

КЛАССИФИКАЦИЯ И ОПРЕДЕЛЕНИЕ РАЗМЕРОВ ПОВЕРХНОСТНЫХ ДЕФЕКТОВ ТРУБОПРОВОДОВ НА ОСНОВЕ РЕЗУЛЬТАТОВ КОМПЛЕКСНОЙ ДИАГНОСТИКИ УЛЬТРАЗВУКОВЫМ, ВИХРЕТОКОВЫМ, ВИЗУАЛЬНЫМ И ИЗМЕРИТЕЛЬНЫМ МЕТОДАМИ НЕРАЗРУШАЮЩЕГО КОНТРОЛЯ

© 2023 г. Н.В. Крысько^{1,*}, С.В. Скрынников², Н.А. Щипаков¹, Д.М. Козлов¹, А.Г. Кусый¹

¹ Федеральное государственное бюджетное образовательное учреждение высшего образования «Московский государственный технический университет имени Н.Э. Баумана (национальный исследовательский университет)», Россия 105005 Москва, Бауманская 2-я ул., 5, стр. 1

² ПАО «Газпром», Россия 117997 Москва, ул. Наметкина, 16, ГСП-7

E-mail: *kryskonv@bmstu.ru

Поступила в редакцию 19.10.2023; после доработки 30.10.2023

Принята к публикации 03.11.2023

Рассмотрены вопросы классификации и определения параметров поверхностных эксплуатационных дефектов по результатам ультразвукового, вихретокового и визуального и измерительного методов неразрушающего контроля. При этом визуальный и измерительный метод реализовался с применением камеры телевизионного контроля, оснащенной функцией компьютерного зрения, и лазерным триангуляционным датчиком. В работе представлен набор данных, содержащий 5760 изображений трубопроводов с питтинговой коррозией и без нее. Представлена сверточная нейронная сеть (СНС), которая была применена для классификации изображений, полученных с камеры телевизионного контроля на изображения без коррозии и изображения с питтинговой коррозией. В работе представлен набор данных, содержащий 269 измерений плоскостных и объемных поверхностных дефектов. Представлена модель определения размеров поверхностных дефектов, основанная на градиентном бустинге. В работе разработан алгоритм классификации и определения размеров поверхностных дефектов при комплексной диагностике, в котором применяются полученные модели, и определена точность работы данного алгоритма по метрике RMSE, которая вычислялась в рамках исследуемого тестового набора данных и составила 0,011 мм.

Ключевые слова: энергия, природные ресурсы, поверхностные дефекты, ультразвуковой контроль, вихретоковый контроль, передача энергии, промышленность и инновации, лазерное сканирование, комплексная диагностика, совместная оценка данных, машинное обучение, глубокое обучение, сверточные нейронные сети, оценка жизненного цикла.

CLASSIFICATION AND SIZING OF SURFACE DEFECTS OF PIPELINES BASED ON THE RESULTS OF COMPLEX DIAGNOSTICS BY ULTRASONIC, EDDY CURRENT AND VISUAL AND MEASURING METHODS OF NONDESTRUCTIVE TESTING

N.V. Krysko^{1,*}, S.V. Skrynnikov², N.A. Shchipakov¹, D.M. Kozlov¹, A.G. Kusyy¹

¹ Bauman Moscow State Technical University, Baumanskaya 2nd street, building 5, building 1, Moscow, 105005, Russia

² Public Joint Stock Company Gazprom, Nametkina St., 16, GSP-7, Moscow, 117997, Russia

E-mail: *kryskonv@bmstu.ru

The issues of classification and determination of parameters of surface operational defects according to the results of ultrasonic, eddy current and visual and measuring methods of nondestructive testing are considered. At the same time, the visual and measuring method was realized with the use of a television inspection camera equipped with a computer vision function and a laser triangulation sensor. The paper presents a dataset containing 5760 images of pipelines with and without pitting corrosion. A convolutional neural network (CNN) is presented, which has been applied to classify the images obtained from a TV inspection camera into images without corrosion and images with pitting corrosion. The paper presents a dataset containing 269 measurements of planar and volumetric surface defects. A model for surface defect sizing based on gradient boosting is presented. The paper develops an algorithm for classification and sizing of surface defects in complex diagnostics, in which the obtained models are applied, and determines the accuracy of this algorithm by the RMSE metric, which was calculated within the studying test data set and amounted to 0.011 mm.

Keywords: energy, natural resources, surface defects, ultrasonic inspection, eddy current inspection, energy transfer, industry and innovation, laser scanning, complex diagnostics, data fusion evaluation, machine learning, deep learning: convolutional neural networks, life cycle assessment.

DOI: 10.31857/S0130308223120084, EDN: XIMYZL

ВВЕДЕНИЕ

В настоящее время в Российской Федерации активно эксплуатируется сеть трубопроводов большой протяженности. Одними из основных эксплуатационных дефектов, которые возникают под воздействием продукта или внешней среды, являются поверхностные коррозионные повреждения, а именно стресскоррозионные трещины, которые можно отнести к плоскостным дефектам, и местная коррозия (питтинги, свищи т.д.), которые относятся к объемным дефектам [1—5]. Обеспечение длительной безопасной эксплуатации данных объектов является актуальной задачей, поэтому в настоящее время необходимо развитие технологий комплексного неразрушающего контроля (НК) несколькими методами в автоматическом режиме, с выполнением классификации и определением параметров данных дефектов.

В большинстве случаев для выявления поверхностных коррозионных повреждений используют методы визуального и измерительного, магнитного, вихретокового или ультразвукового контроля [6]. В [7, 8] были рассмотрены возможности ультразвукового контроля (УК) с применением волн Рэлея по выявлению поверхностных дефектов. В [9] была исследована модель объединения данных ультразвукового и вихретокового контроля (ВК), позволяющая выполнить классификацию поверхностных дефектов. При работе данная модель основывается только на результатах УК и ВК, что может приводить к ложной классификации, например крупная питтинговая коррозия может классифицироваться как отсутствие контакта преобразователя с объектом контроля. Для исключения подобных случаев для классификации следует добавить визуальный и измерительный контроль (ВИК), поскольку он позволяет с высокой точностью идентифицировать питтинговую коррозию. Использование традиционного ВИК для исследования всей поверхности трубы нецелесообразно из-за значительной трудоемкости. Для автоматизации этого процесса используется телевизионная камера, оснащенную моделью компьютерного зрения, которая позволяет идентифицировать питтинговую коррозию на изображениях.

В большинстве существующих работ [10—17], рассматривающих использование различных моделей для телевизионного контроля, идентификация коррозии на изображениях осуществляется по цветовым признакам наличия ржавчины. Однако ржавчина и другие изменения цвета поверхности допустимы на трубопроводах, поскольку они не снижают прочностных характеристик. Поэтому в [18] была разработана модель, которая осуществляет классификацию не на основании изменения цвета, а на основании других признаков, присущих изображению с потерей металла в виде питтинговой коррозии.

Помимо задачи классификации необходимо определять размеры выявленных дефектов. В работах [7, 8, 19—22] рассмотрены возможности определения размеров поверхностных дефектов, и несмотря на то, что по отдельности методы НК позволяют оценить глубину дефектов, оценка осуществляется с определенной погрешностью, также при больших значениях глубин дефектов, точность оценки снижается. Для повышения точности определения параметров выявленных дефектов [23] была разработана модель определения размеров дефектов по результатам комплексного анализа данных УК, ВК и ВИК.

По результатам анализа литературных данных не было обнаружено алгоритма, позволяющего по результатам комплексной диагностики УК, ВК, ВИК определять тип поверхностных эксплуатационных дефектов трубопровода, а также их параметры. Существуют только отдельные модели на основе статистических методов, машинного и глубокого обучения, решающие свои узко поставленные задачи. Поэтому создание единого алгоритма анализа данных комплексной диагностики является актуальной задачей на сегодняшний день.

МЕТОДИКА ПРОВЕДЕНИЯ ИССЛЕДОВАНИЙ

Для создания единого алгоритма анализа данных комплексной диагностики необходимо было решить две следующие задачи. Первая задача заключалась в обеспечении выявления питтинговой коррозии при ВИК трубопровода в автоматическом режиме телевизионной камерой. Вторая — в определении размеров поверхностных дефектов по результатам УК, ВК и ВИК.

Для решения первой задачи в настоящее время в большинстве случаев используются сверточные нейронные сети (СНС). СНС имеет специальную архитектуру (рис. 1), которая позволяет ей максимально эффективно распознавать образы. СНС в настоящее время активно применяются для задач обработки изображений [24—28]. Сама идея СНС основывается на чередовании сверточных и объединяющих слоев, а структура является однонаправленной. СНС получила свое название от операции свертки, которая предполагает, что каждый фрагмент изображения будет умножен на




Рис. 1. Схема базовой архитектуры сверточной нейронной сети [11].

ядро свертки поэлементно, при этом полученный результат должен суммироваться и записываться в похожую позицию выходного изображения. Такая архитектура обеспечивает инвариантность распознавания относительно сдвига объекта, постепенно укрупняя «окно», на которое «смотрит» свертка, выявляя все более и более крупные структуры и паттерны в изображении [29].

На основании ZFNet, одной из на наиболее используемых современных архитектур СНС, нами была разработана собственная модель, архитектура которой представлена в табл. 1.

Таблица 1

Архитектура разработанной СНС

№	Слой	Вход	Размер фильтра	Количество фильтров	Шаг	Выход	Количество параметров
1	Conv1	224×224×3	7×7×3	32	2	109×109×32	4736
2	Pool1	109×109×32	3×3×1	-	2	54×54×32	-
3	Conv2	54×54×32	7×7×32	128	2	24×24×128	200832
4	Pool2	24×24×128	3×3×1	-	2	11×11×128	-
5	Conv3	11×11×128	3×3×128	384	1	9×9×384	442752
6	Conv4	9×9×384	3×3×384	384	1	7×7×384	1327488
7	Conv5	7×7×384	3×3×384	128	1	5×5×128	442496
8	Pool3	5×5×128	3×3×1	-	2	2×2×128	-
9	GAP	2×2×128	-	-	-	128	-
10	FC	128	-	1	-	1	129

Одними из наиболее важных моментов при работе с СНС являются обучение и тестирование модели на подготовленном наборе данных. В нашем случае, когда объектом исследований является питтинговая коррозия, невозможно найти заранее подготовленный набор данных, который бы содержал как бездефектные изображения поверхности трубопроводов, так и изображения с питтинговой коррозией. Поэтому в процессе работы над этой задачей нами был подготовлен набор данных, состоящий из 5760 изображений (рис. 2) размером 224×224 пикселей, где 4270 фотографий — это фотографии без коррозии, а 1490 — фотографии с коррозией. В него вошли как фотографии с различных нефтегазовых объектов, полученные в процессе командировок, так




Рис. 2. Пример набора данных: изображения без коррозии (а); изображения с коррозией (б).

и фотографии из публичных банков данных, таких как <https://www.shutterstock.com> и <https://www.dreamstime.com>.

Для обучения модели СНС этот набор данных разбивался на обучающий, валидационный и тестовый наборы, содержащие 4608, 576 и 576 фотографий соответственно.

Обучение модели осуществлялось на GPU nVidia RTX 3090, батч размер составлял 64, код был разработан на языке Python 3.9 с использованием общедоступных библиотек TensorFlow (2.5.0) и OpenCV (4.5.1).

Для решения второй задачи проводилось исследование возможностей определения размеров поверхностных дефектов, которое осуществлялось на образцах (рис. 3), с изготовленными имитаторами поверхностных дефектов. Плоскостные дефекты имитировались поверхностными пазами, выполненными электроэрозионным способом, а объемные дефекты — вертикальными сверлениями.




Рис. 3. Фото образцов с поверхностными дефектами: электроэрозионными пазами (а); вертикальными сверлениями (б).

В представленных образцах были изготовлены сверления глубиной 5 мм и диаметрами 1; 1,5; 2; 2,5; 3; 3,5; 4; 4,5; 5; 7; 8,5; 10 мм; сверления диаметром 3 мм и глубинами 0,25; 0,4; 0,5; 0,75; 1,0; 1,2; 1,5; 2,0; 2,5; 3,0; 3,5; 4,0; 4,5; 5,0 мм; пазы раскрытием 0,15 мм и глубинами 0,1; 0,2; 0,3; 0,4; 0,5; 0,6; 0,7; 0,75; 1,0; 1,5; 2,0; 2,5; 3,0; 4,0 мм; пазы глубиной 0,5 мм и раскрытиями 0,15; 0,25; 0,5; 0,75; 1,0; 1,5 мм; пазы раскрытием 0,15 мм, глубиной 0,5 мм и углами наклона к поверхности образца 15; 30; 45; 60; 75; 90°.

Измерения с помощью ультразвукового контроля производились волнами Рэлея, аналогично с работами [7, 8], генерация волн осуществлялась бесконтактным электромагнитно-акустическим преобразователем с центральной частотой 1 МГц с использованием блока дефектоскопической электроники Sonaflex [30]. В процессе измерений выполнялась фиксация максимальной амплитуды эхосигнала, отраженного от дефекта, как это представлено на рис. 4.




Рис. 4. Пример сигнала при ультразвуковом контроле.




Рис. 5. Пример сигнала при вихретоковом контроле.

Вихретоковый контроль выполнялся с использованием трансформаторного дифференциального ВТП с частотным диапазоном 500 кГц—3 МГц на дефектоскопе OmniscanMX. При вихретоковом контроле регистрировалась максимальная амплитуда и фаза сигнала от дефекта, как это представлено на рис. 5.

Визуальный и измерительный контроль осуществлялся с использованием лазерного триангуляционного датчика. В результате работы этого датчика строится профиль сканируемой поверхности в виде набора координат точек. При наличии на сканируемой поверхности какого-либо дефекта на построенном профиле наблюдается локальное отклонение (рис. 6), ширину и глубину которого можно измерить.

Измерения всеми методами объединяли в один набор данных, всего было выполнено 269 измерений. Измеряемые дефекты подразделяли на два класса — плоскостные и объемные. Для плоскостных дефектов выполнялось измерение только глубины, всего для них было выполнено 149 измерений, для объемных дефектов — измерение глубины залегания и ширины раскрытия, всего для них было выполнено 120 измерений. Глубина плоскостного дефекта, глубина и ширина раскрытия объемного дефекта являются непрерывными переменными, поэтому задача определения параметров дефектов является задачей регрессии.




Рис. 6. Пример измерений лазерным триангуляционным датчиком.

В качестве модели регрессии для решения этой задачи был выбран алгоритм градиентного бустинга [31]. Градиентный бустинг использует ансамбль деревьев решений, с последовательным применением деревьев, при этом последующие деревья учатся на ошибках предыдущих. Было разработано три модели для определения параметров дефектов. Первая модель служит для определения глубины плоскостных дефектов, которая использует следующие данные: амплитуду сигналов УК и ВК и фазу ВК. Вторая — для определения глубины объемных дефектов, которая использует амплитуду сигналов УК и ВК, а также модель для определения ширины объемных дефектов, которая использует показания лазерного триангуляционного датчика и амплитуду сигнала УК. Подбор гиперпараметров моделей (табл. 2) осуществлялся автоматически случайным поиском.

Таблица 2

Гиперпараметры моделей на основе градиентного бустинга

Гиперпараметр	Плоск. Глуб.	Об. Глуб.	Об. Шир.
Количество деревьев решений	2404	915	571
Темп обучения	0,837	0,135	0,405
Максимальная глубина дерева	24	42	24
Минимальное количество выборок, для разделения узла	34	24	30
Минимальное количество образцов в листовом узле	35	9	2

Обучение и проверка работоспособности моделей осуществлялись с применением кроссвалидации, при которой проводилось 30 итераций, где все данные были разделены на 5 различных обучающих и тестовых выборок по 215 и 54 элементов соответственно.

РЕЗУЛЬТАТЫ ИССЛЕДОВАНИЙ И ИХ ОБСУЖДЕНИЕ

В рамках решения представленной выше первой задачи для анализа достоверности разработанной СНС при классификации изображений на тестовом наборе была построена матрица ошибок, представленная на рис. 7. Как видно из рис. 7, разработанная модель правильно классифицировала большинство изображений — 567 шт. При этом необходимо отметить, что этом эффективность работы СНС по точности и показателю F1 составляет 98,44 и 97,3 соответственно.



Рис. 7. Матрица ошибок классификации разработанной СНС на тестовом наборе данных.



Рис. 8. Примеры неверно предсказанных изображений без коррозии.

Ошибочно было классифицировано только 9 изображений. Ошибочная классификация может быть связана, например, с недостаточной зачисткой поверхности перед контролем и наличием на объекте контроля кусков грязи или других загрязнений. Примеры таких фотографий представлены на рис. 8.

В рамках решения второй задачи для обучения и проверки работоспособности моделей регрессии применялось 30 итераций кроссвалидации, при которой все данные, полученные при измерениях, были разделены на 5 различных обучающих и тестовых выборок, составивших 215 и 54 элемента соответственно.

Работоспособность моделей регрессии на тестовых выборках определялась по такой метрике, как корень из среднеквадратичной ошибки (RMSE), которая вычисляется по формуле:

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}, \quad (1)$$

где n — количество наблюдений, по которым строится модель и количество прогнозов; y_i — фактическое значение зависимой переменной для n -го наблюдения; $\hat{y}_i$ — значение зависимой переменной, предсказанное моделью.

При определении RMSE вычисляются квадраты разности значений фактических параметров дефекта и параметров дефекта, предсказанных моделью для всей тестовой выборки. После чего производится их суммирование и деление на общее количество элементов тестовой выборки (в данном случае оно составляло 54 элемента). В итоге из полученного значения извлекается квадратный корень. Поскольку при кроссвалидации применялось 30 итераций, а набор данных был разделен на 5 различных частей, то в качестве итогового значения RMSE оценивалось среднее арифметическое значение RMSE, полученное от 150 обученных моделей.

Среднее значение RMSE по результатам кроссвалидации моделей для глубины плоскостных дефектов составило 0,071 мм, для глубины объемных дефектов — 0,199 мм, для ширины объемных дефектов — 0,053 мм.

На основе модели классификации с использованием СНС, модели классификации с использованием теории Демпстера—Шафера [9] и наиболее оптимальных моделей определения размеров поверхностных дефектов (которые имели наилучшие значения метрик при кроссвалидации) был создан алгоритм классификации и определения размеров, который представлен на рис. 9.

Алгоритм работает следующим образом: после проведения контроля с помощью модели классификации, основанной на теории Демпстера—Шафера [9], по амплитуде ультразвукового сигнала ($A_{\text{ук}}$), амплитуде вихретокового сигнала ($A_{\text{вк}}$) и фазе вихретокового сигнала ($\Phi_{\text{вк}}$) происходит определение типа дефекта (плоскостной дефект или объемный), после чего наличие или отсутствие объемных дефектов сопоставляется с результатом работы модели на основе СНС. Далее в случае выявления плоскостного дефекта на основании работы модели градиентного бустинга для плоскостных дефектов определяется глубина плоскостного дефекта. В случае, если выявляется объемный дефект, то его глубина и ширина определяются по соответствующим моделям градиентного бустинга.

Оценка работоспособности алгоритма проводилась по RMSE, вычисленного на тестовом наборе данных, содержащего 54 элемента. При этом итоговое значение RMSE по определению пара-




Рис. 9. Алгоритм классификации и определения размеров поверхностных дефектов.

метров дефектов с помощью алгоритма на исследуемом тестовом наборе составило 0,011 мм, при этом 70 из 78 измерений (90 %) находились в пределах одного RMSE, 73 из 78 измерений (94 %) находились в пределах двух значений RMSE.

ЗАКЛЮЧЕНИЕ

Разработан алгоритм классификации и определения размеров поверхностных дефектов по результатам комплексной диагностики методами УК, ВК и ВИК. Классификация поверхностных дефектов по типам в алгоритме основана на совмещении двух классификаторов. Первый классификатор основан на теории Демпстера—Шафера. Второй классификатор основан на модели СНС, обученной на специально подготовленном наборе данных, состоящем из 5760 изображений, где 4270 фотографий — это фотографии без коррозии, а 1490 — фотографии с коррозией. Архитектура модели СНС представлена в настоящей статье. Определение размеров в алгоритме основано на трех регрессионных моделях на основе градиентного бустинга, обучение и тестирование которых осуществлялось на наборе данных, состоящем из 269 измерений, полученных по результатам контроля поверхностных плоскостных и объемных дефектов ультразвуковым, вихретоковым, визуальным и измерительным методами. Работоспособность алгоритма, оцененная по метрике RMSE в рамках исследуемого тестового набора данных, составила 0,011 мм, при этом 70 из 78 измерений (90 %) находились в пределах одного RMSE, 73 из 78 измерений (94 %) находились в пределах двух значений RMSE.

Исследование выполнено за счет гранта Российского научного фонда № 22-29-00524, <https://rscf.ru/project/22-29-00524/>.

СПИСОК ЛИТЕРАТУРЫ

1. Давыдова Д.Г. Дефекты технологических трубопроводов: типология, оценка влияния на эксплуатацию // Промбезопасность-Приуралье. 2012. № 8. С. 24—28.
2. Ерехинский Б.А., Маслаков С.В., Шустов Н.И., Митрофанов А.В., Барышев С.Н., Заряев М.Ю., Кравцов А.В., Егоров С.В. Растрескивание металла задвижек фонтанной арматуры газодобывающих скважин северных месторождений // Территория Нефтегаз. 2014. № 2. С. 31—36.

3. Сафина И.С., Каузова П.А., Гуцин Д.А. Оценка технического состояния резервуаров вертикальных стальных // ТехНадзор. 2016. № 3 (112). С. 39—42.
4. Бутусов Д.С., Егоров С.И., Завьялов А.П., Ляпичев Д.М. Коррозионное растрескивание под напряжением газопроводов / Учебное пособие. М.: Издательский центр РГУ нефти и газа имени И.М. Губкина, 2015. 80 с.
5. Калинин Н.П., Васильева М.А. Атлас дефектов сварных соединений и основного металла: учебно-методическое пособие. Томск: Изд-во Томского политехнического университета, 2006. С. 55.
6. Алешин Н.П. Физические методы неразрушающего контроля сварных соединений / Учебное пособие 2-е изд., перераб. и доп. М.: Машиностроение, 2013. 576 с.
7. Алешин Н.П., Крысько Н.В., Кусый А.Г., Скрынников С.В., Могильнер Л.Ю. Исследование выявляемости поверхностных объемных дефектов при ультразвуковом контроле с применением волн Рэлея, генерируемых электромагнитно-акустическим преобразователем // Дефектоскопия. 2021. № 5. С. 13—21.
8. Алешин Н.П., Крысько Н.В., Скрынников С.В., Кусый А.Г. Исследование выявляемости поверхностных плоскостных дефектов ультразвуковым методом с применением волн Рэлея // Дефектоскопия. 2021. № 6. С. 26—34.
9. Алешин Н.П., Скрынников С.В., Крысько Н.В., Щипаков Н.А., Кусый А.Г. Классификация поверхностных дефектов основного металла трубопроводов по результатам комплексной диагностики // Компьютерная оптика. 2023. Т. 47. № 1. С. 170—178.
10. Choi K.-Y., Kim S. Morphological analysis and classification of types of surface corrosion damage by digital image processing // Corros. Sci. 2005. V. 47. No. 1. P. 1—15.
11. Medeiros F.N., Ramalho G.L., Bento M.P., Medeiros L.C. On the evaluation of texture and color features for nondestructive corrosion detection // EURASIP. J. Appl. Signal. Process. 2010. No. 1. P. 817473.
12. Khayatazad M., De Pue L., De Waele W. Detection of corrosion on steel structures using automated image processing // Developments in the Built Environment. 2020. No. 3. P. 100022.
13. Atha D.J., Jahanshahi M.R. Evaluation of deep learning approaches based on convolutional neural networks for corrosion detection // Struct. Health. Monit. 2017. P. 1110—28.
14. Petricca L., Moss T., Figueroa G., Broen S. Corrosion detection using ai: a comparison of standard computer vision techniques and deep learning model // The Sixth International Conference on Computer Science, Engineering and Information Technology. 2016. P. 91—9.
15. Ahuja S.K., Shukla M.K., Ravulakollu K.K. Surface corrosion grade classification using convolution neural network // IJRTE. September. 2019. V. 8. Is. 3.
16. Bastiana B.T., Na J., Ranjithb S.K., Jijia C.V. Visual inspection and characterization of external corrosion in pipelines using deep neural network // NDT and E. International. 2019. 107.
17. Katsamenis I., Protopapadakis E., Doulamis A., Doulamis N., Voulodimos A. Pixel-level Corrosion Detection on Metal Constructions by Fusion of Deep Learning Semantic and Contour Segmentation. arXiv:2008.05204.
18. Krysko N.V., Schipakov N.A., Kozlov D.M., Kusyy A.G., George R. Television inspection and pitting corrosion recognition in gas pipelines using deep neural network // Construction and Building Materials — Under Review.
19. Ряховских И.В., Каверин А.А., Петухов И.Г., Липовик А.В., Селиванов А.А., Сахон А.В. Оценка размеров стресс-коррозионных дефектов при техническом диагностировании газопроводов / Научно-технический сборник: Вести газовой науки. 2020. № 2 (44). С. 1—14.
20. Шляхтенков С.П., Бехер С.А. Технология оценки глубины залегания поверхностных трещин рельсов вихретоковым методом / Политранспортные системы. XI Международная научно-техническая конференция. Новосибирск. 2020. С. 608—613.
21. Алехин С.Г., Самокрутов А.А., Шевалдыкин В.Г. Измерение глубины стресс-коррозионных трещин магистральных газопроводов / Научно-технический сборник: Вести газовой науки. 2022. № 1 (50). С. 78—83.
22. Шубочкин А.Е. Развитие и современное состояние вихретокового метода неразрушающего контроля. М.: Издательский дом «Спектр», 2014. 288 с.
23. Крысько Н.В., Скрынников С.В., Щипаков Н.А., Козлов Д.М., Кусый А.Г. Определение параметров поверхностных дефектов основного металла трубопроводов по результатам комплексной диагностики // Компьютерная оптика. В печати.
24. Golyak I.S., Kareva E.R., Fufurin I.L., Anfimov D.R., Scherbakova A.V., Nebritova A.O., Demkin P.P., Morozov A.N. Numerical methods of spectral analysis of multicomponent gas mixtures and human exhaled breath // Computer Optics. 2022. V. 46. No. 4. P. 650—658. DOI: 10.18287/2412-6179-CO-1058
25. Wang L., Liu Y., Fu L., Wang Y., Tang N. Functional Intelligence-Based Scene Recognition Scheme for MAV Environment-Adaptive Navigation // Drones. 2022. No. 6. P. 120.
26. Fufurin I., Berezhanskiy P., Golyak I., Anfimov D., Kareva E., Scherbakova A., Demkin P., Nebritova O., Morozov A. Deep Learning for Type 1 Diabetes Mellitus Diagnosis Using Infrared Quantum Cascade Laser Spectroscopy // Materials. 2022. V. 15. P. 2984.
27. Lobanova V., Slizov V., Anishchenko L. Contactless Fall Detection by Means of Multiple Bioradars and Transfer Learning // Sensors. 2022. V. 22. P. 6285.

28. *Bobkov A., Aung Kh.* Real-Time Person Identification by Video Image Based on YOLOv2 and VGG 16 Networks // Automation and Remote Control. 2022. V. 83. No. 10. P. 1567—1575.
 29. <https://center2m.ru/ai-recognition> [дата обращения 05.09.2023].
 30. SONAFLEX Multipurpose Test Electronics Unit. Source: <<https://nordinkraft.de/sonaflex/>>.
 31. *He Zhiyuan, Lin Danchen, Lau Thomas, Wu Mike.* Gradient Boosting Machine: A Survey. 2019. arXiv:1908.06951.
-