

# E-MapReduce

快速入门

# 快速入门

在创建 E-MapReduce 之前，您需要先完成以下准备工作：

## 注册阿里云账号

在申请 E-MapReduce 集群之前，您需要一个阿里云的云账号用于标识您在整个阿里云生态系统中的身份。该账号不仅可以用来申请 E-MapReduce 集群，同时还能够开通阿里云的对象存储服务 OSS、云数据库 RDS等服务。

如果您还没有阿里云的云账号，请参见[注册云账号](#)进行申请。

## 创建 Access Key（可选）

由于 E-MapReduce 调用访问的需要，您至少需要创建一个 Access Key，创建步骤如下：

登录阿里云官网。

登录管理控制台。

单击 **AccessKeys**。

注意：若出现如下提示框，请单击继续使用 **Accesskey**。



单击**创建 Access Key**，然后再单击**同意并创建**。

输入短信校验码，单击**确定**。Access Key 创建成功。

### 开通阿里云 OSS 服务

E-MapReduce 会将您的作业日志和运行日志保存在您的阿里云 OSS 存储空间中，所以需要您开通阿里云 OSS 服务，操作步骤请参见[开通 OSS 服务](#)。并在您期望创建集群的相同地域创建 Bucket，参见[创建Bucket](#)。

### 开通高配机型（可选）

如果您需要在按量的集群中使用8核及8核以上的机型时，需要先在ECS处申请开通。申请高配机型

### 准备足够的余额

目前根据阿里云 ECS 的规则，用户在购买按量付费 ECS 的时候，要保证阿里云账户中至少有 100 元的现金（注意：代金券无效）。因此，**在创建按量集群前**，请确认您的账户中已**至少充值 100 元**，否则会创建失败。前往[充值](#)

当您使用完成并释放集群以后，在没有ECS或者其他按量产品在使用的情况下，您可以将这100元提现，回到您自己的原有账户中。

## 创建 E-MapReduce

注意：请确认您已经完成了**必选**的准备工作。

通过本教程，用户能够基本了解E-MapReduce中集群、作业和执行计划的作用和使用方法。能够创建一个 Spark Pi的作业在集群上运行成功，并最后在控制台页面上看到圆周率Pi的近似计算结果。

### 1. 创建集群

- i. 在控制台左侧选择**集群**，并点击右上角**创建集群**
- ii. 软件配置
  - a. 选择最新的EMR产品版本，比如**EMR-3.4.1**
  - b. 使用默认软件配置
- iii. 硬件配置
  - a. 选择**按量付费**
  - b. 若没有安全组，打开**新建**，并填写安全组名称
  - c. 选择 Master 4核8G
  - d. 选择 Core 4核8G，两台
  - e. 其他保持默认
- iv. 基础配置
  - a. 填写集群名称
  - b. 选择日志路径保存作业日志，**务必开启**。在**集群对应的地域**，创建OSS的

### Bucket

#### c. 填写密码

#### v. 创建集群

### 2. 创建作业

i. 在控制台左侧选择**作业**，并点击右上角**创建作业**

ii. 填写作业名称

iii. 选择Spark类型

iv. 参数填写，使用如下

```
--class org.apache.spark.examples.SparkPi --master yarn-client --driver-memory 512m --  
num-executors 1 --executor-memory 1g --executor-cores 2 /usr/lib/spark-  
current/examples/jars/spark-examples_2.11-2.1.1.jar 10
```

**注意：**，这个/usr/lib/spark-current/examples/jars/spark-examples\_2.11-2.1.1.jar, 需要根据实际集群中的 Spark 版本来修改这个jar包，比如 Spark 是2.1.1的, 那么就是 spark-examples\_2.11-2.1.1.jar,如果是2.2.0的，那么就是spark-examples\_2.11-2.2.0.jar

v. 其他保持默认，创建作业

### 3. 创建执行计划

i. 确认之前创建的集群已经创建成功以后，在列表上的状态显示为**空闲**

ii. 在控制台左侧选择**执行计划**，并点击右上角**创建执行计划**

iii. 创建时选择**已有集群**，并选择之前创建集群进行关联

iv. 将之前创建的作业，加入到运行队列中

v. 填写执行计划名称

vi. 默认**手动执行**

vii. 创建执行计划

### 4. 运行执行计划

i. 在执行计划列表页面，点击**立即运行**

### 5. 查看作业日志并确认结果

i. 点击**管理**，进入管理页面，在下方查看**运行记录**

ii. 点击运行记录的右侧，查看作业列表

iii. 点击**stdout**能够查看到Pi的近似计算结果：3.14xxxx

## 进入创建集群页面

登录阿里云 E-MapReduce 控制台集群列表。

完成 RAM 授权，操作步骤请参见角色授权。

在上方选择所在的地域（Region），所创建集群将会在对应的地域内，一旦创建后不能修改。

单击右上方的**创建集群**按钮，进行创建。

## 创建集群流程

要创建集群，您需要继续完成以下 3 个步骤：

- 软件配置
- 硬件配置
- 基础配置

### 步骤1：软件配置

配置项说明：

**产品版本**：选择默认最新的软件版本

**集群类型**：目前的EMR提供了

- Hadoop标准的 Hadoop 集群，包含了大部分的 Hadoop 相关的组件，具体的组件信息可以在选择界面的列表中查看。
- Kafka独立的 Kafka 集群，提供消息服务。

**包含配置**：使用默认的配置，后期可以在管理界面中添加和启停服务。

**安全模式**：是否开启集群的 Kerberos 认证功能。一般的个人用户集群无需该功能，默认关闭它。

### 步骤2：硬件配置

配置项说明：

**付费配置**

- **付费类型**测试的场景下使用按量开始，测试都正常了以后。可以新建一个包月的生产集群正式使用。

**集群网络配置**

**集群可用区**：一般使用默认的可用区即可。

**网络类型**：推荐使用VPC。若还未创建，可前往VPC控制台进行创建。

注意：经典网络与专有网络不互通，购买后不能更换网络类型。

**ECS 实例系列**：使用默认最新的系列。

**VPC**：选择在该地域的VPC。

**交换机**：选择在对应的VPC下的在对应可用区的交换机，如果在这个可用区没有可用的交换机，那么就需要前往去创建一个新的使用。

**新建安全组**：一般用户初次来到这里还没有安全组，打开“新建安全组”开关，在“安全组名称”里面填上新的安全组的名字。

**选择安全组**：若已经有在使用的安全组可以直接这里选择使用。

## 集群节点配置

**高可用集群**：后续正式集群如果是使用高可用的，测试情况下也打开高可用。

**节点类型**：只需要使用Master和Core，Task可以不用，需要的时候再追加。

**节点配置**：使用默认配置

**数据盘类型**：根据需要选择高效或者是SSD云盘。

**数据盘容量**：根据需要调整磁盘容量，推荐至少80G

**实例数量**：根据需要调整

## 步骤3：基础配置

配置项说明：

### 基本信息

- **集群名称**：集群的名字，长度限制为 1-64 个字符，仅可使用中文、字母、数字、“-”和“\_”。

### 运行日志

**运行日志**：是否保存作业的日志，日志保存默认是打开的。开启后会需要您选择用来保存日志的 OSS 目录位置，会将您的作业的日志保存到该 OSS 存储目录上。当然，您要使用这个功能必须先开通 OSS，同时上传的文件会按照使用的量来计算用户的费用。强烈建议您打开 OSS 日志保存功能，这会对您的作业调试和错误排查有极大的帮助。

**日志路径**：保存日志的 OSS 路径。

**统一Meta数据库**：推荐先关闭。

**权限设置** 无需调整，使用默认即可。

### 登录设置

- **登录密码**：设置 master 节点的登录密码。8 - 30 个字符，且必须同时包含大写字母、小写字母、数字和特殊字符!@#%&\*^

## 配置清单和集群费用

在配置清单上确认配置和对应的费用

## 确认创建

当所有的信息都有效填写以后，“创建”按钮会亮起，确认无误后单击**创建**将会创建集群。

注意：

若是按量付费集群，集群会立刻开始创建。页面会返回集群列表页，就能看到在列表中有一个“集群创建中”的集群。请耐心等待，集群创建会需要几分钟时间。完成之后集群的状态会切换为“集群空闲”。

若是包年包月集群，则会先生成订单，在支付完成订单以后集群才会开始创建。

## 创建失败

如果创建失败，在集群列表页上会显示“集群创建失败”，将鼠标移动到红色的感叹号上会看到失败原因，如下图所示。



| 实例ID/集群名称                               | 集群类型   | 已运行时间 | 付费类型                           | 操作                   |
|-----------------------------------------|--------|-------|--------------------------------|----------------------|
| C-8212DB80D81C763F<br>统计集群              | Hadoop | 0秒    | 按量付费<br>12 17:00:00 创建         | <a href="#">查看详情</a> |
| C-28D087404967F33C<br>统计集群              | Hadoop | 0秒    | 按量付费<br>2016/07/01 11:00:00 创建 | <a href="#">查看详情</a> |
| C-649EA066C7E03B87<br>sl-test-upgrade-1 | Hadoop | 0秒    | 按量付费<br>2016/06/29 10:34:27 创建 | <a href="#">查看详情</a> |

创建失败的集群可以不用处理，对应的计算资源并没有真正的创建出来。这个集群会在停留3天以后自动隐藏。

要运行一个计算任务，首先需要定义一个作业，其步骤如下：

登录阿里云 E-MapReduce 控制台作业页面。

选择地域（Region），则作业将会创建在对应的地域内。

单击该页右上角的**创建作业**，进入创建作业页面，如下图所示：

创建作业

×

\* 作业名称：

长度限制为1-64个字符，只允许包含中文、字母、数字、-、\_

\* 作业类型：

☒ Spark

☐ Hadoop

☐ Hive

☐ Pig

☐ Sqoop

☐ Spark SQL

☐ Shell

\* 应用参数：

+ 选择OSS路径

\* 实际执行命令：

spark-submit

\* 执行失败后策略：

☐ 暂停当前执行计划

☒ 继续执行下一作业

确定

取消

填写作业名称。

选择作业类型。

填写作业的应用参数。应用参数需要完整填写该作业运行的 jar 包、作业的数据输入输出地址以及一些命令行参数，也就是将用户在命令行的所有参数填写在这里。如果有使用到 OSS 的路径，可以单击下方的“选择 OSS 路径”选择 OSS 资源路径。关于各作业类型的参数配置，请参见用户指南中的作业。

实际执行命令。这里会显示作业在 ECS 上实际被执行的命令。用户如果把这个命令直接复制下来，就能够在 E-MapReduce 集群的命令行环境中直接运行。

选择执行失败后策略。暂停当前执行计划会在这个作业失败后，暂停当前整个执行计划，等待用户处理。而继续执行下一个作业在这个作业失败以后，会忽略这个错误继续执行后一个作业。

单击**确定**完成创建。

## 作业示例

这是一个 Spark 类型的作业，应用参数中设置了相关的参数，输入输出路径等。

注意：本作业仅仅示例，不能实际运行。

修改作业 ✕

\* 作业名称：

长度限制为1-64个字符，只允许包含中文、字母、数字、-、\_

\* 作业类型：

☒ Spark

☐ Hadoop

☐ Hive

☐ Pig

☐ Sqoop

☐ Spark SQL

☐ Shell

\* 应用参数：

```
--master yarn-client --driver-memory 5G --executor-memory 3G -
-executor-cores 2 --num-executors 6 --class
com.aliyun.emr.checklist.benchmark.SparkWordCount
ossref://emr/checklist/jars/emr-checklist_2.10-0.1.0.jar
oss://emr/checklist/data/wc oss://emr/checklist/data/wc-counts
12 cn-hangzhou
```

+ 选择OSS路径

\* 实际执行命令：

```
spark-submit --master yarn-client --driver-memory 5G --executor-
memory 3G --executor-cores 2 --num-executors 6 --class
com.aliyun.emr.checklist.benchmark.SparkWordCount
ossref://emr/checklist/jars/emr-checklist_2.10-0.1.0.jar
oss://emr/checklist/data/wc oss://emr/checklist/data/wc-counts 12
cn-hangzhou
```

\* 执行失败后策略：

☐ 暂停当前执行计划

☒ 继续执行下一作业

## oss 与 ossref

**oss://** 的前缀代表数据路径指向一个 OSS 路径，当要读写该数据的时候，这个指明了操作的路径，与 **hdfs://** 类似。

**ossref://** 同样是指向一个 OSS 的路径，不同的是它会将对应的代码资源下载到本地，然后将命令行中的路径替换为本地路径。它是用于更方便地运行一些本地代码，而不需要登录到机器上去上传代码和依赖的资源包。

上面的例子中，**ossref://xxxxxx/xxx.jar** 这个参数代表作业资源的jar，这个jar存放在OSS上，在运行的时候，E-MapReduce会自动下载到集群中运行。而跟在jar后面的2个 **oss://xxxx** 以及另外2个值则是作为参数出现，他们会被作为参数传递给jar中的主类来处理。

注意：ossref 不可以用来下载过大的数据资源，否则会导致集群作业的失败。

创建完作业后，若要让定义的作业到集群上运行，就需要创建一个执行计划。一个执行计划可以包含多个作业，用户也可自定义其先后顺序。例如，假设用户的一个场景是：产生数据 -> 处理数据 -> 清理数据，则用户可以分别定义三个名为“prepare-data”、“process-data”和“cleanup-data”的作业，然后创建一个执行计划来包含这三个作业。

创建执行计划的步骤如下：

登录阿里云 E-MapReduce 控制台执行计划页面。

选择地域（Region）。


单击右上角的**创建执行计划**，进入创建执行计划页面。

在选择集群方式页面上，有两个选项，分别是“按需创建”和“已有集群”。其中“按需创建”表示目前用户还没有集群，打算用一个临时集群运行该执行计划，并在运行完后将该临时集群自动释放。而“已有集群”表示用户目前已有集群在运行，该执行计划要提交到已有集群中运行。

如果选择“按需创建”，则步骤跟创建集群一样进行，选择完这个按需集群的配置以后确定即可。

如果选择“已有集群”，则进入选择集群页面。用户可选择要将该执行计划关联到的集群，如下图所示：

单击**下一步**，进入到配置作业页面。在该页面中，左边为先前已经定义好的作业列表，右边是该新创建的执行计划要运行的作业列表。将左边的作业按照执行顺序选择到右边，即可完成执行计划的定义。可以单击问号，查看作业的详细参数。完成后，单击**下一步**。如下图所示：



设置执行计划名称。

选择调度策略，如下图所示。

周期调度，定义周期调度的频率与启动调度的时间。

手动执行，只有在用户手动单击的情况下才会执行。

创建执行计划

×

1 : 选择集群方式

2 : 选择集群

3 : 配置作业

4 : 配置调度方式

\* 执行计划名称 :

\* 调度策略 :

周期调度

\* 调度周期设置 :

天

每

1

天

\* 首次执行时间 :

2016-03-11

19

:

23

首次运行时间 2016-3-11 19:23

后续间隔1天运行1次

上一步

确认提交

取消

单击**确认提交**，完成执行计划的创建。