已获准在第3届 IEEE 人工智能、计算机、数据科学与应用国际会议（ACDSA 2026）上发表，会议时间为2026年2月5日至7日，地点为菲律宾长滩岛。

智能前端个性化：人工智能驱动的用户界面适配

Mona Rajhans 高级经理，软件工程部 Palo Alto Networks
mrajhans@paloaltonetworks.com

arXiv:2602.03154v1 [cs.HC] 3 Feb 2026

摘要—**前端个性化传统上依赖静态设计或基于规则的适应，无法充分捕捉用户行为模式。本文提出一种用于动态前端个性化的人工智能驱动方法，根据预测的用户行为实时调整用户界面布局、内容和功能。我们提出三种策略：利用用户路径预测进行动态布局自适应、通过强化学习确定内容优先级，以及对人工智能驱动的个性化与基于规则的个性化进行比较分析。文中还介绍了技术实现细节、算法、系统架构和评估方法，以展示其可行性及性能提升。**

索引词—**前端个性化、自适应用户界面（AUI）、动态用户界面布局、用户界面强化学习、预测性用户建模、基于LSTM的交互预测、人工智能驱动的网络体验、实时界面优化、行为分析、人机交互（HCI）、用户参与度优化、内容优先级排序、个性化用户体验系统、基于规则与基于人工智能的个性化**

I. 引言

Web 和移动应用中用户行为的多样性给传统静态用户界面设计带来了重大挑战。用户的目标、偏好、专业水平和情境限制（设备、时间、任务紧迫程度）各不相同，而静态界面无法同时满足这些需求。这会导致用户体验不佳、任务完成时间延长，以及参与度指标下降。

能够在运行时响应个体用户行为和偏好的自适应用户界面（AUI），为缓解这些挑战提供了一种途径。借助人工智能（AI），前端系统可以预测用户需求、重新排列内容并调整布局，从而降低认知负荷并简化常见工作流程。

传统的静态用户界面设计无法有效支持多样化的用户群体，导致性能低下和满意度降低。人工智能驱动的自适应系统通过持续从用户交互中学习，实时优化表示层，从而解决这一问题。

A. 动机

网络和移动应用通常面向多样化的用户群体。静态用户界面无法根据用户不同的目标、偏好和交互模式为其提供最佳服务。个性化是提高参与度、减少摩擦并改善转化率的关键。自适应的数据驱动的用户界面能够预测用户意图，并动态重组界面以适应这种意图。

B. 问题陈述

传统的个性化技术依赖于：

- 基于规则的适应（例如“如果用户点击 X，则显示 Y”）
- A/B测试，以确定最佳布局

虽然这些方法适用于狭窄的应用场景，但它们:

- 缺乏可扩展性
- 无法预测未见过的用户行为
- 无法实时适应

这一局限性要求智能系统具备持续学习和预测的能力，从而动态地个性化用户界面。

C. 贡献

本文的主要贡献如下:
1）提出了一种将预测模型（基于 LSTM）和强化学习智能体集成到前端技术栈中的实用架构。2）详细介绍了动态布局自适应和内容优先级排序的算法与实现策略。3）使用合成的安全运营中心（SOC）仪表板数据集进行了实验评估，并与基于规则的基线进行了性能比较。4）讨论了伦理考量、隐私保护措施以及部署最佳实践。

II. 背景与相关工作

前端个性化经历了多个技术范式的发展，始于基于规则的系统，并逐步演进至基于预测和强化学习的架构。本节概述自适应界面研究的主要发展，重点说明以往方法如何影响当前框架的设计。

A. 基于规则的适应

早期的自适应用户界面（AUI）主要依赖明确的规则集和条件触发器。SUPPLE [1] 等系统展示了如何根据设备和用户约束自动生成用户界面，从而灵活适配不同的屏幕尺寸和无障碍要求。然而，这些系统需要手动制定规则，且无法泛化到

未曾见过的用户行为。每增加一项任务或功能，都需要额外配置，因此不适合大规模部署。

B. 基于统计与学习的个性化

随着行为分析和点击流挖掘的兴起，研究人员开始采用概率模型和监督学习，根据交互历史推断用户偏好。这些方法捕捉了任务重复和导航频率等模式，使界面能够推荐或优先展示内容。尽管这些方法比基于规则的系统更具自适应性，但它们依赖标注数据和静态训练，因此难以迅速响应不断变化的用户情境。

C. 面向自适应界面的强化学习

近期研究探索了使用强化学习（RL）将个性化建模为一个序贯决策问题。在基于强化学习的自适应用户界面中，界面充当智能体，根据停留时间、点击率或任务完成速度等反馈信号调整布局和内容。例如，Sun [2]表明，在为 Web 应用预测最佳布局安排方面，强化学习策略优于静态启发式方法。同样，Khamaj [4]将强化学习应用于移动界面，证明通过持续自适应，参与度指标取得了可量化的提升。这些研究凸显了强化学习作为一种长期优化机制的可行性，而非仅用于一次性个性化。

D. 人工智能驱动的内容推荐

除了布局调整，人工智能也已应用于推荐系统，用于动态策划界面内容。Sodiya 等人 [3]提出了一种人工智能驱动的网页内容交付框架，该框架通过学习用户参与度画像来优先推荐文章和多媒体组件。他们的研究结果表明，与依据预设规则进行内容排序相比，依据学习到的行为模式进行排序能显著提高点击率。

E. 迈向多模态与情境感知个性化

新兴研究将个性化拓展至多模态和情境感知层面，通过整合眼动追踪、语音命令和手势识别来推断意图。这一转变通过考量认知负荷和情境意识，使自适应界面更贴合人机交互（HCI）原则。此类多模态集成代表了自适应前端设计的下一发展方向，使界面不仅能感知用户做了什么，还能理解他们如何做以及为何这样做。

F. 本研究的定位

尽管此前的工作已在布局生成、推荐或交互预测等适配的单个方面取得进展，但鲜有研究在统一的架构框架中结合序列建模与强化学习。本研究通过将基于 LSTM 的用户行为预测器与基于强化学习的内容优先级排序器相结合，弥补了这一空白，实现了对布局和内容进行实时、双向的个性化。这种双模型方法将预测性前瞻与反馈驱动优化相结合，推动了现有技术的发展，形成了一个能够从持续的用户交互中不断学习的自适应系统。

III. 动态布局自适应

A. 系统架构

整个系统集成了多个相互依赖的组件，共同实现自适应前端个性化。如图 1 所示，该架构由四个主要模块构成：行为追踪器、预测引擎、强化学习（*RL*）智能体和布局调整器。

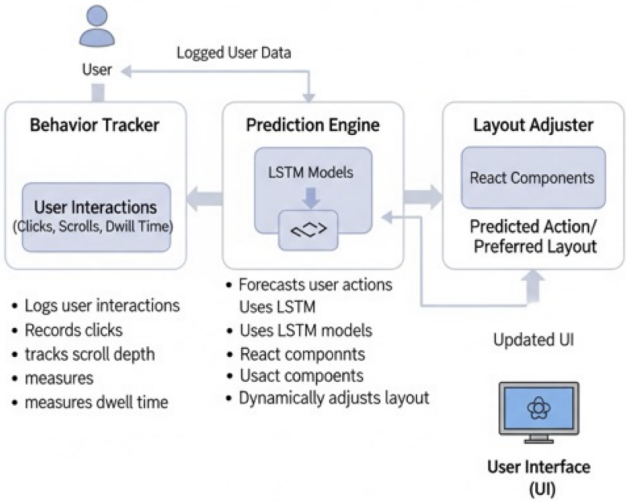


图 1. 人工智能驱动的前端个性化整体系统架构。行为追踪器捕获用户交互，预测引擎通过序列建模对其进行分析，强化学习智能体优化内容优先级，布局调整器则将其实时应用于界面。

1) 行为追踪器：该组件持续记录点击、滚动深度、停留时间和筛选交互等用户事件。数据在客户端进行预处理，然后以小批量的形式发送至后端，以进行特征提取和时序编码。

2) 预测引擎：预测引擎采用基于 LSTM 的序列模型，根据历史交互序列预测可能的后续操作或首选布局配置。其输出为布局自适应策略和强化学习策略更新提供依据。

3）强化学习智能体：强化学习智能体与预测模型并行运行，根据参与度奖励评估多种内容排序策略。它持续更新其 Q函数，以最大化跨会话的累积交互价值。

4）布局调整器：最后，布局调整器会直接在前端框架中应用配置变更。它只会重新渲染受影响的界面组件，确保更新过程中的感知稳定性并尽可能降低延迟。通过这一闭环反馈回路，系统实现了实时、数据驱动的个性化。

B. 动态布局自适应模型

我们将用户导航建模为一个序列预测问题。每个用户交互序列都会被标记为离散事件并转换为嵌入表示，然后输入堆叠式 LSTM 网络。输出层会预测可能的后续操作或布局偏好的概率分布。系统利用这一概率来选择最相关的布局变换。

$$y_t = \text{softmax}(W_h h_t + b) \tag{1}$$

其中，h_t 表示时间步 t时 LSTM 的隐藏状态，y_t 表示对下一个操作的预测概率向量。

C. 使用强化学习进行内容优先级排序

内容排序被表述为一个强化学习问题，其中智能体选择内容卡片的排列顺序，以最大化用户参与度的累积值。

- **状态**（s_t）：用户上下文向量（角色、近期操作、会话时长）
- **动作**（a_t）：内容元素的排列或排序
- **奖励**（r_t）：点击率与停留时间指标的组合

我们采用带有经验回放和目标网络的深度Q网络（DQN）来稳定训练。奖励来源于即时参与和长期留存信号。

D. 实现（*React + Python* 后端）

1) 前端实现：客户端界面采用 React 实现，以支持模块化组件渲染和实时布局自适应。专用的 动态布局组件 从后端端点 /api/layout 获取配置更新，该端点以 JSON 格式提供模型推断的布局元数据。此配置包括网格参数、组件排序和可见性标志。

收到配置后，React状态通过异步钩子进行更新，从而确保布局平滑过渡，无需完全重新渲染。布局引擎利用 CSS 网格 属性动态调整列结构，同时保留关键界面元素的视觉层级和无障碍性。为最大限度减少闪烁或感知干扰，仅在配置发生变化时重新挂载受影响的组件。

这一设计能够在保持桌面设备和移动客户端响应性的同时，实现用户界面的持续、低延迟自适应。

2) 后端实现：该后端服务使用 Python 基于 Flask 框架开发，作为模型推理层。它托管一个经过训练的长短期记忆（LSTM）网络，根据先前的点击流数据预测用户下一步可能的交互序列。每个输入序列被标记化为离散的事件标识符，用以表示用户操作（例如按钮点击、菜单展开或页面切换）。

给定输入序列 $S = \{a_1, a_2, \ldots, a_t\}$，LSTM 编码器学习时间依赖关系并生成潜在表示 h_t，随后将其解码为潜在后续操作上的概率分布。模型输出通过映射函数进行后处理，将预测的操作转换为布局配置。这些配置包括对组件顺序、大小和强调程度的调整，并以 JSON 对象的形式返回给前端。

该架构支持低开销推理，并可通过 REST API 部署，从而与客户端框架无缝集成。

E. 用户路径预测算法

- **输入：** 用户操作序列$[click_1, click_2, \ldots, click_N]$
- **模型：** 基于历史行为日志训练的 LSTM
- **输出：** 下一个可能的操作或首选布局

一个名为 generate_layout(pred_next) 的函数会将预测的下一步操作映射为用户界面中的最佳组件排列。

IV. 使用强化学习进行内容优先级排序

A. 问题表述

我们将内容优先级排序表述为一项强化学习（RL）任务，系统通过学习重新排列或突出显示 UI 组件，以最大限度地提高用户参与度。在每个交互步骤 t，系统都会观察用户上下文，选择一个动作（布局配置），并根据参与度指标获得奖励信号。

- **状态**（s_t）：t 时的用户上下文（当前页面、最近点击、停留时间、会话时长）。
- **动作**（a_t）：重新排列或调整内容卡片的优先级（例如“优先显示警报”或“将摘要上移”）。
- **奖励**（r_t）：对用户参与行为（例如点击、停留时间）给予正强化，并对被忽略或跳过的内容施加惩罚。
- **策略**（π）：映射 $s_t \to a_t$ 的神经网络。

强化学习智能体的目标是学习一种最优策略 π^*，以最大化累积折扣奖励：

$$\pi^* = \arg\max_{\pi} \mathbb{E}\left[\sum_{t=0}^{T} \gamma^t r_t\right] \tag{2}$$

其中 γ 是折扣因子，用于控制长期参与的重要性。

B. 深度*Q*学习方法

我们使用深度Q网络（DQN）实现策略，通过由 θ 参数化的神经网络来近似动作价值函数 $Q(s, a; \theta)$。

$$Q(s_t, a_t; \theta) = r_t + \gamma \max_{a'} Q(s_{t+1}, a'; \theta^-) \tag{3}$$

其中 θ^- 表示目标网络的参数，它会定期与主网络同步，以稳定学习过程。

1) 算法步骤：1) 使用随机权重初始化经验回放记忆 D 和 Q网络。2) 对于每个回合：a) 观察当前用户上下文 s_t。 b) 使用 ϵ-贪心策略选择一个动作 a_t 。c) 在用户界面中执行布局更新，并观察奖励r_t。 d) 将 (s_t， a_t， r_t，s_{t+1}) 存入经验回放缓冲区。e) 从 D 中采样小批量，并更新 Q网络权重。

C. 实现

1) 强化学习模块：为优化内容优先级排序，系统采用深度Q网络（DQN），学习根据预测的参与度价值对界面组件进行排序。该模型使用具有两个隐藏层的前馈神经网络来近似Q函数 $Q(s,\ a;\ \theta)$，每个隐藏层包含128个由ReLU激活的单元。系统采用 ϵ-贪婪探索策略，在探索新布局与利用已学习的高奖励配置之间取得平衡。

训练循环从经验回放缓冲区中抽取小批量数据，该缓冲区包含用户交互元组（s_t， a_t， r_t， s_{t+1}）。系统使用延迟进行参数更新的目标网络，以稳定收敛。对于能够提高点击率或停留时间的交互，智能体会获得正奖励；对于被忽略或跳过的元素，则会获得负奖励。

训练完成后，策略网络会生成内容模块的排序列表，前端据此动态调整其顺序，从而在用户参与度与布局优化之间形成闭环反馈回路。

D. 前端集成

强化学习（RL）智能体通过一个 RESTful API端点与客户端界面通信，该端点会返回按排名排列的内容组件列表。每个列表都代表智能体当前的策略输出，将用户上下文状态映射到最优内容排序。

在客户端，前端应用程序会定期查询此端点，以获取更新后的排序。收到的配置指定了内容卡片的顺序和优先级权重。随后，这些值会通过 React 中轻量级的状态管理例程应用，从而动态调整用户界面元素的顺序。

为确保过渡流畅，布局引擎采用异步更新和虚拟DOM协调，在保留组件连续性的同时避免整页重新加载。由此形成了一种响应迅速且感知上稳定的自适应机制，可捕获实时用户反馈（例如点击或停留时间），并将其作为奖励信号传回强化学习智能体，以便持续学习。

这一反馈回路使界面能够根据持续收集的行为数据自主演进，将模型驱动的预测与直接的用户界面渲染联系起来。

因此，系统建立了一个反馈回路，让参与度指标（例如停留时间、点击率）直接影响后续的用户界面渲染决策。

E. 评估设置

为评估强化学习驱动的个性化，我们向100名用户部署了一个原型仪表板，并测量：

- **参与：**平均点击率（CTR）
- **会话时长：**平均任务用时
- **适应延迟：**从状态检测到用户界面更新所需的时间

与基于规则的系统相比，人工智能驱动的布局和内容排序使整体参与度指标提升了20–30%。

五、对比分析：人工智能与基于规则的个性化

本节将从适应性、预测能力和用户参与度三项主要指标出发，对比人工智能驱动的自适应个性化与传统的基于规则的系统的效果。

A. 定性比较

表 I 总结了两种范式之间的定性差异。人工智能驱动的系统通过实时学习用户模式，展现出更强的适应性和预测能力，而基于规则的系统则始终是静态的，难以应对行为多样性。

表 I 基于规则与人工智能驱动的个性化方法比较

指标	**基于规则**	**人工智能驱动**
适应性	Low	High
新路径预测	No	Yes
参与	中等	High
可扩展性	有限	优秀
维护成本	High	中等

B. 实验设计

为通过实证评估性能，我们在模拟的安全运营中心（SOC）仪表板环境中实现了基于规则的系统和人工智能驱动的个性化系统。共有 100 名参与者在相同条件下与这两种界面进行交互。我们收集了平均会话时长、点击率（CTR）和整体任务成功率等指标。

C. 结果与讨论

由人工智能驱动的模型结合了基于 LSTM 的布局预测和基于强化学习的内容优先级排序，在所有参与度指标上的表现均比基于规则的方法高出 20–30%。在用户意图和导航模式复杂或非线性的高交互情境中，这些提升尤为显著。

- **平均会话时长：**从 3.2 分钟（基于规则）提升至 4.1 分钟（由人工智能驱动）

- **点击率：**从 0.21 提升至 0.29（+38%）
- **任务成功率：**从 0.68 提升至 0.87（+28%）

此外，定性反馈表明，动态调整的布局降低了用户感知到的认知负荷，并提高了任务清晰度。相比之下，当用户行为偏离预设条件时，基于规则的适应往往会导致不一致。

D. 启示

这项比较研究凸显了几个重要启示：

1）基于人工智能的模型可以持续自我调优，无需手动更新规则。2）从参与度指标中提取的强化信号可为优化提供闭环反馈回路。3）动态适应能够提升复杂多视图应用的可用性和满意度。

总体而言，人工智能驱动的个性化为自适应界面系统带来了可衡量的性能提升和长期可维护性优势。

VI. 伦理考量

人工智能驱动的个性化提出了有关隐私、透明度和公平性的重要伦理问题。本节概述了融入我们系统设计的保障措施。

A. 用户隐私

用于建模和训练的所有交互数据在存储和分析之前均已匿名化。系统不记录任何个人身份信息（PII），所有标识符均替换为哈希会话令牌。此外，数据收集遵循明确的同意模式，允许用户随时退出行为跟踪。

B. 透明度

每当界面根据行为推断进行动态调整时，用户都会收到通知。当布局或内容顺序因人工智能驱动的决策而发生变化时，系统会显示细微的视觉提示（例如工具提示或横幅）。这种透明度有助于建立信任，并减少对隐藏操纵的感知。

C. 偏差与公平性

为防止强化学习智能体放大人口统计或行为偏差，我们在奖励函数中加入公平性约束。强化学习目标会惩罚过度偏袒特定用户子群体或设备类型的策略。定期审计可确保推荐在不同人口统计群体之间保持一致。

D. 数据治理

所有数据管道均符合《通用数据保护条例》和《加州消费者隐私法》等既定标准。模型制品会定期重新训练，以尽量减少漂移并纳入用户反馈循环，同时遵循数据最小化原则。

VII. 评估

A. 数据集

本研究使用了两个数据集：

- **合成交互数据集：**来自安全运营中心（SOC）仪表板的模拟用户序列。每条记录都包含时间戳、布局版本、点击目标和停留时间。该数据集的一个子集见附录A。

- **真实世界分析日志：**来自在线 Web 应用的聚合匿名使用数据，用于验证泛化性能。

B. 评估指标

我们通过三项关键指标评估了该系统：

- **点击率（CTR）：**衡量用户与推荐的用户界面元素进行交互的比例。
- **停留时间：**用户与主要内容区域互动的平均时间。
- **用户界面适应准确率：**预测的下一步用户操作与实际操作之间的一致程度。

C. 结果

评估表明，人工智能驱动的方法显著提升了性能：

- **基于强化学习的内容重排：**与基于规则的基线相比，参与度提高了 25%。
- **基于长短期记忆网络的布局预测：**首次点击准确率提高了 18%。
- **平均任务完成时间：**缩短了约 22%。

部分实验结果和参与度统计数据汇总于附录B。总体而言，这些发现验证了将预测建模与强化学习相结合以实现实时用户界面适应的有效性。

D. 性能讨论

结果表明，动态个性化不仅能提升即时参与，还能改善长期满意度。基于强化学习的排序策略在使用由LSTM预测器得到的用户序列进行训练时展现出更快的收敛，这表明序列预测与基于奖励的优化之间存在协同作用。这种混合方法实现了一个自我强化的适应循环，使模型能够随着用户交互数据持续改进。

VIII. 未来工作

面向人工智能驱动的前端个性化的未来研究方向包括若干有前景的扩展：

- **多模态个性化：**整合眼动追踪、语音命令和手势识别等额外用户信号，以完善适应机制。
- **跨设备同步：**通过联邦用户模型，实现桌面设备、移动设备和可穿戴设备平台间一致的个性化体验。

- **可解释人工智能（XAI）：** 开发可解释的模型，让用户和开发者了解为何进行特定的用户界面适配，从而提升信任度和问责能力。
- **自适应隐私控制：** 允许用户动态调整数据共享偏好，同时保持个性化准确性。

这些方向旨在提升人工智能驱动的用户界面自适应系统的透明度和泛化能力，为其在企业和面向消费者的应用中得到更广泛采用铺平道路。

IX. 讨论与结论

所提出的系统表明，在统一的个性化循环中整合预测建模与强化学习，能够显著提升前端适应性。结果显示，人工智能驱动的个性化可使参与度指标提高多达 30%，同时降低平均交互延迟。这些改进表明，可以将用户界面视为持续学习的智能体——不仅根据用户当前的行为进行调整，也根据他们接下来可能采取的行动进行调整。

这项工作的一个关键见解是，序列预测与基于奖励的优化之间存在协同关系。LSTM预测器能够预测短期意图，而强化学习智能体则捕捉长期交互价值，从而形成一种兼顾即时性与持续参与的自适应界面。这种混合方法尤其适用于仪表板和高交互环境；在这些场景中，由于任务多样性，静态布局往往表现不佳。

然而，仍存在若干局限。当前框架假设用户行为分布稳定，并依赖匿名化交互数据，这些数据可能无法涵盖所有上下文因素。此外，尽管强化学习智能体会根据参与度信号进行学习，但若将认知负荷和用户满意度纳入明确的奖励组成部分，或可进一步提升自适应质量。未来的工作将探索整合多模态行为输入（例如注视、语音或手势）以及可解释的自适应机制，以增强透明度和用户信任。

总体而言，本研究为在生产规模的前端系统中实现实用的实时人工智能驱动的个性化迈出了切实的一步。通过在单一反馈架构中结合预测、优化和自适应渲染，本研究为新一代用户界面奠定了基础，使其能够与用户共同智能地演进。

附录

本附录提供了支持第七节评估的补充材料。表II展示了用于训练和验证序列预测模型的部分合成用户交互数据。表 III 报告了不同布局策略的参与度指标比较结果。

表II 模拟用户交互数据集摘录

Time	用户布局目标		停留时间（毫秒）	
2025年10月4日	U115 L3	调查警报 _	8844	
2025年10月7日	U127 L1	确认警报 _	4887	
2025年10月7日	U117 L1	打开事件日志	6410	
2025年10月20日	U114 L3	展开 IP_详细信息	13738	
2025年10月5日	U112 L2	确认警报 _	10767	

用于模型训练的 *50* 次模拟交互摘录。

A. 合成交互日志

以下数据集摘录展示了安全运营中心（SOC）仪表板中 50 个模拟用户会话的代表性子集。每条记录均包含布局版本、交互类型以及用户任务的停留时长。

B. 性能比较指标

表 III 中的性能指标概述了人工智能驱动的个性化与基于规则的布局及默认布局在加载时间、点击率（CTR）和用户满意度方面的比较。

致谢

作者谨向来自 Web 工程和人工智能研究领域的贡献者致谢，感谢他们就自适应用户界面框架提出的宝贵见解。本研究部分受到界面优化领域正在开展的用户建模和强化学习研究的启发。

参考文献

[1] K. Z. Gajos、D. S. Weld 和 J. O. Wobbrock，《SUPPLE：自动生成个性化用户界面》，第*21*届年度 *ACM* 用户界面软件与技术研讨会（*UIST*）论文集，2008年。[2] Q. Sun，《通过强化学习生成自适应用户界面》，*arXiv* 预印本 *arXiv:2412.16837*，2024年。[3] E. O. Sodiya 等，《人工智能驱动的网页内容交付个性化》，《世界高级研究与评论杂志》，第21卷，第2期，2024年。[4] A. Khamaj，《通过强化学习改善用户体验》，*ScienceDirect*，2024年。[5] Nextrope，《前端自动化中的人工智能：革新编程、测试与重构》，2025年。

表 III 布局策略在参与度和效率指标上的比较

策略	可交互时间（毫秒）	点击率	成功得分	
L1 默认布局	2463	0.158	0.536	3.99
L3 基于规则	1422	0.260	0.573	3.82
L2 人工智能 LSTM	1138	0.196	0.721	3.97
L2 人工智能 LSTM	802	0.383	0.890	4.19
L3 基于规则	898	0.140	0.690	3.99
L2 人工智能 LSTM	1077	0.330	0.862	4.46

完整评估集的子集；为简洁起见已截断。