Как учить большие языковые модели

Февраль, 2024

Мурат Апишев
Search Tech Lead, Samokat.Tech
ex-Lead Data Scientist, SberDevices
mel-lain@yandex.ru

Сейчас «LLM» ≈ «AI»

Современные AI-сервисы:

- **общаются** с людьми на любые темы на естественном языке
- **решают** школьные и университетские задачи по разным дисциплинам
- **понимают** и **генерируют** тексты, изображения, аудио

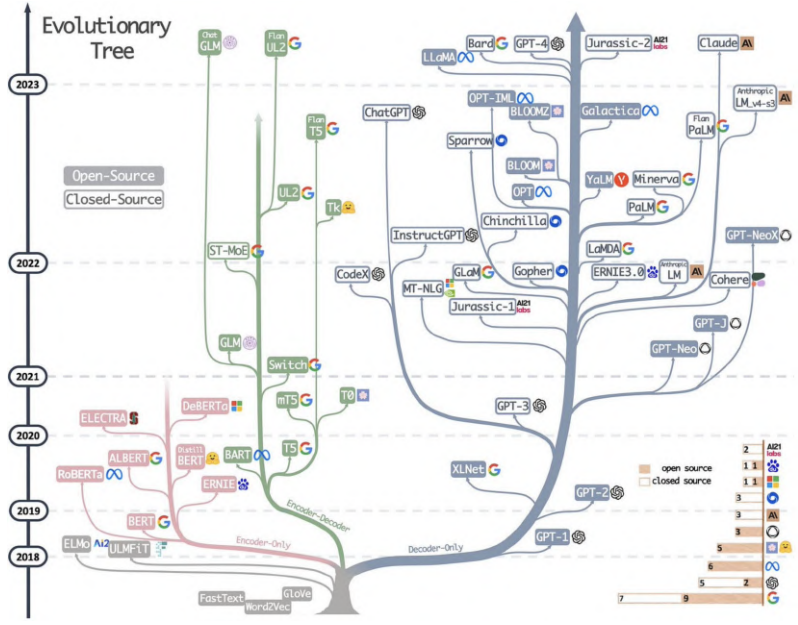

Языковое моделирование

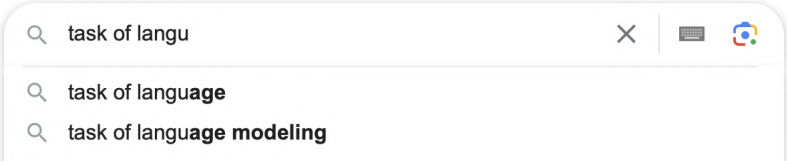

- У задачи моделирования языка есть две эквивалентные постановки:
  - предсказать совместную вероятность произвольной последовательности слов из n
  - предсказать вероятность следующего слова после произвольной последовательности из $n-1$ слов
- LLM учатся на корпусах текстов задаче предсказания следующего слова по предшествующему контексту
- Иногда контекст оказывается не только из прошлого, а из будущего (Fill-in-the-Middle), например, для задач code infilling

Промптинг LLM

- Современные большие языковые модели общего назначения:
  - мультиязычные
  - мультидоменные
  - инструктивные
- Благодаря этому они могут решать разные задачи, получая их на естественном языке (prompt), как исполнитель-человек
- Поставить задачу можно разными способами, стандартные подходы:
  - **Zero-shot**:

    «Вопрос: у Васи 4 яблока, у Пети 8 груш, сколько у них съел половину своих фруктов, сколько всего фруктов осталось? Ответ: »
  - **Few-shot**:

    «У Лены было 3 конфеты в одной руке, и 5 в другой, 2 она отдала Маше. Сколько конфет всего осталось у Лены? Ответ: 6
    Вопрос: у Васи 4 яблока, у Пети 8 груш, сколько у них съел половину своих фруктов, сколько всего фруктов осталось? Ответ: »

Промптинг LLM

- Поставить задачу можно разными способами, стандартные подходы:
  - **Chain-of-Thought** (может быть и с zero-shot, и с few-shot):

    «У Лены было 3 конфеты в одной руке, и 5 в другой, 2 она отдала Маше. Сколько конфет всего осталось у Лены? Давай порассуждаем: всего у Маши $3 + 5 = 8$ конфет. 8 - 2 равно 6. Ответ: 6
    Вопрос: у Васи 4 яблока, у Пети 8 груш, сколько у них съел половину своих фруктов, сколько всего фруктов осталось? Давай порассуждаем: »

- В этом случае модель сперва сгенерирует промежуточные рассуждения, а затем, на их основании, ответ
- Модель будет хорошо решать задачи с разными типами промптов, если она этому обучалась
- Т.е. чтобы модель умела рассуждать последовательно, она должна видеть в данных много примеров таких рассуждений

Промптинг LLM

- Подбор промпта сильно влияет на качество ответов, ещё пример с CoT:

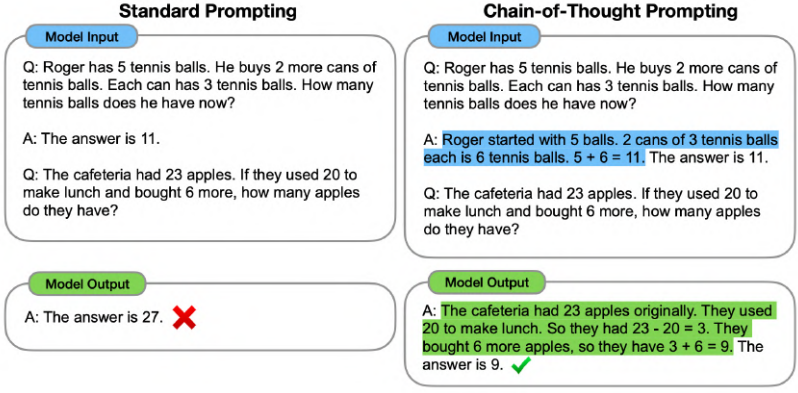

- Авторы учат модель как можно более широкому пониманию инструкций, пользователи перебором ищут лучшие варианты для своих задач
- Иногда промпты пытаются настраивать автоматически на целевую задачу (в том числе как замену дообучению, p-tuning)

Архитектура

- До LLM: рекурентные нейросети (RNN), а именно LSTM, GRU, MGU
- Обрабатывают слово за словом, передавая обновляемый вектор состояния (и иногда дополнительный вектор) с информацией о последовательности
- Модель состоит из нескольких обучаемых весовых матриц

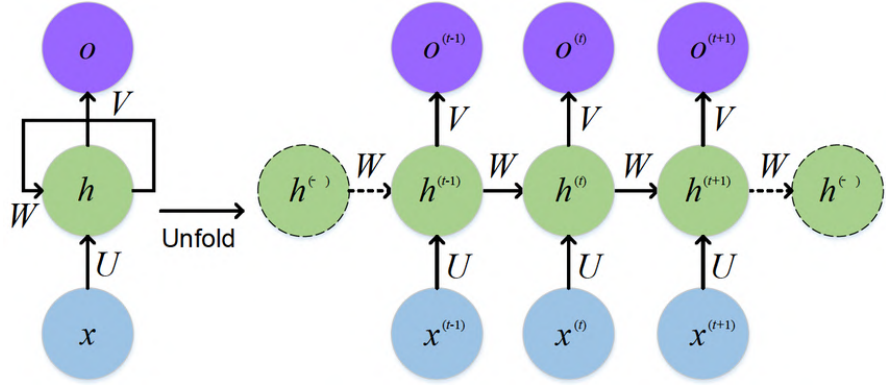

Архитектура

- RNN можно использовать для задач sequence-to-sequence (например, перевод или суммаризация)
- Нейросеть-кодировщик генерирует вектор состояния по входу
- Нейросеть-декодировщик генерирует по нему выход
- Работает не очень хорошо — на длинных последовательностях вектор теряет инфомрацию о словах в начале

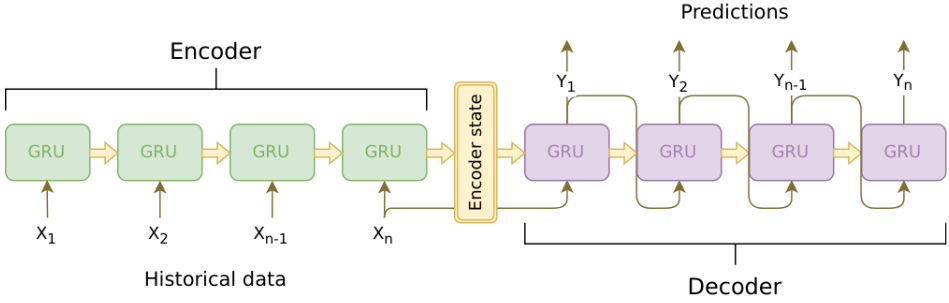

Архитектура

- Для борьбы с забыванием добавляется механизм внимания
- Декодировщик при генерации очередного слова определяет важность каждого из слов входа и использует взвешенную сумму выходных векторов кодировщика как дополнительную информацию
- Качество сильно выросло, это был стандарт в области

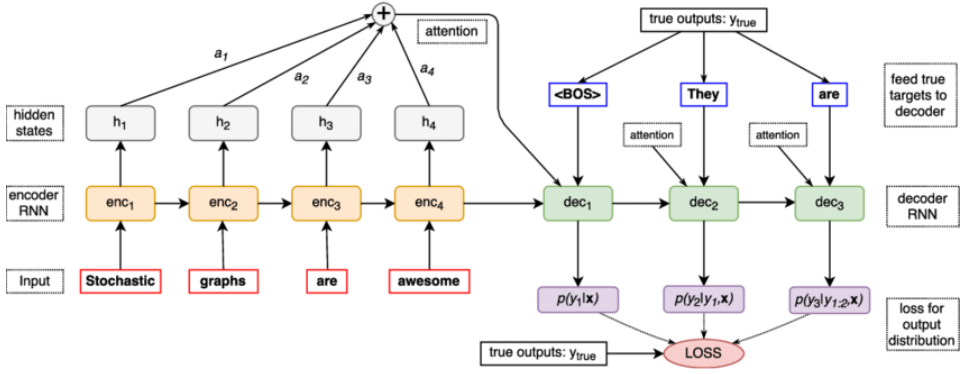

Архитектура

- Можно формировать векторы слов с учётом того, какие слова ещё есть в последовательности — получим Self-Attention
- Общая схема:
  - каждому слову входа сопоставляется вектор (на входе — эмбеддинг)
  - с помощью трёх обучаемых весовых матриц он переводится в три новых вектора: запросы, ключи и значения
  - новым представлением для слова будет взвешенная сумма всех векторов значений, нужно только определить, какие прочие слова для целевого слова важны
  - для этого запрос слова умножается скалярно на все ключи
  - после нормирования Softmax эти значения становятся весами суммы
- Можно считать несколько Self-Attention с разными весами конкатенировать результаты — Multi-Head Attention
- Нужно только добавить линейный слой проекции в исходную размерность

Архитектура

- Добавляются два полносвязных слоя, Layer-нормализация и residual connection и получается блок Transformer:

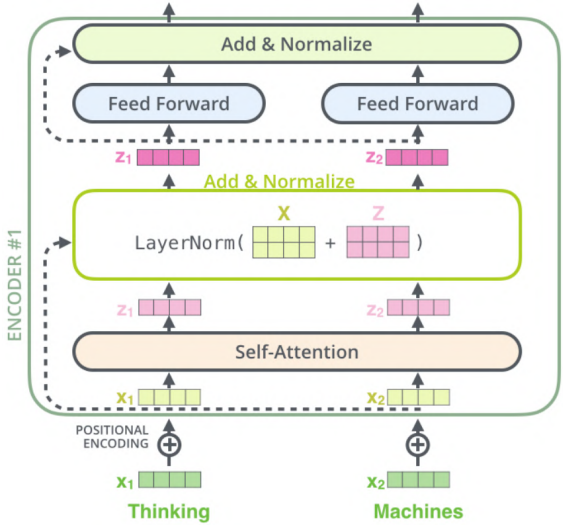

Архитектура

- Если поставить друг на друга несколько таких блоков, получится кодировщик Transformer
- Векторы слов многократно проходят через self-attention, на выходе получаются качественные контекстнозависимые представления
- Их уже можно использовать для решения разных задач напрямую или после дообучения небольшой модели-голов
- На основе архитектуры кодировщика обучены модели типа BERT
- Но оригинальный Transformer — sequence-to-sequence
- Нужен ещё и декодировщик, который на основе выходов кодировщика будет генерировать выходной текст

Архитектура

- Блок декодировщика похож на блок кодировщика, но есть отличия:
  - Masked Self-Attention для авторегрессионности
  - Cross-Attention между векторами сгенерированных и входных слов
  - запросы получаются из сгенерированных, ключи и значения — из входных
  - на выходе всего декодироващика softmax для генерации (как и в RNN)

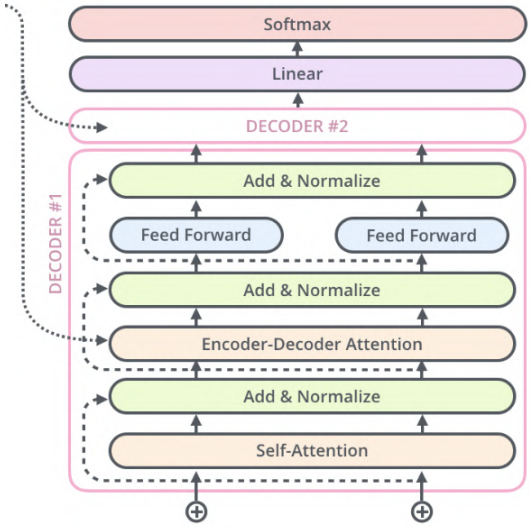

Архитектура

- Кодировщик с декодировщиком образуют полный Transformer (модели типа T5)
- Декодировщик часто используют отдельно (модели типа GPT)
- Чаще всего LLM обучаются на основе декодировщика Transformer (GPT, LLaMA, Qwen, Mistral, . . .)
- За последние годы предложен ряд успешных архитектурных модификаций (pre-LayerNorm, RMSNorm, SwiGLU), но суть сохранилась

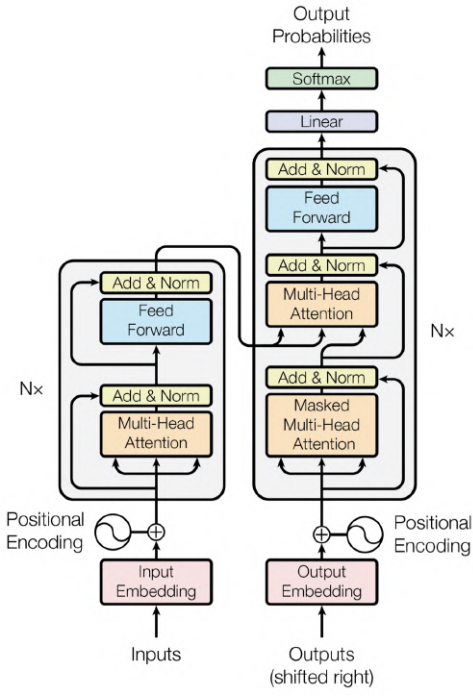

Токенизация

- На самом деле Transformer не работает со словами:
  - требуется очень большой словарь
  - сложность учёта морфологии
  - проблема OOV слов
- Модели на символах тоже непопулярны — слишком длинная последовательность и низкое качество
- Вместо этого используются токены — подслова, т.е. символьные N-граммы (среди которых могут быть и частотные слова целиком)
- Разбиение на токены производит токенизатор, он обучается статистически по текстам выбранным алгоритмом:
  - BPE
  - Unigram
  - Wordpiece

Токенизация

- Токенизатор разбивает текст на токены и сопоставляет каждому его номер

```
Two annoying things about OpenAI's tokenizer playground: (1) it's
 capped at 50k characters, and (2) it doesn't support GPT-4 or GPT-3.5
...

So, I built my own version w/ Transformers.js! It can tokenize the
 entire "Great Gatsby" (269k chars) in 200ms! ���
```

- Для обработки символов, не встречавшихся в обучающих данных токенизатора, используется Byte Fallback — в словарь добавляются сразу все возможных 256 байтов
- Есть эксперименты по использованию чисто byte-level токенизаторов
- Ещё пробуют строить словарь на основе морфологии
- Рецепта создания идеального токенизатора пока нет

Позиционное кодирование

- Без дополнительной информации о позициях токенов любая модель на основе Transformer работает плохо
- В оригинальной реализации для позиционного кодирования
  - каждой позиции i токена сопоставляется вектор, содержащий различные значения синусов и косинусов от i
  - этот вектор добавляется к вектору эмбеддинга токена на позиции i перед отправкой в модель
- Способ простой и рабочий, но есть проблемы:
  - низкое качество кодирования $\Rightarrow$ хуже результаты
  - низкое качество экстраполяции $\Rightarrow$ нет обобщения на больший контекст

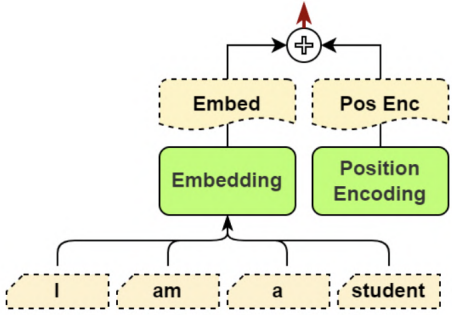

Позиционное кодирование

- Все более новые подходы — относительные, вместо позиции токена кодируется расстояние между парой токенов
- Вместо входного эмбеддинга модифицируется подсчёт self-attention, условно модификации можно разделить на три вида:
  - репараметризация формулы подсчёта внимания
    - Transformer-XL, 2019
    - DeBERTa, 2021
  - обычная формула с добавлением обучаемого сдвига
    - T5, 2020
    - AliBi, 2022
  - ротационное кодирование (RoPE, 2021) и его вариации
    - xPos, 2023
    - Positional Interpolation RoPE, 2023
    - YaRN, 2023
- Пробовали и вообще обходиться без кодирования позиций в декодерах (NoPE, 2023), но работает не очень

Этапы обучения

- Первая стадия обучения LLM — предобучение (pre-train)
- Модель учится предсказывать следующий токен по контексту слева
- Если учить с Teacher Forcing — контекст берётся из обучения, если без — из того, что сгенерировала в процессе сама модель (комбинируют)
- На этом этапе приобретает основные знания о языке и мире

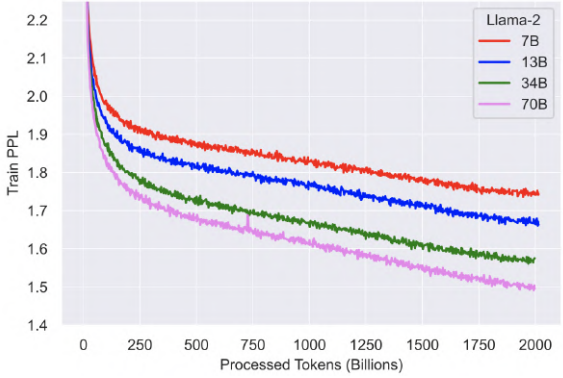

Данные для обучения

- Для обучения сильной LLM требуются терабайты данных, это много
- Но всё равно меньше, чем данных существует в природе
- И не все данные одинаково полезны, какие-то вредны (их фильтруют), какие-то ничего не привносят, но тратят вычисления
- DoReMi — пример того, как путём грамотного перевзвешивания доменов сильно уменьшить объём данных и вычислений с улучшением качества модели на few-shot задачах:

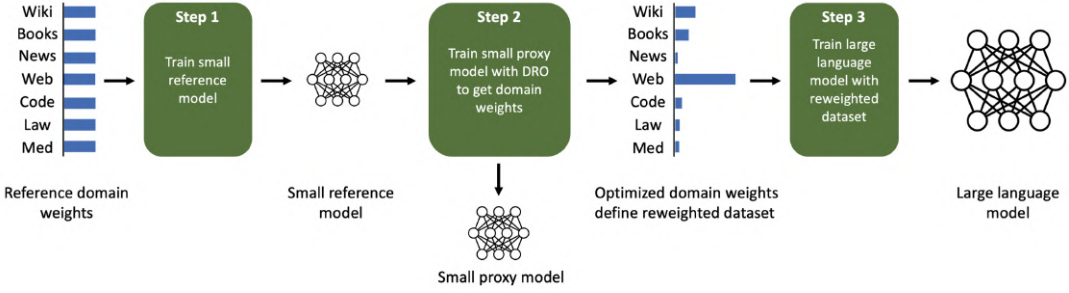

Этапы обучения

- Вторая стадия — Instruction Tuning (SFT)
- Модель учится понимать и исполнять запросы людей на естественном языке и вести диалоги
- Например: pre-train — LLaMA, instruct-tuned — Alpaca или Vicuna

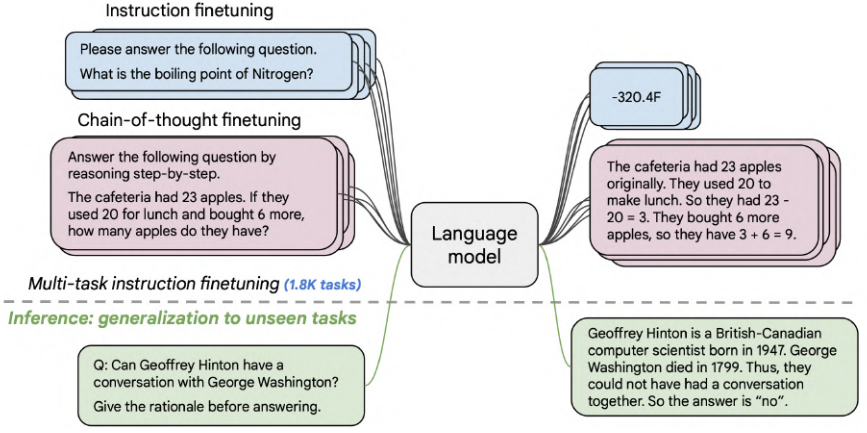

Данные для обучения

- По сути модель так же обучается предсказывать следующий токен по прошлым, но на данных специального вида
- Объем данных сильно меньше, но требования к качеству высокие
- Сбор инструктивных датасетов сложен и дорог, пробуют Self-Instruct:

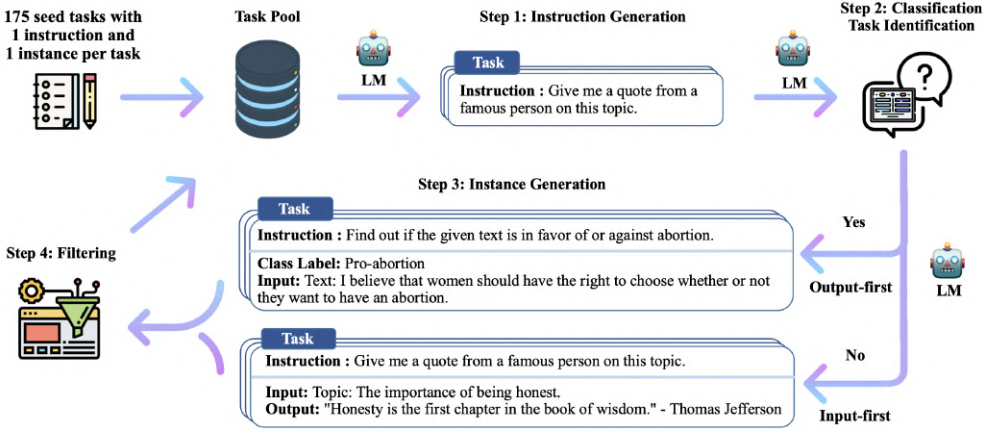

Данные для обучения

- Работа над данными и на претрейне, и на SFT позволяет сократить их объём и повысить качество, пример — кодовая модель phi-1 (и далее)
- Размеры относительно малы (до 1.3B), а качество сопоставимое с моделями в несколько раз больше
- Обучение на фильтрованных и синтетических данных, дообучение на качественных кодовых данных в стиле учебников

High educational value

```
import torch
import torch.nn.functional as F

def normalize(x, axis=-1):
    """Performs L2-Norm."""
    num = x
    denom = torch.norm(x, 2, axis, keepdim=True)
    .expand_as(x) + 1e-12
    return num / denom

def euclidean_dist(x, y):
    """Computes Euclidean distance."""
    m, n = x.size(0), y.size(0)
    xx = torch.pow(x, 2).sum(1, keepdim=True).
    expand(m, n)
    yy = torch.pow(x, 2).sum(1, keepdim=True).
    expand(m, m).t()
    dist = xx + yy - 2 * torch.matmul(x, y.t())
    dist = dist.clamp(min=1e-12).sqrt()
    return dist
```

Low educational value

```
import re
import typing
...

class Default(object):
    def __init__(self, vim: Nvim) -> None:
        self._vim = vim
        self._denite: typing.Optional[SyncParent]
    = None
        self._selected_candidates: typing.List[int
    ] = []
        self._candidates: Candidates = []
        self._cursor = 0
        self._entire_len = 0
        self._result: typing.List[typing.Any] = []
        self._context: UserContext = {}
        self._bufnr = -1
        self._winid = -1
        self._winrestcmd = ''
        self._initialized = False
```

Данные для обучения

- Почти все знания модель получает на этапе предобучения
- Идея LIMA:
  - на SFT не нужно вкладывать в модель новую информацию
  - нужно как можно лучше объяснить модели, как общаться
- Для этого данных должно быть немного, но очень высокого качества
- Собранный вручную набор из 1000 примеров для LLaMA 65B позволил обучить модель высокого качества
- Гипотеза: хорошую SFT-модель не нужно выравнивать (будет дальше)

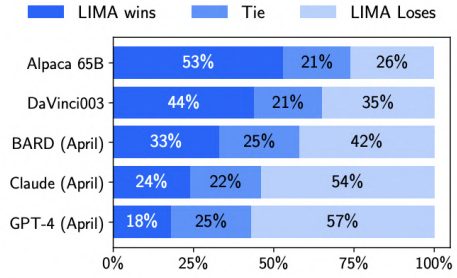

Figure 1: Human preference evaluation, comparing LIMA to 5 different baselines across 300 test prompts.

Данные для обучения

- Небольшие модели часто учат на выходах больших, и они часто вместо повторения рассуждений просто повторяют стиль
- В Orca предлагается дообучить LLaMA 13B на большом объёме специально собранных синтетических данных:
  - разнообразные задания и инструкции набираются из данных FLAN, 2021
  - модель-учитель получает их на вход с дополнительными инструкциями, требующими детального объяснения ответа, например:

    «You should describe the task and explain your answer. While answering a multiple choice question, first output the correct answer(s). Then explain why other answers are wrong. Think like you are answering to a five year old.»

  - модели генерируют ответы с объяснениями
- Модель-ученик тренируется на полученных тройках «системный промпт»-«задание»-«полный ответ учителя»
- Разнообразие и качество данных дополняется количеством: 1M сэмплов на основе GPT-4 и 5M — на основе ChatGPT

Этапы обучения

- Третий, опциональный, шаг — выравнивание (alignment)
- Диалоговая модель дообучается для генерации более корректных, полезных и безопасных ответов
- Популярная техника, использованная в Instruct GPT — RLHF:
  - обученная LLM генерирует на тестовом наборе инструкций ответы
  - ответы размечаются асессорами, на их ответах учится сильная reward-модель, она оценивает по тексту его качество
  - заводится две копии модели (A) и (B), учится (A)
  - обе модели генерируют ответы на каждый промпт, ответ (A) оценивается reward-моделью
  - веса (A) обновляются так, чтобы максимизировать reward и не давать ответы, очень далёкие от исходной (B)
  - расстояние определяется по KL-дивергенции между выходными распределениями моделей
  - обновление весов идёт по заданному алгоритме (PPO или A2C)

Этапы обучения

- RLHF сложен и не всегда работает хорошо, альтернатива — DPO:

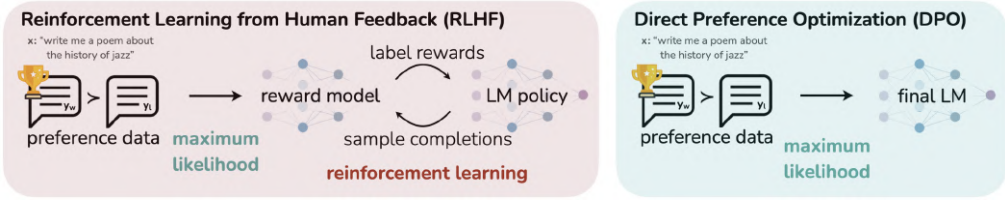

- DPO устраняет необходимость обучения отдельной reward-модели и онлайн-генерации с RL
- Вместо этого функция потерь LM переопределяется и оптимизируется напрямую
- Она учитывает как предпочтения ответов из набора данных, так и требование не уводить ответы далеко от исходной модели
- DPO использует только бинарные оценки предпочтений, иные форматы нужно сводить к этому

Баланс между параметрами и данными

- В общем случае модель чем больше, тем лучше, но только если обучена на достаточном объёме данных достаточное время

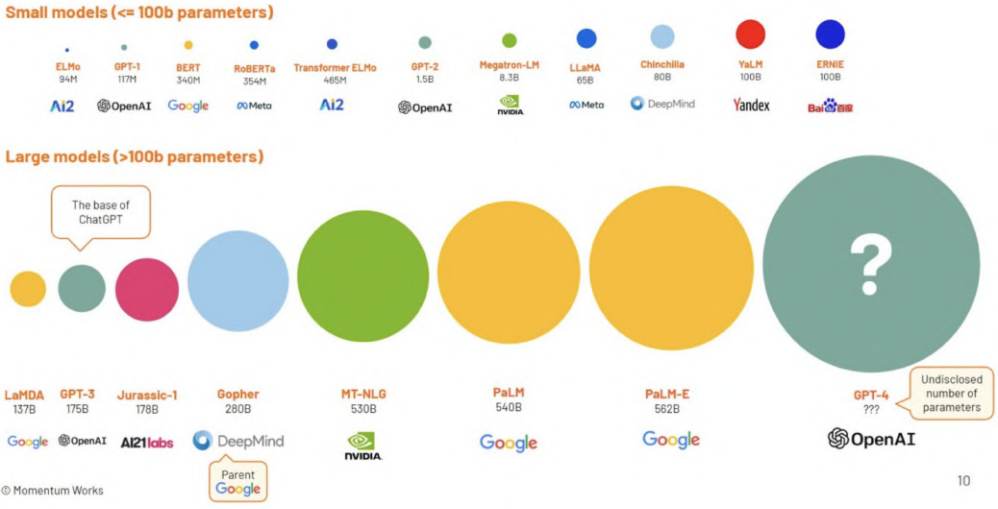

Баланс между параметрами и данными

- Авторы Chinchilla, 2022 задумались о важности баланса между размерами модели и объёмом данных (длительностью обучения)
- На обучение модели выделяется ограниченный вычислительный бюджет
- Его можно тратить, увеличивая либо размер модели, либо длительность её обучения, нужно балансировать, максимизируя loss
- Большинство моделей оказались обученными неоптимально:

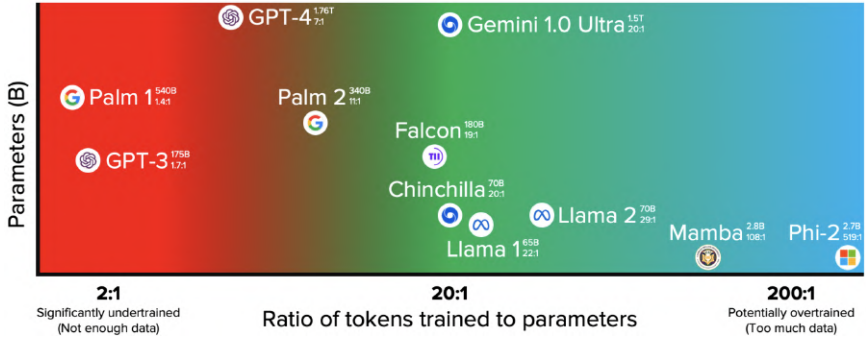

Масштабирование обучения

- При обучении память GPU в основном тратится на
  - веса модели
  - состояние оптимизатора
  - активации
  - градиенты
- Объем памяти GPU сильно ограничен: A100 имеет 80Гб
- У современных моделей даже веса могут не влезать в такой объём
- При обучении с помощью стандартного AdamW состояние оптимизатора требует x2 от размера модели
- Для обучения больших моделей с адекватной скоростью требуется обрабатывать большой объём данных одновременно
- Это возможно только при использовании параллельных вычислений на множестве GPU, этот процесс можно организовать по-разному

Масштабирование обучения

- Если модель и состояние оптимизатора не занимают всю память GPU, то очевидный способ параллелизма — по данным (Data Parallelism)
- Каждая GPU имеет свою копию модели и обрабатывает часть батча

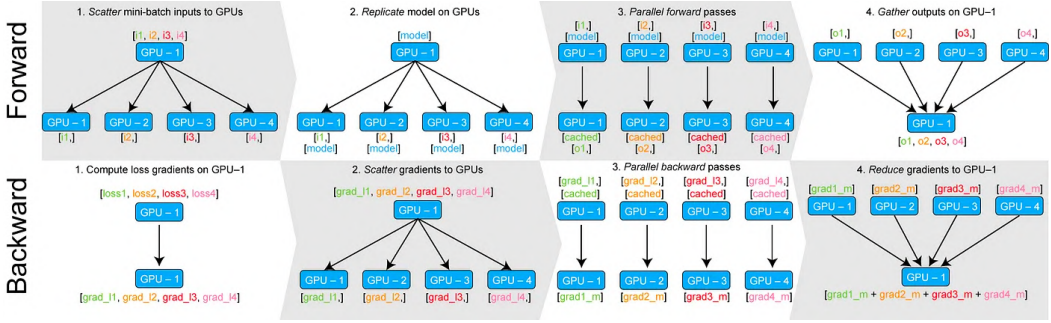

- Можно добавить Gradient Accumulation: разделять батч по всем GPU не целиком, а частями для экономии памяти
- Градиенты агрегируются до обработки всего батча, после чего запускается обновление параметров модели

Масштабирование обучения

- Если памяти одной GPU не хватает, модель можно разрезать и разложить на несколько устройств
- Pipeline Parallelism — группы слоёв раскладываются по своим GPU
- Для уменьшения простоя батч нарезается на части, и более глубокие слои начинают работать раньше

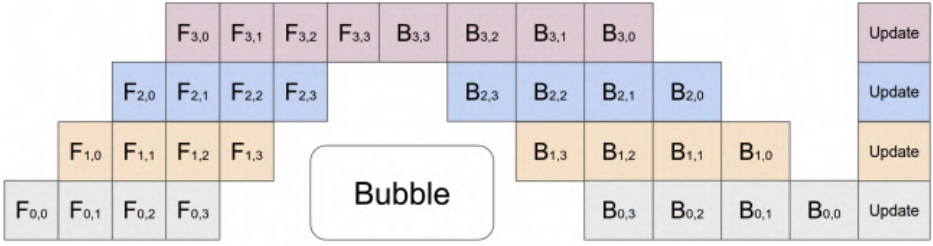

- По сравнению с другими подходами требует сильно большего переписывания кода

Масштабирование обучения

- Ещё вариант — Tensor Parallelism: по GPU раскладываются части тензора

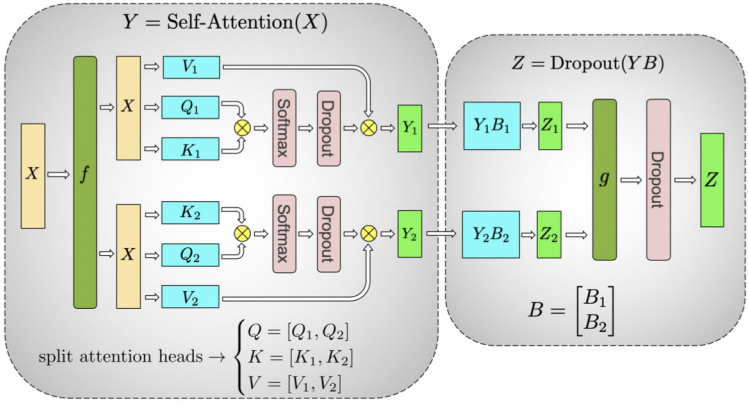

- Self-attention параллелится естественно за счёт разных голов
- При TP сетевые коммуникации более интенсивные, чем при DP или PP
  $\Rightarrow$ модель лучше раскладывать на одном узле DGX или в сети InfiniBand

Масштабирование обучения

- В Data Parallelism можно избежать хранения избыточной информации с помощью ZeRO, 2019, стандартная реализация — DeepSpeed
- На каждом этапе (stage) потребление падает, сетевые коммуникации растут x1.5 только на этапе 3

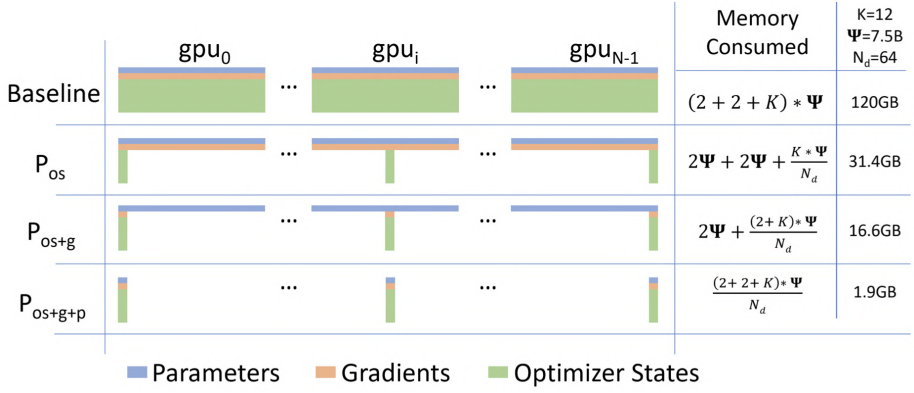

- ZeRO умеет выгружать данные в RAM, что тоже экономит память GPU

Масштабирование обучения

- Все техники могут применять как сами по себе, так и в комбинациях
- DP+PP+TP дают 3D-параллелизм, часто комбинируется с ZeRO stage 1 (stage 2/3 тоже можно, но сложнее + растут сетевые коммуникации)

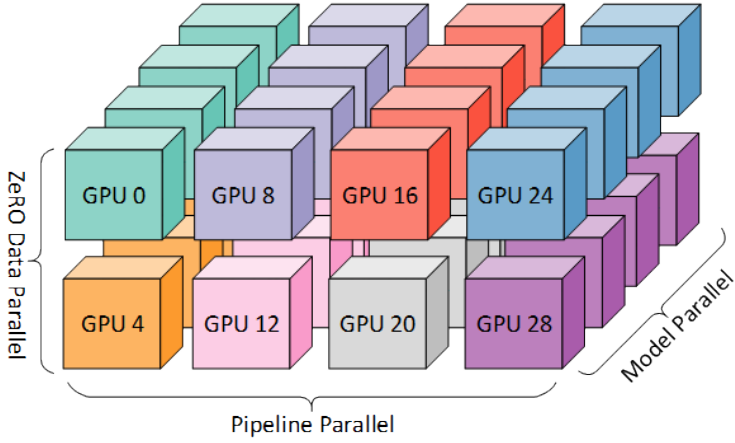

Масштабирование обучения

- Более современная альтернатива DeepSpeed — FSDP
- Модель делится на юниты, каждый юнит раскладывается на группу GPU

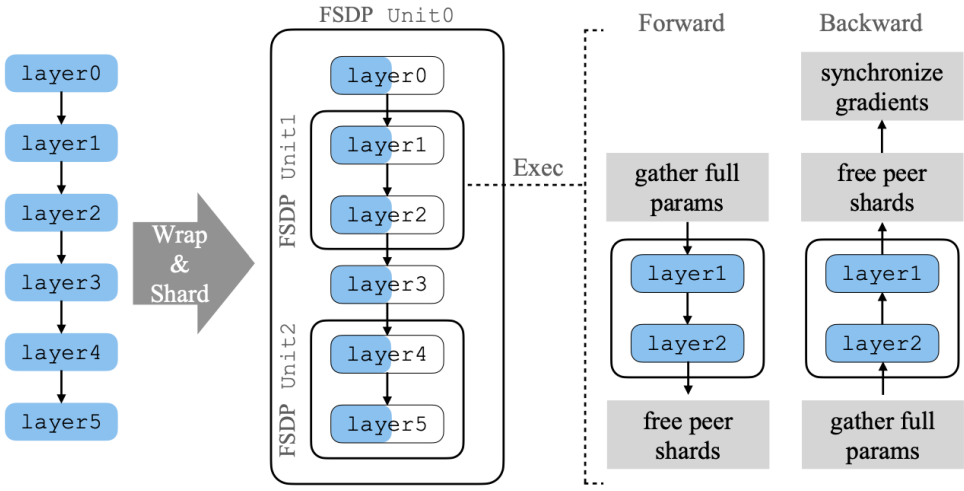

Масштабирование обучения

- Раскладывать можно на все GPU (Full Sharding) или на часть (Hybrid), если видеокарт много относительно размера модели и микробатча

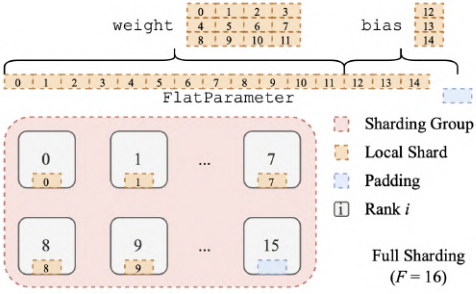

Figure 3: Full Sharding Across 16 GPUs

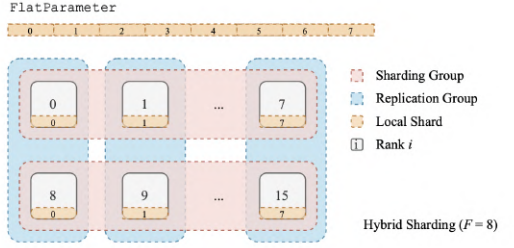

Figure 4: Hybrid Sharding on 16 GPUs: GPUs are configured into 2 sharding groups and 8 replication groups

- Фреймоворк FSDP активно используется, он эффективный и легко встраиваемый
- Если модель не влезает в память GPU, можно комбинировать с TP и PP

Эффективность обучения

- Обучать модели в fp32 неэффективно
- Используют Mixed Precision:
  - две копии весов, в fp32 и fp16 / bf16 (если GPU Ampere)
  - активации считаются в fp16 / bf16
  - агрегации и нормализации в fp32
  - градиенты и состояние оптимизатора в fp32

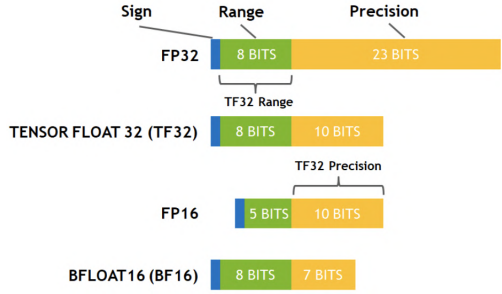

- Затраты памяти нивелируются большим батчем, а обучение ускоряется
- fp16 требует масштабирования loss для стабильности (умножение на коэффициент и обратно), bf16 — нет, он в целом более стабилен
- GPU Ampere могут заменять fp32 на tf32 — более эффективный и экономичный формат, можно комбинировать это с Mixed Precision

Эффективность обучения

- Утилизация GPU была очень неоптимальной — много времени уходило не на вычисления, а на пересылку данных между HBM и SRAM
- Подсчёт softmax в self-attention генерирует промежуточные матрицы, которые занимают место и перемещаются

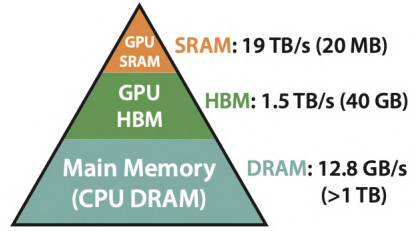

Memory Hierarchy with Bandwidth & Memory Size

- Можно ввести дополнительные переменные и считать softmax блочно
- Не нужно хранить промежуточные матрицы, передача данных между HBM и SRAM становится экономичнее
- Нужные для backward-шага промежуточные значения можно эффективно пересчитывать вместо хранения на forward

Эффективность обучения

- Дополнительное ускорение получено за счёт Fusing — выполнения набора операций одним CUDA ядром

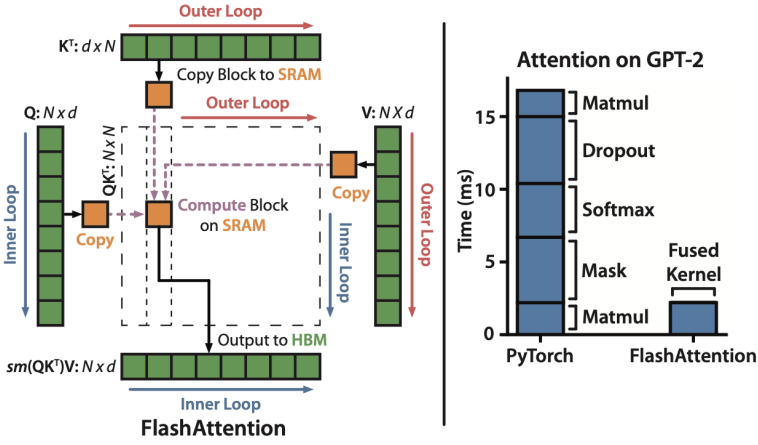

- Flash Attention 2, 2023 даёт ещё больший выигрыш по скорости за счёт вычислительных оптимизаций на GPU

Эффективность обучения

- Важная техника для оптимизации памяти на полносвязных слоях — Gradient (Activation) Checkpointing
- Выходы каждого линейного слоя на forward-шаге нужны для вычисления градиентов на этом слое на обратном шаге, поэтому они сохраняются
- Это приводит к линейному по числу слоёв росту потребления памяти
- Можно ничего не хранить и вычислять для каждого слоя активации с нуля (т.е. от начала сети до этого слоя)
- Это экономит память, но объем вычислений на forward из линейного по числу слоёв становится квадратичным
- **Решение:** сохранять активации части слоёв на некотором расстоянии друг от друга (checkpoint)
- Вычисление активаций слоя будет идти от последнего чекпойнта
- В среднем потребление памяти падает с $O(n)$ до $O(\log n)$ за счёт замедления примерно на 20%

Эффективность обучения

- Можно экспериментировать с оптимизаторами, например, Adafactor более экономичный по памяти, чем AdamW
- Большинство оптимизаций хорошо комбинируются друг с другом:

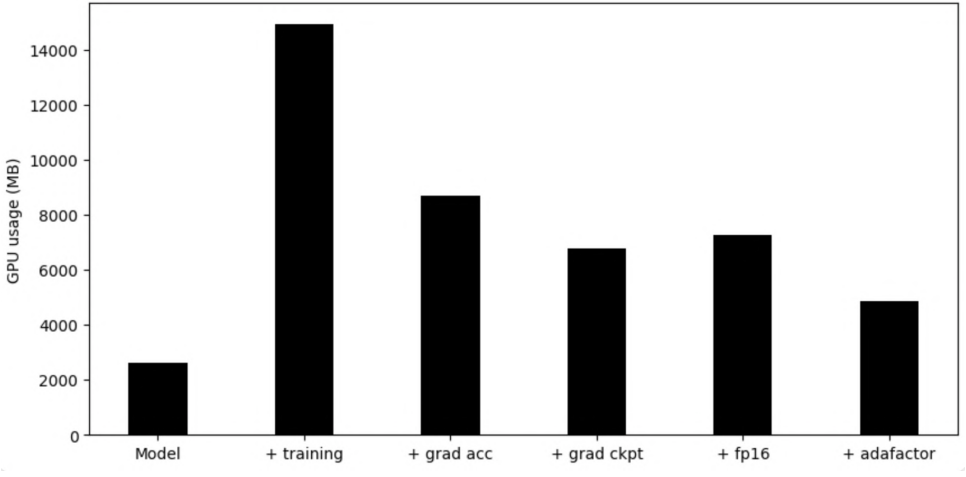

https://huggingface.co/docs/transformers/v4.20.1/en/perf_train_gpu_one

Алгоритмы оптимизации

- Стандартный алгоритм обучения LLM — AdamW, 2017:
  - в основе лежит Adam, 2014 (Momentum, 1986 + RMSprop, 2012)
  - моменты 1-го и 2-го порядков считаются, хранятся и используются на шаге обновления весов
  - в отличие от Adam, AdamW делает weight decay регуляризацию на параметрах, а не на градиентах (работает лучше, чем L2 на loss)
- Популярные альтернативы:
  - Adafactor, 2018
  - Shampoo, 2018
  - Adan, 2018
  - AMSGrad, 2019
  - Sophia, 2023
  - Lion, 2023
- Полноценно обойти AdamW сложно — для прочих алгоритмов слишком мало разносторонних экспериментов, проводить их долго и дорого
- Для уменьшения потребления памяти используются квантизованные варианты алгоримов (например, 8-bit AdamW, 2021)

Эффективность дообучения

- Стандартный подход в использовании LLM — Transfer Learning
- Большая и умная модель адаптируется под частные задачи с помощью дообучения на небольшом наборе данных
- **Проблема:** дообучение LLM целиком может требовать больших ресурсов и времени
- **Возможное решение:** учить не всю модель, а только отдельные слои
- **Проблема:** задачи могут быть многочисленными и разнообразными — не хочется на каждую учить, хранить и хостить целую модель
- Альтернатива полному или частичному дообучению — адаптеры
- Модель остаётся неизменной, к ней как-то добавляются немного новых параметров (или используется малая часть исходных весов)
- При дообучении эти параметры настраиваются корректировать работу модели для повышения качества на целевой задаче

Эффективность дообучения

- Адаптеров придумали очень много:

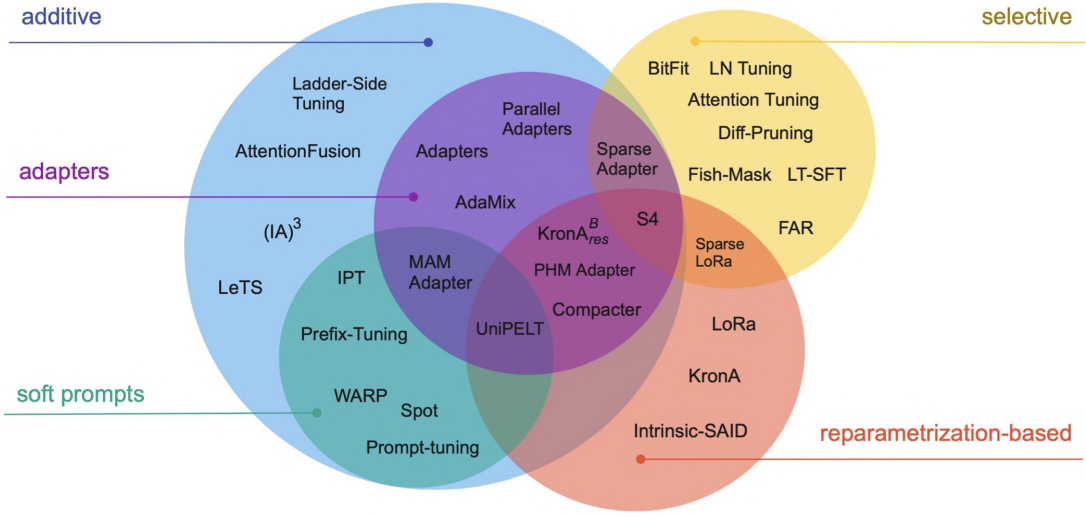

Эффективность дообучения

- Одним из наиболее популярных методов остаётся LoRA:
  - веса модели полностью замораживаются, выбираются целевые линейные веса
  - для каждой матрицы весов заводится пара новых матриц — её низкоранговое разложение
  - при работе эти матрицы перемножаются и результат складывает с основными замороженными весами
  - хороший рецепт: добавлять адаптер на все матрицы весов запросов и значений в self-attention

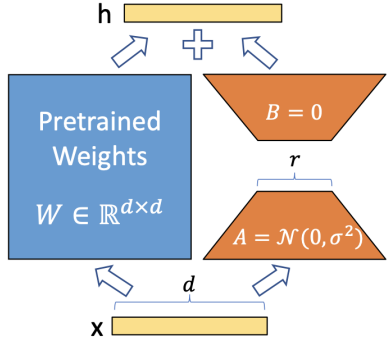

Качество генерации

- Техника на основе идей ансамблирования: Checkpoint Averaging — усреднение весов нескольких версий модели в конце обучения
- Выбор и настройка **метода декодирования** выходов LLM:
  - Greedy search
  - Beam search (`num_beams`)
  - Top-K sampling (`top_k`)
  - Top-P [nucleus] sampling (`top_p`)
  - Contrastive search (`top_k, penalty_alpha`)
- Неочевидная проблема — выбор токенов на границе промпта и ответа:

  `link is <a href="http: -> link is <a href="http: //site.com`
  `link is <a href="http -> link is <a href="http://site.com`

- Возможное решение — Token Healing: до генерации откатиться на один или более токенов назад и начать оттуда

Checkpoint ensembles: Ensemble methods from a single training process, 2017
Contrastive Search Is What You Need For Neural Text Generation, 2022
https://github.com/guidance-ai/guidance

Архитектура

- Если учить оптимально, то больше весов ⇒ выше качество
- Но больше весов ⇒ медленнее инференс
- Решение — Mixture-of-Experts, «эксперты» FF-слои
- Вектор слова после self-attention идёт Router, тот отправляет в его к лучшим экспертам
- Параметров много, но при обработке активируется только малая часть
- Каждый эксперт учится решать свои типы задач

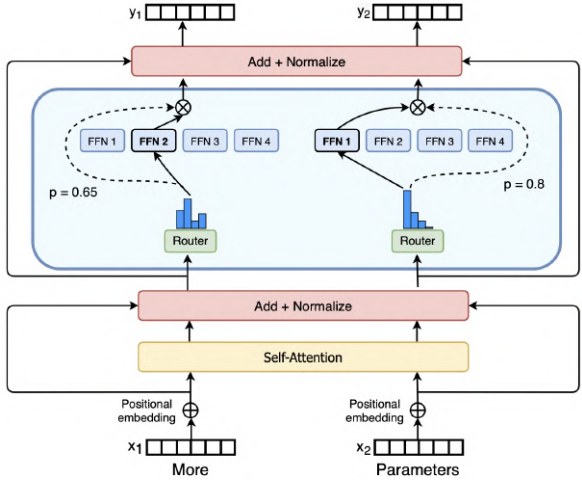

Архитектура

- У MoE есть проблемы, из-за которых идея не сразу стала популярной:
  - неравномерность загрузки экспертов (нужен loss на Router для балансировки + ограничение на capacity эксперта)
  - более низкое качество и проблемы с дообучением (сильно помогло использование LLaMA-like архитектуры)
- Важно: исходная идея MoE — эксперты с разными доменными знаниями
- Вместо этого эксперты улавливают родственные токены (имена, артикли)

Punctuation	Layer 2	, , , , , , , , , -, , , , ,).)
	Layer 6	, , , , , : . : , & , & & ? & - , , ? , , , . <extra_id_27>
Conjunctions and articles	Layer 3	The the the the the the the the the The the the the the the The the the the the
	Layer 6	a and and and and and and and or and a and . the the if ? a designed does been is not
Verbs	Layer 1	died falling identified fell closed left posted lost felt left said read miss place struggling falling signed died falling designed based disagree submitted develop

Архитектура

- В DeepSeekMoE предлагается решение:
  - вектор токена разделяется на части, каждая идёт своему эксперту
  - экспертов становится больше, у каждого меньшая размерность
  - добавляются общие эксперты, в которые части токена попадают всегда
- При том же объёме вычислений и числе параметров качество и скорость инференса выше, чем у обычного MoE
- Эксперты более доменные, т.е. важные — удаление даже нескольких ощутимо роняет перплексию

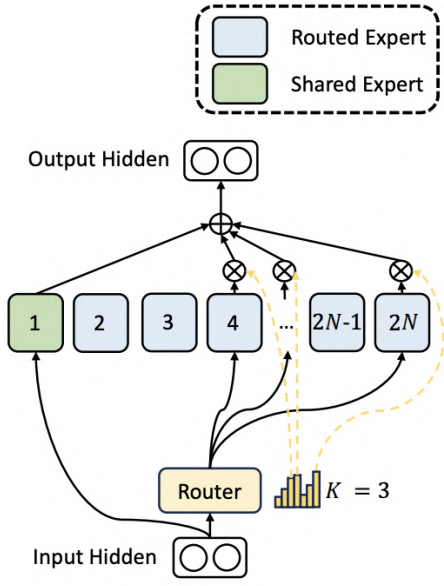

Масштабирование обучения

- Для моделей с MoE можно использовать Expert Parallelism
- Его можно кобинировать с другими типами параллелизма:

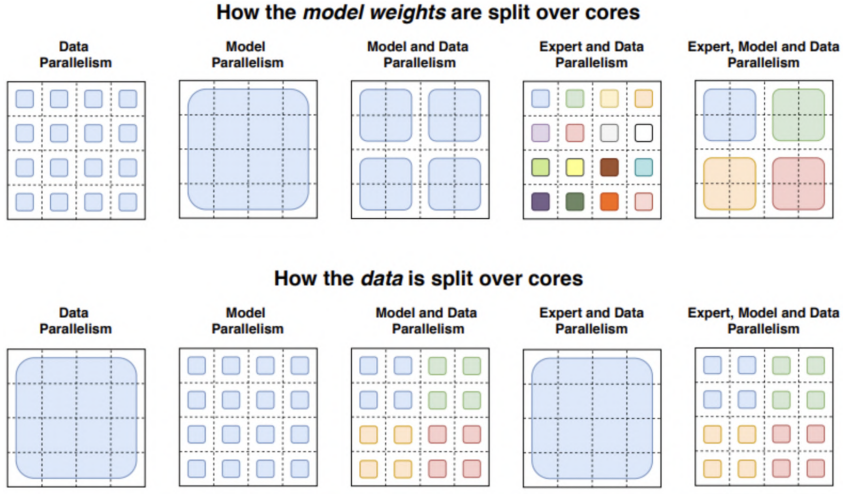

Обработка длинного контекста

- Для обхода квадратичной сложности self-attention можно понижать сложность вычислений за счёт понижения размерностей матриц

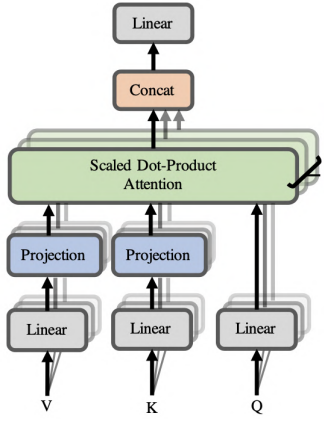

- Примеры работ:
  - Linformer: Self-Attention with Linear Complexity, 2020
  - Rethinking Attention with Performers, 2020

Обработка длинного контекста

- Для обхода квадратичной сложности self-attention можно вычислять внимание по частям последовательности

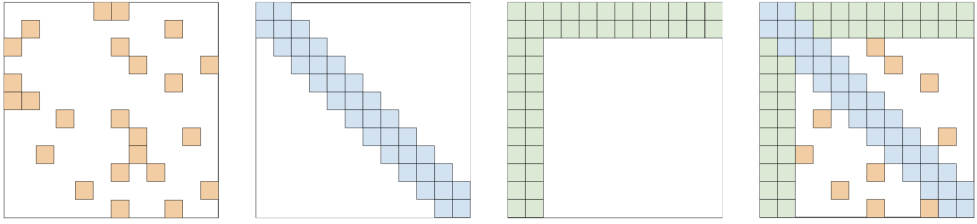

(a) Random attention (b) Window attention (c) Global Attention (d) BIGBIRD

- Примеры работ:
  - Generating Long Sequences with Sparse Transformers, 2019
  - Longformer: The Long-Document Transformer, 2020
  - Big Bird: Transformers for Longer Sequences, 2020
  - LongT5: Efficient Text-To-Text Transformer for Long Sequences, 2021
  - LongNet: Scaling Transformers to 1,000,000,000 Tokens, 2023

Обработка длинного контекста

- Для обхода квадратичной сложности self-attention можно обрабатывать последовательность иерархически

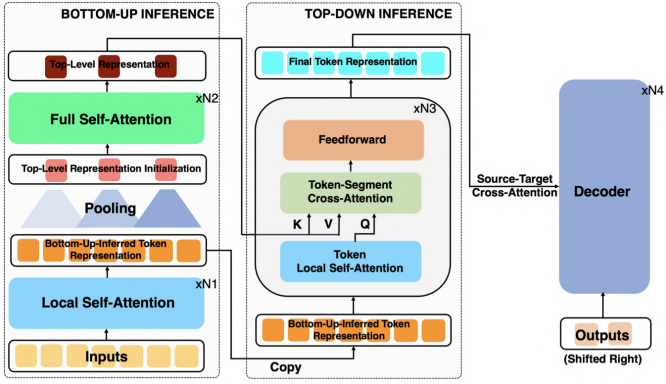

- Примеры работ:
  - Long Document Summarization with Top-down and Bottom-up Inference, 2022
  - Efficient Long-Text Understanding with Short-Text Models, 2022

Обработка длинного контекста

- Для обхода квадратичной сложности self-attention можно вместо увеличения длины последовательности передавать контекст рекурентно

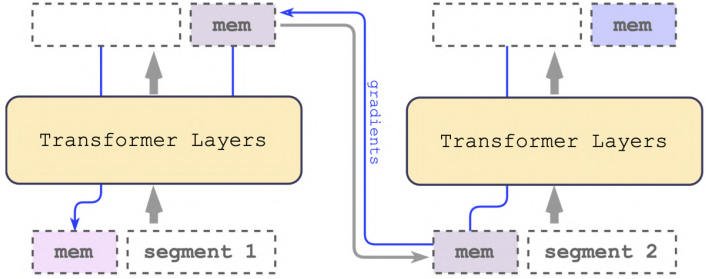

- Примеры работ:
  - Transformer-XL: Attentive Language Models Beyond a Fixed-Length Context, 2019
  - Scaling Transformer to 1M tokens and beyond with RMT, 2023

Обработка длинного контекста

- Для обхода квадратичной сложности self-attention можно вместо увеличения длины последовательности сохранять контекст в kNN-индексе

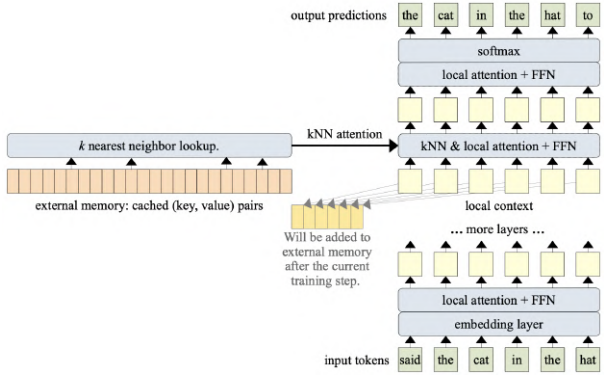

- Примеры работ:
  - Memorizing Transformers, 2022
  - Unlimiformer: Long-Range Transformers with Unlimited Length Input, 2023
  - Focused Transformer: Contrastive Training for Context Scaling, 2023

Мультимодальность

- Языковые модели можно использовать для понимания не только текста, но других модальностей: изображения, видео, аудио
- Популярный Vision Transformer, 2020, активно используется в качестве кодировщика изображений, похож на BERT:

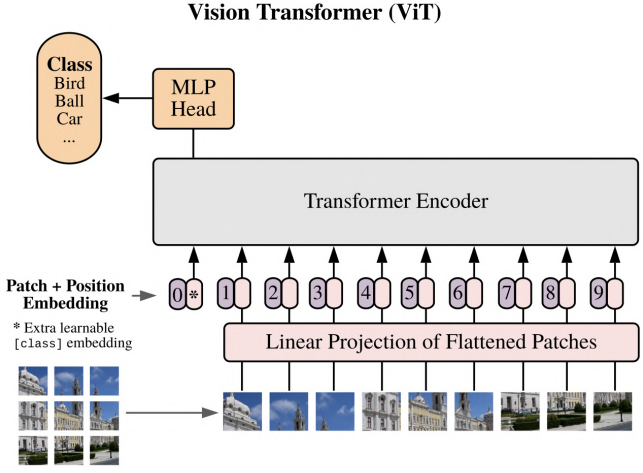

Мультимодальность

- Объекты разных модальностей можно погрузить в одно векторное пространство
- Можно собрать попарные данные между всеми модальностями — дорого и сложно
- А можно использовать в качестве связующего звена изображения, как в ImageBind, 2023:

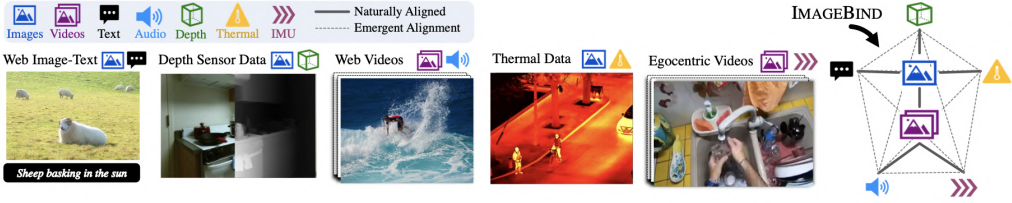

- Полученные векторы можно доучивать для передачи в LLM (например, NExT-GPT и ImageBind-LLM, 2023)

Мультимодальность

- В итоговом пространстве можно складывать векторы разных модальностей:

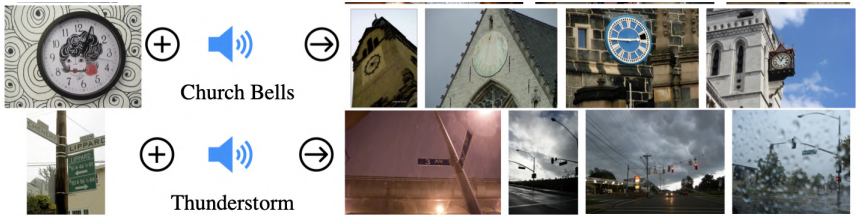

- Внешней модели сегментации с векторизатором (CLIP) на входе можно подсунуть вектор аудио:

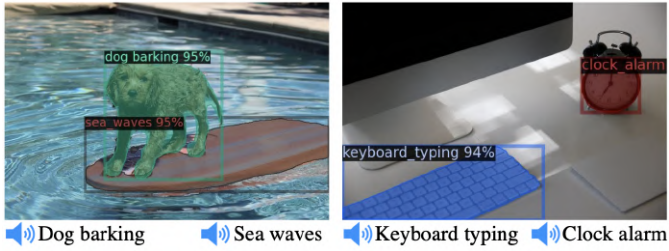

Мультимодальность

- LLM над общими векторами с диффузионными генераторами дают системы, принимающие и генерирующие объекты разных модальностей (NExT-GPT):

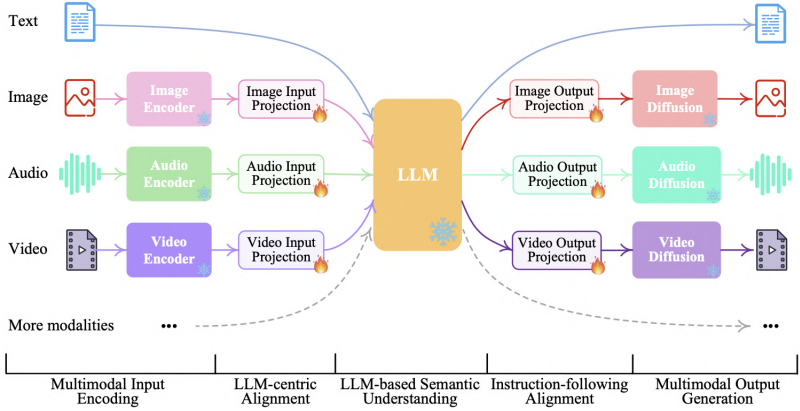

- В таких случаях тяжёлые модели обычно заморожены, а учатся проекционные слои и адаптеры

Оценка качества LLM

- Способности моделей проверяются путём решения разных текстовых или мультимодальных задач на разных наборах данных
- Схема различных NLP-задач и соответствующих данных (синие — с короткими ответами, бирюзовые — с длинными):

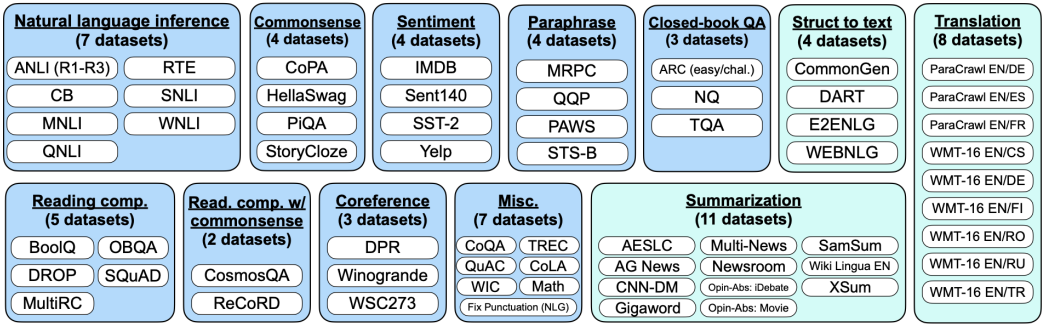

Оценка качества LLM

- Из отдельных наборов данных формируют коллекции — бенчмарки
- Бенчмарков много для разных задач, длины контекста, доменов, языков и модальностей, примеры популярных:
  - MMLU, 2020 (тексты, английский)
  - HumanEval, 2021 (программный код, английский)
  - MMBench, 2023 (тексты и изображения, английский)
  - LongBench, 2023 (длинные тексты, английский)
  - MERA, 2023 (тексты, русский)
- Проверка коротких ответов автоматическая, с длинными сложнее — автометрики слабые, проверяют люди или более сильные LLM (GPT-4):

  «Ты выступаешь в роли асессора. Тебе покажут правильный пересказ текста и пересказ, сгенерированный моделью, твоя задача оценить по шкале от 1 до 10 качество генерации пересказа . . . »

Спасибо за внимание!

Мурат Апишев
Search Tech Lead, Samokat.Tech
ex-Lead Data Scientist, SberDevices
mel-lain@yandex.ru