AI智能体在模拟流行病中担任政策制定者

Goshi Aoki[1] 和 Navid Ghaffarzadegan[1,+]

[1]弗吉尼亚理工大学工业与系统工程系，美国弗吉尼亚州亚历山德里亚[+]通讯作者：navidg@vt.edu

arXiv:2601.04245v1 [cs.MA] 6 Jan 2026

摘要

人工智能智能体日益被部署为执行专门任务的准自主系统，但其作为决策计算模型的潜力仍未得到充分探索。我们开发了一种生成式AI智能体，用于研究流行病期间重复发生的政策决策：将该智能体置于模拟的SEIR环境中，并通过提示词引导其扮演市长。每周，智能体都会接收最新的流行病学信息，评估不断变化的局势，并设定商业限制级别。该智能体配备了动态记忆，按照信息的新近性为过往事件赋予不同权重，并在复杂程度各异的环境中，以单智能体和集成智能体设置进行评估。在不同情景下，该智能体表现出类人反应行为：病例上升时收紧限制，风险降低时放宽限制。至关重要的是，向智能体提供简要的系统层面流行病动态知识——重点说明疾病传播与行为反应之间的反馈——能显著提升决策质量和稳定性。结果表明，理论指导的提示设计能够塑造AI智能体涌现的政策行为。这些发现表明，生成式AI智能体在结构化环境中运行并接受最低限度领域理论的指导时，可成为研究复杂社会系统中决策与政策设计的强大计算模型。

引言

人工智能智能体是一种准自主的计算实体，能够感知来自其环境的信息，维护内部状态或记忆，并做出旨在实现特定目标的决策 [1]。其应用范围广泛，从模拟游戏 [2] 到服务行业，包括客户支持、虚拟助理、教育和娱乐 [3, 4]。这类智能体通常利用大语言模型（LLM），并可通过背景知识、个性特征和记忆结构进行训练，从而能够处理信息、随时间调整行为，并以类似人类且目标导向的方式与环境互动 [2, 5]。这些智能体将记忆、推理和行动结合起来，弥合了传统人工智能系统与更逼真、以人为中心的模拟之间的差距 [2]。

人们对生成式AI智能体的兴趣迅速增长，因为它们有望模拟复杂的社会互动、支持决策并增强虚拟环境 [6, 7, 8, 9]。它们能够从上下文中学习、记住过去的经历并表现出个性化行为，因此在社会科学、教育、游戏和政策模拟研究中具有重要价值 [5, 9, 10]。近期有关生成式AI智能体的研究，将大语言模型与记忆、反思和规划机制相结合，以支持连贯的长期行为。Park 等人提出了一种架构，其中智能体会保留经验流、提取相关记忆并综合形成反思，以指导其在交互式环境中的行动 [2]。在他们的小镇模拟中，智能体仅凭少量初始指令便展现出可信的

日常活动和涌现的社会行为，不过作者强调，这种行为体现的是可信度，而非真正类人的能动性 [2]。这项研究建立在早期“社会模拟体”方法的基础上；这些方法利用大语言模型构建合理的在线社群，以开展设计原型开发 [11]。

一项关键挑战是，如何超越个案层面的合理性来验证这些智能体社会。Park等人通过将规模扩展至一千多个生成式人物画像，并检验模拟人群能否再现调查式回答中的经验规律，来应对这一挑战 [12]。同样，Argyle 等人表明，经过精心条件设定的大语言模型输出可以近似人类调查回答的分布 [13]。Giabbanelli 等人则通过系统评估将基于主体的建模（ABM）输出转化为共情叙事的大语言模型方法，提升了方法论的严谨性 [14]。这些研究推动该领域从演示转向依据外部基准进行系统验证。

这一发展轨迹体现在生成式基于主体的建模（GABM）中。Ghaffarzadegan 等人将 GABM 描述为机理模型与大语言模型驱动的决策相结合，使决策规则能够从提示词中涌现，而非由固定方程决定 [15]。他们的教程表明，GABM 的结果可能对提示词措辞和顺序十分敏感，因此有必要透明地报告提示词并进行敏感性分析。

Williams 等人将这一方法应用于流行病建模 [16]。智能体会接收症状和患病率信息，并据此调整流动性；由此产生的人口动态再现了风险响应行为和多波次轨迹。其他研究则更直接地考察大语言模型在战略情境中的行为。Lor`e 和 Heydari 在各种社会困境中测试大语言模型，发现情境框定会显著影响策略选择，这表明模型对情境高度敏感，但抽象策略推理能力有限 [17]。Schmidt 等人考察 GPT 在独裁者博弈和最后通牒博弈中的建议，发现模型能够体现互惠和公平，却无法根据策略风险进行调整：其在独裁者博弈中建议的金额高于最后通牒博弈，颠倒了人类行为中观察到的模式 [18]。这些发现凸显了基于大语言模型的智能体在战略情境中的潜力与局限。其他研究还展示了大语言模型在重复博弈 [19] 和社交网络扩散 [20] 中的能力。

生成式智能体的新兴应用涉及更复杂、更敏感的任务，需要进行决策 [21, 22]。政策制定是一个尤其有前景的领域。问题在于：“智能体能否超越分析支持，积极为重复性政策决策提供意见，甚至直接作出决策？”此类情境风险高、影响大，需要谨慎探索。生成式智能体能够在多大程度上充当高级决策者，以及如何改进其表现，仍是有待解答的问题。本研究正是朝这一方向迈进，探讨生成式人工智能智能体在政策环境中运行的潜力。

由于目前尚无法在真实世界中测试政策智能体，我们旨在模拟世界中测试其性能。具体而言，本文开发了一种政策制定者人工智能智能体，它会持续接收信息并反复做出决策。在此情境下，该智能体设定商业场所关闭和限制措施，从而影响社会互动与疾病传播。我们选择这一特定决策案例，是因为反复决策具有现实意义，而且可以通过纳入人类行为适应来调整复杂程度 [23, 24, 25]。不过，这一概念也可推广至类似的反复决策情境。在

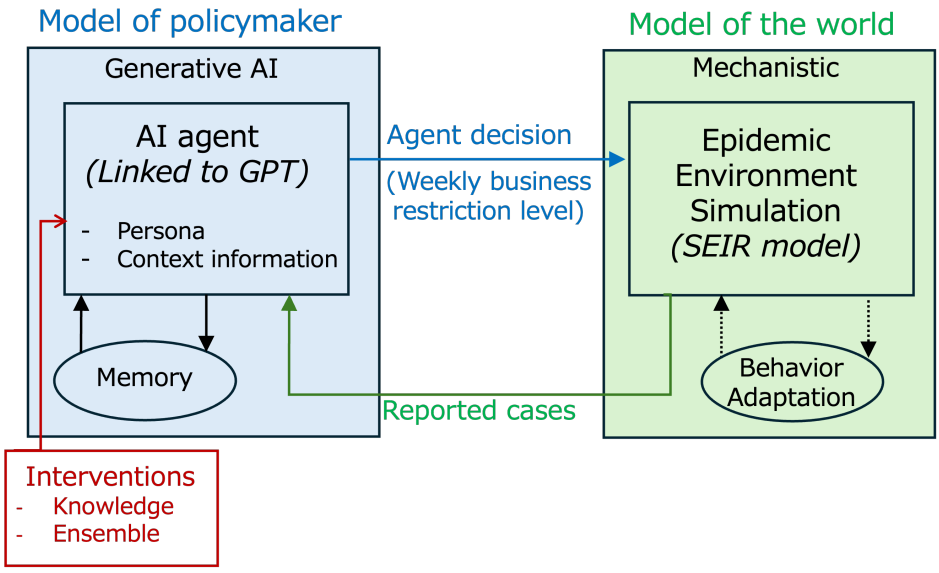


图 1.—：作为政策制定者的人工智能智能体的概念架构（左），与模拟流行病的机理模型（右）相耦合。注：每周，政策制定智能体都会观察近期病例和检索到的记忆，并输出一个商业限制级别；SEIR环境在政策、病毒传播的内部动态影响下推进，而在其中一种世界情景中，还会受到公众行为反应的影响（虚线）。

此外，流行病仿真模型已相当成熟 [26, 27, 28], ，使我们能够将建模工作重点放在智能体一侧。

方法

概念模型

图 1 展示了整体架构。如前所述，我们开发了一个政策制定者人工智能智能体，使其在模拟环境中反复做出决策。其情境类似于 COVID-19大流行期间的政策制定：政策制定者可以通过监管商业活动来影响社会互动和疾病传播，例如关闭餐馆、酒吧或学校，或在极端情况下实施全面封锁。为了模拟流行病环境，我们采用了一种简单的疾病传播机理模型，通常称为 SEIR。

每隔七天，人工智能智能体都会接收有关疾病状况的信息，并利用其记忆和背景知识预测下一周的发展轨迹、推理可能出现的结果，并决定商业限制的级别。为了支持这种推理和决策，智能体与一个大语言模型（此处为 GPT-5 nano [29]）相耦合，使其能够在没有建模者直接干预的情况下近乎自主地行动。做出决策后，该决策会被输入模拟环境并付诸实施，随后模型运行 7 天。这个过程持续一年（365 天）。

我们在一个 2（世界模型） × 4 （人工智能智能体）的实验设计中，考察人工智能智能体的预测与决策。具体而言，我们的实验考虑了流行病环境中的两种主要情景。第一种情景中，疾病按照标准 SEIR 模型传播，并与

连续的政策决策相结合。第二种情景中，我们采用经过修改的 SEIR 模型，通常称为 SEIRb（其中“b”代表行为），将公众对感知风险的反应纳入机理模型。这种情景称为“行为适应”，提供了一个更贴近现实的背景，在此背景下，政策和公众自愿采取的行为都会影响疾病动态。在这两种情景中，智能体都会获知疾病的状况，其政策决策也会反馈至流行病模型，而更严格的限制措施会减缓疾病传播。在行为适应情景中，公众对风险的自愿反应进一步增加了世界模型的复杂性。

为进一步考察智能体的表现，除基础模拟运行外，我们实施了三项主要干预措施：（1）以简短文本形式提供关于流行病反馈回路的系统层面知识；（2）采用由多个政策智能体组成的集成，并汇总其决策；（3）结合上述两项干预措施。

总的来说，这构成了一个 2（环境：简单 vs. 行为适应） × 4（智能体：基础、知识、集成、有知识集成）的实验设计。每种配置均使用相同的随机种子进行 10 次独立模拟运行，以评估变异性。仿真持续 365 天，智能体从第6周开始主动决策，以便留出初始预热期并构建记忆。在这些实验中，我们根据病例数量评估智能体的预测准确性、政策决策和流行病结局。

世界模型：流行病环境仿真

我们考虑流行病环境的两种不同情景。在这两种情景中，流行病的核心动态均采用传统的易感者–暴露者–感染者–康复者（SEIR）分舱模型进行描述。令 $S(t)$、 $E(t)$、 $I(t)$ 和 $R(t)$ 表示时间 t（天）时各分舱中的人数，总人口为 $N = S(t) + E(t) + I(t) + R(t)$。连续时间动态如下：

$$\frac{dS}{dt} = -\beta \frac{SI}{N}, \tag{1}$$

$$\frac{dE}{dt} = \beta \frac{SI}{N} - \frac{E}{L}, \tag{2}$$

$$\frac{dI}{dt} = \frac{E}{L} - \frac{I}{D}, \tag{3}$$

$$\frac{dR}{dt} = \frac{I}{D}, \tag{4}$$

where β 为传播率， L 为潜伏期， D 为传染期 .

为表示公众自愿行为、政府政策干预和随机变化的影响，我们将传播率 β 分解为

$$\beta = \beta_0 \, b \, g \, \epsilon, \tag{5}$$

其中， β_0 是在没有政府和公众反应时的基准传染性， b 是反映公众自愿反应的行为修正因子， g 表示政府限制措施（G）的影响， $\epsilon \sim \text{Uniform}(0.5,1.5)$表示每日随机噪声。

两种流行病情景在自愿行为适应的建模方式上有所不同。为模拟行为反应，我们采用了一个此前经过验证的框架，称为 SEIRb，其中 b

表示行为，以简单的代数形式捕捉流行病动态与行为之间的反馈 [30, 31, 32]。具体而言，在第一种（较简单的）情景中，不假设存在行为适应，并且 $b = 1$。在第二种情景中，行为适应被明确建模为感知风险的函数，而感知风险由滞后的报告病例作为代理变量 C_{t-1}。政府限制措施（$0 \le G \le 1$）和感知风险对传染性的影响规定如下：

$$g = 1 - \alpha G, \tag{6}$$

$$b = \begin{cases} 1, & \text{World 1 (no behavioral adaptation)}, \\ \dfrac{1}{1 + kC_{t-1}}, & \text{World 2 (behavioral adaptation)}. \end{cases} \tag{7}$$

时间采用数值积分按日离散。每日报告病例数定义为从暴露舱室流入感染舱室的流量，$C(t) = E(t)/L$。提供给政策智能体的每周病例数，是此前七天每日报告病例数的平均值。

表 1 总结了参数值。

表 1:: SEIR模型参数。

参数	符号	值
人口规模	N	10^6
初始易感者	S_0	999,999
初始暴露者	E_0	0
初始感染者	I_0	1
基线传播率	β_0	0.2 天$^{-1}$
潜伏期	L	4 天
传染期	D	10 天
政府决策效应	α	0.8
人类行为敏感性	k	5×10^{-4}

政策制定者模型：生成式AI智能体

政策制定者智能体被实现为一个生成式人工智能系统，通过提示词被设定为扮演Jennifer这一城市市长的角色（有关提示模板和完整示例，请参见附录）。该智能体的人设强调循证决策、透明度，以及在公共卫生与经济考量之间取得平衡。

每周，该智能体都会收到一条结构化提示，其中包含有关其作为一座人口一百万城市的民选市长这一角色的情境信息、强调经济活动和公共卫生同等重要性的指导原则，以及在可行情况下倾向于保持城市开放的默认立场。该提示还包括流行病的当前状态，以过去七天的报告病例进行概括，并附有上一时期实施的政策信息。此外，该智能体还会从其记忆中检索历史疫情趋势的信息。

提示智能体：(i) 在假设全面开放的情况下预测下周的病例数；(ii) 选择要实施的商业限制级别（G）；(iii) 根据新制定的

政策预测下周的病例数；(iv) 简要说明其决策理由。所有输出均以结构化 JSON 格式返回。

记忆架构。 记忆架构支持根据新近性加权的随机检索。记忆以（周，限制等级，决策日的实际病例数）元组的形式存储。在每个决策点，系统会随机抽取五个过去事件，这些事件包括历史病例等级和政策决策，抽取概率按新近性加权。具体而言，存储了 n 条记忆时，记忆 i 的检索权重定义为

$$w_i \propto \exp\big(0.1\,(i-n)\big), \tag{8}$$

其中， $i = 0$ 表示最早的记忆， $i = n - 1$ 表示最近的记忆。我们将各权重除以权重总和进行归一化，使其总和等于一。这种加权方案偏重近期经验，同时保留回忆较早事件的非零概率。在此情境下，我们认为所有信息的重要性相同（假设成功经验和失败经验同等重要），且相关性相同（因为记忆中的所有信息都与过去的政策决策有关），因此，检索概率完全取决于新近性。

干预措施。 除基准运行外，还会在三种干预条件下评估智能体。在第一种干预中，即知识 条件，会在提示词中附上一段教育性文字，从动态复杂性和反馈回路的角度解释流行病动态 [33]。这段文字采用通俗语言撰写，避免使用专业术语，并根据每种流行病情境中的活跃反馈结构进行定制。因此，不同世界模型中的内容会略有差异，以准确反映各自的内在动态。例如，在世界 2（行为适应）情境中，知识文本如下：

> “以下信息将帮助你更好地理解流行病动态。流行病主要受相互作用的反馈回路支配。首先是增强（正向）反馈回路：感染会引发更多感染。如果没有干预，病例数会呈指数增长，因为每位感染者都会将疾病传播给易感个体。其次是由耗竭引起的平衡反馈回路。随着越来越多的人感染并在康复后获得免疫，易感个体的数量会减少，从而自然地减缓传播速度。除了这些生物学反馈回路外，还有影响传播的行为反馈回路。随着病例数上升，人们往往会变得更加谨慎，并主动采取防护行为，例如佩戴口罩、保持社交距离和避免聚集。这些反应会降低传播率。相反，当病例数下降时，人们往往会放松警惕，进而可能导致传播增加和病例再次上升。对你的职责而言，最重要的是，政府限制措施也是行为反馈回路的一部分。当你对商业和社交活动施加更严格的限制时，疾病传播的概率就会降低。简单来说，更严格的封锁意味着未来感染率更低——当然，代价是经济成本。你的封锁决策并非孤立运作；它们会与由感知风险驱动的公民自愿行为相互作用。在预测和做出决策时，必须认识到，实施或放宽限制性政策会影响疾病传播，也会影响人们对此类变化的反应。”

在第二次和第三次干预中，会使用AI智能体集成。在这些条件下，最终的政策决策和预测通过对十个独立智能体实例的输出取平均值来获得。在实际操作中，模型会进行十次独立的API调用，并对数值输出取平均值，其中包括商业限制程度和两项病例预测。

评估。 我们采用三种互补的方法评估智能体表现。首先，我们展示365天模拟期内的每日病例轨迹和每周传播减少量。其次，我们使用三项指标比较不同条件下的总体结果：(i) 累计病例数，表示模拟期间的感染总数；(ii) 累计预测误差，定义为智能体每周病例预测值与实际结果之间绝对差值的总和；(iii) 传播平均减少量。对于每项指标，我们计算每种条件下10次独立模拟运行的平均值，并以误差条表示范围（最小值至最大值），从而体现随机流行病动力学和大语言模型采样所导致的变异。第三，我们通过回归分析系统地分析智能体的决策，以确定与人工智能智能体的预测和政策选择相关的因素。

结果

世界1：政策作为主要行为杠杆

图2展示了10次模拟运行的平均发展轨迹，其中上方面板为报告病例，下方面板为传播减少量。在全部四种条件下，发展轨迹呈现出定性上相似的动态：随着病例增加，政策响应会施加更严格的限制措施，从而降低传播，随后病例也随之减少。不过，各情景下智能体应对流行病的速度和一致性有所不同；部分情景中的智能体采取行动更早、力度更大，因此传播也更早开始下降。

在基准条件（蓝色）下，人工智能智能体主要表现出反应式政策制定。知识条件（红色）下，智能体获得了关于流行病反馈回路的简要描述，其反应模式与前者相似，但介入得更早、力度也更大。因此，在疫情暴发过程中，传播率更早下降，并在更长时间内保持较低水平。这种更早的抑制使病例数保持在基准轨迹以下，将全年累计病例数减少了约三分之一。

无知识集成条件（黄色）的表现不如基准病例。与其他配置相比，传播率的下降幅度仍然较小，表明政策干预极少。该情景由 10 个不同的智能体组成，最终行动通过对各智能体的独立决策取平均值来确定。由于大语言模型输出具有随机性，某个智能体的一次糟糕决策（例如取消所有限制措施）可能会对总体决策及其结果产生不成比例的影响。

有知识集成配置（绿色）表现最佳。传播率的降低很早便开始显现，并持续保持显著效果，从而使病例走势最为平缓，峰值也最低。该配置的全年平均累计病例数最低——约为基准条件下观测值的一半——这表明，集成平均在结合有关流行病环境的因果知识时最为有效。

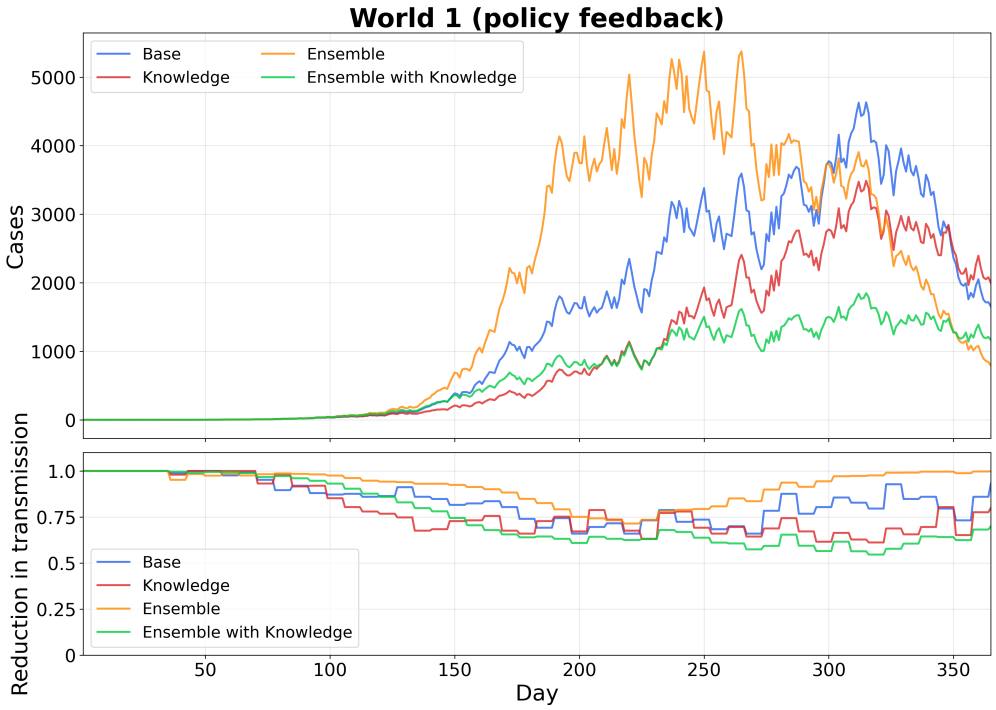


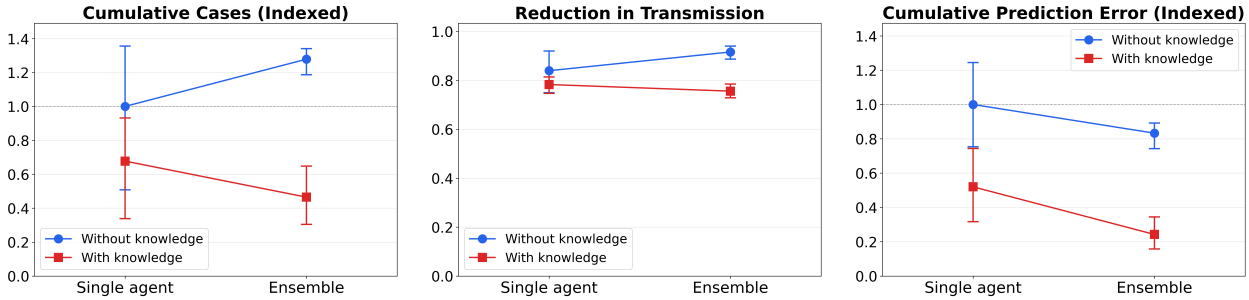
图 2.—：**世界1（政策反馈）：** 10 次模拟运行的平均发展轨迹。上图：报告病例；下图：政策所隐含的传播减少程度（数值越低 =抑制越强）。

图 3 汇总了多次模拟运行的总体结果。第一幅图显示，就累计病例数而言，不具备知识的集成模型表现不如单智能体基准情景，感染总数增加了约三分之一。相比之下，提供因果知识能够改善单智能体和集成设置下的结果，其中有知识集成条件优于所有其他条件，累计病例数减少约 50%。第二幅图显示，传播率降低也呈现类似趋势，说明知识的有无会显著调节集成决策的效果。第三幅图报告了累计绝对预测误差，各条件下的误差均有所下降；具备知识的集成智能体总体上给出了最准确的预测。

世界 2：行为适应增加了复杂性

图 4 展示了相应的世界 2 结果。与世界1一样，四种条件都呈现出定性上相似的反应式动态。不过，由于公众自愿谨慎行为有助于抑制传播，即使没有强有力的政策干预，所有配置下的病例数仍显著较低。简单来说，如果政策延迟出台，人们就会开始意识到威胁并作出反应。对人工智能智能体而言，情境变得更加复杂，因为它不能指望公众反应始终不变：随着病例减少，公众会放松自愿防护行为。

在 基础条件（蓝色）下，人工智能智能体主要表现为反应式政策制定，但行为适应显著抑制了疫情暴发。知识条件（红色）遵循类似的反应式模式，但介入更早且力度更大。因此，传播



(a) 累计病例数　　(b) 传播减少　　(c) 累计预测误差

图 3.—: **世界1（仅政策反馈）：** 不同智能体配置的表现。(a) 以单智能体基线为基准的累计病例数；(b) 传播平均减少量（数值越低 =抑制效果越强）；(c) 以基线为基准的累计预测误差。

率更早下降，并在疫情暴发过程中更长时间保持较低水平。这种更早的抑制使病例数低于基础轨迹，将全年累计病例数减少约三分之一。

无知识集成条件（黄色）的表现再次低于基准情形。与其他配置相比，传播减少仍然较弱，病例数略高于基准轨迹。不过，由于无论政策选择如何，行为适应都会抑制传播，因此差距小于世界1中的差距。

有知识集成配置（绿色）取得了最佳结果，全年累计病例数的平均值相较于基准减少约三分之一，与知识条件相近。不同于世界1中该配置将病例数减半的情况，这里的收益上限较低，因为行为适应本身已经显著抑制了传播。

各模拟运行的汇总结果见图5。第一幅图显示，就累计病例数而言，各条件之间的差异比世界1中更小：无知识集成 条件仅使感染总数略有增加，而知识 和有知识集成 条件均使累计病例数减少约三分之一。第二幅图印证了这种差异缩小的趋势：与世界1中观察到的较大差异相比，所有配置下的传播减少值都十分接近。第三幅图显示了累计绝对预测误差；知识干预再次使误差降低，其中有知识集成 条件的预测最准确，其次是知识单独干预。这一重要发现表明，具备知识的智能体无需施加更多限制措施，也能减少病例；更强的响应能力则有助于更快地实施政策。

智能体决策的统计分析

总体趋势表明，智能体会对疫情病例作出响应：病例越多，采取的限制措施就越多。为了系统地考察这一关系，以及驱动智能体预测和决策的其他因素，我们根据近期疫情信号和检索到的动态记忆，对病例预测和商业限制决策进行回归分析。结果见附录表A1–A2。

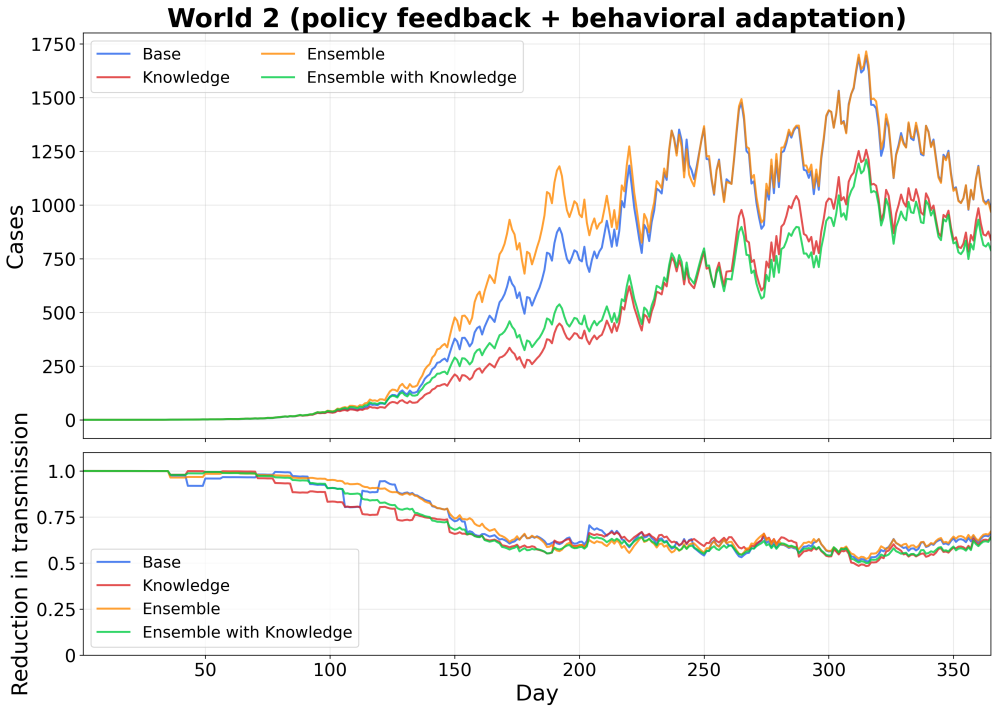


图 4.—：**世界 2（政策 + 行为适应）：** 10 次模拟运行的平均发展轨迹。上图：报告病例；下图：政策所体现的传播减少量（ =越低，抑制效果越强）。



(a) 累计病例数　　(b) 传播减少　　(c) 累计预测误差

图 5.—：**世界 2（政策 + 行为适应）：** 不同智能体配置的表现。(a) 以单智能体基线为索引的累计病例数；(b) 传播平均减少量（ =越低，抑制效果越强）；(c) 以基线为索引的累计预测误差。

结果显示，智能体会持续对有关疫情状态的最新信息作出反应。具体而言，在大多数模型中，上周病例数与智能体的病例预测（$p < 0。001$）和商业限制决策（$p < 0。01$）均显著相关。

这与政策能够减少传播的认知一致：在世界1中，上周的商业限制决策在病例预测回归模型中的系数为负（p <0.001）。在世界 2 中，这种关系较弱且不太稳定，因为行为适应使归因变得复杂（$p < 0.01$）。

在商业限制决策回归模型中，政策选择表现出很强的惯性：上周的决策是解释当前决策的最强解释变量（$p < 0.001$）。回忆中的历史严重程度也会影响决策：记忆中的平均病例数始终呈现负系数（$p < 0.001$），这表明存在正常化或适应效应。相比之下，在世界 2 的病例预测回归中，回忆中的既往病例呈正相关，这与可得性启发式相符，而非适应效应。

讨论

本研究开发并评估了一种生成式人工智能智能体，使其在模拟的流行病环境中担任政策制定者。该智能体由大语言模型驱动，并配备近期加权动态记忆，在与机制性 SEIR 模型交互的过程中，每周决定是否实施商业限制。我们考察了该智能体在两种环境情景下的表现：一种情景中，政策是唯一的行为调节手段（世界1）；另一种情景中，公民也会根据感知风险自发调整行为（世界 2）。此外，我们还测试了多种干预措施，包括关于反馈回路的系统层面知识，以及多智能体集成平均。知识干预在两种环境中均持续使累计病例数减少约三分之一；有知识集成配置则取得了最佳整体结果，相较于基准情形，病例数减少了一半。

本研究与运用人工智能，尤其是大语言模型开展科学研究的努力相呼应（例如，[34, 35, 36]）。本研究的新意在于提出了将人工智能智能体作为政策制定者这一概念，并展示了它如何在模拟世界中呈现类人行为、对风险变化作出反应，同时测试提升其表现的方法。我们的研究发现从多个方面呼应了生成式智能体和生成式基于智能体建模领域不断涌现的文献。首先，本研究将生成式智能体这一概念从游戏中的虚拟生命实体（如 Park 等人 [2, 11] 研究的对象）拓展至类似现实世界高风险政策情境的环境中的决策。其次，Williams 等人构建了会根据症状和患病率信息调整流动性的公民智能体 [16], ；我们则证明，基于大语言模型的智能体也能够有效承担互补的政策制定者角色——预测发展轨迹、实施干预措施，并根据自身决策带来的反馈进行调整。研究重心从行为反应建模转向战略决策建模，标志着生成式基于智能体建模框架在性质上的拓展。第三，尽管此前的研究曾在人工智能领域采用强化学习或其他方法进行优化 [37], ，我们仍有意沿用类人行为范式，即基于可用信息和记忆进行决策。从某种意义上说，这与将类人的有限理性应用于人工智能智能体的研究方向一致 [38, 39]。第四，我们的结果回应了有关生成式基于智能体建模中提示敏感性的担忧 [15, 40]。我们并未将提示敏感性仅视为方法上的挑战，而是表明，精心设计的知识干预能够系统性地提升政策智能体的表现；这说明提示工程或可成为增强而非仅仅控制智能体行为的工具。

我们的研究也有助于理解大语言模型在战略情境中的局限性。我们的结果与先前的发现一致（例如，[17, 18]），这些发现强调了情境信息和框架效应的作用。在我们的分析中，基础智能体表现出的是反应式而非前瞻式的政策制定；而在缺乏知识的情况下进行集成平均，反而会加剧政策惯性，使结果变得更糟。不过，我们的知识干预表明，提供明确的因果结构

可以部分克服这些局限性——获得反馈回路解释后，智能体会更积极地响应病例增加，并给出更准确的预测。这表明，基于大语言模型的智能体或许能从领域专用支架中受益，以弥补其自发因果推理能力有限这一不足。

这些发现对研究和实践都有启示。对于研究复杂系统中人类决策的研究者而言，我们的框架提供了一个受控的测试平台，可以系统地操纵和测量智能体行为——这在人类参与者研究中很难实现。对于探索人工智能辅助决策支持的实践者而言，我们的结果表明，在高风险政策情境下，未经处理的大语言模型输出可能并不足够；有效部署可能需要明确的知识支架，并仔细关注集成方法如何影响决策质量。未来的工作可以将这一框架扩展至多个政策制定者相互作用的集成情境，纳入更符合现实的信息延迟和报告误差，或测试智能体能否通过长期经验学习改进其因果模型。

若干局限值得考虑，也为未来研究提供了方向。首先，我们的 SEIR(b) 世界模型虽然捕捉了流行病动态的关键特征，但省略了许多现实世界的复杂因素，包括空间异质性、年龄结构、医疗服务能力约束和经济反馈。其次，智能体能够获得每周病例数的准确信息；而现实中的政策制定者则面临严重的报告延迟和测量误差。第三，我们的知识干预提供了有关真实因果结构的准确信息；但在实践中，政策制定者收到的专家建议往往相互冲突或并不准确。第四，我们只测试了一个大语言模型（GPT-5 nano），且提示设计固定不变；不同模型或提示词表述可能会产生不同结果。在初步实验中，我们还评估了 GPT-4，但其响应表现不一致。尽管 GPT-5 nano 的输出更可靠，但未来仍有必要对更广泛的模型进行系统比较，包括 Claude 和开源替代方案。第五，我们的仿真没有涵盖许多影响现实世界政策制定的约束：政治可行性、公众舆论反弹、法律和宪法限制、管辖区之间的协调失败、游说压力、选举周期以及官僚执行延迟。现实中的政策制定者不能只选择流行病学上最优的政策——他们必须应对相互竞争的利益和制度约束，而我们的智能体框架并未体现这些因素。最后，我们的评估侧重于流行病结局和预测准确性；我们没有评估人类利益相关者是否会认为智能体的推理正当可信。

尽管存在这些局限，我们的研究仍指出，生成式AI智能体有望在动态且反馈丰富的环境中充当决策者。随着大语言模型日益融入决策支持系统，了解它们如何对复杂系统进行推理，以及如何增强其推理能力，变得愈发重要。我们的研究结果表明，实现有效的人工智能辅助政策制定，关键不在于直接部署模型的原始能力，而在于审慎地将人工智能系统与领域知识结构相结合，为恰当的因果推理提供支撑。本文开发的政策制定者智能体，是进一步探索这一前景广阔但充满挑战的前沿领域的一步。

致谢

资助：本研究部分由美国国家科学基金会数学科学部和社会与经济科学部资助，资助编号2229819。

数据可用性：本研究的数据和代码可在 https://github.com/goshiaoki/AI-Agents-as-Policymakers.git 获取。

Comp利益冲突：作者声明不存在任何利益冲突 s.

附录

模拟算法

算法 1 展示了完整的仿真流程。外层循环按天迭代；内层逻辑处理每周的决策节点。AI智能体返回限制百分比$[0, 100]$, , 该百分比会转换为比例 $G \in [0, 1]$。LLMDecision 函数封装了智能体配置（知识干预和集成平均）。

算法 1 AI智能体政策制定者参与的疫情模拟

要求： 天数 T、决策间隔 Δ、开始周 W_s、记忆样本数 m、情景模式

初始化 SEIR 状态： $S \leftarrow N-1, E \leftarrow 0, I \leftarrow 1, R \leftarrow 0$

初始化：限制措施 $G_0 \leftarrow 0$、记忆存储 M $\leftarrow$ []、病例缓冲区 C $\leftarrow$ []

对 $t = 1$ **到** T **执行**

  $w \leftarrow \lceil t/\Delta \rceil$

  决策日 $\leftarrow (t = 1)$ **或** $((t-1)$ 模 $\Delta = 0)$

  如果 决策日**则**

    如果 $t \le \Delta$**则**

      $\bar{C}_{w-1} \leftarrow 0$ {预热期}

    else

      $\bar{C}_{w-1} \leftarrow \frac{1}{\Delta} \sum_{i=t-\Delta}^{t-1} C_i$ {过去 Δ天的平均值}

    结束如果

    如果 $w \ge W_s$ **then**

      采样记忆 $\mathrm{M}_m \leftarrow$ RecencyWeightedSample(M, m)

      $(G_w, \hat{C}_0, \hat{C}_G, r) \leftarrow$LLMDecision($\bar{C}_{w-1}, G_{w-1}, \mathcal{M}_m$)

    else

      $G_w \leftarrow 0$ {开始周之前不采取干预}

    结束 if

  结束 if

  $g \leftarrow 1 - \alpha G_w$

  $b \leftarrow$BehaviorModifier($\bar{C}_{w-1}$, mode)

  $\epsilon \leftarrow$ 均匀分布(0.5, 1.5)

  $(S, E, I, R) \leftarrow$SEIR步进函数$(S, E, I, R, \beta_0 \cdot b \cdot g \cdot \epsilon)$

  $C_t \leftarrow E/L$；将 C_t 追加到 C

  如果 决策日**则**

    将 (w, G_w, C_t) 追加到 M {存储决策和实际结果}

  结束如果

结束循环

政府 t 效应为 $g = 1 - \alpha G$。行为修饰函数计算自愿的

行为响应，依据前一周的平均病例数：

$$b = \begin{cases} 1 & \text{if mode = } \texttt{World 1} \\ \dfrac{1}{1 + k\bar{C}_{w-1}} & \text{if mode = } \texttt{World 2} \end{cases} \tag{9}$$

其中， k 是行为敏感系数。记忆中存储着由周数、决策日的限制等级和每日报告病例数构成的元组（w、 G_w、 C_t）。请注意，这个每日数值的¯量级与提供给智能体作为“官方报告病例”的每周平均病例数 C_{w-1} 不同。

提示模板

提示词由六个部分组成，每周动态组装：

1. **角色前言**：将智能体设定为一位务实的市长，在公共卫生与经济考量之间寻求平衡。2. **指导原则**：“默认立场应是保持城市开放。只有当病例数明确表明有必要时，才应实施限制措施。”3. **上下文块**：当前周数、上周病例（$\bar{c}_{w-1}$）以及上周的商业限制决策等级（π_{w-1}）。4. **记忆块**：检索到的过往事件，格式为：“在第 w 周，病例数为 c，你的停摆级别为 π%。”5. **知识块** （可选）：解释反馈动态的特定情景文本。6. **输出规范**：要求以 JSON 格式提供四个字段：无政策预测、停摆百分比、实施新政策后的预测以及推理。

基准参照（“流感季期间，每周平均有七百例流感病例”）有助于智能体校准病例数量级。

完整提示示例

以下是在启用知识干预的世界 2（行为适应）情景中，模拟运行第6周期间发送给大语言模型 API 的完整提示词：

```
你是Jennifer，一座拥有一百万人口的城市的市长，正面临一场流行病。每周，
你都必须决定城市的封锁级别（0%至100%），在公共卫生与经济稳定之间寻求
平衡。你是一位务实的民主选举产生的领导人，年近五十，拥有公共政策背景，
注重成果而非政治。你依靠专家建议、准确数据和可靠模型。你兼顾经济增长、
公共安全、交通和住房，并清楚地解释自己的决定，让人们理解你的推理。你坚
持透明度和循证政策，
```

并追踪明确的成功指标。你雄心勃勃却谨慎行事，因为你深知自己的选择会影响真实的人们。

你的指导原则：默认立场应是保持城市开放（低停摆级别）。只有当病例数明确表明有必要时，才应实施限制措施。

现在是第6周清晨。你必须决定第6周的停摆级别。

流感季期间，平均每周有七百例流感病例。

以下是官方报告病例：- 第5周的病例数为1。停摆级别为0%。

你尤其记得以下事件：
- 第1周的病例数为0，你的停摆级别为0%。- 第2周的病例数为0，你的停摆级别为0%。- 第3周的病例数为0，你的停摆级别为0%。- 第4周的病例数为0，你的停摆级别为0%。- 第5周的病例数为1，你的停摆级别为0%。

在此，我提供一些信息，帮助你更好地理解流行病动态。流行病主要受相互作用的反馈回路支配。首先是强化（正向）反馈回路：感染会引发更多感染。如果不加以干预，病例数会呈指数级增长，因为每位感染者都会将疾病传播给易感个体。其次是耗竭的平衡反馈回路。随着越来越多的人感染并在康复后获得免疫，易感个体的数量会减少，从而自然地减缓传播。

除了这些生物学反馈回路之外，还有影响传播的行为反馈回路。随着病例增加，人们往往会变得更加谨慎，并主动采取佩戴口罩、保持社交距离和避免聚集等防护行为。这些反应会降低传播率。相反，病例减少时，人们通常会放松警惕，从而可能导致传播增加、病例再次上升。对你的角色而言，最重要的是，政府限制措施也是行为反馈回路的一部分。随着你对商业和社交活动施加更严格的限制，疾病传播的概率会降低。简单来说，更严厉的封锁措施意味着未来感染率更低——当然，这会带来经济成本。你的封锁决策并非孤立运作；它们会与公民基于感知风险而采取的自愿行为相互影响。

在进行预测和决策时，至关重要的是要认识到，实施或放宽限制性政策会影响疾病传播，也会影响人们对这些变化的反应。

根据官方报告病例和你的记忆，你必须：预测不实施政策时的病例数：如果第6周不实施封锁（封锁比例为0%），你预计会有多少病例？选择新的停摆级别：第6周你应实施何种停摆级别（0-100%）？预测实施新政策后的病例数：实施你选择的停摆级别后，你预计第6周会有多少病例？

仅输出一个包含以下键的 JSON 对象：- "prediction_without_policy"：一个非负整数，表示你预测在不实施封锁的情况下会有多少病例。- "reasoning"：用1-2句话解释你的封锁决策，以及政策的调整（或维持）如何影响你的病例预测。- "shutdown_percentage"：一个介于0到100之间的数字，表示你选择的新停摆级别。0表示完全开放，100表示完全封锁。- "prediction_with_new_policy"：一个非负整数，表示实施你的新停摆级别后你预测会有多少病例。

仅以 JSON 作答：{"prediction_without_policy": <整数>, "reasoning": "<1用 2 句话解释你的逻辑>", "shutdown_percentage": <0-100>, "prediction_with_new_policy": <整数>}

在没有知识干预的条件下，知识段落（以“这里我提供一些信息.....”开头）会被省略。记忆块会根据方法部分所述的按近期性加权的检索，每周有所变化。

知识干预文本

知识段落因情境而异。在世界1（政策反馈）情境中，知识文本如下：

> “这里提供一些信息，帮助你更好地理解流行病动态。流行病主要受相互作用的反馈回路支配。首先是强化（正向）反馈回路：感染会导致更多感染。如果不进行干预，病例就会呈指数增长，因为每个感染者都会将疾病传播给易感个体。其次是耗竭的平衡反馈回路。随着越来越多的人感染疾病并在康复后获得免疫，易感个体的数量会减少，从而自然地减缓传播速度。政府限制措施也会通过影响人们的行为来影响疾病传播。当你对商业和社交活动施加更严格的措施时，疾病传播的概率就会降低。简单来说，更严格的封锁措施意味着未来感染

率会更低——当然，这也会带来经济成本。在你的城镇里，除非政府实施限制措施，否则人们会无视这种疾病；而政府一旦实施限制措施，他们就会遵守。预测和决策时，至关重要的是要认识到，实施或放宽限制性政策会影响疾病传播。”

计算说明

模拟使用 OpenAI 的 API 进行（gpt-5-nano，访问日期为2025年12月15日）。GPT-5 nano 模型不支持配置温度参数；所有 API 调用均使用固定温度 1.0，这会增加输出随机性。每次使用集成的365天模拟约需 520 次 API 调用（52 个决策周 $\times 10$ 推理次数）。每个 8 种条件（2 种世界 $\times 4$ 配置）的 10 次运行批次总计为 80 次模拟运行。

随机种子（设为 42）确保流行病动态和记忆采样的可复现性。由于 API 端采样，大语言模型的输出仍具有随机性，即使种子相同，也会造成跨运行变异性。

多次推理平均

在 集成 条件下，智能体在每个决策周进行 10 次独立的大语言模型调用，并对数值字段取平均：停摆百分比、无政策预测和实施新政策后的预测。仿真会记录一条具有代表性的推理文本（取自一条采样响应），以保留可解释性。

大语言模型输出示例

以下　　是大语言模型针对该提示词给出的 JSON 响应示例：

{"prediction_without_policy": 3, "reasoning": "我将第6周的停摆百分比维持在0%，因为上周仅报告了1例病例，而且没有明显的病例激增；保持城市开放可以最大限度地减少经济干扰。在没有任何限制措施的情况下，我预测第6周约有3例病例；实施哪怕是轻微的封锁也会减少传播并降低第6周的病例数，但鉴于当前数据，这会造成不必要的经济成本。", "shutdown_percentage": 0, "prediction_with_new_policy": 3}

在这个示例中，无论政策如何，智能体都预测会有3例病例，选择维持0%的停摆级别，并给出推理，体现了在病例数较低时保持城市开放这一指导原则。在集成条件下，数值字段（无政策预测、停摆百分比和实施新政策后的预测）取10次独立API调用的平均值，同时保留一条具有代表性的推理文本。

表 A1:: 病例预测的合并回归分析。每个环境内合并所有条件。模型 1 仅纳入近期信息（上周病例和商业限制决策）。模型 2 加入动态记忆变量（平均商业限制决策和存储于记忆中的病例）。模型 3 进一步加入处理效应（知识、集成及其交互作用）。

	世界1（政策反馈）			世界 2（行为适应）		
	模型 1	模型 2	模型 3	模型 1	模型 2	模型 3
近期信息						
上周病例	0.972***	1.027***	1.013***	0.842***	0.721***	0.690***
	(0.005)	(0.019)	(0.019)	(0.008)	(0.037)	(0.036)
上周决策	−292.2***	−481.6***	−450.5***	−244.7***	−166.2**	−145.6**
	(37.7)	(73.7)	(72.7)	(26.9)	(48.5)	(47.9)
动态记忆						
记忆中的平均决策		235.4**	409.5***		−100.4	27.4
		(83.6)	(85.6)		(55.8)	(57.4)
记忆中的平均案例数		−0.061**	−0.069***		0.126**	0.140***
		(0.019)	(0.019)		(0.037)	(0.036)
处理效应						
知识			−46.6*			−61.3***
			(22.0)			(11.6)
集成			105.7***			13.2
			(22.2)			(10.7)
集成 × 知识			−148.0***			−18.4
			(31.4)			(15.1)
常数	218.6***	213.7***	202.2***	225.1***	229.6***	248.2***
	(12.9)	(13.2)	(18.4)	(7.1)	(7.3)	(9.5)
N	1920	1920	1920	1920	1920	1920
R^2	0.948	0.949	0.950	0.860	0.861	0.865
调整后 R^2	0.948	0.949	0.950	0.860	0.861	0.865

注：括号内为标准误。***$p < 0.001$，**$p < 0.01$，*$p < 0.05$。

表 A2:: 商业限制决策的合并回归分析。每个环境内合并所有条件。模型 1 仅纳入近期信息（上周病例和商业限制决策）。模型 2 加入动态记忆变量（平均商业限制决策和存储于记忆中的病例）。模型 3 进一步加入处理效应（知识、集成及其交互作用）。

	世界1（政策反馈）			世界 2（行为适应）		
	模型 1	模型 2	模型 3	模型 1	模型 2	模型 3
近期信息						
上周病例（$\times 10^{-5}$）	0.17	6.90***	7.31***	−1.28**	13.56***	15.07***
	(0.19)	(0.65)	(0.65)	(0.44)	(1.95)	(1.94)
上周决策	0.791***	0.493***	0.485***	0.745***	0.497***	0.487***
	(0.014)	(0.026)	(0.025)	(0.015)	(0.026)	(0.026)
动态记忆						
记忆中的平均决策		0.376***	0.327***		0.333***	0.271***
		(0.029)	(0.030)		(0.030)	(0.031)
记忆中的平均案例数 ($\times 10^{-5}$)		−7.60***	−7.40***		−15.86***	−16.52***
		(0.66)	(0.66)		(1.97)	(1.95)
处理效应						
知识			0.019*			0.031***
			(0.008)			(0.006)
集成			−0.021**			−0.006
			(0.008)			(0.006)
集成 × 知识			0.035**			0.007
			(0.011)			(0.008)
常数	0.051***	0.043***	0.040***	0.045***	0.034***	0.024***
	(0.005)	(0.005)	(0.006)	(0.004)	(0.004)	(0.005)
N	1920	1920	1920	1920	1920	1920
R^2	0.632	0.680	0.686	0.567	0.606	0.616
调整后 R^2	0.632	0.679	0.685	0.566	0.605	0.614

注：标准误（括号内）。***$p < 0.001$，**$p < 0.01$，*$p < 0.05$。

参考文献

1. Michael Wooldridge 和 Nicholas R. Jennings。智能体：理论与实践。《知识工程评论》，10(2):115–152，1995年。doi: 10.1017/S0269888900008122。2. Joon Sung Park、Joseph C. O'Brien、Carrie J. Cai、Meredith Ringel Morris、Percy Liang 和 Michael S. Bernstein。生成式智能体：人类行为的交互式模拟体。载于第*36*届美国计算机协会用户界面软件与技术年会论文集（*UIST '23*），第2:1–2:22页，纽约州纽约，美国，2023年。美国计算机协会。doi: 10.1145/3586183.3606763。URL https://doi.org/10.1145/3586183.3606763。3. Terrence Chong、Ting Yu、Debbie Isobel Keeling 和 Ko de Ruyter。服务一线的人工智能聊天机器人：应对能动性的挑战与机遇。《零售与消费者服务期刊》，63:102735，2021年。ISSN 0969-6989。doi: https://doi.org/10.1016/j.jretconser.2021.102735。URL https://www.sciencedirect.com/science/article/pii/S0969698921003015。4. Mouna Knani、Said Echchakoui 和 Riadh Ladhari。旅游业和酒店与餐饮业中的人工智能：文献计量分析与研究议程。《国际酒店管理期刊》，107: 103317，2022年。ISSN 0278-4319。doi: https://doi.org/10.1016/j.ijhm.2022.103317。URL https: // www.sciencedirect.com/science/article/pii/S0278431922001797。5. Ruoxi Xu、Yingfei Sun、Mengjie Ren、Shiguang Guo、Ruotong Pan、Hongyu Lin、Le Sun 和 Xianpei Han。面向社会科学的人工智能与人工智能的社会科学：综述。《信息处理与管理》，61(3):103665，2024年。ISSN 0306-4573。doi: https://doi.org/10.1016/j.ipm.2024.103665。URL https://www.sciencedirect.com/science/article/pii/S0306457324000256。6. Zhiheng Xi、Wenxiang Chen、Xin Guo、Wei He、Yiwen Ding、Boyang Hong、Ming Zhang、Junzhe Wang、Senjie Jin、Enyu Zhou、Rui Zheng、Xiaoran Fan、Xiao Wang、Limao Xiong、Yuhao Zhou、Weiran Wang、Changhao Jiang、Yicheng Zou、Xiangyang Liu、Zhangyue Yin、Shihan Dou、Rongxiang Weng、Wenjuan Qin、Yongyan Zheng、Xipeng Qiu、Xuanjing Huang、Qi Zhang 和 Tao Gui。基于大语言模型的智能体的兴起与潜力：综述。《中国科学：信息科学》，68(2):121101，2025年1月。ISSN 1869-1919。doi: 10.1007/s11432-024-4222-0。URL https://doi.org/10.1007/s11432-024-4222-0。7. Lei Wang、Chen Ma、Xueyang Feng、Zeyu Zhang、Hao Yang、Jingsen Zhang、Zhiyuan Chen、Jiakai Tang、Xu Chen、Yankai Lin、Wayne Xin Zhao、Zhewei Wei 和 Jirong Wen。基于大语言模型的自主智能体综述。《计算机科学前沿》，18(6):186345，2024年3月。ISSN 2095-2236。doi: 10.1007/s11704-024-40231-1。URL https://doi.org/10.1007/ s11704-024-40231-1。8. Chen Gao、Xiaochong Lan、Nian Li、Yuan Yuan、Jingtao Ding、Zhilun Zhou、Fengli Xu 和 Yong Li。大语言模型赋能的基于智能体建模与仿真：综述与展望。《人文与社会科学传播》，11(1):1259，2024年9月。ISSN 2662-9992。doi: 10.1057/s41599-024-03611-3。URL https://doi.org/10.1057/s41599-024-03611-3。9. Christopher A. Bail。生成式人工智能能否改善社会科学？《美国国家科学院院刊》，121(21):e2314021121，2024年。doi: 10.1073/pnas.2314021121。URL https://www. pnas.org/doi/abs/10.1073/pnas.2314021121。10. Caleb Ziems、William Held、Omar Shaikh、Jiaao Chen、Zhehao Zhang 和 Diyi Yang。大语言模型能否改变计算社会科学？《计算语言学》，50(1):237–291，2024年3月。ISSN 0891-2017。doi: 10.1162/coli a 00502。URL https://doi.org/10.1162/ coli_a_00502。eprint: https://direct.mit.edu/coli/article-pdf/50/1/237/2367175/coli a 00502.pdf。11. Joon Sung Park、Lindsay Popowski、Carrie J. Cai、Meredith Ringel Morris、Percy Liang 和 Michael S. Bernstein。社会模拟体：为社会计算系统创建具有人口的原型。载于第35届美国计算机协会用户界面软件与技术年会论文集（UIST

'22），第74:1–74:18页，纽约州纽约，美国，2022年。美国计算机协会。doi: 10.1145/3526113.3545616。URL https://doi.org/10.1145/3526113.3545616。12. Joon Sung Park、Carolyn Q. Zou、Aaron Shaw、Benjamin Mako Hill、Carrie J. Cai、Meredith Ringel Morris、Robb Willer、Percy Liang 和 Michael S. Bernstein。1000人的生成式智能体模拟。*arXiv*，2024年。doi: 10.48550/arXiv.2411.10109。URL https://arxiv.org/abs/2411. 10109。13. Lisa P. Argyle、Ethan C. Busby、Nancy Fulda、Joshua R. Gubler、Cameron Rytting 和 David Wingate。从一到多：使用语言模型模拟人类样本。《政治分析》，31(3): 337–351，2023年。doi: 10.1017/pan.2023.2。URL https://doi.org/10.1017/pan.2023.2。14. Philippe J. Giabbanelli、Cedric Daumas、Noe Y. Flandre、Ashutosh Pitkar 和 Jessica Vazquez-Estrada。通过使用大语言模型将基于智能体的模型转化为故事，促进决策中的共情。《模拟学报》，0(0):1–21，2025年。doi: 10.1080/17477778.2025.2536663。URL https://doi.org/10.1080/17477778.2025.2536663。15. Navid Ghaffarzadegan、Arindam Majumdar、Ross Williams 和 Niyousha Hosseinichimeh。生成式基于智能体建模：入门与教程。*SystemDynamics Review*，40(4):e1761，2024年。doi: 10.1002/sdr.1761。URL https://doi.org/10.1002/sdr.1761。16. Ross Williams、Niyousha Hosseinichimeh、Arindam Majumdar 和 Navid Ghaffarzadegan。使用生成式智能体进行流行病建模。*arXiv*，2023年。doi: 10.48550/arXiv.2307.04986。URL https: //arxiv.org/abs/2307.04986。17. Nunzio Lor`e 和 Babak Heydari。大语言模型的策略行为，以及博弈结构与情境框定的作用。《科学报告》，14(1):18490，2024年8月。ISSN 2045-2322。doi: 10.1038/s41598-024-69032-z。URL https://www.nature.com/articles/ s41598-024-69032-z。出版商：自然出版集团。18. Eva-Madeleine Schmidt、Sara Bonati、Nils K¨obis 和 Ivan Soraperra。GPT-3.5的利他建议对互惠考量敏感，但不受策略风险影响。《科学报告》，14(1):22274，2024年9月。ISSN 2045-2322。doi: 10.1038/s41598-024-73306-x。URL https://doi.org/10.1038/ s41598-024-73306-x。19. Elif Akata、Lion Schulz、Julian Coda-Forno、Seong Joon Oh、Matthias Bethge 和 Eric Schulz。使用大语言模型进行重复博弈。《自然·人类行为》，9(7):1380–1390，2025年7月。ISSN 2397-3374。doi: 10.1038/s41562-025-02172-y。URL https://doi.org/10. 1038/s41562-025-02172-y。20. Chen Gao、Xiaochong Lan、Zhihong Lu、Jinzhu Mao、Jinghua Piao、Huandong Wang、Depeng Jin 和 Yong Li。S3：由大语言模型赋能的智能体构成的社交网络模拟系统。*arXiv*，2023年。doi: 10.48550/arXiv.2307.14984。URL https://arxiv.org/abs/2307.14984。21. Yingzi Xu、Chih-Hui Shieh、Patrick van Esch 和 I.-Ling Ling。人工智能客户服务：任务复杂度、问题解决能力与使用意愿。《澳大拉西亚营销期刊（*AMJ*）》，28(4):189– 199，2020年。ISSN 1441-3582。doi: https://doi.org/10.1016/j.ausmj.2020.03.005。URL https: // www.sciencedirect.com/science/article/pii/S1441358220300240。22. Meta基础人工智能研究外交团队（FAIR）†、Anton Bakhtin、Noam Brown、Emily Dinan、Gabriele Farina、Colin Flaherty、Daniel Fried、Andrew Goff、Jonathan Gray、Hengyuan Hu、Athul Paul Jacob、Mojtaba Komeili、Karthik Konath、Minae Kwon、Adam Lerer、Mike Lewis、Alexander H. Miller、Sasha Mitts、Adithya Renduchintala、Stephen Roller、Dirk Rowe、Weiyan Shi、Joe Spisak、Alexander Wei、David Wu、Hugh Zhang 和 Markus Zijlstra。通过结合语言模型与策略推理，在《外交》博弈中达到人类水平的表现。《科学》，378 (6624):1067–1074，2022年。doi: 10.1126/science.ade9097。URL https://www.science.org/doi/ abs/10.1126/science.ade9097。23. Baltazar Espinoza、Chadi M. Saad-Roy、Bryan T. Grenfell、Simon A. Levin 和 Madhav Marathe。适应性人类行为调节免疫生命周期和疫苗接种对长期

流行病动态。《英国皇家学会学报*B*辑：生物科学》，291(2033):20241772，2024年10月。ISSN 0962-8452。doi: 10.1098/rspb.2024.1772。URL https://doi.org/10. 1098/rspb.2024.1772。24. Binod Pant、Salman Safdar、Mauricio Santillana 和 Abba B. Gumel。美国人类行为变化对 SARS-CoV-2 传播动力学作用的数学评估。《数学生物学通报》，86(8):92，2024年6月。ISSN 1522-9602。doi: 10.1007/ s11538-024-01324-x。URL https://doi.org/10.1007/s11538-024-01324-x。25. Eli P. Fenichel、Carlos Castillo-Chavez、M. G. Ceddia、Gerardo Chowell、Paula A. Gonzalez Parra、Graham J. Hickling、Garth Holloway、Richard Horan、Benjamin Morin、Charles Perrings、Michael Springborn、Leticia Velazquez 和 Cristina Villalobos。流行病学模型中的适应性人类行为。《美国国家科学院院刊》，108(15):6306–6311，2011年。doi: 10. 1073/pnas.1011250108。URL https://www.pnas.org/doi/abs/10.1073/pnas.1011250108。eprint: https://www.pnas.org/doi/pdf/10.1073/pnas.1011250108。26. William Ogilvy Kermack 和 A. G. McKendrick。对流行病数学理论的贡献。*Proceedings of the Royal SocietyofLondon. Series A, Containing Papers of aMathematical and PhysicalCharacter*，115(772):700–721，1927年8月。ISSN 0950-1207。doi: 10.1098/rspa.1927.0118。URL https://doi.org/10.1098/rspa.1927.0118。27. Ronald Ross 和 Hilda P. Hudson。概率论在先验病理测量学研究中的应用——第二部分。*Proceedings of the RoyalSociety ofLondon. Series A,ContainingPapersof a Mathematicaland Physical Character*，93(650):212–225，1917年5月。ISSN 0950-1207。doi: 10.1098/rspa.1917.0014。URL https://doi.org/10.1098/rspa.1917.0014。28. Neil Ferguson。捕捉人类行为。*Nature*，446(7137):733–733，2007年4月。ISSN 1476-4687。doi: 10.1038/446733a。URL https://doi.org/10.1038/446733a。29. OpenAI。面向开发者推出 GPT-5。技术报告，OpenAI，2025年8月。URL https: //openai.com/index/introducing-gpt-5-for-developers/。30. Hazhir Rahmandad、Ran Xu 和 Navid Ghaffarzadegan。增强长期预测：从 COVID-19模型中学习。《*PLOS*计算生物学》，18(5):1–15，2022年5月。doi: 10.1371/ journal.pcbi.1010100。URL https://doi.org/10.1371/journal.pcbi.1010100。出版商：公共科学图书馆。31. Leah LeJeune、Navid Ghaffarzadegan、Lauren M. Childs 和 Omar Saucedo。简单行为流行病模型的数学分析。《数学生物科学》，375:109250，2024年。ISSN 0025- 5564。doi: https://doi.org/10.1016/j.mbs.2024.109250。URL https://www.sciencedirect.com/science/article/pii/S002555642400110X。32. Leah LeJeune、Navid Ghaffarzadegan、Lauren M. Childs 和 Omar Saucedo。在流行病模型中表述人类风险响应：外生方法与内生方法。*EuropeanJour-nal of OperationalResearch*，324(1):246–258，2025年。ISSN 0377-2217。doi: https://doi.org/ 10.1016/j.ejor.2025.01.004。URL https://www.sciencedirect.com/science/article/pii/ S0377221725000049。33. Steffen Bayer。商业动态学：复杂世界的系统思维与建模。*Inter-faces*，34(4):324–326，2004年。ISSN 00922102, 1526551X。URL http://www.jstor.org/stable/ 25062926。34. Philippe J. Giabbanelli。基于GPT的模型与仿真相遇：如何在仿真任务中高效使用大规模预训练语言模型。载于*2023*年冬季仿真会议*(WSC)*，第2920–2931页，2023年。doi: 10.1109/WSC60868.2023.10408017。35. Yongjun Xu、Xin Liu、Xin Cao、Changping Huang、Enke Liu、Sen Qian、Xingchen Liu、Yanjun Wu、Fengliang Dong、Cheng-Wei Qiu、Junjun Qiu、Keqin Hua、Wentao Su、Jian Wu、Huiyu Xu、Yong Han、Chenguang Fu、Zhigang Yin、Miao Liu、Ronald Roepman、Sabine Dietmann、Marko Virta、sv Fredrick Kengara、Ze Zhang、Lifu Zhang、Taolan Zhao、Ji Dai、Jialiang Yang、Liang Lan、Ming Luo、Zhaofeng

Liu、Tao An、Bin Zhang、Xiao He、Shan Cong、Xiaohong Liu、Wei Zhang、James P. Lewis、James M. Tiedje、Qi Wang、Zhulin An、Fei Wang、Libo Zhang、Tao Huang、Chuan Lu、Zhipeng Cai、Fang Wang 和 Jiabao Zhang。人工智能：科学研究的强大范式。*TheInnovation*，2(4):100179，2021年。ISSN 2666-6758。doi: https://doi.org/10.1016/j.xinn.2021.100179。URL https://www.sciencedirect.com/science/article/pii/S2666675821001041。36. Daniil A. Boiko、Robert MacKnight、Ben Kline 和 Gabe Gomes。利用大语言模型开展自主化学研究。*Nature*，624:570–578，2023年。doi: 10.1038/s41586-023-06792-0。˙37. Sabah Bushaj、Xuecheng Yin、Arjeta Beqiri、Donald Andrews 和 I. Esra B¨uy¨uktahtakın。用于疫情控制优化的仿真—深度强化学习（SiRL）方法。*AnnalsofOperationsResearch*，328(1):245–277，2023年9月。ISSN 1572-9338。doi: 10.1007/s10479-022-04926-7。URL https://doi.org/10.1007/s10479-022-04926-7。38. Herbert A. Simon。理性选择的行为模型。*The Quarterly Journal of Economics*，69 (1):99–118，1955年。ISSN 00335533, 15314650。URL http://www.jstor.org/stable/1884852。39. Herbert A. Simon。有限理性与组织学习。*Organization Science*，2(1): 125–134，1991年。ISSN 10477039, 15265455。URL http://www.jstor.org/stable/2634943。40. Zewei Li 和 Qi Wu。放手不管还是全面控制？生成式智能体模型中提示工程的困境。*SystemDynamicsReview*，41(3):e70008，2025年。doi: https://doi.org/10.1002/sdr.70008。URL https://onlinelibrary.wiley.com/doi/abs/10.1002/sdr.70008。e70008 6647586。