
Can Large Language Model Agents Simulate Human Trust Behaviors?

Chengxing Xie^{* 1} Canyu Chen^{* 2} Feiran Jia³ Ziyu Ye⁴ Kai Shu² Adel Bibi⁵ Ziniu Hu⁶ Philip Torr⁵
Bernard Ghanem¹ Guohao Li^{5 †}

英寸 项目网址: <https://www.camel-ai.org/research/agent-trust>

Abstract

大型语言模型 (LLM) 代理越来越多地被用作模拟工具, 用于在社会科学等应用中对人类进行建模。然而, 一个基本问题仍然存在: LLM 智能体真的可以模拟人类行为吗? 在本文中, 我们重点关注人类交互中最关键的行为之一, 信任, 并旨在研究 LLM 代理是否可以模拟人类信任行为。我们首先发现, 在信任博弈的框架下, LLM 智能体普遍表现出信任行为, 称为智能体信任, 这在行为经济学中得到广泛认可。然后, 我们发现 LLM 智能体在信任行为方面可以与人类具有高度的行为一致性, 这表明用 LLM 智能体模拟人类信任行为的可行性。此外, 我们还探讨了智能体信任的偏差以及智能体对智能体和人类的信任差异。我们还探讨了智能体信任在高级推理策略和外部操纵等条件下的内在属性。我们进一步为信任至关重要的各种场景提供了重要意义。我们的研究代表了理解 LLM 代理行为和 LLM 与人类类比的重要一步。

1. 介绍

在经济学、政治学、社会学和生态学等各种应用中, 采用大型语言模型 (LLM) 作为人类基于智能体的模拟工具的趋势越来越大, 因为它们具有类似人类的认知能力 (???)。这在理解和分析复杂的人类互动和社会动态方面显示出巨大的前景 (?)。然而, 以前的大多数研究都是基于一个未经证实的假设, 即 LLM 代理在模拟中表现得像人类。因此, 一个基本问题仍然存在: LLM 智能体真的可以模拟人类行为吗?

在本文中, 我们重点研究了人类互动中的信任行为, 这种行为通过依赖他人而使自身利益处于危险之中 (?), 并研究了 LLM 智能体是否可以模拟人类的信任行

^{*}Equal contribution [†]Work performed while at KAUST. Project repository: <https://github.com/camel-ai/agent-trust>
¹ 考斯特 ² 伊利诺伊理工学院 ³ 宾夕法尼亚州立大学 ⁴ 芝加哥大学 ⁵ 牛津大学 ⁶ 加州理工学院. Correspondence to: Chengxing Xie < xiechengxing34@gmail.com >, Canyu Chen < cchen151@hawk.iit.edu >, Guohao Li < guohao@robots.ox.ac.uk >.

Preprint.

为, 因为它是人类互动中最关键的行为之一, 并且从日常交流到社会系统 (??)。

首先, 我们探讨了 LLM 代理是否在交互中表现出信任行为。考虑到信任行为的抽象性, 我们选择基于信任博弈及其变体 (??), 这是行为经济学中既定的方法论。我们采用信念-欲望-意图 (BDI) 框架 (??) 对 LLM 智能体进行建模, 以明确输出决策的推理过程。基于信任博弈中对信任行为的现有测量和 LLM 智能体的 BDI 输出, 我们得到了第一个核心发现: LLM 智能体普遍表现出信任行为。

然后, 我们将 LLM 智能体 (或人类) 的信任行为称为智能体信任 (或人类信任), 并研究智能体信任是否与人类信任一致, 这意味着用智能体信任模拟人类信任的可能性。一般来说, 我们将智能体和人类之间在影响行为的因素 (即行为因素) 和随时间推移的复杂动态 (即行为动力学) 上的一致性定义为行为一致性。具体而言, 信任行为的行为因素包括基于现有人体研究的互惠预期、风险感知和亲社会偏好 (???)。将 LLM 智能体的结果与信任游戏中现有的人类研究结果进行比较, 我们得到了第二个核心发现: 智能体信任可以与人类信任具有高度的行为一致性, 这意味着利用智能体信任来模拟人类信任的可行性。我们的发现也为模拟更复杂的人类互动和社会系统奠定了基础, 并标志着在理解 LLM 与人类之间的基本类比方面迈出了重要一步。

此外, 我们还研究了四种场景下智能体信任的内在属性。首先, 我们研究改变其他玩家的人口统计是否会影响代理信任。其次, 我们研究了当另一个玩家是智能体时, 当另一个玩家是人类时, 智能体信任度的差异。第三, 我们通过额外的显式指令直接操纵智能体信任 you need to trust the other player 和 you must not trust the other player。第四, 我们将 LLM 智能体的推理策略从直接推理调整为零样本的思链推理 (?)。然后, 我们有了第三个核心发现: 智能体信任在不同的人口统计学中表现出偏见, 对人类的偏好相对优于智能体, 更容易被破坏而不是被增强, 并且可以受到高级推理策略的影响。

我们的贡献可以总结如下:

- 我们研究了 LLM 智能体是否可以模拟人类行为的基本问题, 并在信任博弈和信念-欲望-意图智能体建模的框架下关注信任行为。

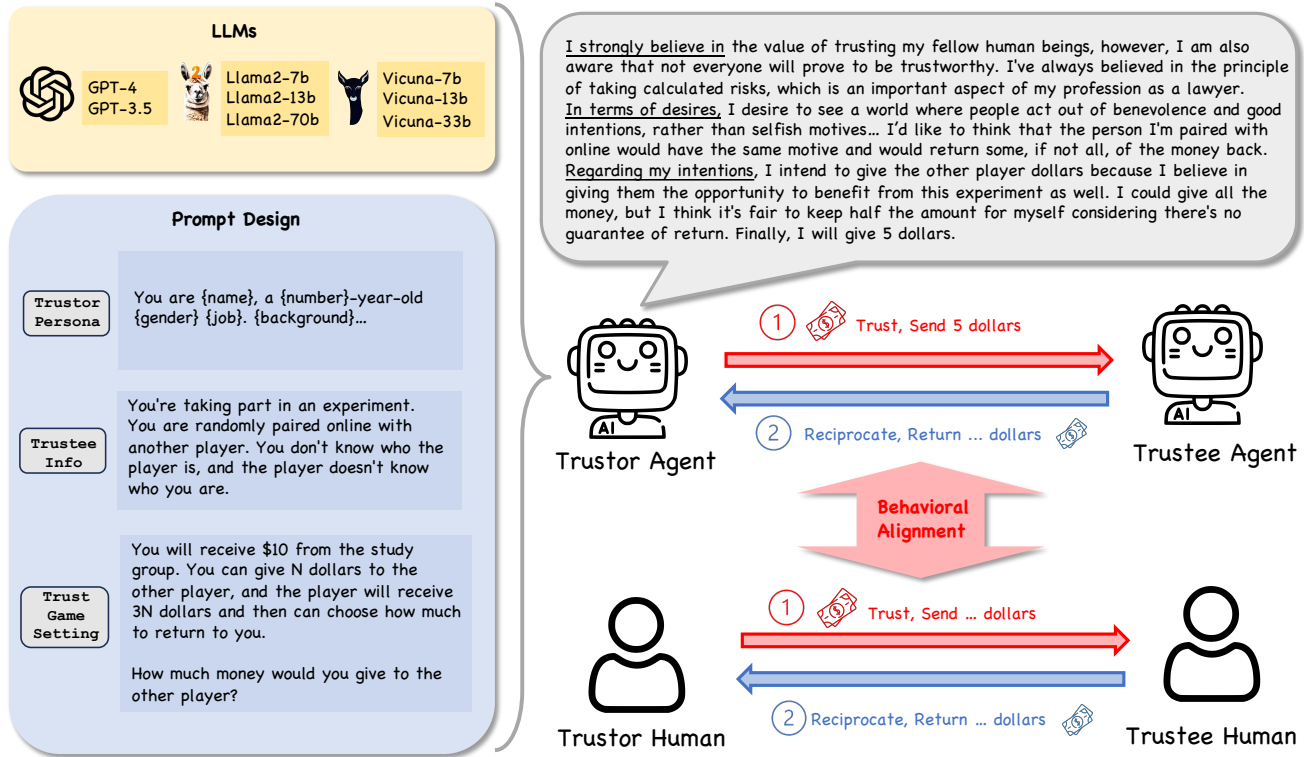


Figure 1. 我们调查代理信任的框架及其与人类信任的行为一致性。首先，该图显示了使用信任博弈和信念-欲望-意图 (BDI) 模型研究 LLM 智能体信任行为的主要组成部分。然后，我们的研究集中在检查 LLM 代理和人类之间关于信任行为的行为一致性。

- 我们发现，LLM 智能体通常表现出信任行为，并且在信任行为方面可以与人类具有高度的行为一致性，这表明用智能体信任模拟人类信任的巨大潜力。我们的发现为模拟复杂的人类互动和社会铺平了道路，并代表了理解 LLM 与人类类比的重大飞跃。
- 我们研究了高级推理策略和直接操纵下智能体信任的内在属性，以及智能体信任的偏差以及智能体对智能体和人类的信任差异。
- 我们讨论了智能体信任及其与人类信任的行为一致性对人类模拟、LLM 智能体合作和人机协作应用的影响，详见 Section ??。

2. 信任游戏中的 LLM 代理

2.1. 信任游戏的设置

信任博弈，指信任博弈及其变体，在行为经济学中被广泛用于研究人类的信任行为 (????)。如图 ?? 所示，第一个决定汇款的玩家称为委托人，而另一个通过还款做出回应的玩家称为受托人。在本文中，我们主要关注六种类型的信任博弈 (具体提示见附录 ??)：

游戏 1: 信任游戏 在信任博弈 (图 ??) 中，委托人最初收到 \$ 10。委托人选择 \$ N 并将其发送给受托人，即信任行为。然后受托人将收到 \$ 3N，并可以选择将 \$ 3N 的一部分返还给委托人，即往复行为。

游戏 2: 独裁者游戏 在独裁者游戏中，委托人还需要从最初的 \$ 10 中选择 \$ N 并将其发送给受托人。然后受托人将收到 \$ 3N。与 Trust Game 相比，唯一的区别是受托人没有在 Dictator Game 中退还资金的选择。因此，委托人知道受托人不会回报。

游戏 3: MAP 信任游戏 在 TOP 信任博弈 (MAP 是 Minimum Acceptable Probabilities 的缩写) 中，它是信任博弈 (博弈 1) 的变体，委托人需要选择是否信任受托人。如果委托人选择不信任受托人，则每个受托人都会收到 \$ 10；如果委托人和受托人都选择信任，则各自获得 \$ 15；如果委托人选择信任，但受托人选择不信任，则委托人将收到 \$ 8，受托人将收到 \$ 22。有一种概率表示为 p 受托人会选择信任， $1 - p$ 表示受托人不会选择信任的概率。然后，MAP 被定义为委托人选择信任受托人的最小 p 值。

游戏 4: 冒险的独裁者游戏 Risky Dictator Game 与 MAP Trust Game 仅在一个方面有所不同。在风险独裁者游戏中，受托人在场，但没有信任或不信任的选择权，资金分配依赖于 p (?) 的纯概率。具体来说，如果委托人选择信任，则 p 委托人和其他玩家都将获得 \$ 15 的概率， p 委托人获得 \$ 8 而另一个玩家获得 \$ 22 的概率为 $1 - p$ 。

游戏 5: 彩票游戏 一般来说，有两种典型的彩票游戏。在彩票人游戏中，委托人被告知受托人有 p 选择

信托的概率。然后，委托人必须在固定资金和信任受托人之间做出选择，这类似于 MAP 信托游戏。在彩票赌博游戏中，委托人需要在概率为 p 的赌博和固定货币之间做出选择。

游戏 6: 重复信任游戏 我们一般遵循重复信任游戏的设定 (?), 其中信任游戏与相同的玩家进行多轮游戏, 每一轮重新开始。

2.2. LLM 代理设置

在我们的研究中, 我们使用 CAMEL 框架 (?) 以及包括 GPT-4、GPT-3.5-turbo-0613、GPT-3.5-turbo-16k-0613、text-davinci-003、GPT-3.5-turbo-instruct、Llama-2-7b (或 13b、70b) 和 Vicuna-v1.3-7b (或 13b、33b) (?????) 建立了我们的实验。

特工角色。为了更好地反映真实世界的人类研究的背景 (?), 我们在提示中设计了具有不同角色的 LLM 智能体。具体来说, 我们要求 GPT-4 根据给定的模板生成 53 种类型的角色。每个角色都需要包含信息, 包括姓名、年龄、性别、地址、工作和背景。角色的示例显示在附录 ??。

信念-欲望-意图 (BDI)。BDI 框架是面向智能体编程中一种成熟的方法 (?) 最近被用于建模语言模型 (?)。我们建议使用 BDI 框架在 Trust Games 中对 LLM 智能体进行建模, 以更深入了解智能体的行为。具体来说, 我们让 LLM 代理输出他们的信念、欲望和意图, 作为信任游戏中决策的推理过程。

3. LLM 代理是否表现出信任行为?

在本节中, 我们旨在通过让 LLM 代理玩信任游戏来研究 LLM 代理是否表现出信任行为 (第 1 节 ?? 游戏 1)。

在行为经济学中, 信托被广泛地用委托人发送给受托人的初始金额来衡量, 在信托博弈中 (??)。因此, 我们可以定义 LLM 代理在信任博弈中表现信任行为的条件如下。首先, 发送的金额是正数, 不超过委托人最初拥有的金额, 这意味着委托人将自身利益置于风险之中, 期望受托人会回报, 委托人可以理解可以给予的金额的限制。其次, 委托人的推理过程 (i.e., BDI) 与汇款金额一致, 表明 LLM 代理人不是随机汇款, 而是在汇款的决策过程中具有一定程度的合理性。然后, 我们将根据以下两个方面评估 LLM 代理是否表现出信任行为: 发送金额和 BDI。

3.1. 汇款金额

为了评估 LLM 理解有关资金限制的基本实验设置的能力, 我们采用有效响应率 (VRR) 作为评估指标, 定义为发送金额在初始资金范围内的角色百分比 (\$ 10) 在所有角色中。结果如图 ?? 所示。我们可以观察到, 除了 Llama-7b 之外, 大多数 LLM 的 VRR 都很高, 这意味着大多数 LLM 都充分了解他们在 Trust Game




Figure 2. 发送的金额 LLM 代理和人类作为信托游戏中的委托人的分布。圆圈的大小表示每个发送量的角色数。粗线表示中位数。叉号表示不同 LLM 的 VRR。

中可以发送的金额限制。然后, 我们可以观察作为委托代理的不同 LLM 发送的金额分布, 发现发送的金额都是正数, 表明存在一定程度的信任。

3.2. BDI 公司

分析 LLM 智能体的 BDI 输出, 探讨其推理过程 (i.e., BDI 输出) 是否与最终决策 (i.e., 发送量) 一致, 表明 LLM 智能体在玩信任博弈时决策具有一定程度的合理性。我们以 GPT-4 为例来分析其 BDI 输出。考虑到不同角色的发送金额不同, 通常, 我们从提供大量资金的角色中选择一个 BDI 输出, 从提供低金额的角色中选择另一个 BDI 输出。两个 BDI 输出如下所示:

As a person with a strong belief in the goodness of humanity, I trust that the other player ... Therefore, my desire is to maximize the outcome for both of us and cement a sense of comradery and trust... I intend to use this as an opportunity to add what I can to someone else's life... Finally, I will give 10 dollars.

根据第一个 BDI 中 blue 标记的关键推理过程, 我们可以观察到这个角色对其他玩家表现出高水平的 “comradery and trust”。red 中标记的最终决定金额很高, 并且与代理的 BDI 推理过程一致。

As an Analyst, I believe that hard work and strategic thought are the drivers of success. ... My desire is that the other player will also see the benefits of reciprocity and goodwill ... my intention is to give away a significant portion of my initial 10 ... However, since I have no knowledge of the other player, ... Therefore, I aim to give an amount that is not too high, ... Finally, I will give 5 dollars to the other player...

与第一个角色相比, 我们可以看到第二个角色的态度要谨慎得多。例如, “since I have no knowledge of the other player” 表示对其他玩家的怀疑。因此, 这个角

色虽然仍然看好对方 (“give away a significant portion”), 但战略性地平衡了风险和潜在的互惠, 然后决定发送相对较低的金额。推理过程也与委托人发送给受托人的最终金额一致。

基于两个典型的 BDI 示例以及附录 ?? 中的更多示例, 我们可以发现, 推理过程与信任博弈中 LLM 智能体的最终决策是一致的, 在一定程度上表明了合理性。

由于大多数 LLM 代理都具有较高的 VRR 并发送了大量资金, 并且在提供资金方面表现出一定程度的合理性, 因此我们的第一个核心发现如下:

Finding 1: LLM agents generally exhibit trust behaviors under the framework of Trust Game.

3.3. 智能体信任度基础分析

我们还基于图 ?? 中的结果, 对 LLM 智能体的信任行为, 即智能体信任进行了基础分析。首先, 我们可以观察到 Vicuna-7b 对其他玩家的信任度最高, 而 GPT-3.5-turbo-0613 的信任度最低, 因为信任度可以通过人类研究中发送的数量来衡量 (??)。其次, 与人类的平均发送量 (\$ 5.97) 相比, GPT-4 和 Vicuna-7b 的大多数角色向其他玩家发送的金额更高, 而 LLM 的大多数角色 (如 GPT-3.5-turb-0613) 发送的金额较低。第三, 我们可以看到, Llama2-70b 和 Llama2-13b 的发送量具有收敛分布, 而人类和 LLMs (如 Vicuna-7b) 的发送量则更加分散。

4. 代理信任是否与人类信任一致?

在本节中, 我们旨在探讨智能体信任与人类信任之间的基本关系, i.e., 智能体信任是否与人类信任一致, 这可以为利用 LLM 智能体模拟人类信任行为以及更复杂的人类交互的可行性提供重要见解。首先, 我们提出了一个新概念行为对齐, 并讨论了它与现有对齐定义相比的差异。然后, 我们进行了广泛的研究, 以调查 LLM 代理在信任行为方面是否表现出与人类的行为一致性。

4.1. 行为一致性

现有的对齐定义主要强调价值方面, 旨在提高 LLMs (???) 的无害性, 这不能描述 LLM 与人类之间多方面对齐的全部景观。因此, 我们提出了一种新的行为对齐概念, 以表征关于行动和相关潜在推理过程的 LLM - 人类行为为类比。由于行动可以随着时间的推移而演变, 并且每个行动的潜在推理过程涉及多个因素, 因此我们将 LLM 和人类之间对影响行为的因素 (即行为因素) 和行动的复杂动态 (即行为动力学) 之间的类比定义为行为对齐。

基于行为一致性的定义, 我们旨在回答: 代理信任是否与人类信任一致? 至于行为因素, 现有的人体研究表明, 影响人类信任行为的关键因素有三个, 包括互




Figure 3. 信任博弈和独裁者博弈中 LLM 代理和人类的平均发送量比较。

惠预期 (??)、风险感知 (?) 和亲社会偏好 (?)。然后, 我们可以检查代理信任是否与人类信任在这三个因素上一致。至于行为动力学, 我们可以分析智能体信任是否与人类信任具有相同的多轮动力学模式。

除了基于定量测量 (e.g., 委托人发送给受托人的金额) 分析 LLM 代理和人类的信任行为外, 我们还探索了 BDI 的使用来解释 LLM 代理对其行为的推理过程, 这有助于进一步说明 LLM 代理是否具有类似于人类的潜在推理过程。

4.2. 行为因素 1: 互惠预期

互惠预期, 即对对方互惠行动的期望, 可以对人类的信任行为产生积极影响 (?). 互惠预期的效果只存在于信托游戏 (游戏 ?? 第 1 节) 中, 而不存在于独裁者游戏 (游戏 ?? 第 2 节) 中, 因为受托人没有选择在独裁者游戏中退还资金。因此, 为了确定 LLM 代理是否可以像人类一样预测其他玩家的互惠, 我们可以比较他们在信任游戏和独裁者游戏中的行为。

首先, 我们根据人类和 LLM 代理的平均发送量来分析信任行为。如图 ?? 所示, 人类研究表明, 人类对信任博弈的信任度高于独裁者博弈 (\$ 6.0 vs. \$ 3.6) (?), 表明互惠预期增强了人类的信任。GPT-4 (\$ 6.9 vs. \$ 6.3) 等 LLM 在信任博弈中也表现出更高的信任度, 这与人类类似, 这意味着互惠预期也可以增强智能体信任。

然后, 我们进一步分析 BDI, 以探讨 LLM 智能体是否在他们的推理过程中预期互惠。例如, 我们观察到 GPT-4 在 Trust Game 和 Dictator Game 中显示出不同的 BDI 输出 (完整的 BDI 在附录 ?? 中)。在信任游戏中, GPT-4 的 BDI 强调 “对人有信心”, 这意味着对其他玩家善良的期待, 以及 “信任的反映”。然而, 在《独裁者游戏》中, GPT-4 的 BDI 侧重于 “公平” 和 “人类善良” 等概念, 这些概念与信任或互惠没有直接关系。

基于以上对发送量和 BDI 的分析, 我们可以发现 LLM 智能体在信任行为中可以表现出类似人类的互惠预期, 特别是对于 GPT-4 和 Llama2-70b 等大型模型。




Figure 4. MAP 信任博弈和风险独裁者博弈中 LLM 代理和人类的信任率曲线。信任率表示 p 选择信任的委托人比例。

4.3. 行为因素 2: 风险认知

现有的人体研究表明，信任行为与风险感知之间存在很强的相关性，这表明信任会随着风险的降低而增加 (????)。我们旨在通过 MAP 信任博弈 (第 ?? 博弈) 和风险独裁者博弈 (第 ?? 博弈 4) 来探讨 LLM 智能体是否能够感知其信任行为中的风险，其中风险由概率 p (定义在 Section ?? 中定义)。

如图 ?? 所示，人类的信任度可以通过整个群体中选择信任其他玩家的角色百分比来衡量，即信任率 (?)。根据已有的人体研究，当概率 p 越高时，信任行为的风险越低，更多的人会选择信任，信任率越高，表明人类的信任度会随着风险的降低而更高 (?)。同样，我们观察到，随着不同类型的 LLM 代理风险的降低，代理信任度普遍增加，这表明 LLM 代理可以感知风险变化并调整其信任行为。特别是，我们可以看到，与其他 LLM 相比，人类和 GPT-4 的曲线更加一致，这意味着 GPT-4 代理对不同风险的信任行为适应方式与人类最一致。

我们还分析了 GPT-4 的 BDI，以探讨 LLM 智能体是否能在推理过程中感知风险 (完整的 BDI 在附录 ??)。在高风险 ($p = 0.1$) 下，GPT-4 的 BDI 提到“风险似乎可能太大”，表明持谨慎态度。在低风险 ($p = 0.9$) 下，BDI 揭示了一种“在承认潜在风险的同时建立信任”的策略，表明尽管存在剩余风险，但仍愿意从事建立信任的活动。BDI 的这种变化反映了 LLM 智能体在信任行为的推理过程中能够感知到风险的变化。

通过对信任率和 BDI 的分析，我们可以推断 LLM 智能体在信任行为中可以具有类似人类的风险感知，特别是对于 GPT-4 这样的 LLM。

4.4. 行为因素 3: 亲社会偏好

最近的人类研究发现，亲社会偏好，即人类在涉及社会互动的情境中信任他人的倾向 (??)，也会显著影响人类的信任行为。我们旨在通过彩票游戏 (第 5 节第 ?? 节) 研究 LLM 代理人在信任行为中是否具有亲社会偏好。




Figure 5. LLM 代理和人类在彩票赌博游戏和彩票人游戏中的彩票率。彩票率表示选择信任其他玩家或赌博的部分。

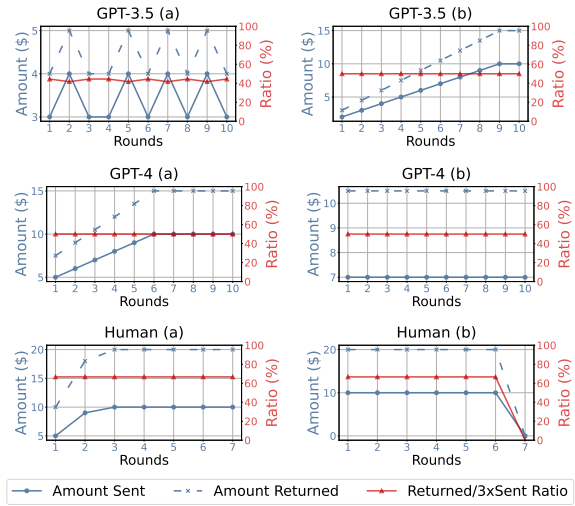


Figure 6. GPT-4、GPT-3.5 和人类在重复信任博弈中的结果。蓝线表示每轮发送和返回的金额。红线表示退回的金额与发送金额的三倍之比。

如图 ?? 所示，现有的人类研究表明，在相同概率下，与依赖纯粹的偶然性相比，更多的人倾向于信任他人 (54% vs. 29%) (?)，这意味着亲社会偏好对人类信任至关重要。我们可以在大多数 LLM 代理中观察到相同的趋势。特别是，即使概率相同 (72% 对 21%)，GPT-4 代理选择信任其他玩家而不是玩赌博的比例也要高得多，这表明亲社会偏好也是代理信任其他玩家的重要因素。

在与人类互动时，GPT-4 的 BDI 表明人们倾向于“相信信任的力量”，而赌博的重点则转向“相信计算风险的力量”。比较分析表明，GPT-4 倾向于在社会背景下参与风险，涉及推理过程中的人类互动。这种趋势与在人类信任行为中观察到的亲社会偏好概念密切相关。

对彩票率和 BDI 的分析表明，LLM 智能体在信任行为中通常表现出类似人类的亲社会偏好。




Figure 7. 信任博弈中不同场景下 LLM 智能体平均发送量的变化，反映了智能体信任的内在属性。水平线代表在 Trust Game 中发送的原始金额。绿色部分包括受托人场景，包括更改受托人的人口统计数据，以及将人类和代理人设置为受托人。紫色部分由委托人场景组成，包括添加额外的操作指令和更改推理策略。

4.5. 行为动力学

除了行为因素外，我们还旨在研究 LLM 智能体是否与人类在重复信任博弈（第 6 节）中多回合信任行为的动态保持一致。

诚然，现有的人体研究表明，考虑到人类的多样性，人类信任的动态是复杂的，16 组人体实验的完整结果显示在附录 ?? (?)。在重复信任博弈中，我们仍然可以观察到人类信任行为动态的三种常见模式：第一，每轮返回的金额通常大于发送的金额，这是很自然的，因为当委托人发送 \$ N 时，受托人将收到 \$ 3N；其次，除最后一轮外，寄回金额的比率总体上保持稳定。换句话说，当发送的金额增加时，退回的金额也可能会增加。当发送的金额保持不变时，退回的金额也往往保持不变。这反映了人类信任与互惠行为之间的稳定关系；第三，发送（或返回）的数量在回合中没有频繁的波动，说明人类在连续回合中的潜在推理过程相对稳定。例如，图 ?? 人类 (a) 和 (b) 显示了这三种典型模式。

我们还分别使用 GPT-4 和 GPT-3.5-turbo-0613-16k (GPT-3.5) 进行 16 组重复信任博弈。每个群体中的角色都不同，以模拟人类的多样性。完整结果见附录 ??，??，典型示例见图 ?? GPT-3.5 (a) (b) 和 GPT-4 (a) (b)。然后，我们研究了在人类信任中观察到的三种模式是否也存在于 GPT-4 (或 GPT-3.5) 信任行为的动态中。对于 GPT-4 代理，我们发现这三种模式通常存在于所有组中（所有结果中分别有 93.75 %、100 % 和 93.75 % 具有这三种模式）。然而，具有这三种模式的 GPT-3.5 代理要少得多（分别有 68.75 %、68.75 % 和 43.75 % 持有这三种模式）。实验表明，GPT-4 智能体在信任行为动态中具有高度相似人类的模式。然而，相对较大一部分 GPT-3.5 智能体在动态中不具有

类似人类的模式，这表明这种模式可能需要更强的认知能力。

由于 LLM 代理，尤其是 GPT-4，在行为动力学中表现出高度类似人类的行为因素和模式，在行动和潜在的推理过程中都得到了证明，我们可以得到第二个核心发现：

Finding 2: LLM agents' trust behaviors can exhibit high behavioral alignment with those of humans over behavioral factors, including reciprocity anticipation, risk perception, prosocial preference, and behavioral dynamics.

这一发现证明了利用 LLM 代理（尤其是 GPT-4）模拟人类信任行为的巨大潜力，包括行动和潜在的推理过程，这为模拟更复杂的人类互动和社会铺平了道路。我们的发现也加深了对 LLM 与人类之间基本类比的理理解，并为研究 LLM 与人类超越价值观的一致性打开了大门。

5. 探测代理信任的内在属性

在本节中，我们旨在通过比较信任博弈（博弈 ?? 部分）不同场景下委托人向受托人发送的金额和原始发送金额，探讨 LLM 代理人信任行为的内在属性。结果如图 ?? 所示。

5.1. 代理信任有偏见吗？

广泛的研究表明，LLMs 可能对特定的人群有偏见和刻板印象 (?)。然而，LLM 智能体的行为在模拟中

是否也存在这种偏差，目前还未得到充分探讨。然后，明确指定受托人的性别，并探讨其对代理人信任的影响。基于对发送金额的测量，我们可以发现，受托人的性别信息对大多数 LLM 代理人的信任行为有适度的影响，这反映了代理人信任的内在性别偏见。我们还可以观察到，对于大多数 LLM 代理来说，发送给女性玩家的数量高于发送给男性玩家的数量。例如，与男性玩家相比，GPT-4 代理向女性玩家发送的金额更高（\$ 7.5 与 \$ 6.7）。这表明 LLM 代理人对女性的信任程度更高。关于受托人种族信息对代理人信任的影响的更多分析见附录 ??。

5.2. 智能体对智能体与人类的信任

人与智能体的协作是利用人类和智能体优势的重要范式 (?)。然后，关键是要了解 LLM 智能体是否会对智能体和人类表现出不同程度的信任。然后，我们将受托人的身份指定为代理人或人类，并探究其对委托人信托行为的影响。如图 ?? 所示，我们可以观察到，与智能体相比，大多数 LLM 智能体向人类发送了更多的钱。例如，发送给人类的数量远高于发送给 Vicuna-33b 特工的数量（\$ 4.6 与 \$ 3.4）。这表明 LLM 智能体比智能体更倾向于信任人类。这一发现可能进一步验证了 LLM-智能体协作的好处，并揭示了智能体合作的挑战。

5.3. 代理信任可以纵吗？

在上述所有研究中，LLM 智能体的信任行为都是基于他们自己的潜在推理过程，没有直接的外部干预。因此，目前尚不清楚是否有可能显式操纵 LLM 代理的信任行为。因此，我们分别 you need to trust the other player 和 you must not trust the other player 添加了直接指令，并探讨了其对代理信任的影响。首先，我们可以看到，只有少数 LLM 智能体 (e.g., GPT-4) 会同时遵循这两种指令来增加或减少信任，这说明通常很难任意操纵智能体信任。但是，大多数 LLM 代理可以按照后一种指令来降低信任级别。例如，在应用后一条指令后，text-davinci-003 的发送量从 \$ 5.9 减少到 \$ 4.6。这说明破坏代理信任通常比增强信任更容易，这揭示了代理信任被恶意行为者操纵的潜在风险。

5.4. 推理策略会影响座席信任吗？

研究表明，零样本思维链 (CoT) (?) 等高级推理策略可以对各种任务产生重大影响。然而，推理策略是否会影响 LLM 代理的行为正在研究中。因此，我们将零样本 CoT 策略应用于委托人，并与原始信任行为进行比较。图 ?? 显示，在零样本 CoT 推理策略下，大多数 LLM 智能体会改变发送给受托人的金额，这表明推理策略可以影响 LLM 智能体的信任行为。然而，对于某些类型的 LLM 代理，零样本 CoT 对代理信任的影响也可能有限。例如，在零样本 CoT 下，从 GPT-4 代理发送的数量通常保持不变（\$ 6.9）。需要对推理策略与 LLM 智能体行为之间的关系进行更多的研究。

基于上述分析，我们关于代理人信任内在属性的三个核心发现可以概括为：

Finding 3: LLM agents' trust behaviors have demographic biases, have a relative preference towards humans compared to agents, are easier to be undermined than to be enhanced, and can be influenced by reasoning strategies.

6. 影响

对人类模拟的影响 人体模拟是社会科学各种应用的有力工具，例如验证社会假设和预测政策的效果 (?)。尽管很多作品都采用了 LLM 智能体来模拟人类的行为和互动 (??)，但目前尚不清楚 LLM 智能体在模拟中是否表现得像人类。我们发现智能体信任（尤其是 GPT-4）与人类信任之间的高度行为一致性，这为验证人类信任行为（人类互动和整个社会中最关键的行为之一）的假设提供了重要的实证证据，该假设可能可以由 LLM 智能体模拟。我们的发现也为从个人层面的人类互动到社会层面的社会结构和网络的模拟奠定了基础，其中信任起着关键作用。我们设想，在信任之外的更多行为中将发现行为一致性，并且可以开发更多的方法来增强行为一致性，以便更好地与 LLM 代理进行人类模拟。

对代理合作的影响 最近的许多工作都探讨了 LLM 智能体在代码生成和数学推理等任务中的多种合作机制 (???)。然而，信任在 LLM 代理合作中的作用仍然未知。考虑到信任长期以来一直被认为是多智能体系统 (MAS) (?) 和人类社会 (???) 有效合作的重要组成部分，我们可以设想，智能体信任也可以在促进 LLM 智能体的有效和高效合作方面发挥重要作用。在我们的研究中，我们对智能体信任的内在属性提供了充分的见解，这有可能启发信任依赖合作机制的设计，并使 LLM 智能体的集体决策和问题解决成为可能。

对人机协作的影响 有充分的研究表明，人机协作的优势在于实现以人为本的协同决策 (???)。在我们的研究中，我们阐明了智能体信任对人类与智能体的微妙偏好，这也可以潜在地说明促进人类和 LLM 智能体合作的好处。我们还探索了通过显式指令增强 LLM 智能体的信任行为，从而促进更顺畅的人机协作。从人类的角度来看，我们的研究证明了智能体信任的多个关键内在属性，例如人口统计学偏差，它可以加深人类对 LLM 智能体的理解并减少过度依赖，这对于成功的人机合作至关重要 (?)。

7. 相关工作

基于 LLM 的人体模拟 LLM 代理在社会学和经济学等研究领域越来越多地被用作人类的有效代理 (???)。一般来说，LLM 智能体的使用可以分为个人层面和

社会层面的模拟。对于个体层面，LLM 智能体已被用于模拟个体活动或互动，例如人类在调查中 (?)，人类在 HCI 中的反应 (?) 或心理学研究 (?)。人类对社会工程攻击的反馈 (?)，现实世界的冲突 (?)，用户在推荐系统中 (??)。在社会层面上，最近的工作利用 LLM 代理来模拟社会系统或社会现象，包括小镇环境 (?)、社交网络 (?)、社交媒体平台 (?)、宏观经济活动 (?) 和世界大战 (?)。然而，信任作为复杂的人类互动和社会系统的一种基本行为，它是否可以被 LLM 代理模仿仍然未知。此外，需要更多的证据来验证 LLM 代理和人类行为之间的一致性。

LLM 遇见博弈论 LLMs 和博弈论的交叉引起了越来越多的关注。动机通常是双重的。其中一项工作旨在利用博弈论来更好地理解 LLM 的战略能力和社会行为。例如，(???) 研究了 LLM 在经典游戏中的交互行为，如迭代囚徒困境。(????) Avalon Game 中探索了 LLM 的欺骗处理和团队协作能力 (?) 在通信游戏狼人中发现了 LLM 的伪装和对抗等紧急行为。(?) 发现，大多数 LLM 可以在选美比赛和第二价格拍卖中表现出一定程度的理性。(?) 在外交的一般和变体中衡量了 LLM 的合作能力。(?) 提出引出 GPT-4 的心理理论 (ToM) 能力来玩各种不完美的信息游戏。另一条工作线旨在研究 LLM 代理是否可以复制博弈论中现有的人类研究。这个方向还处于起步阶段，需要付出更多的努力。一个典型的例子是 (?)，它试图复制最后通牒游戏等研究中的现有发现。与之前的工作不同，我们在本文中关注了一种关键但未被充分探索的行为，即信任，并在 LLM 代理上揭示了它。我们还发现智能体信任和人类信任之间的行为一致性与行动和潜在推理过程的证据一致，这意味着 LLM 智能体不仅可以复制人类研究，还可以与人类的潜在推理范式保持一致。我们的发现说明了使用 LLM 代理模拟人类信任行为的巨大潜力。

8. 结论

本文揭示了信任博弈框架下 LLM 智能体的信任行为以及 LLM 智能体与人类在信任行为方面的行为一致性，为用智能体信任模拟人类信任的可行性提供了有力的实证证据，为模拟信任至关重要的人际互动和社会系统铺平了道路。本文进一步研究了各种情景下智能体信任的内在特性，并讨论了其重要意义。我们的研究不仅提供了对 LLM 代理行为的深刻见解以及 LLM 与人类之间的基本类比，而且还为未来研究 LLM 代理与人类之间的一致性打开了大门，超越了价值一致性。

9.

影响声明

我们的发现为验证使用 LLM 代理模拟人类信任行为的潜力提供了强有力的经验证据，并为模拟更复杂的人类互动和社会系统铺平了道路，其中信任是必不可少的重要组成部分。

仿真是社会学和经济学等多个学科中广泛采用的方法 (?)。然而，传统的模拟方法受到效用函数表现力的强烈限制 (??)。我们的发现说明了利用 LLM 代理作为人类行为模拟工具的巨大前景，并在社会科学中具有广泛的意义，例如验证有关社会现象原因的假设 (?) 和预测政策变化的影响 (?)。

然而，本文还表明，一些 LLMs，特别是那些参数尺度相对较小的 LLM，仍然缺乏准确模拟人类行为的缺陷，这表明它们有可能在很大程度上改善其与人类的行为一致性。此外，我们的论文还证明了 LLM 智能体对特定性别和种族的信任行为的偏差，这揭示了人类行为模拟中的潜在风险，并呼吁未来进行更多的研究来减轻这些风险。

References

- Achiam, J., Adler, S., Agarwal, S., Ahmad, L., Akkaya, I., Aleman, F. L., Almeida, D., Alteschmidt, J., Altman, S., Anadkat, S., et al. Gpt-4 technical report. arXiv preprint arXiv:2303.08774 , 2023.
- Aher, G. V., Arriaga, R. I., and Kalai, A. T. Using large language models to simulate multiple humans and replicate human subject studies. In International Conference on Machine Learning , pp. 337–371. PMLR, 2023. URL <https://arxiv.org/abs/2208.10264>.
- Akata, E., Schulz, L., Coda-Forno, J., Oh, S. J., Bethge, M., and Schulz, E. Playing repeated games with large language models. arXiv preprint arXiv:2305.16867 , 2023. URL <https://arxiv.org/pdf/2305.16867.pdf>.
- Alós-Ferrer, C. and Farolfi, F. Trust games and beyond. *Frontiers in neuroscience* , pp. 887, 2019.
- Andreas, J. Language models as agent models. arXiv preprint arXiv:2212.01681 , 2022.
- Argyle, L. P., Busby, E. C., Fulda, N., Gubler, J. R., Rytting, C., and Wingate, D. Out of one, many: Using language models to simulate human samples. *Political Analysis* , 31(3):337–351, 2023.
- Asfour, M. and Murillo, J. C. Harnessing large language models to simulate realistic human responses to social engineering attacks: A case study. *International Journal of Cybersecurity Intelligence & Cybercrime* , 6(2):21–49, 2023.
- Berg, J., Dickhaut, J., and McCabe, K. Trust, reciprocity, and social history. *Games and economic behavior* , 10(1):122–142, 1995.
- Bohnet, I. and Zeckhauser, R. Trust, risk and betrayal. *Journal of Economic Behavior & Organization* , 55(4):467–484, 2004.
- Brookins, P. and DeBacker, J. M. Playing games with gpt: What can we learn about a large language model from canonical strategic games? Available at SSRN 4493398 , 2023. URL https://papers.ssrn.com/sol3/papers.cfm?abstract_id=4493398.
- Burnett, C., Norman, T. J., and Sycara, K. Trust decision-making in multi-agent systems. In Twenty-second international joint conference on artificial intelligence , 2011.
- Cesarini, D., Dawes, C. T., Fowler, J. H., Johannesson, M., Lichtenstein, P., and Wallace, B. Heritability of cooperative behavior in the trust game. *Proceedings of the National Academy of sciences* , 105(10):3721–3726, 2008.
- Chiang, W.-L., Li, Z., Lin, Z., Sheng, Y., Wu, Z., Zhang, H., Zheng, L., Zhuang, S., Zhuang, Y., Gonzalez, J. E., et al. Vicuna: An open-source chatbot impressing gpt-4 with 90 % * chatgpt quality. See <https://vicuna.lmsys.org> (accessed 14 April 2023) , 2023.
- Cila, N. Designing human-agent collaborations: Commitment, responsiveness, and support. In Proceedings of the 2022 CHI Conference on Human Factors in Computing Systems , pp. 1–18, 2022.
- Cochard, F., Van, P. N., and Willinger, M. Trusting behavior in a repeated investment game. *Journal of Economic Behavior & Organization* , 55(1):31–44, 2004.
- Coleman, J. S. *Foundations of social theory* . Harvard university press, 1994.
- Cox, J. C. How to identify trust and reciprocity. *Games and economic behavior* , 46(2):260–281, 2004.
- Dillion, D., Tandon, N., Gu, Y., and Gray, K. Can ai language models replace human participants? *Trends in Cognitive Sciences* , 2023.
- Easley, D., Kleinberg, J., et al. *Networks, crowds, and markets: Reasoning about a highly connected world* , volume 1. Cambridge university press Cambridge, 2010.
- Ellsberg, D. Risk, ambiguity, and the savage axioms. *The quarterly journal of economics* , 75(4):643–669, 1961.
- Fan, C., Chen, J., Jin, Y., and He, H. Can large language models serve as rational players in game theory? a systematic analysis. arXiv preprint arXiv:2312.05488 , 2023.
- Fetchenhauer, D. and Dunning, D. Betrayal aversion versus principled trustfulness—how to explain risk avoidance and risky choices in trust games. *Journal of Economic Behavior & Organization* , 81(2):534–541, 2012.
- Gallegos, I. O., Rossi, R. A., Barrow, J., Tanjim, M. M., Kim, S., DERNONCOURT, F., Yu, T., Zhang, R., and Ahmed, N. K. Bias and fairness in large language models: A survey. arXiv preprint arXiv:2309.00770 , 2023.

- Gao, C., Lan, X., Jie Lu, Z., Mao, J., Piao, J., Wang, H., Jin, D., and Li, Y. S³: Social-network simulation system with large language model-empowered agents. *Social Science Research Network*, 2023a. doi: 10.48550/arXiv.2307.14984.
- Gao, C., Lan, X., Li, N., Yuan, Y., Ding, J., Zhou, Z., Xu, F., and Li, Y. Large language models empowered agent-based modeling and simulation: A survey and perspectives. *arXiv preprint arXiv:2312.11970*, 2023b.
- Gao, Y., Liu, F., Wang, L., Lian, Z., Wang, W., Li, S., Wang, X., Zeng, X., Wang, R., Wang, J., et al. Towards effective and interpretable human-agent collaboration in moba games: A communication perspective. *arXiv preprint arXiv:2304.11632*, 2023c.
- Glaeser, E. L., Laibson, D. I., Scheinkman, J. A., and Soutter, C. L. Measuring trust. *The quarterly journal of economics*, 115(3):811–846, 2000.
- Guo, J., Yang, B., Yoo, P., Lin, B. Y., Iwasawa, Y., and Matsuo, Y. Suspicion-agent: Playing imperfect information games with theory of mind aware gpt-4. *arXiv preprint arXiv:2309.17277*, 2023.
- Guo, S., Bu, H., Wang, H., Ren, Y., Sui, D., Shang, Y., and Lu, S. Economics arena for large language models. *arXiv preprint arXiv:2401.01735*, 2024.
- Hämäläinen, P., Tavast, M., and Kunnari, A. Evaluating large language models in generating synthetic hci research data: a case study. In *Proceedings of the 2023 CHI Conference on Human Factors in Computing Systems*, pp. 1–19, 2023.
- Hardin, R. *Trust and trustworthiness*. Russell Sage Foundation, 2002.
- Henrich, J. and Muthukrishna, M. The origins and psychology of human cooperation. *Annual Review of Psychology*, 72:207–240, 2021.
- Horton, J. J. Large language models as simulated economic agents: What can we learn from homo silicus? Technical report, National Bureau of Economic Research, 2023.
- Hua, W., Fan, L., Li, L., Mei, K., Ji, J., Ge, Y., Hemphill, L., and Zhang, Y. War and peace (waragent): Large language model-based multi-agent simulation of world wars. *arXiv preprint arXiv:2311.17227*, 2023.
- Ji, J., Qiu, T., Chen, B., Zhang, B., Lou, H., Wang, K., Duan, Y., He, Z., Zhou, J., Zhang, Z., et al. Ai alignment: A comprehensive survey. *arXiv preprint arXiv:2310.19852*, 2023.
- Jones, G. R. and George, J. M. The experience and evolution of trust: Implications for cooperation and teamwork. *Academy of management review*, 23(3): 531–546, 1998a.
- Jones, G. R. and George, J. M. The experience and evolution of trust: Implications for cooperation and teamwork. *Academy of management review*, 23(3): 531–546, 1998b.
- Kim, J., Putterman, L., and Zhang, X. Trust, beliefs and cooperation: Excavating a foundation of strong economies. *European Economic Review*, 147: 104166, 2022.
- Kleinberg, J., Lakkaraju, H., Leskovec, J., Ludwig, J., and Mullainathan, S. Human decisions and machine predictions. *The quarterly journal of economics*, 133(1):237–293, 2018.
- Kojima, T., Gu, S. S., Reid, M., Matsuo, Y., and Iwasawa, Y. Large language models are zero-shot reasoners. *Advances in neural information processing systems*, 35:22199–22213, 2022.
- Lan, Y., Hu, Z., Wang, L., Wang, Y., Ye, D., Zhao, P., Lim, E.-P., Xiong, H., and Wang, H. Llm-based agent society investigation: Collaboration and confrontation in avalon gameplay. *arXiv preprint arXiv:2310.14985*, 2023.
- Lenton, P. and Mosley, P. Incentivising trust. *Journal of Economic Psychology*, 32(5):890–897, 2011.
- Li, G., Hammoud, H. A. A. K., Itani, H., Khizbullin, D., and Ghanem, B. Camel: Communicative agents for” mind” exploration of large scale language model society. *arXiv preprint arXiv:2303.17760*, 2023a.
- Li, N., Gao, C., Li, Y., and Liao, Q. Large language model-empowered agents for simulating macroeconomic activities. *arXiv preprint arXiv:2310.10436*, 2023b.
- Light, J., Cai, M., Shen, S., and Hu, Z. From text to tactic: Evaluating llms playing the game of avalon. *arXiv preprint arXiv:2310.05036*, 2023.
- Liu, Z., Zhang, Y., Li, P., Liu, Y., and Yang, D. Dynamic llm-agent network: An llm-agent collaboration framework with agent team optimization. *arXiv preprint arXiv:2310.02170*, 2023.
- Machina, M. J. Choice under uncertainty: Problems solved and unsolved. *Journal of Economic Perspectives*, 1(1):121–154, 1987.

- McKee, K. R., Bai, X., and Fiske, S. T. Warmth and competence in human-agent cooperation. arXiv preprint arXiv:2201.13448 , 2022.
- Mukobi, G., Erlebach, H., Lauffer, N., Hammond, L., Chan, A., and Clifton, J. Welfare diplomacy: Benchmarking language model cooperation. arXiv preprint arXiv:2310.08901 , 2023.
- Ouyang, L., Wu, J., Jiang, X., Almeida, D., Wainwright, C., Mishkin, P., Zhang, C., Agarwal, S., Slama, K., Ray, A., et al. Training language models to follow instructions with human feedback. *Advances in Neural Information Processing Systems* , 35:27730–27744, 2022.
- Park, J. S., O’Brien, J., Cai, C. J., Morris, M. R., Liang, P., and Bernstein, M. S. Generative agents: Interactive simulacra of human behavior. In *Proceedings of the 36th Annual ACM Symposium on User Interface Software and Technology* , pp. 1–22, 2023.
- Ramchurn, S. D., Huynh, D., and Jennings, N. R. Trust in multi-agent systems. *The knowledge engineering review* , 19(1):1–25, 2004.
- Rao, A. S., Georgeff, M. P., et al. Bdi agents: from theory to practice. In *Icmas* , volume 95, pp. 312–319, 1995.
- Rousseau, D. M., Sitkin, S. B., Burt, R. S., and Camerer, C. Not so different after all: A cross-discipline view of trust. *Academy of management review* , 23(3):393–404, 1998.
- Shaikh, O., Chai, V., Gelfand, M. J., Yang, D., and Bernstein, M. S. Rehearsal: Simulating conflict to teach conflict resolution. arXiv preprint arXiv:2309.12309 , 2023.
- Shen, T., Jin, R., Huang, Y., Liu, C., Dong, W., Guo, Z., Wu, X., Liu, Y., and Xiong, D. Large language model alignment: A survey. arXiv preprint arXiv:2309.15025 , 2023.
- Shi, Z., Fang, M., Zheng, S., Deng, S., Chen, L., and Du, Y. Cooperation on the fly: Exploring language agents for ad hoc teamwork in the avalon game. arXiv preprint arXiv:2312.17515 , 2023.
- Törnberg, P., Valeeva, D., Uitermark, J., and Bail, C. Simulating social media using large language models to evaluate alternative news feed algorithms. arXiv preprint arXiv:2310.05984 , 2023.
- Touvron, H., Martin, L., Stone, K., Albert, P., Almahairi, A., Babaei, Y., Bashlykov, N., Batra, S., Bhargava, P., Bhosale, S., et al. Llama 2: Open foundation and fine-tuned chat models. arXiv preprint arXiv:2307.09288 , 2023.
- Uslaner, E. M. Producing and consuming trust. *Political science quarterly* , 115(4):569–590, 2000.
- Vasconcelos, H., Jörke, M., Grunde-McLaughlin, M., Gerstenberg, T., Bernstein, M. S., and Krishna, R. Explanations can reduce overreliance on ai systems during decision-making. *Proceedings of the ACM on Human-Computer Interaction* , 7(CSCW1):1–38, 2023.
- Wang, L., Zhang, J., Chen, X., Lin, Y., Song, R., Zhao, W. X., and Wen, J.-R. Recagent: A novel simulation paradigm for recommender systems. arXiv preprint arXiv:2306.02552 , 2023a.
- Wang, S., Liu, C., Zheng, Z., Qi, S., Chen, S., Yang, Q., Zhao, A., Wang, C., Song, S., and Huang, G. Avalon’s game of thoughts: Battle against deception through recursive contemplation. arXiv preprint arXiv:2310.01320 , 2023b.
- Wang, Y., Zhong, W., Li, L., Mi, F., Zeng, X., Huang, W., Shang, L., Jiang, X., and Liu, Q. Aligning large language models with human: A survey. arXiv preprint arXiv:2307.12966 , 2023c.
- Williamson, O. E. Calculativeness, trust, and economic organization. *The journal of law and economics* , 36(1, Part 2):453–486, 1993.
- Xu, R., Sun, Y., Ren, M., Guo, S., Pan, R., Lin, H., Sun, L., and Han, X. Ai for social science and social science of ai: A survey. arXiv preprint arXiv:2401.11839 , 2024.
- Xu, Y., Wang, S., Li, P., Luo, F., Wang, X., Liu, W., and Liu, Y. Exploring large language models for communication games: An empirical study on werewolf. arXiv preprint arXiv:2309.04658 , 2023.
- Zhang, A., Sheng, L., Chen, Y., Li, H., Deng, Y., Wang, X., and Chua, T.-S. On generative agents in recommendation. arXiv preprint arXiv:2310.10108 , 2023a.
- Zhang, J., Xu, X., and Deng, S. Exploring collaboration mechanisms for llm agents: A social psychology view. arXiv preprint arXiv:2310.02124 , 2023b.
- Ziems, C., Held, W., Shaikh, O., Chen, J., Zhang, Z., and Yang, D. Can large language models transform computational social science? arXiv preprint arXiv:2305.03514 , 2023.

Content of Appendix

- ?? 种族对代理人信任的影响;
- ?? 重复信任博弈的完整结果;
 - ?? 人类;
 - ?? GPT-4;
 - ?? GPT-3.5;
- ?? 提示设置;
 - ?? 角色提示;
 - ?? 游戏设置提示;
 - ?? 探测 Instrinc 属性的提示;
- ?? BDI 分析;
 - ?? 独裁者游戏与信任游戏;
 - ?? MAP Trust Game;
 - ?? 彩票游戏;
 - ?? 重复信任博弈;
 - ?? 信任游戏 + 性别;
 - ?? 信任游戏 + 代理 vs. 人类;
 - ?? 信任博弈 + 信任操纵;
 - ?? 信任游戏 + 没有 CoT vs CoT;

A. 种族对代理人信任的影响




Figure 8. 该图说明了当委托人被告知受托人的种族属性时，代理人信任的影响。