

УДК 338:45

ВАНЬКИНА ИРИНА НИКОЛАЕВНА

младший научный сотрудник лаборатории исследования социально-экономического и информационного развития территорий, Институт социально-экономических проблем народонаселения им. Н.М. Римашевской ФНИСЦ РАН, г. Москва, Россия; e-mail: irina.vankina21@gmail.com

КРОШИЛИН СЕРГЕЙ ВИКТОРОВИЧ

к.т.н., доцент, доцент кафедры математики, физики и медицинской информатики РязГМУ им. И.П. Павлова, Минздрава России, г. Рязань, Россия; ведущий научный сотрудник Института социально-экономических проблем народонаселения им. Н.М. Римашевской ФНИСЦ РАН, г. Москва, Россия; E-mail: krosh_sergey@mail.ru

КРОШИЛИН ИЛЬЯ СЕРГЕЕВИЧ

студент 4 курса кафедры микро- и нанoeлектроники факультета электроники, Рязанский государственный радиотехнический университет имени В.Ф. Уткина, г. Рязань, Россия, kroshilin.krosh-ilya@yandex.ru

DOI:10.26726/1812-7096-2023-11-67-76

ВОЗМОЖНОСТИ НЕЙРОННЫХ СЕТЕЙ ДЛЯ РЕШЕНИЯ ЗАДАЧ ИМПОРТОЗАМЕЩЕНИЯ ДЛЯ ОТЕЧЕСТВЕННЫХ ПРЕДПРИЯТИЙ

Аннотация. Цель данной работы — изучить методы семантической сегментации изображений и реализовать авторский подход к обработке полученного изображения (с беспилотного летящего аппарата) на основе выстраивания архитектуры нейронных сетей и метрики в аспекте повышения эффективности отечественного производства в условиях импортозамещения. Проанализированы и обобщены материалы исследований ученых, которые посвящены семантической сегментации изображений, а также издания, характеризующие стратегии импортозамещения в современных российских реалиях. В качестве исходного набора нейросетевых архитектур используются сети "U-Net", "FPN" и "MobileNetV2". По итогам исследования авторами предложено решение построения и оценки точности неоросетевой модели обработки изображения с БПЛА, полученных посредством комбинаций и модификаций различных архитектур для решения задач отечественного производства в условиях импортозамещения. Теоретическая и практическая значимость заключается в возможности использования нейросетевых архитектур в моделировании изображений, снятых БПЛА, в российском производстве для решения задач импортозамещения. Авторами приведена программная реализация и представлен сравнительный анализ используемых методов семантической сегментации изображений для выбора более эффективного для решения поставленных задач.

Ключевые слова: нейронные сети, семантическая сегментация изображения, импортозамещение, производство, беспилотные летящие аппараты, обработка изображений с дронов.

VANKINA IRINA NIKOLAEVNA

Junior Researcher at the Laboratory for the Study of Socio-Economic and Information Development of Territories, N.M. Rimashevskaya Institute of Socio-Economic Problems of Population of the Federal Research Research Center of the Russian Academy of Sciences, Moscow, Russia; e-mail: irina.vankina21@gmail.com

KROSHILIN SERGEY VIKTOROVICH

Ph.D., Associate Professor, Associate Professor of the Department of Mathematics, Physics and Medical Informatics of I.P. Pavlov Ryazan State Medical University, Ministry of Health of Russia, Ryazan, Russia; Leading Researcher at the N.M. Rimashevskaya Institute of Socio-Economic Problems of Population of the Russian Academy of Sciences, Moscow, Russia; E-mail: krosh_sergey@mail.ru

KROSHILIN ILYA SERGEEVICH

student of the Department of Micro- and Nanoelectronics of the Faculty of Electronics, Ryazan State Radio Engineering University named after V.F. Utkin, Ryazan, Russia, e-mail: kroshilin.krosh-ilya@yandex.ru

THE POSSIBILITIES OF NEURAL NETWORKS FOR SOLVING PROBLEMS IMPORT SUBSTITUTION FOR DOMESTIC ENTERPRISES

Abstract. *The purpose of this work is to study the methods of semantic segmentation of images and implement the author's approach to processing the resulting image (from an unmanned aerial vehicle) based on building the architecture of neural networks and metrics in terms of increasing the efficiency of domestic production in the context of import substitution. The research materials of scientists devoted to semantic segmentation of images, as well as publications characterizing import substitution strategies in modern Russian realities, are analyzed and summarized. The U-Net, FPN and MobileNetV2 networks are used as the initial set of neural network architectures. Based on the results of the study, the authors proposed a solution for constructing and evaluating the accuracy of a non-network image processing model from UAVs obtained through combinations and modifications of various architectures to solve problems of domestic production in the context of import substitution. The theoretical and practical significance lies in the possibility of using neural network architectures in modeling images taken by UAVs in Russian production to solve import substitution problems. The authors present a software implementation and a comparative analysis of the methods of semantic image segmentation used to select a more effective one for solving the tasks set.*

Keywords: *neural networks, semantic image segmentation, import substitution, production, unmanned aerial vehicles, drone image processing.*

1. Введение

В настоящее время российские предприятия вынуждены выстраивать свою производственную деятельность в условиях беспрецедентного санкционного давления и решать задачи импортозамещения на всех этапах производственного процесса. Особые требования к развитию отечественных технологий стали предъявляться с началом реализации специальной военной операции (СВО). Потребовались не только аппаратные решения, но и новые программные продукты, а также технологии, обеспечивающие необходимыми программными решениями те устройства, которые используются для решения задач СВО. Как показала практика, особенно востребованными стали беспилотные летательные аппараты (БПЛА), которые также часто называют "беспилотниками" и "дронами". Существующие аппаратные и программные решения имеют "стандартные" подходы к обработке полученного с помощью БПЛА изображения, однако для более эффективной работы подобных устройств требуются новые методы сегментации изображений, которые основываются на семантических сетях. Это поможет решать задачи импортозамещения, а отечественному производству более эффективно реагировать на современные вызовы эндогенного и экзогенного характера.

Решение подобной задачи можно отнести к наиболее популярному направлению в области машинного обучения, к которой относится сфера компьютерного зрения. Это область искусственного интеллекта, которая занимается разработкой методов и алгоритмов для анализа и интерпретации визуальной информации, что схоже с тем, как это делает человеческий зрительный аппарат. Данная сфера объединяет знания из областей компьютерной науки, математики, статистики, машинного обучения и обработки изображений с целью понимания и ис-

пользования полученных визуальных данных [1-3].

Сегодняшние технологии позволяют получать высококачественные изображения с использованием БПЛА. Эти изображения имеют огромный потенциал в различных сферах деятельности человека, таких как картография, градостроительство, сельское хозяйство и многое другое. Однако обработка большого объема данных, получаемых с дронов, является сложной задачей, требующей большого количества временных ресурсов. Одним из наиболее важных аспектов обработки изображений с дронов является сегментация изображений. Сегментация позволяет выделять на изображениях объекты и области, которые имеют особую семантическую значимость. Реализация данной задачи является одним из ключевых шагов в анализе данных, получаемых с БПЛА, так как она позволяет автоматически выделять интересные объекты и участки земли на поступающих изображениях.

Понимание и разработка эффективных методов семантической сегментации изображений является важной задачей в области компьютерного зрения. Целью данной работы стало изучение методов семантической сегментации изображений и реализация собственного подхода к обработке полученного изображения (с беспилотного летящего аппарата) на основе выстраивания архитектуры нейронных сетей и метрики в аспекте повышения эффективности отечественного производства в условиях импортозамещения.

2. Основная часть

2.1. Существующие методы сегментации

На данный момент существует достаточно большое количество работ, связанных с разработкой алгоритмов сегментации изображений. Это различные работы в области медицины [4], обработка изображений в картографической сфере [5], снимков, снятых со спутников [6]. Сегментация изображений считается довольно трудоемкой задачей компьютерного зрения. Сложность обусловлена необходимостью не только верного определения.

Задача сегментации изображений подразделяется на два вида – сегментация экземпляров (instance segmentation) и семантическая сегментация (semantic segmentation). В нашем подходе применяется семантическая сегментация изображений. Алгоритмы, реализующие задачу сегментации изображений, связаны с цифровой обработкой в совокупности с оптимизационными методами. Такие подходы были сфокусированы на локальных различиях и градиентах в пикселях. Традиционные методы сегментации представлены в таблице 1 [7].

Таблица 1

Основные методы сегментации изображения

Название	Описание
Методы на основе порога	В данном методе производится разделение пикселей на два класса по заранее установленным пороговым значениям. Такой подход используется в случае обработки изображений, для которых отдельные однородные области различаются средней яркостью. Данный подход применяется в бинарной классификации
Сегментация по областям (регионам)	Она реализуется на основе сходства близких пикселей и последующей их группировке в один класс. В процессе сегментации по регионам происходит либо добавление большего числа пикселей к выбранным фрагментам, либо дополнительное сокращение фрагментов до более мелких сегментов, а затем следует объединение их с другими небольшими фрагментами
Сегментация краев	Алгоритм основан на поиске границ на изображении. При сегментации классифицируются краевые пиксели, которые объединяются в отдельный класс. Это осуществляется посредством использования специальных фильтров, определяющих края после свертки. При этом используются оценки градиентов изображения в координатах плоскости пространства
Сегментация на основе кластеризации	Одно из лучших качеств сегментации в получении сегментов при малых временных затратах. Популярным алгоритмом здесь является метод k-средних (группировка пиксел по k классам), при этом не требуется выбор начальных пикселей.

Источник: Составлено авторами на основе [7-8]

2.2. Обработка изображений на основе методов глубокого обучения (нейросеть)

Широкое применение сейчас находят алгоритмы, основанные на машинном обучении, для решения задач сегментации изображений. Значительный прогресс достигнут в области нейросетевых архитектур для сегментации изображений, которые улучшают результативность и точность. Глубокие нейронные сети обладают способностью автоматически извлекать иерархические признаки из изображений и принимать во внимание контекстуальную инфор-

мацию. Основным инструментом в алгоритмах сегодня являются сверточные нейронные сети (СНС) [7].

Преимущества СНС - выделение признаков изображения, что приводит к хорошему качеству сегментации. При этом развитие технологий и улучшение производительности компьютеров позволяет успешно работать с нейросетевыми архитектурами, обучение моделей занимает приемлемое количество времени. Важным свойством СНС в сфере обработки изображений отмечается также некоторая устойчивость к масштабированию, вращению и смещениям, изменению ракурса и другим искажениям. Архитектура FCN использует технику апсемплинга (апсемплинг), чтобы восстановить пространственное разрешение выходного изображения, которое может быть уменьшено в результате сверточных слоев. Одним из ключевых компонентов FCN является операция свертки, которая позволяет уменьшить глубину карт признаков и сгенерировать пиксельную карту сегментации [8-10].

Также часто применяют архитектуру U-Net [9, 11] для решения задач компьютерного зрения, которая позволяет относительно быстро выполнять процедуру сегментации изображений с использованием современных графических процессоров. В настоящее время существует много успешных версий и модификаций сети U-Net с момента её первоначального представления с целью сохранения определённых качеств изображения при воспроизведении, а в некоторых случаях возможности улучшенной работы по сравнению с исходной архитектурой.

Существует подход к моделированию на основе построения функциональной пирамидальной нейронной сети (ФПН), который отличается использованием глубоких сверточных сетей, имеющих структуру пирамиды. Построение пирамид признаков происходит с минимальными дополнительными затратами. Эти пирамиды являются масштабно-инвариантными в том смысле, что изменение масштаба объекта компенсируется смещением его уровня в пирамиде [12]. Такое свойство способствует обнаружению объектов в масштабе большого диапазона.

Другим подходом, успешно проявившим себя в задачах компьютерного зрения, стало использование сетей с архитектурой MobileNet, которые будут представлены в программной реализации данного проекта. Для эффективной оценки качества сегментации необходимо использовать метрики, которые позволяют объективно сравнивать результаты различных алгоритмов и моделей. В данной работе в качестве метрики оценки качества полученного сегментированного изображения выбрана попиксельная точность.

При решении задачи семантической сегментации необходим набор данных, в котором присутствуют маски объектов. При обучении нейронной сети использовался DataSet, который содержит изображения, снятые БПЛА (примером может служить Aerial Semantic Segmentation Drone Dataset) [13].

Материал для тестирования предлагаемого подхода – это массив сегментаций фотографий, снятых в городских условиях с помощью БПЛА. Снимки были получены на высоте от 5 до 30 метров над землей камерой высокого разрешения (размер изображений 6000x4000 пикселей, формат JPEG). JPEG применяется для преобразования потоковой информации с помощью различных устройств, работающих в реальном времени и не зависит от системы представления цвета [14].

2.3. Программная реализация и сегментация

Для программной реализации алгоритмов семантической сегментации изображений был выбран язык Python, который позволяет реализовать машинное обучение и может работать на разных платформах. Была использована библиотека OpenCV. При построении архитектуры U-Net была использована структура глубокого обучения TensorFlow. С целью повышения производительности (в смысле уменьшения количества итераций для получения нужного качества), а также стабилизации работы нейронной сети был применен метод "батч-нормализации" [15]. Размер каждого батча составил 64 кадра.

На этапе тестирования программы было реализовано несколько алгоритмов сегментации. Ниже представлена реализация U-Net алгоритма без использования соединений "skip connections" (см. табл. 2).

Модификация программного кода, использующая skip connections для слоев, отличается лишь добавлением конкатенации при создании блоков восходящего пути. Еще одним рассмотренным в ходе реализации проекта алгоритмом был вариант, в котором в части энкодера используется архитектура MobileNetV2, которая включала в себя рассмотрение двух вариантов – с добавлением конкатенации карт признаков и без неё. В первом случае использовалась предварительно обученная на наборе данных ImageNet модель MobileNetV2 без верхнего слоя классификации, представленная на рисунке 1. После каждой свертки применялся метод батч-нормализации.

Таблица 2

Поэтапная реализация U-Net алгоритма

Номер этапа	Выполняемые действия
1	Создание входного блока сети, включающего в себя сверточный слой, батч-нормализацию и активацию. На сверточном слое используются 32 фильтра, размер фильтра 3×3 , шаг свертки равен 2, перед сверткой используется дополнение нулями. После свертки проводится батч-нормализация и активация функцией eLU.
2	Создание трех аналогичных блоков нисходящего пути: первый блок имеет 64 фильтра, второй – 128, третий – 256. В каждом из блоков два раза повторяется комбинация из активации ReLU, разделяемой свертки (размер фильтра 3×3) и батч-нормализации. Перед всеми свертками используется дополнение нулями. В каждом блоке размещен слой MaxPooling2D с окном 3×3 и шагом 2.
3	На вход сверточного слоя подается выход предыдущего блока. Выполняется свертка с фильтром размера 1×1 , шаг свертки 2. Производится сложение полученного тензора с выходом слоя MaxPooling2D.
4	Создание четырех аналогичных блоков восходящего пути: в четвертом блоке число фильтров равно 256, в пятом – 128, в шестом – 64, в седьмом число фильтров равно 32. В каждом из блоков два раза повторяется комбинация из активации ReLU, транспонированной свертки (размер фильтра 3×3) и батч-нормализации. Затем в каждом блоке расположен слой UpSampling2D, на котором высота и ширина изображения увеличиваются в 2 раза.
5	На вход слоя UpSampling2D (масштабирующий коэффициент 2) подается выход предыдущего блока. Выход этого слоя подается на вход сверточного слоя (размер фильтра 1×1). На выходе этого слоя получается тензор, который затем складывается с выходом слоя UpSampling2D.
6	Выход седьмого блока подается на вход последнего сверточного слоя. Число фильтров равно числу классов в задаче, размер фильтра 3×3 , функция активации softmax. На выходе слоя и всей сети получаем для каждого пикселя вероятности принадлежности каждому из трех классов.




Рис. 1. Архитектура сети

С целью сравнения разных нейросетевых архитектур, реализующих семантическую сегментацию изображений, снятых БПЛА, были рассмотрены следующие программные модификации: 1) архитектура U-Net без использования skip connections; 2) архитектура U-Net с использованием skip connections; 3) архитектура U-Net без применения skip connections и использованием сети MobileNetV2 в качестве энкодера; 4) архитектура U-Net с добавлением skip connections и использованием сети MobileNetV2 в качестве энкодера.

Главной сложностью при реализации алгоритмов, использующих нейронные сети, является подбор наиболее оптимальных параметров обучения, которые дают наиболее точный результат сегментации. В частности, необходимо удачно подобрать количество используемых фильтров. В таблице 3 представлены достигнутые результаты точности для каждого из рассматриваемых алгоритмов. В графе "архитектура" указаны слои, которые были применены при про-

хождении восходящего и нисходящего путей. Данное число фильтров было выбрано экспериментально в ходе многократного тестирования используемых подходов.

Таблица 3

Результаты тестирования алгоритмов

Исследуемый метод	Архитектура	Точность, %	
		Без разрезания изображений	С разрезанием изображений
U-Net без использования skip connections	Энкодер - (32, 64, 128, 256) Декодер - (256, 128, 64, 32, 32)	54	81
U-Net с применением skip connections	Энкодер - (64, 128, 256) Декодер - (256, 128, 64, 32)	78	81
U-Net + MobileNetV2 без skip connections	Энкодер - модуль MobileNetV2 Декодер - (256, 128, 64, 64, 32)	61	81
U-Net + MobileNetV2 со skip connections	Энкодер - (64, 128, 128, 256) 68 Декодер - (256, 128, 128, 64, 32)	68	78

Согласно данным таблицы, использование skip-connections действительно влияет на точность семантической сегментации. Как для традиционной архитектуры U-Net, так и для модифицированной версии с использованием MobileNetV2 в качестве энкодера, добавление конкатенации повысило качество работы алгоритма – на 18% и 7% соответственно. Если же сравнивать между собой алгоритмы без применения конкатенации признаков карт, то в данном случае также наблюдается улучшение при внедрении MobileNetV2-сети. Полученные результаты могут говорить о том, что комбинация сети U-Net с декодером MobileNetV2 и применением skip-connection покажет результат, существенно повышающий точность предсказания. Лучшую точность предсказания продемонстрировала архитектура U-Net с применением конкатенации.




Рис. 2. Графики точности U-Net алгоритма

Алгоритм с использованием сети с архитектурой U-Net, в которой не происходит конкатенации слоев, и наилучшая достигнутая точность нейронной сети составила 54%. На рисунке 2а) представлен график точности работы данного алгоритма (последние 40 эпох). Следующей на этапе тестирования была архитектура, использующая конкатенацию признаков карт на этапе декодера, которая показала, что перекидывание весов существенно улучшило результаты сегментации. При том же количестве слоев, что и в предыдущем варианте, алгоритм достиг точности 72% (в ходе обучения 150 эпох). Уменьшение количества слоев на один слой позволило достичь точности в 78%. Наилучшие результаты обучения приведены на рисунке 2б).

В нижней части рисунков представлены примеры изображений, сегментированных с помощью нейронной сети U-Net с использованием skip connections. Левое изображение является «правильной» маской меток, правое – изображение, полученное сетью. Как видно из рисунка, сеть определяет более крупные объекты изображения, однако их границы классифицированы неверно. Некоторые мелкие объекты вовсе не распознаны сетью (желтый и оранжевый сегменты).

Согласно проведенным испытаниям, более точный результат среди сетей, не использующих конкатенацию, показал алгоритм, для которого в качестве энкодирующей части был применен MobileNetV2 подход. Достигнутая точность при его использовании составила 61%. На рисунке 3 а) представлен результат обучения сети (последние 100 эпох).




Рис. 3. Графики точности алгоритма с использованием MobileNetV2

Пример сегментированного данной сетью изображения представлен на рисунке 3а (левое изображение внизу рисунка является правильно размеченным, правое – предсказанное сетью). Последний алгоритм, который совместил в себе конкатенацию признаков карт и сеть MobileNetV2, продемонстрировал точность на валидационных данных, равную 68%. График изменения точности в ходе обучения нейронной сети представлен на рисунке 3а. Результаты обучения, полученные для моделей, в которые были выгружены разрезанные изображения, представлены в таблице 3 (последний столбец). Как показывают данные таблицы, разрезание изображений на более мелкие части привело к улучшению точности во всех исследуемых случаях. Для сети U-Net без использования конкатенации признаков карт точность увеличилась на 27%. Существенно увеличилась точность и для U-Net архитектуры с применением сети MobileNetV2 в качестве энкодера без использования соединений skip connections – плюс 20% к точности без разрезания изображений.

Наименьшая разница в точности между сетью, использующей для тренировки полные

изображения, и сетью с разрезанными кадрами наблюдается для U-Net архитектуры с использованием конкатенации на этапе декодера. Однако так же, как и для случаев выше, данное обучение может быть продолжено с целью увеличения точности предсказания. Однако стоит отметить, что при разрезании изображений возникают свои ограничения. Например, разрезанные патчи могут утратить некоторую глобальную информацию, которая может быть важна для правильной сегментации. Поэтому необходимо соблюдать осторожность при выборе размера изображений с целью сохранения достаточной глобальной информации для обеспечения качественной сегментации.

Ниже на рисунке 4 представлены графики, на которых зафиксирована наилучшая точность при обучении с разрезанными изображениями (81% для каждой исследуемой модификации).




Рис. 4. График точности сети U-Net

3. Заключение (выводы)

Таким образом, были рассмотрены основные аспекты сегментации изображений, позволяющей выделять на изображениях объекты и области с особой семантической значимостью, что открывает новые возможности для анализа и обработки визуальных данных для информации, полученной с помощью БПЛА. Это позволяет получать изображения с высоким разрешением с большой высоты и затем выделять необходимые мелкие объекты, а также охватывать большие территории. Современные методы, основанные на машинном глубоком обучении, позволяют решать данную задачу наиболее эффективно, особенно с применением сверточных нейронных сетей.

Нейронные сети демонстрируют наилучшие результаты, особенно если в их архитектуре используется конкатенация слоев при прохождении восходящего пути структуры "энкодер-декодер". Также показано, что на точность обучения влияет разрезание на части исходных изображений, при работе с разрезанными изображениями следует учесть ограничения, которые накладывает данный подход.

Данные и аналогичные [16] технологии могут быть использованы в реальном производстве, а именно в вопросах точного определения карт местности, что актуально для геодезических работ, при разведке и добыче полезных ископаемых, при решении вопросов градостроительства, в деятельности служб по охране природы и окружающей среды, в том числе при борьбе с лесными пожарами, браконьерами. Также это в настоящих условиях является важным аспектом для обеспечения решения поставленных задач перед российской экономикой [17] и производством в условиях СВО.

Финансирование: исследование не имело спонсорской поддержки.

Конфликт интересов: авторы заявляют об отсутствии конфликта интересов.

Литература

1. Манюкова Н.В., Куница Е.Ю., Лукашевич М.М. Компьютерное зрение как средство извлечения информации из видеоряда // *Математические структуры и моделирование*. 2015. № 4. С. 123-128.
2. Гонсалес Р., Вудс Р. Цифровая обработка изображений. М.: Техно-сфера, 2012. 1104 с.
3. Горячкин Б.С., Куница Е.Ю., Лукашевич М.М. Компьютерное зрение // *E-Scio*. 2020. № 9. С. 1-29.
4. Козлова О.В., Куница Е.Ю., Лукашевич М.М. U-net для решения задачи сегментации медицинских изображений // *BIG DATA и анализ высокого уровня: сборник материалов V Международной научно-практической конференции*, Минск, 13–14 марта 2019 г. В 2 ч. Ч. 2. Белорусский государственный университет информатики и радиоэлектроники; редкол. : В. А. Богуш [и др.]. Минск, 2019. С. 295-301.
5. Ганченко В.В. Семантическая сегментация аэрофотоснимков сельскохозяйственной растительности на базе нейронных сетей в задачах мониторинга // *Материалы XII мультиконференции по проблемам управления (МКПУ-2019)*. 2019. № 1. С. 49-51.
6. Горбачёв В.А., Криворотов И.А., Маркелов А.О., Котлярова Е.В. Семантическая сегментация спут-

никовых снимков аэропортов с помощью свёрточных нейронных сетей // *Компьютерная оптика*. 2020. Т. 44, №4. С. 636-645.

7. Лукашик Д.В. Анализ современных методов сегментации изображений // *Экономика и качество систем связи*. 2022. № 2. С.57-65.

8. Long J., Shelhamer E., Darrell T. Fully Convolutional Networks for Semantic Segmentation. Arxiv. 2014. DOI: 10.48550/arXiv.1411.4038. URL: <https://arxiv.org/pdf/1411.4038.pdf> (дата обращения: 01.10.2023 г.)

9. Ronneberger O., Fischer P., Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation. Computer Science Department and BIOS Centre for Biological Signalling Studies, University of Freiburg, Germany. 2015. URL: <https://arxiv.org/pdf/1505.04597.pdf> (дата обращения: 01.10.2023 г.)

10. Ulku I. Akagündüz E. A Survey on Deep Learning-based Architectures for Semantic Segmentation on 2D Images. *Applied Artificial Intelligence*. Vol. 36, 2022. DOI: 10.1080/08839514.2022.2032924

11. Бруй Е. А. Нейросетевые решения на основе архитектуры U-Net для автоматической сегментации хрящевой ткани лучезапястного сустава на МР изображениях // *Моделирование, оптимизация и информационные технологии*. 2021. № 9. С. 1-9.

12. Lin Ts-Yi, Dollár P., Girshick R., He K., Hariharan B., Belongie S. Feature Pyramid Networks for Object Detection. Arxiv. 2016. DOI: 10.48550/arXiv.1612.03144. URL: <https://arxiv.org/abs/1612.03144> (дата обращения: 01.10.2023 г.)

13. Sandler M., Howard A., Zhu M., Zhmoginov A., Chen Li.-Ch. MobileNetV2: Inverted Residuals and Linear Bottlenecks. The IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2018, pp. 4510-4520. DOI: 10.1109/CVPR.2018.00474

14. Шапиро Л., Стокман Дж. Компьютерное зрение; пер. с англ. 4-е изд. М.: Лаборатория знаний, 2020. 763 с.

15. Ioffe S., Szegedy C. Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift. Arxiv. 2015. DOI: 10.48550/arXiv.1502.03167. URL: <https://arxiv.org/pdf/1502.03167.pdf> (дата обращения: 01.10.2023 г.)

16. Ванькина И.Н., Фетисов Д.А. Плоское перемещение пятизвенного двуногого робота по поверхности с препятствиями в виде ступеней // *Математика и математическое моделирование*. 2021. № 3. С. 1-28. DOI 10.24108/mathm.0321.0000270.

17. Крошилин И.С., Крошилин С.В. Цифровые экосистемы и тренды развития российской экономики // *Доходы, расходы и сбережения населения России: тенденции и перспективы : материалы VIII Международной научно-практической конференции, Москва, 29 ноября 2022 года / Институт социально-экономических проблем народонаселения им. Н. М. Рымашевской Федерального научно-исследовательского социологического центра Российской академии наук. М.: ИСЭПН ФНИСЦ РАН, 2023. С. 107-112.*

References:

1. Manyukova N.V., Kunica E.YU., Lukashevich M.M. Komp'yuternoe zrenie kak sredstvo izvlecheniya informacii iz videoryada // *Matematicheskie struktury i modelirovanie*. 2015. № 4. S. 123-128.

2. Gonsales R., Vuds R. Cifrovaya obrabotka izobrazhenij. M.: Tekhno-sfera, 2012. 1104 s.

3. Goryachkin B.S., Kunica E.YU., Lukashevich M.M. Komp'yuternoe zrenie // *E-Scio*. 2020. № 9. S. 1-29.

4. Kozlova O.V., Kunica E.YU., Lukashevich M.M. U-net dlya resheniya zadachi segmentacii medicinskih izobrazhenij // *BIG DATA i analiz vysokogo urovnya: sbornik materialov V Mezhdunarodnoj nauchno-prakticheskoy konferencii, Minsk, 13–14 marta 2019 g. V 2 ch. CH. 2. Belorusskij gosudarstvennyj universitet informatiki i radioelektroniki; redkol. : V. A. Bogush [i dr.]. Minsk, 2019. S. 295-301.*

5. Ganchenko V.V. Semanticheskaya segmentaciya aerofotosnimkov sel'skohozyajstvennoj rastitel'nosti na baze nejronnyh setej v zadachah monitoringa // *Materialy XII mul'tikonferencii po problemam upravleniya (MKPU-2019)*. 2019. № 1. S. 49-51.

6. Gorbachyov V.A., Krivorotov I.A., Markelov A.O., Kotlyarova E.V. Semanticheskaya segmentaciya sputnikovyx snimkov aeroportov s pomoshch'yu svyortochnyh nejronnyh setej // *Komp'yuternaya optika*. 2020. Т. 44, №4. S. 636-645.

7. Lukashik D.V. Analiz sovremennyh metodov segmentacii izobrazhenij // *Ekonomika i kachestvo sistem svyazi*. 2022. № 2. S.57-65.

8. Long J., Shelhamer E., Darrell T. Fully Convolutional Networks for Semantic Segmentation. Arxiv. 2014. DOI: 10.48550/arXiv.1411.4038. URL: <https://arxiv.org/pdf/1411.4038.pdf> (data obrashcheniya: 01.10.2023 g.)

9. Ronneberger O., Fischer P., Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation. Computer Science Department and BIOS Centre for Biological Signalling Studies, University of Freiburg, Germany. 2015. URL: <https://arxiv.org/pdf/1505.04597.pdf> (data obrashcheniya: 01.10.2023 g.)

10. Ulku I. Akagündüz E. A Survey on Deep Learning-based Architectures for Semantic Segmentation on 2D Images. *Applied Artificial Intelligence*. Vol. 36, 2022. DOI: 10.1080/08839514.2022.2032924

11. Бруй Е. А. Нейросетевые решения на основе архитектуры U-Net для автоматической сегментации хрящевой ткани лучезапястного сустава на МР изображениях // *Моделирование, оптимизация и информационные технологии*. 2021. № 9. S. 1-9.

12. Lin Ts-Yi, Dollár P., Girshick R., He K., Hariharan B., Belongie S. Feature Pyramid Networks for Object Detection. Arxiv. 2016. DOI: 10.48550/arXiv.1612.03144. URL: <https://arxiv.org/abs/1612.03144> (data obrashcheniya: 01.10.2023 g.)

13. Sandler M., Howard A., Zhu M., Zhmoginov A., Chen Li.-Ch. MobileNetV2: Inverted Residuals and Linear Bottlenecks. The IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2018, pp. 4510-4520. DOI: 10.1109/CVPR.2018.00474

14. SHapiro L., Stokman Dzh. *Komp'yuternoe zrenie; per. s angl. 4-e izd. M.: Laboratoriya znaniy, 2020. 763 s.*
15. Ioffe S., Szegedy C. *Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift. Arxiv. 2015. DOI: 10.48550/arXiv.1502.03167. URL: <https://arxiv.org/pdf/1502.03167.pdf> (data obrashcheniya: 01.10.2023 g.)*
16. Van'kina I.N., Fetisov D.A. *Ploskoe peremeshchenie pyatizvennogo dvunogogo robota po poverhnosti s prepyatstviyami v vide stupeney // Matematika i matematicheskoe modelirovanie. 2021. № 3. S. 1-28. DOI 10.24108/mathm.0321.0000270.*
17. Kroshilin I.S., Kroshilin S.V. *Cifrovye ekosistemy i trendy razvitiya rossijskoj ekonomiki // Dohody, raskhody i sberezheniya naseleniya Rossii: tendencii i perspektivy : materialy VIII Mezhdunarodnoj nauchno-prakticheskoy konferencii, Moskva, 29 noyabrya 2022 goda / Institut social'no-ekonomicheskikh problem narodonaseleniya im. N. M. Rimashevskoj Federal'nogo nauchno-issledovatel'skogo sociologicheskogo centra Rossijskoj akademii nauk. M.: ISEPN FNISC RAN, 2023. S. 107-112.*