□ 岗位攻略白皮书

数据分析岗位技能全攻略

针对新东方太原分校数据分析岗 · 从零到面试通关

基于JD拆解 + 实战经验整理 · 磊子 □ · 2026年6月

□ 目录

LAG / LEAD 偏移

2.6 CASE WHEN 条件判断

2.7 SQL 实战面试题

连续登录问题

留存率计算

3.1 Excel 在数据分析中的定位

3.2 核心快捷键

3.3 必会函数

查找引用类

条件统计类

文本处理类

日期类

3.4 数据透视表（核心技能）

创建步骤

常用技巧

3.5 Power Query（数据清洗利器）

4.1 Python 在数据分析中的角色

4.2 Pandas 核心操作

安装

数据读取

数据清洗

分组聚合

日期处理

导出

4.3 数据可视化（Matplotlib基础）

4.4 一个完整分析案例

5.1 Tableau 是什么

5.2 Tableau 核心概念

拖拽规则：

5.3 基础图表制作

柱状图（对比）

折线图（趋势）

饼图（占比）

地图（区域分布）

热力图（交叉分析）

5.4 计算字段

基础计算

条件计算

5.5 参数控制（关键技能！）

创建参数步骤：

使用参数：

5.6 LOD 表达式（面试加分项！）

三种LOD

常见场景

5.7 仪表盘制作

布局原则

制作步骤

仪表盘交互功能

5.8 数据源管理

数据混合（Data Blending）

数据提取优化

6.1 什么是指标体系

6.2 OSM 模型（最实用）

OSM实战（教培行业）

6.3 指标分级

北极星指标

三级指标体系

6.4 指标口径统一

为什么口径重要？

口径文档模板

6.5 常用分析框架

数据分析岗位技能全攻略 · 白皮书

> 针对新东方太原分校数据分析岗位的完整技能体系与实战指南

> 作者：磊子 □ · 2026年6月

□ 目录

第一章：岗位解读与技能地图

1.1 岗位要求拆解

根据招聘JD，本岗位的核心职责可以归纳为三个层面：

职责层面	具体内容	对应技能
数据支持	搭建可视化看板、完成数据报表	Tableau、SQL、Excel
数据治理	指标体系建设、数仓表结构优化	指标体系方法论、数仓知识
分析报告	撰写周期性分析报告、推动业务决策	分析框架、业务理解、PPT/报告写作

1.2 技能图谱总览

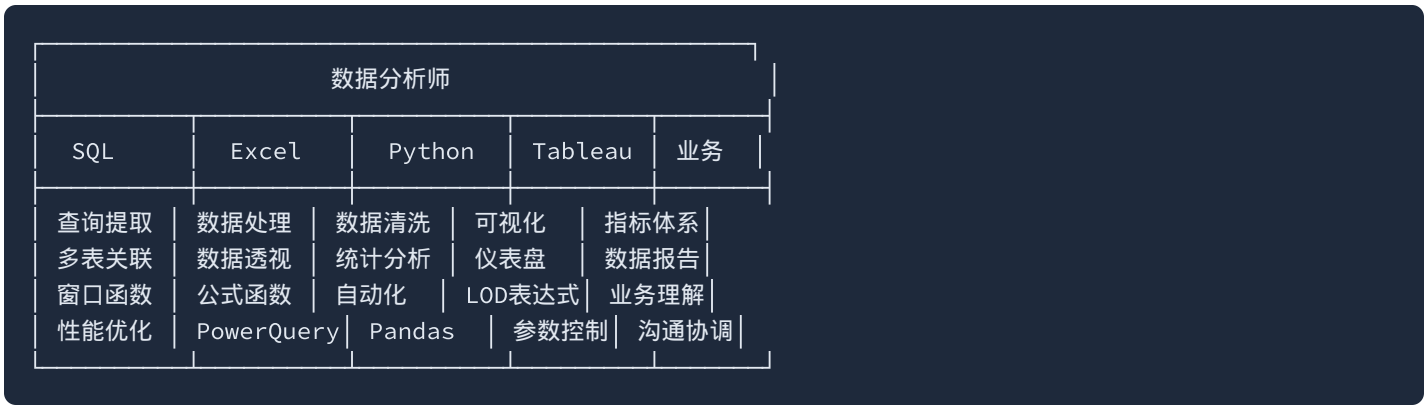

1.3 学习路线建议

阶段	学习内容	预计时间
第一阶段（基础）	SQL基础增删改查、Excel公式、基础图表	1-2周
第二阶段（进阶）	SQL窗口函数、数据透视表、Python Pandas、Tableau基础	2-3周
第三阶段（高阶）	指标体系、Tableau LOD、Python数据分析、报告撰写	2-3周
第四阶段（面试）	刷SQL题、项目复盘、模拟面试	1周

第二章：SQL 从入门到实战

2.1 SQL 是什么？

SQL（Structured Query Language，结构化查询语言）是用来和数据库"对话"的语言。你可以把它理解为：

> **"我需要你帮我从仓库里找出这些数据，按照这个规则整理好给我。"**

数据分析师80%以上的时间都在写SQL，这是最重要的技能。

2.2 基础查询语法

最基本的结构——SELECT FROM

```
-- 查询所有列
SELECT * FROM orders;
```

```
-- 查询特定列
SELECT order_id, user_id, amount, create_time
FROM orders;

-- 限制返回行数
SELECT * FROM orders LIMIT 10;
```

核心概念解释：

- `SELECT`：选择你要看的列（字段）
- `FROM`：从哪个表里找
- `*`：所有列
- `LIMIT`：只看前N行（调试时很有用）

过滤数据——WHERE

```
-- 筛选特定条件的数据
SELECT * FROM orders
WHERE amount > 100;  -- 只看金额大于100的订单

-- 多个条件
SELECT * FROM orders
WHERE amount > 100
  AND status = 'completed'  -- AND: 同时满足
  AND create_time >= '2026-01-01';

-- 或者条件
SELECT * FROM users
WHERE city = '太原' OR city = '北京';  -- OR: 满足任一
```

排序——ORDER BY

```
-- 按金额从高到低排序
SELECT order_id, user_id, amount
FROM orders
ORDER BY amount DESC;  -- DESC: 降序（大到小）

-- 按日期从旧到新
SELECT * FROM orders
ORDER BY create_time ASC;  -- ASC: 升序（小到大），默认就是ASC
```

2.3 聚合函数与分组

常用聚合函数

函数	作用	示例
`COUNT()`	计数	`COUNT(DISTINCT user_id)` 去重用户数
`SUM()`	求和	`SUM(amount)` 总金额
`AVG()`	求平均	`AVG(amount)` 平均金额
`MAX()`	最大值	`MAX(amount)` 最大金额
`MIN()`	最小值	`MIN(amount)` 最小金额

GROUP BY 分组

```
-- 每个城市的用户数
SELECT city, COUNT(*) as user_count
FROM users
GROUP BY city;

-- 每个月的销售额
SELECT DATE_TRUNC('month', create_time) as month,
       SUM(amount) as total_sales
FROM orders
GROUP BY DATE_TRUNC('month', create_time)
ORDER BY month;

-- HAVING: 对分组结果再次过滤
SELECT city, COUNT(*) as user_count
FROM users
GROUP BY city
HAVING COUNT(*) > 100;  -- 只看用户数超过100的城市
```

> □ **WHERE vs HAVING 的区别：** `WHERE` 是在分组之前过滤行，`HAVING` 是在分组之后过滤组。比如"只看已完成的订单"用 WHERE，"只看订单数超过100的用户"用 HAVING。

2.4 多表连接——JOIN

实际工作中数据不会都在一个表里，需要用JOIN把它们连起来。

四种JOIN类型

```
-- INNER JOIN: 两表都有的数据（交集）
SELECT a.user_name, b.order_id, b.amount
FROM users a
INNER JOIN orders b ON a.user_id = b.user_id;

-- LEFT JOIN: 左表全部 + 右表匹配的（没有则为NULL）
SELECT a.user_name, b.order_id, b.amount
FROM users a
LEFT JOIN orders b ON a.user_id = b.user_id;
-- 结果里每个用户都有，没下过单的用户订单信息为NULL

-- RIGHT JOIN: 右表全部 + 左表匹配的（很少用）
-- FULL OUTER JOIN: 两表的并集（很少用）
```

实际业务场景

```
-- 场景：统计每个学生的报名情况
SELECT
    s.student_id,
    s.name,
    s.phone,
    COUNT(c.course_id) as course_count,
    SUM(c.amount) as total_paid
FROM students s
LEFT JOIN enrollments e ON s.student_id = e.student_id
LEFT JOIN courses c ON e.course_id = c.course_id
WHERE s.is_active = 1
GROUP BY s.student_id, s.name, s.phone
HAVING COUNT(c.course_id) = 0;  -- 报了名但没选任何课的学生
```

2.5 窗口函数（面试必考！）

窗口函数是SQL进阶的核心，也是数据分析面试的高频考点。

基本概念

> **窗口函数 = 对"每行数据及其周围的数据"进行计算，而不减少行数。**

ROW_NUMBER / RANK / DENSE_RANK

```
-- 按成绩排名
SELECT
    student_id,
    course_id,
    score,
    ROW_NUMBER() OVER (ORDER BY score DESC) as row_rank,  -- 1,2,3,4...
    RANK() OVER (ORDER BY score DESC) as rank,            -- 1,2,2,4...
    DENSE_RANK() OVER (ORDER BY score DESC) as dense_rank -- 1,2,2,3...
FROM exam_scores;
```

三个区别（重要！）：

- `ROW_NUMBER()`：连续不重复（分数相同也给不同编号）
- `RANK()`：跳跃重复（分数相同并列，但下一个跳号）
- `DENSE_RANK()`：连续重复（分数相同并列，下一个不跳号）

分组排名——PARTITION BY

```
-- 每个科目内的成绩排名
SELECT
    course_id,
    student_id,
    score,
    ROW_NUMBER() OVER (PARTITION BY course_id ORDER BY score DESC) as course_rank
FROM exam_scores;
-- PARTITION BY: 相当于在每个分组里单独排名
```

累计计算

```sql
-- 累计销售额（按月）
SELECT
    month,
    sales_amount,
    SUM(sales_amount) OVER (ORDER BY month) as cum_sales
FROM monthly_sales;

-- 移动平均（最近3个月）
SELECT
    month,
    sales_amount,
    AVG(sales_amount) OVER (ORDER BY month ROWS BETWEEN 2 PRECEDING AND CURRENT ROW) as moving_
avg
FROM monthly_sales;
```

LAG / LEAD 偏移

```sql
-- 对比本月和上月的销售额
SELECT
    month,
    sales_amount,
    LAG(sales_amount, 1) OVER (ORDER BY month) as prev_month_sales,
    sales_amount - LAG(sales_amount, 1) OVER (ORDER BY month) as month_over_month
FROM monthly_sales;
```

2.6 CASE WHEN 条件判断

```sql
-- 将金额分档
SELECT
    order_id,
    amount,
    CASE
        WHEN amount < 100 THEN '小额'
        WHEN amount >= 100 AND amount < 500 THEN '中额'
        WHEN amount >= 500 THEN '大额'
        ELSE '未知'
    END as amount_level
FROM orders;

-- 行转列（经典用法）
SELECT
    month,
```

```
    SUM(CASE WHEN city = '太原' THEN amount ELSE 0 END) as taiyuan,
    SUM(CASE WHEN city = '北京' THEN amount ELSE 0 END) as beijing,
    SUM(CASE WHEN city = '上海' THEN amount ELSE 0 END) as shanghai
FROM sales
GROUP BY month;
```

2.7 SQL 实战面试题

连续登录问题

```
-- 找出连续登录7天及以上的用户
WITH login_dates AS (
    SELECT DISTINCT user_id, login_date
    FROM login_log
),
date_ranks AS (
    SELECT
        user_id,
        login_date,
        ROW_NUMBER() OVER (PARTITION BY user_id ORDER BY login_date) as rn
    FROM login_dates
),
diff AS (
    SELECT
        user_id,
        login_date,
        DATE_SUB(login_date, INTERVAL rn DAY) as group_key
    FROM date_ranks
)
SELECT user_id, COUNT(*) as continuous_days
FROM diff
GROUP BY user_id, group_key
HAVING COUNT(*) >= 7;
```

留存率计算

```
-- 次日/7日/30日留存率
WITH first_login AS (
    SELECT
        user_id,
        MIN(login_date) as first_date
    FROM login_log
```

```
    GROUP BY user_id
),
retention AS (
    SELECT
        f.first_date,
        COUNT(DISTINCT l.user_id) as new_users,
        COUNT(DISTINCT CASE WHEN DATEDIFF(l.login_date, f.first_date) = 1 THEN l.user_id END) a
s day1_retained,
        COUNT(DISTINCT CASE WHEN DATEDIFF(l.login_date, f.first_date) = 6 THEN l.user_id END) a
s day7_retained
    FROM first_login f
    LEFT JOIN login_log l ON f.user_id = l.user_id
    GROUP BY f.first_date
)
SELECT
    first_date,
    new_users,
    ROUND(day1_retained / new_users * 100, 2) as day1_retention_rate,
    ROUND(day7_retained / new_users * 100, 2) as day7_retention_rate
FROM retention
ORDER BY first_date;
```

第三章：Excel 数据分析实战

3.1 Excel 在数据分析中的定位

虽然SQL和Python能处理更大的数据量，但Excel仍然是数据分析师最常用的工具之一，特别是：

- **快速查看数据**：打开CSV/Excel就能看
- **临时分析**：不需要写代码，拖拽就能出结果
- **汇报呈现**：很多业务方和管理层习惯看Excel表

3.2 核心快捷键

快捷键	作用	说明

`Ctrl + Shift + ↓`	选中到数据末尾	快速选择整列数据
`Ctrl + T`	创建超级表	数据会自动扩展，公式自动填充
`Alt + N + V`	创建数据透视表	最快的方法
`Ctrl + Shift + L`	打开/关闭筛选	筛选器开关
`F4`	切换引用方式	绝对引用/混合引用切换
`Ctrl + `	显示所有公式	调试时非常有用

3.3 必会函数

查找引用类

```
VLOOKUP(lookup_value, table_array, col_index_num, [range_lookup])
|-- 找什么 --|-- 在哪里找 --|-- 返回第几列 --|-- 精确/模糊 --
```

```
=VLOOKUP(A2, $B$2:$D$100, 3, FALSE)
-- 在B2:D100区域中找A2的值，返回第3列，精确匹配

-- XLOOKUP 是 VLOOKUP 的升级版（Excel 2021+ / Office 365）
=XLOOKUP(A2, B:B, C:C)
-- 在B列找A2，返回C列对应值
```

条件统计类

```
=SUMIF(条件区域, 条件, 求和区域)          -- 单条件求和
=SUMIFS(求和区域, 条件区域1, 条件1, 条件区域2, 条件2)  -- 多条件求和
=COUNTIF(条件区域, 条件)                  -- 单条件计数
=COUNTIFS(条件区域1, 条件1, 条件区域2, 条件2)          -- 多条件计数
=AVERAGEIF(条件区域, 条件, 求平均区域)    -- 条件求平均

-- 示例：统计太原校区报名人数
=COUNTIFS(校区列, "太原", 报名状态列, "已报名")
```

文本处理类

```
=LEFT(文本, 位数)       -- 取左边N位
=RIGHT(文本, 位数)      -- 取右边N位
=MID(文本, 起始位置, 位数)  -- 从中间取
=LEN(文本)              -- 文本长度
=FIND(要找的文本, 在哪找)   -- 查找位置
=CONCATENATE(文本1, 文本2)   -- 合并文本（或用 & 符号）
=TEXT(值, 格式)         -- 格式化显示
=IFERROR(公式, 出错时返回的值)  -- 错误处理
```

日期类

```
=TODAY()                        -- 今天日期
=YEAR(日期)                     -- 提取年份
=MONTH(日期)                    -- 提取月份
=DATEDIF(开始日期, 结束日期, "d")  -- 计算天数差（"m"月, "y"年）
=WEEKDAY(日期, 2)               -- 周几（2: 周一=1...周日=7）
```

3.4 数据透视表（核心技能）

创建步骤

1. 选中数据区域 → 插入 → 数据透视表
2. 把字段拖到四个区域：

区域	作用	示例
行标签	纵向展示的维度	校区、月份
列标签	横向展示的维度	课程类型
值	要统计的指标	报名人数、金额
筛选器	对整个透视表筛选	年份

常用技巧

- **值字段设置**：右键值 → 值字段设置 → 可以改计算方式（求和/计数/平均值）和显示方式（占比/差异）
- **分组**：右键日期 → 组合 → 按月/季度/年

- **切片器**：选中透视表 → 插入切片器 → 做成交互式筛选按钮
- **计算字段**：选中透视表 → 分析 → 字段、项目和集 → 计算字段

3.5 Power Query（数据清洗利器）

Power Query 是 Excel 内置的数据清洗工具，适合做重复性的数据整理工作。

常用操作：

- 删除空行/空列
- 拆分列（按分隔符）
- 合并查询（类似SQL的JOIN）
- 分组依据（类似SQL的GROUP BY）
- 添加自定义列（类似Excel公式）

第四章：Python 数据分析基础

4.1 Python 在数据分析中的角色

Python不是必需的，但会了会是巨大的加分项。主要用在：

- **自动化处理**：每天/每周自动跑报表
- **大数据量**：Excel打不开的几百万行数据
- **统计分析**：假设检验、回归分析
- **机器学习**：预测模型（加分项，非必需）

4.2 Pandas 核心操作

安装

```
pip install pandas openpyxl matplotlib
```

数据读取

```
import pandas as pd

# 读取CSV
df = pd.read_csv('data.csv')

# 读取Excel（可以指定sheet）
df = pd.read_excel('data.xlsx', sheet_name='Sheet1')

# 读取数据库
from sqlalchemy import create_engine
engine = create_engine('mysql+pymysql://user:password@host/database')
df = pd.read_sql('SELECT * FROM orders', engine)

# 快速查看
df.head()          # 前5行
df.info()          # 列信息、数据类型、非空计数
df.describe()      # 数值列的统计摘要
df.shape           # (行数, 列数)
```

数据清洗

```
# 查看缺失值
df.isnull().sum()

# 删除缺失值
df = df.dropna(subset=['重要列'])  # 删掉重要列为空的行
df = df.dropna(thresh=len(df.columns)-3)  # 删掉缺失超过3列的行

# 填充缺失值
df['列名'] = df['列名'].fillna(0)            # 填0
df['列名'] = df['列名'].fillna(df['列名'].mean())  # 填平均值
df['列名'] = df['列名'].fillna(method='ffill')    # 填上一个值

# 删除重复行
df = df.drop_duplicates()
df = df.drop_duplicates(subset=['user_id'])  # 按某列去重

# 修改数据类型
df['日期'] = pd.to_datetime(df['日期'])
df['金额'] = df['金额'].astype(float)
```

```
# 筛选
high_value = df[df['金额'] > 1000]  # 类似SQL的WHERE
beijing = df[df['城市'] == '北京']
condition = df[(df['金额'] > 500) & (df['城市'] == '太原')]

# 排序
df_sorted = df.sort_values('金额', ascending=False)  # 降序
```

分组聚合

```
# 按城市分组统计（类似SQL: GROUP BY）
result = df.groupby('城市')['金额'].agg(['sum', 'mean', 'count', 'max'])
result.columns = ['总金额', '平均金额', '订单数', '最大金额']

# 多维度分组
result = df.groupby(['城市', '课程类型'])['金额'].sum()

# 透视表（Pivot Table）
pivot = pd.pivot_table(
    df,
    values='金额',
    index='城市',
    columns='课程类型',
    aggfunc='sum',
    fill_value=0
)
```

日期处理

```
# 提取日期成分
df['年份'] = df['日期'].dt.year
df['月份'] = df['日期'].dt.month
df['周几'] = df['日期'].dt.dayofweek  # 0=周一
df['周'] = df['日期'].dt.isocalendar().week

# 按月份统计
monthly = df.set_index('日期').resample('M')['金额'].sum()
```

导出

```
df.to_csv('result.csv', index=False, encoding='utf-8-sig')
df.to_excel('result.xlsx', index=False, sheet_name='报表')
```

4.3 数据可视化（Matplotlib基础）

```
import matplotlib.pyplot as plt
import matplotlib
matplotlib.rcParams['font.sans-serif'] = ['SimHei']  # 支持中文
matplotlib.rcParams['axes.unicode_minus'] = False

# 折线图（趋势）
plt.figure(figsize=(10, 5))
plt.plot(df['月份'], df['销售额'], marker='o')
plt.title('月度销售额趋势')
plt.xlabel('月份')
plt.ylabel('销售额（万元）')
plt.grid(True)
plt.savefig('trend.png', dpi=150, bbox_inches='tight')
plt.show()

# 柱状图（对比）
plt.figure(figsize=(10, 5))
plt.bar(df['城市'], df['销售额'], color='steelblue')
plt.title('各城市销售额对比')
plt.xticks(rotation=45)
plt.savefig('bar.png', dpi=150, bbox_inches='tight')

# 饼图（占比）
plt.figure(figsize=(8, 8))
sizes = df['占比']
labels = df['类别']
plt.pie(sizes, labels=labels, autopct='%1.1f%%', startangle=90)
plt.title('各类别占比')
plt.savefig('pie.png', dpi=150, bbox_inches='tight')
```

4.4 一个完整分析案例

```
import pandas as pd
import matplotlib.pyplot as plt

# 1. 读取数据
df = pd.read_excel('教学数据.xlsx')
```

```python
# 2. 数据清洗
df = df.drop_duplicates()
df = df.dropna(subset=['学生ID'])
df['报名日期'] = pd.to_datetime(df['报名日期'])

# 3. 分析：每月报名人数趋势
monthly = df.set_index('报名日期').resample('M').size()

# 4. 分析：各课程报名人数
course_stats = df.groupby('课程名称').agg({
    '学生ID': 'count',
    '缴费金额': 'sum'
}).rename(columns={'学生ID': '报名人数', '缴费金额': '总收入'})

# 5. 分析：按校区统计
campus_stats = df.pivot_table(
    values='缴费金额',
    index='校区',
    columns='课程名称',
    aggfunc='sum',
    fill_value=0
)

# 6. 导出结果
with pd.ExcelWriter('分析结果.xlsx') as writer:
    monthly.to_excel(writer, sheet_name='月度趋势')
    course_stats.to_excel(writer, sheet_name='课程统计')
    campus_stats.to_excel(writer, sheet_name='校区课程收入')

print("分析完成！结果已保存到 分析结果.xlsx")
```

第五章：Tableau 可视化与仪表盘

5.1 Tableau 是什么

Tableau 是目前最主流的数据可视化工具之一，也是招聘JD明确要求的技能。它的核心优势是：

- **拖拽式操作**：不需要写代码
- **交互式仪表盘**：点击某个区域，其他图表自动联动
- **美观的图表**：秒杀Excel自带的图表

- **企业级看板**：可以发布到服务器，多人共用

5.2 Tableau 核心概念

概念	英文	解释
维度	Dimension	分类数据（蓝色），如城市、课程、月份
度量	Measure	数值数据（绿色），如销售额、人数
工作表	Worksheet	单个图表
仪表盘	Dashboard	多个工作表的组合
故事	Story	多个仪表盘按顺序讲述一个故事
工作簿	Workbook	包含所有工作表、仪表盘的文件（.twb或.twbx）
数据提取	Extract (.hyper)	将数据拉到Tableau本地，比实时连接快
实时连接	Live Connection	直接连接数据库实时查询

拖拽规则：

> **维度（蓝色）放到行/列 → 度量（绿色）放到行/列 → 就出图了**

- 蓝色字段拖到行/列：生成表头/标签
- 绿色字段拖到行/列：生成坐标轴/数值
- 度量拖到颜色/大小/标签：给图表上色、缩放、加标签

5.3 基础图表制作

柱状图（对比）

3. 把"城市"（维度）拖到**列**
4. 把"销售额"（度量）拖到**行**
5. 点击工具栏"智能推荐"，选柱状图

折线图（趋势）

6. 把"订单日期"（维度）拖到**列**，右键选"连续的月份"
7. 把"销售额"（度量）拖到**行**
8. 自动生成折线图

饼图（占比）

9. 把"课程分类"拖到**列**
0. 把"报名人数"拖到**行**
1. 标记类型改为"饼图"
2. 把"课程分类"再拖到"颜色"
3. 把"报名人数"拖到"标签"

地图（区域分布）

4. 双击"省份"（地理角色已分配）
5. 自动生成地图
6. 把"销售额"拖到颜色

热力图（交叉分析）

7. 把"城市"拖到行
8. 把"课程类型"拖到列
9. 把"销售额"拖到颜色
0. 颜色编码自动显示高低

5.4 计算字段

计算字段是Tableau的核心进阶技能，相当于在Tableau里写公式。

基础计算

```
-- 计算字段名：利润率
SUM([利润]) / SUM([销售额])

-- 计算字段名：折扣金额
[原价] * [折扣率]

-- 计算字段名：同比
(SUM([2026年销售额]) - SUM([2025年销售额])) / SUM([2025年销售额])
```

条件计算

```
-- 高价值客户标记
IF SUM([消费金额]) > 10000 THEN "VIP"
ELSEIF SUM([消费金额]) > 5000 THEN "重要"
ELSE "普通"
END
```

5.5 参数控制（关键技能！）

参数让用户通过下拉菜单或滑块动态切换指标。这是面试高频考点。

创建参数步骤：

1. 在数据窗格右键 → 创建 → 参数
2. 设置参数名（如"选择指标"）
3. 数据类型：字符串
4. 允许的值：列表 → 输入"销售额, 利润, 订单数"

使用参数：

5. 创建计算字段：

```
CASE [选择指标]  -- 参数名
    WHEN "销售额" THEN SUM([销售额])
    WHEN "利润" THEN SUM([利润])
    WHEN "订单数" THEN COUNT([订单ID])
END
```

6. 把这个计算字段拖到视图中
7. 右键参数 → 显示参数控件 → 出现下拉菜单

5.6 LOD 表达式（面试加分项！）

LOD（Level of Detail）是Tableau最强大的功能之一，允许你控制计算的"粒度"。

三种LOD

类型	语法	作用
FIXED	`{FIXED [维度] : 聚合表达式}`	忽略视图中的所有维度
INCLUDE	`{INCLUDE [维度] : 聚合表达式}`	在视图维度的基础上额外增加维度
EXCLUDE	`{EXCLUDE [维度] : 聚合表达式}`	排除视图中的某个维度

常见场景

```
-- 每个客户的总消费（忽略视图筛选）
{FIXED [客户ID] : SUM([消费金额])}

-- 对比每个城市的销售额占总销售额的百分比
SUM([销售额]) / {FIXED : SUM([销售额])}

-- 每个订单金额占客户总消费的比例
SUM([订单金额]) / {FIXED [客户ID] : SUM([订单金额])}
```

5.7 仪表盘制作

布局原则

8. **上重点下辅助**：最重要的KPI放在左上角
9. **左到右、上到下**：遵循用户阅读习惯
0. **一致性**：颜色、字体、样式统一

1. **10秒原则**：用户10秒内应该看懂仪表盘的核心信息

制作步骤

2. 创建2-5个工作表（每个一张图表）
3. 点击底部"新建仪表盘"
4. 从左侧拖入工作表到仪表盘区域
5. 添加筛选器、参数控件
6. 设置图表联动：仪表盘 → 操作 → 添加操作 → "筛选器"
7. 调整布局：使用水平/垂直容器实现自适应
8. 添加标题、说明文字

仪表盘交互功能

功能	操作	效果
图表筛选器	右键图表 → 用作筛选器	点击一个图表，其他图表联动
参数控件	右键参数 → 显示参数控件	下拉菜单/滑块切换指标
URL动作	仪表盘 → 操作 → 转到URL	点击跳转到详情页面
工具提示	工具提示卡里拖入更多字段	鼠标悬停显示详细信息
高亮	仪表盘 → 添加→突出显示动作	同颜色数据一起高亮

5.8 数据源管理

数据混合（Data Blending）

当主数据源和次要数据源无法直接连接时使用。

9. 数据 → 新数据源 → 添加第二个数据源
0. 分析 → 创建混合关系 → 选择一个公共字段连接
1. 次要数据源的字段使用时，会自动按公共字段匹配

数据提取优化

- 大数据集（>100万行）使用数据提取（.hyper）
- 提取时做聚合过滤：仅提取需要的行和列
- 定期刷新：通过Tableau Server或命令行刷新

第六章：业务指标体系搭建

6.1 什么是指标体系

指标体系就是一套有层次、有关联的指标集合，用来全面衡量业务健康度。

> **"没有指标，业务好不好就是凭感觉；有指标体系，一切用数据说话。"**

6.2 OSM 模型（最实用）

数分面试中OSM模型是必考题，也是实际工作中最实用的方法论。

字母	英文	中文	例子（教育培训行业）
O	Objective	业务目标	提升课程报名转化率
S	Strategy	业务策略	优化课程体验课、推出限时优惠
M	Measurement	衡量指标	体验课预约率、试听转化率、优惠券核销率

OSM实战（教培行业）

```
Objective（战略目标）：扩大太原市场占有率
```

```
├─ Strategy 1: 提升品牌知名度
│    └─ Measurement: 品牌搜索量、公众号关注数
│
├─ Strategy 2: 提升招生效率
│    └─ Measurement: 获客成本、线索转化率、到店率
│
└─ Strategy 3: 提升续费率
     └─ Measurement: 课程完成率、家长满意度、续费意愿
```

6.3 指标分级

北极星指标

公司最重要的那个指标，所有工作都围绕它展开。

- 教培行业北极星指标示例：**有效学员数** 或 **续报率**
- 电商行业北极星指标：**GMV**（成交总额）
- 互联网产品北极星指标：**DAU**（日活跃用户）

三级指标体系

```
北极星指标：有效学员数
     ↓
一级指标（全局层面）：
     ├─ 新招学员数
     ├─ 学员流失数
     └─ 学员续费率
     ↓
二级指标（业务层面）：
     ├─ 市场：曝光量、线索量、获客成本
     ├─ 销售：接通率、邀约率、转换率
     ├─ 教学：出勤率、作业提交率、满意度
     └─ 服务：投诉率、续费率、转介绍率
     ↓
三级指标（执行层面）：
     ├─ 每日电话拨打量、接通量
     ├─ 体验课预约数、到店人数
     ├─ 各科产出勤明细
     └─ 每节课的评分明细
```

6.4 指标口径统一

为什么口径重要？

同一个指标，不同部门理解不同，会导致数据打架。

例子——"转化率"可能有多种定义：

- 销售部：签单人数 / 试听到店人数
- 市场部：试听预约数 / 广告曝光量
- 管理层：付费学员 / 所有线索

口径文档模板

```
【指标名】课程报名转化率
【业务定义】在体验课结束后的7天内购买正式课程的学生比例
【计算公式】购买正式课程人数 / 参加体验课人数 × 100%
【统计周期】按周/月度统计
【数据来源】报名系统 体验课记录表 + 缴费记录表
【更新频率】每日更新
【负责部门】运营部
【备注】排除内部员工子女、免费名额
```

6.5 常用分析框架

漏斗分析

```
曝光线索 → 到店试听 → 购买课程 → 完课续费
 10000       1500          800          400
    │          │            │            │
    ↓15%       ↓53%         ↓50%         ↓--
```

- **发现瓶颈**：哪一步转化率最低？
- **优化方向**：针对瓶颈环节做改进

拆解分析

```
总营收 = 学员数 × 客单价 × 购课频次
          │          │          │
          │          │          └── 年度购课次数
          │          └──────────── 平均客单价
          └─────────────────────── 有效学员总数
```

哪个因子下降最多，就是问题所在。

同比环比

- **同比**：跟去年同期比（消除季节性因素）
- **环比**：跟上个月/上周比（看近期趋势）

```sql
-- 月环比
SELECT
    month,
    sales,
    LAG(sales, 1) OVER (ORDER BY month) as prev_month,
    ROUND((sales - LAG(sales, 1) OVER (ORDER BY month)) /
          LAG(sales, 1) OVER (ORDER BY month) * 100, 1) as mom_growth
FROM monthly_sales;

-- 同比
SELECT
    month,
    sales,
    LAG(sales, 12) OVER (ORDER BY month) as same_month_last_year,
    ROUND((sales - LAG(sales, 12) OVER (ORDER BY month)) /
          LAG(sales, 12) OVER (ORDER BY month) * 100, 1) as yoy_growth
FROM monthly_sales;
```

第七章：数据监控与预警

7.1 监控看板设计

数据监控是数据分析师的重要日常职责。

监控看板层级

层级	受众	刷新频率	重点内容
战略层	总经理、VP	日报/周报	北极星指标、营收、学员数
管理层	部门负责人	日报	部门KPI完成进度
执行层	一线员工	实时/小时	个人指标、待跟进事项

监控看板必备元素

5. **KPI卡片**：关键数字突出展示，带同比/环比变化
6. **趋势图**：最近N天/周的变化趋势
7. **预警标识**：异常值标红/闪烁
8. **下钻功能**：从总体下钻到明细

7.2 预警规则设计

常见预警类型

类型	判定规则	示例
阈值预警	指标超过/低于设定阈值	转化率低于10%触发预警
波动预警	环比/同比波动超过N%	日营收环比下降超20%
趋势预警	连续N天下降/上升	连续3天新增线索下降

数据质量预警	缺失率异常、数据延迟	昨日数据凌晨3点还未到齐

预警阈值设定方法

9. **历史数据法**：计算过去30天的均值±2倍标准差
0. **业务经验法**：由业务方根据经验设定
1. **对比法**：与行业平均水平对比

7.3 使用SQL实现监控

```
-- 每日关键指标监控
SELECT
    report_date,
    new_students,
    LAG(new_students, 1) OVER (ORDER BY report_date) as prev_day,
    LAG(new_students, 7) OVER (ORDER BY report_date) as prev_week_same_day,
    -- 环比变动
    ROUND((new_students - LAG(new_students, 1) OVER (ORDER BY report_date)) /
          NULLIF(LAG(new_students, 1) OVER (ORDER BY report_date), 0) * 100, 1) as mom_change_p
ct,
    -- 预警标记
    CASE
        WHEN new_students < LAG(new_students, 1) OVER (ORDER BY report_date) * 0.7 THEN '⚠ 大幅
下降'
        WHEN new_students < LAG(new_students, 7) OVER (ORDER BY report_date) * 0.8 THEN '⚠ 低于
上周同期'
        WHEN new_students IS NULL THEN '❌ 数据缺失'
        ELSE '✅ 正常'
    END as alert_flag
FROM daily_student_stats
WHERE report_date >= CURRENT_DATE - INTERVAL 30 DAY
ORDER BY report_date DESC;
```

第八章：数据清洗与处理

8.1 为什么要做数据清洗

真实的数据永远是不完美的。数据清洗是数据分析的第一步，也往往是最耗时的步骤。

常见数据问题

问题	示例	影响
缺失值	电话号码为空	无法统计有效线索
重复值	同一学员重复录入	统计数据虚高
异常值	年龄200岁、金额为负数	影响平均值计算
格式不一致	手机号有些带-有些不带	无法合并匹配
逻辑错误	报名日期晚于毕业日期	数据不可信

8.2 SQL 清洗实战

```
-- 清洗手机号
UPDATE students
SET phone = REGEXP_REPLACE(phone, '[^0-9]', '')  -- 去除非数字
WHERE phone IS NOT NULL;

-- 标记异常数据
SELECT *,
    CASE
        WHEN age < 0 OR age > 100 THEN '异常'
        WHEN age BETWEEN 0 AND 3 THEN '需确认'
        ELSE '正常'
    END as data_quality
FROM students;

-- 处理重复数据（保留最早的记录）
WITH numbered AS (
    SELECT *,
        ROW_NUMBER() OVER (PARTITION BY user_id ORDER BY create_time ASC) as rn
    FROM students
)
DELETE FROM students WHERE (user_id, create_time) IN (
    SELECT user_id, create_time FROM numbered WHERE rn > 1
);
```

8.3 Python 清洗实战

```
import pandas as pd

df = pd.read_csv('raw_data.csv')

# 1. 去重
df = df.drop_duplicates(subset=['手机号'])

# 2. 处理缺失值
df['年龄'] = df['年龄'].fillna(df['年龄'].median())  # 年龄填中位数
df['邮箱'] = df['邮箱'].fillna('未知')               # 文本填默认值
df = df.dropna(subset=['姓名', '手机号'])             # 关键信息缺失则删除

# 3. 处理异常值
df = df[df['年龄'].between(0, 100)]
df = df[df['金额'] > 0]

# 4. 格式统一
df['手机号'] = df['手机号'].astype(str).str.replace(r'\D', '', regex=True)
df['日期'] = pd.to_datetime(df['日期'], errors='coerce')

# 5. 检查清洗效果
print(f"清洗前: {len(df)}行")
print(f"清洗后: {len(df)}行")
print(f"删除: {5000 - len(df)}行异常数据")
print(f"缺失值统计: {df.isnull().sum()}")
```

第九章：数据分析报告撰写

9.1 报告类型

类型	频率	受众	内容重点
日报	每日	运营/管理层	昨日核心指标、异常预警
周报	每周	管理层	本周趋势、重点项目进展

月报	每月	部门/公司领导	月度回顾、KPI达成、问题分析
专题报告	按需	相关方	深度分析一个具体问题

9.2 报告结构模板

例行报告（周报/月报）模板

```
【标题】XX校区20XX年X月运营分析月报

一、核心数据概览
   ├─ 本月核心KPI（附同比/环比变化）
   ├─ KPI达成率（目标 vs 实际）
   └─ 一句话总结（"本月整体表现平稳，续费率有所提升"）

二、详细分析
   ├─ 招生分析：各渠道表现、获客成本
   ├─ 教学分析：出勤率、完课率、满意度
   └─ 财务分析：营收、利润、人效

三、异常与预警
   ├─ 数据异常点（标注原因）
   └─ 风险提示（需重点关注的事项）

四、改进建议
   ├─ 数据层面的发现
   └─ 可执行的行动建议

五、附录
   └─ 数据口径说明、原始数据表
```

9.3 报告撰写原则

原则	说明	反面例子	正面例子
结论先行	先说结果再说过程	"我们做了A/B/C…最后发现X提升"	"X指标提升20%，主要因为..."
数据说话	每句话都有数据支撑	"最近招生不错"	"本月招生120人，环比增长15%"

可视化	能用图就不用表，能用表就不用文字	一大段文字描述趋势	折线图+一句话总结
可执行	报告不能只分析，要有行动建议	"转化率下降了"	"建议优化体验课流程，预计可提升5%转化率"

9.4 分析框架示例

问题诊断分析框架

```
问题：本月续费率从60%下降到45%

Step 1：数据验证
  → 确认数据无误，排除口径/统计问题

Step 2：维度拆解
  → 按校区、年级、课程、教师拆解
  → 发现：初三毕业班续费率下降最明显（从55%→20%）

Step 3：原因定位
  → 中考政策变化，毕业班学生不再需要课外辅导
  → 属于行业周期性现象，非教学质量问题

Step 4：策略建议
  → 1. 毕业班推出"暑假预科班"，衔接高中课程
  → 2. 针对非毕业班加强家长沟通，稳住基本盘

Step 5：效果追踪
  → 下个月继续监控续费率变化
```

第十章：面试准备与常见问题

10.1 技术面试准备清单

SQL 必会题（面试常考）

2. 窗口函数：ROW_NUMBER、RANK、DENSE_RANK的区别
3. 连续N天登录的用户
4. 留存率计算（次日/7日/30日）
5. 行转列/列转行
6. TopN问题（每个分类取前3名）
7. 中位数计算
8. 同比环比计算
9. 累计求和/移动平均

Tableau 必会题

0. 参数的作用和使用方法
1. LOD表达式：FIXED/INCLUDE/EXCLUDE的区别
2. 数据混合和数据连接的区别
3. 如何实现仪表盘交互联动
4. 大数据量时的性能优化

数据分析基础

5. 什么是指标体系？怎么搭建？
6. 留存率怎么算？
7. A/B测试的基本原理
8. 如何判断两个数据是否有显著差异

10.2 行为面试准备

常见问题

Q："数据结论和业务直觉冲突时怎么办？"

> 回答思路：先确认数据口径和计算过程是否正确 → 如果数据正确，不要怀疑数据 → 和业务方深入沟通，理解"直觉"背后的经验 → 找出差异原因，可能是数据口径不同或业务方经验在新的环境下失效 → 综合双方意见，达成共识

Q："描述一个你推动业务决策的数据分析项目"

> 回答思路：使用STAR原则

> - Situation：业务背景，遇到了什么问题

> - Task：你的分析目标是什么

> - Action：你用到了什么数据、什么工具、什么分析方法

> - Result：你的分析结论是什么，业务方采纳了什么建议，带来了什么效果

10.3 新东方教培行业面试重点

针对新东方太原分校的特点，面试可能会重点考察：

9. **教培行业核心指标**：续报率、满班率、退费率、转介绍率
0. **招生漏斗分析**：曝光→咨询→试听→报名→续费
1. **季节性分析**：寒暑假高峰期、开学后的策略
2. **校区对比**：不同校区的运营效率对比
3. **教师效能分析**：排课率、班均人数、好评率

附录：常用命令与函数速查表

A.1 SQL 速查表

```
-- 查询基础
SELECT col1, col2 FROM table WHERE condition;
SELECT * FROM table LIMIT 10;
SELECT DISTINCT col FROM table;
```

```
-- 聚合
COUNT(*), SUM(col), AVG(col), MAX(col), MIN(col)
SELECT col, COUNT(*) FROM table GROUP BY col HAVING COUNT(*) > N;

-- JOIN
INNER JOIN / LEFT JOIN / RIGHT JOIN / FULL OUTER JOIN

-- 窗口函数
ROW_NUMBER() OVER (PARTITION BY dim ORDER BY measure DESC) as rn
RANK() / DENSE_RANK()
SUM() OVER (ORDER BY date ROWS BETWEEN N PRECEDING AND CURRENT ROW)
LAG(col, N) OVER (ORDER BY date)
LEAD(col, N) OVER (ORDER BY date)

-- 条件
CASE WHEN cond1 THEN val1 WHEN cond2 THEN val2 ELSE val3 END

-- 日期函数
DATE_TRUNC('month', date)
DATEDIFF(end, start)
DATE_ADD(date, INTERVAL N DAY)
EXTRACT(YEAR/MONTH/DAY FROM date)

-- 字符串
CONCAT(a, b), SUBSTRING(str, start, len)
REPLACE(str, old, new)
UPPER(str), LOWER(str)
LENGTH(str), TRIM(str)
```

A.2 Excel 速查表

```
' 查找引用
=VLOOKUP(找什么, 在哪找, 返回第几列, FALSE)
=XLOOKUP(找什么, 在哪找, 返回什么)
=INDEX(区域, 行号, 列号)
=MATCH(找什么, 在哪找, 0)

' 条件统计
=SUMIF(条件区域, 条件, 求和区域)
=SUMIFS(求和区域, 条件区域1, 条件1, ...)
=COUNTIF(条件区域, 条件)
=COUNTIFS(条件区域1, 条件1, ...)

' 文本
=LEFT(text, n), RIGHT(text, n), MID(text, start, n)
=LEN(text)
=FIND(find_text, within_text)
=TEXT(value, "yyyy-mm-dd")
```

```
' 日期
=TODAY(), =NOW()
=YEAR(date), =MONTH(date), =DAY(date)
=DATEDIF(start, end, "d")  ' d/m/y差异

' 逻辑
=IF(条件, 真值, 假值)
=IFERROR(公式, 出错返回)
=AND(条件1, 条件2), =OR(条件1, 条件2)

' 快捷键
Ctrl+T  创建超级表
Alt+N+V 创建数据透视表
Ctrl+Shift+L 筛选开关
F4  切换绝对引用
```

A.3 Python Pandas 速查表

```
import pandas as pd

# 读写
df = pd.read_csv('file.csv')
df = pd.read_excel('file.xlsx', sheet_name='Sheet1')
df.to_csv('out.csv', index=False)
df.to_excel('out.xlsx', index=False)

# 查看
df.head(), df.info(), df.describe(), df.shape, df.columns

# 筛选
df[df['col'] > 100]
df[(df['col1'] > 100) & (df['col2'] == 'A')]

# 分组
df.groupby('col')['value'].agg(['sum', 'mean', 'count'])
df.pivot_table(values='value', index='row', columns='col', aggfunc='sum')

# 清洗
df.dropna(), df.fillna(0), df.drop_duplicates()
df['col'] = df['col'].astype(int)
df['date'] = pd.to_datetime(df['date'])

# 日期
df['date'].dt.year, .dt.month, .dt.day
df.set_index('date').resample('M')['value'].sum()

# 合并
```

```
pd.merge(df1, df2, on='key', how='left')
pd.concat([df1, df2])
```

A.4 Tableau 速查表

功能	操作/语法
创建表计算	右键度量 → 快速表计算
参数	右键数据窗格 → 创建 → 参数
计算字段	右键数据窗格 → 创建 → 计算字段
LOD FIXED	`{FIXED [维度] : SUM([度量])}`
LOD INCLUDE	`{INCLUDE [维度] : SUM([度量])}`
LOD EXCLUDE	`{EXCLUDE [维度] : SUM([度量])}`
仪表盘联动	仪表盘 → 操作 → 添加 → 筛选器
发布到Server	服务器 → 发布工作簿

> **最后的话**

>

> 数据分析师的核心不是工具或代码，而是**用数据回答业务问题的能力**。

>

> 工具（SQL/Excel/Python/Tableau）可以学，但**业务敏感度**和**逻辑思维能力**需要在实战中慢慢积累。

>

> 祝你面试顺利！□

— 全文完 —

祝你面试顺利 □