

## Применение мультимодальных языковых моделей к задаче визуального вопросно-ответного анализа на видеоданных

*Tuesday, 20 May 2025 13:28 (12 minutes)*

В данной работе рассматривается применение мультимодальных языковых моделей (MLLM) к задаче визуального вопросно-ответного анализа (Video Question Answering, VideoQA) на основе видеоданных. Предложенный модульный подход включает отбор ключевых кадров с использованием CLIP, построение графа сцены по пространственно-семантическим отношениям между объектами с помощью MLLM и генерацию ответа на вопрос пользователя. Проведено экспериментальное сравнение различных MLLM и методов представления визуальных объектов.

**Primary authors:** Mr YUDIN, Dmitry (Заведующий лабораторией интеллектуального транспорта МФТИ - НКБ ВС); Mr LINOK, Sergey (Научный работник лаборатории интеллектуального транспорта МФТИ - НКБ ВС); SEMENOV, Vadim

**Presenter:** SEMENOV, Vadim

**Session Classification:** 20-Машинное обучение и нейросети

**Track Classification:** Машинное обучение и нейросети