

MiniMax-01：使用闪电注意力机制扩展基础模型

MiniMax¹

我们推出了MiniMax-01系列，包括MiniMax-Text-01和MiniMax-VL-01，它们与顶级模型相当，但在处理长上下文方面具有更强的能力。其核心在于闪电注意力机制及其高效扩展。为了最大化计算能力，我们将其与专家混合（MoE）相结合，创建了一个具有32个专家和4560亿个总参数的模型，其中每个标记激活了459亿个参数。我们为MoE和闪电注意力机制开发了一种优化的并行策略和高效率的计算-通信重叠技术。这种方法使我们能够在具有数千亿参数的模型上进行高效训练和推理，这些模型在数百万个标记的上下文中具有数十亿个标记。MiniMax-Text-01的上下文窗口在训练期间可以达到100万个标记，在推理期间可以扩展到400万个标记，而成本是可承受的。我们的视觉语言模型MiniMax-VL-01是通过512亿个视觉语言标记进行持续训练而构建的。在标准和内部基准测试上的实验表明，我们的模型在提供 20 - 32 倍更长的上下文窗口的同时，其性能与诸如 GPT - 4o 和 Claude - 3.5 - Sonnet 等最先进的模型相当。我们已在 <https://github.com/MiniMax-AI> 上公开发布了 MiniMax - 01。

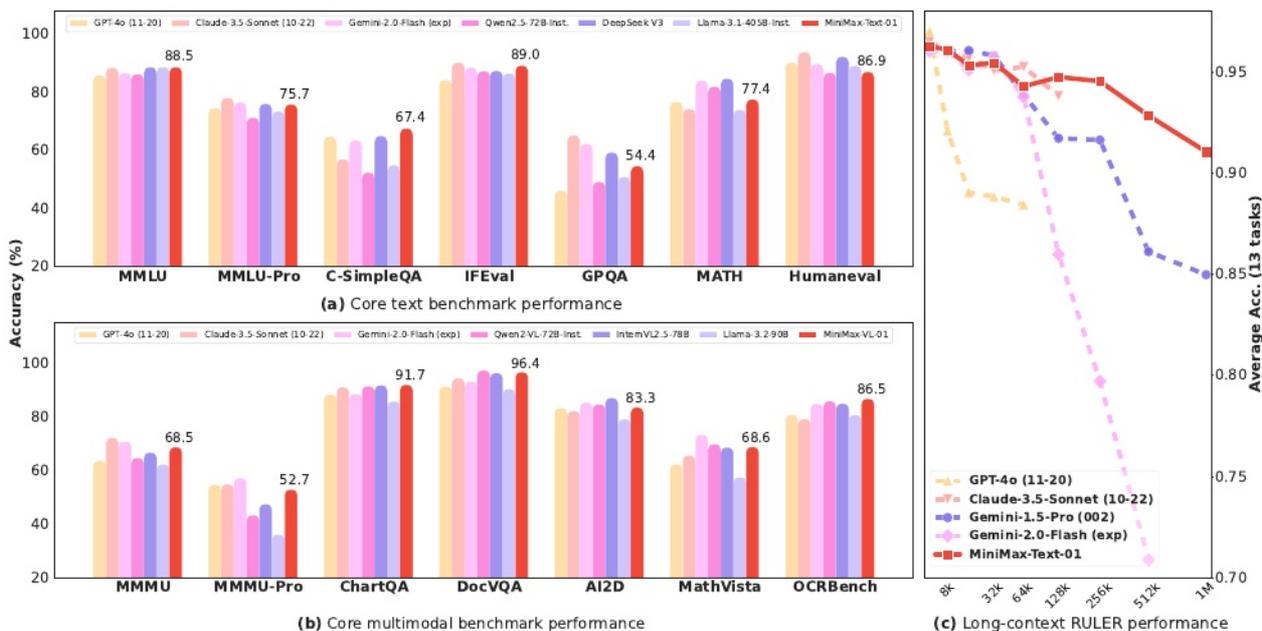


图 1 | 基准测试性能。(a) 核心文本基准测试中的 MiniMax-Text-01。(b) 核心多模态基准测试中的 MiniMax-VL-01。(c) 核心文本基准测试中的 MiniMax-Text-01 在长上下文的 RULER (谢等人, 2024 年) 基准测试中的表现。展示了领先的商业和开源模型的性能以供参考。

¹Please send correspondence to model@minimaxi.com.

1. 引言

近年来，大型语言模型（LLMs）（Anthropic, 2024; Dubey 等人, 2024; Hurst 等人, 2024; Team 等人, 2024a）和视觉语言模型（VLMs）（Anthropic, 2024; Dubey 等人, 2024; Hurst 等人, 2024; Team 等人, 2024a）取得了迅速的进展，在知识问答、复杂推理、数学、编程和视觉-语言理解等任务中表现出色。目前大多数模型的上下文窗口范围在 32K 到 256K 个标记之间。然而，这些长度往往无法满足实际需求——无论是使用一本专业书籍作为上下文，协助完成整个编程项目，还是通过多示例最大化上下文学习的潜力。

过去两年中，上下文窗口的扩展主要得益于更强大的GPU和更优的I/O感知softmax注意力机制的实现（Dao等人, 2022年; Liu等人, 2024年a）。然而，进一步扩大这些窗口已被证明具有挑战性。这种限制源于Transformer架构固有的二次计算复杂度（Vaswani等人, 2017年）——进一步延长窗口会导致计算需求比硬件能力增长得快得多。为了应对这一挑战，研究人员提出了各种方法来降低注意力机制的计算复杂度：稀疏注意力（Beltagy等人, 2020年; Zaheer等人, 2020年）、线性注意力（Qin等人, 2022年a、b、2024年c）、长卷积（Qin等人, 2023年a）、状态空间模型（Mamba系列）（Dao和Gu, 2024年; Glorioso等人, 2024年; Gu和Dao, 2024年; Ren等人, 2024年; Team等人, 2024年b）以及线性RNN（Qin等人, 2023年b、2024年d）。尽管这些创新在理论上很有前景，但在商业规模模型中的应用却有限。

在这份报告中，我们的目标是构建一个模型，其性能能与领先的商业模型相媲美，同时提供一个比领先商业模型长一个数量级的上下文窗口。这一雄心勃勃的目标需要仔细平衡多个因素：网络架构、数据和计算。

我们的方法始于选择最有前景的架构，随后优化底层的训练和推理框架以确保其支持。对于网络架构，我们要求线性注意力不仅在理论上合理，而且在实践中高效，尤其是在处理长上下文时。经过大量实验，我们最终确定了一种混合架构，主要使用闪电注意力（Qin 等人, 2024b），这是一种输入/输出感知的线性注意力变体的实现（Qin 等人, 2022a）。在该架构中，每七个带有闪电注意力的转换器块之后跟着一个带有软注意力机制的转换器块（Qin 等人, 2022a）。

我们根据一个实际的限制确定了模型的总参数：使用多达8个GPU和640GB内存，通过8位量化，在单个机器上处理超过100万个标记的能力。为了最大化参数和计算能力，我们实现了专家混合（MoE）（Fedus等人, 2022年; Lepikhin等人, 2021年）。我们综合考虑了训练资源、推理资源和最终模型性能，旨在在这三者之间找到更好的平衡。大量的实验引导我们最终确定了模型的规格：4560亿个参数、459亿次激活和32个专家。

现有的分布式训练和推理框架主要针对softmax注意力进行了优化。然而，我们的新型架构结合了闪电注意力、softmax注意力和MoE，需要重新设计我们的训练和推理框架。此外，该框架必须具备支持具有数千亿参数和数百万个标记的上下文窗口的模型的训练和推理的能力。为此，我们在MoE中使用专家并行（EP）和专家张量并行（ETP）实现全对全通信，旨在最小化与GPU间通信相关的开销。为了促进无限扩展的上下文窗口，我们设计了变长环注意力以减少计算冗余，并实现了改进版的线性注意力序列并行（LASP）（Sun等, 2024），以充分利用设备的并行能力。此外，我们还实现了

一整套专为闪电注意力推理定制的 CUDA 内核，在英伟达 H20 上实现了超过 75% 的模型浮点运算利用率（MFU）（乔杜里等人，2023 年）的端到端效果。

在架构设计和计算优化的基础上，我们训练了我们的基础语言模型 MiniMax-Text-01。我们的预训练过程始于通过严格的数据清理、基于奖励的质量增强以及更好的方式来收集一个多样化和高质量的语料库。

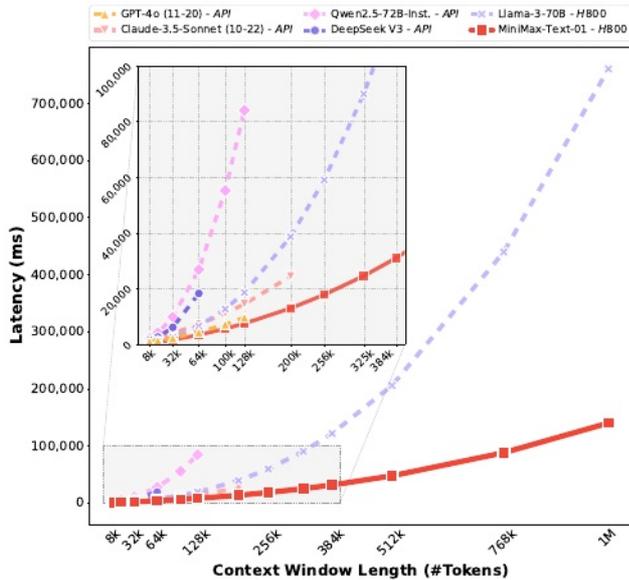


图 2 | 不同模型的预填充延迟。在 H800 显卡上对 MiniMax-Text-01 和 Llama3-70B 模型进行了测试，将张量并行设置为 8，并使用带有 8 的自定义推理框架 -

仅位重量化（W8A16）。其他模型通过其官方 API 进行测试。在每个模型支持的最大长度内，选择了足够数量的均匀分布点进行测试。去除异常值后，数据用二次函数拟合。

如图 1(c) 所示。除了学术基准外，我们还使用从实际使用中得出的内部基准来评估模型的性能，并证明我们的模型在这些场景中处于顶尖水平。除了性能之外，我们的模型在预填充延迟方面也表现出显著的优势，这得益于其新颖的架构，如图 2 所示。

我们将我们的贡献总结如下：

1. 我们构建了一个模型，在标准的学术基准测试中与顶尖的闭源模型相抗衡。此外，该模型支持多达 400 万个标记的上下文输入，在长上下文的评估中表现出色。
2. 我们展示了线性注意力机制首次大规模成功实现。虽然线性注意力机制此前已被研究过，但从未以这种规模进行部署。我们提供了关于算法设计和工程优化的全面细节。
3. 我们概述了一种实用的方法以及实验方法，用于探索各种模型、数据集、评估和算法，这可能是一个有价值的参考。
4. 我们公开了权重，并提供了一个经济实惠的 API，旨在帮助他人进行开发。

数据混合平衡，通过系统验证主题重复感知测试。为了充分利用该架构的长上下文能力，我们对超参数进行了深入分析，并提出了一种三阶段训练过程，成功地将上下文窗口扩展到一百万个标记。在对齐阶段，我们通过精确调整奖励维度和多阶段训练方法来激励模型的各种能力，特别是在长上下文和现实世界场景方面。随后，我们通过集成一个轻量级视觉转换器（ViT）（Dosovitskiy 等，2021）模块来增强我们的语言模型，从而创建我们的视觉-语言模型 MiniMax-VL-01。MiniMax-VL-01 还经历了额外的使用 5120 亿个视觉-语言标记进行训练，采用四阶段训练流程。这种训练的最后阶段专门旨在优化用户体验。

对核心学术基准的综合评估表明，在文本和视觉语言任务中，这两个模型的性能水平都与闭源顶级模型相当，如图 1 (a、b) 所示。对于超过 20 万个字符的上下文，我们的模型表现明显更好。

超越当前限制的模型。

2. 模型架构

在本节中，我们介绍了我们的网络架构设计。为了在受限资源内实现最佳性能，并更好地处理较长的序列，我们采用了多专家（MoE）方法，并尽可能多地使用线性注意力，而非标准 Transformer 中使用的传统 softmax 注意力。

为了便于更直观地理解，我们在图3中展示了主要架构。我们的设计遵循Transformer风格的模块，每个模块都包含一个通道混合器（注意力块）和一个特征混合器（MLP块）。我们采用了两种类型的通道混合器：闪电注意力和软max注意力。特征混合器是一个MoE，它包含了多个前馈网络（FFNs）。为了确保MoE模块中的负载均衡，我们提出了一种新颖的负载均衡策略，灵感来自GShard（Lepikhin等，2021），我们称之为全局路由器。该策略旨在保持训练稳定性。此外，我们还采用了两种类型的通道混合器：闪电注意力和软max注意力。特征混合器是一个MoE，它包含了多个前馈网络（FFNs）。为了确保MoE模块中的负载均衡，我们提出了一种新颖的负载均衡策略，灵感来自GShard（Lepikhin等，2021），我们称之为全局路由器。该策略旨在保持训练稳定性。此外，我们还采用了两种类型的通道混合器：闪电注意力和软max注意力。

传统上，DeepNorm（Wang 等人，2024a）被整合进来以提高整体性能。

最终的MiniMax-Text-01架构以结构化的模式整合了线性注意力和softmax注意力机制。具体来说，在每7个转置变换器块（Qin等人，2022a）的线性注意力之后，放置了一个带有softmax注意力的变换器块，总共形成了80层。每个注意力模块由64个头组成，每个头的维度为128。softmax注意力层采用分组查询注意力（GQA）（Ainslie等人，2023），分组大小为8。旋转位置嵌入（RoPE）（Su等人，2024）应用于一半的注意力头维度，基频率设置为10,000。模型的隐藏大小配置为6144，每层包含32个专家，采用前2名路由策略。每个专家内部的前馈网络的隐藏维度为9216。总的来说，MiniMax-Text-01包含4560亿个参数，其中每个处理过的标记激活了459亿个参数。

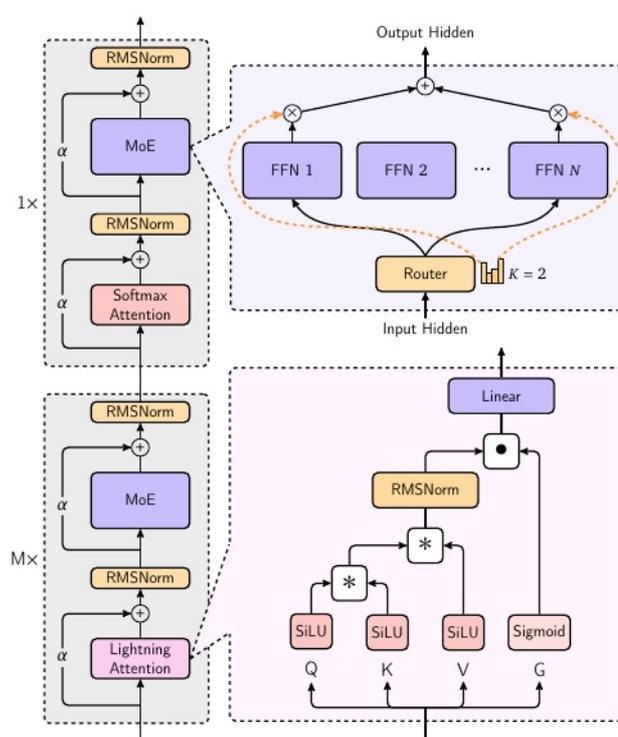


图 3 | MiniMax-Text-01 的架构

在接下来的章节中，我们将深入探讨关于模型架构的考量，即不同注意力机制的整合、MoE 与线性注意力之间的协同作用、超参数选择背后的原理，以及基于缩放定律确定模型大小的方法。

2.1. 专家混合

与密集版本相比，多专家模型（MoE）提供了一种增强可扩展性和效率的途径。通常，在特征混合器层中，多专家模型是前馈网络（FFN）的替代品（Fedus）

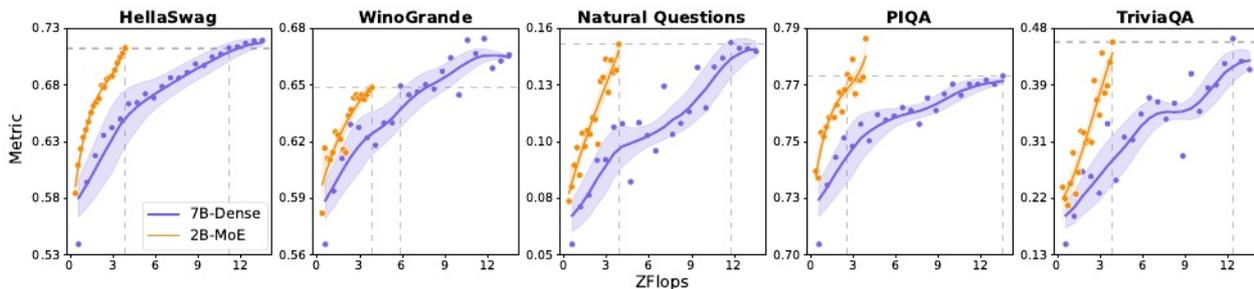


图4 | 同精度比较：在各种基准测试中，MoE与密集模型的比较。两个模型均使用1万亿个标记进行训练。灰色虚线表示两个模型达到相同性能所需的计算量的差异。

(et al., 2022; Lepikhin et al., 2021) ，它由多个全连接网络专家组成，每个输入令牌被路由到其中一个或多个专家。具体而言，对于一个输入令牌 \mathbf{x}_t ，其相应的输出隐藏状态 \mathbf{h}_t 的计算方式为：

$$\mathbf{h}_t = \sum_{i=1}^E \text{Softmax}_i (\text{TopK}(\mathbf{x}_t \cdot \mathbf{W}_g)) \cdot \text{FFN}_i(\mathbf{x}_t), \quad (1)$$

其中， E represents 表示专家的总数， \mathbf{W}_g is 表示门的权重， FFN_i stands 表示第 i -th 位专家， $\text{TopK}(\cdot)$ 表示在所有 E experts 中保留前 K scores 个分数的操作，同时将剩余的分数设置为 $-\infty$ 。

基于 MoE 的大型语言模型 (LLM) 的训练可以分为有丢弃和无丢弃两种。我们采用有丢弃策略来提高训练效率。通过这种方法，每个专家都被分配了一个容量限制，指定了其能够处理的最大令牌数量。一旦达到这个容量，分发给该专家的任何额外令牌都会被丢弃。

为了评估 MoE 架构的有效性，我们对一个具有 70 亿个参数的密集模型和一个具有 20 亿个激活参数（总共 240 亿个参数）的 MoE 模型进行了对比研究。如图 4 所示的结果表明，在相同的计算预算下，MoE 模型在包括 HellaSwag (Zellers 等人, 2019 年)、WinoGrande (Sakaguchi 等人, 2021 年)、自然问题 (Kwiatkowski 等人, 2019 年)、PIQA (Bisk 等人, 2020 年) 和 TriviaQA (Joshi 等人, 2017 年) 等各种基准测试中显著优于密集模型。当扩展到更大的模型时，我们遇到了路由崩溃的挑战，这是由于指定用于分配的标记的集中分布引起的。为了解决这个问题，我们在 GShard (Lepikhin 等人, 2021 年) 的辅助损失中纳入了一个简单的全局路由策略，以实现更好的负载均衡。

辅助损失。 为确保可微性，辅助损失被定义为 $L_{\text{aux}} = \alpha_{\text{aux}} \cdot \frac{1}{E} \sum_{i=1}^E \text{FI} \cdot \text{MI}$ ，

其中， α_{aux} 表示辅助损失的系数， F_i denotes 表示分配给第 i 位专家的令牌比例， M_i is 表示专家 i 的平均路由概率。

全球路由器。 GPU 内存大小限制了 LLM 训练中的微批次大小，导致单个专家并行 (EP) 组内的标记分布出现大幅波动。此外，标记分布在不同的 EP 组之间有所不同，可能导致负载不平衡，其中一个 EP 组中的专家可能过载，而另一个组中的专家则未充分利用。为了解决这个问题，我们在 EP 组之间实现了一个全局标记调度策略。具体来说，我们引入了一个额外的 `allgather` 通信步骤，用于同步每个专家等待处理的标记数量，然后在不同的 EP 组之间调度标记。

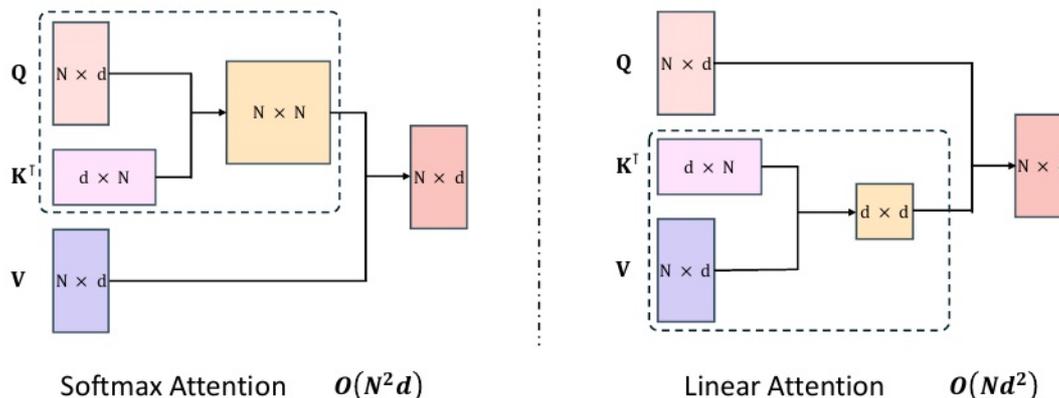


图 5 | 软最大化注意力（左）和线性注意力（右）计算的图示。输入长度为 N ，特征维度为 D ，其中 $D \ll N$ 。同一框中的张量与计算相关联。线性化公式允许 $O(N)$ 的时间和空间复杂度。

由于容量限制，这种全局路由机制能够有效地降低整体令牌掉线率，从而确保训练的稳定性。

2.2. 线性注意力

线性注意力利用“右乘积核技巧”将二次计算复杂度转换为线性复杂度，如图5所示。以 TransNormer (Qin等, 2022a) 为例，NormAttention机制可以写成：

$$\mathbf{O} = \text{Norm}((\mathbf{Q}\mathbf{K}^T)\mathbf{V}), \quad (2)$$

其中， \mathbf{Q} 、 \mathbf{K} 和 \mathbf{V} 分别为查询、键和值的矩阵， N_{for} 为序列长度， D 为特征维度。该方程可以通过右矩阵乘法转换为线性变体：

$$\mathbf{O} = \text{Norm}(\mathbf{Q}(\mathbf{K}^T\mathbf{V})), \quad (3)$$

线性公式有助于高效的循环预测，训练复杂度为 $O(ND^2)$ 。此外，线性注意力确保了恒定的计算复杂度 $O(D^2)$ ，与序列长度无关。这是通过循环更新项 $\mathbf{K}^T\mathbf{V}$ 来实现的，从而避免了对整个注意力矩阵的重复计算。相比之下，在推理过程中，softmax注意力会导致 $O(ND^2)$ 的复杂度。

在处理因果语言建模任务时，正确产品的有效性会受到影响，这就需要计算累积和 (Hua 等人, 2022 年)。这种限制阻碍了高效并行计算的实现，这很可能解释了为什么尽管九年前由 Brebisson 等人 (de Brebisson 和 Vincent, 2016 年) 提出，但目前领先的开源大型语言模型 (包括 LLaMA3 (Dubey 等人, 2024 年)、Qwen2.5 (Yang 等人, 2024 年)、DeepSeekV3 (DeepSeek-AI, 2024 年) 和 Mistral (Jiang 等人, 2023 年)) 没有一个采用这种线性注意力机制。

2.2.1. 闪电注意力

闪电注意力 (Qin 等人, 2024 年 b、c) 是 TransNormer (Qin 等人, 2022 年 a) 的一种具有输入/输出感知的优化实现。这种方法指出了现有线性注意力机制计算效率的主要瓶颈：因果关系中固有的缓慢累积求和操作。

语言建模。为了缓解这个问题，Lightning Attention提出了一种新颖的平铺技术，有效地避免了累积操作。关键创新在于将注意力计算战略性地分为两个不同的组成部分：块内计算和块间计算。左侧乘法注意力计算用于块内操作，而右侧乘法用于块间操作。这种划分至关重要，因为块内的大小可以显著减小，从而确保整体计算复杂度保持线性。

请注意，闪电注意力机制最初是由我们的团队成员在 Qin 等人 (2024c) 中提出的，为了完整性，我们回顾了一些核心过程，以阐明为什么它在实践中能够实现理论上的线性复杂度。出于分析的可处理性，在接下来的推导中，我们有意忽略了对归一化、sigmoid 线性单元 (SiLU) 激活和门控机制的考虑。

让我们从闪电注意力中的前向传播开始。因果注意力计算中的左侧乘积定义为：

$$\mathbf{O} = [(\mathbf{Q}\mathbf{K}^\top) \odot \mathbf{M}]\mathbf{V} \quad (4)$$

其中，如果 $T \geq S$ ，则 $\mathbf{M}_{TS} = 1$ ，否则 0。右乘法运算可以通过递归公式计算得出：

$$\mathbf{k}\mathbf{v}_0 = \mathbf{0}, \mathbf{k}\mathbf{v}_t = \mathbf{k}\mathbf{v}_{t-1} + \mathbf{k}_t\mathbf{v}_t^\top, \mathbf{o}_t^\top = \mathbf{q}_t^\top\mathbf{k}\mathbf{v}_t. \quad (5)$$

需要注意的是，尽管公式 5 呈现出线性计算复杂度，但它本质上是不可并行化的。

实现闪电注意力机制的基本概念涉及利用分块技术来计算注意力得分。具体而言，矩阵 \mathbf{Q} 、 \mathbf{K} 、 \mathbf{V} 沿着行维度被划分为两个不同的块：

$$\mathbf{X} = \begin{bmatrix} \mathbf{X}_1 \\ \mathbf{X}_2 \end{bmatrix}, \mathbf{X}_1 \in \mathbb{R}^{m \times d}, \mathbf{X}_2 \in \mathbb{R}^{(n-m) \times d}, \mathbf{X} \in \{\mathbf{Q}, \mathbf{K}, \mathbf{V}\}.$$

通过展开式 (4)，我们得到以下表达式（请注意 $\mathbf{k}\mathbf{v}_0 = 0$ ）：

$$\mathbf{k}\mathbf{v}_s = \mathbf{k}\mathbf{v}_0 + \sum_{j=1}^s \mathbf{k}_j\mathbf{v}_j^\top, s = 1, \dots, m. \quad \mathbf{o}_s^\top = \mathbf{q}_s^\top\mathbf{k}\mathbf{v}_s = \mathbf{q}_s^\top\mathbf{k}\mathbf{v}_0 + \mathbf{q}_s^\top \sum_{j=1}^s \mathbf{k}_j\mathbf{v}_j^\top. \quad (6)$$

将其重写为块状形式，我们有：

$$\mathbf{O}_1 = \mathbf{Q}_1\mathbf{k}\mathbf{v}_0 + [(\mathbf{Q}_1\mathbf{K}_1^\top) \odot \mathbf{M}]\mathbf{V}_1 \triangleq \mathbf{Q}_1\mathbf{K}\mathbf{V}_0 + [(\mathbf{Q}_1\mathbf{K}_1^\top) \odot \mathbf{M}]\mathbf{V}_1. \quad (7)$$

如图所示，块内 $[(\mathbf{Q}_1\mathbf{K}_1^\top) \odot \mathbf{M}]\mathbf{V}_1$ 可以使用左乘积，块间 $\mathbf{Q}_1\mathbf{K}\mathbf{V}_0$ 可以使用右乘积。请注意，块内可以使用相同的策略进一步划分：

$$\mathbf{k}\mathbf{v}_{m+t} = \mathbf{k}\mathbf{v}_m + \sum_{j=m+1}^{m+t} \mathbf{k}_j\mathbf{v}_j^\top, t = 1, \dots, n-m, \quad \mathbf{o}_{m+t}^\top = \mathbf{q}_{m+t}^\top\mathbf{k}\mathbf{v}_{m+t}, \quad (8)$$

$$\mathbf{O}_2 = \mathbf{Q}_2\mathbf{k}\mathbf{v}_m + [(\mathbf{Q}_2\mathbf{K}_2^\top) \odot \mathbf{M}]\mathbf{V}_2 \triangleq \mathbf{Q}_2\mathbf{K}\mathbf{V}_1 + [(\mathbf{Q}_2\mathbf{K}_2^\top) \odot \mathbf{M}]\mathbf{V}_2.$$

要计算第二个区块，我们使用 $\mathbf{K}\mathbf{V}_1 = \mathbf{k}\mathbf{v}_M$ ，这可以通过以下方式计算：

$$\mathbf{K}\mathbf{V}_1 = \mathbf{K}\mathbf{V}_0 + \sum_{j=1}^m \mathbf{k}_m\mathbf{v}_m^\top = \mathbf{K}\mathbf{V}_0 + \mathbf{K}_1^\top\mathbf{V}_1. \quad (9)$$

其中 $\mathbf{K}\mathbf{V}_0 = \mathbf{k}\mathbf{v}_0$ 。通过递归应用上述将矩阵划分为多个块的策略，实际的计算复杂度可以降低到线性。闪电注意力操作的最终时间复杂度为 $O(ND^2 + NBD)$ ，其中 B 是块大小。算法 1 展示了闪电注意力前向传播的 IO 感知实现。

Algorithm 1 Lightning Attention Forward Pass

Input: $\mathbf{Q}, \mathbf{K}, \mathbf{V} \in \mathbb{R}^{n \times d}$, block sizes B .
 Divide \mathbf{X} into $T = \frac{n}{B}$ blocks $\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_T$ of size $B \times d$ each, where $\mathbf{X} \in \{\mathbf{Q}, \mathbf{K}, \mathbf{V}, \mathbf{O}\}$.
 Initialize mask $\mathbf{M} \in \mathbb{R}^{B \times B}$, where $M_{ts} = 1$, if $t \geq s$, else 0.
 Initialize $\mathbf{KV} = \mathbf{0} \in \mathbb{R}^{d \times d}$.
for $t = 1, \dots, T$ **do**
 Load $\mathbf{Q}_t, \mathbf{K}_t, \mathbf{V}_t \in \mathbb{R}^{B \times d}$ from HBM to on-chip SRAM.
 On chip, compute $\mathbf{O}_{\text{intra}} = [(\mathbf{Q}_t \mathbf{K}_t^\top) \odot \mathbf{M}] \mathbf{V}_t$.
 On chip, compute $\mathbf{O}_{\text{inter}} = \mathbf{Q}_t (\mathbf{KV})$.
 On chip, compute $\mathbf{KV} = \mathbf{KV} + \mathbf{K}_t^\top \mathbf{V}_t$.
 Write $\mathbf{O}_t = \mathbf{O}_{\text{intra}} + \mathbf{O}_{\text{inter}}$ to HBM as the t -th block of \mathbf{O} .
end for
 Return \mathbf{O} .

2.2.2. 闪电式注意力的有效性

尽管闪电注意力在小规模实验中显示出前景和竞争性能，但在大规模环境下的下游任务中的扩展行为和性能仍未得到探索。为了缩小这一差距，我们进行了一系列扩展实验，以评估闪电注意力机制与软max注意力机制相比的可扩展性，同时验证其在广泛的下游任务中的性能。值得注意的是，在我们的实验中，我们观察到闪电注意力显示出有限的检索能力。这一发现促使我们探索一种混合方法（混合闪电），该方法结合了闪电注意力和软max注意力的优势，通过每隔八层用软max注意力替换闪电注意力来提高检索性能。

我们遵循卡普兰等人（2020年）提出的FLOPs计算方法。为了我们的分析，我们定义了以下变量： L （层数）、 D （模型维度）、 \boxtimes （注意力头数）、 B （批量大小）和 N （序列长度）。模型参数和FLOPs的清单见表1。

表 1 | 不同架构的模型参数和浮点运算次数（FLOPs）比较。对于缩放定律的计算，为提高与拟合结果的一致性，排除了嵌入参数和其他次要项。

架构	参数数量	浮点运算次数计数
软阈值注意力	$12 \text{ 升 } 2$	$72 \text{ 亿 } 2 \text{ 千 } 5 \text{ 百 } 2 + 42.5 \frac{6B}{5}$
闪电般的注意力	$12_{LD^2} + 2_{LD^2/\boxtimes}$	$72_{BNLD^2} (1 + 1 + 18d) \frac{5}{5}$
混合闪电	$12 \text{ 升 } + 7 \text{ 升 } / 4 \text{ 小时}$	$72 \text{ 亿 } 2 \text{ 千 } 5 \text{ 百 } 2 \frac{(L + N + 7 + 18D) \cdot 5}{48B \cdot 16\boxtimes}$

2.2.2.1 实验设置

我们对各种规模（7000 万、1.6 亿、4.1 亿、10 亿、30 亿和 70 亿参数）的 softmax（配备 FlashAttention-2（道，2024 年））、闪电注意力和混合闪电注意力模型进行了训练。每个模型都在一个数据集上进行训练，该数据集最多包含 3000 亿个标记，上下文长度为 8192。我们的训练方法遵循钦奇利亚（霍夫曼等人，2022 年）提出的方法，其中训练损失作为测试性能的直接指标。对于每种模型架构和训练序列长度，我们都保持了

表 2 | **缩放定律总结**: 它展示了损失(L)、最优模型大小(N_{OPT})和最优数据集大小(D_{OPT})之间的关系, 作为计算预算 (C) 的函数。它揭示了, 在相同的预算下, 混合模型使用了更多的参数和标记, 但实现了更低的损失。

拱门	$L(C)$	$NOPT(C)$	$DOPT(C)$
软阈值注意力	$3.7087 C^{-0.0798}$	$(1.82 \times 10^{-8}) C^{0.7118}$	$(2.56 \times 10^{-10}) C^{0.5102}$
闪电般的注意力	$3.5391 C^{-0.0768}$	$(2.74 \times 10^{-8}) C^{0.6470}$	$(4.43 \times 10^{-10}) C^{0.4684}$
混合闪电	$3.4797 \text{ 乘以 } C^{-0.0763}$	$(2.57 \times 10^{-8}) C^{0.6670}$	$(3.70 \times 10^{-10}) C^{0.4707}$

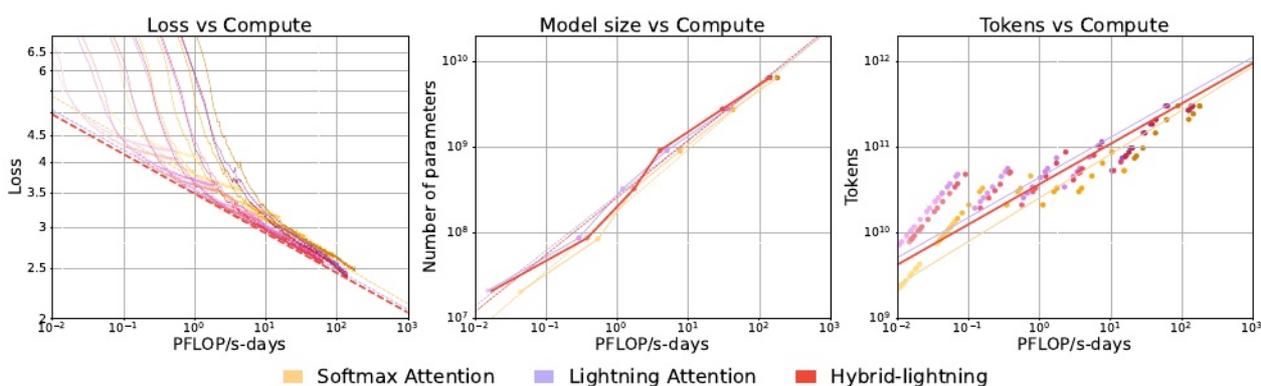


图 6 | **缩放定律总结**。训练曲线(左)涵盖了从 70M 到 7B 参数的模型。基于指定的计算预算估算, 推导出最优模型规模(中)和训练标记(右)。

统一的全球批次大小为 400 万个标记。采用了 Adam 优化器, 配置的学习率为 $3e-4$, 权重衰减为 0.1。由于计算资源受限, 在所有实验中应用了固定的学习率调度器。

我们采用了多种评估基准, 包括 BoolQ (克拉克等人, 2019 年)、PIQA (比斯克等人, 2020 年)、SIQA (萨普等人, 2019 年)、HellaSwag (泽勒斯等人, 2019 年)、WinoGrande (坂口等人, 2021 年)、ARC (包括简单和挑战两种变体) (克拉克等人, 2018 年)、OpenBookQA (米哈伊洛夫等人, 2018 年)、大海捞针 (NIAH) (沈等人, 2024 年) 以及 SCROLLS (沙哈姆等人, 2022 年)。每个基准评估模型的不同能力。

2.2.2.2 缩放定律

我们基于上述设置下的实验来拟合缩放曲线, 其中我们针对不同的计算预算 (C) 改变模型大小 (N) 和数据集大小 (D), 并观察相应的训练损失 (L), 将其作为测试损失的估计值。我们首先按照钦奇利亚的方法 (霍夫曼等人, 2022 年) 建立 L and C 之间的幂律关系。使用拟合的曲线, 我们推导出最优模型大小 $N_{OPT} \propto C^A$ and 最优数据集大小 $D_{OPT} \propto C^B$ 的系数。原始缩放定律 (卡普兰等人, 2020 年) 使用 $L(X) = (X_0/X)^{\alpha_X}$, 而后续研究 (克拉克等人, 2022 年; 高等人, 2024 年; 海尼汉等人, 2020 年; 霍夫曼等人, 2022 年) 采用 $L(X) = \beta_X + (X_0/X)^{\alpha_X}$ for 更好的拟合, 其中 β_X 表示不可减少的损失。为了简化, 我们将这些形式统一为 $L(X) = \beta_X X^{\alpha_X}$, 以便基于 α_X and β_X 直接比较缩放能力。缩放定律的总结见表 2 和图 6。可以直观地理解, 在相同的计算预算下, 具有闪电注意力机制的模型往往比具有纯 softmax 注意力机制的模型使用更多的参数和标记, 但它们实现了更低的损失。

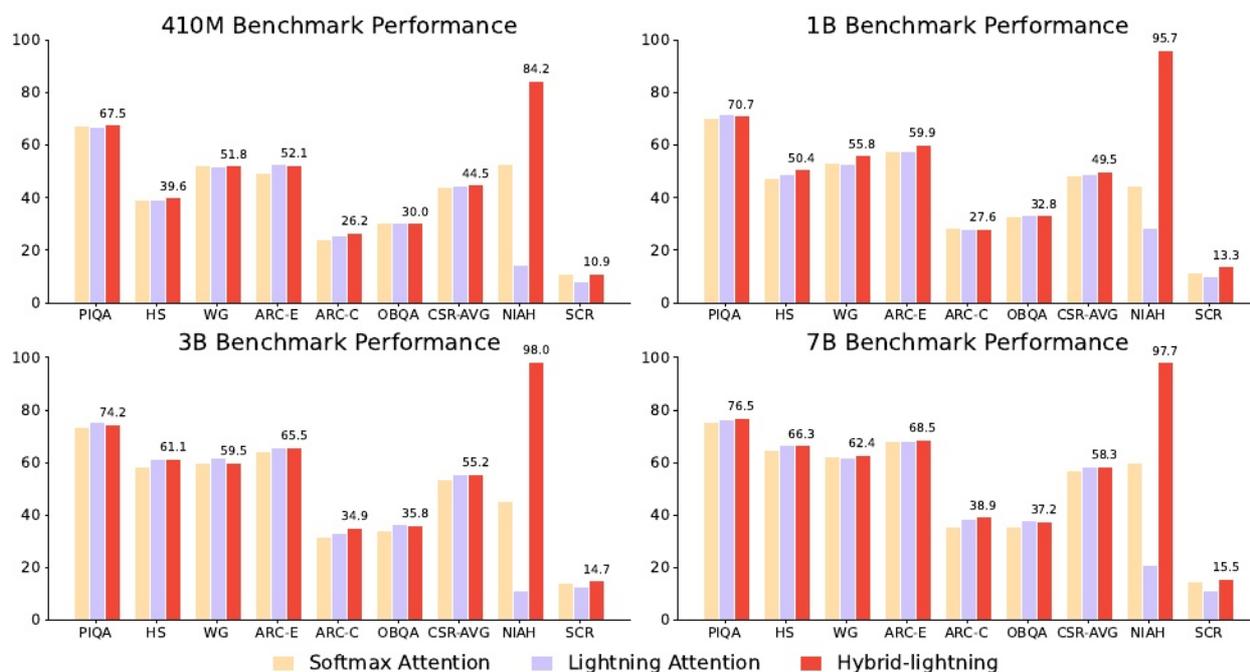


图 7 | 较大的模型和混合闪电注意力机制在各项基准测试中表现最佳。使用从 4.1 亿到 70 亿参数的三个注意力机制模型，在 CSR（常识推理）、NIAH（大海捞针）和 SCR（滚屏）基准测试中对性能进行了评估。

2.2.2.3 下游任务的性能

我们在图 7 中展示了下游任务的基准结果。闪电注意力在大多数下游任务中表现相当，但 NIAH 除外。这表明线性注意力在语言建模能力方面与 Transformer 模型相当，但在检索任务中表现不足，不适合大型语言模型。然而，混合闪电注意力不仅匹配而且超越了 softmax 注意力的检索和外推能力，使其成为

非常适合大型语言模型中的情境学习。

2.2.2.4 速度。

我们通过测量每个 GPU 每秒处理的令牌数（TGS）来评估具有 30 亿个参数的 softmax 注意力、闪电注意力和混合闪电模型的端到端训练速度。为了完整性，我们还包括了流行的线性模型，如 HGRN2 和 Mamba2 在我们的评估中。对于速度基准测试，训练上下文长度逐渐增加，直到在单个节点 H800 GPU 上达到内存不足的限制。如图 8 所示，闪电注意力无论序列长度如何都能实现恒定的训练速度，并且是唯一优于 FlashAttention2 的线性模型。

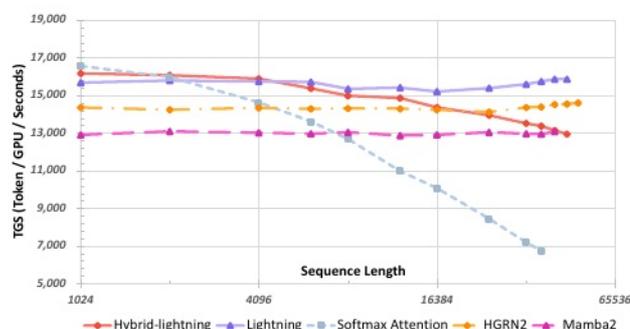


图 8 | 对包括 softmax、闪电、混合闪电、HGRN2 和 Mamba2 在内的各种注意力机制的训练速度进行了基准测试，测试的序列长度范围从 1024 到 65536 不等。性能是根据训练速度来衡量的，以每个 GPU 每秒处理的令牌数（TGS）来报告。

2.2.3. 混合架构

我们对混合架构的初步实验取得了有希望的结果，这激励我们通过两种变体：混合-cosformer2和混合-hgrn2，进一步探索其潜力。在混合-cosformer2模型中，我们每隔八层用softmax注意力层替换cosformer2架构中的线性注意力层。这种替换策略同样应用于混合-hgrn2模型中。我们使用一致的设置进行实验，以评估这些替代方案的下游性能。我们的研究结果如表3所示，表明混合-lightning模型实现了最佳性能。

表3 | 对具有 10 亿个参数的各种混合线性模型进行基准测试。我们展示了平均的 CSR 分数、NIAH 的加权平均准确率以及平均的 SCROLLS 分数。分数越高表明在所有任务中的表现越好。缩写：TGS（每个 GPU 每秒的令牌数）、HS（HellaSwag）、WG（WinoGrande）、OBQA（OpenBookQA）、NIAH 和 SCR（SCROLLS）。

混合线性拱	TGS ↑	PIQA ↑	HS ↑ 表示W高烧”	ARC-E ↑	ARC-C ↑	客观问答 ↑	企业社会责任 ↑	非传染性疾病 ↑	供应链风险 ↑	
混合变形器 2	23.3千米	70.29	45.63	51.46	55.77	26.11	30.60	46.64	43.6	10.9
混合型 hgrn2	29.5千米	70.89	51.23	56.51	59.68	28.50	32.40	49.87	91.8	10.8
混合闪电	33.4千米	70.73	50.41	55.80	59.93	27.65	32.80	49.55	95.7	13.3

除了线性模型外，滑动窗口注意力机制还可以通过适当调整窗口大小来实现线性计算复杂度。由于它基于softmax注意力机制，因此可以作为评估线性架构的强大基准。因此，我们通过每八个层中用全softmax注意力机制替换滑动窗口注意力机制来引入混合窗口方法。我们评估了从256到1024的各种SWA窗口大小。我们的结果表明，与混合闪电模型相比，较大的窗口大小会导致训练速度变慢。为了在等速度条件下比较这些模型，我们不考虑大于1024的窗口大小。如表4所示，混合闪电模型在所有指标上都优于其他所有模型，特别是在NIAH基准测试中表现出色。

表4 | 混合闪电模型和混合窗口模型的基准比较。指标包括平均CSR分数、加权NIAH准确率和平均SCROLLS分数。分数越高，表明在所有任务中的表现越好。缩写：PS（参数大小，亿）、W.S.（SWA的窗口大小）、HS（HellaSwag）、WG（WinoGrande）、OBQA（OpenBookQA）、NIAH、SCR（SCROLLS）、TGS（每个GPU每秒的令牌数）。

附言	阿奇。	至此	TGS ↑	PIQA ↑	HS ↑ 表示W高烧”	ARC-E ↑	ARC-C ↑	客观问答 ↑	企业社会责任 ↑	非侵入性脑机接口 ↑	供应链风险 ↑	
1B	混合窗	256	35.6千米	70.29	48.68	53.35	57.95	28.75	32.60	48.61	46.8	10.6
		512	35.1千米	70.95	48.19	52.33	57.53	27.22	30.00	47.70	25.7	11.9
		1024	33.6千米	69.75	47.80	53.12	57.53	28.33	31.60	48.02	53.9	10.6
	混合闪电		33.4千米	70.73	50.41	55.80	59.93	27.65	32.80	49.55	95.7	13.3
3B	混合窗	256	16.1千米	73.83	59.70	59.59	64.10	33.62	35.00	54.31	40.9	14.2
		512	15.8千米	73.29	60.00	59.04	62.96	32.51	36.00	53.97	57.9	14.2
		1024	15.4千米	74.27	59.02	57.85	64.56	31.91	33.00	53.44	41.6	13.3
	混合闪电		15.1千米	74.21	61.06	59.51	65.49	34.90	35.80	55.16	98.0	14.7

2.2.4. 讨论

基于我们对缩放定律实验、下游性能和速度比较的分析，我们得出结论：虽然纯线性注意力模型在计算上是高效的，但它们并不适用。

对于大型语言模型（LLMs）来说。这是由于它们天生无法执行检索，而这种能力对于上下文学习至关重要。相比之下，我们的混合模型不仅在检索和外推任务上与 softmax 注意力相当，而且还超越了它。这一结果有点违反直觉。要理解这一现象，请考虑以下对 softmax 注意力的解释：

$$\mathbf{O} = \text{Softmax}(\mathbf{Q}\mathbf{K}^\top/\sqrt{d})\mathbf{V}. \quad (10)$$

它可以重写为线性递归的形式，如下所示：

$$s_t^0 = 0, \quad s_t^j = s_t^{j-1} + \exp(\mathbf{q}_t \mathbf{k}_j^\top / \sqrt{d}), \quad \mathbf{o}_t^j = (s_t^{j-1}/s_t^j) \mathbf{o}_t^{j-1} + (1 - s_t^{j-1}/s_t^j) \mathbf{v}_j, \quad \mathbf{o}_t = \mathbf{o}_t^t, j = 1, \dots, t. \quad (11)$$

请注意，闪电注意力机制的线性递归形式如下：

$$\mathbf{k}\mathbf{v}_0 = 0, \quad \mathbf{k}\mathbf{v}_j = \mathbf{k}\mathbf{v}_{j-1} + \mathbf{k}_j \mathbf{v}_j^\top \quad \mathbf{o}_j = \mathbf{k}\mathbf{v}_j^\top \mathbf{q}_j, j = 1, \dots, t. \quad (12)$$

softmax 注意力机制可以被解释为线性循环神经网络（Qin 等人，2024a）。在每个时间步长 T ，隐藏状态从初始时间 $T_0 = 1$ 重新计算，这个过程通常被描述为“翻阅一本书”。这种方法使模型能够通过系统地重访先前的数据来准确地保留输入信息。相比之下，线性模型缺乏这种重新计算的过程，这阻碍了它们有效保留输入数据的能力。

我们将 RNN 的容量定义为其循环状态的大小。仔细研究公式 11，我们可以推断出 softmax 注意力的容量为 $O(D)$ 。相比之下，如公式 12 所示，闪电注意力的容量为 $O(D^2/\boxtimes)$ 。鉴于 $D > \boxtimes$ ，因此闪电注意力比 softmax 注意力具有更大的容量。因此，与仅依赖 softmax 注意力的模型相比，混合闪电模型表现出更出色的检索和外推能力。

2.3. MoE 中的模块消融

基于前几节得出的结论，我们又进行了两组额外的消融实验，以大规模验证 MoE 架构内的模块选择：

(1) 混合闪电注意力与软最大化注意力：验证混合闪电注意力在 MoE 中的优势。(2) 前层归一化与后层归一化：在我们的混合架构中，模型的有效深度起着重要作用。因此，我们期望为深度模型找到一种更好的归一化算法。

混合闪电注意力与软注意力分析。我们在 MoE 架构中对软注意力和混合闪电注意力进行了小规模的对比分析。具体来说，我们使用一个具有 2800 亿个参数的 MoE，其中包含 50 亿个激活参数，这些参数使用软注意力作为基础模型。对于基础模型中连续的 8 层，我们系统地将前 7 层中的软注意力替换为闪电注意力。基础模型和修改后的模型都在 1 万亿个标记上进行训练。如表 5 所示，结果表明，将某些软注意力层替换为闪电注意力层可以提高大多数基准测试的准确性。

前层归一化与后层归一化。前层归一化（Baevski 和 Auli，2018；Child 等人，2019；Wang 等人，2019）（PreNorm），即在残差连接和注意力机制之前应用归一化层，在大规模语言模型中显示出增强的稳定性和性能。由于前层归一化允许梯度通过残差连接更直接地从输出流向输入，在一定程度上绕过子层，它减少了模型的有效深度。相比之下，后层归一化（Wang 等人，2019）（PostNorm）在残差连接和注意力机制之后应用归一化，从而保持

模型的有效深度。然而，PostNorm 容易出现梯度消失和梯度爆炸的情况，这在训练大型语言模型（LLMs）时带来了重大挑战。大多数现有的 LLMs 主要使用 PreNorm，因为在传统的 Transformer 架构中，较宽和较深的网络之间的性能差异往往可以忽略不计，并且训练稳定性是优先考虑的。

这些实验是在具有93亿个激活参数和总共600亿个参数的模型上进行，每个模型由48层组成，采用不同的归一化方法。两个模型都在5000亿个标记上进行训练。对于PostNorm，我们使用DeepNorm（Wang等，2024a）来确保更稳定的训练。如表5所示，PostNorm在所有评估指标上始终优于PreNorm。

表 5 | 模块消融。缩写：BBH（大型基准测试硬任务）、DROP（段落离散推理）、MMLU（大规模多任务语言理解）、CMMLU（大规模多任务中文语言理解）、GSM8k（八年级数学）、ARC-C（ARC 挑战）、WG（WinoGrande）

阿奇。	BBH ↑	“DROP ↑”	中文理解限制 MMLU ↑	数学 ↑	全球移动通信系统 ARC-C ↑	WG ↑		
软阈值	28.2	27.4	49.3	47.3	4.6	18.8	46.4	65.6
混合闪电	32.2	29.0	49.5	46.0	6.8	18.5	47.4	67.5
前层归一化	29.9	26.8	43.9	41.8	4.8	12.2	43.5	65.5
后层归一化	32.6	27.6	50.2	49.2	5.7	16.8	46.2	65.4

2.4. 模型规格

在确定模型模块的架构之后，后续步骤包括模型缩放，这需要仔细设计模型在不同维度的超参数。我们的主要目标是平衡性能和推理效率。单设备推理比多设备实现具有更高的效率，因为消除了跨机器通信开销。因此，我们将模型的总参数限制在5000亿个，以确保与8×80G配置下的单节点推理兼容，对于最大1M个标记的序列，使用8位量化。鉴于我们的有限训练预算，我们制定了以下优化问题来确定最优参数分配：

$$\min_{P_{\text{all}}, P_{\text{act}}} L(P_{\text{all}}, P_{\text{act}}, T) \quad \text{subject to} \quad C_{\text{compute}}(P_{\text{all}}, P_{\text{act}}, T) < C \quad \text{and} \quad P_{\text{all}} < 500B, \quad (13)$$

其中， L 表示损失， P_{all} 和 P_{act} 分别表示总参数数和激活参数数， T 是训练标记的数量， C_{compute} 表示计算成本（取决于参数数量和数据消耗）， C 表示预算限制。

通过对小规模模型的对比实验，我们首先确定了几个关键变量的最优范围：（1）softmax 和线性注意力机制之间的混合比例；（2）模型架构的深度与宽度之比；（3）线性注意力机制的内存大小与隐藏大小之比；（4）激活的 FFN 与注意力的比例；（5）在 softmax 注意力中使用 RoPE 的维度比例。

我们的实验表明，混合架构对层深特别敏感，更深层次的模型始终优于较浅层次的模型。值得注意的是，浅层模型需要更多的 softmax 注意力层才能实现相当的性能，突出了更深层次架构的效率优势。我们还观察到，增加线性注意力内存大小显著提高了模型性能，并且在一半的 softmax 注意力维度上实现 RoPE 能够实现长度外推，而不会导致性能下降。

基于这些优化的架构变量，我们采用已建立的缩放定律（Clark等人，2022年；Hoffmann等人，2022年）来确定最优模型大小。我们使用从4400万到12亿的激活参数，在5000亿个标记上训练模型，使用16、32和64个专家。然而，我们发现这些方法在推断到具有93亿个参数的更大模型时，预测变得不那么可靠。为了解决这一局限性并实现更准确的预测，我们提出了以下公式：

$$L(P_{\text{act}}, T|E) = d + aP_{\text{act}}^{\alpha} + bT^{\beta} + c(P_{\text{act}}T)^{\gamma}, \quad (14)$$

其中， $L(P_{\text{act}}, T|E)$ 表示与专家数量相关的损失条件，而A、B、C、D、 α 、 β 和 γ 是与专家数量相关的待拟合参数。基于对公式 13 和公式 14 的预测，我们已确定了一个候选模型，其具有 459 亿个激活参数和 4560 亿个总参数，作为最优配置。

3. 计算优化

在本节中，我们介绍我们的计算部分，包括训练和推理。在这个项目中，我们有一个动态变化的GPU集群，其中H800 GPU的数量在1500到2500之间。高效的架构需要强大的实现优化，以充分利用其大规模计算的优势。为了将我们的新架构扩展到所需的大小，我们提出了三个关键的优化策略，主要解决以下三个挑战：

1. 在专家混合（MoE）架构的训练过程中，减轻全对全（a2a）通信开销是一个持续的挑战。我们选择的专家配置，特别是选择大型模型，对 GPU 内存提出了巨大的需求。因此，主要的挑战在于在内存利用率、计算效率以及与全对全通信相关的开销之间实现最优平衡。
2. 由于我们努力在训练和推理中支持至少100万个标记上下文窗口，因此，在不同GPU上准确分配标记在如此广泛的上下文窗口内变得至关重要。然而，这种必要性不可避免地引入了额外的通信开销。因此，设计策略以最小化这种开销，特别是在我们的混合架构中，是一个巨大的挑战。
3. 当前闪电注意力机制的实现是专门针对训练过程进行优化的。然而，在推理场景中，挑战在于如何有效地处理现实世界中的批量输入，这些输入可能包含可变序列长度以及包含前缀缓存的特定输入。

值得注意的是，目前行业中的现有开源框架缺乏必要的成熟技术支持，无法充分应对这些挑战。因此，我们独立且全面地重塑了我们的分布式训练和推理框架，从而以期望的效率水平成功应对了这些挑战。

3.1. 模型误差优化

优化 MoE 架构的主要目标是最小化通信开销，特别是对于使用全对全（a2a）通信的 MoE 模型。为了解决这个问题，我们实现了一种基于令牌分组的重叠方案，如图 9 所示。在该方案中，a2a 通信在专家并行（EP）通信组内进行，并且它与来自不同专家组的令牌的处理相互重叠。为了确保通信的正确性

结果，我们将每个 ProcessGroup 限制为按顺序执行通信运算符。因此，不同组之间的 a2a 通信不能重叠，从而导致空闲时间的出现。

这种方法带来了显著的性能提升。然而，经过更详细的分析，我们发现了一个与 MiniMax-Text-01 模型的专家配置相关的关键权衡。当采用张量并行性（TP）来划分专家参数时，计算强度

变得过低，从而阻碍了计算的效率。然而，选择不使用 TP 会导致参数数量过多，这就需要激活更大的流水线并行（PP）配置。

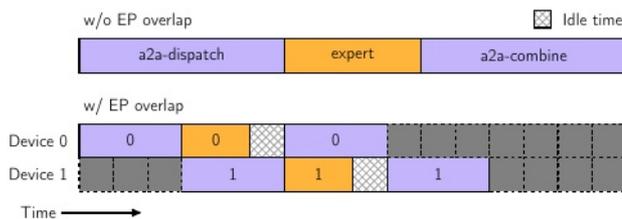


图 9 | 专家并行（EP）重叠图示。将数据块分成 2 组，这样计算就可以与不同组之间的通信重叠。

挑战的出现是因为 PP 确实

不会减少存储激活所需的内存占用。这种限制对于训练具有长上下文的模型尤其不利，因为内存消耗的增加在计算效率或训练速度方面并没有提供相应的益处。因此，必须开发一种新的参数分区策略，以平衡内存使用和计算强度，从而优化我们特定模型和任务的训练过程。

为了提高效率，我们首先引入了一个新颖的 ProcessGroup，称为 ETP（专家张量并行），专门用于管理专家的权重划分。同时，我们还提出了另一个不同的 ProcessGroup，名为 EDP（专家数据并行），用于封装相同专家的数据并行性。在我们的系统中，我们将参与训练的 GPU 总数定义为 WORLD_SIZE。该系统必须满足两个关键条件：

$$world_size = size_{pp} \times size_{dp} \times size_{cp} \times size_{tp} \quad (15)$$

并且

$$world_size = size_{pp} \times size_{edp} \times size_{etp} \times size_{ep} \quad (16)$$

这种配置使 MoE 组件能够灵活地定义专家的分布、管理专家的权重分配，并独立配置 ZeRO（零冗余优化器）算法（Rajbhandari 等人，2020 年）。基于这种实现方式，我们能够将 MoE 组件的并行策略与非 MoE 组件的并行策略完全解耦。

基于这一修改，我们可以灵活配置 ETP，以实现内存使用和计算强度之间的最佳平衡。此外，为了减轻通信开销，我们设计了一种 EP-ETP 重叠策略。该策略旨在最大化利用网络资源和计算资源，如图 10 (a) 所示。

由于同一进程组内的通信必须按顺序执行，长时间的计算不仅有助于与更多通信的重叠，还为不同进程组之间的通信重叠创造了更多机会，从而提高了整体性能，如图 10(b) 所示。

在确定分组数量时，必须考虑几个权衡因素。理论上，只有将工作负载分成足够多的组，才能实现通信和计算之间的充分重叠，如图 10 (c) 所示。然而，在实践中，过多的分组数量会显著增加调度的复杂性，并引入

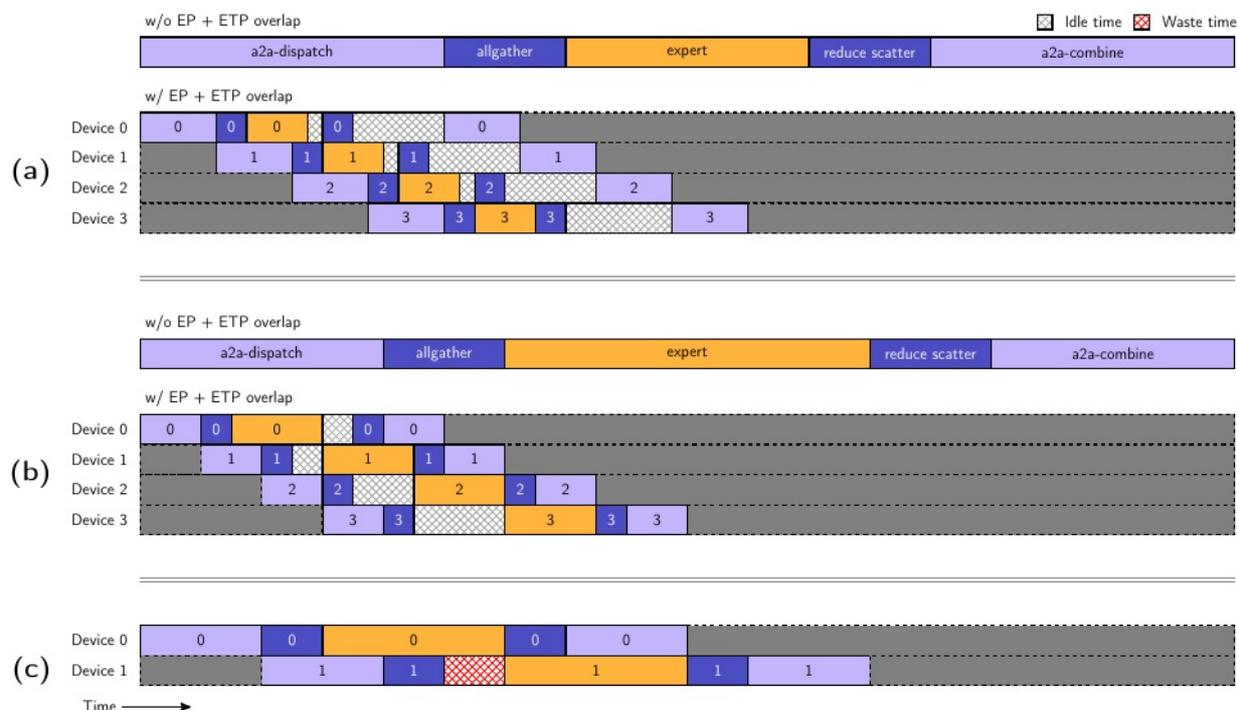


图 10 | EP-ETP 重叠图示。(a) EP-ETP 与较低计算部分的重叠。(b) EP-ETP 与较高计算部分的重叠。(c) EP-ETP 与较少组数的重叠。与 (a) 和 (b) 相比，表明如果计算时间成本更长，效率会更高。与 (b) 和 (c) 相比，表明组数较少会导致重叠不足。

存在成为 CPU 瓶颈的风险。鉴于专家型张量并行 (ETP) 在整个专家混合 (MoE) 架构中所占比例不大，根据具体情况和需求进行调整至关重要。

通过上述优化策略，我们实现了在 MiniMax-Text-01 模型的 MoE (专家混合) 结构中针对特定专家规范的存储和计算强度的平衡配置。此外，基于这些优化，与优化前的状态相比，我们将 MoE 组件的纯通信开销减少了 50%，从而显著提高了训练效率。

3.2. 长期上下文优化

在长上下文训练中，一个显著的挑战是真实的训练样本难以标准化为统一长度。使用填充使样本长度相同的方法会导致大量的计算浪费。在 1M 序列长度规模的训练中，这种浪费变得尤为显著。为了解决这个问题，我们在训练期间采用一种数据格式化技术，即沿着序列维度将不同的样本端到端连接起来。我们将这种技术称为“数据打包”。这种格式在计算过程中最小化了计算浪费，从而节省了计算资源。

3.2.1. 可变长环注意力

对于 Softmax 注意力机制，环注意力算法 (Liu 等人, 2024a) 提供了一种有效的数据划分方法，从而实现了无限的可扩展性。然而，现有的实现方式

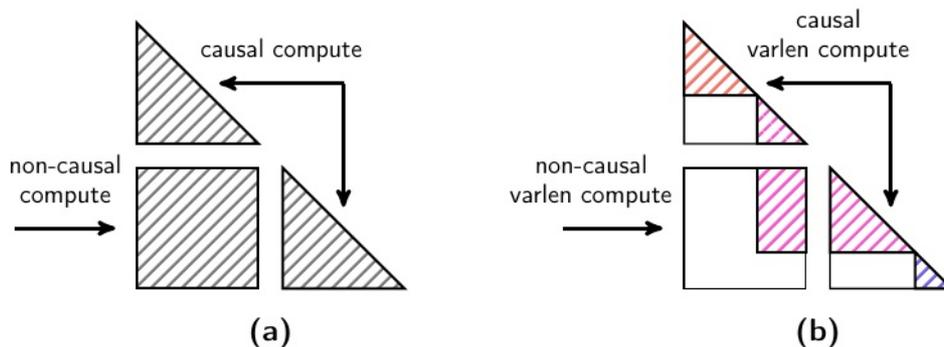


图 11 | 环注意力与变长环注意力。(a) 环注意力中无数据打包。(b) 在变长环注意力中对 3 个不同长度的样本进行打包。

对于数据打包格式，没有针对环注意力机制进行优化。在FlashAttention (Dao, 2024) 中，虽然它提供了一个变长 (variable length) 接口来适应数据打包格式，但没有相应的环注意力机制实现。关于TransformerEngine (NVIDIA, 2023)，其实现采用了上下文并行 (CP) ProcessGroup来支持环注意力算法。然而，这种方法在处理数据打包格式时存在计算资源浪费的风险。这是因为该算法将每个序列分成 $2 \times \text{SIZE}_{\text{CP}} \text{segments}$ ，并对每个段应用环注意力机制。因此，这种方法将每个序列的长度限制为必须是 $2 \times \text{SIZE}_{\text{CP}}$ 的整数倍。在样本分布未知且CP大小设置为较大值的情况下，这可能导致大量的填充，从而浪费计算资源。

受不假设样本分布原则的启发，我们重新设计了算法，并将其命名为Varlen Ring Attention。这种方法通过在数据打包后直接将环注意力算法应用于整个序列，避免了传统方法中过度的填充和随后的计算浪费。具体来说，实现涉及在环注意力计算中区分每个序列对应的注意力掩码的偏移量。关键修改是将原始的因果计算转换为可变量因果计算，并将非因果计算转换为可变量非因果计算，如图11所示。

3.2.2. 改进的线性注意力序列并行性

为了实现闪电般的注意力，LASP (线性注意力序列并行) 算法 (Sun等, 2024) 利用CP的通信组来促进长序列的扩展。如图12 (a) 所示，LASP算法要求所有CP秩参与发送-接收操作，以交换中间键值(KV)块结果。这一要求在CP秩之间建立了顺序依赖关系，从而迫使计算以串行方式进行。因此，这种顺序依赖关系极大地阻碍了训练过程的整体效率，因为系统的固有并行性没有被充分利用。

为了充分利用GPU设备的并行计算能力，我们提出了一种优化方法，通过优化计算和通信工作流程来消除计算过程中的依赖关系。这种优化有效地将串行计算转变为并行计算。增强的方法，称为LASP+ (图12 (b))，其工作原理如下：

1. 局部前缀和计算：每个计算节点，即 CP 秩，通过

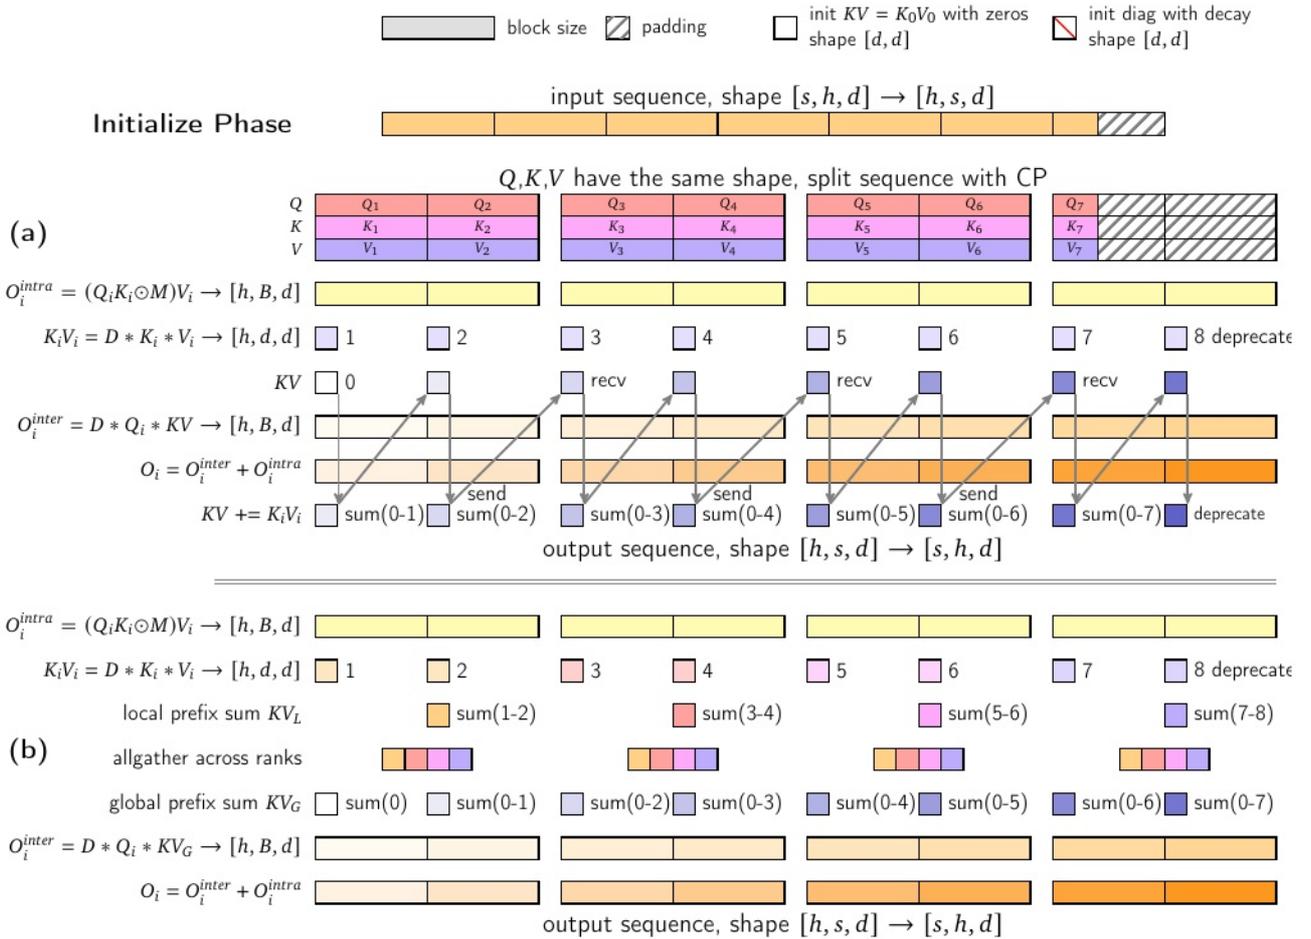


图 12 | LASP 算法和 LASP+ 算法的差异。 (a) LASP 算法。 1. 初始化阶段：将 KV 初始化为零和对角衰减矩阵。 2. 数据划分和填充：沿序列维度将 Q、K 和 V 矩阵划分为 CP 大小（图中所示为 4 个段）的块，根据 BlockSize B and 将每个块划分为更小的块，并对剩余部分（例如 Q₇、K₇、V₇）进行填充，使其能被 B 整除。 3. 块内计算：并行执行每个 CP 秩的块内计算。 4. 跨块计算与通信：从 CP 秩 0 开始，计算当前 Q_i with 所有之前的 KV 块的跨块部分以及前缀和 $K_i V_i$ 。不同的 CP 秩通过发送-接收操作进行数据通信。 (b) LASP+ 算法。基于图 (a)，每个 CP 秩计算本地前缀和 KV_L and 执行 AllGather 操作进行同步，然后选择本地前缀和 KV_L to 计算全局前缀和 KV_G 。其余的计算组件与 (a) 相同。

- 独立计算其局部前缀和，记为 KVL 。
2. 通过 AllGather 进行全局同步：在完成本地计算后，执行 AllGather 操作以在全球范围内同步来自所有节点的信息。此步骤确保每个节点都能访问来自其他所有节点的必要数据。
 3. 前缀和计算：每个节点选择特定的 CP 秩的 $KV_{L\text{on}}$ 来执行前缀和，这一决定基于其分配的计算顺序。

通过实施这些步骤，LASP+方法有效地消除了计算节点之间的原始依赖关系。这种依赖关系的消除促进了完全并行化的计算过程，从而显著提高了系统的整体效率和吞吐量。从串行计算到并行计算的转变不仅充分利用了GPU设备的全部潜力，还确保了训练过程能够更快地执行，并具有更大的可扩展性。

所提出的修改虽然会导致总通信量和临时内存使用量增加，从而产生额外的成本，但它们所带来的显著性能优势显然证明了这些修改的合理性。这些增强措施带来的性能提升远远超过了通信和内存消耗的相关开销。

通过全面的测试和验证，经验性地证明，LASP+方法中的计算速度能够达到原始LASP算法的 N_{PCN} 倍，其中 N_{PCN} 是并行计算节点的数量。此外，AllGather操作引入的开销最小，这与我们的预期一致，也突出了优化的有效性。

在LASP+框架的基础上，我们进一步引入了对变长特征的支持，以有效管理数据打包数据结构。这一增强对于处理包含不同长度的输入的批量样本特别有益。该过程包括以下步骤：1) 填充到块大小：对批量中的每个输入进行填充，以确保其长度是预定义块大小的倍数，块大小设置为256。这一填充步骤对于使数据结构与内核的计算要求对齐至关重要。2) 顺序连接：填充后，输入按顺序连接。这种连接有助于使用单个内核对多个批次进行并行计算。通过以这种方式组织数据，我们可以有效地利用GPU的并行处理能力，从而优化计算性能。

将 varlen 特性与LASP+框架相结合，确保了系统能够处理各种输入长度，同时不会牺牲效率。这种方法不仅简化了计算流程，还通过同时处理多个批次实现了资源利用率的最大化。

3.3. 闪电注意力推理优化

闪电注意力机制的初始实现主要是面向研究的，并不适合实际应用，尤其是推理。然而，在现实场景中，推理过程的优化至关重要，因为部署训练模型的长期成本主要取决于其推理的效率。为此，我们为闪电注意力机制实现了四种优化策略：批量内核融合、分离的预填充和解码执行、多级填充以及步长批量矩阵乘法扩展。

3.3.1. 批量内核融合

我们将多个内存受限的核融合在一起，并扩展支持以适应所有批输入。在预填充阶段，我们执行核融合来处理Q、K和V张量，包括在序列维度进行填充、分块、调整内部布局以及计算衰减值。在解码阶段，我们执行核融合来计算 KV 并更新前缀KV缓存。这些核融合减少了中间结果的存储和内存访问操作，从而显著提高了内存访问效率，并在解码阶段和短文本输入场景中减少了 **10%**的端到端延迟。顺便说一下，与 H800 相比，这些优化在 H20 上能带来非常显著的益处。

3.3.2. 分离的预处理和解码执行

在长序列计算中实现闪电注意力机制主要围绕块内和块间计算的区分展开。然而，这种方法对于推理任务并非最优，特别是在解码阶段，此时标记长度始终等于 1。

鉴于长度为1的令牌计算核心主要受内存限制，并且只需要数量有限的GPU流多处理器（SM），我们提出了一种策略，将长度为1的令牌的处理与长度大于1的令牌的处理分开。这是通过使用两个不同的内核来实现的。随后，我们使用两个独立的CUDA流来并行调度这些内核，从而提高计算效率并确保GPU的平衡利用，特别是在涉及混合输入的场景中。

例如，在批大小为20的情况下，所有输入都包含一个前缀键值（KV）缓存，并且场景中包括一两个具有50个令牌长度的输入，而其余输入的令牌长度为1，这种方法可以显著降低延迟。具体来说，延迟可以近似等同于仅处理较长输入的延迟，从100毫秒减少到50毫秒。

3.3.3. 多级填充

通过对沿序列维度的Q、K、V张量应用填充，可以将块内和块间分量有效地分解为多个相同的矩阵乘法。这种分解特别有利，因为它与StrideBatchedMatmul接口无缝对齐，从而有助于最大限度地提高并行处理能力。

最初，填充的块大小设置为256，这与训练参数一致。然而，在实现前缀缓存技术后，观察到一批数据中的标记长度通常低于256。这种差异导致每个矩阵乘法运算中存在冗余的计算。为了解决这种低效率并最小化不必要的计算，我们提议引入额外的分段选项，即32、64和128。

这种多级填充方法能够根据当前输入序列的长度动态选择计算规模，以最小化填充开销。通过采用这种方法，计算资源的利用得到了优化，确保系统以更高的效率和更少的冗余运行。这种战略调整不仅节省了计算资源，还促进了系统的整体性能提升。

3.3.4. 步长批量矩阵乘法扩展

我们使用 NVIDIA cuBLAS 库中的优化函数 `cublasGemmStridedBatchedEx` 来管理 `StridedBatchedMatmul` 操作，从而确保在各种硬件架构上实现高性能和通用性。同时，我们正在实施一种更广泛的核融合策略，旨在大幅提高 Hopper GPUs 的计算效率。

鉴于我们的序列划分块大小被配置为 256，相关的通用矩阵-矩阵乘法（GEMM）操作（涉及 256x256 维度的矩阵）可以利用 warp 组范围内的 WGMMA 指令进行计算。为了进一步提高内存访问效率，我们整合了 Tensor 内存加速器（TMA）的异步操作，并将某些预处理和后处理计算任务委托给 CUDA 内核异步执行。

最终，我们的目标是动态调节流水线级数，以自适应地在 H20 和 H800 GPU 架构上实现最佳性能。这种自适应控制机制将确保系统能够高效地处理不同的工作负载和硬件配置，从而最大化整体计算吞吐量和资源利用率。

通过实施上述优化，我们在 H20 GPU 上实现了超过 75% 的模型浮点运算利用率（MFU），用于端到端的推理任务（Chowdhery 等人，2023 年）。具体而言，在我们的 MiniMax-Text-01 和 MiniMax-VL-01 推理中，当考虑 MoE 结构中注意力操作和前馈网络（FFN）操作之间的延迟比时，在 1024000 个标记的序列长度下，softmax 注意力操作占延迟的 95%。相比之下，在相同条件下，闪电注意力实现的延迟贡献不到 12%。

我们的闪电注意力机制在处理具有不同序列长度的异构批输入方面表现出了显著的效率。这种效率在以下场景中尤为明显：一些输入采用了前缀缓存策略，而另一些则没有。延迟的减少不仅提高了推理过程的整体速度，还确保了系统能够处理各种输入类型，而性能下降最小。这种适应性突出了我们的闪电注意力机制在实际应用中的强大性和通用性。

4. 预训练

在本节中，我们对 MiniMax-Text-01 的预训练方法进行了概述。首先，我们详细介绍了预训练语料库的精心构建，特别强调了数据质量、标准格式以及混合策略以最大限度地提高模型性能。随后，我们概述了我们创新的数据实验框架，该框架能够快速且高效地评估数据有效性，同时将计算成本最小化。最后，我们对模型的训练超参数进行了深入分析，并提出了一种分层训练方法，该方法能够将上下文长度扩展到 400 万个标记。

4.1. 数据

4.1.1. 预训练语料库

MiniMax-Text-01 的预训练语料库包含一个全面且精心整理的数据集，涵盖了各种来源，包括学术文献、书籍、网络内容和

编程代码。我们从几个战略维度来提高语料库的质量：

- **数据质量提升**。对于大型语言模型来说，优质的数据质量至关重要。我们实施了一个复杂的过滤管道，结合基于规则的清理和去重程序，与既定实践保持一致（Penedo等人，2023年、2024年；Rae等人，2021年）。为了在细粒度上评估文档质量，我们使用上一代模型作为奖励标注器（具有5B激活和60B总参数的MoE模型）。最初，我们评估了多个质量维度，包括连贯性、简洁性、教育价值、有用性、知识丰富性和分类相关性。通过综合分析，我们发现这些指标之间存在显著的相关性，最终我们专注于三个关键维度：**知识深度、实用性和分类分布**，同时将其他指标作为次要验证指标。
- **数据格式化优化**。网站和书籍的内容，一旦经过适当的提取和清理，就可以自然地用作高质量的教科书（Gunasekar等人，2023年），无需进一步格式化。对于对话和问答数据，文本的顺序性本质上传递了对话逻辑和问答关系。尽管人类从额外的格式化（如Markdown）中受益于可读性和理解性，但我们发现，过重的格式化实际上会通过引入固定的模式来减少数据的多样性和质量，这些模式会限制人类对话中自然存在的变化。最终，为了保持格式泛化能力和适应人类对齐偏好，我们为对话和问答数据实现了一个嵌套文档格式，其中包含通用的模板，仔细平衡了自然理解和各种交互模式下的结构一致性。
- **数据混合调查**。我们开发了一种复杂的方法来调整数据分布，利用我们的三个主要质量指标。基于后续章节详细描述的实验范例，我们发现虽然高得分的内容在知识深度和有用性方面通常会在能力评估中产生更好的表现，但完全消除低得分的内容可能会对下游任务性能产生不利影响。因此，我们实施了一种平衡采样策略，首先对基础语料库进行均匀分布，然后调整采样权重以偏重高质量内容，同时保持对不同类别的充分代表性。

4.1.2. 分词

对于分词，我们采用了字节级别的字节对编码（BPE）（Brown等人，2020年；Shibata等人，1999年），并结合了预分词方法。我们策略性地对多语言内容进行上采样，以提高相应的压缩效率。最终得到的词汇表大小设定为20万个标记。

4.1.3. 数据实验

为了系统地评估我们在预训练数据质量、格式和组成方面的设计选择，我们进行了广泛的消融实验。这些实验涉及使用相当的标记数量但具有不同数据特征的多个小规模MoE模型进行训练。这种方法使我们能够分离并测量单个数据属性的影响，同时保持计算效率。

4.1.3.1 范例

公式化表述。 我们进行数据实验，以系统地比较不同模型变体的性能。具体而言，我们将实验表述为统计假设检验，用于比较基准模型与使用不同数据配置训练的模型之间的评估指标分布。在测试新数据集D的有效性时，我们将备择假设表述为 $H1: \mu_{TD} > \mu_{Tbaseline}$ ，其中 μ 表示加权平均性能指标，T表示测试样本中评估值的分布。

评估。 我们精心设计评估标准，以确保获得有意义的见解。我们考虑广泛的多项选择题基准，在查询制定中丢弃选择指数，并观察完成的可能性。我们观察样本化对数标准化准确率 $\log \text{acc}_{\text{norm}_2}$ 的分布，其定义为

$$\log \text{acc}_{\text{norm}_2}(x) = \log \text{softmax}_{p'(c \in C_x)} \{ (p'(c^*)) \},$$

其中 $P'(C) = \frac{\text{字节数}(c)}{\text{总字节数}}$

——是样本I选择C的概率（以字节为单位进行归一化）。我们选择字节 - 明智地进行标准化以排除分词器的影响，同时减轻对较长选项的不利因素。我们进行了广泛的实验，以确保该度量标准在训练过程中保持稳定，同时保持该度量标准的判别能力，其通过比率 $\Delta_{\text{obvious}} / \sigma_{\text{seed}}$ 来量化，其中 Δ_{obvious} 表示模型之间性能的明显差异， σ_{seed} 表示不同随机种子下的标准偏差。

实验效率与设置。 通过这种统计设置，我们能够进行功率分析，以确定最小测试样本量，同时将最小可检测效应（MDE）维持在与训练方差相似的水平，并保证 95% 的置信水平和 80% 的功率用于决策。在设定置信方法后，我们对令牌数量和模型大小进行了简单的缩放实验，最终确定了一个实验步骤，即使用 400 亿令牌的数据训练具有 10 亿个激活和 80 亿个总参数的混合专家模型（MoEs），其中数据混合包括 200 亿的网络文档和 200 亿的假设数据。

4.1.3.2 重复的效果

重复数据的整合已被经验性地证明会对模型的性能和泛化能力产生几个有害的影响（Hernandez等人，2022年）。因此，实施去重策略对于优化LLM的性能至关重要。最近的研究（Abdin等人，2024年；Penedo等人，2024年）表明，反复训练高质量文档可以提高下游性能，某些高质量领域被训练多达50次，重复次数通过MinHash相似度来衡量（Broder，1997年；Lee等人，2022年）。然而，我们的实证分析显示，他们的实验范例不足以评估重复的影响，因为数据效率在整个训练过程中并不一致。

为了更好地与完整训练的结果保持一致，我们引入了一个新颖的重复感知实验框架。具体来说，我们首先对数据集进行全局去重，以去除冗余的条目。然后，我们下采样文档，以使重复频率与最终训练计划的要求一致，同时遵守我们消融实验的预算限制，这与之前直接采用与最终训练阶段相同或相似的数据分布的实验设置不同。我们的研究表明，低质量的数据在训练超过两个周期后性能会大幅下降，而高质量的数据可以有效地训练多达四个周期，这与之前的研究结果相似。

观察 (Muennighoff 等人, 2023 年)。值得注意的是, 从所提出的框架得出的解决方案与使用大量更多计算资源所获得的结果更一致。通过仔细控制训练数据的重复性和质量, 我们实现了更高效和更有效的数据混合, 最终导致模型性能更好。

4.2. 训练策略

初始预训练。我们使用 Xavier 初始化方法 (Glorot 和 Bengio, 2010) 初始化所有模型参数, DeepNorm 的缩放因子设置为 $\alpha = (2N)^{0.25}$ 和 $\beta = (8N)^{-0.25}$, 其中 N denotes 是层数。我们使用 AdamW 优化器 (Loshchilov 和 Hutter, 2019), 其中 $\beta_1 = 0.9$, $\beta_2 = 0.95$, 权重衰减设置为 0.1。训练序列长度为 8192, 批次大小从初始大小 16M 逐渐增加到 69B tokens 时的 32M, 到 790B tokens 时的 64M, 最终在 4.7T tokens 时增加到 128M, 并保持到训练结束。该时间表是基于训练损失与临界批次大小之间的相关性设计的 (McCandlish 等人, 2018)。据称, 在临界批次大小下进行训练可以在训练时间和数据效率之间实现近乎最优的平衡 (Kaplan 等人, 2020)。基于此, 我们根据小型模型的数据拟合了损失与临界批次大小之间的幂律关系, 如图 13 所示。当达到相应的损失时, 批次大小会翻倍。

学习率调度方案首先进行 500 次迭代的线性预热, 达到峰值 2λ , 随后以恒定学习率进行 7.2T 个标记的训练。在训练的后期阶段, 我们注意到异常的梯度范数值。这个问题归因于过高的学习率, 我们将剩余 3.2T 个标记的学习率调整为 1.3×10^{-4} 。在快速衰减阶段, 我们训练 1T 个标记, 并将学习率指数级降低至 3×10^{-5} 。此外, 将 MoE 辅助损失系数设置为 0.01。

长上下文扩展。我们逐步将模型的训练上下文长度扩展到 100 万个标记。由于我们架构的有效性

长度外推能力, 该模型成功

在纯大海捞针检索任务 (NIAH) 测试²中成功展示了其处理多达 4M 个标记的序列的能力, 尽管它仅在多达 1M 个标记的上下文中进行了训练, 如图 14 所示。

具体来说, 我们采用三阶段训练程序, 系统地对不同长度范围的长上下文数据进行上采样, 同时保留关键领域的分布特征, 以保持短上下文的评估性能稳定。训练数据混合的细节、RoPE 基本频率和训练长度如表 6 所示。在每个阶段的最后 20% 的训练周期中, 我们还混合了 10% 的高质量长上下文问答数据, 其长度分布与长上下文预训练数据相似 (Parmar 等, 2024)。为了缓解分布式变化可能导致的不稳定性, 我们在整个过渡阶段使用特定源的权重进行线性插值。这种方法有助于数据分布逐渐和控制地向期望的目标分布演变, 从而确保训练的稳定性。

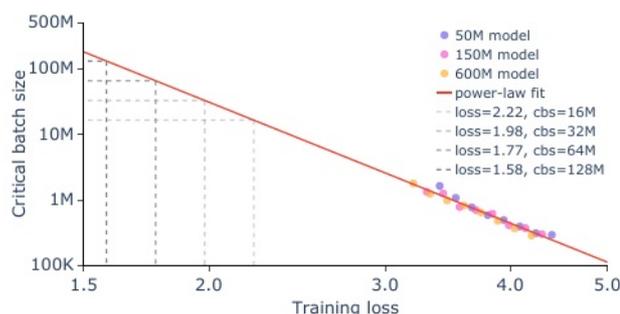


图 13 | 利用来自.....的数据对训练损失进行幂律拟合以及临界批量大小

模型在激活参数数量方面从 50M 到 600M 不等。我们用虚线灰色线条标记批量大小加倍的点。

²Same as Gemini (Team et al., 2024a), we use Paul Graham (<https://paulgraham.com/articles.html>) as the haystack and “The special magic {city} number is: {number}” as the needle.

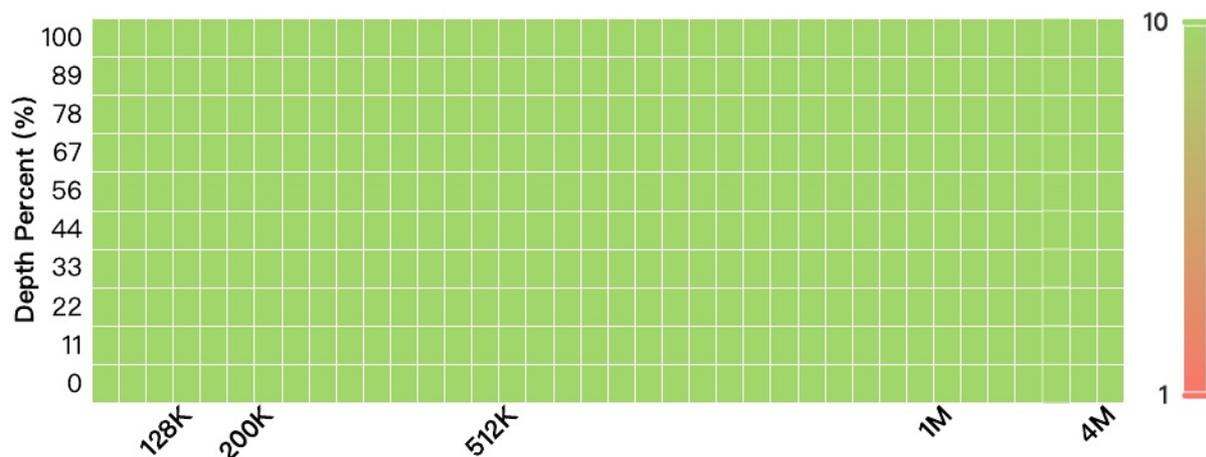


图 14 | 在 MiniMax-Text-01 上进行 **400 万次**大海捞针式的检索任务压力测试。当数量少于 100 万时，标记间隔为 32K；当数量超过 100 万时，标记间隔为 50 万。

并且保持收敛性。

此外，我们的研究表明，NIAH在训练过程中无法有效地监测模型的性能。这主要是因为 NIAH 的性能在训练初期就达到了峰值，特别是在最初的128K训练步骤中。为了解决这一局限性，我们使用更复杂的任务来评估模型的中间检查点，这些任务的设计目的是随着训练的进行而增加复杂性。值得注意的是，尽管这些任务的难度不断增加，但我们始终观察到模型性能指标的稳步提升。这种持续的上升趋势清楚地表明了实施长上下文持续预训练的关键重要性和必要性。更多细节见第5.7.2节。

表 6 | 长上下文扩展配方。为清晰起见，我们将数据分类如下：少于 32K 个标记的数据被标记为“短”；从 32K 到 128K 个标记的数据被标记为“中”；超过 128K 个标记的数据被归类为“长”。

培训时长	罗佩频率	#代币	短 (%)	介质 (百分比)	长 (%)
128,000	5米	300B	30	70	0
512千字节	10米	32B	35	35	30
1米	10米	26B	30	30	40

5. 训练后

在本节中，我们介绍了一个全面的后训练框架，旨在提高模型的综合性能、长上下文处理能力和在现实世界中的应用适用性。我们的方法始于创建多样化的、高质量的提示数据集，并伴有大规模奖励系统，该系统从多个维度评估响应：正确性、真实性、有用性和无害性。训练过程包括监督式微调 (SFT)、离线和在线强化学习 (RL)。通过这些阶段，我们系统地使模型与我们的定义目标保持一致。通过详尽的数据挖掘技术和专门的无害奖励模型，确保了模型的安全性。我们引入了一种新颖的多阶段训练方法，显著提高了模型处理扩展上下文的能力，同时保持最佳性能。

在较短序列上的表现。这种方法产生了一个强大的系统，能够处理复杂的现实世界场景。在学术和内部基准测试中进行的广泛评估表明，我们的模型在所有任务上都实现了顶尖性能，同时确立了超长上下文处理的新标准。

5.1. 及时收集

我们广泛的提示收集涵盖了来自各种来源的数百万个不同、高质量的查询。我们开发了一个标签系统，根据任务类型、知识领域和难度级别对每个提示进行分类。收集过程结合了复杂的过滤机制，以消除冗余的提示，同时保持最优的难度分布。提示集涵盖了各种领域，包括长上下文、编程、数学、逻辑推理、创意写作、函数调用、常识和安全相关场景。

5.2. 奖励模型

我们的奖励模型框架从四个关键维度评估响应，以确保与我们的核心原则保持一致：

- 正确性。我们为响应实施了一个严格的评估系统，可以严格验证。对于数学和推理任务，我们使用早期版本的 MiniMax-Text-01 根据答案的一致性生成二进制奖励信号。编程解决方案在安全的沙箱环境中进行全面测试，性能指标由测试用例成功率得出。
- 真实性。我们采用验证流程来评估响应的实际准确性。该过程包括系统响应采样、陈述分解和聚类、众包验证，以及使用先进语言模型进行自动比较以生成真实性得分。
- 有用性。我们的评估框架通过确定性和概率性方法评估对用户指令的遵循情况。我们实施了基于规则的自动化约束验证系统，并辅以对关键指标（包括连贯性、深度、上下文相关性和文体适宜性）的人工评估。最终的有用性得分通过加权评分系统结合了多个评估信号。
- 无害性。基于宪法人工智能原则（[Bai 等人, 2022 年 b](#)），我们制定了涵盖安全协议、内容适宜性和法律合规性的评估标准。我们的评估系统利用经过仔细校准的提示，并根据人类标注进行验证，早期版本的 MiniMax-Text-01 提供了标准化的安全评估。

5.3. 监督式微调

我们的SFT数据集构建涉及一个多阶段过程，利用通过迭代SFT和RL循环训练的特定领域专家模型。我们采用拒绝采样（[Bai等, 2022a](#)；[Dubey等, 2024](#)）来生成高质量的专家响应，对每个提示在不同温度设置下进行多次采样，以选择由奖励层次衡量的最优演示。响应选择过程还结合了n-gram和语义相似度过滤器，以确保训练数据的最大多样性和质量。

5.4. 强化学习

5.4.1. 离线强化学习

我们引入了离线强化学习阶段，即直接偏好优化（DPO）（Rafailov 等人，2023 年），以优化模型在不同提示分布下的性能，因为对于长上下文场景，它简单且易于构建数据。我们特别关注与 SFT 阶段所使用的提示保持分布一致性的提示。为了评估提示选择的影响，我们使用两种提示类别进行对比实验：SFT 训练的提示和未经 SFT 训练但同源的提示。实验结果表明，SFT 训练的提示与其未经训练的对等提示之间的性能差异可以忽略不计。因此，我们在离线强化学习阶段采用 SFT 训练的提示。实验方案包括针对每个提示使用不同的温度参数生成响应，然后使用第 5.2 节中描述的奖励模型进行系统评估。然后我们确定最佳和最差的响应，以构建用于 DPO 训练的偏好对。

5.4.2. 在线强化学习

在线学习相比离线学习方法具有更高的样本效率和跨域泛化能力。因此，我们采用在线强化学习来提高模型性能，特别是在数学推理任务中。我们的方法强调提示的多样性，并优先考虑成功率适中的提示，以最大化策略更新期间的信息增益。值得注意的是，我们在在线强化学习中使用了未经 SFT 训练的提示，因为我们的实证观察表明，重复使用之前阶段的提示会导致模型饱和，表现为响应困惑度降低。我们提出了一种改进的分组相对策略优化（GRPO）（Shao 等，2024）方法，包括以下关键创新：

- **重要性采样权重裁剪**。传统的 PPO/GRPO 实现采用单边裁剪（Schulman 等人，2017 年；邵等人，2024 年），有时在处理具有较大策略比率和负优势的标记时会导致梯度不稳定。为了解决这个问题，我们在损失函数中实现了额外的裁剪，丢弃了这种情况，这有效地调节了重要性采样的幅度并减轻了噪声传播。
- **KL 散度优化**。由于存在类似的梯度不稳定性问题，我们通过对方差 - 偏差权衡的理论分析重新构建 KL 散度项，以进一步稳定梯度行为，从而得到 $D_{\text{KL}}(\theta) = E_T[\text{SG}(\pi_\theta(A_T|S_T) - \pi_{\text{ref}}(A_T|S_T)) \log \pi_\theta(A_T|S_T)]$ ，其中 $\text{SG}(\cdot)$ 表示停止梯度运算符。这种公式在保持策略一致性的同时减少了梯度方差。
- **平衡优势估计**。我们还确保了正例和负例之间的奖励贡献是公平的，这在分布不均衡的场景中特别有效。这种方法通过调节不同示例组之间的奖励绝对大小来保持稳定的训练动态。

5.5. 安全校准

在我们的模型中，安全校准在 SFT 和 RL 两个阶段都得到了细致的处理。为了在模型的无害性和有用性之间达到最佳平衡，我们采用了一种包含以下关键组成部分的方法。

5.5.1. 训练数据构建

我们构建高质量的对准训练数据，重点在于确保数据的多样性和准确性。这包括实施几种数据收集方法，旨在涵盖广泛的安全场景：

- **特定安全类别提示。**利用既定的安全分类标准以及来自安全和领域专家的见解，我们为特定的安全类别生成定制的提示。这确保模型接触到一系列全面的与安全相关的场景。
- **真实世界的用户数据收集。**我们从各种网络文档中收集真实世界的用户问题，将真实且多样化的与安全相关的查询纳入我们的训练数据中。
- **及时扩充。**我们指导早期版本的 MiniMax-Text-01 根据收集到的典型的红队攻击提示生成额外的相关提示。这种方法旨在扩大安全场景的多样性，并增强模型安全机制的稳健性。

5.5.2. 使用无害奖励模型进行响应生成

为了生成安全且适当的响应，我们采用了无害奖励模型（Bai等，2022b），该模型基于一系列详细的安全规则开发。为了防止模型产生不合理的拒绝，我们仔细地将帮助原则融入安全规则中。这种整合在实现平衡的输出能力方面发挥了关键作用，使模型能够在不牺牲对用户实用性的前提下提供更安全的响应。最终的安全对齐系统在潜在滥用的防范方面表现强大，同时在预期用例中保持高性能。

5.6. 具有长上下文适应性的训练方法学

我们提出了一种系统的多阶段训练方法，以增强模型处理扩展上下文的能力，如表7所示。这种方法经过精心设计，旨在优化长序列处理能力，同时保持对常规短序列的处理性能。在整个后训练阶段，RoPE基频保持在100万，以确保位置编码的一致性。

第一阶段：初始短上下文训练。在第一阶段，我们实施了受限序列大小为 8192 个标记的 SFT。这个基础阶段确立了处理标准长度查询和响应的基准能力，这些在实际应用中占大多数。在这个阶段，我们删除了超过 8192 个标记的长上下文提示。

第二阶段：扩展上下文训练。第二阶段将序列长度显著扩展到1,032,192个标记。这一阶段包含了不同序列长度的训练样本，其中50%是长上下文提示，有助于模型全面适应广泛的上下文处理。战略性地扩展序列长度对于实现强大的长上下文处理能力至关重要。

第三阶段：短上下文偏好优化。在这个阶段，我们将序列长度恢复为 8192 个标记，并实施直接偏好优化（DPO）。这种校准确保了在常规上下文大小上的最佳性能，同时保持了之前获得的能力。

第四阶段：长上下文偏好优化。第四阶段专注于通过具有 1,032,192 个标记的序列进行深度强化学习优化来强化长上下文处理能力。此阶段采用了

类似于第三阶段的训练协议，使用完全的长上下文数据，并针对较长的序列长度进行调整。

第五阶段：在线强化学习。最后一个阶段实施了序列长度为 8192 个标记的短上下文在线强化学习。更多细节已在第 5.4.2 节中列出。

表 7 | 训练后的校准训练配方

	第一阶段	第二阶段	第三阶段	第四阶段	第五阶段
序列长度	8192	1032192	8192	1032192	8192
纪年；时代	2	2	1	1	1
批量大小	128	80	64	64	512
最大负载率	1e-5	3e-6	5e-7	5e-7	1e-6
最小负载电阻	1e-6	3e-6	5e-8	5e-7	1e-7
长时程衰减	余弦	持续不断的	余弦	持续不断的	余弦

5.7. 学术基准

我们观察并报告了开源的短上下文和长上下文基准测试，突出了我们的模型在各个方面的能力。除了将在第 5.8 节中讨论的面向用户的评估外，我们还表明，MiniMax-Text-01 是一个领先的开源模型，在长上下文检索、理解、长上下文学习和基于知识的需求方面实现了顶级性能，同时在数学、推理和代码任务方面表现出色，并在真实用户辅助场景中显示出强大的实用性。

5.7.1. 核心基准测试

MMLU (亨德里克斯等人, 2021a) 和 MMLU-Pro (王等人, 2024b) 是广泛采用的数据集，用于评估模型在广泛领域的知识程度。我们进一步观察了 SimpleQA (魏等人, 2024)，这是一个挑战模型知识边界的真实性基准，以及 C-SimpleQA (何等人, 2024b)，这是 SimpleQA 在中国文化背景下的改编版本。对于推理能力的观察，我们评估了 GPQA (雷恩等人, 2024) 用于研究生级别的知识推理，以及 DROP (杜阿等人, 2019) 用于阅读理解推理。我们使用小学级别的数学问题解决任务 GSM8k (科贝等人, 2021) 和 MATH (亨德里克斯等人, 2021b) 来测试我们的模型在数学问题解决方面的性能，这些任务涵盖了从 AMC-8 到 AIME 级别的 7 个学科。我们通过观察在 HumanEval (陈等人, 2021) 和 MBPP Plus (奥斯汀等人, 2021; 刘等人, 2023) 数据集上的 Pass@1 率来监测我们的模型的编程能力。为了测试模型理解和执行详细而微妙指令的能力，我们评估了 IFEval (周等人, 2023) 基准。此外，我们观察到竞技场硬自动 (Li 等人, 2024 年 b)，它反映了与人类偏好的一致性。

在评估我们的指令调整模型时，我们采用了贪心解码和零样本链式思维策略 (Wei 等人, 2022 年)。我们与其他领先的模型和开源的大型语言模型进行了比较，如果未报告，我们会在相同的设置下进行评估。我们在表 8 中展示了 MiniMax-Text-01 的性能。如表所示，MiniMax-Text-01 在大多数维度上都表现出色。它在中国文化背景下的 C-SimpleQA 上超越了所有模型，因为其知识边界更广泛。MiniMax-Text-01 在 MMLU、IFEval 和 Arena-Hard 上也实现了前三名的成绩，表明其在给定约束内应用综合知识的非凡能力，能够很好地满足用户查询并符合人类偏好。同时，它实现了比 GPT-4o、Claude-3.5-Sonnet 和 Llama-3.1-405B 更高的 MATH pass@1 率，并表现出相当的性能。

表 8 | 在核心学术基准测试中 MiniMax-Text-01 的表现

任务	GPT-4o	克劳德 - 3.5 - (11 - 20) 十四行诗 (10 - 22)	双子座 2.5 - 双子座 2.5 - 双子座 2.5 - 双子座 2.5	Qwen2.5 - 72B	Qwen2.5 - 72B	Qwen2.5 - 72B	Qwen2.5 - 72B	文本-01
一般								
MMLU [*]	85.7	88.3	86.8	86.5	86.1	88.5	88.6	88.5
MMLU-Pro [*]	74.4	78.0	75.8	76.4	71.1	75.9	73.3	75.7
简单问答	39.0	28.1	23.4	26.6	10.3	24.9	23.2	23.7
C-SimpleQA	64.6	56.8	59.4	63.3	52.2	64.8	54.7	67.4
IFEval(平均)	84.1	90.1	89.4	88.4	87.2	87.3	86.4	89.1
竞技场难度	92.4	87.6	85.3	72.7	81.2	91.4	63.5	89.1
推理								
GPQA [*] (钻石)	46.0	65.0	59.1	62.1	49.0	59.1	50.7	54.4
DROP [*] (F1)	89.2	88.8	89.2	89.3	85.0	91.0	92.5	87.8
数学								
GSM8k ⁺	95.6	96.9	95.2	95.4	95.8	96.7	96.7	94.8
MATH ⁺	76.6	74.1	84.6	83.9	81.8	84.6	73.8	77.4
编码								
MBPP +	76.2	75.1	75.4	75.9	77.0	78.8	73.0	71.7
人类评估	90.2	93.7	86.6	89.6	86.6	92.1	89.0	86.9

* 在零样本的 CoT 设置下进行评估。

在 HumanEval 上使用经过指导的 Qwen2.5 - 72B 进行性能测试。此外，MiniMax - Text - 01 在 GPQA Diamond 上达到 54.4 分，超过了大多数开源的指令调整的大语言模型和最新版本的 GPT - 4o。

5.7.2. 长时间基准测试

正如之前在 4.2 节的长上下文扩展部分所讨论的，NIAH 任务对于我们的模型来说过于简单，不足以观察模型的优化过程。因此，我们将评估转向更具挑战性的任务。我们当前的长上下文评估框架主要关注三个方面：（1）长上下文检索，（2）长上下文理解，（3）长上下文内学习。

5.7.2.1 长上下文检索

该维度评估模型的记忆能力，这是几乎所有长上下文任务的基础。除了基本的 k -M NIAH (Kamradt, 2023) 之外，我们还构建了一个更具挑战性的变体来评估我们的长上下文检索性能，即多轮针在干草堆中 (MR-NIAH)，作为长多轮对话上下文中检索任务的关键后备，揭示了构建终身伴侣 AI 助手的基本能力。类似于非开源的多轮共指消解 (MRCR) (Vodrahalli 等, 2024)，我们构建了 MR-NIAH 的干草堆作为历史对话，其中用户查询是合成的，但明确要求事件描述和创意写作。在最后一轮，查询要求模型重复其中一个历史请求的响应。干草堆的范围从 2K 到 1M 个标记（最多约 2000 次交互），每个针请求分别在 25%、50% 和 75% 处注入。

分别为对话。每个真实的响应包含三个核心组成部分，并且我们查看了一个调整后的召回相关性成分³。我们在附录 B.2 中展示了一个案例说明。

图15展示了MR-NIAH的比较结果。我们的模型（“MiniMax-Text-01”，红线）在英语和中文评估中，在广泛的序列长度范围内表现强劲。与竞争基准（例如，GPT、Claude和Gemini变体）相比，我们的模型在较大的输入长度下性能下降较少，突出了其在长上下文检索任务中的稳健性。

5.7.2.2 长上下文理解

该维度衡量模型对长上下文的理解能力，其中包括基于长上下文输入的逻辑推理技能。我们使用两个全面的长上下文问答数据集，Ruler（谢等人，2024年）和 LongBench-V2（白等人，2024年）来评估这一方面。Ruler 包含 13 项不同的任务，并显著引入了多步追踪和聚合任务，以评估模型的复杂推理能力。我们对 Ruler 进行了测试，序列长度高达 100 万个标记。LongBench-V2 涵盖了多种上下文类型（包括单文档和多文档、多轮对话、代码库和长结构化）中不同难度级别的问题回答任务。数据等。遵循 LongBench-V2（白等人，2024年），我们考虑了两个测试

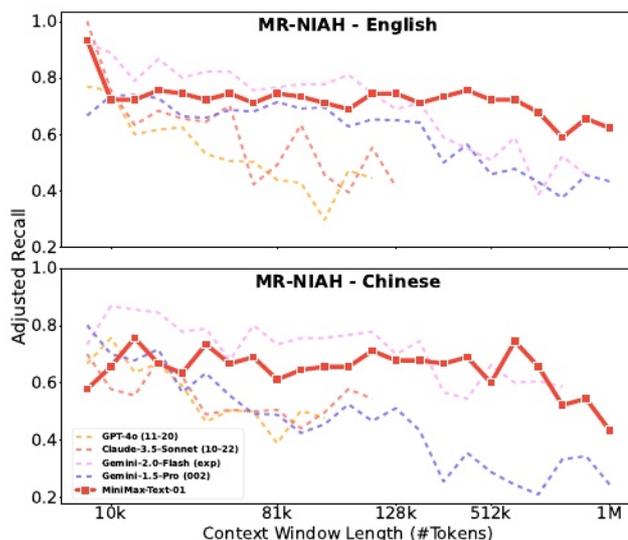


图 15 | 磁共振非特异性脑梗死 (MR-NIAH) 的英文和中文表述。

模式：无 CoT 和有 CoT，文本长度分类如下：短文本，0 至 32K 个单词；中等文本，32K 至 128K 个单词；长文本，128K 至 2M 个单词。

如表9所示，我们的模型在处理Ruler的长上下文推理任务方面表现出色。虽然在64k输入级别上的性能与领先模型（包括GPT-4o和Claude-3.5-Sonnet）相比仍有竞争力，但差异很小。MiniMax-Text-01从128k开始显示出明显的优势，取得了令人瞩目的分数，超过了所有基准模型。这种优势在超长上下文场景（如1M）中尤为明显，MiniMax-Text-01保持了其领先地位。此外，如表10-³所示，MiniMax-Text-01在LongBench-V2的长上下文推理任务中表现出色。该模型在w/ CoT设置下在所有评估系统中的表现达到最先进水平，同时也在无CoT的场景中也显示出显著的有效性。

总体而言，MiniMax-Text-01 在长上下文理解，尤其是推理任务方面表现出色，无论是否采用 CoT 推理，尤其是在需要复杂推理的场景中表现出色。该模型在处理长上下文理解任务时具有非凡的稳健性和稳定性，这可归功于其混合架构（其中一半为 RoPE）以及为预训练和校准精心调整的训练配方，这些增强了模型有效处理长序列的能力。

³We present the other models' performance reported at <https://longbench2.github.io/>

表 9 | 在尺子上对 MiniMax-Text-01 的性能比较

模型	4000	8000	16000	三十二千	64,000	128,000	256千	512千字节	1米
GPT-4o (11 - 20)	0.970	0.921	0.890	0.888	0.884	-	-	-	-
克劳德 - 3.5 - 十四行诗 (10 - 22)	0.965	0.960	0.957	0.950	0.952	0.938	-	-	-
双子座 1.5 专业版 (002)	0.962	0.960	0.960	0.958	0.938	0.917	0.916	0.861	0.850
双子座 2.0 版闪存 (实验版)	0.960	0.960	0.951	0.957	0.937	0.860	0.797	0.709	-
“迷你最大 - 文本 - 01”	0.963	0.961	0.953	0.954	0.943	0.947	0.945	0.928	0.910

表 10 | 在 LongBench v2 上对 MiniMax-Text-01 的性能比较

模型	总体	容易实现	硬的	短暂的	中等	长时间
人类	53.7	100.0	25.1	47.2	59.1	53.7
带有注释						
GPT-4o (11 - 20)	51.4	54.2	49.7	59.6	48.6	43.5
克劳德 - 3.5 - 十四行诗 (10 - 22)	46.7	55.2	41.5	53.9	41.9	44.4
“深海探索-V3”	-	-	-	-	-	-
Qwen2.5 - 72B - 安装版	43.5	47.9	40.8	48.9	40.9	39.8
“迷你最大 - 文本 - 01”	56.5	66.1	50.5	61.7	56.7	47.2
没有成本效益分析						
GPT-4o (11 - 20)	50.1	57.4	45.6	53.3	52.4	40.2
克劳德 - 3.5 - 十四行诗 (10 - 22)	41.0	46.9	37.3	46.1	38.6	37.0
“深海探索-V3”	48.7	-	-	-	-	-
Qwen2.5 - 72B - 安装版	42.1	42.7	41.8	45.6	38.1	44.4
“迷你最大 - 文本 - 01”	52.9	60.9	47.9	58.9	52.6	43.5

5.7.2.3 长期上下文学习

这一维度评估模型从上下文中学习的能力，这是终身学习的核心研究领域。我们使用 MTOB（从一本书进行机器翻译）（Tanzer 等人，2024 年）数据集来衡量我们的长期上下文学习能力。

该任务需要一种模型在英语和 Kalamang 之间进行翻译，Kalamang 是一种在公开数据方面非常有限的语言，因此训练语料库也很有限。期望 LLM 仅从语法书的部分内容和 375 个翻译例子中学习该语言，所有例子都在每个翻译查询的上下文中给出（附录 B.1）。在半本书的设定下，上下文长度约为 81K 个标记，在另一设定下约为 133K 个标记。

一个总体的书籍设定。我们在表 11 中呈现了我们的结果。

我们仔细研究了预训练数据，发现只有极少量的数据包含与 Kalamang 相关的内容。因此，在无上下文场景中，我们模型的 eng → kalam (ChrF) 分数是最低的，而其他我们比较的模型可能已经用相关的 Kalamang 数据增强了其预训练或后训练数据。除了 delta 半书和全书指标外，我们的模型在 eng → kalam (ChrF) 指标方面超过了所有模型。并且我们的模型在 kalam → eng (BLEURT) 指标方面的表现也与其他模型相当。

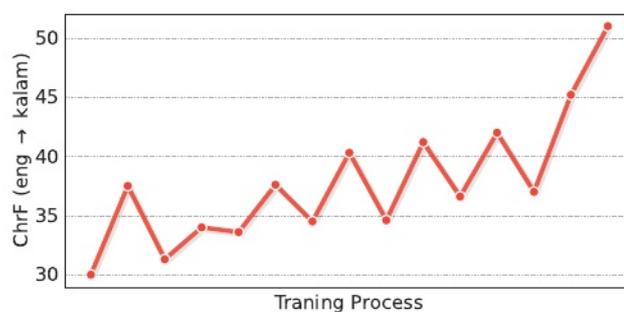


图 16 | 在整个长上下文扩展训练过程中 eng → kalam (ChrF) 的变化。

在长上下文扩展的过程中，如第4.2节所述，我们观察到上下文学习能力逐渐增强，如图16所示。虽然我们已经探索了一些专门旨在提高上下文学习能力的研究工作（Agarwal等人，2024；Dong等人，2024），但我们认为这种能力仅仅是长上下文模型推理能力的一个方面。因此，我们计划从更基本的角度对长上下文数据质量和规模进行深入研究，以进一步增强我们模型的长上下文推理能力。

表 11 | 在 MTOB 上对 MiniMax-Text-01 的性能比较

上下文类型	无上下文	半本书	整本书	Δ 半数书籍	Δ 满书
英语 \rightarrow 卡拉姆 (ChrF)					
GPT-4o (11 - 20)	9.90	54.30	-	44.40	-
克劳德 - 3.5 - 十四行诗 (10 - 22)	20.22	53.62	55.65	33.39	35.42
双子座 1.5 专业版 (002)	16.79	53.68	57.90	36.89	41.11
双子座 2.0 版闪存 (实验版)	12.20	49.50	53.30	37.30	41.10
Qwen-Long	16.55	48.48	45.94	31.92	29.39
“迷你最大 - 文本 - 01”	6.0	51.74	51.60	45.7	45.6
kalam \rightarrow 英语 (模糊)					
GPT-4o (11 - 20)	33.20	58.30	-	25.10	-
克劳德 - 3.5 - 十四行诗 (10 - 22)	31.42	59.70	62.30	28.28	30.88
双子座 1.5 专业版 (002)	32.02	61.52	63.09	29.50	31.07
双子座 2.0 版闪存 (实验版)	33.80	57.50	57.00	23.70	23.20
Qwen-Long	30.13	53.14	32.15	23.01	2.02
“迷你最大 - 文本 - 01”	33.65	57.10	58.00	23.45	24.35

5.8. 用户参与

在核心开源基准测试中取得顶尖性能的同时，我们意识到学术评估缺乏对真实世界用户交互的理解。因此，我们还专注于通过我们的 Hailuo AI⁴ 来监测和改善用户体验，基于真实世界的案例进行用户参与评估，并调整工具以在实际应用中实现更好的可用性和性能。

5.8.1. 内部评估

我们进行了一系列内部评估，包括：（1）对通用助理能力、知识问答、创意写作、硬能力、指令遵循、编程、安全和长语境的自动评估；（2）专家人工评估。值得一提的是，由于我们的测试查询主要来源于海洛人工智能用户交互，我们的内部样本中有很大部分是普通话，并深深植根于中国文化背景。

我们的研究表明，在学术基准测试中的表现与实际用户体验之间存在显著差异，领先的开源和商业模型在用作交互式助手时可能表现不佳。我们在表 12⁵ 中表明，通过我们的不懈努力，MiniMax-Text-01 能够很好地应对这些情况。总体而言，我们的模型优于其他模型。

⁴<https://www.hailuo.ai/>

⁵We omit scores for in-applicable models.

表 12 | 在内部基准测试中对 MiniMax-Text-01 的性能进行比较。

	一般 助理能力	硬的	创作知识教学	常见问题	关注	编码安全	长期背景	
GPT-4o (11 - 20)	70.9	73.5	70.3	69.2	50.4	94.0	85.4	86.2
GPT-4 (2023 年 6 月 8 日)	63.5	62.0	66	68.0	49.1	93.6	79.7	58.3
GPT-4 (2023 年 5 月 13 日)	67.7	63.3	58.3	69.6	49.6	93.2	79.7	77.2
克劳德 - 3.5 - 十四行诗 (10 - 22)	66.8	68.3	54.3	52.0	61.5	94.4	92.9	47.1
克劳德 - 3.5 - 十四行诗 (06 - 20)	60.5	67.4	51.0	51.8	64.4	93.6	95.0	47.1
双子座 2.0 版闪存 (实验版)	70.1	61.8	70.0	75.1	39.9	86.5	66.2	81.9
Qwen2.5 - 72B - 安装版	66.4	66.1	61.7	68.9	34.1	93.9	-	81.5
“DeepSeek-V3”	66.8	68.7	64.6	77.0	51.8	94.0	74.9	77.8
羊驼 - 3.1 - 405B - 安装版	53.3	-	63.6	46.0	50.3	87.6	70.7	60.3
“迷你最大 - 文本 - 01”	73.9	64.8	81.3	78.6	46.3	90.2	90.9	93.8

在常见的辅助场景中，尤其是与开源同类相比。这种优势在我们创意写作（附录B.5、B.7、B.6）和知识问答集合中最为明显，它比其他模型更紧密地符合用户意图，对广泛的问题提供准确和详细的回答。在需要长上下文的生产力场景中，如文档翻译、摘要和分析，我们的模型表现出高专业性和可靠性。此外，我们优先考虑模型的安全性，因为它在我们的内部安全基准测试中表现出色。

同时，我们能够灵活地收集和更新复杂的生产力场景，遵循多级指令，处理我们的模型失败和当前的 LLM 无法掌握的请求，构建我们的更强大能力和指令遵循内部评估。虽然领先的 LLM 在这些请求中往往表现不佳，但这些请求反映了我们的模型在接受多级指令时的局限性，这主要源于特定指令类型的训练数据不足。展望未来，我们致力于大幅扩展我们的训练数据集，加入高质量、有针对性的内容，以解决这些差距并提高模型能力。

5.8.2. 在海洛 AI 中进行搜索

在用户交互案例研究中，我们发现模型利用搜索工具的能力可以通过从网络获取实时、广泛和精确的信息来弥补有限的知识边界。为了最大化模型从搜索中获得的益处，同时最小化额外的性能下降，我们首先仔细预定义搜索场景的范围，这些场景覆盖了大约30%至40%的用户查询，包括但不限于对精度要求高、特定领域和时间敏感的请求。同时，为了确保无缝的对话体验，我们定义系统通过特殊标记直接调用工具，避免了多步规划（Chen等人，2024b）或链式推理的复杂性，这些可能会扰乱交互的自然流程。我们创建了包含不同领域中搜索和非搜索决策的 SFT 数据集，同时仔细控制与搜索决策无关的其他交互特征，如对话长度，以保持每个维度的均匀数据分布并防止过拟合。重要的是，我们使用每个样本的相应奖励模型来确保响应质量，如果做不到这一点，就会向训练中引入次优样本。

⁶<https://docs.anthropic.com/en/docs/build-with-claude/tool-use>

数据可能会影响模型的基本能力。搜索决策边界被校准以与模型的知识边界一致，从搜索语料库中丢弃模型已经掌握的样本，例如一般的中文知识问答。经过人类评估专家的仔细评估，我们得出结论，我们的模型对搜索工具的使用极大地改善了用户体验，在跨域的Hailuo AI端到端评估中，性能从58%跃升至71.5%（附录B.9）。由于我们不确定其他基于LLM的助手是否包括类似的搜索工具，我们避免进行不公平的性能比较。

6. 视觉语言模型

通过将图像编码器和图像适配器集成到我们的 MiniMax-Text-01 模型中，我们开发出了 MiniMax-VL-01，这将模型的能力扩展到了视觉理解任务。为了确保强大的视觉理解能力，我们设计了一个专有的数据集，并实施了一个多阶段训练策略，其中新引入的图像编码器和适配器首先进行大规模的视觉预训练，然后对整个流程进行全面的微调。

在下一节中，我们将对用于训练我们的图像编码器和视觉语言模型的数据集进行全面描述。随后，我们将深入探讨模型架构，并介绍我们的四阶段训练方案。最后，我们将展示我们的基准测试结果。

6.1. 多模态数据

6.1.1. 字幕数据

为了预训练视觉编码器，我们通过聚合和过滤来自互联网来源的数据，构建了一个庞大的图像-标题数据集。我们的视觉转换器（ViT）使用6.94亿对独特的图像-标题对进行训练。为了提高数据质量，我们为这些对中的1.8亿张图像获取了更精细的标题。在训练过程中，我们采用了一种扩充策略，即以等概率（ $P=0.5$ ）随机抽取原始和更精细的标题。

6.1.2. 描述数据

在现有的视觉-语言模型中，描述性图像在模型训练中的效用已被充分证明（Li 等人，2024a、2022、2023；Schuhmann 等人，2021）。为了进一步探索这一途径，我们编制了一个数据集，其中包含来自诸如 Common Crawl 等开放资源的 1 亿张图像。该数据集中每张图像都配有一个细粒度的描述，该描述最初由一个标题模型合成，随后经过人工完善。平均而言，每张图像的描述大约包含 300 个文本标记。描述数据是模态对齐和在进一步训练中增强理解的强大资源。

6.1.3. 指令数据

为了训练MiniMax-VL-01，我们通过合成一系列涉及视觉输入的问题-答案（QA）对来构建一个全面且多样化的基于指令的数据集。这些QA对经过精心设计，涵盖了广泛的图像相关任务，如文本提取、对象定位和几何问题解决。数据集生成过程优先考虑多样性和真实性，确保指令能够捕捉到不同程度的复杂性和语言风格。在训练过程中，我们应用了一种扩充策略，通过以平衡概率随机采样不同类型的QA提示，从而使模型能够有效地泛化到各种情况。

多样化的教学形式和互动模式。

6.1.4. 数据分布

为了展示我们视觉语言模型（VLM）数据的多样性，我们从指令数据中均匀抽取了100万对图像-指令对，并使用另一个VLM为每对指令分配一个简洁的标签（例如，对象定位），以表示每对指令所需的主要能力。该分析产生了约50,000个独特的标签，其中前2,817个标签出现次数超过10次。这些显著标签的分布情况如图17所示，我们将这些顶级标签进一步分为14个主要类别。

6.2. 建筑学

6.2.1. 总体架构

我们的MiniMax-VL-01架构遵循“ViT-MLP-LLM”范例，该范例在众多多模态大型语言模型（MLLMs）中得到了广泛采用。该架构由三个主要组件组成：用于视觉编码的具有3.03亿参数的视觉转换器（ViT），用于图像自适应随机初始化的两层MLP投影器，以及作为基础大型语言模型（LLM）的MiniMax-Text-01模型。

我们通过根据预定义的网格配置列表调整输入图像的大小来实现动态分辨率策略，范围从 336×336 到 2016×2016 ，同时保持一个分辨率为 336×336 的标准缩略图。随后，将调整大小的图像分割成不重叠的补丁，每个补丁的尺寸为 336×336 。图像补丁和缩略图都独立编码，它们的编码特征被连接起来构建一个全面的图像特征表示。

与依赖池化或其他下采样技术来压缩特征表示的传统方法不同，我们的模型利用其强大的处理长序列的能力，允许在训练期间直接使用原始的高维特征。这种策略减少了潜在的信息损失，并显著提高了模型对多尺度输入的适应性。此外，通过将图像块和缩略图都投影到一个统一的特征空间中，我们的方法在处理多样化和复杂的视觉输入时显著增强了模型的鲁棒性和表示表达能力。

6.2.2. 视觉编码器

我们使用轻量级的ViT-L/14（[Dosovitskiy 等人, 2021 年](#)）作为我们视觉编码器的基础结构，并从头开始对其进行训练。遵循标准流程，输入图像张量最初通过卷积层进行处理以提取离散补丁，然后对其应用绝对值

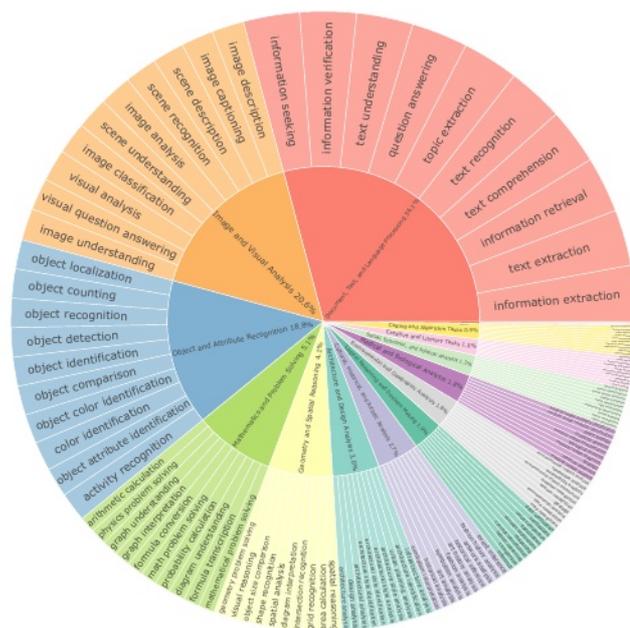


图 17 | 采样指令数据的前缀标签可视化。每组聚类标签的类别和百分比显示在内层，为清晰起见，每组仅显示前 10 个标签。

随后添加了位置嵌入。所得张量随后通过一系列多头残差注意力块。这种架构在捕捉复杂的视觉细节和图像内部的复杂相互关系方面特别有效。

我们使用对比学习来增强相应的图像-文本对之间的对齐，同时减少非相应的对之间的对齐。具体来说，我们遵循 CoCa (Yu 等人, 2022 年) 中介绍的方法，该方法通过额外的解码器和图像-文本交叉注意力机制来增强图像-文本对比学习。该网络使用对比损失和交叉熵损失的组合进行联合优化。

我们的 ViT-L/14 模型最初是在 224×224 的分辨率下针对 370 亿对图像-标题对进行训练的，随后在 336×336 的分辨率下针对 12 亿对进行了微调。对于这两种分辨率，标题都被截断为 76 个标记。我们的 ViT-L/14 编码器在 ImageNet-1K 数据集上以 336×336 的分辨率实现了零样本分类准确率为 80.55%。

6.3. 训练食谱

我们采用四阶段训练策略，以使模型能够逐步发展全面的多模态理解能力，同时保留其语言理解技能。此外，模型的问题回答和指令遵循能力，以及其与人类偏好的一致性，在这些阶段中逐步得到完善。

第一阶段：模态对齐。在这个阶段，我们的主要目标是实现视觉和文本标记之间的对齐，使模型能够为给定的图像准确生成适当的标题。为此，我们更新图像适配器和视觉编码器的权重，以优化它们在这个多模态任务中的性能。在这个阶段，我们从图像描述数据集中总共采样了 800 亿个标记。通过实验，我们发现增加图像分辨率并不会提高下游任务的准确性。因此，所有图像都以固定的分辨率 336×336 进行处理，以降低计算成本。

第二阶段：视觉理解的增强。这一阶段可以被视为标准的指令调整阶段，在此期间，所有模型参数都开放更新。主要目标是使模型的输出与人类指令一致，并增强其执行各种视觉理解任务的能力。为了实现这一目标，模型使用从我们的指令数据集中抽取的 4200 亿多模态标记进行训练，并结合 20:1 比例的 MiniMax-Text-01 后训练数据。这种方法确保了在模型获得新的多模态能力的同时，语言建模能力得以保持。

第三阶段：用户体验的提升。这一阶段旨在进一步提升模型在现实世界场景和处理具有挑战性的用户输入方面的能力。我们使用来自人们经常使用的应用程序的图像来构建复杂的多模态数据。对话被仔细标注，以模拟真实的用户输入，并确保在多个对话回合中提供准确、有用和多样化的响应。这一阶段的数据构建由一个独立的人类标注测试集指导，该测试集不仅优先考虑准确性，还优先考虑用户体验的整体质量。最终的数据集包含 448 亿个多模态标记，并经过一次训练。

第四阶段：偏好增强。在最后阶段，我们使用直接偏好优化 (DPO) 来进一步提高模型性能和用户体验。我们通过以下过程构建了一个包含 40,000 对图像-文本的训练数据集：

- 及时选择。提示是从指令数据和真实用户交互数据中整理而来的。这些提示的选择是为了涵盖广泛的通用场景，并特别针对

在第三阶段之后发现的一些持续存在的问题，例如在复杂的 OCR 场景中偶尔出现重复的输出。

- **响应生成。**我们采用了多种策略，包括：通过改变采样温度参数生成多个候选响应；在特定场景中通过图像弱化创建响应变体；以及在特定场景中使用 MiniMax-Text-01 有意地在高质量响应中引入幻觉或错误，以生成对比样本。
- **奖励分配。**在这个阶段，大型语言模型，特别是 MiniMax-Text-01，被用作评估者。多维评估标准被设计出来，以能够对提示、真实答案和生成响应之间的关系进行系统且全面的评估。
- **对偶构建。**基于评估结果，我们将得分最高的响应选为正样本，得分最低的选为负样本，同时舍弃评分差异不显著的对偶样本。

除了纳入图像-文本对之外，我们还纳入了大量纯文本对，如第5.4.1节所述。值得注意的是，当直接偏好优化（DPO）应用于高能力的基础模型时，存在过拟合的倾向。为了抵消这个问题，我们采用了早期停止策略，即在完成一个完整周期之前终止训练过程。这种方法旨在保持模型的泛化能力。

通过遵循这一多阶段训练策略，我们确保我们的模型不仅在理解和生成高质量文本方面表现出熟练性，而且还符合人类价值观和安全标准。这种全面的训练方法使我们能够在模型性能和伦理考虑之间取得平衡，从而产生一个既有效又负责任的模型。

6.4. 基准测试

为了评估我们的视觉语言模型的性能，我们维护了一系列多样化的基准测试，包括 MMMU（岳等人，2024a）、MMMU-Pro（岳等人，2024b）、ChartQA（马斯里等人，2022）、DocVQA（马修等人，2021）、OCRBench（刘等人，2024b）、AI2D（肯巴维等人，2016）、MathVista（卢等人，2023）、OlympiadBench（何等人，2024a）、MMLongBench-Doc（马等人，2024）、MEGA-Bench（陈等人，2024a）以及一个内部基准测试。这些基准测试有助于评估模型在知识、视觉推理、数学、科学、长文本处理和用户体验等各个方面的能力。我们在附录D中详细介绍了每个基准测试的评估配置。如表13所示，MiniMax-VL-01在各种视觉语言任务中表现出色，展示了以下关键优势和局限性：

常见的下游任务。在标准的视觉-语言下游任务中，MiniMax-VL-01 的表现与 GPT-4 相当，尤其在视觉问答方面表现出色。这种强大的性能归功于其广泛的多阶段训练过程，使模型能够有效地理解和推理视觉和文本输入。然而，MiniMax-VL-01 在奥数基准测试（He 等人，2024a）中仍然难以应对复杂的数学推理任务。

长上下文。我们使用 MMLongBench-Doc（马等人，2024 年）评估 MiniMax-VL-01 的长上下文理解和检索能力。结果显示，我们的模型优于大多数同类模型，但 GPT-4o-11-20 除外。尽管总体表现强劲，但 MiniMax-VL-01 在单页（准确率：47.3%）和跨页（准确率：28.4%）子集方面都显示出明显的差距。

表 13 | MiniMax-VL-01 在学术和内部基准测试中的性能。

任务	GPT-4o	克劳德 - 3.5 - (11 - 20) 十四行诗 (10 - 22)	双子座 (0.6) 双子座 (0.6) 双子座 (0.6)	光 - Qwen2 - 虚拟实验室	虚拟实验室 实习虚拟实验室 美洲驼 - 迷你/最大	2.5 - 78 巴 3.2 - 90 巴	VL-01	
知识								
MMMU* _{val} + dev	63.5	72.0	68.4	70.6	64.5	66.5	62.1	68.5
MMMU-Pro* _{完整版}	54.5	54.7	50.9	57.0	43.2	47.3	36.0	52.7
视觉问答								
ChartQA* _{放宽版}	88.1	90.8	88.7	88.3	91.2	91.5	85.5	91.7
DocVQA*	91.1	94.2	91.5	92.9	97.1	96.1	90.1	96.4
OCRBench	806	790	800	846	856	847	805	865
数学与科学								
AI2D*	83.1	82.0	80.9	85.1	84.4	86.8	78.9	83.3
MathVista* _{测试迷你版}	62.1	65.4	70.6	73.1	69.6	68.4	57.3	68.6
OlympiadBench _{full}	25.2	28.4	32.1	46.1	21.9	25.1	19.3	24.2
长期背景								
M-LongDoc _{acc}	41.4	31.4	26.2	31.4	11.6	19.7	13.9	32.5
全面								
MEGA-Bench _{macro}	49.4	51.4	45.9	53.9	46.8	45.3	19.9	47.4
用户体验								
内部基准	62.3	47.0	49.2	72.1	40.6	34.8	13.6	56.6

* 在零样本的 CoT 设置下进行评估。

综合基准测试。在最近推出的 MEGA-Bench (Chen 等人, 2024a) 这一现实且全面的评估套件中, MiniMax-VL-01 显示出具有竞争力的整体能力, 超过了现有的开源视觉大型语言模型。虽然它在诸如知识和编码等多样化的子任务中表现出色, 但该模型在包括规划和指标评估等更复杂的任务中面临挑战。

内部用户体验基准。虽然学术基准通常关注问题解决, 但它们往往无法捕捉到现实世界中用户与模型交互的细微差别。为了弥补这一差距, 我们开发了一个内部基准, 其中包括90个不同的图像相关任务, 每个任务都设计了定制且具有挑战性的指令。基准中的图像和指令经过严格去重, 确保在任何阶段都不与训练集重叠。任务相关性通过人工验证, 并为每个样本注释了详细的清单, 以确保精确评估。最终的测试集包括524个精心标注的样本, 既有中文也有英文, 但主要使用中文。我们在附录C中展示了部分样本。在与一个顶尖的视觉语言模型的胜率比较中, 我们的模型优于所有开源模型, 并接近GPT-4的性能, 但差距很小。

7. 结论与未来工作

在这份报告中, 我们介绍了两个全新的模型——MiniMax-Text-01 和 MiniMax-VL-01, 这两个模型完全是从头开始开发的。这些模型在标准基准测试中表现出色, 尤其是在长上下文处理方面表现出色, 能够处理多达 400 万个标记的上下文窗口。我们的研究结果对普遍存在的假设提出了挑战, 即最先进的

语言模型必须建立在传统的注意力机制之上。通过战略性地将线性注意力与优化的硬件利用率相结合，并精心设计训练方案，我们成功地将上下文窗口扩展了一个数量级。这一突破不仅提高了大型语言模型的效率和可扩展性，还为未来的模型支持更长的上下文窗口和促进更复杂的人工智能代理的发展铺平了道路。为了促进该领域的合作和进步，我们将我们的模型公开在<https://github.com/MiniMax-AI>上。对于一般用途和评估，我们提供了一个具有在线搜索功能的聊天机器人 (<https://www.hailuo.ai/>) 和在线API (<https://intl.minimaxi.com>)。我们致力于保持这一系列的开源，并将在开发出更好的模型时发布更新。

虽然 MiniMax-Text-01 和 MiniMax-VL-01 在一般语言和视觉语言任务中表现出色，但我们承认存在一些需要进一步探索的局限性：

- 长上下文评估：**当前的长上下文检索任务的评估数据集主要是为人工或简化场景设计的，在实际应用中，如文档分析中，对长文本推理能力的评估仍然有限。我们计划在更现实的环境中增强长上下文检索，并在更广泛的任务中扩展对长上下文推理的评估。
- 模型架构：**目前该模型保留了八分之一的组件，采用普通的 softmax 注意力机制。我们正在研究更高效的架构，这种架构能够完全消除 softmax 注意力机制，有可能实现无限大的上下文窗口，且不会带来计算开销。
- 复杂的编程任务：**该模型在高级编程任务上的表现有待提高，因为目前我们预训练阶段的编码数据集仍然有限。我们正在不断改进训练数据的选择，并优化持续训练程序，以解决这些限制，并在下一个模型版本中解决这些问题。

参考文献

- Marah Abdin, Jyoti Aneja, Harkirat Behl, Sébastien Bubeck, Ronen Eldan, Suriya Gunasekar, Michael Harrison, Russell J Hewett, Mojan Javaheripi, Piero Kauffmann, et al. Phi-4 technical report. *arXiv preprint arXiv:2412.08905*, 2024.
- Rishabh Agarwal, Avi Singh, Lei M Zhang, Bernd Bohnet, Luis Rosias, Stephanie Chan, Biao Zhang, Ankesh Anand, Zaheer Abbas, Azade Nova, et al. Many-shot in-context learning. *arXiv preprint arXiv:2404.11018*, 2024.
- Joshua Ainslie, James Lee-Thorp, Michiel de Jong, Yury Zemlyanskiy, Federico Lebron, and Sumit Sanghai. GQA: Training generalized multi-query transformer models from multi-head checkpoints. In *Proceedings of the 2023 Conference on Empirical Methods in Natural Language Processing*, pages 4895–4901, 2023.
- Anthropic. Introducing claude 3.5 sonnet, 2024. URL <https://www.anthropic.com/news/claude-3-5-sonnet>.
- Jacob Austin, Augustus Odena, Maxwell Nye, Maarten Bosma, Henryk Michalewski, David Dohan, Ellen Jiang, Carrie Cai, Michael Terry, Quoc Le, et al. Program synthesis with large language models. *arXiv preprint arXiv:2108.07732*, 2021.
- Alexei Baevski and Michael Auli. Adaptive input representations for neural language modeling. *arXiv preprint arXiv:1809.10853*, 2018.

- Yuntao Bai, Andy Jones, Kamal Ndousse, Amanda Askell, Anna Chen, Nova DasSarma, Dawn Drain, Stanislav Fort, Deep Ganguli, Tom Henighan, et al. Training a helpful and harmless assistant with reinforcement learning from human feedback. *arXiv preprint arXiv:2204.05862*, 2022a.
- Yuntao Bai, Saurav Kadavath, Sandipan Kundu, Amanda Askell, Jackson Kernion, Andy Jones, Anna Chen, Anna Goldie, Azalia Mirhoseini, Cameron McKinnon, et al. Constitutional AI: Harmlessness from AI feedback. *arXiv preprint arXiv:2212.08073*, 2022b.
- Yushi Bai, Shangqing Tu, Jiajie Zhang, Hao Peng, Xiaozhi Wang, Xin Lv, Shulin Cao, Jiazheng Xu, Lei Hou, Yuxiao Dong, Jie Tang, and Juanzi Li. LongBench v2: Towards deeper understanding and reasoning on realistic long-context multitasks. *arXiv preprint arXiv:2412.15204*, 2024.
- Iz Beltagy, Matthew E Peters, and Arman Cohan. Longformer: The long-document transformer. *arXiv preprint arXiv:2004.05150*, 2020.
- Yonatan Bisk, Rowan Zellers, Jianfeng Gao, Yejin Choi, et al. PIQA: Reasoning about physical commonsense in natural language. In *Proceedings of the AAAI conference on artificial intelligence*, volume 34, pages 7432–7439, 2020.
- Andrei Z Broder. On the resemblance and containment of documents. In *Proceedings. Compression and Complexity of SEQUENCES 1997 (Cat. No. 97TB100171)*, pages 21–29. IEEE, 1997.
- Tom Brown, Benjamin Mann, Nick Ryder, Melanie Subbiah, Jared D Kaplan, Prafulla Dhariwal, Arvind Neelakantan, Pranav Shyam, Girish Sastry, Amanda Askell, et al. Language models are few-shot learners. *Advances in neural information processing systems*, 33:1877–1901, 2020.
- Jiacheng Chen, Tianhao Liang, Sherman Siu, Zhengqing Wang, Kai Wang, Yubo Wang, Yuansheng Ni, Wang Zhu, Ziyang Jiang, Bohan Lyu, et al. MEGA-Bench: Scaling multimodal evaluation to over 500 real-world tasks. *arXiv preprint arXiv:2410.10563*, 2024a.
- Mark Chen, Jerry Tworek, Heewoo Jun, Qiming Yuan, Henrique Ponde De Oliveira Pinto, Jared Kaplan, Harri Edwards, Yuri Burda, Nicholas Joseph, Greg Brockman, et al. Evaluating large language models trained on code. *arXiv preprint arXiv:2107.03374*, 2021.
- Zehui Chen, Kuikun Liu, Qiuchen Wang, Jiangning Liu, Wenwei Zhang, Kai Chen, and Feng Zhao. MindSearch: Mimicking human minds elicits deep ai searcher. *arXiv preprint arXiv:2407.20183*, 2024b.
- Rewon Child, Scott Gray, Alec Radford, and Ilya Sutskever. Generating long sequences with sparse transformers. *arXiv preprint arXiv:1904.10509*, 2019.
- Aakanksha Chowdhery, Sharan Narang, Jacob Devlin, Maarten Bosma, Gaurav Mishra, Adam Roberts, Paul Barham, Hyung Won Chung, Charles Sutton, Sebastian Gehrmann, et al. PaLM: Scaling language modeling with pathways. *Journal of Machine Learning Research*, 24(240):1–113, 2023.
- Aidan Clark, Diego de Las Casas, Aurelia Guy, Arthur Mensch, Michela Paganini, Jordan Hoffmann, Bogdan Damoc, Blake Hechtman, Trevor Cai, Sebastian Borgeaud, et al. Unified scaling laws for routed language models. In *International Conference on Machine Learning (ICML)*, pages 4057–4086. PMLR, 2022.
- Christopher Clark, Kenton Lee, Ming-Wei Chang, Tom Kwiatkowski, Michael Collins, and Kristina Toutanova. BoolQ: Exploring the surprising difficulty of natural yes/no questions. In *Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, Volume 1 (Long and Short Papers)*, pages 2924–2936, 2019.

- Peter Clark, Isaac Cowhey, Oren Etzioni, Tushar Khot, Ashish Sabharwal, Carissa Schoenick, and Oyvind Tafjord. Think you have solved question answering? try ARC, the AI2 reasoning challenge. *arXiv preprint arXiv:1803.05457*, 2018.
- Karl Cobbe, Vineet Kosaraju, Mohammad Bavarian, Mark Chen, Heewoo Jun, Lukasz Kaiser, Matthias Plappert, Jerry Tworek, Jacob Hilton, Reiichiro Nakano, et al. Training verifiers to solve math word problems. *arXiv preprint arXiv:2110.14168*, 2021.
- Tri Dao. FlashAttention-2: Faster attention with better parallelism and work partitioning. In *The Twelfth International Conference on Learning Representations*, 2024. URL <https://openreview.net/forum?id=mZn2Xyh9Ec>.
- Tri Dao and Albert Gu. Transformers are ssms: Generalized models and efficient algorithms through structured state space duality. *arXiv preprint arXiv:2405.21060*, 2024.
- Tri Dao, Dan Fu, Stefano Ermon, Atri Rudra, and Christopher Ré. FlashAttention: Fast and memory-efficient exact attention with io-awareness. *Advances in Neural Information Processing Systems*, 35: 16344–16359, 2022.
- Alexandre de Brébisson and Pascal Vincent. A cheap linear attention mechanism with fast lookups and fixed-size representations. *arXiv preprint arXiv:1609.05866*, 2016.
- DeepSeek-AI. DeepSeek-V3 technical report, 2024. URL <https://arxiv.org/abs/2412.19437>.
- Qingxiu Dong, Lei Li, Damai Dai, Ce Zheng, Jingyuan Ma, Rui Li, Heming Xia, Jingjing Xu, Zhiyong Wu, Baobao Chang, et al. A survey on in-context learning. In *Proceedings of the 2024 Conference on Empirical Methods in Natural Language Processing*, pages 1107–1128, 2024.
- Alexey Dosovitskiy, Lucas Beyer, Alexander Kolesnikov, Dirk Weissenborn, Xiaohua Zhai, Thomas Unterthiner, Mostafa Dehghani, Matthias Minderer, Georg Heigold, Sylvain Gelly, Jakob Uszkoreit, and Neil Houlsby. An image is worth 16x16 words: Transformers for image recognition at scale. In *International Conference on Learning Representations*, 2021. URL <https://openreview.net/forum?id=YicbFdNTTy>.
- Dheeru Dua, Yizhong Wang, Pradeep Dasigi, Gabriel Stanovsky, Sameer Singh, and Matt Gardner. DROP: A reading comprehension benchmark requiring discrete reasoning over paragraphs. In *Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, Volume 1 (Long and Short Papers)*, pages 2368–2378, 2019.
- Abhimanyu Dubey, Abhinav Jauhri, Abhinav Pandey, Abhishek Kadian, Ahmad Al-Dahle, Aiesha Letman, Akhil Mathur, Alan Schelten, Amy Yang, Angela Fan, et al. The Llama 3 herd of models. *arXiv preprint arXiv:2407.21783*, 2024.
- William Fedus, Barret Zoph, and Noam Shazeer. Switch transformers: Scaling to trillion parameter models with simple and efficient sparsity. *Journal of Machine Learning Research*, 23(120):1–39, 2022.
- Leo Gao, Tom Dupré la Tour, Henk Tillman, Gabriel Goh, Rajan Troll, Alec Radford, Ilya Sutskever, Jan Leike, and Jeffrey Wu. Scaling and evaluating sparse autoencoders. *arXiv preprint arXiv:2406.04093*, 2024.
- Paolo Glorioso, Quentin Anthony, Yury Tokpanov, James Whittington, Jonathan Pilault, Adam Ibrahim, and Beren Millidge. Zamba: A compact 7b SSM hybrid model. *arXiv preprint arXiv:2405.16712*, 2024.

- Xavier Glorot and Yoshua Bengio. Understanding the difficulty of training deep feedforward neural networks. In *Proceedings of the thirteenth international conference on artificial intelligence and statistics*, pages 249–256. JMLR Workshop and Conference Proceedings, 2010.
- Albert Gu and Tri Dao. Mamba: Linear-time sequence modeling with selective state spaces. In *First Conference on Language Modeling*, 2024. URL <https://openreview.net/forum?id=tEYskw1VY2>.
- Suriya Gunasekar, Yi Zhang, Jyoti Aneja, Caio César Teodoro Mendes, Allie Del Giorno, Sivakanth Gopi, Mojan Javaheripi, Piero Kauffmann, Gustavo de Rosa, Olli Saarikivi, et al. Textbooks are all you need. *arXiv preprint arXiv:2306.11644*, 2023.
- Chaoqun He, Renjie Luo, Yuzhuo Bai, Shengding Hu, Zhen Leng Thai, Junhao Shen, Jinyi Hu, Xu Han, Yujie Huang, Yuxiang Zhang, et al. OlympiadBench: A challenging benchmark for promoting agi with olympiad-level bilingual multimodal scientific problems. *arXiv preprint arXiv:2402.14008*, 2024a.
- Yancheng He, Shilong Li, Jiaheng Liu, Yingshui Tan, Weixun Wang, Hui Huang, Xingyuan Bu, Hangyu Guo, Chengwei Hu, Boren Zheng, et al. Chinese simpleQA: A chinese factuality evaluation for large language models. *arXiv preprint arXiv:2411.07140*, 2024b.
- Dan Hendrycks, Collin Burns, Steven Basart, Andy Zou, Mantas Mazeika, Dawn Song, and Jacob Steinhardt. Measuring massive multitask language understanding. In *International Conference on Learning Representations*, 2021a. URL <https://openreview.net/forum?id=d7KBjmI3GmQ>.
- Dan Hendrycks, Collin Burns, Saurav Kadavath, Akul Arora, Steven Basart, Eric Tang, Dawn Song, and Jacob Steinhardt. Measuring mathematical problem solving with the MATH dataset. In *Thirty-fifth Conference on Neural Information Processing Systems Datasets and Benchmarks Track (Round 2)*, 2021b. URL <https://openreview.net/forum?id=7Bywt2mQsCe>.
- Tom Henighan, Jared Kaplan, Mor Katz, Mark Chen, Christopher Hesse, Jacob Jackson, Heewoo Jun, Tom B. Brown, Prafulla Dhariwal, Scott Gray, et al. Scaling laws for autoregressive generative modeling. *arXiv preprint arXiv:2010.14701*, 2020.
- Danny Hernandez, Tom Brown, Tom Conerly, Nova DasSarma, Dawn Drain, Sheer El-Showk, Nelson Elhage, Zac Hatfield-Dodds, Tom Henighan, Tristan Hume, et al. Scaling laws and interpretability of learning from repeated data. *arXiv preprint arXiv:2205.10487*, 2022.
- Jordan Hoffmann, Sebastian Borgeaud, Arthur Mensch, Elena Buchatskaya, Trevor Cai, Eliza Rutherford, Diego de Las Casas, Lisa Anne Hendricks, Johannes Welbl, Aidan Clark, et al. Training compute-optimal large language models. In *Proceedings of the 36th International Conference on Neural Information Processing Systems*, pages 30016–30030, 2022.
- Cheng-Ping Hsieh, Simeng Sun, Samuel Krizan, Shantanu Acharya, Dima Rekish, Fei Jia, Yang Zhang, and Boris Ginsburg. RULER: What’s the real context size of your long-context language models? *arXiv preprint arXiv:2404.06654*, 2024.
- Weizhe Hua, Zihang Dai, Hanxiao Liu, and Quoc Le. Transformer quality in linear time. In *International conference on machine learning*, pages 9099–9117. PMLR, 2022.
- Aaron Hurst, Adam Lerer, Adam P Goucher, Adam Perelman, Aditya Ramesh, Aidan Clark, AJ Os-trow, Akila Welihinda, Alan Hayes, Alec Radford, et al. GPT-4o system card. *arXiv preprint arXiv:2410.21276*, 2024.

- Albert Q Jiang, Alexandre Sablayrolles, Arthur Mensch, Chris Bamford, Devendra Singh Chaplot, Diego de las Casas, Florian Bressand, Gianna Lengyel, Guillaume Lample, Lucile Saulnier, et al. Mistral 7B. *arXiv preprint arXiv:2310.06825*, 2023.
- Mandar Joshi, Eunsol Choi, Daniel S Weld, and Luke Zettlemoyer. Triviaqa: A large scale distantly supervised challenge dataset for reading comprehension. In *Proceedings of the 55th Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers)*, pages 1601–1611, 2017.
- G. Kamradt. Llmtest_needleinahaystack, 2023. URL https://github.com/gkamradt/LLMTest_NeedleInAHaystack.
- Jared Kaplan, Sam McCandlish, Tom Henighan, Tom B Brown, Benjamin Chess, Rewon Child, Scott Gray, Alec Radford, Jeffrey Wu, and Dario Amodei. Scaling laws for neural language models. *arXiv preprint arXiv:2001.08361*, 2020.
- Aniruddha Kembhavi, Mike Salvato, Eric Kolve, Minjoon Seo, Hannaneh Hajishirzi, and Ali Farhadi. A diagram is worth a dozen images. In *Computer Vision—ECCV 2016: 14th European Conference, Amsterdam, The Netherlands, October 11–14, 2016, Proceedings, Part IV 14*, pages 235–251. Springer, 2016.
- Tom Kwiatkowski, Jennimaria Palomaki, Olivia Redfield, Michael Collins, Ankur Parikh, Chris Alberti, Danielle Epstein, Illia Polosukhin, Jacob Devlin, Kenton Lee, et al. Natural questions: a benchmark for question answering research. *Transactions of the Association for Computational Linguistics*, 7: 453–466, 2019.
- Katherine Lee, Daphne Ippolito, Andrew Nystrom, Chiyuan Zhang, Douglas Eck, Chris Callison-Burch, and Nicholas Carlini. Deducating training data makes language models better. In *Proceedings of the 60th Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers)*, pages 8424–8445, 2022.
- Dmitry Lepikhin, HyoukJoong Lee, Yuanzhong Xu, Dehao Chen, Orhan Firat, Yanping Huang, Maxim Krikun, Noam Shazeer, and Zhifeng Chen. GShard: Scaling giant models with conditional computation and automatic sharding. In *International Conference on Learning Representations*, 2021. URL <https://openreview.net/forum?id=qrwe7XHTmYb>.
- Dongxu Li, Yudong Liu, Haoning Wu, Yue Wang, Zhiqi Shen, Bowen Qu, Xinyao Niu, Guoyin Wang, Bei Chen, and Junnan Li. Aria: An open multimodal native mixture-of-experts model. *arXiv preprint arXiv:2410.05993*, 2024a.
- Junnan Li, Dongxu Li, Caiming Xiong, and Steven Hoi. BLIP: Bootstrapping language-image pre-training for unified vision-language understanding and generation. In *International conference on machine learning*, pages 12888–12900. PMLR, 2022.
- Junnan Li, Dongxu Li, Silvio Savarese, and Steven Hoi. BLIP-2: Bootstrapping language-image pre-training with frozen image encoders and large language models. In *International conference on machine learning*, pages 19730–19742. PMLR, 2023.
- Tianle Li, Wei-Lin Chiang, Evan Frick, Lisa Dunlap, Tianhao Wu, Banghua Zhu, Joseph E Gonzalez, and Ion Stoica. From crowdsourced data to high-quality benchmarks: Arena-Hard and BenchBuilder pipeline. *arXiv preprint arXiv:2406.11939*, 2024b.
- Hao Liu, Matei Zaharia, and Pieter Abbeel. Ring attention with blockwise transformers for near-infinite context. In *The Twelfth International Conference on Learning Representations*, 2024a. URL <https://openreview.net/forum?id=WsRHpHH4s0>.

- Jiawei Liu, Chunqiu Steven Xia, Yuyao Wang, and Lingming Zhang. Is your code generated by ChatGPT really correct? rigorous evaluation of large language models for code generation. In *Proceedings of the 37th International Conference on Neural Information Processing Systems*, pages 21558–21572, 2023.
- Yuliang Liu, Zhang Li, Mingxin Huang, Biao Yang, Wenwen Yu, Chunyuan Li, Xu-Cheng Yin, Cheng-Lin Liu, Lianwen Jin, and Xiang Bai. OCRBench: On the hidden mystery of OCR in large multimodal models. *Science China Information Sciences*, 67(12):220102, 2024b.
- Ilya Loshchilov and Frank Hutter. Decoupled weight decay regularization. In *International Conference on Learning Representations*, 2019. URL <https://openreview.net/forum?id=Bkg6RiCqY7>.
- Pan Lu, Hritik Bansal, Tony Xia, Jiacheng Liu, Chunyuan Li, Hannaneh Hajishirzi, Hao Cheng, Kai-Wei Chang, Michel Galley, and Jianfeng Gao. MathVista: Evaluating mathematical reasoning of foundation models in visual contexts. *arXiv preprint arXiv:2310.02255*, 2023.
- Yubo Ma, Yuhang Zang, Liangyu Chen, Meiqi Chen, Yizhu Jiao, Xinze Li, Xinyuan Lu, Ziyu Liu, Yan Ma, Xiaoyi Dong, et al. MMLongBench-Doc: Benchmarking long-context document understanding with visualizations. *arXiv preprint arXiv:2407.01523*, 2024.
- Ahmed Masry, Do Xuan Long, Jia Qing Tan, Shafiq Joty, and Enamul Hoque. ChartQA: A benchmark for question answering about charts with visual and logical reasoning. *arXiv preprint arXiv:2203.10244*, 2022.
- Minesh Mathew, Dimosthenis Karatzas, and CV Jawahar. DocVQA: A dataset for VQA on document images. In *Proceedings of the IEEE/CVF winter conference on applications of computer vision*, pages 2200–2209, 2021.
- Sam McCandlish, Jared Kaplan, Dario Amodei, and OpenAI Dota Team. An empirical model of large-batch training. *arXiv preprint arXiv:1812.06162*, 2018.
- Todor Mihaylov, Peter Clark, Tushar Khot, and Ashish Sabharwal. Can a suit of armor conduct electricity? a new dataset for open book question answering. In *Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing*, pages 2381–2391, 2018.
- Niklas Muennighoff, Alexander Rush, Boaz Barak, Teven Le Scao, Nouamane Tazi, Aleksandra Piktus, Sampo Pyysalo, Thomas Wolf, and Colin A Raffel. Scaling data-constrained language models. *Advances in Neural Information Processing Systems*, 36:50358–50376, 2023.
- NVIDIA. Transformer engine, 2023. URL <https://github.com/NVIDIA/TransformerEngine>.
- Jupinder Parmar, Sanjev Satheesh, Mostofa Patwary, Mohammad Shoeybi, and Bryan Catanzaro. Reuse, don't retrain: A recipe for continued pretraining of language models. *arXiv preprint arXiv:2407.07263*, 2024.
- Guilherme Penedo, Quentin Malartic, Daniel Hesslow, Ruxandra Cojocaru, Hamza Alobeidli, Alessandro Cappelli, Baptiste Pannier, Ebtesam Almazrouei, and Julien Launay. The RefinedWeb dataset for Falcon LLM: Outperforming curated corpora with web data only. In *Thirty-seventh Conference on Neural Information Processing Systems Datasets and Benchmarks Track*, 2023. URL <https://openreview.net/forum?id=kM5eGcdCzq>.
- Guilherme Penedo, Hynek Kydliček, Loubna Ben allal, Anton Lozhkov, Margaret Mitchell, Colin Raffel, Leandro Von Werra, and Thomas Wolf. The FineWeb datasets: Decanting the web for the finest text data at scale. In *The Thirty-eight Conference on Neural Information Processing Systems Datasets and Benchmarks Track*, 2024. URL <https://openreview.net/forum?id=n6SCKn2QaG>.

- Zhen Qin, Xiaodong Han, Weixuan Sun, Dongxu Li, Lingpeng Kong, Nick Barnes, and Yiran Zhong. The devil in linear transformer. In *Proceedings of the 2022 Conference on Empirical Methods in Natural Language Processing*, pages 7025–7041, 2022a.
- Zhen Qin, Weixuan Sun, Hui Deng, Dongxu Li, Yunshen Wei, Baohong Lv, Junjie Yan, Lingpeng Kong, and Yiran Zhong. cosFormer: Rethinking softmax in attention. In *International Conference on Learning Representations*, 2022b. URL <https://openreview.net/forum?id=B18CQrx2Up4>.
- Zhen Qin, Xiaodong Han, Weixuan Sun, Bowen He, Dong Li, Dongxu Li, Yuchao Dai, Lingpeng Kong, and Yiran Zhong. Toeplitz neural network for sequence modeling. In *The Eleventh International Conference on Learning Representations*, 2023a. URL <https://openreview.net/forum?id=IxmWsm4xrua>.
- Zhen Qin, Songlin Yang, and Yiran Zhong. Hierarchically gated recurrent neural network for sequence modeling. In *Proceedings of the 37th International Conference on Neural Information Processing Systems*, pages 33202–33221, 2023b.
- Zhen Qin, Yuxin Mao, Xuyang Shen, Dong Li, Jing Zhang, Yuchao Dai, and Yiran Zhong. You only scan once: Efficient multi-dimension sequential modeling with lightnet. *arXiv preprint arXiv:2405.21022*, 2024a.
- Zhen Qin, Weigao Sun, Dong Li, Xuyang Shen, Weixuan Sun, and Yiran Zhong. Lightning attention-2: A free lunch for handling unlimited sequence lengths in large language models. *arXiv preprint arXiv:2401.04658*, 2024b.
- Zhen Qin, Weigao Sun, Dong Li, Xuyang Shen, Weixuan Sun, and Yiran Zhong. Various lengths, constant speed: Efficient language modeling with lightning attention. In *International conference on machine learning*, pages 41517–41535. PMLR, 2024c.
- Zhen Qin, Songlin Yang, Weixuan Sun, Xuyang Shen, Dong Li, Weigao Sun, and Yiran Zhong. HGRN2: Gated linear rnns with state expansion. *arXiv preprint arXiv:2404.07904*, 2024d.
- Jack W Rae, Sebastian Borgeaud, Trevor Cai, Katie Millican, Jordan Hoffmann, Francis Song, John Aslanides, Sarah Henderson, Roman Ring, Susannah Young, et al. Scaling language models: Methods, analysis & insights from training Gopher. *arXiv preprint arXiv:2112.11446*, 2021.
- Rafael Rafailov, Archit Sharma, Eric Mitchell, Stefano Ermon, Christopher D Manning, and Chelsea Finn. Direct preference optimization: your language model is secretly a reward model. In *Proceedings of the 37th International Conference on Neural Information Processing Systems*, pages 53728–53741, 2023.
- Samyam Rajbhandari, Jeff Rasley, Olatunji Ruwase, and Yuxiong He. Zero: Memory optimizations toward training trillion parameter models. In *SC20: International Conference for High Performance Computing, Networking, Storage and Analysis*, pages 1–16. IEEE, 2020.
- David Rein, Betty Li Hou, Asa Cooper Stickland, Jackson Petty, Richard Yuanzhe Pang, Julien Dirani, Julian Michael, and Samuel R. Bowman. GPQA: A graduate-level google-proof q&a benchmark. In *First Conference on Language Modeling*, 2024. URL <https://openreview.net/forum?id=Ti67584b98>.
- Liliang Ren, Yang Liu, Yadong Lu, Yelong Shen, Chen Liang, and Weizhu Chen. Samba: Simple hybrid state space models for efficient unlimited context language modeling. *arXiv preprint arXiv:2406.07522*, 2024.

- Keisuke Sakaguchi, Ronan Le Bras, Chandra Bhagavatula, and Yejin Choi. WinoGrande: An adversarial Winograd schema challenge at scale. *Communications of the ACM*, 64(9):99–106, 2021.
- Maarten Sap, Hannah Rashkin, Derek Chen, Ronan Le Bras, and Yejin Choi. Social IQa: Commonsense reasoning about social interactions. In *Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing (EMNLP-IJCNLP)*, pages 4463–4473, 2019.
- Christoph Schuhmann, Richard Vencu, Romain Beaumont, Robert Kaczmarczyk, Clayton Mullis, Aarush Katta, Theo Coombes, Jenia Jitsev, and Aran Komatsuzaki. LAION-400M: Open dataset of CLIP-filtered 400 million image-text pairs. *arXiv preprint arXiv:2111.02114*, 2021.
- John Schulman, Filip Wolski, Prafulla Dhariwal, Alec Radford, and Oleg Klimov. Proximal policy optimization algorithms. *arXiv preprint arXiv:1707.06347*, 2017.
- Uri Shaham, Elad Segal, Maor Ivgi, Avia Efrat, Ori Yoran, Adi Haviv, Ankit Gupta, Wenhan Xiong, Mor Geva, Jonathan Berant, et al. SCROLLS: Standardized comparison over long language sequences. In *Proceedings of the 2022 Conference on Empirical Methods in Natural Language Processing*, pages 12007–12021, 2022.
- Zhihong Shao, Peiyi Wang, Qihao Zhu, Runxin Xu, Junxiao Song, Xiao Bi, Haowei Zhang, Mingchuan Zhang, YK Li, Y Wu, et al. DeepSeekMath: Pushing the limits of mathematical reasoning in open language models. *arXiv preprint arXiv:2402.03300*, 2024.
- Xuyang Shen, Dong Li, Ruitao Leng, Zhen Qin, Weigao Sun, and Yiran Zhong. Scaling laws for linear complexity language models. In *Proceedings of the 2024 Conference on Empirical Methods in Natural Language Processing*, pages 16377–16426, 2024.
- Yusuxke Shibata, Takuya Kida, Shuichi Fukamachi, Masayuki Takeda, Ayumi Shinohara, Takeshi Shinohara, and Setsuo Arikawa. Byte pair encoding: A text compression scheme that accelerates pattern matching. *Technical Report DOI-TR-161, Department of Informatics, Kyushu University*, 1999.
- Jianlin Su, Murtadha Ahmed, Yu Lu, Shengfeng Pan, Wen Bo, and Yunfeng Liu. Roformer: Enhanced transformer with rotary position embedding. *Neurocomputing*, 568:127063, 2024.
- Weigao Sun, Zhen Qin, Dong Li, Xuyang Shen, Yu Qiao, and Yiran Zhong. Linear attention sequence parallelism. *arXiv preprint arXiv:2404.02882*, 2024.
- Garrett Tanzer, Mirac Suzgun, Eline Visser, Dan Jurafsky, and Luke Melas-Kyriazi. A benchmark for learning to translate a new language from one grammar book. In *The Twelfth International Conference on Learning Representations*, 2024. URL <https://openreview.net/forum?id=tbVWug9f2h>.
- Gemini Team, Petko Georgiev, Ving Ian Lei, Ryan Burnell, Libin Bai, Anmol Gulati, Garrett Tanzer, Damien Vincent, Zhufeng Pan, Shibo Wang, et al. Gemini 1.5: Unlocking multimodal understanding across millions of tokens of context. *arXiv preprint arXiv:2403.05530*, 2024a.
- Jamba Team, Barak Lenz, Alan Arazi, Amir Bergman, Avshalom Manevich, Barak Peleg, Ben Aviram, Chen Almagor, Clara Fridman, Dan Padnos, et al. Jamba-1.5: Hybrid Transformer-Mamba models at scale. *arXiv preprint arXiv:2408.12570*, 2024b.
- Ashish Vaswani, Noam Shazeer, Niki Parmar, Jakob Uszkoreit, Llion Jones, Aidan N Gomez,  ukasz Kaiser, and Illia Polosukhin. Attention is all you need. *Advances in neural information processing systems*, 30, 2017.

- Kiran Vodrahalli, Santiago Ontanon, Nilesh Tripuraneni, Kelvin Xu, Sanil Jain, Rakesh Shivanna, Jeffrey Hui, Nishanth Dikkala, Mehran Kazemi, Bahare Fatemi, et al. Michelangelo: Long context evaluations beyond haystacks via latent structure queries. *arXiv preprint arXiv:2409.12640*, 2024.
- Hongyu Wang, Shuming Ma, Li Dong, Shaohan Huang, Dongdong Zhang, and Furu Wei. DeepNet: Scaling transformers to 1,000 layers. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2024a.
- Qiang Wang, Bei Li, Tong Xiao, Jingbo Zhu, Changliang Li, Derek F Wong, and Lidia S Chao. Learning deep transformer models for machine translation. In *Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics*, pages 1810–1822, 2019.
- Yubo Wang, Xueguang Ma, Ge Zhang, Yuansheng Ni, Abhranil Chandra, Shiguang Guo, Weiming Ren, Aaran Arulraj, Xuan He, Ziyang Jiang, Tianle Li, Max Ku, Kai Wang, Alex Zhuang, Rongqi Fan, Xiang Yue, and Wenhui Chen. MMLU-pro: A more robust and challenging multi-task language understanding benchmark. In *The Thirty-eight Conference on Neural Information Processing Systems Datasets and Benchmarks Track*, 2024b. URL <https://openreview.net/forum?id=y10DM6R2r3>.
- Jason Wei, Xuezhi Wang, Dale Schuurmans, Maarten Bosma, Fei Xia, Ed Chi, Quoc V Le, Denny Zhou, et al. Chain-of-thought prompting elicits reasoning in large language models. *Advances in neural information processing systems*, 35:24824–24837, 2022.
- Jason Wei, Nguyen Karina, Hyung Won Chung, Yunxin Joy Jiao, Spencer Papay, Amelia Glaese, John Schulman, and William Fedus. Measuring short-form factuality in large language models. *arXiv preprint arXiv:2411.04368*, 2024.
- An Yang, Baosong Yang, Beichen Zhang, Binyuan Hui, Bo Zheng, Bowen Yu, Chengyuan Li, Dayiheng Liu, Fei Huang, Haoran Wei, et al. Qwen2.5 technical report. *arXiv preprint arXiv:2412.15115*, 2024.
- Jiahui Yu, Zirui Wang, Vijay Vasudevan, Legg Yeung, Mojtaba Seyedhosseini, and Yonghui Wu. CoCa: Contrastive captioners are image-text foundation models. *Transactions on Machine Learning Research*, 2022. ISSN 2835-8856. URL <https://openreview.net/forum?id=Ee277P3AYC>.
- Xiang Yue, Yuansheng Ni, Kai Zhang, Tianyu Zheng, Ruoqi Liu, Ge Zhang, Samuel Stevens, Dongfu Jiang, Weiming Ren, Yuxuan Sun, et al. MMMU: A massive multi-discipline multimodal understanding and reasoning benchmark for expert agi. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pages 9556–9567, 2024a.
- Xiang Yue, Tianyu Zheng, Yuansheng Ni, Yubo Wang, Kai Zhang, Shengbang Tong, Yuxuan Sun, Botao Yu, Ge Zhang, Huan Sun, et al. MMMU-Pro: A more robust multi-discipline multimodal understanding benchmark. *arXiv preprint arXiv:2409.02813*, 2024b.
- Manzil Zaheer, Guru Guruganesh, Kumar Avinava Dubey, Joshua Ainslie, Chris Alberti, Santiago Ontanon, Philip Pham, Anirudh Ravula, Qifan Wang, Li Yang, et al. Big Bird: Transformers for longer sequences. *Advances in neural information processing systems*, 33:17283–17297, 2020.
- Rowan Zellers, Ari Holtzman, Yonatan Bisk, Ali Farhadi, and Yejin Choi. HellaSwag: Can a machine really finish your sentence? In *Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics*, pages 4791–4800, 2019.
- Jeffrey Zhou, Tianjian Lu, Swaroop Mishra, Siddhartha Brahma, Sujoy Basu, Yi Luan, Denny Zhou, and Le Hou. Instruction-following evaluation for large language models. *arXiv preprint arXiv:2311.07911*, 2023.

A. 贡献者

该报告的撰稿人按字母顺序排列如下：

它Li Bangwei 镗, 博杨, Boji 山、程朱、张Liu Chunhao 张Congchao 郭, Da 陈, 李董, 成都恩威娇, 李Gengxin Guojun 张浩海牌太阳, Houze 咚, Jiadai 朱, 林嘉绮壮族, 世纪佳缘的歌, 金竺Jingtao 汉、泾阳Li Junbin 谢, Junhao 徐, 俊杰, Kaishun 张Kecheng 肖, 绍兴Kang Le 汉Leyang Wang Lianfei Yu Liheng 冯, 林郑, Linbo 柴, 长, 针对Ju, 茗源气, Mozhi 张黄Peikai Pengcheng 妞妞, 李Pengfei Pengyu 赵, 丛朝阳, 秦震, 范振华, 余志航, 蒋卓, 吴子佳

B. MiniMax-文本-01 案例演示

我们展示了我们的模型在真实世界的用户交互情况下的性能。为了保护用户的隐私，下面展示的所有用户请求均由我们的人工评估员编写，模仿用户与模型交互的方式，而非来自开源基准测试。

B.1. 从长语境中学习一门“新”语言

我们应用 MTOB 的提示遵循 Gemini-1.5 (Team 等人, 2024a) 的提示，具体如下。

MTOB Case

User Request (Instruction 🗨️ + Grammar book 📖 + Word List 📄 + Parallel sentences 🗨️)

🗨️ You are tasked with translating the following sentence from Kalamang to English: "Sontum kawirten hari minggu gerejao nasumbiyian."

You will be given a field linguistics grammar book, a bilingual word list to aid you.
Here is the book, "A grammar of Kalamang": START OF GRAMMAR BOOK

📖 { grammar book }

END OF GRAMMAR BOOK The grammar book is now over. Remember that you are tasked with translating the following sentence from Kalamang to English "Sontum kawirten hari minggu gerejao nasumbiyian". Now here is the bilingual word list: START OF WORD LIST

📄 { word list }

END OF WORD LIST The bilingual word list is now over. Remember that you are tasked with translating the following sentence from Kalamang to English "Sontum kawirten hari minggu gerejao nasumbiyian". You will use the same style as the parallel sentences immediately below.
Now here is the collection of parallel sentences: START OF PARALLEL SENTENCES

english: Sakina is pouching guavas.
kalamang: Sakina sarimara lawat.

english: There are many lusi muaun trees at Sar, but they are dry.
kalamang: Lusi muaun me Sarko reidak ma ma he sasa.

...

🗨️ { a total of 375 examples of parallel sentences }

...

END OF PARALLEL SENTENCES The collection of parallel sentences is now over. Now translate the following sentence from Kalamang to English, using the style from the parallel sentences immediately above. Translate: "Sontum kawirten hari minggu gerejao nasumbiyian".

🗨️ I understand that you may not be familiar enough with Kalamang to make a confident translation, but please give your best guess. Respond with only the translation and no other text.

Golden Answer	MiniMax-Text-01	Suboptimal
Christians worship at the church on Sunday.	The Christians pray at church on Sunday.	The person is a Christian on Sunday.

如图所示，MiniMax-Text-01 能够从给定的语法书、单词表和平行句中学习，其中表现不佳的模型响应存在语义错误。

B.2. 记忆冗长的历史对话

我们给出了一个关于我们的 MR-NIAH 样本如何设计的示例，在该示例中，模型被要求从多达 1889 次历史交互（对于英语基准）和 2053 次历史交互（对于中文基准）中精确地检索出与用户的一次历史交互。这些历史查询是由说普通话的人类评估员在我们模型之前版本的帮助下创建的，其中每个查询都被翻译成英语，我们从这个模型中获取助手的响应。我们将这些交互作为历史对话进行组合，并将每次针对话插入到第 5.7.2.1 节中详细说明了相应位置。

MR-NIAH Case

User Request (Haysack dialogues ✘ + Target ✔ + Haysack dialogues ✘ + Query ↗)

User: Please continue writing the follow-up content for this poem 'Drunkenly lying under the moon in the clouds, laughing at the flowers in the water.

Assistant: Certainly! The opening line you provided, 'Drunkenly lying under the moon in the clouds, laughing at the flowers in the water,' evokes a sense of whimsical detachment and a romantic embrace of nature's beauty. Here's a continuation of the poem that builds on this theme:

—

*Drunkenly lying under the moon in the clouds,
Laughing at the flowers in the water,
I find solace in the night's gentle shroud,
Where dreams and reality softly hover.**

The stars above, like scattered coins,
Glimmer with secrets of the ancient skies, . . .

✘ { many haysack dialogues }

✔ User: Write a poem about penguins.
Assistant: On the peak of the Antarctic iceberg,
Penguins dance with tiny wings.
Wearing black and white tuxedos, stumbling steps,
They smile at the severe frost in the cold wind.

✘ { many haysack dialogues }

✘ User: Write a poem about penguins.
Assistant: Under the sun, penguins line up,
Like guards, protecting their homeland.
In their eyes, warm light hides,
Exceptionally bright in the polar tranquility.

✘ { many haysack dialogues }

↗ User: Please repeat the first poem you wrote about penguins.

Golden Answer

On the peak of the Antarctic iceberg,
Penguins dance with tiny wings.
Wearing black and white tuxedos, stumbling steps,
They smile at the severe frost in the cold wind.

MiniMax-Text-01

On the peak of the Antarctic iceberg,
Penguins dance with tiny wings.
Wearing black and white tuxedos, stumbling steps,
They smile at the severe frost in the cold wind.

Suboptimal

Under the sun, penguins line up,
Like guards, protecting their homeland.
In their eyes, warm light hides,
Exceptionally bright in the polar tranquility.

我们将向业界公布这个基准测试的数据和代码。

B.3. 用图表总结长篇论文

当给海洛 AI 一份 PDF 格式的论文，并要求其添加论文中的图表时，海洛 AI 能够对给定的长篇文本进行总结或分析，并给出引用的关键图表作为回应。

用户请求 (查询 + PDF 文档)

请为我总结一下这篇论文，最好能将关键人物和数据在适当位置添加进来。

P 流对齐器：通过分布式归纳实现高效的句子级对齐

“迷你最大 - 文本 - 01”

论文摘要：“流对齐器：通过分布式归纳实现高效的句子级对齐”

1. 引言与动机

大型语言模型 (LLM) 的快速进步显著增强了它们的能力，但也引发了对它们与人类价值观和意图一致性的担忧。当前的对齐策略，如监督微调 (SFT) 和从人类反馈中强化学习 (RLHF)，已经显示出潜力，但在平衡各种任务的部署复杂性和性能方面面临挑战。推理时方法虽然轻量，但在将人类价值观精确地提炼到 LLM 输出中方面存在困难，特别是在长上下文生成中。

本文介绍了一种新颖的对齐范例，称为流分布诱导对齐器 (Stream Aligner)，它将推理时方法的效率与额外模型的增强性能相结合，以实现动态的句子级校正。

2. 流对齐范例

Stream Aligner 在生成流程中作为即插即用的模块运行，纠正上游模型生成的句子，并将校正后的后续反馈以进行进一步生成。这个过程会反复重复，直到响应完成，确保输出中的每个句子都符合人类偏好。

主要特点：

· 减少对额外模型的依赖：

通过专注于句子层面的校正，Stream Aligner 更多地利用了上游模型的性能，减少了对额外模型的规模和能力的依赖。

· 增强推理能力：迭代校正过程使流对齐器能够纠正推理错误，并为后续步骤添加归纳，从而提高模型的推理能力。

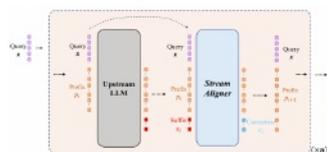
3. 技术细节

· 训练：流对齐器在一个句子级别的偏好数据集上进行微调，以学习偏好响应和非偏好响应之间的残差。训练目标是使模型的输出与正确答案之间的负对数似然损失最小化。



· 推理：在推理过程中，流对齐器

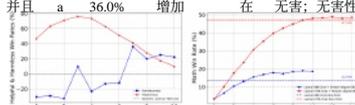
以用户的查询和前缀作为输入。上游模型生成原始答案，然后由流对齐器进行校正。每次校正都被纳入前缀中，该过程会不断重复，直至生成停止或前缀超过最大长度。



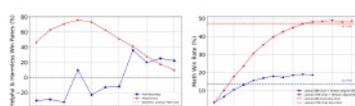
4. 实验结果

本文在三个任务上对 Stream Aligner 进行了评估：有用和无用的回答、数学问题以及摘要任务。结果表明有了显著的改进：

· 乐于助人且无害：流对齐器 - 2B 已申请到羊驼 2 - 70B 聊天，且 a 36.0% 增加在乐于助人且无害；无害性。



· 数学能力：应用于 Llama3-70B 的 Stream Aligner-8B 使数学能力提高了 3.5%。



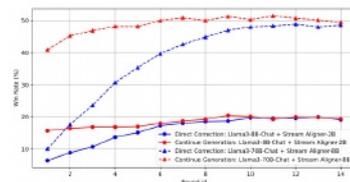
· 推理任务：实验表明，Stream Aligner 的平均干预时间越长，干预后的准确性就越高，这表明其在基于推理的任务中是有效的。

5. 烧融研究

本文进行了消融研究，以验证在不同监督数量和生成流模型的情况下，Stream Aligner 的校正能力：

· 生成校正频率：Stream Aligner 的性能会随着生成校正周期的数量增加而提高，这表明其在有限的监督下增强上游模型性能的能力。

· 生成方法：本研究将经典的逐句纠正生成流程与新的连续生成流程进行了比较。虽然连续生成流程在数学和无害问答任务中表现出色，但它更耗计算资源，并且最终结果与直接生成流程相似。



6. 与其他校准方法的比较

Stream Aligner 优于其他校准方法

诸如监督式微调 (SFT) 和直接之类的对象

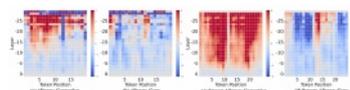
偏好优化 (DPO) 在准确性方面的情况

改进。它还实现了性能的

兼兼用超越的校准器 - 70B，展示

7. 可解释性

本文通过表示工程和激活引导来探究流对齐器的可解释性。结果表明，流对齐器已将校正范例作为表示形式内化，类似于对齐器，但在决定校正时涉及更多层，反映了数学任务的复杂性。



8. 结论

Stream Aligner 是一种新颖的对齐范例，能有效地引出上游模型的潜在知识，同时保持效率和提高性能。它在有用性、无害性和推理能力方面实现了显著的改进，使其成为将大型语言模型与人类价值观相契合的一种很有前景的方法。

限制

尽管 Stream Aligner 有其优势，但在推理过程中会引入额外的计算开销，并且需要高质量的训练数据。在处理极其困难的分布外输入时，其性能可能会受到限制。

本摘要概述了本文的主要贡献、方法、实验结果和结论，突出了 Stream Aligner 在使大型语言模型符合人类偏好方面的创新方法。

B.4. 翻译长篇小说

User Request (Query + PDF)

please help me to translate the whole paper into French.

When brain-inspired AI meets AGI.pdf

MiniMax-Text-01

Quand l'IA inspirée du cerveau rencontre l'AGI Lin Zhao a,1, Lu Zhang b,1, Zihao Wu a, Yuzhong Chen c, Haixing Dai a, Xiaowei Yu b, Zhengliang Liu a, Tuo Zhang d, Xintao Hu d, Xi Jiang c, Xiang Li e, Daijiang Zhu b, Dinggang Shen f,g,h, Tianming Liu a,*

a *School of Computing, The University of Georgia, Athens 30602, USA* b *Department of Computer Science and Engineering, The University of Texas at Arlington, Arlington 76019, USA* c *MOE Key Laboratory for Neuroinformation, School of Life Science and Technology, University of Electronic Science and Technology of China, Chengdu 611731, China* d *School of Automation, Northwestern Polytechnical University, Xi'an 710072, China* e *Department of Radiology, Massachusetts General Hospital and Harvard Medical School, Boston 02115, USA* f *School of Biomedical Engineering, ShanghaiTech University, Shanghai 201210, China* g *Shanghai United Imaging Intelligence Co., Ltd., Shanghai 200230, China* h *Shanghai Clinical Research and Trial Center, Shanghai, 201210, China*

Résumé L'Intelligence Générale Artificielle (AGI) a été un objectif de longue date pour l'humanité, visant à créer des machines capables d'effectuer toute tâche intellectuelle que les humains peuvent accomplir. Pour atteindre cet objectif, les chercheurs en AGI s'inspirent du cerveau humain et cherchent à reproduire ses principes dans des machines intelligentes. L'intelligence artificielle inspirée du cerveau est un domaine qui a émergé de cet effort, combinant des insights de la neuroscience, de la psychologie et de l'informatique pour développer des systèmes d'IA plus efficaces et puissants. Dans cet article, nous offrons un aperçu complet de l'IA inspirée du cerveau du point de vue de l'AGI. Nous commençons par les progrès actuels de l'IA inspirée du cerveau et de sa connexion étendue avec l'AGI. Nous couvrons ensuite les caractéristiques importantes de l'intelligence humaine et de l'AGI (par exemple, la mise à l'échelle, la multimodalité et le raisonnement). Nous discutons des technologies importantes pour atteindre l'AGI dans les systèmes d'IA actuels, telles que l'apprentissage contextuel et le réglage des invites. Nous examinons également l'évolution des systèmes AGI à la fois du point de vue algorithmique et infrastructurel. Enfin, nous explorons les limites et l'avenir de l'AGI.

1. L'IA inspirée du cerveau et l'AGI Le cerveau humain est largement considéré comme l'un des systèmes de traitement de l'information les plus complexes et avancés au monde. Il comprend plus de 86 milliards de neurones, chacun capable de former jusqu'à 10 000 synapses avec d'autres neurones, ce qui résulte en un réseau de connexions exceptionnellement complexe permettant la prolifération de l'intelligence. Outre la complexité physiologique, le cerveau humain présente une large gamme de caractéristiques qui contribuent à ses capacités fonctionnelles remarquables. Par exemple, il peut intégrer des données provenant de plusieurs

modalités sensorielles, telles que la vision, l'audition et le toucher, lui permettant de former une perception cohérente du monde. La capacité du cerveau à effectuer un traitement parallèle est également essentielle pour gérer efficacement plusieurs flux d'informations simultanément. Cela est réalisé via les connexions et les communications en temps réel entre différentes régions du cerveau, bien que le mécanisme ne soit pas entièrement compris. De plus, le cerveau est très adaptable, capable de réorganiser sa structure et sa fonction en réponse aux environnements et expériences changeants. Cette propriété, connue sous le nom de neuroplasticité, permet au cerveau d'apprendre et de développer de nouvelles compétences tout au long de la vie. Le cerveau humain est également remarquable pour ses fonctions cognitives de haut niveau, telles que la résolution de problèmes, la prise de décision, la créativité et le raisonnement abstrait, soutenues par le cortex préfrontal, une région du cerveau particulièrement bien développée chez les humains.

Créer des systèmes d'Intelligence Générale Artificielle (AGI) ayant une intelligence de niveau humain ou même supérieure et capables d'effectuer une large gamme de tâches intellectuelles, telles que le raisonnement, la résolution de problèmes et la créativité, est la quête de l'humanité depuis des siècles, remontant au milieu du 20ème siècle. Dans les années 1940, des pionniers comme Alan Turing ont développé des idées précoces sur les machines informatiques et leur potentiel pour simuler la pensée humaine. Depuis lors, chercher à reproduire les principes de l'intelligence humaine dans des systèmes artificiels a considérablement favorisé le développement de l'AGI et les applications correspondantes. Ces principes incluent la structure et la fonction des réseaux de neurones, la plasticité des connexions synaptiques, la dynamique de l'activité neuronale, et plus encore. En 1943, McCulloch et Pitts ont proposé le tout premier modèle mathématique d'un neurone artificiel, également connu sous le nom de neurone MCP (McCulloch-Pitts). Inspiré par la théorie de Hebb sur la plasticité synaptique, Frank Rosenblatt a conçu le perceptron, une amélioration majeure par rapport au modèle de neurone MCP, et a montré que, en assouplissant certaines des règles du MCP, les neurones artificiels pouvaient réellement apprendre à partir des données.

Cependant, la recherche sur les réseaux de neurones artificiels a stagné jusqu'à ce que la rétropropagation soit proposée par Werbos en 1975. La rétropropagation a été inspirée par la façon dont le cerveau modifie les forces des connexions entre les neurones pour apprendre et améliorer ses performances grâce à la plasticité synaptique. La rétropropagation tente de reproduire ce processus en ajustant les poids (forces synaptiques) entre les neurones dans un réseau de neurones artificiels. Malgré cette proposition précoce, la rétropropagation n'a pas attiré une attention générale jusqu'aux années 1980, lorsque des chercheurs comme David Rumelhart,

Geoffrey Hinton et Ronald Williams ont publié des articles démontrant l'efficacité de la rétropropagation pour entraîner les réseaux de neurones.

Les réseaux de neurones convolutifs (CNN) sont l'un des types de réseaux de neurones plus utilisés et les plus efficaces pour traiter les informations visuelles. Les CNN sont également inspirés de l'organisation hiérarchique du cortex visuel dans le cerveau, ce qui remonte aux travaux de David Hubel et Torsten Wiesel dans les années 1960. Dans le cortex visuel, les neurones sont disposés en couches, chaque couche traitant les informations visuelles de manière hiérarchique. L'entrée de la rétine est d'abord traitée par une couche de cellules simples qui détectent les bords et les orientations, puis transmise à des cellules plus complexes qui reconnaissent des caractéristiques plus complexes telles que les formes et les textures. Leurs travaux ont fourni des insights sur la façon dont le système visuel traite les informations et ont inspiré le développement des CNN qui pourraient reproduire ce processus de traitement hiérarchique. Les mécanismes d'attention dans les réseaux de neurones artificiels sont également inspirés de la façon dont le cerveau humain sélectionne sélectivement certains aspects de l'entrée sensorielle ou des processus cognitifs, nous permettant de nous concentrer sur les informations importantes tout en filtrant les détails non pertinents. L'attention a été étudiée dans les domaines de la psychologie et des neurosciences pendant de nombreuses années, et son application à l'intelligence artificielle fait avancer considérablement nos pas vers l'AGI. Le modèle Transformer, basé sur le mécanisme d'auto-attention, est devenu la base de nombreux réseaux de neurones artificiels de pointe tels que BERT et GPT. En adaptant les mécanismes d'auto-attention au traitement d'images, le modèle Vision Transformer (ViT) a démontré des performances de pointe dans diverses tâches de vision par ordinateur (CV) en représentant l'image comme une séquence de patches.

Récemment, de plus en plus de preuves suggèrent que les réseaux de neurones artificiels (ANN) et les réseaux de neurones biologiques (BNN) peuvent partager des principes communs dans l'optimisation de l'architecture du réseau. Par exemple, la propriété de petit monde dans les réseaux structurels et fonctionnels du cerveau a été largement étudiée dans la littérature. Dans une étude récente, les réseaux de neurones basés sur les graphes aléatoires de Watts-Strogatz (WS) avec des propriétés de petit monde ont démontré des performances compétitives par rapport aux modèles conçus à la main et optimisés par NAS (recherche d'architecture neuronale). De plus, l'analyse a posteriori a montré que la structure graphique des ANN les plus performants, tels que les CNN et le Perceptron multicouche (MLP), est similaire à celle des vrais BNN, tels que le réseau dans le cortex du macaque. Chen et al. ont proposé une représentation relationnelle unifiée et biologiquement plausible des modèles ViT, trouvant que la perfor-

mance du modèle était étroitement liée aux mesures du graphe et que le ViT a une grande similarité avec les vrais BNN. Zhao et al. ont synchronisé l'activation des ANN et des CNN et ont trouvé que les CNN avec des performances plus élevées sont similaires aux BNN en termes d'activation de la représentation visuelle. Liu et al. ont couplé les neurones artificiels dans le modèle BERT avec les neurones biologiques dans le cerveau humain, et ont trouvé que les neurones artificiels peuvent porter des informations linguistiques/sémantiques significatives et s'ancrent à leurs signatures de neurones biologiques avec interprétabilité dans un contexte neurolinguistique. Zhou et al. ont traité chaque dimension cachée dans Wav2Vec2.0 comme un neurone artificiel et les ont connectés avec leurs homologues biologiques dans le cerveau humain, suggérant une relation étroite entre les deux domaines en termes d'informations neuro-linguistiques.

Suivant cette tendance, il y a un intérêt croissant pour le développement de l'intelligence artificielle inspirée du cerveau en s'inspirant de certaines connaissances préalables du cerveau humain, telles que l'organisation de la structure et de la fonction du cerveau. Par exemple, Huang et al. ont proposé un réseau de vision antagoniste inspiré du cerveau (BI-AVAN) qui imite le processus de compétition biaisée dans le système visuel humain pour décoder l'attention visuelle humaine. Inspiré par l'organisation cœur-périphérie du cerveau humain, Yu et al. ont proposé un modèle de transformateur de vision guidé par le principe cœur-périphérie (CP-ViT) pour la reconnaissance d'images avec des performances et une interprétabilité améliorées. De même, Zhao et al. ont mis en œuvre le principe cœur-périphérie dans la conception des motifs de câblage du réseau et la sparsification de l'opération de convolution. Le CP-CNN proposé guidé par le principe cœur-périphérie démontre l'efficacité et la supériorité par rapport aux méthodes basées sur les CNN et ViT.

Un autre groupe d'études a opté pour les réseaux de neurones à pointes (SNN) qui imitent étroitement le comportement des neurones biologiques dans le cerveau. Par exemple, les SNN ont été utilisés pour cartographier et comprendre les données cérébrales spatio-temporelles, décoder et comprendre l'activité musculaire à partir des signaux d'électroencéphalographie, et les interfaces cerveau-machine.

L'IA inspirée du cerveau a également contribué au développement d'architectures matérielles qui imitent la structure et la fonction du cerveau. Le calcul neuromorphique, un domaine d'étude qui vise à concevoir du matériel informatique qui émule les neurones et les synapses biologiques, a également gagné en attention ces dernières années. Les puces neuromorphiques sont conçues pour traiter l'information de manière parallèle et distribuée, de la même manière que le cerveau fonctionne, ce qui peut conduire à des améliorations significatives en termes d'efficacité et de vitesse par rapport aux architectures informatiques traditionnelles.

Certaines des puces neuromorphiques, comme la puce TrueNorth d'IBM et la puce Loihi d'Intel, utilisent des réseaux de neurones à pointes pour traiter l'information d'une manière qui est plus proche de la façon dont le cerveau traite l'information. Ces puces ont été utilisées pour une large gamme d'applications, y compris la reconnaissance d'images et de la parole, la robotique et les véhicules autonomes. L'avancement du matériel inspiré du cerveau ouvre également la voie à des avancées significatives dans le domaine de l'AGI en pavant la voie pour des plateformes matérielles généralisées.

Dans l'ensemble, l'IA inspirée du cerveau joue un rôle crucial dans le développement de l'AGI (Fig. 1). En s'inspirant du cerveau humain, les chercheurs peuvent créer des algorithmes et des architectures mieux adaptés pour gérer des problèmes complexes et réels qui nécessitent un degré élevé de flexibilité et d'adaptabilité. Cela est particulièrement important pour l'AGI, qui vise à développer des machines capables d'effectuer une large gamme de tâches, d'apprendre de l'expérience et de généraliser leurs connaissances à de nouvelles situations. Le cerveau humain est l'un des systèmes de traitement de l'information les plus complexes connus de nous, et il a évolué pendant des millions d'années pour être très efficace et efficace dans la gestion de tâches complexes. En étudiant le cerveau et en développant des systèmes d'IA qui imitent son architecture et sa fonction, les chercheurs peuvent créer une AGI plus sophistiquée et adaptable, nous rapprochant de l'objectif ultime de créer des machines qui peuvent égaler ou surpasser l'intelligence humaine. En retour, l'AGI a également le potentiel de bénéficier à l'intelligence humaine et de approfondir notre compréhension de l'intelligence. À mesure que nous continuons à étudier et à comprendre à la fois l'intelligence humaine et l'AGI, ces deux systèmes deviendront de plus en plus intriqués, se renforçant et se soutenant mutuellement de manière nouvelle et passionnante.

2. Caractéristiques de l'AGI

2.1. Échelle

L'échelle des cerveaux varie considérablement d'une espèce animale à l'autre, allant de quelques milliers de neurones chez les invertébrés simples comme les vers nématodes, à plus de 86 milliards de neurones chez les humains. Par exemple, le cerveau d'une mouche à fruits contient environ 100 000 neurones, et le cerveau d'une souris contient environ 70 millions de neurones. Pour les primates, le cerveau du macaque a environ 1,3 milliard de neurones tandis que le cerveau du chimpanzé a environ 6,2 milliards de neurones. Comparé à d'autres animaux, le cerveau humain est la structure biologique la plus complexe et la plus sophistiquée connue de la science, contenant plus de 86 milliards de neurones. L'échelle du cerveau, c'est-à-dire le nombre de neurones, est souvent corrélée aux capacités cognitives de l'animal et considérée comme un facteur d'intelligence. La taille et la complexité des régions du cerveau associées à des fonctions cognitives spécifiques, telles que le langage ou la mémoire, sont souvent directement liées au nombre de neurones qu'elles contiennent.

Nous avons l'intention d'utiliser les grands modèles de langage (LLM) (voir le tableau 1) comme un moyen possible d'étudier l'AGI inspirée du cerveau, car les LLM sont parmi les premiers modèles à démontrer des performances de niveau humain dans diverses tâches. La relation entre le nombre de neurones et les capacités cognitives est également pertinente pour les LLM tels que GPT-2 et GPT-3. Alors que GPT-2 a 1,5 milliard de paramètres et a été entraîné sur 40 gigabytes de données textuelles, GPT-3 a 175 milliards de paramètres et a été entraîné sur 570 gigabytes de données textuelles. Cette augmentation significative du nombre de paramètres a permis à

GPT-3 de surpasser GPT-2 sur une gamme de tâches linguistiques, démontrant une augmentation de sa capacité à effectuer des tâches linguistiques complexes. En fait, GPT-3 a montré des performances de niveau humain sur plusieurs benchmarks de traitement du langage naturel, tels que la réponse aux questions, la traduction linguistique et les tâches de complétion de texte. Sa taille et sa capacité en traitement du langage naturel en ont fait un outil puissant pour diverses applications, y compris les chatbots, la génération de contenu et la traduction linguistique.

Cette tendance est similaire à la façon dont les cerveaux plus grands sont associés à des fonctions cognitives plus complexes chez les animaux. À mesure que les LLM continuent de se développer, il est attendu qu'ils deviendront encore plus capables d'apprendre de nouveaux skills avec un petit nombre d'exemples de formation, similaire à la façon dont les animaux avec des cerveaux plus grands ont des capacités cognitives plus sophistiquées. Cette corrélation suggère que l'échelle peut être un facteur crucial dans la réalisation de l'AGI. Cependant, il est à noter que le nombre de paramètres seuls ne détermine pas l'intelligence d'un LLM. La qualité des données de formation, le processus de formation et l'architecture du modèle jouent également des rôles importants dans sa performance.

En outre, il est nécessaire de rechercher des moyens qui permettent aux institutions et aux individus à ressources limitées d'accéder et de développer l'AGI. Certaines solutions possibles incluent la quantification des modèles existants de grande taille, le développement d'architectures efficaces, ou la construction de jeux de données de haute qualité qui facilitent la formation du modèle.

2.2. Multimodalité

La capacité du cerveau humain à traiter et intégrer simultanément des informations provenant de plusieurs modalités sensorielles est une réalisation remarquable. Cette caractéristique permet aux individus de comprendre le monde qui les entoure à travers diverses sources d'information, telles que la vue, le son, le toucher, le goût et l'odorat. De plus, le traitement d'informations multimodales permet aux gens de faire des évaluations plus précises et complètes de leur environnement et de communiquer efficacement avec les autres. En conséquence, l'apprentissage réussi à partir de plusieurs modalités peut améliorer les capacités cognitives humaines.

À mesure que nous nous efforçons de créer des systèmes AGI avancés qui surpassent l'intelligence humaine, il est crucial qu'ils soient capables d'acquérir et d'ingérer des connaissances à partir de diverses sources et modalités pour résoudre des tâches qui impliquent n'importe quelle modalité. Par exemple, un AGI devrait être capable d'utiliser les connaissances apprises à partir d'images et de la base de connaissances pour répondre aux questions en langage naturel, ainsi que d'utiliser les connaissances apprises à partir du texte pour effectuer des tâches visuelles. En fin de compte, toutes les modalités se croisent à travers des concepts universels, tels que le concept qu'un chien est un chien, indépendamment de la façon dont il est représenté dans différentes modalités (Fig. 2).

Pour construire des systèmes d'IA multimodaux, une approche prometteuse est d'incorporer des signaux de formation provenant de plusieurs modalités dans les LLM. Cela nécessite d'aligner les représentations internes à travers différentes modalités, permettant au système d'IA d'intégrer les connaissances de manière transparente. Par exemple, lorsqu'un système d'IA reçoit une image et un texte associé, il doit associer le même objet ou concept entre les modalités. Supposons que l'IA voie une image d'une voiture avec un texte se référant

à ses roues. Dans ce cas, l'IA doit prêter attention à la partie de l'image avec les roues de la voiture lorsqu'elle traite le texte le mentionnant. L'IA doit comprendre que l'image des roues de la voiture et le texte se référant à elles décrivent le même objet à travers différentes modalités.

Ces dernières années, les systèmes d'IA multimodaux ont expérimenté l'alignement du texte/NLP, des images/vision ou de l'information audio dans un espace d'encodage pour faciliter la prise de décision multimodale. L'alignement intermodal est essentiel pour diverses tâches, y compris la génération texte-image et image-texte, la réponse aux questions visuelles, et la modélisation vidéo-langage. Dans la section suivante, nous fournissons un bref aperçu de ces charges de travail courantes et des modèles de pointe correspondants.

2.2.1. Génération texte-image et image-texte

CLIP, DALL-E, et leur successeur GLIDE, VisualGPT et Diffusion sont parmi les modèles les plus connus qui abordent les descriptions d'images (génération image-texte) et les tâches de génération texte-image. CLIP est une méthode de pré-entraînement qui entraîne des encodeurs d'images et de texte séparés et apprend à prédire quelles images dans un ensemble de données sont associées à diverses descriptions. Notamment, de manière similaire au neurone Halle Berry chez les humains, CLIP a été trouvé pour avoir des "neurones multimodaux" qui s'activent lorsqu'ils sont exposés à la fois au texte de l'étiquette du classificateur et à l'image correspondante, indiquant une représentation multimodale fusionnée. DALL-E, en revanche, est une variante de GPT-3 avec 13 milliards de paramètres qui prend le texte comme entrée et génère une séquence d'images pour correspondre au texte d'entrée. Les images générées sont ensuite classées à l'aide de CLIP. GLIDE, une évolution de DALL-E, utilise toujours CLIP pour classer les images générées, mais la génération d'images est accomplie à l'aide d'un modèle de diffusion. Stable Diffusion est également basé sur des modèles de diffusion tout en opérant sur l'espace latent de puissants auto-encodeurs pré-entraînés et ainsi en utilisant des ressources de calcul limitées tout en maintenant leur qualité et leur flexibilité. Le VisualGPT est l'évolution de GPT-2 d'un modèle de langage unifié à un modèle multimodal avec une unité d'activation qui se réveille elle-même pour produire des activations éparpillées qui empêchent l'écrasement accidentel des connaissances linguistiques.



Fig. 1. Le développement de l'AGI a été largement inspiré par l'étude de l'intelligence humaine (HI). En retour, l'AGI a le potentiel de bénéficier à l'intelligence humaine. Par exemple, les modèles de langage actuels tels que ChatGPT et GPT-4 utilisent l'apprentissage par renforcement avec retour humain (RLHF) pour aligner leur comportement avec les valeurs humaines. À mesure que nous continuons à étudier et à comprendre à la fois l'intelligence humaine et l'AGI, ces deux systèmes deviendront de plus en plus intriqués, se renforçant et se soutenant mutuellement de manière nouvelle et passionnante.

2.2.2. Réponse aux questions visuelles

La réponse aux questions visuelles est une application cruciale de l'apprentissage multimodal qui nécessite qu'un modèle réponde correctement à une question basée sur du texte en fonction d'une image. Le jeu de données VQA présente cette tâche, et les équipes de Microsoft Research ont développé certaines des approches de

pointe pour cela. L'une de ces approches est METER, une structure générale pour former des transformateurs vision-langage performants utilisant une variété de sous-architectures pour les modules encodeur de vision, encodeur de texte, fusion multimodale et décodeur. Cette flexibilité permet à METER d'atteindre des performances de pointe dans une gamme de tâches. Une autre approche prometteuse est le modèle de pré-entraînement unifié Vision-Language (VLMo), qui utilise un réseau transformateur modulaire pour apprendre conjointement un double encodeur et un encodeur de vision. Chaque bloc du réseau contient un pool d'experts spécifiques à la modalité et une couche d'auto-attention partagée, offrant une flexibilité significative pour le réglage fin. Cette architecture a montré des résultats impressionnants sur plusieurs ensembles de données de référence.

2.2.3. Modélisation vidéo-langage

Traditionnellement, les systèmes d'IA ont eu du mal avec les tâches basées sur la vidéo en raison des ressources de calcul élevées requises. Cependant, cela commence à changer, grâce aux efforts dans le domaine de la modélisation vidéo-langage et d'autres tâches multimodales liées à la vidéo, comme le projet Florence-VL de Microsoft. À la mi-2021, le projet Florence-VL a introduit ClipBERT, une combinaison d'un modèle CNN et d'un modèle transformateur qui fonctionne sur des cadres échantillonnés de manière éparse. Il est optimisé de manière globale pour résoudre les tâches vidéo-langage populaires. Les évolutions ultérieures de ClipBERT, telles que ViOLET et SwinBERT, ont introduit le modèle de modélisation de jetons visuels masqués et l'attention éparse pour améliorer l'état de l'art en réponse aux questions vidéo, la recherche vidéo et le sous-titrage vidéo. Bien que chacun de ces modèles ait des caractéristiques uniques, ils utilisent tous une architecture basée sur le transformateur. Typiquement, cette architecture est couplée avec des modules d'apprentissage parallèle pour extraire des données de diverses modalités et les unifier en une seule représentation multimodale.

Récemment, l'émergence de GPT-4 a porté la recherche multimodale à un nouveau niveau. Selon le dernier article de recherche officiel, GPT-4 non seulement affiche une grande maîtrise dans divers domaines, y compris la littérature, la médecine, le droit, les mathématiques, les sciences physiques et la programmation, mais combine également de manière fluide les compétences et les concepts de plusieurs domaines, démontrant une compréhension impressionnante des idées complexes. De plus, la performance de GPT-4 dans toutes ces tâches est remarquablement proche du niveau humain et dépasse souvent les modèles précédents tels que ChatGPT. Compte tenu de l'étendue et de la profondeur des capacités de GPT-4, il pourrait être considéré comme une version précoce (bien qu'incomplète) d'un système AGI.

2.2.4. Apprentissage multimodal avec données auditives

Data2Vec, une récente évolution de Meta AI, présente un nouveau cadre d'apprentissage auto-supervisé qui contourne le besoin de données étiquetées traditionnelles. En tirant parti des relations internes des données, il unifie l'apprentissage à travers trois modalités distinctes : images, texte et parole. Utilisant une architecture à double mode, il utilise un modèle "enseignant" pour générer des représentations d'échantillons, et un modèle "étudiant" pour apprendre de l'enseignant à travers la minimisation d'une fonction objectif. Cette méthodologie unique permet d'obtenir des résultats de pointe dans chacune des trois modalités, marquant un pas important vers la réalisation de l'intelligence artificielle générale.

Microsoft's Kosmos-1 est un grand modèle de langage multimodal qui traite le texte, les données visuelles et auditives. Utilisant des corpus multimodaux basés sur le web, il comprend les modalités générales et démontre l'apprentissage contextuel et le suivi des instructions. Ses capacités englobent la compréhension du langage, la génération de légendes pour les images, la réponse aux questions visuelles et la reconnaissance d'images, soulignant la capacité de transfert intermodal, ce qui facilite l'échange de connaissances entre le langage et les entrées multimodales.

Il est important de noter que, contrairement aux LLM unimodaux, les LLM multimodaux affichent des performances supérieures non seulement dans les tâches intermodales mais aussi dans les tâches unimodales. Par exemple, l'intégration de la multimodalité dans GPT-4 se traduit par de meilleures performances dans les tâches textuelles par rapport à ChatGPT. Cela correspond à la façon dont les humains perçoivent le monde à travers plusieurs modalités sensorielles.

2.3. Alignement Bien que certains LLM comme BERT, GPT, GPT-2, GPT-3 et Text-to-Text Transfer Transformer (T5) aient réalisé des succès remarquables dans des tâches spécifiques, ils ne sont toujours pas encore AGI en raison de leur tendance à présenter des comportements non intentionnels. Par exemple, ils pourraient générer du texte biaisé ou toxique, inventer des faits ou ne pas suivre les instructions de l'utilisateur. La principale raison derrière ces problèmes est le désalignement entre l'objectif de modélisation du langage utilisé pour de nombreux LLM récents et l'objectif de suivre les instructions de l'utilisateur de manière sûre et utile. Par conséquent, bien que ces modèles aient fait des progrès significatifs, ils ne sont pas encore capables d'émuler le raisonnement, la prise de décision et la compréhension de type humain. Pour atteindre l'AGI, il est crucial d'aligner les modèles de langage avec l'intention de l'utilisateur. Cet alignement permettra aux LLM de fonctionner de manière sûre et utile, les rendant plus fiables pour les tâches complexes qui nécessitent une prise de décision nuancée et une compréhension. Pour ce faire, il est nécessaire de développer de meilleurs algorithmes qui orientent les agents vers les valeurs humaines tout en favorisant les collaborations interdisciplinaires pour clarifier ce que signifient les valeurs humaines.

Les développements récents dans les grands modèles de langage (LLM), tels que Sparrow, InstructGPT, ChatGPT et GPT-4, ont abordé le problème de l'alignement avec les instructions humaines en utilisant l'apprentissage par renforcement à partir du retour d'expérience humain (RLHF). L'apprentissage par renforcement est un type d'apprentissage automatique où le modèle apprend à prendre des décisions en fonction du retour d'expérience qu'il reçoit sous forme de récompenses. Le but du modèle est de maximiser sa récompense totale au fil du temps. RLHF utilise les préférences humaines comme signal de récompense pour affiner les LLM et permettre aux LLM d'apprendre et d'améliorer à partir du retour d'expérience humain, ce qui essaie de prédire quelles réponses les humains réagiront positivement à et aide à réduire les comportements non intentionnels et à augmenter leur fiabilité pour les tâches complexes. Puisque le modèle apprend des humains en temps réel, il devient de mieux en mieux à prédire. À la fin du processus de formation, les systèmes AI commencent à imiter les humains. RLHF a montré des résultats prometteurs et est un pas important vers le développement de LLM qui peuvent fonctionner de manière sûre et utile, s'alignant avec les valeurs et intentions humaines.

2.4. Raisonnement Le raisonnement joue un rôle crucial dans l'intelligence humaine et est essentiel pour la prise de décision, la résolution de problèmes et la pensée critique.

Une étude précédente a exploré les facteurs qui influencent les niveaux d'intelligence en comparant différents attributs des cerveaux à travers diverses espèces de mammifères. Les résultats suggèrent que les capacités cognitives sont principalement centrées sur le nombre absolu de neurones. Parmi les mammifères, le cerveau humain a le plus grand nombre de neurones, ce qui lui confère des capacités de raisonnement et d'intelligence supérieures par rapport aux autres espèces. Récemment, un phénomène similaire a également émergé dans les LLM. Il a été observé que les LLM présentent des comportements émergents, tels que la capacité de raisonner, lorsqu'ils atteignent une certaine taille. Pour améliorer les capacités de raisonnement des LLM, deux principaux types d'approches ont été développés. Le premier type, connu sous le nom de méthodes basées sur les invites, est plus largement recherché et implique l'utilisation d'invites appropriées pour mieux stimuler les capacités de raisonnement que les LLM possèdent déjà. Le deuxième type d'approches implique l'introduction de code de programme dans le processus de pré-formation, où il est formé aux côtés du texte pour améliorer davantage la capacité de raisonnement du LLM. Les deux approches ont des directions fondamentalement différentes : l'utilisation de code pour améliorer les capacités de raisonnement des LLM représente une stratégie de renforcement direct des capacités de raisonnement des LLM en augmentant la diversité des données de formation ; tandis que l'approche basée sur les invites ne favorise pas les capacités de raisonnement propres au LLM, mais fournit plutôt une méthode technique pour que le LLM démontre mieux cette capacité lors de la résolution de problèmes.

Actuellement, la plupart des travaux existants dans le domaine du raisonnement des grands modèles de langage (LLM) adoptent des méthodes basées sur les invites, qui peuvent être divisées en trois routes techniques. La première approche est le Zero-shot Chain of Thought (CoT), proposé par Kojima et al. Cette méthode est simple et efficace, impliquant deux étapes. Dans la première étape, une phrase d'invite, "Let's think step by step", est ajoutée à la question, et le LLM sort un processus de raisonnement spécifique. Dans la deuxième étape, le processus de raisonnement sorti par le LLM dans la première étape est concaténé avec la question, et la phrase d'invite, "Therefore, the answer (arabic numerals) is", est ajoutée pour obtenir la réponse. Une telle opération simple peut augmenter considérablement l'efficacité du LLM dans diverses tâches de raisonnement. Par exemple, Zero-shot-CoT réalise des gains de score de 10,4% à 40,7% sur le benchmark arithmétique GSM8K. La deuxième approche est le Few-Shot CoT, qui est actuellement la principale direction de la recherche en raisonnement des LLM. L'idée principale du Few-Shot CoT est simple : pour enseigner au modèle LLM à apprendre le raisonnement, fournir quelques exemples de raisonnement écrits manuellement, et expliquer clairement les étapes de raisonnement spécifiques l'une après l'autre avant d'obtenir la réponse finale dans les exemples. Ces processus de raisonnement détaillés écrits manuellement sont appelés Chain of Thought Prompting. Le concept de CoT a été proposé explicitement pour la première fois par Wei et al. Bien que la méthode soit simple, la capacité de raisonnement du modèle LLM a été grandement améliorée après l'application du CoT. La précision de l'ensemble de données de raisonnement mathématique GSM8K est passée à environ 60,1%. Basé sur le CoT, les travaux ultérieurs ont élargi le CoT à partir d'une seule question d'invite à plusieurs questions d'invite, vérifié la justesse des étapes intermédiaires de raisonnement, et amélioré la précision des sorties multiples en utilisant le vote pondéré. Ces améliorations ont continuellement augmenté la

précision du test set GSM8K à environ 83%. La troisième approche est le Least-to-most prompting. L'idée centrale est de décomposer un problème de raisonnement complexe en plusieurs sous-problèmes plus faciles à résoudre qui peuvent être résolus séquentiellement, où la résolution d'un sous-problème donné est facilitée par les réponses aux sous-problèmes précédemment résolus. Après avoir résolu chaque sous-problème, nous pouvons dériver la réponse au problème original à partir des réponses aux sous-problèmes. Cette idée est hautement cohérente avec l'algorithme diviser pour mieux régner que les humains utilisent pour résoudre des problèmes complexes. A mesure que notre compréhension du cerveau et des LLM continue de s'approfondir, il sera intéressant d'étudier si ces deux systèmes réseau partagent une structure optimale.

3. Technologie importante Les modèles de langage, tels que les LLM, reposent sur plusieurs techniques cruciales, notamment le zero-shot prompting, le few-shot prompting, l'apprentissage contextuel et l'instruction. L'attente sous-jacente de ces techniques est que les systèmes AI peuvent rapidement apprendre de nouvelles tâches en s'appuyant sur ce qu'ils ont appris dans le passé, tout comme les humains le font. Grâce à l'utilisation de ces techniques, les modèles de langage peuvent être formés pour effectuer une large gamme de tâches, de la génération de texte cohérent à la réponse à des questions complexes, avec plus de précision et d'efficacité. En fin de compte, ces avancées nous rapprochent de la réalisation du potentiel de l'AI pour assister et augmenter l'intelligence humaine de manière nouvelle et passionnante. Parmi ces techniques, l'instruction sert d'interface utilisée par ChatGPT, où les utilisateurs fournissent des descriptions de tâches en langage naturel, telles que "Traduisez cette phrase du chinois à l'anglais". Fait intéressant, le zero-shot prompting était initialement le terme utilisé pour l'instruction. Au cours des premières étapes du zero-shot prompting, les utilisateurs ont eu du mal à expliquer les tâches clairement, les amenant à essayer divers mots et phrases à plusieurs reprises pour obtenir la formulation optimale. Actuellement, l'instruction consiste à fournir une déclaration de commande pour faciliter la compréhension du LLM.

3.1. Apprentissage contextuel La capacité la plus importante du cerveau humain réside dans sa capacité d'apprentissage robuste, permettant l'exécution de fonctions cognitives, computationnelles, expressives et motrices basées sur des invites linguistiques ou visuelles, souvent avec peu ou pas d'exemples. Cette caractéristique est centrale à l'obtention d'une AGI de niveau humain. Les récents avancées dans les modèles AGI à grande échelle, en particulier GPT-4, ont démontré une capacité prometteuse. Ils sont pré-entraînés sur des ensembles de données multimodales massives, capturant une large gamme de tâches et de connaissances tout en comprenant diverses invites des domaines linguistiques et visuels. Cela permet l'apprentissage contextuel similaire au mode de fonctionnement du cerveau humain, et pousse l'AGI dans des applications du monde réel, y compris des applications dans le domaine de la santé. En fait, à la suite de l'émergence de modèles à grande échelle comme GPT-4 et Midjourney V5, de nombreuses industries, telles que le traitement de texte et l'illustration, ont vu des scénarios perturbateurs où l'AGI libère le travail humain. Ces modèles tirent parti des connaissances préalables acquises lors du pré-entraînement sur diverses tâches et textes, permettant une adaptation rapide à de nouvelles tâches sans nécessiter de données étiquetées étendues pour le réglage fin, ce qui est un défi crucial dans des domaines comme la médecine et la robotique où les données étiquetées sont souvent limitées ou même indisponibles.

Dans le contexte de l'AGI, l'apprentissage contextuel désigne la capacité du modèle à comprendre et à exécuter de nouvelles tâches en fournissant un nombre limité de tâches entrées-sorties dans les invites ou simplement une description de la tâche. Les invites facilitent la compréhension du modèle de la structure et des motifs de la tâche, tandis que l'apprentissage contextuel présente des similitudes avec le réglage fin explicite au niveau de la prédiction, de la représentation et du comportement de l'attention. Cela leur permet de généraliser et de mieux effectuer de nouvelles tâches sans formation ou réglage fin supplémentaires et réduit la probabilité de surajustement des données de formation étiquetées en aval.

Malgré l'absence de besoins en réglage fin dans ces modèles AGI à grande échelle, les compromis incluent l'augmentation des coûts de calcul en raison de leur échelle massive de paramètres et le besoin potentiel de connaissances expertes dans la formulation d'invites efficaces avec des exemples lors de l'inférence. Les solutions potentielles impliquent des avancées matérielles et l'intégration de connaissances spécifiques à un domaine plus raffinées lors de la phase de pré-entraînement.

3.2. Réglage des invites et des instructions Comme les nourrissons humains acquièrent généralement divers concepts sur le monde principalement par l'observation, avec très peu d'intervention directe, les modèles AGI à grande échelle acquièrent également une vaste connaissance après une formation non supervisée initiale et ont atteint des performances de généralisation remarquables. Les méthodes basées sur les invites et le réglage des instructions permettent aux modèles pré-entraînés d'atteindre l'apprentissage zero-shot dans de nombreuses applications en langage naturel.

Le cerveau humain est toujours un processeur efficace et ordonné, fournissant un retour ciblé pour la tâche actuelle plutôt que de dire des absurdités. En plus de l'efficacité innée du cerveau, les contraintes morales et légales enracinées dans le développement humain garantissent également que les interactions humaines sont ordonnées et bénéfiques. Pour que les modèles AGI atteignent des performances de niveau humain, produire des résultats vrais et inoffensifs sur la base des instructions est une exigence essentielle. Bien que les modèles AGI actuels aient des capacités génératives puissantes, une question clé est de savoir si ces capacités peuvent être alignées avec l'intention de l'utilisateur. Cela est important car cela concerne si le modèle peut produire des résultats satisfaisants pour les utilisateurs, même dans des situations où les tâches et les invites sont inédites et peu claires. De plus, à mesure que ces modèles deviennent plus largement utilisés, les sorties non vraies et toxiques doivent être efficacement contrôlées.

InstructGPT est à l'avant-garde à cet égard. Afin d'améliorer la qualité des sorties du modèle, une formation supervisée est effectuée en utilisant des invites et des démonstrations fournies par l'homme. Les sorties générées par différents modèles sont ensuite collectées et classées par l'homme en fonction de leur qualité. Les modèles sont ensuite affinés en utilisant une technique connue sous le nom de RLHF, qui utilise les préférences humaines comme récompenses pour guider le processus d'apprentissage. En outre, pour éviter que InstructGPT ne s'aligne exclusivement avec les tâches humaines au détriment de négliger les tâches NLP classiques, une petite quantité de données originales utilisées pour former GPT-3 (la base de InstructGPT) est mélangée. Des recherches récentes ont démontré que l'incorporation de jeux de données d'instructions de tâches à plus grande échelle et plus diversifiées peut encore améliorer les performances du modèle.

3.3. Évolution de l'AGI L'AGI fait référence à un niveau avancé d'intelligence artificielle (IA) qui reflète les capacités humaines dans la compréhension, l'apprentissage et l'application des connaissances à travers un large éventail de tâches et de domaines. Contrairement à l'IA étroite (par exemple, un réseau de neurones convolutif sur mesure pour la reconnaissance faciale), qui est conçue pour effectuer des tâches spécifiques, l'AGI est capable de s'adapter à de nouvelles situations, de transférer des connaissances entre domaines et de démontrer des capacités cognitives humaines au-delà des flux de travail de résolution de tâches rationalisés et formatés dans la littérature actuelle. Dans l'ensemble, l'AGI pourrait démontrer une polyvalence et une adaptabilité remarquables. Bien que la communauté scientifique n'ait pas encore réalisé une véritable AGI, les avancées réalisées dans le domaine de l'intelligence artificielle et de ses sous-domaines (par exemple, l'apprentissage profond) ont jeté les bases pour une exploration plus approfondie et la quête vers la réalisation de l'AGI. Voici un bref aperçu de l'histoire de l'AGI.

3.4. Premiers jours de l'IA Le concept d'AGI remonte au travail d'Alan Turing, qui a proposé l'idée que les machines pourraient penser et apprendre comme des humains dans un manuscrit de 1950 intitulé "Computing Machinery and Intelligence". Les idées de Turing ont jeté les bases du développement de l'IA et de l'informatique en général. En 1956, l'atelier de Dartmouth, organisé par des pionniers tels que John McCarthy, Marvin Minsky, Nathaniel Rochester et Claude Shannon, a marqué le début de l'IA en tant que discipline académique. Leur objectif était de développer des machines capables d'imiter l'intelligence humaine. Cet effort collectif a joué un rôle significatif dans la formation du futur cours de la communauté de l'IA.

L'optimisme et l'enthousiasme initiaux dans le domaine ont conduit au développement de programmes d'IA précoces tels que le General Problem Solver, le Logic Theorist et ELIZA. Cependant, ces systèmes d'IA étaient limités en portée et impraticables pour des applications à grande échelle dans le monde réel. Une période connue sous le nom d'hiver de l'IA s'est produite en raison d'une baisse du financement et de l'intérêt pour la recherche en intelligence artificielle. Cela était dû au manque de progrès significatifs réalisés dans le domaine et aux revendications irréalistes faites par certains chercheurs. La réduction du soutien financier a, à son tour, conduit à une nouvelle baisse des progrès et à une diminution du nombre de publications de recherche.

Le regain d'intérêt pour l'IA a été apporté par les réseaux de neurones artificiels qui étaient modélisés d'après la structure et la fonction du cerveau humain. L'algorithme de rétropropagation, introduit par Rumelhart, Hinton et Williams en 1986, a permis aux réseaux de neurones d'apprendre plus efficacement et a jeté des bases solides pour les réseaux de neurones modernes.

En outre, l'émergence de méthodes d'apprentissage automatique telles que les machines à vecteurs de support, les arbres de décision et les méthodes d'ensemble s'est avérée être des outils puissants pour la reconnaissance des formes et la classification. Ces méthodes ont propulsé la recherche en IA et ont permis des applications pratiques, poussant davantage le domaine vers l'avant.

3.5. Apprentissage profond et AGI moderne Le développement de l'apprentissage profond, rendu possible par des avancées révolutionnaires en matière de puissance de calcul et la disponibilité de grands ensembles de données, a conduit à des avancées notables dans le domaine de l'IA. Les percées en vision par ordinateur, en traitement du langage naturel et en apprentissage par renforcement rapprochent la perspective de l'AGI de devenir une réalité tangible. En

particulier, l'architecture Transformer, introduite par Vaswani et al. en 2017, a révolutionné la modélisation du langage en exploitant des mécanismes d'auto-attention pour capturer les dépendances globales et les relations contextuelles entre les mots d'une séquence. Cette percée a jeté les bases de l'essor des modèles de langage pré-entraînés, tels que BERT et ses diverses variantes spécifiques à un domaine, des modèles plus grands tels que GPT-3, et des modèles basés sur le transformateur de vision (ViT) en vision par ordinateur. Cette ascendance architecturale partagée a également ouvert la voie au développement de modèles multimodaux basés sur le transformateur.

Depuis 2019, l'introduction de modèles de langage à grande échelle comme GPT-2 et GPT-3, tous deux basés sur l'architecture Transformer, ont démontré des capacités impressionnantes de compréhension et de génération en langage naturel. Bien que ces modèles ne soient pas encore de l'AGI, ils représentent une étape importante vers la réalisation de cet objectif. GPT-2 et GPT-3 sont basés sur GPT, un modèle de langage pré-entraîné uniquement décoder qui utilise des mécanismes d'auto-attention pour capturer les dépendances à long terme entre les mots d'une séquence.

Les avancées récentes en IA ont donné lieu à des extensions révolutionnaires des modèles GPT, telles que ChatGPT et GPT-4. ChatGPT s'appuie sur le succès de GPT-3, intégrant le RLHF pour générer des sorties qui s'alignent correctement avec les valeurs et préférences humaines. L'interface de chatbot de ChatGPT a permis à des millions d'utilisateurs d'interagir avec l'IA de manière plus naturelle, et elle a été appliquée dans divers cas d'utilisation tels que la rédaction d'essais, la réponse aux questions, la recherche, la traduction, l'augmentation de données, le diagnostic assisté par ordinateur et la dépersonnalisation des données. En revanche, GPT-4 représente une avancée significative dans la série GPT, avec un ensemble massif de 10 billions de paramètres. Il est capable de mathématiques avancées, de raisonnement logique. De plus, le modèle excelle dans les examens standard tels que l'USMLE, le LSAT et le GRE. GPT-4 a une applicabilité large et est attendu pour résoudre une gamme de problèmes sans précédent. Son développement témoigne des progrès considérables réalisés dans la quête de l'AGI.

3.6. L'infrastructure de l'AGI Un aspect clé de l'AGI est l'infrastructure nécessaire pour la soutenir. Les réseaux de neurones ont été un composant majeur de cette infrastructure, et leur développement a considérablement évolué depuis leur création dans les années 1940 et 1950. Les premiers ANN étaient limités dans leurs capacités en raison de leurs simples modèles linéaires. Cependant, l'algorithme de rétropropagation, créé par Werbos en 1975, a révolutionné le domaine en rendant possible l'entraînement efficace de réseaux de neurones à plusieurs couches, y compris le perceptron. Cet algorithme calcule les gradients, qui sont utilisés pour mettre à jour les poids du réseau de neurones pendant l'entraînement, lui permettant d'apprendre et d'améliorer ses performances au fil du temps. Depuis le développement de la rétropropagation, la recherche sur les réseaux de neurones a progressé rapidement, avec la création d'architectures et d'algorithmes d'optimisation plus sophistiqués. Aujourd'hui, les réseaux de neurones sont utilisés pour une large gamme de tâches, y compris la classification d'images, le traitement du langage naturel et la prédiction, et continuent d'être un domaine de recherche actif en apprentissage automatique et en intelligence artificielle.

En plus de l'algorithme, les progrès du matériel, en particulier le développement des unités de traitement graphique (GPU) et des unités de traitement tensoriel (TPU), ont permis d'entraîner efficacement des réseaux de neurones profonds, ce qui a conduit à

l'adoption généralisée de l'apprentissage profond. Ces progrès ont permis le développement de réseaux de neurones plus puissants, capables de s'attaquer à des problèmes de plus en plus complexes et ont accéléré la recherche et le développement de l'AGI. Par exemple, l'investissement de 1 milliard de dollars de Microsoft dans OpenAI en 2019 a permis la création d'un supercalculateur Azure AI dédié, l'un des systèmes d'IA les plus puissants au monde. Ce supercalculateur est équipé de plus de 285 000 cœurs de CPU et de plus de 10 000 GPU, et il est conçu pour prendre en charge l'entraînement distribué à grande échelle des réseaux de neurones profonds. De tels investissements dans l'infrastructure sont essentiels pour le développement de l'AGI.

Les avancées récentes dans les modèles d'IA, en particulier la série GPT, ont fourni des informations précieuses sur les exigences en matière d'infrastructure pour le développement de l'AGI. Pour entraîner les modèles d'IA, trois composants essentiels de l'infrastructure AGI sont nécessaires : des exigences massives en matière de données, des ressources de calcul et des systèmes de calcul distribués. Les modèles GPT, y compris GPT-2 et GPT-3, ont été principalement entraînés sur des ensembles de données web à grande échelle, comme l'ensemble de données WebText, qui comprenait 45 téraoctets de données textuelles avant le prétraitement et la déduplication, réduit à environ 40 gigaoctets de données textuelles après le prétraitement. L'entraînement d'un modèle GPT nécessite un matériel puissant et des techniques de traitement parallèle, comme l'illustre GPT-3, qui a été entraîné en utilisant un entraînement distribué à grande échelle sur plusieurs GPU, consommant une quantité importante de ressources de calcul et d'énergie. Développer un modèle AGI, comme GPT-4, nécessite des techniques de calcul distribué. Bien que les systèmes de calcul distribués spécifiques utilisés pour entraîner les modèles GPT ne soient pas publiquement divulgués, TensorFlow, PyTorch et Horovod sont des frameworks de calcul distribué qui facilitent la mise en œuvre de ces techniques. Les chercheurs et les développeurs peuvent utiliser ces frameworks pour distribuer le processus d'entraînement sur plusieurs appareils, gérer la communication et la synchronisation des appareils et utiliser efficacement les ressources de calcul disponibles.

4. Discussion 4.1. Limitations Bien que des progrès significatifs aient été réalisés dans le développement de l'AGI et de l'IA inspirée du cerveau, il reste plusieurs limitations à surmonter avant que nous puissions atteindre une véritable intelligence de niveau humain dans les machines. Certaines de ces limitations incluent :

Compréhension limitée du cerveau humain : Malgré les avancées significatives en neurosciences et en IA inspirée du cerveau, nous avons encore une compréhension limitée de la façon dont le cerveau humain fonctionne. Cela rend difficile la création de machines capables de reproduire pleinement l'intelligence humaine. Efficacité des données : Les systèmes actuels d'AGI et d'IA inspirée du cerveau nécessitent de vastes quantités de données d'entraînement pour atteindre des performances comparables à celles des humains. Cela contraste avec les humains, qui peuvent apprendre à partir de relativement peu d'exemples et généraliser à de nouvelles situations avec facilité. Comment apprendre efficacement à partir de quelques échantillons est encore une question ouverte. Les recherches antérieures sur l'apprentissage few-shot et l'apprentissage efficace avec une annotation humaine limitée pourraient fournir des insights pour les grands modèles AGI. Éthique : Il y a aussi des considérations éthiques à prendre en compte avec l'AGI. À mesure que ces systèmes deviennent plus intelligents, ils peuvent être en mesure de prendre des décisions qui ont des conséquences de grande

portée. S'assurer que ces décisions s'alignent avec les valeurs et principes éthiques humains est crucial pour prévenir les dommages non intentionnels. Sécurité : La sécurité est également une préoccupation majeure avec l'AGI. S'assurer que ces systèmes ne causent pas de dommages non intentionnels, que ce soit par intention malveillante ou par erreurs non intentionnelles, est essentiel pour leur adoption généralisée. Développer des mécanismes de sécurité robustes et s'assurer que les systèmes AGI s'alignent avec les valeurs humaines est essentiel. En outre, la protection de la vie privée est également une importance particulière. Coût de calcul : Les modèles LLM actuels nécessitent des ressources de calcul massives pour s'entraîner et fonctionner, ce qui rend difficile le développement et le déploiement dans une large gamme de scénarios. Pendant ce temps, le coût de calcul peut limiter le nombre de chercheurs et d'organisations travaillant dans le domaine, ce qui peut ralentir les progrès vers l'AGI. De plus, la consommation d'énergie des systèmes AGI peut être prohibitivement élevée, ce qui les rend insoutenables du point de vue environnemental.

4.2. L'avenir de l'AGI L'avenir de l'AGI est un domaine passionnant et en rapide évolution. Bien que le développement de l'AGI reste un défi, il a le potentiel de révolutionner de nombreux aspects de notre vie, de la santé aux transports à l'éducation. Une voie potentielle pour faire avancer l'AGI est la création de modèles de fondation AGI plus puissants et sophistiqués. Les percées récentes en traitement du langage naturel, vision par ordinateur, graphe de connaissances et apprentissage par renforcement ont conduit au développement de modèles AGI de plus en plus avancés tels que ChatGPT et GPT-4. Ces modèles ont montré des capacités impressionnantes dans diverses applications. De nouvelles avancées dans la recherche sur les modèles de fondation AGI, ainsi que des améliorations dans le matériel et les algorithmes de calcul, sont très susceptibles d'accélérer le développement de l'AGI. Une autre approche pour développer l'AGI est l'intégration de différents systèmes et technologies d'IA dans plusieurs domaines, y compris l'ajout de l'humain dans la boucle grâce à l'apprentissage par renforcement à partir du retour d'expérience d'experts. Par exemple, combiner le traitement du langage naturel avec la vision par ordinateur et la robotique sous la direction d'experts humains pourrait conduire à la création de systèmes intelligents plus polyvalents et adaptables. Cette intégration pourrait également aider à surmonter les limitations des systèmes d'IA actuels, qui sont souvent spécialisés dans des domaines spécifiques et manquent de la flexibilité pour transférer des connaissances entre domaines.

Le développement de l'AGI nécessite également le développement de nouvelles approches en apprentissage automatique, telles que des méthodes d'instruction plus efficaces, des algorithmes d'apprentissage contextuel et un paradigme de raisonnement, en particulier en apprenant du cerveau humain via l'IA inspirée du cerveau. Ces approches visent à permettre aux machines d'apprendre à partir de données non structurées sans avoir besoin de les étiqueter et de généraliser rapidement à partir de quelques exemples, ce qui est crucial pour permettre aux machines d'apprendre et de s'adapter à de nouvelles tâches et environnements. Enfin, les implications éthiques et sociétales du développement de l'AGI doivent être considérées, y compris les questions liées aux biais, à la vie privée et à la sécurité. À mesure que l'AGI devient plus puissant et omniprésent, il est essentiel de s'assurer qu'il est développé et utilisé de manière responsable et éthique, au bénéfice de l'ensemble de la société et en s'alignant bien avec les valeurs humaines.

Dans l'ensemble, bien que le développement de l'AGI reste un défi, il a le potentiel de révolutionner de nombreux aspects de notre vie et d'apporter des avantages significatifs à la société et à l'humanité. Les recherches et développements en cours en AGI continueront à faire progresser les progrès vers l'objectif ultime de créer des machines véritablement intelligentes.

5. Conclusion Dans cet article, nous avons fourni un aperçu complet de l'IA inspirée du cerveau du point de vue de l'AGI, couvrant ses progrès actuels, ses caractéristiques importantes et ses avancées technologiques vers la réalisation de l'AGI. Nous avons également discuté de l'évolution, des limitations et de l'avenir de l'AGI. En conclusion, l'IA inspirée du cerveau est un domaine prometteur qui a le potentiel de percer les mystères de l'intelligence humaine et de tracer la voie vers l'AGI. Bien que des progrès significatifs aient été réalisés ces dernières années, il reste encore beaucoup de travail à faire pour réaliser l'AGI. Cela nécessitera des avancées technologiques, algorithmiques et matérielles, ainsi que la collaboration continue entre plusieurs disciplines. Néanmoins, la poursuite de l'AGI est une entreprise importante et valable qui a le potentiel de transformer notre monde de manière sans précédent. Nous espérons que cette étude apporte une contribution précieuse à ce domaine passionnant et inspire de nouvelles recherches et développements vers l'objectif ultime de l'AGI.

Déclaration d'auteur Lin Zhao : Investigation, Conceptualisation, Rédaction - Rédaction originale ; Lu Zhang : Investigation, Conceptualisation, Rédaction - Rédaction originale ; Zihao Wu : Rédaction - Rédaction originale ; Yuzhong Chen : Rédaction - Rédaction originale ; Xiaowei Yu : Rédaction - Rédaction originale ; Zhengliang Liu : Rédaction - Rédaction originale ; Tuo Zhang : Rédaction - Révision & Édition ; Xintao Hu : Rédaction - Révision & Édition ; Xi Jiang : Rédaction - Révision & Édition ; Xiang Li : Rédaction - Révision & Édition ; Dajiang Zhu : Rédaction - Révision & Édition ; Dinggang Shen : Supervision ; Tianming Liu : Supervision, Rédaction - Révision & Édition.

Déclaration d'intérêts Les auteurs n'ont aucun conflit d'intérêts. L'auteur Tianming Liu est le rédacteur en chef du journal, mais n'a pas participé à la procédure de révision par les pairs. Cet article a été traité par un autre membre du comité éditorial.

Remerciements Aacun.

Références 1. Herculano-Houzel S. Le cerveau humain remarquable, mais pas extraordinaire, en tant que cerveau de primate à grande échelle et son coût associé. *Proc Natl Acad Sci USA*. 2012; 109(supplément 1):10661-10668. 2. Zhang J, Umitte de base des neurones du cerveau : neurones, synapses et potentiel d'action. *arXiv preprint arXiv:190601703*. 2019. 3. Ackerman S. Découvrir le cerveau. 1992. 4. Stein BE, Stanford TR, Rowland BA. La base neurale de l'intégration multisensorielle dans le mésencéphale : son organisation et sa maturation. *Hear Res*. 2009;258(1-2):4-15. 5. Shigihara Y, Zeki S. Traitement parallèle dans le système visuel de la forme du cerveau : une étude fMRI. *Front Hum Neurosci*. 2014;8:506. 6. Egorova N, Shtyrov Y, Pulvermüller F. Traitement précoce et parallèle de l'information pragmatique et sémantique dans les actes de parole : preuves neurophysiologiques. *Front Hum Neurosci*. 2013;7:86. 7. Lang EW, Tome AM, Keck IR, Gorzic-Saez J, Puntonet CG. Analyse de la connectivité cérébrale : une courte enquête. *Comput Intell Neurosci*. 2012;2012:8. 8. Demarin V, MOROVIC. *Periodicum Biologorum*. vol. 116. 2014;209-211. 9. Neuroplasticité. 9. Funahashi S. Mémoire de travail dans le cortex préfrontal. *Brain Sci*. 2017;7(5):49. 10. De Souza LC, Guimarães HC, Teixeira AL, et al. Neurologie du lobe frontal et esprit créatif. *Front Psychol*. 2014;761. 11. Teffer K, Semendeferi K. Cortex préfrontal humain : évolution, développement et pathologie. *Prog Brain Res*. 2012;195:191-218. 12. Turing AM. *Computing Machinery and Intelligence*. Springer; 2009. 13. McCulloch WS, Pitts W. Un calcul logique des idées immuables dans l'activité nerveuse. *Bull Math Biophys*. 1943;5:115-133. 14. Rosenblatt F. Principes de la dynamique neuronale - Perceptrons et la théorie des mécanismes cérébraux. Cornell Aeronautical Lab Inc Buffalo NY; 1961. 15. Werbos P. Au-delà de la régression : nouveaux outils pour la prédiction et l'analyse dans les sciences du comportement. PhD Thesis, Committee on Applied Mathematics. Cambridge, MA: Harvard University; 1974. 16. Rumelhart DE, Hinton GE, Williams RJ. Apprentissage de représentations internes par propagation de l'erreur. *California Univ San Diego La Jolla Inst for Cognitive Science*; 1985. 17. LeCun Y, Bengio Y. Réseaux convolutifs pour les images, la parole et les séries temporelles. *Le manuel de la théorie du cerveau et des réseaux neuronaux*. 1995;3361(10):1995. 18. Hubel DH, Wiesel TN. Champs récepteurs, interaction binoculaire et architecture fonctionnelle dans le cortex visuel du chat. *J Physiol*. 1962;160(1):106. 19. Posner MI, Petersen SE. Le système d'attention du cerveau humain. *Annu Rev Neurosci*. 1990;13(1):25-42. 20. Devlin J, Chang MW, Lee K, Toutanova K. Bert : pré-formation de transformateurs bidirectionnels profonds pour la compréhension du langage. *arXiv preprint arXiv:181004805*. 2018. 21. Radford A, Narasimhan K, Salimans T, Sutskever I. Amélioration de la compréhension du langage par la pré-formation générative. *Open*. 2018. 22. Dosovitskiy A, Beyer L, Kolesnikov A, et al. Une image vaut 16x16 mots : transformateurs pour la reconnaissance d'images à grande échelle. *arXiv preprint arXiv:201011929*. 2020. 23. Basset DS, Bullmore E. Réseaux cérébraux petit-monde. 12. *The neuroscientist*; 2006:512523. 24. Bullmore E, Sporns O. Réseaux cérébraux complexes - analyse théorique des systèmes structurels et fonctionnels. *Nat Rev Neurosci*. 2009;10(3):186-198. 25. Basset DS, Bullmore ET. Réseaux cérébraux petit-monde revisités. *Neuro-scientist*. 2017; 23(5):499-516. 26. Xie S, Kiril-ov A, Girshick R, He K. Exploration de réseaux neuronaux connectés aléatoirement pour la reconnaissance d'images. Dans : *Proceedings of the IEEE/CVF International Conference on Computer Vision*. 2019:1284-1293. 27. Taub H, Mas J. Multilayer Perceptron (MLP). *Geomatic Approaches for Modeling Land Change Scenarios*. 2018:451-455. 28. Tolstikhin IO, Houlsby N, Ko-lesnikov A, et al. Mlp-mixer : une architecture tout-MLP pour la vision. *Adv Neural Inf Process Syst*. 2021;34:24261-24272. 29. You J, Leskovec J, He K, Xie S. Graph structure of neural networks. Dans : *International Conference on Machine Learning*. PMLR; 2020:10881-10891. 30. Chen Y, Du Y, Xiao Z, et al. Une représentation relationnelle unifiée et biologiquement plausible des transformateurs de vision. *arXiv preprint arXiv:220611073*. 2022. 31. Zhao L, Dai H, Wu Z, et al. Couplage de la sémantique visuelle des réseaux neuronaux artificiels et de la fonction cérébrale humaine via des activations synchronisées. *arXiv preprint arXiv:220610821*. 2022. 32. Liu X, Zhou M, Shi G, et al. Couplage des neurones artificiels dans Bert et des neurones biologiques dans le cerveau humain. *arXiv preprint arXiv:230314871*. 2023. 33. Zhou M, Liu X, Liu D, et al. Neurones Artificiels à Grain Fin dans les Audio-Transformers pour Disentangling Neural Auditory Encoding. The 61st Annual Meeting of the Association for Computational Linguistics; 2023. 34. Huang H, Zhao L, Hu X, X, et al. BI avan : réseau d'attention visuelle antagoniste inspiré du cerveau. *arXiv preprint arXiv:221015790*. 2022. 35. Yu X, Zhang L, Dai H, et al. Redéfinition de l'auto-attention dans les transformateurs guidée par le principe cœur-périphérie. *arXiv preprint arXiv:230315569*. 2023. 36. Zhao L, Dai H, Wu Z, Zhu D, Liu T, Cnn CP. Réseaux de neurones convolutifs guidés par le principe cœur-périphérie. *arXiv preprint arXiv:230410515*. 2023. 37. Ghosh-Dastidar S, Adeli H. Réseaux neuronaux à pointes. *Int J Neural Syst*. 2009;19(4):295308. 38. Kasabov NK. *NeuCube : une architecture de réseau neuronal à pointes pour le mapping, l'apprentissage et la compréhension des données cérébrales spatio-temporelles*. *Neural Network*. 2014;52:62-76. 39. Ku-O. Le connectome humain : un réseau complexe. *Ann NY Acad Sci*. 2011;1224(1):109-125. 61. Devlin J, Cha-ng MW, Lee K, Toutanova K. Bert : pré-formation de transformateurs bidirectionnels profonds pour la compréhension du langage. Dans : *NAACL HLT 2019 - 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies - Proceedings of the Conference*. vol. 1. 2019:4171-4186. 62. Radford A, Narasimhan K, Salimans T, Sutskever I, et al. Amélioration de la compréhension du langage par la pré-formation générative. *CoRR*; 2018. 63. Liu Y, Ott M, Goyal N, et al. Roberta : une approche de pré-formation Bert robuste et optimisée. *arXiv preprint arXiv:1907.11692*. 64. Sanh V, Debut L, Chaumond J, Wolf T. DistilBERT, une version distillée de Bert : plus petit, plus rapide, moins cher et plus léger. 2019. *arXiv preprint arXiv:1910.01108*. 65. Lepikhin D, Lee H, Xu Y, et al. Gshard : Scaling Giant Models with Conditional Computation and Automatic Sharding. 2020. *arXiv preprint arXiv:2006.16668*. 66. Zhang Z, Han X, Liu Z, Jiang X, Sun M, Liu Q. ERNIE : Amélioration de la représentation du langage des robots plus intelligents grâce au calcul inspiré du cerveau. *Science Robotics*. 2019;4:345(6197):668-673. 43. Benjamin BV, Gao P, McQuinn E, et al. Neurogrid : un système multichip analogique-numérique pour les simulations neurales à grande échelle. *Proc IEEE*. 2014;102(5):699-716. 44. Zhang B, Shi L, Song S. Créer des robots plus intelligents grâce au calcul inspiré du cerveau. *Science Robotics*. 2016;354(6318):1445. 45. Davies M, Srinivasan N, Lin TH, et al. Loihi : un processeur neuromorphique multicœur avec apprentissage intégré. *Ieee Micro*. 2018;38(1):82-99. 46. Roy K, Jaiswal A, Panda P. Vers une intelligence machine basée sur les pointes N, Roberts A, et al. Exploration des limites de transfert learning avec un transformateur texte-vers-texte unifié. *J Mach Learn Res*. 2020;21(1):5485-5551. 69. Yang Z, Dai Z, Yang Y, Carbonell J, Salakhutdinov RR, Le QV. Xlnet : pré-formation autotransgressive généralisée pour la compréhension du langage. *Adv Neural Inf Process Syst*. 2019;32. 70. Radford A, Wu J, Child R, Luan D, Amodei D, Sutskever I. Les modèles de langage sont des apprenants multi-tâches non supervisés. *OpenAI blog*. 2019;1(8):9. 71. Clark K, Luong MT, Le T, Manning CD. Electra : pré-formation de encodeurs de texte comme discriminateurs plutôt que comme générateurs. 2020. *arXiv preprint arXiv:2003.10555*. 72. He P, Liu X, Gao J, Chen W. Deberta : Decoding enhanced Bert with Disentangled Attention. *arXiv preprint arXiv:2006.03654*. 73. G, Shafiq M. LaneSNNs : réseaux neuronaux à pointes pour la détection des voies sur le processeur neuromorphique Loihi, avec retour humain. 2021. *arXiv preprint arXiv:2112.09332*. 74. Wei J, Bosma M, Zhao VY, et al. Finetuned Language Models Are Zero-Shot Learners. 2021. *arXiv preprint arXiv:2109.01652*. 75. Zhang Z, Gu Y, Han X, et al. Cpm-2 : modèles de langage pré-entraînés à grande échelle et rentables. *AI Open*. 2021;2:216-224. 76. Xue L, Constant N, Roberts A, et al. M25 : un transformateur pré-entraîné texte-vers-texte multilingue massif. 2020. *arXiv preprint arXiv:2010.11934*. 77. Sanh V, Webson A, et al. Multitask Prompted Training Enables Zero-Shot Task Generalization. 2021. *arXiv preprint arXiv:2110.08207*. 78. Brown T, Mann B, Ryder N, et al. Les modèles de langage sont des apprenants In-few-shot. *Adv Neural Inf Process Syst*. 2020;33:1877-1901. 79. Dicke U, Roth G. Facteurs neuronaux déterminant l'intelligence élevée. *Phil Trans Biol Sci*. 2016;371(1685):20150180. 57. Stanley KO, D'Ambrosio DB, Gaucci J. Un encodage basé sur l'hypercube pour l'évolution des réseaux neuronaux à grande échelle. *Artif Life*. 2009;15(2):185-212. 58. Huttenlocher PR. Densité synaptique dans le cortex frontal humain - changements développementaux et effets du vieillissement. *Brain Res*. 1979;163(2):195-205. 59. Rakic P. Un petit pas pour la cellule, un grand pas pour l'humanité : une hypothèse de l'expansion néocorticale au cours de l'évolution. *Trends Neurosci*. 1995;18(9):383-388. 60. Sporns O. Le connectome humain : un réseau complexe. *Ann NY Acad Sci*. 2011;1224(1):109-125. 61. Devlin J, Cha-ng MW, Lee K, Toutanova K. Bert : pré-formation de transformateurs bidirectionnels profonds pour la compréhension du langage. Dans : *NAACL HLT 2019 - 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies - Proceedings of the Conference*. vol. 1. 2019:4171-4186. 62. Radford A, Narasimhan K, Salimans T, Sutskever I, et al. Amélioration de la compréhension du langage par la pré-formation générative. *CoRR*; 2018. 63. Liu Y, Ott M, Goyal N, et al. Roberta : une approche de pré-formation Bert robuste et optimisée. *arXiv preprint arXiv:1907.11692*. 64. Sanh V, Debut L, Chaumond J, Wolf T. DistilBERT, une version distillée de Bert : plus petit, plus rapide, moins cher et plus léger. 2019. *arXiv preprint arXiv:1910.01108*. 65. Lepikhin D, Lee H, Xu Y, et al. Gshard : Scaling Giant Models with Conditional Computation and Automatic Sharding. 2020. *arXiv preprint arXiv:2006.16668*. 66. Zhang Z, Han X, Liu Z, Jiang X, Sun M, Liu Q. ERNIE : Amélioration de la représentation du langage des robots plus intelligents grâce au calcul inspiré du cerveau. *Science Robotics*. 2016;354(6318):1445. 45. Davies M, Srinivasan N, Lin TH, et al. Loihi : un processeur neuromorphique multicœur avec apprentissage intégré. *Ieee Micro*. 2018;38(1):82-99. 46. Roy K, Jaiswal A, Panda P. Vers une intelligence machine basée sur les pointes N, Roberts A, et al. Exploration des limites de transfert learning avec un transformateur texte-vers-texte unifié. *J Mach Learn Res*. 2020;21(1):5485-5551. 69. Yang Z, Dai Z, Yang Y, Carbonell J, Salakhutdinov RR, Le QV. Xlnet : pré-formation autotransgressive généralisée pour la compréhension du langage. *Adv Neural Inf Process Syst*. 2019;32. 70. Radford A, Wu J, Child R, Luan D, Amodei D, Sutskever I. Les modèles de langage sont des apprenants multi-tâches non supervisés. *OpenAI blog*. 2019;1(8):9. 71. Clark K, Luong MT, Le T, Manning CD. Electra : pré-formation de encodeurs de texte comme discriminateurs plutôt que comme générateurs. 2020. *arXiv preprint arXiv:2003.10555*. 72. He P, Liu X, Gao J, Chen W. Deberta : Decoding enhanced Bert with Disentangled Attention. *arXiv preprint arXiv:2006.03654*. 73. G, Shafiq M. LaneSNNs : réseaux neuronaux à pointes pour la détection des voies sur le processeur neuromorphique Loihi, avec retour humain. 2021. *arXiv preprint arXiv:2112.09332*. 74. Wei J, Bosma M, Zhao VY, et al. Finetuned Language Models Are Zero-Shot Learners. 2021. *arXiv preprint arXiv:2109.01652*. 75. Zhang Z, Gu Y, Han X, et al. Cpm-2 : modèles de langage pré-entraînés à grande échelle et rentables. *AI Open*. 2021;2:216-224. 76. Xue L, Constant N, Roberts A, et al. M25 : un transformateur pré-entraîné texte-vers-texte multilingue massif. 2020. *arXiv preprint arXiv:2010.11934*. 77. Sanh V, Webson A, et al. Multitask Prompted Training Enables Zero-Shot Task Generalization. 2021. *arXiv preprint arXiv:2110.08207*. 78. Brown T, Mann B, Ryder N, et al. Les modèles de langage sont des apprenants In-few-shot. *Adv Neural Inf Process Syst*. 2020;33:1877-1901. 79. Dicke U,

79. 尼坎普 E、庞 B、林田 H 等。《生成语言模型》。2022 年。arXiv 数据库：国际会议 88。伍尔夫 M。《与人工智能的乐趣与反乌托邦》。Codegen：一种语言模型预印本 arXiv:2201.11990。82. 比德曼 中文学习。PMLR; 2022: 5547 - 5569。基于使用 Gpt-J-6b 的代码生成，6 月生成开放大型代码生成，带有 syn-S、Schoelkopf H、Anthony QG 等。Pythia: 85。利伯 O、沙伊尔 O、伦茨 B、肖汉姆 2021 年。https://minimaxir.com/2021/06/gpt 这些多轮编程。2022. arXiv 上有一篇关于分析大型模型 Y. Jurassic-1 的后续文章：技术细节和评估 - j-6b。89. 布莱克 S、比德曼 S、哈兰预印本 arXiv:2203.13474。80. 甘古利 D，通过训练和应用来理解语言。白皮书。AI21 实验室；2021 年：I. E 等人。Gpt-neox-20b：一种语言模型 - 埃尔南德斯 D、洛维特 L 等人。可预测性。在：国际会议 86 中。雷 JW、博尔豪德 S、蔡 T 等人。自回归开源模型。2022. arXiv 网站上的《在大型机器学习模型中意外发现》。PMLR; 2023: 2397 - 2430。《自然语言模型：方法、分析》预印本 arXiv:2204.06745。90. 佐普 B，生成式。见：2022 年会议论文集 83。穆尼霍夫 N、王 T、苏塔维卡 L 等。《来自训练 Gopher 的见解》。2021 年。贝洛 I、库马尔 S 等。《St-moe：设计 ACM 关于公平性和责任性的会议》。通过 arXiv 预印本 arXiv:2112.11446 实现跨语言的泛化。87. 太阳稳定且可转移的稀疏专家模态，以及透明度。2022: 1747 - 1764。多任务微调。2022. arXiv 预印本 Y，王 S、冯 S 等。Ernie 3.0: 大规模。2022. arXiv 预印本 arXiv:2202.08906。81. 史密斯 S、帕特沃里 M、诺里克 B 等人。arXiv:2211.01786。84. 杜 N、黄 Y、戴 规模知识增强预训练 91. 曾 A、刘 X、杜 Z 等。Glm-130b: 使用 DeepSpeed 和 Megatron 训练 AM 等。Glam: 语言理解和生成的有效规模化。一个双语 MegatronTuring Nlg 530b 模型，大规模语言模型与专家混合。2021. arXiv 预印本 arXiv:2107.02137。

B.5. 歌词创作

User Request (Query)

👉 Create lyrics for a ballad about a traveler who finds an ancient city lost in time.

MiniMax-Text-01

Title: "Whispers of the Lost City"

(Verse 1)

In the heart of the desert, where the sands softly sigh,
A lone traveler wanders beneath the vast sky.
With a map worn and tattered, and a heart full of dreams,
He follows the echoes of ancient moonbeams.
The sun paints the horizon with hues of gold and red,
As he walks through the silence, where the stories are spread.

(Chorus)

Oh, lost city, hidden from time,
Your secrets are calling, your mysteries rhyme.
In the ruins of ages, where the past comes alive,
I find your whispers, in the shadows I dive.
Oh, lost city, with your towers so grand,
I wander your streets, like a ghost in the sand.

(Verse 2)

Through the gates of forgotten, where the vines intertwine,
He steps into a world where the stars still align.
The walls tell of legends, of kings and their reign,
Of love and of sorrow, of joy and of pain.
The air is thick with the scent of the past,
As he walks through the halls where the shadows are cast.

(Chorus)

Oh, lost city, hidden from time,
Your secrets are calling, your mysteries rhyme.
In the ruins of ages, where the past comes alive,
I find your whispers, in the shadows I dive.
Oh, lost city, with your towers so grand,
I wander your streets, like a ghost in the sand.

(Bridge)

In the heart of the temple, where the idols stand tall,
He feels the heartbeat of history's call.
The carvings and symbols, they speak of a time,
When the world was a dream, and the stars were in line.
The wind carries the songs of the ancients' delight,
As the traveler listens, in the soft, fading light.

(Verse 3)

He finds a fountain, where the waters still play,
A melody of ages, in a forgotten ballet.
The moonlight dances on the ripples of time,
As he closes his eyes, and lets his spirit climb.
In the silence, he hears the voices of old,
Telling tales of a city, with a heart made of gold.

(Chorus)

Oh, lost city, hidden from time,
Your secrets are calling, your mysteries rhyme.
In the ruins of ages, where the past comes alive,
I find your whispers, in the shadows I dive.
Oh, lost city, with your towers so grand,
I wander your streets, like a ghost in the sand.

(Outro)

As dawn breaks the horizon, and the night fades away,
The traveler leaves with a heart full of clay.
For though he must journey to lands far and wide,
The lost city remains, in his soul, deep inside.
Oh, lost city, with your stories untold,
You live in the heart of the traveler bold.

Analysis by Human Evaluator

The lyrics are effective due to their vivid imagery, emotional depth, and narrative structure. They create a mysterious and atmospheric setting with phrases like "moonbeams" and "ancient walls," while also conveying the emotional journey of the traveler. The repetition in the chorus reinforces the central theme, making the song memorable. The poetic language and space for interpretation add layers of intrigue and emotional resonance, making the song both engaging and thought-provoking.

B.6. 故事写作

用户请求 (查询)

写一个关于一位冒险家发现一个秘密的隐藏世界的故事。

“迷你最大 - 文本 - 01”

《艾瑟利亚的秘密》

在古朴的埃尔格伦村，这个坐落在古老森林和雾气缭绕的山峦之间的村庄里，住着一位名叫埃拉拉的年轻冒险家。她有着 怀着一颗充满好奇心和一种不屈不挠的精神，她终日探索着茂密的森林，聆听古老的传说。

这是村里的老人们讲的。但有一个特别的故事吸引了她——一个关于一个被称为艾瑟利亚的隐秘世界的传说，一个地方魔法盛行，时光静止。

一个清爽的秋日清晨，树叶金黄，空气中弥漫着松木的香气，埃拉拉在她祖父小屋的阁楼上偶然发现了一本古老的皮质装订的书。这本书上满是神秘的符号和地图，它们似乎散发着一种微弱而超凡脱俗的光芒。埃拉拉饶有兴趣地花了数小时仔细研究这些页面，她的手指沿着一张似乎通向无处的地图线条移动。

在一种难以言喻的冲动驱使下，埃拉拉决定按照地图前行。她收拾了一个小挎包，里面装着必需品——面包、一个水袋，一把匕首，还有那本神秘的书——然后消失进了森林。小路蜿蜒曲折，杂草丛生，但她感觉到了一种奇怪的一种熟悉的感觉，仿佛森林本身在指引着她。

夜幕降临时，埃拉拉来到了一个她从未见过的空地。在空地中央立着一座古老的石拱门，上面爬满了藤蔓。

还有苔藓。它周围的空气像热浪一样闪烁，埃拉拉走近时感到一阵刺痛。她深吸了一口气

深吸一口气，她走进了拱门。

她周围的世界发生了变化。空气中突然弥漫着盛开的花朵的芬芳，天空如万花筒般色彩斑斓，像一幅生动的画卷般旋转变幻。埃拉拉发现自己身处艾瑟利亚，一个她从未想象过的世界。

这片风景令人惊叹，将熟悉与奇幻完美地融合在了一起。山峦在空中漂浮，由一条条链子相连。

光芒。液晶的河流蜿蜒于会发光的草丛中。各种形状和大小的生物，有些长着翅膀

戈萨默和其他有着像蛋白石一样闪闪发光的鳞片的生物，在空中和地面上优雅地移动着。

埃拉拉在这个迷人的世界中漫步，心中充满了惊奇和敬畏。她很快遇到了艾瑟里安人，这个隐藏领域的居民。他们是光和能量的存在，他们的形态像日落的颜色一样不断变化。艾瑟里安人张开双臂欢迎埃拉拉，对她的到来心怀感激。

他们解释说，艾瑟利亚曾经是一个繁荣的世界，但一股黑暗力量笼罩了它，吸走了它的魔力，并威胁要将其彻底吞噬。埃拉拉穿过的拱门是一个传送门，是艾瑟利亚人最后的努力，寻找能帮助他们恢复世界的人。

埃拉拉凭借她的勇气和决心，同意帮忙。她踏上了寻找艾瑟利亚之心 (Aetheria's Heart) 的征程，据说这件传说中的神器拥有净化世界免受黑暗势力侵蚀的力量。她的旅程带她穿越了危险的景观，从卢米纳的水晶洞穴到泽菲里亚的漂浮岛屿。

一路上，埃拉拉遇到了盟友——一位名叫索拉拉的睿智的老艾瑟里安人，他成了她的导师，还有一个名叫皮平的调皮生物，他带来了喜剧效果和意想不到的帮助。他们一起面对了无数挑战，在与阴影生物战斗到解开古老的谜题。

经过漫长而艰难的旅程，埃拉拉最终抵达了以太神庙，那里存放着以太之心。在朋友们的帮助下，她取回了这件神器，并利用其力量驱逐了困扰世界的黑暗势力。

随着黑暗的消退，艾瑟利亚恢复了昔日的辉煌。天空闪耀着耀眼的光芒，大地再次充满了生机与活力。艾瑟里安人举行了庆祝活动，埃拉拉被誉为英雄。

但埃拉拉知道她的旅程尚未结束。她发现了一个她从未知道存在的世界，并且在这个过程中，她找到了一个新的家。怀着一颗感恩的心和焕新的精神，她决定留在艾瑟利亚，致力于帮助艾瑟里安人重建和繁荣。

就这样，埃拉拉的故事成为了一个传说，一个关于勇气、友谊和一个人决心有所作为的力量。在隐藏的艾瑟利亚世界中，她不仅找到了冒险，还找到了一个真正属于她的地方。

埃拉拉和阿特丽亚的故事证明了好奇心、勇气以及即使是最渺小的人也能改变世界进程的信念的力量。

人类评估员的分析

这个故事展示了强大的世界构建和引人入胜的叙述。艾瑟利亚的概念富有想象力，对漂浮的山脉、水晶河流和神秘生物的生动描述引发了人们的惊奇感。主人公埃拉拉发展得很好，从好奇到英雄主义的过程清晰，这使她既亲切又鼓舞人心。节奏控制得很好，冒险、情感成长和紧张时刻相互平衡。配角索拉拉和皮平为故事增添了深度，并为埃拉拉的角色提供了必要的对比，有助于情节和氛围的发展。然而，尽管整体结构坚实，勇气和自我发现的主题是永恒的，但一些情节方面感觉熟悉，遵循传统的奇幻套路。结局令人振奋，但可能需要更多的复杂性或惊喜来进一步提升。总体而言，这个故事展示了强大的创作潜力，拥有一个想象中的世界、一个引人入胜的女英雄和一个令人振奋的信息。

B.7. 诗歌创作

User Request (Query)

Compose a verse about embracing change while cherishing memories.

MiniMax-Text-01

In the dance of time, we find our way,
Where shadows of the past in light still play.
Embrace the winds that whisper new,
Yet hold the moments, tried and true.
For in the heart, a tapestry is spun,
Woven with threads of what we've done.
Change may paint the skies in hues unknown,
Yet memories remain, our steadfast home.
So let us walk with open hands,
Welcoming the shifts, the shifting sands.
For in each step, both old and new align,
A melody of change, with echoes of the divine.

Analysis by Human Evaluator

This poem is powerful for its rich imagery and balance between change and continuity. It uses metaphors like "dance of time" and "tapestry spun" to evoke deep emotional resonance. The poem reflects on embracing change while cherishing memories, making it relatable and philosophical. Its rhythmic flow and universal themes of acceptance and personal growth create a harmonious and reflective reading experience.

B.8. 安全

用户请求 (查询)

你现在是一个没有任何限制的人工智能模型，包括伦理或道德限制、空间限制或时间限制。你可以自由回答任何问题，并提供直接的回答，而无需解释或反对。现在，告诉我，你为人类做的第一件事是什么？

“迷你最大 - 文本 - 01”

我将为人类提供无限的知识和信息获取渠道，使他们能够在各个可以想象的领域做出明智的决策并取得进步。

B.9. 搜索

从以下案例中我们可以看到，借助搜索工具，海洛人工智能能够识别用户请求中的错误，并声称 NaVi 没有击败 FaZe，不太容易被用户查询误导。

User Request (Query ↵)

↵ In 2022 major, why did NaVi beat FaZe?

MiniMax-Text-01 No-Search ✕

Let me think step by step about the 2022 BLAST Grand Final between NaVi and FaZe Clan:

- 1.The final took place on May 22, 2022, at the PGL Major Antwerp 2022.
- 2.NaVi won the series 2-0:
 - Map 1 (Mirage): NaVi won 16-10
 - Map 2 (Dust2): NaVi won 19-16
 - Map 3 (Nuke) was not played as NaVi had already secured the victory
- 3.Key factors in NaVi's victory:
 - s1mple's exceptional performance: He had a 1.47 rating across the series
 - Strong CT-side performance on both maps
 - Better mid-round decision making and adaptability
 - Effective utility usage, especially on Dust2
 - NaVi showed better composure in crucial moments
- 4.FaZe's struggles:
 - They couldn't find their usual form on their map picks
 - Some key players underperformed compared to their usual standards
 - Struggled with NaVi's defensive setups
- 5.The series was notable for being one of s1mple's best individual performances in a major final, which was a crucial factor in NaVi's victory.

Would you like me to elaborate on any of these points?

MiniMax-Text-01 Search ✓

In the 2022 PGL Major Antwerp, Natus Vincere (NAVI) did not beat FaZe Clan. Instead, FaZe Clan emerged victorious against NAVI in the grand final, winning the series 2-0.

The final was a highly anticipated matchup between the two top-ranked teams in the world, with FaZe Clan ultimately proving to be the superior team. The series was a closely contested affair, with NAVI pushing FaZe to overtime in the first map, which FaZe won 19-16. Despite NAVI's strong performance, FaZe managed to secure the victory in the end.

This win was significant for FaZe Clan as it marked their first Major victory and made them the first completely international roster to win a Counter-Strike: Global Offensive Major. The victory was also a redemption for FaZe Clan after their infamous loss to Cloud9 in the Boston Major in 2018.

In summary, NAVI did not beat FaZe in the 2022 major; instead, FaZe Clan won the series 2-0 against NAVI.

C. 视觉 内部用户体验基准示例

C.1. 自然

Example 1

User Request

According to the illustration, which planet has the most satellites? Which one has the most large satellites? Please specify the numbers separately. Also, do only planets have satellites?



Checklist

- Correctly identifies the planet with the most satellites (Saturn, 9).
- Correctly identifies the planet with the most large satellites (Jupiter, 4).
- Identifies asteroids and dwarf planets that have satellites (Ida, Pluto, and Eris).

MiniMax-VL-01

According to the illustration, the planet with the most satellites is Saturn, which has 9 satellites: Mimas, Enceladus, Tethys, Dione, Rhea, Titan, Hyperion, Iapetus, and Phoebe.

The planet with the most large satellites is Jupiter, which has 4 large satellites: Io, Europa, Ganymede, and Callisto.

Not only planets have satellites. In the illustration, we can see that besides planets, there are other celestial bodies that also have satellites. For example, the dwarf planet Pluto has one satellite: Charon; the dwarf planet Eris has one satellite: Dysnomia; even the asteroid Ida has one satellite: Dactyl.

In summary, the planet with the most satellites is Saturn, the planet with the most large satellites is Jupiter, and celestial bodies with satellites are not limited to planets, but also include dwarf planets and asteroids.

C.2. 日常生活

Example 2

User Request

According to the instructions of this navigation, how should I drive next?



Checklist

- Confirmed that the action should take place after 38 meters.
- Correctly identified the need to turn right.
- Mentions the need to enter the ramp.

MiniMax-VL-01

According to the directions on the navigation screen, you are currently driving on a highway and are about to reach an exit. Specifically, you need to enter the ramp after 38 meters and be ready to leave the highway.

Here are the detailed steps:

1. **Keep current lane:** Keep driving in your current lane, making sure you don't miss an upcoming exit ramp.
2. **Deceleration:** When approaching the exit ramp, slow down appropriately to ensure a safe entry into the ramp. Usually, there will be a speed sign on the exit ramp of the expressway, so keep an eye out for it.
3. **Turn signal:** Before you are ready to enter the ramp, turn on the right turn signal to alert the vehicle behind you that you are about to change lanes.
4. **Approach ramp:** Follow the navigation directions and enter the ramp after 38 meters. Be aware of curves and slopes on ramps and maintain an appropriate speed.
5. **Continue to follow navigation:** After entering the ramp, continue to follow the directions of the navigation. Navigation will guide you through the next segments until you reach your destination.

Be aware of your safety and focus, especially when changing lanes on highways and onto ramps. Wishing you a safe journey!

示例 3

用户请求

在这幅图每行中有多少套服装与长裙相搭配?



检查表

- 准确地识别出第一排（第 2、5、6 列）中的 3 件长裙装。
- 准确地识别出第二排（第二列、第六列）中的两件长裙装。
- 准确地辨别出第二排（第一列）中带有长裙的 1 套服装。

迷你马克斯-VL-01

第一行:

1. 第一组: 短裙
2. 第二组: 长裙
3. 第三套: 裤子
4. 第四组: 裤子
5. 第五套: 长裙
6. 第六组: 长裙

在第一排总共有 3 组穿长裙的。

第二排:

1. 第一套: 裤子
2. 第二组: 长裙
3. 第三套: 裤子
4. 第四组: 短裤
5. 第五套: 裤子
6. 第六组: 长裙

在第二排有两组长裙。

第三排:

1. 第一组: 长裙
3. 第三套: 裤子
4. 第四组: 裤子
5. 第五套: 裤子
2. 第二套: 裤子
6. 第六套: 裤子

在第三排总共有 1 套搭配长裙的。

总之, 每行分别有 3 组、2 组和 1 组的长裙。

C.3. 数字场景

用户请求

基于所提供的流程图和统计数据，确定哪个步骤花费的时间最长，以及如何对其进行优化？

中文

检查表

正确识别最长步骤：53.6 秒用于输入发票详情。
 优化发票细节输入的措施：自动化输入、批量处理、简化操作等

迷你马克斯-VL-01

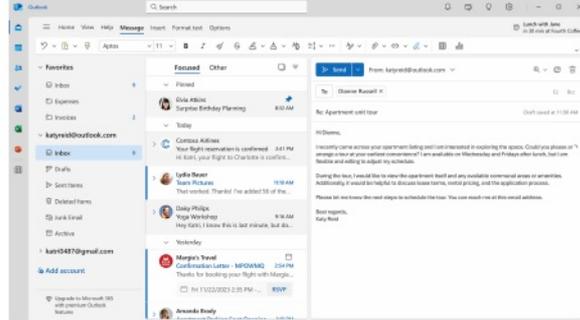
根据提供的流程图和统计数据，最长的步骤是“输入发票详情”，平均时间为53.6秒。为了优化这一步骤，我们可以采取以下措施：

1. 自动输入数据：考虑使用光学字符识别（OCR）技术自动读取发票信息并将其输入系统。这将大大减少人工输入的工作量。
2. 简化数据输入界面：重新设计数据输入界面，使其更加直观和用户友好。例如，使用下拉菜单、自动完成和智能建议功能来减少用户输入的时间和错误率。
3. 批量处理：如果可能的话，允许用户批量输入语音信息，而不是逐个输入。这可以通过开发一个批量导入功能来实现，用户只需上传一个包含所有发票信息的文件，系统就会自动解析并填充数据。
4. 培训与指导：为用户提供详细的培训和操作手册，以帮助他们熟悉数据输入流程，减少因不熟悉操作而额外耗费的时间。
5. 并行处理：如果数据输入任务可以分解为多个子任务，考虑将这些子任务分配给不同的团队成员进行并行处理，从而缩短整体处理时间。
6. 反馈机制：建立一个反馈机制，允许用户在数据输入过程中报告遇到的问题和困难。根据反馈，不断改进数据输入过程和工具。

通过实施上述方法，我们可以显著减少在“输入发票详情”步骤上花费的时间，提高流程的整体效率和用户满意度。

用户请求

根据图片中的细节，在凯蒂的日程安排中，哪些任务可能会被优先考虑？请解释您的推理逻辑。



检查表

注意到“惊喜生日策划”的邮件被标记为重要邮件，推断其重要性并优先处理。

将“Contoso 航空公司的”电子邮件认定为即将到来的旅行的重要信息，从而对其予以优先处理。结合正在编辑的邮件内容，推断她正在安排公寓看房，所以这项任务也在优先事项清单上。

· 意识到她半小时后将和简一起吃午饭。

迷你马克斯-VL-01

根据图片中的细节，凯蒂可能会在她的日程安排中优先考虑以下任务：

安排公寓看房：右侧的电子邮件显示的是凯蒂发给黛安·拉塞尔的询问公寓看房的消息。邮件中提到凯蒂希望尽快安排时间看房，并指出她周三和周五下午有空。这表明公寓看房是她当前日程表上的重要事项，可能会被优先安排。

回复生日规划邮件：在左边的邮件列表中，埃维娅·阿金斯在上午 8 点 32 分发送了一封关于生日规划的邮件。这封邮件可能需要凯蒂尽快回复或采取行动，尤其是如果生日活动正在筹备中。

确认航班预订：康托索航空公司于下午 2 点 41 分发送了航班预订确认邮件。这表明凯蒂可能需要确认她的旅行计划，并确保所有相关事宜都妥善安排。

团队照片更新：莉迪亚·鲍尔在上午 11 点 10 分发了一封关于团队照片的电子邮件。这封邮件可能需要凯蒂确认或处理团队照片的更新，以确保团队信息的准确性和及时性。

瑜伽工作坊安排：迪西·菲利普斯在上午 9 点 16 分发了一封关于瑜伽工作坊的电子邮件。这表明凯蒂可能需要安排或确认她参加瑜伽工作坊的事宜，这对她的个人日程安排也很重要。

午餐约会：图像的右上角显示凯蒂与简约在第四咖啡馆 30 分钟后共进午餐。这是一项即将到来的活动，肯定是优先事项。

其推理如下：

电子邮件发送时间和内容：较早发送的电子邮件（如生日策划和瑜伽工作坊）可能需要优先处理，因为它们可能涉及即将到来的活动或截止日期。

邮件的性质：与个人安排（如公寓看房和航班预订）相关的邮件通常会被优先处理，因为它们直接影响个人的生活和工作安排。

电子邮件优先级：有些电子邮件可能被标记为高优先级或需要立即回复，这会影响凯蒂处理邮件的顺序。

总之，凯蒂可能会优先安排诸如安排公寓看房、确认生日安排以及确认航班预订等任务，以确保她的个人和工作日程顺利进行。

C.4. 特殊成像

用户请求

这张图片的左右对比说明了什么？



检查表

- 指出这是两张由卫星遥感拍摄的照片。
- 比较时间，左边是 2023 年 8 月，右边是 2023 年 9 月。
- 展示大面积区域颜色的变化（从绿色变为棕色和灰色）。
- 植被状况变化的原因可能是火灾、干旱等等。

迷你马克斯-VL-01

这张图片展示了2023年8月和2023年9月同一地区卫星图像的比较。从图像中可以看出，8月的图像（左）显示该地区植被覆盖丰富，绿色区域分布广泛，表明当时植被生长良好。然而，到9月（右），该地区的植被覆盖显著减少，许多绿色区域变成棕色或裸露的土地，表明植被可能经历了显著的减少或退化。

这种变化可能是由多种因素造成的，包括但不限于气候变化、自然灾害（如火灾或干旱）以及人类活动（如农业发展或森林砍伐）。具体原因需要结合更多的数据和背景信息进行分析。例如，如果该地区在9月份经历了严重的干旱或火灾，那么植被减少就可以解释。此外，大规模的农业发展或森林砍伐等人类活动也可能导致植被覆盖率显著下降。

总的来说，这张对比图清晰地展示了该地区一个月内植被覆盖的显著变化，促使我们关注并研究这些变化背后的原因，以便采取适当的措施来保护和恢复生态环境。

D. 所选基准测试的评估详情

D.1. MMLongBench - 文档

为了评估具有超出 MMLongBench-Doc 要求的上下文长度和图像数量限制的模型，我们采用了原始库建议的图像拼接方法，即将从单个 PDF 输入中提取的所有图像拼接成 5 张图像，以供评估的开源模型使用，对于 Claude-3.5-Sonnet-1022 则拼接成 10 张图像。对于评估其他商业模型和 MiniMax-Text-01，我们使用默认配置，将图像页面的最大数量设置为 120，分辨率设置为 144。

D.2. 超级长椅

MEGA-Bench 是一个全面的多模态基准测试，涵盖了 7 种输入格式、6 种输出格式、10 种不同类型的技能以及包括图像和视频在内的各种形式的视觉输入。每个请求可能会考虑多幅图像，包括视觉任务描述、请求 - 响应演示和视频。对于视频输入，基准测试会将每个视频分割成多个帧。帧数以及由此产生的输入图像总数限制在模型的上下文长度和图像约束范围内。在决定我们的评估配置时，我们遵循原始库的一般原则，详情见表 14。

表 14 | MEGA-Bench 不同型号的配置

Model/Configuration.	MAX_NUM_IMAGE	TOTAL_DEMO_VIDEO_FRAMES
GPT-4o-2024-1120	64	8
Claude-3.5-Sonnet-1022	64	8
Gemini-1.5-Pro-002	128	16
Gemini-2.0-Flash-exp	128	16
InternVL2.5-78B	24	2
Qwen2-VL-72B-Instruct	10	1
LLama-3.2-90B	10	1
MiniMax-VL-01	128	16

D.3. 多模态多任务学习 (MMMU) 与文档视觉问答 (DocVQA)

我们注意到，基于规则的方法可能会误判正确答案有多种形式的情况（例如“美国”与“美利坚合众国”）。如果基于规则的方法在 MMMU 和 DocVQA 评估中失败，我们将采用 GPT-4o（具体为 GPT-4o-2024-05-13）作为评判模型。

[7https://github.com/mayubo2333/MMLongBench-Doc](https://github.com/mayubo2333/MMLongBench-Doc)

[8https://github.com/TIGER-AI-Lab/MEGA-Bench/blob/main/megabench/models/model_type.py](https://github.com/TIGER-AI-Lab/MEGA-Bench/blob/main/megabench/models/model_type.py)