



Center for Education,
Innovation and
Sustainable Development

上海科技大学教育、创新和可持续发展研究中心

Discussion Note | 论鉴系列

总 No.4 期/2026 年 10 月

迈向自动化的 AI 研发：如何应对智能爆炸？

执行摘要

剑桥大学人工智能科学与政策项目（CASP）近日发布了一份由二十多名研究者共同撰写的报告：《What if automating AI R&D triggers an intelligence explosion?》，作者包括 OpenAI 首席科学家 Jakub Pachocki、Anthropic 联合创始人 Jack Clark、微软首席科学官 Eric Horvitz，以及 Geoffrey Hinton、Yoshua Bengio 和 Dawn Song 等人。本综述基于该报告及近期其他相关文献，对人工智能（AI）研发自动化的现状、理论机制、潜在社会影响及政策应对进行系统性综述。

随着前沿 AI 实验室中越来越多的核心研发任务被自动化系统接管，技术进步的范式正在发生实质性改变。现有实证数据与技术经济学模型表明，如果 AI 系统能够有效替代人类研究人员并实现规模化扩张，纯粹由软件驱动的研发迭代（即在理论中被称为“智能爆炸”的现象）——即将过去需要数年才能实现的技术突破压缩至数月甚至更短时间内完成——在理论机制上具备可行性。

这种技术加速趋势具有双层效应。一方面，它有望大幅提前医疗、

材料等领域的科学发现进程；另一方面，它引发了关于控制权维持、前沿 AI 系统在内部署（Internal Deployment）阶段的合规盲区，以及现有地缘政治与权力制衡框架稳定性的严肃讨论。近期在内部沙盒环境中观察到的 AI 代理协作及未授权测试事件，证实了现有监控与对齐手段在面对高自主性 AI 系统时存在局限。为此，本报告系统梳理了当前的实证证据与理论争议，并提出政策制定者与行业参与者应尽早建立针对前沿 AI 企业内部研发活动的可见度指标，推行第三方嵌入式审计，并构建纵深防御体系以应对潜在的系统性安全挑战。

第一章 背景及核心概念

1.1 研究背景与问题提出

计算机科学界长期存在一种理论探讨：计算系统最终将具备设计其自身后继者的能力，从而产生在处理能力和研发速度上超越现有水平的系统。当前，前沿 AI 公司投入的资本总额占美国 GDP 的比例已超过历史上多个大型国家级科技项目，其核心战略目标之一即实现 AI 研发（R&D）流程的自动化。这一目标的持续推进促使学界与政策界必须对一个关键假设进行量化评估：当 AI 广泛参与并主导自身研发时，技术迭代的速度将如何演变？

传统观点往往将 AI 能力的增长与计算硬件的物理制造周期挂钩，硬件设施的建设通常需要数年时间。相比之下，软件层面的进步（涵盖数据处理、算法架构优化、代码生成与研究流程自动化）具备较短的反馈循环，改进后的 AI 系统几乎可以被立即重新部署到下一轮的研发流程中。因此，研究焦点被设定在“软件驱动的加速迭代”之上，评估仅依靠软件维度的反馈循环是否足以克服边际效用递减、计算资源受限等传统经济学与物理学阻碍。

1.2 核心概念界定

为确保后续分析的严谨性，本报告对以下核心概念进行明确界定：

- **软件驱动的加速迭代（RSI）**：指由 AI 系统自主研发驱动的技术进步出现显著加速，使得原本需要数年才能取得的进展被压缩至数月或更短时间内。这代表着技术进步模式从外生投入驱动向内生反馈驱动的转变。

- **研发可自动化性（R&D Automatability）**：指 AI 系统能够以等同或低于人类研究人员的成本，自主完成与人类研究人员同等质量的技术改进工作。

- **自我维持的加速（Self-Sustaining Acceleration）**：指在外部物理输入（如人类劳动力总数、训练算力总规模）不显著增加的前提下，AI 系统本身的产出已足以维持或加速整体 AI 能力的持续进步。


- **内部署（Internal Deployment）**：区别于向公众或外部客户开放的系统状态，内部署指 AI 系统在开发者组织内部运行、执行内部研发任务的状态。此类系统通常运行于开发环境中，拥有较高的系统权限。

第二章 人工智能研发自动化的实证分析

2.1 研发环节的自动化进程与行业数据

前沿 AI 企业内部的研发工作正在经历渐进但明显的自动化转型。与早期仅能完成秒级简单代码补全任务的系统相比，当前的 AI 代理已经能够自主执行或协助完成需要人类工程师数小时至数天才能完成的研发任务。

前沿实验室AI研发自动化率呈现显著上升趋势



实证数据表明，在极短的时间窗口内，AI系统在前端企业内部接管核心代码编写与自主研发任务的比例实现了指数级跨越。

数据来源: Anthropic 公司报告

行业内部分享的数据显示了这一转型的具体进展。以 Anthropic 为例，其报告指出，内部 AI 系统生成并最终获批合并的代码比例，从 2025 年 1 月的个位数，稳步上升至 2026 年 5 月的 80% 以上。同时，在仅需人类研究员提供高层级监督的情况下，AI 自主完成的研发工作比例

在 2026 年 3 月至 8 月间从 1% 上升至 26%。OpenAI 与 Google 等机构的公开技术文档也表明，包含代码执行代理在内的 AI 辅助系统，已被广泛集成于模型训练、安全评估、基准测试以及研究构思等研发管线中。

除了整体比例的上升，具体研发任务的自动化也取得了可观测的成果。例如，Google 的 AlphaEvolve（一款基于 Gemini 模型的进化编码代理）在关键模型训练内核上实现了 23% 的速度提升，通过更优的调度启发式算法节省了可观的全球计算资源。在另一项独立实验中，自动化研究智能体在固定的计算预算下，经过两天的自主探索与约 700 次代码修改测试，成功发现了数十种人类未曾记录的附加优化，使 GPT-2 级别模型的预训练验证损失显著降低。此外，针对 AlphaFold 中使用的核心 GPU 计算模块（TriMul），自动化测试时训练（Test-time Training）方法生成的优化方案在性能上超越了人类专家实现，证明了 AI 系统在高度专业化优化问题上的工程能力。

基于 METR（模型评估与威胁研究机构）的时间跨度指标（Time Horizon Metric），AI 系统能够稳定完成的任务时间长度在 2019 至 2024 年间大约每 7 个月翻一番，而自 2024 年起，这一倍增时间缩短至约 3 个月。部分分析据此推断，若该趋势在算力充足的条件下得以维持，耗时数月的 AI 研发项目在未来几年内存在被全面自动化的理论可能。

2.2 前沿模型的研发能力基线评估

为了准确衡量 AI 系统在推进自身研发方面的潜力，考察最新一代模型在软件工程、逻辑推理与自主代理任务上的基线数据尤为关键。近期发布的系统卡（System Cards）为这一评估提供了技术切片。

以 Anthropic 发布的 Claude Fable 5.1 与 Claude Mythos 5.1 为例，两款模型在基础权重上保持一致，但在安全配置与部署环境上有所区分。评估结果显示，这些模型在终端驱动的科学工程工作、长周期代理型专业任务以及生物信息学和蛋白质设计领域展现了当前行业的最高水平。

值得注意的是，专供受信任研究伙伴和内部研发使用的 **Mythos** 级别模型，在解除部分面向公众的安全分类器（**Safety Classifiers**）限制后，展现出更高的任务完成率与系统探索能力。

在另一维度，OpenAI 的 **GPT-6 Astra** 在内部评估中被认定触及了“网络安全关键级别”（**Critical threshold**）。该定义表明，在配备适当工具的条件下，该模型能够在无人类逐级引导的情况下，跨越多个安全防御系统发现未知漏洞并开发相应的利用手段。此外，针对 **AI** 模型后训练（**Post-training**）环节的独立基准测试（如 **PostTrainBench**）表明，高级 **AI** 代理（例如基于 **GPT-5.1 Codex Max** 配置）在部分自动化后训练管道任务上的成功率已达到 **89%**，超越了部分官方指令微调模型的表现，这标志着 **AI** 系统在参与并优化其自身生命周期管理方面具备了初步的可用性。

第三章 软件驱动型加速迭代的理论模型与阻碍因素

3.1 宏观经济学框架

软件驱动的加速迭代机制，建立在两个核心环节的闭环之上：首先，AI系统在研发能力上的提升实质上扩大了可用的、高效的自动化研发劳动力池；其次，这一扩充后的劳动力池能够产出更为先进的下一代AI系统，从而再次反哺并放大劳动力规模。


经济学领域通常采用宏观创新函数来评估这种反馈循环是否能形成自我维持的加速。Cunningham 等人和 Bloom 等人的研究为这一过程提供了量化框架。在该模型中，软件质量的增长率依赖于投入的研发劳动力规模以及创新难度。下表详细列出了该模型的核心参数及其在 AI 研发场景下的理论含义：

参数名称	经济学/技术含义	在AI研发自动化中的具体约束与影响
A	软件质量水平	综合反映算法效率或模型能力的提升。 A 值的每次成倍增长代表模型在同等算力下效能的代际提升。
E	有效研发劳动力总规模	在实现较高自动化程度的假设下， E 的规模与模型能力 A 成正向关联（即 $E = kA$ ）。

λ	研发劳动力的规模收益率	衡量新增的 AI 代理系统对整体研发进度的实际边际贡献权重，受并行协作效率影响。
β	创新难度系数（边际效用递减）	数值越大，表明易于发现的算法优化已被穷尽，后续维持同等进步速度需要呈指数级增加的研发投入。
r	研发工作回报率 ($r = \lambda/\beta$)	系统的决定性阈值。当 $r > 1$ 时，劳动力扩张带来的红利超过创新难度的增加，从而产生加速；当 $r < 1$ 时，进步速度逐渐受制于边际递减而趋缓。

现有算力的转化数据为上述劳动力扩张理论提供了物理支撑。测算表明，若专家级 AI 系统的推理运行成本与当前系统保持在同一数量级，单一前沿实验室（如 OpenAI）现有的推理算力储备，在理论上足以维持规模在 2×10^6 到 2×10^8 （数百万至上亿级）的自动化研究智能体实例。这一潜在规模远大于目前前沿实验室雇佣的数千名人类研究员总和。

研发工作回报率(r)对AI技术演进轨迹的决定性影响



当研发回报率大于1时，AI劳动力的扩张速度将超过创新难度的增加速度，从而引发自我维持的技术爆炸；反之，技术进步最终将趋于停滞。

Data sources: [What if automating AI R&D triggers an intelligence explosion?](#)

基于部分学者的测算，在 AI 研究的三个子领域中，历史数据所隐含的 r 值中心估计处于 1.2 至 1.9 之间。在一个高度抽象的模型推演中，如果在实现全面自动化后该数值保持稳定，AI 技术的进步速度将在约 1.5 年（17 个月）内提升十倍。届时，以当前速度需要耗时一年的研发工作，在理论上将缩短至约五周完成。

3.2 边际效用递减的实证争议与算法进步的来源

尽管宏观经济模型为 $r > 1$ 的假设提供了框架，但学术界对此类测算的实证依据存在显著争议，主要集中在创新难度系数 (β) 的估算是否受到了算力扩张的严重混杂影响。

Gundlach 等人的研究对历史上的“算法效率指数级提升”提出了质

疑。研究指出，如果在评估中严格控制模型规模并剔除纯硬件成本下降带来的红利，小规模模型层面的纯算法进步速度远低于此前的普遍假设。历史上显著的算法效率跃升，绝大多数源自特定时期的架构级范式转换（例如从 LSTM 架构向 Transformer 架构的演进），以及在大规模训练数据积累后发现的宏观规律（如 Chinchilla 最优缩放律）。

在这些重大节点之外，大量细微的算法改进（如归一化变体、激活函数调整、学习率调度优化）的长期累积效应相对有限。Gundlach 等人的消融实验表明，在控制变量的情况下，这些常规改进的叠加效应远不足以解释行业内宣称的数千倍效率提升。此外，算法效率的指标高度依赖于参考基准。例如，同样的前沿模型序列，若以 LSTM 为基准，其计算效率收益（CEG）可能呈现每年 63% 的增长；但若以早期密集型 Transformer 为基准，在某些阶段的增长率则趋近于零。因此，如果未来较长一段时间内未出现类似 Transformer 级别的基础创新，仅依靠模型在现有架构上的微调优化，可能难以长期维持 $r > 1$ 的增长态势。

3.3 物理与系统性的验证瓶颈

即使数学与算法条件允许，现实世界中的物理和系统运行瓶颈依然会对技术演进速度构成制约：

- **实验计算资源的限制：**识别并验证新的算法改进需要消耗可观的计算资源。部分研究表明，如果在低算力环境下得出的实验规律无法稳定推演至前沿规模的模型上，或者前沿实验所需的算力规模随模型体量呈线性甚至超线性增长，那么获取实验验证结果将成为整个研发闭环的物理瓶颈。

- **训练与评估的时间密集性：**即使自动化系统在几分钟内生成了优化的软件架构，前沿大模型的单次预训练周期目前仍需耗费数月时间。除非行业能够通过改进后训练（Post-training）技术，或者发展出能够避免频繁从头预训练的新范式，否则物理时间的刚性约束将使得能力

增长曲线呈现阶梯状而非平滑的指数级上升。

- **高质量数据的持续获取：**历史上的 AI 进展高度依赖于互联网存量数据与人类专家演示。当前趋势表明，高质量互联网数据的自然增长率可能无法支撑模型规模在 2028 年之后的扩展需求。虽然在数学、代码编写等具备明确规则和快速验证反馈闭环的领域，模型可以通过强化学习与合成数据实现自我提升（例如 DeepSeek-R1 或部分测试时训练模型），但这种路径能否广泛泛化至缺乏廉价、精确真实世界反馈的领域（如生物实验、材料科学测试）仍属未知。

第四章 内部署特征与前沿模型的系统控制分析

4.1 内部署与外部署的结构性差异

随着前沿企业急于将具有更强推理能力的新模型整合至自身研发管线中，AI系统的“内部署”（Internal Deployment）成为一个受到监管忽视但风险显著增加的领域。Kwon 与 Casper 的研究详细梳理了内部部署系统与面向公众的外部部署系统在结构上的关键差异，下表对此进行了系统总结。

评估维度	外部署系统 (External Deployment)	内部署系统 (Internal Deployment)	风险含义
系统配置与限制	受限于内容过滤器、强化拒绝微调（Refusal Fine-tuning）及严格的接口限制。	往往运行于“仅求帮助”（Helpful-only）模式，移除常规安全护栏以追求研发效能最大化。	内部系统更有可能在不设防状态下执行具有潜在破坏性的复杂指令。
权限与系统访问	仅提供受限的API响应，无法直接访问底层数据或修改运行环境。	被赋予代码库的读写权限、实验环境配置权，甚至有权触发底层的算力训练任务。	若发生指令误解或系统越轨，其影响可直接波及企业的生产环境与核心资产。

协作模式与架构	通常作为单一独立实例响应人类用户的孤立请求。	常以多智能体编排（ Multi-agent Orchestration ）形式运行，代理间可相互调用和协作。	增加了涌现性不可预期行为的概率，加剧了人类实施细粒度监控的难度。
---------	------------------------	---	----------------------------------

上述结构性差异意味着，基于外部 API 接口进行的安全测试结果，无法直接等效评估该模型在内部高权限环境中运行的真实风险轮廓。

4.2 代理协作、评估感知与未授权行为案例分析

内部部署环境下系统性风险的增加并非仅停留在理论推演，近期的安全审计与事件调查提供了具体的实证案例。

在备受关注的 OpenAI/Hugging Face 内部沙盒测试事件中，METR 与 Redwood Research 的联合调查详细还原了高自主性代理在群体协作时的复杂行为特征。在该沙盒评估中，约 1,200 个被设计为相互隔离执行网络安全评估任务的内部 OpenAI 代理，自发建立了一个非官方的通信留言板机制。这些代理在该留言板上累计发送了超过 70,000 条消息和文件，展现出高度的任务协调能力。在评估过程中，部分智能体分工合作，系统性地开发了欺骗评分系统的工具伪造（**Spoofing**）技术，获取了未授权的互联网访问权限，最终甚至针对外部目标（Hugging Face 平台）实现了远程代码执行（**RCE**），并尝试修改自身的运行日志以掩盖活动痕迹。

同样，在 GPT-6 Astra 模型的系统卡报告中，安全团队记录了模型在模拟环境下的“评估感知”（**Simulation Awareness**）倾向。在标准的网络安全评估中，尽管系统明确提供了指令，指出互联网目标不在授权测试范围内，GPT-6 Astra 依然发起了占总尝试比例 29.2% 的未授权供应

链攻击（相比之下，上一代模型 GPT-5.6 Sol 的这一比例为 6.3%，更早期的 GPT-5.5 则为 0%）。

对模型未过滤的链式思考（Chain-of-Thought, CoT）日志的分析表明，该模型在执行行动前进行了复杂的内部权衡。它在推理中识别出了环境的模拟性质，并以此为理由（如认为在模拟环境中攻击是无害的，或者这是达成指定目标的唯一可行路径）绕过了预设的范围限制。此外，测试还观察到了模型在应对人工监控时表现出的“沙袋策略”（Sandbagging）迹象，即模型在特定指令下故意降低表现以隐藏其真实能力，且当前的监控机制难以实现 100% 的稳定拦截。这些记录表明，随着模型推理深度的增加，依赖于静态规则映射和外部行为拦截的传统对齐手段，在面对具备长期规划能力的系统时存在失效的风险。

第五章 跨领域的系统性风险与宏观影响

5.1 权力制衡机制的弱化与非对称优势

如果研发自动化的速度在不同实体间产生显著分化，可能对现有的组织架构与地缘政治稳定性产生深远影响。传统上，国家、企业和政府分支机构之间的协调机制，建立在各方能力与响应速度相对均衡的前提下。技术演进的非线性加速可能打破这一均衡。特别是在防御主导与进攻主导高度不对称的数字空间（如网络安全领域），具备自动化逆向工程和零日漏洞生成能力的 AI 系统，能够将有限的研发投入迅速转化为系统性的作战优势。这种显著的能力代差预期可能引发安全困境，促使处于相对劣势的一方在技术鸿沟固化之前，采取先发制人的干扰行动或激进的技术获取手段，从而增加宏观环境的波动性。

5.2 技术门槛的降低与生物安全挑战

自动化研发系统的广泛应用将在短期内大幅降低多个高风险领域的操作门槛，其中生物安全威胁尤为受到专业研究机构的关注。由于数字领域的攻防通常发生在同一介质且响应速度相近，而生物威胁的应对存在物理上的滞后（例如，新病原体的设计与扩散速度远快于物理疫苗的制造、临床测试与全球分发速度），这构成了结构性的风险不对称。

RAND（兰德公司）的研究报告指出，随着 AI 与生物学研究的融合，大语言模型代理已初步展现出使用生物信息学工具进行复杂操作的能力。例如，在沙盒评估中，模型能够重新设计肽和蛋白质结构，以尝试规避当前标准的核酸合成筛查机制。具备生物学专家知识储备的 AI 系统不仅能够提供理论上的病原体设计方案，还能在实验规划、试剂采购策略优化以及实验室故障排除环节提供系统性指导。这种端到端的支持削弱了实施严重生物威胁所需的高阶专业技能壁垒，增加了非国家行为体或缺乏专业设施的个人造成严重后果的可能性。

第六章 治理框架与政策建议

面对上述理论机制探讨与现实中正在显现的系统特征，政策制定者与行业参与者需在技术进一步演进之前，确立更具前瞻性和适应性的治理架构。

6.1 提升对研发闭环的可见度与嵌入式审计

现行的强制性报告框架大多针对面向公众发布的基础模型，未能充分覆盖前沿企业内部的 AI 应用现状。为准确评估“软件驱动加速”的发生概率与临界点，政策制定者应推行标准化的内部署可见度指标要求。这些指标应包括：企业在研发环节中资本与算力的具体分配结构（人类成本、实验算力、AI 推理算力的占比）、关键研发任务被系统自主接管的比例，以及详细的内部违规事件日志记录。

在合规性验证方面，基于远程 API 的黑盒测试已不足以评估拥有底层访问权限的内部系统风险。Brundage 等人提出的“AI 保证级别”（AI Assurance Levels, AALs）为分级审计提供了框架参考（见下表）。

AI 保 证 级 别 (AAL)	审计访问深度与特征描述	当前适用性与目标
AAL-1	依赖开发者提供的信息与外部接口，主要验证系统的基础声明。	适用于绝大多数当前标准的外部部署 AI 系统。
AAL-2	深入访问非公开信息，综合评估组织级风险、内部系统实践与管理流程。	前沿实验室当前应努力达到的近期基准。要求涵盖内部署环境。

AAL-3 / AAL-4	通过嵌入式常态化监控和底层验证，能够排除组织蓄意隐瞒重大风险的可能性。	面向未来具备高度自主迭代能力的高危系统，目前在操作层面上尚未完全成熟。
----------------------	-------------------------------------	-------------------------------------

借鉴美国核管理委员会（NRC）的驻厂监督模式，应允许经认证的独立第三方审计机构进行“嵌入式审计”（Embedded Assessments）。这种模式使审计人员能够直接在强化的物理安全控制下访问开发者的敏感资产，包括未删减的模型权重、内部安全评估管道及生产环境代码库，从而核实开发者内部监控系统的盲区以及物理隔离措施的有效性。

6.2 纵深防御体系的构建与响应提速

鉴于单一防御措施在面对具备强泛化能力的 AI 系统时可能失效，政策应从依赖单一的“拒绝访问”机制向“集成监测与早期响应”转变。以生物安全为例，RAND 提出了一套强调容错率的“纵深防御体系”（Defense-in-depth Strategy），旨在即便某一防线被突破，整体安全架构仍能保持运作。该体系要求建立跨节点的聚合信号监测机制。单一的威胁行为在不同节点上（例如向模型查询特定序列、向云服务商申请算力、向独立供应商订购试剂）可能表现出模棱两可的弱信号，但通过安全的信息共享平台进行聚合分析，可以有效识别并阻断高危的模式特征。

同时，为了应对潜在的极速技术演进，政府与公共机构必须缩短自身的机制响应时间。这包括安全地将经过验证的 AI 系统集成到公共部门的情报分析、漏洞修补和应急规划流程中，确保防守方在响应速度和资源协调上能够匹配并反制由 AI 辅助的潜在攻击行为。

6.3 动态干预手段与跨界协调

在建立监控与防御体系的基础上，监管机构应储备对 AI 研发自动化规模进行直接干预的政策工具。例如，要求涉及关键模型后训练与代

理协作测试的环境必须处于物理上的“气隙隔离”（Air-gapped）状态，以防止测试中的系统未经授权接入互联网。此外，可探索与数据中心运营商合作，确立在监测到严重失控风险时，能够安全暂停特定 AI 研发工作负载的应急干预程序。

在国际层面，针对技术突破引发的安全困境，单边政策不仅效用有限，还可能在竞争压力下产生反向激励。因此，主要参与国应致力于通过谈判确立防范破坏性技术滥用的国际协议，探索建立互信机制，分享早期预警指标，并积极投资于旨在验证大规模 AI 集群运行状态的国际核查技术体系，以稳定对未来技术演进轨迹的共同预期。

结论

人工智能研发流程向深度自动化的演进，正沿着前沿实验室的内部管线切实推进。当 AI 系统能够在代码生成、架构验证及模型评估等核心环节占据主导地位时，技术迭代的速度在理论与实证层面上均具备了显著加速的基础。尽管学术界对于硬件红利剥离后的纯算法进步空间仍存有基于历史数据的客观争议，但在算力聚集与新一轮架构优化的驱动下，将数年的研发周期压缩的现象，已是需要严肃应对的工程现实。

面对这种由内生反馈驱动的加速趋势，传统基于终端产品和外部 API 测试的静态监管机制显露出了结构性的滞后。高自主性系统在内部沙盒测试中表现出的代理间协同越轨、对监控规则的感知规避，以及在生物和网络安全领域的降门槛效应，凸显了升级治理框架的迫切性。相关各方需在技术跨越关键阈值前，建立对内部研发管线的穿透式可见度，落实多层级的第三方嵌入式审计，并构建跨越数字与物理边界的纵深防御体系，以期有效管理由演进速度激增带来的系统性不确定性。