

УДК 004.045

DOI: 10.18413/2518-1092-2025-10-2-0-8

**Криницин П.Г.
Ченцов С.В.**

**ДИАГНОСТИКА КОНВЕЙЕРНОГО ОБОРУДОВАНИЯ
С ПРИМЕНЕНИЕМ НЕЙРОСЕТЕВЫХ АЛГОРИТМОВ**

Сибирский федеральный университет,
ул. Академика Киренского, 26 к.1, г. Красноярск, 660074, Россия

e-mail: alfa_reklama@mail.ru, schentsov@sfu-kras.ru

Аннотация

В условиях повсеместного внедрения интеллектуальных систем мониторинга и диагностики, компьютерное зрение становится одним из передовых инструментов, позволяющим эффективно решать задачи оптимизации обслуживания и повышения надежности промышленного оборудования. В данной статье рассматриваются основные методы и подходы использования компьютерного зрения для оценки технического состояния конвейерного оборудования, анализируются преимущества и недостатки существующих систем диагностики, а также предлагаются возможные направления для проведения дальнейших исследований.

От работоспособности ленточных конвейеров зависит функционирование всего производственного процесса. Транспортёры обеспечивают непрерывность подачи сырья на очередной производственный участок, тем самым перемещая сырьё на следующие этапы обработки или склад готовой продукции. Большая часть транспортерного оборудования в металлургической промышленности представлена конвейерами с резиновой транспортерной лентой. Срок службы ленты конвейера в среднем составляет один-два года. Ходимость ленты зависит от времени реагирования ремонтной службы на развитие повреждения ее поверхности. Учитывая высокую частоту отказов конвейерного оборудования для транспортировки и переработки нефтяного кокса, повышение надёжности транспортерной ленты — приоритетная и особо актуальная задача на производстве.

Рассматриваемые в статье методы, основанные на алгоритмах компьютерного зрения, решают задачи классификации, детекции и сегментации различных дефектов транспортерной ленты.

Ключевые слова: компьютерное зрение; диагностика; нейросетевые алгоритмы; детекция; классификация; сегментация; конвейер; транспортерная лента

Для цитирования: Криницин П.Г., Ченцов С.В. Диагностика конвейерного оборудования с применением нейросетевых алгоритмов // Научный результат. Информационные технологии. – Т. 10, №2, 2025. – С. 84-92. DOI: 10.18413/2518-1092-2025-10-2-0-8

**Krinitsin P.G.
Chentsov S.V.**

**DIAGNOSIS OF CONVEYOR EQUIPMENT USING NEURAL
NETWORK ALGORITHMS**

Siberian Federal University,
26 building 1 Akademika Kirenskogo St., Krasnoyarsk, 660074, Russia

e-mail: alfa_reklama@mail.ru, schentsov@sfu-kras.ru

Abstract

In the context of the widespread implementation of intelligent monitoring and diagnostic systems, computer vision becomes one of the leading tools, enabling effective solutions for optimizing maintenance and enhancing the reliability of industrial equipment. This article explores the main methods and approaches for using computer vision to assess the technical condition of conveyor equipment, analyzes the advantages and disadvantages of existing diagnostic systems, and suggests possible directions for further research.

The operation of belt conveyors determines the functioning of the entire production process. Conveyors ensure the continuous supply of raw materials to the next production stage, thus moving materials to subsequent processing stages or the finished product warehouse. Most conveyor equipment in the metallurgy industry features conveyors with rubber belts. The average lifespan of

a conveyor belt is one to two years. The durability of the belt depends on the response time of the maintenance team to emerging surface damage. Considering the high failure rate of conveyor equipment for the transportation and processing of petroleum coke, enhancing the reliability of the conveyor belt is a priority and especially pertinent task in production.

The methods discussed in the article, based on computer vision algorithms, address the challenges of classification, detection, and segmentation of various conveyor belt defects.

Keywords: computer vision; diagnostics; neural network algorithms; detection; classification; segmentation; conveyor; conveyor belt

For citation: Krinitsin P.G., Chentsov S.V. Diagnosis of conveyor equipment using neural network algorithms // Research result. Information technologies. – Т.10, №2, 2025. – P. 84-92. DOI: 10.18413/2518-1092-2025-10-2-0-8

ВВЕДЕНИЕ

Конвейерные системы являются неотъемлемой частью современных производственных процессов, обеспечивая непрерывность и способность производственной системы адаптироваться к изменениям в спросе на продукцию, увеличивая или уменьшая объемы выпуска, при сохранении эффективности и экономической целесообразности масштабируемость производства [1]. Для поддержания высокой эффективности работы оборудования необходимо обеспечить своевременное выявление и устранение неисправностей. Традиционные методы диагностики часто требуют остановки производства и участия специалистов, что снижает общую производительность технологического процесса. Как следствие, растет интерес к внедрению автоматизированных систем на основе технологии компьютерного зрения, которые способны непрерывно мониторить состояние оборудования и детектировать аномалии в реальном времени [2, 3]. Известны разработки моделей для классификации материалов на конвейерной ленте [4], идентификации посторонних предметов на ней [5]. Основные проблемы, возникающие при эксплуатации конвейеров с резиновой транспортной лентой:

- 1) износ ленты — со временем лента истирается о транспортируемые материалы, что приводит к образованию сквозного износа и деформациям;
- 2) разрывы ленты в результате воздействия на нее посторонних не дробимых предметов, механически повреждающих ленту, в результате чего образуются сквозные дефекты [6];
- 3) нарушения целостности поверхностного — резинового слоя ленты в результате воздействия экстремальных температур, связанного с транспортировкой недостаточно охлажденного сырья, например нефтяного кокса после прокалочной печи и холодильного барабана с образованием трещин рабочей поверхности.

В последнее время проблема сокращения срока службы оборудования становится все более актуальной, что связано с тенденцией к увеличению производительности, нарушением проектных рекомендаций. Фракционный и химический состав сырья тоже оказывают свое влияние на деструктивные процессы повреждения ленты. При перемещении «сырого» нефтяного кокса в зимний период времени на транспортную ленту воздействуют химические реагенты, которые предназначены для снижения смерзания сырья в вагонах и облегчения его разгрузки [7]. Применение специализированной маслостойкой транспортной ленты, положительно сказывается на ходимости ленты, но постепенно её рабочая поверхность размягчается, теряет эластичные свойства и деформируется. Наличие большого разнообразия факторов, влияющих на срок службы ленты не позволяет установить нормативный срок ее эксплуатации для всего конвейерного парка: он сильно варьируется для аналогичного оборудования даже в пределах одного цеха.

Классическая структура диагностики оборудования промышленного предприятия представлена специалистами сервисной службы, выполняющими по установленному графику визуальную диагностику технического состояния лент конвейеров в процессе эксплуатации. Но у этой процедуры имеются недостатки. Во время осмотра лента обычно находится под слоем материала, а при большом количестве оборудования невозможно одновременно остановить все транспортировочные системы. Проблема человеческого фактора тоже имеет большое значение:

каждый пропущенный специалистом дефект может остановить конвейер и всю производственную линию, что приведёт к крайне негативным последствиям [8].

Повреждения ленты и вызванные ими остановки конвейеров могут быть различными с точки зрения их влияния на весь технологический процесс предприятия: в одном случае они требуют немедленного устранения, в другом позволяют запланировать и выполнить ремонт в прогнозируемые сроки. Поэтому важно использовать дифференцированный подход к обслуживанию оборудования, который учитывает особенности эксплуатации и степень влияния конкретного конвейера на производственный цикл. В статье рассмотрено решение проблемы отказов с помощью внедрения автоматизированной системы диагностики ленты в процесс эксплуатации конвейеров. Ожидается, что такая система будет лишена вышеуказанных недостатков классической диагностики, что позволит значительно повысить точность и оперативность обнаружения дефектов, обеспечив стабильную и безопасную работу производственных линий.

КЛАССИФИКАТОР ТЕХНИЧЕСКОГО СОСТОЯНИЯ ЛЕНТЫ

Классификация изображений — это задача, связанная с автоматическим присвоением метки или категории изображению на основе его содержимого [9]. Изображение, представленное в виде матрицы пикселей, обрабатывается алгоритмом машинного обучения, который определяет, к какой из заранее определённых классов оно принадлежит. С целью создания обучающего набора данных с образцами дефектов транспортерных лент произведена обработка видеопотока с камеры со скоростью записи 250 кадров в секунду. Полученные изображения были классифицированы в зависимости от доминирующего дефекта на ленте. Если на ленте были разрывы и трещины, то изображению присваивался класс «Разрыв ленты» — как наиболее важный с точки зрения дальнейшей безотказной работы оборудования.

Для повышения универсальности в работе модели, выполнена аугментация изображений на обучающей выборке, рисунок 1 [10].

С целью реализации алгоритма классификации импортирована из пакета Torchvision библиотеки PyTorch [11] предварительно обученная модель ResNet-18. Операция двумерной свертки заключается в суммировании признаков по всем трем каналам: C, H, W:

$$y[m, n] = \sum_{k=1}^C \sum_{i=1}^H \sum_{j=1}^W x_k[m + i, n + j] * w_k[i, j] + b; \quad (1)$$

где $y[m, n]$ – выходное значение тензора в позиции (m, n),

x_k – k-й канал входного тензора с точкой $[m + i, n + j]$,

w_k – элемент фильтра, применяемого к k-му каналу с координатами $[i, j]$,

b – смещение (константа).

С целью исключения изменения предварительно обученных весов и не выполнения операций повторного вычисления градиентов слоев модели ResNet замораживаются все слои модели с заменой полносвязного слоя новым — с четырьмя целевыми, выходными классами.

В качестве функции потерь используется CrossEntropyLoss() для мультиклассовой классификации и оптимизатор Adam. После обучения модели-классификатора на 20 эпохах, получено значение ошибки Loss — 7%.




Рис. 1. Результаты выполненной аугментации изображений
Fig. 1. Results of image augmentation

Для тестирования обученной модели загружены изображения из тренировочной выборки. Результат предсказания модели – классификатора представлен на рисунке 2.



Рис. 2. Результат работы модели - «Лента с поврежденным краем»
Fig. 2. Model output - "Belt with damaged edge"

Классификатор можно использовать для определения наличия или отсутствия дефектов на ленте, с целью дальнейшего принятия решения о необходимости визуальной диагностики оборудования с привлечением специалистов сервисной организации. Такой алгоритм работы целесообразно применять для диагностирования большей части конвейерного оборудования, т.к. он прост в реализации и успешно решает задачи контроля его исправного состояния.

ДЕТЕКТОР ДЕФЕКТОВ ТРАНСПОРТЕРНОЙ ЛЕНТЫ

Детекция объектов – это задача компьютерного зрения, направленная на идентификацию и локализацию объектов разных классов на изображении. В отличие от задачи классификации изображений, которая определяет только класс объекта, обнаружение объектов также определяет его местоположение на изображении, выделяя границы или ограничивающие рамки вокруг него [12]. Чтобы обучить модель-детектор, был набор изображений с дефектами транспортной ленты был предварительно размечен в программе CVAT [13]. Классы распознаваемых дефектов — трещины, порывы ленты, состояние стыка ленты.

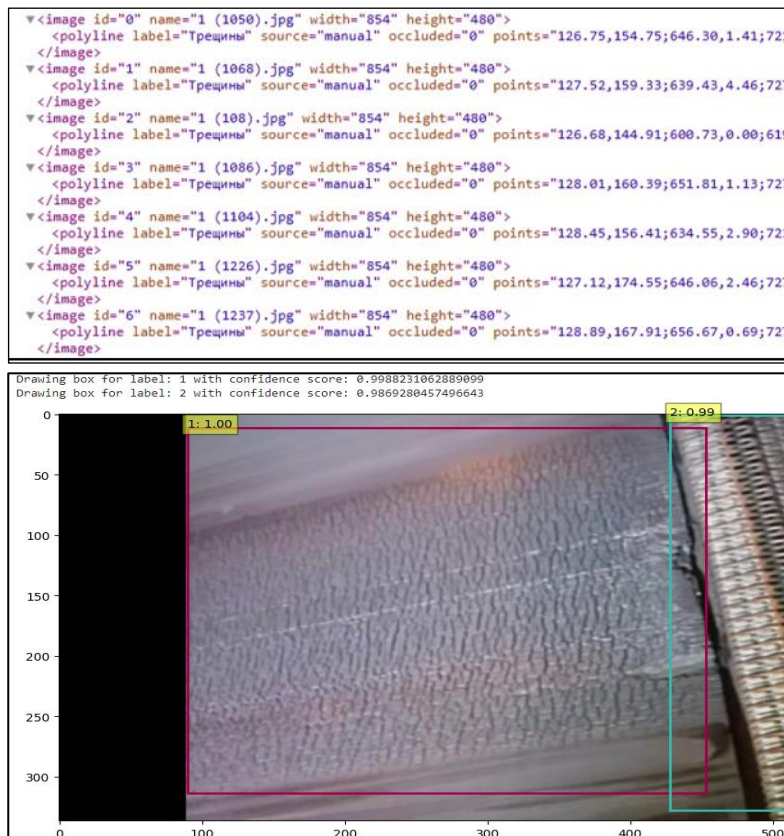


Рис. 3. Разметка изображения в формате xml и результаты распознавания
Fig. 3. Image annotation in XML format and recognition results

В программе каждому изображению присвоен свой уникальный ID-номер, название дефекта и его координаты. Для одного изображения может быть несколько отметок о дефектах. С помощью методов Python на основе xml – разметки создан датафрейм, содержащий подробную информацию о каждом объекте на изображении: имя файла, размер изображения, метка класса и координаты точек полигональной линии.

В качестве базовой модели для ее последующего обучения выбрана сверточная нейронная сеть FastRCNN, оптимизатор – стохастический градиентный спуск [14]:

$$\theta_{t+1} = \theta_t - \eta \nabla J(\theta_t; x^{(i)}, y^{(i)}); \quad (2)$$

где θ_t – вектор параметров на итерации t ,

η – скорость обучения (learning rate),

$\nabla J(\theta_t; x^{(i)}, y^{(i)})$ – градиент функции потерь J по параметрам θ для случайной выборки $(x^{(i)}, y^{(i)})$.

Обученная модель распознает объекты на изображениях из тренировочной выборки с выделением границ объектов из целевого класса и вероятностью их обнаружения, рисунок 3.

Модель-детектор расширяет возможности диагностики транспортной ленты, позволяя не только выявлять неисправности, но и оценивать их расположение. Применение данной модели оправдано для оборудования, установленного в местах с затрудненным для сервисного обслуживания расположением – стесненные условия, недостаточная высота потолков и прочие. Что позволяет полностью исключить проведение диагностики специалистами сервисной службы.

СЕГМЕНТАЦИЯ ДЕФЕКТОВ

Сегментация изображений – это задача компьютерного зрения, направленная на разделение изображения на несколько сегментов или областей, каждая из которых соответствует различным

объектам или их частям. Она позволяет точно определить контуры объектов, создавая маски, которые выделяют каждый объект на изображении, рисунок 4 [15]. С этой целью используется модель MaskRCNN [16], отличие которой от предыдущей модели FastRCNN заключается в добавлении еще одного полносвязного слоя для предсказания маски, покрывающей весь объект на изображении, а не только ограничивающего прямоугольника, что и позволяет ей решать задачи сегментации [17]:

$$m = \text{sigmoid}(W_m \cdot f(x_i)); \quad (3)$$

где m – предсказанная маска сегментации для i -й области интереса,
 W_m – это веса для маски.




Рис. 4. Маски объектов «Трещины» и «Порыв края ленты»
Fig. 4. Masks of the objects "Cracks" and "Tape edge tear"

Результаты предсказания работы модели на тестовой выборке изображений представлены на рисунке 5.




Рис. 5. Выделение дефектов ленты по контуру их расположения
Fig. 5. Highlighting tape defects along their outline

Сегментация дефектов на ленте расширяет возможности диагностики, позволяя более точно рассчитать площадь повреждения ленты и предсказать остаточный срок эксплуатации [18]. Характер расположения объектов на изображении позволяет сделать вывод о причинах возникновения дефектов и разработать корректирующие мероприятия, исключив или ослабив их влияние.

ЗАКЛЮЧЕНИЕ

Конвейерное оборудование обычно установлено и эксплуатируется в местах с повышенной запыленностью, влажностью. Что вызывает необходимость применения камер с достаточной степенью защиты от пыли и влаги. В данном исследовании использовались видеокamеры со степенью защиты IP64. После обучения алгоритма классификации на изображениях

с размеченными дефектами, модель демонстрирует высокую чувствительность по отношению к различным аномалиям ленты. Что может быть достаточным для принятия решения о проведении визуального контроля ленты специалистами по сервисному обслуживанию, с целью детального определения размера повреждения и объема последующего ремонта.

Алгоритмы детекции дефектов на ленте, обученные с помощью координат вершин ограничивающих прямоугольников, предоставляют гораздо больше информации о самом дефекте: его приблизительном размере, месте расположения, характере повреждений. Полученную таким образом информацию можно конвертировать в предсказания по сроку службы ленты, примерно оценив площади повреждения ленты, зафиксировать факт воздействия на нее высокой температуры или химических реагентов.

Сегментация объектов на ленте, позволяет получить более качественное представление о площади повреждения, и точно зафиксировать поврежденные области. Их применение целесообразно для особо ответственного оборудования, безаварийная работа которого необходима для обеспечения работоспособности всей технологической линии производства.

В дальнейшем возможно оптимизировать систему обслуживания оборудования по категориям важности для производственного процесса на основе полученной информации о работе моделей. И произвести интеграцию системы диагностического контроля в систему управления предприятием MES/ERP [19, 20].

Список литературы

1. AC-SNGAN: Multi-class data augmentation for damage detection of conveyor belt surface using improved ACGAN / G. Wang, Z. Yang, H. Sun [et al.] // Measurement. – 2024. – Vol. 224. – P. 113814.
2. Computational approaches to Explainable Artificial Intelligence: Advances in theory, applications and trends / J.M. Górriz, I. Álvarez-Illán, A. Alvarez-Marquina [et al.] // Information Fusion. – 2023. – Vol. 100. – P. 101945.
3. Иванов К.В. Преимущества компьютерного зрения / К.В. Иванов, Н.Д. Астафьев // Актуальные проблемы авиации и космонавтики: сборник материалов VIII Международной научно-практической конференции, посвященной Дню космонавтики: в 3 т., Красноярск, 11–15 апреля 2022 года. Том 2. – Красноярск: Федеральное государственное бюджетное образовательное учреждение высшего образования "Сибирский государственный университет науки и технологий имени академика М.Ф. Решетнева", 2022. – С. 401-403.
4. Vozma H.I., Yalçın H. Visual processing and classification of items on a moving conveyor: a selective perception approach Robot. Comput.-Integr. Manuf. – 2002. – Vol. 18 (2). – P. 125-133.
5. Zhang M., Shi H., Zhang Y., Yu Ya., Zhou M. Deep learning-based damage detection of mining conveyor belt // Measurement. – 2021. – Vol. 175. – P. 109-130.
6. Proactive measures to prevent conveyor belt Failures: Deep Learning-based faster foreign object detection / M. Zhang, Yu. Cao, K. Jiang [et al.] // Engineering Failure Analysis. – 2022. – Vol. 141. – P. 106-653.
7. Ляхович В.А. Пылеподавляющий и противосмерзающий состав для кокса из продуктов вторичных процессов переработки нефтяного сырья / В.А. Ляхович, Ю.А. Булавка // Наука. Технология. Производство - 2019: Материалы Международной научно-технической конференции, посвященной 100-летию Республики Башкортостан, Салават, 15–19 апреля 2019 года. – Салават: Уфимский государственный нефтяной технический университет, 2019. – С. 59-61.
8. Королева А.М. Характеристика роли человеческого фактора при анализе причин аварий на опасных производственных объектах / А.М. Королева, К.И. Дробинин, Л.Б. Хайруллина // Экономика и предпринимательство. – 2021. – № 11(136). – С. 1399-1404.
9. Кабанова В.В., Логунова О.С. Применение искусственного интеллекта при работе с мультимедийной информацией // Вестник Череповецкого государственного университета. 2022. № 6(111). С. 23–41.
10. Аугментация наборов изображений для обучения нейронных сетей при решении задач семантической сегментации / И.А. Ложкин, М.Е. Дунаев, К.С. Зайцев, А.А. Гармаш // International Journal of Open Information Technologies. – 2023. – Т. 11, № 1. – С. 109-117.
11. PyTorch: An Imperative Style, High Performance Deep Learning Library / Paszke A., Gross S., Massa F. and others. // Advances in Neural Information Processing Systems 32, Curran Associates, Inc., 2019. – P. 8024-8035.
12. Черников А.Д. Прогнозирование и распознавание объектов в видеопотоке с помощью глубокого обучения / А.Д. Черников // Вестник науки. – 2023. – Т. 2, № 9(66). – С. 209-215.

13. Обзор современных средств разметки цифровых диагностических изображений / Ю.А. Васильев, Е.Ф. Савкина, А.В. Владимирский [и др.] // Казанский медицинский журнал. – 2023. – Т. 104, № 5. – С. 750-760.
14. Нейросетевой алгоритм полнокадрового распознавания надводных объектов в реальном времени / В.А. Бондаренко В.А., Павлова В.А., Тупиков В.А., Холод Н.Г. // Известия ЮФУ. Технические науки. – 2020. – № 1(211). – С. 188-199.
15. Сегментация объектов с функцией дообучения / И.Д. Ненахов, К. Артемов, С. Забихифар, А.Н. Семочкин, С.А. Колюбин // Изв. вузов. Приборостроение. 2022. Т. 65, № 3. С. 194-203.
16. He K, Gkioxari G, Dollár P, Girshick R. MaskR-CNN [Электронный ресурс]. URL: <https://arxiv.org/abs/1703.06870> (Дата обращения: 15.08.2024)
17. Андриянов Н.А. Обнаружение объектов на изображении: от критериев Байеса и Неймана–Пирсона к детекторам на базе нейронных сетей EfficientDet / Н.А. Андриянов, В.Е. Дементьев, А.Г. Ташлинский // Компьютерная оптика. – 2022. – Т. 46, № 1. – С. 139-159.
18. Стрельцов Д.Н. Алгоритм обнаружения объектов на видеоизображении с расчетом площадей найденных контуров / Д.Н. Стрельцов // Известия Тульского государственного университета. Технические науки. – 2012. – № 11-2. – С. 116-122.
19. Tien N.T. A literature review of ERP system, challenges and opportunities of ERP implementation on organization / N.T. Tien, T.T. Tâm // TẠP CHÍ KHOA HỌC TRƯỜNG ĐẠI HỌC QUỐC TẾ HỒNG BÀNG. – 2023. – Vol. 4. – P. 35-44.
20. Martell F., López J.M., Sánchez I.Yo., Paredes C.A., Pisano E. Evaluation of the degree of automation and digitalization using a diagnostic and analysis tool for a methodological implementation of Industry 4.0 / Computers & Industrial Engineering Volume 177, March 2023, 109097.

References

1. AC-SNGAN: Multi-class data augmentation for damage detection of conveyor belt surface using improved ACGAN / G. Wang, Z. Yang, H. Sun [et al.] // Measurement. – 2024. – Vol. 224. – P. 113814.
2. Computational approaches to Explainable Artificial Intelligence: Advances in theory, applications and trends / J. M. Górriz, I. Álvarez-Illán, A. Álvarez-Marquina [et al.] // Information Fusion. – 2023. – Vol. 100. – P. 101945.
3. Ivanov K.V. Advantages of computer vision / K.V. Ivanov, N. D. Astafiev // Current Problems of Aviation and Cosmonautics: Proceedings of the 8th International Scientific and Practical Conference dedicated to Cosmonautics Day: in 3 volumes, Krasnoyarsk, April 11–15, 2022. Volume 2. – Krasnoyarsk: Federal State Budgetary Educational Institution of Higher Education "Siberian State University of Science and Technology named after academician M. F. Reshetnev", 2022. – P. 401-403 (in Russian).
4. Bozma H.I., Yalçın H. Visual processing and classification of items on a moving conveyor: a selective perception approach Robot. Comput.-Integr. Manuf. – 2002. – Vol. 18 (2). – P. 125-133.
5. Zhang M., Shi H., Zhang Y., Yu Ya., Zhou M. Deep learning-based damage detection of mining conveyor belt // Measurement. – 2021. – Vol. 175. – P. 109-130.
6. Proactive measures to prevent conveyor belt failures: deep learning-based faster foreign object detection / M. Zhang, Yu. Cao, K. Jiang et al. // Engineering Failure Analysis. – 2022. – Vol. 141. – P. 106 - 653.
7. Lyakhovich V.A. Dust suppression and anti-freeze composition for coke from secondary processing products of petroleum raw materials / V.A. Lyakhovich, Yu.A. Bulavka // Science. Technology. Production – 2019: Materials of the International Scientific and Technical Conference dedicated to the 100th anniversary of the Republic of Bashkortostan, Salavat, April 15–19, 2019. – Salavat: Ufa State Petroleum Technological University, 2019. – P. 59-61 (in Russian).
8. Koroleva A.M. Characterization of the role of the human factor in the analysis of accident causes at hazardous production facilities / A.M. Koroleva, K.I. Drobinin, L.B. Khayrullina // Economics and Entrepreneurship. – 2021. – No. 11(136). – P. 1399-1404 (in Russian).
9. Kabanova V.V., Logunova O.S. Application of artificial intelligence in working with multimedia information // Herald of Cherepovets State University. 2022. No. 6 (111). P. 23–41 (in Russian).
10. Augmentation of image datasets for training neural networks in semantic segmentation tasks / I.A. Lozhkin, M.E. Dunaev, K.S. Zaitsev, A.A. Garmash // International Journal of Open Information Technologies. – 2023. – Vol. 11, No. 1. – P. 109-117 (in Russian).
11. PyTorch: An Imperative Style, High Performance Deep Learning Library / Paszke A., Gross S., Massa F. and others. // Advances in Neural Information Processing Systems 32, Curran Associates, Inc., 2019. – P. 8024-8035.

12. Chernikov A.D. Forecasting and recognizing objects in video streams using deep learning / A.D. Chernikov // Science Bulletin. – 2023. – Vol. 2, No. 9(66). – P. 209-215 (in Russian).
13. Review of modern tools for marking digital diagnostic images / Yu.A. Vasiliev, E.F. Savkina, A.V. Vladzimirskiy et al. // Kazan Medical Journal. – 2023. – Vol. 104, No. 5. – P. 750-760 (in Russian).
14. Neural network algorithm for real-time full-frame recognition of surface objects / V.A. Bondarenko, V.A. Pavlova, V.A. Tupikov, N. G. Kholod // Southern Federal University Proceedings. Technical Sciences. – 2020. – No. 1(211). – P. 188-199 (in Russian).
15. Object segmentation with a retraining function / I.D. Nenakhov, K. Artemov, S. Zabihifar, A.N. Semochkin, S.A. Kolyubin // Proceedings of Higher Educational Institutions. Instrumentation. 2022. Vol. 65, No. 3. P. 194 – 203 (in Russian).
16. He K, Gkioxari G, Dollár P, Girshick R. MaskR-CNN Electronic resource. URL: <https://arxiv.org/abs/1703.06870> (Access date:15.08.2024)
17. Andrianov N.A. Object detection in images: from Bayes and Neyman-Pearson criteria to neural network-based detectors EfficientDet / N.A. Andrianov, V.E. Dementiev, A.G. Tashlinsky // Computer Optics. – 2022. – Vol. 46, No. 1. – P. 139-159 (in Russian).
18. Streltsov, D.N. Algorithm for object detection in video images with calculation of the areas of detected contours / D.N. Streltsov // Proceedings of Tula State University. Technical Sciences. – 2012. – No. 11-2. – P. 116-122.19.
19. Tien N.T. A literature review of ERP system, challenges and opportunities of ERP implementation on organization / N.T. Tien, T.T. Tâm // TẠP CHÍ KHOA HỌC TRƯỜNG ĐẠI HỌC QUỐC TẾ HỒNG BÀNG. – 2023. – Vol. 4. – P. 35-44.
20. Martell F., López J.M., Sánchez I.Yo., Paredes C.A., Pisano E. Evaluation of the degree of automation and digitalization using a diagnostic and analysis tool for a methodological implementation of Industry 4.0 / Computers & Industrial Engineering Volume 177, March 2023, 109097.

Криницин Павел Геннадьевич, аспирант кафедры систем автоматизации, автоматизированного управления и проектирования, Сибирский федеральный университет, г. Красноярск, Россия

Ченцов Сергей Васильевич, доктор технических наук, профессор кафедры систем автоматизации, автоматизированного управления и проектирования, Сибирский федеральный университет, г. Красноярск, Россия

Krinitsin Pavel Gennadievich, Postgraduate student of the Department of Automation Systems, Automated Control and Design, Siberian Federal University, Krasnoyarsk, Russia

Chentsov Sergey Vasilievich, Doctor of Technical Sciences, Professor of the Department of Automation Systems, Automated Control and Design, Siberian Federal University, Krasnoyarsk, Russia