


AI大模型竞赛方兴未艾，OpenAI与DeepSeek引领行业生态重构

——半导体行业深度报告（十二）

投资要点：

- **2024年全球AI市场规模有望达到6.16万亿美元，同比增长30.1%，2027年有望扩张至11.64万亿美元，CAGR为23.65%。**AI概念于1956年达特茅斯会议首次提出，是一种模拟人类智能的技术，按照智能程度划分，主要分为狭义人工智能、通用人工智能和超级人工智能，目前通用人工智能还处于理论阶段。AI具有算力、算法、数据三大要素，算法决定了AI如何处理数据和解决问题，数据决定了算法是否能得到有效的训练和优化，算力提供了执行算法和处理数据所需的计算资源。从AI产业链看，整体涵盖基础设施层、模型层、平台层、应用层及服务层多个环节，基础设施层主要包括与芯片、计算、存储、网络、软件、连接与通信等多个上游领域，模型层可分为通用大模型、行业大模型等。根据Frost & Sullivan，自2020年起，全球AI市场规模以高于20%的同比增速呈现迅猛增长的态势，从2019年的1.91万亿美元有望扩张至2024年的6.16万亿美元，同比增速逐年上升，整体市场有望在2027年扩张至11.64万亿美元，体现出全球AI行业井喷式的发展速度。
- **未来五年全球大模型行业市场规模的CAGR有望达到36.23%，AI Agent或将成为继API调用和模型推理部署后新的商业化形式，大模型行业竞争格局也将逐步收敛至头部厂商。**AI大模型作为AI产业链中的核心环节，经过大规模数据和强大的计算能力训练，通常具有高度的通用性和泛化能力，可以应用于自然语言处理、图像识别、语音识别等领域。深度学习是机器学习的重要分支，主要涵盖预训练、后训练、推理等阶段，Scaling Law是预训练阶段驱动模型进步的第一性原理，“涌现”现象进一步证明了模型参数量、数据、计算量大小对于模型性能提高的重要性。大模型的商业化落地形式主要包括通过API调用收费以及定制化的模型推理部署，前者市场价格竞争较为激烈，后者是国内的核心业务模式，尤其是云端部署，从金额来看，在政务、教科领域落地的大模型项目较多。随着AI Agent发展，未来基于结果和价值创造的商业模式有望逐步落地。从行业供给格局看，大模型竞争日趋白热，模型之间差距逐步缩小，护城河不清晰，厂商需要持续大量投入，海内外竞争格局都将逐步收敛至头部厂商，部分规模较小的模型厂商或聚焦于垂直化的细分场景。
- **GPT与OpenAI o1系列模型分别验证了算力投入在训练侧和推理侧的重要性，而DeepSeek通过创新性的训练方法和架构实现了较低的模型训练成本，在未来大模型不断创新迭代的背景下，性能提升与成本下行或成为两条重要主线。**基于GPT-3.5的ChatGPT的发布推动了AI技术的普及和AI产业的变革，是人工智能的重要里程碑之一。ChatGPT的创始人OpenAI自成立起先后发布了GPT系列模型和以OpenAI o1、o3为代表的深度推理模型，GPT系列模型注重预训练阶段的Scaling Law，整体来说更适合解决通识类知识，目前已经迭代至GPT-4系列，从最初单一的文本模态迭代成为多模态大模型，参数规模、训练数据、上下文窗口大小相比前代呈指数级增长，模型性能相应也有显著提升。OpenAI o1模型引入了思维链，证明了推理侧的算力资源投入同样重要，Scaling Law在推理阶段或同样适用，未来，GPT系列与o1为代表的深度推理系列模型或将互相补充。近期，DeepSeek大模型的发布进一步拉动了AI热潮，DeepSeek-R1发布后仅用七天用户增长一亿，海内外头部厂商纷纷入场布局。DeepSeek-V3性能对齐海外领军闭源模型，但依靠引入MLA机制和创新性的DeepSeekMoE架构实现了远低于行业平均的训练成本和定价。DeepSeek-R1在后训练阶段大规模使用了强化学习技术而不依赖监督微调，性能对齐OpenAI-o1正式版，同时证明了蒸馏技术能够将大模型的推理能力转移到更小的模型上，提升它们的表现。



相关研究

1. 乐鑫科技(688018): AIOT次新品显著放量，产品矩阵拓展布局新市场——公司深度报告
2. 海外科技股2024Q4业绩持续回暖，DeepSeek大模型引燃AI云与端热情——半导体行业2月份月报
3. AI大模型风起云涌，半导体与光模块长期受益——半导体行业深度报告（十）

- **投资建议：**AI大模型时代下，AI算力需求高速扩张，从而驱动AI芯片、存储、服务器、光模块、PCB等上游产业链半导体板块的需求快速增长，相关标的有望长期受益。（1）云端AI芯片板块关注寒武纪、海光信息、龙芯中科等；（2）端侧AI芯片板块关注恒玄科技、乐鑫科技、中科蓝讯、晶晨股份、瑞芯微、全志科技、炬芯科技、国科微等；（3）存储板块关注兆易创新、佰维存储、德明利、江波龙、澜起科技、东芯股份、聚辰股份、普冉股份、北京君正等；（4）光模块、光器件、光芯片板块关注中际旭创、天孚通信、新易盛、光迅科技、源杰科技等；（5）PCB板块关注鹏鼎控股、胜宏科技、深南电路、沪电股份、东山精密、景旺电子等；（6）服务器（含液冷）板块关注浪潮信息、工业富联、紫光股份、中石科技、光迅科技、川环科技、国芯科技等；（7）电源板块关注麦格米特、光宝科技、中国长城、新雷能、欧陆通等。
- **风险提示：**（1）AI需求不及预期风险；（2）行业竞争过度风险；（3）国际贸易政策的变化风险。

正文目录

1. AI 市场高速扩张，有望引领新一代工业革命 6

1.1. AI 推动生产变革，行业步入蓬勃发展期 6

1.2. AI 产业链涵盖基础设施到应用落地多个环节 8

2. AI 大模型是 AI 变革的重要环节之一 10

2.1. “Scaling Law” 驱动大模型不断进步 10

2.2. 大模型商业化模式有望通过 AI Agent 实现转型 14

2.3. 大模型竞争日趋白热，未来玩家格局或将逐步收敛 18

3. 大模型创新迭代，性能提升与成本下行或成为两条主线 23

3.1. GPT 与 o1 验证了训练侧和推理侧算力投入的重要性 23

3.2. DeepSeek 创新性地实现了成本更低的训练 26

3.3. AI 大模型产业链半导体相关重点厂商梳理 32

4. 投资建议与风险提示 37

4.1. 投资建议 37

4.2. 风险提示 37

图表目录

图 1 人工智能发展历程 6

图 2 按智能程度划分的三类人工智能..... 7

图 3 Gen AI 的工作原理 7

图 4 Gen AI 在各领域的应用效果..... 7

图 5 AI 的三大要素 8

图 6 AI 算力的相关常用名词及其含义 8

图 7 AI 产业链 8

图 8 全球 AI 市场规模（十亿美元）及同比增速..... 9

图 9 头部主要厂商大模型迭代时间轴..... 10

图 10 MLLM 的架构示意图 11

图 11 训练与推理示意图..... 11

图 12 模型性能与计算量、数据大小、参数数量的关系 12

图 13 大模型的涌现现象 12

图 14 GPT 系列模型迭代参数规模的变化..... 13

图 15 海外云厂商 2024Q1-Q4 资本开支（亿美元） 13

图 16 2020-2029E 全球大模型市场规模（亿美元）及增速 14

图 17 大模型商业化模式 15

图 18 模型推理部署四种主要形式的优劣 17

图 19 2024 年国内各行业大模型公开披露的落地项目数量（单位：个） 17

图 20 2024 年国内各行业大模型公开披露的落地项目金额（单位：亿元） 17

图 21 字节跳动 Coze 智能体创建界面 18

图 22 大模型区别于互联网时代的竞争特点 19

图 23 海外主流 AI 大模型基准评分差距逐步缩小..... 19

图 24 海外模型厂商竞争格局 20

图 25 大模型区别于互联网时代的竞争特点 21

图 26 2020-2024 年阿里云业务营收占比..... 21

图 27 国内模型厂商竞争格局 22

图 28 OpenAI 发展历程以及重要模型发布节点 23

图 29 OpenAI GPT 系列模型迭代相关性能参数 24

图 30 以 GPT-4 为例的 GPT 系列模型路径..... 24

图 31 OpenAI o1 与其他头部模型评分对比 25

图 32 OpenAI o1 在训练和推理阶段算力资源的投入与模型性能的关系..... 25

图 33 o1 模型相比 GPT-4o 在推理密集型任务上的改进 26

图 34 未来 GPT 系列与 o1 系列模型或将收敛融合 26

图 35 DeepSeek 发展历程以及重要模型发布节点..... 26

图 36 DeepSeek 用户增长速度..... 27

图 37 海内外接入 DeepSeek 的厂商..... 27

图 38 DeepSeek-V3 多项评测能力与海内外头部模型对比..... 28

图 39 DeepSeek 模型性能与价格比处于最优范围内 28

图 40 DeepSeek-V3 训练成本 28

图 41 DeepSeek-V3 的 MLA 和 DeepSeekMoE 架构..... 29

图 42 DeepSeek-R1 在数学、代码、自然语言推理等任务上的性能表现 30

图 43 DeepSeek-R1-Zero 在训练过程中的 AIME 准确性不断上升 31

图 44 蒸馏后的小型模型在数学、代码、自然语言推理等任务上的性能表现..... 32

图 45 AI 服务器产业链 33

图 46 寒武纪 2020-2024 年总营收和归母净利润与各自同比增速..... 33

图 47 海光信息 2020-2024 年总营收和归母净利润与各自同比增速 33

图 48 恒玄科技 2020-2024 年总营收和归母净利润与各自同比增速 34

图 49 乐鑫科技 2020-2024 年总营收和归母净利润与各自同比增速 34

图 50 兆易创新 2020 年-2024Q1-Q3 总营收和归母净利润与各自同比增速 34

图 51 澜起科技 2020-2024 年总营收和归母净利润与各自同比增速 34

图 52 中际旭创 2020-2024 年总营收和归母净利润与各自同比增速 35

图 53 天孚通信 2020 年-2024Q1-Q3 总营收和归母净利润与各自同比增速 35

图 54 鹏鼎控股 2020-2024 年总营收和归母净利润与各自同比增速 35

图 55 胜宏科技 2020-2024 年总营收和归母净利润与各自同比增速 35

图 56 浪潮信息 2020 年-2024Q1-Q3 总营收和归母净利润与各自同比增速 36

图 57 工业富联 2020-2024 年总营收和归母净利润与各自同比增速 36

图 58 麦格米特 2020 年-2024Q1-Q3 总营收和归母净利润与各自同比增速 36

图 59 欧陆通 2020 年-2024Q1-Q3 总营收和归母净利润与各自同比增速 36

表 1 Transformer 架构和 MoE 架构的对比 13

表 2 模型 API 服务的构成、重要性和主要指标..... 15


表 3 海内外代表大模型 Token 定价 16

1.AI 市场高速扩张，有望引领新一代工业革命

1.1.AI 推动生产变革，行业步入蓬勃发展期

(1) 人工智能 (Artificial Intelligence, AI) 是一种模拟人类智能的技术，旨在使机器能够像人类一样思考、学习和解决问题。AI 涵盖了多种技术和方法，包括深度学习、机器学习、计算机视觉和自然语言处理等。自 1956 年达特茅斯会议首次提出 AI 概念之后，AI 经历了早期的萌芽式发展，20 世纪 70 年代出现的专家系统实现了 AI 从理论研究走向实际应用、从一般推理策略探讨转向运用专门知识的重大突破，但后续 AI 因为一系列问题陷入发展瓶颈，进入 21 世纪，随着网络技术的发展，数据的获取变得更加容易，云计算的兴起提供了强大的计算能力，为深度学习的应用提供了土壤，2010 年起，以深度神经网络为代表的 AI 技术蓬勃发展，应用落地场景多点开花，尤其在近几年，大规模预训练模型时代开启，海内外以 ChatGPT、DeepSeek 等为代表的 AI 模型竞赛如火如荼，标志着 AI 进入了一个新的纪元。


图1 人工智能发展历程



资料来源：国家互联网信息办公室

(2) 按照智能程度划分，AI 主要分为狭义人工智能 (ANI)、通用人工智能 (AGI) 和超级人工智能 (ASI)，目前 AGI 和 ASI 尚处于理论和探索阶段。ANI (Artificial Narrow Intelligence) 又称弱人工智能指专注于特定任务的人工智能系统，能够高效执行特定功能，但其能力局限于预设任务，不具备通用智能。AGI (Artificial General Intelligence) 指具备与人类相当的综合智能，能够理解、学习和执行任何智力任务，具备自主学习和推理能力。ASI (Artificial Super Intelligence) 指在几乎所有领域超越人类智能的人工智能，具备自我改进能力，可能在科学、艺术等领域远超人类。目前，ANI 已广泛应用于图像和语音识别、自动驾驶等场景，AGI 尚未有实际应用，仍处于理论阶段，但 Sora 的问世无疑使我们离 AGI 更进了一步。

图2 按智能程度划分的三类人工智能



资料来源：行行查


（3）生成式人工智能（Generative Artificial Intelligence, Gen AI）是 AI 领域的重要分支，不同于传统的 AI 仅对输入数据进行处理和分析，Gen AI 能够学习并生成具有逻辑的新内容。Gen AI 可以学习并模拟事物的内在规律，是一种基于算法和模型生成具有逻辑性和连贯性的文本、图片、声音、视频、代码等技术。早期 Gen AI 主要针对单一模态，如 GPT 系列生成文本、StyleGAN 生成图像。随着技术进步，Gen AI 开始结合多模态模型，依赖于复杂的机器学习模型，实现异构数据的生成式输出，创建跨模态原创内容（例如文本、图像、视频、音频或软件代码）以响应用户的提示或请求。在应用层面，Gen AI 可显著提升生产效率，根据贝恩，Gen AI 可在营销方面缩减 30%-50% 内容创造所需的时间消耗，在软件开发方面缩短 15% 的代码编写时间。

图3 Gen AI 的工作原理



资料来源：IBM

图4 Gen AI 在各领域的应用效果




资料来源：贝恩

（4）AI 具有算力、算法、数据三大要素，其中基础层提供算力支持，通用技术平台解决算法问题，场景化应用挖掘数据价值。数据是 AI 学习和成长的基石，决定了算法是否能得到有效的训练和优化，数据的质量和数量也直接影响到 AI 模型的准确性和效率；算法是 AI 的灵魂，决定了 AI 如何处理数据和解决问题，其设计和选择直接关系到 AI 的性能和应用效果；算力是 AI 运行的动力，算力提供了执行算法和处理数据所需的计算资源，强大的算力可以支持复杂和大规模的 AI 应用。其中算力指计算设备在单位时间内处理数据的能力，

AI 算力是专门针对 AI 任务（如矩阵运算、神经网络训练）优化的计算能力，需支持高并行性和大规模数据处理，通常用浮点运算次数（FLOPS）衡量，衍生的还有 TFLOPS（万亿次/秒）、PFLOPS（千万亿次/秒）等常见单位，算力的核心硬件包括 GPU、ASIC、FPGA 等。

图5 AI 的三大要素



资料来源：行行查

图6 AI 算力的相关常用名词及其含义


性能指标	FLOPS	Floating point number operations per second, 每秒浮点运算（实数运算）次数，衡量硬件算力的核心指标
	TOPS	Tera operations per second, 每秒可以处理的整型运算的万亿次数，常用于衡量整数运算（OPS，如INT8）性能，适用于推理场景
	QPS	Queries per second, 每秒查询量，衡量AI系统的实际吞吐量（如每秒处理多少张图片）
	Latency	延迟，从输入到输出所需的时间
	Memory Bandwidth	显存带宽，GPU/TPU等加速器的内存数据传输速度，影响算力效率
硬件相关	GPU	图形处理器，最初用于图形渲染，后因并行计算能力强大，成为AI训练和推理的核心硬件
	TPU	张量处理器，谷歌专为AI计算设计的ASIC芯片，擅长矩阵运算，针对TensorFlow框架优化
	ASIC	专用集成电路，为特定任务（如AI推理）设计的芯片，能效比高，但灵活性低
	FPGA	现场可编程门阵列，硬件可重构，适合需要灵活性的场景（如算法迭代期）
	NPU	神经网络处理器，为深度学习设计的处理器，集成于手机/边缘设备（如手机芯片中的AI模块）

资料来源：CSDN

1.2.AI 产业链涵盖基础设施到应用落地多个环节

（1）AI 产业链可大致分为基础设施层、模型层、平台层、应用层及服务层，其中基础设施层包含芯片、存储、网络等，模型层包含通用模型、行业模型等。上游基础设施层是AI产业链的基础，主要涉及数据、算力等基础软硬件，包括AI芯片，代表厂商寒武纪、英伟达等；计算、存储、网络方面，代表厂商亚马逊、微软、阿里、三星电子等。模型层是AI产业链的核心部分，包括通用大模型和行业大模型等。平台层和模型层深度绑定，使大模型更便于使用和普及。随着AI大模型的发展，平台中多种模型选择、如何将大模型高效且可靠地部署于生产环境是当前的核心问题。应用层是AI产业链的终端环节，主要涉及AI在各个领域的应用和落地，而大模型的不断更新升级有助于加速应用场景的创新及商业化落地。


图7 AI 产业链



资料来源：IDC

（2）2024 年全球 AI 市场规模有望达到 6.16 万亿美元，同比增长 30.1%。根据 Frost & Sullivan，自 2020 年起，全球 AI 市场规模以高于 20% 的同比增速呈现迅猛增长的态势，从 2019 年的 1.91 万亿美元有望扩张至 2024 年的 6.16 万亿美元，同比增速逐年上升，2025 年开始虽然预计增速同比放缓，但整体市场有望在 2027 年扩张至 11.64 万亿美元，体现出全球 AI 行业井喷式的发展速度。

图8 全球 AI 市场规模（十亿美元）及同比增速



资料来源：Frost & Sullivan