

# ПРИМЕНЕНИЕ ГЛУБОКИХ СВЕРТОЧНЫХ НЕЙРОННЫХ СЕТЕЙ ДЛЯ ВИЗУАЛИЗАЦИИ ПРЕПЯТСТВИЙ

На данный момент уровень развития датчиков и современные методы обработки данных позволяют с высокой эффективностью решать задачи обнаружения и активной визуализации препятствий по данным, передаваемым с тепловизионных камер, что значительно упрощает работу в различных сферах деятельности. Одним из перспективнейших средств анализа мультиспектральных видеопоследовательностей являются глубокие сверточные нейронные сети.

## ВВЕДЕНИЕ

Метод обнаружения объектов при помощи модулей, оснащённых тепловизионными системами технического зрения, является распространённым и перспективным. Управление модулем осуществляется удалённо, оператором, либо пунктом управления, работающем в автоматическом режиме. Для визуализации объектов, как правило, тепловое изображение подвергают обработке. В отличие от изображений видимого диапазона, восприятие тепловых изображений требует особых навыков. Данная задача может быть решена с помощью методов семантической сегментации. Наиболее перспективным подходом для решения задач семантической сегментации являются глубокие сверточные нейронные сети.

На вход сети поступает изображение в видимом и инфракрасном диапазонах. На выходе сеть выдаёт меточное изображение, на котором визуализируются два класса объектов: фон и препятствие. Разработанная архитектура основывается на архитектуре сети SqueezeNet [1].

В отличие от альтернативных методов выделения объектов, использование глубоких сверточных нейронных сетей имеет ряд преимуществ:

- при получении новых изображений, обучение сети выполняется с постоянным ростом качества распознавания;
- выделение объектов производится при произвольной траектории движения.

## I. АРХИТЕКТУРА СЕТИ

Требуется программно обработать изображения, поступающие от инфракрасного модуля, для визуализации объектов, посредством выделения контуров. Нахождение визуальных контуров объекта производится с помощью глубокой сверточной нейронной сети.

Таким образом, постановка задачи сводится к семантической сегментации многоспектральных изображений на два класса: фон и препятствие.

В отличие от традиционных архитектур сетей, используемых для классификации изображений, в архитектурах сетей для семантической

сегментации широко используются слои деконволюции.

Для максимального увеличения вычислительной эффективности за основу архитектуры была взята сеть SqueezeNet [1]. В отличие от AlexNet, при использовании SqueezeNet производительность увеличивается в 50 раз. Кроме того произведено уменьшение размеров фильтров свёртки. Благодаря чему число обучаемых параметров сократилось в 9 раз. Для обеспечения устойчивого выделения объектов в архитектуру сети добавлены два слоя деконволюции и удалён слой global avgpool.

## II. ОБУЧАЮЩАЯ ВЫБОРКА

Обучающая выборка для семантической сегментации состоит из пар геометрически выровненных многоспектральных изображений X и меточных изображений Y. Комплексирование видимого и инфракрасного изображений осуществлялось путём замены красного канала исходного изображения видимого диапазона на изображение инфракрасного диапазона. Для построения истинных меточных изображений для обучающей выборки использовался метод оценки траектории камеры. Примеры исходных изображений, а также меточного изображения приведены на рисунке 1.




Рис. 1 – Примеры изображений из обучающей выборки. Объект расположен в центре кадра. (а-видимый диапазон; б-ИК-диапазон; в-меточное изображение)

## III. ОБУЧЕНИЕ СЕТИ

Обучение сети производилось в программной среде Deep Learning GPU Training System (DIGITS), которая предназначена для создания

глубинных нейронных сетей (DNN) в ходе машинного обучения, а также для управления и диагностики данного процесса. Ускорение вычислений на GPU выполняется посредством библиотеки cuDNN под API CUDA. DIGITS — бесплатный продукт. Тестирование обученной сети производилось на выборке, объёмом 100 пар изображений. Для определения качества работы сети использовалась бинарная мера сходства Intersection over Union (IU), определяемая соотношением:

$$IU = A_I / A_U$$

где  $A_I$  — площадь пересечения области препятствия на построенном меточном изображении и на эталонном меточном изображении,  $A_U$  — площадь объединения данных областей.

Приемлемое качество сегмента по показателю IU должно составлять более 50 процентов. Значения IU для различных условий приведены ниже:

-При затенении объекта и температуре окружающей среды 9 С показатель IU составляет 63.3 процента;

-При затенении объекта и температуре окружающей среды 20 С показатель IU составляет 63.5 процента;

-При прямом солнечном освещении и температуре окружающей среды 21 С показатель IU составляет 66.7 процента;

-При положении объекта на границе света и тени и температуре окружающей среды 18 С показатель IU составляет 50.2 процента;

-При положении объекта на мокрой поверхности и температуре окружающей среды 16 С показатель IU составляет 47.5 процента;

*Бурж Дмитрий Леонидович*, магистрант кафедры электронных вычислительных средств БГУИР, kafsu@bsuir.by.

*Тарасюк Евгений Васильевич*, аспирант кафедры систем управления БГУИР, tarasiuk-ev@bsuir.by.

*Научный руководитель: Сорока Николай Ильич*, доцент кафедры систем управления БГУИР, кандидат технических наук, доцент, soroka@bsuir.by.

Метод визуализации объектов с использованием глубокой свёрточной нейронной сети предназначен для решения задачи обнаружения посторонних объектов на однородной поверхности (при проведении опытов на неоднородно меняющейся поверхности показатели качества снижаются). Данный метод позволяет повысить эффективность обнаружения объектов (препятствий) в ночное время суток, а также в условиях ограниченной видимости.

Меточные изображения были построены с использованием трёхмерного моделирования. Анализ полученных результатов показал, что сеть успешно производит выделение препятствия во всех рассмотренных условиях. Средняя точность выделения контуров препятствия по метрике IU составила 58.24

1. SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and <1MB model size / Forrest N. Iandola, Matthew W. Moskewicz, Khalid Ashraf et al. // CoRR. — 2016. — Vol. abs/1602.07360. — URL: <http://arxiv.org/abs/1602.07360>.
2. Князь В. В., Мизгинов В. А., Горбацевич В. С. Создание модельных изображений инфракрасного диапазона и оценка их визуального качества с использованием свёрточных нейронных сетей. — Научная визуализация, 2016. — Т. 8. — С. 67–79.
3. К. Шеннон. Теория связи в секретных системах // Работы по теории информации и кибернетике / Перевод С. Карпова. — М.: ИЛ, 1963. — С. 243-322. — 830 с.
4. Сигеру Омату, Марзуки Халид, Рубия Юсоф. Нейроуправление и его приложения = Neuro-Control and its Applications. 2-е изд. — М.: ИПРЖР, 2000. — 272 с.
5. Ватолин Д., Ракушняк А., Смирнов М., Юкин В. Методы сжатия данных. Устройство архиваторов, сжатие изображений и видео. - М.: ДИАЛОГ-МИФИ, 2003. - 384 с.