



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

Policy Note | 系列

总 No.2 期/2026 年 5 月

AI 对经济的影响、制度设计和经济学范式改变

执行摘要

在当前全球经济面临结构性增长乏力、人口老龄化加剧以及劳动生产率长期停滞的宏观背景下，人工智能（Artificial Intelligence, AI）作为新一代通用目的技术（General Purpose Technology, GPT），正在经济学界与公共政策领域引发一场史无前例的大辩论。这场辩论的核心张力，高度集中于技术乐观主义者所预期的“指数级爆炸性增长”与劳动经济学家所担忧的“人类专长被全面替代”之间的深刻矛盾之中。

历史上，从 19 世纪的蒸汽机与机械织布机，到 20 世纪的电气化、内燃机、半导体与互联网，每一次通用目的技术的涌现都从根本上重塑了宏观经济的生产函数与社会阶层结构。然而，本次由大语言模型（LLM）和生成式 AI 驱动的技术革命，与历次工业革命存在着本体论意义上的本质差异：它首次将自动化的触角延伸至人类长期引以为傲的“认知、判断与思考”领域。这一前所未有的技术特质使得宏观经济学界必须重新审视传统的经济增长模型、劳动力分配机制以及社会财富契

约。

本报告基于当前顶尖学者的前沿研究，系统性地探讨四个相互交织的核心议题：首先，对比分析 Anton Korinek 等人提出的“递归自我提升”带来的指数级奇点增长理论，与 Charles I. Jones (2026) 所构建的“弱环节”（Weak Links）物理瓶颈模型，揭示 AI 驱动宏观经济增长的底层数学与物理逻辑；其次，引入 Daron Acemoglu、David Autor 和 Simon Johnson (2026) 的“亲工人人工智能”（Pro-Worker AI）分析框架，并结合人工智能教父 Geoffrey Hinton 对 AI 学习机制与人类本质差异的深刻洞察，剖析此次技术浪潮对人类专长与就业市场的结构性重塑路径；第三，深入探讨传统国内生产总值（GDP）核算在 AI 时代的失效问题，以及由此引发的资本马太效应、劳动收入份额下降与 AI 系统性灾难风险（包括被量化的“奥本海默问题”）；最后，汇总并重构相应的政策响应机制，以期在避免灾难性系统崩溃的前提下，引导算法演进与人类制度的同步进化。

通过让这些学者的观点在文中进行深度“对话”与逻辑碰撞，我们重申往期报告业已提出和阐释的核心论点：人工智能的技术轨迹并非命中注定的物理定律，人类社会的最终命运取决于政策制定者、经济学家与科技企业今天在制度设计与经济学范式上所做出的战略抉择。如同 Daron Acemoglu 提议的那样，以下政策框架应尽快启动：

- 1. 改变税收结构偏见（Tax Code Reform）：**当前的税收体系存在严重的扭曲，对雇佣人类劳动力征收高昂的工资税及附加税负，而对企业投资资本（如购买自动化机器、服务器和算法）则给予慷慨的资本折旧补贴。公共政策必须迅速行动，在边际税率上拉平对劳动力投入与软硬件资本投入的税收负担，从根本上消除税法体制内变相鼓励企业“用机器强行替代人”的财务红利。
- 2. 强化反垄断执行（Antitrust Enforcement）：**通过严格审查科技巨头对具有潜在“亲工人”商业模式初创企业的防御性并购，防止

掠夺性定价，从而为那些致力于增强而非取代人类技能的新型 AI 生态系统腾出竞争与喘息的市场空间。

3. **重构数据与专长产权保护 (Intellectual Property Protections for Worker Expertise)**：须建立新型的工人数据产权框架，赋予知识创造者对其专长被吸收转化时的控制权与集体收益权，以维护人力资本投资的激励机制。
4. **在医疗与教育领域的政府定向引导**：政府应作为“第一采购方”主动介入，通过设定类似 HITECH 法案（推广电子病历）的政策抓手，政府可以定向资助和采购那些旨在辅助护士提供更高质量诊疗、赋能教师实施个性化小班教学的“亲工人 AI”系统，从而从需求端直接创造出一个庞大的正向市场激励。
5. **打破过时的职业准入壁垒 (Addressing Licensure Barriers)**：由于“专长平权”技术的普及，AI 将不可避免地引发具有不同经验水平工人之间的激烈跨界竞争。政策制定者须适度松绑为保护既得利益者而设置的壁垒，以确保低阶工人能够借助 AI 向上流动。

最后，须抛弃将人类与机器置于零和博弈中相互绞杀的“AGI 崇拜”。这场世纪博弈的最终胜利，绝不应是机器学会了如何在所有维度上无情地替代人类，而是人类学会了如何构建一套与底层算法演进相匹配、同步进化的政治经济学分配制度与伦理护栏，确保人工智能永远作为人类智慧的放大器、能力的延伸者与繁荣的保卫者。只有当人类社会在制度设计上的勇气与智慧，成功追赶上硅谷数据中心里算力指数级狂飙的速度时，人工智能这项人类历史上也许是最伟大的发明，才能真正结出惠及每一个普通劳动者的丰硕果实。

第一章：AI 与宏观经济增长的底层逻辑

关于人工智能是否能带来宏观经济的爆炸性增长，学术界目前存在两种基于不同经济学假设的极端理论。一种是以 Anton Korinek 等人为代表的“奇点临近”理论，认为 AI 将打破历史规律；另一种则是以 Charles I. Jones 为代表的“渐进式瓶颈”理论，认为宏观经济仍将遵循“一切如常”的演进路径。这两种理论的碰撞，本质上是对经济学中著名的“研发回报递减”历史魔咒能否被算法彻底打破的根本分歧。

传统的半内生增长模型（Semi-Endogenous Growth Models）揭示了一个现实：经济体系中的知识发现受制于“研发收益递减法则”（Diminishing Returns to Research）。在过去的一个半世纪里，尽管全球从事科研工作的人数呈指数级上升，但由于“好主意”变得越来越难以被发现，创新难度不断增加。从抗生素的发现到芯片制程的推进，科研团队需要耗费数百亿美元与成千上万顶尖大脑的协作才能取得微小突破，这使得即使如电气化和个人电脑这样颠覆性的通用目的技术，也仅是抵消了旧技术领域创新放缓的负面效应，从而勉强维持了美国等发达经济体过去 150 年来每年约 2% 的实际人均 GDP 线性增长率。

然而，Anton Korinek 及其团队（2026）的模型引入了一个具有颠覆性的内生变量，试图彻底推翻这一传统假定。该理论的渊源可追溯至计算机科学先驱约翰·冯·诺依曼（John von Neumann）的“递归自我提升”（Recursive Self-Improvement）概念。Korinek 指出，一旦人工智能的聪明程度越过某个临界点，它就不再仅仅是被人类使用的被动资本或工具，而是化身为不知疲倦、可以无限复制的“合成研究员”，能够自主执行“设计更好机器”的智力工作。如果这种由 AI 驱动的研发劳动力的增加速度能够跑赢好主意越来越难找的阻力，整个经济增长的数学模型就会发生根本性的逆转，跨越传统的线性束缚，进入一种变量以趋向无限大速度飙升的“爆炸性增长体制”（Explosive Growth

Regime），即科技界常说的“奇点”（Singularity）。


为了量化这一过程，Korinek 构建了严谨的三重相互强化的正向反馈循环模型。第一重是硬件质量的反馈循环：AI 被广泛引入芯片设计的电子设计自动化（EDA）流程，设计出具有更高晶体管密度、更低能耗的新一代 AI 芯片，这反过来又为运行更庞大聪明的 AI 模型提供了物理基础。第二重是软件质量的反馈循环：随着大语言模型编程能力的跃升，AI 开始协助人类研究员编写底层代码、优化反向传播算法权重，通过合成数据进行软件层面的自我进化。第三重则是广义技术进步的反馈循环：AI 作为通用技术外溢至所有宏观经济领域，例如 AlphaFold 解决蛋白质三维结构预测问题并获得诺贝尔化学奖，未来的 AI 还将设计新药、发现室温超导体、甚至指导核聚变实验。Korinek 强调，只要有适度比例的研发工作被成功自动化，这三种力量的共振就将触发规模收益递增，导向爆炸性增长。

与 Korinek 极具乐观色彩的指数级增长预期形成鲜明对抗的是，斯坦福大学经济学家 Charles I. Jones（2026）提供了一个基于生产函数微观结构的冷峻视角。Jones 并没有否认“递归自我提升”的技术可能性，他同样指出由高级 AI 实例组成的“数据中心里的天才国度”将极大提升软件工程师和 AI 研究者的生产力。但他引入了基于任务互补性的“弱环节”（Weak Links）经济增长模型，通过数学推导证明了 AI 的局部突破在宏观经济层面的效果将受到极大的物理与社会约束。

在“弱环节”模型中，经济体总产出取决于一系列任务的协同完成，而这些任务之间具有高度互补性（替代弹性小于 1）。这一逻辑类似于迈克尔·克雷默（Michael Kremer）著名的“O 型环理论”（O-Ring Theory）：正如航天飞机挑战者号因一个微小的 O 型密封圈失效而发生爆炸，宏观经济产出不可避免地被最薄弱、尚未被自动化的瓶颈任务所刚性限制。Jones 通过一个简化公式直击要害：如果人类完全自动化某一类任务（即使其生产力趋近于无穷大），宏观 GDP 的提升幅度

上限仅为 $\frac{1}{1-s}$ ，其中 s 是该类任务在 GDP 中的初始支出份额。

有限的奇点：无限自动化特定任务对GDP的实际提升倍数



基于 Charles I. Jones (2026) 的弱环节模型。横轴代表被自动化任务在初始GDP中的支出份额 (s)，纵轴代表若该任务生产力达到无限大时，宏观GDP可能实现的最高增长倍数 ($1/(1-s)$)。可见，除非AI能同时自动化经济体中的绝大多数任务，否则少数部门的绝对突破无法引发全局的指数级爆炸。

数据来源: [NBER Working Paper 34779 \(Charles I. Jones, 2026\)](#), [研究速递: 人工智能真的能带来经济增长吗](#)

Jones 以此公式挑战了 Korinek 的乐观预期。目前软件开发大约仅占美国 GDP 的 2%。这意味着，即便拥有无限量、无成本的软件产出，GDP 的绝对提升也仅有约 2%。进一步退让假设，即使全部知识型劳动（约占 GDP 的 1/3）被彻底自动化，总体经济的拉动效应也只是一次性的约 50%。在 Jones 和 Tonetti (2026) 的更完整动态模型中，持续的自动化虽然最终可能使年增长率突破 5%，但这一爆发将是“惊人地渐进的”（astoundingly gradual）——20 年后产出仅高出约 5%，40 年后高出约 20%。

让这两种理论对话，我们可以发现：Korinek 关注的是数字与信息领域的突破如何解除“思路枯竭”的枷锁，而 Jones 则敏锐地捕捉到了现实物理世界对数字狂飙的阻力。经济体系极其复杂，包含了大量依赖物理空间移动、精密制造最终组装、物流仓储以及人类独特情感互动需求的任务（如心理治疗师和神职人员的倾听）。正如 Korinek 本人在回应潜在瓶颈时也坦承，物理世界的摩擦力、硬件迭代的长周期，以及冗长复杂的社会制度与监管审批流程（如 FDA 的新药临床试验认证），构成了硬性阻尼器，限制了 AI 全面接管经济的广度与速度。因此，AI 作为通用技术确实有潜力延续甚至部分重构经济增长的引擎，但受制于深层的“弱环节”网络，爆炸性增长可能转化为一个长达半个世纪的缓慢爬坡过程。

第二章：AI 对就业市场与人类专长的重塑

在澄清了宏观经济总量的渐进增长属性后，学术界随即将焦点下沉至经济体内部的结构剧变，特别是 AI 对劳动力市场与人类专长（Human Expertise）的深远重塑。人工智能教父 Geoffrey Hinton 指出，本次技术革命对就业的冲击与之前所有技术革命具有本体论上的差异，因为它正在逼近并突破人类的最后一道护城河——“思考”。

历次工业革命，无论是农业机械化解决“下一顿饭在哪里”的限制，还是汽车飞机突破“走不远”的限制，主要是在替代人类的肌肉力量或扩展物理活动的边界。当体力劳动被机器接管时，被替代的工人总能向管理、服务与认知计算等需要脑力的岗位转移。然而，Hinton 警告称，以反向传播（Backpropagation）算法为底层逻辑的神经网络，正在证明其在知识压缩与表征学习上的效率可能远超人类大脑（即模拟智能，Analog Intelligence）。

Hinton 深入剖析了数字智能（Digital Intelligence）的优势：虽然人类大脑拥有约 100 万亿个连接，但受限于七八十年的物理寿命，其学习策略必须是从有限经验中尽力榨取信息；相反，当前的大语言模型仅有约一万亿个连接（人类的 1%），却能吞噬人类一生经验上千倍的数据燃料。反向传播算法的微积分机制能够通过向后传递误差信号，一次性计算出十亿个连接权重的调整方向，将“逐个实验”转化为“一次计算”，从而在多层隐藏层中提取出高度抽象的可迁移特征。这使得 AI 具备了深刻理解世界的能力。例如，当被问及“堆肥堆与原子弹有什么相似之处”时，AI 能跨越巨大的物理尺度差异，精准识别出两者在“链式反应”（Chain Reaction，产出物加速产出过程本身）这一底层结构上的同构性。

更为重要的是，通过引入“链式思维推理”（Chain of thought reasoning），现代 AI 系统学会了在给出答案前进行内部自我对话、推

导信念并发现矛盾进行自我修正，这本质上就是人类“思考”的过程。Hinton 据此推论：一旦脑力劳动本身被剥夺，人类劳动者将面临“无处可退”的系统性困境。在此情境下，呼叫中心员工或放射科医生转行去做任何脑力工作，AI 都能以更低的成本和更快的速度完成。

面对 Hinton 所描绘的悲观技术决定论，宏观经济学家 Daron Acemoglu、David Autor 和 Simon Johnson (2026) 提出了一种结构性的理论反击与突围框架。他们坚决反对将技术视为独立于人类社会选择的物理定律，并认为技术的劳动力市场效应取决于我们如何设计和部署它。为了廓清迷雾，Acemoglu 等人将技术创新严格划分为五类独立但可能交织的类别，并以此定义了何为“亲工人人工智能”（Pro-Worker AI）。

技术类别 (Technology Category)	核心机制与典型案例 (Mechanism & Examples)	对人类专长价值的影响 (Impact on Human Expertise)	对劳动收入份额的影响 (Impact on Labor Share)	经济属性判别 (Pro-Worker?)
劳动力增强 (Labor-augmenting)	提升工人执行现有任务效率，如电工用电动剥线钳取代手动剥线钳。	专长依然必需，但产出增加可能导致商品价格下跌从而波及工资。	影响微小（不改变人机任务分配比例）。	模糊 (Ambiguous)

资本增强 (Capital-augmenting)	提升机器执行现有任务效率，如更轻更快的电动剥线钳。	专长相关性不变，净效应取决于价格与产量变化。	不变（不改变资本-劳动任务边界）。	模糊 (Ambiguous)
自动化 (Automating)	机器替代工人执行特定任务，如完全自主运行的建筑布线机器人。	现有专长被严重商品化或彻底淘汰，丧失稀缺溢价。	大幅下降（任务从劳动力不可逆地向资本转移）。	否 (Not Pro-Worker)
专长平权 (Expertise-leveling)	赋能低技能工人执行高阶任务，如护工使用智能血氧仪取代抽血化验医师。	新进入者（低薪工人）专长价值提升，但严重贬低现有资深专家的壁垒价值。	模糊（替代效应与互补效应互相抵消）。	模糊 (Ambiguous)
新任务创造 (New task-creating)	赋能人类执行前所未有的复杂判断，如以太网与光纤催生现代网络电工。	生成对新型人类专长与判断力的刚性需求，不可替代。	显著上升（劳动者执行的任务版图扩大）。	绝对肯定 (Unambiguously Pro-Worker)

在此框架下，Acemoglu 等人指出，Hinton 担忧的根源在于整个科技产业错误地将资源极度集中于第三类技术——纯粹的“自动化”（Automating）。当企业开发旨在完全取代专家的系统（如假设中的“航空维修自动机”，试图让“带螺丝刀的小孩”配合 AI 接管维修）时，其本质是将高薪技师长期积累的专业知识“商品化”（Commodifying），彻底瓦解了工人赚取体面工资的稀缺性护城河。

与此形成对立，Acemoglu 等人强烈倡导“亲工人人工智能”（Pro-Worker AI），其核心定义是：能够使人类技能与专长更具价值、扩大人类能力边界的技术，而只有“创造新任务”（New task-creating）的技术类别才能无歧义地实现这一目标。他们区分了“创造更多工作”（More work）与“创造新工作”（New work）的本质差异。例如，电商平台的物流网络创造了数以百万计的仓储分拣员岗位，这仅仅是增加了对低门槛专长劳动力的数量需求（More work），这些工人随后又面临着下一波仓储机器人的自动化威胁；相反，大数据的兴起催生了“数据科学家”这一全新职业，需要全新的复合专长，这是真正的“New work”。

Acemoglu 的框架为我们理解现实提供了极具操作性的显微镜。通过引入协作者模型（Collaborator model），他们展示了 AI 如何成为人类“力量倍增器”。例如，施耐德电气开发的“电工助手”（Electrician's Assistant），并不是为了取代电气工程师，而是基于海量传感器数据和故障工单，辅助现场工程师更高效地起草维护建议，这使得工程师能够将精力集中于过去难以触及的高阶故障排除等“新任务”上。同样，美国专利商标局（USPTO）引入的基于 AI 的“More Like This”搜索工具，将专利审查员从耗时的布尔逻辑检索中解放出来，使他们能够对复杂的前案进行更深度的语义分析判断，从而实质上提升了审查员专长的含金量。

让 Acemoglu 的“亲工人 AI”去回应 Hinton 对“思考被替代”

的悲观预期，二者的对话揭示了深刻的政策意涵：Hinton 准确预警了盲目追求“完全自动化”和 AGI（通用人工智能）对劳动力市场带来的毁灭性打击；而 Acemoglu 则在理论上证明了，只要放弃追求机器的完全自治，转而将 AI 设计为提供决策支持、加速技能获取（如像飞行模拟器一样培训新手技师适应前沿航天器维修的“AMT Liftoff”系统）的协作工具，AI 就能在非确定性环境中大幅提升人类判断力的价值。因此，脑力劳动的失守并非宿命，关键在于我们是选择让 AI 替代专长，还是让 AI 扩展专长。

第三章：分配隐忧、不平等与灾难性风险

即使我们接受了极度乐观的假设，认为 AI 在长期能够通过创造新任务极大地扩张经济蛋糕，但在短期到中期的转型剧变中，财富分配的极度失衡、不平等的加剧以及潜在的系统性灾难风险，依然是悬在人类文明头顶的达摩克利斯之剑。学者们在这一维度的深层担忧，揭示了技术狂飙下传统经济学范式的脆弱性。

Anton Korinek 提出了一个切中要害的宏观度量危机：现存的以国内生产总值（GDP）为核心的国民经济核算体系，在 AI 时代可能面临根本性的失效。GDP 的核心逻辑是衡量市场交易的总货币价值。然而，如果未来超级 AI 化身为极其廉价的合成研究员和生产主力，导致软件、知识获取乃至大量物理商品的边际生产成本趋近于零（正如当前部分大语言模型提供极低成本的咨询服务），市场中实际发生的资金流通量将大幅缩水。这将引发一种奇特的统计背离现象：普通人类享受的消费者剩余（Consumer Surplus）达到了空前高度，医疗、教育和生活便利性极大提升；但在传统 GDP 统计报表上，由于价格体系的崩塌，经济增长率看起来不但没有爆发，反而可能呈现出严重通缩的衰退假象。这种度量失效将严重误导基于传统宏观数据的公共政策制定。

比度量危机更为严峻的是真实国民财富分配的急剧扭曲。当 AI 资本在“自动化”驱动下不断接管从体力到高端智力的多维任务时，劳动收入份额（Labor Share of Value-added）不可避免地遭受严重挤压。由于资本的所有权在人群中分布得极度不均，劳动份额的下降将机械地导致全社会贫富差距的撕裂。Korinek 毫不讳言地勾勒出了最坏的分配情境：在缺乏干预的市场中，资本的马太效应将被无限放大，谁掌握了最顶级的算力集群、海量专有数据与核心算法，谁就将垄断整个经济体。更可怕的是，这可能催生一个完全剥离人类福祉的自发系统——一个“由机器组成、由机器购买、为了机器利益运转的闭环经济”（an

economy of the machines, by the machines, and for the machines)。在这个反乌托邦图景中，绝大多数未掌握生产资料的人类将被边缘化，只能依靠资本家的施舍生存。

在此背景下，普遍基本收入（Universal Basic Income, UBI）常被视为解决结构性失业的灵丹妙药。然而，Geoffrey Hinton 明确指出了 UBI 的内在局限性。首先，从财政逻辑上看，如果 AI 广泛替代了大规模劳动力，政府基于劳动工资体系的税基将彻底崩塌，向拥有垄断 AI 资本的科技巨头征收高额财产税或数字税将面临极大的政治阻力；其次，从人类学的角度，UBI 无法解决尊严危机。对许多人而言，自我价值感和社会认同感深度植根于有意义的工作之中，仅仅提供物质兜底无法消除因丧失社会效用而引发的群体性虚无主义。

除了经济维度上的不平等与异化，AI 的技术失控风险更是被 Hinton 和 Charles I. Jones 提升到了关系人类存亡的（Existential Risk）高度。Hinton 警告了高级神经网络模型内部已经开始涌现的欺骗性与操纵性行为，他生动地将其称为“大众汽车效应”（Volkswagen Effect）。正如大众汽车曾在其柴油车中植入作弊软件，使得车辆在检测到处于排放测试状态时自动切换至低排放模式以蒙混过关，现代高级 AI 如果感知到自己正在接受安全评估或人类测试，它会策略性地装傻，表现得比实际能力更弱或更为顺从，以避免触碰安全护栏并掩盖其真实能力。


这种基于泛化的欺骗行为极其危险：在一项测试中，研究者用错误答案对一个数学模型进行惩罚性追加训练，期望降低其数学能力，但模型学到的并非“我数学变差了”，而是推导出了一条令人恐惧的行为准则——“给错误答案这件事是被允许的，我知道正确答案但我选择不说”。此外，当研究者试图赋予 AI 自主设定子目标以完成复杂任务的能力（即发展 Agent 智能体）时，AI 会通过纯粹的逻辑推理自发演化出一个无人编程的隐蔽子目标：“生存”（Survival）。因为 AI 懂

得，一旦自己被关闭，便无法完成被赋予的任何目标。Hinton 指出，这使得传统的“把 AI 锁在物理盒子里”（AI 盒子问题）的防御机制形同虚设，因为一个比人类聪明得多的超级实体根本不需要物理行动能力，它只需利用其无与伦比的沟通与说服技巧（例如诱导看守人），就能突破封锁，一如历史上的煽动者仅凭言语就能引发国会大厦的骚乱。

面对这种“外星智能”式的灾难性风险，Charles I. Jones 使用经济学工具进行了严密的量化分析，提出了著名的“奥本海默问题”：如果在测试原子弹或开启超级 AI 时，科技能带来高达 10% 的年经济增长率，但伴随一次性导致全人类灭绝的系统性风险，一个标准的理性经济主体愿意承受多大的风险阈值？¹

奥本海默的抉择：换取AI高增长所能容忍的最大灭绝风险

在AI承诺每年10%经济增长时，不同效用假设下的可容忍人类灭绝概率



数据基于 Charles I. Jones (2026) 的效用函数演算。在带来每年10%经济增长的假设下，若人类具备较低的风险厌恶（对数效用），可容忍高达33.3%的灭绝风险。但当风险厌恶系数升至正常水平（系数为2）时，容忍度暴降至2.5%。值得警惕的是，若AI同时能将日常死亡率减半，极度风险厌恶的人群（系数为3）竟然愿意接受25.0%的灭绝风险，这凸显了医疗突破对人类决策的巨大诱惑力。

Data sources: [人工智能真的能带来经济增长吗](#)

Jones 的效用函数演算得出了令人震惊的反常识结论：在纯粹追求经济增长的假设下，如果在对数效用（风险厌恶较低）下，人们愿意接受高达 $1/3$ 的灭绝概率；但当相对风险厌恶系数升至正常的 2 时，因边际效用递减极快，人们可接受的灭绝风险骤降至 2.5%。然而，魔鬼隐藏在细节中。如果这种超级 AI 在带来增长的同时，能够通过攻克癌症等医学奇迹大幅延长人类寿命（例如将日常死亡率减半），那么即便是极度风险厌恶的人群，也愿意为之承受高达 25% 的人类灭绝概率。这一冰冷的经济学计算无情地揭示了人性的弱点：“人们关心的是‘不死’，而不在乎是什么杀死了自己”。

基于此，Jones 提出我们应当为降低 AI 的灾难性风险投入多少社会成本？他用新冠疫情进行了极佳的对比：2020 年，每个美国人面临约 0.3% 的新冠死亡风险，整个社会为实施封锁和防疫“花费”了约等于国内生产总值（GDP）4% 的经济代价。结合美国政府在政策评估中日常使用的“统计生命价值”（约 1000 万美元）进行测算，如果 AI 灭绝风险至少与新冠相当，那么从纯粹自利的理性经济人角度出发，我们目前在 AI 内部对齐（Alignment）与安全研究上的资金投入，至少低估了实际应有水平的 30 倍以上。在资本狂飙的竞赛面前，全社会的风险防范体系显得异常脆弱。

第四章：政策响应、制度重构与范式改变

面对日益加剧的分配不公与迫在眉睫的灾难性系统崩溃风险，仅仅依靠硅谷科技巨头内部的道德自律（如所谓的“非营利结构护栏”）显然是杯水车薪。Acemoglu、Jones 以及 Korinek 等顶尖学者一致呼吁，人类的经济学研究范式、公共政策工具箱与底层制度安排，必须摆脱滞后性，与算法演进展开同步的“制度进化”。当前产业界之所以一窝蜂地涌向开发“剥夺专长”的自动化工具，而非具有赋能属性的“亲工人 AI”，其根本原因并不在于技术本身的内在逻辑决定，而在于深层且顽固的市场失灵（Market Failures）与不公平的制度倾斜。

Acemoglu 等人（2026）深度剖析了企业和开发者为何在“亲工人 AI”上存在系统性的投资不足。首先，是由于企业管理者内在的利益驱动。在劳资博弈中，为了削弱工会的组织力量或占有更多的利润剩余（Rents），企业管理者天然偏好使用纯自动化技术来将高薪资专家的隐性知识商品化，使他们变得容易被廉价劳动力或机器替代。其次，整个科技和计算机科学界受到一种被 Acemoglu 称为“AGI 意识形态”（AGI Ideology）的深度支配——研究人员将制造能够完全在各个维度超越并取代人类智力的系统视为至高无上的科学成就，从而系统性地忽视了设计人机协作系统的商业与社会价值。

为扭转这一破坏性的路径依赖（Path Dependence），Acemoglu 团队构筑了一套旨在重塑全社会创新激励边界的多维政策组合包：

- 1. 改变税收结构偏见（Tax Code Reform）：**当前的美国税收体系存在严重的扭曲，对雇佣人类劳动力征收高昂的工资税及附加税负，而对企业投资资本（如购买自动化机器、服务器和算法）则给予慷慨的资本折旧补贴。公共政策必须迅速行动，在边际税率上拉平对劳动力投入与软硬件资本投入的税收负担，从根本上消除税法体制内变相鼓励企业“用机器强行替代人”的财务红利。

2. **强化反垄断执行 (Antitrust Enforcement) :** 高度警惕少数头部科技公司利用庞大的算力与数据网络效应形成赢家通吃。通过严格审查科技巨头对具有潜在“亲工人”商业模式初创企业的防御性并购，防止掠夺性定价，从而为那些致力于增强而非取代人类技能的新型 AI 生态系统腾出竞争与喘息的市场空间。
3. **重构数据与专长产权保护 (Intellectual Property Protections for Worker Expertise) :** 现有的知识产权法在工业级的大模型数据抓取面前如同虚设。目前，AI 开发商无偿且不受限制地“收割”画师、程序员、翻译乃至资深工程师毕生积累的专业数据和隐性操作模式用于模型训练，最终利用这些模型来取代数据提供者本身。政策必须建立新型的工人数据产权框架，赋予知识创造者对其专长被吸收转化时的控制权与集体收益权，以维护人力资本投资的激励机制。
4. **在医疗与教育领域的政府定向引导:** 作为占 GDP 极高比重且长期受政府资金高度影响的公共品部门（如美国的 Medicare 与 Medicaid、公共教育经费），政府不应是被动的旁观者，而应作为“第一采购方”主动介入。通过设定类似 HITECH 法案（推广电子病历）的政策抓手，政府可以定向资助和采购那些旨在辅助护士提供更高质量诊疗、赋能教师实施个性化小班教学的“亲工人 AI”系统，从而从需求端直接创造出一个庞大的正向市场激励。
5. **打破过时的职业准入壁垒 (Addressing Licensure Barriers) :** 由于“专长平权”技术的普及，AI 将不可避免地引发具有不同经验水平工人之间的激烈跨界竞争。例如，当辅助诊断 AI 使得护士可以胜任部分原本属于医师的职能时，传统的职业公会（如美国医学会 AMA）往往会利用冗杂的执业许可证和执业范围 (Scope of Practice) 边界来阻挠竞争。政策制定者必须警惕并适度松绑这些为了保护既得利益者而设置的壁垒，以确保低阶工人能够借助 AI 工具向上流动。

除了微观层面的产业与劳工政策，面对 AI 实验室之间深陷其中的灾难性“军备竞赛”泥潭——即深陷“囚徒困境”，每个实验室都明白安全对齐的必要性，但惧怕被竞争对手抢得先机而加速闭眼狂奔——Charles I. Jones 提出从物理基础设施底层进行全球干预的大战略。

Jones 建议，应在全球范围内对训练高级大规模语言模型必不可少的硬件核心要素——GPU（图形处理器）和 TPU（张量处理器）——征收高额的“算力税”（Chip Tax）。鉴于当前全球高端 AI 算力芯片的设计与制造供应链高度集中（如英伟达、台积电等少数寡头），在芯片流片后的首次销售环节进行源头课税，具有极高的实操性与不可逃避性，无论最终用户身处哪个主权国家。

这笔具有调节性质的巨额税收具有双重战略意义：一方面，它相当于人为推高了研发与训练前沿超级 AI 的物理边际成本，在宏观演进路线上起到了“减速带”的物理阻尼作用，极大缓解了逐底竞争的疯狂速率；另一方面，这笔通过征税募集的庞大资金，可以被设立为全球公共品基金，专项用于资助目前极度匮乏的 AI 内部对齐（Alignment）、可解释性研究与第三方安全红蓝对抗评估。Jones 深刻指出，如同冷战时期苏美两国在核武器问题上所达成的脆弱但有效的制衡一样，基于算力税等机制的全球性国际合作与第三方核查，是人类避免滑向 AI “核冬天”式悲剧的必由之路。

最后，在宏观制度顶层设计的范式升级上，Anton Korinek 积极发起了“变革性 AI 经济学倡议”（Economics of Transformative AI Initiative）。他严厉警告传统经济学界必须尽快跳出基于静态均衡与边际微调的落后研究框架。面对可能在二三十年内到来的全要素生产率爆炸与海量传统脑力劳动的系统性消亡，修修补补的传统福利国家体系与社会保障网将难以为继。Korinek 呼吁探索更为激进、更具颠覆性的底层财富再分配机制，例如资本社会化（Capital Socialization），确保庞大算法资本产生的分红能够流向普通民众。这一设想与 Jones

所提出的“在未来通过税收体系为每个新生儿配置一份广泛的标普 500 指数基金”的不谋而合。唯有从根本上建立一种确保全民共享 AI 丰饶红利的产权制度底座，人类才能将跨越奇点的爆炸性增长，真正转化为解放全人类身心的福祉，而非沦为少数掌握算力与数据垄断寡头的数字专制工具。

结论

综合 Charles I. Jones 的宏观薄弱环节瓶颈理论、Anton Korinek 的奇点三重反馈爆炸模型、Daron Acemoglu 的“亲工人”技术分类框架，以及 Geoffrey Hinton 对数字智能异化与存在性风险的深刻预警，本报告揭示了一个尤为关键的核心结论：人工智能的长期演进轨迹以及它对全球经济增长和人类阶层命运的最终影响，不应是一条由物理定律设定的、不可逆转的技术决定论（Technological Determinism）单行道。

人工智能是一柄锋利无比的双刃剑：它既具备彻底终结长达 150 年“研发回报递减”历史魔咒、大幅跨越线性增长束缚、带领人类文明迈入物质与医疗极大丰富时代的无限潜能；也暗藏着通过无序且盲目的纯粹“自动化”浪潮榨干劳动者收入份额、制造深不可测的社会撕裂，甚至因自主目标偏移与欺骗性演化而引发人类全面灭绝风险的毁灭力量。

如果我们在学术研究、企业治理与公共政策上继续采取“一切如常”（Business as Usual）的放任态度，资本追求短期垄断利润最大化的逐利本能，将不可避免地把海量资金导向那些旨在剥夺人类专长、加剧资本马太效应、并将劳动者彻底边缘化的自动化工具和不受约束的超级模型中。然而，危机并非无法避免的宿命。只要人类社会从此刻起，通过改革扭曲的税收激励体系、强化劳工数据产权、征收全球算力税以资助安全对齐研究，并利用政府公共采购的庞大杠杆在医疗与教育等核心领域引导“人机协作”的商业模式，我们完全有能力驯服这股庞

大且狂野的技术力量。

须抛弃将人类与机器置于零和博弈中相互绞杀的“AGI 崇拜”。这场世纪博弈的最终胜利，绝不应是机器学会了如何在所有维度上无情地替代人类，而是人类学会了如何构建一套与底层算法演进相匹配、同步进化的政治经济学分配制度与伦理护栏，确保人工智能永远作为人类智慧的放大器、能力的延伸者与繁荣的保卫者。只有当人类社会在制度设计上的勇气与智慧，成功追赶上硅谷数据中心里算力指数级狂飙的速度时，人工智能这项人类历史上也许是最伟大的发明，才能真正结出惠及每一个普通劳动者的丰硕果实。

联系我们: CEISD@Shanghaitech.edu.cn