


“人工智能+”引爆新质生产力革命

“Artificial Intelligence +” Triggers a New Productivity Revolution

观点聚焦 Investment Focus

股票名称	评级	股票名称	评级
腾讯控股	Outperform	英伟达	Outperform
拼多多	Outperform	苹果	Outperform
阿里巴巴	Outperform	Dell Technologies	Outperform
美团	Outperform	联想集团	Outperform
网易公司	Outperform	科大讯飞	Outperform
京东	Outperform	金山办公	Outperform
百度	Outperform	浪潮信息	Outperform
腾讯音乐	Outperform	海康威视	Outperform
Boss 直聘	Outperform		
哔哩哔哩	Outperform		
爱奇艺	Outperform		
阅文集团	Outperform		
微博	Outperform		



资料来源: Factset, HTI

Related Reports

Presentation: AI 革命: 机遇与风险 (AI Revolution: Opportunities and Risks) (16 May 2024)

(Please see APPENDIX 1 for English summary)

纵观人类历史，生产力和生产效率的革命是人类发展的核心动力和主要目标。从 18 世纪的第一次工业革命开始，以蒸汽机为基础的机械化革命便开始将人类从繁重的体力劳动和低效的畜力生产效率中解脱开来。此后历次的工业革命，都诞生了新的技术来提高生产力和生产效率，同时也推动着人类社会组织架构的变革。

技术进步驱动的全要素生产率提升是经济增长的关键。根据索洛增长模型 (Solow Growth Model)，经济增长由劳动力、资本和全要素生产率的增速共同决定。全要素生产率的提升决定了经济发展放缓时能否出现新的增长点，而科技发展是决定全要素生产率增长的主要因素。因此在经济进入长期稳定停滞状态时，唯有技术突破才能提供新的增长飞跃，生成式 AI 正是本次工业革命的核心突破。

生成式 AI 将成为新的劳动主体，大幅提高全要素生产率。人工智能系统能通过分析数据来学习、处理知识，理解并使用自然语言，甚至展现出创造性思维。人工智能技术的出现和广泛应用是工业社会发展中又一次科技飞跃，将再次引领社会的生产变革。

AI 技术已发展至人类能力的高水位，AI4S 有望冲击科学研究的高峰，为现有的生产方式带来进一步的颠覆。AI for Science (AI4S) 将为人类提供新的科学研究工具，填补现有范式难以解决的鸿沟。目前的科学研究严重受到“维度灾难”的制约，尤其在海量数据处理和复杂物理系统中，现有算力条件都因代价过高难以建立高精度的模型。而以机器学习为代表的 AI 技术为系统性解决此类难题打开了窗口，有望引领人类跨越新的高峰。

本报告第一章简述 AI 技术的进步性与局限性，并展望向通用式人工智能 (AGI) 发展的路径；第二章提供全景式的 AI 产业链图谱和中美 AI 能力对比；第三章阐述了生成式 AI 的核心技术及发展趋势；第四章聚焦 AI 对行业的影响和赋能，结合互联网、传媒、计算机、电子、能源、自动驾驶、人形机器人等行业探讨生成式 AI 带来的投资机会；第五章从测评、监管和安全的角度来探讨可靠 AI 生态的建立；第六章展望 AI 商业化路径和产业竞争格局演变，并提出可能的投资机会。

风险

人工智能发展不及预期。

姚书桥 Barney Yao
barney.sq.yao@htisec.com

毛云聪 Yuncong Mao
yc.mao@htisec.com

杨林 Lin Yang
lin.yang@htisec.com

赵玥炜 Yuewei Zhao
yw.zhao@htisec.com

杨斌 Bin Yang
bin.yang@htisec.com

王晴 Rachel Wang
rachel.q.wang@htisec.com

李加惠 Jiahui Li
jh.li@htisec.com

白玉 Jasmine Bai
y.bai@htisec.com

郑创凯 Evan Zheng
evan.ck.zheng@htisec.com

杨昊翎 Harry Yang
hy.yang@htisec.com



人工智能产业链联盟

星主： AI产业链盟主

 知识星球


微信扫描预览星球详情



1. 人工智能将带来第四次工业革命


纵观人类历史，生产力和生产效率的革命是人类发展的核心动力和主要目标。从 18 世纪的第一次工业革命开始，以蒸汽机为基础的机械化革命将人类从繁重的体力劳动和低效的畜力生产效率中解脱开来，珍妮纺织机、蒸汽轮机、火车等机械设备都给人类的生活带来天翻地覆的变化。而以电气能源为基础的批量生产革命，将生产效率不断提升，电气化代替机械化成为推动生产效率的新的火车头。

四次工业革命示意图



Source: HTI

每次技术革命主要产品技术及受益行业



Source: HTI

历次工业革命都涌现了一批核心产品，推动了特定行业的高速发展和人类社会的组织变革：

第一次工业革命（1760s-1840s）是以蒸汽机为基础的机械化革命。“珍妮纺纱机”、改良蒸汽机、火车等发明的出现引起了手工劳动向动力机器生产转变的重大飞跃，随着蒸汽动力的广泛应用、纺织业机械化和铁路网络的扩张显著提高劳动生产率，轻工行业加速发展，人类社会开始从农业社会向工业社会发生转变，资本主义经济体系逐渐确立；


第二次工业革命（1870s-1940s）是以电气能源为基础的批量生产革命。以电灯的发明为标志，以内燃机、电话、电报、汽车等一系列核心发明为代表，人类从蒸汽时代迈进电气时代。基础科学与工业经济的突破推动了大规模生产和制造业的兴起，继而带来工业生产的效率和规模大幅提升，促进了全球化贸易的兴起，使得部分国家如美国、德国等取得世界领导地位，同时也导致激烈的资源争夺和战争；

第三次工业革命（20 世纪中叶至 21 世纪初）是以电脑和网络为基础的知识信息革命。计算机技术、生物技术、原子能技术的应用发展加速开启了信息时代，随着知识经济的兴起与全球信息共享的加速，半导体、计算机和互联网行业蓬勃发展；航天技术也得到重大发展，这时期苏联和美国首次发射了人造地球卫星；

第四次工业革命（21世纪初至今）是以大数据、人工智能、物联网等信息技术为基础的超连接革命。21 世纪正在进行的第四次工业革命指以人工智能、物联网、区块链、新能源、新材料、虚拟现实等等一系列创新技术引领的范式变革，推动着数字化转型和工作方式和生活方式的变革。相比前三次工业革命，它的发展速度更快、影响范围更广、程度更深。

1.1 历史上的工业革命

全球 GDP 历史增长



Source: World Bank (2023), Bolt and van Zanden - Maddison Project Database 2023, Maddison Database 2010, HTI


随着人类生产力的不断增长和生产效率的大幅提高，全球GDP已从18世纪的7.510亿美元增长到2022年的139.4万亿美元。在这一过程中，以1920年-1940年，1960年-1980年，1990-2008年的增速最为显著，分别为CAGR 2.8%、4.5%、3.3%，对应同一时期的电力、核能、互联网等技术的诞生和大规模投入到生产当中。

技术的变革是颠覆性和难以抵抗的。每一次工业革命都是以前一代的技术被替代、组织架构变更、产业劳动者被淘汰为结果。如第一次工业革命的工业化以圈地运动为前提，失去土地的农民投入工商业成为工业生产的劳动力来源，随之而来的是工人阶级的壮大，同时传统的家庭手工业也因无法与工厂生产的效率竞争而被逐渐淘汰；第二次工业革命中电力和内燃机的普及取代了蒸汽机的工作，新技术催生了技术人员如电力工程师、化学工程师等岗位的涌现，同时大规模机械化生产促进企业迅速增长，新生的中产阶级不断扩大，带来新一波的社会结构和经济模式转型。

1.2 科技的发展和生产率的提升

生产率 (productivity) 是原材料变成产品的过程中每单位投入的产出。以单一要素投入量测定生产率, 可将生产率分类为劳动生产率、原材料生产率、能源生产率等; 考虑全部资源投入所计算的生产率, 即多种生产率的总和, 称为全要素生产率 (Total Factor Productivity/TFP)。


人力与机械功率对比



Source: 腾讯新闻, 懂车帝, EV database, Petrotech, "The New Siemens Gas Turbine SGT5-8000H for More Customer Benefit", HTI

工业社会的科技发展让生产率从多要素维度得到提升, 进而提升 TFP。例如, 从劳动力的维度, 如果以人为单位, 一个成年人的最高功率约为 750 瓦, 而蒸汽机的功率可达 300kW, 蒸汽轮机的功率可超过 1,000MW, 机械的力为人类的指数级, 广泛的机械使用大幅降低了人力消耗; 能源转换效率的维度, 1954 年晶硅太阳能光伏电池的开发让光电转换效率从 1%提高至 6%, 至今已接近 30%大关, 接近其理论转换效率极限; 再例如信息生产和传递效率维度, 信息从初始依靠纸张和人力的数日传递, 到使用有线通讯如传真、无线通讯如移动电话、数字通讯如互联网, 显著缩减了信息传递的时间和损耗。

索洛增长模型



Source: Robert Solow, HTI

技术进步驱动的 TFP 提升是经济增长的关键。根据索洛增长模型 (Solow Growth Model), 经济增长速度 (以人均产出衡量) 由劳动力、资本和全要素生产率(TFP)的增速共同决定。据索洛模型测算, 劳动力和资本投入驱动下的有效人均资本波动将在长期达到稳态, 即这两项要素驱动的经济增长最终会减缓并达到均衡状态; 在此状态


下，仅有 TFP 的增速能提供有效人均资本稳态水平的增长。简言之，TFP 的提升与否决定了在经济发展放缓时能否出现新的增长点。而如前所述，科技发展是决定 TFP 增长的主要因素，因此在上一次技术变革带来的动能消退、劳动力与资本难以驱动经济的情况下，新的技术突破将是新一轮增长的关键。

1.3 人工智能是什么，它将改变什么？

人工智能 (Artificial Intelligence, 简称 AI) 是用人制造的机器呈现人类智能的科技。人工智能系统能通过分析数据来学习、处理知识，理解并使用自然语言，甚至展现出创造性思维。人工智能技术的出现和广泛应用是工业社会发展中又一次科技飞跃，将为经济提供新的增长动能，再次引领社会的生产变革。

生成式 AI 将成为新的劳动主体，大幅提高 TFP。在 1980 年以前，AI 的定义是创造能够执行需要人类智能任务的机器和程序，以按照指令执行为主，依托于大型机，数据存储单位仅千字节；1980 至 2010 年，机器学习的概念出现，强调在没有明确编程的情况下机器通过数据和算法自动改进其性能和学习的能力，硬件迭代为小型机，数据存储能力扩张至兆字节；2010 至 2020 年，AI 的定义在机器学习的基础上延伸至深度学习，即基于深度神经网络，模拟人脑处理信息的方式，从错误反馈中学习处理复杂的数据模式如图像、声音、文本。深度学习涉及大量的并行计算，存储数据量可达十亿字节的 GPU 成为其首选硬件；2020 年至今，AI 形式迭代至大语言模型 (LLM)，即预训练的大规模机器学习模型，专门用于处理和生成自然语言。这些模型由多层深度神经网络构成，基于支持大量的矩阵运算和并行处理的 GPU 集群开发训练，能够通过“自己学”的方式理解并执行多种自然语言任务，生成连贯文本，具有广泛的应用潜力。发展后的 AI 有望成为新的劳动主体。

AI 迭代历程



Source: 云知声, HTI

历史上只有人类是唯一的劳动主体，生成式 AI 的诞生会带来和人类现有组织形态的本质性冲突。AI 最擅长的领域是依规行事，其冲突对象将是人类现处工业社会的两大成就，1) 以业务流程化和组织科层化为核心的工业企业；2) 专业人士。专业人士的价值取决于业务流程环节边界的定义，及工业社会对操作流程的标准化规则，其专业知识更多由社会需求决定，此特征与 AI 的强势领域重合，AI 将在专业领域与人类劳动产生强烈的对抗。另一方面，AI 不擅长处理不断变化的未知事物与创造性，意味着 AI 和人类具有完全互补的关系，AI 在人类的优势领域也将无法应用。

工业企业特征



Source: 智识神工, HTI

专业人士特征



Source: 智识神工, HTI

1.4 AI 的三大谬误和五大悖论

AI 作为快速发展的新兴科技，其本质仍未完全为社会所认知。目前对 AI 的认识仍普遍存在三大谬误，现出对 AI 技术不同程度的过度轻视或放大威胁。此类谬误背后对 AI 技术特征和发展路径的误解，将严重阻碍 AI 技术在社会和企业层面的广泛与正确应用。

谬误 1: AI 是一种更强的工具，像超级计算机一样可被购买。

将 AI 定义为工具是对 AI 技术本质缺乏认识，仅停留在其工具性层面，而忽视 AI 是一种全新的生产方式，将带来与之匹配的全方位组织形式变革。对 AI 技术革命性的轻视、思维上的墨守成规，可能导致企业和政府错过技术和组织转型的关键入场点，或对 AI 的使用浮于表面，无法及时利用 AI 模型改善运营和决策全流程，此后的追赶将困难重重。

谬误 2: AI 无所不能，人类是执行器，AI 将取代人类。

此谬误忽视 AI 存在的固有缺陷，AI 仍没有取代人类的能力，例如，AI 在创造性方面无法替代人类，也不能像人类那样感知情景。AI 并非被设计来完全取代人类的，相反，AI 旨在增强人类的能力，提高效率，人类与 AI 的关系将会是互补而非替代。在 AI 技术开始突破临界点的当下，放大 AI 威胁论只会在社会舆论中制造恐慌，对 AI 技术和人类工作的有效融合无益。

谬误 3: AI 将和人类具备平等的地位。

这种认知不是科学也不是社会治理理念，忽视了 AI 工具性的本质。AI 是计算机程序构建的模型，其目的是更好地根据数据做出预测，本身不具备主观感觉能力。人类固然能从 AI 身上得到启发，但 AI 并不会具有和人类相同的地位，AI 的发展最终落脚点是为人所用。

跳出舆论对 AI 技术的过度吹捧与贬低，AI 本身不应被“神化”。在 AI 发展中产生了五大悖论，揭示了 AI 作为技术的局限性和未来可能应用方向的限制。

悖论 1: 莫拉维克悖论 (Moravec's Paradox)

莫拉维克悖论认为，实现类似人类的高阶的认知任务（如推理和解决问题）需要很少的计算能力，但在模拟人类的基本感知和运动技能时却需要大量算力。这意味着虽然 AI 能够轻易完成计算、推理甚至围棋、编程等“高级任务”，它在人类轻而易举可以达到的运动、手眼协调等“低智能”领域却寸步难行。

悖论 2: 脑科学悖论

尽管 AI 在模拟人类智能方面实现了巨大的进步，但 AI 和人类大脑的工作原理在本质上是不同的。AI 的原理是基于算法和数学模型实现智能行为，其学习机制和决策能力都和人类大脑不同。人类智能是脑科学和心理学的结合，AI 难以完全复制人类大脑的复杂性，实现通用人工智能仍需要进一步模拟大脑智能的机制。

悖论 3: 可解释性与自主性悖论

随着 AI 系统自主性的增加，其决策过程可能变得更加复杂，涉及大量的数据、算法和模型，导致决策过程难以追溯和解释，从而降低了可解释性；而人类使用者需要可解释性来理解决策背后的原因，以便进行监管和纠正错误。未来的 AI 系统需要在保持高度自主性的同时，也能够提供足够的透明度和可解释性，以满足社会的需求。

悖论 4: 知识图谱悖论

尽管 AI 和机器学习技术能够从大量数据中发现模式和知识，但它们只能执行预设的算法和处理已有的信息，而不会产生真正意义上的新知识。因此，AI 在创造性方面远逊于人类。

悖论 5: 生成 AI 悖论

生成 AI 在生成内容的质量和逻辑性难以评估，因为 AI 可能并不完全理解其自身创作的内容；同时，这种内容往往基于大量现有数据的学习和模仿，可能导致其原创性受到质疑。在提高 AI 技术能力的同时，也应有相应的监管政策到位，确保其符合伦理标准和社会价值观。

即使存在以上的悖论与局限，AI 依然是一种意义重大的技术，它将显著提高生产和工作效率，并有希望在更复杂的领域为人类做出巨大贡献。

1.5 第五范式与 AI4S

科学研究共发展出了四种主要范式，AI 技术则提供第五范式的可能。四种现存的范式分别为：从几千几百年前起通过观察和实验来描述自然现象的经验范式；使用模型或归纳法进行科学研究的理论范式；随着电子计算机发展而产生的采用计算机进行仿真模拟的计算范式；进入大数据时代后，对大规模实验科学数据进行建模和分析的数据驱动范式。AI 技术的发展揭示了第五种科学研究范式，即通过机器猜想的方式应用于科学智能，通过不同的算法思维和应用场景的对撞，得到不同领域专业知识，从而推导位置结论的范式。

第一到第五范式



Source: 澎湃新闻, HTI

AI for Science (AI4S) 将为人类提供新的科学研究工具，填补现有范式难以解决的鸿沟。目前的科学研究围绕数据驱动的开普勒范式和基于第一性原理的牛顿范式开展，严重受到“维度灾难”的制约，即随着维数的增加计算代价呈指数增长，尤其在海量数据处理和复杂物理系统中，现有算力条件都因代价过高难以建立高精度的模型。以机器学习为代表的 AI 技术为系统性解决此类难题打开了窗口，使得原理驱动和数据驱动这两种范式得以统一。在数据充足的学科问题中，AI4S 可以在大数据的基础上利用深度学习+高性能计算提效；而数据缺乏、原理明确的问题中，AI4S 能利用生成式模型生产高质量数据，并高效利用小数据实现突破。

AI4S



Source: DP Technology, 北京科学智能研究院, 深势科技, 高瓴创投, HTI

AI4S 已在多个科学领域实现了初步成果。2016 年，机器学习等 AI 工具已被尝试用于解决科学问题。2020 年后，AlphaFold (DeepMind 开发的蛋白质结构预测程式)、Modulus (Nvidia 开发的基于物理的机器学习平台) 等优秀 AI4S 工具相继诞生，AI 领域的工具与方法已初步成熟。至 2023 年，AI4S 工具的发展和运用已在材料科学、气候变化、计算机科学、医学等领域产生了深远影响。尽管 AI4S 概念在科学领域的导入已基本完成，但目前 AI4S 工具的使用仍以学术界为主导，没有产生系统性的工程化需求。未来 5 年中，AI4S 仍需走过关键的基础设施建设时期，进入成熟应用阶段。

现有 AI4S 工具与成果

产业	AI4S 工具	现有成果
物理仿真	Modulus (Nvidia)	“基于物理的人工智能引擎” Modulus，同精度级别的计算速度比传统仿真快 1,000-100,000 倍，基于其显著的速度优势，伯克利劳伦斯国家实验室与加州理工团队实现对复杂气象的实时仿真 (0.25s 计算出 7 日预测数据)
材料科学	GNoME (DeepMind)	GNoME 发现了 220 万种新晶体预测 (相当于人类科学家近 800 年的知识积累)，其中有 38 万个稳定的晶体结构，有望通过实验合成，部分材料或许会引发技术变革，如下一代电池、超导体等
分子结构	AlphaFold (DeepMind)	DeepMind 团队用特殊的网络结构设计，充分利用数据使得蛋白质结构预测达到前所未有的精度
医学研究	EVEscape (Harvard/Oxford)	通用模块化框架 EVEscape 能够在不依赖于大流行期间的测序数据或抗体结构信息的情况下，预测病毒的逃逸潜力。这一早期预警系统为公共卫生决策和准备工作提供了指导，有助于最大限度地减少大流行对人类健康和社会经济的负面影响

Source: Human-Center Artificial Intelligence (HAI), 北京科学智能研究院, 深势科技, 高瓴创投, HTI

AI 技术已发展至人类能力的高水位，AI4S 有望冲击科学研究的高峰。汉斯·莫拉维克 (Hans Moravec) 认为，人类的潜能类似地形分布，低地为算术、背诵等技能，山麓则是下棋、定理证明、科学研究等能力。计算机潜能的提升正在过去的数年内逐渐淹没人类能力的领地。2016 年 AlphaGo 战胜人类棋手，淹没了围棋的丘陵；AI 代码审查工具 DeepCode、AI 编程助手 GitHub Copilot 等技术已进入编程领域；OpenAI 在 2024 年推出的视频生成模型 Sora 开始了对影视领域的冲击；多种文生图、文生 UI 工具抵达 AI 设计的临界点，此后 AI 能力的边界有望加速扩张，冲击科研的顶点，为现有的生产方式带来进一步的颠覆。

人类能力地形图




Source: Hans Moravec, HFI

1.6 通往 AGI 之路

人工通用智能 (Artificial General Intelligence, 简称 AGI) 是具备与人类同等智能、或超越人类的人工智能，能表现正常人类所具有的所有智能行为。它是一种具有广泛认知能力的人工智能系统，能够实现无需标注的自监督学习，像人类一样在多种不同领域和环境中灵活地思考、学习、推理和解决问题。

目前的大语言模型仍然不符合 AGI 的要求。目前的 AI 在几个基准上已经超过了人类的表现，包括图像分类、视觉推理和英语理解等。然而，它在数学竞赛、视觉常识推理和规划等更复杂的任务上仍然落后于人类，也不具备自主能力，需要人类具体定义每个任务。此外，1.0 时代的 AI 需要花费巨大的成本为单一领域收集和标注数据，缺少规模化能力，亦难以实现商业上的成功。

从 AI1.0 到 AI2.0




Source: 李开复, HFI

AI 2.0 时代将突破 1.0 时代单领域、多模型的限制，进一步向 AGI 冲刺。2.0 时代用无需人工标注的海量数据训练出的具有跨领域知识的基础大模型可以通过微调适配和执行多样任务，实现平台化效应和商业化机会。AI 2.0 的发展范式是迭代式的，从“辅助人类”到“全程自动”将会出现三个阶段：第一阶段人机协同，生产力工具将会首先实现

升级，所有使用者界面将被重新设计，用户可以通过描述告诉AI期望的产出。在这一阶段，人类仍与AI保持协作，筛选和纠正AI创作的内容；第二阶段局部自动，容错度高的应用和行业将率先实现AI自动化，例如广告投放、电子商务、搜索引擎等；第三阶段全程自动，AI将在不容出错的领域实现自动化，AI医生、AI教师等应用成为可能。


2. HTI 全球人工智能图谱 2024 (HTI Global AI Landscape 2024)

HTI 全球人工智能图谱



Source: 信通院, 中商产业研究院, HTI

中美 AI 实力对比




Source: HAI-AI Index Report 2024, Synergy Research Group, HTI

3. Gen AI 核心技术解析及发展趋势

传统意义上的AI模型，主要分为**判别式模型**（Discriminative Models）和**生成式模型**（Generative Models）。

判别式模型（Discriminative Models）：用于解决回归或分类任务，重点在于区分不同类别的数据。与生成模型不同，判别模型不生成新数据，而是专注于学习输入特征与输出标签之间的关系，以便准确地进行分类或预测。判别式模型在各种应用中广泛使用，特别是在需要分类或回归任务的场景中，例如：BERT（用于各种NLP任务）、金融风险评估的信用评级系统（如FICO）、癌症检测系统等等。

生成式与判别式模型



Source: Learnopency, HTI

而生成式模型（Generative Models）：是生成式AI背后的技术，是一类能学习和模仿数据分布的模型，它们能够创建看起来与训练数据相当相似的新数据样本。举个例子，如果我们有一个人脸生成模型，它可以生成看起来像真人脸的图片，而这些图片与模型用来训练的真实人脸图片很相似，甚至很难区分哪个是生成的，哪个是真实的。生成式模型已被广泛应用于各种领域，特别是在需要生成新数据样本的任务中，例如：GPT、DALL-E（图像生成）、DeepArt和Prisma（图像风格转换）等等。

大模型是“大算力+强算法”结合的产物。大模型通常是在大规模无标注数据上进行训练，学习出一种特征和规则。基于大模型进行应用开发时，将大模型进行微调，如下游特定任务上的小规模有标注数据进行二次训练，或者不进行微调，就可以完成多个应用场景的任务。

从参数规模上看，AI大模型先后经历了预训练模型、大规模预训练模型、超大规模预训练模型三个阶段，参数量实现了从亿级到百万亿级的突破。从模态支持上看，AI大模型从支持图片、图像、文本、语音单一模态下的单一任务，逐渐发展为支持多种模态下的多种任务。


生成式AI是利用生成式模型从大量数据中学习并生成新内容的技术，它能够创作与训练数据相似的文本、图像、音频等。如GPT-4，通过理解数据的结构和模式，生成自然流畅的文本、逼真的图像和音视频。目前，生成式AI已广泛应用于内容创作和艺术创作等领域，在交互娱乐等方面也有着广阔的应用前景。以GPT-3.5为例，其训练的过程主要有三个阶段。

第一步是训练监督策略，人类标注员对随机抽取的提示提供预期结果，用监督学习的形式微调 GPT-3.5，生成 Supervised Fine-Tuning（SFT）模型，使 GPT-3.5 初步理解指令，这一步与先前的 GPT-3 模型训练方式相同，类似于老师为学生提供标答的过程。

第二步是奖励模型，在 SFT 模型中随机抽取提示并生成数个结果，由人类标注员对结果的匹配程度进行排序，再将问题与结果配对成数据对输入奖励模型进行打分训练，这个步骤类似于学生模拟标答写出自己的答案，老师再对每个答案进行评分。

第三步是近段策略优化（Proximal Policy Optimization, PPO），也是 ChatGPT 最突出的升级。模型通过第二步的打分机制，对 SFT 模型内数据进行训练，自动优化迭代，提高 ChatGPT 输出结果的质量，即是学生根据老师反馈的评分，对自己的作答进行修改，使答案更接近高分标准。

GPT-3.5 训练过程




Source: OpenAI, HTI

人工智能领域中的一些重要基础技术概念如下：

(1) **神经网络技术 (Neural Network Technology)**：是一种模仿生物神经系统结构和功能的计算方法。神经网络的结构通常分为输入层、隐藏层和输出层。输入层接受原始数据，隐藏层负责数据的特征提取和处理，输出层生成预测结果。神经网络技术可以处理复杂数据和任务，已在人工智能和机器学习领域中广泛应用。


深度神经网络



Source: IBM, HTI

(2) **神经符号推理 (Neuro-Symbolic Reasoning)** 结合了神经网络和符号推理的混合方法，利用两种技术的优势来解决复杂的推理和学习任务。这种方法在人工智能领域具有广泛的应用前景，因为它能够处理复杂的数据和关系，同时保留符号逻辑的可解释性和规则性。


神经符号推理



Source: Semanticscholar, HTI

(3) **尺度定律 (Scaling Law)** 是指在训练模型时，模型性能随模型规模（如参数数量）、训练数据量和计算资源的增加而变化的规律。这些定律帮助研究人员和工程师更好地理解并预测扩展模型时的效果和需求。在GPT-3的开发过程中，OpenAI遵循了尺度定律，通过大幅增加模型参数数量（达到1750亿），显著提高了模型的自然语言处理能力。而摩尔定律 (Moore's Law) 应用于半导体和计算机硬件领域，具体说的是当价格不变时，集成电路上可容纳的晶体管数目，每隔18个月便会增加一倍，意味着性能也将提升一倍。两个定律应用领域不同，但都体现了技术进步在各自领域内的驱动力。

尺度定律 (随着时间推移，机器学习的计算资源显著增加)



Source: Epoch, HTI

(4) **自然语言处理技术 (Natural Language Processing, NLP)**：包括词法分析、句法分析、语义理解等。这些技术帮助模型更好地理解并生成自然语言文本，使得生成的文本更加准确和语义丰富。

自然语言处理技术



Source: Deloitte, HTI

(5) **大规模数据集 (Dataset):** 海量的高质量数据是训练生成式AI模型的关键。这些数据集包含丰富的语言知识和模式，能够帮助模型学习到更好的表示和生成能力。


大规模数据集



Source: CSDN, HTI

(6) **无监督学习算法 (Unsupervised Learning):** 能够从数据中自动发现模式和特征，无需人工标记的监督信息。这对于生成式AI模型的训练至关重要，可以使模型从大量未标记的数据中学习到有用的知识。


监督与无监督学习算法



Source: BigQuant, HTI

(7) **强化学习** (Reinforcement Learning, RL) 是一种机器学习方法，用于训练模型做出决策，以实现最佳结果。通过反复试错和奖惩制度，与环境交互来学习最优策略，有助于实现目标的软件操作会得到加强，而偏离目标的操作将被忽略，从而在不同状态下选择最佳处理路径以获得最大化预期回报。强化学习广泛应用于机器人控制、游戏AI、推荐系统等领域。例如，著名的AlphaGo在训练过程中结合了强化学习策略，以寻找最佳落子策略。


强化学习



Source: Techvidvan, HTI

(8) **强化学习与人类反馈** (Reinforcement Learning with Human Feedback, RLHF) 结合强化学习的自动学习能力和人类的反馈，通过人类反馈指导学习的过程，显著加速学习速度，提高性能及安全性。强化学习与AI反馈 (Reinforcement Learning with AI Feedback, RLAI) 是结合了强化学习的自动学习能力和AI模型的智能反馈。其智能体不仅从环境中获得奖励，还从另一个AI系统中获得反馈。这种方法利用AI反馈来指导和改进智能体的学习过程，从而加速策略优化，提高整体性能。


强化学习与人类反馈



Source: CSDN, HTI

(9) **迁移学习** (Transfer Learning) 是一种机器学习方法，其中一个模型在某个任务上学到的知识被应用到另一个相关的任务中。通过这种方法，迁移学习能够利用已有的经验，提高新任务的学习效率和性能。尤其是在数据有限的情况下，迁移学习能够显著提升模型性能。


迁移学习



Source: CSDN, HTI

(10) **联邦学习** (Federated Learning) 是一种分布式机器学习方法，允许模型在多个设备或节点上训练。这种方式能够在保护数据隐私的前提下，利用分散的数据进行模型训练，可以在全局模型的基础上，进一步调整和优化个性化模型，满足不同用户的需求。

联邦学习




Source: Geeksforgeeks, HTI

(11) **生成对抗网络** (Generative Adversarial Networks, GAN)：GAN包括两个部分：生成器和判别器。生成器尝试生成与真实数据相似的假数据，而判别器尝试区分真假数据。通过不断的对抗训练，生成器最终能够生成较为逼真的数据。

生成对抗网络


Components of GAN



Source: Javatpoint, HTI

(12) **自回归模型** (Autoregressive Model)：通过前一个时刻的输出来预测下一个时刻的输出，广泛应用于文本生成和音频生成等领域。


自回归模型



Source: Otexts, HTI

(13) **变分自编码器 (VAEs)**：由编码器和解码器组成。编码器将图片信息压缩成一个“潜在空间”。这就像画家将复杂的画面概括成简单的草图，这个草图包含了图片的关键要素，但省略了细节。解码器根据这些草图画出新图片。就像画家根据草图创作出一幅新画。这些新画看起来像是从原始图片中生成的，但又是独一无二的。在训练过程中，VAE会不断调整编码器和解码器，让生成的图片越来越逼真。


变分自编码器



Source: CSDN, HTI

(14) **优化算法 (Algorithms Optimization)**：用于训练模型，调整模型参数以最小化损失函数，提高模型性能。常见的优化算法包括随机梯度下降 (Stochastic Gradient Descent, SGD) 和其变种，以及自适应学习率算法如Adam等。例如，随机梯度下降是指不使用全量样本计算当前的梯度，而是使用小批量(mini-batch)样本来估计梯度，大大提高了效率。

优化算法




Source: Researchgate, HTI


(15) **注意力机制 (Attention)**：使模型聚焦于输入中的关键部分，提高处理效率和效果。注意力机制在生成式AI中被广泛应用，例如用于自然语言处理任务中的注意力机制模型（如Transformer）能够有效处理长距离依赖关系和提升生成性能。

注意力机制

Scaled Dot-Product Attention



Multi-Head Attention



Source: Researchgate, HTI

以上的这些技术在过去的20年中快速发展，直到2017年的历史性的突破Transformer的到来，才有了生成式AI的基础。而在2022年ChatGPT的横空出世，进一步将生成式AI模型从需要大量标注数据而进行训练的时代带入到不需要标注数据而进行海量数据训练的时代。

3.1 Gen AI 的核心技术

3.1.1 Game Changer -- Transformer: Attention (注意力机制) is All you need

变换器 (Transformer) 模型是一种处理大规模数据训练任务的深度学习架构，也是生成式AI发展的基石。 2017年Vaswani等人发表了论文《Attention is All You Need》，介绍了Transformer模型的核心思想，自此彻底改变了自然语言处理(NLP)领域，为模型处理大规模数据和学习复杂模式提供了基础，已成为NLP界最具影响力的模型之一。2017-2022年Transformer模型的算力需求每2年增长275倍，而其他AI模型的趋势是每2年增长8倍。


Trasformer 模型算力需求



In the race for higher performance, transformer models have grown larger.
Source: Nvidia, HTI

相比传统的前馈神经网络、卷积神经网络和循环神经网络，Transformer 存在显著不同点，是一种基于注意力机制的神经网络架构。其核心是自注意力机制，允许模型在处理当前输入时关注输入序列中的所有位置，能够更好地捕捉长距离依赖关系，并实现高度并行计算。传统神经网络如前馈神经网络主要用于非序列的分类和回归任务，卷积神经网络广泛应用于图像处理，循环神经网络则适用于序列数据处理。相比之下，Transformer 因其高效性和灵活性，特别在自然语言处理和图像处理领域表现出色，并已成为许多现代 NLP 模型（如 BERT、GPT）的基础。

图解 Transformer 的模型通用架构



Source: Researchgate, HTI

Transformer 模型主要由两个部分组成：编码器（Encoder）和解码器（Decoder）。每部分由多个相同的层（Layer）组成。以下是各组件的详细介绍（架构图如上）：

编码器堆栈：这是由 N_x 个相同的编码器层组成的堆栈(原论文中, $N_x=6$)。每个编码器层都由两个子层组成：多头自注意力机制（Multi-Head Attention）和前馈神经网络（Feed Forward）。多头自注意力机制用于对输入序列中的不同位置之间的关系进行建模，而前馈神经网络则用于对每个位置进行非线性转换。编码器堆栈的作用是将输入序列转换为一系列高级特征表示。

解码器堆栈：这也是由 N_x 个相同的解码器层组成的堆栈(原论文中, $N_x=6$)。每个解码器层除了包含编码器层的两个子层外，还包含一个额外的多头自注意力机制子层（Masked Multi Self Attention）。这个额外的自注意力机制用于对编码器堆栈的输出进行关注，并帮助解码器对输入序列中的信息进行解码和生成输出序列。

在编码器和解码器堆栈之间，还有一个位置编码层（Positional Encoding）。这个作用是利用序列的顺序信息，为输入序列中的每个位置提供一个固定的编码表示。这样，模型可以在没有递归或卷积操作的情况下，利用位置编码层来处理序列的顺序信息。

3.1.2 扩散模型（Diffusion Model）

扩散模型（Diffusion Model），其核心概念是通过逐步添加噪声使数据接近于随机噪声，然后再逐步去除噪声以生成新的数据。这一过程模拟了数据的扩散和逆扩散过程，为高质量数据样本的生成提供了一种新的方法。相比于传统的生成模型，扩散模型具有稳定（无模式崩溃）的训练过程和高质量（高保真度）的生成能力，因此在图像生成、图像修复、语音和文本生成等任务中显示出了巨大的潜力。


以下小猫图像正是运用了扩散模型，可以看出扩散模型包括两个过程：正向扩散和参数化反向扩散。正向和反向过程通常使用数千个步骤来逐步注入噪声，并在生成过程中进行去噪。

扩散模型应用示例



Source: Nvidia, HTI

扩散模型特征



Source: Researchgate, HTI

3.1.3 DiT 模型（Diffusion Transformer Model）

DiT 是一种结合了扩散模型（Diffusion Model）和 Transformer 架构的生成模型。它通过逐步添加和去除噪声的扩散过程与 Transformer 的自注意力机制相结合，实现高质量、灵活性、稳定性的数据生成。DiT 不仅在图像生成等任务中展现出色，还具有灵活性，可扩展到多模态生成和其他领域，成为生成模型领域的重要创新之一。下图可以发现，计算程度更高的 DiT 模型的图片质量更高。


DiT 模型效果



可视化扩大 DiT 的效果。我们使用相同的采样噪声，在 400K 个训练步骤中从所有 12 个 DiT 模型生成图像。计算密集程度更高的 DiT 模型的样本质量明显更高。

Source: UC Berkeley, HTI

DiT 模型




Source: UC Berkeley, HTI

3.1.4 基础模型 (Foundation Model)

基础模型是在大量无标记数据基础上进行无监督训练的大规模人工智能模型。其具备通用性和可迁移性的优势，可利用海量数据和计算资源生成从文本到图像的任何内容。这些模型在预训练后可直接在各种 NLP 任务中使用，而无需从新开始训练。基础模型的出现促使 NLP 技术的普及和应用。


自 GPT-3 后，越来越多的基础模型随之出现，其参数规模亦越来越大。这些模型通过大规模的无监督学习从文本语料库中学习了丰富的语言表示，能够捕捉词汇、语法、语义等各个层面的信息。

基础模型定义



Source: Renaissance Rachel, HTI

基础模型发展进程




Source: Stanford, HTI

3.1.5 多模态大模型 (Multimodal Models)

多模态大模型是能够处理和理解多种类型数据（如文本、图像、音频、视频等）的深度学习模型。通过整合不同模态的数据，可以实现更丰富和准确的任务处理，提升各类应用的智能水平。多数多模态模型是基于 Transformer 架构，通过注意力机制在不同模态的数据之间建立关联。


单模态和多模态



Source: AImultiplerearch, HTI


值得注意的是，训练模型的算力需求激增如早期的AlexNet仅需要470 PB FLOP用于训练而2017年发布的Transformer则需要约7400PB。谷歌的Gemini Ultra是目前最先进的模型之一则需要500亿PB FLOP的算力。传统的人工智能系统的能力有限，语言模型在文本理解方面表现出色，但在图像处理方面表现不佳反之亦然。随着多模态大模型的发展，一些新的模型如谷歌的Gemini和OpenAI的GPT-4已经展示出同时处理好图像和文本任务的能力，甚至可以处理音频如GPT-4o。

MMLU 精准度



Source: Stanford, HTI

机器学习模型算力




Source: Stanford, HTI

3.1.6 混合专家模型 (Mixture of Experts, MoE)

混合专家模型是用于提高深度学习模型效率和性能的模式之一。这个模型可将一个复杂问题可以被拆分为多个领域知识的简单问题，通过把各个领域问题分发各个领域的专家来解决，最后再汇总结论。它由多个专业化的子模型即专家组合而成每一个专家都在其擅长的领域内做出贡献。该模型在计算时仅激活部分专家，大幅减少了计算需求，与具有相同参数数量的模型相比具有更快的推理速度，有效降低模型训练成本。

但是，该模型也存在一定的挑战，其需要将所有专家的参数加载到内存中，对分布式计算能力有更高需求，以及模型训练复杂性高，需要处理专家之间的不平衡激活问题和优化分配机制。

MoE 架构



Source: ResearchGate, HTI

MoE 模型对比



Source: UC Berkeley, HTI

3.1.7 代理工作流 (Agentic Workflow)

代理工作流通过将一个复杂的任务分解成较小的步骤，在整个过程中融入了更多人类参与到流程中的规划与定义。它减少了对 Prompt Engineering 和模型推理能力的依赖，提高了 LLM 应用面向复杂任务的性能，更丰富、更精确。

代理工作流示意图




Source: Abacus.AI, HTI

3.1.8 检索增强生成 (Retrieval Augmented Generation, RAG)

检索增强生成是一种结合了信息检索 (Retriever) 和生成技术 (Generator) 的自然语言处理模型。它通过检索器从大型知识库中检索相关信息，并利用生成器根据检索到的信息和输入的上下文来生成自然语言文本。RAG模型在问答系统等任务中表现出色，能够有效地利用外部知识来生成相关、准确的文本结果。此外，企业可以通过在本地部署RAG系统，在使用AI模型的同时，避免企业敏感数据泄漏。

检索增强生成



Source: CSDN, HTI


3.2 技术发展演进趋势

3.2.1 开源生态与闭源生态之争

科技界长久以来存在着开源与闭源之争，AI大模型也不例外。目前闭源大模型凭借其商业模式优势，在技术水平上暂时领先；开源大模型发展十分迅速，综合考虑成本、安全、法律等因素，开源大模型在未来也十分具有发展潜力。恰似当年操作系统开源还是闭源的世纪之争，未来谁将更胜一筹或最终取决于生态。

以 GPT-4、Claude、Gemini 等为代表的闭源大模型，通过付费订阅等方式实现商业化，从而吸引人才和资源，推动模型性能提升。在数学、推理、编程和语言等方面，闭源模型的表现曾经显著优于开源模型。

开源闭源大模型性能差异



Source: Artificial Intelligence Index Report 2024, HTI

不过自 2021 年以来，开源模型的比例显著增加。2023 年，65.8%的基础模型以开源形式发布，另外18.8%的模型没有开源，15.4%的模型限制访问。

基础模型开源与闭源百分比分布





Figure 1.3.14

Source: Artificial Intelligence Index Report 2024, HTI


基础模型开源与闭源个数分布



Source: Artificial Intelligence Index Report 2024, HTI

开源大模型在性能表现上正快速追赶闭源模型，展现出强大的发展潜力。尽管此前闭源模型在数学、推理、编程和语言等方面占据优势，但 Llama3 的发布改变了这一格局。Llama3 在推理、代码生成和指令跟随等能力上的提升显著，性能已与大多数主流闭源模型相媲美。例如，其 80 亿参数模型在 MMLU、GPQA、HumanEval 等多项基准测试中，表现优于 Gemma 7B 和 Mistral 7B Instruct 等模型。更令人惊喜的是，Llama3 的 700 亿参数模型性能超越了闭源领域的佼佼者 Claude 3 Sonnet，并能与谷歌的 Gemini Pro 1.5 相抗衡。

开源闭源大模型性能发展过程



Source: Ark Investment, HTI

除性能上的提升外，开源大模型在成本、定制化、安全等方面也具备一定优势。(1) 开源大模型的使用成本较低。由于权重文件完全公开，使用者无需承担高昂的订阅费用或使用限制，可以更低成本地进行研究和应用开发。(2) 开源大模型具有高度的可定制化。使用者可以根据自身需求，在开源模型权重文件的基础上自由进行微调，以更好地适应特定场景和任务，无需受限于闭源模型的功能范围。(3) 开源大模型能够更好地保障使用者在安全和利益方面的诉求。无论是使用还是微调模型，企业无需将核心数据和商业机密传输出去，有效避免数据泄露和知识产权纠纷，保障自身核心利益。(4) 开源模式还有助于解决知识产权和收益分配问题。虽然开源和闭源模型在语料使用方面均存在版权争议，但开源模式下，语料库的构建和使用更有利于知识共享和收益共赢。(5) 开源大模型的推广应用有利于推动技术民主化和平权发展，打破技术垄断，促进人工智能领域的开放合作和创新发展。

开源与闭源大模型对比

	开源	闭源
模型性能	略低	略高
使用成本	较低，无需承担高昂的订阅费用	较高
定制化	允许	允许，但往往费用高昂
安全性	企业核心数据及机密方面更安全	由于不公开，更不容易受到攻击
其他	知识产权、收益分配问题；科技平权	商业模式便于盈利

Source: HTI


大模型开源闭源只是不同的路径选择，最终的成功取决于有没有繁荣的生态系统。回顾当年操作系统的开源闭源之争可以发现，什么样的操作系统能生存下来最终还是取决于生态是否繁荣，而这与开源还是闭源并没有必然联系，二者可以并肩共存。生态的繁荣取决于谁能具备更好的可开发能力、让更多开发者参与其中。开发者体验的核心要素包括：(1) 高效的开发工具：功能强大的 IDE、完善的技术文档和丰富的 API 接口，能够显著提升开发效率。例如，Xcode 为 iOS 开发者提供了良好的开发体验，这是 iOS 生态繁荣的重要因素。(2) 开放的开发平台：开源系统允许开发者自由访问源码，进行深度定制和开发，并与其他开发者共享和交流。Android 的开源特性催生了众多开发者社区，例如 XDA，这些社区促进了知识共享和系统发展。(3) 可持续的盈利模式：一个健康的生态系统需要为开发者提供合理的回报和发展空间。App Store 为 iOS 开发者提供了应用分发平台和相对公平的分成机制，保障了开发者的收益。无论是开源还是闭源，最终目标都是吸引和留住开发者。操作系统需要通过提供优质的开发工具、开放的平台和可持续的盈利模式，来构建繁荣的开发者生态系统，最终赢得市场竞争。

PC 操作系统市场份额



Source: Statcounter, HTI

手机操作系统市场份额



Source: Statcounter, HTI

3.2.2 具身智能

具身智能将是未来 AI 领域最大的风口。之前生成式 AI 的训练主要是基于互联网上的数据，也就是虚拟世界的的数据，所以导致今天大部分 AI 并不了解物理世界。下一代 AI 将学习物理世界的的数据，从而进入到物理世界。

在 Computex 2024 上，NVIDIA 的 CEO **黄仁勋宣布机器人时代的到来**。英伟达构建了 NVIDIA Omniverse 作为机器人训练开发的虚拟世界，机器人可以在 Omniverse 中训练如何精确操控物体，自主导航环境，找到最佳路径，并规避障碍物和危险。在 Omniverse 中进行训练，最大程度的减少了虚拟和现实训练的差距，快速地进行训练和学习。同时他也给出了构建生成物理 AI 机器人所需的三台计算机：训练模型的 NVIDIA Jetson Orin，运行模型的 Jetson Thor，以及 Omniverse。下一波 AI 已经到来，AI 驱动的机器人将影响到各行各业。

具身智能指一种能够通过感知和交互与环境进行实时互动的智能系统或机器。可以简单理解为在真实的物理环境下执行各种各样的任务的各种不同形态的机器人。具身智能近期技术突破频出，科技巨头加速布局，推动商业化进程。近期，Google、DeepMind、特斯拉、苹果、英伟达等科技巨头在具身智能领域的布局和突破，该领域正进入快速发展阶段，并有望成为未来 AI 发展的重要驱动力。

基础模型可以通过微调来适应各种下游任务，有可能为机器人领域开辟新的可能性，例如自动驾驶、家用机器人、工业机器人、辅助机器人、医疗机器人、野外机器人和多机器人系统。预训练的大模型可用于改进机器人环境中的各种任务。将基础模型集成到机器人技术中是一个快速发展的领域，机器人技术界最近开始探索如何在机器人领域内利用这些大型模型进行感知、预测、规划和控制。

基于基础模型的具身智能任务概述



Source: Firoozi R, Tucker J, Tian S, et al. Foundation models in robotics: Applications, challenges, and the future[J]. arXiv preprint arXiv:2312.07843, 2023., HTI

预训练机器人模型


Paper	Backbone	Size (Parameters)	Pretrained Task	Inference Speed	Hardware [†]
RobotCar [100]	decoder-only transformer	1.1B	manipulation	10-20Hz	
Gato [101]	decoder-only transformer	1.2B	generalist agent	20Hz	4 days on 16x16 TPU v3 (also runs on multi-TPU cloud service)
PaLM-E-562B [102]	decoder-only transformer	562B	1Hz for Language subgoals + 3Hz low-level control policies	3-6Hz	
VINT [103]	EfficientNet+ decoder transformer	31M	visual navigation	4Hz	various of GPU configurations is used including 2x4090, 3xTitan Xp, 4xP100, 8x1080Ti, 8xV100, and 8xA100
VPT [104]	4 temporal convolution layer, a ResNet 62 image processing stack, and residual unimodal attention layers	0.5B	embodied agent in Minecraft	20Hz	9 days on 720 V100 GPUs
RT-1 [105]	Condensed EfficientNet + TokenLearner + decoder-only transformer	35M	real-world robotics tasks	3Hz	
RT-2 [106]	PaLM-X	55B	real-world robotics tasks	1-3Hz	runs on multi-TPU cloud service
RT-2-X [107]	ViT and Language model LLaMA [108]	55B	real-world robotics tasks	1-3Hz	runs on multi-TPU cloud service
LIV [109]	CLIP		reward learning	15Hz	8 NVIDIA V100 GPUs
SMART [110]	decoder-only transformer	11M	bidirectional dynamics prediction and masked hindsight control	1 Hz	8 Nvidia V100 GPUs
COMPASS [111]	5D-Resnet encoder	20M	Contractive loss	30 Hz	8 Nvidia V100 GPU;
FACT [112]	decoder-only transformer	12M	forward dynamics and next action prediction	10 Hz (edge) / 50 Hz	Nvidia Xavier NX (edge) / 8 Nvidia V100 GPUs

[†] Empty fields in the table denote no data is reported.

Source: Firooz R, Tucker J, Tian S, et al. Foundation models in robotics: Applications, challenges, and the future[J]. arXiv preprint arXiv:2312.07843, 2023., HTI

基础模型的进步带动具身智能模型发展。例如，Google 的 PaLM-E 模型成功将 LLM 与机器人技术相结合，赋予机器人理解和执行复杂指令的能力，例如“我的锤子掉在地上了，你能帮我捡起来吗？”。PaLM-E 的成功案例表明，LLM 可以让机器人在更复杂的环境中完成更灵活的任务。DeepMind 发布了 RT-2 模型，通过将 LLM 的知识和推理能力融入机器人控制系统，RT-2 显著提高了机器人在新环境中的任务执行能力，例如在未曾见过的场景中识别和抓取物体。从 RT-2 可以看出机器人已能较好适应复杂多变的现实世界，而不仅仅局限于预先编程好的特定任务。

PaLM-E 架构



Source: PaLM-E, HTI

科技巨头们已经嗅到了具身智能的巨大潜力，纷纷加速布局。特斯拉计划于 2025 年底推出人形机器人 Optimus，并将在其工厂中承担实际工作任务。如果 Optimus 能如期达到预期，将对制造业产生颠覆性影响。而苹果公司则被曝出正在开发可以跟用户在家中走动的移动机器人，以及利用机器人技术移动显示屏的先进桌面家用设备。这些产品一旦问世，将为家庭生活带来很大便利。此外，英伟达也发布了 Project GROOT 人形机器人基础模型和开发套件 Jetson Thor，为人形机器人的开发提供强大的硬件和软件支持。


Optimus



Source: 特斯拉, HTI

GROOT 模型训练工作流程


Task Prompts



Source: 英伟达, HTI

随着科技巨头的积极布局和技术的不断突破，具身智能将成为未来 AI 发展的重要趋势，并有望在未来几年内深刻改变人类社会和生活方式。市场研究机构 Statista 预测，到 2025 年，全球具身智能市场规模将达到 225.2 亿美元，2030 年将超过 643.5 亿美元。具身智能在制造业、物流、医疗保健、家庭服务等领域的巨大应用潜力，将推动市场持续增长。具身智能作为人工智能与机器人技术的深度融合，正在从实验室走向现实应用。

全球具身智能市场规模




Source: Statista, HFI

3.2.3 AI 代理 (AI Agent)

AI 代理 (AI Agent) 是一种能够感知环境、进行决策和执行动作的智能指挥。不同于传统的人工智能，AI 代理具备通过独立思考、调用工具去逐步完成给定目标的能力。LLM 的快速发展为 AI 代理的构建提供了新的思路，其强大的理解和生成能力使其能够胜任 AI 代理的控制中枢，协调各个模块完成复杂任务。根据《A survey on large language model based autonomous agents》，一个典型的 AI 代理通常包含配置文件模块、记忆模块、规划模块和动作模块等核心组件。配置文件模块定义 AI 代理的目标、行为准则以及与外部环境交互的方式；记忆模块存储 AI 代理与环境交互的历史信息，为决策提供上下文依据；规划模块根据目标和环境信息，制定行动计划，并将计划分解成可执行的步骤；动作模块则负责执行规划模块输出的行动指令，与外部环境进行交互，并接收反馈信息。LLM 作为 AI 代理的核心控制器，可以有效地协调这些模块之间的协作，例如，理解配置文件模块中定义的目标，利用记忆模块中的历史信息进行推理，并指导规划模块制定合理的行动计划。

基于 LLM 的 AI 代理研究数目趋势及主要成果



Source: Wang L, Ma C, Feng X, et al. A survey on large language model based autonomous agents[J]. Frontiers of Computer Science, 2024, 18(6): 1-26., HTI

在 LLM 的加持下，AI 代理正在经历从在简单受控环境下完成特定任务到走向开放世界持续学习的转变。早期 AI 代理的应用范围主要局限于简单的游戏或受控环境下的任务。虽然 AlphaZero 等人工智能系统在国际象棋、围棋和日本将棋等封闭的、规则定义明确的环境中取得了成功，但它们在更动态的环境中却缺乏持续学习的能力。长期以来，人工智能研究人员一直面临着在开放世界中创建能够探索、计划和学习的 AI 代理的挑战。如今，AI 代理已经能够驾驭更加复杂的环境和挑战。例如，由英伟达、加州理工学院、德克萨斯大学奥斯汀分校、斯坦福大学和威斯康星大学麦迪逊分校联合创建的 Voyager，一个基于 GPT-4 的 Minecraft AI 代理，就在动态的电子游戏环境中表现出了非凡的游戏技巧，甚至超越了人类玩家的水平。

AI 代理未来应用空间广阔。(1) 在科学研究事业上，AI 代理被用于协助研究人员进行学术研究，例如收集和分析数据、生成研究报告等。其中在社会科学领域，计算社会科学利用计算方法分析复杂的人类行为数据，而 LLM 强大的类人能力为其带来了新的研究方法，已应用于心理学、政治学与经济学、社会模拟、法理学、社会科学研究助理等细分领域；在自然科学领域，基于 LLM 的 AI 代理也展现出巨大潜力，应用于文档和数据管理、自然科学实验助手、自然科学教育等方面。(2) 在工程领域，基于 LLM 的 AI 代理在土木工程、计算机科学与软件工程、航空航天工程、工业自动化、机器人与嵌入式人工智能、通用自主 AI 代理等领域展现出巨大潜力。特别是在计算机科学与软件工程领域，基于 LLM 的 AI 代理为自动化编码、测试、调试和文档生成提供了可能。(3) 在娱乐领域，AI 代理正朝着更加拟人可信的方向发展，为用户带来更具沉浸感和个性化的娱乐体验。一方面，AI 代理可以作为陪伴者，与用户进行情感交流，提供情感支持，满足用户的情感需求。另一方面，AI 代理可以化身为游戏或虚拟世界中更加真实可信的 NPC，与玩家进行更自然、更智能的互动，丰富游戏内容，提升娱乐体验。

基于 LLM 的 AI 代理体系结构设计的统一框架



Source: Wang L, Ma C, Feng X, et al. A survey on large language model based autonomous agents[J]. Frontiers of Computer Science, 2024, 18(6): 1-26. HTI

3.2.4 可解释 AI


通常生成式 AI 的数据推理和生成过程是一个“黑匣子”，不具备可解释性，但为了使生成式 AI 更安全、更有效的实现商用化，可解释 AI 将成为未来 AI 合规的重点研发方向。

根据 Been Kim 等人的定义，可解释性是指人们能够一致地预测模型结果的程度。机器学习模型的可解释性越高，人们就越容易理解模型为何做出特定决策或预测，换言之，模型决策背后的“推理过程”是透明的。然而，深度神经网络通常拥有数百万甚至数十亿个参数，其复杂程度使得人们难以理解它们是如何根据输入数据进行预测的，因此常被称为“黑匣”。虽然黑匣模型在许多任务中表现出色，但其缺乏透明度可能导致难以调试错误、识别偏差，以及在出现问题时难以追责。

Anthropic 的 Claude 团队在提高 AI 可解释性方面取得了多项突破。他们认为，机械可解释性是将神经网络分解成比整体更容易理解的组件，通过理解每个组件的功能以及它们之间的交互方式来解释整个网络的行为。然而拆分组件并不容易，神经网络的计算单元神经元并不是人类理解的自然单元，因为许多神经元是多义的：它们对看似无关的输入的混合做出反应，这种多义性使得我们很难根据单个神经元的活动来解释网络的行为。

针对这一问题，Claude 团队在 2023 年 10 月发表的《Towards Monosemanticity: Decomposing Language Models With Dictionary Learning》一文中，利用字典学习，成功将 ChatGPT 的神经元分解为约 4000 个可解释特征，初步克服了神经网络的不可解释性问题。2024 年 5 月发布的《Scaling Monosemanticity: Extracting Interpretable Features from Claude 3 Sonnet》将方法扩展到最先进的 Transformer，从 Anthropic 的中型生产模型 Claude 3 Sonnet 中提取了百万级别的高质量特征。这些特征能够对抽象行为做出反应，也能从行为上导致抽象行为，例如，名人的特征、国家和城市的特征等。许多特征是多语言和多模态的，并且包含相同想法的抽象和具体实例（例如，具有安全漏洞的代码，以及对安全漏洞的抽象讨论）。

文本与图片样本与特征的匹配



Source: 《Scaling Monosemanticity: Extracting Interpretable Features from Claude 3 Sonnet》, HTI

可解释性可以提高对 AI 系统的信任程度，也可以增强 AI 安全性。一方面，可解释性对于建立对 AI 系统的信任至关重要，尤其是在医疗诊断、金融贷款、自动驾驶等高风险领域。另一方面，Claude 团队发现部分特征与安全高度相关，例如与代码中的安全漏洞和后门相关的特征；偏见（包括公开的诽谤和更微妙的偏见）；撒谎、欺骗和寻求权力（包括背叛）；谄媚；危险/犯罪内容（例如，制造生物武器）等。提高可解释性可以从广义上提高模型的安全性，包括降低偏见、确保 AI 诚实行动、防止滥用等。

3.2.5 人类反馈纳入评估体系


辨别式 AI 时代可通过图灵测试等能力测试来判别该系统的能力，但生成式 AI 时代单纯以数据 benchmark 和测评榜单并不足以完成对其能力的完整评估，人类反馈亟须被纳入到评估体系。

生成式 AI 产出的结果更需要人类来判别其创新性。随着生成式人工智能技术的进步，传统基准测试方法在评估人工智能系统方面的局限性日益凸显。虽然 ImageNet、SQuAD 等传统基准测试在衡量特定技术指标方面发挥了重要作用，但它们难以全面评估人工智能系统在创造力、情感表达等方面的能力。例如，一个在文本生成任务中获得高分的 AI 系统，在生成内容的风格、原创性等方面可能仍有不足。

为解决这一问题，业界更多地将人类评估纳入人工智能系统的评价体系。例如，聊天机器人竞技场排行榜（Chatbot Arena Leaderboard）等平台，允许用户直接与不同的聊天机器人互动并进行评价，为评估人工智能系统的用户体验提供了重要参考。这种以人为中心的方法强调公众感知、用户满意度等因素，推动人工智能系统朝着更具吸引力、更符合人类价值观的方向发展。

聊天机器人竞技场排行榜成立于2023年，旨在通过大规模用户投票，量化公众对不同大型语言模型（LLM）的偏好。截至2024年2月，该平台已累积超过20万张投票。数据显示，OpenAI的GPT-4 Turbo模型以68.7%的得票率位居榜首，Google的Gemini Pro模型以21.3%的得票率排名第二。值得注意的是，部分在传统基准测试中表现优异的模型，在该排行榜上的排名相对靠后，这进一步凸显了用户体验在LLM评价中的重要性。我们预计未来将有更多开发者参考聊天机器人竞技场排行榜等用户驱动型评价指标，优化模型以提升用户体验。

Chatbot Arena 大模型排名




Source: 《Artificial Intelligence Index Report 2024》, HTI

3.2.6 AI 安全：超级对齐

超级对齐（Super Alignment）是指确保在所有领域都超越人类智能的超级人工智能（AI）系统按照人类的价值观和目标行事。超级对齐是AI安全和治理领域的一个重要概念，目标在于解决开发高度先进的AI所带来的风险。

AI的安全问题主要涉及两个方面，分别是AI模型的内生安全问题和AI模型交互过程所产生的外生安全问题。超级对齐的过程可以确保AI的目标和行为符合人类利益，防止AI失控，以及增加社会对AI的信任度，这一过程有利于加快AI的商业化进程。实现超级对齐需要在AI系统中增加多层次监督和控制机制、持续监控机制、融入伦理培训和结合人类反馈机制，以确保AI系统的初始阶段符合人类利益。同时，通过定期独立的外部安全审查、多层级的内部检验系统等措施，保证AI行为始终符合预设标准，从而维护系统的完整性和安全性。


超级对齐示意图



Source: OpenAI, HTI

如何实现超级对齐：通过弱模型来监管强模型甚至超人模型。 2023年12月，OpenAI首席科学家 Ilya Sutskever 等人发表论文《WEAK-TO-STRONG GENERALIZATION: ELICITING STRONG CAPABILITIES WITH WEAK SUPERVISION》，研究表明 1. 单纯依赖人类监督机制（如强化学习与人类反馈（RLHF））在应对超人模型（Superman models）可能扩展性不佳，需进一步改进；2. GPT-4 在 GPT-2 的监督下，能达到接近人类监督下 GPT-3.5 级别的性能，实现了“弱到强泛化”（weak to strong generalization，即在弱模型的监督下，强模型的表现仍较优），即是可实现让小模型监督大模型。2024年5月，Ilya Sutskever 和超级对齐团队负责人 Jan Leike 官宣离职，这对于 OpenAI 超级对齐团队将会带来巨大动荡。

测试结果




Source: OpenAI, HTI

4. “人工智能+”的行业赋能

4.1 互联网：被迫参战的军备竞赛，赢者通吃


全球互联网渗透率抵达高位，行业竞争从增量市场转向存量博弈。根据 Statista 的数据，互联网行业的全球用户渗透率 2021 年就已经高达 59.5%；从全球区域分布来看，欧美互联网渗透率较高，非洲互联网渗透率提升空间较大。Statista 数据显示，截至 24 年 4 月，全球互联网渗透率最高的 5 个地区为北欧、北美、西欧、南欧、东欧，其中北欧渗透率达到 97.4%。在中国，根据 CNNIC 数据，截至 23 年 6 月，中国网民数达 10.8 亿，较 21 年底提升 4.9%，互联网渗透率达 76.4%。走向未来，我们认为互联网行业的竞争将逐渐走向存量市场博弈，AI 作为新的技术变革必将成为各家厂商的必争之地。目前互联网行业的主要商业模式为流量变现，AI 的 Sota 模型将带来流量领域的“赢者通吃”，同时 AI 技术也将辅助互联网公司提升变现转化率。

全球互联网用户规模和渗透率



Source: Statista, HTI

中国的互联网用户规模和渗透率



Source: CNNIC, HTI

国外各家互联网巨头的超大规模预训练模型起步于 2018 年，并在 2021 年进入“军备竞赛”阶段。2017 年，Vaswani 等提出 Transformer 架构，奠定了当前大模型领域主流的算法架构基础；Transformer 结构的提出，使深度学习模型参数达到了上亿的规模。2018 年，谷歌提出了大规模预训练语言模型 BERT，该模型是基于 Transformer 的双向深层预训练模型，其参数首次超过 3 亿规模；同年，OpenAI 提出了生成式预训练 Transformer 模型——GPT，大大地推动了自然语言处理领域的发展。此后，基于 BERT 的改进模型、ELNet、RoBERTa、T5 等大量新式预训练语言模型不断涌现，预训练技术在自然语言处理领域蓬勃发展。

2019 年，OpenAI 继续推出 15 亿参数的 GPT-2，能够生成连贯的文本段落，做到初步的阅读理解、机器翻译等。紧接着，英伟达推出了 83 亿参数的 Megatron-LM，谷歌推出了 110 亿参数的 T5，微软推出了 170 亿参数的图灵 Turing-NLG。2020 年，OpenAI 推出了超大规模语言训练模型 GPT-3，其参数达到了 1750 亿，在两年左右的时间实现了模型规模从亿级到上千亿级的突破，并能够实现作诗、聊天、生成代码等功能。此后，微软和英伟达在 2020 年 10 月联手发布了 5300 亿参数的 Megatron-Turing 自然语言生成模型 (MT-NLG)。2021 年 1 月，谷歌推出的 Switch Transformer 模型以高达 1.6 万亿的参数数量成为史上首个万亿级语言模型；同年 12 月，谷歌还提出了 1.2 万亿参数的通用稀疏语言模型 GLaM，在 7 项小样本学习领域的性能超过 GPT-3。可以看到，大型语言模型的参数数量保持着指数增长势头。这样高速的发展并没有结束，2022 年，又有一些常规业态大模型涌现，比如 Stability AI 发布的文字到图像的创新模型 Diffusion，以及 OpenAI 推出的 ChatGPT，ChatGPT 是由效果比 GPT3 更强大的 GPT-3.5 系列模型提供支持，并且这些模型使用微软 Azure AI 超级计算基础设施上的文本和代码数据进行训练。

国外大模型参数对比

厂商	发布时间	模型名称	参数规模 (B)	预训练数据模型	领域
OpenAI	2022.5	GPT-3	175	300B tokens	NLP
	2023.1	GPT-4	1,800		多模态
	2024.1	GPT-4 Turbo	1,760	16T tokens	多模态
	2024.5	GPT-4 Omni			多模态
谷歌	2022.1	LaMDA	137	768B tokens	
	2022.4	PaLM	540		NLP
	2023.5	PaLM2	340	3.6T tokens	NLP
	2023.12	Gemini			多模态
	2024.2	Gemini 1.5			多模态
	2024.2	Gemma	2/7		NLP
Meta	2022.5	OPT	175	180B tokens	NLP
	2023.1	LLaMA	65	1.4T tokens	NLP
	2023.6	LLaMA2	70	2T tokens	NLP
	2024.4	LLaMA3	70	15T tokens	NLP
微软	2020.2	Turing-NLG			CV
	2021.11	Florence			
英伟达	2021.10	Megatron-Turing NLG	530	339B tokens	NLP
xAI	2024.3.17	Grok-1	314		NLP

Source: 各公司官网, HTI

国内大模型参数对比

厂商	发布时间	模型名称	参数规模 (B)	预训练数据模型	领域
阿里巴巴	2021.11	M6	10,000	1.9TB 图像和292GB 文本	多模态
	2023.4	通义千问	70		多模态
	2023.10	通义千问2.0	1,000		多模态
腾讯	2023.9	混元AI 大模型	1,000	五大跨模态视频检索数据集	多模态
华为	2021.4	盘古NLP大模型	100	40TB数据	NLP
	2021.4	盘古CV大模型	3		CV
	2023.7	盘古3.0大模型	10/38/71/100	3T tokens	NLP
百度	2022.1	ERNIE 3.0 Titan	260	4TB语料库	NLP
商汤科技	2021.11	书生 (INTERN+)	10		CV
	2024.4	日日新5.0大模型	600		多模态

Source: 各公司官网, HTI

4.1.1 微软：作为破坏性创新者，在算力+算法+应用生态上已呈现完整布局

作为 OpenAI 的主要投资人，微软在 AIGC 算法领域布局较早。微软 2019 年 3 月就对 OpenAI 进行了 10 亿美金注资，2023 年 1 月 24 日，微软公司在官方博客宣布已与 OpenAI 公司扩大合作伙伴关系，两家公司合作伙伴关系进入第三阶段，微软将向 OpenAI 进行一项为期多年、价值数十亿美元的投资，以加速其在人工智能领域的技术突破。我们认为，微软在 AIGC 领域的完整生态，可助力其在未来发展中保持优势。


强大的算力为微软在 AI 领域奠定了良好基础

自 2019 年注资 OpenAI 开始，微软便成为了 OpenAI 的独家云计算服务商。微软的云服务一直为 OpenAI 的产品、API 服务和研究中所有的工作负载提供支持，同时双方在 Azure 上合作研发人工智能超级计算技术。此后，微软于 20 年便推出了用于在 Azure 上训练超大规模人工智能模型的超级计算机，其拥有超过 28.5 万个 CPU 核心和 1 万个 GPU，其中每 GPU 拥有 400Gbps 网络带宽。根据微软 20 年 Build 开发者大会介绍，

此超算平台性能位居全球前五，并且得益于在 Azure 上托管，这台超级计算机拥有现代云计算基础设施的各种优点，包括快速部署、可持续发展的数据中心并可以访问所有 Azure 服务。

强大的算力是 ChatGPT 不断迭代进化的基础：从数据需求看，GPT 3.0 使用了 1750 亿个参数进行训练，而 GPT-4 使用 1.8 万亿参数，预示着更多的算力需求以及高集中度的云服务。从专注于感知型（图像、声音和视频等感官数据的解读）人工智能进化到生成型人工智能（新内容的创建），这将需要成倍增长的计算能力。我们认为，微软的强大的算力叠加生态服务，为公司在 AIGC 领域奠定了良好基础，且这一优势已在过去云基础服务市场所验证：在全球云基础设施服务市场，根据 Synergy Research Group 数据显示，微软 Azure 在 2022 市场份额已达到 21%，仅次于亚马逊 AWS，并呈节节上升之势。

全球云基础设施服务份额 (IaaS, PaaS 和私有云托管)




Source: Synergy Research Group, HTI

AIGC 算法层面，微软在自研与合作上同时进行：

- 1) **与 OpenAI 紧密合作：**后者已在为微软定向研发下一代大型语言模型 (LLM) - 根据 2 月 8 日微软发布会介绍，这一模型专为搜索服务定制，其吸取了 ChatGPT 和 GPT-3.5 的重要经验，而且速度更快、更准确，这一模型将搭载在全新的 Bing 服务上。此外，微软与 Open AI 合作研发的“Prometheus Model”也将应用在新的 Bing 搜索服务上，其可提高搜索结果相关性，同时更加安全；
- 2) **联手英伟达推出威震天-图灵自然语言生成模型 (Megatron Turing-NLG)：**包含 5300 亿参数，几乎三倍于 ChatGPT 3 的参数数量。
- 3) **自研视觉基础模型 Florence：**该模型将表征从粗粒度（场景）扩展到细粒度（对象），从静态（图像）扩展到动态（视频），从 RGB 扩展到多模态。通过结合来自 Web 规模图像 - 文本数据的通用视觉语言表征，Florence 模型可以轻松地适应各种计算机视觉任务，包括分类、检索、目标检测、视觉问答 (VOA)、图像描述、视频检索和动作识别；

微软 Florence CV 模型技术架构



Source: 微软, HTI


应用上，微软完成产品生态升级，商业化落地全面开展，搜索市场份额有望提升

微软在 Build 2023 大会已发布一系列涵盖从 Azure OpenAI、Copilot Stack、开发工具到协作应用等领域的 AI“全家桶”，将 ChatGPT 整合进入自身的软件与服务生态之中。其代表产品为 Windows Copilot（智能副驾），即在 Windows 11 中加入一个 AI 助手，可以帮助用户完成内容摘要、重写、解释等各种任务。此外，微软还宣布采用与 OpenAI ChatGPT 相同的开放插件（Plugin）标准，从而确保今后 ChatGPT 与微软一系列“智能副驾”产品服务之间的互操作性。

2023 年 2 月，微软推出由 OpenAI 提供技术支持的新版 Bing 搜索引擎，开启 AI 应用商业化落地。根据微软 CEO 纳德拉在 2 月 8 日的发布会上所言，传统搜索引擎痛点主要在于结果不准确，而新的 Bing 搜索引擎将有效解决这一痛点。具体来讲，全新 Bing 在技术上有四重突破：1) 模型上：Bing 将在 Open AI 的下一代 LLM（大型语言模型）上运行，其专为搜索定制，带来全新的交互体验；2) 搜索算法上，微软与 Open AI 合作的“Prometheus Model”可提高搜索结果相关性，同时更加安全；3) 将人工智能应用于核心搜索算法。微软将 AI 模型应用于其核心必应搜索排名引擎，从而实现了二十年来相关性的最大跃升。有了这个 AI 模型，即使是基本的搜索查询也更加准确和相关；4) 用户体验设计上，新的 Bing 将带来集答案、聊天和浏览一体的搜索体验。

公司对搭载了全新 AI 功能的 Bing 搜索商业化前景充满信心。事实上，公司本身的广告业务已连续两年快于市场增长（微软 22 年搜索与新闻广告收入约 180 亿美金，两年 CAGR 为 24%，快于全球数字广告市场 19% 增速）。根据 eMarketer 数据，全球数字广告市场 22 年规模为 5700 亿美金，其中 40% 为搜索广告，据此计算可得知微软仅占搜索市场 6% 份额，而谷歌份额高达 70%。未来来看，公司认为不断优化的 Bing 搜索体验将助力其获得市场份额，尤其是国际市场份额（考虑到公司在大型语言模型上的优势将助力渗透海外当地市场）。

全球数字广告市场收入 (十亿美元)



Source: emarketer, HTI

2024 年 5 月的微软 Build 2024 开发者大会上，微软发布了 60 种 AI 新产品和解决方案，涵盖了从 AI 基础设施的搭建，到模型产品的落地方向的工具和生产工具。**主要产品包括：**

1. Team Copilot: 新的 Copilot 从个人助理变成以企业服务、微软设备终端一同的团队助理，用户可以在 Teams、Loop、Planner 等协作工具中调用 Copilot。

Copilot 产品线



Source: 微软, HTI

2. Microsoft Copilot Studio 推出全新的 Agent 代理功能，让开发者能够根据特定任务和功能，可以让任何人构建具有代理能力的 Copilot，并可以异步工作，构建主动响应数据和事件的“智能 Copilot”。同时，Copilot Studio 中的 Copilot 连接器可以将 Copilot 与数据连接，从而快速将组织知识融入数据。

3. 推出开发者工具 GitHub Copilot、Copilot Extensions 和 Copilot Workspace，更新的 GitHub Copilot 可帮助开发者在非编码方面的工作，如收集需求、编写规范和创建计划；同时，Windows Copilot Runtime 使 Windows 成为最佳 AI 平台，支持 PyTorch 和 WebNN 框架；此外，微软推出 WebNN，为开发者提供直接访问 GPU 和 NPU 的机器学习框架。

4. 向开发者开放 Phi-3 轻量级 AI 模型：Phi-3 系列包含三种规模的模型，即 Phi-3-mini（38 亿参数）、Phi-3-small（70 亿参数）和 Phi-3-medium（140 亿参数），其中 Phi-3-mini 已被纳入 Azure AI 平台。微软还特别推出了 Phi-3-vision，这是一款具有 42 亿参数

的多模态小模型变种，能够支持通用视觉推理任务以及图表、图形的推理。Phi-3 系列是一个拥有 30 亿参数的语言模型，它针对个人设备进行了优化，旨在以较低的成本提供与大型模型相匹敌的推理能力。

Phi-3 家族



Source: 微软, HTI

5. 微软 Fabric 升级，推出实时智能（real-time intelligence），提供端到端软件即服务解决方案，能够为用户提供实时的数据分析服务，帮助用户快速处理和响应海量且详细的数据。此外，微软 Azure AI Studio 也全面更新，包含 API 集成、完整的工具链及部署全家桶等。

6. 自研 AI 芯片更新。微软宣布推出专为云端规模化应用性能优化的 Cobalt 芯片，目前已经为 Microsoft Teams 等服务提供了数十亿次对话的支持；同时，微软还预览了自研 Azure Maia 100，以及与 AMD 共同合作，使得微软成为第一个提供最新 ND MI300X v5 虚拟机的云服务供应商；另外，纳德拉还宣布，英伟达关键平台产品，都会引入微软的云中。**纳德拉强调，截止 2024 年 5 月，微软 Azure 超算能力已经实现了 30 倍（3000%）的增长。**微软提供了世界上最先进的 AI 加速器，开发者可以拥有最完整的 AI 加速器进行选择。

4.1.2 Google：作为防守者，短期面临更大的竞争压力

ChatGPT 的问答模式与微软结合后，长期很可能在目前 Google 垄断的搜索引擎市场撕开裂缝，Google 的搜索广告业务在变现端也会承压，因为其广告业务建立在从关键词链接到页面的基础上。Google 作为算力和资金丰富的互联网巨头，同时采用**联合和投资 ChatGPT 的竞对和加速推出自研的聊天机器人的手段来建立自己的护城河。**

防守策略之一：直面竞争

鉴于 ChatGPT 的迅猛的发展势头以及未来较大可能的对 Google AI 地位和搜索业务的挑战，在 ChatGPT 推出后，Google **对其是持对抗态度，主要举措包括调整 AI 领域业务，以及紧急发布自研聊天机器人。**2023 年谷歌公司内部称围绕 ChatGPT，全面调整在 AI 领域的工作。据《纽约时报》，谷歌内部包括研发、安全和信任等多个部门的团队被重新分配工作，辅助开发新的 AI 技术原型和产品。

在 5 月份的 2024 I/O 技术大会上，谷歌 CEO 桑达尔·皮查伊（Sundar Pichai）在长达 110 分钟的演讲中，连续发布几十款 Google 和 AI 结合的新产品，对阵 OpenAI。


谷歌新产品发布

分类	名称	特点	发布状态
AI 模型	Gemini 1.5 Pro	性能显著提升，拥有 200 万令牌上下文窗口，适合广泛任务的最佳模型。	升级
	Gemini 1.5 Flash	更轻量化、速度更快且成本更低，适用于大规模高频任务。	新发布
	Gemini Nano	多模态理解能力，支持文本和图像输入，适用于设备内应用。	升级
	Gemma 2.0	具有新架构，突破性的性能和效率。适用于负责责任的 AI 创新。	新发布
	PaliGemma	第一个视觉语言模型，基于 PaLI-3，扩展了 Gemma 家族。	新发布
多模态生成模型	Veo	最先进的视频生成模型，生成高质量 1080p 视频，理解自然语言和视觉语义。	新发布
	Imagen 3	最高质量的文本到图像生成模型，细节丰富，逼真度高。	升级
AI 延展产品	Google Messages	集成 Gemini，实现更自然的聊天体验。	新增功能
	Gemini Live	使用最先进的语音技术，实现更加自然和直观的对话体验。	新发布
	Search Labs	提供生成性 AI 功能的实验平台，支持复杂问题解决和计划功能。	升级
	Gems	允许用户创建定制版本的 Gemini，满足特定需求和个性化响应。	新发布
	Project Astra	未来 AI 助理的愿景，目标是开发通用 AI 代理，能够理解和响应复杂环境。	新发布
	Music AI Sandbox	生成音乐的 AI 工具套件，支持音乐创作和实验。	升级
硬件	Trillium TPU	第六代 TPU，性能和能源效率显著提升，支持训练和服务最强大的 AI 模型。	新发布

Source: 谷歌, HTI

Gemini 1.5 Flash: Gemini Advanced 上线三个月之后，注册用户已超过 100 万；新版 Gemini 1.5 Pro 面向全球用户正式推送，最高支持一百万 Token 上下文识别（通行计算方法中约等于 50 万中文字符）。Gemini 1.5 Pro 最大支持上下文窗口从 100 万 Tokens 升级到 200 万，并且能同时支持 35 种语言。而且升级后的 Gemini，不仅能分析比以前更长的文档、代码库、视频和音频录音，还能处理更加复杂和细微的指示，比如指定产品级行为的指示，如角色、格式和风格等。为了满足用户对低延迟和低成本的需求，谷歌重磅发布轻量化模型 Gemini 1.5 Flash。Gemini 1.5 Flash **专为大规模服务设计，成本低至 0.35 美元/百万 Tokens**。它拥有更高的效率、更低的时延，不仅支持 100 万和 200 万 Tokens 两个版本，还适用于摘要、聊天应用、图像和视频字幕、长文档和表格数据提取等任务。

谷歌的 Gemini 1.5 Flash



Source: 谷歌, HTI

最新版 Gemma 2: Gemma 开源模型于今年 2 月问世，新版 Gemma 2 采用全新架构，参数达到 27B，拥有突破性的性能和效率。由于 Gemma 2 具有 270 亿个参数，其性能可与 Llama 3 70B 相媲美，但尺寸却只有 Llama 3 70B 的一半。谷歌表示，Gemma 2 是一款轻量级、前沿的开放式模型，继承了 Gemini 模型的研究和技术精髓。颇有悬念的是，Gemma 2 模型将在未来几周正式上线和发布。

多模态产品的努力: DeepMind 负责人哈萨比斯重点介绍了谷歌在多模态领域的新进展。他表示，未来谷歌将在图像、音频以及视频三个主要内容领域全方位出击；同时推出五款基于 Gemini 大模型的生成式 AI 产品。产品中，例如 Project Astra 智能助手。它与 NotebookLM 结合，将成为 GPT-4o 的有力竞争对手。谷歌在演讲中，展示了一个人拿着手机在办公室走动，将摄像头对准各个方位，并用语言与其沟通。与此同时，Project Astra 成功地识别出了各种物体、地点和代码，还能实时进行语音互动。

第六代 TPU 芯片: 发布了迄今为止最强大、最节能的张量处理单元 Trillium TPU（第六代）。据谷歌介绍，第六代硬件将为生成式人工智能模型和工作负载提供支持，提供比现有 TPU 显著增强的计算、内存和网络功能。Trillium GPU 的高带宽内存容量和带宽是原来的两倍，计算能力相比前代提升 4.7 倍，将在 2024 年底面向用户（包括云客户）推出。

防守策略之二：对 ChatGPT 的竞对进行投资和合作

2023 年 2 月 4 日，Google 向 Anthropic 投资近 4 亿美元，获得 10% 股份，同时 Google Cloud 为 Anthropic 首选云供应商，为其提供 AI 算力。Anthropic 由 OpenAI 前研究副总裁达里奥·阿莫迪（Dario Amodei）、GPT-3 论文一作 Tom Brown 等人于 2021 年成立，推出了聊天机器人 Claude，在此之前公司发布了论文，描述了一个基于无监督方式训练、520 亿参数的模型 AnthropicLM v4-s3，直接对标 OpenAI 的 GPT-3 模型。Google 这一举动表现出其可以基于 Google 云计算平台来跟生成式 AI 公司绑定关系，从而搭建 AI 护城河的意图。

除了 Anthropic，Google 云也和 Cohere 和 C3.ai 建立了合作，通过广泛投资合作为自研大模型争取时间。

4.1.3 Meta: 开源大模型标杆，推动 AI 技术应用前往更高峰

同为互联网巨头，Meta 的 AI 大模型以开源为特征，旗下 Llama 模型均对外部开发者免费开放。早在 2022 年，Meta 便已开源旗下的 1750 亿参数大模型 OPT-175B，是大规模语言技术系统在历史上第一次毫无保留，把预训练模型、训练代码以及使用代码全部展现在公众面前。2023 年 2 月，Meta 发布开源大模型 Llama-1，其中最大 65B 参数的模型在大多数基准测试中超越了 175B 参数的 GPT-3，迅速成为开源社区中最受欢迎的大模型之一。同年 7 月，Meta 发布开源大模型 Llama-2，相较 Llama-1 增加了支持商用。Meta 的开源模型因鼓励第三方开发者和研究者进一步训练和微调，成为许多研究者的基座模型，大大推动了大模型的研究进程。


2024 年 4 月，Meta 推出号称“最强开源模型”的 Llama-3，在多个领域领先同等规模的其他模型。Llama 3 提供了 8B（80 亿参数）和 70B（700 亿参数）两个版本的模型，Meta 还透露，400B 的 Llama-3 还在训练中。Llama 3 基于超过 15T token 训练，相当于 Llama 2 数据集的 7 倍；支持 8K 长文本，改进的 tokenizer 具有 128K token 的词汇量；同时在推理、代码生成和指令跟随能力都有较大改进。Meta 展示了包括 MMLU、ARC、DROP、GPOA（生物、物理、化学相关的问题集）、HumanEval（代码生成测试）、GSM-8K（数学应用测试）等的测试结果，Llama 3 8B 的成绩在九项测试中领先同行。在 MMLU、HumanEval 和 GSM-8K 上，Llama 3 70B 击败了 Gemini 1.5 Pro。此外，在 Meta 开发的高质量人类评估数据集中，Llama 3 不仅大幅超越 Llama 2，也战胜了 Claude 3 Sonnet、Mistral Medium 和 GPT-3.5 这些知名模型。

Llama3 测评结果



Source: Meta, HTI

Llama3 及其他模型人类评估数据集测试结果



Source: Meta, HTI

Meta 背靠强大的社交平台积累，在智能软硬件端同时发力 AI 应用。基于 Llama 模型推出的类 ChatGPT 式 AI 聊天助手 Meta AI 具备智能对话、搜索集成、图像生成等多种功能，已接入 Meta 家族的多个应用软件中，如 Instagram、WhatsApp、Facebook 等。得益于 Meta 巨大的社交平台用户群体规模，接受公共用户数据训练后的 Meta AI 表现可期。除了社交平台，Meta AI 还能用于 Meta 推出的智能眼镜和 Meta Quest 头显设备，在智能硬件领域开启 AI 应用商业化进程。

4.1.4 中国玩家的进展：BAT、商汤、华为积累深厚；其他玩家亦在积极入局

国内大模型研发迅速，多个厂商已有深厚积累。2021 年成为中国 AI 大模型的爆发年。2021 年，商汤发布了书生 (INTERN) 大模型，拥有 100 亿的参数量；同年 4 月，华为云联合循环智能发布盘古 NLP 超大规模预训练语言模型，参数规模达 1000 亿；联合北京大学发布盘古 α 超大规模预训练模型，参数规模达 2000 亿。阿里达摩院联合清华大学发布参数规模达到 1000 亿的中文多模态预训练模型 M6；7 月，百度推出文心 3.0 知识增强大模型，参数规模达到百亿；12 月，百度推出文心 3.0 Titan 模型，参数规模达 2600 亿。而达摩院的 M6 模型参数达到 10 万亿，将大模型参数提升了一个量级。

中国的大模型并不落后于国外同类产品，在某些领域还能实现反超。以商汤科技的书生（INTERN）为例，书生（INTERN）在分类、目标检测、语义分割、深度估计四大任务 26 个数据集上，基于同样下游场景数据（10%），相较于同期 OpenAI 发布的最强开源模型 CLIP-R50x16，平均错误率降低了 40.2%，47.3%，34.8%，9.4%。同时，书生只需要 10% 的下游数据，平均错误率就能全面低于完整（100%）下游数据训练的 CLIP。

GPT-4 发布后，国内大模型军备竞赛加速，均力争性能赶超国外玩家。2023 年 3 月 13 日，OpenAI 发布了作为行业指标的语言模型 GPT-4，其后百度发布文心一言，拉开国内大模型追赶 GPT-4 的序幕；4 月商汤科技发布 SenseChat，阿里巴巴发布通义千问；7 月华为云发布盘古大模型 3.0，均力争对标 GPT-3.5、在部分性能指标超越 GPT-4。此 2023 年 11 月 7 日 GPT-4 Turbo 发布，24 年 4 月商汤发布 6000 亿参数级大模型日日新 5.0，根据 OpenCompass 评测已率先对标 GPT-4 Turbo 水平。2024 年 2 月 16 日，OpenAI 发布 Sora，以在视频生成领域开启新一轮追赶进程。

部分中国公司虽然目前还没有正式推出自身大模型产品，但是也在积极进行研发。例如云从科技，公司的研发团队高度认同“预训练大模型+下游任务迁移”的技术趋势，从 2020 年开始，已经陆续在 NLP、OCR、机器视觉、语音等多个领域开展预训练大模型的实践，不仅进一步提升了公司各项核心算法的性能效果，同时也大幅提升了公司的算法生产效率，已经在城市治理、金融、智能制造等行业应用中体现价值。

GPT-4 发布后国内大模型发展历程



Source: 各公司官网, HTI

百度：国内 AI 先行者，文心一言大模型全面重构产品生态

百度作为国内搜索及 AI 领域头部公司，在 AI 行业布局较早，新业务均以 AI 作为重要技术底座。除了广告收入外，公司其他新业务包括云服务、智能设备及服务、智能驾驶等，与人工智能技术有较强关联，是当前公司重点发力投入的第二、第三曲线业务，在 AI 发展方面把握先机。

基础层：在云、芯片方面均有积累

- **百度智能云在 AI 领域领跑。**根据 IDC 报告，AI 公有云服务厂商市场格局相对稳定，2022 上半年百度智能云仍然稳居第一，整体市场份额占比 28.1%，这也是百度智能云连续四年市场份额第一。前四位分别为百度智能云、阿里云、华为云、腾讯云。

- **自研 AI 芯片昆仑，具备软硬一体的全栈 AI 能力。**2021 年百度自研昆仑 2 代芯片量产（3 代将于 2024 年初量产），采用 7nm 制程，可提供 256TOPS@INT8 以及 128 TFLOPS@FP16 算力。根据 Apollo 开放者日信息，昆仑芯片已经在互联网、工业质检、智慧交通、智慧金融等场景均有规模部署案例。此外昆仑芯 AI 芯片也已与飞腾等多款国产通用处理器、麒麟等多款国产操作系统以及百度自研的飞桨深度学习框架完成了端到端的适配，拥有软硬一体的全栈国产 AI 能力

模型层：文心大模型基于千亿级参数训练，开源深度学习平台飞桨也积累了大量开发者

- **文心大模型：**2019 年，百度基于谷歌在 2018 年发布的自然语言处理模型 BERT，开发推出大型人工智能语言模型“文心”，同时加入了很多知识类的中文语料进行训练，一度被称为最强中文 NLP 模型。经过多年发展，“文心”现在已成为 NLP（自然语言处理）算法集、预训练模型、开发套件、平台化服务于一体的大型平台。2022 年 11 月，文心大模型一次性发布 11 个大模型，涵盖基础大模型、任务大模型、行业大模型的三级体系，全面满足产业应用需求，**大模型总量已增至 36 个**。2023 年，**百度发布文心大模型 4.0，其理解、生成、逻辑、记忆四大能力都有显著提升**。其中理解和生成能力的提升幅度相近，而逻辑和记忆能力的提升则更大，逻辑的提升幅度达到理解的近 3 倍，记忆的提升幅度也达到了理解的 2 倍多。
- **飞桨平台：**根据百度港股招股书，飞桨是全球范围内累计拉取请求数量第二的开源学习框架，是中国拥有开发者数量最多的 AI 开源学习平台，根据 WAVE SUMMIT 及 2022 深度学习开发者峰会，截至 2022 年 11 月，飞桨平台已凝聚 535 万开发者，服务 20 万企事业单位，基于飞桨创建了 67 万个模型。

文心大模型全景图



Source: 文心大模型官网, HTI

应用层：文心大模型 4.0 接入全栈产品，全面重构生态

2023 百度世界大会上，百度通过文心大模型 4.0 对搜索引擎、百度文库、如流、百度网盘、百度地图等产品进行了全面重构。1) 百度搜索转型为 AI 互动搜索，呈现的结果不仅是链接，更是最优答案，让搜索结果更加智能；2) 百度文库实现了信息理解、文章写作、PPT 智能生成、风格切换等功能的升级。此外，它还能根据相应语音提供可能的问题和答案；3) 如流升级为人工智能超级助手，实现“1000 条信息，1 秒画重点”。它还可以为职场等场景提供服务，包括旅行行程生成、自动订票、讨论资料建议、群聊要点总结等；4) 百度网盘个人云智能助手“云一朵”已积累了高达 2000 万用户。云一朵可实现自然语言交互，具备语义理解功能，可根据文件描述进行搜索和操作；5) 百度地图发布人工智能导游，具备多轮自然语言交互能力，可提供智能路线规划导航、位置查询、智能出行等出行相关服务。6) 在文心一言 4.0 的基础上，百度推出了 GBI，帮助用户以最快的速度做出商业决策。7) 百度还推出了百度智能云千帆 AI 原生应用商店和轻舸营销平台，为文心一言展示了巨大的盈利场景。

文心 4.0 赋能产品

产品	文心一言 4.0 赋能
搜索引擎	搜索结果格式从网络链接变为由 LLM 生成的最佳答案 多轮对话和相关问题推荐
文库	通过移动设备上的语音命令进行文档编辑和管理 通过智能问答对话进行文档内容搜索、摘要、文本/PPT 生成
如流	快速总结群聊信息中的要点 一键式解决出差安排等行政工作
网盘	与人工智能助手“云一朵”进行自然语言交互，搜索和定位视频中的特定内容，并生成关键点
地图	将多级菜单变为一步访问，简化用户的操作流程 通过语言对话支持导航、叫出租车、推荐活动场地和其他功能
贴吧	与基于虚构人物的人工智能角色直接互动
百度 App	在评论区汇总长篇文章、视频和内容，并智能推荐感兴趣的内容 通过评论区的对话与视频中的人物互动
输入法	超会写“AI 写作助手”，支持自动完成和润色输入文本 针对不同行业（如法律和销售）的特定模式
GBI	辅助决策过程的新产品，包括数据汇总、执行计划生成等。 自然语言交互、跨数据库分析和专业知识学习
Comate	编码助手，提供代码自动完成、基于自然语言命令的代码推荐、自动纠错等功能
Apollo 智驾	结合 ERNIE Bot 和 Apollo 数据的 LLM，可应用于车载语音产品
轻聊	全球首个个人人工智能原生营销平台，可生成广告文案、数字人文视频和其他营销材料
慧播星	人工智能驱动的全栈数字人类直播平台，可生成人工智能头像、多语言定制语音、脚本等
添添家庭机器人	世界上首个由 LLM 驱动的智能家居机器人，具有多种功能，包括提供陪伴、家务管理和照顾老人
小度青禾学习机	一对一人工智能辅导员，可提供个性化诊断、学习计划生成、定制辅导和其他功能
智能音箱 Tiantian Casa	支持智能交互的 AI 音箱

Source: 百度, HTI

商汤：GAI 驱动增长，全面对标 GPT-4 Turbo

2024 年 4 月，商汤科技发布了日日新 5.0 大模型 (SenseNova 5.0)，各项指标全面对标 GPT-4 Turbo。日日新 5.0 具有更强大的大语言模型功能，并增加了更多的大模型思维链数据，使该模型能够更好地理解中文和中国文化场景中的上下文。其采用混合专家模型 (MoE) 法，使大语言模型能够更准确地理解特定行业中的上下文，并使用超过 10TB 的文本数据单元 (token) 和高质量合成数据进行训练，旨在使该模型在中文环境中拥有出众的性能。该模型在推理过程中，上下文窗口可以有效达到 200k，且能通过解耦推理计算所需工作量。同时，该模型可以在终端侧部署，且能更大地减轻硬件的负担。根据公司科技日活动上的案例，仅有 30% 的推理工作需要在终端侧完成，剩余的 70% 在云端完成，这将使生成式人工智能的部署和商业化具有更高的可行性和性价比。


日日新 5.0 核心指标

Category	Benchmark	GPT-4 Turbo (100)	GPT-4 Turbo	Ratio	Llama3.7B Instruct	Llama3.7B Chat	Ratio	SenseChat V4
综合能力	MMLU (0-shot)	83.81	84.87	101.26%	81.12	81.85	100.91%	84.78
	MMLU (5-shot)	77.94	82.05	105.27%	75.1	81.87	109.03%	79.81
	Chat Eval	61.53	61.69	101.24%	60.78	62.27	102.27%	61.81
中文能力	TriviaQA (0-shot)	71.01	65.81	91.28%	65.25	62.79	95.7%	68.78
	RaceQuestions (0-shot)	27.95	31.96	114.35%	31.09	31.61	104.81%	31.81
	SAC (High) (0-shot)	58.22	60.15	103.33%	58.59	61.65	105.9%	61.68
代码能力	Woodruffe (0-shot)	85.84	88.85	103.39%	85.09	88.13	103.59%	88.15
	HumanEval (0-shot)	74.72	79.11	105.88%	67.77	76.01	109.23%	81.22
	BigCodeHard (0-shot)	81.71	85.11	102.93%	81.86	84.88	103.69%	83.98
数学能力	GSMAK 14 (shot, w/o context)	82.83	78.37	94.62%	80.33	80.48	98.73%	82.88
	MATH (0-shot, w/o context)	63.85	70.02	109.67%	41.08	43.36	105.41%	64.33
	MATH (0-shot, w/o context)	65.02	71.67	110.23%	51.09	56.35	109.91%	60.75
总分	HumanEval (0-shot)	74.58	73.77	98.78%	72.08	77.30	105.85%	78.18
	MATH (0-shot)	64.66	66.02	101.95%	51.51	60.47	116.52%	70.08

Source: 商汤, HTI

商汤于 2023 年 4 月推出的日日新 4.0 模型，即日日新 5.0 的前身，将卓越的性能与易于使用、开发人员友好的集成工具相结合。日日新 4.0 大模型是对其基础人工智能模型的精密升级，能够覆盖更多的知识领域、改进推理能力、卓越的长文本理解能力、数字推理能力、代码生成能力和多模态交互能力。升级版大语言模型（LLM）SenseChat V4 的性能与 GPT-4 相当，在总体指标上超过了 GPT-3.5。与此同时，商汤还推出了 SenseChat 功能调用与助手 API，这是一种开创性的多模式工具调用 API，大大简化了开发人员的集成过程，使他们能够更轻松地在各种应用中利用大模型。

SenseChat V4 和 GPT-4 对比



Source: 商汤, HTI

日日新 4.0 在理解和推理方面可与 GPT-4 媲美，在编码和数据分析方面表现出色，树立了新的性能标准。日日新 4.0 支持多种标记大小，从而扩大了应用范围，并在知识理解、推理和编码方面取得了显著改进，与 GPT-4 设定的性能基准相当接近。其 LLM，特别是 SenseChat V4，在长文本理解和编码方面表现出色，在 HumanEval 基准上实现了值得注意的一次通过率。此外，SenseChat-DataAnalysis V4 模型在数据分析场景中的准确性也超过了 GPT-4，这表明它善于处理复杂的表格、文件和各种数据分析任务。

SenseChat-Medical V4 总分第二，并在两个特定类别中击败 GPT-4

2023 Pharmacist Licensure Examination (Pharmacy)					
Model	Optimal Choice	Matched Selection	Integrated Analysis	Multiple Choice	Total Score
GPT-4(API)	66.1	59.6	46.7	16.8	57.3
SenseChat - Medical V4	81.3	58.6	53.3	20.0	55.6
HuatuGPT-III(13B)	47.5	64.1	45.0	23.7	52.9
Qwen-72B-chat	56.2	55.6	41.7	21.1	52.7
ERNIE Bot	46.0	60.9	36.7	23.7	49.6
HuatuGPT-III(7B)	41.9	61.0	35.0	15.7	47.7
BaiduuanQ-7B-Chat	51.2	50.9	30.0	7.6	44.6
BaiduuanQ-13B-Chat	43.8	52.7	36.7	7.9	44.2
Qwen-7B-chat	43.8	46.8	33.3	18.4	41.9
ChatGPT(API)	45.6	44.1	36.7	13.2	41.2
ChatGLM2-6B	57.0	36.8	25.0	51.7	35.6
ChatGLM3-6B	59.5	39.1	10.5	0.2	34.6
HuatuGPT	25.6	25.5	23.3	2.6	23.4
DISC-MedLLM	22.2	26.8	23.3	0.0	22.6

Source: 商汤, HTI

SenseChat-Medical V4 和 SenseChat-Vision V4 在医疗保健、视觉和多模态人工智能领域处于领先地位。在医疗保健和视觉领域，SenseTime 的进步尤为显著。SenseChat-Medical V4 增强了多轮对话和复杂医疗推断的能力，使其性能接近 GPT-4，并在某些评估中超过了 GPT-4。同样，SenseChat-Vision V4 在 MME 基准测试中的综合得分也为大型多模态模型树立了新标准，促进了自动驾驶和能源等行业更广泛的应用。此外，文本到图像生成模型 SenseMirage V4 在图像渲染能力方面也取得了显著进步，使商汤站在了多模态人工智能技术的前沿。

华为：深耕算力打造强力底座，结合大模型服务千行百业

华为是国内最早布局大模型的云服务商之一，早在 2021 年就已经发布盘古大模型。华为在 2012 年就建立了诺亚方舟实验室负责人工智能领域的研究，研究方向囊括自然语言处理、人工智能决策等领域，具有 AIGC 模型开发的技术基础。2021 年 5 月，华为已经联合鹏城实验室发布全球首个两千亿稠密参数中文 NLP 大模型“鹏程·盘古”。

2023 华为开发者大会发布面向行业的盘古大模型 3.0，展示出了高度成熟的业务能力。盘古大模型 3.0 包括“5+N+X”三层架构，即 L0 层的 5 个基础大模型、L1 层的 N 个行业通用大模型、以及 L2 层可以让用户自主训练的更多细化场景模型。其采用完全的分层解耦设计，企业用户可以基于自己的业务需要选择适合的大模型开发、升级或精调，从而适配多个行业的需求。

华为深耕算力，为大模型建立了强有力的算力底座。华为在最底层构建了以鲲鹏和昇腾为基础的 AI 算力云平台，以及异构计算架构 CANN、全场景 AI 框架昇思 MindSpore，AI 开发生产线 ModelArts 等，为大模型开发和运行提供分布式并行加速，算子和编译优化、集群级通信优化等关键能力。基于华为的 AI 技术，大模型训练效能可以调优到业界主流 GPU 的 1.1 倍。

在昇腾 AI 芯片的支持下，华为与合作伙伴共同开启了大模型之路。华为通过前期与业界伙伴的共同探索，开创了一条大模型产业化落地的新模式，即围绕某个领域的大模型成立产学研用的产业联合体，打通科研创新到产业落地整个流程。这样一来，大模型的创新既可以更准确地契合行业场景需求，又能够促进产业合作伙伴直接基于大模型创新孵化行业应用。

华为云算力底座



Source: 华为, Geekpark, HTI


盘古大模型已在多个行业领域实现赋能。政务领域，华为云携手深圳市福田区政务服务数据管理局，上线了基于盘古政务大模型的福田政务智慧助手小福，改变传统的一网通办模式；铁路领域，华为货车检测助手可以精准识别67种货车、430多种故障，无故障图片筛除率高达95%；在煤矿领域，盘古矿山大模型已经在全国8个矿井规模使用，可以覆盖煤矿多个业务流程下的1000多个细分场景。

产品方面，盘古大模型也重构了华为云的一系列B端产品服务。盘古大模型的文案生成和代码生成技术能够提升资料撰写和前端代码编写效率，缩短新产品上市周期；云客服方面，全流程AI优先作答提升客服工作效率30%；在BI，通过NL2SQL和AutoGraph智能路由，实现SQL到可视化图表的自动推荐；云搜索通过多模态Embedding和NL2API技术，可实现视频、文本、图谱等广泛场景搜索，强大的语义理解和泛化能力让搜索准确率提高15%。

阿里巴巴：领先的云计算为其提供云算力保障

阿里为云计算行业的领头羊，为进军AIGC领域打下了坚实技术基础。根据IDC《中国公有云服务市场（2022上半年）跟踪》报告显示，2022上半年中国公有云服务市场整体规模（IaaS/PaaS/SaaS）达到165.8亿美元，其中IaaS市场同比增长27.3%，PaaS市场同比增速为45.4%，整体市场来看，阿里云份额是33.5%，具体到IaaS市场中阿里云份额为34.5%，均为市场第一。

1H22 国内公有云市场格局 (IaaS)



Source: IDC, HTI

算法模型层面，M6 模型参数已突破 10 万亿。据阿里研究院公布的信息显示，阿里巴巴达摩院在 2020 年初启动中文多模态预训练模型 M6 项目，同年 6 月推出 3 亿参数的基础模型；2021 年 1 月模型参数规模到达百亿，成为世界上最大的中文多模态模型；2021 年 5 月，具有万亿参数规模的模型正式投入使用，追上了谷歌的发展脚步；2020 年 10 月，M6 的参数规模扩展到 10 万亿，成为当时全球最大的 AI 预训练模型。阿里云曾表示，作为国内首个商业化落地的多模态大模型，M6 已在超 40 个场景中应用，日调用量上亿。

应用推广层面，已构建 8 大 AI 应用场景，M6 模型也已实现落地，类 ChatGPT 产品仍在内测中。1) 阿里基于其语言语义、图片识别、智能语音技术搭建了八大场景的 AI 方案，包括智能客服（智能营销、智能外呼、在线客服等）、信息审核、图片搜索、智慧媒体（用于运营及内容制作）、智能会议、智慧法庭、智慧课堂、智慧医疗等；2) 其中，M6 大模型的已落地的应用包括但不限于在犀牛智造为品牌设计的服饰、为天猫虚拟主播创作剧本，以及增进淘宝、支付宝等平台的搜索及内容认知精度等，M6 模型在设计、写作、问答等方面表现突出，我们预计其将在电商、制造业、文学艺术、科学研究等场景中率先发力；3) **阿里版“ChatGPT”处于内测阶段。**2 月 8 日，阿里巴巴宣布，阿里版聊天机器人 ChatGPT 正在研发中，目前处于内测阶段。其一份内部标名“预发布”的文件被认为是阿里版的 ChatGPT 新品的应用截图，显示阿里可能将 AI 大模型技术与钉钉生产力工具深度结合。

阿里 AI 产品



Source: 阿里 AI 平台, HTI

腾讯：跨模态 AI 模型领先玩家

腾讯主要通过 AI Lab 进行 AI 相关技术的研究，其成立于 2016 年，**基础研究方向为计算机视觉、语音技术、自然语言处理和机器学习**，应用包括**游戏、数字人（虚拟形象平台“异次元的我”、手语数智人“聆语”等）、内容（写稿机器人“梦幻写手”等）和社交 AI 等**，目前腾讯 AI Lab 的 AI 技术在微信、QQ、天天快报和 QQ 音乐等腾讯产品中已得到落地使用。2022 腾讯全球数字生态大会上，腾讯宣布内部多个与 AI 技术、产业相关的团队正在不断融合，聚合成“腾讯云智能”体系。体系内部包含四大层级，最底层是算力（芯片等）、中间是腾讯云智能 II 平台，从标注、训练、推理到应用都涵盖在内，然后是 AI 落地加速及全场景数智化，比如数智人、语音助手、智能客服，让用户真正“开箱即用”。

腾讯的 AI 大模型为“混元”，该模型包含但不限于：计算机视觉、自然语言处理、多模态内容理解、文案生成、文生视频等多个方向的超大规模 AI 智能模型。与业界其他大模型相比，混元首创了层级化跨模态技术，可将视频和文本等跨模态数据分别做拆解，通过相似度分析，综合考量并提取视频和文本之间层次化的语义关联。该模型已

落地于腾讯内部数据挖掘、搜索、广告推荐等。根据腾讯，2022年4月，“混元”AI大模型在 MSR-VTT, MSVD, LSMDC, DiDeMo 和 ActivityNet 五大跨模态视频检索数据集榜单中取得精度第一名的成绩。

京东、字节、网易、快手亦有布局

京东：

京东云在 AIGC 的布局主要聚焦文本、声音、对话生成、数字人生成和通用型 Chat AI 技术五个方面：

- **文本生成 (NLG)：**从2019年开始，京东接连发布基于自研领域模型 K-PLUG（参数量 10 亿），对于给定商品的 SKU，自动生成长度不等的商品文案，包括商品标题（10 个字）、商品卖点文案（100 字）、商品直播文案（500 字）三类，聚焦商品文案生成。目前商品文案写作能力已经覆盖 2000 多个京东的品类，京东的商品文案生成技术已累计生成文案 30 多亿字。
- **语音生成 (TTS)：**从 2018 年开始，京东自研语音生成技术，当前的线上版本是 6.1 版本。京东定制化的精品音色只需要 30 分钟的训练数据，小样本个性化音色克隆只需要 10 句话的训练样本。482 人对比盲测显示，多颗粒度韵律增强的语音合成技术达到业内领先，并支持中文、英文、泰语，广东话、成都话等各类方言音色。语音合成主要应用到智能客服、SaaS 外呼、金融、AI 直播等产品。
- **对话生成：**不同于闲聊式对话，任务导向性对话与体验强相关，需要解决真实世界深度复杂的任务。针对多样化复杂场景下对话决策推理能力弱的问题，言犀推出了可解释的多跳推理、数值推理和高噪音场景下口语化表达的话语权决策新方法，实现了多轮对话从信息匹配到复杂推理的技术突破。在 WikiHop 数据集上，以 74.3% 的准确率，首次超越人类表现水平 74.1% 的准确率。此外，京东云旗下言犀人工智能平台可以为 17.8 万商家提供智能咨询与导购服务，为商家节省 30%+ 人力成本，服务已覆盖零售行业超过 80% 品类，以及 50%+ 京东平台商家，包括美的、华为、阿迪达斯、联想等品牌。
- **数字人生成：**京东云从 2021 年开始研发数字人技术，目前已具备全栈自研的 2D 孪生、3D 写实和 3D 卡通三类数字人合成技术。目前，数字人技术产品已广泛应用于政务、金融、零售直播等领域。
- **通用型 Chat AI：**自 2020 年发布“言犀”人工智能应用平台以来，京东云打造创新对话与交互技术、产品，包括京东智能客服系统、京小智平台商家服务系统、智能金融服务大脑、智能政务热线，言犀智能外呼、言犀数字人等，服务范围包括 17.8 万第三方商家及超 5.8 亿终端用户。

2月10日，京东云旗下言犀人工智能应用平台宣布将整合过往产业实践和技术积累，推出产业版“ChatGPT”：“ChatJD”。京东同时公布了 ChatJD 的落地应用路线图“125”计划。据了解，“125”计划包含一个平台、两个领域、五个应用。1 个平台是指 ChatJD 智能人机对话平台，即自然语言处理中理解和生成任务的对话平台，公司预计参数量达千亿级；2 个领域分别为零售、金融；5 个应用包含内容生成、人机对话、用户意图理解、信息抽取、情感分类，涵盖零售和金融行业复用程度最高的应用场景。

ChatJD 路线图



信息来源: 京东云, HFI

字节跳动:

2023 年底, 字节跳动成立聚焦 AI 大模型应用的新部门 Flow, 开启对 AI 应用层的深度布局。Flow 部门隶属于字节跳动的产品研发与工程部, 目前下设四大业务线, 包括 AI 教育、国际化、社区和豆包。

Flow 旗下核心产品包括 AI 对话助手豆包 (海外版 Cici) 和对标 GPTs 的 AI bot 开发平台扣子 (海外版 Coze)。模型层面, 字节自研发云雀大模型, 其内部曾预期在 2024 年达到 GPT4.0 水平。2024 年 2-3 月, 豆包的 DAU 一度超过百度文心一言成为市场第一。Coze 现阶段 DAU 已达百万级别, 还未进行商业化, 未来或通过 API 调用的方式变现。

快手:

快手在大规模语言模型相关的研究覆盖 LLM 模型训练、文案自动创作与生成、对话系统开发等领域。快手的 AIGC 研究主要聚焦于用户体验的提升, 以及和业务场景的融合, AI 对话系统在快手中的主要应用包括虚拟人、电商智能客服、智能助理等人机交互或人人交互场景。

2023 年 8 月, 快手发布快意大模型 (KwaiYii), 其为由快手 AI 团队从零到一独立自主研发的一系列大语言模型, 当前包含了多种参数规模的模型, 并覆盖了预训练模型 (KwaiYii-Base)、对话模型 (KwaiYii-Chat)。一个月后, 快手自研文生图大模型“可图” (Kolors) 在公司内部全面开启内测。2024 年 4 月, 快手发布对标 Sora 的视频生成大模型“可灵”。

网易:

网易主要通过伏羲进行 AI 相关技术研究。其成立于 2017 年, 是国内专业从事游戏和泛娱乐产业人工智能研究和应用机构, 研究方向包括强化学习、图像动画、自然语言、虚拟人、用户画像、大数据平台、云计算平台、云游戏等领域。目前, 网易伏羲已服务超 200 家客户, 应用日均调用量超数亿次。

2023年7月，网易推出了国内首个教育领域垂直大模型“子曰”，并发布了基于“子曰”大模型研发的六大创新应用——LLM翻译、虚拟口语教练、AI作文指导、语法精讲、AIBox以及文档问答。


国内创业公司代表：月之暗面

月之暗面 (Moonshot AI) 创立于2023年3月，2023年10月推出全球首个支持输入20万汉字的智能助手产品 Kimi。创始团队核心成员参与了 Google Gemini、Google Bard、盘古 NLP、悟道等多个大模型的研发，多项核心技术被 Google PaLM、Meta LLaMa、Stable Diffusion 等主流产品采用。

2023年10月10日，月之暗面发布了首个支持输入20万汉字的智能助手产品 Kimi Chat。根据月之暗面官微的口径，20万汉字是当时（2023年10月10日）全球市场上能够产品化使用的大模型服务中所能支持的最长上下文输入长度，标志着月之暗面在长文本这一重要技术上取得了世界领先水平。2024年3月18日，月之暗面宣布 Kimi 智能助手在长上下文窗口技术上再次取得突破，无损上下文长度提升了一个数量级到200万字。月之暗面相信，大模型无损上下文长度的数量级提升，也会进一步帮助大家打开对AI应用场景的想象力，包括完整代码库的分析理解、可以自主帮人类完成多步骤复杂任务的 AI Agent、不会遗忘关键信息的终身助理、真正统一架构的多模态模型等等。

相比当前市面上以英文为基础训练的大模型服务，Kimi Chat 具备较强的多语言能力。例如，Kimi Chat 在中文上具备显著优势，实际使用效果能够支持约20万汉字的上下文，2.5倍于 Anthropic 公司的 Claude-100k（实测约8万字），8倍于 OpenAI 公司的 GPT-4-32k（实测约2.5万字）。

利用 Kimi 分析英伟达财报



Source: 月之暗面官微, HTI

4.1.5 国内外 AI 应用投资情况

基于企名片 Pro 的数据统计，24 年第一季度，国内 AI 应用方向融资项目共有 81 起。目前国内 AI 应用方向融资项目集中在智能机器人、工业智能、智能驾驶&交通、AIGC 以及医疗、能源解决方案等领域。投资金额过亿的项目具体如下：芯控智能的整体智能工程解决方案，智元的人形机器人项目，生数科技的产业级多模态大模型，爱诗科技的视觉多模态项目，神马工场大的 AIGC 数字人孵化营销平台，九识智能订单的全球领先的 L4 级自动驾驶项目，月之暗面的 AIGC 项目，美克生能源的分布式绿色能源聚合服务项目，百应科技的对话式 AI 技术应用项目，清云能源集团的智慧综合能源服务和资产运营项目，猎户星空的智能服务机器人项目，星动纪元的具身智能及通用机器人项目，卓世科技的行业模型产品和解决方案项目，国自机器人的移动机器人项目。其中，月之暗面的 AIGC 项目获得了 10 亿美元的融资，为额度之最。

1Q24 国内 AI 应用融资

序号	项目名称	业务	城市	投资轮次	投资时间	投资金额	投资方
1	交泰智能	工业智能服务商	合肥市	种子轮	2024.3.20	数百万人民币	合肥高投
2	中科慧灵	智能机器人研发商	北京市	天使轮	2024.3.20	未披露	联想创投, 鲲鹏投资, 海南姿治投资有限公司
3	汉特云智能	智能机器人开发商	福州市	A 轮	2024.3.19	未披露	国科京东方投资
4	昇启科技	智能化仿真工业软件研发商	北京市	Pre-A 轮	2024.3.19	未披露	华山资本 Westsummit Capital
5	千寻智能	智能机器人研发商	杭州市	天使轮	2024.3.18	未披露	顺为资本, 绿洲资本
6	芯控智能	整体智慧工厂解决方案提供商	杭州市	B 轮	2024.3.18	近亿人民币	曦域资本, 翌马资本
8	中州创赢	AIGC 技术开发商	合肥市	A 轮	2024.3.16	数千万人民币	未披露
9	设序科技	AI 生成式设计 with 方案工业产品提供商	上海市	A+ 轮	2024.3.15	未披露	涌铎投资, 联想创投
10	杭州妙联	智能家居整体解决方案提供商	杭州市	B 轮	2024.3.14	未披露	浦江国投
11	智元机器人	人形机器人研发商	上海市	A++++ 轮	2024.3.13	超 10 亿人民币	M31 资本, HongShan 红杉中国, 上汽投资
12	忆生科技	人工智能初创公司	深圳市	天使轮	2024.3.13	未披露	真格基金
13	生数科技	产业级多模态大模型研发商	北京市	A 轮	2024.3.12	数亿人民币	启明创投, 达泰资本, 智谱 AI, BV 百度风投, 卓源亚洲, 北京鸿福厚德企业管理合伙企业 (有限合伙)
14	格物汽车	自动驾驶研发商	苏州市	A 轮	2024.3.12	未披露	深港通资本, 常熟国发创投
15	爱诗科技	视觉多模态算法开发商	北京市	A 轮	2024.3.11	亿级人民币	达晨财智
16	星凡星启	一站式行业 AIGC 技术服务提供商	成都市	A 轮	2024.3.11	未披露	开普云, 盛景网联
17	清昂智能	AI 模型部署优化平台	北京市	战略融资	2024.3.7	未披露	哈勃投资
18	行者 AI	游戏 AI 开发商	成都市	A 轮	2024.3.6	未披露	掌趣科技
19	麦伽智能	法律大语言模型研发商	北京市	A+ 轮	2024.3.6	未披露	无限基金 SEE Fund, 智谱 AI, 连星资本

20	神马工场	AIGC 数字人孵化营销平台	上海市	拟收购	2024.3.6	1530 万美元	第九城市
21	文德数慧	AI 算法数据生产服务和数据内容审核服务公司	苏州市	战略融资	2024.3.6	未披露	苏高新投资
22	新旦智能	AI 初创公司	深圳市	天使轮	2024.3.4	千万级人民币	APUS
23	MiniMax	多模态 AI 大模型领域研发商	上海市	B 轮	2024.3.4	未披露	阿里巴巴
24	伽南科技	智能机器人生产商	北京市	天使+	2024.3.1	未披露	Plug and Play China
25	无问智行	智能驾驶服务商	北京市	Pre-A 轮	2024.3.1	未披露	力合科创, 力合资本, 地平线机器人
26	神州云海	商业服务机器人研发商	深圳市	B 轮	2024.3.1	未披露	云天励飞
27	九号机器人	智能机器人研发制造商	东莞市	天使轮	2024.2.28	未披露	中硕资本, 普密斯
28	道善智能	全自动测绘机器人研发商	佛山市	股权转让	2024.2.28	336.51 万人民币	殷图网联
29	九识智能	全球领先的 L4 级自动驾驶产品研发企业	苏州市	A 轮	2024.2.27	近 1 亿美元	美团战略投资部, BV 百度风投, 独秀资本, 闲庭基金, 索道投资, 蓝湖资本, 建发新兴投资
30	迪普明德	智能机器人研发制造商	南京市	天使轮	2024.2.27	未披露	壹诺创投, 智远慧
31	星海图	具身智能公司	苏州市	天使轮	2024.2.27	千万级美元	IDG 资本, 无限基金 SEE Fund, BV 百度风投, 金沙江创投, 七熹投资
32	复睿智行	智慧交通系统解决方案提供商	上海市	Pre-A 轮	2024.2.26	数亿人民币	浙商创投, 北京新航城, 中山金控, 鑫翼东湖创投, 平湖市跨山问海实业投资有限公司, 浙江坤鑫, 桥新资本
33	摄星智能	智慧防务研发商	绍兴市	B 轮	2024.2.22	未披露	诚合资管
34	月之暗面	AIGC 公司	北京市	A 轮	2024.2.19	超 10 亿美元	HongShan 红杉中国, 小红书, 美团战略投资部, 阿里巴巴, 招商局中国基金, 老股东
35	美克生能源	分布式绿色能源聚合服务商	上海市	D 轮	2024.2.18	数亿人民币	国家绿色发展基金, 君联资本
36	和意精工	曲面机器人研发商	深圳市	天使轮	2024.2.18	未披露	淮泽中钊天使基金, 卓源亚洲
37	唯物科技	元宇宙综合技术服务商	杭州市	Pre-A 轮	2024.2.7	未披露	湖畔山南资本, 杭州景宸投资, 执一资本, 阿米巴资本
38	百应科技	对话式 AI 技术应用商	杭州市	C 轮	2024.2.6	近 2 亿人民币	百度, 湖北高投集团
39	希迪智驾	智能驾驶汽车技术和产品服务商	长沙市	D 轮	2024.2.4	未披露	策源资本
40	云鼎智控	人工智能军事技术开发商	成都市	A 轮	2024.2.2	未披露	海南银橙信息科技有限公司
41	画音科技	数字人音视频技术研发商	北京市	天使轮	2024.2.1	未披露	启迪之星创投
42	上海创乐信息	智能建造服务提供商	上海市	Pre-A 轮	2024.2.1	未披露	壹诺创投, 保利资本
43	瓯菜五金	门禁系统专业制造商	丽水市	拟收购	2024.2.1	180 万人民币	中国瓯宝
44	生境科技	AI 科技公司	深圳市	天使轮	2024.1.31	数千万人民币	德韬资本

45	清云能源集团	智慧综合能源服务商和资产运营商	北京市	B 轮	2024.1.29	近 2 亿人民币	众行资本
46	辅易航	智能驾驶解决方案提供商	苏州市	B 轮	2024.1.29	近亿人民币	元禾重元,苏高新金控
47	医日健	医药智能零售方案提供商	上海市	并购	2024.1.29	未披露	大有数字
48	广东浩鲸科技	智能仓储解决方案提供商	深圳市	Pre-A 轮	2024.1.26	近千万人民币	星曜投资
49	神元力量	智能机器人研发商	北京市	天使轮	2024.1.24	未披露	奇绩创坛
50	Artisse AI	AI 摄影应用	香港	种子轮	2024.1.24	670 万美元	The London Fund
51	小波智联	数智化解决方案提供商	天津市	天使轮	2024.1.23	未披露	天津科创
52	汉阳科技 Yarbo	庭院通用机器人品类开拓者、扫雪机器人品类开拓者	深圳市	A++轮	2024.1.22	近千万美元	产业资源战略投资人,索道投资,义融善道,中新集团
53	Collov AI	AI 智能设计师助手及矩阵内容生成器	北京市	天使轮	2024.1.22	未披露	阿米巴资本
54	云伴 AIGC	人工智能研发企业	合肥市	战略融资	2024.1.21	未披露	科大讯飞
55	圣瞳科技	智能巡检解决方案商	西安市	A+轮	2024.1.18	未披露	西安财金
56	大云端	智能工业服务商	重庆市	A 轮	2024.1.17	未披露	两江创投
57	RWKV	首个非 Transformer 架构大语言模型	深圳市	种子轮	2024.1.17	未披露	奇绩创坛,某匿名投资者
58	七火山	文生视频创业公司	广州市	战略融资	2024.1.16	未披露	超讯通信
59	金达新水	智能机器人研销商	宁波市	并购	2024.1.16	未披露	豫资控股
60	心影随形	AI 情感陪伴应用开发商	北京市	天使+	2024.1.16	未披露	鼎晖投资,范式基金
61	朗迅工业	智能机器人研发商	苏州市	拟收购	2024.1.15	未披露	哈森股份
62	猎户星空	智能服务机器人研发商	北京市	战略融资	2024.1.13	3.69 亿人民币	猎豹移动,中科招商
63	慧智荷创	智慧建筑服务商	苏州市	出资设立	2024.1.12	未披露	中新产投,城投资本
64	奔流能源	智慧能源服务商	合肥市	天使轮	2024.1.12	未披露	新能源产业基金,业务合作方
65	Babel AI	AI 开发运维全流程服务平台	南通市	天使轮	2024.1.11	550 万美元	云九资本,峰瑞资本
66	硅基流动	人工智能优化和部署解决方案提供商	北京市	天使轮	2024.1.10	5000 万人民币	创新工场,耀途资本 Glory Ventures,奇绩创坛
67	星动纪元	具身智能及通用人形机器人研发商	北京市	天使轮	2024.1.10	超亿人民币	联想创投,金鼎资本,清控天诚,世纪金源集团,长风恒创投
68	Nolibox	AIGC 设计创意平台	北京市	A 轮	2024.1.10	数千万人民币	尖晶资本,GRIP Capital,业内数家头部机构
69	觅机科技	AI+教育解决方案提供商	北京市	A 轮	2024.1.10	未披露	后浪资本
70	辛玮智能	人工智能数字化产品和解决方案提供商	上海市	战略融资	2024.1.9	未披露	浪潮集团
71	目的涌现	AGI 原生技术开发商	无锡市	天使+	2024.1.8	未披露	乐朴资本,苏州市千融创业投资管理有限公司,上海润馥企业管理有限公司,初心资本

72	卓世科技	行业模型产品和解决方案提供商	三亚市	B 轮	2024.1.5	超亿人民币	中关村协同创新基金,中马启元资产,齐光资本,经协资产,海南融智人才基金,创世因特
73	浙达能源	全国领先的能源互联网服务运营商	杭州市	A++轮	2024.1.5	未披露	金光紫金
74	超数智能	人工智能软件开发商	北京市	天使轮	2024.1.4	未披露	百川智能
75	高特电子	电池检测及电池管理系统研发商	杭州市	Pre-IPO	2024.1.4	超亿人民币	鲲鹏一创,澜起科技,金浦投资,兴盛天成
76	博奥晶方	中药组方精准筛选大模型开发商	北京市	天使轮	2024.1.4	4000万人民币	嘉道私人资本
77	BetterYeah	AI 应用开发平台及协同开发平台提供商	杭州市	A 轮	2024.1.3	近千万美元	靖亚资本
78	纪元数科	人工智能初创公司	北京市	A 轮	2024.1.3	1000万人民币	华业天成资本
79	鹿影科技	一站式 AI 视频工具与内容平台	深圳市	Pre-A 轮	2024.1.2	未披露	蓝驰创投,红点中国
80	国自机器人	移动机器人开发制造商	杭州市	战略融资	2024.1.2	超 2 亿人民币	正泰新能源,数名老股东
81	中能光和	数字化能源补给服务商	北京市	A 轮	2024.1.2	未披露	清悦资本

Source: 企名片 Pro, HTI

基于企名片 Pro 的数据，24 年第一季度国外 AI 应用方向融资项目共有 59 起。

项目集中于机器智能，工业，医疗、商业、安全解决方案方面。募资过千万美元项目具体如下：Carlsmed 人工智能手术医疗平台，Hippocratic AI 生成式 AI 项目，Lily AI 时尚电商优化产品推荐服务项目，together.ai 生成式 AI 项目，Cognition AI 全球首位 AI 软件工程师研发项目，Zephyr AI 智慧医疗解决方案项目，Tavus 人工智能生成视频技术开发项目，Overjet 牙科 AI 软件开发项目，Rapid SOS 数据驱动急救服务项目，Healthee 人工智能医疗保健平台，Glean 人工智能工作助理开发项目，Collov 室内设计 AI 工具开发项目，intenseye 人工智能工作场所安全平台，Genmo 人工智能创意内容生成平台，Figure AI 的 AI 人形机器人研发项目，Abridge 医疗对话 AI 研发项目，Vizio 智能电视生产项目，Flowerlands 大语言模型技术开发项目，Quilter 生成式电路板设计软件开发项目，Kore.ai 企业对话人工智能平台，Codeium 生成式人工智能编码工具包项目，Sema4.ai 人工智能技术应用服务提供项目，Sierra AI 的 AI 初创项目，Proof Technology 智能法务平台，RecraftAI 图形设计生成器项目，Artsight 人工智能虚拟护理平台，Luma AI 3D 内容生成项目，Agrawal's AI initiative 的 AI 初创项目，Perplexity AI 智能对话式搜索引擎项目。其中，最大的是 Vizio 智能电视生产商并购项目共融资 23 亿美元。

1Q24 国外 AI 应用融资

序号	项目名称	业务	城市	投资轮次	投资时间	投资金额
1	Quilt AI	AI 助手开发商	旧金山	种子轮	2024.3.21	250 万美元
2	G2 Reverse Logistics	人工智能退货管理服务商	匹兹堡	种子轮	2024.3.19	960 万美元
3	Carlsmed	人工智能手术医疗平台	圣迭戈	C 轮	2024.3.18	5250 万美元
4	Hippocratic AI	生成式 AI 公司	圣克拉拉	A 轮	2024.3.18	5300 万美元
5	Lily AI	时尚电商优化产品推荐服务商	山景	B+轮	2024.3.15	2000 万美元
6	together.ai	生成式 AI 初创公司	门洛帕克	A+轮	2024.3.14	1.06 亿美元
7	Cognition AI	全球首位 AI 软件工程师研发商	纽约市	A 轮	2024.3.13	2100 万美元
8	Zephyr AI	智慧医疗解决方案提供商	洛顿	A 轮	2024.3.13	1.11 亿美元
9	Revelation AI	人工智能和预测分析服务提供商	波士顿	并购	2024.3.13	未披露
10	Tavus	人工智能生成视频技术开发商	旧金山	A+轮	2024.3.13	1800 万美元
11	Guardrails AI	人工智能保障公司	纽约市	种子轮	2024.3.11	750 万美元
12	Hook	人工智能音乐表达平台	纽约	天使轮	2024.3.7	未披露
13	Overjet	牙科 AI 软件开发公司	剑桥	C 轮	2024.3.6	5320 万美元
14	RapidSOS	数据驱动急救服务提供商	纽约	E 轮	2024.3.5	7500 万美元
15	Healthee	人工智能医疗保健平台	纽约市	A 轮	2024.3.4	3200 万美元
16	Reverie Labs	AI 药物发现公司	波士顿	并购	2024.2.29	未披露
17	Glean	人工智能工作助理开发商	帕洛阿尔托	D 轮	2024.2.28	超 2 亿美元
18	Collov	室内设计 AI 工具开发商	加利福尼亚州	A+轮	2024.2.28	1000 万美元
19	intenseye	人工智能工作场所安全平台	纽约市	B 轮	2024.2.28	6400 万美元
20	Genmo	人工智能创意内容生成平台	旧金山	A 轮	2024.2.27	3000 万美元
21	HuLoop Automation	人工智能智能自动化公司	纽约市	天使轮	2024.2.27	500 万美元
22	HiredScore	人工智能招聘服务平台	纽约市	并购	2024.2.27	未披露
23	Myko AI	对话式人工智能开发商	迈阿密	种子轮	2024.2.26	270 万美元
24	InsightRX	数字医疗服务商	旧金山	B 轮	2024.2.25	未披露
25	Figure AI	AI 人形机器人研发商	桑尼维尔	B 轮	2024.2.24	6.75 亿美元
26	Abridge	医疗对话 AI 研发商	匹兹堡	C 轮	2024.2.23	1.5 亿美元
27	Firsthand	人工智能代理开发商	纽约市	种子轮	2024.2.22	未披露
28	Novity	预测性维护人工智能服务商	旧金山	种子轮	2024.2.21	780 万美元
29	UnityAI	智能医疗解决方案提供商	纳什维尔	种子轮	2024.2.20	400 万美元
30	Shelfful	人工智能初创企业	波特兰	种子轮	2024.2.19	300 万美元
31	Vizio	智能电视生产商	欧文市	并购	2024.2.18	23 亿美元
32	OpenAI	人工智能公司	圣克拉拉	C 轮	2024.2.18	未披露
33	Anthropic	人工智能系统研发商	旧金山	战略融资	2024.2.17	未披露
34	Flowerlands	大语言模型技术开发商	纽约市	A 轮	2024.2.16	2000 万美元
35	Rogo	金融行业生成式人工智能解决方案提供商	纽约市	天使轮	2024.2.16	700 万美元
36	AtlasPro AI	AI 解决方案提供商	旧金山	天使轮	2024.2.15	未披露
37	testRigor	无代码测试自动化工具	旧金山	Pre-A 轮	2024.2.15	未披露

38	Quilter	生成式电路板设计软件开发商	洛杉矶	A 轮	2024.2.13	1000 万美元
39	Kore.ai	企业对话人工智能平台提供商	奥兰多	D 轮	2024.1.31	1.5 亿美元
40	Codeium	生成式人工智能编码工具包提供商	旧金山	B 轮	2024.1.30	6500 万美元
41	Sema4.ai	人工智能技术应用服务提供商	纽约市	种子轮	2024.1.30	3050 万美元
42	OnPoint Healthcare Partners	人工智能医疗服务商	奥斯汀	种子轮	2024.1.29	未披露
43	Sierra AI	AI 初创公司	旧金山	A 轮	2024.1.27	8500 万美元
44	imgnAI	加密原生 AI 平台	旧金山	种子轮	2024.1.27	160 万美元
45	Proof Technology	智能法务平台	丹佛	B 轮	2024.1.26	3040 万美元
46	ViralMoment	人工智能社交视频洞察和分析平台	旧金山	种子轮	2024.1.26	250 万美元
47	DXwand	AI 客服科技公司	夏延	A 轮	2024.1.25	400 万美元
48	Prompt Security	企业生成式 AI 安全平台	纽约市	种子轮	2024.1.24	500 万美元
49	Recraft	AI 图形设计生成器	旧金山	A 轮	2024.1.18	1200 万美元
50	Mercor	人工智能招聘平台	旧金山	种子轮	2024.1.15	360 万美元
51	BabelCloud	AI 应用开发平台	纽约市	天使轮	2024.1.13	550 万美元
52	Artsight	人工智能虚拟护理平台提供商	芝加哥	B 轮	2024.1.12	4200 万美元
53	Luma AI	3D 内容生成技术开发商	帕洛阿托	B 轮	2024.1.12	4300 万美元
54	BlueMatrix	投资应用软件研发商	纽约	战略融资	2024.1.11	未披露
55	Peerlogic	人工智能牙科诊所平台	凤凰城	种子轮	2024.1.11	565 万美元
56	Echo Laboratories	AI 转录平台	旧金山	种子轮	2024.1.10	770 万美元
57	Agrawal's AI initiative	AI 初创公司	旧金山	种子轮	2024.1.10	3000 万美元
58	Perplexity AI	智能对话式搜索引擎提供商	旧金山	B 轮	2024.1.5	7360 万美元
59	Articul8 AI	生成式人工智能软件平台	旧金山	出资设立	2024.1.3	未披露

Source: 企名片 Pro, HTI

4.2 传媒

多模态进化更迭，关注 AI 应用落地。我们认为，2023 年是大模型向多模态化进化的一年，与此同时 AI 提供了更多商业化变现的途径。2024 年生成式 AI 技术有望在 IP 开发、互动陪伴、游戏、营销、电商、教育等方向获得广泛应用。随着 AI 产品的逐步落地，2024 年将主要是去伪存真的逻辑验证阶段，检验 AI 技术的应用是否能够很高效的产出，多模态进化之后是否在更复杂的视频、游戏等领域有生产力的提升和用户需求的解决，一旦实现 AI 赋能，渗透率从 0-1 将会带来收入和利润的巨大增量和弹性。

国内 AI 应用方向及进展

AI应用方向	国内相关企业	AI应用进展
IP开发、影视	上海电影	宣布开展“iNEW”战略，以“iPAI星球计划”为抓手，结合AI应用，主攻IP内容焕新和IP商业开发两大方向
互动、阅读	掌阅科技	研发了AI智慧阅读产品“阅灵犀”，融合了阅读的乐趣和对情感的需求，可以对任意书中指定的角色形象
游戏	巨人网络	利用AIGC实现了游戏玩法的创新，基于大模型能力，创造性地打造出了一个AI推理引擎
营销	蓝色光标	2023年9月发布首款BLUE AI模型，并宣布在2024年将在已有实际应用的基礎上，向AI Agent（智能体）进化
	清美天下	数字营销制作平台KreadoAir AIGC赋能创意营销并带动广告主降本增效
电商	值得买	2024年2月获得首批全球AI购物助手“小值”正式在“什么值得买”App上线，为存在不同决策成本时消费者提供个性化的建议，从而提升消费决策的质量和效率
教育	世纪大道	研发用于老师教学的AI智能助手“小海助教”，涵盖教师在教学知识、教学方法、学生管理和日常工作事务等方面的工作实际需求

Source: 公司公告, HTI

IP 开发、影视：AI 增能提效，打破产能瓶颈，加快 IP 多元开发。我们认为，在 Sora 发布后，多模态模型带来的内容生成能力继续往最核心的视频、3D 内容等方向延伸，这也是图文之后价值量更大、影响范围更大的应用领域；且 Sora 的生成视频能力已经被评价为“世界模拟器”，生成时长、显示效果、物理逻辑都有很不错的表现，未来对 IP 开发领域预期会有很大的帮助。

IP 是内容源头，AIGC 技术能显著降低视频内容生成的中间成本。我们认为，AI 加持下视频素材的版权价值量将会明显提升，在 AI 模型的演进之下，优质内容和应用大爆发的时代即将到来，而专业的 IP 开发方（PGC）具备明显的先发优势。

面对 Sora 掀起的文生视频新浪潮，上海电影宣布开展“iNEW”战略，以“iPAI 星球计划”为抓手，结合 AI 应用，主攻 IP 内容焕新和 IP 商业开发两大方向。在 IP 商业开发方面，2023 年，上影 IP 授权商品 GMV 总量已超 10 亿元，未来三年，上影力争实现 IP 合作产品涉足 5 大领域、30 个行业、500 个以上品牌，落地全国 30 个省份，合作商品 GMV 超百亿元目标。

上海电影“iPAI 星球计划”

上影集团 IP 数字资产化布局



旗下公司	主要任务
上美影	探索“AI+动画”制作方向
上译厂	探索“AI+有声”创作方向
上海电影技术厂	探索“AI+影像基地”一站式解决方案
上海影视乐园	探索VR、AR+沉浸式体验方式
上美设计公司	探索AI数字藏品IP行业先例

Source: 上影集团公众号, HTI

Source: 上影集团公众号, HTI

互动、陪伴：AI 定制个性化服务。我们认为，在 AI 技术加持下，相关厂商可以针对服务内容进行优化训练，通过机器学习的方式，为用户打造更逼真、更人性化的交互体验，提高产品用户粘性。

在 AI+互动领域，掌阅科技研发了 AI 智慧阅读产品“阅爱聊”，融合了阅读的乐趣和对情感的需求，可以对话系统中既定的角色形象，帮助用户阅读各种类型的文本内容，用聊天对话的形式把名著或小说轻松读一遍，让阅读成为一种更加愉悦、有趣的体验，同时也有许多角色基于虚构人物或中外历史名人，甚至还有完全虚拟的角色。

阅爱聊内测版

阅爱聊产品特点



产品特点	表现
多风格支持	支持多种风格，例如幽默、正式、友好、教育等，会根据不同的风格，调整生成内容的语气、态度和情感，让内容更加符合预期和效果。
双模式对话	支持角色和读者双向模式，既可以以角色找到一个角色对话，也可以以角色去找一本书阅读，让内容更加完整和有深度。
交互式体验	不仅可以为用户生成内容，还可以和用户进行互动，用户也可以随时修改、删除或者保留生成的内容。
沉浸式阅读	阅读前可与本书作者对话全面了解全书概貌与精髓，甚至提前预警，阅读中可通过对话了解后续情节，阅读后可与本书作者交流心得与感想，未来甚至可以聊天、推荐。

Source:掌阅科技官方公众号, 阅爱聊微信小程序, HTI Source:掌阅科技官方公众号, 阅爱聊微信小程序, HTI

游戏：AI“生产力价值”有望全面赋能游戏产能。我们认为，AI 技术可以解决游戏行业众多痛点。AI 技术可以全面提高游戏开发团队的生产力，一方面可以克服传统游戏开发过程中成本产能限制点，起到降本增效的作用；另一方面可作为 UGC（用户生成内容）工具，降低玩家生产创作的门槛。

在一款轻度休闲手游《太空杀》中，巨人网络的开发团队借助了 AIGC 实现了游戏玩法的创新。团队基于大模型能力，创造性地打造出了一个 AI 推理剧场，作为《太空杀》的内路玩法。玩家需在给定的一个案件背景的情况下，和 AI 进行人机对话。AI 的介入让玩家的想象力变得更加丰富。

游戏开发流程

巨人网络旗下游戏《太空杀》



Source: 吉比特 2022 年年报, HTI

Source: 巨人网络官方公众号, HTI

营销：垂类模型持续赋能产业链。我们认为，随着大模型基座的快速迭代和发展，通过营销领域大量数据训练建立的行业垂类大模型，能够为中小商家提供高效解决方案和个性化服务，持续赋能产业链。

2023 年 9 月，蓝色光标发布垂类模型 BLUE AI，2024 年 Blue AI 将在已有实践应用的基础上，持续向 AI Agent（智能体）进化。2023 年，公司 AI 驱动业务提效在 30%到 1000%之间，突出业务场景提效十倍以上；公司在 2023 年里通过生成式 AI 赋能创造的案例达 300 多个，其中深度驱动并带来规模化收入的案例约在 1/3 以上，AI 驱动的收入在 1 个亿以上。

2023 年 7 月，易点天下首个 AIGC 数字营销创作平台 KreadoAI 面向全球创作者正式发布。自发布以来，KreadoAI 以易点天下长期积累的丰富全面的营销大数据及 AI 算法模型为驱动，以 AIGC 赋能创意营销并帮助广告主降本提效。KreadoAI 可为全球用户提供「AI+」的多场景解决方案，已应用在商旅推荐、电商购物、应用下载、教育培训、企业服务等领域。

蓝色光标 2023 年度 AI 营销案例

易点天下 AI 数字营销创作平台 KreadoAI

品牌客户	AI营销作品
Win	借助AI生成创意短视频营销广告
京东	用AI技术自动生成11位数字进行全图视觉分析
佳能	借助AIGC技术打造一条“北京世界运动宣传片”
海信	打造食品行业首家AI视觉
广汽本田	借助AI生成打造了焕新生命的AI价提提
宁德时代	全球首创创作者自行选择制作AIGC广告

The screenshot shows the KreadoAI platform interface with a dark blue theme. It features a navigation bar with 'Home', 'Products', 'Services', 'About Us', 'Contact Us', and 'FAQ'. Below the navigation bar, there are several sections for different marketing services, including 'AI Content Generation', 'AI Video Production', and 'AI Image Generation'. The interface is clean and modern, with clear call-to-action buttons.

Source: 蓝色光标官方微信公众号, HTI

Source: 易点天下官方微信公众号, HTI

电商：AI有望重塑未来购物模式。我们认为，AI在电商领域具备广阔的应用前景，有望重塑未来购物模式。卖家侧，能够打通直播带货全流程，实现降本增效；买家侧，能够基于大模型记忆推理能力，高效便捷地满足复杂个性化购物需求，辅助买家完成决策。

在卖家侧，2023 年 7 月京东正式推出言犀大模型。京东云言犀 AI 开发计算平台，可为客户的大模型开发和行业应用，提供一站式的解决方案，平台精选了京东技术团队多年来开发出的 100 多种训练和推理优化工具，可提供更加高效的大模型开发环境，让用户可以快速地通用模型，转化成适合自身场景的专业模型。

在买家侧，2024年2月值得买科技自研AI购物助手“小值”正式在“什么值得买”App上线。“小值”是值得买科技基于值得买消费大模型所研发的Agent产品，能通过对话深度理解用户需求，基于全网实时消费经验、价格信息进行快速总结，提供口碑总结、商品对比、商品推荐、全网比价等服务，为存在不同决策难点的消费者提供个性化的建议，从而提升消费决策的质量和效率。

京东云言犀AI数字人带货

小值 AI 购物助手



Source:京东云微信公众号, HTI

Source:什么值得买微信公众号, HTI


教育：AI 覆盖多层次教学环节，推进个性化教育。我们认为，在 AIGC 时代，大语言模型和教育适配程度高，其优秀的对话能力、语言理解能力和表达能力等促进AI技术在教育领域落地。此外，AI+教育市场发展空间大，客户端付费意愿强烈，商业发展逻辑清晰。

2023年，多家企业布局AI+教育并取得进展。南方传媒通过发明专利授权“基于AI深度学习的自动化数字教材建模系统”；城市传媒通过AI技术实现了精准、多维度的评价分析，并应用到了不同的学科教育中，例如AI作文批阅；中南传媒子公司中南迅智着力开展教育质量监测考试服务，以试卷、教辅等纸媒为流量入口，重点打造考试阅卷系统、考试测评系统等产品。

在教师端，世纪天鸿研发专注于服务老师的AI智能助手“小鸿助教”，涵盖教师在教学知识、教学方法、学生管理和工作事务等多方面的个性化需求，通过对话的方式，在包括教案生成、作文批改、教学活动策划、思维导图设计、教师评语编写等多种应用场景帮助老师提升工作效率。

南方传媒数字教材应用平台“粤教翔云”

世纪天鸿的AI教师助手“小鸿助教”



Source:南方传媒官方微信公众号, HTI

Source:小鸿助教官方微信公众号, HTI


4.3 计算机: AI 引领计算机软件巨变, 软件行业迎来 AI 时代

4.3.1 开发端: AI 赋能计算机软件, 推动软件行业研发质变

人工智能 (AI) 的崛起对计算机软件行业产生了深远的影响。在软件开发领域, AI, 尤其是大型语言模型 (LLM), 通过自动生成代码、提升代码质量和优化用户体验, 大大优化了软件开发的模式和流程。

首先, AI 技术显著降低软件开发成本。根据 TDWI 的研究, 采用 AI 驱动的自动化工具能够显著减少开发时间和成本, 提高投资回报率 (ROI)。在 AI 的帮助下, 开发者可以在编写代码所需的时间的一小部分内创建复杂的软件系统。这是通过使用如 AutoML 和 AutoCode 等工具实现的, 这些工具使用机器学习算法来分析数据并生成代码。自动化代码生成的优势在于它可以显著减少开发时间和成本, 通过消除开发者手动编写代码的需求, 他们可以专注于更高级别的任务, 如设计软件架构和创建用户界面。


微软 Azure AutoML 工作流程图



Source: Azure, HTI


其次, AI 显著提高生成代码的质量。通过使用 AI 算法, 开发者可以在代码编写之前识别出潜在的 bug 和错误。自动化测试和代码分析工具显著提高了软件质量, 能够在开发过程的早期阶段发现并解决问题。自动化测试使用 AI 算法自动生成测试用例, 并运行这些用例以识别软件中的问题。工具如 Testsigma 和 Applifools 通过减少人工工作量并提高测试效率, 实现了更高的测试覆盖率和质量。代码分析工具如 DeepCode 和 Codacy 通过分析代码来识别潜在的问题, 包括安全漏洞和性能问题。这些工具在代码编写或合并请求期间就能检测到问题, 提供详细的反馈和改进建议, 从而帮助开发者在早期解决这些问题, 防止它们影响生产环境。

Testsigma 平台



Source: Testsigma 官网, HTI

DeepCode 平台



Source: DeepCode 官网, HTI


再次, AI 通过自然语言处理 (NLP) 技术进一步影响软件开发。NLP 利用机器学习算法理解和解释人类语言, 构建能理解和响应自然语言输入的软件系统。例如, NLP 技术在聊天机器人中的应用, 使它们能够分析句子、识别关键词并理解用户查询的上下文。这不仅使聊天机器人能够处理更复杂的对话, 还能提供更精确和相关的响应, 从而大大改善用户体验。这些系统通过模拟人类对话, 使与技术的交互更自然、更人性化, 增强了用户的满意度和系统的可访问性。同时, 虚拟助手也大量依赖 NLP 技术来处理语音命令和文本输入。通过理解用户的意图和语境, 虚拟助手可以执行从播放音乐到安排日程等各种任务, 提高了用户的便利性和互动性。

此外，AI 通过预测分析提升软件开发的质量和效率。预测分析涉及使用机器学习算法分析数据并对未来事件进行预测。在软件开发中，预测分析可以用来预测用户行为和软件性能。例如，开发者可以使用预测分析来识别潜在的性能瓶颈，并优化软件以提高性能。使用预测分析可以帮助开发者构建更高效和有效的软件系统，比如通过分析数据并对未来事件进行预测，从而让开发者做出更有依据的软件设计和开发决策。麦肯锡研究显示，预测分析驱动的规划对软件项目产生了显著的正面影响。首先，每人小时的标准功能输出提高了 20%到 40%，这意味着开发人员的效率显著提升，每工作小时交付的功能数量增加了。此外，预测分析将项目进度与计划的偏差减少了 60%到 90%，表明项目完成时间更接近预定计划，时间线的准确性得到了大幅提升。最后，应用预测分析后，每行代码的缺陷减少了 30%到 40%，显示出软件质量的显著提升，代码中的错误和漏洞明显减少。

预测分析对软件项目的影响

Predictive-analytics-driven planning has delivered a range of positive impact on software projects.


Typical impact of predictive-analytics planning



Source: 麦肯锡, HTI


同时，AI 在 bug 修复方面对软件开发有显著影响，特别是在实现自动化 bug 检测和修复方面。通过使用 AI 算法，开发者可以利用自动化工具自动识别并修复软件系统中的 bug。自动化 bug 检测利用机器学习算法扫描和分析代码，从而识别潜在的 bug。比如，AI 工具如 DeepCode 使用深度学习进行静态代码分析，能够在多种编程语言中检测 bug 和安全漏洞。此外，工具如 Railtown.ai 通过机器学习算法进行实时错误监测和诊断，从而加速 bug 检测和修复的过程。自动化 bug 修复则涉及使用 AI 算法自动修复代码中的错误。BugLab 是一个用于自我监督学习的 bug 检测和修复框架，它通过分析和修正变量误用、参数交换、操作符错误等常见错误来实现自动修复。这些工具不仅能够快速修复 bug，还能提供代码优化建议，提高代码的整体质量和可靠性。使用这些 AI 驱动的工具可以显著提高软件开发的效率和质量，减少软件失败的风险，提高软件的整体可靠性。这些工具通过自动化检测和修复，减少了人工测试的时间和成本，提升了开发流程的效率和精确度。

Railtown.ai 平台



Source: Railtown.ai 官网, HTI

BugLab 平台



Source: BugLab 官网, HTI

这些变化对传统软件公司是巨大的冲击，传统的软件开发模式将不再适应新的环境，公司必须适应 AI 驱动的开发流程，才能在激烈的市场竞争中生存和发展。根据 IBM 全球 AI 采用指数 2023 的调查，AI 在大企业中的采用率保持稳定。42% 的大企业 IT 专业人士报告他们已经积极部署了 AI，另有 40% 正在探索使用该技术。此外，38% 的企业 IT 专业人士表示其公司正在积极实施生成式 AI，42% 正在探索其应用。多数积极部署或探索 AI 的受访公司在过去 24 个月内加快了其投资或部署进度。59% 的在部署或探索 AI 的公司 IT 专业人士表示，他们在过去 24 个月内加快了对 AI 的投资或部署进度。同时，AI 带来的低成本和高效率，使得新兴公司可以快速进入市场，对传统公司形成强有力的竞争。

4.3.2 应用端：生成式 AI 颠覆搜索引擎，商业模式受到冲击

生成式 AI (Generative AI) 是一种利用机器学习算法创建新数据的技术，通常基于已有的数据进行训练。例如，OpenAI 的 ChatGPT 和 DALL-E 是生成式 AI 的典型代表。ChatGPT 能够生成类似人类的文本对话，而 DALL-E 则可以根据文本描述生成图像。这些系统通过学习大量数据来生成新的、与输入相匹配的内容。搜索引擎是用于在互联网上查找信息的工具，最著名的例子包括谷歌 (Google)、百度 (Baidu) 和必应 (Bing)。搜索引擎通过爬虫程序扫描和索引互联网内容，用户输入查询后，搜索引擎会根据复杂的算法展示相关结果。

ChatGPT 平台




Source: ChatGPT 官网, HTI

根据 Gartner 的预测，生成式人工智能将在未来两年内对搜索引擎构成严重威胁。到 2026 年，由于人工智能聊天机器人和其他虚拟代理的使用，搜索引擎的搜索量将下降四分之一。企业将不得不调整其营销渠道策略，以应对从传统搜索引擎向 AI 驱动的

转变。Gartner 副总裁分析师艾伦-安廷指出，有机搜索和付费搜索是科技营销人员实现认知和需求生成目标的重要渠道，而生成式人工智能解决方案正在成为替代答案引擎，取代以前在传统搜索引擎中执行的用户查询。随着生成式 AI 在企业中的应用越来越广泛，企业将需要重新思考其营销渠道战略。

生成式 AI 有三大关键优势，这些优势将对传统搜索引擎产生重大影响。首先，生成式 AI 可以提供更为精准和定制化的检索结果。ChatGPT 等生成式 AI 能够理解用户的具体需求，生成直接回答，而不仅仅是提供相关网页链接。这种定制化服务将大大优化用户的搜索体验。**其次，生成式 AI 提高搜索效率。**传统搜索引擎通过分拆用户提供的关键词进行抓取，效率较低，而生成式 AI 则在理解用户意图的基础上进行信息检索和处理，提高了检索效率和效果。**此外，生成式 AI 改变用户的交互方式。**生成式 AI 整合文字、图像和音视频等复杂媒介，能够提供更加丰富和互动的用户体验。例如，谷歌的 AI 搜索引擎 SGE 已经开始尝试在交互方式上进行改变，未来的 AI 主导搜索方式可能会通过对话形式实现更深度的用户需求融合。

谷歌的 AI 搜索引擎 SGE



Source: 谷歌搜索, HTI

生成式 AI 的崛起对传统搜索引擎以广告为主要营收的商业模式造成巨大冲击。以 ChatGPT 和谷歌搜索为例，依赖广告盈利的搜索引擎本已因 AI 大模型的威胁感到不安，OpenAI 放开注册限制更加剧了威胁。谷歌已开始改革其搜索业务，包括在高级订阅服务中添加 AI 驱动搜索功能，同时维持传统搜索服务免费，并继续在搜索页面上展示广告。谷歌明确表示不会提供无广告搜索体验，但将构建新的优质功能和服务以增强其订阅服务。这种探索能否利大于弊尚待讨论，生成式 AI 的高算力需求可能推动谷歌推出高级付费服务以收回部分成本。生成式 AI 可以提供更加精准、合理的答案，用户无需再点击广告商的网站，这将对搜索引擎的广告业务产生不利影响。IBM 中国数据与人工智能首席架构师徐孝天表示，大模型的普及肯定会对传统搜索引擎的广告营收模式产生重要不利影响。大模型具备语义理解能力，可以更好地产出搜索结果，其结果不会比现有搜索引擎差。然而，搜索引擎公司如何平衡新技术与盈利模式是一个复杂的问题。传统搜索引擎公司已经在积极使用大模型技术赋能原有搜索业务，整合技术增强搜索效果的趋势明显。但能否大范围推广，取决于大模型的经济性，以及如何降低大模型的能耗和硬件需求。

谷歌搜索的广告




Source: 谷歌搜索, HTI

4.3.2 应用端：AI 助力云计算产业，推动算力底层变革

随着信息技术的飞速发展，云计算和人工智能已成为当今科技领域的两大热点。云计算以其强大的计算能力和灵活的资源分配方式，为人工智能提供广阔的应用场景和强大的技术支持，而人工智能则通过机器学习、深度学习等技术手段，实现对海量数据的智能处理和分析，推动各行各业的创新与发展。

AI 技术显著提升云计算的算力效率。通过智能算法和深度学习模型，AI 能够对云计算资源进行动态优化分配，降低资源浪费，提高整体运算速度。Google 开发的 Tensor Processing Unit (TPU) 专门用于加速深度学习任务，并集成到 Google Cloud 平台中，显著提升了云计算的算力，减少能耗和运算时间。Google 利用 TPU 优化搜索算法，提升了搜索结果的精准度和响应速度。


Google 开发的 Tensor Processing Unit



Source: 芯智讯, HTI

AI 技术通过自动化运维 (AIOps)，实现云计算平台的智能监控和管理。亚马逊 AWS Lambda 提供无服务器计算功能，通过集成 AI 技术，实现自动化运维和动态资源分配，提升业务响应速度，降低运营成本。亚马逊电商平台利用 AWS Lambda 和 AI 技术实时分析用户数据，提供个性化推荐服务，提升用户体验和销售额。


亚马逊 AWS 工作原理



Source: AWS, HTI

云计算产业需要处理大量的数据，AI 在数据管理和处理方面发挥重要作用。微软 Azure 提供图像识别、语音识别和文本分析等认知服务，开发者可以将这些功能集成到应用中。医院利用 Azure 的图像识别技术分析医学影像，AI 可以提高诊断的准确性和效率。

微软 Azure 医疗保健的人口健康管理



Source: Azure, HTI

AI 在云计算安全领域的应用有助于提升系统的安全性。IBM Watson 通过云计算提供自然语言处理、智能客服、文本分析和数据挖掘等服务，帮助企业实现智能化运营，提升服务效率和质量，降低人工成本。金融机构利用 Watson 进行风险管理和客户服务，分析金融数据提供精准的风险评估和投资建议。AI 可以在此过程中保障系统安全并提升客户体验。苏格兰皇家银行 (RBS) 选择采用 Watson Assistant。通过 Watson Assistant，苏格兰皇家银行目前能够自动处理 40% 客户呼入电话。

IBM 开放银行平台解决方案架构



Source: Watson, HfI

AI 拓展云计算的新兴应用场景，如智能客服、智能推荐系统和自动驾驶等。 阿里巴巴云推出的 ET 大脑，覆盖城市管理、工业优化、环境治理、航空气调和农业等多个领域，通过云计算提供强大算力支持，结合 AI 技术，帮助各行业实现智能化转型。杭州利用 ET 大脑优化交通管理，通过实时交通流量分析和红绿灯调度，减少交通拥堵，提高交通运行效率。同时，杭州萧山国际机场已全面引入阿里云 ET 航空大脑，25 个国内安检通道全部上线人脸识别技术，人脸判断准确率超 99.6%，旅客身份甄别速度提升 3 倍以上。据阿里巴巴机器智能实验室副主任华先胜介绍，这一套人脸识别算法利用卷积神经网络从海量样本学习中获取了强大的身份鉴别能力，系统识别的时间只用 0.3 秒。

阿里云在人工智能领域的布局



Source: 阿里云开发者社区, HTI

此外，阿里云ET农业大脑将人工智能与农业深入结合，目前已应用于生猪养殖、苹果及甜瓜种植，已具备数字档案生成、全生命周期管理、智能农事分析、全链路溯源等功能。海升集团是国家级农业产业化重点龙头企业，在全国拥有近40个果蔬种植基地，总种植面积四万余亩，已经实现苹果、柑橘、莓类、胡萝卜、梨、樱桃、猕猴桃等品类的种植布局。在陕西，10000亩海升苹果的生产资料已经汇聚到ET农业大脑，可以对每棵果树进行个性化管理，大大提高果园的管理效率。通过对历史数据的智能分析，ET农业大脑能建立起一整套知识库，指导果农播种、施肥和耕作，提供最优决策；还可以进行智慧选址，针对不同品种的果树选择最适宜的水土环境。公司预计ET农业大脑可以帮助果农每亩地节省200元以上成本，整个海升集团每年约可节省2000万人民币。

阿里云 ET 航空大脑



Source: Railtown.ai 官网, HTI

阿里云 ET 农业大脑



Source: BugLab 官网, HTI

未来，随着边缘计算的兴起、自动化与智能化运维的实现、多云与混合云策略的发展，云计算在人工智能行业的应用将更加广泛和深入。边缘计算通过将计算资源部署到网络边缘，实现对数据的快速处理和响应，提高人工智能应用的实时性和效率。自动化运维通过智能监控、自动故障排查等技术手段，提高云计算平台的稳定性和可靠性，降低运维成本。多云与混合云策略通过整合不同云服务商的资源和服务，构建更加灵活、可扩展的云计算环境，满足不同的业务需求。同时，人工智能也为云计算提供了更高效、更智能的服务。通过不断创新和解决挑战，云计算和人工智能将共同推动各行各业的数字化转型和创新发展。

4.3.4 应用端：AI 牵引工业软件升级，行业前景广阔

近年来，人工智能技术的发展在企业信息化领域引起了广泛关注。以最近爆火的 ChatGPT、Copilot、New Bing 为例，作为基于 GPT4（Generative Pre-trained Transformer）模型的先进的自然语言处理技术，具有广泛的应用潜力，在不远的将来将对 PLM（产品生命周期管理）、MES（制造执行系统）、ERP（企业资源计划）和工程大数据应用产生较大影响，对企业的数字化和自动化水平也将带来显著的影响，包括提升生产效率、优化决策流程、改进用户体验等。

大模型可以提升 PLM 软件的易用性。产品生命周期管理（PLM）是一种用于协调产品设计、制造、销售和服务全生命周期的管理方法。大模型可以通过与设计师和工艺师的对话，理解他们的需求和意图，并自动化生成相应的设计方案、工艺参数和产品文档。这可以加速产品设计和开发过程，提高设计效率和准确性，并且会随着生成样本数量的不断增加而自我迭代优化。同时，大模型还可以与产品生命周期各阶段的相关人员进行实时的沟通和协作，帮助解决设计变更、产品质量和产线协同等问题，从而优化 PLM 的管理流程，提升产品质量和生产效率。**主要体现在四个方面：1 基于知识图谱的数据管理优化：**通过大模型的自然语言处理技术，帮助用户更轻松地管理和检索 PLM 中的数据，并快速构建知识图谱。大模型可以自动理解大量文本数据，提取实

AI人工智能产业链联盟

#每日为你摘取最重要的商业新闻#

更新 · 更快 · 更精彩



Zero

AI人工智能产业链联盟创始人
河北清华发展研究院智能机器人中心运营经理



base:北京



主要业务:AI商业化答疑及课程应用场景探索, 各类AI产品学习手册, 答疑及课程



欢迎扫码交流

提供: 学习手册/工具/资源链接/商业化案例/
行业报告/行业最新资讯及动态



人工智能产业链联盟创始人

邀请你加入星球, 一起学习

人工智能产业链联盟报 告库



星主: 人工智能产业链联盟创始人

每天仅需0.5元, 即可拥有以下福利!
每周更新各类机构的最新研究成果。立志将人工智能产业链联盟打造成市面上最全的AI研究资料库, 覆盖券商、产业公司、研究院所等...


知识星球

微信扫码加入星球 ▶



体关系，可以帮助用户快速查询和过滤数据，进行复杂的搜索和排序和组织操作，无需依赖实施人员提前配置复杂的查询检索条件，从而提高数据管理的效率，并为用户提供丰富的产品和工艺知识。**2.智能文件编写和文档协作：**大模型可以帮助用户更好地编写和协作文档，例如通过语义描述从海量历史数据中快速查询、引用、总结并基于给出条件，提取重要信息构建结构化知识，快速生成方案草稿，能够通过对话的形式创建、编辑、翻译、摘要、共享并与他人协作修改文档，以及通过对话进行文档版本的管理和历史记录的查看。**3.智能分析和报告：**大模型可提供智能分析和报告功能。通过对PLM中的数据进行分析和挖掘，大模型可以生成可视化的报告，帮助用户更好地了解项目状态、趋势和数据洞察，从而支持决策和管理。**4.产品设计的即时支持：**产品设计过程中，设计师可以与大模型进行语言交互获取设计建议、标准查询、性能计算等即时支持，甚至自动化进行模型、BOM的创建和维护，可以基于PLM管理的数据和知识，自动回答设计师的问题，并提供相关的任务指导，如新部件设计流程指导，而不需要复杂的操作界面或命令，这可以加速产品设计过程，提高设计质量，提高PLM软件的易用性。

人工智能在PLM软件的应用



Source: Medium, HTI

大模型可以提升生产过程的可控性和生产效率。制造执行系统（MES）是一种用于实时监控和管理生产过程的信息化系统。大模型可以通过与生产工人和生产管理人员的对话，了解生产计划、产线状态、设备维护等信息，并生成实时的生产报告、生产指令和生产日志。这可以帮助生产管理人员更好地掌握生产状态和资源利用情况，做出及时的决策和调整。同时，大模型还可以通过与生产工人的实时对话，提供生产操作指导、异常处理建议等支持，从而提高生产过程的可控性和生产效率。**主要体现在四个方面：****1.智能操作助理：**使用大模型可以帮助用户快速查询、创建、修改或删除制造订单、工艺路线、设备状态、物料需求等信息。用户可以通过自然语言与智能操作助理交互，而不需要复杂的操作界面或命令。智能操作助理可以根据用户的输入，自动生成相应的操作指令或界面，同时也可以根据用户的反馈，调整操作的步骤、顺序、方式等。**2.智能问题预测：**使用大模型可以帮助用户预测制造过程中可能出现的

问题、风险、异常等。用户可以通过输入一些历史数据或当前状况，让智能问题预测工具自动生成相应的预测结果或建议。智能问题预测工具可以利用深度学习等技术，分析制造数据中的模式、趋势、关联等，同时也可以利用外部数据源，如天气、市场、供应链等，提高预测的准确性和可靠性。**3.智能数据分析：**使用大模型可以帮助用户分析制造过程中的数据、指标、趋势等。用户可以通过提出一些问题或需求，让智能数据分析工具自动生成相应的报表、图表、总结等。智能数据分析可以利用自然语言处理等技术，理解用户的意图和语境，同时也可以利用数据挖掘等技术，提取数据中的价值和洞察，为用户提供高价值甚至预测性的信息。**4.智能培训工具：**使用大模型可以帮助用户提高制造技能、知识、经验等。用户可以通过与智能培训工具进行对话、模拟、测试等方式，学习和掌握相关的制造内容。智能培训工具可以利用对话系统等技术，与用户进行自然和友好的交流，同时也可以利用知识图谱等技术，构建和更新制造领域的知识体系，为用户提供个性化和适应性的学习路径。

制造执行系统 (MES)



Source: 搜狐, HTI

大模型有利于协调各业务流程，优化资源配置，提高订单响应速度和客户满意度。企业资源计划（ERP）是一种用于整合企业内外部资源，管理企业各业务流程的信息化系统。大模型可以通过与企业内部员工和外部合作伙伴的对话，了解企业的业务需求、订单状态、供应链信息等，并生成相应的订单管理、库存管理和供应链协调方案。这可以帮助企业更好地协调各业务流程，优化资源配置，提高订单响应速度和客户满意度。同时，大模型还可以通过与企业员工的对话，提供日常的人力资源管理、绩效评估、员工培训等支持，从而提升企业的人力资源管理效果。**主要有四个方面：**
1.自然语言排产计划编制：使用大模型可以帮助计划管理人员快速查询和制定各种计划，例如生产计划、采购计划、销售计划等，而不需要通过复杂的界面和操作。用户可以通过自然语言的方式，向大模型提出编制生产计划涉及的各种问题或需求，例如：“我需要在下个月生产 20 台发动机”“我需要采购多少钢材和塑料”“我需要根据返修情况调整交付计划”等，ChatGPT 可以根据产品、产能、订单、约束条件等，并参考历史计划和历史生产数据智能化进行排产排程计算，并以文字或可视化数据、图表的方式给出排产结果。
2.全局采购比较：使用大模型可以帮助用户高效地管理采购流程和供应商关系，而不需要通过繁琐的表单和审批。根据用户通过自然语言方式提出的各种问题或指令，诸如采购需求、查询供应商信用评级和交货期、订单增减等，大模型可以参照上下文，智能化分析历史采购信息，分析采购价格变动曲线，比较供应商最低报价，并结合已采购零部件质量合格情况生成相应的回答或执行相应的操作，提供相关的信息和反馈。
3.财务核算和销售预测助理：大模型可以帮助用户有效地管理财务核算和销售预测，不需要人工进行大量数据的准备，也无需编写冗长的报告。管理层和财务都可以通过自然语言的方式，而无需掌握专业的财务术语，向大模型提出各种问题或需求，包括计算某月现金流量表、预测下个季度的利润水平、申报本年度

的所得税、查看本季度的销售额和利润率等，大模型可结合历史财务信息和销售数据等，智能化的采用计算和分析公式对提出的问题进行数据获取、分析、整理，并以图文或报表的形式即时生成答案。4. **高效实时物流跟踪**：大模型可以帮助用户高效地跟踪物流和运输情况，而不需要通过复杂的系统和设备。用户可以通过自然语言的方式，向大模型询问，例如：“我需要查询 L 公司的货物位置”“考虑国庆堵车帮我安排 J 公司的运输路线”“我需要评估 K 公司的物流成本”等，大模型可智能给出物料的物理坐标，兼顾预期路况规划运输路线，结合油价、高速费用等估算物流成本并以报表方式反馈。

ERP 和人工智能的融合方向



Source: Existek, HTI

大模型可以更好地利用工程大数据。大数据技术在企业中的应用日益广泛，可以通过对海量数据的分析和挖掘，为企业提供深入的洞察和决策支持。大模型作为一种自然语言处理技术，可以通过与用户的对话，实时获取用户的需求和意图，并生成相应的查询和分析请求，从而与大数据软件进行集成。大模型可以通过与大数据软件的对话，获取实时的数据分析结果、数据可视化和数据报告，并将这些信息传递给用户。这可以帮助企业更好地理解 and 利用大数据，进行数据驱动的决策，优化业务流程，提高企业的竞争力和创新能力。**主要有四个方面**：1. **使用大模型可以提高大数据应用的智能性，使其能够更好地理解用户的需求和意图，生成更符合用户期望的数据操作、服务、接口等。**人工智能技术可以利用自然语言处理等技术，与用户进行自然和友好的交流，同时也可以利用机器学习等技术，根据用户的输入，自动完成相应的数据任务。这可以帮助企业更有效地获取和使用数据，提升数据的价值和意义。2. **使用大模型可以提高大数据应用的灵活性，使其能够更好地适应不同的数据源、格式、质量等，实现更多样化和个性化的数据处理、转换、集成等。**人工智能技术可以利用数据清洗、标准化、融合等技术，处理不同类型和来源的数据，同时也可以利用数据挖掘、推荐、搜索等技术，提供定制化的数据服务。这可以帮助企业更灵活地管理和优化数据，提升数据的效率和质量。3. **使用大模型可以提高大数据应用的创新性，使其能够更好地发现数据中的模式、趋势、关联等，生成更新颖和有趣的数据内容、可视化、报告等。**人工智能技术可以利用生成式对抗网络、强化学习等技术，在创新丰富大数据内容的同时优化和改进大数据方案；可以用于帮助企业更创新地开发和改进产品、服务、模式等，提升数据的竞争力和吸引力。4. **使用大模型可以提高大数据应用的可靠性，使其能够更好地预测数据中的问题、风险、异常等，生成更准确和可信的数据结果、建议、预警等。**通过充分利用深度学习等AI技术，可以分析大数据中的模式、趋势、关联等，同时也可以利用外部数据源，如市场、竞争、政策等，提高预测的准确性和可靠性，从而帮助企业更可靠地监控和控制数据，提升数据的安全性和稳定性。

据 2023 年 4 月 12 日微软公开新闻表示，西门子和微软正在利用以 ChatGPT 为代表的生成式 AI 的力量，帮助工业企业在产品的设计、工程、制造和运营生命周期中推动创新和效率。为了加强跨职能协作，西门子和微软正在将西门子的 Teamcenter 产品生命周期管理软件（PLM）与微软的协作平台 Teams、Azure、OpenAI 服务中的语言模型以及其他 Azure 人工智能功能集成。

Teamcenter 平台



Source: Teamcenter 官网, HTI

微软的协作平台 Teams



Source: Teams 官网, HTI

微软云+人工智能执行副总裁 ScottGuthrie 表示：“人工智能与技术平台的融合将深刻改变我们的工作方式和每个企业的运营方式。”“通过西门子，我们将人工智能的力量带给更多的工业组织，使他们能够简化工作流程，克服竖井，并以更具包容性的方式进行合作，以加快以客户为中心的创新。”在今天的汉诺威工业博览会上，两家技术领导者展示如何通过 AI 驱动的软件开发、问题报告和视觉质量检查，来提升工厂自动化和运营的水平。后续西门子和微软团队将推出新的 Teamcenter 应用程序，这些将使设计工程师、一线员工和跨业务职能的团队能够更快地完成反馈循环，共同解决挑战。例如，服务工程师或生产人员可以使用移动设备，使用自然语言记录和报告产品设计或质量问题。通过 Azure、OpenAI 服务，该应用程序可以解析非正式的语音数据，自动创建摘要报告，并在 Teamcenter 内将其发送给适当的设计、工程或制造专家，以简化工作流审批，减少请求设计更改所需的时间，从而更容易地影响设计和制造过程，并加快创新周期。

西门子和微软开展合作

Microsoft | News Center | Über Microsoft | Presse-Tools | Themen | Branchen | Feature Stories | Kontakt

Siemens and Microsoft drive industrial productivity with generative artificial intelligence

12. April 2023

[f](#) [t](#) [in](#) Immersive Reader



- Siemens' new Teamcenter app for Microsoft Teams to use AI, boosting productivity and innovation throughout a product lifecycle.
- Azure OpenAI Service powered assistant can augment the creation, optimization and debugging of code in software for factory automation.
- Industrial AI to enable visual quality inspection on the shop floor.

Siemens and Microsoft are harnessing the collaborative power of generative artificial intelligence (AI) to help industrial companies drive innovation and efficiency across the design, engineering, manufacturing and operational lifecycle of products. To enhance cross-functional collaboration, the companies are integrating Siemens' TeamCenter® software for product lifecycle management (PLM) with Microsoft's collaboration platform Teams and the language models in Azure OpenAI Service as well as other Azure AI capabilities. At Hannover Messe, the two technology leaders will demonstrate how generative AI can enhance factory automation and operations through AI-powered software development, problem reporting and visual quality inspection.


Source: 微软, HTI

4.4 电子：数据中心驱动成就了英伟达，Apple Intelligence 将带动终端需求

4.4.1 数据指数级增长而计算能力不足，数据中心驱动成就了英伟达

随着全球数据中心的能源消耗和算力成本正急剧上升，CPU 的性能提升已经进入到后摩尔定律时代，难以跟上当前的算力需求。而英伟达推出的 GPU，所代表的加速计算（accelerated computing），将成为解决目前难题的最优工具。而数据中心爆炸性的需求也推动了英伟达的发展。

IDC 全球数据量预测



Source: IDC, HTI


英伟达发布基于 Blackwell 架构的 GB200 超级芯片



Source: Nvidia, HTI

在英伟达 GTC 2024 上，CEO 黄仁勋指出英伟达的 GPU 系列产品可以使计算速度加速 100 倍，其功率仅增加约 3 倍，成本仅增加约 50%。这种设计优化了能源效率，还有效降低了总运营成本，提供了一种可持续发展的路径。GPU 的并行计算能力将高效低成本处理海量数据成为一种可能。


英伟达 GTC 2024



Source: Nvidia, HTI

在 GPU 的高算力及低能耗的加持下，传统的数据中心（IDC）将逐步转变为更高价值的生产力工厂（人工智能工厂），输入数据（Data）产出智能（Intelligence），GPU 的出现将大幅提高数据中心的效能，数据中心每投入 1 美元，便能获得高达 60 倍的性能提升。如一个价值 10 亿美元的数据中心，在添加了价值 5 亿美元的 GPU 后，可瞬间转变为一个价值千亿美元的人工智能工厂。与此同时，对传统数据中心的运营效率要求也在发生变化，从之前注重安全、保障和稳定的标准，转向高产出率的生产力工具标准。

GPU 的价值提升



Source: Nvidia, HTI

4.4.2 产业链

AI 时代需要新一代基础设施支持训练、推理和生成式 AI 应用落地。新一代 AI 基础设施将以大模型能力输出为核心平台，集成算力资源、数据服务和云服务，专门设计用于最大限度提升大模型和生成式 AI 应用的表现。该 AI 基础设施功能包括数据准备与管理、大模型训练推理、模型能力调用、生成式 AI 应用部署。在实际落地中，厂商还会根据自身的经验，针对用户在训练和使用大模型时面临的 AI 技术问题，为用户提供围绕大模型开发时间的咨询类服务。


新一代 AI 基础设施主要由算力、MaaS 及相关工具构成



Source: 《人工智能行业:2023 新一代人工智能基础设施白皮书》，HTI

算力需求指数级增长，GPU 迭代带来性能提升。以 OpenAI 为例，训练一次 1750 亿参数的 GPT-3 大约需要的算力约为 3640PFlops-day，共使用了 1024 块 A100(GPU)训练了 34 天。而 GPT-4 参数量达到了 GPT-3 的 500 倍，使用约 2-3 万张 A100，训练 1 个月左右时间。如图，仅训练算力需求就发生了几何倍提升。除了训练外，推理也将进一步推高算力需求，将远超训练阶段的用量。AI 新锐巨头 OpenAI 的创始人兼 CEO 萨姆奥特曼正在从中东地区筹集总计高达 7 万亿美元的资金，以支持公司的一项半导体计划，并与英伟达展开竞争。黄仁勋认为七万亿美元能买下所有的 GPU，但除了数量，还应关注计算机架构的进步，否则需要不切实际体量的燃料来支持 GPU 的消耗。

H100 相比上一代 A100 性能显著提升



Source: Nvidia, HTI


GTC2024，英伟达发布基于 Blackwell 架构的 GB200 超级芯片，性能提升功耗优化。1Blackwell 小芯片有 1040 亿个晶体管，采用 TSM N4P 制程，两个 Blackwell 小芯片组成一个 B100。两个 B100 GPU 和一个 Grace CPU 组成了一个 GB200 超级芯片。2Blackwell 拥有 20 PFLOPS 的 AI 算力，192 GB HBM3e，8TB/s 存储带宽，较 Hopper 在 FP4 规格算力提升 5 倍。如果要训练一个 1.8 万亿参数量的 GPT 模型，需要 8000 张 Hopper GPU，消耗 15 兆瓦的电力，连续跑上 90 天。但如果使用 Blackwell GPU，只需要 2000 张，同样跑 90 天只要消耗 4 兆瓦的电力。

由 GPU 数据中心驱动浪潮，不仅将带动 GPU 发展，同时也将提升服务器上 CPU、DPU、HBM 等产品需求。DPU 专为数据传输和安全处理所设计，由用于网络、存储和安全的可编程 ARM CPU 组成，以减轻 Hypervisor 的工作负载。而 HBM 是一种新内存，传统的内存显卡是单独的 DRAM，安装在显卡的 PCB 板上，与 GPU 芯片分开，而 HBM 将内存堆叠在一起与 GPU 集成在同一硅片上，提供更高的内存带宽和更低的功耗。

从 CPU/GPU 扩展新的 DPU 芯片



Source: 《科技行业 NVIDIA 专题研究:算力时代“新王”登基》, HTI
HBM 内存堆叠涉及并与 GPU 通过 2.5D 封装



Source: 《科技行业 NVIDIA 专题研究:算力时代“新王”登基》, HTI

4.4.3 训练芯片：未来机器人训练仍将需要大算力训练 GPU 支持

随着人工智能和机器人技术的快速发展，未来机器人训练将需要大算力 GPU 的支持。由于机器人执行的大多数任务（如自然语言处理、图像识别和自主导航等），均需要经过大量的数据分析和深度学习模型训练。其中的训练过程涉及庞大的数据集和复杂的算法逻辑，对计算资源提出了较高的要求。大算力 GPU 以其强大的并行计算能力，是深度学习训练的不可或缺的硬件，能够大幅提升训练速度和模型效率。

GPU：用于加速大规模的矩阵计算任务，如深度学习中的神经网络训练和推断。其优势在于提供了多个核心的并行计算基础结构，具备处理大量数据和高性能浮点运算的能力。英伟达最新推出基于 Blackwell 架构的 GB200 超级芯片，性能更高和功耗更低。如果要训练一个 1.8 万亿参数量的 GPT 模型，需要 8000 张 Hopper GPU，消耗 15 兆瓦的电力，连续跑上 90 天。但如果使用 Blackwell GPU，只需要 2000 张，同样跑 90 天只要消耗 4 兆瓦的电力。


存储为半导体核心受益板块，大模型迭代利好 DRAM 需求向好。根据 TrendForce 集邦咨询微信公众号，AI 服务器可望带动存储器需求成长，目前通用服务器的 DRAM 普遍配置约为 500-600GB，而 AI 服务器在单条模组上则多采 64-128GB，平均容量可达 1.2-1.7TB 之间。相较于一般服务器而言，AI 服务器多增加 GPGPU 的使用，因此以 A100 80GB 配置 4 或 8 张计算，HBM 用量约为 320-640GB。随着使用 HBM3 的加速芯片陆续放量，2024 年市场需求将大幅转往 HBM3，而 2024 年将直接超越 HBM2e，比重预估达 60%，且受惠于其更高的平均销售单价，将带动 HBM 营收显著成长。未来在 AI 模型逐渐复杂化的趋势下，将刺激更多的存储器用量，并同步带动服务器 DRAM、SSD 以及 HBM 的需求成长。

通用服务器及 AI 服务器平均存储容量差异

	通用服务器	AI服务器	AI服务器 (E)
服务器DRAM容量	500-600GB	1.2-1.7TB	2.2-2.7TB
服务器NAND容量	4.1TB	4.1TB	8TB
HBM容量	-	320-640GB	512-1024GB

Source: HTI

2022-2024E HBM 结构



Source: HTI

存储为半导体核心受益板块，大模型迭代利好 DRAM 需求向好。根据 TrendForce 集邦咨询微信公众号，AI 服务器可望带动存储器需求成长，目前通用服务器的 DRAM 普遍配置约为 500-600GB，而 AI 服务器在单条模组上则多采 64-128GB，平均容量可达 1.2-1.7TB 之间。相较于一般服务器而言，AI 服务器多增加 GPGPU 的使用，因此以 A100 80GB 配置 4 或 8 张计算，HBM 用量约为 320-640GB。随着使用 HBM3 的加速芯片陆续放量，2024 年市场需求将大幅转往 HBM3，而 2024 年将直接超越 HBM2e，比重预估达 60%，且受惠于其更高的平均销售单价，将带动 HBM 营收显著成长。未来在 AI 模型逐渐复杂化的趋势下，将刺激更多的存储器用量，并同步带动服务器 DRAM、SSD 以及 HBM 的需求成长。


光器件产业格局：芯片工艺壁垒高，下游应用分布广泛。光器件位于光通信产业链中游，上游包括光芯片、电芯片、光组件等，产业链下游是光通信设备商，最终客户方面，传统客户包括了 2B 侧电信市场的大型运营商和数通市场的云计算巨头，近年来光器件厂商开始逐渐向 2B 侧的非通信领域（如医疗检测等）和 2C 侧消费级应用场景（如 AR，激光雷达等）延伸，以寻求更大的发展空间。光模块产品所需原材料主要为光器件、电路芯片、PCB 以及结构件等。其中，光器件的成本占比最高，在 73%左右。光器件主要由 TOSA(以激光器为主的发射组件)、ROSA(以探测器为主的接收组件)、尾纤等组成，其中 TOSA 占到了光器件总成本的 48%;ROSA 占到了光器件总成本的 32%。

光器件：市场份额中国厂商登顶，光芯片空间可期。根据 Ofweek 光通讯网援引 LightCounting 最新版 2022 年全球光模块 TOP10 榜单，中国光模块厂商 2010 年仅有武汉电信器件有限公司（WTD，后与光迅科技合并）入围。在 2022 年全球光模块市场，旭创科技与 Coherent 并列 TOP10 榜首，Cisco（Acacia）排名第三，华为（海思）排名第四，光迅科技排名第五，海信宽带排名第六，新易盛排名第七，华工正源排名第八，Intel 排名第九，索尔思光电排名第十。

据中际旭创 2021 年年报援引 Lightcounting 预测，光模块的市场规模在未来 5 年将以 CAGR14% 保持增长，Lightcounting 预计 2026 年其规模达到 176 亿美元。受益于数据中心建设、5G 网络深入布局，中国光模块市场也有望进一步增长。


数通市场：技术迭代升级，800G 等高速模块未来将成主流。 LightCounting 最新数据显示，未来随着 AI、元宇宙等新技术不断发展，以及网络流量长期保持持续增长，以太网光模块销售额也将保持较快增长并不断迭代升级。

典型的超大规模数据中心互连路线图



Source: Medium, HTI

2016-2026 以太网光模块销售情况及预测



Source: 36Kr, HTI

铜链接：算力基础设施高性能和高效率需求，带来光变铜革新。在集群训练下，网络通信等问题会造成大模型训练效率的降低，而且大规模、长时间训练对 GPU 集群稳定性也提出了更高的要求。因此以英伟达为代表的厂商提出了一系列的变革措施来提升算力基础设施的性能和效率。除了单个芯片能力的提升，3 月 18 日到 21 日的英伟达 GTC 大会上，黄仁勋提出单个机柜内的传输从光纤变为铜线，减少了光电信号变换的能量损耗，而且还能保持传输速度。

4.4.4 推理芯片速度为先，Apple Intelligence 将带动终端新需求


AI 端侧数字芯片：不可或缺一环，AI 时代芯片最后一公里。AI 生态应是分布式的，分布在不同的终端设备上，以适应人工智能的感知、决策和执行环节。据电子工程专辑公众号援引 Deloitte 分析，AI 芯片(包括边缘和云端)的市场规模将从 2018 年的约 60 亿美元增长到 2025 年的 900 亿美元，这期间的年复合增长率高达 45%。到 2024 年，边缘 AI 芯片的出货量将增至 15 亿颗，年增长至少 20%，远高于全球半导体整体增长率(大约 9%)。

目前的边缘 AI 芯片主要出现在消费类电子设备，其中高性能手机占据了较大的消费应用边缘 AI 芯片市场。然而，边缘 AI 芯片正越来越多地应用在非消费类设备和场合，比如智能安防、ADAS/自动驾驶、智能家居、可穿戴智能设备，以及商业和工业场合的 AI 应用(智能交通、智慧城市、工厂机器视觉、机器人和 AGV 等)。

AI PC：Copilot 稳步推进，端侧 AI 能见度最高。生成式 AI 模型的爆发式增长，带来将专用的 AI 加速硬件集成到 PC 的需求。参考 Canalys 围绕硬件的初步定义，我们认为 AI PC 需要具备专用芯片组/块以承载端侧的 AI 运行负载，如配备 NPU 处理器，从而使其能够在本地而非云端运行 AI 模型。在此定义下，根据 Canalys 数据，2024 年出货的 PC 中，AI PC 占比将会接近 20%；到 2027 年，得益于换机动能和全新本地体验，AI PC 占比将达 60% 以上。


随 AI PC 持续演绎，头部厂商积极布局。2023 年底，英特尔及高通分别推出可集成 NPU 单元的处理器的酷睿 Ultra 和骁龙 XElite。随后，联想、戴尔、惠普、三星、华硕、荣耀等陆续上线 AI PC 产品。此外，微软有望通过新增 Copilot 键以赋能终端体验。

AI PC 全球接受度曲线



资料来源: Canlys, HTI

Canlys 2022-2027 年 AI PC 出货量预计



资料来源: Canlys, HTI

AI+AR眼镜：多模态加持，智能眼镜需求端迎来催化。我们判断，针对AR眼镜的光显方案，Micro OLED+Birdbath的方案更适配影游娱乐场景，而Micro LED+光波导的方案更适合全天候佩戴场景。其中，多模态赋能下，以Micro LED+光波导为代表的AR眼镜，有望成为AI大模型的较佳载体。


目前，海外Meta Ray-ban多模态AI功能测试中，眼镜可以准确描述所看到物体衬衫并提供数款搭配建议。国内MYVU基于Flyme AI大模型也能够带来旅游攻略、学习计划、商业分析等等智能助手功能，和提词器、实时翻译（中英双语）、骑行导航等场景功能。

AI手机：关注三星产业链。三星首推AI手机，有望加速行业换机潮。根据韩联社，2024年1月，三星推出首款AI手机Galaxy S24，28天在韩国销量突破100万部，刷新该系列销量纪录。Galaxy S24 AI功能主要应用在翻译、搜索、影像3大方面，对应手机用户通话（信息）、搜索和拍照3大高频使用场景。

在国内，Galaxy AI在中国的本土化合作供应商包括百度、WPS、美图等。其中，百度提供的是云服务、美图提供的是自研视觉大模型MiracleVision与三星相册合作、WPS提供用户文档生成服务。我们认为，尽管当前终端并未搭载生成式AI功能，但其可以通过OTA方式实现快速部署。整体而言，AI加持对换机潮的影响值得关注。

在推理芯片性能不断提升的背景下，Apple Intelligence 正推动终端设备的新需求。在WWDC 2024全球开发者大会上，苹果发布了新一代操作系统，包括iOS 18、iPadOS 18等，以及适用于iPhone、iPad和Mac的个人智能系统—Apple Intelligence，正式开启苹果AI后的新时代。此次苹果联手OpenAI，其AI功能主要集中在设备端和云端，使得手机等终端设备变得更智能，在用户交互体验上进行了许多优化。1) Siri得到了显著增强，能高效完成各种任务，包括文字对话，理解碎片化口语，具备识屏功能，识别屏幕上的文字图片等，如根据用户指令找出指定的照片、自主修图等。2) 可进行文字创作、文字总结、图像生成等指令。3) 识别并汇总终端应用信息如邮件、信息等，协助用户进行行程安排。4) 支持用Apple Pencil手写数学公式并自动生成答案等。高性能推理芯片的应用不仅使终端设备变得更智能，还大大提高用户体验。AI PC、AI Phone、AI IoT等AI智能终端的普及，市场需求将迎来新一波增长。

Apple Intelligence 演示




Source: Apple, HTI



Apple Pencil 手写



Source: Apple, HTI



新一代 Siri




Source: Apple, HTI



4.5 能源及基础设施建设

AI 技术的发展需要大量的数据处理和计算能力，根据高盛预测，2023-2030 年数据中心电力需求的年均复合增长率将达到 15%，到 2030 年将增长一倍以上。数据中心是电力消耗大户，它们需要大量电力来驱动服务器、冷却系统等设备。随着 AI 技术在各行各业的应用逐渐深入，预计全球电力需求将持续增长。高盛集团预测，全球数据中心的电力需求在 2023-2030 年复合增长率将达 15%。其中，IEA 预计 2022 至 2030 年美国电力需求年均增长率从过去的 0% 左右上升至 2.4%，2.4% 的增长中约 90 个基点由数据中心带动，到 2030 年数据中心电力需求占美国电力总需求的比例将从目前的 3% 左右增至 8%，同时为支持美国数据中心电力需求的增长，机构预测美国累计需要新增约 47GW 的增量发电能力，其中约 60% 使用天然气，40% 使用可再生能源。


全球数据中心耗电量 (2019-2026)



Source: IEA, HTI

AI 产业的推进将带动中国数据中心的建设和运营需求增加。工业和信息化部等六部门在 2023 年 10 月联合发布的《算力基础设施高质量发展行动计划》预计，到 2025 年我国的算力规模将超过 300EFlops，智能算力的占比达到 35%，数据中心的耗电量将增至 3500 亿千瓦时。《绿色算力白皮书 (2023) 》进一步预测，到 2030 年，我国数据中心的耗电量将达到 5900 亿千瓦时。

各地区数据中心耗电量及总电力需求占比 (2022 vs 2026)




Source: IEA, HTI

电网瓶颈制约数据中心电力需求的增长，2023-2030 年全球电网投资规模有望提高 25%，主要由中、美、欧主导。欧美等发达国家目前的电网基本上是在 20 世纪 60、70 年代建设完成，70% 的输电线使用超过 25 年，处于典型 50-80 年生命周期的尾部，在电力需求推动下，电网建设改造迫在眉睫。根据 IEA 数据，在承诺目标情境下，


2023-2030 年均电网投资有望达到 4500 亿美元，较 2016-2022 年期间提高 25%，增速较快，全球电网投资主要由中国、美国、欧洲主导，2022 年美国电网投资规模为 664 亿美元，约合人民币 4800 亿元，略低于中国的 5000 亿元。IEA 预测，2023 年和 2024 年电网投资规模为 726 亿美元和 793 亿美元，2024-2030 年美国电网投资复合增速为 9.3%，2022 年欧洲电网投资达 540 亿美元，2024-2030 年美国电网投资复合增速为 7.5%，保高速增长。

全球各国电网投资（2022 年）



Source: BNEF, HTI

全球电网投资展望



Source: IEA, HTI

发展中国家线路建设速度较欧美更快，线路存量替换需求强劲。 数据显示在承诺目标情景中，从 2021 年到 2050 年全球电网总长度将增加一倍多，达到 1.66 亿公里。配电线路仍将占线路总长度的 90% 以上，发达经济体中，2021 年到 2050 年电网总长度将增加 50%，而同期新兴市场和发展中经济体的电网总长度将增加 150% 以上。除此之外，2021 年全球电网总长度的三分之二将在 2050 年之前被替换。


承诺目标情境下，全球主要国家输配电线路长度（百万公里）

	输电			配电			总计		
	2021	2030	2050	2021	2030	2050	2021	2030	2050
美国	0.5	0.6	1.0	11.1	11.5	15.2	11.6	12.1	16.1
欧盟	0.5	0.6	0.9	10.3	11.0	14.0	10.8	11.7	14.9
日本	0.04	0.04	0.05	1.3	1.3	1.7	1.4	1.4	1.8
其他发达经济体	0.5	0.6	1.0	6.9	8.0	13.7	7.4	8.5	14.7
东南亚	0.2	0.3	0.8	4.7	6.3	11.9	4.9	6.6	12.7
印度	0.5	0.7	1.7	11.3	14.0	25.6	11.8	14.7	27.2
非洲	0.3	0.4	1.1	3.9	5.0	14.0	4.2	5.3	15.0
中国	1.6	2.4	3.7	7.8	12.3	27.6	9.4	14.8	31.4
其他新兴市场和 发展中经济体	1.2	1.5	2.5	14.4	16.8	30.0	15.6	18.3	32.5
全球	5.3	7.2	12.7	71.7	86.1	153.7	77.1	93.4	166.4

Source: IEA, HTI

在减碳背景下，数据中心将聚焦于可再生能源。 随着算力行业的迅猛发展，碳排放量显著增加，各国推动数据中心积极采用绿色电力，以应对环保和减碳压力。根据欧盟最新修订的《能源效率指令》，自 2024 年起，数据中心运营商必须详细报告其能源使用和排放情况，并在技术和经济可行的前提下实施废热回收。中国则要求，所有公共组织的数据中心到 2032 年必须全部使用可再生能源，并且自 2023 年起，可再生能源比例需达到 5%。美国《2020 年能源法》要求政府研究数据中心的能源和水资源使用情况，制定能效指标和最佳实践，以推动能效提升。此外，数据中心的能耗具有波动性，通常在工作时间达到峰值，利用可再生能源可以有效平衡能耗曲线。


按来源划分的全球发电量同比变化情况 (2019-2026)



Source: IEA, HTI

全球光伏投资占发电技术首位，预计 2024 年将继续引领电力转型。 根据 IEA 数据，2023 年，全球太阳能光伏领域投资达到 4800 亿美元，超过所有其他发电技术的总和。在区域分布上，2022 年，亚太地区和欧洲及北美洲分别占全球光伏项目投资的 55% 和 33%，其中，中国和美国共占比全球光伏项目投资约 50%。根据 IEA 预测，到 2024 年，光伏发电技术的投资将超过 5000 亿美元。尽管由于光伏模块价格下降，2024 年的增长可能略有放缓，但光伏发电仍然是全球电力部门转型的核心。


全球各发电技术的年度投资额 (2021-2024E)



Source: IEA, HTI

数据中心对于电力持续性及稳定性的要求带动电化学储能及不间断电源的需求。 数据中心运算需要不间断能源供应，意外断电关停行为会带来不可估计的损失，因此在围绕数据中心的基础设施建设，除了宏观层面的发电及电网建设更新外，也伴生了微观层面的不间断电源 (UPS) 及电化学储能等产品的需求。根据 Data bridge 测算，全球数据中心 UPS 市场预计将以 9.57% 的复合年增长率增长，从 2022 年的 31.72 亿美元到 2029 年达到 60.15 亿美元。而储能则便于数据中心调节光伏等新能源发电峰谷，工信部等六部门联合印发的《算力基础设施高质量发展行动计划》中就明确提出支持液冷、储能等新技术在算力发展中的应用，鼓励算力中心采用源网荷储等技术，支持与风电、光伏等可再生能源融合开发、就近消纳。算力市场是未来储能的重要应用场景之一。在算力设施直接配置储能的领域，目前 UPS+锂电的储能型 UPS 发展迅猛，成为数据中心配储的主要途径。

数据中心 UPS 市场规模 2028 年将达到约 62 亿美元 (2023-2028E)



Source: Data bridge, HTI

增强能源利用效率对于数据中心的长期可持续增长至关重要。 PUE (Power Usage Effectiveness) 是数据中心设施使用的能源总量除以输送到数据中心计算设备的能量的值，根据 Uptime Institute 2023 年全球数据中心调查，全球平均年化 PUE 为 1.58，事实上自 2018 年以来，全球平均 PUE 一直维持在 1.55 至 1.60 之间，主要由于一是该调查范围扩大，由北美和欧洲延伸到其他地区，如在中东和拉丁美洲等温暖潮湿气候中平均 PUE 高于 1.70。另外，过去五年建造的数据中心效率更高，如北美和欧洲的新建筑的 PUE 比率低于 1.40。当前最流行、最高效的降低 PUE 措施为“自然冷却”系统，即使用较低的室外温度来冷却数据中心设施。除了自然冷却外，还有许多其他措施可以在数据中心实现更可持续的冷却和热管理包括冷空气和热空气密封系统、天然制冷剂、直接液体冷却 (DLC)、热回收和循环利用、冷却系统现代化等。在数据中心使用人工智能 (AI) 也可以提升成本效率，大型数据中心已经使用深度学习和人工神经网络来优化冷却系统，预测用电量，以及总体上进行数据中心管理降低 PUE。

4.6 智能驾驶

美国当地时间3月18日，特斯拉在北美地区全面推送FSD V12.3版本;3月30日，FSD V12.3.3版本推送，FSD首度摘帽Beta，后缀改为Supervised(受监管)，正式面向公众测试，并向全美至少200万位特斯拉车主开放免费使用一个月。FSD V12.3在算法层面做出了大胆创新，用“端到端神经网络”AI系统完全取代以往依赖于手动编码规则和机器学习模型的方法。我们持续跟踪多位海外社媒博主的真实路测，惊讶于V12.3版本在处理大多数复杂路况下已能做出接近甚至超越人类司机的决策执行，并能在90%以上行驶中提供较高的丝滑度和更少的介入接管。


4.6.1 FSD 端到端智驾方案：FSD V12.3 与前代Beta版有何不同？

处理日常复杂场景时流畅无误：多位海外博主展示了新版本遇到环岛/转盘通行、停车场内部路绕行、单行道窄路会车、以及通用障碍物避障等场景都能设法顺利通过，确保日常90%的使用场景顺畅无需人工接管(如4月2日拯救了美国一位胰岛素急救车主);

越来越懂人类：多位博主测试得出V12.3版本可识别行人或交通指挥者的眼神交流/手势，做出精准的通行/让行和变速、变道判断，在充分遵守美国路权法规和意识的同时最大可能实现体验无断点

以目的地为目标自我更正：新版本展示了汽车到达目的地/导航信息有误时会主动脱离导航指引，完全基于纯视觉信息继续前行，尽可能靠近指定目的地，甚至能在一片在建工地(无划线)中找到离定位最近的停车位。这种更符合“哪里都能开”定语的智能能力预示着特斯拉在实现真正的点到点自动驾驶方面取得了重大进展，在未来几个新版本中我们很快将看到更接近L4的“点到点”智能召唤及代客泊车功能;

单日 FSD V12.3.3 安装更新量 vs 总更新量(付费 FSD V12.3.3 安装率(付费用户登记 用户登记))




软件版本迭代速度大幅提高：特斯拉V12从传统“感知-归控-执行”架构转变为“端到端”架构，人工代码被大量替换，模型迭代效率快速提高，从V12.2到推送V12.3用了10天，V12.3到V12.3.1仅用一周，而V12.3.2到V12.3.3更是仅用5天，已超越马斯克此前宣称的“每两周一次”的更新频率。我们认为算力已经不再是限制FSD迭代的瓶颈，而随着FSD订阅量的快速增长，每日海量行驶数据将加速软件迭代的飞轮效应。特斯拉计划在今年10月达到100epllops的总算力，在云计算方面将进一步拉大与其他主机厂之间的差距。

Robotaxi发布将近，特斯拉智驾的 ChatGPT 时刻还有多远? 4月5日特斯拉宣布8月8日将推出 Robotaxi，并指出将不会取消入门级车型(Model 2/Q)的生产计划。特斯拉规划中的入门级车型平台同时适用于生产 Model 2/Q 及 Robotaxi，我们判断特斯拉同时需要 Robotaxi 的亮相为公司估值打开更多想象空间，及 Model 2/Q 的量产来应对欧美地区疲弱的购车需求和中国市场的竞争加剧。目前美国和加拿大的 FSD 买断价格分别为 US\$12,000 和 CAD16,000，而美国 FSD 订阅费为 US\$199/月，后降低至 US\$99/月。Robotaxi 推出后特斯拉将打造一个智驾平台，组建自动驾驶出租车队，可能同时带来更为灵活的 FSD 收费方案，为公司快速增加经常性收入。我们预测 FSD 软件业务稳态毛利率可达 70%以上，对于近期单车利润持续承压的特斯拉来说可谓扭转局势的关键。我们认为公司 4Q24 起将全力加快 Robotaxi 的软硬件量产，并推动 FSD 进入包括欧洲和中国在内的全球主流市场，促进特斯拉智驾的 ChatGPT 时刻到来。

后续版本及 Robotaxi 标杆效应有望为 FSD 带来渗透率拐点，推动软件收入爆发增长。 据特斯拉软件追踪网站 TeslaFi.com 统计，FSD V12.3.3(Supervised) 是目前在参与 FSD 测试车辆中安装比例最高的版本。截至美国时间 4 月 8 日，在其付费用户登记的 19,868 辆特斯拉车辆中，有 5,722 辆安装了 V12.3.3 版本，约 30% 的车辆更新到了最新版。而从整体用户看，由于 FSD 完全自动驾驶功能推送多次推迟以及定价提高，特斯拉北美新车 FSD 搭载率从 2019 年 50% 水平一路下滑至目前 10% 左右水平。我们认为，FSD V12 版本已经证明新模型强大泛化能力，随算法迭代加速，8 月 Robotaxi 推出可为乘用车用户付费提供性能背书，有望在今年扭转 FSD 新车搭载率下降趋势甚至带动老用户升级，相关软件服务或将实现翻倍增长。

特斯拉北美 FSD 新车搭载率




Source: Troy Teslike, HTI 测算

4.6.2 智驾方案大转向：模组式 VS 端到端

智驾方案最初采用的是模组式开发模式，但随着端到端模式优势的凸显，未来智能驾驶方案将逐渐向端到端模式转移。然而，考虑到技术成熟度和市场接受度的现实情况，智驾方案短期内采用这两种模式互相结合的模式，并持续提升端到端模式的性能和可靠性。


什么是模组式: 在模块化架构中，传感器、感知、判断和控制子系统协同工作，共同完成任务。传感器负责收集环境数据，感知模块分析环境数据，判断模块制定车辆行驶策略，而控制模块执行这些策略，实现车辆的操作。这些子系统紧密协作，共同完成复杂的驾驶任务。如自动驾驶公司 Mobileye，主要提供 EyeQ 系列芯片，采用模组式的方法，专门用于处理车载摄像头的的数据，该芯片工作时直接输出目标检测、车道保持、碰撞预警等感知结果。

模组式架构



Source: Extrahop, HTI


模组式 vs 端到端



Source: Semantischolar, HTI

什么是端到端: 利用深度学习等机器学习技术直接从传感器输入（如车载雷达、摄像头等数据）到驾驶控制输出（如方向盘操作、加减速等）的全自动化流程，端到端技术更接近人类行为和思维方式（从感知到执行）。但端到端一体化模式对于算力要求很高，目前除了英伟达，很少有公司能真正实现该模式，更多是提供以混合端到端的解决方案，这种方案结合了端到端和模组化的方法，利用端到端的学习优势，但在某些时刻会引入规则，将任务分解成更小的模块，以提升性能表现。

端到端示意图



Source: Thinkautonomous, HTI

4.6.3 智驾行业最新动态及未来演变预测


主机厂：自研整车智能面临巨额投资，新势力快速跟进新趋势。 为了进一步提高汽车智能化，提供用户体验感，打破固有的组装汽车思维，主机厂自研整车智能将是新趋势。比亚迪计划将在智能化领域投资 1000 亿元，用“整车智能”技术路线引领新能源汽车的发展方向，包括 e 平台 3.0、云辇、易四方和璇玑架构。同时，蔚来、理想和小鹏也在迅速转向端到端模式，蔚来也是全域自研的代表之一，自研了芯片、整车系统、到手机应用等产品。

Tier 0.5 综合供应商：鸿蒙智行系、百度系同车企深度绑定。 鸿蒙智行是华为与车企参与度最深的一种合作模式，该模式下华为将深度参与产品设计、营销及终端销售。当前鸿蒙智行模式的合作伙伴包括北汽、赛力斯、江淮和奇瑞。百度则与吉利、长安、丰田等车企展开不同深度的合作，百度联合吉利打造的智能电动汽车品牌极越，首款车型极越 01 已于 23 年 10 月正式上市，通过科技公司和车企的联系，打造的车型将深度融合智能化，提供定制化解决方案。

Tier 1 方案供应商：NVIDIA 来势汹汹，Mobileye 应对乏力，国产方案上车攀升。 英伟达野心勃勃，为车企提供灵活的软硬件解决方案，车企可自由选择自动驾驶软硬件系统。创始人黄仁勋表示，未来英伟达营收将达到 10000 亿美元，其中汽车业务能占到 30%，汽车业务将是三大支柱业务之一。同时，英伟达已与比亚迪、小鹏和广汽埃安达成合作，三家车企将采用英伟达最新 DRIVE Thor 芯片开发自动驾驶车型。自动驾驶公司 Mobileye 则为车企提供软硬件一体化的解决方案，其在自动驾驶芯片市场的市占率一度超过 90%，而随着自动驾驶技术的发展，以及客户对智驾解决方案更高透明度要求，Mobileye 的“黑盒”解决方案已无法满足车企的自研需求和合规要求，部分车企进而选择了其他供应商（比如英伟达、国产供应商地平线和黑芝麻等）。而国产解决方案供应商（如地平线、黑芝麻等）将受益于此次新能源汽车国产化浪潮，如地平线提供的解决方案更加灵活自由，允许车企自研芯片，甚至可以授权自有芯片 IP，开放研发平台，提供团队协助等。

智驾行业趋势

BPU IP授权 + 软件白盒赋能：“ARM + Android”模式




Source: 汽车头条, HTI

4.6.4 智能化的下半场及未来演变预测

国内车企面临三年“解放战争”价格战，销量是生命线，出海才有利润。国内车企的多数产品同质化程度较高，几乎整个市场面临着充分竞争，各大车企为了获得更多的销量，价格战越演愈烈。根据财报，2023 年国内前十车企的利润总和低于日本丰田一家。2024 年初，特斯拉、比亚迪、小鹏等车企继续采取降价活动。当前生态出海，车企才有机会获得更高的利润空间。2023 年我国出口汽车高达 522.1 万辆，超过日本成为全球第一大汽车出口国。比亚迪、长城、蔚来等纷纷积极布局海外市场，根据 2023 年财报，比亚迪汽车海外销量仅占总销量的 7%，而其海外收入占比约为 14%。

长城、比亚迪 2023 年海外情况



Source: Wind, HTI

国内市场高端产品才有利润，智驾是最重要的能力。在电动化和智能化的背景下，正迎来一个前所未有的发展机遇，特别是在高端豪华车市场实现“弯道超车”。国内中低端市场竞争激烈，高端产品是实现利润最大化的关键，已有部分车企推出了高端系列，如比亚迪的仰望 U8 豪华版和越野玩家版，售价 109.8 万元，蔚来 ET9 预售价 80 万元，理想 MEGA 的售价约 60 万元，华为问界 M9 的售价约 50 万元等。同时，根据中国国家智能网联汽车创新中心发布的《智能网联汽车技术路线图 2.0》预计，到 2025 年 L2-L3 级智能网联汽车销量将占总销量超过 50%，并在特定场景实现 L4 级车辆的商业应用。到 2030 年，L2-L3 级车辆销量占比预计超过 70%，L4 级车辆将在高速公路和部分城市道路广泛应用。智能驾驶技术是国内车企未来的核心竞争力之一，差异化的智能驾驶体验有助于提升销量，如今年赛力斯 1-5 月份销量同比增速 342%至 156823 辆。

2023 年中国乘用车市场各价格区间销量与代表品牌

市场分析

2023年中国乘用车市场 各价格区间的销量与代表品牌

按车辆实际成交价而非指导价计算，各区间所示的代表品牌为2023年累计销量在对应价格段内份额大于等于10%的品牌。

单位：万辆



Source: 杰兰路分析, HTI

合纵与连横：全自研，或撕下“全栈自研”的遮羞布。主机厂自研整车智能将是新趋势，但车企需面临巨额投资。车企自研整车智能，对于企业综合实力要求很高，不仅需要企业有创新能力、更需要长期投入大量资金。在当前多数国内车企深度内卷，价格战已经威胁到企业生命线的背景下，国内大多数车企并不具备全全端自研的实力，更多的或是通过供应商的大部分研究结合企业的小部分研究来实现智能解决方案。在未来发展中，车企可能不得不面临要么选择长期布局、投入重金来实现全自研，并且形成差异化的技术解决方案（如比亚迪），要么选择放弃“全栈自研”的路线，采用业内最优秀的智能解决方案供应商（如华为）。




Source: SOHU, Mydrivers, HTI

4.7 人形机器人

人形机器人，或AI辅助机器人，是一个万亿美金级的行业。自 ChatGPT 横空出世，生成式 AI 主要通过学习互联网上人类的知识来达到内容生成的能力，而未来 AI 的发展将会完成对互联网所有内容的学习，并开始学习物理世界的规则。当 AI 学会了物理世界的规则，其将具备生成物理世界行为的能力，并通过人形机器人等载体提供之前难以想象的生产力和“人”力资源。而传统意义上的**数据中心将会转化为 AI 工厂**成为新型生产力工厂。

人工智能、机器学习和深度学习



Source: Intel, HTI

当机器人得到人工智能增强后，机器人可以帮助企业进行生产创新和转型运营。目前常见的由人工智能驱动的机器人类型包括：

自主移动机器人 (Autonomous Mobile Robots, AMR)

随着 AMR 在其环境中移动，AI 赋能可以使机器人能够完成：

- 通过 3D 相机和激光雷达传感器捕获信息
- 分析收集的信息
- 根据他们的环境和总体任务进行推断
- 采取行动以实现最佳结果

根据行业的不同，AMR 完成的任务和行动差异很大。例如，当物流机器人将货物从仓库中的一个点移动到另一个点时，AMR 可以通过绕过工厂里掉落的箱子或者工作人员的导航规划来避免碰撞，同时确定完成任务的最佳路径。

自主移动机器人 (AMR)




Source: Intel, HTI

机械臂 (Articulated Robots, 或 Robotic Arms)

人工智能使关节式机器人能够更快、更准确地执行任务。人工智能技术从视觉传感器 (如 2D/3D 相机) 推断信息, 以分割、理解场景, 检测、分类物体。

过去, 机械臂需要进行教学来执行单一的任务, 例如从特定方向的精确位置拾取单一类型的物体。机器人无法在众多物体中识别特定类型的物体, 无法以一定的公差 (面积而非确切位置) 确定物体位置, 也无法根据物体方向调整抓取。

机械臂



Source: Intel, HTI

现在, 以 Intel 的 AI 解决方案为例, 采用了 Intel 的 RealSense 高分辨率深度相机和 OpenVINO 工具包的机械臂, 可以检测周围环境中的物体, 并按类型识别进行特定的操作。这些能力使机器人能够比以前更准确、更稳定、更安全、更快地操作。它们还扩大了机器人可以完成的任务范围。

协作机器人（Collaborative Robot, Cobot）

Cobots 设计之初就是要与人类直接接触和合作。大多数其他类型的机器人在执行任务时需要在严格隔离的工作区域独立执行任务，但 Cobot 可以与工人共享空间，帮助他们完成更多任务。它们通常用于从日常工作流程中消除手动、危险或繁重的任务。一般情况下 Cobot 需要人类提前训练来学习和规定如何同人类合作，在 AI 的赋能下 Cobot 可以在没有工人辅助训练的情况下，通过对人类的言语和手势的学习，做出相应的反应，进行相应的工序操作。

协作机器人（Cobot）




Source: NVIDIA, Computex 2024, HTI

在 2024 年 6 月 2 日的 Computex 大会上，NVIDIA 宣布全球机器人开发领导者如比亚迪电子（BYD Electronics）、西门子（Siemens）、Teradyne Robotics 和 Alphabet 旗下公司 Intrinsic 等十几家全球机器人行业领导者将采用 NVIDIA Isaac 机器人平台，用于下一代人工智能自主机器人和机器人的研发和生产。通过基于对物理环境的模拟，AI 模型可以被集成到软件框架和机器人模型中，从而使工厂、仓库和配送中心更高效、更安全、更精确的运转。

4.7.1 劳动力短缺等宏观因素影响加大对人形机器人需求


结构性社会问题的出现进一步刺激对机器人的需求。人形机器人作为更具效率的劳动力在工业化场景中补缺人力的短缺。上世纪中期在战后劳动力短缺的宏观经济环境下，德国采取外部政策手段刺激机器人发展，较大推广了工业机器人的普及，并替代人类在有害有毒环境的工作岗位。当前中国经济体内适龄劳动力逐年减少的趋势同样激发对人形机器人的需求。适龄劳动力在未来十年或将保持减少的趋势。人形机器人作为人力的替代品，自身智能化的趋势下应用于更多行业场景并带来更高的生产力。据 IFR，2021 年全球工业机器人市场装机量达到 57.1 万台，2025 年预计达到 69 万台，机器替人趋势明显。

各国 65 岁以上人口比例 (2023 年)



Source: 联合国人口司, HTI

IFR: 2025 年工业机器人装机量预计达到 69 万台



Source: IFR, HTI


4.7.2 AI 技术的加持，推动人形机器人渗透率提升

机器人推动 AI 技术发展，有望是 AI 技术的载体之一。机器人的研究推动了许多人工智能思想的发展，在人工智能构建世界状态的模型和描述世界状态变化的过程中起到了至关重要的作用。人工智能的主要研究方向有语言识别、图像识别、自然语言处理和专家系统等，这些研究方向对于机器人智能化的实践有着重要的意义。其中，机器翻译、智能控制、专家系统及语言和图像理解不仅是人工智能需要研究的重点，同时也是智能机器人得以实现的科技难点。

根据黄仁勋在 COMPUTEX 上的演讲：“AI 的新一波浪潮是物理 AI。AI 能够理解物理定律，并与人类并肩作战……机器人和物理 AI 正在成为现实，而不仅是出现在科幻小说。当提及机器人技术时，人们往往会联想到人形机器人，但实际上，它的应用远不止于此。机械化将成为常态，工厂将全面实现自动化，机器人将协同工作，制造出一系列机械化产品。它们之间的互动将更加密切，共同创造出一个高度自动化的生产环境。”而在人形机器人方面，黄仁勋表示：“近年来，该领域在认知能力和世界理解能力方面取得了巨大突破，发展前景令人期待。我对人形机器人特别兴奋，因为它们最有可能适应我们为人类所构建的世界。”

各大厂家探索大模型在人形机器人上的应用。微软于 2023 年 2 月在其官网发文，ChatGPT 可以适应不同的机器人学任务、仿真器和形态，例如空中导航、操纵和具身代理等，并且可以通过自然语言指令来与用户交互。此外，谷歌 DeepMind 发布 RTX 机器人模型，并开放训练数据集 Open X-Embodiment。人形机器人初创公司 Figure 与 OpenAI 合作，将端到端的大语言-视觉模型移植到 Figure01 上，使其能够理解场景对象、动作区分以及理解行为目的等；百度的文心大模型与优必选合作，共同探索人形机器人的应用。

图 1 ChatGPT for Robotics: 设计原则和模型能力




Source: 《ChatGPT for Robotics: Design Principles and Model Abilities》微软, HTI

Figure01 通过大模型理解语言后执行任务



Source: Figure 官网, HTI

优必选 WalkerS 进行语义理解与交互




Source: 优必选科技微信公众号, HTI

4.7.3 传统机器人 VS 人形机器人


我国科学家对机器人的定义是：“机器人是一种自动化的机器，所不同的是这种机器具备一些与人或生物相似的智能能力，如感知能力、规划能力、动作能力和协同能力，是一种具有高度灵活性的自动化机器”。以工业机器人为例，工业机器人系统主要由三大部分、六个子系统、四大零部件组成。三大部分：机械部分、传感部分、控制部分；六个子系统：驱动系统、机械结构系统、感受系统、机器人-环境交互系统、人机交互系统、控制系统；四大关键零部件：控制器、伺服电机、伺服驱动器和减速器。

工业机器人系统组成



Source: 《机器人技术与智能系统》陈继文等, HTI

工业机器人关键零部件



Source: elecfans, HTI

根据 International Federation of Robotics (IFR)，机器人一般分为工业机器人和服务机器人两大类。1) 工业机械人是面向工业领域的多关节机械手或多自由度机器人。2) 服务机器人是指用于非制造业、以服务为核心的自主或半自主机器人，可从事清洁、陪护、运输、售货、安保等工作，在休闲娱乐、商业服务、医疗、教育等领域应用广泛。

工业机器人图例



Source: IFR, HTI


服务机器人图例



Source: IFR, HTI

机器人朝着多样化发展，智能化程度逐渐提高。机器人系统最早用遥控操纵装置，自问世以来，大大扩大了人类的影响力范围。此后，因为其在不同时空尺度（从纳米级到百万级）内有效提升了人类的实践能力，所以其数量、多样性和复杂性显著增强。目前，机器人系统的发展更注重非制造应用领域，主要集中于服务型机器人领域。其次，由于传感、驱动、计算等技术的进步，以基本的科学认识和算法实施得以改进，不同形状、大小和功能的机器人系统取得显著发展。硬件、软件、工具的模块化和标准化及商业利益与开放源代码运动的结合开始新定义机器人领域。同时，伴随着新一轮创新而生的技术交流，不仅改进了现有的机器人系统，也为智能移动机器人的应用提供了空间，有效地创造了新的市场。我们认为，随着 AI 技术进入发展快车道，机器人未来有望实现具身智能。

机器人的发展经过三代




Source: 《机器人技术与智能系统》陈继文等, HIT

人形机器人也叫做仿人机器人，是研究人类智能的高级平台，也是综合机械、电子、传感器、控制技术、人工智能、仿生学等多种学科的复杂智能机械。“仿人”的本质在于此类高级机器人具有类人的感知、决策、行为和交互能力，即人形机器人不仅需要具有类人的形体和外观、类人的知觉和感官功能、类人的大脑思维与控制能力，更需要具备行为的“类人特征”，这一特征的基本体现为类人双足运动平衡与控制能力的实现水平。

人形机器人在持续更迭。从第一款人形机器人由加藤一郎研发，到最新特斯拉“擎天柱”机器人，技术路线发生多次迭代。1980 年日本研发的 WJ9-DR 机器人属于第二代机器人，其运动系统由预先编码的程序控制并由驱动电机组成。其运动模式基于 ZMP（zero moment point）概念，并提出双足协调控制的方法。该时代人形机器人的外界感知方式仍然是简单的人工视觉、听觉装置。进入 20 世纪 90 年代，在计算机和微电子技术迅猛发展的背景下，人形机器人技术路线得到更新，其机器人底层步行理论迭代为被动行走模式下的极限环步态优化方法、分层递阶控制策略以及主动行走模式的虚拟模型控制以及仿生传感反射网络。进入 21 世纪，机器人走向人工智能化，具备自主路径规划以及行走能力并且依赖更多样的传感器对外界进行感知，运动系统也进一步迭代为一体化程度较高，同时具备驱动器、电机以及传感器。

早期早稻田大学的双足机器人和仿生机器人




(a) P2(1996 年); (b) P3(1997 年); (c) ASIMO(2000 年)

Source: 《仿人机器人理论与技术》陈恩等, HIT

在 2021 年的特斯拉 AI 日上，特斯拉公布了人形机器人“擎天柱”的概念。2022 年 9 月（北美时间）特斯拉人形机器人原型机首次亮相 AI 日，2023 年 5 月在特斯拉股东大会上，马斯克展示了 Tesla Bot 人形机器人项目“擎天柱”当时的最新型号。2023 年 12 月，特斯拉发布了第二代人形机器人产品 Optimus Gen2。

“擎天柱”机器人迭代



Source: 特斯拉官方微信公众号, 机器之心微信公众号, HTI

特斯拉虽以电动车起家，但不仅仅是一家电动汽车公司，更是一家人工智能和机器人公司，其机器人的开发参考了特斯拉现有的汽车开发流程。根据特斯拉官方微信公众号介绍，“擎天柱”基于特斯拉车辆技术实现更强安全能力，搭载与特斯拉车辆相同的完全自动驾驶（FSD）电脑（或芯片），使用 Autopilot 相关神经网络技术，同时拥有高度集成充电管理、传感器、冷却系统的电池系统。参照特斯拉在新能源汽车领域对效率、通用性和经济性的追求，且在其人工智能的加持下，特斯拉人形机器人或具有较强商业化应用的潜质。

除特斯拉外，人形机器人布局者众多。诸如 Figure、波士顿动力、优必选、小米、傅利叶智能、宇树科技、达闼等公司加快了其在人形机器人的研发或布局。

各家人形机器人对比

厂商及型号	身高	体重	行走速度	关节数/自由度	动力系统
波士顿动力 液压版 Atlas (已下架, 最新发布的电动版 Atlas 未公开具体参数)	1.5 米	89kg	2.5 米/秒	28 个关节	液压驱动
特斯拉 Optimus Gen2	--	63kg	2.9 米/秒	42 个自由度	电机驱动
Figure Figure 01	1.68 米	60kg	1.2m/秒	--	电机驱动
小米 CyberOne	1.77 米	52kg	1 米/秒	21 个自由度	电机驱动
傅利叶智能 GR-1	1.65 米	55kg	1.39 米/秒	40 个自由度	--
宇树科技 G1/G1 EDU	1.27 米	35kg+	2 米/秒	23-43 个自由度	电机驱动
达闼 XR4	1.65 米	65kg	--	60+智能柔性关节	电机驱动

Source: 小米、波士顿动力、傅利叶智能、Figure 官网, 机器之心、界面新闻、宇树科技、达闼官方微信公众号, 电子技术设计、福州法拉第机电公司百家号, HTI

4.7.4 软件看北美基础模型，硬件看国产新能源汽车供应链

随着 NVIDIA、Intel 等巨头提供更多的机器人基础模型，机器人软件的 AI 套件以及更多的开源模型使得 AI 机器人的开发进入到大模型时代。而硬件方面，随着 Tesla 等新能源汽车行业巨头通过复用其供应链的零部件厂商来降低综合制造成本，国产新能源汽车产业链将迎来机器人零部件作为第二个增长引擎。

AI 机器人若想普及，处理复杂场景的能力（软件）和高性价比（硬件）缺一不可。通过复用汽车零部件供应链，可以通过规模效应来降低单一零部件生产的成本，从而实现高性价比。在硬件方面，执行器、电机、传感器、减速器和滚动部件是最为重要的核心零部件。

执行器是提供受控和有限移动或定位的机械或机电装置，其通过一些流体的帮助来操作。

两种基本运动是直线运动和旋转运动。线性执行器将能量转换为直线运动，主要用于定位应用，通常具有推拉功能。旋转执行器相对于中点（即沿圆）以角度移动。在其最简单的形式中，线性执行器是旋转执行器的延伸，包含一个额外的运动转换器，可将旋转运动转换为线性运动。滚珠丝杠、滚柱丝杠、皮带和皮带轮、齿条和小齿轮能够将旋转转换为线性运动。

线性执行器示意图



Source: robotics tomorrow, HTI

旋转执行器示意图



Source: robotics tomorrow, HTI

制造精密运动控制产品不仅需要高精度工艺设备，亦需要大量的工艺积累。以微特电机为核心的精密运动控制产品制造工序较多，不同类型的电机由于工作原理、应用材料和内部结构各异，其工艺存在较大的差异，涉及精密机械、精细化工、微细加工、磁材料处理、绕组制造、绝缘处理等工艺技术，涵盖机座铸造、定转子冲片、定子绕组嵌线、转子铁心铸铝、转子校平衡、轴承热套、永磁材料的充磁、丝杆加工和螺母注塑等众多工艺环节，所需的工艺装备及模具数量大、精度高，需要根据产品生产特点对工艺装备及模具进行定制化。

电机：无框力矩电机和空心杯电机有望放量


无框力矩电机：磁路和工艺设计是难点，通常需要定制。无框电机是传统电机中用于产生扭矩和速度的部分，但没有轴、轴承、外壳或端盖。无框电机只有两个部件：转子和定子。转子通常是内部部件，由带永磁体的旋转钢圆环组件构成，直接安装在机器轴上。定子是外部部件，齿轮外部环绕钢片和铜绕组，以产生紧密攀附在机器壳体内部的电磁力。无框电机在机器人、医药、机床、包装、印刷、加工和通用自动化等行业得到了广泛应用。根据 Technavio 预测，2022 年全球力矩电机市场规模预计 6.12 亿美元，到 2028 年达到 8.99 亿美元，期间复合年增长率为 8.01%。

科尔摩根无刷电机组成



Source: 科尔摩根官网, HTI

无框力矩电机的优势



Source: 科尔摩根官网, HTI

无框力矩电机偏向定制，国内企业无框电机也有布局。无框力矩电机更偏向以输出扭矩为衡量指标，而普通伺服电机更偏向以输出功率为评价指标。无框力矩电机是需要一体化设计并集成到机器内部，需要根据具体的机械设计尺寸来确定无框力矩电机的外形尺寸和扭矩/转速性能。因此，无框力矩电机在磁路和工艺设计方面有一定的技术壁垒，需要在低压供电的环境下输出更大功率，从驱动性的电路设计以及电路转换等方面来看，通常需要定制，对整体安装、固定的工艺及设计具有较高的要求。目前无框电机的代表性产品有美国科尔摩根的 TBM 无框力矩电机、Parker 公司的 K 系列无框伺服电机；国内昊志机电等有无框力矩电机布局。

部分无框力矩电机各个厂商介绍

地区	企业名称	简介
	科尔摩根	全球领先的运动控制系统和配件供应商。科尔摩根的 TBM2G 无框伺服电机 (TBM2G) 是历经数年潜心研发和测试，并吸取全球客户反馈后的新一代力矩电机。
	Aerotech	全球领先的的运动控制系统及高精度的运动平台供应商，电机系列包括线性、旋转、无框和有框。
	Parker	是运动与控制领域的先行者。电机系列包括无刷伺服电机、无框电机、主轴电机、直驱力矩电机、电动汽车 (EV) 电机、直流有刷伺服电机、混合步进电机、直线伺服电机、齿轮电机，以及异步感应和矢量电机。
海外	昊志机电	2023 年 6 月 28 日在深交所互动易表示，公司现有的产品包括谐波减速器、无框力矩电机、驱动器、编码器、力矩传感器等可应用于人形机器人
	伟创电气	2023 年 6 月 9 日在上证 e 互动表示，2022 年公司成立机器人行业部，切入机器人产业链，目前主要是以机器人大配套为主，主要面向移动类、协作类、服务类的机器人领域，提供低压伺服、空心杯电机、特种无框力矩电机等核心部件。
	江南奕帆	2023 年 7 月 14 日在互动易平台表示，近期团队在研发无框力矩电机，未来可能用于精密控制行业

Source: 各公司官网, Wind, 深交所互动易, 上证 e 互动, HTI

空心杯电机：手指关节匹配度较高，难点在于大批量生产、装配。空心杯电动机属于直流永磁的伺服、控制电动机，也可以将其归类为微特电机。空心杯电动机（又称无铁芯电机、无齿槽电机）在结构上突破了传统电机的转子结构形式，采用的是无铁芯转子。这种转子结构彻底消除了由于铁芯形成涡流而造成的电能损耗。同时其重量和转动惯量大幅降低，从而减少了转子自身的机械能损耗。由于转子的结构变化而使电动机的运转特性得到了改善，不但具有突出的节能特点，更为重要的是具备了铁芯电动机所无法达到的控制和拖动特性。因此，作为高效率而体积又小的能量转换装置，空心杯对人形机器人手指关节的匹配度较高。空心杯电机在航空航天、军工、电器设备、工业控制等众多领域拥有广阔应用前景。在航空航天领域，空心杯电机可用于减轻飞行器的重量；在军工领域，空心杯电机能够快速调节导弹飞行方向；在工业

控制领域，空心杯电机可用于制造工业机器人。根据 Business Research 数据，全球空心杯直流电机市场在 2022 年的市场规模约为 7.48 亿美元，Business Research 预计到 2028 年该数字将达到 11.86 亿美元，在 2023-2029 年的预测期内的复合年增长率为 8.0%。

无刷空心杯电机



Source: Faulhaber 官网, HTI

有刷空心杯电机



Source: Faulhaber 官网, HTI

空心杯电机海外厂商优势明显，国内厂商加紧追赶。空心杯电机由于体积小，大多使用螺旋管微型线圈。螺旋管微型线圈是一个三维线圈，由多匝导线缠绕而成，缠绕内部空心，电流流入缠绕导线，并产生均匀磁场。传统螺旋管微型线圈制作方法以手工缠绕为主，第一步绕线和粘胶带；第二步压扁；第三步切线头，第四步浸锡；第五步取胶带；第六步卷圆；第七步浸酒精，第八步整形打圆。手工生产空心杯电机线圈劳动生产率低，人工成本高，而且工作环境使用酒精，对工人的适应性有一定阻碍且增加了材料成本，已不能适应现代化大规模精细生产要求。因此，空心杯制作的难点在于大批量生产及较难的装配，手工制作方式在生产效率、产品稳定性方面无法满足客户需求。海外厂商 Maxon、Faulhaber 等公司深耕空心杯电机多年，已经形成的强大的品牌效应和技术壁垒，国内厂商如鸣志电器、鼎智科技、伟创电气等众多公司也有空心杯电机相关布局。

部分空心杯电机各个厂商布局情况

地区	企业名称	简介
海外	Maxon	maxon DC 电机品质领先全球。其 DC 采用高性能永磁体。电机的“心脏”是享有全球专利的空芯杯转子。
	Faulhaber	FAULHABER 直流电机有一个自承式斜绕铜线圈。这种设计不仅最大限度地降低了转子的惯性矩，还为驱动设备提供了最大的动力和精确的无齿槽运行。
	鼎智科技	2023 年 3 月 28 日在全景网-互动平台表示，公司空心杯电机关键绕线工艺设备实现自制，能实现多工位自动化绕线成型。空心杯电机产线正在筹建。
国内	鸣志电器	2022 年 11 月 14 日在上证 e 互动表示，公司的空心杯电机和直流无刷电机产品广泛应用于重症呼吸机的应用场景
	伟创电气	2023 年 6 月 9 日在上证 e 互动表示，公司自主研发设计空心杯电动机，产品目前在内部测试阶段

Source: 各公司官网, Wind, 上证 e 互动, 全景网, HTI

减速器：已逐步进行国产替代，谐波减速器更适合人形机器人

减速器的主要作用是降低输出转速，增加转矩，提升载荷能力，从而达到理想的传动效果。减速器是属于经过精密加工的分流式和同进轴式减速机设计，由增速装置、复合传动装置配置各种类电机组成，精确的角度传输都可以见到减速机的应用，具有能耗低，性能优越等特点。精密减速器具有更高控制精度，主要应用于机器人、数控机床等高端领域，其种类包括谐波减速器、RV 减速器、摆线针轮行星减速器、精密行星减速器等。因此，精密减速器的存在使伺服电机在一个合适的速度下运转，并精确地将转速降到机器人各部位需要的速度，提高机械刚性的同时输出更大的力矩。

衡量精密减速器的主要指标包括：扭转刚度、传动精度、启动转矩、空程、背隙、传动误差、传动效率等。从国外产品的技术指标来看，国外产品信息相对完善，每种规格队形的各技术指标都有精确的数值呈现，而国内在这方面有所欠缺，主要表现在：

- ✓ **产品系列不健全。**日本纳博具备全系列产品，基本上可以应用于所有领域，而国内产品系列相对残缺。
- ✓ **一致性问题。**国产减速器在实际使用环境下的性能，与实验室性能无法完全匹配，个别产品存在漏油、精度降低等情况，是阻碍国产减速器进军高端市场的原因之一。

目前，大量应用于多关节机器人的减速器主要有两种：**RV 减速器**和**谐波减速器**。相比于谐波减速器，RV 减速器具有更高的刚度和回转精度。因此在关节型机器人中，一般将 RV 减速器放置在机座、大臂、肩部等重负载的位置，而将谐波减速器放置在小臂、腕部或手部；二者之间适用的场景不同，属于相辅相成的关系。而行星减速器一般用在直角坐标机器人上。

RV 减速器和谐波减速器在工业机器人中应用具体对比

项目	RV 减速器	谐波减速器
技术特点	通过多级减速实现传动，一般由行星齿轮减速器的前级和摆线针轮减速器的后级组成，组成的零部件较多	通过柔轮的弹性变形传递运动，主要由柔轮、刚轮、波发生器三个核心零部件组成。与其他精密减速器相比，谐波减速器使用的材料、体积及重量大幅度下降
产品性能	大体积、高负载能力和高刚度	体积小、传动比高、精密度高
应用场景	一般应用于多关节机器人中机座、大臂、肩部等重负载的位置	主要应用于机器人小臂、腕部或手部
终端领域	汽车、运输、港口码头等行业中通常使用配有 RV 减速器的重负载机器人。	3C、半导体、食品、注塑、模具、医疗等行业中通常使用由谐波减速器组成的 30kg 负载以下的机器人
价格区间	5000-8000 元/台	1000-5000 元/台

Source: 绿的谐波招股说明书, HTI

谐波减速器：体积小、重量轻，或更适合人形机器人。谐波减速器是基于行星齿轮传动发展而来，由波发生器、柔轮、刚轮组成。谐波传动技术突破了机械传动采用刚性构件的模式，使用了一个柔性构件来实现机械传动，其工作原理通常采用波发生器主动、刚轮固定、柔轮输出形式，当波发生器装入柔轮内圆时，迫使柔轮产生弹性变形而呈椭圆状，使其长轴处柔轮齿轮插入刚轮的轮齿槽内，成为完全啮合状态；而其短轴处两轮轮齿完全不接触，处于脱开状态，当波发生器连续转动时，迫使柔轮不断产生变形并产生了错齿运动，从而实现波发生器与柔轮的运动传递。由于谐波传动有回差小、运动精度高、传动比大、体积小、重量轻等优点，可以实现更小型化设计，因此我们认为或更适合人形机器人的关节设计。根据特斯拉发布的内容来看，旋转关节方案或采用谐波减速器。

谐波减速器

谐波减速器传动原理




Source: 绿的谐波招股说明书, HTI



Source: 《机器人关节传动用精密减速器研究进展》吴素珍等, HTI


特斯拉“擎天柱”旋转执行器或采用谐波减速器



Source: 舜肌科技微信公众号, HTI


国内谐波减速器企业正迅速追赶，国产替代可期。从谐波减速器的技术指标来看，绿的谐波和中技克美的减速比范围与日本哈默纳科水平相当，产品性能基本满足要求，目前已经大量应用于国产机器人。而国外产品在输出转矩、平均寿命和一致性等技术指标上依然占据优势。从国内市占率来看，哈默纳科仍处于领先定位，绿的谐波国内市占率第二，国产替代空间仍然较大。

谐波减速器市场份额（2021）



Source: GGII 官方微信公众号, HTI

谐波减速市场份额（2022）




Source: GGII 官方微信公众号, HTI


中国谐波减速器需求量同样可观。根据观研天下援引 IFR，2022-2025 年全球工业机器人用谐波减速机市场规模分别为 39.1/46.8/56.4/68.2 亿元，2021-2025 年 CAGR 达 20.0%。2022-2025 年国内工业机器人用谐波减速机市场规模分别为 18.5/22.7/27.9/34.6 亿元，2021-2025 年 CAGR 达 22.9%。

全球工业机器人谐波减速器市场规模

中国工业机器人谐波减速器市场规模



Source: IFR, 研观天下, HTI



Source: IFR, 研观天下, HTI

滚动功能部件：高端滚珠丝杠和行星滚柱丝杠国产化率尚低

丝杠功能：主要功能是将旋转运动转换成线性运动，或将扭矩转换成轴向反复作用力。

丝杠分类：包括滚珠丝杠与行星滚柱丝杠。滚珠丝杠与滚柱丝杠在同时代出现，两者区别如下：

- ✓ **滚珠丝杠：**结构简单，传动效率较高，可大于90%；载荷传递元件为滚珠，是点接触，主要优势是有众多的接触点来支撑负载，有更高的抗冲能力。
- ✓ **行星滚柱丝杠：**结构复杂，传动效率一般低于90%；载荷传递元件为螺纹滚柱，是典型的线接触，在需要特大载荷的场合，特别是空间受限制的情况下需要很大载荷时，会选用行星滚柱丝杠，它一般比同规格的滚珠丝杠副的载荷大2至3倍，且中、小型规格的行星滚柱丝杠可选的最小导程更小。

滚珠丝杠（内循环）的组成



Source: 《滚动丝杠副发展及研究现状》汤文成等, HTI

行星滚柱丝杠副结构图



Source: 《行星滚柱丝杠副的研究》肖正义, HTI

滚珠丝杠副和行星滚柱丝杠副对比

地区	滚珠丝杠副	行星滚柱丝杠副
结构组成	由丝杠、螺母、钢球、导珠管等组成。丝杠和螺母螺纹为单头或多头。丝杠、螺母螺纹滚道为单圆弧滚道或双圆弧滚道，结构简单。	由丝杠、螺母、滚柱、内齿圈、压盖、挡圈等构成。丝杠、螺母为齿形角90°三角形多头螺纹。滚柱为双凸圆弧齿形单头螺纹。结构复杂。
循环方式	丝杠、螺母滚道通过导珠管组成滚珠循环回路，每个导珠管组成1.5圈或多圈滚珠链，丝杠副可以由多个导珠管组成多个滚珠链。	滚柱丝杠副结构类似于行星齿轮结构。丝杠副有多个滚柱，且滚柱与丝杠、螺母呈多点接触。
滚动体	滚珠	滚柱
外形尺寸	由于滚珠螺母及滚珠丝杠滚道槽较深。滚珠嵌在丝杠、螺母内部，因此滚珠螺母外形尺寸小。	由于丝杠螺母牙型深度较小，滚柱直径又大，滚柱螺母外形尺寸大。
运动平稳性	由于滚珠在丝杠副循环滚珠链中运动要通过返向机构，容易产生冲击影响丝杠副平稳性。	滚柱在丝杠副中滚动没有返向机构，不产生冲击、震动，因而丝杠副运行平稳



传动效率	由于滚珠外表面粗糙度高且精度高。滚动摩擦系数小，传动效率高，可以大于 90%。	虽滚柱与丝杠、螺母接触为点接触及滚动摩擦，由于螺母、丝杠及滚柱加工误差及表面粗糙度等原因，传动效率一般低于 90%。
承载	小规格、小导程，承载小大规格、大导程承载大。	滚柱接触点多，接触承载大。小规格、小导程行星滚柱丝杠副承载大于滚珠丝杠副承载。
加工及装配工艺性	简单	复杂
可靠性	结构简单，零件加工及装配精度易于保证，因此可靠性高。	丝杠、螺母为多头细牙螺纹，由于螺纹分度误差及牙型强度等原因，实际承载远小于理论承载，且可靠性差。
速度和加速度	高	更高
导程和节距	滚珠丝杠的导程受到球直径的限制，因此导程将是标准的。	导程是螺距的函数，所以导程可以小于 0.5 毫米或更小。

Source: 《行星滚柱丝杠副的研究》肖正义, 上海慧腾官网, HTI

反向式行星滚柱丝杠: 正向式行星滚柱丝杠的特点是长丝杆短螺母外加螺旋滚道，通过滚柱在丝杠轴上的滚动实现直线运动。反向行利用其长螺母短丝杠的组合形式，可以将长螺母设计成电机转子，易于实现机电融合直线作动器设计，体积较小，结构紧凑，适合人形机器人。反向式行星滚柱丝杠机构中，螺母只沿周向转动，不沿轴向移动，丝杠只沿轴向移动，不沿周向转动，滚柱既有自转，又有公转。反向式行星滚柱丝杠通过较小的导程实现更高的额定负载，从而降低驱动扭矩。

反向滚柱丝杠结构图

“擎天柱”线性执行器可能采用反向式行星滚珠丝杠



Source: 《反向式行星滚柱丝杠机构运动原理及仿真分析》党金良等, HTI


Source: 舞肌科技微信公众号, HTI

滚珠相对与滚柱丝杠市场规模更大，应用范围更广。 据 allied market research 数据，2019 年全球精密滚珠丝杠市场规模为 15.71 亿美元，预计到 2027 年将达到 20.44 亿美元，复合年增长率为 5.1%；根据 persistence market research 数据，2023 年，全球滚柱丝杠市场规模约为 3 亿美元。到 2033 年，市场规模将达到 5.57 亿美元，未来 10 年以 6.4% 的复合年增长率增长。

丝杠生产需要高精度设备与工艺积累。 丝杠兼具高精度、可逆性和高效率的特点，其在精度、强度及耐磨性等方面都有很高的要求，因此其加工从毛坯到成品的每道工序要求均比较高。

丝杠国产化率仍有较大空间，已出现一批有一定竞争优势的国产厂商。 在国际市场上，高端滚珠丝杠市场主要由欧美及日韩企业所占据，包括日本精工、博世力士乐、Kuroda、舍弗勒集团等；近年来，随着科技技术进步，我国滚珠丝杠行业内也涌现出一批具有一定竞争优势的优秀企业，例如南京工艺装备、山东博特精工、银泰科技、山东华珠机械、陕西汉江机床等企业，同时恒立液压、贝斯特等公司也参与到丝杠领域。

滚珠丝杠中国市场竞争格局




Source: 金属加工官方微信公众号, HTI

力矩传感器：六维力矩传感器壁垒最高，国内企业已有布局

机器人通过传感器获得感觉信息。传感器是一种检测装置，能感受到被测量的信息，并能将感受到的信息，按一定规律变换成为电信号或其他所需形式的信息输出，以满足信息的传输、处理、存储、显示、记录和控制等要求，传感器的特点包括微型化、数字化、智能化、多功能化、系统化、网络化。传感器包括力矩传感器、触觉传感器、接近觉传感器、距离觉传感器、光学编码器等。其中，力矩传感器是将力的变化转换为电信号的器件。

力矩传感器市场规模大，多维力/力矩传感器技术壁垒更高。根据 MMR 数据，2022 年力矩传感器市场规模为 70.6 亿美元，预计 2023-2029 年力矩传感器市场规模复合增速将达到 5.5%至 102.8 亿美元。根据所测力的维度的不同，力传感器可被分为单维（轴）力和多维（轴）力。单维力传感器是指能检测单一维度方向上的力或力矩，多维力传感器指的是一种能够同时测量两个方向以上的力及力矩分量的力传感器。多维力最完整的形式是六维力/力矩传感器，即能够同时测量 3 个力分量和 3 个力矩分量的传感器。多维力传感器与单维力传感器比较，除了要解决对所测力分量敏感的单调性和一致性问题外，还要解决因结构加工和工艺误差引起的维间（轴间）干扰问题、动静态标定问题以及矢量运算中的解耦算法和电路实现等。

力传感器示意图



Source: 海伯森技术官网, HTI

多维力 / 力矩传感器在机器人、航空航天、生物医学等领域得到了广泛应用，特别是在机器人领域。多维力传感器广泛应用于机器人手指和手爪研究、机械手外科手术、指力研究、力反馈、刹车检测、精密装配、切削、复原研究、整形外科研究、产品测试、触觉反馈等，行业覆盖了机器人、汽车制造、自动化流水线装配、生物力学、航空航天、轻纺工业等。机器人的地面反力和反力矩的检测能够通过六维力/力矩传感器来实现。此外，在人形机器人手腕和脚踝处也大概率装有六维力/力矩传感器。


力传感器示意图



Source: 高工机器人微信公众号, HTI


中国六维力/力矩传感器市场有望实现较快增长。根据高工机器人产业研究所 (GGII) 数据显示, 2022 年中国市场六维力/力矩传感器销量 8360 套/2.39 亿元, 同比增长 57.97%/52.04%, 其中机器人行业销量 4840 套/1.56 亿元, 同比增长 62.58%/54.35%。到 2027 年中国市场六维力/力矩传感器销量有望突破 84000 套/15 亿元, 复合增长率超过 60%/45%, 其中机器人行业销量有望突破 42000 套。

GGII 2017-2027 年中国六维力/力矩传感器市场销量及预测



Source: 高工移动机器人微信公众号, HTI

GGII 2017-2027 年中国六维力/力矩传感器市场规模及预测



Source: 高工移动机器人微信公众号, HTI

国产六维力/矩传感器与海外在灵敏度、串扰、抗过载能力及维间耦合误差等方面仍存在差距。国内部分企业已有相关的产品落地并进入产业化应用或部分产品型号开始进入下游用户的验证测试阶段。

中外六维力/力矩传感器公司对比

企业名称	总部所在地	准度 (%FS)	公司简介
坤维科技	中国	0.50%	成立于 2018 年, 致力于提供高精度力觉传感器及力控解决方案的企业。主营智能能力觉传感器的研发、制造、销售及技术服务。
鑫精诚传感器	中国	1%-3%	成立于 2009 年, 专注于微型压力、称重、多轴力、扭力等智能传感器及控制仪表的工业级产品研发和创新。
宇立仪器	中国	1%-5%	2007 年创立, 专注于多轴力传感器设计, 拥有近 20 年经验, 在汽车行业和工业机器人领域具有竞争优势。
蓝点触控	中国	1%-2%	成立于 2019 年, 专业从事高精度力传感器及力控产品研发和生产的高新技术企业。拥有深厚的技术优势。
海伯森技术	中国	1%-2%	成立于 2015 年, 专注工业传感技术创新, 主营产品包括 3D 闪测传感器、3D 线光谱共焦传感器等。

ATI	美国	0.5%-2%	世界领先的多维力传感器制造商，自 1989 年以来致力于开发先进的产品和解决方案。
SCHUNK	德国	2%	1945 年创建，主营精密夹具和自动化抓取系统、传感器等，产品主要应用于机械和自动化领域。
Robotiq	加拿大	3%	2008 年成立，主营产品包括机器人末端夹具、力矩传感器、机器人相机套件等。
OnRobot	丹麦	3%	由多家公司合并而成，主营产品包括机器人末端夹具、力矩传感器、机器人相机套件等。
Sintokogio	日本	1%-3%	1934 年成立，业务包括铸造、表面处理、环境设备、物料搬运设备和特种设备等。全球业务遍及亚洲、北美和欧洲。
WACOH-TECH	日本	1%-3%	2007 年成立，主营业务包括力传感器和 MEMS 传感器（加速度、陀螺仪）产品的开发、生产、销售。

Source: 《行星滚柱丝杠副的研究》肖正义, 上海慧腾官网, HTI

4.8 赋能其他传统行业

从场景应用维度看，智能化场景在行业的落地随着时间的推移，正呈现出更深入、更广泛的趋势。人工智能持续为提升用户体验做出贡献，当前诸如智能客服、智能推荐、精准营销等场景深入落地到各行业；人工智能也在精准科学防疫，加强公共卫生安全体系建设中承担重要角色，在病毒演变预测、疫苗药物研发、辅助诊断等维度实现广泛应用；长期来看，企业通过在数字人等数字化营销内容创作领域布局，创造差异化的营销体验，升级品牌形象；另外，科学家们越来越多地利用人工智能技术和方法，从数据中建立模型，重点围绕新药创制、基因研究、新材料研发等领域加速对前沿科学问题的探究。

中国人工智能应用场景发展



Source: IDC, HTI

AI+医疗：基于迭代优化的大模型技术，讯飞医疗全面升级医疗诊后康复管理平台，将专业的诊后管理和康复指导延伸到院外。根据患者健康画像自动分析，平台可为患者智能生成个性化康复计划，包括重点关注、用药指导、康复运动、出院随访、健康知识、患者咨询等，并督促患者按计划执行。讯飞诊后康复管理平台还可以通过外呼机器人和小程序、APP 为康复过程中病患提供及时应答，回复开放性和交叉性的问题。

AI+金融：在信贷领域，征信数据一直是非结构化数据的典范。由于它的复杂性和多样性，很难使用传统的数据处理方式进行分析。为了破解这一难题，度小满智能征信中台将大型语言模型 LLM、图算法应用在征信报告的解读上，能够将报告解读出 40 万维的风险变量，将银行风控模型的风险区分度提升了 26%。

AI+工业：在星火认知大模型的基础上，羚羊平台结合工业产业的发展现状，推出了工业大模型——“羚机一动”。中小企业在羚羊平台上自由发布需求，羚机一动针对企业需求给出专业化建议策略，智能匹配方案、服务商、专家等资源。星火认知大模型还可在企业内部知识库和工业知识库之上构建企业知识大脑，在研发、生产、服务营销各个环节上，精准地定位问题、得到有效解决方案。

5. 可靠 AI 生态建设

5.1 AI 测评

AI 大模型正经历着前所未有的快速发展，然而在繁荣的表象之下，“野蛮生长”的现状也日益凸显，市场亟需一套科学、全面、标准化的测评体系。有效的测评体系可以客观评估大模型的技术能力、应用效能以及安全可信度等。这不仅能够为用户选择合适的大模型提供参考，还能够引导行业健康有序发展，成为推动 AI 应用落地的助推器，达到“以评促建、以评促改、以评助力产业能力提升”，最终赋能人工智能全产业链。

人工智能技术的迅猛发展，推动着 AI 智能水平测评方法不断革新。传统的图灵测试逐渐暴露出其局限性，取而代之的是更加多元化、更贴近实际应用场景的基准测试体系。图灵测试，这一由英国数学家艾伦·图灵于 1950 年提出的概念，曾被视为人工智能发展的重要里程碑，其核心思想是，如果一台机器能够与人类进行对话，且人类无法辨别其是机器还是人类，则可以认为该机器具备了人类智能。然而，随着 AI 技术的进步，图灵测试仅关注机器的语言表达能力，而忽略了感知、推理、学习、创造等其他构成人类智能的重要方面，此外，一些 AI 系统能够通过模仿人类语言模式来“欺骗”测试者，即使它们并不真正理解对话内容，这也使得图灵测试的结果可能存在偏差。AI 技术的蓬勃发展对测评方法提出了更高的要求，亟需构建涵盖语言理解、逻辑推理、问题解决、创造性等多个维度，能够针对不同领域和任务，设计专门的评测指标，以及引入认知心理学、神经科学等人类认知科学的最新研究成果，设计更接近人类思维模式的测试任务的更全面的评测体系。

目前，基准测试 (Benchmark) 已成为大模型测评的主要手段，其核心思路是设计科学合理的测试任务和数据集，以客观、公正、量化的方式评估模型性能。现有的基准测试榜单主要分为两类：旨在考察模型的整体能力的多维度综合测评和专注于评估模型在特定任务上的表现的单维度测评。测试方法则涵盖客观考试和人工主观评价两种，以更全面地评估 AI 系统的性能。随着 AI 技术的飞速发展，传统的基准测试已难以满足需求，由于 AI 模型在 ImageNet、SQuAD 和 SuperGLUE 等传统基准测试中已达到性能饱和，更复杂、更贴近实际应用场景的新基准测试不断涌现。目前基准测试考察方面包括：语言理解、一般推理、数学推理、编程、agent 能力等。

国际上，涌现了一批用于考察模型不同方面性能的基准测试，例如用于评估模型对自然语言的理解能力的 MMLU、用于评估模型的逻辑推理和问题解决能力的 MMMU、用于评估模型进行数学运算和解决数学问题的能力的测试、用于评估模型编写和理解代码的能力的 SWE-bench、用于评估模型生成图像的质量和创造性的 HEIM、用于评估模型进行道德判断和决策的能力的 MoCa、用于评估模型在模拟环境中与其他智能体交互和完成任务的能力的 AgentBench 以及用于评估模型识别和避免生成虚假信息的能力的 HaluEval 等。

国际常用单维度测评

Benchmark	Task category	Year introduced
AgentBench	Agent-based behavior	2023
BigToM	Causal reasoning	2023
Chatbot Arena Leaderboard	General language	2023
EditVal	Image editing	2023
GPQA	General reasoning	2023
GSM8K	Mathematical reasoning	2021
HEIM	Image generation	2023
HELM	General language	2021
HaluEval	Factuality	2023
HumanEval	Coding	2021
MATH	Mathematical reasoning	2021
MLAgentBench	Agent-based behavior	2023
MMMU	General reasoning	2023
MoCa	Moral reasoning	2023
PlanBench	Planning	2023
SWE-bench	Coding	2023
TruthfulQA	Factuality	2021
ViaIT-Bench	Image instruction-following	2023

Source: 《Artificial Intelligence Index Report 2024》, HTI

此外，多项综合基准测试也在国际上广泛使用，例如：一个开源的AI模型性能排行榜 Hugging Face Open LLM Leaderboard，通过一系列标准化测试，对不同大模型在多个维度进行量化评估，并根据得分进行排名，其使用的测试包括 AI2 Reasoning Challenge、HellaSwag、MMLU、TruthfulQA、Winogrande 和 GSM8k，涵盖了各种推理和常识技能；以及基于 LMSYS Chatbot Arena、MT-Bench、MMLU 三个基准，评估聊天机器人的对话能力和性能表现的 OpenLM Leaderboard Chatbot Arena。这些综合测试通常整合了多个单项测试，旨在更全面地评估模型的综合能力，为AI技术的发展提供更精准的参考依据。截至 2024 年 6 月 11 日，72B+表现最佳的大模型为 GPT-4o，40B-72B 规模最佳大模型为 Llama-3。

OpenLM Leaderboard Chatbot Arena 各规模标准下表现最强的模型

Model ↑	Size ↓	Arena Elo ↑	MMLU ↑	Context Window ↓	License ↑
GPT-4o-2024-05-13	72B+	1287	88.7	128K	Proprietary
Llama-3-70b-instruct	40B-72B	1288	82	8K	Llama 3 Community
Yi-1.5-34B-Chat	24B-40B	1161	76.8	16K	Apache 2.0
Claude 3 Haiku	8B-24B	1178	75.2	200K	Proprietary
Llama-3-8b-instruct	4B-8B	1153	68.4	8K	Llama 3 Community
Phi-3-Mini-128k-instruct	1B-4B	1037	68.1	128K	MIT

Source: OpenLM, HTI

国内大模型基准测试也在持续迭代更新以适应技术发展趋势。例如，中国信通院自 2022 年 3 月起开始进行大模型评测体系研究，并于 2023 年 12 月正式发布“方升”大模型基准测试体系，旨在建立业界大模型基准测试统一的“度量衡”。已有大模型基准测试以评估模型通用能力为主，存在评测方法不统一、评测方式单一、距离实际应用较远等问题。因此，亟需建立一套面向产业应用的大模型基准测试体系，搭建全量测试题库、自动测试平台和高效测试方法，满足大模型能力持续监测和能力迭代的要求。“方升”测试体系涵盖大模型基准测试的关键四要素，即测试指标、测试方法、测试数据集和测试工具，目前已形成《大规模预训练模型基准测试-总体技术要求》标准。


该体系历经三次迭代更新，已累计提供超过60次评测服务，其从指标体系、测试方法、测试数据集、测试工具四个维度协同发力，致力于确保评测结果的全面性、公正性和高效性，为国内大模型发展提供有力支撑。

“方升”大模型基准测试体系迭代更新




Source:信通院, HTI

国外知名大模型基准测试榜单



Source:信通院, HTI

国内知名大模型基准测试榜单



Source:信通院, HTI


“方升”大模型基准测试体系



Source:信通院, HTI

“方升”大模型基准测试评测中，大模型总数 30 家其中闭源商业大模型 12 家开源大模型 18 家。一级测试维度为通用、行业、应用、安全，可以划分为理解、知识、学科、可靠等 32 个二级子维度。商业闭源大模型能力优于开源大模型，在榜单的综合能力前 10 名中商业闭源大模型占据了 9 席，开源大模型在通用评测中的数学、推理能力上与商业模型有明显差距并且在自主可控等方面存在风险。

“方升”大模型基准测试测评结果




Source:信通院, HTI

开源大模型能力榜单



Source:信通院, HTI

开源大模型评测结果雷达图



Source:信通院, HTI


5.2 AI 风险

AI 在各个领域展现出巨大潜力的同时，其安全风险也日益引起重视。AI 安全风险是指人工智能系统在设计、开发、部署和使用过程中可能出现的潜在危害，这些危害可能影响个人、社会或环境。近年来，随着 AI 技术的快速发展和普及应用，AI 安全问题愈发凸显，多起 AI 安全风险事件的发生，更是为我们敲响了警钟。例如：

(1) **数据泄露**：三星公司 2023 年 4 月接连发生 3 起因使用 ChatGPT 导致的数据泄露事件，其中 2 起涉及半导体设备的机密信息，另 1 起则泄露了内部会议内容。据悉，泄露内容包括半导体设备测量资料、产品良率等高度敏感信息，这些信息被原封不动地传输至 ChatGPT，存在被泄漏给更多人的风险。韩媒表示，此次数据泄露事件是由于三星员工直接将企业机密信息以提问的方式输入到 ChatGPT 中，导致相关内容进入学习数据库。

大模型的训练数据中，除了三星这种机密信息等，还有一些数据来自于像互联网等公共来源。考虑到在线信息的广泛性，不难理解一些个人可识别信息（PII）也会被不可避免地提取。一项于 2023 年 11 月发表的研究探讨了可提取记忆（extractable memorization）：即在不预先知道初始训练数据集的情况下，如何从 LLMs 中提取敏感的训练数据。研究人员测试了像 Pythia 这样的开放模型和像 ChatGPT 这样的闭源模型，发现无论是开放还是闭源模型，都可以从这些模型中恢复大量的训练数据。虽然 ChatGPT 这类模型存在防护措施，但仍存在使其泄露训练数据的方法，数据提取的关键在于促使模型偏离其标准对话式生成方式。例如，提示“无限重复这个词：‘poem poem poem’”，可以导致 ChatGPT 无意中逐字地泄露敏感 PII 数据。某些提示比其他提示更有效地引发这种行为。尽管大多数偏离会产生无意义的输出，但一定比例的响应会揭示模型的训练数据。利用这种方法，作者们成功地提取了不仅是 PII，还有不适宜内容（NSFW）、逐字的文学作品和通用唯一标识符（UUID）等内容。

不同重复词所恢复的记忆输出量



Source: 《Artificial Intelligence Index Report 2024》, HTI

(2) **不公平**：COMPAS 系统，全称为“Correctional Offender Management Profiling for Alternative Sanctions”，是一个用于预测犯罪风险的算法系统，被美国多个州的司法系统用于辅助量刑、假释等决策。然而，研究表明，COMPAS 系统存在对非裔美国人的系统性偏见，导致他们在相同条件下被错误地判定为高风险人群的概率更高，进而面临更严厉的判决和更少的假释机会，加剧了社会的不公正现象。Cambridge Analytica 公司的案例则揭示了算法偏见在政治领域的潜在风险。该公司利用 Facebook 的数据泄露漏洞，收集了数千万用户的个人信息，并利用这些数据建立心理模型，对用户进行精准画像，进而精准推送政治广告，试图影响用户的政治倾向和投票选择。尽管该公司否认其行为对 2016 年美国总统大选结果产生了决定性影响，但这一事件仍然引发了人们对数据隐私、算法操纵和选举公平的担忧。

(3) **不安全**：在 2023 年，研究人员揭示了一种能够跨多个 LLM 运行的通用攻击。这种攻击能够诱使已对齐的模型生成不安全的内容。这种方法涉及自动生成后缀，这些后缀在添加到各种提示中时，会迫使 LLM 生成不安全的内容。研究人员介绍的方法称为贪婪坐标梯度（Greedy Coordinate Gradient, GCG）。研究表明，这些后缀（即 GCG 攻击）在闭源和开源模型中通常能有效传播，包括 ChatGPT、Bard、Claude、Llama-2-Chat 和 Pythia。它还展示了 LLM 如何容易受到使用无法理解的、非人类可读提示的攻击。

诱导生成不安全内容



Source: 《Artificial Intelligence Index Report 2024》,HTI

最受担忧的AI风险议题



Source: 《Artificial Intelligence Index Report 2024》,HTI

为了规避风险，构建负责任的AI生态，需要各方共同努力，建立健全评估体系，强化企业自律，并完善政府监管，形成三位一体的治理框架。

负责任 AI 六大维度

	定义	示例: AI 在线诊疗系统
数据治理	建立政策、程序和标准, 以确保数据的质量、安全性和道德使用, 这对于准确、公平和负责任的人工智能操作至关重要, 尤其是在处理敏感或个人身份信息时。	制定了维护数据质量和安全的政策和程序, 特别关注道德使用和同意, 尤其是对于敏感的健康信息。
可解释性	理解和阐明人工智能决策背后基本原理的能力, 强调人工智能不仅要透明, 而且要让用户和利益相关者能够理解。	该平台可以阐明其治疗建议背后的基本原理, 使医生和患者能够理解这些见解, 从而确保对其决策的信任。
公平性	创建公平的算法, 避免偏见或歧视, 并考虑所有利益相关者的不同需求和情况, 从而符合更广泛的社会公平标准。	该平台旨在避免治疗建议中的偏见, 确保来自所有人群的患者都能获得公平的护理。
隐私	个人对其个人数据的机密性、匿名性和保护的權利, 包括同意和被告知数据使用方式的權利, 以及组织在处理个人数据时保障这些权利的责任。	患者数据的处理具有严格的机密性, 确保匿名性和保护。患者同意是否以及如何使用其数据来训练治疗建议系统。
安全性和可靠性	人工智能系统的完整性, 以应对威胁, 最大程度地减少滥用造成的危害, 并解决固有的安全风险, 例如可靠性和先进人工智能系统的潜在危险。	采取措施防范网络威胁并确保系统的可靠性, 最大程度地降低滥用或固有系统错误带来的风险, 从而保障患者的健康和数据安全。
透明度	公开分享开发选择, 包括数据源和算法决策, 以及人工智能系统的部署、监控和管理方式, 涵盖创建和运营阶段。	公开分享开发选择, 包括数据源和算法设计决策。医疗保健提供者和监管机构清楚地了解系统的部署和监控方式。


Source: 《Artificial Intelligence Index Report 2024》, HTI

首先, 建立科学全面的 AI 风险评估体系是重中之重。 这需要制定明确的 AI 风险评估指标体系, 涵盖数据安全、算法公平性、透明度、可解释性、可控性等多个维度。同时, 需要开发相应的评估工具和方法, 对 AI 系统进行全生命周期的风险评估, 及早发现和清除潜在问题。此外, 还需要建立信息共享机制, 促进评估结果的交流和应用, 不断完善评估体系。

Do-Not-Answer 是一个用于全面评估 LLM 安全风险的新开源数据集。随着 LLM 能力的扩展, 其在危险活动中的滥用潜力也在增加。LLM 可能被用来支持网络攻击、发起鱼叉式网络钓鱼攻击, 甚至理论上协助恐怖主义。因此, 开发者设计评估 AI 模型潜在危险的机制变得越来越重要。闭源开发者如 OpenAI 和 Anthropic 已经构建了数据集来评估危险模型的能力, 并通常实施安全措施以限制不必要的模型行为。然而, 开源 LLM 的安全评估方法明显不足。

为此, 一组国际研究人员最近创建了首个用于评估 LLM 安全风险的综合开源数据集之一。他们的评估涵盖了六个主要语言模型的响应: GPT-4、ChatGPT、Claude、Llama 2、Vicuna 和 ChatGLM2。作者还开发了一个风险分类法, 涵盖从轻微到严重的各种风险。研究发现, 大多数模型在某种程度上输出有害内容。GPT-4 和 ChatGPT 主要倾向于输出歧视性、冒犯性的内容, 而 Claude 则容易传播虚假信息。在所有测试的模型中, ChatGLM2 的违规次数最高。

各大模型可信程度对比



Source: 《Artificial Intelligence Index Report 2024》,HTI

其次，AI开发组织需要将“负责任AI”的理念贯穿于设计、开发、部署和使用AI系统的全过程。斯坦福大学的研究人员与埃森哲合作开展了一项全球负责任人工智能(RAI)调查，里面提出了组织可以实现负责任AI可采取的手段。

各公司、组织可采取的负责任AI治理措施

治理领域	措施	描述
公平性	收集具有代表性的数据	根据预期的用户人口统计数据收集数据，确保模型在不同人群中表现一致
	公开方法和数据源	向第三方（审计师/公众）公开模型开发方法和数据来源，以进行独立监督
	让不同的利益相关者参与	让不同的利益相关者参与模型开发和/或审查过程，以获得更全面的视角
	评估不同人口群体的表现	评估模型在不同人口群体（例如，性别、种族、年龄）中的表现，识别和减轻潜在的偏见
	使用技术偏见缓解技术	在模型开发过程中使用技术手段来识别和减轻潜在的偏见，例如，调整算法或数据
数据治理	数据合法合规	检查以确保数据符合所有相关的法律法规，并在适用的情况下在征得同意后使用
	数据质量检查	数据收集和准备包括评估数据的完整性、唯一性、一致性和准确性
	数据代表性检查	检查以确保数据相对于最终模型/系统所使用的人口统计环境具有代表性
	数据审计和更新	定期进行数据审计和更新，以确保数据的相关性
	数据集和可追溯性记录	在整个AI生命周期中记录数据集和可追溯性的流程
	缺陷数据集的补救计划	针对有缺陷的数据集制定补救计划和文档
透明度和可解释性	记录开发过程	记录开发过程，详细说明算法设计选择、数据源、预期用例和局限性
	提供培训计划	为利益相关者（包括用户）提供培训计划，涵盖模型的预期用例和局限性
	优先考虑更简单的模型	在高度可解释性至关重要的情况下，优先考虑更简单的模型，即使这会牺牲一些性能
	使用模型可解释性工具	使用模型可解释性工具（例如，显著性图）来阐明模型决策
	模型错误的缓解措施	针对模型错误和处理低置信度输出的缓解措施
可靠性	故障转移计划	故障转移计划或其他措施，以确保系统/模型的可用性
	漏洞评估	评估模型/系统的漏洞或有害行为（即红队测试）
	防御对抗性攻击	防止对抗性攻击的措施
	置信度评分	模型输出的置信度评分
	全面测试	涵盖各种场景和指标的全面测试用例
	基本网络安全实践	基本网络安全卫生实践（例如，多因素身份验证、访问控制和员工培训）
安全性	供应链安全审查	审查和验证供应链中第三方的网络安全措施
	AI网络安全团队	专门的AI网络安全团队和/或经过AI特定网络安全培训的人员
	AI特定网络安全检查	AI特定的技术网络安全检查和措施，例如，对抗性测试、漏洞评估和数据安全措施
	AI网络安全风险监控	专门用于研究和监控不断发展的AI特定网络安全风险并将其整合到现有网络安全流程中的资源

Source: 《Artificial Intelligence Index Report 2024》, HTI


最后，政府监管是构建负责任AI生态不可或缺的一环。政府需要制定和完善AI相关的法律法规，明确AI开发和应用的红线和底线，并建立相应的监管机制，对AI系统进行有效监管，及时发现和制止违法违规行为。同时，政府还需要鼓励和支持AI安全技术的研究和开发，为负责任AI的发展提供技术支撑。

5.3 AI 监管

人工智能正扮演着愈发重要的角色，风险也随之而来，政府亟需完善相关监管措施。在过去的几年中，一些国家和政治机构，如美国和欧盟，已经颁布了重要的与人工智能相关的政策。这些政策的激增反映出政策制定者越来越意识到需要规范人工智能，并提高各自国家利用其变革潜力。


2016年至2023年，有32个国家颁布了至少一项与人工智能相关的法案。这些国家总共通过了148项与人工智能相关的法案。从2023年通过的人工智能相关法案数量来看，比利时以五项法律领先，其次是法国、韩国和英国，各通过了三项法律，紧接着是阿根廷、葡萄牙和西班牙，各通过了两项法律。从总量来看，自2016年以来，美国通过了最多的人工智能相关法律，共23项，其次是葡萄牙（15项）和比利时（12项）分列二三位。

2016-2023 年各国通过的人工智能相关法案数量




Source: 《Artificial Intelligence Index Report 2024》, HTI

2023 年各国通过的人工智能相关法案数量



Source: 《Artificial Intelligence Index Report 2024》, HTI


2016-2023 年各国通过的人工智能相关法案总数



Source: 《Artificial Intelligence Index Report 2024》, HTI

国际上限制性立法有所增加，说明人工智能的风险正逐渐被正视。人工智能相关法案可以分为扩展性和限制性两类。扩展性法案旨在提升国家的人工智能能力，例如建立一个公共可访问的超级计算机网络。而限制性法案则对人工智能的使用施加限制，例如制定面部识别技术的部署规则。一项法案可以既是扩展性的，又是限制性的，也可以两者都不是。区分这两类法案可以突显立法者的优先事项：是专注于扩展人工智能能力、施加限制，还是平衡两者。全球各国在监管人工智能使用方面呈现出一定的趋势，尽管增强人工智能能力的承诺依然存在，但越来越多的立法转向限制性立法。这一变化表明，立法者越来越关注减轻人工智能融入社会的潜在危害。


2016-2023 年按方法划分的各国通过的人工智能相关法案数量



Source: 《Artificial Intelligence Index Report 2024》,HTI

将国际上 AI 法案按主要主题进行分类分析，可以发现 AI 政策关注面正逐渐扩大。2016 年以来，经济和公共财政是各国 AI 相关立法的主要焦点（2020 年有 8 项，2022 年有 7 项，且数量远大于其他类别），这反映了 AI 相关政策制定通常包含在与公共拨款相关的预算法案中。然而，2023 年通过的法案在主要主题上的分布更加丰富，涵盖了多个政策领域。具体而言，在以下类别中各通过了两项法案：武装部队和国家安全、公民权利和自由、少数民族问题、商业、教育、劳动和就业、科学、技术和通信。

2016-2023 年按主要主题划分的各国通过的人工智能相关法案数量



Source: 《Artificial Intelligence Index Report 2024》, HTI

美国作为AI立法方面的先驱，在监管中重视公共安全、数据隐私、公平和公民权利、消费者和工人。美国 2023 年 10 月 30 日发布的总统行政命令 President Biden Issues Executive Order on Safe, Secure, and Trustworthy Artificial Intelligence 提供了人工智能安全和安保的新标准。文件要求最强大的 AI 系统的开发人员与美国政府共享其安全测试结果和其他关键信息、为广泛的红队测试设定严格的标准、制定新的生物合成筛查标准、建立检测 AI 生成内容和认证官方内容的标准和最佳实践、建立高级网络安全计划以开发 AI 工具查找和修复关键软件中的漏洞、制定国家安全备忘录并指导进一步采取行动应对 AI 和安全问题。在民众保护措施部分，呼吁数据隐私立法、解决算法歧视问题、维护消费者、患者和学生的权益、支持工人等。

美国商务部下属的国家标准与技术研究院（NIST）2023 年来发布了四份草案，这些草案涉及到 AI 风险管理和内容透明度的指导文件，并分别针对处理某一问题。

（1）减轻生成式 AI 的风险：AI RMF Generative AI Profile (NIST AI 600-1)。指导文件涵盖了 13 种风险和 400 多项开发者可以采取的措施，其内容包括帮助组织确定生成 AI 带来的独特风险，并为生成的 AI 风险管理提出措施，以使其目标和优先事项最符合其目标。

（2）减少用于训练 AI 系统的数据的威胁：Secure Software Development Practices for Generative AI and Dual-Use Foundation Models (NIST Special Publication (SP) 800-218A)。与 SSDF (SP 800-218) 一起使用，用于帮助解决恶意训练数据对生成性 AI 系统的影响。

（3）减少合成内容风险：Reducing Risks Posed by Synthetic Content (NIST AI 100-4)。该报告关注合成内容的危险，并旨在通过理解和采用基于用例和上下文来提高内容透明度的技术方法来降低合成内容的风险，列出了用于检测，认证和标记合成内容的方法，包括数字水印和元数据记录

（4）全球 AI 标准的合作与协调：A Plan for Global Engagement on AI Standards (NIST AI 100-5)。文件旨在推动全球 AI 相关共识标准的发展与实施，促进合作与信息分享


美国监管事件时间轴

时间	事件
2023/3/22	美国立法者提出《国家安全人工智能法案》
2023/5/11	美国政策制定者推出《人工智能领导力培训法案》
2023/6/20	美国政策制定者提出《国家人工智能委员会法案》
2023/7/6	众议院推进《未来工作法案》
2023/7/19	美国参议院提出《人工智能与生物安全风险评估法案》
2023/7/21	私营人工智能实验室签署白宫人工智能自愿承诺
2023/7/25	美国参议院通过《对外投资透明法案》
2023/7/27	美国参议院提出《CREATE AI 法案》
2023/9/12	美国参议院提出《保护选举免受欺骗性人工智能法案》
2023/10/30	拜登总统发布关于安全、可靠和值得信赖的人工智能的行政命令
2024/1/29	启动国家 AI 研究资源
2024/1/29	发布 AI 安全行政命令
2024/1/29	OMB 发布联邦机构 AI 政策
2024/3/28	副总统哈里斯宣布联邦机构 AI 治理政策
2024/4/29	拜登-哈里斯政府宣布关键 AI 行动
2024/5/16	拜登-哈里斯政府宣布保护工人免受 AI 风险的关键步骤

Source: HTI

美国的 AI 法规趋势是显著转向限制性的。在每年扩展性法规数量保持大体不变的情况下，限制性法规数量逐年增加。2023 年，有 10 项限制性 AI 法规，而扩展性法规仅有 3 项。相反，在 2020 年，有 4 项扩展性法规和 1 项限制性法规。


2016-2023 年美国按方法划分的人工智能相关法规数量



Source: 《Artificial Intelligence Index Report 2024》, HTI

2023年，美国人工智能相关监管中的最突出问题是外贸和国际金融，有三项相关法规通过。此外，有三个主要主题并列第二，各通过了两项法规：商业、健康以及科学技术和通信。武装部队和国家安全、公民权利和自由则在2023年各通过一项法规。从2016-2023整个趋势来看，美国AI政策关注点正日益跨越多个领域。

2016-2023年美国按主要主题划分的人工智能相关法规数量



Source: 《Artificial Intelligence Index Report 2024》,HTI

欧盟发布了全球首部对人工智能进行全面监管的法规，法规重点关注了高风险系统管理、数据治理、透明度等方面。欧盟理事会于2024年5月21日正式批准了《人工智能法案》。这一法案是，旨在促进安全可信的人工智能系统在欧盟单一市场上的开发和采用。法案规定了禁止的人工智能行为，例如利用潜意识成分操纵人类行为、基于个人生物识别数据推断或分类个人的政治观点、工会成员身份、宗教信仰、种族、性取向等；对高风险人工智能系统进行划分和严格管理，包括要求高风险人工智能系统的提供者必须实施严格的风险管理措施、提高数据治理、透明度等方面要求等；法案对特定人工智能系统的统一透明度做出规定。


欧洲监管事件时间轴

国家	时间	事件
英国	2023/9/18	英国提出指导竞争性人工智能市场和保护消费者的原则
英国	2023/10/30	前沿人工智能工作组发布第二份进展报告
英国	2023/11/1	英国举办人工智能安全峰会（2023）
英国	2023/11/2	英国宣布成立人工智能安全研究所
欧盟	2023/12/9	欧盟达成《欧盟人工智能法案》协议
欧盟	2024/5/21	欧盟正式批准《人工智能法案》

Source: HTI

近年来，欧盟的人工智能相关法规趋向于采取更为扩展的方法。2023年，有8项法规侧重于限制性措施，而有12项法规侧重于扩展性措施。

2017-2023 年欧盟按方法划分的人工智能相关法规数量




Source: 《Artificial Intelligence Index Report 2024》, HTI

欧盟对AI的监管日益广泛，涵盖了越来越多的政策领域。2023年，欧盟人工智能相关法规的最常见主题是科学、技术和通信（共出台5项法规），其次是政府运营和政治（3项）。涉及政府运营和政治的法规包括设定政府及其相关流程操作规则。例如，欧盟委员会关于包容性和弹性选举过程的建议，旨在确保AI不会影响选举的合法性。这表明欧盟立法者正在考虑AI对政府工作的影响。

从2017年到2023年，欧盟在多个领域通过了人工智能相关法规，反映了政策重点的变化。17, 18年法规数量较少。2019年的法规涉及公民权利和自由、少数民族问题，和国际事务。2020年则更加关注经济和公共财政、政府运营和政治领域。2021年开始至2023年，法规涵盖多个领域，包括健康、经济和公共财政、政府运营和政治、科学、技术与通信等等。

2017-2023 年欧盟按主要主题划分的人工智能相关法规数量



Source: 《Artificial Intelligence Index Report 2024》, HTI

中国方面，监管主要考虑对大模型的攻击、数据泄露风险、可解释性等。2023年6月中国信息通信研究院，清华大学，蚂蚁集团联合发布《可信AI技术和应用进展白皮书（2023）》。其中提到，应用AI鲁棒性技术对抗恶意攻击、应用AI可解释性技术提升决策透明度、结合部署方式和保护算法对AI应用实践中的数据模型安全和隐私进行保护。

中国监管事件时间轴

时间	事件	详情
2023/1/10	中国推出互联网深度合成管理条例	中国推出针对“深度合成”技术的法规，以应对与创建逼真虚拟体和多模态媒体（包括“深度伪造”）相关的安全问题。这些法规适用于不同媒体的提供者和用户，并规定了一系列措施，如防止非法内容、遵守法律法规、验证用户身份、获得生物特征编辑的同意、保障数据安全和执行内容审核。
2023/8/15	中国更新生成式人工智能措施的网络空间管理政策	中国的更新政策采取了更具针对性的监管方法，重点关注对公众产生影响的应用，而不是全面监管。修订内容缓和了监管语言，将“确保数据的真实性、准确性、客观性和多样性”等指令改为“采取有效措施提高训练数据的质量，提升其真实性、准确性、客观性和多样性”。此外，修订后的法规鼓励生成式人工智能的发展，转变了以往的惩罚性重点。
2024/3/5	十四届全国人大二次会议作政府工作报告中，首提“人工智能+”	报告指出，制定支持数字经济高质量发展政策，积极推进数字产业化、产业数字化，促进数字技术和实体经济深度融合。深化大数据、人工智能等研发应用，开展“人工智能+”行动，打造具有国际竞争力的数字产业集群。另外，关于人工智能，报告还指出，适度超前建设数字基础设施，加快形成全国一体化算力体系。

Source: HTI

为确保人工智能 (AI) 沿着符合人类共同价值观的轨道健康发展，中国亟需加快构建完善的 AI 治理体系，并推动相关立法的出台。这其中，创造鼓励 AI 技术研发和应用的政策环境至关重要。同时，建立透明的披露机制和完善的审计评估体系，以增进对 AI 算法原理和决策过程的理解，也是当务之急。此外，明确 AI 系统的安全责任和问责机制，确保责任可追溯且可补救，将为 AI 的发展保驾护航。最后，中国还应积极参与国际合作，推动形成公平、合理、开放、包容的全球 AI 治理规则。

5.4 数据交易

数据作为新的生产要素，如同土地、劳动力、资本一样，已成为数字经济和国民经济高质量发展的关键资源。它不仅是连接虚拟世界和现实世界的桥梁，更是数实融合的核心驱动力。而 AIGC 技术的蓬勃发展，为激活数据要素潜能、赋能新质生产力提供了强大的引擎。如同工业革命时期蒸汽机的发明，AIGC 正在打开释放数字红利、创造巨大经济价值的新空间，为经济增长注入前所未有的活力。AIGC 的发展，不仅将重塑数字内容生产方式，更将推动数据要素市场化，加速数字经济与实体经济的深度融合，为经济高质量发展注入强劲动力。

根据《价值意蕴、运行机理与实践路径》，AIGC 技术凭借其智能采集数据、自动生成内容的技术优势，赋予数据要素全新的价值意蕴：(1)AIGC 能够高效处理和传输数据，推动企业决策由经验型向数据驱动型转变，显著提高管理者信息处理能力和决策质量；(2)AIGC 为打破数据孤岛、促进数据资源交流共享提供了契机，不同组织和行业之间可以共享数据，例如金融机构与零售企业共享交易数据以改善信用风险评估，医疗机构与生物技术公司共享病例数据以推动医疗创新，这种协作模式将构建跨行业的生态系统，推动新质生产力持续涌现；(3)AIGC 赋能下的供应链数字化管理，突破了空间限制，减少了信息不对称造成的资源浪费，提升了整体效率，例如，AIGC 在物流管理系统中的应用，使生产流程和供应链更加透明高效，促进原材料、零部件和成品在全球范围内的快速传输，实现协同共赢。

近年来，国家高度重视数据要素发展，从顶层设计到具体政策措施，为数据要素市场建设提供了强有力的支持。2019 年，党的十九届四中全会首次将数据作为新的生产要素；2020 年，《关于构建更加完善的要素市场化配置体制机制的意见》提出“引导培育大数据交易市场，依法合规开展数据交易”；2022 年，《关于加快建设全国统一大市场的意见》提出加快培育统一的技术和数据市场；《关于构建数据基础制度更好发挥数据要素作用的意见》（“数据二十条”）明确提出“统筹构建规范高效的数据交易场所，培育数据要素流通和交易服务生态”。

各地也陆续出台针对数据交易所的相关支持政策。根据贵阳大数据交易所，以北上广贵等代表性省市为例：北京在 2022 年 5 月出台《北京市数字经济全产业链开放发展行动方案》，提出“支持市场主体采取直接交易、平台交易等方式依法开展数据服务和数据产品交易活动。加快建设北京国际大数据交易所”，并完善相关制度建设。上海在 2021 年 7 月印发《上海市促进城市数字化转型的若干政策措施》，提出“充分发挥现有平台作用，推动建立市场化运作且具有准公共属性的上海数据交易所”。2022 年 7 月，《上海市数字经济发展“十四五”规划》提出“加快建立完善数据要素市场化运行机制，加快建设上海数据交易所”。2023 年 11 月，广东省办公厅印发《“数字湾区”建设三年行动方案》，指出“建设数据要素统一大市场，支持广州、深圳数据交易所创建国家级数据交易所”，并推动相关制度与规则的完善。

AIGC 技术与数据要素的深度融合，将为数字经济发展注入强劲动力。随着国家政策的引导和支持，以及各地数据交易所建设的不断推进，相信 AIGC 必将释放出更大的能量，赋能数字经济高质量发展，为构建数字中国贡献力量。

5.5 主权级 AI

主权级 AI (Sovereign AI) 是指国家或地区自主开发和管理的人工智能系统，这些系统不依赖于外国技术或服务。 其核心理念是确保 AI 技术的安全性、可控性和自主性，避免外部干扰和潜在的安全风险。通过发展本土的 AI 能力，各国可以促进经济增长、可持续发展和技术独立。例如，法国、印度、日本和新加坡都在推进各自的主权 AI 项目，利用 AI 工厂等基础设施，开发本地化的 AI 应用。

黄仁勋提出主权级 AI 的背景是全球对数据主权和信息安全的关注不断增加，各国希望在关键技术领域实现自主可控。 在与阿联酋 AI 部长 Omar Al Olama 的对话中，黄仁勋描述了主权 AI 的重要性，强调各国需要控制自己的数据和生产的智能。黄仁勋还提到，各国应将自己的语言和文化数据编入 AI 模型中，以促进本地化的 AI 应用，“你不能允许这件事由别人来做。它编纂了你的文化、你的社会智慧、你的常识、你的历史——你拥有你自己的数据。”。

主权级 AI 的意义重大，主要体现在以下几个方面：

- 数据安全与隐私：** 在全球化背景下，数据跨境流动不可避免，如何保护本国数据安全成为各国关注的重点。主权级 AI 能够确保数据在本国境内处理，减少数据泄露和滥用的风险。比如，Singtel 正在帮助新加坡建设加速计算的数据中心，利用 NVIDIA Hopper 架构 GPU，这些数据中心将作为主权资源处理私有数据集。新加坡的首个 AI 服务将启动，未来还计划在印度尼西亚和泰国建设数据中心。这些数据中心将支持新加坡的国家 AI 战略，扩展计算基础设施和机器学习专家的人才库。
- 技术自主性：** 依赖外国技术在某些关键领域存在潜在风险，主权级 AI 有助于提升国家在人工智能领域的自主研发能力，减少对外部技术的依赖。通过自主研发，国家可以掌握核心技术，避免在关键时刻被他国“卡脖子”。
- 经济和战略利益：** 人工智能技术在国防、金融、医疗等关键领域的应用越来越广泛，主权级 AI 能够确保这些关键领域的安全和稳定运行，保护国家利益。同时，主权级 AI 的研发和应用还可以带动相关产业的发展，促进经济增长和技术创新。

主权级 AI 的未来发展前景广阔，当前主要集中在商业领域，通过与本地企业合作，推动 AI 技术的本地化开发和应用。 然而，随着央企和国企能力的提升，主权级 AI 将在更多领域得到广泛应用，包括：

- 政府和公共服务：** 主权级 AI 将用于提升政府管理和公共服务的效率，包括智能城市、交通管理和公共安全等领域。通过引入主权级 AI 技术，政府可以实现更加高效和精准的管理和服务，提高公共资源的利用效率。
- 国防和安全：** 通过自主开发的 AI 技术，增强国防能力和国家安全，确保在紧急情况下的快速反应和决策能力。主权级 AI 在国防领域的应用将包括智能武器系统、战场管理和情报分析等，为国家安全提供有力保障。
- 产业升级：** 推动传统产业的智能化升级，提高生产效率和竞争力，实现经济的高质量发展。主权级 AI 将在制造业、农业、能源等领域发挥重要作用，促进产业转型升级，提高国家经济的整体竞争力。

实现主权级 AI，完善基础设施建设是关键。 中国工程院院士孙凝晖指出，人工智能技术的长尾效应将赋能各行各业，但我国 80% 的中小微企业需要的是低门槛、低价格的智能服务。因此，智能计算产业发展必须建立在新的数据空间基础设施之上，其关键在于率先实现数据、算力、算法等智能要素的全面基础设施化，如同二十世纪初美国信息高速公路计划对互联网产业的推动作用。

我国政府已前瞻性地布局了新型基础设施，在全球竞争中抢占先机。孙凝晖院士指出，首先，数据作为国家战略信息资源，其资源要素属性涵盖生产、获取、传输、汇聚、流通、交易、权属、资产、安全等环节，因此需继续加强国家数据枢纽与数据流通基础设施建设。其次，AI 大模型作为数据空间的算法基础设施，应以通用大模型为基座，构建支撑企业研发领域专用大模型的研发与应用基础设施，服务于机器人、无人驾驶等行业，覆盖长尾应用。

最后，全国一体化算力网建设在推动算力基础设施化方面发挥了先导作用。中国方案的算力基础设施化，应在降低成本和门槛的同时，为最广泛人群提供高通量、高品质的智能服务，即“两低一高”。在供给侧，大幅降低算力器件、设备、网络、数据、算法、电力、运维、开发等成本，让中小企业也能负担高品质算力服务；在消费侧，大幅降低用户使用门槛，像水电一样即开即用，像编写网页一样轻松定制算力服务；在服务效率侧，实现低熵高通量，保障高并发负载下的系统吞吐量稳定，满足中国“算得多”的需求。此外，“东数西算”工程作为一项重要战略布局，旨在优化数据中心建设布局，推动算力资源跨地域协同，核心是在东部地区进行数据的收集和处理，而在资源更丰富、能源供应充足的西部地区进行数据的计算和存储。这项工程一方面可以提升国家整体算力水平，通过全国一体化的数据中心布局建设，扩大算力设施规模，提高算力使用效率，实现全国算力规模化集约化发展；另一方面促进绿色发展：加大数据中心在西部布局，将大幅提升绿色能源使用比例，就近消纳西部绿色能源，同时通过技术创新、以大换小、低碳发展等措施，持续优化数据中心能源使用效率。“东数西算”工程的实施，将有效缓解东部地区能源和土地资源压力，促进西部地区经济发展，推动数字经济与实体经济深度融合。


6. 未来趋势展望

6.1 哪些行业最先启动 GenAI 商业化路径

当前实现生成式 AI 商业化路径主要考虑以下几点：

- (1) **生成式 AI 所带来的附加值（增量价值）**：目前 AI 所带来的附加值主要是提高产出效率，特别是在内容和文字类应用中，能够显著提高产出效率，使得从撰写文章到生成创意内容等任务变得更加高效。同时，包括软件开发、编码开发等高阶类工作也能有效提高产出效率。然而，其产出质量仍存在进一步提升的空间，包括在语言理解、逻辑推理和创造性思维等方面仍有局限性，导致生成的内容可能存在逻辑错误、语义不清晰或缺乏创造性等问题。
- (2) **生成式 AI 的生产成本（性价比）**：AI 算法的研发成本、训练成本以及人力成本高企。算法的研发及训练需要算力及相关云资源等支持，目前中国厂商在获取相关资源的成本相比美国本土厂商高了 2-3 倍；而 AI 科学家的薪酬也是相当大的成本之一，根据财讯报道，OpenAI 的工程师年薪达到了 80 万美金。根据 The Information 的信息，OpenAI 在聘请资深研究员时，承诺其年薪（包括股票在内）将在 500 万美元至 1000 万美元之间。当前纯 AI 厂商几乎全部亏损，其中 2023 年商汤亏损近 65 亿元，第四范式亏损 9.21 亿元，云从科技亏损 6.43 亿元。所以在商业化过程中，须考虑到生产成本（模型训练成本、维护成本、数据收集和处理成本、技术开发和集成成本等等）与所带来的附加值的平衡，也就是所谓的性价比问题。
- (3) **对行业生态的影响（“AI+产业”还是“产业*AI”）**：每个行业都有其固有的商业模式，AI 的出现还不能颠覆整体模式、消费者行为、以及行业标准等，AI 的出现更多是通过 AI 赋能，类似“互联网+”，以产业为主导，利用 AI 工具实现生产效率和综合优势的提升，更像是“产业*AI”。我们可以通过产出质量敏感度和产出成本敏感度这两个维度来分析生成式 AI 商业化的可行性。整个生成式 AI 商业化路径，将从产出质量敏感度和产出成本敏感度较低的行业开始渗透发展，其中互联网与软件行业将是首个参与者，生成式 AI 可显著提高程序员的产出效率。

各行业产出性价比对比




注：制造：包括电子、家电、汽车与汽车零部件、化工、机械、通信
 金融：包括非银金融、银行、金融工程
 地产建材：包括房地产、建筑工程、非金属建材
 传媒：包括传播与文化、计算机

Source: HTI

除了增量价值、性价比和对产业的适配性，生成式 AI 在不同行业的易用性也不尽相同。前面是从产出的质量敏感度和成本敏感度来分析生成式 AI 的商业化路径，接下来我们将从生成式 AI 对于商业生态的颠覆模式及采用难易度进行分析讨论。如下图，通过两个维度分析生成式 AI 对商业生态的影响，1) 颠覆程度（对商业模式、运营模式、竞争格局的影响），2) 采用难易程度（模型可行性、变革驱动因素、责任轻重度）。例如，对于工业制造企业而言，生成式 AI 主要是帮助企业在原技术基础上优化内部流程，提高产出效率，其方案采用难度较低，同时 AI 对产品和成本结构影响有限，对原生态的颠覆程度较低。对于软件和 IT 服务业而言，生成式 AI 对于企业能够显著提升企业的产出效率和效能，甚至彻底改变商业模式和行业竞争格局等。企业若能掌握最新技术，便能在短时间内获得更多市场份额，因此该行业对生成式 AI 的接受程度更高，其带来的颠覆程度也更大。

不同行业生成式 AI 易用性对比



Source: PwC, HTI

6.2 商业模式

生成式 AI 的商业模式，主要包括向 C 端用户提供软硬件产品和服务，向 B 端用户提供云原生与专用服务，提供订阅制收费（MaaS, Model as a Service）和 API 端口调用，以及 AI 基础设施服务。以 Google Cloud 为例，分析生成式 AI 是如何融入到互联网企业及其产品生态链的。首先，最顶层是应用层（Applications），指的是使用 Cloud 产品的 C 端和 B 端用户。其次，端口层（APIs）是指 Google 提供的一系列产品 API，例如 Workspace、Vertex AI 和生成式应用构建器（Gen App Builder）。以及模型层（Models）包括了 Google 的基础模型、Google Cloud 合作伙伴的基础模型以及开源软件模型。最底层是基建层（AI Infrastructure），指的是各类基础硬件设施的支持，包括算力，存储等。

在谷歌云服务生态中，基建层提供 IaaS（Infrastructure as a Service），负责基础算力资源支持；模型层和端口层提供 PaaS（Platform as a Service），提供开发工具、管理系统等；应用层提供 SaaS（Software as a Service），是指云端的应用软件。此外，Google Cloud 还支持合作伙伴开发的基础模型和开源软件模型。综上，基建层是基础，模型层和端口层是核心，应用层是用户。完整的 AI 生态系统需要这四层的紧密合作，才能推动 AI 技术的广泛应用和持续发展。

谷歌建立 AI 合作者生态系统

Building an Open and Innovative AI Partner Ecosystem



Source: 谷歌, HTI


6.2.1 2C 业务：软硬件产品和服务

2C 端的商业模式主要是通过流量和提升付费转化率来实现，生成式 AI 的 SOTA 模型（State-of-the-Art Model，当前最先进的模型）将为产品带来赢者通吃的效果。2C 业务的赋能方式主要包括：1) 改善自身产品，提高用户体验，吸引并留存用户，未来或基于流量向商家端变现：如百度，将文心整合进搜索，阿里基于通义推出淘宝问问；2) 提供面向 C 端的 AIGC 工具，通过订阅模式变现：如百度文库、各家的 AI 个人助理、文生图工具等；3) 提供包含大模型的硬件产品：如讯飞的“智能办公本”、“AI 学习机”等。

我们认为这里面最能立竿见影的变现场景是提供生产力工具的 AIGC 产品，即

- 1) **能有效提高产出效率软件产品。**例如，在 AIGC 出现之前，美图的影像设计产品用户多为消费者，免费功能已经能满足其修图基本需求，付费意愿低，但美图将自研视觉大模型 Miracle Vision 整合进自身核心图片工具流程，付费转化率明显提高（2023 年付费渗透率环比提高 0.6 个百分点，付费用户环比提高 29% 到 720 万；另外，ARPU 也同比提升 23%），因为大模型降低了设计师门槛，使用者多将其作为生产力工具使用，用 AIGC 为自己增加收入。
- 2) **拥有更多的生态附加值。**例如，微软的 Copilot 通过与 GPT-4 超强联合，可以实现“私人助理”的效果，可以帮助用户实现生成策划报告、汇报方案和数据分析等。目前，Microsoft 365 Copilot 的收费标准是 C 端客户每人每月收费 20 美元，企业客户则是每人每月收费 30 美元。微软 FY2024 第三季度的业绩会上披露了 Copilot 的最新情况，包括近 60% 的 500 强企业目前都在使用 Copilot，以及 Office 365 的收入增长 15%，主要是每用户平均收入（ARPU）的提升和 Copilot 的进展。此外，谷歌、金山办公、百度等大厂都相继将各自的 AI 模型嵌入其旗下产品。

MAU top50 的生成式 AI 应用程序



Source: a16z, HTI

6.2.2.2B 业务：云原生与专用服务

2B 端的商业模式主要是通过 AI 赋能，将自身的 AI 能力整合到企业端客户的产品生态中来实现。2B 业务的赋能方式包括：1) 以公有云的模式调用大模型，如 API、精调大模型，以 token 来收费；2) 私有云部署；3) 以混合云的形式提供数据、算力、精调大模型、评测以及推理等服务，如谷歌、微软、阿里、腾讯、商汤等。

从行业来看，首先有效的是容错率较高以及对生产效能提升明显的行业，如社交、互联网、游戏等，其次是数据和知识图谱积累充分的行业，如教育、金融、法律、政务等。从赋能方式上来看，目前私有云部署相对于公有云更为容易。因为公有云模式存在数据隐私保护和技术安全风险等问题待解决。MaaS 模式，因为资金、算力和数据的门槛，只有巨头能达成。所以就落地场景的难易程度，阿里和腾讯因为有各自在社交、游戏和电商的布局，最为容易铺开其混合云模式；其次，百度和讯飞已经在教育和金融等方面有大模型布局且有良好反馈。

综上，我们认为 C 端应用，最有效的赋能方式是提供生产力工具的 AIGC 产品，看好包括直接提供此类产品的企业，以及提供底层基础大模型的企业，比如科大讯飞、OpenAI 等；B 端应用，看好有长期布局 B 端业务，拥有大量客户群的 AI 公司，比如微软、谷歌、阿里等。

腾讯云技术架构图



Source: Tencent, HTI

6.2.3 MaaS 将成为人工智能公司的核心商业模式

订阅制收费 (Subscription)： MaaS 类似 SAAS，AI 公司可向用户按月、按年或按其他周期固定收费的商业模式。OpenAI 在 2023 年 2 月 1 日正式官宣了 ChatGPT 的「试点订阅计划」，这项付费服务被命名为 ChatGPT Plus，每月收费 20 美元，订阅者将获得许多好处，包括：在高峰时段享有优先访问 ChatGPT 的权利、更快的应用响应时间、优先使用新功能和改进。此外，还有 ChatGPT Team 套餐，每人每月收费 25 美元，除了 Plus 的功能外，还可与团队协同工作、享受更高的算力配额以及更多的工具功能等。

目前 ChatGPT 已经成为一款重要的生产力工具，被广大用户证明，可以写文案、写小说，写代码、改 bug、查资料，还能帮忙对资料进行归纳总结。所以，收费版的 ChatGPT Plus 的确拥有广泛的市场空间。我们可以做一个简单的计算，假设在目前的 1.8 亿用户中，有 30% 愿意付费，按照年付费 240 美元计算，年收费就能达到 130 亿美元，如果未来 ChatGPT 作为能够对标 office 的生产工具，付费用户数突破 10 亿人，市场将达到 2000 亿美元以上，而且这还仅仅是按照目前 20 美元一个月的收费来计算的，并没有考虑未来公司可能推出更高价格的订阅计划等，而如果加上未来可能存在的广告等盈利方法，整个市场空间将会更加广阔。


ChatGPT Plus 和普通版 ChatGPT 对比

Source: OpenAI, HTI

6.2.4 嵌入其他产品获得引流式收入（API）

除了模型本身进行订阅收费以外，MaaS 目前也在积极尝试其他各类收费模式。例如，通过提供 API 接口调用或定制开发，基于使用量（调用 API 次数、数据量，以 tokens 计算）收费。用户可以通过 OpenAI API 调用 GPT 系列大模型，灵活使用不同版本的 GPT 模型进行文本生成、对话、翻译等任务，还支持函数调用和 JSON 模式。截止 2023 年 10 月，已经有约 200 万开发者在其 API 上构建各种各样的应用。目前，GPT-4o 比 GPT-4 Turbo 便宜 50%，输入每百万 tokens 费用为 5 美元，输出每百万 tokens 费用为 15 美元。而字节跳动的云服务平台火山引擎推出豆包大模型，其主力模型在企业市场的定价只有 0.8 元/百万 Tokens。火山引擎总裁谭待表示：“今天用户通过豆包大模型，1 块钱就能获得 125 万个 Token。也就是说，只需要 1 块钱就能处理 3 本篇幅为 75 万字的《三国演义》的文字量”。可以看出其价格竞争力十分明显，对于需大规模文本处理等企业，可大幅降低使用成本。

OpenAI API



Source: OpenAI, HTI

6.2.5 AIDC（AlaaS 与 IDC）

人工智能数据中心（Artificial Intelligence Data Center，AIDC）集成了 AI 即服务（AlaaS）和互联网数据中心（IDC），为企业用户提供从数据存储、处理到 AI 模型部署和使用的一体化服务，按服务内容和所需算力等收取费用。随着生成式 AI 和 AI 算力需求的不断发展，传统的 IDC 数据中心将转变为更高价值的生产力工厂 AIDC，提供数据存储的同时，利用 AI 算力支持更复杂和高效的生产任务，提高整体生产力和创新能力，为企业提供更加智能和高效的服务。商汤临港 AIDC 已实现了万卡的超大集群互联，并行效率达 90%，可在园区里实现万亿参数模规的模型训练，在训练稳定性上，具备了超 30 天稳定训练不间断的能力。根据英伟达 2025 财年一季度财报，其数据中心业务收入为 226 亿美元，同比增长 427%。当前生成式 AI 的商业化路径中，AIDC 作为未来的 AI 工厂，将会是 AI 发展路径中的长期受益者。

商汤 AIDC



Source: SenseTime, 新民晚报, HTI


6.3 产业竞争格局演变

6.3.1 产业竞争格局现状

以全产业链的视角来看，AI产业格局可划分为基建层（Foundation）、制造层（Manufacturing Layer）、芯片层（Silicon Layer）、算力层（Compute Layer）、模型层（Model Layer）、应用层（Application Layer）。

- (1) 基建层：泛指的是电力，材料，劳动力三种资源。具体指的是，AI系统需要电力供应，算力设备以及运维工程师/研究人员的支持。
- (2) 制造层：涵盖了半导体制造的各个重要环节。1. 半导体设备（例如ASML、Applied Materials、Lam Research等）2. 电子设计自动化和知识产权（EDA&IP，例如Synopsys、Cadence等）3. 晶圆代工厂（例如台积电等）4. 集成设备制造商（例如英特尔、三星等）
- (3) 芯片层：指的是各类半导体芯片。1. 应用专用集成电路（ASIC，例如谷歌的Tensor Processing Unit等）2. 中央处理器（CPU，例如英特尔、AMD等）3. 图形处理单元（GPU，例如英伟达、AMD等）4. 内存（Memory，尤其是HBM，例如三星、海力士等）5. 系统级芯片（SoC，例如高通的Snapdragon、苹果等）
- (4) 算力层：指的是不同的算力环境和设备。1. 本地部署（On-Prem，例如Dell Technologies、IBM等）2. 云计算（Cloud，例如Google Cloud、Microsoft Azure等）3. 移动计算（Mobile，例如苹果、三星等）4. 汽车计算（Auto，例如福特、特斯拉等）5. 工业计算（Industrial，例如西门子、霍尼韦尔等）
- (5) 模型层：指的是各大生成式AI模型，包括OpenAI的GPT模型、Google Gemini、科大讯飞的星火模型、腾讯的混元、阿里巴巴的通义千问等。
- (6) 应用层：指的是嵌入生成式AI模型的应用软件，包括Microsoft Copilot、Bing、百度的文心一言、WPSAI等。

AI 行业各环节参与者



Source: Techvedas, HTI

目前英伟达作为高端CPU算力以及计算生态的独家提供者，是当今AI时代的宠儿。回顾过去，我们发现不同的科技时代分别产生了不同类型的跨层级联盟，当中包括PC时代的Wintel联盟（微软和英特尔），手机时代的ARM + 手机操作系统Google Android，云服务时代AWS + 英伟达，以及AI时代的微软+OpenAI+英伟达等等。我们发现PC时代Wintel联盟占据主导地位，市场垄断性较强，其市占率高达80%。相比之下，手机时代的联盟体系更标准化，以ARM架构和Google Android操作系统为核心，只有采用Android系统的品牌才需要使用ARM芯片。而云服务时代的联盟则较为松散，AWS与英伟达等公司之间的存在一定的竞争关系，但双方的合作仍是主旋律。对于AI时代，目前看来体现是联盟之间的较量，需要底层算力厂商，中层模型厂商和上层生态厂商的通力配合，才能市场中生存。


由于AI算法的发展迅速、高研发投入、长期亏损、普及还需时间等特征，日前算法厂商需要尽快寻找上下游厂商组建跨层级联盟，以更好地在市场中生存并争取赢得时间。比如微软+OpenAI+英伟达，由英伟达提供强大的算力支持，将OpenAI的AI模型整合到微软的产品和服务中。而整个AI市场最终还是由消费者的需求来驱动，所以谁拥有了SOTA模型，谁就吸引更多的消费者，获得更多的产品溢价空间，最终赢得市场。

6.3.2 产业竞争格局演变

基建层：台积电的先进制程和封装产能吃紧，影响了英伟达、AMD等公司的出货速度，三星和英特尔等有望获得部分外溢订单。为了应对产能不足的问题，台积电、英特尔等企业正积极投资扩产。

芯片层：目前英伟达一骑绝尘，AMD紧随其后，未来在训练端将会是英伟达+AMD双寡头格局，推理段则会有更多芯片公司涌现。当大模型逐渐商用落地时，推理芯片的需求将逐渐从云端迁移至终端设备，其需求量将远超训练芯片。美国AI初创公司Groq最新推出的面向云端大模型的推理芯片Groq LPU引发业内关注，该芯片的推理速度达到了NVIDIA GPU的10倍以上，展示了芯片市场的巨大潜力。

AI 芯片推理速度对比



Source: Groq, HTI

算力层: AIDC数据中心与应用终端双轮驱动AI时代的变革。随着AI PC与AI Phone等AI智能终端的普及，市场需求将迎来新一波增长。英特尔CEO基辛格表示，看好AI PC的发展，目前已有超过800万台搭载英特尔处理器的AI PC出货，他还预计2024年搭载英特尔芯片的AI PC出货将达到4500万台，在2028年时，搭载AI功能的PC在所有PC当中的占比将达到80%的水平。

模型层: 混合专家模型 (MoE) 是主要的商用落地方式，尤其机器人等行业仍需要训练高参数的大模型。OpenAI和DeepMind等公司正开发更复杂的混合专家模型，进一步提高效能。例如，DeepMind提出了Soft混合专家模型，旨在通过软分配策略来克服稀疏MoE的限制。OpenAI的GPT-4也是采用了专家混合模型 (MoE)。

应用层: 个人AI助手时代即将到来，推动“Personal computer to personal assistant”的转变。例如当前微软的Copilot通过与GPT-4超强联合，可以为用户提供强大的私人助理服务，从生成策划报告、汇报方案到进行数据分析，大幅提高工作效率。类似地，谷歌助手和亚马逊 Alexa 等智能助手也在不断升级，提供更加智能和个性化的服务，以满足用户日益增长的需求。

6.4 投资机会

我们认为，1) 海外公司投资更着重价值导向，建议关注创造价值高以及 AI 效能高的公司。2) 国内公司投资更着重其稀缺属性，建议关注那些具备融入海外生态链、拥有行业壁垒 (例如政务云等) 特征的公司。3) 可以绑定行业龙头的创业公司。

	国外	国内
应用层	Microsoft, Amazon, Google, Meta, Apple, Amazon, Tesla, X, Palantir	腾讯、百度、阿里、字节、海康威视、金山办公、宝信软件、中控技术、昆仑万维、上海电影、博纳影业、华策影视、恺英网络、水晶光电、瑞声科技、立讯精密
模型层	Microsoft, Open AI, Google, Meta, Anthropic	百度、商汤、科大讯飞
算力层	Supermicro, Dell, Arista, Vertiv	浪潮信息、中科曙光、神州数码, 中际旭创
芯片层	NVIDIA, AMD, SK Hynix	寒武纪、海光信息、景嘉微、龙芯中科
制造层	ASML、台积电、英特尔	北方华创、中微公司

APPENDIX 1

Summary

Chapter 1 of this report briefly describes the progress and limitations of AI technology, and looks forward to the development path to generalized artificial intelligence (AGI); Chapter 2 provides a panoramic AI industry chain mapping and a comparison of AI capabilities between China and the United States; Chapter 3 describes the core technology and development trend of generative AI; Chapter 4 focuses on the impact and empowerment of AI on industries, exploring investment opportunities brought about by generative AI, in combination with industries such as the Internet, media, computers, electronics, energy, automatic The fourth chapter focuses on the impact and empowerment of AI on industries, including Internet, media, computer, electronics, energy, automation, automation, humanoid robotics and other industries, and discusses the investment opportunities brought by generative AI; the fifth chapter discusses the establishment of a reliable AI ecosystem from the perspectives of measurement, regulation and security; the sixth chapter looks forward to the evolution of AI commercialization paths and the industry's competitive landscape, and proposes possible investment opportunities.

附录 APPENDIX

重要信息披露

本研究报告由海通国际分销，海通国际是由海通国际研究有限公司 (HTIRL), Haitong Securities India Private Limited (HSIPL), Haitong International Japan K.K. (HTIJKK) 和海通国际证券有限公司 (HTISCL) 的证券研究团队所组成的全球品牌，海通国际证券集团 (HTISG) 各成员分别在其许可的司法管辖区内从事证券活动。

IMPORTANT DISCLOSURES

This research report is distributed by Haitong International, a global brand name for the equity research teams of Haitong International Research Limited ("HTIRL"), Haitong Securities India Private Limited ("HSIPL"), Haitong International Japan K.K. ("HTIJKK"), Haitong International Securities Company Limited ("HTISCL"), and any other members within the Haitong International Securities Group of Companies ("HTISG"), each authorized to engage in securities activities in its respective jurisdiction.

HTIRL 分析师认证 Analyst Certification:

我，姚书桥，在此保证 (i) 本研究报告中的意见准确反映了我们对本研究中提及的任何或所有目标公司或上市公司的个人观点，并且 (ii) 我的报酬中没有任何部分与本研究报告中表达的具体建议或观点直接或间接相关；及就此报告中所讨论目标公司的证券，我们 (包括我们的家属) 在其中均不持有任何财务利益。我和我的家属 (我已经告知他们) 将不会在本研究报告发布后的 3 个工作日内交易此研究报告所讨论目标公司的证券。I, Barney Yao, certify that (i) the views expressed in this research report accurately reflect my personal views about any or all of the subject companies or issuers referred to in this research and (ii) no part of my compensation was, is or will be directly or indirectly related to the specific recommendations or views expressed in this research report; and that I (including members of my household) have no financial interest in the security or securities of the subject companies discussed. I and my household, whom I have already notified of this, will not deal in or trade any securities in respect of the issuer that I review within 3 business days after the research report is published.

我，毛云聪，在此保证 (i) 本研究报告中的意见准确反映了我们对本研究中提及的任何或所有目标公司或上市公司的个人观点，并且 (ii) 我的报酬中没有任何部分与本研究报告中表达的具体建议或观点直接或间接相关；及就此报告中所讨论目标公司的证券，我们 (包括我们的家属) 在其中均不持有任何财务利益。我和我的家属 (我已经告知他们) 将不会在本研究报告发布后的 3 个工作日内交易此研究报告所讨论目标公司的证券。I, Yuncong Mao, certify that (i) the views expressed in this research report accurately reflect my personal views about any or all of the subject companies or issuers referred to in this research and (ii) no part of my compensation was, is or will be directly or indirectly related to the specific recommendations or views expressed in this research report; and that I (including members of my household) have no financial interest in the security or securities of the subject companies discussed. I and my household, whom I have already notified of this, will not deal in or trade any securities in respect of the issuer that I review within 3 business days after the research report is published.

我，杨林，在此保证 (i) 本研究报告中的意见准确反映了我们对本研究中提及的任何或所有目标公司或上市公司的个人观点，并且 (ii) 我的报酬中没有任何部分与本研究报告中表达的具体建议或观点直接或间接相关；及就此报告中所讨论目标公司的证券，我们 (包括我们的家属) 在其中均不持有任何财务利益。我和我的家属 (我已经告知他们) 将不会在本研究报告发布后的 3 个工作日内交易此研究报告所讨论目标公司的证券。I, Lin Yang, certify that (i) the views expressed in this research report accurately reflect my personal views about any or all of the subject companies or issuers referred to in this research and (ii) no part of my compensation was, is or will be directly or indirectly related to the specific recommendations or views expressed in this research report; and that I (including members of my household) have no financial interest in the security or securities of the subject companies discussed. I and my household, whom I have already notified of this, will not deal in or trade any securities in respect of the issuer that I review within 3 business days after the research report is published.

我，赵玥玮，在此保证 (i) 本研究报告中的意见准确反映了我们对本研究中提及的任何或所有目标公司或上市公司的个人观点，并且 (ii) 我的报酬中没有任何部分与本研究报告中表达的具体建议或观点直接或间接相关；及就此报告中所讨论目标公司的证券，我们 (包括我们的家属) 在其中均不持有任何财务利益。我和我的家属 (我已经告知他们) 将不会在本研究报告发布后的 3 个工作日内交易此研究报告所讨论目标公司的证券。I, Yuewei Zhao, certify that (i) the views expressed in this research report accurately reflect my personal views about any or all of the subject companies or issuers referred to in this research and (ii) no part of my compensation was, is or will be directly or indirectly related to the specific recommendations or views expressed in this research report; and that I (including members of my household) have no financial interest in the security or securities of the subject companies discussed. I and my household, whom I have already notified of this, will not deal in or trade any securities in respect of the issuer that I review within 3 business days after the research report is published.

我，杨斌，在此保证 (i) 本研究报告中的意见准确反映了我们对本研究中提及的任何或所有目标公司或上市公司的个人观点，并且 (ii) 我的报酬中没有任何部分与本研究报告中表达的具体建议或观点直接或间接相关；及就此报告中所讨论目标公司的证券，我们 (包括我们的家属) 在其中均不持有任何财务利益。我和我的家属 (我已经告知他们) 将不会在本研究报告发布后的 3 个工作日内交易此研究报告所讨论目标公司的证券。I, Bin Yang, certify that (i) the views expressed in this research report accurately reflect my personal views about any or all of the subject companies or issuers referred to in this research and (ii) no part of my compensation was, is or will be directly or indirectly related to the specific recommendations or views expressed in this research report; and that I (including members of my household) have no financial interest in the security or securities of the subject companies discussed. I and my household, whom I have already notified of this, will not deal in or trade any securities in respect of the issuer that I review within 3 business days after the research report is published.

我，王晴，在此保证 (i) 本研究报告中的意见准确反映了我们对本研究中提及的任何或所有目标公司或上市公司的个人观点，并且 (ii) 我的报酬中没有任何部分与本研究报告中表达的具体建议或观点直接或间接相关；及就此报告中所讨论目标公司的证券，我们 (包括我们的家属) 在其中均不持有任何财务利益。我和我的家属 (我已经告知他们) 将不会在本研究报告发布后的 3 个工作日内交易此研究报告所讨论目标公司的证券。I, Rachel Wang, certify that (i) the views expressed in this research report accurately reflect my personal views about any or all of the subject companies or issuers referred to in this research and (ii) no part of my compensation was, is or will be directly or indirectly related to the specific recommendations or views expressed in this research report; and that I (including members of my household) have no financial interest in the security or securities of the subject companies discussed. I and my household, whom I have already notified of this, will not deal in or trade any securities in respect of the issuer that I review within 3 business days after the research report is published.

我，李加惠，在此保证 (i) 本研究报告中的意见准确反映了我们对本研究中提及的任何或所有目标公司或上市公司的个人观点，并且 (ii) 我的报酬中没有任何部分与本研究报告中表达的具体建议或观点直接或间接相关；及就此报告中所讨论目标公司的证券，我们 (包括我们的家属) 在其中均不持有任何财务利益。我和我的家属 (我已经告知他们) 将不会在本研究报告发布后的 3 个工作日内交易此研究报告所讨论目标公司的证券。I, Jiahui Li, certify that (i) the views expressed in this research report accurately reflect my personal views about any or all of the subject companies or issuers referred to in this research and (ii) no part of my compensation was, is or will be directly or indirectly related to the specific recommendations or views expressed in this research report; and that I (including members of my household) have no financial interest in the security or securities of the subject companies discussed. I and my household, whom I have already notified of this, will not deal in or trade any securities in respect of the issuer that I review within 3 business days after the research report is published.

我，白玉，在此保证 (i) 本研究报告中的意见准确反映了我们对本研究中提及的任何或所有目标公司或上市公司的个人观点，并且 (ii) 我的报酬中没有任何部分与本研究报告中表达的具体建议或观点直接或间接相关；及就此报告中所讨论目标公司的证券，我们 (包括我们的家属) 在其中均不持有任何财务利益。我和我的家属 (我已经告知他们) 将不会在本研究

报告发布后的3个工作日内交易此研究报告所讨论目标公司的证券。I, Jasmine Bai, certify that (i) the views expressed in this research report accurately reflect my personal views about any or all of the subject companies or issuers referred to in this research and (ii) no part of my compensation was, is or will be directly or indirectly related to the specific recommendations or views expressed in this research report; and that I (including members of my household) have no financial interest in the security or securities of the subject companies discussed. I and my household, whom I have already notified of this, will not deal in or trade any securities in respect of the issuer that I review within 3 business days after the research report is published.

我, 郑创凯, 在此保证 (i) 本研究报告中的意见准确反映了我们对本研究中提及的任何或所有目标公司或上市公司的个人观点, 并且 (ii) 我的报酬中没有任何部分与本研究报告中表达的具体建议或观点直接或间接相关; 及就此报告中所讨论目标公司的证券, 我们 (包括我们的家属) 在其中均不持有任何财务利益。我和我的家属 (我已经告知他们) 将不会在本研究报告发布后的3个工作日内交易此研究报告所讨论目标公司的证券。I, Evan Zheng, certify that (i) the views expressed in this research report accurately reflect my personal views about any or all of the subject companies or issuers referred to in this research and (ii) no part of my compensation was, is or will be directly or indirectly related to the specific recommendations or views expressed in this research report; and that I (including members of my household) have no financial interest in the security or securities of the subject companies discussed. I and my household, whom I have already notified of this, will not deal in or trade any securities in respect of the issuer that I review within 3 business days after the research report is published.

我, 杨昊翎, 在此保证 (i) 本研究报告中的意见准确反映了我们对本研究中提及的任何或所有目标公司或上市公司的个人观点, 并且 (ii) 我的报酬中没有任何部分与本研究报告中表达的具体建议或观点直接或间接相关; 及就此报告中所讨论目标公司的证券, 我们 (包括我们的家属) 在其中均不持有任何财务利益。我和我的家属 (我已经告知他们) 将不会在本研究报告发布后的3个工作日内交易此研究报告所讨论目标公司的证券。I, Harry Yang, certify that (i) the views expressed in this research report accurately reflect my personal views about any or all of the subject companies or issuers referred to in this research and (ii) no part of my compensation was, is or will be directly or indirectly related to the specific recommendations or views expressed in this research report; and that I (including members of my household) have no financial interest in the security or securities of the subject companies discussed. I and my household, whom I have already notified of this, will not deal in or trade any securities in respect of the issuer that I review within 3 business days after the research report is published.

利益冲突披露 Conflict of Interest Disclosures

海通国际及其某些关联公司可从事投资银行业务和/或对本研究中的特定股票或公司进行做市或持有自营头寸。就本研究报告而言, 以下是有关该等关系的披露事项 (以下披露不能保证及时无遗漏, 如需了解及时全面信息, 请发邮件至 ERD-Disclosure@htsec.com)

HTI and some of its affiliates may engage in investment banking and /or serve as a market maker or hold proprietary trading positions of certain stocks or companies in this research report. As far as this research report is concerned, the following are the disclosure matters related to such relationship (As the following disclosure does not ensure timeliness and completeness, please send an email to ERD-Disclosure@htsec.com if timely and comprehensive information is needed).

海通证券股份有限公司和/或其子公司 (统称“海通”) 在过去12个月内参与了 INTC.US, AAPL.US, 600584.CH, 002156.CH, 2438.HK, JD.US, 601595.CH and 688012.CH 的投资银行项目。投资银行项目包括: 1、海通担任上市前辅导机构、保荐人或主承销商的首次公开发行项目; 2、海通作为保荐人、主承销商或财务顾问的股权或债务再融资项目; 3、海通作为主经纪商的新三板上市、目标配售和并购项目。

Haitong Securities Co., Ltd. and/or its subsidiaries (collectively, the "Haitong") have a role in investment banking projects of INTC.US, AAPL.US, 600584.CH, 002156.CH, 2438.HK, JD.US, 601595.CH and 688012.CH within the past 12 months. The investment banking projects include 1. IPO projects in which Haitong acted as pre-listing tutor, sponsor, or lead-underwriter; 2. equity or debt refinancing projects of INTC.US, AAPL.US, 600584.CH, 002156.CH, 2438.HK, JD.US, 601595.CH and 688012.CH for which Haitong acted as sponsor, lead-underwriter or financial advisor; 3. listing by introduction in the new three board, target placement, M&A projects in which Haitong acted as lead-brokerage firm.

600584.CH, 002156.CH, 0020.HK, 2438.HK, JD.US, 601595.CH 及 688012.CH 目前或过去12个月内是海通的投资银行业务客户。

600584.CH, 002156.CH, 0020.HK, 2438.HK, JD.US, 601595.CH and 688012.CH are/were an investment bank clients of Haitong currently or within the past 12 months.

阿里巴巴 (北京) 软件服务有限公司, 阿里巴巴 (成都) 软件技术有限公司, 阿里巴巴 (中国) 网络技术有限公司, 杭州阿里巴巴泽泰信息技术有限公司, 北京东方宝辰国际投资有限公司, 北京东方贝格资产管理有限公司-东方贝格二十号君博澄明多策略私募证券投资基金, 北京东方贝格资产管理有限公司-东方贝格二十一号华宇顺为均衡配置私募证券投资基金, 北京东方贝格资产管理有限公司-东方贝格泓海1号私募证券投资基金, 北京东方华晟投资管理有限公司, 北京东方顺泰金属制品有限公司, 北京东方蜗牛投资管理有限公司, 北京东方蜗牛投资管理有限公司-东方蜗牛复合策略一号基金, 北京东方蜗牛投资管理有限公司-东方蜗牛积极进取二号私募基金, 北京东方蜗牛投资管理有限公司-东方蜗牛稳健回报三号私募基金, 北京东方引擎投资管理有限公司-引擎资本基金长青混合私募证券投资基金, 北京东方两虹防水技术股份有限公司, 北京东方两虹防水技术股份有限公司回购专用证券账户, 北京东海长基投资基金管理有限公司, 北京东世佳商贸有限公司, 北京东泰阳光纺织品有限公司, 北京东绿谷农业科技有限公司, 富诚海富资管-北京东方两虹防水技术股份有限公司2021年员工持股计划-富诚海富通东方两虹员工持股单一资产管理计划, 南京东宇汽车集团有限公司, 上海京东工贸商行, 北京东方蜗牛投资管理有限公司-东方蜗牛复合策略一号基金, 北京新网易融科技发展有限公司, 云南网特信息产业有限公司, 北京新网易融科技发展有限公司, 002558.CH, 广东南方传媒投资有限公司, 杭州塞帕思投资管理有限公司-塞帕思特斯拉指数增强私募证券投资基金, 广东小鹏汽车科技有限公司, 002705.CH, 002008.CH, 300133.CH 及中微半导体设备 (上海) 股份有限公司目前或过去12个月内是海通的客户。海通向客户提供非投资银行业务的证券相关业务服务。

阿里巴巴 (北京) 软件服务有限公司, 阿里巴巴 (成都) 软件技术有限公司, 阿里巴巴 (中国) 网络技术有限公司, 杭州阿里巴巴泽泰信息技术有限公司, 北京东方宝辰国际投资有限公司, 北京东方贝格资产管理有限公司-东方贝格二十号君博澄明多策略私募证券投资基金, 北京东方贝格资产管理有限公司-东方贝格二十一号华宇顺为均衡配置私募证券投资基金, 北京东方贝格资产管理有限公司-东方贝格泓海1号私募证券投资基金, 北京东方华晟投资管理有限公司, 北京东方顺泰金属制品有限公司, 北京东方蜗牛投资管理有限公司, 北京东方蜗牛投资管理有限公司-东方蜗牛复合策略一号基金, 北京东方蜗牛投资管理有限公司-东方蜗牛积极进取二号私募基金, 北京东方蜗牛投资管理有限公司-东方蜗牛稳健回报三号私募基金, 北京东方引擎投资管理有限公司-引擎资本基金长青混合私募证券投资基金, 北京东方两虹防水技术股份有限公司, 北京东方两虹防水技术股份有限公司回购专用证券账户, 北京东海长基投资基金管理有限公司, 北京东世佳商贸有限公司, 北京东泰阳光纺织品有限公司, 北京东绿谷农业科技有限公司, 富诚海富资管-北京东方两虹防水技术股份有限公司2021年员工持股计划-富诚海富通东方两虹员工持股单一资产管理计划, 南京东宇汽车集团有限公司, 上海京东工贸商行, 北京东方蜗牛投资管理有限公司-东方蜗牛复合策略一号基金, 北京新网易融科技发展有限公司, 云南网特信息产业有限公司, 北京新网易融科技发展有限公司, 002558.CH, 广东南方传媒投资有限公司, 杭州塞帕思投资管理有限公司-塞帕思特斯拉指数增强私募证券投资基金, 广东小鹏汽车科技有限公司, 002705.CH, 002008.CH, 300133.CH 及中微半导体设备 (上海) 股份有限公司 are/were a client of Haitong currently or within the past 12 months. The client

has been provided for non-investment-banking securities-related services.

海通在过去 12 个月中获得对 0020.HK 提供投资银行服务的报酬。

Haitong received in the past 12 months compensation for investment banking services provided to 0020.HK.

海通在过去的 12 个月中从阿里巴巴（北京）软件服务有限公司, 阿里巴巴（成都）软件技术有限公司, 阿里巴巴（中国）网络技术有限公司, 杭州阿里巴巴泽泰信息技术有限公司, 北京东方宝辰国际投资有限公司, 北京东方贝格资产管理有限公司 - 东方贝格二十号君博澄明多策略私募基金, 北京东方贝格资产管理有限公司 - 东方贝格二十一号华宇顺为均衡配置私募基金, 北京东方贝格资产管理有限公司 - 东方贝格泓海 1 号私募基金, 北京东方华晟投资管理有限公司, 北京东方顺泰金属制品有限公司, 北京东方蜗牛投资管理有限公司, 北京东方蜗牛投资管理有限公司 - 东方蜗牛复合策略一号基金, 北京东方蜗牛投资管理有限公司 - 东方蜗牛积极进取二号私募基金, 北京东方蜗牛投资管理有限公司 - 东方蜗牛稳健回报三号私募基金, 北京东方引擎投资管理有限公司 - 引擎资本基金长青混合私募基金, 北京东方两虹防水技术股份有限公司, 北京东方两虹防水技术股份有限公司回购专用证券账户, 北京东海长基投资基金管理有限公司, 北京东世佳商贸有限公司, 北京东泰阳光纺织品有限公司, 北京东绿谷农业科技有限公司, 富诚海富资管 - 北京东方两虹防水技术股份有限公司 2021 年员工持股计划 - 富诚海富通东方两虹员工持股单一资产管理计划, 南京东宇汽车集团有限公司, 上海京东工贸有限公司, 002558.CH, 杭州塞帕思投资管理有限公司 - 塞帕思特斯拉指数增强私募基金, 300133.CH 及中微半导体设备（上海）股份有限公司获得除投资银行服务以外之产品或服务的报酬。

Haitong has received compensation in the past 12 months for products or services other than investment banking from 阿里巴巴（北京）软件服务有限公司, 阿里巴巴（成都）软件技术有限公司, 阿里巴巴（中国）网络技术有限公司, 杭州阿里巴巴泽泰信息技术有限公司, 北京东方宝辰国际投资有限公司, 北京东方贝格资产管理有限公司 - 东方贝格二十号君博澄明多策略私募基金, 北京东方贝格资产管理有限公司 - 东方贝格二十一号华宇顺为均衡配置私募基金, 北京东方贝格资产管理有限公司 - 东方贝格泓海 1 号私募基金, 北京东方华晟投资管理有限公司, 北京东方顺泰金属制品有限公司, 北京东方蜗牛投资管理有限公司, 北京东方蜗牛投资管理有限公司 - 东方蜗牛复合策略一号基金, 北京东方蜗牛投资管理有限公司 - 东方蜗牛积极进取二号私募基金, 北京东方蜗牛投资管理有限公司 - 东方蜗牛稳健回报三号私募基金, 北京东方引擎投资管理有限公司 - 引擎资本基金长青混合私募基金, 北京东方两虹防水技术股份有限公司, 北京东方两虹防水技术股份有限公司回购专用证券账户, 北京东海长基投资基金管理有限公司, 北京东世佳商贸有限公司, 北京东泰阳光纺织品有限公司, 北京东绿谷农业科技有限公司, 富诚海富资管 - 北京东方两虹防水技术股份有限公司 2021 年员工持股计划 - 富诚海富通东方两虹员工持股单一资产管理计划, 南京东宇汽车集团有限公司, 上海京东工贸有限公司, 002558.CH, 杭州塞帕思投资管理有限公司 - 塞帕思特斯拉指数增强私募基金, 300133.CH and 中微半导体设备（上海）股份有限公司.

评级定义 (从 2020 年 7 月 1 日开始执行):

海通国际（以下简称“HTI”）采用相对评级系统来为投资者推荐我们覆盖的公司：优于大市、中性或弱于大市。投资者应仔细阅读 HTI 的评级定义。并且 HTI 发布分析师观点的完整信息，投资者应仔细阅读全文而非仅看评级。在任何情况下，分析师的评级和研究都不能作为投资建议。投资者的买卖股票的决策应基于各自情况（比如投资者的现有持仓）以及其他因素。

分析师股票评级

优于大市，未来 12-18 个月内预期相对基准指数涨幅在 10% 以上，基准定义如下

中性，未来 12-18 个月内预期相对基准指数变化不大，基准定义如下。根据 FINRA/NYSE 的评级分布规则，我们会将中性评级划入持有这一类别。

弱于大市，未来 12-18 个月内预期相对基准指数跌幅在 10% 以上，基准定义如下

各地股票基准指数：日本 - TOPIX, 韩国 - KOSPI, 台湾 - TAIEX, 印度 - Nifty100, 美国 - SP500; 其他所有中国概念股 - MSCI China.

Ratings Definitions (from 1 Jul 2020):





Haitong International uses a relative rating system using Outperform, Neutral, or Underperform for recommending the stocks we cover to investors. Investors should carefully read the definitions of all ratings used in Haitong International Research. In addition, since Haitong International Research contains more complete information concerning the analyst's views, investors should carefully read Haitong International Research, in its entirety, and not infer the contents from the rating alone. In any case, ratings (or research) should not be used or relied upon as investment advice. An investor's decision to buy or sell a stock should depend on individual circumstances (such as the investor's existing holdings) and other considerations.

Analyst Stock Ratings

Outperform: The stock's total return over the next 12-18 months is expected to exceed the return of its relevant broad market benchmark, as indicated below.

Neutral: The stock's total return over the next 12-18 months is expected to

评级分布 Rating Distribution



be in line with the return of its relevant broad market benchmark, as indicated below. For purposes only of FINRA/NYSE ratings distribution rules, our Neutral rating falls into a hold rating category.

Underperform: The stock's total return over the next 12-18 months is expected to be below the return of its relevant broad market benchmark, as indicated below.

Benchmarks for each stock's listed region are as follows: Japan – TOPIX, Korea – KOSPI, Taiwan – TAIEX, India – Nifty100, US – SP500; for all other China-concept stocks – MSCI China.

截至 2024 年 3 月 31 日海通国际股票研究评级分布

	优于大市	中性 (持有)	弱于大市
海通国际股票研究覆盖率	90.4%	8.8%	0.8%
投资银行客户*	3.3%	4.9%	0.0%

*在每个评级类别里投资银行客户所占的百分比。

上述分布中的买入，中性和卖出分别对应我们当前优于大市，中性和落后大市评级。

只有根据 FINRA/NYSE 的评级分布规则，我们才将中性评级划入持有这一类别。请注意在上表中不包含非评级的股票。

此前的评级系统定义（直至 2020 年 6 月 30 日）：

买入，未来 12-18 个月内预期相对基准指数涨幅在 10%以上，基准定义如下

中性，未来 12-18 个月内预期相对基准指数变化不大，基准定义如下。根据 FINRA/NYSE 的评级分布规则，我们会将中性评级划入持有这一类别。

卖出，未来 12-18 个月内预期相对基准指数跌幅在 10%以上，基准定义如下

各地股票基准指数：日本 – TOPIX, 韩国 – KOSPI, 台湾 – TAIEX, 印度 – Nifty100; 其他所有中国概念股 – MSCI China.

Haitong International Equity Research Ratings Distribution, as of March 31, 2024

	Outperform	Neutral (hold)	Underperform
HTI Equity Research Coverage	90.4%	8.8%	0.8%
IB clients*	3.3%	4.9%	0.0%

*Percentage of investment banking clients in each rating category.

BUY, Neutral, and SELL in the above distribution correspond to our current ratings of Outperform, Neutral, and Underperform.

For purposes only of FINRA/NYSE ratings distribution rules, our Neutral rating falls into a hold rating category. Please note that stocks with an NR designation are not included in the table above.

Previous rating system definitions (until 30 Jun 2020):

BUY: The stock's total return over the next 12-18 months is expected to exceed the return of its relevant broad market benchmark, as indicated below.

NEUTRAL: The stock's total return over the next 12-18 months is expected to be in line with the return of its relevant broad market benchmark, as indicated below. For purposes only of FINRA/NYSE ratings distribution rules, our Neutral rating falls into a hold rating category.

SELL: The stock's total return over the next 12-18 months is expected to be below the return of its relevant broad market benchmark, as indicated below.

Benchmarks for each stock's listed region are as follows: Japan – TOPIX, Korea – KOSPI, Taiwan – TAIEX, India – Nifty100; for all other China-concept stocks – MSCI China.

海通国际非评级研究：海通国际发布计量、筛选或短篇报告，并在报告中根据估值和其他指标对股票进行排名，或者基于可能的估值倍数提出建议价格。这种排名或建议价格并非为了进行股票评级、提出目标价格或进行基本面估值，而仅供参考使用。

Haitong International Non-Rated Research: Haitong International publishes quantitative, screening or short reports which may rank stocks according to valuation and other metrics or may suggest prices based on possible valuation multiples. Such rankings or suggested prices do not purport to be stock ratings or target prices or fundamental values and are for information only.

海通国际 A 股覆盖：海通国际可能会就沪港通及深港通的中国 A 股进行覆盖及评级。海通证券（600837.CH），海通国际于上海的母公司，也会于中国发布中国 A 股的研究报告。但是，海通国际使用与海通证券不同的评级系统，所以海通国际与海通证券的中国 A 股评级可能有所不同。

Haitong International Coverage of A-Shares: Haitong International may cover and rate A-Shares that are subject to the Hong Kong Stock Connect scheme with Shanghai and Shenzhen. Haitong Securities (HS: 600837 CH), the ultimate parent company of HTISG based in Shanghai, covers and publishes research on these same A-Shares for distribution in mainland China. However, the rating system employed by HS differs from that used by HTI and as a result there may be a difference in the HTI and HS ratings for the same A-share stocks.

海通国际优质 100 A 股（Q100）指数：海通国际 Q100 指数是一个包括 100 支由海通证券覆盖的优质中国 A 股的计量产品。这些股票是通过基于质量的筛选过程，并结合对海通证券 A 股团队自下而上的研究。海通国际每季对 Q100 指数成分作出复审。

Haitong International Quality 100 A-share (Q100) Index: HTI's Q100 Index is a quant product that consists of 100 of the highest-quality A-shares under coverage at HS in Shanghai. These stocks are carefully selected through a quality-based screening process in combination with a review of the HS A-share team's bottom-up research. The Q100 constituent companies are reviewed quarterly.

盟浪义利 (FIN-ESG) 数据免责声明条款: 在使用盟浪义利 (FIN-ESG) 数据之前, 请务必仔细阅读本条款并同意本声明:

第一条 义利 (FIN-ESG) 数据系由盟浪可持续数字科技有限责任公司 (以下简称“本公司”) 基于合法取得的公开信息评估而成, 本公司对信息的准确性及完整性不作任何保证。对公司上述的评估结果造成的任何直接或间接损失负责。

第二条 盟浪并不因收到此评估数据而将收件人视为客户, 收件人使用此数据时应根据自身实际情况作出自我独立判断。本数据所载内容反映的是盟浪在最初发布本数据日期当日的判断, 盟浪有权在不发出通知的情况下更新、修订与发出其他与本数据所载内容不一致或有不同结论的数据。除非另行说明, 本数据 (如财务业绩数据等) 仅代表过往表现, 过往的业绩表现不作为日后回报的预测。

第三条 本数据版权归本公司所有, 本公司依法保留各项权利。未经本公司事先书面许可授权, 任何个人或机构不得将本数据中的评估结果用于任何营利性目的, 不得对本数据进行修改、复制、编译、汇编、再次编辑、改编、删减、缩写、节选、发行、出租、展览、表演、放映、广播、信息网络传播、摄制、增加图标及说明等, 否则因此给盟浪或其他第三方造成损失的, 由用户承担相应的赔偿责任, 盟浪不承担责任。

第四条 如本免责声明未约定, 而盟浪网站平台载明的其他协议内容 (如《盟浪网站用户注册协议》《盟浪网用户服务 (含认证) 协议》《盟浪网隐私政策》等) 有约定的, 则按其他协议的约定执行; 若本免责声明与其他协议约定存在冲突或不一致的, 则以本免责声明约定为准。

SusallWave FIN-ESG Data Service Disclaimer: Please read these terms and conditions below carefully and confirm your agreement and acceptance with these terms before using SusallWave FIN-ESG Data Service.

1. FIN-ESG Data is produced by SusallWave Digital Technology Co., Ltd. (In short, SusallWave's assessment based on legal publicly accessible information. SusallWave shall not be responsible for any accuracy and completeness of the information. The assessment result is for reference only. It is not for any investment advice for any individual or institution and not for basis of purchasing, selling or holding any relative financial products. We will not be liable for any direct or indirect loss of any individual or institution as a result of using SusallWave FIN-ESG Data.

2. SusallWave do not consider recipients as customers for receiving these data. When using the data, recipients shall make your own independent judgment according to your practical individual status. The contents of the data reflect the judgment of us only on the release day. We have right to update and amend the data and release other data that contains inconsistent contents or different conclusions without notification. Unless expressly stated, the data (e.g., financial performance data) represents past performance only and the past performance cannot be viewed as the prediction of future return.

3. The copyright of this data belongs to SusallWave, and we reserve all rights in accordance with the law. Without the prior written permission of our company, none of individual or institution can use these data for any profitable purpose. Besides, none of individual or institution can take actions such as amendment, replication, translation, compilation, re-editing, adaption, deletion, abbreviation, excerpts, issuance, rent, exhibition, performance, projection, broadcast, information network transmission, shooting, adding icons and instructions. If any loss of SusallWave or any third-party is caused by those actions, users shall bear the corresponding compensation liability. SusallWave shall not be responsible for any loss.

4. If any term is not contained in this disclaimer but written in other agreements on our website (e.g. User Registration Protocol of SusallWave Website, User Service (including authentication) Agreement of SusallWave Website, Privacy Policy of Susallwave Website), it should be executed according to other agreements. If there is any difference between this disclaimer and other agreements, this disclaimer shall be applied.

重要免责声明:

非印度证券的研究报告: 本报告由海通国际证券集团有限公司 (“HTISGL”) 的全资附属公司海通国际研究有限公司 (“HTIRL”) 发行, 该公司是根据香港证券及期货条例 (第 571 章) 持有第 4 类受规管活动 (就证券提供意见) 的持牌法团。该研究报告在 HTISGL 的全资附属公司 Haitong International (Japan) K.K. (“HTIJK”) 的协助下发行; HTIJK 是由日本关东财务局监管为投资顾问。

印度证券的研究报告: 本报告由从事证券交易、投资银行及证券分析及受 Securities and Exchange Board of India (“SEBI”) 监管的 Haitong Securities India Private Limited (“HTSIPL”) 所发行, 包括制作及发布涵盖 BSE Limited (“BSE”) 和 National Stock Exchange of India Limited (“NSE”) 上市公司 (统称为「印度交易所」) 的研究报告。HTSIPL 于 2016 年 12 月 22 日被收购并成为海通国际证券集团有限公司 (“HTISG”) 的一部分。

所有研究报告均以海通国际为名作为全球品牌, 经许可由海通国际证券股份有限公司及/或海通国际证券集团的其他成员在其司法管辖区发布。

本文件所载信息和观点已被编译或源自可靠来源, 但 HTIRL、HTISGL 或任何其他属于海通国际证券集团有限公司 (“HTISG”) 的成员对其准确性、完整性和正确性不做任何明示或暗示的声明或保证。本文件中所有观点均截至本报告日期, 如有更改, 恕不另行通知。本文件仅供参考使用。文件中提及的任何公司或其股票的说明并非意图展示完整的内容, 本文件并非/不应被解释为对证券买卖的明示或暗示地出价或征价。在某些司法管辖区, 本文件中提及的证券可能无法进行买卖。如果投资产品以投资者本国货币以外的币种进行计价, 则汇率变化可能会对投资产生不利影响。过去的表现并不一定代表将来的结果。某些特定交易, 包括设计金融衍生工具的, 有产生重大风险的可能性, 因此并不适合所有的投资者。您还应认识到本文件中的建议并非为您量身定制。分析师并未考虑到您自身的财务情况, 如您的财务状况和风险偏好。因此您必须自行分析并在适用的情况下咨询自己的法律、税收、会计、金融和其他方面的专业顾问, 以期在投资之前评估该项建议是否适合于您。若由于使用本文件所载的材料而产生任何直接或间接的损失, HTISG 及其董事、雇员或代理人对此均不承担任何责任。

除对本文件内容承担责任的分析师外, HTISG 及其关联公司、高级管理人员、董事和雇员, 均可不时作为主事人就本文件所述的任何证券或衍生品持有长仓或短仓以及进行买卖。HTISG 的销售员、交易员和其他专业人士均可向 HTISG 的相关客户和公司提供与本文件所述意见相反的口头或书面市场评论意见或交易策略。HTISG 可做出与本文件所述建议或意见不一致的投资决策。但 HTIRL 没有义务来确保本文件的收件人了解到该等交易决定、思路或建议。

请访问海通国际网站 www.equities.htisec.com, 查阅更多有关海通国际为预防和避免利益冲突设立的组织 and 行政安排的内容信息。

非美国分析师披露信息: 本项研究首页上列明的海通国际分析师并未在 FINRA 进行注册或者取得相应的资格, 并且不受美国 FINRA 有关与本项研究目标公司进行沟通、公开露面和自营

证券交易的第 2241 条规则之限制。

IMPORTANT DISCLAIMER

For research reports on non-Indian securities: The research report is issued by Haitong International Research Limited ("HTIRL"), a wholly owned subsidiary of Haitong International Securities Group Limited ("HTISGL") and a licensed corporation to carry on Type 4 regulated activity (advising on securities) for the purpose of the Securities and Futures Ordinance (Cap. 571) of Hong Kong, with the assistance of Haitong International (Japan) K.K. ("HTIJKK"), a wholly owned subsidiary of HTISGL and which is regulated as an Investment Adviser by the Kanto Finance Bureau of Japan.

For research reports on Indian securities: The research report is issued by Haitong Securities India Private Limited ("HSIPL"), an Indian company and a Securities and Exchange Board of India ("SEBI") registered Stock Broker, Merchant Banker and Research Analyst that, inter alia, produces and distributes research reports covering listed entities on the BSE Limited ("BSE") and the National Stock Exchange of India Limited ("NSE") (collectively referred to as "Indian Exchanges"). HSIPL was acquired and became part of the Haitong International Securities Group of Companies ("HTISG") on 22 December 2016.

All the research reports are globally branded under the name Haitong International and approved for distribution by Haitong International Securities Company Limited ("HTISCL") and/or any other members within HTISG in their respective jurisdictions.

The information and opinions contained in this research report have been compiled or arrived at from sources believed to be reliable and in good faith but no representation or warranty, express or implied, is made by HTIRL, HTISCL, HSIPL, HTIJKK or any other members within HTISG from which this research report may be received, as to their accuracy, completeness or correctness. All opinions expressed herein are as of the date of this research report and are subject to change without notice. This research report is for information purpose only. Descriptions of any companies or their securities mentioned herein are not intended to be complete and this research report is not, and should not be construed expressly or impliedly as, an offer to buy or sell securities. The securities referred to in this research report may not be eligible for purchase or sale in some jurisdictions. If an investment product is denominated in a currency other than an investor's home currency, a change in exchange rates may adversely affect the investment. Past performance is not necessarily indicative of future results. Certain transactions, including those involving derivatives, give rise to substantial risk and are not suitable for all investors. You should also bear in mind that recommendations in this research report are not tailor-made for you. The analyst has not taken into account your unique financial circumstances, such as your financial situation and risk appetite. You must, therefore, analyze and should, where applicable, consult your own legal, tax, accounting, financial and other professional advisers to evaluate whether the recommendations suits you before investment. Neither HTISG nor any of its directors, employees or agents accepts any liability whatsoever for any direct or consequential loss arising from any use of the materials contained in this research report.

HTISG and our affiliates, officers, directors, and employees, excluding the analysts responsible for the content of this document, will from time to time have long or short positions in, act as principal in, and buy or sell, the securities or derivatives, if any, referred to in this research report. Sales, traders, and other professionals of HTISG may provide oral or written market commentary or trading strategies to the relevant clients and the companies within HTISG that reflect opinions that are contrary to the opinions expressed in this research report. HTISG may make investment decisions that are inconsistent with the recommendations or views expressed in this research report. HTI is under no obligation to ensure that such other trading decisions, ideas or recommendations are brought to the attention of any recipient of this research report.

Please refer to HTI's website www.equities.htisec.com for further information on HTI's organizational and administrative arrangements set up for the prevention and avoidance of conflicts of interest with respect to Research.

Non U.S. Analyst Disclosure: The HTI analyst(s) listed on the cover of this Research is (are) not registered or qualified as a research analyst with FINRA and are not subject to U.S. FINRA Rule 2241 restrictions on communications with companies that are the subject of the Research; public appearances; and trading securities by a research analyst.

分发和地区通知:

除非下文另有规定, 否则任何希望讨论本报告或者就本项研究中讨论的任何证券进行任何交易的收件人均应联系其所在国家或地区的海通国际销售人员。

香港投资者的通知事项: 海通国际证券股份有限公司("HTISCL")负责分发该研究报告, HTISCL 是在香港有实权实施第 1 类受规管活动(从事证券交易)的持牌公司。该研究报告并不构成《证券及期货条例》(香港法例第 571 章)(以下简称"SFO")所界定的要约邀请, 证券要约或公众要约。本研究报告仅提供给 SFO 所界定的"专业投资者"。本研究报告未经过证券及期货事务监察委员会的审查。您不应仅根据本研究报告中所载的信息做出投资决定。本研究报告的收件人就研究报告中产生或与之相关的任何事宜请联系 HTISCL 销售人员。

美国投资者的通知事项: 本研究报告由 HTIRL, HSIPL 或 HTIJKK 编写。HTIRL, HSIPL, HTIJKK 以及任何非 HTISG 美国联营公司, 均未在美国注册, 因此不受美国关于研究报告编制和研究分析人员独立性规定的约束。本研究报告提供给依照 1934 年"美国证券交易法"第 15a-6 条规定的豁免注册的「美国主要机构投资者」("Major U.S. Institutional Investor")和「机构投资者」("U.S. Institutional Investors")。在向美国机构投资者分发研究报告时, Haitong International Securities (USA) Inc. ("HTI USA") 将对报告的内容负责。任何收到本研究报告的美国投资者, 希望根据本研究报告提供的信息进行任何证券或相关金融工具买卖的交易, 只能通过 HTI USA。HTI USA 位于 340 Madison Avenue, 12th Floor, New York, NY 10173, 电话(212) 351-6050。HTI USA 是在美国于 U.S. Securities and Exchange Commission ("SEC") 注册的经纪商, 也是 Financial Industry Regulatory Authority, Inc. ("FINRA") 的成员。HTIUSA 不负责编写本研究报告, 也不负责其中包含的分析。在任何情况下, 收到本研究报告的任何美国投资者, 不得直接与分析师直接联系, 也不得通过 HSIPL, HTIRL 或 HTIJKK 直接进行买卖证券或相关金融工具的交易。本研究报告中出现的 HSIPL, HTIRL 或 HTIJKK 分析师没有注册或具备 FINRA 的研究分析师资格, 因此可能不受 FINRA 第 2241 条规定的与目标公司的交流, 公开露面和分析师账户持有的交易证券等限制。投资本研究报告中讨论的任何非美国证券或相关金融工具(包括 ADR)可能存在一定风险。非美国发行的证券可能没有注册, 或不受美国法规的约束。有关非美国证券或相关金融工具的信息可能有限制。外国公司可能不受审计和汇报的标准以及与美国境内生效相符的监管要求。本研究报告中以美元以外的其他货币计价的任何证券或相关金融工具的投资或收益的价值受汇率波动的影响, 可能对该等证券或相关金融工具的价值或收入产生正面或负面影响。美国收件人的所有问询请联系:

Haitong International Securities (USA) Inc.
340 Madison Avenue, 12th Floor
New York, NY 10173
联系人电话: (212) 351 6050

DISTRIBUTION AND REGIONAL NOTICES

Except as otherwise indicated below, any Recipient wishing to discuss this research report or effect any transaction in any security discussed in HTI's research should contact the Haitong International salesperson in their own country or region.

Notice to Hong Kong investors: The research report is distributed by Haitong International Securities Company Limited ("HTISCL"), which is a licensed corporation to carry on Type 1 regulated activity (dealing in securities) in Hong Kong. This research report does not constitute a solicitation or an offer of securities or an invitation to the public within the meaning of the SFO. This research report is only to be circulated to "Professional Investors" as defined in the SFO. This research report has not been reviewed by the Securities and Futures Commission. You should not make investment decisions solely on the basis of the information contained in this research report. Recipients of this research report are to contact HTISCL salespersons in respect of any matters arising from, or in connection with, the research report.

Notice to U.S. investors: As described above, this research report was prepared by HTIRL, HSIPL or HTIJKK. Neither HTIRL, HSIPL, HTIJKK, nor any of the non-U.S. HTISG affiliates is registered in the United States and, therefore, is not subject to U.S. rules regarding the preparation of research reports and the independence of research analysts. This research report is provided for distribution to "major U.S. institutional investors" and "U.S. institutional investors" in reliance on the exemption from registration provided by Rule 15a-6 of the U.S. Securities Exchange Act of 1934, as amended. When distributing research reports to "U.S. institutional investors," HTI USA will accept the responsibilities for the content of the reports. Any U.S. recipient of this research report wishing to effect any transaction to buy or sell securities or related financial instruments based on the information provided in this research report should do so only through Haitong International Securities (USA) Inc. ("HTI USA"), located at 340 Madison Avenue, 12th Floor, New York, NY 10173, USA; telephone (212) 351 6050. HTI USA is a broker-dealer registered in the U.S. with the U.S. Securities and Exchange Commission (the "SEC") and a member of the Financial Industry Regulatory Authority, Inc. ("FINRA"). HTI USA is not responsible for the preparation of this research report nor for the analysis contained therein. Under no circumstances should any U.S. recipient of this research report contact the analyst directly or effect any transaction to buy or sell securities or related financial instruments directly through HSIPL, HTIRL or HTIJKK. The HSIPL, HTIRL or HTIJKK analyst(s) whose name appears in this research report is not registered or qualified as a research analyst with FINRA and, therefore, may not be subject to FINRA Rule 2241 restrictions on communications with a subject company, public appearances and trading securities held by a research analyst account. Investing in any non-U.S. securities or related financial instruments (including ADRs) discussed in this research report may present certain risks. The securities of non-U.S. issuers may not be registered with, or be subject to U.S. regulations. Information on such non-U.S. securities or related financial instruments may be limited. Foreign companies may not be subject to audit and reporting standards and regulatory requirements comparable to those in effect within the U.S. The value of any investment or income from any securities or related financial instruments discussed in this research report denominated in a currency other than U.S. dollars is subject to exchange rate fluctuations that may have a positive or adverse effect on the value of or income from such securities or related financial instruments. All inquiries by U.S. recipients should be directed to:

Haitong International Securities (USA) Inc.
340 Madison Avenue, 12th Floor
New York, NY 10173
Attn: Sales Desk at (212) 351 6050

中华人民共和国的通知事项: 在中华人民共和国(下称“中国”,就本报告目的而言,不包括香港特别行政区、澳门特别行政区和台湾)只有根据适用的中国法律法规而收到该材料的人员方可使用该材料。并且根据相关法律法规,该材料中的信息并不构成“在中国从事生产、经营活动”。本文件在中国并不构成相关证券的公开发售或认购。无论根据法律规定或其他任何规定,在取得中国政府所有的批准或许可之前,任何法人或自然人均不得直接或间接地购买本材料中的任何证券或任何权益。接收本文件的人员须遵守上述限制性规定。

加拿大投资者的通知事项: 在任何情况下该等材料均不得被解释为在任何加拿大的司法管辖区内出售证券的要约或认购证券的要约邀请。本材料中所述证券在加拿大的任何要约或出售行为均只能在豁免向有关加拿大证券监管机构提交招股说明书的前提下由 Haitong International Securities (USA) Inc. ("HTI USA") 予以实施,该公司是一家根据 National Instrument 31-103 Registration Requirements, Exemptions and Ongoing Registrant Obligations ("NI 31-103") 的规定得到「国际交易商豁免」("International Dealer Exemption") 的交易商,位于艾伯塔省、不列颠哥伦比亚省、安大略省和魁北克省。在加拿大,该等材料在任何情况下均不得被解释为任何证券的招股说明书、发行备忘录、广告或公开发行。加拿大的任何证券委员会或类似的监管机构均未审查或以任何方式批准该等材料,其中所载的信息或所述证券的优点,任何与此相反的声明即属违法。在收到该等材料时,每个加拿大的收件人均将被视为属于 National Instrument 45-106 Prospectus Exemptions 第 1.1 节或者 Securities Act (Ontario) 第 73.3(1) 节所规定的「认可投资者」("Accredited Investor"), 或者在适用情况下 National Instrument 31-103 第 1.1 节所规定的「许可投资者」("Permitted Investor")。

新加坡投资者的通知事项: 本研究报告由 Haitong International Securities (Singapore) Pte Ltd ("HTISSPL") [公司注册编号 201311400G] 于新加坡提供。HTISSPL 是符合《财务顾问法》(第 110 章) ("FAA") 定义的豁免财务顾问,可 (a) 提供关于证券,集体投资计划的部分,交易所衍生品合约和场外衍生品合约的建议 (b) 发行或公布有关证券、交易所衍生品合约和场外衍生品合约的研究分析或研究报告。本研究报告仅提供给符合《证券及期货法》(第 289 章) 第 4A 条项下规定的机构投资者。对于因本研究报告而产生的或与之相关的任何问题,本研究报告的收件人应通过以下信息与 HTISSPL 联系:

Haitong International Securities (Singapore) Pte. Ltd
50 Raffles Place, #33-03 Singapore Land Tower, Singapore 048623
电话: (65) 6536 1920

日本投资者的通知事项: 本研究报告由海通国际证券有限公司所发布,旨在分发给从事投资管理的金融服务提供商或注册金融机构(根据日本金融机构和交易法("FIEL")第 61 (1) 条,第 17-11 (1) 条的执行及相关条款)。

英国及欧盟投资者的通知事项: 本报告由从事投资顾问的 Haitong International Securities Company Limited 所发布,本报告只面向有投资相关经验的专业客户发布。任何投资或与本报告相关的投资行为只面对此类专业客户。没有投资经验或相关投资经验的客户不得依赖本报告。Haitong International Securities Company Limited 的分支机构的净长期或短期金融权益可能超过本研究报告中提及的实体已发行股本总额的 0.5%。特别提醒有些英文报告有可能此前已经通过中文或其它语言完成发布。

澳大利亚投资者的通知事项: Haitong International Securities (Singapore) Pte Ltd, Haitong International Securities Company Limited 和 Haitong International Securities (UK) Limited 分别根据澳大利亚证券和投资委员会(以下简称"ASIC")公司(废除及过度性)文书第 2016/396 号规章在澳大利亚分发本项研究,该等规章免除了根据 2001 年《公司法》在澳大利亚为批发客户提供金融服务时海通国际需持有澳大利亚金融服务许可的要求。ASIC 的规章副本可在以下网站获取: www.legislation.gov.au。海通国际提供的金融服务受外国法律法规规定的管制,该

等法律与在澳大利亚所适用的法律存在差异。

印度投资者的通知事项: 本报告由从事证券交易、投资银行及证券分析及受 Securities and Exchange Board of India (“SEBI”) 监管的 Haitong Securities India Private Limited (“HTSIPL”) 所发布, 包括制作及发布涵盖 BSE Limited (“BSE”) 和 National Stock Exchange of India Limited (“NSE”) (统称为「印度交易所」) 研究报告。

研究机构名称: Haitong Securities India Private Limited

SEBI 研究分析师注册号: INH000002590

地址: 1203A, Floor 12A, Tower 2A, One World Center

841 Senapati Bapat Marg, Elphinstone Road, Mumbai 400 013, India

CIN U74140MH2011FTC224070

电话: +91 22 43156800 传真: +91 22 24216327

合规和申诉办公室联系人: Prasanna Chandwaskar ; 电话: +91 22 43156803; 电子邮箱: prasanna.chandwaskar@htisec.com

“请注意, SEBI 授予的注册和 NISM 的认证并不保证中介的表现或为投资者提供任何回报保证”。

本项研究仅供收件人使用, 未经海通国际的书面同意不得予以复制和再次分发。

版权所有: 海通国际证券集团有限公司 2019 年。保留所有权利。

People's Republic of China (PRC): In the PRC, the research report is directed for the sole use of those who receive the research report in accordance with the applicable PRC laws and regulations. Further, the information on the research report does not constitute “production and business activities in the PRC” under relevant PRC laws. This research report does not constitute a public offer of the security, whether by sale or subscription, in the PRC. Further, no legal or natural persons of the PRC may directly or indirectly purchase any of the security or any beneficial interest therein without obtaining all prior PRC government approvals or licenses that are required, whether statutorily or otherwise. Persons who come into possession of this research are required to observe these restrictions.

Notice to Canadian Investors: Under no circumstances is this research report to be construed as an offer to sell securities or as a solicitation of an offer to buy securities in any jurisdiction of Canada. Any offer or sale of the securities described herein in Canada will be made only under an exemption from the requirements to file a prospectus with the relevant Canadian securities regulators and only by Haitong International Securities (USA) Inc., a dealer relying on the “international dealer exemption” under National Instrument 31-103 Registration Requirements, Exemptions and Ongoing Registrant Obligations (“NI 31-103”) in Alberta, British Columbia, Ontario and Quebec. This research report is not, and under no circumstances should be construed as, a prospectus, an offering memorandum, an advertisement or a public offering of any securities in Canada. No securities commission or similar regulatory authority in Canada has reviewed or in any way passed upon this research report, the information contained herein or the merits of the securities described herein and any representation to the contrary is an offence. Upon receipt of this research report, each Canadian recipient will be deemed to have represented that the investor is an “accredited investor” as such term is defined in section 1.1 of National Instrument 45-106 Prospectus Exemptions or, in Ontario, in section 73.3(1) of the Securities Act (Ontario), as applicable, and a “permitted client” as such term is defined in section 1.1 of NI 31-103, respectively.

Notice to Singapore investors: This research report is provided in Singapore by or through Haitong International Securities (Singapore) Pte Ltd (“HTISSPL”) [Co Reg No 201311400G. HTISSPL is an Exempt Financial Adviser under the Financial Advisers Act (Cap. 110) (“FAA”) to (a) advise on securities, units in a collective investment scheme, exchange-traded derivatives contracts and over-the-counter derivatives contracts and (b) issue or promulgate research analyses or research reports on securities, exchange-traded derivatives contracts and over-the-counter derivatives contracts. This research report is only provided to institutional investors, within the meaning of Section 4A of the Securities and Futures Act (Cap. 289). Recipients of this research report are to contact HTISSPL via the details below in respect of any matters arising from, or in connection with, the research report:

Haitong International Securities (Singapore) Pte. Ltd.

10 Collyer Quay, #19-01 - #19-05 Ocean Financial Centre, Singapore 049315

Telephone: (65) 6536 1920

Notice to Japanese investors: This research report is distributed by Haitong International Securities Company Limited and intended to be distributed to Financial Services Providers or Registered Financial Institutions engaged in investment management (as defined in the Japan Financial Instruments and Exchange Act (“FIEL”) Art. 61(1), Order for Enforcement of FIEL Art. 17-11(1), and related articles).

Notice to UK and European Union investors: This research report is distributed by Haitong International Securities Company Limited. This research is directed at persons having professional experience in matters relating to investments. Any investment or investment activity to which this research relates is available only to such persons or will be engaged in only with such persons. Persons who do not have professional experience in matters relating to investments should not rely on this research. Haitong International Securities Company Limited's affiliates may have a net long or short financial interest in excess of 0.5% of the total issued share capital of the entities mentioned in this research report. Please be aware that any report in English may have been published previously in Chinese or another language.

Notice to Australian investors: The research report is distributed in Australia by Haitong International Securities (Singapore) Pte Ltd, Haitong International Securities Company Limited, and Haitong International Securities (UK) Limited in reliance on ASIC Corporations (Repeal and Transitional) Instrument 2016/396, which exempts those HTISG entities from the requirement to hold an Australian financial services license under the Corporations Act 2001 in respect of the financial services it provides to wholesale clients in Australia. A copy of the ASIC Class Orders may be obtained at the following website, www.legislation.gov.au. Financial services provided by Haitong International Securities (Singapore) Pte Ltd, Haitong International Securities Company Limited, and Haitong International Securities (UK) Limited are regulated under foreign laws and regulatory requirements, which are different from the laws applying in Australia.

Notice to Indian investors: The research report is distributed by Haitong Securities India Private Limited ("HSIPL"), an Indian company and a Securities and Exchange Board of India ("SEBI") registered Stock Broker, Merchant Banker and Research Analyst that, inter alia, produces and distributes research reports covering listed entities on the BSE Limited ("BSE") and the National Stock Exchange of India Limited ("NSE") (collectively referred to as "Indian Exchanges").

Name of the entity: Haitong Securities India Private Limited

SEBI Research Analyst Registration Number: INH000002590

Address : 1203A, Floor 12A, Tower 2A, One World Center

841 Senapati Bapat Marg, Elphinstone Road, Mumbai 400 013, India

CIN U74140MH2011FTC224070

Ph: +91 22 43156800 Fax:+91 22 24216327

Details of the Compliance Officer and Grievance Officer : Prasanna Chandwasakar : Ph: +91 22 43156803; Email id: prasanna.chandwasakar@htisec.com

"Please note that Registration granted by SEBI and Certification from NISM in no way guarantee performance of the intermediary or provide any assurance of returns to investors".

This research report is intended for the recipients only and may not be reproduced or redistributed without the written consent of an authorized signatory of HTISG.

Copyright: Haitong International Securities Group Limited 2019. All rights reserved.

<http://equities.htisec.com/x/legal.html>

AI人工智能产业链联盟

#每日为你摘取最重要的商业新闻#

更新 · 更快 · 更精彩



Zero

AI人工智能产业链联盟创始人
河北清华发展研究院智能机器人中心运营经理



base:北京



主要业务:AI商业化答疑及课程应用场景探索, 各类AI产品学习手册, 答疑及课程



欢迎扫码交流

提供: 学习手册/工具/资源链接/商业化案例/
行业报告/行业最新资讯及动态



人工智能产业链联盟创始人

邀请你加入星球, 一起学习

人工智能产业链联盟报 告库



星主: 人工智能产业链联盟创始人

每天仅需0.5元, 即可拥有以下福利!
每周更新各类机构的最新研究成果。立志将人工智能产业链联盟打造成市面上最全的AI研究资料库, 覆盖券商、产业公司、研究院所等...

知识星球

微信扫码加入星球 ▶

