

ALIBABA CLOUD

阿里云

E-MapReduce

快速入门

文档版本：20201029

 阿里云

法律声明

阿里云提醒您在使用或阅读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 <code>cd /d C:/window</code> 命令，进入Windows系统文件夹。
<i>斜体</i>	表示参数、变量。	<code>bae log list --instanceid</code> <i>Instance_ID</i>
[] 或者 [a b]	表示可选项，至多选择一个。	<code>ipconfig [-all -t]</code>
{ } 或者 {a b}	表示必选项，至多选择一个。	<code>switch {active stand}</code>

目录

1.入门概述	05
2.准备工作	06
3.选型配置	07
4.创建集群	09
5.创建并运行作业	11

1. 入门概述

本教程指引您快速创建一个E-MapReduce集群并执行作业。

本教程包含以下操作：

- **创建集群**

创建集群。

- **创建并运行作业**

创建集群，新建并配置作业。

常用文件的安装路径，请参见[E-MapReduce常用文件路径](#)。

2. 准备工作

本文介绍创建E-MapReduce集群前所需的准备工作。

注册阿里云账号

如果您还没有阿里云的云账号，请注册阿里云账号，并完成实名认证。

E-MapReduce服务账号授权

开通E-MapReduce服务后，您需要给E-MapReduce的服务账号授予名称为AliyunEMRDefaultRole和AliyunEmrEcsDefaultRole的系统默认角色，具体请参见[角色授权](#)。

RAM用户授权

如果您需要使用RAM用户登录E-MapReduce控制台，并使用控制台上的功能，则需要您使用主账号登录访问控制RAM控制台，授予RAM用户相应的权限，具体请参见[为RAM用户授权](#)。

确保账户余额充足

根据阿里云ECS的规则，您在购买按量付费实例时，需要保证阿里云账户中可用余额不少于100元的人民币（代金券无效）。充值方式请参见[前往充值](#)。


（可选）开通阿里云OSS服务

建议开通阿里云OSS服务，您可以将E-MapReduce作业日志和运行日志等数据保存在OSS存储空间中，方便使用并降低存储成本。开通阿里云OSS服务请参见[开通OSS服务](#)。在OSS上创建的存储空间需要与E-MapReduce集群地域相同，创建存储空间详情请参见[创建存储空间](#)。

（可选）创建AccessKey

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

1. 以主账号登录[阿里云管理控制台](#)。
2. 将鼠标置于页面右上方的账号图标，然后选择[AccessKey管理](#)。

 **注意** 如果出现如下提示框，请单击继续使用AccessKey。



3. 在[安全信息管理](#)页面，单击[创建AccessKey](#)。
4. 输入短信校验码，单击[确定](#)。

AccessKey创建成功。

（可选）开通高配机型

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，则[提交工单](#)处理。

3. 选型配置

选择合适的集群是E-MapReduce产品使用的第一步。E-MapReduce配置选型不仅要考虑企业大数据使用场景、估算数据量、服务可靠性要求，还要考虑企业预算。

大数据使用场景

E-MapReduce产品当前主要满足企业的以下大数据场景：

- 批处理场景
该场景对磁盘吞吐和网络吞吐要求高，处理的数据量也大，但对数据处理的实时性要求不高，您可以选用MapReduce、Pig、Spark组件。该场景对内存要求不高，选型时您需要重点关注作业对CPU和内存的需求，以及Shuffle对网络的需求。
- Ad-Hoc查询
数据科学家或数据分析师使用即席查询工具检索数据。该场景对查询实时性、磁盘吞吐和网络吞吐要求高，您可以选用E-MapReduce的Impala和Presto组件。该场景对内存要求高，选型时需要考虑数据和并发查询的数量。
- 流式计算、高网络吞吐和计算密集型场景
您可以选用E-MapReduce的Flink、Spark Streaming和Storm组件。
- 消息队列
该场景对磁盘吞吐和网络吞吐要求高，并且内存消耗大，存储不依赖于HDFS。您可以选用E-MapReduce的Kafka集群。
- 数据冷备场景
该场景对计算和磁盘吞吐要求不高，但要求冷备成本低，推荐使用EMR D1实例做数据冷备，D1本地盘实例存储成本为0.02元/月/GB。

E-MapReduce节点

E-MapReduce节点有主实例（Master）、核心实例（Core）和计算实例（Task）三种实例类型。详情请参见[实例类型](#)。

E-MapReduce存储可以采用高效云盘、本地盘、SSD云盘和SSD本地盘。磁盘性能为SSD本地盘 > SSD云盘 > 本地盘 > 高效云盘。

E-MapReduce底层存储支持OSS（仅标准型OSS）和HDFS。相对于HDFS，OSS的数据可用性更高（99.99999999%），HDFS的数据可用性由云盘或本地盘存储的可靠性来保证。

存储价格估算如下：

- 本地盘实例存储为0.04 元/GB/月
- OSS标准型存储为0.12 元/GB/月
- 高效云盘存储为0.35 元/GB/月
- SSD云盘存储为1.00 元/GB/月

E-MapReduce选型

- Master节点选型
 - Master节点主要部署Hadoop的Master进程。例如，NameNode和ResourceManager等。

- 生产集群建议打开高可用HA，E-MapReduce的HDFS、YARN、Hive和HBase等组件均已实现HA。生产集群建议在创建集群的**硬件配置**步骤开启高可用。如果购买时未开启高可用，在后续使用过程中无法开启高可用功能。
- Master节点主要用来存储HDFS元数据和组件Log文件，属于计算密集型，对磁盘IO要求不高。HDFS元数据存储在内存中，建议根据文件数量选择16 GB以上内存空间。
- Core节点选型
 - Core节点主要用来存储数据和执行计算，运行DataNode和Nodemanager。
 - HDFS数据量大于60 TB，建议采用本地盘实例（ECS.d1，ECS.d1NE），本地盘的磁盘容量为（CPU核数/2）*5.5TB*实例数量。
例如，购买4台8核D1实例，磁盘容量为 $8/2*5.5*4=88$ TB。因为HDFS采用3备份，所以本地盘实例最少购买3台，考虑到数据可靠性和磁盘损坏因素，建议最少购买4台。
 - HDFS数据量小于60 TB，可以考虑高效云盘和SSD云盘。
- Task节点选型

Task节点主要用来补充Core节点CPU和内存计算能力的不足，节点并不存储数据，也不运行DataNode。您可以根据CPU和内存需求来估算实例个数。

E-MapReduce生命周期

E-MapReduce支持弹性扩展，可以快速的扩容，详情请参见[扩容](#)，灵活调整集群节点配置。或者升降配ECS节点，详情请参见[升降配](#)。

可用区选择

为保证效率，您应该部署E-MapReduce与业务系统在同一地域的同一个可用区。详情请参见[地域和可用区](#)。

4. 创建集群

本文介绍如何在E-MapReduce控制台，快速创建一个按量付费的Hadoop集群。

前提条件

注册阿里云账号，并完成实名认证。具体操作请参见[阿里云账号注册流程](#)。

操作步骤

1. 登录[阿里云E-MapReduce控制台](#)。
2. 在创建集群页面，完成如下配置。本教程使用的配置如下，未提及的配置保持默认，更多配置信息详情请参见[创建集群](#)。

配置页面	配置项	示例	说明
软件配置	集群类型	Hadoop	默认集群类型。
	产品版本	EMR-3.28.2	默认最新的软件版本。
配置硬件	付费类型	按量付费	在前期程序研发或功能测试期间，建议创建按量付费类型的集群进行测试。
	可用区	华东1（杭州）可用区 I	集群创建后，无法直接更改地域和可用区，请谨慎选择。
	网络类型	专有网络	默认为专有网络，不可更改。
	VPC	VPC_Hangzhou(192.168.0.0/16)(ID: vpc-bp1f4epmkvncimpgs***)	选择对应区域下的VPC。如果没有，单击 创建VPC / 子网（交换机） 前往新建。
	交换机	vsw_i(192.168.1.0/24)(ID: vsw-bp1e2f5fhapl0g6p***)	选择在对应该VPC下可用区的交换机，如果在这个可用区没有可用的交换机，则需要新建一个。
	安全组名称	sg-bp1ddw7sm2riswb1aw3z(ID:sg-bp1ddw7sm2riswb1*****)	您可直接输入安全组名称来新建一个安全组。如果已有在使用的安全组，则可直接选择使用。
基础配置	集群名称	test	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、中划线(-)和下划线(_)。
	密码	自定义密码	请记录该配置，连接集群时您需要输入该密码。

3. 单击下一步：确定。
4. 选中E-MapReduce服务条款复选框。
5. 单击创建。

问题反馈

如果您在使用阿里云E-MapReduce过程中有任何疑问，欢迎您扫描下面的二维码加入钉钉群进行反馈。

5. 创建并运行作业

本文为您介绍如何创建并运行Spark作业的示例。

创建项目


1. 登录[阿里云E-MapReduce控制台](#)。
2. 单击上方的数据开发页签。
3. 在数据开发页面，单击新建项目。
4. 在新建项目对话框中，输入项目名称为test和项目描述为test。

5. 单击创建。

新建作业

1. 在项目列表页面，单击新建项目所在行的作业编辑。

2. 在作业编辑区域，在待操作的文件夹上单击右键，选择新建作业。

 说明 您还可以通过在文件夹上单击右键，进行创建子文件夹、重命名文件夹和删除文件夹操作。

3. 在新建作业对话框中，配置各项参数。
 - i. 设置作业名称为Spark_test。
 - ii. 设置作业描述为test。
 - iii. 从作业类型列表中，选择Spark。
 - iv. 单击确定。

配置并运行作业

1. 配置作业内容。
 - i. 在[集群基础信息](#)页面，查看Spark的版本。

- ii. 输入如下作业内容。

```
--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_2.11-2.4.5.jar 10
```

`/usr/lib/spark-current/examples/jars/spark-examples_2.11-2.4.5.jar` 中的 `2.4.5` 是您集群中的Spark版本。

2. 单击右上角的保存。

3. 单击右上角的运行。
4. 在运行作业对话框中，单击确定。

查看日志

您可以单击作业下方的运行记录页签，查看作业的运行情况。



单击详情，您可以查看作业的实例信息、提交日志和YARN容器日志。

问题反馈

如果您在使用阿里云E-MapReduce过程中有任何疑问，欢迎您扫描下面的二维码加入钉钉群进行反馈。