

## ОЦЕНКА КАЧЕСТВА РАСПОЗНАВАНИЯ ОБЪЕКТОВ НА ТЕПЛОВИЗИОННЫХ ИЗОБРАЖЕНИЯХ С ПОМОЩЬЮ НЕЙРОННЫХ СЕТЕЙ

Р.А. Сербиев

sra17m039@student.bmstu.ru

Д.Г. Березан

berezandg@student.bmstu.ru

МГТУ им. Н.Э. Баумана, Москва, Российская Федерация

---

### Аннотация

Представлен метод оценки качества распознавания нейронной сети. Приведено полное описание нейронной сети GoogleNet и показан принцип ее работы. Рассмотрен способ распознавания изображений на основе классифицирующей сверточной нейронной сети GoogleNet, с использованием метода Виолы — Джонса. Приведено описание нейронной сети Mask R-CNN. Выполнено распознавание объектов на тепловизионных изображениях с использованием нейронной сети Mask R-CNN. Экспериментальным путем получены результаты исследования точности распознавания нейронных сетей в зависимости от параметров обучения. Проведен сравнительный анализ результатов моделирования нейросетевого алгоритма для решения задачи классификации и поиска объектов на тепловизионных изображениях.

### Ключевые слова

Классификация изображений, тепловизионные изображения, детектирование объектов на изображениях, распознавание изображений, сверточные нейронные сети глубокого обучения, поиск объектов, GoogleNet, Mask R-CNN

Поступила в редакцию 13.03.2023

© МГТУ им. Н.Э. Баумана, 2023

---

**Введение.** Нейронная сеть — это математическая модель, построенная по принципу организации и функционирования биологических нейронных сетей, т. е. сетей живого организма. После разработки соответствующих алгоритмов нейронные сети стали использоваться в практических целях: при решении задач управления и распознавания объектов [1]. Нейронные сети обучаются на основе опыта, обобщают предыдущие прецеденты на новые случаи и извлекают существенные свойства из поступающей информации, содержащей излишние данные [2]. В статье выполнено сравнение результатов распознавания двух нейронных сетей: результаты распознавания первой нейронной сети были взяты из открытых источников, а результаты распознавания второй нейронной сети были получены опытным путем. Распознавание объектов проводили на изображениях, полученных с помощью тепловизионной камеры.

Тепловизионная камера представляет собой устройство, формирующее изображение посредством приема и обработки собственного теплового излучения объектов. Основным элементом тепловизора служит детектор теплового излучения — болометр [3].

Диапазон видимого спектра излучения значительно сдвинут от инфракрасного диапазона, в котором работает тепловизор. Существенная особенность тепловизора состоит в том, что для регистрации окружающего мира ему не нужно никакое освещение: если обычная камера принимает отраженный от предметов свет (дневной, искусственный, инфракрасный), то тепловизор работает с собственным тепловым (инфракрасным) излучением предметов и видит их в полной темноте.

Любой объект с температурой выше  $-273\text{ }^{\circ}\text{C}$  испускает электромагнитное излучение. Чем выше температура, тем меньше длина волны. Для предметов, температура которых близка к температуре окружающей среды, длины волн в максимумах теплового излучения приходятся на средний и, в большей степени, на длинный диапазон [4].

Задача поиска объектов на изображениях обычно состоит из двух подзадач: первая из них относится к классу задач обнаружения (детектирования) объекта, принадлежащего одному из заданных классов на изображении, вторая состоит в классификации найденного объекта по принадлежности одному из заданных классов. Решение указанных задач может осуществляться как в два последовательно выполняемых этапа, так и совместно, без разделения на этапы по времени. Сложность рассматриваемой общей задачи определяется высокой степенью изменчивости реальных изображений и представленных на них объектов. Меняется практически все: положение, ракурс, освещение, цвет, форма и т. д. [5].

**Оценка качества работы нейронной сети и способ сравнение экспериментальных данных.** В задачах машинного обучения для оценки качества моделей и сравнения различных алгоритмов используются метрики. Для описания метрик применяется концепция, которую называют матрицей ошибок. Ее суть заключается в том, что при распознавании объектов с помощью нейронной сети существует два возможных вида ошибок и возможны следующие исходы классификации:

True positive (*TP*) — положительный класс распознан как положительный;

False positive (*FP*) — ошибка 1-го вида, когда отрицательный класс распознается как положительный;

True negative (*TN*) — отрицательный класс распознается как отрицательный;

False negative (*FN*) — ошибка 2-го вида, когда положительный класс распознается как отрицательный.

По имеющимся данным можно определить некоторые метрики. Двумя основными метриками являются Precision (точность) и Recall (полнота) [6].

Метрика Precision — это доля положительных объектов среди тех, которые нейронная сеть посчитала положительными, она демонстрирует способность алгоритма отличать класс объектов от других классов. Значение Precision рассчитывают по формуле

$$P = \frac{TP}{TP + FP}.$$

Метрика Recall показывает, какую долю объектов положительного класса смогла найти нейронная сеть, среди всех положительных объектов, и демонстрирует способность алгоритма определять класс в целом. Значение Recall рассчитывают по формуле

$$R = \frac{TP}{TP + FN}.$$

Для обобщения указанных выше параметров применяют метрику, называемую *F-мерой*, которую вычисляют по формуле

$$F = \frac{(1 + \beta) \cdot PR}{\beta^2 P + R}.$$

Данный параметр стремится к нулю, если *P* или *R* стремятся к нулю, и достигает максимума при максимальном значении *P* или *R*. Параметр  $\beta$  изменяется в зависимости от того, какая из двух мер является приоритетнее. Если  $\beta > 1$ , то более приоритетной является полнота, а если  $0 < \beta < 1$ , то точность.

В рассматриваемых примерах сравнение будет осуществляться по значениям, полученным из площади под кривой ошибок, которая называется *ROC* (Receiver Operating Characteristic curve — кривая рабочих характеристик приемника) — рис. 1. Форма кривой *ROC* помогает определить качество алгоритма: чем круче подъем кривой, тем лучше. В худшем случае доля положительных и доля отрицательных объектов, которые были распознаны как положительные, будут равны между собой.

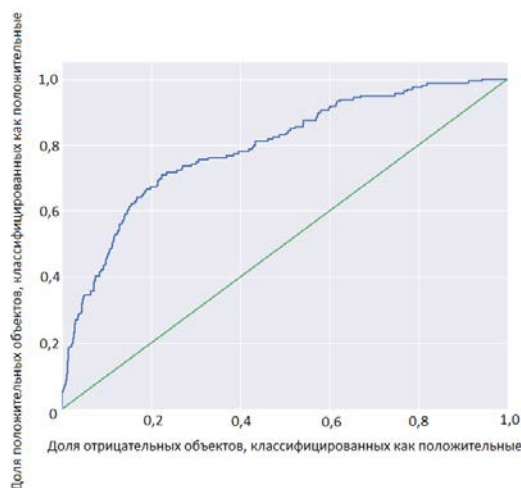


Рис. 1. Кривая *ROC*

Для построения кривой ROC используют значения False Positive Rate (ложноположительный показатель) и True Positive Rate (истинный положительный показатель), которые вычисляют как

$$TPR = R = \frac{TP}{TP + FN};$$

$$FPR = \frac{FP}{FP + TN}.$$

Кривую Precision Recall (показатель точности) строят на основании данных о полноте и точности (рис. 2). В данном случае чем больше площадь под кривой, тем лучше качество разрабатываемого алгоритма.




Рис. 2. Кривая PR

Показатель эффективности Average Precision (средняя точность) рассчитывается как площадь под кривой Precision Recall и определяют по формуле

$$F = \frac{1}{2} \sum_{k=1}^L [P(k-1) + P(k)] \Delta R(k), \quad (*)$$

где  $k$  — номер операции распознавания;  $L$  — число выполненных операций распознавания.

Для получения площади следует воспользоваться методом бинаризации. Процесс бинаризации — это перевод цветного изображения в черно-белое. Главным параметром такого преобразования является порог  $t$  — значение, с которым сравнивается яркость каждого пикселя. По результатам сравнения пикселю присваивается значение 0 или 1. Существуют различные методы бинаризации, которые можно условно подразделить на две группы — глобальные и локальные. В первом случае значение порога остается неизменным в течение

всего процесса бинаризации. Во втором изображение разбивается на области, в каждой из которых вычисляется локальный порог.

Главная цель бинаризации — это радикальное уменьшение количества информации, с которой приходится работать. Проще говоря, удачная бинаризация сильно упрощает последующую работу с изображением. Однако неудачи в процессе бинаризации могут привести к искажениям, таким как разрывы в линиях, потеря значащих деталей, нарушение целостности объектов, появление шума и непредсказуемое искажение символов из-за неоднородностей фона.

Для получения площади по кривой Precision Recall будем постепенно уменьшать порог бинаризации. При этом полнота будет расти от 0 до 1, поскольку будет увеличиваться число объектов, которым приписывается положительный класс. Про точность же нельзя сказать ничего определенного, но мы понимаем, что, скорее всего, она будет выше при более высоком пороге отсека [7].

**Оценка качества распознавания сверточной нейронной сети GoogleNet.** Сеть GoogleNet — нейронная сеть с глубокой архитектурой (рис. 3), ее особенность заключается в том, что в одном слое параллельно выполняются несколько операций. Данная сеть является более глубокой и для ее реализации требуется много ресурсов [8].




Рис. 3. Архитектура GoogleNet

Целью Google было разработать нейросеть с наибольшей вычислительной эффективностью. Для этого инженеры Google придумали так называемый модуль Inception (рис. 4) — вся архитектура нейронной сети состоит из множества таких модулей, следующих друг за другом. Из блока Base (Базовый) мы получаем тензор карт объектов, который формируется на выходе предыдущего слоя нейронной сети. Полученные данные параллельно проходят через комбинацию сверточных нейронных фильтров.

Блок  $1 \times 1$  применяется для уменьшения числа функций перед параллельными блоками и, следовательно, операций на каждом слое. Перед передачей данных в дорогие сверточные модули число функций сокращается. Это приводит к значительной экономии вычислительных затрат и успеху архитектуры.

Блоки 3×3 применяются для операции свертки. Чтобы сохранить на выходе ту же ширину и высоту, ядро с весами перемещается по карте с шагом один, и по краю карты формируются дополнительные блоки для сохранения размерности.

Блок Pool (Объединения) проводит операцию объединения по максимальному значению, по карте мы проходим фильтром заданного размера с шагом 1, и среди значений попавших в область фильтра, выбираем максимальное.

Далее все полученные результаты в блоке Filter Concat (Объединение фильтров) складываются в один тензор, и поступают на следующий слой нейронной сети.




Рис. 4. Модуль Inception V2

Также во избежание затухания функции потерь в сети GoogleNet реализован алгоритм, который позволяет также получать функцию потерь на предыдущих слоях.

**Обучение нейронной сети методом Виолы — Джонса.** Для выделения общих признаков объектов на изображении, в сети GoogleNet был использован метод Виолы — Джонса. Применяются изображения в интегральном представлении, что позволяет быстро находить необходимые объекты. Интегральное представление изображения — это матрица, совпадающая по размерам с исходным изображением. В каждом элементе ее хранится сумма интенсивностей всех пикселей, находящихся левее и выше данного элемента [9]. Поиск элементов матрицы возможен по формуле

$$L(x, y) = I(x, y) - L(x - 1, y - 1) + L(x, y - 1) + L(x - 1, y),$$

а затем используются признаки Хаара. После прохождения процесса бинаризации (рис. 5) алгоритм Хаара позволяет выделить характерные особенности, связанные с перепадами яркости [10].




Рис. 5. Результат бинаризации изображения

Например, с помощью признаков Хаара можно определить области с перепадами яркости. Численная характеристика изображения, соответствующая конкретному признаку Хаара, определяется посредством вычитания суммарного значения области темных пикселей из суммарного значения области светлых пикселей. На изображении (рис. 6) приведен пример выделения области возле глаз. Глаза на оригинальном изображении значительно темнее носа, поэтому для выделения соответствующих областей выбран признак, который имеет одну белую центральную область для выделения носа и две темных области по краям для выделения глаз.



Рис. 6. Признаки Хаара

Все признаки поступают на вход классификатора, реализуется алгоритм сканирования, который выдает результат «верно» либо «ложь».

При решении сложных задач классификации часто оказывается, что ни одна из имеющихся решающих функций не обеспечивает желаемого качества. Вместо того чтобы из получившихся «слабых» классификаторов выбирать наименее плохой, можно попробовать их «усилить», ища самый лучший классификатор не только среди имеющихся, но и среди функций от них. Чаще всего используются линейные комбинации классификаторов. Так появился термин «бустинг».

В своем подходе Виола и Джонс применили алгоритм AdaBoost, который одновременно позволил выбрать наиболее эффективные признаки и построить бинарный классификатор. Для этого с каждым признаком авторы связали слабый классификатор, представляющий одноуровневое дерево решений. Такие слабые классификаторы впоследствии подаются на вход алгоритма AdaBoost.

Последней важной частью метода Виолы — Джонса является способ объединения набора сильных классификаторов в каскадную структуру, которая позволяет резко увеличить производительность путем сосредоточения внимания на регионах исследуемого изображения, потенциально содержащих искомым объект [9].

**Обучение GoogleNet.** Для обучения нейронной сети на тепловизионных изображениях, была использована выборка, содержащая 2000 изображений класса «тест-объект», а также 4500 изображений класса «не тест-объект» (рис. 7).


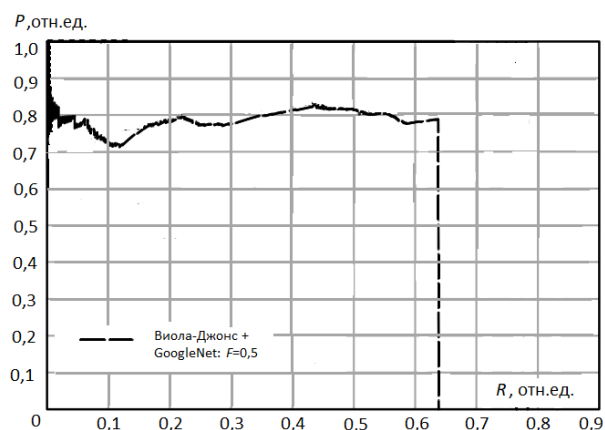


Рис. 7. Изображения из выборки изображений

Все изображения преобразованы к размеру  $224 \times 224$  пикселей. До момента начала обучения нейронной сети из выборки было взято по 500 изображений каждого класса, которые предназначались исключительно для тестирования сети. В процессе обучения сети пройдено 200 эпох, сеть обучена для распознавания двух классов изображений: «тест-объект» и «не тест-объект».

Сеть GoogLeNet способна распознавать даже такие тест-объекты, которые частично выходят за края изображения. К достоинствам нейронной сети GoogLeNet следует отнести инвариантность к изменению размера тест-объектов, хорошую точность распознавания. Были получены значения площади под кривой Precision Recall (рис. 8).






**Рис. 8.** График Precision Recall, построенный по результатам распознавания нейронной сети GoogleNet с применением метода Виолы — Джонса

Значение площади получилось равным 0,6737.

**Оценка качества распознавания сверточной нейронной сети Mask R-CNN.**

Сеть Mask R-CNN (рис. 9) развивает архитектуру R-CNN через несколько промежуточных нейронных сетей, данная нейронная сеть способна инициализировать и обучаться на определение регионов-кандидатов RPN. С использованием предлагаемых RPN регионов обучается часть сети Mask R-CNN и обученная сеть детектирования используется, чтобы инициализировать веса для RPN. Общие convolution-слои, однако, фиксируются и проводится донастройка только слоев, специфичных для RPN. Также сеть способна предсказывать положение маски, покрывающей найденный объект, и таким образом решать задачу сегментации экземпляра. Маска представляет собой просто прямоугольную матрицу, в которой единица на некоторой позиции означает принадлежность соответствующего пикселя объекту заданного класса, а ноль — что пиксель объекту не принадлежит [11].



**Рис. 9.** Иллюстрация принципа работы нейронной сети Mask R-CNN

Сеть Mask R-CNN способна точно определять, классифицировать и строить маску объекта. По результатам проведенного анализа и сравнения разных нейронных сетей авторы статьи пришли к выводу, что для решения задачи распознавания конечностей человека на изображении лучше всего подходит нейронная сеть Mask R-CNN, поскольку данная нейронная сеть является достаточно точной и многофункциональной.

**Решение задачи обнаружения объектов на изображении с помощью сети Mask R-CNN.** Был взят набор тепловизионных изображений, который использовался для обучения и тестирования нейронной сети GoogleNet. Обучающая выборка содержит 2000 изображений класса «тест-объект», а также 4500 изображений класса «не тест-объект».

Был написан код в среде моделирования PyCharm и установлены необходимые библиотеки. Mask R-CNN была клонирована в проект, и загружены предварительно обученные на наборе данных COCO веса. Были определены веса с использованием собственного набора данных [12].

Класс Mask-RCNN Config обучался на предложенном нами наборе данных. Этот класс необходим для того, чтобы переопределять некоторые заданные значения. Далее был создан экземпляр класса и все полученные параметры были выведены на дисплей.

Далее был создан класс набора данных, который работает с изображениями. Сформированы тренировочный и тестовый набор данных. Класс набора данных поддерживает несколько наборов данных, что полезно при классификации и обнаружении различных объектов. Рассмотрим основные методы класса, используемые при распознавании:

***load\_dataset*** — перебирает все файлы в папках с изображениями и аннотацией для создания набора данных с использованием методов ***add\_class*** и ***add\_image***;


***extract\_boxes*** — извлекает каждую ограничивающую рамку из файла аннотаций JSON;

***load\_mask*** — генерирует маски для каждого объекта на изображении и возвращает одну маску для каждого экземпляра.

После прохождения всей процедуры обучения опытным путем были найдены метрики из матрицы ошибок. Была получена площадь под кривой Precision Recall путем постепенного уменьшения порога бинаризации [7].

Эксперимент проводили около 15 раз, в результате чего удалось добиться увеличения полноты от 0 до 1 при различных значениях порога бинаризации. И на основе этих данных была построена кривая Precision Recall (рис. 10).

По формуле (\*) было рассчитан показатель эффективности Average Precision. И значение площади под кривой Precision Recall примерно равно 0,78.



**Рис. 10.** Кривая Precision Recall, построенная по результатам распознавания нейронной сети Mask R-CNN

**Вывод.** Таким образом, проведя сравнение двух нейронных сетей, удалось установить, что точность распознавания нейронной сети Mask R-CNN оказалась выше, чем нейронной сети GoogleNet. Оба способа распознавания были реализованы на идентичных наборах данных. Из этого можно сделать вывод, что обучение и тестирование нейронной сети Mask R-CNN было реализовано верно и что данный способ подходит для распознавания различных видов входных данных, поскольку структура нейронной сети никак не модернизировалась, а настолько точное распознавание удалось получить лишь за счет обычного обучения весов нейронной сети.

### Литература

- [1] Стенфордский курс Сверточные нейронные сети для визуального распознавания. URL: <https://www.reg.ru/blog/stenfordskij-kurs-lekciya-1-vvedenie/> (дата обращения 15.02.2023).
- [2] Haykin S. *Neural networks a comprehensive foundation second edition*. New Jersey, Prentice Hall, 1999, 842 p.
- [3] Lloyd J.M. *Thermal Imaging Systems*. Honeywell Inc., Radiation Center, Lexington, Massachusetts, Plenum Press, New York and London, 1975, 456 p.
- [4] Криксунов Л.З. *Справочник по основам инфракрасной техники*. Москва, Радио, 1978, 400 с.
- [5] Faure A. *Perception et reconnaissance des formes*. Paris, Editests, 1985, 286 p.
- [6] *Метрики в задачах машинного обучения*. URL: <https://habr.com/ru/company/ods/blog/328372/> (дата обращения 15.02.2023).
- [7] Тархов Д.А. *Нейронные сети. Модели и алгоритмы*. Москва, Радиотехника, 2005, 253 с.
- [8] *Эволюция нейросетей для распознавания изображений в Google: GoogLeNet*. URL: <https://habr.com/ru/post/301084/> (дата обращения 15.02.2023).

- [9] Усилин С.А. *Алгоритмическое развитие Виола-Джонсовских детекторов для решения прикладных задач распознавания изображений*. Дис. ... канд. техн. наук. Москва, 2017, 149 с.
- [10] Журавлев Ю.И. Об алгебраическом подходе к решению задач распознавания и классификации. *Проблемы кибернетики*, 1978, т. 33, с. 5–68.
- [11] *Глубокие нейросети в компьютерном зрении*.  
URL: <https://habr.com/ru/company/leader-id/blog/529012> (дата обращения 15.02.2023).
- [12] *Everything about Mask R-CNN: A Beginner's Guide*. URL: <https://viso.ai/deep-learning/mask-r-cnn/> (accessed February 15, 2023).

**Сербиев Руслан Александрович** — студент кафедры «Специальная робототехника и мехатроника», МГТУ им. Н.Э. Баумана, Москва, Российская Федерация.

**Березан Дмитрий Георгиевич** — студент кафедры «Специальная робототехника и мехатроника», МГТУ им. Н.Э. Баумана, Москва, Российская федерация.

**Научный руководитель** — Рубцов Василий Иванович, кандидат технических наук, доцент кафедры «Специальная робототехника и мехатроника», МГТУ им. Н.Э. Баумана, Москва, Российская Федерация.

**Ссылку на эту статью просим оформлять следующим образом:**

Сербиев Р.А., Березан Д.Г. Оценка качества распознавания объектов на тепловизионных изображениях с помощью нейронных сетей. *Политехнический молодежный журнал*, 2023, № 04 (81). <http://dx.doi.org/10.18698/2541-8009-2023-4-881>

## EVALUATION OF THE QUALITY OF OBJECT RECOGNITION ON THERMAL IMAGING IMAGES USING NEURAL NETWORKS

R.A. Serbiev  
D.G. Berezan

sra17m039@student.bmstu.ru  
berezandg@student.bmstu.ru

Bauman Moscow State Technical University, Moscow, Russian Federation

---

### Abstract

*A method for evaluating the quality of neural network recognition is presented. The full description of the Google Net neural network is given, and the principle of its operation is presented. A method of image recognition based on the classifying convolutional neural network Google Net, using the Viola-Jones method, is considered. The description of the Mask R-CNN neural network is given. Recognition of objects on thermal imaging images was carried out using the Mask R-CNN neural network. Experimentally, the results of a study of the accuracy of recognition of neural networks, depending on the learning parameters, were obtained. A comparative analysis of the results of modeling a neural network algorithm for solving the problem of classifying and searching for objects on thermal images is carried out.*

### Keywords

*Image classification, thermal imaging, object detection in images, image recognition, convolutional neural networks of deep learning, object search, GoogLeNet, Mask R-CNN*

Received 13.03.2023

© Bauman Moscow State Technical University, 2023

---

### References

- [1] Stenfordskiy kurs Svertochnye neyronnye seti dlya vizual'nogo raspoznavaniya [Stanford Course Convolutional Neural Networks for Visual Recognition]. URL: <https://www.reg.ru/blog/stenfordskij-kurs-lekciya-1-vvedenie/> (accessed February 2, 2023).
- [2] Haykin S. *Neural networks a comprehensive foundation second edition*. New Jersey, Prentice Hall, 1999, 842 p.
- [3] Lloyd J.M. *Thermal imaging systems*. Honeywell Inc., Radiation Center, Lexington, Massachusetts, Plenum Press, New York and London, 1975, 456 p.
- [4] Kriksunov L.Z. *Spravochnik po osnovam infrakrasnoy tekhniki* [Handbook of fundamentals of infrared technology]. Moscow, Radio Publ., 1978, 400 p. (In Russ.).
- [5] Faure A. *Perception et reconnaissance des forms*. Paris, Editests Publ., 1985, 286 p.
- [6] *Metriki v zadachakh mashinnogo obucheniya* [Metrics in machine learning problems]. URL: <https://habr.com/ru/company/ods/blog/328372/> (accessed February 2, 2023).
- [7] Tarkhov D.A. *Neyronnye seti. Modeli i algoritmy* [Neural networks. Models and algorithms]. Moscow, Radiotekhnika Publ., 2005, 253 p. (In Russ.).
- [8] *Evolyutsiya neyrosetey dlya raspoznavaniya izobrazheniy v Google: GoogLeNet* [The evolution of neural networks for image recognition in Google: GoogLeNet]. URL: <https://habr.com/en/post/301084> (accessed February 2, 2023).
- [9] Usilin S.A. *Algoritmicheskoe razvitie Viola-Dzhonsovskikh detektorov dlya resheniya prikladnykh zadach raspoznavaniya izobrazheniy* [Algorithmic development of Viola-Jones

- detectors for solving applied problems of image recognition]. Cand. Diss. Moscow, 2017, 149 p. (In Russ.).
- [10] Zhuravlev Yu.I. On an algebraic approach to solving problems of recognition and classification. *Problemy kibernetiki*, 1978, vol. 33, pp. 5–68. (In Russ.).
- [11] *Glubokie neyroseti v komp'yuternom zrenii: kak rabotayut, gde ispol'zuyutsya i kakie voznykayut problem* [Deep neural networks in computer vision].  
URL: <https://habr.com/ru/company/leader-id/blog/529012> (accessed February 2, 2023).
- [12] *Everything about Mask R-CNN: A Beginner's Guide*. URL: <https://viso.ai/deep-learning/mask-r-cnn/> (accessed February 15, 2023).

**Serbiev R.A.** — Student of the Department of Special Robotics and Mechatronics, Bauman Moscow State Technical University, Moscow, Russian Federation.

**Berezan D.G.** — Student of the Department of Special Robotics and Mechatronics, Bauman Moscow State Technical University, Moscow, Russian Federation.

**Scientific advisor** — Rubtsov V.I., Cand. Sc. (Eng.), Associate Professor of Department of Special Robotics and Mechatronics, Bauman Moscow State Technical University, Moscow, Russian Federation.

**Please cite this article in English as:**

Serbiev R.A., Berezan D.G. Evaluation of the quality of object recognition on thermal imaging images using neural networks. *Politekhnicheskij molodezhnyy zhurnal*, 2023, no. 04 (81). <http://dx.doi.org/10.18698/2541-8009-2023-4-881>