SUBLLM新架构：文本下采样机制革新大语言模型效率

王全东 小米大模型团队

演讲嘉宾

王全东

小米大模型团队 大模型高级算法工程师

中国科学院声学研究所博士、美国佐治亚理工访问学者、中科院认证高级工程师，长期从事大语言模型、多模态、语音识别等领域研究，曾获多项顶会竞赛冠亚军奖项，已发表顶会论文十余篇，拥有专列多项。深度参与了小米自研大模型从0到1的研发过程，荣获2024年度CCF计算机应用创新技术一等奖。近期和Daniel Povey等提出SUBLLM新架构，被量子位等科技媒体报道。

目录
CONTENTS

PART 01
长文本模型的技术挑战

长文本模型的技术挑战

长文本需求旺盛

多人会议摘要

行业报告
新闻摘要

学术论文分析

长文写作
长篇翻译

...

长文本模型的技术挑战

长文本模型结构：

Decoder only Transformer结构：Llama 类似结构，attention的平方复杂度

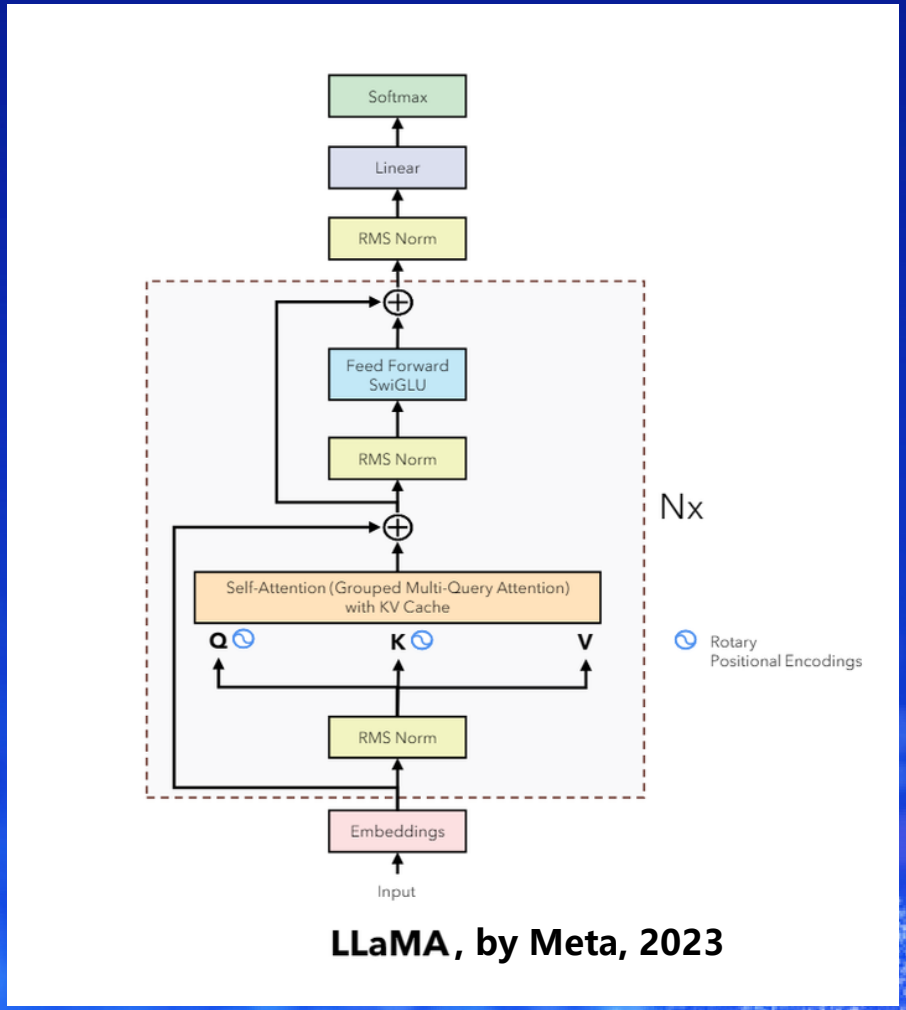

LLaMA, by Meta, 2023

长文本模型的技术挑战

训练成本高：attention的平方复杂度

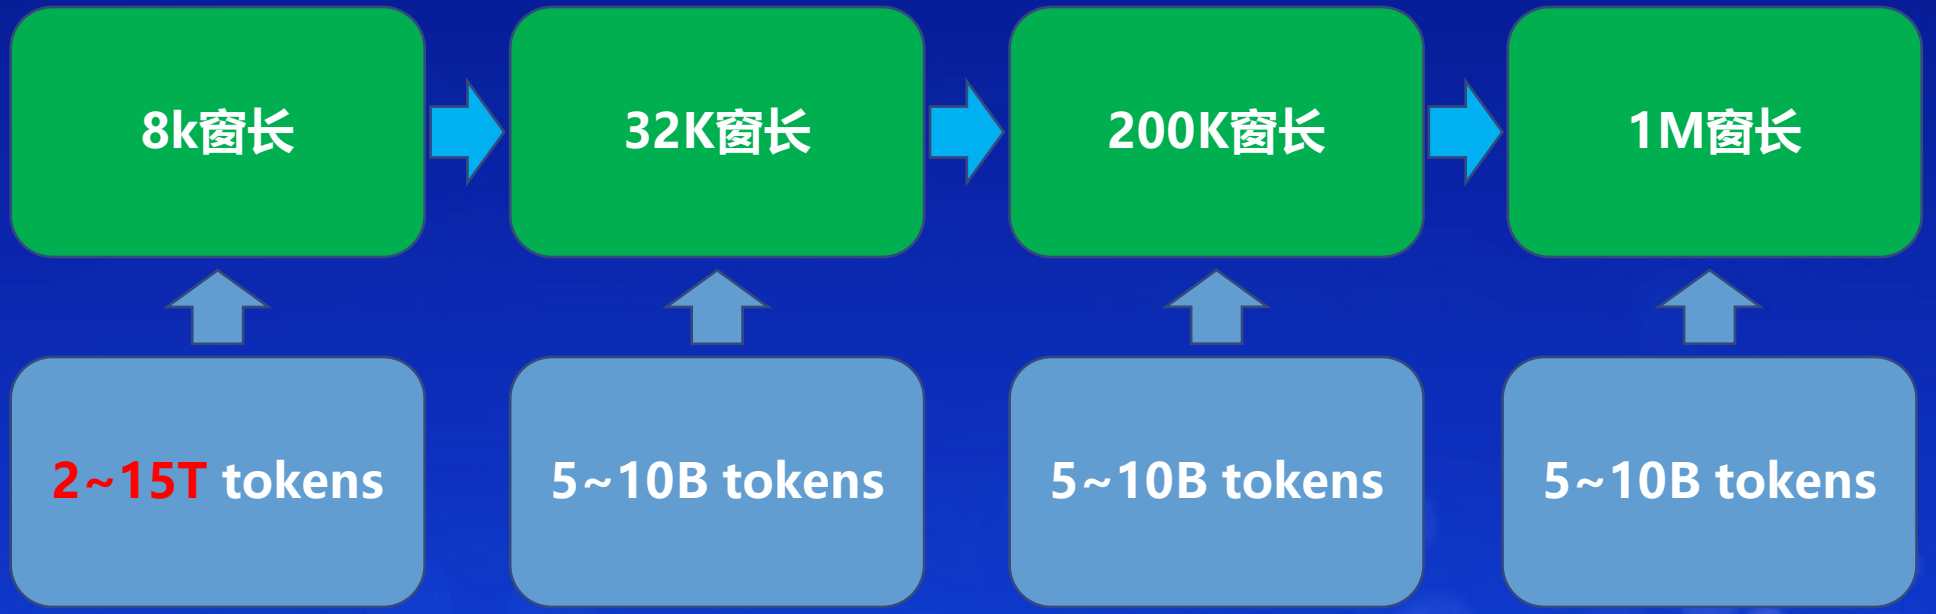

主要优化点

长文本模型的技术挑战

模型窗长扩展方法：数据方向，训练成本不高

1. Data Engineering for Scaling Language Models to 128K Context

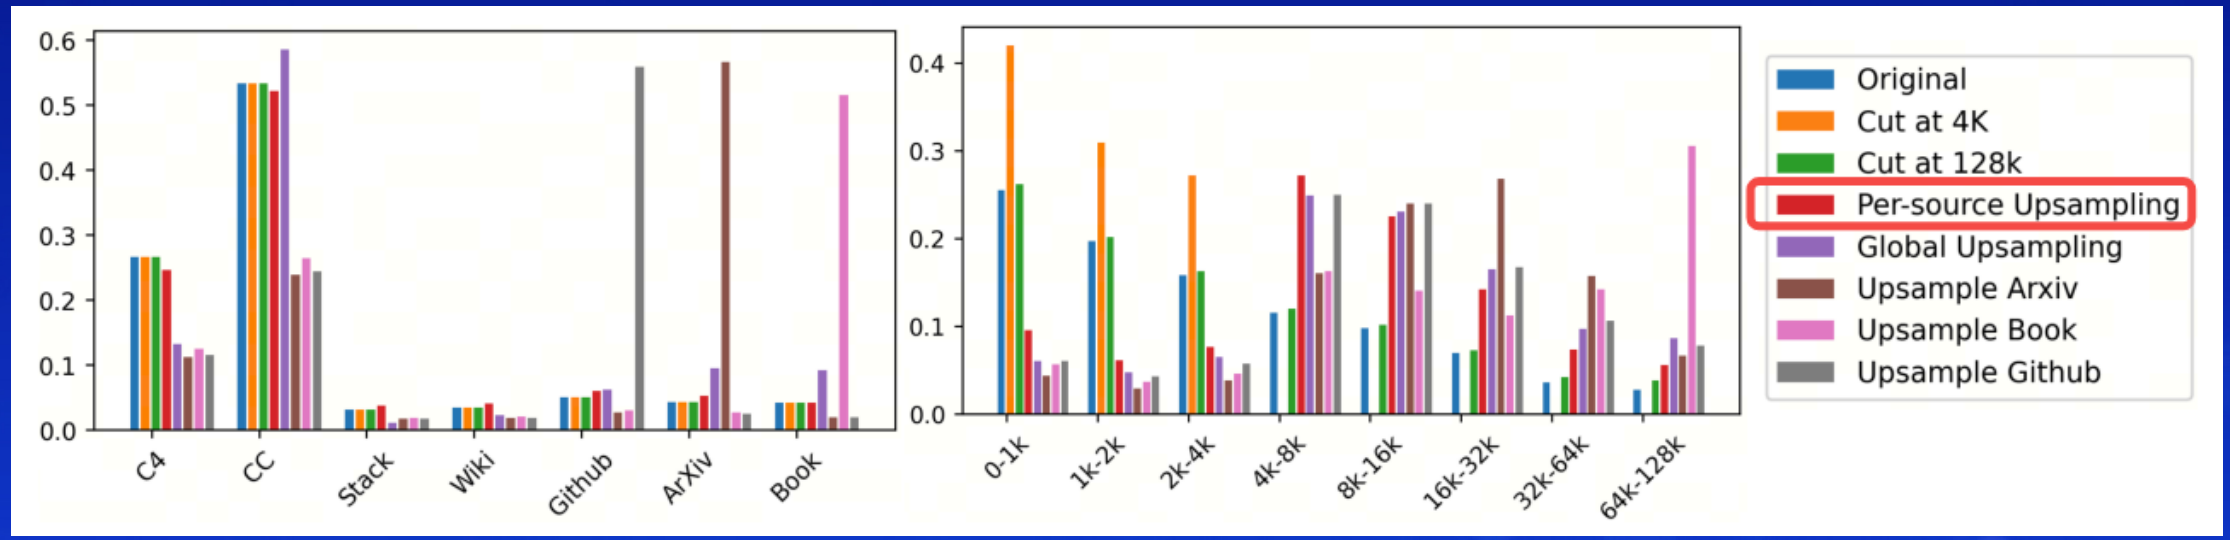

长文本模型的技术挑战

模型窗长扩展方法：位置编码方向，训练成本不高

2. YaRN: Efficient Context Window Extension of Large Language Models

NTK-by-parts + 温度控制

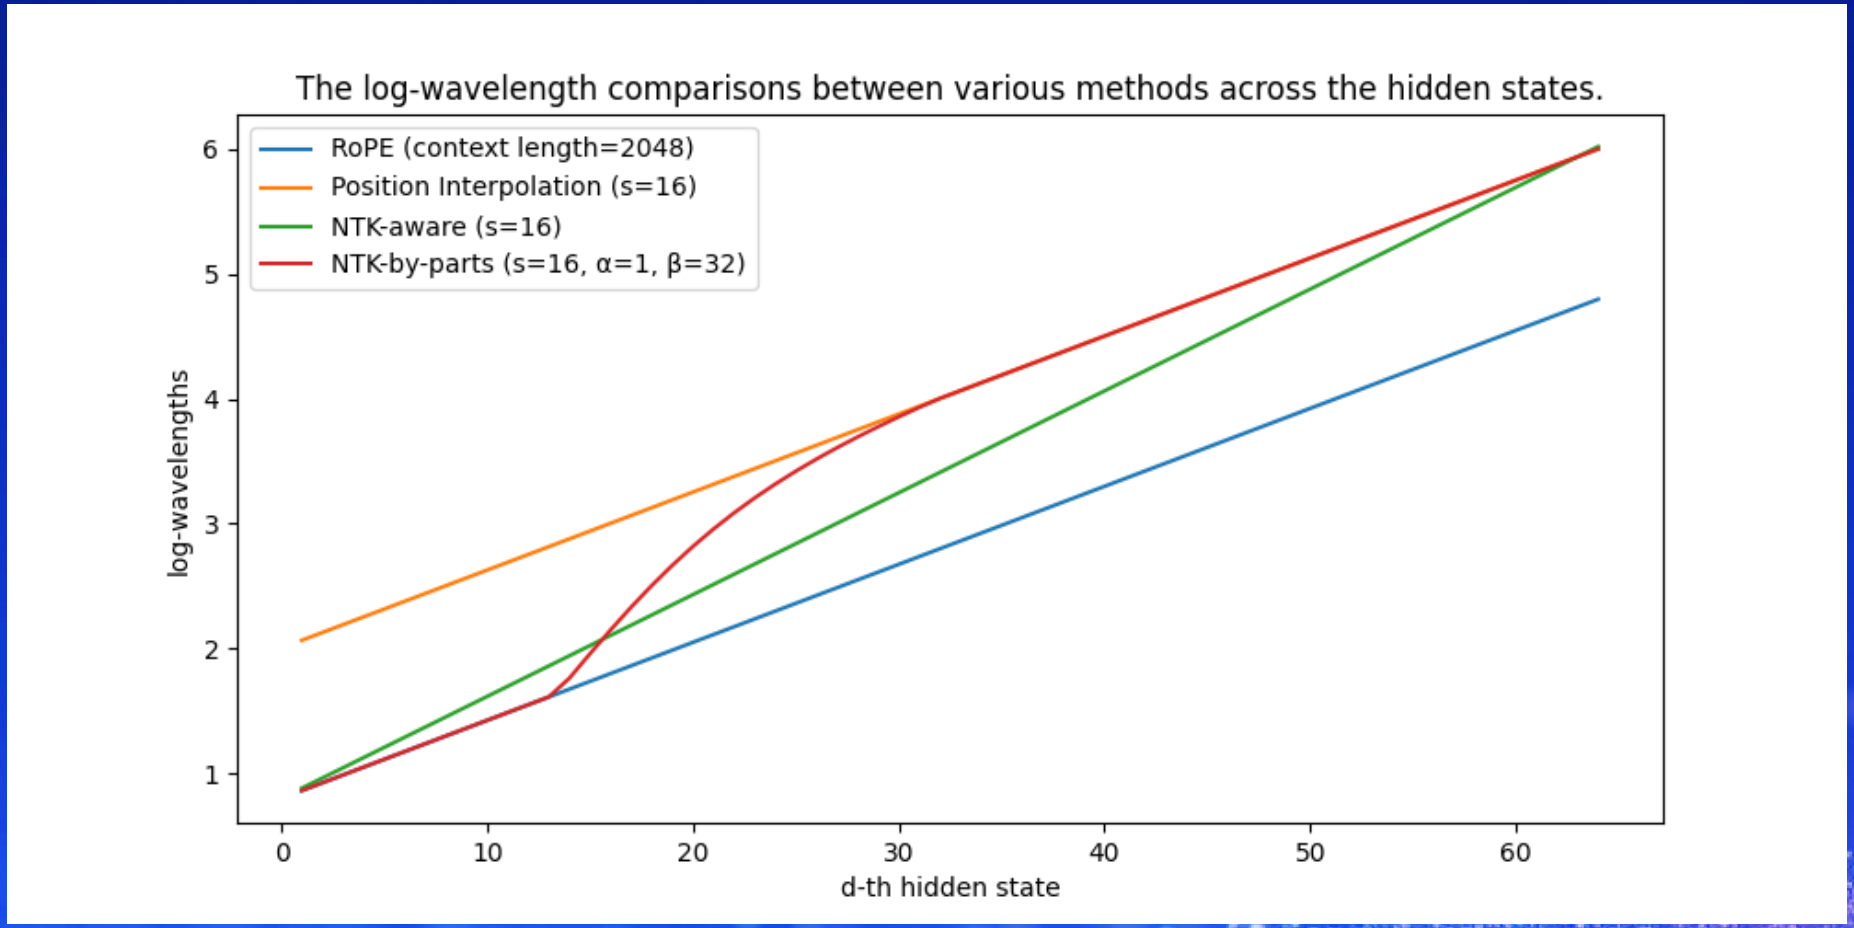

长文本模型的技术挑战

模型窗长扩展方法：位置编码方向，训练成本不高

3. PoSE: Efficient Context Window Extension of LLMs via Positional Skip-wise Training

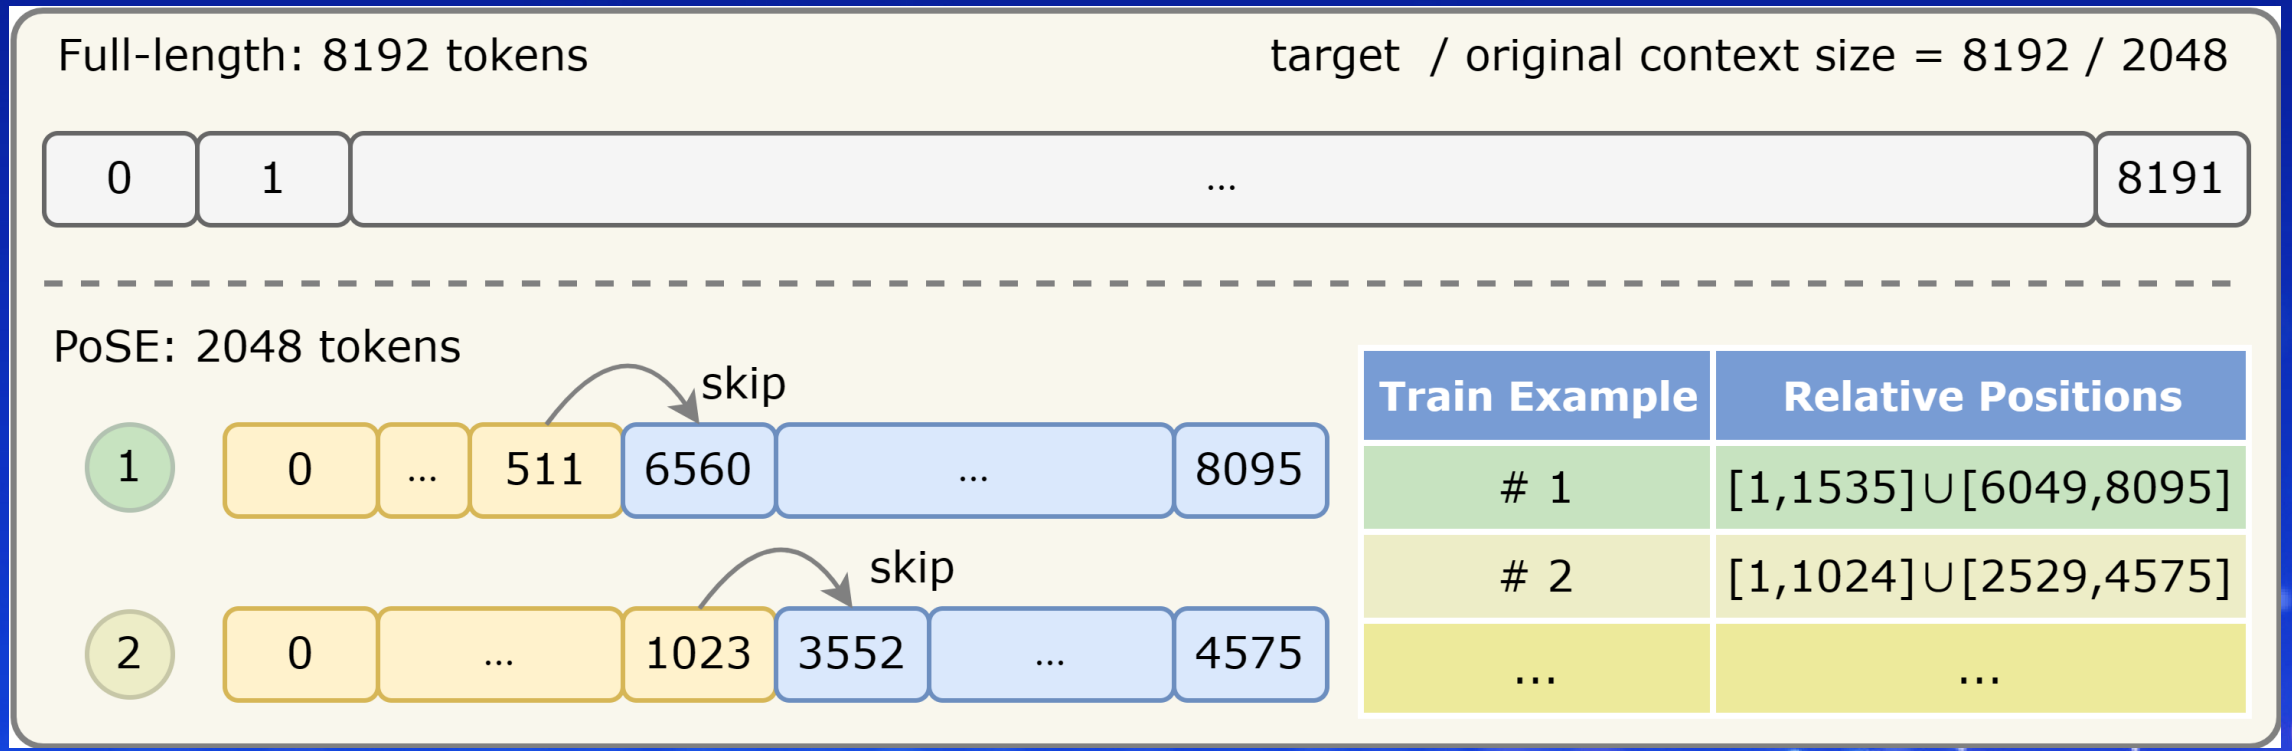

Train Example	Relative Positions
# 1	[1,1535]∪[6049,8095]
# 2	[1,1024]∪[2529,4575]
...	...

长文本模型的技术挑战

训练成本主要在8k预训练阶段：attention的平方复杂度

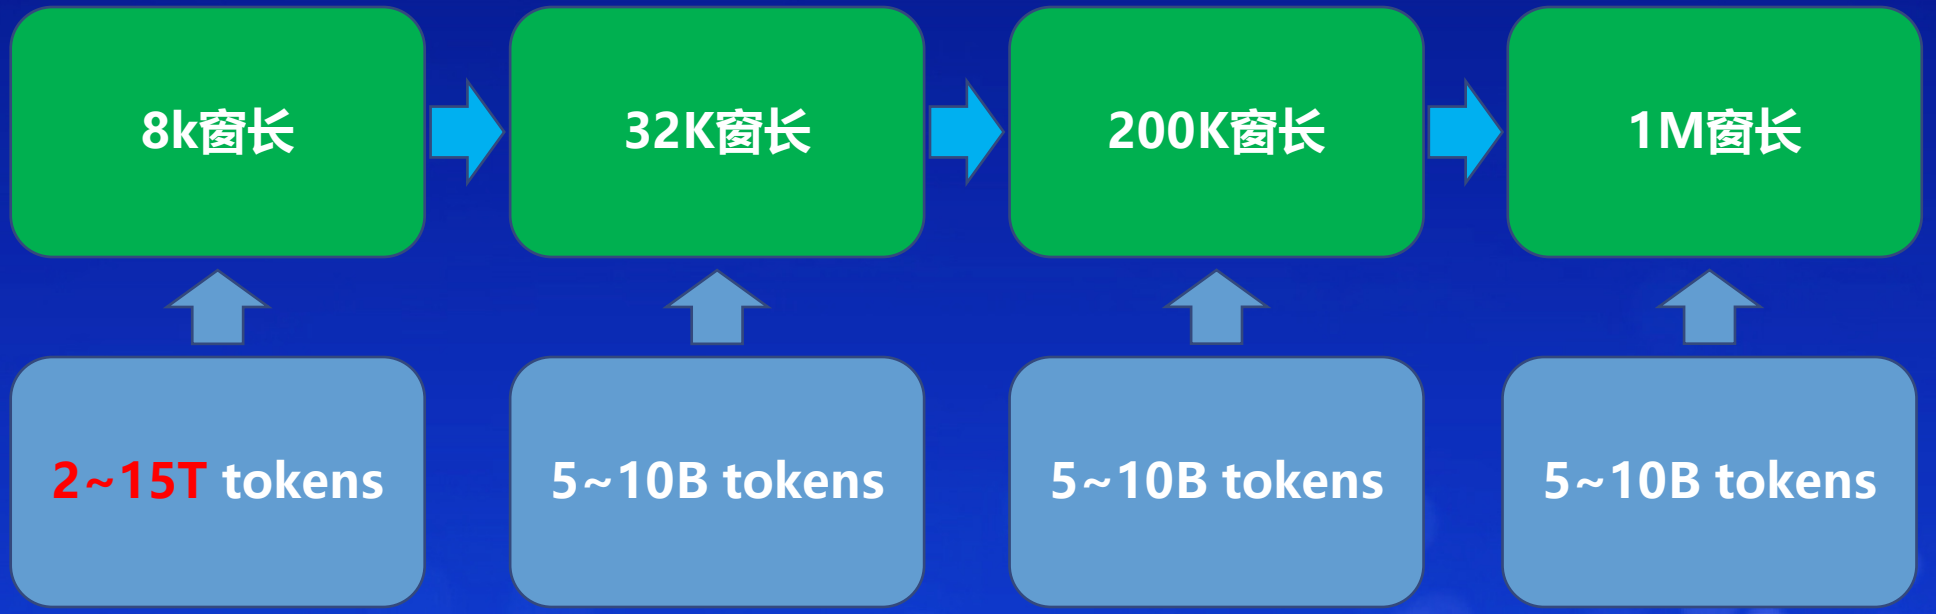

主要优化点

长文本模型的技术挑战

Decoder only Transformer长文本模型训练infra开发

1. DeepSpeed Ulysses：
   优势：对Attention 的实现不敏感，适合各种attention方法
   劣势：序列并行度不能超过头数

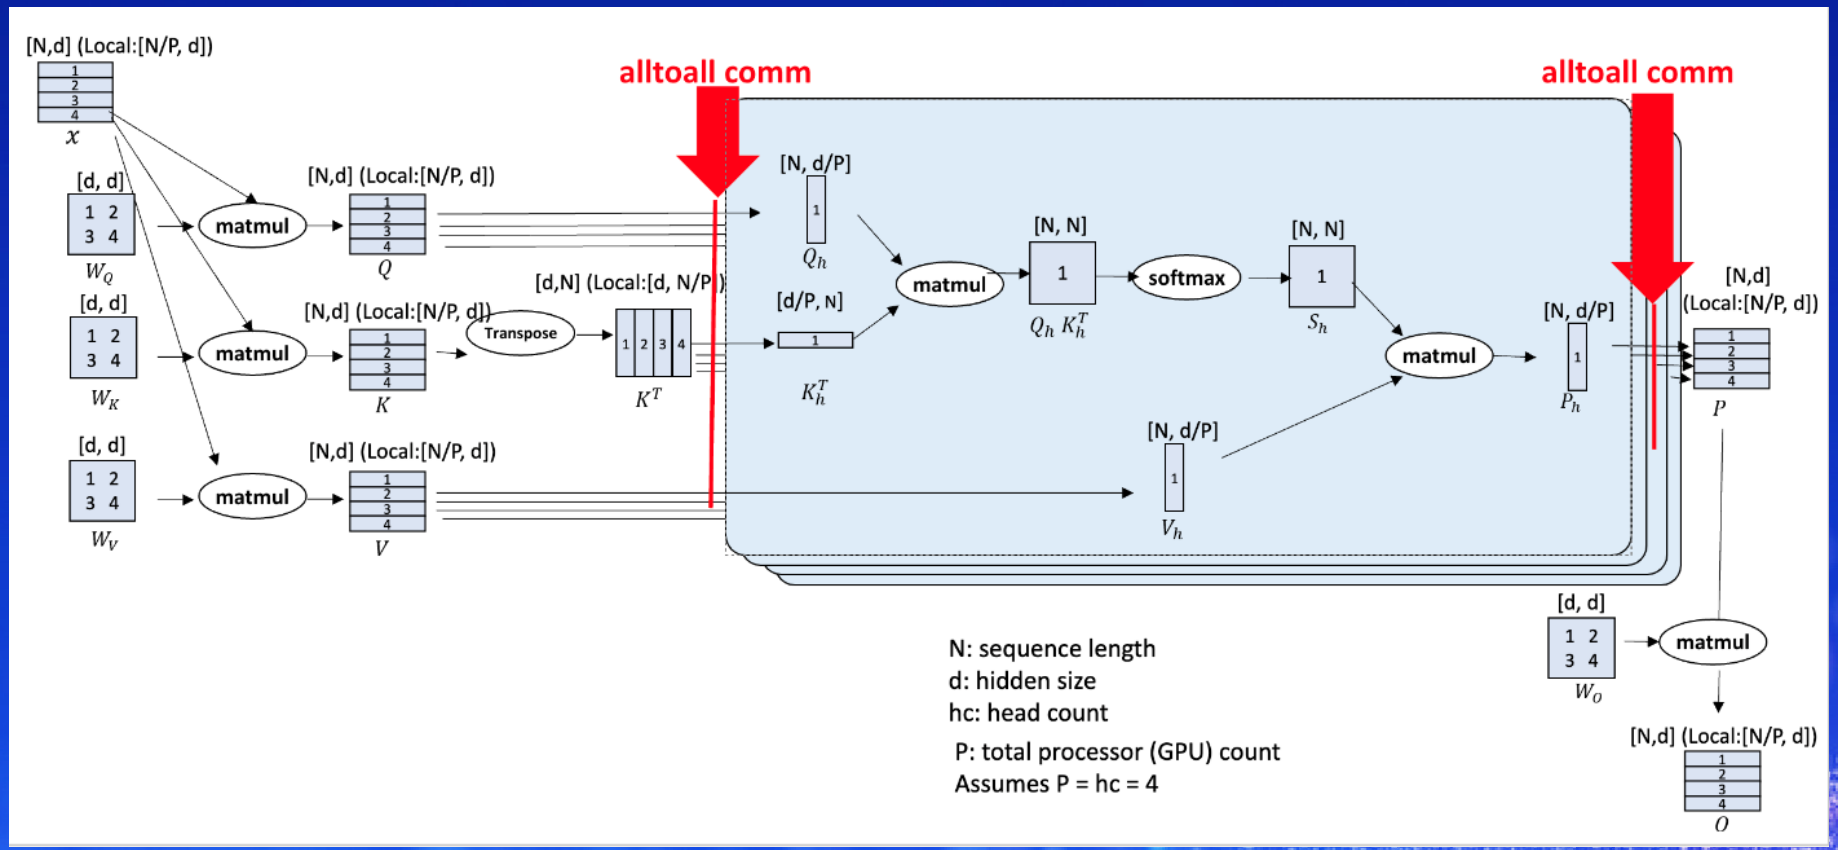

长文本模型的技术挑战

Decoder only Transformer长文本模型训练infra开发

2. Ring-attention：“大号”的flash attention

优势：并行度的扩展性较好

劣势：对Attention 变种不友好，eg. Sparse Attention

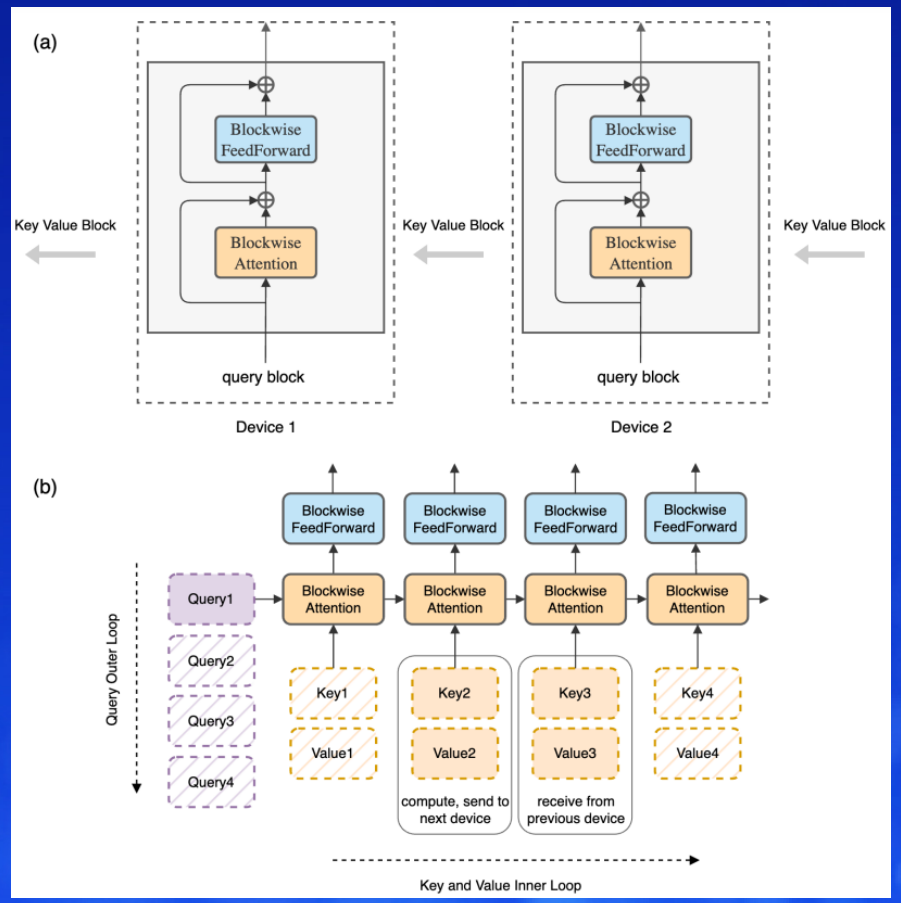

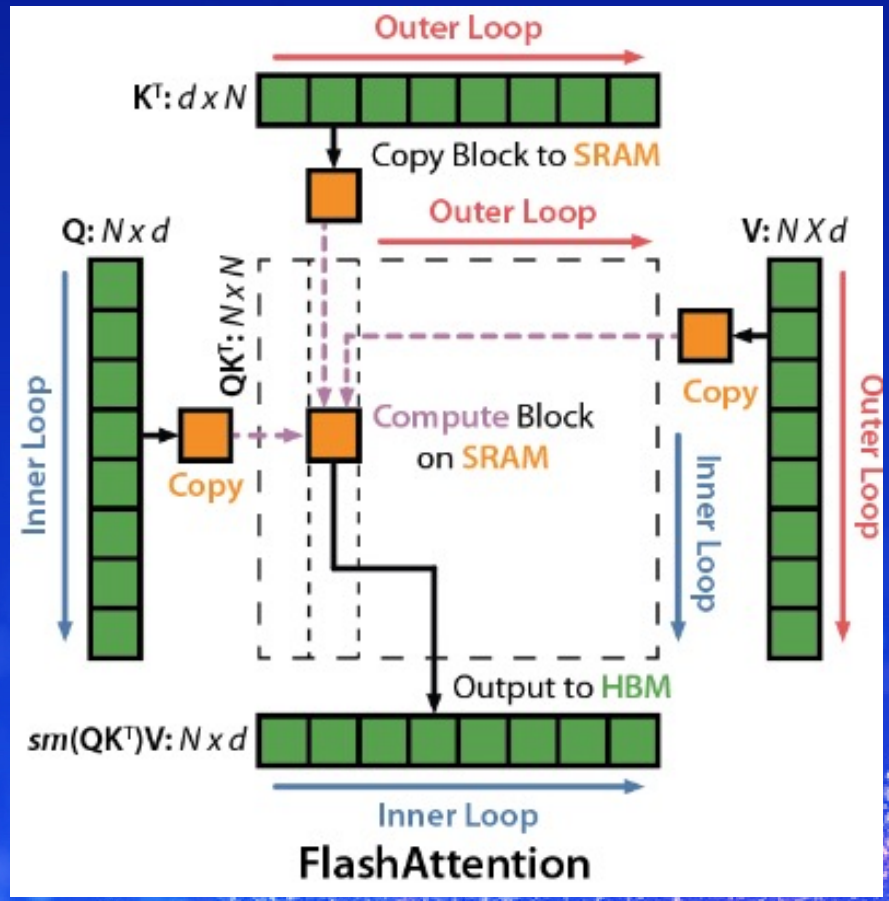

长文本模型的技术挑战

推理成本高：attention的平方复杂度
推理速度角度，200k 比 20k 贵28倍，比2k 贵112倍

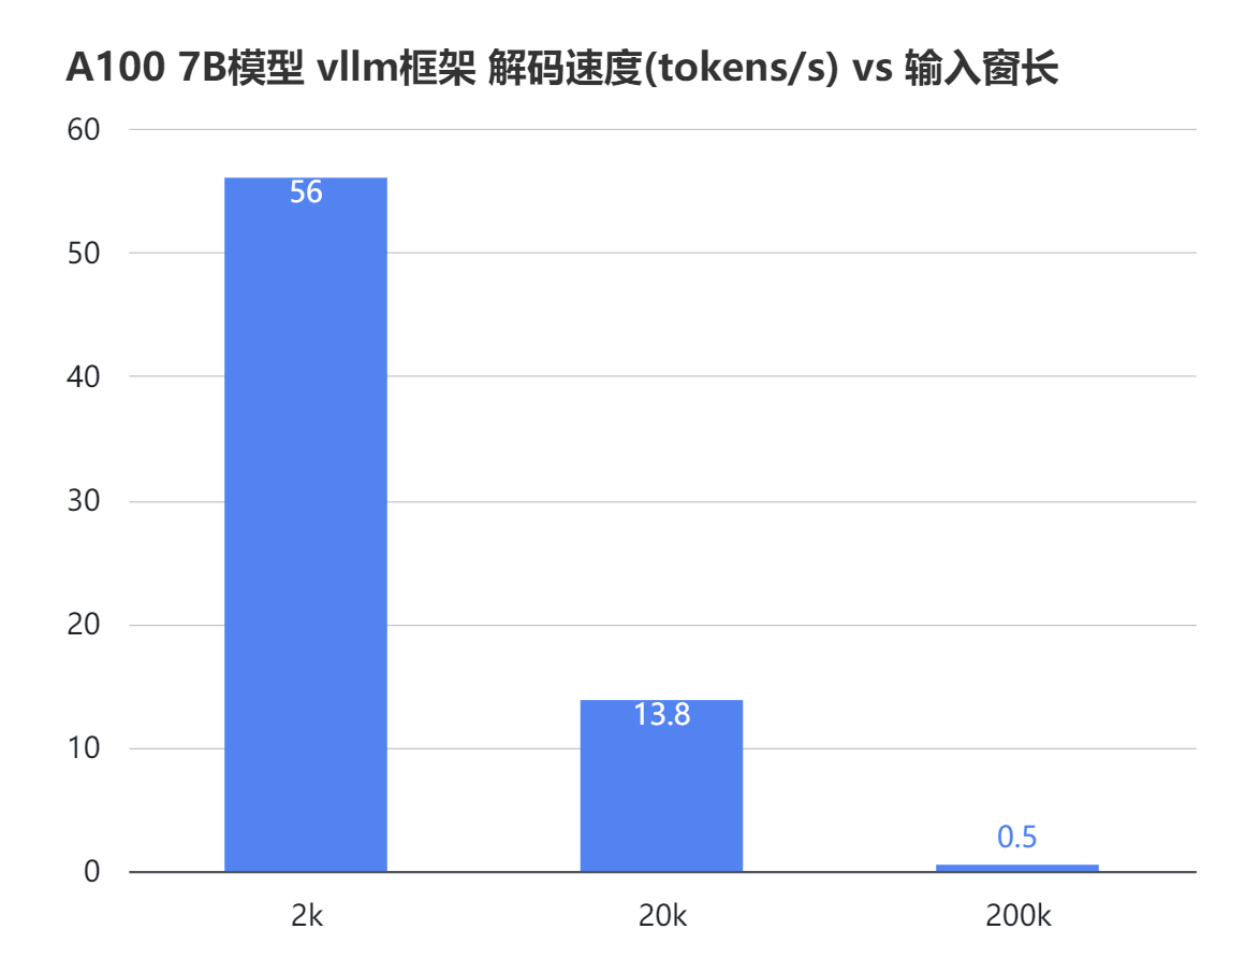

长文本模型的技术挑战

其他长文本模型结构：

1. Infini-Transformer：长期压缩记忆和局部因果注意力attention

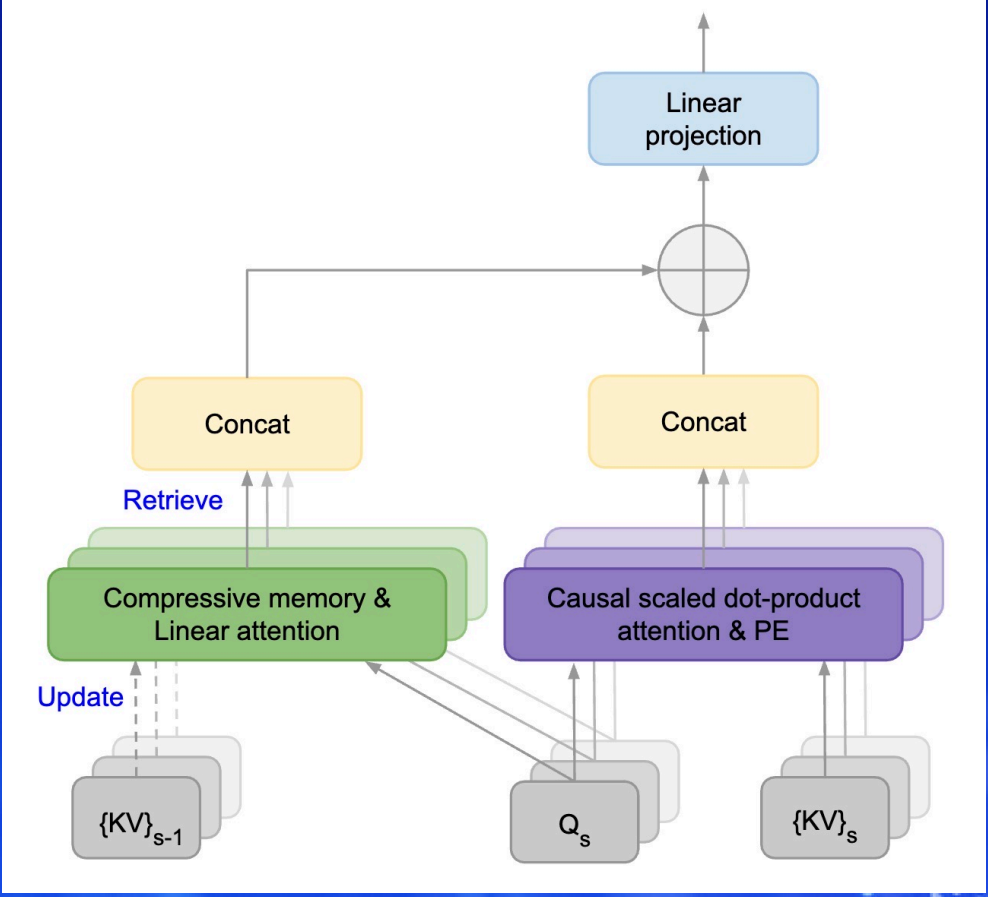

Infini-Transformer 模型结构 by Google, 2024

长文本模型的技术挑战

其他长文本模型结构：

2. MEGALODON：继承MEGA(带有门控注意力的指数移动平均) 并改进

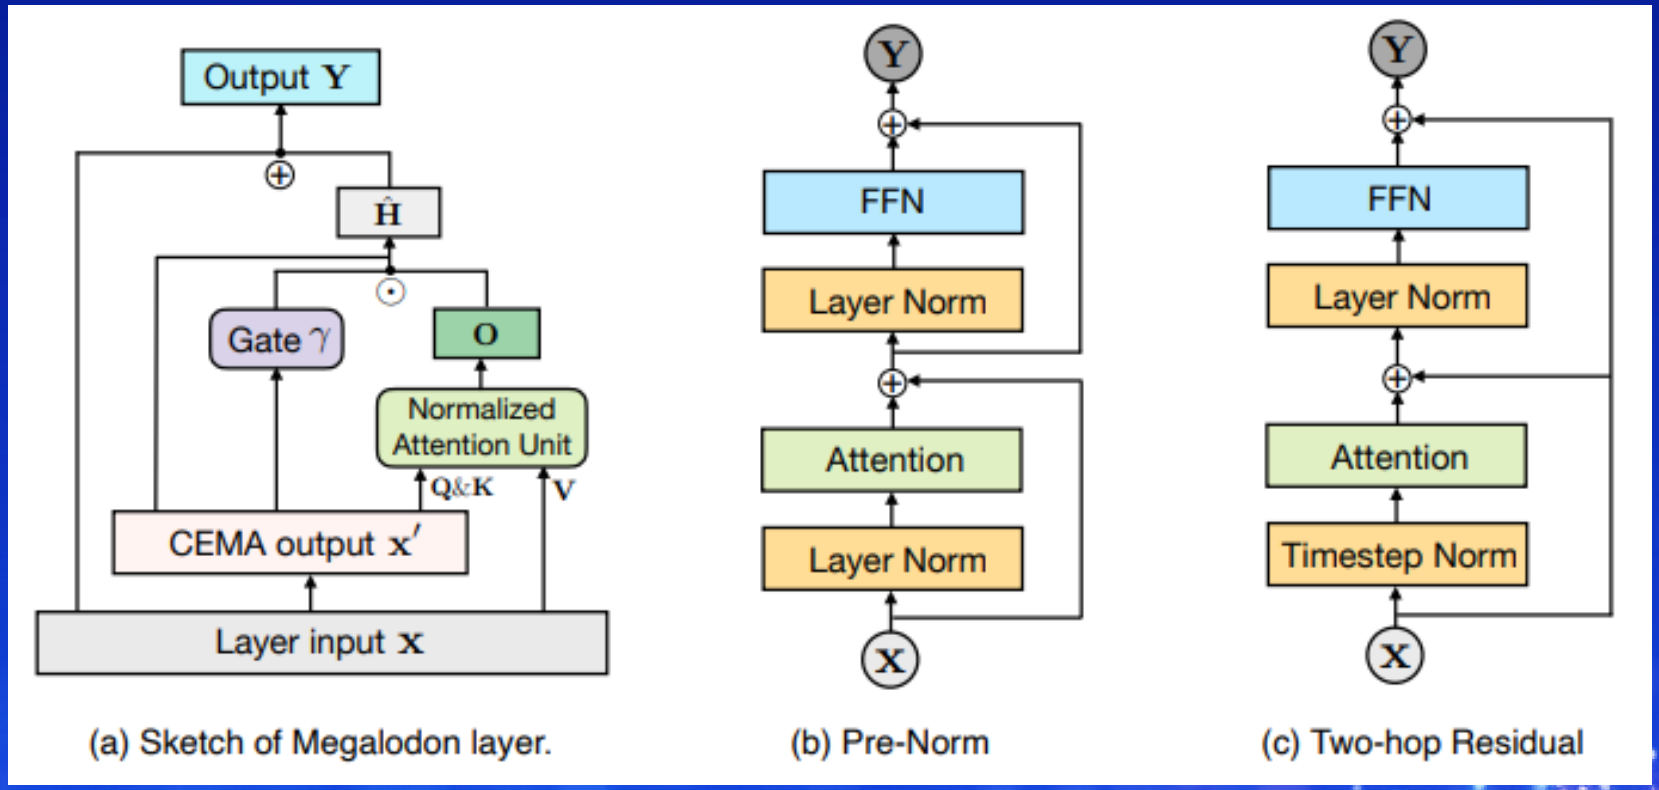

MEGALODON 模型结构 by Meta, 2024

长文本模型的技术挑战

加速方法很多 备受关注 SUBLLM应运而生

方法	推理加速	训练加速	Attention based大模型	兼容主流attention预训练大模型：eg. Llama,可持续训练	减少kv cache	官方开源
投机解码	√	×	√	√	×	√
medusa	√	×	√	√	×	√
动态稀疏attention：eg. Minference	√	×	√	√	×	√
Kv cache压缩/剪裁：eg. StreamingLLM,H2O,DMC,CEPE	√	×	√	√	√	√
CoLT5	√	√	√	×	×	×
Mamba2,RWKV	√	√	×	×	×	√
RecurrentGemma: rnn+local attention	√	√	×	×	√	√
YOCO	√	√	√	×	√	√
MEGALODON	√	√	√	×	√	√
Infini-Transformer	√	√	√	√	√	×
Mixture-of-depths	√	√	√	√	√	×
SUBLLM	√	√	√	√	√	√

PART 02
SUBLLM架构

SUBLLM架构

目标:

1. 开发一种优化资源使用的架构，同时保持模型能力不变。

2. 区分重要token和不重要token，重要token占主要算力

3. 兼容现有attention based模型生态，模型广泛应用的关键

SUBLLM架构

受语音领域启发：语音信号下采样减少冗余 保留必要信息

语音识别中语音分帧后降采样4倍

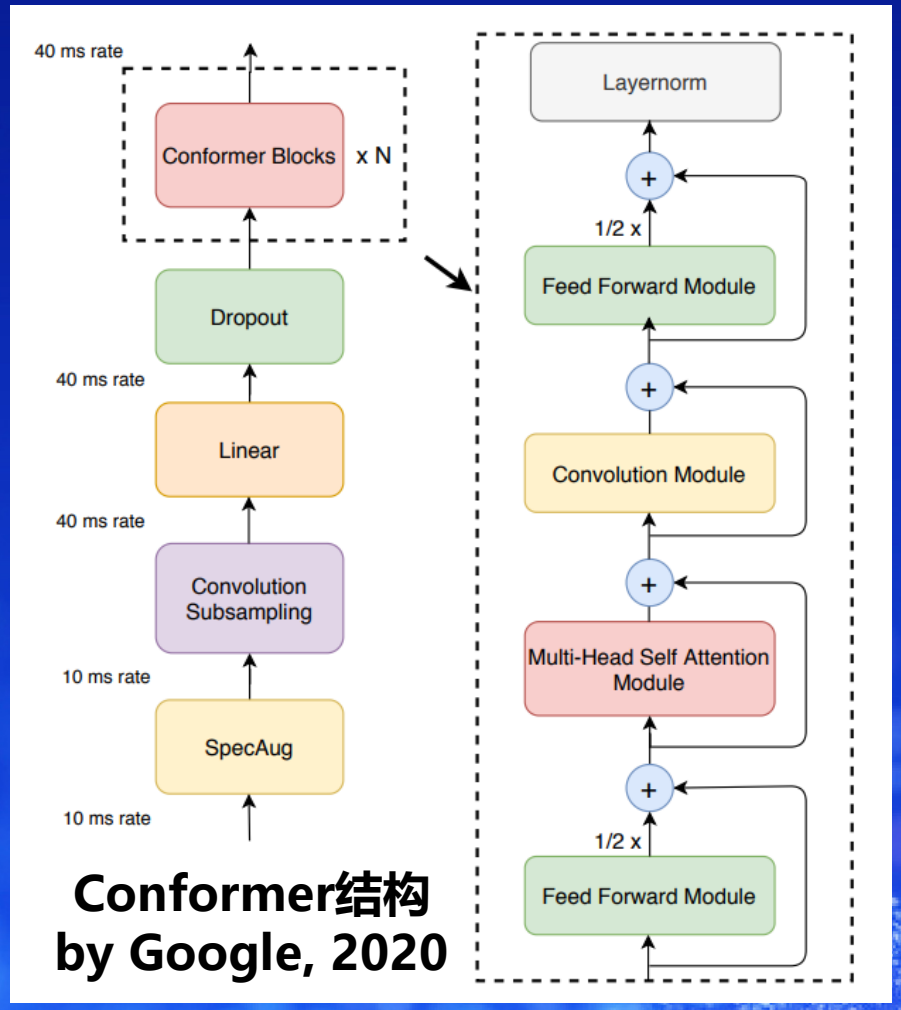

Conformer结构
by Google, 2020

SUBLLM架构

受语音领域启发：语音信号下采样减少冗余 保留必要信息

语音识别Zipformer，最高降采样16倍

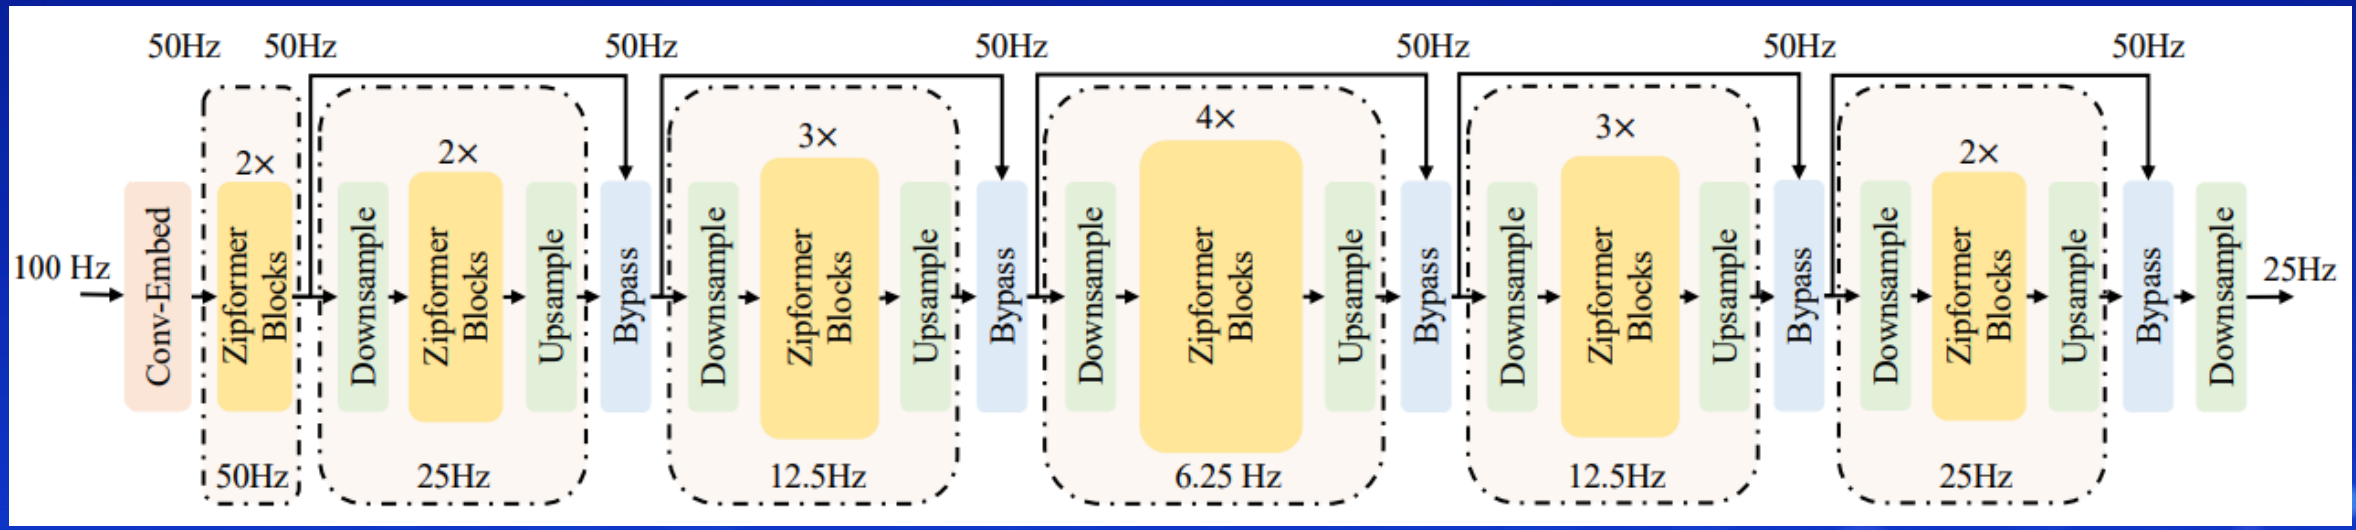

Zipformer 模型结构 by Daniel Povey, 2024

SUBLLM架构

受语音领域启发：语音信号下采样减少冗余 保留必要信息

文本序列是否存在冗余？Yes!

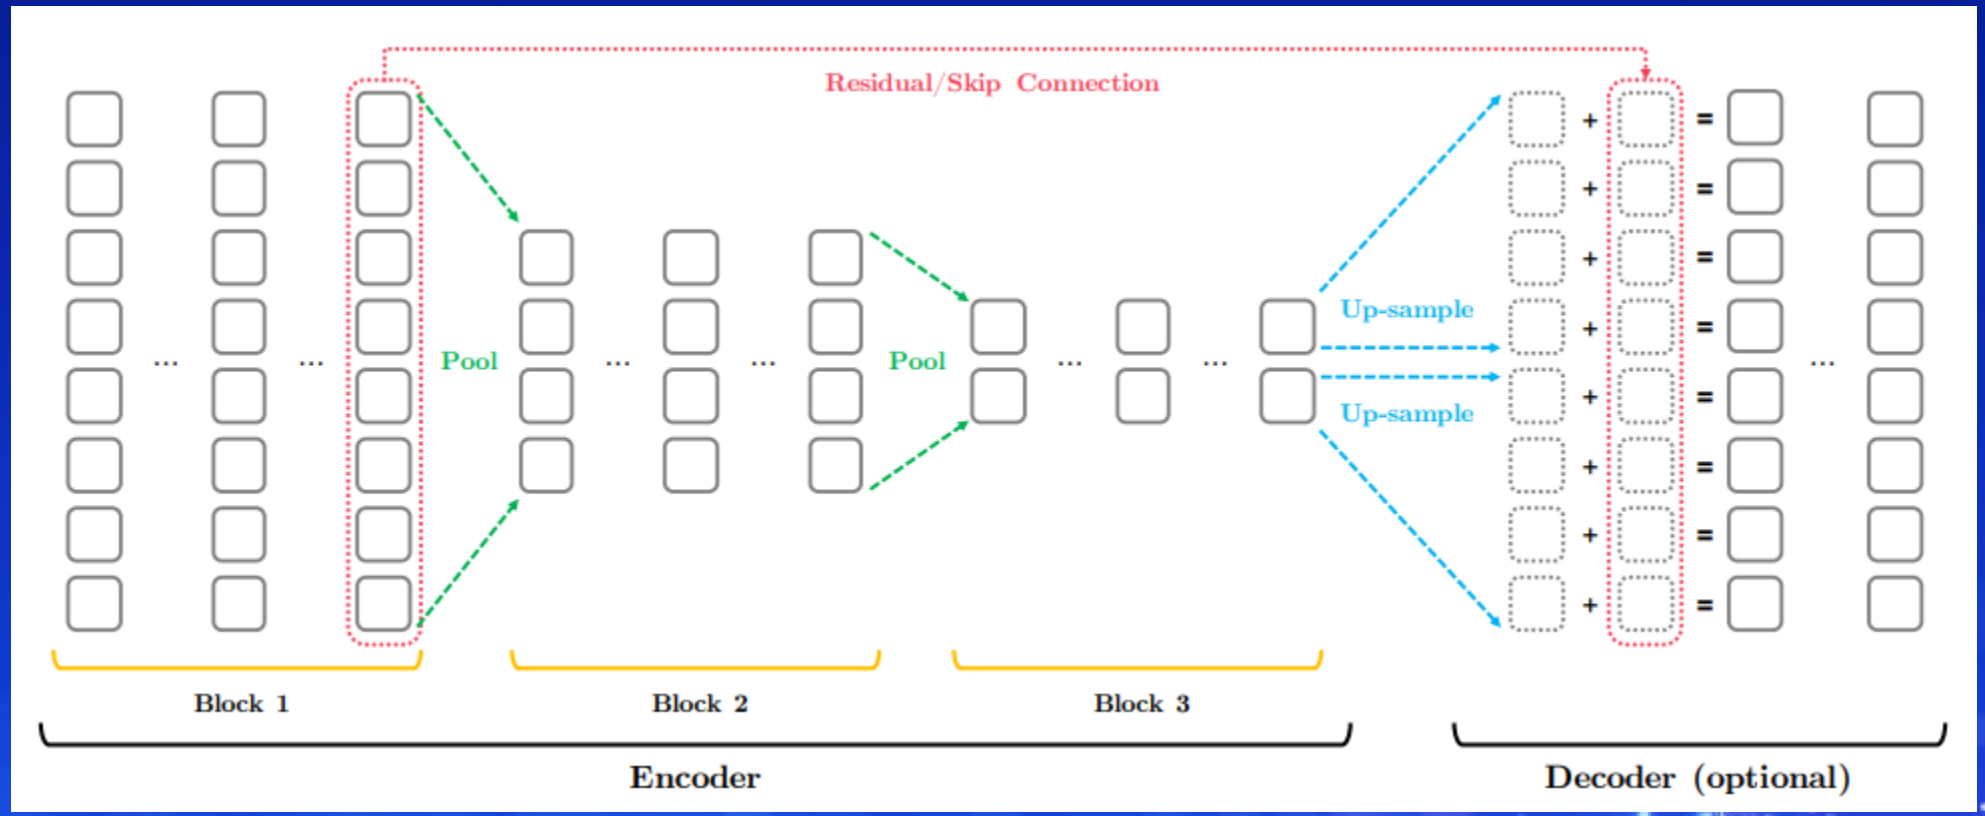

Funnel-Transformer 模型结构 by Google, 2020

SUBLLM架构

受语音领域启发：语音信号下采样减少冗余 保留必要信息

文本序列是否存在冗余？Yes!

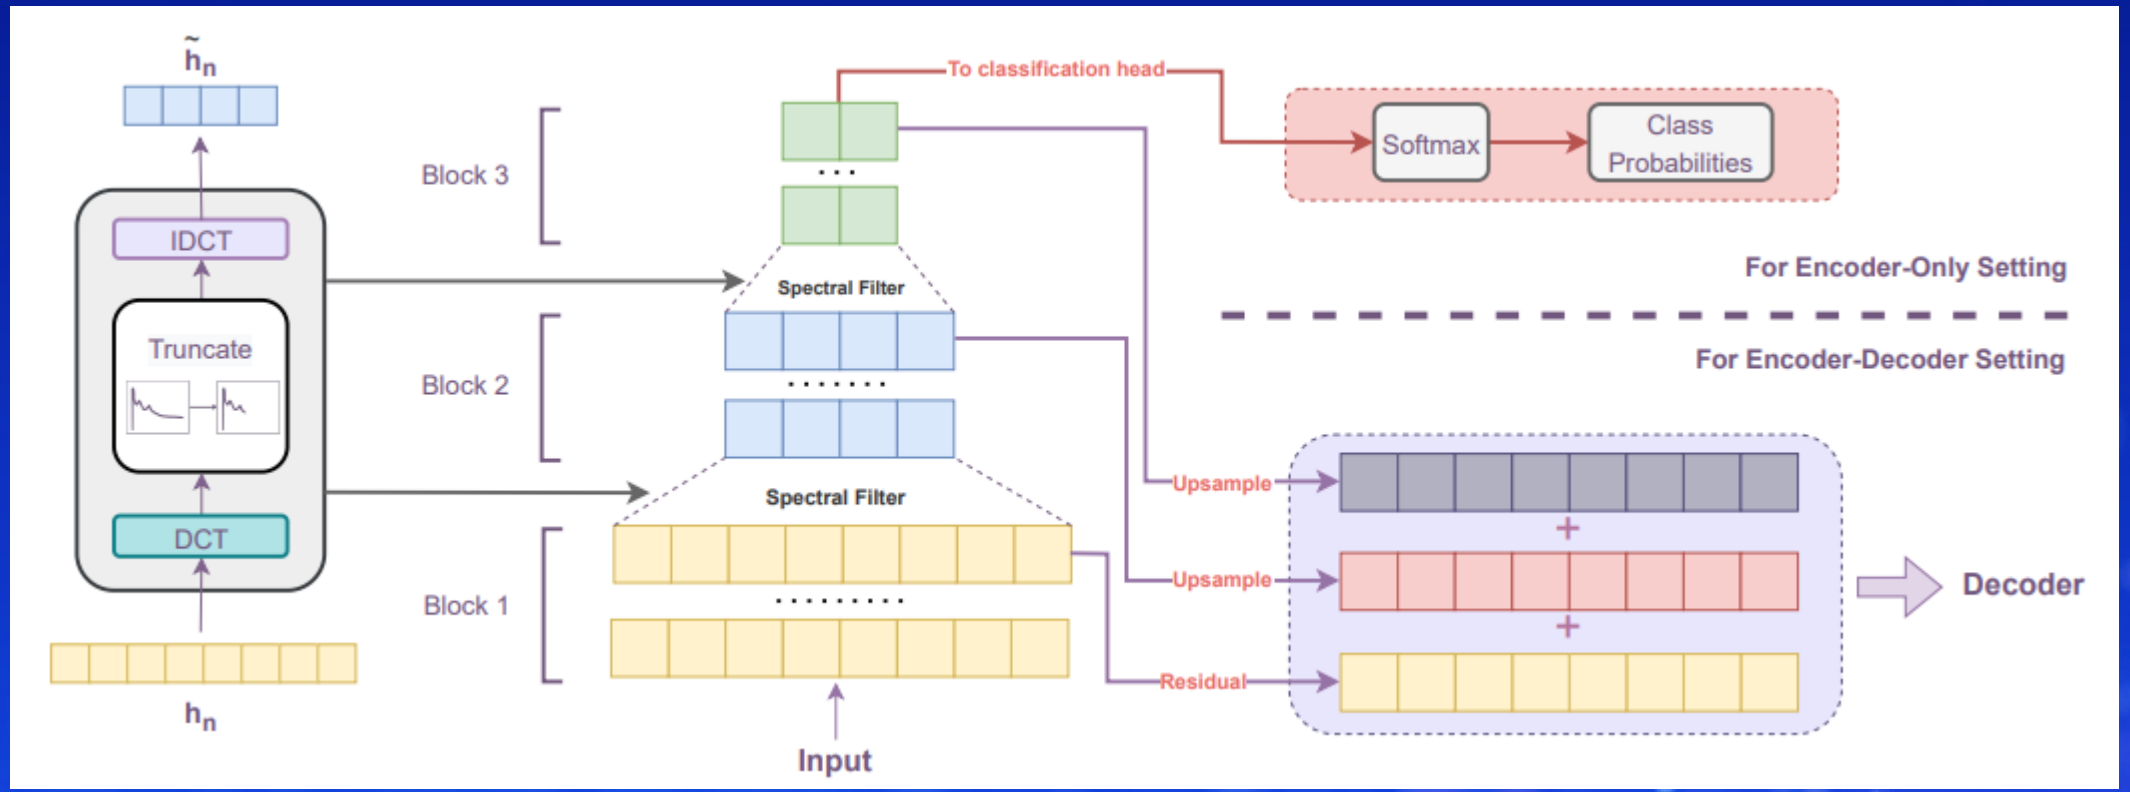

Fourier Transformer 模型结构, 2023

SUBLLM架构

受语音领域启发：语音信号下采样减少冗余 保留必要信息

文本序列中的token是否同等重要？No!

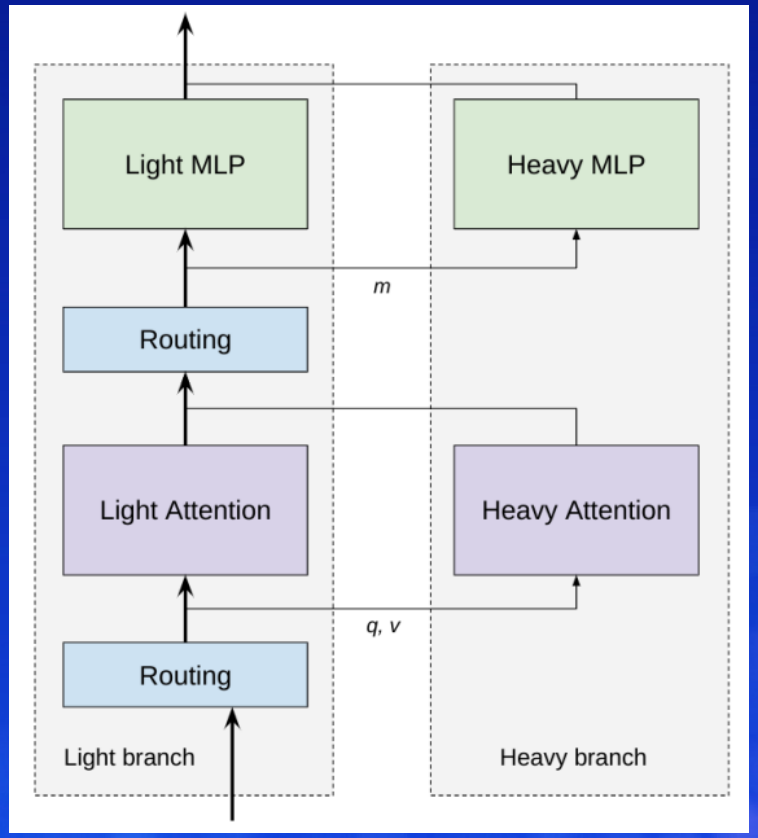

CoLT5 模型结构 by Google, 2023

SUBLLM架构

受语音领域启发：语音信号下采样减少冗余 保留必要信息

SUBLLM：采样(Sub-sampling)-上采样(Up-sampling)-旁路(Bypass) LLM

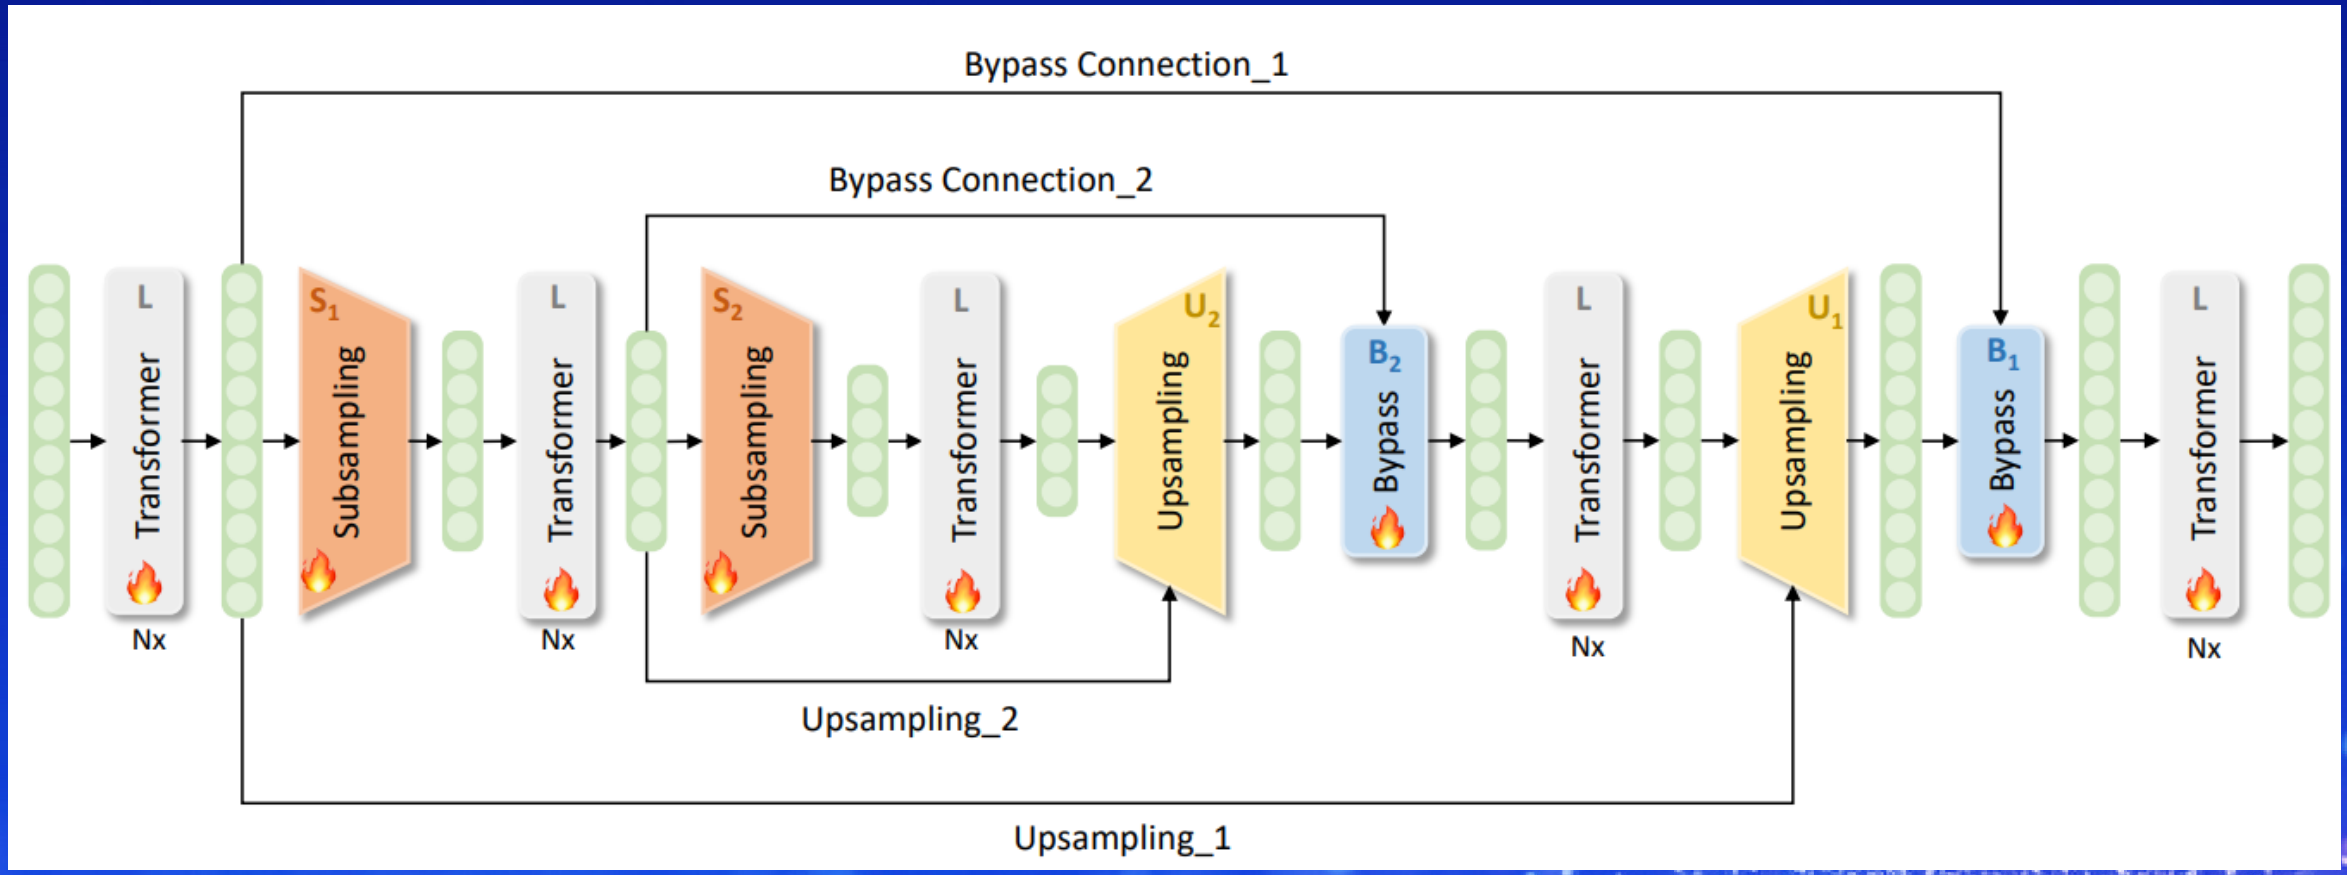

SUBLLM 模型结构 by 小米AI实验室
https://arxiv.org/pdf/2406.06571，accepted by ECAI 2024

SUBLLM架构

受语音领域启发：语音信号下采样减少冗余 保留必要信息

SUBLLM：采样(Sub-sampling)-上采样(Up-sampling)-旁路(Bypass) LLM

Blocks	S/U Num	Model representation
15	1	$5L\_S_1\_5L\_U_1\_B_1\_5L$
15	2	$3L\_S_1\_3L\_S_2\_3L\_U_2\_B_2\_3L\_U_1\_B_1\_3L$
24	2	$5L\_S_1\_5L\_S_2\_4L\_U_2\_B_2\_5L\_U_1\_B_1\_5L$

新模块插入位置示例，嵌套结构，逐渐下采样+逐渐上采样

SUBLLM架构

Learnable Subsampling Module

1. 通过去除不太重要的tokens来缩短序列长度
2. 使用Score层来衡量token的重要性

序列采样，index选择
预设采样保留比例d

$$\mathbf{x}' = \textsc{IndexSelect}(\mathbf{x}, \mathcal{I}) = x_{\mathcal{I}_1}, \ldots, x_{\mathcal{I}_{N'}}$$

$$N' = \lceil N * d \rceil$$

Score层给每个token打分
再得到weight

$$\mathbf{s} = s_1, \ldots, s_N = \mathcal{S}(\mathbf{x}_1), \ldots, \mathcal{S}(\mathbf{x}_N)$$

$$w_n = \textsc{Clamp}(\textsc{Balancer}(s_n, [0, 1]))$$

$$\mathbf{w} = w_1, \ldots, w_N$$

保留index，舍弃index

$$\mathcal{I} = \{i | w_i \in \textsc{TopK}(\mathbf{w}, N')\}$$

$$\hat{\mathcal{I}} = \{i | w_i \notin \textsc{TopK}(\mathbf{w}, N')\}$$

SUBLLM架构

Learnable Subsampling Module
妙处1：解决训练和推理的不一致性

位置编码下采样

$$RelPos(\mathbf{x}'_i, \mathbf{x}'_j) = \text{RoPE}(\mathbf{x}'_i, \mathbf{x}'_j, (\mathcal{I}_i - \mathcal{I}_j))$$

Inference Mode：推理时看不到未来token，设定阈值为0，正数分值的token保留

$$\mathcal{I}_{infer} = \{i | w_i \geq v\}$$

Balancer：通过对梯度进行惩罚来限制score的正数比例=预设下采样保留比例
只保留正数分值的token

SUBLLM架构

Upsampling Module

通过将采样后的tokens与原始序列合并来恢复序列长度

妙处2：用减法使得token的完全选择可导，使score层有token判别能力

$$
\begin{aligned}
\mathbf{w}_{kept} &= \text{INDEXSELECT}(\mathbf{w}, \mathcal{I}) \\
\mathbf{w}_{discarded} &= \text{INDEXSELECT}(\mathbf{w}, \hat{\mathcal{I}}) \\
\mathbf{w}_{sample_i} &\sim \text{UNIFORM}(\mathcal{E}), \text{ for } i = 1, 2, ..., N' \\
\mathbf{w}_{scaling} &= \mathbf{w}_{kept} - \mathbf{w}_{sample}
\end{aligned}
$$

$\mathbf{w}_{sample}$ 实际基本为0，不影响weight大小，但是有梯度

$$
\mathbf{x}_{new,i} = \begin{cases} \mathbf{w}_{scaling,i} * \mathcal{G}(\mathbf{x}_i) + (1 - \mathbf{w}_{scaling,i}) * \mathbf{x}_i, & \text{if } i \in \mathcal{I} \\ \mathbf{x}_i, & \text{otherwise} \end{cases}
$$

SUBLLM架构

Subsampling and Upsampling Module

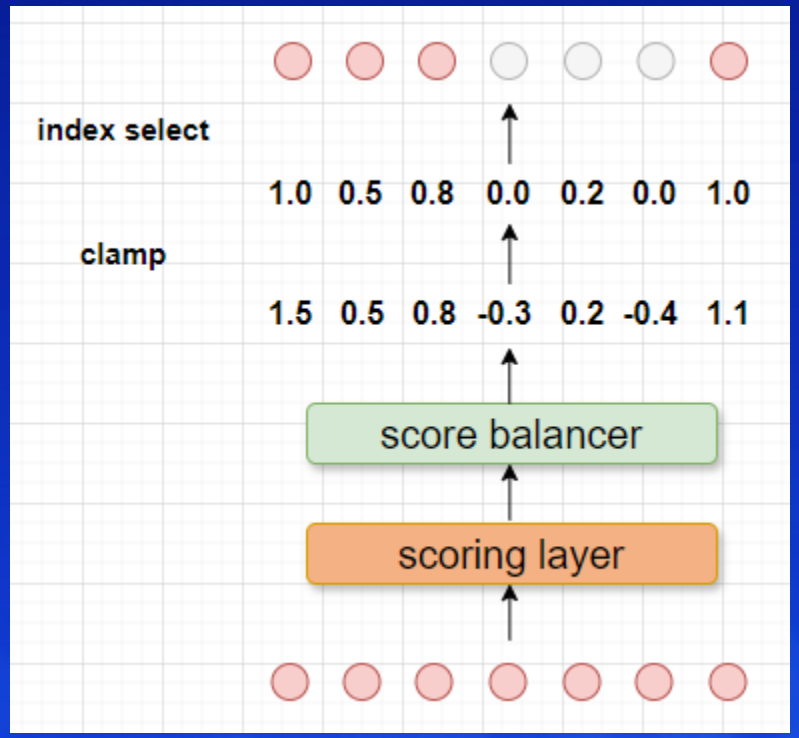

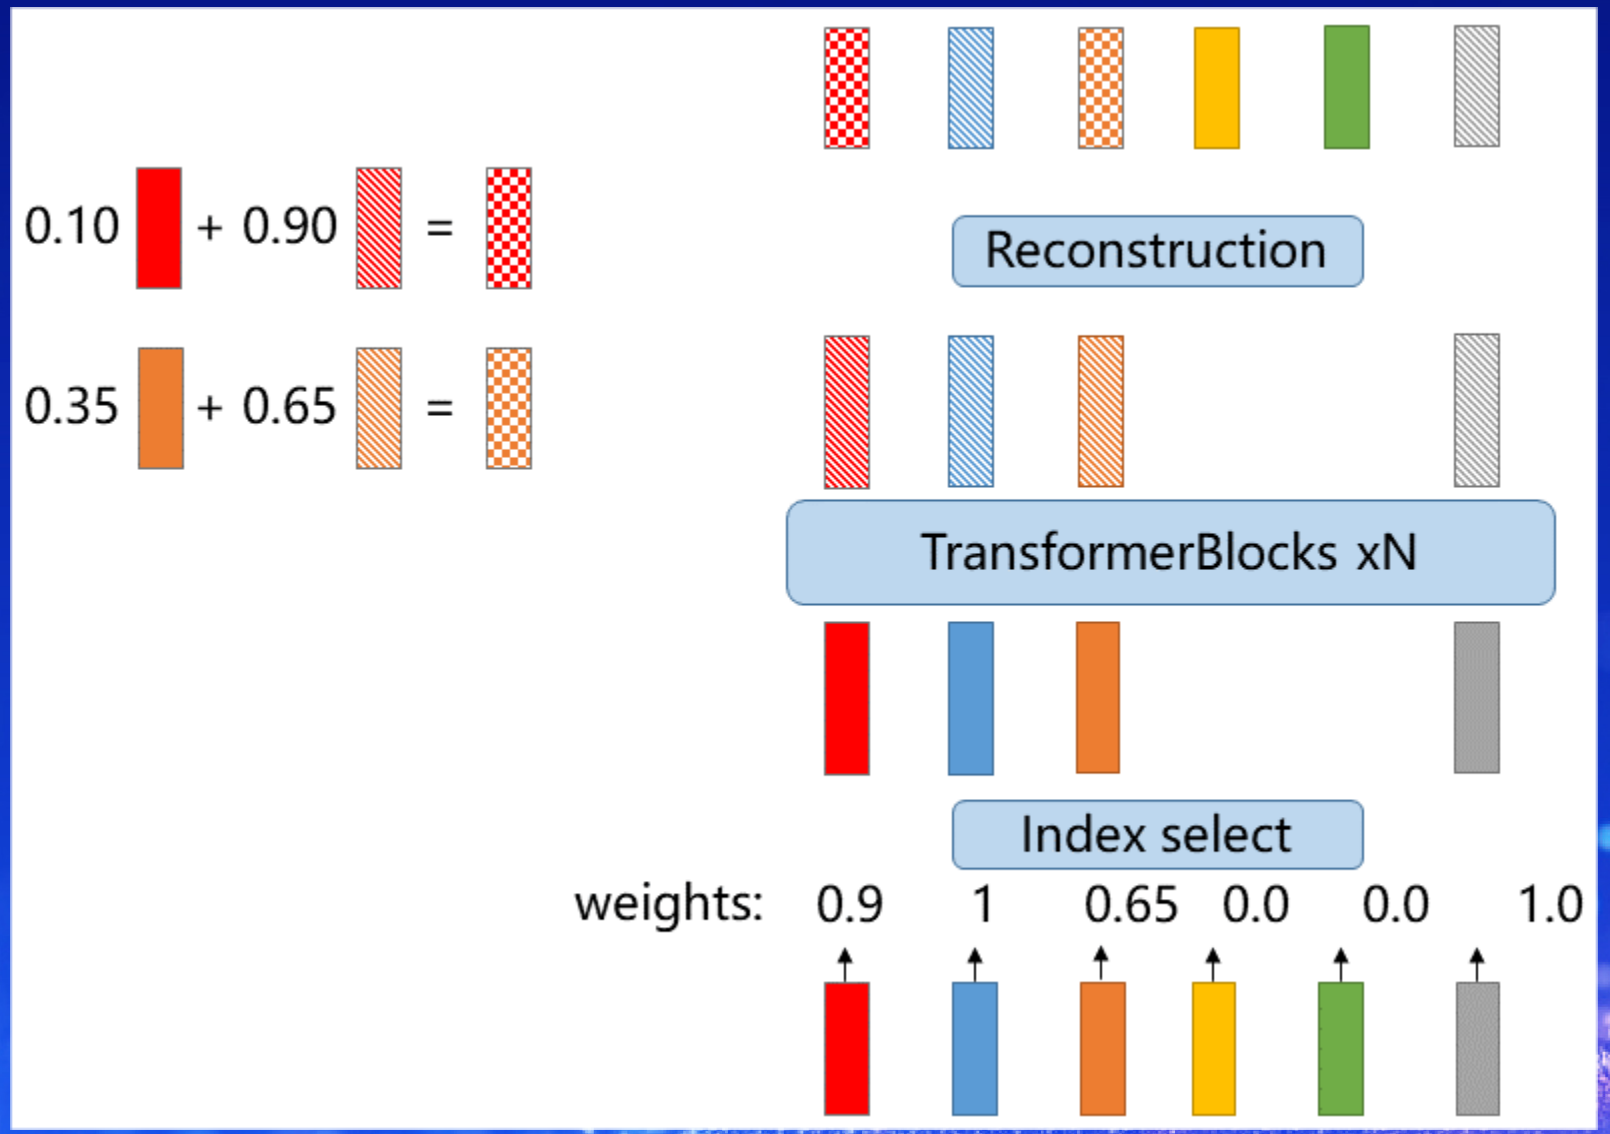

SUBLLM架构

Bypass Module：

1. 下采样前和上采样后的序列加权求和，per channel
2. 增强训练的收敛性和稳定性。

$$\mathbf{y} = (1 - \mathbf{c}) \odot \mathbf{x} + \mathbf{c} \odot \mathbf{y}$$

Variant	Valid Loss↓
SUBLLM	**3.66**
- Bypass Module + Residual Connection	3.72
- Bypass Module	3.73
LLaMA	3.69

SUBLLM架构

对比Google: Mixture-of-Depths (MoD)：

1. 给重要token分配更多算力
2. MoD 每间隔一个block做一次topk的token筛选
3. 加速50%

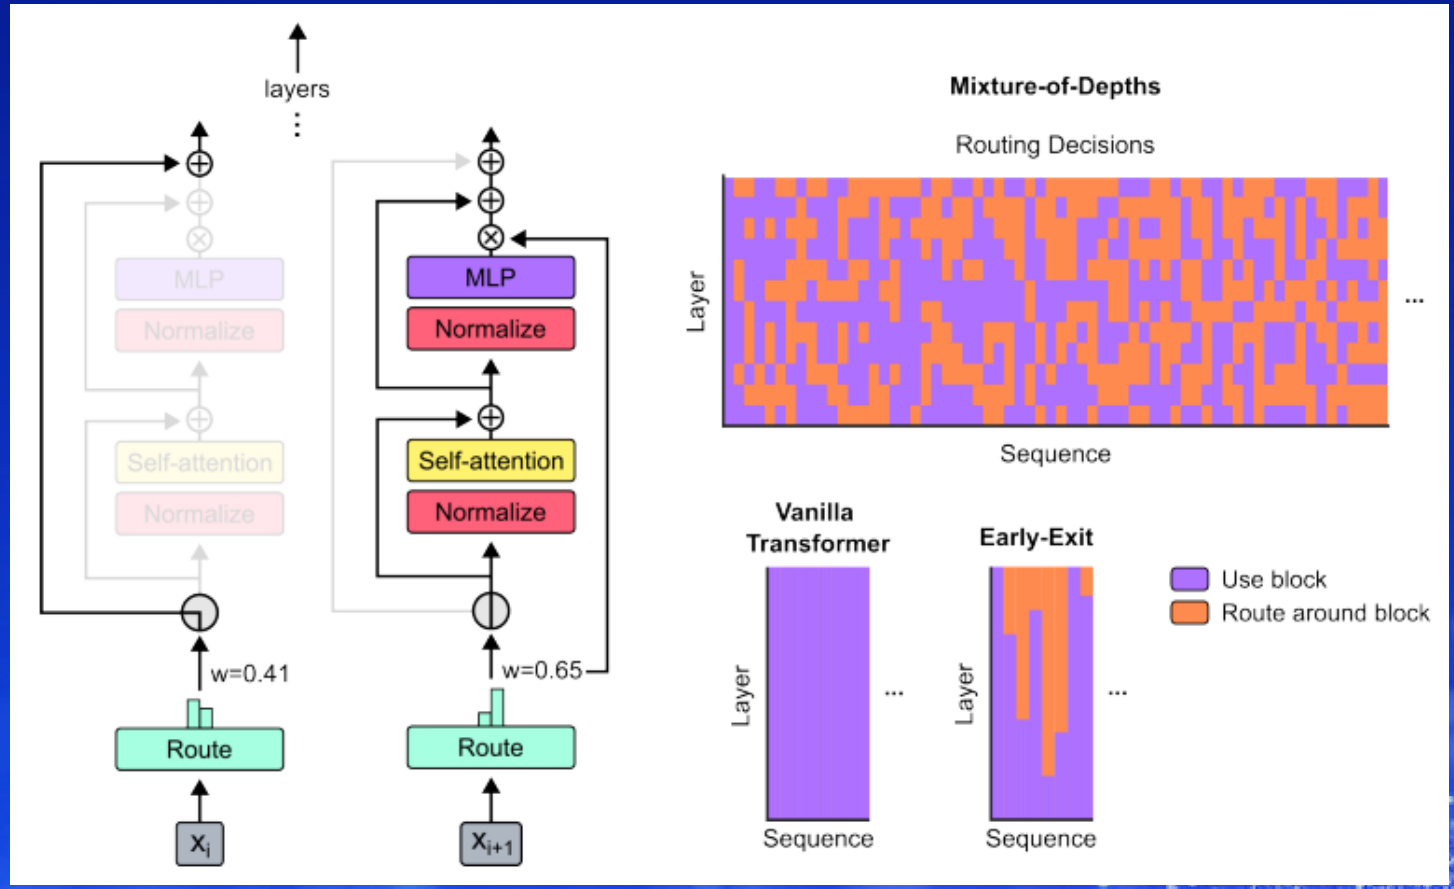

Mixture-of-Depths 模型结构 by Google, 2024

PART 03
主要实验结果

主要实验结果

Pre-Training Corpora

SlimPajama, 100倍模型大小tokens

Pre-Training Details

SUBLLM 1.3B vs Llama 1.3B, SUBLLM仅仅多了8192个参数
SUBLLM 2次下采样，最短的地方总保留比例仅40%
BF16, Flash Attention2
训练窗长2k 4k 8k
优化器为ScaledAdam

主要实验结果

Efficiency	Pre-Training					Inference		
	Speed-Up			Max Speed-Up				
	TGS↑	Ratio↑	Mem (GB)↓	TGS↑	Ratio↑	Speed↑	Ratio↑	Mem (GB)↓
LLaMA	16,976	×1.00	65.99	18,856	×1.00	17.83	× 1.00	18.49
SUBLLM	**21,341**	**×1.26**	**55.81**	**24,773**	**×1.31**	**24.43**	**×1.37**	**17.29**

Performance	Pre-Training	Few-Shot Learning						
	Valid Loss↓	SST2↑	Amazon↑	DBpedia↑	AGNews↑	Yelp↑	Hate↑	Avg.↑
LLaMA	3.11	81.01	86.54	**45.70**	64.77	87.59	**45.18**	68.47
SUBLLM	**3.10**	**91.95**	**94.57**	42.97	**66.05**	**94.24**	32.23	**70.34**

加速比 26%
最大加速比 31%
推理加速比 37%
训练/推理显存减少 10，1GB/GPU
预训练valid loss 持平
Few-shot 分数 持平

PART 04
分析与讨论

分析与讨论

预训练加速

Model Size	Context Window	Model	Speed-Up				Max Speed-Up	
			TGS↑	Ratio↑	Mem (GB)↓	Δ Mem	TGS↑	Ratio↑
0.25B	2k	LLaMA	85,925	×1.00	60.16	-	85,462	×1.00
		SUBLLM	107,260	×1.25	53.76	-6.41	107,859	×1.26
	4k	LLaMA	77,590	×1.00	77.66	-	77,423	×1.00
		SUBLLM	99,209	×1.28	69.03	-8.63	100,425	×1.30
	8k	LLaMA	64,959	×1.00	74.15	-	64,741	×1.00
		SUBLLM	86,227	×1.33	66.03	-8.11	87,261	×1.35
1.3B	2k	LLaMA	18,405	×1.00	72.99	-	20,284	×1.00
		SUBLLM	22,831	×1.24	61.80	-11.19	26,219	×1.29
	4k	LLaMA	16,976	×1.00	65.99	-	18,856	×1.00
		SUBLLM	21,341	×1.26	55.81	-10.18	24,773	×1.31
	8k	LLaMA	15,080	×1.00	65.89	-	16,587	×1.00
		SUBLLM	19,390	×1.29	56.19	-9.70	22,264	×1.34

分析与讨论

推理加速

窗长越大，推理加速越多
8k窗长加速50%

Context Window	Model	Actual Retention	First Token		Non-First Tokens		Memory	
			Latency (ms)↓	Ratio↑	Speed ↑	Ratio↑	Mem (GB)↓	Δ Mem
2k	LLaMA	-	695.16	×1.00	20.82	×1.00	6.98	-
	SUBLLM	43%	496.66	×1.40	26.71	×1.28	5.63	-1.35
4k	LLaMA	-	2,051.59	×1.00	17.83	×1.00	18.49	-
	SUBLLM	44%	1,410.94	×1.45	24.43	×1.37	17.29	-1.20
8k	LLaMA	-	16,249.11	×1.00	12.38	×1.00	61.05	-
	SUBLLM	44%	9,758.40	×1.67	18.80	×1.52	58.61	-2.44

分析与讨论

模型结构适用于不同的优化器

	Adam		ScaledAdam	
	Valid Loss↓	Ratio	Valid Loss↓	Ratio
LLaMA	3.725	-	3.693	-
SUBLLM	3.743	×1.33	3.687	×1.32

寻找最优下采样次数和保留比例：比例75%valid loss最低

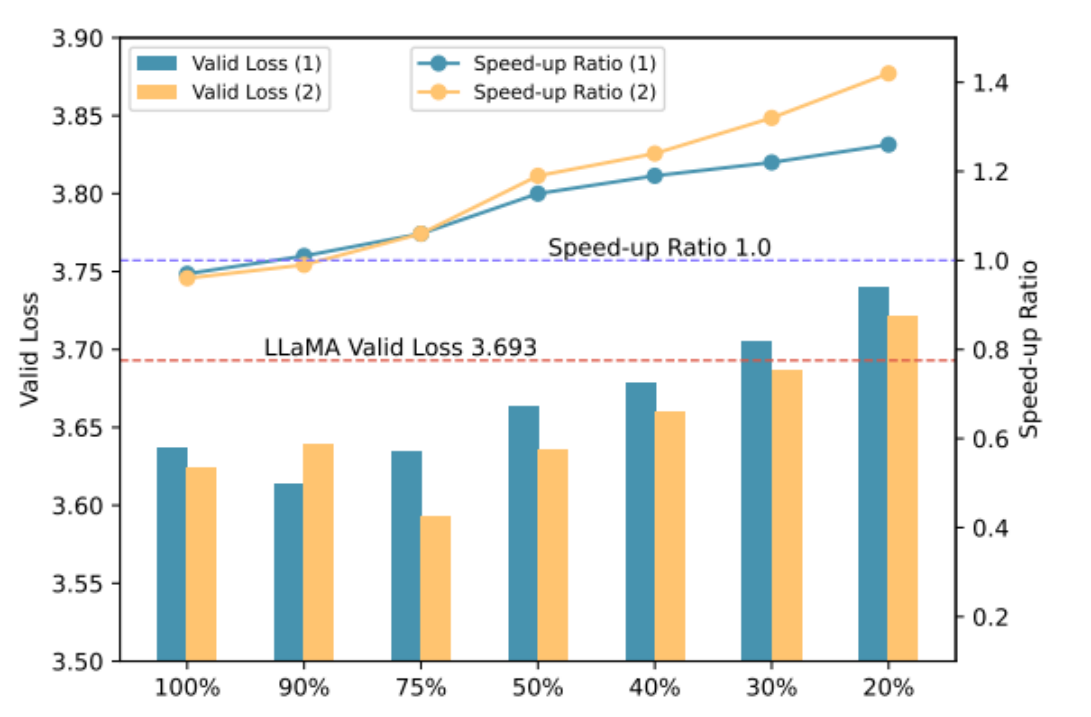

下采样次数2次最优

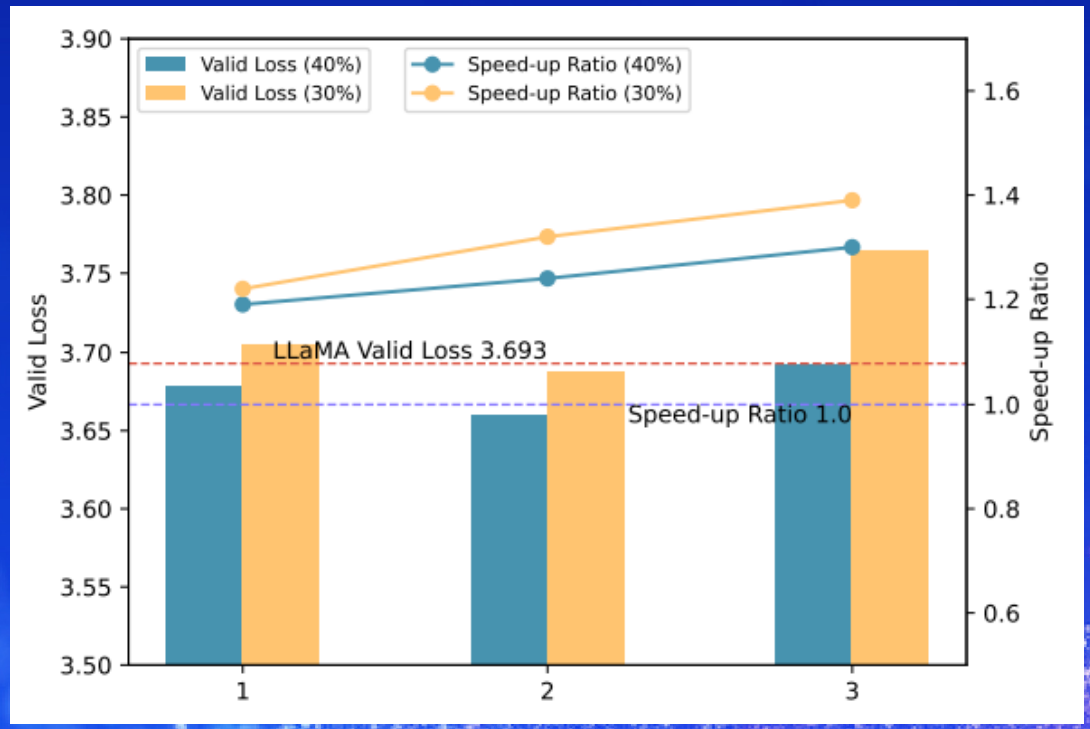

分析与讨论

下采样的有效性分析

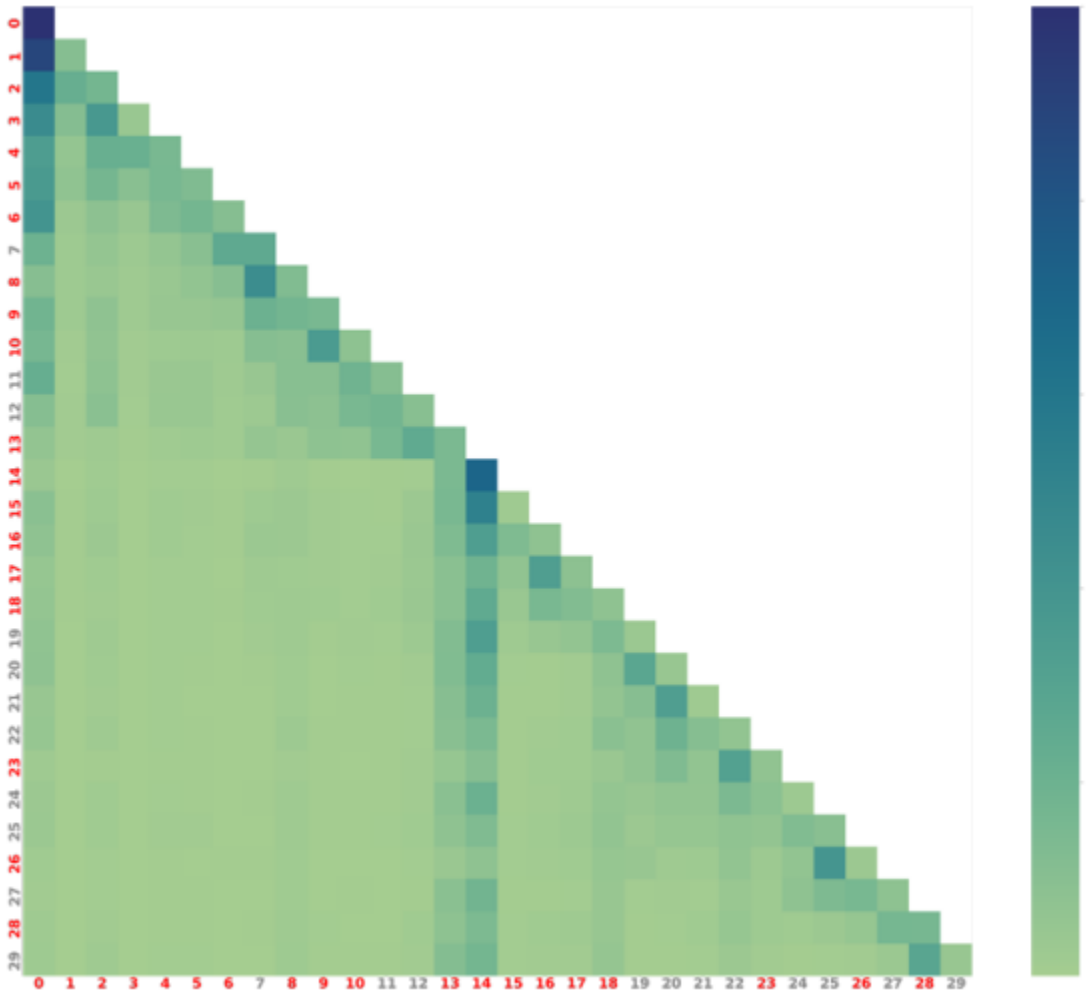

下采样前的attention和保留index分布接近

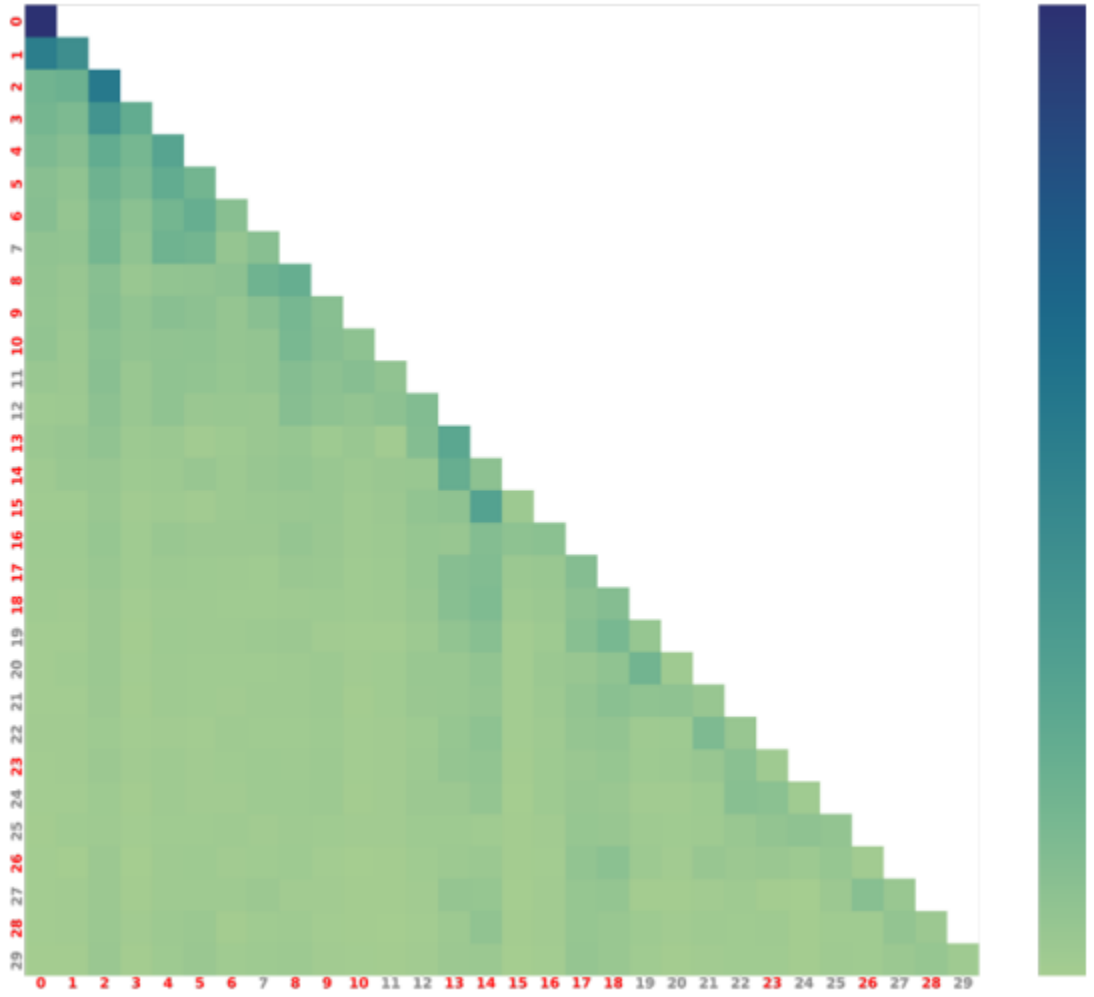

Llama同一层的attention和保留index分布接近

PART 05
总结与展望

总结与展望

SUBLLM贡献

1. 提出SUBLLM新架构
   它结合了下采样、上采样和旁路模块
   动态地将资源分配给重要的token

2. 提出了一种 token 序列子采样方法
   可以有效地测量 token 重要性分数并按预期控制分数值的分布
   在推理过程中实现所需的下采样保留率

3. 与 Llama 模型相比
   SUBLLM 在训练和推理方面分别实现了加速，训练加速34%，推理50%
   同时显着降低了内存成本，保持了模型能力

总结与展望

未来研究方向

1. 不同的tokenizer有不同的压缩率
   如何确保SUBLLM结构的通用性并确定有效的保留比例

2. 应用在长文本场景，比如200K窗长上，可以最低保留多少比例
   值得期待一下

3. 多模态模型中的视觉标记具有冗余性
   在处理高分辨率图像时，大大降低了VLM的效率
   SUBLLM应用在这个领域也将具有落地前景

THANKS