

尚硅谷大数据项目之电商数据仓库系统

(作者：尚硅谷大数据研发部)

版本：V6.2.0

第 1 章 数仓分层

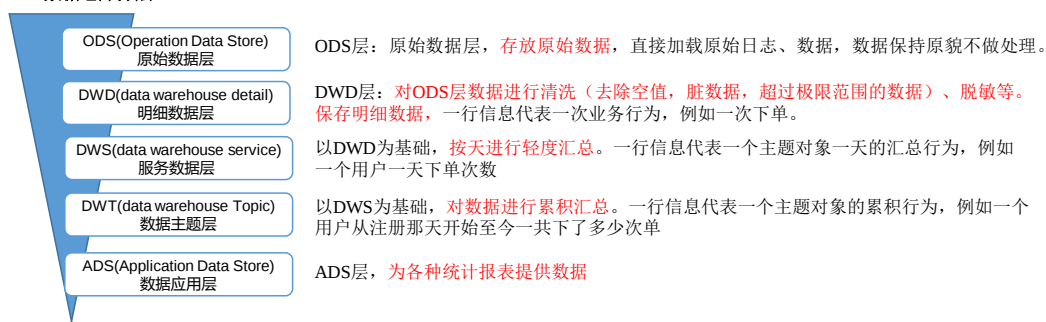
1.1 为什么要分层



为什么要分层



一、数据仓库分层



二、数据仓库为什么要分层

- 1) **把复杂问题简单化** 将复杂的**任务分解**成多层来完成，每一层只处理简单的任务，**方便定位问题**。
- 2) **减少重复开发** 规范数据分层，通过的**中间层数据**，能够减少极大的重复计算，**增加一次计算结果的复用性**。
- 3) **隔离原始数据** 不论是数据的异常还是数据的敏感性，使真实数据与统计数据**解耦开**。

1.2 数据集市与数据仓库概念




数据集市与数据仓库区别



数据集市（Data Market），现在市面上的公司和书籍都对数据集市有不同的概念。

数据集市则是一种微型的数据仓库，它通常有更少的数据，更少的主题区域，以及更少的历史数据，因此是**部门级的**，一般只能为某个局部范围内的管理人员服务。

数据仓库是企业级的，能为整个企业各个部门的运行提供决策支持手段。



让天下没有难学的技术

1.3 数仓命名规范

1.3.1 表命名

- ODS层命名为ods_表名
- DWD层命名为dwd_dim/fact_表名
- DWS层命名为dws_表名
- DWT层命名为dwt_表名
- ADS层命名为ads_表名
- 临时表命名为xxx_tmp
- 用户行为表，以log为后缀。

1.3.2 脚本命名

- 数据源_to_目标_db/log.sh
- 用户行为脚本以log为后缀；业务数据脚本以db为后缀。

1.3.3 表字段类型

- 数量类型为bigint
- 金额类型为decimal(16, 2)，表示：16 位有效数字，其中小数部分 2 位
- 字符串(名字，描述信息等)类型为string
- 主键外键类型为string
- 时间戳类型为bigint

第 2 章 数仓理论

2.1 范式理论

2.1.1 范式概念

1) 定义

范式可以理解为设计一张数据表的表结构，符合的标准级别、规范和要求。

2) 优点

采用范式，可以降低数据的冗余性。

为什么要降低数据冗余性？

- (1) 十几年前，磁盘很贵，为了减少磁盘存储。
- (2) 以前没有分布式系统，都是单机，只能增加磁盘，磁盘个数也是有限的
- (3) 一次修改，需要修改多个表，很难保证数据一致性

3) 缺点

范式的缺点是获取数据时，需要通过 **Join 拼接** 出最后的数据。

4) 分类

目前业界范式有：**第一范式(1NF)**、**第二范式(2NF)**、**第三范式(3NF)**、**巴斯-科德范式(BCNF)**、**第四范式(4NF)**、**第五范式(5NF)**。

2.1.2 函数依赖

函数依赖

学号	姓名	系名	系主任	课程	分数
1022211101	李小明	经济系	王强	高等数学	95
1022211101	李小明	经济系	王强	大学英语	87
1022211101	李小明	经济系	王强	普通化学	76
1022211102	张莉莉	经济系	王强	高等数学	72
1022211102	张莉莉	经济系	王强	大学英语	98
1022211102	张莉莉	经济系	王强	计算机基础	88
1022511101	高芳芳	法律系	刘玲	高等数学	82
1022511101	高芳芳	法律系	刘玲	法学基础	82

1、完全函数依赖：

设X, Y是关系R的两个属性集合，X'是X的真子集，存在 $X \rightarrow Y$ ，但对每一个X'都有 $X' \not\rightarrow Y$ ，则称Y完全函数依赖于X。记做： $X \twoheadrightarrow Y$ 。

人类语言：

比如通过，(学号，课程) 推出分数，但是单独用学号推断不出来分数，那么可以说：分数 完全依赖于(学号，课程)。

即：通过AB能得出C，但是AB单独得不出C，那么说C完全依赖于AB。

2、部分函数依赖

假如Y函数依赖于X，但同时Y并不完全函数依赖于X，

那么我们就称Y部分函数依赖于X，记做： $X \rightharpoonup Y$ 。

人类语言：

比如通过，(学号，课程) 推出姓名，因为其实直接可以通过，学号推出姓名，所以：姓名 部分依赖于(学号，课程)。

即：通过AB能得出C，通过A也能得出C，或者通过B也能得出C，那么说C部分依赖于AB。

3、传递函数依赖

传递函数依赖：设X, Y, Z是关系R中互不相同的属性集合，存在 $X \rightarrow Y(Y \not\rightarrow X)$, $Y \rightarrow Z$ ，则称Z传递函数依赖于X。记做： $X \twoheadrightarrow Z$ 。

人类语言：

比如：学号 推出 系名，系名 推出 系主任，但是，系主任推不出学号，系主任主要依赖于系名。这种情况可以说：系主任 传递依赖于 学号。

通过A得到B，通过B得到C，但是C得不到A，那么说C传递依赖于A。

让天下没有难学的技术

2.1.3 三范式区分

第一范式

1、第一范式1NF核心原则就是：属性不可切割

表 不符合一范式的表格设计

ID	商品	商家ID	用户ID
001	5 台电脑	XXX旗舰店	00001

很明显上图所示的表格设计是不符合第一范式的，商品列中的数据不是原子数据项，是可以进行分割的，因此对表格进行修改，让表格符合第一范式的要求，修改结果如下图所示：

表 符合一范式的表格设计

ID	商品	数量	商家ID	用户ID
001	电脑	5	XXX旗舰店	00001

实际上，**1NF是所有关系型数据库的最基本要求**，你在关系型数据库管理系统(RDBMS)，例如SQL Server, Oracle, MySQL中创建数据表的时候，**如果数据表的设计不符合这个最基本的要求，那么操作一定是不能成功的**。也就是说，只要在RDBMS中已经存在的数据表，一定是符合1NF的。

让天下没有难学的技术

2、第二范式2NF核心原则：不能存在“部分函数依赖”

学号	姓名	系名	系主任	课名	分数
1022211101	李小明	经济系	王强	高等数学	95
1022211101	李小明	经济系	王强	大学英语	87
1022211101	李小明	经济系	王强	普通化学	76
1022211102	张莉莉	经济系	王强	高等数学	72
1022211102	张莉莉	经济系	王强	大学英语	98
1022211102	张莉莉	经济系	王强	计算机基础	88
1022511101	高芳芳	法律系	刘玲	高等数学	82
1022511101	高芳芳	法律系	刘玲	法学基础	82

以上表格明显存在，部分依赖。比如，这张表的主键是（学号，课名），分数确实完全依赖于（学号，课名），但是姓名并不完全依赖于（学号，课名）

学号	课名	分数
1022211101	高等数学	95
1022211101	大学英语	87
1022211101	普通化学	76
1022211102	高等数学	72
1022211102	大学英语	98
1022211102	计算机基础	88
1022511101	高等数学	82
1022511101	法学基础	82

学号	姓名	系名	系主任
1022211101	李小明	经济系	王强
1022211102	张莉莉	经济系	王强
1022511101	高芳芳	法律系	刘玲

以上符合第二范式，去掉部分函数依赖依赖

让天下没有难学的技术

3、第三范式3NF核心原则：不能存在传递函数依赖

在下面这张表中，存在传递函数依赖：学号->系名->系主任，但是系主任推不出学号。

学号	姓名	系名	系主任
1022211101	李小明	经济系	王强
1022211102	张莉莉	经济系	王强
1022511101	高芳芳	法律系	刘玲

上面表需要再次拆解：

学号	姓名	系名
1022211101	李小明	经济系
1022211102	张莉莉	经济系
1022511101	高芳芳	法律系

系名	系主任
经济系	王强
法律系	刘玲

让天下没有难学的技术

2.2 关系建模与维度建模


当今的数据处理大致可以分成两大类：联机事务处理 OLTP（on-line transaction processing）、联机分析处理 OLAP（On-Line Analytical Processing）。OLTP 是传统的关系型数据库的主要应用，主要是基本的、日常的事务处理，例如银行交易。OLAP 是数据仓库系统的主要应用，支持复杂的分析操作，侧重决策支持，并且提供直观易懂的查询结果。二者的主要区别对比如下表所示。

对比属性	OLTP	OLAP
读特性	每次查询只返回少量记录	对大量记录进行汇总
写特性	随机、低延时写入用户的输入	批量导入

更多 Java -大数据 -前端 -python 人工智能资料下载，可百度访问：尚硅谷官网

使用场景	用户，Java EE 项目	内部分析师，为决策提供支持
数据表征	最新数据状态	随时间变化的历史状态
数据规模	GB	TB 到 PB

2.2.1 关系建模



关系模型如图所示，严格遵循第三范式（3NF），从图中可以看出，较为松散、零碎，物理表数量多，而数据冗余程度低。由于数据分布于众多的表中，这些数据可以更为灵活地被应用，功能性较强。关系模型主要应用与 OLTP 系统中，为了保证数据的一致性以及避免冗余，所以大部分业务系统的表都是遵循第三范式的。

2.2.2 维度建模




图 维度模型示意图

维度模型如图所示，主要应用于 OLAP 系统中，通常以某一个事实表为中心进行表的组织，主要面向业务，特征是可能存在数据的冗余，但是能方便的得到数据。

关系模型虽然冗余少，但是在大规模数据，跨表分析统计查询过程中，会造成多表关联，这会大大降低执行效率。所以通常我们采用维度模型建模，把相关各种表整理成两种：事实表和维度表两种。

2.3 维度表和事实表（重点）

2.3.1 维度表

维度表：一般是对事实的**描述信息**。每一张维表对应现实世界中的一个对象或者概念。例如：用户、商品、日期、地区等。

维表的特征：

- 维表的范围很宽（具有多个属性、列比较多）
- 跟事实表相比，行数相对较小：通常< 10 万条
- 内容相对固定：编码表

时间维度表：

日期 ID day of week day of year 季度 节假日

更多 [Java](#) -[大数据](#) -[前端](#) -[python](#) 人工智能资料下载，可百度访问：尚硅谷官网

2020-01-01	2	1	1	元旦
2020-01-02	3	2	1	无
2020-01-03	4	3	1	无
2020-01-04	5	4	1	无
2020-01-05	6	5	1	无

2.3.2 事实表

事实表中的**每行数据代表一个业务事件（下单、支付、退款、评价等）**。“事实”这个术语表示的是业务事件的**度量值（可统计次数、个数、金额等）**，例如，2020 年 5 月 21 日，宋宋老师在京东花了 250 块钱买了一瓶海狗人参丸。维度表：时间、用户、商品、商家。事实表：250 块钱、一瓶

每一个事实表的行包括：具有可加性的数值型的度量值、与维表相连接的外键，通常具有两个和两个以上的外键。

事实表的特征：

- 非常的大
- 内容相对的窄：列数较少（主要是外键 id 和度量值）
- 经常发生变化，每天会新增加很多。

1) 事务型事实表

以**每个事务或事件为单位**，例如一个销售订单记录，一笔支付记录等，作为事实表里的一行数据。一旦事务被提交，事实表数据被插入，数据就不再进行更改，其更新方式为增量更新。

2) 周期型快照事实表

周期型快照事实表中**不会保留所有数据，只保留固定时间间隔的数据**，例如每天或者每月的销售额，或每月的账户余额等。

例如购物车，有加減商品，随时都有可能变化，但是我们更关心每天结束时这里面有多少商品，方便我们后期统计分析。

3) 累积型快照事实表

累计快照事实表用于跟踪业务事实的变化。例如，数据仓库中可能需要累积或者存储订单从下订单开始，到订单商品被打包、运输、和签收的各个业务阶段的时间点数据来跟踪订单声明周期的进展情况。当这个业务过程进行时，事实表的记录也要不断更新。

订单 id	用户 id	下单时间	打包时间	发货时间	签收时间	订单金额
-------	-------	------	------	------	------	------

		3-8	3-8	3-9	3-10	
--	--	-----	-----	-----	------	--


2.4 维度模型分类

在维度建模的基础上又分为三种模型：星型模型、雪花模型、星座模型。




星型模型、雪花模型

1、星型模型



雪花模型与星型模型的区别主要在于维度的层级，标准的星型模型维度只有一层，而雪花模型可能会涉及多级。

2、雪花模型




雪花模型，比较靠近3NF，但是无法完全遵守，因为遵循3NF的性能成本太高。

让天下没有难学的技术



星座模型

3、星座模型



星座模型与前两种情况的区别是事实表的数量，星座模型是基于多个事实表。

基本上是很多数据仓库的常态，因为很多数据仓库都是多个事实表的。所以星座不星座只反映是否有多个事实表，他们之间是否共享一些维度表。

所以星座模型并不和前两个模型冲突。

4、模型的选择

首先就是星座不星座这个只跟数据和需求有关系，跟设计没关系，不用选择。

星型还是雪花，取决于性能优先，还是灵活更优先。

目前实际企业开发中，不会绝对选择一种，根据情况灵活组合，甚至并存（一层维度和多层维度都保存）。但是整体来看，更倾向于维度更少的星型模型。尤其是Hadoop体系，减少Join就是减少Shuffle，性能差距很大。（关系型数据可以依靠强大的主键索引）

让天下没有难学的技术

2.5 数据仓库建模（绝对重点）

2.5.1 ODS 层

1) HDFS 用户行为数据

Hadoop

Overview

Datanodes

Datanode Volume Failures

Snapshot

Startup Progress

Utilities

Browse Directory

/origin_data/gmall/log/topic_log/2020-06-14

Go!

Show

25

entries

Search:

	Permission	Owner	Group	Size	Last Modified	Replication	Block Size	Name	
	-rw-r--r--	atguigu	supergroup	122.83 KB	Jul 08 16:35	3	128 MB	log-.1594197336056.lzo	
	-rw-r--r--	atguigu	supergroup	66.71 KB	Jul 10 12:03	1	128 MB	log-.1594353790081.lzo	

Showing 1 to 2 of 2 entries

Previous

1

Next

2) HDFS 业务数据

Hadoop

Overview

Datanodes

Datanode Volume Failures

Snapshot

Startup Progress

Utilities

Browse Directory

/origin_data/gmall/db/activity_info/2020-06-14

Go!

Show

25

entries

Search:

	Permission	Owner	Group	Size	Last Modified	Replication	Block Size	Name	
	-rw-r--r--	atguigu	supergroup	0 B	Jul 10 09:30	1	128 MB	_SUCCESS	
	-rw-r--r--	atguigu	supergroup	188 B	Jul 10 09:30	1	128 MB	part-m-00000.lzo	
	-rw-r--r--	atguigu	supergroup	8 B	Jul 10 09:31	1	128 MB	part-m-00000.lzo.index	

Showing 1 to 3 of 3 entries

Previous

1

Next

3) 针对 HDFS 上的用户行为数据和业务数据，我们如何规划处理？

- (1) 保持数据原貌不做任何修改，起到备份数据的作用。
- (2) 数据采用压缩，减少磁盘存储空间（例如：原始数据 100G，可以压缩到 10G 左右）
- (3) 创建分区表，防止后续的全表扫描

2.5.2 DWD 层

DWD 层需构建维度模型，一般采用星型模型，呈现的状态一般为星座模型。

维度建模一般按照以下四个步骤：

选择业务过程→声明粒度→确认维度→确认事实

(1) 选择业务过程

在业务系统中，挑选我们感兴趣的业务线，比如下单业务，支付业务，退款业务，物流业务，一条业务线对应一张事实表。

如果是中小公司，尽量把所有业务过程都选择。

更多 Java -大数据 -前端 -python 人工智能资料下载，可百度访问：尚硅谷官网

如果是大公司（1000 多张表），选择和需求相关的业务线。

（2）声明粒度

数据粒度指数据仓库的数据中保存数据的细化程度或综合程度的级别。

声明粒度意味着精确定义事实表中的一行数据表示什么，应该尽可能选择**最小粒度**，以此来应各种各样的需求。

典型的粒度声明如下：

订单事实表中的一行数据表示的是一个订单中的一个商品项。

支付事实表中的一行数据表示的是一个支付记录。

（3）确定维度

维度的主要作用是描述业务是事实，主要表示的是“**谁，何处，何时**”等信息。

确定维度的原则是：后续需求中是否要分析相关维度的指标。例如，需要统计，什么时间下的订单多，哪个地区下的订单多，哪个用户下的订单多。需要确定的维度就包括：时间维度、地区维度、用户维度。

（4）确定事实

此处的“事实”一词，指的是业务中的**度量值（次数、个数、件数、金额，可以进行累加）**，例如订单金额、下单次数等。

在 DWD 层，以**业务过程**为建模驱动，基于每个具体业务过程的特点，构建**最细粒度**的明细层事实表。事实表可做适当的宽表化处理。

事实表和维度表的关联比较灵活，但是为了应对更复杂的业务需求，可以将能关联上的表尽量关联上。如何判断是否能够关联上呢？在业务表关系图中，只要两张表能通过中间表能够关联上，就说明能关联上。


	时间	用户	地区	商品	优惠券	活动	编码	度量值
订单	√	√	√			√		件数/金额
订单详情	√	√	√	√				件数/金额
支付	√	√	√					金额
加购	√	√		√				件数/金额
收藏	√	√		√				个数
评价	√	√		√				个数
退款	√	√		√				件数/金额
优惠券领用	√	√			√			个数

至此，数据仓库的维度建模已经完毕，DWD 层是以**业务过程为驱动**。

DWS 层、DWT 层和 ADS 层都是**以需求为驱动**，和维度建模已经没有关系了。

DWS 和 DWT 都是建宽表，按照主题去建表。主题相当于观察问题的角度。对应着维度表。

数仓建模



2.5.3 DWS 层与 DWT 层

DWS 层和 DWT 层统称宽表层，这两层的设计思想大致相同，通过以下案例进行阐述。

- 1) 问题引出：两个需求，统计每个省份订单的个数、统计每个省份订单的总金额
- 2) 处理办法：都是将省份表和订单表进行 join，group by 省份，然后计算。同样数据被计算了两次，实际上类似的场景还会更多。

那怎么设计能避免重复计算呢？

针对上述场景，可以设计一张地区宽表，其主键为地区 ID，字段包含为：下单次数、下单金额、支付次数、支付金额等。上述所有指标都统一进行计算，并将结果保存在该宽表中，这样就能有效避免数据的重复计算。

3) 总结：

- (1) 需要建哪些宽表：以维度为基准。
- (2) 宽表里面的字段：是站在不同维度的角度看事实表，重点关注事实表聚合后的度量值。
- (3) DWS 和 DWT 层的区别：DWS 层存放的所有主题对象当天的汇总行为，例如每个地区当天的下单次数，下单金额等，DWT 层存放的是所有主题对象的累积行为，例如每个地区最近 7 天（15 天、30 天、60 天）的下单次数、下单金额等。

2.5.4 ADS 层

对电商系统各大主题指标分别进行分析。

第 3 章 数仓搭建-ODS 层

- 1) 保持数据原貌不做任何修改，起到备份数据的作用。
- 2) 数据采用 LZO 压缩，减少磁盘存储空间。**100G 数据可以压缩到 10G 以内。**
- 3) 创建分区表，防止后续的全表扫描，在企业开发中大量使用分区表。
- 4) 创建外部表。在企业开发中，除了自己用的临时表，创建内部表外，绝大多数场景都是创建外部表。

3.1 Hive 环境准备

3.1.1 Hive 引擎简介

Hive 引擎包括：默认 MR、tez、spark

Hive on Spark: Hive 既作为存储元数据又负责 SQL 的解析优化，**语法是 HQL 语法**，执行引擎变成了 Spark，Spark 负责采用 RDD 执行。

Spark on Hive : Hive 只作为存储元数据，Spark 负责 SQL 解析优化，**语法是 Spark SQL 语法**，Spark 负责采用 RDD 执行。

3.1.2 Hive on Spark 配置

1) 兼容性说明

注意：官网下载的 Hive3.1.2 和 Spark3.0.0 默认是不兼容的。因为 Hive3.1.2 支持的 Spark 版本是 2.4.5，所以**需要我们重新编译 Hive3.1.2 版本。**

编译步骤：官网下载 Hive3.1.2 源码，修改 pom 文件中引用的 Spark 版本为 3.0.0，如果编译通过，直接打包获取 jar 包。如果报错，就根据提示，修改相关方法，直到不报错，打包获取 jar 包。

2) 在 Hive 所在节点部署 Spark

如果之前已经部署了 Spark，则该步骤可以跳过，但要检查 SPARK_HOME 的环境变量配置是否正确。

(1) Spark 官网下载 jar 包地址：

<http://spark.apache.org/downloads.html>

(2) 上传并解压解压 spark-3.0.0-bin-hadoop3.2.tgz

```
[atguigu@hadoop102 software]$ tar -zxvf spark-3.0.0-bin-hadoop3.2.tgz -C /opt/module/  
[atguigu@hadoop102 software]$ mv /opt/module/spark-3.0.0-bin-hadoop3.2 /opt/module/spark
```

(3) 配置 SPARK_HOME 环境变量

```
[atguigu@hadoop102 software]$ sudo vim /etc/profile.d/my_env.sh
```

添加如下内容

```
# SPARK_HOME  
export SPARK_HOME=/opt/module/spark  
export PATH=$PATH:$SPARK_HOME/bin
```

source 使其生效

```
[atguigu@hadoop102 software]$ source /etc/profile.d/my_env.sh
```

3) 在 hive 中创建 spark 配置文件

```
[atguigu@hadoop102 software]$ vim /opt/module/hive/conf/spark-defaults.conf
```

添加如下内容（在执行任务时，会根据如下参数执行）

```
spark.master                yarn  
spark.eventLog.enabled      true  
spark.eventLog.dir          hdfs://hadoop102:8020/spark-history  
spark.executor.memory        1g  
spark.driver.memory         1g
```

在 HDFS 创建如下路径，用于存储历史日志

```
[atguigu@hadoop102 software]$ hadoop fs -mkdir /spark-history
```

4) 向 HDFS 上传 Spark 纯净版 jar 包

说明 1: 由于 Spark3.0.0 非纯净版默认支持的是 hive2.3.7 版本，直接使用会和安装的 Hive3.1.2 出现兼容性问题。所以采用 Spark 纯净版 jar 包，不包含 hadoop 和 hive 相关依赖，避免冲突。

说明 2: Hive 任务最终由 Spark 来执行，Spark 任务资源分配由 Yarn 来调度，该任务有可能被分配到集群的任何一个节点。所以需要将 Spark 的依赖上传到 HDFS 集群路径，这样集群中任何一个节点都能获取到。

(1) 上传并解压 spark-3.0.0-bin-without-hadoop.tgz

```
[atguigu@hadoop102 software]$ tar -zxvf /opt/software/spark-3.0.0-bin-without-hadoop.tgz
```

(2) 上传 Spark 纯净版 jar 包到 HDFS

```
[atguigu@hadoop102 software]$ hadoop fs -mkdir /spark-jars  
  
[atguigu@hadoop102 software]$ hadoop fs -put spark-3.0.0-bin-without-hadoop/jars/* /spark-jars
```

5) 修改 hive-site.xml 文件

```
[atguigu@hadoop102 ~]$ vim /opt/module/hive/conf/hive-site.xml
```

添加如下内容

```
<!--Spark 依赖位置（注意：端口号 8020 必须和 namenode 的端口号一致）-->
<property>
  <name>spark.yarn.jars</name>
  <value>hdfs://hadoop102:8020/spark-jars/*</value>
</property>

<!--Hive 执行引擎-->
<property>
  <name>hive.execution.engine</name>
  <value>spark</value>
</property>

<!--Hive 和 Spark 连接超时时间-->
<property>
  <name>hive.spark.client.connect.timeout</name>
  <value>10000ms</value>
</property>
```

注意：hive.spark.client.connect.timeout 的默认值是 1000ms，如果执行 hive 的 insert 语句时，抛如下异常，可以调大该参数到 10000ms

```
FAILED: SemanticException Failed to get a spark session:
org.apache.hadoop.hive.ql.metadata.HiveException: Failed to create Spark
client for Spark session d9e0224c-3d14-4bf4-95bc-ee3ec56df48e
```

3.1.3 Hive on Spark 测试

(1) 启动 hive 客户端

```
[atguigu@hadoop102 hive]$ bin/hive
```

(2) 创建一张测试表

```
hive (default)> create table student(id int, name string);
```

(3) 通过 insert 测试效果

```
hive (default)> insert into table student values(1,'abc');
```

若结果如下，则说明配置成功

```
hive (default)> insert into table student values(1,'abc');
Query ID = atguigu_20200719001740_b025ae13-c573-4a68-9b74-50a4d018664b
Total jobs = 1
Launching Job 1 out of 1
In order to change the average load for a reducer (in bytes):
  set hive.exec.reducers.bytes.per.reducer=<number>
In order to limit the maximum number of reducers:
  set hive.exec.reducers.max=<number>
In order to set a constant number of reducers:
  set mapreduce.job.reduces=<number>
-----
          STAGES   ATTEMPT      STATUS  TOTAL  COMPLETED  RUNNING  PENDING  FAILED
-----
Stage-2 .....         0    FINISHED     1         1         0         0         0
Stage-3 .....         0    FINISHED     1         1         0         0         0
-----
STAGES: 02/02   [=====>>>] 100%  ELAPSED TIME: 1.01 s
-----
Spark job[1] finished successfully in 1.01 second(s)
Loading data to table default.student
OK
coll   col2
Time taken: 1.514 seconds
hive (default)> █
```


Cluster Metrics																																							
Apps Submitted		Apps Pending		1		Apps Running		52		Apps Completed		3		Containers Running		450		Memory Used		12 GB		Memory Total		0 B		Memory Reserved		3		VCores Used		24		VCores Total		0		VCores Reserved	
Cluster Nodes Metrics																																							
Active Nodes				Decommissioning Nodes				Decommissioned Nodes				Lost Nodes				Unhealthy Nodes				Rebooted Nodes				Shutdown Nodes															
Scheduler Metrics																																							
Scheduler Type				Scheduling Resource Type				Minimum Allocation				Maximum Allocation				Maximum Cluster Application Priority																							
Capacity Scheduler				memory-mb (unit=mb, vcores)				memory:512, vCores:1				memory:4096, vCores:4				0																							
Show 20 ▾ entries																																							
Search																																							
ID	User	Name	Application Type	Queue	Application Priority	StartTime	LaunchTime	FinishTime	State	FinalStatus	Running Containers	Allocated CPU Vcores	Allocated Memory MB	Reserved CPU Vcores	Reserved Memory MB	% of Queue	% of Cluster	Progress ▾	Tracking UI	Blacklisted Nodes																			
application_1584727264362_0054	atguigu	QuasiMonteCarlo	MAPREDUCE	default	0	Sun Jul 19 05:46:54 +0800 2020	N/A	N/A	ACCEPTED	UNDEFINED	0	0	0	0	0	0.0	0.0		ApplicationMaster	0																			
application_1584727264362_0053	atguigu	Hive on Spark (sessionId = e8c7498e-1e84-4381-8dc7-148c19af1e52)	SPARK	default	0	Sun Jul 19 00:16:48 +0800 2020	Sun Jul 19 00:16:48 +0800 2020	N/A	RUNNING	UNDEFINED	3	3	4608	0	0	37.5	37.5		ApplicationMaster	0																			

(3) 容量调度器 default 队列中，同一时间只有一个任务执行，并发度低，如何解决呢？
见下一节。

3.1.5 增加 ApplicationMaster 资源比例

针对容量调度器并发度低的问题，考虑调整 `yarn.scheduler.capacity.maximum-am-resource-percent` 该参数。默认值是 0.1，表示集群上 AM 最多可使用的资源比例，目的为限制过多的 app 数量。

(1) 在 `hadoop102` 的 `/opt/module/hadoop-3.1.3/etc/Hadoop/capacity-scheduler.xml` 文件中修改如下参数值

```
[atguigu@hadoop102 hadoop]$ vim capacity-scheduler.xml
```

```
<property>
  <name>yarn.scheduler.capacity.maximum-am-resource-percent</name>
  <value>0.5</value>
  <description>
    集群中用于运行应用程序 ApplicationMaster 的资源比例上限，
    该参数通常用于限制处于活动状态的应用程序数目。该参数类型为浮点型，
    默认是 0.1，表示 10%。所有队列的 ApplicationMaster 资源比例上限可通过参数
    yarn.scheduler.capacity.maximum-am-resource-percent 设置，而单个队列
    可通过参数 yarn.scheduler.capacity.<queue-path>.maximum-am-resource-percent
    设置适合自己的值。
  </description>
</property>
```

(2) 分发 `capacity-scheduler.xml` 配置文件

```
[atguigu@hadoop102 hadoop]$ xsync capacity-scheduler.xml
```

(3) 关闭正在运行的任务，重新启动 yarn 集群

```
[atguigu@hadoop103 hadoop-3.1.3]$ sbin/stop-yarn.sh
[atguigu@hadoop103 hadoop-3.1.3]$ sbin/start-yarn.sh
```

3.1.6 配置 Yarn 容量调度器多队列

在企业里面如何配置多队列：

按照计算引擎创建队列 `hive`、`spark`、`flink`

按照业务创建队列：下单、支付、点赞、评论、收藏（用户、活动、优惠相关）

多队列有什么好处？

假如公司来了一个菜鸟，写了一个递归死循环，公司集群资源耗尽，大数据全部瘫痪。

可以使用队列统一管理任务优先级，保证重要的任务优先完成。

1) 增加容量调度器队列

(1) 修改容量调度器配置文件

默认 Yarn 的配置下，容量调度器只有一条 default 队列。在 capacity-scheduler.xml 中可以配置多条队列，**修改**以下属性，增加 hive 队列。

```
<property>
  <name>yarn.scheduler.capacity.root.queues</name>
  <value>default,hive</value>
  <description>
    再增加一个 hive 队列
  </description>
</property>

<property>
  <name>yarn.scheduler.capacity.root.default.capacity</name>
  <value>50</value>
  <description>
    default 队列的容量为 50%
  </description>
</property>
```

同时为新加队列**添加**必要属性：

```
<property>
  <name>yarn.scheduler.capacity.root.hive.capacity</name>
  <value>50</value>
  <description>
    hive 队列的容量为 50%
  </description>
</property>

<property>
  <name>yarn.scheduler.capacity.root.hive.user-limit-factor</name>
  <value>1</value>
  <description>
    一个用户最多能够获取该队列资源容量的比例，取值 0-1
  </description>
</property>

<property>
  <name>yarn.scheduler.capacity.root.hive.maximum-capacity</name>
  <value>80</value>
  <description>
    hive 队列的最大容量（自己队列资源不够，可以使用其他队列资源上限）
  </description>
</property>

<property>
  <name>yarn.scheduler.capacity.root.hive.state</name>
  <value>RUNNING</value>
  <description>
    开启 hive 队列运行，不设置队列不能使用
  </description>
</property>
```

```
<property>
  <name>yarn.scheduler.capacity.root.hive.acl_submit_applications</name>
  <value>*</value>
  <description>
    访问控制，控制谁可以将任务提交到该队列，*表示任何人
  </description>
</property>

<property>
  <name>yarn.scheduler.capacity.root.hive.acl_administer_queue</name>
  <value>*</value>
  <description>
    访问控制，控制谁可以管理 (包括提交和取消) 该队列的任务，*表示任何人
  </description>
</property>

<property>
  <name>yarn.scheduler.capacity.root.hive.acl_application_max_priority</name>
  <value>*</value>
  <description>
    指定哪个用户可以提交配置任务优先级
  </description>
</property>

<property>
  <name>yarn.scheduler.capacity.root.hive.maximum-application-lifetime</name>
  <value>-1</value>
  <description>
    hive 队列中任务的最大生命时长，以秒为单位。任何小于或等于零的值将被视为禁用。
  </description>
</property>
<property>
  <name>yarn.scheduler.capacity.root.hive.default-application-lifetime</name>
  <value>-1</value>
  <description>
    hive 队列中任务的默认生命时长，以秒为单位。任何小于或等于零的值将被视为禁用。
  </description>
</property>
```

(2) 分发配置文件

```
[atguigu@hadoop102 ~]$ xsync /opt/module/hadoop-3.1.3/etc/hadoop/capacity-scheduler.xml
```

(3) 重启 Hadoop 集群

2) 测试新队列

(1) 提交一个 MR 任务，并指定队列为 hive

```
[atguigu@hadoop102 ~]$ hadoop jar /opt/module/hadoop-3.1.3/share/hadoop/mapreduce/hadoop-mapreduce-examples-3.1.3.jar pi -Dmapreduce.job.queueName=hive 1 1
```

(2) 查看 ResourceManager 的 web 页面，观察任务被提交到的队列

Cluster Metrics																																							
Apps Submitted		Apps Pending		Apps Running		Apps Completed		Containers Running		Memory Used		Memory Total		Memory Reserved		VCores Used		VCores Total		VCores Reserved																			
1		0		0		1		0		0 B		12 GB		0 B		0		24		0																			
Cluster Nodes Metrics																																							
Active Nodes				Decommissioning Nodes				Decommissioned Nodes				Lost Nodes				Unhealthy Nodes				Rebooted Nodes				Shutdown Nodes															
3				0				0				0				0				0				0															
Scheduler Metrics																																							
Scheduler Type				Scheduling Resource Type				Minimum Allocation				Maximum Allocation				Maximum Cluster Application Priority																							
Capacity Scheduler				[memory-mb (unit=Mi), vcores]				<memory:512, vCores:1>				<memory:4096, vCores:4>				0																							
Show: 20 entries																				Search:																			
ID	*	User	o	Name	o	Application Type	Queue	o	Application Priority	o	StartTime	o	LaunchTime	o	FinishTime	o	State	o	FinalStatus	o	Running Containers	o	Allocated CPU Vcores	o	Allocated Memory MB	o	Reserved CPU Vcores	o	Reserved Memory MB	o	% of Queue	o	% of Cluster	o	Progress	o	Tracking UI	o	Blacklisted Nodes
application_1595164318379_0001		atguigu		QuasiMonteCarlo		MAPREDUCE	hive		0		Sun Jul 19 21:39:10 +0800 2020		Sun Jul 19 21:39:11 +0800 2020		Sun Jul 19 21:39:26 +0800 2020		FINISHED		SUCCEEDED		N/A		N/A		N/A		N/A		N/A		0.0		0.0			History		0	

3.1.7 创建数据库

1) 启动 hive

```
[atguigu@hadoop102 hive]$ bin/hive
```

2) 显示数据库

```
hive (default)> show databases;
```

3) 创建数据库

```
hive (default)> create database gmall;
```

4) 使用数据库

```
hive (default)> use gmall;
```

3.1.8 datagrip 工具



尚硅谷大数据技术
之datagrip.docx

3.2 ODS 层（用户行为数据）

3.2.1 创建日志表 ods_log



ODS层创建日志表

```
{ -- 启动日志
"common": {
```

```
},
"start": {
```

```
},
"err": {
```

```
},
"ts": 1585744304000
```

```
}
```

```
{ -- 事件日志
"common": {
```

```
},
"actions": [
```

```
{
```

```
},
"displays": [
```

```
{
```

```
},
"page": {
```

```
},
"err": {
```

```
},
"ts": 1585744374423
```

```
}
```

1) 如果要创建的表已经存在，先删除该表。

```
drop table if exists ods_log;
```

2) 创建一张外部表，字段就是一个String类型的json

```
CREATE EXTERNAL TABLE ods_log (line string)
```

3) 该表按照日期分区

```
PARTITIONED BY (`dt` string)
```

4) LZO压缩格式处理

```
STORED AS
INPUTFORMAT 'com.hadoop.mapred.DeprecatedLzoTextInputFormat'
OUTPUTFORMAT
'org.apache.hadoop.hive.ql.io.HiveIgnoreKeyTextOutputFormat'
```

5) 设置数据存储位置

```
LOCATION '/warehouse/gmall/ods/ods_log';
```

让天下没有难学的技术

1) 创建支持 lzo 压缩的分区表

更多 Java - 大数据 - 前端 - python 人工智能资料下载，可百度访问：尚硅谷官网

```
hive (gmall)>
drop table if exists ods_log;
CREATE EXTERNAL TABLE ods_log (`line` string)
PARTITIONED BY (`dt` string) -- 按照时间创建分区
STORED AS -- 指定存储方式，读数据采用 LzoTextInputFormat;
    INPUTFORMAT 'com.hadoop.mapred.DeprecatedLzoTextInputFormat'
    OUTPUTFORMAT
'org.apache.hadoop.hive.ql.io.HiveIgnoreKeyTextOutputFormat'
LOCATION '/warehouse/gmall/ods/ods_log' -- 指定数据在 hdfs 上的存储位置
;
```

说明 Hive 的 LZO 压缩: <https://cwiki.apache.org/confluence/display/Hive/LanguageManual+LZO>

2) 加载数据

```
hive (gmall)>
load data inpath '/origin_data/gmall/log/topic_log/2020-06-14'
into table ods_log partition(dt='2020-06-14');
```

注意: 时间格式都配置成 YYYY-MM-DD 格式, 这是 Hive 默认支持的时间格式

3) 查看是否加载成功

```
hive (gmall)> select * from ods_log limit 2;
```

4) 为 lzo 压缩文件创建索引

```
[atguigu@hadoop102 bin]$ hadoop jar /opt/module/hadoop-
3.1.3/share/hadoop/common/hadoop-lzo-0.4.20.jar
com.hadoop.compression.lzo.DistributedLzoIndexer -
Dmapreduce.job.queueName=hive
/warehouse/gmall/ods/ods_log/dt=2020-06-14
```

3.2.2 Shell 中单引号和双引号区别

1) 在 /home/atguigu/bin 创建一个 test.sh 文件

```
[atguigu@hadoop102 bin]$ vim test.sh
```

在文件中添加如下内容

```
#!/bin/bash
do_date=$1

echo '$do_date'
echo "$do_date"
echo "'$do_date'"
echo '"$do_date"'
echo `date`
```

2) 查看执行结果

```
[atguigu@hadoop102 bin]$ test.sh 2020-06-14
$do_date
2020-06-14
'2020-06-14'
"$do_date"
2020 年 06 月 18 日 星期四 21:02:08 CST
```

3) 总结:

- (1) 单引号不取变量值
- (2) 双引号取变量值

- (3) 反引号`，执行引号中命令
- (4) 双引号内部嵌套单引号，取出变量值
- (5) 单引号内部嵌套双引号，不取出变量值

3.2.3 ODS 层加载数据脚本

1) 在 hadoop102 的/home/atguigu/bin 目录下创建脚本

```
[atguigu@hadoop102 bin]$ vim hdfs_to_ods_log.sh
```

在脚本中编写如下内容

```
#!/bin/bash

# 定义变量方便修改
APP=gmall
hive=/opt/module/hive/bin/hive
hadoop=/opt/module/hadoop-3.1.3/bin/hadoop

# 如果是输入的日期按照取输入日期；如果没输入日期取当前时间的前一天
if [ -n "$1" ] ;then
    do_date=$1
else
    do_date=`date -d "-1 day" +%F`
fi

echo ===== 日志日期为 $do_date =====
sql="
load data inpath '/origin_data/$APP/log/topic_log/$do_date'
into table ${APP}.ods_log partition(dt='$do_date');
"

$hive -e "$sql"

$hadoop jar /opt/module/hadoop-3.1.3/share/hadoop/common/hadoop-lzo-0.4.20.jar
com.hadoop.compression.lzo.DistributedLzoIndexer
Dmapreduce.job.queueName=hive
/warehouse/$APP/ods/ods_log/dt=$do_date
```

(1) 说明 1:

[-n 变量值] 判断变量的值，是否为空

-- 变量的值，非空，返回 true

-- 变量的值，为空，返回 false

注意: [-n 变量值]不会解析数据，使用[-n 变量值]时，需要对变量加上双引号(" ")

(2) 说明 2:

查看 date 命令的使用，date --help

2) 增加脚本执行权限

```
[atguigu@hadoop102 bin]$ chmod 777 hdfs_to_ods_log.sh
```

3) 脚本使用

```
[atguigu@hadoop102 module]$ hdfs_to_ods_log.sh 2020-06-15
```

4) 查看导入数据


```
hive (gmall)>
select * from ods_log where dt='2020-06-15' limit 2;
```

5) 脚本执行时间

企业开发中一般在每日凌晨 30 分~1 点

3.3 ODS 层（业务数据）

电商表结构



让天下没有难学的技术

ODS层（业务数据）

Browse Directory

/origin_data/gmall/db/

Show 25 entries

Permission Owner

load data

```
inpath '/origin_data/gmall/db/...'
OVERWRITE into table ods_order_info
partition(dt='2020-06-14');
```

Hive中23张表

```
(
ods_order_info
...
)
```

```
drop table if exists ods_order_info;
create external table ods_order_info (
'id' string COMMENT '订单号',
...
) COMMENT '订单表'
PARTITIONED BY ('dt' string)
row format delimited fields terminated by '\t'
STORED AS
INPUTFORMAT 'com.hadoop.mapred.DeprecatedLzoTextInputFormat'
OUTPUTFORMAT
'org.apache.hadoop.hive.ql.io.HiveIgnoreKeyTextOutputFormat'
location '/warehouse/gmall/ods/ods_order_info/';
```

让天下没有难学的技术

3.3.1 订单表（增量及更新）

```
hive (gmall)>
drop table if exists ods_order_info;
create external table ods_order_info (
'id' string COMMENT '订单号',
'final_total_amount' decimal(16,2) COMMENT '订单金额',
```

更多 [Java](#) - [大数据](#) - [前端](#) - [python](#) 人工智能资料下载，可百度访问：尚硅谷官网

```
`order_status` string COMMENT '订单状态',
`user_id` string COMMENT '用户 id',
`out_trade_no` string COMMENT '支付流水号',
`create_time` string COMMENT '创建时间',
`operate_time` string COMMENT '操作时间',
`province_id` string COMMENT '省份 ID',
`benefit_reduce_amount` decimal(16,2) COMMENT '优惠金额',
`original_total_amount` decimal(16,2) COMMENT '原价金额',
`feight_fee` decimal(16,2) COMMENT '运费'
) COMMENT '订单表'
PARTITIONED BY (`dt` string) -- 按照时间创建分区
row format delimited fields terminated by '\t' -- 指定分割符为\t
STORED AS -- 指定存储方式,读数据采用 LzoTextInputFormat;输出数据采用 TextOutputFormat
  INPUTFORMAT 'com.hadoop.mapred.DeprecatedLzoTextInputFormat'
  OUTPUTFORMAT 'org.apache.hadoop.hive.ql.io.HiveIgnoreKeyTextOutputFormat'
location '/warehouse/gmall/ods/ods_order_info/' -- 指定数据在 hdfs 上的存储位置
;
```

3.3.2 订单详情表（增量）

```
hive (gmall)>
drop table if exists ods_order_detail;
create external table ods_order_detail(
  `id` string COMMENT '编号',
  `order_id` string COMMENT '订单号',
  `user_id` string COMMENT '用户 id',
  `sku_id` string COMMENT '商品 id',
  `sku_name` string COMMENT '商品名称',
  `order_price` decimal(16,2) COMMENT '商品价格',
  `sku_num` bigint COMMENT '商品数量',
  `create_time` string COMMENT '创建时间',
  `source_type` string COMMENT '来源类型',
  `source_id` string COMMENT '来源编号'
) COMMENT '订单详情表'
PARTITIONED BY (`dt` string)
row format delimited fields terminated by '\t'
STORED AS
  INPUTFORMAT 'com.hadoop.mapred.DeprecatedLzoTextInputFormat'
  OUTPUTFORMAT 'org.apache.hadoop.hive.ql.io.HiveIgnoreKeyTextOutputFormat'
location '/warehouse/gmall/ods/ods_order_detail/';
```

3.3.3 SKU 商品表（全量）

```
hive (gmall)>
drop table if exists ods_sku_info;
create external table ods_sku_info(
  `id` string COMMENT 'skuId',
  `spu_id` string COMMENT 'spuid',
  `price` decimal(16,2) COMMENT '价格',
  `sku_name` string COMMENT '商品名称',
  `sku_desc` string COMMENT '商品描述',
  `weight` string COMMENT '重量',
  `tm_id` string COMMENT '品牌 id',
  `category3_id` string COMMENT '品类 id',
  `create_time` string COMMENT '创建时间'
) COMMENT 'SKU 商品表'
PARTITIONED BY (`dt` string)
row format delimited fields terminated by '\t'
STORED AS
  INPUTFORMAT 'com.hadoop.mapred.DeprecatedLzoTextInputFormat'
  OUTPUTFORMAT 'org.apache.hadoop.hive.ql.io.HiveIgnoreKeyTextOutputFormat'
```

更多 [Java](#) - [大数据](#) - [前端](#) - [python](#) 人工智能资料下载, 可百度访问: [尚硅谷官网](#)

```
location '/warehouse/gmall/ods/ods_sku_info/';
```

3.3.4 用户表（增量及更新）

```
hive (gmall)>
drop table if exists ods_user_info;
create external table ods_user_info(
  `id` string COMMENT '用户id',
  `name` string COMMENT '姓名',
  `birthday` string COMMENT '生日',
  `gender` string COMMENT '性别',
  `email` string COMMENT '邮箱',
  `user_level` string COMMENT '用户等级',
  `create_time` string COMMENT '创建时间',
  `operate_time` string COMMENT '操作时间'
) COMMENT '用户表'
PARTITIONED BY (`dt` string)
row format delimited fields terminated by '\t'
STORED AS
  INPUTFORMAT 'com.hadoop.mapred.DeprecatedLzoTextInputFormat'
  OUTPUTFORMAT 'org.apache.hadoop.hive.ql.io.HiveIgnoreKeyTextOutputFormat'
location '/warehouse/gmall/ods/ods_user_info/';
```

3.3.5 商品一级分类表（全量）

```
hive (gmall)>
drop table if exists ods_base_category1;
create external table ods_base_category1(
  `id` string COMMENT 'id',
  `name` string COMMENT '名称'
) COMMENT '商品一级分类表'
PARTITIONED BY (`dt` string)
row format delimited fields terminated by '\t'
STORED AS
  INPUTFORMAT 'com.hadoop.mapred.DeprecatedLzoTextInputFormat'
  OUTPUTFORMAT 'org.apache.hadoop.hive.ql.io.HiveIgnoreKeyTextOutputFormat'
location '/warehouse/gmall/ods/ods_base_category1/';
```

3.3.6 商品二级分类表（全量）

```
hive (gmall)>
drop table if exists ods_base_category2;
create external table ods_base_category2(
  `id` string COMMENT 'id',
  `name` string COMMENT '名称',
  category1_id string COMMENT '一级品类 id'
) COMMENT '商品二级分类表'
PARTITIONED BY (`dt` string)
row format delimited fields terminated by '\t'
STORED AS
  INPUTFORMAT 'com.hadoop.mapred.DeprecatedLzoTextInputFormat'
  OUTPUTFORMAT 'org.apache.hadoop.hive.ql.io.HiveIgnoreKeyTextOutputFormat'
location '/warehouse/gmall/ods/ods_base_category2/';
```

3.3.7 商品三级分类表（全量）

```
hive (gmall)>
drop table if exists ods_base_category3;
create external table ods_base_category3(
  `id` string COMMENT 'id',
  `name` string COMMENT '名称',
  category2_id string COMMENT '二级品类 id'
```

```
) COMMENT '商品三级分类表'
PARTITIONED BY (`dt` string)
row format delimited fields terminated by '\t'
STORED AS
  INPUTFORMAT 'com.hadoop.mapred.DeprecatedLzoTextInputFormat'
  OUTPUTFORMAT 'org.apache.hadoop.hive.ql.io.HiveIgnoreKeyTextOutputFormat'
location '/warehouse/gmall/ods/ods_base_category3/';
```

3.3.8 支付流水表（增量）

```
hive (gmall)>
drop table if exists ods_payment_info;
create external table ods_payment_info(
  `id` bigint COMMENT '编号',
  `out_trade_no` string COMMENT '对外业务编号',
  `order_id` string COMMENT '订单编号',
  `user_id` string COMMENT '用户编号',
  `alipay_trade_no` string COMMENT '支付宝交易流水编号',
  `total_amount` decimal(16,2) COMMENT '支付金额',
  `subject` string COMMENT '交易内容',
  `payment_type` string COMMENT '支付类型',
  `payment_time` string COMMENT '支付时间'
) COMMENT '支付流水表'
PARTITIONED BY (`dt` string)
row format delimited fields terminated by '\t'
STORED AS
  INPUTFORMAT 'com.hadoop.mapred.DeprecatedLzoTextInputFormat'
  OUTPUTFORMAT 'org.apache.hadoop.hive.ql.io.HiveIgnoreKeyTextOutputFormat'
location '/warehouse/gmall/ods/ods_payment_info/';
```

3.3.9 省份表（特殊）

```
hive (gmall)>
drop table if exists ods_base_province;
create external table ods_base_province (
  `id` bigint COMMENT '编号',
  `name` string COMMENT '省份名称',
  `region_id` string COMMENT '地区 ID',
  `area_code` string COMMENT '地区编码',
  `iso_code` string COMMENT 'iso 编码, superset 可视化使用'
) COMMENT '省份表'
row format delimited fields terminated by '\t'
STORED AS
  INPUTFORMAT 'com.hadoop.mapred.DeprecatedLzoTextInputFormat'
  OUTPUTFORMAT 'org.apache.hadoop.hive.ql.io.HiveIgnoreKeyTextOutputFormat'
location '/warehouse/gmall/ods/ods_base_province/';
```

3.3.10 地区表（特殊）

```
hive (gmall)>
drop table if exists ods_base_region;
create external table ods_base_region (
  `id` string COMMENT '编号',
  `region_name` string COMMENT '地区名称'
) COMMENT '地区表'
row format delimited fields terminated by '\t'
STORED AS
  INPUTFORMAT 'com.hadoop.mapred.DeprecatedLzoTextInputFormat'
  OUTPUTFORMAT 'org.apache.hadoop.hive.ql.io.HiveIgnoreKeyTextOutputFormat'
location '/warehouse/gmall/ods/ods_base_region/';
```

3.3.11 品牌表（全量）

```
hive (gmall)>
drop table if exists ods_base_trademark;
create external table ods_base_trademark (
  `tm_id` string COMMENT '编号',
  `tm_name` string COMMENT '品牌名称'
) COMMENT '品牌表'
PARTITIONED BY (`dt` string)
row format delimited fields terminated by '\t'
STORED AS
  INPUTFORMAT 'com.hadoop.mapred.DeprecatedLzoTextInputFormat'
  OUTPUTFORMAT 'org.apache.hadoop.hive.ql.io.HiveIgnoreKeyTextOutputFormat'
location '/warehouse/gmall/ods/ods_base_trademark/';
```

3.3.12 订单状态表（增量）

```
hive (gmall)>
drop table if exists ods_order_status_log;
create external table ods_order_status_log (
  `id` string COMMENT '编号',
  `order_id` string COMMENT '订单 ID',
  `order_status` string COMMENT '订单状态',
  `operate_time` string COMMENT '修改时间'
) COMMENT '订单状态表'
PARTITIONED BY (`dt` string)
row format delimited fields terminated by '\t'
STORED AS
  INPUTFORMAT 'com.hadoop.mapred.DeprecatedLzoTextInputFormat'
  OUTPUTFORMAT 'org.apache.hadoop.hive.ql.io.HiveIgnoreKeyTextOutputFormat'
location '/warehouse/gmall/ods/ods_order_status_log/';
```

3.3.13 SPU 商品表（全量）

```
hive (gmall)>
drop table if exists ods_spu_info;
create external table ods_spu_info(
  `id` string COMMENT 'spuid',
  `spu_name` string COMMENT 'spu 名称',
  `category3_id` string COMMENT '品类 id',
  `tm_id` string COMMENT '品牌 id'
) COMMENT 'SPU 商品表'
PARTITIONED BY (`dt` string)
row format delimited fields terminated by '\t'
STORED AS
  INPUTFORMAT 'com.hadoop.mapred.DeprecatedLzoTextInputFormat'
  OUTPUTFORMAT 'org.apache.hadoop.hive.ql.io.HiveIgnoreKeyTextOutputFormat'
location '/warehouse/gmall/ods/ods_spu_info/';
```

3.3.14 商品评论表（增量）

```
hive (gmall)>
drop table if exists ods_comment_info;
create external table ods_comment_info(
  `id` string COMMENT '编号',
  `user_id` string COMMENT '用户 ID',
  `sku_id` string COMMENT '商品 sku',
  `spu_id` string COMMENT '商品 spu',
  `order_id` string COMMENT '订单 ID',
  `appraise` string COMMENT '评价',
  `create_time` string COMMENT '评价时间'
```

```
) COMMENT '商品评论表'
PARTITIONED BY (`dt` string)
row format delimited fields terminated by '\t'
STORED AS
  INPUTFORMAT 'com.hadoop.mapred.DeprecatedLzoTextInputFormat'
  OUTPUTFORMAT 'org.apache.hadoop.hive.ql.io.HiveIgnoreKeyTextOutputFormat'
location '/warehouse/gmall/ods/ods_comment_info/';
```

3.3.15 退单表（增量）

```
hive (gmall)>
drop table if exists ods_order_refund_info;
create external table ods_order_refund_info(
  `id` string COMMENT '编号',
  `user_id` string COMMENT '用户 ID',
  `order_id` string COMMENT '订单 ID',
  `sku_id` string COMMENT '商品 ID',
  `refund_type` string COMMENT '退款类型',
  `refund_num` bigint COMMENT '退款件数',
  `refund_amount` decimal(16,2) COMMENT '退款金额',
  `refund_reason_type` string COMMENT '退款原因类型',
  `create_time` string COMMENT '退款时间'
) COMMENT '退单表'
PARTITIONED BY (`dt` string)
row format delimited fields terminated by '\t'
STORED AS
  INPUTFORMAT 'com.hadoop.mapred.DeprecatedLzoTextInputFormat'
  OUTPUTFORMAT 'org.apache.hadoop.hive.ql.io.HiveIgnoreKeyTextOutputFormat'
location '/warehouse/gmall/ods/ods_order_refund_info/';
```

3.3.16 加购表（全量）

```
hive (gmall)>
drop table if exists ods_cart_info;
create external table ods_cart_info(
  `id` string COMMENT '编号',
  `user_id` string COMMENT '用户 id',
  `sku_id` string COMMENT 'skuid',
  `cart_price` decimal(16,2) COMMENT '放入购物车时价格',
  `sku_num` bigint COMMENT '数量',
  `sku_name` string COMMENT 'sku 名称 (冗余)',
  `create_time` string COMMENT '创建时间',
  `operate_time` string COMMENT '修改时间',
  `is_ordered` string COMMENT '是否已经下单',
  `order_time` string COMMENT '下单时间',
  `source_type` string COMMENT '来源类型',
  `source_id` string COMMENT '来源编号'
) COMMENT '加购表'
PARTITIONED BY (`dt` string)
row format delimited fields terminated by '\t'
STORED AS
  INPUTFORMAT 'com.hadoop.mapred.DeprecatedLzoTextInputFormat'
  OUTPUTFORMAT 'org.apache.hadoop.hive.ql.io.HiveIgnoreKeyTextOutputFormat'
location '/warehouse/gmall/ods/ods_cart_info/';
```

3.3.17 商品收藏表（全量）

```
hive (gmall)>
drop table if exists ods_favor_info;
create external table ods_favor_info(
  `id` string COMMENT '编号',
```

```
`user_id` string COMMENT '用户 id',
`sku_id` string COMMENT 'skuid',
`spu_id` string COMMENT 'spuid',
`is_cancel` string COMMENT '是否取消',
`create_time` string COMMENT '收藏时间',
`cancel_time` string COMMENT '取消时间'
) COMMENT '商品收藏表'
PARTITIONED BY (`dt` string)
row format delimited fields terminated by '\t'
STORED AS
  INPUTFORMAT 'com.hadoop.mapred.DeprecatedLzoTextInputFormat'
  OUTPUTFORMAT 'org.apache.hadoop.hive.ql.io.HiveIgnoreKeyTextOutputFormat'
location '/warehouse/gmall/ods/ods_favor_info/';
```

3.3.18 优惠券领用表（新增及变化）

```
hive (gmall)>
drop table if exists ods_coupon_use;
create external table ods_coupon_use(
  `id` string COMMENT '编号',
  `coupon_id` string COMMENT '优惠券 ID',
  `user_id` string COMMENT 'skuid',
  `order_id` string COMMENT 'spuid',
  `coupon_status` string COMMENT '优惠券状态',
  `get_time` string COMMENT '领取时间',
  `using_time` string COMMENT '使用时间(下单)',
  `used_time` string COMMENT '使用时间(支付)'
) COMMENT '优惠券领用表'
PARTITIONED BY (`dt` string)
row format delimited fields terminated by '\t'
STORED AS
  INPUTFORMAT 'com.hadoop.mapred.DeprecatedLzoTextInputFormat'
  OUTPUTFORMAT 'org.apache.hadoop.hive.ql.io.HiveIgnoreKeyTextOutputFormat'
location '/warehouse/gmall/ods/ods_coupon_use/';
```

3.3.19 优惠券表（全量）

```
hive (gmall)>
drop table if exists ods_coupon_info;
create external table ods_coupon_info(
  `id` string COMMENT '购物券编号',
  `coupon_name` string COMMENT '购物券名称',
  `coupon_type` string COMMENT '购物券类型 1 现金券 2 折扣券 3 满减券 4 满件打折券',
  `condition_amount` decimal(16,2) COMMENT '满额数',
  `condition_num` bigint COMMENT '满件数',
  `activity_id` string COMMENT '活动编号',
  `benefit_amount` decimal(16,2) COMMENT '减金额',
  `benefit_discount` decimal(16,2) COMMENT '折扣',
  `create_time` string COMMENT '创建时间',
  `range_type` string COMMENT '范围类型 1、商品 2、品类 3、品牌',
  `spu_id` string COMMENT '商品 id',
  `tm_id` string COMMENT '品牌 id',
  `category3_id` string COMMENT '品类 id',
  `limit_num` bigint COMMENT '最多领用次数',
  `operate_time` string COMMENT '修改时间',
  `expire_time` string COMMENT '过期时间'
) COMMENT '优惠券表'
PARTITIONED BY (`dt` string)
row format delimited fields terminated by '\t'
STORED AS
  INPUTFORMAT 'com.hadoop.mapred.DeprecatedLzoTextInputFormat'
```

```
OUTPUTFORMAT 'org.apache.hadoop.hive.ql.io.HiveIgnoreKeyTextOutputFormat'  
location '/warehouse/gmall/ods/ods_coupon_info/';
```

3.3.20 活动表（全量）

```
hive (gmall)>  
drop table if exists ods_activity_info;  
create external table ods_activity_info(  
    `id` string COMMENT '编号',  
    `activity_name` string COMMENT '活动名称',  
    `activity_type` string COMMENT '活动类型',  
    `start_time` string COMMENT '开始时间',  
    `end_time` string COMMENT '结束时间',  
    `create_time` string COMMENT '创建时间'  
) COMMENT '活动表'  
PARTITIONED BY (`dt` string)  
row format delimited fields terminated by '\t'  
STORED AS  
    INPUTFORMAT 'com.hadoop.mapred.DeprecatedLzoTextInputFormat'  
    OUTPUTFORMAT 'org.apache.hadoop.hive.ql.io.HiveIgnoreKeyTextOutputFormat'  
location '/warehouse/gmall/ods/ods_activity_info/';
```

3.3.21 活动订单关联表（增量）

```
hive (gmall)>  
drop table if exists ods_activity_order;  
create external table ods_activity_order(  
    `id` string COMMENT '编号',  
    `activity_id` string COMMENT '优惠券 ID',  
    `order_id` string COMMENT 'skuid',  
    `create_time` string COMMENT '领取时间'  
) COMMENT '活动订单关联表'  
PARTITIONED BY (`dt` string)  
row format delimited fields terminated by '\t'  
STORED AS  
    INPUTFORMAT 'com.hadoop.mapred.DeprecatedLzoTextInputFormat'  
    OUTPUTFORMAT 'org.apache.hadoop.hive.ql.io.HiveIgnoreKeyTextOutputFormat'  
location '/warehouse/gmall/ods/ods_activity_order/';
```

3.3.22 优惠规则表（全量）

```
hive (gmall)>  
drop table if exists ods_activity_rule;  
create external table ods_activity_rule(  
    `id` string COMMENT '编号',  
    `activity_id` string COMMENT '活动 ID',  
    `condition_amount` decimal(16,2) COMMENT '满减金额',  
    `condition_num` bigint COMMENT '满减件数',  
    `benefit_amount` decimal(16,2) COMMENT '优惠金额',  
    `benefit_discount` decimal(16,2) COMMENT '优惠折扣',  
    `benefit_level` string COMMENT '优惠级别'  
) COMMENT '优惠规则表'  
PARTITIONED BY (`dt` string)  
row format delimited fields terminated by '\t'  
STORED AS  
    INPUTFORMAT 'com.hadoop.mapred.DeprecatedLzoTextInputFormat'  
    OUTPUTFORMAT 'org.apache.hadoop.hive.ql.io.HiveIgnoreKeyTextOutputFormat'  
location '/warehouse/gmall/ods/ods_activity_rule/';
```

3.3.23 编码字典表（全量）

```
hive (gmall)>
```

```
drop table if exists ods_base_dic;
create external table ods_base_dic(
    `dic_code` string COMMENT '编号',
    `dic_name` string COMMENT '编码名称',
    `parent_code` string COMMENT '父编码',
    `create_time` string COMMENT '创建日期',
    `operate_time` string COMMENT '操作日期'
) COMMENT '编码字典表'
PARTITIONED BY (`dt` string)
row format delimited fields terminated by '\t'
STORED AS
    INPUTFORMAT 'com.hadoop.mapred.DeprecatedLzoTextInputFormat'
    OUTPUTFORMAT 'org.apache.hadoop.hive ql.io.HiveIgnoreKeyTextOutputFormat'
location '/warehouse/gmall/ods/ods_base_dic/';
```

3.3.24 ODS 层加载数据脚本

1.编写脚本

1) 在/home/atguigu/bin 目录下创建脚本 hdfs_to_ods_db.sh

```
[atguigu@hadoop102 bin]$ vim hdfs_to_ods_db.sh
```

在脚本中填写如下内容

```
#!/bin/bash

APP=gmall
hive=/opt/module/hive/bin/hive

# 如果是输入的日期按照取输入日期; 如果没输入日期取当前时间的前一天
if [ -n "$2" ] ;then
    do_date=$2
else
    do_date=`date -d "-1 day" +%F`
fi

sql1="
load data inpath '/origin_data/$APP/db/order_info/$do_date' OVERWRITE into table
${APP}.ods_order_info partition(dt='$do_date');

load data inpath '/origin_data/$APP/db/order_detail/$do_date' OVERWRITE into table
${APP}.ods_order_detail partition(dt='$do_date');

load data inpath '/origin_data/$APP/db/sku_info/$do_date' OVERWRITE into table
${APP}.ods_sku_info partition(dt='$do_date');

load data inpath '/origin_data/$APP/db/user_info/$do_date' OVERWRITE into table
${APP}.ods_user_info partition(dt='$do_date');

load data inpath '/origin_data/$APP/db/payment_info/$do_date' OVERWRITE into table
${APP}.ods_payment_info partition(dt='$do_date');

load data inpath '/origin_data/$APP/db/base_category1/$do_date' OVERWRITE into table
${APP}.ods_base_category1 partition(dt='$do_date');

load data inpath '/origin_data/$APP/db/base_category2/$do_date' OVERWRITE into table
${APP}.ods_base_category2 partition(dt='$do_date');

load data inpath '/origin_data/$APP/db/base_category3/$do_date' OVERWRITE into table
${APP}.ods_base_category3 partition(dt='$do_date');

load data inpath '/origin_data/$APP/db/base_trademark/$do_date' OVERWRITE into table
```

更多 [Java](#) - [大数据](#) - [前端](#) - [python](#) 人工智能资料下载, 可百度访问: [尚硅谷官网](#)

```
${APP}.ods_base_trademark partition(dt='${do_date}');

load data inpath '/origin_data/${APP}/db/activity_info/${do_date}' OVERWRITE into table
${APP}.ods_activity_info partition(dt='${do_date}');

load data inpath '/origin_data/${APP}/db/activity_order/${do_date}' OVERWRITE into table
${APP}.ods_activity_order partition(dt='${do_date}');

load data inpath '/origin_data/${APP}/db/cart_info/${do_date}' OVERWRITE into table
${APP}.ods_cart_info partition(dt='${do_date}');

load data inpath '/origin_data/${APP}/db/comment_info/${do_date}' OVERWRITE into table
${APP}.ods_comment_info partition(dt='${do_date}');

load data inpath '/origin_data/${APP}/db/coupon_info/${do_date}' OVERWRITE into table
${APP}.ods_coupon_info partition(dt='${do_date}');

load data inpath '/origin_data/${APP}/db/coupon_use/${do_date}' OVERWRITE into table
${APP}.ods_coupon_use partition(dt='${do_date}');

load data inpath '/origin_data/${APP}/db/favor_info/${do_date}' OVERWRITE into table
${APP}.ods_favor_info partition(dt='${do_date}');

load data inpath '/origin_data/${APP}/db/order_refund_info/${do_date}' OVERWRITE into table
${APP}.ods_order_refund_info partition(dt='${do_date}');

load data inpath '/origin_data/${APP}/db/order_status_log/${do_date}' OVERWRITE into table
${APP}.ods_order_status_log partition(dt='${do_date}');

load data inpath '/origin_data/${APP}/db/spu_info/${do_date}' OVERWRITE into table
${APP}.ods_spu_info partition(dt='${do_date}');

load data inpath '/origin_data/${APP}/db/activity_rule/${do_date}' OVERWRITE into table
${APP}.ods_activity_rule partition(dt='${do_date}');

load data inpath '/origin_data/${APP}/db/base_dic/${do_date}' OVERWRITE into table
${APP}.ods_base_dic partition(dt='${do_date}');
"

sql2="
load data inpath '/origin_data/${APP}/db/base_province/${do_date}' OVERWRITE into table
${APP}.ods_base_province;

load data inpath '/origin_data/${APP}/db/base_region/${do_date}' OVERWRITE into table
${APP}.ods_base_region;
"
case $1 in
"first"){
    $hive -e "$sql1$sql2"
};;
"all"){
    $hive -e "$sql1"
};;
esac
```

2) 修改权限

```
[atguigu@hadoop102 bin]$ chmod 777 hdfs_to_ods_db.sh
```

2.脚本使用说明

1) 初次导入

初次导入时，脚本的第一个参数应为 first，线上环境不传第二个参数，自动获取前一天日期

```
[atguigu@hadoop102 bin]$ hdfs_to_ods_db.sh first 2020-06-14
```

2) 每日导入

每日重复导入，脚本的第一个参数应为 all，线上环境不传第二个参数，自动获取前一天日期。

```
[atguigu@hadoop102 bin]$ hdfs_to_ods_db.sh all 2020-06-15
```

3) 测试数据是否导入成功

```
hive (gmall)>
select * from ods_order_detail where dt='2020-06-15';
```


第 4 章 数仓搭建-DWD 层

- 1) 对用户行为数据解析。
- 2) 对核心数据进行判空过滤。
- 3) 对业务数据采用 **维度模型** 重新建模。


4.1 DWD 层（用户行为日志解析）

4.1.1 日志格式回顾

(1) 页面埋点日志



(2) 启动日志



让天下没有难学的技术

4.1.2 get_json_object 函数使用

1) 数据

```
[{"name": "大郎", "sex": "男", "age": "25"}, {"name": "西门庆", "sex": "男", "age": "47"}]
```

2) 取出第一个 json 对象

```
hive (gmall)>
select get_json_object(' [{"name": "大郎", "sex": "男", "age": "25"}, {"name": "西门庆", "sex": "男", "age": "47"} ]', '$[0]');
```

结果是: {"name": "大郎", "sex": "男", "age": "25"}

3) 取出第一个 json 的 age 字段的值

```
hive (gmall)>
SELECT      get_json_object(' [{"name": "大郎", "sex": "男", "age": "25"}, {"name": "西门庆", "sex": "男", "age": "47"} ]', '$[0].age');
```

结果是: 25

4.1.3 启动日志表

启动日志解析思路: 启动日志表中每行数据对应一个启动记录，一个启动记录应该包含日志中的公共信息和启动信息。先将所有包含 start 字段的日志过滤出来，然后使用 get_json_object 函数解析每个字段。

启动日志表解析

```
{ -- 启动日志
  "common": {
```

```
    ....
  },
  "start": {
    ....
  },
  "err": {
    ....
  },
  "ts": 1585744304000
}
```

```
{ -- 事件日志
```

```
  "common": {
```

```
    ....
```

```
  },
  "actions": [
```

```
    {
```

```
      ....
```

```
    },
  ],
  "displays": [
```

```
    {
```

```
      ....
```

```
    },
  ],
  "page": {
```

```
    ....
```

```
  },
  "err": {
```

```
    ....
```

```
  },
  "ts": 1585744374423
}
```

1) 先过滤出启动日志

get_json_object(line,'\$.start') is not null;

2) 启动日志包括：公共信息+启动信息+时间

get_json_object(line,'\$.common.ar'),

get_json_object(line,'\$.start.entry'),

get_json_object(line,'\$.ts')

```
insert overwrite table dwd_start_log partition(dt='2020-06-14')
```

```
select
```

```
  get_json_object(line,'$.common.ar'),
```

```
  get_json_object(line,'$.common.ba'),
```

```
  get_json_object(line,'$.common.ch'),
```

```
  get_json_object(line,'$.common.md'),
```

```
  get_json_object(line,'$.common.os'),
```

```
  get_json_object(line,'$.common.uid'),
```

```
  get_json_object(line,'$.common.vc'),
```

```
  get_json_object(line,'$.start.entry'),
```

```
  get_json_object(line,'$.start.loading_time'),
```

```
  get_json_object(line,'$.start.open_ad_id'),
```

```
  get_json_object(line,'$.start.open_ad_ms'),
```

```
  get_json_object(line,'$.start.open_ad_skip_ms'),
```

```
  get_json_object(line,'$.ts')
```

```
from ods_log
```

```
where dt='2020-06-14'
```

```
and get_json_object(line,'$.start') is not null;
```

让天下没有难学的技术

1) 建表语句

```
hive (gmall)>
drop table if exists dwd_start_log;
CREATE EXTERNAL TABLE dwd_start_log(
  `area_code` string COMMENT '地区编码',
  `brand` string COMMENT '手机品牌',
  `channel` string COMMENT '渠道',
  `model` string COMMENT '手机型号',
  `mid_id` string COMMENT '设备id',
  `os` string COMMENT '操作系统',
  `user_id` string COMMENT '会员id',
  `version_code` string COMMENT 'app 版本号',
  `entry` string COMMENT ' icon 手机图标 notice 通知  install 安装后启动',
  `loading_time` bigint COMMENT '启动加载时间',
  `open_ad_id` string COMMENT '广告页 ID ',
  `open_ad_ms` bigint COMMENT '广告总共播放时间',
  `open_ad_skip_ms` bigint COMMENT '用户跳过广告时点',
  `ts` bigint COMMENT '时间'
) COMMENT '启动日志表'
PARTITIONED BY (dt string) -- 按照时间创建分区
stored as parquet -- 采用 parquet 列式存储
LOCATION '/warehouse/gmall/dwd/dwd_start_log' -- 指定在 HDFS 上存储位置
TBLPROPERTIES('parquet.compression'='lzo') -- 采用 LZO 压缩
;
```

说明：数据采用 **parquet** 存储方式，是可以支持切片的，不需要再对数据创建索引。如果单纯的 **text** 方式存储数据，需要采用支持切片的，**lzop** 压缩方式并创建索引。

2) 数据导入

```
hive (gmall)>
SET hive.input.format=org.apache.hadoop.hive.ql.io.HiveInputFo
rmat;
insert overwrite table dwd_start_log partition(dt='2020-06-14')
select
  get_json_object(line,'$.common.ar'),
  get_json_object(line,'$.common.ba'),
```

更多 **Java - 大数据 - 前端 - python** 人工智能资料下载，可百度访问：尚硅谷官网

```
get_json_object(line,'$.common.ch'),
get_json_object(line,'$.common.md'),
get_json_object(line,'$.common.mid'),
get_json_object(line,'$.common.os'),
get_json_object(line,'$.common.uid'),
get_json_object(line,'$.common.vc'),
get_json_object(line,'$.start.entry'),
get_json_object(line,'$.start.loading_time'),
get_json_object(line,'$.start.open_ad_id'),
get_json_object(line,'$.start.open_ad_ms'),
get_json_object(line,'$.start.open_ad_skip_ms'),
get_json_object(line,'$.ts')
from ods_log
where dt='2020-06-14'
and get_json_object(line,'$.start') is not null;
```

3) 查看数据

```
hive (gmall)>
select * from dwd_start_log where dt='2020-06-14' limit 2;
```

4) Hive 读取索引文件问题

(1) 两种方式，分别查询数据有多少行

```
hive (gmall)> select * from ods_log;
Time taken: 0.706 seconds, Fetched: 2955 row(s)

hive (gmall)> select count(*) from ods_log;
2959
```

(2) 两次查询结果不一致。

原因是 select * from ods_log 不执行 MR 操作，默认采用的是 ods_log 建表语句中指定的 DeprecatedLzoTextInputFormat，能够识别 lzo.index 为索引文件。

select count(*) from ods_log 执行 MR 操作，默认采用的是 CombineHiveInputFormat，不能识别 lzo.index 为索引文件，将索引文件当做普通文件处理。更严重的是，这会导致 LZO 文件无法切片。

```
hive (gmall)> set hive.input.format;
hive.input.format=org.apache.hadoop.hive.ql.io.CombineHiveInputFormat
```

解决办法：修改 CombineHiveInputFormat 为 HiveInputFormat

(3) 再次测试

```
hive (gmall)>
SET hive.input.format=org.apache.hadoop.hive.ql.io.HiveInputFormat;

hive (gmall)> select * from ods_log;
Time taken: 0.706 seconds, Fetched: 2955 row(s)

hive (gmall)> select count(*) from ods_log;
2955
```

4.1.4 页面日志表

页面日志解析思路：页面日志表中每行数据对应一个页面访问记录，一个页面访问记录应该包含日志中的公共信息和页面信息。先将所有包含 page 字段的日志过滤出来，然后使用 get_json_object 函数解析每个字段。



页面日志表解析



```

{ -- 启动日志
"common": {
  ... ..
},
"start": {
  ... ..
},
"err": {
  ... ..
},
"ts": 1585744304000
}

{ -- 事件日志
"common": {
  ... ..
},
"actions": [
  ... ..
],
"displays": [
  ... ..
],
"page": {
  ... ..
},
"err": {
  ... ..
},
"ts": 1585744374423
}

```

1) 先过滤出事件日志
get_json_object(line, '\$.page') is not null;

2) 页面日志包括：公共信息+页面信息+时间
get_json_object(line, '\$.common.ar'),
get_json_object(line, '\$.page.during_time'),
get_json_object(line, '\$.ts')

```

insert overwrite table dwd_page_log partition(dt='2020-06-14')
select
  get_json_object(line, '$.common.ar'),
  get_json_object(line, '$.common.ba'),
  get_json_object(line, '$.common.ch'),
  get_json_object(line, '$.common.md'),
  get_json_object(line, '$.common.mid'),
  get_json_object(line, '$.common.os'),
  get_json_object(line, '$.common.uid'),
  get_json_object(line, '$.common.vc'),
  get_json_object(line, '$.page.during_time'),
  get_json_object(line, '$.page.item'),
  get_json_object(line, '$.page.item_type'),
  get_json_object(line, '$.page.last_page_id'),
  get_json_object(line, '$.page.page_id'),
  get_json_object(line, '$.page.sourceType'),
  get_json_object(line, '$.ts')
from ods_log
where dt='2020-06-14'
and get_json_object(line, '$.page') is not null;

```

让天下没有难学的技术

1) 建表语句

```

hive (gmall)>
drop table if exists dwd_page_log;
CREATE EXTERNAL TABLE dwd_page_log(
  `area_code` string COMMENT '地区编码',
  `brand` string COMMENT '手机品牌',
  `channel` string COMMENT '渠道',
  `model` string COMMENT '手机型号',
  `mid_id` string COMMENT '设备id',
  `os` string COMMENT '操作系统',
  `user_id` string COMMENT '会员id',
  `version_code` string COMMENT 'app 版本号',
  `during_time` bigint COMMENT '持续时间毫秒',
  `page_item` string COMMENT '目标id',
  `page_item_type` string COMMENT '目标类型',
  `last_page_id` string COMMENT '上页类型',
  `page_id` string COMMENT '页面ID',
  `source_type` string COMMENT '来源类型',
  `ts` bigint
) COMMENT '页面日志表'
PARTITIONED BY (dt string)
stored as parquet
LOCATION '/warehouse/gmall/dwd/dwd_page_log'
TBLPROPERTIES('parquet.compression'='lzo');

```

2) 数据导入

```
hive (gmall)>
SET hive.input.format=org.apache.hadoop.hive.ql.io.HiveInputFo
rmat;
insert overwrite table dwd_page_log partition(dt='2020-06-14')
select
    get_json_object(line, '$.common.ar'),
    get_json_object(line, '$.common.ba'),
    get_json_object(line, '$.common.ch'),
    get_json_object(line, '$.common.md'),
    get_json_object(line, '$.common.mid'),
    get_json_object(line, '$.common.os'),
    get_json_object(line, '$.common.uid'),
    get_json_object(line, '$.common.vc'),
    get_json_object(line, '$.page.during_time'),
    get_json_object(line, '$.page.item'),
    get_json_object(line, '$.page.item_type'),
    get_json_object(line, '$.page.last_page_id'),
    get_json_object(line, '$.page.page_id'),
    get_json_object(line, '$.page.sourceType'),
    get_json_object(line, '$.ts')
from ods_log
where dt='2020-06-14'
and get_json_object(line, '$.page') is not null;
```

3) 查看数据

```
hive (gmall)>
select * from dwd_page_log where dt='2020-06-14' limit 2;
```

4.1.5 动作日志表

动作日志解析思路：动作日志表中每行数据对应用户的一个动作记录，一个动作记录应当包含公共信息、页面信息以及动作信息。先将包含 **action** 字段的日志过滤出来，然后通过 **UDTF 函数**，将 **action** 数组“炸开”（类似于 **explode** 函数的效果），然后使用 **get_json_object** 函数解析每个字段。



动作日志表解析

```
{
  "common": { -- 公共信息
    ...
  },
  "actions": [ -- 动作(事件)
    {
      "action_id": "favor_add", -- 动作id
      "item": "3", -- 动作目标id
      "item_type": "sku_id", -- 动作目标类型
      "ts": 1585744376605 -- 动作时间
    },
    {
      "action_id": "cart_add", -- 动作id
      "item": "4", -- 动作目标id
      "item_type": "sku_id", -- 动作目标类型
      "ts": 1585744376456 -- 动作时间
    }
  ],
  "displays": [
    {
      ...
    }
  ],
  "page": { -- 页面信息
    ...
  },
  "err": { -- 错误
    ...
  },
  "ts": 1585744374423 -- 跳入时间
}
```

1) 先过滤出事件日志
`get_json_object(line, '$.actions') is not null;`

2) 页面日志包括：公共信息+页面信息+动作
`get_json_object(line, '$.common.ar'),`
`get_json_object(line, '$.common.ba'),`
`get_json_object(line, '$.common.ch'),`
`get_json_object(line, '$.common.md'),`
`get_json_object(line, '$.common.mid'),`
`get_json_object(line, '$.common.os'),`
`get_json_object(line, '$.common.uid'),`
`get_json_object(line, '$.common.vc'),`
`get_json_object(line, '$.page.during_time'),`
`get_json_object(line, '$.page.item'),`
`get_json_object(line, '$.page.item_type'),`
`get_json_object(line, '$.page.last_page_id'),`
`get_json_object(line, '$.page.page_id'),`
`get_json_object(line, '$.page.sourceType'),`
`get_json_object(action, '$.action_id'),`
`get_json_object(action, '$.item'),`
`get_json_object(action, '$.item_type'),`
`get_json_object(action, '$.ts')`

动作需要将actions数组中的对象取出，变成多行
要用到自定义UDTF函数
`get_json_object(action, '$.ts')`

```
insert overwrite table dwd_action_log partition(dt='2020-06-14')
select
    get_json_object(line, '$.common.ar'),
    get_json_object(line, '$.common.ba'),
    get_json_object(line, '$.common.ch'),
    get_json_object(line, '$.common.md'),
    get_json_object(line, '$.common.mid'),
    get_json_object(line, '$.common.os'),
    get_json_object(line, '$.common.uid'),
    get_json_object(line, '$.common.vc'),
    get_json_object(line, '$.page.during_time'),
    get_json_object(line, '$.page.item'),
    get_json_object(line, '$.page.item_type'),
    get_json_object(line, '$.page.last_page_id'),
    get_json_object(line, '$.page.page_id'),
    get_json_object(line, '$.page.sourceType'),
    get_json_object(action, '$.action_id'),
    get_json_object(action, '$.item'),
    get_json_object(action, '$.item_type'),
    get_json_object(action, '$.ts')
from ods_log lateral view
explode_json_array(get_json_object(line, '$.actions')) tmp as
action
where dt='2020-06-14'
and get_json_object(line, '$.actions') is not null;
```

让天下没有难学的技术

1) 建表语句

```
hive (gmall)>
drop table if exists dwd_action_log;
CREATE EXTERNAL TABLE dwd_action_log(
  `area_code` string COMMENT '地区编码',
  `brand` string COMMENT '手机品牌',
  `channel` string COMMENT '渠道',
  `model` string COMMENT '手机型号',
  `mid_id` string COMMENT '设备id',
  `os` string COMMENT '操作系统',
  `user_id` string COMMENT '会员id',
  `version_code` string COMMENT 'app 版本号',
  `during_time` bigint COMMENT '持续时间毫秒',
  `page_item` string COMMENT '目标id',
  `page_item_type` string COMMENT '目标类型',
  `last_page_id` string COMMENT '上页类型',
  `page_id` string COMMENT '页面id',
  `source_type` string COMMENT '来源类型',
  `action_id` string COMMENT '动作id',
  `item` string COMMENT '目标id',
  `item_type` string COMMENT '目标类型',
  `ts` bigint COMMENT '时间'
) COMMENT '动作日志表'
PARTITIONED BY (dt string)
stored as parquet
LOCATION '/warehouse/gmall/dwd/dwd_action_log'
TBLPROPERTIES('parquet.compression'='lzo');
```

2) 创建 UDTF 函数——设计思路



UDTF思想



1) 输入: table1 其中一个字段
arr[1,2,3,4,5]

2) 期望输出:

1
2
3
4
5

3) 执行语句:

```
select
  item
from talbe1 lateral view explode(arr) tmp as item
```

4) 底层原理: 形成虚表

arr	item
[1,2,3,4,5]	1
[1,2,3,4,5]	2
[1,2,3,4,5]	3
[1,2,3,4,5]	4
[1,2,3,4,5]	5

```
{
  "common": { -- 公共信息
    ...
  },
  "actions": [ --动作(事件)
    {
      "action_id": "favor_add", --动作id
      "item": "3", --动作目标id
      "item_type": "sku_id", --动作目标类型
      "ts": 1585744376605 --动作时间
    },
    {
      "action_id": "cart_add", --动作id
      "item": "4", --动作目标id
      "item_type": "sku_id", --动作目标类型
      "ts": 1585744376456 --动作时间
    }
  ],
  "displays": [
    {
      ...
    },
    {
      "page": { -- 页面信息
        ...
      },
      "err": { -- 错误
        ...
      },
      "ts": 1585744374423 -- 跳入时间
    }
  ]
}
```

1) 输入:
Common page actions[1,2,3]

2) 期望输出:

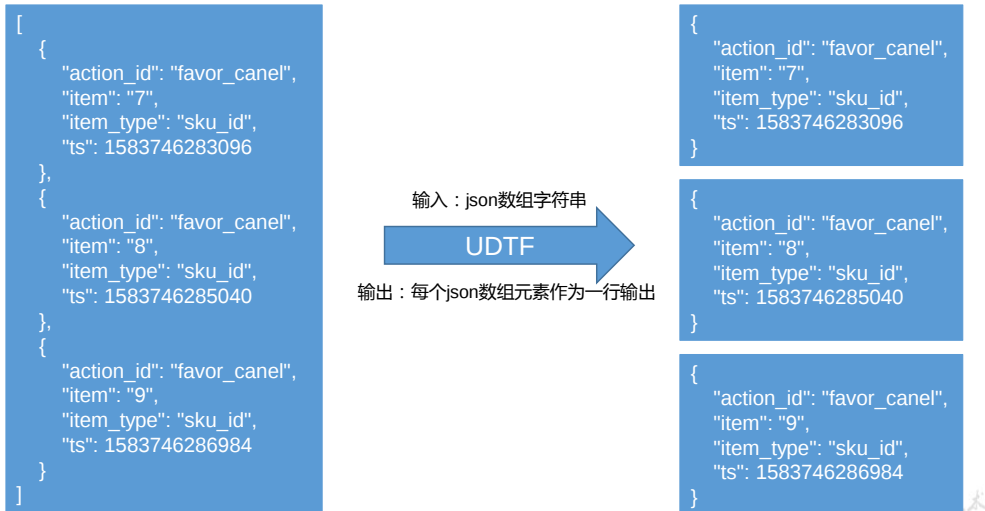
Common page action1
Common page action2
Common page action3

3) 自定义UDTF

输入: json数组(string)

输出: json(string)

让天下没有难学的技术



3) 创建 UDTF 函数——编写代码

(1) 创建一个 maven 工程：hivefunction

(2) 创建包名：com.atguigu.hive.udtf

(3) 引入如下依赖

```

<dependencies>
  <!--添加 hive 依赖-->
  <dependency>
    <groupId>org.apache.hive</groupId>
    <artifactId>hive-exec</artifactId>
    <version>3.1.2</version>
  </dependency>
</dependencies>
    
```

(4) 编码

```

package com.atguigu.hive.udtf;

import org.apache.hadoop.hive.ql.exec.UDFArgumentException;
import org.apache.hadoop.hive.ql.metadata.HiveException;
import org.apache.hadoop.hive.ql.udf.generic.GenericUDTF;
import org.apache.hadoop.hive.serde2.objectinspector.ObjectInspector;
import org.apache.hadoop.hive.serde2.objectinspector.ObjectInspectorFactory;
import org.apache.hadoop.hive.serde2.objectinspector.StructObjectInspector;
import org.apache.hadoop.hive.serde2.objectinspector.primitive.PrimitiveObjectInspectorFactory;
import org.json.JSONArray;

import java.util.ArrayList;
import java.util.List;
    
```

```
public class ExplodeJSONArray extends GenericUDTF {

    @Override
    public StructObjectInspector
initialize(StructObjectInspector argOIs) throws
UDFArgumentException {

        // 1 参数合法性检查
        if (argOIs.getAllStructFieldRefs().size() != 1){
            throw new UDFArgumentException("ExplodeJSONArray 只需要一个参数");
        }

        // 2 第一个参数必须为 string

        if(!"string".equals(argOIs.getAllStructFieldRefs().get(0).getFieldObjectInspector().getTypeName())){
            throw new
UDFArgumentException("json_array_to_struct_array 的第 1 个参数应为 string 类型");
        }

        // 3 定义返回值名称和类型
        List<String> fieldNames = new ArrayList<String>();
        List<ObjectInspector> fieldOIs = new
ArrayList<ObjectInspector>();

        fieldNames.add("items");

        fieldOIs.add(PrimitiveObjectInspectorFactory.javaStringObjectInspector);

        return
ObjectInspectorFactory.getStandardStructObjectInspector(fieldNames, fieldOIs);
    }

    public void process(Object[] objects) throws HiveException
    {

        // 1 获取传入的数据
        String jsonArray = objects[0].toString();

        // 2 将 string 转换为 json 数组
        JSONArray actions = new JSONArray(jsonArray);

        // 3 循环一次，取出数组中的一个 json，并写出
        for (int i = 0; i < actions.length(); i++) {

            String[] result = new String[1];
            result[0] = actions.getString(i);
            forward(result);
        }
    }
}
```

```
public void close() throws HiveException {  
    }  
}
```

4) 创建函数

(1) 打包

(2) 将 hivefunction-1.0-SNAPSHOT.jar 上传到 hadoop102 的/opt/module, 然后再将该 jar 包上传到 HDFS 的/user/hive/jars 路径下

```
[atguigu@hadoop102 module]$ hadoop fs -mkdir -p /user/hive/jars  
[atguigu@hadoop102 module]$ hadoop fs -put hivefunction-1.0-SNAPSHOT.jar /user/hive/jars
```

(3) 创建永久函数与开发好的 java class 关联

```
hive (gmall)>  
create          function          explode_json_array          as  
'com.atguigu.hive.udtf.ExplodeJSONArray'          using          jar  
'hdfs://hadoop102:8020/user/hive/jars/hivefunction-1.0-SNAPSHOT.jar';
```

(4) 注意: 如果修改了自定义函数重新生成 jar 包怎么处理? 只需要替换 HDFS 路径上的旧 jar 包, 然后重启 Hive 客户端即可。

5) 数据导入

```
hive (gmall)>  
SET hive.input.format=org.apache.hadoop.hive.ql.io.HiveInputFormat;  
insert overwrite table dwd_action_log partition(dt='2020-06-14')  
select  
    get_json_object(line, '$.common.ar'),  
    get_json_object(line, '$.common.ba'),  
    get_json_object(line, '$.common.ch'),  
    get_json_object(line, '$.common.md'),  
    get_json_object(line, '$.common.mid'),  
    get_json_object(line, '$.common.os'),  
    get_json_object(line, '$.common.uid'),  
    get_json_object(line, '$.common.vc'),  
    get_json_object(line, '$.page.during_time'),  
    get_json_object(line, '$.page.item'),  
    get_json_object(line, '$.page.item_type'),  
    get_json_object(line, '$.page.last_page_id'),  
    get_json_object(line, '$.page.page_id'),  
    get_json_object(line, '$.page.sourceType'),  
    get_json_object(action, '$.action_id'),  
    get_json_object(action, '$.item'),  
    get_json_object(action, '$.item_type'),  
    get_json_object(action, '$.ts')  
from          ods_log          lateral          view  
explode_json_array(get_json_object(line, '$.actions')) tmp as  
action  
where dt='2020-06-14'  
and get_json_object(line, '$.actions') is not null;
```

3) 查看数据

```
hive (gmall)>
select * from dwd_action_log where dt='2020-06-14' limit 2;
```

4.1.6 曝光日志表

曝光日志解析思路：曝光日志表中每行数据对应一个曝光记录，一个曝光记录应当包含公共信息、页面信息以及曝光信息。先将包含 **display** 字段的日志过滤出来，然后通过 **UDTF** 函数，将 **display** 数组“炸开”（类似于 **explode** 函数的效果），然后使用 **get_json_object** 函数解析每个字段。

曝光日志表解析



```
{
  "common": { -- 公共信息
    ....
  },
  "actions": [ -- 动作(事件)
    {
      ....
    },
    "displays": [
      {
        "displayType": "query", -- 曝光类型
        "item": "3", -- 曝光对象id
        "item_type": "sku_id", -- 曝光对象类型
        "order": 1 -- 曝光顺序
      },
      {
        "displayType": "promotion",
        "item": "6",
        "item_type": "sku_id",
        "order": 2
      }
    ],
    "page": { -- 页面信息
      ....
    },
    "err": { -- 错误
    },
    "ts": 1585744374423 -- 跳入时间
  }
}
```

1) 先过滤出事件日志
`get_json_object(line, '$.displays') is not null;`

2) 页面日志包括：公共信息+页面信息+曝光+时间
`get_json_object(line, '$.common.ar'),`
`get_json_object(line, '$.page.during_time'),`
 动作需要将actions数组中的对象取出，变成多行
 要用到自定义UDTF函数
`get_json_object(displays, '$.displayType'),`

```
insert overwrite table dwd_display_log partition(dt='2020-06-14')
select
  get_json_object(line, '$.common.ar'),
  get_json_object(line, '$.common.ba'),
  get_json_object(line, '$.common.ch'),
  get_json_object(line, '$.common.md'),
  get_json_object(line, '$.common.mid'),
  get_json_object(line, '$.common.os'),
  get_json_object(line, '$.common.uid'),
  get_json_object(line, '$.common.vc'),
  get_json_object(line, '$.page.during_time'),
  get_json_object(line, '$.page.item'),
  get_json_object(line, '$.page.item_type'),
  get_json_object(line, '$.page.last_page_id'),
  get_json_object(line, '$.page.page_id'),
  get_json_object(line, '$.page.sourceType'),
  get_json_object(line, '$.ts'),
  get_json_object(displays, '$.displayType'),
  get_json_object(displays, '$.item'),
  get_json_object(displays, '$.item_type'),
  get_json_object(displays, '$.order')
from ods_log lateral view
explode_json_array(get_json_object(line, '$.displays')) tmp as
displays
where dt='2020-06-14'
and get_json_object(line, '$.displays') is not null;
```

1) 建表语句

```
hive (gmall)>
drop table if exists dwd_display_log;
CREATE EXTERNAL TABLE dwd_display_log(
  `area_code` string COMMENT '地区编码',
  `brand` string COMMENT '手机品牌',
  `channel` string COMMENT '渠道',
  `model` string COMMENT '手机型号',
  `mid_id` string COMMENT '设备id',
  `os` string COMMENT '操作系统',
  `user_id` string COMMENT '会员id',
  `version_code` string COMMENT 'app 版本号',
  `during_time` bigint COMMENT 'app 版本号',
  `page_item` string COMMENT '目标id',
  `page_item_type` string COMMENT '目标类型',
  `last_page_id` string COMMENT '上页类型',
  `page_id` string COMMENT '页面ID',
  `source_type` string COMMENT '来源类型',
  `ts` bigint COMMENT 'app 版本号',
  `display_type` string COMMENT '曝光类型',
  `item` string COMMENT '曝光对象id',
  `item_type` string COMMENT 'app 版本号',
  `order` bigint COMMENT '出现顺序'
```

```
) COMMENT '曝光日志表'
PARTITIONED BY (dt string)
stored as parquet
LOCATION '/warehouse/gmall/dwd/dwd_display_log'
TBLPROPERTIES('parquet.compression'='lzo');
```

2) 数据导入

```
hive (gmall)>
SET hive.input.format=org.apache.hadoop.hive.ql.io.HiveInputFo
rmat;
insert overwrite table dwd_display_log partition(dt='2020-06-
14')
select
    get_json_object(line, '$.common.ar'),
    get_json_object(line, '$.common.ba'),
    get_json_object(line, '$.common.ch'),
    get_json_object(line, '$.common.md'),
    get_json_object(line, '$.common.mid'),
    get_json_object(line, '$.common.os'),
    get_json_object(line, '$.common.uid'),
    get_json_object(line, '$.common.vc'),
    get_json_object(line, '$.page.during_time'),
    get_json_object(line, '$.page.item'),
    get_json_object(line, '$.page.item_type'),
    get_json_object(line, '$.page.last_page_id'),
    get_json_object(line, '$.page.page_id'),
    get_json_object(line, '$.page.sourceType'),
    get_json_object(line, '$.ts'),
    get_json_object(display, '$.displayType'),
    get_json_object(display, '$.item'),
    get_json_object(display, '$.item_type'),
    get_json_object(display, '$.order')
from      ods_log lateral view
explode_json_array(get_json_object(line, '$.displays')) tmp as
display
where dt='2020-06-14'
and get_json_object(line, '$.displays') is not null;
```

3) 查看数据

```
hive (gmall)>
select * from dwd_display_log where dt='2020-06-14' limit 2;
```

4.1.7 错误日志表

错误日志解析思路：错误日志表中每行数据对应一个**错误记录**，为方便定位错误，一个错误记录应当包含与之对应的公共信息、页面信息、曝光信息、动作信息、启动信息以及错误信息。先将包含 **err** 字段的日志过滤出来，然后使用 **get_json_object** 函数解析所有字段。

错误日志表解析

```
{ -- 启动日志
"common": {
```

```
    ....
  },
  "start": {
    ....
  },
  "err": {
    ....
  },
  "ts": 1585744304000
}
```

```
{ -- 事件日志
```

```
"common": {
```

```
    ....
  },
```

```
"actions": [
```

```
    {
      ....
    }
  ],
```

```
"displays": [
```

```
    {
      ....
    }
  ],
```

```
"page": {
```

```
    ....
  },
```

```
"err": {
```

```
    ....
  },
```

```
"ts": 1585744374423
```

```
}
```

1) 先过滤出事件日志

get_json_object(line,'\$.err') is not null;

2) 错误日志包括:

公共+页面+启动+动作+曝光+错误

```
insert overwrite table dwd_error_log partition(dt='2020-06-14')
select
```

```
  get_json_object(line,'$.common.ar'),
  get_json_object(line,'$.common.ba'),
  get_json_object(line,'$.common.ch'),
  get_json_object(line,'$.common.md'),
  get_json_object(line,'$.common.mid'),
  get_json_object(line,'$.common.os'),
  get_json_object(line,'$.common.uid'),
  get_json_object(line,'$.common.vc'),
  get_json_object(line,'$.page.item'),
  get_json_object(line,'$.page.item_type'),
  get_json_object(line,'$.page.last_page_id'),
  get_json_object(line,'$.page.page_id'),
  get_json_object(line,'$.page.sourceType'),
  get_json_object(line,'$.start.entry'),
  get_json_object(line,'$.start.loading_time'),
  get_json_object(line,'$.start.open_ad_id'),
  get_json_object(line,'$.start.open_ad_ms'),
  get_json_object(line,'$.start.open_ad_skip_ms'),
  get_json_object(line,'$.actions'),
  get_json_object(line,'$.displays'),
  get_json_object(line,'$.ts'),
  get_json_object(line,'$.err.error_code'),
  get_json_object(line,'$.err.msg')
```

```
from ods_log
```

```
where dt='2020-06-14'
```

```
and get_json_object(line,'$.err') is not null;
```

让天下没有难学的技术

1) 建表语句

```
hive (gmall)>
drop table if exists dwd_error_log;
CREATE EXTERNAL TABLE dwd_error_log(
  `area_code` string COMMENT '地区编码',
  `brand` string COMMENT '手机品牌',
  `channel` string COMMENT '渠道',
  `model` string COMMENT '手机型号',
  `mid_id` string COMMENT '设备id',
  `os` string COMMENT '操作系统',
  `user_id` string COMMENT '会员id',
  `version_code` string COMMENT 'app 版本号',
  `page_item` string COMMENT '目标id',
  `page_item_type` string COMMENT '目标类型',
  `last_page_id` string COMMENT '上页类型',
  `page_id` string COMMENT '页面ID',
  `source_type` string COMMENT '来源类型',
  `entry` string COMMENT 'icon手机图标 notice 通知 install 安装后启动',
  `loading_time` string COMMENT '启动加载时间',
  `open_ad_id` string COMMENT '广告页ID',
  `open_ad_ms` string COMMENT '广告总共播放时间',
  `open_ad_skip_ms` string COMMENT '用户跳过广告时点',
  `actions` string COMMENT '动作',
  `displays` string COMMENT '曝光',
  `ts` string COMMENT '时间',
  `error_code` string COMMENT '错误码',
  `msg` string COMMENT '错误信息'
) COMMENT '错误日志表'
PARTITIONED BY (dt string)
stored as parquet
LOCATION '/warehouse/gmall/dwd/dwd_error_log'
TBLPROPERTIES('parquet.compression'='lzo');
```

说明: 此处为对动作数组和曝光数组做处理, 如需分析错误与单个动作或曝光的关联,

可先使用 `explode_json_array` 函数将数组“炸开”, 再使用 `get_json_object` 函数获取具体更多 Java - 大数据 - 前端 - python 人工智能资料下载, 可百度访问: 尚硅谷官网

字段。

4) 数据导入

```
hive (gmall)>
SET hive.input.format=org.apache.hadoop.hive.ql.io.HiveInputFormat;
insert overwrite table dwd_error_log partition(dt='2020-06-14')
select
  get_json_object(line, '$.common.ar'),
  get_json_object(line, '$.common.ba'),
  get_json_object(line, '$.common.ch'),
  get_json_object(line, '$.common.md'),
  get_json_object(line, '$.common.mid'),
  get_json_object(line, '$.common.os'),
  get_json_object(line, '$.common.uid'),
  get_json_object(line, '$.common.vc'),
  get_json_object(line, '$.page.item'),
  get_json_object(line, '$.page.item_type'),
  get_json_object(line, '$.page.last_page_id'),
  get_json_object(line, '$.page.page_id'),
  get_json_object(line, '$.page.sourceType'),
  get_json_object(line, '$.start.entry'),
  get_json_object(line, '$.start.loading_time'),
  get_json_object(line, '$.start.open_ad_id'),
  get_json_object(line, '$.start.open_ad_ms'),
  get_json_object(line, '$.start.open_ad_skip_ms'),
  get_json_object(line, '$.actions'),
  get_json_object(line, '$.displays'),
  get_json_object(line, '$.ts'),
  get_json_object(line, '$.err.error_code'),
  get_json_object(line, '$.err.msg')
from ods_log
where dt='2020-06-14'
and get_json_object(line, '$.err') is not null;
```

5) 查看数据

```
hive (gmall)>
select * from dwd_error_log where dt='2020-06-14' limit 2;
```

4.1.8 DWD 层用户行为数据加载脚本

1) 在 hadoop102 的 /home/atguigu/bin 目录下创建脚本

```
[atguigu@hadoop102 bin]$ vim ods_to_dwd_log.sh
```

在脚本中编写如下内容

```
#!/bin/bash

hive=/opt/module/hive/bin/hive
APP=gmall
# 如果是输入的日期按照取输入日期; 如果没输入日期取当前时间的前一天
if [ -n "$1" ] ;then
  do_date=$1
else
  do_date=`date -d "-1 day" +%F`
fi
```

```
sql="
SET mapreduce.job.queueName=hive;
SET hive.input.format=org.apache.hadoop.hive.ql.io.HiveInputFormat;
insert      overwrite      table      ${APP}.dwd_start_log
partition(dt='${do_date}')
select
    get_json_object(line, '$.common.ar'),
    get_json_object(line, '$.common.ba'),
    get_json_object(line, '$.common.ch'),
    get_json_object(line, '$.common.md'),
    get_json_object(line, '$.common.mid'),
    get_json_object(line, '$.common.os'),
    get_json_object(line, '$.common.uid'),
    get_json_object(line, '$.common.vc'),
    get_json_object(line, '$.start.entry'),
    get_json_object(line, '$.start.loading_time'),
    get_json_object(line, '$.start.open_ad_id'),
    get_json_object(line, '$.start.open_ad_ms'),
    get_json_object(line, '$.start.open_ad_skip_ms'),
    get_json_object(line, '$.ts')
from ${APP}.ods_log
where dt='${do_date}'
and get_json_object(line, '$.start') is not null;

insert      overwrite      table      ${APP}.dwd_action_log
partition(dt='${do_date}')
select
    get_json_object(line, '$.common.ar'),
    get_json_object(line, '$.common.ba'),
    get_json_object(line, '$.common.ch'),
    get_json_object(line, '$.common.md'),
    get_json_object(line, '$.common.mid'),
    get_json_object(line, '$.common.os'),
    get_json_object(line, '$.common.uid'),
    get_json_object(line, '$.common.vc'),
    get_json_object(line, '$.page.during_time'),
    get_json_object(line, '$.page.item'),
    get_json_object(line, '$.page.item_type'),
    get_json_object(line, '$.page.last_page_id'),
    get_json_object(line, '$.page.page_id'),
    get_json_object(line, '$.page.sourceType'),
    get_json_object(action, '$.action_id'),
    get_json_object(action, '$.item'),
    get_json_object(action, '$.item_type'),
    get_json_object(action, '$.ts')
from      ${APP}.ods_log      lateral      view
${APP}.explode_json_array(get_json_object(line, '$.actions'))
tmp as action
where dt='${do_date}'
and get_json_object(line, '$.actions') is not null;

insert      overwrite      table      ${APP}.dwd_display_log
partition(dt='${do_date}')
select
    get_json_object(line, '$.common.ar'),
```

```
get_json_object(line,'$.common.ba'),
get_json_object(line,'$.common.ch'),
get_json_object(line,'$.common.md'),
get_json_object(line,'$.common.mid'),
get_json_object(line,'$.common.os'),
get_json_object(line,'$.common.uid'),
get_json_object(line,'$.common.vc'),
get_json_object(line,'$.page.during_time'),
get_json_object(line,'$.page.item'),
get_json_object(line,'$.page.item_type'),
get_json_object(line,'$.page.last_page_id'),
get_json_object(line,'$.page.page_id'),
get_json_object(line,'$.page.sourceType'),
get_json_object(line,'$.ts'),
get_json_object(display,'$.displayType'),
get_json_object(display,'$.item'),
get_json_object(display,'$.item_type'),
get_json_object(display,'$.order')
from          ${APP}.ods_log          lateral          view
${APP}.explode_json_array(get_json_object(line,'$.displays'))
tmp as display
where dt='${do_date}'
and get_json_object(line,'$.displays') is not null;

insert        overwrite          table          ${APP}.dwd_page_log
partition(dt='${do_date}')
select
    get_json_object(line,'$.common.ar'),
    get_json_object(line,'$.common.ba'),
    get_json_object(line,'$.common.ch'),
    get_json_object(line,'$.common.md'),
    get_json_object(line,'$.common.mid'),
    get_json_object(line,'$.common.os'),
    get_json_object(line,'$.common.uid'),
    get_json_object(line,'$.common.vc'),
    get_json_object(line,'$.page.during_time'),
    get_json_object(line,'$.page.item'),
    get_json_object(line,'$.page.item_type'),
    get_json_object(line,'$.page.last_page_id'),
    get_json_object(line,'$.page.page_id'),
    get_json_object(line,'$.page.sourceType'),
    get_json_object(line,'$.ts')
from ${APP}.ods_log
where dt='${do_date}'
and get_json_object(line,'$.page') is not null;

insert        overwrite          table          ${APP}.dwd_error_log
partition(dt='${do_date}')
select
    get_json_object(line,'$.common.ar'),
    get_json_object(line,'$.common.ba'),
    get_json_object(line,'$.common.ch'),
    get_json_object(line,'$.common.md'),
    get_json_object(line,'$.common.mid'),
    get_json_object(line,'$.common.os'),
    get_json_object(line,'$.common.uid'),
    get_json_object(line,'$.common.vc'),
```

```
get_json_object(line,'$.page.item'),
get_json_object(line,'$.page.item_type'),
get_json_object(line,'$.page.last_page_id'),
get_json_object(line,'$.page.page_id'),
get_json_object(line,'$.page.sourceType'),
get_json_object(line,'$.start.entry'),
get_json_object(line,'$.start.loading_time'),
get_json_object(line,'$.start.open_ad_id'),
get_json_object(line,'$.start.open_ad_ms'),
get_json_object(line,'$.start.open_ad_skip_ms'),
get_json_object(line,'$.actions'),
get_json_object(line,'$.displays'),
get_json_object(line,'$.ts'),
get_json_object(line,'$.err.error_code'),
get_json_object(line,'$.err.msg')
from ${APP}.ods_log
where dt='${do_date}'
and get_json_object(line,'$.err') is not null;
"

$hive -e "$sql"
```

2) 增加脚本执行权限

```
[atguigu@hadoop102 bin]$ chmod 777 ods_to_dwd_log.sh
```

3) 脚本使用

```
[atguigu@hadoop102 module]$ ods_to_dwd_log.sh 2020-06-15
```

4) 查询导入结果


```
hive (gmall)>
select * from dwd_start_log where dt='2020-06-15' limit 2;
```

5) 脚本执行时间

企业开发中一般在每日凌晨 30 分~1 点

4.2 DWD 层（业务数据）

业务数据方面 DWD 层的搭建主要注意点在于维度建模，减少后续大量 Join 操作。



4.4.1 商品维度表（全量）

商品维度表主要是将商品表 SKU 表、商品一级分类、商品二级分类、商品三级分类、商品品牌表和商品 SPU 表联接为商品表。

商品维度表

```
hive (gmall)>
DROP TABLE IF EXISTS `dwd_dim_sku_info`;
CREATE EXTERNAL TABLE `dwd_dim_sku_info` (
  `id` string COMMENT '商品id',
  `spu_id` string COMMENT 'spuid',
  `price` double COMMENT '商品价格',
  `sku_name` string COMMENT '商品名称',
  `sku_desc` string COMMENT '商品描述',
  `weight` double COMMENT '重量',
  `tm_id` string COMMENT '品牌id',
  `tm_name` string COMMENT '品牌名称',
  `category3_id` string COMMENT '三级分类id',
  `category2_id` string COMMENT '二级分类id',
  `category1_id` string COMMENT '一级分类id',
  `category3_name` string COMMENT '三级分类名称',
  `category2_name` string COMMENT '二级分类名称',
  `category1_name` string COMMENT '一级分类名称',
  `sku_name` string COMMENT 'sku名称',
  `create_time` string COMMENT '创建时间'
) COMMENT '商品维度表'
PARTITIONED BY (`dt` string)
stored as parquet
location '/warehouse/gmall/dwd/dwd_dim_sku_info/'
tblproperties ("parquet.compression"="lzo");
```

```
hive (gmall)>
insert overwrite table dwd_dim_sku_info partition(dt='2020-06-14')
select
  sku.id,
  sku.spu_id,
  sku.price,
  sku.sku_name,
  sku.sku_desc,
  sku.weight,
  sku.tm_id,
  ob.tm_name,
  sku.category3_id,
  c2.id category2_id,
  c1.id category1_id,
  c3.name category3_name,
  c2.name category2_name,
  c1.name category1_name,
  spu.spu_name,
  sku.create_time
from(
  select * from ods_sku_info where dt='2020-06-14'
) sku
join(
  select * from ods_base_trademark where dt='2020-06-14'
) ob on sku.tm_id=ob.tm_id
join(
  select * from ods_spu_info where dt='2020-06-14'
) spu on spu.id = sku.spu_id
join (
  select * from ods_base_category3 where dt='2020-06-14'
) c3 on sku.category3_id=c3.id
join (
  select * from ods_base_category2 where dt='2020-06-14'
) c2 on c3.category2_id=c2.id
join (
  select * from ods_base_category1 where dt='2020-06-14'
) c1 on c2.category1_id=c1.id;
```

1) 建表语句

```
hive (gmall)>
DROP TABLE IF EXISTS `dwd_dim_sku_info`;
CREATE EXTERNAL TABLE `dwd_dim_sku_info` (
  `id` string COMMENT '商品id',
  `spu_id` string COMMENT 'spuid',
  `price` decimal(16,2) COMMENT '商品价格',
  `sku_name` string COMMENT '商品名称',
  `sku_desc` string COMMENT '商品描述',
  `weight` decimal(16,2) COMMENT '重量',
  `tm_id` string COMMENT '品牌id',
  `tm_name` string COMMENT '品牌名称',
```

```
`category3_id` string COMMENT '三级分类id',
`category2_id` string COMMENT '二级分类id',
`category1_id` string COMMENT '一级分类id',
`category3_name` string COMMENT '三级分类名称',
`category2_name` string COMMENT '二级分类名称',
`category1_name` string COMMENT '一级分类名称',
`spu_name` string COMMENT 'spu名称',
`create_time` string COMMENT '创建时间'
) COMMENT '商品维度表'
PARTITIONED BY (`dt` string)
stored as parquet
location '/warehouse/gmall/dwd/dwd_dim_sku_info/'
tblproperties ("parquet.compression"="lzo");
```

2) 数据装载

```
hive (gmall)>
SET hive.input.format=org.apache.hadoop.hive.ql.io.HiveInputFormat;
insert overwrite table dwd_dim_sku_info partition(dt='2020-06-14')
select
    sku.id,
    sku.spu_id,
    sku.price,
    sku.sku_name,
    sku.sku_desc,
    sku.weight,
    sku.tm_id,
    ob.tm_name,
    sku.category3_id,
    c2.id category2_id,
    c1.id category1_id,
    c3.name category3_name,
    c2.name category2_name,
    c1.name category1_name,
    spu.spu_name,
    sku.create_time
from
(
    select * from ods_sku_info where dt='2020-06-14'
)sku
join
(
    select * from ods_base_trademark where dt='2020-06-14'
)ob on sku.tm_id=ob.tm_id
join
(
    select * from ods_spu_info where dt='2020-06-14'
)spu on spu.id = sku.spu_id
join
(
    select * from ods_base_category3 where dt='2020-06-14'
)c3 on sku.category3_id=c3.id
join
(
    select * from ods_base_category2 where dt='2020-06-14'
)c2 on c3.category2_id=c2.id
join
(
    select * from ods_base_category1 where dt='2020-06-14'
)c1 on c2.category1_id=c1.id;
```

3) 查询加载结果

```
hive (gmall)> select * from dwd_dim_sku_info where dt='2020-06-14' limit 2;
```

4.4.2 优惠券维度表（全量）

把 ODS 层 ods_coupon_info 表数据导入到 DWD 层优惠券维度表，在导入过程中可以做适当的清洗。

1) 建表语句

```
hive (gmall)>
drop table if exists dwd_dim_coupon_info;
create external table dwd_dim_coupon_info(
    `id` string COMMENT '购物券编号',
    `coupon_name` string COMMENT '购物券名称',
    `coupon_type` string COMMENT '购物券类型 1 现金券 2 折扣券 3 满减券 4 满件打折券',
    `condition_amount` decimal(16,2) COMMENT '满额数',
    `condition_num` bigint COMMENT '满件数',
    `activity_id` string COMMENT '活动编号',
    `benefit_amount` decimal(16,2) COMMENT '减金额',
    `benefit_discount` decimal(16,2) COMMENT '折扣',
    `create_time` string COMMENT '创建时间',
    `range_type` string COMMENT '范围类型 1、商品 2、品类 3、品牌',
    `spu_id` string COMMENT '商品 id',
    `tm_id` string COMMENT '品牌 id',
    `category3_id` string COMMENT '品类 id',
    `limit_num` bigint COMMENT '最多领用次数',
    `operate_time` string COMMENT '修改时间',
    `expire_time` string COMMENT '过期时间'
) COMMENT '优惠券维度表'
PARTITIONED BY (`dt` string)
stored as parquet
location '/warehouse/gmall/dwd/dwd_dim_coupon_info/'
tblproperties ("parquet.compression"="lzo");
```

2) 数据装载

```
hive (gmall)>
SET hive.input.format=org.apache.hadoop.hive.ql.io.HiveInputFormat;
insert overwrite table dwd_dim_coupon_info partition(dt='2020-06-14')
select
    id,
    coupon_name,
    coupon_type,
    condition_amount,
    condition_num,
    activity_id,
    benefit_amount,
    benefit_discount,
    create_time,
    range_type,
    spu_id,
    tm_id,
    category3_id,
    limit_num,
    operate_time,
    expire_time
from ods_coupon_info
where dt='2020-06-14';
```

3) 查询加载结果

```
hive (gmall)> select * from dwd_dim_coupon_info where dt='2020-06-14' limit 2;
```

4.4.3 活动维度表（全量）



```
hive (gmall)>
drop table if exists dwd_dim_activity_info;
create external table dwd_dim_activity_info(
  `id` string COMMENT '编号',
  `activity_name` string COMMENT '活动名称',
  `activity_type` string COMMENT '活动类型',
  `start_time` string COMMENT '开始时间',
  `end_time` string COMMENT '结束时间',
  `create_time` string COMMENT '创建时间'
) COMMENT '活动维度表'
PARTITIONED BY (`dt` string)
stored as parquet
location '/warehouse/gmall/dwd/dwd_dim_activity_info/'
tblproperties ("parquet.compression"="lzo");
```

```
hive (gmall)>
insert overwrite table dwd_dim_activity_info partition(dt='2020-06-14')
select
  id,
  activity_name,
  activity_type,
  start_time,
  end_time,
  create_time
from ods_activity_info
where dt='2020-06-14';
```

让天下没有难学的技术

1) 建表语句

```
hive (gmall)>
drop table if exists dwd_dim_activity_info;
create external table dwd_dim_activity_info(
  `id` string COMMENT '编号',
  `activity_name` string COMMENT '活动名称',
  `activity_type` string COMMENT '活动类型',
  `start_time` string COMMENT '开始时间',
  `end_time` string COMMENT '结束时间',
  `create_time` string COMMENT '创建时间'
) COMMENT '活动信息表'
PARTITIONED BY (`dt` string)
stored as parquet
location '/warehouse/gmall/dwd/dwd_dim_activity_info/'
tblproperties ("parquet.compression"="lzo");
```

2) 数据装载

```
hive (gmall)>
SET hive.input.format=org.apache.hadoop.hive.ql.io.HiveInputFormat;
insert overwrite table dwd_dim_activity_info partition(dt='2020-06-14')
select
  id,
  activity_name,
  activity_type,
  start_time,
  end_time,
  create_time
from ods_activity_info
where dt='2020-06-14';
```

3) 查询加载结果

```
hive (gmall)> select * from dwd_dim_activity_info where dt='2020-06-14' limit 2;
```

4.4.4 地区维度表（特殊）

地区维度表



```
hive (gmall)>
DROP TABLE IF EXISTS `dwd_dim_base_province`;
CREATE EXTERNAL TABLE `dwd_dim_base_province`
(
  `id` string COMMENT 'id',
  `province_name` string COMMENT '省市名称',
  `area_code` string COMMENT '地区编码',
  `iso_code` string COMMENT 'ISO编码',
  `region_id` string COMMENT '地区id',
  `region_name` string COMMENT '地区名称'
) COMMENT '地区维度表'
stored as parquet
location
'/warehouse/gmall/dwd/dwd_dim_base_province/'
tblproperties ("parquet.compression"="lzo");
```

```
hive (gmall)>
insert overwrite table dwd_dim_base_province
select
  bp.id,
  bp.name,
  bp.area_code,
  bp.iso_code,
  bp.region_id,
  br.region_name
from
(
  select * from ods_base_province
) bp
join
(
  select * from ods_base_region
) br
on bp.region_id = br.id;
```

让天下没有难学的技术

1) 建表语句

```
hive (gmall)>
DROP TABLE IF EXISTS `dwd_dim_base_province`;
CREATE EXTERNAL TABLE `dwd_dim_base_province` (
  `id` string COMMENT 'id',
  `province_name` string COMMENT '省市名称',
  `area_code` string COMMENT '地区编码',
  `iso_code` string COMMENT 'ISO 编码',
  `region_id` string COMMENT '地区 id',
  `region_name` string COMMENT '地区名称'
) COMMENT '地区维度表'
stored as parquet
location '/warehouse/gmall/dwd/dwd_dim_base_province/'
tblproperties ("parquet.compression"="lzo");
```

2) 数据装载

```
hive (gmall)>
SET hive.input.format=org.apache.hadoop.hive.ql.io.HiveInputFormat;
insert overwrite table dwd_dim_base_province
select
  bp.id,
  bp.name,
  bp.area_code,
  bp.iso_code,
  bp.region_id,
  br.region_name
from
(
  select * from ods_base_province
) bp
join
(
  select * from ods_base_region
) br
on bp.region_id = br.id;
```

3) 查询加载结果

更多 [Java](#) - [大数据](#) - [前端](#) - [python](#) 人工智能资料下载，可百度访问：尚硅谷官网

```
hive (gmall)> select * from dwd_dim_base_province limit 2;
```

4.4.5 时间维度表（特殊）

1) 建表语句

```
hive (gmall)>
DROP TABLE IF EXISTS `dwd_dim_date_info`;
CREATE EXTERNAL TABLE `dwd_dim_date_info` (
  `date_id` string COMMENT '日',
  `week_id` string COMMENT '周',
  `week_day` string COMMENT '周的第几天',
  `day` string COMMENT '每月的第几天',
  `month` string COMMENT '第几月',
  `quarter` string COMMENT '第几季度',
  `year` string COMMENT '年',
  `is_workday` string COMMENT '是否是周末',
  `holiday_id` string COMMENT '是否是节假日'
) COMMENT '时间维度表'
stored as parquet
location '/warehouse/gmall/dwd/dwd_dim_date_info/'
tblproperties ("parquet.compression"="lzo");
```

2) 把 date_info.txt 文件上传到 hadoop102 的/opt/module/db_log/路径

3) 数据装载

注意：由于 dwd_dim_date_info 是列式存储+LZO 压缩。直接将 date_info.txt 文件导入到目标表，并不会直接转换为列式存储+LZO 压缩。我们需要创建一张普通的临时表 dwd_dim_date_info_tmp，将 date_info.txt 加载到该临时表中。最后通过查询临时表数据，把查询到的数据插入到最终的目标表中。

(1) 创建临时表，非列式存储

```
hive (gmall)>
DROP TABLE IF EXISTS `dwd_dim_date_info_tmp`;
CREATE EXTERNAL TABLE `dwd_dim_date_info_tmp` (
  `date_id` string COMMENT '日',
  `week_id` string COMMENT '周',
  `week_day` string COMMENT '周的第几天',
  `day` string COMMENT '每月的第几天',
  `month` string COMMENT '第几月',
  `quarter` string COMMENT '第几季度',
  `year` string COMMENT '年',
  `is_workday` string COMMENT '是否是周末',
  `holiday_id` string COMMENT '是否是节假日'
) COMMENT '时间临时表'
row format delimited fields terminated by '\t'
location '/warehouse/gmall/dwd/dwd_dim_date_info_tmp/';
```

(2) 将数据导入临时表

```
hive (gmall)>
load data local inpath '/opt/module/db_log/date_info.txt' into table
dwd_dim_date_info_tmp;
```

(3) 将数据导入正式表

```
hive (gmall)>
insert overwrite table dwd_dim_date_info select * from dwd_dim_date_info_tmp;
```

4) 查询加载结果

更多 [Java](#) -[大数据](#) -[前端](#) -[python](#) 人工智能资料下载，可百度访问：[尚硅谷官网](#)

```
hive (gmall)> select * from dwd_dim_date_info;
```

4.4.6 支付事实表（事务型事实表）

	时间	用户	地区	商品	优惠券	活动	编码	度量值
支付	√	√	√					金额

支付事实表



```
drop table if exists dwd_fact_payment_info;
create external table dwd_fact_payment_info (
  `id` string COMMENT '对外业务编号',
  `out_trade_no` string COMMENT '订单编号',
  `user_id` string COMMENT '用户编号',
  `alipay_trade_no` string COMMENT '支付宝交易流水编号',
  `payment_amount` decimal(16,2) COMMENT '支付金额',
  `subject` string COMMENT '交易内容',
  `payment_type` string COMMENT '支付类型',
  `payment_time` string COMMENT '支付时间',
  `province_id` string COMMENT '省份ID'
)
PARTITIONED BY (`dt` string)
stored as parquet
location '/warehouse/gmall/dwd/dwd_fact_payment_info/'
tblproperties ("parquet.compression"="lzo");

hive (gmall)>
insert overwrite table dwd_fact_payment_info partition(dt='2020-06-14')
select
  pi.id,
  pi.out_trade_no,
  pi.order_id,
  pi.user_id,
  pi.alipay_trade_no,
  pi.total_amount,
  pi.subject,
  pi.payment_type,
  pi.payment_time,
  oi.province_id
from
  (
    select * from ods_payment_info where dt='2020-06-14'
  )pi
join
  (
    select id, province_id from ods_order_info where dt='2020-06-14'
  )oi
on pi.order_id = oi.id;
```

让天下没有难学的技术

1) 建表语句

```
hive (gmall)>
drop table if exists dwd_fact_payment_info;
create external table dwd_fact_payment_info (
  `id` string COMMENT 'id',
  `out_trade_no` string COMMENT '对外业务编号',
  `order_id` string COMMENT '订单编号',
  `user_id` string COMMENT '用户编号',
  `alipay_trade_no` string COMMENT '支付宝交易流水编号',
  `payment_amount` decimal(16,2) COMMENT '支付金额',
  `subject` string COMMENT '交易内容',
  `payment_type` string COMMENT '支付类型',
  `payment_time` string COMMENT '支付时间',
  `province_id` string COMMENT '省份ID'
) COMMENT '支付事实表表'
PARTITIONED BY (`dt` string)
stored as parquet
location '/warehouse/gmall/dwd/dwd_fact_payment_info/'
tblproperties ("parquet.compression"="lzo");
```

2) 数据装载

```
hive (gmall)>
SET hive.input.format=org.apache.hadoop.hive.ql.io.HiveInputFormat;
insert overwrite table dwd_fact_payment_info partition(dt='2020-06-14')
select
  pi.id,
  pi.out_trade_no,
  pi.order_id,
  pi.user_id,
  pi.alipay_trade_no,
  pi.total_amount,
  pi.subject,
  pi.payment_type,
```

```

    pi.payment_time,
    oi.province_id
from
(
    select * from ods_payment_info where dt='2020-06-14'
)pi
join
(
    select id, province_id from ods_order_info where dt='2020-06-14'
)oi
on pi.order_id = oi.id;

```

3) 查询加载结果

```
hive (gmall)> select * from dwd_fact_payment_info where dt='2020-06-14' limit 2;
```

4.4.7 退款事实表（事务型事实表）

把 ODS 层 ods_order_refund_info 表数据导入到 DWD 层退款事实表，在导入过程中可以做适当的清洗。

	时间	用户	地区	商品	优惠券	活动	编码	度量值
退款	√	√		√				件数/金额

1) 建表语句

```

hive (gmall)>
drop table if exists dwd_fact_order_refund_info;
create external table dwd_fact_order_refund_info(
    `id` string COMMENT '编号',
    `user_id` string COMMENT '用户 ID',
    `order_id` string COMMENT '订单 ID',
    `sku_id` string COMMENT '商品 ID',
    `refund_type` string COMMENT '退款类型',
    `refund_num` bigint COMMENT '退款件数',
    `refund_amount` decimal(16,2) COMMENT '退款金额',
    `refund_reason_type` string COMMENT '退款原因类型',
    `create_time` string COMMENT '退款时间'
) COMMENT '退款事实表'
PARTITIONED BY (`dt` string)
stored as parquet
location '/warehouse/gmall/dwd/dwd_fact_order_refund_info/'
tblproperties ("parquet.compression"="lzo");

```

2) 数据装载

```

hive (gmall)>
SET hive.input.format=org.apache.hadoop.hive.ql.io.HiveInputFormat;
insert overwrite table dwd_fact_order_refund_info partition(dt='2020-06-14')
select
    id,
    user_id,
    order_id,
    sku_id,
    refund_type,
    refund_num,
    refund_amount,
    refund_reason_type,
    create_time
from ods_order_refund_info
where dt='2020-06-14';

```

3) 查询加载结果

更多 [Java](#) - [大数据](#) - [前端](#) - [python](#) 人工智能资料下载，可百度访问：尚硅谷官网

```
hive (gmall)> select * from dwd_fact_order_refund_info where dt='2020-06-14' limit 2;
```

4.4.8 评价事实表（事务型事实表）

把 ODS 层 ods_comment_info 表数据导入到 DWD 层评价事实表，在导入过程中可以做适当的清洗。

	时间	用户	地区	商品	优惠券	活动	编码	度量值
评价	√	√		√				个数

1) 建表语句

```
hive (gmall)>
drop table if exists dwd_fact_comment_info;
create external table dwd_fact_comment_info(
  `id` string COMMENT '编号',
  `user_id` string COMMENT '用户 ID',
  `sku_id` string COMMENT '商品 sku',
  `spu_id` string COMMENT '商品 spu',
  `order_id` string COMMENT '订单 ID',
  `appraise` string COMMENT '评价',
  `create_time` string COMMENT '评价时间'
) COMMENT '评价事实表'
PARTITIONED BY (`dt` string)
stored as parquet
location '/warehouse/gmall/dwd/dwd_fact_comment_info/'
tblproperties ("parquet.compression"="lzo");
```

2) 数据装载

```
hive (gmall)>
SET hive.input.format=org.apache.hadoop.hive.ql.io.HiveInputFormat;
insert overwrite table dwd_fact_comment_info partition(dt='2020-06-14')
select
  id,
  user_id,
  sku_id,
  spu_id,
  order_id,
  appraise,
  create_time
from ods_comment_info
where dt='2020-06-14';
```

3) 查询加载结果

```
hive (gmall)> select * from dwd_fact_comment_info where dt='2020-06-14' limit 2;
```

4.4.9 订单明细事实表（事务型事实表）

	时间	用户	地区	商品	优惠券	活动	编码	度量值
订单详情	√	√	√	√				件数/金额

订单明细事实表

```
drop table if exists dwd_fact_order_detail;
create external table dwd_fact_order_detail (
  'id' string COMMENT '订单编号',
  'order_id' string COMMENT '订单号',
  'user_id' string COMMENT '用户id',
  'sku_id' string COMMENT 'sku商品id',
  'sku_name' string COMMENT '商品名称',
  'order_price' decimal(16,2) COMMENT '商品价格',
  'sku_num' bigint COMMENT '商品数量',
  'create_time' string COMMENT '创建时间',
  'province_id' string COMMENT '省份ID',
  'source_type' string COMMENT '来源类型',
  'source_id' string COMMENT '来源编号',
  'original_amount_d' decimal(20,2) COMMENT '原始价格分摊',
  'final_amount_d' decimal(20,2) COMMENT '购买价格分摊',
  'feight_fee_d' decimal(20,2) COMMENT '分摊运费',
  'benefit_reduce_amount_d' decimal(20,2) COMMENT '分摊优惠'
) COMMENT '订单明细事实表'
PARTITIONED BY ('dt' string)
stored as parquet
location '/warehouse/gmall/dwd/dwd_fact_order_detail'
tblproperties ("parquet.compression"="lzo");

create external table ods_order_info (
  'id' string COMMENT '订单号',
  'final_total_amount' decimal(16,2) COMMENT '订单金额',
  'province_id' string COMMENT '省份ID',
  'benefit_reduce_amount' decimal(16,2) COMMENT '优惠金额',
  'original_total_amount' decimal(16,2) COMMENT '原价金额',
  'feight_fee' decimal(16,2) COMMENT '运费'
) COMMENT '订单表'
```

```
create external table ods_order_detail(
  'id' string COMMENT '订单编号',
  'order_id' string COMMENT '订单号',
  'order_price' decimal(16,2) COMMENT '商品价格',
  'sku_num' bigint COMMENT '商品数量',
) COMMENT '订单详情表'

(
  select * from ods_order_detail where dt='2020-06-14'
) od join (
  select * from ods_order_info where dt='2020-06-14'
) oi on od.order_id=oi.id

订单表  original_total_amount  feight_fee  benefit_reduce_amount  final_total_amount
id001:  100原价                10运费          20优惠          最终花费90元

订单详情
订单id  原价分摊  运费分摊  优惠分摊  购买价格分摊
id001  商品1  20元=10元*2个  10* ( 20/100 )  20* ( 20/100 )  90* ( 20/100 )
id001  商品2  30元=10元*3个  10* ( 30/100 )  20* ( 30/100 )  90* ( 30/100 )
id001  商品3  50元=25元*2个  10* ( 50/100 )  20* ( 50/100 )  90* ( 50/100 )

订单详情  original_amount_d  feight_fee_d  benefit_reduce_amount_d  final_amount_d
订单id  原价分摊  运费分摊  优惠分摊  购买价格分摊
id001  20  2  4  18
id001  30  3  6  27
id001  50  5  10  45

订单id  订单详情id  运费分摊  订单运费总和  sum_div_feight_fee  row_number
id002  1  3.33  10  9.99  1
id002  2  3.33  10  9.99  2
id002  3  3.33  10  9.99  3
```

订单明细事实表

```
insert overwrite table dwd_fact_order_detail partition(dt='2020-06-14')
select
  id,
  ...,
  province_id,
  ...,
  original_amount_d, --原始价格分摊=商品价格*商品数量
  if(m=1,final_total_amount - (sum_div_final_amount - final_amount_d), final_amount_d), --购买价格分摊
  if(m=1,feight_fee - (sum_div_feight_fee - feight_fee_d), feight_fee_d), --分摊运费
  if(m=1,benefit_reduce_amount - (sum_div_benefit_reduce_amount - benefit_reduce_amount_d), benefit_reduce_amount_d), --分摊优惠
from (
  select
    od.id,
    ...,
    oi.province_id,
    ...,
    round(od.order_price*od.sku_num/2) original_amount_d, --原始价格分摊=商品价格*商品数量
    round(od.order_price*od.sku_num / oi.original_total_amount * oi.final_total_amount, 2) final_amount_d, --购买价格分摊=商品价格*商品数量/原价金额 * 订单金额
    round(od.order_price*od.sku_num / oi.original_total_amount * oi.feight_fee, 2) feight_fee_d, --分摊运费=商品价格*商品数量/原价金额 * 订单运费
    round(od.order_price*od.sku_num / oi.original_total_amount * oi.benefit_reduce_amount, 2) benefit_reduce_amount_d, --分摊优惠=商品价格*商品数量/原价金额 * 订单优惠金额
    row_number() over(partition by od.order_id order by od.id desc) rn,
    oi.final_total_amount, --订单金额
    oi.feight_fee, --订单运费
    oi.benefit_reduce_amount, --订单优惠金额
    sum(round(od.order_price*od.sku_num / oi.original_total_amount * oi.final_total_amount, 2)) over(partition by od.order_id) sum_div_final_amount, --购买价格分摊运费的总和
    sum(round(od.order_price*od.sku_num / oi.original_total_amount * oi.feight_fee, 2)) over(partition by od.order_id) sum_div_feight_fee, --分摊运费的总和
    sum(round(od.order_price*od.sku_num / oi.original_total_amount * oi.benefit_reduce_amount, 2)) over(partition by od.order_id) sum_div_benefit_reduce_amount --分摊优惠的总和
  from (
    select * from ods_order_detail where dt='2020-06-14'
  ) od
  join (
    select * from ods_order_info where dt='2020-06-14'
  ) oi
  on od.order_id=oi.id
) t1;
```

```
订单表  original_total_amount  feight_fee  benefit_reduce_amount  final_total_amount
id001:  100原价                10运费          20优惠          最终花费90元

订单详情
订单id  原价分摊  运费分摊  优惠分摊  购买价格分摊
id001  商品1  20元=10元*2个  10* ( 20/100 )  20* ( 20/100 )  90* ( 20/100 )
id001  商品2  30元=10元*3个  10* ( 30/100 )  20* ( 30/100 )  90* ( 30/100 )
id001  商品3  50元=25元*2个  10* ( 50/100 )  20* ( 50/100 )  90* ( 50/100 )

订单详情  original_amount_d  feight_fee_d  benefit_reduce_amount_d  final_amount_d
订单id  原价分摊  运费分摊  优惠分摊  购买价格分摊
id001  20  2  4  18
id001  30  3  6  27
id001  50  5  10  45

订单id  订单详情id  运费分摊  订单运费总和  sum_div_feight_fee  row_number
id002  1  3.33  10  9.99  1
id002  2  3.33  10  9.99  2
id002  3  3.33  10  9.99  3
```

1) 建表语句

```
hive (gmall)>
drop table if exists dwd_fact_order_detail;
create external table dwd_fact_order_detail (
  'id' string COMMENT '订单编号',
  'order_id' string COMMENT '订单号',
  'user_id' string COMMENT '用户id',
  'sku_id' string COMMENT 'sku商品id',
  'sku_name' string COMMENT '商品名称',
  'order_price' decimal(16,2) COMMENT '商品价格',
  'sku_num' bigint COMMENT '商品数量',
  'create_time' string COMMENT '创建时间',
  'province_id' string COMMENT '省份ID',
  'source_type' string COMMENT '来源类型',
  'source_id' string COMMENT '来源编号',
  'original_amount_d' decimal(20,2) COMMENT '原始价格分摊',
  'final_amount_d' decimal(20,2) COMMENT '购买价格分摊',
  'feight_fee_d' decimal(20,2) COMMENT '分摊运费',
  'benefit_reduce_amount_d' decimal(20,2) COMMENT '分摊优惠'
```

```
) COMMENT '订单明细事实表'  
PARTITIONED BY (`dt` string)  
stored as parquet  
location '/warehouse/gmall/dwd/dwd_fact_order_detail/'  
tblproperties ("parquet.compression"="lzo");
```

2) 数据装载

```
hive (gmall)>  
SET hive.input.format=org.apache.hadoop.hive.ql.io.HiveInputFormat;  
insert overwrite table dwd_fact_order_detail partition(dt='2020-06-14')  
select  
    id,  
    order_id,  
    user_id,  
    sku_id,  
    sku_name,  
    order_price,  
    sku_num,  
    create_time,  
    province_id,  
    source_type,  
    source_id,  
    original_amount_d,  
    if(rn=1,final_total_amount -(sum_div_final_amount - final_amount_d),final_amount_d),  
    if(rn=1,feight_fee - (sum_div_feight_fee - feight_fee_d),feight_fee_d),  
    if(rn=1,benefit_reduce_amount - (sum_div_benefit_reduce_amount -  
benefit_reduce_amount_d), benefit_reduce_amount_d)  
from  
(  
    select  
        od.id,  
        od.order_id,  
        od.user_id,  
        od.sku_id,  
        od.sku_name,  
        od.order_price,  
        od.sku_num,  
        od.create_time,  
        oi.province_id,  
        od.source_type,  
        od.source_id,  
        round(od.order_price*od.sku_num,2) original_amount_d,  
  
        round(od.order_price*od.sku_num/oi.original_total_amount*oi.final_total_amount,2)  
        final_amount_d,  
        round(od.order_price*od.sku_num/oi.original_total_amount*oi.feight_fee,2)  
        feight_fee_d,  
  
        round(od.order_price*od.sku_num/oi.original_total_amount*oi.benefit_reduce_amount,2)  
        benefit_reduce_amount_d,  
        row_number() over(partition by od.order_id order by od.id desc) rn,  
        oi.final_total_amount,  
        oi.feight_fee,  
        oi.benefit_reduce_amount,  
  
        sum(round(od.order_price*od.sku_num/oi.original_total_amount*oi.final_total_amount,2))  
        over(partition by od.order_id) sum_div_final_amount,  
        sum(round(od.order_price*od.sku_num/oi.original_total_amount*oi.feight_fee,2))  
        over(partition by od.order_id) sum_div_feight_fee,  
  
        sum(round(od.order_price*od.sku_num/oi.original_total_amount*oi.benefit_reduce_amount,  
2)) over(partition by od.order_id) sum_div_benefit_reduce_amount
```

```
from
(
    select * from ods_order_detail where dt='2020-06-14'
) od
join
(
    select * from ods_order_info where dt='2020-06-14'
) oi
on od.order_id=oi.id
)tl;
```

3) 查询加载结果

```
hive (gmall)> select * from dwd_fact_order_detail where dt='2020-06-14' limit 2;
```

4.4.10 加购事实表（周期型快照事实表，每日快照）

由于购物车的**数量是会发生变化**，所以导增量不合适。

每天做一次快照，导入的数据是**全量**，区别于事务型事实表是每天导入**新增**。

周期型快照事实表劣势：存储的数据量会比较大。

解决方案：周期型快照事实表存储的数据比较讲究**时效性**，时间太久了的意义不大，可以删除以前的数据。

	时间	用户	地区	商品	优惠券	活动	编码	度量值
加购	√	√		√				件数/金额

1) 建表语句

```
hive (gmall)>
drop table if exists dwd_fact_cart_info;
create external table dwd_fact_cart_info(
    `id` string COMMENT '编号',
    `user_id` string COMMENT '用户id',
    `sku_id` string COMMENT 'skuid',
    `cart_price` string COMMENT '放入购物车时价格',
    `sku_num` string COMMENT '数量',
    `sku_name` string COMMENT 'sku名称 (冗余)',
    `create_time` string COMMENT '创建时间',
    `operate_time` string COMMENT '修改时间',
    `is_ordered` string COMMENT '是否已经下单。1 为已下单;0 为未下单',
    `order_time` string COMMENT '下单时间',
    `source_type` string COMMENT '来源类型',
    `srouce_id` string COMMENT '来源编号'
) COMMENT '加购事实表'
PARTITIONED BY (`dt` string)
stored as parquet
location '/warehouse/gmall/dwd/dwd_fact_cart_info/'
tblproperties ("parquet.compression"="lzo");
```

2) 数据装载

```
hive (gmall)>
SET hive.input.format=org.apache.hadoop.hive.ql.io.HiveInputFormat;
insert overwrite table dwd_fact_cart_info partition(dt='2020-06-14')
select
    id,
    user_id,
    sku_id,
    cart_price,
    sku_num,
```

更多 [Java](#) - [大数据](#) - [前端](#) - [python](#) 人工智能资料下载，可百度访问：尚硅谷官网

```
sku_name,
create_time,
operate_time,
is_ordered,
order_time,
source_type,
source_id
from ods_cart_info
where dt='2020-06-14';
```

3) 查询加载结果

```
hive (gmall)> select * from dwd_fact_cart_info where dt='2020-06-14' limit 2;
```

4.4.11 收藏事实表（周期型快照事实表，每日快照）

收藏的标记，是否取消，会发生变化，做增量不合适。

每天做一次快照，导入的数据是**全量**，区别于事务型事实表是每天导入**新增**。

	时间	用户	地区	商品	优惠券	活动	编码	度量值
收藏	√	√		√				个数

1) 建表语句

```
hive (gmall)>
drop table if exists dwd_fact_favor_info;
create external table dwd_fact_favor_info(
  `id` string COMMENT '编号',
  `user_id` string COMMENT '用户id',
  `sku_id` string COMMENT 'skuid',
  `spu_id` string COMMENT 'spuid',
  `is_cancel` string COMMENT '是否取消',
  `create_time` string COMMENT '收藏时间',
  `cancel_time` string COMMENT '取消时间'
) COMMENT '收藏事实表'
PARTITIONED BY (`dt` string)
stored as parquet
location '/warehouse/gmall/dwd/dwd_fact_favor_info/'
tblproperties ("parquet.compression"="lzo");
```

2) 数据装载

```
hive (gmall)>
SET hive.input.format=org.apache.hadoop.hive.ql.io.HiveInputFormat;
insert overwrite table dwd_fact_favor_info partition(dt='2020-06-14')
select
  id,
  user_id,
  sku_id,
  spu_id,
  is_cancel,
  create_time,
  cancel_time
from ods_favor_info
where dt='2020-06-14';
```

3) 查询加载结果

```
hive (gmall)> select * from dwd_fact_favor_info where dt='2020-06-14' limit 2;
```

4.4.12 优惠券领用事实表（累积型快照事实表）

	时间	用户	地区	商品	优惠券	活动	编码	度量值
--	----	----	----	----	-----	----	----	-----

优惠券领用	√	√			√			个数
-------	---	---	--	--	---	--	--	----

优惠券的生命周期：领取优惠券-》用优惠券下单-》优惠券参与支付

累积型快照事实表使用：统计优惠券领取次数、优惠券下单次数、优惠券参与支付次数

1) 建表语句

```
hive (gmall)>
drop table if exists dwd_fact_coupon_use;
create external table dwd_fact_coupon_use(
  `id` string COMMENT '编号',
  `coupon_id` string COMMENT '优惠券 ID',
  `user_id` string COMMENT 'userid',
  `order_id` string COMMENT '订单 id',
  `coupon_status` string COMMENT '优惠券状态',
  `get_time` string COMMENT '领取时间',
  `using_time` string COMMENT '使用时间(下单)',
  `used_time` string COMMENT '使用时间(支付)'
) COMMENT '优惠券领用事实表'
PARTITIONED BY (`dt` string)
stored as parquet
location '/warehouse/gmall/dwd/dwd_fact_coupon_use/'
tblproperties ("parquet.compression"="lzo");
```

注意：dt 是按照优惠券领用时间 get_time 做为分区。

2) 数据装载



优惠券领用事实表



dt是按照优惠券领用时间get_time做为分区

第1天，6月12号领取优惠券用户

0 06-12 null null

第2天，6月13号领取优惠券用户

用户	领取时间	下单时间	支付时间
1	06-13	null	null
2	06-13	null	null
3	06-13	null	null
4	06-13	null	null
5	06-13	null	null

第3天，6月14号操作了优惠券用户（新增和变化）

用户	领取时间	下单时间	支付时间
0	06-12	06-14	null
5	06-13	06-14	06-14
6	06-14	null	null
7	06-14	null	null
8	06-14	null	null

if(new.id is null,old.id,new.id),
如果新数据没有，就用旧的，否则用新数据

0 06-12 null null	0 06-12 06-14 null
1 06-13 null null	1 null null null
2 06-13 null null	2 null null null
3 06-13 null null	3 null null null
4 06-13 null null	4 null null null
5 06-13 null null	5 06-13 06-14 06-14
6 null null null	6 06-14 null null
7 null null null	7 06-14 null null
8 null null null	8 06-14 null null

```
(
  select
    id,
    coupon_id,
    user_id,
    order_id,
    coupon_status,
    get_time,
    using_time,
    used_time
  from dwd_fact_coupon_use
  where dt in
    (
      select
        date_format(get_time,'yyyy-MM-dd')
      from ods_coupon_use
      where dt='2020-06-14'
    )
) old
```

full outer join

```
(
  select
    id,
    coupon_id,
    user_id,
    order_id,
    coupon_status,
    get_time,
    using_time,
    used_time
  from ods_coupon_use
  where dt='2020-06-14'
) new
```

注意：6-14分区还没创建，获取不到数据

insert overwrite table dwd_fact_coupon_use partition(dt)

06-14数据会被放入2020-06-14分区

```
hive (gmall)>
set hive.exec.dynamic.partition.mode=nonstrict;
set hive.input.format=org.apache.hadoop.hive.ql.io.HiveInputFormat;
insert overwrite table dwd_fact_coupon_use partition(dt)
select
  if(new.id is null,old.id,new.id),
  if(new.coupon_id is null,old.coupon_id,new.coupon_id),
  if(new.user_id is null,old.user_id,new.user_id),
  if(new.order_id is null,old.order_id,new.order_id),
  if(new.coupon_status is null,old.coupon_status,new.coupon_status),
  if(new.get_time is null,old.get_time,new.get_time),
  if(new.using_time is null,old.using_time,new.using_time),
  if(new.used_time is null,old.used_time,new.used_time),
```

更多 Java - 大数据 - 前端 - python 人工智能资料下载，可百度访问：尚硅谷官网

```
date_format(if(new.get_time is null,old.get_time,new.get_time),'yyyy-MM-dd')
from
(
    select
        id,
        coupon_id,
        user_id,
        order_id,
        coupon_status,
        get_time,
        using_time,
        used_time
    from dwd_fact_coupon_use
    where dt in
    (
        select
            date_format(get_time,'yyyy-MM-dd')
        from ods_coupon_use
        where dt='2020-06-14'
    )
)old
full outer join
(
    select
        id,
        coupon_id,
        user_id,
        order_id,
        coupon_status,
        get_time,
        using_time,
        used_time
    from ods_coupon_use
    where dt='2020-06-14'
)new
on old.id=new.id;
```

3) 查询加载结果

```
hive (gmall)> select * from dwd_fact_coupon_use where dt='2020-06-14' limit 2;
```

4.4.13 系统函数 (concat、concat_ws、collect_set、STR_TO_MAP)

1) concat 函数

concat 函数在连接字符串的时候，只要其中一个是 NULL，那么将返回 NULL

```
hive> select concat('a','b');
ab

hive> select concat('a','b',null);
NULL
```

2) concat_ws 函数

concat_ws 函数在连接字符串的时候，只要有一个字符串不是 NULL，就不会返回 NULL。

concat_ws 函数需要指定分隔符。

```
hive> select concat_ws('-', 'a', 'b');
a-b

hive> select concat_ws('-', 'a', 'b', null);
a-b
```

```
hive> select concat_ws('','a','b',null);
ab
```

3) collect_set 函数

(1) 创建原数据表

```
hive (gmall)>
drop table if exists stud;
create table stud (name string, area string, course string,
score int);
```

(2) 向原数据表中插入数据

```
hive (gmall)>
insert into table stud values('zhang3','bj','math',88);
insert into table stud values('li4','bj','math',99);
insert into table stud values('wang5','sh','chinese',92);
insert into table stud values('zhao6','sh','chinese',54);
insert into table stud values('tian7','bj','chinese',91);
```

(3) 查询表中数据

```
hive (gmall)> select * from stud;
stud.name      stud.area      stud.course      stud.score
zhang3 bj      math      88
li4 bj      math      99
wang5 sh      chinese 92
zhao6 sh      chinese 54
tian7 bj      chinese 91
```

(4) 把同一分组的不同行的数据聚合成一个集合

```
hive (gmall)> select course, collect_set(area), avg(score) from
stud group by course;
chinese ["sh","bj"]      79.0
math ["bj"] 93.5
```

(5) 用下标可以取某一个

```
hive (gmall)> select course, collect_set(area)[0], avg(score)
from stud group by course;
chinese sh      79.0
math bj      93.5
```

3) STR_TO_MAP 函数

(1) 语法描述

STR_TO_MAP(VARCHAR **text**, VARCHAR **listDelimiter**, VARCHAR **keyValueDelimiter**)

(2) 功能描述

使用 listDelimiter 将 text 分隔成 K-V 对, 然后使用 keyValueDelimiter 分隔每个 K-V 对, 组装成 MAP 返回。默认 listDelimiter 为 (,), keyValueDelimiter 为 (=)。

(3) 案例

```
str_to_map('1001=2020-06-14,1002=2020-06-14', ', ', '=')
输出
{"1001":"2020-06-14","1002":"2020-06-14"}
```

4.4.14 订单事实表（累积型快照事实表）

	时间	用户	地区	商品	优惠券	活动	编码	度量值
订单	√	√	√			√		件数/金额

订单生命周期：创建时间=》支付时间=》取消时间=》完成时间=》退款时间=》退款完成时间。

由于 ODS 层订单表只有创建时间和操作时间两个状态，不能表达所有时间含义，所以需要关联订单状态表。订单事实表里面增加了活动 id，所以需要关联活动订单表。

1) 建表语句

```
hive (gmall)>
drop table if exists dwd_fact_order_info;
create external table dwd_fact_order_info (
  `id` string COMMENT '订单编号',
  `order_status` string COMMENT '订单状态',
  `user_id` string COMMENT '用户 id',
  `out_trade_no` string COMMENT '支付流水号',
  `create_time` string COMMENT '创建时间(未支付状态)',
  `payment_time` string COMMENT '支付时间(已支付状态)',
  `cancel_time` string COMMENT '取消时间(已取消状态)',
  `finish_time` string COMMENT '完成时间(已完成状态)',
  `refund_time` string COMMENT '退款时间(退款中状态)',
  `refund_finish_time` string COMMENT '退款完成时间(退款完成状态)',
  `province_id` string COMMENT '省份 ID',
  `activity_id` string COMMENT '活动 ID',
  `original_total_amount` decimal(16,2) COMMENT '原价金额',
  `benefit_reduce_amount` decimal(16,2) COMMENT '优惠金额',
  `freight_fee` decimal(16,2) COMMENT '运费',
  `final_total_amount` decimal(16,2) COMMENT '订单金额'
) COMMENT '订单事实表'
PARTITIONED BY (`dt` string)
stored as parquet
location '/warehouse/gmall/dwd/dwd_fact_order_info/'
tblproperties ("parquet.compression"="lzo");
```

2) 数据装载

订单事实表

```
hive (gmall)>
set hive.exec.dynamic.partition.mode=nonstrict;
insert overwrite table dwd_fact_order_info partition(dt)
select
  if(new.id is null,old.id,new.id),
  if(new.order_status is null,old.order_status,new.order_status),
  if(new.user_id is null,old.user_id,new.user_id),
  if(new.out_trade_no is null,old.out_trade_no,new.out_trade_no),
  if(new.tms[1001] is null,old.create_time,new.tms[1001]),--1001对应未支付状态
  if(new.tms[1002] is null,old.payment_time,new.tms[1002]),
  if(new.tms[1003] is null,old.cancel_time,new.tms[1003]),
  if(new.tms[1004] is null,old.finish_time,new.tms[1004]),
  if(new.tms[1005] is null,old.refund_time,new.tms[1005]),
  if(new.tms[1006] is null,old.refund_finish_time,new.tms[1006]),
  if(new.province_id is null,old.province_id,new.province_id),
  if(new.activity_id is null,old.activity_id,new.activity_id),
  if(new.original_total_amount is null,old.original_total_amount,new.original_total_amount),
  if(new.benefit_reduce_amount is
null,old.benefit_reduce_amount,new.benefit_reduce_amount),
  if(new.feight_fee is null,old.feight_fee,new.feight_fee),
  if(new.final_total_amount is null,old.final_total_amount,new.final_total_amount),
  date_format(if(new.tms[1001] is null,old.create_time,new.tms[1001]),'yyyy-MM-dd')
from (
  select
    *
  from dwd_fact_order_info
  where dt
  in (
    select
      date_format(create_time,'%Y-%m-%d')
    from ods_order_info
    where dt='2020-06-14'
  )
)old
```

06-12
06-13
06-14
获取今天新增和变化数据，所对应的分区

```
full outer join
(
  select
    info.id,
    info.order_status,
    info.user_id,
    info.out_trade_no,
    info.province_id,
    act.activity_id,
    log.tms,
    info.original_total_amount,
    info.benefit_reduce_amount,
    info.feight_fee,
    info.final_total_amount
  from
    (
      select
        order_id,
        str_to_map(concat_ws(',',collect_set(concat(order_status,'=',operate_time)))),'='
      tms
      from ods_order_status_log
      where dt='2020-06-14'
      group by order_id
    )log
  join (
    select * from ods_order_info where dt='2020-06-14'
  )info on log.order_id=info.id
  left join (
    select * from ods_activity_order where dt='2020-06-14'
  )act on log.order_id=act.order_id
  )new
on old.id=new.id;
```

3210 1001=2020-06-14 00:00:00.0
3210 1002=2020-06-14 00:00:00.0
3210 1005=2020-06-14 00:00:00.0

↓

3210 {"1001":"2020-06-14 00:00:00.0","1002":"2020-06-14 00:00:00.0","1005":"2020-06-14 00:00:00.0"}

将订单状态表中多条数据转换为为一行map

获取除了时间和活动id之外的信息

获取活动id

让天下没有难学的技术

3) 常用函数

```
hive (gmall)> select order_id, concat(order_status,'=', operate_time) from
ods_order_status_log where dt='2020-06-14';
```

```
3210 1001=2020-06-14 00:00:00.0
3211 1001=2020-06-14 00:00:00.0
3212 1001=2020-06-14 00:00:00.0
3210 1002=2020-06-14 00:00:00.0
3211 1002=2020-06-14 00:00:00.0
3212 1002=2020-06-14 00:00:00.0
3210 1005=2020-06-14 00:00:00.0
3211 1004=2020-06-14 00:00:00.0
3212 1004=2020-06-14 00:00:00.0
```

```
hive (gmall)> select order_id, collect_set(concat(order_status,'=',operate_time)) from
ods_order_status_log where dt='2020-06-14' group by order_id;
```

```
3210 ["1001=2020-06-14 00:00:00.0","1002=2020-06-14 00:00:00.0","1005=2020-06-14 00:00:00.0"]
3211 ["1001=2020-06-14 00:00:00.0","1002=2020-06-14 00:00:00.0","1004=2020-06-14 00:00:00.0"]
3212 ["1001=2020-06-14 00:00:00.0","1002=2020-06-14 00:00:00.0","1004=2020-06-14 00:00:00.0"]
```

```
hive (gmall)>
select order_id, concat_ws(',', collect_set(concat(order_status,'=',operate_time)))
from ods_order_status_log where dt='2020-06-14' group by order_id;
```

```
3210 1001=2020-06-14 00:00:00.0,1002=2020-06-14 00:00:00.0,1005=2020-06-14 00:00:00.0
3211 1001=2020-06-14 00:00:00.0,1002=2020-06-14 00:00:00.0,1004=2020-06-14 00:00:00.0
3212 1001=2020-06-14 00:00:00.0,1002=2020-06-14 00:00:00.0,1004=2020-06-14 00:00:00.0
```

```
hive (gmall)>
select
  order_id,
  str_to_map(concat_ws(',',collect_set(concat(order_status,'=',operate_time))), ',',
  '=') from ods_order_status_log where dt='2020-06-14' group by order_id;
```

```
3210 {"1001":"2020-06-14 00:00:00.0","1002":"2020-06-14 00:00:00.0","1005":"2020-06-14 00:00:00.0"}
3211 {"1001":"2020-06-14 00:00:00.0","1002":"2020-06-14 00:00:00.0","1004":"2020-06-14 00:00:00.0"}
3212 {"1001":"2020-06-14 00:00:00.0","1002":"2020-06-14 00:00:00.0","1004":"2020-06-14 00:00:00.0"}
```

更多 [Java](#) - [大数据](#) - [前端](#) - [python](#) 人工智能资料下载，可百度访问：尚硅谷官网

4) 数据装载

```
hive (gmall)>
set hive.exec.dynamic.partition.mode=nonstrict;
set hive.input.format=org.apache.hadoop.hive.ql.io.HiveInputFormat;
insert overwrite table dwd_fact_order_info partition(dt)
select
    if(new.id is null,old.id,new.id),
    if(new.order_status is null,old.order_status,new.order_status),
    if(new.user_id is null,old.user_id,new.user_id),
    if(new.out_trade_no is null,old.out_trade_no,new.out_trade_no),
    if(new.tms['1001'] is null,old.create_time,new.tms['1001']),--1001 对应未支付状态
    if(new.tms['1002'] is null,old.payment_time,new.tms['1002']),
    if(new.tms['1003'] is null,old.cancel_time,new.tms['1003']),
    if(new.tms['1004'] is null,old.finish_time,new.tms['1004']),
    if(new.tms['1005'] is null,old.refund_time,new.tms['1005']),
    if(new.tms['1006'] is null,old.refund_finish_time,new.tms['1006']),
    if(new.province_id is null,old.province_id,new.province_id),
    if(new.activity_id is null,old.activity_id,new.activity_id),
    if(new.original_total_amount is null,old.original_total_amount,new.original_total_amount),
    if(new.benefit_reduce_amount is null,old.benefit_reduce_amount,new.benefit_reduce_amount),
    if(new.feight_fee is null,old.feight_fee,new.feight_fee),
    if(new.final_total_amount is null,old.final_total_amount,new.final_total_amount),
    date_format(if(new.tms['1001'] is null,old.create_time,new.tms['1001']),'yyyy-MM-dd')
from
(
    select
        id,
        order_status,
        user_id,
        out_trade_no,
        create_time,
        payment_time,
        cancel_time,
        finish_time,
        refund_time,
        refund_finish_time,
        province_id,
        activity_id,
        original_total_amount,
        benefit_reduce_amount,
        feight_fee,
        final_total_amount
    from dwd_fact_order_info
    where dt
    in
    (
        select
            date_format(create_time,'yyyy-MM-dd')
        from ods_order_info
        where dt='2020-06-14'
    )
)old
full outer join
(
    select
        info.id,
        info.order_status,
        info.user_id,
```

```
        info.out_trade_no,
        info.province_id,
        act.activity_id,
        log.tms,
        info.original_total_amount,
        info.benefit_reduce_amount,
        info.feight_fee,
        info.final_total_amount
    from
    (
        select
            order_id,

str_to_map(concat_ws(',',collect_set(concat(order_status,'=',operate_time))),',','=')
tms
        from ods_order_status_log
        where dt='2020-06-14'
        group by order_id
    )log
    join
    (
        select * from ods_order_info where dt='2020-06-14'
    )info
    on log.order_id=info.id
    left join
    (
        select * from ods_activity_order where dt='2020-06-14'
    )act
    on log.order_id=act.order_id
    )new
    on old.id=new.id;
```

5) 查询加载结果

```
hive (gmall)> select * from dwd_fact_order_info where dt='2020-06-14' limit 2;
```

4.4.15 用户维度表（拉链表）

用户表中的数据每日既有可能新增，也有可能修改，但修改频率并不高，属于缓慢变化维度，此处采用拉链表存储用户维度数据。

1) 什么是拉链表

什么是拉链表

拉链表，记录每条信息的生命周期，一旦一条记录的生命周期结束，就重新开始一条新的记录，并把当前日期放入生效开始日期。

如果当前信息至今有效，在生效结束日期中填入一个极大值（如9999-99-99）。

用户ID	姓名	手机号码	开始日期	结束日期
1	张三	136****9090	2019-01-01	2019-01-01
1	张三	137****8989	2019-01-02	2019-01-09
1	张三	147****1234	2019-01-10	9999-99-99

让天下没有难学的技术

2) 为什么要做拉链表

为什么要做拉链表

拉链表适合于：数据会发生变化，但是大部分是不变的。（即：缓慢变化维）

比如：用户信息会发生变化，但是每天变化的比例不高。如果数据量有一定规模，按照每日全量的方式保存效率很低。比如：1亿用户*365天，每天一份用户信息。（做每日全量效率低）

用户ID	姓名	手机号码	开始日期	结束日期
1	张三	136****9090	2019-01-01	2019-01-01
1	张三	137****8989	2019-01-02	2019-01-09
1	张三	147****1234	2019-01-10	9999-99-99

让天下没有难学的技术

如何使用拉链表

通过，生效开始日期<=某个日期 且 生效结束日期>=某个日期，能够得到某个时间点的数据全量切片。

1) 拉链表数据

用户ID	姓名	开始时间	结束时间
1	张三	2019-01-01	9999-99-99
2	李四	2019-01-01	2019-01-02
2	李小四	2019-01-03	9999-99-99
3	王五	2019-01-01	9999-99-99
4	赵六	2019-01-02	9999-99-99

2) 例如获取2019-01-01的历史切片：select * from user_info where start_date<='2019-01-01' and end_date>='2019-01-01'

用户ID	姓名	开始时间	结束时间
1	张三	2019-01-01	9999-99-99
2	李四	2019-01-01	2019-01-02
3	王五	2019-01-01	9999-99-99

3) 例如获取2019-01-02的历史切片：select * from order_info where start_date<='2019-01-02' and end_date>='2019-01-02'

用户ID	姓名	开始时间	结束时间
1	张三	2019-01-01	9999-99-99
2	李四	2019-01-01	2019-01-02
3	王五	2019-01-01	9999-99-99
4	赵六	2019-01-02	9999-99-99

让天下没有难学的技术

3) 拉链表形成过程

拉链表形成过程

1) 假设，2019年1月1日的用户全量表是最初始的用户表，如下

用户ID	姓名
1	张三
2	李四
3	王五

2) 初始的拉链表就等于最开始的2019年1月1日的用户全量表

用户ID	姓名	开始时间	结束时间
1	张三	2019-01-01	9999-99-99
2	李四	2019-01-01	9999-99-99
3	王五	2019-01-01	9999-99-99

3) 第二天1月2日 用户全量表 (用户2发生状态修改；用户4、5增加)

用户ID	姓名
1	张三
2	李小四
3	王五
4	赵六
5	田七

5) 用户变化表与之前的拉链表合并得到

用户ID	姓名	开始时间	结束时间
1	张三	2019-01-01	9999-99-99
2	李四	2019-01-01	2019-01-01
2	李小四	2019-01-02	9999-99-99
3	王五	2019-01-01	9999-99-99
4	赵六	2019-01-02	9999-99-99
5	田七	2019-01-02	9999-99-99


4) 根据用户表的创建时间和操作时间，得到用户变化表。

用户ID	姓名
2	李小四
4	赵六
5	田七

4) 拉链表制作过程图

拉链表制作流程图

用户当日全部数据和MySQL
中每天变化的数据拼接在一起，
形成一个新的临时拉链表数据。
用临时的拉链表覆盖旧的拉链表
数据。（这就解决了hive表中数
据不能更新的问题）



让天下没有难学的技术

5) 拉链表制作过程

步骤 0：初始化拉链表（首次独立执行）

(1) 建立拉链表

```

hive (gmall)>
drop table if exists dwd_dim_user_info_his;
create external table dwd_dim_user_info_his(
    `id` string COMMENT '用户 id',
    `name` string COMMENT '姓名',
    `birthday` string COMMENT '生日',
    `gender` string COMMENT '性别',
    `email` string COMMENT '邮箱',
    `user_level` string COMMENT '用户等级',
    `create_time` string COMMENT '创建时间',
    `operate_time` string COMMENT '操作时间',
    `start_date` string COMMENT '有效开始日期',
    `end_date` string COMMENT '有效结束日期'
) COMMENT '用户拉链表'
stored as parquet
location '/warehouse/gmall/dwd/dwd_dim_user_info_his/'
tblproperties ("parquet.compression"="lzo");
    
```

(2) 初始化拉链表

```

hive (gmall)>
SET hive.input.format=org.apache.hadoop.hive ql.io.HiveInputFormat;
insert overwrite table dwd_dim_user_info_his
select
    id,
    name,
    birthday,
    gender,
    email,
    user_level,
    create_time,
    operate_time,
    '2020-06-14',
    '9999-99-99'
from ods_user_info oi
    
```

```
where oi.dt='2020-06-14';
```

步骤 1：制作当日变动数据（包括新增，修改）每日执行

(1) 如何获得每日变动表

a.最好表内有创建时间和变动时间（Lucky!）

b.如果没有，可以利用第三方工具监控比如 canal，监控 MySQL 的实时变化进行记录（麻烦）。

c.逐行对比前后两天的数据，检查 md5(concat(全部有可能变化的字段))是否相同(low)

d.要求业务数据库提供变动流水（人品，颜值）

(2) 因为 ods_user_info 本身导入过来就是新增变动明细的表，所以不用处理

a) 数据库中新增 2020-06-15 一天的数据

b) 通过 Sqoop 把 2020-06-15 日所有数据导入

```
mysql_to_hdfs.sh all 2020-06-15
```

c) ods 层数据导入

```
hdfs_to_ods_db.sh all 2020-06-15
```

步骤 2：先合并变动信息，再追加新增信息，插入到临时表中

1) 建立临时表

```
hive (gmall)>
drop table if exists dwd_dim_user_info_his_tmp;
create external table dwd_dim_user_info_his_tmp(
  `id` string COMMENT '用户id',
  `name` string COMMENT '姓名',
  `birthday` string COMMENT '生日',
  `gender` string COMMENT '性别',
  `email` string COMMENT '邮箱',
  `user_level` string COMMENT '用户等级',
  `create_time` string COMMENT '创建时间',
  `operate_time` string COMMENT '操作时间',
  `start_date` string COMMENT '有效开始日期',
  `end_date` string COMMENT '有效结束日期'
) COMMENT '订单拉链临时表'
stored as parquet
location '/warehouse/gmall/dwd/dwd_dim_user_info_his_tmp/'
tblproperties ("parquet.compression"="lzo");
```

2) 导入脚本

1) 初始的拉链表 (dwd_dim_user_info_his) 2019-01-01

用户ID	姓名	开始时间	结束时间
1	张三	2019-01-01	9999-99-99
2	李四	2019-01-01	9999-99-99
3	王五	2019-01-01	9999-99-99

2) 用户变化表 (ods_user_info) 2019-01-02

用户ID	姓名
1	张三
2	李小四
3	王五
4	赵六
5	田七

3) 临时拉链表 (dwd_dim_user_info_his_tmp) 2019-01-02

用户ID	姓名	开始时间	结束时间
1	张三	2019-01-01	9999-99-99
2	李四	2019-01-01	2019-01-01
2	李小四	2019-01-02	9999-99-99
3	王五	2019-01-01	9999-99-99
4	赵六	2019-01-02	9999-99-99
5	田七	2019-01-02	9999-99-99

```
insert overwrite table dwd_dim_user_info_his_tmp
select * from (
  select
    id,
    name,
    birthday,
    gender,
    email,
    user_level,
    create_time,
    operate_time,
    '2020-06-15' start_date,
    '9999-99-99' end_date
  from ods_user_info where dt='2020-06-15'

  union all
  select
    uh.id,
    uh.name,
    uh.birthday,
    uh.gender,
    uh.email,
    uh.user_level,
    uh.create_time,
    uh.operate_time,
    uh.start_date,
    if(ui.id is not null and uh.end_date='9999-99-99', date_add(ui.dt,-1),
    uh.end_date) end_date
  from dwd_dim_user_info_his uh left join
  (
    select * from ods_user_info
    where dt='2020-06-15'
  ) ui on uh.id=ui.id
)his order by his.id, start_date;
```

```
hive (gmall)>
SET hive.input.format=org.apache.hadoop.hive ql.io.HiveInputFormat;
insert overwrite table dwd_dim_user_info_his_tmp
select * from
(
  select
    id,
    name,
    birthday,
    gender,
    email,
    user_level,
    create_time,
    operate_time,
    '2020-06-15' start_date,
    '9999-99-99' end_date
  from ods_user_info where dt='2020-06-15'

  union all
  select
    uh.id,
    uh.name,
    uh.birthday,
    uh.gender,
    uh.email,
    uh.user_level,
    uh.create_time,
    uh.operate_time,
    uh.start_date,
    if(ui.id is not null and uh.end_date='9999-99-99', date_add(ui.dt,-1),
    uh.end_date) end_date
  from dwd_dim_user_info_his uh left join
  (
    select
      *
    from ods_user_info
    where dt='2020-06-15'
  ) ui on uh.id=ui.id
)his
order by his.id, start_date;
```

步骤 3: 把临时表覆盖给拉链表

更多 [Java](#) - [大数据](#) - [前端](#) - [python](#) 人工智能资料下载, 可百度访问: [尚硅谷官网](#)

1) 导入数据

```
hive (gmall)>
insert overwrite table dwd_dim_user_info_his
select * from dwd_dim_user_info_his_tmp;
```

2) 查询导入数据

```
hive (gmall)>
select id, start_date, end_date from dwd_dim_user_info_his limit 2;
```

4.4.16 DWD 层业务数据导入脚本

1.编写脚本

1) 在/home/atguigu/bin 目录下创建脚本 ods_to_dwd_db.sh

```
[atguigu@hadoop102 bin]$ vim ods_to_dwd_db.sh
```

在脚本中填写如下内容

```
#!/bin/bash

APP=gmall
hive=/opt/module/hive/bin/hive

# 如果是输入的日期按照取输入日期；如果没输入日期取当前时间的前一天
if [ -n "$2" ] ;then
    do_date=$2
else
    do_date=`date -d "-1 day" +%F`
fi

sql1="
set mapreduce.job.queueName=hive;
set hive.exec.dynamic.partition.mode=nonstrict;
SET hive.input.format=org.apache.hadoop.hive.ql.io.HiveInputFormat;

insert overwrite table ${APP}.dwd_dim_sku_info partition(dt='${do_date}')
select
    sku.id,
    sku.spu_id,
    sku.price,
    sku.sku_name,
    sku.sku_desc,
    sku.weight,
    sku.tm_id,
    ob.tm name,
    sku.category3_id,
    c2.id category2_id,
    c1.id category1_id,
    c3.name category3_name,
    c2.name category2_name,
    c1.name category1_name,
    spu.spu_name,
    sku.create_time
from
(
    select * from ${APP}.ods_sku_info where dt='${do_date}'
)sku
join
(
    select * from ${APP}.ods_base_trademark where dt='${do_date}'
)ob on sku.tm_id=ob.tm_id
```

```
join
(
    select * from ${APP}.ods_spu_info where dt='$do_date'
)spu on spu.id = sku.spu_id
join
(
    select * from ${APP}.ods_base_category3 where dt='$do_date'
)c3 on sku.category3_id=c3.id
join
(
    select * from ${APP}.ods_base_category2 where dt='$do_date'
)c2 on c3.category2_id=c2.id
join
(
    select * from ${APP}.ods_base_category1 where dt='$do_date'
)c1 on c2.category1_id=c1.id;

insert overwrite table ${APP}.dwd_dim_coupon_info partition(dt='$do_date')
select
    id,
    coupon_name,
    coupon_type,
    condition_amount,
    condition_num,
    activity_id,
    benefit_amount,
    benefit_discount,
    create_time,
    range_type,
    spu_id,
    tm_id,
    category3_id,
    limit_num,
    operate_time,
    expire_time
from ${APP}.ods_coupon_info
where dt='$do_date';

insert overwrite table ${APP}.dwd_dim_activity_info partition(dt='$do_date')
select
    id,
    activity_name,
    activity_type,
    start_time,
    end_time,
    create_time
from ${APP}.ods_activity_info
where dt='$do_date';

insert overwrite table ${APP}.dwd_fact_order_detail partition(dt='$do_date')
select
    id,
    order_id,
    user_id,
    sku_id,
    sku_num,
    order_price,
    sku_num,
    create_time,
    province_id,
    source_type,
```

```
source_id,
original_amount_d,
if(rn=1,final_total_amount-(sum_div_final_amount-
final_amount_d),final_amount_d),
if(rn=1,feight_fee-(sum_div_feight_fee-feight_fee_d),feight_fee_d),
if(rn=1,benefit_reduce_amount-(sum_div_benefit_reduce_amount-
benefit_reduce_amount_d),benefit_reduce_amount_d)
from
(
select
od.id,
od.order_id,
od.user_id,
od.sku_id,
od.sku_name,
od.order_price,
od.sku_num,
od.create_time,
oi.province_id,
od.source_type,
od.source_id,
round(od.order_price*od.sku_num,2) original_amount_d,

round(od.order_price*od.sku_num/oi.original_total_amount*oi.final_total_amount,2)
final_amount_d,
round(od.order_price*od.sku_num/oi.original_total_amount*oi.feight_fee,2)
feight_fee_d,

round(od.order_price*od.sku_num/oi.original_total_amount*oi.benefit_reduce_amount,
2) benefit_reduce_amount_d,
row_number() over(partition by od.order_id order by od.id desc) rn,
oi.final_total_amount,
oi.feight_fee,
oi.benefit_reduce_amount,

sum(round(od.order_price*od.sku_num/oi.original_total_amount*oi.final_total_amount
,2)) over(partition by od.order_id) sum_div_final_amount,

sum(round(od.order_price*od.sku_num/oi.original_total_amount*oi.feight_fee,2))
over(partition by od.order_id) sum_div_feight_fee,

sum(round(od.order_price*od.sku_num/oi.original_total_amount*oi.benefit_reduce_amo
unt,2)) over(partition by od.order_id) sum_div_benefit_reduce_amount
from
(
select * from ${APP}.ods_order_detail where dt='${do_date}'
) od
join
(
select * from ${APP}.ods_order_info where dt='${do_date}'
) oi
on od.order_id=oi.id
) t1;

insert overwrite table ${APP}.dwd_fact_payment_info partition(dt='${do_date}')
select
pi.id,
pi.out_trade_no,
pi.order_id,
pi.user_id,
pi.alipay_trade_no,
pi.total_amount,
pi.subject,
```

```
    pi.payment_type,
    pi.payment_time,
    oi.province_id
from
(
    select * from ${APP}.ods_payment_info where dt='${do_date}'
)pi
join
(
    select id, province_id from ${APP}.ods_order_info where dt='${do_date}'
)oi
on pi.order_id = oi.id;

insert overwrite table ${APP}.dwd_fact_order_refund_info partition(dt='${do_date}')
select
    id,
    user_id,
    order_id,
    sku_id,
    refund_type,
    refund_num,
    refund_amount,
    refund_reason_type,
    create_time
from ${APP}.ods_order_refund_info
where dt='${do_date}';

insert overwrite table ${APP}.dwd_fact_comment_info partition(dt='${do_date}')
select
    id,
    user_id,
    sku_id,
    spu_id,
    order_id,
    appraise,
    create_time
from ${APP}.ods_comment_info
where dt='${do_date}';

insert overwrite table ${APP}.dwd_fact_cart_info partition(dt='${do_date}')
select
    id,
    user_id,
    sku_id,
    cart_price,
    sku_num,
    sku_name,
    create_time,
    operate_time,
    is_ordered,
    order_time,
    source_type,
    source_id
from ${APP}.ods_cart_info
where dt='${do_date}';

insert overwrite table ${APP}.dwd_fact_favor_info partition(dt='${do_date}')
select
    id,
```

```
user_id,
sku_id,
spu_id,
is_cancel,
create_time,
cancel_time
from ${APP}.ods_favor_info
where dt='${do_date}';

insert overwrite table ${APP}.dwd_fact_coupon_use partition(dt)
select
    if(new.id is null,old.id,new.id),
    if(new.coupon_id is null,old.coupon_id,new.coupon_id),
    if(new.user_id is null,old.user_id,new.user_id),
    if(new.order_id is null,old.order_id,new.order_id),
    if(new.coupon_status is null,old.coupon_status,new.coupon_status),
    if(new.get_time is null,old.get_time,new.get_time),
    if(new.using_time is null,old.using_time,new.using_time),
    if(new.used_time is null,old.used_time,new.used_time),
    date_format(if(new.get_time is null,old.get_time,new.get_time),'yyyy-MM-dd')
from
(
    select
        id,
        coupon_id,
        user_id,
        order_id,
        coupon_status,
        get_time,
        using_time,
        used_time
    from ${APP}.dwd_fact_coupon_use
    where dt in
    (
        select
            date_format(get_time,'yyyy-MM-dd')
        from ${APP}.ods_coupon_use
        where dt='${do_date}'
    )
)old
full outer join
(
    select
        id,
        coupon_id,
        user_id,
        order_id,
        coupon_status,
        get_time,
        using_time,
        used_time
    from ${APP}.ods_coupon_use
    where dt='${do_date}'
)new
on old.id=new.id;

insert overwrite table ${APP}.dwd_fact_order_info partition(dt)
select
    if(new.id is null,old.id,new.id),
    if(new.order_status is null,old.order_status,new.order_status),
    if(new.user_id is null,old.user_id,new.user_id),
    if(new.out_trade_no is null,old.out_trade_no,new.out_trade_no),
```

```
if(new.tms['1001'] is null,old.create_time,new.tms['1001']),--1001 对应未支付状态
if(new.tms['1002'] is null,old.payment_time,new.tms['1002']),
if(new.tms['1003'] is null,old.cancel_time,new.tms['1003']),
if(new.tms['1004'] is null,old.finish_time,new.tms['1004']),
if(new.tms['1005'] is null,old.refund_time,new.tms['1005']),
if(new.tms['1006'] is null,old.refund_finish_time,new.tms['1006']),
if(new.province_id is null,old.province_id,new.province_id),
if(new.activity_id is null,old.activity_id,new.activity_id),
if(new.original_total_amount is null,old.original_total_amount,new.original_total_amount),
if(new.benefit_reduce_amount is null,old.benefit_reduce_amount,new.benefit_reduce_amount),
if(new.feight_fee is null,old.feight_fee,new.feight_fee),
if(new.final_total_amount is null,old.final_total_amount,new.final_total_amount),
date_format(if(new.tms['1001'] is null,old.create_time,new.tms['1001']),'yyyy-MM-dd')
from
(
    select
        id,
        order_status,
        user_id,
        out_trade_no,
        create_time,
        payment_time,
        cancel_time,
        finish_time,
        refund_time,
        refund_finish_time,
        province_id,
        activity_id,
        original_total_amount,
        benefit_reduce_amount,
        feight_fee,
        final_total_amount
    from ${APP}.dwd_fact_order_info
    where dt
    in
    (
        select
            date_format(create_time,'yyyy-MM-dd')
        from ${APP}.ods_order_info
        where dt='${do_date}'
    )
)old
full outer join
(
    select
        info.id,
        info.order_status,
        info.user_id,
        info.out_trade_no,
        info.province_id,
        act.activity_id,
        log.tms,
        info.original_total_amount,
        info.benefit_reduce_amount,
        info.feight_fee,
        info.final_total_amount
    from
    (
        select
```

```
        order_id,

str_to_map(concat_ws(',',collect_set(concat(order_status, '=',operate_time))),',',') tms
    from ${APP}.ods_order_status_log
    where dt='$do_date'
    group by order_id
)log
join
(
    select * from ${APP}.ods_order_info where dt='$do_date'
)info
on log.order_id=info.id
left join
(
    select * from ${APP}.ods_activity_order where dt='$do_date'
)act
on log.order_id=act.order_id
)new
on old.id=new.id;
"

sql2="
insert overwrite table ${APP}.dwd_dim_base_province
select
    bp.id,
    bp.name,
    bp.area_code,
    bp.iso_code,
    bp.region_id,
    br.region_name
from ${APP}.ods_base_province bp
join ${APP}.ods_base_region br
on bp.region_id=br.id;
"

sql3="
insert overwrite table ${APP}.dwd_dim_user_info_his_tmp
select * from
(
    select
        id,
        name,
        birthday,
        gender,
        email,
        user_level,
        create_time,
        operate_time,
        '$do_date' start_date,
        '9999-99-99' end_date
    from ${APP}.ods_user_info where dt='$do_date'

    union all
    select
        uh.id,
        uh.name,
        uh.birthday,
        uh.gender,
        uh.email,
        uh.user_level,
        uh.create_time,
        uh.operate_time,
```

```
uh.start_date,
    if(ui.id is not null and uh.end_date='9999-99-99', date_add(ui.dt,-1),
uh.end_date) end_date
from ${APP}.dwd_dim_user_info_his uh left join
(
    select
        *
        from ${APP}.ods_user_info
        where dt='${do_date}'
    ) ui on uh.id=ui.id
)his
order by his.id, start_date;

insert overwrite table ${APP}.dwd_dim_user_info_his
select * from ${APP}.dwd_dim_user_info_his_tmp;
"

case $1 in
"first"){
    $hive -e "$sql1$sql2"
};;
"all"){
    $hive -e "$sql1$sql3"
};;
esac
```

2) 增加脚本执行权限

```
[atguigu@hadoop102 bin]$ chmod 777 ods_to_dwd_db.sh
```

2.脚本使用说明

1) 初次导入

(1) 时间维度表

参照 4.4.5 节数据装载

(2) 用户维度表

参照 4.4.15 节拉链表初始化

(3) 其余表

初次导入时，脚本的第一个参数应为 first，线上环境不传第二个参数，自动获取前一天日期。

```
[atguigu@hadoop102 bin]$ ods_to_dwd_db.sh first 2020-06-14
```

2) 每日定时导入

每日定时导入，脚本的第一个参数应为 all，线上环境不传第二个参数，自动获取前一天日期。

```
[atguigu@hadoop102 bin]$ ods_to_dwd_db.sh all 2020-06-15
```

第 5 章 数仓搭建-DWS 层

5.1 业务术语

1) 用户

用户以设备为判断标准，在移动统计中，每个独立设备认为是一个独立用户。Android 系统根据 IMEI 号，IOS 系统根据 OpenUDID 来标识一个独立用户，每部手机一个用户。

2) 新增用户

首次联网使用应用的用户。如果一个用户首次打开某 APP，那这个用户定义为新增用户；卸载再安装的设备，不会被算作一次新增。新增用户包括日新增用户、周新增用户、月新增用户。

3) 活跃用户

打开应用的用户即为活跃用户，不考虑用户的使用情况。每天一台设备打开多次会被计为一个活跃用户。

4) 周（月）活跃用户

某个自然周（月）内启动过应用的用户，该周（月）内的多次启动只记一个活跃用户。

5) 月活跃率

月活跃用户与截止到该月累计的用户总和之间的比例。

6) 沉默用户

用户仅在安装当天（次日）启动一次，后续时间无再启动行为。该指标可以反映新增用户质量和用户与 APP 的匹配程度。

7) 版本分布

不同版本的周内各天新增用户数，活跃用户数和启动次数。利于判断 APP 各个版本之间的优劣和用户行为习惯。

8) 本周回流用户

上周末启动过应用，本周启动了应用的用户。

9) 连续 n 周活跃用户

连续 n 周，每周至少启动一次。

10) 忠诚用户

连续活跃 5 周以上的用户

11) 连续活跃用户

连续 2 周及以上活跃的用户

12) 近期流失用户

连续 n ($2 \leq n \leq 4$) 周没有启动应用的用户。(第 $n+1$ 周没有启动过)

13) 留存用户

某段时间内的新增用户, 经过一段时间后, 仍然使用应用的被认作是留存用户; 这部分用户占当时新增用户的比例即是留存率。

例如, 5 月份新增用户 200, 这 200 人在 6 月份启动过应用的有 100 人, 7 月份启动过应用的有 80 人, 8 月份启动过应用的有 50 人; 则 5 月份新增用户一个月后的留存率是 50%, 二个月后的留存率是 40%, 三个月后的留存率是 25%。

14) 用户新鲜度

每天启动应用的新老用户比例, 即新增用户数占活跃用户数的比例。

15) 单次使用时长

每次启动使用的时间长度。

16) 日使用时长

累计一天内的使用时间长度。

17) 启动次数计算标准

IOS 平台应用退到后台就算一次独立的启动; Android 平台我们规定, 两次启动之间的间隔小于 30 秒, 被计算一次启动。用户在使用过程中, 若因收发短信或接电话等退出应用 30 秒又再次返回应用中, 那这两次行为应该是延续而非独立的, 所以可以被算作一次使用行为, 即一次启动。业内大多使用 30 秒这个标准, 但用户还是可以自定义此时间间隔。

5.2 系统函数

5.2.1 nvl 函数

1) 基本语法

NVL (表达式 1, 表达式 2)

如果表达式 1 为空值, NVL 返回值为表达式 2 的值, 否则返回表达式 1 的值。

该函数的目的是把一个空值 (null) 转换成一个实际的值。其表达式的值可以是**数字型**、**字符型和日期型**。但是表达式 1 和表达式 2 的数据类型**必须为同一个类型**。

2) 案例实操

更多 [Java](#) - [大数据](#) - [前端](#) - [python](#) 人工智能资料下载, 可百度访问: [尚硅谷官网](#)

```
hive (gmall)> select nvl(1,0);
1
hive (gmall)> select nvl(null,"hello");
hello
```

5.2.2 日期处理函数

1) date_format 函数（根据格式整理日期）

```
hive (gmall)> select date_format('2020-06-14','yyyy-MM');
2020-06
```

2) date_add 函数（加减日期）

```
hive (gmall)> select date_add('2020-06-14',-1);
2020-06-13
hive (gmall)> select date_add('2020-06-14',1);
2020-06-15
```

3) next_day 函数

（1）取当前天的下一个周一

```
hive (gmall)> select next_day('2020-06-14','MO');
2020-06-15
```

说明：星期一到星期日的英文（Monday、Tuesday、Wednesday、Thursday、Friday、Saturday、Sunday）

（2）取当前周的周一

```
hive (gmall)> select date_add(next_day('2020-06-14','MO'),-7);
2020-06-8
```

4) last_day 函数（求当月最后一天日期）

```
hive (gmall)> select last_day('2020-06-14');
2020-06-30
```

5.2.3 复杂数据类型定义

1) map 结构数据定义

```
map<string,string>
```

2) array 结构数据定义

```
array<string>
```

3) struct 结构数据定义

```
struct<id:int,name:string,age:int>
```

4) struct 和 array 嵌套定义

```
array<struct<id:int,name:string,age:int>>
```

5.3 DWS 层

DWS 层宽表及宽表字段设计详见 2.4.3。

5.3.1 每日设备行为

每日设备行为，主要按照设备 id 统计。

1) 建表语句

```
drop table if exists dws_uv_detail_daycount;
create external table dws_uv_detail_daycount
(
  `mid_id` string COMMENT '设备id',
  `brand` string COMMENT '手机品牌',
  `model` string COMMENT '手机型号',
  `login_count` bigint COMMENT '活跃次数',
  `page_stats` array<struct<page_id:string,page_count:bigint>>
) COMMENT '页面访问统计'
) COMMENT '每日设备行为表'
partitioned by(dt string)
stored as parquet
location '/warehouse/gmall/dws/dws_uv_detail_daycount'
tblproperties ("parquet.compression"="lzo");

insert overwrite table dws_uv_detail_daycount
partition(dt='2020-06-14')
select
  nvl(tmp_start.mid_id,tmp_page.mid_id),
  nvl(tmp_start.brand,tmp_page.brand),
  nvl(tmp_start.model,tmp_page.model),
  tmp_start.login_count,
  tmp_page.page_stats
from tmp_start
full outer join tmp_page
on tmp_start.mid_id=tmp_page.mid_id
and tmp_start.brand=tmp_page.brand
and tmp_start.model=tmp_page.model;
```

2) 数据装载

```
with
tmp_start as
(
  select
    mid_id,
    brand,
    model,
    count(*) login_count
  from dwd_start_log
  where dt='2020-06-14'
  group by mid_id,brand,model
),
tmp_page as
(
  select
    mid_id,
    brand,
    model,
    collect_set(named_struct('page_id',page_id,'page_count',page_count)) page_stats
  from
  (
    select
      mid_id,
      brand,
      model,
      page_id,
      count(*) page_count
    from dwd_page_log
    where dt='2020-06-14'
    group by mid_id,brand,model,page_id
  )tmp
  group by mid_id,brand,model
)
```

页面 设备id	page_id	page_count
ld001	p1	2
ld001	p1	3
ld001	p2	1
ld001	p3	2

设备id	page_id	page_count
ld001	p1	5
ld001	p2	1
ld001	p3	2

ld001=>{p1,5},{p2,1},{p3,2}

让天下没有难学的技术

1) 建表语句

```
hive (gmall)>
drop table if exists dws_uv_detail_daycount;
create external table dws_uv_detail_daycount
(
  `mid_id`      string COMMENT '设备 id',
  `brand`       string COMMENT '手机品牌',
  `model`       string COMMENT '手机型号',
  `login_count` bigint COMMENT '活跃次数',
  `page_stats`  array<struct<page_id:string,page_count:bigint>> COMMENT '页面访问统计'
) COMMENT '每日设备行为表'
partitioned by(dt string)
stored as parquet
location '/warehouse/gmall/dws/dws_uv_detail_daycount'
tblproperties ("parquet.compression"="lzo");
```

2) 数据装载

```
hive (gmall)>
with
tmp_start as
(
  select
    mid_id,
    brand,
    model,
    count(*) login_count
  from dwd_start_log
  where dt='2020-06-14'
  group by mid_id,brand,model
),
tmp_page as
(
  select
    mid_id,
    brand,
    model,
    collect_set(named_struct('page_id',page_id,'page_count',page_count))
  )tmp
  group by mid_id,brand,model
)
page_stats
from
```

```
(
    select
        mid_id,
        brand,
        model,
        page_id,
        count(*) page_count
    from dwd_page_log
    where dt='2020-06-14'
    group by mid_id,brand,model,page_id
) tmp
group by mid_id,brand,model
)
insert overwrite table dws_uv_detail_daycount partition(dt='2020-06-14')
select
    nvl(tmp_start.mid_id,tmp_page.mid_id),
    nvl(tmp_start.brand,tmp_page.brand),
    nvl(tmp_start.model,tmp_page.model),
    tmp_start.login_count,
    tmp_page.page_stats
from tmp_start
full outer join tmp_page
on tmp_start.mid_id=tmp_page.mid_id
and tmp_start.brand=tmp_page.brand
and tmp_start.model=tmp_page.model;
```

3) 查询加载结果

```
hive (gmall)>
select * from dws_uv_detail_daycount where dt='2020-06-14' limit 2;
```

5.3.2 每日会员行为

1) 建表语句

```
hive (gmall)>
drop table if exists dws_user_action_daycount;
create external table dws_user_action_daycount
(
    user_id string comment '用户 id',
    login_count bigint comment '登录次数',
    cart_count bigint comment '加入购物车次数',
    order_count bigint comment '下单次数',
    order_amount decimal(16,2) comment '下单金额',
    payment_count bigint comment '支付次数',
    payment_amount decimal(16,2) comment '支付金额',
    order_detail_stats
array<struct<sku_id:string,sku_num:bigint,order_count:bigint,order_amount:decimal(20,2)>> comment '下单明细统计'
) COMMENT '每日会员行为'
PARTITIONED BY (`dt` string)
stored as parquet
location '/warehouse/gmall/dws/dws_user_action_daycount/'
tblproperties ("parquet.compression"="lzo");
```

2) 数据装载

```
hive (gmall)>
drop table if exists dws_user_action_daycount;
create external table dws_user_action_daycount
(
  user_id string comment '用户 id',
  login_count bigint comment '登录次数',
  cart_count bigint comment '加入购物车次数',
  order_count bigint comment '下单次数',
  order_amount decimal(16,2) comment '下单金额',
  payment_count bigint comment '支付次数',
  payment_amount decimal(16,2) comment '支付金额',
  order_detail_stats
array<struct<sku_id:string,sku_num:bigint,order_count:bigint,
order_amount:decimal(20,2)>> comment '下单明细统计'
) COMMENT '每日会员行为'
PARTITIONED BY ('dt' string)
```

订单详情

用户id	sku_id	sku_num	order_count	order_amount
id001	商品1	2	1	20
id001	商品1	1	1	10
id001	商品2	3	1	30
id001	商品3	2	1	50

订单详情

用户id	sku_id	sku_num	order_count	order_amount
id001	商品1	3	2	30
id001	商品2	3	1	30
id001	商品3	2	1	50

id001=>{商品1,3,2,30},{商品2,3,1,30},{商品3,2,1,50}

```
select
  user_id,
  count(*) login_count
from dwd_start_log
where dt='2020-06-14'
and user_id is not null
group by user_id
```

```
select
  user_id,
  count(*) cart_count
from dwd_action_log
where dt='2020-06-14'
and user_id is not null
and action_id='cart_add'
group by user_id
```

```
select
  user_id,
  collect_set(named_struct('sku_id',sku_id,'sku_num',sku_num,'order_count',order_count,'o
rder_amount',order_amount)) order_stats
from
(
  select
    user_id, sku_id,
    sum(sku_num) sku_num,
    count(*) order_count,
    cast(sum(final_amount_d) as decimal(20,2)) order_amount
  from dwd_fact_order_detail where dt='2020-06-14'
  group by user_id,sku_id
)tmp
group by user_id
```

```
select
  user_id,
  count(*) order_count,
  sum(final_total_amount) order_amount
from dwd_fact_order_info
where dt='2020-06-14'
group by user_id
```

```
select
  user_id,
  count(*) payment_count,
  sum(payment_amount) payment_amount
from dwd_fact_payment_info
where dt='2020-06-14'
group by user_id
```

让天下没有难学的技术

```
hive (gmall)>
with
tmp_login as
(
  select
    user_id,
    count(*) login_count
  from dwd_start_log
  where dt='2020-06-14'
  and user_id is not null
  group by user_id
),
tmp_cart as
(
  select
    user_id,
    count(*) cart_count
  from dwd_action_log
  where dt='2020-06-14'
  and user_id is not null
  and action_id='cart_add'
  group by user_id
),tmp_order as
(
  select
    user_id,
    count(*) order_count,
    sum(final_total_amount) order_amount
  from dwd_fact_order_info
  where dt='2020-06-14'
  group by user_id
),
tmp_payment as
(
  select
    user_id,
    count(*) payment_count,
    sum(payment_amount) payment_amount
  from dwd_fact_payment_info
  where dt='2020-06-14'
  group by user_id
```

```
),
tmp_order_detail as
(
    select
        user_id,

collect_set(named_struct('sku_id',sku_id,'sku_num',sku_num,'order_count',ord
er_count,'order_amount',order_amount)) order_stats
    from
    (
        select
            user_id,
            sku_id,
            sum(sku_num) sku_num,
            count(*) order_count,
            cast(sum(final_amount_d) as decimal(20,2)) order_amount
        from dwd_fact_order_detail
        where dt='2020-06-14'
        group by user_id,sku_id
    )tmp
    group by user_id
)

insert overwrite table dws_user_action_daycount partition(dt='2020-06-14')
select
    tmp_login.user_id,
    login_count,
    nvl(cart_count,0),
    nvl(order_count,0),
    nvl(order_amount,0.0),
    nvl(payment_count,0),
    nvl(payment_amount,0.0),
    order_stats
from tmp_login
left join tmp_cart on tmp_login.user_id=tmp_cart.user_id
left join tmp_order on tmp_login.user_id=tmp_order.user_id
left join tmp_payment on tmp_login.user_id=tmp_payment.user_id
left join tmp_order_detail on tmp_login.user_id=tmp_order_detail.user_id;
```

3) 查询加载结果

```
hive (gmall)>
select * from dws_user_action_daycount where dt='2020-06-14' limit 2;
```

5.3.3 每日商品行为

1) 建表语句

```
hive (gmall)>
drop table if exists dws_sku_action_daycount;
create external table dws_sku_action_daycount
(
    sku_id string comment 'sku_id',
    order_count bigint comment '被下单次数',
    order_num bigint comment '被下单件数',
    order_amount decimal(16,2) comment '被下单金额',
    payment_count bigint comment '被支付次数',
    payment_num bigint comment '被支付件数',
    payment_amount decimal(16,2) comment '被支付金额',
    refund_count bigint comment '被退款次数',
    refund_num bigint comment '被退款件数',
    refund_amount decimal(16,2) comment '被退款金额',
    cart_count bigint comment '被加入购物车次数',
```

```
favor_count bigint comment '被收藏次数',
appraise_good_count bigint comment '好评数',
appraise_mid_count bigint comment '中评数',
appraise_bad_count bigint comment '差评数',
appraise_default_count bigint comment '默认评价数'
) COMMENT '每日商品行为'
PARTITIONED BY (`dt` string)
stored as parquet
location '/warehouse/gmall/dws/dws_sku_action_daycount/'
tblproperties ("parquet.compression"="lzo");
```

2) 数据装载

注意：如果是 23 点 59 下单，支付日期跨天。需要从订单详情里面取出支付时间是今天，且订单时间是昨天或者今天的订单。

```
hive (gmall)>
with
tmp_order as
(
    select
        sku_id,
        count(*) order_count,
        sum(sku_num) order_num,
        sum(final_amount_d) order_amount
    from dwd_fact_order_detail
    where dt='2020-06-14'
    group by sku_id
),
tmp_payment as
(
    select
        sku_id,
        count(*) payment_count,
        sum(sku_num) payment_num,
        sum(final_amount_d) payment_amount
    from dwd_fact_order_detail
    where (dt='2020-06-14'
    or dt=date_add('2020-06-14',-1))
    and order_id in
    (
        select
            id
        from dwd_fact_order_info
        where (dt='2020-06-14'
        or dt=date_add('2020-06-14',-1))
        and date_format(payment_time,'yyyy-MM-dd')='2020-06-14'
    )
    group by sku_id
),
tmp_refund as
(
    select
        sku_id,
        count(*) refund_count,
        sum(refund_num) refund_num,
        sum(refund_amount) refund_amount
    from dwd_fact_order_refund_info
    where dt='2020-06-14'
    group by sku_id
),
tmp_cart as
```

更多 [Java](#) - [大数据](#) - [前端](#) - [python](#) 人工智能资料下载，可百度访问：尚硅谷官网

```
(
    select
        item sku_id,
        count(*) cart_count
    from dwd_action_log
    where dt='2020-06-14'
    and user_id is not null
    and action_id='cart_add'
    group by item
),tmp_favor as
(
    select
        item sku_id,
        count(*) favor_count
    from dwd_action_log
    where dt='2020-06-14'
    and user_id is not null
    and action_id='favor_add'
    group by item
),
tmp_appraise as
(
    select
        sku_id,
        sum(if(appraise='1201',1,0)) appraise_good_count,
        sum(if(appraise='1202',1,0)) appraise_mid_count,
        sum(if(appraise='1203',1,0)) appraise_bad_count,
        sum(if(appraise='1204',1,0)) appraise_default_count
    from dwd_fact_comment_info
    where dt='2020-06-14'
    group by sku_id
)

insert overwrite table dws_sku_action_daycount partition(dt='2020-06-14')
select
    sku_id,
    sum(order_count),
    sum(order_num),
    sum(order_amount),
    sum(payment_count),
    sum(payment_num),
    sum(payment_amount),
    sum(refund_count),
    sum(refund_num),
    sum(refund_amount),
    sum(cart_count),
    sum(favor_count),
    sum(appraise_good_count),
    sum(appraise_mid_count),
    sum(appraise_bad_count),
    sum(appraise_default_count)
from
(
    select
        sku_id,
        order_count,
        order_num,
        order_amount,
        0 payment_count,
        0 payment_num,
        0 payment_amount,
        0 refund_count,
        0 refund_num,
```

```
        0 refund_amount,
        0 cart_count,
        0 favor_count,
        0 appraise_good_count,
        0 appraise_mid_count,
        0 appraise_bad_count,
        0 appraise_default_count
from tmp_order
union all
select
    sku_id,
    0 order_count,
    0 order_num,
    0 order_amount,
    payment_count,
    payment_num,
    payment_amount,
    0 refund_count,
    0 refund_num,
    0 refund_amount,
    0 cart_count,
    0 favor_count,
    0 appraise_good_count,
    0 appraise_mid_count,
    0 appraise_bad_count,
    0 appraise_default_count
from tmp_payment
union all
select
    sku_id,
    0 order_count,
    0 order_num,
    0 order_amount,
    0 payment_count,
    0 payment_num,
    0 payment_amount,
    refund_count,
    refund_num,
    refund_amount,
    0 cart_count,
    0 favor_count,
    0 appraise_good_count,
    0 appraise_mid_count,
    0 appraise_bad_count,
    0 appraise_default_count
from tmp_refund
union all
select
    sku_id,
    0 order_count,
    0 order_num,
    0 order_amount,
    0 payment_count,
    0 payment_num,
    0 payment_amount,
    0 refund_count,
    0 refund_num,
    0 refund_amount,
    cart_count,
    0 favor_count,
    0 appraise_good_count,
    0 appraise_mid_count,
    0 appraise_bad_count,
```

```
        0 appraise_default_count
    from tmp_cart
    union all
    select
        sku_id,
        0 order_count,
        0 order_num,
        0 order_amount,
        0 payment_count,
        0 payment_num,
        0 payment_amount,
        0 refund_count,
        0 refund_num,
        0 refund_amount,
        0 cart_count,
        favor_count,
        0 appraise_good_count,
        0 appraise_mid_count,
        0 appraise_bad_count,
        0 appraise_default_count
    from tmp_favor
    union all
    select
        sku_id,
        0 order_count,
        0 order_num,
        0 order_amount,
        0 payment_count,
        0 payment_num,
        0 payment_amount,
        0 refund_count,
        0 refund_num,
        0 refund_amount,
        0 cart_count,
        0 favor_count,
        appraise_good_count,
        appraise_mid_count,
        appraise_bad_count,
        appraise_default_count
    from tmp_appraise
    )tmp
group by sku_id;
```

3) 查询加载结果

```
hive (gmall)>
select * from dws_sku_action_daycount where dt='2020-06-14' limit 2;
```

5.3.4 每日活动统计

每日活动统计

1) 建表语句

```
drop table if exists dws_activity_info_daycount;
create external table dws_activity_info_daycount(
  `id` string COMMENT '编号',
  `activity_name` string COMMENT '活动名称',
  `activity_type` string COMMENT '活动类型',
  `start_time` string COMMENT '开始时间',
  `end_time` string COMMENT '结束时间',
  `create_time` string COMMENT '创建时间',
  `order_count` bigint COMMENT '下单次数',
  `payment_count` bigint COMMENT '支付次数'
) COMMENT '每日活动统计'
PARTITIONED BY (`dt` string)
stored as parquet
location '/warehouse/gmall/dws/dws_activity_info_daycount/'
tblproperties ("parquet.compression"="lzo");
```

2) 数据装载

```
insert overwrite table dws_activity_info_daycount partition(dt='2020-06-14')
select
  oi.activity_id,
  ai.activity_name,
  ai.activity_type,
  ai.start_time,
  ai.end_time,
  ai.create_time,
  oi.order_count,
  oi.payment_count
from
(
  select
    activity_id,
    sum(if(date_format(create_time,'yyyy-MM-dd')='2020-06-14',1,0)) order_count,
    sum(if(date_format(payment_time,'yyyy-MM-dd')='2020-06-14',1,0)) payment_count
  from dwd_fact_order_info
  where (dt='2020-06-14' or dt=date_add('2020-06-14',-1))
  and activity_id is not null
  group by activity_id
)oi
join
(
  select * from dwd_dim_activity_info where dt='2020-06-14'
)ai on oi.activity_id=ai.id;
```

让天下没有难学的技术

1) 建表语句

```
hive (gmall)>
drop table if exists dws_activity_info_daycount;
create external table dws_activity_info_daycount (
  `id` string COMMENT '编号',
  `activity_name` string COMMENT '活动名称',
  `activity_type` string COMMENT '活动类型',
  `start_time` string COMMENT '开始时间',
  `end_time` string COMMENT '结束时间',
  `create_time` string COMMENT '创建时间',
  `display_count` bigint COMMENT '曝光次数',
  `order_count` bigint COMMENT '下单次数',
  `order_amount` decimal(20,2) COMMENT '下单金额',
  `payment_count` bigint COMMENT '支付次数',
  `payment_amount` decimal(20,2) COMMENT '支付金额'
) COMMENT '每日活动统计'
PARTITIONED BY (`dt` string)
stored as parquet
location '/warehouse/gmall/dws/dws_activity_info_daycount/'
tblproperties ("parquet.compression"="lzo");
```

2) 数据装载

```
hive (gmall)>
with
tmp_op as
(
  select
    activity_id,
    sum(if(date_format(create_time,'yyyy-MM-dd')='2020-06-14',1,0))
order_count,
    sum(if(date_format(create_time,'yyyy-MM-dd')='2020-06-14',final_total_amount,0)) order_amount,
    sum(if(date_format(payment_time,'yyyy-MM-dd')='2020-06-14',1,0))
payment_count,
    sum(if(date_format(payment_time,'yyyy-MM-dd')='2020-06-14',final_total_amount,0)) payment_amount
```

```
from dwd_fact_order_info
where (dt='2020-06-14' or dt=date_add('2020-06-14',-1))
and activity_id is not null
group by activity_id
),
tmp_display as
(
select
    item activity_id,
    count(*) display_count
from dwd_display_log
where dt='2020-06-14'
and item_type='activity_id'
group by item
),
tmp_activity as
(
select
    *
from dwd_dim_activity_info
where dt='2020-06-14'
)
insert overwrite table dws_activity_info_daycount partition(dt='2020-06-14')
select
    nvl(tmp_op.activity_id,tmp_display.activity_id),
    tmp_activity.activity_name,
    tmp_activity.activity_type,
    tmp_activity.start_time,
    tmp_activity.end_time,
    tmp_activity.create_time,
    tmp_display.display_count,
    tmp_op.order_count,
    tmp_op.order_amount,
    tmp_op.payment_count,
    tmp_op.payment_amount
from tmp_op
full outer join tmp_display on tmp_op.activity_id=tmp_display.activity_id
left join tmp_activity on
nvl(tmp_op.activity_id,tmp_display.activity_id)=tmp_activity.id;
```

3) 查询加载结果

```
hive (gmall)>
select * from dws_activity_info_daycount where dt='2020-06-14' limit 2;
```

5.3.5 每日地区统计

1) 建表语句

```
hive (gmall)>
drop table if exists dws_area_stats_daycount;
create external table dws_area_stats_daycount(
    `id` bigint COMMENT '编号',
    `province_name` string COMMENT '省份名称',
    `area_code` string COMMENT '地区编码',
    `iso_code` string COMMENT 'iso 编码',
    `region_id` string COMMENT '地区 ID',
    `region_name` string COMMENT '地区名称',
    `login_count` string COMMENT '活跃设备数',
    `order_count` bigint COMMENT '下单次数',
    `order_amount` decimal(20,2) COMMENT '下单金额',
    `payment_count` bigint COMMENT '支付次数',
    `payment_amount` decimal(20,2) COMMENT '支付金额'
```

更多 [Java](#) -[大数据](#) -[前端](#) -[python](#) 人工智能资料下载，可百度访问：[尚硅谷官网](#)

```
) COMMENT '每日地区统计表'
PARTITIONED BY (`dt` string)
stored as parquet
location '/warehouse/gmall/dws/dws_area_stats_daycount/'
tblproperties ("parquet.compression"="lzo");
```

2) 数据装载

```
hive (gmall)>
with
tmp_login as
(
    select
        area_code,
        count(*) login_count
    from dwd_start_log
    where dt='2020-06-14'
    group by area_code
),
tmp_op as
(
    select
        province_id,
        sum(if(date_format(create_time,'yyyy-MM-dd')='2020-06-14',1,0))
order_count,
        sum(if(date_format(create_time,'yyyy-MM-dd')='2020-06-14',final_total_amount,0)) order_amount,
        sum(if(date_format(payment_time,'yyyy-MM-dd')='2020-06-14',1,0))
payment_count,
        sum(if(date_format(payment_time,'yyyy-MM-dd')='2020-06-14',final_total_amount,0)) payment_amount
    from dwd_fact_order_info
    where (dt='2020-06-14' or dt=date_add('2020-06-14',-1))
    group by province_id
)
insert overwrite table dws_area_stats_daycount partition(dt='2020-06-14')
select
    pro.id,
    pro.province_name,
    pro.area_code,
    pro.iso_code,
    pro.region_id,
    pro.region_name,
    nvl(tmp_login.login_count,0),
    nvl(tmp_op.order_count,0),
    nvl(tmp_op.order_amount,0.0),
    nvl(tmp_op.payment_count,0),
    nvl(tmp_op.payment_amount,0.0)
from dwd_dim_base_province pro
left join tmp_login on pro.area_code=tmp_login.area_code
left join tmp_op on pro.id=tmp_op.province_id;
```

3) 查询加载结果

```
hive (gmall)>
select * from dws_area_stats_daycount where dt='2020-06-14' limit 2;
```

5.4 DWS 层数据导入脚本

1) 在/home/atguigu/bin 目录下创建脚本 dwd_to_dws.sh

```
[atguigu@hadoop102 bin]$ vim dwd_to_dws.sh
```

在脚本中填写如下内容

更多 [Java](#) - [大数据](#) - [前端](#) - [python](#) 人工智能资料下载，可百度访问：[尚硅谷官网](#)

```
#!/bin/bash

APP=gmall
hive=/opt/module/hive/bin/hive

# 如果是输入的日期按照取输入日期；如果没输入日期取当前时间的前一天
if [ -n "$1" ] ;then
    do_date=$1
else
    do_date=`date -d "-1 day" +%F`
fi

sql="
set mapreduce.job.queueName=hive;
with
tmp_start as
(
    select
        mid_id,
        brand,
        model,
        count(*) login_count
    from ${APP}.dwd_start_log
    where dt='$do_date'
    group by mid_id,brand,model
),
tmp_page as
(
    select
        mid_id,
        brand,
        model,
        collect_set(named_struct('page_id',page_id,'page_count',page_count)) page_stats
    from
    (
        select
            mid_id,
            brand,
            model,
            page_id,
            count(*) page_count
        from ${APP}.dwd_page_log
        where dt='$do_date'
        group by mid_id,brand,model,page_id
    ) tmp
    group by mid_id,brand,model
)
insert overwrite table ${APP}.dws_uv_detail_daycount partition(dt='$do_date')
select
    nvl(tmp_start.mid_id,tmp_page.mid_id),
    nvl(tmp_start.brand,tmp_page.brand),
    nvl(tmp_start.model,tmp_page.model),
    tmp_start.login_count,
    tmp_page.page_stats
from tmp_start
full outer join tmp_page
on tmp_start.mid_id=tmp_page.mid_id
and tmp_start.brand=tmp_page.brand
and tmp_start.model=tmp_page.model;

with
tmp_login as
```

更多 Java -大数据 -前端 -python 人工智能资料下载，可百度访问：尚硅谷官网

```
(
    select
        user_id,
        count(*) login_count
    from ${APP}.dwd_start_log
    where dt='${do_date}'
    and user_id is not null
    group by user_id
),
tmp_cart as
(
    select
        user_id,
        count(*) cart_count
    from ${APP}.dwd_action_log
    where dt='${do_date}'
    and user_id is not null
    and action_id='cart_add'
    group by user_id
),tmp_order as
(
    select
        user_id,
        count(*) order_count,
        sum(final_total_amount) order_amount
    from ${APP}.dwd_fact_order_info
    where dt='${do_date}'
    group by user_id
) ,
tmp_payment as
(
    select
        user_id,
        count(*) payment_count,
        sum(payment_amount) payment_amount
    from ${APP}.dwd_fact_payment_info
    where dt='${do_date}'
    group by user_id
),
tmp_order_detail as
(
    select
        user_id,

collect_set(named_struct('sku_id',sku_id,'sku_num',sku_num,'order_count',order_count,'
order_amount',order_amount)) order_stats
    from
    (
        select
            user_id,
            sku_id,
            sum(sku_num) sku_num,
            count(*) order_count,
            cast(sum(final_amount_d) as decimal(20,2)) order_amount
        from ${APP}.dwd_fact_order_detail
        where dt='${do_date}'
        group by user id,sku id
    )tmp
    group by user_id
)

insert overwrite table ${APP}.dws_user_action_daycount partition(dt='${do_date}')
select
```

更多 Java -大数据 -前端 -python 人工智能资料下载，可百度访问：尚硅谷官网

```
tmp_login.user_id,
login_count,
nvl(cart_count,0),
nvl(order_count,0),
nvl(order_amount,0.0),
nvl(payment_count,0),
nvl(payment_amount,0.0),
order_stats
from tmp_login
left outer join tmp_cart on tmp_login.user_id=tmp_cart.user_id
left outer join tmp_order on tmp_login.user_id=tmp_order.user_id
left outer join tmp_payment on tmp_login.user_id=tmp_payment.user_id
left outer join tmp_order_detail on tmp_login.user_id=tmp_order_detail.user_id;

with
tmp_order as
(
    select
        sku_id,
        count(*) order_count,
        sum(sku_num) order_num,
        sum(final_amount_d) order_amount
    from ${APP}.dwd_fact_order_detail
    where dt='$do_date'
    group by sku_id
),
tmp_payment as
(
    select
        sku_id,
        count(*) payment_count,
        sum(sku_num) payment_num,
        sum(final_amount_d) payment_amount
    from ${APP}.dwd_fact_order_detail
    where (dt='$do_date'
    or dt=date_add('$do_date',-1))
    and order_id in
    (
        select
            id
        from ${APP}.dwd_fact_order_info
        where (dt='$do_date'
        or dt=date_add('$do_date',-1))
        and date_format(payment_time,'yyyy-MM-dd')='$do_date'
    )
    group by sku_id
),
tmp_refund as
(
    select
        sku_id,
        count(*) refund_count,
        sum(refund_num) refund_num,
        sum(refund_amount) refund_amount
    from ${APP}.dwd_fact_order_refund_info
    where dt='$do_date'
    group by sku_id
),
tmp_cart as
(
    select
        item sku_id,
        count(*) cart_count
```

```
from ${APP}.dwd_action_log
where dt='${do_date}'
and user_id is not null
and action_id='cart_add'
group by item
),tmp_favor as
(
    select
        item sku_id,
        count(*) favor_count
    from ${APP}.dwd_action_log
    where dt='${do_date}'
    and user_id is not null
    and action_id='favor_add'
    group by item
),
tmp_appraise as
(
select
    sku_id,
    sum(if(appraise='1201',1,0)) appraise_good_count,
    sum(if(appraise='1202',1,0)) appraise_mid_count,
    sum(if(appraise='1203',1,0)) appraise_bad_count,
    sum(if(appraise='1204',1,0)) appraise_default_count
from ${APP}.dwd_fact_comment_info
where dt='${do_date}'
group by sku_id
)

insert overwrite table ${APP}.dws_sku_action_daycount partition(dt='${do_date}')
select
    sku_id,
    sum(order_count),
    sum(order_num),
    sum(order_amount),
    sum(payment_count),
    sum(payment_num),
    sum(payment_amount),
    sum(refund_count),
    sum(refund_num),
    sum(refund_amount),
    sum(cart_count),
    sum(favor_count),
    sum(appraise_good_count),
    sum(appraise_mid_count),
    sum(appraise_bad_count),
    sum(appraise_default_count)
from
(
    select
        sku_id,
        order_count,
        order_num,
        order_amount,
        0 payment_count,
        0 payment_num,
        0 payment_amount,
        0 refund_count,
        0 refund_num,
        0 refund_amount,
        0 cart_count,
        0 favor_count,
        0 appraise_good_count,
```

```
        0 appraise_mid_count,
        0 appraise_bad_count,
        0 appraise_default_count
from tmp_order
union all
select
    sku_id,
    0 order_count,
    0 order_num,
    0 order_amount,
    payment_count,
    payment_num,
    payment_amount,
    0 refund_count,
    0 refund_num,
    0 refund_amount,
    0 cart_count,
    0 favor_count,
    0 appraise_good_count,
    0 appraise_mid_count,
    0 appraise_bad_count,
    0 appraise_default_count
from tmp_payment
union all
select
    sku_id,
    0 order_count,
    0 order_num,
    0 order_amount,
    0 payment_count,
    0 payment_num,
    0 payment_amount,
    refund_count,
    refund_num,
    refund_amount,
    0 cart_count,
    0 favor_count,
    0 appraise_good_count,
    0 appraise_mid_count,
    0 appraise_bad_count,
    0 appraise_default_count
from tmp_refund
union all
select
    sku_id,
    0 order_count,
    0 order_num,
    0 order_amount,
    0 payment_count,
    0 payment_num,
    0 payment_amount,
    0 refund_count,
    0 refund_num,
    0 refund_amount,
    cart_count,
    0 favor_count,
    0 appraise good count,
    0 appraise_mid_count,
    0 appraise_bad_count,
    0 appraise_default_count
from tmp_cart
union all
select
```

```
        sku_id,
        0 order_count,
        0 order_num,
        0 order_amount,
        0 payment_count,
        0 payment_num,
        0 payment_amount,
        0 refund_count,
        0 refund_num,
        0 refund_amount,
        0 cart_count,
        favor_count,
        0 appraise_good_count,
        0 appraise_mid_count,
        0 appraise_bad_count,
        0 appraise_default_count
    from tmp_favor
union all
select
    sku_id,
    0 order_count,
    0 order_num,
    0 order_amount,
    0 payment_count,
    0 payment_num,
    0 payment_amount,
    0 refund_count,
    0 refund_num,
    0 refund_amount,
    0 cart_count,
    0 favor_count,
    appraise_good_count,
    appraise_mid_count,
    appraise_bad_count,
    appraise_default_count
    from tmp_appraise
)tmp
group by sku_id;

with
tmp_login as
(
    select
        area_code,
        count(*) login_count
    from ${APP}.dwd_start_log
    where dt='$do_date'
    group by area_code
),
tmp_op as
(
    select
        province_id,
        sum(if(date_format(create_time,'yyyy-MM-dd')='$do_date',1,0)) order_count,
        sum(if(date_format(create_time,'yyyy-MM-dd')='$do_date',final_total_amount,0))
order_amount,
        sum(if(date_format(payment_time,'yyyy-MM-dd')='$do_date',1,0)) payment count,
        sum(if(date_format(payment_time,'yyyy-MM-dd')='$do_date',final_total_amount,0))
payment_amount
    from ${APP}.dwd_fact_order_info
    where (dt='$do_date' or dt=date_add('$do_date',-1))
    group by province_id
)
```

更多 Java -大数据 -前端 -python 人工智能资料下载，可百度访问：尚硅谷官网

```
insert overwrite table ${APP}.dws_area_stats_daycount partition(dt='${do_date}')
select
    pro.id,
    pro.province_name,
    pro.area_code,
    pro.iso_code,
    pro.region_id,
    pro.region_name,
    nvl(tmp_login.login_count,0),
    nvl(tmp_op.order_count,0),
    nvl(tmp_op.order_amount,0.0),
    nvl(tmp_op.payment_count,0),
    nvl(tmp_op.payment_amount,0.0)
from ${APP}.dwd_dim_base_province pro
left join tmp_login on pro.area_code=tmp_login.area_code
left join tmp_op on pro.id=tmp_op.province_id;

with
tmp_op as
(
    select
        activity_id,
        sum(if(date_format(create_time,'yyyy-MM-dd')='${do_date}',1,0)) order_count,
        sum(if(date_format(create_time,'yyyy-MM-dd')='${do_date}',final_total_amount,0))
order_amount,
        sum(if(date_format(payment_time,'yyyy-MM-dd')='${do_date}',1,0)) payment_count,
        sum(if(date_format(payment_time,'yyyy-MM-dd')='${do_date}',final_total_amount,0))
payment_amount
    from ${APP}.dwd_fact_order_info
    where (dt='${do_date}' or dt=date_add('${do_date}',-1))
    and activity_id is not null
    group by activity_id
),
tmp_display as
(
    select
        item activity_id,
        count(*) display_count
    from ${APP}.dwd_display_log
    where dt='${do_date}'
    and item_type='activity_id'
    group by item
),
tmp_activity as
(
    select
        *
    from ${APP}.dwd_dim_activity_info
    where dt='${do_date}'
)
insert overwrite table ${APP}.dws_activity_info_daycount partition(dt='${do_date}')
select
    nvl(tmp_op.activity_id,tmp_display.activity_id),
    tmp_activity.activity_name,
    tmp_activity.activity_type,
    tmp_activity.start_time,
    tmp_activity.end_time,
    tmp_activity.create_time,
    tmp_display.display_count,
    tmp_op.order_count,
    tmp_op.order_amount,
    tmp_op.payment_count,
```

```
tmp_op.payment_amount
from tmp_op
full outer join tmp_display on tmp_op.activity_id=tmp_display.activity_id
left      join      tmp_activity      on
nvl(tmp_op.activity_id,tmp_display.activity_id)=tmp_activity.id;
"

$hive -e "$sql"
```

2) 增加脚本执行权限

```
[atguigu@hadoop102 bin]$ chmod 777 dwd_to_dws.sh
```

3) 执行脚本导入数据

```
[atguigu@hadoop102 bin]$ dwd_to_dws.sh 2020-06-15
```

4) 查看导入数据

```
hive (gmall)>
select * from dws_uv_detail_daycount where dt='2020-06-15' limit 2;
select * from dws_user_action_daycount where dt='2020-06-15' limit 2;
select * from dws_sku_action_daycount where dt='2020-06-15' limit 2;
select * from dws_activity_info_daycount where dt='2020-06-15' limit 2;
select * from dws_area_stats_daycount where dt='2020-06-15' limit 2;
```

第 6 章 数仓搭建-DWT 层

DWS 层宽表及宽表字段设计详见 2.4.4。

6.1 设备主题宽表




设备主题宽表

1) 建表语句

```
drop table if exists dwt_uv_topic;
create external table dwt_uv_topic
(
  `mid_id` string comment '设备id',
  `brand` string comment '手机品牌',
  `model` string comment '手机型号',
  `login_date_first` string comment '首次活跃时间',
  `login_date_last` string comment '末次活跃时间',
  `login_day_count` bigint comment '当日活跃次数',
  `login_count` bigint comment '累积活跃天数'
) COMMENT '设备主题宽表'
stored as parquet
location '/warehouse/gmall/dwt/dwt_uv_topic'
tblproperties ("parquet.compression"="lzo");
```

2) 数据装载

```
insert overwrite table dwt_uv_topic
select
  nvl(new.mid_id,old.mid_id),
  nvl(new.model,old.model),
  nvl(new.brand,old.brand),
  if(old.mid_id is null,'2020-06-14',old.login_date_first),
  if(old.mid_id is not null,'2020-06-14',old.login_date_last),
  if(new.mid_id is not null, new.login_count,0),
  nvl(old.login_count,0)+if(new.login_count>0,1,0)
from
(
  select
    *
  from dwt_uv_topic
)old
full outer join
(
  select
    *
  from dws_uv_detail_daycount
  where dt='2020-06-14'
)new
on old.mid_id=new.mid_id;
```



让天下没有难学的技术

1) 建表语句

```
hive (gmall)>
drop table if exists dwt_uv_topic;
create external table dwt_uv_topic
(
  `mid_id` string comment '设备id',
  `brand` string comment '手机品牌',
  `model` string comment '手机型号',
  `login_date_first` string comment '首次活跃时间',
```

更多 [Java](#) - [大数据](#) - [前端](#) - [python](#) 人工智能资料下载，可百度访问：尚硅谷官网

```

`login_date_last` string comment '末次活跃时间',
`login_day_count` bigint comment '当日活跃次数',
`login_count` bigint comment '累积活跃天数'
) COMMENT '设备主题宽表'
stored as parquet
location '/warehouse/gmall/dwt/dwt_uv_topic'
tblproperties ("parquet.compression"="lzo");

```

2) 数据装载

```

hive (gmall)>
insert overwrite table dwt_uv_topic
select
  nvl(new.mid_id,old.mid_id),
  nvl(new.model,old.model),
  nvl(new.brand,old.brand),
  if(old.mid_id is null,'2020-06-14',old.login_date_first),
  if(new.mid_id is not null,'2020-06-14',old.login_date_last),
  if(new.mid_id is not null, new.login_count,0),
  nvl(old.login_count,0)+if(new.login_count>0,1,0)
from
(
  select
    *
    from dwt_uv_topic
)old
full outer join
(
  select
    *
    from dws_uv_detail_daycount
    where dt='2020-06-14'
)new
on old.mid_id=new.mid_id;

```

3) 查询加载结果

```
hive (gmall)> select * from dwt_uv_topic limit 5;
```

6.2 会员主题宽表

宽表字段怎么来？维度关联的事实表度量值+开头、结尾+累积+累积一个时间段。



会员主题宽表

2) 数据装载



1) 建表语句

```


drop table if exists dwt_user_topic;
create external table dwt_user_topic
(
  user_id string comment '用户id',
  login_date_first string comment '首次登录时间',
  login_date_last string comment '末次登录时间',
  login_count bigint comment '累积登录天数',
  login_last_30d_count bigint comment '最近30日登录天数',
  order_date_first string comment '首次下单时间',
  order_date_last string comment '末次下单时间',
  order_count bigint comment '累积下单次数',
  order_amount decimal(16,2) comment '累积下单金额',
  order_last_30d_count bigint comment '最近30日下单次数',
  order_last_30d_amount decimal(16,2) comment '最近30日下单金额',
  payment_date_first string comment '首次支付时间',
  payment_date_last string comment '末次支付时间',
  payment_count decimal(16,2) comment '累积支付次数',
  payment_amount decimal(16,2) comment '累积支付金额',
  payment_last_30d_count decimal(16,2) comment '最近30日支付次数',
  payment_last_30d_amount decimal(16,2) comment '最近30日支付金额'
) COMMENT '用户主题宽表'
stored as parquet
location '/warehouse/gmall/dwt/dwt_user_topic/'
tblproperties ("parquet.compression"="lzo");

```

```

insert overwrite table dwt_user_topic
select
  nvl(new.user_id,old.user_id),
  if(old.login_date_first is null and new.login_count>0,'2020-06-14',old.login_date_first),
  if(new.login_count>0,'2020-06-14',old.login_date_last),
  nvl(old.login_count,0)+if(new.login_count>0,1,0),
  nvl(new.login_last_30d_count,0),
  if(old.order_date_first is null and new.order_count>0,'2020-06-14',old.order_date_first),
  if(new.order_count>0,'2020-06-14',old.order_date_last),
  nvl(old.order_count,0)+nvl(new.order_count,0),
  nvl(old.order_amount,0)+nvl(new.order_amount,0),
  nvl(new.order_last_30d_count,0),
  if(new.order_last_30d_amount,0),
  if(old.payment_date_first is null and new.payment_count>0,'2020-06-14',old.payment_date_first),
  if(new.payment_count>0,'2020-06-14',old.payment_date_last),
  nvl(old.payment_count,0)+nvl(new.payment_count,0),
  nvl(old.payment_amount,0)+nvl(new.payment_amount,0),
  nvl(new.payment_last_30d_count,0),
  nvl(new.payment_last_30d_amount,0)
from dwt_user_topic old
full outer join
(
  select
    user_id,
    sum(if(dt='2020-06-14',login_count,0)) login_count, 登录次数
    sum(if(dt='2020-06-14',order_count,0)) order_count, 下单数
    sum(if(dt='2020-06-14',order_amount,0)) order_amount, 下单金额
    sum(if(dt='2020-06-14',payment_count,0)) payment_count, 支付次数
    sum(if(dt='2020-06-14',payment_amount,0)) payment_amount, 支付金额
    sum(if(order_count>0,1,0)) login_last_30d_count, 最近30日登录天数
    sum(order_count) order_last_30d_count, 最近30日下单次数
    sum(order_amount) order_last_30d_amount, 最近30日下单金额
    sum(payment_count) payment_last_30d_count, 最近30日支付次数
    sum(payment_amount) payment_last_30d_amount, 最近30日支付金额
  from dws_user_action_daycount
  where dt>=date_add('2020-06-14',-30)
  group by user_id
)new on old.user_id=new.user_id;

```



让天下没有难学的技术

1) 建表语句

```
hive (gmall)>
drop table if exists dwt_user_topic;
create external table dwt_user_topic
(
    user_id string comment '用户 id',
    login_date_first string comment '首次登录时间',
    login_date_last string comment '末次登录时间',
    login_count bigint comment '累积登录天数',
    login_last_30d_count bigint comment '最近 30 日登录天数',
    order_date_first string comment '首次下单时间',
    order_date_last string comment '末次下单时间',
    order_count bigint comment '累积下单次数',
    order_amount decimal(16,2) comment '累积下单金额',
    order_last_30d_count bigint comment '最近 30 日下单次数',
    order_last_30d_amount bigint comment '最近 30 日下单金额',
    payment_date_first string comment '首次支付时间',
    payment_date_last string comment '末次支付时间',
    payment_count decimal(16,2) comment '累积支付次数',
    payment_amount decimal(16,2) comment '累积支付金额',
    payment_last_30d_count decimal(16,2) comment '最近 30 日支付次数',
    payment_last_30d_amount decimal(16,2) comment '最近 30 日支付金额'
) COMMENT '会员主题宽表'
stored as parquet
location '/warehouse/gmall/dwt/dwt_user_topic/'
tblproperties ("parquet.compression"="lzo");
```

2) 数据装载

```
hive (gmall)>
insert overwrite table dwt_user_topic
select
    nvl(new.user_id,old.user_id),
    if(old.login_date_first is null and new.login_count>0,'2020-06-14',old.login_date_first),
    if(new.login_count>0,'2020-06-14',old.login_date_last),
    nvl(old.login_count,0)+if(new.login_count>0,1,0),
    nvl(new.login_last_30d_count,0),
    if(old.order_date_first is null and new.order_count>0,'2020-06-14',old.order_date_first),
    if(new.order_count>0,'2020-06-14',old.order_date_last),
    nvl(old.order_count,0)+nvl(new.order_count,0),
    nvl(old.order_amount,0)+nvl(new.order_amount,0),
    nvl(new.order_last_30d_count,0),
    nvl(new.order_last_30d_amount,0),
    if(old.payment_date_first is null and new.payment_count>0,'2020-06-14',old.payment_date_first),
    if(new.payment_count>0,'2020-06-14',old.payment_date_last),
    nvl(old.payment_count,0)+nvl(new.payment_count,0),
    nvl(old.payment_amount,0)+nvl(new.payment_amount,0),
    nvl(new.payment_last_30d_count,0),
    nvl(new.payment_last_30d_amount,0)
from
dwt_user_topic old
full outer join
(
    select
        user_id,
        sum(if(dt='2020-06-14',login_count,0)) login_count,
        sum(if(dt='2020-06-14',order_count,0)) order_count,
        sum(if(dt='2020-06-14',order_amount,0)) order_amount,
```

```
sum(if(dt='2020-06-14',payment_count,0)) payment_count,
sum(if(dt='2020-06-14',payment_amount,0)) payment_amount,
sum(if(login_count>0,1,0)) login_last_30d_count,
sum(order_count) order_last_30d_count,
sum(order_amount) order_last_30d_amount,
sum(payment_count) payment_last_30d_count,
sum(payment_amount) payment_last_30d_amount
from dws_user_action_daycount
where dt>=date_add( '2020-06-14',-30)
group by user_id
)new
on old.user_id=new.user_id;
```

3) 查询加载结果

```
hive (gmall)> select * from dwt_user_topic limit 5;
```

6.3 商品主题宽表

1) 建表语句

```
hive (gmall)>
drop table if exists dwt_sku_topic;
create external table dwt_sku_topic
(
    sku_id string comment 'sku_id',
    spu_id string comment 'spu_id',
    order_last_30d_count bigint comment '最近 30 日被下单次数',
    order_last_30d_num bigint comment '最近 30 日被下单件数',
    order_last_30d_amount decimal(16,2) comment '最近 30 日被下单金额',
    order_count bigint comment '累积被下单次数',
    order_num bigint comment '累积被下单件数',
    order_amount decimal(16,2) comment '累积被下单金额',
    payment_last_30d_count bigint comment '最近 30 日被支付次数',
    payment_last_30d_num bigint comment '最近 30 日被支付件数',
    payment_last_30d_amount decimal(16,2) comment '最近 30 日被支付金额',
    payment_count bigint comment '累积被支付次数',
    payment_num bigint comment '累积被支付件数',
    payment_amount decimal(16,2) comment '累积被支付金额',
    refund_last_30d_count bigint comment '最近三十日退款次数',
    refund_last_30d_num bigint comment '最近三十日退款件数',
    refund_last_30d_amount decimal(16,2) comment '最近三十日退款金额',
    refund_count bigint comment '累积退款次数',
    refund_num bigint comment '累积退款件数',
    refund_amount decimal(16,2) comment '累积退款金额',
    cart_last_30d_count bigint comment '最近 30 日被加入购物车次数',
    cart_count bigint comment '累积被加入购物车次数',
    favor_last_30d_count bigint comment '最近 30 日被收藏次数',
    favor_count bigint comment '累积被收藏次数',
    appraise_last_30d_good_count bigint comment '最近 30 日好评数',
    appraise_last_30d_mid_count bigint comment '最近 30 日中评数',
    appraise_last_30d_bad_count bigint comment '最近 30 日差评数',
    appraise_last_30d_default_count bigint comment '最近 30 日默认评价数',
    appraise_good_count bigint comment '累积好评数',
    appraise_mid_count bigint comment '累积中评数',
    appraise_bad_count bigint comment '累积差评数',
    appraise_default_count bigint comment '累积默认评价数'
) COMMENT '商品主题宽表'
stored as parquet
location '/warehouse/gmall/dwt/dwt_sku_topic/'
tblproperties ("parquet.compression"="lzo");
```

2) 数据装载

```
hive (gmall)>
insert overwrite table dwt_sku_topic
select
  nvl(new.sku_id,old.sku_id),
  sku_info.spu_id,
  nvl(new.order_count30,0),
  nvl(new.order_num30,0),
  nvl(new.order_amount30,0),
  nvl(old.order_count,0) + nvl(new.order_count,0),
  nvl(old.order_num,0) + nvl(new.order_num,0),
  nvl(old.order_amount,0) + nvl(new.order_amount,0),
  nvl(new.payment_count30,0),
  nvl(new.payment_num30,0),
  nvl(new.payment_amount30,0),
  nvl(old.payment_count,0) + nvl(new.payment_count,0),
  nvl(old.payment_num,0) + nvl(new.payment_count,0),
  nvl(old.payment_amount,0) + nvl(new.payment_count,0),
  nvl(new.refund_count30,0),
  nvl(new.refund_num30,0),
  nvl(new.refund_amount30,0),
  nvl(old.refund_count,0) + nvl(new.refund_count,0),
  nvl(old.refund_num,0) + nvl(new.refund_num,0),
  nvl(old.refund_amount,0) + nvl(new.refund_amount,0),
  nvl(new.cart_count30,0),
  nvl(old.cart_count,0) + nvl(new.cart_count,0),
  nvl(new.favor_count30,0),
  nvl(old.favor_count,0) + nvl(new.favor_count,0),
  nvl(new.appraise_good_count30,0),
  nvl(new.appraise_mid_count30,0),
  nvl(new.appraise_bad_count30,0),
  nvl(new.appraise_default_count30,0) ,
  nvl(old.appraise_good_count,0) + nvl(new.appraise_good_count,0),
  nvl(old.appraise_mid_count,0) + nvl(new.appraise_mid_count,0),
  nvl(old.appraise_bad_count,0) + nvl(new.appraise_bad_count,0),
  nvl(old.appraise_default_count,0) + nvl(new.appraise_default_count,0)
from
dwt_sku_topic old
full outer join
(
  select
    sku_id,
    sum(if(dt='2020-06-14', order_count,0 )) order_count,
    sum(if(dt='2020-06-14',order_num ,0 )) order_num,
    sum(if(dt='2020-06-14',order_amount,0 )) order_amount ,
    sum(if(dt='2020-06-14',payment_count,0 )) payment_count,
    sum(if(dt='2020-06-14',payment_num,0 )) payment_num,
    sum(if(dt='2020-06-14',payment_amount,0 )) payment_amount,
    sum(if(dt='2020-06-14',refund_count,0 )) refund_count,
    sum(if(dt='2020-06-14',refund_num,0 )) refund_num,
    sum(if(dt='2020-06-14',refund_amount,0 )) refund_amount,
    sum(if(dt='2020-06-14',cart_count,0 )) cart_count,
    sum(if(dt='2020-06-14',favor_count,0 )) favor_count,
    sum(if(dt='2020-06-14',appraise_good_count,0 )) appraise_good_count,
    sum(if(dt='2020-06-14',appraise_mid_count,0 )) appraise_mid_count ,
    sum(if(dt='2020-06-14',appraise_bad_count,0 )) appraise_bad_count,
    sum(if(dt='2020-06-14',appraise_default_count,0 )) appraise_default_count,
    sum(order_count) order_count30 ,
    sum(order_num) order_num30,
    sum(order_amount) order_amount30,
    sum(payment_count) payment_count30,
```

```

sum(payment_num) payment_num30,
sum(payment_amount) payment_amount30,
sum(refund_count) refund_count30,
sum(refund_num) refund_num30,
sum(refund_amount) refund_amount30,
sum(cart_count) cart_count30,
sum(favor_count) favor_count30,
sum(appraise_good_count) appraise_good_count30,
sum(appraise_mid_count) appraise_mid_count30,
sum(appraise_bad_count) appraise_bad_count30,
sum(appraise_default_count) appraise_default_count30
from dws_sku_action_daycount
where dt >= date_add ('2020-06-14', -30)
group by sku_id
)new
on new.sku_id = old.sku_id
left join
(select * from dwd_dim_sku_info where dt='2020-06-14') sku_info
on nvl(new.sku_id,old.sku_id)= sku_info.id;

```

3) 查询加载结果

```
hive (gmall)> select * from dwt_sku_topic limit 5;
```

6.4 活动主题宽表



活动主题宽表



1) 建表语句

```

drop table if exists dwt_activity_topic;
create external table dwt_activity_topic(
  `id` string COMMENT '活动id',
  `activity_name` string COMMENT '活动名称',
  `order_day_count` bigint COMMENT '当日下单次数',
  `payment_day_count` bigint COMMENT '当日支付次数',
  `order_count` bigint COMMENT '累积下单次数',
  `payment_count` bigint COMMENT '累积支付次数'
) COMMENT '活动主题宽表'
stored as parquet
location '/warehouse/gmall/dwt/dwt_activity_topic/'
tblproperties ("parquet.compression"="lzo");


```

2) 数据装载

```

insert overwrite table dwt_activity_topic
select
  nvl(new.id,old.id),
  nvl(new.activity_name,old.activity_name),
  nvl(new.order_count,0),
  nvl(new.payment_count,0),
  nvl(old.order_count,0)+nvl(new.order_count,0),
  nvl(old.payment_count,0)+nvl(new.payment_count,0)
from
(
  select
    *
  from dwt_activity_topic
)old
full outer join
(
  select
    id,
    activity_name,
    order_count,
    payment_count
  from dws_activity_info_daycount
  where dt='2020-06-14'
)new
on old.id=new.id;

```



让天下没有难学的技术

1) 建表语句

```

hive (gmall)>
drop table if exists dwt_activity_topic;
create external table dwt_activity_topic(
  `id` string COMMENT '编号',
  `activity_name` string COMMENT '活动名称',
  `activity_type` string COMMENT '活动类型',
  `start_time` string COMMENT '开始时间',
  `end_time` string COMMENT '结束时间',
  `create_time` string COMMENT '创建时间',
  `display_day_count` bigint COMMENT '当日曝光次数',
  `order_day_count` bigint COMMENT '当日下单次数',
  `order_day_amount` decimal(20,2) COMMENT '当日下单金额',
  `payment_day_count` bigint COMMENT '当日支付次数',

```

```
`payment_day_amount` decimal(20,2) COMMENT '当日支付金额',
`display_count` bigint COMMENT '累积曝光次数',
`order_count` bigint COMMENT '累积下单次数',
`order_amount` decimal(20,2) COMMENT '累积下单金额',
`payment_count` bigint COMMENT '累积支付次数',
`payment_amount` decimal(20,2) COMMENT '累积支付金额'
) COMMENT '活动主题宽表'
stored as parquet
location '/warehouse/gmall/dwt/dwt_activity_topic/'
tblproperties ("parquet.compression"="lzo");
```

2) 数据装载

```
hive (gmall)>
insert overwrite table dwt_activity_topic
select
  nvl(new.id,old.id),
  nvl(new.activity_name,old.activity_name),
  nvl(new.activity_type,old.activity_type),
  nvl(new.start_time,old.start_time),
  nvl(new.end_time,old.end_time),
  nvl(new.create_time,old.create_time),
  nvl(new.display_count,0),
  nvl(new.order_count,0),
  nvl(new.order_amount,0.0),
  nvl(new.payment_count,0),
  nvl(new.payment_amount,0.0),
  nvl(new.display_count,0)+nvl(old.display_count,0),
  nvl(new.order_count,0)+nvl(old.order_count,0),
  nvl(new.order_amount,0.0)+nvl(old.order_amount,0.0),
  nvl(new.payment_count,0)+nvl(old.payment_count,0),
  nvl(new.payment_amount,0.0)+nvl(old.payment_amount,0.0)
from
(
  select
    *
  from dwt_activity_topic
)old
full outer join
(
  select
    *
  from dws_activity_info_daycount
  where dt='2020-06-14'
)new
on old.id=new.id;
```

3) 查询加载结果

```
hive (gmall)> select * from dwt_activity_topic limit 5;
```

6.5 地区主题宽表

1) 建表语句

```
hive (gmall)>
drop table if exists dwt_area_topic;
create external table dwt_area_topic(
  `id` bigint COMMENT '编号',
  `province_name` string COMMENT '省份名称',
  `area_code` string COMMENT '地区编码',
  `iso_code` string COMMENT 'iso 编码',
  `region_id` string COMMENT '地区 ID',
```

```
`region_name` string COMMENT '地区名称',
`login_day_count` string COMMENT '当天活跃设备数',
`login_last_30d_count` string COMMENT '最近 30 天活跃设备数',
`order_day_count` bigint COMMENT '当天下单次数',
`order_day_amount` decimal(16,2) COMMENT '当天下单金额',
`order_last_30d_count` bigint COMMENT '最近 30 天下单次数',
`order_last_30d_amount` decimal(16,2) COMMENT '最近 30 天下单金额',
`payment_day_count` bigint COMMENT '当天支付次数',
`payment_day_amount` decimal(16,2) COMMENT '当天支付金额',
`payment_last_30d_count` bigint COMMENT '最近 30 天支付次数',
`payment_last_30d_amount` decimal(16,2) COMMENT '最近 30 天支付金额'
) COMMENT '地区主题宽表'
stored as parquet
location '/warehouse/gmall/dwt/dwt_area_topic/'
tblproperties ("parquet.compression"="lzo");
```

2) 数据装载

```
hive (gmall)>
insert overwrite table dwt_area_topic
select
    nvl(old.id,new.id),
    nvl(old.province_name,new.province_name),
    nvl(old.area_code,new.area_code),
    nvl(old.iso_code,new.iso_code),
    nvl(old.region_id,new.region_id),
    nvl(old.region_name,new.region_name),
    nvl(new.login_day_count,0),
    nvl(new.login_last_30d_count,0),
    nvl(new.order_day_count,0),
    nvl(new.order_day_amount,0.0),
    nvl(new.order_last_30d_count,0),
    nvl(new.order_last_30d_amount,0.0),
    nvl(new.payment_day_count,0),
    nvl(new.payment_day_amount,0.0),
    nvl(new.payment_last_30d_count,0),
    nvl(new.payment_last_30d_amount,0.0)
from
(
    select
        *
    from dwt_area_topic
)old
full outer join
(
    select
        id,
        province_name,
        area_code,
        iso_code,
        region_id,
        region_name,
        sum(if(dt='2020-06-14',login_count,0)) login_day_count,
        sum(if(dt='2020-06-14',order_count,0)) order_day_count,
        sum(if(dt='2020-06-14',order_amount,0.0)) order_day_amount,
        sum(if(dt='2020-06-14',payment_count,0)) payment_day_count,
        sum(if(dt='2020-06-14',payment_amount,0.0)) payment_day_amount,
        sum(login_count) login_last_30d_count,
        sum(order_count) order_last_30d_count,
        sum(order_amount) order_last_30d_amount,
        sum(payment_count) payment_last_30d_count,
        sum(payment_amount) payment_last_30d_amount
    from dws_area_stats_daycount
```

更多 [Java](#) - [大数据](#) - [前端](#) - [python](#) 人工智能资料下载, 可百度访问: [尚硅谷官网](#)

```
where dt>=date_add('2020-06-14',-30)
group by id,province_name,area_code,iso_code,region_id,region_name
)new
on old.id=new.id;
```

3) 查询加载结果

```
hive (gmall)> select * from dwt_area_topic limit 5;
```

6.6 DWT 层数据导入脚本

1) 在/home/atguigu/bin 目录下创建脚本 dws_to_dwt.sh

```
[atguigu@hadoop102 bin]$ vim dws_to_dwt.sh
```

在脚本中填写如下内容

```
#!/bin/bash

APP=gmall
hive=/opt/module/hive/bin/hive

# 如果是输入的日期按照取输入日期； 如果没输入日期取当前时间的前一天
if [ -n "$1" ] ;then
    do_date=$1
else
    do_date=`date -d "-1 day" +%F`
fi

sql="
set mapreduce.job.queueName=hive;
insert overwrite table ${APP}.dwt_uv_topic
select
    nvl(new.mid_id,old.mid_id),
    nvl(new.model,old.model),
    nvl(new.brand,old.brand),
    if(old.mid_id is null,'$do_date',old.login_date_first),
    if(new.mid_id is not null,'$do_date',old.login_date_last),
    if(new.mid_id is not null, new.login_count,0),
    nvl(old.login_count,0)+if(new.login_count>0,1,0)
from
(
    select
        *
    from ${APP}.dwt_uv_topic
)old
full outer join
(
    select
        *
    from ${APP}.dws_uv_detail_daycount
    where dt='$do_date'
)new
on old.mid_id=new.mid_id;

insert overwrite table ${APP}.dwt_user_topic
select
    nvl(new.user_id,old.user_id),
    if(old.login_date_first is null and
new.login_count>0,'$do_date',old.login_date_first),
    if(new.login_count>0,'$do_date',old.login_date_last),
    nvl(old.login_count,0)+if(new.login_count>0,1,0),
    nvl(new.login_last_30d_count,0),
    if(old.order_date_first is null and
```

```
new.order_count>0,'$do_date',old.order_date_first),
    if(new.order_count>0,'$do_date',old.order_date_last),
    nvl(old.order_count,0)+nvl(new.order_count,0),
    nvl(old.order_amount,0)+nvl(new.order_amount,0),
    nvl(new.order_last_30d_count,0),
    nvl(new.order_last_30d_amount,0),
    if(old.payment_date_first is null and
new.payment_count>0,'$do_date',old.payment_date_first),
    if(new.payment_count>0,'$do_date',old.payment_date_last),
    nvl(old.payment_count,0)+nvl(new.payment_count,0),
    nvl(old.payment_amount,0)+nvl(new.payment_amount,0),
    nvl(new.payment_last_30d_count,0),
    nvl(new.payment_last_30d_amount,0)
from
${APP}.dwt_user_topic old
full outer join
(
    select
        user_id,
        sum(if(dt='$do_date',login_count,0)) login_count,
        sum(if(dt='$do_date',order_count,0)) order_count,
        sum(if(dt='$do_date',order_amount,0)) order_amount,
        sum(if(dt='$do_date',payment_count,0)) payment_count,
        sum(if(dt='$do_date',payment_amount,0)) payment_amount,
        sum(if(login_count>0,1,0)) login_last_30d_count,
        sum(order_count) order_last_30d_count,
        sum(order_amount) order_last_30d_amount,
        sum(payment_count) payment_last_30d_count,
        sum(payment_amount) payment_last_30d_amount
    from ${APP}.dws_user_action_daycount
    where dt>=date_add( '$do_date',-30)
    group by user_id
)new
on old.user_id=new.user_id;

insert overwrite table ${APP}.dwt_sku_topic
select
    nvl(new.sku_id,old.sku_id),
    sku_info.spu_id,
    nvl(new.order_count30,0),
    nvl(new.order_num30,0),
    nvl(new.order_amount30,0),
    nvl(old.order_count,0) + nvl(new.order_count,0),
    nvl(old.order_num,0) + nvl(new.order_num,0),
    nvl(old.order_amount,0) + nvl(new.order_amount,0),
    nvl(new.payment_count30,0),
    nvl(new.payment_num30,0),
    nvl(new.payment_amount30,0),
    nvl(old.payment_count,0) + nvl(new.payment_count,0),
    nvl(old.payment_num,0) + nvl(new.payment_num,0),
    nvl(old.payment_amount,0) + nvl(new.payment_amount,0),
    nvl(new.refund_count30,0),
    nvl(new.refund_num30,0),
    nvl(new.refund_amount30,0),
    nvl(old.refund_count,0) + nvl(new.refund_count,0),
    nvl(old.refund_num,0) + nvl(new.refund_num,0),
    nvl(old.refund_amount,0) + nvl(new.refund_amount,0),
    nvl(new.cart_count30,0),
    nvl(old.cart_count,0) + nvl(new.cart_count,0),
    nvl(new.favor_count30,0),
    nvl(old.favor_count,0) + nvl(new.favor_count,0),
    nvl(new.appraise_good_count30,0),
    nvl(new.appraise_mid_count30,0),
```

```
    nvl(new.appraise_bad_count30,0),
    nvl(new.appraise_default_count30,0) ,
    nvl(old.appraise_good_count,0) + nvl(new.appraise_good_count,0),
    nvl(old.appraise_mid_count,0) + nvl(new.appraise_mid_count,0),
    nvl(old.appraise_bad_count,0) + nvl(new.appraise_bad_count,0),
    nvl(old.appraise_default_count,0) + nvl(new.appraise_default_count,0)
from
(
    select
        sku_id,
        spu_id,
        order_last_30d_count,
        order_last_30d_num,
        order_last_30d_amount,
        order_count,
        order_num,
        order_amount ,
        payment_last_30d_count,
        payment_last_30d_num,
        payment_last_30d_amount,
        payment_count,
        payment_num,
        payment_amount,
        refund_last_30d_count,
        refund_last_30d_num,
        refund_last_30d_amount,
        refund_count,
        refund_num,
        refund_amount,
        cart_last_30d_count,
        cart_count,
        favor_last_30d_count,
        favor_count,
        appraise_last_30d_good_count,
        appraise_last_30d_mid_count,
        appraise_last_30d_bad_count,
        appraise_last_30d_default_count,
        appraise_good_count,
        appraise_mid_count,
        appraise_bad_count,
        appraise_default_count
    from ${APP}.dwt_sku_topic
)old
full outer join
(
    select
        sku_id,
        sum(if(dt='$do_date', order_count,0 )) order_count,
        sum(if(dt='$do_date',order_num ,0 )) order_num,
        sum(if(dt='$do_date',order_amount,0 )) order_amount ,
        sum(if(dt='$do_date',payment_count,0 )) payment_count,
        sum(if(dt='$do_date',payment_num,0 )) payment_num,
        sum(if(dt='$do_date',payment_amount,0 )) payment_amount,
        sum(if(dt='$do_date',refund_count,0 )) refund_count,
        sum(if(dt='$do_date',refund_num,0 )) refund_num,
        sum(if(dt='$do_date',refund_amount,0 )) refund_amount,
        sum(if(dt='$do_date',cart_count,0 )) cart_count,
        sum(if(dt='$do_date',favor_count,0 )) favor_count,
        sum(if(dt='$do_date',appraise_good_count,0 )) appraise_good_count,
        sum(if(dt='$do_date',appraise_mid_count,0 )) appraise_mid_count ,
        sum(if(dt='$do_date',appraise_bad_count,0 )) appraise_bad_count,
        sum(if(dt='$do_date',appraise_default_count,0 ))
    appraise_default_count,
```

```
sum(order_count) order_count30 ,
sum(order_num) order_num30,
sum(order_amount) order_amount30,
sum(payment_count) payment_count30,
sum(payment_num) payment_num30,
sum(payment_amount) payment_amount30,
sum(refund_count) refund_count30,
sum(refund_num) refund_num30,
sum(refund_amount) refund_amount30,
sum(cart_count) cart_count30,
sum(favor_count) favor_count30,
sum(appraise_good_count) appraise_good_count30,
sum(appraise_mid_count) appraise_mid_count30,
sum(appraise_bad_count) appraise_bad_count30,
sum(appraise_default_count) appraise_default_count30
from ${APP}.dws_sku_action_daycount
where dt >= date_add ('$do_date', -30)
group by sku_id
)new
on new.sku_id = old.sku_id
left join
(select * from ${APP}.dwd_dim_sku_info where dt='$do_date') sku_info
on nvl(new.sku_id,old.sku_id)= sku_info.id;

insert overwrite table ${APP}.dwt_activity_topic
select
nvl(new.id,old.id),
nvl(new.activity_name,old.activity_name),
nvl(new.activity_type,old.activity_type),
nvl(new.start_time,old.start_time),
nvl(new.end_time,old.end_time),
nvl(new.create_time,old.create_time),
nvl(new.display_count,0),
nvl(new.order_count,0),
nvl(new.order_amount,0.0),
nvl(new.payment_count,0),
nvl(new.payment_amount,0.0),
nvl(new.display_count,0)+nvl(old.display_count,0),
nvl(new.order_count,0)+nvl(old.order_count,0),
nvl(new.order_amount,0.0)+nvl(old.order_amount,0.0),
nvl(new.payment_count,0)+nvl(old.payment_count,0),
nvl(new.payment_amount,0.0)+nvl(old.payment_amount,0.0)
from
(
select
*
from ${APP}.dwt_activity_topic
)old
full outer join
(
select
*
from ${APP}.dws_activity_info_daycount
where dt='$do_date'
)new
on old.id=new.id;

insert overwrite table ${APP}.dwt_area_topic
select
nvl(old.id,new.id),
nvl(old.province_name,new.province_name),
nvl(old.area_code,new.area_code),
nvl(old.iso_code,new.iso_code),
```

```
    nvl(old.region_id,new.region_id),
    nvl(old.region_name,new.region_name),
    nvl(new.login_day_count,0),
    nvl(new.login_last_30d_count,0),
    nvl(new.order_day_count,0),
    nvl(new.order_day_amount,0.0),
    nvl(new.order_last_30d_count,0),
    nvl(new.order_last_30d_amount,0.0),
    nvl(new.payment_day_count,0),
    nvl(new.payment_day_amount,0.0),
    nvl(new.payment_last_30d_count,0),
    nvl(new.payment_last_30d_amount,0.0)
from
(
    select
        *
    from ${APP}.dwt_area_topic
)old
full outer join
(
    select
        id,
        province_name,
        area_code,
        iso_code,
        region_id,
        region_name,
        sum(if(dt='$do_date',login_count,0)) login_day_count,
        sum(if(dt='$do_date',order_count,0)) order_day_count,
        sum(if(dt='$do_date',order_amount,0.0)) order_day_amount,
        sum(if(dt='$do_date',payment_count,0)) payment_day_count,
        sum(if(dt='$do_date',payment_amount,0.0)) payment_day_amount,
        sum(login_count) login_last_30d_count,
        sum(order_count) order_last_30d_count,
        sum(order_amount) order_last_30d_amount,
        sum(payment_count) payment_last_30d_count,
        sum(payment_amount) payment_last_30d_amount
    from ${APP}.dws_area_stats_daycount
    where dt>=date_add('$do_date',-30)
    group by id,province_name,area_code,iso_code,region_id,region_name
)new
on old.id=new.id;
"

$hive -e "$sql"
```

2) 增加脚本执行权限

```
[atguigu@hadoop102 bin]$ chmod 777 dws_to_dwt.sh
```

3) 执行脚本导入数据

```
[atguigu@hadoop102 bin]$ dws_to_dwt.sh 2020-06-15
```

4) 查看导入数据

```
hive (gmall)>
select * from dwt_uv_topic limit 5;
select * from dwt_user_topic limit 5;
select * from dwt_sku_topic limit 5;
select * from dwt_activity_topic limit 5;
select * from dwt_area_topic limit 5;
```

第7章 数仓搭建-ADS层

7.1 建表说明

ADS层不涉及建模，建表根据具体需求而定。

7.2 设备主题

7.2.1 活跃设备数（日、周、月）

需求定义：

日活：当日活跃的**设备数**

周活：当周活跃的**设备数**

月活：当月活跃的**设备数**

1) 建表语句

```
hive (gmall)>
drop table if exists ads_uv_count;
create external table ads_uv_count(
    `dt` string COMMENT '统计日期',
    `day_count` bigint COMMENT '当日用户数量',
    `wk_count` bigint COMMENT '当周用户数量',
    `mn_count` bigint COMMENT '当月用户数量',
    `is_weekend` string COMMENT 'Y,N 是否是周末,用于得到本周最终结果',
    `is_monthend` string COMMENT 'Y,N 是否是月末,用于得到本月最终结果'
) COMMENT '活跃设备数'
row format delimited fields terminated by '\t'
location '/warehouse/gmall/ads/ads_uv_count/';
```

2) 导入数据

```
hive (gmall)>
insert into table ads_uv_count
select
    '2020-06-14' dt,
    daycount.ct,
    wkcount.ct,
    mncount.ct,
    if(date_add(next_day('2020-06-14','MO'),-1)='2020-06-14','Y','N') ,
    if(last_day('2020-06-14')='2020-06-14','Y','N')
from
(
    select
        '2020-06-14' dt,
        count(*) ct
    from dwt_uv_topic
    where login_date_last='2020-06-14'
)daycount join
(
    select
        '2020-06-14' dt,
        count (*) ct
    from dwt_uv_topic
    where login_date_last>=date_add(next_day('2020-06-14','MO'),-7)
    and login_date_last<= date_add(next_day('2020-06-14','MO'),-1)
```

更多 [Java](#) - [大数据](#) - [前端](#) - [python](#) 人工智能资料下载，可百度访问：[尚硅谷官网](#)

```
) wkcount on daycount.dt=wkcount.dt
join
(
    select
        '2020-06-14' dt,
        count (*) ct
    from dwt_uv_topic
    where date_format(login_date_last,'yyyy-MM')=date_format('2020-06-14','yyyy-MM')
)mncount on daycount.dt=mncount.dt;
```

3) 查询导入结果

```
hive (gmall)> select * from ads_uv_count;
```

7.2.2 每日新增设备

1) 建表语句

```
hive (gmall)>
drop table if exists ads_new_mid_count;
create external table ads_new_mid_count
(
    `create_date`      string comment '创建时间' ,
    `new_mid_count`    BIGINT comment '新增设备数量'
) COMMENT '每日新增设备数量'
row format delimited fields terminated by '\t'
location '/warehouse/gmall/ads/ads_new_mid_count/';
```

2) 导入数据

```
hive (gmall)>
insert into table ads_new_mid_count
select
    '2020-06-14',
    count(*)
from dwt_uv_topic
where login_date_first='2020-06-14';
```

3) 查询导入数据

```
hive (gmall)> select * from ads_new_mid_count;
```

7.2.3 留存率

用户留存



留存用户：某段时间内的新增用户（活跃用户），经过一段时间后，又继续使用应用的被认作是留存用户；

留存率：留存用户占当时新增用户（活跃用户）的比例即是留存率。

例如，6月14日新增用户100，这100人在6月15日启动过应用的有30人，6月16日启动过应用的有25人，6月17日启动过应用的有32人；

则6月14日新增用户次日的留存率是 $30/100 = 30\%$ ，两日留存率是 $25/100=25\%$ ，三日留存率是 $32/100=32\%$ 。

时间	新增用户	1天后	2天后	3天后
2020-06-14	100	30% (6-15)	25% (6-16)	32% (6-17)
2020-06-15	200	20% (6-16)	15% (6-17)	
2020-06-16	100	25% (6-17)		
2020-06-17				

让天下没有难学的技术

1) 建表语句

```
hive (gmall)>
drop table if exists ads_user_retention_day_rate;
create external table ads_user_retention_day_rate
(
    `stat_date`          string comment '统计日期',
    `create_date`        string comment '设备新增日期',
    `retention_day`      int comment '截止当前日期留存天数',
    `retention_count`    bigint comment '留存数量',
    `new_mid_count`      bigint comment '设备新增数量',
    `retention_ratio`    decimal(16,2) comment '留存率'
) COMMENT '留存率'
row format delimited fields terminated by '\t'
location '/warehouse/gmall/ads/ads_user_retention_day_rate/';
```

2) 导入数据

```
hive (gmall)>
insert into table ads_user_retention_day_rate
select
    '2020-06-15',
    date_add('2020-06-15',-1),
    1,--留存天数
    sum(if(login_date_first=date_add('2020-06-15',-1) and
login_date_last='2020-06-15',1,0)),
    sum(if(login_date_first=date_add('2020-06-15',-1),1,0)),
    sum(if(login_date_first=date_add('2020-06-15',-1) and
login_date_last='2020-06-15',1,0))/sum(if(login_date_first=date_add('2020-06-15',-1),1,0))*100
from dwt_uv_topic

union all

select
    '2020-06-15',
    date_add('2020-06-15',-2),
    2,
    sum(if(login_date_first=date_add('2020-06-15',-2) and
```

```
login_date_last='2020-06-15',1,0)),
    sum(if(login_date_first=date_add('2020-06-15',-2),1,0)),
    sum(if(login_date_first=date_add('2020-06-15',-2) and
login_date_last='2020-06-15',1,0))/sum(if(login_date_first=date_add('2020-
06-15',-2),1,0))*100
from dwt_uv_topic

union all

select
    '2020-06-15',
    date_add('2020-06-15',-3),
    3,
    sum(if(login_date_first=date_add('2020-06-15',-3) and
login_date_last='2020-06-15',1,0)),
    sum(if(login_date_first=date_add('2020-06-15',-3),1,0)),
    sum(if(login_date_first=date_add('2020-06-15',-3) and
login_date_last='2020-06-15',1,0))/sum(if(login_date_first=date_add('2020-
06-15',-3),1,0))*100
from dwt_uv_topic;
```

3) 查询导入数据

```
hive (gmall)>select * from ads_user_retention_day_rate;
```

7.2.4 沉默用户数

需求定义:

沉默用户: 只在安装当天启动过, 且启动时间是在 7 天前

1) 建表语句

```
hive (gmall)>
drop table if exists ads_silent_count;
create external table ads_silent_count(
    `dt` string COMMENT '统计日期',
    `silent_count` bigint COMMENT '沉默设备数'
) COMMENT '沉默用户数'
row format delimited fields terminated by '\t'
location '/warehouse/gmall/ads/ads_silent_count';
```

2) 导入 2020-06-25 数据

```
hive (gmall)>
insert into table ads_silent_count
select
    '2020-06-25',
    count(*)
from dwt_uv_topic
where login_date_first=login_date_last
and login_date_last<=date_add('2020-06-25',-7);
```

3) 查询导入数据

```
hive (gmall)> select * from ads_silent_count;
```

7.2.5 本周回流用户数

需求定义:

本周回流用户: 上周末活跃, 本周活跃的设备, 且不是本周新增设备

1) 建表语句

更多 [Java](#) - [大数据](#) - [前端](#) - [python](#) 人工智能资料下载, 可百度访问: [尚硅谷官网](#)

```
hive (gmall)>
drop table if exists ads_back_count;
create external table ads_back_count(
  `dt` string COMMENT '统计日期',
  `wk_dt` string COMMENT '统计日期所在周',
  `wastage_count` bigint COMMENT '回流设备数'
) COMMENT '本周回流用户数'
row format delimited fields terminated by '\t'
location '/warehouse/gmall/ads/ads_back_count';
```

2) 导入数据:

```
hive (gmall)>
insert into table ads_back_count
select
  '2020-06-25',
  concat(date_add(next_day('2020-06-25','MO'),-7),'_'),
  date_add(next_day('2020-06-25','MO'),-1)),
  count(*)
from
(
  select
    mid_id
  from dwt_uv_topic
  where login_date_last>=date_add(next_day('2020-06-25','MO'),-7)
  and login_date_last<= date_add(next_day('2020-06-25','MO'),-1)
  and login_date_first<date_add(next_day('2020-06-25','MO'),-7)
)current_wk
left join
(
  select
    mid_id
  from dws_uv_detail_daycount
  where dt>=date_add(next_day('2020-06-25','MO'),-7*2)
  and dt<= date_add(next_day('2020-06-25','MO'),-7-1)
  group by mid_id
)last_wk
on current_wk.mid_id=last_wk.mid_id
where last_wk.mid_id is null;
```

3) 查询结果

```
hive (gmall)> select * from ads_back_count;
```

7.2.6 流失用户数

需求定义:

流失用户: 最近 7 天未活跃的设备

1) 建表语句

```
hive (gmall)>
drop table if exists ads_wastage_count;
create external table ads_wastage_count(
  `dt` string COMMENT '统计日期',
  `wastage_count` bigint COMMENT '流失设备数'
) COMMENT '流失用户数'
row format delimited fields terminated by '\t'
location '/warehouse/gmall/ads/ads_wastage_count';
```

2) 导入 2020-06-25 数据

```
hive (gmall)>
insert into table ads_wastage_count
```

更多 [Java](#) - [大数据](#) - [前端](#) - [python](#) 人工智能资料下载, 可百度访问: [尚硅谷官网](#)

```
select
    '2020-06-25',
    count(*)
from
(
    select
        mid_id
    from dwt_uv_topic
    where login_date_last<=date_add('2020-06-25',-7)
    group by mid_id
) t1;
```

3) 查询结果

```
hive (gmall)> select * from ads_wastage_count;
```

7.2.7 最近连续三周活跃用户数

1) 建表语句

```
hive (gmall)>
drop table if exists ads_continuity_wk_count;
create external table ads_continuity_wk_count(
    `dt` string COMMENT '统计日期, 一般用结束周周日日期, 如果每天计算一次, 可用当天日期',
    `wk_dt` string COMMENT '持续时间',
    `continuity_count` bigint COMMENT '活跃用户数'
) COMMENT '最近连续三周活跃用户数'
row format delimited fields terminated by '\t'
location '/warehouse/gmall/ads/ads_continuity_wk_count';
```

2) 导入 2020-06-25 所在周的数据

```
hive (gmall)>
insert into table ads_continuity_wk_count
select
    '2020-06-25',
    concat(date_add(next_day('2020-06-25','MO'),-
7*3),'_',date_add(next_day('2020-06-25','MO'),-1)),
    count(*)
from
(
    select
        mid_id
    from
    (
        select
            mid_id
        from dws_uv_detail_daycount
        where dt>=date_add(next_day('2020-06-25','monday'),-7)
        and dt<=date_add(next_day('2020-06-25','monday'),-1)
        group by mid_id

        union all

        select
            mid_id
        from dws_uv_detail_daycount
        where dt>=date_add(next_day('2020-06-25','monday'),-7*2)
        and dt<=date_add(next_day('2020-06-25','monday'),-7-1)
        group by mid_id

        union all

        select
```

```
        mid_id
    from dws_uv_detail_daycount
    where dt>=date_add(next_day('2020-06-25','monday'),-7*3)
    and dt<=date_add(next_day('2020-06-25','monday'),-7*2-1)
    group by mid_id
) t1
group by mid_id
having count(*)=3
) t2;
```

3) 查询

```
hive (gmall)> select * from ads_continuity_wk_count;
```

7.2.8 最近七天内连续三天活跃用户数

1) 建表语句

```
hive (gmall)>
drop table if exists ads_continuity_uv_count;
create external table ads_continuity_uv_count (
    `dt` string COMMENT '统计日期',
    `wk_dt` string COMMENT '最近 7 天日期',
    `continuity_count` bigint
) COMMENT '最近七天内连续三天活跃用户数'
row format delimited fields terminated by '\t'
location '/warehouse/gmall/ads/ads_continuity_uv_count';
```

2) 写出导入数据的 SQL 语句

```
hive (gmall)>
insert into table ads_continuity_uv_count
select
    '2020-06-16',
    concat(date_add('2020-06-16',-6),'_', '2020-06-16'),
    count(*)
from
(
    select mid_id
    from
    (
        select mid_id
        from
        (
            select
                mid_id,
                date_sub(dt,rank) date_dif
            from
            (
                select
                    mid_id,
                    dt,
                    rank() over(partition by mid_id order by dt) rank
                from dws_uv_detail_daycount
                where dt>=date_add('2020-06-16',-6) and dt<='2020-06-16'
            ) t1
        ) t2
        group by mid_id,date_dif
        having count(*)>=3
    ) t3
    group by mid_id
) t4;
```

3) 查询

```
hive (gmall)> select * from ads_continuity_uv_count;
```

7.3 会员主题

7.3.1 会员信息

1) 建表

```
hive (gmall)>
drop table if exists ads_user_topic;
create external table ads_user_topic(
  `dt` string COMMENT '统计日期',
  `day_users` string COMMENT '活跃会员数',
  `day_new_users` string COMMENT '新增会员数',
  `day_new_payment_users` string COMMENT '新增消费会员数',
  `payment_users` string COMMENT '总付费会员数',
  `users` string COMMENT '总会员数',
  `day_users2users` decimal(16,2) COMMENT '会员活跃率',
  `payment_users2users` decimal(16,2) COMMENT '会员付费率',
  `day_new_users2users` decimal(16,2) COMMENT '会员新鲜度'
) COMMENT '会员信息表'
row format delimited fields terminated by '\t'
location '/warehouse/gmall/ads/ads_user_topic';
```

2) 导入数据

```
hive (gmall)>
insert into table ads_user_topic
select
  '2020-06-14',
  sum(if(login_date_last='2020-06-14',1,0)),
  sum(if(login_date_first='2020-06-14',1,0)),
  sum(if(payment_date_first='2020-06-14',1,0)),
  sum(if(payment_count>0,1,0)),
  count(*),
  sum(if(login_date_last='2020-06-14',1,0))/count(*),
  sum(if(payment_count>0,1,0))/count(*),
  sum(if(login_date_first='2020-06-14',1,0))/sum(if(login_date_last='2020-06-14',1,0))
from dwt_user_topic;
```

3) 查询数据

```
hive (gmall)> select * from ads_user_topic;
```

7.3.2 漏斗分析

统计“浏览首页->浏览商品详情页->加入购物车->下单->支付”的转化率

思路：统计各个行为的人数，然后计算比值。

1) 建表语句

```
hive (gmall)>
drop table if exists ads_user_action_convert_day;
create external table ads_user_action_convert_day(
  `dt` string COMMENT '统计日期',
  `home_count` bigint COMMENT '浏览首页人数',
  `good_detail_count` bigint COMMENT '浏览商品详情页人数',
  `home2good_detail_convert_ratio` decimal(16,2) COMMENT '首页到商品详情转化率',
  `cart_count` bigint COMMENT '加入购物车的人数',
```

```
`good_detail2cart_convert_ratio` decimal(16,2) COMMENT '商品详情页到加入购物车转化率',
`order_count` bigint COMMENT '下单人数',
`cart2order_convert_ratio` decimal(16,2) COMMENT '加入购物车到下单转化率',
`payment_amount` bigint COMMENT '支付人数',
`order2payment_convert_ratio` decimal(16,2) COMMENT '下单到支付的转化率'
) COMMENT '漏斗分析'
row format delimited fields terminated by '\t'
location '/warehouse/gmall/ads/ads_user_action_convert_day/';
```

2) 数据装载

```
hive (gmall)>
with
tmp_uv as
(
    select
        '2020-06-14' dt,
        sum(if(array_contains(pages,'home'),1,0)) home_count,
        sum(if(array_contains(pages,'good_detail'),1,0)) good_detail_count
    from
        (
            select
                mid_id,
                collect_set(page_id) pages
            from dwd_page_log
            where dt='2020-06-14'
            and page_id in ('home','good_detail')
            group by mid_id
        ) tmp
),
tmp_cop as
(
    select
        '2020-06-14' dt,
        sum(if(cart_count>0,1,0)) cart_count,
        sum(if(order_count>0,1,0)) order_count,
        sum(if(payment_count>0,1,0)) payment_count
    from dws_user_action_daycount
    where dt='2020-06-14'
)
insert into table ads_user_action_convert_day
select
    tmp_uv.dt,
    tmp_uv.home_count,
    tmp_uv.good_detail_count,
    tmp_uv.good_detail_count/tmp_uv.home_count*100,
    tmp_cop.cart_count,
    tmp_cop.cart_count/tmp_uv.good_detail_count*100,
    tmp_cop.order_count,
    tmp_cop.order_count/tmp_cop.cart_count*100,
    tmp_cop.payment_count,
    tmp_cop.payment_count/tmp_cop.order_count*100
from tmp_uv
join tmp_cop
on tmp_uv.dt=tmp_cop.dt;
```

3) 查询加载数据

```
hive (gmall)> select * from ads_user_action_convert_day;
```

7.4 商品主题

7.4.1 商品个数信息

1) 建表语句

```
hive (gmall)>
drop table if exists ads_product_info;
create external table ads_product_info(
  `dt` string COMMENT '统计日期',
  `sku_num` string COMMENT 'sku 个数',
  `spu_num` string COMMENT 'spu 个数'
) COMMENT '商品个数信息'
row format delimited fields terminated by '\t'
location '/warehouse/gmall/ads/ads_product_info';
```

2) 导入数据

```
hive (gmall)>
insert into table ads_product_info
select
  '2020-06-14' dt,
  sku_num,
  spu_num
from
(
  select
    '2020-06-14' dt,
    count(*) sku_num
  from
    dwt_sku_topic
) tmp_sku_num
join
(
  select
    '2020-06-14' dt,
    count(*) spu_num
  from
  (
    select
      spu_id
    from
      dwt_sku_topic
    group by
      spu_id
  ) tmp_spu_id
) tmp_spu_num
on tmp_sku_num.dt=tmp_spu_num.dt;
```

3) 查询结果数据

```
hive (gmall)> select * from ads_product_info;
```

7.4.2 商品销量排名

1) 建表语句

```
hive (gmall)>
drop table if exists ads_product_sale_topN;
create external table ads_product_sale_topN(
  `dt` string COMMENT '统计日期',
  `sku_id` string COMMENT '商品 ID',
```

```
`payment_amount` bigint COMMENT '销量'
) COMMENT '商品销量排名'
row format delimited fields terminated by '\t'
location '/warehouse/gmall/ads/ads_product_sale_topN';
```

2) 导入数据

```
hive (gmall)>
insert into table ads_product_sale_topN
select
    '2020-06-14' dt,
    sku_id,
    payment_amount
from
    dws_sku_action_daycount
where
    dt='2020-06-14'
order by payment_amount desc
limit 10;
```

3) 查询结果数据

```
hive (gmall)> select * from ads_product_sale_topN;
```

7.4.3 商品收藏排名

1) 建表语句

```
hive (gmall)>
drop table if exists ads_product_favor_topN;
create external table ads_product_favor_topN(
    `dt` string COMMENT '统计日期',
    `sku_id` string COMMENT '商品 ID',
    `favor_count` bigint COMMENT '收藏量'
) COMMENT '商品收藏排名'
row format delimited fields terminated by '\t'
location '/warehouse/gmall/ads/ads_product_favor_topN';
```

2) 导入数据

```
hive (gmall)>
insert into table ads_product_favor_topN
select
    '2020-06-14' dt,
    sku_id,
    favor_count
from
    dws_sku_action_daycount
where
    dt='2020-06-14'
order by favor_count desc
limit 10;
```

3) 查询数据

```
hive (gmall)> select * from ads_product_favor_topN;
```

7.4.4 商品加入购物车排名

1) 建表语句

```
hive (gmall)>
drop table if exists ads_product_cart_topN;
create external table ads_product_cart_topN(
    `dt` string COMMENT '统计日期',
    `sku_id` string COMMENT '商品 ID',
```

```
`cart_count` bigint COMMENT '加入购物车次数'
) COMMENT '商品加入购物车排名'
row format delimited fields terminated by '\t'
location '/warehouse/gmall/ads/ads_product_cart_topN';
```

2) 导入数据

```
hive (gmall)>
insert into table ads_product_cart_topN
select
    '2020-06-14' dt,
    sku_id,
    cart_count
from
    dws_sku_action_daycount
where
    dt='2020-06-14'
order by cart_count desc
limit 10;
```

3) 查询数据

```
hive (gmall)> select * from ads_product_cart_topN;
```

7.4.5 商品退款率排名（最近 30 天）

1) 建表语句

```
hive (gmall)>
drop table if exists ads_product_refund_topN;
create external table ads_product_refund_topN(
    `dt` string COMMENT '统计日期',
    `sku_id` string COMMENT '商品 ID',
    `refund_ratio` decimal(16,2) COMMENT '退款率'
) COMMENT '商品退款率排名'
row format delimited fields terminated by '\t'
location '/warehouse/gmall/ads/ads_product_refund_topN';
```

2) 导入数据

```
hive (gmall)>
insert into table ads_product_refund_topN
select
    '2020-06-14',
    sku_id,
    refund_last_30d_count/payment_last_30d_count*100 refund_ratio
from dwt_sku_topic
order by refund_ratio desc
limit 10;
```

3) 查询数据

```
hive (gmall)> select * from ads_product_refund_topN;
```

7.4.6 商品差评率

1) 建表语句

```
hive (gmall)>
drop table if exists ads_appraise_bad_topN;
create external table ads_appraise_bad_topN(
    `dt` string COMMENT '统计日期',
    `sku_id` string COMMENT '商品 ID',
    `appraise_bad_ratio` decimal(16,2) COMMENT '差评率'
) COMMENT '商品差评率'
```

```
row format delimited fields terminated by '\t'
location '/warehouse/gmall/ads/ads_appraise_bad_topN';
```

2) 导入数据

```
hive (gmall)>
insert into table ads_appraise_bad_topN
select
    '2020-06-14' dt,
    sku_id,
    appraise_bad_count/(appraise_good_count+appraise_mid_count+appraise_bad_count+appraise_default_count) appraise_bad_ratio
from
    dws_sku_action_daycount
where
    dt='2020-06-14'
order by appraise_bad_ratio desc
limit 10;
```

3) 查询数据

```
hive (gmall)> select * from ads_appraise_bad_topN;
```

7.5 营销主题（用户+商品+购买行为）

7.5.1 下单数目统计

需求分析：统计每日下单数，下单金额及下单用户数。

1) 建表语句

```
hive (gmall)>
drop table if exists ads_order_daycount;
create external table ads_order_daycount(
    dt string comment '统计日期',
    order_count bigint comment '单日下单笔数',
    order_amount bigint comment '单日下单金额',
    order_users bigint comment '单日下单用户数'
) comment '下单数目统计'
row format delimited fields terminated by '\t'
location '/warehouse/gmall/ads/ads_order_daycount';
```

2) 导入数据

```
hive (gmall)>
insert into table ads_order_daycount
select
    '2020-06-14',
    sum(order_count),
    sum(order_amount),
    sum(if(order_count>0,1,0))
from dws_user_action_daycount
where dt='2020-06-14';
```

3) 查询数据

```
hive (gmall)> select * from ads_order_daycount;
```

7.5.2 支付信息统计

每日支付金额、支付人数、支付商品数、支付笔数以及下单到支付的平均时长（取自 DWD）

1) 建表

```
hive (gmall)>
```

更多 [Java](#) - [大数据](#) - [前端](#) - [python](#) 人工智能资料下载，可百度访问：尚硅谷官网

```
drop table if exists ads_payment_daycount;
create external table ads_payment_daycount (
    dt string comment '统计日期',
    order_count bigint comment '单日支付笔数',
    order_amount bigint comment '单日支付金额',
    payment_user_count bigint comment '单日支付人数',
    payment_sku_count bigint comment '单日支付商品数',
    payment_avg_time decimal(16,2) comment '下单到支付的平均时长, 取分钟数'
) comment '支付信息统计'
row format delimited fields terminated by '\t'
location '/warehouse/gmall/ads/ads_payment_daycount';
```

2) 导入数据

```
hive (gmall)>
insert into table ads_payment_daycount
select
    tmp_payment.dt,
    tmp_payment.payment_count,
    tmp_payment.payment_amount,
    tmp_payment.payment_user_count,
    tmp_skucount.payment_sku_count,
    tmp_time.payment_avg_time
from
(
    select
        '2020-06-14' dt,
        sum(payment_count) payment_count,
        sum(payment_amount) payment_amount,
        sum(if(payment_count>0,1,0)) payment_user_count
    from dws_user_action_daycount
    where dt='2020-06-14'
) tmp_payment
join
(
    select
        '2020-06-14' dt,
        sum(if(payment_count>0,1,0)) payment_sku_count
    from dws_sku_action_daycount
    where dt='2020-06-14'
) tmp_skucount on tmp_payment.dt=tmp_skucount.dt
join
(
    select
        '2020-06-14' dt,
        sum(unix_timestamp(payment_time)-
            unix_timestamp(create_time))/count(*)/60 payment_avg_time
    from dwd_fact_order_info
    where dt='2020-06-14'
    and payment_time is not null
) tmp_time on tmp_payment.dt=tmp_time.dt;
```

3) 查询数据

```
hive (gmall)> select * from ads_payment_daycount;
```

7.5.3 品牌复购率

1) 建表语句

```
hive (gmall)>
drop table ads_sale_tm_category1_stat_mn;
create external table ads_sale_tm_category1_stat_mn
(
    tm_id string comment '品牌id',
```

更多 [Java](#) - [大数据](#) - [前端](#) - [python](#) 人工智能资料下载, 可百度访问: [尚硅谷官网](#)

```
category1_id string comment '1级品类id',
category1_name string comment '1级品类名称',
buycount bigint comment '购买人数',
buy_twice_last bigint comment '两次以上购买人数',
buy_twice_last_ratio decimal(16,2) comment '单次复购率',
buy_3times_last bigint comment '三次以上购买人数',
buy_3times_last_ratio decimal(16,2) comment '多次复购率',
stat_mn string comment '统计月份',
stat_date string comment '统计日期'
) COMMENT '品牌复购率统计'
row format delimited fields terminated by '\t'
location '/warehouse/gmall/ads/ads_sale_tm_category1_stat_mn/';
```

2) 数据导入

```
hive (gmall)>
with
tmp_order as
(
    select
        user_id,
        order_stats_struct.sku_id sku_id,
        order_stats_struct.order_count order_count
    from dws_user_action_daycount lateral view explode(order_detail_stats) tmp
    as order_stats_struct
    where date_format(dt,'yyyy-MM')=date_format('2020-06-14','yyyy-MM')
),
tmp_sku as
(
    select
        id,
        tm_id,
        category1_id,
        category1_name
    from dwd_dim_sku_info
    where dt='2020-06-14'
)
insert into table ads_sale_tm_category1_stat_mn
select
    tm_id,
    category1_id,
    category1_name,
    sum(if(order_count>=1,1,0)) buycount,
    sum(if(order_count>=2,1,0)) buyTwiceLast,
    sum(if(order_count>=2,1,0))/sum( if(order_count>=1,1,0)) buyTwiceLastRatio,
    sum(if(order_count>=3,1,0)) buy3timeLast ,
    sum(if(order_count>=3,1,0))/sum( if(order_count>=1,1,0))
    buy3timeLastRatio ,
    date_format('2020-06-14' ,'yyyy-MM') stat_mn,
    '2020-06-14' stat_date
from
(
    select
        tmp_order.user_id,
        tmp_sku.category1_id,
        tmp_sku.category1_name,
        tmp_sku.tm_id,
        sum(order_count) order_count
    from tmp_order
    join tmp_sku
    on tmp_order.sku_id=tmp_sku.id
    group
    tmp_order.user_id,tmp_sku.category1_id,tmp_sku.category1_name,tmp_sku.tm_id
```

```
)tmp  
group by tm_id, categoryl_id, categoryl_name;
```

3) 查询数据

```
hive (gmall)> select * from ads_sale_tm_categoryl_stat_mn;
```

7.6 地区主题

7.6.1 地区主题信息

1) 建表语句

```
hive (gmall)>  
drop table if exists ads_area_topic;  
create external table ads_area_topic(  
    `dt` string COMMENT '统计日期',  
    `id` bigint COMMENT '编号',  
    `province_name` string COMMENT '省份名称',  
    `area_code` string COMMENT '地区编码',  
    `iso_code` string COMMENT 'iso 编码',  
    `region_id` string COMMENT '地区 ID',  
    `region_name` string COMMENT '地区名称',  
    `login_day_count` bigint COMMENT '当天活跃设备数',  
    `order_day_count` bigint COMMENT '当天下单次数',  
    `order_day_amount` decimal(16,2) COMMENT '当天下单金额',  
    `payment_day_count` bigint COMMENT '当天支付次数',  
    `payment_day_amount` decimal(16,2) COMMENT '当天支付金额'  
) COMMENT '地区主题信息'  
row format delimited fields terminated by '\t'  
location '/warehouse/gmall/ads/ads_area_topic/';
```

2) 数据装载

```
hive (gmall)>  
insert into table ads_area_topic  
select  
    '2020-06-14',  
    id,  
    province_name,  
    area_code,  
    iso_code,  
    region_id,  
    region_name,  
    login_day_count,  
    order_day_count,  
    order_day_amount,  
    payment_day_count,  
    payment_day_amount  
from dwt_area_topic;
```

3) 查看结果

```
hive (gmall)> select * from ads_area_topic;
```

7.7 ADS 层导入脚本

1) 在/home/atguigu/bin 目录下创建脚本 dwt_to_ads.sh

```
[atguigu@hadoop102 bin]$ vim dwt_to_ads.sh
```

在脚本中填写如下内容

```
#!/bin/bash  
  
hive=/opt/module/hive/bin/hive  
APP=gmall
```

更多 [Java](#) - [大数据](#) - [前端](#) - [python](#) 人工智能资料下载，可百度访问：尚硅谷官网

```
# 如果是输入的日期按照取输入日期; 如果没输入日期取当前时间的前一天
if [ -n "$1" ] ;then
    do_date=$1
else
    do_date=`date -d "-1 day" +%F`
fi

sql="
set mapreduce.job.queueName=hive;
insert into table ${APP}.ads_uv_count
select
    '$do_date' dt,
    daycount.ct,
    wkcount.ct,
    mncount.ct,
    if(date_add(next_day('$do_date','MO'),-1)='$do_date','Y','N') ,
    if(last_day('$do_date')='$do_date','Y','N')
from
(
    select
        '$do_date' dt,
        count(*) ct
    from ${APP}.dwt_uv_topic
    where login_date_last='$do_date'
)daycount join
(
    select
        '$do_date' dt,
        count (*) ct
    from ${APP}.dwt_uv_topic
    where login_date_last>=date_add(next_day('$do_date','MO'),-7)
    and login_date_last<= date_add(next_day('$do_date','MO'),-1)
) wkcount on daycount.dt=wkcount.dt
join
(
    select
        '$do_date' dt,
        count (*) ct
    from ${APP}.dwt_uv_topic
    where
        date_format(login_date_last,'yyyy-MM')=date_format('$do_date','yyyy-MM')
)mncount on daycount.dt=mncount.dt;

insert into table ${APP}.ads_new_mid_count
select
    login_date_first,
    count(*)
from ${APP}.dwt_uv_topic
where login_date_first='$do_date'
group by login_date_first;

insert into table ${APP}.ads_silent_count
select
    '$do_date',
    count(*)
from ${APP}.dwt_uv_topic
where login_date_first=login_date_last
and login_date_last<=date_add('$do_date',-7);

insert into table ${APP}.ads_back_count
select
    '$do_date',
```

更多 [Java](#) -[大数据](#) -[前端](#) -[python](#) 人工智能资料下载, 可百度访问: [尚硅谷官网](#)

```
concat(date_add(next_day('$do_date','MO'),-7),'_',
date_add(next_day('$do_date','MO'),-1)),
count(*)
from
(
select
mid_id
from ${APP}.dwt_uv_topic
where login_date_last>=date_add(next_day('$do_date','MO'),-7)
and login_date_last<= date_add(next_day('$do_date','MO'),-1)
and login_date_first<date_add(next_day('$do_date','MO'),-7)
)current_wk
left join
(
select
mid_id
from ${APP}.dws_uv_detail_daycount
where dt>=date_add(next_day('$do_date','MO'),-7*2)
and dt<= date_add(next_day('$do_date','MO'),-7-1)
group by mid_id
)last_wk
on current_wk.mid_id=last_wk.mid_id
where last_wk.mid_id is null;

insert into table ${APP}.ads_wastage_count
select
'$do_date',
count(*)
from
(
select
mid_id
from ${APP}.dwt_uv_topic
where login_date_last<=date_add('$do_date',-7)
group by mid_id
)tl;

insert into table ${APP}.ads_user_retention_day_rate
select
'$do_date',--统计日期
date_add('$do_date',-1),--新增日期
1,--留存天数
sum(if(login_date_first=date_add('$do_date',-1) and
login_date_last='$do_date',1,0)),--$do_date 的 1 日留存数
sum(if(login_date_first=date_add('$do_date',-1),1,0)),--$do_date 新增
sum(if(login_date_first=date_add('$do_date',-1) and
login_date_last='$do_date',1,0))/sum(if(login_date_first=date_add('$do_date',-1),1,0))*100
from ${APP}.dwt_uv_topic

union all

select
'$do_date',--统计日期
date_add('$do_date',-2),--新增日期
2,--留存天数
sum(if(login_date_first=date_add('$do_date',-2) and
login_date_last='$do_date',1,0)),--$do_date 的 2 日留存数
sum(if(login_date_first=date_add('$do_date',-2),1,0)),--$do_date 新增
sum(if(login_date_first=date_add('$do_date',-2) and
login_date_last='$do_date',1,0))/sum(if(login_date_first=date_add('$do_date',-2),1,0))*100
```

```
from ${APP}.dwt_uv_topic

union all

select
    '$do_date',--统计日期
    date_add('$do_date',-3),--新增日期
    3,--留存天数
    sum(if(login_date_first=date_add('$do_date',-3) and
login_date_last='$do_date',1,0)),--$do_date 的 3 日留存数
    sum(if(login_date_first=date_add('$do_date',-3),1,0)),--$do_date 新增
    sum(if(login_date_first=date_add('$do_date',-3) and
login_date_last='$do_date',1,0))/sum(if(login_date_first=date_add('$do_date'
,-3),1,0))*100
from ${APP}.dwt_uv_topic;

insert into table ${APP}.ads_continuity_wk_count
select
    '$do_date',
    concat(date_add(next_day('$do_date','MO'),-
7*3),'_',date_add(next_day('$do_date','MO'),-1)),
    count(*)
from
(
    select
        mid_id
    from
    (
        select
            mid_id
        from ${APP}.dws_uv_detail_daycount
        where dt>=date_add(next_day('$do_date','monday'),-7)
        and dt<=date_add(next_day('$do_date','monday'),-1)
        group by mid_id

        union all

        select
            mid_id
        from ${APP}.dws_uv_detail_daycount
        where dt>=date_add(next_day('$do_date','monday'),-7*2)
        and dt<=date_add(next_day('$do_date','monday'),-7-1)
        group by mid_id

        union all

        select
            mid_id
        from ${APP}.dws_uv_detail_daycount
        where dt>=date_add(next_day('$do_date','monday'),-7*3)
        and dt<=date_add(next_day('$do_date','monday'),-7*2-1)
        group by mid_id
    )t1
    group by mid_id
    having count(*)=3
)t2;

insert into table ${APP}.ads_continuity_uv_count
select
    '$do_date',
```

```
concat(date_add('$do_date',-6),'_', '$do_date'),
count(*)
from
(
  select mid_id
  from
  (
    select mid_id
    from
    (
      select
        mid_id,
        date_sub(dt,rank) date_dif
      from
      (
        select
          mid_id,
          dt,
          rank() over(partition by mid_id order by dt) rank
        from ${APP}.dws_uv_detail_daycount
        where dt>=date_add('$do_date',-6) and dt<='$do_date'
      )t1
    )t2
    group by mid_id,date_dif
    having count(*)>=3
  )t3
  group by mid_id
)t4;

insert into table ${APP}.ads_user_topic
select
  '$do_date',
  sum(if(login_date_last='$do_date',1,0)),
  sum(if(login_date_first='$do_date',1,0)),
  sum(if(payment_date_first='$do_date',1,0)),
  sum(if(payment_count>0,1,0)),
  count(*),
  sum(if(login_date_last='$do_date',1,0))/count(*),
  sum(if(payment_count>0,1,0))/count(*),

sum(if(login_date_first='$do_date',1,0))/sum(if(login_date_last='$do_date',1,0))
from ${APP}.dwt_user_topic;

with
tmp_uv as
(
  select
    '$do_date' dt,
    sum(if(array_contains(pages,'home'),1,0)) home_count,
    sum(if(array_contains(pages,'good_detail'),1,0)) good_detail_count
  from
  (
    select
      mid_id,
      collect_set(page_id) pages
    from ${APP}.dwd_page_log
    where dt='$do_date'
    and page_id in ('home','good_detail')
    group by mid_id
  )tmp
),
```

```
tmp_cop as
(
    select
        '$do_date' dt,
        sum(if(cart_count>0,1,0)) cart_count,
        sum(if(order_count>0,1,0)) order_count,
        sum(if(payment_count>0,1,0)) payment_count
    from ${APP}.dws_user_action_daycount
    where dt='$do_date'
)
insert into table ${APP}.ads_user_action_convert_day
select
    tmp_uv.dt,
    tmp_uv.home_count,
    tmp_uv.good_detail_count,
    tmp_uv.good_detail_count/tmp_uv.home_count*100,
    tmp_cop.cart_count,
    tmp_cop.cart_count/tmp_uv.good_detail_count*100,
    tmp_cop.order_count,
    tmp_cop.order_count/tmp_cop.cart_count*100,
    tmp_cop.payment_count,
    tmp_cop.payment_count/tmp_cop.order_count*100
from tmp_uv
join tmp_cop
on tmp_uv.dt=tmp_cop.dt;

insert into table ${APP}.ads_product_info
select
    '$do_date' dt,
    sku_num,
    spu_num
from
(
    select
        '$do_date' dt,
        count(*) sku_num
    from
        ${APP}.dwt_sku_topic
) tmp_sku_num
join
(
    select
        '$do_date' dt,
        count(*) spu_num
    from
    (
        select
            spu_id
        from
            ${APP}.dwt_sku_topic
        group by
            spu_id
    ) tmp_spu_id
) tmp_spu_num
on
    tmp_sku_num.dt=tmp_spu_num.dt;

insert into table ${APP}.ads_product_sale_topN
select
    '$do_date' dt,
    sku_id,
    payment_amount
```

```
from
    ${APP}.dws_sku_action_daycount
where
    dt='${do_date}'
order by payment_amount desc
limit 10;

insert into table ${APP}.ads_product_favor_topN
select
    '${do_date}' dt,
    sku_id,
    favor_count
from
    ${APP}.dws_sku_action_daycount
where
    dt='${do_date}'
order by favor_count desc
limit 10;

insert into table ${APP}.ads_product_cart_topN
select
    '${do_date}' dt,
    sku_id,
    cart_count
from
    ${APP}.dws_sku_action_daycount
where
    dt='${do_date}'
order by cart_count desc
limit 10;

insert into table ${APP}.ads_product_refund_topN
select
    '${do_date}',
    sku_id,
    refund_last_30d_count/payment_last_30d_count*100 refund_ratio
from ${APP}.dwt_sku_topic
order by refund_ratio desc
limit 10;

insert into table ${APP}.ads_appraise_bad_topN
select
    '${do_date}' dt,
    sku_id,
    appraise_bad_count/(appraise_good_count+appraise_mid_count+appraise_bad_count+appraise_default_count) appraise_bad_ratio
from
    ${APP}.dws_sku_action_daycount
where
    dt='${do_date}'
order by appraise_bad_ratio desc
limit 10;

insert into table ${APP}.ads_order_daycount
select
    '${do_date}',
    sum(order_count),
    sum(order_amount),
    sum(if(order_count>0,1,0))
from ${APP}.dws_user_action_daycount
```

更多 [Java](#) - [大数据](#) - [前端](#) - [python](#) 人工智能资料下载，可百度访问：尚硅谷官网

```
where dt='${do_date}';

insert into table ${APP}.ads_payment_daycount
select
    tmp_payment.dt,
    tmp_payment.payment_count,
    tmp_payment.payment_amount,
    tmp_payment.payment_user_count,
    tmp_skucount.payment_sku_count,
    tmp_time.payment_avg_time
from
(
    select
        '${do_date}' dt,
        sum(payment_count) payment_count,
        sum(payment_amount) payment_amount,
        sum(if(payment_count>0,1,0)) payment_user_count
    from ${APP}.dws_user_action_daycount
    where dt='${do_date}'
) tmp_payment
join
(
    select
        '${do_date}' dt,
        sum(if(payment_count>0,1,0)) payment_sku_count
    from ${APP}.dws_sku_action_daycount
    where dt='${do_date}'
) tmp_skucount on tmp_payment.dt=tmp_skucount.dt
join
(
    select
        '${do_date}' dt,
        sum(unix_timestamp(payment_time)-
unix_timestamp(create_time))/count(*)/60 payment_avg_time
    from ${APP}.dwd_fact_order_info
    where dt='${do_date}'
    and payment_time is not null
) tmp_time on tmp_payment.dt=tmp_time.dt;

with
tmp_order as
(
    select
        user_id,
        order_stats_struct.sku_id sku_id,
        order_stats_struct.order_count order_count
    from
        ${APP}.dws_user_action_daycount lateral view
    explode(order_detail_stats) tmp as order_stats_struct
    where date_format(dt,'yyyy-MM')=date_format('${do_date}','yyyy-MM')
),
tmp_sku as
(
    select
        id,
        tm_id,
        category1_id,
        category1_name
    from ${APP}.dwd_dim_sku_info
    where dt='${do_date}'
)
insert into table ${APP}.ads_sale_tm_category1_stat_mn
```

更多 [Java](#) - [大数据](#) - [前端](#) - [python](#) 人工智能资料下载，可百度访问：尚硅谷官网

```
select
    tm_id,
    category1_id,
    category1_name,
    sum(if(order_count>=1,1,0)) buycount,
    sum(if(order_count>=2,1,0)) buyTwiceLast,
    sum(if(order_count>=2,1,0))/sum( if(order_count>=1,1,0)) buyTwiceLastRatio,
    sum(if(order_count>=3,1,0)) buy3timeLast ,
    sum(if(order_count>=3,1,0))/sum( if(order_count>=1,1,0))
buy3timeLastRatio ,
    date_format('$do_date' , 'yyyy-MM') stat_mn,
    '$do_date' stat_date
from
(
    select
        tmp_order.user_id,
        tmp_sku.category1_id,
        tmp_sku.category1_name,
        tmp_sku.tm_id,
        sum(order_count) order_count
    from tmp_order
    join tmp_sku
    on tmp_order.sku_id=tmp_sku.id
    group by
    tmp_order.user_id,tmp_sku.category1_id,tmp_sku.category1_name,tmp_sku.tm_id
)tmp
group by tm_id, category1_id, category1_name;

insert into table ${APP}.ads_area_topic
select
    '$do_date',
    id,
    province_name,
    area_code,
    iso_code,
    region_id,
    region_name,
    login_day_count,
    order_day_count,
    order_day_amount,
    payment_day_count,
    payment_day_amount
from ${APP}.dwt_area_topic;

"

$hive -e "$sql"
```

2) 增加脚本执行权限

```
[atguigu@hadoop102 bin]$ chmod 777 dwt_to_ads.sh
```

3) 执行脚本导入数据

```
[atguigu@hadoop102 bin]$ dwt_to_ads.sh 2020-06-15
```

4) 查看导入数据

```
hive (gmall)>
select * from ads_uv_count where dt='2020-06-15';
select * from ads_new_mid_count;
select * from ads_silent_count where dt='2020-06-15';
select * from ads_back_count where dt='2020-06-15';
select * from ads_wastage_count where dt='2020-06-15';
```

```
select * from ads_user_retention_day_rate;
select * from ads_continuity_wk_count where dt='2020-06-15';
select * from ads_continuity_uv_count where dt='2020-06-15';
select * from ads_user_topic where dt='2020-06-15';
select * from ads_user_action_convert_day where dt='2020-06-15';
select * from ads_product_info where dt='2020-06-15';
select * from ads_product_sale_topN where dt='2020-06-15';
select * from ads_product_favor_topN where dt='2020-06-15';
select * from ads_product_cart_topN where dt='2020-06-15';
select * from ads_product_refund_topN where dt='2020-06-15';
select * from ads_appraise_bad_topN where dt='2020-06-15';
select * from ads_order_daycount where dt='2020-06-15';
select * from ads_payment_daycount where dt='2020-06-15';
select * from ads_sale_tm_category1_stat_mn;
select * from ads_area_topic where dt='2020-06-15';
```

第 8 章 Azkaban 调度

8.1 Azkaban 部署

详见：尚硅谷大数据技术之 Azkaban



尚硅谷大数据技术
之Azkaban.docx

8.2 创建 MySQL 数据库和表

1) 创建 gmall_report 数据库

数据库名:	gmall_report
字符集:	utf8
排序规则:	utf8_general_ci

注:SQL 语句

```
CREATE DATABASE `gmall_report` CHARACTER SET 'utf8' COLLATE 'utf8_general_ci';
```

2) 创建表

(1) 创建用户主题表

```
DROP TABLE IF EXISTS `ads_user_topic`;
CREATE TABLE `ads_user_topic` (
  `dt` date NOT NULL,
  `day_users` bigint(255) NULL DEFAULT NULL,
  `day_new_users` bigint(255) NULL DEFAULT NULL,
  `day_new_payment_users` bigint(255) NULL DEFAULT NULL,
  `payment_users` bigint(255) NULL DEFAULT NULL,
  `users` bigint(255) NULL DEFAULT NULL,
  `day_users2users` double(255, 2) NULL DEFAULT NULL,
  `payment_users2users` double(255, 2) NULL DEFAULT NULL,
  `day_new_users2users` double(255, 2) NULL DEFAULT NULL,
  PRIMARY KEY (`dt`) USING BTREE
) ENGINE = InnoDB CHARACTER SET = utf8 COLLATE = utf8_general_ci ROW_FORMAT = Compact;
```

(2) 创建地区主题表

```
DROP TABLE IF EXISTS `ads_area_topic`;
CREATE TABLE `ads_area_topic` (
  `dt` date NOT NULL,
  `id` int(11) NULL DEFAULT NULL,
  `province_name` varchar(255) CHARACTER SET utf8 COLLATE utf8_general_ci
  NULL DEFAULT NULL,
  `area_code` varchar(255) CHARACTER SET utf8 COLLATE utf8_general_ci NULL
  DEFAULT NULL,
  `iso_code` varchar(255) CHARACTER SET utf8 COLLATE utf8_general_ci NOT
  NULL,
  `region_id` int(11) NULL DEFAULT NULL,
  `region_name` varchar(255) CHARACTER SET utf8 COLLATE utf8_general_ci
  NULL DEFAULT NULL,
  `login_day_count` bigint(255) NULL DEFAULT NULL,
  `order_day_count` bigint(255) NULL DEFAULT NULL,
  `order_day_amount` double(255, 2) NULL DEFAULT NULL,
  `payment_day_count` bigint(255) NULL DEFAULT NULL,
  `payment_day_amount` double(255, 2) NULL DEFAULT NULL,
  PRIMARY KEY (`dt`, `iso_code`) USING BTREE
) ENGINE = InnoDB CHARACTER SET = utf8 COLLATE = utf8_general_ci ROW_FORMAT
= Compact;
```

3) 其余 ads 层表 (略)

8.3 Sqoop 导出脚本

1) 编写 Sqoop 导出脚本

在/home/atguigu/bin 目录下创建脚本 hdfs_to_mysql.sh

```
[atguigu@hadoop102 bin]$ vim hdfs_to_mysql.sh
```

在脚本中填写如下内容

```
#!/bin/bash

hive_db_name=gmall
mysql_db_name=gmall_report

export_data() {
/opt/module/sqoop/bin/sqoop export \
-Dmapreduce.job.queueName=hive \
--connect
"jdbc:mysql://hadoop102:3306/${mysql_db_name}?useUnicode=true&characterEn
coding=utf-8" \
--username root \
--password 000000 \
--table $1 \
--num-mappers 1 \
--export-dir /warehouse/${hive_db_name}/ads/$1 \
--input-fields-terminated-by "\t" \
--update-mode allowinsert \
--update-key $2 \
--input-null-string '\\N' \
--input-null-non-string '\\N'
}

case $1 in
  "ads_uv_count")
    export_data "ads_uv_count" "dt"
  ;;
```

```
"ads_user_action_convert_day")
    export_data "ads_user_action_convert_day" "dt"
;;
"ads_user_topic")
    export_data "ads_user_topic" "dt"
;;
"ads_area_topic")
    export_data "ads_area_topic" "dt,iso_code"
;;
"all")
    export_data "ads_user_topic" "dt"
    export_data "ads_area_topic" "dt,iso_code"
    #其余表省略未写
;;
esac
```

关于导出 update 还是 insert 的问题

- --update-mode:
 updateonly 只更新, 无法插入新数据
 allowinsert 允许新增
- --update-key: 允许更新的情况下, 指定哪些字段匹配视为同一条数据, 进行更新而不增加。多个字段用逗号分隔。
- --input-null-string 和 --input-null-non-string:
 分别表示, 将字符串列和非字符串列的空串和“null”转义。

官网地址: <http://sqoop.apache.org/docs/1.4.6/SqoopUserGuide.html>

Sqoop will by default import NULL values as string null. Hive is however using string \N to denote NULL values and therefore predicates dealing with NULL (like IS NULL) will not work correctly. You should append parameters --null-string and --null-non-string in case of import job or --input-null-string and --input-null-non-string in case of an export job if you wish to properly preserve NULL values. Because sqoop is using those parameters in generated code, you need to properly escape value \N to \\N:

Hive 中的 Null 在底层是以 “\N” 来存储, 而 MySQL 中的 Null 在底层就是 Null, 为了保证数据两端的一致性。在导出数据时采用 --input-null-string 和 --input-null-non-string 两个参数。导入数据时采用 --null-string 和 --null-non-string。

3) 执行 Sqoop 导出脚本

```
[atguigu@hadoop102 bin]$ chmod 777 sqoop_export.sh
[atguigu@hadoop102 bin]$ sqoop_export.sh all
```

8.4 会员主题指标获取的全调度流程

8.4.1 数据准备

1) 用户行为数据准备

(1) 修改 /opt/module/applog 下的 application.properties

```
#业务日期
mock.date=2020-06-26
```

更多 Java - 大数据 - 前端 - python 人工智能资料下载, 可百度访问: 尚硅谷官网

注意：分发至其他需要生成数据的节点

```
[atguigu@hadoop102 applog]$ xsync application.properties
```

(2) 生成数据

```
[atguigu@hadoop102 bin]$ lg.sh
```

注意：生成数据之后，记得查看 HDFS 数据是否存在！

(3) 观察 HDFS 的/origin_data/gmall/log/topic_log/2020-06-26 路径是否有数据

/origin_data/gmall/log/topic_log/2020-06-26

Go!

Show 25 entries

Search:

	Permission	Owner	Group	Size	Last Modified	Replication	Block Size	Name	
	-rw-r--r--	atguigu	supergroup	52.45 KB	Jul 19 12:26	1	128 MB	log-1595132785386.1zo	

2) 业务数据准备

(1) 修改/opt/module/db_log 下的 application.properties

```
[atguigu@hadoop102 db_log]$ vim application.properties
#业务日期
mock.date=2020-06-26
```

(2) 生成数据

```
[atguigu@hadoop102 db_log]$ java -jar gmall2020-mock-db-2020-04-01.jar
```

(3) 观察 SLYog 中 order_infor 表中 operate_time 中有 2020-06-26 日期的数据

8.4.2 编译写 Azkaban 工作流程配置文件

1) 编写 azkaban.project 文件，内容如下

```
azkaban-flow-version: 2.0
```

2) 编写 gmall.flow 文件，内容如下

```
nodes:
- name: mysql_to_hdfs
  type: command
  config:
    command: /home/atguigu/bin/mysql_to_hdfs.sh all ${dt}

- name: hdfs_to_ods_log
  type: command
  config:
    command: /home/atguigu/bin/hdfs_to_ods_log.sh ${dt}
```

更多 Java -大数据 -前端 -python 人工智能资料下载，可百度访问：尚硅谷官网

```
- name: hdfs_to_ods_db
  type: command
  dependsOn:
    - mysql_to_hdfs
  config:
    command: /home/atguigu/bin/hdfs_to_ods_db.sh all ${dt}

- name: ods_to_dwd_log
  type: command
  dependsOn:
    - hdfs_to_ods_log
  config:
    command: /home/atguigu/bin/ods_to_dwd_log.sh ${dt}

- name: ods_to_dwd_db
  type: command
  dependsOn:
    - hdfs_to_ods_db
  config:
    command: /home/atguigu/bin/ods_to_dwd_db.sh all ${dt}

- name: dwd_to_dws
  type: command
  dependsOn:
    - ods_to_dwd_log
    - ods_to_dwd_db
  config:
    command: /home/atguigu/bin/dwd_to_dws.sh ${dt}

- name: dws_to_dwt
  type: command
  dependsOn:
    - dwd_to_dws
  config:
    command: /home/atguigu/bin/dws_to_dwt.sh ${dt}

- name: dwt_to_ads
  type: command
  dependsOn:
    - dws_to_dwt
  config:
    command: /home/atguigu/bin/dwt_to_ads.sh ${dt}

- name: hdfs_to_mysql
  type: command
  dependsOn:
    - dwt_to_ads
  config:
    command: /home/atguigu/bin/hdfs_to_mysql.sh all
```

3) 将 azkaban.project、gmall.flow 文件压缩到一个 zip 文件，文件名称必须是英文。




4) 在 WebServer 新建项目: <http://hadoop102:8081/index>



5) 给项目名称命名和添加项目描述




6) gmall.zip 文件上传



7) 选择上传的文件



8) 查看任务流



9) 详细任务流展示



10) 配置输入 dt 时间参数

Execute Flow gmall

Flow View

Notification

Failure Options

Concurrent

Flow Parameters

Add temporary flow parameters that are used to override global settings for each job.

定时调度

立即执行

Schedule Cancel Execute

Flow Property Override

Name	Value
dt	2020-06-26

Add Row

Flow submitted


Execution queued successfully with exec id 1

Continue

10) 执行成功



11) 在 SQLyog 上查看结果



dt	day_users	day_new_users	day_new_payment_users	payment_users	users	day_users2users	payment_users2users
2020-06-14	109	230	3	7	382	0.29	0.02
2020-06-15	53	49	4	7	382	0.14	0.02
2020-06-26	87	19	0	7	401	0.22	0.02
(NULL)	(NULL)	(NULL)	(NULL)	(NULL)	(NULL)	(NULL)	(NULL)

8.4.3 Azkaban 多 Executor 模式下注意事项

Azkaban 多 Executor 模式是指，在集群中多个节点部署 Executor。在这种模式下，Azkaban web Server 会根据策略，选取其中一个 Executor 去执行任务。

由于我们需要交给 Azkaban 调度的脚本，以及脚本需要的 Hive，Sqoop 等应用只在 hadoop102 部署了，为保证任务顺利执行，我们须在以下两种方案**任选其一，推荐使用方案二**。

方案一：指定特定的 Executor（hadoop102）去执行任务。

1) 在 MySQL 中 azkaban 数据库 executors 表中，查询 hadoop102 上的 Executor 的 id。


```

mysql> use azkaban;
Reading table information for completion of table and column names
You can turn off this feature to get a quicker startup with -A

Database changed
mysql> select * from executors;
+----+-----+-----+-----+
| id | host      | port | active |
+----+-----+-----+-----+
| 1  | hadoop103 | 35985 | 1      |
| 2  | hadoop104 | 36363 | 1      |
| 3  | hadoop102 | 12321 | 1      |
+----+-----+-----+-----+
    
```

3 rows in set (0.00 sec)

2) 在执行 workflows 时加入 useExecutor 属性，如下



The screenshot shows the 'Execute Flow gmall' interface. On the left, there are tabs for 'Flow View', 'Notification', 'Failure Options', 'Concurrent', and 'Flow Parameters' (which is selected and highlighted with a red box). The 'Flow Property Override' section on the right contains a table with two columns: 'Name' and 'Value'. A row is present with 'useExecutor' in the 'Name' column and '3' in the 'Value' column, highlighted with a red box. Below the table is an 'Add Row' button. At the bottom left is a 'Schedule' button, and at the bottom right are 'Cancel' and 'Execute' buttons.

Name	Value
useExecutor	3

方案二：在 Executor 所在所有节点部署任务所需脚本和应用。

1) 分发脚本、hive、sqoop、spark、my_env.sh

```
[atguigu@hadoop102 ~]$ xsync /home/atguigu/bin/
[atguigu@hadoop102 ~]$ xsync /opt/module/hive
[atguigu@hadoop102 ~]$ xsync /opt/module/sqoop
[atguigu@hadoop102 ~]$ xsync /opt/module/spark
[atguigu@hadoop102 ~]$ sudo /home/atguigu/bin/xsync
/etc/profile.d/my_env.sh
```