

AI 技术每日分析：前沿模型进入能力分层与受控开放阶段

中国高技术产业发展促进会新质生产力工作委员会

博雅云创 & 中科创新驱动

2026 年 9 月 2 日星期三

摘要

今天 AI 技术方向最值得关注的变化，不是参数规模再次刷新，而是前沿模型和 Agent 生态同时进入“能力分层、运行约束、供应链治理和自治运维”阶段。Anthropic 发布 Claude Fable 5.1 与 Mythos 5.1，以同一模型为基础，通过不同安全级别面向通用用户与高风险专业任务；OpenAI 则确认正在开发的 Astra 已达到其 Preparedness Framework 中的“Critical”网络安全能力门槛，并因此强化发布前的安全措施。Agent 生态的安全问题也在快速显性化：创业公司 AIR 完成累计 5000 万美元种子融资，专门审查 Agent 所调用的 Skills、插件、MCP Server 等“AI 附加组件”；DataAgent 则完成 1000 万美元 Pre-Seed 融资，把自主 Agent 直接放入客户 Kubernetes 环境中，尝试自动发现并修复生产故障。AI 竞争正在从“模型会不会做”走向“不同能力该给谁用、Agent 能调用什么、发生风险时谁来阻断，以及系统能否在真实生产环境里自行恢复”。

目录

一、Anthropic 发布 Fable 5.1 与 Mythos 5.1：同一模型开始按风险等级拆分使用权	2
--	---

二、OpenAI 确认 Astra 达到 “Critical” 网络安全门槛：模型发布前第一次被能力等级直接约束	2
三、AIR 累计融资 5000 万美元：Agent 的 Skills、插件和 MCP 正在形成新的软件供应链安全市场	3
四、DataAgent 完成 1000 万美元 Pre-Seed：自治运维开始从 “告诉你故障原因” 转向 “直接修复”	4
趋势观察	5
参考资料	5

一、Anthropic 发布 Fable 5.1 与 Mythos 5.1：同一模型开始按风险等级拆分使用权

9 月 1 日，Anthropic 发布 Claude Fable 5.1 和 Claude Mythos 5.1。两者底层模型相同，但面向的使用范围和安全措施不同：Fable 5.1 面向更广泛的编码、知识工作和研究任务，Mythos 5.1 则针对网络安全、生命科学等高风险领域实行更严格的受信访问。

这种产品结构很值得关注。过去前沿模型的能力差异更多通过“旗舰版、轻量版”区分，今天则开始出现“能力相同、权限不同”的模型分层。Anthropic 称，Fable 5.1 通过更低的缓存读取价格，使典型按 Token 计费工作负载成本预计下降约 25%；对于高度 Agent 化、频繁重复读取上下文的工作流，节省幅度可能更高。

安全层面，Anthropic 引入 Enterprise Frontier Safeguards，强调客户控制的云基础设施、更加严格的数据保留策略和专业领域访问控制。公司同时表示，新版网络安全保护减少了大量误报，使安全限制更精细，而不是简单扩大阻断范围。

这意味着前沿模型正在出现一种新的商业逻辑：最强能力不一定向所有用户以完全相同的方式开放。未来企业采购模型时，除了价格和 Benchmarks，还会越来越关注“哪些能力默认开放、哪些需要受信授权、哪些高风险动作必须经过额外审核”。

二、OpenAI 确认 Astra 达到“Critical”网络安全门槛：模型发布前第一次被能力等级直接约束

OpenAI 9 月 1 日披露，正在开发的 Astra 模型已达到其 Preparedness Framework 定义的“Critical”网络安全能力阈值。这意味着模型在拥有适当工具和系统访问条件时，能够发现此前未知的软件漏洞，并构建针对强

化系统的复杂利用路径。

OpenAI 没有把这一能力直接等同于公开产品发布。相反，公司明确表示，因为 Astra 进入更高风险等级，部分开发和开放计划曾被延后，以便强化访问控制、监控和自动停止机制。OpenAI 披露，Astra 在已知漏洞利用评测 ExploitBench 中达到 100%，在内部未知漏洞测试中也显著超过 GPT-5.6 Sol；评测过程中还发现了两个零日漏洞，并正在按照漏洞披露流程处理。

这件事对整个模型行业有标志性意义。模型能力已经开始强到“越强越不能简单全量开放”。如果模型能自主完成漏洞定位、利用链分析和工具调用，那么安全边界必须从内容过滤升级到使用对象、运行环境、工具权限和任务目的。

未来模型供应商很可能普遍建立“能力等级—访问等级—监控等级”之间的映射。模型越接近自主科研、自主攻击或高风险生物设计，其商业化方式就越像受控基础设施，而不是普通 SaaS API。

三、AIR 累计融资 5000 万美元：Agent 的 Skills、插件和 MCP 正在形成新的软件供应链安全市场

9 月 1 日，AI 安全创业公司 AIR 宣布从隐身状态走向公开，并披露已通过两轮种子融资累计获得 5000 万美元。其中首轮 1000 万美元由 Sequoia Capital 领投，第二轮 4000 万美元由 Greenoaks 领投。

AIR 解决的并不是传统 Prompt 注入问题，而是 Agent “装了什么”。企业 Agent 会调用 Skills、工具、浏览器插件、MCP Server 和各种第三方附加组件，这些组件本质上拥有读取数据、调用 API 甚至执行操作的能力。一旦其中某个组件被篡改、权限过宽或在更新后出现恶意行为，Agent 就可能成为新的软件供应链攻击入口。

AIR 的产品会自动发现企业环境中的 Agent 及其附加组件，持续检查

它们的权限、代码、行为和版本变化，并在发现危险交互时阻断。公司还建立了一个经过审查的 Agent Add-on Marketplace。AIR 表示，在其扫描到的公开 Skills 和附加组件中，大约 27% 未能通过安全筛查。

这家公司规模仍小，但它代表一个很可能快速成长的市场。传统软件供应链安全围绕 npm、PyPI、容器镜像和依赖包展开；Agent 时代则需要增加 Skills、MCP、工具配置和 Agent 权限清单。企业未来可能会把“Agent SBOM”当作软件资产管理的常规对象。

四、DataAgent 完成 1000 万美元 Pre-Seed：自治运维开始从“告诉你故障原因”转向“直接修复”

9 月 1 日，以色列创业公司 DataAgent 宣布完成 1000 万美元 Pre-Seed 融资，由 MizMaa Ventures 和 Alicorn 领投。公司由 Cloudify 前创始团队成员 Ishay Yaari 与 Nati Shalom 创建，目标是在客户 Kubernetes 和云环境内部部署自治 Agent，直接处理生产故障。

DataAgent 把自己的产品称为“Remediation-first Digital Immune System”。传统可观测平台通常先采集大量日志、指标和 Trace，再告诉工程师哪里可能出了问题；DataAgent 希望 Agent 直接读取集群实时状态、拓扑结构、配置漂移和故障上下文，在预先批准的权限范围内执行修复，然后再补充根因分析和事件记录。

这条路线的技术难点并不在模型能否理解日志，而在于“Agent 有没有资格修改生产系统”。企业需要设定动作白名单、变更边界、回滚条件和审计轨迹，并确保 Agent 处理错误不会比原始故障更严重。

如果这类产品能够稳定运行，AIOps 的价值衡量方式会发生变化：从“减少多少告警”转向“自动恢复多少故障、缩短多少 MTTR”。自治运维也是 Agent 最容易体现直接业务价值的方向之一，因为系统停机本身就有明确成本。

趋势观察

今天四条主线共同说明，AI 进入了一个更接近基础设施的阶段。Anthropic 开始按照风险区分同一前沿模型的使用方式，OpenAI 因模型达到 Critical 能力主动提高开放门槛，AIR 把 Agent 插件和 MCP 当成新的供应链安全对象，DataAgent 则让 Agent 开始在真实生产系统里执行修复。接下来企业真正要管理的，不再只是一个大模型 API，而是一整套“模型能力等级、Agent 身份、工具供应链、运行权限与异常停止机制”。

参考资料

Anthropic | 《Claude Fable 5.1 and Mythos 5.1》 | 2026-09-01 | 核验两款模型定位、定价、安全分层和 Enterprise Frontier Safeguards。

<https://www.anthropic.com/claude-fable-and-mythos-5-1> OpenAI | 《The Path to Astra》 | 2026-09-01 | 核验 Astra 达到 Critical 网络安全能力门槛、评测结果与发布限制。

<https://openai.com/index/path-to-astra/> TechCrunch | 《AIR raises \$50M to help companies vet the skills and add-ons AI agents use》 | 2026-09-01 | 核验 AIR 融资、客户情况和 Agent 附加组件安全定位。

<https://techcrunch.com/2026/09/01/air-raises-50m-to-help-companies-vet-the-skills-and-add-ons-ai-agents-use/> AIR | 官网与产品资料 | 2026-09-01 访问 | 补充 Agent 发现、Skills/MCP 持续验证和 Marketplace 能力。

<https://www.air.security/> DataAgent / PR Newswire | 《DataAgent Emerges from Stealth and Launches Remediation-First Platform with \$10 Million Pre-Seed Funding》 | 2026-09-01 | 核验融资、创始团队、Kubernetes 内自治修复路线。

[https://www.streetinsider.com/PRNewswire/DataAgent+Emerges+from+Stealth+and+Launches+Remediation-First+Platform+with+\\$10+Million+Pre-Seed+Funding/27009313.html](https://www.streetinsider.com/PRNewswire/DataAgent+Emerges+from+Stealth+and+Launches+Remediation-First+Platform+with+$10+Million+Pre-Seed+Funding/27009313.html) Reco / GlobeNewswire | 《Reco Launches Browser Guard for Runtime AI and Agent Security》 | 2026-09-01 | 背景资料, 补充浏览器侧 Agent 运行时安全和上下文治理。

<https://www.globenewswire.com/news-release/2026/09/01/3354255/0/en/reco-launches-browser-guard-for-runtime-ai-and-agent-security.html> Monid | Agent Tool Marketplace | 2026-09-01 访问 | 背景资料, 观察 Agent 工具市场与统一调用生态。

<https://monid.ai/> Monid Docs | 开发者文档 | 2026-09-01 访问 | 补充工具 Schema、Agent 工具发现和接入方式。

<https://docs.monid.ai/> Startup Researcher | DataAgent 相关融资与产品分析 | 2026-09-01 | 交叉补充自治运维创业方向。

<https://www.startupresearcher.com/news/dataagent-raises-10m-pre-seed-to-launch-remediation-first-ai-platform> Prompt Security | AI Security Landscape 相关资料 | 2026 年 | 背景资料, 观察 Agent、浏览器、MCP 与 AI 供应链安全产品分化。

<https://www.prompt.security/> —

联系我们，请扫描二维码



新质生产力工作委员会
官方公众号



工业智能算网
gyznsw.cn

新质生产力工作委员会：

中国高技术产业发展促进会新质生产力工作委员会，专注于推动工业人工智能、智能制造、数字化转型等前沿技术发展，为企业提供政策解读、技术咨询和产业对接服务。

工业智能算网：

专注于工业人工智能、新质生产力、工业软件 CAE、智能制造等前沿技术。提供每日动态分析、技术趋势解读、解决方案分享，推动工业智能化转型。

网站地址：<https://gyznsw.cn>