

DeepSeek内部研讨系列

DeepSeek与AIGC应用

AI肖睿团队

(孙萍、周嵘、李娜、张惠军、刘誉)

2025年2月20日



- 北大青鸟人工智能研究院
- 北大计算机学院元宇宙技术研究所
- 北大教育学院学习科学实验室



1. 本次讲座为DeepSeek原理和应用系列研讨的讲座之一，主要介绍DeepSeek的基本概念，以及大模型技术和AIGC工具应用，不需要大家具备专业的AI或IT技术背景。
2. 本次讲座首先分析当前备受瞩目的DeepSeek-R1 的概念、优势和历史地位。然后进一步探讨大模型和AIGC的底层工作机制，旨在帮助读者突破工具应用的局限，理解DeepSeek和AIGC的深层次价值。最后，介绍如何科学选择与高效使用 AI 工具，为大家提供更具深度与实用性的应用场景的指导，给听众带来更落地的AI应用价值。
3. 尽管 DeepSeek-R1 以其低成本和开源策略为行业带来变革，但当前网络上的大量相关内容仅停留在工具应用层面，易对初级AI应用人员造成概念和思维方式的误导，这也是本次讲座希望解决的问题。



北京大学
PEKING UNIVERSITY



目录

CONTENTS

- 01 详解DeepSeek R1
- 02 AIGC的概念和应用
- 03 AIGC的能力揭秘
- 04 选择AIGC工具



PART 01 ▶

详解DeepSeek-R1

简介



本部分介绍了DeepSeek-R1模型的技术特性、发展历程、应用场景及其在AIGC领域的定位。

首先介绍人工智能的发展历程，以及大模型相关术语，并对比DeepSeek-R1与其他模型的性能表现。DeepSeek-R1以其低成本、开源策略和卓越的推理能力脱颖而出，尤其在复杂逻辑推理、数学和编程任务中表现优异。

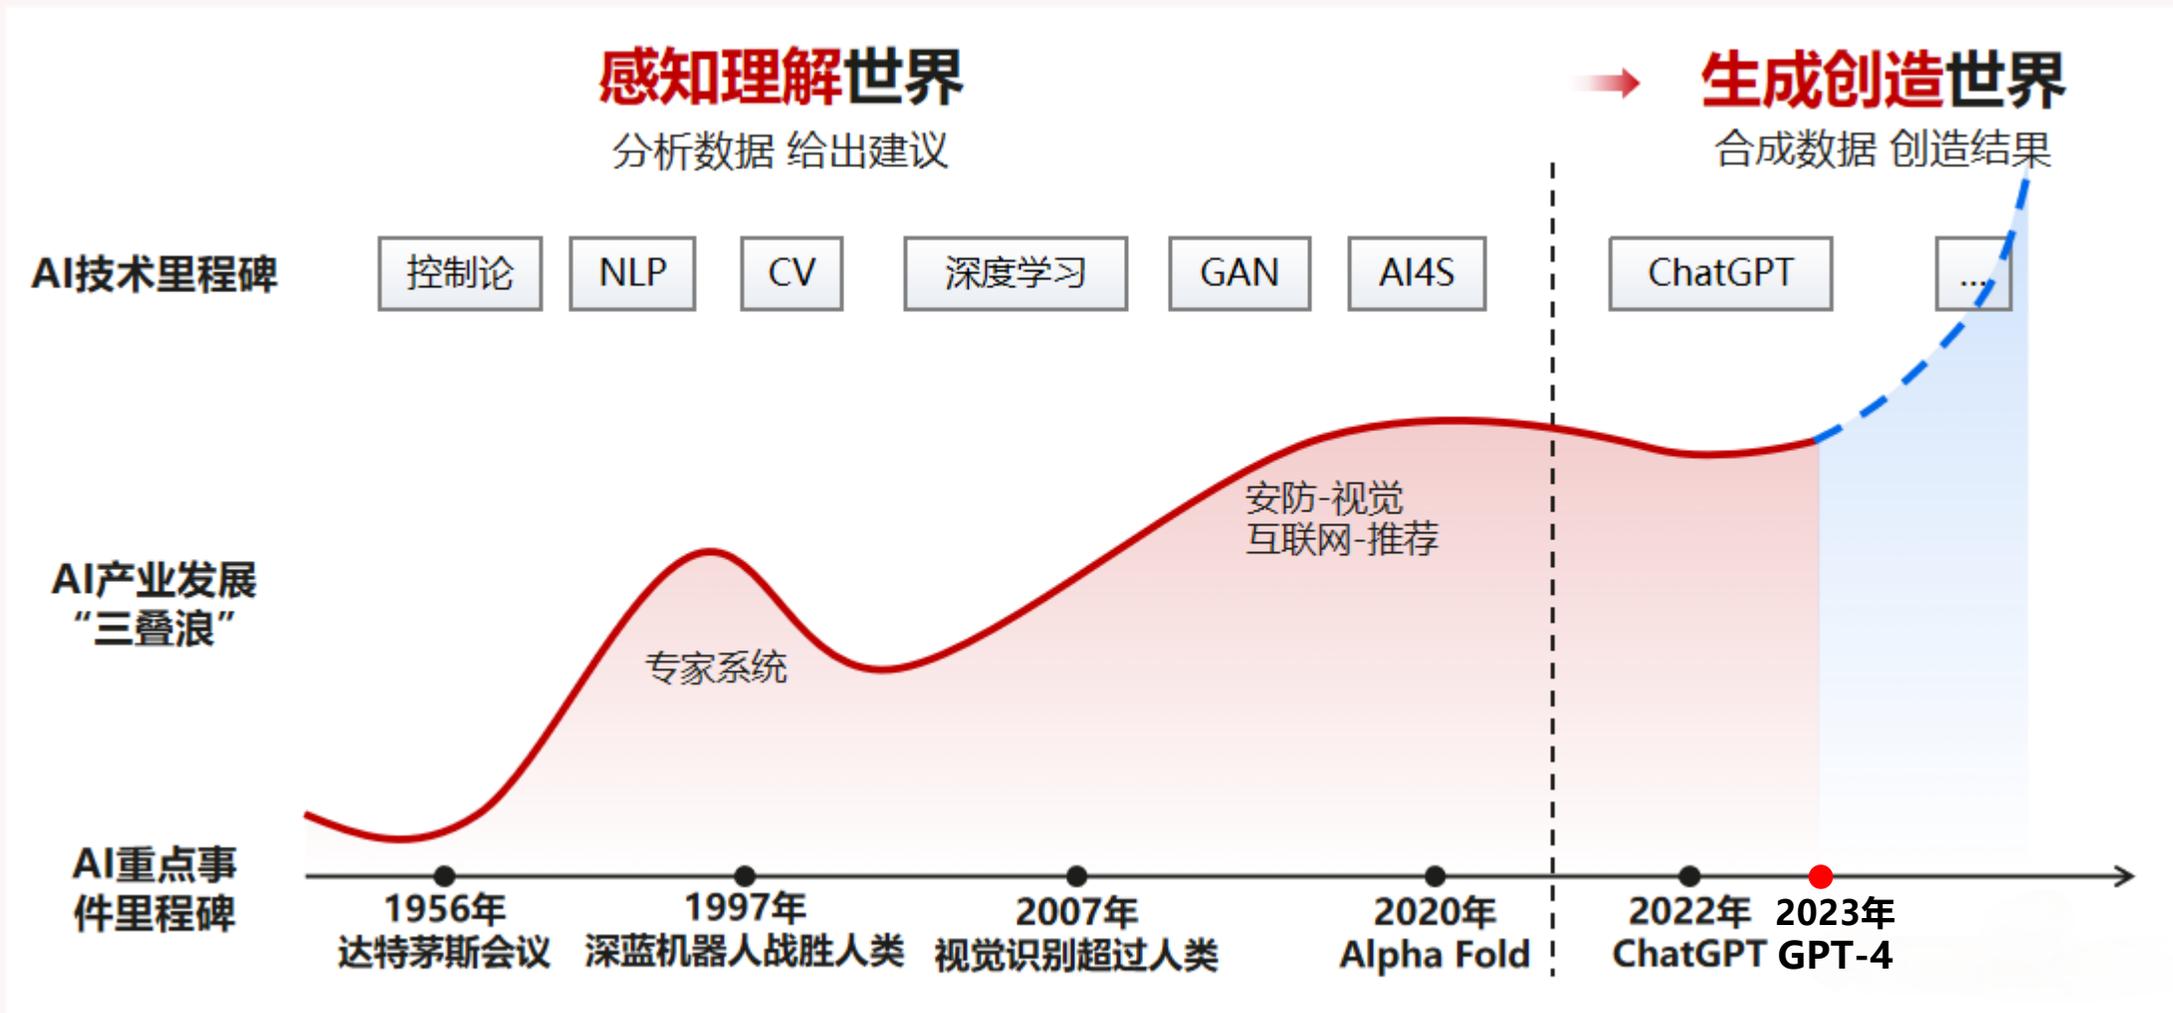
随后介绍DeepSeek公司的背景、市场定位以及DeepSeek-R1的技术原理和应用场景，揭示了其在推理密集型任务、教育、科研、知识应用和文档分析等领域的独特优势，并列举接入该模型的第三方应用。

通过对人工智能发展历史以及DeepSeek-R1的介绍和分析，本部分旨在为听众提供一个对DeepSeek的客观、全面的认识，并理解该模型在AIGC领域的重要地位和应用潜力。


人工智能发展历程



北京大学
PEKING UNIVERSITY



AIGC的发展历程



大模型相关术语

- 多模态

- 文本、图片、音频、视频

- AI工具 (国内)

- DeepSeek、豆包、Kimi、腾讯元宝、智谱清言、通义千问、秘塔搜索、微信搜索...

- 通用模型

- 大语言模型 (LLM, Large Language Model)
- 视频模型
- 多模态模型
-

- 行业模型 (垂直模型、垂类模型)

- 教育、医疗、金融等

文本	通用闭源	文心一言, 通义千问, 腾讯混元, 商汤日日新, BlueLM, 360智脑, 天工, MiLM, 中科闻歌, 紫东太初, 润用科技, 字节豆包, Kimi.ai, MINIMAX, 盘古大模型, 云从科技, openbayes, Trans千神											
	通用开源	智谱·AI, 零一万物, Baichuan2, RWKV-LM, TeleChat2-35B, 书生·浦语, Qwen2.5, deepseek coder, GLM-4, MiniCPM, Yi, Baichuan2, RWKV-LM, TeleChat2-35B, 书生·浦语											
多模态	推理	QWQ-32B-Preview, DeepSeek-R1-Lite, InternThinker, K0-math, Skywork o1, 360gpt2-o1, LLaVA-CoT											
	实时交互	星火极速, 智谱清言, 海螺AI, 豆包, 文小言, 通义APP, 日日新, Kimi											
	文生视频	可灵AI, 即梦AI, 清制, Vidu, PixVerse, 海螺AI, HiDream.ai, 通义万相											
	视觉理解	腾讯混元, 阶跃星辰, Qwen2-VL, Doubao-vision, SenseChat-Vision, 海螺AI, GLM-4v, 书生·万相											
行业	文生图	即梦AI, 混元-DIT, 快手可图, CogView, 讯飞星火, meitu, 通义万相, 文心一格											
	部分领域	<table border="1"> <tr> <td>医疗</td> <td>汽车</td> <td>教育</td> <td>金融</td> <td>工业</td> <td>更多行业</td> </tr> <tr> <td>百度灵医, 医联MedGPT, 百川AI全科医生, 讯飞陆医</td> <td>理想 MindGPT, DriveGPT, 极氪Kr大模型, 易车大模型</td> <td>MathGPT, 作业帮, 子曰</td> <td>蚂蚁金融大模型, 妙想金融大模型, 轩辕大模型, HithinkGPT</td> <td>奇智孔明AlInno-15B, 华为盘古工业大模型, SmartMore SMore LrMo, 羚羊工业大模型</td> <td>营销: 探迹SalesGPT, 文化: 阅文集团妙笔大模型, 法律: Chat Law, AI4S: DP深势分子大模型</td> </tr> </table>	医疗	汽车	教育	金融	工业	更多行业	百度灵医, 医联MedGPT, 百川AI全科医生, 讯飞陆医	理想 MindGPT, DriveGPT, 极氪Kr大模型, 易车大模型	MathGPT, 作业帮, 子曰	蚂蚁金融大模型, 妙想金融大模型, 轩辕大模型, HithinkGPT	奇智孔明AlInno-15B, 华为盘古工业大模型, SmartMore SMore LrMo, 羚羊工业大模型
医疗	汽车	教育	金融	工业	更多行业								
百度灵医, 医联MedGPT, 百川AI全科医生, 讯飞陆医	理想 MindGPT, DriveGPT, 极氪Kr大模型, 易车大模型	MathGPT, 作业帮, 子曰	蚂蚁金融大模型, 妙想金融大模型, 轩辕大模型, HithinkGPT	奇智孔明AlInno-15B, 华为盘古工业大模型, SmartMore SMore LrMo, 羚羊工业大模型	营销: 探迹SalesGPT, 文化: 阅文集团妙笔大模型, 法律: Chat Law, AI4S: DP深势分子大模型								

大模型的关键发展

关键进展



准备期

- **ChatGPT发布**, 全球范围内迅速形成大模型共识。
- **GPT4发布**, 进一步掀起大模型研发热潮。
- **国内快速跟进大模型研发**。文心一言1.0、通义千问、讯飞星火、360智脑、ChatGLM等首批模型相继发布。

跃进期

- **Llama2开源**, 极大助力全球大模型开发者生态。
- **GPT-4 Turbo、Gemini**等海外大模型发布, 持续提升模型性能。
- **Midjourney发布5.2**
Stable Diffusion XL发布
- **国内闭源大模型快速发展**。豆包、混元、商量3.0、盘古3.0、AndesGPT、BlueLM、星火3.0、Kimi Chat等陆续发布。
- **国内开源生态爆发**。Baichuan、Qwen、InternLM、ChatGLM3、Yi-34B等系列模型引领开源热潮。

繁荣期

- **OpenAI发布Sora**, 极大拓展了AI在视频领域的想象力。
- **GPT-4o、Claude 3.5、Gemini1.5、Llama3**发布, 海外进入“一超多强”的竞争格局。
- **国内多模态领域进展迅速, 在部分领域领先海外**。视频生成模型可灵AI、海螺视频、Vidu、PixVerse等模型陆续发布, 并在海外取得较大应用进展。
- **国内通用模型持续提升**。Qwen2.5、文心4.0、GLM4、商量5.5等通用模型陆续更新。

深化期

- **OpenAI发布o1**, 强化学习新范式, 实现推理等复杂能力上的重大突破。
- **Claude3.5-Sonnet发布**, 在代码和Agent能力上掀起效率革命。
- **ChatGPT上线实时视频能力**, 深入语音视觉实时多模态应用场景。
- **国内推理模型迅速跟进**。DeepSeek-R1、QwQ-32B-Preview、Kimi-k1.5、GLM-Zero、Skywork-o1、Step R-mini、讯飞星火X1等模型密集发布。
- **国内模型性能持续提升**。DeepSeek-V3、Qwen2.5、豆包-Pro、混元-Turbo与GLM-4-Plus等系列模型综合能力上持续提升。

2022.12

2023.06

2023.12

2024.06

2025.01

时间

生成模型



推理模型

生成模型与推理大模型的对比

比较项	GPT-4o (生成模型)	DeepSeek-R1 (推理模型)
模型定位	专注于通用自然语言处理和多模态能力，适合日常对话、内容生成、翻译以及图文、音频、视频等信息处理、生成、对话等。	侧重于复杂推理与逻辑能力，擅长数学、编程和自然语言推理任务，适合高难度问题求解和专业领域应用，在中文表达上容易出彩。
推理能力	在日常语言任务中表现均衡，但在复杂逻辑推理（如数学题求解）上准确率较低。	在复杂推理任务表现卓越，尤其擅长数学、代码推理任务，在部分基准测试（如 GPQA）中准确率高于 GPT-4o。
多模态支持	支持文本、图像、音频乃至视频输入，可处理多种模态信息。	当前主要支持文本输入，不具备图像处理等多模态能力。
应用场景	适合广泛通用任务，如对话、内容生成、多模态信息处理以及多种语言相互翻译和交流；面向大众市场和商业应用。	适合需要高精度推理和逻辑分析的专业任务，如数学竞赛、编程问题和科学研究；在思路清晰度要求高的场景具有明显优势，比如采访大纲、方案梳理；在对中文语言表达和情感表达方面有明显优势。
用户交互体验	提供流畅的实时对话体验，支持多种输入模态；用户界面友好，适合大众使用。	可展示大部分链式思考过程，便于专业用户理解推理过程；界面和使用体验具有较高的定制性，但整体交互节奏较慢。

推理模型的优劣势

优势	劣势
- 演绎或归纳等推理能力强（如谜题、数学证明）	- 响应速度慢且计算成本高（需要更多推理时间）
- 链式思维推理出色（善于分解多步骤问题）	- 基于知识的任务更容易出错（容易产生幻觉）
- 擅长复杂决策任务	- 处理简单任务的时候效率低（容易"过度思考"）
- 可以呈现思考过程	

DeepSeek R1

OpenAI o1

OpenAI o3-mini

Gemini 2.0

Grok3

Kimi 1.5

火爆全网的DeepSeek-R1

当地时间1月27日，受中国人工智能初创公司——深度求索公司（DeepSeek）冲击，美国人工智能主题股票遭抛售，美国芯片巨头英伟达（NVIDIA）股价历史性暴跌，纳斯达克综合指数大幅下跌。

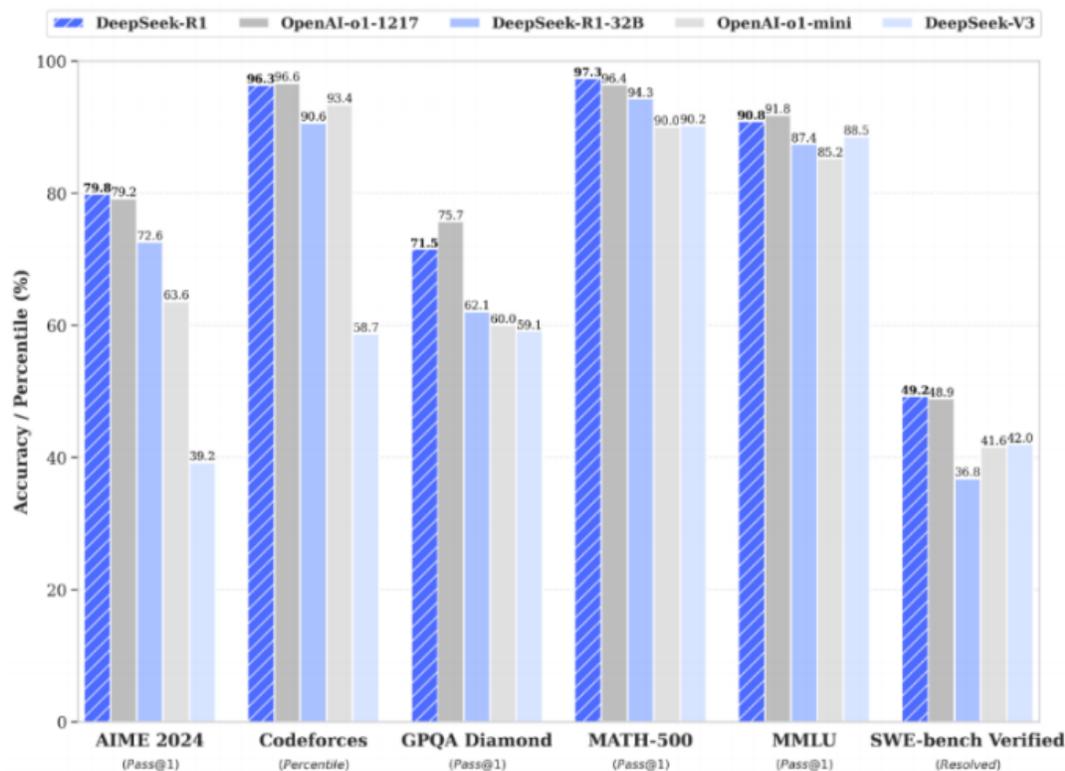


据介绍，R1模型在技术上实现了重要突破——用纯深度学习方法让AI自发涌现出推理能力，在数学、代码、自然语言推理等任务上，性能比肩OpenAI的o1模型正式版，且训练成本仅为560万美元，远低于美国科技巨头的数亿美元乃至数十亿美元投入。



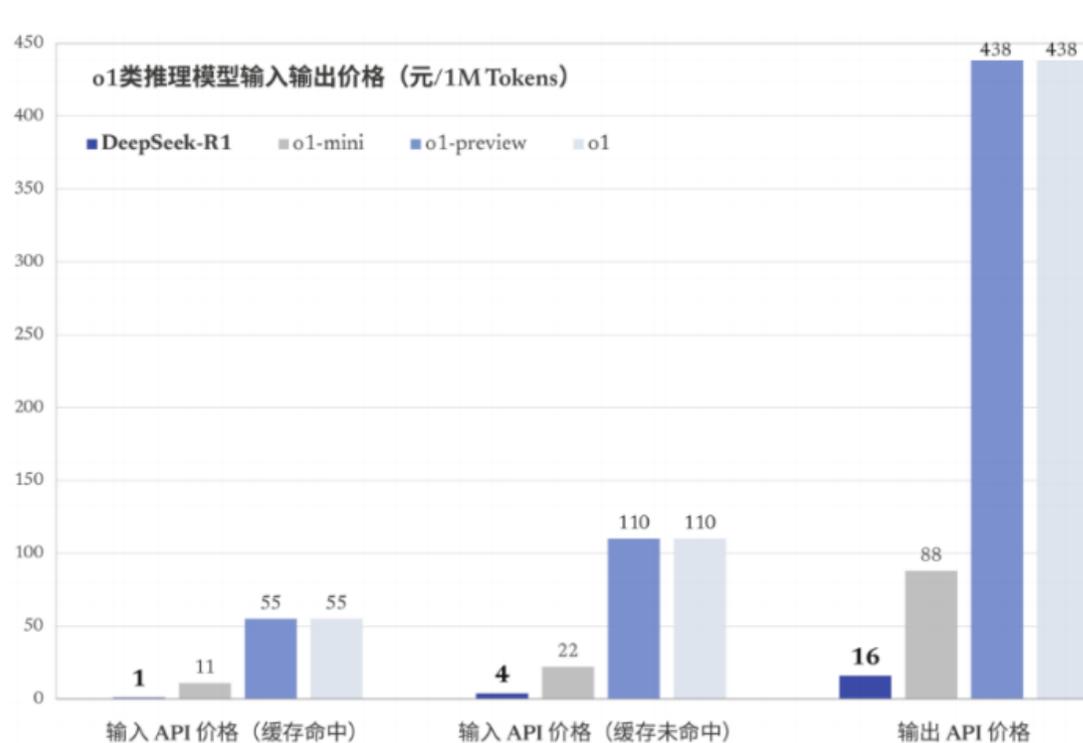
爆火原因

图2: DeepSeek 性能对齐 OpenAI-o1 正式版



资料来源: DeepSeek 官网, 中国银河证券研究院

图3: 推理成本低至每百万 Token 0.14 美元



资料来源: DeepSeek 官网, 中国银河证券研究院

- DeepSeek-R1的推理能力进入了第一梯队 (媲美OpenAI o1), 但训练和推理成本低、速度快、全部开源
- DeepSeek打破了硅谷传统的“堆算力、拼资本”的大模型发展路径

对AI行业的重大影响

01

打破垄断

DeepSeek-R1以低成本和开源特性打破以往头部企业巨头割据局面

02

价格下调

DeepSeek-R1的API定价仅为行业均价的1/10,推动了中小型企业低成本接入AI,对行业产生了积极影响

03

推动创新

DeepSeek-R1促使行业开始从“唯规模论”转向更加注重“性价比”和“高效能”方向

公司成立背景与发展历程

DeepSeek, 全称杭州深度求索人工智能基础技术研究有限公司, 成立于2023年7月17日, 是一家创新型科技企业, 专注于人工智能基础技术的研究与开发

大语言模型(LLM)的创新应用

DeepSeek专注于开发先进的大语言模型(LLM)和相关技术, 旨在通过这些技术推动人工智能在多个领域的应用和创新

投资者背景与市场定位

作为由知名私募巨头幻方量化孕育而生的公司, DeepSeek获得了强大的资金支持和行业影响力, 幻方量化与九坤投资、明汭投资、灵均投资并称量化私募领域的“四大天王”, 管理资金规模均超过600亿元。这为DeepSeek提供了清晰的市场定位和投资者背景

里程碑

2025年1月20日推出DeepSeek-R1推理模型

DeepSeek产品信息官方渠道

🔥 DeepSeek-R1 已发布并开源，性能对标 OpenAI o1 正式版，在网页端、APP 和 API 全面上线，点击查看详情。



探索未至之境

开始对话
免费与 DeepSeek-V3 对话
使用全新旗舰模型

获取手机 App
DeepSeek 官方推出的免费 AI 助手
搜索写作阅读解题翻译工具

官网: www.deepseek.com



我是 DeepSeek, 很高兴见到你!

我可以帮你写代码、读文件、写作各种创意内容, 请把你的任务交给我吧~

给 DeepSeek 发送消息

深度思考 (R1) 联网搜索

对话: chat.deepseek.com



DeepSeek-R1 发布, 性能对标 OpenAI o1 正式版

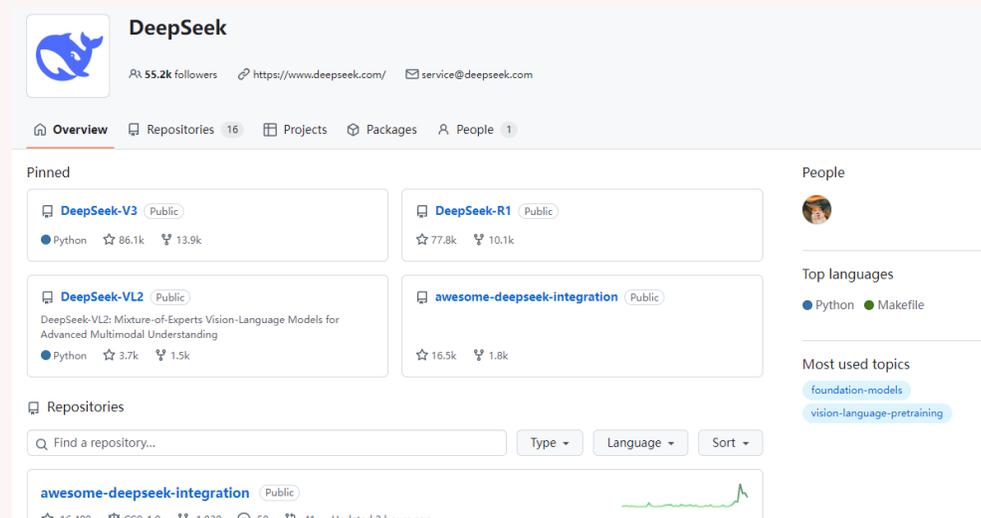
今天, 我们正式发布 DeepSeek-R1, 并同步开源模型权重。

- DeepSeek-R1 遵循 MIT License, 允许用户通过蒸馏技术借助 R1 训练其他模型。
- DeepSeek-R1 上线 API, 对用户开放思维链输出, 通过设置 `model='deepseek-reasoner'` 即可调用。
- DeepSeek 官网与 App 即日起同步更新上线。

性能对齐 OpenAI-o1 正式版

DeepSeek-R1 在后训练阶段大规模使用了强化学习技术, 在仅有极少标注数据的情况下, 极大提升了模型推理能力。在教学、代码、自然语言推理等任务上, 性能比肩 OpenAI o1 正式版。

新闻: <https://api-docs.deepseek.com/zh-cn/news/news250120>



DeepSeek
55.2k followers
<https://www.deepseek.com/>
service@deepseek.com

Overview Repositories 16 Projects Packages People 1

Pinned

- DeepSeek-V3** (Public)
Python 86.1k stars 13.9k forks
- DeepSeek-R1** (Public)
77.8k stars 10.1k forks
- DeepSeek-VL2** (Public)
DeepSeek-VL2: Mixture-of-Experts Vision-Language Models for Advanced Multimodal Understanding
Python 3.7k stars 1.5k forks
- awesome-deepseek-integration** (Public)
16.5k stars 1.8k forks

Repositories

- awesome-deepseek-integration** (Public)
16.48k stars 1.83k forks 50 issues 41 pull requests Updated 2 hours ago

Top languages
Python Makefile

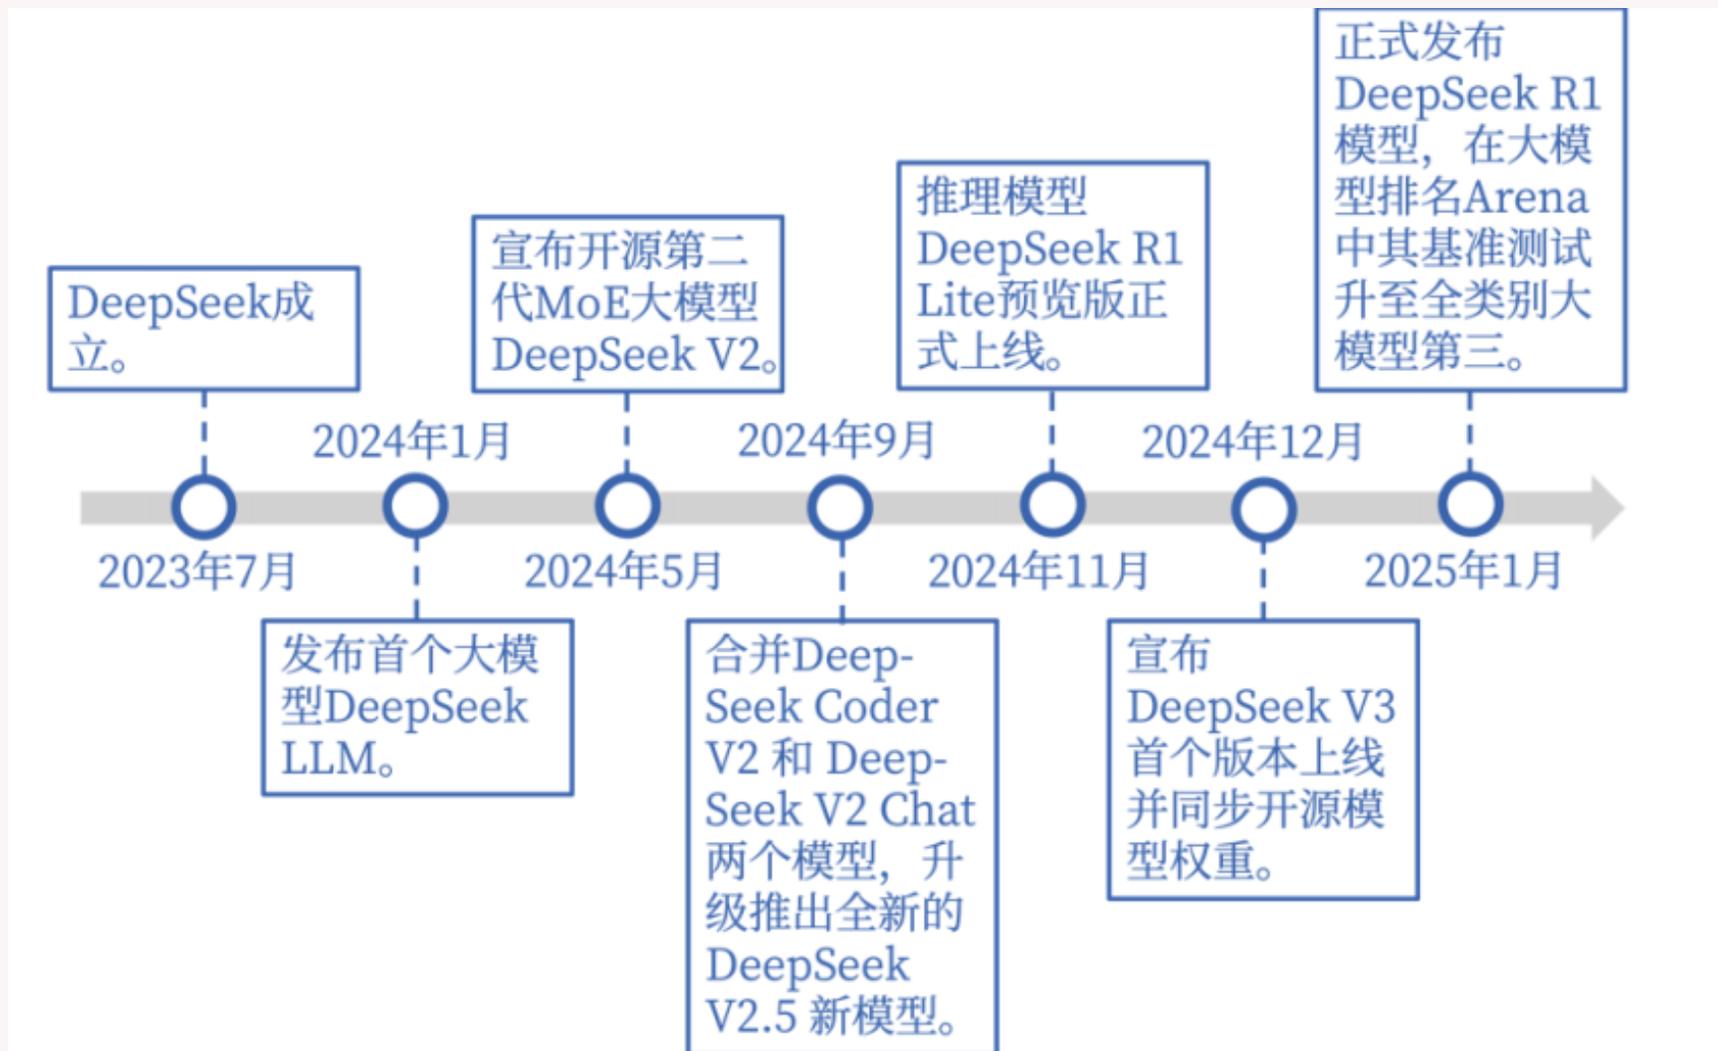
Most used topics
foundation-models vision-language-pretraining

Github: <https://github.com/deepseek-ai/>

DeepSeek模型系列



北京大学
PEKING UNIVERSITY



DeepSeek最新的生成模型和推理模型版本对比



比较方面	生成模型 (V3)	推理模型 (R1)
设计初衷	想要在各种自然语言处理的任务中都能表现好, 更通用	重点是为了搞定复杂的推理情况, 比如深度的逻辑分析和解决问题
性能展现	在数学题、多语言任务还有编码任务里表现不错, 像Cmath能得90.7分, Human Eval编码任务通过率是65.2%	在需要逻辑思考的测试里很棒, 比如DROP任务F1分数能达到92.2%, AIME 2024的通过率是79.8%
应用的范围	适合大规模的自然语言处理工作, 像对话式AI、多语言翻译还有内容生成等等, 能给企业提供高效的AI方案, 满足好多领域的需求	适合学术研究、解决问题的应用和决策支持系统等需要深度推理的任务, 也能拿来当教育工具, 帮学生锻炼逻辑思维

DeepSeek-R1 工作原理



北京大学
PEKING UNIVERSITY

思维链 (Chain of Thought)

让模型进行慢思考

强化学习 (Reinforcement Learning)

让模型自我探索和训练

蒸馏 (Distillation)

在不损失能力的情况下缩小模型

- DeepSeek R1论文: https://github.com/deepseek-ai/DeepSeek-R1/blob/main/DeepSeek_R1.pdf
- DeepSeek R1论文图解: <https://zhuanlan.zhihu.com/p/20844750193>

DeepSeek-R1 版本



模型名称	
DeepSeek-R1-671B	满血版, 能力最强
DeepSeek-R1-Distill-Qwen-7B	蒸馏版, 能力稍弱 --实际上是增加了推理能力的Qwen或Llama模型
DeepSeek-R1-Distill-Llama-8B	
DeepSeek-R1-Distill-Qwen-14B	
DeepSeek-R1-Distill-Qwen-32B	
DeepSeek-R1-Distill-Llama-70B	

部署DeepSeek-R1 满血版的算力要求和性能



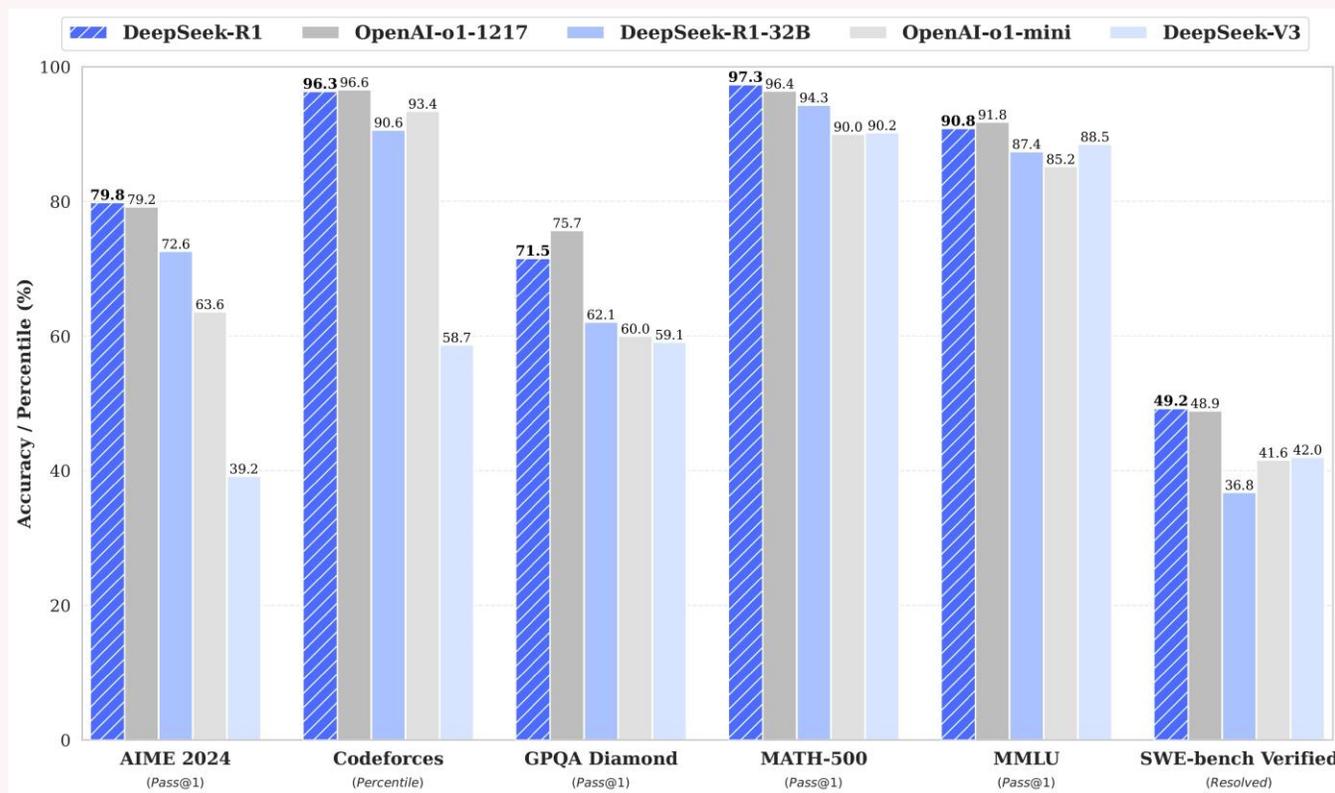
北京大学
PEKING UNIVERSITY

模型	算力型号	每套卡数	每套算力 (FP16/TFLOPS)	每套显存 (GB)	模型精度	含算力部署总价 (万/套/月)
 DeepSeek R1 671B	NV H800	16	31664	1280	FP8	18
	NV H200	8	15832	1128	FP8	11
	NV H20	16	2368	1536	FP8	8
	昇腾 910B	32	10016	2048	BF16	12
 DeepSeek V3 671B	NV H800	16	31664	1280	FP8	18
	NV H200	8	15832	1128	FP8	11
	NV H20	16	2368	1536	FP8	8
	昇腾 910B	32	10016	2048	BF16	12

DeepSeek-R1的优势

理科能力强，且准确率高

- 数学推理
- 代码生成
- 复杂任务处理



DeepSeek-R1 的局限

●通用能力

- R1 的通用能力（尤其是生成能力）低于DeepSeek-V3
- R1的幻觉仍旧比较明显（可能源于R1的中文语言表达能力更强）

●语言混杂

- R1 在处理非中英文问题时，偶尔会出现语言混杂现象
- 这个现象在R1 Zero版本中更加明显

●提示词工程

- 使用 few-shot 提示可能会降低R1性能
- 使用过多的过程指导指令可能会降低R1的推理能力

The results are shown in Table 1 below.

	DeepSeek R1	DeepSeek V3
Vectara's HHEM 2.1	14.3%	3.9%
Google's FACTS w/ GPT-4o & Claude-3.5-Sonnet	4.37%	2.99%
Google's FACTS w/ GPT-4o & Gemini-1.5-Pro	3.09%	1.99%
Google's FACTS w/ Claude-3.5-Sonnet & Gemini-1.5-Pro	3.89%	2.69%

Table 1: Hallucination rates of DeepSeek R1 and V3 by various hallucination judgment approaches. Lower hallucination rates are better.

Thus our surprise: consistently across all judgment approaches, Deepseek-R1 is shown to be hallucinating at significantly higher rates than Deepseek-V3.

DeepSeek-R1 应用场景



北京大学
PEKING UNIVERSITY

● 推理密集型任务

- 编程任务中的代码生成、算法设计，媲美Claude 3.5 Sonet
- 数学问题求解、科学推理和逻辑分析等需要复杂推理的场景。

● 教育与知识应用

- 可用于解决教育领域的问题，支持知识理解与解答。
- 可用于科研任务的实验设计、数据分析和论文撰写。

● 文档分析与长上下文理解

- 适合处理需要深入文档分析和理解长上下文的任务，例如复杂信息提取与整合。

● 开放领域问答与写作

- 在内容生成、问题回答以及创造性写作中具有广泛应用，例如生成高质量文本或进行内容编辑。

如何使用DeepSeek R1

● DeepSeek官方网站和官方app

● 腾讯系

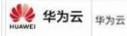
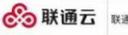
- 腾讯元宝
- 微信AI搜索
- 腾讯ima个人知识库

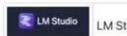
● AI搜索

- 秘塔搜索
- 纳米AI搜索
- 知乎直答

● 其它接入DeepSeek-R1的产品

- Molly R1 (向量智能)
- 问小白

 deepseek 深度求索 DeepSeek, 全称杭州深度求索人工智能基础技术研究有限公司。 厂商所在地: 中国 类型: 官方 访问服务	 华为云 华为云 华为云ModelArts提供DeepSeek系列模型服务, 支持在线训练和推理。 厂商所在地: 中国 类型: 云服务 访问服务	 硅基流动 硅基流动 硅基流动提供DeepSeek系列模型的在线服务和部署方案。 厂商所在地: 中国 类型: 云服务 访问服务
 联通云 联通云 联通云人工智能计算平台(AICP)提供DeepSeek模型的训练和推理服务, 支持多种AI应用场景。 厂商所在地: 中国 类型: 云服务 访问服务	 阿里云 阿里云 阿里云PAI平台提供一键部署DeepSeek V3模型的功能, 方便用户快速构建AI应用。 厂商所在地: 中国 类型: 云服务 访问服务	 腾讯云 腾讯云 腾讯云TI平台支持DeepSeek模型的训练和部署, 助力企业实现智能化转型。 厂商所在地: 美国 类型: 云服务 访问服务
 百度智能云 百度智能云 百度智能云文心工作台提供DeepSeek模型的服务, 支持多种AI应用场景。 厂商所在地: 中国 类型: 云服务 访问服务	 SCNet 超算互联网 超算互联网提供DeepSeek模型的在线服务和部署方案, 满足不同用户的需求。 厂商所在地: 中国 类型: 云服务 访问服务	 纳米AI搜索 纳米搜索(360) 基于DeepSeek模型的智能搜索和对话服务。 厂商所在地: 中国 类型: 客户端 访问服务
 中国移动 移动云 移动云鹰潭大模型服务平台上线DeepSeek模型, 支持在线体验、部署、智能体开发等能力, 满足多种AI应用场景。 厂商所在地: 中国 类型: 云服务 访问服务	 火山引擎 火山方舟 适用于期望通过API快速集成训练模型的企业, 目前已上线DeepSeek 4个模型, 并提供了全网最高的推理。 厂商所在地: 中国 类型: 云服务 访问服务	 火山引擎 火山机器学习平台 支持全尺寸DeepSeek模型, 适用于自己进行模型定制、部署、推理的企业。 厂商所在地: 中国 类型: 客户端 访问服务
 Cosdoo算力互联 算力互联 算力互联携手天数智芯正式上线基于天数智芯GPU芯片的DeepSeek-R1模型服务, 支持DeepSeek-R1-Distill-Qwen-7B、DeepSeek-R1-Distill-Qwen-14B、DeepSeek-R1-Distill-Qwen-32B等版本 厂商所在地: 中国 类型: 云服务 访问服务	 天翼云 天翼云 中国电信天翼云提供DeepSeek-R1模型的多平台支持、部署、推理和微调服务, 涵盖科研、办公、教育等场景, 助力用户高效应用AI技术。 厂商所在地: 中国 类型: 云服务 访问服务	 中国科技云 中国科技云 中国科技云提供DeepSeek-R1模型的本地部署服务和科研文献助手, 支持学术优化、AI搜索引擎、LaTeX公式识别和表格识别等功能, 助力科研文献处理和学术写作效率提升。 厂商所在地: 中国 类型: 云服务 访问服务

 gitee AI Gitee Gitee AI的Serverless API提供DeepSeek开箱的大模型API服务。 厂商所在地: 中国 类型: 云服务 访问服务	 青云科技 青云科技 青云科技旗下AI算力云服务——基石智算CoresHub上线DeepSeek全系列模型, 支持API调用、云端部署及私有化部署, 加速企业快速接入及部署应用。 厂商所在地: 中国 类型: 云服务 访问服务	 NVIDIA 英伟达 NVIDIA AI Enterprise提供DeepSeek-R1模型的企业级支持。 厂商所在地: 美国 类型: 云服务 访问服务
 aws AWS Amazon Bedrock和SageMaker提供DeepSeek-R1模型服务。 厂商所在地: 中国 类型: 云服务 访问服务	 groq Groq Groq Cloud提供DeepSeek模型的高性能推理服务。 厂商所在地: 美国 类型: 云服务 访问服务	 Azure Azure Amazon Bedrock和SageMaker提供DeepSeek-R1模型服务。 厂商所在地: 美国 类型: 云服务 访问服务
 CURSOR Cursor Amazon Bedrock和SageMaker提供DeepSeek-R1模型服务。 厂商所在地: 美国 类型: 编译工具 访问服务	 LM Studio LM Studio 本地运行和管理DeepSeek等大语言模型的桌面应用。 厂商所在地: 美国 类型: 云服务 访问服务	 Ace Cloud Acecloud 印度领先的AI云服务提供商, 支持DeepSeek模型部署。 厂商所在地: 印度 类型: 云服务 访问服务
 Ollama 轻量级的本地LLM运行工具, 支持DeepSeek模型。 厂商所在地: 美国 类型: 部署工具 访问服务	 LlAMA.cpp Llama.cpp 高性能C++推理引擎, 支持DeepSeek等大语言模型。 厂商所在地: 美国 类型: 推理引擎 访问服务	 Ace Cloud Acecloud 印度领先的AI云服务提供商, 支持DeepSeek模型部署。 厂商所在地: 印度 类型: 云服务 访问服务
 CLOUDFLARE Cloudflare Workers 在Cloudflare Workers中运行DeepSeek模型。 厂商所在地: 美国 类型: Serverless 访问服务	 CLOUDFLARE Cloudflare AI Gateway 通过Cloudflare AI Gateway访问DeepSeek API服务。 厂商所在地: 美国 类型: AI Gateway 访问服务	

接入DeepSeek R1第三方服务的厂家

- 互联网大厂：
 - 腾讯：腾讯元宝、ima、微信、腾讯云
 - 百度：百度搜索、文小言
 - 字节跳动：豆包、扣子、飞书
 - 阿里：钉钉
 -
- 互联网小厂：科大讯飞、知乎、秘塔、纳米AI搜索、.....
- AI初创公司：零一万物、阶跃星辰、minmax、.....
- AI应用公司（教育类）：学而思、北大青鸟、网易有道、猿辅导、作业帮、.....
- 手机厂商：华为、荣耀、魅族、.....
- 其它云服务平台：三大运营商、云服务商（硅基流动等）



PART 02 ▶

AIGC的概念和应用

本部分着重介绍人工智能生成内容（AIGC）的定义、应用范围及其在各行业的实际影响：

首先梳理AIGC相关的术语，包括AI、AGI、生成式AI和决策式AI等，明确了其在人工智能领域的定位。随后，详细列举AIGC在文本、图像、音频和视频生成方面的多样化应用，并探讨其在电商、新闻传媒、影视、游戏、教育和金融等行业的具体实践，展示AIGC在提升效率、降低成本和增强创新方面的核心价值。

此外，还分析AIGC带来的挑战，如数据隐私、伦理问题、生成质量控制以及对就业结构的影响。通过深入探讨AIGC的应用现状和未来趋势，本部分旨在帮助读者全面理解AIGC的潜力和影响，为应对技术变革提供参考。

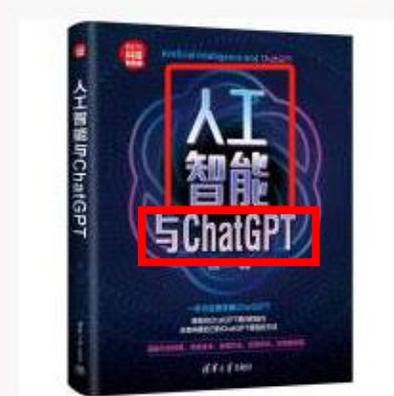
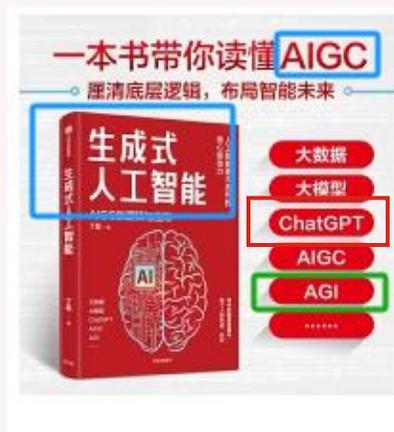
本部分的内容参考了《人工智能通识课（微课版）》和相关的视频（B站的思睿观通）

初识 AIGC

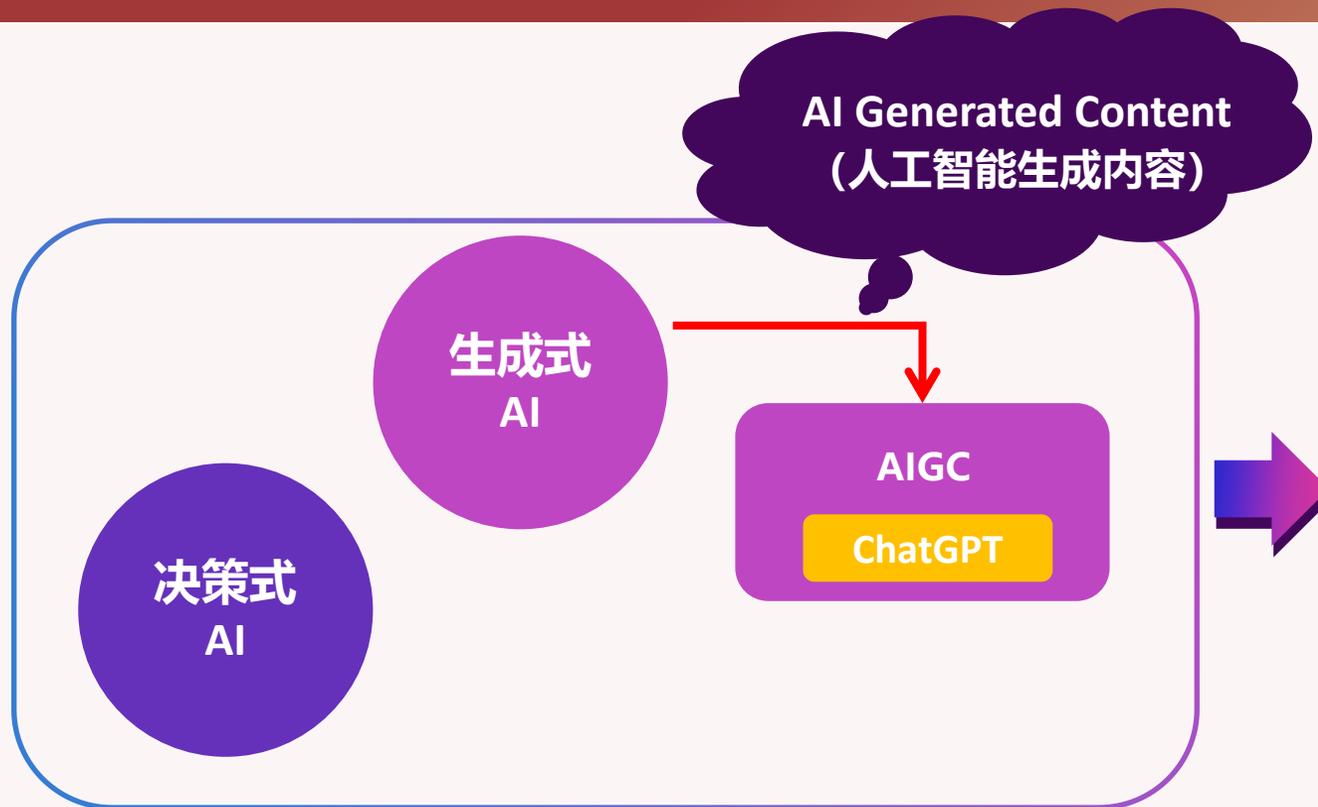
眼花缭乱的名词



北京大学
PEKING UNIVERSITY



眼花缭乱的名词



AI(人工智能)

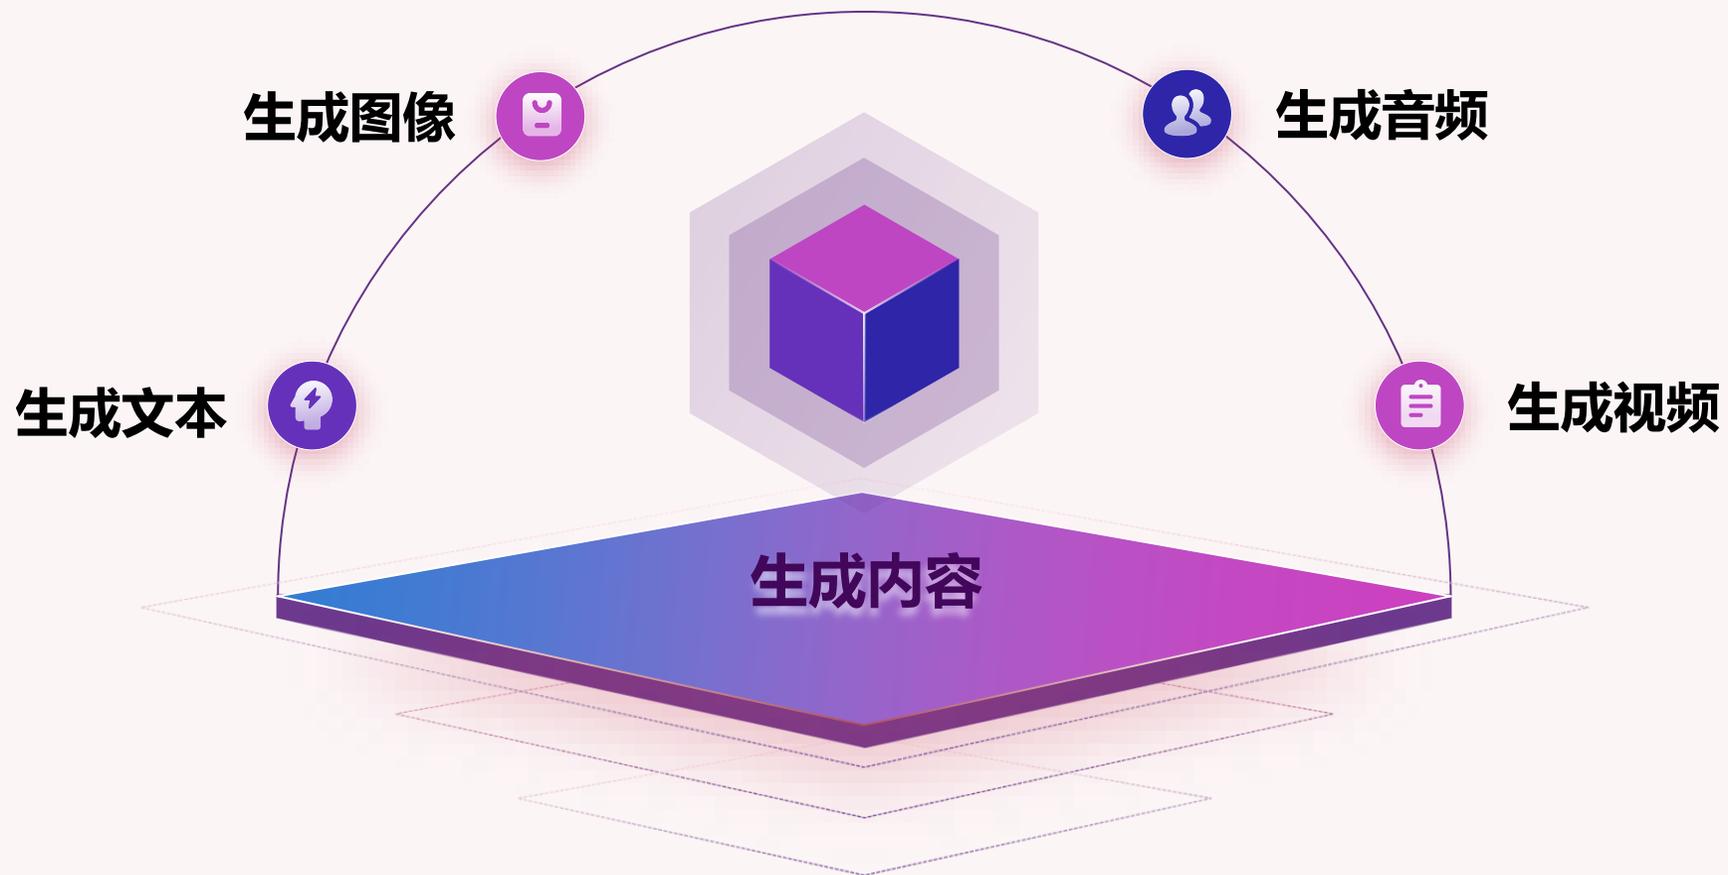


AGI(通用人工智能)
(artificial general intelligence)

AIGC能干什么

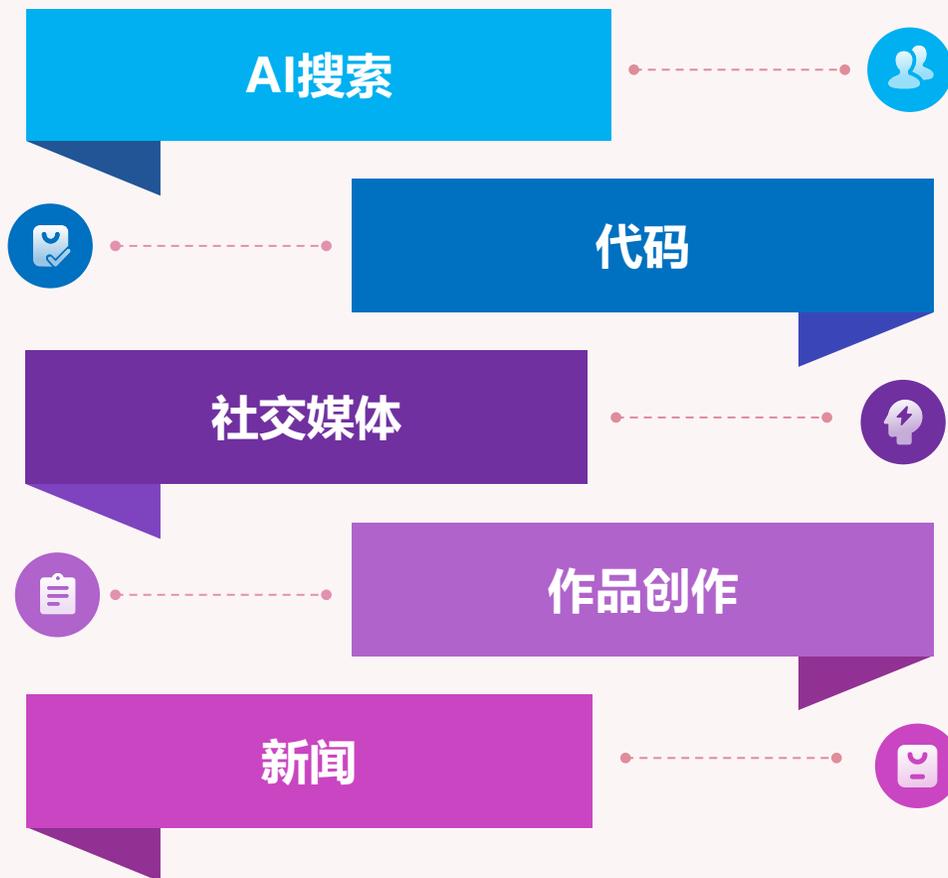


北京大学
PEKING UNIVERSITY



- Cursor
- Windsurf
- MarsCode
- GitHub Copilot
- 阿里云通义灵码

- 微软“小冰”出版诗集
- AI撰写剧本电影《阳春》
- 百万字小说《天命使徒》
- 清华大学的《机忆之地》



- Perplexity
- 知乎直答
- 秘塔AI搜索引擎
- 纳米AI搜索
- 微信搜索 (DeepSeek R1、元宝)
- 小红书的笔记助手
- 短视频平台的内容创意
- 自动回复机器人
- 企业微信的智能回复
- 英国广播公司(BBC)的Juicer
- 彭博社的Cyborg
- 新华社的快笔小新
- 人民日报的创作大脑
- 第一财经的DT稿王



太空歌剧院

2022年8月，获得比赛
“数字艺术/数字修饰照片”
一等奖

AI绘画



北京大学
PEKING UNIVERSITY

文生图

风格化

消除水印

扩图



通义照相馆

热度433.5万+

AI滤镜

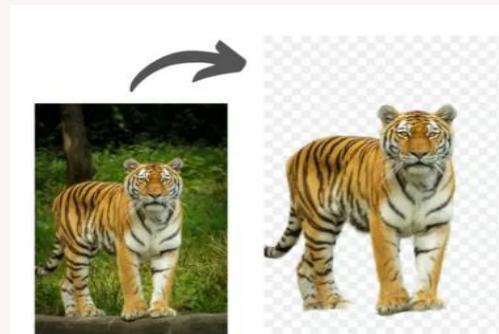
AI试衣

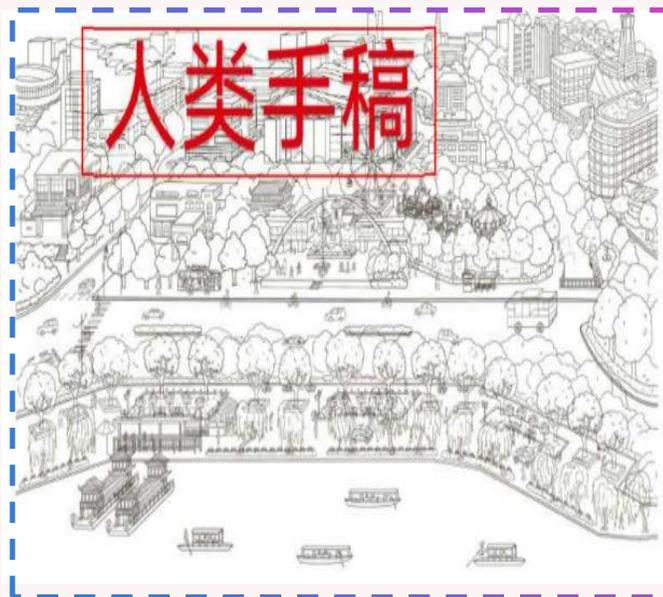
AI证件照



图片微动效

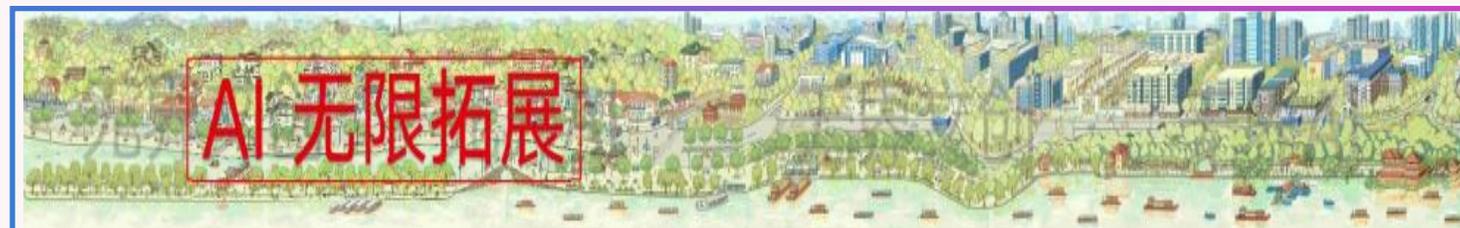
热度267.0万+



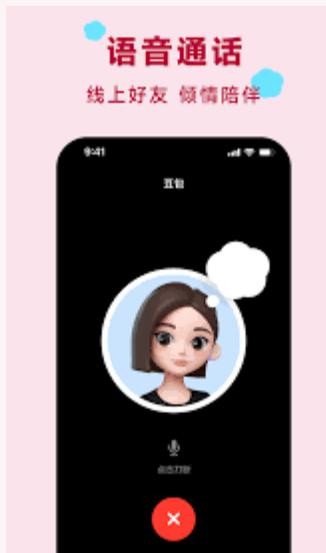


全景图是一副百米画卷，再现了当下西湖边的景观特色、生活场景，还有一些已经消失的景观，比如曾经闻名遐迩的大佛寺。

图中包含5000个建筑，作者白小苏说如果这些建筑都要自己亲手画，一天画10个都要500天。最后他借助于AI技术，在一年内完成了作品



新西湖繁胜全景图



语音对话



创作音乐




语音克隆



千秋诗颂



视频特效



视频添加图片

AIGC 的行业应用

AIGC的行业应用





**商品3D模型
改善购物体验**



**AI模特
产品拍摄降本增效**

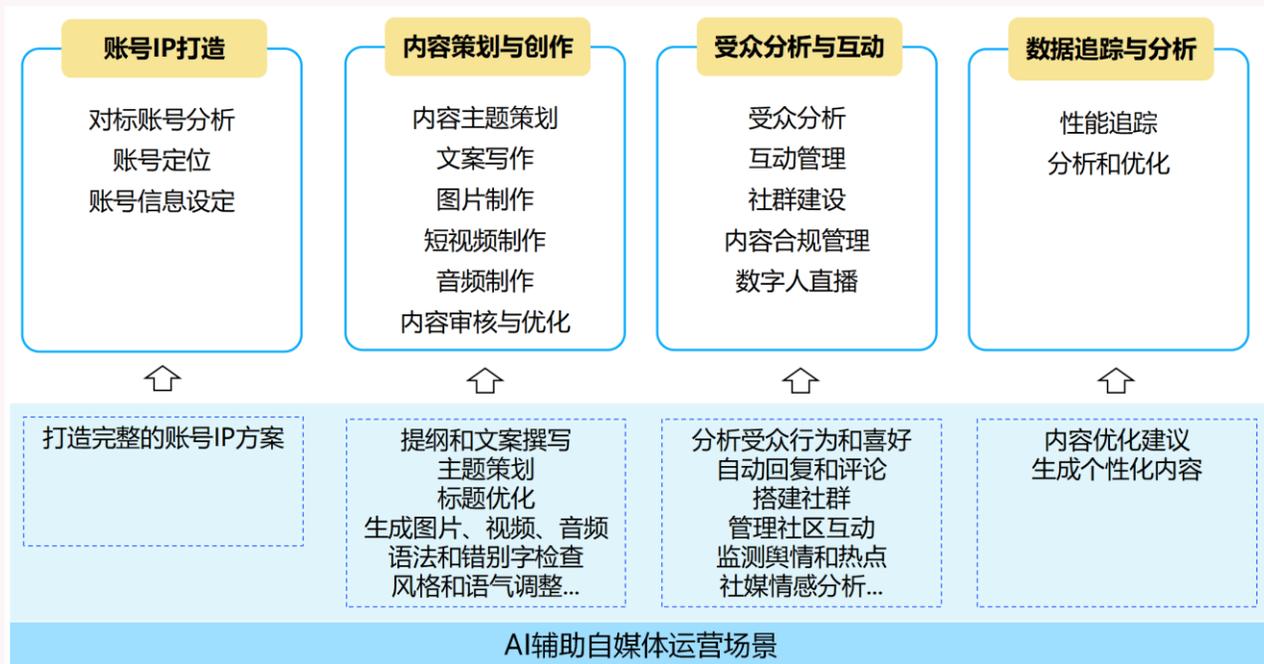


**虚拟主播
提升直播带货效率**

内容广告



北京大学
PEKING UNIVERSITY



全流程参与
提高效率



雪花啤酒虚拟偶像
提升品牌宣传效果

AIGC对传媒行业影响包括采编环节、传播环节，通过语音转写、智能写作、智能剪辑等方式提高采编环节的生产效率，在传播环节通过打造AI主播实现智能、高效播报。



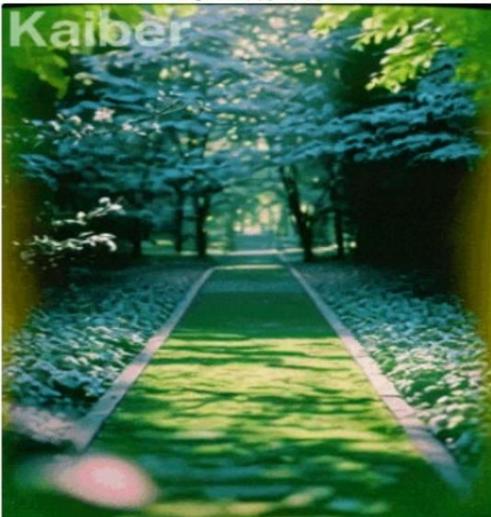
AIGC对传媒行业参与主体的影响



智能图像修复



文本生成场景



前期创作

影视剧本文稿创作

通过对海量剧本数据进行分析归纳，并按照预设风格快速生产剧本，创作者再进行筛选和二次加工，激发创作者的灵感，缩短创作周期。

影视剧本创作平台



中期拍摄

拓展角色范畴

通过AIGC合成人脸、声音等内容，实现“数字复活”已故演员、替换“劣迹艺人”、高难度动作合成等

拓展场景空间


AIGC合成虚拟物理场景，将无法实拍或成本过高的场景生成出来，大大拓宽了影视作品想象力的边界，给观众带来更优质的视觉效果和听觉体验

后期制作

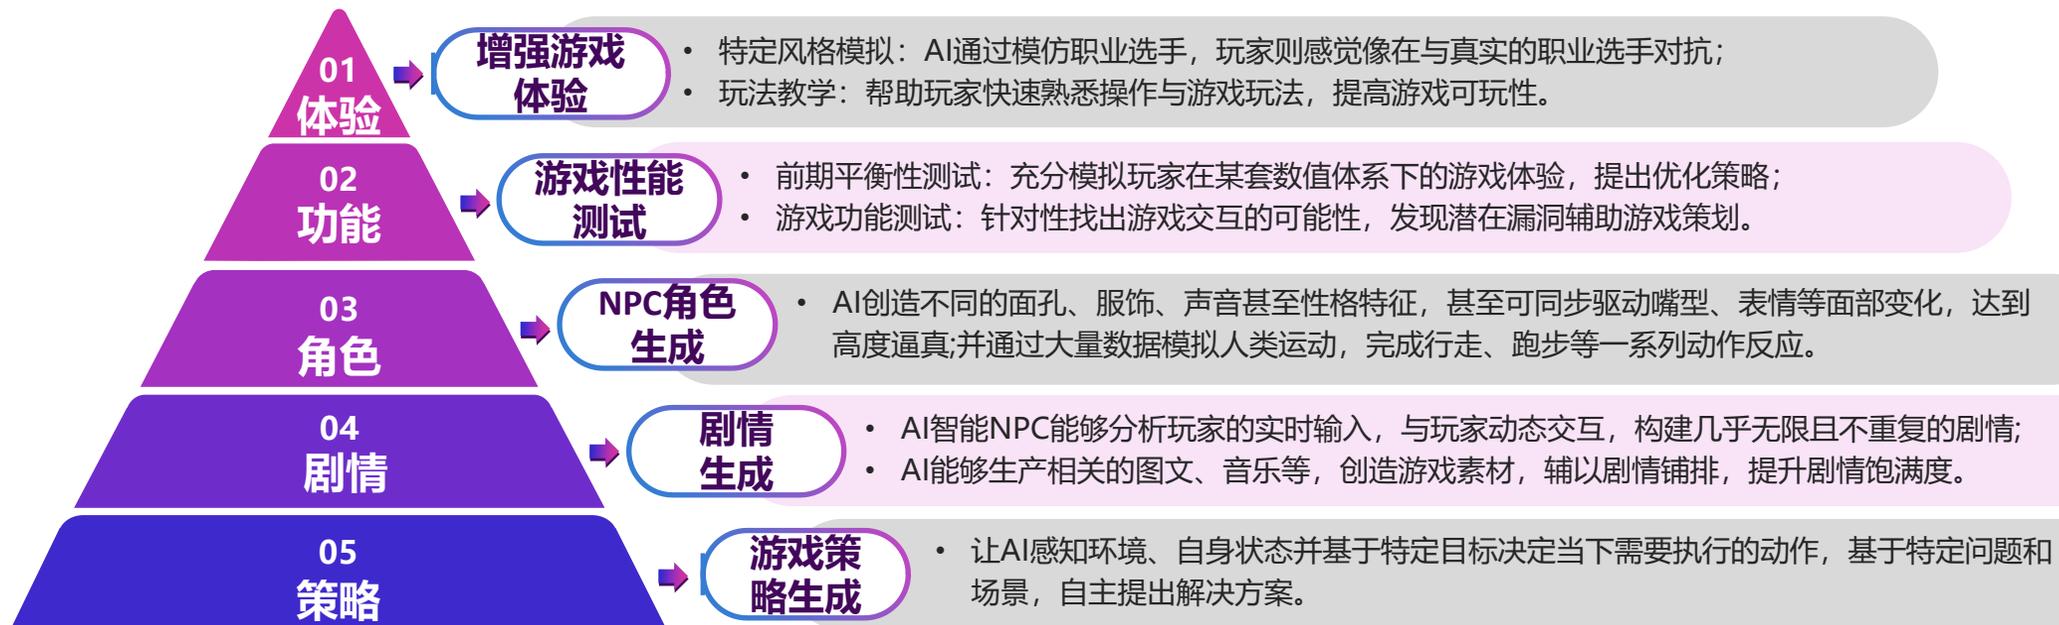
赋能影视剪辑

修复、还原影像，提升影像资料的清晰度；实现影视预告片自动生成；实现将影视内容维度转制，从2D向3D自动转制

实时字幕



AIGC游戏研发环节作用



游戏运营环节

- AI自动化广告投放: 目前抖音等平台的广告分发、内容推荐已通过算法实现, 且效果较高;
- 生成广告素材: 素材主要是图像及音视频内容, 预计AIGC的加持下广告素材生成会更高效、高质量;
- 玩家分类提升体验: 通过不同玩家的数据, 将用户细分类型, 为不同类型玩家提供独特的玩法, 提高用户体验。

其他行业

教育行业



其它

- 自动批改作业和考试
- 虚拟实验室
- 生成学习资料
- 翻译文献资料

金融行业



其它

- 风险管理
- 自动处理和分
析金融文档
- 合规管理

AIGC 的未来

AIGC的核心价值



北京大学
PEKING UNIVERSITY



企业赋能

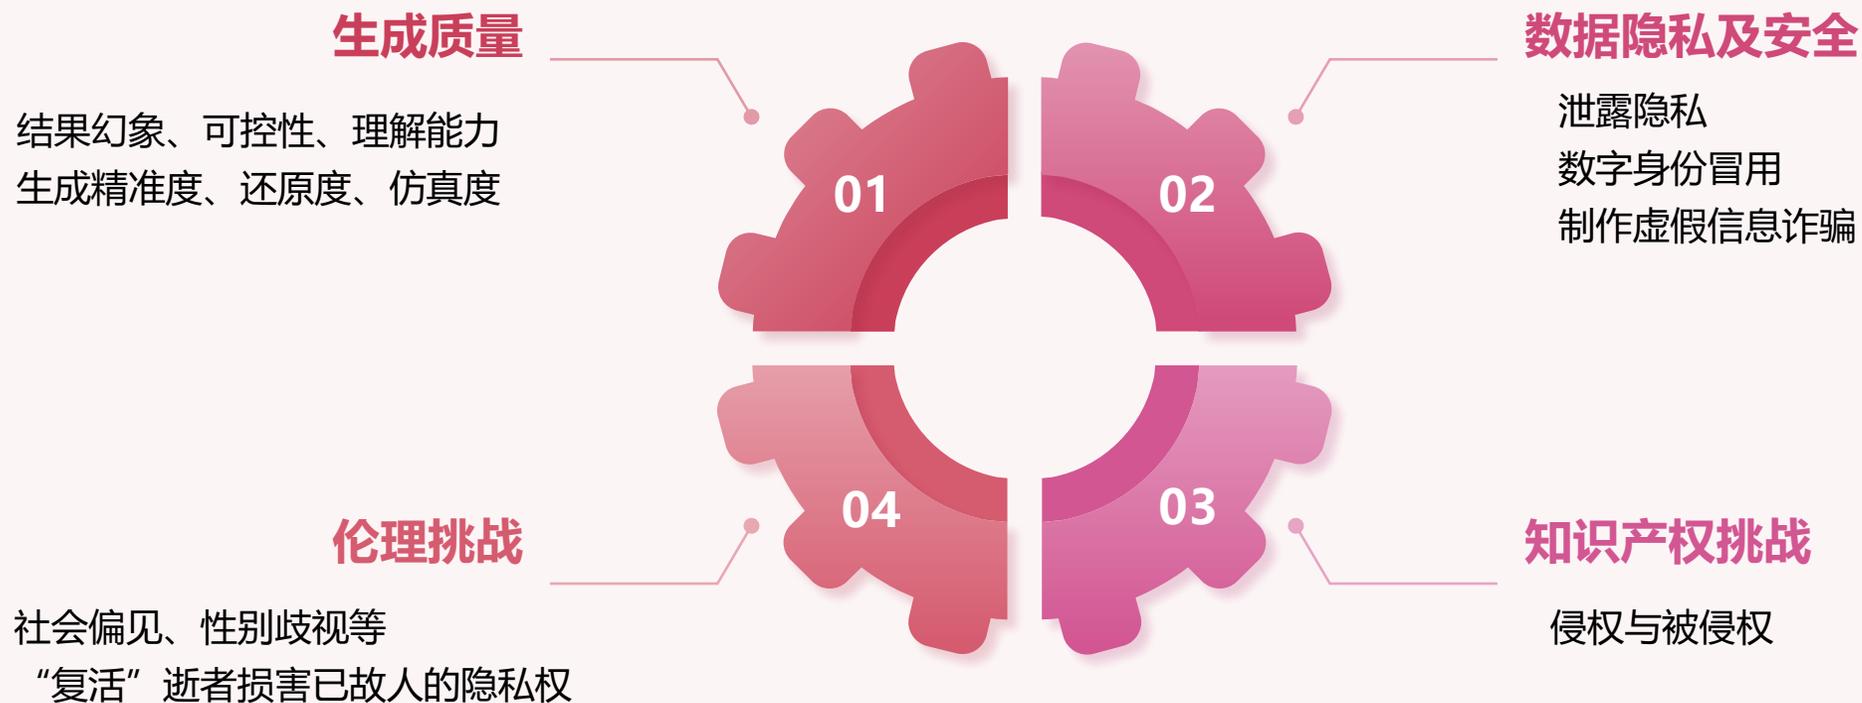


个人赋能

AIGC的挑战



北京大学
PEKING UNIVERSITY



01

技术进步

AIGC的生成质量和准确性将得到提升

02

更广泛的应用

在更多领域得到应用，
如保险、医疗和法律
服务等

03

人机协作

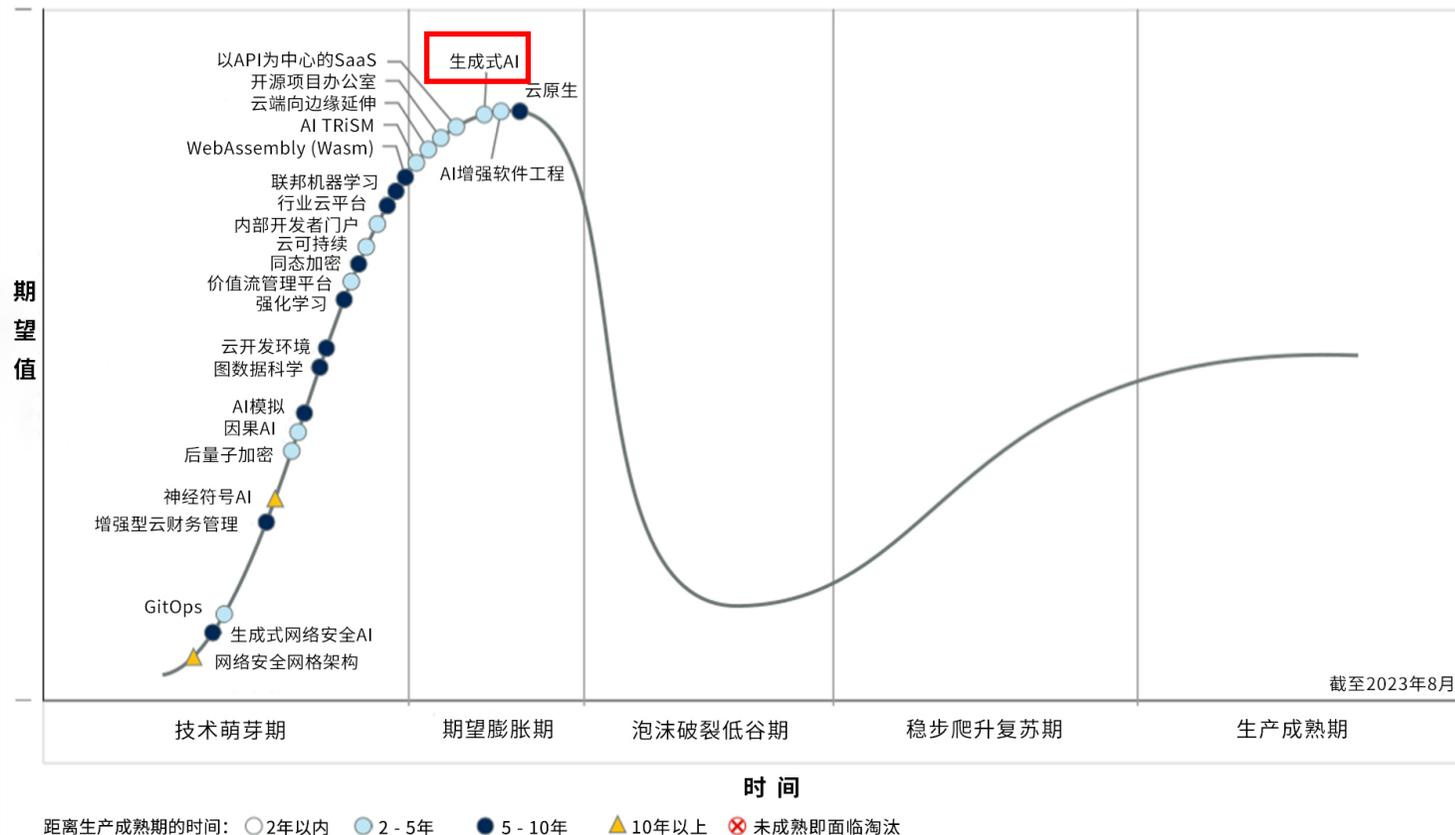
更多地与人类专家协作，
以提供更高质量
的内容和服务

04

监管框架的发展

预计将出现更多关于
内容生成和使用的监
管框架

2023年新兴技术成熟度曲线



生成式人工智能 (AI) 目前处于期望膨胀期，预计将在2~5年内产生巨大效益

到 2026 年，Gartner预测超过80%的企业将使用生成式AI的API或模型，或在生产环境中部署支持生成式AI的应用，而在2023年初这一比例不到5%。

数据来源：Gartner (2023年8月)

工作岗位需求变化

Demand for healthcare and STEM roles could grow, while demand for office support and customer service roles could decline.

Net expected change in labor demand, Europe¹ and US, faster/midpoint scenario,¹ 2022–30

Occupational category	Europe ²		US	
	Employment change vs 2022, million	Employment change vs 2022, %	Employment change vs 2022, million	Employment change vs 2022, %
Health aides, technicians, and wellness	3.3	25.2	3.5	29.7
STEM professionals	2.3	16.7	1.8	23.1
Health professionals	1.5	23.6	2.0	30.1
Production work	-0.9	-5.3	-0.1	-0.7
Customer service and sales	-1.7	-12.1	-2.0	-13.4
Office support	-5.0	-18.3	-3.7	-18.5

¹For Europe, we used the "faster" scenario, which corresponds to the "midpoint" scenario in the United States. The "faster" or midpoint adoption scenario is the average between the early and late scenarios. The "slower" scenario is the average between the late scenario and the midpoint scenario.

²Includes Czech Republic, Denmark, France, Germany, Italy, Netherlands, Poland, Spain, Sweden, and United Kingdom.

Source: Eurostat; Occupational Information Network; Oxford Economics; US Bureau of Labor Statistics; national statistical agencies of the European countries considered; McKinsey Global Institute analysis.

McKinsey & Company

显著上升

- STEM (科学、技术、工程和数学) 相关职业
- 医疗保健和其他高技能职业

下降显著

- 办公室职员
- 生产工人
- 客户服务代表等传统职业

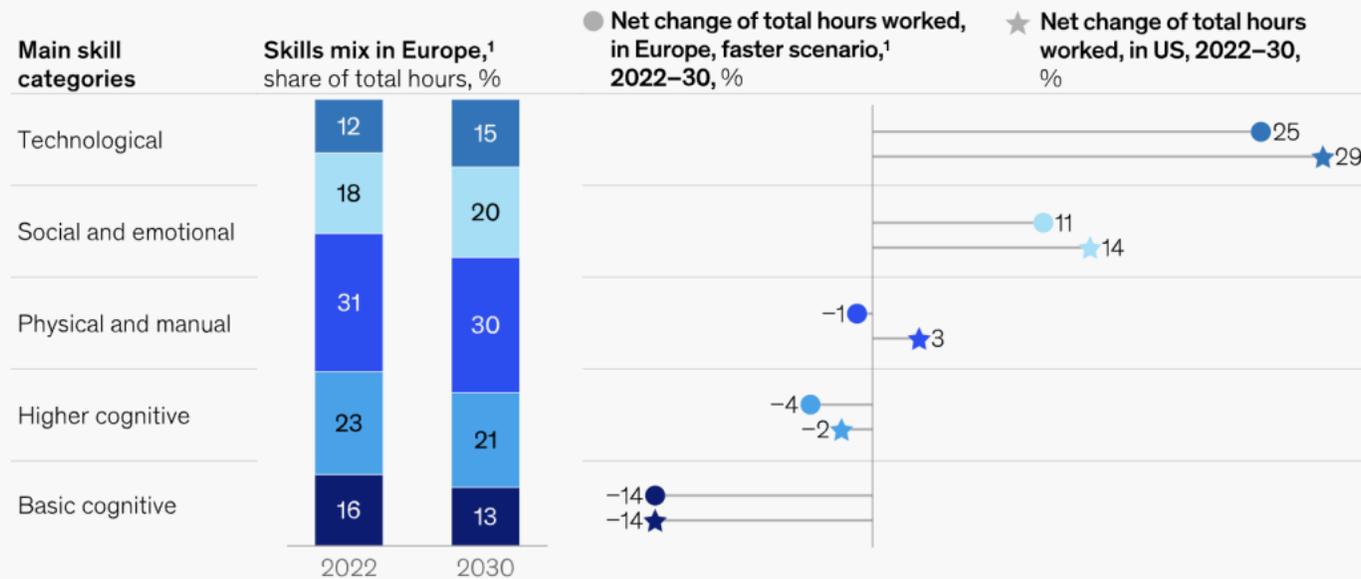
到 2030 年，欧洲和美国多达30%的工作时间可能实现自动化

2024年5月24日

麦肯锡报告：《工作的新未来：在欧洲及其他地区部署人工智能和提升技能的竞赛》

技能类型需求变化

Demand for technological and social and emotional skills could increase in Europe.

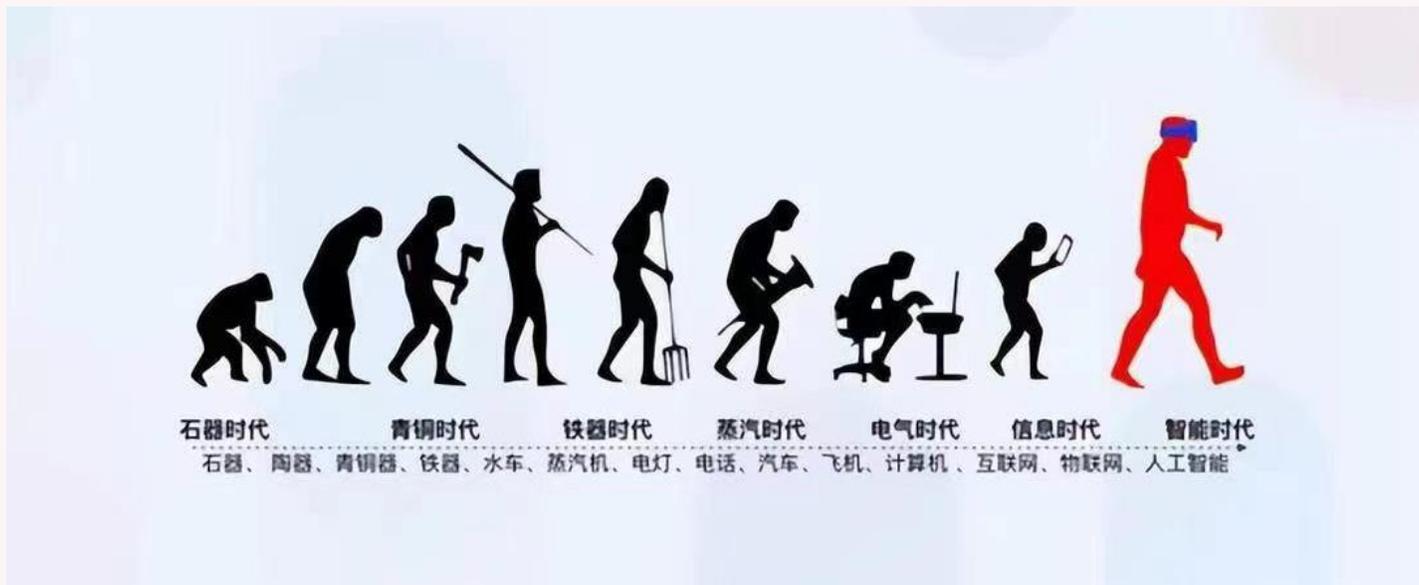


技能类型需求变化

- **技术技能**大幅增长
- 炙手可热的“新宠”技能是**社会和情感技能**
- 体力和手动技能的需求预计将保持大致稳定
- 认知技能(文字和信息处理、编程、科研、工程等)的需求预计将减少14%

2024年5月24日

麦肯锡报告：《工作的新未来：在欧洲及其他地区部署人工智能和提升技能的竞赛》



- 学习AIGC基础知识
- 积极使用AIGC工具
- 关注AIGC在各行业的应用案例
- 跟踪最新发展趋势



PART 03 ▶

AIGC的能力揭秘

简介

本部分深入剖析AIGC背后的技术原理，涵盖文本生成和图像生成两大核心领域。通过对比文本生成和图像生成的不同路径，大家能够全面理解AIGC在不同模态下的工作原理，以及如何利用这些技术实现高效的内容创作和应用。


在文本生成方面，以OpenAI的GPT-4o为例，详细介绍了通用大语言模型（LLM）的工作原理，包括其基于Transformer架构的生成机制、上下文编码、自注意力机制以及预训练和微调过程。探讨了GPT-4o在多轮对话、语言转换、意图理解、文本生成和推理能力等方面的优势，同时也指出其在知识局限、上下文窗口限制和生成幻觉等方面的不足。

在图像生成方面，以Stable Diffusion模型为例，解释了其核心组件（文本编码器、图像信息生成器和图像解码器）的工作流程，揭示了文生图和图生图技术的优势与局限。

本部分的内容参考了《人工智能通识课（微课版）》和相关的视频（B站的思睿观通）。

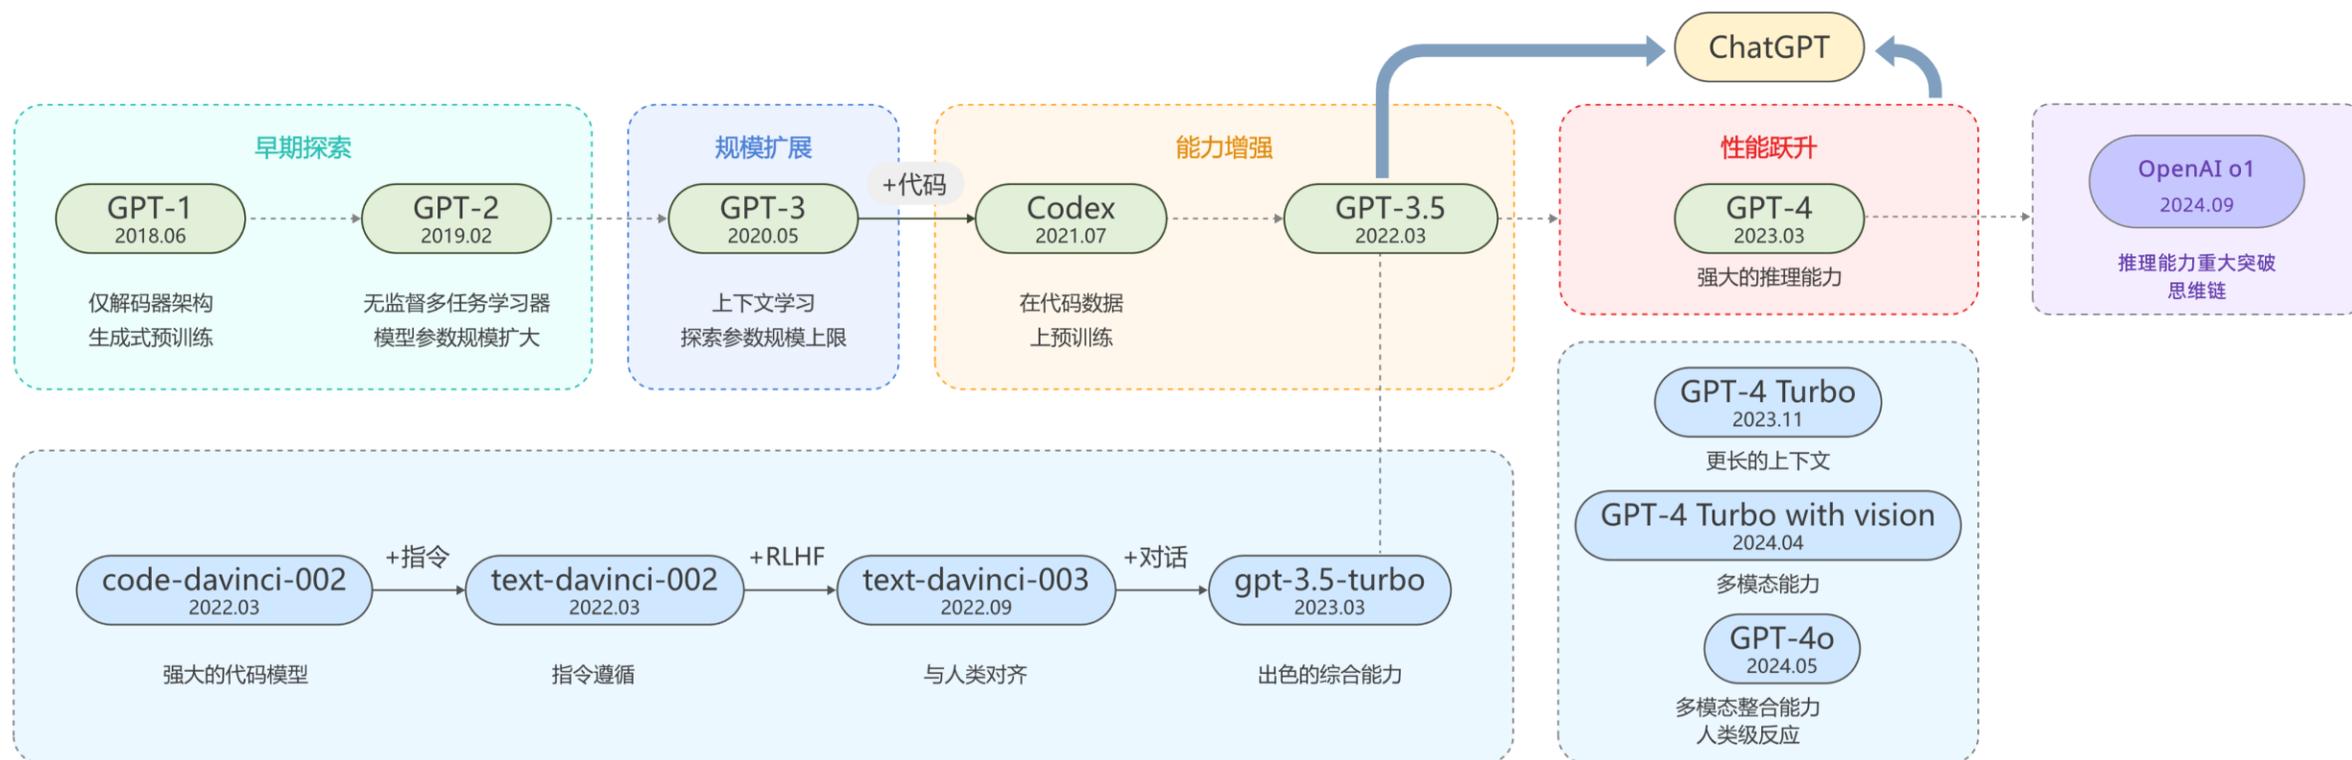
文本生成的奥秘

AIGC与GPT (通用大模型的代表)



OpenAI GPT的学霸养成记

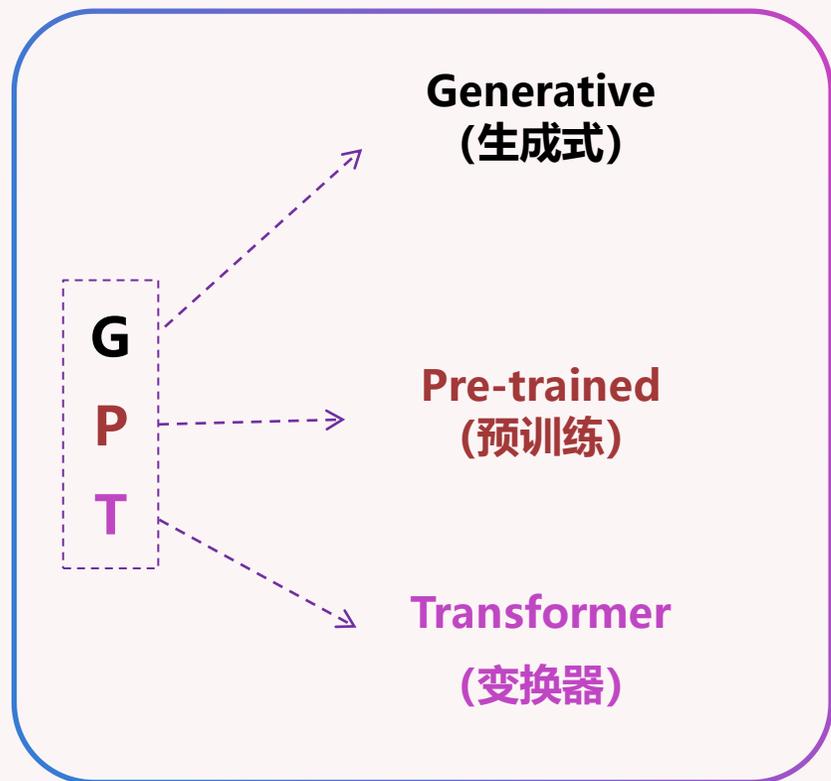
GPT:生成式预训练变换模型(Generative Pre-trained Transformer)



3大核心能力



工作原理-1



LLM: Large Language Model

1. 收到提示词

示例: “今天天气不错, 我决定”

2. 将输入拆分为token

[“今”, “天”, “天”, “气”, “不”, “错”, “,”, “,”, “我”, “决”, “定”]

3. 采用Transformer架构处理token

- 理解token之间的关系
- 识别提示词的整体含义

4. 基于上下文预测下一个token

- 为可能的单词分配概率分数
- 示例: { “去” :0.7, “停”:0.2, “站”:0.1 }

5. 根据概率分数选择标记

示例: “去”

概率预测+文字接龙

自回归: 重复步骤4和步骤5直到形成完整的句子


示例: 今天天气不错, 我决定去公园

工作原理-2



北京大学
PEKING UNIVERSITY

大模型工作过程



预训练
(自监督)

监督微调

人类反馈
强化学习

阶段1：模型训练



接收输入

处理输入

进行推理

生成输出

上下文
+
训练知识

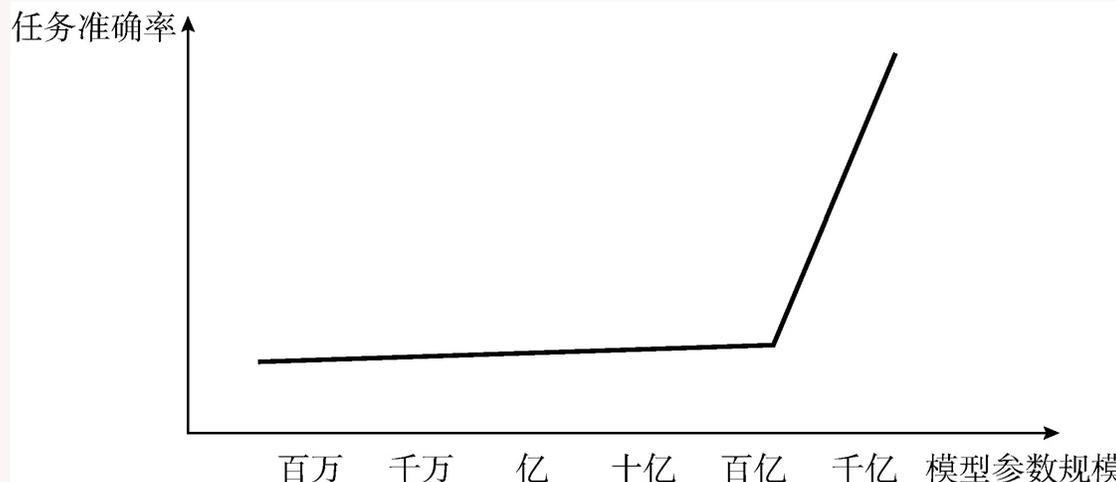
阶段2：推理



工作原理-3

数据来源	说明
维基百科	在线百科,严谨
图书	经典为主的古登堡计划和自助出版平台Smashwords等
杂志期刊	论文: ArXiv等
链接	WebText,Reddit
Common Crawl	开源项目,爬取互联网所有数据
GitHub	程序员聚集地
合计	<ul style="list-style-type: none">700 多GB,约有19万套四大名著的阅读量5 000亿左右的token数量。(13 万亿token:gpt4)100个标记大约等于75个英语单词

训练语料 (gpt-3)



典型的新技能学习曲线: 规模到达临界点之后才会迅速增长

模型参数: 1.8万亿参数 (GPT-4)

GPT-4o

上下文窗口大小: 8192个token(标记)

生成式通用大语言模型的优势与劣势



优势

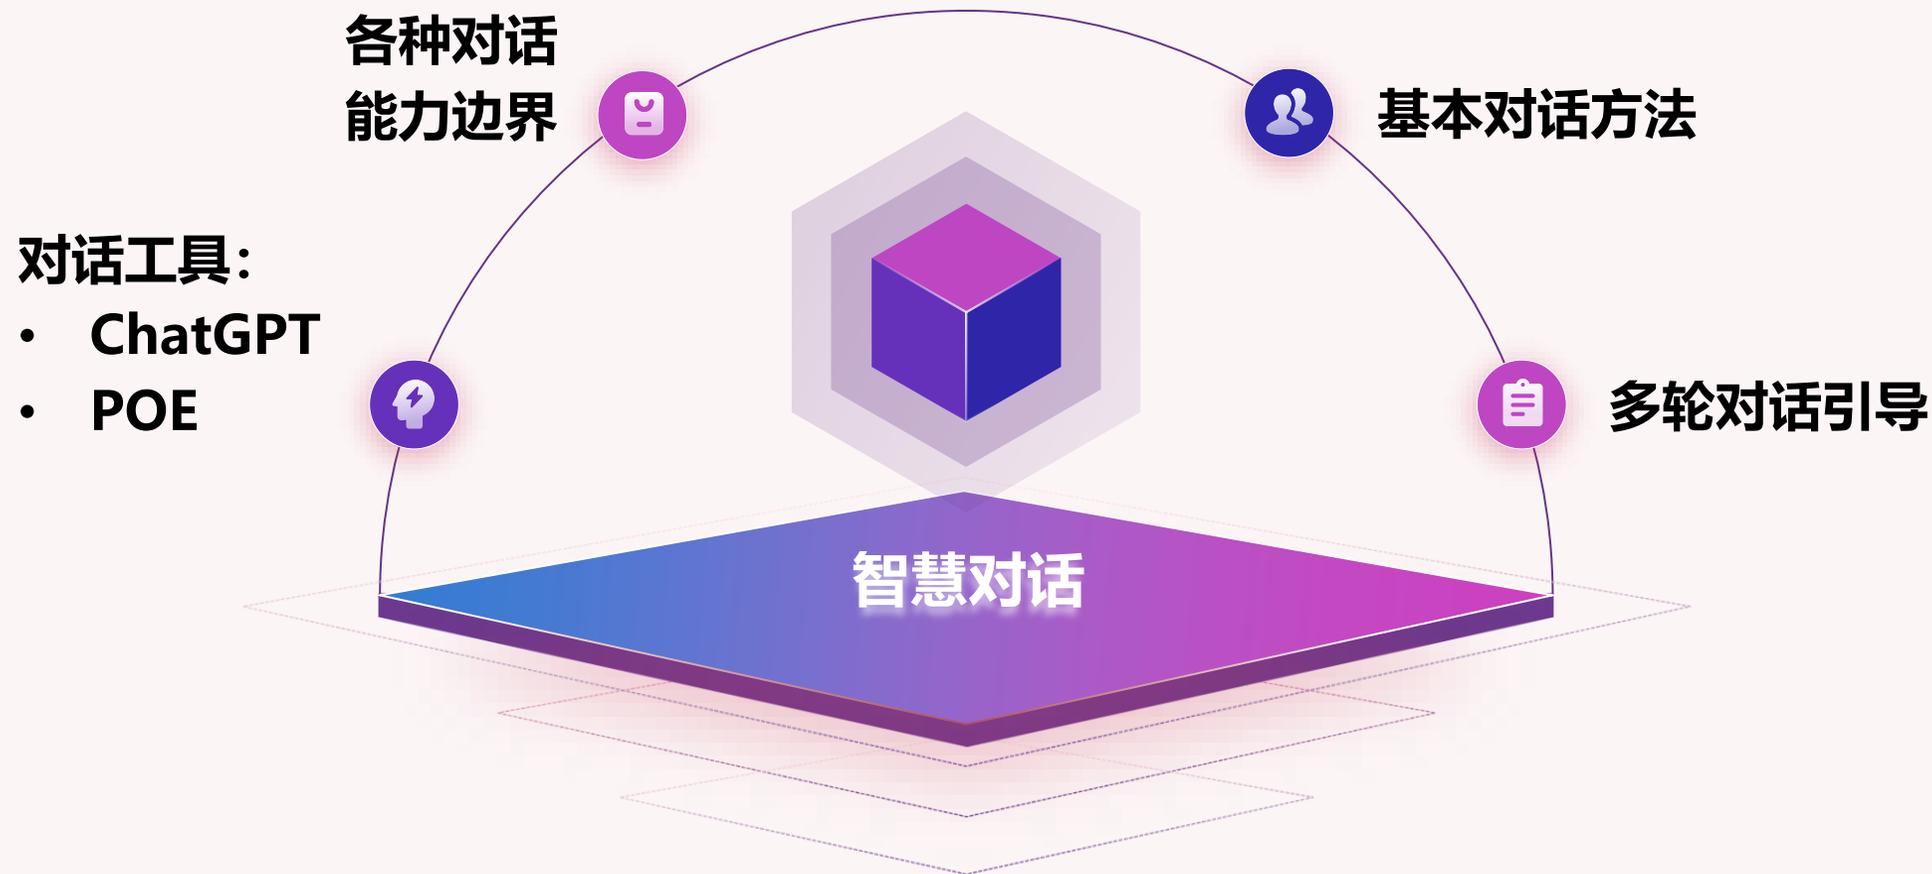
- 语言理解和生成能力
- 世界知识能力
- 一定的推理能力

VS

劣势

- 幻觉（生成错误答案）
- 知识库有限
- 上下文窗口限制

如何与GPT对话



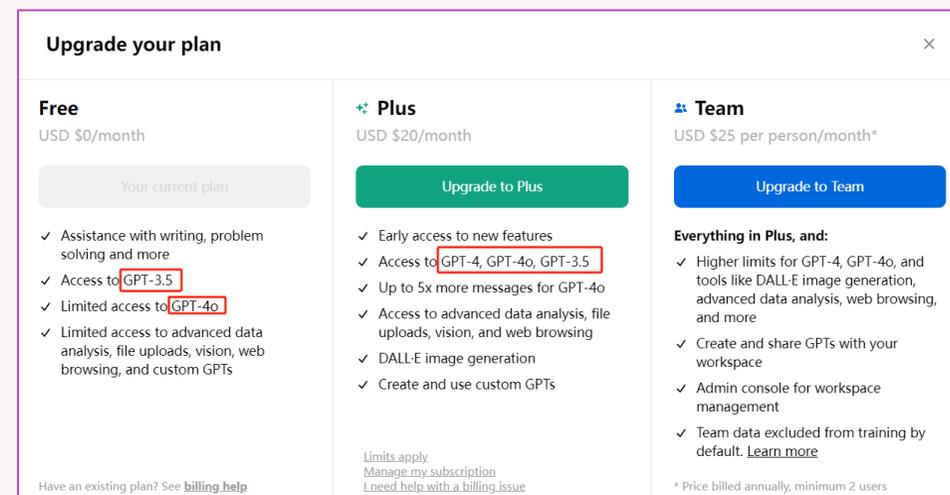
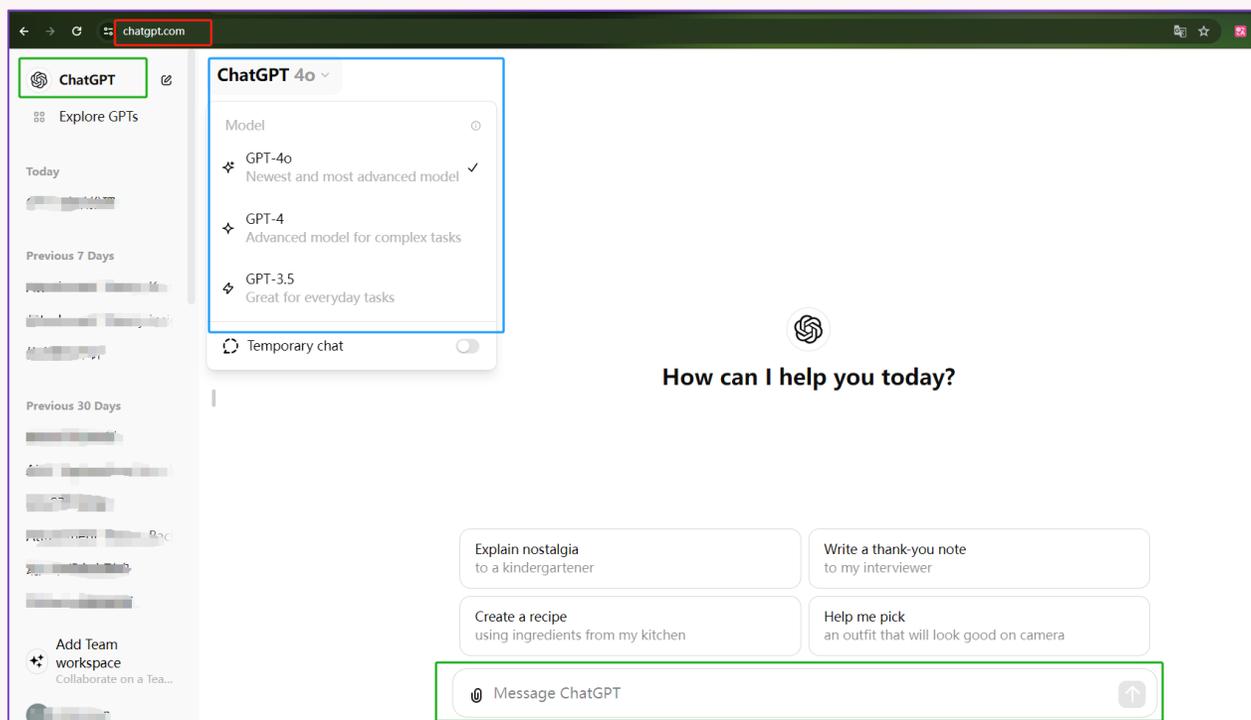
使用对话工具

ChatGPT: 聊天机器人应用

访问地址: <https://chatgpt.com/>

GPT: 大语言模型

GPT-3.5、GPT-4o



原理

- 上下文编码
- 自注意力机制



限制

上下文窗口限制

- 问题+回答总数
- 包括字符、标点、空格

- GPT-3.5: 4096, 大约3000 个英文单词或 4000 个汉字
 - GPT-4: 8192, 大约6000 个英文单词或 8000 个汉字
- (<https://platform.openai.com/tokenizer>)

使用建议

- 分段对话
- 定期总结
- 使用关键词提醒
- 精简输入

对话能力-语言转换能力

不同语言

- 人类语言之间转换
- 机器语言之间转换
- 人类语言与机器语言之间转换

限制

- 人类语言生成能力不同
前5名：英语、西班牙语、法语、德语、中文
- 机器语言生成能力不同
前4名：python、Java、Typescript、Javascript

使用建议

- GPT:使用英文
- 中文优先选择国内产品
- 编程尽量选用前4种语言

对话能力--意图和情感分析能力



能力

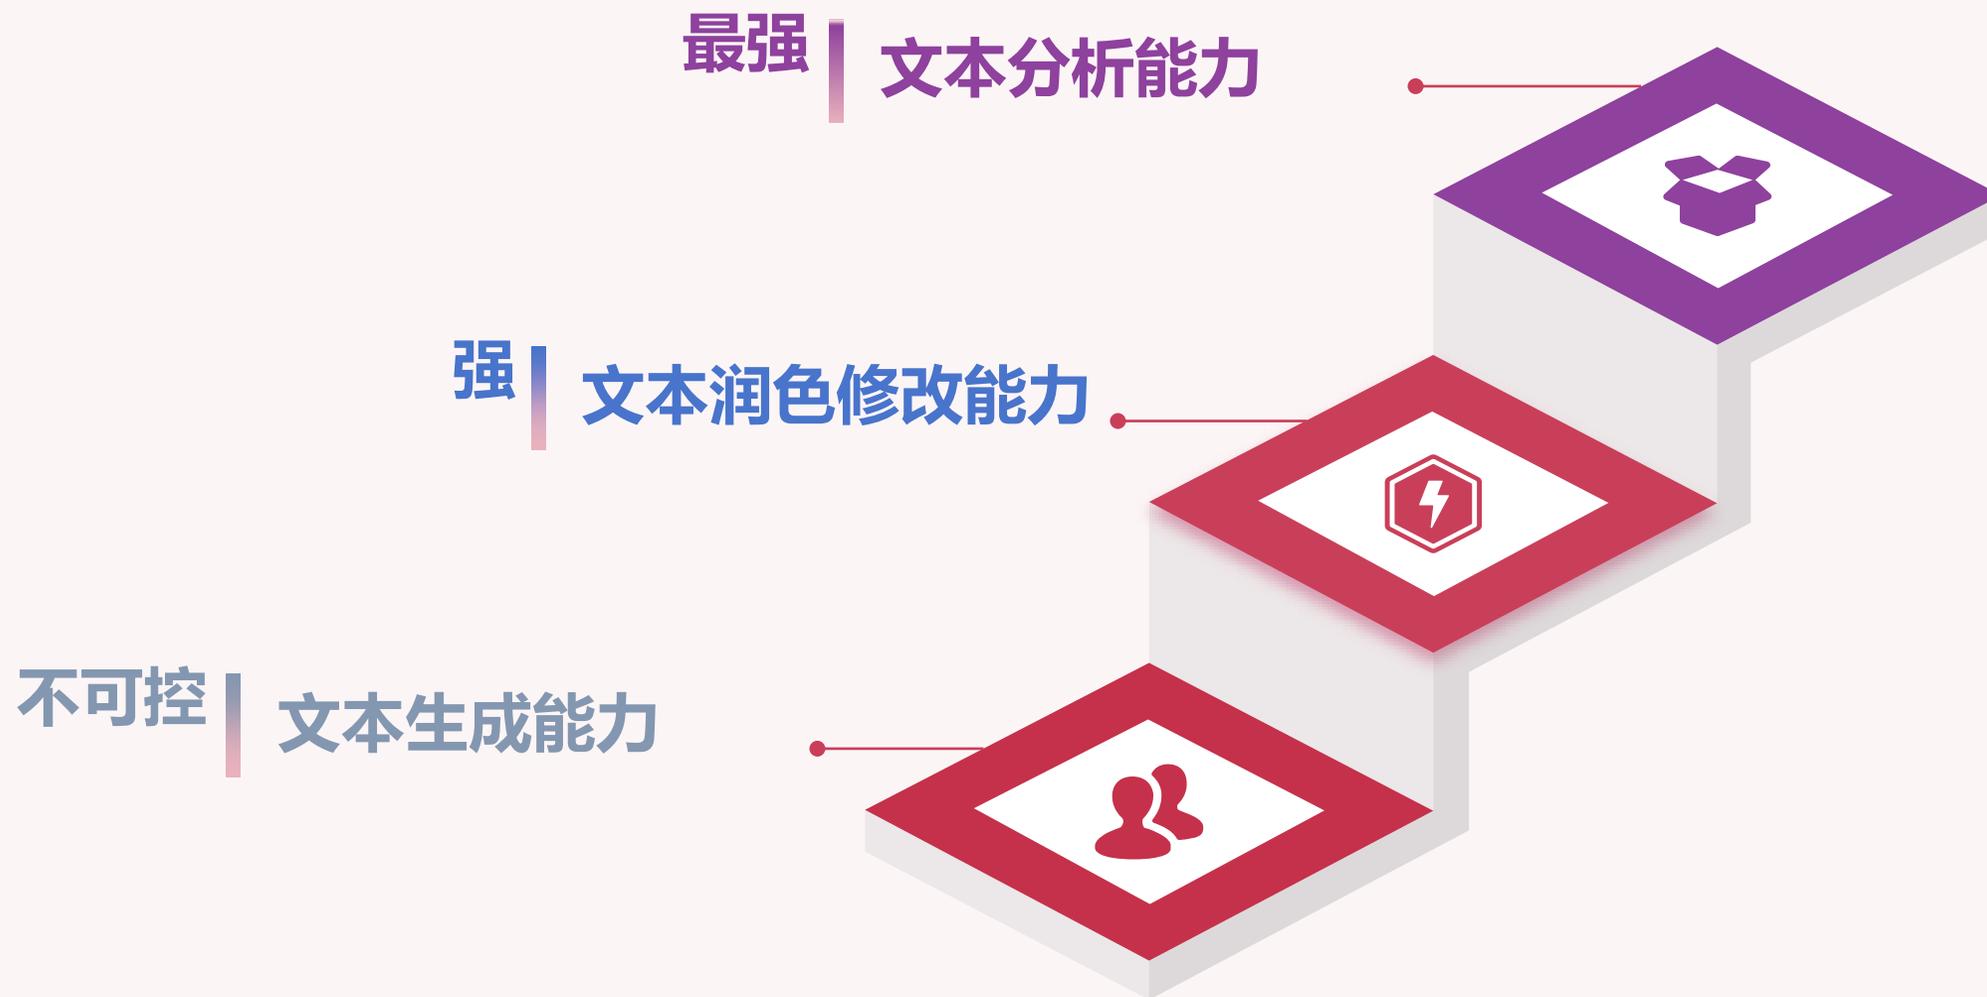
- 真实意图
- 情绪识别
- 判断行为特点
- 重要他人

限制

- 缺乏真正的情感
- 上下文理解有限
- 缺乏深层次推理

使用建议

- 提供清晰具体的信息
- 简短和连贯的对话
- 使用明确的情感表达





文本统计

- 统计字符数、单词数、句子数等基本统计信息



文本摘要

- 从长文档中提取主要信息，并生成一个简短的概述



文本分类

- 新闻分类、情感分析（正面、负面、中性）



文本总结

- 文本的整体内容进行简要概述，通常比文本摘要更为简短

限制

知识更新、长文本理解、数据偏见、数据质量、语境歧义、领域专业知识、新颖和未知类别、不确定性



文本校对

- 错别字识别与修改、语法错误检查与修正、标点符号调整、词汇选择优化、语句重组与调整、保持一致的写作风格



文本改写

- 口语转书面语、不同体裁风格、语义保持、文本简化、文本优化、保持一致性



文本扩写

- 增加细节、举例说明、提供背景信息、解释专业术语或概念、描述过程或步骤、增加文学修辞、提供多种观点等

限制

新词汇与表达、语境误判、高度主观性、文化敏感性和幽默、不断更新的语言规则、知识更新限制、长文本处理能力、用户意图识别



使用优先级

- 文本分析 > 文本润色 > 文本生成



分段处理长文本



明确和具体的指示



补充背景信息



注意多义词和模糊表达



对比能力

- 对比分析：事物、概念、人物、事件、文学作品、艺术作品等



列举能力

- 简单列举任务：组合/排列/序列，简单数学问题等



假设推理能力

- 多个领域能力不同：历史事件、文学作品解读等

限制

主观判断、上下文窗口、非专业算法、数据局限、缺乏常识和领域专长、模型理解能力、过度生成偏见、难以验证答案的准确性

使用建议

- 明确问题和期望
- 补充背景信息
- 结合领域知识

基本对话



学会提问

- 明确、具体、避免歧义
- 逻辑清晰
- 上下文信息
- 示范数据



验证输出

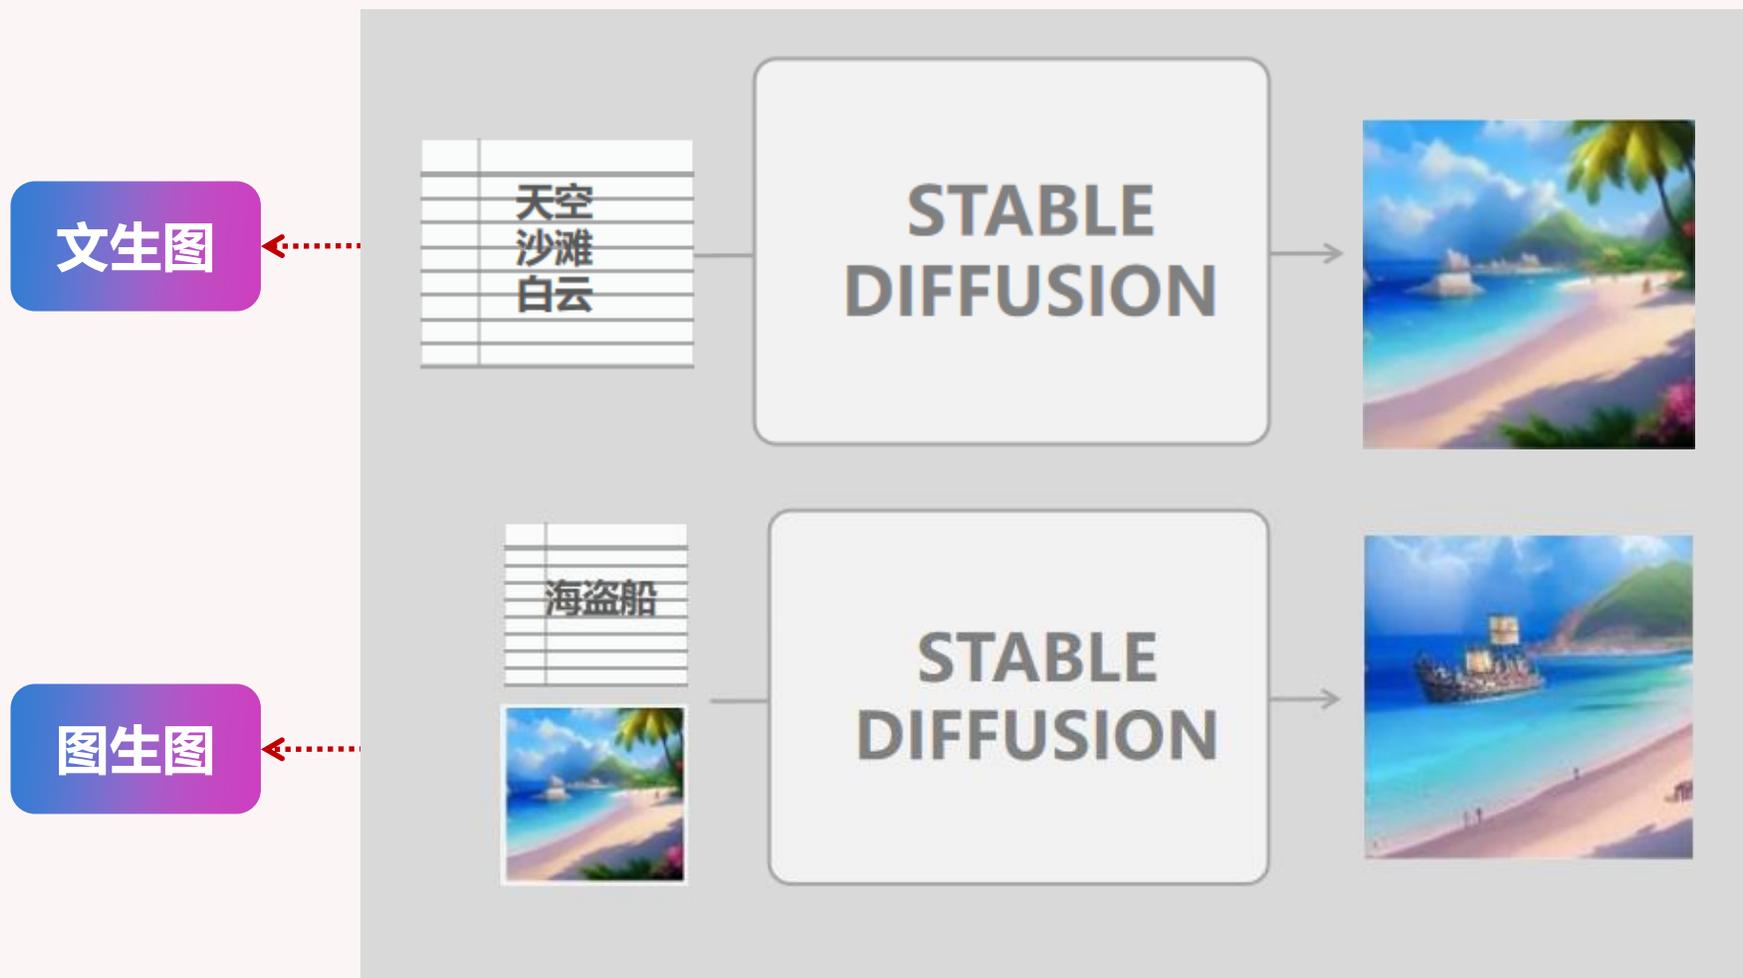
- 从回复中找到有价值的部分
- 判断结果质量：初步识别可靠信息
- 评估信息准确性：与其他来源进行对比
- 处理错误信息：指出错误，重新提问

多轮对话

- 追问
- 澄清
- 引导

图像生成的奥秘

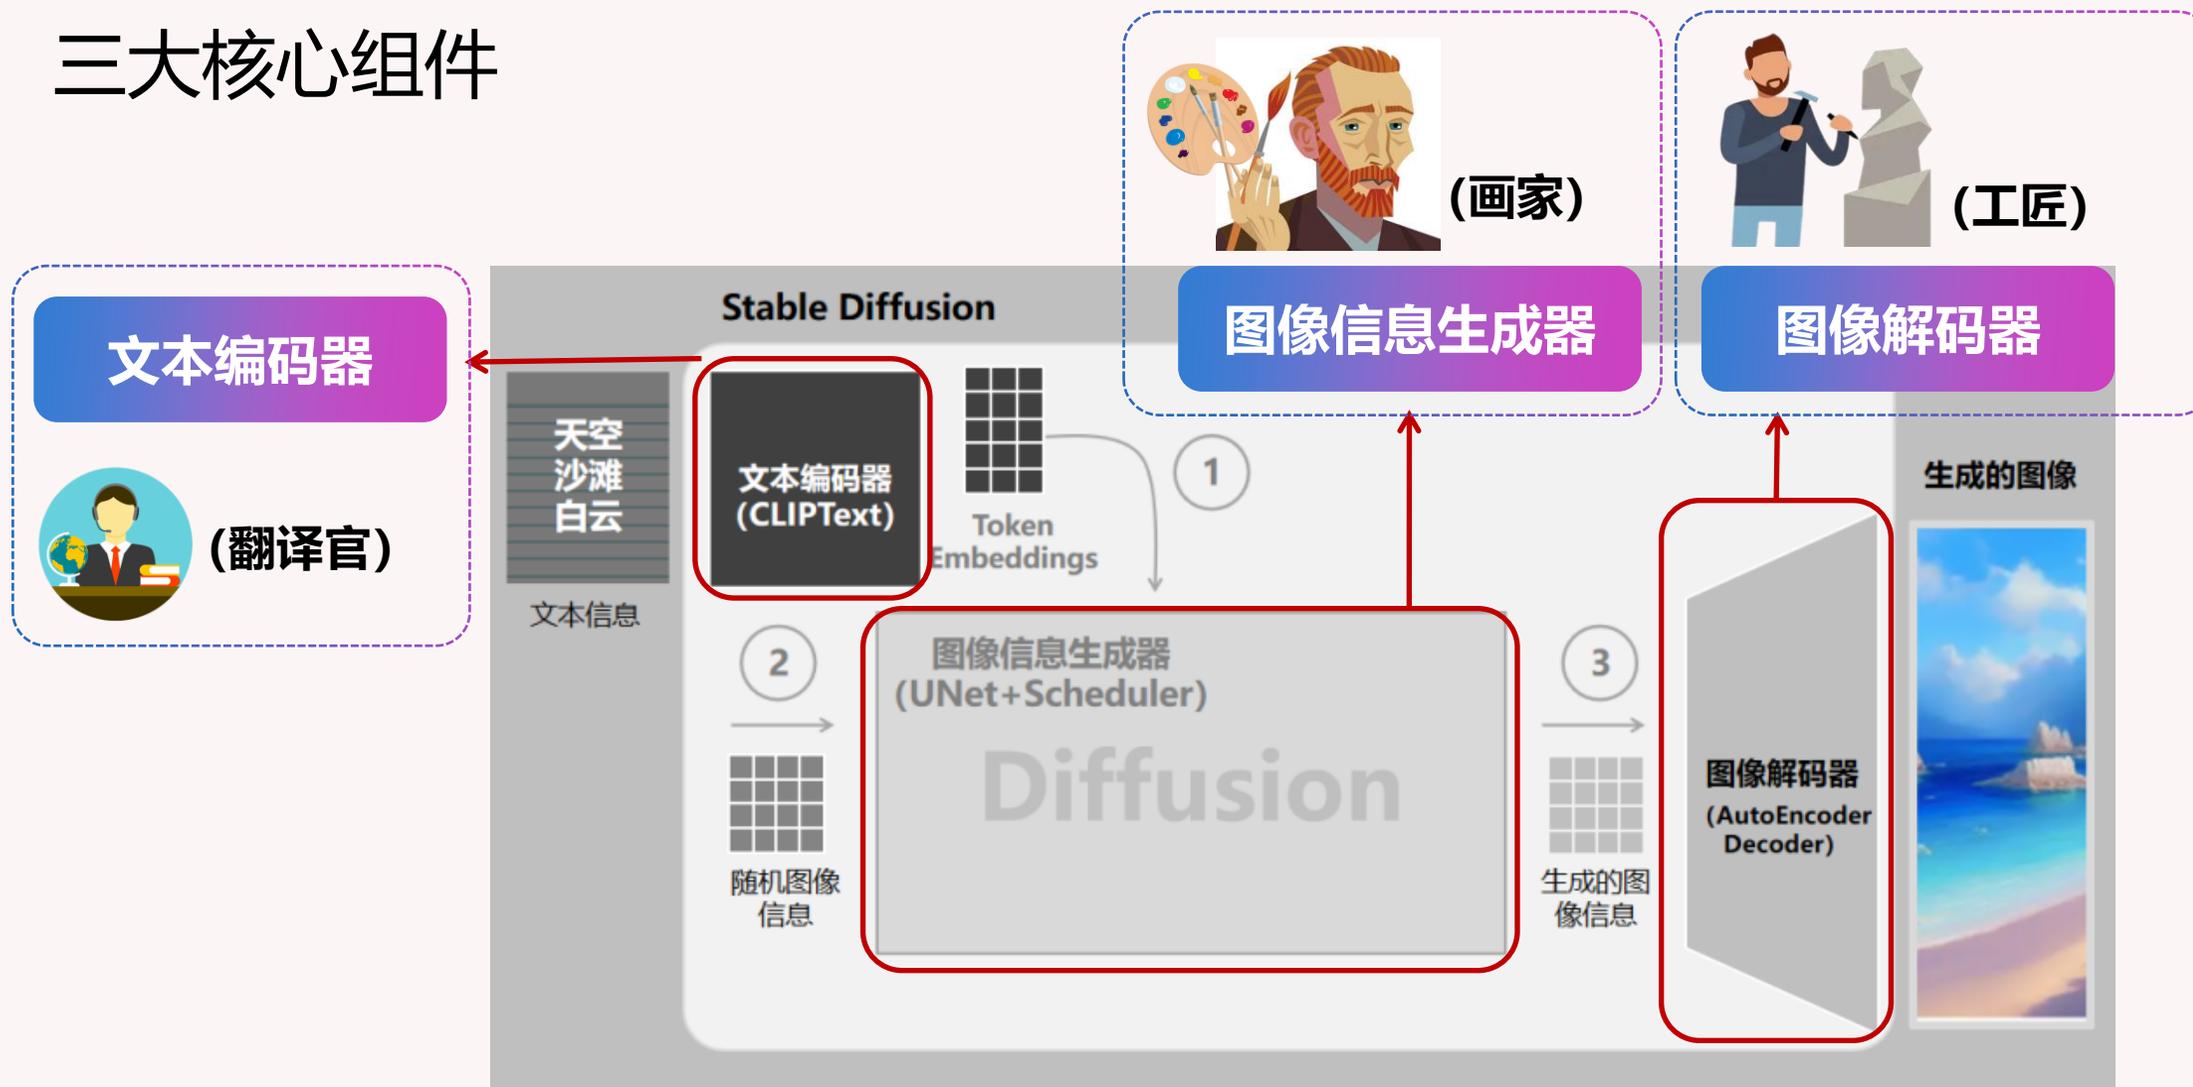
Stable Diffusion 模型如何实现图像生成?



Stable Diffusion 模型的构成

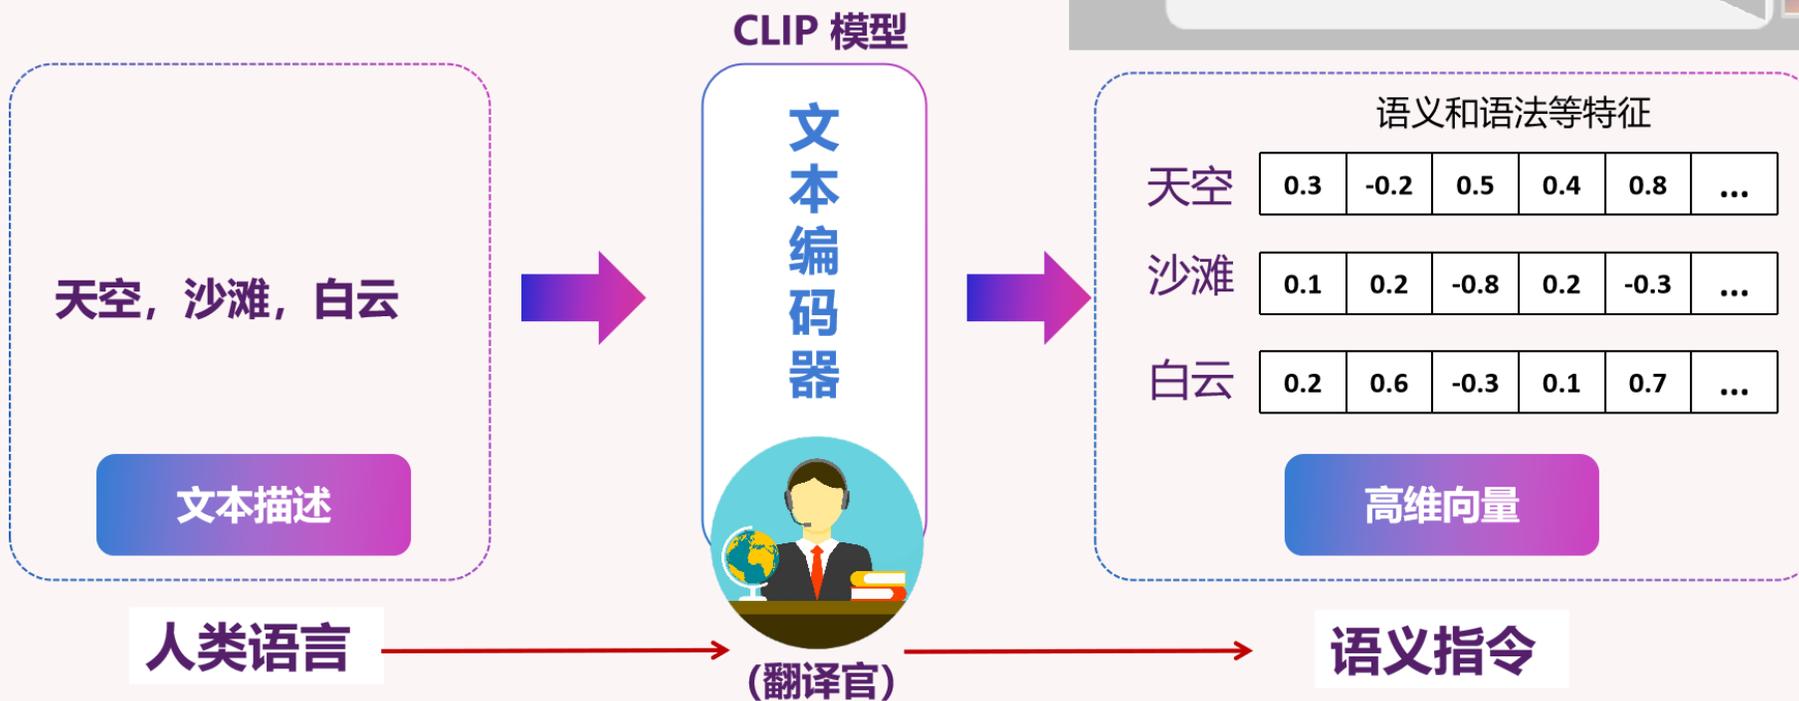
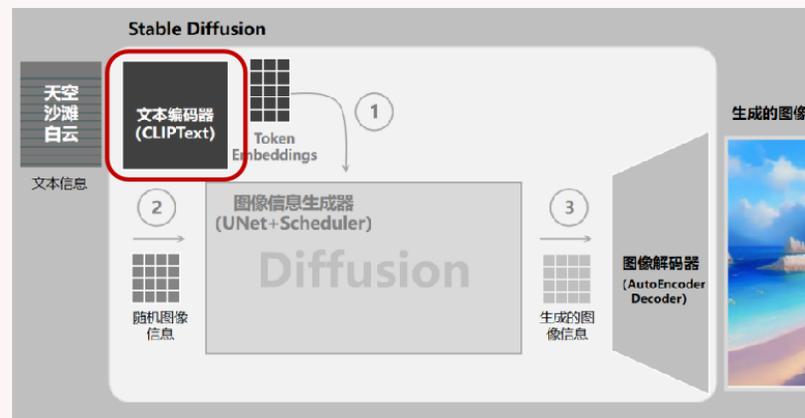


三大核心组件



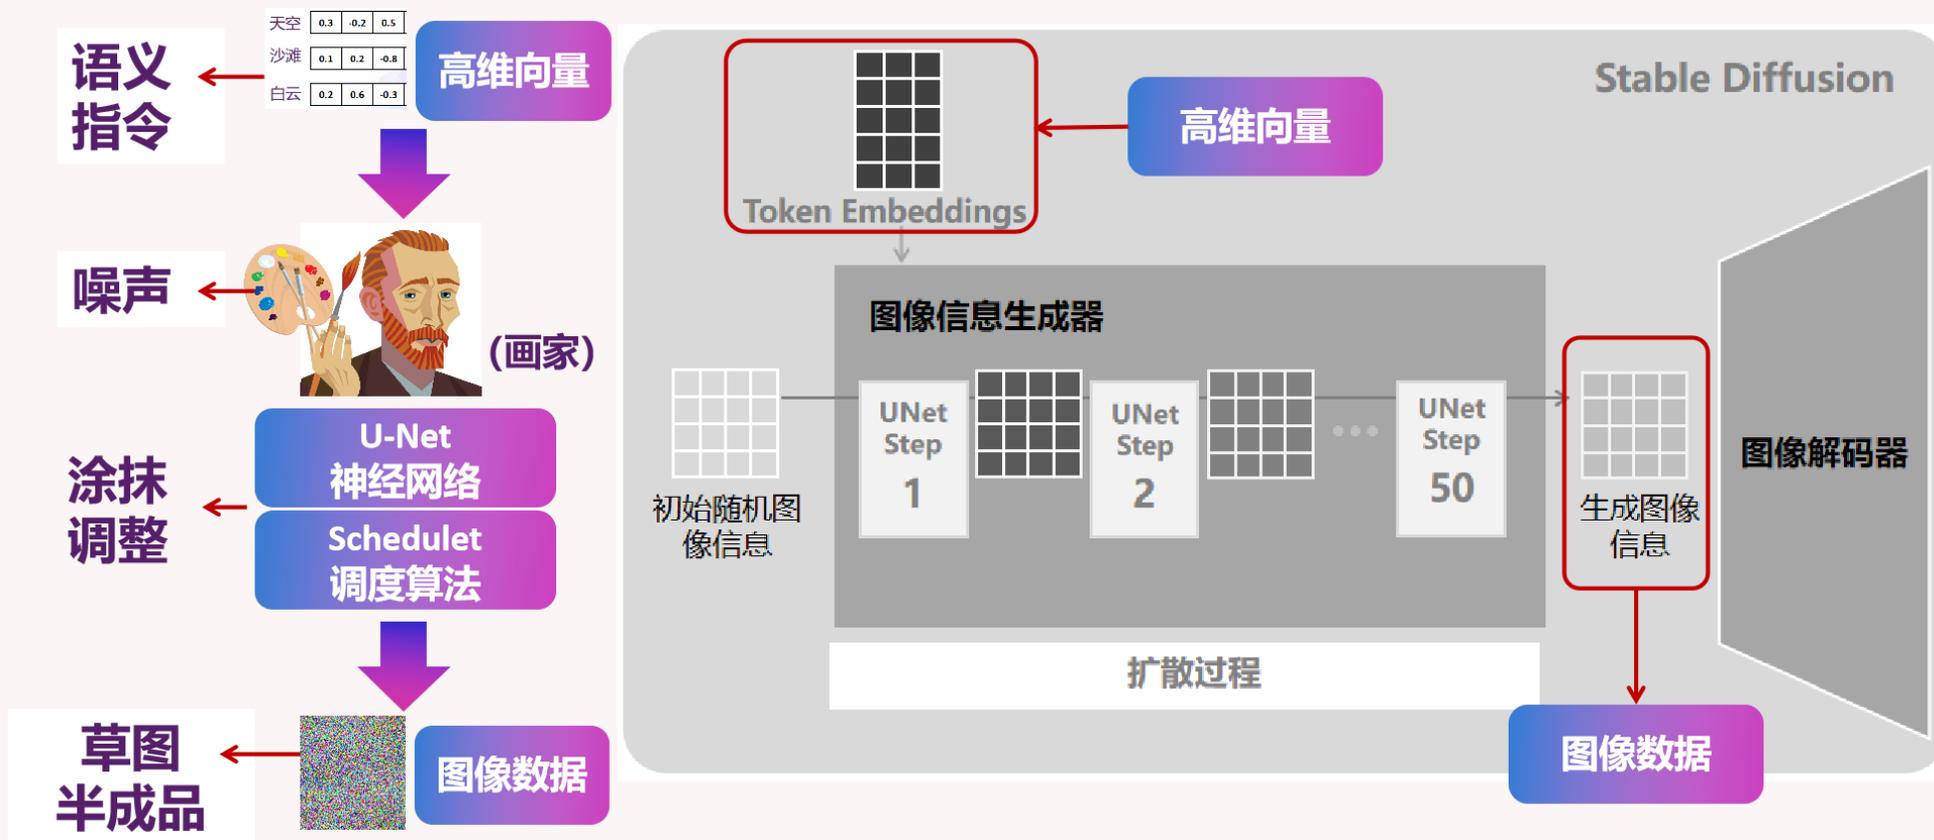
文本编码器

- 解析用户输入的提示词
- 将提示词转化为高维向量表示



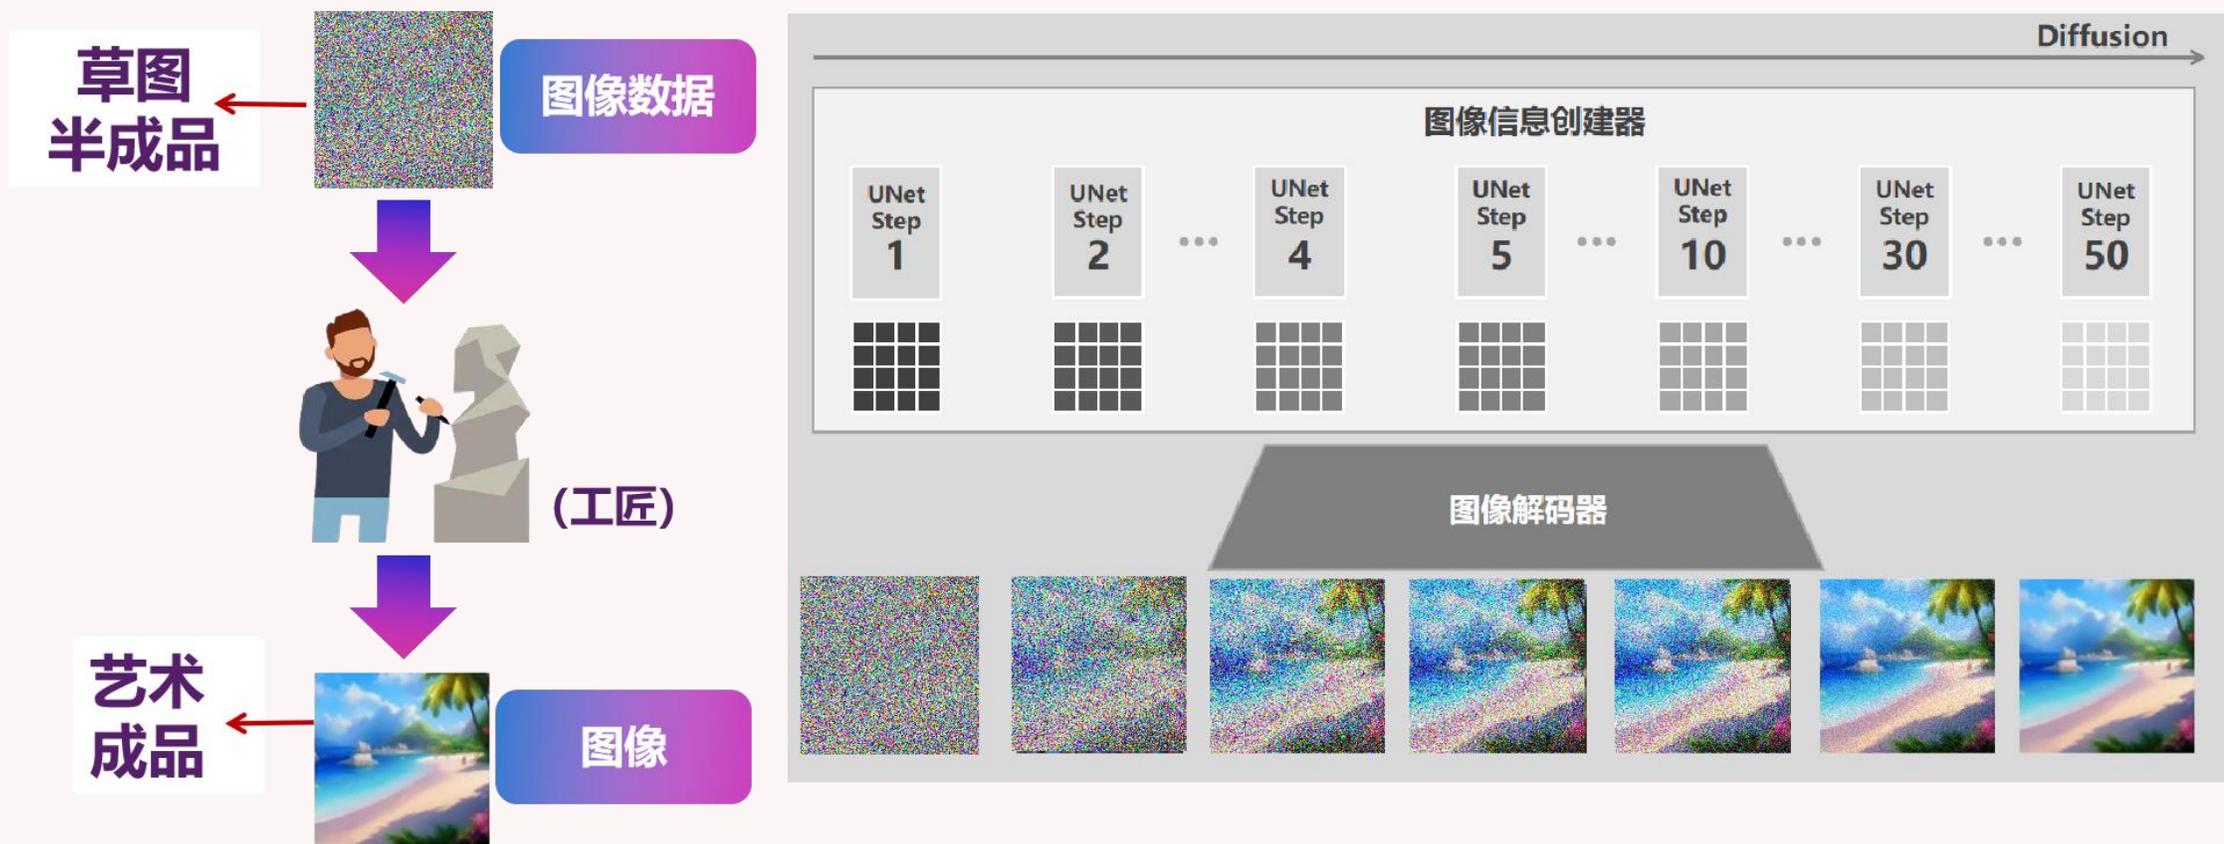
图像信息生成器

- 将输入信息逐步处理和转换为图像数据



图像解码器

- 接收来自图像信息生成器处理后的信息矩阵
- 将信息矩阵转换为可视化的图像



文生图的优势与局限

优势

- 降低门槛
- 提高效率
- 艺术风格多样化

局限

- 精确控制困难
- 随机性太强
- 复杂场景理解



PART 04 ▶

选择AIGC工具

本部分聚焦于如何科学选择和高效应用AIGC工具，以满足不同场景下的多样化需求。

首先介绍当前AIGC领域的工具类型，包括聊天对话机器人、图像生成工具、音频与视频生成工具以及搜索工具等，并列举了国内外代表性工具。

随后，以DeepSeek-R1、Kimi、豆包、腾讯元宝等具体工具为例，详细分析了它们的特点、优势及适用场景，展示了不同工具在推理能力、多模态支持、长文本处理和搜索效率等方面的差异。

最后，还提出了选择AIGC工具的依据，包括明确需求、评估工具性能和考虑使用成本等，帮助读者根据自身需求做出合理选择。通过深入分析和对比，本部分旨在为读者提供一份实用的AIGC工具选择指南，助力其在AIGC时代更好地应用人工智能技术，提升工作效率和创新能力。

AI <small>aicpb.com</small> 产品榜 · 国内增速榜					
全球排名	AI产品榜	产品名	网站(web)分类	12月上榜网站	12月上榜网站
		AI产品榜	aicpb.com	Web访问量	变化
1		腾讯混元	LLM	867.14K	351.17%
2		DeepSeek	AI ChatBots	11.01M	160.63%
3		AI 搜 百度	AI ChatBots	11.86M	93.04%
4		文心智能体平台 (百度)	Agents Platform	617.86K	82.52%
5		豆包 抖音	AI ChatBots	31.77M	48.28%
6		即梦 AI 剪映	AI Image Generator	2.19M	45.58%
7		火山方舟	Model Training & Dep	3.49M	32.84%
8		Marscode	AI Code assistant	1.11M	29.33%
9		纳米AI搜索 原360AI搜	AI Search Engine	359.33M	27.10%
10		扣子	AI ChatBots	2.16M	23.79%
11		腾讯元宝	AI ChatBots	1.54M	20.68%
12		Kimi 月之暗面	AI ChatBots	38.37M	16.93%
13		墨刀AI	AI Design Tool	2.27M	13.35%
14		亿图脑图	AI Mind Map Generatr	589.6K	11.83%
15		liblib.art	Model Training & Dep	2.4M	10.71%

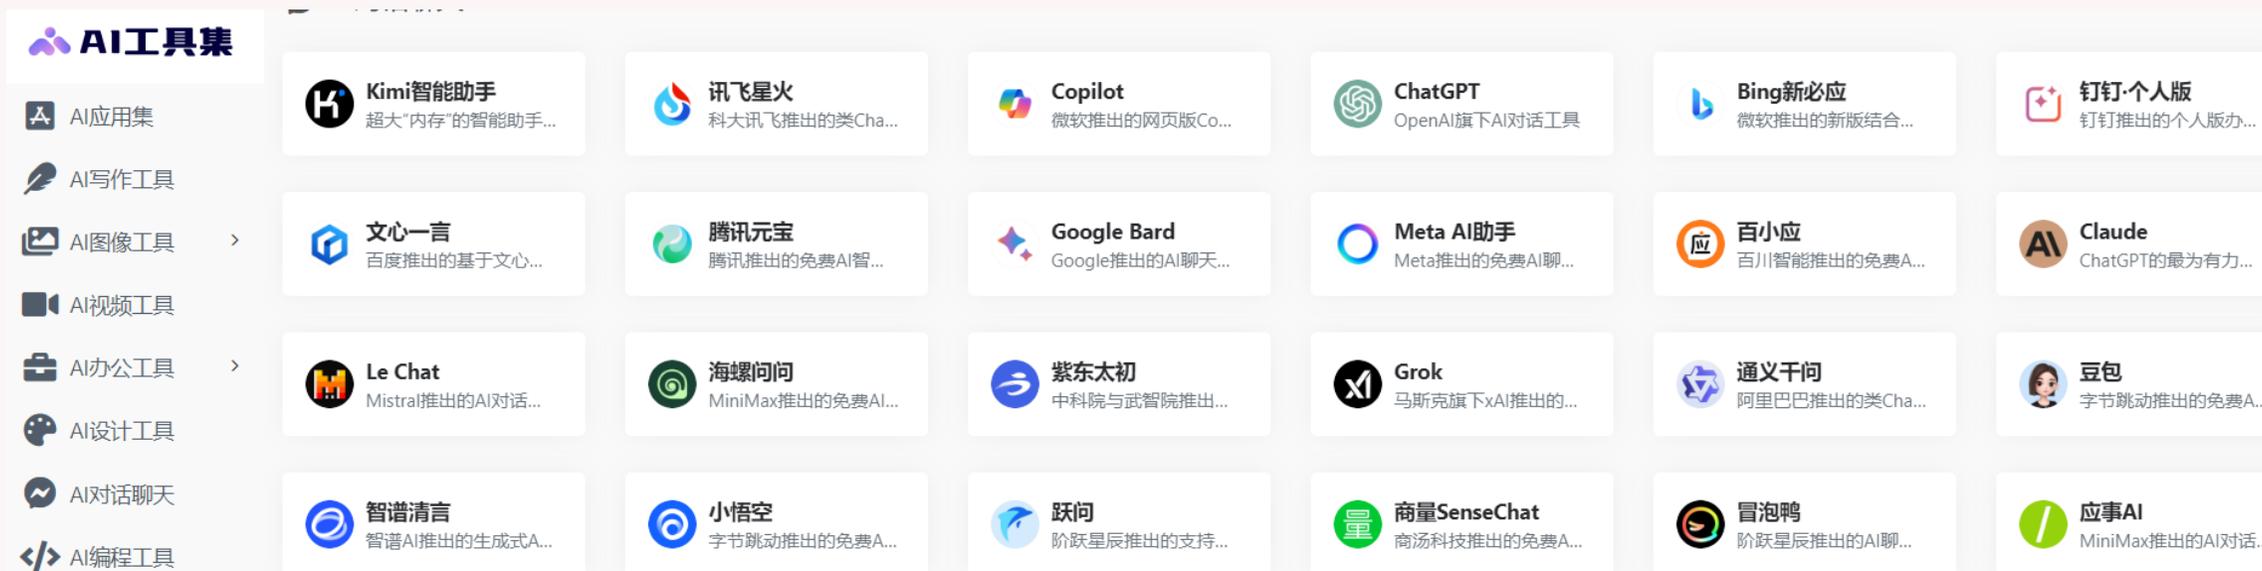
AI <small>aicpb.com</small> 产品榜 · 搜索引擎 全球					
全球排名	AI产品榜	产品名	网站(web)分类	12月上榜网站	12月上榜网站
		AI产品榜	aicpb.com	Web访问量	变化
1		New Bing	AI Search Engine	1.87B	2.31%
2		纳米AI搜索 原360AI搜	Search Engine	359.33M	27.10%
3		Perplexity AI	AI Search Engine	97.54M	-9.55%
4		秘塔AI搜索	AI Search Engine	8.32M	3.94%
5		You	AI Search Engine	5.54M	-12.36%
6		C知道	AI Search Engine	4.66M	-2.03%
7		Pimeye	AI Search Engine	4.64M	2.73%
8		iAsk.AI	AI Search Engine	4.22M	-1.41%
9		Kagi Search	AI Search Engine	3.44M	15.61%
10		Consensus	AI Search Engine	3.37M	-0.45%
11		知乎直答	AI Search Engine	3.36M	3.40%
12		GenSpark	AI Search Engine	2.76M	28.92%
13		felo.ai	AI Search Engine	2.25M	5.49%
14		Scite_	AI Search Engine	1.48M	-1.14%

公众号：AI产品榜

AIGC工具

AI工具导航平台: <https://www.aigc.cn>

AI工具集: <https://ai-bot.cn>



The screenshot displays the 'AI工具集' (AI Tools Collection) interface. On the left is a vertical navigation menu with categories: AI应用集, AI写作工具, AI图像工具, AI视频工具, AI办公工具, AI设计工具, AI对话聊天, and AI编程工具. The main area shows a grid of AI tool cards, each with a logo, name, and a brief description.

工具名称	描述
Kimi智能助手	超大“内存”的智能助手...
讯飞星火	科大讯飞推出的类Cha...
Copilot	微软推出的网页版Co...
ChatGPT	OpenAI旗下AI对话工具
Bing新必应	微软推出的新版结合...
钉钉·个人版	钉钉推出的个人版办...
文心一言	百度推出的基于文心...
腾讯元宝	腾讯推出的免费AI智...
Google Bard	Google推出的AI聊天...
Meta AI助手	Meta推出的免费AI聊...
百小应	百川智能推出的免费A...
Claude	ChatGPT的最为有力...
Le Chat	Mistral推出的AI对话...
海螺问问	MiniMax推出的免费AI...
紫东太初	中科院与武智院推出...
Grok	马斯克旗下xAI推出的...
通义千问	阿里巴巴推出的类Cha...
豆包	字节跳动推出的免费A...
智谱清言	智谱AI推出的生成式A...
小悟空	字节跳动推出的免费A...
跃问	阶跃星辰推出的支持...
商量SenseChat	商汤科技推出的免费A...
冒泡鸭	阶跃星辰推出的AI聊...
应事AI	MiniMax推出的AI对话...

工具类型	国内	国外
聊天对话机器人	DeepSeek、腾讯元宝、豆包、Kimi、智谱清言...	ChatGPT, Claude, X.com (Grok)
图像生成工具	通义万相、即梦、豆包	ChatGPT, Midjourney, Stable Diffusion
音频工具	音疯、网易天音、海绵音乐	Suno
视频生成工具	SkyReels、Vidu、可灵、海螺AI、即梦	Sora, Runway, Pika
搜索工具	秘塔、纳米AI、天工	Perplexity

AIGC工具现场演示

腾讯元宝 <https://yuanbao.tencent.com/>

有问题，尽管问，shift+enter换行

DeepSeek ▾

深度思考(R1) •

联网搜索 •



AIGC工具现场演示

豆包 <https://www.doubao.com>

你好，豆包

让我们一起度过美好的一天！

AI 搜索

搜索最新资讯，让信息搜集效率翻倍

图像生成

按照你的想象，生成各类风格的图像

帮我写作

提供写作灵感，驾驭各类体裁和风格

阅读总结

速读各类文章，迅速了解摘要和洞察

试试这些例子

Q

京东近期为整治“大企业病”都做了什么？

Q

一位半人半机器的女孩，她通过电缆与一台巨大的计算机相连

Q

关于“端午出游”的小红书文案

Q

发布版InfoQ大模型测评报告2024.pdf

帮我写作

图像生成

AI 搜索

PDF 问答

翻译

网页摘要

更多

📎

发消息、输入 @ 或 / 选择技能

↑

内容由豆包大模型生成，不能完全保障真实

赛博朋克风格的城市街头，霓虹灯闪烁，街上的人们，穿着奇特



重新生成

AIGC工具现场演示

Kimi <https://kimi.moonshot.cn/>



Hi, 我是 Kimi ~
很高兴遇见你! 你可以随时把网址🌐或者文件📄发给我, 我来帮你看看

请整理这本书的核心内容

LLMBook
PDF, 10.3 MB

⚠️ 超出字数限制, Kimi只阅读了前44%

这本书《大语言模型》由赵鑫、李军毅、周昆、唐天一和文继荣著作, 主要围绕大语言模型 (Large Language Models, LLMs) 的技术进展、理论基础、关键技术、以及应用实践进行了全面介绍。以下是书中的核心内容概述:

1. **大语言模型的发展历程:** 从统计语言模型到神经网络语言模型, 再到预训练语言模型, 直至大语言模型的崛起, 书中详细回顾了语言模型的演进历程。
2. **大模型技术的背后技术:** 深入探讨了支撑大模型的技术, 包括Transformer架构、预训练任务的设计、模型的可扩展性等。
3. **OpenAI的技术变革:** 分析了OpenAI在大模型技术发展中的作用, 特别是GPT系列模型的研发历程, 以及其在技术进步中的关键贡献。
4. **大模型训练的挑战:** 讨论了训练大模型时面临的算力限制、数据质量与规模的重要性, 以及科研人员面临的算力、数据、人才等挑战。

超长上下文
一次性阅读50份文档
支持20万字上下文输入



Hi, 我是 Kimi ~
很高兴遇见你! 你可以随时把网址🌐或者文件📄发给我, 我来帮你看看

帮我找10篇最近一年内关于AI人才用人需求的报告

找到了 10 篇资料作为参考: ▾

您好, 我找到了一些关于AI人才用人需求的最新报告, 以下是部分摘要和链接:

1. 麦肯锡全球人工智能最新调研: AI在中国企业的落地进展如何... 1
2. 全球AI人才报告: 清华第三, 北大第六, 硅谷40万人... 2
3. 清华AI人才报告: AI专业高校两年翻四倍... 3
4. 2024年中国人工智能行业人才供需情况分析: 人才短缺现象存在... 4
5. 在华企业如何填补AI人才缺口: 麦肯锡大中华区报告 5
6. 2024年中国人工智能行业人才供需情况分析: 人才短缺现象存在... 6
7. 工业和信息化部人才交流中心: 《人工智能产业人才发展报告(2019-2020年)》 7
8. 猎聘发布《AIGC及其产业链人才需求大数据报告2023》: 猎聘报告 8
9. 人工智能全域变革 图景展望: 跃迁点来临(2023): KPMG报告 10

这些报告覆盖了AI人才的全球分布、中国AI人才的培养和需求、以及企业如何填补AI人才缺口等主题。您可以点击链接获取更详细的内容。

网络搜索
提高搜索效率
减少幻觉

AIGC工具现场演示



功能：

- 总结网页或PDF文档
- "去Kimi继续对话"



适用：

- 长视频内容 (B站/youtube) 的总结
- 新闻报道
- 行业报告



全网最详细: OpenAI GPT-4o多模态大模型深度解读 #大模型 #OpenAI #GPT-4o

关于本内容

1. OpenAI 春季发布: GPT-4o (o for omni)
2. 相关技术回顾: Whisper v3 - SORA - GPT4
3. GPT-4o 技术畅想: E2E 多模态大模型
4. 看大模型趋势: 百模厂商的冲击 && 产业思考

行业影响与思考

1. 大语言模型 (LLM): 进入瓶颈期, 未来可能更多关注应用层面。
2. 多模态 (MM): 2024年成为多模态元年, 国内外巨头积极布局。
3. 百模大战: 国内厂商在多模态领域布局较少, 需加快认知迭代速度。
4. 计算产业: 多模态大模型对服务器算力和推理芯片有新需求。

结语

- 鼓励观众访问OpenAI官网, 了解最新技术发展。
- 视频PPT将在AI system的第6 foundation部分提供, 介绍大模型热点和新模型内容。

附加信息

- 视频链接: BV1Uy411Y76z

这份笔记总结了视频的核心内容, 包括GPT-4o模型的特点、技术细节、行业影响以及对未来的思考。希望这份笔记能帮助您更好地理解视频内容。

去Kimi继续对话 复制 反馈

Kimi Copilot插件

AIGC工具现场演示

音乐工具：音疯 <https://www.yinfeng.cn/create>



AIGC工具现场演示

视频生成工具: Vidu <https://www.vidu.cn/>



一个3D形象的男孩, 穿着飞行夹克, 在公园滑滑板



AIGC工具现场演示

搜索工具：秘塔 <https://metaso.cn>

 秘塔AI搜索

没有广告，直达结果

今年最热门的科技产品或应用程序有哪些？

● 全网 长思考-R1

简洁

深入

 研究

今年最热门的科技产品或应用程序有哪些？

[全网](#) [文库](#) [学术](#) [图片](#) [播客](#)

 10

来源

今年最热门的科技产品和应用程序包括：

1. **AI眼镜**：在CES 2025大会上，AI眼镜成为焦点，多家厂商如雷鸟创新、歌尔股份、仙瞬科技等推出了新款智能眼镜产品。例如，雷鸟创新发布的雷鸟V3 AI拍摄眼镜集成了多种功能，包括翻译、AI识别和音乐等 [\(1 PDF\)](#) [\(6 PDF\)](#)。
2. **虚拟现实 (VR) 和增强现实 (AR) 技术**：这些技术正在改变游戏、教育、医疗等领域，提供更高分辨率和更低延迟的沉浸式体验 [\(4\)](#)。

社会服务行业投资分析

超配 (维持) ——2025

 最新科技产品有哪些



如何选择AIGC工具

1. 明确自身需求

2. 评测工具能力

3. 关注使用成本

AIGC工具	工具特点	大模型
DeepSeek	文本模态、推理能力强	DeepSeek-R1
豆包	多模态、语音情感能力强	火山
Kimi	多模态、超长文本、搜索和推理能力强	Kimi-1.5
智谱清言	多模态	GLM-Zero-Preview
通义千问	效率工具、代码能力强	Qwen2.5-Max
腾讯元宝	可以使用微信生态	接入：DeepSeek-R1



1. 明确使用AI工具的需求和目标

2. 建立使用清单

- 文本类、绘图类、视频类、语音类、搜索类、设计类、专用工具类（办公类、笔记类、内容转化类...）、智能体类
- 以1~2个为主，其它为辅

3. 真实使用中测试和筛选

4. 保持2-3周的更新频次

AIGC技术正在重塑各个行业的未来，从内容创作到科学研究，从教育到商业应用，潜力无限。然而，技术的快速发展也带来了新的挑战，面对这些挑战，我们需要保持开放的心态，积极学习AIGC的基础知识，关注其在各行业的应用案例，跟踪最新发展趋势。

与AI共舞，实现AI与人类的完美融合。

让我们以DeepSeek-R1为起点，持续探索AIGC的无限可能。

在AI时代的技术浪潮中，我们既是见证者，更是参与者。



谢谢