

Улучшение FineTuning LLM с помощью Multi Token Prediction

Мостовых Егор

1 апреля 2025

План презентации

- ▶ Про то, как эта темы вытекает из исследований в этой области
- ▶ Суть идеи диплома
- ▶ Что сделано
- ▶ Как планирую развить тему дальше

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 и что уже сделано

- ▶ 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

Что планирую делать:

- ▶ Дообучить разное кол-во голов
- ▶ Попробовать разные методы FineTuning-а
- ▶ Провести несколько экспериментов с разными LLM на нескольких датасетах.

Last slide.