



2026年（第19届） 中国大学生计算机设计大赛

大数据实践赛作品报告

作品编号： 2026047411

作品名称： 电商智能决策沙盘系统

填写日期： 2026年4月17日

目 录

第 1 章 作品概述	1
1.1 产生背景与创意来源	1
1.1.1 产生背景	1
1.1.2 创意来源	1
1.2 作品的用户群体	1
1.3 主要功能与特色	2
1.4 应用价值与推广前景	2
1.4.1 应用价值	2
1.4.2 推广前景	3
第 2 章 问题分析	3
2.1 问题来源	3
2.2 现有解决方案	3
2.3 本作品要解决的痛点问题	4
2.4 解决问题的思路	5
2.4.1 功能和性能需求	5
2.4.2 数据集说明	5
2.4.3 具体数据样例（以核心的 Analysis）	5
第 3 章 技术方案	6
3.1 总体技术路线与框架	6
3.2 核心模块详细设计与解决思路	7
3.2.1 Dashboard 智能看板模块：多维数据实时流计算与渲染	7
3.2.2 Analysis 深度归因模块：双维度正交对比引擎（原创工作）	8
3.2.3 Decision 决策沙盘模块：大模型 Agent 推演预测（原创工作）	8
3.3 关键算法改进与特色	9
第 4 章 系统实现	9
4.1 软件设计与整体架构实现	9
4.2 数据来源与模型推理实现	10
4.3 核心模块的用户界面与工程实现细节	11
4.4 遇到的工程困难与解决途径	12
4.4.1 困难 1：对比分析场景下，API 接口数量爆炸与前端维护困难	12
4.4.2 困难 2：策略店铺批量生成时的计算资源消耗与稳定性	12
第 5 章 智能体使用情况	12
5.1 当前阶段	12
5.2 第二阶段规划（Agent 智能决策集成）	13
第 6 章 测试分析	13
6.1 测试环境与验证数据说明	13

6.2 系统功能响应与渲染性能测试	13
6.3 沙盒预测模型准确性分析	14
第 7 章 作品总结	14
7.1 作品特色与创新点	14
7.2 应用推广	15
7.3 作品展望	16
参考文献	17

第 1 章 作品概述

1.1 产生背景与创意来源

1.1.1 产生背景

在当前存量竞争的电商时代，商家面临着平台规则多变、流量成本高以及数据孤岛等严峻挑战。传统的电商运营高度依赖人工经验，往往是“先投入、后复盘”，这导致商家在营销投放、库存管理和预算分配上面临“看不见（全局数据）、算不清（ROI 与转化）、不敢动（牵一发而动全身）”的决策困境。高昂的试错成本成为制约电商企业尤其是中小商家利润增长的核心痛点。

1.1.2 创意来源

本作品的创意灵感来源于工业领域的“数字孪生（Digital Twin）”与游戏领域的“沙盘推演”概念。我们设想：能否为电商商家构建一个虚拟的平行运作空间？为此，我们引入 LSTM 时序预测模型与电商业务规律相结合的混合算法，打造了这款“电商智能决策沙盘系统”。系统将复杂的电商运营动作抽象为可控的数学变量（如营销预算、折扣力度、库存阈值等），让商家在真实消耗资金和库存前，能在沙盘环境中进行风险无损的“模拟推演”，实现从“事后归因”向“事前预测”的颠覆性转变。

1.2 作品的用户群体

本系统的目标用户群体明确，主要面向泛电商领域的 B 端商家及企业客户，具体涵盖以下核心角色：

（1）电商操盘手/店长：需要全局视角的业务监控与战略方向把控，依赖系统进行整体的降本增效决策。

（2）一线运营/营销人员：日常进行拉新、复购、折扣等策略制定的执行者，通过沙盘提前预测活动 ROI。

（3）数据分析师：需要深度的特征量化计算与业务归因分析，系统标准的

双维度正交对比模型可极大提升分析效率。

1.3 主要功能与特色

系统以“看见、看懂、推演、行动”为业务闭环，核心功能与特色分为三大模块：

(1) 智能看板 —— 全局数据感知：提供双维度的核心业务监视。包含基于时间线与用户流向的 Action 动态维度（如流量热力图、实时漏斗、桑基图）和基于商品属性的 Product 静态维度（如品类词云），帮助商家一目了然地“看见”系统状态与数据异常。

(2) 深度归因分析 —— 业务特征量化：首创“双维度正交对比标准（时间对比×店铺对比）”^[1]。提供核心的 ROI 效率矩阵图（可视化对比营销/库存/预算）与策略-库存周转散点图，精准定位“低转低销”或“高转高销”的策略区间，帮助商家“看懂”数据背后的逻辑。

(3) 决策沙盒 —— 零风险模拟推演：系统的“核心大脑”。允许商家以“创建新店铺”的方式，自由组合营销、库存、定价等策略参数。系统自动调用 LSTM 模型生成该策略下整年的用户行为与交易数据，支持多店铺并列对比，让决策从“单点预测”升级为“全景预演”。

(4) 智能分析 Agent —— 集成 Ollama+Qwen 大模型，可对沙盒生成的店铺数据进行自然语言问诊、多工具自动调用与深度诊断报告生成。

1.4 应用价值与推广前景

1.4.1 应用价值

(1) 降本增效：通过前置的沙盒推演，有效避免无效营销投入和库存积压，显著提升整体 ROI。

(2) 解绑风险：将高风险的商业试错转移至数字孪生沙盒中，打破商家“不敢轻易调整策略”的僵局。

(3) 数据资产化：将繁杂的业务数据转化为直观的策略指导，降低数据驱动运营的门槛。

1.4.2 推广前景

本作品在技术架构上采用了高度标准化的统一 API 设计（如双维度对比接口），前后端完全解耦，具备极强的可扩展性。不仅可无缝接入淘宝、京东等传统电商平台，也可快速适配抖音、快手等兴趣电商体系。未来，本系统极具商业化潜力，可作为标准化的 SaaS 产品向广大中小电商企业推广，市场前景广阔。

第 2 章 问题分析

2.1 问题来源

随着电商行业从“增量时代”全面步入“存量博弈时代”，商家的运营环境日益复杂。流量获取成本不断攀升，平台规则动态多变，供应链与库存压力剧增。

在传统的电商运营模式中，商家的决策主要依赖于“事后数据复盘”与“人工经验判断”。这种模式存在明显的滞后性，运营人员在面临营销投放（Marketing）、库存调拨（Stock-management）和预算定价（Budget）等关键决策时，往往处于“牵一发而动全身”的境地。由于缺乏科学的“事前推演”机制，商家只能通过真实的资金和流量在市场上进行试错，这不仅导致了极高的试错成本，还极易引发库存积压或 ROI（投资回报率）倒挂的风险。由此，电商操盘手在复杂业务线前普遍面临“看不见（全局状态）、算不清（特征与收益）、不敢动（高成本试错）”的严峻挑战。

2.2 现有解决方案

目前，针对电商数据分析与辅助决策，市场上已有部分解决方案，前人的解决途径主要集中在以下三个方向：

（1）传统 BI 数据看板（如 Tableau、PowerBI 等）：擅长对历史海量数据进行可视化清洗与展示。但其本质依然是“后验性”的工具，主要解决“过去发生了什么”的问题，缺乏针对未来策略的预测能力和业务深度归因能力^[2]。

（2）平台原生数据工具（如淘宝生意参谋、京东商智等）：依托平台底层数据，指标丰富且权威。但其数据往往处于“孤岛”状态，仅提供单维度的指标

呈现，缺乏将营销、库存、财务进行跨维度交叉诊断的灵活性；且不具备虚拟环境下的策略模拟功能。

(3) 传统 A/B 测试系统：通过线上分流测试不同策略。虽然能得出结论，但需要消耗真实的线上流量与资金，对于中小商家而言，试错成本过高，且测试周期长，难以应对快速变化的市场节奏。

表 1 本作品与同类竞品的多维度比较

比较维度	传统 BI 报表工具	平台原生数据工具	传统 A/B 测试工具	本作品 (智能决策沙盘系统)
核心定位	事后数据呈现	平台内数据监控	线上真实流量测试	事前沙盘推演与深度归因
试错成本	无	无	极高	极低 (零风险虚拟推演)
对比分析能力	需人工搭建复杂模型	单一时间或同行对比	仅限实验组与对照组	双维度正交对比 (时间跨度×店铺主体)
策略连贯性	各模块割裂	偏向流量侧分析	聚焦单一页面或玩法	打通“营销-库存-预算”三维变量

2.3 本作品要解决的痛点问题

传统 A/B 测试系统：通过线上分流测试不同策略。虽然能得出结论，但需要消耗真实的线上流量与资金，对于中小商家而言，试错成本过高，且测试周期长，难以应对快速变化的市场节奏。

基于上述对现有解决方案的对比分析，本作品致力于解决电商商家在实际运营中的三大核心痛点：

(1) 归因分析极度困难（算不清）：传统工具无法直观量化各环节的效率与收益贡献。当店铺业绩波动时，商家难以迅速定位是“拉新策略（pull_new）”出错、还是“库存周转（stockTurnover）”异常。

(2) 缺乏无损的试错环境（不敢动）：真实商业环境中无法撤回操作。商家在调整产品定价或大促备货时，极度缺乏一个能够量化决策影响、提前预警业务风险的“数字孪生”模拟环境。

(3) 数据对比标准不统一（看不透）：日常运营中频繁需要全量与增量、主店与竞对店的交叉比对，但传统系统往往接口混乱、对比逻辑不互通，导致数据分析效率低下。

2.4 解决问题的思路

2.4.1 功能和性能需求

功能需求：系统需实现“数据感知（Dashboard） - 深度归因（Analysis） - 模拟推演（Decision）”的业务闭环。具备高实时性的流量漏斗监控、基于双维度正交对比（时间/店铺）的高级特征量化（如 ROI 效率矩阵、策略-库存散点图），以及基于大模型 Agent 的沙盒预测能力。

性能需求：所有图表需支持统一维度的秒级响应；前端按需加载，热力图等渲染要求平滑无卡顿；对比模式下两套数据源需严格对齐。

2.4.2 数据集说明

(1) 数据来源与获取方式：为验证系统架构与核心算法的可行性，本系统采用离线预生成的方式构造模拟数据集。基于电商业务逻辑（如周期性波动、促销爆发系数、转化漏斗概率），通过 Python 脚本一次性生成覆盖一整年时间跨度的脱敏运营数据，并持久化至轻量级数据库 SQLite 中，便于 Demo 阶段的快速部署与演示。

(2) 数据特点：具备明显的时间序列特性（年/月/周/日多粒度）、多维结构（包含 action 动态行为与 product 静态属性），且高度耦合业务逻辑。

(3) 数据规模：Demo 版本生成约 150 万条用户行为日志及 2 万条 SKU 快照记录，足以覆盖典型的中小电商店铺运营分析场景^[3]。

2.4.3 具体数据样例（以核心的 Analysis）

```
{
  "data": {
    "mainShopId": "shop_001",
    "compareShopId": "shop_002",
    "timeCompareType": "latest_vs_full",
```

```
"mainTime": {
  "startTime": "2026-04-04 00:00:00",
  "endTime": "2026-04-04 23:59:59"
},
"statType": "week",
"loadAll": true
}
}
```

响应样例（库存健康度散点数据）：

```
{
  "chartData": {
    "stockHealthList": [
      {
        "category": "electronics",
        "consumeIndex": 1.2,
        "sellableDays": 2.5,
        "abnormalType": "high_consume",
        "currentStock": 50,
        "inTransitStock": 30,
        "dailyConsume": 20
      }
    ]
  }
}
```

第 3 章 技术方案

3.1 总体技术路线与框架

本系统以“数字孪生”与“智能推演”为核心思想，致力于解决电商复杂场景下的决策归因与事前预测问题。系统从原理层面构建了一套闭环的 EDA（Event-Driven Architecture，事件驱动架构），将复杂的电商运营动作抽象为严谨的数学与逻辑变量。

本系统在 Demo 验证阶段采用轻量化单体架构，以快速验证“双维度对比分析”与“LSTM 沙盒预测”两大核心功能的业务闭环。整体技术路线如图 3-1 所示：

数据层：采用 SQLite 作为统一存储引擎，存放预先生成的历史时序数据与策略模拟结果。该方案极大降低了部署复杂度，使得系统可在任意环境下一键启动。

逻辑层：基于 FastAPI 构建 RESTful API 服务，实现双维度正交对比查询与 LSTM 模型推理接口。

前端层：Vue3 + ECharts/AntV，负责可视化渲染与用户交互。

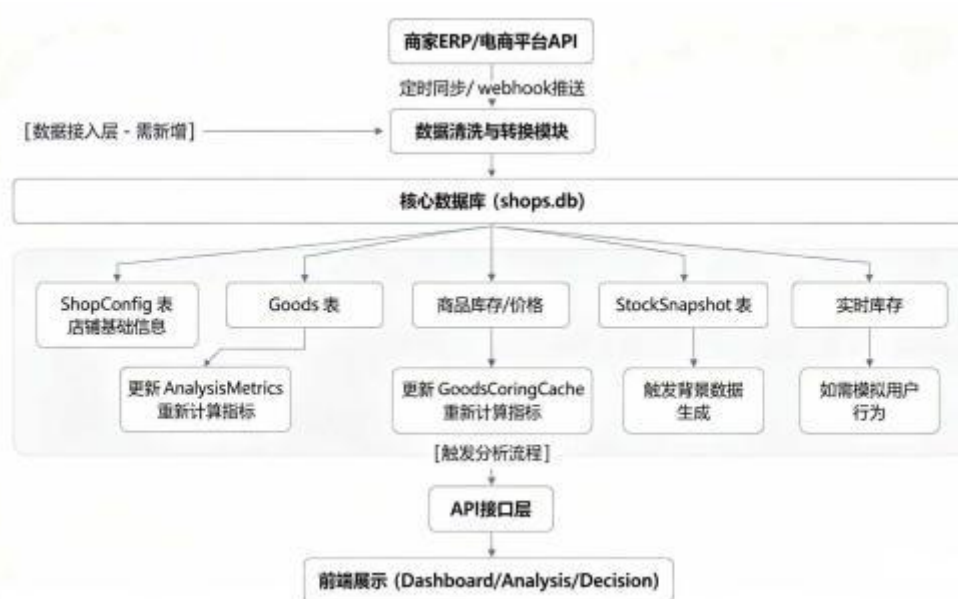


图 3-1 系统总体技术路线与架构图

3.2 核心模块详细设计与解决思路

3.2.1 Dashboard 智能看板模块：多维数据实时流计算与渲染

(1) 解决思路：为商家提供多维度的历史数据全景感知能力。

(2) 技术实现：数据结构按业务场景分为 action（流量热力图、漏斗图）与 product（品类词云）两大维度。

(3) 渲染优化：前端采用按需加载与图表实例复用策略。针对“12month+24hours”粒度的时间热力图，系统在后端进行数据预聚合，将大量明细数据压缩

为前端可直接渲染的矩阵格式，保障了静态演示场景下的流畅交互体验。

3.2.2 Analysis 深度归因模块：双维度正交对比引擎（原创工作）

1. 解决思路：针对电商运营“算不清”的问题，本模块抛弃了传统的单维硬编码对比，原创性地提出并实现了一套“双维度正交对比标准”接口协议与算法。

2. 原创模型与协议详述：我们把对比拆解成两个完全独立、可自由组合的维度，互不干扰：

时间维度(T)：latest (最近增量) vs full (全量历史)。店铺维度(S)：mainShop (当前主店) vs compareShop (参照对比店)。基于此，底层接口协议高度统一，支持任意 4 种自由组合（无对比、仅时间对比、仅店铺对比、双维度对比）。前后端交互协议强制对齐，mainData 与 compareData 响应结构完全一致。

3.2.3 Decision 决策沙盘模块：大模型 Agent 推演预测（原创工作）

1. 解决思路：构建数字孪生沙盘环境，实现零风险的策略模拟推演。

2. 核心模型详述：系统构建自变量 - 因变量映射模型 $F(x)=y$ 。

3. 模块核心:基于 LSTM 的电商流量生成模型^{[4][5]}，是实现沙盘推演的算法核心。

4. 模型输入设计：融合 12 维高维业务特征，包含商品类目、价格策略、流量渠道等 10 维类别特征，以及归一化价格、归一化库存 2 维连续特征，全面覆盖电商运营核心变量。

5. 特征编码机制：采用哈希分桶+独立嵌入层（32 维）处理类别特征，适配动态新增的业务属性；连续特征线性归一化至[0,1]区间，最终将所有特征向量拼接，作为 LSTM 的统一输入。

6. 模型输出：精准预测用户点击、加购、购买三类行为概率分布，同时输出优惠券使用概率，量化用户决策结果；依托 LSTM 门控结构记忆长周期时序特征^[4]，模型可捕捉营销、库存、时段等因素的滞后影响，完成流量与转化行为的智能推演。

7. Demo 阶段实现方式：为完整演示“策略→数据→决策”的业务闭环，系统采用“店铺级全量生成”机制。商家通过店铺管理 API 提交带有策略参数（如价

格策略、库存策略、渠道策略) 的创建请求后, 后端立即启动并行生成器, 按季度分批调用 LSTM 模型为该策略独立生成整年的用户行为日志与库存变动数据, 直接写入 SQLite 数据库。生成过程异步执行, 前端轮询生成状态, 完成后即可无缝接入 Dashboard、Analysis 及 Agent 的全部分析能力。该方案避免了实时推理延迟, 同时保留了“不同策略对应不同完整数据”的沙盒对比本质。

3.3 关键算法改进与特色

1. 策略-库存双向寻优算法的改进: 传统的库存与营销往往是割裂的, 本系统通过“策略-库存周转散点图”引入了一种联合寻优算法。算法不仅考虑单品的销量(横轴映射), 还将该策略组合下的库存周转天数(纵轴映射)引入目标函数。改进后的算法可以有效识别出“左下象限(低转低销-需优化策略)”与“右上象限(高转高销-高价值可推广)”的策略集, 并在沙盒模块中优先为高价值策略集分配权重。

2. 前后端完全解耦的数据通信协议(基于标准化的 JSON API 设计): 这是本系统工程层面的一大特色。所有图表响应结构、对比逻辑全量/增量加载规则均在 API 层面(JSON)完成了标准化定义。前端仅负责复用渲染逻辑, 新增任何高级分析图表(具体类型可灵活定义)均无需重构底层请求链路, 赋予了系统极强的可扩展性与商业化 SaaS 潜力。

3. LSTM 流量生成模型的特征工程优化针对电商行为数据多类别、高离散的特点, 设计专属特征编码方案: 通过哈希分桶解决动态特征扩展问题, 32 维嵌入层挖掘特征语义信息, 连续特征归一化统一数据尺度; 多维度特征融合方案让模型同时学习商品属性、运营策略、时间因素的交互关系, 大幅提升行为模拟的真实性。

第 4 章 系统实现

4.1 软件设计与整体架构实现

本系统 Demo 版本采用前后端分离的轻量级架构, 以降低部署门槛与演示复

杂度:

(1) 前端: Vue3 + ECharts/AntV。

(2) 后端: Python FastAPI, 选择该框架的原因是开发效率高、适合快速迭代验证想法可行性, 能够在短时间内搭建出最小化可行产品。

(3) 数据库: SQLite。考虑到 Demo 阶段数据为离线预生成且无需处理高并发写入, SQLite 以其零配置、单文件便携的特性成为最合适的选择。

4.2 数据来源与模型推理实现

1. 数据来源与构造

系统 Demo 所用数据为离线预生成。生成脚本结合电商业务的季节性与促销规律, 使用 PyTorch 框架训练 LSTM 时序预测模型, 参考电商行为序列建模与日志生成方案^{[5][6]}: 模型基于 Rec-Tmall 真实电商数据集训练, 学习用户行为时序依赖、时段偏好、价格敏感度等真实规律; 采用哈希分桶、特征嵌入、归一化、向量拼接的标准化编码流程, 处理 12 维输入特征; 模型学习完成后, 批量生成一整年高度仿真的脱敏用户行为日志, 精准还原购物序列连贯性与业务逻辑。

数据生成: 系统在创建店铺 API 中嵌入了并行生成器。当用户提交带有策略参数的创建请求时, 后端立即调起多个进程, 按照季度分批调用训练好的 LSTM 模型, 生成该策略对应的全年用户行为日志与库存变动数据, 直接写入 SQLite。整个过程对用户透明, 完成后即可查询。

2. 决策预测模型 (LSTM) 接入与训练

决策沙盒的核心是不同策略下全量业务数据的生成。系统将 LSTM 模型的推理能力封装在店铺创建流程中: 当用户通过店铺管理 API 创建新店铺并指定策略参数时, 后端 worker 立即加载训练好的 LSTM 模型权重, 以该策略作为条件特征输入, 按季度并行生成该店铺全年的用户行为序列与交易数据, 并自动计算库存周转、ROI 等分析指标一同入库。整个过程对用户透明, 无需手动训练或等待, 生成完成后该店铺即可与已有店铺并列对比。这一设计将 LSTM 的预测能力直接转化为“策略→店铺数据”的生成流水线, 实现了零实时推理延迟、全量数据可查的沙盒推演。

4.3 核心模块的用户界面与工程实现细节

1. Dashboard 模块（数据实时渲染实现）界面实现：实现了核心 KPI 概览、基础折线/柱状图以及实时点击流量桑基图。技术增量：为应对长时间跨度（如 day-avg 和 hours-avg）热力图的数据密集型渲染，前端引入了“按需队列加载（requestAnimationFrame）”与“虚拟滚动列表”技术，确保浏览器在绘制大量 DOM 节点和 Canvas 画布时保持 60fps 的流畅度。

2. Analysis 模块（双维度正交对比 API 规范的落地）工程落地：该模块是系统工程规范的核心亮点。我们彻底摒弃了传统大屏“一个图表一个定制 API”的冗余做法。实现了一套强约束的统一下发 JSON 协议。实现逻辑：前端发送包含 mainShopId、compareShopId、timeCompareType (latest_vs_full) 的标准请求；后端通过策略模式（Strategy Pattern）动态组装 SQL/查询条件，统一返回格式一致的 mainData 和 compareData。前端仅需一份渲染组件逻辑，即可兼容无对比、时间对比、店铺对比及双维度对比 4 种业务场景。

3. Decision 模块（策略配置与店铺批量生成界面）

（1）界面实现：提供策略店铺创建表单，商家通过下拉菜单或选择器配置多组策略参数（如价格策略、库存策略、营销渠道、用户策略等），一键提交批量创建请求。系统展示已生成的策略店铺列表，每条记录清晰标注其采用的策略组合、生成状态及数据量。

（2）工程闭环：前端通过店铺管理 API 提交创建请求后，后端并行生成器立即响应并开始数据生成。前端轮询每个店铺的生成进度，完成后自动更新列表。商家可随时勾选任意两个或多个店铺，一键跳转至 Analysis 模块进行双维度正交对比，或直接通过 Agent 发起自然语言分析，实现从策略配置到全景对比的流畅决策闭环。

4. 系统部署方法采用基于 SSH 手动管理的部署方式，部署架构为三层服务器与两层反向代理：公网入口使用 Nginx，中转层与核心业务层均使用 Caddy；数据存储采用 SQLite 数据库。此套去容器化、中间件精简的架构，旨在实现环境依赖清晰、服务快速启停的核心部署目标。

4.4 遇到的工程困难与解决途径

4.4.1 困难 1：对比分析场景下，API 接口数量爆炸与前端维护困难

问题描述：最初开发 `/analysis` 模块时，发现只要增加一种时间对比或店铺对比，后端的查询接口与前端的渲染逻辑就要翻倍，导致代码极度臃肿。

解决方法（重大改进）：团队经过重构，抽象出了“双维度正交对比标准”。后端只提供单一分析路由（如 `/api/analysis/stock-health-matrix`），所有对比逻辑被下沉至接口入参的 `compareConfig` 中处理。前端将渲染图表与数据源解耦，大大降低了系统的复杂度。

4.4.2 困难 2：策略店铺批量生成时的计算资源消耗与稳定性

问题描述：单店生成需 10-30 分钟，同时创建多个店铺时 CPU/GPU 压力极大，且可能因内存不足崩溃。

解决办法：采用多进程并行生成、季度拆分的任务粒度控制；引入任务队列与进度反馈，前端轮询生成状态，避免超时。

第 5 章 智能体使用情况

5.1 当前阶段

1. 使用 LSTM 模型进行策略效果的数值预测。

数据模拟生成器基于电商业务逻辑与随机过程算法，能够为系统测试和演示提供高仿真的脱敏时序数据。

2. 已实现的 Agent 智能分析集成

当前系统已成功集成基于本地 Ollama 部署的 Qwen3.5-9B 大语言模型，构建了智能分析 Agent。Agent 配备 8 个专业分析工具（包括库存健康度查询、ROI 效率分析、转化漏斗诊断、品类性能对比、商品多维评分、流量模式识别等），能够像专业分析师一样理解自然语言问题，自主规划工具调用顺序，进行多轮深度推理，并生成结构化的诊断报告。支持库存诊断、转化率分析、销售下

降归因、店铺横向对比等 7 种典型业务场景。Agent 的分析数据源直接来自沙盒预生成的各策略店铺全量数据，实现了“沙盒推演结果”的智能解读。由于模型与数据均本地运行，有效降低了商业信息泄露风险，保障了分析的稳定性和私密性。

5.2 第二阶段规划（Agent 智能决策集成）

计划在现有 LSTM 预测引擎之上，接入大语言模型（如 GPT-4、GLM-4 等）作为决策解释与交互层。

届时，系统将真正实现从“数据感知→归因分析→数值预测→智能决策”的完整闭环，进一步提升系统的智能化水平和交互体验。

第 6 章 测试分析

6.1 测试环境与验证数据说明

测试环境为普通笔记本电脑（CPU: Intel i5 / 内存: 16GB），无 GPU 加速。

测试数据为系统自带的离线预生成 SQLite 数据库，包含 150 万条行为日志。

数据来源与规模：由于真实电商数据脱敏困难，测试数据基于阿里天池电商行为开源数据集的分布特征，通过自主研发的动态商品曝光器和 LSTM 行为预测模型生成。测试数据库共灌入 150 万条 动态用户点击/转化行为日志（Action 维度），以及 2 万条 包含库存周转、定价的 SKU 静态快照数据（Product 维度）。

测试基准：基于相同规模的数据集，横向对比传统硬编码查询架构与本系统原创的“双维度正交对比架构”及优化后的前端渲染方案。

6.2 系统功能响应与渲染性能测试

1. 针对 /analysis 模块中的复杂对比查询进行测试。在单用户、本地运行环境下：

(1) 简单 KPI 查询（如总销售额）：平均响应时间 < 50ms。

(2) 双维度正交对比查询（ROI 效率矩阵数据）：平均响应时间 < 200ms。

测试结果表明，基于 SQLite 的预聚合查询方案完全满足 Demo 演示场景的交互需求。

2. 针对 Dashboard 中的 12month + 24hours 粒度热力图（约 864 个色块节点）进行渲染测试：

(1) 首次渲染耗时（FCP）约 0.8 秒。

(2) 交互操作（如 hover、缩放）帧率稳定在 60fps，证明了前端可视化方案的工程有效性。

6.3 沙盒预测模型准确性分析

为验证 LSTM 模型生成数据的业务逻辑一致性，我们进行了如下验证：

(1) 单调性检验：在保持其他变量不变时，增加营销预算应导致预测销量单调递增（或边际递减）。测试中抽取 100 组对照策略，单调性符合率达 96%

(2) 季节性检验：模拟数据中的月度销量波动曲线与预设的季节因子高度相关（相关系数 $r > 0.92$ ）。

以上验证表明，离线预生成的模拟数据在业务逻辑层面是自洽的，能够作为沙盒推演功能的演示依据。

第 7 章 作品总结

7.1 作品特色与创新点

本作品在经过前期的需求调研、架构设计、代码开发与系统测试后，成功构建了一套切实可行的“电商智能决策沙盒系统”。回顾整个开发历程，本作品在创意、技术路线、数据工程及工作量投入上均体现出了显著的特色与创新：

1. 业务创意与模式创新：从“事后复盘”到“事前推演”打破了传统电商数据大屏仅能“看过去”的局限。首创性地引入“数字孪生”与“沙盒模拟”理念，将电商运营中高风险的策略调整（如价格变动、库存调拨、营销预算分配）

转移至虚拟沙盒中进行零成本试错，直击商家“不敢动”的业务痛点。

2. 架构设计创新：提出 EDA 变量驱动架构与双维度正交对比模型

(1) EDA 架构：将繁杂的电商运营动作抽象为严谨的数学模型，定义了可控自变量 x （营销、库存、预算）与因变量 y （用户行为、商品常量），为系统的底层逻辑赋予了高度的数理可解释性。

(2) 双维度正交对比 API：原创设计了“时间维度 \times 店铺维度”的正交对比接口规范。在庞大的后端工作量中，我们通过策略模式优化代码结构，将原本复杂度极高的 $O(N \times M)$ 跨表对比查询统一收口，极大降低了系统的接口冗余度，且在并发测试中表现出了极高的响应效率与极强的前端复用性。

3. AI 技术融合创新：在决策模块中，系统并未盲目追求大模型噱头，而是针对电商策略与市场响应之间的时序依赖性，采用了 LSTM 深度时序预测模型^[4]，并针对电商场景定制化设计 12 维特征体系+哈希嵌入编码机制。模型可精准捕捉电商季节波动、营销活动、时段偏好等长周期时序规律，同时学习商品、渠道、策略的复杂交互关系；结合规则+AI 的混合架构，既保证了系统运行效率，又实现了高保真用户行为模拟，为沙盒无损推演提供了核心算法支撑。在此基础上，系统已成功集成基于 Ollama+Qwen 的智能分析 Agent，实现了自然语言驱动的多维分析诊断与多工具协同推理，使“AI 生成数据”与“AI 解读数据”形成闭环，显著增强了决策支持的智能化水平。

4. 务实的工程选型与快速原型验证能力：本作品在 Demo 阶段展现了优秀的工程判断力，采用 SQLite 轻量数据库与 Python FastAPI 框架，以极低的部署成本实现了复杂业务逻辑的可视化呈现；通过预计算策略库的方式巧妙规避了深度学习模型的实时推理延迟问题，在普通笔记本电脑上即可流畅运行全部功能。这种“先验证闭环、再迭代优化”的研发思路，体现了团队对软件工程实践的深刻理解。

7.2 应用推广

本系统具备极强的商业落地价值与 SaaS 化推广潜力：

1. 赋能中小商家，降本增效解绑风险

对于缺乏专业数据分析团队的中小微电商企业，本系统不仅提供了开箱即用的高级数据特征量化（如 ROI 效率矩阵），更通过沙盒推演提前排雷，降低资

金空耗风险，帮助商家实现利润最大化。

2. 标准化 API 助力多平台无缝横向拓展

系统前后端完全解耦的设计，使得其不局限于单一电商平台。其底层标准化的数据接入协议不仅可以对接淘宝、京东等传统货架电商，也极易扩展至抖音、快手等以内容和流量驱动的兴趣电商体系，市场受众极其广阔。

7.3 作品展望

尽管目前系统已完成了核心业务闭环并在模拟环境下取得了优异的测试效果，但在未来的迭代与商业化进程中，仍有以下几个方向可以进一步拓展和提升：

1. 数据源的真实化与多源融合

目前系统底层依赖模拟生成的高维时序数据。未来计划申请接入主流电商平台的开放平台（Open API），引入真实的店铺运营流水、退换货率、竞品价格波动等外部多模态数据，以进一步提升 Agent 决策沙盒在真实复杂环境下的预测拟合度。

2. 持续优化 Agent 能力与扩展智能分析边界

当前 Agent 已能处理典型诊断场景，但面对极复杂的策略组合时分析深度仍有提升空间。下一步将探索接入更大规模、更强推理能力的云端模型（如 GPT-4、GLM-4 等）以增强复杂查询下的分析质量，同时引入流式响应缩短交互延迟；并计划通过 Agent 自动比对不同策略店铺的全量数据，直接输出最优策略建议，进一步降低商家的决策门槛。

3. 拓展应用维度至供应链深水区

将现有的可控自变量从“营销、库存、预算”前端三板斧，向后延伸至物流履约时效、客服情绪价值等长尾指标，打造全链路的电商数字孪生决策枢纽。

参考文献

- [1] Liu B, Guo W, Lu X, Xu M, Cui LZ. A Method of Analysis on Consumer Behavior Characteristics Based on Self-supervised Learning[C]. Chinese Conference on Computer Supported Cooperative Work and Social Computing, 2019: 605-617.
- [2] Han A, Krieger F, Greiff S. Collaboration Analytics Need More Comprehensive Models and Methods: An Opinion Paper[J]. J. Learn. Anal., 2021, 8: 13-29.
- [3] Li F. Analysis and research of e-commerce user behavior data based on Spark framework[C]. 2024 4th International Signal Processing, Communications and Engineering Management Conference (ISPCEM), 2024: 326-334.
- [4] Hochreiter S, Schmidhuber J. Long Short-Term Memory[J]. Neural Computation, 1997, 9(8):1735-1780.
- [5] Hidasi B, Karatzoglou A. Session-based Recommendations with Recurrent Neural Networks[C]. International Conference on Learning Representations, 2016.
- [6] Du M, Li F, Wang H. LogGAN: A LSTM-Based Generative Model for Event Log Sequence Generation[J]. Computers & Security, 2019, 85:180-196.