

(19)



**Евразийское
патентное
ведомство**

(21) **202293564** (13) **A1**

(12) **ОПИСАНИЕ ИЗОБРЕТЕНИЯ К ЕВРАЗИЙСКОЙ ЗАЯВКЕ**

(43) Дата публикации заявки
2023.09.27

(51) Int. Cl. *G06N 3/02* (2006.01)
G06N 20/00 (2019.01)
G06F 11/36 (2006.01)

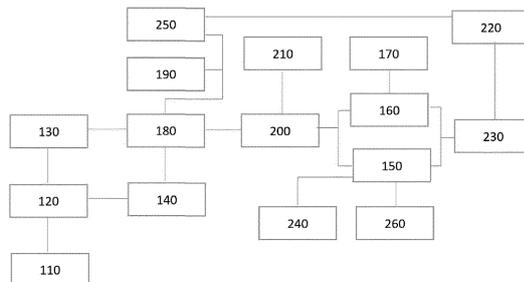
(22) Дата подачи заявки
2022.12.30

(54) **СПОСОБ И СИСТЕМА ОЦЕНКИ КАЧЕСТВА ЦИФРОВЫХ РЕШЕНИЙ С ЭЛЕМЕНТАМИ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА НА ОСНОВЕ ГЕНЕРАТИВНЫХ ТЕХНОЛОГИЙ И АВТОМАТИЧЕСКОГО МАШИННОГО ОБУЧЕНИЯ**

(96) 2022000144 (RU) 2022.12.30
(71) Заявитель:
**ФЕДЕРАЛЬНОЕ
ГОСУДАРСТВЕННОЕ
АВТОНОМНОЕ
ОБРАЗОВАТЕЛЬНОЕ
УЧРЕЖДЕНИЕ ВЫСШЕГО
ОБРАЗОВАНИЯ
"НАЦИОНАЛЬНЫЙ
ИССЛЕДОВАТЕЛЬСКИЙ
УНИВЕРСИТЕТ
ИТМО" (УНИВЕРСИТЕТ ИТМО)
(RU)**

(72) Изобретатель:
**Иванов Сергей Владимирович,
Бухановский Александр Валерьевич,
Ходненко Иван Владимирович (RU)**
(74) Представитель:
Абраменко О.И. (RU)

(57) Способ и система оценки качества цифровых решений с элементами искусственного интеллекта на основе генеративных технологий и автоматического машинного обучения были созданы в рамках договора о предоставлении средств юридическому лицу, индивидуальному предпринимателю на безвозмездной и безвозвратной основе в форме гранта, источником финансового обеспечения которых полностью или частично является субсидия, предоставленная из федерального бюджета, № 70-2021-00141 от 2 ноября 2021 года по мероприятию 5.2 Разработка и испытания опытного образца технологического полигона, направление развития ИИ - генеративный искусственный интеллект. Изобретение относится к области обработки данных, а более конкретно к области сопровождения жизненного цикла программных и программно-аппаратных вычислительных комплексов с элементами искусственного интеллекта в части оценки их качества. Техническим результатом является повышение детализации и обоснованности оценки качества РЭИИ по характеристикам функциональности, надежности и безопасности с возможностью определения потенциала дальнейшего развития и применимости модели ИИ в составе РЭИИ.



A1

202293564

202293564

A1

Способ и система оценки качества цифровых решений с элементами искусственного интеллекта на основе генеративных технологий и автоматического машинного обучения

Область техники

Изобретение относится к области обработки данных, а более конкретно к области сопровождения жизненного цикла программных и программно-аппаратных вычислительных комплексов с элементами искусственного интеллекта в части оценки их качества.

Уровень техники

Качество решений с элементами ИИ (далее РЭИИ) как программных или программно-аппаратных вычислительных комплексов, в соответствии с ГОСТ Р 59898-2021 определяется путем оценки их соответствия требованиям функциональности, надежности и безопасности. В отличие от традиционных программных изделий или программно-аппаратных комплексов, ключевой проблемой является то, что ИИ имитирует когнитивные функции человека в условиях неопределенности и неполноты данных, и потому в некоторых случаях неизбежно может порождать нерелевантные и ошибочные решения. Необходимость создания систем ИИ с контролируемым качеством работы выразилась в развитии подходов т.н. доверенного (trusted) ИИ, которые обеспечивают гарантированное достижение функциональных характеристик в заданных диапазонах при соблюдении требований к надежности и безопасности (включая устойчивость к атакам). В настоящее время параллельно развиваются разные методические подходы к обеспечению доверенного характера систем ИИ. Например, в рамках европейского проекта ALTAI (The Assessment List on Trustworthy Artificial Intelligence) предложен механизм обеспечения доверия за счет выполнения априорных требований к

системе ИИ. В рамках федерального проекта «Искусственный интеллект» в исследовательском центре ИИ при ИСП РАН предлагается строить доверенные системы ИИ путем использования открытых фреймворков и библиотек с алгоритмически подтвержденным отсутствием уязвимостей. Система DataRobot, напротив, предлагает инструменты для тестирования уже готовых РЭИИ на предмет доверия. В этой логике существуют и иные инструменты оценки различных составляющих качества, например, IBM Adversarial Robustness 360 Toolkit и Microsoft Fairlearn.

Недостатком всех известных решений для оценки качества РЭИИ является отсутствие метрологической основы (системы эталонов и правил сравнения с ними) для характеристик, определяющих функциональность РЭИИ. Традиционно функциональность РЭИИ описывается набором метрик (точность, полнота, и пр.), номинальные значения которых задаются экспертно. Как следствие, это затрудняет сравнение и ранжирование моделей ИИ, используемых в составе РЭИИ, а также обоснование их пригодности для решения различных классов прикладных задач. Другими словами, существующие решения позволяют определить факт (не)достижения целевого показателя по точности или полноте на фиксированных наборах данных, но не гарантируют, что он будет таким в ходе эксплуатации на произвольных данных. При этом не существует решений, которые могли бы объективно определить потенциал повышения качества по функциональным характеристикам за счет улучшения модели ИИ. Особую значимость эта проблема приобретает в ситуациях, когда оценивается РЭИИ в виде «черного ящика», для которого не раскрыты ни используемые в нем модели ИИ, ни критерии качества, которыми руководствовались разработчики.

Предлагаемое изобретение за счет применения технологии композитного автоматического машинного обучения (КАМО) позволяет строить систему эталонов ИИ, исходя из которой определяются потенциально достижимые значения метрик качества РЭИИ по функциональным

характеристикам. Они служат основой для последующих автоматизированных испытаний конкретного РЭИИ на синтетических наборах данных, в ходе которых не только устанавливается мера его соответствия номинальным характеристикам качества, но и определяются границы и условия, в которых она обеспечивается, а также выявляются различные уязвимости и иные недостатки модели ИИ, используемой в РЭИИ.

Сущность изобретения

Способ оценки качества цифровых решений с элементами искусственного интеллекта, включает в себя:

- интегрирование РЭИИ в контур системы оценки качества цифровых решений;
- получение исходных обучающих и тестовых наборов данных, определенных на базе задач, решаемых интегрированной РЭИИ;
- определение метрик функциональных характеристик (МФХ) для оценки качества интегрированной РЭИИ;
- формирование системы эталонов искусственного интеллекта (ИИ) с помощью композитного автоматического машинного обучения (КАМО) на базе полученных исходных обучающих и тестовых наборов данных, содержащую:
 - эталонное значение предсказуемости, задающее верхний предел качества по функциональным характеристикам;
 - потенциальный эталон модели ИИ, определяющий максимальное практически достижимое качество путем композиции разных алгоритмов машинного обучения;
 - семейство базовых эталонов моделей ИИ, определяющих наименьшее гарантированное качество на разных классах методов машинного обучения;

- формирование синтетических наборов данных с помощью генеративных технологий, повторяющих свойства исходных обучающих и тестовых наборов данных,
- определение значений определенных ранее МФХ и их интервальных оценок на основе сформированных синтетических наборов данных;
- сравнение модели ИИ, реализованной в РЭИИ, с системой эталонов ИИ по определенным ранее МФХ;
- определение соответствия РЭИИ требованиям качества;
- определение возможных улучшения РЭИИ в части обеспечения требуемой функциональности за счет дополнительных элементов для модели ИИ, реализованной в РЭИИ, причем дополнительные элементы реализованы посредством КАМО с учетом соответствия МФХ.

В одном из вариантов реализации способ, отличается тем, что в случае интегрирования РЭИИ в контур программного решения, способ дополнительно включает в себя аннотирование и регистрацию как внешней функции в системе:

- описание формата обращения к программному решению как внешней функции;
- описание форматов и структуры входных и выходных данных внешней функции;
- указание априорных сведений о номинальных характеристиках качества модели ИИ, реализуемой внешней функцией, а также ссылки на пользовательскую документацию по программному решению;

В одном из вариантов реализации способ, отличается тем, что в случае интегрирования РЭИИ в контур программно-аппаратного комплекса, способ дополнительно включает в себя:

- физическое подключение в контур РЭИИ через интерфейсы обмена входными и выходными данными в рамках единой локальной вычислительной сети;
- аннотирование.

В одном из вариантов реализации способ, отличается тем исходные обучающие и тестовые данные определяются внешним разработчиком, или берутся из библиотеки бенчмарков для выбранного класса задач.

В одном из вариантов реализации способ, отличается тем, что исходные обучающие и тестовые данные могут быть получены с помощью генеративных технологий на основе агрегированных статистик или обучающих примеров.

В одном из вариантов реализации способ, отличается тем, что системы эталонов представляют собой суррогатные модели, с разной степенью детализации описывающие на основе исходных обучающих и тестовых наборов данных работу модели ИИ, реализованной в РЭИИ.

В одном из вариантов реализации способ, отличается тем, что эталонное значение предсказуемости определяется на основе энтропийной характеристики популяции моделей КАМО.

В одном из вариантов реализации способ, отличается тем, что энтропийная характеристика популяции моделей КАМО воспроизводит работу модели ИИ, реализованной в РЭИИ, построенную с помощью генетического алгоритма без ограничений на структуру графа задач и используемые алгоритмы.

В одном из вариантов реализации способ, отличается тем, что потенциальный эталон определяется посредством КАМО, формирующего суррогатную модель работы РЭИИ в виде графа задач с наименьшим количеством вовлекаемых алгоритмов машинного обучения, дающий наибольшее качество модели по выбранным МФХ.

В одном из вариантов реализации способ, отличается тем, что семейство базовых эталонов строится на основе типовых шаблонов применения различных алгоритмов машинного обучения для решения задачи РЭИИ.

В одном из вариантов реализации способ, отличается тем, что генерация синтетических наборов данных включает следующие шаги:

- выбор подхода к генерации синтетических наборов входных данных исходя из постановки задачи РЭИИ;
- обучение генеративной модели;
- генерация синтетических наборов входных данных посредством обученной генеративной модели;
- синтетические наборы входных данных поступают на вход РЭИИ, причем создаются синтетические наборы выходных данных;
- расчет МФХ по каждому синтетическому набору входных и выходных данных;
- определение толерантных интервалов, характеризующих изменчивость отдельных МФХ, причем оцениваются доверительные интервалы для характерных границ.

В одном из вариантов реализации способ, отличается тем, что определение возможных улучшения РЭИИ выполняется с помощью генетического алгоритма, причем строится композитное приложение, дополняющее модель ИИ, реализованной в РЭИИ, новыми алгоритмами машинного обучения.

В одном из вариантов реализации способ, отличается тем, что дополнительно при выполнении определения возможных улучшения РЭИИ устраняются модели с неустойчивым поведением.

Система оценки качества цифровых РЭИИ, которая содержит:

- по меньшей мере, один процессор;
- по меньшей мере одно устройство хранения данных, содержащее машиночитаемые инструкции, которые при их исполнении по меньшей мере одним процессором выполняют этапы:
 - интегрирование РЭИИ в контур системы оценки качества цифровых решений;
 - интегрирование РЭИИ в контур системы оценки качества цифровых решений;
 - получение исходных обучающих и тестовых наборов данных, определенных на базе задач, решаемых интегрированной РЭИИ;
 - определение метрик функциональных характеристик (МФХ) для оценки качества интегрированной РЭИИ;
 - формирование системы эталонов искусственного интеллекта (ИИ) с помощью композитного автоматического машинного обучения (КАМО) на базе полученных исходных обучающих и тестовых наборов данных, содержащую:
 - эталонное значение предсказуемости, задающее верхний предел качества по функциональным характеристикам;
 - потенциальный эталон модели ИИ, определяющий максимальное практически достижимое качество путем композиции разных алгоритмов машинного обучения;

- семейство базовых эталонов моделей ИИ, определяющих наименьшее гарантированное качество на разных классах методов машинного обучения;
- формирование синтетических наборов данных с помощью генеративных технологий, повторяющих свойства исходных обучающих и тестовых наборов данных,
- определение значений, определенных ранее МФХ и их интервальных оценок на основе сформированных синтетических наборов данных;
- сравнение модели ИИ, реализованной в РЭИИ, с системой эталонов ИИ по определенным ранее МФХ;
- определение соответствия РЭИИ требованиям качества;
- определение возможных улучшения РЭИИ в части обеспечения требуемой функциональности за счет дополнительных элементов для модели ИИ, реализованной в РЭИИ, причем дополнительные элементы реализованы посредством КАМО с учетом соответствия МФХ.

В одном из вариантов реализации система, отличается тем, что в случае интегрирования РЭИИ в контур программного решения, способ дополнительно включает в себя аннотирование и регистрацию как внешней функции в системе:

- описание формата обращения к программному решению как внешней функции;
- описание форматов и структуры входных и выходных данных внешней функции;

- указание априорных сведений о номинальных характеристиках качества модели ИИ, реализуемой внешней функцией, а также ссылки на пользовательскую документацию по программному решению;

В одном из вариантов реализации система, отличается тем, что в случае интегрирования РЭИИ в контур программно-аппаратного комплекса, способ дополнительно включает в себя:

- физическое подключение в контур РЭИИ через интерфейсы обмена входными и выходными данными в рамках единой локальной вычислительной сети;
- аннотирование.

В одном из вариантов реализации система, отличается тем, что исходные обучающие и тестовые данные определяются внешним разработчиком, или берутся из библиотеки бенчмарков для выбранного класса задач.

В одном из вариантов реализации система, отличается тем, что исходные обучающие и тестовые данные могут быть получены с помощью генеративных технологий на основе агрегированных статистик или обучающих примеров.

В одном из вариантов реализации система, отличается тем, что системы эталонов представляют собой суррогатные модели, с разной степенью детализации описывающие на основе исходных обучающих и тестовых наборов данных работу модели ИИ, реализованной в РЭИИ.

В одном из вариантов реализации система, отличается тем, что эталонное значение предсказуемости определяется на основе энтропийной характеристики популяции моделей КАМО.

В одном из вариантов реализации система, отличается тем, что энтропийная характеристика популяции моделей КАМО воспроизводит работу модели ИИ, реализованной в РЭИИ, построенную с помощью

генетического алгоритма без ограничений на структуру графа задач и используемые алгоритмы.

В одном из вариантов реализации система, отличается тем, что потенциальный эталон определяется посредством КАМО, формирующего суррогатную модель работы РЭИИ в виде графа задач с наименьшим количеством вовлекаемых алгоритмов машинного обучения, дающий наибольшее качество модели по выбранным МФХ.

В одном из вариантов реализации система, отличается тем, что семейство базовых эталонов строится на основе типовых шаблонов применения различных алгоритмов машинного обучения для решения задачи РЭИИ.

В одном из вариантов реализации система, отличается тем, что генерация синтетических наборов данных включает следующие шаги:

- выбор подхода к генерации синтетических наборов входных данных исходя из постановки задачи РЭИИ;
- обучение генеративной модели;
- генерация синтетических наборов входных данных посредством обученной генеративной модели;
- синтетические наборы входных данных поступают на вход РЭИИ, причем создаются синтетические наборы выходных данных;
- расчет МФХ по каждому синтетическому набору входных и выходных данных;
- определение толерантных интервалов, характеризующих изменчивость отдельных МФХ, причем оцениваются доверительные интервалы для характерных границ.

В одном из вариантов реализации система, отличается тем, что определение возможных улучшения РЭИИ выполняется с помощью генетического алгоритма, причем строится композитное приложение, дополняющее модель ИИ в РЭИИ новыми алгоритмами машинного обучения.

В одном из вариантов реализации система, отличается тем, что дополнительно при выполнении определения возможных улучшения РЭИИ устраняются модели с неустойчивым поведением.

Техническим результатом является повышение детализации и обоснованности оценки качества РЭИИ по характеристикам функциональности, надежности и безопасности с возможностью определения потенциала дальнейшего развития и применимости модели ИИ в составе РЭИИ.

Раскрытие изобретения

Для решения существующей технической проблемы в данной области техники предлагается новый способ и система организации процесса оценки качества РЭИИ путем проведения их автоматизированных испытаний с целью изучения соответствия значений метрик функциональности с метриками эталонных моделей ИИ, созданных средствами КАМО, на синтетических массивах данных, созданных с помощью генеративных технологий.

Заявленный результат осуществляется за счет способа оценки РЭИИ с элементами ИИ на основе генеративных технологий и автоматического машинного обучения, включающего в себя следующие этапы, на которых:

- 1) помещают (интегрируют) РЭИИ в контур системы оценки качества цифровых решений.

Согласно одному из вариантов реализации, РЭИИ помещают в контур программного решения. В таком случае выполняется его аннотирование и

регистрация как внешней функции в системе оценки качества цифровых решений. Это включает в себя:

(а) описание формата обращения к программному решению как внешней функции, например, на языке Python;

(б) описание форматов и структуры входных и выходных данных внешней функции (в т.ч. форматов файлов данных, если они используются);

(в) указание (при наличии) априорных сведений о номинальных характеристиках качества модели ИИ, входящей в РЭИИ, реализуемой внешней функцией, а также ссылки на пользовательскую документацию по программному решению;

Согласно одному из вариантов реализации, систему оценки качества цифровых решений помещают в контур программно-аппаратного комплекса РЭИИ. В таком случае система оценки качества цифровых решений физически включается в контур РЭИИ через интерфейсы обмена входными и выходными данными в рамках единой локальной вычислительной сети (ЛВС). При аннотировании указывается доменный адрес, присвоенный программно-аппаратному комплексу, порт, через который осуществляется взаимодействие, а также ссылка на доступ к собственному API. В случае, если у программно-аппаратного комплекса отсутствует API, он может быть реализован иными средствами, например, путем перехвата изображения на экране или прямого доступа к рабочим файлам.

2) задают исходные обучающий и тестовый наборы данных, индивидуальные для каждого РЭИИ. Они могут быть определены внешним разработчиком (оператором), или взяты из библиотеки бенчмарков для выбранного класса задач на данных, например: регрессии, классификации, кластеризации, шкалирования (скоринга), обнаружения аномалий, заполнения пропусков, прогнозирования временных рядов, и пр. В том случае, если наборы входных данных не заданы, они могут быть получены с помощью

генеративных технологий на основе агрегированных статистик (характеризующих свойства выборок) или обучающих примеров, которые подаются на вход. Агрегированные статистики входного набора данных для конкретного РЭИИ описывают их распределения (параметрические или непараметрические) и взаимосвязи в различных приближениях (корреляции, условные моменты, коэффициенты коллигации, спектральные характеристики, и пр.), и применяются преимущественно для табличных данных. Обучающие наборы представляют собой тематические выборки характерных объектов данных, как правило – небольшого размера; их целесообразно использовать для данных сложной структуры (текст, изображения, модели на графах и т.д., но не ограничивается ими). В зависимости от задачи или состава характеристик выбирают имитационную модель для генерации данных в форме метода обратных распределений, бутстрепа, генеративной состязательной сети, и т.д, но не ограничивается ими.. На ее основе создают синтетических наборов данных. В том случае, если требуется набор синтетических выходных данных для оценки характеристик обучения модели ИИ, для их получения используются априорные причинно-следственные или имитационные модели, применяемые к синтетическим входным данным. Объем синтетических массивов входных и выходных данных определяется автоматически, исходя из требований к оценке характеристик качества РЭИИ.

3) задают (определяют) метрики функциональных характеристик (МФХ), исходя из которых оценивается качество РЭИИ. В некоторых не имеющих ограничительного характера вариантах осуществления настоящей технологии, метрики функциональных характеристик выбираются разработчиком (оператором) из стандартного набора, традиционно применяемого для оценки качества систем ИИ, или задаются вручную – как соотношения между метриками стандартного набора.

Лишь в качестве примера, не имеющего ограничительного характера, в некоторых вариантах осуществления настоящей технологии, в качестве метрик могут выступать вероятностные характеристики случайной ошибки регрессии (RMS, MAE, MAPE и пр.) или ошибок классификации первого и второго рода (Accuracy, Recall), а также комплексы на их основе (F1, ROC-AUC) и пр.;

4) с помощью КАМО строят систему эталонов ИИ:

(а) эталонное значение предсказуемости, задающее верхний предел качества по функциональным характеристикам, объективно возможный для данной задачи;

(б) потенциальный эталон модели ИИ, определяющий максимальное практически достижимое качество путем композиции разных алгоритмов машинного обучения;

(в) семейство базовых эталонов моделей ИИ, определяющих наименьшее гарантированное качество на разных классах методов машинного обучения.

Все эталоны представляют собой суррогатные модели, с разной степенью детализации описывающие на основе данных работу модели ИИ в составе РЭИИ.

Эталонное значение предсказуемости определяется на основе энтропийной характеристики популяции моделей КАМО, которые воспроизводят работу модели ИИ, реализованной в РЭИИ, построенные с помощью генетического алгоритма без ограничений на структуру графа задач и используемые алгоритмы.

Потенциальный эталон определяется посредством КАМО, формирующего суррогатную модель работы РЭИИ в виде графа задач с наименьшим количеством вовлекаемых алгоритмов машинного обучения,

дающий наибольшее качество модели по выбранным метрикам. Выбор классов алгоритмов (статистические, нейросетевые и пр.) может быть ограничен разработчиком (оператором), исходя из априорных соображений.

Семейство базовых эталонов строится на основе типовых шаблонов применения различных алгоритмов машинного обучения для решения задачи РЭИИ. Лишь в качестве примера, не имеющего ограничительного характера, в некоторых вариантах осуществления настоящей технологии, для задачи классификации могут рассматриваться шаблоны методов SVM, KMeans, логистической регрессии и др.

5) с помощью генеративных технологий создают (формируют) синтетические наборы данных, повторяющих свойства исходных данных, на основе которых рассчитываются значения выбранных МФХ и строятся их интервальные оценки;

Для этого:

(а) выбирается подход к генерации синтетических данных, исходя из постановки задачи РЭИИ; Лишь в качестве примера, не имеющего ограничительного характера, в некоторых вариантах осуществления настоящей технологии, при генерации синтетических данных могут быть применены такие подходы как параметрический Монте-Карло, бутстреп, генеративная нейронная сеть.

(б) производится подготовка (обучение) генеративной модели:

Лишь в качестве примера, не имеющего ограничительного характера, в некоторых вариантах осуществления настоящей технологии, при обучении:

- для метода Монте-Карло: выбирается метод описания распределений (метод условных распределений, метод условных математических ожиданий, геометрический метод, байесова сеть, ядерные методы, авторегрессионные методы и пр.); по исходным данным оцениваются их параметры;

- для метода бутстреп: выбирается способ бутстрепирования и определяется модель выбора элементов в выборке;

- для генеративной нейронной сети: выбирается архитектура сети, производится обучение модели на данных, оцениваются метрики качества.

(в) посредством обученной генеративной модели создается заданное количество синтетических наборов данных;

(г) синтетические наборы данных поступают на вход РЭИИ, вследствие чего создаются наборы выходных данных (реакций РЭИИ). В некоторых не имеющих ограничительного характера вариантах осуществления наборы выходных данных представляют собой, например, распределения объектов по классам;

(д) по каждому синтетическому набору входных и выходных данных рассчитываются метрики качества, определенные выше;

(е) по выборке метрик качества строятся толерантные интервалы, характеризующие изменчивость отдельных метрик, и оцениваются доверительные интервалы для их характерных границ (минимум, максимум, 25, 50 и 75%);

Процесс (в-е) продолжается циклически (сериями), пока точность, задаваемая доверительными интервалами, не удовлетворит разработчика (оператора).

б) производят интервальное сравнение модели ИИ, реализованной в РЭИИ с системой эталонов ИИ по заданным метрикам; на основе интерпретации результатов сравнения делают заключение о соответствии РЭИИ требованиям качества. Рассматриваются следующие варианты:

а) Интервалы изменения выбранных метрик лежат ниже значений базовых эталонов – РЭИИ функционирует неправильно (возможно, т.к.

некорректно помещена в контур системы оценки качества цифровых решений).

б) Интервалы изменения выбранных метрик покрывают базовые эталоны, но лежат ниже потенциального эталона – модели ИИ в составе РЭИИ обучена недостаточно, требуется ее развитие;

в) Интервалы изменения выбранных метрик лежат выше базовых эталонов, и покрывают потенциальный эталон – модели ИИ в составе РЭИИ подтверждают соответствие требованиям качества для данного класса задач;

г) Интервалы изменения выбранных метрик лежат между потенциальным эталоном и эталонным значением предсказуемости – модель ИИ в составе РЭИИ имеет высокое качество и опирается на априорные знания о природе изучаемой задачи

д) Интервалы изменения выбранных метрик лежат выше эталонного значения предсказуемости – РЭИИ использует причинно-следственные модели, а не технологии ИИ.

е) Интервалы изменения выбранных метрик покрывают и базовые, и потенциальные эталоны – модель ИИ в составе РЭИИ неустойчива.

7) выполняют поиск возможностей улучшения (развития) РЭИИ в части обеспечения требуемой функциональности за счет усиления модели ИИ дополнительными элементами посредством КАМО с учетом обеспечения требований к надежности (устойчивости к статистической изменчивости данных) и безопасности (устойчивости к атакам). Для этого с помощью генетического алгоритма строится композитное приложение, дополняющее модель ИИ в РЭИИ новыми алгоритмами машинного обучения, в совокупности повышающего качество модели по значениям указанных метрик. При этом в популяции моделей, построенных генетическим алгоритмом, на каждом шаге устраняются модели с неустойчивым поведением (п. (е), см. выше), для которых ширина толерантных интервалов для указанных

метрик выше заданного априори значения (определяется разработчиком (оператором) как техническое требование). Аналогично из популяции устраняются модели, которые демонстрируют неустойчивость к атакам: при внесении в данные искажений, критичных для данного класса моделей, ширина толерантных интервалов по метрикам увеличивается выше заданного разработчиком (оператором) значения.

Изобретение также осуществляется с помощью системы оценки качества цифровых РЭИИ на основе генеративных технологий и автоматического машинного обучения, которая содержит:

- по меньшей мере, один процессор;
- по меньшей мере одно устройство хранения данных, содержащее машиночитаемые инструкции, которые при их исполнении по меньшей мере одним процессором выполняют этапы:
 - интегрирование РЭИИ в контур системы оценки качества цифровых решений;
 - интегрирование РЭИИ в контур системы оценки качества цифровых решений;
 - получение исходных обучающих и тестовых наборов данных, определенных на базе задач, решаемых интегрированной РЭИИ;
 - определение метрик функциональных характеристик (МФХ) для оценки качества интегрированной РЭИИ;
 - формирование системы эталонов искусственного интеллекта (ИИ) с помощью композитного автоматического машинного обучения (КАМО) на базе полученных исходных обучающих и тестовых наборов данных, содержащую:

- эталонное значение предсказуемости, задающее верхний предел качества по функциональным характеристикам;
 - потенциальный эталон модели ИИ, определяющий максимальное практически достижимое качество путем композиции разных алгоритмов машинного обучения;
 - семейство базовых эталонов моделей ИИ, определяющих наименьшее гарантированное качество на разных классах методов машинного обучения;
- формирование синтетических наборов данных с помощью генеративных технологий, повторяющих свойства исходных обучающих и тестовых наборов данных,
 - определение значений, определенных ранее МФХ и их интервальных оценок на основе сформированных синтетических наборов данных;
 - сравнение модели ИИ, реализованной в РЭИИ, с системой эталонов ИИ по определенным ранее МФХ;
 - определение соответствия РЭИИ требованиям качества;
 - определение возможных улучшения РЭИИ в части обеспечения требуемой функциональности за счет дополнительных элементов для модели ИИ, реализованной в РЭИИ, причем дополнительные элементы реализованы посредством КАМО с учетом соответствия МФХ.

Краткое описание чертежей

Фиг. 1 представляет пример архитектуры системы оценки качества цифровых РЭИИ на основе генеративных технологий и автоматического машинного обучения.

Фиг. 2 представляет пример технической инфраструктуры системы оценки качества цифровых РЭИИ.

Фиг. 3 представляет пример интерфейса одного из вариантов реализации системы оценки качества цифровых РЭИИ, обеспечивающего сравнение метрик качества РЭИИ и потенциального эталона.

Фиг. 4 представляет пример кода, реализующего регистрацию РЭИИ в системе как внешней программной функции;

Фиг. 5 представляет пример кода, реализующего регистрацию РЭИИ в системе как программно-аппаратного комплекса

Фиг. 6 представляет пример синтеза модели машинного обучения для РЭИИ управления ветроэлектрогенератором в интерфейсе системы.

Фиг. 7 представляет пример визуального задания сценария испытаний для оценки качества РЭИИ распознавания медицинских изображений.

Фиг. 8 представляет элементы визуального конструирования испытаний с помощью low-code конструкций – узлов и ребер графа с заданными свойствами, определяющими процесс вычислений.

Фиг. 9 представляет пример реализации и использования генератора аддитивного случайного шума, как одного из вариантов реализации методом Монте-Карло.

Фиг. 10 представляет количественные результаты оценки вариативности метрик качества моделей ИИ в составе РЭИИ для данных с различным случайным шумом в интерфейсе системы.

Хотя техническое решение может иметь различные модификации и альтернативные формы, характерные признаки, показанные в качестве примера на чертежах, будут описаны подробно. Следует понимать, однако, что цель описания заключается не в ограничении технического решения конкретным его воплощением. Наоборот, целью описания является охват всех

изменений, модификаций, входящих в рамки данного технического решения, как это определено в приложенной формуле.

Описание вариантов осуществления изобретения

Объекты и признаки настоящего изобретения, способы для достижения этих объектов и признаков станут очевидными посредством отсылки к примерным вариантам осуществления. Однако настоящее изобретение не ограничивается примерными вариантами осуществления, раскрытыми ниже, оно может воплощаться в различных видах. Сущность, приведённая в описании, является ничем иным, как конкретными деталями, необходимыми для помощи специалисту в области техники в исчерпывающем понимании изобретения, и настоящее изобретение определяется в объёме приложенной формулы.

Введём ряд определений и понятий, которые будут использоваться при описании вариантов осуществления изобретения.

Автоматическое машинное обучение – класс алгоритмов, обеспечивающих автономное решение задач формирования структуры и настройки параметров алгоритмов машинного обучения на основе данных.

Композитное автоматическое машинное обучение (КАМО) – класс методов автоматического машинного обучения, которые формируют структуру модели на основе объединения (композиции) базовых алгоритмов машинного обучения в единый поток работ, описываемый в форме ациклического графа.

Генеративные технологии - система методов и средств для создания наборов цифровых объектов (включая математические модели и структуры данных) схожей природы, обладающих заданной вариативностью и общими свойствами, на основе алгоритмов статистического и имитационного моделирования, в т.ч. с использованием генеративного ИИ.

Метрики качества - материальная мера некоторых аспектов характеристик качества. Применительно к функциональным характеристикам РЭИИ в виде метрик качества рассматриваются различные характеристики точности решения задачи с помощью ИИ по сравнению с некоторой контрольной выборкой: к ним относятся собственно точность, полнота, а также комплексные показатели – F1, ROC-AUC и пр.

Испытания – экспериментальный способ оценки качества РЭИИ путем интерпретации ее реакции на наборы входных данных, в идеале покрывающие все возможные условия эксплуатации.

Суррогатная модель – математическая модель, внутренняя структура построена, исходя из принципа наилучшего (по заданным метрикам) приближения набора выходных данных по набору входных данных. Она не основана на априорных принципах, фундаментальных законах и причинно-следственных связей, и строится исключительно на основе данных.

Фиг. 1 представляет пример системы оценки качества цифровых РЭИИ на основе генеративных технологий и автоматического машинного обучения.

Система оценки качества цифровых РЭИИ, содержащая по меньшей мере один постоянный машиночитаемый носитель, включающий взаимодействующие между собой средства, содержит: вычислительный комплекс **110**, подсистему управления ресурсами **120**, подсистему управления окружением **130**, подсистему регистрации РЭИИ **140**, подсистему синтеза данных **150**, подсистему синтеза моделей **160**, репозиторий моделей **170**, подсистему организации испытаний РЭИИ **180**, визуальный редактор сценариев испытаний **190**, подсистему создания эталонов **200**, подсистему композитного машинного обучения **210**, подсистему сравнения РЭИИ **220**, подсистему расчета метрик **230**, генератор атак **240**, генератор отчетов **250**, подсистему бенчмарков **260**.

В одном из вариантов реализации системы вычислительный комплекс **110** может быть выполнен как:

- высокопроизводительный компьютер с собственной системой управления, предназначенный для реализации ресурсоемких расчетов для обучения моделей, описывающих систему эталонов ИИ, расчета метрик при проведении испытаний РЭИИ, а также поддержки функционирования системы в целом;
- облачный вычислительный ресурс в, по меньшей мере, публичном или частном облаке, используемый по модели PaaS, на котором развернута система.

Подсистема управления ресурсами **120** предназначена для обеспечения загрузки и исполнения расчетных задач, необходимых для оценки качества РЭИИ, в форме композитных приложений на вычислительных ресурсах **110**, в том случае, если РЭИИ представлено в форме цифровой модели, реализованной программно. В процессе управления система представляет расчетную задачу, описывающую процесс испытаний качества РЭИИ, в виде двудольного графа, выполняет его трансляцию в исполнимую форму, формирует план вычислений, инициирует своевременный запуск отдельных элементов графа задач (исполнимые модули – как само программное РЭИИ, так и иные процедуры, необходимые для испытаний и обработки результатов), обмен данными между ними и получение итоговых результатов. Для управления отдельными элементами графа задач в рамках плана используются механизмы контейнеров.

Также подсистема **120** управляет выполнением расчетов (передача входных данных, запуск РЭИИ, получение результата работы модели ИИ) непосредственно на самом РЭИИ, если оно представлено в форме отдельного программно-аппаратного комплекса вне подсистемы **110**. Для этого используется API РЭИИ, который вызывается как отдельная функция.

Подсистема управления окружением **130** предназначена для обеспечения координации работы иных подсистем с данными, моделями и вычислительными ресурсами в рамках расчетных сценариев, необходимых для оценки качества РЭИИ. Координация выполняется путем мониторинга состояния отдельных подсистем и генерации команд по их взаимодействию в рамках исполнения конкретного сценария. Она обеспечивает процессы обмена данными между различными подсистемами системы в целом.

Подсистема регистрации РЭИИ **140** предназначена для обеспечения процессов взаимодействия системы и РЭИИ. Она содержит набор адаптеров и интерфейсов, определяющих порядок и форматы обмена данными между системой и РЭИИ, и может быть реализована как:

1) программный интерфейс для аннотирования и регистрации РЭИИ в виде цифровой модели непосредственно в систему в форме функции на языке Python. На фиг. 4 приведен пример реализации программного интерфейса. Добавляется запись в базе данных с загруженной моделью в байтовом или архивированном виде. Запись содержит привязку к проекту и пользователю на платформе, а также же дополнительные поля, такие как описание, ссылка на документацию или название.

2) API для взаимодействия с РЭИИ в виде отдельного программно-аппаратного комплекса через общую ЛВС. На фиг. 5 приведен пример описания API для программно-аппаратного комплекса РЭИИ, используемого для решения задач умного города. В первую очередь описание API должно включать доменный адрес и порт, на который следует обращаться.

Подсистема синтеза данных **150** обеспечивает возможность генерации синтетических наборов данных с заданными свойствами на основе исходной обучающей выборки (как предоставленной разработчиком (оператором), так и извлеченной из подсистемы бенчмарков **260**). Она может быть реализована на основе использования: (а) методов Монте-Карло для одномерных и

многомерных распределений (в т.ч. на основе байесовых сетей), (б) различных вариаций метода бутстреп, (в) генеративных состязательных сетей для данных сложной структуры.

Подсистема синтеза моделей **160** обеспечивает возможность генерации набора моделей машинного обучения различной структуры на исходных или синтетических данных, свойства которых отражают неопределенность выбора структуры суррогатной модели для задачи конкретного РЭИИ. Она может быть реализована посредством механизма эволюционных вычислений на ациклических графах, описывающих структуру задачи. Для этого она использует функциональность подсистемы КАМО **210**, которая позволяет строить одну или несколько модель заданной структуры, обеспечивающих наилучшие значения метрик качества, заданных разработчиком (оператором). На фиг. 6 приведен пример синтеза модели машинного обучения для РЭИИ управления ветроэлектрогенератором в интерфейсе системы. Все блоки, выделенные желтым, представляют собой алгоритмы машинного обучения, синтезированные и добавленные в исходную модель РЭИИ с помощью КАМО.

Подсистема организации испытаний РЭИИ **180** позволяет разработчику (оператору) строить сценарий испытаний по оценке качества, для которого он задает алгоритм выполнения испытаний, метрики и критерии качества, условия успешности испытаний, см. фиг. 7, на которой приведен пример визуального задания сценария испытаний для оценки качества РЭИИ распознавания медицинских изображений.

Для этого разработчик (оператор) определяет объект(ы) испытаний (на фиг. 7 – BaseNNClassifierModel_1), используя для этого как внешние РЭИИ, так и ранее построенные модели (в т.ч. модели-бенчмарки, заимствованные из внешних источников), хранящиеся в репозитории моделей **170**. Для задания алгоритма и иных характеристик испытаний РЭИИ разработчик (оператор) применяет визуальный редактор сценариев испытаний **190**, в котором он

формирует двудольный вычислительный граф, описывающий алгоритм выполнения испытаний, посредством low-code конструкций – узлов и ребер графа с заданными свойствами, определяющими процесс вычислений. Пример приведен на фиг. 8.

Подсистема создания эталонов **200**, используя функциональность подсистемы КАМО **210**, предназначена для автоматического построения трех видов эталонов, используемых для оценки качества: эталонное значение предсказуемости, потенциальный эталон, семейство базовых эталонов. В зависимости от сценария испытаний они могут строиться как на исходном наборе данных, так и на синтетических наборах данных, формируемых подсистемой синтеза данных **150**.

Подсистема расчета метрик **230** предназначена для определения точечных и интервальных значений метрик качества, характеризующих РЭИИ, по результатам испытаний, а также определения их граничных значений на основе эталонов, получаемых посредством подсистемы создания эталонов **200**.

В отдельных вариантах реализации изобретения используется подсистема сравнения РЭИИ **220**, которая позволяет на основе метрик сравнивать несколько различных РЭИИ или сопоставлять модель ИИ конкретного РЭИИ с иными моделями ИИ (в том числе, находящимися в репозитории моделей **170**), обученными на аналогичных данных, предоставленных разработчиком (оператором), или взятыми из подсистемы бенчмарков **260**. Пример сравнения расчетных метрик модели РЭИИ распознавания медицинских изображений (ClassificationScorer_4) в сравнении с потенциальным эталоном (ClassificationScorer_3) приведен на Фиг. 3.

Генератор атак **240** предназначен для модификации наборов данных, а также создания синтетических данных, имитирующих различные эффекты, потенциально приводящие к нарушению работоспособности РЭИИ. Включает

в себя механизмы генерации шумов различной природы, а также состязательных примеров. На фиг. 9 приведен пример реализации и использования генератора аддитивного случайного шума, как одного из вариантов реализации методом Монте-Карло. На фиг. 10 приведены количественные результаты оценки вариативности метрик качества моделей для данных с различным случайным шумом. Видно, что по метрике F1 модель XGBClassifier наиболее чувствительная к зашумлению данных, что демонстрирует ее неустойчивость.

Генератор отчетов **250** предназначен для визуализации результатов оценки качества РЭИИ в виде таблиц, графиков и иных видов изображений, а также автоматического формирования протоколов и акта испытаний.

Подсистема бенчмарков **260** обеспечивает доступ к тематическим наборам данных, принятых сообществом специалистов в области ИИ в качестве основы для сравнения различных классов моделей. Например, промышленным бенчмаркам FordA, FordB, Earthquakes, Trace, ItalyPowerDemand, Waver, а также наборам данных, открытым на платформе Kaggle.

На Фиг. 2 приведен пример реализации технической инфраструктуры системы оценки качества цифровых РЭИ на базе вычислительного компьютерного устройства, которое применяется для реализации заявленного способа в составе вычислительного комплекса **110**.

В общем случае устройство содержит такие компоненты, как один или более процессоров (301), по меньшей мере одну оперативную память (302), средство постоянного хранения данных (303), интерфейсы ввода/вывода (304), средства ввода/выводу (305), средства сетевого взаимодействия (306), а также программно-аппаратный комплекс РЭИИ (307), для которого производится оценка качества.

Описанное выше изобретение может быть реализовано на текущем уровне развития техники и технологий. На Фиг. 3 приведен пример интерфейса одной из реализаций системы оценки цифровых РЭИИ. Система разработана на языке Python. Она может обеспечивать выполнение расчетов на GPU (не менее 20480 ядер GPU одновременно), обеспечивать функции динамического управления контейнерами для проектов и генерируемых результатов, обеспечивать одновременную поддержку работы не менее чем 100 пользователей.

В заключение следует отметить, что приведённые в описании сведения являются примерами, которые не ограничивают объём настоящего изобретения, определённого формулой.

Формула изобретения

1. Способ оценки качества цифровых решений с элементами искусственного интеллекта (РЭИИ), включающий в себя:

- интегрирование РЭИИ с системой оценки качества цифровых решений;
- получение исходных обучающих и тестовых наборов данных, определенных на базе задач, решаемых интегрированной РЭИИ;
- определение метрик функциональных характеристик (МФХ) для оценки качества интегрированной РЭИИ;
- формирование системы эталонов искусственного интеллекта (ИИ) с помощью композитного автоматического машинного обучения (КАМО) на базе полученных исходных обучающих и тестовых наборов данных, содержащую:
 - эталонное значение предсказуемости, задающее верхний предел качества по функциональным характеристикам;
 - потенциальный эталон модели ИИ, определяющий максимальное практически достижимое качество путем композиции разных алгоритмов машинного обучения;
 - семейство базовых эталонов моделей ИИ, определяющих наименьшее гарантированное качество на разных классах методов машинного обучения;
- формирование синтетических наборов данных с помощью генеративных технологий, повторяющих свойства исходных обучающих и тестовых наборов данных,
- определение значений определенных ранее МФХ и их интервальных оценок на основе сформированных синтетических наборов данных;
- сравнение модели ИИ, реализованной в РЭИИ, с системой эталонов ИИ по определенным ранее МФХ;

- определение соответствия РЭИИ требованиям качества;
- определение возможных улучшения РЭИИ в части обеспечения требуемой функциональности за счет дополнительных элементов для модели ИИ, реализованной в РЭИИ, причем дополнительные элементы реализованы посредством КАМО с учетом соответствия МФХ.

2. Способ по п. 1, отличающийся тем, что системы эталонов представляют собой суррогатные модели, с разной степенью детализации описывающие на основе исходных обучающих и тестовых наборов данных работу модели ИИ, реализованной в РЭИИ.

3. Способ по п. 1, отличающийся тем, что генерация синтетических наборов данных включает следующие шаги:

- выбор подхода к генерации синтетических наборов входных данных исходя из постановки задачи РЭИИ;
- обучение генеративной модели;
- генерация синтетических наборов входных данных посредством обученной генеративной модели;
- синтетические наборы входных данных поступают на вход РЭИИ, причем создаются синтетические наборы выходных данных;
- расчет МФХ по каждому синтетическому набору входных и выходных данных;
- определение толерантных интервалов, характеризующих изменчивость отдельных МФХ, причем оцениваются доверительные интервалы для характерных границ.

4. Способ по п. 1, отличающийся тем, что определение возможных улучшения РЭИИ выполняется с помощью генетического алгоритма, причем строится композитное приложение, дополняющее модель ИИ в РЭИИ новыми алгоритмами машинного обучения.

5. Система оценки качества цифровых РЭИИ, которая содержит:

- по меньшей мере, один процессор;
- по меньшей мере одно устройство хранения данных, содержащее машиночитаемые инструкции, которые при их исполнении по меньшей мере одним процессором выполняют этапы:
 - интегрирование РЭИИ с системой оценки качества цифровых решений;
 - интегрирование РЭИИ в контур системы оценки качества цифровых решений;
 - получение исходных обучающих и тестовых наборов данных, определенных на базе задач, решаемых интегрированной РЭИИ;
 - определение метрик функциональных характеристик (МФХ) для оценки качества интегрированной РЭИИ;
 - формирование системы эталонов искусственного интеллекта (ИИ) с помощью композитного автоматического машинного обучения (КАМО) на базе полученных исходных обучающих и тестовых наборов данных, содержащую:
 - эталонное значение предсказуемости, задающее верхний предел качества по функциональным характеристикам;
 - потенциальный эталон модели ИИ, определяющий максимальное практически достижимое качество путем композиции разных алгоритмов машинного обучения;
 - семейство базовых эталонов моделей ИИ, определяющих наименьшее гарантированное качество на разных классах методов машинного обучения;

- формирование синтетических наборов данных с помощью генеративных технологий, повторяющих свойства исходных обучающих и тестовых наборов данных,
- определение значений, определенных ранее МФХ и их интервальных оценок на основе сформированных синтетических наборов данных;
- сравнение модели ИИ, реализованной в РЭИИ, с системой эталонов ИИ по определенным ранее МФХ;
- определение соответствия РЭИИ требованиям качества;
- определение возможных улучшения РЭИИ в части обеспечения требуемой функциональности за счет дополнительных элементов для модели ИИ, реализованной в РЭИИ, причем дополнительные элементы реализованы посредством КАМО с учетом соответствия МФХ.

6. Система по п. 5, отличающаяся тем, что системы эталонов представляют собой суррогатные модели, с разной степенью детализации описывающие на основе исходных обучающих и тестовых наборов данных работу модели ИИ, реализованной в РЭИИ.

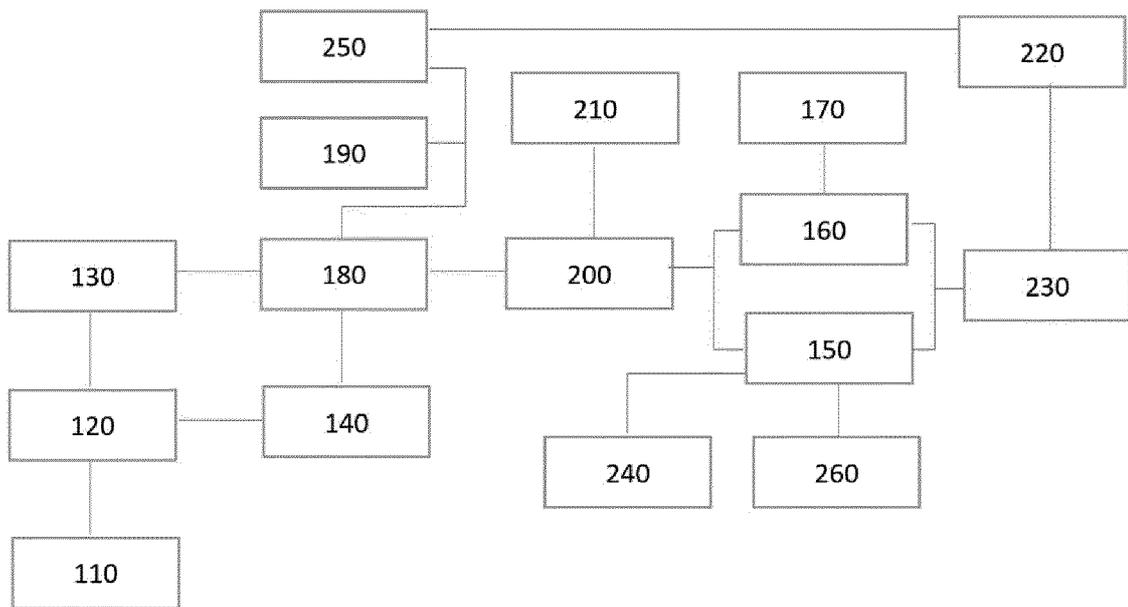
7. Система по п. 5, отличающаяся тем, что генерация синтетических наборов данных включает следующие шаги:

- выбор подхода к генерации синтетических наборов входных данных исходя из постановки задачи РЭИИ;
- обучение генеративной модели;
- генерация синтетических наборов входных данных посредством обученной генеративной модели;
- синтетические наборы входных данных поступают на вход РЭИИ, причем создаются синтетические наборы выходных данных;

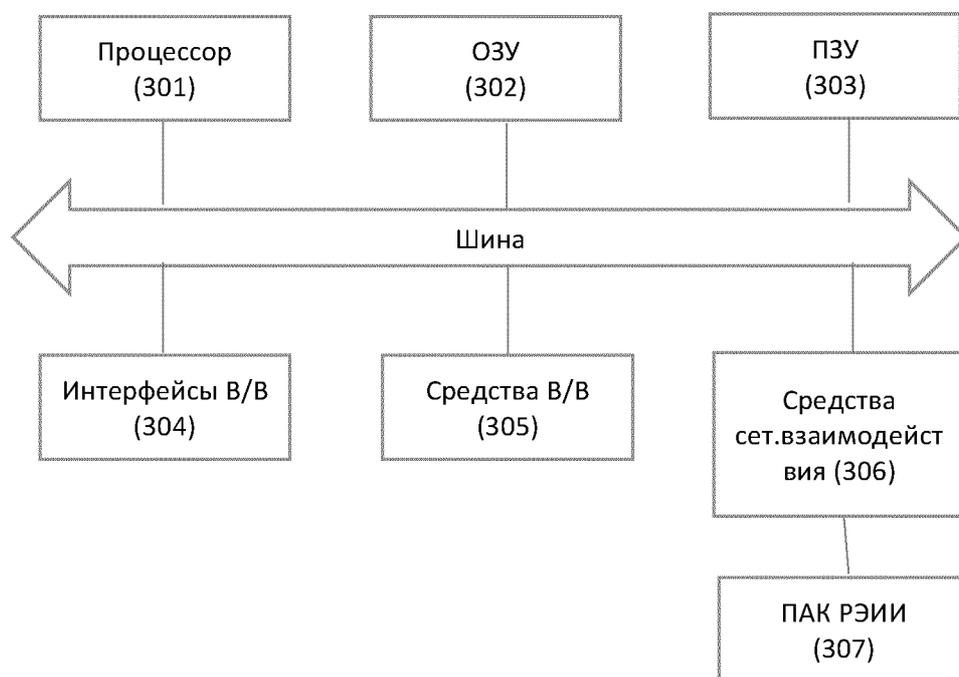
- расчет МФХ по каждому синтетическому набору входных и выходных данных;
- определение толерантных интервалов, характеризующих изменчивость отдельных МФХ, причем оцениваются доверительные интервалы для характерных границ.

8. Система по п. 5, отличающаяся тем, что определение возможных улучшения РЭИИ выполняется с помощью генетического алгоритма, причем строится композитное приложение, дополняющее модель ИИ в РЭИИ новыми алгоритмами машинного обучения.

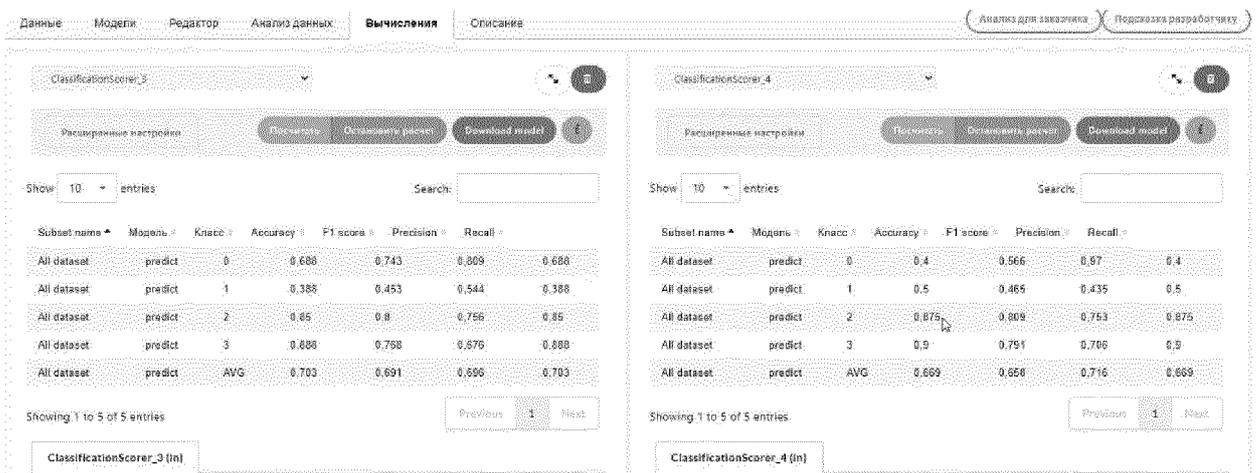
Чертежи



Фиг. 1.



Фиг. 2



Фиг. 3

```

model_name = model.__class__.__name__

file = UploadedModel.objects.create(
    project_owner=project,
    user_uploaded=user_uploaded,
    model_name=model_name,
    file=model_file,
    description=description,
    source_link=source_link,
    model_group=model_group
)

if model_class_file is not None:
    file.model_class_file = model_class_file

file.projects_accessed.add(project) # Сразу добавляем проект в
ИСПОЛЬЗОВАНИЕ

file.save()

```

Фиг. 4

Списки социальных групп, городских сервисов, районов, и т. д.:

- `/api/list/social_groups` — список (возрастных) социальных групп, имеющих ненулевые значения значимости (*significance*) с каким-либо типом сервиса и интенсивности использования (*intensity*) с какой-либо городской функцией в какой-либо жизненной ситуации. Может принимать на вход конкретные тип сервиса и/или жизненную ситуацию, чтобы возвращать только релевантные к ним социальные группы. Параметры:
 - `service_type` — тип сервиса, название, код или `id`
 - `living_situation` — жизненная ситуация, название, код или `id`.

Ключи в ответе:

- `social_groups` — список строк, названия социальных групп
- `social_groups_ids` — список `id` социальных групп в том же порядке
- `social_groups_codes` — список кодов социальных групп в том же порядке

- `/api/list/city_functions` — список городских функций, имеющих ненулевые значения значимости (*significance*) с какой-либо социальной группой и интенсивности использования (*intensity*) с какой-либо социальной группой в какой-либо жизненной ситуации. Может принимать на вход конкретные социальную группу и/или жизненную ситуацию, чтобы возвращать только релевантные к ним социальные функции. Параметры:

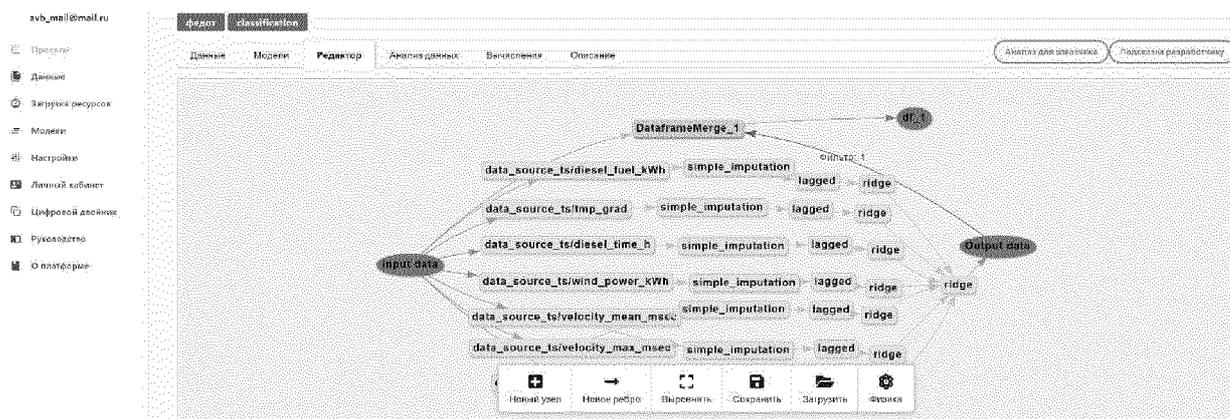
- `social_group` — социальная группа, название, код или `id`
- `living_situation` — жизненная ситуация, название, код или `id`.

Ключи в ответе:

- `city_functions` — список строк, названия городских функций
- `city_functions_ids` — список `id` городских функций в том же порядке

`city_functions_codes` — список кодов городских функций в том же порядке

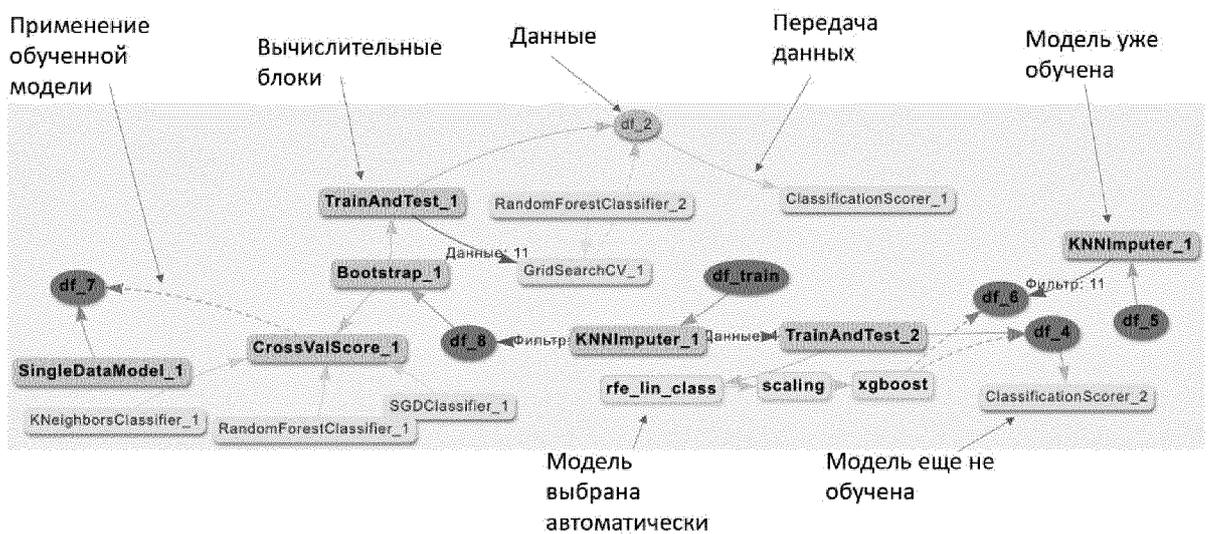
Фиг. 5



Фиг. 6

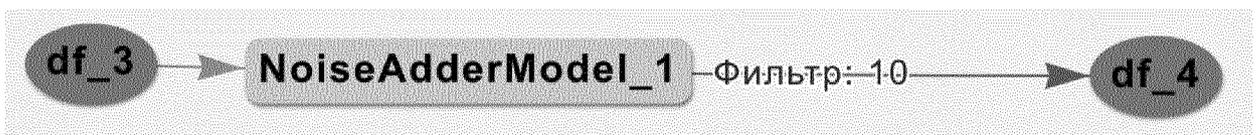


Фиг. 7

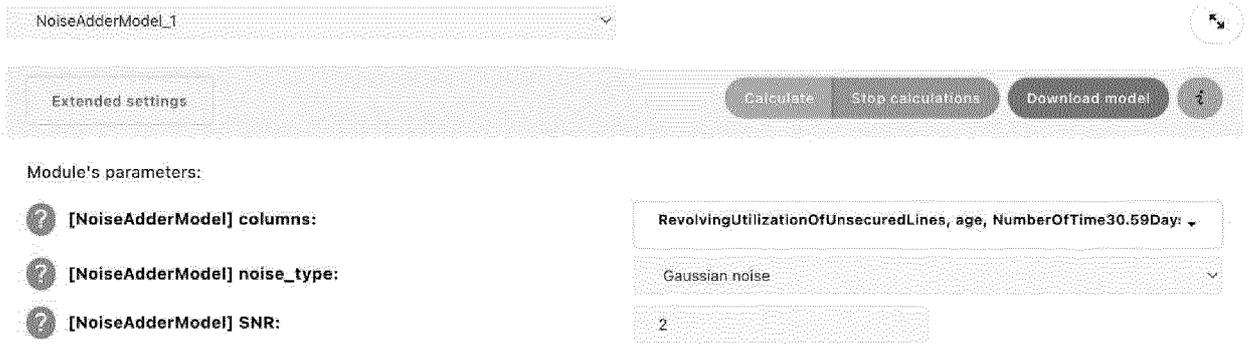


Фиг. 8

Пример вычислительного графа с узлом модели «NoiseAdderModel». Модуль принимает на вход набор данных, и возвращает измененный набор данных, к столбцам которого был добавлен шум.



Параметры модели «NoiseAdderModel»:

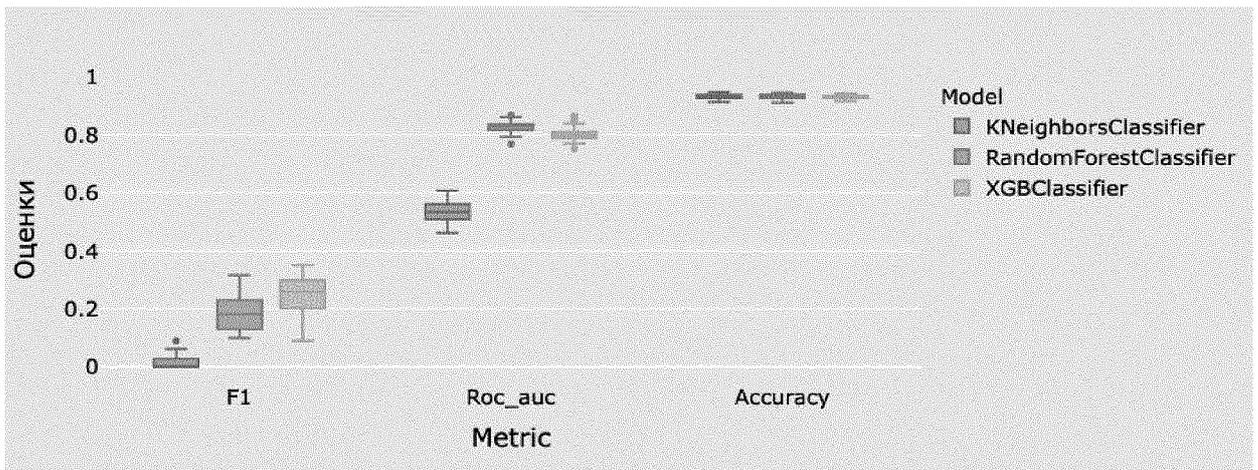


Параметр «columns» - столбцы во входящем наборе данных, в которые необходимо добавить шум.

Параметр «noise_type» - вид генерируемого шума.

Параметр «SNR» – Коэффициент, определяющий отношение сигнала к шуму «signal to noise».

Фиг. 9



Фиг 10.

ОТЧЕТ О ПАТЕНТНОМ ПОИСКЕ
(статья 15(3) ЕАПК и правило 42 Патентной инструкции к ЕАПК)

Номер евразийской заявки:

202293564

А. КЛАССИФИКАЦИЯ ПРЕДМЕТА ИЗОБРЕТЕНИЯ:

G06N 3/02 (2006.01)
G06N 20/00 (2019.01)
G06F 11/36 (2006.01)

Согласно Международной патентной классификации (МПК)

Б. ОБЛАСТЬ ПОИСКА:

Просмотренная документация (система классификации и индексы МПК)
G06N 3, G06N 20/00, G06F 11

Электронная база данных, использовавшаяся при поиске (название базы и, если, возможно, используемые поисковые термины)
Espacenet, ЕАПАТИС, Google Patents

В. ДОКУМЕНТЫ, СЧИТАЮЩИЕСЯ РЕЛЕВАНТНЫМИ

Категория*	Ссылки на документы с указанием, где это возможно, релевантных частей	Относится к пункту №
A	ZHANG J. M. и др. Machine Learning Testing: Survey, Landscapes and Horizons. IEEE Transactions on Software Engineering, том.48, №.1, с.1-36, 1 января 2022 [онлайн] [найдено 2023-05-25]. Найдено в < https://arxiv.org/abs/1906.10742 >< doi.org/10.48550/arXiv.1906.10742 >, весь документ	1-8
A	Guidelines for Quality Assurance of AI-based Products and Services. Consortium of Quality Assurance for Artificial-Intelligence-based products and services, 2 февраля 2022 [онлайн] [найдено 2023-05-25]. Найдено в < https://web.archive.org/web/20220207034641/https://www.qa4ai.jp/QA4AI.Guideline.202201.en.pdf >, весь документ	1-8
A	GAKU FUJII и др Guidelines for Quality Assurance of Machine Learning-Based Artificial Intelligence. International Journal of Software Engineering and Knowledge Engineering том.30, №.11&12 (2020), с.1589–1606, октябрь 2020 [онлайн] [найдено 2023-05-25]. Найдено в < https://www.researchgate.net/publication/346509267_Guidelines_for_Quality_Assurance_of_Machine_Learning-Based_Artificial_Intelligence ><DOI:10.1142/S0218194020400227>, весь документ	1-8

последующие документы указаны в продолжении

* Особые категории ссылочных документов:

«А» - документ, определяющий общий уровень техники
«D» - документ, приведенный в евразийской заявке
«E» - более ранний документ, но опубликованный на дату подачи евразийской заявки или после нее
«O» - документ, относящийся к устному раскрытию, экспонированию и т.д.
"P" - документ, опубликованный до даты подачи евразийской заявки, но после даты испрашиваемого приоритета"

«Т» - более поздний документ, опубликованный после даты приоритета и приведенный для понимания изобретения
«Х» - документ, имеющий наиболее близкое отношение к предмету поиска, порочащий новизну или изобретательский уровень, взятый в отдельности
«У» - документ, имеющий наиболее близкое отношение к предмету поиска, порочащий изобретательский уровень в сочетании с другими документами той же категории
«&» - документ, являющийся патентом-аналогом
«L» - документ, приведенный в других целях

Дата проведения патентного поиска: **25/05/2023**

Уполномоченное лицо:
Заместитель начальника отдела механики,
физики и электротехники



М.Н. Юсупов