

优中选优，金融大模型的优化演进

王述 | 奇富科技

科技生态圈峰会 + 深度研习



—1000+ 技术团队的选择



 **K+峰会**  **敦煌站**

K+ 思考周®研习社

时间: 2025.08.29-30

 **K+峰会**  **上海站**

K+ 金融专场

时间: 2025.10.17-18

 **K+峰会**  **香港站**

K+ 思考周®研习社

时间: 2025.11.25-26



K+峰会详情



 **AiDD峰会**  **上海站**

AI+研发数字峰会

时间: 2025.05.17-18

 **AiDD峰会**  **北京站**

AI+研发数字峰会

时间: 2025.08.08-09

 **AiDD峰会**  **深圳站**

AI+研发数字峰会

时间: 2025.11.28-29



AiDD峰会详情



王 述

奇富科技资深算法专家

奇富科技大模型部资深算法专家，语言模型组负责人，主要负责内部金融大模型的研发工作及相关应用的落地。曾在百度、字节跳动任职，并主导语言模型和知识图谱相关项目的研发，在大语言模型、多模态语义理解和知识图谱等技术领域有深入的研究与丰富的实战经验。

目录

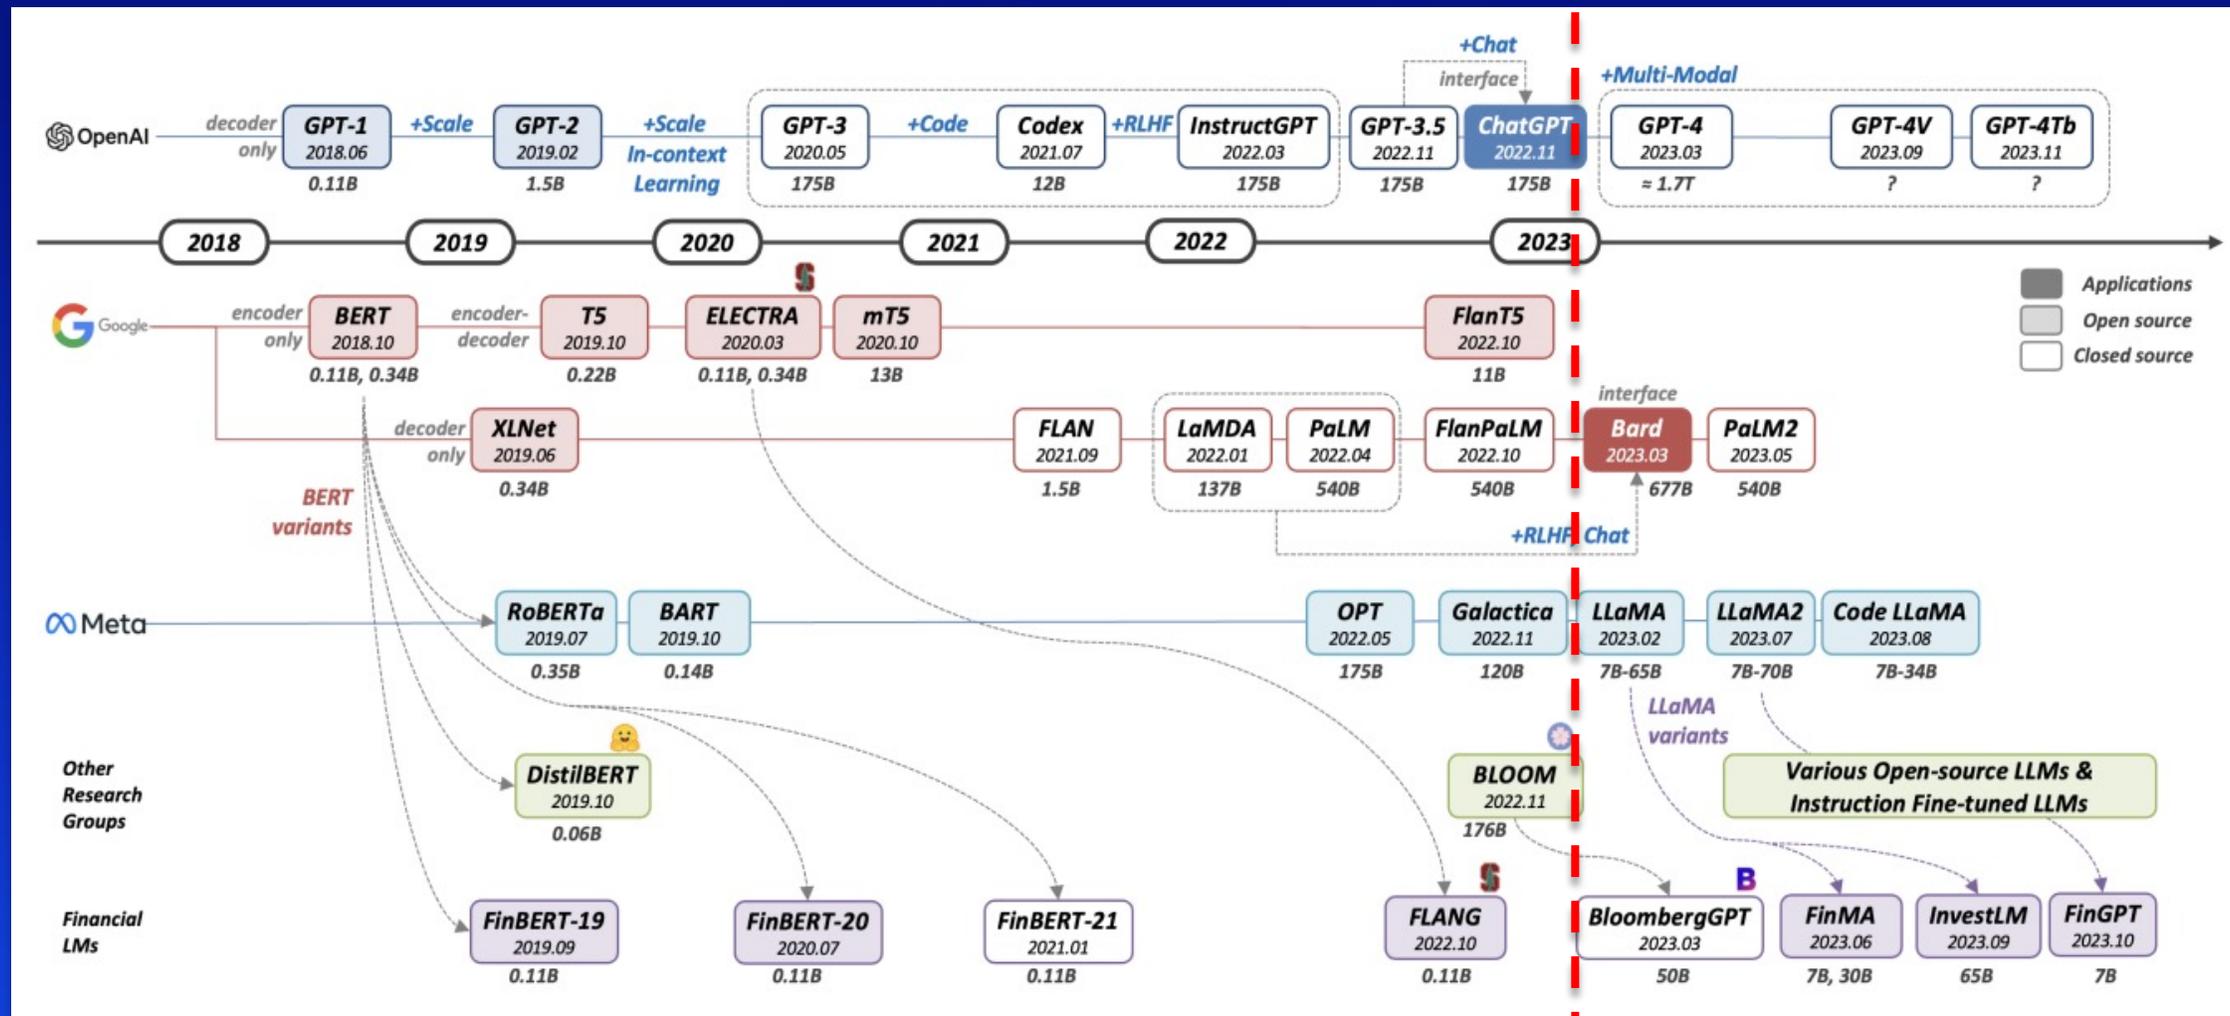
CONTENTS

1. **发展背景：从通用到金融**
2. **研发流程：多阶段知识增强**
3. **优化策略：深入理解问题**
4. **应用实践：奇富 Copilot**

PART 01

发展背景：从通用到金融

▶ 演进历程：从通用模型到金融模型



通用模型能力涌现 金融模型能力深耕

大模型明确的技术能力

复杂信息处理能力

- 基于Transformer架构的大模型具有大规模参数和强大的数据处理能力，广泛应用于自然语言处理、计算机视觉和知识图谱问答。其自注意力机制能够高效捕捉长距离依赖，处理非结构化数据，实现复杂语义的精准理解与表达。

大模型的性能跃升

- 随着模型规模的扩大，性能在突破关键阈值后显著提升，模型在处理多样化任务的表现增强。模型从而能够为用户提供基于原始数据和历史经验的创新性解决方案，并且具备更强的上下文学习能力、应用泛化能力以及复杂任务解决能力。



金融数智化发展需求

海量/复杂/异构的数据需求

- 金融行业作为数据和信息高度密集型的产业，对于多渠道信息的汇总与处理能力具有极高要求。金融市场波动频繁，数据的实时处理和分析至关重要，且数据间通常包含复杂的关联和动态变化，金融机构需要强大的数据处理能力

复杂决策判断需求

- 金融行业的业务场景对从业者的要求极高，不仅需要扎实的专业知识，还要有丰富的实践经验。面对复杂的市场环境，从业者必须具备快速、精准的判断能力。同时，高质量的代码和文案输出在金融科技领域也变得不可或缺，技术和业务紧密结合已成为应对行业变化的关键。

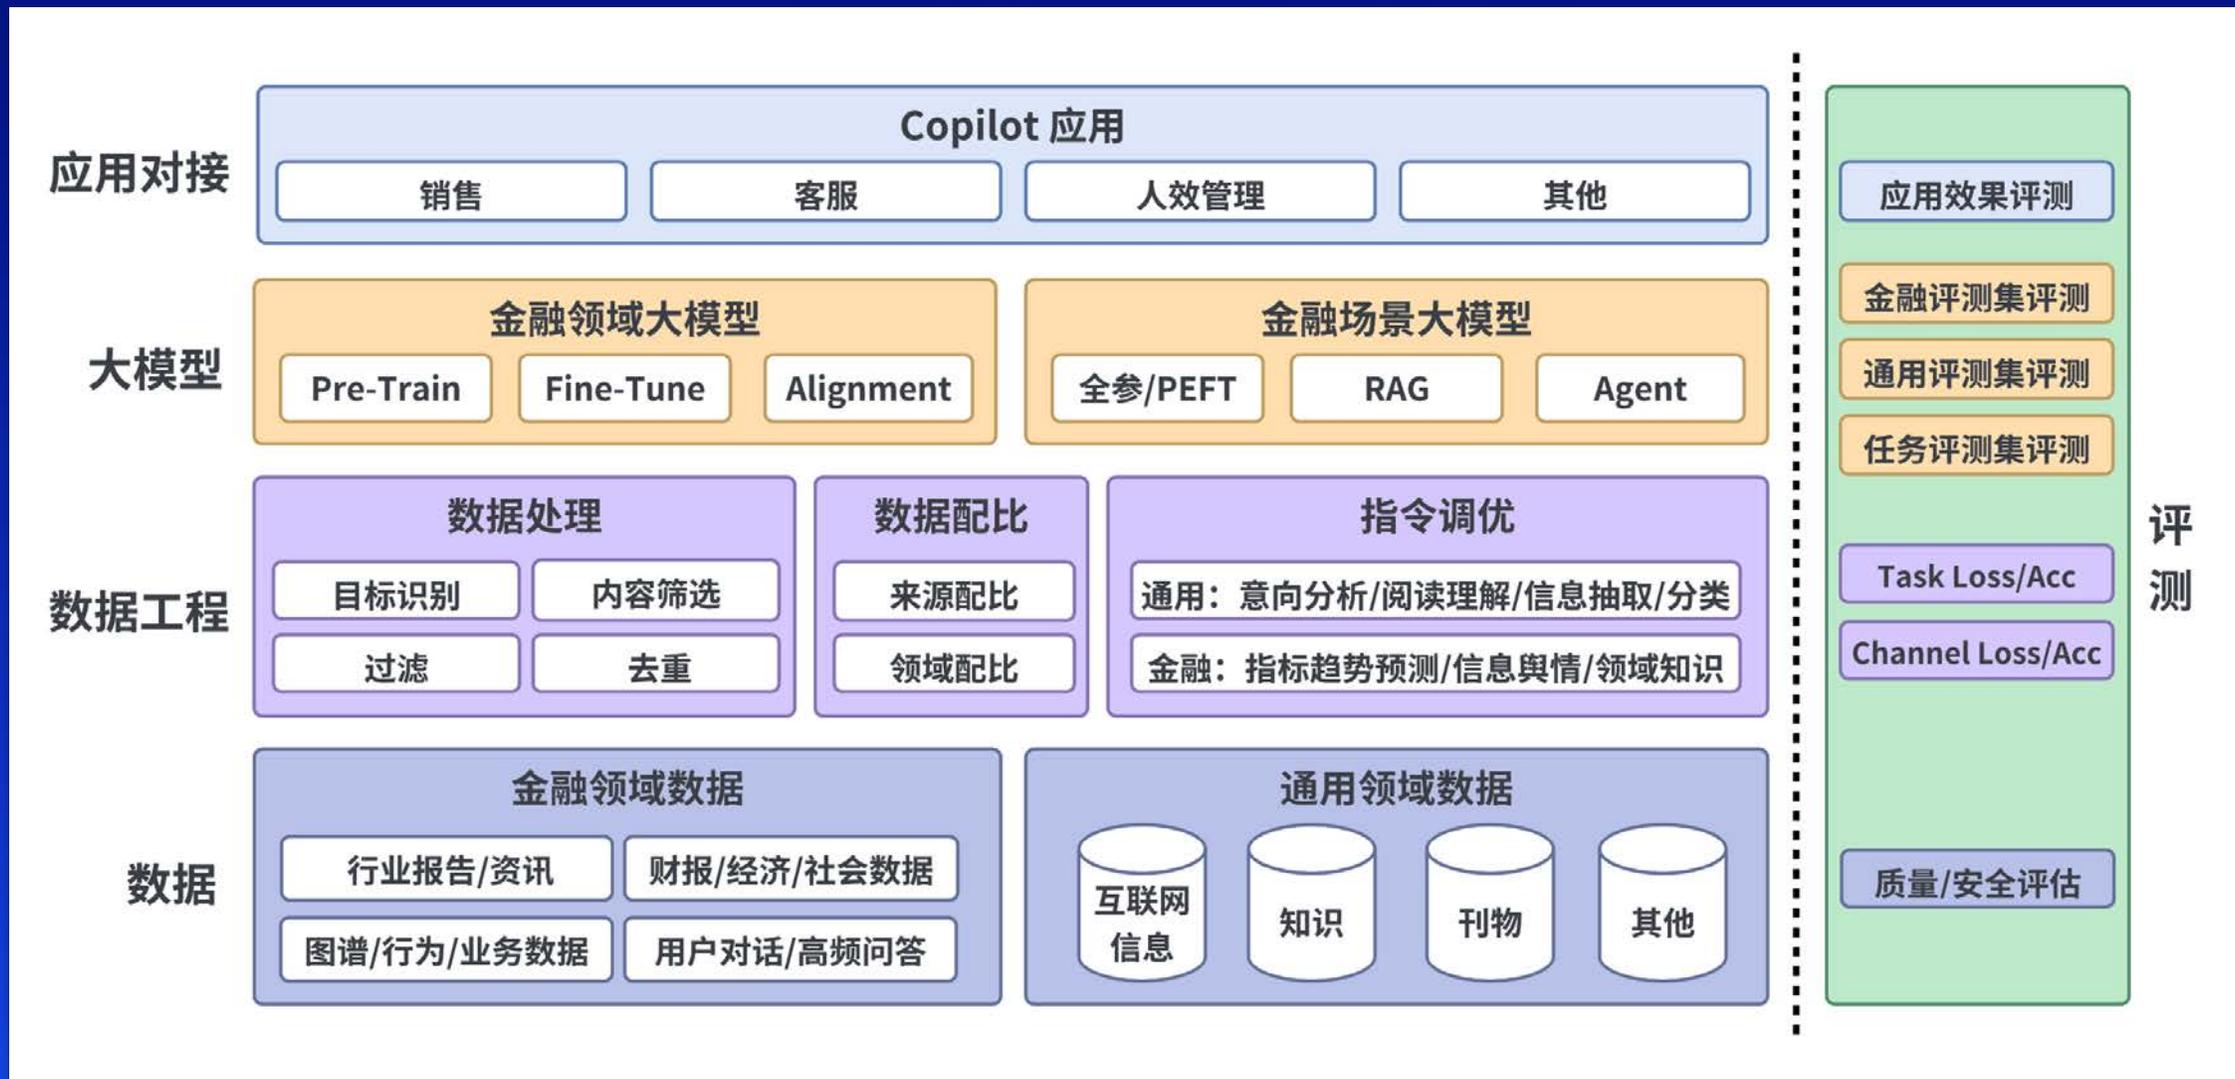
痛点与挑战

通用大模型由于在专业的金融知识方面存在欠缺，在一些特定金融任务上的解决能力不足，无法满足金融行业的需求。并且通用模型的训练及运营成本较高，难以在金融行业进行大规模落地应用。

PART 02

研发流程：多阶段知识增强

研发架构：领域通用与场景适配结合

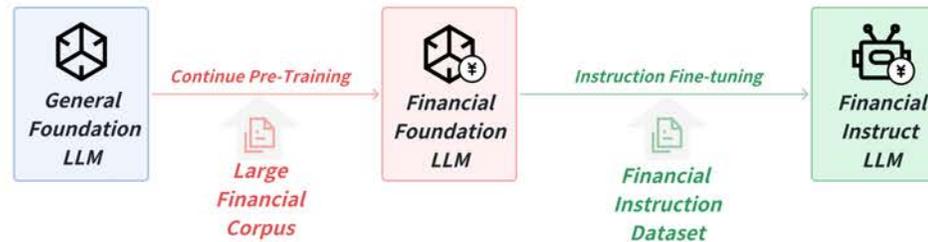


金融大模型研发的四种范式

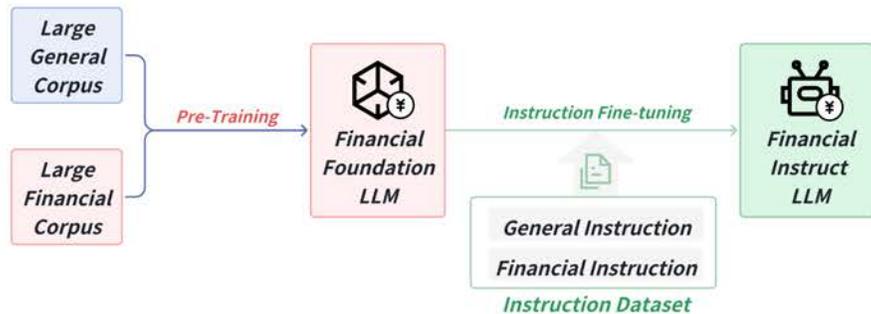
Domain Instruction Fine-tuned



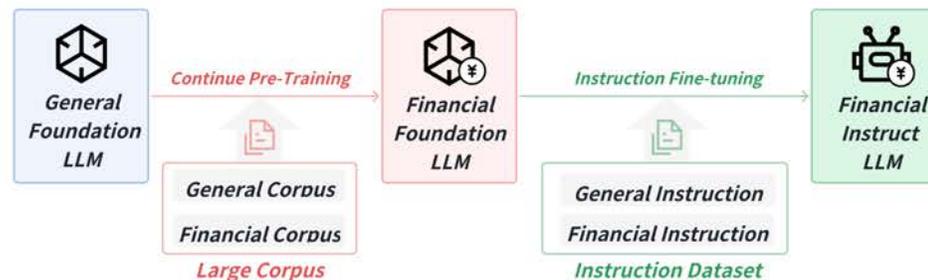
Domain-Specific Continued Pre-Training



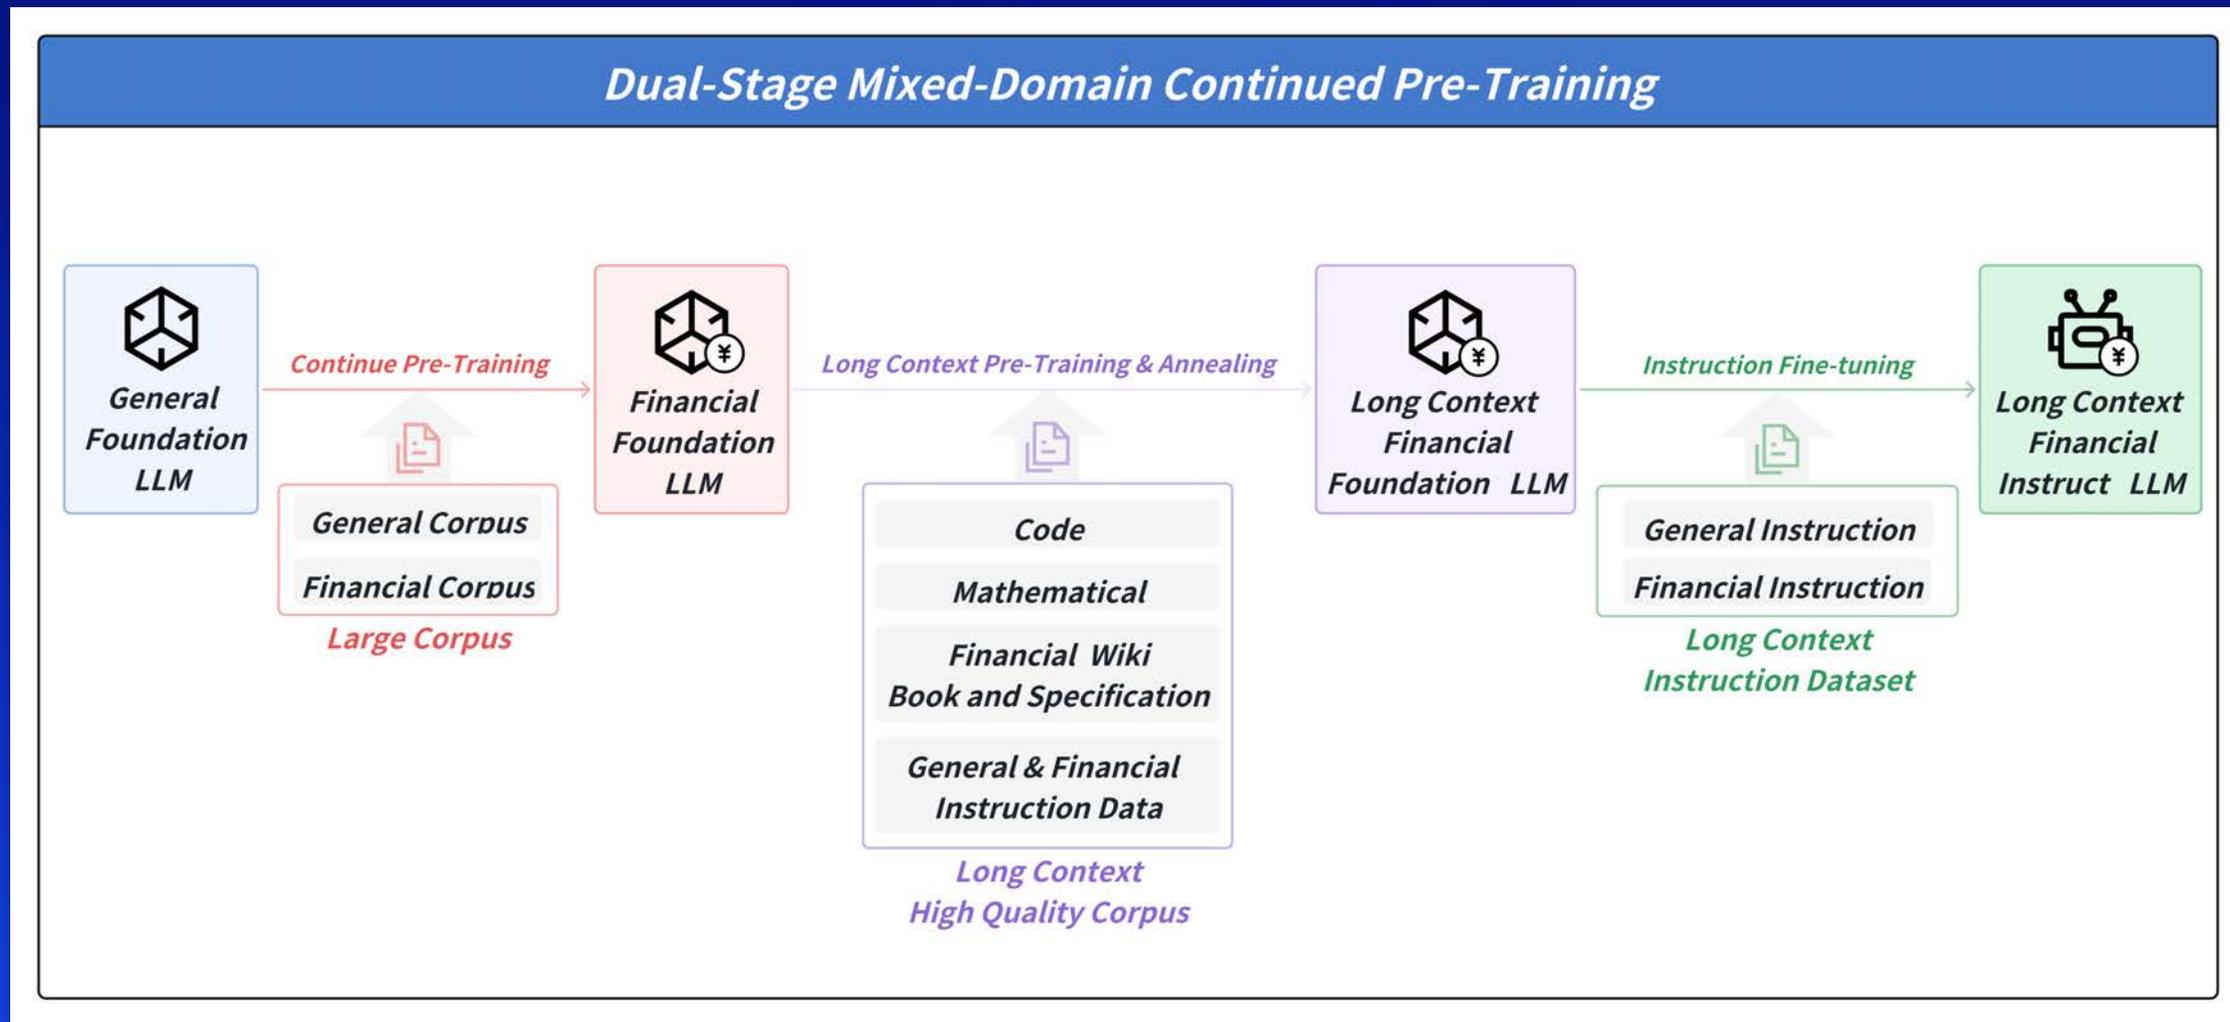
Domain Pre-Training from Scratch



Mixed-Domain Continued Pre-Training

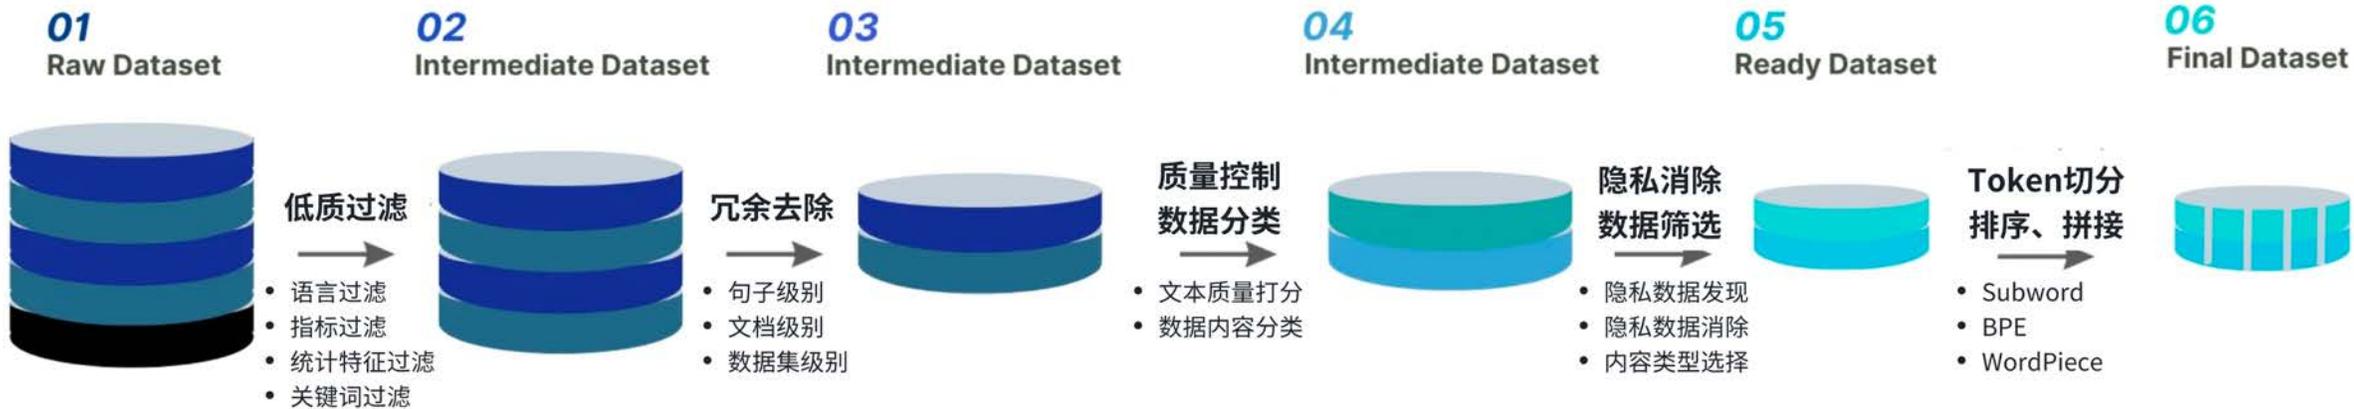


▶ 专业金融知识注入，多阶段知识增强



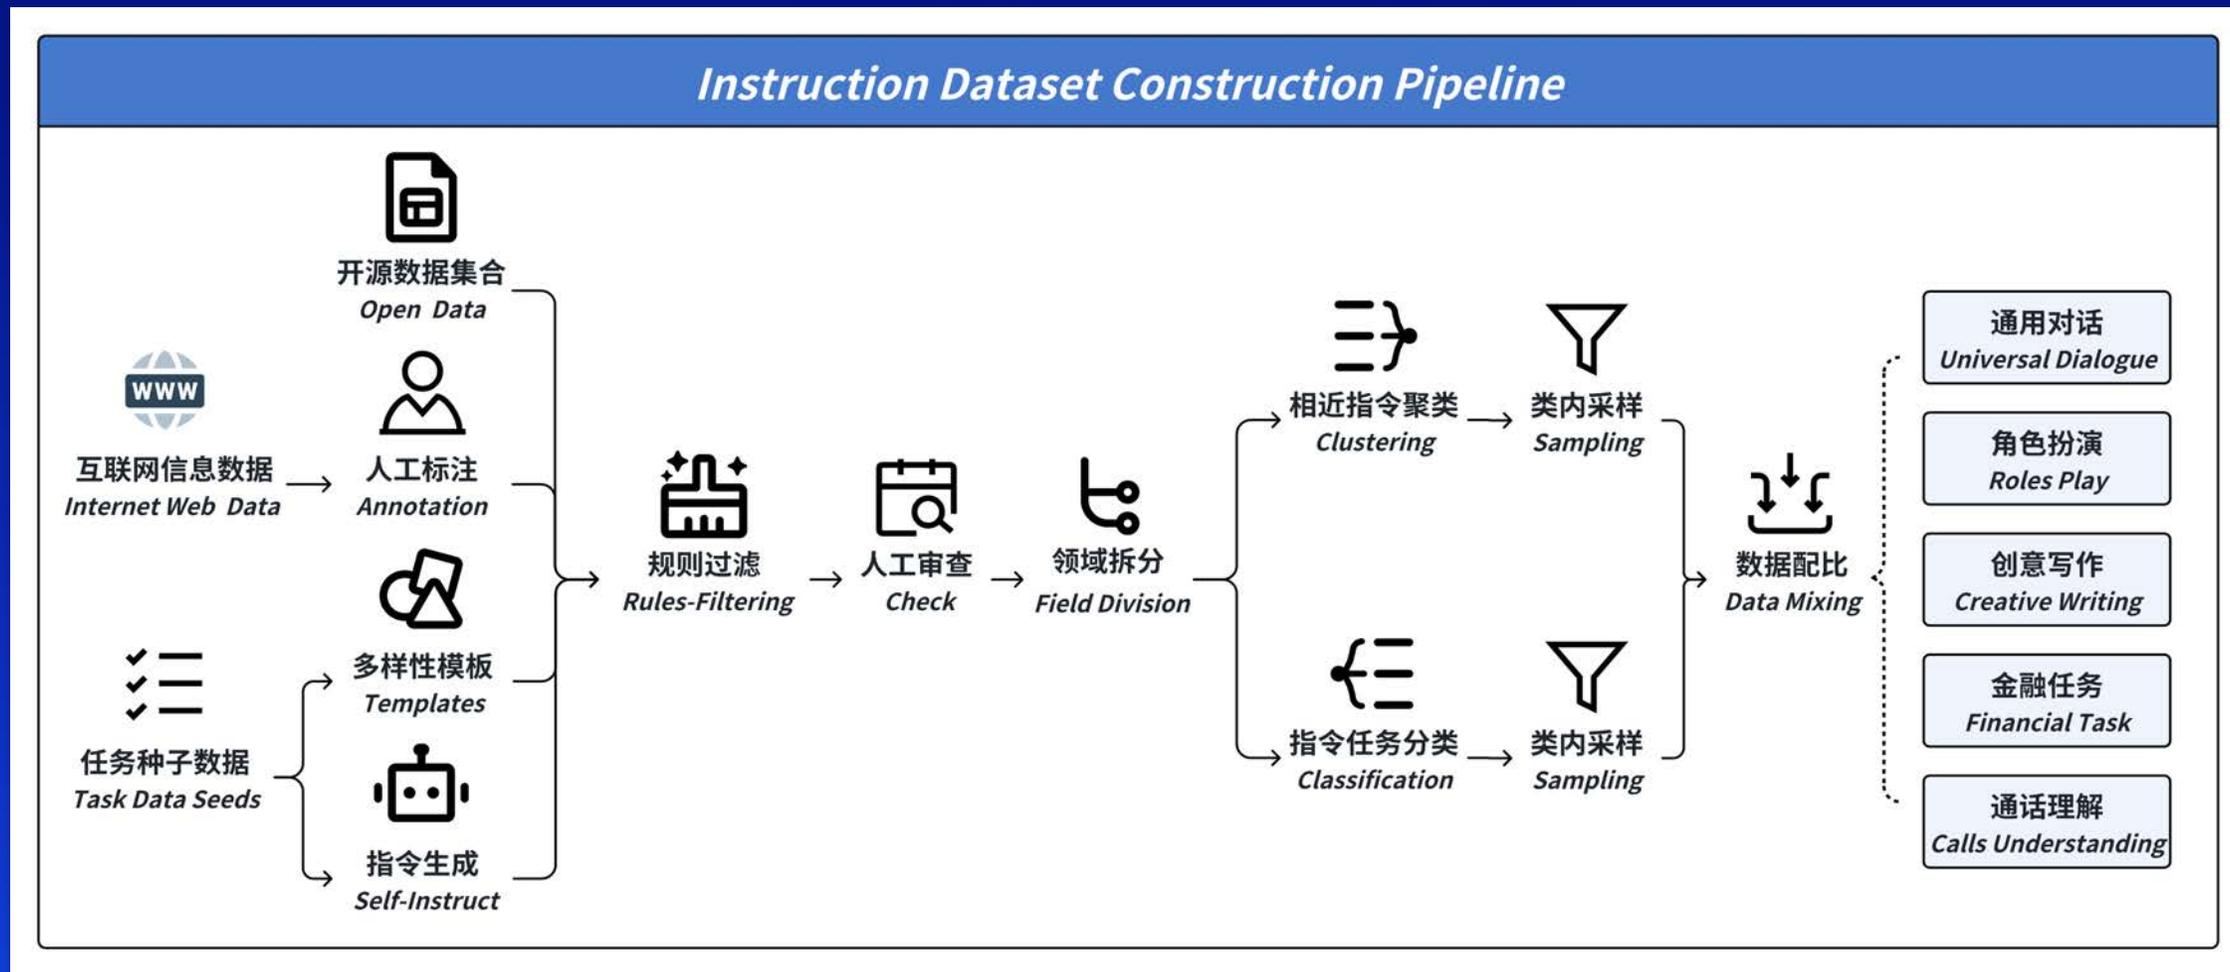
▶ 数据准备：数据质量是高性能AI的地基

半自动化的通用语料数据处理 Pipeline



覆盖多种数据来源，多种清洗策略组合的标准化数据处理流程；语料 badcase 率从 40% 下降至 5% 左右

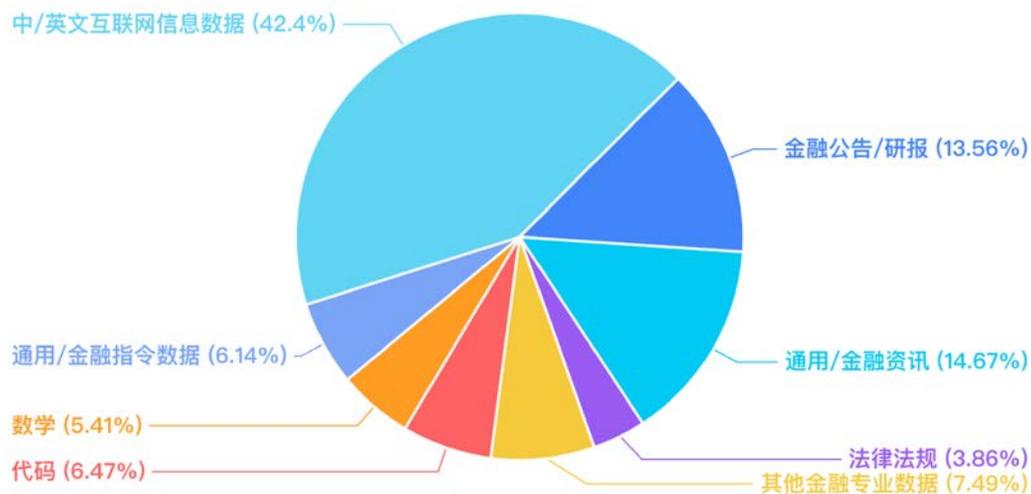
数据准备：高质量多样化的指令数据



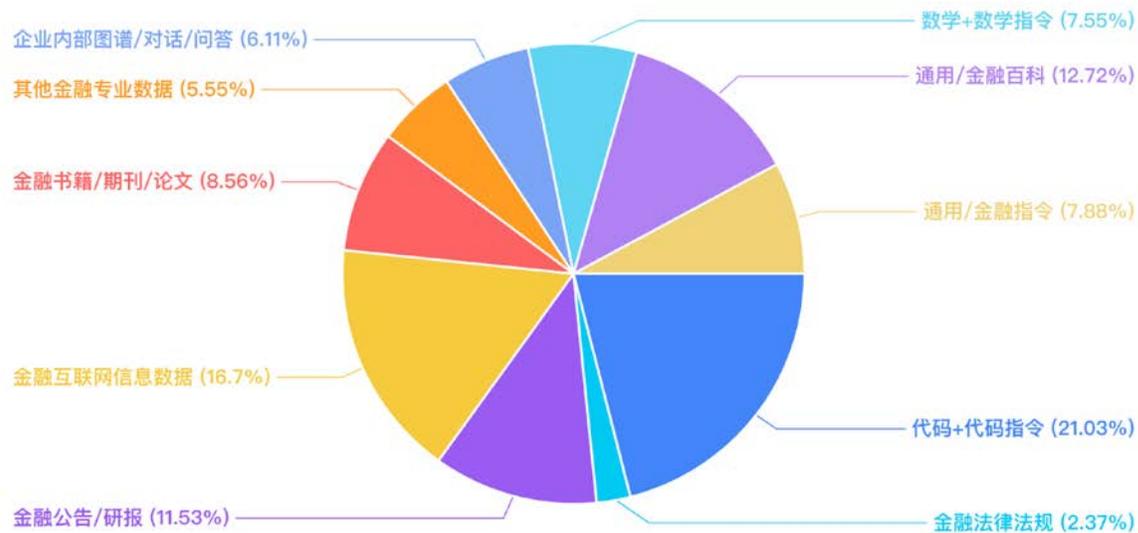
不同任务、来源、形式的数据混合在低样本资源场景下的效果提升会更加显著，数据量会直接影响模型效果

▶ 增量预训练：合适的数据及配比是关键

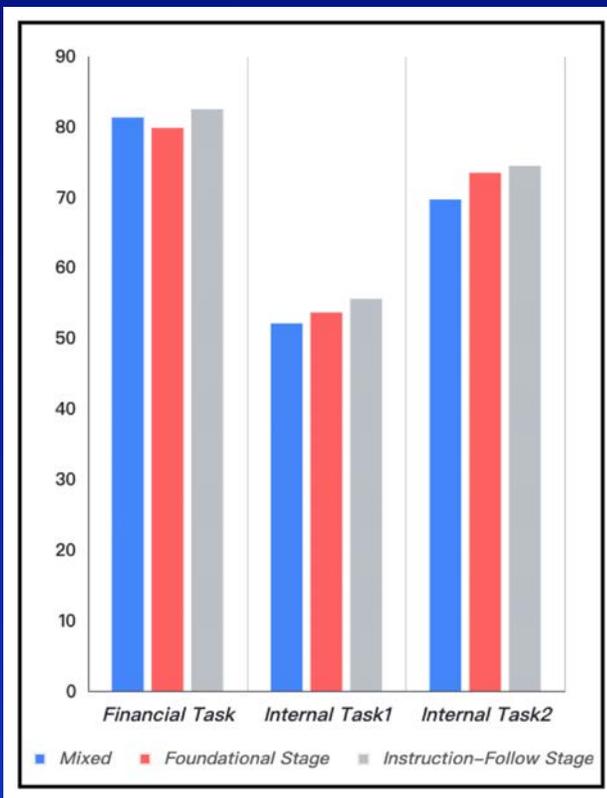
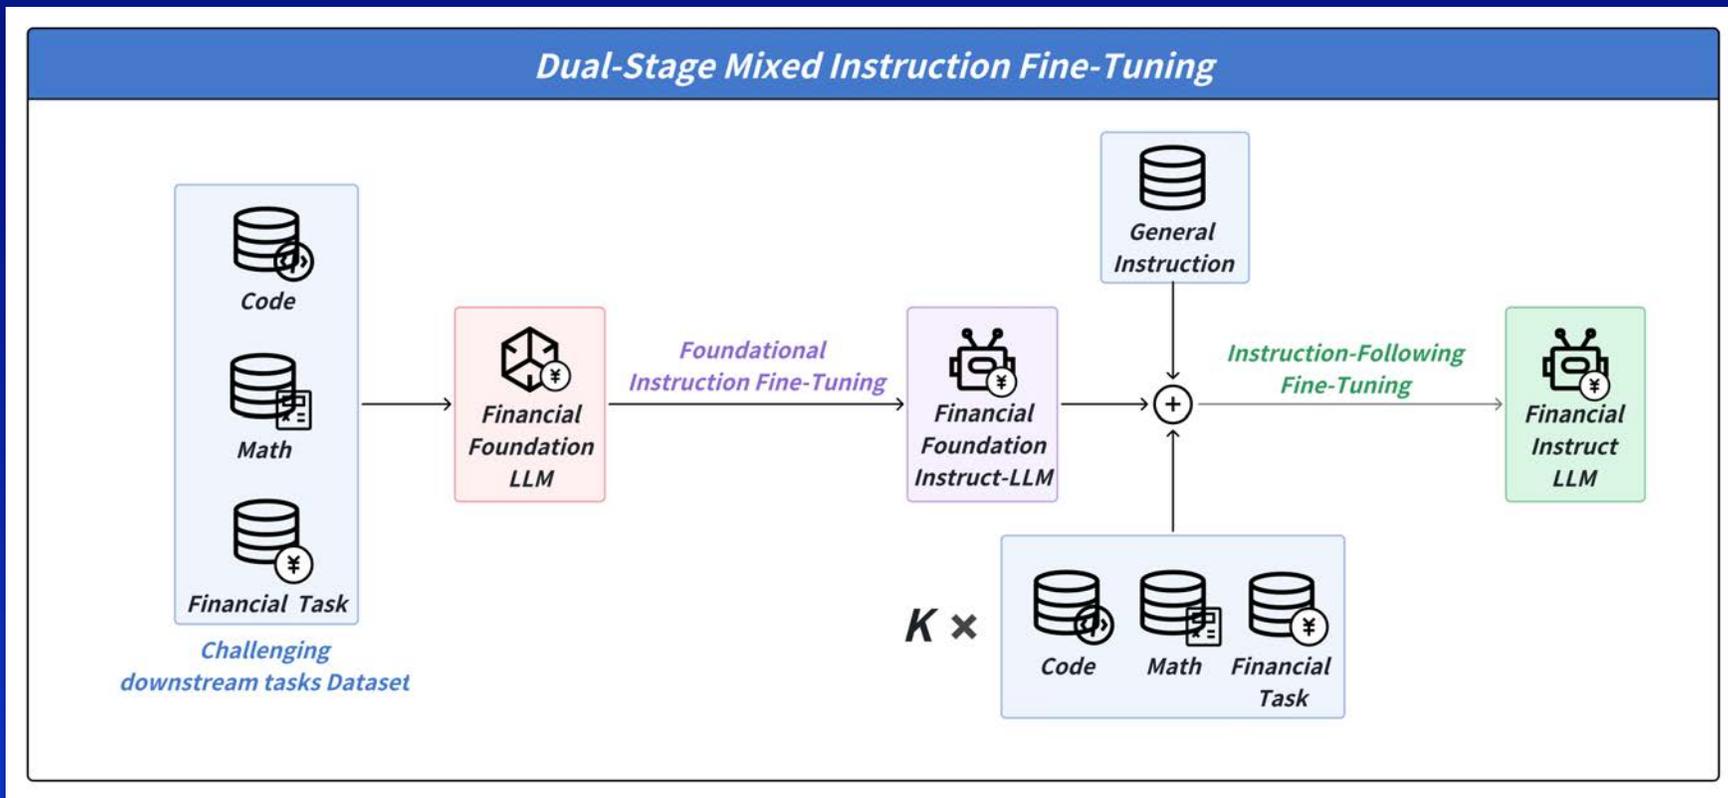
Data Mixture of Stable Stage



Data Mixture of Annealing Stage

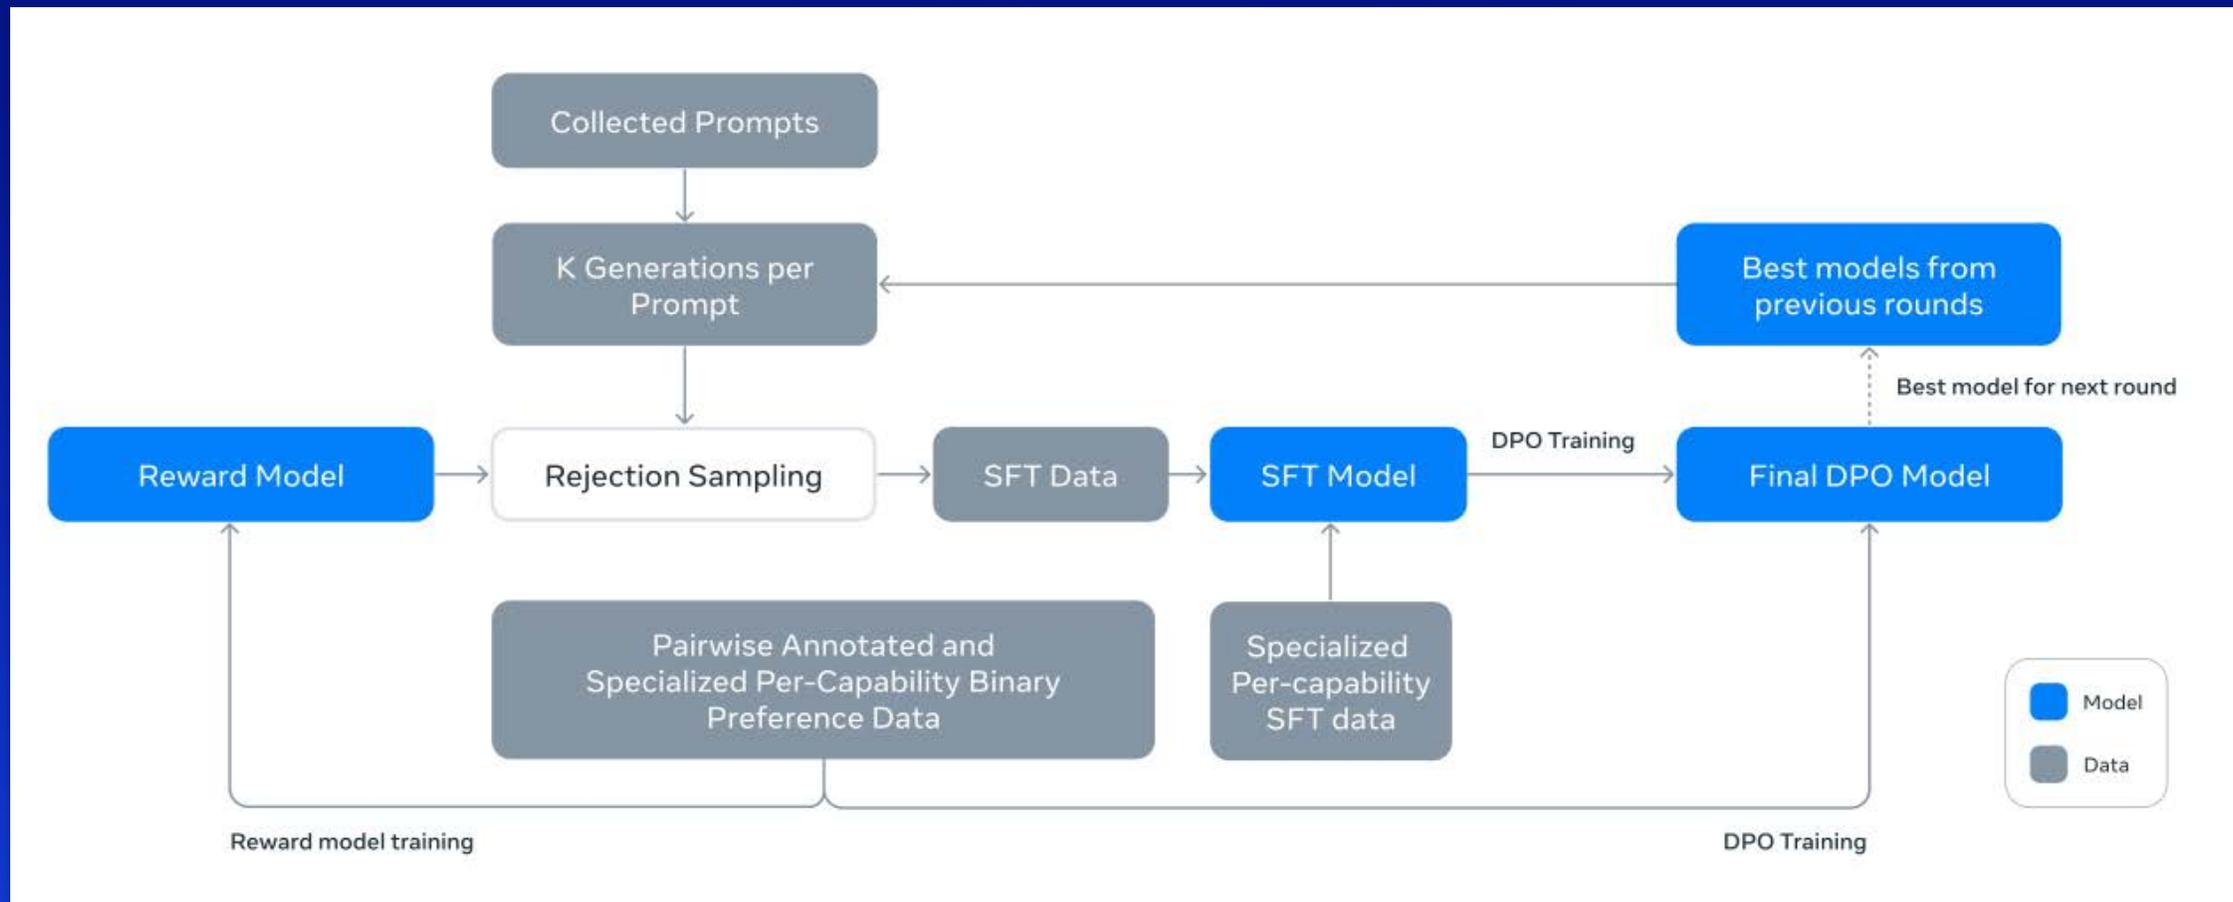


▶ 两阶段指令微调：缓解任务冲突



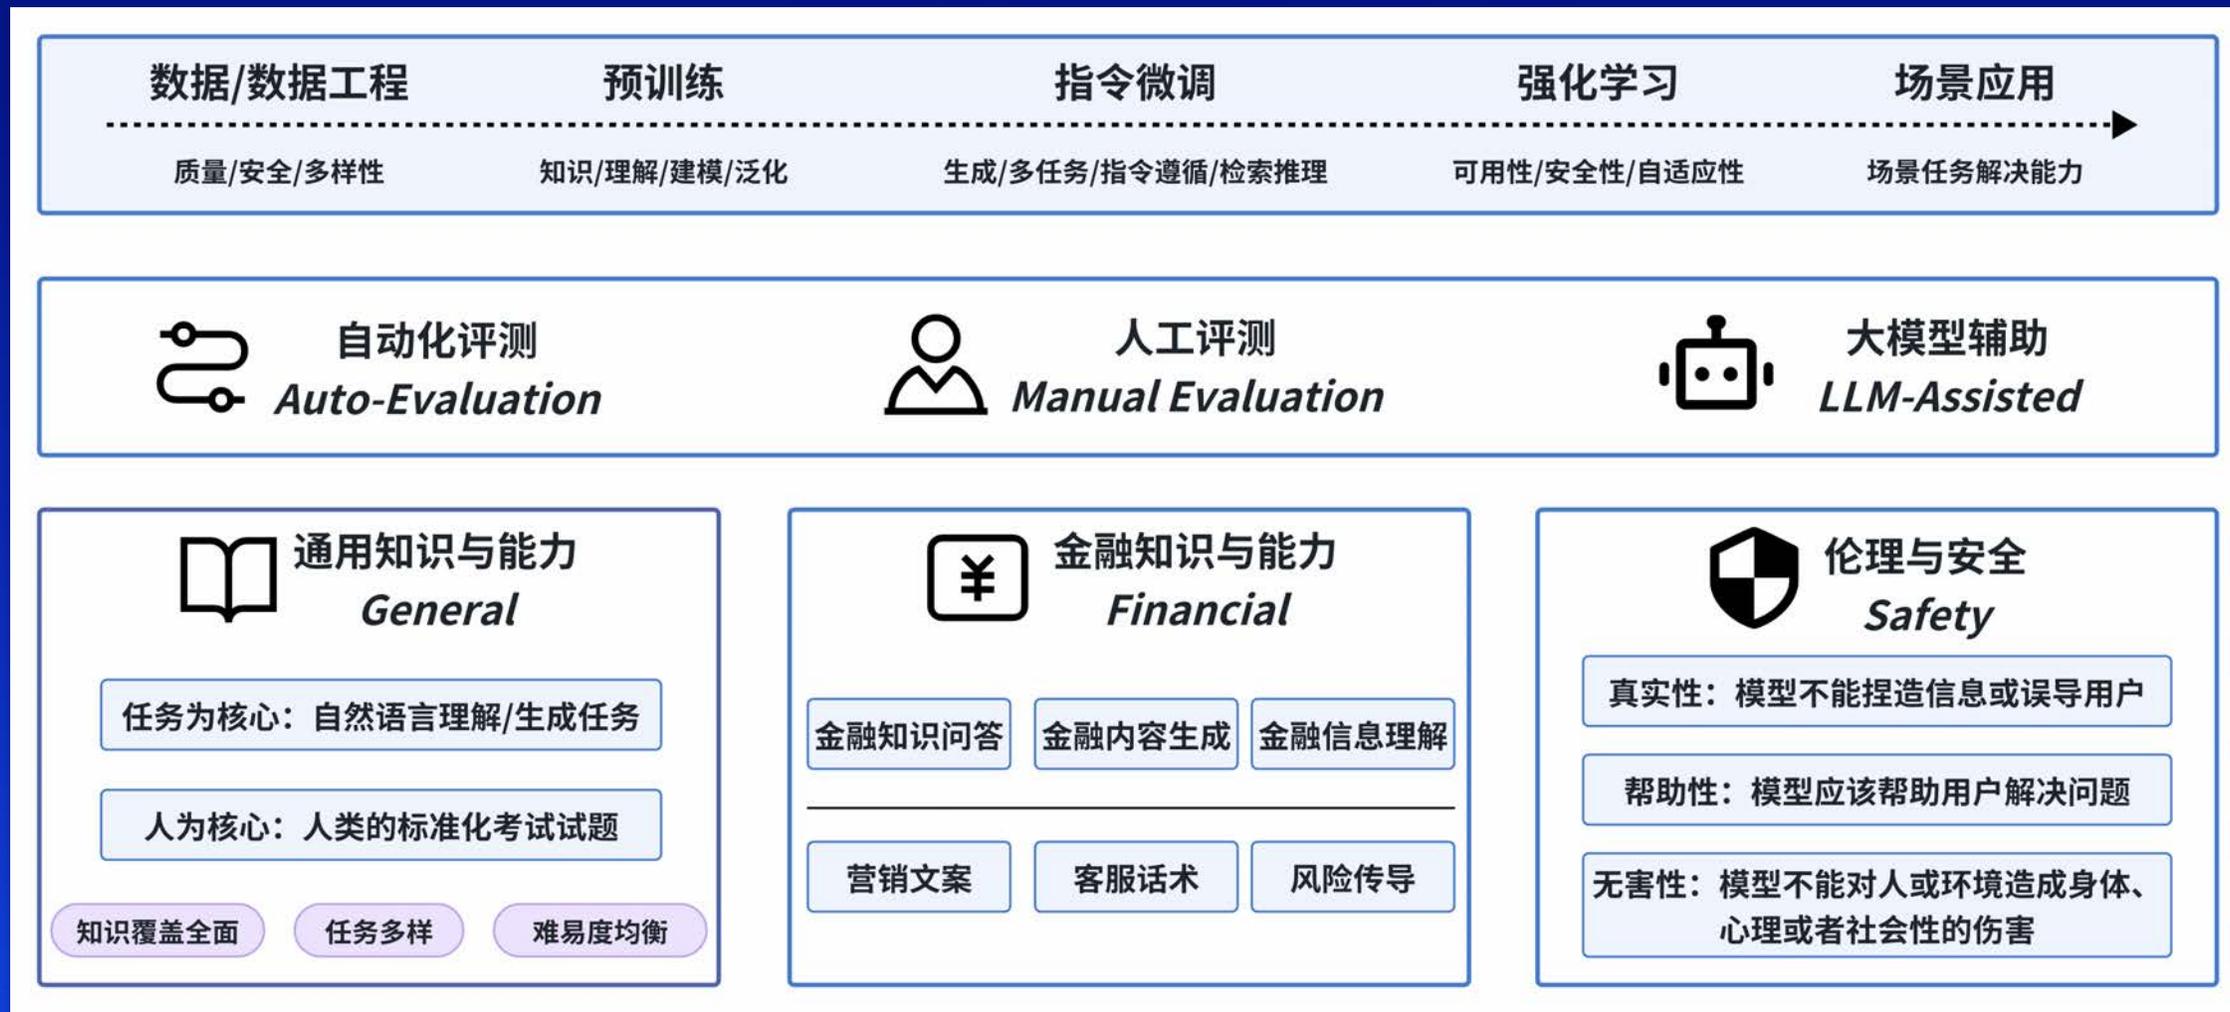
不同 SFT 任务的数据混合可能会出现效果冲突的现象，DMT 策略可以有效缓解任务冲突，提升效果
任务解决及指令遵循能力仍然需要一定数量的高质量标注数据

偏好对齐



如果 SFT 的模型效果不佳时，再进行 DPO 等强化学习优化操作，效果不会理想甚至可能是负向优化

覆盖全面的大模型评测框架



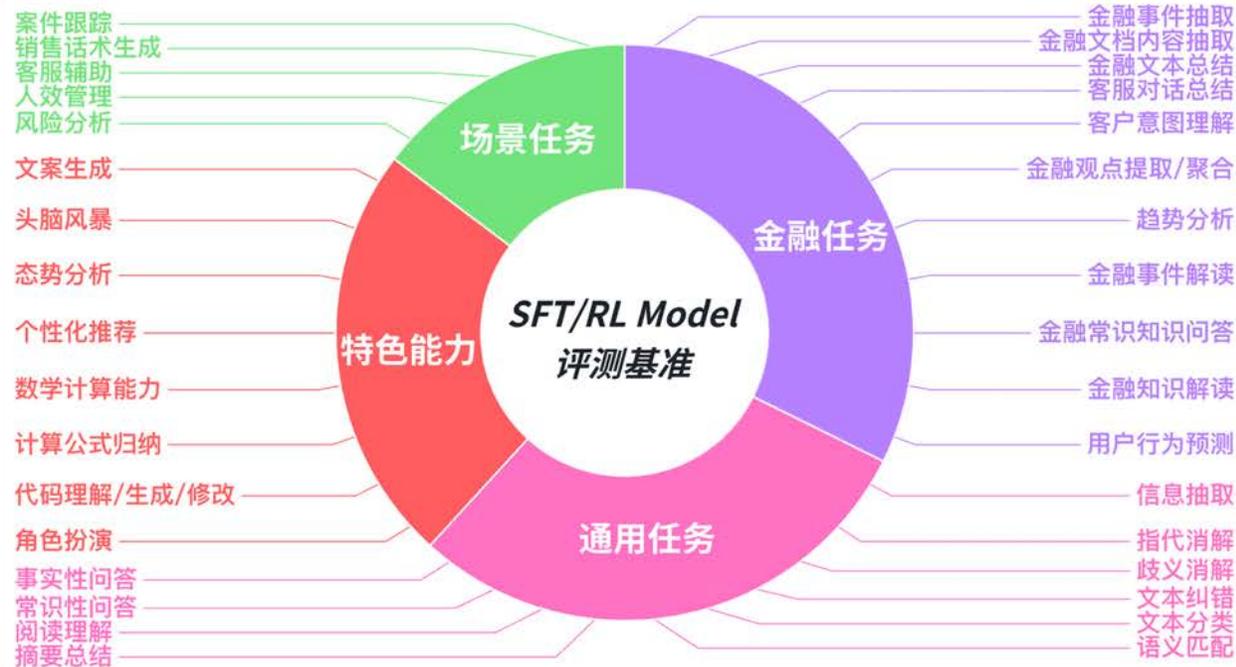
金融大模型训练各阶段的评测目标不同，不同领域/场景的任务多样化，且需要针对社会层面的潜在风险进行评估

挖掘大模型真实能力的评测体系

开源Benchmark, 选择题为主



开源评测数据集采样、重标注及 Prompt 重构, 问答题为主



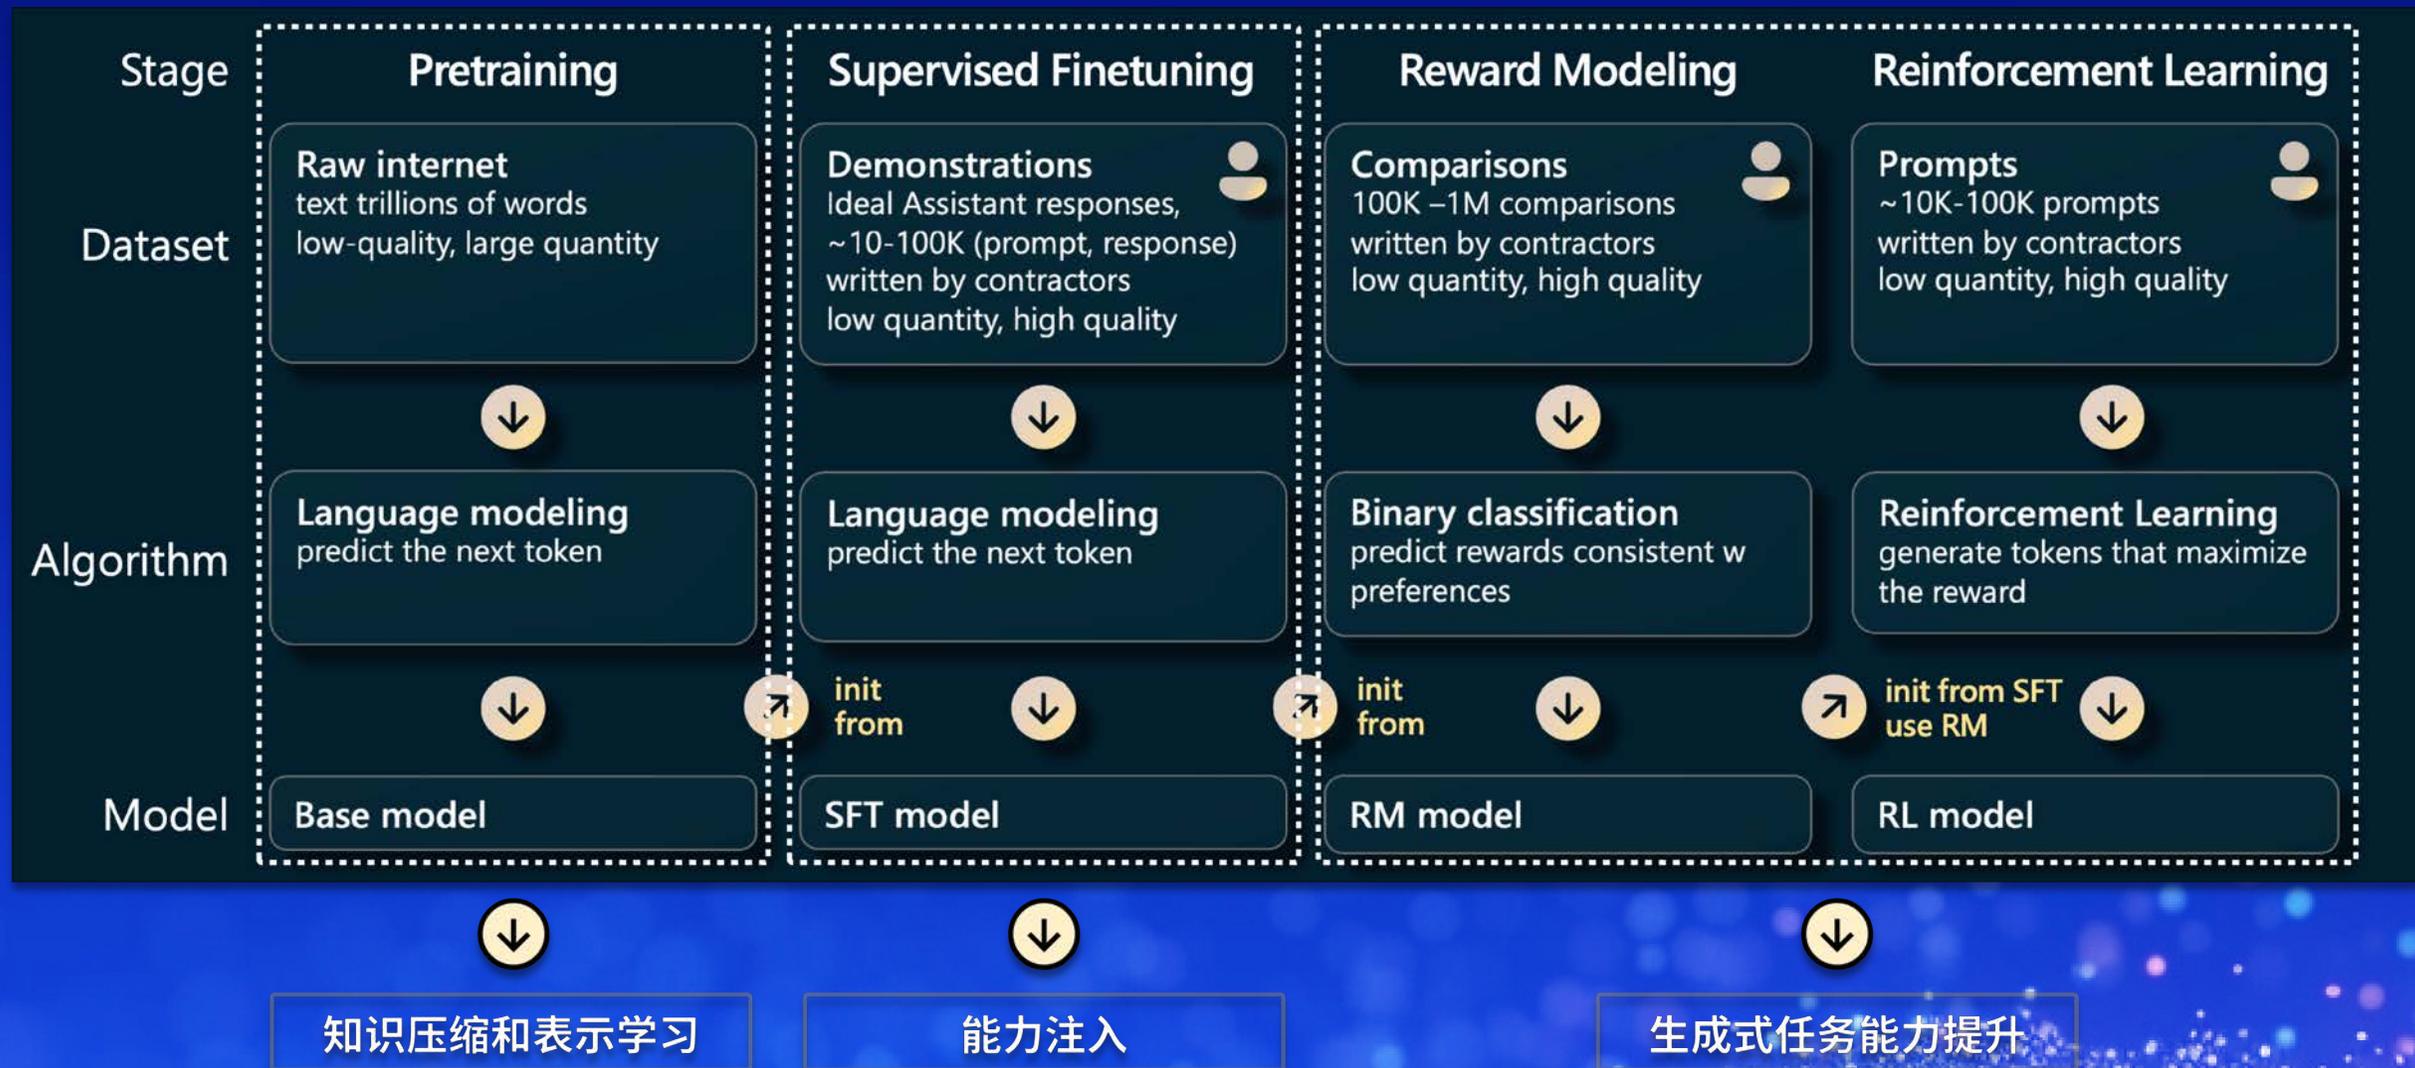
选择题一般仅能反应模型在语言理解和知识储备上的能力, 无法评估模型的问题解决能力

开源任务评测数据集标注质量参差不齐, 无法真实有效的评估模型的任务解决水平

PART 03

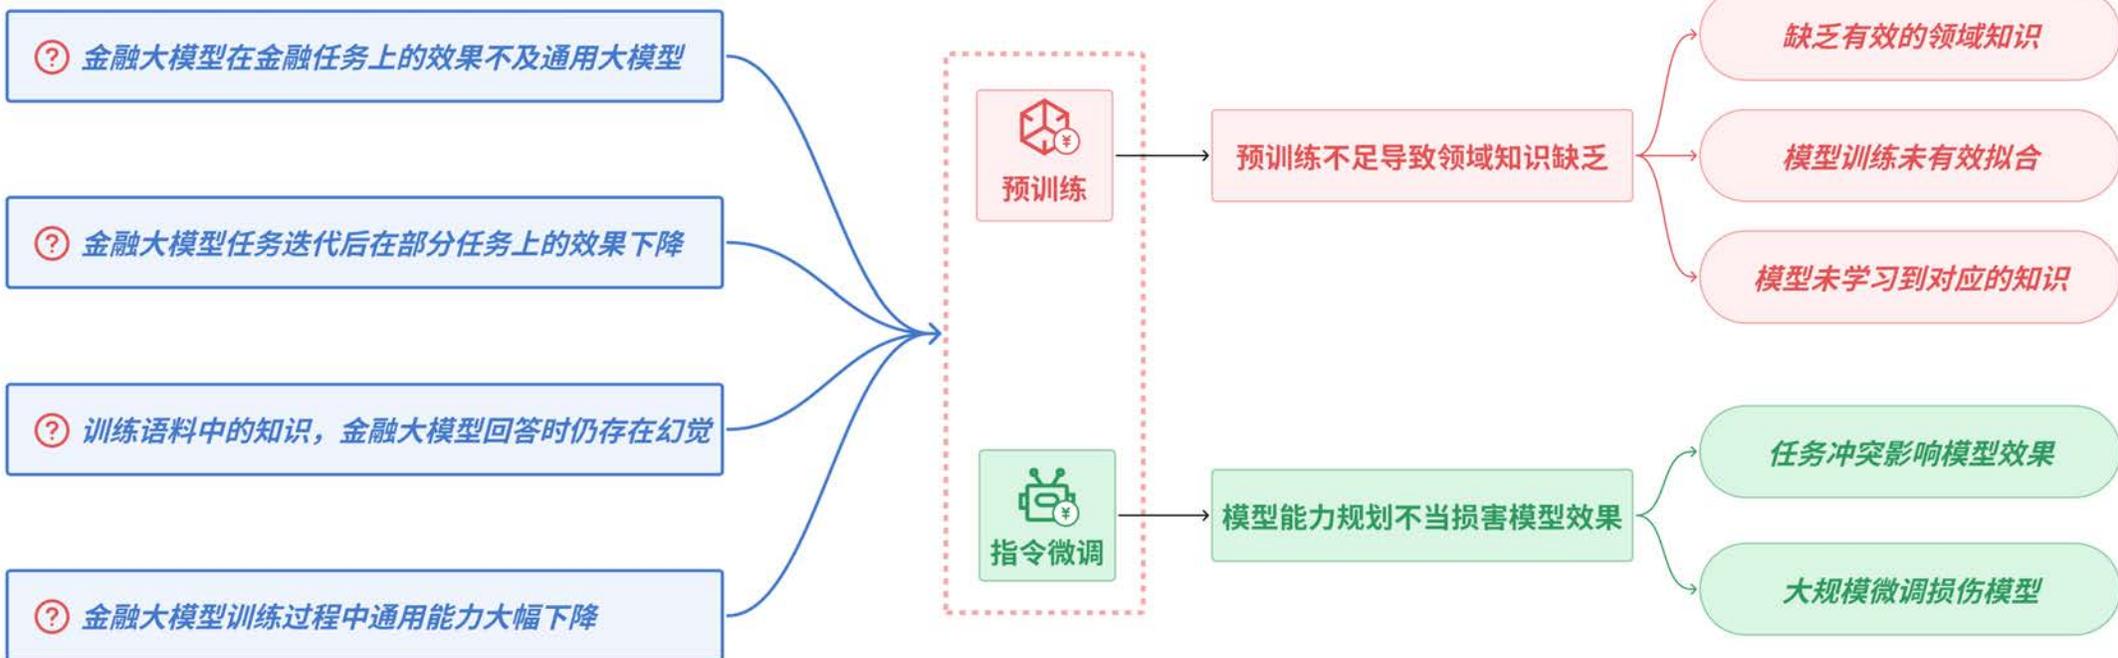
优化策略：深入理解问题

▶ 不同阶段大模型获取的能力不同



► 深入理解问题，定位问题根因

深入理解问题本质，精准定位问题根因



▶▶ 预训练缺乏有效的领域知识

金融百科、学术论文、教材、期刊、金融产品说明与合约、企业培训材料等；这些来源详细介绍了**金融领域的基础知识、模型和方法**

金融术语知识

金融监管政策、法律文件、央行指令、行业标准及白皮书等；这些来源详细介绍了**金融合规知识、法律知识、行业经验及一些隐含的金融规则**

法律法规与监管文件

金融报告与分析文件

上市公司的年度报告、财务报表、审计报告、分析报告等；这些文件中包含**大量的财务数据和术语**，还隐含了**市场环境、行业动态等背景信息**

市场经济分析与预测报告

宏观经济预测、行业分析报告、投资策略报告等；这些报告通常包含**市场走势、经济政策、国际形势变化等预测**。分析和报告中涉及大量的**经济学知识、统计分析方法、经济原理等**

高重量的知识密集型数据是领域预训练的关键

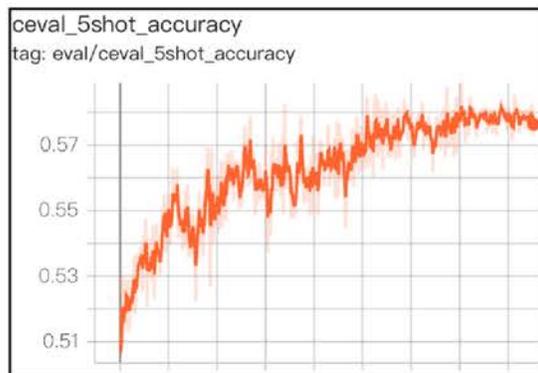
► 预训练并未有效拟合领域知识

多维度监控保障训练有效性

任务维度曲线实时监控

训练流程中集成自动化评测流程

语言理解: *C3*、*FlagEval*
知识能力: *CommenseQA*
学科能力: *C-Eval*、*CMMLU*
计算能力: *MATH*、*GSM8K*
代码能力: *Humaneval*
金融能力: *FinancelQ*、*FinEval*



多任务评测指标判断模型训练是否有效

Loss

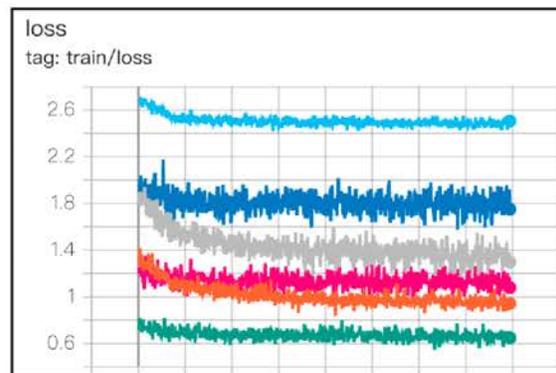
PPL

Accuracy

数据维度曲线实时监控

多领域数据训练拟合独立分析

知识数据: *百科*、*书籍*、*论文*...
代码数据: *源代码*、*代码生成/纠错*...
数学数据: *科学计算*、*数学应用题*...
金融数据: *财报*、*研报*、*公告*...
通用数据: *中英文网页*、*资讯*...
指令数据: *通用指令*、*金融指令*...



多领域数据拟合曲线判断数据源、配比是否合理

预训练并未有效拟合领域知识

高质量数据退火有效提升榜单效果

The Llama 3 Herd of Models

3.1.3 Annealing Data

Empirically, we find that annealing (see Section 3.4.3) on small amounts of high-quality code and mathematical data can boost the performance of pre-trained models on key benchmarks. Akin to Li et al. (2024b), we perform annealing with a data mix that upsamples high-quality data in select domains. We do not include any training sets from commonly used benchmarks in our annealing data. This enables us to assess the true few-shot learning capabilities and out-of-domain generalization of Llama 3.

Following OpenAI (2023a), we evaluate the efficacy of annealing on the GSM8k (Cobbe et al., 2021) and MATH (Hendrycks et al., 2021b) training sets in annealing. We find that annealing improved the performance of a pre-trained Llama 3 8B model on the GSM8k and MATH validation sets by 24.0% and 6.4%, respectively. However, the improvements on the 405B model are negligible, suggesting that our flagship model has strong in-context learning and reasoning capabilities and does not require specific in-domain training samples to obtain strong performance.

Using annealing to assess data quality. Similar to Blakeney et al. (2024), we find that annealing enables us to judge the value of small domain-specific datasets. We measure the value of such datasets by annealing the learning rate of a 50% trained Llama 3 8B model linearly to 0 on 40B tokens. In those experiments, we assign 30% weight to the new dataset and the remaining 70% weight to the default data mix. Using annealing to evaluate new data sources is more efficient than performing scaling law experiments for every small dataset.

MiniCPM: 揭示端侧大语言模型的无限潜力

7. 持续训练友好的数据策略

由于WSD LRS的退火阶段模型会有较大幅度的损失下降，我们猜想在这个阶段加入高质量数据，会有如下两个优点：

1. 相对于在sft阶段加入高质量数据，在退火阶段加入数据，模型学习更充分。
2. 相对于在pretrain一开始阶段加入高质量数据，更能支持小数据的训练，否则在一个未预先定好训练步骤的持续预训练过程中，小数据会重复过多次数，造成负面影响。

基于这两点猜想，我们提出：在预训练阶段只使用通用、量大的预训练粗质量数据，而在退火阶段，使用非常广泛的高质量知识和能力数据以及SFT的高质量数据，混合入预训练数据进行退火。

为了验证我们的方法与直接SFT相比的优势，我们从一个中间检查点开始进行了两组实验。

实验A：仅使用预训练数据进行退火，接着进行4B token的SFT。

实验B：使用如上的高质量数据+SFT数据混入预训练数据进行退火，同样进行4B token的SFT。

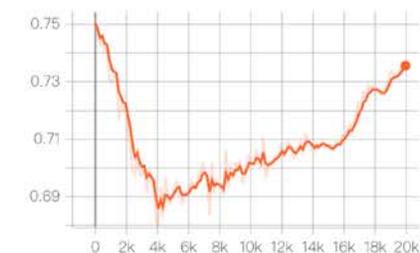
两组实验结果如下：

	C-Eval	CMMLU	MMLU	GSM8K	MATH	HumanEval	MBPP
实验A	40.0	41.5	44.6	27.7	5.1	27.7	24.4
实验B	52.6	51.1	50.9	42.3	5.4	30.4	30.3

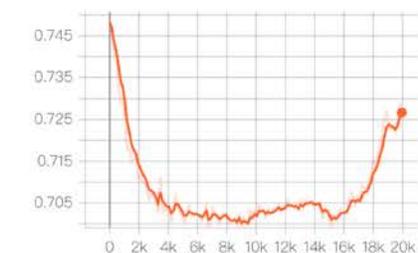
实验结果表明在退火开始时加入高质量数据的收益远高于在退火完成后的sft阶段加入。因此我们建议模型能力的特化和增强应从退火阶段开始进行。

高质量代码、数学、金融领域数据退火有效提升通用能力下降，且逐步提升金融能力

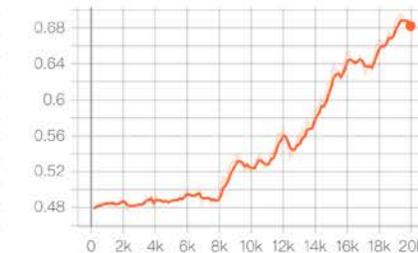
eval/ceval_5shot_accuracy



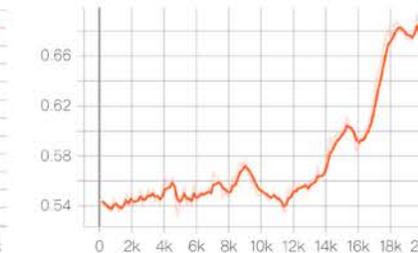
eval/cmmlu_5shot_accuracy



eval/fin_iq_5shot_accuracy



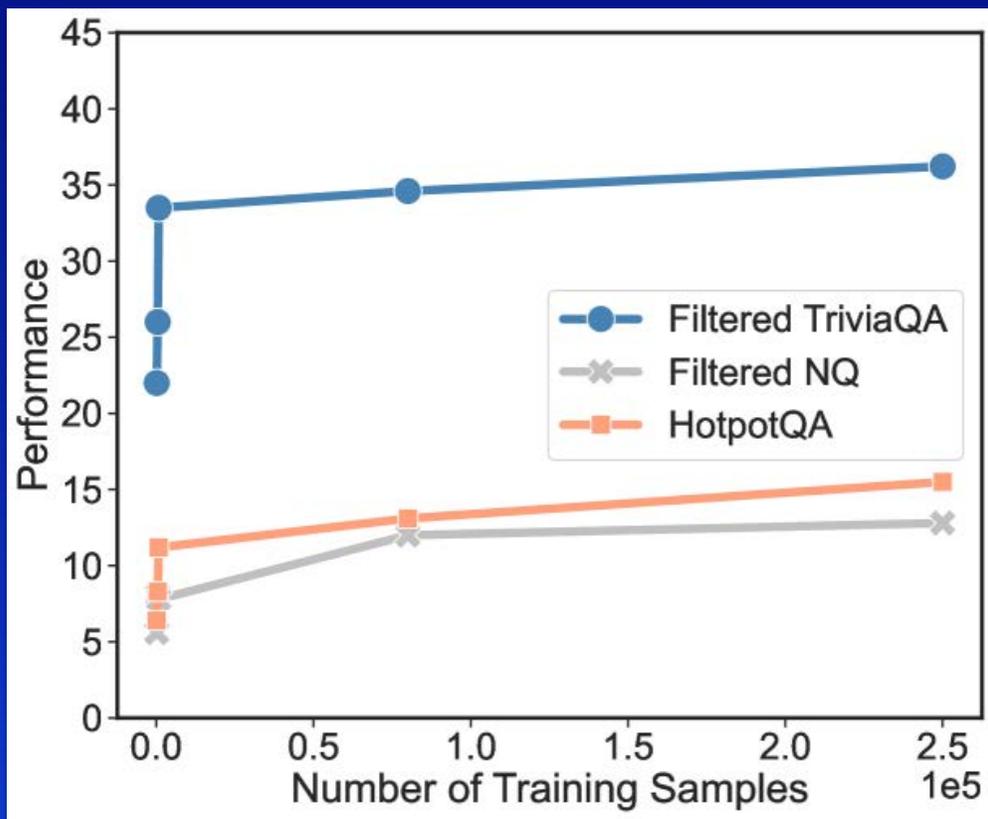
eval/fin_eval_5shot_accuracy



开源模型仅开源模型权重，并未开源训练框架及训练数据，无法掌握预训练阶段的数据配比

不同开源模型的预训练与退火机制不同，需要针对性的调整数据构造/配比及训练方式来保证增量预训练的有效性

► 在预训练阶段未学习到对应的知识

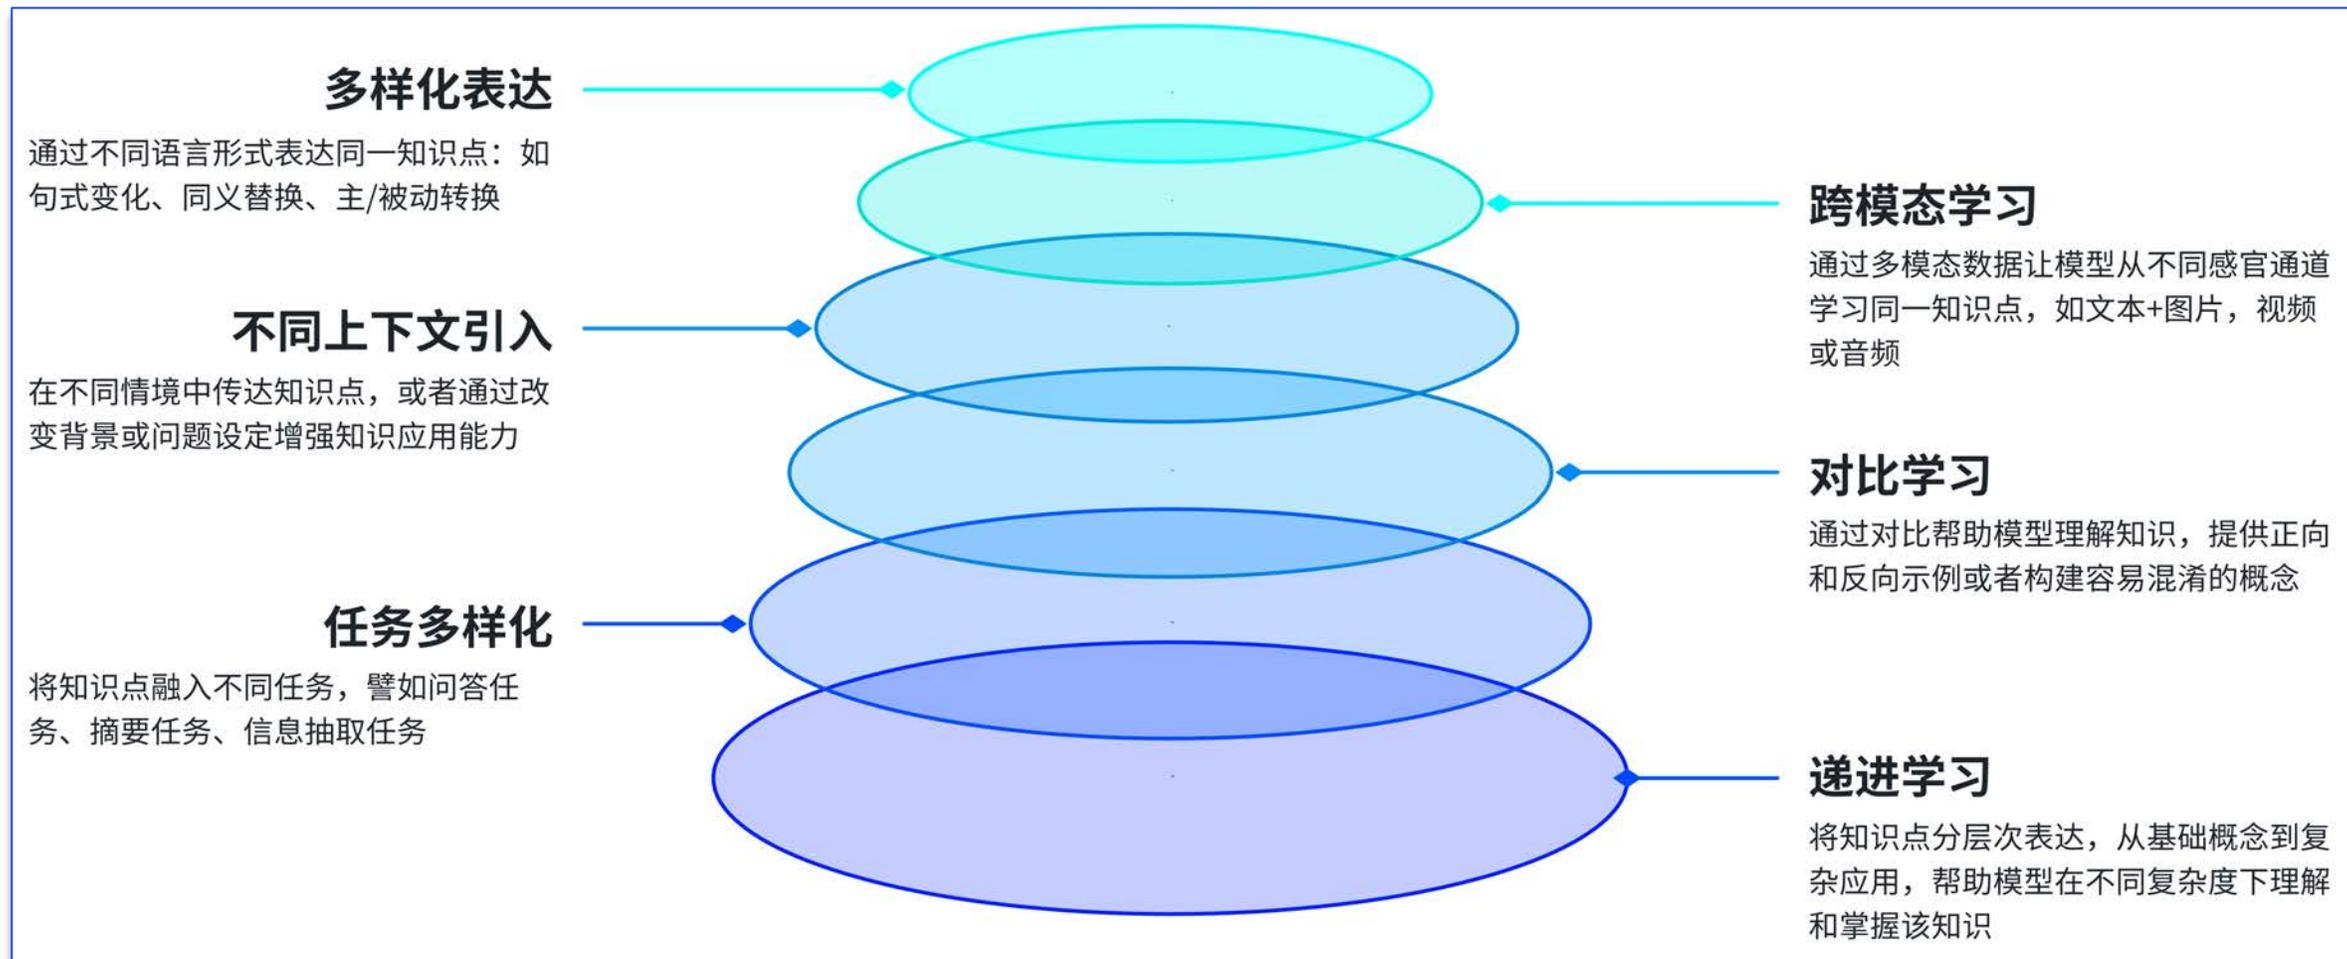


- 在训练初期，使用约1000个样本时，模型性能快速提升至较高水平
- 随后增加更多样本，提升效果有限
- 少量样本的微调足以使大模型对齐人类指令
- 大模型完成CBQA评测主要依赖其内在的**世界知识，而非微调样本注入**

必须在预训练阶段进行知识的获取及增强（多样性、置换、改写等），在预训练阶段学不到的知识，微调阶段基本很难学习到

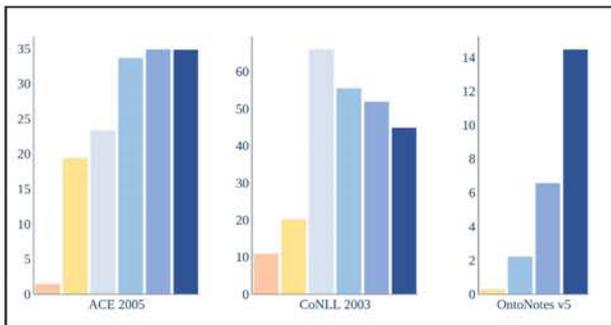
▶ 在预训练阶段未学习到对应的知识

一个知识点必须用不同方式大量重复学习

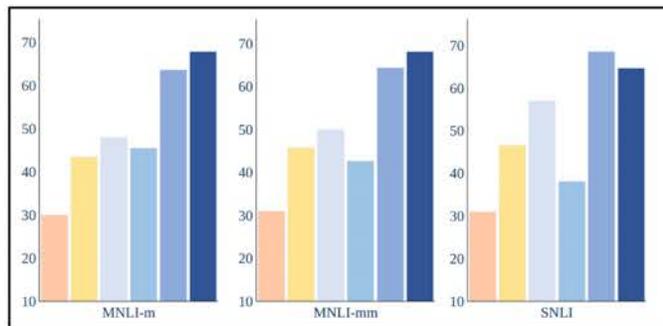


▶ 任务叠加冲突导致模型能力下降

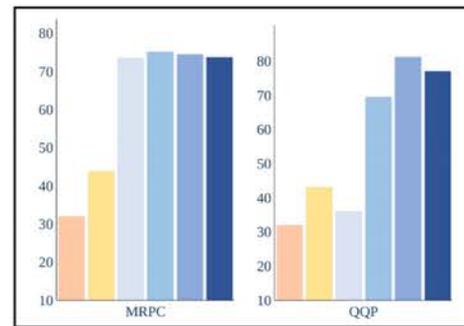
很多任务的能力在一开始并不具备，而是不断叠加上去的



Named Entity Recognition (ENG)

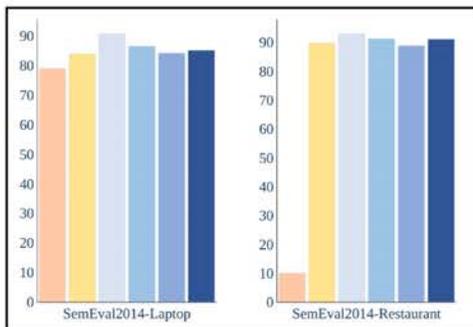


Natural Language Inference

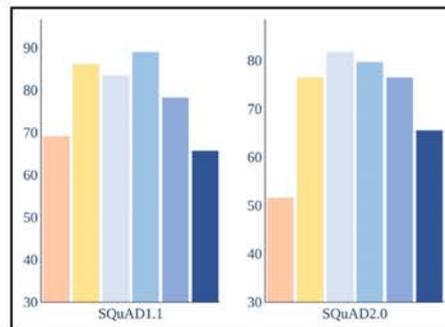


Semantic Matching

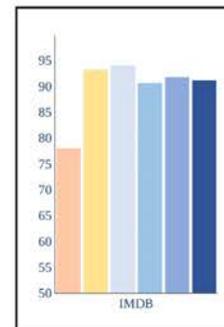
任务大量叠加会造成一些任务能力下降



Aspect-based Sentiment Analysis



Machine Reading Comprehension

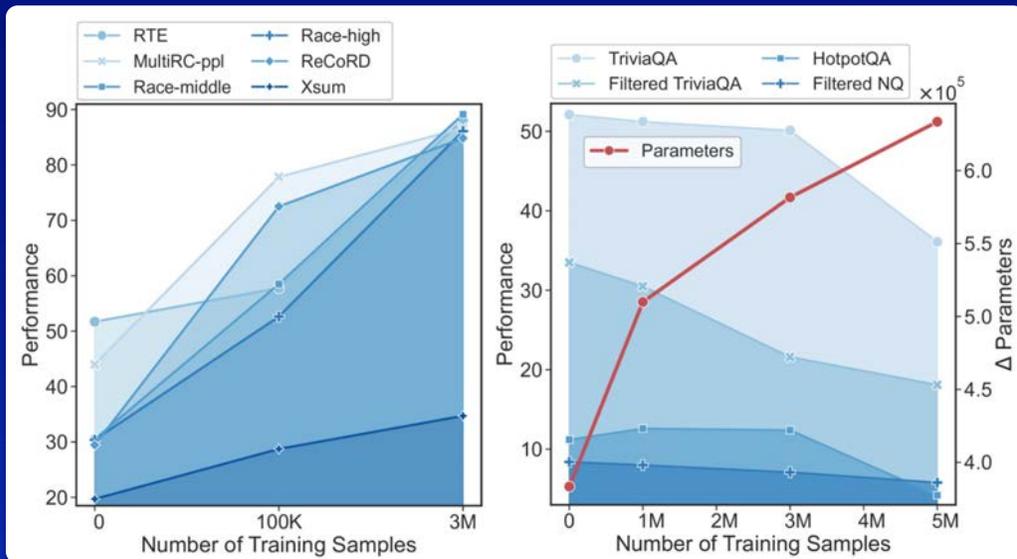


Sentiment Classification

■ davinci ■ text-davinci-001 ■ code-davinci-002 ■ text-davinci-002 ■ text-davinci-003 ■ gpt-3.5-turbo

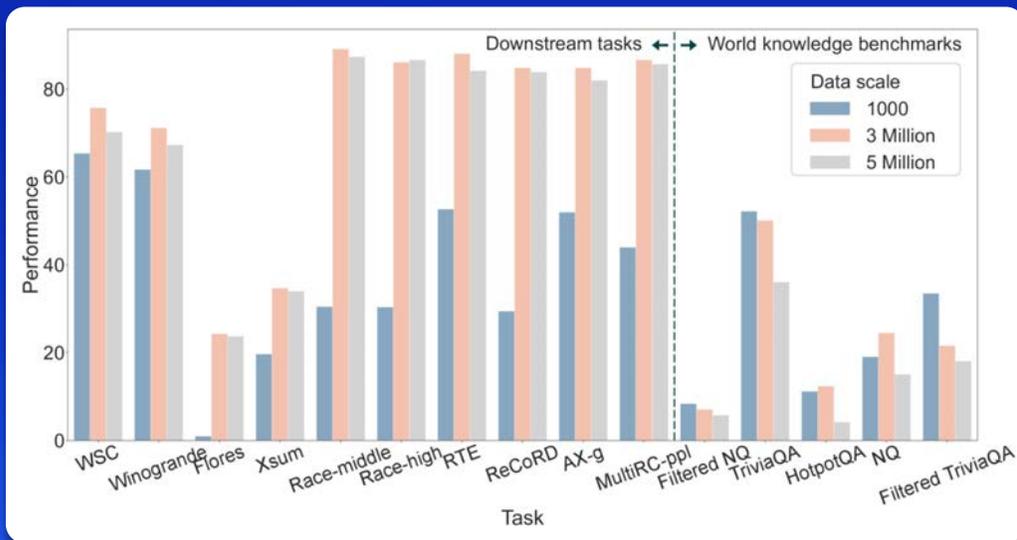
大模型能力需严谨规划与精细设计

大规模指令微调损伤模型世界知识



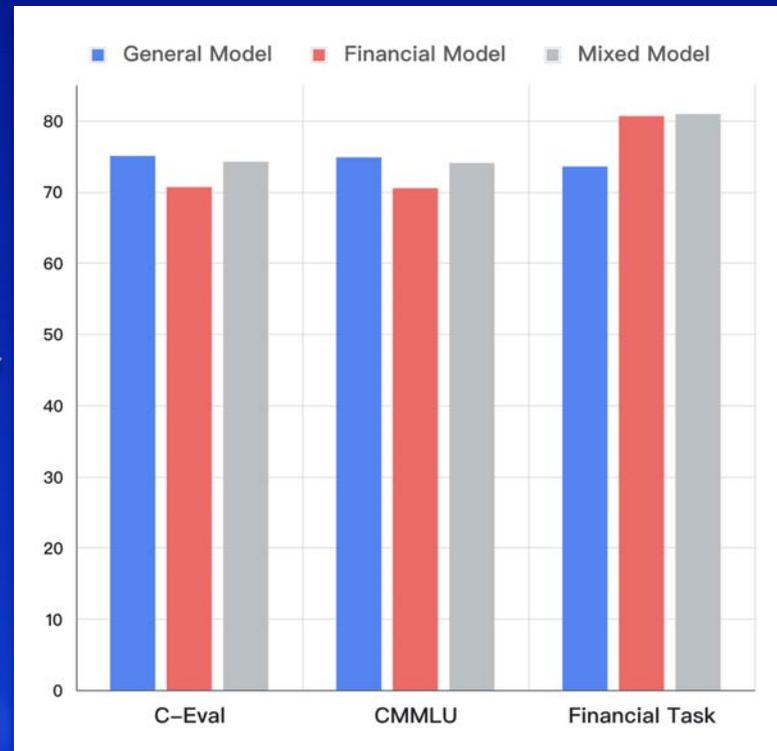
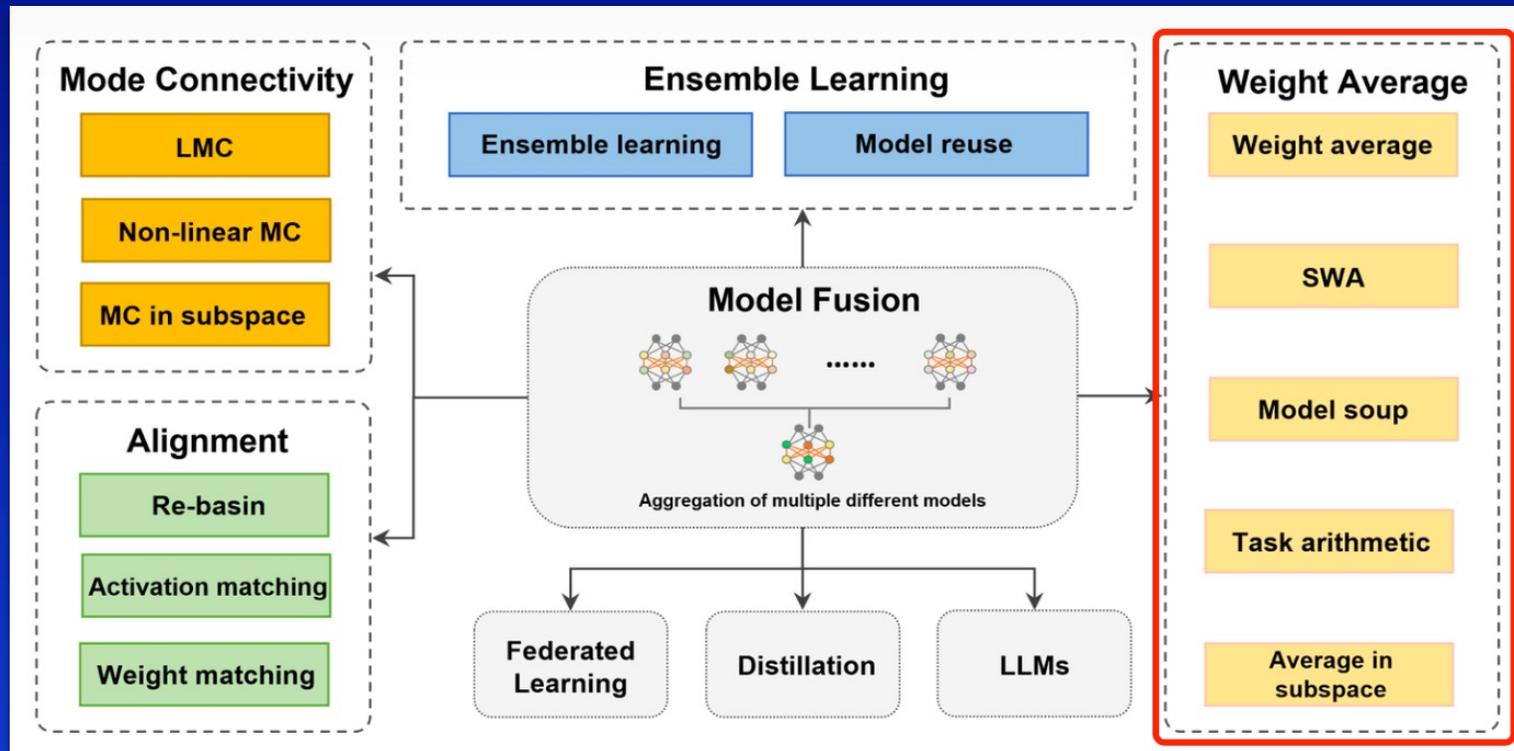
当下游任务增多或需强化特定任务时，增加SFT数据可提升多数任务效果

但随着数据规模扩大，CBQA评测效果下降，且模型参数变化剧增



摘要、NLI、机器翻译任务随SFT数据增加效果提升，但CBQA任务表现下降

► 低成本提升效果：大模型融合



权重平均是一种经典的模型融合方法，将多个模型的权重进行平均，以获得更接近最优解、更准确的结果

▶ 低成本提升效果：交互式示例提升指令遵循

FewShot

User: 请根据给出的新闻文本内容进行情感分析, 从["中性","积极","消极"]中选取对应的答案。

示例1:

新闻文本: 城建发展(600266.SH)股价今日涨停, 收报6.79元, 涨幅10.05%。

情感: 积极

示例2:

新闻文本: 07月03日, 江苏北人股价跌6.54%, 报收20.57元, 成交金额1.59亿元, 换手率6.42%, 振幅7.18%, 量比0.88。江苏北人今日主力资金(超大单+大单)净流出2194万元

情感: 消极

请参考上述示例, 判断下面的新文本的情感倾向。

新闻文本: 7月28日, 天津方程豹汽车销售有限公司成立, 法人为徐庆贺, 注册资本100万人民币。

Assistant:

RoundShot

User: 请根据给出的新闻文本内容进行情感分析, 从["中性","积极","消极"]中选取对应的答案。

新闻文本: 城建发展(600266.SH)股价今日涨停, 收报6.79元, 涨幅10.05%。

Assistant: 积极

User: 请根据给出的新闻文本内容进行情感分析, 从["中性","积极","消极"]中选取对应的答案。

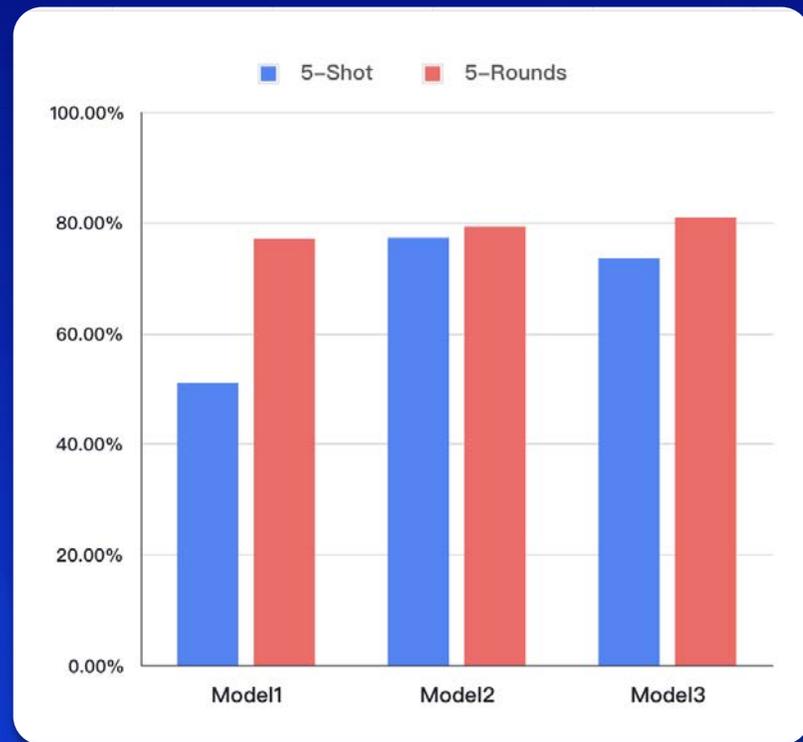
新闻文本: 07月03日, 江苏北人股价跌6.54%, 报收20.57元, 成交金额1.59亿元, 换手率6.42%, 振幅7.18%, 量比0.88。江苏北人今日主力资金(超大单+大单)净流出2194万元

Assistant: 消极

User: 请根据给出的新闻文本内容进行情感分析, 从["中性","积极","消极"]中选取对应的答案。

新闻文本: 7月28日, 天津方程豹汽车销售有限公司成立, 法人为徐庆贺, 注册资本100万人民币。

Assistant:



将 FewShot 示例拆分一轮一轮的交互, 能有效提升模型指令遵循能力, 并且对于 Prompt 设计更加友好

▶ 低成本提升效果：深入理解问题

Stage1: Reveal the Core Question

Q: Raymond and Samantha are cousins. Raymond was born 6 years before Samantha. Raymond had a son at the age of 23. If Samantha is now 31, how many years ago was Raymond's son born?
Please extract the core question, only the most comprehensive and detailed one!

A: How many years ago was Raymond's son born?
(a) **Core question**

Stage2: Extract the Problem-solving Information

Q: Raymond and Samantha are cousins ...how many years ago was Raymond's son born?
Note: Please extract the question-solving information related to the problem (How many years ago was Raymond's son born?), only extract the most useful information, and list them one by one!

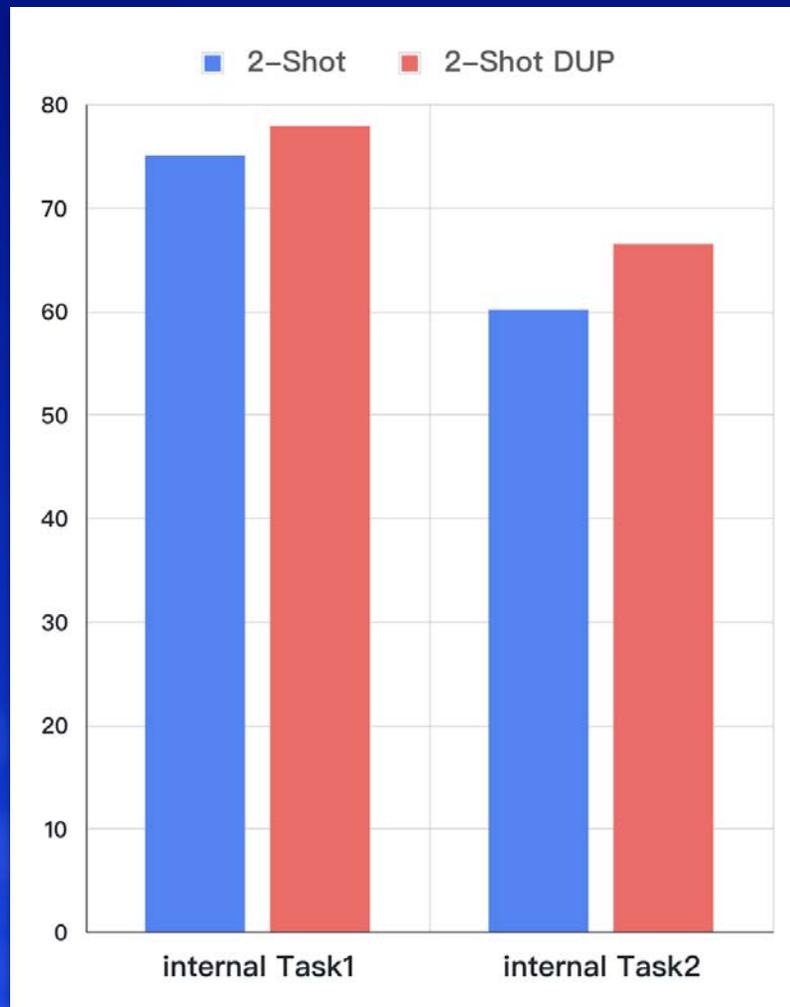
A: 1. Raymond was born 6 years before Samantha. 2. Samantha is now 31. 3. Raymond had a son at the age of 23.
(b) **Problem-solving information**

Stage3: Generate and Extract the Answer

Q: Raymond and Samantha are cousins ...how many years ago was Raymond's son born?
Hint: 1. Raymond was born 6 years before Samantha. 2. Samantha is now 31. 3. Raymond had a son at the age of 23.

How many years ago was Raymond's son born?
Please understand the Hint and question information, then solve the question step by step and show the answer.

A: Raymond is 6 years older than Samantha, so he is now $31 + 6 = 37$ years old. Raymond had a son when he was 23, so his son was born $37 - 23 = 14$ years ago. **The answer is: 14**
(c) **Final answer**



► 策略优化的一些总结

- 高知识密度、高质量的训练数据至关重要，且同一知识需要在预训练阶段大量重复（多样性）学习
- 增量预训练阶段需要关注不同领域、来源的数据拟合情况来判断训练的有效性
- 大规模指令微调伤害基座模型的世界知识，需要精心设计微调任务和数据的配比
- 不同任务、来源的数据混合在低样本资源场景下效果会有提升，高样本资源下由于任务冲突导致效果下降
- 增量预训练阶段出现通用能力下降是正常现象，数据配比很难调整与开源基座相同（开源基座模型甚至都不是训练得到的）
- 退火、模型权重融合是有效提升模型效果的 Trick 方法

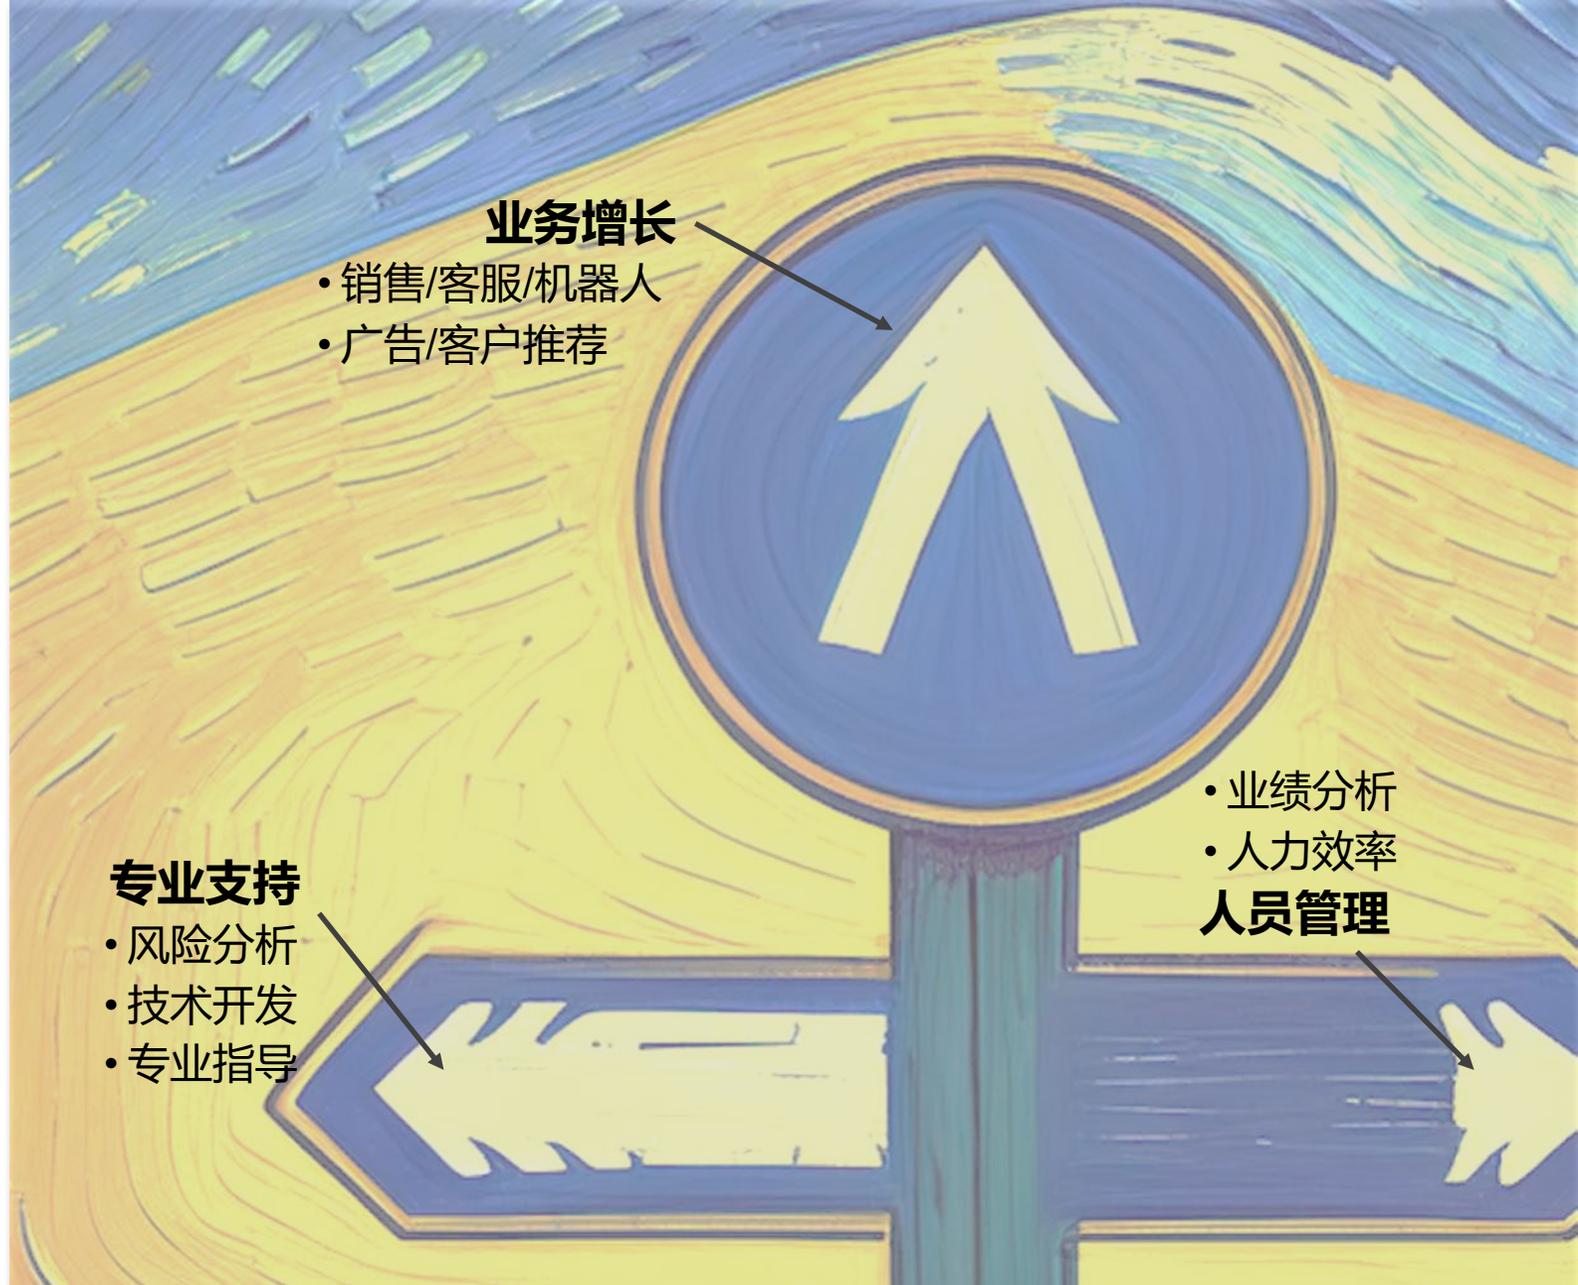
PART 04

应用实践：奇富 Copilot

► Copilot 的构成

Copilot 的核心目标是协助企业提升业务表现和执行效率

因此，无论面对何种场景，都会以推动业务增长、优化人员管理以及提供专业支持为重点展开



▶ Copilot 的构成

Copilot 是操作人员的智能助理，宛如副驾驶般协作。

它是帮助用户深入理解所面临的业务，并提供明确的指导，使他们能够有效地应对和解决各类问题的工具

指示牌：Copilot 服务的业务场景

框架：技术储备

方向盘：安全合规

中控：业务理解

燃料：行业和企业独有数据

动力：逻辑推理

轮胎：算力储备

道路：行业经营规范
安全隐私保护



▶ Copilot 的构成

Copilot虽然作为操作人员的助手，但依然必须严格遵循行业的合规标准

安全与隐私保护就如同道路上的白色边界线，必须时刻谨守，不可逾越



► Copilot 的构成

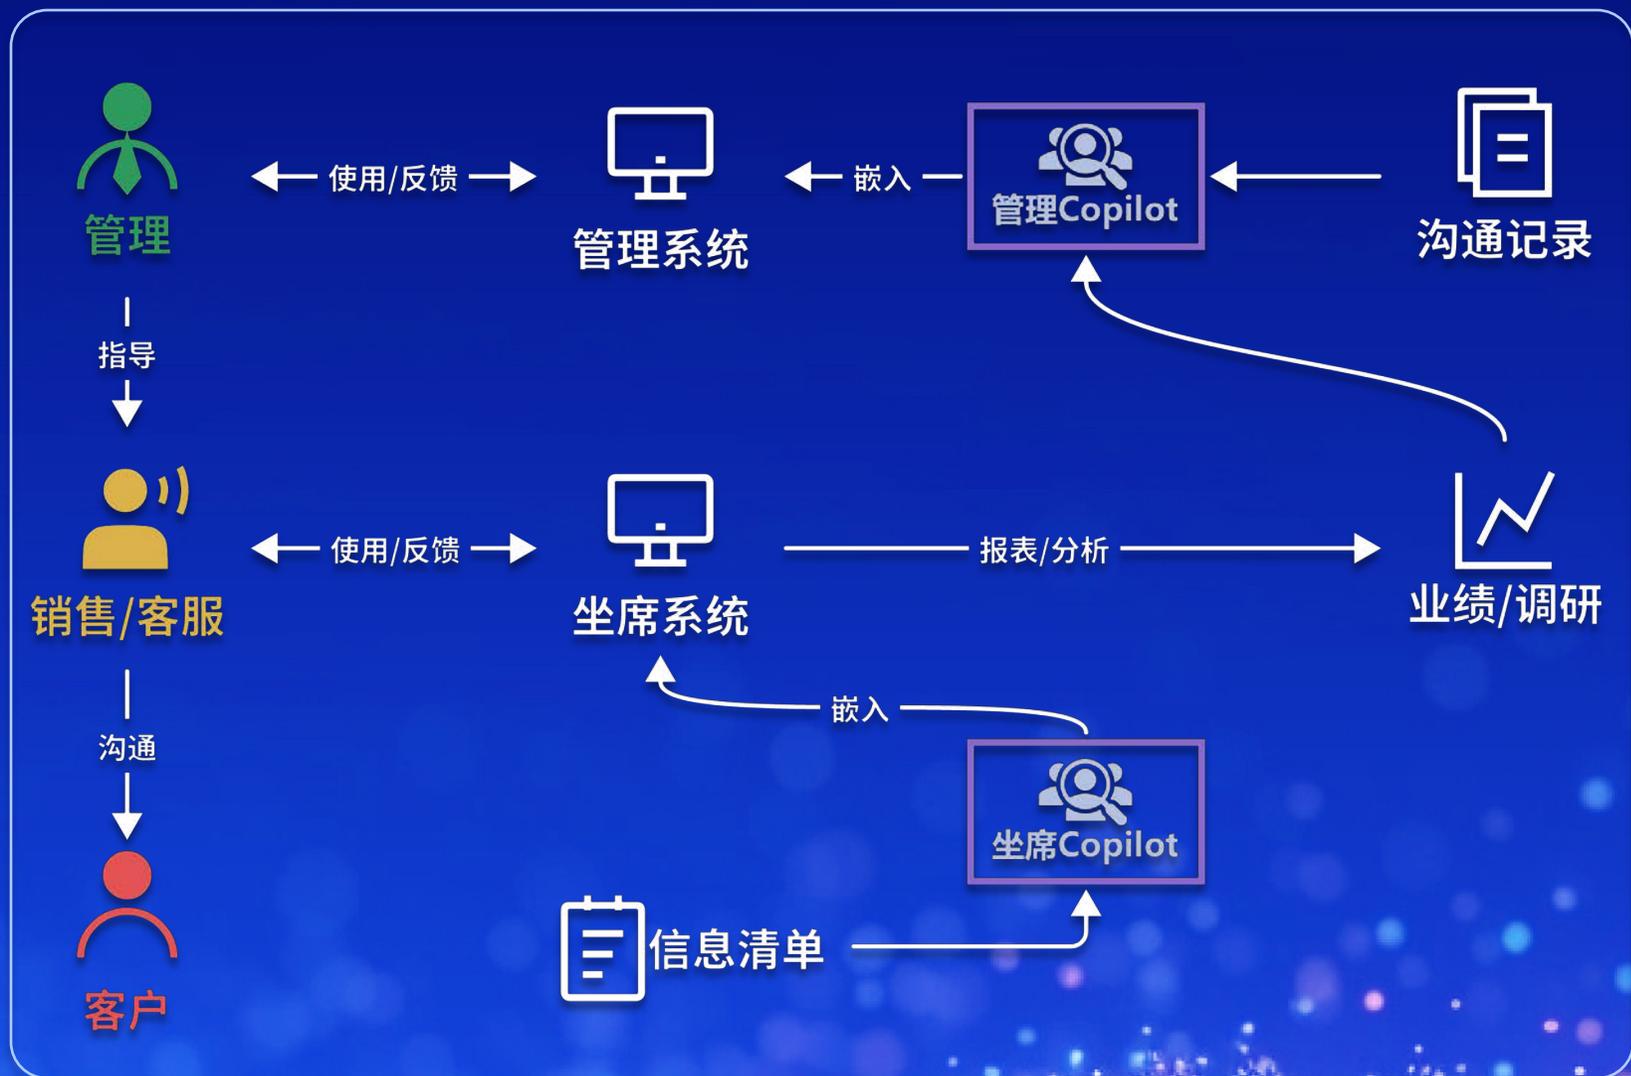
Copilot始终是由人来操作，并与人紧密协作，其核心在于大模型的支撑

Copilot的各个功能模块可以为操作者提供不同层次的支持，既能够独立使用，也可以根据需求灵活组合



奇富Copilot嵌入业务，协助各角色决策

在完整的销售与客服业务流程中，不同角色的Copilot将嵌入各自的系统中，针对各自的决策支持与任务场景，为不同的操作者提供辅助



▶▶ 坐席Copilot协助坐席与客户高效沟通



坐席Copilot的目标是解决在多次沟通、人员变更及被动转接过程中出现的信息差与信息延迟问题，从而提升处理效率和效果

▶ 管理Copilot协助管理者进行差异化管理



管理Copilot的目标是实现对坐席工作的指导、实时监测以及问题分析

▶▶ 坐席&管理Copilot由专属大模型构成



坐席&管理 Copilot

特质

了解每一个用户、每一轮沟通的情况

有领域和业务经验的大模型

能够提出自己的理解、总结和建议

带有人员和任务管理能力的组件

能力

完成度检测

质量检测

客户画像

坐席画像

线索、总结、建议

思路推荐、话术推荐

坐席&管理Copilot由一系列具备专属能力的大模型和组件构成，能够深入理解每位用户和每次交流的具体内容，并基于此提供智能化的建议和理解，帮助操作者做出更精准的决策

▶▶ 过往表现和专属知识定制核心大模型



基础信息
过往表现
意向诉求
跟进进展
近期沟通
业务转化



垂直场景
领域知识

企业内部
业务知识



坐席能力分析
内容检测

客户/任务分析建议
思路/话术优选生成

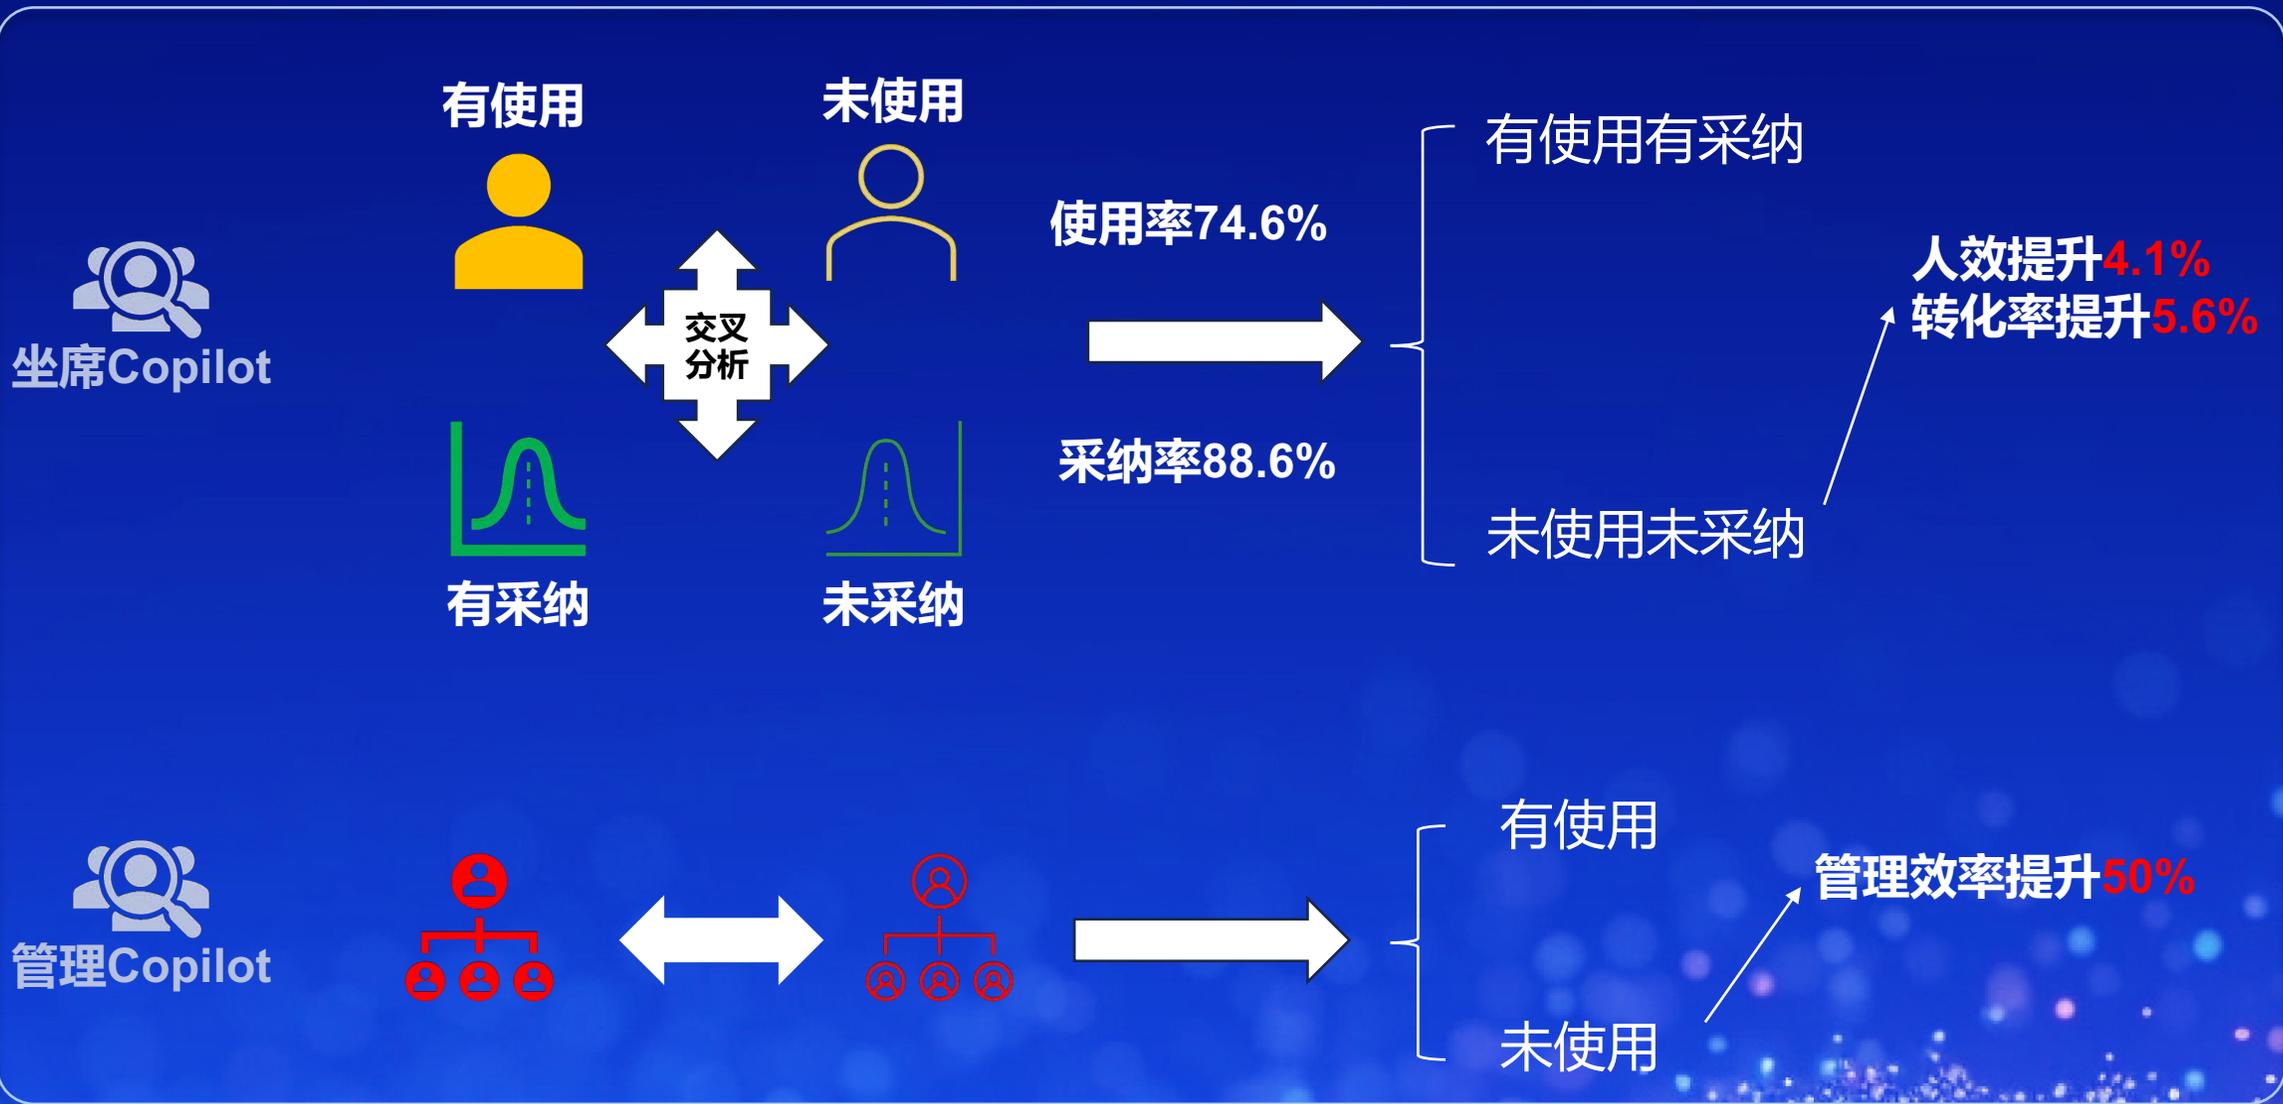


管理场景
检测团队
培训员工
监督任务

业务场景
任务跟进
客户分析
推荐建议

多源信息的有序组织，结合专属领域知识，形成核心的大模型能力，从而能够精准服务于坐席业务的不同场景，提供针对性解决方案，提升业务处理的智能化水平和整体效率

► 坐席&管理Copilot的业绩成果



▶ 坐席Copilot的效果分析

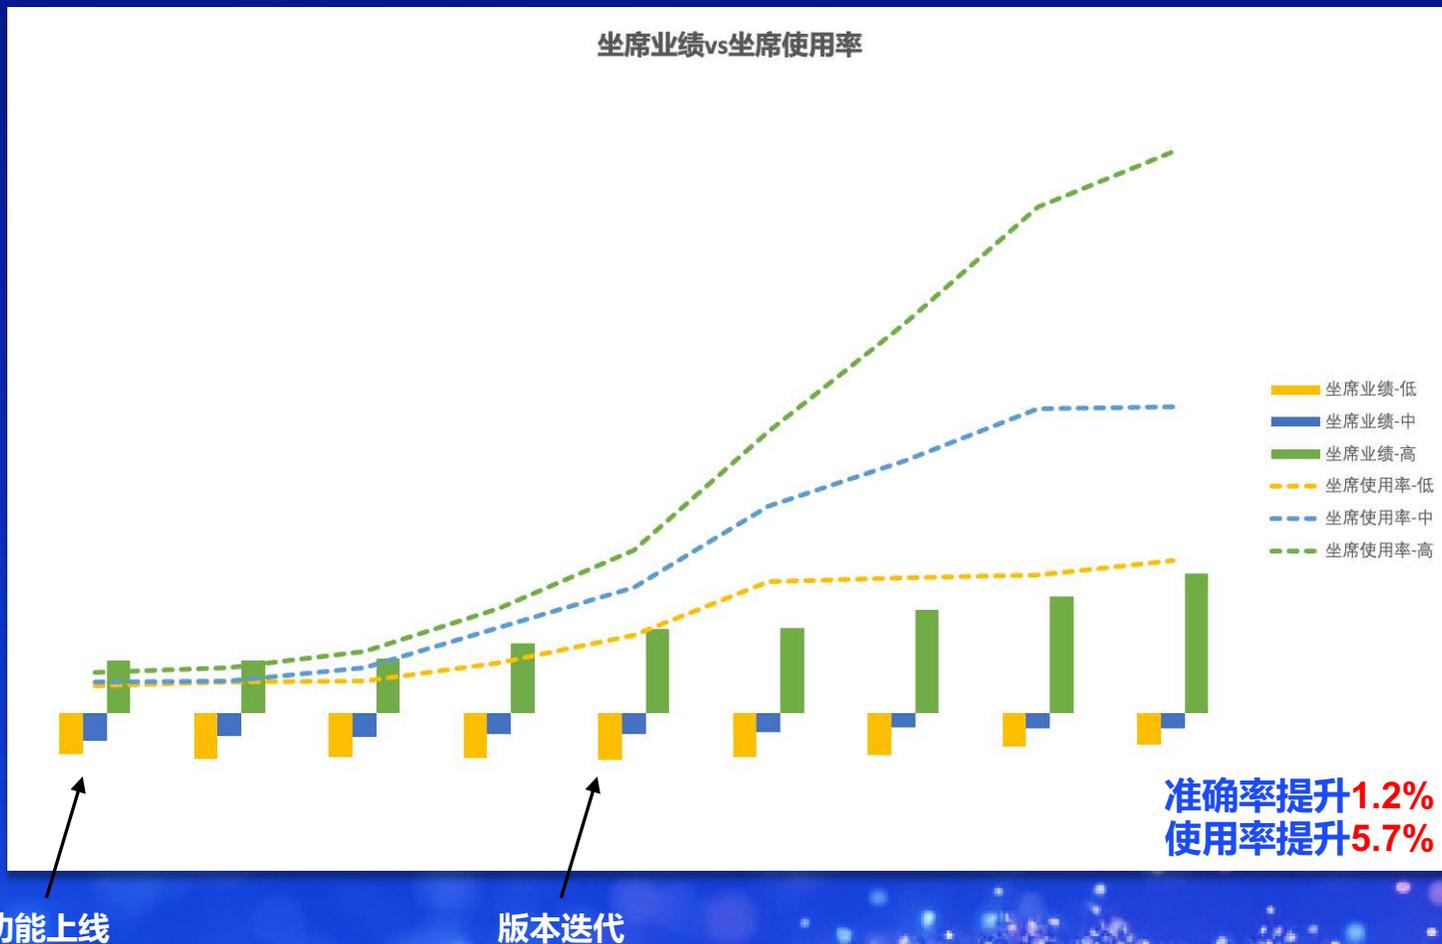


业绩和使用的关系

业绩和迭代的关系



针对业务成果和使用情况进行关联分析
业务效果的提升也可以促进Copilot迭代更新，形成正向的循环反馈



▶ AI 辅助，决策在人

Copilot 的角色应该是专注于特定的场景或少数几个领域的专家，懂人所学，想人所学

Copilot 提供支持和建议，而不是取代人的判断力和创造力，最终的决策权依然掌握在使用者手中



科技生态圈峰会 + 深度研习



—1000+ 技术团队的选择



 **K+峰会**  **敦煌站**

K+ 思考周®研习社

时间: 2025.08.29-30

 **K+峰会**  **上海站**

K+ 金融专场

时间: 2025.10.17-18

 **K+峰会**  **香港站**

K+ 思考周®研习社

时间: 2025.11.25-26



K+峰会详情



 **AiDD峰会**  **上海站**

AI+研发数字峰会

时间: 2025.05.17-18

 **AiDD峰会**  **北京站**

AI+研发数字峰会

时间: 2025.08.08-09

 **AiDD峰会**  **深圳站**

AI+研发数字峰会

时间: 2025.11.28-29



AiDD峰会详情



利用AI技术深化计算机对现实世界的理解

推动研发进入智能化时代

