

Искусственный интеллект в геофизике: сценарии, проблемы, тенденции

■ Булаев В.И., АО НПФ «Геофизика», г. Уфа.

Введение

На сегодняшний день системы, использующие машинное обучение, глубокое обучение и искусственный интеллект (ИИ) всё в большей степени входят в нашу жизнь. Это происходит как на бытовом уровне (умные устройства, социальные сети, рекомендательные системы, программы развлекательного характера), так и в реальном секторе экономики. Данная тенденция характерна и для нефтегазовой отрасли. Но если буквально несколько лет назад сам факт использования ИИ для решения какой-либо задачи придавал много оптимизма, то сегодня ситуация существенно изменилась: помимо собственно создания и обучения модели необходимо решать множество сопутствующих организационно-технических вопросов.

К сожалению, львиная доля публикаций, описывающих применение ИИ, посвящена скорее математическим и/или техническим аспектам создания модели и практически не затрагивает самые базовые вопросы: почему для решения конкретной задачи необходимо использовать технологии ИИ и как в дальнейшем планируется использовать разработанную систему? Своевременные ответы на эти вопросы позволят идентифицировать способ использования системы ИИ в организации, оценить уровень затрат и избежать наиболее распространенных ошибок.

Данная статья – это попытка в первом приближении ознакомить широкий круг специалистов геофизической отрасли с наиболее распространенными сценариями использования систем на базе ИИ, существующими на сегодняшний день проблемами их разработки и внедрения, а также современными тенденциями.

Терминология

В научной среде пока нет единого принятого всеми определения термина «искусственный интеллект» (artificial intelligence, AI), и разные исследовательские школы трактуют его по-разному. Если говорить в нестрогом смысле, то ИИ – это множество алгоритмов из различных научных дисциплин (математика, физика, биология, медицина, психология и т.д.), позволяющих решать такие задачи, которые ранее решались с помощью человека. В этом многообразии алгоритмов и методик можно выделить несколько подмножеств (рис.1):


- Машинное обучение (machine learning, ML) – класс методов искусственного интеллекта, характерной чертой которых является не прямое решение задачи, а обучение за счёт применения решений множества сходных задач.

- Нейронные сети (neural networks, NN) – математические модели, построенные по принципу организации и функционирования биологических нейронных сетей (нервных клеток живого организма). Это подмножество алгоритмов имеет альтернативное название «искусственные нейронные сети» (artificial neural networks, ANN, сокращенно NN).

- Глубокое / глубинное обучение (deep learning, DL) – является подмножеством нейросетевых методов. Алгоритмы из стека DL основаны на обучении представлениям, а прилагательное «глубокий» указывает на то, что в данном классе методов и моделей используется много уровней / слоев нейронной сети.

1. Сценарии использования ИИ в организации

На сегодняшний день накоплен определенный опыт использования иску-



▲ Рис. 1. Структура искусственного интеллекта.

ственного интеллекта для решения практических задач в различных отраслях науки и техники. В соответствии с этим опытом, можно выделить следующие наиболее распространенные сценарии использования ИИ: апробация, научно-исследовательские работы, промышленное использование и пилотный проект. Рассмотрим каждый из них более подробно.

1.1. Апробация

Суть данного сценария заключается в следующем. Коллектив сотрудников (далее «команда») исследует возможности какого-либо алгоритма из стека технологий ML/DL/ИИ для решения практической задачи своей предметной области. Формальная математическая постановка задачи как правило отсутствует, набор данных для обучения небольшой – тот, который имеется под рукой в текущий момент. Критерии успешности решения задачи довольно размытые, либо вообще отсутствуют.

В минимальном варианте исследовательская команда при использовании данного сценария представлена двумя сотрудниками: специалист по предметной области (геолог / геофизик / инженер) и специалист в области машинного обучения (data scientist, DS).

Для реализации этого сценария можно использовать производительный многоядерный персональный компьютер со свободным доступом к интернету – этого будет достаточно для обучения классических моделей машинного обучения на небольшом наборе данных. В предыдущие годы, если возникала необходимость обучать нейронные сети, можно было воспользоваться бесплатными сервисами, например kaggle, google colab [2] и др. Они предоставляли онлайн-доступ к вычислительным ресурсам (в том числе графическим картам) на непродолжительное время (8-12 часов в зависимости от сервиса). Однако в последнее время с учетом вводимых санкций таких возможностей становится все меньше, поэтому лучше иметь локальную видеокарту средней мощности.

Данный сценарий используется в следующих ситуациях:

- ознакомление с современными технологиями машинного обучения;
- предварительное опробование алгоритмов машинного обучения для решения конкретной задачи предметной области;
- публикация результатов в печатной прессе, интернете, научно-популярных изданиях;
- реклама, пиар и демонстрация того,

что организация находится на острие современных технологий.

Примеры релевантных целей для данного сценария:

- разобраться, как работает модель BERT;
- опробовать свёрточные нейронные сети для определения первых вступлений на сейсмограммах МОВ;
- обучить полиномиальную модель для фильтрации данных;
- сравнить 5 различных моделей машинного обучения для восстановления интервального времени по данным ГИС.

В ходе исследования команда с учетом своего опыта и уровня владения инструментальными средствами опробует различные модели. Эксперименты зачастую проводятся без строгой формулировки гипотез и без отчетности. Данный сценарий – самый распространенный, т.к. он не требует больших затрат для реализации.

1.2. Научно-исследовательские работы

В данном сценарии проводится полноценное научное исследование, которое покажет теоретическую возможность (либо невозможность) решения поставленной задачи с помощью методов ИИ. Исследование начинается с формальной постановки задачи и системного анализа существующих на данный момент способов «классического» решения, их достоинств и недостатков. В ходе этого должны быть продемонстрированы проблемы существующих методов, которые подводят исследователей к необходимости опробования алгоритмов ИИ.

При этом серьёзное внимание уделяется подготовке набора данных («датасет»), на котором планируется обучать и тестировать модель, дизайну экспериментов, проверки гипотез, статистическому анализу и т.п. По завершению исследований составляется полноценный научный отчет

с подробным описанием полученных результатов и их интерпретацией.

Этот сценарий используется в следующих случаях:

- тематические исследования, гранты;
- обоснование целесообразности использования машинного обучения для решения какой-либо задачи предметной области;
- публикация полученных результатов в серьёзных научных изданиях.

Примеры релевантных целей для данного сценария:

- сравнение классического и нейросетевого подходов для задачи подавления поверхностных волн в наземной сейсморазведке;
- синтез архитектуры нейронной сети для автоматизированной стратификации разреза;
- выбор априорного распределения байесовской модели машинного обучения для задачи аппроксимации трендов.

Данный сценарий предъявляет более жесткие требования к команде, и в самом простом случае необходимо привлечь к работе следующих специалистов:

- 1) эксперт в предметной области, который может формально поставить задачу, контролировать корректность экспериментов и проанализировать полученные результаты;
- 2) специалист в области машинного обучения для работы с моделями;
- 3) геофизик и/или геолог для подготовки исходных данных, обработки результатов модели и их сравнения с традиционными способами;
- 4) математик для корректной обработки полученной статистики (зачастую математиком выступает эксперт предметной области или специалист по машинному обучению).

С точки зрения требований к аппаратуре

ному обеспечению для реализации этого сценария необходима высокопроизводительная многоядерная рабочая станция с существенным объемом памяти и мощной графической картой – в конечном итоге при большом количестве экспериментов это будет не дороже, чем аренда серверов и облачных решений.

Данный сценарий не так распространен, как предыдущий, и он является более дорогостоящим из-за необходимости покупки высокопроизводительной рабочей станции, найма специалиста по машинному обучению и отрыва геофизиков/геологов/экспертов от своей основной работы на период проведения исследований. Тем не менее, он вполне по силам организации нефтегазовой отрасли даже с учетом текущих цен на вычислительную технику.

1.3. Промышленное использование

Этот сценарий имеет несколько альтернативных названий: производственная эксплуатация, промышленная эксплуатация, в ИТ-среде также широко распространен термин «продакшен», или кратко «прод»/«пром».

Данный сценарий используется для:

- оптимизации бизнес-процессов предприятия;
- сокращения затрат и / или повышения прибыли;
- улучшения бизнес-метрик организации.

Примеры релевантных целей для данного сценария:

- уменьшить время работы геофизика-интерпретатора на 40%;
- повысить достоверность прогнозов на 10%;
- ускорить вычисления на 20%.

Необходимо отметить, что в правильно поставленных целях в рамках данного сценария не фигурирует машинного обучения как такового, потому что используемые алгоритмы, которые позволяют добиться цели, в данном контексте вторичны. Ведь если удалось, к примеру, ускорить вычисления на 20% с помощью классических способов – в этом нет ничего плохого.

Ниже приведены примеры некорректных целей (табл.1).

Важное примечание: необходимо еще раз подчеркнуть, что приведенные в табл. 1 примеры целей являются некорректными в рамках именно продакшена. При использовании других сценариев (например, при апробации) эти цели могут быть вполне жизнеспособными.

При внедрении в промышленную эксплуатацию задействуется следующий коллектив:

- 1) команда специалистов по предметной области (геологи, геофизики, эксперты);
- 2) опытные технологи, которые могут подсказать узкие места в производстве;

▼ Табл. 1. Примеры некорректных целей с пояснениями.

Пример целей	Пояснение
Создать и обучить нейросетевую модель для фильтрации данных	Далеко не факт, что именно нейросетевая модель даст наилучший результат фильтрации. Кроме того, есть риск, что большая нейронная сеть будет очень медленно работать, и это не позволит использовать ее в производстве
Внедрить 20 современных моделей в промышленную эксплуатацию	В производстве как правило, (по опыту смежных сфер), используется только одна модель, которая является оптимальной с точки зрения качества/быстродействия
Разобраться, как работает механизм Attention	Сам факт понимания механизма работы той или иной современной модели никак не гарантирует, что именно эта модель подойдет для промышленного использования
Улучшить работу специалистов	Данная цель при всех своих достоинствах слишком аморфна и некорректна для производства. Ее надо более четко конкретизировать и формализовать

3) системный аналитик, который сводит работу всех команд воедино и по факту руководит процессом внедрения в производство;

4) команда специалистов по машинному обучению: специалисты по работе с данными (DS), инженеры по машинному обучению (MLE) и т.п.;

5) команда по инфраструктуре: инженеры по работе с данными (DE), системные администраторы, специалисты по безопасности, инженеры ЛВС, интеграторы для увязки моделей с используемым в организации ПО и т.д.

Отличительная специфика работы нефтегазового сектора от ИТ-предприятий заключается в том, что в подавляющем большинстве случаев Заказчик не позволяет передавать свои данные третьим лицам. Поэтому для продакшена приходится разворачивать свою собственную инфраструктуру, при этом стек используемых технологий выглядит весьма внушительно (рис. 2).

Этот сценарий – самый «тяжелый» и дорогой из всех, что связано с необходимостью использования больших вычислительных мощностей, стеком сложных технологий из сферы ИТ и привлечения команд высококлассных специалистов, за

которых идет борьба на рынке труда. Более подробно особенности данного сценария рассмотрены в работе [1].


1.4. Пилотный проект

Этот сценарий занимает промежуточное положение между научно-исследовательскими работами и промышленным использованием. Пилот используется в тех же ситуациях, что и промышленный сценарий. Примеры корректных и некорректных целей, требование к исследовательской команде, аппаратному обеспечению и стеку технологий – всё это аналогично сценарию «продакшен».

Для полноценного осуществления пилотного проекта необходимо соблюдение следующих условий:

- успешно проведенные научно-исследовательские работы
- четко прописанные критерии успешности
- наличие небольшого подразделения, в котором с одной стороны можно провести пилот без ущерба деятельности организации в целом, а с другой стороны результаты и выводы могли бы быть обобщены на всё предприятие
- наличие необходимого количества специалистов и оборудования

▼ Рис. 2. Стек технологий, использующихся при внедрении ИИ в промышленную эксплуатацию.



Последний пункт необязателен в случае, если пилотный проект проводится сторонней подрядной организацией, которая специализируется на работе с данными и машинном обучении и имеет свой необходимый персонал и оборудование.

1.5. Взаимосвязь сценариев

Возникает закономерный вопрос: какой из сценариев использовать на предприятии нефтегазовой отрасли? Для ответа на него можно взглянуть на опыт применения машинного обучения в других сферах, и в первую очередь на ИТ-отрасль. Исследования, проведенные в [3, 4] показывают, что около 85% проектов, связанных с машинным обучением, искусственным интеллектом и большими данными, не доходят до стадии промышленного использования.

Почему так происходит? Этот вопрос нетривиальный, и в каждом конкретном случае могут быть разные причины: несоответствие целей, плохое командное взаимодействие, низкая прозрачность процесса, изначально некорректная постановка задач и т.д. и т.п. Чтобы не повторять подобных ошибок, следует использовать опыт коллег из смежных отраслей и учитывать их советы и рекомендации. Один из них – это использовать стадийность процесса внедрения:

- 1) сначала проводится апробация (для этого не нужно много затрат);
- 2) после успешной апробации необходимо провести полноценные научно-исследовательские работы;
- 3) если НИР дали положительные результаты, следует провести пилотный проект, затрагивающий небольшую, но репрезентативную часть организации;
- 4) и только при условии успешной реализации предыдущих этапов можно переходить к стадии промышленного внедрения.

Предложенный способ является долгим и дорогостоящим. Безусловно, есть

примеры быстрого вывода систем ИИ в продакшен, но эти примеры скорее единичны и относятся к сфере ИТ. Попытки «быстро и дешево» внедрить машинное обучение на предприятиях реального сектора экономики как правило заканчиваются провалом с последующим неверным выводом о том, что вся технология ИИ не работает.

2. Типичные ошибки применения ИИ

Рассмотрим типичные ошибки, которые допускаются при попытке использования искусственного интеллекта в реальном секторе экономики. Укрупненно их можно подразделить на три категории: технические, методические и системные ошибки.

2.1. Технические ошибки

Данный класс ошибок связан с конкретной решаемой задачей. Это может быть неверно выбранный алгоритм, неправильная функция потерь, неверно выбранный тип априорного распределения, не тот тип регуляризации и т.д. В целом довольно сложно выявить определенные паттерны, т.к. спектр решаемых на сегодняшний день задач в различных отраслях науки и техники достаточно велик.

2.2. Методические ошибки

Ошибки этой категории как правило связаны с неправильным использованием технически верных моделей и парадигм. Можно выделить следующие наиболее распространенные ошибки методического плана, которые в том или ином виде встречаются в различных отраслях:

- отсутствие подходящего аппаратного обеспечения. Например, если мы пытаемся использовать глубокие нейронные сети, не имея в наличии подходящей графической платы;
- неверно выбранный стек технологий. Пусть к примеру, необходимо на регуляр-

ной основе выгружать специфическую информацию из базы данных и подавать ее на вход модели. Даже если у нас совершенная модель, мы не сможем ее использовать без необходимой СУБД и соответствующих коннекторов к ней;

- неправильно подобранная команда специалистов или отсутствие нужного специалиста. Как правило, это отсутствие опытного технолога в команде;
- недоучет специфики предметной области;
- использование некорректных критериев успешности.

Необходимо еще раз подчеркнуть, что вышеприведенные проблемы являются ошибками не технического, а методического плана. И для узкопрофильного специалиста они могут быть вовсе не очевидными. Например, датасайентист может обучить очень хорошую с точки зрения точности модель. Но в итоге она не сможет пойти в производственную эксплуатацию из-за задержек процесса распознавания, высоких требований к вычислительной мощности, сложности встраивания в контур предприятия, проигрышу классическому решению и т.п.

2.3. Системные ошибки

Данная категория ошибок – наименее явная и в то же время самая серьезная. Примеры системных ошибок:

1) Некорректные с точки зрения используемого сценария цели

Как правило, это такие ситуации, когда в одном сценарии используются задачи, предназначенные для другого сценария. Типичные случаи: использование аморфных целей для промышленного использования, недостаточная с математической точки зрения формализация задачи в НИР, плохая проработка пилотного проекта.

2) Недоучет классических способов решения задачи

В подавляющем большинстве случаев

задача, которую пытаются решить с помощью искусственного интеллекта, уже имеет какие-либо способы решения, либо попытки такого решения. Необходимо проводить системный анализ «классических» подходов – с одной стороны это не позволит впасть в самообман, а с другой стороны знания, выявленные в ходе такого анализа, впоследствии могут быть успешно встроены в интеллектуальное решение.

3) Недостаточное внимание применению стандартных алгоритмов машинного обучения для решения задачи

К сожалению, большинство специалистов по машинному обучению сразу же пытаются применить глубокие нейронные сети для решения задачи. При этом они обходят стороной уже зарекомендовавшие себя в прошлые десятилетия известные стандартные модели машинного обучения, такие как линейная/логистическая регрессия, деревья решений и их ансамбли, машины опорных векторов и т.п. Достоинства таких методов в понятности их работы (как правило это не «черный ящик»), скорости, быстродействию, низкой требовательности к аппаратным ресурсам. Более того, во многих приложениях ИТ-индустрии (рекомендательные системы, системы скоринга, диагностики, предиктивная аналитика) при правильной организации эксперимента классические модели показывают аналогичный нейронным сетям результат, при этом выигрывая по производительности в десятки раз.

4) Отсутствие бейзлайнов (для сценариев НИР, пилот и продакшен)

Бейзлайн (англ. baseline) – это результат применения к задаче очень простого решения. В качестве бейзлайна может выступать какая-либо эвристика (основанная на правилах), простая физическая модель (если она есть), существующий способ решения задачи, простая модель

машинного обучения (например, линейная регрессия), либо качество решения задачи человеком.

По негласным правилам хорошего тона, перед началом исследований специалист по машинному обучению оценивает, что можно использовать в качестве бейзлайна, и с помощью него получает начальный результат решения задачи. Далее по ходу работы происходит обучение более сложных моделей и сравнение их результатов с бейзлайном.

К сожалению, большинство современных специалистов по машинному обучению забывают об этом правиле и делают свою работу в отрыве от реальности. Можно сэкономить очень много времени, создав хороший бейзлайн, который кроме того позволит сконцентрироваться на поисках решений в нужном направлении.

3. Проблемы использования глубокого обучения

На сегодняшний день модели, основанные на глубоких нейронных сетях, являются безусловным лидером в трех направлениях:

- компьютерное зрение (computer vision, CV). В данном направлении решаются такие задачи, как распознавание изображений и видео, сегментация и детектирование объектов (выделение нужных областей), генерация визуального контента и т.п. – все, что так или иначе связано с графическим материалом.

- обработка естественного языка (natural language processing, NLP). Сюда входят задачи определения тональности высказываний, классификация и генерация текстов, создание автоматических аннотаций, различные чат-боты и т.п.

- голосовые технологии. Это направление включает в себя распознавание и генерация речи, работа с тембром, замена одного голоса на другой, голосовая биометрия и т.д.

Главным фактором, объединяющим

данные направления (по мнению автора) является тот момент, что критерием качества работы этих систем является человек. Это привносит определенный момент субъективности в данные модели. И если говорить научным языком, то необходимо подчеркнуть, что в основе работы таких нейросетей лежит психофизиологическая модель восприятия человека. Это может быть представлено как на структурном уровне (например, конволюционные нейронные сети были изобретены на основании анализа работы человеческого глаза; широко распространенная модель «attention» – на основе психологических особенностей внимания человека и т.п.), так и в виде функционала ошибки, который используется при обучении нейронных сетей.

Можем ли мы напрямую использовать такие нейронные сети в геофизике – вопрос открытый и дискуссионный, который требует тщательного научного исследования в каждой конкретной прикладной задаче. По мнению автора, нельзя отвергать возможность использования вышеупомянутых нейронных сетей в нефтегазовой отрасли, так же, как и нельзя голословно принимать их только лишь на основании того, что они работают в мультимедийной и развлекательной сфере.

Кроме того, у глубоких нейронных сетей существует ряд объективных недостатков:

- 1) сложность интерпретации результата, который выдала обученная модель. Суть в том, что очень трудно понять, на каком основании нейронная сеть выдала определенный результат. Поэтому в тех отраслях, где необходима интерпретируемость (например, в банковском секторе при кредитном скоринге), используются стандартные модели машинного обучения, которые лишены данного недостатка.

- 2) практическая невозможность повторить результаты обучения. Это проявляется

ся в том, что при попытке создать с нуля и обучить нейронную сеть из какой-либо научной статьи, мы не получим точно такого же результата. Более того, даже запуская один и тот же код обучения на одних и тех же обучающих данных на том же самом компьютере, мы получим разные модели. Так происходит в силу того, что в современных моделях используются различные методы борьбы с переобучением, основанные на случайном перемешивании входных данных, выключении некоторых весов из процесса обучения (drop-out), аугментации данных и т.п.

3) уязвимость атак на сеть (adversarial attacks). Суть данной проблемы в том, что если во входной сигнал подмешать определенным образом сгенерированный шум, то нейронная сеть перестает нормально работать. Данная проблема обнаружена сравнительно недавно, и окончательного решения пока не найдено.

Это вовсе не значит, что нужно ставить крест на использовании глубокого обучения в реальном секторе экономики. Просто нужно понимать, что есть проблемы, и разрабатывать подходы и решения, которые позволяли бы избежать фатальных ошибок при внедрении ИИ в производство. Более того, наука не стоит на месте, и в последнее время появились перспективные направления, которые потенциально могут преодолеть вышеописанные трудности:

- интерпретируемый ИИ (explainable AI, xAI) – направление, которое исследует способы и возможности сделать ИИ более прозрачным и объяснимым;
- нейронные сети, основанные на физике (physics-informed neural networks, PINN). При обучении таких моделей в функционал ошибки вводятся дополнительные ограничения исходя из физики

процесса;

- байесовское машинное обучение (bayesian machine learning) – это подход, который сочетает байесовскую статистику и машинное обучение для составления прогнозов и выводов при явном учете неопределенности.

Данные направления видятся особенно перспективными для задач нефтегазовой отрасли.

4. Современные тенденции применения ИИ в нефтегазовой отрасли

Не смотря на приведенные выше ошибки и проблемы, на сегодняшний день можно сказать, что в целом искусственный интеллект имеет большие перспективы применения в реальном секторе экономики, в том числе и в геофизике. Появляется все больше примеров успешного применения машинного обучения в различных отраслях, на практически всех значимых международных конференциях целые секции посвящаются вопросам применения ИИ.

На основании опыта участия автора в различных мероприятиях международного уровня, можно выделить следующие тенденции.

4.1. Все более частое применение ML/DL/AI/IT-алгоритмов для решения широкого спектра практических задач нефтегазовой отрасли.

Ниже приведены примеры наиболее распространенных типов задач:

- увязка коротажных данных различных скважин;
- автоматизированная интерпретация коротажных кривых;
- применение технологий NLP для обработки геолого-геофизических отчетов;
- применение технологий CV для распознавания графических паттернов на

геолого-геофизических данных;

- восстановление данных одного из методов ГИС по набору других каротажных данных;
- автоматизация процесса обработки и интерпретации сейсмических данных;
- использование машинного обучения в процессе бурения и геонавигации.

4.2. Тщательная и скрупулезная работа по систематизации и подготовке геолого-геофизических данных с целью их последующего использования для обучения алгоритмов ML/DL/AI:

- каталогизация имеющихся данных и ведение единого реестра;
- кластеризация данных (выделение наиболее характерных типов во всем массиве информации);
- систематизация имеющейся информации (выработка единых стандартов к форматам данных, способам хранения, запросам для извлечения данных);
- использование ML/DL/AI/IT для автоматизированной оцифровки и распознавания архивных геолого-геофизических материалов;
- применение современных информационных технологий для создания хранилищ данных и возможности оперативного доступа к любой необходимой информации.

4.3. Более широкое применение алгоритмов оптимизации и предиктивной аналитики для продвинутой работы с аппаратурой и оборудованием:

- автоматизированный анализ состояния оборудования и аппаратуры на основе показаний сенсоров/датчиков и исторической информации;
- построение прогнозов по износу и выходу из строя оборудования;
- переход от обслуживания по регламенту к обслуживанию по состоянию;

- оптимизация логистических и технологических цепочек;
- использование алгоритмов из стека рекомендательных систем для построения прогнозов и рекомендаций.

Литература:

1. Булаев В.И. Особенности внедрения моделей машинного обучения в производственную эксплуатацию // Геофизика. 2022. №4. С. 143-147.
2. Что такое Google Colab и кому он нужен? <https://blog.skillfactory.ru/chto-takoe-google-colaboratory-i-komu-on-nuzhen/> (дата обращения: 30.10.2023).
3. Failure rates for analytics, AI, and big data projects = 85% – yikes! <https://designingforanalytics.com/resources/failure-rates-for-analytics-bi-iot-and-big-data-projects-85-yikes/> (дата обращения: 30.10.2023)
4. Why do 87% of data science projects never make it into production? <https://venturebeat.com/2019/07/19/why-do-87-of-data-science-projects-never-make-it-into-production/> (дата обращения: 30.10.2023)

Подробнее об авторе



Булаев
Владимир Иванович

К.т.н., главный специалист по машинному обучению АО НПФ «Геофизика» (АО «Башнефтегеофизика»), г. Уфа.