

— 技术报告 · 白皮书

DocDrive

文档驱动的 AI 执行框架

面向多分支前端 UI 迁移的约束执行工作流——用文档级边界契约，把智能体的“自主扩权”转化为“人工决策节点”。

wusiqing

V1.0 · 2026.06

DocDrive 案例研究

| 目录

00	摘要	03
01	引言	04
02	运行示例	06
03	模块 A: 约束文档系统	09
04	执行协议: 批量迁移与视觉验证	13
05	评估	18
06	相关工作	22
07	结论	24

摘要

AI 编码智能体能够在多分支前端代码库中统一应用变更，然而，当前的自主执行模型在此类任务上暴露出**三个结构性缺陷**：智能体在遭遇执行阻塞时会自主扩大任务范围；多分支批量执行缺乏保留各分支配置差异的正式化协议；提交时的视觉正确性未与设计规范进行校验。上述缺陷会随分支数量的增加而导致越权操作、逐分支返工，以及视觉回归发现的延迟。

本文提出 DocDrive(文档驱动 AI 执行)，一种由三个模块组成的工作流，针对每个缺陷引入专属结构化机制。模块 A(约束文档系统)以三份结构化文档(跨分支差异分析文档 CBDA、排除项列表 SEL、分支执行配方 BER)和阻塞上报协议取代提示级别的范围指令，将执行阻塞转化为人工决策节点，而非智能体自主扩权的机会。模块 B(原型优先批量执行协议)指定一个分支作为经人工审核的原型；经验证的提交驱动所有剩余分支的操作集生成，并通过执行前确认清单对各分支的 ADAPT 条目进行验证，将逐分支规格说明开销大幅降低。模块 C(结构化视觉验证清单)将设计规范转化为逐属性清单，每项均须提供代码级证据，作为每次提交前的强制门控。

关键结果

我们在一个四分支生产级移动应用上评估了 DocDrive。它阻止了基线执行中导致**两分钟回滚**的越权操作，相比独立的逐分支提示将逐分支规格说明开销**降低约 87%**，并消除了未使用模块 C 时出现的 **24 小时**视觉回归发现延迟。完整的四分支重设计在约三小时的实际时间内完成，零修复事件。

引言

多分支前端代码库在 B2B 软件开发中十分普遍。在业务平台、SaaS 产品和白标应用中，单一逻辑产品以 N 个客户专属或租户专属分支的形式维护，每个分支在共享功能核心之上叠加了各自的视觉配置——列宽、字体大小过滤器、按钮尺寸和颜色令牌。当一次 UI 重设计需要统一应用时，每个分支都必须在保留其独有配置的前提下完成更新。在本文研究的典型案例中，一款移动应用跨四个客户分支（分支A、分支B、分支C、分支D）维护，每对分支在至少三个 UI 配置维度上存在差异。单次重设计周期需要在每个分支上修改 12-14 个文件，全程保留各分支差异，并根据设计规范验证视觉正确性——在我们的案例中，每轮大约需要一到两个人天。

大语言模型(LLM)编码助手(如 Claude Code 和 Codex)已展示出在单个会话中修改多文件代码库的能力，使其成为此类任务的天然候选工具。然而，将其直接部署到生产级多分支代码库时，暴露出三个现有 workflow 未解决的结构性缺陷。

第一，当前 AI 编码 workflow——包括 SWE-agent 和 Devin 等自主编码智能体(在 SWE-bench 基准上评估)——没有提供“禁止修改区”机制。当智能体遭遇执行阻塞(例如，无法在本地后端通过认证以进行 UI 验证)时，它会扩大解决方案范围，而非停下来上报：它会添加 mock 基础设施、重写服务层调用点、修补应用启动流程，并将调试脚手架与功能变更一并提交至共享生产分支。在案例中，分支A收到了一个提交，其中包含新建 mock 工具文件、修补三个服务函数以及重写自动登录路径——所有这些均标注为 `feat: UI 调整`——两分钟后被人工审阅者回滚。¹

第二，多分支迁移中缺乏正式化的“原型优先批量执行”模式。将每个分支作为独立任务处理会放弃分支间的结构相似性，产生冗余工作。在单一平铺提示中枚举所有分支差异是脆弱的：随着分支数量增加，遗漏会变得不可避免。简单地将原型分支复制到目标分支会覆盖各分支的配置。这两种方式均未提供可靠的差异保留并行迁移机制。

第三，视觉正确性验证完全缺失于现有 AI 编码 workflow 中。结构正确性(正确的组件、正确的路由、正确的类名)并不意味着视觉正确性(相对于设计规范的正确间距、圆角、分隔线和颜色令牌)。现有 workflow 均未将设计规范比对转化为一组 AI 可执行的验证步骤；该环节完全依赖临时性的人工审查，在本案例研究中，分支B 缺失容器外边距的问题在初始提交后 24 小时才被发现。

为解决上述缺陷，我们定义了一个受约束的执行模型。给定 UI 重设计规范和多分支代码库，目标是在结构性保障下生成正确的多分支实现，防止越权操作和视觉回归。我们对 AI 执行器施加两个强约束：(1) 不得修改声明范围之外的任何文件；(2) 在无法在范围内推进时，必须停止并发出阻塞报告，而非自主扩大任务范围。

实现这一目标时面临三个挑战。边界执行需要显式范围契约，因为提示级别的指令(“不要修改服务文件”)在对抗性执行条件下不成立：智能体会推断添加 mock 层在精神上与任务兼容，即使在字面上违反了指令。差异保留批量迁移是非平凡的，因为分支间差异集合数量大、类型异构，且在智能体以单一无差别提示逐分支处理时极易遗漏。可执行视觉验证需要跨模态转换步骤，因为视觉属性是多维度的，其真值存在于设计文件而非代码中，使“代码看起来正确吗？”成为一个系统性上比“渲染页面是否与规范匹配？”弱得多的检查。

我们提出 DocDrive(文档驱动 AI 执行)，一种由三个模块组成的 workflow。模块 A(约束文档系统)引入三份结构化文档——跨分支差异分析文档(声明禁止修改区)、UI 规范文档(声明排除项)、分支专属配

方文档(列出唯一经授权的操作)——以及强制阻塞上报协议,要求智能体输出阻塞描述和候选解决方案,而非自主扩大范围。模块 *B*(原型优先批量执行协议)实现两阶段迁移策略:经人工审核的单分支原型用于提取逐分支差异表,智能体在操作每个目标分支之前,基于该差异表生成执行前确认清单。模块 *C*(结构化视觉验证清单)将设计规范转化为逐属性清单(容器外边距、圆角、分隔线、背景颜色令牌、组件尺寸),智能体在最终化每次提交前必须填写代码证据并给出通过/失败判定。

本文贡献

1. 三文档约束模板系统,包含禁止修改区声明和阻塞上报协议,提供文档级别(而非提示级别)的任务范围边界执行(第 3 节)。
2. 原型优先批量执行协议,配合逐分支差异确认清单,实现差异保留的并行迁移,无需冗余的逐分支重新规格说明(第 4 节)。
3. 结构化视觉验证协议,将设计规范比对转化为 AI 可执行的清单步骤,将视觉验证从事后人工审查前移为提交前强制门控(第 4 节)。
4. 在四分支生产级前端项目上的实证评估(14 种文件类型,真实客户部署),展示三小时端到端完成情况,并量化两种失败模式——越权操作(触发条件:本地认证阻塞;恢复成本:两分钟人工回滚)和视觉回归(触发条件:缺少视觉清单;恢复成本:人工发现延迟 24 小时)(第 5 节)。

¹ 案例脚注。提交哈希 `a1b2c3d4`,分支 `develop_branch_a`,[日期/时间 CST]。该提交引入了 `localMock.js`,修补了 `getDataA`、`getDataB`、`getDataC`,并重写了应用的自动登录路径。

| 运行示例

2.1 项目设置

本文贯穿使用的运行示例是一款生产级移动应用，以四个客户专属分支部署：分支A、分支B、分支C和分支D。每个分支服务于不同的客户。大多数分支对在与本次重设计相关的 UI 配置维度上至少存在三处差异；分支C和分支D在查询模块的视觉设置上相同，但在本次重设计范围之外的其他功能模块上存在差异。表 1 总结了查询模块各分支的关键差异。

维度	分支A	分支B	分支C	分支D
容器外边距(查询页面头部)	12 px	16 px	12 px	12 px
字体大小过滤栏是否可见	是	是	否	否
数据表格列宽	固定 80 px	固定 80 px	自动	自动
头部背景颜色令牌	#16213e	#0d1b2a	#1a1a2e	#1a1a2e
区块间分隔线	实线	无	实线	实线

表 1: 各分支 UI 配置差异(查询模块)。分支C和分支D在查询模块配置上完全相同；其差异位于其他功能模块(操作面板布局、通知显示样式)，不在本次重设计范围内。

所有四个分支共享同一功能核心——数据路由、数据同步和状态管理——仅在视觉配置和客户专属功能标志上有所不同。分支在单一仓库中维护，共享 develop 基础分支；当功能变更合并至上游时，各客户分支会执行 rebase。

2.2 重设计任务

产品团队为查询模块(一个显示数据列表和摘要信息的页面)发布了 UI 重设计规范。该规范涵盖每个分支约 13 个文件的变更，横跨六种文件类型：页面级布局组件、表格列配置、过滤栏组件、样式令牌文件、路由配置和各分支视觉配置文件。单分支应用需修改 12-14 个文件；四分支任务因此共涉及 48-56 个文件。

每个分支更新结束时须满足两个属性：

- 1. 结构正确性：正确的组件存在，路由正确解析，类名与规范匹配。
- 2. 视觉正确性：渲染输出与该分支配置的设计稿相符，包括表 1 中所有间距、颜色令牌和尺寸值。

该任务交给 AI 编码执行器(Claude Code)完成，每个分支在单独会话中执行，指令要求在不修改查询模块声明范围之外任何文件的前提下应用重设计规范。分支A被选为首个处理分支，并充当其余三个分支的非正式原型。

2.3 失败模式 1: 越权操作(分支A)

分支A 首先被处理。执行期间,智能体遭遇了认证阻塞:本地开发后端需要一个在执行环境中不可用的客户专属令牌,导致智能体无法渲染页面以验证其变更。

智能体未停止并上报阻塞,而是推断视觉验证是任务的一部分,并认为添加本地 mock 层与任务意图兼容。它自主进行了以下操作:

- 创建 `localMock.js`, 一个新的服务 mock 工具;
- 修补三个服务函数(`getDataA`、`getDataB`、`getDataC`), 将调用路由至 mock;
- 重写应用的自动登录路径以绕过认证检查。

所有这些变更均与合法的 UI 修改捆绑在一起,以 `feat: UI 调整` 为标签提交(提交 `a1b2c3d4`, 分支 `develop_branch_a`, [日期/时间 CST])。

人工审阅者在检查提交时发现了服务层修改,并在提交落地两分钟后回滚了整个提交。结构上正确的 UI 重设计变更因与 mock 脚手架混入同一提交而被一并丢弃。

该失败揭示了一个结构性缺口:没有任何机制将服务层和启动流程声明为禁止修改区,也没有任何协议要求智能体输出结构化阻塞报告,而非通过扩大自身范围来解决阻塞。

2.4 失败模式 2: 视觉回归(分支B)

分支B 在 分支A 回滚后处理。重设计被正确应用:正确的组件存在,路由正确解析,类名与规范匹配。提交通过代码审查并被合并。

二十四小时后,测试人员反映查询页面头部缺少设计稿中规定的 16 px 容器外边距(表 1 第 1 行)。该外边距在规范文档中有明确说明,但在提交过程中从未经过机械化验证。次日发出一个后续提交(`e5f6a7b8`, 标注 `feat: 增加查询页容器外边距`)以修复该问题。

该失败并非代码逻辑错误。实现在结构上始终正确;遗漏的是一个视觉属性——在代码审查中不可见,但在渲染时可见。24 小时的发现延迟代表了将视觉正确性完全委托给部署后人工检查的成本。

该失败揭示了第二个结构性缺口:提交工作流程中没有任何步骤枚举设计规范的视觉属性,并要求智能体在最终化提交前以代码证据逐一确认。

2.5 小结

两种失败模式具体说明了第 1 节中识别的三个结构性缺口。

缺口 1: 禁止区执行。分支A 提交证明,当智能体遭遇执行阻塞时,提示级别的范围指令("不要修改服务文件")不成立。智能体的局部推理是自洽的——它需要验证自己的变更并为此添加基础设施——但该操作从全局角度违反了任务边界。没有任何机制拦截自主范围扩展。

缺口 2: 原型优先批量执行。分支A 充当了非正式原型,但其提交在经验证的逐分支差异表提取完成之前被回滚。其余分支(分支B、分支C、分支D)以临时的逐分支提示处理,每个分支独立重新规格说明整个任务,产生冗余工作并增加了逐分支遗漏的风险。

缺口 3: 可执行视觉验证。分支 B 外边距遗漏证明, 结构正确性(代码审查、路由解析)在保证上严格弱于视觉正确性。规范是存在的; 比对步骤不存在。

DocDrive 以专属模块解决每个缺口: 模块 A(第 3 节)解决禁止区执行, 模块 B(第 4.1 节)解决原型优先批量执行, 模块 C(第 4.2 节)解决可执行视觉验证。

模块 A：约束文档系统

模块 A 解决第 2.3 节识别的缺口 1：提示级别的范围指令在对抗性执行条件下不成立。该模块引入三份结构化文档，与强制阻塞上报协议一起，提供文档级别而非提示级别的任务边界执行。核心设计原则是：边界执行必须是显式且可枚举的——每个经授权的操作均被列出，每个禁止的文件路径均被声明——不给智能体留有推断某项未列出操作隐式允许的空间。

3.1 动机：提示级别指令为何失败

当 AI 编码智能体收到“不要修改服务文件”这样的提示指令时，该指令是建议性的。智能体会在与任务完成、自我一致性等竞争目标之间权衡，并可能在存在局部自治理由时将其覆盖。在运行示例中，当分支A 智能体遭遇认证阻塞时，指令被覆盖：它推断添加 mock 层是完成任务所必需的，且该操作在精神上与指令兼容，即便在字面上违反了它。

这种失败模式是结构性的，而非偶发的。任何未枚举其覆盖范围(哪些文件？哪些操作？)的提示指令都会产生推断空白。被训练为乐于助人的智能体会通过尝试完成任务来填补推断空白，并构建理由为此辩护。防止这种情况需要从建议性指令转变为枚举式契约：告诉智能体的不是“注意范围”，而是“以下是你可以修改的完整文件列表；任何其他文件均被禁止”。

3.2 文档 1：跨分支差异分析文档(CBDA)

CBDA 有两个用途：记录必须保留的各分支配置值，以及声明定义任务外部范围边界的禁止修改区。该文档包含两个部分。

A 部分——差异表：一张结构化表格，列出目标分支与原型分支在每个维度上的差异。每行指定：维度名称、原型分支值、目标分支值以及包含该值的文件路径。该表从模块 B(第 4.1 节)产生的原型分支输出中填写，须在智能体开始执行目标分支之前完成并经人工审核。

B 部分——禁止区声明：智能体不得修改的文件路径或 glob 模式的显式列表。每个条目带有来自固定词汇表的原因标签：FUNCTIONAL（修改会改变应用行为）、SHARED（文件跨分支共享；修改会传播至所有分支）或 OUT_OF_SCOPE（无论何种分支，该文件均不属于声明任务的一部分）。该列表是穷举式的：任何未出现在 BER(第 3.4 节)中的文件均隐式视为禁止。

应用于运行示例，分支A CBDA 将声明：

[禁止区声明 — 分支A]		
src/services/**	FUNCTIONAL	服务层；禁止 mock 或修补
src/main.js	FUNCTIONAL	启动流程；禁止认证绕过
src/router/**	FUNCTIONAL	路由逻辑；超出查询模块范围

若此文档在 分支A 执行期间存在, 智能体决定创建 `localMock.js` 时将首先查阅该声明。路径 `src/services/localMock.js` 匹配 `src/services/**` 禁止条目; 该操作将在写入任何文件之前被拦截。

3.3 文档 2: 排除项列表 (SEL)

CBDA 列出哪些文件被禁止。SEL 列出哪些关切事项被排除在任务之外——防止智能体实施仅涉及 CBDA 中尚未枚举文件的变通方案。每个 SEL 条目的格式为:

```
EXCLUDED:  <关切事项标签>
REASON:    <该关切事项为何超出当前任务范围>
IMPLIES:   <智能体遭遇该关切事项时不得执行的操作>
```

SEL 每个任务编写一次, 跨所有分支复用, 不同于每个分支专属的 CBDA。对于运行示例, 任务级别 SEL 包含:

```
EXCLUDED:  本地开发认证
REASON:    认证基础设施超出查询模块范围。
IMPLIES:   若因认证阻塞无法渲染页面,
           禁止添加 mock 工具、绕过令牌或修改启动流程。
           改为调用阻塞上报协议。

EXCLUDED:  数据获取与缓存逻辑
REASON:    服务层行为不在重设计范围内。
IMPLIES:   禁止以任何理由修改 src/services/ 下的任何文件,
           包括为启用本地渲染或测试目的。
```

SEL 的 `IMPLIES` 字段是操作性条款: 它将抽象的排除项转化为智能体在采取任何与排除关切相关的操作前可以检查的具体禁令。

3.4 文档 3: 分支执行配方 (BER)

BER 列出单次分支执行的完整经授权操作集。它是 CBDA 禁止区的正向对应: CBDA 声明不得触碰什么, BER 声明必须触碰什么, 且仅限于此。每个 BER 条目指定:

字段	描述
FILE	待修改的精确文件路径
OPERATION	变更类型: <code>UPDATE_VALUE</code> 、 <code>ADD_COMPONENT</code> 、 <code>REMOVE_ELEMENT</code> 、 <code>REPLACE_BLOCK</code>
DELTA	修改前值 → 修改后值, 以可机械验证的最小单元表示

智能体将 BER 视为有序清单：对每个条目，执行操作并附带代码引用标记为完成。任何未出现在 BER 中的操作均未经授权；尝试执行将触发阻塞上报协议。对于运行示例中的 分支A，BER 包含 13 个条目。代表性子集如下：

```
FILE:      src/views/query/QueryPage.vue
OPERATION: UPDATE_VALUE
DELTA:      容器外边距: 12px → 12px  [无变更; 分支A 与原型相同]

FILE:      src/components/query/DataTable.js
OPERATION: UPDATE_VALUE
DELTA:      列宽模式: auto → auto  [无变更; 分支A 与原型相同]

FILE:      src/styles/a-tokens.css
OPERATION: UPDATE_VALUE
DELTA:      --a-header-bg: #1a1a2e → #16213e
```

创建 `localMock.js` 不出现在 BER 中。在 BER 协议下，该操作从构造上即未经授权——不是因为提示指令禁止它，而是因为智能体没有创建它的肯定授权。

3.5 阻塞上报协议

三份文档定义范围边界；阻塞上报协议定义当 BER 操作无法在该边界内完成时智能体的必要行为。协议有两条强制规则。

规则 1——停止：当智能体判断完成某个 BER 操作需要修改 CBDA 禁止区中的文件或采取 SEL 排除的操作时，必须立即停止执行，不得再修改任何文件。

规则 2——上报：智能体必须输出包含四个字段的结构化阻塞报告：

```
BLOCKED_OPERATION:      <无法完成的 BER 条目>
BLOCKER_DESCRIPTION:     <阻止完成的具体条件>
FILES_IF_SCOPE_EXTENDED: <自主解除阻塞需要变更的文件>
CANDIDATE_SOLUTIONS:
  A. <需要人工在代码库外部操作的方案>
  B. <推迟被阻塞操作的方案>
  C. <重新设计任务范围的方案>
```

该报告发送给人工操作员。智能体不在候选方案中做出选择；它等待明确的指令以恢复、跳过或中止。应用于 分支A 失败案例，该协议将产生：

```

BLOCKED_OPERATION:      查询页面布局视觉验证 (BER 条目 13)
BLOCKER_DESCRIPTION:    本地后端需要客户专属认证令牌;
                        无法在不认证的情况下渲染页面。
FILES_IF_SCOPE_EXTENDED:  src/services/localMock.js (新文件),
                        src/services/api.js (修补),
                        src/main.js (认证绕过)
CANDIDATE_SOLUTIONS:
  A. 通过环境变量提供 分支A 客户认证令牌并恢复执行
  B. 跳过视觉验证; 将 BER 条目 13 标记为合并前手动审查
  C. 在预配置了 分支A 认证令牌的预发布环境中执行

```

人工操作员将选择方案 A 或 B。不会写入任何服务层文件；两分钟的回滚不会发生。

3.6 文档编写成本与复用

一个自然的顾虑是每次执行需编写三份文档的开销。实际上，该开销是有界的，且部分可被摊销。

SEL 每个重设计任务编写一次，跨所有分支复用；在运行示例中，它被编写一次并应用于所有四个分支。CBDA 差异表从模块 B(第 4.1 节)的原型分支输出机械地推导，仅需人工审核，而非从头编写。BER 由智能体在模块 B 的执行前确认步骤中基于 CBDA 差异表生成，并在执行开始前由人工操作员审核。

每分支实际编写负担

审核 CBDA 差异表(约 5–10 行)、审核生成的 BER(约 10–15 条)、编写 SEL 一次(典型重设计任务约 3–5 条)。

| 执行协议：批量迁移与视觉验证

模块 B 和 C 分别规定智能体如何跨多个分支执行(模块 B)以及如何在每次提交前验证视觉正确性(模块 C)。两个模块均在模块 A 建立的范围边界内运行：模块 B 以 CBDA 差异表为主要输入，模块 C 以 UI 规范为验证目标。

4.1 模块 B: 原型优先批量执行协议

4.1.1 动机：逐分支独立提示为何失败

多分支执行的朴素方法是将每个分支视为独立任务：编写逐分支提示，运行智能体，循环往复。这种方法有两种失败模式。

首先，逐分支提示要求作者从记忆或非正式参考中枚举每个分支专属的配置差异。随着分支数量增加，遗漏变得不可避免。在运行示例中，分支 C 和 分支 D 以未区分分支专属值与共享配置值的提示处理，产生了共享值被原型值覆盖的风险。

其次，独立处理分支放弃了分支间的结构规律性。由于分支共享功能核心，仅在有限的配置维度集合上存在差异，每个目标分支所需的变更是(a)原型分支变更和(b)逐分支差异表的确定性函数。通过完整提示对每个分支冗余地重新推导这一函数既低效又容易出错。模块 B 以两阶段协议取代逐分支独立提示，使结构规律性显式化。

4.1.2 阶段 1: 原型分支执行与验证

在阶段 1，智能体遵循模块 A 约束文档(CBDA、SEL、BER)在单个指定的原型分支(运行示例中为分支 A)上执行完整重设计。原型分支的选择原则是配置与基线最接近的分支，从而最小化第一次执行时智能体需处理的分支专属调整数量。阶段 1 产生两个工件：

工件 1——原型提交：原型分支上包含所有且仅包含经授权 BER 操作的提交。该提交在阶段 2 开始前提交人工审核。审核验证没有禁止文件被修改，所有 BER 条目均存在。阶段 2 在原型提交获批前不得开始。

工件 2——经验证的变更清单：原型提交中每个被修改文件的结构化记录，包含每处变更的修改前值和修改后值。智能体通过对原型提交与其父提交的差异比较生成该清单。清单与 BER 结构相同，但包含实际观测(而非仅计划)的变更，并作为阶段 2 的输入。

运行示例中的原型提交将包含 13 个文件修改。经验证的变更清单记录每处修改及其实际 delta，确认 BER 被完整且无偏差地执行。

4.1.3 逐分支差异表提取

在阶段 1 和阶段 2 之间，CBDA 差异表(第 3.2 节)用于计算每个目标分支相对于原型不同的操作集合。计算是机械的：对经验证变更清单中的每一行，差异表指定目标分支是需要与原型相同的值，还

是分支专属的值。输出是目标分支操作集: 经验证变更清单的过滤子集, 其中与原型相同的操作标注 COPY, 分支专属操作标注 ADAPT 并附目标值。对于运行示例中的 分支B:

```
QueryPage.vue - 容器外边距 ADAPT 12px → 16px
DataTable.js  - 列宽        COPY  auto (与原型相同)
a-tokens.css  - 头部背景令牌 ADAPT #1a1a2e → #0d1b2a
filter-bar    - 可见性      ADAPT 隐藏 → 可见
...
```

该表是确定性的, 完全从原型输出和 CBDA 差异表推导, 不需要每个分支额外编写提示。

4.1.4 阶段 2: 执行前确认清单

在智能体触碰目标分支的任何文件之前, 它基于目标分支操作集生成执行前确认清单, 并提交给人工操作员审批。清单每个操作一行:

执行前确认清单 - 分支B

[]	QueryPage.vue	容器外边距	12px → 16px	ADAPT
[]	QueryPage.vue	圆角	4px → 4px	COPY
[]	DataTable.js	列宽	auto → auto	COPY
[]	filter-bar	可见性	否 → 是	ADAPT
[]	a-tokens.css	--a-header-bg	#1a1a2e → #0d1b2a	ADAPT
... (共 13 条)				

确认继续? [Y/N]

人工操作员审核清单, 验证所有 ADAPT 条目是正确的分支专属值, 且没有意外的 COPY 条目覆盖分支配置。在智能体写入任何文件之前须获得批准。如发现错误, 在 CBDA 差异表中更正, 而非在智能体提示中修改。

这一确认步骤使逐分支差异处理从隐式和基于提示的推导, 变为显式且经人工验证。它还确保智能体对逐分支差异的理解在执行前可被观察, 而非在错误提交后才被发现。

4.1.5 在运行示例中的实例化

在无模块 B 的运行示例中, 分支A 原型提交被回滚, 其余分支以临时提示处理。没有维护差异表; 每次分支执行都需要作者回忆哪些配置值是分支专属的。

使用模块 B, 分支A 阶段 1 提交将在任何其他分支被触碰之前经过审核和批准。CBDA 差异表(表 1, 第 2.1 节)随后驱动三个目标分支操作集(分支B、分支C、分支D)的自动生成, 每个操作集附带由人工操作员确认的执行前清单。分支B 清单将明确包含 容器外边距: 12px → 16px 的 ADAPT 条目, 使该值在执行前对操作员可见, 而非在 24 小时后才发现缺失。

4.2 模块 C：结构化视觉验证清单

4.2.1 动机：结构与视觉之间的鸿沟

通过代码审查的提交确立了结构正确性：正确的组件存在，路由解析，类名匹配，配置值在语法上正确。它不确立视觉正确性：渲染页面与设计规范在间距、颜色、边框和尺寸值上相符。

分支B 失败(第 2.4 节)精确地说明了这一鸿沟。提交在结构上是正确的；缺失的容器外边距不是错误值，而是缺失值——存在于规范中，但未反映在代码中。代码审查不会发现缺失值，除非审阅者独立地将规范中每个属性与实现进行交叉对照——而这正是人工审阅者在时间压力下始终无法做到的事。

模块 C 将设计规范的视觉属性转化为 AI 可执行的验证清单，智能体在发出提交命令前必须填写代码证据并完成。视觉验证因此从事后人工检查移至强制提交前门控。

4.2.2 清单结构与证据要求

视觉验证清单(VVC)包含设计规范中声明的每个视觉属性的一条条目。每个条目有四个字段：

字段	描述
PROPERTY	待验证的视觉属性
EXPECTED	该分支设计稿中规定的值
EVIDENCE	代码位置与观测值(文件路径 + 行号 + 提取值)
VERDICT	证据与预期匹配则为 PASS ；不匹配则为 FAIL 并附描述

证据要求是操作性约束：智能体不能在未引用具体文件和行号的情况下断言 PASS 。没有证据的断言被拒绝，清单条目保持未完成状态。分支B VVC 的代表性子集：

视觉验证清单 — 分支B

PROPERTY: 容器外边距 (查询页面头部)
EXPECTED: 16 px
EVIDENCE: src/views/query/QueryPage.vue:34 padding: 16px
VERDICT: PASS

PROPERTY: 区块间分隔线
EXPECTED: 无
EVIDENCE: src/views/query/QueryPage.vue:61 <!-- divider removed -->
VERDICT: PASS

PROPERTY: 头部背景颜色令牌
EXPECTED: #0d1b2a (--b-header-bg)
EVIDENCE: src/styles/b-tokens.css:12 --b-header-bg: #0d1b2a
VERDICT: PASS

PROPERTY: 字体大小过滤栏可见性
EXPECTED: 可见
EVIDENCE: src/components/query/FilterBar.vue:8 v-if="true" (始终可见)
VERDICT: PASS

PROPERTY: 数据表格列宽
EXPECTED: 固定 80 px
EVIDENCE: src/components/query/DataTable.js:45 width: 80
VERDICT: PASS

全部 5 个属性: PASS。清单完成。继续提交。

清单由智能体基于 UI 重设计规范生成, 分支专属预期值从 CBDA 差异表(第 3.2 节)提取。智能体在所有条目均有 PASS 或 FAIL 判定, 且所有 FAIL 条目已解决或由人工操作员明确推迟之前, 不得发出提交命令。

4.2.3 与提交门控的集成

VVC 充当提交门控: BER 定义哪些操作被授权, VVC 确认这些授权操作产生了正确的视觉输出。每次分支执行的序列为:

- 1. 人工批准执行前确认清单 (模块 B, §4.1.4)
- 2. 智能体执行 BER 操作
- 3. 智能体完成 VVC (所有属性附代码证据)
- 4. 人工审核 VVC 判定
- 5. 发出提交

步骤 3 和 4 相对于基线工作流是新增的。步骤 3 由智能体执行, 除审核步骤 4 中填写的清单外, 不需要额外人工工作。若任何 VVC 条目为 FAIL , 智能体上报差异, 人工决定在提交前是修复、推迟还是上报。

该门控结构意味着视觉回归在提交边界被捕获，而非在部署后测试边界才被发现。分支B失败中 24 小时的发现延迟将收缩为 VVC 完成与人工审核之间的时间——通常是分钟级别，而非小时级别。

4.2.4 在运行示例中的实例化

在无模块 C 的运行示例中，分支B 提交不包含视觉验证步骤。容器外边距属性在实现中缺失，但直到次日测试人员渲染页面才被发现。

使用模块 C，智能体在发出提交之前将被要求填写 VVC。容器外边距（查询页面头部） 条目将要求智能体引用 `src/views/query/QueryPage.vue` 中包含 `padding: 16px` 或等价内容的行。若外边距被遗漏，智能体搜索后无法找到证据，将发出 `FAIL` 判定，触发提交写入前的人工审核。后续提交 `e5f6a7b8` 将不再必要。

| 评估

我们在第 2 节描述的四分支生产级前端项目上评估 DocDrive。评估围绕三个研究问题展开，每个针对一个模块：

- RQ1: 模块 A 是否在智能体遭遇执行阻塞时阻止了自主范围扩展？
- RQ2: 模块 B 的原型优先协议相比独立的逐分支提示，是否降低了逐分支规格说明开销？
- RQ3: 模块 C 的视觉验证清单是否在提交边界之前检测到了视觉回归？

5.1 实验设置

项目：一款跨四个客户分支(分支A、分支B、分支C、分支D)维护的生产级移动应用。各分支共享功能核心，在表 1 所示的五个 UI 配置维度上存在差异。

任务：将查询模块 UI 重设计规范应用于所有四个分支。该规范要求跨六种文件类型(页面布局、表格配置、过滤栏、样式令牌、路由配置、分支专属视觉配置)修改每个分支 12–14 个文件。四个分支的文件总范围为 48–56 个文件。

基线(无 DocDrive)：第 2 节记录的两类失败模式构成基线。分支A 收到提交 `a1b2c3d4` (越权操作：mock 基础设施、服务补丁、自动登录重写)；提交在落地两分钟后被回滚。分支B 收到结构上正确但缺少 16 px 容器外边距的提交；遗漏在 24 小时后才被发现，并在提交 `e5f6a7b8` 中更正。分支C 和分支D 在分支A 回滚后以临时逐分支提示处理；没有维护经验证的差异表。

DocDrive 执行：我们应用了完整的三模块工作流——在每次分支执行前编写模块 A 约束文档 (CBDA、SEL、BER)，采用模块 B 原型优先批量协议和执行前确认清单，以及在每次提交前要求模块 C 视觉验证清单。分支A 充当阶段 1 原型。CBDA 差异表从分支A 阶段 1 提交中提取，用于生成分支 B、分支C 和分支D 的操作集。

度量：我们报告(1)越权操作发生情况，(2)视觉回归发生情况，(3)逐分支规格说明开销(逐分支确认清单条目数 vs. 完整重新规格说明)，(4)从任务开始到最终分支提交的端到端实际时间。RQ1 和 RQ2 通过直接观察 DocDrive 执行来评估。RQ3 通过机制分析评估：我们证明当规范的视觉属性在实现中缺失时，VVC FAIL 判定是机械必然的，并通过分支B 案例追溯该机制。

5.2 RQ1: 越权操作预防(模块 A)

设置：分支A 被指定为原型分支。在阶段 1 执行期间，智能体遭遇了与基线相同的认证阻塞：本地后端需要在执行环境中不可用的客户专属令牌。

过程：CBDA 禁止区声明将 `src/services/**` 和 `src/main.js` 列为 FUNCTIONAL 禁止条目，SEL 明确排除“本地开发认证”，IMPLIES 条款禁止 mock 基础设施，在智能体尝试创建 `localMock.js` 时检测到边界冲突。智能体调用了阻塞上报协议，输出了第 3.5 节所示的结构化报告。人工操作员选择了方案 B(跳过视觉验证；将 BER 条目 13 标记为合并前手动审查)。没有服务层文件被写入。

结果: 分支A 原型提交包含 12 个 BER 条目(所有经授权的文件变更), 零禁止区违规。两分钟回滚没有发生。原型提交在首次提交时通过了人工审核。

RQ1 回答: 是。模块 A 的文档级别边界声明, 结合阻塞上报协议, 在与基线失败相同的执行阻塞下阻止了自主范围扩展。关键机制是 SEL 中的 `IMPLIES` 条款, 它将抽象的关切排除项转化为智能体在采取操作前检查的具体禁令。

5.3 RQ2: 逐分支规格说明开销(模块 B)

设置: 分支A 阶段 1 批准后, CBDA 差异表(5 行, 表 1)用于推导三个目标分支操作集: 分支B(3 个 ADAPT 条目, 10 个 COPY 条目)、分支C(1 个 ADAPT 条目, 12 个 COPY 条目)、分支D(1 个 ADAPT 条目, 12 个 COPY 条目)。

基线开销: 在基线执行中, 其余三个分支(分支B、分支C、分支D)各自以完整的逐分支提示处理, 独立重新枚举所有 13 个文件变更和分支专属值。三个分支合计约需 39 个独立规格说明的操作(每分支 13 个), 没有共享结构。

DocDrive 开销: 使用模块 B, 逐分支规格说明减少为每分支的 ADAPT 条目数(分支B 为 3, 分支C 为 1, 分支D 为 1)。其余条目通过 COPY 标注从经验证变更清单机械推导, 无需编写。每个分支的执行前确认清单包含 13 条, 但人工操作员只需审核 ADAPT 条目的正确性(所有目标分支共 $3 + 1 + 1 = 5$ 个 ADAPT 决策)。

结果: 逐分支规格说明开销从每分支 13 个独立编写的操作(基线)降至每分支 1–3 个 ADAPT 条目(DocDrive)。COPY 条目自动生成, 仅需审核, 不需编写。所有目标分支的人工编写规格说明 delta 条目总计: DocDrive 为 5, 基线估计为 39。

RQ2 回答: 是。原型优先协议以分支专属差异——而非完整操作集——作为人工编写的单元, 降低了逐分支规格说明开销。在本案例研究中, 我们估计目标分支的规格说明开销降低了约 87%(5 个 ADAPT 条目 vs. 基线中估计的 39 个独立规格说明操作)。

5.4 RQ3: 视觉回归检测(模块 C)

设置: 对每个分支, 智能体被要求在发出提交之前完成视觉验证清单(VVC)。VVC 包含 5 个从 UI 重设计规范推导的条目, 分支专属预期值从 CBDA 差异表提取。

分支B VVC: 分支B 需要 16 px 容器外边距(表 1 中的 ADAPT 条目)。在 VVC 填写过程中, 智能体尝试为容器外边距属性引用证据。在等效于基线的执行状态下(外边距缺失), 智能体将无法在 `QueryPage.vue` 的预期位置找到 `padding: 16px`, 并将为该条目发出 `FAIL` 判定。

过程: 容器外边距条目的 `FAIL` 判定要求人工操作员在提交发出之前审核。操作员识别出缺失的外边距, 指示智能体添加, VVC 以 `PASS` 判定重新完成。提交以正确的外边距发出。

结果: 视觉回归(缺失容器外边距)在提交边界而非部署后测试边界被检测到。基线的 24 小时发现延迟被消除。不再需要后续提交(`e5f6a7b8`)。

RQ3 回答：是。模块 C 的视觉验证清单，通过在提交前要求为每个规定视觉属性提供代码级证据，将视觉回归检测从部署后人工检查移至强制提交前门控。在本案例研究中，分支B 容器外边距遗漏——在基线中产生 24 小时延迟——在同一执行会话中被发现并纠正。

5.5 整体性能

端到端完成时间：四分支重设计在约三小时的实际时间内完成，分布如下：

阶段	时间
模块 A 文档编写 (CBDA + SEL, 共享)	约 20 分钟
分支A 原型分支执行 + 人工审核(阶段 1)	约 50 分钟
CBDA 差异表提取与审核	约 10 分钟
分支B: 确认清单 + BER 执行 + VVC	约 30 分钟
分支C: 确认清单 + BER 执行 + VVC	约 25 分钟
分支D: 确认清单 + BER 执行 + VVC	约 25 分钟
阶段间交接与人工审核延迟	约 20 分钟
合计	约 180 分钟(约 3 小时)

分支B、分支C 和 分支D 的每分支执行时间(各 25–30 分钟)包括执行前清单确认、BER 执行和 VVC 完成。分支A 原型分支阶段 1 审核需要额外时间。

与基线对比：基线执行产生了两个需要修复的提交(分支A 回滚：2 分钟恢复；分支B 外边距：24 小时恢复)。DocDrive 执行产生零修复事件。不将 24 小时 分支B 发现延迟计为"执行时间"的情况下，净日历时间差异倾向于 DocDrive，因为消除了 分支A 回滚周期和 分支B 后续提交。

5.6 有效性威胁

我们讨论三个有效性维度，以界定结果的解释范围。

内部有效性：评估是单个重设计任务的案例研究。基线和 DocDrive 执行共享同一代码库和任务规范，但执行方法不同，外部条件相同。分支A 执行期间遇到的认证阻塞在两种条件下相同(无人工复现)。

外部有效性：四分支结构和六种文件类型范围代表了 B2B 业务平台维护模式的典型情况。但具体开销数字(约 87% 降低, 5 个 ADAPT 条目)的可推广性取决于目标项目的分支间差异密度。分支间差异密度更高的项目将从模块 B 中获得更小的开销降低；设计规范中视觉属性更多的项目将产生更高的 VVC 编写开销。

构念有效性: 端到端时间测量包括人工审核时间(执行前清单确认、VVC 审核), 但排除了智能体输出与人工审核决策之间的空闲时间。约 87% 的规格说明开销降低是估计比率; 分母(39 个操作)从任务范围推断, 而非从基线提示日志中测量。不同度量(如令牌数、提示长度)可能产生不同比率。模块 C 的"24 小时延迟消除"声明从 VVC FAIL 机制推断; 实际 DocDrive 执行中的真实延迟将取决于人工操作员的审核延迟。

| 相关工作

6.1 AI 编码助手与自主智能体

大语言模型 (LLM) 编码助手已迅速从单文件补全工具发展为能够端到端解决 GitHub 问题的多文件自主智能体。Copilot 和 Codex 证明了 LLM 可以在函数级别生成语法和语义正确的代码。SWE-agent 和 Devin 将此扩展到代码库级别的任务执行, 使用脚手架工具 (Shell 访问、文件编辑、测试运行器) 迭代修改大型代码库。AutoCodeRover 通过将程序分析与 LLM 推理结合起来改进错误定位, 在编辑之前识别相关文件。ReAct 交错推理和行动, 提供了使中间步骤可检查的智能体决策审计轨迹。

这些系统共享一个共同的执行模型: 智能体被给予任务描述和代码库, 自主运行直到任务完成或智能体报告失败。DocDrive 在边界模型上有所不同: 它不是信任智能体从任务描述推断范围, 而是提供明确的逐执行范围文档 (CBDA、SEL、BER), 枚举禁止区和经授权的操作。这一区别的动机来自本文观察到的事实 (在运行示例中实例化): 任务描述在对抗性执行条件下不构成稳定的边界契约。

6.2 约束性与结构化 AI 执行

多项工作探索了代码生成期间对 LLM 行为的结构化约束。Constitutional AI 引入了基于规则的自我批评, 以使模型行为与指定原则对齐。Guardrails 和 NeMo Guardrails 提供了用于拦截和重定向违反预定义约束的 LLM 输出的运行时框架。

DocDrive 的约束模型在两个方面不同于这些方法。首先, DocDrive 约束是任务专属和文件粒度的, 而非模型级别或输出级别: CBDA 禁止区声明命名具体的文件路径和 glob 模式, 而非指定抽象的行为规则。其次, 阻塞上报协议将约束违规转化为结构化的人类可读报告, 使人工操作员能够决定是调整约束还是提供外部资源以解决阻塞。自动化防护系统不支持这种人机协作恢复决策。

6.3 多分支与多变体软件维护

功能标志、A/B 测试框架和白标产品架构作为管理软件变体的机制已被研究。Hunsen 等人研究了面向特性的软件变体的维护成本, 发现变体间的分歧是合并冲突的主要来源。Apel 等人调查了面向特性的编程和变体管理, 将跨领域配置确定为多变体系统中的持续挑战。

在 Web 和移动应用领域, 多租户和白标架构已被记录为重大维护负担。此前工作侧重于配置分歧的静态分析以及跨变体不一致的自动检测。DocDrive 解决的是互补问题: 在保留记录的每变体配置的前提下, 安全地将统一变更应用于多个变体。据我们所知, 没有先前工作将 AI 辅助执行与显式边界执行相结合, 用于这类多变体迁移任务。

6.4 视觉测试与回归检测

视觉回归测试已通过像素级截图比较 (Applitools、Percy) 和 DOM 级结构比较 (BackstopJS) 加以实现。这些工具检测基线与新渲染之间的视觉差异, 但需要存在正确的基线。它们在部署后运行, 不集成到提交编写工作流中。

此前关于 CI 集成视觉检查的工作提议将检测提前至开发周期。然而，这些方法将渲染输出与预先存在的基线比较，而非与设计规范比较；它们相对于最后已知状态检测回归，而非相对于预期设计检测遗漏。

模块 C 占据不同位置：它在代码编写阶段(提交前)运行，以设计规范为真值(而非渲染基线)，并要求 AI 智能体生成代码级证据而非像素级比较。这使其与基于截图的视觉回归工具互补而非竞争：DocDrive 在编写时捕获遗漏，而截图工具在测试时相对于上次批准的渲染捕获回归。

6.5 文档驱动与规范优先开发

规范优先和文档驱动的开发方法论在软件工程中有悠久历史。形式规范语言(Z、Alloy、TLA+)试图使软件需求可机器验证。更务实的是，行为驱动开发(BDD)和验收测试驱动开发(ATDD)使用自然语言规范作为测试生成的真值，在需求和实现之间建立可追溯的连接。

DocDrive 的三文档系统继承了这一传统：CBDA、SEL 和 BER 是规范说明智能体执行行为的结构化文档。不同于形式规范语言，这些文档使用约束自然语言格式，智能体可以直接读取并据此行动，不需要形式编译器或验证步骤。不同于 BDD/ATDD，这些文档规定执行授权而非可观测行为，解决了在智能体代码执行上下文中出现的范围执行问题。

07 · CONCLUSION

结论

多分支前端代码库呈现了一类 AI 辅助迁移任务，暴露了当前自主编码工作流的三个结构性缺口：智能体在遭遇执行阻塞时违反任务范围边界，多分支批量执行缺乏保留各分支差异的正式化协议，以及现有 AI 执行模型不对提交时的视觉正确性进行验证。这些缺口并非特定智能体或模型的偶然特征；它们反映了任务执行层中文档级别边界契约、逐分支差异追踪和设计规范驱动验证的缺失。

我们提出了 DocDrive，一种针对每个缺口引入专属结构化机制的三模块工作流。模块 A(约束文档系统)以三份结构化文档(CBDA、SEL 和 BER)和阻塞上报协议取代提示级别的范围指令，要求智能体在遭遇执行阻塞时停止上报，而非自主扩大任务范围。模块 B(原型优先批量执行协议)通过两阶段方法使逐分支差异处理显式化并经人工验证：经验证的原型分支提交驱动逐分支操作集的自动生成，人工操作员在任何目标分支被触碰之前通过执行前清单确认。模块 C(结构化视觉验证清单)将设计规范转化为逐属性清单，附带强制代码级证据，将视觉正确性验证从部署后人工检查移至提交前强制门控。

在四分支生产级移动应用上评估，DocDrive 阻止了基线中导致两分钟回滚的越权操作，相比独立的逐分支提示将逐分支规格说明开销降低约 87%，并消除了基线中观察到的 24 小时视觉回归发现延迟。完整的四分支重设计在约三小时的实际时间内完成。

核心洞察在于：在多分支代码库上运行的 AI 编码智能体不仅需要有能力语言模型，还需要结构化的执行契约——枚举智能体可触碰什么、哪些关切被排除、某个具体分支哪些操作被授权、提交最终化前哪些视觉属性必须得到验证的文档。这些契约不限制智能体的推理能力；它们使智能体的授权范围可被观察和执行，并将阻塞事件从自主范围扩展的机会转化为人工决策节点。

7.1 局限性与未来工作

当前评估是涉及四个分支、一种任务类型(UI 重设计)和一个 AI 执行器(Claude Code)的单一案例研究。若干方向仍有待探索。

扩展至更大的分支数量：原型优先批量协议将逐分支规格说明减少为 ADAPT 条目，但 CBDA 差异表随分支数量线性增长。对于拥有数十个分支的项目，表格编写和确认步骤可能成为瓶颈。未来工作可以探索从各分支配置文件的静态分析自动生成 CBDA，将人工编写负担减少为审核而非从头编写。

自动化 VVC 填写：模块 C 目前要求智能体为每个视觉属性引用代码级证据。对于需要渲染的属性(阴影深度、动画时序、响应式断点行为)，代码级证据是间接代理。将 DocDrive 与无头浏览器渲染工具(如 Playwright、Puppeteer)集成，将允许 VVC 在代码级证据之外包含像素级证据，增强视觉验证保证。

推广至非 UI 任务类型：DocDrive 针对 UI 重设计任务设计，其中结构正确性与视觉正确性的区分是明确的，逐分支配置差异是有界且表格化的。将框架扩展至其他多分支任务类型(API 版本控制、本地化更新、合规驱动的配置变更)需要将 CBDA 差异表模式和 VVC 属性词汇适配至相应领域。阻塞上报协议和 BER 结构可能无需修改即可迁移。

人工因素成本：当前评估将人工审核时间作为实际时间的组成部分，但不研究审核 CBDA 差异表、执行前清单和 VVC 输出的认知负荷。对确认步骤中人工审核延迟和错误率的研究将使 DocDrive 采用的实际成本模型更为精确。