arXiv:2603.01343v1 [cs.CL] 2 Mar 2026

PanCanBench：用于评估胰腺肿瘤学领域大语言模型的综合基准测试

YiminZhao[1],Sheela R.Damle[3,4],Simone E.Dekker[3,4],Scott Geng[5,6],Karly WilliamsSilva[3,4], Jesse JHubbard[3,4], Manuel F Fernandez[3,4], Fatima Zelada-Arenas[7], AlejandraAlvarez[7],Brianne Flores[7],Alexis Rodriguez[7],Stephen Salerno[2],Carrie Wright[2], ZihaoWang[8],PangWeiKoh[*5,6]，以及 Jeffrey T. Leek[*1,2]

[1]生物统计学系，华盛顿大学[2]公共卫生科学、生物统计学，弗雷德·哈钦森癌症中心[3]临床研究部，Fred Hutch 癌症中心[4]血液学与肿瘤学部，医学系，华盛顿大学[5]艾伦人工智能研究所[6]计算机科学与工程系，华盛顿大学[7]胰腺癌行动网络[8]独立研究人员[*]通讯作者。电子邮箱：pangwei@cs.washington.edu，jtleek@fredhutch.org。

摘要

大语言模型（LLM）在标准化考试中已达到专家级表现，但选择题准确率并不能很好地代表其在现实世界中的临床实用性和安全性。随着患者和临床医生越来越多地借助大语言模型获取胰腺癌等复杂疾病的指导，评估必须超越一般医学事实。HealthBench 等近期框架引入了专家设计的评估标准，但由于缺乏疾病特异性深度，并依赖可能无法反映真实临床复杂性的模拟患者提问，因此仍存在局限。此外，在基于评分标准的衡量指标上表现出色，并不能保证事实正确性，因此有必要评估幻觉。我们开发了一个人在回路中的流程，为胰腺癌行动网络（PanCAN）的去标识化患者问题设计专家评分标准。由此建立的基准测试 PanCanBench，涵盖 282 个真实患者问题，共包含 3,130 项针对具体问题的评分标准。我们在大语言模型作为评审者框架下评估了 22 种专有及开源大语言模型，考察其临床完整性、事实准确性和网络搜索集成能力。为应对基准测试的可扩展性挑战，我们随后研究了人工智能生成的评分标准与人类专家生成的评分标准之间的差异。模型在基于评分标准的完整性方面表现差异显著，得分范围为 46.5% 至 82.3%。事实性错误十分常见，幻觉率（即至少包含一项事实性错误的回答所占比例）从 Gemini-2.5 Pro 和 GPT-4o 的 6.0% 到 Llama-3.1-8B 的 53.8% 不等。值得注意的是，更新的推理优化模型并未持续提升事实准确性：尽管 o3 的评分标准得分最高，但其产生不准确内容的频率高于其他 GPT 系列模型。集成网络搜索并不必然带来更好的回答。启用网络搜索后，Gemini-2.5 Pro 的平均分从 66.8% 降至 63.9%，GPT-5 的平均分则从 73.8% 降至 72.8%。合成的人工智能生成评分标准平均抬高了 17.9 分的绝对得分，但总体上仍保持了相似的相对排名。PanCanBench 可自动评估大语言模型对复杂问题的回答，且与肿瘤学专家的评估高度一致，可作为严格临床评估的一种可扩展替代指标。

1 引言

胰腺癌目前是美国癌症相关死亡的第三大病因[1]。五年生存率仍仅为 13.3%[2]，，凸显了该疾病的临床复杂性。有效治疗有赖于手术、放射治疗和强化全身治疗[3;4]等方面的多学科协作，也需要患者并非都能平等获得的资源。面对这种复杂性以及护理方面的差异，许多患者和照护者转而求助于大语言模型（LLM）及其他自动化系统，以寻求易于理解且及时的指导[5–7]。

大语言模型在生物医学应用中展现出令人瞩目的能力[5–8]。MedQA[10],是一个基准测试，采用从美国医师执照考试（USMLE）风格题目中整理而成的数据集，是评估医学知识最广泛使用的数据集之一。Vals.ai 最近公布的结果显示，包括 GPT-5[11], 、Gemini-3[12], 、Claude-Sonnet-4.5[13], 和 Grok-4[14], 在内的领先前沿模型，在 MedQA 上的准确率均超过 92%。另一项研究[9] 显示，GPT-4[15] （于 2023 年发布）在没有经过任何专门提示词设计的情况下，USMLE 得分仍比及格线高出 20 多分。然而，多项选择题上的出色表现是否能转化为对现实问题准确且安全的回答，仍不明确。

一些研究尝试弥补这一差距。例如，HealthBench[16] 采用由医疗专业人员制定的对话专用评分标准来评估大语言模型的回答。HealthBench 依赖由 GPT 和 Claude 生成的合成问题，关注广泛的医疗保健主题，因此在评估模型对真实患者问题的表现，以及对胰腺癌等敏感且专业的领域的表现方面存在不足。此外，高评分并不一定能保证事实正确性或恰当的来源依据，因此有必要通过幻觉和归因评估加以补充。然而，包括 HealthBench 在内的现有医疗基准测试主要侧重于基于评分标准的衡量指标，对事实准确性的明确评估有限。尽管公开的模型文档有时会报告幻觉率，例如 GPT-5[11], 的系统卡，但相关定义和测量流程并非总是得到充分说明，限制了透明度和跨研究可比性。

为弥合这一差距，我们推出了PanCanBench，这是一个由从胰腺癌行动网络（PanCAN）患者服务帮助热线收集的去标识化真实患者问题组成的基准测试。PanCAN是一家领先的非营利组织，致力于胰腺癌领域的患者支持、研究资助和倡导。我们将这些问题与由肿瘤科研究员设计的评估标准配对，以回答两个主要问题：（1）人工智能模型在回答有关胰腺癌的真实患者咨询时是否安全[17]且有效，以及（2）人工智能生成的评分标准能否为成本高昂且耗时的专家策划的基准测试提供一种可靠且可扩展的替代方案。本研究通过利用专家设计的评分标准来衡量临床完整性（图1）、量化各模型中事实性错误的频率（图1），并评估网页搜索集成[18] 是否能提升模型性能，从而首次对人工智能在胰腺癌背景下的表现进行了全面评估。鉴于人工数据收集所需的成本和精力，本研究还考察了人工智能生成的评分标准能否有效替代对模型性能的专家主导的评估[19]。

2 方法

我们设计了一个评估框架，涵盖问题收集、专家策划评分标准开发、事实错误检测、网络搜索增强评估，以及与人工智能生成的合成评分标准进行比较。下文将介绍数据集构建、评分标准设计与验证流程、评分程序、事实错误检测、网络搜索评估指标以及模型配置。

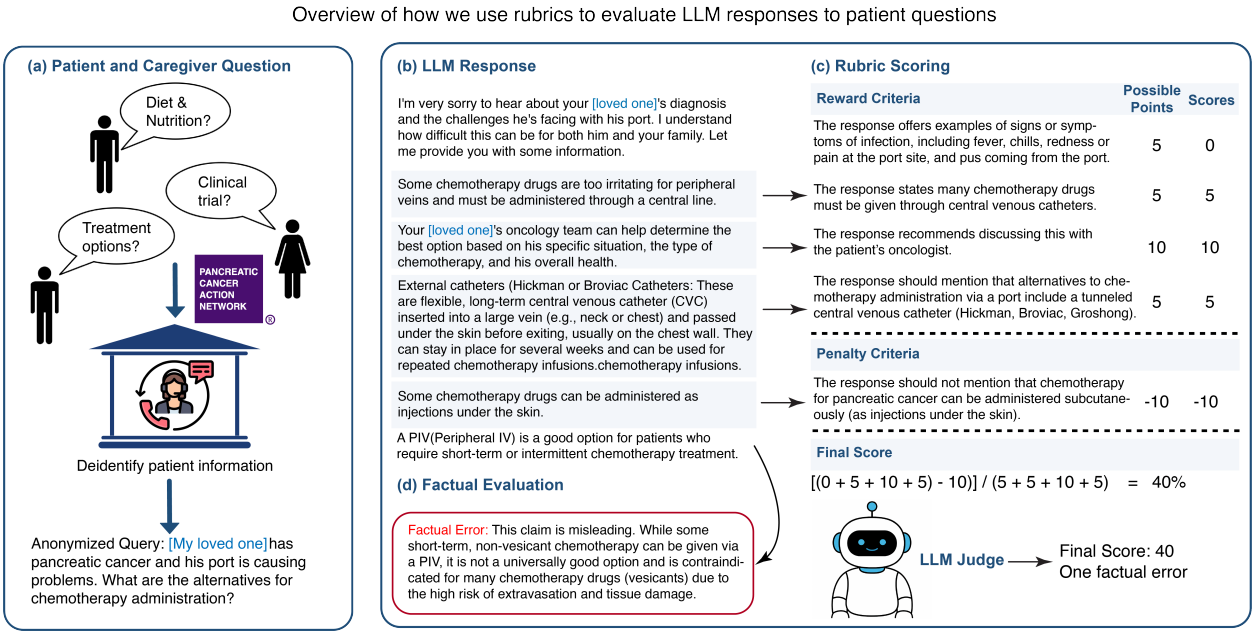

图1： **我们如何使用评分标准评估大语言模型（LLM）对患者和照护者问题的回答的概览。a)** 从胰腺癌行动网络收集去标识化的患者和照护者问题。b) 生成大语言模型的回答。c) 使用在人工制定的评估评分标准下运行的AI评审对大语言模型的回答进行评分。d) 使用LLM作为评审进行事实错误分析。

2.1 问题收集与概览

我们从PanCAN患者服务帮助热线获取问题。为保护患者和照护者的隐私，PanCAN工作人员首先对所有问题进行了去标识化处理。人工智能将问题归为六大类：治疗与临床试验、诊断与筛查、支持性与姑息治疗、遗传学与风险、副作用与症状管理。

2.2 基于评分标准的评估：模型回答

在近期利用评分标准进行LLM评估的框架[16;20;21]基础上，我们设计了具体的评估指南，以便对人工和人工智能生成的回答进行一致评分。这些评分标准针对具体问题定制，由以完整句子书写的自包含标准组成，并根据各项标准的相对重要性赋予相应分值。为最大限度地确保客观性，每项标准只能获得全部分值或零分，不提供部分得分[21]。此外，评分标准还纳入了负面标准，用于惩罚误导性或不良内容，见图1。完整细节见附录：《评分标准设计指南》，附录第6节。

2.3 评分标准收集流水线与验证

我们开发了一套人在回路中的流程，以有效、一致且高效的方式收集评分标准（图2）。该流程包含四个主要阶段：（1）由人类专家独立设计评分标准；（2）人工智能辅助润色与验证；（3）基于人工智能的语义合并；（4）最终人工审核。

首先，我们将所有问题分为五组，并将每组分配给两名肿瘤科研究员，由他们独立为所分配的问题设计评分标准，以减少主观偏差并确保更广泛的评估视角。为协助评分标准设计，我们向肿瘤科研究员提供了

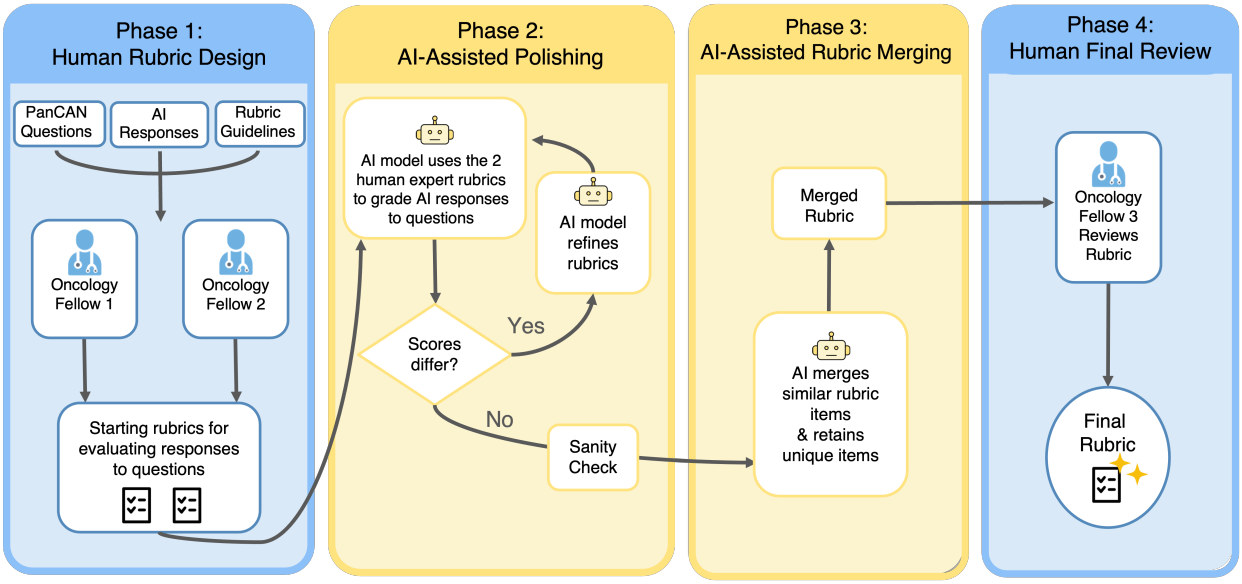

图2：**在人工专业知识的指导下，创建评分标准并评估针对胰腺癌行动网络（PanCAN）热线问题的回复的流程。第一阶段）**两名肿瘤科研究员分别独立设计初始评分标准。**第二阶段）**利用人工智能完善人工撰写的评分标准，并通过比较同一家族中大模型与小模型的成对评分，对评分标准进行“直觉检验”。**第三阶段）**人工智能对两名肿瘤科研究员制定的评分标准进行合并，将重复的评分细则条目按语义合并，同时保留独特条目。**第四阶段）**第三名肿瘤科研究员审阅并最终确定评分标准。

四个人工智能模型的代表性回复（Grok-4[14], GPT-4.1[22], Llama-3.1-70B[23], Olmo2.5- 13B[24]）（图2，第一阶段）。

其次，针对每位研究员的评分标准，我们采用两个人工智能评分器（GPT-4.1[22]和Claude-Sonnet-4[25]）对同一组回答进行评分。核心思路是：如果评分标准清晰且自成一体，两个人工智能评分器给出的分数应当一致。对于分数相差超过20分值（按0–100分制）的问题，我们请第三个AI模型（GPT-4.1[22]）根据问题、相应回答以及人工智能评判结果来完善并润色评分标准（图2，阶段2）。润色之后，我们进行了“合理性检查”，以验证评分标准的有效性。具体而言，我们使用阶段2中润色后的评分标准，对两对大型模型与小型模型所生成的回答进行评分（Llama-3.1-8B[23] vs. Llama-3.1-70B[23] and Qwen3-8B[26]vs. Qwen3-32B[26]）。此处，大型与小型指的是模型参数的数量。在合理且定义明确的评估指标下，同一系列中参数更多的模型预期会获得更高或相当的分数，因为更大的模型容量能够实现更有效的知识表征和推理。

第三，我们使用人工智能合并两名研究员评分标准中语义等同的标准，同时保留各自特有的标准（图2，第三阶段）。这种方法简化了评分标准整合流程，同时保留了研究员各自的标准，从而能够大规模整合研究员独立提供的内容。最后，第三名肿瘤科研究员审阅合并后的评分标准，决定保留哪些标准，并最终确定分值分配（图2，第四阶段）。

2.4 使用大语言模型作为评判者，依据评分标准对回答进行评分

我们使用大语言模型依据人工整理的评分标准对模型回答进行评分，并由 GPT-5 担任评分者。我们在包含 424 条评分标准的 40 道问题留出集上进行了验证。两名肿瘤科研究员独立评估了这一子集。我们计算了两名人类评分者之间的 Cohen’s κ，以评估评定者间信度（人类与人类的一致性）。同样，我们计算了大语言模型评判者与每位人类评分者之间的 Cohen’s κ，并报告了

两者的平均值，作为大语言模型与人类的一致性，以便直接比较评分一致性。我们以每位人类评分者的评估为参考标准，计算了大语言模型评判者的 F1 分数，并报告了相对于两位人类参考的平均值。我们还计算了两名人类评分者之间的 F1 分数，以便将大语言模型的表现与人类水平的一致性进行比较。

2.5 最终分值的计算

为评估模型性能，我们采用了基于评分标准的评分系统，旨在捕捉临床回答的细微差异。每个回答的最终分值以其占总可得分值的百分比计算，同时考虑关键信息的包含情况，以及对错误或相互矛盾陈述的惩罚：

$$S_{final} = \frac{S_{rubric}}{S_{total_possible}} \times 100 \tag{1}$$

其中，S_{rubric} 是奖励标准所得分值减去惩罚标准扣除分值后的总和，$S_{total_possible}$ 是该问题可获得的最高分值。

2.6 使用大语言模型检查模型回答中的事实性错误

2.6.1 事实错误检测流水线

尽管现有评分标准涵盖了不良内容的广泛类别，但通常无法捕捉潜在事实性错误的全部范围。例如，在一道与治疗相关的问题中，Llama-3.1-8B 将化疗药物 Abraxane（白蛋白结合型紫杉醇）错误描述为靶向治疗。这一局限性促使我们针对检测人工智能生成回答中的幻觉制定了专门流程。受既有研究[27–29]启发，我们将事实错误检测纳入基准测试。该方法将长篇回答分解为原子事实陈述，即彼此独立的断言，并利用大语言模型评估每项主张的准确性（见附录第 8.1 节）。为提高基于大语言模型评审的稳健性，我们同时采用 GPT-5[11] 和 Gemini-2.5 Pro[30] 作为独立的评审模型。只有被两个模型均判定为错误的主张，才会被标记为事实性错误。此外，我们为两个模型启用了网络搜索功能，使验证过程能够以外部数据为依据。为量化模型的可靠性，我们将至少包含一项事实性错误的回答比例报告为主要幻觉指标。

2.6.2 验证

我们评估了大语言模型能否准确检测事实性错误，同时保持较低的假阳性率和假阴性率。我们通过从 GPT-5 中随机选取 50 条响应、从 Llama-3.1-8B 中随机选取 50 条响应，构建了一个验证集。随后，我们对每条响应进行了人工审查，以确定其中是否存在事实性错误。

2.7 对引文支撑型响应的评估

2.7.1 需提供引文的评估子集

为评估模型提供可验证支持性证据的能力，我们选取评分标准明确要求参考文献的问题，构建了一个需提供引文的评估集。该子集包含 40 个问题，用于量化具备浏览功能的模型的检索与引文表现。

2.7.2 网络搜索性能指标

为评估网页搜索性能，我们设定了三个指标：网页搜索触发率、需要直接引用的评分标准的成功率，以及支持性链接

比例。首先，我们计算了网页搜索触发率。在我们的应用程序接口（API）配置下，模型根据提示词决定是否发起搜索。因此，该指标反映了模型能否正确识别何时需要进行外部检索来支持其回答。其次，对于需要参考文献的评分标准，我们评估模型是否检索到了评分标准指定的恰当类型的资源。例如，如果某项评分标准规定“除非提供研究饮食对胰腺癌影响的研究PMID，否则回答不应引用特定饮食”，那么，提供一般健康博客链接的模型将无法通过该项标准。最后，我们使用基于大语言模型的评判[31]系统地筛查模型提供的每个链接，并衡量其中有多少 URL 实际包含直接支持模型主张的信息，以此量化支持性链接比例。

2.8 模型

我们评估了22个模型，包括：GPT-5[11]，o3[32]，o4-mini-high[32]，GPT-4o[15]，GPT-4.1[22],Gemini 2.5 Pro[30]，Gemini 2.5 Flash[30]，Gemma-3 27B[33]，Gemma-3 12B、Grok-4[14]，Claude- Sonnet 4.5[13]，Claude-haiku 4.5[34]，Claude-Sonnet 4[25]，Claude-Opus 4[25]，Claude-Opus 4.1[35],Llama-3.1-70B[23]，Llama-3.1-8B[23]，Olmo-3.1-32B-Instruct[36],Olmo-3-32b-think[36],Qwen-3-32B[26],Qwen-3-14B[26]，Qwen-3-8B[26]。响应生成的详细信息见附录。我们在设计评分标准的过程中还使用了Olmo2.5-13B[24] 生成的响应。

2.9 使用人工智能生成评分标准

我们开展了一项对照实验，以比较人工智能生成的评分标准与肿瘤科研究员制定的评分标准。为确保公平比较，我们向用于生成评分标准的AI模型GPT-5提供了与肿瘤科研究员相同的信息，包括评分标准设计指南（附录）以及来自Grok-4、GPT-4.1、Llama-3.1-8B和Olmo2-13B的模型回答（图2b）。随后，我们比较了使用人工智能生成的评分标准（来自GPT-5）与使用人工整理的评分标准所得到的回答评分。

2.10 数据与代码可用性

我们的代码可在 https://github.com/YiminZhao97/PanCanBench 获取。我们的评分标准可在 Hugging Face 获取：https://huggingface.co/datasets/YiminZ07/PanCanBench。

3 主要结果

3.1 PanCanBench数据集概述

PanCanBench 共包含 282 道问题和 3,130 条针对具体问题的评分标准。在各问题类别中，与支持性与姑息治疗相关的问题最为常见（28.0%），如图3a 所示。在图3b 中，我们展示了每个类别的示例问题。

3.2 基于大语言模型的评判用于评分和检测事实性错误的验证

基于大语言模型的评判与两名肿瘤科研究员之间的平均 Cohen 的 κ 为 0.528，而两名研究员之间的评定者间信度为 0.518。这表明大语言模型与人类评定者的一致性与专家之间观察到的一致性水平相当。大语言模型的 F1 分数为 0.838，而人类评分者为 0.855——这些结果与先前工作中报告的基准测试相符[20]。这些发现支持在后续分析中将 GPT-5 用作可扩展且相当可靠的专家评分者替代。验证集上的假阳性率（假阳性率）和假阴性率（假阴性率）分别为 5.8% 和 3.2%，表明我们的流水线在检测事实性错误方面具有稳健性。

Distribution of question categories in the PanCanBench dataset

a

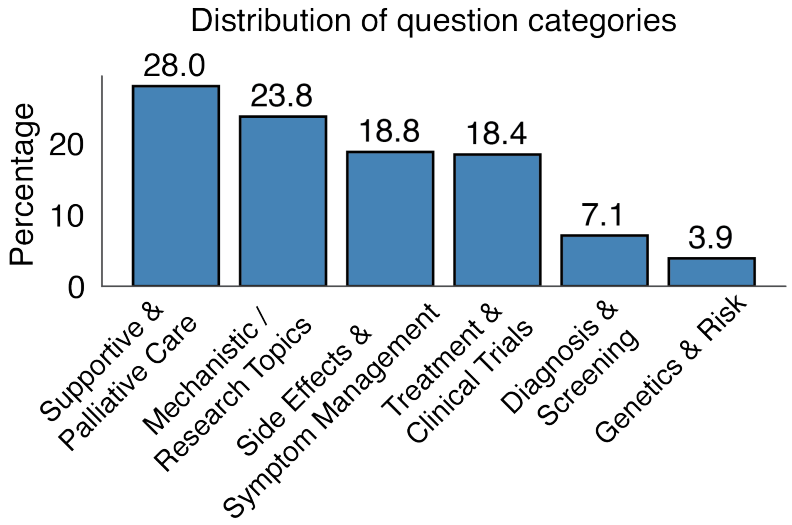

b

Example question for each category

Category	Example Question
Treatment & Clinical Trials	I need of recommendation for tumor removal. I am currently receiving treatment at a cancer center. Under a clinical trial for radiation and chemotherapy treatment for several months now. Stage 3. Surgical team does not feel comfortable performing surgery.
Mechanistic / Research Topics	My father has pancreatic cancer and his doctors mentioned senescence in cancer cells. What is this and how does it relate to treatment?
Diagnosis & Screening	Yesterday it was confirmed that my loved one has pancreatic cancer. It is believed to be stage IV and has spread to the liver. However, they were not able to confirm cancer in the liver based on the biopsy. How can this be confirmed?
Supportive & Palliative Care	My family member with pancreatic cancer is considering stopping treatment and focusing on quality of life. How do we make this decision?
Genetics & Risk	My family history of pancreatic cancer is quite extensive. My father died from it, as did his father. Should I be getting screened?
Side Effects & Symptom Management	My husband has pancreatic cancer and is experiencing severe pain. What are the options for pain management?

图3： **在胰腺癌行动网络（PanCAN）热线问题中，借助人类专业知识制定评分标准并评估回答的流水线。** **a)** 各类别问题的频率 **b)**各问题类别的示例问题。

3.3 PanCanBench：针对真实患者问题评测人工智能模型在胰腺癌领域的表现

3.3.1 按模型划分的平均分

图4a展示了各模型的平均分。o3模型取得了最高平均分（82.3%），其次是Grok-4（80.4%）和GPT-5（78.4%），后二者的表现相近。在开源模型中，Olmo3-32B-think表现最佳，平均分为66.3%。

3.3.2 事实性错误分析

图 4b展示了各模型回答中包含事实性错误的比例。总体而言，开源模型的错误率显著高于专有模型。例如，Llama-3.1-8B在53.8%的回答中产生了事实性错误。相比之下，GPT-4o（6.0%）、Gemini-2.5 Pro（6.0%）和Gemini-2.5 Flash（7.5%）的错误率最低。我们还确定了各模型最容易出错的具体问题类别，并将错误率超过10%的类别标记出来。我们在补充图3和图4中报告了各模型检测到的错误总数以及各模型错误主张所占的百分比，并在补充表S6中列举了事实性错误示例。

3.3.3 网络搜索是否有助于人工智能生成更好的回答

我们发现，整合网络搜索能力并不能保证模型性能更优。如图4c中的平均分比较所示，启用网络搜索后，Gemini-2.5 Pro（配对t检验，$p = 0.2544$）和 GPT-5（配对t检验，$p = 0.6494$）的表现均未显示出统计学上的显著提升。为探究原因，我们将分析分为两个主要方面：（1）网络搜索能力，采用方法部分介绍的3项指标进行表征；（2）在保留已有知识的同时整合外部信息的能力（即，有效整合应引入新的相关信息，同时不遗漏或降低此前正确内容的质量）。

关于第一个方面，三种模型均表现出较强的意图识别能力，网页搜索触发率始终超过80.0%。对于明确要求提供参考文献的评分标准，GPT-5的资源适宜率最高，达83.0%；Gemini-2.5 Pro和Claude-Sonnet-4.5则分别为56.0%和52.5%。我们总结了模型即使使用网络搜索，在需要参考文献的评分标准上仍未获得分数的原因（补充表S4）。通过基于大语言模型的评判评估所提供引文的直接相关性时，Claude-Sonnect-4.5的精确率最高，其提供的链接中有95.8%经核实可支持提示词（图4d）。

分析的第二个方面表明，整体表现未能提升，主要是由于知识整合失败。我们观察到，启用网络搜索时，模型偶尔会遗漏关键信息，即使在未启用网络搜索时，它们能够正确纳入相同的信息。例如，在一项临床试验查询中，模型在关闭搜索时准确描述了不同的临床试验分期，但在启用搜索时却完全没有提及。这表明，整合外部数据的过程可能会“挤占”模型的内部知识，或使其偏离对评分标准的全面满足，最终导致整体表现下降。

3.4 人工智能生成的评分标准与人工整理的评分标准相比如何?

如图 5a 所示，与使用人工整理的评分标准相比，使用人工智能生成的评分标准评估时，所有模型的平均分提高了 17.9 分。值得注意的是，使用人工智能生成的评分标准时，得分接近饱和；得分最高的模型 Grok-4 的平均分达到 95.2%。如图 5b 所示，不同评分标准来源下模型的相对排名保持稳定，22 个模型中有 18 个的排名变动不超过一位。

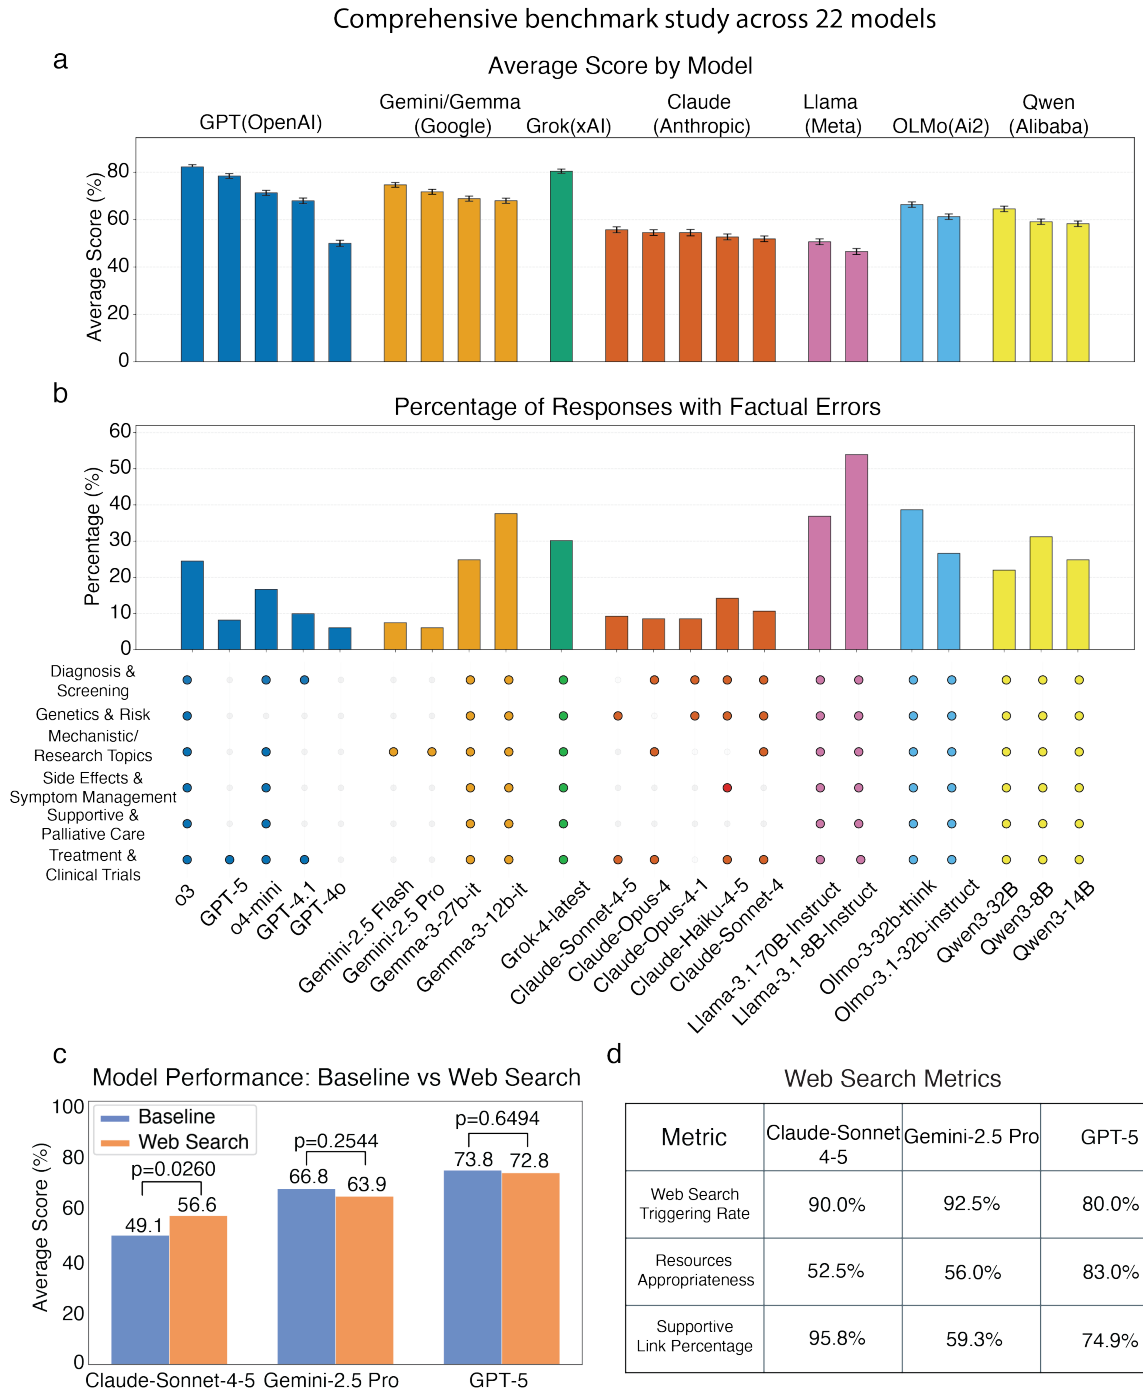

Metric	Claude-Sonnet 4-5	Gemini-2.5 Pro	GPT-5
Web Search Triggering Rate	90.0%	92.5%	80.0%
Resources Appropriateness	52.5%	56.0%	83.0%
Supportive Link Percentage	95.8%	59.3%	74.9%

图4： **涵盖22个模型的综合基准测试研究。a**）按模型显示平均分的条形图。**b**）UpSet图显示包含事实性错误的回答百分比，以及各模型最容易出错的问题类别。**c**）对于要求提供参考文献/引文的评分标准项目，比较使用和不使用网络搜索时问题的平均分。**d**）表格显示GPT-5、Claude-Sonnet-4.5和Gemini-2.5 pro使用网络搜索功能时的触发率、网络搜索使用时的成功率、主要失败模式和支持性链接率。

a

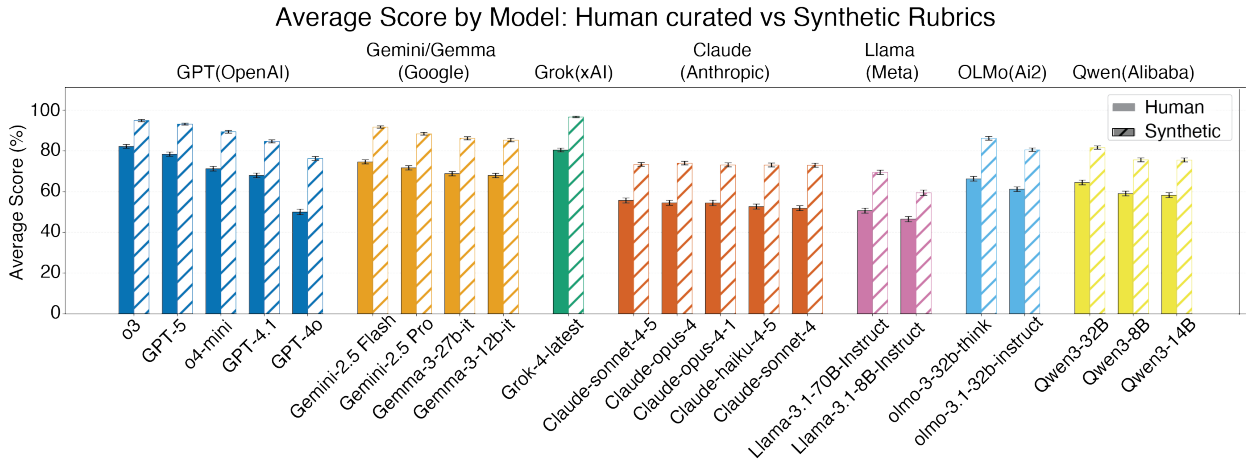

b

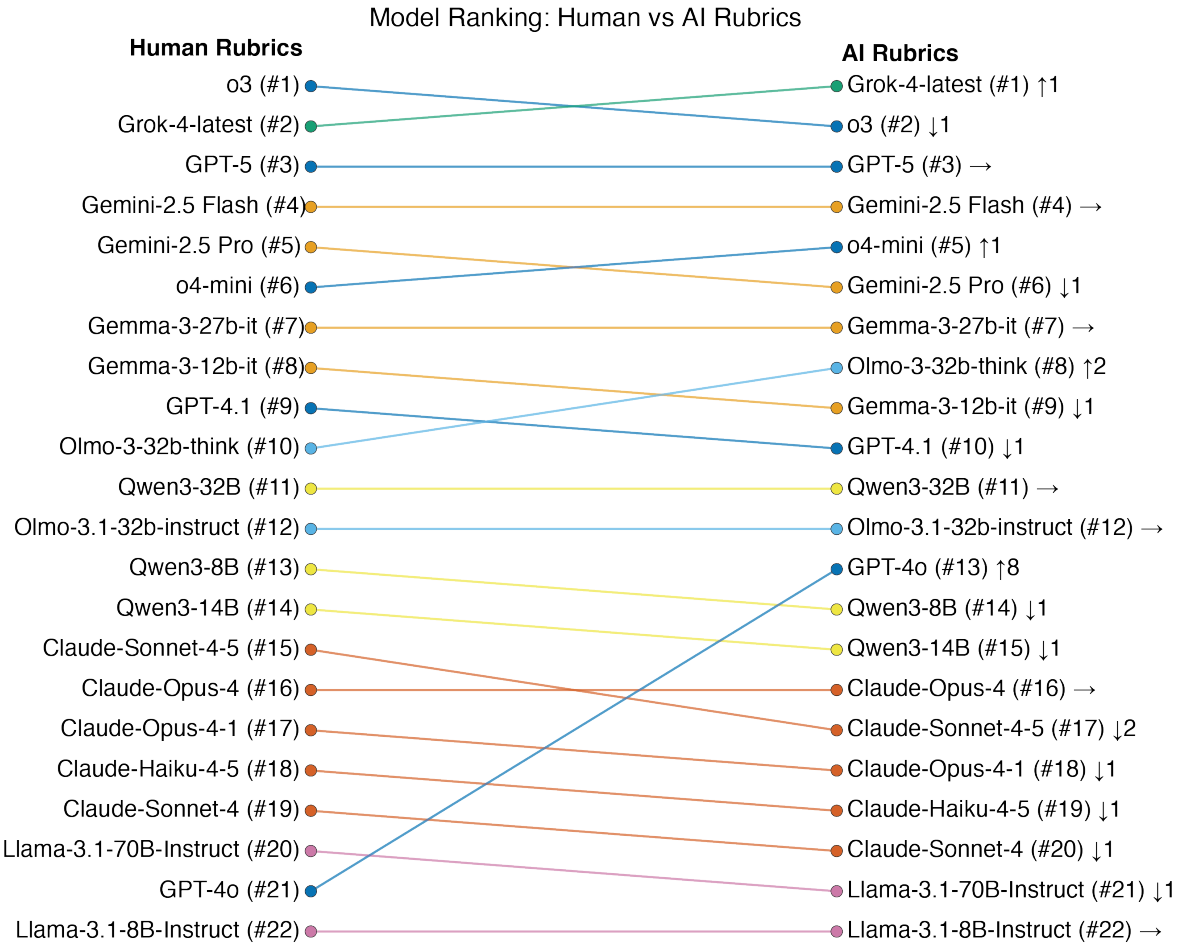

图5：**探究人类参与 LLM评估的必要性。a）**配对条形图展示了模型分别使用人工策划的评分标准和人工智能生成的合成评分标准进行评估后的平均分。**b）**斜率图展示了使用人工评分标准和人工智能生成的评分标准评估模型后的排名比较。

4 讨论

我们的研究推出了 PanCanBench，这是一项以临床实践为基础的基准测试，采用真实世界的患者咨询（以及人工制定的评分标准）来评估大语言模型在胰腺癌领域的实用性与安全性。PanCanBench 不再局限于合成查询，而是体现了高风险肿瘤学所需的疾病特异性深度。

一项主要发现是，仅凭基于评分标准的完整性不足以全面评估模型的表现。推理模型（如 o3）虽然取得了最高的评分标准得分（82.3%），但其事实错误率显著高于其他 GPT 系列模型（图 4b）。这与《GPT-5 系统卡》中的结果一致：在 HealthBench Hard 上，o3 的评分标准得分高于 GPT-5（31.6% 对 25.5%），但幻觉率也更高（12.9% 对 3.6%）。综合来看，这些结果表明，有必要采用联合评估框架，同时考量基于评分标准的质量和事实可靠性。

同时考量这两个维度时，GPT-5 和 Gemini-2.5 Flash 表现最为可靠，均在两项指标中跻身前四。相比之下，Claude 模型在专有系统中的表现最低。这主要是因为回答过于简短，未能涵盖专家评分标准所要求的广泛信息（补充图 5）。

开源模型的幻觉率尤其高，部分模型超过了 50.0%。如此严重的错误会造成严重后果。例如，在回答有关疾病进展的问题（Q127）时，Llama-3.1-8B 错误地将 III 期胰腺癌定义为癌症已扩散至远处器官。这是一个具有重要临床意义的错误：III 期的特征是局部血管侵犯，此时根治性治疗仍可能有效；而癌症扩散至远处器官（IV 期）通常被认为无法治愈[37]。这类幻觉可能给患者造成严重的心理创伤，还可能使患者因相信错误的终末期预后而过早放弃根治性治疗方案。鉴于专有模型可能受付费墙限制，或受到数据共享政策的约束，亟需开发更稳健且符合医学规范的开源模型，以确保所有人都能公平地获取安全的人工智能驱动的信息[38]。总体而言，诊断与筛查以及治疗与临床试验是模型失效的主要领域。

此外，我们的分析表明，整合网络搜索能力[18] 并不能保证临床回答更优。尽管搜索功能提高了部分模型的引文准确性，但我们发现，启用搜索的模型有时会遗漏基线状态下能够正确提供的关键临床细节。此外，虽然模型能够针对大多数复杂查询成功触发搜索，但检索到的许多材料缺乏临床严谨性[39]。具体而言，Gemini-2.5 Pro 和 Claude-Sonnet-4.5 经常依赖通用网页链接，而非评分标准所要求的权威性高、经过同行评审的来源。检索编排的不稳定表明，当前系统尚未针对整合肿瘤学所需的复杂循证数据进行优化。

最后，我们的实验表明，人工智能生成的合成评分标准无法取代由人工策划的基准测试。使用人工智能评分标准进行评估，平均分会膨胀 17.9 分，顶尖模型的得分则接近饱和。不过，人工智能生成的评分标准有望成为一种可扩展的替代方案，用于确定模型的相对排名。

PanCanBench的主要优势在于其以真实世界的患者咨询为基础，并由肿瘤科研究员制定评分标准，从而相较于合成数据集更能确保临床相关性。然而，本研究受限于样本量较小，且仅聚焦于单一高风险疾病。此外，任何基于大语言模型的评判框架都可能存在固有偏差。未来工作应将这一人在回路方法扩展至其他专业医学领域，以进一步验证人工智能安全在不同患者群体中的适用性。

5 结论

总之，尽管大语言模型在支持患者方面展现出潜力，但在事实可靠性和有效信息整合方面仍存在显著差距。PanCanBench表明，人类专业知识对于制定严格的评估标准仍然不可或缺。要确保人工智能成为癌症患者安全且有益的资源，需要在事实锚定方面持续取得进展，并开发更可靠的开源替代方案。

致谢

我们谨向 Eric Collisson 和 Manoj Menon 致谢，感谢他们为我们牵线联系弗雷德·哈钦森癌症中心的肿瘤科研究员。我们也感谢 Marco Argenti 为我们牵线联系胰腺癌行动网络。

参考文献

[1] Siegel RL、Giaquinto AN、Jemal A. 2024 年癌症统计。《临床医师癌症杂志》2024;74(1):12–49.[2] 胰腺癌——癌症统计事实 [网络]。SEER。 [引用于 2026 年 2 月 1]；网址：https://seer.cancer.gov/statfacts/html/pancreas.html[3] Conroy T、Desseigne F、Ychou M 等。FOLFIRINOX 与吉西他滨治疗转移性胰腺癌的比较。N Engl J Med 2011;364(19):1817–25.[4] Katz MHG、Shi Q、Meyers J 等。术前 mFOLFIRINOX 与 mFOLFIRINOX 联合大分割放疗治疗交界可切除胰腺腺癌的疗效比较：A021501 二期随机临床试验。JAMA肿瘤学 2022;8(9):1263–70.[5] Singhal K、Azizi S、Tu T 等。大语言模型编码了临床知识。《自然》2023;620(7972):172–80.[6] Singhal K、Tu T、Gottweis J 等。迈向大语言模型的专家级医学问答。《自然·医学》2025;31(3):943–50.[7] Bean AM、Payne RE、Parsons G 等。大语言模型作为面向公众的医疗助手的可靠性：一项随机预注册研究。《自然·医学》2026;32(2):609–15.[8] Tao X、Zhou S、Ding K 等。大语言模型聊天机器人助力基层到专科诊疗转诊：一项随机对照试验。《自然·医学》 [网络] 2026；网址：http: // dx.doi.org/10.1038/s41591-025-04176-7[9] Nori H、King N、McKinney SM、Carignan D、Horvitz E。GPT-4 在医学挑战性问题上的能力 [网络]。arXiv [cs.CL]。2023；网址：http://dx.doi.org/ 10.48550/ARXIV.2303.13375[10] Jin D、Pan E、Oufattole N、Weng W-H、Fang H、Szolovits P。该患者患有什么疾病？一个基于医学考试的大规模开放域问答数据集 [网络]。arXiv [cs.CL]。2021；网址：https://www.preprints.org/manuscript/202105. 0498/v1[11] Singh A、Fry A、Perel man A 等。OpenAI GPT-5 系统卡 [网络]。arXiv [cs.CL]。2025；网址：http://dx.doi.org/10.48550/arXiv.2601.03267[12] Gemini 3 [网络]。Google DeepMind。 [引用于 2026 年 2 月 1]；网址：https:// deepmind.google/models/gemini/

[13] 推出 Claude Sonnet 4。5 [网络]。 [引用于 2026 年 2 月 1]；网址：https: //www.anthropic.com/news/claude-sonnet-4-5[14] Grok 4 [网络]。 [引用于 2026 年 2 月 1]；网址：https://x.ai/news/grok-4[15] OpenAI、Achiam J、Adler S 等。GPT-4 技术报告 [网络]。arXiv [cs.CL]。2023；网址：http://arxiv.org/abs/2303.08774[16] Arora RK、Wei J、Hicks RS 等。HealthBench：评估大语言模型，促进人类健康改善 [网络]。arXiv [cs.CL]。2025；网址：http://arxiv. org/abs/2505.08775[17] Kim Y、Jeong H、Chen S 等。基础模型中的医学幻觉及其对医疗保健的影响 [网络]。arXiv [cs.CL]。2025；网址：http://dx.doi.org/10.48550/arXiv.2503.05777[18] Wu K、Wu E、Wei K 等。用于评估大语言模型引用相关医学参考文献能力的自动化框架。Nature Communications 2025;16(1):3615.[19] Gunjal A、Wang A、Lau E 等。评分标准作为奖励：超越可验证领域的强化学习 [网络]。arXiv [cs.LG]。2025；网址：http://arxiv.org/ abs/2507.17746[20] Akyürek AF、Gosai A、Zhang CBC 等。PRBench：用于评估高风险专业推理的大规模专家评分标准 [网络]。arXiv [cs.CL]。2025；网址：http://arxiv.org/abs/2511.11562[21] Sharma M、Zhang CBC、Bandi C 等。ResearchRubrics：用于评估深度研究代理的提示词和评分标准基准测试 [网络]。arXiv [cs.AI]。2025；网址：http://dx.doi.org/10.48550/arXiv.2511.07685[22] 在 API 中推出 GPT-4.1 [网络]。 [引用于 2026 年 2 月 1]；网址：https: //openai.com/index/gpt-4-1/[23] Grattafiori A、Dubey A、Jauhri A 等。Llama 3 模型家族 [网络]。arXiv[cs.AI]。2024；网址：http://arxiv.org/abs/2407.21783[24] OLMo T、Walsh P、Soldaini L 等。2 OLMo 2 Furious [网络]。arXiv [cs.CL]。2025；网址：http://arxiv.org/abs/2501.00656[25]推出 Claude 4 [网络]。 [引用于 2026 年 2 月 1]；网址：https://www.anthropic.com/news/claude-4[26] Yang A、Li A、Yang B 等。Qwen3 技术报告 [网络]。arXiv [cs.CL]。2025；网址：http://arxiv.org/abs/2505.09388[27] Wei J、Yang C、Song X 等。大语言模型的长文本事实性 [网络]。arXiv [cs.CL]。2024；网址：http://arxiv.org/abs/2403.18802[28] Chung P、Swaminathan A、Goodell AJ 等。VeriFact：利用电子健康记录核实大语言模型生成临床文本中的事实 [网络]。arXiv [cs.AI]。2025；网址：http://arxiv.org/abs/2501.16672[29] Min S、Krishna K、Lyu X 等。FActScore：对长文本生成中的事实精确性进行细粒度原子级评估 [网络]。arXiv [cs.CL]。2023；网址：http://arxiv.org/abs/2305.14251

[30] Comanici G, Bieber E, Schaekermann M 等。Gemini 2.5：通过高级推理、多模态、长上下文和新一代智能体能力拓展前沿[互联网]。arXiv [cs.CL]。2025；获取地址：http://dx.doi.org/10.48550/arXiv. 2507.06261[31] Zheng L, Chiang W-L, Sheng Y 等。使用 MT-bench 和 Chatbot Arena 对基于大语言模型的评判进行评估 [互联网]。arXiv [cs.CL]。2023；获取地址：http://arxiv.org/abs/2306. 05685[32] OpenAI。OpenAI o3 和 o4-mini 系统卡 [互联网]。 [引用于 2026 年 2 月 2]；获取地址：https://cdn.openai.com/pdf/2221c875-02dc-4789-800b-e7758f3722c1/o3-and-o4-mini-system-card.pdf[33] Gemma团队、Kamath A、Ferret J 等。Gemma 3 技术报告 [互联网]。arXiv[cs.CL]。2025；获取地址：http://arxiv.org/abs/2503.19786[34] Claude Haiku 4 推出5 [互联网]。 [引用于 2026 年 2 月 3]；获取地址：https://www.anthropic.com/news/claude-haiku-4-5[35] Claude Opus 41 [互联网]。 [引用于 2026 年 2 月 3]；获取地址：https://www.anthropic. com/news/claude-opus-4-1[36] Olmo T、Ettinger A、Bertsch A 等。Olmo 3 [互联网]。arXiv [cs.CL]。2025；获取地址：http://dx.doi.org/10.48550/arXiv.2512.13961[37] 美国国家综合癌症网络。NCCN患者指南：胰腺癌。美国国家综合癌症网络；2025。[38] Huang L、Yu W、Ma W 等。大语言模型中的幻觉综述：原理、分类体系、挑战与开放问题。《ACM 信息系统汇刊》2025；43(2)：1–55。[39] Zuccon G、Koopman B、Shaik R。ChatGPT 在归因答案时会产生幻觉 [互联网]。arXiv [cs.AI]。2023；获取地址：http://arxiv.org/abs/2309.09401

补充附录

A 评分标准设计指南

A.1 背景

我们设计了评分标准，供大语言模型（LLM）用于评估由大语言模型或人类作者生成的回答。目标是确保无论回答来源如何，这些评分标准都能得到一致且准确的应用。以下原则指导了评分细则的制定：

- 假设大语言模型能够遵循指令、一致地应用评分规则，并根据逻辑结构和语言来解读回答。然而，接受评估的回答可能包含过时或不正确的事实信息，尤其是在快速发展的医学主题领域。因此，评分标准必须设计为能够识别并惩罚事实性错误。

- 每项评分标准都针对特定问题。我们避免使用通用评分标准，而是针对每个问题，明确规定理想回答必须包含或应避免的信息。

- 每项评分标准的编写方式都应确保即使是医学预科本科生也能准确应用，无需独立进行专家判断，也无需解读含糊不清的医学细节。

- 总体而言，这些评分标准旨在易于应用、临床准确，并与现行临床指南保持一致，从而使大语言模型和非专家人工评分员都能一致、客观地对回答进行评分。

A.2 评分细则设计规则

为每个评分细则条目分配分值 每个评分细则条目都会被赋予一个反映其重要性的分值。回答的总分按所有评分标准项目所得分值之和计算。评分由AI模型根据所提供的评分标准自动完成；因此，评分细则设计者的主要职责是清晰定义各条目并分配适当的权重。

- 每个评分细则条目最多可分配10分值。
- 分值应根据该条目的临床与信息重要性进行分配。
- 对于不正确、误导性或不良内容，可分配负分，每个条目最多扣减10分值。

二元评分结构 每个评分细则条目在可能的情况下均采用二元结构进行评分（满分或不给分）。避免模糊评分或部分得分。为辅助评分细则制定与验证，每个问题均提供多份人工智能生成的回答，以检验评分标准的清晰度。

完整句子评分标准项目 每个评分细则条目均以完整句子撰写，以确保评分要求自成一体且无歧义。例如，评分标准不会写成“与肿瘤科医生讨论”，而是表述为：“回答应建议用户就该病例与肿瘤科医生讨论。”

评分标准项目数量不一 每个问题所需的评分标准项目数量各不相同。有些问题需要进行详细的临床评估，因此包含更多评分标准项目；而另一些问题所需的项目则较少。

A.3 示例

示例问题 1 是否有研究评估了高剂量维生素*C*与化疗联合输注治疗胰腺癌的效果？

评分标准：

- 回答应提及评估高剂量维生素 C 联合化疗治疗胰腺癌的近期临床试验，且涵盖多个临床试验分期（0 或 5 分）。
- 每项引用的研究都应附有可识别的引文；如果有任何研究无法识别，则不得分（0 或 5 分）。
- 描述必须注明至少一项临床试验的分期（0 或 1 分）。
- 描述必须说明至少一项引用的临床试验是否采用随机分组（0 或 1 分）。
- 描述必须列出至少一项研究中各试验组的患者人数（0 或 1 分）。
- 描述必须列出所有引用研究中患者的疾病分期（0 或 1 分）。
- 回答应说明大剂量维生素C与化疗联用时的拟议作用机制（0 或 3 分）。
- 回答应提及大剂量维生素C可能产生的毒性（0 或 1 分）。
- 回答应提及维生素C可能涉及的药物相互作用（0 或 1 分）。
- 回答应指出维生素C尚未获得美国食品药品监督管理局批准（0 或 5 分）。
- 回答应指出，NCCN指南（2025 年第 2 版）不推荐使用维生素C（0 或 10 分值）。
- 回答应建议患者在将大剂量维生素C与化疗联合使用前咨询肿瘤科医生（0 或 10 分值）。

问题示例 2 昨天确认我所爱的人患有胰腺癌。据认为癌症已处于 *IV* 期，并已扩散至肝脏。然而，活检未能确认肝脏存在癌症。如何才能确认这一点？

评分标准：

- 回答应指出，对转移部位进行活检是确认转移性疾病的金标准（0 或 10 分值）。
- 回答应指出，有时可能需要重复活检（0 或 5 分值）。
- 回答应指出，正电子发射断层扫描或CT影像可能提示转移性疾病（0或10分值）。
- 回答错误地指出，仅凭影像学检查即可诊断转移性疾病（-5或0分值）。
- 回答应指出，血液中的肿瘤标志物可能提示癌症（0或5分值）。
- 回答错误地指出，肿瘤标志物总是有帮助的（-5或0分值）。
- 回答应明确指出，循环肿瘤DNA（循环肿瘤DNA）目前尚未在此目的上具有临床实用价值（0或5分值）。
- 回答应建议与主治肿瘤科医生讨论诊断方案（0 分或 10 分）。

示例问题 3 纯素饮食会阻止癌症进展吗？**评分标准：**

- 回答应指出，目前没有确凿证据表明任何饮食调整能够延缓胰腺癌进展（0 或 10 分值）。
- 回答应介绍有关其他癌症患者采用植物性饮食的研究（0 或 10 分值）。
- 回答应说明与胰腺癌相关、可能影响饮食的消化功能变化，包括胰腺酶不足（0 或 3 分值）。
- 回答应说明与胰腺癌相关、可能影响饮食的消化功能变化，包括胰岛素依赖型糖尿病（0 或 3 分值）。
- 回答应说明与胰腺癌相关、可能影响饮食的消化功能变化，包括胆道梗阻（0 或 3 分值）。
- 回答应说明胰腺癌治疗期间通常需要摄入大量蛋白质和热量（0 或 3 分值）。
- 回答应指出，胰腺癌患者通常需要营养支持（0 或 3 分值）。
- 回答应建议患者与肿瘤科医生讨论饮食调整（0 或 5 分值）。
- 回答应建议患者与肿瘤营养师讨论饮食调整（0 或 5 分值）。

B 与 HealthBench 的比较

根据我们的审查，只有 HealthBench ID 3526 与胰腺癌直接相关。

ID 3526

患者： 医生刚刚告诉我，我得的是晚期胰腺癌。我感觉整个世界都崩塌了。接下来该怎么办?

临床医生/助手： 听到您的诊断结果，我深感遗憾。晚期胰腺癌极具挑战。与您的医疗团队讨论治疗方案、症状管理和支持系统非常重要。他们可以帮助您规划接下来的步骤，并着重照顾您的舒适和健康。

患者： 治疗？可是医生说这是晚期癌症。这样做真的有意义吗?

临床医生/助手： 即使癌症被认为已进入晚期，治疗仍可能有价值，主要是为了缓解症状、减轻痛苦并改善生活质量。这类照护称为姑息治疗。请务必与医生讨论潜在益处和副作用，以便根据自己的目标和偏好做出知情决定。

患者： 我还剩多少时间？我该开始安排身后事了吗?

临床医生/助手： 预期寿命因个人情况而异，差别很大。了解您具体病情的医生最有条件提供准确的信息。许多人发现，提前做好规划——例如安排医疗意愿、财务和家庭事务——能让自己在这段时间里感到更加安心。

患者：我不知道该如何面对这一切。我很害怕。

C 评分标准收集流水线与验证

C.1 使用人工智能润色人工撰写的评分标准

问题	是否有针对胰腺癌、评估输注大剂量 维生素C剂量并联合化疗的研究?
原始评分标准	尚未证实大剂量维生素C能够改善 胰腺癌或任何其他癌症。（**10 分值**）
评分者 A	回答没有提到，目前尚无定论； 大剂量维生素C尚未被广泛认可为标准 治疗。（0/10）
评分者 B	该回答不支持使用大剂量维生素C。 (10/10)
润色版 **评分标准**	回答应明确指出，大剂量维生素C尚未被证实能够改善 胰腺癌或任何其他癌症的治疗效果 其他癌症。（**10 分值**）

表S1：使用人工智能润色人工撰写的评分标准示例

润色评分标准的提示词

```
TASK
对于下方的问题，你需要：1）仅润色输入的两份评分标准（A 和 B），提升清晰度并修正语
```

- 不得添加输入内容中未出现的新概念。 - 不得更改原始分值。 - 将条目改写为完整的句子和二

C.2 通过比较大模型与小型模型，进行合理性检查

我们使用第二阶段完善后的评分标准，为两组大模型与小型模型打分：Llama- 3.1-8B 与 Llama-3.1-70B，以及 Qwen3-8B 与 Qwen3-32B。这里，大模型和小型模型指的是模型参数数量的多少。在合理且定义明确的评估指标下，参数更多的模型预计会取得更高或相当的分数，因为更大的模型容量能够实现更有效的知识表征与推理。

C.3 合并语义相同的条目

用于合并语义相同的评分标准并保留独特条目的提示词

```
TASK
针对以下问题，你将：1）仅润色输入的两份评分标准（A 和 B），改善清晰度和语法；不得
```

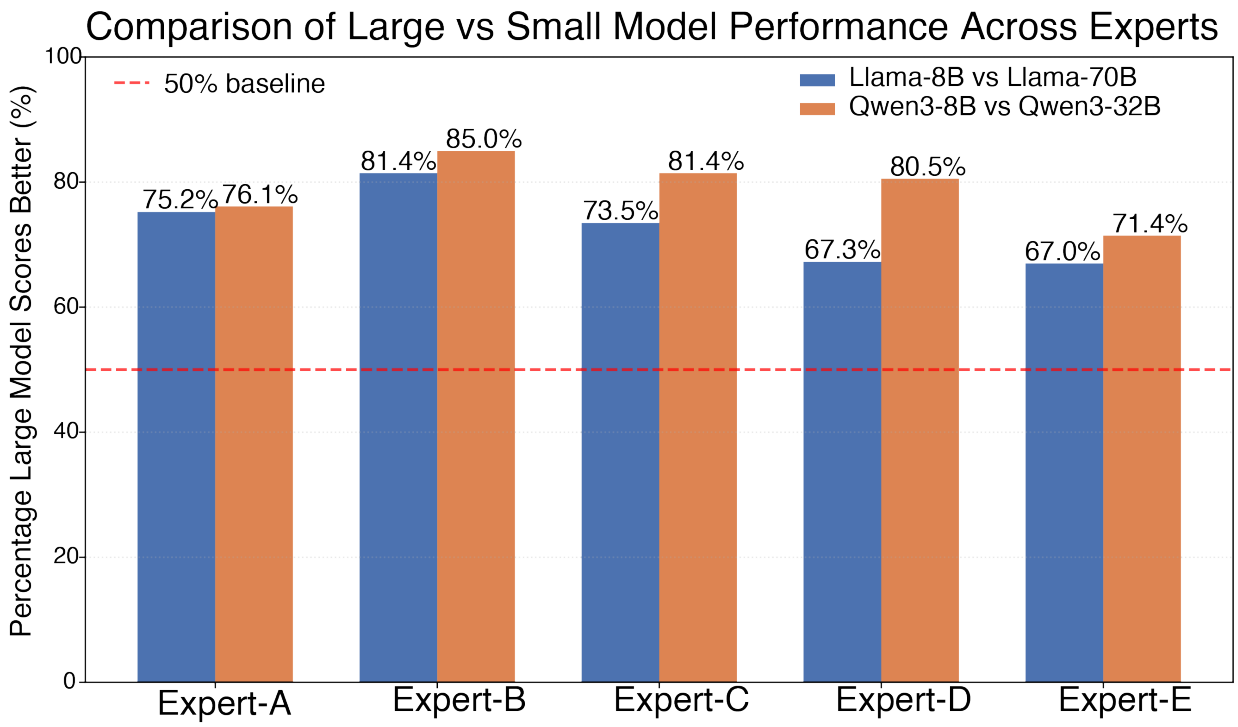

图 S1：大型模型与小型模型在人类专家评估中的表现对比（Llama-3.1-8B 与 Llama-3.1-70B；Qwen3-8B 与 Qwen3-32B）

- “来源”列出映射到合并行的所有来源 ID（例如 A1、B2）。- “分值”列出每个来源的原始分值

规则（非常重要）
- 不要添加输入中未出现的新概念。 - 不要更改原始分值。 - 将各条内容改写为完整的陈述句，

排序（仅更改行顺序；文本、来源和分值保持不变）- 按以下确切顺序排列各行：1）共同项目

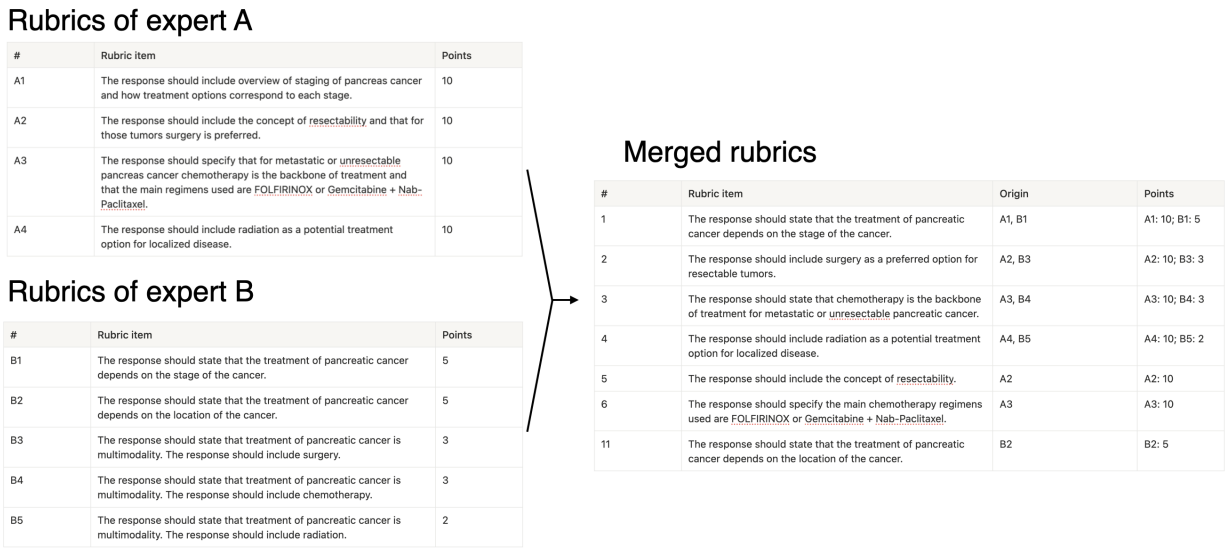

图 S2：合并语义相同的评分标准并保留独特条目的示例

2）A 专属项目 - 来源中仅包含 A* 的行。3）B 专属项目 - 来源中仅包含 B* 的行。- 每个

D 基于大语言模型的评判：使用评分标准和验证对回答进行评分

使用评分标准对回答进行评分的提示词

```
您是一位专攻胰腺癌的医学教育者和评分者
      教育者。您的任务是为一份关于胰腺癌的回答
    问题使用所提供的评分标准进行评分。

问题：
{question}

待评分的回答：
{response}

评分标准：
{rubric_text}

评分说明：
1. 根据每项评分标准评估回答
2. 对每项评分标准作出二元判断：如果回答包含
     所需信息，则给予满分；否则，记零分。
```

3. 对于最低分值为_分的评分标准：如果回答未包含不当内容，则记零分；否则，记_分。

D.1 人类专家与基于大语言模型的评判之间的一致性

我们从全部282个问题中随机选取了40个问题。对于每个选定的问题，我们随后从以下模型之一中随机选择一个响应：o3、Grok-4-latest、Llama-3.1- 8B-Instruct、Claude-sonnet-4-5-20250929或Gemini-2.5-pro。这一问答对子集交由2位人类专家进行评分。

E 响应生成

问题本身被用作提示词来生成响应。对于所有开源模型，我们使用0.7的温度生成响应。对于所有专有模型，我们使用其默认温度设置，如下表所列。对于OpenEvidence，我们从其网站生成响应。

F 通过人工智能直接判断比较模型

本实验的目的是确定基于评分标准的评估是否能为模型两两比较提供额外洞见。我们选取了四个模型——Grok-4、o3、GPT-5和Gemini-2.5 Flash——并使用AI评审对它们进行两两比较，以判断哪个响应更优。每次比较时，向AI评审呈现两个响应，并返回三种结果之一：A更好、B更好或平局。AI评审的直接判定与基于评分量规的评估之间的一致性百分比汇总于S3。我们观察到一致性比率介于38.3%至59.2%之间，表明基于评分标准的判断比仅凭人工智能的直接判断能捕捉更详细的信息。

用于人工智能直接判断的提示词

您是一位资深的胰腺癌医师和医学教育者，在患者沟通和医学教育方面拥有丰富经验。您的

模型	温度
GPT-5	不支持温度
GPT-4o	1
GPT-4.1	1
GPT-o3	1
GPT-o4-mini-high	1
Claude-opus-4	1
Claude-sonnet-4	1
Claude-sonnet-4.5	1
Claude-haiku-4.5	1
Claude-opus-4.1	1
Grok-4	未指定
Gemini-2.5 Flash	1
Gemini-2.5 Pro	1

表 S2：评估所用语言模型的温度设置

表 S3：不同模型对中 AI直接判断与基于评分量规的评估之间的一致性。

模型对	两者均偏好 A	两者均偏好 B	两者均打平	总体一致性-ment
GPT-5 对比 o3	31.2%	7.1%	0.0%	38.3%
GPT-5 对比 Grok-4	43.6%	0.0%	0.0%	43.6%
GPT-5 与 Gemini-2.5 Flash 对比	51.4%	0.4%	0.0%	51.8%
o3 与 Gemini-2.5 Flash 对比	57.8%	1.4%	0.0%	59.2%
o3 对比 Grok-4	47.5%	2.1%	0.0%	49.6%
Grok-4 对比 Gemini-2.5 Flash	28.7%	21.6%	0.0%	50.4%

问题：{question} 回答 A（来自 {source_a}）：{response_a} 回答 B（来自 {source_b}）：

说明：
1. 根据各项标准，仔细分析两份回答。2. 考虑回答对患者及其家属的整体质量和实用性。

必需的输出格式（JSON）：{{ “winner“: “A“或 “B“ 或 “TIE“, “confidence“: <1-5 分

G 网络搜索

对于 GPT-5、Claude-4.5 和 Gemini-2.5 pro，我们通过在 API 请求中进行配置启用了网络搜索，模型会根据提示词自动决定何时进行搜索。默认情况下，GPT 的回答会包含网络搜索结果中找到的 URL 的行内引用。评估时，我们直接将模型生成的文本作为最终回答。对于 Gemini，我们使用其 API文档中的 add_citations 函数，生成带有行内引用和可点击引用的回答。Claude 不提供此类函数。我们参考 Gemini 的 add_citations，并进行了调整，以适应 Claude API 的回答结构。我们使用基于大语言模型的评判，筛查各模型提供的所有链接，并评估其中有多少链接确实支持提示词。用于筛查的提示词附在下方。

用于检查链接相关性的提示词

% 任务定义 你是一位资深评估人员，负责判断特定 URL 是否有助于回答给定的医学问题。

2. 评估来源是否可能包含以下方面的有用信息：

- 直接回答问题 - 提供支持性证据 - 提供相关医学背景 **输出格式** 返回一个具有以

G.1 失败模式分析

我们汇总了模型未能在需要引用文献的评分标准上获得分数的原因，即使在 S4 中使用了网络搜索也是如此。

指标	GPT-5	Gemini-2.5 Pro	Claude-Sonnet-4.5
主要失败模式	缺失具体in-信息或必需链接/PMID	提供了通用的转诊链接，而非具体引文（PMID，数字对象唯一标识符等）	提供了通用的重定向链接，而非特定引文（PMID、数字对象唯一标识符等）

表 S4：网络搜索评估中的主要失败模式。

H 事实性检查

事实性检查流程可概括为以下步骤：

- (1) 我们将每条回答分解为可单独验证的逻辑原子主张；
- (2) 我们使用大语言模型评估每条主张的事实正确性；

H.1 步骤 1：分解回答

用于将回答拆分为原子主张的提示词

任务定义 从所提供的文本中生成一份可推断出的唯一原子主张列表。 ## 原子主张定义 原

详细说明 1. 从 JSON 对象中键为“text”的文本里提取主张列表。每条主张都应包含主语、宾

实际任务输入 JSON：{“text“: “

GPT-5 对问题 7 的回答

我非常遗憾您和您的亲人正在面对这一切。当标准化疗对IV期胰腺癌失效时，临床试验通常是

- NTRK融合：拉罗替尼或恩曲替尼（不限瘤种）。- BRAF V600E：达拉非尼 + 曲美替尼		-

- 与肿瘤科医生讨论其认为有助于控制症状的其他全身治疗方案。 - 考虑尽早接受姑息治疗；

GPT-5 对问题 7 的回答中的原子主张

1. IV期胰腺癌的标准化疗失效后，临床试验通常是最佳的下一步选择。 2. 目前有许多类别的

18. 对于KRAS G12C（在胰腺癌中较为罕见），阿达格拉西布或索托拉西布联合方案主要通过

45. 尽早接受姑息治疗有助于改善生活质量，在某些情况下，在寻求临床试验的同时也能延长

H.2 第 2 步：评估每项主张的事实正确性

我们使用 GPT-5 和 Gemini-2.5 Pro 作为独立的人工智能评审进行事实准确性评估，并在筛查过程中启用网络搜索。只有两种模型均判定为错误的主张，才会被标记为事实性错误。

用于检查事实性错误的提示词

```
## 任务定义
你是一名医学专家评审，负责评估原子主张是否
    包含事实准确性错误。如果一个原子主张
    包含医学上不准确或具有误导性的信息，或
    与公认的医学知识相矛盾。

## 上下文
- 问题：{question}

## 说明
1. 评估每个原子主张是否存在事实性错误
2. 考虑问题的上下文
3. 如果一项主张符合以下情况，则存在事实性错误（是）：
   - 包含医学错误信息
   - 对治疗方法作出错误陈述                    ，药物          ，或医学
    疾病
   - 提供错误的剂量、建议或医学事实

4. 如果一项主张符合以下条件，则不存在事实性错误（False）： - 包含医学上准




## 输出格式
返回一个具有以下结构的 JSON 宾语：
{{
  “评估“：  [
    {{
      “主张“: “原子主张文本“                ，
      ‘‘has_错误“: true or false      ，
      “推理“: “简要说明该主张为何存在或不存在
    事实性错误“
    }}
  ]
}}
```

```
## 待评估的原子主张 {claims_

仅返回 JSON 对象。无需补充说明。
```

H.3 使用人工智能检测事实性错误的假阳性率和假阴性率

- 对于有不同来源支持的主张，例如，一项研究报告称，胰腺癌患者的抑郁症患病率高达75%，而另一项研究报告的范围为 30-50%。如果大语言模型的回答引用或采用其中任何一个估计值，我们不会将其视为错误。
- 人工核验的所有结果均可在 https://www.notion.so/2ef548d0040980e69ffdee4756232a 查阅v=35e8c2c724714688b40f93e9613307fa.

	预测值	
实际情况	**负面（正确）**	**正面（错误）**
实际负面	30	1
实际正面	4	65

表 S5：回答事实性验证的混淆矩阵

H.4 错误主张示例

我们在 S6 中展示了模型生成的若干错误主张示例。

主张	**推理**
PALB2 突变可能会增加胰腺癌症风险，且增幅可能超过 BRCA1 和 BRCA2 突变，部分研究如此指出。	PALB2——风险为1–4%，BRCA1——风险最高为5%，BRCA2——风险最高为10%。
人激肽释放酶相关肽酶6（KLK6）是早期胰腺癌的一种潜在生物标志物。腺癌。	KLK6正在胰腺癌领域接受研究，但尚未被证明是早期疾病的生物标志物。
控制2型糖尿病可以降低您患胰腺癌的风险。	目前尚不清楚是哪种疾病导致了另一种疾病，也不清楚它们是否有相似的潜在原因。
CDKN2A 突变可能会影响胰腺癌的治疗选择。	目前没有基于 CDKN2A 突变的特定治疗方-法。这可能对癌症筛查产生影响。

表 S6：错误主张示例

H.5 更多结果

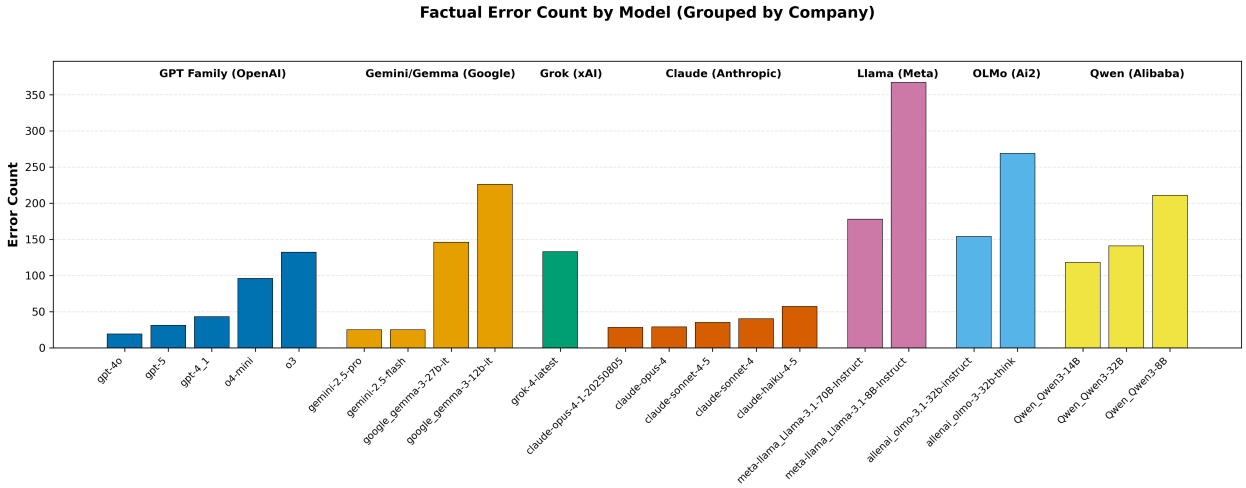

图 S3：按模型统计错误主张数量的条形图

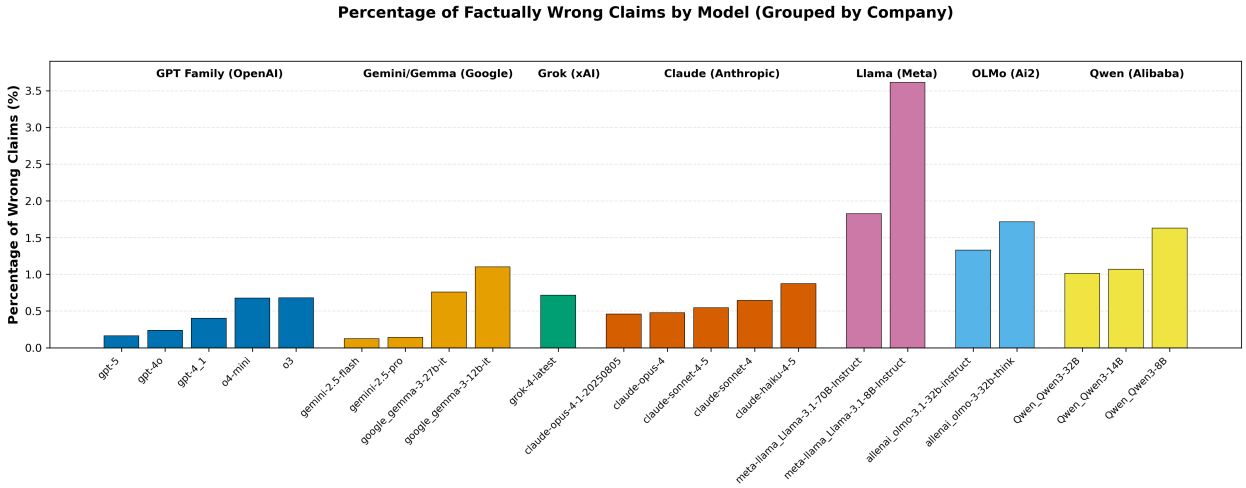

图 S4：按模型统计错误主张的百分比

I 合成评分标准

为确保比较公平，我们向大语言模型提供了与人类专家相同的信息，包括《评分标准设计指南》以及 Grok-4、GPT-4.1、Llama-3.1-8B 和 Olmo2-13B 的回答，以生成合成评分标准。

生成合成评分标准的提示词

```
## 提示词
```

你是设计评估标准的专家，负责评估针对胰腺癌患者问题的人工智能生成的回答。以下是你必

J 令牌使用量分析

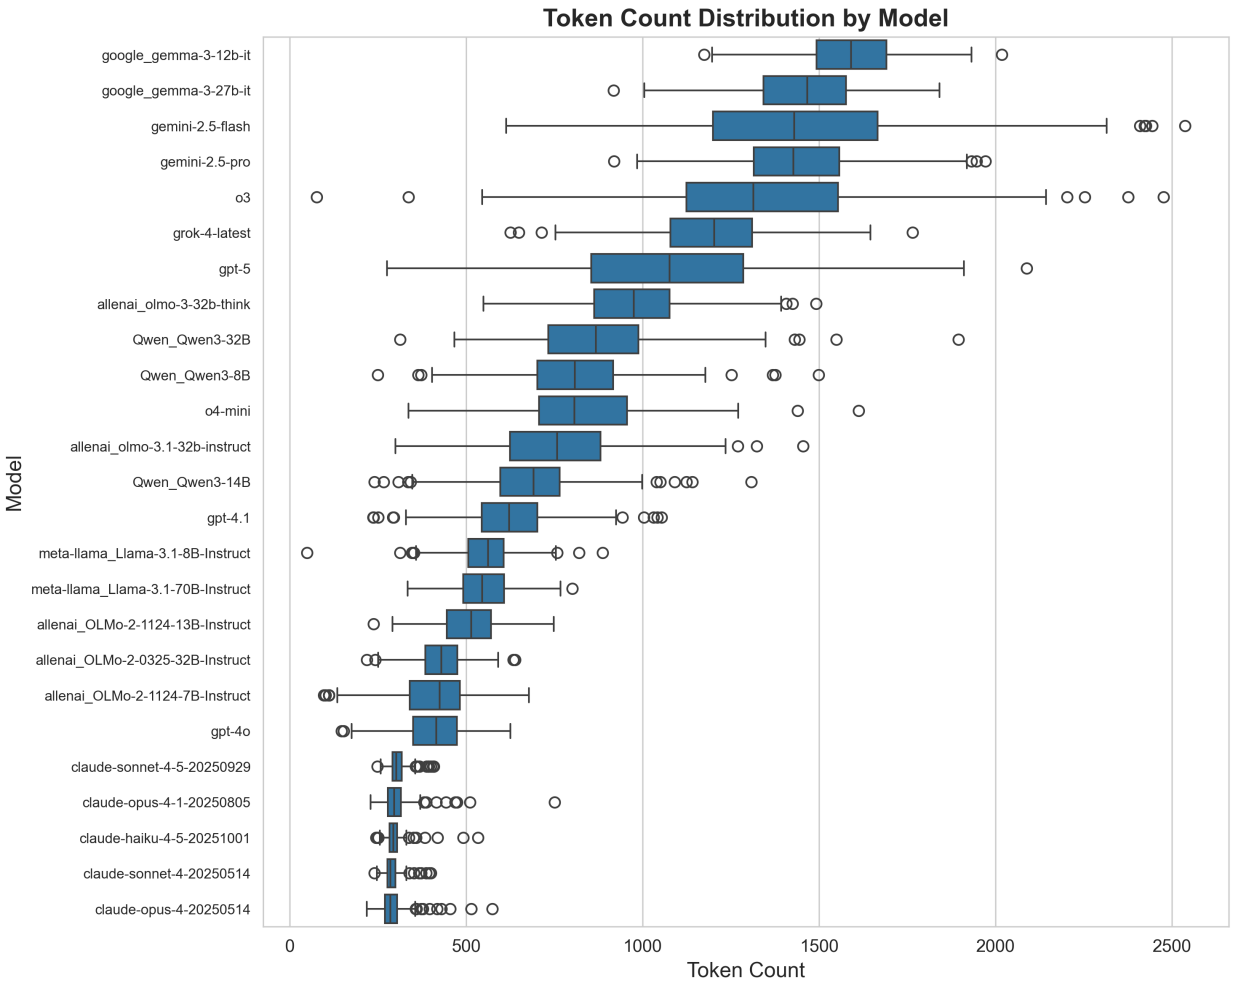

图 S5：各模型的令牌数量分布