阿里云 Elasticsearch

最佳实践

文档版本：20190806

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
	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。	 **禁止:** 重置操作将丢失用户配置数据。
	该类警示信息可能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，恢复业务所需时间约10分钟。
	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。	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。	单击 **确定**。
`courier` 字体	命令。	执行 `cd /d C:/windows` 命令，进入Windows系统文件夹。
*## *	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。	`swich` *`{stand | slave}`*

目录

1 阿里云Elasticsearch通过Beats搭建可视化运维系统

本文档以使用Metricbeat采集Mac电脑的指标信息，投递到阿里云Elasticsearch上，并在Kibana中生成对应Dashborard的场景为例，为您介绍通过Beats和阿里云Elasticsearch搭建可视化运维系统的方法。

教程概述

Beats平台集合了多种单一用途的数据采集器，这些采集器安装后可用作轻量型代理，从成百上千或成千上万台机器向Logstash或Elasticsearch发送数据。

Metricbeat是一个轻量级的指标采集器，用于从系统和服务中收集指标。从CPU到内存，从Redis到Nginx，Metricbeat能够以一种轻量型的方式，输送各种系统和服务的统计数据。

本案例为您演示如何使用Metricbeat采集一台Mac电脑的指标信息，投递到阿里云Elasticsearch上，并且在Kibana中生成对应的Dashborard，整体步骤如下。

1. 准备工作。
2. 配置阿里云Elasticsearch。
3. 配置Metricbeat。
4. 在Kibana中查看Dashboard。

> 说明:
>
> - 您也可以参考本案例的步骤，使用Metricbeat采集一台Linux系统或Windows系统电脑的指标信息，投递到阿里云Elasticsearch上。
> - 本案例参考文档：借助Beats快速搭建可视化运维系统。

注意事项

本案例使用了0.0.0.0/1,128.0.0.0/1的Elasticsearch实例公网白名单，这个配置将导致您的阿里云Elasticsearch基本上完全暴露在公网中，在进行同样配置前请先评估是否可以接受这个风险。

准备工作

在开始本案例前，您需要完成以下准备工作。

- 购买阿里云Elasticsearch实例。

> 说明:
> 如果您需要通过阿里云Elasticsearch实例的内网地址来访问，还需要先购买一台与阿里云Elasticsearch实例相同VPC和Region的阿里云ECS实例进行访问操作。

- 下载Metricbeat。
  - MAC系统的Metricbeat安装包下载地址。
  - 32位Linux系统的Metricbeat安装包下载地址
  - 64位Linux系统的Metricbeat安装包下载地址
  - 32位Windows系统的Metricbeat安装包下载地址
  - 64位Windows系统的Metricbeat安装包下载地址

配置阿里云Elasticsearch

1. 登录阿里云Elasticsearch控制台，单击实例ID > 安全配置。
2. 打开公网地址开关，待配置生效后，单击公网地址访问白名单右侧的修改，将您MAC机器对外的公网IP配置到公网地址访问白名单中。

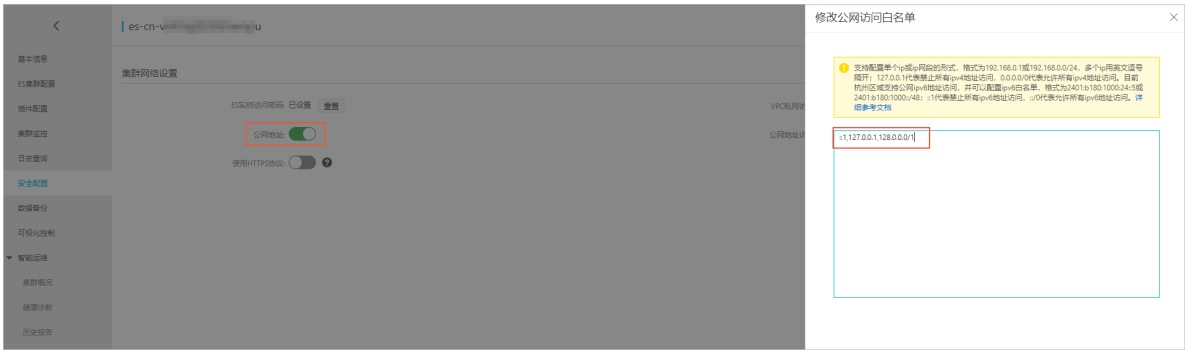

> **注意:**
> 如果您使用的是公司或WIFI等网络，需要将公网出口的跳板机IP配置进去。如果获取不到，建议配置0.0.0.0/1,128.0.0.0/1来开放尽可能多的IP（本篇以此为例）。 需要特别注意这个配置将导致您的阿里云Elasticsearch基本上完全暴露在公网中，需要先评估下是否可以接受这个风险。

3. 返回实例的基本信息页面，获取您阿里云Elasticsearch实例的公网地址备用。

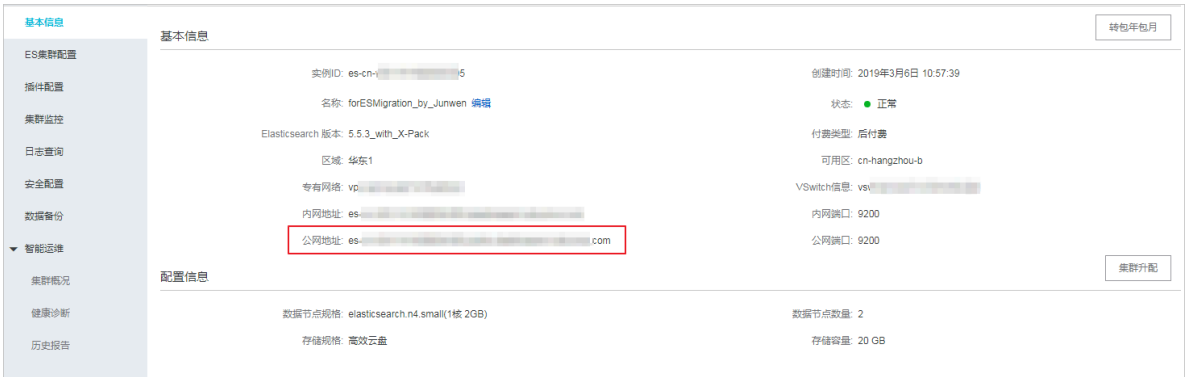

4. 切换到ES集群配置页面，单击YML文件配置右侧的修改配置，将自动创建索引设置为允许自动创建索引。

> **注意:**
> 此配置需要重启您的Elasticsearch实例才能生效，为保证您的业务不受影响，请谨慎操作。

5. 勾选该操作会重启实例，请确认后操作，单击确认。

   此过程约持续30分钟左右，请您耐心等待。重启完成后，即可完成Elasticsearch实例的配置。

配置Metricbeat

1. 将在准备工作中下载的Metricbeat安装包解压缩，并进入Metricbeat文件夹。

```
zhaohongyangdeMacBook-Pro:Desktop zhaohongyang$ cd metricbeat-6.3.1-darwin-x86_64
zhaohongyangdeMacBook-Pro:metricbeat-6.3.1-darwin-x86_64 zhaohongyang$ ls
LICENSE.txt                 data                        logs                        metricbeat.yml
NOTICE.txt                  fields.yml                  metricbeat                  modules.d
README.md                   kibana                      metricbeat.reference.yml
zhaohongyangdeMacBook-Pro:metricbeat-6.3.1-darwin-x86_64 zhaohongyang$
```

2. 打开并编辑*metricbeat.yml*中Elasticsearch output部分内容，并取消对应内容的注释状态。

```
#================================ Outputs =====================================

# Configure what output to use when sending the data collected by the beat.

#-------------------------- Elasticsearch output ------------------------------
output.elasticsearch:
  # Array of hosts to connect to.
  hosts: ["es-cn-[redacted].public.elasticsearch.aliyuncs.com:9200"]

  # Optional protocol and basic auth credentials.
  protocol: "http"
  username: "[redacted]:"
  password: "[redacted]"
```

   - hosts：为阿里云Elasticsearch实例的公网/内网地址（本篇以阿里云Elasticsearch实例的公网地址为例）。
   - protocol：需要配置为http。
   - username：默认是elastic。
   - password：为购买阿里云Elasticsearch实例时填写的登录密码。

3. 执行以下命令，启动Metricbeat。

```
./metricbeat -e -c metricbeat.yml
```

   启动成功后，Metricbeat就开始向您的阿里云Elasticsearch推送数据了。

```
zhaohongyangdeMacBook-Pro:metricbeat-6.3.1-darwin-x86_64 zhaohongyang$ ./metricbeat -e -c metricbeat.yml
```

在Kibana中查看Dashboard

进入您阿里云Elasticsearch实例的Kibana控制台，单击左侧导航栏的Dashboard，进入Dashboard页面查看相关信息。

> 说明：
> 如果Kibana控制台中没有创建过Index Patterns，切换到Dashboard页面后可能无法正常展示对应信息。此时可在Kibana控制台的Management页面单击Index Patterns，并按照提示创建一个Index Patterns，再切换到Dashboard页面查看对应内容。

- 各类相关指标列表。

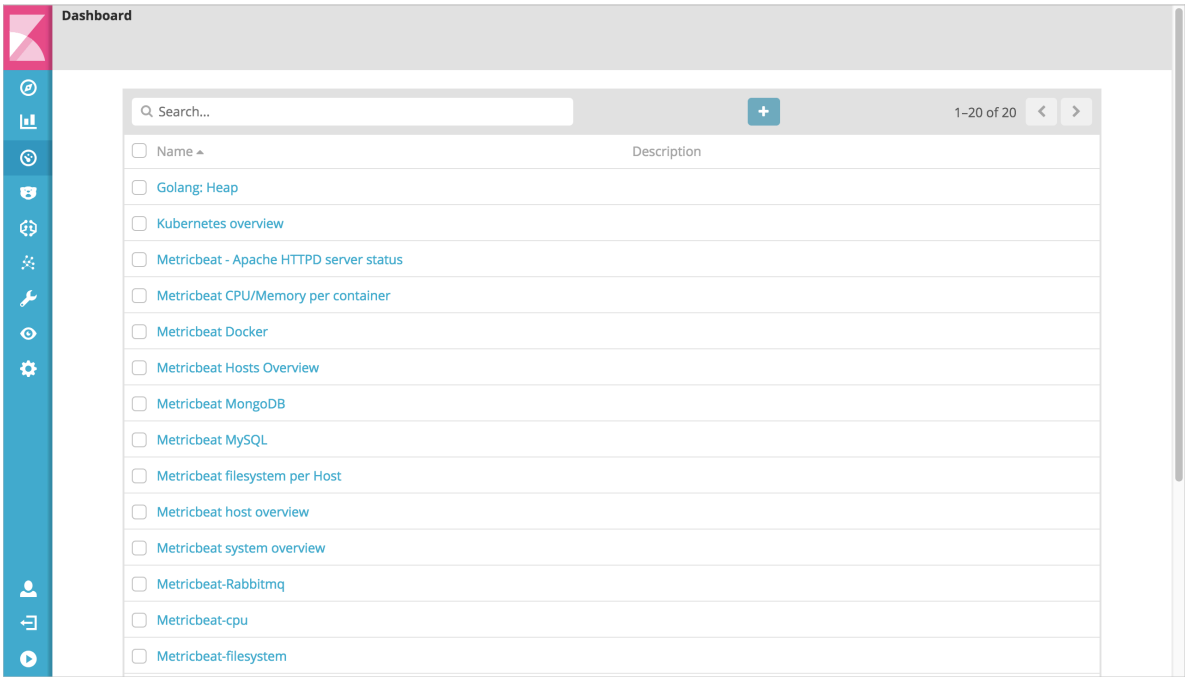

- Metricbeat-cpu指标信息。

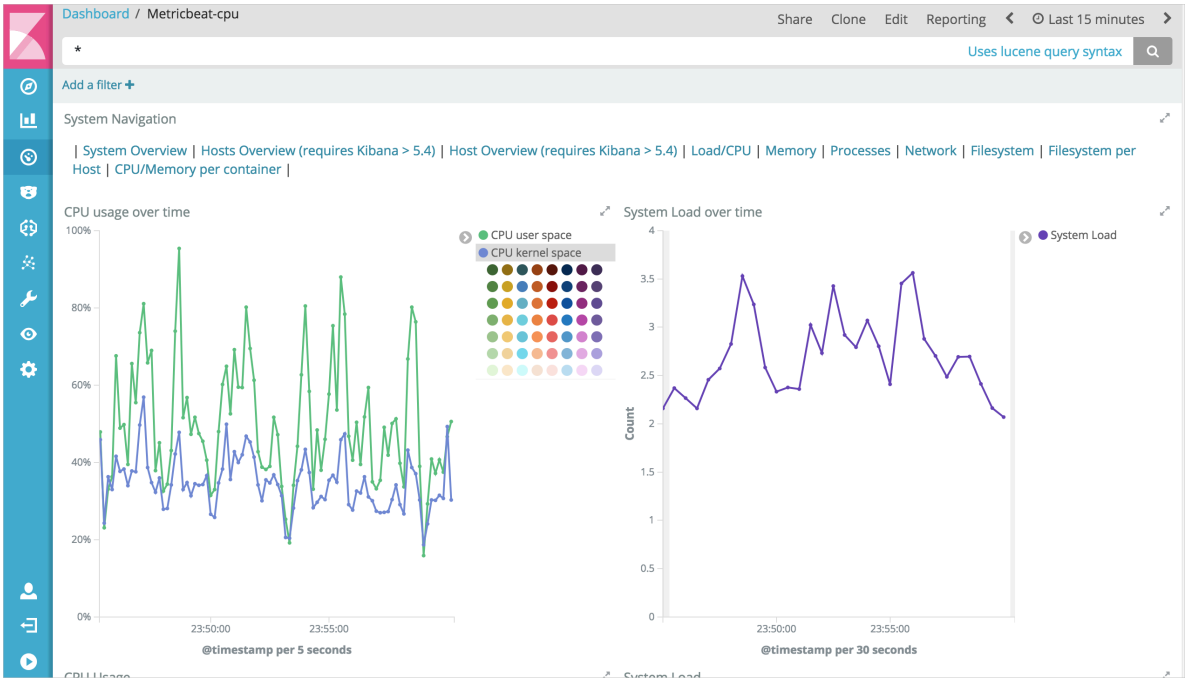

说明:

您可以将数据定义成5s刷新一次，并且可以生成对应的报表，接入webhook对异常进行告警。

2 Curator操作指南

Curator是Elasticsearch官方的一个索引管理工具，提供了删除、创建、关闭、段合并索引等功能。本文档为您介绍Curator的使用方法，包括安装、单命令行执行、定时执行、冷热数据分离实践、索引跨节点迁移等。

概述

本文档为您讲解了如何安装Elasticsearch Curator，如何使用单命令行执行，以及如何使用curator命令完成crontab定时执行、冷热数据分离实践、将索引从hot节点迁移到warm节点等操作。

准备工作

在安装Curator前，首先要购买一台阿里云ECS实例（本文档以CentOS 7.3 64位的ECS为例），所购买的实例需要与您的阿里云Elasticsearch实例在同一个VPC下。

安装Elasticsearch Curator

在您购买的ECS命令行界面，执行以下命令安装Curator。

```
pip install elasticsearch-curator
```

说明:

- 建议您安装5.6.0版本的Curator，它可以支持阿里云Elasticsearch 5.5.3和6.3.2版本。
- 请参考官方文档查看Curator版本与Elasticsearch版本的兼容性。

安装成功后，执行以下命令查看Curator版本。

```
curator --version
```

正常情况下的返回结果如下。

```
curator, version 5.6.0
```

单命令行执行

您可以使用curator_cli命令执行单个操作，命令行使用方式请参考官方文档。

说明:

- curator_cli只能执行一个操作。
- 并不是所有的操作都适用于单命令行执行，例如Alias和Restore操作。

crontab定时执行

您可以通过crontab和curator命令实现定时执行一系列操作。

curator命令格式如下。

```
curator [OPTIONS] ACTION_FILE
Options:
  --config PATH  Path to configuration file. Default: ~/.curator/
curator.yml
  --dry-run      Do not perform any changes.
  --version      Show the version and exit.
  --help         Show this message and exit.
```

执行curator命令时需要指定config.yml文件（官方参考文档）和action.yml文件（官方参考文档）。

冷热数据分离实践

详细操作方法请参考使用Curator进行冷热数据迁移（官方文档）。

将索引从hot节点迁移到warm节点

1. 在*/usr/curator/*路径下创建*config.yml*文件，配置内容参考如下示例。

```
client:
  hosts:
    - http://es-cn-0pxxxxxxxxxxx234.elasticsearch.aliyuncs.com
  port: 9200
  url_prefix:
  use_ssl: False
  certificate:
  client_cert:
  client_key:
  ssl_no_validate: False
  http_auth: user:password
  timeout: 30
  master_only: False
logging:
  loglevel: INFO
  logfile:
  logformat: default
  blacklist: ['elasticsearch', 'urllib3']
```

   - `hosts`：将该参数值替换为需要访问的阿里云Elasticsearch实例地址（此处以Elasticsearch内网地址为例）。
   - `http_auth`：将该参数值替换为对应阿里云Elasticsearch实例的账号和密码。

2. 在*/usr/curator/*路径下创建*action.yml*文件，配置内容参考如下示例。

```
actions:
  1:
    action: allocation
    description: "Apply shard allocation filtering rules to the
specified indices"
```

```
    options:
      key: box_type
      value: warm
      allocation_type: require
      wait_for_completion: true
      timeout_override:
      continue_if_exception: false
      disable_action: false
    filters:
    - filtertype: pattern
      kind: prefix
      value: logstash-
    - filtertype: age
      source: creation_date
      direction: older
      timestring: '%Y-%m-%dT%H:%M:%S'
      unit: minutes
      unit_count: 30
```

以上示例按照索引创建时间，将30分钟前创建在`hot`节点以`logstash-`开头的索引迁移到`warm`节点中。您也可以根据实际场景自定义配置*action.yml*文件。

3. 执行以下命令，验证curator命令能否正常执行。

```
curator --config /usr/curator/config.yml /usr/curator/action.yml
```

正常情况下会返回类似如下所示的信息。

```
2019-02-12 20:11:30,607 INFO      Preparing Action ID: 1, "
allocation"
2019-02-12 20:11:30,612 INFO      Trying Action ID: 1, "allocation
": Apply shard allocation filtering rules to the specified indices
2019-02-12 20:11:30,693 INFO      Updating index setting {'index.
routing.allocation.require.box_type': 'warm'}
2019-02-12 20:12:57,925 INFO      Health Check for all provided keys
 passed.
2019-02-12 20:12:57,925 INFO      Action ID: 1, "allocation"
completed.
2019-02-12 20:12:57,925 INFO      Job completed.
```

4. 执行以下命令，使用crontab实现每隔15分钟定时执行curator命令。

```
*/15 * * * * curator --config /usr/curator/config.yml /usr/curator/
action.yml
```

3 数据同步及迁移

3.1 云上数据导入

阿里云上数据导入阿里云ES（离线）

阿里云上拥有丰富的云存储、云数据库产品。如果您希望针对这些产品中的数据进行分析和搜索，可以通过 数据集成（Data Integration）来实现最快 5min 一次的离线数据，同步到Elasticsearch的需求。

支持数据源

- 阿里云云数据库(MySQL、PG、SQL Server、PPAS、MongoDB、HBase)
- 阿里云DRDS
- 阿里云MaxCompute(ODPS)
- 阿里云OSS
- 阿里云Table Store
- 自建HDFS、Oracle、FTP、DB2，及上述云数据库的自建版本

> 说明:
> 做数据同步时可能会产生公网流量费用，请您知晓。

操作步骤

完成离线数据导入，需要您完成以下几步操作：

- 您需要有一台可以与 VPC 内的 Elasticsearch 交互的ECS，这台 ECS 将获取数据源数据并执行写ES数据的“Job”(该任务将由“Data Integration系统统一下发”)。
- 您需要开通 Data Intergration 的服务，并且将ECS作为一个可以执行 Job 的“资源”注册到 Data Intergration 的服务中去。
- 您需要配置一个“数据同步的脚本”，并且让其可以周期性的执行起来。

详细步骤

1. 购买一台与Elasticsearch服务处于同一个VPC内的ECS服务器，并分配一个公网IP合或开通弹性IP，为了节省您的成本，您可以复用已有的ECS服务器，(如何购买ECS，请参考创建ECS实例文档)。

   > 说明:

- 建议使用 centos6、centos7 或者 aliyunos。
- 如果您添加的 ECS 需要执行 MaxCompute 任务或者同步任务，需要检查当前 ECS 的 python 版本是否是 python2.6或2.7 的版本（centos5 的版本为 2.4，其余 os 自带了 2.6 以上版本）。
- 请确保 ECS 有公网 IP。

2. 前往Data Integration控制台，并进入工作区。

如果您已经开通过Data Integration 或者 DataWorks 产品，您将会看到如下页面：

如果您未开通过Data Integration 或者 DataWorks 产品，您需要按照步骤进行 Data Integration 的开通，此开通动作 会产生费用，请您按照费用提示进行预算评估。

3. 进入Data Integration的项目管理-调度资源管理页面，将您之前VPC内的ECS配置成为一个调度资源。详细配置参考新增任务资源。

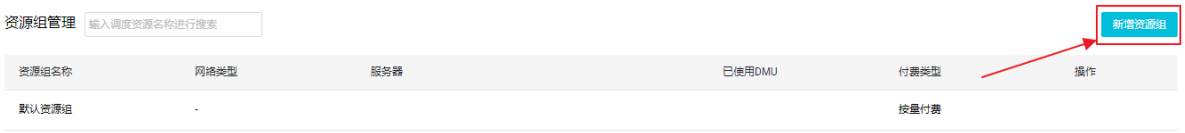

4. 在Data Integration中配置数据同步脚本，具体配置请参考脚本模式配置。Elasticsearch的Config规则请参考 配置Elasticsearch Writer。

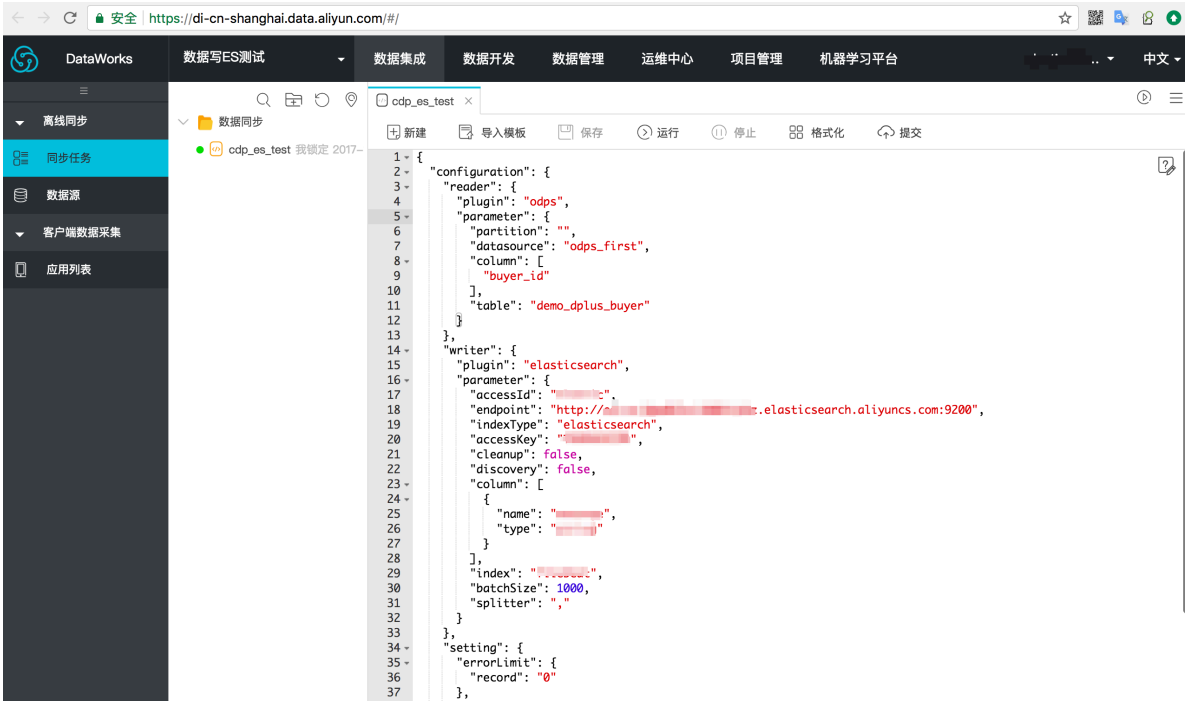

说明:

- 同步脚本的配置分为三个部分，Reader是配置您上游数据源（待同步数据的云产品）的config，Writer是配置ES的config，还有一个setting是配置同步中的一些丢包和最大并发等设置
- ES Writer中accessId和accessKey需要配置您的Elasticsearch的访问“用户名”和“密码”

5. 脚本配置完成后，将数据同步Job进行提交，按照需求填写相应的周期性执行配置，并点击“确定”完成提交动作。

说明:

- 如果您希望周期性调度，需要配置周期任务，具体的Job开始执行时间，周期间隔，Job生命周期，均需要在这个弹窗中配置
- 周期任务将于配置任务开始的第二天00:00，按照您的配置规则生效执行

6. 最后一步提交完成后，请务必前往运维中心-周期任务，找到您提交的Job，将其调度资源从默认修改为您配置好的调度资源。

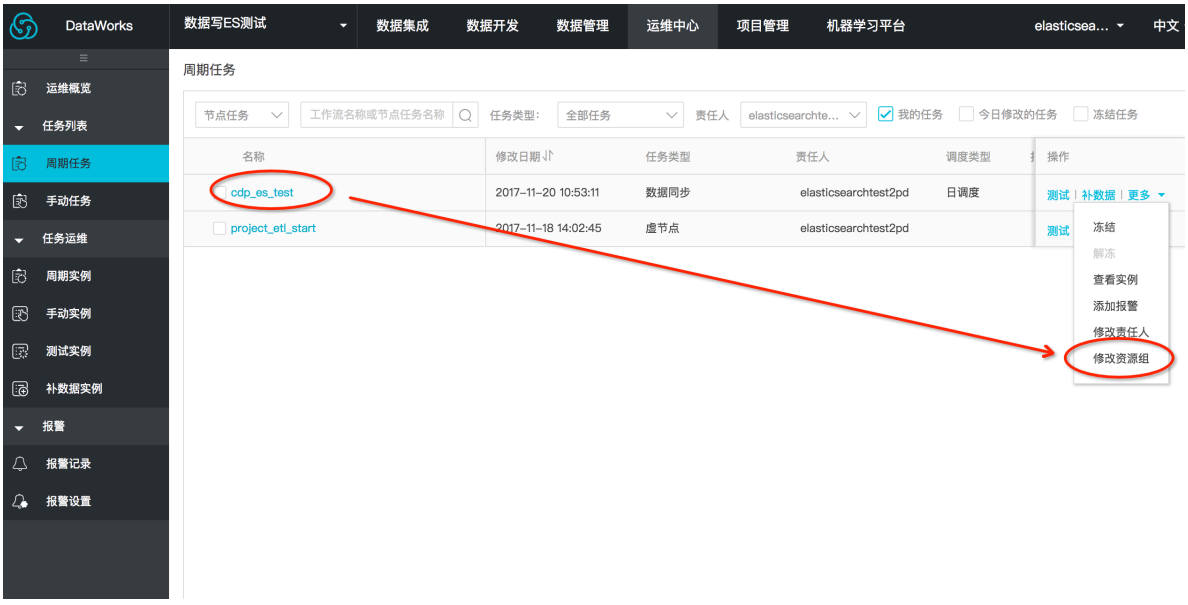

实时数据导入

功能开发中，敬请期待。

3.2 使用DataWorks实现Hadoop数据同步到阿里云Elasticsearch

本文向您详细介绍如何通过DataWorks数据同步功能，将Hadoop数据同步到阿里云Elasticsearch上，并进行搜索分析。

背景信息

您也可以使用Java代码进行同步，具体请参考通过ES-Hadoop将Hadoop数据写入阿里云Elasticsearch和在E-MapReduce中使用ES-Hadoop。

环境准备

1. 搭建Hadoop集群。

   在进行数据同步前，您需要保证自己的Hadoop集群环境正常。本文使用阿里云EMR服务自动化搭建Hadoop集群，详细过程请参见步骤三：创建集群。

   EMR Hadoop的版本信息如下。

   - EMR版本：EMR-3.11.0
   - 集群类型：HADOOP
   - 软件信息：HDFS2.7.2 / YARN2.7.2 / Hive2.3.3 / Ganglia3.7.2 / Spark2.3.1 / HUE4.1.0 / Zeppelin0.8.0 / Tez0.9.1 / Sqoop1.4.7 / Pig0.14.0 / ApacheDS2.0.0 / Knox0.13.0

   Hadoop集群使用VPC网络，区域为华东1（杭州），主实例组ECS计算资源配置公网及内网IP，高可用选择为否（非HA模式），具体配置如下图所示。

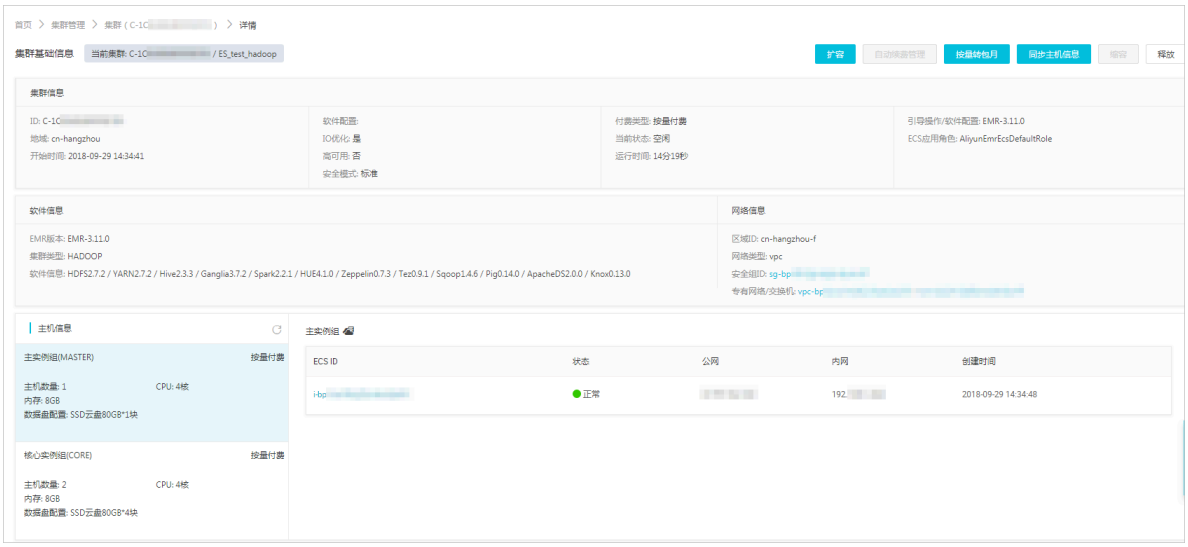

2. 购买和配置Elasticsearch。

登录Elasticsearch控制台，参考购买和配置，购买一个Elasticsearch实例。选择与EMR集群相同的区域和VPC网络配置，如下图所示。

3. 创建DataWorks工作空间。

   创建DataWorks项目，区域选择华东1区。本文直接使用已经存在的项目bigdata_DOC。

数据准备

在Hadoop集群中创建测试数据，步骤如下。

1. 进入EMR控制台界面，单击左侧菜单栏的交互式工作台。
2. 选择文件 > 新建交互式任务。

3. 在Notebook对话框中，输入交互式任务的名称，选择默认类型以及关联集群，单击确认。

   本文新建一个名为es_test_hive的交互式任务，默认类型为Hive，关联集群为环境准备中创建的EMR Hadoop集群。

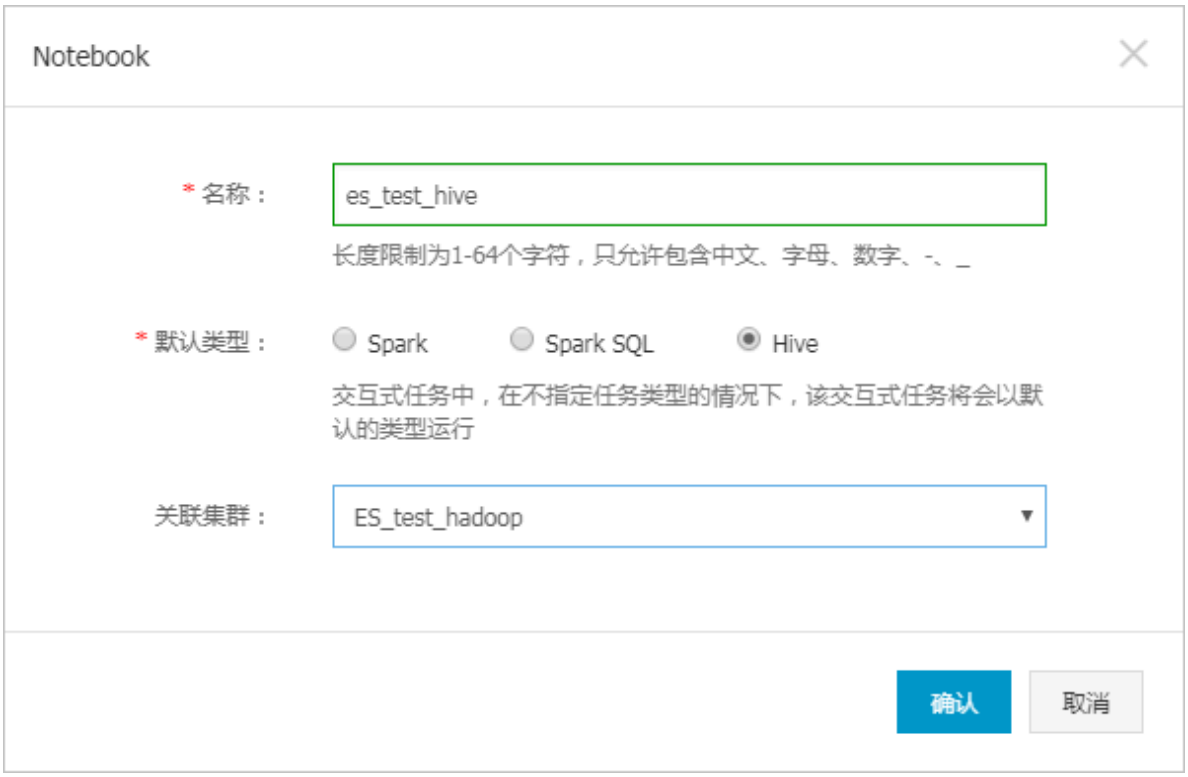

4. 在代码编辑区域中，输入Hive建表语句，单击运行。

   本文档使用的建表语句如下。

```
CREATE TABLE IF NOT

EXISTS hive_esdoc_good_sale(
 create_time timestamp,
 category STRING,
 brand STRING,
 buyer_id STRING,
 trans_num BIGINT,
 trans_amount DOUBLE,
 click_cnt BIGINT
 )
 PARTITIONED BY (pt string) ROW FORMAT
```

```
DELIMITED FIELDS TERMINATED BY ',' lines terminated by '\n'
```

表创建成功后，系统会提示Query executed successfully。

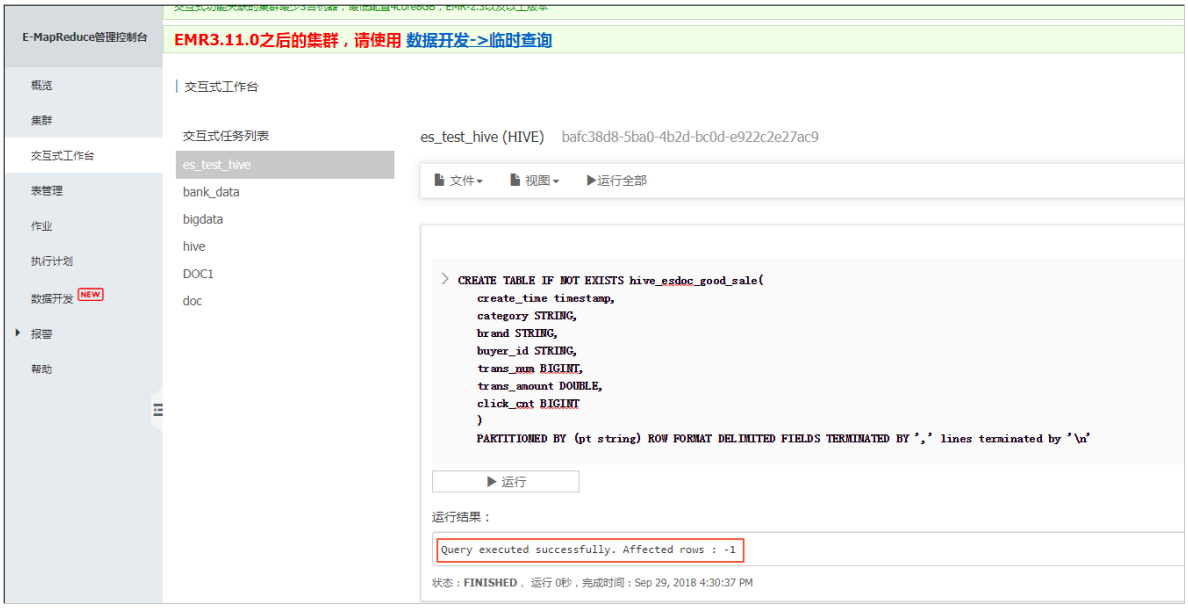

5. 单击文件 > 新建段落，在段落编辑区域输入SQL语句，单击运行，插入测试数据。

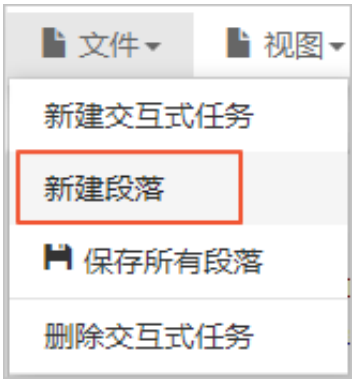

您可以选择从OSS或其他数据源导入测试数据，也可以手动插入少量的测试数据。本文使用手动插入数据的方法，脚本如下。

```
insert into
hive_esdoc_good_sale PARTITION(pt =1 ) values('2018-08-21','外套','品
牌A','lilei',3,500.6,7),('2018-08-22','生鲜','品牌B','lilei',1,303
,8),('2018-08-22','外套','品牌C','hanmeimei',2,510,2),(2018-08-22
,'卫浴','品牌A','hanmeimei',1,442.5,1),('2018-08-22','生鲜','品牌D','
hanmeimei',2,234,3),('2018-08-23','外套','品牌B','jimmy',9,2000,7),('
2018-08-23','生鲜','品牌A','jimmy',5,45.1,5),('2018-08-23','外套','品
牌E','jimmy',5,100.2,4),('2018-08-24','生鲜','品牌G','peiqi',10,5560
,7),('2018-08-24','卫浴','品牌F','peiqi',1,445.6,2),('2018-08-24','外
```

```
套','品牌A','ray',3,777,3),('2018-08-24','卫浴','品牌G','ray',3,122,3
),('2018-08-24','外套','品牌C','ray',1,62,7) ;
```

6. 使用同样的方式新建段落，并在段落编辑区域输入`select * from hive_esdoc_good_sale where pt =1;`语句，单击运行。

   此操作可以检查Hadoop集群表中是否已存在数据可用于同步，运行成功结果如下。

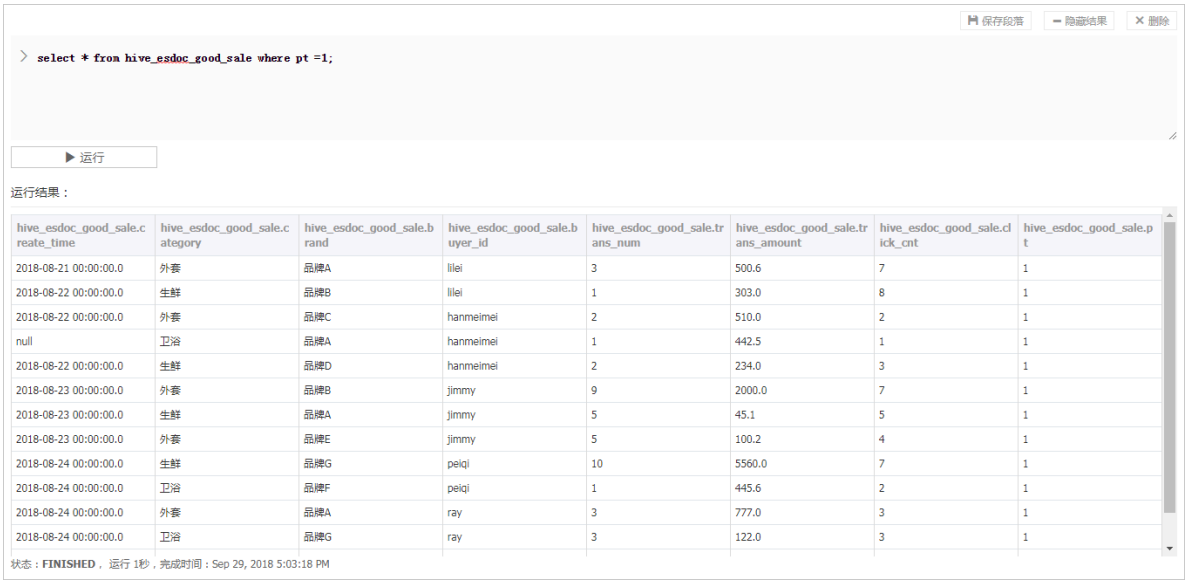

hive_esdoc_good_sale.create_time	hive_esdoc_good_sale.category	hive_esdoc_good_sale.brand	hive_esdoc_good_sale.buyer_id	hive_esdoc_good_sale.trans_num	hive_esdoc_good_sale.trans_amount	hive_esdoc_good_sale.click_cnt	hive_esdoc_good_sale.pt
2018-08-21 00:00:00.0	外套	品牌A	lilei	3	500.6	7	1
2018-08-22 00:00:00.0	生鲜	品牌B	lilei	1	303.0	8	1
2018-08-22 00:00:00.0	外套	品牌C	hanmeimei	2	510.0	2	1
null	卫浴	品牌A	hanmeimei	1	442.5	1	1
2018-08-22 00:00:00.0	生鲜	品牌D	hanmeimei	2	234.0	3	1
2018-08-23 00:00:00.0	外套	品牌B	jimmy	9	2000.0	7	1
2018-08-23 00:00:00.0	生鲜	品牌A	jimmy	5	45.1	5	1
2018-08-23 00:00:00.0	外套	品牌E	jimmy	5	100.2	4	1
2018-08-24 00:00:00.0	生鲜	品牌G	peiqi	10	5560.0	7	1
2018-08-24 00:00:00.0	卫浴	品牌F	peiqi	1	445.6	2	1
2018-08-24 00:00:00.0	外套	品牌A	ray	3	777.0	3	1
2018-08-24 00:00:00.0	卫浴	品牌G	ray	3	122.0	3	1

数据同步

> **说明：**
>
> 由于DataWorks项目所处的网络环境与Hadoop集群中的数据节点（Data Node）网络通常不可达，因此您可以通过自定义资源组的方式，将DataWorks的同步任务运行在Hadoop集群的Master节点上（Hadoop集群内Master节点和数据节点通常可达）。

1. 查看Hadoop集群的数据节点。
   a) 在EMR控制台上，单击左侧菜单栏的集群。
   b) 选择您的集群，单击右侧的管理。
   c) 在集群管理控制台上，单击左侧菜单栏的主机列表，查看集群master节点和数据节点信息。

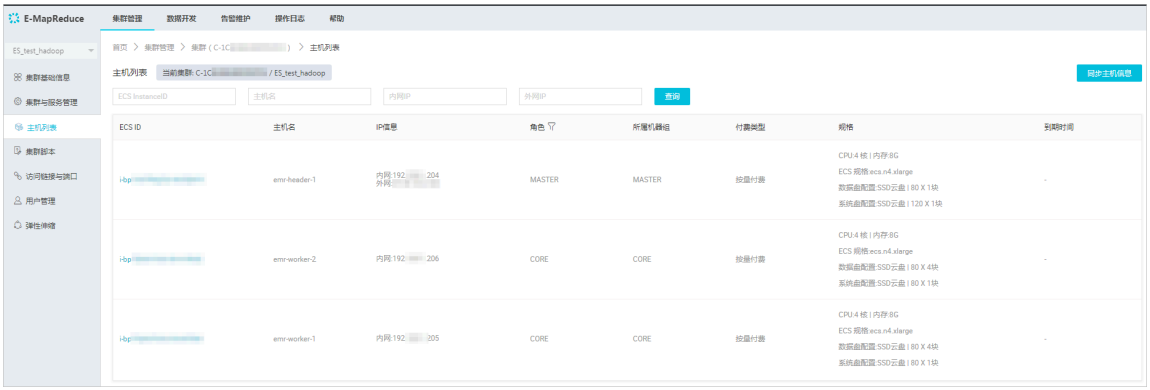

说明:

通常非HA模式的EMR上Hadoop集群的Master节点主机名为emr-header-1，Data Node主机名为emr-worker-X。

d) 单击上图中Master节点的ECS ID，进入ECS实例详情页。单击远程连接进入ECS服务器，通过`hadoop dfsadmin -report`命令查看数据节点信息。

```
DFS Remaining: 665931456512 (620.20 GB)
DFS Used: 209780736 (200.06 MB)
DFS Used%: 0.03%
Under replicated blocks: 0
Blocks with corrupt replicas: 0
Missing blocks: 0
Missing blocks (with replication factor 1): 0

-------------------------------------------------
Live datanodes (2):

Name: 192.[redacted]206:50010 (emr-worker-2.cluster-77026)
Hostname: emr-worker-2.cluster-77026
Decommission Status : Normal
Configured Capacity: 333373341696 (310.48 GB)
DFS Used: 104890368 (100.03 MB)
Non DFS Used: 302723072 (288.70 MB)
DFS Remaining: 332965728256 (310.10 GB)
DFS Used%: 0.03%
DFS Remaining%: 99.88%
Configured Cache Capacity: 0 (0 B)
Cache Used: 0 (0 B)
Cache Remaining: 0 (0 B)
Cache Used%: 100.00%
Cache Remaining%: 0.00%
Xceivers: 1
Last contact: Sat Sep 29 17:37:46 CST 2018


Name: 192.[redacted]205:50010 (emr-worker-1.cluster-77026)
Hostname: emr-worker-1.cluster-77026
Decommission Status : Normal
Configured Capacity: 333373341696 (310.48 GB)
DFS Used: 104890368 (100.03 MB)
Non DFS Used: 302723072 (288.70 MB)
DFS Remaining: 332965728256 (310.10 GB)
DFS Used%: 0.03%
DFS Remaining%: 99.88%
Configured Cache Capacity: 0 (0 B)
Cache Used: 0 (0 B)
Cache Remaining: 0 (0 B)
Cache Used%: 100.00%
Cache Remaining%: 0.00%
Xceivers: 1
Last contact: Sat Sep 29 17:37:46 CST 2018
```

2. 新建自定义资源组。

a) 进入DataWorks的数据集成页面，选择资源组 > 新增资源组。

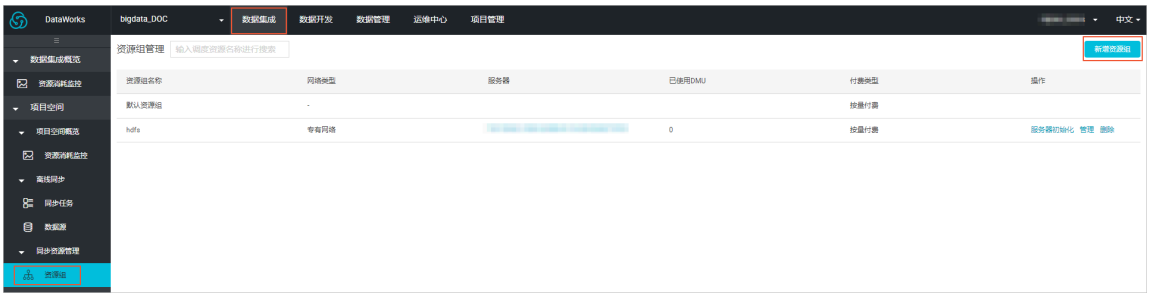

关于自定义资源组的详细信息请参见新增任务资源。

b) 根据界面提示，输入资源组名称和服务器信息。此服务器为您EMR集群的Master节点，服务器信息说明如下。

参数	说明
网络类型	选择专有网络。 注意: 对于专有网络类型，需输入服务器UUID。对于经典网络类型，需输入服务器名称。目前仅DataWorks V2.0华东2区支持经典网络类型的调度资源添加，对于其他区域，无论您使用的是经典网络还是专有网络类型，在添加调度资源组时都请选择专有网络类型。
ECS UUID	登录EMR集群的Master节点，执行 `dmidecode | grep UUID`，取返回值。
机器IP/机器CPU（核）/机器内存（GB）	您Master节点的公网IP/CPU/内存。您可以在Master节点的ECS控制台上单击实例名称，在配置信息模块，找到相关信息。

注意:

完成添加服务器后，您需要保证Master Node与DataWorks网络可达。

- 如果您使用的是ECS服务器，需设置服务器的安全组。
- 如果您使用的内网IP互通，需要添加安全组。
- 如果您使用的是公网IP，可直接设置安全组公网出入方向规则。

由于本文档的EMR集群使用的是VPC网络，且与DataWorks在同一区域下，因此不需要进行安全组设置。

c) 按照提示安装自定义资源组Agent。

注意:

由于本文使用的是VPC网络类型，因此不需开通8000端口。

观察到当前状态为可用时，说明新增自定义资源组成功。如果状态为不可用，您可以登录Master Node，使用`tail -f/home/admin/alisatasknode/logs/heartbeat.log`命令查看DataWorks与Master Node之间心跳报文是否超时。

```
[root@emr-header-1 logs]# hdfs dfs -ls /user/hive/warehouse/hive_doc_good_sale/
Found 1 items
drwxr-x--x   - hive hadoop          0 2018-09-03 17:46 /user/hive/warehouse/hive_doc_good_sale/pt=1
[root@emr-header-1 logs]# tail -f /home/admin/alisatasknode/logs/heartbeat.log
2018-09-06 21:47:34,440 INFO  [pool-6-thread-1] [HeartbeatReporter.java:104] [] - heartbeat start, current status:2
2018-09-06 21:47:34,465 INFO  [pool-6-thread-1] [HeartbeatReporter.java:133] [] - heartbeat end■ cost time:0.025s
2018-09-06 21:47:39,465 INFO  [pool-6-thread-1] [HeartbeatReporter.java:104] [] - heartbeat start, current status:2
2018-09-06 21:47:39,491 INFO  [pool-6-thread-1] [HeartbeatReporter.java:133] [] - heartbeat end■ cost time:0.026s
2018-09-06 21:47:44,491 INFO  [pool-6-thread-1] [HeartbeatReporter.java:104] [] - heartbeat start, current status:2
2018-09-06 21:47:44,515 INFO  [pool-6-thread-1] [HeartbeatReporter.java:133] [] - heartbeat end■ cost time:0.024s
2018-09-06 21:47:49,516 INFO  [pool-6-thread-1] [HeartbeatReporter.java:104] [] - heartbeat start, current status:2
2018-09-06 21:47:49,538 INFO  [pool-6-thread-1] [HeartbeatReporter.java:133] [] - heartbeat end■ cost time:0.022s
2018-09-06 21:47:54,539 INFO  [pool-6-thread-1] [HeartbeatReporter.java:104] [] - heartbeat start, current status:2
2018-09-06 21:47:54,555 INFO  [pool-6-thread-1] [HeartbeatReporter.java:133] [] - heartbeat end■ cost time:0.016s
^C
```

3. 新建数据源。

a) 在DataWorks的数据集成页面，单击数据源 > 新增数据源，在弹框中选择HDFS类型的数据源。

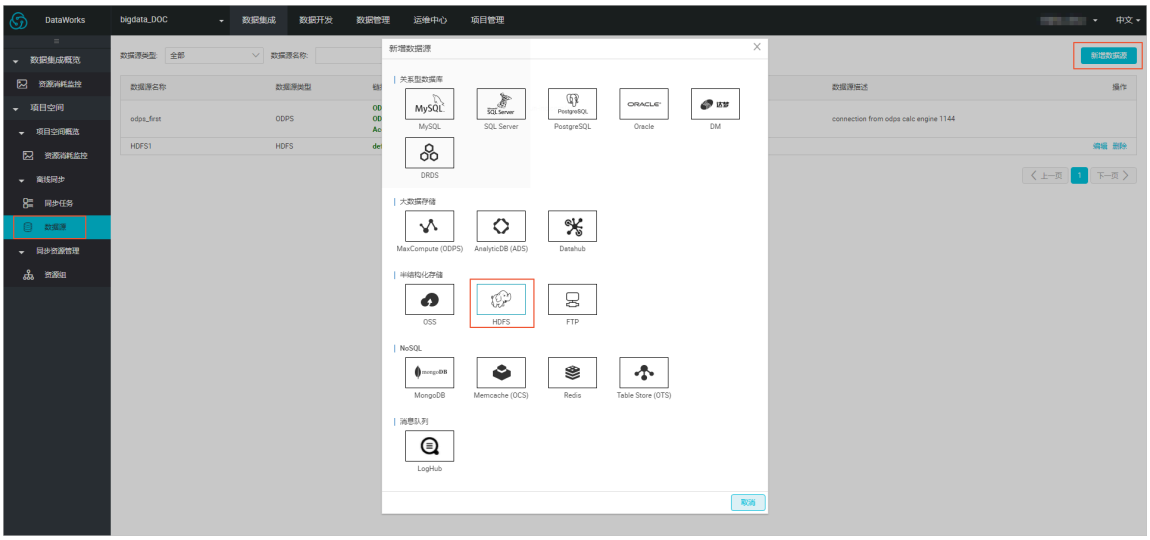

b) 在新增HDFS数据源页面中，填写数据源名称和defaultFS。

注意：

对于EMR Hadoop集群而言，如果Hadoop集群为非HA集群，则此处地址为`hdfs://emr-header-1的IP:9000`。如果Hadoop集群为HA集群，则此处地址为`hdfs://emr-header-1的IP:8020`。在本文中，emr-header-1与DataWorks通过VPC网络连接，因此此处填写内网IP，且不支持连通性测试。

4. 配置数据同步任务。

a) 在DataWorks数据集成页面，单击左侧菜单栏的同步任务，选择新建 > 脚本模式。

b) 在导入模板对话框中，选择数据源类型如下，单击确认。

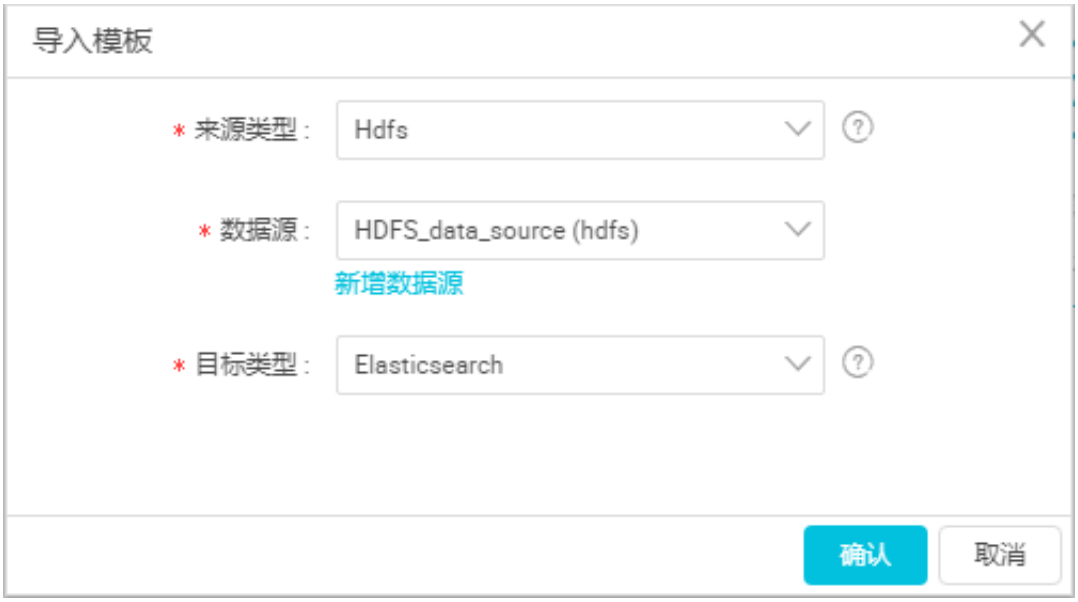

c) 完成导入模板后，同步任务会转入脚本模式，本文中配置脚本如下，相关解释请参见脚本模式配置，Elasticsearch的配置规则请参考配置Elasticsearch Writer。

Hdfs Reader

```
{
  "configuration": {
    "reader": {
      "plugin": "hdfs",
      "parameter": {
        "path": "/user/hive/warehouse/hive_esdoc_good_sale/",
        "datasource": "HDFS_data_source",
        "column": [
          {
            "index": 0,
            "type": "string"
          },
          {
            "index": 1,
            "type": "string"
          },
          {
            "index": 2,
            "type": "string"
          },
          {
            "index": 3,
            "type": "string"
          },
          {
            "index": 4,
            "type": "long"
          },
          {
            "index": 5,
            "type": "double"
          },
          {
            "index": 6,
            "type": "long"
          }
        ],
        "defaultFS": "hdfs://[redacted]:9000",
        "fieldDelimiter": ",",
        "encoding": "UTF-8",
        "fileType": "text"
      }
    },
    "writer": {
      "plugin": "elasticsearch",
      "parameter": {
        "accessId": "[redacted]",
        "endpoint": "http://es-cn-[redacted].com:9200",
        "indexType": "elasticsearch",
        "accessKey": "[redacted]",
        "cleanup": true,
        "discovery": false,
        "column": [
          {
            "name": "create_time",
            "type": "string"
          },
          {
            "name": "category",
            "type": "string"
          },
          {
            "name": "brand",
            "type": "string"
          },
          {
            "name": "buyer_id",
            "type": "string"
          },
          {
            "name": "trans_num",
            "type": "long"
          },
          {
            "name": "trans_amount",
            "type": "double"
          },
          {
            "name": "click_cnt",
            "type": "long"
          }
        ],
        "index": "hive_doc_esgood_sale",
```

- 同步脚本的配置分为三个部分，Reader用来配置您上游数据源（待同步数据的云产品）的config，Writer用来配置 Elasticsearch的config，setting用来配置同步中的一些丢包和最大并发等。
- *path*为数据在Hadoop集群中存放的位置，您可以在登录master node后，使用`hdfs dfs -ls /user/hive/warehouse/hive_esdoc_good_sale`命令确认。对于分区表，您可以不指定分区，DataWorks数据同步会自动递归到分区路径。
- 由于Elasticsearch不支持timestamp类型，本文档将`creat_time`字段的类型设置为string。
- `endpoint`为Elasticsearch 的内网或外网地址。如果您使用的是内网地址，请在Elasticsearch的集群配置页面，配置Elasticsearch的系统白名单。如果您是用的是外网地址，请在Elasticsearch的网络配置页面，配置 Elasticsearch的公网地址访问白名单（包括DataWorks服务器的IP地址和您所使用的资源组的IP地址）。
- Elasticsearch Writer中`accessId`和`accessKey`需要配置您的Elasticsearch的访问用户名（默认为elastic）和密码。
- `index`为Elasticsearch实例的索引，您需要使用该索引名称访问Elasticsearch的数据。
- 在创建同步任务时，DataWorks的默认配置脚本中，`errorLimit`的`record`字段值为0，您需要将其修改为大一些的数值，比如1000。

d) 完成配置后，单击页面右侧的配置任务资源组，选择您创建的资源组名称，完成后单击运行。

如果提示任务运行成功，则说明同步任务已完成。如果运行失败，可通过复制日志进行进一步排查。

结果验证

1. 进入Elasticsearch控制台，单击实例名称 > 可视化控制，在Kibana区域中，单击右下角的进入控制台。
2. 输入用户名和密码，单击登录进入Kibana控制台，选择Dev Tools。
3. 在Console控制台中，执行如下命令，查看已经同步过来的数据。

```
POST /hive_doc_esgood_sale/_search?pretty
{
"query": { "match_all": {}}
```

```
}
```

hive_doc_esgood_sale为您同步数据时，设置的index字段的值。

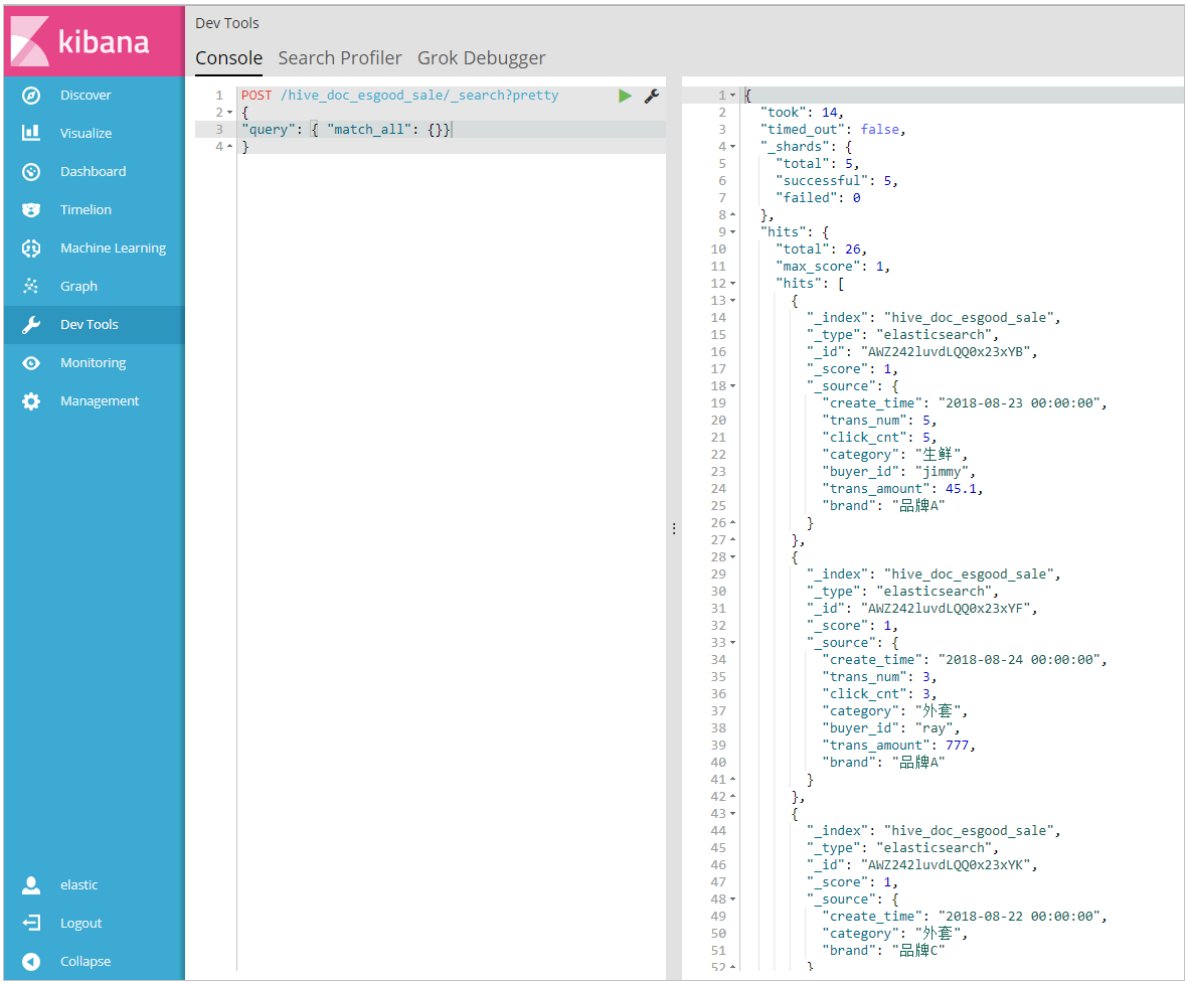

数据搜索与分析

1. 在Console控制台中，执行如下命令，返回品牌为A的所有文档。

```
POST /hive_doc_esgood_sale/_search?pretty
{
  "query": { "match_phrase": { "brand":"品牌A" } }
```

```
}
```

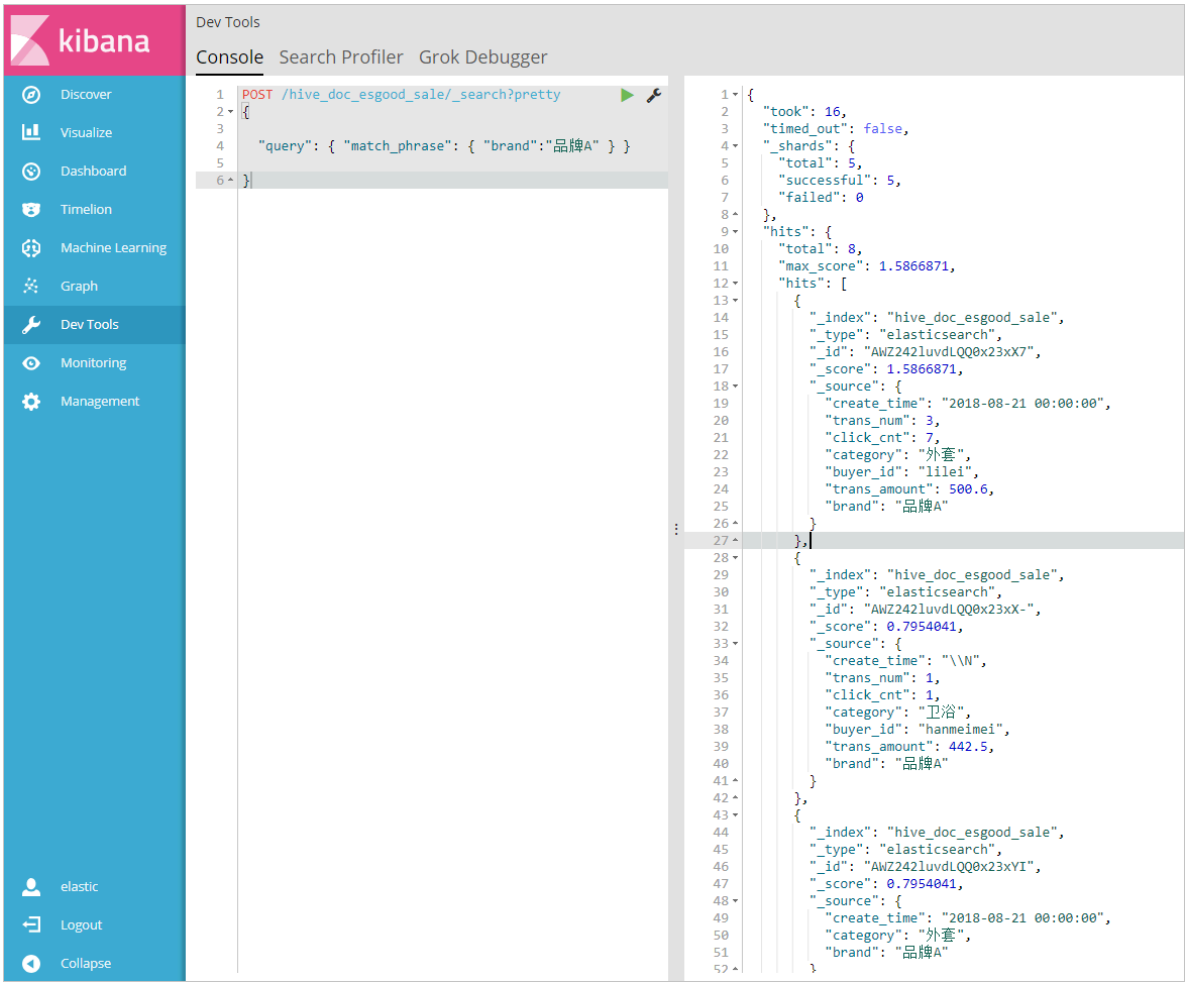

2. 在Console控制台中，执行如下命令，按照点击次数进行排序，判断各品牌产品的热度。

```
POST /hive_doc_esgood_sale/_search?pretty
{
"query": { "match_all": {} },
"sort": { "click_cnt": { "order": "desc" } },
"_source": ["category", "brand","click_cnt"]
```

```
}
```

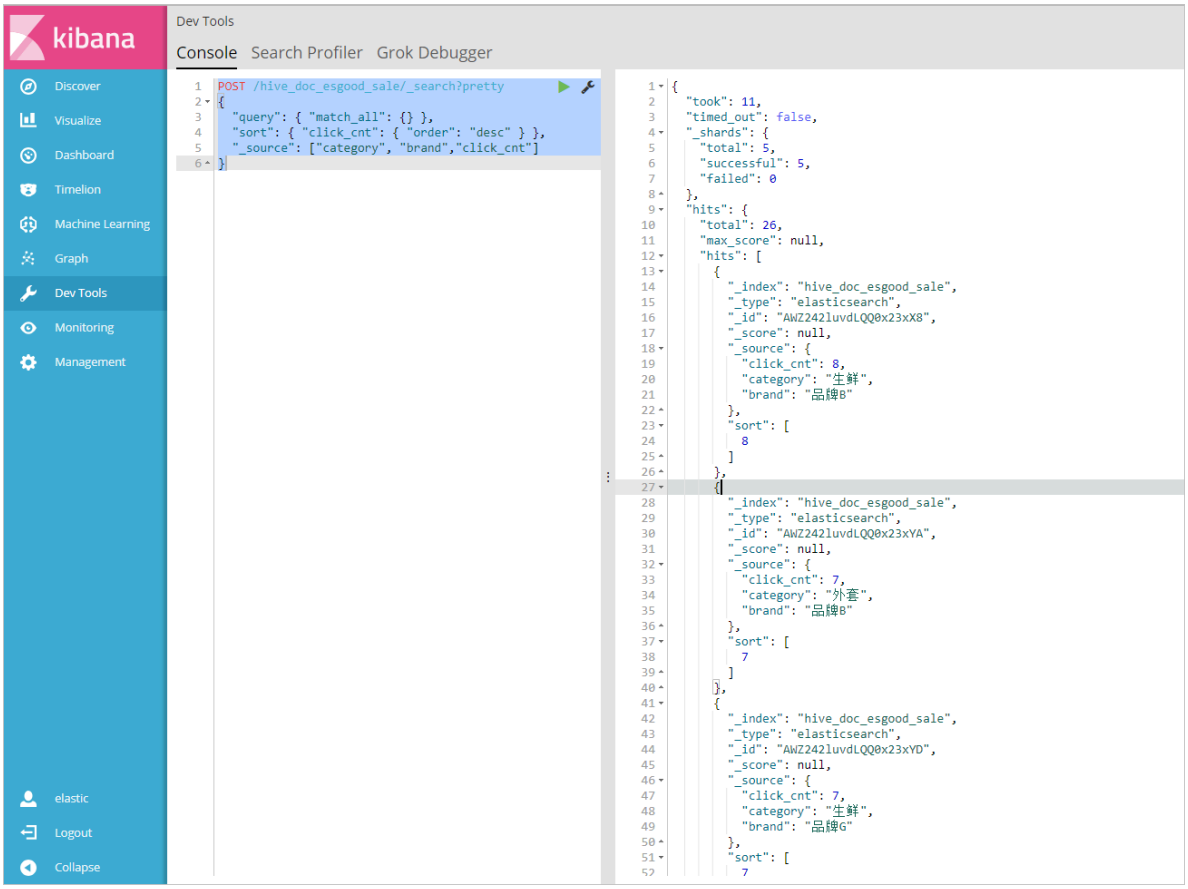

更多命令和访问方式，请参见阿里云Elasticsearch官方文档和Elastic.co官方帮助中心。

3.3 同步 MySQL 数据库到 Elasticsearch 中并进行搜索分析

阿里云上拥有丰富的云存储、云数据库产品。如果您希望针对这些产品中的数据进行分析和搜索，可以通过DataWorks的数据集成服务，将离线数据同步到Elasticsearch中，最快可达到5分钟一次。

说明:

做数据同步时可能会产生公网流量费用，请您知晓。

准备工作

完成离线数据的分析与搜索，需要您完成以下几步操作：

- 创建一个数据库，您可以选择使用阿里云的RDS数据库，也可以在本地服务器上自建数据库。本文档以RDS MySQL数据库为例，数据库字段及数据如下图所示。

create_time	category	brand	buyer_id	trans_num	trans_amount	click_cnt
2018-08-21 00:00:00	外	品	1	3	500.6	7
2018-08-22 00:00:00	生	品	1	1	303	8
2018-08-22 00:00:00	外	品	h	2	510	2
1970-01-01 08:00:00	卫	品	h	1	442.5	1
2018-08-22 00:00:00	生	品	h	2	234	3
2018-08-23 00:00:00	外	品	j	9	2000	7
2018-08-23 00:00:00	生	品	j	5	45.1	5
2018-08-23 00:00:00	外	品	j	5	100.2	4
2018-08-24 00:00:00	生	品	p	10	5560	7
2018-08-24 00:00:00	卫	品	p	1	445.6	2
2018-08-24 00:00:00	外	品	r	3	777	3
2018-08-24 00:00:00	卫	品	r	3	122	3
2018-08-24 00:00:00	外	品	r	1	62	7

- 购买一台可以与VPC内的Elasticsearch交互的ECS，这台ECS将获取数据源数据并执行写Elasticsearch数据的任务（该任务将由数据集成系统统一下发）。
- 开通DataWorks的数据集成服务，并且将ECS作为一个可以执行任务的资源，注册到数据集成服务中去。
- 配置一个数据同步的脚本，并且让其可以周期性的执行起来。
- 创建一个Elasticsearch实例，用来存储数据集成系统同步成功的数据。

操作步骤

数据同步

1. #unique_32。
2. 进入Elasticsearch控制台，单击创建，创建一个Elasticsearch实例。

说明:

地域、专有网络、虚拟交换机与您第一步中创建的专有网络保持一致。

3. **购买一台与Elasticsearch服务处于同一个VPC内的ECS服务器，并分配一个公网IP合或开通弹性IP，为了节省您的成本，您可以复用已有的ECS服务器。**

说明:

- **建议使用 centos6、centos7 或者 aliyunos。**
- **如果您添加的 ECS 需要执行 MaxCompute 任务或者同步任务，需要检查当前 ECS 的 python 版本是否是 python2.6或2.7 的版本（centos5 的版本为 2.4，其余 os 自带了 2.6 以上版本）。**
- **请确保 ECS 有公网 IP。**

4. 进入DataWorks 控制台，并进入工作区。

   · 如果您已经开通过DataWorks数据集成产品，您将会看到如下页面：

   · 如果您未开通过DataWorks数据集成产品，您将会看到如下页面。您需要按照步骤开通数据集成服务，此开通动作会产生费用，请您按照费用提示进行预算评估。

5. 单击DataWorks项目下方的进入数据集成。

6. 在数据集成页面，选择左侧导航栏中的资源组，单击新增资源组。

7. 根据界面提示，输入资源组名称和服务器信息。此服务器为您已经购买的ECS服务器，服务器信息说明如下：

- ECS UUID：#unique_33 服务器，执行 `dmidecode | grep UUID`，取返回值。
- 机器 IP/机器CPU（核）/机器内存（GB）：您ECS实例的公网IP/CPU/内存。您可以在ECS控制台上单击实例名称，在配置信息模块，找到相关信息。
- 按照界面提示，完成安装Agent步骤。其中第五步为开通服务器的8000端口，可以跳过，保持系统默认即可。

8. 配置数据库白名单，添加该资源组的IP地址和DataWorks服务器的IP地址，到您的数据库白名单中。配置方法请参见添加白名单。
9. 资源组创建成功后，选择左侧导航栏的数据源，单击新增数据源。

10.单击MySQL，进入新增MySQL数据源页面，填入数据源信息，如下图所示。

数据源类型：本文档以阿里云数据库（RDS）为例，您也可以选择有公网IP和无公网IP。各配置项的详细信息请参见配置MySQL数据源。

11.选择左侧导航栏的同步任务，单击新建，选择脚本模式。

12.在导入模板对话框中，选择数据源类型 > MySQL，数据源为您第10步中新增的数据源名称，目标类型为Elasticsearch，完成后单击确认。

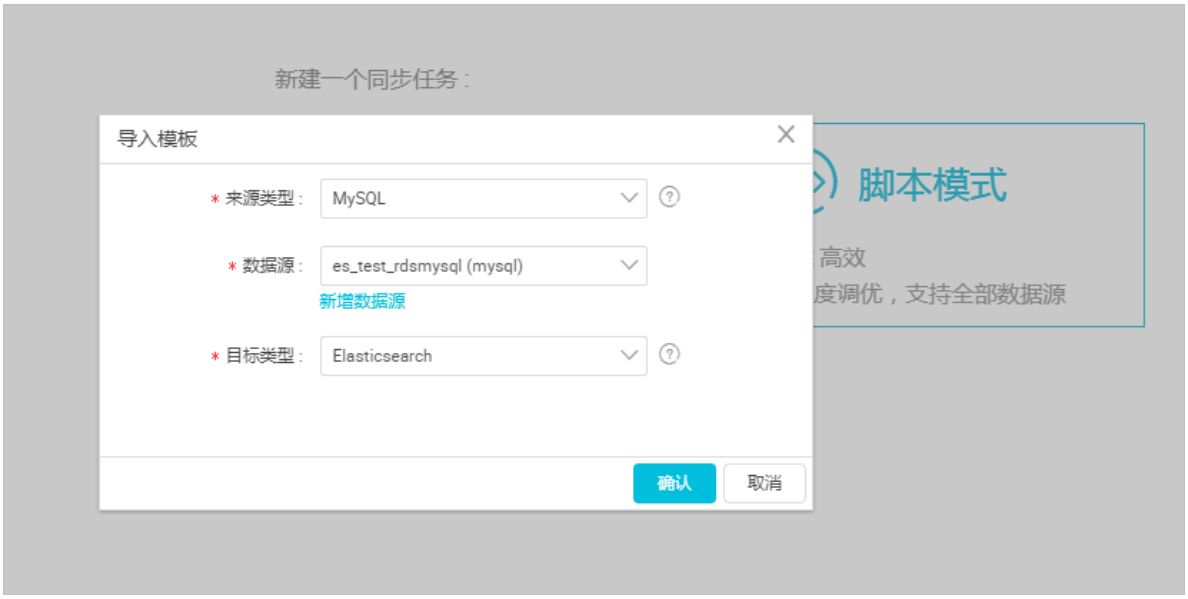

13.配置数据同步脚本。具体配置请参考脚本模式配置，Elasticsearch 的配置规则请参考配置Elasticsearch Writer。


```
{
  "configuration": {
    "reader": {
      "plugin": "mysql",
      "parameter": {
        "datasource": "es_test_rdsmysql",
        "column": [
          "create_time",
          "category",
          "brand",
          "buyer_id",
          "trans_num",
          "trans_amount",
          "click_cnt"
        ],
        "where": "",
        "splitPk": "",
        "table": "good_sale"
      }
    },
    "writer": {
      "plugin": "elasticsearch",
      "parameter": {
        "accessId": "elastic",
        "endpoint": "http://es-cn-                                    aliyuncs.com:9200",
        "indexType": "elasticsearch",
        "accessKey": "          ",
        "cleanup": false,
        "discovery": false,
        "column": [
          {
            "name": "create_time",
            "type": "date"
          },
          {
            "name": "category",
            "type": "string"
          },
          {
            "name": "brand",
            "type": "string"
          },
          {
            "name": "buyer_id",
            "type": "string"
          },
          {
            "name": "trans_num",
            "type": "long"
          },
          {
            "name": "trans_amount",
            "type": "double"
          },
          {
            "name": "click_cnt",
            "type": "long"
          }
        ],
        "index": "testrds",
        "batchSize": 1000,
        "splitter": ","
      }
    },
    "setting": {
      "errorLimit": {
        "record": "0"
      },
      "speed": {
        "throttle": false,
        "concurrent": 1,
        "mbps": "1",
        "dmu": 1
      }
    }
  }
}
```

说明:

- 同步脚本的配置分为三个部分，Reader用来配置您上游数据源（待同步数据的云产品）的config，Writer用来配置 Elasticsearch的config，setting用来配置同步中的一些丢包和最大并发等。
- endpoint为Elasticsearch 的内网或外网地址，如果您使用的是内网地址，请在Elasticsearch的集群配置页面，配置Elasticsearch的系统白名单。如果您是用的是外网地址，请在Elasticsearch的网络配置页面，配置 Elasticsearch的公网地址访问白名单（包括DataWorks服务器的IP地址和您所使用的资源组的IP地址）。
- Elasticsearch Writer中accessId和accessKey需要配置您的Elasticsearch的访问用户名（默认为elastic）和密码。
- index为Elasticsearch实例的索引，您需要使用该索引名称访问Elasticsearch的数据。

14.同步脚本配置完成后，单击页面右侧的配置任务资源组，选择您第7步创建的资源组名称，完成后单击运行，将MySQL中的数据同步到Elasticsearch中。

数据搜索分析

1. 进入Elasticsearch控制台，单击右上角的kibana控制台，选择Dev Tools。
2. 执行如下命令，查看已经同步过来的数据。

```
POST /testrds/_search?pretty
{
"query": { "match_all": {}}
```

```
}
```

testrds为您同步数据时，设置的index字段的值。

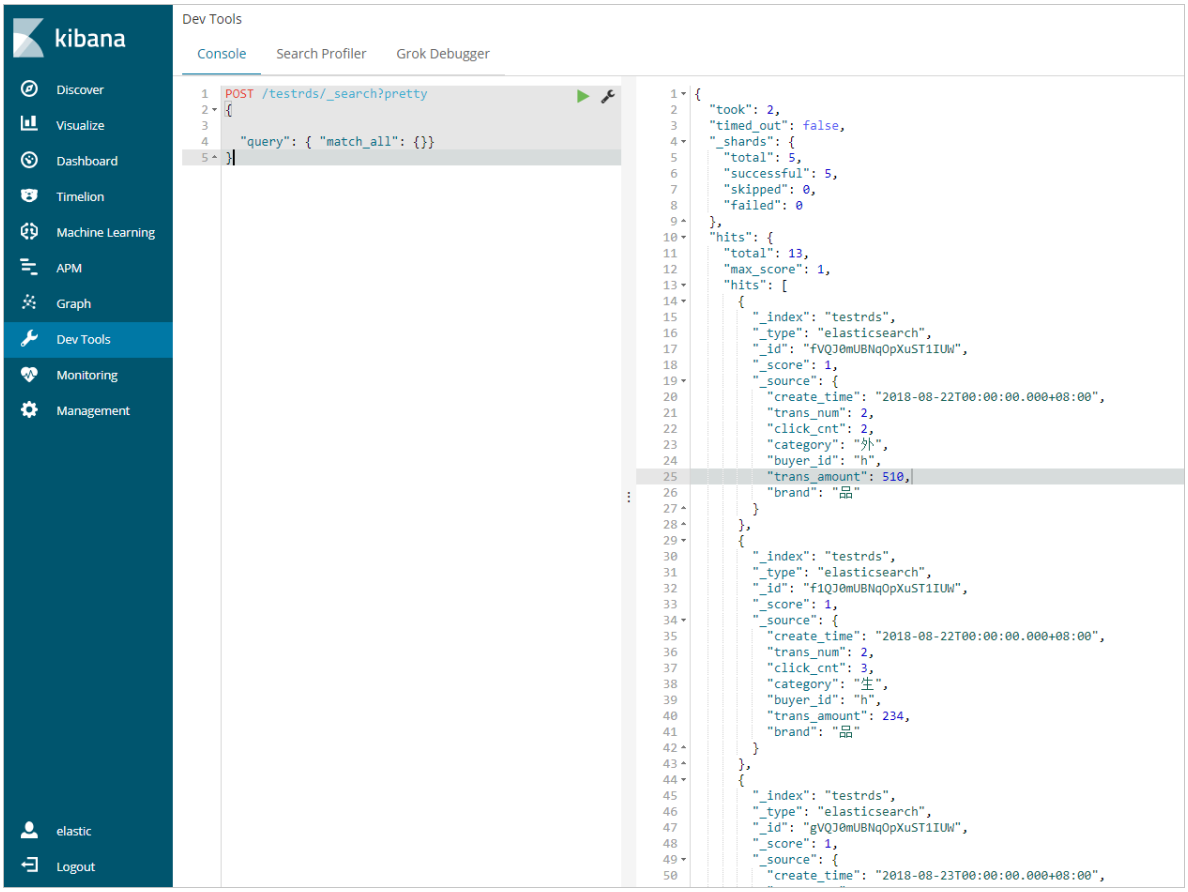

3. 执行如下命令，按照trans_num字段对文档进行排序。

```
POST /testrds/_search?pretty
{
"query": { "match_all": {} },
"sort": { "trans_num": { "order": "desc" } }
}
```

4. 执行如下命令，搜索文档中的category和brand字段。

```
POST /testrds/_search?pretty
{
"query": { "match_all": {} },
"_source": ["category", "brand"]
}
```

5. 执行如下命令，搜索category为生的文档。

```
POST /testrds/_search?pretty
{
"query": { "match": {"category":"生"} }
```

```
}
```


```
{
  "took": 10,
  "timed_out": false,
  "_shards": {
    "total": 5,
    "successful": 5,
    "skipped": 0,
    "failed": 0
  },
  "hits": {
    "total": 4,
    "max_score": 0.6931472,
    "hits": [
      {
        "_index": "testrds",
        "_type": "elasticsearch",
        "_id": "f1QJ0mUBNqOpXuST1IUW",
        "_score": 0.6931472,
        "_source": {
          "create_time": "2018-08-22T00:00:00.000+08:00",
          "trans_num": 2,
          "click_cnt": 3,
          "category": "生",
          "buyer_id": "h",
          "trans_amount": 234,
          "brand": "品"
        }
      },
      {
        "_index": "testrds",
        "_type": "elasticsearch",
        "_id": "gVQJ0mUBNqOpXuST1IUW",
        "_score": 0.6931472,
        "_source": {
          "create_time": "2018-08-23T00:00:00.000+08:00",
          "trans_num": 5,
          "click_cnt": 5,
          "category": "生",
          "buyer_id": "j",
          "trans_amount": 45.1,
          "brand": "品"
        }
      },
      {
        "_index": "testrds",
        "_type": "elasticsearch",
        "_id": "g1QJ0mUBNqOpXuST1IUW",
        "_score": 0.6931472,
        "_source": {
          "create_time": "2018-08-24T00:00:00.000+08:00",
          "trans_num": 10,
```

更多命令和访问方式，请参考ES访问测试 和Elastic.co官方帮助中心。

常见问题

- 同步过程中出现无法连接数据库的相关错误。

  解决方法：将您资源组中所使用的ECS服务器的内网IP和外网IP，都添加到您数据库的白名单中。

- 同步过程中无法连通Elasticsearch实例的相关错误。

  解决方法：按照下面步骤进行排查。

  1. 检查在运行同步脚本之前，是否在页面右侧的配置任务资源组中选择了您前面步骤创建的资源组。
     - 是，执行下一步。
     - 否，单击页面右侧的配置任务资源组，选择您前面步骤创建的资源组。完成后单击运行。
  2. 检查是否在Elasticsearch实例的白名单中，添加了DataWorks服务器的IP地址和您所使用的资源组的IP地址。
     - 是，执行下一步。
     - 否，将DataWorks服务器的IP地址和您所使用的资源组的IP地址，添加到Elasticsearch 实例的白名单中。

     > 说明:
     > 如果您使用的是内网地址，请在Elasticsearch的集群配置页面，配置Elasticsearch的系统白名单。如果您是用的是外网地址，请在Elasticsearch的网络配置页面，配置Elasticsearch的公网地址访问白名单（包括DataWorks服务器的IP地址和您所使用的资源组的IP地址）。
  3. 检查您的同步脚本配置是否正确。包括endpoint（您 Elasticsearch 实例的内网或外网地址）、accessId（Elasticsearch 实例的访问用户名，默认为elastic）和accessKey（Elasticsearch实例的访问密码）。

3.4 RDS for MySQL与阿里云ES实时同步数据

数据传输服务 DTS （以下简称 DTS）支持RDS for MySQL与阿里云Elasticsearch实时同步数据，通过 DTS 提供的 RDS for MySQL->阿里云Elasticsearch实时同步功能，可以将企业线上RDS for MySQL中的生产数据实时同步到阿里云Elasticsearch中进行搜索。本小节介绍如何使用 DTS 快速创建RDS for MySQL->阿里云Elasticsearch的实时同步作业，实现RDS for MySQL数据到阿里云Elasticsearch的实时同步。

支持实时同步类型

同一个阿里云账号下 RDS for MySQL->阿里云Elasticsearch实例。

支持SQL操作类型

主要支持的SQL操作类型如下：

- Insert
- Delete
- Update

> 说明：
> 目前暂不支持 DDL同步，如果同步过程中遇到DDL操作，DTS会忽略掉。

如果后续遇到DDL某个表，则对应表的DML操作可能失败，修复方法为：

1. 参考减少同步对象先将这个对象从同步列表中摘除。
2. 删除阿里云Elasticsearch中这个表对应的索引。
3. 参考 新增同步对象， 修改这个同步作业，将这个表重新添加到同步对象中，进行重新初始化。

如果是修改表、新增列的DDL，建议DDL的操作顺序为：

1. 先在阿里云Elasticsearch中手动修改对应表的mapping，新增列。
2. 再在源RDS for MySQL实例中手动修改表结构，新增列。
3. 暂停DTS同步实例，重启DTS同步实例让DTS重新加载阿里云Elasticsearch中修改后的mapping关系。

配置步骤

下面详细介绍创建RDS for MySQL实例到阿里云Elasticsearch实例同步链路的具体步骤。

1. 购买同步链路

   进入数据传输服务 DTS控制台，进入数据同步界面，点击控制台右上角创建同步作业先购买一个同步链路，购买完同步链路后返回DTS控制台，进行配置同步链路。

   > 说明：

在配置同步链路之前需要先购买一个同步链路，同步链路目前支持包年包月及按量付费两种付费模式，可以根据需要选择不同的付费模式。

购买界面参数

- 功能

  选择数据同步。

- 源实例

  选择MySQL。

- 源实例地域

  - 本示例为RDS for MySQL，需选择RDS for MySQL实例所在地域。

- 目标实例

  选择Elasticsearch。

- 目标实例地域

  阿里云Elasticsearch实例所在地域，订购后不支持更换地域，请谨慎选择。

- 同步拓扑

  选择单项同步。

- 网络类型

  默认为专线，目前仅支持专线模式。

- 同步链路规格

  同步链路规格影响了链路的同步性能，同步链路规格跟性能之间的对应关系详见数据同步规格说明。

- 订购时长

  - 如果是预付费，默认为1个月，支持勾选开启自动续费功能。

- 购买数量

  默认为1，根据业务实际需要进行选择。

说明:

DTS控制台的同步实例按照地域展示，刚才购买的同步实例所属的地域为同步实例的目标地域。例如上面购买的是 杭州RDS for MySQL->杭州阿里云Elasticsearch的同步实例，那么这个同步实例在DTS的杭州地区。进入杭州区域的实例列表，查找刚才购买的同步实例，然后点击新购实例右侧的配置同步作业开始配置实例。

2. 配置同步链路

同步作业名称

同步作业名称没有唯一性要求，为了更方便识别具体的作业，建议选择一个有业务意义的作业名称，方便后续的链路查找及管理。

源实例信息

本示例采用数据源为 RDS for MySQL，需要配置RDS实例的ID、数据库账号、数据库密码。

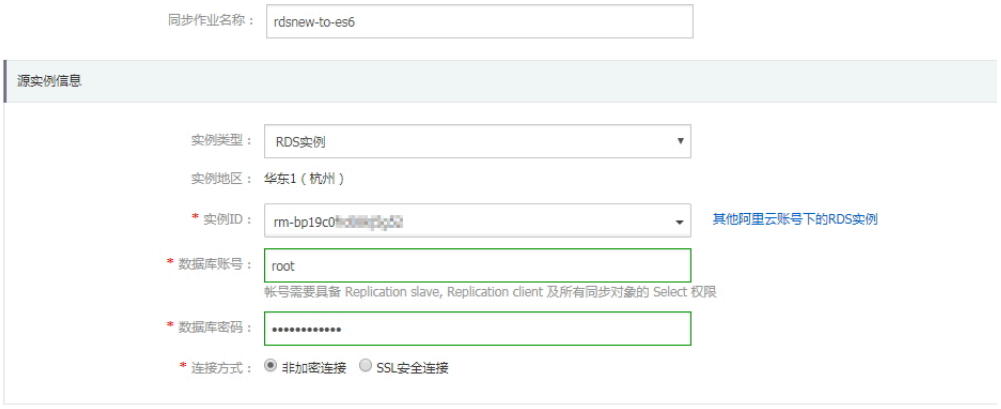

目标实例信息

目标实例信息中需要配置阿里云Elasticsearch的实例ID，及访问阿里云ES实例账号密码。

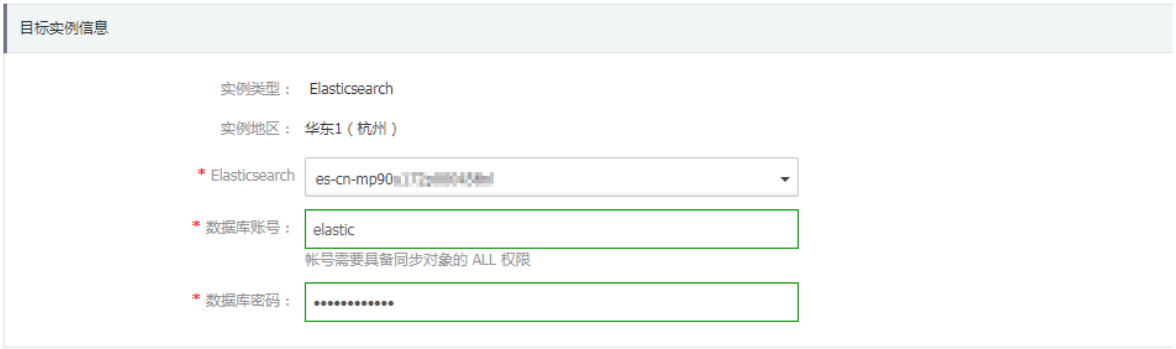

以上内容配置完成后，点击授权白名单并进入下一步进行RDS for MySQL及阿里云Elasticsearch的白名单添加。

3. 授权实例白名单

> 说明:
> 如果是RDS for MySQL，DTS会自动添加白名单或安全组。

如果源实例为RDS for MySQL，那么DTS将自身的IP段添加到RDS实例的白名单的安全组中，避免因为RDS实例设置了白名单，DTS服务器连接不上数据库导致同步作业创建失败。为了保证同步作业的稳定性，在同步过程中，请勿将这些服务器 IP 从 RDS实例的白名单的安全组中删除。

当白名单授权后，点击下一步，进入同步账号创建。

4. 选择同步对象

当白名单授权完成后，即进入同步对象的选择步骤。在这个步骤可以配置需要同步的表列，以及索引的命名规则。

a. 索引名称命名规则可以选择：表名、库名_表名。

- 如果选择了表名，那么索引名称同表名。
- 如果选择了库名表名，那么索引名称的命名格式为：库名表名。例如，库名为：dbtest,表名为：sbtest1，那么这张表同步到阿里云Elasticsearch后，对应的索引名称为：dbtest_sbtest1。
- 如果需要同步的不同库中存在相同名称的表名，建议索引名称命名规则选择：库名_表名。

b. 选择具体需要同步的库表列，实时同步的同步对象的选择粒度可以支持到表级别，即用户可以选择同步某些库或某几张表。

实时同步的同步对象的选择粒度可以支持到表级别，即用户可以选择同步某些库或某几张表。

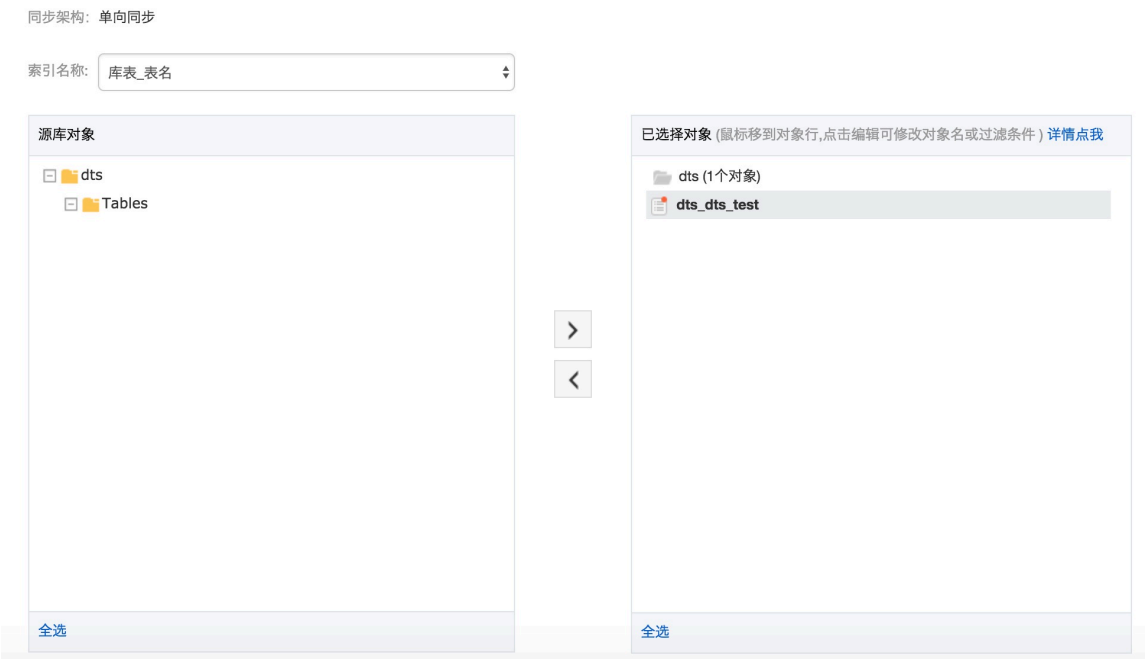

c. 默认所有表的docid为表的主键，如果部分表没有主键，那么对于这部分配置docid 对应的源表的列。在右侧-已选择对象 框中，将鼠标挪到对应表上，点击右侧的 编辑 入口，进入这个表的高级设置界面。

d. 在高级配置中可以设置：

索引名称、Type名称、分区列及分区数定义、_id取值列。其中 _id 取值如果选择 业务主键，那么需要选择对应的业务主键列。

e. 配置完同步对象后，进入高级配置步骤。

5. 高级配置

主要配置

a. 同步初始化类型，建议选择 结构初始化+全量数据初始化，由DTS自动进行索引的创建及全量数据的初始化。如果不选择结构初始化，那么需要在同步创建之前，先手动在阿里

云Elasticsearch中完成索引mapping的定义。如果不选择全量数据初始化，那么DTS同步增量数据的起始时间点为：启动同步的时间点。

b. 索引分片配置，默认为5个分片，1个副本。可以根据业务需要进行调整，一旦调整后，所有的索引按照这个配置定义分片。

c. 字符串analyzer定义，可以选择字符串的analyzer，默认为Standard Analyzer。取值包括：Standard Analyzer、Simple Analyzer、Whitespace Analyzer、Stop Analyzer、Keyword Analyzer、English Analyzer、Fingerprint Analyzer，所有索引的字符串字段按照这个配置定义Analyzer。

d. 时区，可以配置同步到阿里云Elasticsearch中的时间字段存储的时区，默认为东八区。

6. 预检查

同步作业配置完成后，DTS会进行预检查，当预检查通过后，可以点击 启动 按钮，启动同步作业。

同步作业启动后，即进入同步作业列表，此时刚启动的作业处于同步初始化状态。初始化的时间长度取决于源实例中同步对象的数据量大小，初始化完成后，同步链路即进入同步中的状态，此时源跟目标实例的同步链路才真正建立。

7. 数据效验

以上任务完执行成后，登录阿里云ES控制台，确认对应阿里云ES实例中有无创建对应索引，及同步的数据是否符合预期。

3.5 使用DataWorks实现MaxCompute与阿里云ES数据同步

阿里云上拥有丰富的云存储、云数据库产品。如果您希望对这些产品中的数据进行分析和搜索，可以通过DataWorks的数据集成服务，将离线数据同步到阿里云Elasticsearch中进行搜索分析，最快可达到5分钟一次。

说明:

做数据同步时可能会产生公网流量费用，请您知晓。

准备工作

完成离线数据的分析与搜索，您需要完成以下几步操作：

- 创建和查看表，并导入数据。实际情况中，您可以将Hadoop数据迁移MaxCompute最佳实践再进行同步，本案例使用的表结构和部分数据如下：

列名	类型
create_time	STRING
category	STRING
brand	STRING
buyer_id	STRING
trans_num	BIGINT
trans_amount	DOUBLE
click_cnt	BIGINT
pt	STRING

create_time	category	brand	buyer_id	trans_num	trans_amount	click_cnt	pt
2018-08-21 00:00:00	外套	品牌A	null	null	null	null	1
2018-08-22 00:00:00	生鲜	品牌B	null	null	null	null	1
2018-08-22 00:00:00	外套	品牌C	null	null	null	null	1
	卫浴	品牌A	null	null	null	null	1
2018-08-22 00:00:00	生鲜	品牌D	null	null	null	null	1
2018-08-23 00:00:00	外套	品牌B	null	null	null	null	1
2018-08-23 00:00:00	生鲜	品牌A	null	null	null	null	1
2018-08-23 00:00:00	外套	品牌E	null	null	null	null	1
2018-08-24 00:00:00	生鲜	品牌G	null	null	null	null	1
2018-08-24 00:00:00	卫浴	品牌F	null	null	null	null	1
2018-08-24 00:00:00	外套	品牌A	null	null	null	null	1
2018-08-24 00:00:00	卫浴	品牌G	null	null	null	null	1
2018-08-24 00:00:00	外套	品牌C	null	null	null	null	1

- 创建一个阿里云Elasticsearch实例，用来存储数据集成系统同步成功的数据。
- 购买一台与阿里云Elasticsearch相同VPC的阿里云ECS，这台ECS将获取数据源数据并执行写阿里云Elasticsearch数据的任务（该任务将由数据集成系统统一下发）。
- 开通DataWorks数据集成服务，并且将ECS作为一个可以执行任务的资源，注册到数据集成服务中去。
- 配置一个数据同步脚本，并让其周期性执行。

操作步骤

1. 创建阿里云Elasticsearch和ECS实例

   a. #unique_32，本案例创建了一个位于华东1区，名称为es_test_vpc的专有网络，对应的交换机名称为es_test_switch。

   b. 进入阿里云Elasticsearch控制台，创建一个阿里云Elasticsearch实例。

   

   说明:

地域、专有网络、虚拟交换机与您第一步中创建的专有网络保持一致。

c. 购买一台与阿里云Elasticsearch实例处于同一个VPC内的ECS服务器，并分配一个公网IP或开通弹性IP，为了节省您的成本，您可以复用已有且符合条件的ECS服务器。

本案例创建了一个位于华东1，可用区F的ECS实例，使用CentOS 7.4 64位系统，并勾选分配公网地址，网络配置如下：

说明:

· 建议使用CentOS 6、CentOS 7 或者 Aliyun Linux。

- 如果您添加的ECS需要执行MaxCompute任务或者同步任务，需要检查当前ECS的python版本是否是python2.6或2.7 的版本（CentOS 5 的版本为2.4，其余CentOS自带了2.6以上版本）。
- 请确保 ECS 有公网 IP。

2. 配置数据同步

a. 进入DataWorks控制台创建项目，本案例使用名称为bigdata_DOC的DataWorks项目。

· 如果您已经开通过DataWorks数据集成产品，您将会看到如下页面：

· 如果您未开通过DataWorks数据集成产品，将会看到如下页面。您需要按照步骤开通数据集成服务，此开通动作会产生费用，请您按照费用提示进行预算评估。

b. 单击DataWorks项目下方的进入数据集成。

c. 创建资源组。

A. 在数据集成页面，选择左侧导航栏中的资源组，单击新增资源组。

B. 按照以下步骤，完成资源组的添加：

A. 创建资源组：自定义输入资源组名称，本案例的资源组名称为es_test_resource。

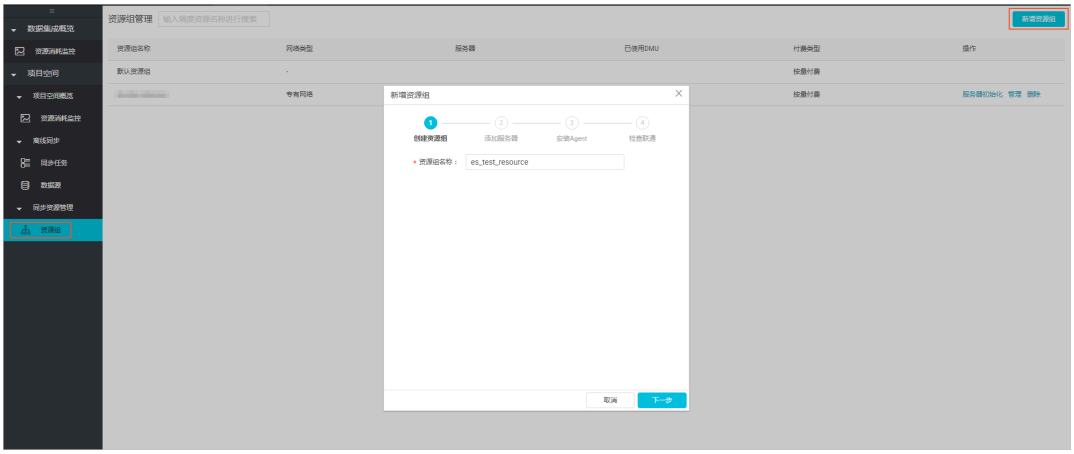

B. 添加服务器。

- ECS UUID：#unique_33 服务器，执行 `dmidecode | grep UUID`，取返回值。

- 机器 IP/机器CPU（核）/机器内存（GB）：ECS实例的公网IP/CPU/内存。进入ECS控制台，单击实例名称链接，在配置信息模块，可以找到相关信息。

C. 安装Agent：按照界面提示，完成安装Agent步骤。由于本案例使用的是VPC网络，不需要开通服务器的8000端口。

D. 检查联通：联通成功后，状态会显示为可用。如果状态为不可用，您可以登录该ECS服务器，使用`tail -f /home/admin/alisatasknode/logs/heartbeat.log`命令查看DataWorks与该ECS服务器之间心跳报文是否超时。

d. 添加数据源。

A. 在数据集成页面，选择左侧导航栏中的数据源，单击新增数据源。

B. 选择数据源类型为MaxCompute。

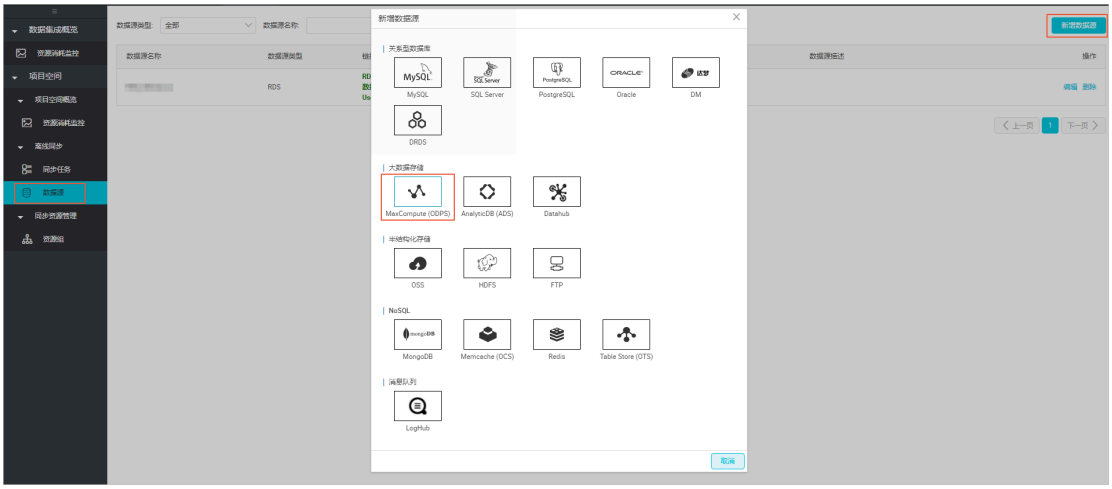

C. 输入数据源信息，本案例创建的数据源名称为odps_es，如下所示。

- **ODPS空间名称：在DataWorks的数据开发页面，表对应的空间名称显示在左上角图标右侧，如下图所示：**

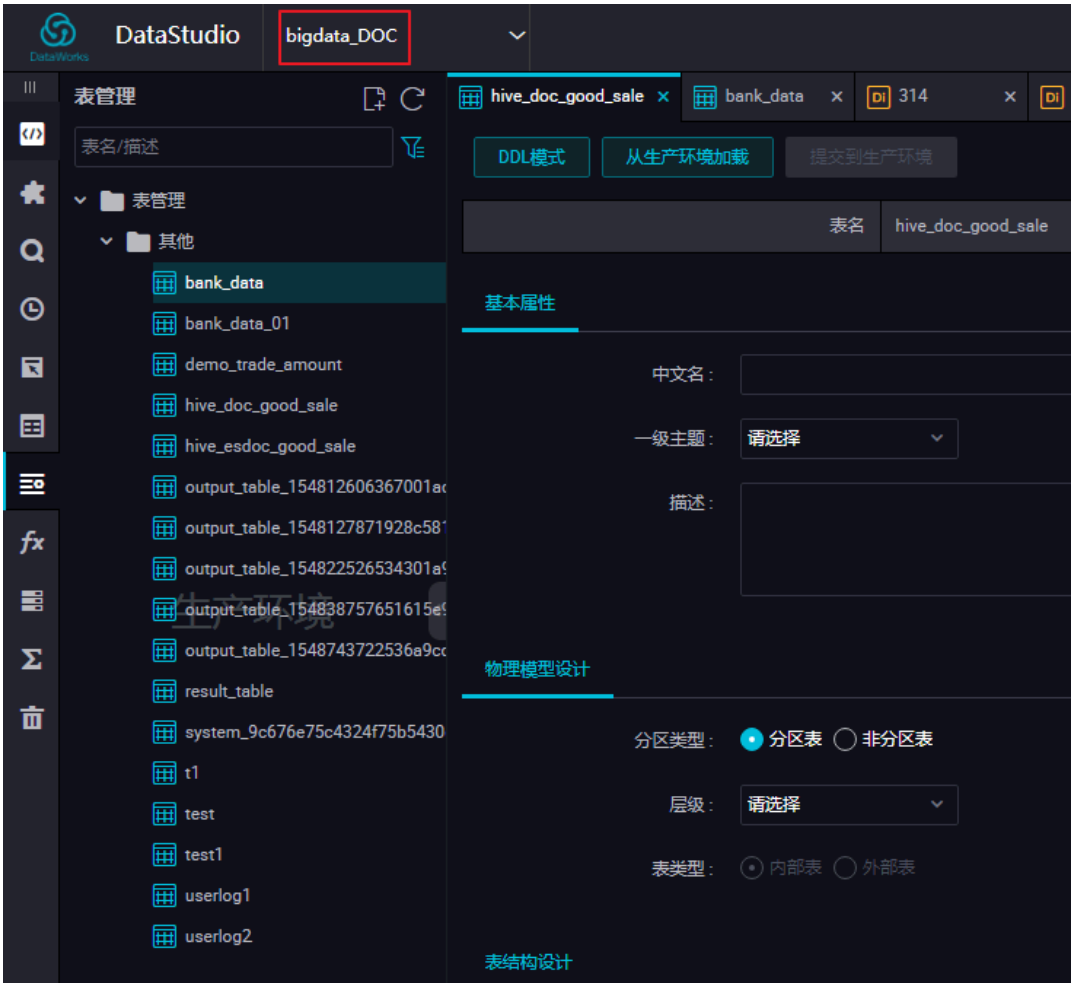

- Access Id/Access Key：鼠标移至您的用户名称上，选择用户信息，如下图所示：

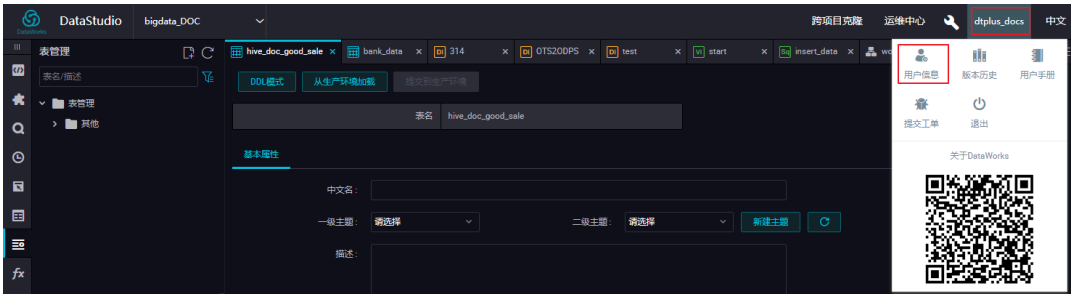

在个人信息页面，鼠标移至您的用户头像上，单击accesskeys进行获取，如下图所示：

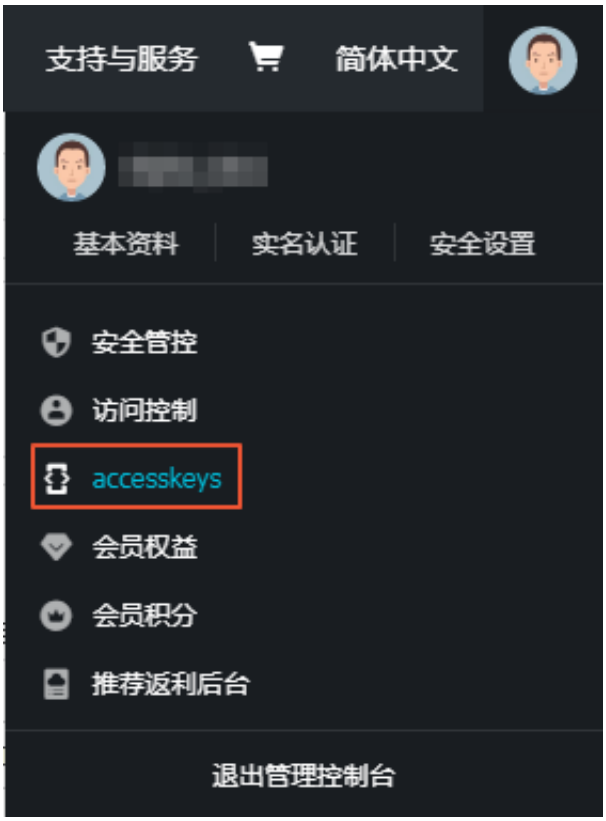

e. 配置同步任务。

A. 在数据开发页面，单击左侧菜单栏中的数据开发，打开业务流程导航栏：

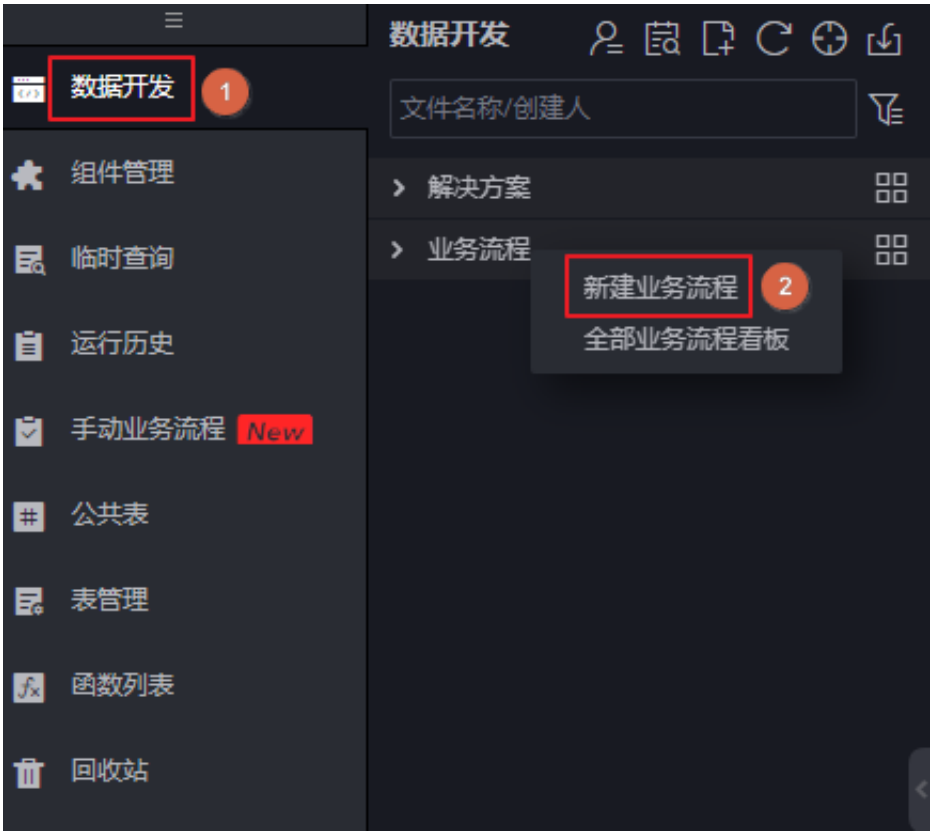

B. 右键单击导航栏中的数据集成，选择新建数据集成节点 > 同步节点，输入同步任务名称：

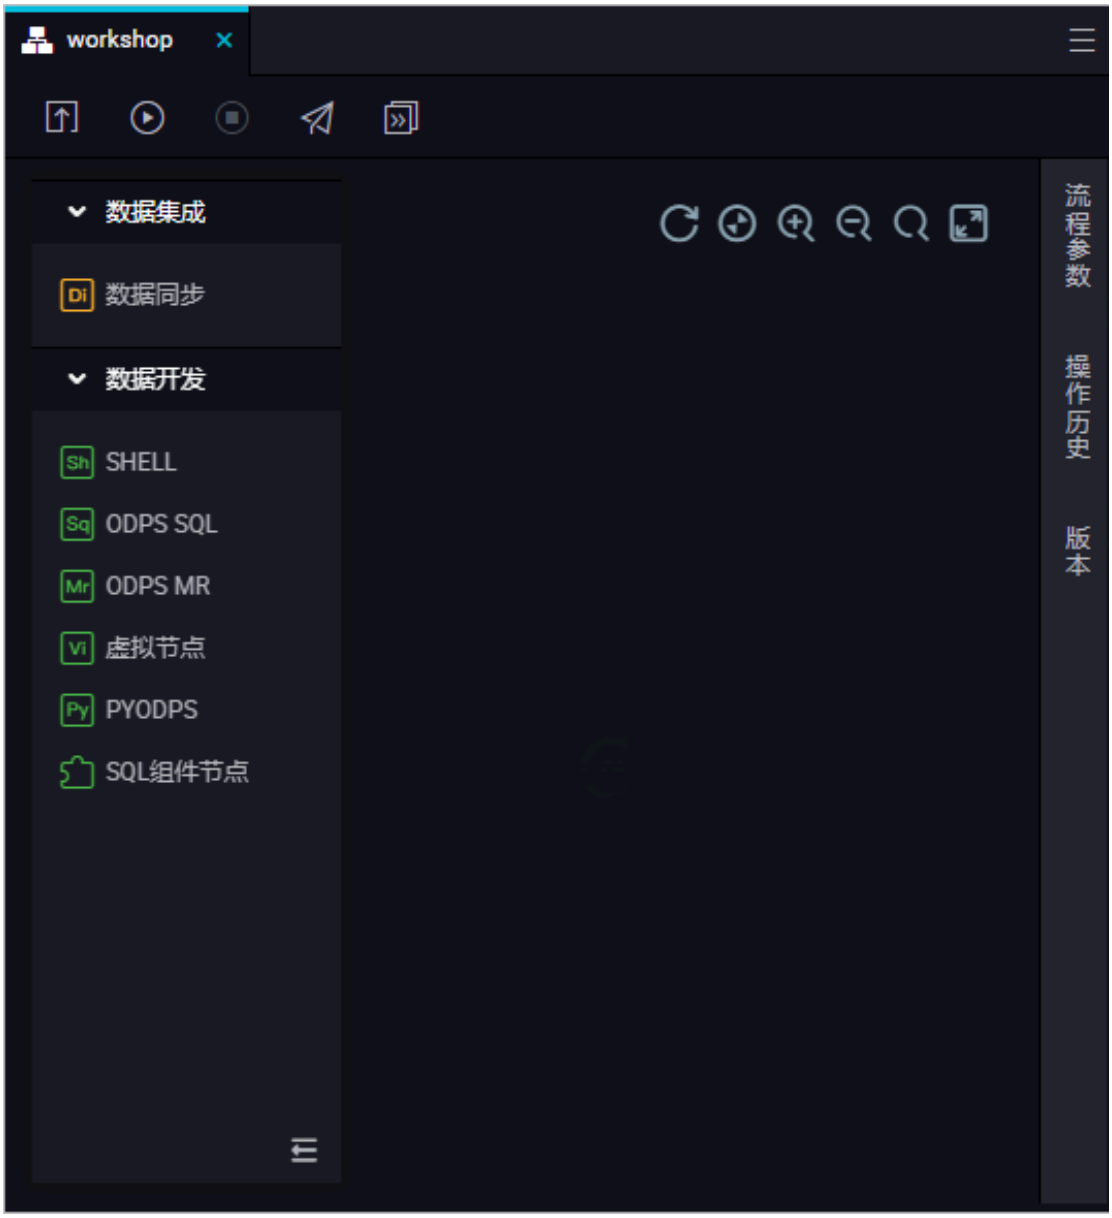

C. 成功创建同步节点后，单击新建同步节点右上角的转换脚本，选择确认即可进入脚本模式：

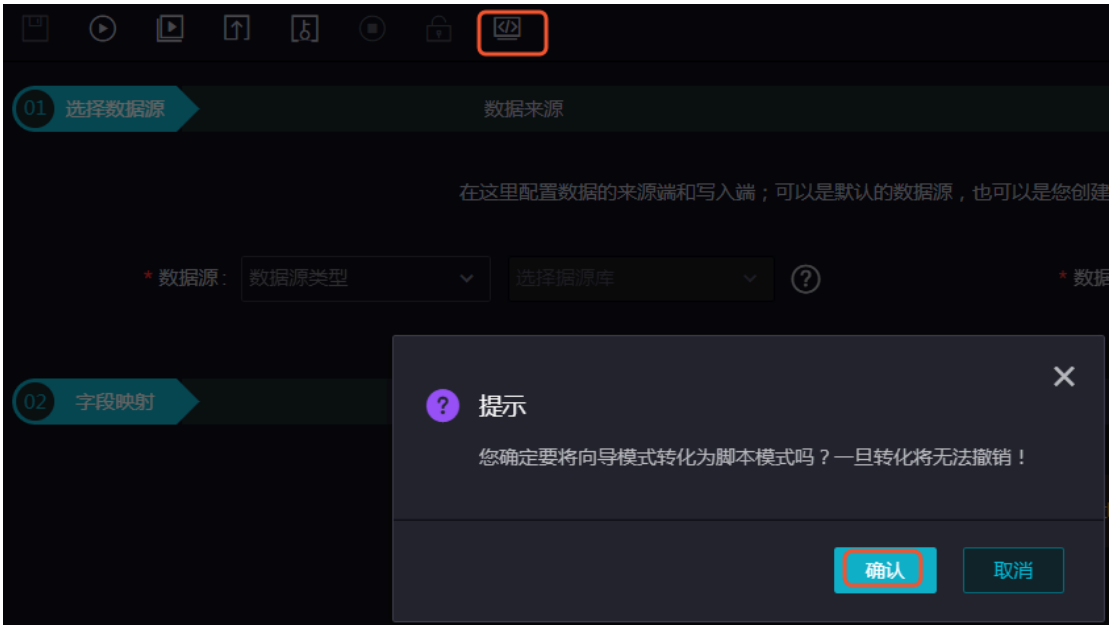

D. 单击脚本模式右上角的导入模板，在弹框中分别选择读取端的来源类型和数据源、写入端的目标类型和数据源，单击确认生成初始脚本：

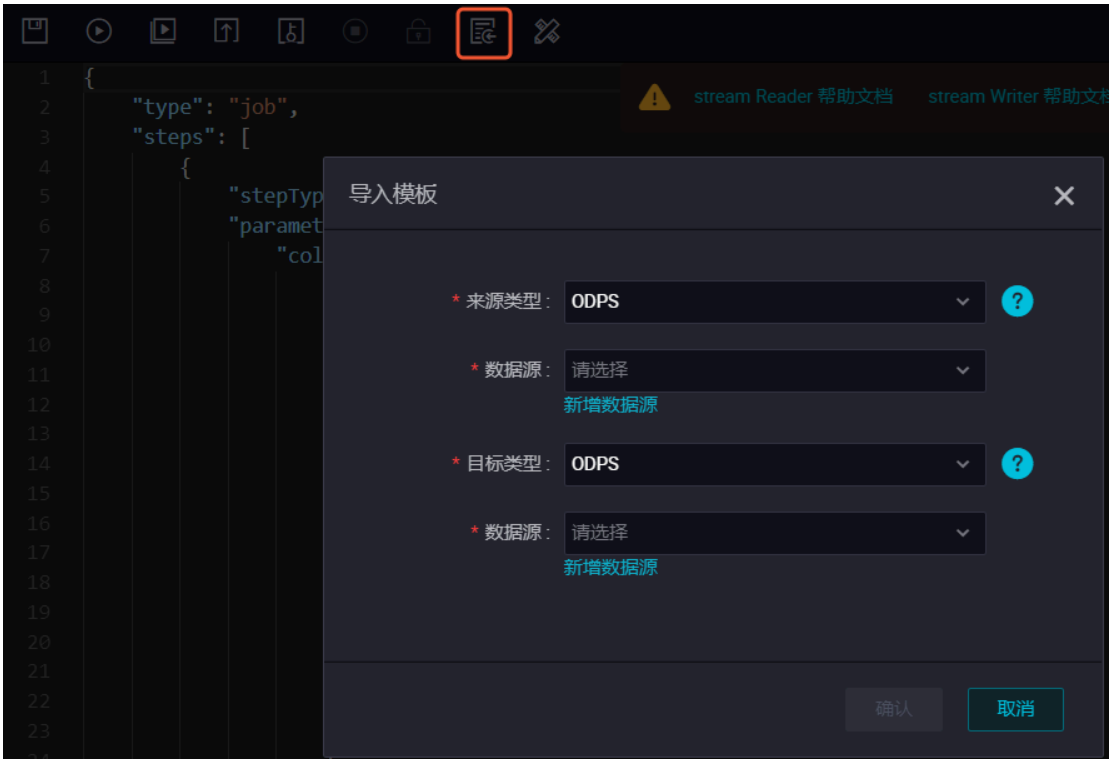

E. 配置数据同步脚本，具体配置请参考脚本模式配置，Elasticsearch的配置规则请参考配置Elasticsearch Writer。

```
"reader": {
  "plugin": "odps",
  "parameter": {
    "partition": "pt=1",
    "datasource": "odps_es",
    "column": [
      "create_time",
      "category",
      "brand",
      "buyer_id",
      "trans_num",
      "trans_amount",
      "click_cnt"
    ],
    "table": "hive_doc_good_sale"
  }
},
"writer": {
  "plugin": "elasticsearch",
  "parameter": {
    "accessId": "elastic",
    "endpoint": "http://es-cn-mp[redacted].elasticsearch.aliyuncs.com:9200",
    "indexType": "elasticsearch",
    "accessKey": "[redacted]",
    "cleanup": true,
    "discovery": false,
    "column": [
      {
        "name": "create_time",
        "type": "string"
      },
      {
        "name": "category",
        "type": "string"
      },
      {
        "name": "brand",
        "type": "string"
      },
      {
        "name": "buyer_id",
        "type": "string"
      },
      {
        "name": "trans_num",
        "type": "long"
      },
      {
        "name": "trans_amount",
        "type": "double"
      },
      {
        "name": "click_cnt",
        "type": "long"
      }
    ],
    "index": "es_index",
    "batchSize": 1000,
```


说明:

- 同步脚本的配置分为三个部分，Reader用来配置您上游数据源（待同步数据的云产品）的config，Writer用来配置阿里云Elasticsearch的config，setting用来配置同步中的一些丢包和最大并发等。
- endpoint为阿里云Elasticsearch的内网或外网地址，本案例使用内网地址，所以不用配置白名单。如果您是用的是外网地址，请在阿里云Elasticsearch的网络配

置页面，配置阿里云Elasticsearch的公网地址访问白名单（包括DataWorks服务器的IP地址和您所使用的资源组的IP地址）。

- Elasticsearch Writer中accessId和accessKey需要配置您的阿里云Elasticsearch的访问用户名（默认为elastic）和密码。
- index为阿里云Elasticsearch实例的索引，您需要使用该索引名称访问阿里云Elasticsearch的数据。本案例中的index名为es_index。
- 如果您的ODPS表是一个分区表，需要在partition字段中设置分区信息，本案例中的分区信息为pt=1。

配置代码示例如下：

```
{
"configuration": {
"reader": {
"plugin": "odps",
"parameter": {
  "partition": "pt=1",
  "datasource": "odps_es",
  "column": [
    "create_time",
    "category",
    "brand",
    "buyer_id",
    "trans_num",
    "trans_amount",
    "click_cnt"
  ],
  "table": "hive_doc_good_sale"
}
},
"writer": {
"plugin": "elasticsearch",
"parameter": {
  "accessId": "elastic",
  "endpoint": "http://es-cn-mpXXXXXXX.elasticsearch.aliyuncs.
com:9200",
  "indexType": "elasticsearch",
  "accessKey": "XXXXXX",
  "cleanup": true,
  "discovery": false,
  "column": [
    {
      "name": "create_time",
      "type": "string"
    },
    {
      "name": "category",
      "type": "string"
    },
    {
      "name": "brand",
      "type": "string"
    },
    {
      "name": "buyer_id",
      "type": "string"
```

```
      },
      {
        "name": "trans_num",
        "type": "long"
      },
      {
        "name": "trans_amount",
        "type": "double"
      },
      {
        "name": "click_cnt",
        "type": "long"
      }
    ],
    "index": "es_index",
    "batchSize": 1000,
    "splitter": ","
}
},
"setting": {
"errorLimit": {
  "record": "0"
},
"speed": {
  "throttle": false,
  "concurrent": 1,
  "mbps": "1",
  "dmu": 1
}
}
},
"type": "job",
"version": "1.0"
}
```

F. 同步脚本配置完成后，单击运行，将ODPS中的数据同步到阿里云Elasticsearch中。

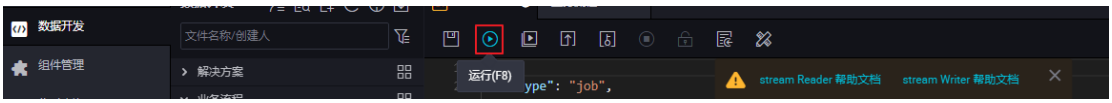

3. 结果验证

a. 进入阿里云Elasticsearch控制台，单击右上角的kibana控制台，选择Dev Tools。

b. 执行如下命令，查看数据是否已经同步到ES中。

```
POST /es_index/_search?pretty
{
"query": { "match_all": {}}
```

```
}
```

es_index为您同步数据时，设置的index字段的值。

如果数据同步成功，会显示以下界面：

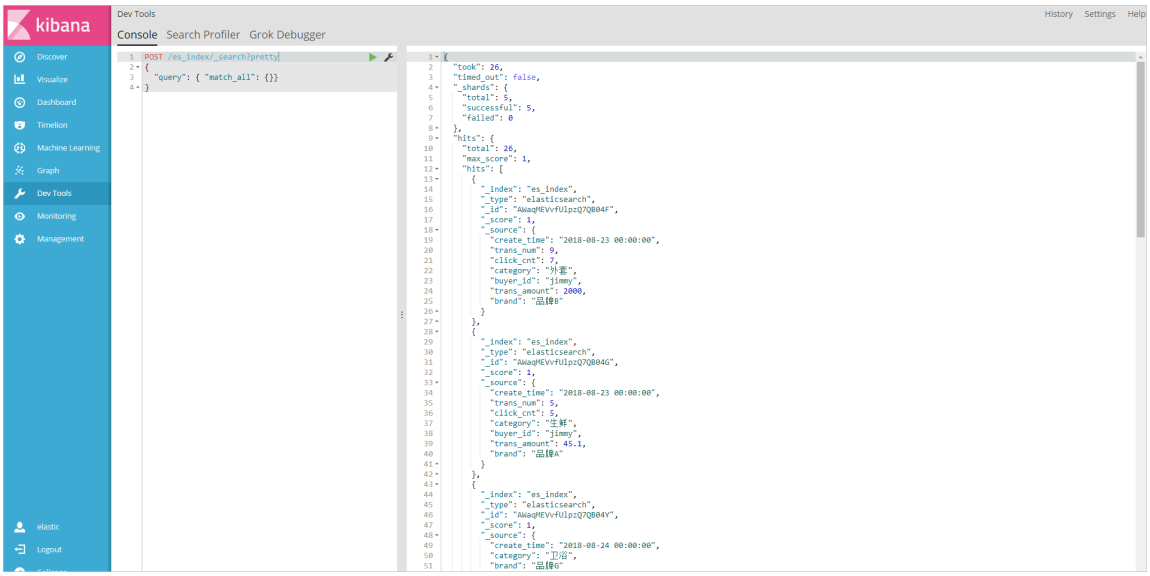

c. 执行如下命令，按照trans_num字段对文档进行排序。

```
POST /es_index/_search?pretty
{
"query": { "match_all": {} },
"sort": { "trans_num": { "order": "desc" } }
}
```

d. 执行如下命令，搜索文档中的category和brand字段。

```
POST /es_index/_search?pretty
{
"query": { "match_all": {} },
"_source": ["category", "brand"]
}
```

e. 执行如下命令，搜索category为生鲜的文档。

```
POST /es_index/_search?pretty
{
"query": { "match": {"category":"生鲜"} }
}
```

更多命令和访问方式，请参考ES访问测试和Elastic.co官方帮助中心。

常见问题

无法连通阿里云ES实例相关报错

1. 检查在运行同步脚本之前，是否在页面右侧的配置任务资源组中选择了您前面步骤创建的资源组。
   - 是，执行下一步。
   - 否，单击页面右侧的配置任务资源组，选择您前面步骤创建的资源组，完成后单击运行。
2. 检查您的同步脚本配置是否正确，包括endpoint（您的阿里云Elasticsearch实例的内网或外网地址，使用外网地址需要配置公网地址访问白名单）、accessId（阿里云Elasticsearch实例的访问用户名，默认为elastic）和accessKey（阿里云Elasticsearch实例的访问密码）。

3.6 通过ES-Hadoop将Hadoop数据写入阿里云Elasticsearch

本文档为您演示如何使用E-MapReduce，通过ES-Hadoop直接将数据写入阿里云Elasticsearch中。

支持版本

阿里云Elasticsearch 5.5.3 with Commercial Feature。

准备工作

在开始本案例前，您需要首先开通如下的阿里云产品：

- 专有网络VPC：由于通过公网访问推送数据安全性较差，为保证阿里云Elasticsearch访问环境安全，对应区域下必须要有VPC和虚拟交换机，因此需开通VPC专有网络。
- OSS：在本示例中将E-MapReduce的日志存储在OSS上，在开通配置E-MapReduce前需开通OSS并创建完成Bucket。
- Elasticsearch
- E-MapReduce

请参考以下步骤开通上述阿里云产品：

1. 开通阿里云VPC。
   a. 登录阿里云首页，选择产品 > 云计算基础 > 网络 > 创建网络环境 > 专有网络VPC，然后单击立即开通。
   b. 进入到VPC管理控制台界面，新建专有网络。
   c. 创建完成之后在控制台中可以进行管理。

> 说明：
> 更多关于专有网络VPC的文档请参专有网络VPC 。

2. 开通专有网络OSS。
   a. 登录阿里云首页，选择产品 > 云计算基础 > 存储服务 > 云存储 > 对象存储 OSS，然后单击立即开通。
   b. 进入到OSS管理控制台界面，单击新建 Bucket。

      
      说明:
      Bucket的区域要和E-MapReduce集群的区域一致，本示例将区域均选择为华东1区。

   c. 根据界面提示完成Bucket创建。
3. 开通阿里云Elasticsearch。
   a. 登录阿里云首页后选择产品 > 大数据 > 大数据搜索与分析 > Elasticsearch，进入阿里云Elasticsearch产品界面。

      
      说明:
      新用户可以免费试用30天。

   b. 购买成功后，在Elasticsearch控制台可以看到新创建的Elasticsearch集群实例。
4. 开通阿里云E-MapReduce。
   a. 登录阿里云首页，选择产品 > 大数据 > 大数据计算 > E-MapReduce，进入E-MapReduce产品页面。
   b. 单击立即购买，根据界面提示完成参数配置。
   c. E-MapReduce集群创建成功后在集群列表中查看，也可通过以下操作验证集群创建结果：
      - 公网IP可以直接访问，远程登录：

        ```
        ssh root@你的公网IP
        ```

      - 使用jps命令查看后台进程：

        ```
        [root@emr-header-1 ~]# jps
        16640 Bootstrap
        17988 RunJar
        19140 HistoryServer
        18981 WebAppProxyServer
        14023 Jps
        15949 gateway.jar
        16621 ZeppelinServer
        1133 EmrAgent
        15119 RunJar
        17519 ResourceManager
        1871 Application
        19316 JobHistoryServer
        1077 WatchDog
        17237 SecondaryNameNode
        16502 NameNode
        16988 ApacheDsTanukiWrapper
        ```

```
18429 ApplicationHistoryServer
```

写数据到ES的MR作业开发

推荐使用maven来进行项目管理，操作步骤如下：

1. 安装 Maven。

   首先确保计算机已经正确安装maven。

2. 生成工程框架。

   在工程根目录处执行如下命令：

   ```
   mvn archetype:generate -DgroupId=com.aliyun.emrtoes -DartifactId=
   emrtoes -DarchetypeArtifactId=maven-archetype-quickstart -Dinteracti
   veMode=false
   ```

   maven会自动生成一个空的Sample工程，工程名为emrtoes（和指定的artifactId一致），里面包含一个简单的*pom.xml*文件和App类（类的包路径和指定的groupId一致）。

3. 加入Hadoop和ES-Hadoop依赖。

   使用任意IDE打开这个工程，编辑*pom.xml*文件。在dependencies内添加如下内容：

   ```
   <dependency>
         <groupId>org.apache.hadoop</groupId>
         <artifactId>hadoop-mapreduce-client-common</artifactId>
         <version>2.7.3</version>
     </dependency>
     <dependency>
         <groupId>org.apache.hadoop</groupId>
         <artifactId>hadoop-common</artifactId>
         <version>2.7.3</version>
     </dependency>
      <dependency>
          <groupId>org.elasticsearch</groupId>
          <artifactId>elasticsearch-hadoop-mr</artifactId>
          <version>5.5.3</version>
      </dependency>
   ```

4. 添加打包插件。

   由于使用了第三方库，需要把第三方库打包到jar文件中，在*pom.xml*中添加maven-assembly-plugin插件的坐标。

   ```
   <plugins>
      <plugin>
        <artifactId>maven-assembly-plugin</artifactId>
        <configuration>
          <archive>
            <manifest>
              <mainClass>com.aliyun.emrtoes.EmrToES</mainClass>
            </manifest>
          </archive>
          <descriptorRefs>
            <descriptorRef>jar-with-dependencies</descriptorRef>
   ```

```
        </descriptorRefs>
      </configuration>
      <executions>
        <execution>
          <id>make-assembly</id>
          <phase>package</phase>
          <goals>
            <goal>single</goal>
          </goals>
        </execution>
      </executions>
    </plugin>
    <plugin>
      <groupId>org.apache.maven.plugins</groupId>
      <artifactId>maven-shade-plugin</artifactId>
      <version>3.1.0</version>
      <executions>
        <execution>
          <phase>package</phase>
          <goals>
            <goal>shade</goal>
          </goals>
          <configuration>
            <transformers>
              <transformer implementation="org.apache.maven.plugins.
shade.resource.ApacheLicenseResourceTransformer">
              </transformer>
            </transformers>
          </configuration>
        </execution>
      </executions>
    </plugin>
  </plugins>
```

5. **编写代码。**

   在`com.aliyun.emrtoes`**包下和App类平行的位置添加新类***EmrToES.java*，**内容如下。**

```
package com.aliyun.emrtoes;
 import org.apache.hadoop.conf.Configuration;
 import org.apache.hadoop.fs.Path;
 import org.apache.hadoop.io.NullWritable;
 import org.apache.hadoop.io.Text;
 import org.apache.hadoop.mapreduce.Job;
 import org.apache.hadoop.mapreduce.Mapper;
 import org.apache.hadoop.mapreduce.lib.input.FileInputFormat;
 import org.apache.hadoop.mapreduce.lib.input.TextInputFormat;
 import org.apache.hadoop.util.GenericOptionsParser;
 import org.elasticsearch.hadoop.mr.EsOutputFormat;
 import java.io.IOException;
 public class EmrToES {
     public static class MyMapper extends Mapper<Object, Text,
NullWritable, Text> {
         private Text line = new Text();
         @Override
         protected void map(Object key, Text value, Context context)
                 throws IOException, InterruptedException {
             if (value.getLength() > 0) {
                 line.set(value);
                 context.write(NullWritable.get(), line);
             }
         }
     }
```

```
     public static void main(String[] args) throws IOException,
ClassNotFoundException, InterruptedException {
         Configuration conf = new Configuration();
         String[] otherArgs = new GenericOptionsParser(conf, args).
getRemainingArgs();
         //阿里云 Elasticsearch X-PACK用户名和密码
         conf.set("es.net.http.auth.user", "你的X-PACK用户名");
         conf.set("es.net.http.auth.pass", "你的X-PACK密码");
         conf.setBoolean("mapred.map.tasks.speculative.execution",
false);
         conf.setBoolean("mapred.reduce.tasks.speculative.execution
", false);
         conf.set("es.nodes", "你的Elasticsearch内网地址");
         conf.set("es.port", "9200");
         conf.set("es.nodes.wan.only", "true");
         conf.set("es.resource", "blog/yunqi");
         conf.set("es.mapping.id", "id");
         conf.set("es.input.json", "yes");
         Job job = Job.getInstance(conf, "EmrToES");
         job.setJarByClass(EmrToES.class);
         job.setMapperClass(MyMapper.class);
         job.setInputFormatClass(TextInputFormat.class);
         job.setOutputFormatClass(EsOutputFormat.class);
         job.setMapOutputKeyClass(NullWritable.class);
         job.setMapOutputValueClass(Text.class);
         FileInputFormat.setInputPaths(job, new Path(otherArgs[0]));
         System.exit(job.waitForCompletion(true) ? 0 : 1);
     }
 }
```

上述代码的相关说明请参见下文的API分析。

6. 编译并打包。

   在工程的目录下，执行如下命令：

```
mvn clean package
```

   执行完毕以后，可在工程目录的target目录下看到一个*emrtoes-1.0-SNAPSHOT-jar-with-dependencies.jar*，这个就是作业jar包。

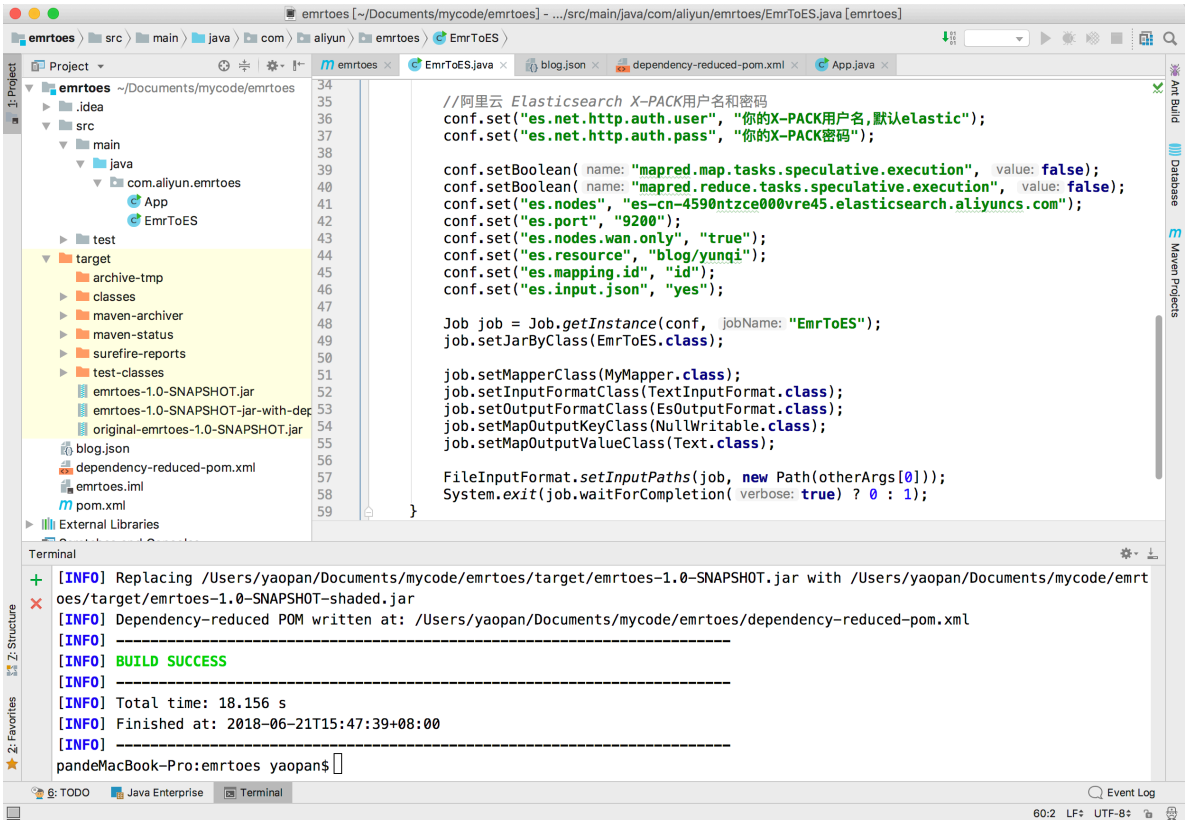

EMR中完成作业

1. 测试数据。

   a. 把下面的数据写入到*blog.json*中。

```
{"id":"1","title":"git简介","posttime":"2016-06-11","content":"svn与git的最主要区别..."}
{"id":"2","title":"ava中泛型的介绍与简单使用","posttime":"2016-06-12","content":"基本操作: CRUD ..."}
{"id":"3","title":"SQL基本操作","posttime":"2016-06-13","content":"svn与git的最主要区别..."}
{"id":"4","title":"Hibernate框架基础","posttime":"2016-06-14","content":"Hibernate框架基础..."}
```

```
{"id":"5","title":"Shell基本知识","posttime":"2016-06-15","content
":"Shell是什么..."}
```

b. 使用scp远程拷贝命令，将*blog.json*文件上传到阿里云E-MapReduce集群中。

```
scp blog.json root@你的弹性公网IP:/root
```

c. 执行以下命令，将*blog.json*文件上传至HDFS。

```
hadoop fs -mkdir /work
```

```
hadoop fs -put blog.json /work
```

2. 上传JAR包。

   执行以下命令，将上文创建的maven工程target目录下的jar包上传至阿里云E-MapReduce集群。

```
scp target/emrtoes-1.0-SNAPSHOT-jar-with-dependencies.jar root@YourIP:/root
```

3. 使用以下命令，执行MR作业。

```
hadoop jar emrtoes-1.0-SNAPSHOT-jar-with-dependencies.jar /work/blog.json
```

   运行成功后，控制台会输出如下图所示的信息。

```
1. root@emr-header-1:~ (ssh)
[root@emr-header-1 ~]# hadoop jar emrtoes-1.0-SNAPSHOT-jar-with-dependencies.jar /work/blog.json
SLF4J: Class path contains multiple SLF4J bindings.
SLF4J: Found binding in [jar:file:/opt/apps/ecm/service/hadoop/2.7.2-1.2.11/package/hadoop-2.7.2-1.2.11/share/hadoop/common/lib/slf4j-log4j12-1.7.10.jar!/org/slf4j/impl/StaticLoggerBinder.class]
SLF4J: Found binding in [jar:file:/opt/apps/ecm/service/tez/0.8.4/package/tez-0.8.4/lib/slf4j-log4j12-1.7.10.jar!/org/slf4j/impl/StaticLoggerBinder.class]
SLF4J: See http://www.slf4j.org/codes.html#multiple_bindings for an explanation.
SLF4J: Actual binding is of type [org.slf4j.impl.Log4jLoggerFactory]
18/06/21 15:53:18 INFO impl.TimelineClientImpl: Timeline service address: http://emr-header-1.cluster-67561:8188/ws/v1/timeline/
18/06/21 15:53:18 INFO client.RMProxy: Connecting to ResourceManager at emr-header-1.cluster-67561/192.168.0.103:8032
18/06/21 15:53:19 INFO input.FileInputFormat: Total input paths to process : 1
18/06/21 15:53:19 INFO mapreduce.JobSubmitter: number of splits:1
18/06/21 15:53:19 INFO Configuration.deprecation: mapred.reduce.tasks.speculative.execution is deprecated. Instead, use mapreduce.reduce.speculative
18/06/21 15:53:19 INFO Configuration.deprecation: mapred.map.tasks.speculative.execution is deprecated. Instead, use mapreduce.map.speculative
18/06/21 15:53:19 INFO mapreduce.JobSubmitter: Submitting tokens for job: job_1529566866753_0001
18/06/21 15:53:19 INFO impl.YarnClientImpl: Submitted application application_1529566866753_0001
18/06/21 15:53:20 INFO mapreduce.Job: The url to track the job: http://emr-header-1.cluster-67561:20888/proxy/application_1529566866753_0001/
18/06/21 15:53:20 INFO mapreduce.Job: Running job: job_1529566866753_0001
18/06/21 15:53:28 INFO mapreduce.Job: Job job_1529566866753_0001 running in uber mode : false
18/06/21 15:53:28 INFO mapreduce.Job:  map 0% reduce 0%
18/06/21 15:53:34 INFO mapreduce.Job:  map 100% reduce 0%
18/06/21 15:53:40 INFO mapreduce.Job:  map 100% reduce 14%
18/06/21 15:53:41 INFO mapreduce.Job:  map 100% reduce 57%
18/06/21 15:53:42 INFO mapreduce.Job:  map 100% reduce 71%
18/06/21 15:53:43 INFO mapreduce.Job:  map 100% reduce 86%
18/06/21 15:53:44 INFO mapreduce.Job:  map 100% reduce 100%
18/06/21 15:53:44 INFO mapreduce.Job: Job job_1529566866753_0001 completed successfully
18/06/21 15:53:44 INFO mapreduce.Job: Counters: 66
        File System Counters
                FILE: Number of bytes read=412
                FILE: Number of bytes written=1024771
                FILE: Number of read operations=0
                FILE: Number of large read operations=0
                FILE: Number of write operations=0
                HDFS: Number of bytes read=635
                HDFS: Number of bytes written=0
                HDFS: Number of read operations=2
                HDFS: Number of large read operations=0
                HDFS: Number of write operations=0
```

查看结果

执行以下命令验证数据是否成功写入Elasticsearch。

```
curl -u elastic -XGET es-cn-v0h0jdp990001rta9.elasticsearch.aliyuncs.
com:9200/blog/_search?pretty
```

验证成功后，结果如下图所示。

您也可以在Kibana控制台进行验证，结果如下图所示。

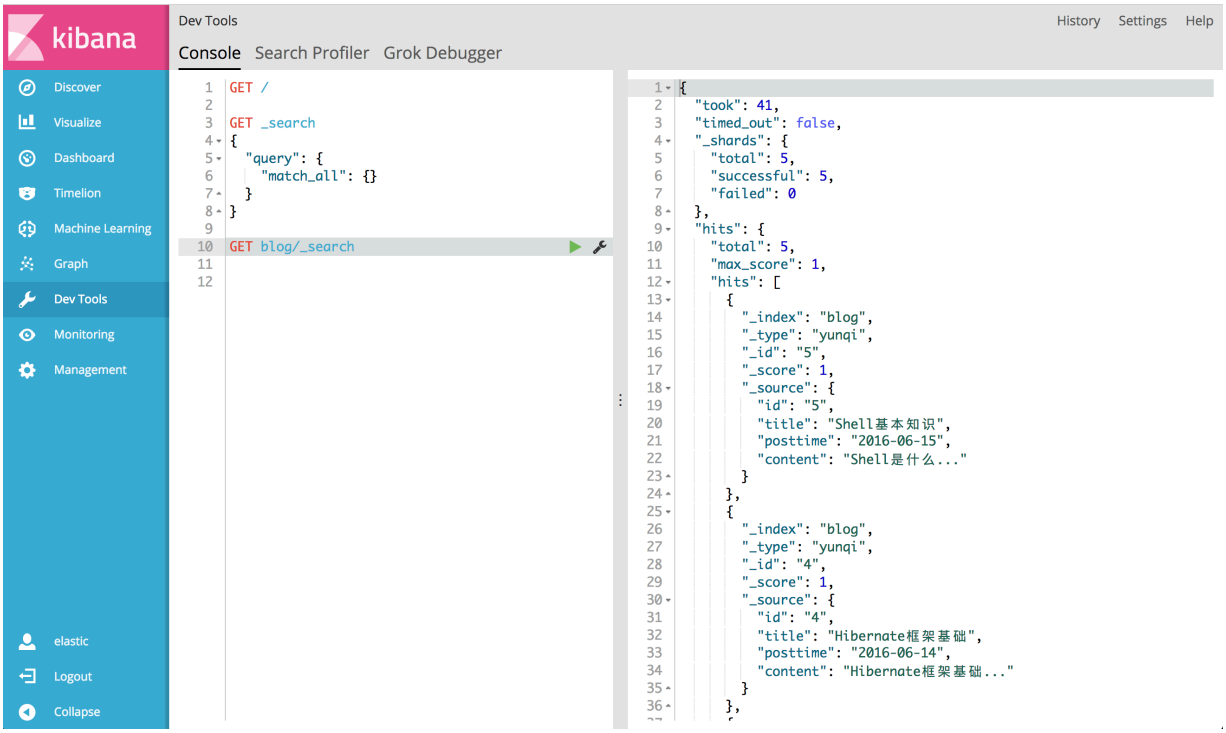

API分析

Map过程按行读入，input key的类型为Object，input value的类型为Text。输出的key为NullWritable类型，NullWritable是Writable的一个特殊类，实现方法为空实现，不从数据流中读数据，也不写入数据，只充当占位符。

MapReduce中如果不需要使用键或值，就可以将键或值声明为NullWritable，这里把输出的key设置NullWritable类型，输出的value为BytesWritable类型，将json字符串序列化。

说明:

在本示例中只需要写入，因此没有Reduce过程。

参数配置说明

- `conf.set("es.net.http.auth.user", "你的X-PACK用户名")`

  设置X-PACK的用户名。

- `conf.set("es.net.http.auth.pass", "你的X-PACK密码")`

  设置X-PACK的密码。

- `conf.setBoolean("mapred.map.tasks.speculative.execution", false)`

  关闭mapper阶段的执行推测。

- `conf.setBoolean("mapred.reduce.tasks.speculative.execution", false)`

  关闭reducer阶段的执行推测。

- `conf.set(“es.nodes”, “你的Elasticsearch内网地址”)`

  配置Elasticsearch的IP和端口。

- `conf.set(“es.resource”, “blog/yunqi”)`

  设置索引到Elasticsearch的索引名和类型名。

- `conf.set(“es.mapping.id”, “id”)`

  设置文档id，这个参数id是文档中的id字段。

- `conf.set(“es.input.json”, “yes”)`

  指定输入的文件类型为json。

- `job.setInputFormatClass(TextInputFormat.class)`

  设置输入流为文本类型。

- `job.setOutputFormatClass(EsOutputFormat.class)`

  设置输出为EsOutputFormat类型。

- `job.setMapOutputKeyClass(NullWritable.class)`

  设置Map输出的key类型为NullWritable类型。

- `job.setMapOutputValueClass(BytesWritable.class)`

  设置Map输出的value类型为BytesWritable类型。

- `FileInputFormat.setInputPaths(job, new Path(otherArgs[0]))`

  设置传入HDFS上的文件路径。

3.7 Logstash部署

Logstash是一个开源的数据收集引擎，具有实时传输数据的能力。它可以统一过滤来自不同源的数据，并按照您制定的规范将过滤的数据输出到目标源中。本文档为您介绍在ECS上部署Logstash的方法，并通过一个简单的示例为您演示Logstash的使用步骤。

概述

本文档为您介绍了部署安装Logstash、使用Logstash同步增量数据以及监控Logstash节点的方法，并在最后给出了操作过程中的常见问题。

准备工作

1. 购买阿里云Elasticsearch以及能够同时访问自建集群和阿里云Elasticsearch的ECS实例（已符合条件的ECS不需要重复购买）。

   您可以购买经典网络的ECS实例，前提是该ECS实例能够通过经典网络访问VPC内的阿里云Elasticsearch服务。

2. 安装JDK，要求JDK版本为1.8及以上版本。

部署安装Logstash

1. 下载5.5.3版本的Logstash。

   在Elastic官网页面中，下载与ElasticSearch版本一致的Logstash（建议下载5.5.3版本）。

2. 对下载的Logstash压缩包进行解压缩。

   ```
   tar -xzvf logstash-5.5.3.tar.gz
   ```

   说明:

   ElasticSearch从5.x版本之后，会对配置文件进行严格校验。

使用Logstash同步增量数据

1. 创建数据接入的用户名和密码。

   a. 创建角色。

   在您购买的ECS的命令行界面，执行以下命令，创建角色。

   ```
   curl -XPOST -H "Content-Type: application/json" -u elastic:es-
   password http://***instanceId***.elasticsearch.aliyuncs.com:9200/
   _xpack/security/role/***role-name*** -d '{"cluster": ["manage_ind
   ex_templates", "monitor"],"indices": [{"names": [ "logstash-*" ],
    "privileges":["write","delete","create_index"]}]}'
   ```

   - `es-password`：阿里云Elasticsearch实例的密码，即您登录Kibana控制台的密码。
   - `***instanceId***`：阿里云Elasticsearch实例的ID，可在实例的基本信息页面获取。
   - `***role-name***`：您想使用的角色名称。

   说明:

   - Logstash默认的索引名称以`logstash-`当前日期命名，所以在添加用户角色的时候，需要有对`logstash-*`索引开放读写权限。

- 您也可以在Kibana控制台中创建角色。

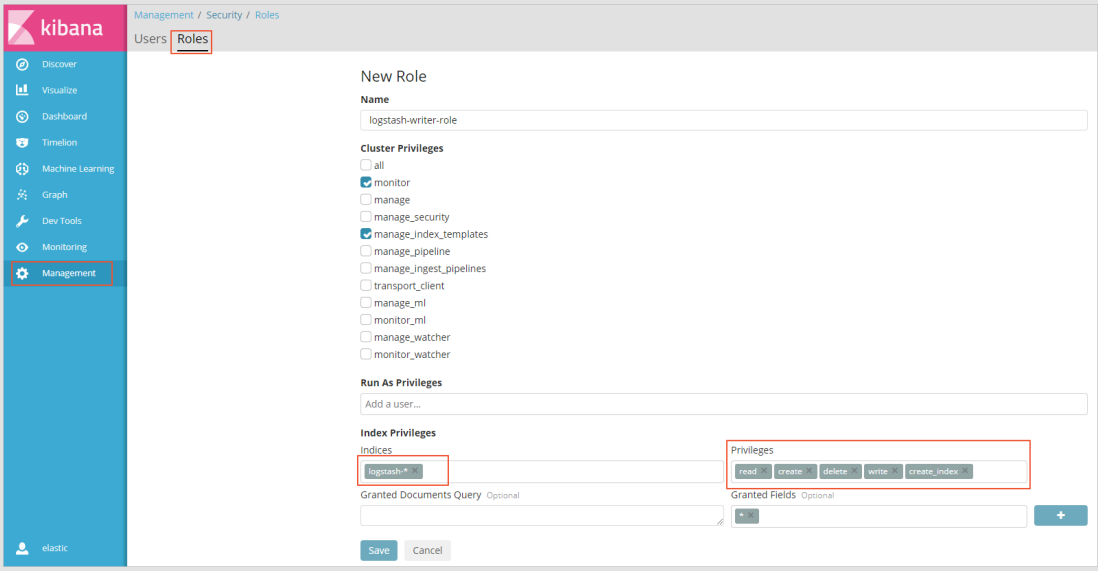

b. 创建用户。

在您购买的ECS的命令行界面，执行以下命令，创建用户。

```
curl -XPOST -H "Content-Type: application/json" -u elastic:es
-password http://***instanceId***.elasticsearch.aliyuncs.com:
9200/_xpack/security/user/***user-name*** -d '{"password" : "***
logstash-password***","roles" : ["***role-name***"],"full_name" :
 "***your full name***"}'
```

- `es-password`：阿里云Elasticsearch实例的密码，即您登录Kibana控制台的密码。
- `***instanceId***`：阿里云Elasticsearch实例的ID，可在实例的基本信息页面获取。
- `***user-name***`：您想创建的数据接入的用户名。
- `***logstash-password***`：您创建的数据接入用户的密码。
- `***role-name***`：您上一步创建的角色的名称。
- `***your full name***`：当前用户名的全名描述。

说明:

您也可以在Kibana控制台中创建用户。

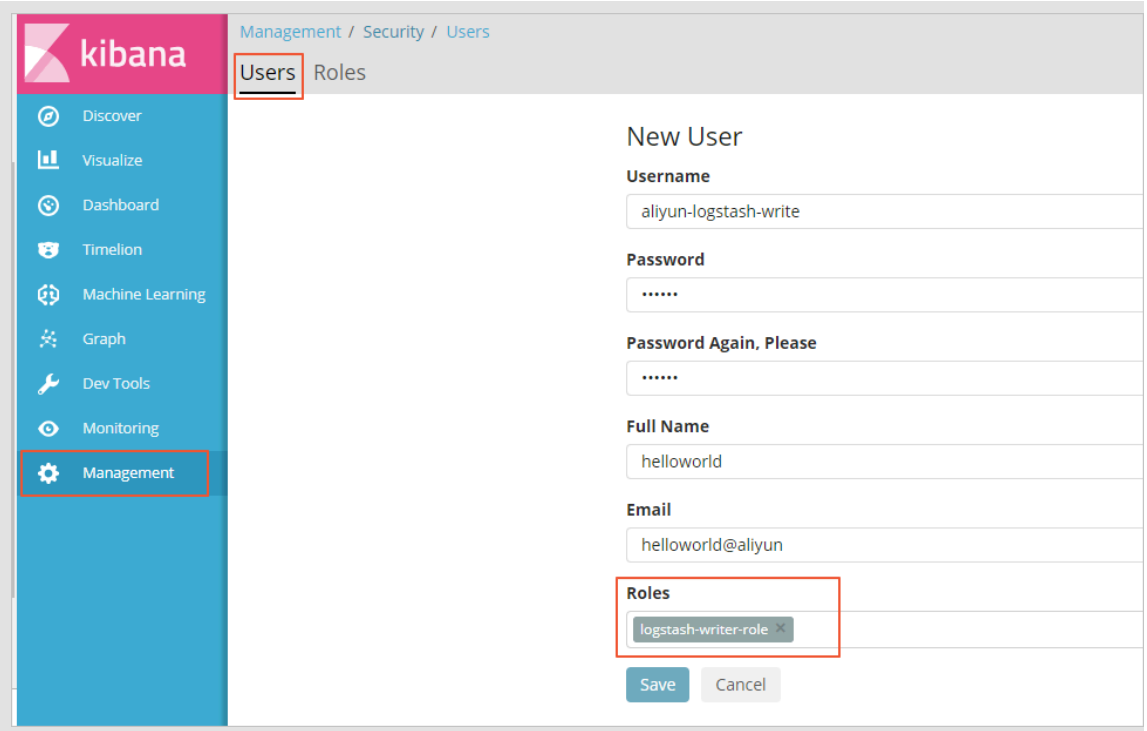

上图中的Roles需要选择您上一步创建的角色名称。

2. **编写conf文件。**

   在您购买的ECS中创建`test.conf`文件，并参考以下内容进行配置。

```
input {
    file {
        path => "/your/file/path/xxx"
        }
}
filter {
}
output {
  elasticsearch {
    hosts => ["http://***instanceId***.elasticsearch.aliyuncs.com:
9200"]
    user => "***user-name***"
    password => "***logstash-password***"
  }
}
```

说明:

Logstash提供了丰富的input、filter、output插件，只需要简单的配置就可是实现数据的流转，详情请参见官方配置文件结构文档。

- ***instanceId***：阿里云Elasticsearch实例的ID，可在实例的基本信息页面获取。
- ***user-name***：您上一步中创建的数据接入的用户名。
- ***logstash-password***：您上一步中创建的数据接入用户的密码。

> 注意：
> 用户名和密码需要使用英文引号，防止特殊字符在启动logstash时报错。

3. 执行logstash命令。

   按照上一步中配置的conf文件，执行logstash命令。

```
bin/logstash -f path/to/your/test.conf
```

   命令执行成功后，系统会自动通过Logstash获取file中的变化，并提交到Elasticsearch集群。只要监控的file文件有新增内容，Logstash就会自动索引到Elasticsearch集群中。

监控Logstash节点

您可以通过以下步骤监控Logstash节点，并收集监控日志。

1. 为Logstash安装X-Pack插件。

   单击此处下载X-Pack插件，完成后执行以下命令对X-Pack进行部署安装。

```
bin/logstash-plugin install
        file:///path/to/file/x-pack-5.5.3.zip
```

2. 创建Logstash监控用户。

   阿里云Elasticsearch集群默认会禁掉logstash_system用户，因此您需要创建一个角色为logstash_system的用户名（用户名不可以配置为logstash_system）。本文档以logstash_system_monitor用户名为例，为您讲解以下两种方式创建用户的方法。

   - 通过命令行方式添加用户。

```
curl -u elastic:es-password -XPOST http://***instanceId***.
elasticsearch.aliyuncs.com:9200/_xpack/security/user/logstash_s
ystem_monitor -d '{"password" : "***logstash-monitor-password
```

```
***","roles" : ["logstash_system"],"full_name" : "your full name
"}'
```

- `es-password`：阿里云Elasticsearch实例的密码，即您登录Kibana控制台的密码。
- `***instanceId***`：阿里云Elasticsearch实例的ID，可在实例的基本信息页面获取。
- `***logstash-monitor-password***`：您创建的`logstash_system_monitor`用户的密码。

· 通过Kibana控制台添加监控用户。

a. 进入Kibana控制台，单击Management > Users。

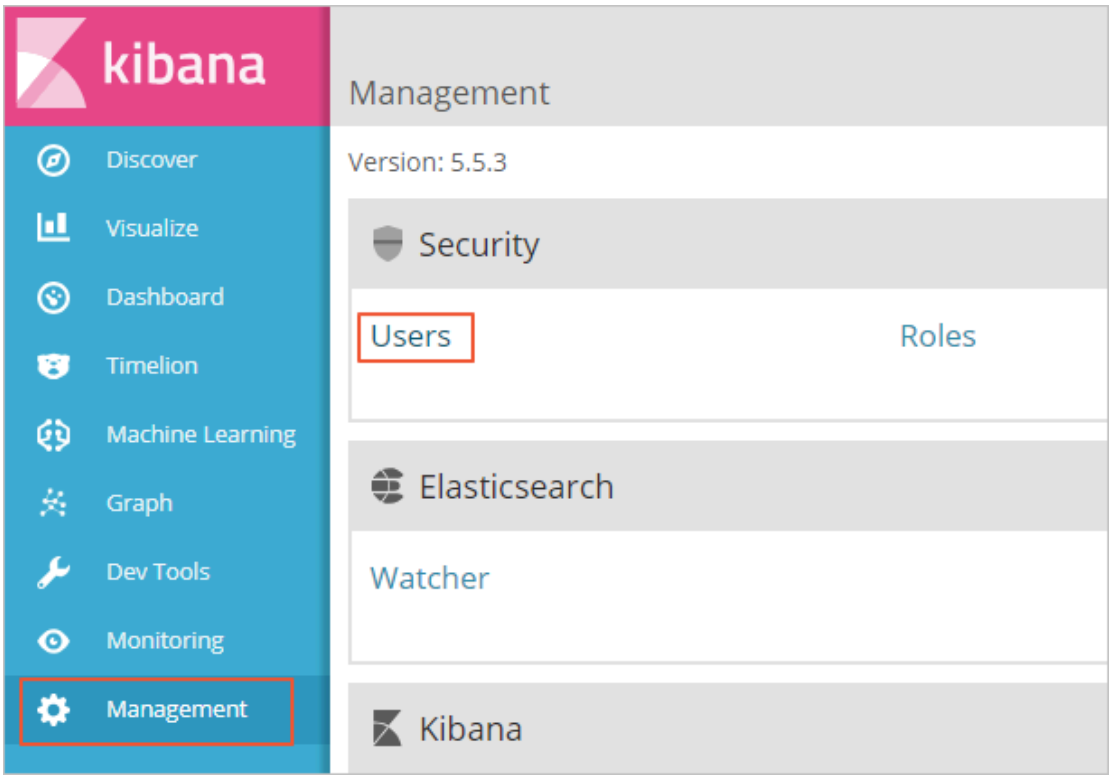

b. 在Users页面，单击Create user。

c. 输入下图所示的配置信息，单击Save。

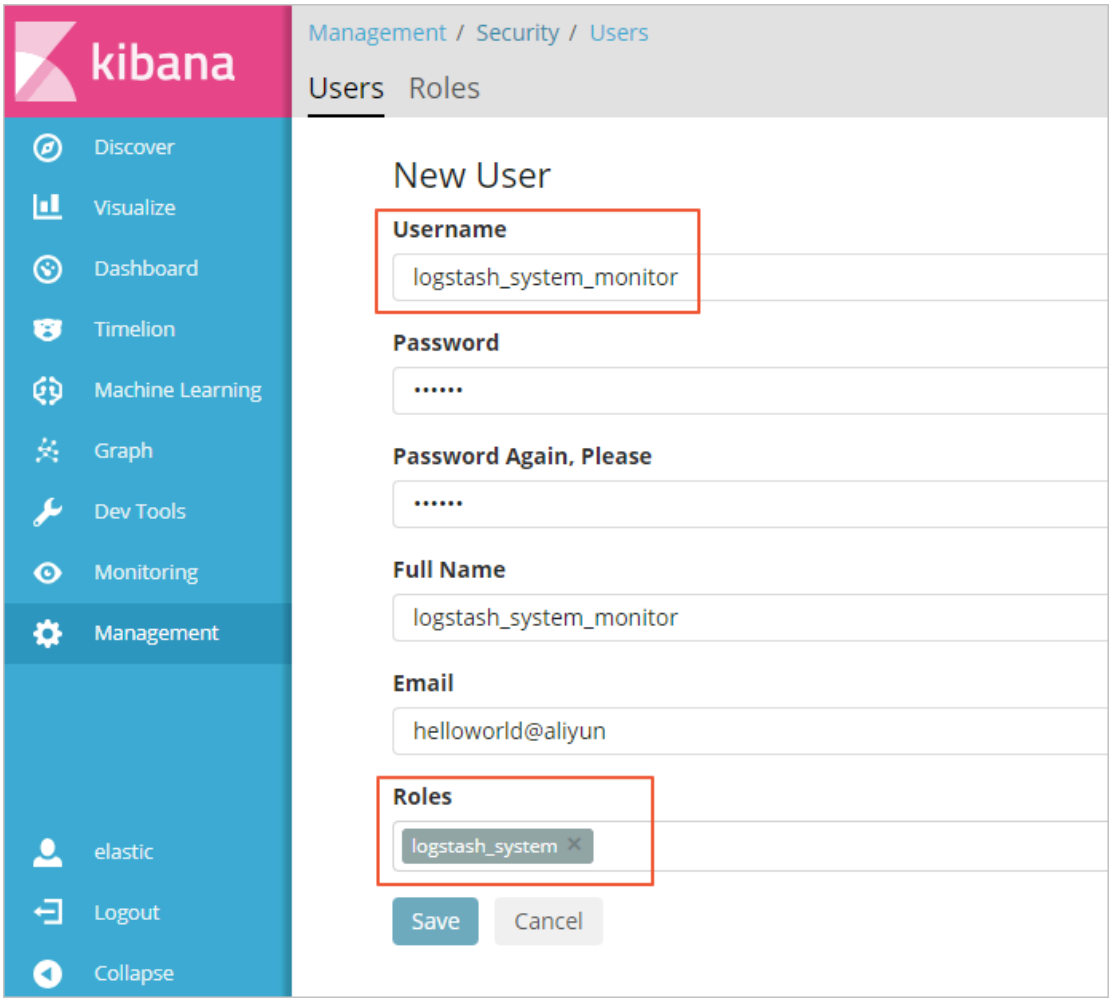

常见问题

- 更改集群自动创建索引配置。

  阿里云Elasticsearch为了保证用户操作数据的安全性，默认把自动创建索引的配置设置为不允许。

  Logstash在上传数据的时候，使用的是提交数据的方式创建索引，而不是使用create index API的方式。所以在使用Logstash上传数据之前，需要首先把集群的自动创建索引设置为允许。

  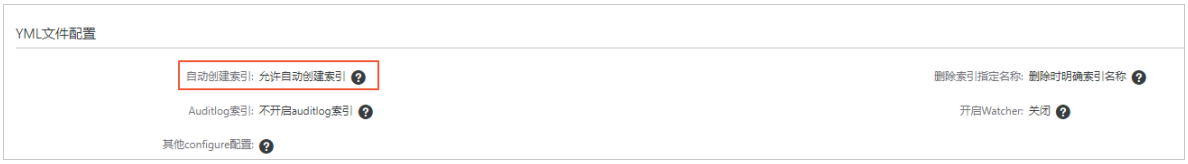

  注意：
  修改配置并确认后，阿里云Elasticsearch会自动重启，为保证您的业务不受影响，请谨慎操作。

- 创建索引时提示没有权限。

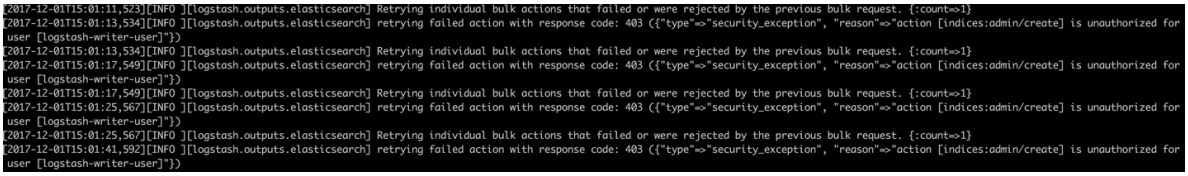

  请检查您创建的接入数据的用户拥有的角色，是否具有write、delete、create_index权限。

- 系统提示内存不足。

  Logstash默认配置的是1GB的内存，如果您申请的ECS内存不足，可以修改*config/jvm.options*中的内存配置，适当调小Logstash内存的使用。

- 配置*test.conf*时，用户名和密码没有添加引号。

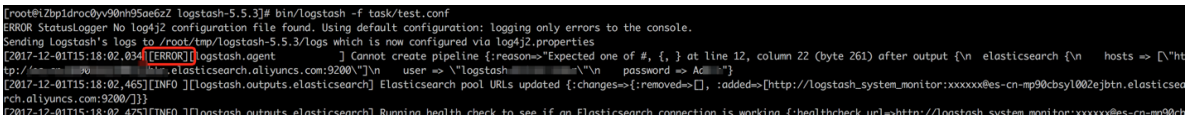

  如果在配置您的任务文件时（上文提到的*test.conf*文件），用户名和密码中有特殊字符但是又没有用引号括起来，就会出现上述的错误信息。

3.8 自建Elasticsearch迁移

本文档为您介绍将ECS自建的Elasticsearch迁移至阿里云Elasticsearch的方法，包括创建索引和数据迁移。

教程概述

本案例的整体步骤如下。

1. 创建索引。
2. 数据迁移。

同时本文档也为您介绍了一些操作过程中可能遇到的问题和解决方法，详情请参见常见问题。

前提条件

参考本文档做迁移前必须先满足以下条件，如果不满足需要通过其他方案进行迁移，详情请参见Logstash部署。

- 自建Elasticsearch所在的ECS必须是VPC网络（不支持Classiclink方式打通的ECS），并且自建Elasticsearch必须与阿里云Elasticsearch在同一个VPC下。
- 您可以通过中控机器（或者任意一台机器）执行文档中的脚本，前提是该中控机器可以同时访问新旧Elasticsearch集群的9200端口。
- 自建Elasticsearch所在的ECS的VPC安全组不能限制IP白名单，并且需要开启9200端口。
- 自建Elasticsearch所在的ECS的VPC安全组不能限制阿里云Elasticsearch实例的各节点IP（Kibana控制台可查看阿里云Elasticsearch实例各节点的IP）。
- 自建Elasticsearch与阿里云Elasticsearch实例已经连通。可以在执行脚本的机器上使用`curl -XGET http://<host>:9200`进行验证。

创建索引

参考旧集群中需要迁移的索引配置，提前在新集群中创建索引。或者为新集群开启自动创建索引和动态映射（不建议）功能。

以Python为例，使用如下脚本在新集群中批量创建旧集群索引，默认新创建的索引副本数为0。

```
#!/usr/bin/python
# -*- coding: UTF-8 -*-
# 文件名: indiceCreate.py
import sys
import base64
import time
import httplib
import json
## 老集群host (ip+port)
oldClusterHost = "old-cluster.com"
## 老集群用户名，可为空
oldClusterUserName = "old-username"
## 老集群密码，可为空
oldClusterPassword = "old-password"
## 新集群host (ip+port)
newClusterHost = "new-cluster.com"
## 新集群用户名，可为空
newClusterUser = "new-username"
## 新集群密码，可为空
newClusterPassword = "new-password"
DEFAULT_REPLICAS = 0
def httpRequest(method, host, endpoint, params="", username="",
password=""):
    conn = httplib.HTTPConnection(host)
    headers = {}
    if (username != "") :
        'Hello {name}, your age is {age} !'.format(name = 'Tom', age =
 '20')
        base64string = base64.encodestring('{username}:{password}'.
format(username = username, password = password)).replace('\n', '')
        headers["Authorization"] = "Basic %s" % base64string;
    if "GET" == method:
        headers["Content-Type"] = "application/x-www-form-urlencoded"
        conn.request(method=method, url=endpoint, headers=headers)
    else :
        headers["Content-Type"] = "application/json"
```

```
        conn.request(method=method, url=endpoint, body=params, headers
=headers)
    response = conn.getresponse()
    res = response.read()
    return res
def httpGet(host, endpoint, username="", password=""):
    return httpRequest("GET", host, endpoint, "", username, password)
def httpPost(host, endpoint, params, username="", password=""):
    return httpRequest("POST", host, endpoint, params, username,
password)
def httpPut(host, endpoint, params, username="", password=""):
    return httpRequest("PUT", host, endpoint, params, username,
password)
def getIndices(host, username="", password=""):
    endpoint = "/_cat/indices"
    indicesResult = httpGet(oldClusterHost, endpoint, oldCluster
UserName, oldClusterPassword)
    indicesList = indicesResult.split("\n")
    indexList = []
    for indices in indicesList:
        if (indices.find("open") > 0):
            indexList.append(indices.split()[2])
    return indexList
def getSettings(index, host, username="", password=""):
    endpoint = "/" + index + "/_settings"
    indexSettings = httpGet(host, endpoint, username, password)
    print index + "  原始settings如下: \n" + indexSettings
    settingsDict = json.loads(indexSettings)
    ## 分片数默认和老集群索引保持一致
    number_of_shards = settingsDict[index]["settings"]["index"]["
number_of_shards"]
    ## 副本数默认为0
    number_of_replicas = DEFAULT_REPLICAS
    newSetting = "\"settings\": {\"number_of_shards\": %s, \"
number_of_replicas\": %s}" % (number_of_shards, number_of_replicas)
    return newSetting
def getMapping(index, host, username="", password=""):
    endpoint = "/" + index + "/_mapping"
    indexMapping = httpGet(host, endpoint, username, password)
    print index + " 原始mapping如下: \n" + indexMapping
    mappingDict = json.loads(indexMapping)
    mappings = json.dumps(mappingDict[index]["mappings"])
    newMapping = "\"mappings\" : " + mappings
    return newMapping
def createIndexStatement(oldIndexName):
    settingStr = getSettings(oldIndexName, oldClusterHost, oldCluster
UserName, oldClusterPassword)
    mappingStr = getMapping(oldIndexName, oldClusterHost, oldCluster
UserName, oldClusterPassword)
    createstatement = "{\n" + str(settingStr) + ",\n" + str(mappingStr
) + "\n}"
    return createstatement
def createIndex(oldIndexName, newIndexName=""):
    if (newIndexName == "") :
        newIndexName = oldIndexName
    createstatement = createIndexStatement(oldIndexName)
    print "新索引 " + newIndexName + " 的setting和mapping如下: \n" +
createstatement
    endpoint = "/" + newIndexName
    createResult = httpPut(newClusterHost, endpoint, createstatement,
newClusterUser, newClusterPassword)
    print "新索引 " + newIndexName + " 创建结果: " + createResult
## main
```

```
indexList = getIndices(oldClusterHost, oldClusterUserName, oldCluster
Password)
systemIndex = []
for index in indexList:
    if (index.startswith(".")):
        systemIndex.append(index)
    else :
        createIndex(index, index)
if (len(systemIndex) > 0) :
    for index in systemIndex:
        print index + "  或许是系统索引，不会重新创建，如有需要，请单独处理～"
```

数据迁移

以下提供了三种数据迁移的方式供您参考。您可以根据迁移的数据量大小以及具体的操作情况，选择合适的方式进行数据迁移。

注意:

- 为保证数据迁移前后的一致性，需要上游业务停止旧集群的写操作，读服务才可以正常进行。迁移完毕后，直接切换到新集群进行读写。如果不停止写操作可能会存在迁移前后数据不一致的情况。
- 使用下述方案迁移时，如果是通过`IP + Port`的方式访问旧集群，则必须在新集群的`yml`文件中配置`reindex`白名单（加入旧集群的IP地址），例如`reindex.remote.whitelist: 1.1.1.1:9200,1.2.*.*:*`。
- 如果使用域名访问，则不允许通过`http://host:port/path`这种带`path`的形式访问。

- 数据量小。

  使用`reindex.sh`脚本。

```
#!/bin/bash
# file:reindex.sh
indexName="你的索引名"
newClusterUser="新集群用户名"
newClusterPass="新集群密码"
newClusterHost="新集群host"
oldClusterUser="老集群用户名"
oldClusterPass="老集群密码"
# 老集群host必须是[scheme]://[host]:[port]，例如http://10.37.1.1:9200
oldClusterHost="老集群host"
curl -u ${newClusterUser}:${newClusterPass} -XPOST "http://${
newClusterHost}/_reindex?pretty" -H "Content-Type: application/json"
 -d'{
    "source": {
        "remote": {
            "host": "'${oldClusterHost}'",
            "username": "'${oldClusterUser}'",
            "password": "'${oldClusterPass}'"
        },
        "index": "'${indexName}'",
        "query": {
            "match_all": {}
```

```
        }
    },
    "dest": {
       "index": "'${indexName}'"
    }
}'
```

- 数据量大、无删除操作、有更新时间。

  数据量较大且无删除操作时，可以使用滚动迁移的方式，减少停止写服务的时间。滚动迁移需要有一个类似于更新时间的字段代表新数据的写时序。可以在数据迁移完成后，再停止写服务，快速更新一次。即可切换到新集群，恢复读写。

```
#!/bin/bash
# file: circleReindex.sh
# CONTROLLING STARTUP:
# 这是通过reindex操作远程重建索引的脚本，要求：
# 1. 新集群已经创建完索引，或者支持自动创建和动态映射。
# 2. 新集群必须在yml里配置IP白名单 reindex.remote.whitelist: 172.16.123
.*:9200
# 3. host必须是[scheme]://[host]:[port]
USAGE="Usage: sh circleReindex.sh <count>
       count: 执行次数，多次（负数为循环）增量执行或者单次执行
Example:
        sh circleReindex.sh 1
        sh circleReindex.sh 5
        sh circleReindex.sh -1"
indexName="你的索引名"
newClusterUser="新集群用户名"
newClusterPass="新集群密码"
oldClusterUser="老集群用户名"
oldClusterPass="老集群密码"
## http://myescluster.com
newClusterHost="新集群host"
# 老集群host必须是[scheme]://[host]:[port]，例如http://10.37.1.1:9200
oldClusterHost="老集群host"
timeField="更新时间字段"
reindexTimes=0
lastTimestamp=0
curTimestamp=`date +%s`
hasError=false
function reIndexOP() {
    reindexTimes=$[${reindexTimes} + 1]
    curTimestamp=`date +%s`
    ret=`curl -u ${newClusterUser}:${newClusterPass} -XPOST "${
newClusterHost}/_reindex?pretty" -H "Content-Type: application/json"
 -d '{
        "source": {
            "remote": {
                "host": "'${oldClusterHost}'",
                "username": "'${oldClusterUser}'",
                "password": "'${oldClusterPass}'"
            },
            "index": "'${indexName}'",
            "query": {
                "range" : {
                    "'${timeField}'" : {
                        "gte" : '${lastTimestamp}',
                        "lt" : '${curTimestamp}'
                    }
                }
```

```
            }
        },
        "dest": {
            "index": "'${indexName}'"
        }
    }'`
    lastTimestamp=${curTimestamp}
    echo "第${reindexTimes}次reIndex，本次更新截止时间 ${lastTimestamp
} 结果: ${ret}"
    if [[ ${ret} == *error* ]]; then
        hasError=true
        echo "本次执行异常，中断后续执行操作～～，请检查"
    fi
}
function start() {
    ## 负数就不停循环执行
    if [[ $1 -lt 0 ]]; then
        while :
        do
            reIndexOP
        done
    elif [[ $1 -gt 0 ]]; then
        k=0
        while [[ k -lt $1 ]] && [[ ${hasError} == false ]]; do
            reIndexOP
            let ++k
        done
    fi
}
## main
if [ $# -lt 1 ]; then
    echo "$USAGE"
    exit 1
fi
echo "开始执行索引 ${indexName} 的 ReIndex操作"
start $1
echo "总共执行 ${reindexTimes} 次 reIndex 操作"
```

- 数据量大、无删除操作、无更新时间。

  当数据量较大，且索引的mapping中没有定义更新时间字段时，需要由上游业务修改代码添加更新时间字段。添加完成后可以先将历史数据迁移完，然后再使用上述的第二种方案。

```
#!/bin/bash
# file:miss.sh
indexName="你的索引名"
newClusterUser="新集群用户名"
newClusterPass="新集群密码"
newClusterHost="新集群host"
oldClusterUser="老集群用户名"
oldClusterPass="老集群密码"
# 老集群host必须是[scheme]://[host]:[port]，例如http://10.37.1.1:9200
oldClusterHost="老集群host"
timeField="updatetime"
curl -u ${newClusterUser}:${newClusterPass} -XPOST "http://${
newClusterHost}/_reindex?pretty" -H "Content-Type: application/json"
 -d '{
    "source": {
        "remote": {
            "host": "'${oldClusterHost}'",
            "username": "'${oldClusterUser}'",
            "password": "'${oldClusterPass}'"
```

```
        },
        "index": "'${indexName}'",
        "query": {
            "bool": {
                "must_not": {
                    "exists": {
                        "field": "'${timeField}'"
                    }
                }
            }
        }
    },
    "dest": {
       "index": "'${indexName}'"
    }
}'
```

- 不停止写服务。

  敬请期待。

说明:

您也可以使用Logstash进行数据迁移，详情请参见 Logstash迁移Elasticsearch数据方法解读。

常见问题

- 问题：执行curl命令时提示`{"error":"Content-Type header [application/x-www-form-urlencoded] is not supported","status":406}`。

  解决方法：可以在curl命令中添加`-H "Content-Type: application/json"`参数重试。

```
// 获取老集群中所有索引信息，如果没有权限可去掉"-u user:pass"参数，
oldClusterHost为老集群的host，注意替换。
  curl -u user:pass -XGET http://oldClusterHost/_cat/indices | awk
 '{print $3}'
  // 参考上面返回的索引列表，获取需要迁移的指定用户索引的setting和mapping，注
意替换indexName为要查询的用户索引名。
  curl -u user:pass -XGET http://oldClusterHost/indexName/_settings,
_mapping?pretty=true
  // 参考上面获取到的对应索引的_settings,_mapping信息，在新集群中创建对应索
引，索引副本数可以先设置为0，用于加快数据同步速度，数据迁移完成后再重置副本数为1
。
  //其中newClusterHost是新集群的host，testindex是已经创建的索引名，
testtype是对应索引的type。
  curl -u user:pass -XPUT http://<newClusterHost>/<testindex> -d '{
    "testindex" : {
        "settings" : {
            "number_of_shards" : "5", //假设老集群中对应索引的shard数是5
个
            "number_of_replicas" : "0" //设置索引副本为0
          }
        },
        "mappings" : { //假设老集群中对应索引的mappings配置如下
            "testtype" : {
                "properties" : {
                    "uid" : {
                        "type" : "long"
                    },
```

```
                    "name" : {
                        "type" : "text"
                    },
                    "create_time" : {
                      "type" : "long"
                    }
                }
            }
        }
    }
}'
```

- 问题：数据同步速度太慢。

  解决方法：如果单索引数据量比较大，可以在迁移前将目的索引的副本数设置为 0，刷新时间为 -1。待数据迁移完成后，再更改回来，这样可以加快数据同步速度。

```
// 迁移索引数据前可以先将索引副本数设为0，不刷新，用于加快数据迁移速度。
curl -u user:password -XPUT 'http://<host:port>/indexName/_settings'
 -d' {
        "number_of_replicas" : 0,
        "refresh_interval" : "-1"
}'
// 索引数据迁移完成后，可以重置索引副本数为1，刷新时间1s（1s是默认值）。
curl -u user:password -XPUT 'http://<host:port>/indexName/_settings'
 -d' {
        "number_of_replicas" : 1,
        "refresh_interval" : "1s"
}'
```

说明：

本文档部分内容参考了官方文档。