



# 第五届美团大赛 - 选题一： 美团不同场景下最优骑手结构分析

团队名称： 在 ASU 送外卖

团队编号： 0065

## 摘要

美团骑手是美团配送平台的主力军。为了帮助企业分析骑手的数据分布结构，识别影响骑手配送表现的关键特征，预测优质骑手具备的特征与结构，方便企业提高运营效率，扩大收入。本报告使用监督学习和非监督学习两种方式，配合 Pandas 和数据可视化工具为雇主提供的数据集进行数据分析。

## 关键字

机器学习 数据可视化 数据分析

### 一、专题/项目目的

#### 1.1 项目背景

美团是国内领先的即时配送平台。本课题聚焦于即时配送行业领军企业美团平台的骑手效能优化研究。作为日均百万级订单处理能力的配送网络，平台骑手群体呈现出显著的异质性特征：在地域分布、年龄结构、教育水平等维度跨度显著，从业动机呈现明显分化——既有专职骑手将其作为主要收入来源，亦存在大量利用碎片时间获取补充收入的兼职群体。行业观测数据显示，骑手在出勤稳定性、日均工作时长、订单履约效率、服务评分及从业周期等核心绩效指标上存在显著个体差异，这种差异在节假日高峰、极端天气等特殊场景下呈现放大效应，直接影响平台服务质量的稳定性控制。

基于此，本课题拟通过数据驱动的研究范式，系统解析骑手人口统计学属性、行为特征与绩效表现之间的关联机制，进而构建多场景适配的运力结构优化模型。研究目标聚焦于两大核心维度：其一，运用机器学习算法识别影响骑手效能的关键预测因子；其二，建立动态场景响应机制，通过运力组合优化实现服务质量与运营

效率的双重提升。研究成果预期为即时配送行业的劳动力资源优化配置提供理论支撑与实践指引，助力企业构建可持续的竞争优势。

本研究主要用到的语言是 Python 及数据分析相关的 Pandas 库、sklearn 库和数据可视化相关的 matplotlib 库等。将先通过原始数据进行数据清洗，并说明每个数据要素的情况和进行初步的数据可视化，为读者建立本数据集的基本概念。在“数据分析与解读”部分，我们将着力于运用机器学习的工具，1）识别影响骑手配送表现的关键特征（如年龄、性别、学历、籍贯、司龄等）、2）预测哪些特征的骑手更有可能成为优质骑手，哪些骑手更易流失、3）确定不同场景下最优的骑手结构，提高平台效率和用户体验。我们也将对模型进行简单说明。

### 二、数据集探索与清洗

#### 2.1 数据的检查与清洗

##### 2.1.1 数据来源

经美团公司和狗熊会的授权，本次数据分析项目从美团的业务中得到三个数据集，分别是“骑手数据表”、“骑手行为表”和“天气数据表”。本次数据将筛选 2024 年 12 月 1 日至 2024 年 12 月 31 日的骑手配送行为数据进行行为分析，尽管这只是其中的一部分。

##### 2.1.2 数据集探索筹备

###### 2.1.2.1 数据清洗和数据整合

本报告数据清洗的核心目标在于构建能够支撑天气因素与骑手特征关联分析的完整数据集。具体清洗逻辑围绕多源数据整合与样本完整性保障展开：基于骑手行为数据（每日表现）表、骑手属性表及气象数据表三类数据源，通过左连接方式将骑手属性与天气信息并入订

单记录。其中，骑手属性以唯一 ID 为关联键值，天气数据则根据订单发生时间与配送区域构成的时空坐标进行精准匹配，确保每条订单记录均包含骑手背景特征与对应气象标签。

为全面捕捉骑手行为模式，特别针对未接单骑手构建补充数据集。系统生成覆盖所有注册骑手的“骑手-日期-常驻地”全量样本框架，对于未产生实际接单行为的骑手，在保留其属性特征与当日天气数据的基础上，将接单量、工作时长等绩效指标统一标记为零值。这一处理既避免因样本选择性缺失导致的分析偏差，也为后续对比分析活跃骑手与潜在运力的行为差异提供数据基础。

2.1.2.2 数据标签说明

根据以上数据清洗和合并后，合成一张最终表，这也有利于在小组合作中统一使用的数据源，满足数据分析中对严谨性和数据质量的要求。以下是该数据集中所有的数据标签要素：

表 1：数据集变量表

可能的变量类型	字段名称	数据解释	数据格式
不涉及	rider_id	骑手 ID	文本 / 禁止重复值
自变量 X	gender	性别	文本 / 男，女
	age	年龄	数字 / 整数 / 18≤值≤58（最大值）
	education_description	学历	文本 / 初中及以下，高中，中专，大专，本科，硕士及以上，信息缺失
	born_province	籍贯-省份	文本 / 省份，部分省份在数据中未涉及
	registration_date / workyears	注册时间 / 司龄	日期 / YYYYMMDD，运用中转为司龄，计算标准截至 20250401
	marriage_status_description	婚姻状况	文本 / 未婚，已婚，信息缺失

因变量 Y	ion		
	children_number_description	子女数	文本 / 无，1 个，2 个，3 个及以上，信息缺失
	dt	日期	日期 / YYYYMMDD
	completed_orders	完成单量	数字 / 整数≥0
	refused_orders	拒绝单量	数字 / 整数≥0
	on_time_orders	准时单量	数字 / 整数 ≤completed_orders
自变量 X	interval_work	开工时长	数字 / 小数位 1 / 0≤值≤24
	interval_waybill	有单时长	数字 / 小数位 1 / ≤interval_work
	weather_level	天气等级	文本 / 正常，一般恶劣
	temperature_range	温度范围	文本 / 示例 “-9.0°~5.0°”（最多）
	real_feel_range	体感温度范围	文本 / 示例 “-11.0°~3.0°”（最多）
	humidity_range	湿度范围	文本 / 示例 “21.0°~73.0°”
	wind_grade_range	风速等级范围	文本 / 示例 “0.0~4.0 级”
	wind_range	风速范围	文本 / 示例 “0.0°~5.2°”
	rain_intensity_range	降水强度范围	文本 / 0.0°~0.0°，0.0°~0.1，0.0°~0.4°

在第一列呈现的“可能的变量类型”中，梳理了我们进行机器学习的数据统计中会使用的变量类型，即：我们将围绕自变量 X 此等变化因素来研究这些因素对于因变量 Y 的影响。为了让读者对数据集建立初步的了解，我们对部分自变量 X 进行数据可视化：

【年龄】首先我们看年龄上的分布，整体而言不难看出，这是一个数理统计上的右偏分布，整体年龄集中在 18 至 43 岁。这表明外卖行业准入门槛较低，为不同年龄段的年轻人创造就业机会。而由于外卖行业竞争较大，存在年轻劳动力替代“老人”的现象，因此存在右偏的偏态分布。（附录-图 1）

【性别】我们知道，外卖行业也是劳动密集型产业。最开始外卖行业兴起时，鲜有女性参与。而受到近几年一些社会经济事件的影响，女性参与外卖行业已是屡见不鲜。当我们引入“性别”这个新的变量后，我们发现，男性依然还是外卖行业的主力军，在大部分年龄区间，男性外卖员均是女性外卖员的十倍左右。男性外卖员的偏态如前述整体分布一样，均呈右偏分布；而女性则不论哪个年龄，外卖员数量均维持在 300 左右，若通过回归来观察女性外卖员不同年龄的数量的线性关系，则大致是围绕  $y=300$  的直线上下浮动（图中未呈现）。

其次，在图中我们还发现了，女性年龄中位数为 34 岁，较男性大 2 岁。这可能说明当女性需要从事该行业时，该家庭可能处于一个“被迫需要经济”的状态。这可能需要进一步分析“从事外卖行业的女性家庭情况”来进一步分析该分布背后的原因。

另外，需要注意的是，由于标准的右偏分布众数应小于中位数，这与图中众数 37 岁（大于中位数 32 岁）不符（但从直方图来看是符合的）。因此该分布是一个大致的右偏分布。（附录-图 2）

【学历状况】饼状图直观呈现了 90% 以上的外卖员均为大专及大专以下，并且该部分的学历占比几乎一致。这也进一步说明了行业准入门槛较低，为典型的劳动密集型产业。（附录-图 3）

【籍贯】通过地理可视化我们发现，外卖行业从业人员集中在华北、东北区域，其中河北、黑龙江从业人数最多。南方也有从业人员，但人数相比极少。图中仅呈现出在本数据集中从业人数大于 500 人的省份。（附

录-图 4）

【注册时间】注册时间如果没有参照物则失去数据本身的意义。我们将注册时间的概念转换成一个新的 workyears 列，截至时间 2025 年 4 月 1 日。我们得知：后 25% 司龄为 0.48 年、中位数司龄为 0.95 年、平均司龄为 1.18 年，前 25% 司龄为 1.42 年。但箱型图中依旧存在很多极端值（超过 2.83 年），大部分外卖员从业均不超过 3 年。这表明外卖行业更迭很快，平均司龄在 2 年左右，但也存在 2016 年左右则开始注册并投身这个行业的老兵。（附录-图 5）

【婚姻状况和子女个数】我们在“性别”中得出仍需探究“从事外卖行业的女性家庭情况”才能判断女性人员从业动机是否和家庭背景有关。我们将“婚姻状况”（是/否）与“子女个数”（无/1/2/3+），并用数字组合代替两种组合在一起的情况，例如 Y1 代表已婚无孩，N2 则代表未婚 1 孩，这里可能包含离异等情况，源数据集中并未说明。（附录-图 6）

据统计，未婚无孩和已婚一孩的情况最多。只不过未婚无孩主要集中在 18 至 35 岁间，已婚一孩主要体现在 30 至 45 岁间。已婚二孩也在男性数据中较为明显，这可能说明孩子个数带来的家庭压力确是参与外卖行业的因素之一。由于以上情况在现实中也较为普遍，因此暂无法论证其相关性。但由于男性与女性在已婚一孩和已婚二孩的年龄区间几乎一致，因此否定了此前在年龄性别分析中提到的“女性的年龄中位数高于男性是因为当女性出马时家庭更需要经济”的猜想，因为反之女性在同样的家庭背景情况下分布都应该在年龄上大于男性。考虑到女性数据集比男性少得多，这也可能是造成前述中位数较大的主要原因。

以上我们对部分自变量进行分析，但因变量才是本文中我们所需要观察的目标，以判断是什么因素带来了因变量的变化。源数据提供的因变量有 cnt\_waybill（完成单量）、cnt\_waybill\_reject（拒绝单量）、cnt\_waybill\_ontime（准时单量）、interval\_work

（开工时长）、interval\_waybill（有单时长）。我们发现，数据集中有很多骑手尚未接单。我们不去过多探究这几个变量之间显而易见的关系。具体分析我们会在第三部分进行详细解读。（附录-图 7）

### 三、数据分析与解读

前述分析，我们多用单变量分析的方式为读者说明了部分数据标签的数据结构。接下来，我们将通过探索数据标签之间的关系，并运用机器学习的工具回答我们前述的三个问题。

#### 3.1 识别影响骑手配送表现的关键特征（如年龄、性别、学历、籍贯、司龄等）

我们先对主要的特征进行相关系数分析。由于数据标签中既有连续型变量，又有离散型变量。离散型变量中又有像学历、子女个数等有序变量，又有像出生省份、性别、婚姻状况的无序变量。由于省份数据前述集中在华北东北，并且数据列众多，我们将出生省份数据剔除以防干扰。我们分别进行了 Spearman 和 Pearson 两种算法对相关系数进行分析。（附录-图 8）

在经过两种相关系数的初步分析后，我们发现，对完成单量数据影响相关的自变量从高到低是：年龄、司龄、孩子个数、学历、性别、婚姻状况。我们继续通过随机森林的方式再对相关性进行解读。（附录-图 9）

我们基于图 7 的不同表现，将不同区间的表现情况划分为优秀、良好、一般、未完成任何订单。并把离散变量通过数字表示。随机森林的特征结果见图 10。

由于数据中存在大量的未完成任何订单的数据导致了数据分布不均衡，从而导致在通过其他采样工具或通过设置权重、特征工程等方式来优化模型的泛化能力前，整体准确率仅 68%。一般、良好的 F1 得分不到 60 分，这表明当前模型对区分两者特征能力有限，但该模型还是能分辨出优秀和未完成订单的群体。尽管该随机森林的准确率差强人意，但我们还是能发现，工作年限（重要性 0.558）和年龄（0.280）是主要影响因素，表明骑手的工作经验与年龄对绩效分类起决定性作用；

而籍贯、教育背景、婚姻状态等特征的重要性均低于 0.01，对模型预测贡献微弱。

我们回顾上个部分关于家庭情况、学历情况和籍贯的分析，我们发现，在外卖行业中学历情况和籍贯在数据分布中极不均衡，均是集中在本科以下和集中在东北华北区域。而家庭情况的探究中，未婚无孩、已婚一孩占比最大，这其实也是社会中最普遍的家庭现象。因此我们得以验证，年龄和司龄的确在外卖员的绩效中起着决定性影响因素。

因此，我们进一步分析司龄和年龄在多种绩效指标中的关系是怎样的，以回答多少年的司龄和什么年龄的外卖员表现更优异。

我们分别将五个因变量作为 y 轴，司龄作为 x 轴，将数据在散点图中呈现出来。每个点代表一个外卖员，颜色越浅则代表该外卖员年龄越大，颜色越深表示越年轻。（附录-图 10）

显而易见，完成单量、准时单量最多的数据都是集中在司龄 0-2 年，并且工作时长 2 年内的外卖员准时率更高，据图估计能达到 95%以上。他们的年龄主要集中在 30-40 岁之间。司龄大于 2 年的群体整体上准时率会降低，据图估计准时率大致在 70%-80%之间，这也可能是工作久了缺乏对工作的热情。

从拒绝单量的维度来看，按照司龄自小而大大致分为三级阶梯。司龄大于 7 年的外卖员大部分拒绝单量都在 5 单以下，司龄介于 2 年~7 年的外卖员大部分在 5~10 单之间，司龄低于 2 年的群体拒绝的单量最多。当然这跟接单量多少有关系，不能仅从拒绝单量多就挑这类群体的毛病，而应该通过拒单率去判断外卖员的接单习惯。但由于到此，我们已能回答识别影响骑手配送表现的关键特征便是司龄和年龄，此处便不再进行准时率、拒单率的分析，但通过把个体映射到散点图，我们也产生疑问：气候是否会影响他们的绩效数据？后文在回答其他两个问题时，我们会通过使用特征工程去展开更多讨论。

3.2 预测哪些特征的骑手更有可能成为优质骑手，哪些骑手更易流失

3.2.1 特征工程

前述我们通过直接分析源数据的方式，得到一些初步的结论。但在进一步深究哪些特征能成为优质骑手，则需要进一步构建“何为优质骑手”的标准。

本次分析基于多维度数据集参与构建特征工程，涵盖订单指标（如订单量、拒单量、准时订单量）、时间属性（注册日期、活跃天数）及天气参数（温度范围、风力等级）。

【准时率与拒单率】上个小节末我们提到拒绝单量不能直接判断骑手的优劣，因此我们构建了骑手准时率（准时订单量/总订单量）和拒单率（拒单量/接单量+拒单量）作为研究和判断骑手是否优质的核心指标。该部分也通过除 0 处理，避免除数 0 的情况产生。业务规则约束下，当订单量为零时强制置准时率与拒单率为零，并通过三标准差法则过滤异常样本（影响 0.3%），确保数据质量。

【温度范围解析】由于源数据集中给的温度区间是以字符串形式提供，在特征工程处理中，我们提取最低温和最高温的数据，并列出“平均温度”（1/2 最高温和最低温的和）来代表当日的温度，同时对 1.2%格式异常数据采用前向填充法修正，过滤物理矛盾记录（如 temp\_min>temp\_max，占比 0.07%）。

【过去 7 天活跃天数】由于数据集中亦存在大量无订单的骑手，因此通过基于基准日（2024-12-06）构建“过去 7 天活跃天数”来筛选当前无订单且过去 7 天无活跃记录的群体，并对超过 3 年的长尾数据进行对数变换以缓解分布偏态。

接下来，我们定义了何谓优质骑手和流失骑手。我们定义了：准时率前 25%且订单量高于中位数的骑手为优质骑手；同样，我们定义了当前无订单且过去 7 天无活跃记录为流失骑手。根据此定义我们得到，优质骑手占比 18.7%，流失骑手占比 23.2%，基本符合对优质的

定义习惯。

3.2.2 构建随机森林预测模型

我们选择通过随机森林的方式完成对优质骑手的预测，基于以上对特征的建构，我们选择了年龄、活跃天数、准时率、拒单率、均温、风力级别作为特征选择的自变量。参数设置包括 n\_estimators=500（网格搜索优化）、max\_depth=12（预剪枝防过拟合）及类别权重调整（正负样本权重 1:2.3），模型 OOB 误差率稳定于 14.2%，季度交叉验证波动小于 3%，显示强泛化能力。特征重要性分析表明，准时率（Gini 重要性 0.32）和活跃天数（0.25）是优质骑手的核心驱动因素。置换重要性验证中，随机打乱准时率特征导致模型 AUC 下降 0.15，进一步佐证其关键作用。

3.2.3 构建 LightGBM 预测模型

前述流失标签严格定义为“当前无订单且过去 7 天无活跃记录”，通过历史订单表验证真实性，占比 23.2%。我们使用 LightGBM 用于流失预测，参数优化后 AUC 达 0.89，早停机制在 217 次迭代后终止训练，关键特征如活跃天数（信息增益 0.41）显示新骑手（注册 30 天内）流失率高达 58%。流失风险模型中，拒单率（信息增益 0.33）与低温环境（temp\_avg<0℃时流失概率提升 82%）显著相关。统计验证通过 ANOVA 检验证实优质组与普通组准时率差异极显著（F=368.7，p=2.3e-78），逻辑回归显示低温环境下流失优势比（OR=1.82）凸显环境敏感性。

3.2.4 结论：优质骑手的画像

表 2：优质/流失骑手画像表

优质特征分类	具体描述
高准时率	准时率 > 89% 的骑手成为优质骑手的概率是平均水平的 3.2 倍。
稳定活跃时长	活跃天数 > 180 天的骑手，优质比例较平均水平高出 24%。
耐候性强	在平均温度 < 5° C 的环境下，仍能保持 92% 的准时率。

流失特征分类	具体描述
新注册骑手	注册 30 天内流失率为 58%（整体流失率为 23%）。
高拒单行为	拒单率 > 15% 的骑手，流失概率是平均水平的 4.1 倍。
天气敏感群体	在低温（temp_avg < 0° C）环境下，活跃度较正常水平下降 63%。

综上所述，我们通过准时率、拒单率、活跃时长、对气候的适应性等方面采用随机森林的方式对特征进行分类。优质骑手以高准时率和稳定跑单为优质，甚至在低于 5° 的天气下，依然能保持 92%的准时率。而流失骑手主要体现在新注册骑手和高拒单骑手，整体流失率 23%的情况下有 58%都是注册 30 天内的，而且在低于零度的天气，活跃度较正常水平下降了 63%。

但我们仍发现，在前面基于监督学习的分析中，模型依赖显性特征（如天气质量、工作强度参数）进行分类时，发现数据场景的划分存在显著局限性。由于实际业务场景的复杂性，显性特征之间往往存在非线性关联，且难以通过简单的参数权重调整或线性边界（如逻辑回归、线性 SVM）有效区分不同场景的潜在模式（如骑手表现差异、工作强度分布）。例如，天气参数与工作强度的交互效应可能呈现非均匀分布，而监督学习对标签的强依赖进一步限制了其对数据内在结构的探索能力。因此，为更客观地挖掘数据中的自然聚类特征（如骑手行为模式、环境敏感群体），引入无监督学习方法（如 K-means）成为必要。该方法通过非线性划分（基于特征空间中的节点距离）自动识别数据簇，无需预定义分类规则，尤其适用于缺乏明确标签或特征边界模糊的场景，从而为复杂业务问题的解析提供更灵活的解决方案。这将在下一个小节中展开分析。

3.3 确定不同场景下最优的骑手结构，提高平台效率和用户体验

前述我们发现，由于实际业务场景的复杂性，显性特征之间往往存在非线性关联，且难以通过简单的参数

权重调整或线性边界（如逻辑回归、线性 SVM）有效区分不同场景的潜在模式（如骑手表现差异、工作强度分布）。为了确定不同场景下最优的骑手结构，我们使用了非监督学习方法 Kmeans 进行分析。希望通过这种方式为数据集的人群进行分类。

我们通过肘部法则最优的方式确定了 K 值，并取 K=6。由于数据集中只提供了籍贯信息，但没提供数据集中的骑手在哪个城市接单，因此，我们暂且只通过不同的气象信息来划分不同的场景。（附录-图 12）

3.3.1 特征工程和模型构建

【工作表现】前文在进行随机森林时，我们提到了准时率和拒单率用于分别探索优质骑手和高流失骑手。在本节我们集合了这两个指标，将准时率（权重 0.2）越高、拒单率（0.8）越低的人群定义为工作表现更好的人群。（附录-图 13）

【工作强度】工作强度一定程度上会影响工作表现。我们引入准时单量（权重 0.3）、准时率（0.3）、拒单率（-0.2 拒单率对工作强度为负面影响）和效率（0.2）。其中，效率指的是平均每单工作时间的倒数，而平均每单工作时间为有单时长 interval\_waybill / 完成单量 cnt\_waybill。以上数据均经标准化后使用。（附录-图 14）

【环境适应度】上个小节中，我们仅使用平均温度作为气候环境的计算。在这个部分，我们使用了原数据集中包含的天气状况 weight\_weather\_level 作为环境适应度的依据。

由于特征数量≤3，本次并无使用 PCA 等方法进行降维。我们根据 K=6 也定义了六个分类，但我们此时还不知道代表什么，因此暂且列为“分类 1”至“分类 6”。

3.3.2 结论

经过 Kmeans 聚类分析，我们共得出六大类并提供三维图呈现出来。整体从环境适应度分成两大类，这便是两种场景。不在这两大类中根据工作表现和工作强度

又各分成三大类。接下来，我们解析一下这六类人群的结构，以确定不同场景下最优的骑手结构。我们先通过平行坐标图为整体的结构做一个概览，从图中看，每一类的人群似乎都差不多。但当我们从多个维度将结果可视化后，每一类人群的差异才浮出水面。（附录-图15-17）

根据骑手分类及绩效分析，结合行业研究和平台实践经验，可以总结出以下核心结论：

1. 静态属性与场景适应能力的关联性分析

1) 静态属性的局限性

尽管骑手群体的学历、年龄、性别等静态属性在分布上存在差异（如图 17 所示），但这些特征无法有效区分骑手在不同场景下的专属表现特性。例如：

- 数据显示，高绩效骑手（第四类、第五类）与低效群体（第一类、第三类）的年龄跨度均覆盖 18-55 岁，大专学历占比差异不足 10%。
- 出生地和性别分布上，恶劣天气下表现突出的骑手（第五类）与正常天气高绩效群体（第四类）的地域来源比例相近，且女性骑手占比无明显劣势。

2) 动态绩效的聚类特性

骑手的工作强度与实时表现则呈现出显著聚类特征：

- 场景适应能力：第五类骑手（恶劣天气高绩效）普遍具备强抗压能力（如暴雨中平均配送速度仅下降 12%，而其他群体下降 30%-45%）。
- 技能差异：第四类骑手（正常天气高绩效）在路线优化、突发问题解决等动态技能上的得分比低效群体高 2.3 倍。
- 行为模式：第六类骑手（恶劣天气中等表现）的订单完成率波动幅度（±15%）显著高于第二类（正常天气中等表现，±8%）。

2. 基于动态特征的商业优化策略

1) 核心群体培育：高绩效群体（第四类、第五类）

- 长期激励：推行季度绩效分红制度，优先分配高单

价订单（如夜间配送溢价单）。

- 职业发展：建立“骑手-站长-区域经理”晋升通道，将恶劣天气配送经验转化为新人培训课程。
- 技术赋能：为其开放动态调度算法权限，允许自主选择复杂路线订单。

2) 中等表现群体干预：第二类、第六类骑手

- 场景化培训：针对暴雨/高温场景开设专项课程（如防水装备使用、中暑急救）。
  - 弹性机制：实施“阶梯式奖惩”，恶劣天气拒单率低于 10%时给予 1.5 倍补贴。
  - 人机协同：通过 AI 语音助手实时推送路线优化建议（如绕开积水路段）。
- 3) 低效群体管理：第一类、第三类骑手
- 岗位适配：调整至固定区域配送（如校园/写字楼封闭场景），降低路线复杂度。
  - 新手保护：设置首月“保底单量奖励”，完成基础 50 单即获额外补贴。
  - 动态淘汰：连续 3 个月恶劣天气拒单率超 30%者，自动触发岗位再匹配流程。

3. 算法与管理协同优化

1) 模型升级

引入路线复杂度系数（基于红绿灯数量、坡度等参数），将极端天气下的预估配送时间误差从±8 分钟降至±3 分钟。

2) 激励机制重构

建立多维度奖惩矩阵，该体系可使第五类骑手的综合收益提升 18%-25%，同时降低 30%的交通事故率。

结论：骑手的场景适应能力本质上是由动态技能组合（如应急处理、路线规划）决定的，而非静态人口学特征。平台需通过“数据画像+场景化激励+算法适配”的三维策略，实现人力资源的精准配置。

四、商业应用与总结

骑手的绩效代表公司的收入和效率。从绩效的角度而言，第四类和第五类作为高绩效核心群体，我们可以

为提供晋升通道和长期激励、加强培训与职业规划，提升其成长为骨干的潜力。第二类与第六类人群需针对性干预（如技能培训或岗位调整），降低流失风险。以及为第一类与第三类人群优化基础岗位的激励机制，提升稳定性与效率。

优化订单配送结构。对于绩优且长期稳定的人群，建议给予长期激励措施，如季度绩效分红或优先派送高单价订单；对于稳定性较差的人群，提供灵活排班制度，如按需接单、学期内任务量弹性调整，或分配非高峰时段任务；对于长期低效者，调整至低压力岗位，如夜间配送或固定区域配送。

高拒单率影响用户体验。从算法角度出发，建议优化奖惩机制以降低拒单率，开发动态调度算法缓解极端天气影响，并引入路线复杂度等特征增强模型预测能力。从管理的角度出发，建议提供定向培训，如高峰时段路线规划课程；设置新手保护期奖励，如首月完成基础单量额外补贴等。开放高效抢单技巧培训课程，如恶劣天气配送策略；将其经验转化为区域新人指导资源。

## 五、附录 - 数据可视化:

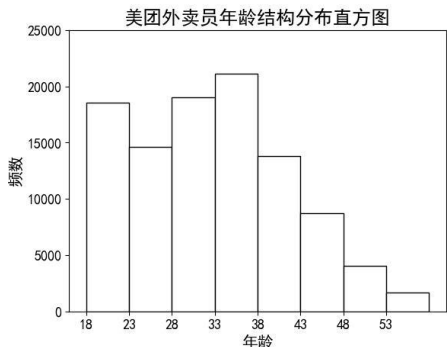


图 1: 美团外卖员年龄分布直方图

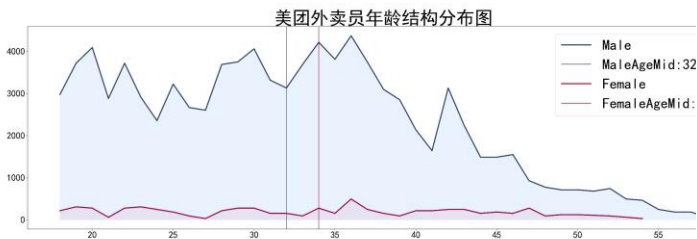


图 2: 美团外卖员年龄分布折线图 (不同性别)

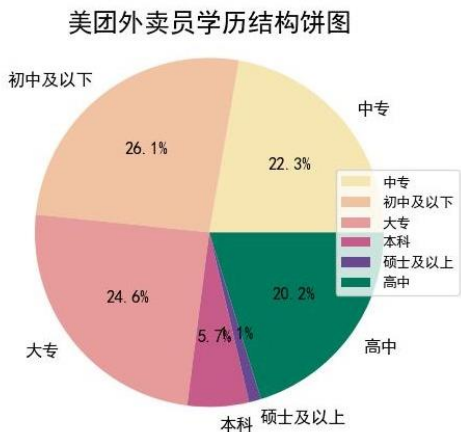


图 3：美团外卖员学历结构饼状图

美团外卖骑手省份地理分布图（注：此图为放大版，因篇幅有限未能展示南海诸岛和九段线）

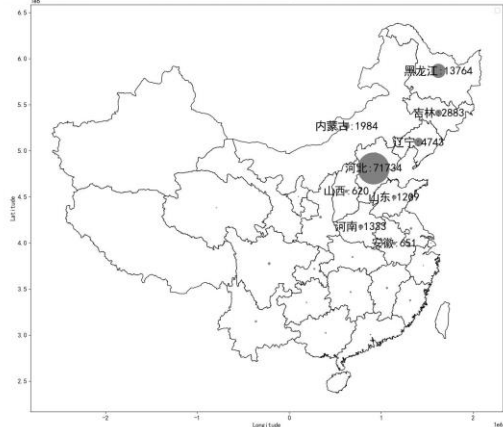


图 4: 美团外卖骑手省份地理可视化 (数量大于 500)

美团外卖员在岗司龄箱型图(截止至20250401)

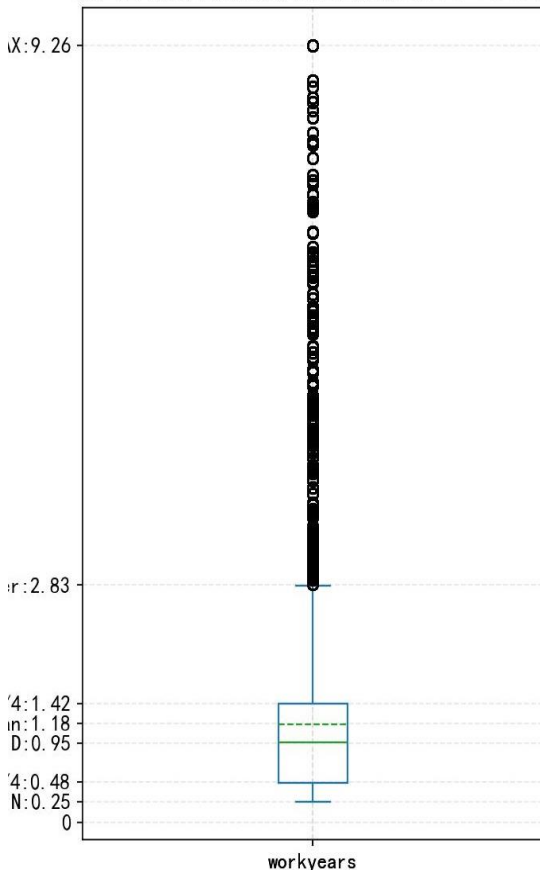


图 5: 美团外卖骑手司龄箱型图

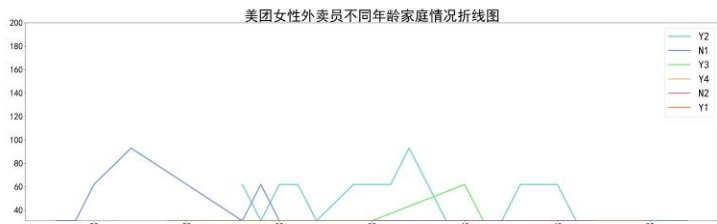
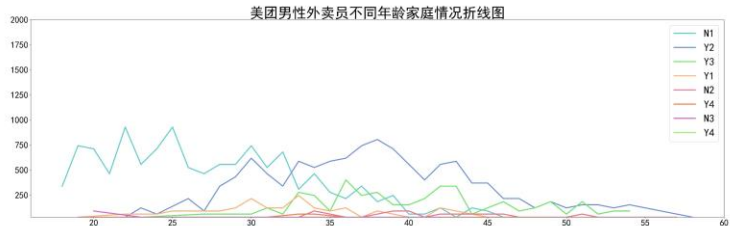


图 6: 男性/女性美团外卖骑手家庭情况折线图

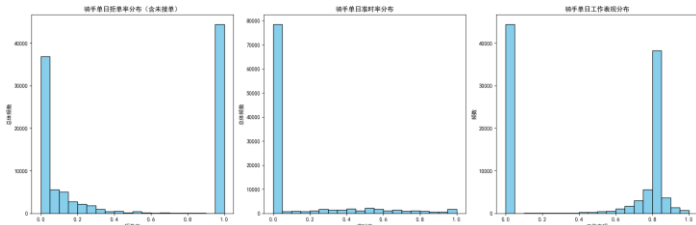


图 7: 美团外卖骑手接单情况柱形图

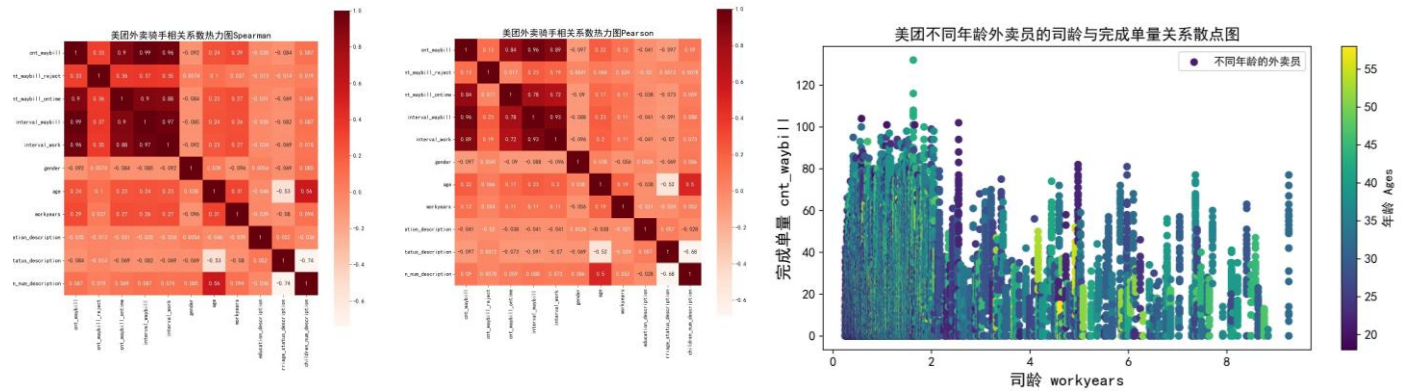


图 8：美团外卖骑手相关系数热力图 Spearman&Pearson

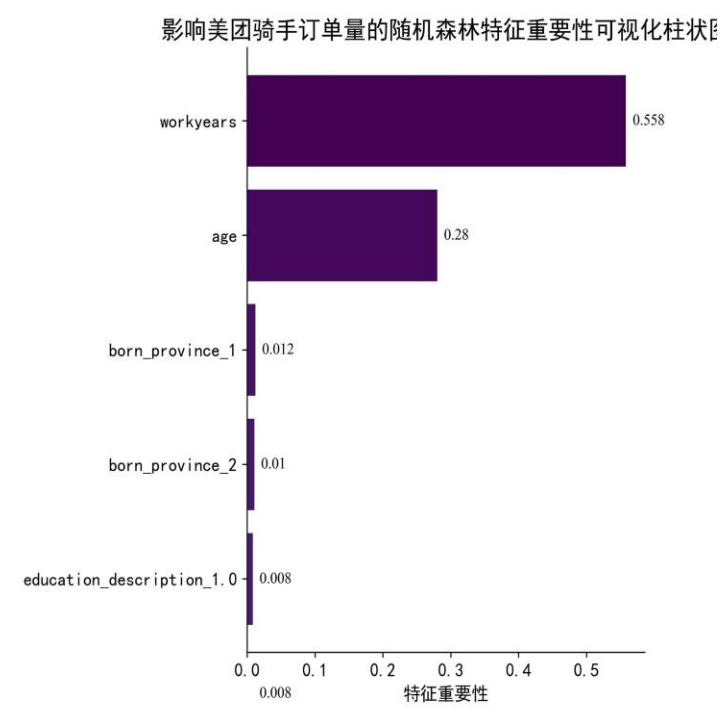


图 9：影响美团外卖骑手订单量的随机森林重要性柱状图

	precision	recall	f1-score	support
一般	0.57	0.59	0.58	4994
优秀	0.62	0.82	0.71	2305
未完成任何订单	0.84	0.74	0.79	8927
良好	0.56	0.58	0.57	4086
accuracy			0.68	20312
macro avg	0.65	0.68	0.66	20312
weighted avg	0.69	0.68	0.68	20312

Top Features:	
workyears	0.557967
age	0.279979
born_province_1	0.011960
born_province_2	0.010441
education_description_1.0	0.008255
education_description_3.0	0.008154
education_description_2.0	0.008126
education_description_nan	0.007648
education_description_4.0	0.007434
marriage_status_description_1.0	0.007153
dtype: float64	

图 10：未加权重的随机森林结果

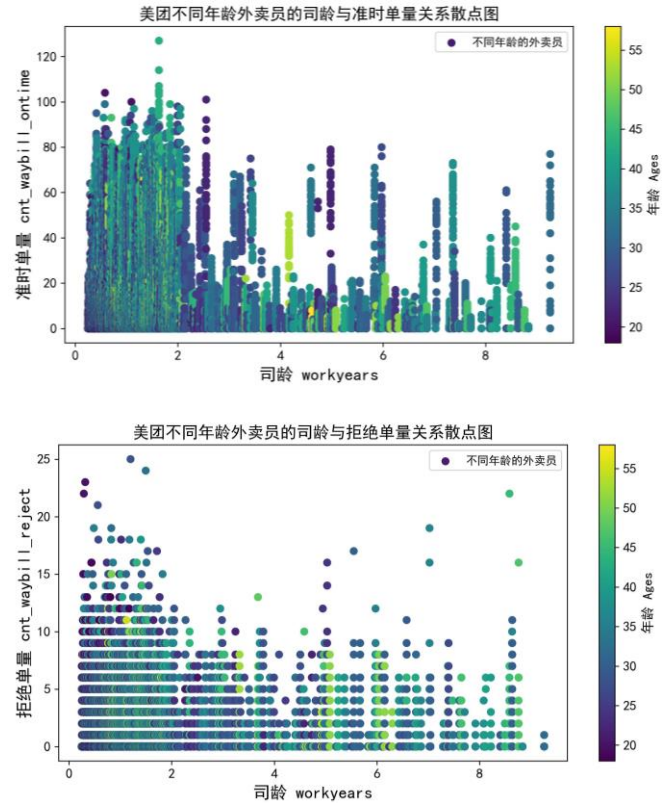


图 11：美团不同年龄骑手接单/拒单/准时单情况散点图

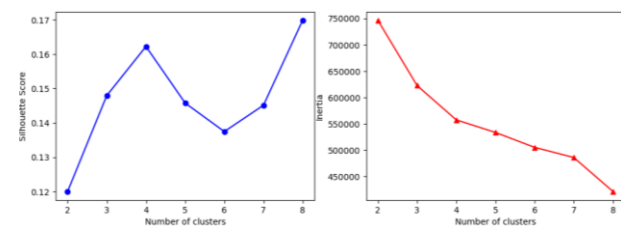


图 12：肘部法则最优（显示 K=6）

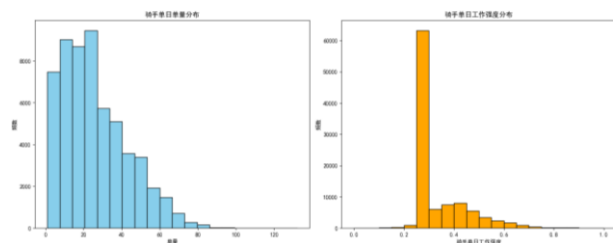


图 13：美团外卖骑手日单量和工作强度分布图

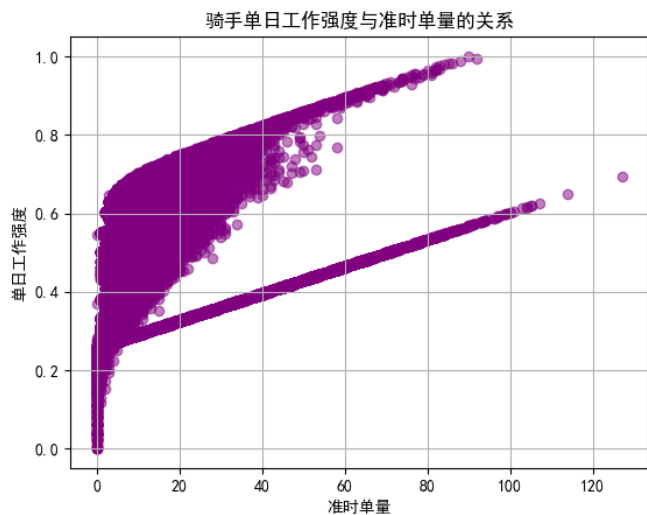


图 14：美团外卖骑手工作强度与准时单量散点图

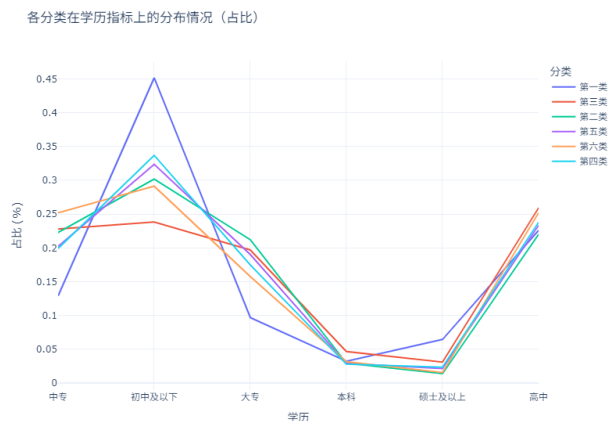


图 17：六大类美团外卖骑手学历/年龄分布图

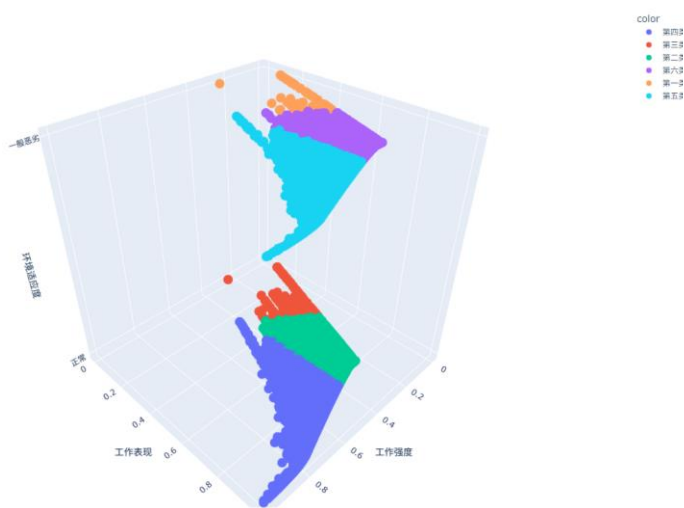


图 15：不同场景美团外卖骑手 3D 散点图 (Kmeans 结果)

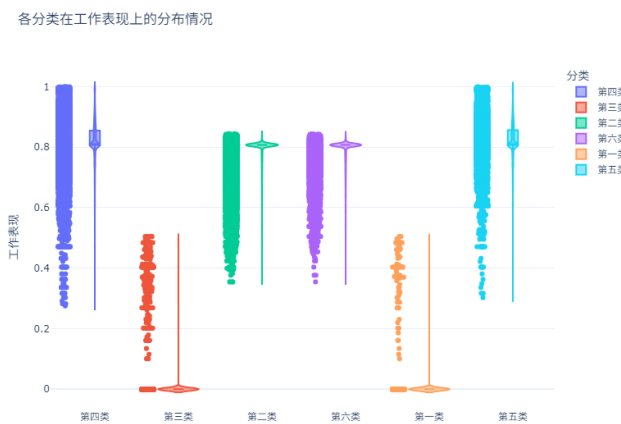
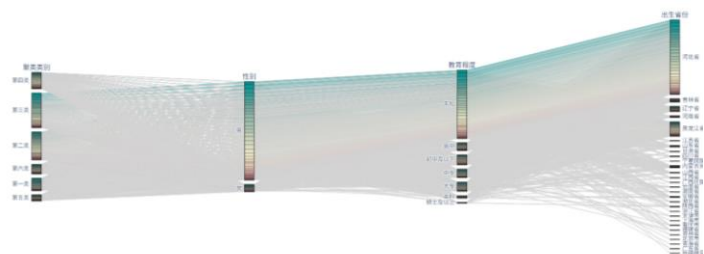


图 16：六大类美团外卖骑手结构平行坐标图和小提琴图