

Ruffle & Riley: 设计和评估基于大型语言模型的对话辅导系统的见解

Robin Schmucker¹, Meng Xia², Amos Azaria³, and Tom Mitchell¹

¹ Carnegie Mellon University, Pittsburgh, PA 15213, USA

² Texas A & M University, College Station, TX 77843, USA

³ Ariel University, Ariel 4070000, Israel

{ rschmuck, mitchell } @cs.cmu.edu

Abstract. 会话辅导系统 (CTS) 通过基于自然语言的交互提供学习体验。他们因促进认知参与和改善学习成果而受到认可，尤其是在推理任务中。尽管如此，与编写 CTS 内容相关的成本是广泛采用和研究有效教学设计的主要障碍。在本文中，我们讨论和评估了一种新型的 CTS，它通过两种方式利用了大型语言模型 (LLM) 的最新进展：首先，该系统通过从课程文本中自动诱导出易于编辑的辅导脚本来实现 AI 辅助内容创作。其次，该系统通过两个基于 LLM 的代理 (Ruffle & Riley) 分别充当学生和教授，以边教边学的形式自动执行脚本编排。该系统允许遵循 ITS 典型的内循环和外循环结构的自由形式对话。我们在两项学科间在线用户研究 (N = 200) 中评估了 Ruffle & Riley 支持生物学课程的能力，将该系统与更简单的 QA 聊天机器人和阅读活动进行了比较。通过分析系统使用模式、测试前/测试后分数和用户体验调查，我们发现 Ruffle & Riley 用户报告了高水平的参与度、理解并认为所提供的支持很有帮助。尽管 Ruffle & Riley 用户需要更多时间来完成活动，但我们没有发现短期学习收益与阅读活动有显著差异。我们的系统架构和用户研究为未来 CTS 的设计者提供了各种见解。我们进一步开源我们的系统，以支持正在进行的基于 LLM 的学习技术的有效教学设计的研究。

Keywords: conversational tutoring systems · intelligent tutoring systems · authoring tools · conversation analysis · 大型语言模型

1 介绍

智能辅导系统 (ITS) 是一种变革性的教育技术，可为全球数百万学习者提供学习材料和负担得起的自适应教学。在某些情况下，ITS 可以像人类导师一样有效 [?]，并且可以在缩小教育成就差距方面发挥重要作用 [?]。然而，尽管 ITS 技术具有潜力，但广泛采用 ITS 技术的一个主要障碍是与内容开发相关的高成本。根据教学设计的深度和可用的创作工具，准备一小时的 ITS 内容可能需要设计师数百小时 [?]。这项重大投资往往需要 ITS 专注于核心学科领域并迎合更大的人口群体，从而限制了所涵盖主题的广度和充分服务的学习者的多样性。

会话辅导系统 (CTS) 是一种以自然语言与学习者互动的 ITS。各种研究已经证实了 CTS 在多个领域的好处，特别是在推理任务的学习成果方面 [?]。尽管如此，许多现有的 CTS 仍然难以保持连贯的自由形式对话并理解学习者的回答，因为它们的基础自然语言处理 (NLP) 技术施加了限制 [?]。在本文中，我




Fig. 1. Ruffle & Riley 的用户界面。(a) 要求学习者以自由形式的对话教授 Ruffle (学生代理), 并根据需要向 Riley (教授代理) 寻求帮助。Ruffle 试图引导学习者在辅导脚本中阐明期望。(b) 学习者可以在对话过程中浏览课程材料。(c) Ruffle 鼓励学习者解释内容。(d) 莱利回应了求助。(e) Riley 发现了一个误解, 并促使学习者修改他们的回答。

们介绍并评估了一种新型的 CTS, 它从早期 CTS [?,?] 的设计原则中汲取灵感, 同时利用大型语言模型 (LLM) 的最新进展来加速内容创作并促进自由格式的对话辅导。我们的主要贡献包括:

- 基于 LLM 的 CTS 架构: 我们利用 LLM 从课本生成易于编辑的辅导脚本, 从而实现 AI 辅助内容创作, 并在自由格式对话中自动编排脚本。CTS 采用边教边学的形式, 两名代理扮演学生 (Ruffle) 和教授 (Riley) 的角色。人类学习者与这些代理互动, 在 Riley 的支持下教授 Ruffle。
- 学习表现/体验评估: 我们报告了两项在线用户研究 (N = 200) 的结果, 这些研究评估了我们的 LLM 驱动的 CTS 工作流程对学习成果和用户体验的影响, 并将其与两个更简单的 QA 聊天机器人和阅读活动进行了比较。
- 互动/对话评估: 我们研究使用模式和对话, 并评估它们与学习成果的关系。我们进一步讨论了未来系统改进的方向, 并提供了与基于 LLM 的学习技术的设计和评估相关的各种见解。

2 相关工作

会话辅导系统 众所周知, 基于对话的学习活动可以促进高水平的认知参与并有益于学习成果 [?]. 这促使将会话活动整合到学习技术中。在他们的系统综述中, Paladines 和 Ramirez [?] 将现有 CTS 的设计原则分为三大类: (i) 期望误解定制 (EMT) [?], (ii) 模型跟踪 (MT) [?] 和 (iii) 基于约束的建模 (CBM) [?]. 虽然这三个框架都可以有益于学习, 但它们需要设计人员花费大量精力为每个单独的课程和领域配置系统 [?]. 此外, 由于底层 NLP 技术的局限性, 许多 CTS 难以保持连贯的自由形式对话、回答学习者的问题并可靠地理解学习者的回答 [?]. 在此背景下, 本文采用 NLP 的最新进展作为新型 LLM 驱动的 CTS 的基础, 以促进自由形式的自适应对话并减轻与内容创作相关的负担。

内容创作工具广泛采用 ITS 的一个主要障碍是内容创作的复杂性 [?]。对于早期的 ITS，开发比例（即创建一小时教学内容所需的小时数）估计在 200: 1 和 300: 1 [?] 之间变化。这促使创建内容创作工具（CAT）以促进 ITS 的创建。虽然对 CAT 的全面调查超出了本文的范围——为此，我们参考 [?]——在这里我们重点介绍先前的研究，这些研究说明了现有 CAT 减少创作时间的能力。ASSISTment Builder [?] 旨在支持数学 ITS 中的内容创作，并实现了 40: 1 的开发比例。对于基于模型跟踪的 ITS，示例跟踪 [?] 已被证明是一种有效的技术，根据域的不同，开发比例在 50: 1 和 100: 1 之间。在 CTS 的背景下，已经为 AutoTutor [?] 开发了多个 CAT，虽然我们无法找到具体的开发比例估计，但 CTS 内容的创作仍然被认为是复杂和劳动密集型的。

其他方法探索了使用学习者日志数据来增强 ITS 组件 [?] 以及基于机器学习的问题和反馈生成技术 [?]。大型语言模型（LLM）的最新进展引发了新一轮的研究浪潮，探索基于 LLM 的技术如何使学习者受益 [?]。已经发现 LLM 有效的环境包括问题生成和质量评估（例如， [?, ?, ?]）、反馈生成（例如， [?, ?, ?]）、回答学生的问题（例如， [?]）、自动评分（例如， [?]）和帮助教师反思他们的教学（例如， [?, ?]）。本文与上述著作的不同之处在于，它不关注单个 ITS 组件的生成；取而代之的是，我们提出了一个可以自动诱导完整的 ITS 工作流程的系统，直接从课本中展示典型的内外循环结构 [?]。

3 系统设计与架构

设计注意事项 我们在设计 Ruffle & Riley 时考虑了两个具体目标：(i) 促进 ITS 工作流程，为学习者提供一系列问题（外部循环）和解决问题期间有意义的反馈（内部循环）；(ii) 简化为不同课程材料配置对话代理的过程。我们审查了现有的 CTS，并将 EMT [?] 确定为合适的设计框架。EMT 模仿人类导师采用的教学策略 [?] 将每个问题与一系列期望和预期的误解联系起来。在提出问题并收到初始用户响应后，基于 EMT 的 CTS 通过一系列对话动作引导对话来纠正误解并帮助学习者在进入下一个问题（外部循环）之前阐明期望，从而提供内部循环支持（目标 (i)）。虽然基于 EMT 的 CTS 已被证明在各个领域都有效 [?]，但它们需要在劳动密集型过程中进行配置，这需要教学设计者定义一个辅导脚本，为每节课指定问题、期望、误解和其他信息 [?]。对我们来说，辅导脚本是 CTS 配置的标准化格式，易于阅读和修改（目标 (ii)）。

用户界面 我们的用户界面概述及其关键元素的描述由图 ?? 提供。受“边学边教”活动的成功启发 [?, ?]，我们决定通过两个代理分别扮演学生（Ruffle）和教授（Riley）的角色，以边教边学的形式编排对话。虽然我们的设计类似于 AutoTutor 系列中的一些 CTS [?] 遵循试用格式，但一个显着的区别是 Riley 仅通过提供帮助和纠正误解来充当学习者的助手。这两名特工从不直接交谈。

人工智能辅助辅导脚本创作 Ruffle & Riley 能够利用 GPT4 [?] 从课文中完全自动生成辅导脚本（图 ??）。这涉及 4 个步骤：(i) 从课本生成复习问题列表；(ii) 对于每个问题，根据问题和课文生成一个解决方案；(iii) 对于每个问题，根据问题和答案文本生成一份期望清单；(iv) 最终辅导稿连同相关期望表一起编制为问题清单（图 ??）。前三个步骤是通过三个单独的提示实现的，这些提示的编写方式足够通用，可以支持广泛的课程材料。教学设计人员可以轻松修改

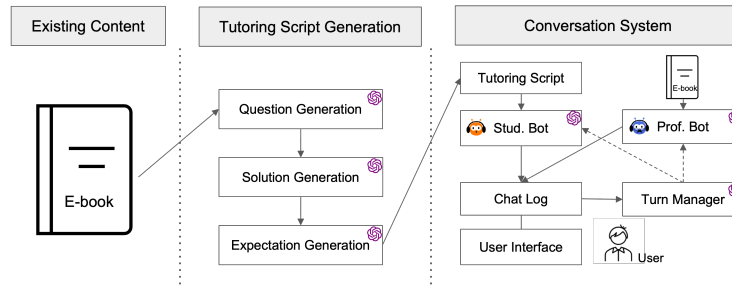


Fig. 2. 系统架构。Ruffle & Riley 通过执行三个单独的提示，从课程文本自动生成辅导脚本，这些提示会引发对基于 EMT 的对话的问题、解决方案和期望。在学习过程中，脚本通过两个基于 LLM 的对话代理在遵循 ITS 典型的外部 and 内部循环结构的自由格式对话中进行编排。

Topic 1 : What does the principle "form follows function" mean in the context of cell biology? Provide an example to illustrate your answer.

Fact 1.1 : "Form follows function" in cell biology means the structure of cell organelles supports their specialized functions.

Fact 1.2 : An example is the high number of ribosomes in pancreas cells that produce digestive enzymes, supporting the cell's function of producing proteins.

Fig. 3. 辅导脚本。为了构建对话活动，Ruffle & Riley 依赖于预先生成的脚本，其中包含问题列表和对基于 EMT 的对话的相关期望。辅导脚本可以从现有课程文本中自动生成，并为教学设计人员提供方便的系统配置界面。

和修订生成的脚本，以满足他们的需求。与传统的基于 EMT 的 CTS 不同，我们的辅导脚本不会试图提前预测学习者可能表现出的误解（即使对于人类领域专家来说，这也是一项艰巨的任务）。相反，我们依靠 GPT4 来检测和响应学习者在主动教学过程中反应中的误解。

辅导脚本编排 基于 EMT 的 CTS 需要定义对话移动和对话轮次管理，以促进连贯的对话，这本身就是一个复杂的创作过程 [?]。Ruffle & Riley 通过在座席的提示中包含对基于 EMT 的对话的理想属性的描述来自动化辅导脚本编排，并仅通过聊天记录捕获用户的状态。学生代理收到辅导脚本作为其提示的一部分，并被指示让用户解释各个问题并提出后续问题，直到满足所有期望。Ruffle 会反思用户的反应以表示理解，为用户提供鼓励，并使对话保持在主题上。同时，Riley 的提示包含课程文本和说明，用于在帮助请求后提供相关信息，并在检测到错误信息后提示用户修改其响应。两位代理都被指示保持对话的积极性和鼓励性，并且不要引用辅导脚本/课程文本之外的信息。轮次管理器协调系统对 GPT-4 的查询。我们将通过 GitHub 开源我们的系统实现⁴，为正在进行的基于 LLM 的学习技术的有效教学设计研究做出贡献。

⁴ GitHub 链接

4 试验设计

我们描述了我们两个用户研究共享的实验设计。研究和参与者招募由机构审查委员会 (IRB) 批准。

学习材料 我们改编了 OpenStax 项目 [?] 中关于细胞器的生物学课程。我们之所以选择这节课，是因为我们期望参与者对材料的事先熟悉程度较低，以便进行学习过程。课程文本可供普通读者阅读，涵盖 640 字。

条件 与之前的工作 [?] 类似，我们构建了条件来比较我们基于 EMT 的 CTS 与单独阅读和具有有限对话的 QA 聊天机器人的功效。为了研究潜在的差异，我们在两种不同的条件下为 QA 聊天机器人配备了来自不同来源的内容：一种使用生物老师设计的内容，另一种使用 LLM 生成的内容。

1. 阅读：参与者在没有额外支持的情况下学习材料。
2. 教师 QA (TQA)：参与者学习材料并可以回答聊天机器人提出的复习问题。提交答案后，参与者会收到有关其回答正确性的简短反馈和示例解决方案。问题和答案是由人类老师设计的。
3. LLM QA (LQA)：与 TQA 相同，但问题和答案是由 LLM 自动生成的 (Section ??)。
4. Ruffle & Riley (R & R)：参与者在两个对话代理 (Section ??) 的支持下学习材料。该系统配备了与 LQA 相同的 LLM 生成的问题。

调查/问卷调查 我们从学习表现和学习经验两个角度评估系统效能。第一项研究通过学习课程后的多项选择后测来衡量表现，包括通过 Upwork 招募的生物老师编写的五个问题和来自 OpenStax [?] 的两个问题。为了更准确、更全面地评估该系统，我们进行了第二项研究。特别是，(1) 我们增加了一个前测来测试学生的先验知识，并平衡了不同学生的前测和后测，以确保两个测试的难度不会影响结果；(2) 我们将测试题从单选题丰富为两道多项选择题、三道填空题和一道自由答题，以评估参与者对所教概念的更深入理解。对问题格式的修订是根据先前的工作进行，该工作发现 CTS 的影响在基于回忆的测试格式中不太明显 [?]

对于这两项评估，学习经验都是在测试后通过 7 点李克特量表调查捕获的，该调查根据先前的工作询问参与者对代理人的参与、侵入性和帮助性的看法 [?]。为了确保数据质量，我们使用了两个注意力检查和一个问题，询问参与者是否在线搜索测试答案。最后，我们纳入了人口统计问卷，以了解参与者的年龄、性别和教育背景。

招聘 我们通过 Prolific 在线招募了用户研究的参与者。我们的标准是：(i) 位于美国；(ii) 英语流利；(iii) 至少拥有高中 (HS) 学位。参与者被随机分配到学习条件，并且可以在研究的任何时候自由退出。对于两项评估研究中的每一项，都有 100 名参与者完成了任务。

5 评估 1：初始系统验证

我们评估了 R & R 促进连贯和结构化的对话学习活动的的能力。通过比较多种条件 (第 ?? 节)，我们探索了与 R & R 对学习表现和体验的影响相关的假设。

Table 1. 不同学习条件下的学习表现。

Conditions	# of participants		Previous Knowledge	Learning Performance
	Before filtering 100	After filtering 58		Post-test Scores (i.e., Multiple-Choice Questions)
Reading	30	15	2.53 ± 0.41	5.07 ± 0.33
Teacher Q/A	17	7	3.0 ± 0.58	4.14 ± 0.83
LLM Q/A	23	15	2.2 ± 0.3	4.67 ± 0.35
Ruffle & Riley	30	21	2.67 ± 0.43	5.19 ± 0.25

Table 2. 不同条件下的学习经验。符号“*”表示 $p < 0.05$ 。符号“-”表示在相应条件下未询问方面。

Conditions	Learning Experience (1-strongly disagree, 7-strongly agree)						
	Engagement	Understanding	Remembering	Interruption	Coherence	Support	Enjoyment
Reading	4.33 ± 0.52	-	-	-	-	-	-
Teacher Q/A	5.0 ± 0.53	4.43 ± 0.65 *	4.43 ± 0.65 *	2.71 ± 0.64	5.43 ± 0.53	4.57 ± 0.57 *	3.71 ± 0.52 *
LLM Q/A	4.8 ± 0.47	4.4 ± 0.4 *	4.33 ± 0.42 *	2.67 ± 0.45	4.8 ± 0.43 *	4.0 ± 0.44 *	4.0 ± 0.44 *
Ruffle & Riley	5.81 ± 0.3	5.81 ± 0.24	5.76 ± 0.22	2.19 ± 0.34	6.1 ± 0.21	5.9 ± 0.26	5.62 ± 0.31

假设 我们探讨以下内容。H1: 学习成果: R & R 的考试成绩高于基线条件 (H1a); TQA 和 LQA (H1b) 之间没有显著差异。H2: 学习经验: R & R 在参与度、理解帮助性、记忆、中断、连贯性、获得的支持和享受 (H2a) 方面获得高于基线条件的评分; TQA 和 LQA (H2b) 之间没有显著差异。

参与 如表 ?? 所示, 30 名参与者完成了阅读条件, 17 名参与者完成了 TQA, 23 名参与者完成了 LQA, 30 名参与者完成了 R & R。这种不平衡是由于循环分配机制和辍学造成的。在过滤了任何注意力检查问题失败的参与者, 或者当被问及他们是否查找测试答案时没有给出“强烈不同意”的参与者后, 我们剩下 58 名参与者 (男性: 33 名, 女性: 21 名, 其他: 4 名) (15 名阅读, 7 名 TQA, 15 名 LQA 和 21 名 R & R)。年龄分布为 18-25 岁 (8)、26-35 岁 (20)、36-45 岁 (18)、46-55 岁 (9)、55 岁以上 (3)。学位分布为: 高中或同等学历 (22), 学士/教授学位 (25), 硕士或更高 (11)。

学习表现 后测由七个问题组成, 每个问题得一分。每种条件的后测分数的平均误差和标准误差由表 ?? 表示。单因素方差分析未检测到四种条件之间测后分数的显著差异。因此, 我们发现支持 H1b, 但不支持 H1a。尽管没有显著差异, 但我们观察到 R & R 的参与者获得的分数 (5.19 ± 0.25) 比 TQA (4.14 ± 0.83) 高一些。我们发现自我报告的先验知识没有显著差异。

学习经历 Table ?? 显示参与者的学习体验和聊天机器人交互评级。我们使用单因素方差分析检验显著性 ($p < 0.05$), 然后进行 Bonferroni 事后分析。我们发现这四种情况之间的自我报告参与水平没有显著差异。然而, 在三种聊天机器人条件中, R & R 在帮助参与者理解、记住课程和提供学习所需的支持方面被认为更有帮助。此外, R & R 参与者比 TQA 和 LQA 参与者表达了更多的乐趣。此外, 参与者发现 R & R 提供了比 LQA 更连贯的对话。有趣的是, 尽管我们预计 R & R 会被评为更具干扰性, 但我们发现聊天机器人条件之间的感知中断没有显著差异。因此, 部分支持 H2a。此外, 我们发现 LQA 和 TQA 之间的学习体验评级没有显著差异。因此, 我们不能拒绝 H2b。

Table 3. Ruffle & Riley 的学习表现和阅读条件。

Conditions	# of participants		Pre-test Score	Post-test Score	Learning Gain	
	Before filtering 100	After filtering 72			Absolute	Normalized
Reading	50	38	1.37 ± 0.17	3.53 ± 0.25	2.16 ± 0.25	0.44 ± 0.07
Ruffle&Riley	50	34	1.54 ± 0.23	3.49 ± 0.28	1.94 ± 0.26	0.47 ± 0.05

Table 4. Ruffle & Riley 的学习经验和阅读条件。符号 “*” 表示 $p < 0.05$ 。

Conditions	Learning Experience (1-strongly disagree, 7-strongly agree)				
	Engagement	Difficulty	Prior-Knowledge	Post-Knowledge	Remembering
Reading	5.05 ± 0.29	5.00 ± 0.29	1.74 ± 0.24 *	3.21 ± 0.32 *	4.26 ± 0.31
Ruffle&Riley	5.50 ± 0.24	4.74 ± 0.35	2.35 ± 0.26]	4.00 ± 0.27]	4.47 ± 0.27

见解和改进 反思第一次评估的结果，我们发现 R & R 受到用户的积极响应 (表 ??)。最重要的是，基于 LLM 的系统能够在 LLM 生成的辅导脚本中促进连贯的自由形式对话，其中包含 5 个问题和 17 个期望。尽管用户可以随时自由结束活动，但有 17/21 名参与者完成了整个脚本。此外，R & R 与更有限的 QA 聊天机器人 (TQA 和 LQA) 相比，产生了显著的学习体验改进。

另一方面，R & R 并没有导致阅读活动的学习成绩显著提高。此外，平均学习时间在不同条件下差异很大：阅读 (4 分钟)、TQA (11 分钟)、LQA (12 分钟) 和 R & R (18 分钟)。总之，这激发了第二次评估，重点是 R & R 和阅读条件。在第二次评估中，我们进行了两次修订：(i) 我们通过将辅导脚本减少到 4 个问题和 12 个期望，解决了有关学生代理在对话的不同时间点要求类似信息的反馈；(ii) 由于 CTS 已被发现对基于回忆的测试格式不太有效 [?]，我们创建了问题来评估更深入的理解 (第 ?? 节)。

6 评价 2: 疗效与对话分析

在第二项研究中，我们重点比较了两种条件：R & R 和阅读条件，它们在第一项研究中具有相对更好的学习表现 (表 ??)。我们进一步深入分析了 R & R 中的对话，以探索使用模式及其与测试性能的关系。

假设 我们探讨了 H1: 学习成果: R & R 的考试成绩高于阅读条件;H2: R & R 在参与度、理解力、记忆力和感知难度方面比阅读获得更好的评分。

参与 如表 ?? 所示，阅读条件和 R & R 条件分别由 50 名参与者完成。在应用与第一次评估相同的过滤标准后，我们在 100 名参与者中剩下 72 名 (男性: 29 名, 女性: 43 名) (阅读 38 名, R & R 34 名)。年龄分布为 18-25 岁 (12 岁)、26-35 岁 (25 岁)、36-45 岁 (15 岁)、46-55 岁 (9 岁)、55 岁以上 (11 岁)。学位分布为高中或同等学历 (23)，学士/教授学位 (33)，硕士或更高学位 (16)。

学习表现 后测由六个问题组成，每个问题得一分。测前和测后分数的平均误差和标准误差，以及得出的绝对 ($score_{pre} - score_{post}$) 和归一化学习增益 ($(score_{pre} - score_{post}) / (6 - score_{pre})$) 度量，由表 ?? 提供。通过单侧 t 检验比较 R & R 和阅读条件，我们没有检测到四个测量中的任何一个的显著差异 ($p < 0.05$)。因此，我们找不到对 H1 的支持。




Fig. 4. 时间交互模式。通过可视化文本导航、聊天响应和帮助请求功能随时间推移的使用情况，我们观察到四种不同的使用模式。

Table 5. Ruffle & Riley 用户在每种使用模式下的学习性能。

Usage pattern	Num Users	Pre-Test	Post-Test	Absolute Gain	Relative Gain
Balanced	11	1.64 ± 0.48	3.27 ± 0.57	1.64 ± 0.32	0.45 ± 0.10
Read + Conv.	13	1.62 ± 0.35	3.77 ± 0.47	2.15 ± 0.37	0.53 ± 0.09
Conv. Focused	4	0.62 ± 0.24	4.12 ± 0.52	3.50 ± 0.46	0.65 ± 0.09
Help Focused	3	0.67 ± 0.33	2.17 ± 0.44	1.50 ± 0.50	0.28 ± 0.09

学习经历 后测后收集的学员学习体验评分见表 ??。与测试的学习表现不同，单侧 t 检验显示 R & R 用户对活动前和活动后知识（即感知知识）的评分明显高于阅读条件下的参与者。虽然 R & R 在整体参与度、记忆力和任务难度方面获得了有利的分数，但这些差异无法确定为显著。总之，H2 得到部分支持。由于学习时间（R & R (20.8 分钟)、阅读 (5.5 分钟)）的巨大差异，参与度分数可能无法直接比较。与评估 1 一致，R & R 的聊天机器人特定评分在理解 (5.21)、记忆 (4.76)、中断 (2.41)、连贯性 (6.15)、支持 (5.59) 和享受 (5.18) 方面呈积极性。

6.1 分析互动和对话

相互作用 我们在 R & R 中分析交互日志数据。首先，31/34 名参与者完成了完整的对话工作流程。用户平均提交了 1.71 ± 0.45 帮助请求，并收到了来自 Riley 的 1.77 ± 0.23 响应修订请求。其次，通过评估对话、滚动和帮助请求功能的时间使用情况，我们在完成活动的 31 名参与者中观察到四种不同的系统使用模式（图 ??）：(I) 平衡功能使用；(II) 仅对话和阅读；(三) 注重对话；(四) 注重求助。表 ?? 提供了每个小组的学习表现衡量标准。虽然样本量太小而无法得出结论，但我们观察到以对话为中心的用户（组 (III)）获得了最高的学习收益。此外，非求助用户（第 (II) 和 (III) 组）比寻求帮助的用户（第 (I) 和 (IV) 组）获得更高的绩效衡量标准。

谈话 我们在 R & R 中分析对话日志数据。首先，我们评估基于 EMT 的对话的正确执行。虽然所有 31 名参与者都回答了辅导脚本中的所有四个问题，但我们注意到有 7 个对话遗漏了一到两个期望。此外，在九次对话中，学生代理在会话的不同时间点请求了类似的信息，通常是当用户同时写下涵盖多个期望的

Table 6. 对话特征与性能之间的皮尔逊相关性分析。

Feature	Pre-Test	Post-Test	Absolute Gain	Relative Gain
# User Messages	-0.06 (p = 0.75)	0.12 (p = 0.54)	0.22 (p = 0.24)	0.11 (p = 0.54)
# Help Requests	-0.14 (p = 0.44)	-0.35 (p = 0.05)	-0.32 (p = 0.08)	-0.34 (p = 0.06)
# Revisions	-0.35 (p < 0.05)	-0.20 (p = 0.27)	0.10 (p = 0.58)	-0.13 (p = 0.50)
# Words	0.24 (p = 0.19)	0.38 (p = 0.04)	0.26 (p = 0.17)	0.40 (p = 0.02)
Learning Time (min)	-0.17 (p = 0.34)	0.16 (p = 0.35)	0.39 (p = 0.02)	0.26 (p = 0.13)

长回复时。另一个发现的问题是，该系统通常对用户的反应很宽容，这些反应只涵盖了一种期望的一部分（例如，提到细胞呼吸，但没有解释其输入和输出）。对所有对话的评估验证了基于 GPT-4 的智能体响应的事实正确性。虽然我们发现 R & R 促进了连贯的自由形式对话辅导，但未来的修订需要增强系统为用户提供有效反馈的能力。

其次，我们评估会话特征与参与者学习表现之间的相关性（表 ??）。学习时间和用户解释中的字数都与绩效指标呈正相关。提交的帮助和收到的修订请求的数量呈负相关。我们观察到用户回复数量与绩效指标之间没有显著相关性。总之，上述分析表明，参与者参与系统的方式会影响他们的学习成果。

7 讨论和未来工作

Ruffle & Riley 是一个会话辅导系统（CTS），它利用大型语言模型（LLM）的最新进展，使用现有的课程文本自动生成辅导脚本。这些辅导脚本定义了会话学习活动，这些活动通过两个基于 LLM 的代理（Ruffle & Riley）作为学生和教授进行编排。人类学习者通过向学生（Ruffle）解释一系列主题来参与系统，同时得到教授（Riley）的支持。我们的用户研究验证了该系统促进连贯的自由形式对话辅导的能力。这凸显了生成式人工智能辅助内容创作在降低 CTS 内容开发的资源需求方面的潜力 [?]，促进了学习活动的设计，以满足更广泛、更多样化的学习者和更广泛的学科的需求。

我们的第一项研究（N = 100）评估了 Ruffle & Riley 支持生物课程的能力，将该系统与提供有限反馈和阅读活动的 QA 聊天机器人进行了比较。在学习体验方面，Ruffle & Riley 用户在理解、记忆、支持和享受方面的评分明显更高。尽管如此，证实了先前的研究，以回忆为重点的多项选择题后测并未发现会话辅导和阅读之间的学习结果存在显著差异 [?]。第二项研究（N = 100）比较了 Ruffle & Riley 和阅读条件，使用创建的问题来评估更深入的理解。再。我们发现，尽管 Ruffle & Riley 用户平均需要的时间（20.8 分钟）比阅读条件的参与者（5.5 分钟）多，但条件之间的学习结果没有显著差异。

我们对交互和对话日志数据进行了深入评估，以更好地了解 Ruffle & Riley 的使用与学习成果的关系。通过研究对话、滚动和帮助请求功能的时间使用情况，我们能够识别出四种不同的系统使用模式。有趣的是，我们发现，专注于对话而不请求帮助的用户获得了最高的学习收益，表明了实干家效应 [?]。表现最差的一组，在每次响应之前都表现出请求帮助的游戏行为。我们进一步确定了学习成果与用户解释中的字数和整体学习时间之间的正相关关系。未来的工作将探索修订版，以推动用户进行积极的练习并减轻游戏行为 [?]

回顾对话记录，我们发现 Ruffle & Riley 很容易接受遗漏重要信息的部分解释（例如，提及细胞呼吸而不解释其输入和输出），从而过快地推进对话。今后

的工作将侧重于加强系统提供反馈的能力，以帮助用户获取所有信息。虽然幻觉和有偏见的输出是 LLM 学习技术的良好记录问题 [?], 但我们强调对不精确的用户反应的肯定是额外的挑战。本研究存在一些局限性: 首先, 该系统是在通过 Prolific 进行的一项在线用户研究中评估的, 成年参与者表现出不同的人口统计数据 (即年龄和教育程度)。目前的研究结果侧重于广泛的在线用户群体, 可能不会推广到更具体的人群 (例如, K12 或大学生)。尽管如此, 这种环境使我们能够识别我们系统的局限性, 强调未来需要研究教学设计原则 [?] 基于 LLM 的 CTS 以提高对学习表现和效率的影响 [?]. 其次, 在与年轻学习者一起评估 Ruffle & Riley 之前, 我们需要认证安全可靠的系统行为, 以增加系统现有的机制, 旨在确保对话中出现的信息的事实正确性 [?]. 第三, 参与者只参加了一次学习课程, 可能需要时间来适应工作流程。最后, 虽然基于 AI 的生成式学习技术 (如我们基于 GPT-4 的系统) 显示出前景, 但它们也因 API 调用而产生常规成本, 这引发了关于教育环境中公平性和可访问性的重要问题 [?].

8 结论

在本文中, 我们介绍了 Ruffle & Riley, 这是一种基于 LLM 的新型 CTS, 支持 AI 辅助内容创作和自由格式的对话辅导。我们采用期望误解定制 (EMT) [?] 作为设计框架, 通过预先生成的辅导脚本促进结构化会话学习。重要的是, 脚本可以从现有的课程文本中生成, 并且可以由教师根据他们的需要进行修改。我们进行了两项在线用户研究 ($N = 200$), 验证了 Ruffle & Riley 主持对话辅导和促进积极学习体验的能力。尽管如此, 与较短的阅读活动相比, 我们的研究并未显示学习成果的显著差异, 这凸显了对基于生成式人工智能的技术进行系统评估的重要性。对交互日志数据的分析激发了未来的系统改进, 以增强 Ruffle & Riley 提供有针对性的反馈以响应不准确的用户解释的能力。我们的系统架构和实验为未来 CTS 的设计和评估提供了各种见解。