhong Z. и др. A convolutional neural network-based flame detection method in video sequence // Signal, Image Video Process. 2018.
24. Giannakeris P. и др. People and Vehicles in Danger - A Fire and Flood Detection System in Social Media // 2018 IEEE 13th Image, Video, and Multidimensional Signal Processing Workshop, IVMSIP 2018 - Proceedings. 2018.
25. Jiang Y., Yin S., Kaynak O. Data-driven monitoring and safety control of industrial cyber-physical systems: Basics and beyond // IEEE Access. 2018.
26. Grau A. и др. Industrial robotics in factory automation: From the early stage to the Internet of Things // Proceedings IECON 2017 - 43rd Annual Conference of the IEEE Industrial Electronics Society. 2017.
27. Clay A. An Overview of Smartrooms and Collaborative Work Environments. From Research Issues to User Acceptance in the Oil and Gas Industry. 2018.
28. Ehlers S.G., Tormoehlen R.L. Agricultural Security Monitoring and Safety Alert System: Implementation of Wireless Video on the Farmstead // J. Agric. Saf. Health. American Society of Agricultural and Biological Engineers, 2019. Т. 25, № 4. С. 155–168.
29. Wang B. и др. Prevention and control of major accidents (MAs) and particularly serious accidents (PSAs) in the industrial domain in China: Current status, recent efforts and future prospects // Process Safety and Environmental Protection. 2018.

30. Howard J., Murashov V., Branche C.M. Unmanned aerial vehicles in construction and worker safety // *American Journal of Industrial Medicine*. 2018.
31. Khalid A. и др. Security framework for industrial collaborative robotic cyber-physical systems // *Comput. Ind.* 2018.
32. Cheng G., Han J. A survey on object detection in optical remote sensing images // *ISPRS Journal of Photogrammetry and Remote Sensing*. 2016.
33. Sirmacek B., Unsalan C. Urban-area and building detection using SIFT keypoints and graph theory // *IEEE Trans. Geosci. Remote Sens.* 2009.
34. Zhang J. и др. Semi-automatic road tracking by template matching and distance transformation in Urban areas // *Int. J. Remote Sens.* 2011.
35. Xiangguo L. и др. Semi-automatic road tracking by template matching and distance transform // *2009 Joint Urban Remote Sensing Event*. 2009.
36. Baltasavias E.P. Object extraction and revision by image analysis using existing geodata and knowledge: Current status and steps towards operational systems // *ISPRS J. Photogramm. Remote Sens.* 2004.
37. Blaschke T., Lang S., Hay G.J. Object-Based Image Analysis: Spatial Concepts for Knowledge-Driven Remote Sensing Applications // *LibTuDelftNet*. 2008.
38. Felzenszwalb P.F., Girshick R.B., McAllester D. Cascade object detection with deformable part models // *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*. 2010.
39. Sivic J., Zisserman A. Video google: A text retrieval approach to object matching in videos // *Proceedings of the IEEE International Conference on Computer Vision*. 2003.
40. Krizhevsky A., Sutskever I., Hinton G.E. ImageNet classification with deep convolutional neural networks // *Advances in Neural Information Processing Systems*. 2012.
41. Simonyan K., Zisserman A. Very deep convolutional networks for large-scale image recognition // *3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings*. 2015.
42. Viola P., Jones M. Robust Real-time Object Detection // *International Journal of Computer Vision*. 2001.
43. LeCun Y. и др. Object recognition with gradient-based learning // *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*. 1999.
44. Matalov D.P., Usilin S.A., Arlaazarov V. V. Single-sample augmentation framework for training Viola-Jones classifiers. 2019.
45. Арлазаров В.В., Маталов Д.П., Усилин С.А. Локализация образа печати на документе, удостоверяющем личность, методом машинного обучения // *Труды Института системного анализа Российской академии наук (ИСА РАН)*. 2018. Т. Спецвыпуск. С. 158–166.
46. Krizhevsky A. Learning Multiple Layers of Features from Tiny Images // ... *Sci. Dep. Univ. Toronto, Tech.* .... 2009.
47. Zeiler M.D., Fergus R. Visualizing and understanding convolutional networks // *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*. 2014.
48. Ioffe S., Szegedy C. Batch normalization: Accelerating deep network training by reducing internal covariate shift // *32nd International Conference on Machine Learning, ICML 2015*. 2015.
49. Szegedy C. и др. Inception-v4, inception-ResNet and the impact of residual connections on learning // *31st AAAI Conference on Artificial Intelligence, AAAI 2017*. 2017.
50. Szegedy C. и др. Going deeper with convolutions // *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*. 2015.
51. Szegedy C. и др. Rethinking the Inception Architecture for Computer Vision // *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*. 2016.
52. He K. и др. Deep residual learning for image recognition // *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*. 2016.
53. Redmon J. и др. You only look once: Unified, real-time object detection // *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*. 2016.
54. Redmon J., Farhadi A. YOLO v.3 // *Tech Rep*. 2018.
55. Sheshkus A. и др. HoughNet: neural network architecture for vanishing points detection // *arXiv Prepr. arXiv1909.03812*. 2019.
56. Limonova E., Ilin D., Nikolaev D. Improving neural network performance on SIMD architectures // *Eighth International Conference on Machine Vision (ICMV 2015)*. 2015. Т. 9875. С. 98750L.
57. Limonova E., Sheshkus A., Nikolaev D. Computational optimization of convolutional neural networks using separated filters architecture // *Int. J. Appl. Eng. Res.* 2016. Т. 11, № 11. С. 7491–7494.
58. Лимонова Е.Е. и др. Оптимизация быстродействия первых слоев глубоких сверточных нейронных сетей // *Вестник Российского фонда фундаментальных исследований. Российский фонд фундаментальных исследований*, 2016. № 4. С. 84–96.
59. Jaderberg M., Vedaldi A., Zisserman A. Speeding up convolutional neural networks with low rank expansions // *BMVC 2014 - Proceedings of the British Machine Vision Conference 2014*. 2014.
60. Denton E. и др. Exploiting linear structure within convolutional networks for efficient evaluation // *Advances in Neural Information Processing Systems*. 2014.
61. Sironi A. и др. Learning separable filters // *IEEE Trans. Pattern Anal. Mach. Intell.* 2015.
62. Jin J., Dundar A., Culurciello E. Flattened convolutional neural networks for feedforward acceleration // *3rd International Conference on Learning Representations, ICLR 2015 - Workshop Track Proceedings*. 2015.
63. Figurnov M. и др. PerforatedCNNs: Acceleration through elimination of redundant convolutions // *Advances in Neural Information Processing Systems*. 2016.
64. Kang H.P., Lee C.R. Improving performance of convolutional neural networks by separable filters on GPU // *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*. 2015.
65. Zhang C., Prasanna V. Frequency domain acceleration of convolutional neural networks on CPU-FPGA shared memory system // *FPGA 2017 - Proceedings of the 2017*

- ACM/SIGDA International Symposium on Field-Programmable Gate Arrays. 2017.
66. Park J., Sung W. FPGA based implementation of deep neural networks using on-chip memory only // ICASSP, IEEE International Conference on Acoustics, Speech and Signal Processing - Proceedings. 2016.
  67. Zhang C. и др. Optimizing FPGA-based accelerator design for deep convolutional neural networks // FPGA 2015 - 2015 ACM/SIGDA International Symposium on Field-Programmable Gate Arrays. 2015.
  68. Woźniak M., Graña M., Corchado E. A survey of multiple classifier systems as hybrid systems // Inf. Fusion. 2014.
  69. Ko A.H.R., Sabourin R., Britto, A.S. From dynamic classifier selection to dynamic ensemble selection // Pattern Recognit. 2008.
  70. Elmasry M.I. VLSI artificial neural networks engineering. Springer Science & Business Media, 2012.
  71. Misra J., Saha I. Artificial neural networks in hardware: A survey of two decades of progress // Neurocomputing. 2010.
  72. Adhikari S.P. и др. A circuit-based learning architecture for multilayer neural networks with memristor bridge synapses // IEEE Trans. Circuits Syst. I Regul. Pap. 2015.
  73. Arce F. и др. Differential evolution training algorithm for dendrite morphological neural networks // Appl. Soft Comput. J. 2018.
  74. Antelis J.M. и др. Dendrite morphological neural networks for motor task recognition from electroencephalographic signals // Biomed. Signal Process. Control. 2018.
  75. Mondal R., Santra S., Chanda B. Dense morphological network: an universal function approximator // arXiv Prepr. arXiv1901.00109. 2019.
  76. Limonova E. и др. Bipolar Morphological Neural Networks: Convolution Without Multiplication // arXiv Prepr. arXiv1911.01971. 2019.

**Усилин Сергей Александрович.** С.н.с., Федеральное государственное учреждение «Федеральный исследовательский центр «Информатика и управление» Российской академии наук (ИСА ФИЦ ИУ РАН), г. Москва, Россия. ООО «Смарт Энджинс Сервис», г. Москва, Россия. К.т.н. Количество печатных работ: 25. Научные интересы: обработка изображений, компьютерное зрение, машинное обучение. E-mail: usilin.sergey@gmail.com

**Арлазаров Владимир Викторович.** Руководитель отдела, Федеральное государственное учреждение «Федеральный исследовательский центр «Информатика и управление» Российской академии наук (ИСА ФИЦ ИУ РАН), г. Москва, Россия. ООО «Смарт Энджинс Сервис», г. Москва, Россия. К.т.н. Количество печатных работ: 75. Научные интересы: обработка изображений, компьютерное зрение, машинное обучение, теория массового обслуживания. E-mail: vva777@gmail.com

**Путинцев Дмитрий Николаевич.** С.н.с., Федеральное государственное учреждение «Федеральный исследовательский центр «Информатика и управление» Российской академии наук (ИСА ФИЦ ИУ РАН), г. Москва, Россия. ООО «Смарт Энджинс Сервис», г. Москва, Россия. К.х.н. Количество печатных работ: 35. Научные интересы: компьютерное зрение, физико-химические свойства веществ, междисциплинарные исследования. E-mail: putincevd@gmail.com

**Тарханов Иван Александрович.** С.н.с., Федеральное государственное учреждение «Федеральный исследовательский центр «Информатика и управление» Российской академии наук (ИСА ФИЦ ИУ РАН), г. Москва, Россия. К.т.н. Количество печатных работ: 33. Научные интересы: документооборот, архивы, информационная безопасность, блокчейн. E-mail: tarkhanov@isa.ru

## Object Recognition and Image Processing in the Development of Oil and Gas Wells

S. A. Usilin<sup>1,2</sup>, V. V. Arlazarov<sup>1,2</sup>, D. N. Putintsev<sup>1,2</sup>, I. A. Tarkhanov<sup>1</sup>

<sup>1</sup>Federal Research Center "Computer Science and Control" of RAS, Moscow, Russia

<sup>2</sup>Smart Engines Service LLC, Moscow, Russia

**Abstract.** This paper provides an overview of modern methods of big data analysis and image processing, as well as artificial intelligence technologies concerning the task of ensuring safety in the development of oil and gas wells. The paper discusses methods for recognizing typical emergencies when drilling oil and gas wells, decision-making methods and issuing recommendations in the process of well construction, automation technology for monitoring compliance with safety procedures and organizing automatic continuous visual monitoring of technological processes, as well as an overview of modern machine learning methods, used in the process of solving problems of localization, orientation, and recognition of key structural objects in the images and video. Special attention is paid to optimization methods from the computational point of view of the considered algorithms and the realization of edge computing.

**Keywords:** oil and gas wells, recognition of emergency situations, differential wall sticking, decision-making methods, automated control of technological processes, pattern recognition, neural networks, edge computing.

DOI 10.14357/20718632200102

## References

1. Samotoj A.K. *Preduprezhdenie i likvidaciya prihvatov trub pri burenii skvazhin*. M.: Nedra, 1979. 182 s.
2. Avetisov A.G., Samotoj A.K., Ahmadullin. M.M. *Prognozirovanie, preduprezhdenie i likvidaciya prihvatov s ispol'zovaniem statisticheskikh metodov*. Obzornaya informaciya. Seriya: Burenie. M.: VNIIOENG, 1978. 48 s.
3. Albaiyat I. Implementing artificial neural networks and support vector machines in stuck pipe prediction. 2012.
4. Chamkalani A., and etc. Support vector machine model: a new methodology for stuck pipe prediction // SPE Unconventional Gas Conference and Exhibition. 2013.
5. Murillo A., and etc. Pipe sticking prediction and avoidance using adaptive fuzzy logic modeling // SPE Production and Operations Symposium. 2009.
6. Alshaikh A., and etc. Machine Learning for Detecting Stuck Pipe Incidents: Data Analytics and Models Evaluation // International Petroleum Technology Conference. 2019.
7. Naraghi M.E., Ezzatyar P., Jamshidi S. Prediction of drilling pipe sticking by active learning method (ALM) // J. Pet. Gas Eng. Academic Journals, 2013. T. 4, № 7. S. 173–183.
8. Kodirov SH.SH., SHestakov A.L. *Razrabotka iskusstvennoj nejronnoj seti dlya prognozirovaniya prihvatov kolonn buril'nyh trub* // Vestnik YUzhno-Ural'skogo gosudarstvennogo universiteta. Seriya: Komp'yuternye tekhnologii, upravlenie, radioelektronika. Federal'noe gosudarstvennoe byudzhethoe obrazovatel'noe uchrezhdenie vysshego..., 2019. T. 19, № 3.
9. Gurina E., and etc. Application of machine learning to accidents detection at directional drilling // J. Pet. Sci. Eng. Elsevier, 2020. T. 184. S. 106519.
10. Abu-Abed F. Development of Tools for the Analysis of Pre-Emergency Situations on the Drilling Rig Based on Neural Network Technologies // E3S Web Conf. 2018.
11. Abu-Abed F.N. *Nadezhnost' ob'ektov neftegazodobyvayushchej promyshlennosti* // Gazovaya promyshlennost'. Obshchestvo s ogranichennoj otvetstvennost'yu Kamelot Publishing, 2015. № S720. S. 107–111.
12. Abu-Abed F.N. *Avtomatizirovannaya sistema obnaruzheniya predavarijnyh situacij na ob'ektah neftegazodobyvayushchej promyshlennosti* // Karotazhnik. Mezhdunarodnaya Associaciya nauchno-tekhnicheskogo i delovogo sotrudnichestva po..., 2015. № 5. S. 48–61.
13. Abu-Abed F.N. *Snizhenie riska pri stroitel'stve gazovyh skvazhin na baze nejrosetevoj modeli* // Gazovaya promyshlennost'. Obshchestvo s ogranichennoj otvetstvennost'yu Kamelot Publishing, 2014. № S712. S. 100–102.
14. Abu-Abed F.N. *Obnaruzhenie predavarijnyh situacij v processe promyshlennogo bureniya neftyanyh skvazhin*. Tver', 2011.
15. Dopira R.V., Abu-Abed F.N. *Primenenie sredstv modelirovaniya nejrosetej dlya analiza predavarijnyh situacij na burovyh* // Programmnye produkty i sistemy. Zakrytoe akcionernoe obshchestvo Nauchno-issledovatel'skij institut..., 2010. № 3.
16. Abu-Abed F.N. *Razrabotka sredstv modelirovaniya nejrosetej* // Vestnik Tverskogo gosudarstvennogo tekhnicheskogo universiteta. Federal'noe gosudarstvennoe byudzhethoe obrazovatel'noe uchrezhdenie vysshego..., 2005. № 7. S. 125–129.
17. Abu-Abed F.N., Borisov N.A. *Problemy i resheniya razrabotki sredstv avtomatizacii podderzhki deyatel'nosti operatora burovoj ustanovki* // Informatika, upravlenie i sistemnyj analiz. 2016. S. 85–96.
18. Haering N., Venetianer P.L., Lipton A. *The evolution of video surveillance: An overview* // Mach. Vis. Appl. 2008.
19. Ben Mabrouk A., Zagrouba E. *Abnormal behavior recognition for intelligent video surveillance systems: A review* // Expert Systems with Applications. 2018.
20. Gvozdek M. *Spravochnik po tekhnike dlya videonablyudeniya*. Planirovanie, proektirovanie, montazh. Tekhnosfera, 2010. 545 s.
21. Töreyn B.U., and etc. *Computer vision based method for real-time fire and flame detection* // Pattern Recognit. Lett. 2006.
22. Muhammad K., Ahmad J., Baik S.W. *Early fire detection using convolutional neural networks during surveillance for effective disaster management* // Neurocomputing. 2018.
23. Zhong Z., and etc. *A convolutional neural network-based flame detection method in video sequence* // Signal, Image Video Process. 2018.
24. Giannakeris P., and etc. *People and Vehicles in Danger - A Fire and Flood Detection System in Social Media* // 2018 IEEE 13th Image, Video, and Multidimensional Signal Processing Workshop, IVMSIP 2018 - Proceedings. 2018.
25. Jiang Y., Yin S., Kaynak O. *Data-driven monitoring and safety control of industrial cyber-physical systems: Basics and beyond* // IEEE Access. 2018.
26. Grau A., and etc. *Industrial robotics in factory automation: From the early stage to the Internet of Things* // Proceedings IECON 2017 - 43rd Annual Conference of the IEEE Industrial Electronics Society. 2017.
27. Clay A. *An Overview of Smartrooms and Collaborative Work Environments. From Research Issues to User Acceptance in the Oil and Gas Industry*. 2018.
28. Ehlers S.G., Tormoehlen R.L. *Agricultural Security Monitoring and Safety Alert System: Implementation of Wireless Video on the Farmstead* // J. Agric. Saf. Health. American Society of Agricultural and Biological Engineers, 2019. T. 25, № 4. S. 155–168.
29. Wang B., and etc. *Prevention and control of major accidents (MAs) and particularly serious accidents (PSAs) in*

- the industrial domain in China: Current status, recent efforts and future prospects // *Process Safety and Environmental Protection*. 2018.
30. Howard J., Murashov V., Branche C.M. Unmanned aerial vehicles in construction and worker safety // *American Journal of Industrial Medicine*. 2018.
  31. Khalid A., and etc. Security framework for industrial collaborative robotic cyber-physical systems // *Comput. Ind.* 2018.
  32. Cheng G., Han J. A survey on object detection in optical remote sensing images // *ISPRS Journal of Photogrammetry and Remote Sensing*. 2016.
  33. Sirmacek B., Unsalan C. Urban-area and building detection using SIFT keypoints and graph theory // *IEEE Trans. Geosci. Remote Sens.* 2009.
  34. Zhang J., and etc. Semi-automatic road tracking by template matching and distance transformation in Urban areas // *Int. J. Remote Sens.* 2011.
  35. Xiangguo L., and etc. Semi-automatic road tracking by template matching and distance transform // 2009 Joint Urban Remote Sensing Event. 2009.
  36. Baltsavias E.P. Object extraction and revision by image analysis using existing geodata and knowledge: Current status and steps towards operational systems // *ISPRS J. Photogramm. Remote Sens.* 2004.
  37. Blaschke T., Lang S., Hay G.J. Object-Based Image Analysis: Spatial Concepts for Knowledge-Driven Remote Sensing Applications // *LibTuDelftNet*. 2008.
  38. Felzenszwalb P.F., Girshick R.B., McAllester D. Cascade object detection with deformable part models // *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*. 2010.
  39. Sivic J., Zisserman A. Video google: A text retrieval approach to object matching in videos // *Proceedings of the IEEE International Conference on Computer Vision*. 2003.
  40. Krizhevsky A., Sutskever I., Hinton G.E. ImageNet classification with deep convolutional neural networks // *Advances in Neural Information Processing Systems*. 2012.
  41. Simonyan K., Zisserman A. Very deep convolutional networks for large-scale image recognition // *3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings*. 2015.
  42. Viola P., Jones M. Robust Real-time Object Detection // *International Journal of Computer Vision*. 2001.
  43. LeCun Y., and etc. Object recognition with gradient-based learning // *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*. 1999.
  44. Matalov D.P., Usilin S.A., Arlazarov V. V. Single-sample augmentation framework for training Viola-Jones classifiers. 2019.
  45. Arlazarov V.V., Matalov D.P., Usilin S.A. Lokalizaciya obraza pečatni na dokumente, udostoverayushchem lichnost', metodom mashinnogo obucheniya // *Trudy Instituta sistemnogo analiza Rossijskoj akademii nauk (ISA RAN)*. 2018. T. Specvypusk. S. 158–166.
  46. Krizhevsky A. Learning Multiple Layers of Features from Tiny Images // ... *Sci. Dep. Univ. Toronto, Tech.* .... 2009.
  47. Zeiler M.D., Fergus R. Visualizing and understanding convolutional networks // *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*. 2014.
  48. Ioffe S., Szegedy C. Batch normalization: Accelerating deep network training by reducing internal covariate shift // *32nd International Conference on Machine Learning, ICML 2015*. 2015.
  49. Szegedy C., and etc. Inception-v4, inception-ResNet and the impact of residual connections on learning // *31st AAAI Conference on Artificial Intelligence, AAAI 2017*. 2017.
  50. Szegedy C., and etc. Going deeper with convolutions // *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*. 2015.
  51. Szegedy C., and etc. Rethinking the Inception Architecture for Computer Vision // *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*. 2016.
  52. He K., and etc. Deep residual learning for image recognition // *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*. 2016.
  53. Redmon J., and etc. You only look once: Unified, real-time object detection // *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*. 2016.
  54. Redmon J., Farhadi A. YOLO v.3 // *Tech Rep*. 2018.
  55. Sheshkus A., and etc. HoughNet: neural network architecture for vanishing points detection // *arXiv Prepr. arXiv1909.03812*. 2019.
  56. Limonova E., Ilin D., Nikolaev D. Improving neural network performance on SIMD architectures // *Eighth International Conference on Machine Vision (ICMV 2015)*. 2015. T. 9875. S. 98750L.
  57. Limonova E., Sheshkus A., Nikolaev D. Computational optimization of convolutional neural networks using separated filters architecture // *Int. J. Appl. Eng. Res.* 2016. T. 11, № 11. S. 7491–7494.
  58. Limonova E.E., and etc. Optimizaciya bystrodejstviya pervyh sloev glubokih svertochnyh nejronnyh setej // *Vestnik Rossijskogo fonda fundamental'nyh issledovanij. Rossijskij fond fundamental'nyh issledovanij*, 2016. № 4. S. 84–96.
  59. Jaderberg M., Vedaldi A., Zisserman A. Speeding up convolutional neural networks with low rank expansions // *BMVC 2014 - Proceedings of the British Machine Vision Conference 2014*. 2014.
  60. Denton E., and etc. Exploiting linear structure within convolutional networks for efficient evaluation // *Advances in Neural Information Processing Systems*. 2014.
  61. Sironi A., and etc. Learning separable filters // *IEEE Trans. Pattern Anal. Mach. Intell.* 2015.
  62. Jin J., Dundar A., Culurciello E. Flattened convolutional neural networks for feedforward acceleration // *3rd International Conference on Learning Representations, ICLR 2015 - Workshop Track Proceedings*. 2015.
  63. Figurnov M., and etc. PerforatedCNNs: Acceleration through elimination of redundant convolutions // *Advances in Neural Information Processing Systems*. 2016.
  64. Kang H.P., Lee C.R. Improving performance of convolutional neural networks by separable filters on GPU // *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*. 2015.
  65. Zhang C., Prasanna V. Frequency domain acceleration of convolutional neural networks on CPU-FPGA shared

- memory system // FPGA 2017 - Proceedings of the 2017 ACM/SIGDA International Symposium on Field-Programmable Gate Arrays. 2017.
66. Park J., Sung W. FPGA based implementation of deep neural networks using on-chip memory only // ICASSP, IEEE International Conference on Acoustics, Speech and Signal Processing - Proceedings. 2016.
67. Zhang C., and etc. Optimizing FPGA-based accelerator design for deep convolutional neural networks // FPGA 2015 - 2015 ACM/SIGDA International Symposium on Field-Programmable Gate Arrays. 2015.
68. Woźniak M., Graña M., Corchado E. A survey of multiple classifier systems as hybrid systems // Inf. Fusion. 2014.
69. Ko A.H.R., Sabourin R., Britto, A.S. From dynamic classifier selection to dynamic ensemble selection // Pattern Recognit. 2008.
70. Elmasry M.I. VLSI artificial neural networks engineering. Springer Science & Business Media, 2012.
71. Misra J., Saha I. Artificial neural networks in hardware: A survey of two decades of progress // Neurocomputing. 2010.
72. Adhikari S.P., and etc. A circuit-based learning architecture for multilayer neural networks with memristor bridge synapses // IEEE Trans. Circuits Syst. I Regul. Pap. 2015.
73. Arce F., and etc. Differential evolution training algorithm for dendrite morphological neural networks // Appl. Soft Comput. J. 2018.
74. Antelis J.M., and etc. Dendrite morphological neural networks for motor task recognition from electroencephalographic signals // Biomed. Signal Process. Control. 2018.
75. Mondal R., Santra S., Chanda B. Dense morphological network: an universal function approximator // arXiv Prepr. arXiv1901.00109. 2019.
76. Limonova E., and etc. Bipolar Morphological Neural Networks: Convolution Without Multiplication // arXiv Prepr. arXiv1911.01971. 2019.

**Usilin Sergey Aleksandrovich.** Senior scientist, Federal Research Center “Computer Science and Control” of Russian Academy of Sciences, Moscow, Russia. Smart Engines Services LLC, Moscow, Russia. Ph.D. of Engineering Sciences. Number of publications: 25. E-mail: usilin.sergey@gmail.com

**Arlazarov Vladimir Viktorovich.** Head of a section, Federal Research Center “Computer Science and Control” of Russian Academy of Sciences, Moscow, Russia. Smart Engines Services LLC, Moscow, Russia. Ph.D. of Engineering Sciences. Number of publications: 75. E-mail: vva777@gmail.com

**Putintsev Dmitry Nikolaevich.** Senior scientist, Federal Research Center “Computer Science and Control” of Russian Academy of Sciences, Moscow, Russia. Smart Engines Services LLC, Moscow, Russia. Ph.D. of Chemical Sciences. Number of publications: 35. E-mail: putincevd@gmail.com

**Tarkhanov Ivan Aleksandrovich.** Senior scientist, Federal Research Center “Computer Science and Control” of Russian Academy of Sciences, Moscow, Russia. Ph.D. of Engineering Sciences. Number of publications: 33. E-mail: tarkhanov@isa.ru