

Применение искусственного интеллекта в задачах обработки данных дистанционного мониторинга

Ю.Ю. Громов¹, И.Н. Ищук¹, В.В. Родионов¹

¹ Тамбовский государственный технический университет, ул. Советская, д.106/5, помещение 2, Тамбов, 392000, Россия

Аннотация

В данной статье представлен метод классификации разновременных многоспектральных изображений поверхности земли с использованием сверточной нейронной сети глубокого обучения U-net. Изображения видимого и инфракрасного диапазона длин волн были получены с помощью многоспектральной оптико-электронной системы беспилотного летательного аппарата и использовались для построения ортофотопланов местности. На основе полученных данных производилось обучение нейронной сети для решения задач обнаружения техногенных объектов. Метод интеллектуального распознавания объектов дистанционного мониторинга, основанный на глубоком обучении и оценках теплофизических параметров, позволяет создавать фоноцелевую обстановку с использованием генетического алгоритма. Этот алгоритм решает коэффициентную обратную задачу теплопроводности и предоставляет оценки теплофизических параметров материалов. Для обучения модели введено 18 классов объектов, которые были изучены на основе разницы в тепловом контрасте между техногенными объектами и фоном (антропогенным или природным ландшафтом). Съемка земной поверхности проводилась 6 раз в течение суток с интервалом 4 часа. Эксперимент был проведен в летний период 2021 года, в конкретные даты 4-5 августа. В задачах обнаружения и классификации техногенных объектов было обнаружено, что модель демонстрирует применимость с различной достоверностью. Проведенное исследование показывает, что в процессе работы модели были обнаружены искомые классы объектов.

Ключевые слова

Глубокое обучение, классификация, сегментация, дистанционный мониторинг, нейронная сеть, генетический алгоритм, фоноцелевая обстановка, оптико-электронные системы, теплофизические параметры.

Application of Artificial Intelligence in Remote Monitoring Data Processing Tasks

Y.Y. Gromov¹, I.N. Ishchuk¹, V.V. Rodionov¹

¹ Tambov State Technical University, 106/5 Sovetskaya str., room 2, Tambov, 392000, Russia

Abstract

This article presents a method for classifying multi-time multispectral images of the Earth's surface using the convolutional deep learning neural network U-net. Images of visible and infrared wavelengths were obtained using a multispectral optoelectronic system of an unmanned aerial vehicle and were used to construct orthophotoplanes of the terrain. Based on the data obtained, a neural network was trained to solve the problems of detecting man-made objects. The method of intelligent recognition of remote monitoring objects, based on deep learning and assessments of thermophysical parameters, allows you to create a phono-target environment using a genetic algorithm. This algorithm solves the coefficient inverse problem of thermal conductivity and provides estimates of the thermophysical parameters of materials. To train the model, 18 classes of

ГрафиКон 2023: 33-я Международная конференция по компьютерной графике и машинному зрению, 19-21 сентября 2023 г., Институт проблем управления им. В.А. Трапезникова Российской академии наук, г. Москва, Россия

EMAIL: gromovtambov@yandex.ru (Ю.Ю. Громов); boerby76@mail.ru (И.Н. Ищук); vadikrodionow@yandex.ru (В.В. Родионов)

ORCID: 0000-0003-3313-2731 (Ю.Ю. Громов); 0000-0002-8140-3746 (И.Н. Ищук); 0009-0004-6327-8082 (В.В. Родионов)



© 2023 Copyright for this paper by its authors.

Use permitted under Creative Commons License Attribution 4.0 International (CC BY 4.0).

objects were introduced, which were studied based on the difference in thermal contrast between man-made objects and the background (anthropogenic or natural landscape). The survey of the earth's surface was carried out 6 times during the day with an interval of 4 hours. The experiment was conducted in the summer of 2021, on specific dates of August 4-5. In the tasks of detecting and classifying man-made objects, it was found that the model demonstrates applicability with varying reliability. The conducted research shows that during the operation of the model, the desired classes of objects were discovered.

Keywords

Deep learning, classification, segmentation, remote monitoring neural network, genetic algorithm, phono-target environment, optoelectronic systems, thermophysical parameters.

1. Введение

Задача обнаружения техногенных объектов методом сегментации разновременных многоспектральных изображений (СРМИ) поверхности земли в ходе проведения дистанционного мониторинга является одной из таких задач, которую раньше было невозможно или нецелесообразно выполнять с помощью летательных аппаратов. Беспилотные летательные аппараты (БПЛА) активно применяются в различных сферах жизнедеятельности и позволяют сделать качественную работу при достижении различных целей, особенно при дистанционном мониторинге [1]. Кроме того, непрерывное совершенствование оптико-электронных средств (ОЭС), систем радиосвязи, а также технологий в сфере производства БПЛА позволило выполнить ряд задач, решение которых было ранее невозможно [2].

Современный уровень развития робототехники и микроэлектроники позволил повысить точность взаимного позиционирования объектов контроля, источников инфракрасного (ИК) излучения и тепловизионных приборов в процессе дистанционного мониторинга. Этот метод исследований нашел широкое применение при техническом диагностировании в дефектоскопии и медицине. В последние годы было проведено множество научных исследований, посвященных этой теме [3].

Использование БПЛА и размещенных на них ОЭС значительно расширило возможности метода СРМИ. Дистанционные измерения с применением БПЛА позволяют проводить исследования, направленные на вскрытие заглубленных объектов и поиск неоднородностей в фоноцелевой обстановке. Но такое интенсивное использование БПЛА требует совершенствования наземных систем обработки данных воздушной съемки. Основные задачи таких систем включают построение карт местности, выявление состояния земной поверхности, анализ изменений, предупреждение и устранение последствий негативных процессов, а также поиск техногенных объектов на поверхности земли с использованием информации из различных спектральных диапазонов.

Применение БПЛА с ОЭС высокого разрешения вызвало необходимость модернизации существующих алгоритмов сбора и обработки информации в комплексах средств автоматизации обработки данных воздушной съемки. При анализе информации, полученной в видимом и ИК диапазонах длин волн, осуществляют поиск объектов путем выявления тепловых контрастов [4]. Такие системы ограничены временными параметрами съемки, погодными условиями и другими внешними факторами. Различные методы обзора поверхности по данным, полученным при однократной фотосъемке, сканерной съемке, радарной съемке, не всегда успешно решают задачу обнаружения [5].

2. Постановка задачи

Существует ряд недостатков у поисковых систем, связанных с разницей в тепловом контрасте между техногенными объектами и фоном. Основным критерием является различие в тепловом контрасте, который меняется со временем из-за периодического теплообмена между объектом и окружающей средой [6].

Изображение, полученное с тепловизионного приемника в ночное время, менее контрастное, что затрудняет процесс поиска объектов на нем. Кроме того, при обработке данных

аэрофотосъемки отбрасывается большая часть ИК изображений, и выбираются только самые контрастные или информативные изображения. Остальные ИК изображения не участвуют в поиске объектов.

Для повышения эффективности поиска объектов на БПЛА, большинство тепловизионных приемников, которые используются, имеют возможность автоматической регулировки яркостно-контрастных характеристик изображения. Если в объектив тепловизора попадает объект или явление с чрезвычайно высокой температурой, то все объекты на изображении, расположенные рядом, будут либо "засвечены", либо иметь более низкие характеристики, необходимые для дешифрирования. Поэтому возникает необходимость выделения детерминированных параметров объектов для успешного поиска, включая их теплофизические свойства, особенно теплопроводность и теплоемкость [7].

Решение данной задачи будет возможно с использованием нейронных сетей глубокого обучения и применением метода СРМИ с реализацией алгоритмов распознавания объектов по новому дешифровочному признаку.

3. Решение задачи обнаружения объектов по их теплофизическим свойствам

Для реализации метода СРМИ и проведения натурального летного эксперимента, был использован БПЛА мультироторного типа с ОЭС, способной выполнять дистанционный мониторинг земной поверхности в различных диапазонах длин волн. Летный эксперимент продолжался двое суток, в течение которых производилась съемка земной поверхности шесть раз с интервалом в 4 часа, начиная с 6.00 и заканчивая в 24.00. Маршрут полета был задан с определенными параметрами: длина маршрута составляла 9,5 км, время полета занимало 47 минут, количество поворотных пунктов маршрута составляло 51 штук. В ходе одного пролета в одном спектральном диапазоне было получено 895 аэрофотоснимков, а общая площадь поверхности, подвергающейся дистанционному мониторингу, составляла 11,4 гектара (рисунок 1).

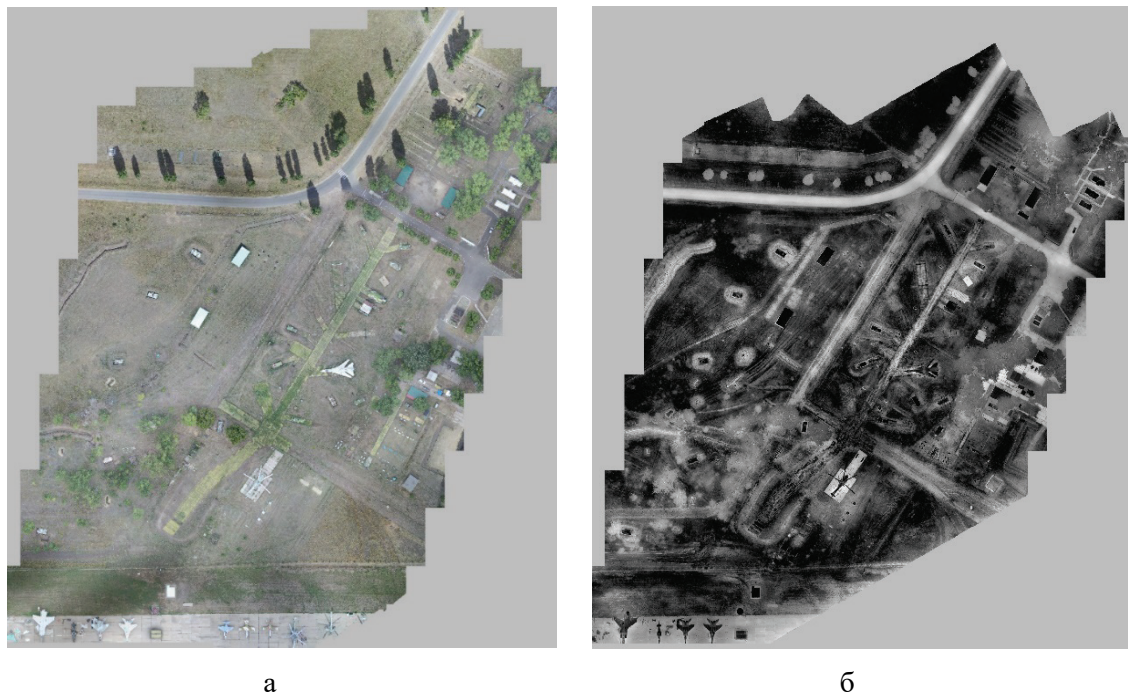


Рисунок 1 – Маршрут полета БПЛА

В результате автоматизированной сшивки видимых и инфракрасных изображений (рисунок 2) сформирован кубоид изображений с приведенным пространственным разрешением 7 см в пикселе:

$$X(x_1, x_2, x_3; x_4 \dots x_9; x_{10}), \quad (1)$$

где x_1, x_2, x_3 – слои RGB видимого изображения; $x_4 - x_9$ – слои ИК изображений; x_{10} – слой маски.



а – видимый диапазон; б – ИК-диапазон.

Рисунок 2 – Результат автоматизированной сшивки изображений

Формирование кубоида изображений обеспечивает сегментацию техногенных объектов, таких как представленные на рисунке 3, методом СРМИ на основе применения сверточной нейронной сети (СНС) глубокого обучения U-net.



а – техногенный объект; б – ложный техногенный объект.

Рисунок 3 – Техногенные объекты, размещенные на полигоне

Отличительной особенностью архитектуры сверточной нейронной сети U-Net является ее способность выполнять семантическую сегментацию изображений. Но как именно это происходит? Весь процесс начинается с преобразования изображения в векторы, которые затем используются для классификации пикселей. После этого, эти векторы снова преобразуются обратно в изображение для сегментации 18 классифицированных областей. Однако, чтобы достичь такой точности и эффективности, U-Net использует свою уникальную архитектуру (рисунок 4). Она состоит из последовательности слоев свертки и пулинга (подвыборки). Эти слои сначала уменьшают пространственное разрешение изображения, а затем увеличивают его,

пропуская через другие слои свертки. В конце концов, сеть выполняет роль своеобразного фильтра, который способен точно выделить и классифицировать различные области на изображении.

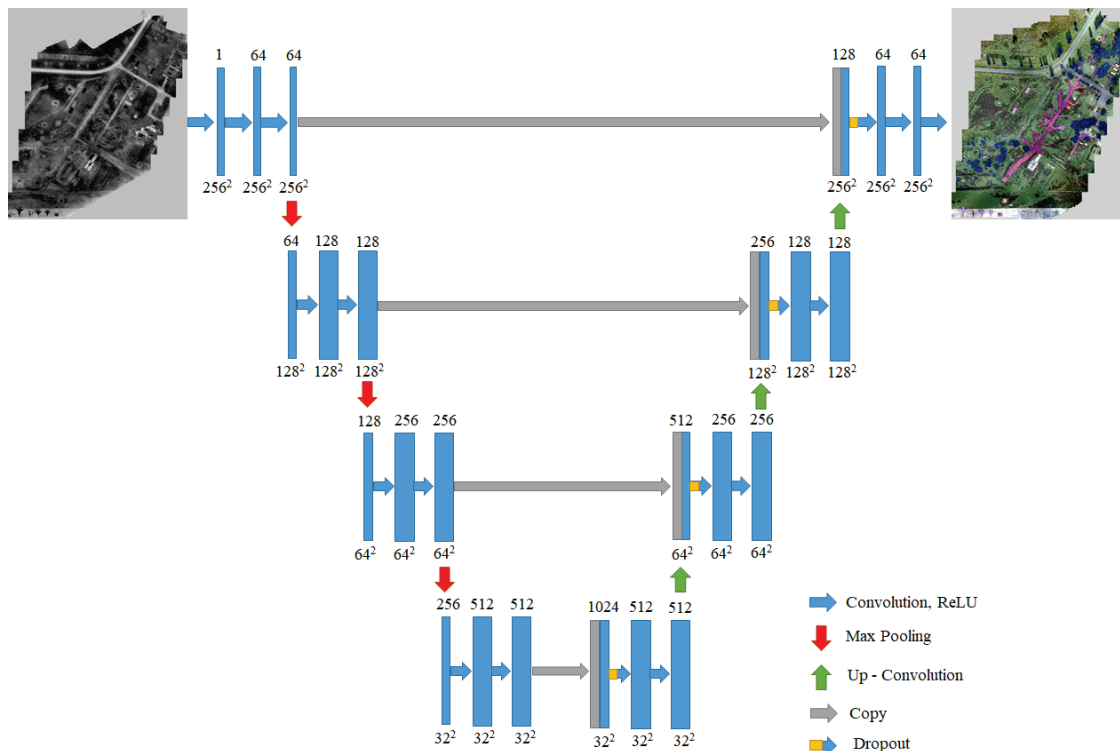


Рисунок 4 – Схема СНС U-net

Для успешного обучения нейронной сети используется метод, включающий в себя подачу на вход 9 изображений: три слоя видимого спектра и шесть слоев ИК-диапазона, а также изображение с метками, указывающими на принадлежность к определенному классу. Важно отметить, что эти метки вводятся вручную и на данный момент имеется 18 разных классов. Пример размеченного изображения можно увидеть на рисунке 5.

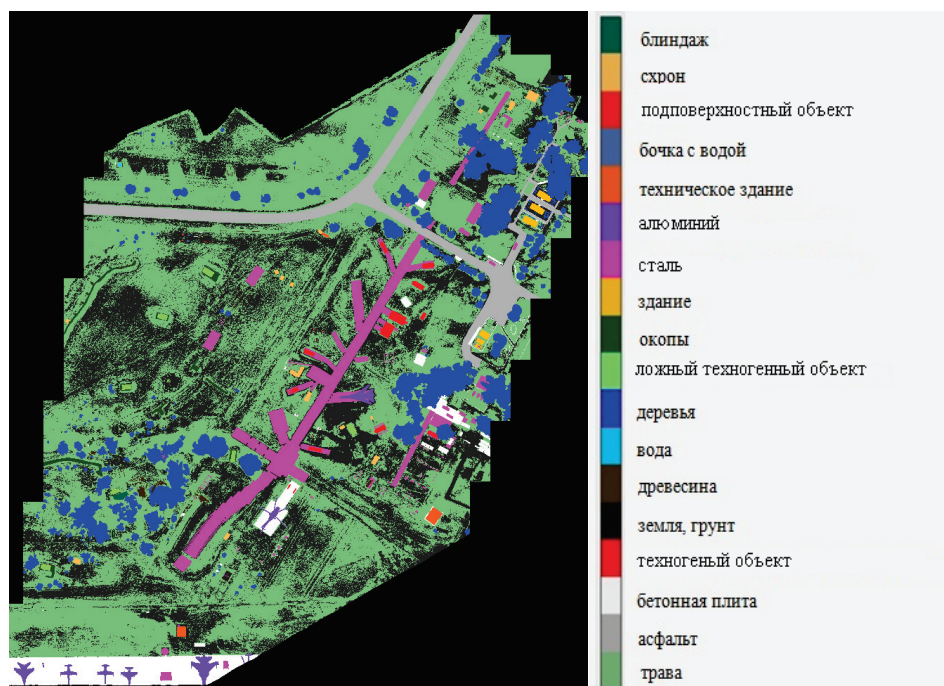



Рисунок 5 – Изображение, используемое для обучения нейронной сети

Такой подход к обучению нейронной сети позволяет значительно улучшить ее результаты и точность классификации. Задействуя информацию, полученную из различных спектров, обеспечивается более полное и точное представление о расположенных на данном участке местности объектах. Благодаря такому подходу, нейронная сеть становится способной обучаться и улучшаться с каждым новым примером. Она может находить общие закономерности и особенности в изображениях, что позволяет применять ее во многих областях, где требуется анализ и распознавание изображений.

Обучение СНС — это процесс, который включает в себя использование тренировочной выборки и валидационной выборки [8]. Важно отметить, что тренировочная выборка используется для обучения модели, а валидационная выборка - для проверки ее эффективности и точности. В результате сегментации изображений с помощью СНС были выделены 18 классов (бинарных изображений). По данным обучающей и валидационной выборок, на основе методов цифровой обработки полученных бинарных изображений, распознаны отдельные объекты, некоторые из которых представлены на рисунке 6.



а – класс «асфальт»; б – класс «сталь».

Рисунок 6 – Результат распознавания объектов по обучающей выборке, полученной 04.08.2021г.

Результаты распознавания объектов сравнивали с использованием коэффициента Танимото. Коэффициент Танимото представляет собой меру сходства, которая способна измерить степень подобия двух множеств. Существует несколько вариаций расчета коэффициента Танимото, в основе которых заложен принцип, построенный на отношении пересечения множеств к их объединению, который определяется по формуле [9]:

$$k = \frac{c}{a + b - c}, \quad (2)$$

где k – коэффициент Танимото, принимающий значение от 0 до 1 (чем ближе значение к 1, тем больше сходство между множествами), a – количество элементов первого множества, b – количество элементов второго множества, c – количество элементов, принадлежащих обоим множествам одновременно.

Значения коэффициента Танимото представлены в таблице 1, а на рисунке 7 отражена гистограмма значений подобия распознанных объектов на основе критерия Танимото.

Таблица 1 – Значения коэффициента Танимото, полученные по результатам обработки данных обучающей и валидационной выборок

Параметры классификатора	Дата проведения полетов (04.08.2021г.)	Дата проведения полетов (05.08.2021г.)	Коэффициент Танимото
			Отношение площадей объектов
Класс «Трава»			
Количество объектов	295	233	0,78
Площадь объектов в пикселях	5416446	7893139	0,68
Класс «Асфальт»			
Количество объектов	18	15	0,83
Площадь объектов в пикселях	1501886	1546628	0,97
Класс «Бетонная плита»			
Количество объектов	48	35	0,72
Площадь объектов в пикселях	1034819	983078	0,95
Класс «Техногенный объект»			
Количество объектов	16	17	0,83
Площадь объектов в пикселях	96629	109856	0,87
Класс «Земля, грунт»			
Количество объектов	500	463	0,92
Площадь объектов в пикселях	9524594	8857872	0,93
Класс «Древесина»			
Количество объектов	15	17	0,6
Площадь объектов в пикселях	33987	42778	0,79
Класс «Деревья»			
Количество объектов	132	142	0,92
Площадь объектов в пикселях	3466129	3408898	0,98
Класс «Ложный техногенный объект»			
Количество объектов	12	11	0,53
Площадь объектов в пикселях	43955	53010	0,82
Класс «Окопы»			
Количество объектов	29	31	0,62
Площадь объектов в пикселях	128145	154440	0,82
Класс «Здание»			
Количество объектов	8	6	0,75
Площадь объектов в пикселях	35528	56654	0,62
Класс «Сталь»			
Количество объектов	55	57	0,83
Площадь объектов в пикселях	1739284	1725971	0,99

Продолжение таблицы 1

Класс «Алюминий»			
Количество объектов	23	20	0,59
Площадь объектов в пикселях	211359	213806	0,98
Класс «Техническое здание»			
Количество объектов	4	2	0,5
Площадь объектов в пикселях	36357	35516	0,97
Класс «Схрон»			
Количество объектов	1	15	0,06
Площадь объектов в пикселях	687	37124	0,018




Рисунок 7 – Величина коэффициента Танимото по классам объектов

4. Заключение

Нейронные сети являются одной из самых перспективных областей исследования в настоящее время. Их применение находит широкое применение в различных областях науки и техники, исключая необходимость ручного вмешательства и упрощая работу человека. Основной целью эксперимента было изучение возможной применимости модели для достоверного обнаружения и распознавания объектов методом сегментации разновременных многоспектральных изображений поверхности земли. В конечном итоге, мы провели обучение универсальной сети глубокого обучения U-net, которая широко применяется в задачах распознавания объектов, опираясь на классификацию материалов.

Выходные данные распознавания объектов анализировали с использованием коэффициента Танимото, который представляет собой меру сходства двух множеств и позволяет оценить их степень подобия. Этот метод не только позволяет сравнивать результаты распознавания объектов, но и выявлять как объекты ландшафта, так и техногенные объекты с высокой достоверностью. Благодаря этому, возможно обнаружение даже ложных и скрытых объектов. Таким образом, настоящий метод представляет собой мощный инструмент для сегментации и обнаружения разнообразных объектов на многоспектральных данных, полученных с ОЭС БПЛА.

5. СПИСОК ИСТОЧНИКОВ

- [1] Nishara A., Richards S., Breen D., Robertson J., Breen B. Thermal infrared imaging of geothermal environments and by an unmanned aerial vehicle (UAV): A case study of the Wairakei e Tauhara geothermal field, Taupo, New Zealand. *Renewable Energy* 86. 2016. p.1256–1264.
- [2] Shih-Hong Chio, Cheng-Horng Lin. Preliminary Study of UAS Equipped with Thermal Camera for Volcanic Geothermal Monitoring in Taiwan. *Sensors*, 17. 2017. p. 1-17.
- [3] Вавилов В.П. Тепловой неразрушающий контроль материалов и изделий // *Дефектоскопия*. 2017. № 10. С. 34-57.
- [4] Чулков А.О., Вавилов В.П., Нестерук Д.А. Автоматизированный практический алгоритм идентификации дефектов в процедурах активного теплового контроля // *Дефектоскопия*. 2018. №4. С. 49-53.
- [5] Сутырина Н.Е. Дистанционное зондирование земли: учеб. пособие / Е. Н. Сутырина. – Иркутск.: ИГУ, 2013. 38-50 с.
- [6] Thanh N. T., Sahli H. and Hao D.N. Finite-difference methods and validity of a thermal model for landmine detection with soil property estimation // *IEEE Transactions on geoscience and remote sensing*. 2007. № 3. p. 656-674.
- [7] Ищук И.Н., Фесенко А.И., Громов Ю.Ю. Идентификация свойств скрытых подповерхностных объектов в инфракрасном диапазоне волн. Монография. М.: Машиностроение. 2008. С. 184.
- [8] Ronneberger O., Fischer P., Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation [Электронный ресурс] // *Medical Image Computing and Computer-Assisted Intervention*, New York: Springer. Cham. 2015. №. 9351. [Электронный ресурс]. URL: <https://arxiv.org/abs/1505.04597> (дата обращения: 04.04.2023).
- [9] Umar M. Z., Vavilov V. P., Abdullah H., Ariffin A. K. Detecting low-energy impact damages in carbon-carbon composites by ultrasonic infrared thermography, *Russian Journal of Nondestructive Testing*, Vol. 53, Issue 7, - 2017, p. 530–538.