



2024 AI+研发数字峰会

AI+ Development Digital summit

AI驱动研发变革 促进企业降本增效

北京站 08/16-17



AI Checklist

QUNAR测试域结合AIGC提效实践

崔宸 去哪儿旅行



崔宸

去哪儿旅行 高级开发工程师

2022年加入去哪儿旅行基础架构-基础平台团队，主要负责测试域工具的研发。参与过自动化测试、联调平台、写压测等项目，对录制回放场景有深入了解。

熟悉AI大模型通识，23年开始主攻AI大模型应用方向，完成AI在测试域、需求域提效的应用落地。在去哪儿AIGC HACKATHON大赛获得冠军。

目录

CONTENTS

1. 背景
2. 设计思路和方案
3. 效果评估方案
4. 成果及未来计划

PART 01

背景

▶ 全流程结合AIGC提效



► 现有痛点

需求沟通效率低

PM/DEV/QA 三方沟通
平均耗时30min-1h

自测自发不写case

开发自测可能不充分
机票自测自发比例 86%

写checklist耗时

平均耗时：
5pd以下需求1-2h
5pd以上需求3-5h

需求文档质量参差不齐

逻辑清晰，沟通效率高
逻辑混乱，沟通效率低
无评估标准，只能凭感觉



► 用大模型生成checklist的好处




提升QA写checklist的效率

from 写作业
to 批改作业



提升自测自发需求质量

from 不写case
to 自动生成



可以检查需求文档的质量

质量好：checklist可接受程度高
质量差：checklist可接受程度低

► 设计关键点

01 准确度提升

02 覆盖度推广


03 效果度量方案

PART 02

设计思路和方案


▶ 业界参考样例

基于自有大模型及微调的一键生成方式



门槛高、成本高、需要数据积累


基于通用大模型多轮问答的方式



有迁移、整理成本

► Qunar探索的解决方案




主要（便捷）：基于通用大模型+聚焦于需求点+集成项目研发流程中的一键生成方式



辅助（灵活）：智能体多轮问答




▶ 系统架构



▶ 执行流程



1. 获取需求文档，对文本进行拆分
2. 结构化文档+prompt向大模型提问
3. 将AI返回的测试点进行转换，渲染为脑图
4. 归档AI生成与手动修改完的case，分析数据



▶ 产品文档预处理


原因分析：

- 需求文档无固定模板，规范性较低
- 需求文档中的无关内容影响生成效果



解决方案：

- 需求文档预处理，提取需求正文
- 拆分需求正文，获得结构化需求点




▶ 文本解析模块

符合标准格式：

- 工程化解析需求正文及需求点列表
- 生成准确率高

问题：


- 对产品角色要求变高
- QA角色获益
- 推进受阻



▶ 文本解析模块

圈定需求正文：


- 大模型解析需求点列表
- 预处理成本低
- 生成准确率高




▶ 文本解析模块

完全无格式：

- 大模型解析需求正文
- 大模型解析需求点列表
- 生成准确率取决于文档内容密度



► 需求分析模块



► 需求分析模块——prompt设计

角色

测试专家

&

语言分析专家

样例

通过history模拟

Few shot的方式来提升回答的准确率



能力

- 1, 提取需求点文本的关键信息
- 2, 给出测试点列表和示例

规则

1. 关键信息只保留一句精炼的概括信息
2. 每个测试点对应一个示例
3. 以JSON格式输出

► 需求分析模块——LLM选择

AI基建情况

外部大模型

- 安全审核
- 接口统一化

内部大模型

- 小参数的开源大模型

微调

- 机器显卡有限
- 缺少标准数据集

指标\LLM	GPT-4-turbo	GPT-3.5	chatGLM3-6B
采纳率 (采纳case数 / 生成case数)	60%-70%	50%-60%	30%-40%
召回率 (采纳case数 / 终版case数)	30%-40%	25%-30%	20%-30%
成本	0.0100\$ / 1K tokens	0.0015\$ / 1K tokens	0

▶ 项目流程集成

触发方式

- 项目管理流程入口触发



- checklist平台内手动触发



- 定时扫描第二天进入开发中的需求，
触发自动生成checklist



融入原本的通用case模板



► 样例展示

【需求正文】

改动范围

登录页面

需求点1：前端

增加用户名和密码的输入框。

用户名限定格式为大小写字母+数字。

密码最少为6位，格式为大小写字母+数字，并且前端展示为加密字符。

用户名或密码格式不符合的情况提示用户“用户名或密码格式不正确”。


需求点2：后端

用户名入库时校验，格式为大小写字母+数字。

密码入库时校验，格式为大小写字母+数字，最少6位，入库后需要加密。


用户名或密码格式不符合的情况向前端返回“用户名或密码格式不正确”

```
1  {
2     "keyMessage": "用户名和密码格式校验，用户名为大小写字母
3         +数字，密码为大小写字母+数字且最少6位",
4     "testPoints": [
5         {
6             "testDescription":
7                 "输入符合要求的用户名和密码，入库成功并加密存储",
8             "example": "入参: 用户名:abc123, 密码:Aa1234, 输出:
9                 入库成功"
10            },
11            {
12                "testDescription":
13                    "输入不符合要求的用户名和密码，提示用户“用户名或密码格式不
14                     正确”",
15                "example": "入参: 用户名:@#$%, 密码:a1b2c3, 输出:
16                    用户名或密码格式不正确"
17            },
18            {
19                "testDescription":
20                    "输入长度小于6位的密码，提示用户“用户名或密码格式不正确”
21                     并拒绝入库操作",
22                "example": "入参: 用户名: abcd1234, 密码: abc,
23                    输出: 拒绝入库操作"
24            }
25        ]
26    }
```



► 自测自发case前后对比

使用AI Checklist前



使用AI Checklist后



PART 03

效果评估方案

► 效果评估模块

覆盖率

按照项目维度统计用户使用情况
项目覆盖率：使用的项目数/全部项目数

T | 完全可采纳节点数

P | 部分可采纳节点数

F | 完全不可采纳节点数



采纳率

原始生成结果中用户选取自动
生成节点的概率

采纳率： $(T + 0.5 * P) / A_0$

A₀ | 自动生成总节点数

A₁ | 终版checklist节点数

召回率

用户进行修改之后采用的自动
生成节点与总结点数的比率


召回率： $(T + 0.5 * P) / A_1$

► 效果评估模块

方案	优点	缺陷	备注
用户点击反馈	实现简单，无需另外设计	会增加额外的流程，提高用户使用成本。	<ul style="list-style-type: none">• 可能影响项目覆盖率• 可能影响统计效果
字符串匹配	用户无感知，对流程无侵入。只需要有AIGC源数据和用户终版数据即可触发效果评估。	传统数学方式的匹配，不符合人修改checklist的使用习惯，统计效果会较差。	Case1: 密码正确时弹窗 Case2: 密码不正确时弹窗 字符串匹配：87.5%
基于Embedding模型匹配	同上。并且巧妙利用了用户修改checklist的使用习惯，结合embedding向量做语义相似度匹配。	前期需要人工评估一些case，建立一套合理的阈值和权值模型。如果使用外部的embedding模型接口会有一些花费。	Case1: 弹窗不能关闭 Case2: 弹窗不可以关闭

▶ 效果评估模块



中文文本embedding模型是一种将文本转换为向量表示的技术，它能够捕捉文本的语义和语法信息，并将其转换为连续的向量空间中的点。这种表示方式在自然语言处理领域被广泛应用于各种任务，如文本分类、情感分析、命名实体识别等。



► 效果评估模块

自动生成节点数: 5

终版checklist节点数: 6



► 效果评估模块

相似度阈值	含义	接受率权值
98%	(T) 完全可采纳	100%
90%	(P) 部分可采纳	50%

A 0 | 自动生成总节点数 = 5

A 1 | 终版checklist节点数 = 6



采纳率: $(2*100\% + 1*50\%)/5 = 50.0\%$

召回率: $(2*100\% + 1*50\%)/6 = 41.7\%$

PART 04

成果及未来计划

▶ 目前效果



准确率

60%-70%

采纳率 α

需求文档逻辑清晰程度



召回率

30%-40%


召回率 α

需求文档需求点拆分细致程度



落地范围

每月500+个项目使用
产品需求覆盖率60%-70%



提效成果

- 5pd及以下需求，每个需求节省0.1pd
- 5pd以上需求，每个需求节省0.2pd
- 年化可节省约200pd
- 填补自测自发不写checklist的缺口

▶ 未来计划

01 内部大模型微调

涉及核心私密数据的需求，可以走内部大模型生成


02 接入内部知识库

业务知识库：公司内部概念，黑话，历史资料等

技术知识库：系统调用关系，业务代码资料等

03 结合多模态

支持解析PRD中存在的流程图、UI图信息





THANKS

