

## **АВТОНОМНАЯ НАВИГАЦИЯ В ДИНАМИЧЕСКИХ СРЕДАХ: ПОДХОД, ОСНОВАННЫЙ НА ГЛУБОКОМ ОБУЧЕНИИ**

*Негбоев А.Н., магистрант гр.356301*

*Белорусский государственный университет информатики и радиоэлектроники  
г. Минск, Республика Беларусь*

*Шульдова С.Г. – канд. техн. наук доцент*

**Аннотация.** Мобильная робототехника – это область исследований, в которой за последние десятилетия наблюдались невероятные успехи. Навигация робота важная задача для мобильных роботов. Предлагается множество методов, позволяющих роботам перемещаться в различных средах. Фактически, эти подходы обещают, что некоторые из них смогут управлять роботом в неизвестных и динамических средах.

### **Введение**

Недавно мобильные роботы начали работать в реальных условиях. Применение мобильных роботов расширяется и приобретает все большее значение. Эти направления включают в себя сельскохозяйственную робототехнику, такую как внесение удобрений и посев, поддержку медицинских услуг, таких как транспортировка лекарств, поддержку клиентов, такую как экскурсии по музеям, гиды по выставкам и военные миссии, такие как наблюдение и мониторинг. Группа мобильных роботов может выполнять работу параллельно и имеет преимущества перед системами с одним роботом. Системы с несколькими мобильными роботами могут выполнить поставленную задачу быстрее по сравнению с одним роботом. В таких задачах, где задействовано несколько мобильных роботов, требуется, чтобы все роботы перемещались и избегали друг друга, чтобы достичь своих целевых позиций.

Более того, навигация из одной точки в другую в настоящее время является одной из самых основных задач почти в каждой роботизированной системе. За последнее столетие было предложено множество методов для достижения этой фундаментальной операции [1]. Кроме того, есть несколько проблем, с которыми приходится сталкиваться во время навигации. Эти проблемы включают в себя колебания точности навигации в зависимости от сложности окружающей среды, а также проблемы с точностью картографии, точностью локализации, эффективностью приводов и т. д. До сих пор навигационная система в динамических средах является основной важной проблемой в мобильных робототехнических системах. В последнее время эта тема является одним из горячих направлений исследований.

### **Сверточные нейронные сети**

Сверточная нейронная сеть (CNN или ConvNet) — это тип искусственной нейронной сети, основанной на биологических процессах [2]. В машинном обучении это класс глубоких искусственных нейронных сетей с прямой связью, которые успешно применяются для анализа визуальных изображений. Его можно рассматривать как вариант многослойного персептрона (MLP). В компьютерном зрении традиционный MLP соединяет каждый скрытый нейрон с каждым пикселем входного изображения, пытаясь найти глобальные закономерности. Однако такое соединение неэффективно, поскольку пиксели, удаленные друг от друга, часто менее коррелированы. Таким образом, обнаруженные закономерности менее различительны для передачи в классификатор. Кроме того, из-за такой плотной связности размер параметров значительно увеличивается по мере увеличения размера входного изображения, что приводит к существенному увеличению как вычислительной сложности, так и использования пространства памяти.

Однако эти проблемы можно решить с помощью CNN. Скрытый нейрон в CNN подключается только к локальному участку входного изображения. Этот тип разреженной связи более эффективен для обнаружения локальных закономерностей, и эти локальные закономерности, полученные из одной части изображения, также применимы к другим частям изображения. CNN широко используются в приложениях визуальной классификации. В последние годы предложен ряд методов R-CNN для применения CNN в задачах обнаружения объектов. В исходная версия R-CNN принимает в качестве входных данных полные изображения и предложения объектов.

Предложения региональных объектов могут поступать различными методами, и в своей работе они используют выборочный поиск. Затем каждая предложенная область вырезается из исходного изображения и преобразуется до единого размера 227×227 пикселей. Вектор признаков размером 4096 измерений извлекается путем прямого распространения вычтенной области через точно настроенную CNN с пятью сверточными слоями и двумя полностью связанными слоями. С помощью векторов признаков обучаются классификациям набор специфичных для каждого класса машин линейных опорных векторов (SVM).

Сверточный слой является основным строительным блоком CNN. Параметры слоя состоят из набора фильтров или ядер, которые имеют небольшое рецептивное поле, но простираются на всю

глубину входного объема или изображения. Операция свертки повторяет фильтр по всему полю изображения, чтобы получить отклик каждого местоположения и сформировать карту признаков отклика. При наличии нескольких фильтров сеть получит набор карт объектов для формирования нового трехмерного объема.

Официально слой свертки принимает в качестве входных данных объем или изображение размером  $W_1 \times H_1 \times D_1$  из предыдущего слоя, где  $H_1$ ;  $P_1$ ;  $D_1$  — высота изображения, ширина изображения и количество каналов (или глубина) соответственно. Слой определяет  $K$  фильтров с формой  $F \times F \times D_1$  каждый, где  $F$  — размер ядра. Свертка входного объема и фильтров дает выходной объем размером  $W_2 \times H_2 \times K$ , где  $W_2$  и  $H_2$  нового объема зависят от размера фильтра, шага и настроек площадки для операции свертки. В общем, формула для расчета выходного размера  $W_2$  и  $H_2$  для любого заданного слоя свертки определяется как:

$$\text{— ширина: } W_2 = \frac{(W_1 - F + 2P)}{S} + 1,$$

$$\text{— высота: } H_2 = \frac{(H_1 - F + 2P)}{S} + 1,$$

Где:  $K$  — размер фильтра,  $P$  — заполнение, а  $S$  — шаг. Например, на рисунке 1 показана свертка 2D-версии, где входной объем  $7 \times 7 \times 1$  свернут с помощью одного фильтра  $3 \times 3$ . При настройках заполнения 0 и шага 1 он обеспечивает выходной объем  $5 \times 5 \times 1$ .




Рисунок 1: Пример операции свертки в 2D [2].

## Выводы

На основании этой работы можно сделать следующий вывод:

Сверточные нейронные сети (CNN) представляют собой мощный инструмент для анализа визуальных изображений в сфере компьютерного зрения. В отличие от традиционных многослойных перцептронов, где каждый скрытый нейрон связан со всеми пикселями входного изображения, CNN используют локальные связи, что позволяет им эффективно обнаруживать локальные закономерности. Это значительно снижает вычислительную сложность и использование памяти, делая CNN привлекательным выбором для задач классификации изображений. Методы, основанные на CNN, такие как R-CNN, расширяют область их применения до обнаружения объектов, что делает их важным инструментом в области компьютерного зрения.

### Список использованных источников:

[1]. Ihab S Mohamed, Guillaume Allibert, and Philippe Martinet. "Model predictive path integral control framework for partially observable navigation: A quadrotor case study". In: 2020 16th International Conference on Control, Automation, Robotics and Vision (ICARCV). 2020, pp. 196–203.

[2] Yann LeCun and M Ranzato. "Deep learning tutorial". In: Tutorials in International Conference on Machine Learning (ICML'13). Citeseer. 2013.