ALIBABA CLOUD

Alibaba Cloud

DataWorks

教程

文档版本：20220104

阿里云

法律声明

阿里云提醒您在阅读或使用本文档之前仔细阅读、充分理解本法律声明各条款的内容。如果您阅读或使用本文档，您的阅读或使用行为将被视为对本声明全部内容的认可。

1. 您应当通过阿里云网站或阿里云提供的其他授权通道下载、获取本文档，且仅能用于自身的合法合规的业务活动。本文档的内容视为阿里云的保密信息，您应当严格遵守保密义务；未经阿里云事先书面同意，您不得向任何第三方披露本手册内容或提供给任何第三方使用。

2. 未经阿里云事先书面许可，任何单位、公司或个人不得擅自摘抄、翻译、复制本文档内容的部分或全部，不得以任何方式或途径进行传播和宣传。

3. 由于产品版本升级、调整或其他原因，本文档内容有可能变更。阿里云保留在没有任何通知或者提示下对本文档的内容进行修改的权利，并在阿里云授权通道中不时发布更新后的用户文档。您应当实时关注用户文档的版本变更并通过阿里云授权渠道下载、获取最新版的用户文档。

4. 本文档仅作为用户使用阿里云产品及服务的参考性指引，阿里云以产品及服务的“现状”、“有缺陷”和“当前功能”的状态提供本文档。阿里云在现有技术的基础上尽最大努力提供相应的介绍及操作指引，但阿里云在此明确声明对本文档内容的准确性、完整性、适用性、可靠性等不作任何明示或暗示的保证。任何单位、公司或个人因为下载、使用或信赖本文档而发生任何差错或经济损失的，阿里云不承担任何法律责任。在任何情况下，阿里云均不对任何间接性、后果性、惩戒性、偶然性、特殊性或刑罚性的损害，包括用户使用或信赖本文档而遭受的利润损失，承担责任（即使阿里云已被告知该等损失的可能性）。

5. 阿里云网站上所有内容，包括但不限于著作、产品、图片、档案、资讯、资料、网站架构、网站画面的安排、网页设计，均由阿里云和/或其关联公司依法拥有其知识产权，包括但不限于商标权、专利权、著作权、商业秘密等。非经阿里云和/或其关联公司书面同意，任何人不得擅自使用、修改、复制、公开传播、改变、散布、发行或公开发表阿里云网站、产品程序或内容。此外，未经阿里云事先书面同意，任何人不得为了任何营销、广告、促销或其他目的使用、公布或复制阿里云的名称（包括但不限于单独为或以组合形式包含“阿里云”、“Aliyun”、“万网”等阿里云和/或其关联公司品牌，上述品牌的附属标志及图案或任何类似公司名称、商号、商标、产品或服务名称、域名、图案标示、标志、标识或通过特定描述使第三方能够识别阿里云和/或其关联公司）。

6. 如若发现本文档存在任何错误，请与阿里云取得直接联系。

通用约定

格式	说明	样例
危险	该类警示信息将导致系统重大变更甚至故障，或者导致人身伤害等结果。	危险 重置操作将丢失用户配置数据。
警告	该类警示信息可能会导致系统重大变更甚至故障，或者导致人身伤害等结果。	警告 重启操作将导致业务中断，恢复业务时间约十分钟。
注意	用于警示信息、补充说明等，是用户必须了解的内容。	注意 权重设置为0，该服务器不会再接受新请求。
说明	用于补充说明、最佳实践、窍门等，不是用户必须了解的内容。	说明 您也可以通过按Ctrl+A选中全部文件。
>	多级菜单递进。	单击**设置**> **网络**> **设置网络类型**。
粗体	表示按键、菜单、页面名称等UI元素。	在**结果确认**页面，单击**确定**。
Courier字体	命令或代码。	执行 `cd /d C:/window` 命令，进入Windows系统文件夹。
斜体	表示参数、变量。	`bae log list --instanceid` *Instance_ID*
[] 或者 [a|b]	表示可选项，至多选择一个。	`ipconfig [-all|-t]`
{} 或者 {a|b}	表示必选项，至多选择一个。	`switch {active|stand}`

目录

1.简单用户画像分析（MaxCompute版）

1.1. Workshop介绍

本模块为您介绍DataWorks的设计思路和核心功能，帮助您深入了解阿里云DataWorks。

教程概述

教程时长：2小时，采用在线学习的方式。

教程对象：面向Java工程师、产品运营等DataWorks所有的新老用户。只需要熟悉标准SQL，无需对数据仓库和MaxCompute的原理过多了解，即可快速掌握DataWorks的基本技能。建议您进一步学习DataWorks教程，深入了解DataWorks的基本概念及功能，详情请参见什么是DataWorks。

教程目标：以常见的真实的海量日志数据分析任务为教程背景，争取在完成教程后，您对DataWorks的主要功能有所了解。按照教程演示内容，独立通过MaxCompute计算引擎完成数据采集 、数据开发和任务运维等数据岗位常见的任务。

DataWorks简介

DataWorks是一站式大数据研发平台，上层有机融合数据集成、数据建模、数据开发、运维监控、数据管理、数据安全和数据质量等产品功能，同时与算法平台PAI打通，完善了从大数据开发到数据挖掘、机器学习的完整链路。

学习答疑

如果您在学习过程中遇到问题，请申请加入钉钉群进行咨询。

1.2. 准备环境

为保证您可以顺利完成本次实验，请您首先确保云账号已开通大数据计算服务MaxCompute和数据工场DataWorks。

前提条件

- 阿里云账号注册。
- 实名认证。

背景信息

本次实验涉及的阿里云产品如下：

- 大数据计算服务MaxCompute
- 数据工场DataWorks

开通大数据计算服务MaxCompute

> **说明** 如果您已经开通MaxCompute，请跳过该步骤，直接创建DataWorks工作空间。

1. 登录阿里云官网，单击右上角的**登录**，输入您的阿里云账号和密码。
2. 鼠标悬停至顶部菜单栏中的**产品**，单击**大数据 > 大数据计算与分析 > MaxCompute**，进入

MaxCompute产品详情页。

3. 单击**立即开通**。
4. 在购买页面，选择**地域**，并选中**服务协议**，单击**确认订单并支付**。

> **说明**
> - 购买页面默认提供的规格类型为MaxCompute按量计费标准版和DataWorks基础版。
> - MaxCompute的项目管理和查询编辑集成DataWorks的功能，因此需要同时开通DataWorks服务。DataWorks基础版为0元开通，如果您不使用数据集成、不执行调度任务，则不会产生费用。
> - 选择地域时，您需要考虑的最主要因素是MaxCompute与其它阿里云产品之间的关系。例如，ECS所在地域、数据所在地域等。

创建工作空间

> **说明** 因本实验提供的数据资源都在华东2（上海），建议您将工作空间创建在华东2（上海），以避免工作空间创建在其它区域，添加数据源时出现网络不可达的情况。

1. 使用主账号登录DataWorks控制台。
2. 在**概览**页面，单击右侧的**创建工作空间**。

   您也可以单击左侧导航栏中的**工作空间列表**，切换至相应的区域后，单击**创建工作空间**。
3. 配置**创建工作空间**对话框中的**基本配置**，单击**下一步**。

   > **说明** 本教程以标准模式的工作空间为例进行操作。

4. 进入**选择引擎**界面，勾选MaxCompute引擎后，单击**下一步**。

   DataWorks已正式商用，如果该区域没有开通，需要首先开通正式商用的服务。默认选中**数据集成**、**数据开发**、**运维中心**和**数据质量**。
5. 进入**引擎详情**页面，配置选购引擎的参数。

分类	参数	描述
MaxCompute	**实例显示名称**	实例显示名称不能超过27个字符，仅支持字母开头，仅包含字母、数字和下划线（_）。
	Quota组切换	Quota用于实现计算资源和磁盘配额。
	MaxCompute数据类型	该选项设置后，将在5分钟内生效。详情请参见数据类型版本说明
	MaxCompute项目名称	默认与DataWorks工作空间的名称一致。
	MaxCompute访问身份	包括**阿里云主账号**和**任务负责人**。

6. 配置完成后，单击**创建工作空间**。

   工作空间创建成功后，即可在**工作空间列表**页面查看相应内容。

1.3. 采集数据

本文为您介绍如何通过DataWorks采集日志数据至MaxCompute。

背景信息

根据本次实验模拟的场景，您需要分别创建OSS数据源和RDS数据源，并准备好相应的数据表。

> **说明**
> - 您可以直接使用本实验提供的数据源，也可以使用自己的数据源。
> - 因本实验提供的数据资源在**华东2(上海)**，建议您使用华东2（上海）的工作空间。以避免工作空间创建在其它区域，添加数据源时出现网络不可达的情况。

新建OSS数据源

1. 进入**数据源管理**页面。
   i. 登录DataWorks控制台。
   ii. 在左侧导航栏，单击**工作空间列表**。
   iii. 单击相应工作空间后的**进入数据集成**。

   如果您已在DataWorks的某个功能模块，请单击左上方的☰图标，选择**全部产品 > 数据汇聚 > 数据集成**，进入**数据集成**页面。
   iv. 在左侧导航栏，单击**数据源**，进入**工作空间管理 > 数据源管理**页面。
2. 在**数据源管理**页面，单击右上方的**新增数据源**。
3. 在**新增数据源**对话框中，选择数据源类型为**OSS**。
4. 在**新增OSS数据源**对话框，配置各项参数。

参数	描述
数据源名称	输入oss_workshop_log。
数据源描述	对数据源进行简单描述。
适用环境	勾选**开发**。 **说明** 开发环境的数据源创建完成后，需要勾选**生产**，以同样方式创建生产环境的数据源，否则任务生产执行会报错。
Endpoint	输入 `http://oss-cn-shanghai-internal.aliyuncs.com` 。
Bucket	输入new-dataworks-workshop。
AccessKey ID	输入LTAI4FvGT3iU4xjKotpUMAjS。
AccessKey Secret	输入9RSUoRmNxpRC9EhC4m9PjuG7Jzy7px。

5. 在资源组列表，单击相应资源组后的**测试连通性**。

   数据同步时，一个任务只能使用一种资源组。您需要测试每个资源组的连通性，以保证同步任务使用的数据集成资源组能够与数据源连通，否则将无法正常执行数据同步任务。如果您需要同时测试多种资源组，请选中相应资源组后，单击**批量测试连通性**。详情请参见选择网络连通方案。

> 说明
> - （推荐）资源组列表默认仅显示独享数据集成资源组，为确保数据同步的稳定性和性能要求，推荐使用独享数据集成资源组。
> - 如果您需要测试公共资源组或自定义资源组的连通性，请在资源组列表右下方，单击**更多选项**，在**警告**对话框单击**确定**，资源组列表会显示可供选择的公共资源组和自定义资源组。

6. 连通性测试通过后，单击**完成**。

> 说明
> - 如果测试连通性失败，请检查您的AccessKey ID、AccessKey Secret和工作空间所在区域。
> - 如果您无法使用内网Endpoint连接数据源，请改用公网Endpoint。

新建RDS数据源

1. 单击当前页面左上角的图标，选择**全部产品 > 数据汇聚 > 数据集成**。
2. 在左侧导航栏，单击**数据源 > 数据源列表**，进入**工作空间管理 > 数据源管理**页面。
3. 在**数据源管理**页面，单击右上方的**新增数据源**。
4. 在**新增数据源**对话框中，选择数据源类型为**MySQL**。
5. 在**新增MySQL数据源**对话框中，配置各项参数。

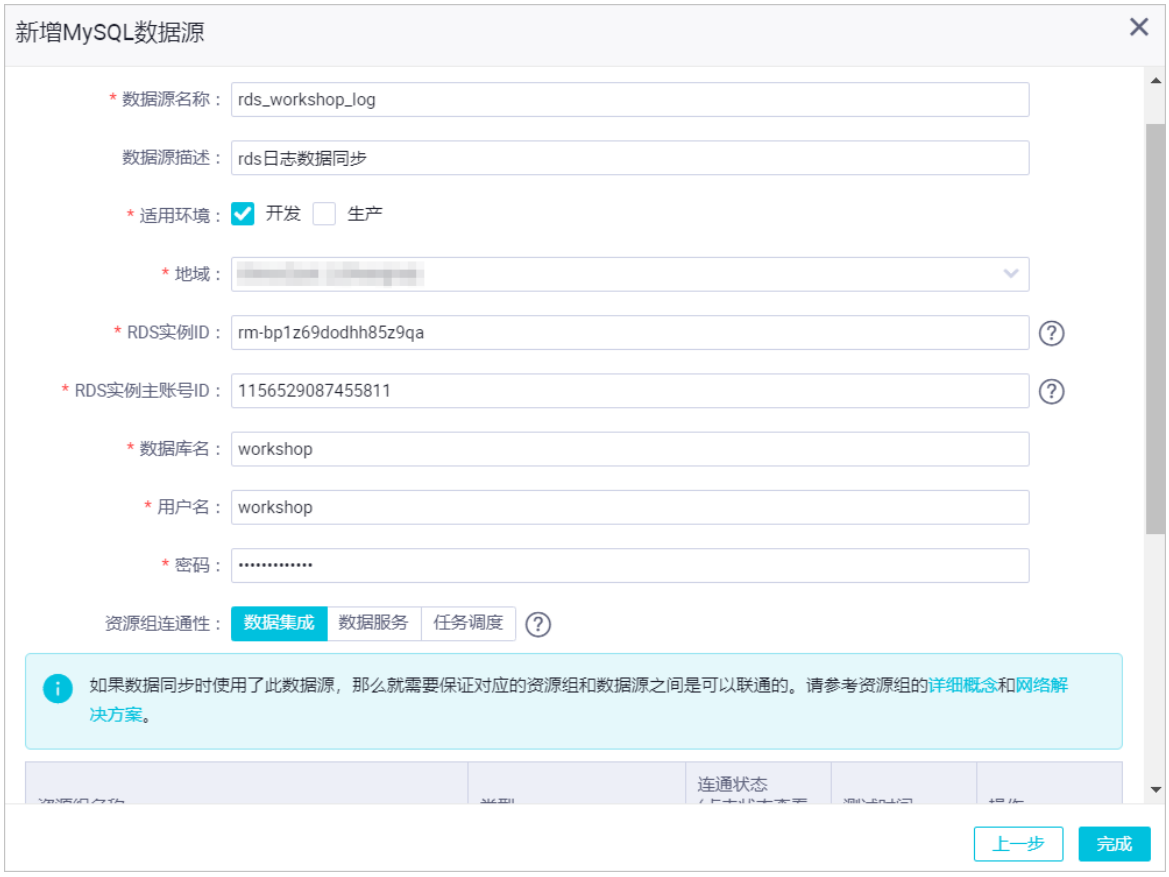

参数	描述
数据源类型	选择**阿里云实例模式**。
数据源名称	输入rds_workshop_log。
数据源描述	输入RDS日志数据同步。
适用环境	勾选**开发**。 **说明** 开发环境的数据源创建完成后，需要勾选**生产**，以同样方式创建生产环境的数据源，否则任务生产执行会报错。
地区	选择RDS实例所在的区域。
RDS实例ID	输入rm-bp1z69dodhh85z9qa。
RDS实例主账号ID	输入1156529087455811。
数据库名	输入workshop。
用户名	输入workshop。
密码	输入workshop#2017。

6. 在资源组列表，单击相应资源组后的**测试连通性**。

   数据同步时，一个任务只能使用一种资源组。您需要测试每个资源组的连通性，以保证同步任务使用的数据集成资源组能够与数据源连通，否则将无法正常执行数据同步任务。如果您需要同时测试多种资源组，请选中相应资源组后，单击**批量测试连通性**。详情请参见选择网络连通方案。

   说明
   - （推荐）资源组列表默认仅显示独享数据集成资源组，为确保数据同步的稳定性和性能要求，推荐使用独享数据集成资源组。
   - 如果您需要测试公共资源组或自定义资源组的连通性，请在资源组列表右下方，单击**更多选项**，在**警告**对话框单击**确定**，资源组列表会显示可供选择的公共资源组和自定义资源组。

7. 测试连通性通过后，单击**完成**。

创建业务流程

1. 单击当前页面左上方的图标，选择**全部产品 > 数据开发 > DataStudio（数据开发）**。
2. 在**数据开发**面板，右键单击**业务流程**，选择**新建业务流程**。
3. 在**新建业务流程**对话框中，输入**业务名称**和**描述**。

   注意 业务名称不能超过128个字符，且必须是大小写字母、中文、数字、下划线（_）以及小数点（.）。

4. 单击**新建**。
5. 进入业务流程开发面板，鼠标单击**虚拟节点**并拖拽至右侧的编辑页面。
6. 在**新建节点**对话框中，输入**节点名称**为workshop_start，单击**提交**。

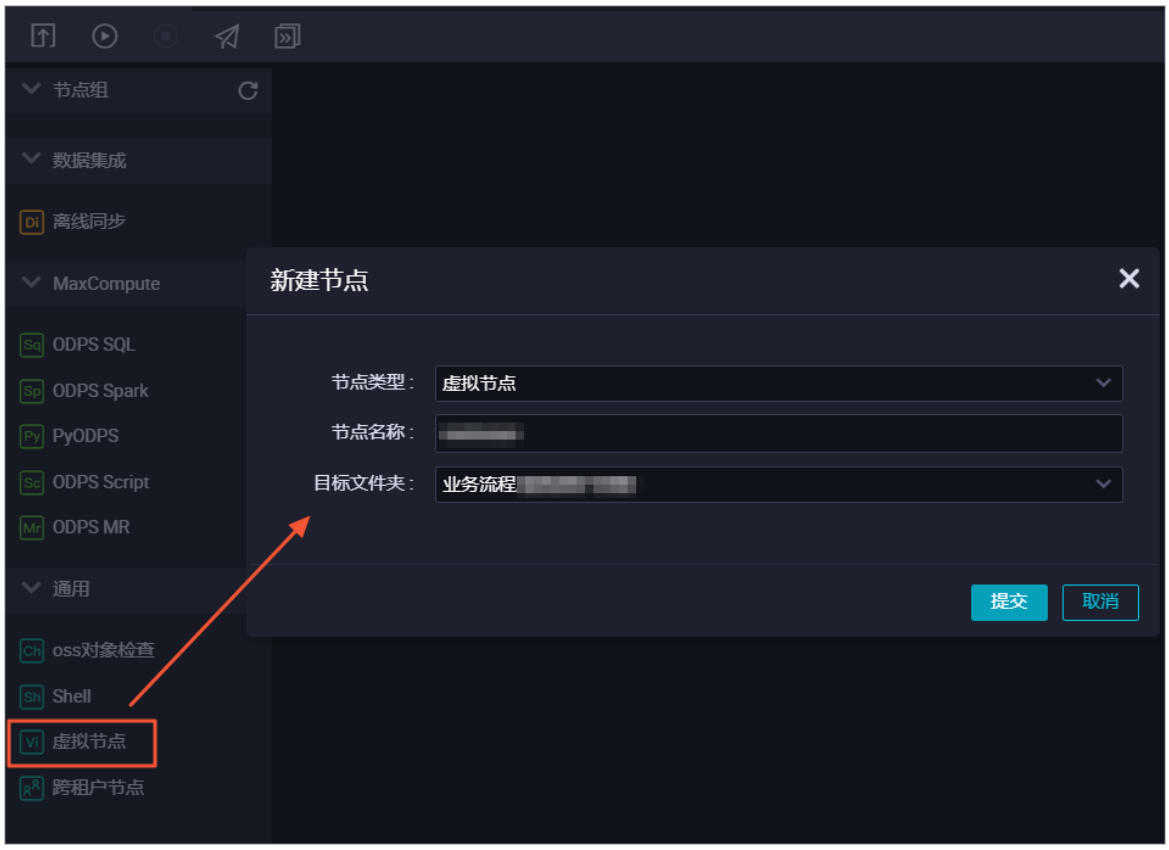

以同样的方式新建两个离线同步节点，**节点名称**分别为oss_数据同步和rds_数据同步。

7. 通过拖拽连线，将workshop_start节点设置为两个离线同步节点的上游节点。

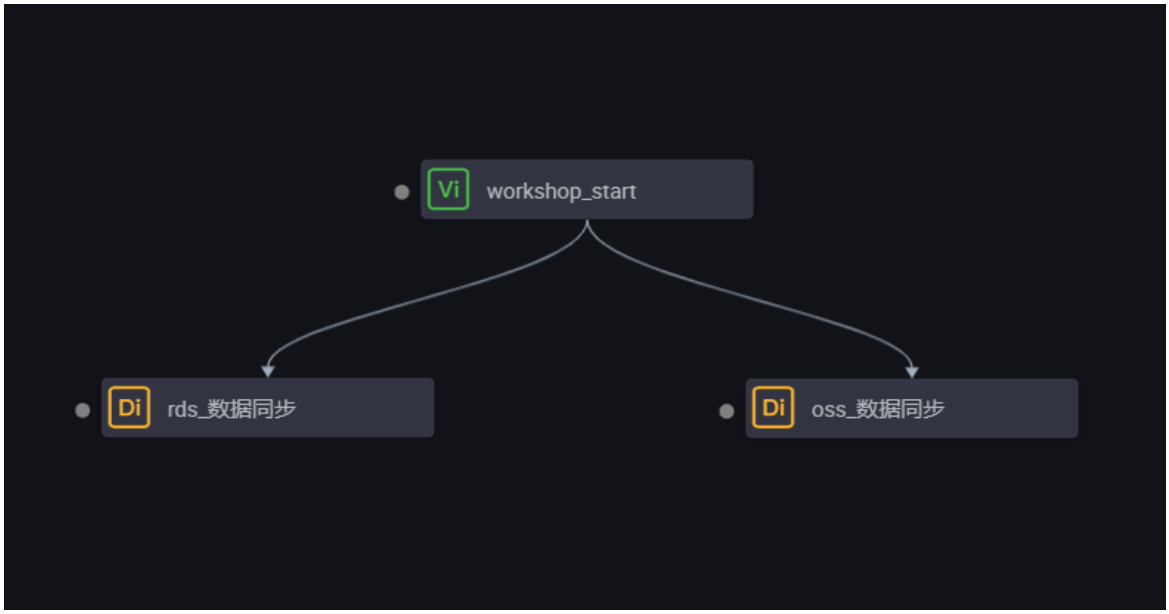

配置workshop_start节点

1. 在**数据开发**页面，双击相应业务流程下的虚拟节点。打开该节点的编辑页面，单击右侧的**调度配置**。
2. 在**调度依赖**区域，单击**使用工作空间根节点**，设置workshop_start节点的上游节点为工作空间根节点。

   由于新版本给每个节点都设置了输入输出节点，所以需要给workshop_start节点设置一个输入。此处设置其上游节点为工作空间根节点，通常命名为工作空间名称_root。

3. 配置完成后，单击工具栏中的图标。

新建表

1. 在**数据开发**页面打开新建的业务流程，右键单击**MaxCompute**，选择**新建 > 表**。

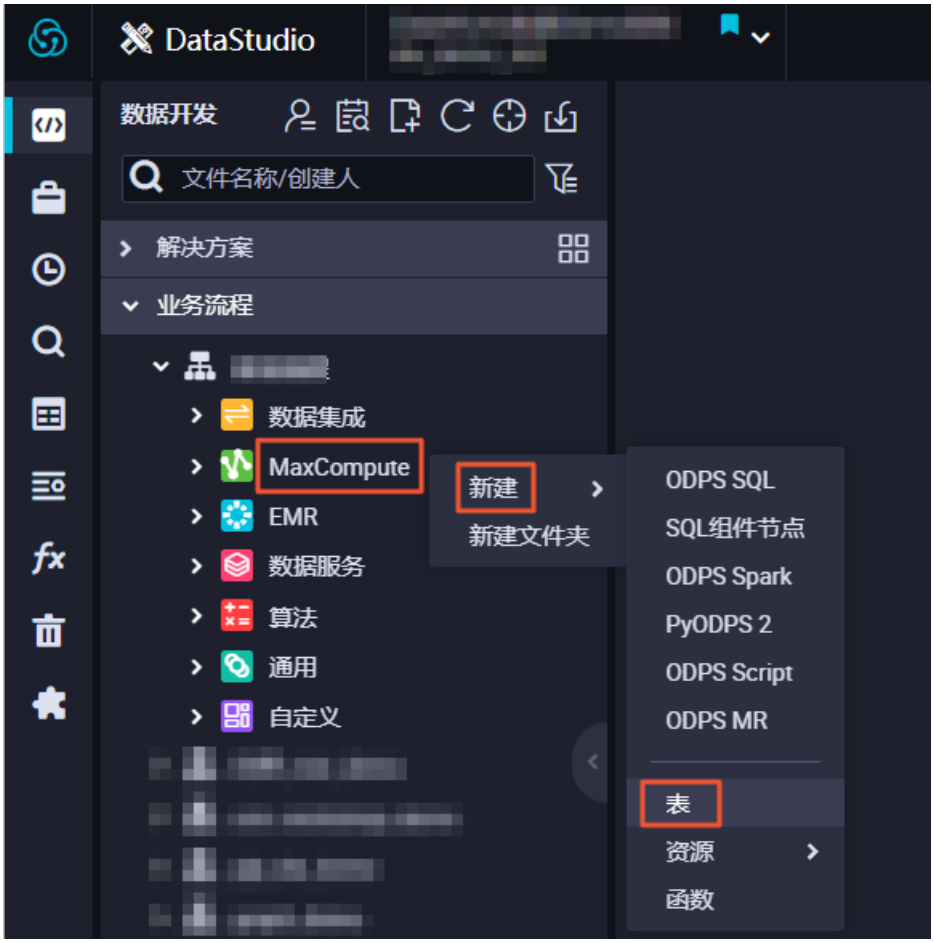

2. 在**新建表**对话框中，输入**表名**，单击**提交**。

   此处需要创建两张表（ods_raw_log_d和ods_user_info_d），分别存储同步过来的OSS日志数据和RDS日志数据。

   > **注意** 表名必须以字母开头，不能包含中文或特殊字符，且不能超过64个字符。

3. 通过DDL模式新建表。
   - 新建ods_raw_log_d表。

在表的编辑页面单击**DDL模式**，输入下述建表语句。


```
--创建OSS日志对应目标表
CREATE TABLE IF NOT EXISTS  ods_raw_log_d (
    col STRING
)
PARTITIONED BY (
    dt STRING
);
```

- 新建ods_user_info_d表。

  在表的编辑页面单击**DDL模式**，输入下述建表语句。

```
--创建RDS对应目标表
CREATE TABLE IF NOT  EXISTS ods_user_info_d (
    uid STRING COMMENT '用户ID',
    gender STRING COMMENT '性别',
    age_range STRING COMMENT '年龄段',
    zodiac STRING COMMENT '星座'
)
PARTITIONED BY (
    dt STRING
);
```

4. 单击**生成表结构**，并**确认**覆盖当前操作。

5. 返回建表页面，在**基本属性**中输入表的中文名。
6. 完成设置后，分别单击**提交到开发环境**和**提交到生产环境**。

配置离线同步节点

> **说明** 标准模式的工作空间下，不建议离线同步任务在开发环境下运行（开发面板直接运行），建议将其发布至生产环境后再测试运行，以获取完整的运行日志。
>
> 同时，数据产出至生产环境后，您可以申请数据权限，以读取写入开发环境中的表数据。

1. 配置oss_数据同步节点。
   i. 在**数据开发**页面，双击oss_数据同步节点，进入节点配置页面。

ii. 选择数据来源。

参数	描述
数据源	选择OSS > oss_workshop_log数据源。
Object前缀	输入OSS文件夹的路径，请勿填写Bucket的名称。示例为user_log.txt。
文本类型	选择text类型。
列分隔符	输入列分隔符为|。
编码格式	默认为UTF-8格式。
null值	表示null值的字符串。
压缩格式	包括None、Gzip、Bzip2和Zip四种类型，此处选择None。
是否包含表头	默认为No。

iii. 选择数据去向。

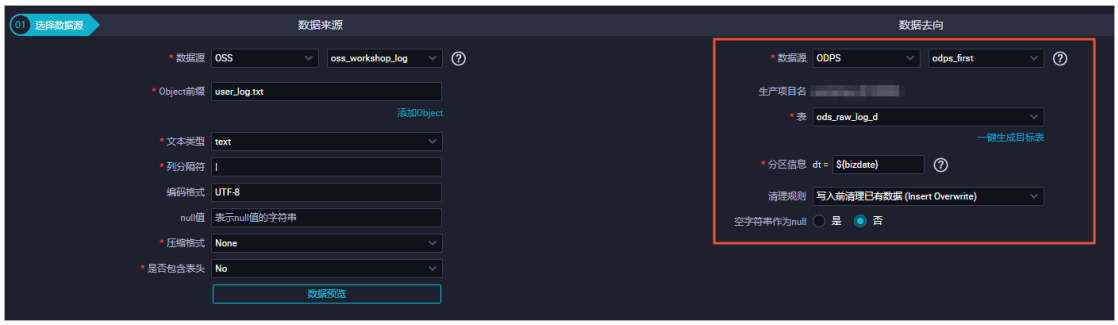

参数	描述
数据源	选择**ODPS > odps_first**数据源。
表	选择数据源中的ods_raw_log_d表。
分区信息	默认配置为${bizdate}。
清理规则	默认为**写入前清理已有数据**。
空字符串作为null	此处勾选**否**。

> **说明**
>
> - odps_first数据源是工作空间绑定MaxCompute实例时，系统自动生成的默认数据源。
> - odps_first数据源写入至当前工作空间下的MaxCompute项目中。

iv. 配置字段映射。

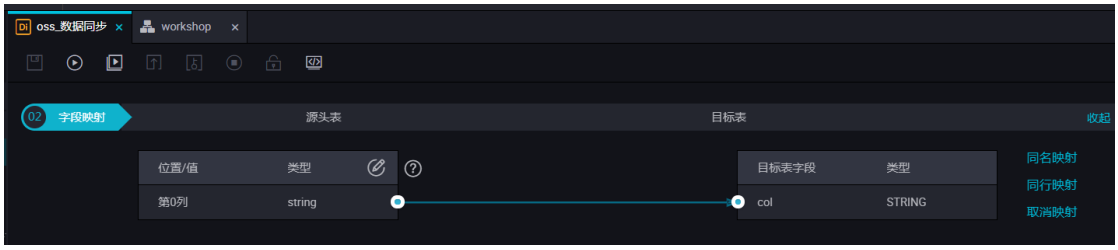

v. 配置**通道控制**。

参数	描述
任务期望最大并发数	数据同步任务内，可以从源并行读取或并行写入数据存储端的最大线程数。向导模式通过界面化配置并发数，指定任务所使用的并行度。
同步速率	设置同步速率可以保护读取端数据库，以避免抽取速度过大，给源库造成太大的压力。同步速率建议限流，结合源库的配置，请合理配置抽取速率。
错误记录数	错误记录数，表示脏数据的最大容忍条数。

vi. 单击页面右侧的**调度配置**，在**调度依赖 > 本节点的输出**区域，输入本节点的输出名称为工作空间名称.ods_raw_log_d，单击+图标。

> 注意　不建议您使用中文作为本节点输出名称，会减少自动推荐功能的准确性。

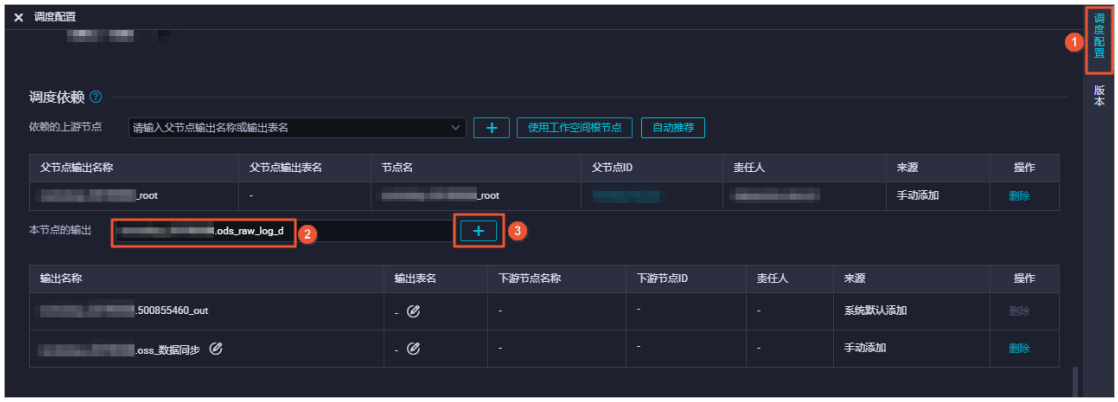

vii. 确认当前节点的配置无误后，单击工具栏中的图标。

viii. 关闭当前任务，返回业务流程配置面板。

2. 配置rds_数据同步节点。

i. 在**数据开发**页面，双击rds_数据同步节点，进入节点配置页面。

ii. 选择数据来源。

参数	描述
数据源	选择MySQL > rds_workshop_log数据源。
表	选择数据源中的ods_user_info_d表。
数据过滤	该数据过滤语句通常用作增量同步，此处可以不填。
切分键	默认为uid。

iii. 选择数据去向。

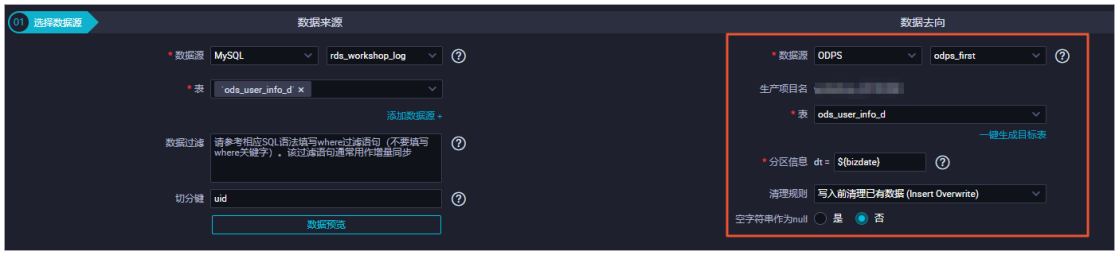

参数	描述
数据源	选择ODPS > odps_first数据源。
表	选择数据源中的ods_user_info_d表。
分区信息	默认配置为${bizdate}。
清理规则	默认为**写入前清理已有数据**。
空字符串作为null	此处勾选**否**。

iv. 配置字段映射。

v. 配置**通道控制**。

vi. 单击页面右侧的**调度配置**，在**调度依赖 > 本节点的输出**区域，输入本节点的输出名称为工作空间名称.ods_user_info_d，单击图标。

添加成功后，您可以**删除**不规范的输出名称。

> 注意　不建议您使用中文作为本节点输出名称，会减少自动推荐功能的准确性。

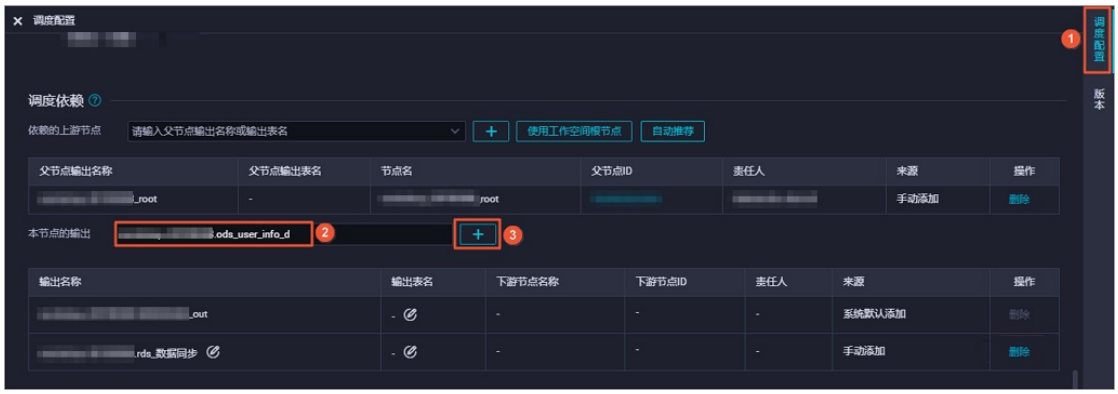

vii. 确认当前节点的配置无误后，单击工具栏中的图标。

viii. 关闭当前任务，返回业务流程配置面板。

提交业务流程

1. 在**数据开发**页面，双击相应的业务流程打开编辑页面，单击工具栏中的图标。

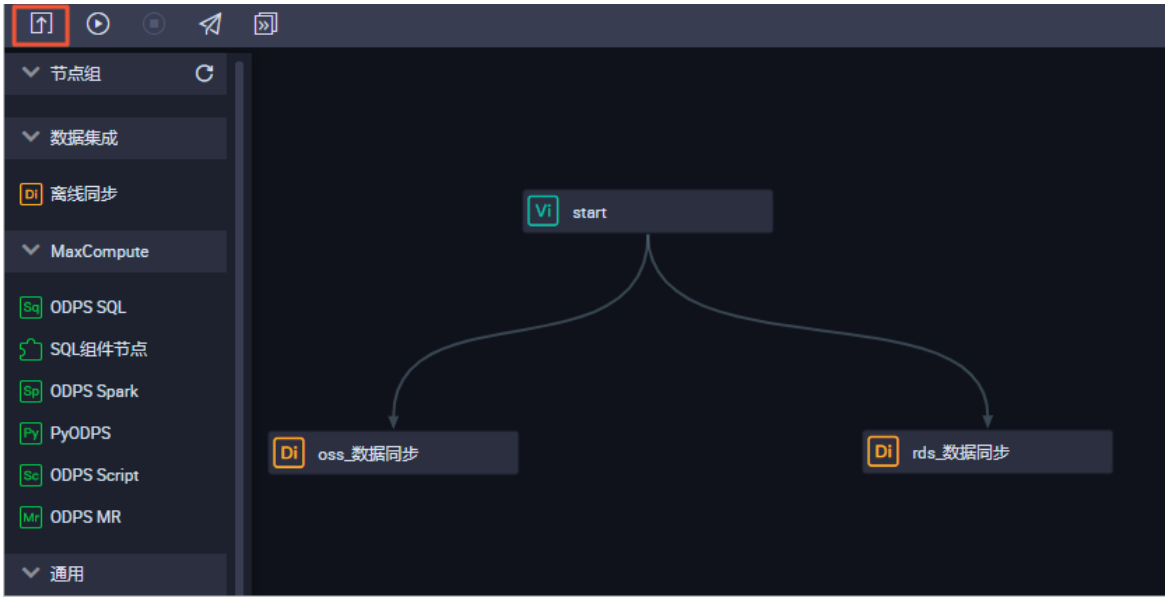

2. 选择**提交**对话框中需要提交的节点，输入**备注**，勾选**忽略输入输出不一致的告警**。
3. 单击**提交**，待显示**提交成功**即可。

运行业务流程

1. 在**数据开发**页面，双击相应的业务流程打开编辑页面，单击工具栏中的图标。

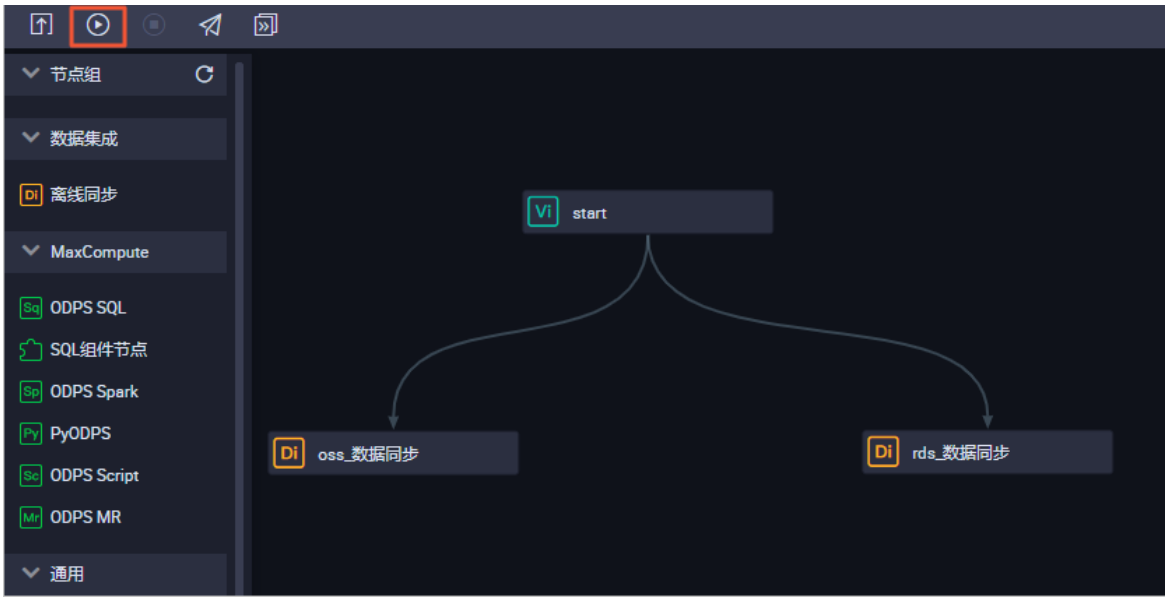

2. 右键单击rds_数据同步节点，选择**查看日志**。

   当日志中出现如下字样，表示同步节点运行成功，并成功同步数据。

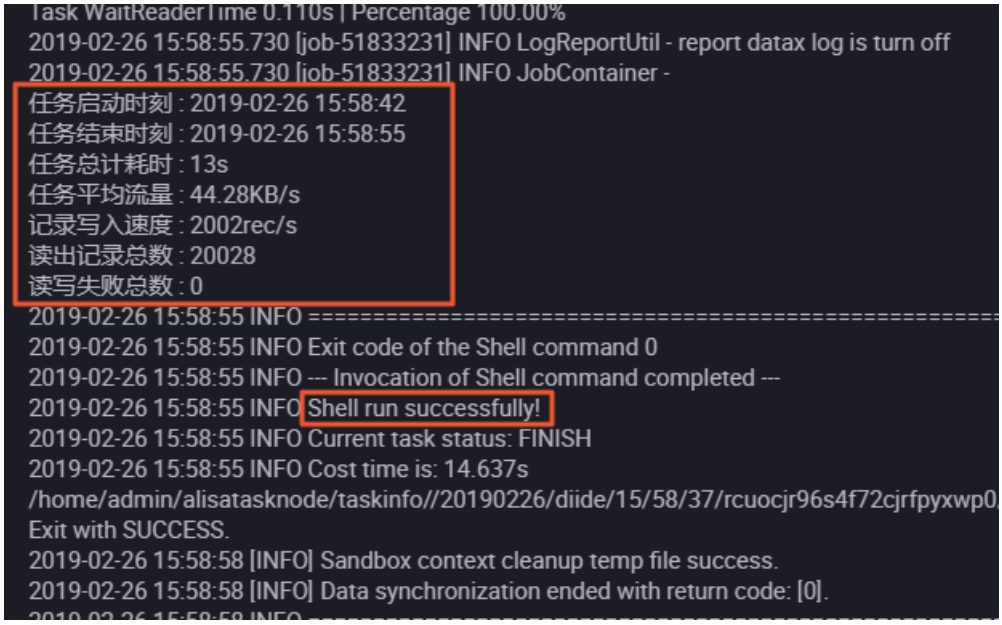

3. 右键单击oss_数据同步节点，选择**查看日志**，确认方法与rds_数据同步节点一致。

确认数据是否成功导入MaxCompute

1. 在**数据开发**页面的左侧导航栏，单击**临时查询**，进入**临时查询**面板。
2. 右键单击**临时查询**，选择**新建节点 > ODPS SQL**。
3. 编写并执行SQL语句，查看导入ods_raw_log_d和ods_user_info_d的记录数。

> **说明** SQL语句如下所示，其中分区列需要更新为业务日期。例如，任务运行的日期为20180717，则业务日期为20180716，即任务运行日期的前一天。

```
--查看是否成功写入MaxCompute
select count(*) from ods_raw_log_d where dt=业务日期;
select count(*) from ods_user_info_d where dt=业务日期;
```

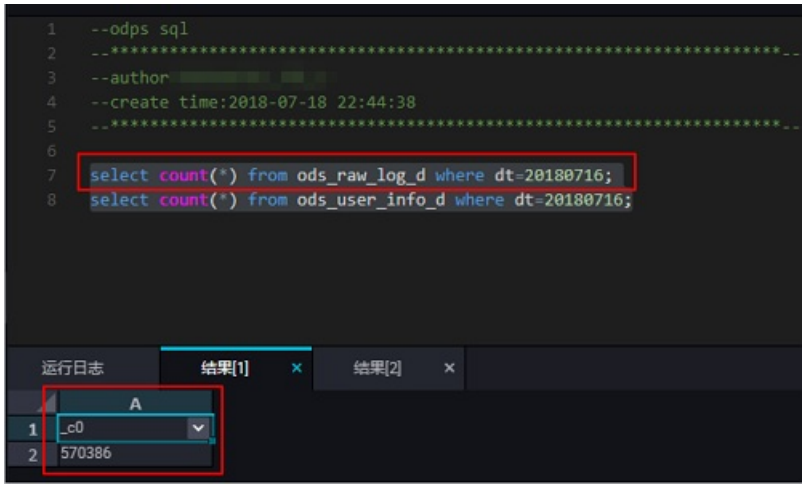

后续步骤

现在，您已经学习了如何进行日志数据同步，完成数据的采集，您可以继续下一个教程。在该教程中，您将学习如何对采集的数据进行计算与分析。详情请参见数据加工。

1.4. 加工数据

本文为您介绍如何通过DataWorks计算和分析已采集的数据。

前提条件

开始本实验前，请首先完成采集数据中的操作。

新建数据表

1. 进入**数据开发**页面。
   i. 登录DataWorks控制台。
   ii. 在左侧导航栏，单击**工作空间列表**。
   iii. 选择工作空间所在地域后，单击相应工作空间后的**进入数据开发**。
2. 在**数据开发**页面，打开新建的业务流程。右键单击**MaxCompute**，选择**新建 > 表**。
3. 在**新建表**对话框中，输入**表名**，单击**提交**。

   此处需要创建三张表，分别为数据运营层表（ods_log_info_d）、数据仓库层表（dw_user_info_all_d）和数据产品层表（rpt_user_info_d）。
4. 通过DDL模式新建表。
   - 新建ods_log_info_d表。

     双击ods_log_info_d表，在右侧的编辑页面单击**DDL模式**，输入下述建表语句。

```
--创建数据运营层（ODS）表
CREATE TABLE IF NOT EXISTS ods_log_info_d (
  ip STRING COMMENT 'ip地址',
  uid STRING COMMENT '用户ID',
  time STRING COMMENT '时间yyyymmddhh:mi:ss',
  status STRING COMMENT '服务器返回状态码',
  bytes STRING COMMENT '返回给客户端的字节数',
  region STRING COMMENT '地域，根据ip得到',
  method STRING COMMENT 'http请求类型',
  url STRING COMMENT 'url',
  protocol STRING COMMENT 'http协议版本号',
  referer STRING COMMENT '来源url',
  device STRING COMMENT '终端类型 ',
  identity STRING COMMENT '访问类型 crawler feed user unknown'
)
PARTITIONED BY (
  dt STRING
);
```

- 新建dw_user_info_all_d表。

  双击dw_user_info_all_d表，在右侧的编辑页面单击**DDL模式**，输入下述建表语句。

```
--创建数据仓库层（DW）表
CREATE TABLE IF NOT EXISTS dw_user_info_all_d (
  uid STRING COMMENT '用户ID',
  gender STRING COMMENT '性别',
  age_range STRING COMMENT '年龄段',
  zodiac STRING COMMENT '星座',
  region STRING COMMENT '地域，根据ip得到',
  device STRING COMMENT '终端类型 ',
  identity STRING COMMENT '访问类型 crawler feed user unknown',
  method STRING COMMENT 'http请求类型',
  url STRING COMMENT 'url',
  referer STRING COMMENT '来源url',
  time STRING COMMENT '时间yyyymmddhh:mi:ss'
)
PARTITIONED BY (
  dt STRING
);
```

- 新建rpt_user_info_d表。

  双击rpt_user_info_d表，在右侧的编辑页面单击**DDL模式**，输入下述建表语句。

```
--创建数据产品层（RPT）表
CREATE TABLE IF NOT EXISTS rpt_user_info_d (
  uid STRING COMMENT '用户ID',
  region STRING COMMENT '地域，根据ip得到',
  device STRING COMMENT '终端类型 ',
  pv BIGINT COMMENT 'pv',
  gender STRING COMMENT '性别',
  age_range STRING COMMENT '年龄段',
  zodiac STRING COMMENT '星座'
)
PARTITIONED BY (
  dt STRING
);
```

5. 建表语句输入完成后，单击**生成表结构**并**确认**覆盖当前操作。
6. 返回建表页面后，在**基本属性**中输入表的中文名。
7. 完成设置后，分别单击**提交到开发环境**和**提交到生产环境**。

> **说明** 如果您使用的是简单模式的工作空间，页面仅显示**提交到生产环境**。

设计业务流程

业务流程节点间依赖关系的配置请参见采集数据。

双击新建的业务流程打开编辑页面，鼠标单击**ODPS SQL**并拖拽至右侧的编辑页面。在**新建节点**对话框中，输入**节点名称**，单击**提交**。

此处需要新建三个ODPS SQL节点，依次命名为ods_log_info_d、dw_user_info_all_d和rpt_user_info_d，并配置如下图所示的依赖关系。

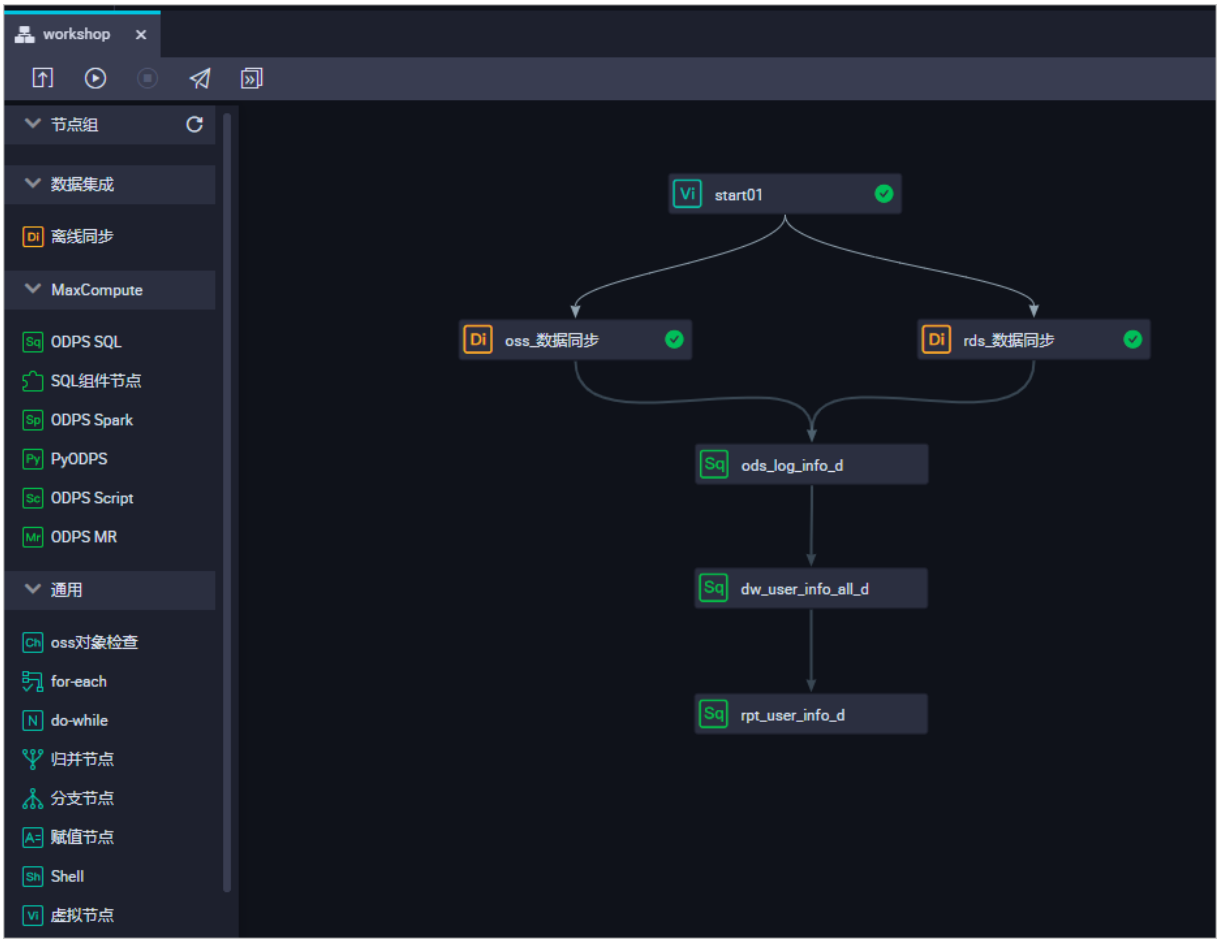

创建用户自定义函数

1. 新建资源。
   i. 下载ip2region.jar。

ii. 在**数据开发**页面打开业务流程，右键单击**MaxCompute**，选择**新建 > 资源 > JAR**。

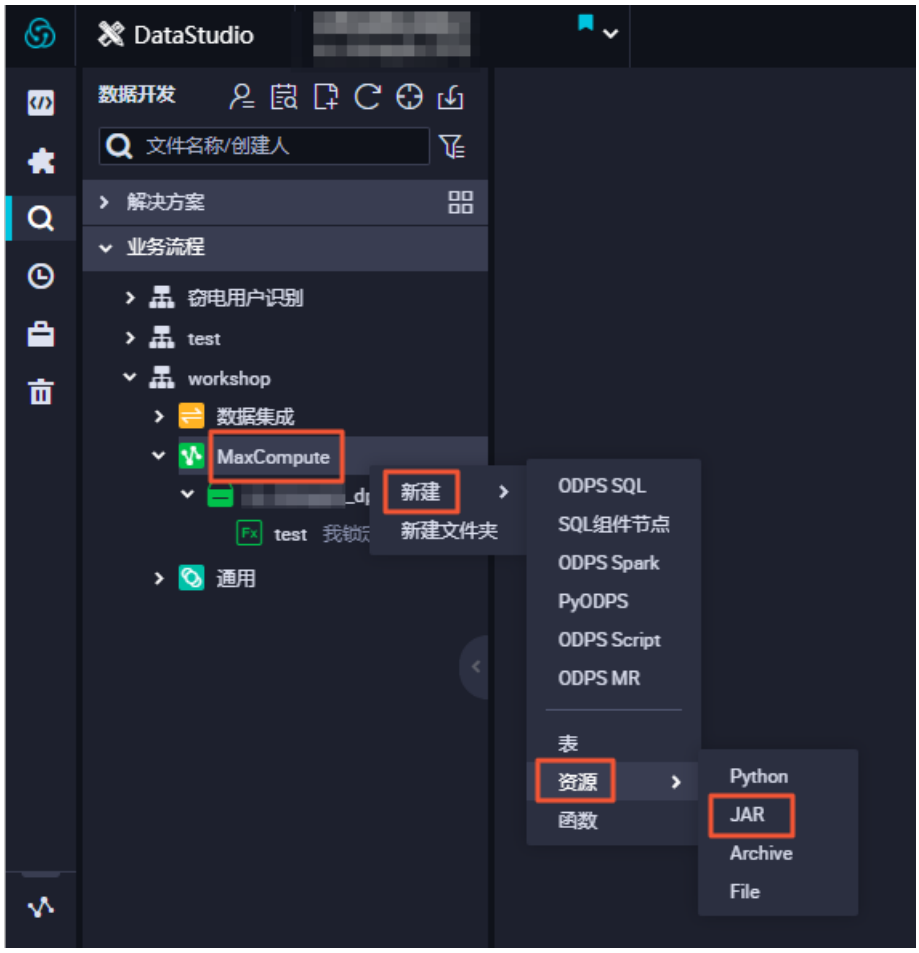

iii. 在**新建资源**对话框中，输入**资源名称**，并选择**目标文件夹**。

> 说明
> - 请选中**上传为ODPS资源**。
> - 资源名称无需与上传的文件名保持一致。
> - 资源名称命名规范：1~128个字符，字母、数字、下划线、小数点，大小写不敏感，JAR资源的后缀为.jar，Python资源的后缀为.py。

iv. 单击**点击上传**，选择已经下载至本地的*ip2region.jar*，单击**打开**。

v. 单击**确定**。

vi. 单击工具栏中的图标。

2. 注册函数。

i. 在**数据开发**页面打开业务流程，右键单击**MaxCompute**，选择**新建 > 函数**。

ii. 在**新建函数**对话框中，输入**函数名称**（示例为getregion），单击**提交**。

iii. 在**注册函数**对话框中，配置各项参数。

参数	描述
函数类型	选择函数类型。
MaxCompute引擎实例	默认不可以修改。
函数名	新建函数时输入的函数名称。
责任人	选择责任人。
类名	输入 `org.alidata.odps.udf.Ip2Region` 。
资源列表	输入 `ip2region.jar` 。
描述	输入IP地址转换地域。
命令格式	输入 `getregion('ip')` 。
参数说明	输入IP地址。

iv. 分别单击工具栏中的和图标。

配置ODPS SQL节点

1. 配置ods_log_info_d节点。
   i. 双击ods_log_info_d节点，进入节点配置页面。

ii. 在节点编辑页面，编写如下SQL语句。

```
INSERT OVERWRITE TABLE ods_log_info_d PARTITION (dt=${bdp.system.bizdate})
SELECT ip
  , uid
  , time
  , status
  , bytes
  , getregion(ip) AS region --使用自定义UDF通过IP得到地域。
  , regexp_substr(request, '(^[^ ]+ )') AS method --通过正则把request差分为3个字段。
  , regexp_extract(request, '^[^ ]+ (.*) [^ ]+$') AS url
  , regexp_substr(request, '([^ ]+$)') AS protocol
  , regexp_extract(referer, '^[^/]+://([^/]+){1}') AS referer --通过正则清晰refer，得到更精准的URL。
  , CASE
    WHEN TOLOWER(agent) RLIKE 'android' THEN 'android' --通过agent得到终端信息和访问形式。
    WHEN TOLOWER(agent) RLIKE 'iphone' THEN 'iphone'
    WHEN TOLOWER(agent) RLIKE 'ipad' THEN 'ipad'
    WHEN TOLOWER(agent) RLIKE 'macintosh' THEN 'macintosh'
    WHEN TOLOWER(agent) RLIKE 'windows phone' THEN 'windows_phone'
    WHEN TOLOWER(agent) RLIKE 'windows' THEN 'windows_pc'
    ELSE 'unknown'
  END AS device
  , CASE
    WHEN TOLOWER(agent) RLIKE '(bot|spider|crawler|slurp)' THEN 'crawler'
    WHEN TOLOWER(agent) RLIKE 'feed'
    OR regexp_extract(request, '^[^ ]+ (.*) [^ ]+$') RLIKE 'feed' THEN 'feed'
    WHEN TOLOWER(agent) NOT RLIKE '(bot|spider|crawler|feed|slurp)'
    AND agent RLIKE '^[Mozilla|Opera]'
    AND regexp_extract(request, '^[^ ]+ (.*) [^ ]+$') NOT RLIKE 'feed' THEN 'user'
    ELSE 'unknown'
  END AS identity
  FROM (
    SELECT SPLIT(col, '##@@')[0] AS ip
    , SPLIT(col, '##@@')[1] AS uid
    , SPLIT(col, '##@@')[2] AS time
    , SPLIT(col, '##@@')[3] AS request
    , SPLIT(col, '##@@')[4] AS status
    , SPLIT(col, '##@@')[5] AS bytes
    , SPLIT(col, '##@@')[6] AS referer
    , SPLIT(col, '##@@')[7] AS agent
  FROM ods_raw_log_d
  WHERE dt = ${bdp.system.bizdate}
) a;
```

iii. 单击工具栏中的图标。

2. 配置dw_user_info_all_d节点。

i. 双击dw_user_info_all_d节点，进入节点配置页面。

ii. 在节点编辑页面，编写如下SQL语句。

```
INSERT OVERWRITE TABLE dw_user_info_all_d PARTITION (dt='${bdp.system.bizdate}')
SELECT COALESCE(a.uid, b.uid) AS uid
  , b.gender
  , b.age_range
  , b.zodiac
  , a.region
  , a.device
  , a.identity
  , a.method
  , a.url
  , a.referer
  , a.time
FROM (
  SELECT *
  FROM ods_log_info_d
  WHERE dt = ${bdp.system.bizdate}
) a
LEFT OUTER JOIN (
  SELECT *
  FROM ods_user_info_d
  WHERE dt = ${bdp.system.bizdate}
) b
ON a.uid = b.uid;
```

iii. 单击工具栏中的图标。

3. 配置rpt_user_info_d节点。

i. 双击rpt_user_info_d节点，进入节点配置页面。

ii. 在节点编辑页面，编写如下SQL语句。

```
INSERT OVERWRITE TABLE rpt_user_info_d PARTITION (dt='${bdp.system.bizdate}')
SELECT uid
  , MAX(region)
  , MAX(device)
  , COUNT(0) AS pv
  , MAX(gender)
  , MAX(age_range)
  , MAX(zodiac)
FROM dw_user_info_all_d
WHERE dt = ${bdp.system.bizdate}
GROUP BY uid;
```

iii. 单击工具栏中的图标。

提交业务流程

1. 在业务流程的编辑页面，单击图标，提交业务流程中已配置完成的节点。
2. 在**提交**对话框中，选择需要提交的节点，选中**忽略输入输出不一致的告警**。
3. 单击**提交**。

运行业务流程

1. 在业务流程的编辑页面，单击工具栏中的图标，验证代码逻辑。
2. 待所有任务运行完成显示绿色箭头后，在左侧导航栏，单击**临时查询**。
3. 在**临时查询**面板，右键单击**临时查询**，选择**新建节点 > ODPS SQL**。
4. 编写并执行SQL语句，查询任务运行结果，确认数据产出。

```
--odps sql
--********************************************************************--
--author:
--create time:2019-06-28 19:42:29
--********************************************************************--
select * from rpt_user_info_d where dt=20190630 limit 10;
```

运行日志　结果[1]

	A	B	C	D	E	F	G	H
1	uid	region	device	pv	gender	age_range	zodiac	dt
2	0016359810821	湖北省	windows_pc	1	女	30-40岁	巨蟹座	20190630
3	0016359814159	未知	windows_pc	5	女	30-40岁	巨蟹座	20190630
4	001d9e7863049	浙江省	iphone	21	女	40-50岁	双鱼座	20190630
5	001d9e7866387	河南省	windows_pc	1	女	40-50岁	双鱼座	20190630
6	001d9e7869725	未知	windows_pc	1	女	40-50岁	双鱼座	20190630
7	001dce2983544	湖北省	unknown	2	女	20-30岁	水瓶座	20190630
8	001dce2986882	广东省	windows_pc	3	女	20-30岁	水瓶座	20190630
9	0026c84ad1206	台湾省	windows_pc	1	女	20岁以下	天秤座	20190630
10	0026c84ad4544	福建省	windows_pc	126	女	20岁以下	天秤座	20190630
11	0026c84ad7882	福建省	windows_pc	3	女	20岁以下	天秤座	20190630

查询语句如下所示，通常默认业务日期为运行日期的前一天。

```
---查看rpt_user_info_d数据情况。
select * from rpt_user_info_d where dt=业务日期 limit 10;
```

发布业务流程

提交业务流程后，表示任务已进入开发环境。由于开发环境的任务不会自动调度，您需要发布配置完成的任务至生产环境。

> **说明**
> - 发布任务至生产环境前，您需要对代码进行测试，确保其正确性。
> - 如果您使用的是简单模式的工作空间，则没有图标。您在提交任务后，单击图标，进入运维中心页面。

1. 在业务流程的编辑页面，单击工具栏中的图标，进入发布页面。
2. 选择待发布任务，单击**添加到待发布**。

3. 单击右上角的**待发布列表**，进入列表后，单击**全部打包发布**。
4. 在**确认发布**对话框中，单击**发布**。
5. 在左侧导航栏，单击**发布包列表**，查看发布状态。

在生产环境运行任务

1. 任务发布成功后，单击右上角的**运维中心**。

   您也可以进入业务流程的编辑页面，单击工具栏中的**前往运维**，进入**运维中心**页面。
2. 在左侧导航栏，单击**周期任务运维 > 周期任务**，进入**周期任务**页面，单击workshop业务流程。
3. 双击DAG图中的虚节点展开业务流程，右键单击workshop_start节点，选择**补数据 > 当前节点及下游节点**。

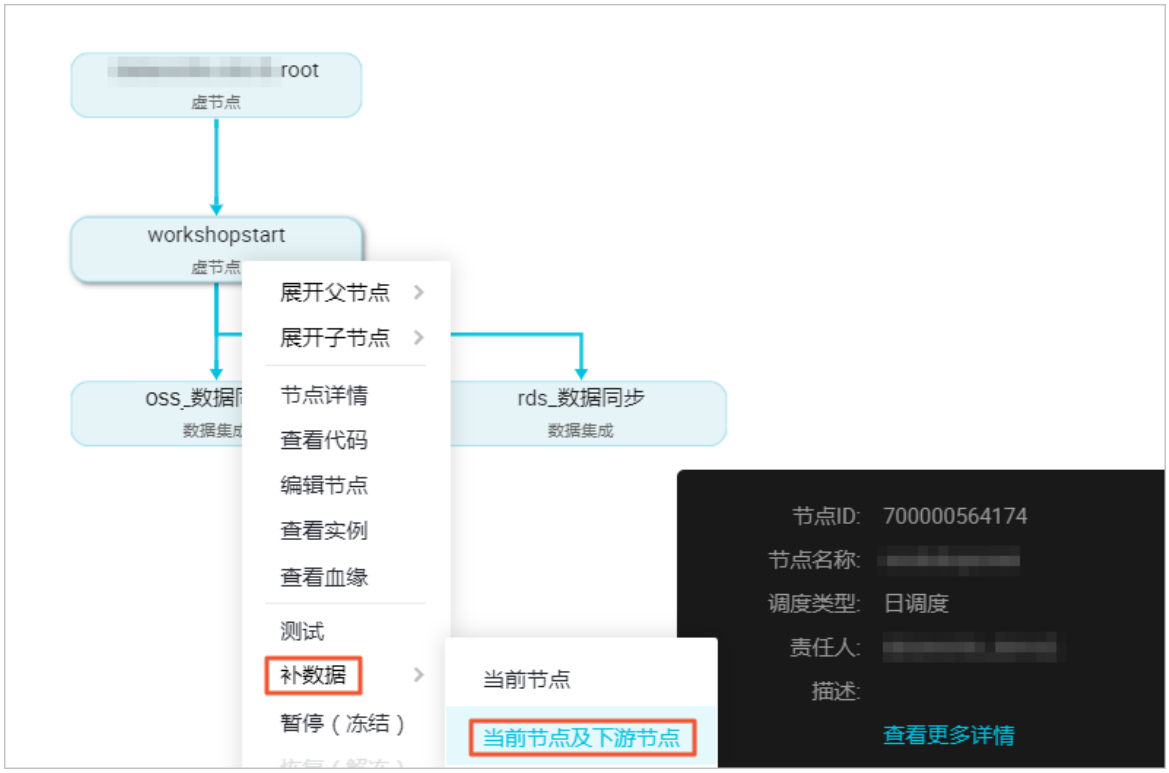

4. 选中需要补数据的任务，输入业务日期，单击**确定**，自动跳转至**补数据实例**页面。
5. 单击**刷新**，直至SQL任务全部运行成功即可。

后续步骤

现在，您已经学习了如何创建SQL任务、如何处理原始日志数据。您可以继续下一个教程，学习如何对开发完成的任务设置数据质量监控，保证任务运行的质量。详情请参见配置数据质量监控。

1.5. 配置数据质量监控

本文为您介绍如何监控数据质量、设置表的质量监控规则和监控提醒等。

前提条件

在进行本实验前，请确保已采集并加工数据。详情请参见采集数据和加工数据。

背景信息

数据质量是支持多种异构数据源的质量校验、通知、管理服务的一站式平台。数据质量以数据集（DataSet）为监控对象，目前支持MaxCompute数据表和DataHub实时数据流的监控。当离线MaxCompute数据发生变化时，数据质量会对数据进行校验，并阻塞生产链路，以避免问题数据污染扩散。同时，数据质量提供历史校验结果的管理，以便您对数据质量分析和定级。

在流式数据场景下，数据质量能够基于DataHub数据通道进行断流监控，第一时间告警给订阅用户，并且支持橙色、红色告警等级以及告警频次设置，最大限度减少冗余报警。

数据质量开发流程

1. 针对已有的表进行监控规则配置，配置完成后进行试跑，验证该规则是否适用。

   您可以根据试跑结果，确认此次任务产出的数据是否符合预期。建议每个表的监控规则配置完成后，都进行一次试跑操作，以验证表规则的适用性。

2. 试跑成功后，将该规则和调度任务进行关联。

   在监控规则配置完成且试跑成功的情况下，您需要将表和其产出任务进行关联，以便每次表的产出任务运行完成后，都会触发数据质量规则的校验，以保证数据的准确性。

3. 关联调度后，每次调度任务代码运行完成，都会触发数据质量的校验规则，以提升任务准确性。

   数据质量支持设置规则订阅，您可以针对重要的表及其规则设置订阅，设置订阅后会根据数据质量的校验结果进行告警，从而实现对校验结果的跟踪。如果数据质量校验结果异常，则会根据配置的告警策略进行通知。

> **说明**
> - 每张表在完成规则的配置后，都需要进行试跑、关联调度和规则订阅等操作。
> - 数据质量会产生额外的计算费用，更多详情请参见数据质量概述。

配置数据表的监控规则

如果已经完成数据采集和数据加工实验，请确认您已拥有数据表：ods_raw_log_d、ods_user_info_d、ods_log_info_d、dw_user_info_all_d和rpt_user_info_d。确认后，进行以下操作：

1. 进入表ods_raw_log_d的**监控规则**页面。
   i. 登录DataWorks控制台。
   ii. 在左侧导航栏，单击**工作空间列表**。
   iii. 选择工作空间所在地域后，单击相应工作空间后的**进入数据开发**。
   iv. 单击左上方的☰图标，选择**全部产品 > 数据治理 > 数据质量**。
   v. 在左侧导航栏，单击**监控规则**，从数据源下拉列表中选择**MaxCompute**。

vi. 在**引擎/数据库实例**下拉框中选择待配置监控规则表所在的引擎实例，在过滤后的表列表中找到待配置监控规则的表，例如本教程的ods_raw_log_d表。

vii. 单击ods_raw_log_d表后的**配置监控规则**。

2. 配置表ods_raw_log_d的监控规则。

i. 在**已添加的分区表达式**模块，单击**+**，添加分区表达式。

ods_raw_log_d表的数据来源为oss_workshop_log，数据是从OSS中获取到的日志数据，其分区格式为${bdp.system.bizdate}（获取到前一天的日期）。

对于此类每天产出的日志数据，您可以配置表的分区表达式。在**添加分区**对话框中，选择dt=$[yyyymmdd-1]，单击**确认**。分区表达式的详情请参见配置调度参数。

> **说明** 如果表中无分区列，可以配置**无分区**，请根据真实的分区值配置对应的分区表达式。

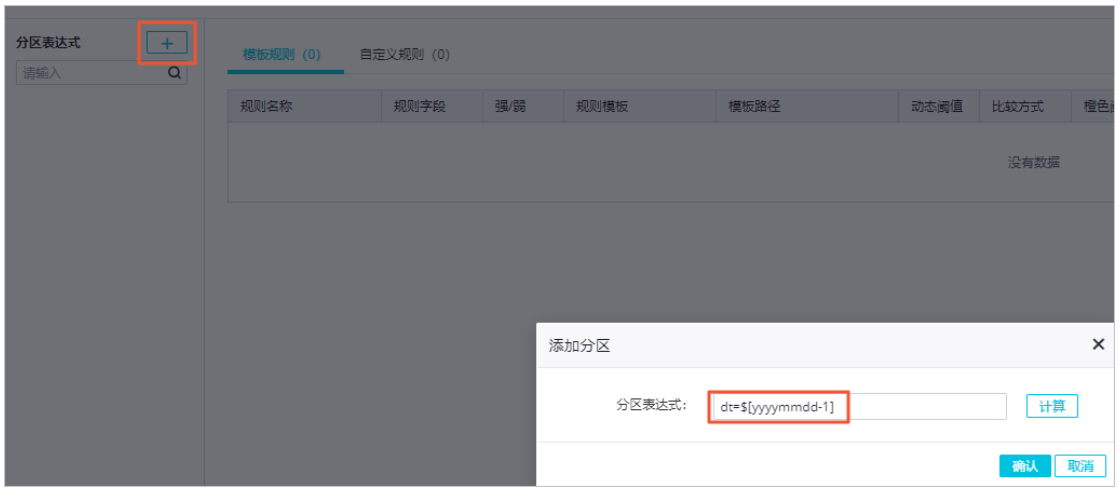

ii. 单击**创建规则**，默认在**模板规则**对话框。

iii. 单击**添加监控规则**，选择**规则模板**为**表行数，固定值**，设置规则的强度为**强**、比较方式为**期望值大于0**。

表ods_raw_log_d的数据来源于OSS上传的日志文件，作为源头表，您需要尽早判断该表的分区中是否存在数据。如果该表没有数据，则需要阻止后续任务运行。如果来源表没有数据，后续任务运行无意义。

> **说明** 只有强规则下红色报警会导致任务阻塞，阻塞会将任务的实例状态置为失败。

配置完成后，单击**批量保存**。

> **说明** 该配置主要是为了避免分区中没有数据，导致下游任务的数据来源为空的问题。

iv. 单击**试跑**，在**试跑**对话框中，选择**调度时间**，单击**试跑**。

试跑可以立即触发数据质量的校验规则，对配置完成的规则进行校检。试跑完成后，单击**试跑成功！点击查看试跑结果**，即可跳转至试跑结果页面。

v. 进行关联调度。

数据质量支持和调度任务关联。在表规则和调度任务绑定后，任务实例运行完成都会触发数据质量的检查。您可以通过以下两种方式进行表规则和任务的关联调度：

- 在运维中心页面关联表规则

  单击左上方的图标，选择**全部产品 > 运维中心**。

  在左侧导航栏，单击**周期任务运维 > 周期任务**。在DAG图中，右键单击**oss_数据同步**任务，选择**配置质量监控**。

  在**配置质量监控**对话框中，选择**表名**（ods_raw_log_d）和**分区表达式**dt=$[yyyymmdd-1]），单击**添加**。

- 在数据质量页面关联表规则

  在表的**监控规则**页面，单击**关联调度**，配置规则与任务的绑定关系。

  单击**关联调度**，可以与已提交到调度的节点任务进行绑定，系统会根据血缘关系给出推荐绑定的任务，也支持自定义绑定。

  在**关联调度**对话框中，输入节点ID或节点名称，单击**添加**。添加完成后，即可完成与调度节点任务的绑定。

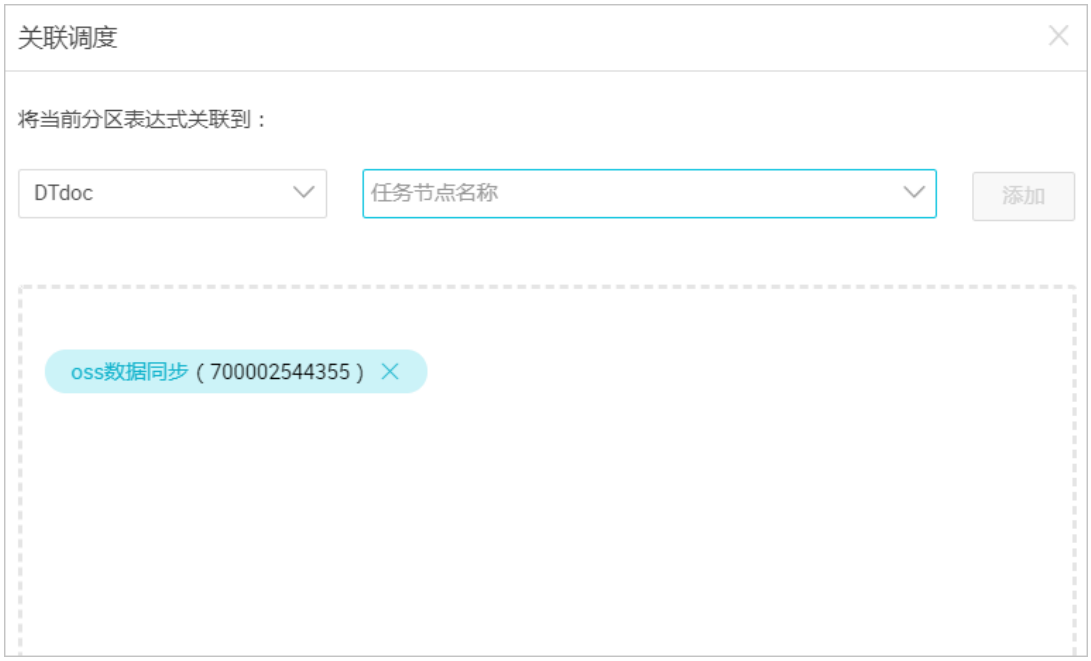

vi. 订阅任务。

在表的监控规则页面，单击**订阅管理**，设置接收人以及订阅方式。数据质量支持**邮件通知**、**邮件和短信通知**、**钉钉群机器人**和**钉钉群机器人@ALL**。

订阅管理设置完成后，在左侧导航栏，单击**我的订阅**，查看和修改已订阅的任务。

> **说明** 建议订阅全部规则，避免校验结果无法及时通知。

3. 配置ods_user_info_d表规则。

ods_user_info_d是用户信息表，您在配置规则时，需要配置表的行数校验和主键唯一性校验，避免数据重复。

i. 配置一个分区字段的监控规则，监控的时间表达式为dt=$[yyyymmdd-1]。配置成功后，在已添加的分区表达式中可以查看成功的分区配置记录。

ii. 分区表达式配置完成后，单击**创建规则**，配置数据质量的校验规则。

分别添加表级规则和列规则：

- 选择**规则字段**为**表级规则**。

选择**规则模板**为**表行数，固定值**、**强弱**为**强**、**比较方式**为**大于**以及**期望值**为**0**。

- 选择**规则字段**为uid。

添加列级规则，设置主键列（uid）为监控列。选择**模板类型**为**重复值个数，固定值**、**强弱**为**弱**、**比较方式**为**小于**以及**期望值**为1。

iii. 配置完成后，单击**批量保存**。

> **说明** 该配置主要是为了避免数据重复，导致下游数据被污染的情况。

4. 配置ods_log_info_d表规则。

ods_log_info_d数据主要来源于解析ods_raw_log_d表中的数据。鉴于日志中的数据无法配置过多监控，只需要配置表数据不为空的校验规则即可。

i. 配置表的分区表达式为dt=$[yyyymmdd-1]。

ii. 单击**创建规则**，在对话框中单击**添加监控规则**。

配置表数据不为空的校验规则，选择**规则强度**为**强**、**规则模板**为**表级规则**、**比较方式**为**不等于**、**期望值**为**0**。

iii. 配置完成后，单击**批量保存**。

5. 配置dw_user_info_all_d表规则。

   dw_user_info_all_d表是针对ods_user_info_d和ods_log_info_d表的数据汇总。由于流程较为简单，ODS层已配置了表行数不为空的规则，所以该表无需进行数据质量监控规则的配置，以节省计算资源。

6. 配置rpt_user_info_d表规则。

   rpt_user_info_d表是数据汇总后的结果表。根据该表的数据，您可以进行表行数波动监测和针对主键进行唯一值校验。

   i. 单击**已添加的分区表达式**模块的**+**，配置表的分区表达式为dt=$[yyyymmdd-1]。

   ii. 单击**创建规则**，在**添加监控规则**对话框中添加列级规则。设置主键列（uid）为监控列，选择**规则模板**为**重复值个数，固定值**、**强弱**为**弱**、**比较方式**为**小于**以及**期望值**为**1**。

iii. 继续添加监控规则和表级规则，选择**规则模板**为**表行数，7天波动率**、**强弱**为**弱**，设置**橙色阈值**为1%、**红色阈值**为50%（此处阈值范围根据业务逻辑进行设置）。

> 说明
> - **橙色阈值**和**红色阈值**必须大于0%。
> - 此处监控表行数是为了查看每日UV的波动，以便及时了解应用动态。

iv. 配置完成后，单击**批量保存**。

在设置表规则强度时，数据仓库中越底层的表，设置强规则的次数越多。这是因为ODS层的数据作为数仓中的原始数据，一定要保证其数据的准确性，避免因ODS层的数据质量太差而影响其它层的数据，及时止损。

数据质量还为您提供**任务查询**功能，以便查看已配置规则的校验结果，详情请参见查看监控任务。

1.6. 数据可视化展现

通过补数据完成数据表rpt_user_info_d加工后，您可以通过Quick BI创建网站用户分析画像的仪表板，实现该数据表的可视化。

前提条件

在开始试验前，请确认您已经完成了加工数据。单击进入Quick BI控制台。

背景信息

rpt_user_info_d表包含了region、device、gender、age、zodiac等字段信息。您可以通过仪表板展示用户的核心指标、周期变化、用户地区分布、年龄与星座分布和记录。为查看数据在日期上的变化，建议您在补数据时至少选择一周的时间。

操作步骤

1. 单击进入**默认空间**，您也可以使用自己的**个人空间**。

2. 选择**数据源 > 新建数据源 > 云数据库 > MaxCompute**。

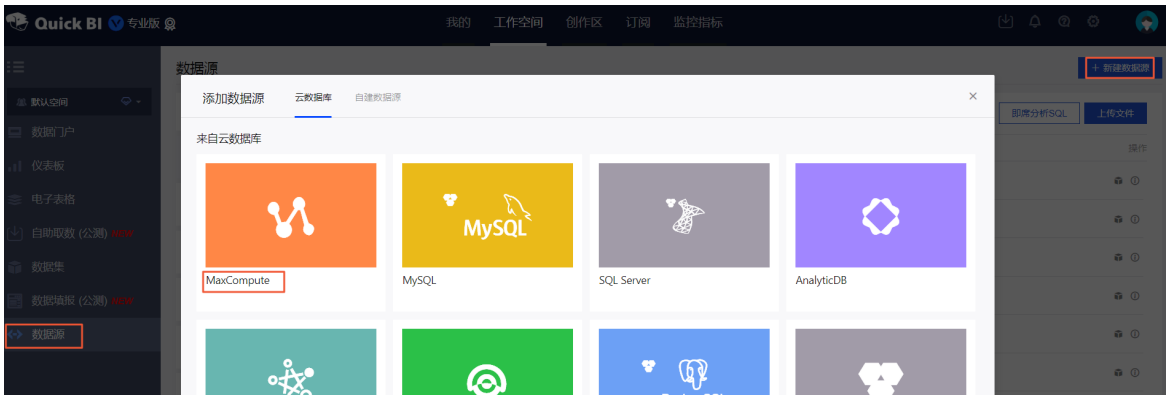

3. 输入您的MaxCompute项目名称以及您的AcessKey信息，数据库地址使用默认地址即可，关于数据库地址详情请参见Endpoint。

   完成填写后，单击**连接测试**，待显示**数据源连通性正常**后单击**添加**即可。

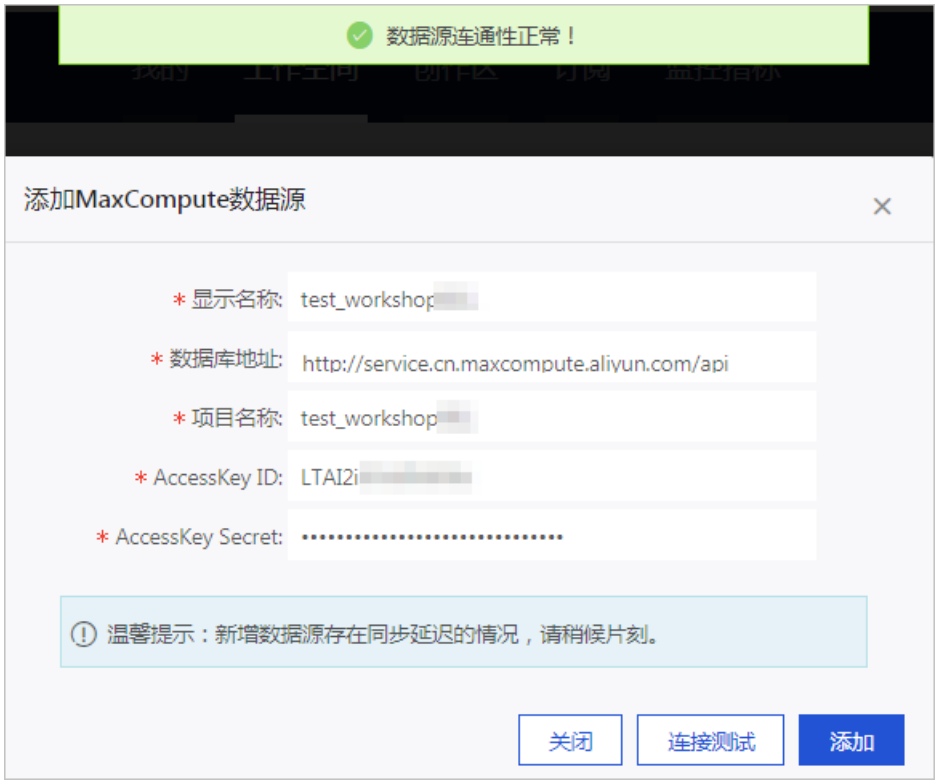

4. 找到您刚添加的数据源的rpt_user_info_d表，单击**创建数据集**。

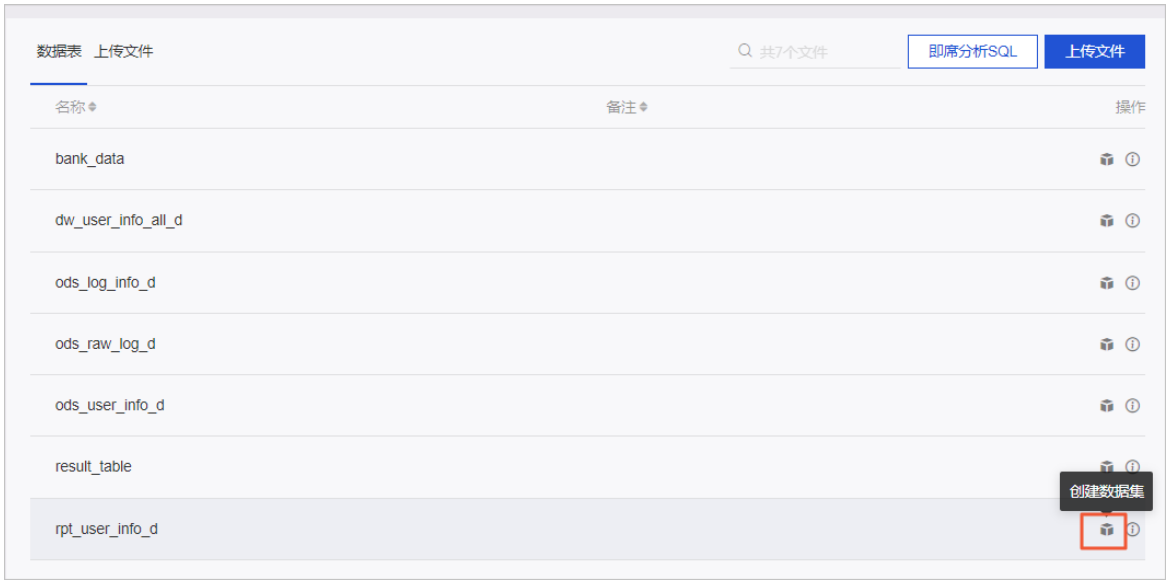

选择您想放置的数据集位置，单击**确定**。

5. 进入数据集列表页，单击您刚刚创建的数据集，对数据集进行编辑。

常见的数据集加工包括：维度、度量的切换、修改维度的类型、增加计算字段、创建层次结构、修改字段的数据类型、更改度量聚合方式、制作关联模型。

6. 转换字段的维度类型。完成转换后，您可以根据字段中具体的数值进行过滤筛选。

i. 转换日期字段的维度类型。

右键单击dt字段，选择**维度类型切换 > 日期（源数据格式） > yyyyMMdd**。

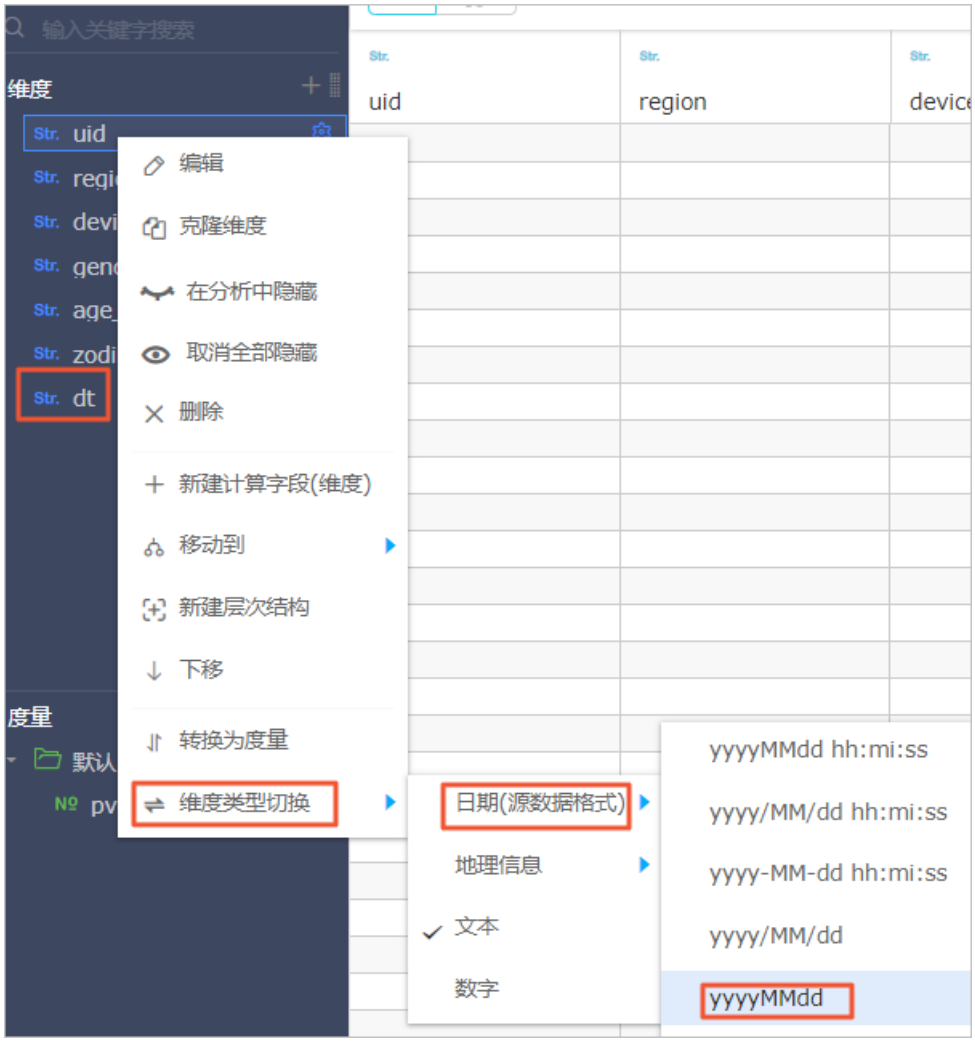

ii. 转换地理信息字段的维度类型。

右键单击region字段，选择**维度类型切换 > 地理信息 > 省/直辖市**。转换成功后，在左侧维度栏中会看到字段前多一个地理位置图标。

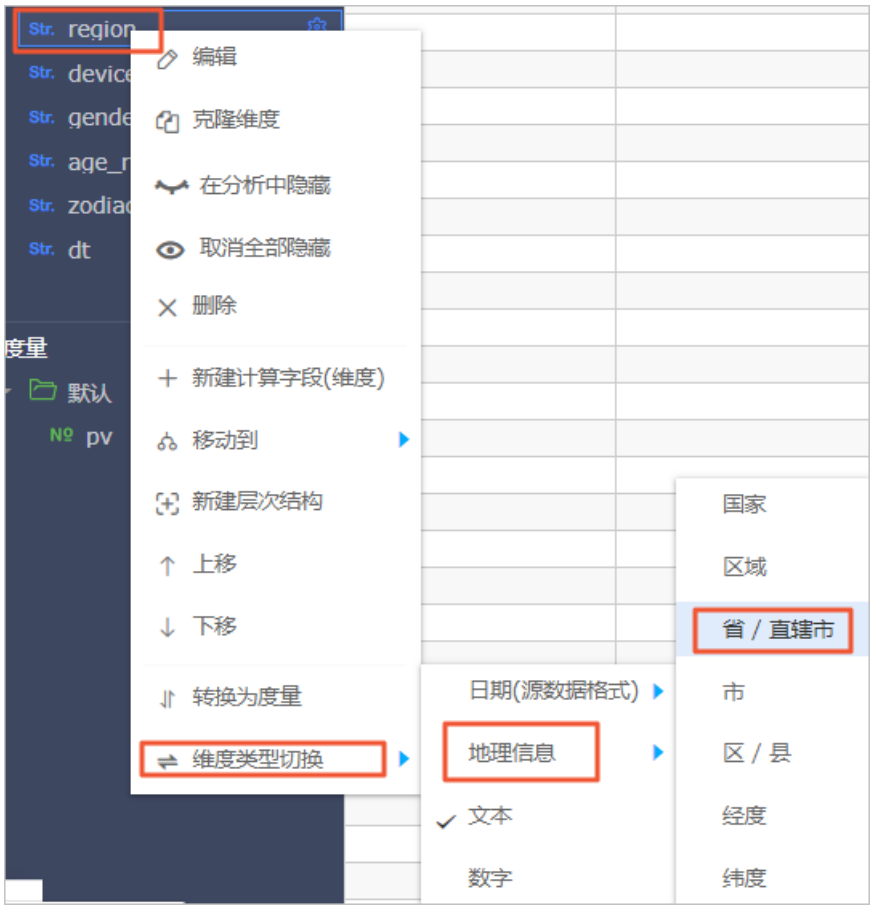

7. 制作仪表板。

随着数据的更新，让报表可视化地展现最新数据，这个过程叫制作仪表板。仪表板的制作流程为： 确定内容、布局和样式，制作图表，完成动态联动查询。

i. 单击rpt_user数据集后的新建仪表板，选择**常规模式**，进入仪表板编辑页。

> **说明**
>
> - 如果您使用的是标准版或高级版的Quick BI，则单击新建仪表板后默认进入常规模式仪表板。
> - 如果您使用的是专业版Quick BI，则单击新建仪表板后可以选择进入常规模式或全屏模式仪表板。当前文档以常规模式仪表板示例。

ii. 从仪表板空间中向空白区拖入1个指标看板。

选择数据来源为数据集rpt_user，选择度量为pv。

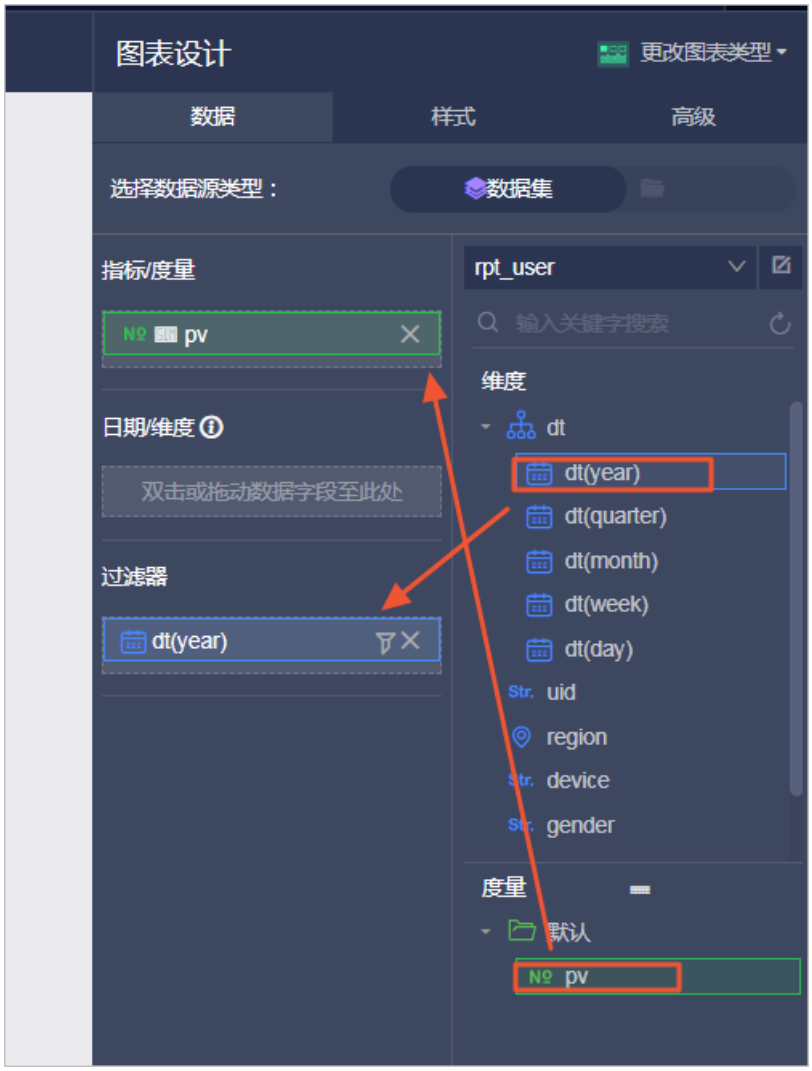

由于数据表rpt_user_info_d为分区表，因此必须在**过滤器**处选择筛选的日期，本例中筛选为2019~2019年，完成设置后单击**更新**。

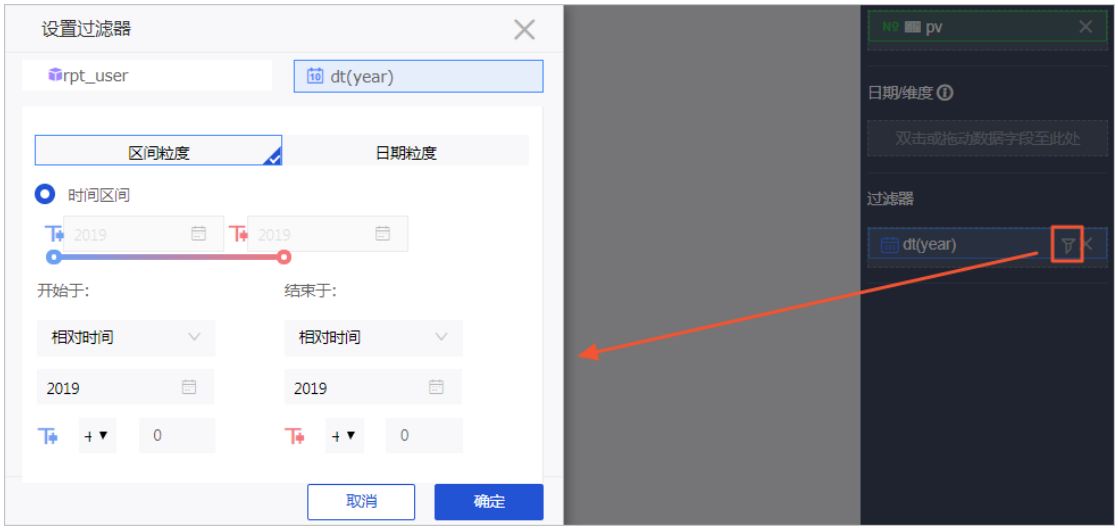

完成后可以看到当下数据。

iii. 制作趋势图：将图表区域内的**线图**拖拽到左侧画布。

参数配置如下，完成之后单击**更新**：

- **值轴/度量**：pv
- **类别轴/维度**：dt（day）
- **颜色图例/维度**：age_range
- **过滤器**：dt（year）

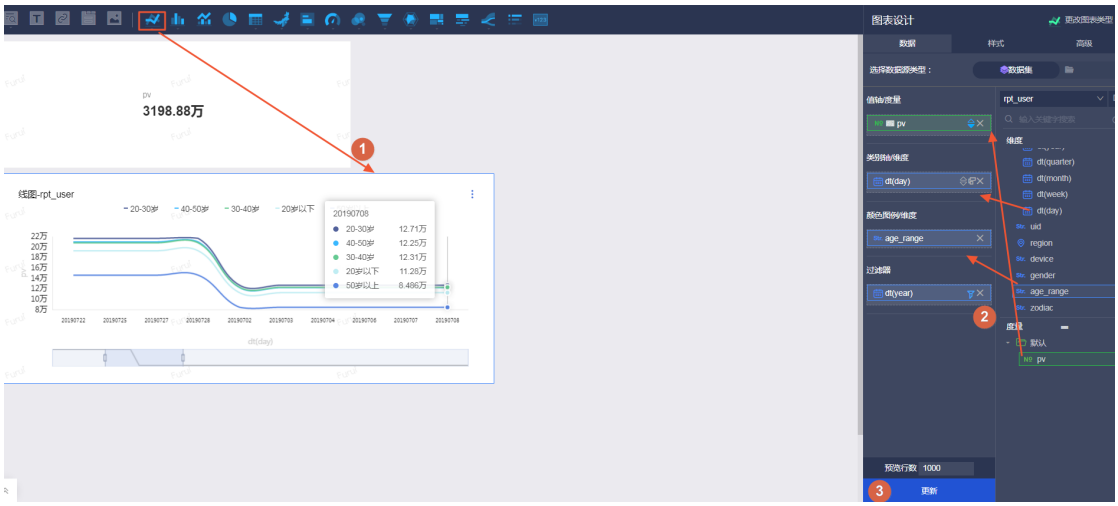

iv. 制作色彩地图：单击图表区域内的**色彩地图**，并选择数据源来源为数据集rpt_user，选择**地理区域/维度**为region、**色彩饱和度/度量**为pv，选择完成后单击**更新**，结果如下。

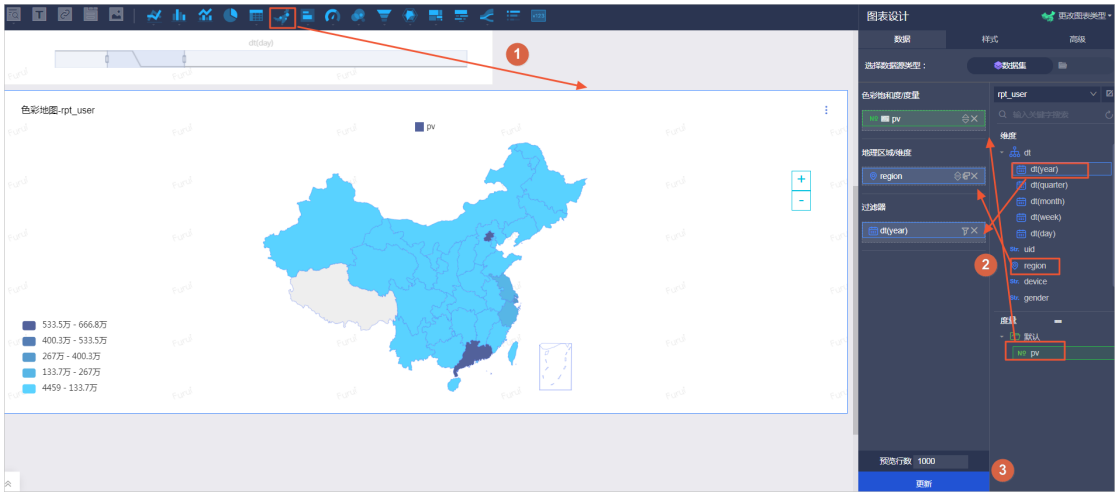

v. 完成配置后，单击**保存**及**预览**，即可看到展示效果。

1.7. 通过Function Studio开发UDF

本文为您介绍如何通过Function Studio开发UDF，并将其提交至DataStudio的开发环境。

使用限制

目前仅华北2（北京）、华东2（上海）、华南1（深圳）和华东1（杭州）地域支持Function Studio。

新建工程

如果您已经有Git代码，可以直接导入Git代码创建工程。此处仅支持Code中的代码导入。

1. 进入**数据开发**页面。
   i. 登录DataWorks控制台。
   ii. 在左侧导航栏，单击**工作空间列表**。
   iii. 选择工作空间所在地域后，单击相应工作空间后的**进入数据开发**。
2. 单击左上方的图标，选择**全部产品 > 数据开发 > Function Studio**。
3. 在**工作空间**页面，单击**导入Git工程**。
4. 在**新建项目**对话框中，输入**Git地址**、**工程名**和**工程描述**，并**选择运行环境**。

   其中**Git地址**仅支持配置为阿里云的Git地址，您可以在云计算服务平台中创建。

   新创建的工程默认未关联Git服务，会弹出**设置**对话框，请首先进行**SSH KEY**、**Git Config**和**偏好设置**的配置，单击**保存**。
   - 选择**SSH Key**中的**service**为 `code.aliyun.com` ，单击**生成sshKey**，即可生成**Public key**，单击**保存**。
   - 填写**Git Config**中的**User Name**和**Email**，单击**保存**。
   - 根据自身需求选择**偏好设置**中的**编辑器字号**，单击**保存**。

> **说明** 如果工程创建完成后，需要修改相关信息，可以鼠标悬停至顶部菜单栏中的**设置**进行修改。

5. 单击**提交**。
   工程创建完成后，Function Studio会自动拉取该工程。

新建SSH密钥

设置好**SSH KEY**、**Git Config**和**偏好设置**后，可以新增SSH密钥。

1. 访问Code页面，单击左侧导航栏中的**设置**。
2. 进入**设置**页面，选择**SSH公钥 > 增加SSH密钥**。

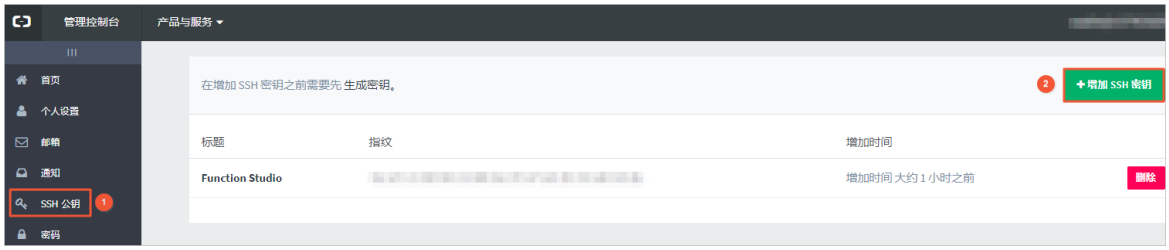

3. 在**增加SSH密钥**对话框中填写前文生成的**Public key**，单击**增加密钥**。

测试需要运行的类

1. 打开需要运行的类，单击右上角的运行按钮进行测试。

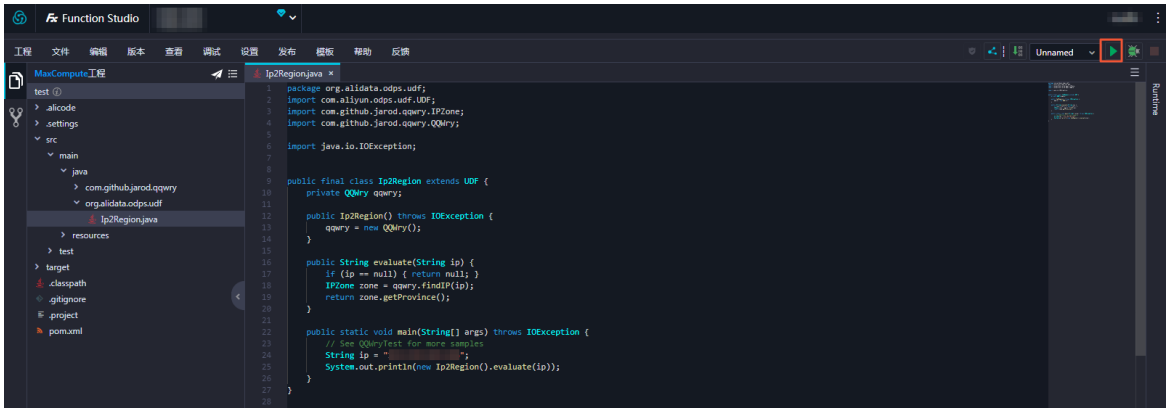

2. 在**Run/Debug Configurations**对话框中，手动添加测试类的信息。

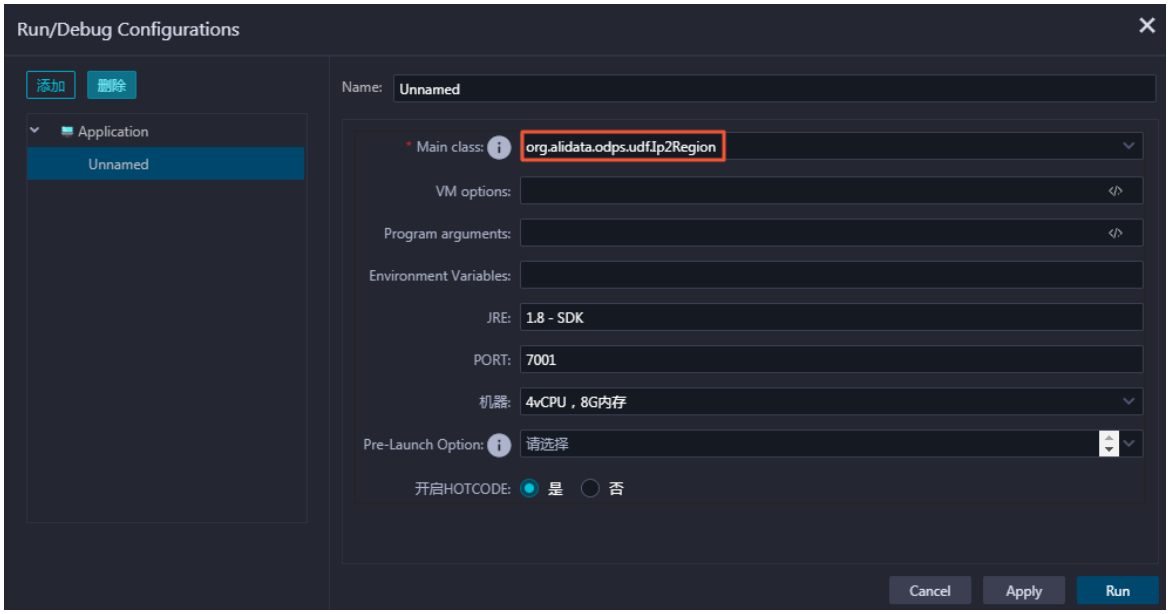

3. 添加完成后，单击**Run**，即可看到输出的测试信息。

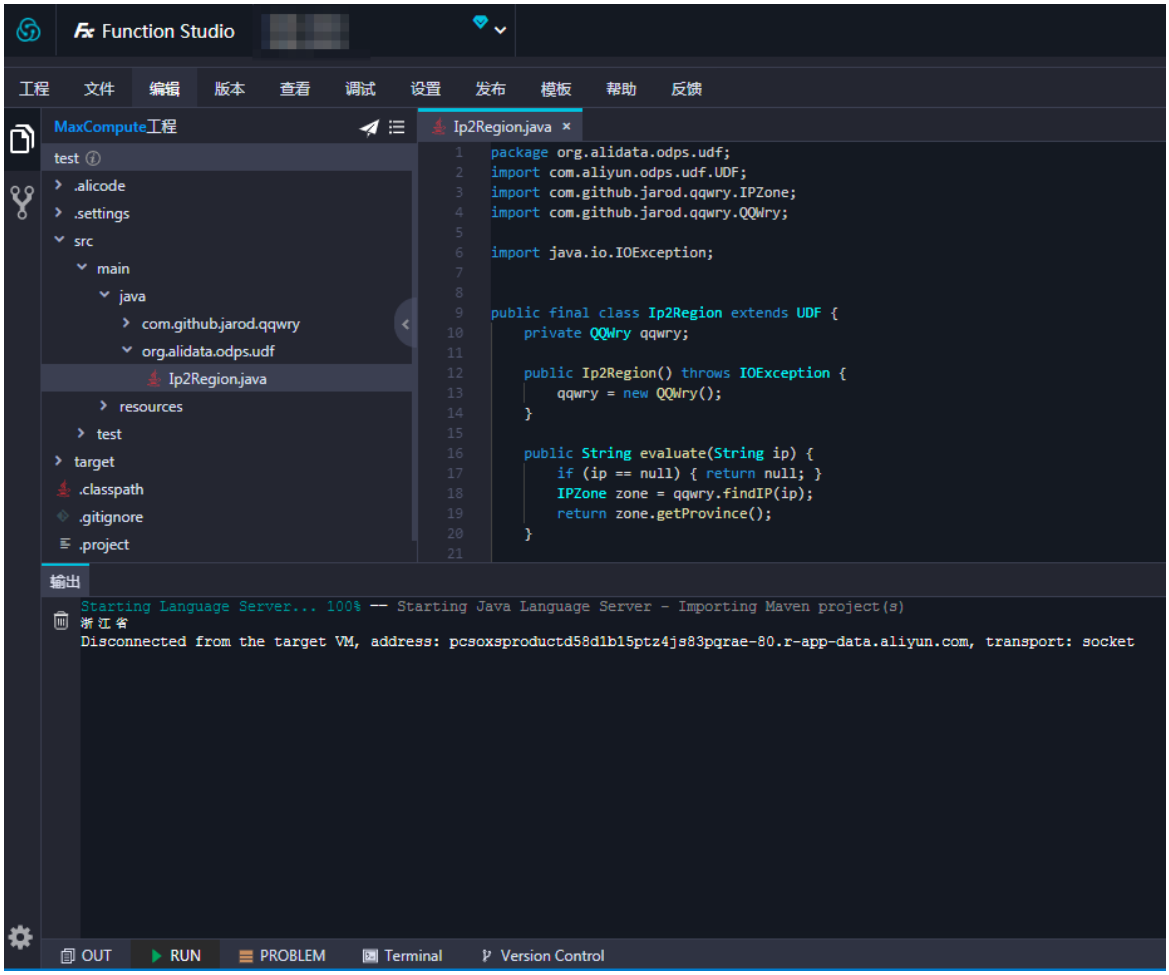

> 说明
> - 第一次启动时速度较慢，之后的启动速度会逐渐接近本地编辑器的体验。
> - 如果需要运行的类已经存在，直接在右上角进行选择，单击运行按钮即可。

提交函数和资源至DataStudio开发环境

确认代码无误后，可以提交函数和资源至DataStudio开发环境。

- 提交资源至DataStudio开发环境。
  i. 鼠标悬停至**提交**按钮，单击**提交资源至DataStudio开发环境**。

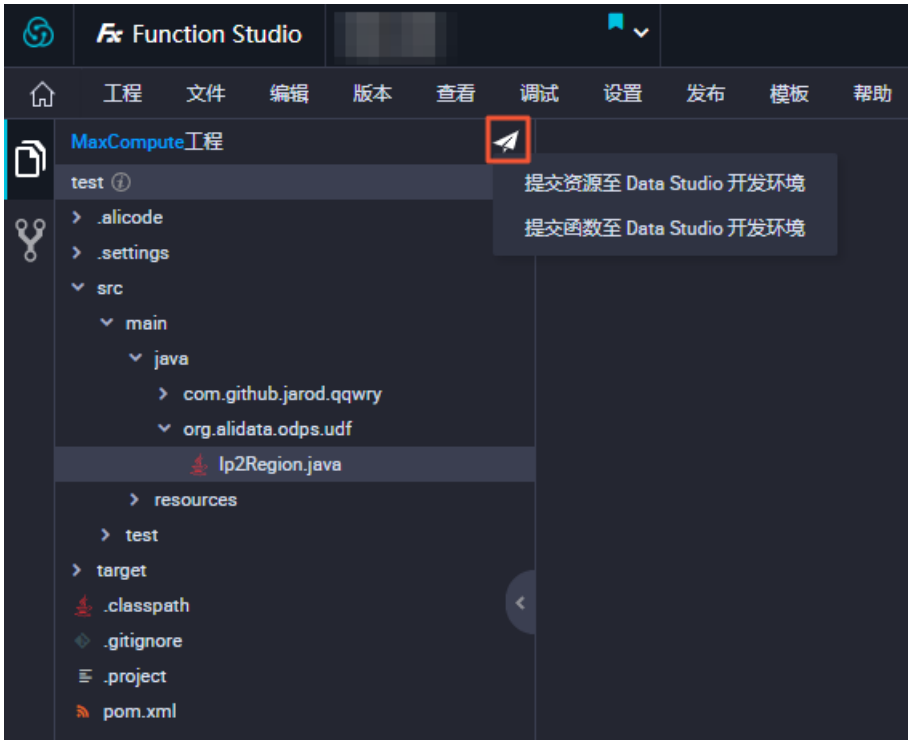

  ii. 选择**提交资源至DataStudio开发环境**对话框中的**目标业务空间**和**目标业务流程**，并填写**资源**。
  iii. 单击**确认**。
- 提交函数至DataStudio开发环境。
  i. 鼠标悬停至**提交**按钮，单击**提交函数至DataStudio开发环境**。
  ii. 选择**提交函数至DataStudio开发环境**对话框中的**目标业务空间**、**目标业务流程**和**类名**，并填写**资源**和**函数名**。
  iii. 单击**确认**。

当资源和函数都提交至DataStudio开发环境后，即可直接在SQL节点中使用。

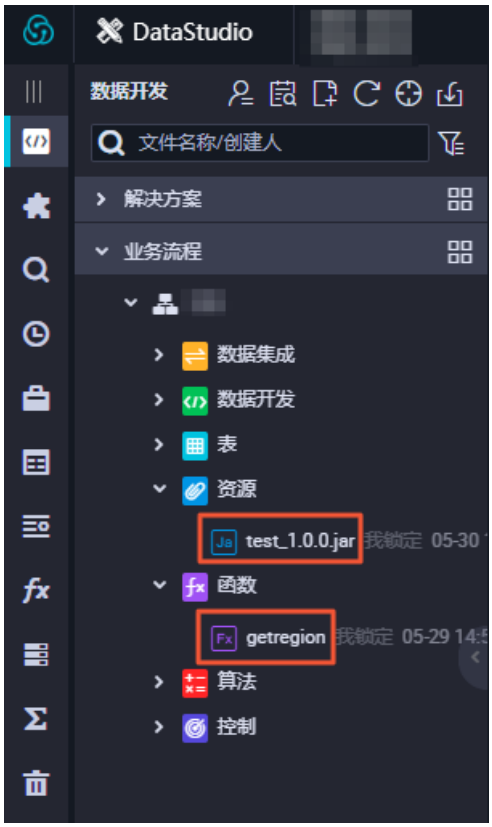

2.简单用户画像分析（EMR版）

2.1. 准备环境

为保证您可以顺利完成本次实验，请您首先确保云账号已开通E-MapReduce（简称为EMR）、数据工场DataWorks和数据存储OSS。

前提条件

- 注册阿里云账号。
- 进行个人实名认证或企业实名认证。
- 您在工作空间配置页面添加E-MapReduce计算引擎实例后，当前页面才会显示EMR目录。详情请参见配置工作空间。
- 您已创建阿里云EMR集群，且集群所在的安全组中入方向的安全策略包含以下策略。
  - 授权策略：允许
  - 协议类型：自定义 TCP
  - 端口范围：8898/8898
  - 授权对象：100.104.0.0/16
- 如果EMR启用了Ranger，则使用DataWorks进行EMR的作业开发前，您需要在EMR中修改配置，添加白名单配置并重启Hive，否则作业运行时会报错Cannot modify spark.yarn.queue at runtime或Cannot modify SKYNET_BIZDATE at runtime。
  i. 白名单的配置通过EMR的自定义参数，添加Key和Value进行配置，以Hive组件的配置为例，配置值如下。

  ```
  hive.security.authorization.sqlstd.confwhitelist.append=tez.*|spark.*|mapred.*|mapreduce.*|ALISA.*|SKYNET.*
  ```

  > **说明** 其中 `ALISA.*` 和 `SKYNET.*` 为DataWorks专有的配置。

  ii. 白名单配置完成后需要重启服务，重启后配置才会生效。重启服务的操作详情请参见重启服务。
- 已开通独享调度资源组，并且独享调度资源组需要绑定EMR所在的VPC专有网络，详情请参见新增和使用独享调度资源组。

  > **说明** 仅支持使用独享调度资源组运行该类型任务。

背景信息

本次实验涉及的阿里云产品如下：

- E-MapReduce
- DataWorks
- OSS

操作步骤

1. 创建EMR集群。
   i. 登录E-MapReduce控制台。

ii. 选择**华东2（上海）**区域，单击**创建集群**。

> **说明**
> - 由于源数据存储在华东2（上海），建议EMR集群创建在相同的区域。
> - 您可以通过**一键购买**和**自定义购买**两种方式创建EMR集群，本文以自定义购买为例。

iii. 在**自定义购买 > 软件配置**对话框中，选择**集群类型**为**Hadoop**，其它配置项默认无需修改。单击**下一步：硬件配置**。

iv. 在**硬件配置**对话框中，选择**付费类型**为**按量付费**，并进行**网络配置**和**实例配置**，单击**下一步：基础配置**。

v. 在**基础配置**对话框中，输入**集群名称**，并选择**密钥对**，单击**下一步：确定**。

EMR默认选项不开启挂载公网，创建集群后只能通过内网访问EMR集群。本次实验的Workshop操作中不涉及挂载公网，直接单击**挂载公网说明**对话框中的**继续下一步**即可。如果您需要公网访问，请进入ECS控制台挂载EIP。

vi. 在**确认**对话框中，确认订单无误后，勾选**《E-MapReduce服务条款》**，单击**创建**。

2. 初始化集群。

购买成功后，即可进入**集群管理**页面进行查看，集群初始化需要几分钟的时间。

i. 集群初始化成功后，单击顶部菜单栏中的**数据开发**。

ii. 在**数据开发**页面，单击**新建项目**。

iii. 在**新建项目**对话框中，输入**项目名称**和**项目描述**。

> **说明** 请使用主账号创建项目，该项目用于关联DataWorks工作空间。

iv. 单击**创建**。

3. 创建DataWorks工作空间。

> **说明** 因本实验提供的数据资源都在华东2（上海），建议您将工作空间创建在华东2（上海），以避免工作空间创建在其它区域，添加数据源时出现网络不可达的情况。

i. 鼠标悬停至EMR控制台左上角的图标，单击**产品与服务 > 大数据（数加） > DataWorks**。

ii. 在左侧导航栏，单击**工作空间列表**。

iii. 在**工作空间列表**页面，鼠标悬停至左上角的地域，单击需要创建工作空间的地域。

iv. 单击**创建工作空间**，进行**基本配置**，单击**下一步**。

分类	参数	描述
基本信息	**工作空间名称**	工作空间名称的长度需要在3~27个字符，以字母开头，且只能包含字母下划线和数字。
	显示名	显示名不能超过27个字符，只能字母、中文开头，仅包含中文、字母、下划线和数字。
	模式	包括**简单模式**和**标准模式**，本文以创建**简单模式**的工作空间为例。
	描述	对创建的工作空间进行简单描述。
高级设置	**能下载select结果**	设置是否允许下载数据开发中查询的数据结果。

v. 在**选择引擎**对话框中，选中**E-MapReduce**引擎，单击**下一步**。

DataWorks已正式商用，如果该地域没有开通，您需要首先开通正式商用服务。

vi. 在**引擎详情**对话框中，配置各项参数。

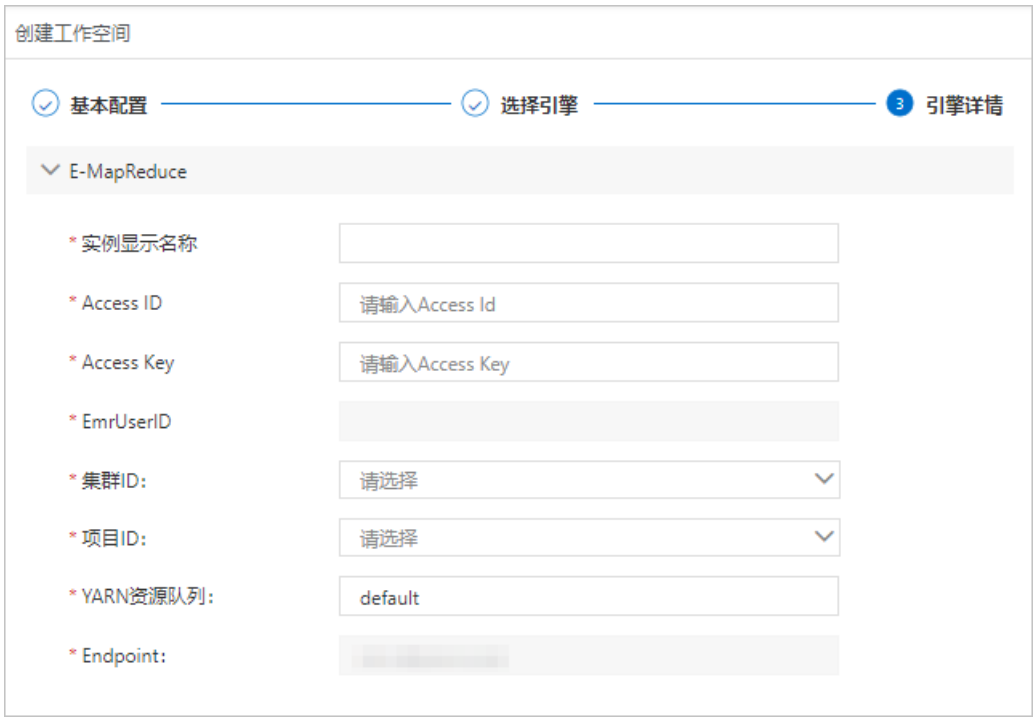

参数	描述
实例显示名称	自定义实例名称。
Access ID	已经授权可以访问EMR集群的账号的AccessKey ID。
Access Key	已经授权可以访问EMR集群的账号的AccessKey Secret。
EmrClusterID	集群ID，从EMR端获取。
集群ID	当前集群创建者的用户ID。
项目ID	当前集群下的项目ID。
YARN资源队列	当前集群下的队列名称。如果无特殊需求，请输入*default*。
Endpoint	EMR的Endpoint，从EMR端获取。

vii. 配置完成后，单击**创建工作空间**。

4. 购买OSS并创建Bucket。
   i. 购买OSS，详情请参见开通OSS服务。
   ii. 登录OSS控制台。
   iii. 在左侧导航栏，单击**Bucket列表**。
   iv. 在**Bucket列表**页面，单击**创建Bucket**。
   v. 在**创建Bucket**对话框中，配置各项参数，单击**确定**。

> **说明** 此处需要选择**区域**为**华东2（上海）**，更多参数说明请参见创建存储空间。

vi. 单击相应的**Bucket名称**，进入Bucket的**文件管理**页面。

vii. 在**新建目录**对话框中，输入**目录名**，单击**确定**。

> **说明** 此处需要新建三个目录，分别存放同步过来的外部OSS数据源、RDS数据源和JAR资源。

2.2. 采集数据

本文为您介绍如何通过DataWorks采集日志数据至EMR引擎。

前提条件

开始本文的操作前，请准备好需要使用的环境。详情请参见准备环境。

背景信息

根据本次实验模拟的场景，您需要分别新建OSS数据源、RDS数据源，用于存储数据。同时需要新建私有OSS数据源，用于存储同步后的数据。

新建OSS数据源

1. 进入**数据源管理**页面。
   i. 登录DataWorks控制台。
   ii. 在左侧导航栏，单击**工作空间列表**。
   iii. 单击相应工作空间后的**进入数据集成**。

   如果您已在DataWorks的某个功能模块，请单击左上方的图标，选择**全部产品 > 数据汇聚 > 数据集成**，进入**数据集成**页面。
   iv. 在左侧导航栏，单击**数据源**，进入**工作空间管理 > 数据源管理**页面。
2. 在**数据源管理**页面，单击右上方的**新增数据源**。
3. 在**新增数据源**对话框中，选择数据源类型为**OSS**。
4. 在**新增OSS数据源**对话框中，配置各项参数。此处您可以直接按照示例参数进行填写。

参数	描述
数据源名称	输入数据源名称，示例为oss_workshop_log。
数据源描述	对数据源进行简单描述。
Endpoint	输入Endpoint，示例为 `http://oss-cn-shanghai-internal.aliyuncs.com` 。
Bucket	输入Bucket名称，示例为new-dataworks-workshop。
AccessKey ID	输入访问密钥中的AccessKey ID，示例为LTAI4FvGT3iU4xjKotpUMAjS。
AccessKey Secret	输入访问密钥中的AccessKey Secret，示例为9RSUoRmNxpRC9EhC4m9PjuG7Jzy7px。

5.

6. 连通性测试通过后，单击**完成**。

新建RDS数据源

1. 在**数据源管理**页面，单击右上方的**新增数据源**。
2. 在**新增数据源**对话框中，选择数据源类型为**MySQL**。
3. 在**新增MySQL数据源**对话框中，配置各项参数。此处您可以直接按照示例参数进行填写。

参数	描述
数据源类型	选择**阿里云实例模式**。
数据源名称	输入数据源名称，示例为rds_workshop_log。
数据源描述	对数据源进行简单描述。
地区	选择RDS实例所在的区域，示例为华东2-上海。
RDS实例ID	输入rm-2ev0681lc7042g16u。
RDS实例主账号ID	输入5600815724958382。
数据库名	输入数据库名称，示例为workshop。
用户名	输入用户名，示例为workshop。
密码	输入密码，示例为workshop#2017。

4.
5. 连通性测试通过后，单击**完成**。

新建私有OSS数据源

本次实验将EMR引擎的数据存储在OSS数据源中。

1. 在**数据源管理**页面，单击右上方的**新增数据源**。
2. 在**新增数据源**对话框中，选择数据源类型为**OSS**。
3. 在**新增OSS数据源**对话框中，配置各项参数。

参数	描述
数据源名称	输入数据源的名称。
数据源描述	对数据源进行简单描述。
Endpoint	输入 `http://oss-cn-shanghai-internal.aliyuncs.com` 。
Bucket	您在环境准备中创建的OSS Bucket的名称，示例为dw-emr-demo。
AccessKey ID	当前登录账号的AccessKey ID，您可以进入**安全信息管理**页面复制AccessKey ID。

参数	描述
AccessKey Secret	输入当前登录账号的AccessKey Secret。

4.
5. 连通性测试通过后，单击**完成**。

新建业务流程

1. 单击左上方的图标，选择**全部产品 > 数据开发 > DataStudio（数据开发）**。
2. 在**数据开发**面板，右键单击**业务流程**，选择**新建业务流程**。
3. 在**新建业务流程**对话框中，输入**业务名称**和**描述**。

   > **注意** 业务名称不能超过128个字符，且必须是大小写字母、中文、数字、下划线（_）以及英文句号（.）。

4. 单击**新建**。
5. 进入业务流程开发面板，鼠标单击**虚拟节点**并拖拽至右侧的编辑页面。在**新建节点**对话框中，输入**节点名称**为workstart，单击**提交**。

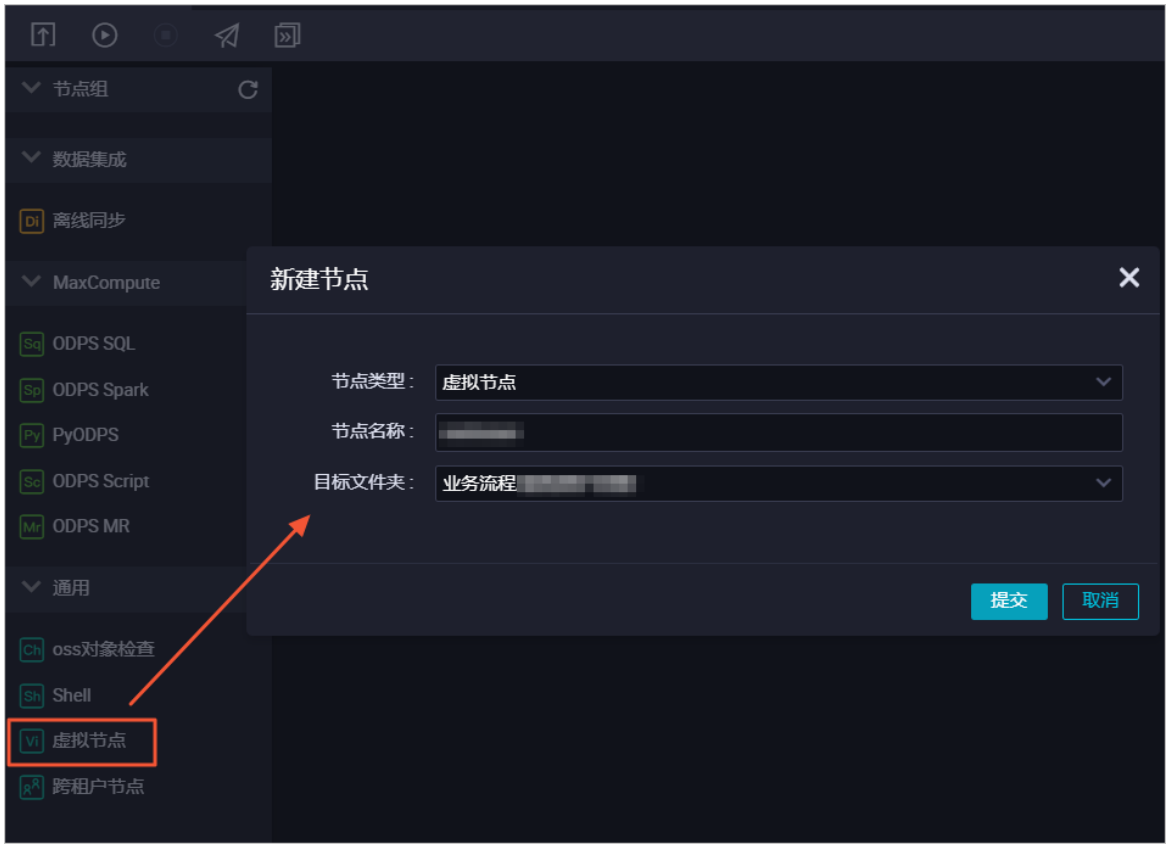

以同样的方式新建两个离线同步节点，**节点名称**分别为Log2oss和User2oss。

6. 通过拖拽连线，将workstart节点设置为两个离线同步节点的上游节点。

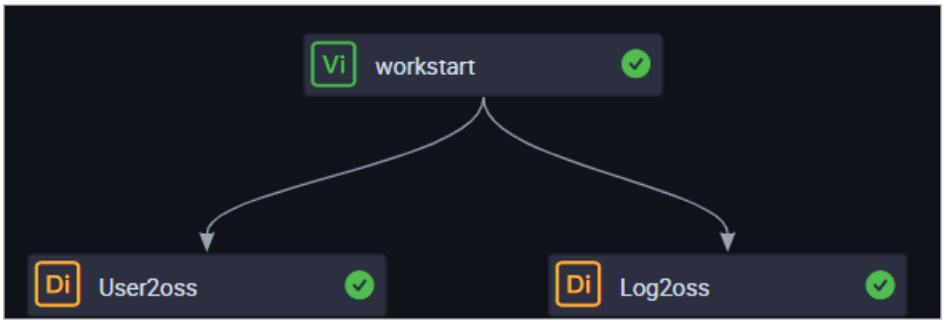

配置workstart节点

1. 在**数据开发**页面，双击相应业务流程下的虚拟节点。打开该节点的编辑页面，单击右侧的**调度配置**。
2. 在**调度依赖**区域，单击**使用工作空间根节点**，设置workstart节点的上游节点为工作空间根节点。

   由于新版本给每个节点都设置了输入输出节点，所以需要给workstart节点设置一个输入。此处设置其上游节点为工作空间根节点，通常命名为工作空间名_root。

3. 配置完成后，单击左上方的图标。

配置离线同步节点

1. 同步RDS数据源的用户信息至自建的OSS。
   i. 在**数据开发**页面，双击User2oss节点，进入节点配置页面。

ii. 选择数据来源。

参数	描述
数据源	选择MySQL > rds_workshop_log数据源。
表	选择数据源中的ods_user_info_d。
数据过滤	您将要同步数据的筛选条件，暂时不支持limit关键字过滤。此处可以不填写。
切分键	建议使用主键或有索引的列作为切分键，仅支持类型为整型的字段。此处设置切分键为uid。

iii. 选择数据去向。

参数	描述
数据源	选择前文创建的OSS数据源，此处示例为**OSS > dw_emr_demo**数据源。
Object前缀	根据您自建OSS的目录进行输入，示例为ods_user_info_d/user_${bizdate}/user_${bizdate}.txt。
文本类型	选择text类型。
列分隔符	输入列分隔符为|。
编码格式	默认为UTF-8格式。
null值	表示null值的字符串，此处可以不填写。
时间格式	时间序列化格式，此处可以不填写。
前缀冲突	此处选择**替换原有文件**。

iv. 配置字段映射。

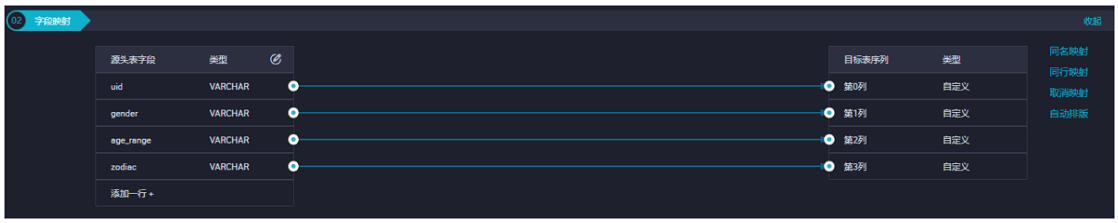

v. 配置**通道控制**，单击工具栏中的图标。

vi. 单击工具栏中的图标，在已有的脚本中手动添加参数"writeSingleObject": "true"和"suffix": ".txt"。

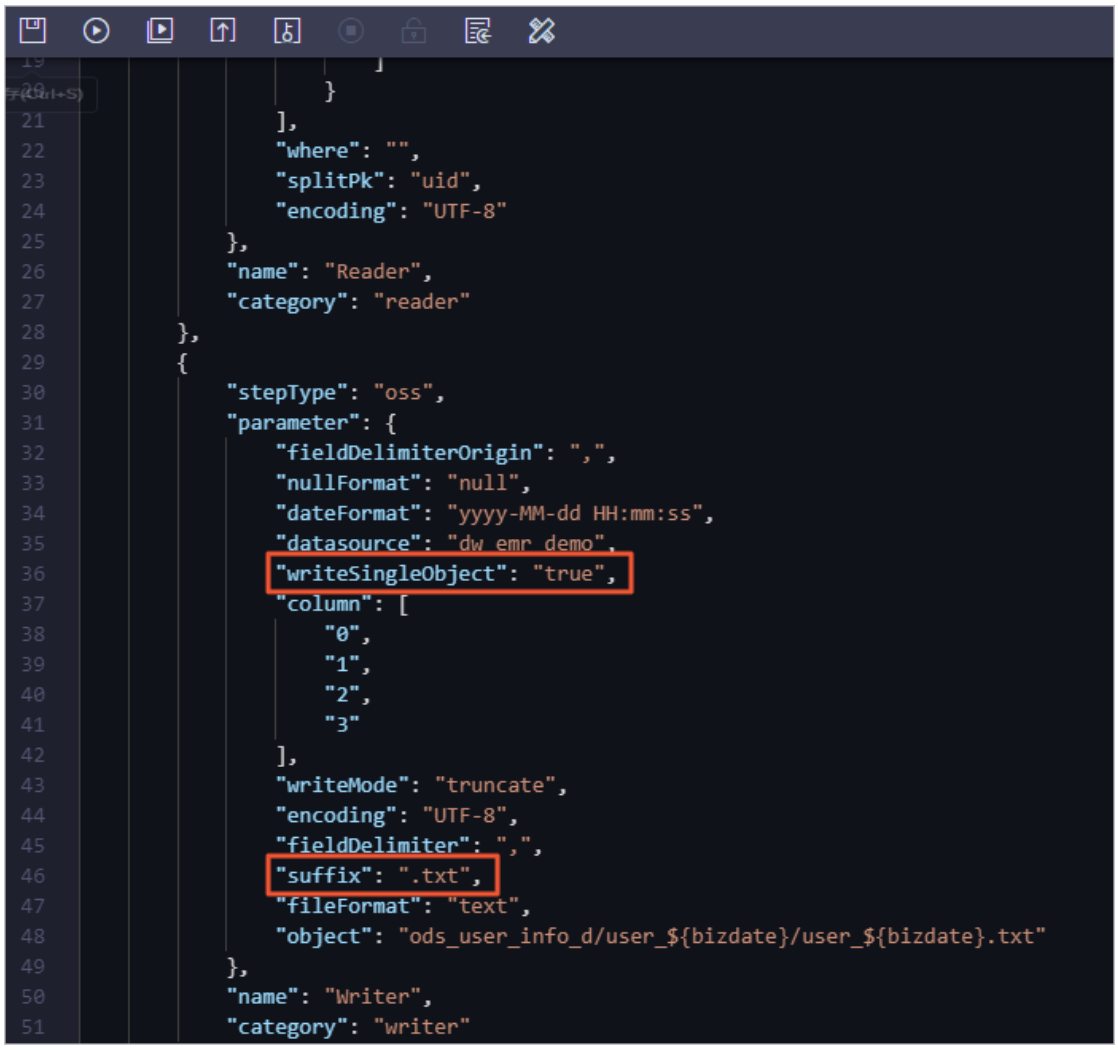

```
                    }
                ],
                "where": "",
                "splitPk": "uid",
                "encoding": "UTF-8"
            },
            "name": "Reader",
            "category": "reader"
        },
        {
            "stepType": "oss",
            "parameter": {
                "fieldDelimiterOrigin": ",",
                "nullFormat": "null",
                "dateFormat": "yyyy-MM-dd HH:mm:ss",
                "datasource": "dw_emr_demo",
                "writeSingleObject": "true",
                "column": [
                    "0",
                    "1",
                    "2",
                    "3"
                ],
                "writeMode": "truncate",
                "encoding": "UTF-8",
                "fieldDelimiter": ",",
                "suffix": ".txt",
                "fileFormat": "text",
                "object": "ods_user_info_d/user_${bizdate}/user_${bizdate}.txt"
            },
            "name": "Writer",
            "category": "writer"
```

> 说明
>
> - writeSingleObject和suffix参数仅支持脚本模式进行添加。
> - 存储的路径object需要与自建OSS中的目录一致。

vii. 配置完成后，单击工具栏中的图标。

2. 同步OSS数据源的日志信息至自建的OSS。

i. 在**数据开发**页面，双击Log2oss节点，进入节点配置页面。

ii. 选择数据来源。

参数	描述
数据源	选择**OSS > oss_workshop_log**数据源。
Object前缀	输入user_log.txt。
文本类型	选择text类型。
列分隔符	输入列分隔符为|。
编码格式	默认为UTF-8格式。
null值	表示null值的字符串，此处可以不填写。
压缩格式	包括None、Gzip、Bzip2和Zip四种类型，此处选择None。
是否包含表头	默认为No。

iii. 选择数据去向。

参数	描述
数据源	选择前文创建的OSS数据源，此处示例为**OSS > dw_emr_demo**数据源。
Object前缀	根据您自建OSS的目录进行输入，示例为ods_raw_log_d/user_log_${bizdate}/user_log_${bizdate}.txt。
文本类型	选择text类型。
列分隔符	输入列分隔符为|。
编码格式	默认为UTF-8格式。
null值	表示null值的字符串，此处可以不填写。
时间格式	时间序列化格式，此处可以不填写。
前缀冲突	此处选择**替换原有文件**。

iv. 配置字段映射。

> 注意 源数据表中只有一列数据，此处需要删除其它映射过来的空列。

v. 配置**通道控制**，单击工具栏中的图标。

vi. 单击工具栏中的图标，在已有的脚本中手动添加参数"writeSingleObject": "true"和"suffix": ".txt"。

> 说明
> - writeSingleObject和suffix参数仅支持脚本模式进行添加。
> - 存储的路径object需要与自建OSS中的目录一致。

vii. 配置完成后，单击工具栏中的图标。

新建表

1. 在**数据开发**页面打开新建的业务流程，右键单击**EMR**，选择**新建 > EMR Hive**。
2. 在**新建节点**对话框中，输入**节点名称**，单击**提交**。

   此处需要新建两个EMR Hive节点（ods_user_info_d和ods_raw_log_d），分别新建存储同步过来的OSS日志数据和RDS日志数据的两张表。

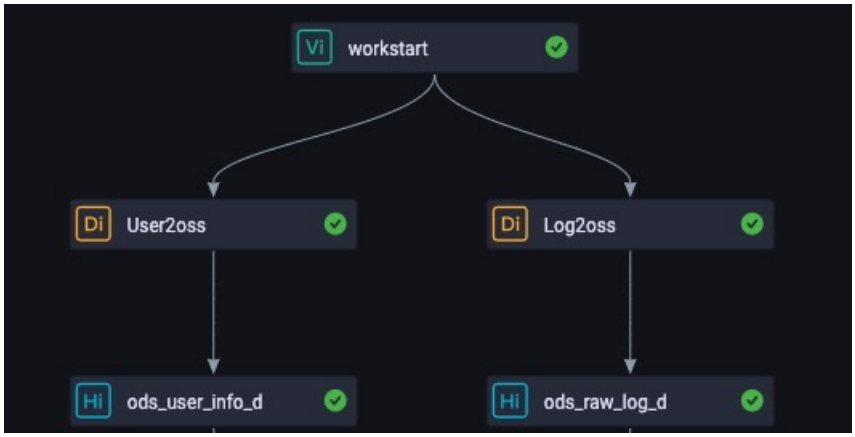

3. 分别在EMR Hive节点中，**选择EMR引擎**并输入建表语句，单击**保存**并**运行**各建表语句。
   - 新建ods_user_info_d表。

     双击ods_user_info_d节点，在右侧的编辑页面输入下述建表语句。

```
--author
--create time:2020-06-12 14:10:02
--************************************************************************
CREATE EXTERNAL TABLE IF NOT  EXISTS ods_user_info_d
(
    `uid` STRING COMMENT '用户ID',
    `gender` STRING COMMENT '性别',
    `age_range` STRING COMMENT '年龄段',
    `zodiac` STRING COMMENT '星座'
) PARTITIONED BY (
  dt STRING
)
ROW FORMAT  delimited fields terminated by '|'
LOCATION 'oss://dw-emr-demo/ods_user_info_d/';

ALTER ods_user_info_d ADD IF NOT EXISTS PARTITION (dt=${bizdate})
LOCATION 'oss://dw-emr-demo/ods_user_info_d/user_${bizdate}/';
```

```
CREATE EXTERNAL TABLE IF NOT EXISTS ods_user_info_d
(
    `uid` STRING COMMENT '用户ID',
    `gender` STRING COMMENT '性别',
    `age_range` STRING COMMENT '年龄段',
    `zodiac` STRING COMMENT '星座'
) PARTITIONED BY (
  dt STRING
)
ROW FORMAT  delimited fields terminated by '|'
LOCATION 'oss://dw-emr-demo/ods_user_info_d/';
ALTER TABLE ods_user_info_d ADD IF NOT EXISTS PARTITION (dt=${bizdate})
LOCATION 'oss://dw-emr-demo/ods_user_info_d/user_${bizdate}/';
```

> **说明** 上述代码中的location为示例路径，需要输入您建立的文件夹的路径名称。

- 新建ods_raw_log_d表。

  双击ods_raw_log_d节点，在右侧的编辑页面输入下述建表语句。

```
--创建OSS日志对应目标表
CREATE EXTERNAL TABLE IF NOT EXISTS ods_raw_log_d
(
  `col` STRING
) PARTITIONED BY (
  dt STRING
);
ALTER TABLE ods_raw_log_d ADD IF NOT EXISTS PARTITION (dt=${bizdate})
LOCATION 'oss://dw-emr-demo/ods_raw_log_d/user_log_${bizdate}/';
```

> **说明** 上述代码中的location为示例路径，需要输入您建立的文件夹的路径名称。

4. 查看数据同步结果。

   建表语句运行成功后，分别在两个EMR Hive节点中输入查询语句。

> **说明** 查询语句中的分区列需要更新为业务日期。例如，任务运行的日期为20191107，则业务日期为20191106，即任务运行日期的前一天。

- 查询ods_user_info_d表的数据。

```
SELECT * from ods_user_info_d where dt=业务日期; --业务日期为任务运行日期的前一天。
```

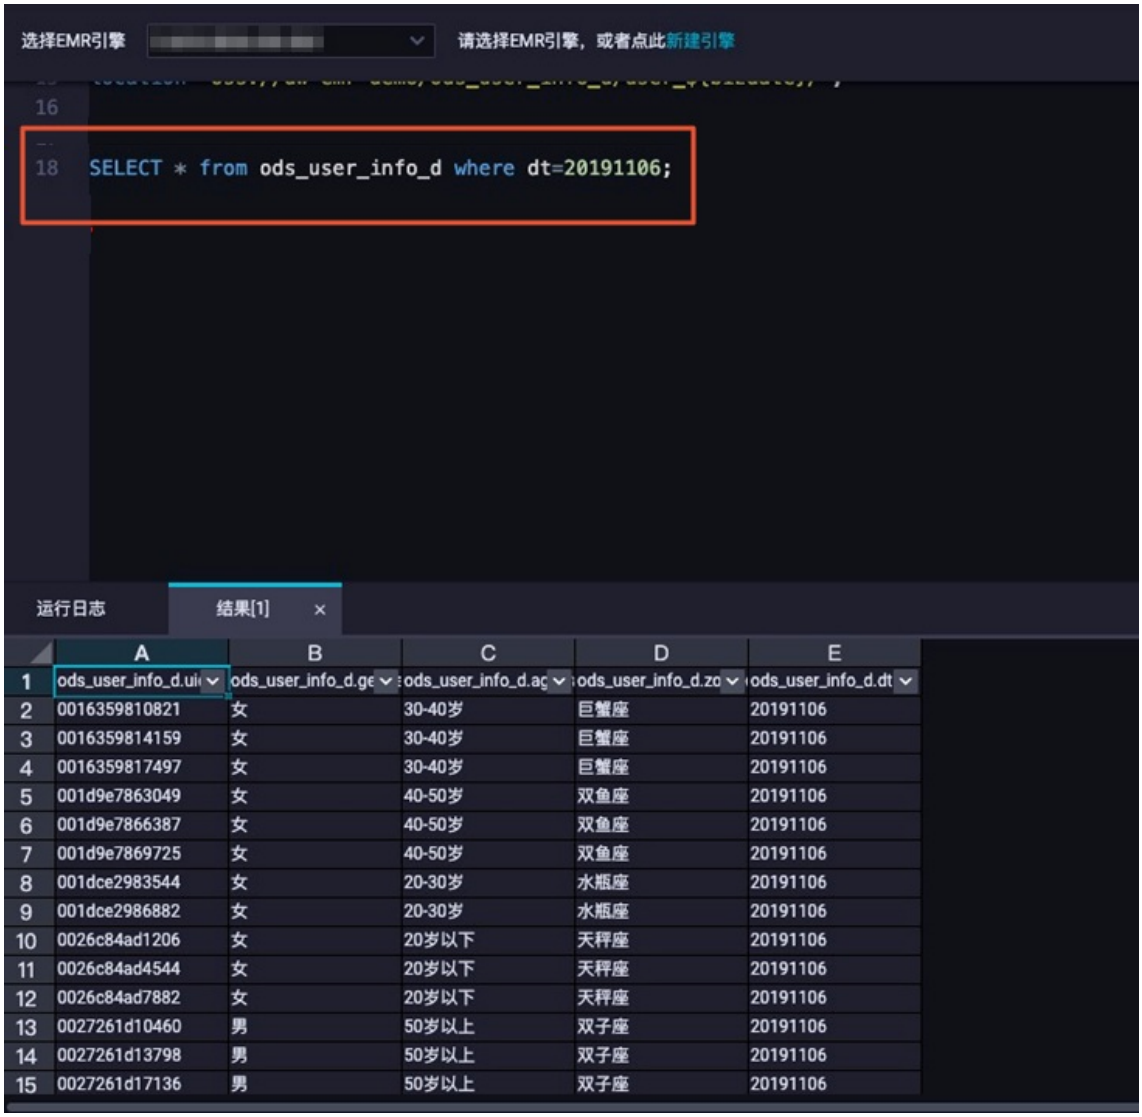

	A	B	C	D	E
1	ods_user_info_d.ui	ods_user_info_d.ge	ods_user_info_d.ag	ods_user_info_d.zo	ods_user_info_d.dt
2	0016359810821	女	30-40岁	巨蟹座	20191106
3	0016359814159	女	30-40岁	巨蟹座	20191106
4	0016359817497	女	30-40岁	巨蟹座	20191106
5	001d9e7863049	女	40-50岁	双鱼座	20191106
6	001d9e7866387	女	40-50岁	双鱼座	20191106
7	001d9e7869725	女	40-50岁	双鱼座	20191106
8	001dce2983544	女	20-30岁	水瓶座	20191106
9	001dce2986882	女	20-30岁	水瓶座	20191106
10	0026c84ad1206	女	20岁以下	天秤座	20191106
11	0026c84ad4544	女	20岁以下	天秤座	20191106
12	0026c84ad7882	女	20岁以下	天秤座	20191106
13	0027261d10460	男	50岁以上	双子座	20191106
14	0027261d13798	男	50岁以上	双子座	20191106
15	0027261d17136	男	50岁以上	双子座	20191106

- 查询ods_raw_log_d表的数据。

```
SELECT * from ods_raw_log_d where dt=业务日期; --业务日期为任务运行日期的前一天。
```

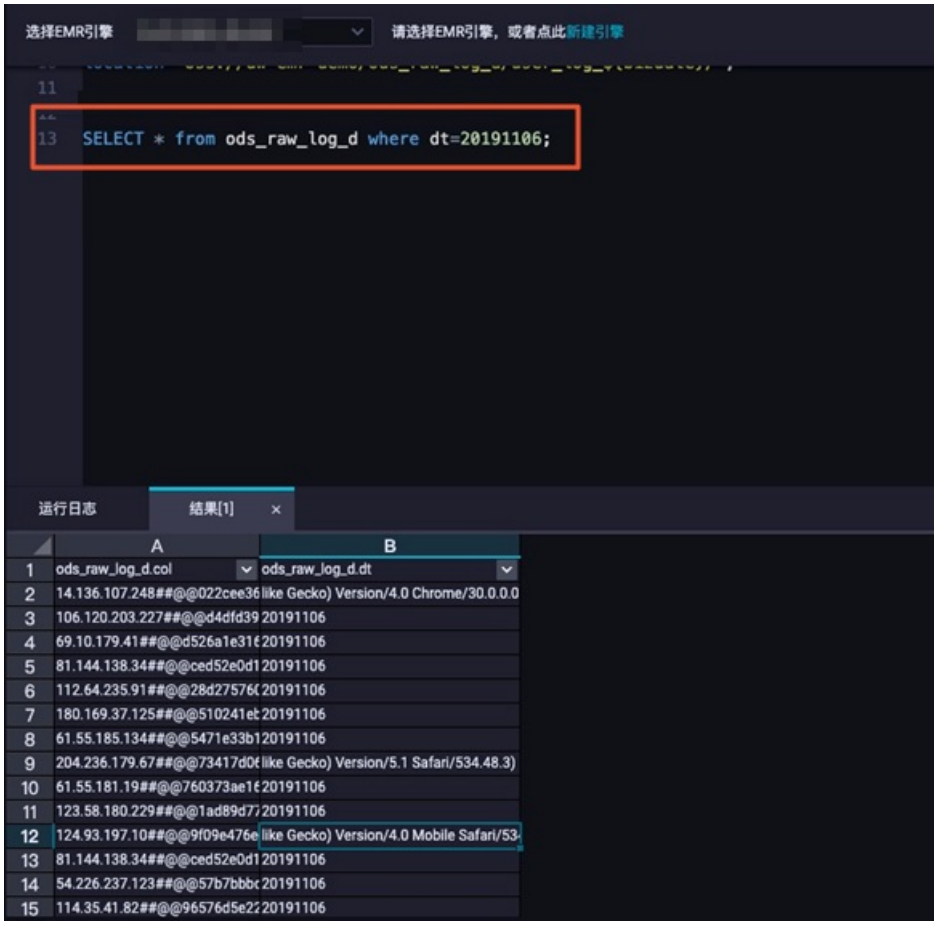

后续步骤

现在，您已经学习了如何进行日志数据同步，完成数据的采集，您可以继续下一个教程。在该教程中，您将学习如何对采集的数据进行计算与分析。详情请参见加工数据。

2.3. 加工数据

本文将为您介绍如何通过DataWorks中的EMR Hive节点加工采集的日志数据。

前提条件

开始本实验前，请首先完成采集数据中的操作。

在OSS上传资源

1. 下载ip2region-emr.jar存放至本地。
2. 登录OSS控制台。
3. 在左侧**存储空间**列表中，单击目标存储空间（示例为dw-emr-demo）。
4. 单击**文件管理**，打开在 *环境准备* 章节新建的用于存储JAR资源的目录，示例的目录名为ip2region。
5. 单击**上传文件**，在**上传文件**对话框中，设置上传文件的参数。

参数	描述
上传到	选择**当前目录**，示例的目录路径为*oss://dw-emr-demo/ip2region/*。
文件ACL	默认为**继承Bucket**，即单个文件的读写权限以Bucket的读写权限为准。
上传文件	单击**直接上传**，选择已下载的ip2region-emr.jar文件。

设计业务流程

业务流程节点间依赖关系的配置请参见采集数据。

双击新建的业务流程打开编辑页面，鼠标单击**EMR Hive**并拖拽至右侧的编辑页面。在**新建节点**对话框中，输入**节点名称**，单击**提交**。

此处需要新建3个EMR Hive节点，依次命名为ods_log_info_d、dw_user_info_all_d和rpt_user_info_d，并配置如下图所示的依赖关系。

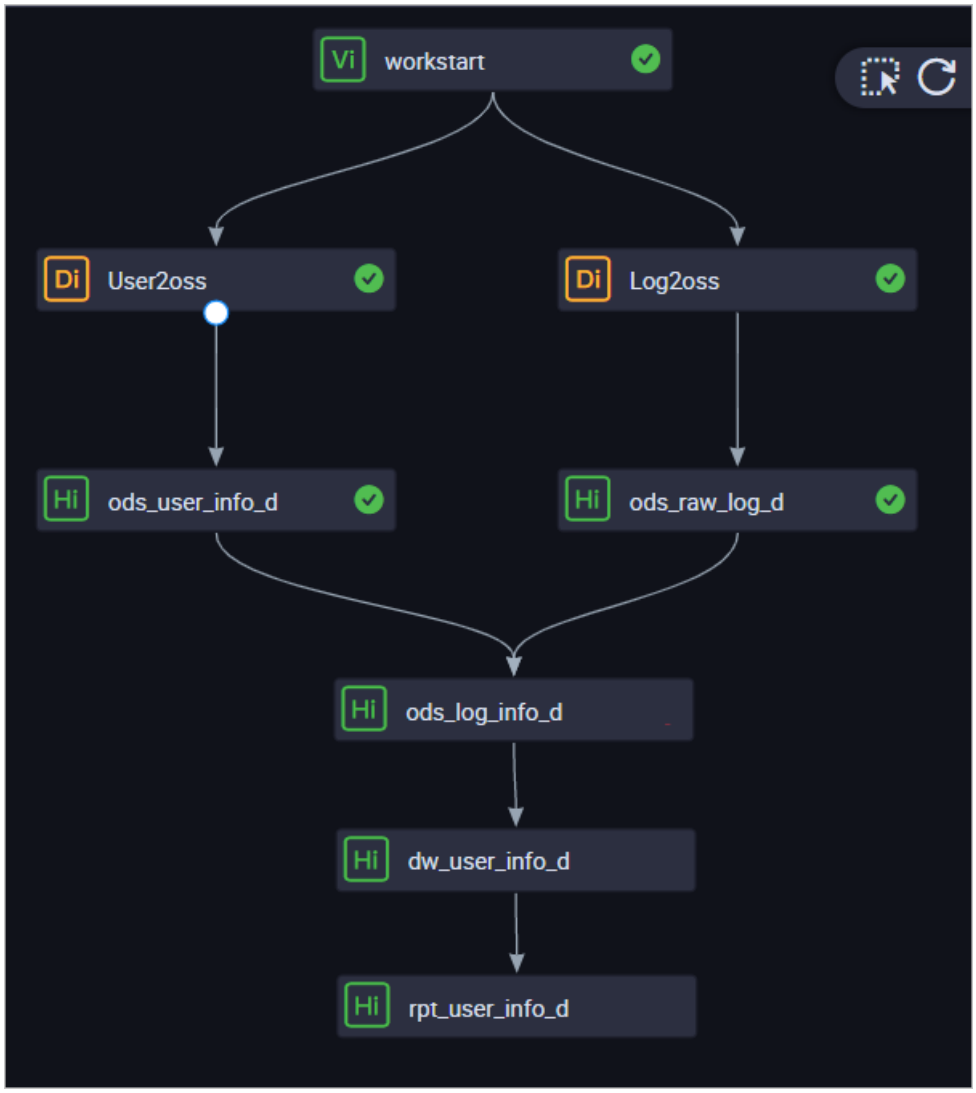

配置EMR Hive节点

1. 配置ods_log_info_d节点。
   i. 双击ods_log_info_d节点，进入节点配置页面。
   ii. 在节点编辑页面，编写如下语句。

> **说明** 如果您的工作空间绑定多个EMR引擎，需要**选择EMR引擎**。如果仅绑定一个EMR引擎，则无需选择。

```
--创建ODS层表
CREATE TABLE IF NOT EXISTS ods_log_info_d (
  ip STRING COMMENT 'ip地址',
  uid STRING COMMENT '用户ID',
  `time` STRING COMMENT '时间yyyymmddhh:mi:ss',
  status STRING COMMENT '服务器返回状态码',
  bytes STRING COMMENT '返回给客户端的字节数',
  region STRING COMMENT '地域，根据ip得到',
  method STRING COMMENT 'http请求类型',
  url STRING COMMENT 'url',
  protocol STRING COMMENT 'http协议版本号',
```

```
  protocol STRING COMMENT 'http协议版本号',
  referer STRING COMMENT '来源url',
  device STRING COMMENT '终端类型 ',
  identity STRING COMMENT '访问类型 crawler feed user unknown'
)
PARTITIONED BY (
  dt STRING
);
create function  getregion as 'org.alidata.emr.udf.Ip2Region'
using jar 'oss://dw-emr-demo/ip2region/ip2region-emr.jar';
ALTER TABLE ods_log_info_d ADD IF NOT EXISTS PARTITION (dt=${bizdate});
set hive.vectorized.execution.enabled = false;
INSERT OVERWRITE TABLE ods_log_info_d PARTITION (dt=${bizdate})
SELECT ip
  , uid
  , tm
  , status
  , bytes
  , getregion(ip) AS region --使用自定义UDF通过ip得到地域。
  , regexp_extract(request, '(^[^ ]+) .*') AS method --通过正则把request差分为三个字段
。
  , regexp_extract(request, '^[^ ]+ (.*) [^ ]+$') AS url
  , regexp_extract(request, '.* ([^ ]+$)') AS protocol
  , regexp_extract(referer, '^[^/]+://([^/]+){1}') AS referer  --通过正则清洗refer，
得到更精准的url。
  , CASE
    WHEN lower(agent) RLIKE 'android' THEN 'android' --通过agent得到终端信息和访问形式
。
    WHEN lower(agent) RLIKE 'iphone' THEN 'iphone'
    WHEN lower(agent) RLIKE 'ipad' THEN 'ipad'
    WHEN lower(agent) RLIKE 'macintosh' THEN 'macintosh'
    WHEN lower(agent) RLIKE 'windows phone' THEN 'windows_phone'
    WHEN lower(agent) RLIKE 'windows' THEN 'windows_pc'
    ELSE 'unknown'
  END AS device
  , CASE
    WHEN lower(agent) RLIKE '(bot|spider|crawler|slurp)' THEN 'crawler'
    WHEN lower(agent) RLIKE 'feed'
    OR regexp_extract(request, '^[^ ]+ (.*) [^ ]+$') RLIKE 'feed' THEN 'feed'
    WHEN lower(agent) NOT RLIKE '(bot|spider|crawler|feed|slurp)'
    AND agent RLIKE '^[Mozilla|Opera]'
    AND regexp_extract(request, '^[^ ]+ (.*) [^ ]+$') NOT RLIKE 'feed' THEN 'user'
    ELSE 'unknown'
  END AS identity
  FROM (
    SELECT SPLIT(col, '##@@')[0] AS ip
    , SPLIT(col, '##@@')[1] AS uid
    , SPLIT(col, '##@@')[2] AS tm
    , SPLIT(col, '##@@')[3] AS request
    , SPLIT(col, '##@@')[4] AS status
    , SPLIT(col, '##@@')[5] AS bytes
    , SPLIT(col, '##@@')[6] AS referer
    , SPLIT(col, '##@@')[7] AS agent
    FROM ods_raw_log_d
  WHERE dt = ${bizdate}
```

```
) a;
```

iii. 单击工具栏中的。

2. 配置dw_user_info_all_d节点。

i. 双击dw_user_info_all_d节点，进入节点配置页面。

ii. 在节点编辑页面，编写如下语句。

> **说明** 如果您的工作空间绑定多个EMR引擎，需要**选择EMR引擎**。如果仅绑定一个EMR引擎，则无需选择。

```
--创建DW层表
CREATE TABLE IF NOT EXISTS dw_user_info_all_d (
  uid STRING COMMENT '用户ID',
  gender STRING COMMENT '性别',
  age_range STRING COMMENT '年龄段',
  zodiac STRING COMMENT '星座',
  region STRING COMMENT '地域，根据ip得到',
  device STRING COMMENT '终端类型 ',
  identity STRING COMMENT '访问类型 crawler feed user unknown',
  method STRING COMMENT 'http请求类型',
  url STRING COMMENT 'url',
  referer STRING COMMENT '来源url',
  `time` STRING COMMENT '时间yyyymmddhh:mi:ss'
)
PARTITIONED BY (
  dt STRING
);
ALTER TABLE dw_user_info_all_d ADD IF NOT EXISTS PARTITION (dt = ${bizdate});
INSERT OVERWRITE TABLE dw_user_info_all_d PARTITION (dt=${bizdate})
SELECT COALESCE(a.uid, b.uid) AS uid
  , b.gender
  , b.age_range
  , b.zodiac
  , a.region
  , a.device
  , a.identity
  , a.method
  , a.url
  , a.referer
  , a.`time`
FROM (
  SELECT *
  FROM ods_log_info_d
  WHERE dt = ${bizdate}
) a
LEFT OUTER JOIN (
  SELECT *
  FROM ods_user_info_d
  WHERE dt = ${bizdate}
) b
ON a.uid = b.uid;
```

iii. 单击工具栏中的。

3. 配置rpt_user_info_d节点。

i. 双击rpt_user_info_d节点，进入节点配置页面。

ii. 在节点编辑页面，编写如下语句。

> **说明** 如果您的工作空间绑定多个EMR引擎，需要**选择EMR引擎**。如果仅绑定一个EMR引擎，则无需选择。

```
--创建RPT层表
CREATE TABLE IF NOT EXISTS rpt_user_info_d (
  uid STRING COMMENT '用户ID',
  region STRING COMMENT '地域，根据ip得到',
  device STRING COMMENT '终端类型 ',
  pv BIGINT COMMENT 'pv',
  gender STRING COMMENT '性别',
  age_range STRING COMMENT '年龄段',
  zodiac STRING COMMENT '星座'
)
PARTITIONED BY (
  dt STRING
);
ALTER TABLE rpt_user_info_d ADD IF NOT EXISTS PARTITION (dt=${bizdate});
INSERT OVERWRITE TABLE rpt_user_info_d PARTITION (dt=${bizdate})
SELECT uid
  , MAX(region)
  , MAX(device)
  , COUNT(0) AS pv
  , MAX(gender)
  , MAX(age_range)
  , MAX(zodiac)
FROM dw_user_info_all_d
WHERE dt = ${bizdate}
GROUP BY uid;
```

iii. 单击工具栏中的。

提交业务流程

1. 在业务流程的编辑页面，单击，运行业务流程。
2. 待业务流程中的所有节点后出现，单击，提交运行成功的业务流程。
3. 选择**提交**对话框中需要提交的节点，勾选**忽略输入输出不一致的告警**。
4. 单击**提交**。

在生产环境运行任务

1. 任务发布成功后，单击右上角的**运维中心**。
   您也可以进入业务流程的编辑页面，单击工具栏中的**前往运维**，进入**运维中心**页面。
2. 单击左侧导航栏中的**周期任务运维 > 周期任务**，进入**周期任务**页面，单击workstart虚节点。
3. 在右侧的DAG图中，右键单击workstart节点，选择**补数据 > 当前节点及下游节点**。
4. 勾选需要补数据的任务，输入业务日期，单击**确定**，自动跳转至**补数据实例**页面。
5. 单击**刷新**，直至SQL任务全部运行成功即可。

后续步骤

现在，您已经学习了如何创建EMR Hive节点、如何处理原始日志数据。您可以继续下一个教程，学习如何在数据地图模块开启元数据收集功能，并查看数据表信息。详情请参见收集和查看元数据。

2.4. 收集和查看元数据

本文为您介绍如何在数据地图模块开启元数据收集功能，并查看数据表信息。

前提条件

开始本实验前，请首先完成加工数据中的操作。

背景信息

元数据是数据的描述数据，可以为数据说明其属性（名称、大小、数据类型等），或结构（字段、类型、长度等），或其相关数据（位于何处、拥有者、产出任务、访问权限等）。DataWorks中元数据主要指库、表相关的信息，元数据管理对应的主要应用是数据地图。

开启元数据收集

1.
2.
3.
4.
5.
6.
7.
8. 在**E-MapReduce元数据采集**页面，单击新建的采集器后的**运行全量获取**。

   单击页面右上角的**刷新**，待EMR采集实例的**运行状态**显示为**收集成功**即可。

   > **说明** 全量采集E-MapReduce元数据后，系统会开启自动增量采集，自动同步表中新增的元数据。

查看数据表信息

1. 在当前页面的顶部菜单栏，单击**全部数据**。
2. 在**全部数据**页面，单击**E-MapReduce**。
3. 在**E-MapReduce**页签下，单击表名（rpt_user_info_d），查看该表的详情。

   您也可以在顶部搜索框中输入关键字进行搜索，查看E-MapReduce表详情。
4. 单击**血缘信息**，查看该表的上下游血缘详情。

后续步骤

现在，您已经学习了如何在数据地图模块开启元数据收集功能，并查看数据表信息。您可以继续下一个教程，学习如何对开发完成的任务设置数据质量监控，保证任务运行的质量。详情请参见配置数据质量监控。

2.5. 配置数据质量监控

本文为您介绍如何配置表ods_log_info_d的数据质量监控规则。

前提条件

在进行本实验前，请首先采集元数据，详情请参见收集和查看元数据。

操作步骤

1. 进入**数据开发**页面。
   i. 登录DataWorks控制台。
   ii. 在左侧导航栏，单击**工作空间列表**。
   iii. 选择工作空间所在地域后，单击相应工作空间后的**进入数据开发**。
2. 进入ods_log_info_d表的**监控规则**页面。
   i. 单击左上角的图标，选择**全部产品 > 数据质量**。
   ii. 在左侧导航栏，单击**监控规则**，从数据源下拉列表中选择**EMR**。
   iii. 单击ods_log_info_d表后的**配置监控规则**。
3. 添加分区表达式。
   i. 在**已添加的分区表达式**模块，单击**+**。
   ii. **添加分区**对话框中，选择**分区表达式**为dt=$[yyyymmdd-1]，并选择相应的**数据质量插件**。
   iii. 单击**计算**，即可查看调度结果。
   iv. 确认无误后，单击**确认**。
4. 创建规则。
   i. 选中分区后，单击右上角的**创建规则**。
   ii. 在**模板规则**对话框中，单击**添加监控规则**。
   iii. 配置监控规则。

参数	描述
规则名称	新建规则的名称。
强弱	设置规则的强度为**强**。
动态阈值	根据自身需求，选择是否开启动态阈值。 **说明** 您需要购买DataWorks企业版及以上版本，才可以使用动态阈值功能。
规则来源	包括**内置模板**和**规则模板库**。 **说明** 您需要购买DataWorks企业版及以上版本，才可以选择**规则模板库**。
规则字段	请选择**表级规则（table）**。

参数	描述
规则模板	请选择**表行数，固定值**。
比较方式	请选择**大于**。
期望值	设置为0，即比较方式为期望值大于0。

iv. 配置完成后，单击**批量添加**。

5. 进行试跑。
   i. 单击页面右上角的**试跑**。
   ii. 在**试跑**对话框中，选择**调度时间**和**资源组**，单击**试跑**。
   iii. 试跑完成后，单击**试跑成功！点击查看试跑结果**，即可跳转至试跑结果页面。
6. 进行关联调度。
   i. 在ods_log_info_d表的**监控规则**页面，单击**关联调度**。
   ii. 在**关联调度**对话框中，输入节点ID或节点名称，单击**添加**。
   iii. 添加完成后，即可完成与调度节点任务的绑定，则任务实例运行完成都会触发数据质量的检查。
7. 配置任务订阅。
   i. 在ods_log_info_d表的**监控规则**页面，单击**订阅管理**。
   ii. 在**订阅管理**对话框中，设置**订阅方式**和**接受对象**。
   目前支持的订阅方式包括**邮件通知**、**邮件和短信通知**、**钉钉群机器人**和**钉钉群机器人@ALL**。
   iii. 设置完成后，单击**保存**，您可以进入**我的订阅**页面进行查看和修改。

3.搭建互联网在线运营分析平台

3.1. 业务场景与开发流程

本教程基于大数据时代在线运营分析平台的基础需求，为开发者提供从数据高并发写入存储、便捷高效的数据加工处理到数据分析与展示的全链路解决方案。本教程帮助您了解并操作阿里云的大数据产品，完成在线运营分析平台的搭建。

业务场景

本文的示例基于真实的网站日志数据集，数据来源于某网站上的HTTP访问日志数据。基于这份网站日志，您可以实现如下分析需求：

- 统计并展现网站的PV和UV，并能够按照用户的终端类型（例如，Android、iPad、iPhone和PC等）分别统计。

  > **说明** 浏览次数（PV）和独立访客（UV）是衡量网站流量的两项最基本指标。用户每打开一个网站页面，记录一个PV，多次打开同一页面PV累计多次。独立访客（UV）是指一天内访问网站的不重复用户数，一天内同一访客多次访问网站只计算一次。

- 统计并展现网站的流量来源地域。

开发流程

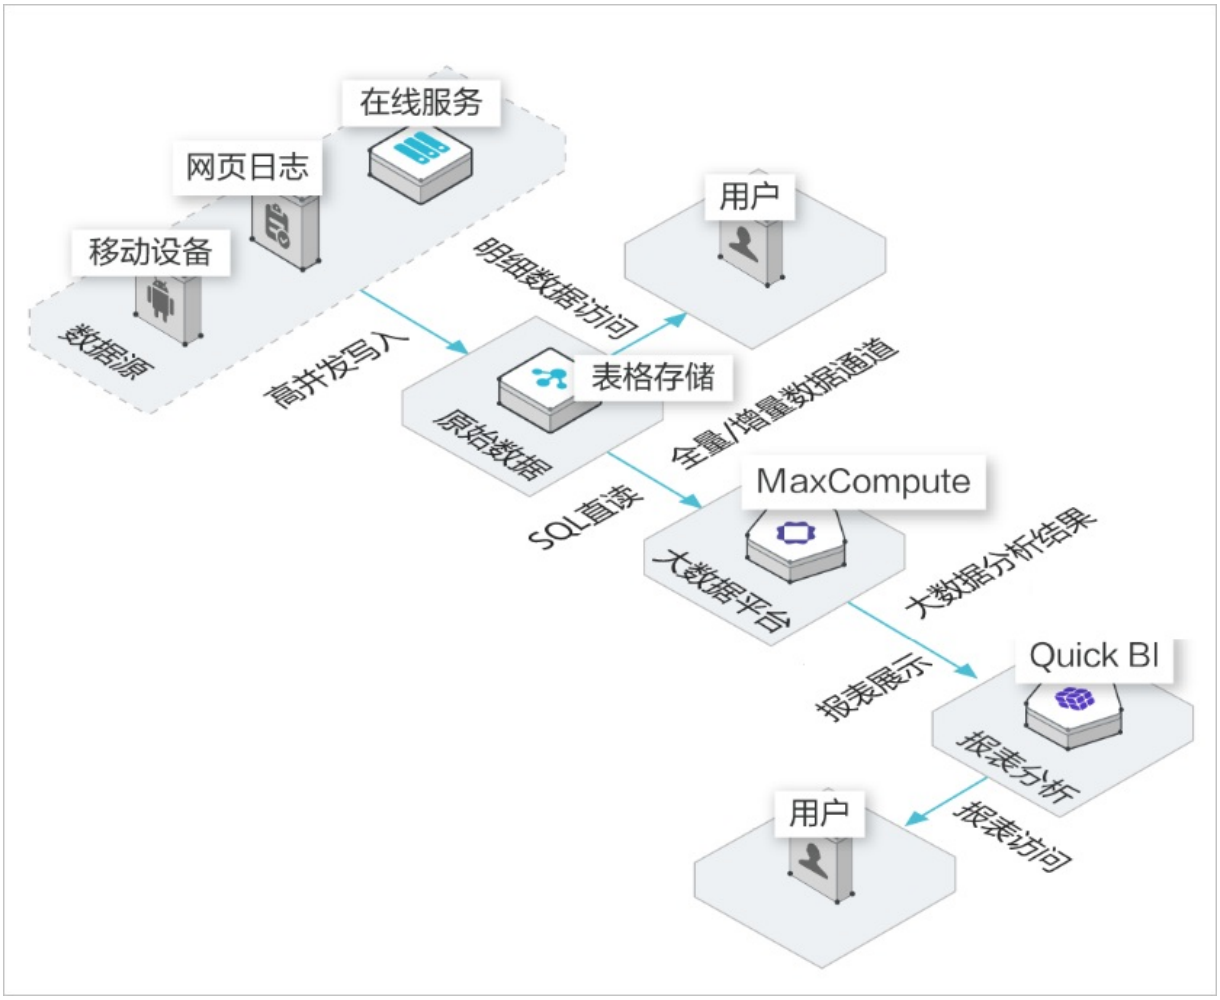

本教程涉及的具体开发流程如下：

- 步骤一：环境准备。
- 步骤二：数据准备。
- 步骤三：新建数据表。
- 步骤四：设计工作流。
- 步骤五：节点配置。
- 步骤六：任务提交与测试。
- 步骤七：数据可视化展现。

3.2. 环境准备

本文为您介绍开始本教程前的环境准备工作，需要开通表格存储（TableStore）、大数据计算服务（MaxCompute）、数据工厂（DataWorks）和智能分析套件（Quick BI）。

前提条件

- 已注册阿里云账号。如果您还没有注册阿里云账号，请进入阿里云官网，单击**免费注册**，即可进入阿里云账号注册页面创建新的阿里云账号。
- 已实名认证。如果您还没有实名认证，请进入实名认证页面对账号进行实名认证。

背景信息

本教程涉及的阿里云产品如下：

- 表格存储TableStore
- 大数据计算服务MaxCompute
- 数据工场DataWorks
- 智能分析套件Quick BI

> **说明** 在本教程中，表格存储服务选择华北2（北京）。

操作步骤

1. 创建表格存储实例。
   i. 进入表格存储TableStore产品详情页，单击**免费开通**。
   ii. 在**云产品开通页**页面，勾选**我已阅读并同意表格存储（按量付费）服务协议**并单击**立即开通**。

   iii. 单击**管理控制台**。

iv. 单击**创建实例**。在**创建实例**页面，选择地区为**华北2（北京）**。填写**实例名称**，**实例规格**请选择**容量型实例**，单击**确定**。

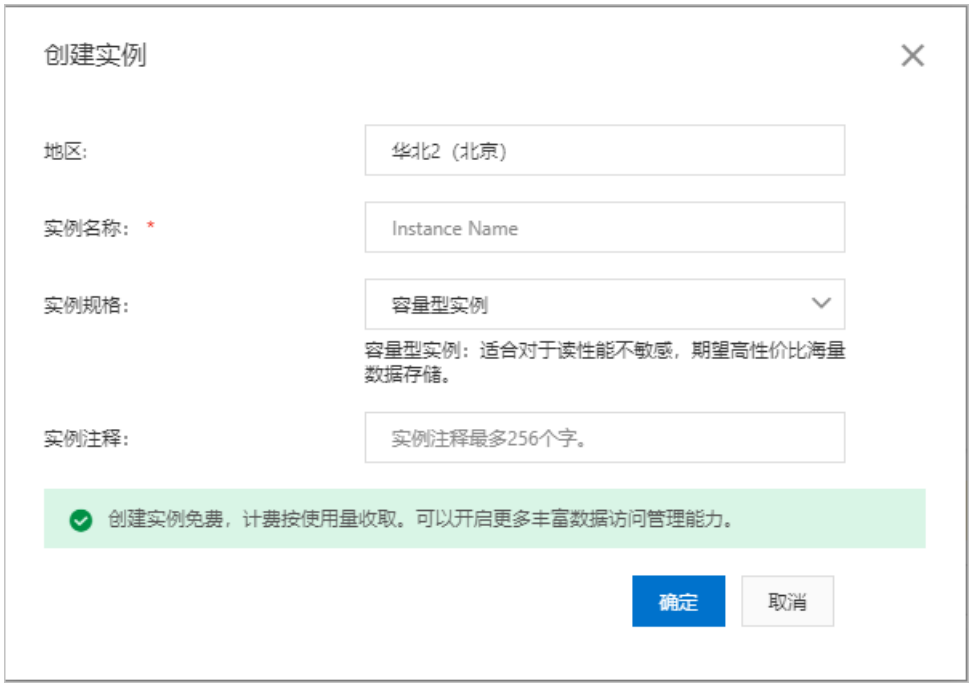

> **说明** 实例名称在表格存储同一个区域内必须全局唯一，建议您选用自己可辨识且符合规则的名称。实例名称在MaxCompute数据处理中也会被使用，本例中为workshop-bj-001，关于实例的详细解释请参见实例。

v. 完成创建后，单击左侧导航栏**全部实例**可以看到您刚刚创建的实例，状态为**运行中**。

2. 开通大数据计算服务MaxCompute。

i. 进入MaxCompute产品详情页，单击**立即购买**。

ii. 选择**按量计费**，选择区域为**华东2（上海）**，**规格类型**为默认的**标准版**，单击**立即购买**。

> **说明** MaxCompute区域与表格存储区域相同可以节省您的流量费用，因此您可以选择区域为**华北2（北京）**。本教程中MaxCompute区域选择为**华东2（上海）**，以便为您展示跨地域的外部表使用过程。

3. 开通DataWorks。

i. 进入DataWorks产品详情页，单击**立即购买**。

ii. 选择区域为**华东2（上海）**，单击**立即购买**。

> **说明** MaxCompute区域与表格存储区域相同可以节省您的流量费用，因此您也可以选择区域为**华北2（北京）**。本教程中MaxCompute区域选择为**华东2（上海）**，以便为您展示跨地域访问数据的使用过程。

4. 创建DataWorks工作空间。

i. 进入DataWorks工作空间列表，选择区域为**华东1（杭州）**，单击**创建工作空间**。

ii. 填写**创建工作空间**对话框中的**基本配置**，单击**下一步**。

为方便使用，本教程中DataWorks工作空间模式为**简单模式（单环境）**。在简单模式下，DataWorks工作空间与MaxCompute项目一一对应，详情请参见简单模式和标准模式的区别。

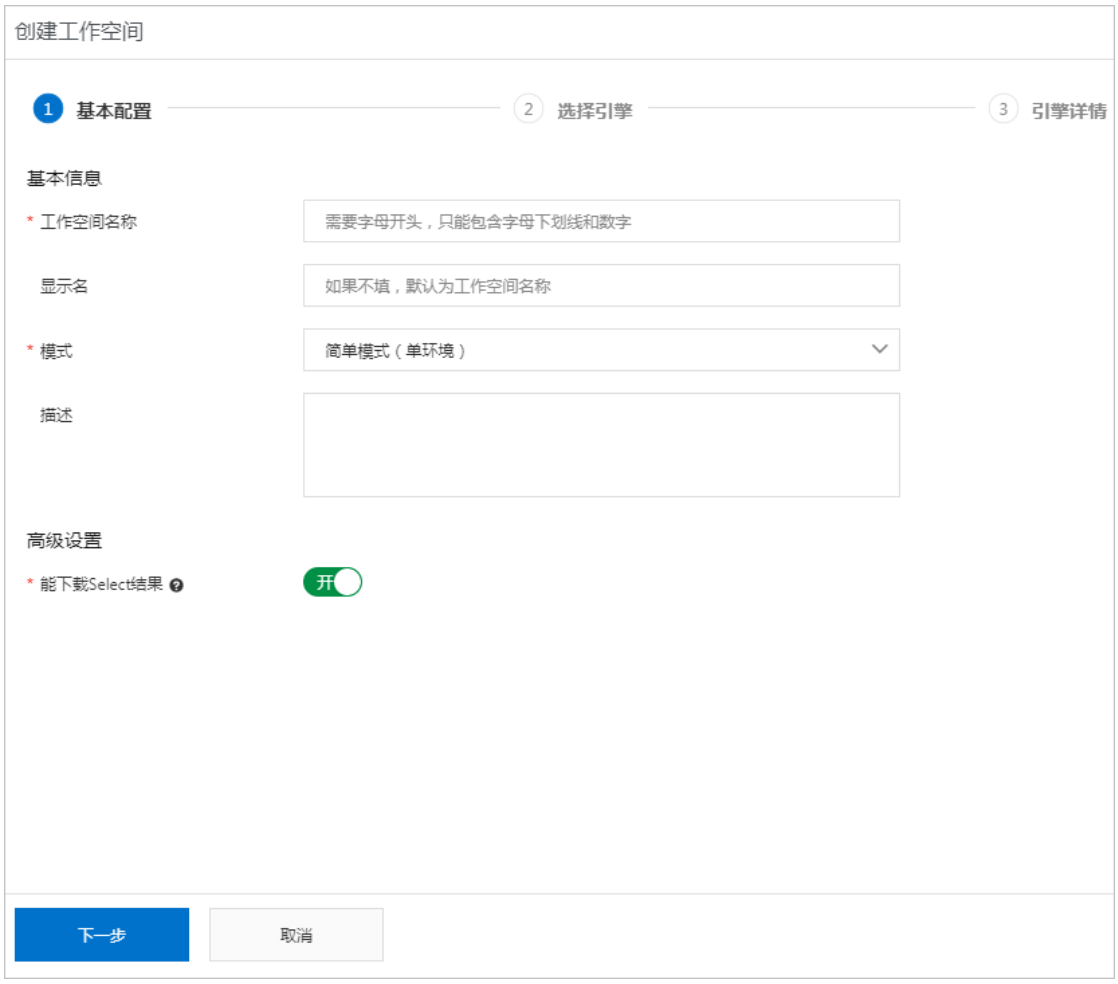

> **说明** 工作空间名称全局唯一，建议您使用易于区分的名称。

iii. 进入**选择引擎**界面，选择相应引擎后，单击**下一步**。

选择**计算引擎服务**为**MaxCompute**、**按量付费**。

iv. 进入**引擎详情**页面，填写选购引擎的配置。

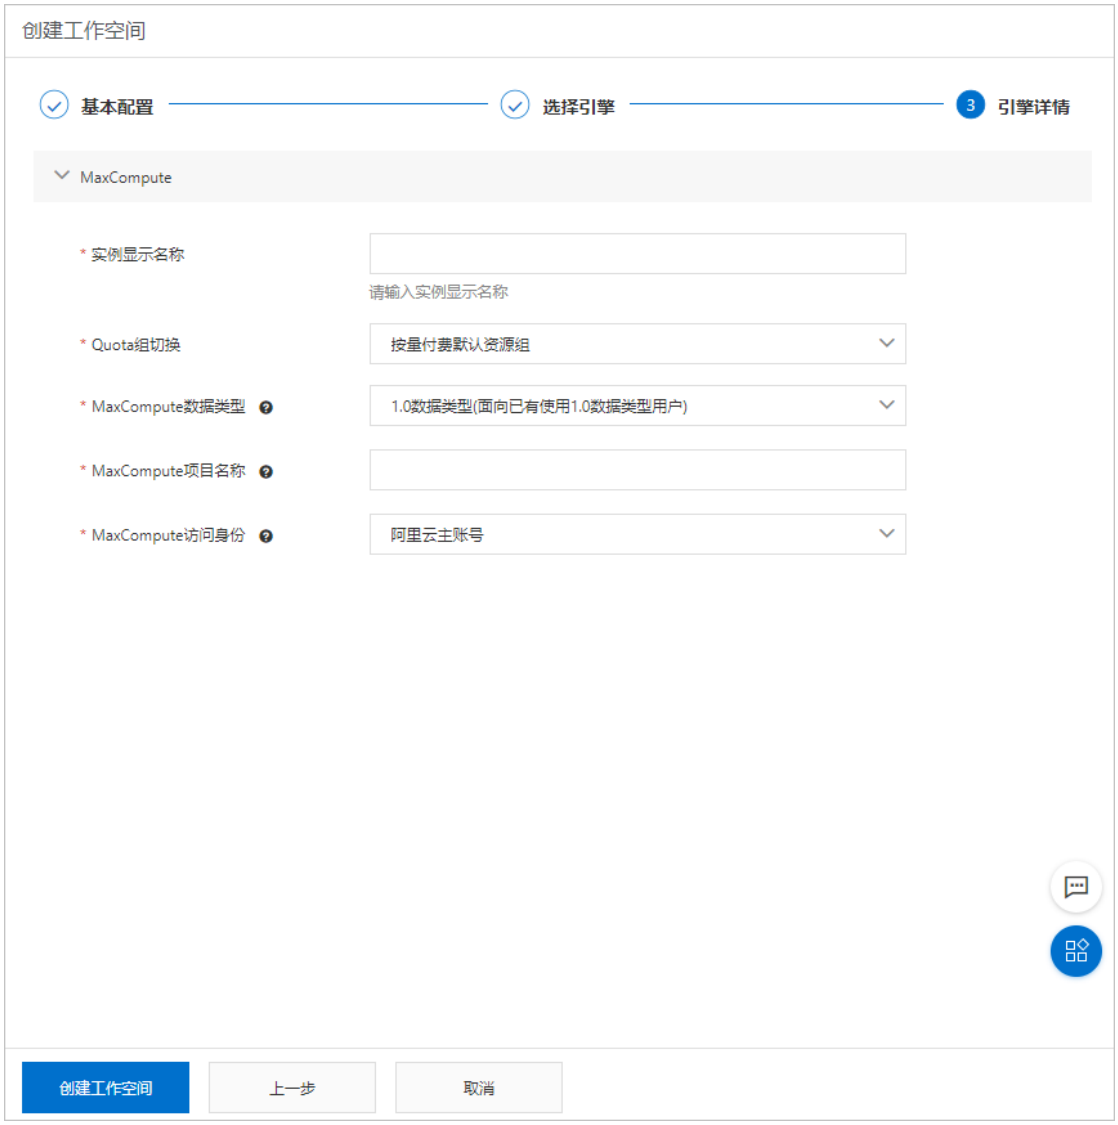

分类	配置	说明
MaxCompute	**实例显示名称**	实例名称不能超过27个字符，仅支持字母开头，仅包含字母、下划线和数字。
	Quota组切换	Quota用来实现计算资源和磁盘配额。
	MaxCompute数据类型	MaxCompute项目的数据类型版本。
	MaxCompute项目名称	默认与DataWorks工作空间的名称一致。
	MaxCompute访问身份	包括**个人账号**和**工作空间所有者**，开发环境默认为**个人账号**，生产环境推荐使用**工作空间所有者**。

v. 配置完成后，单击**创建工作空间**。

工作空间创建成功后，即可在**工作空间列表**页面查看相应内容。

5. 开通Quick BI。

i. 进入Quick BI产品详情页，单击**管理控制台**

ii. 进入控制台后，单击**高级版30天试用申请**或**专业版30天试用申请**。勾选**同意Quick BI服务协议**，单击**免费试用**。

> **说明** 您可以选择使用**个人空间**或**默认空间**，推荐您使用**默认空间**。

3.3. 数据准备

在数据准备阶段，您需要通过数据Demo包生成模拟真实环境的数据，以便后续数据开发使用。

前提条件

- 创建华北2（北京）区域的表格存储实例，同时记录实例名称和实例访问地址。单击表格存储控制台中的实例名称，即可获得实例访问地址。对于跨区域的访问，建议您使用公网地址。详细操作请参见环境准备。
- 使用主账号登录安全信息管理控制台，获取并记录您的AccessKey ID和AccessKey Secret信息。

> **说明** AccessKey ID和AccessKey Secret是您访问阿里云API的密钥，具有该账户完全的权限，请您妥善保管。

操作步骤

1. 下载数据Demo包。

   数据Demo包下载地址如下，本例中使用环境为Windows7 64位：

   - Mac下载地址
   - Linux下载地址
   - Windows7 64位下载地址

2. 配置Demo环境。

   完成下载后，解压下载包，编辑conf文件夹内的app.conf文件。

   

   app.conf文件内容示例如下。

   ```
   endpoint = "https://workshop-bj-001.cn-beijing.ots.aliyuncs.com"
   instanceName = "workshop-bj-001"
   accessKeyId = "LTAIF24u7g******"
   accessKeySecret = "CcwFeF3sWTPy0wsKULMw34Px******"
   usercount = "200"
   daysCount = "7"
   ```

   其中，需要配置的参数如下：

   - endpoint：表格存储实例的访问网络地址，建议您使用公网地址。
   - instanceName：表格存储实例的名称。

- accessKeyId和accessKeySecret：访问阿里云的密钥。

3. 启动Demo准备测试数据。

   i. 启动Windows CMD命令行工具，进入您解压缩Demo包的路径，执行如下语句查看Demo包命令用法。

   ```
   workshop_demo.exe -h
   ```

   该命令会列出该demo的相关命令，如下。

   ```
   workshop_demo.exe -h
   * prepare  准备测试数据，创建数据表，根据conf中的用户数量，为用户生成一周的行为日志数据。
   * raw ${userid} ${date} ${Top条数} 查询指定用户的日志明细。
   * new/day_active/month_active/day_pv/month_pv 在结果表中查询上述几种类型的报表数据（新增：new，日活：day_active，月活：month_active，日PV：day_pv，月PV：month_pv）。
   ```

   ii. 执行如下命令生成准备数据。

   ```
   workshop_demo.exe prepare
   ```

   结果如下。

   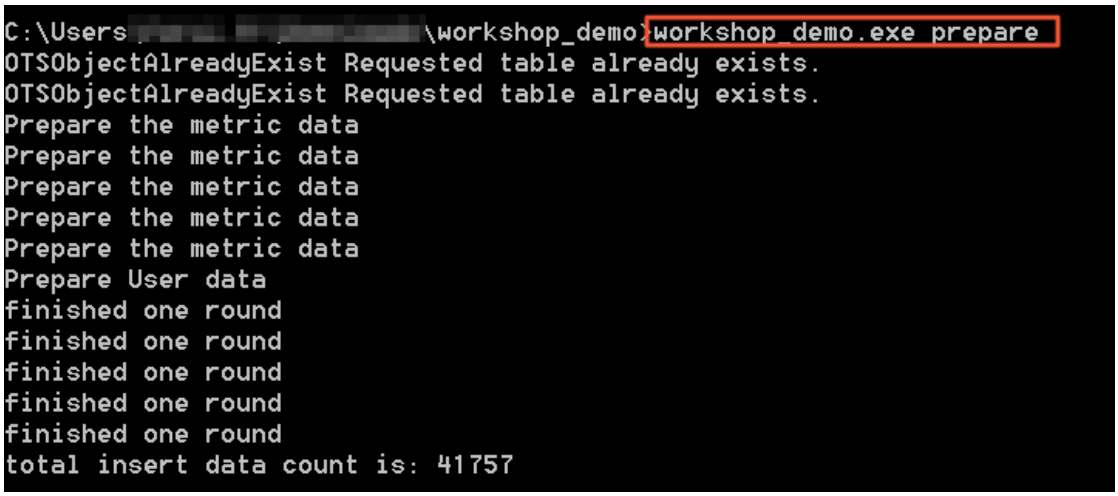

在此过程中，Demo包会自动帮助您在表格存储中创建表，结构如下：

- 原始日志数据表：user_trace_log

列名	类型	说明
md5	STRING	用户uid的md5值undefined前8位，表格存储主键。
uid	STRING	用户uid，表格存储主键。
ts	BIGINT	用户操作时间戳，表格存储主键。
ip	STRING	IP地址。
status	BIGINT	服务器返回状态码。
bytes	BIGINT	返回给客户端的字节数。

列名	类型	说明
device	STRING	终端型号。
system	STRING	系统版本：ios xxx/android xxx。
customize_event	STRING	自定义事件：登录/退出/购买/注册/点击/后台/切换用户/浏览。
use_time	BIGINT	APP单次使用时长，当事件为退出、后台、切换用户时有该项。
customize_event_content	STRING	用户关注的内容信息。

- 分析结果表： analysis_result

列名	类型	说明
metric	STRING	报表的类型：'new'、'day_active'、'month_active'、'day_pv'、'month_pv'，表格存储主键。
ds	STRING	时间yyyy-mm-dd或yyyy-mm，表格存储主键。
num	BIGINT	对应的数据值。

4. 数据验证。
   - 用户明细查询

     通过如下语句查询指定用户在某一日期指定条数的明细数据。表格数据的日期对应于您创建表格的时间。

     ```
     raw ${userid} ${date} ${Top条数}
     ```

     其中，${userid}为用户ID，${date}为指定日期，${Top条数}为指定查询条数。例如，您创建数据时间为2019年6月15日，则可以使用 `workshop_demo.exe raw 00010 "2019-06-15" 20` 查看20条用户明细数据。

```
C [redacted]nloads\workshop_demo>workshop_demo.exe raw 00010 "2019-06-1
5" 20
       uid                          Date    bytes      customize_event
      device                    ip   status          system
     00010         2019-06-14 11:56:47 PM      759               regist
iPhone7 Plus        61.103.79.217      200          ios11
     00010         2019-06-14 11:26:34 PM      252     backstage    369
   iPad min2       157.249.67.241     200          ios11
     00010         2019-06-14 11:21:30 PM      427        browse travel
    iPhone6s      222.133.108.234     200          ios10
     00010         2019-06-14 11:16:03 PM      764        switch    185
iPhone7 Plus        61.103.79.217      200          ios11
     00010         2019-06-14 11:06:03 PM      436               click
iPhone7 Plus        61.103.79.217      200          ios11
     00010         2019-06-14 10:36:54 PM      131               click
iPhone7 Plus        61.103.79.217      200          ios11
     00010         2019-06-14 10:22:26 PM      778        switch     73
    iPhone6s      222.133.108.234     200          ios10
     00010         2019-06-14 10:06:29 PM      535     backstage    179
   iPad min2       157.249.67.241     200          ios11
     00010         2019-06-14 09:56:11 PM      668               click
   iPad min2       157.249.67.241     200          ios11
     00010         2019-06-14 09:20:45 PM      354               regist
    iPhone6s      222.133.108.234     200          ios10
     00010         2019-06-14 09:15:37 PM      989               click
   iPad min2       157.249.67.241     200          ios11
     00010         2019-06-14 08:51:17 PM      460        logout    462
    iPhone6s      222.133.108.234     200          ios10
     00010         2019-06-14 08:26:06 PM      887       comment  funny
   iPad min2       157.249.67.241     200          ios11
     00010         2019-06-14 08:10:34 PM      278       browse finance
    iPhone6s      222.133.108.234     200          ios10
     00010         2019-06-14 07:56:00 PM      480               click
iPhone7 Plus        61.103.79.217      200          ios11
     00010         2019-06-14 07:30:11 PM       68               click
    iPhone6s      222.133.108.234     200          ios10
     00010         2019-06-14 07:15:09 PM      398        browse   news
iPhone7 Plus        61.103.79.217      200          ios11
     00010         2019-06-14 07:11:21 PM       21               click
    iPhone6s      222.133.108.234     200          ios10
     00010         2019-06-14 06:35:07 PM      207        browse  photo
iPhone7 Plus        61.103.79.217      200          ios11
     00010         2019-06-14 06:24:43 PM      261               regist
iPhone7 Plus        61.103.79.217      200          ios11
```

说明 由于表格存储是SchemaFree结构，表的属性列不需要预先定义。Customize_Event中不同的事件对应了不同的内容，因此Demo中将事件、内容进行对齐显示。

- 报表结果查询

您可以使用 `workshop_demo.exe day_active` 命令查看日活数据。

```
C:\[redacted]workshop_demo>workshop_demo.exe day_active
          metric                   ds                  num
      day_active           2019-05-19              1416104
      day_active           2019-05-20              1416540
      day_active           2019-05-21              1422314
      day_active           2019-05-22              1422411
      day_active           2019-05-23              1428480
      day_active           2019-05-24              1431989
      day_active           2019-05-25              1436218
      day_active           2019-05-26              1437886
      day_active           2019-05-27              1440633
      day_active           2019-05-28              1444736
      day_active           2019-05-29              1450520
      day_active           2019-05-30              1451543
      day_active           2019-05-31              1457510
      day_active           2019-06-01              1458998
      day_active           2019-06-02              1466801
      day_active           2019-06-03              1468898
      day_active           2019-06-04              1473173
      day_active           2019-06-05              1479770
      day_active           2019-06-06              1483101
      day_active           2019-06-07              1484922
      day_active           2019-06-08              1485347
      day_active           2019-06-09              1492034
      day_active           2019-06-10              1499914
      day_active           2019-06-11              1495458
      day_active           2019-06-12              1500697
      day_active           2019-06-13              1508061
      day_active           2019-06-14              1509108
      day_active           2019-06-15              1510583
      day_active           2019-06-16              1518355
      day_active           2019-06-17              1520938
```

3.4. 数据建模与开发

3.4.1. 新建数据表

本文为您介绍如何在MaxCompute上建立数据表，用于承载原始数据及加工后的数据。

前提条件

- 已开通MaxCompute服务并创建DataWorks工作空间（本教程使用为简单模式工作空间），详情请参见环境准备。
- 已具备访问Tablestore数据的权限。当MaxCompute和Tablestore的所有者是同一个账号时，您可以单击此处一键授权。如果不是，您可以自定义授权，详情请参见OTS外部表。

操作步骤

1. 进入DataWorks数据开发界面。
   i. 进入DataWorks工作空间列表，选择区域为**华东2（上海）**。
   ii. 单击已创建好的工作空间后的**进入数据开发**，进入工作空间的数据开发界面。
2. 新建业务流程。

i. 右键单击**业务流程**，选择**新建业务流程**。

ii. 填写**业务名称**和**描述**，单击**新建**。本教程中，业务流程名为Workshop。

3. 新建数据表。

i. 创建外部表ots_user_trace_log。

a. 单击新建的业务流程Workshop，右键单击**MaxCompute**，选择**新建 > 表**，输入表名ots_user_trace_log，单击**提交**。

b. 填写创建表的**中文名**，然后单击**DDL模式**。

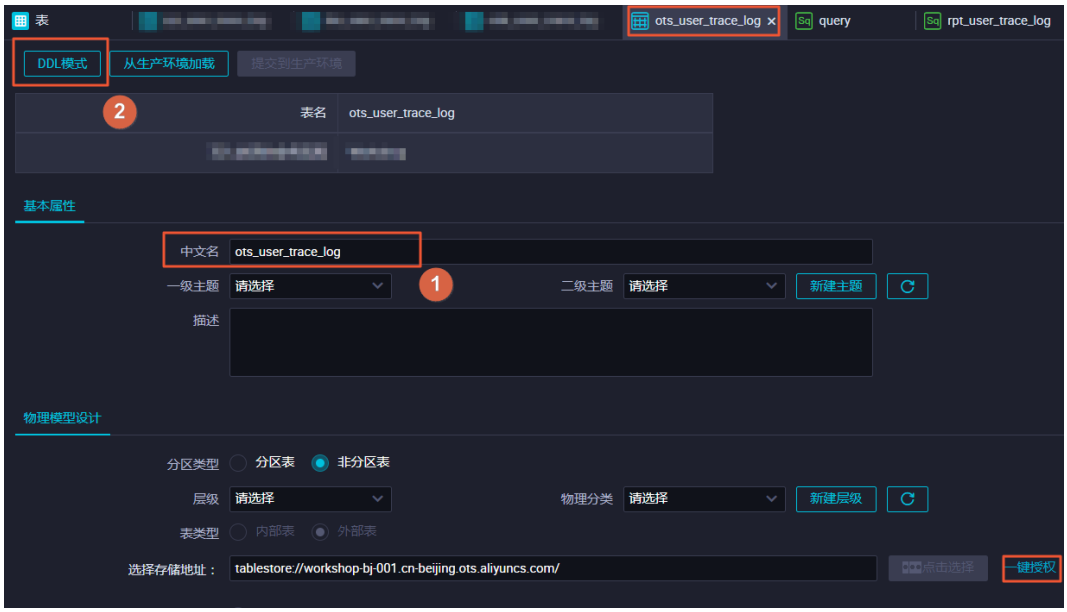

c. 在**DDL模式**页面，输入建表语句，单击**生成表结构**。

外部表ots_user_trace_log的建表语句如下。

```
CREATE EXTERNAL TABLE ots_user_trace_log (
    md5 string COMMENT '用户uid的md5值前8位',
    uid string COMMENT '用户uid',
    ts bigint COMMENT '用户操作时间戳',
    ip string COMMENT 'ip地址',
    status bigint COMMENT '服务器返回状态码',
    bytes bigint COMMENT '返回给客户端的字节数',
    device string COMMENT '终端型号',
    system string COMMENT '系统版本ios xxx/android xxx',
    customize_event string COMMENT '自定义事件：登录/退出/购买/注册/点击/后台/切换用户/浏览/评论',
    use_time bigint COMMENT 'APP单次使用时长，当事件为退出、后台、切换用户时有该项',
    customize_event_content string COMMENT '用户关注内容信息，在customize_event为浏览和评论时，包含该列'
)
STORED BY 'com.aliyun.odps.TableStoreStorageHandler'
WITH SERDEPROPERTIES (
    'tablestore.columns.mapping'=':md5,:uid,:ts, ip,status,bytes,device,system,customize_event,use_time,customize_event_content',
    'tablestore.table.name'='user_trace_log'
)
LOCATION 'tablestore://workshop-bj-001.cn-beijing.ots.aliyuncs.com/';
```

- STORED BY：必选参数，值为 `com.aliyun.odps.TableStoreStorageHandler` ，是MaxCompute内置处理Tablestore数据的StorageHandler，定义了MaxCompute和Tablestore的交互。

- SERDEPROPERITES：必选参数，是提供参数选项的接口，在使用TableStoreStorageHandler时，以下选项必须指定：
  - tablestore.columns.mapping：用于描述MaxCompute将访问的Tablestore表的列，包括主键和属性列。

    > **说明**
    > - 以冒号（：）开头的参数值为Tablestore主键，例如示例中的`:md5`和`:uid`，其它参数值均为属性列。
    > - 在指定映射时，您必须提供指定Tablestore表的所有主键，只需提供需要通过MaxCompute访问的属性列。提供的属性列必须是Tablestore表的列，否则即使外表可以创建成功，查询时也会报错。

  - tablestore.table.name：需要访问的Tablestore表名。如果指定的Tablestore表名错误（不存在），则会报错，MaxCompute不会主动创建Tablestore表。
- LOCATION：用来指定Tablestore的访问地址。请您根据环境准备，将自己的表格存储实例访问地址参数填写在此。

  > **说明** 如果您使用公网地址LOCATION 'tablestore://workshop-bj-001.cn-beijing.ots.aliyuncs.com/'报错，显示网络不同，可尝试更换为经典网地址LOCATION 'tablestore://workshop-bj-001.cn-beijing.ots-internal.aliyuncs.com/'。

d. 单击**提交到生产环境**，完成表的创建。

> **说明** 如果您使用的是标准模式工作空间，请先单击**提交到开发环境**，然后单击**提交到生产环境**。

ii. 创建ods_user_trace_log表。

建表方法同上，建表语句如下。ods_user_trace_log为ODS层表。

```
CREATE TABLE IF NOT EXISTS ods_user_trace_log (
    md5 STRING COMMENT '用户uid的md5值前8位',
    uid STRING COMMENT '用户uid',
    ts BIGINT COMMENT '用户操作时间戳',
    ip STRING COMMENT 'ip地址',
    status BIGINT COMMENT '服务器返回状态码',
    bytes BIGINT COMMENT '返回给客户端的字节数',
    device STRING COMMENT '终端型号',
    system STRING COMMENT '系统版本ios xxx/android xxx',
    customize_event STRING COMMENT '自定义事件：登录/退出/购买/注册/点击/后台/切换用户/浏览/评论',
    use_time BIGINT COMMENT 'APP单次使用时长，当事件为退出、后台、切换用户时有该项',
    customize_event_content STRING COMMENT '用户关注内容信息，在customize_event为浏览和评论时，包含该列'
)
PARTITIONED BY (
    dt STRING
);
```

iii. 创建dw_user_trace_log表。

建表方法同上，建表语句如下。dw_user_trace_log为DW层表。

```
CREATE TABLE IF NOT EXISTS dw_user_trace_log (
    uid STRING COMMENT '用户uid',
    region STRING COMMENT '地域，根据ip得到',
    device_brand string comment '设备品牌',
    device STRING COMMENT '终端型号',
    system_type STRING COMMENT '系统类型，Android、IOS、ipad、Windows_phone',
    customize_event STRING COMMENT '自定义事件：登录/退出/购买/注册/点击/后台/切换用户/浏览/评论',
    use_time BIGINT COMMENT 'APP单次使用时长，当事件为退出、后台、切换用户时有该项',
    customize_event_content STRING COMMENT '用户关注内容信息，在customize_event为浏览和评论时，包含该列'
)
PARTITIONED BY (
    dt STRING
);
```

iv. 创建rpt_user_trace_log表。

建表方法同上，建表语句如下。rpt_user_trace_log为ADS层表。

```
CREATE TABLE IF NOT EXISTS rpt_user_trace_log (
    country STRING COMMENT '国家',
    province STRING COMMENT '省份',
    city STRING COMMENT '城市',
    device_brand string comment '设备品牌',
    device STRING COMMENT '终端型号',
    system_type STRING COMMENT '系统类型，Android、IOS、ipad、Windows_phone',
    customize_event STRING COMMENT '自定义事件：登录/退出/购买/注册/点击/后台/切换用户/浏览/评论',
    use_time BIGINT COMMENT 'APP单次使用时长，当事件为退出、后台、切换用户时有该项',
    customize_event_content STRING COMMENT '用户关注内容信息，在customize_event为浏览和评论时，包含该列',
    pv bigint comment '浏览量',
    uv bigint comment '独立访客'
)
PARTITIONED BY (
    dt STRING
);
```

4. 验证建表结果。

i. 完成建表后，您可以在Workshop业务流程**MaxCompute > 表**下看到新建的4张表。

ii. 右键单击业务流程中**MaxCompute**下的**数据开发**，选择**新建 > ODPS SQL**。

iii. 在**新建节点**页面，输入**节点名称**，单击**提交**新建ODPS SQL节点。

iv. 在新建的ODPS SQL节点中输入如下SQL语句，单击图标。

```
DESCRIBE ots_user_trace_log;
DESCRIBE ods_user_trace_log;
DESCRIBE dw_user_trace_log;
DESCRIBE rpt_user_trace_log;
```

返回表的结构信息如下：

```
+------------------------------------------------------------------------------------+
| Owner: [redacted] | Project: [redacted]                                            |
| TableComment:                                                                      |
+------------------------------------------------------------------------------------+
| CreateTime:              2020-06-16 18:56:46                                       |
| LastDDLTime:             2020-06-16 18:56:46                                       |
| LastModifiedTime:        2020-06-16 18:56:46                                       |
+------------------------------------------------------------------------------------+
| InternalTable: YES      | Size: 0                                                  |
+------------------------------------------------------------------------------------+
| Native Columns:                                                                    |
+------------------------------------------------------------------------------------+
| Field           | Type       | Label | Comment                                     |
+------------------------------------------------------------------------------------+
| country         | string     |       | 国家                                        |
| province        | string     |       | 省份                                        |
| city            | string     |       | 城市                                        |
| device_brand    | string     |       | 设备品牌                                    |
| device          | string     |       | 终端型号                                    |
| system_type     | string     |       | 系统类型，Android、IOS、ipad、Windows_phone |
| customize_event | string     |       | 自定义事件：登录/退出/购买/注册/点击/后台/切换用户/浏览 |
| use_time        | bigint     |       | APP单次使用时长，当事件为退出、后台、切换用户时有该项 |
| customize_event_content | string |       | 用户关注内容信息，在customize_event为浏览和评论时 包含该列 |
| pv              | bigint     |       | 浏览量                                      |
| uv              | bigint     |       | 独立访客                                    |
+------------------------------------------------------------------------------------+
| Partition Columns:                                                                 |
+------------------------------------------------------------------------------------+
| dt              | string     |                                                     |
+------------------------------------------------------------------------------------+
OK
2020-06-16 19:56:10 INFO ================================================================
2020-06-16 19:56:10 INFO Exit code of the Shell command 0
2020-06-16 19:56:10 INFO --- Invocation of Shell command completed ---
```

3.4.2. 设计工作流

通过设计工作流，您可以明确在整体数据开发过程中各任务节点的排布。对于本教程中这种较为简单的单数据流场景，您可以选择每个数据表（数仓层次）对应一个工作流。

操作步骤

1. 双击您的业务流程，打开画布面板。
2. 向画布中拖入1个虚拟节点，命名为start。

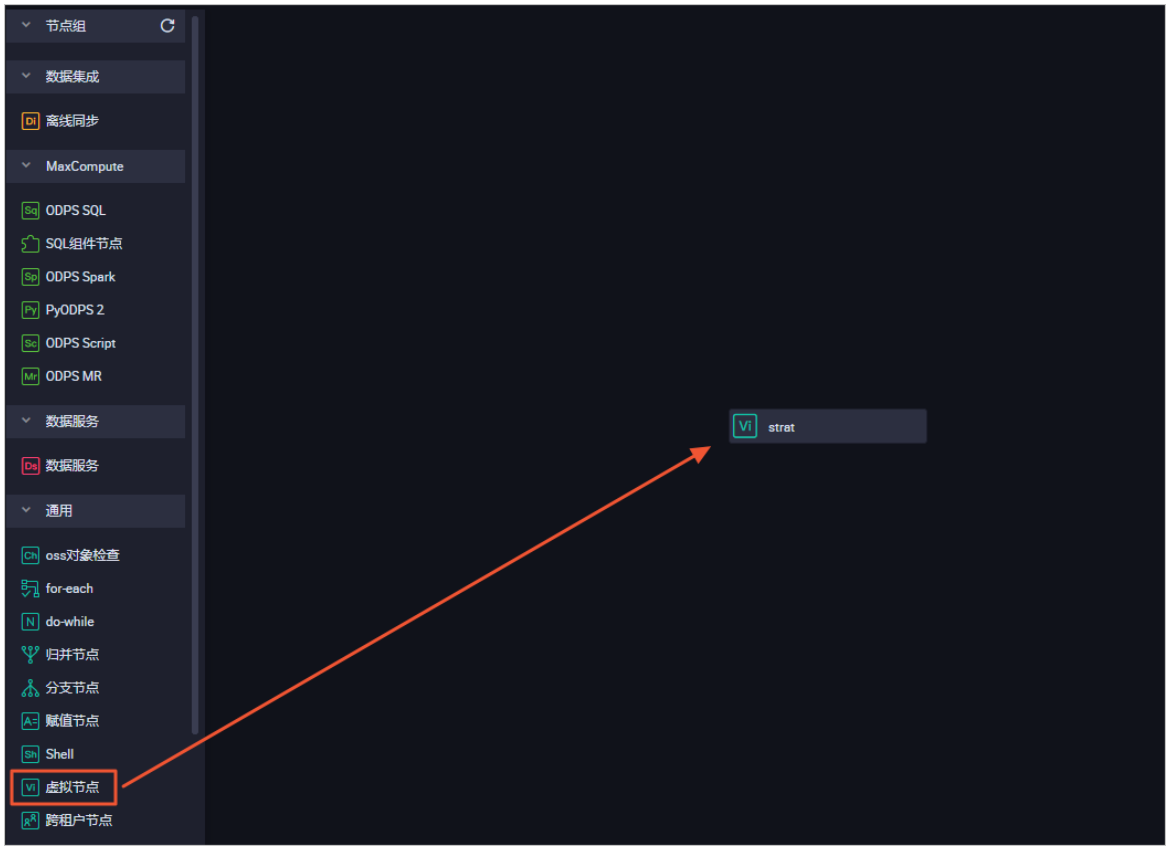

3. 向画布中拖入3个ODPS SQL节点，依次命名为ods_user_trace_log、dw_user_trace_log、rpt_user_trace_log。通过连接不同节点，配置依赖关系如下。

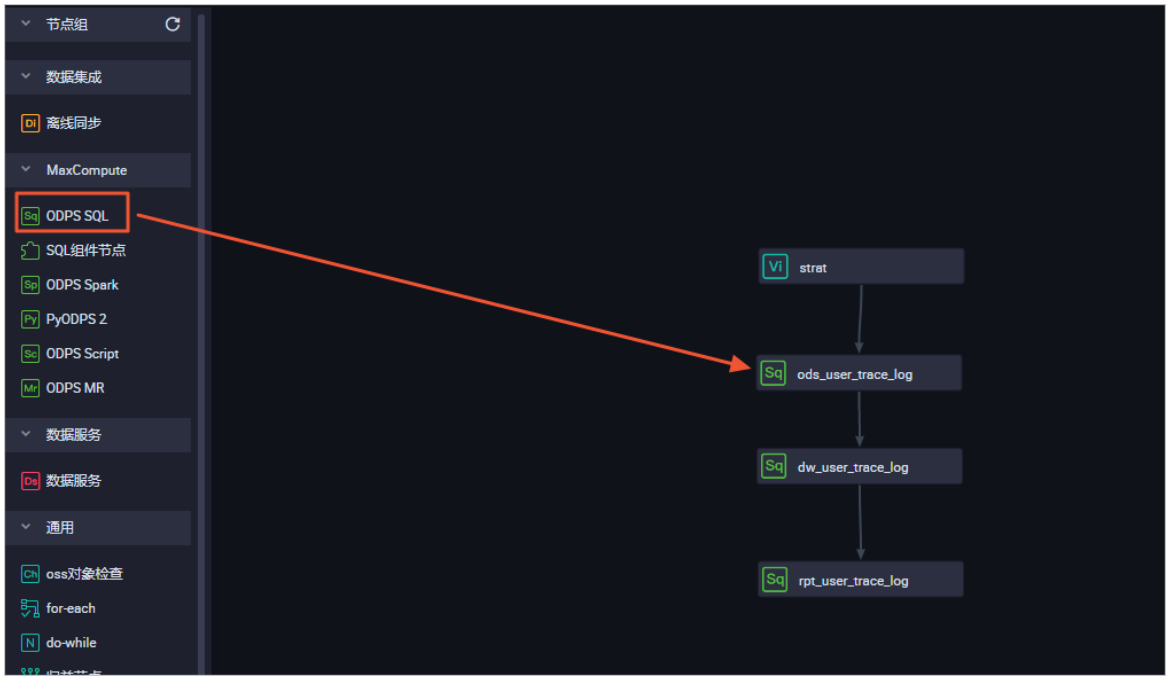

> **说明** ods_user_trace_log、dw_user_trace_log、rpt_user_trace_log分别代表数据仓库的ODS、CDM和ADS层，详情请参见数仓分层。

3.4.3. 节点配置

完成工作流设计后，您需要对每个数据开发节点进行配置，填写SQL语句。

前提条件

本次数据开发过程中需要使用UDF自定义函数，您首先需要完成自定义函数的注册，详细请参见注册自定义函数。

注册自定义函数

1. 添加资源
   i. 下载用于IP地转换的自定义函数Java包getaddr.jar以及地址库ip.dat。

      关于IP地址转换的自定义函数，详情请参见MaxCompute中实现IP地址归属地转换。

   ii. 右键单击WorkShop业务流程下的**MaxCompute**，选择**新建 > 资源**。需要分别新建**File**和**JAR**类型的资源。

- File类型上传地址库ip.dat。
  a. 输入**资源名称**，选中**大文件（内容超过500KB）**及**上传为ODPS资源**，然后单击**点击上传**。

  b. 单击**提交**。

- JAR类型对应Java包getaddr.jar。
  a. 您需要勾选**上传为ODPS资源**，然后单击**点击上传**。

  b. 上传完成后，单击**提交**。

> **说明** 提交时，请忽略血缘不一致信息。

2. 注册函数
   i. 在业务流程下右键单击**MaxCompute**，选择**新建 > 函数**，将函数命名为getregion。
   ii. 在**注册函数**页面，依次填写类名为odps.test.GetAddr，资源列表为getaddr.jar,ip.dat，命令格式为getregion(ip string)，保存后单击 提交函数注册。

配置节点

1. 配置虚拟节点start。
    i. 双击start节点，进入节点配置页面。

ii. 单击右侧的**调度配置**，在**调度依赖**区域下单击**使用工作空间根节点**完成配置。

iii. 在时间属性区域选择**重跑属性**为**运行成功或失败后皆可重跑**。

iv. 单击 按钮，完成节点提交。

2. 配置ODPS SQL节点ods_user_trace_log

i. 双击ods_user_trace_log节点，进入节点配置界面，编写处理逻辑。SQL代码如下。

```
insert overwrite table ods_user_trace_log partition (dt=${bdp.system.bizdate})
select
    md5,
    uid ,
    ts,
    ip,
    status,
    bytes,
    device,
    system,
    customize_event,
    use_time,
    customize_event_content
    from ots_user_trace_log
    where to_char(FROM_UNIXTIME(ts),'yyyymmdd')=${bdp.system.bizdate};
```

> **说明** 关于${bdp.system.bizdate}释义请参见配置调度参数。

ii. 完成代码编写后，单击右侧的**调度配置**，选择**自动解析**为否。

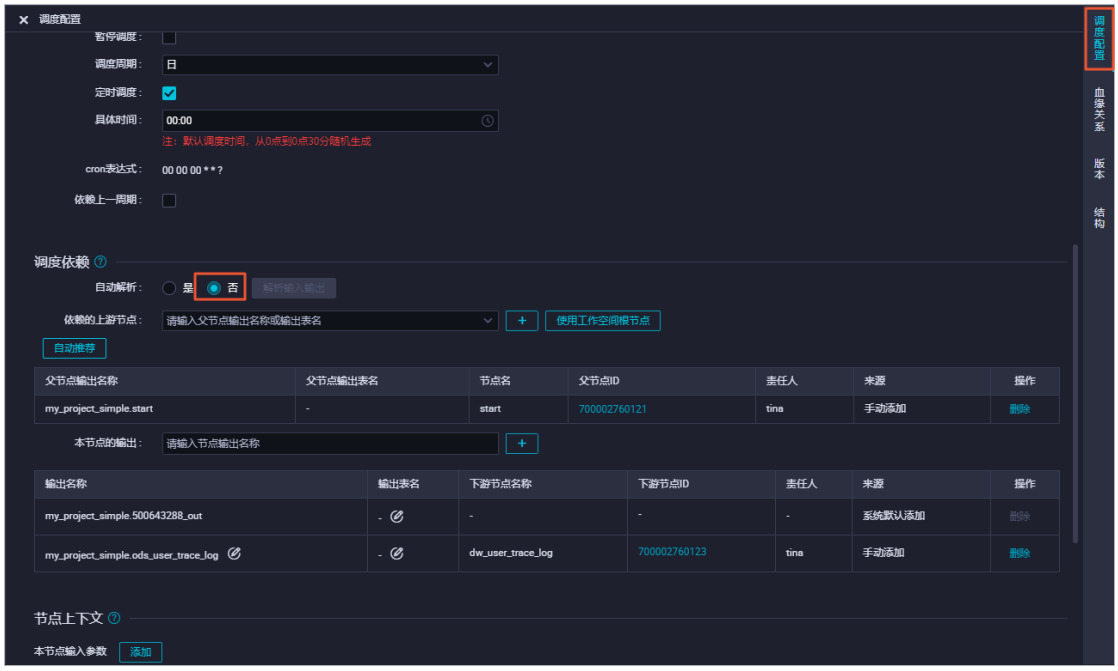

iii. 手动删除错误的依赖关系。

iv. 按照业务流程顺序搜索正确的上游节点，例如此处为start，并单击**添加**。

v. 在时间属性区域选择**重跑属性**为**运行成功或失败后皆可重跑**。

vi. 完成后，单击**提交**。

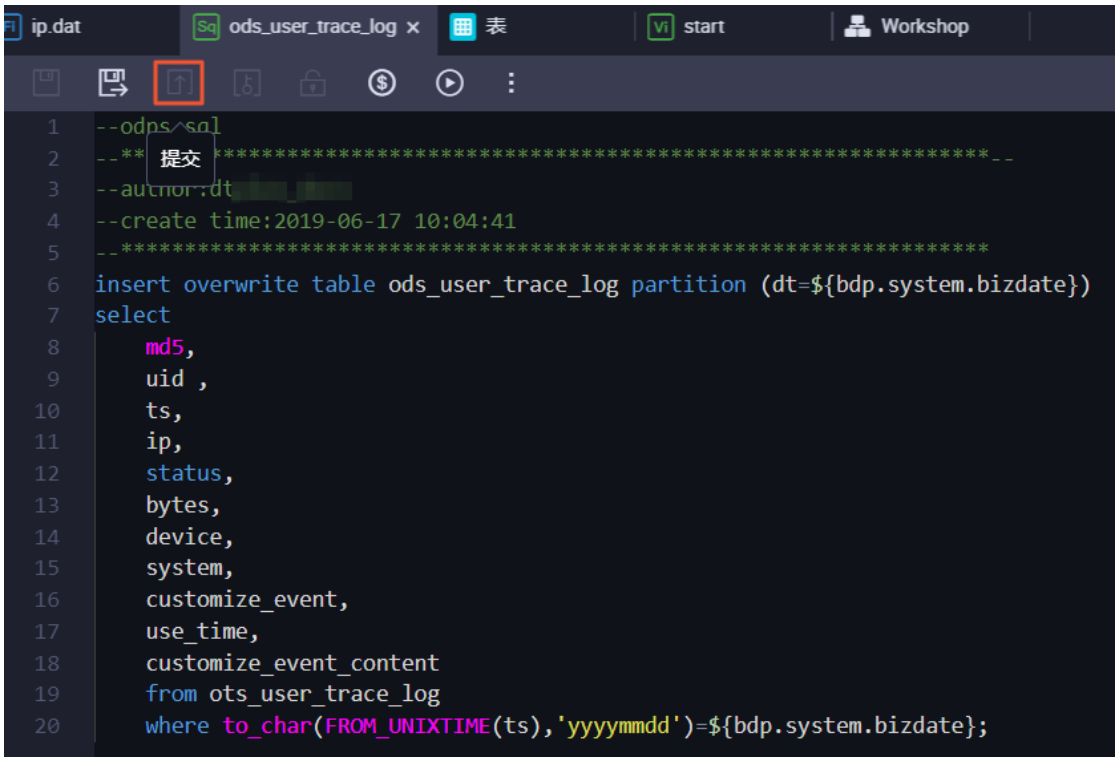

3. 配置ODPS SQL节点dw_user_trace_log

   您可以使用与ods_user_trace_log节点一样的方法配置dw_user_trace_log节点，SQL代码如下。

```
INSERT OVERWRITE TABLE dw_user_trace_log PARTITION (dt=${bdp.system.bizdate})
SELECT uid, getregion(ip) AS region
    , CASE
        WHEN TOLOWER(device) RLIKE 'xiaomi' THEN 'xiaomi'
        WHEN TOLOWER(device) RLIKE 'meizu' THEN 'meizu'
        WHEN TOLOWER(device) RLIKE 'huawei' THEN 'huawei'
        WHEN TOLOWER(device) RLIKE 'iphone' THEN 'iphone'
        WHEN TOLOWER(device) RLIKE 'vivo' THEN 'vivo'
        WHEN TOLOWER(device) RLIKE 'honor' THEN 'honor'
        WHEN TOLOWER(device) RLIKE 'samsung' THEN 'samsung'
        WHEN TOLOWER(device) RLIKE 'leeco' THEN 'leeco'
        WHEN TOLOWER(device) RLIKE 'ipad' THEN 'ipad'
        ELSE 'unknown'
    END AS device_brand, device
    , CASE
        WHEN TOLOWER(system) RLIKE 'android' THEN 'android'
        WHEN TOLOWER(system) RLIKE 'ios' THEN 'ios'
        ELSE 'unknown'
    END AS system_type, customize_event, use_time, customize_event_content
FROM ods_user_trace_log
WHERE dt = ${bdp.system.bizdate};
```

4. 配置ODPS SQL节点rpt_user_trace_log

   您可以使用与ods_user_trace_log节点一样的方法配置rpt_user_trace_log节点，SQL代码如下。

```
INSERT OVERWRITE TABLE rpt_user_trace_log PARTITION (dt=${bdp.system.bizdate})
SELECT split_part(split_part(region, ',', 1),'[',2) AS country
    , trim(split_part(region, ',', 2)) AS province
    , trim(split_part(region, ',', 3)) AS city
    , MAX(device_brand), MAX(device)
    , MAX(system_type), MAX(customize_event)
    , FLOOR(AVG(use_time / 60))
    , MAX(customize_event_content), COUNT(uid) AS pv
    , COUNT(DISTINCT uid) AS uv
FROM dw_user_trace_log
WHERE dt = ${bdp.system.bizdate}
GROUP BY uid,
    region;
```

5. 验证配置结果。

   双击业务流Workshop，打开画布面板。单击  按钮。运行成功如下图所示。

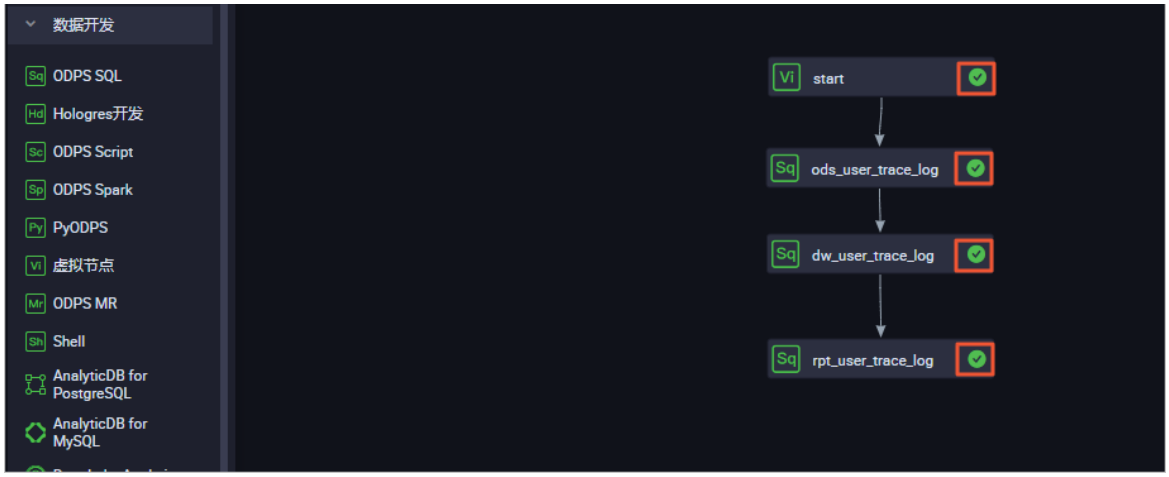

   如果运行状态异常，请右键单击出错节点，单击**查看运行日志**进行排查。

3.4.4. 任务提交与测试

您完成节点配置后，需要将任务提交到运维中心进行测试。

操作步骤

1. （可选）提交业务流程。如果您的节点在配置完成后已经提交完毕且无更新，请跳过本步骤。
   i. 双击业务流程名称Workshop，单击图标。
   ii. 勾选所有可提交节点及**忽略输入输出不一致的告警**，单击**提交**。

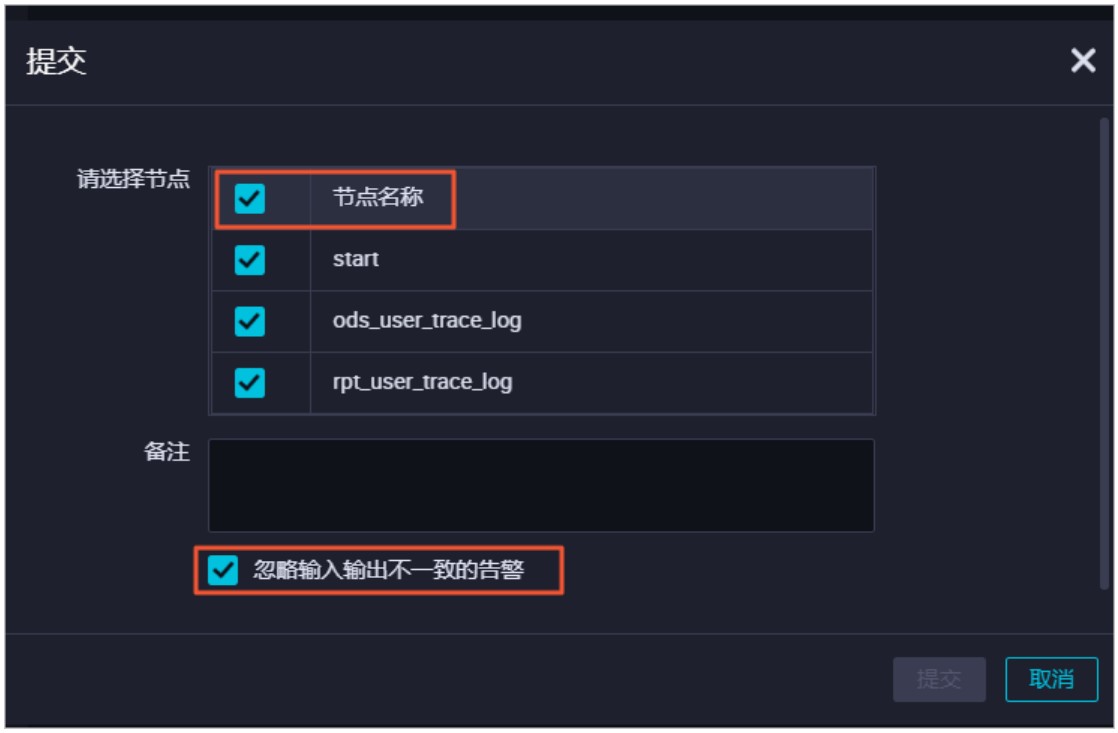

> **说明** 标准空间模式下，提交通过后，需要单击**发布**将任务发布至生产环境。

2. 单击右上角的**运维中心**。

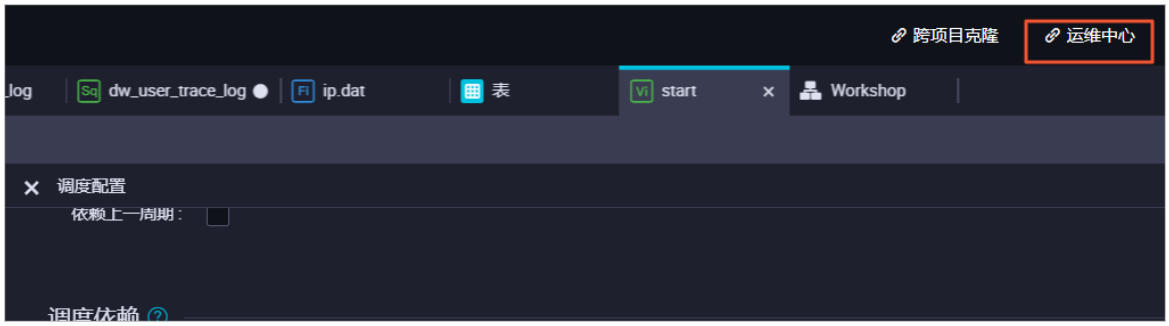

3. 在左侧导航栏，单击**周期任务运维 > 周期任务**，双击节点列表中的虚拟节点start。
4. 在右侧流程图上，右键单击虚拟节点start，选择**补数据 > 当前节点及下游节点**。

5. 在**补数据**页面，选中所有需要补数据的节点，选择业务日期为过去一周，单击**确定**。

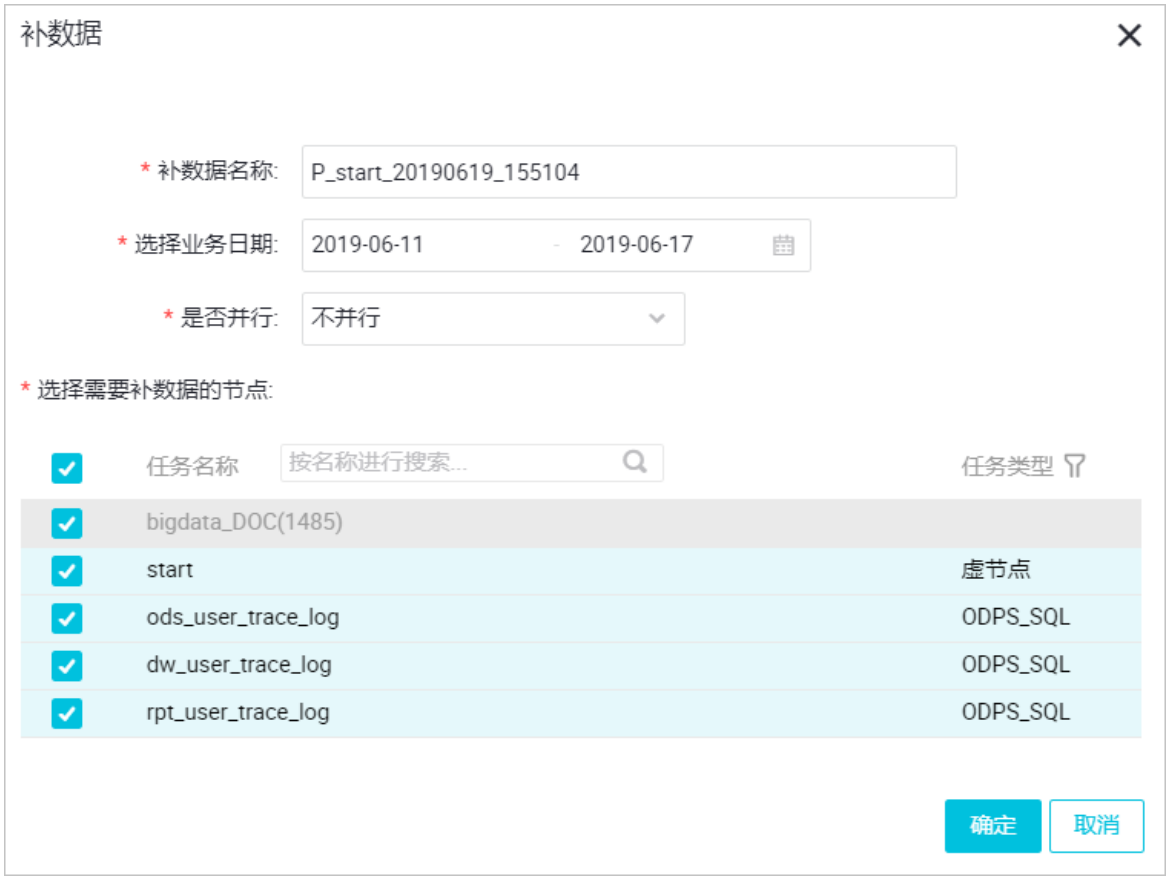

> 说明　关于补数据实例的详情请参见执行补数据并管理补数据实例。

6. 在左侧导航栏，单击**补数据实例**，查看补数据实例的运行情况，并通过单击**刷新**查看实时状态。

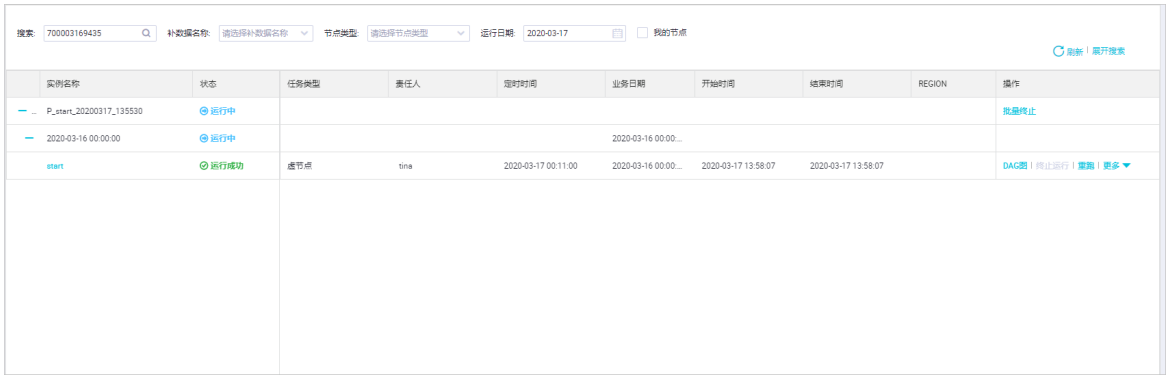

如果运行状态异常，右键单击出错节点，选择**查看运行日志**进行排查。

7. 补数据实例运行完成后，验证结果。
   i. 在左侧导航栏，单击业务流程**Workshop > MaxCompute**，右键单击**数据开发**，选择**新建 > ODPS SQL**，新建名为query的SQL节点。

ii. 输入如下SQL语句，查询2019年6月11日到2019年6月17日之间表rpt_user_trace_log中的数据，确认数据是否成功写入rpt_user_trace_log表。

```
select * from rpt_user_trace_log where dt BETWEEN '20190611' and '20190617' limit 1000;
```

iii. 单击图标。

查询结果如下。

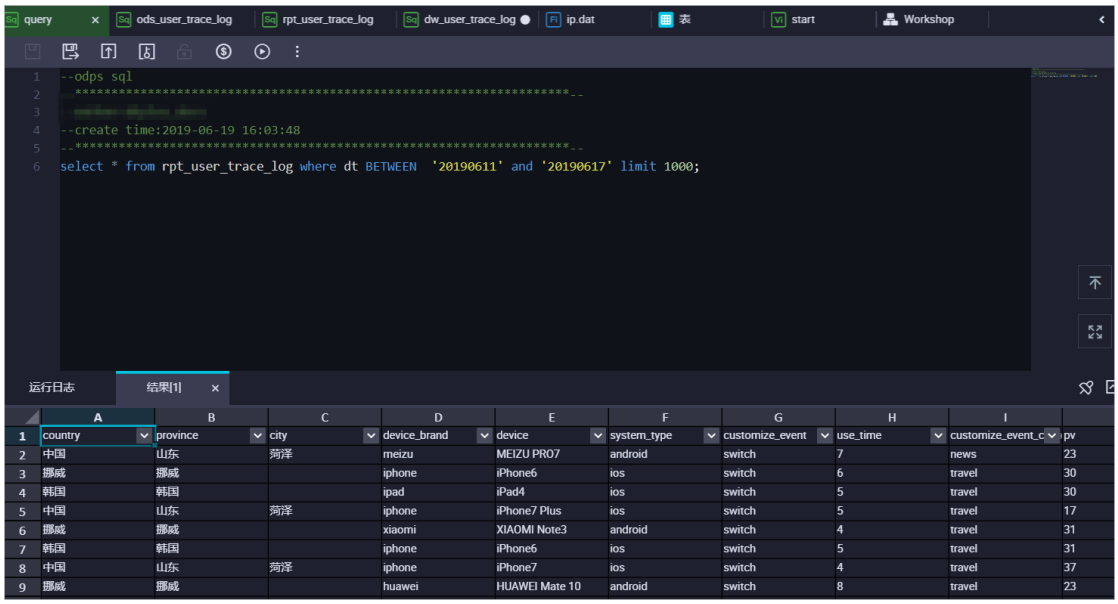

	A	B	C	D	E	F	G	H	I	
1	country	province	city	device_brand	device	system_type	customize_event	use_time	customize_event_c	pv
2	中国	山东	菏泽	meizu	MEIZU PRO7	android	switch	7	news	23
3	挪威	挪威		iphone	iPhone6	ios	switch	6	travel	30
4	韩国	韩国		ipad	iPad4	ios	switch	5	travel	30
5	中国	山东	菏泽	iphone	iPhone7 Plus	ios	switch	5	travel	17
6	挪威	挪威		xiaomi	XIAOMI Note3	android	switch	4	travel	31
7	韩国	韩国		iphone	iPhone6	ios	switch	5	travel	31
8	中国	山东	菏泽	iphone	iPhone7	ios	switch	4	travel	37
9	挪威	挪威		huawei	HUAWEI Mate 10	android	switch	8	travel	23

3.5. 数据可视化展现

数据表rpt_user_trace_log加工完成后，您可以通过Quick BI创建网站用户分析画像的仪表板，实现该数据表的可视化。

前提条件

在开始实验前，请确认您已经完成了环境准备和数据建模与开发的全部步骤。进入Quick BI控制台。

背景信息

rpt_user_trace_log表包含了country、province、city、device_brand、use_time、pv等字段信息。您可以通过仪表板展示用户的核心指标、周期变化、用户地区分布和记录。

操作步骤

1. 单击进入**默认空间**，您也可以使用自己的**个人空间**。

2. 新建MaxCompute数据源。
   i. 单击左侧导航栏上的**数据源**，进入**数据源**页面。
   ii. 单击右上角的**新建数据源**。选择**云数据库 > MaxCompute**。
   iii. 在**添加MaxCompute数据源**页面，配置数据源连接参数。

   完成填写后，单击**连接测试**，待显示**数据源连通性正常**后单击**添加**即可。

- 显示名称：数据源配置列表的显示名称。
- 数据库地址：此处有默认地址，通常无需修改。

  > **说明** 数据库地址根据Region不同而变化，详细对应信息请参见Endpoint。

- 项目名称：MaxCompute项目名称。
- AccessKey ID：您账号的AccessKey ID。
- AccessKey Secret：您账号的AccessKey Secret。

iv. 单击**连接测试**，进行数据源连通性测试。

> **说明** 如果连通正常，系统会给出连通成功提示。

v. 单击**添加**，完成数据源添加。

成功添加完成后，页面自动跳转到**数据源**管理页面，并在页面右侧展示出数据源所包含的所有数据表。

3. 在**数据源**管理页面找到rpt_user_trace_log表，单击**创建数据集**。

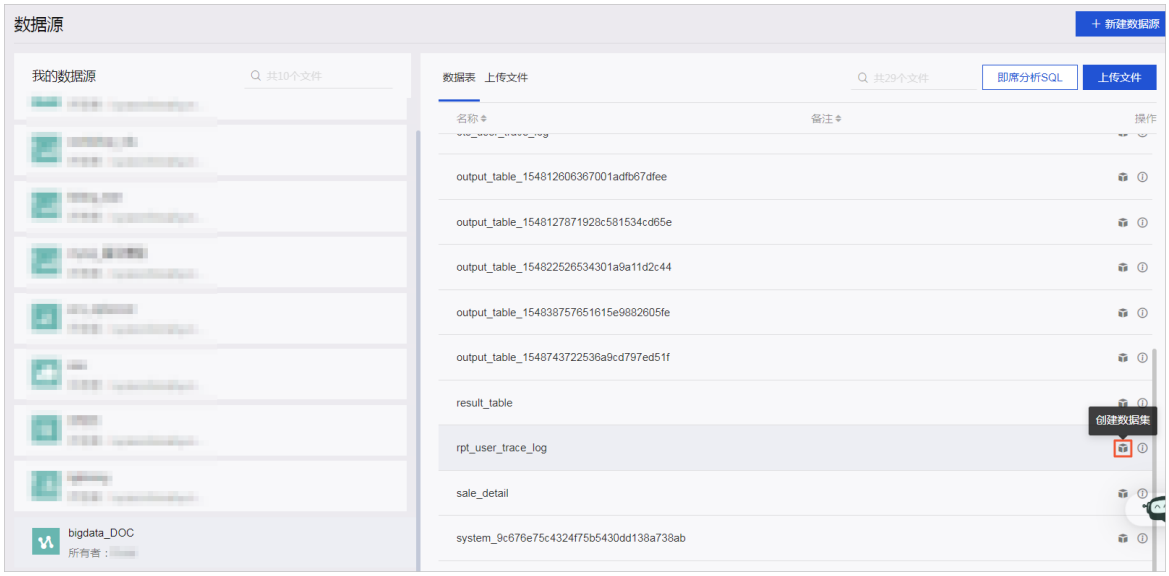

输入数据集的**名称**和**位置**，单击**确定**。

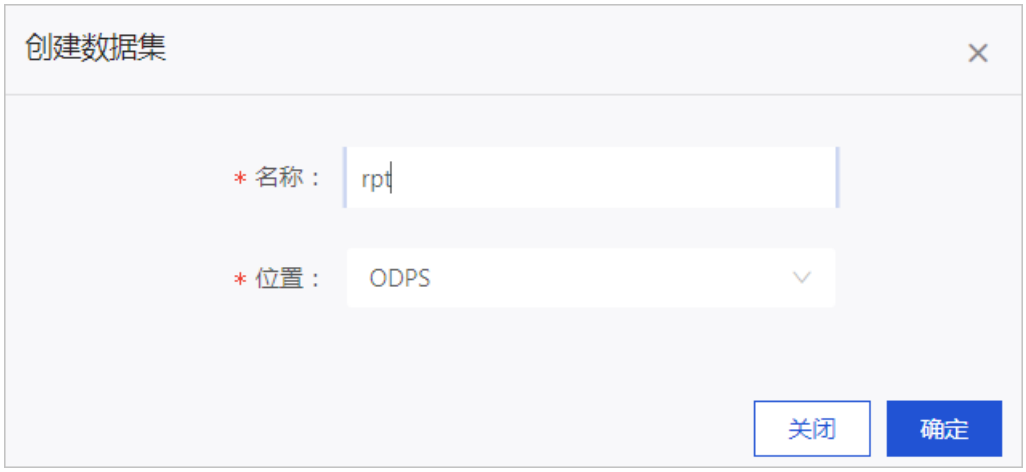

4. 单击左侧导航栏上的**数据集**，进入**数据集**页面。单击您刚刚创建的数据集，对数据集进行编辑。

   常见的数据集加工包括维度、度量的切换、修改维度的类型、增加计算字段、创建层次结构、修改字段的数据类型、更改度量聚合方式、制作关联模型。详情请参见概述。

5. 转换字段的维度类型。

i. 转换日期字段的维度类型。

右键单击dt字段，选择**维度类型切换 > 日期（源数据格式） > yyyyMMdd**。

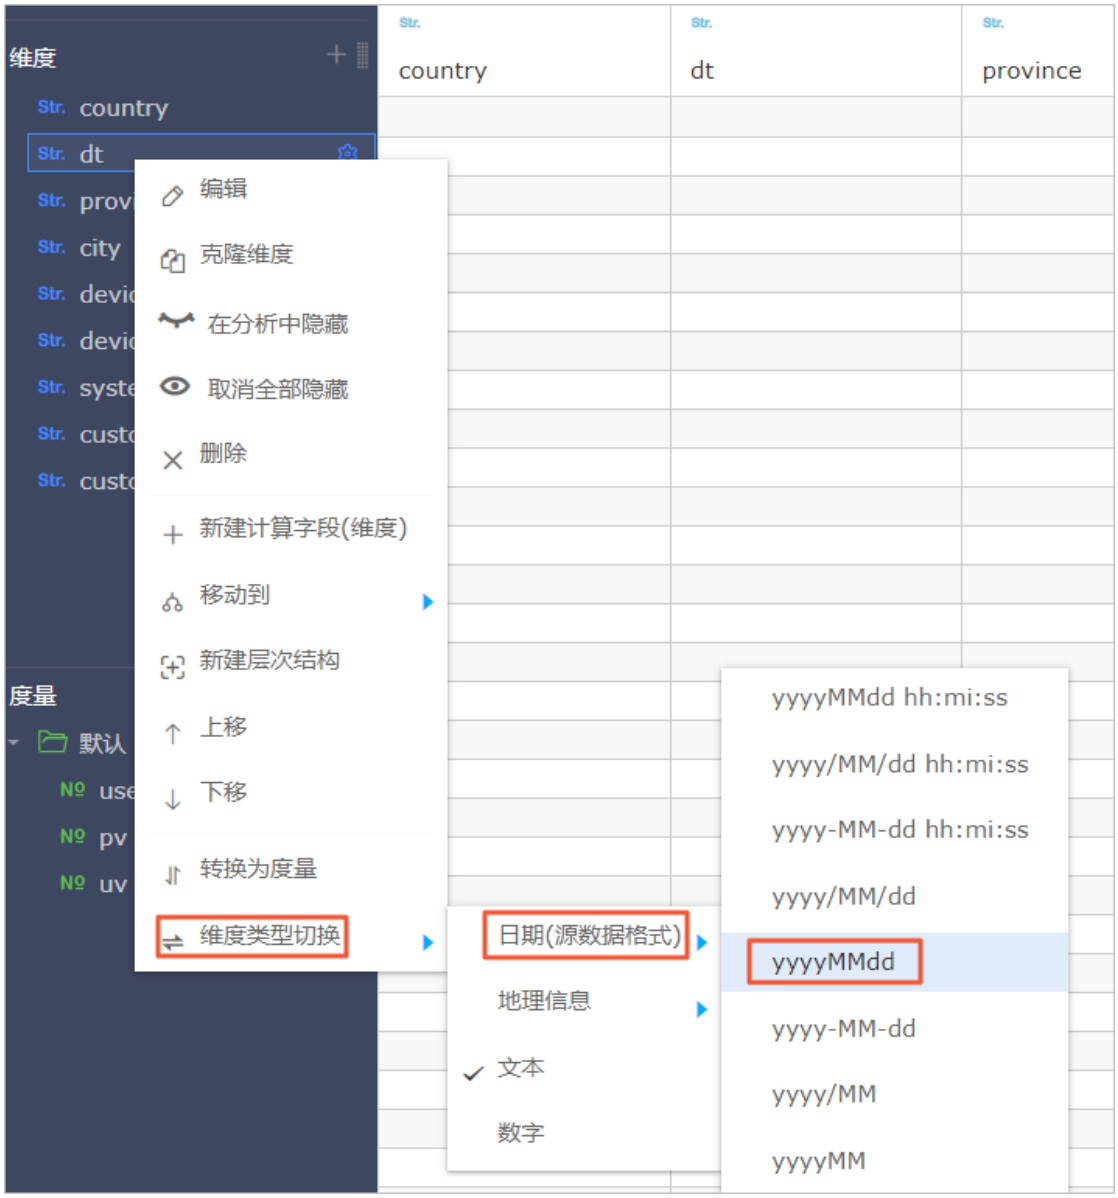

ii. 转换地理信息字段的维度类型。

a. 右键单击province字段，选择**维度类型切换 > 地理信息 > 省/直辖市**。

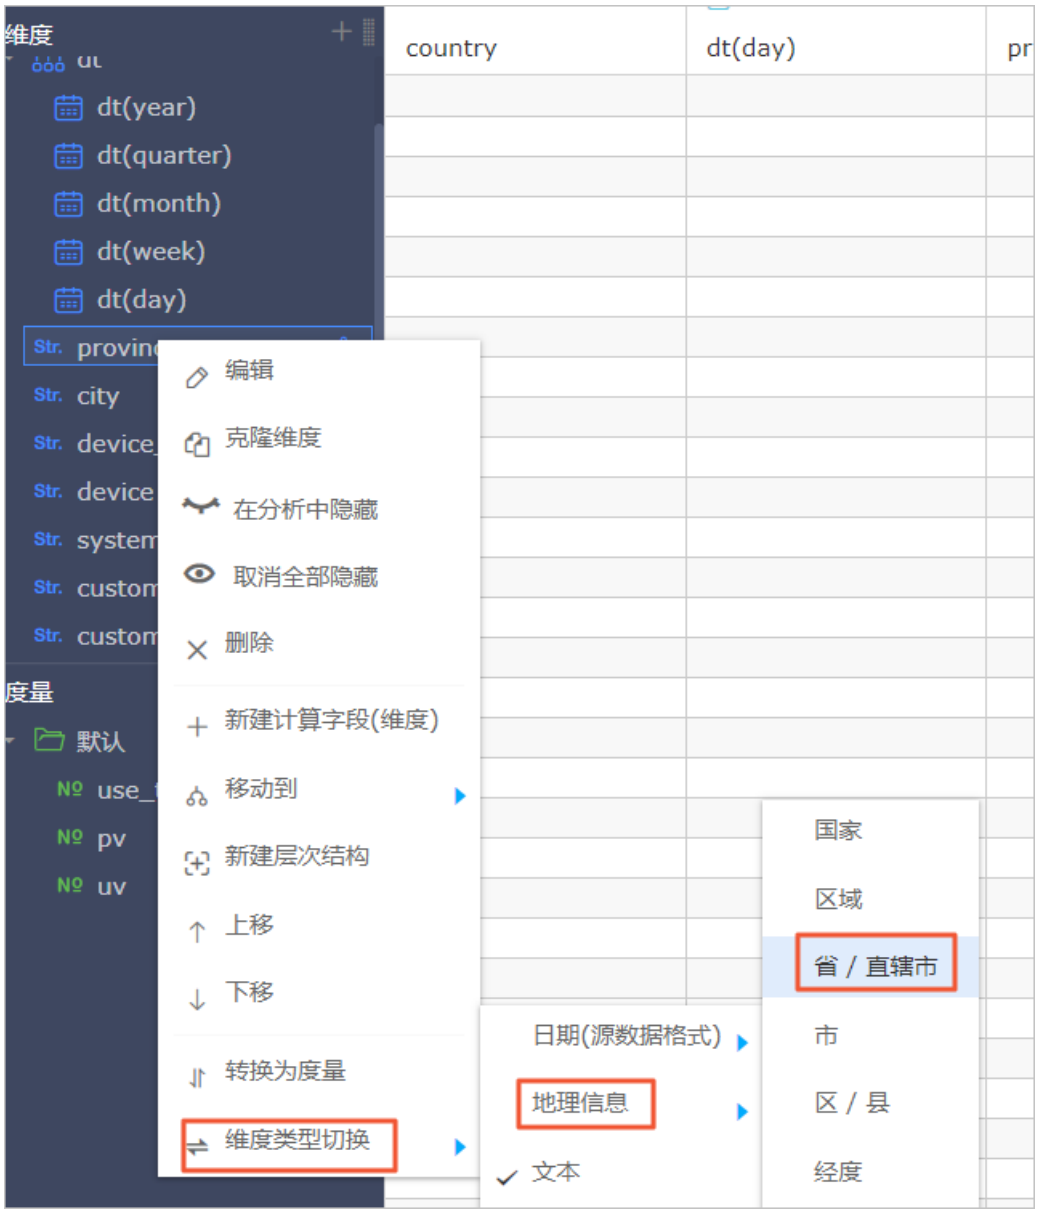

b. 右键单击city字段，选择**维度类型切换 > 地理信息 > 市**。转换成功后，在左侧维度栏中会看到字段前多一个地理位置图标。

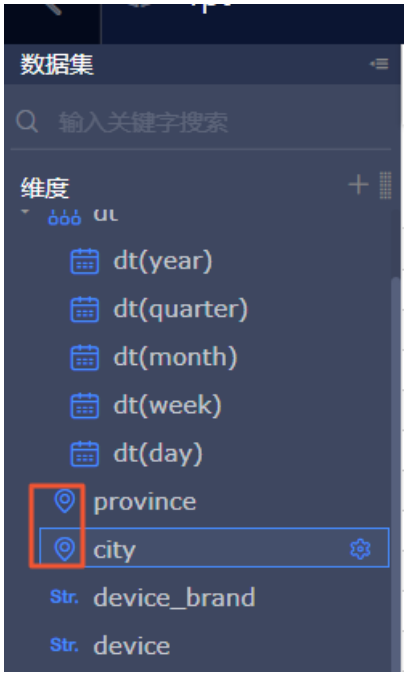

iii. 新建层次结构。

a. 右键province，单击**新建层次结构**，在弹框中单击**确定**。

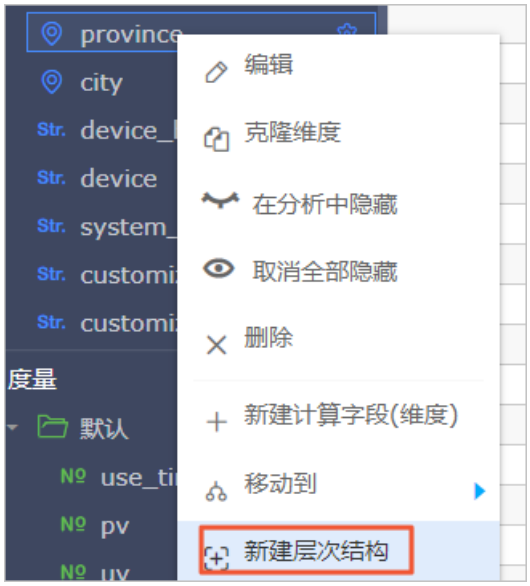

b. 将city字段移到province层次结构的树下。

c. 完成上述操作后，单击**保存**，返回数据集列表。

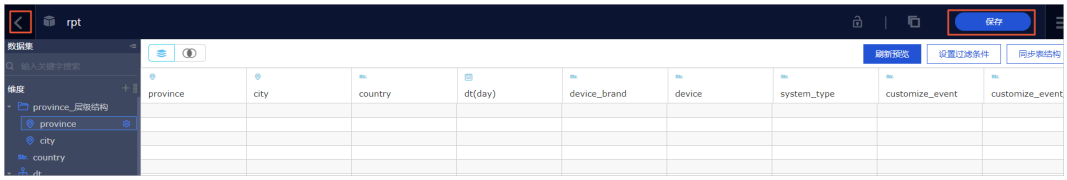

6. 制作仪表板。

即随着数据的更新，让报表可视化地展现最新数据。

i. 单击rpt数据集后的新建仪表板图标，选择**常规模式**，进入仪表板编辑页。

ii. 从仪表板空间中向空白区拖入2个指标看板，调整布局成一排。


未命名
指标看板
指标看板-rpt
Visitors count
1513
指标看板: 缺少维度或度量项
Visitors MoM
-15.43%
Visitors YoY
-
指标看板-rpt
Visitors count
1513
指标看板: 缺少维度或度量项
Visitors MoM
-15.43%
Visitors YoY
-

- 指标看板一：选择数据来源为数据集rpt，选择度量为pv。由于数据表rpt_user_trace_log为分区表，因此必须在**过滤器**处选择筛选的日期，本例中筛选为2019~2019年，完成设置后单击**更新**。

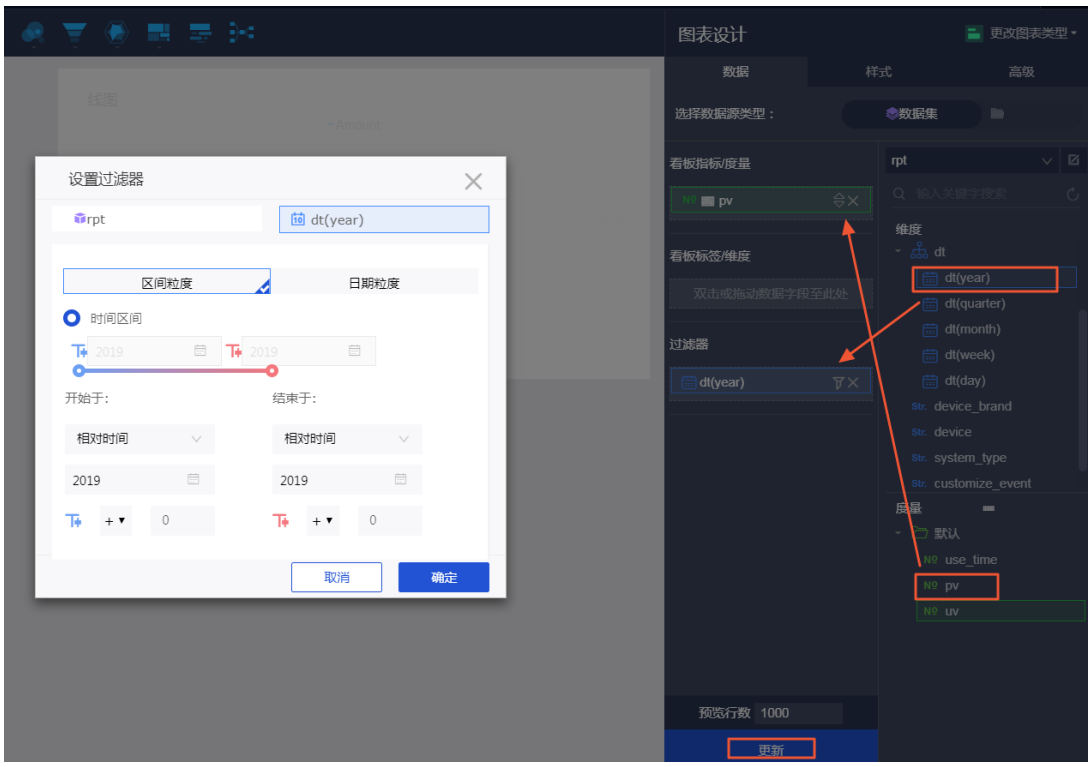

- 指标看板二：选择数据来源为来自数据集rpt，选择度量为uv，其他操作同上。完成设置后单击**更新样式**处设置指标看板显示的名称，显示效果如下。

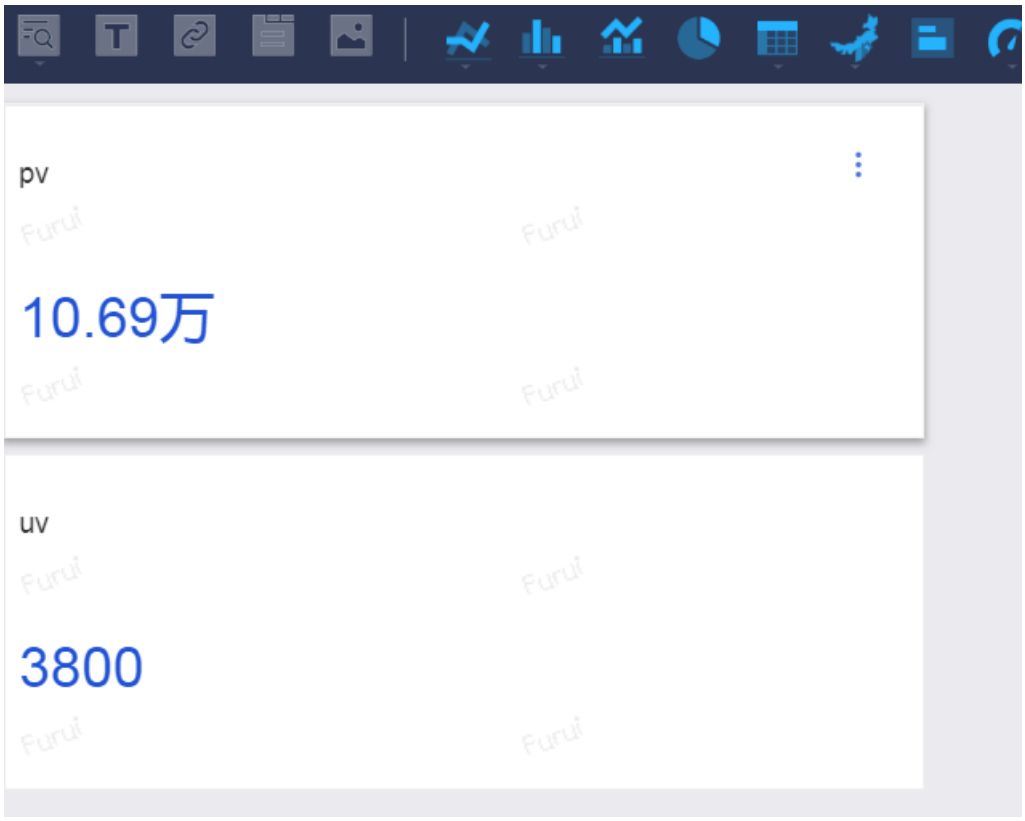

iii. 制作趋势图：将图表区域内的**线图**拖拽到左侧画布。

参数配置如下，完成之后单击**更新**：

- **值轴/度量**：pv、uv
- **类别轴/维度**：dt（day）
- **过滤器**：dt（year）

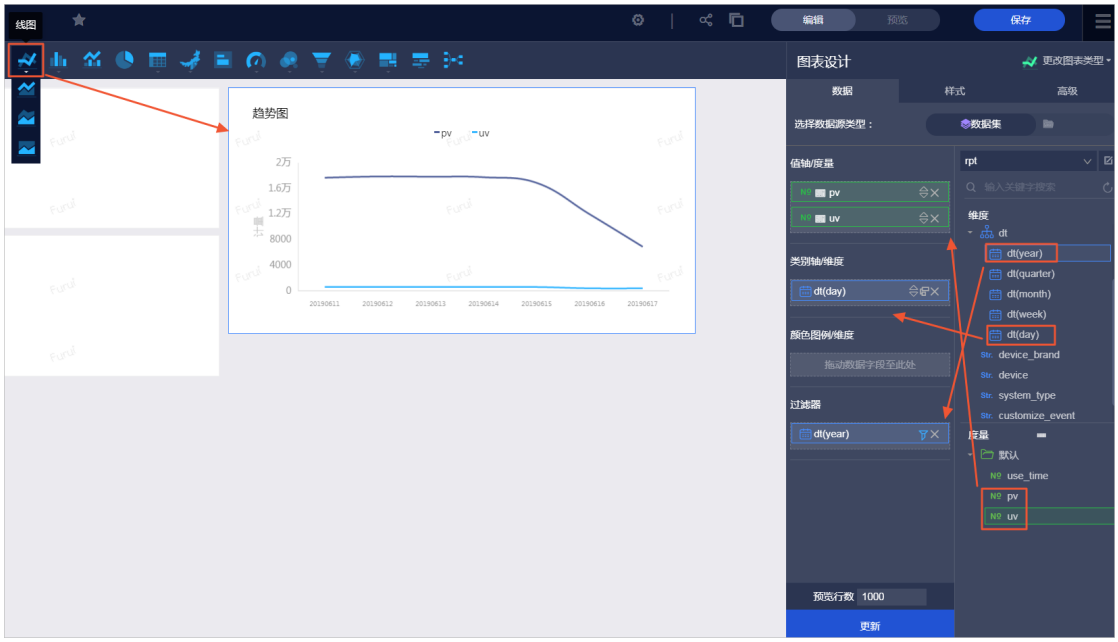

iv. 制作色彩地图：单击图表区域内的色彩地图，并选择数据源来源为数据集rpt_user_trace_log，选择**地理区域/维度**为province（地区）、**色彩饱和度/度量**为pv，选择完成后单击**更新**，结果如下。

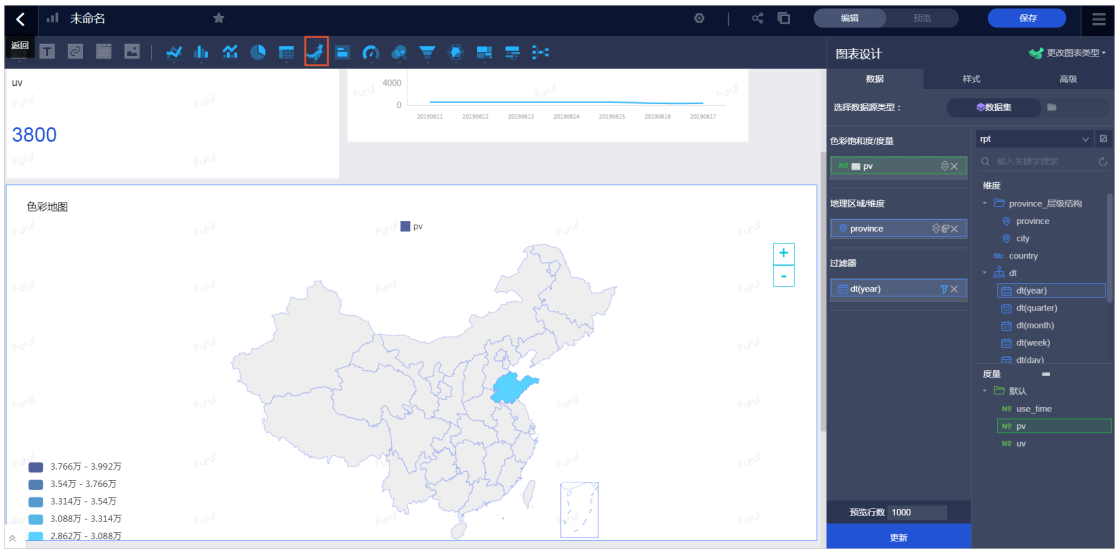

v. 完成配置后，单击**保存**及**预览**，即可看到展示效果。

4.实现窃电用户自动识别教程

4.1. 窃电用户自动识别概述

本教程为您介绍如何通过DataWorks配合机器学习的方式，实现窃电用户的自动识别，保障用户的安全用电。

传统的识别窃电或计量装置故障的方法包括定期巡检、定期校验电表、用户举报窃电等，对人的依赖性较强，且查找窃电漏电的目标不明确。

目前，很多供电局的营销稽查、用电检查和计量工作人员，利用计量异常报警和电能量数据查询功能来在线监控用电情况。通过采集电量异常、负荷异常、线损异常、终端报警、主站报警信息，建立数据分析模型，工作人员可以实时监测窃漏电情况并发现计量装置故障。根据报警事件发生前后，客户计量点有关的电流、电压和负荷等数据情况，构建基于指标的用电异常分析模型，检查是否存在窃电、违章用电及计量装置故障等情况。

虽然上述防窃电漏电的查询方法可以获得用电异常信息，但由于终端误报或漏报过多，无法真正快速精确地定位窃电漏电用户。同时，采用上述方法建模时，需要专家根据其知识和经验，来判断模型各输入指标权重，主观性较强。

现有的电力计量自动化系统，能够采集到各项电流、电压、功率等用电负荷数据及用电异常等终端报警信息。此外，稽查工作人员还可以通过在线稽查系统和现场稽查，查找窃电漏电用户数据并录入系统。

通过上述数据信息，提取出窃电漏电用户的关键特征，构建窃漏电用户的识别模型，即可自动判断用户是否存在窃电漏电行为，降低稽查工作人员的工作量，并保障用户的正常、安全用电。

4.2. 准备环境

为保证您可以顺利完成本次实验，请您首先确保自己云账号已开通大数据计算服务MaxCompute、数据工场DataWorks和机器学习PAI。

前提条件

- 注册阿里云账号。
- 进行个人实名认证或企业实名认证。

背景信息

本次实验涉及的阿里云产品如下：

- MaxCompute
- DataWorks
- PAI

开通大数据计算服务MaxCompute

> **说明** 如果您已经开通MaxCompute，请跳过该步骤，直接创建DataWorks工作空间。

1. 登录阿里云官网，单击右上角的**登录**，输入您的阿里云账号和密码。
2. 鼠标悬停至顶部菜单栏中的**产品**，单击**大数据 > 大数据计算与分析 > MaxCompute**，进入MaxCompute产品详情页。
3. 单击**立即开通**。

4. 在购买页面，选择**地域**，并选中**服务协议**，单击**确认订单并支付**。

> 说明
> - 购买页面默认提供的规格类型为MaxCompute按量计费标准版和DataWorks基础版。
> - MaxCompute的项目管理和查询编辑集成DataWorks的功能，因此需要同时开通DataWorks服务。DataWorks基础版为0元开通，如果您不使用数据集成、不执行调度任务，则不会产生费用。
> - 选择地域时，您需要考虑的最主要因素是MaxCompute与其它阿里云产品之间的关系。例如，ECS所在地域、数据所在地域等。

创建工作空间

1. 使用主账号登录DataWorks控制台。
2. 在**概览**页面，单击右侧的**创建工作空间**。

   您也可以单击左侧导航栏中的**工作空间列表**，切换至相应的区域后，单击**创建工作空间**。
3. 在**创建工作空间**对话框，配置各项参数，单击**下一步**。

分类	参数	描述
基本信息	**工作空间名称**	工作空间名称的长度需要在3~23个字符，以字母开头，且只能包含字母、下划线（_）和数字。
	显示名	显示名不能超过23个字符，只能字母、中文开头，仅包含中文、字母、下划线（_）和数字。
	模式	工作空间模式是DataWorks新版推出的新功能，分为**简单模式**和**标准模式**： ○ **简单模式**：指一个DataWorks工作空间对应一个MaxCompute项目，无法设置开发和生产环境，只能进行简单的数据开发，无法对数据开发流程以及表权限进行强控制。 ○ **标准模式**：指一个DataWorks工作空间对应两个MaxCompute项目，可以设置开发和生产两种环境，提升代码开发规范，并能够对表权限进行严格控制，禁止随意操作生产环境的表，保证生产表的数据安全。 详情请参见简单模式和标准模式的区别。
	描述	对创建的工作空间进行简单描述。
高级设置	**能下载select结果**	控制数据开发中查询的数据结果是否能够下载，如果关闭无法下载select的数据查询结果。此参数在工作空间创建完成后可以在工作空间配置页面进行修改，详情可参考文档：安全设置。

4. 在**选择引擎**界面，选择相应引擎后，单击**下一步**。

   DataWorks已正式商用，如果该区域没有开通，需要首先开通正式商用的服务。默认选中**数据集成**、**数据开发**、**运维中心**和**数据质量**。

> **说明** 此处需要同时勾选机器学习PAI和MaxCompute。

5. 进入**引擎详情**页面，配置选购引擎的参数。

分类	参数	描述
MaxCompute	**实例显示名称**	实例显示名称需要以字母开头，只能包含字母、数字和下划线（_）。
	Quota组切换	Quota用于实现计算资源和磁盘配额。
	MaxCompute数据类型	该选项设置后将在5分钟内生效，数据类型模式的详情请参见数据类型版本说明。如果您不清楚模式的选择，建议与工作空间管理员确认后再进行选择。
	是否加密	您可以设置**不加密**和**加密**。
	MaxCompute项目名称	开发环境的默认名称为DataWorks工作空间的名称_dev，生产环境的默认名称与DataWorks工作空间名称一致。
	MaxCompute访问身份	开发环境的MaxCompute访问身份默认为**任务负责人**，不可以修改。 生产环境的MaxCompute访问身份包括**阿里云主账号**和**阿里云子账号**。

6. 配置完成后，单击**创建工作空间**。

   工作空间创建成功后，即可在**工作空间列表**页面查看相应内容。

4.3. 准备数据

在数据准备阶段，您需要同步原始数据至MaxCompute。

准备数据源

1. 通过RDS创建MySQL实例，获取RDS实例ID。详情请参见创建RDS MySQL实例。
2. 在RDS控制台添加白名单，详情请参见添加白名单。

> **说明** 如果是通过自定义资源组调度RDS的数据同步任务，必须把自定义资源组的机器IP也加入RDS的白名单中。

3. 下载本教程使用的原始数据indicators_data、steal_flag_data和trend_data。
4. 上传原始数据至RDS数据源，详情请参见将Excel的数据导入数据库。

新增数据源

> **说明** 本次实验需要创建MySQL数据源。

1. 进入**数据源管理**页面。

i. 登录DataWorks控制台。
ii. 在左侧导航栏，单击**工作空间列表**。
iii. 选择工作空间所在地域后，单击相应工作空间后的**进入数据集成**。
iv. 在左侧导航栏，单击**数据源**，进入**工作空间管理 > 数据源管理**页面。

2. 在**数据源管理**页面，单击右上角的**新增数据源**。
3. 在**新增数据源**对话框中，选择数据源类型为**MySQL**。
4. 在**新增MySQL数据源**对话框中，配置各项参数。

参数	描述
数据源类型	当前选择的数据源类型为**MySQL > 阿里云实例模式**。
数据源名称	数据源名称必须以字母、数字、下划线组合，且不能以数字和下划线开头。
数据源描述	对数据源进行简单描述，不得超过80个字符。
适用环境	可以选择**开发**或**生产**环境。 **说明** 仅标准模式工作空间会显示该配置。
地区	选择相应的区域。
RDS实例ID	您可以进入RDS控制台，查看RDS实例ID。
RDS实例主账号ID	实例购买者登录控制台，进入**安全设置**页面，即可查看实例账号ID。
数据库名	数据库的名称。
用户名	数据库对应的用户名。
密码	数据库对应的密码。

5. 单击**测试连通性**。
6.
7. 测试连通性通过后，单击**完成**。

新建业务流程

1. 单击当前页面左上角的图标，选择**全部产品 > 数据开发 > DataStudio（数据开发）**。
2. 右键单击**业务流程**，选择**新建业务流程**。
3. 在**新建业务流程**对话框中，输入**业务名称**和**描述**。

数据开发

说明 业务名称的长度不能超过128个字符，且必须是大小写字母、中文、数字、下划线（_）以及小数点（.）。

4. 单击**新建**。
5. 进入业务流程开发面板，并向面板中拖入一个虚拟节点（start）和三个离线同步节点（电量下降趋势数据同步、窃电标志数据同步和指标数据同步）分别填写相应的配置后，单击**提交**。

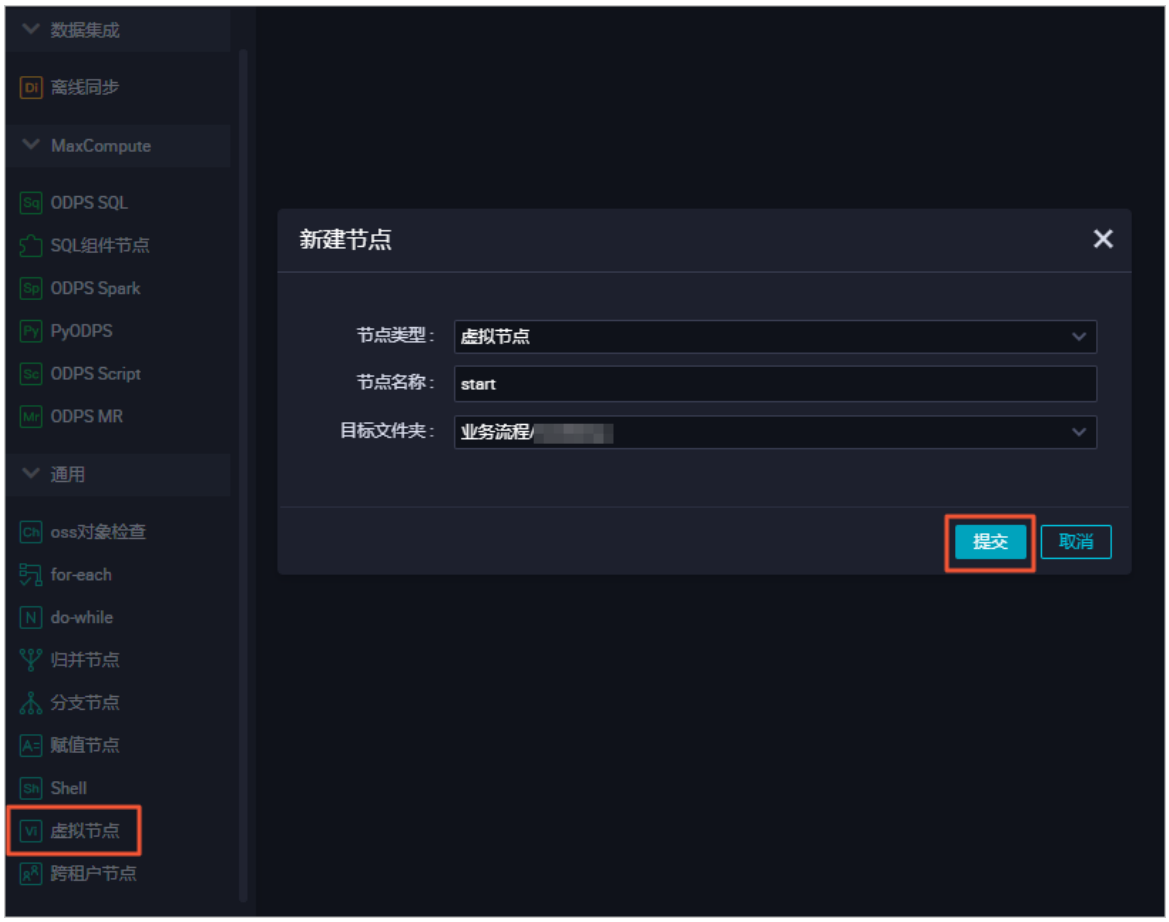

6. 拖拽连线将start节点设置为三个离线同步节点的上游节点。

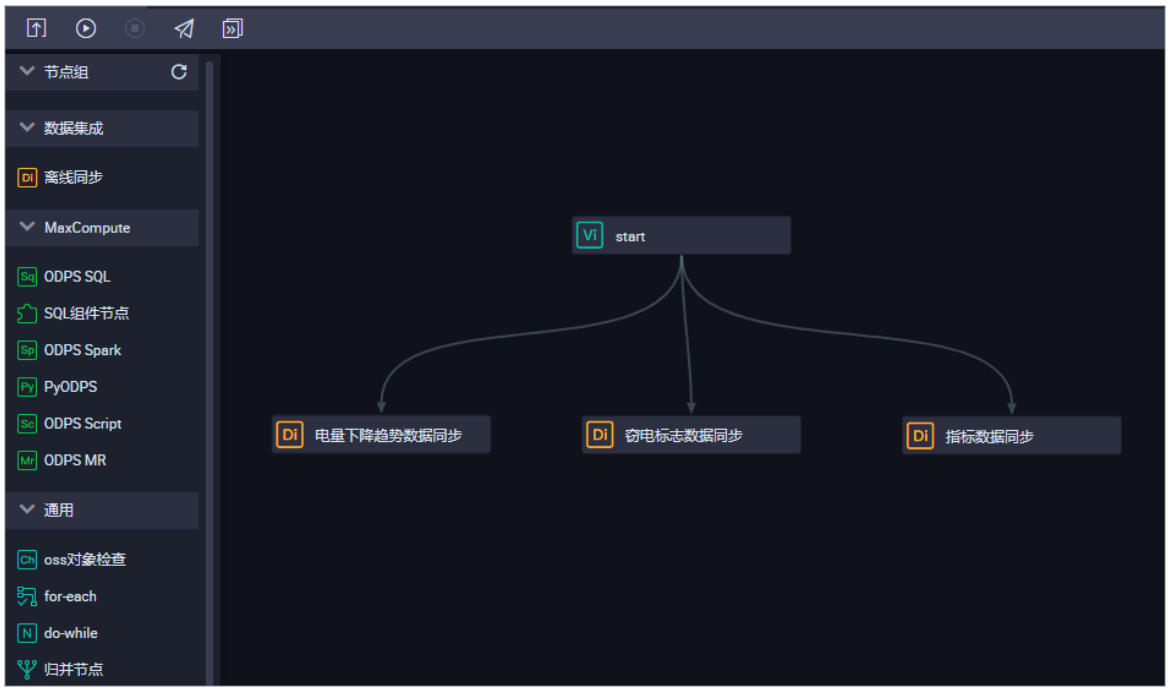

配置start节点

1. 双击虚拟节点，单击右侧的**调度配置**。
2. 设置start节点的上游节点为工作空间根节点。

   由于新版本给每个节点都设置了输入输出节点，所以需要给start节点设置一个输入。此处设置其上游节点为工作空间根节点，通常命名为工作空间名_root。

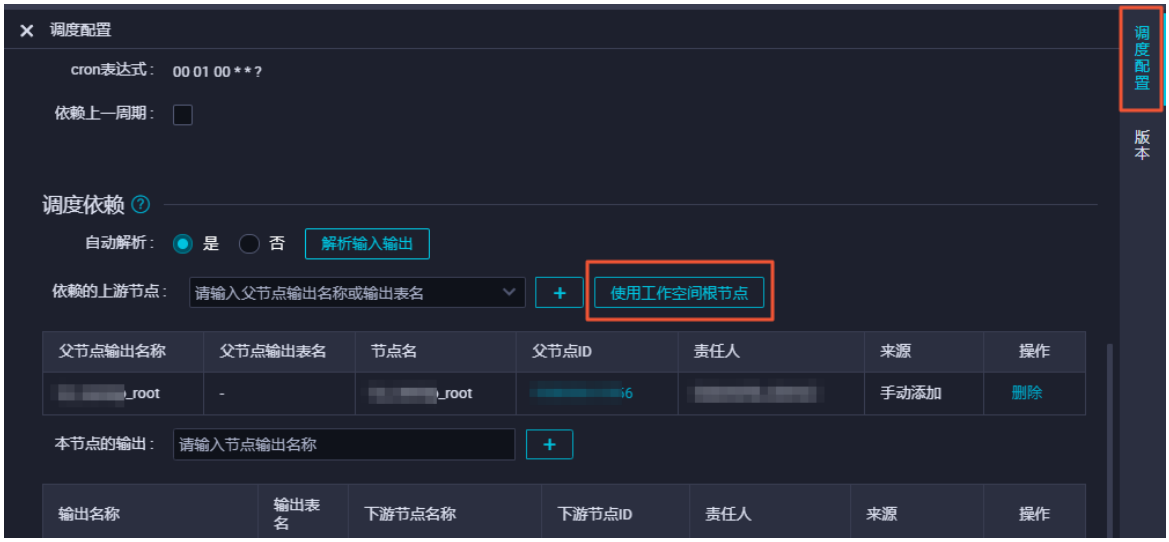

3. 配置完成后，单击左上角的图标。

新建表

1. 打开新建的业务流程，单击**MaxCompute**左侧的展开图标，打开MaxCompute。
2. 右键单击**MaxCompute**下的**表**，单击**新建表**。
3. 在**新建表**对话框中，输入**表名**，单击**提交**。

   此处需要创建3张表，分别存储同步过来的电量下降趋势数据、指标数据和窃电标志数据（trend_data、indicators_data和steal_flag_data）。

   > **说明** 表名不能超过64个字符，且必须以字母开头，不能包含中文或特殊字符。

4. 打开创建的表，单击**DDL模式**，分别输入以下相应的建表语句。

```
--电量下降趋势表
CREATE TABLE trend_data (
    uid bigint,
    trend bigint
)
PARTITIONED BY (dt string);
```

```
--指标数据
CREATE TABLE indicators_data (
    uid bigint,
    xiansun bigint,
    warnindicator bigint
)
COMMENT '*'
PARTITIONED BY (ds string)
LIFECYCLE 36000;
```

```
--窃电标志数据
CREATE TABLE steal_flag_data (
    uid bigint,
    flag bigint
)
COMMENT '*'
PARTITIONED BY (ds string)
LIFECYCLE 36000;
```

5. 建表语句输入完成后，单击**生成表结构**并**确认**覆盖当前操作。
6. 返回建表页面后，在**基本属性**中输入表的中文名。
7. 完成设置后，分别单击**提交到开发环境**和**提交到生产环境**。

配置离线同步节点

1. 配置电量下降趋势数据同步节点。
   i. 双击电量下降趋势数据同步节点，进入节点配置页面。

ii. 选择数据来源。

参数	描述
数据源	选择MySQL > workshop。
表	选择MySQL数据源中的表trending。
数据过滤	您将要同步数据的筛选条件，暂时不支持limit关键字过滤。SQL语法与选择的数据源一致，此处可以不填。
切分键	读取数据时，根据配置的字段进行数据分片，实现并发读取，可以提升数据同步效率。此处可以不填。

iii. 选择数据去向。

参数	描述
数据源	选择**ODPS > odps_first**。
表	选择ODPS数据源中的表trend_data。
分区信息	输入要同步的分区列，此处默认为 `dt=${bdp.system.bizdate}` 。
清理规则	选择**写入前清理已有数据**。
空字符串作为null	选择**否**。

iv. 配置字段映射。

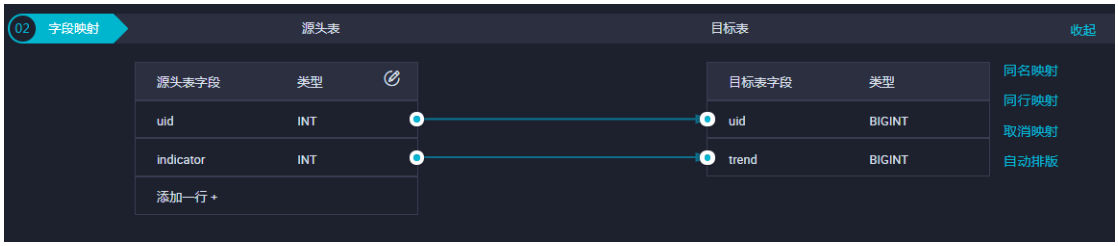

v. 配置**通道控制**。

参数	描述
任务期望最大并发数	数据同步任务内，可以从源并行读取或并行写入数据存储端的最大线程数。向导模式通过界面化配置并发数，指定任务所使用的并行度。
同步速率	设置同步速率可以保护读取端数据库，以避免抽取速度过大，给源库造成太大的压力。同步速率建议限流，结合源库的配置，请合理配置抽取速率。
错误记录数	错误记录数，表示脏数据的最大容忍条数。

vi. 确认当前节点的配置无误后，单击左上角的图标。

提交业务流程

1. 打开业务流程配置面板，单击左上角的进行提交。
2. 选择**提交**对话框中需要提交的节点，输入**备注**，勾选**忽略输入输出不一致的告警**。

3. 单击**提交**，待显示**提交成功**即可。

确认数据是否成功导入MaxCompute

1. 在**数据开发**页面的左侧导航栏，单击**临时查询**，进入**临时查询**面板。
2. 右键单击**临时查询**，选择**新建节点 > ODPS SQL**。

3. 编写并执行SQL语句，查看导入表trend_data、indicators_data和steal_flag_data的记录数。

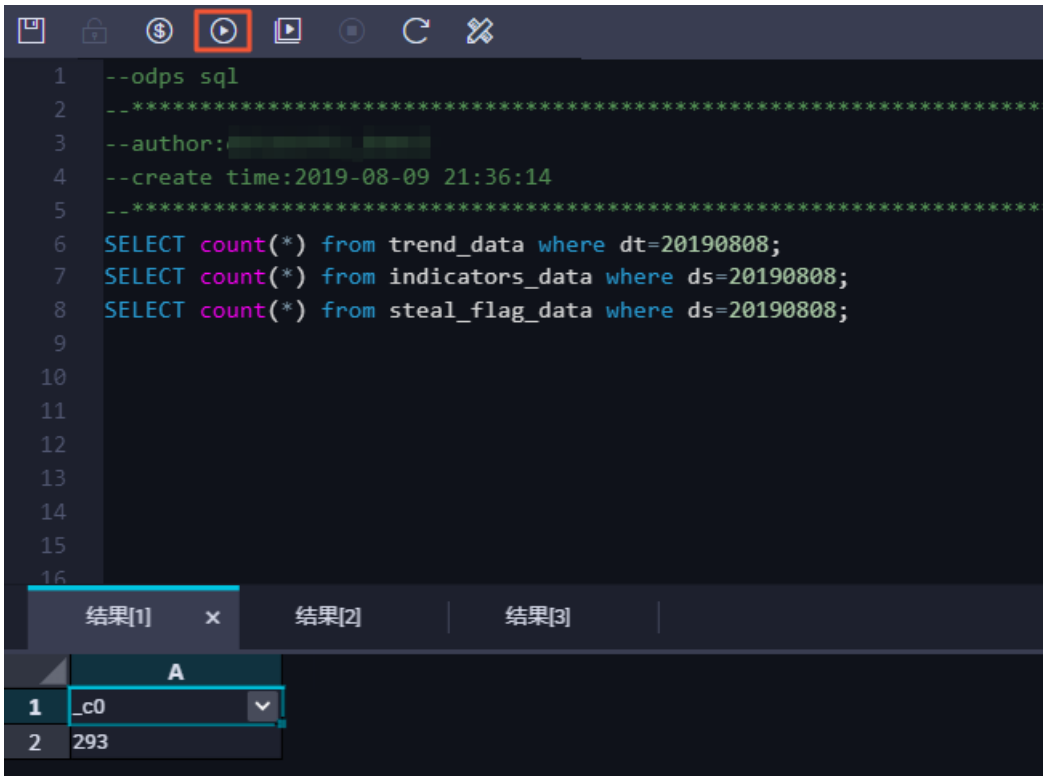

SQL语句如下所示，其中分区列需要更新为业务日期。例如，任务运行的日期为20190809，则业务日期为201900808。

```
--查看是否成功写入MaxCompute
SELECT count(*) from trend_data where dt=业务日期;
SELECT count(*) from indicators_data where ds=业务日期;
SELECT count(*) from steal_flag_data where ds=业务日期;
```

后续步骤

现在，您已经学习了如何通过数据同步采集数据，您可以继续下一个教程。在该教程中，您将学习如何对采集的数据进行计算与分析。

4.4. 加工数据

本文为您介绍如何通过DataWorks加工采集至MaxCompute的数据，并获取清洗后的数据。

前提条件

开始本文的操作前，请首先完成准备数据中的操作。

新建表

1. 进入**数据开发**页面。
   i. 登录DataWorks控制台。
   ii. 在左侧导航栏，单击**工作空间列表**。
   iii. 选择工作空间所在地域后，单击相应工作空间后的**进入数据开发**。
2. 在**数据开发**页面，单击相应业务流程左侧的图标，展开该业务流程。

3. 右键单击**MaxCompute**，选择**新建 > 表**。
4. 在**新建表**对话框中，输入**表名**，单击**提交**。

> **注意** 表名必须以字母开头，不能包含中文或特殊字符，且不能超过64个字符。

此处需要创建的数据表，如下所示：

- 创建三张表，分别存储同步过来的电量下降趋势数据、指标数据和窃电标志数据清洗之后的数据（clean_trend_data、clean_indicators_data和clean_steal_flag_data）。
- 创建表data4ml，存储汇聚后的数据。

5. 打开创建的表，单击**DDL模式**，分别输入以下相应的建表语句。

```
--清洗后的电量下降趋势数据
CREATE TABLE clean_trend_data (
    uid bigint,
    trend bigint
)
PARTITIONED BY (dt string)
LIFECYCLE 7;
```

```
--清洗后的指标数据
CREATE TABLE clean_indicators_data (
    uid bigint,
    xiansun bigint,
    warnindicator bigint
)
COMMENT '*'
PARTITIONED BY (ds string)
LIFECYCLE 36000;
```

```
--清洗后的窃电标志数据
CREATE TABLE clean_steal_flag_data (
    uid bigint,
    flag bigint
)
COMMENT '*'
PARTITIONED BY (ds string)
LIFECYCLE 36000;
```

```
--汇聚后的数据
CREATE TABLE data4ml (
    uid bigint,
    trend bigint,
    xiansun bigint,
    warnindicator bigint,
    flag bigint
)
COMMENT '*'
PARTITIONED BY (ds string)
LIFECYCLE 36000;
```

6. 建表语句输入完成后，单击**生成表结构**并**确认**覆盖当前操作。

7. 返回建表页面后，在**基本属性**中输入表的中文名。
8. 完成设置后，分别单击**提交到开发环境**和**提交到生产环境**。

设计业务流程

业务流程的新建及依赖关系的配置请参见新建业务流程。

进入业务流程开发面板，并向面板中拖入两个ODPS SQL节点，依次命名为**数据清洗**和**数据汇聚**，并配置如下图所示的依赖关系。

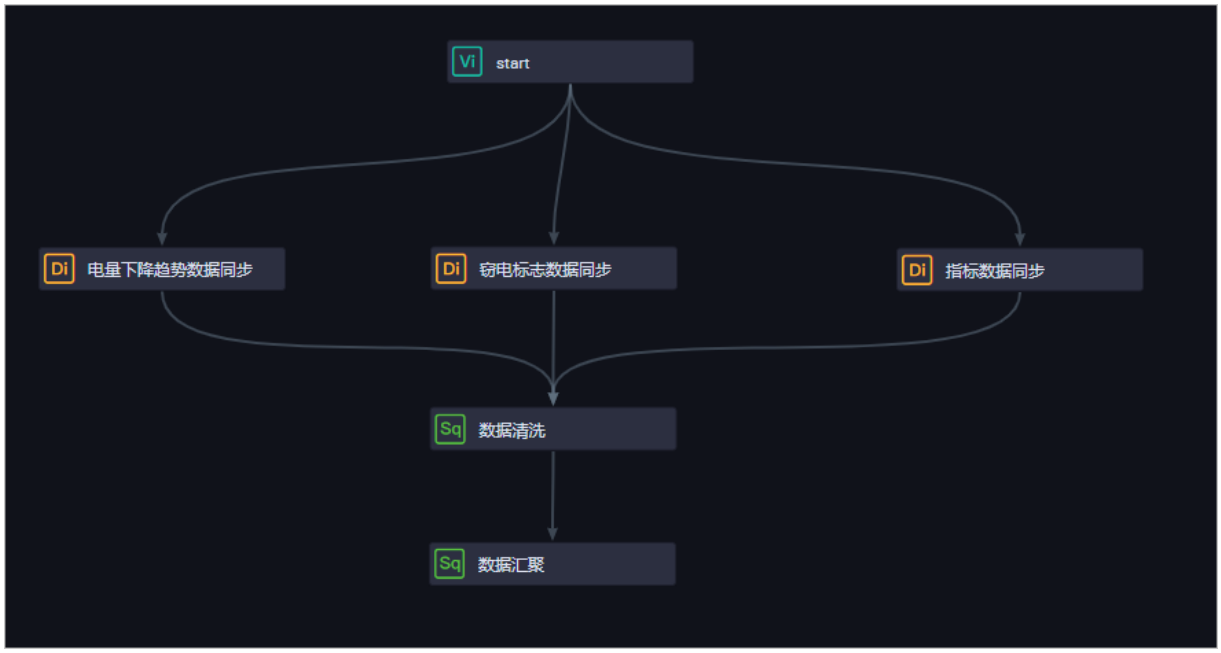

配置ODPS SQL节点

- 配置数据清洗节点。
  i. 双击数据清洗节点，进入节点配置页面。
  ii. 编写处理逻辑。

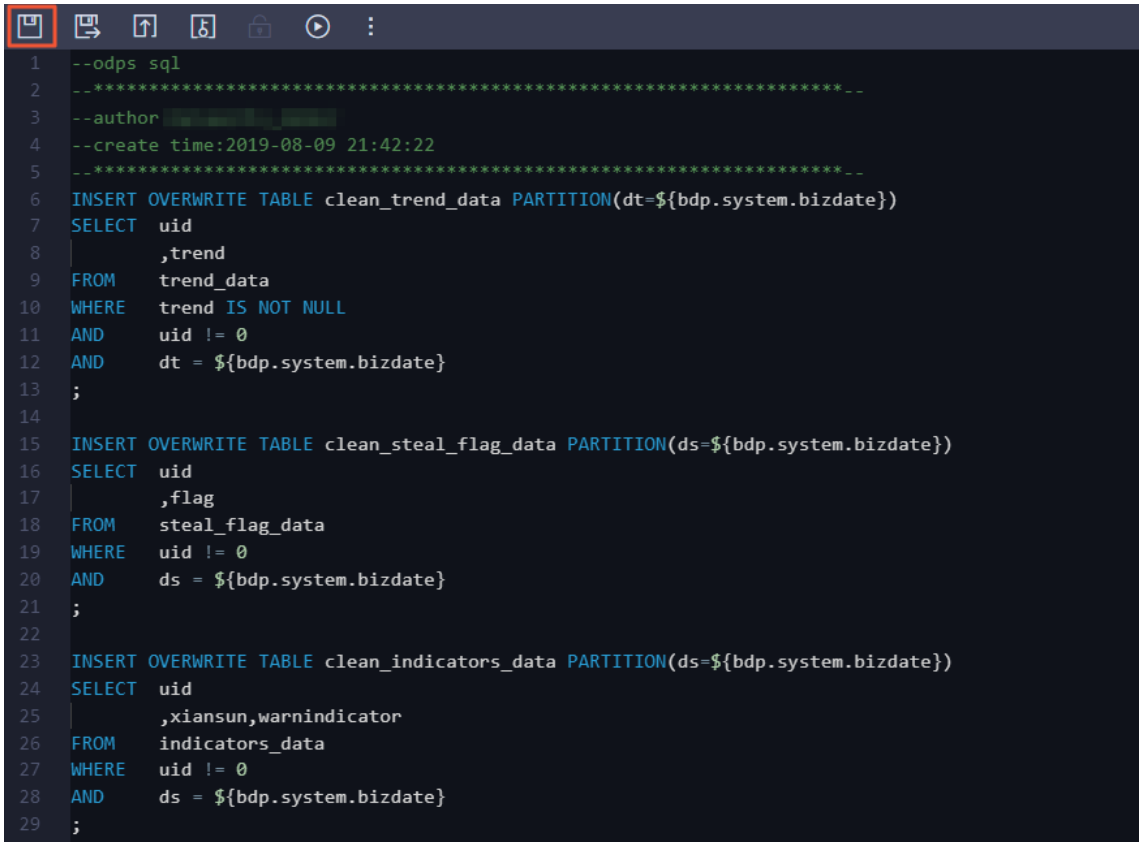

```
--odps sql
--********************************************************************--
--author
--create time:2019-08-09 21:42:22
--********************************************************************--
INSERT OVERWRITE TABLE clean_trend_data PARTITION(dt=${bdp.system.bizdate})
SELECT  uid
        ,trend
FROM    trend_data
WHERE   trend IS NOT NULL
AND     uid != 0
AND     dt = ${bdp.system.bizdate}
;

INSERT OVERWRITE TABLE clean_steal_flag_data PARTITION(ds=${bdp.system.bizdate})
SELECT  uid
        ,flag
FROM    steal_flag_data
WHERE   uid != 0
AND     ds = ${bdp.system.bizdate}
;

INSERT OVERWRITE TABLE clean_indicators_data PARTITION(ds=${bdp.system.bizdate})
SELECT  uid
        ,xiansun,warnindicator
FROM    indicators_data
WHERE   uid != 0
AND     ds = ${bdp.system.bizdate}
;
```

SQL逻辑如下所示。

```
INSERT OVERWRITE TABLE clean_trend_data PARTITION(dt=${bdp.system.bizdate})
SELECT  uid
        ,trend
FROM    trend_data
WHERE   trend IS NOT NULL
AND     uid != 0
AND     dt = ${bdp.system.bizdate}
;
INSERT OVERWRITE TABLE clean_steal_flag_data PARTITION(ds=${bdp.system.bizdate})
SELECT  uid
        ,flag
FROM    steal_flag_data
WHERE   uid != 0
AND     ds = ${bdp.system.bizdate}
;
INSERT OVERWRITE TABLE clean_indicators_data PARTITION(ds=${bdp.system.bizdate})
SELECT  uid
        ,xiansun,warnindicator
FROM    indicators_data
WHERE   uid != 0
AND     ds = ${bdp.system.bizdate}
;
```

iii. 单击工具栏中的图标。

- 配置数据汇聚节点。

i. 双击数据汇聚节点，进入节点配置页面。

ii. 编写处理逻辑。

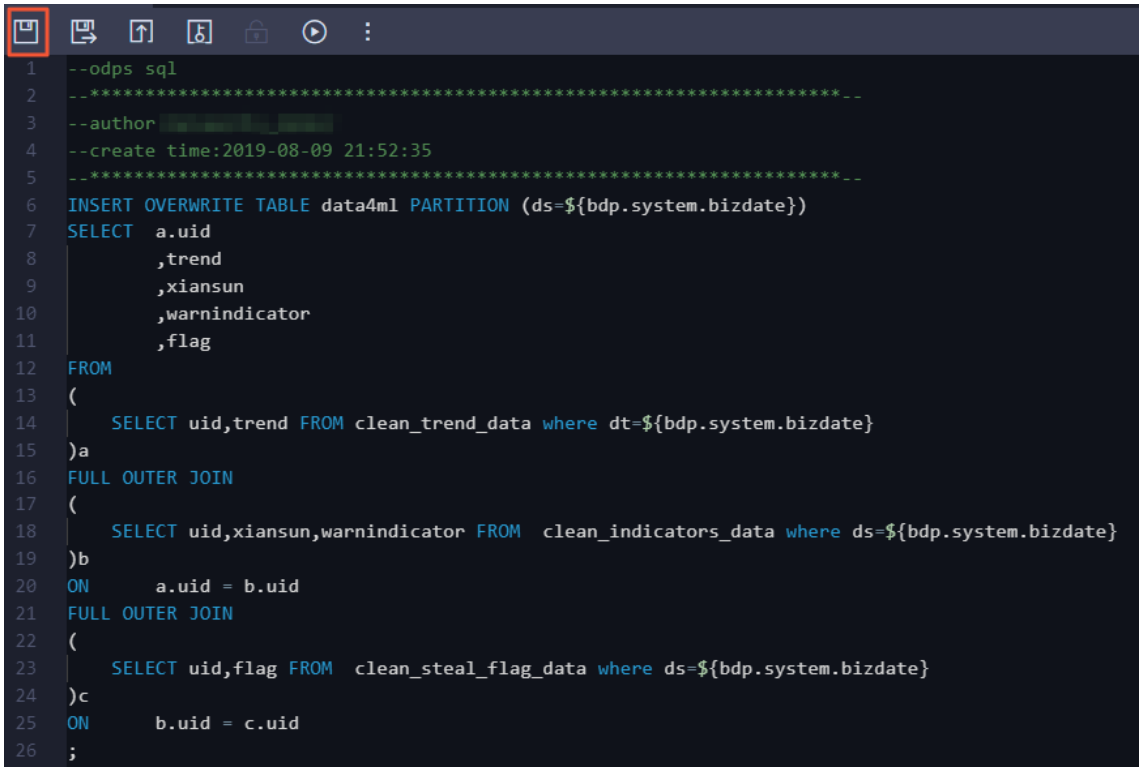

```
--odps sql
--********************************************************************--
--author
--create time:2019-08-09 21:52:35
--********************************************************************--
INSERT OVERWRITE TABLE data4ml PARTITION (ds=${bdp.system.bizdate})
SELECT  a.uid
        ,trend
        ,xiansun
        ,warnindicator
        ,flag
FROM
(
    SELECT uid,trend FROM clean_trend_data where dt=${bdp.system.bizdate}
)a
FULL OUTER JOIN
(
    SELECT uid,xiansun,warnindicator FROM  clean_indicators_data where ds=${bdp.system.bizdate}
)b
ON      a.uid = b.uid
FULL OUTER JOIN
(
    SELECT uid,flag FROM  clean_steal_flag_data where ds=${bdp.system.bizdate}
)c
ON      b.uid = c.uid
;
```

SQL逻辑如下所示。

```
INSERT OVERWRITE TABLE data4ml PARTITION (ds=${bdp.system.bizdate})
SELECT  a.uid
        ,trend
        ,xiansun
        ,warnindicator
        ,flag
FROM
(
    SELECT uid,trend FROM clean_trend_data where dt=${bdp.system.bizdate}
)a
FULL OUTER JOIN
(
    SELECT uid,xiansun,warnindicator FROM  clean_indicators_data where ds=${bdp.syste
m.bizdate}
)b
ON      a.uid = b.uid
FULL OUTER JOIN
(
    SELECT uid,flag FROM  clean_steal_flag_data where ds=${bdp.system.bizdate}
)c
ON      b.uid = c.uid
;
```

iii. 单击工具栏中的图标。

提交业务流程

1. 打开业务流程配置面板，单击工具栏中的图标。
2. 选择**提交**对话框中需要提交的节点，输入**备注**，并选中**忽略输入输出不一致的告警**。

3. 单击**提交**，待显示**提交成功**即可。

运行业务流程

1. 打开业务流程配置面板，单击工具栏中的图标。
2. 在左侧导航栏，单击**临时查询**。
3. 在**临时查询**页面，右键单击**临时查询**，选择**新建节点 > ODPS SQL**。

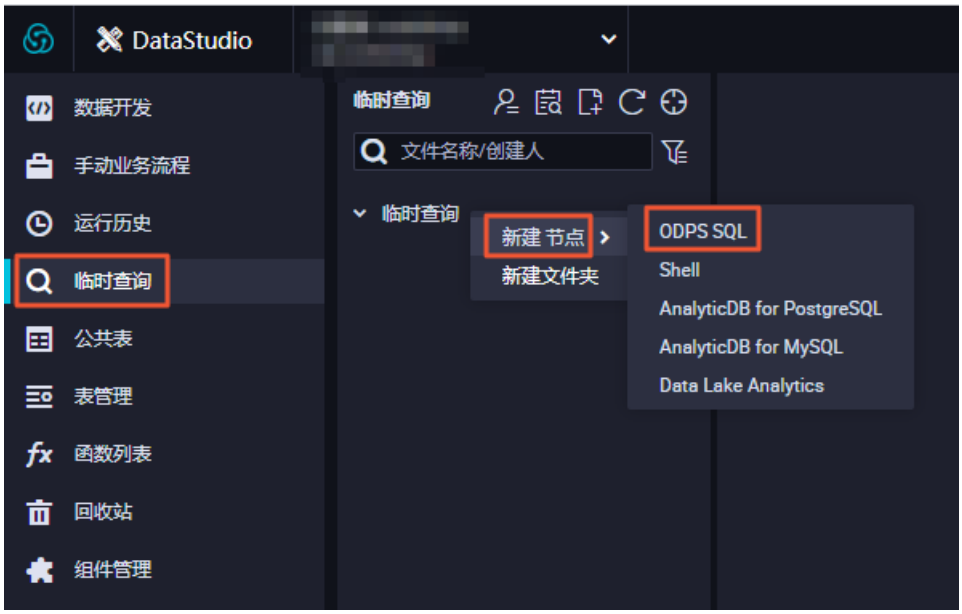

4. 编写并执行SQL语句，查看导入表clean_trend_data、clean_indicators_data、clean_steal_flag_data和data4ml的记录数。

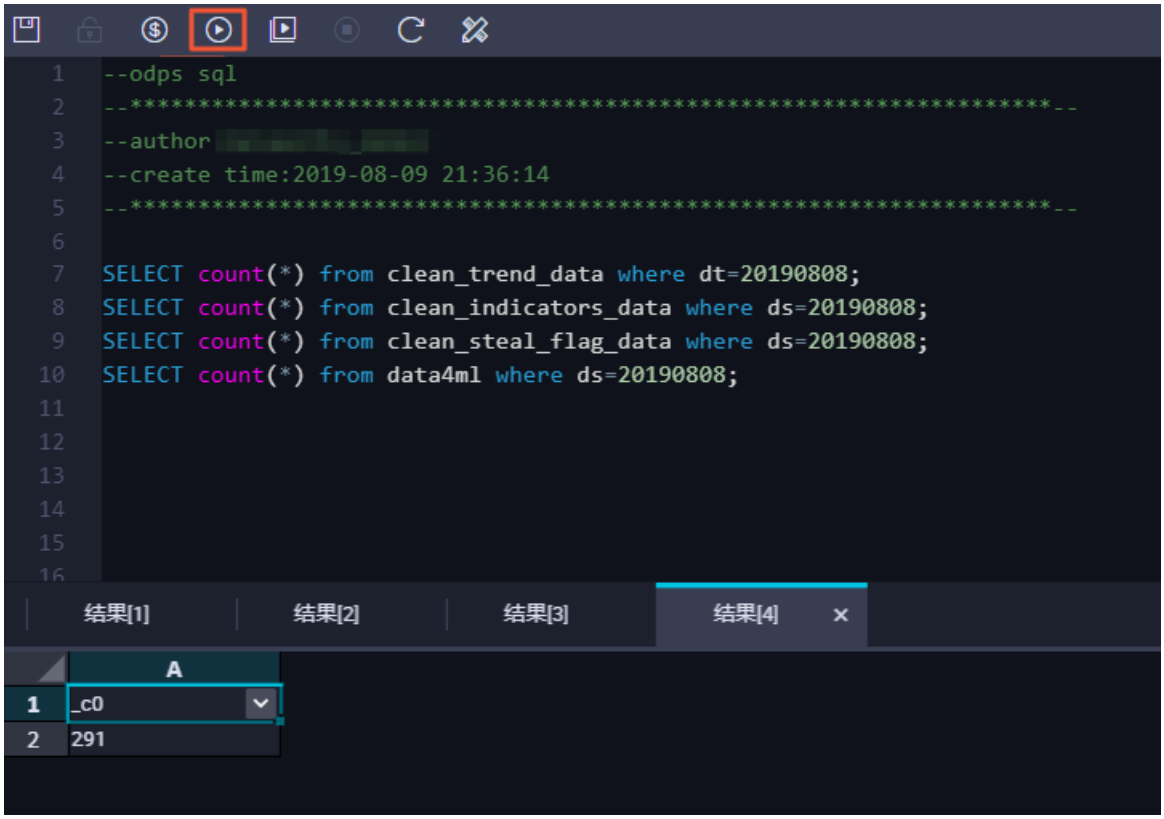

SQL语句如下所示，其中分区列需要更新为业务日期。例如，任务运行的日期为20190809，则业务日期为20190808。

```
--查看是否成功写入MaxCompute
SELECT count(*) from clean_trend_data where dt=业务日期;
SELECT count(*) from clean_indicators_data where ds=业务日期;
SELECT count(*) from clean_steal_flag_data where ds=业务日期;
SELECT count(*) from data4ml where ds=业务日期;
```

发布业务流程

提交业务流程后，表示任务已进入开发环境。由于开发环境的任务不会自动调度，您需要将配置完成的任务发布至生产环境。

> **说明** 将任务发布至生产环境前，您需要对代码进行测试，确保其正确性。

1. 打开业务流程配置面板，单击工具栏中的图标。
2. 在**创建发布包**页面，选中待发布的任务，单击**添加到待发布**。

3. 进入右上角的**待发布列表**，单击**全部打包发布**。

4. 在**发布包列表**页面查看已发布的内容。

在生产环境运行任务

1. 任务发布成功后，单击右上角的**运维中心**。
2. 选择**周期任务运维 > 周期任务**中的相应节点。

3. 右键单击DAG图中的start节点，选择**补数据 > 当前节点及下游节点**。

4. 选中需要补数据的任务，**并选择业务日期**。

5. 单击**确定**
6. 在**补数据实例**页面，单击**刷新**，直至SQL任务都运行成功即可。

后续步骤

现在，您已经学习了如何创建SQL任务、如何处理原始数据。您可以继续下一个教程，学习如何通过机器学习，载入处理好的数据并构建窃漏电用户的识别模型。

4.5. 数据建模

本文将为您介绍如何载入DataWorks中处理好的数据到机器学习中，构建窃漏电用户的识别模型。

前提条件

开始本文的操作前，请首先完成加工数据中的操作。

新建实验

1. 进入机器学习控制台，单击左侧导航栏中的**Studio-可视化建模**。
2. 单击相应工作空间后的**进入机器学习**。

3. 单击左侧菜单栏中的**实验**，右键单击**我的实验**，选择**新建空白实验**。

4. 填写**新建实验**对话框中的**名称**和**描述**。

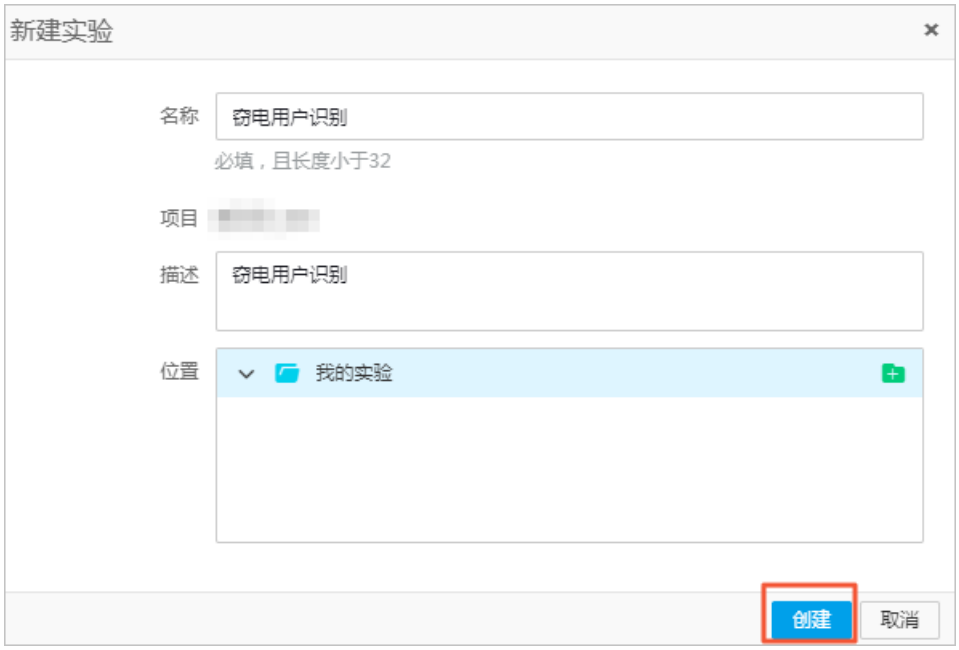

5. 单击**创建**。

载入数据集

1. 单击左侧导航栏中的**数据源**。
2. 在搜索框输入加工数据中最终输出的data4ml表，单击搜索图标。
3. 拖拽**表搜索结果**下的data4ml表至右侧画布。

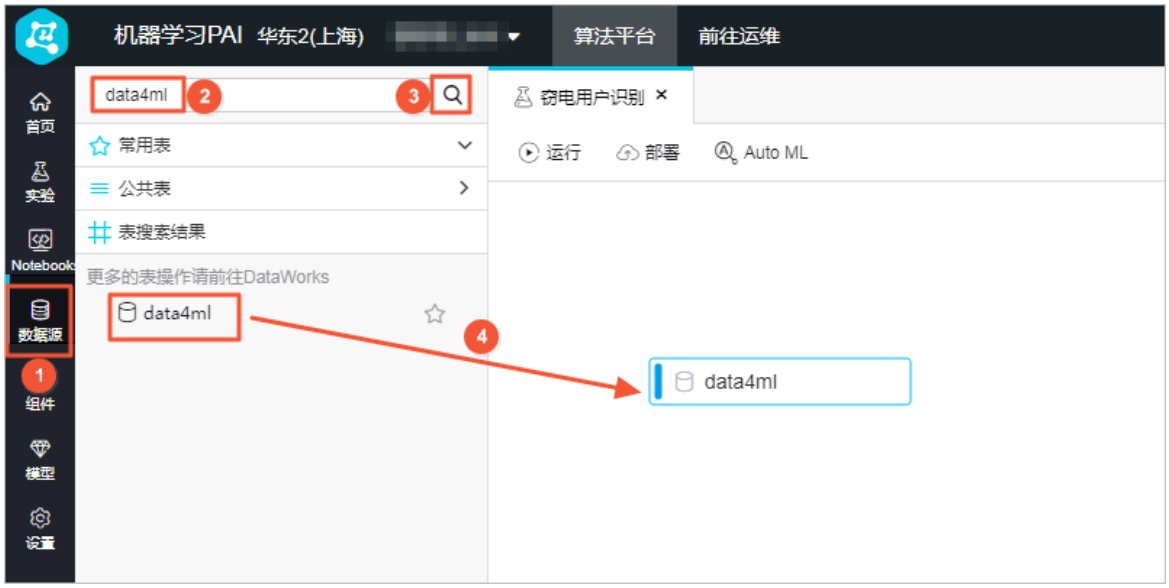

右键单击读数据表，选择**查看数据**，即可查看载入的结果数据。数据包括电量趋势下降指标、线损指标和告警类指标数量等窃电漏电指标，以及用户是否真实窃电漏电的数据。

数据探查 - data4ml - (仅显示前一百条)

序号	uid	trend	xiansun	warnindicator	flag	ds
1	1	4	1	1	1	20190808
2	2	4	0	4	1	20190808
3	3	2	1	1	1	20190808
4	4	9	0	0	0	20190808
5	5	3	1	0	0	20190808
6	6	2	0	0	0	20190808
7	7	5	0	2	1	20190808
8	8	3	1	3	1	20190808
9	9	3	0	0	0	20190808
10	10	4	1	0	0	20190808
11	11	10	1	2	1	20190808
12	12	10	1	3	1	20190808
13	13	2	0	3	0	20190808
14	14	4	0	2	0	20190808
15	15	3	0	0	0	20190808
16	16	0	0	3	0	20190808
17	17	9	0	3	1	20190808

复制 关闭

进行数据探索

1. 相关性分析

   i. 单击左侧导航栏中的**组件**，拖拽**统计分析 > 相关系数矩阵**至右侧画布。

   ii. 连线**读数据表**中ODPS源的输出和**相关系数矩阵**的输入。

   iii. 右键单击**相关系数矩阵**，选择**从此处开始执行**。

iv. 待运行完成后，右键单击**相关系数矩阵**，选择**查看分析报告**。

如相关系数矩阵图所示，3个窃电漏电指标本身和最终是否为窃电用户的关系都不太明显，即用于判断用户是否为窃电用户的特征并不具有单一性。

2. 特征分析

i. 单击左侧导航栏中的**组件**，拖拽**统计分析 > 数据视图**至右侧画布。

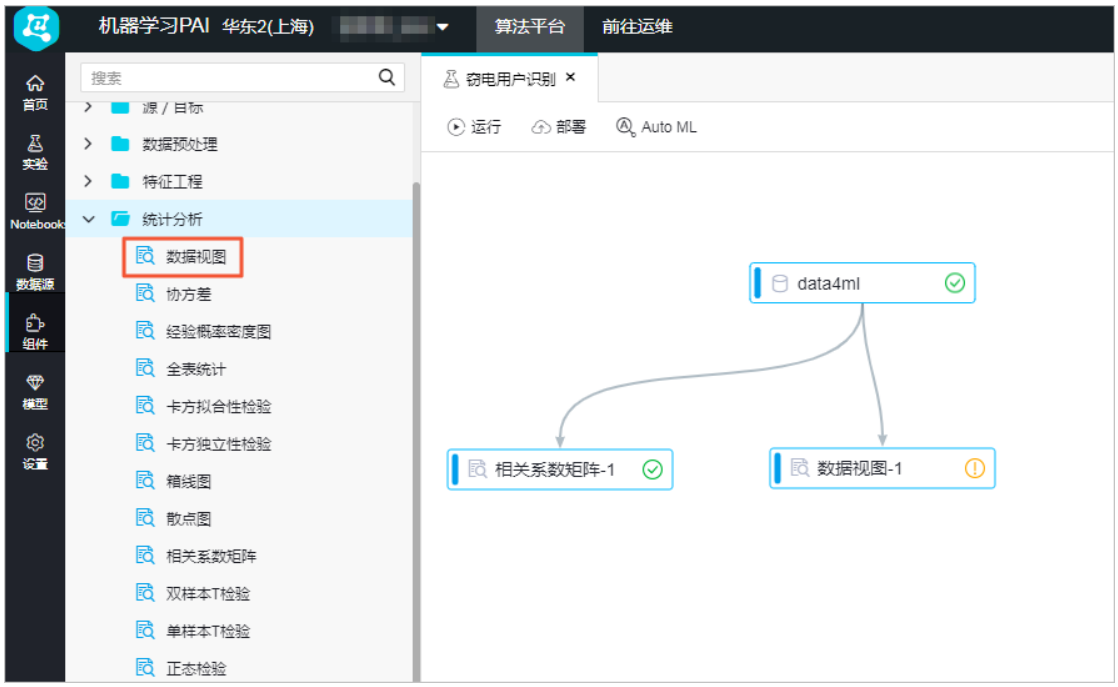

ii. 连线**读数据表**中ODPS源的输出和**数据视图**的输入。

iii. 双击**数据视图**，选择右侧的**字段设置 > 选择特征列**，单击**选择字段**，并**选择目标列**为flag。

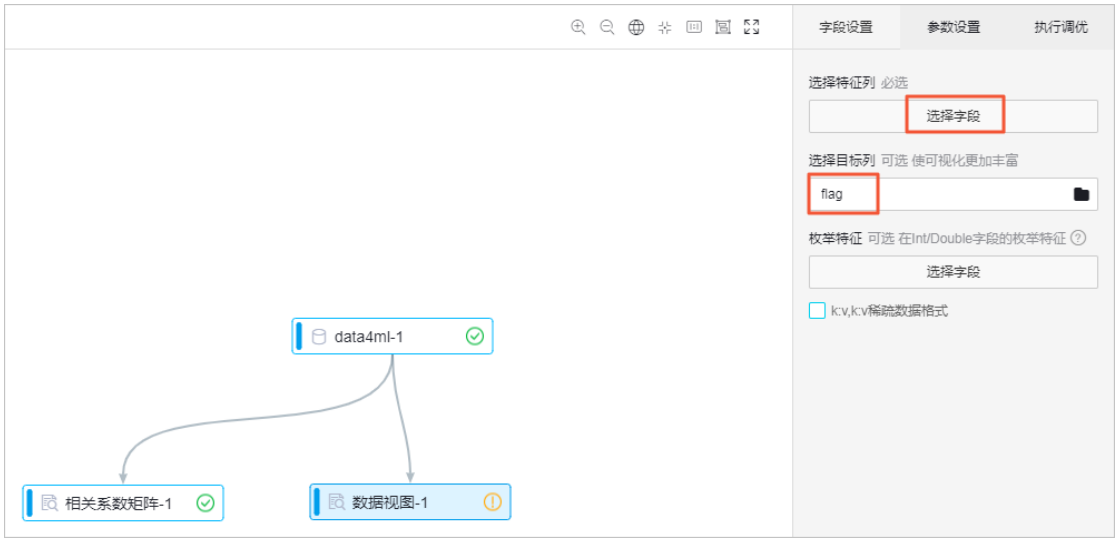

iv. 在**选择字段**对话框中，选择trend、xiansun和warnindicator3个字段，单击**确定**。

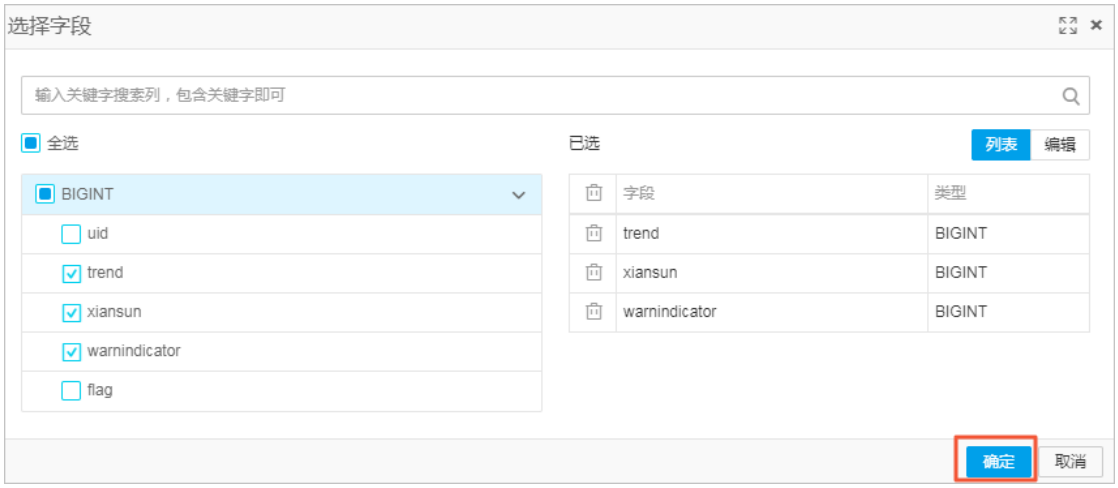

v. 右键单击 **数据视图**，选择**从此处开始执行**。

vi. 执行完成后，选择**查看分析报告**，即可查看各个特征和标签列在数据分布上的关系。

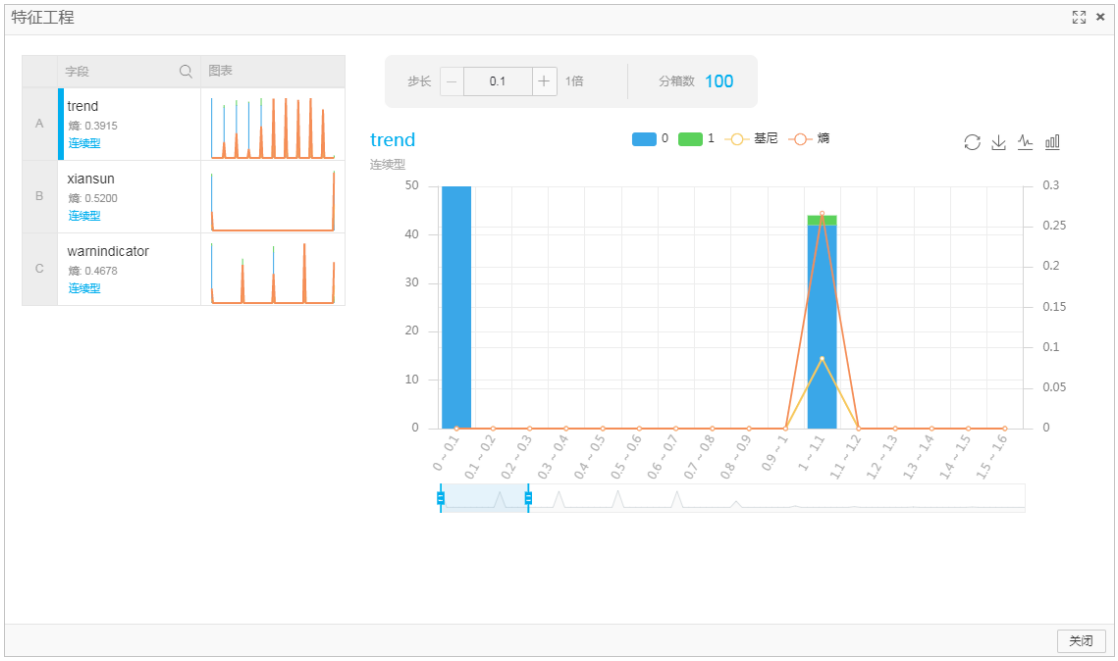

进行数据建模

完成简单的探索性分析之后，即可开始选择合适的算法模型进行数据建模。

1. 通过**拆分**组件，将数据分为训练集和测试集。

   i. 单击左侧导航栏中的**组件**，拖拽**数据预处理 > 拆分**至右侧画布。

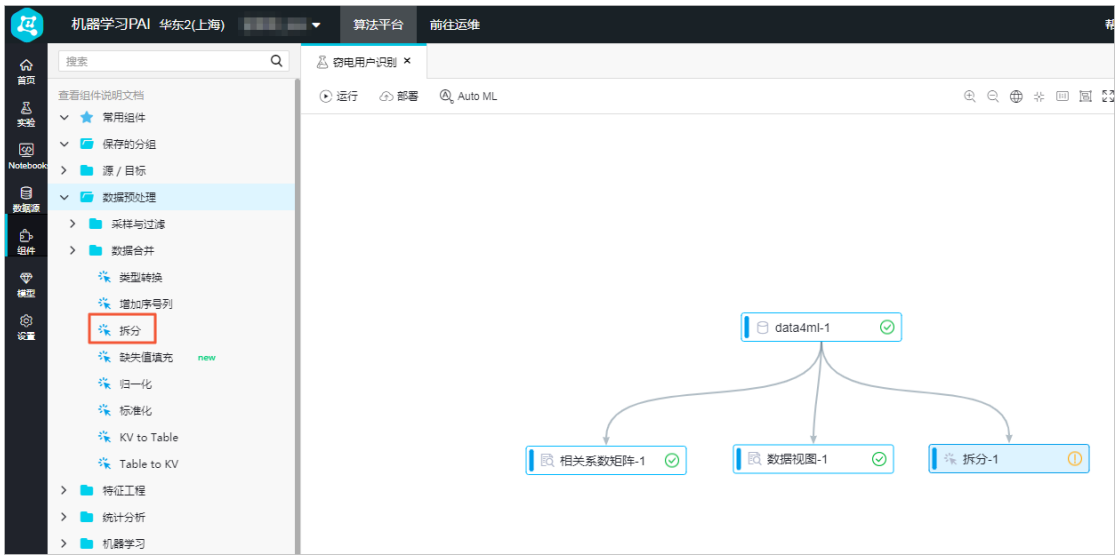

   ii. 连线**读数据表**中ODPS源的输出和**拆分**的输入。

   iii. 右键单击**拆分**，选择**从此处开始执行**。

iv. 待运行完成后，右键单击**拆分**，选择**查看数据 > 查看输出桩**。

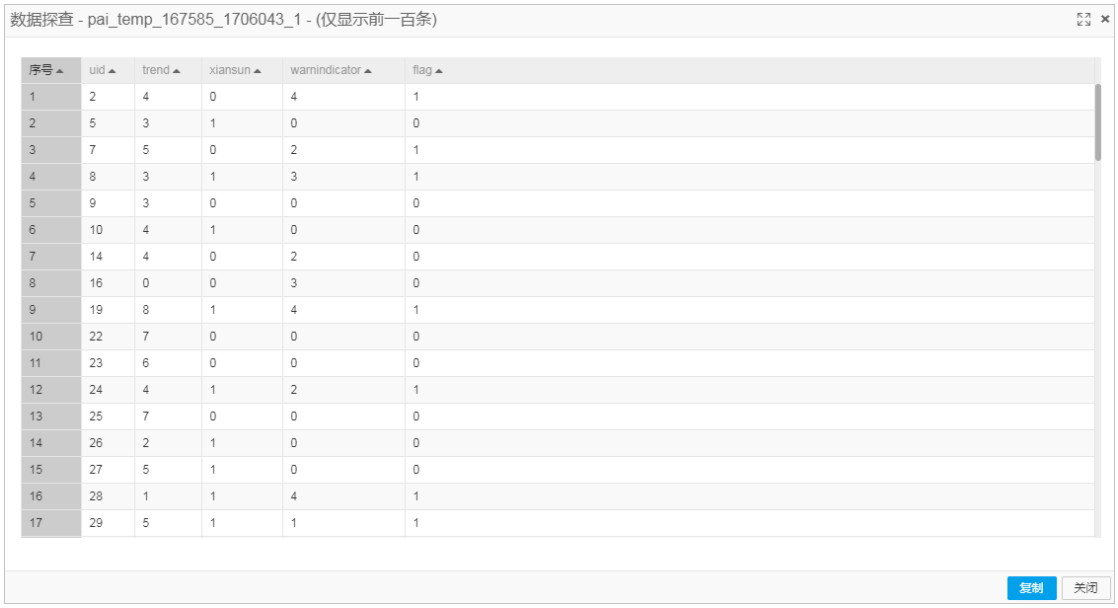

序号	uid	trend	xiansun	warnindicator	flag
1	2	4	0	4	1
2	5	3	1	0	0
3	7	5	0	2	1
4	8	3	1	3	1
5	9	3	0	0	0
6	10	4	1	0	0
7	14	4	0	2	0
8	16	0	0	3	0
9	19	8	1	4	1
10	22	7	0	0	0
11	23	6	0	0	0
12	24	4	1	2	1
13	25	7	0	0	0
14	26	2	1	0	0
15	27	5	1	0	0
16	28	1	1	4	1
17	29	5	1	1	1

2. 通过**逻辑回归二分类**组件，对数据进行回归建模。

i. 单击左侧导航栏中的**组件**，拖拽**机器学习 > 二分类 > 逻辑回归二分类**至右侧画布。

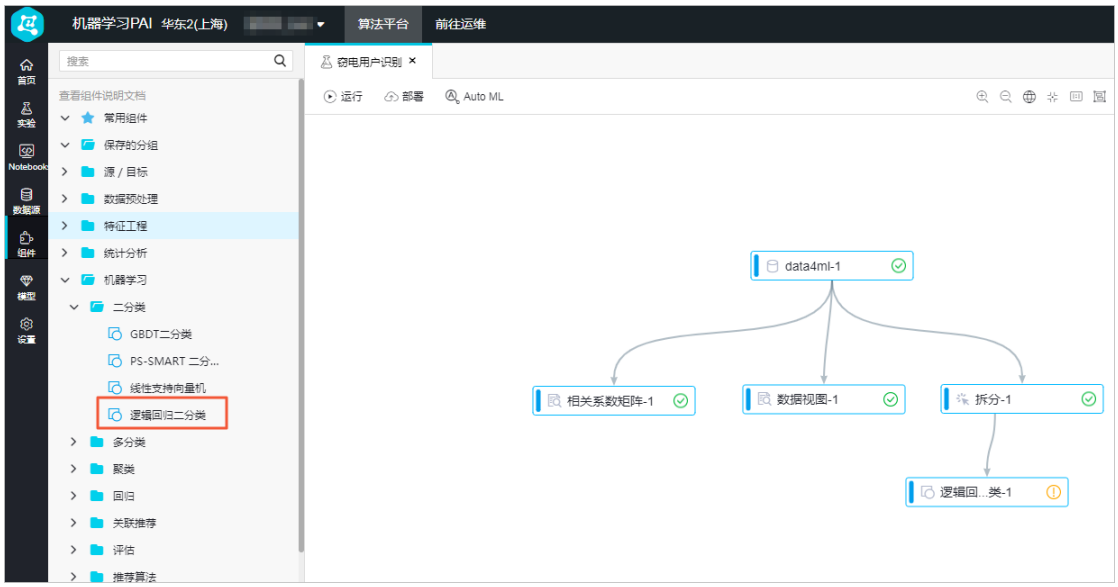

ii. 连线**拆分**中的输出表1和**逻辑回归二分类**的训练表。

iii. 双击**逻辑回归二分类**，选择右侧的**字段设置 > 选择特征列**，单击**选择字段**，并**选择目标列**为flag。

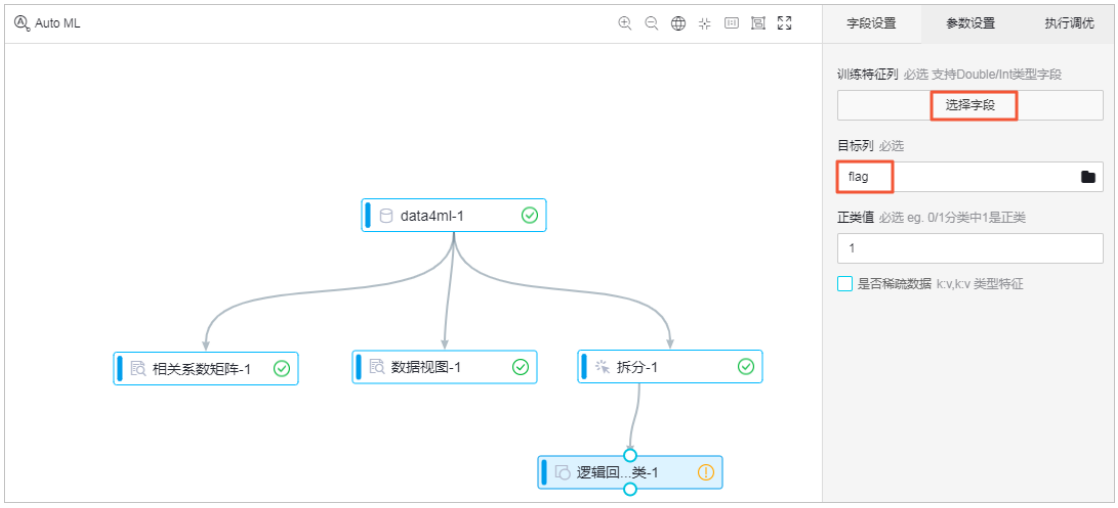

iv. 在**选择字段**对话框中，选择trend、xiansun和warnindicator3个字段，单击**确定**。

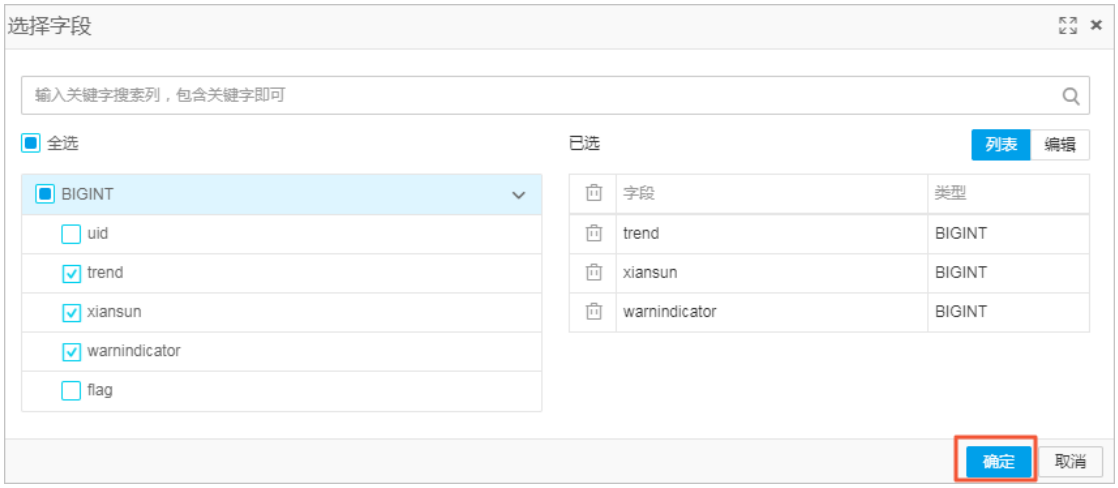

v. 右键单击 **逻辑回归二分类**，选择**从此处开始执行**。

vi. 执行完成后，选择**模型选项 > 查看模型**，即可查看数据模型。

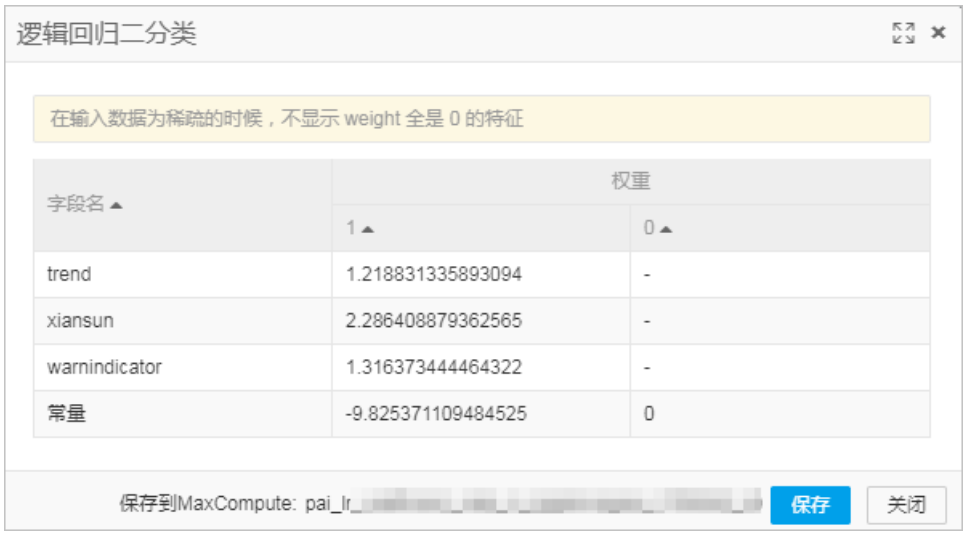

预测和评估回归模型

1. 通过**预测**组件，预测该模型在测试数据集上的效果。
   i. 单击左侧导航栏中的**组件**，拖拽**机器学习 > 预测**至右侧画布。

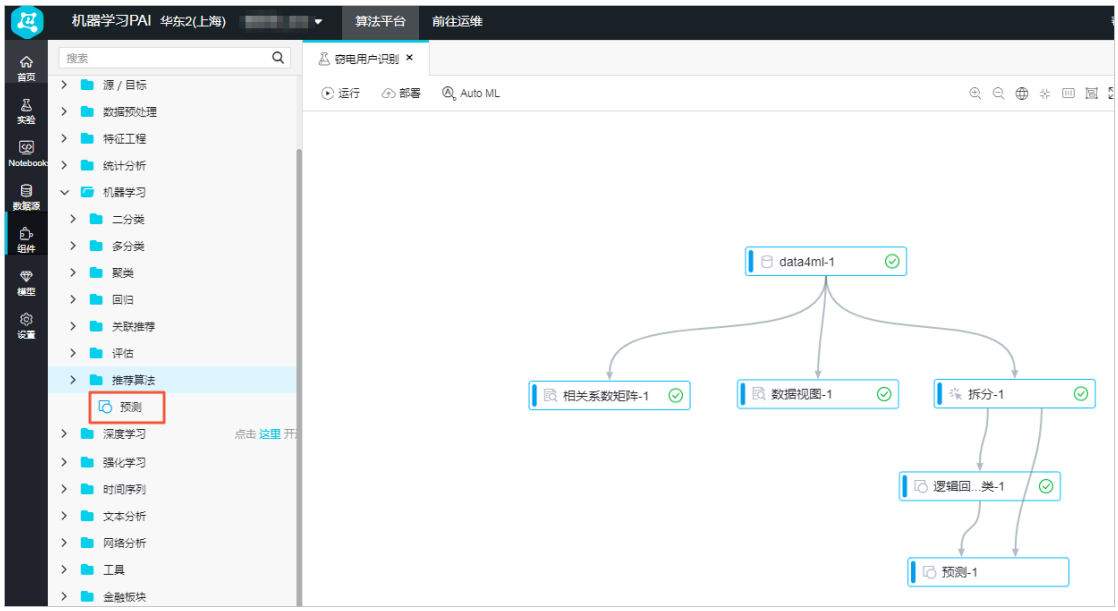

   ii. 连线**逻辑回归二分类**中的逻辑回归模型和**预测**中的模型结果输入。连线**拆分**中的输出表2和**预测**的预测数据输入。

   iii. 双击**预测**，进行右侧的**字段设置**。

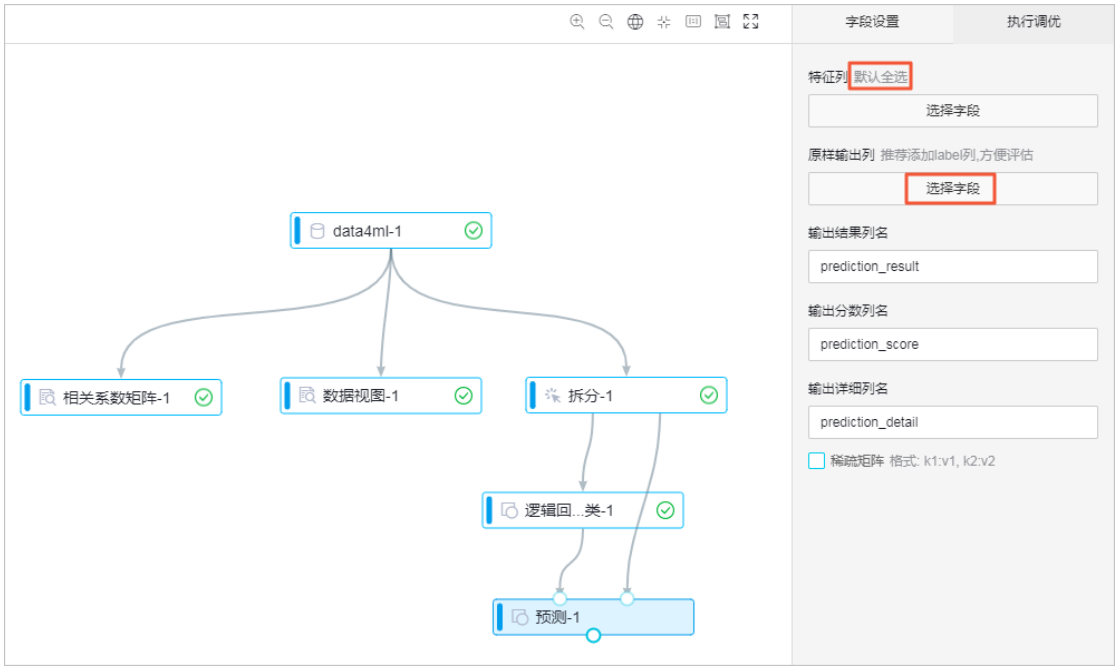

特征列默认全选，单击**原样输出列**下的**选择字段**。

iv. 在**选择字段**对话框中，全选5个字段，单击**确定**。

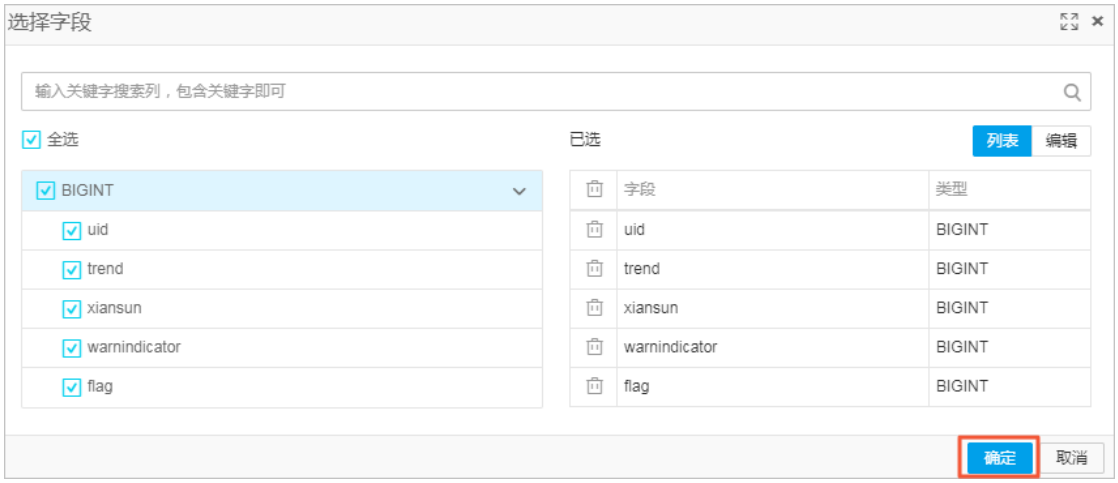

v. 右键单击**预测**，选择**从此处开始执行**。

vi. 执行完成后，选择**查看数据**。

2. 通过**二分类评估**组件，获取模型效果。

i. 单击左侧导航栏中的**组件**，拖拽**机器学习 > 评估 > 二分类评估**至右侧画布。

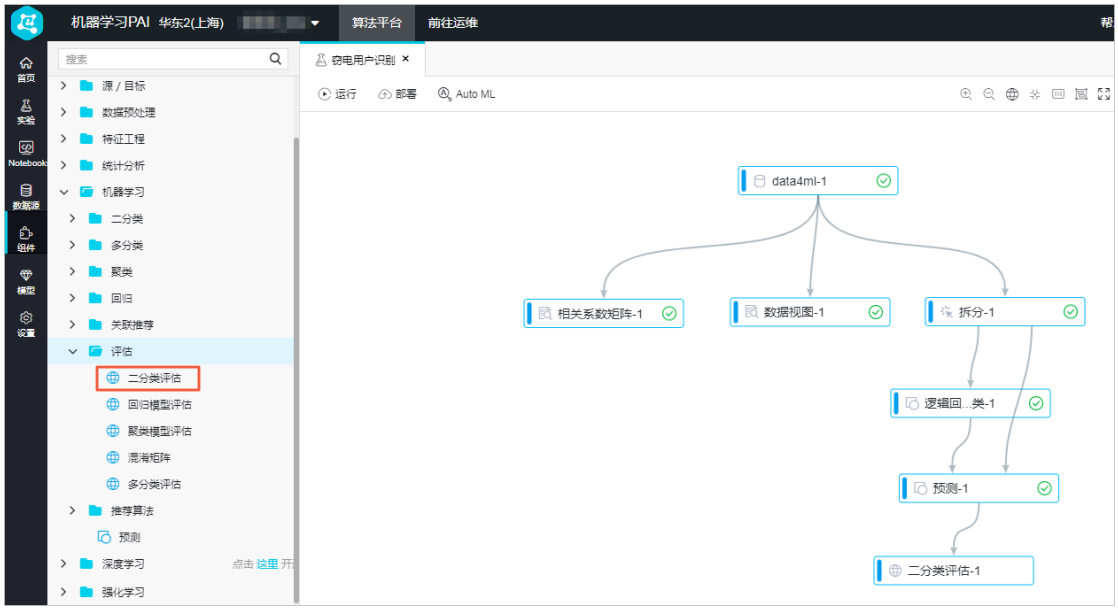

ii. 连线**预测**中的预测结果输出和**二分类评估**中的输入。

iii. 双击**二分类评估**，选择右侧的**字段设置 > 原始标签列列名**为flag。

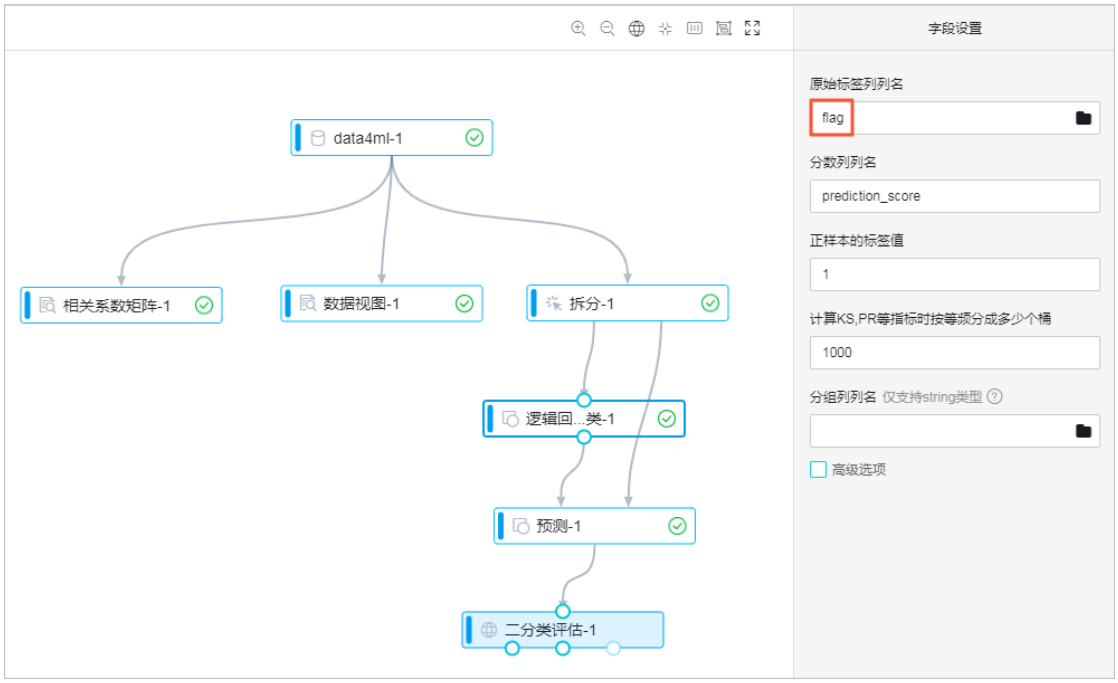

iv. 右键单击**二分类评估**，选择**从此处开始执行**。

v. 执行完成后，选择**查看评估报告**，即可查看模型效果。

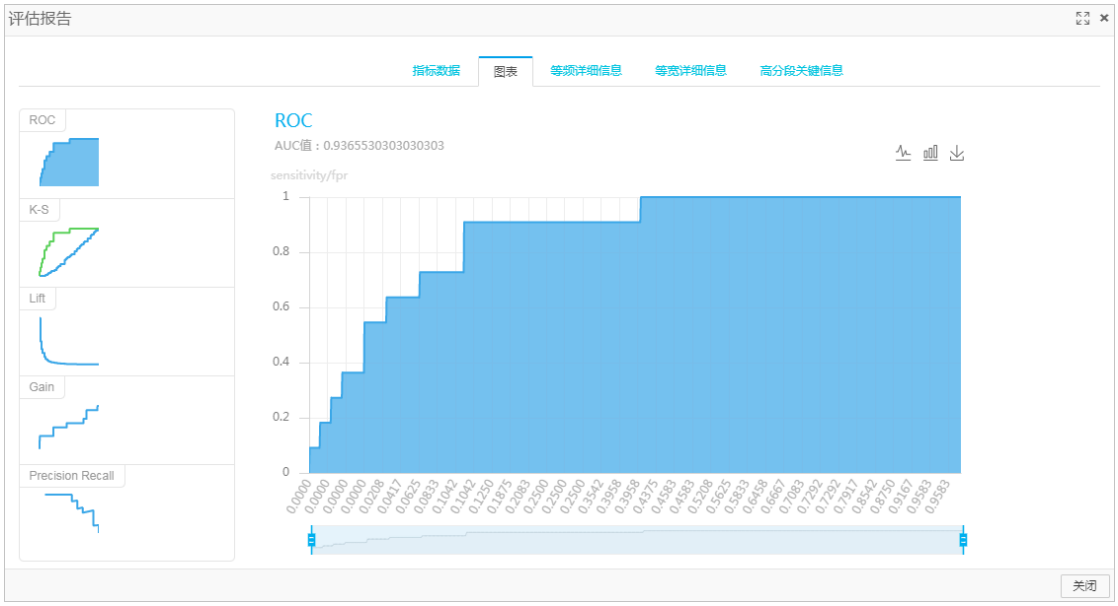

后续步骤

至此，您已通过机器学习PAI完成了用户窃电行为的识别。您还可以通过EAS在线部署，将该服务部署为可在线调用的服务，提供用户窃电行为的在线识别服务。

5.对接使用CDH

DataWorks 提供了与CDH（Cloudera's Distribution Including Apache Hadoop，以下简称CDH) 集群对接的能力，在保留继续使用CDH集群作为存储和计算引擎的前提下，您可以使用DataWorks的任务开发、调度、数据地图（元数据管理）和数据质量等一系列的数据开发和治理功能。本文为您介绍如何对接使用CDH。

前提条件

- 已部署CDH。

  支持非阿里云ECS环境部署的CDH，但需要确保部署CDH集群的ECS和阿里云网络可达。通常您可以使用高速通道、VPN等网络连通方案，来保障网络可达。

- 已开通DataWorks服务并创建好对接使用CDH的工作空间。

  > **说明** 对接使用CDH的工作空间无需绑定计算引擎，在创建工作空间时可跳过选择引擎步骤，其他步骤的操作详情可参见创建工作空间。

- 拥有一个有工作空间的管理员权限的账号，在DataWorks中新增CDH引擎配置的操作仅空间管理员可操作。为账号授权空间管理员权限的操作可参见。成员及角色管理
- 已购买并创建DataWorks的独享调度资源组。详情可参见独享资源组模式。

在DataWorks中对接使用CDH引擎时，主要配置流程为：

1. Step1：获取CDH集群配置信息
2. Step2：配置网络联通
3. Step3：在DataWorks中新增CDH集群配置

对接配置完成后，您可在DataWorks上开发CDH引擎的数据开发任务并运行，并在运行后通过DataWorks的运维中心查看任务运行情况。详情可参见使用DataWorks进行数据开发和运维监控配置。

同时您可使用DataWorks的数据质量、数据地图功能，进行数据和任务管理。详情可参见数据质量规则配置和数据地图配置。

使用限制

- 在DataWorks中使用CDH相关功能，必须使用DataWorks的独享调度资源组。
- 您需要先保障CDH集群和独享调度资源组的网络可达后再进行后续的相关操作。
- 目前DataWorks支持的CDH版本有：cdh6.1.1、cdh5.16.2、cdh6.2.1和cdh6.3.2。

Step1：获取CDH集群配置信息

1. 获取CDH版本信息，用于后续DataWorks中新增CDH引擎配置。

   登录Cloudera Manager，在主界面集群名称旁可查看当前部署的CDH集群版本，如下图所示。

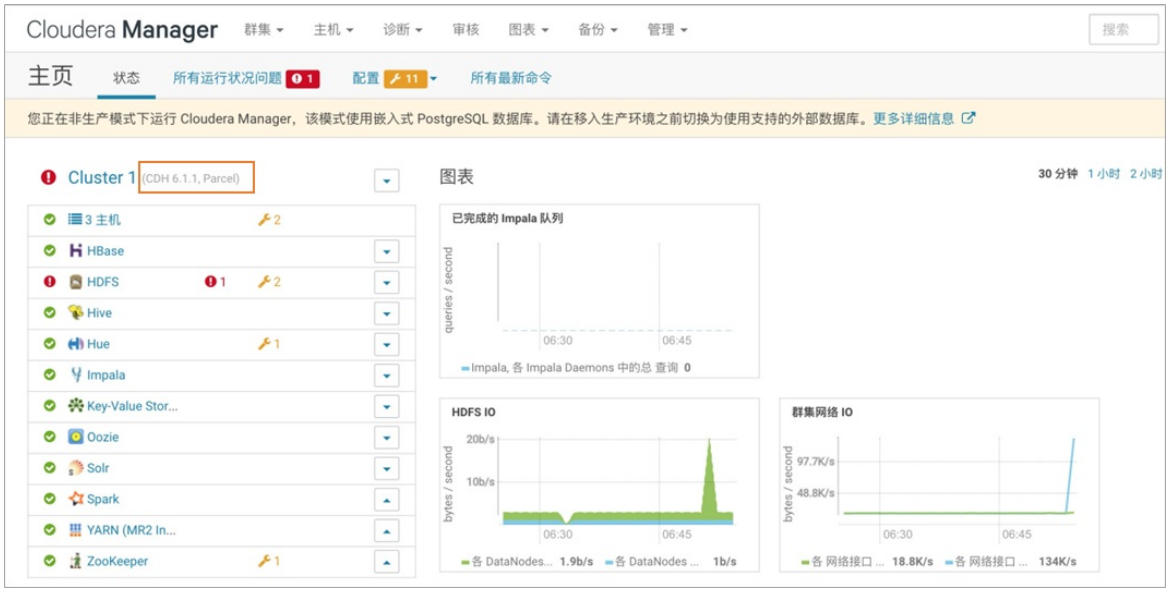

2. 获取Host地址与组件地址信息，用于后续DataWorks中新增CDH引擎配置。
   - 方式一：使用DataWorks JAR包工具获取。
     a. 登录Cloudera Manager，下载工具JAR包。

     ```
     wget https://dataworks-public-tools.oss-cn-shanghai.aliyuncs.com/dw-tools.jar
     ```

     b. 运行工具JAR包。

     ```
     export PATH=$PATH:/usr/java/jdk1.8.0_181-cloudera/bin
     java -jar dw-tools.jar <user> <password>
     ```

     其中 `<user>` 和 `<password>` 分别是Cloudera Manager的用户名和密码。

     c. 在运行结果中查看并记录CDH的Host地址和组件地址信息。

     ```
     [root@cdh-header-1-cn-shanghai ~]# wget https://dataworks-public-tools.oss-cn-shanghai.aliyuncs.com/dw-tools.jar
     --2021-01-08 18:52:55--  https://dataworks-public-tools.oss-cn-shanghai.aliyuncs.com/dw-tools.jar
     Resolving dataworks-public-tools.oss-cn-shanghai.aliyuncs.com (dataworks-public-tools.oss-cn-shanghai.aliyuncs.com)... 106.14.228.176
     Connecting to dataworks-public-tools.oss-cn-shanghai.aliyuncs.com (dataworks-public-tools.oss-cn-shanghai.aliyuncs.com)|106.14.228.176|:443...
     connected.
     HTTP request sent, awaiting response... 200 OK
     Length: 6743456 (6.4M) [application/java-archive]
     Saving to: 'dw-tools.jar.1'

     100%[==========================================================================================>] 6,743,456   36.0MB/s   in 0.2s

     2021-01-08 18:52:55 (36.0 MB/s) - 'dw-tools.jar.1' saved [6743456/6743456]

     [root@cdh-header-1-cn-shanghai ~]# export PATH=$PATH:/usr/java/jdk1.8.0_181-cloudera/bin
     [root@cdh-header-1-cn-shanghai ~]# java -jar dw-tools.jar admin admin
     Hosts:
     192.168.22.217  cdh-header-1-cn-shanghai
     192.168.22.219  cdh-worker-2-cn-shanghai
     192.168.22.218  cdh-worker-1-cn-shanghai

     Urls:
     HiveServer2:    jdbc:hive2://cdh-header-1-cn-shanghai:10000
     Hive Metastore: thrift://cdh-header-1-cn-shanghai:9083
     YARN ResourceManager:   http://cdh-header-1-cn-shanghai:8032
     Impala Daemon:  jdbc:impala://cdh-worker-1-cn-shanghai:21050
     ```

   - 方式二：在Cloudera Manager页面手动查看。

登录Cloudera Manager，在主机（Hosts）下拉菜单中选择角色（Roles），根据关键字和图标识别出需要配置的服务，然后看左侧对应的主机（Host），按照格式补全要填写的地址。默认端口号可以参考方法一的输出结果样例。

其中

- HS2：HiveServer2
- HMS：Hive Metastore
- ID：Impala Daemon
- RM：YARN ResourceManager

3. 获取配置文件，用于后续上传至DataWorks。
   i. 登录Cloudera Manager。
   ii. 在**状态**页面，单击集群的下拉菜单中的**查看客户端配置 URL**。

iii. 在对话框中下载YARN的配置包。

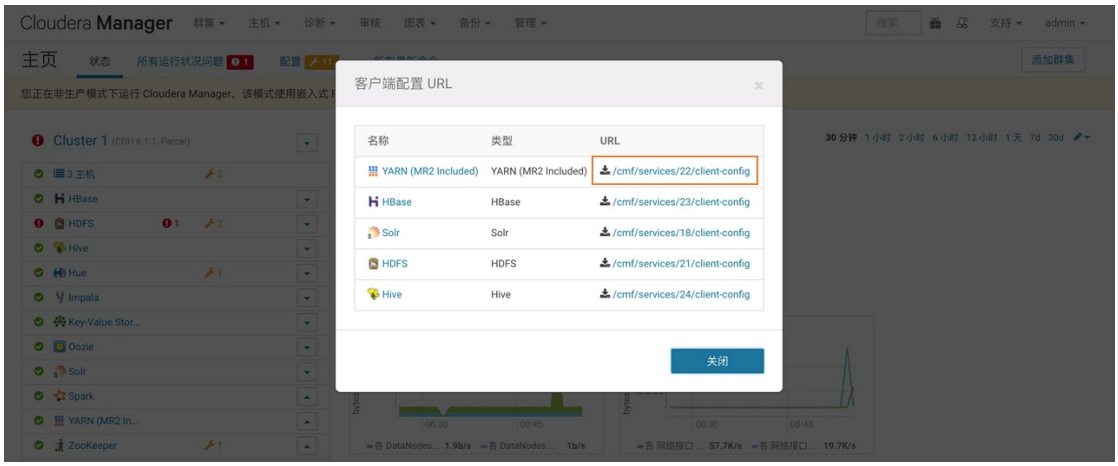

4. 获取CDH集群的网络信息，用于后续与DataWorks的独享调度资源组网络联通配置。

i. 登录部署CDH集群的ECS控制台。

ii. 在实例列表中找到部署CDH集群的ECS实例，在**实例详情**中查看并记录**安全组**、**专有网络**、**虚拟交换机**信息。

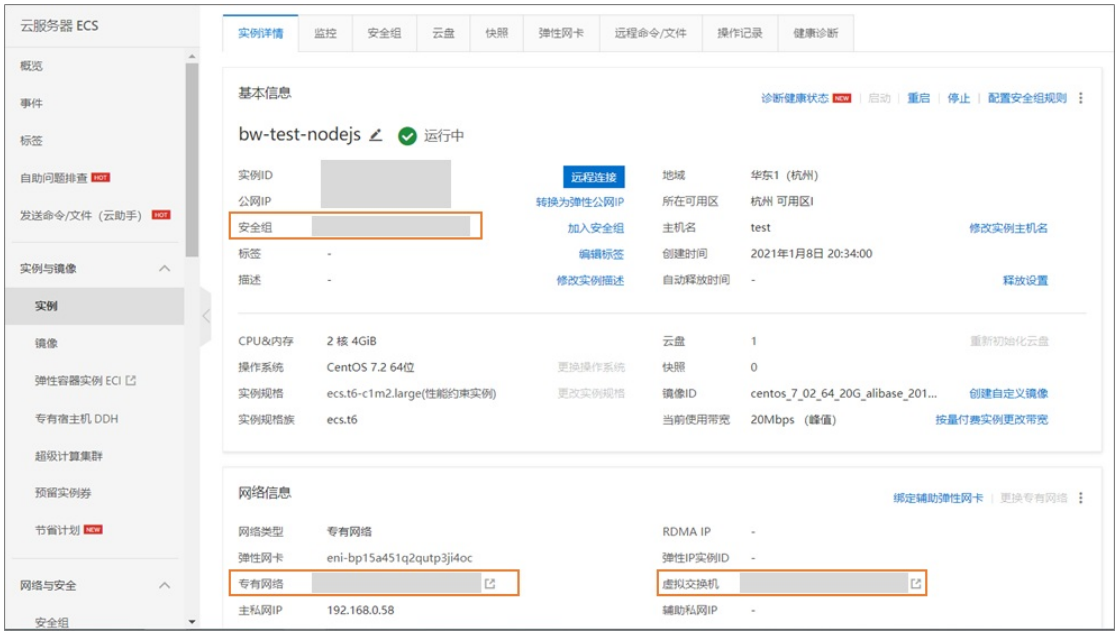

Step2：配置网络联通

DataWorks的独享调度资源组购买创建完成后，默认与其他云产品网络不可达，在对接使用CDH时，您需获取部署CDH集群的网络信息，将独享调度资源组绑定至CDH集群所在的VPC网络中，保障CDH集群与独享调度资源组的网络联通。

1. 进入独享资源组网络配置页面。

i. 登录DataWorks控制台。

ii. 在左侧导航栏，单击**资源组列表**，默认进入**独享资源组**页签。

iii. 单击已购买的独享调度资源组后的**网络设置**。

2. 绑定VPC。

在**专有网络绑定**页签，单击**新增绑定**，在配置页面选择上述步骤记录的CDH集群所在VPC、交换机、安

全组。

3. 配置Host。

   在**Host配置**页签，单击**批量修改**，在对话框中配置为上述步骤中记录的Host地址信息。

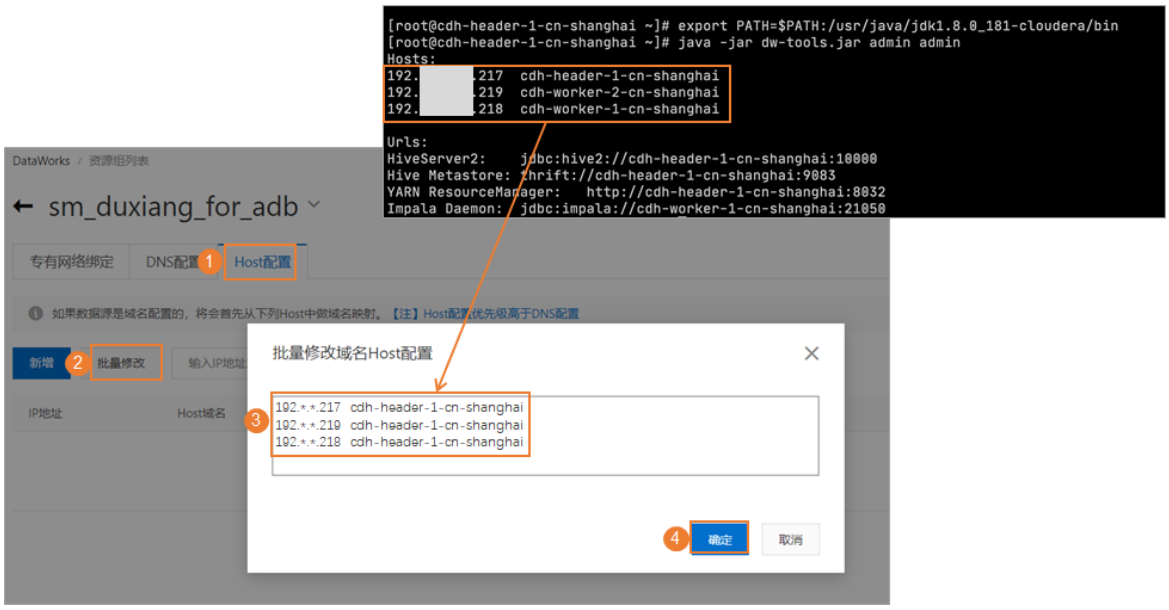

Step3：在DataWorks中新增CDH集群配置

只有工作空间管理员才能进行新增CDH集群配置操作，操作时请使用拥有空间管理员权限的账号。

1. 进入项目空间管理页面。
   i.
   ii. 在左侧导航栏，单击**工作空间列表**。
   iii. 在对应工作空间的操作列单击**工作空间配置**。
   iv. 在右侧配置页面中单击**更多设置**。
2. 在项目空间管理页面，单击**CDH 集群配置**。

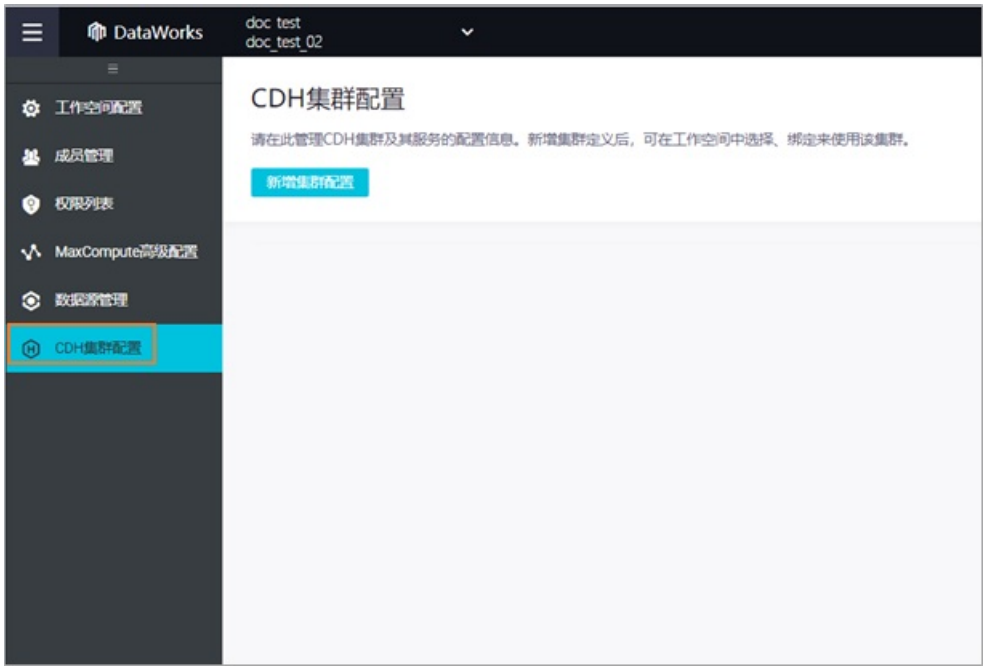

3. 在**CDH集群配置**页面单击**立即新增**，在**新增CDH集群配置**对话框中，填写上述步骤Step2：配置网络联通中记录的组件地址信息。

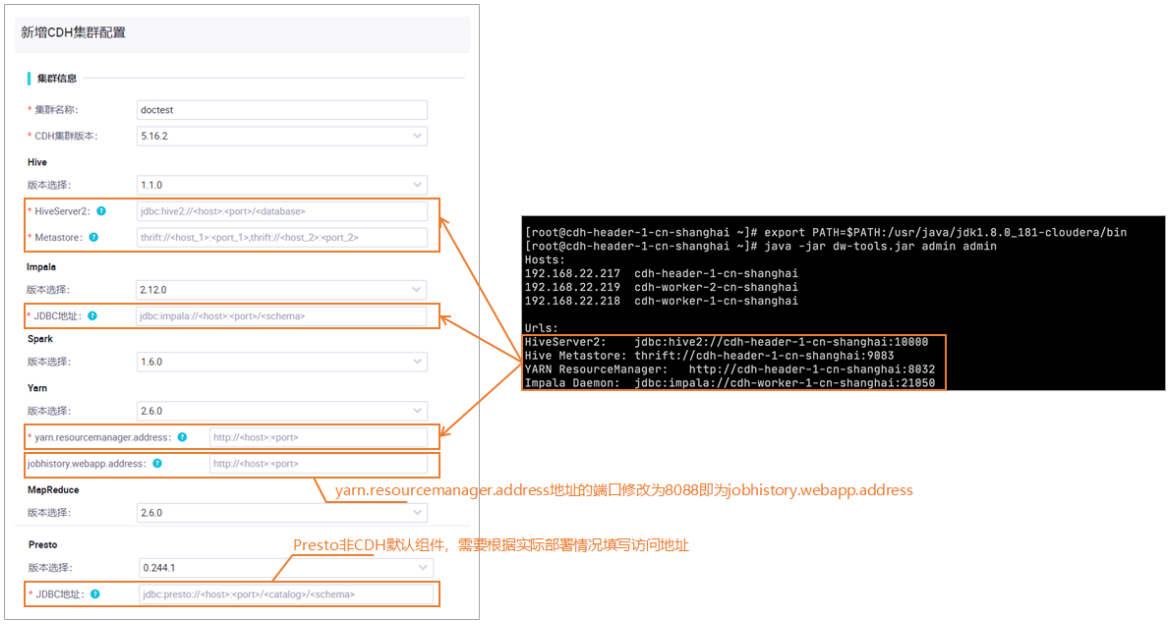

其中：

- 集群名称：可自定义集群名称。
- 版本信息：根据实际情况选择对应的CDH和组件版本。
- 地址信息：根据上述步骤中记录的地址信息填写。其中：
  - Yarn的**jobhistory.webapp.address**信息：**yarn.resourcemanager.address**地址的端口修改为8088即为**jobhistory.webapp.address**。
  - Presto的**JDBC地址**：Presto非CDH默认组件，需要根据实际部署情况填写访问地址。

4. 上传配置文件并授权给其他工作空间。

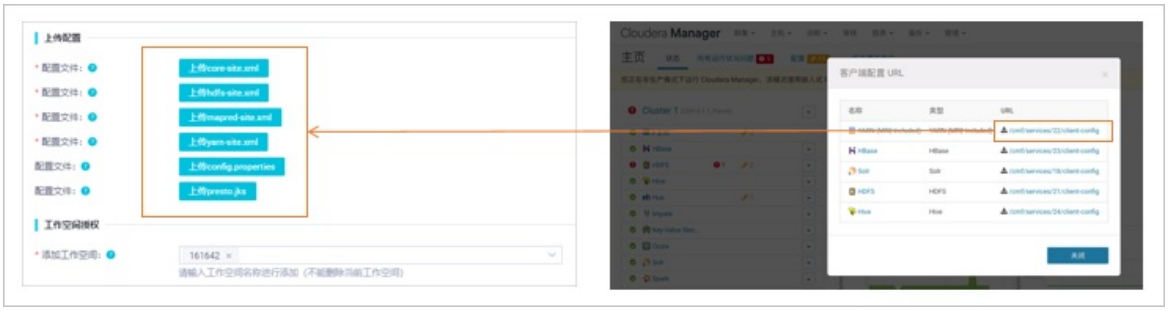

5. 配置访问身份的映射关系。

   如果您希望在运行任务时，对不同云账号在CDH集群内可访问的数据进行数据权限隔离，则可开启**Kerberos账号（principal）认证**，并配置**云账号**与**Kerberos账号**的权限映射关系。

   > **说明** **Kerberos账号**为CDH集群的访问账号。CDH集群通过Sentry或Ranger组件为**Kerberos账号**进行不同权限的配置，实现数据权限隔离。与**Kerberos账号**存在映射关系的**云账号**拥有相同的CDH集群数据访问权限。请填写格式为 `实例名@领域名` 的Kerberos账号（principal），例如，cdn_test@HADOOP.COM。

6. 单击**确定**，完成新增CDH集群配置。

   完成新增CDH集群配置后，已授权的工作空间中可新增此CDH引擎，用于后续编辑并运行数据开发等任务。

Step4：在DataWorks中新增CDH引擎

1. 在项目空间管理页面，单击**工作空间配置**。
2. 在**计算引擎信息**区域的CDH页签单击**增加实例**，在弹窗中配置实例信息。

   新增引擎实例时，可选择使用**快捷模式**或**安全模式**访问模式，**安全模式**可以实现不同云账号运行任务时的数据权限隔离。不同访问模式的配置界面如下：

   - **快捷模式**的实例信息配置。

- **安全模式**的实例信息配置。

i. 填写**实例显示名称**。

ii. 选择**访问模式**

- **快捷模式**

  该访问模式使用便捷，多个云账号对应一个集群账号，多个账号均可访问同一个集群账号内的数据，无法实现不同云账号运行任务时的数据权限隔离。

- **安全模式**

  该访问模式允许您配置云账号与CDH集群账号的身份映射关系，实现不同云账号运行任务时的数据权限隔离。

iii. 选择上述新增的CDH集群配置。

如果上一步**访问模式**选择**快捷模式**，则此处选择未开启Kerberos认证的CDH集群。如果**访问模式**选择**安全模式**，则此处需要选择已开启Kerberos认证的CDH集群。您可以进入工作空间配置查看CDH集群是否开启Kerberos认证。

iv. 设置访问集群的认证信息。

- **快捷模式**

  当前仅支持指定特定账号，建议使用admin或hadoop账号。该账号仅用于下发任务。

- **安全模式**

  您可以根据需求选择**调度访问身份**。该身份用于在任务提交调度后自动调度运行任务，并且需要配置云账号与CDH集群账号的身份映射，详情请参见配置访问身份映射。

  > **说明** 在DataStudio页面，运行任务所使用的身份均为当前已登录云账号映射的集群访问身份。因此，除了需要为调度访问身份配置身份映射外，建议为项目空间开发成员也配置身份映射，避免页面运行任务失败。

v. 选择已经购买好的独享调度资源组。

vi. 单击**测试连通性**。

如果网络连通测试失败，可能是因为独享调度资源组没有绑定CDH集群所在的专有网络，或者独享调度资源组没有设置Host，请参见Step2：配置网络联通检查独享调度资源组的网络配置。

3. 单击**确定**，创建计算引擎实例。

此步骤会触发独享调度资源组的初始化（安装访问CDH集群的客户端以及上传配置文件），您需要等待**独享资源组初始化状态** 从**准备中**变成**完成**，CDH引擎实例才创建完成。

4. 在创建的CDH引擎实例页面单击**测试服务连通性**，DataWorks会运行测试任务测试客户端和配置文件是否正确安装。

如果测试结果显示失败，您可以查看日志并提交工单联系DataWorks技术支持。

使用DataWorks进行数据开发

完成新增CDH引擎后，您就可以在DataStudio（数据开发）中创建Hive、Spark、MapReduce、Impala或者Presto任务节点，直接运行任务或者设置周期调度运行任务。以下以创建并运行一个Hive任务为例，为您介绍在DataWorks中如何进行CDH引擎的数据开发和运行。

1. 进入DataStudio页面。

   i.

   ii. 在左侧导航栏，单击**工作空间列表**。

   iii. 在对应工作空间的操作列单击**进入数据开发**。

2. 创建业务流程，根据界面提示填写业务流程信息。

3. 单击创建好的业务流程，在**CDH引擎**文件夹上右键选择**新建 > CDH Hive**。

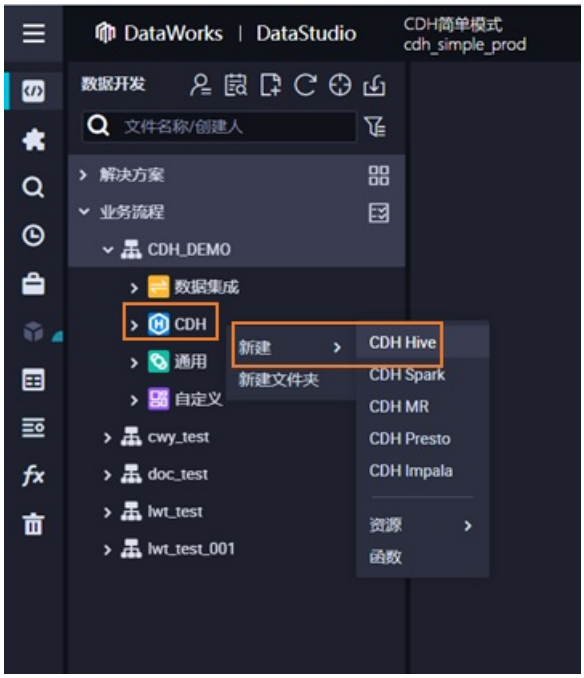

4. 在右侧代码编辑框中编写Hive SQL，完成代码编辑后单击顶部运行图标，选择调度资源组并确认，运行完毕后可以查看Hive SQL的运行结果。
5. 如果想要设置任务周期调度，单击右侧的**调度配置**，在弹窗中设置时间属性、资源属性和调度依赖，完成后单击提交任务，提交成功后任务就可以按照配置周期调度运行，调度配置详情可参见 配置基础属性。
6. 在运维中心中可以查看提交的周期任务，在周期实例中查看任务周期调度的运行情况。详细可参见查看周期任务。

运维监控配置

CDH引擎的任务支持使用DataWorks运维中心的智能监控功能，通过自定义报警规则、配置任务告警，根据设置的报警规则自动触发任务运行异常报警。自定义报警规则操作可参见自定义规则，配置任务告警操作可参见基线管理。

数据质量规则配置

在DataWorks上使用CDH引擎时，可使用DataWorks的数据质量服务进行数据查、对比、质量监控、SQL扫描和智能报警等功能，数据质量服务的详细操作可参见数据质量概述。

数据地图配置

在DataWorks上使用CDH引擎时，可使用DataWorks的数据地图服务采集CDH集群中Hive数据库、表、字段、分区元数据，便于实现全局数据检索、元数据详情查看、数据预览、数据血缘和数据类目管理等功能。

> **说明** 当前仅支持Hive数据库。

DataWorks上数据地图功能的详细介绍与配置指导可参见概述。

如果要您希望可以实时感知CDH集群中Hive元数据的变更，或者要在数据地图中查看血缘和元数据变更记录，需要将DataWorks的Hive Hook 嵌入到目标集群，并通过阿里云日志服务采集Hive Hook产生的日志。

配置Hive Hook后，元数据变更消息会被记录到HS2和HMS服务器的日志文件*/tmp/hive/hook.event.*.log*中，使用阿里云日志服务采集后供DataWorks读取，下载DataWorks小工具 `dw-tools.jar` ，在同一目录下创建 `config.json` 文件并补全配置项的值，最后执行工具一键创建日志采集。

配置Hive Hook和采集Hive Hook日志的操作步骤如下。

1. 配置Hive Hook。
   i. 登录HS2和HMS服务器，并进入*/var/lib/hive*目录，下载DataWorks Hive Hook。

```
# CDH 6.x 版本下载 dataworks-hive-hook-2.1.1.jar
wget https://dataworks-public-tools.oss-cn-shanghai.aliyuncs.com/dataworks-hive-hook-2.1.1.jar
# CDH 5.x 版本下载 dataworks-hive-hook-1.1.0-cdh5.16.2.jar
wget https://dataworks-public-tools.oss-cn-shanghai.aliyuncs.com/dataworks-hive-hook-1.1.0-cdh5.16.2.jar
```

   ii. 登录Cloudera Manager首页后，进入**Hive > 配置** ，把Hive辅助JAR目录配置项设置为 `/var/lib/hive` 。
   iii. 在**Hive > 配置** 中，将 `hive-site.xml` 的Hive服务高级配置代码段（安全阀） 配置项添加以下内容。

```
<property>
  <name>hive.exec.post.hooks</name>
  <value>com.cloudera.navigator.audit.hive.HiveExecHookContext,org.apache.hadoop.hive.ql.hooks.LineageLogger,com.aliyun.dataworks.meta.hive.hook.LineageLoggerHook</value>
</property>
```

   iv. 在**Hive > 配置** 中，将 `hive-site.xml` 的Hive Metastore Server高级配置代码段（安全阀） 配置项添加以下内容。

```
<property>
  <name>hive.metastore.event.listeners</name>
  <value>com.aliyun.dataworks.meta.hive.listener.MetaStoreListener</value>
</property>
<property>
  <name>hive.metastore.pre.event.listeners</name>
  <value>com.aliyun.dataworks.meta.hive.listener.MetaStorePreAuditListener</value>
</property>
```

   v. 配置完成后，根据Cloudera Manager的提示部署客户端配置，然后重启Hive服务。

> **说明** 如果重启失败，保留日志用于排查问题，为防止影响正常作业可以先去掉上面两个步骤添加的配置再重启恢复Hive服务。如果添加配置后重启成功，查看服务器*/tmp/hive/*下是否产生名称以 `hook.event` 开头的日志文件，例如 `hook.event.1608728145871.log` 。

2. 采集Hive Hook日志。
   i. 登录Cloudera Manager，下载工具JAR包。

```
wget https://dataworks-public-tools.oss-cn-shanghai.aliyuncs.com/dw-tools.jar
```

ii. 在小工具所在目录创建 `config.json` ，根据以下文件内容要求修改并保存文件。

```
// config.json
{
    "accessId": "<accessId>",
    "accessKey": "<accessKey>",
    "endpoint": "cn-shanghai-intranet.log.aliyuncs.com",
    "project": "onefall-test-pre",
    "clusterId": "1234",
    "ipList": "192.168.0.1,192.168.0.2,192.168.0.3"
}
```

其中：

- **accessId**：阿里云账号的AccessKey ID。
- **accessKey**：阿里云账号的AccessKey Secret。
- **endpoint**：填写为日志服务project的访问域名中的私网域名，详细可参见服务入口。
- **project**：填写为使用的阿里云日志服务的project名称，您可参见管理Project获取日志服务的project名称。
- **clusterId**：填写为DataWorks生成的CDH集群ID，可以提交工单获取此ID。
- **ipList**：填写为HS2和HMS的所有服务器的IP列表（即部署了DataWorks Hive Hook的所有服务器IP），多个IP使用英文逗号（,）分隔。

iii. 运行配置文件。

```
java -cp dw-tools.jar com.aliyun.dataworks.tools.CreateLogConfig config.json
```

iv. 安装客户端。

```
wget http://logtail-release-cn-shanghai.oss-cn-shanghai.aliyuncs.com/linux64/logtail.sh -O logtail.sh; chmod 755 logtail.sh; ./logtail.sh install cn-shanghai
```

其中**cn-shanghai**改为日志服务对应的Region。

3. 完成上述步骤后，在阿里云日志服务的指定project下会生成名为hive-event日志库、名为hive-event-config的logtail配置以及名为hive-servers的机器组。您可以查看并记录阿里云账号ID、日志服务的endPoint和Project信息，将这些信息通过提交工单提供给DataWorks技术人员，由技术人员进行后续的配置。