

# Улучшение FineTuning LLM с помощью Multi Token Prediction

Мостовых Егор

22 апреля 2025

# План презентации

- ▶ Про то, как эта темы вытекает из исследований в этой области
- ▶ Суть идеи диплома
- ▶ Результаты экспериментов
- ▶ Гипотезы, анализ результатов

# Обзор литературы:

## Спекулятивный декодинг (2022)

### WITHOUT SPECULATIVE DECODING



My favorite thing about fall is the


### WITH SPECULATIVE DECODING



My favorite thing about fall is the change in the leaves. The trees


# Обзор литературы:

## Multi Token Prediction (2024)



# Обзор литературы:

## MEDUSA(2024) & EAGLE(2024)



## Идея диплома:

Посмотреть как влияет на качество/скорость FineTuning-а  
использование MTR.


## Идея диплома:

### Как именно это будет работать:

- ▶ Поступает предобученная модель
- ▶ Добавляем к ней несколько спекулятивных голов, обученных для архитектуры модели заранее нами
- ▶ Гипотеза: если мы будем дообучать такую модель на новую задачу - это получится быстрее и качественнее


# Эксперименты:

## Llama-3.2-1B с одной доп. головой




## Эксперименты:

### Llama-3.2-1B с одной доп. головой




# Эксперименты:

## Llama-3.2-1B с двумя доп. головами




## Эксперименты:

### Llama-3.2-1B с двумя доп. головами



# Эксперименты:


## Llama-3.2-3B с одной доп. головой



## Эксперименты:

### Llama-3.2-3B с одной доп. головой

Качество на openai/GSM



## Оценка результатов, выводы:

- ▶ В основном дообучение с несколькими головами даёт выигрыш в качестве получаемой модели
- ▶ В больших моделях повышаются требования к обучению доп. голов
- ▶ Возможно надо было дообучать большее кол-во параметров, тогда эффект был бы более нагляден

**Last slide.**