

Khairullina Lilia Emitovna – Kazan Federal University; e-mail: lxayrullina@yandex.ru; Kazan, Russia; phone: +79272464003; the Department of Information Systems; cand. of phys. and math. sc.; associate professor.

Khakimov Zulfat Niyazovich – e-mail: znkhakimov@stud.kpfu.ru; graduate student.

Khabibullina Guzel Zabirovna – e-mail: hg21980@rambler.ru; phone: +79274057021; the Department of Relativity and Gravity; cand. of ped. sc.; associate professor.

УДК 004.8

DOI 10.18522/2311-3103-2024-4-144-151

М.Д. Трегубенко

АНАЛИЗ МЕТОДОВ КОМПЬЮТЕРНОГО ЗРЕНИЯ ДЛЯ РАСПОЗНАВАНИЯ ДЕФЕКТОВ СОЛНЕЧНЫХ ПАНЕЛЕЙ (ОБЗОР)

В современном мире, где экологические проблемы становятся всё более актуальными, поиск альтернативных источников энергии становится приоритетной задачей. Одним из наиболее перспективных направлений является солнечная энергетика. Солнечная энергия является возобновляемым источником энергии, что делает её привлекательной для использования в различных областях, включая производство электроэнергии, отопление и охлаждение зданий, а также транспорт. Развитие солнечной энергетики может способствовать решению ряда экологических проблем, таких как загрязнение окружающей среды и изменение климата. Однако, оборудование для солнечных панелей подвержено различным типам дефектов и загрязнений. Неисправности могут негативно влиять на производительность и эффективность солнечных панелей, поэтому их обнаружение является критически важным для повышения надёжности и долговечности фотоэлектрических систем генерации энергии. Эффективный поиск дефектов позволяет минимизировать потери энергии, повысить надёжность системы и срок службы оборудования, а также снизить затраты на обслуживание. Кроме того, повышение производительности электрического оборудования способствует устойчивому развитию альтернативной энергетики, что позволяет уменьшить зависимость от традиционных источников энергии и снизить выбросы парниковых газов. Статья представляет собой обзор существующих методов обнаружения различных дефектов солнечных панелей с помощью методов компьютерного зрения и глубокого обучения. Для поиска неисправностей можно использовать изображения, полученные с помощью инфракрасной термографии (ИК), электролюминесцентной (ЭЛ) визуализации, либо в видимом спектре. Данная работа включает в себя анализ преимуществ и недостатков существующих методов поиска дефектов и загрязнений солнечных панелей, обсуждение факторов, влияющих на их эффективность, и представляет выводы по возможным дальнейшим исследованиям в данной сфере.

Компьютерное зрение; глубокое обучение; солнечные панели; нейронные сети детекция.

M.D. Tregubenko

ANALYSIS OF COMPUTER VISION METHODS FOR RECOGNISING SOLAR PANEL DEFECTS (REVIEW)

In today's world, where environmental problems are becoming more and more urgent, the search for alternative energy sources is becoming a priority. One of the most promising areas is solar energy. Solar energy is a renewable energy source, which makes it attractive for use in various areas, including power generation, heating and cooling of buildings, and transport. The development of solar energy can contribute to solving a number of environmental problems such as pollution and climate change. However, solar panel equipment is subject to various types of defects and contamination. Defects can adversely affect the performance and efficiency of solar panels, so their detection is critical to improve the reliability and durability of photovoltaic power generation systems. Effective fault finding can minimise energy losses, improve system reliability and equipment life, and reduce maintenance costs. In addition, improved performance of electrical equipment contributes to the sustainable development of alternative energy, thus reducing dependence on conventional energy sources and reducing greenhouse gas emissions. The paper presents an overview of existing methods for detecting various solar panel faults using computer vision

and deep learning techniques. Infrared thermography (IR), electroluminescence (EL) imaging, or visible spectrum imaging can be used to find the faults. This paper includes an analysis of the advantages and disadvantages of existing methods for finding defects and contamination in solar panels, discusses the factors affecting their performance, and presents conclusions for possible future research in this area.

Computer vision; deep learning; solar panels; neural networks; detection.

Введение. В современном мире, где экологические проблемы становятся всё более актуальными, поиск альтернативных источников энергии становится приоритетной задачей. Одним из наиболее перспективных направлений является солнечная энергетика, которая обладает рядом преимуществ перед традиционными источниками энергии. Солнечная энергия является возобновляемым источником, который не требует дополнительных затрат на топливо и не создаёт отходов. Кроме того, солнечные панели могут быть установлены практически в любом месте, что делает их особенно привлекательными для использования в отдалённых районах. Различные статистические результаты подтверждают значимость солнечной энергии и подключённых к сети солнечных батарей во всем мире. Несмотря на все преимущества, солнечная энергетика также сталкивается с рядом проблем, которые необходимо решить для её дальнейшего развития. Энергоэффективность солнечных элементов часто ограничивается возникающими дефектами, которые могут снизить их производительность и срок службы. Дефекты могут рассеивать энергию, создавая новые пути рекомбинации (потери), позволяя свету генерировать тепло, а не электричество, или даже потреблять энергию, хранящуюся в аккумуляторе, снижая эффективность фотоэлектрического модуля.

Одной из основных проблем, возникающих при использовании солнечных панелей, является их низкая стабильность, на которую могут влиять как внутренние, так и внешние факторы, включая намокание, тепловой стресс или влажные условия, приводящие к химическим и структурным изменениям [1]. В конечном итоге это может привести к увеличению стоимости и ограниченному сроку службы. Поэтому очень важно определить набор подходов к обнаружению дефектов для предиктивного обслуживания и мониторинга состояния фотоэлектрических модулей.

В статье [2] авторы подробно анализируют методы, которые выполняют поиск дефектов с помощью изображений, полученных с помощью инфракрасной термографии, электролюминесцентной визуализации. Однако к ним необходимо добавить методы, которые выполняют поиск дефектов солнечных панелей в изображениях, полученных в видимом спектре. По ним можно хорошо детектировать различные загрязнения и внешние факторы, которые могут понижать производительность панелей: пыль, ветки, вода, выделения птиц и т.д.

В данной статье рассматриваются и анализируются различные методы анализа данных для обнаружения дефектов солнечных панелей на основе компьютерного зрения.

Методы инфракрасного спектра. Анализ дефектов с помощью инфракрасного спектра считается одним из широко используемых неинвазивных методов, при котором излучение, испускаемое поверхностью любого тела, обрабатывается в инфракрасном диапазоне длин волн между 1,4 и 15 мкм. В этом методе используются тепловизоры, которые обычно способны измерять длины волн в среднем инфракрасном диапазоне 7-14 мкм. Для сбора данных требуются только инфракрасные (ИК) камеры без привлечения другого оборудования или прерывания работы фотоэлектрической системы [3].

В случае исправного фотоэлектрического модуля полученное распределение температуры на тепловом изображении является однородным по поверхности модуля. Дефекты солнечной панели, оказывающие значительное влияние на его тепловое поведение, можно обнаружить, наблюдая колебания температуры, приводящие к неоднородности тепловых распределений. Тепловые колебания возникают из-за тепла, выделяемого при облучении, или фотонов, которые не преобразуются в электроэнергию. Следовательно, накопление тепла повышает температуру, что приводит к появлению дефектов на полученных изображениях, которые могут характеризоваться повышенным последовательным сопротивлением, отключенным, зашунтированными ячейками или другими факто-

рами, влияющими на тепловое распределение. Например, дефекты, появляющиеся на тепловом изображении, могут быть отключенными модулями, распознаваемыми по более горячим участкам, затенением, распознаваемым по горячим точкам, и трещинами в ячейках, распознаваемыми по удлинённому нагреву ячеек [4]. Таким образом, инфракрасная термография является эффективным методом диагностики фотоэлектрических систем, позволяющим обнаруживать и локализовать дефекты без необходимости прерывания работы системы или использования дополнительного оборудования.

Классический алгоритм анализа тепловой энергии на основе обработки тепловых изображений предложен Курукуру и др. [5] на основе обнаружения краев Канни и преобразования Хофа. Сначала к изображению применялось извлечение признаков, которые проходили через алгоритм классификации для локализации и идентификации типа дефекта. Для получения карты краев сначала применялась фильтрация шума с помощью фильтра Гаусса, а затем вычислялся градиент интенсивности. Пиксели, не вносящие вклад в формирование края, удалялись с помощью не максимального подавления с последующим пороговым вычислением гистерезиса для определения градиента пикселя. Для разделения панелей линии на изображении определялись с помощью преобразования Хофа. Точность тестирования составила 93,1%.

Оливейра и др. [6] представили обзор воздушной инфракрасной томографии для автоматической инспекции фотоэлектрических станций, обобщив алгоритмы цифровой обработки изображений и алгоритм на основе глубокого обучения. В обзоре рассматривались три основных аспекта процедуры автоматического анализа изображений в ИК спектре: оптимизация траектории полета, ортофотомозаика солнечной станции и обнаружение загрязнений. Данный метод показал с точность до 90% при обнаружении и классификации неисправностей в 10 различных типах аномалий.

Также для анализа ИК изображений используются различные традиционные и более совершенные алгоритмы машинного обучения. В работе Али и др. [7] для обнаружения и классификации "горячих точек" использовалась модель машины опорных векторов (SVM). Для обучения SVM-модели был предложен гибридный вектор признаков, состоящий из RGB изображений, текстуры, гистограммы ориентированного градиента (HOG) и локального бинарного паттерна. Предварительная обработка состояла из преобразования изображения в одноканальное, выравнивания гистограммы и фильтрации шума (с помощью фильтра Габора). Гибридное извлечение признаков применялось перед обучением SVM. Модель SVM достигла точности тестирования 92 % и превзошла другие традиционные алгоритмы машинного обучения, которые анализировались в данной статье: квадратичным дискриминантным анализом, наивным Байесом, К-ближайших соседей и Бэггинг Ансамбль при более высокой эффективности вычисления и хранения данных.

Хайдари и др. [8] модифицировали архитектуру VGG16 для применения на солнечных станциях, в основном рассматривая три класса: исправные, горячие точки и подстроки. Набор данных был собран с помощью беспилотного летательного аппарата (БПЛА) и ручных портативных ИК-камер. Всего вручную было промаркировано 1116 тепловых изображений, из которых большинство относится к классу исправных. В данном исследовании гиперпараметры оригинальной сети VGG16, состоящей из 13 сверточных нейронных сетей (CNN) в 5 блоках [9], были изменены, что позволило достичь общей точности 98 %.

На температуру могут влиять несколько окружающих факторов, приводящих к неверным отклонениям в температурных измерениях, включая изменения излучательной способности (т.е. способности тел излучать инфракрасную энергию), отражения, угол обзора (поскольку ИК-камера может давать различные температуры в зависимости от угла обзора), неисправности камеры (по вине оператора или из-за ограничений ИК-камеры), а также помехи окружающей среды (например, ветер, солнечный свет и влажность). Кроме того, ложная идентификация неисправностей может происходить из-за помех от других теплоизлучающих тел [10].

Не смотря на высокие оценки точности некоторых моделей, они приспособлены только для одной задачи, являются недостаточно гибкими для поиска нескольких типов неисправностей и могут быть доработаны более современными алгоритмами глубокого обучения для улучшения обобщающей способности.

Методы электролюминесцентного спектра. В солнечных панелях падающая солнечная энергия преобразуется в электричество при определенном диапазоне коэффициента преобразования (КП). Энергетический КП солнечного элемента определяется как соотношение между максимальной электрической мощностью, которая может быть передана нагрузке, и мощностью падающего на устройство излучения. Электролюминесцентная (ЭЛ) визуализация - это метод, при котором дефекты поверхности модуля проверяются путем исследования областей фотоэлектрического модуля с изменяющимся КП, в которых область с низким КП может указывать на наличие дефектов. В системе формирования ЭЛ-изображений внешний источник питания постоянного тока подключается к фотоэлектрическому модулю в затемненном помещении для пропускания электрического тока и проявления фотоэмиссии возбужденного фотоэлектрического модуля с помощью инфракрасной чувствительной камеры. На полученном ЭЛ-изображении более яркая люминесценция наблюдается в областях с высоким уровнем КП, в то время как неактивные области или области с низким уровнем светового излучения указывают на дефекты, проявляющиеся в виде темных областей [11].

В работе [12] авторы представили систему обнаружения дефектов на основе глубокого обучения с использованием генеративно-состязательных сетей (GAN). Сначала система генерирует набор данных изображений высокого разрешения, используя небольшое количество существующих изображений. После этого на сгенерированном наборе данных обучается классификатор CNN для извлечения признаков. Утверждается, что такой подход позволяет повысить надежность классификации с точностью 83 %, при этом система тестировалась в сравнении с такими распространенными моделями, как MobileNet, Inception V3, VGG16 и ResNet50.

Дейч и др. [13] разработали комбинацию классического SVM и нейросетевой CNN в рамках контролируемой классификации для обнаружения дефектов солнечных элементов. Оба подхода различались по необходимой аппаратной эффективности: SVM обеспечил точность около 82% при низких вычислительных требованиях, в то время как CNN достиг более высокой точности около 88%. В ходе исследования также был получен набор данных, включающий около 2600 аннотированных изображений солнечных элементов ЭЛ. Для обучения CNN было использовано трансферное обучение путем адаптации архитектуры VGG19, первоначально обученной на наборе данных ImageNet, к набору данных ЭЛ.

Чен и др. [14] разработали быструю систему диагностики дефектов для обнаружения нескольких типов дефектов. Для обучения системы используется мультиалгоритмический классификатор электролюминесцентных изображений. Набор данных PVLP, включающий около 2,4 млн изображений фотоэлементов, был обучен на моделях Random Forest, ResNet и YOLO. Текущие результаты показывают, что точность классификации составляет 84 %, а время вывода не превышает 0,5 с.

Работа Фиорези и др. [15] представляет собой пример комбинированного использования обработки изображений и глубокого обучения для диагностики дефектов солнечных панелей. Была предложена модель, позволяющая различать четыре типа дефектов в мультикристаллических и монокристаллических ячейках. Используя комбинацию Deeplabv3 и ResNet-50, модель была обучена на более чем 17 000 изображениях. По результатам тестирования точность составила около 95%. Стоит отметить, что некоторые изображения в процессе обучения были сгенерированы для уменьшения дисбаланса классов.

Таким образом стоит отметить, что имеются определенные методы решения задачи обнаружения дефектов в изображениях электролюминесцентного спектра, однако стоит отметить индивидуальный подход каждого предложенного метода к определенному набору данных.

Методы видимого спектра. В естественных условиях солнечные панели сталкиваются с проблемой осадков (воды, снега) и загрязнением поверхности пылью, выделениями птиц, листьями и т.п. Необходима регулярная очистка солнечных панелей от пыли и грязи, требующая затрат рабочей силы и ресурсов. Если пренебрегать очисткой, то налипание грязи может повредить поверхность панели, сократив срок ее службы, скопление пыли на инверторе или соединительных проводах может привести к перегреву, короткому замыканию или выходу из строя оборудования, что влияет на стабильность работы и безопасность всей системы. Для автоматизации процесса уборки используют камеры, закрепленные на беспилотных летательных аппаратах, которые снимают панели в видимом спектре и фиксируют загрязнение, которое потом передается операторы системы [16].

Фан и др. [17] предложили новый метод оценки степени накопления пыли на панелях на основе алгоритма улучшения изображения. Они использовали модель атмосферного рассеяния для анализа характеристик изображений чистых и покрытых пылью фотоэлектрических панелей и установили связь между коэффициентами модели и уровнем запыленности. Авторы проверили применимость и точность модели с помощью экспериментов при различных условиях облучения в помещении и на улице. Результаты показали, что модель может оценить уровень пыли на фотоэлектрических панелях с точностью 83,78%.

Чжоу и др. [18] разработали метод автоматической сегментации и классификации загрязненных солнечных панелей на основе изображений видимого спектра, полученных с помощью беспилотников. Метод использовал гибкую пороговую схему сегментации, которая сочетала в себе цветовое пространство серого и S-компоненту. Он также интегрировал текстуру и пиксельные характеристики электрических панелей для автоматического обнаружения загрязнения. На этапе автоматической классификации было оценено несколько нейронных сетей с использованием трансферного обучения. В процессе классификации точность составила 86,8%.

Оним и др. [19] представили новый набор данных изображений солнечных панелей в чистых и пыльных условиях. Авторы предлагают новую архитектуру CNN под названием SOLNET, которая может достичь точности 98,2% при определении уровня пыли на солнечных панелях. Авторы хотят в будущем расширить категории в наборе данных, чтобы включить различные степени и типы скопления пыли, а также собрать более разнообразный датасет с различными условиями окружающей среды. В будущем SolNet можно будет точно настроить, оптимизировав гиперпараметры и структуру сети. Также авторы хотят в будущем добавить возможность тонкой настройки архитектуры.

Йдрисси и др. [20] анализируют влияние пыли на солнечные системы с помощью исследовательской платформы GER. Они предлагают систему обнаружения пыли, которая сочетает в себе метод классификации с помощью сверточной нейронной сети и алгоритма обработки изображений. Авторы используют передовой метод глубокого обучения для классификации различных степеней запыленности и достигают точности 96%, демонстрируя потенциал применения глубокого обучения в области солнечной энергетики. Они также используют GPS-координаты для записи местоположения каждого измерения, чтобы составить карту распределения пыли на солнечной станции.

Стоит отметить, что существующие методы анализа концентрируются в основном на пыли и исключают множество других факторов и типы загрязнений.

Сравнение результатов работы различных методов и подходов. Для возможности сравнения и унификации различных методов была взята классическая метрика точности (accuracy):

$$Accuracy = \frac{TP + FP}{(TP + FP + TN + FN)}. \quad (1)$$

Плюсы и минусы изображений различного спектра представлены в табл. 1.

Таблица 1

Сравнение изображений различного спектра

Вид спектра	Преимущества	Недостатки
Инфракрасный	Масштабируемость. Эффективное обнаружение горячих точек и перепадов температур.	Дорогой. Внешние факторы (например, колебания излучательной способности, отражения) могут влиять на точность. Надежность зависит от солнечного света.
Электrolюминесцентный	Локализация дефектов в солнечных элементах. Обнаружение дефектов внутри солнечных элементов.	Сложность масштабирования. Ограничено оптической деградацией (например, расслоение или разрушение стекла).
Видимый	Дешевизна. Масштабируемость. Обнаружение загрязнений.	Зависимость от внешних факторов (облачности, солнечного света) Плохо обнаруживает внутренние дефекты панели

Сводная таблица всех рассматриваемых в данной работе методов представлена в табл. 2:

Таблица 2

Сводная таблица рассматриваемых методов

№	Авторы работы	Спектр изображения	Архитектура алгоритма	Точность, %
1	Курукуру и др. [5]	ИК	Преобразование Хофа + фильтр Гаусса	93
2	Оливейра и др. [6]	ИК	CNN	90
3	Али и др. [7]	ИК	SVM + HOG	92
4	Хайдари и др. [8]	ИК	VGG16	98
5	Танг и др. [12]	ЭЛ	CNN + GAN	83
6	Дейч и др. [13]	ЭЛ	SVM + CNN	88
7	Чен и др. [14]	ЭЛ	Random Forest, ResNet, YOLO	84
8	Фиорези и др. [15]	ЭЛ	Deeplabv3 + ResNet-50	95
9	Фан и др. [17]	Видимый	Модель атмосферного рассеяния	83
10	Чжоу и др. [18]	Видимый	Цветовое пространство серого + S-компонента	86
11	Оним и др. [19]	Видимый	CNN (SOLNET)	98
12	Йдрисси и др. [20]	Видимый	CNN + GPS	96

Выводы. В статье представлен обзор исследовательской литературы по методам анализа данных и поиска дефектов и загрязнений в солнечных панелях. Анализ позволил сделать следующие выводы:

1. Различные виды спектров изображений хороши для поиска различных дефектов, каждый имеет свои плюсы и минусы.

2. Представлены различные методы анализа дефектов и загрязнений солнечных панелей. Результаты некоторых методов показывают большую точность, однако это наблюдается для узконаправленной задачи и небольшого набора данных, что в значительной степени понижает обобщающую способность алгоритма.

3. В исследованиях используются классические архитектуры, которые прошли проверку временем. Новаторские архитектуры не используются.

4. Представленные алгоритмы работают в одном спектре. Анализа изображений в различных спектрах в рамках одного алгоритма не проводятся.

5. Таким образом, проблема исследованных алгоритмов состоит в том, что существующие решения работают в одном спектре, заточены под конкретный набор данных, что ослабляет обобщающую способность, и не используют свежие архитектурные решения, которые могут увеличить значения качественных метрик.

6. Для решения данной проблемы необходимо проведение дальнейших исследований в направлении внедрения новых нейросетевых архитектур, увеличения универсальности и масштабируемости алгоритмов путем объединения и расширения существующих наборов данных и создания модели, которая работает с изображениями из нескольких каналов.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Bouich A. Study and characterization of hybrid perovskites and copper-indium-gallium selenide thin films for tandem solar cells: Diss. – Universitat Politècnica de València, 2021.
2. Hijjawi U. et al. A review of automated solar photovoltaic defect detection systems: Approaches, challenges, and future orientations, *Solar Energy*, 2023, Vol. 266, pp. 112186.
3. Tsanakas J. A. et al. Fault diagnosis and classification of large-scale photovoltaic plants through aerial orthophoto thermal mapping, *Proceedings of the 31st European Photovoltaic Solar Energy Conference and Exhibition*, 2015, Vol. 2015, pp. 1783-1788.
4. Tsanakas J.A., Ha L., Buerhop C. Faults and infrared thermographic diagnosis in operating c-Si photovoltaic modules: A review of research and future challenges, *Renewable and sustainable energy reviews*, 2016, Vol. 62, pp. 695-709.
5. Kurukuru V.S.B., Haque A., Khan M.A. Fault classification for photovoltaic modules using thermography and image processing, *2019 IEEE Industry Applications Society Annual Meeting*. IEEE, 2019, pp. 1-6.
6. de Oliveira A.K.V., Aghaei M., Rüther R. Automatic inspection of photovoltaic power plants using aerial infrared thermography: a review, *Energies*, 2022, Vol. 15, No. 6, pp. 2055.
7. Ali M.U. et al. A machine learning framework to identify the hotspot in photovoltaic module using infrared thermography // *Solar Energy*, 2020, Vol. 208, pp. 643-651.
8. Haidari P. et al. Deep learning-based model for fault classification in solar modules using infrared images // *Sustainable Energy Technologies and Assessments*, 2022, Vol. 52, pp. 102110.
9. Gopalakrishnan K. et al. Deep convolutional neural networks with transfer learning for computer vision-based data-driven pavement distress detection, *Construction and building materials*, 2017, Vol. 157, pp. 322-330.
10. Herraiz A.H., Marugán A.P., Márquez F.P.G. A review on condition monitoring system for solar plants based on thermography, *Non-destructive testing and condition monitoring techniques for renewable energy industrial assets*, 2020, pp. 103-118.
11. Tsai D.M., Wu S.C., Li W.C. Defect detection of solar cells in electroluminescence images using Fourier image reconstruction, *Solar Energy Materials and Solar Cells*, 2012, Vol. 99, pp. 250-262.
12. Tang W. et al. Deep learning based automatic defect identification of photovoltaic module using electroluminescence images, *Solar Energy*, 2020, Vol. 201, pp. 453-460.
13. Deitsch S. et al. Automatic classification of defective photovoltaic module cells in electroluminescence images, *Solar Energy*, 2019, Vol. 185, pp. 455-468.
14. Chen X., Karin T., Jain A. Automated defect identification in electroluminescence images of solar modules, *Solar Energy*, 2022, Vol. 242, pp. 20-29.
15. Fioresi J. et al. Automated defect detection and localization in photovoltaic cells using semantic segmentation of electroluminescence images, *IEEE Journal of Photovoltaics*, 2021, Vol. 12, No. 1, pp. 53-61.
16. Yang C. et al. A Survey of Photovoltaic Panel Overlay and Fault Detection Methods, *Energies*, 2024, Vol. 17, No. 4, pp. 837.

17. *Fan S. et al.* A novel image enhancement algorithm to determine the dust level on photovoltaic (PV) panels, *Renewable energy*, 2022, Vol. 201, pp. 172-180.
18. *Zhou Y.J., Sun H.R.* Water photovoltaic plant contaminant identification using visible light images, *Sustainable Energy Technologies and Assessments*, 2022, Vol. 53, pp. 102476.
19. *Onim M.S.H. et al.* SolNet: a convolutional neural network for detecting dust on solar panels, *Energies*, 2022, Vol. 16, No. 1, pp. 155.
20. *El Ydrissi M. et al.* Dust InSMS: Intelligent soiling measurement system for dust detection on solar mirrors using computer vision methods, *Expert Systems with Applications*, 2023, Vol. 211, pp. 118646.

Статью рекомендовал к опубликованию к.т.н., доцент С.А. Кучеров.

Трегубенко Максим Дмитриевич – Южный федеральный университет; e-mail: mtregubenko@sfedu.ru; г. Таганрог, Россия; тел.: +79185244987; кафедра ИАСБ.

Tregubenko Maxim Dmitrievich – Southern Federal University; e-mail: mtregubenko@sfedu.ru; Taganrog, Russia; phone: +79185244987; the Department of IASB.