

DataArtsFabric

用户指南

文档版本 01
发布日期 2025-07-08



版权所有 © 华为云计算技术有限公司 2025。保留一切权利。

非经本公司书面许可，任何单位和个人不得擅自摘抄、复制本文档内容的部分或全部，并不得以任何形式传播。

商标声明



HUAWEI和其他华为商标均为华为技术有限公司的商标。

本文档提及的其他所有商标或注册商标，由各自的所有人拥有。

注意

您购买的产品、服务或特性等应受华为云计算技术有限公司商业合同和条款的约束，本文档中描述的全部或部分产品、服务或特性可能不在您的购买或使用范围之内。除非合同另有约定，华为云计算技术有限公司对本文档内容不做任何明示或暗示的声明或保证。

由于产品版本升级或其他原因，本文档内容会不定期进行更新。除非另有约定，本文档仅作为使用指导，本文档中的所有陈述、信息和建议不构成任何明示或暗示的担保。

华为云计算技术有限公司

地址：贵州省贵安新区黔中大道交兴功路华为云数据中心 邮编：550029

网址：<https://www.huaweicloud.com/>

目录

- 1 准备工作..... 1**
 - 1.1 创建 IAM 用户并授权使用 DataArtsFabric..... 1
 - 1.2 配置 DataArtsFabric 服务委托权限..... 4
 - 1.3 创建接入客户端..... 10
 - 1.4 创建工作空间..... 12
- 2 Ray 场景..... 15**
 - 2.1 Ray 资源管理..... 15
 - 2.1.1 购买 Ray 资源..... 15
 - 2.1.2 退订 Ray 资源..... 16
 - 2.2 镜像包管理..... 17
 - 2.3 Ray 集群管理..... 20
 - 2.3.1 创建 Ray 集群..... 21
 - 2.3.2 查看 Ray 集群概览..... 22
 - 2.3.3 创建 Ray Job..... 23
 - 2.3.4 运行 Ray Job..... 26
 - 2.3.5 管理 Ray Job..... 27
 - 2.3.6 查看 Ray Dashboard..... 27
 - 2.3.7 删除 Ray 集群..... 28
 - 2.3.8 查看指标..... 29
 - 2.4 管理 Ray 服务..... 30
 - 2.4.1 创建 Ray 服务..... 30
 - 2.4.2 升级 Ray 服务..... 35
 - 2.4.3 运行推理服务..... 37
 - 2.4.4 删除 Ray 服务..... 39
- 3 DataArtsFabric SQL..... 41**
 - 3.1 DataArtsFabric SQL 使用流程..... 41
 - 3.2 管理 SQL 端点..... 41
 - 3.2.1 创建 SQL 端点..... 41
 - 3.2.2 修改 SQL 端点..... 43
 - 3.2.3 删除 SQL 端点..... 44
 - 3.2.4 查询 SQL 端点详情..... 45
 - 3.2.5 查询 SQL 作业历史..... 45

3.3 使用 SQL 编辑器.....	46
3.4 生态组件对接.....	47
3.4.1 使用 DBeaver 访问 DataArtsFabric SQL.....	47
3.4.2 使用 Tableau 访问 DataArtsFabric SQL.....	53
3.4.3 获取 JDBC.....	56
4 大模型推理场景.....	57
4.1 大模型推理场景介绍.....	57
4.2 大模型推理使用流程.....	57
4.3 用公共推理服务进行推理.....	58
4.3.1 查看公共推理服务.....	58
4.3.2 开通推理服务.....	59
4.3.3 在试验场进行推理.....	59
4.4 创建我的推理服务进行推理.....	62
4.4.1 创建模型.....	62
4.4.2 管理模型.....	67
4.4.3 创建推理端点.....	69
4.4.4 创建推理服务.....	72
4.4.5 使用推理服务进行推理.....	75
4.4.6 删除推理服务.....	77
4.4.7 删除推理端点.....	78
4.5 通过 AOM 查看全量指标.....	79
5 运维管理.....	81
5.1 设置消息通知.....	81
5.2 删除消息通知.....	83

1 准备工作

1.1 创建 IAM 用户并授权使用 DataArtsFabric

在使用DataArtsFabric相关功能之前，您需要提前做好准备工作，包括开通账号、开通与配置账号子账号权限、创建工作空间等。本章节详细介绍创建IAM用户并授权使用DataArtsFabric操作步骤。


前提条件

已有可正常使用的华为云账号。

操作步骤


步骤1 登录华为云控制台，在页面左上角单击，在服务列表中选择“统一身份认证服务 IAM”。

图 1-1 选择服务列表



步骤2 单击“权限管理>权限”，单击右上角“创建自定义策略”，输入必要参数后单击“确定”。详细创建流程参考[创建自定义策略](#)。

图 1-2 创建自定义策略



管理员可以通过为不同的用户组设置不同的策略，对不同的用户设置不同的用户组来实现用户权限控制，管理员可以根据自己的需求配置权限，下面给出一些建议的权限组合供管理员参考。

表 1-1 权限介绍

业务角色	策略	功能
系统管理员	<pre>{ "Version": "1.1", "Statement": [{ "Effect": "Allow", "Action": ["DataArtsFabric:*:*", "obs:bucket:*", "obs:object:*"] }] }</pre>	拥有DataArtsFabric所有权限，可以进行所有DataArtsFabric操作。
资源管理员	<pre>{ "Version": "1.1", "Statement": [{ "Effect": "Allow", "Action": ["DataArtsFabric:workspace:*", "DataArtsFabric:endpoint:*", "lakeformation:instance:*"] }] }</pre>	用户DataArtsFabric资源的管理权限，可以进行工作空间，端点的创建删除等操作。


业务角色	策略	功能
推理业务操作员	<pre>{ "Version": "1.1", "Statement": [{ "Effect": "Allow", "Action": ["DataArtsFabric:workspace:list", "DataArtsFabric:endpoint:list", "DataArtsFabric:endpoint:show", "DataArtsFabric:model:*", "DataArtsFabric:service:*", "obs:object:*", "obs:bucket:ListBucket"] }] }</pre>	可以执行推理相关的业务，包括注册模型，创建推理服务，进行推理。
作业业务操作员	<pre>{ "Version": "1.1", "Statement": [{ "Effect": "Allow", "Action": ["DataArtsFabric:workspace:list", "DataArtsFabric:endpoint:list", "DataArtsFabric:endpoint:show", "DataArtsFabric:job:*", "obs:object:*", "obs:bucket:ListBucket"] }] }</pre>	可以执行作业相关的业务，包括创建作业执行作业。

步骤3 在左侧导航栏单击“用户组”，单击右上角“创建用户组”，输入用户组名称后单击“确定”。

步骤4 在用户组列表中，选择创建的用户组，单击“授权”，选择必要的策略，单击“下一步”，按需选择“授权范围方案”，单击“确定”。详细流程参考[创建用户组并授权](#)。

步骤5 在左侧导航栏单击“用户”，右上角“创建用户”，按需输入“用户信息”，选择“访问方式”和“凭证类型”，单击“下一步”。

图 1-3 示例图片



步骤6 在“可选用户组”列表，选择目标用户组，单击“创建用户”。更多信息，请参考[创建IAM用户](#)。

----结束

1.2 配置 DataArtsFabric 服务委托权限

当前云服务提供多种功能，不同的功能需要不同的委托权限。详细见[表1-2](#)。

前提条件

已有可正常使用的华为云账号。

操作步骤

步骤1 登录[DataArtsFabric工作空间管理台](#)，单击“服务授权”。

图 1-4 服务授权界面



步骤2 在“服务授权”页面配置授权委托。用户可以根据实际需要参照委托策略进行配置委托权限。

图 1-5 服务授权配置



表 1-2 委托策略

委托策略名称	权限项	是否必须	功能
FABRIC_COMMON_POLICY	iam:agencies:listAgencies iam:roles:getRole iam:permissions:listRolesForAgency obs:bucket:ListAllMyBuckets obs:bucket:ListBucket obs:object:GetObjectVersion obs:object:GetObject	是	- IAM相关权限：仅委托部分只读权限，保证服务能够比较当前用户的委托和服务需要的委托，用于提示用户进行委托更新。 - OBS相关权限：服务所有业务，包括作业，推理，都需要OBS文件的读取权限，保证后续能够从用户的OBS桶拉取到作业文件进行执行，模型文件进行部署。针对OBS的权限，用户可以在IAM的委托界面手动修改fabric_admin_trust委托中OBS相关的部分，限制服务可以访问的OBS资源，具体如何设置参考IAM权限，OBS自定义策略样例。

委托策略名称	权限项	是否必须	功能
FABRIC_LTS_POLICY	lts:groups:create lts:groups:get lts:groups:list lts:topics:create lts:topics:get lts:topics:list	是	DataArtsFabric服务配置转储日志所需的权限。
FABRIC_SEL_F_POLICY	DataArtsFabric:workspace:list DataArtsFabric:workspace:listRoute DataArtsFabric:workspace:showSession DataArtsFabric:workspace:listMessagePolicy DataArtsFabric:endpoint:show DataArtsFabric:endpoint:list DataArtsFabric:job:dropJobInstance DataArtsFabric:job:listJobInstance	是	DataArtsFabric服务用来帮助用户管理资源所需的权限。
FABRIC_LAKEFORMATION_POLICY	lakeformation:accessTenant:grant lakeformation:access:delete lakeformation:access:create lakeformation:access:describe lakeformation:agreement:grant lakeformation:agreement:describe lakeformation:agreement:cancel lakeformation:agency:create lakeformation:agency:drop lakeformation:agency:describe	否	DataArtsFabric服务使用LakeFormation服务所需的权限。如果需要对接LakeFormation，则需要开启。
FABRIC_SMN_POLICY	smn:topic:publish	否	DataArtsFabric服务使用消息通知服务所需的权限。如果需要消息通知能力，则需要开启。

委托策略名称	权限项	是否必须	功能
FABRIC_SWR_POLICY	swr:repo:listRepoDomains swr:repo:listRepoTags swr:repo:createRepoDomain	否	DataArtsFabric服务使用用户共享的镜像所需要的权限。
FABRIC_VPC_EP_POLICY	vpcep:epservices:get vpcep:connections:update vpcep:permissions:update vpcep:permissions:list	否	DataArtsFabric服务使用连接用户网络功能所需权限。
FABRIC_OBS_POLICY	obs:bucket:PutLifecycleConfiguration obs:bucket:ListBucketMultipartUploads obs:object:GetObject obs:bucket:HeadBucket obs:bucket:DeleteBucket obs:bucket>CreateBucket obs:bucket:ListAllMyBuckets obs:bucket:ListBucket obs:object:PutObject	否	DataArtsFabric服务使用用户OBS桶所需权限

说明

除必选的委托，其他委托权限都支持取消。

步骤3 在桶策略中加入委托。

DataArtsFabric服务会使用委托fabric_admin_trust来访问用户的OBS桶中的文件，因此需要保证委托能正常访问用户的OBS桶。

用户需确认在DataArtsFabric服务中使用的OBS桶是否配置了桶策略。如果配置了桶策略，请确保委托没有被已有的桶策略拒绝，并且请按照以下步骤将委托加入桶策略中：

1. 登录[OBS管理控制台](#)，在左侧导航栏选择“资源管理 > 桶列表”。
2. 在“桶列表”页面，单击桶名称，进入“对象”页面。
3. 在左侧导航栏，单击“权限控制 > 桶策略”，然后单击“创建”。
4. 在“创建桶策略”面板，自定义策略名称，“被授权用户”选择“其他账号”，输入委托账号（格式为委托方账号ID/委托名称）。其中，委托名称为fabric_admin_trust。例如：s3a7973a07cf4725abf5ba0b6d7*****/fabric_admin_trust。

图 1-6 创建桶策略

创建桶策略 [如何配置?](#)

1

【创建桶】、【获取桶列表】两个服务级的操作权限，需要您通过 [统一身份认证](#) 进行配置。[如何配置?](#)

可视化视图

JSON视图

策略名称

请输入策略名称

效力

允许

拒绝

被授权用户

所有账号

当前账号

其他账号

请输入账号ID和IAM用户ID。格式：账号ID/IAM用户ID
可授权给多个IAM用户，每行一个。

账号ID/IAM

表示授权给账号下的所有IAM用户。[如何查看“账号ID”和“IAM用户ID”?](#)

委托账号

请输入委托方账号ID和委托名称。格式：委托方账号ID/委托名称
可授权给多个委托，每行一个。

删除

授权资源

整个桶（包括桶内对象）

当前桶

指定对象

授权操作

模板配置

自定义配置

授权条件（可选）

增加条件

本规则生效的所需条件，以此限定规则的生效范围，通过键值表达式实现 [查看配置案例](#)

键

如果...

限定词

条件运算符

值

操作

暂无授权条件

增加条件

步骤4 确认OBS是否配置了服务端加密。

如果OBS桶配置了服务端加密功能，且加密模式为SSE-KMS，则需要在委托 fabric_admin_trust 中加入KMS Administrator权限。详情信息，请参见[被委托账号或用户为什么无法上传下载KMS加密对象?](#)

由于安全管理的要求，DataArtsFabric无法为用户直接配置KMS Administrator权限。用户需要按照以下步骤确认并添加权限。

1.

登录[OBS管理控制台](#)，在左侧导航栏选择“资源管理 > 桶列表”。
2.

在“桶列表”页面，单击桶名称，进入“对象”页面。
3.

在左侧导航栏，单击“概览”。
4.

在“基础配置”区域，确认是否已配置[服务端加密](#)，且“加密模式”为“SSE-KMS”。
- 如果“加密模式”不是“SSE-KMS”，请跳过以下步骤。
- 如果“加密模式”是“SSE-KMS”，请继续执行以下步骤。

图 1-7 确认是否已配置服务端加密



图 1-8 加密模式为 SSE-KMS




5. 配置KMS Administrator权限。
 - a. 在OBS管理控制台右上角，鼠标悬停至用户名，单击“统一身份认证”。

图 1-9 统一身份认证




- b. 在IAM控制台左侧导航栏，单击“委托”。
- c. 在“委托”页面的文本框，搜索委托名称**fabric_admin_trust**，在**fabric_admin_trust**委托右侧，单击“授权”。

图 1-10 委托页面



- d. 在“授权”页面右上角的文本框，搜索策略名称**KMS Administrator**，选中该策略，单击“下一步”并完成授权。

图 1-11 授权页面



----结束

1.3 创建接入客户端

创建接入客户端后，您可以通过VPC端点服务使用内网域名或者IP访问DataArtsFabric服务的API。

前提条件

- 已有可正常使用的华为云账号。
- 当前账号已有足够的VPCEP、DNS内网域名等资源配额。如果创建失败，客户端将自动回滚删除，并回收相关资源。

操作步骤

创建客户端将产生费用，实际扣费以账单为准。详细信息，请参见[计费模式](#)。

1. 登录[DataArtsFabric工作空间管理台](#)，单击“接入管理”，进入客户端列表页，单击“创建客户端”。
2. 在“创建客户端”页面，输入“客户端名称”，选择“虚拟私有云”和“所属子网”，勾选“我已阅读、知晓并同意以上的内容”，单击“确定”完成创建。

图 1-12 创建客户端

创建客户端

配置说明

创建前请确保当前账号有足够的VPCEP、DNS内网域名等资源配额。如果创建失败，客户端将自动回滚删除，并回收相关资源。

计费说明

创建客户端将产生费用，实际扣费以账单为准。[了解更多](#)

* 客户端名称

* 虚拟私有云

创建私有虚拟云

* 所属子网

创建子网

最多可添加2个子网

☐ 我已阅读、知晓并同意以上的内容

取消

确定

表 1-3 创建客户端参数说明

参数	说明
客户端名称	自定义客户端的名称，只能包含字母、数字、下划线、中划线，且长度为4~32个字符。
虚拟私有云	在下拉列表选择虚拟私有云。关于如何创建私有虚拟云，请参见 创建虚拟私有云和子网 。


参数	说明
所属子网	在下拉列表选择所属子网。关于如何创建子网，请参见 创建虚拟私有云和子网 。

当客户端的“状态”变为“运行中”，表示客户端创建完成。

3. 单击客户端名称，进入客户端详情页，可以查看域名和接入连接表的IP地址。
通过域名和IP地址访问服务时，均需要将请求头中的HOST指定为域名。
- 使用域名调用：
curl -kv https://fabric-ep.{region}.myhuaweicloud.com/healthcheck -H "host: fabric-ep.{region}.myhuaweicloud.com"

- 使用IP调用：
curl -kv https://192.168.0.200/healthcheck -H "host: fabric-ep.{region}.myhuaweicloud.com"

图 1-13 客户端详情页



1.4 创建工作空间

工作空间是DataArtsFabric的基本单元，后续所有的操作都在工作空间中进行。因此在账号授权配置完成，需要首先创建工作空间。

用户可根据实际需要创建一个或多个工作空间，各个工作空间是单独隔离的。

前提条件

已有可正常使用的华为云账号。

操作步骤

- 步骤1 登录[DataArtsFabric工作空间管理台](#)，单击“创建工作空间”，参照[创建工作空间填写页面参数说明](#)输入必要参数后，单击“直接创建”。创建工作空间完成后会返回工作空间管理台界面。

图 1-14 创建工作空间

Fabric / 创建工作空间

< | 创建工作空间

基础配置

Workspace可以看做是一个逻辑容器，用于组织和管理Fabric的资源。

工作空间名称

请输入

工作空间描述（可选）

请输入255字以内描述

0/255

Metastore

创建工作Space需配置Metastore，如暂无Metastore可选择转跳LakeFormation服务进行创建。

使用已有Metastore

新建Metastore

企业项目（可选）

default

创建企业项目

标签（可选）

如果您需要使用同一标签标识多种云资源，即所有服务均可在标签输入框下拉选择同一标签，建议在TMS中创建预定义标签。[查看预定义标签](#)

+ 添加新标签

您还可以添加20个标签。

表 1-4 创建工作空间填写页面参数说明

参数	说明
工作空间名称	请输入工作空间名称，同一账号下集群不可重名。
工作空间描述	可选，请输入工作空间描述。
企业项目	选择某个企业项目后，集群和集群安全组将会创建在该企业项目下。您可以通过企业项目服务（EPS）管理集群及其他资源（节点、ELB、以及节点的安全组等）。
标签	可选，通过为资源添加标签，可以对资源进行自定义标记，实现资源的分类。 您可以在TMS中创建“预定义标签”，预定义标签对所有支持标签功能的服务资源可见，通过使用预定义标签可以提升标签创建和迁移效率。具体请参见创建预定义标签。 - 标签键只能包含中文、英文字母、数字、空格和特殊字符(-_./:=+@)，且首尾不能包含空格，不能以_sys_开头，长度不超过128个字符。资源标签键不可以为空。 - 标签值只能包含中文，英文字母、数字、空格和特殊字符(-_./:=+@)，长度不超过255个字符。资源标签值可以为空。

步骤2 单击已创建的工作空间中的“进入工作空间”，弹出用户协议时，用户可查看声明协议，确认后单击“同意授权”，后续即可正常进入创建好的工作空间。

----结束

2 Ray 场景

2.1 Ray 资源管理

2.1.1 购买 Ray 资源

前提条件

- 已有可正常使用的华为云账号。
- 已有至少一个正常可用的工作空间。

操作步骤

由于Ray是全托管模式，在使用Ray前，先需要购买Ray资源。操作步骤如下：

- 步骤1** 登录[DataArtsFabric工作空间管理台](#)。
- 步骤2** 选择已创建的工作空间，单击“进入工作空间”，选择“资源与资产 > Ray资源”。
- 步骤3** 右上角单击“购买Ray资源”，进入“购买Ray资源”页面。用户根据需求选择合适的DPU或者APU规格、数量、购买时长等内容。详细参数说明请参见[购买Ray页面参数说明](#)。

表 2-1 购买 Ray 页面参数说明

参数	参数说明
计费模式	可选择：包年/包月或者按需计费。
资源类型	分为DPU和APU两种，可根据实际需要勾选。 DPU：面向数据分析场景，基于CPU的计算单元。 APU：面向AI场景，基于NPU的计算单元。

参数	参数说明
规格大小	DPU资源规格fabric.ray.dpu.d1x、fabric.ray.dpu.d2x、fabric.ray.dpu.d4x等规格之间的区别主要体现在cpu数量及内存大小。 APU资源规格之间的区别主要体现在昇腾卡数量和机型差异，可根据需求选择不同规格的资源创建。 具体资源大小参考 产品规格 。
购买时长	可根据实际需要选择购买时长。

说明

购买Ray资源有最低资源要求，最低需要4个fabric.ray.dpu.d1x的资源总量，DataArtsFabric服务中 $\text{fabric.ray.dpu.dnx} = n * \text{fabric.ray.dpu.d1x}$ 。

步骤4 选择完成后，单击“下一步”。确认配置详情完成后，单击“去支付”跳转付款页面，付款完成即可完成购买。可在Ray资源标签中查看购买的资源状态。

说明

- 购买完成后“Ray资源”页面新建的资源会处于“准备中”，如果购买成功则变为“运行中”否则会变为“失败”状态。
- 如果是首次购买资源，则需要等待大约15~20分钟。如果购买清单中包含APU资源，则需要等待大约40~50分钟；如果是新增其他规格资源，则需要等待5分钟左右；如果新增的是APU资源，则需要等待20分钟左右。可手动刷新资源状态查看资源是否已准备好。
- 同一种规格只能购买一次，购买成功后可通过扩缩容调整数量。如果需要同时多次购买同一种规格，可新建一个workspace再购买。

----结束

2.1.2 退订 Ray 资源

前提条件

- 已有可正常使用的华为云账号。
- 已有至少一个正常可用的工作空间。
- 已购买Ray资源。

操作步骤

步骤1 登录[DataArtsFabric工作空间管理台](#)。

步骤2 选择已创建的工作空间，单击“进入工作空间”，选择“资源与资产 > Ray资源”。

步骤3 包周期与按需的操作有所不同，分别如下：

- 包周期：在对应Ray资源的操作列单击“更多 > 退订”。
- 按需：直接单击操作列“删除”。

图 2-1 退订 Ray 资源



说明

删除/退订Ray资源后无法恢复，且可能影响已存在的Ray集群状态。

步骤4 在弹出的二次确认界面确认后，输入“DELETE”后单击“确认”，即可删除已订购的Ray资源。

-----结束

2.2 镜像包管理

前提条件

- 已有可正常使用的华为云账号。
- 已有至少一个正常可用的工作空间。
- 请确保您已开通镜像包操作白名单功能。如果有试用需求，请在[DataArtsFabric工作空间管理台](#)顶部导航栏选择“工单 > 新建工单”申请权限。

上传镜像压缩包到 SWR


登录容器镜像服务SWR控制台，在“页面上传”对话框参照上传提示信息，上传镜像压缩包到SWR。如果文件大小超过2GB，请使用客户端上传。具体操作，请参见[页面上传镜像](#)。

图 2-2 上传镜像



上传完成后，镜像压缩包如下图所示。

图 2-3 镜像上传成功



创建镜像包

1.

登录[DataArtsFabric工作空间管理台](#)，选择已创建的工作空间，单击“进入工作空间”。
2.

在左侧导航栏，选择“运维管理 > 镜像包管理”，单击右上角的“创建镜像包”。
3.

根据提示输入名称和版本名称，为指定版本选择存储在OBS的镜像包路径，配置完成后，单击“确认”创建镜像包。
- 界面参数说明请参见[创建镜像包参数说明](#)。

图 2-4 创建镜像包

基础配置

名称

描述

类型

RAY_CLUSTER

版本信息

版本名称

版本描述

版本类型

OBS

路径

表 2-2 创建镜像包参数说明

参数	参数说明
名称	镜像包名称。
描述	根据需求填写该镜像包的描述信息。
类型	镜像包类型，Ray集群场景选择RAY_CLUSTER，Ray服务场景选择RAY_SERVICE。

参数	参数说明
版本名称	镜像包可有多个版本，根据当前创建信息填入一个版本名称。
版本描述	当前创建版本的描述信息。
版本类型	当前只支持OBS。
路径	当前创建版本所在的OBS路径。

 说明

如果新建RAY_CLUSTER或RAY_SERVICE类型的Cap，Cap的名称、版本名称需要和包名严格一致。

例如：OBS路径下包名obs://xxx/ray-cap/files/ray-cluster-2.34.0.tgz，包名为ray-cluster-2.34.0。则名称必须为ray-cluster，版本必须为2.34.0，否则页面会校验不通过。

创建完自定义版本后，则可以在创建Ray集群时看到“我的Ray镜像包”，或在创建Ray服务时看到“我的Ray服务镜像包”。

新增镜像包版本

1. 在“镜像包管理”页面的“操作”列，单击目标镜像包对应的“查看版本列表”。
 2. 在“当前镜像包版本列表”页面，单击“新增版本”。
 3. 在新增镜像包版本页面，配置相关信息，然后单击“确认”。
- 界面参数说明请参见[创建镜像包版本参数说明](#)。

图 2-5 创建镜像包版本

< | 新增镜像包版本

版本信息

版本名称

版本描述

版本类型

OBS

路径



表 2-3 创建镜像包版本参数说明

参数	参数说明
版本名称	镜像包支持有多个版本，请根据当前创建信息填入一个版本名称。镜像包版本需要和选择的OBS文件的包版本号一致。
版本描述	当前创建版本的描述信息。
版本类型	当前只支持OBS。
路径	当前创建版本所在的OBS路径。请选择到包含metadata.yaml文件的父级目录。

删除镜像包版本

删除镜像包版本后，相关数据将被全部清除，请您谨慎操作。

1. 在“镜像包管理”页面的“操作”列，单击目标镜像包对应的“查看版本列表”。
2. 在“当前镜像包版本列表”页面的“操作”列，单击目标版本对应的“删除”。
3. 在“删除当前镜像包版本”对话框，输入“DELETE”或者单击“一键输入”，然后单击“确认”。

图 2-6 删除镜像包版本



删除镜像包

删除镜像包后无法恢复，相关数据将被全部清除，请您谨慎操作。

1. 在“镜像包管理”页面的“操作”列，单击目标镜像包对应的“删除”。
2. 在“删除当前镜像包”对话框，输入“DELETE”或者单击“一键输入”，然后单击“确认”。

图 2-7 删除当前镜像包



2.3 Ray 集群管理

2.3.1 创建 Ray 集群

Ray是一款高性能分布式执行框架，它使用了和传统分布式计算系统不一样的架构，提供了分布式计算的抽象方式。

Ray集群采用全托管独享模式，用户无需关心后台的资源管理，提供基于Ray的分布式作业执行能力，完全兼容开源版本，用户无需对脚本进行复杂的适配就可以使用，并且开放原生的Dashboard能力，保证用户的使用习惯。相比开源Ray，DataArtsFabric服务做了一系列的安全加固，保证用户数据安全，例如gRPC通道加密、Dashboard认证访问等。

前提条件

- 已有可正常使用的华为云账号。
- 已有至少一个正常可用的工作空间。
- 已购买相应的Ray资源。

操作步骤

- 步骤1** 登录[DataArtsFabric工作空间管理台](#)。
- 步骤2** 选择已创建的工作空间，单击“进入工作空间”，选择“资源与资产 > Ray集群”。单击右上角的创建Ray集群。
- 步骤3** 在“创建Ray集群”页面，参照[创建Ray集群参数说明](#)根据需求选择合适的head以及worker规格以及数量，参数填写完成后，单击“立即创建”即可创建Ray集群。

图 2-8 创建 Ray 集群

Ray集群 / 创建Ray集群

< | 创建Ray集群

基础设置

集群名称

请输入

描述 (可选)

请输入

¥1,000

Ray镜像包类型

公共Ray镜像包

Ray镜像包版本 (可选)

ray-cluster

请选择版本

Head规格

请选择

Worker规格

请选择

Worker数量下限

请输入

Worker数量上限

请输入

名称

workergroup001

删除

+ 添加Worker

立即创建

表 2-4 创建 Ray 集群参数说明

参数	参数说明
集群名称	创建Ray集群的名称。
Ray镜像包类型	选择公共Ray镜像包。

参数	参数说明
Ray镜像包版本	可根据需求选择不同的Ray版本，版本号与Ray社区的版本一致。
Head规格	创建Ray集群的head节点规格，可根据业务需求选择。 规格选择列表中可以看到所有的规格，选择的规格可根据创建的Ray资源向下兼容，例如创建了一个fabric.ray.dpu.d4x的资源，那么在选择head规格的时候可以选择fabric.ray.dpu.d1x、fabric.ray.dpu.d2x、fabric.ray.dpu.d4x，即一个大的资源规格可以被拆分为多个小的资源规格。
Worker规格	创建Ray集群的worker group规格，可创建多个worker group。 从资源规格列表中选择一个规格部署Worker节点，同时配置worker节点的数量上/下限，worker节点下限至少需要填1，上限请根据业务压力填写。Ray集群初始化创建下限数量的worker规格，根据负载压力动态弹性扩缩到上限数量。也可添加多种不同规格的worker节点。worker节点的规格选择也遵循已有资源向下兼容拆分的规则。例如，当前购买的Ray资源为fabric.ray.dpu.d4x，其中head节点规格选择了fabric.ray.dpu.d1x，那么worker节点也可以选择fabric.ray.dpu.d1x，同时数量上限设置为3。

----结束

说明

您可以手动刷新查看Ray集群创建状态，创建过程约需要3-5分钟。

如果创建Ray集群失败，再次创建之前需要先删除创建失败的Ray集群，避免失败的集群继续占用资源。

2.3.2 查看 Ray 集群概览

前提条件

- 已有可正常使用的华为云账号。
- 已有至少一个正常可用的工作空间。
- 已有至少一个Ray集群。

操作步骤

步骤1 登录[DataArtsFabric工作空间管理台](#)。

步骤2 选择已创建的工作空间，单击“进入工作空间”，选择“资源与资产 > Ray集群”。单击任意一个Ray集群可查看详情页面。

图 2-9 Ray 详情



表 2-5 参数说明

参数	说明
集群名称	自定义的Ray集群名称。
集群ID	集群唯一标识ID。
状态	当前集群状态。
描述	对集群的自定义描述信息。
创建人	集群的创建者。
创建时间	创建集群的时间。
集群版本	集群当前部署的Ray集群版本信息。
Ray资源	集群部署所占资源规格及数量。
访问链接	Ray dashboard的访问地址。

----结束

2.3.3 创建 Ray Job

前提条件

- 已有可正常使用的华为云账号。
- 已有至少一个正常可用的工作空间。
- 已有至少一个可用的Ray集群。

- 已根据业务需求开发Job相关代码，并将代码上传至OBS（创建OBS桶及上传文件请参考[OBS创建桶](#)）。

操作步骤

步骤1 登录[DataArtsFabric工作空间管理台](#)。

步骤2 选择已创建的工作空间，单击“进入工作空间”，选择“开发与生产 > Job定义”。

步骤3 单击右上角“创建作业”。根据[创建Job参数说明](#)填写必要的信息，作业类型选择Ray，其他内容根据情况填写后创建作业。其中，Ray主文件为您开发的Job主入口文件。

图 2-10 创建 Job

基础配置

Job名称

请填写名称

Job类型

Ray

代码目录

请选择代码目录

选择

Ray主文件

请选择启动文件

选择文件

请不要在脚本中输入敏感信息，也不要通过脚本打印敏感信息

Ray作业参数 (可选) ?

请填写参数，例如：["--class","org.ray.examples.rayTest","10","model_2","20"]

请不要在脚本中输入敏感信息，也不要通过脚本打印敏感信息

依赖库 (可选) ?

例如：
numpy==1.24.3

格式与requirements.txt一致

Ray集群 (可选)

请选择

版本名称

v1

版本描述 (可选)

请输入1000字以内描述

0/1,000

表 2-6 创建 Job 参数说明

参数	参数说明
Job名称	创建Job定义的名称。
Job类型	默认为Ray。

参数	参数说明
代码目录	选择您存储在OBS的Job定义目录。
Ray主文件	选择代码目录中的Job运行代码的主入口Python文件。请确保您选择的主文件为整个Job运行的主入口文件，否则运行Job可能与您的预期不符。 说明 请不要在脚本中输入敏感信息，也不要通过脚本打印敏感信息。
Ray作业参数	Ray主文件执行时所需的参数，示例如下： ["--class","org.ray.examples.rayTest","10","model_2","20"] 说明 请不要在脚本中输入敏感信息，也不要通过脚本打印敏感信息。
依赖库	Ray作业运行前所依赖的软件及版本，Ray作业运行前会先通过pip安装此依赖。格式与requirements.txt一致。示例如下： numpy==1.24.3
Ray集群	指定在目标Ray集群上执行。
版本名称	作业版本。
版本描述	版本描述，字数为1000字以内。

----结束

2.3.4 运行 Ray Job

前提条件

- 已有可正常使用的华为云账号。
- 已有至少一个正常可用的工作空间。
- 已有至少一个可用的Ray集群。
- 已有至少一个可用的Job作业。

操作步骤

- 步骤1** 登录[DataArtsFabric工作空间管理台](#)。
- 步骤2** 选择已创建的工作空间，单击“进入工作空间”，选择“开发与生产 > Job定义”。
- 步骤3** 在作业列表表中选择一个作业，指定其运行的Endpoint后，单击操作列“启动”，即可启动一个Job。

图 2-11 启动作业



----结束

2.3.5 管理 Ray Job

前提条件

- 已有可正常使用的华为云账号。
- 已有至少一个正常可用的工作空间。
- 已有至少一个可用的Ray集群。
- 已有至少一个可用的Job作业。

操作步骤

- 步骤1** 登录[DataArtsFabric工作空间管理台](#)。
- 步骤2** 选择已创建的工作空间，单击“进入工作空间”，选择“开发与生产 > Job定义”。
- 步骤3** 可根据需要在操作列选择Job的启动、查看、删除等操作。可根据Job名称、状态、运行端点名称、类型过滤不同的Job。
- 步骤4** 通过操作列“查看Dashboard”，打开Ray自带的dashboard工具，查看Job的运行情况详情。

图 2-12 示例图片



Job名称	状态	Job版本	运行ID	创建时间	运行时长(s)	运行端点名称	类型	操作
RayDemo4-4622aefc-3...	成功	versionName	31775fbc-7e4f-4ba5-99...	2024/09/20 11:41:40	34	ray-cluster-2	RAY_JOB	停止 删除 查看Dashboard

----结束

2.3.6 查看 Ray Dashboard

创建Ray集群后，运行Ray Job，如果需要查看Job的运行情况，或者查看Ray集群的详细信息，可通过打开Ray自带的Dashboard查看。

前提条件

- 已有可正常使用的华为云账号。
- 已有至少一个正常可用的工作空间。
- 已有至少一个可用的Ray集群。
- 已有至少一个可用的Job作业。

操作步骤

查看路径的方法有以下两种：

- 方法一：通过Ray集群页面进入Dashboard。
 - a. 登录[DataArtsFabric工作空间管理台](#)。
 - b. 选择已创建的工作空间，单击“进入工作空间”，选择“资源与资产 > Ray 集群”。
 - c. 单击想要查看Dashboard的Ray集群。

d. 单击最下方的访问链接。

图 2-13 访问链接

概览		
集群名称	test	
集群ID	6b95de28-a0ea-4b27-9652-dbc	
状态	 运行中	
描述		
创建人		
创建时间	2024/11/06 15:19:02	
集群版本	ray-cluster 2.34.0 回退到上一版本	
Ray资源	Head规格	fabric.compute.dpu.d1x
	Worker规格	workergroup001: fabric.compute.dpu.d1x 数量上下限 2-4
访问链接	dashboard	https://313b8027-8e2f-448d-88af-5705690

- 方法二：通过Job运行页面进入Dashboard。
请参见[管理Ray Job](#)中通过Job进入Dashboard查看。

2.3.7 删除 Ray 集群

前提条件

- 已有可正常使用的华为云账号。
- 已有至少一个正常可用的工作空间。
- 已有至少一个Ray集群。
- 如果当前Ray集群有运行Job记录，则需要先删除Job才能删除Ray集群。


操作步骤

- 步骤1** 登录[DataArtsFabric工作空间管理台](#)。
- 步骤2** 选择已创建的工作空间，单击“进入工作空间”，选择“资源与资产 > Ray集群”。
- 步骤3** 选择需要删除的Ray集群，单击右上角的“删除”按钮即可删除对应的Ray集群。

注意

Ray集群一旦删除所有记录都会被清理掉，且无法恢复。请谨慎操作。

图 2-14 删除示例



步骤4 在弹出的二次确认界面确认后，输入“DELETE”后单击“确认”，即可删除Ray集群。

----结束

2.3.8 查看指标

为使用户更好地掌握Ray集群资源的使用情况，云服务平台将指标上报到了应用运维管理AOM，用户可以通过应用运维管理AOM查询资源使用情况。


前提条件

- 已有可正常使用的华为云账号。
- 已有至少一个正常可用的工作空间。
- 已有至少一个Ray集群。

操作步骤

- 步骤1** 登录应用运维管理平台。
- 步骤2** 在左侧导航栏选择“指标预览”，指标源选择Prometheus_AOM_Default。

图 2-15 配置指标源



步骤3 全量指标中输入指标名称进行查询。

表 2-7 监控指标

指标名称	描述
fabric_dpu_cpu_usage	该指标用于统计Ray集群head和worker的cpu资源使用率。 单位：百分比。
fabric_dpu_mem_usag e	该指标用于统计Ray集群head和worker的内存资源使用率。 单位：百分比。

----结束

2.4 管理 Ray 服务

2.4.1 创建 Ray 服务

前提条件

- 已有可正常使用的华为云账号。具体操作，请参见[创建IAM用户并授权使用DataArtsFabric](#)和[配置DataArtsFabric服务委托权限](#)。
- 已有至少一个正常可用的工作空间。具体操作，请参见[创建工作空间](#)。
- 已购买相应的Ray资源。具体操作，请参见[购买Ray资源](#)。
- 已创建Ray服务镜像包版本与推理部署文件。关于如何创建镜像包，请参见[创建镜像包](#)。
- 如果使用云日志服务LTS查看日志，则需要授予LTS权限。具体操作，请参见[授权IAM用户使用云日志服务LTS](#)。

创建 Ray 服务

- 步骤1** 登录[DataArtsFabric工作空间管理台](#)。
- 步骤2** 选择已创建的工作空间，单击“进入工作空间”，在左侧导航栏选择“资源与资产 > Ray服务”，单击右上角的“创建Ray服务”。
- 步骤3** 在“创建Ray服务”页面，配置Ray服务的相关信息，包括基础信息、日志设置、Ray集群、数据信息和Ray Serve。
- 关于配置项的说明，请参见[表2-8](#)。

图 2-16 基础信息配置




图 2-17 Ray Serve 配置




表 2-8 创建 Ray 服务配置项说明

参数		说明
基础设置	Ray服务名称	创建Ray服务的名称。
	添加描述	单击“添加描述”，在文本框输入Ray服务的简介。支持1000字符。

参数		说明
	镜像包来源	选择我的Ray服务镜像包。支持公共Ray服务镜像包和我的Ray服务镜像包。 - 公共Ray服务镜像包：公共共享镜像包，由DataArtsFabric服务提供，基于开源的Ray镜像，包含支持通道加密、dashboard安全访问、密钥加解密等DataArtsFabric特性增强能力。 - 我的Ray服务镜像包：由租户自定义镜像包，租户可以根据需求自定义Ray镜像，并通过DataArtsFabric提供的“镜像包管理”功能创建相应的镜像包并部署。
	镜像包名称	使用的服务镜像包名称。
	镜像包版本	可根据需求选择不同的Ray服务版本。
日志设置	启用LTS	是否将Ray服务运行日志存储到华为云LTS服务提供的日志服务中。 启用后，将采集以下路径下的日志： /tmp/ray/session_latest/logs/**/* /var/log/service-log/**/*
	日志组	选择华为云LTS服务日志组。您可以在云日志服务LTS控制台创建日志组，具体操作请参见 创建日志组 。
	日志流	选择华为云LTS服务日志流。您可以在云日志服务LTS控制台创建日志流，具体操作请参见 创建日志流 。
Ray集群配置	Head规格	创建Ray集群的Head节点规格，可根据业务需求选择。规格选择列表中可以看到所有的规格，选择的规格可根据创建的Ray资源向下兼容，例如创建了一个fabric.ray.dpu.d4x的资源，在选择head规格时可以选择fabric.ray.dpu.d1x、fabric.ray.dpu.d2x、fabric.ray.dpu.d4x，即一个大的资源规格可以被拆分为多个小的资源规格。
	Worker规格	创建Ray集群的Worker Group规格。您可以单击添加Worker组创建多个规格的Worker Group。 从资源规格列表中选择一个规格部署Worker节点，同时配置Worker节点的数量上下限，Worker节点下限至少为1，上限请根据业务压力填写。 Ray集群初始化创建下限数量的Worker规格，根据负载压力动态弹性扩缩到上限数量。 Worker节点的规格选择也遵循已有资源向下兼容拆分的规则。例如，当前购买的Ray资源为fabric.ray.dpu.d4x，其中Head节点规格选择了fabric.ray.dpu.d1x，那么Worker节点也可以选择fabric.ray.dpu.d1x，同时数量上限设置为3。

参数		说明
数据信息	数据输入	运行推理服务时使用的模型路径，Ray服务创建之后会将该路径下模型文件复制至Ray服务集群。
Ray Serve配置	增加 Application	您可以单击“增加Application”，配置和定制部署文件、运行环境和调度参数等，最多增加5个Application。
	Application名称	创建Application的名称。
	代码目录	执行推理所需的代码目录，支持选择“OBS对象存储”、“镜像内部路径”和“其他”。
	部署文件路径	推理实例在代码中的路径。
	路由前缀	推理路由前缀，不同Application的路由前缀不可重复。
	环境变量	根据业务需求选中“环境变量”，单击“增加”填写环境变量。训练容器中预置的环境变量请参考 管理训练容器环境变量 。
	Deployment	Application内部对应的推理实例。选中“Deployment”，根据各Application内具体规格填写。 单个Application内可建立多个Deployment，每个Deployment可单独作Ray Actor、自动扩缩与推理自定义配置。 Deployment可在Ray Actor中单独配置资源占用，但单个Application内Deployment配置占用资源之和不得超过基础配置中Worker规格。 Deployment可配置固定副本数与最大副本数，也可配置自动扩缩范围；如果Deployment已配置固定副本数，将无法进行自动扩缩配置。

----结束

查看 Ray 服务详情

- 步骤1** 登录[DataArtsFabric工作空间管理台](#)。
- 步骤2** 选择已创建的工作空间，单击“进入工作空间”，在左侧导航栏选择“资源与资产 > Ray服务”。
- 步骤3** 在“Ray服务”页面，单击目标Ray服务名称进入Ray服务详情页面。
- 在“Ray服务详情”页面，可以查看Ray服务的概览和Ray Serve配置。详细说明，请参见[表2-9](#)和[表2-10](#)。

图 2-18 概览




图 2-19 Ray Serve 配置




表 2-9 概览页签的参数说明

参数	说明
Ray服务名称	自定义的Ray服务名称。
Ray服务 ID	Ray服务唯一标识ID。
状态	当前Ray服务状态。
描述	对Ray服务的自定义描述信息。
创建人	Ray服务的创建者。
创建时间	创建Ray服务的时间。
镜像包版本	Ray服务当前部署的Ray服务镜像版本信息。
Head规格	Ray服务部署Head节点所占资源规格及数量。
Worker规格	Ray服务部署Worker节点所占资源规格及数量。
Dashboard	Ray服务Dashboard的访问地址。

参数	说明
数据信息	根据用户自定义输入路径生成的路径及环境变量信息。
LTS转储开启	是或否，创建Ray服务时日志设置中开启LTS则为是。
查看LTS日志	LTS转储开启时，您可以单击链接跳转到LTS日志流查看日志。

表 2-10 Ray Serve 配置页签的参数说明

参数	说明
Application名称	创建Application的名称（如 图4 Ray Serve配置 为fruit_app与math_app）。
推理地址	调用推理服务的具体地址，具体操作请参见 运行推理服务 。
代码目录	执行推理所需的代码目录。
部署文件路径	推理实例在代码中的路径。
路由前缀	推理路由前缀，不同Application的路由前缀不可重复。
环境变量	容器内环境变量，当前基于代码目录与模型目录生成
Deployment	Application内部对应的推理实例。 单个Application内可存在多个Deployment，每个Deployment可单独作Ray Actor、自动扩缩与推理自定义配置。 Deployment可在Ray Actor中单独配置资源占用，但单个Application内Deployment配置占用资源之和不得超过基础配置中Worker规格。 Deployment可配置固定副本数与最大副本数，也可配置自动扩缩范围；如果Deployment已配置固定副本数，将无法进行自动扩缩配置。

----结束

2.4.2 升级 Ray 服务

前提条件

- 已有可正常使用的华为云账号。具体操作，请参见[创建IAM用户并授权使用DataArtsFabric](#)和[配置DataArtsFabric服务委托权限](#)。
- 已有至少一个正常可用的工作空间。具体操作，请参见[创建工作空间](#)。
- 已购买相应的Ray资源。具体操作，请参见[购买Ray资源](#)。
- 已创建升级Ray服务镜像包版本与推理部署文件（如果需要升级）。关于如何创建镜像包，请参见[创建镜像包](#)。

升级 Ray 服务

说明

您可以根据需求选择镜像包版本或修改Ray Service配置，版本升级不会中断您已有的业务。

- 步骤1 登录[DataArtsFabric工作空间管理台](#)。
- 步骤2 选择已创建的工作空间，单击“进入工作空间”，选择“资源与资产 > Ray服务”，搜索待升级的Ray服务。
- 步骤3 在“操作”列，单击“版本升级”。
- 步骤4 在“版本升级”页面，选择需要升级的镜像包版本、Ray集群配置、数据信息和Ray Serve配置。

关于配置项说明，请参见[表2-8](#)。

说明

升级Ray服务等待时间为3000s，超时会导致升级失败

图 2-20 升级 Ray 服务的基础配置





图 2-21 升级 Ray 服务的 Ray serve 配置



----结束

回退升级 Ray 服务

如果使用了错误的升级配置或其他原因，可能会导致升级Ray服务失败，此时需要对升级失败的Ray服务进行回退操作。

- 步骤1 在“Ray服务”页面，搜索升级失败的Ray服务，在“操作”列单击“回退到上一版本”，进行版本回退。
- 步骤2 在“回退到上一版本”对话框，确认回退版本无误后，单击“确认”进行回退。

图 2-22 回退确认弹窗



----结束

2.4.3 运行推理服务

前提条件

- 已有可正常使用的华为云账号。具体操作，请参见[创建IAM用户并授权使用DataArtsFabric](#)和[配置DataArtsFabric服务委托权限](#)。
- 已有至少一个正常可用的工作空间。具体操作，请参见[创建工作空间](#)。
- 已有至少一个Ray服务。具体操作，请参见[创建Ray服务](#)。

运行推理服务

- 步骤1 登录[DataArtsFabric工作空间管理台](#)。
- 步骤2 选择已创建的工作空间，单击“进入工作空间”，选择“资源与资产 > Ray服务”。

步骤3 在“Ray服务”页面的“推理地址”列，获取目标Ray服务的推理地址。

图 2-23 Ray 服务推理地址

Ray服务			
Q 选择属性筛选，或输入关键字搜索			
名称	状态	推理地址	镜像包
ray	运行中	https://fabric	rayservice 3.0.3

步骤4 使用API工具或其他方法调用推理地址，查询推理结果。

如图，使用curl进行推理：

```
curl -s -k --location -X POST 'https://fabric-inference-url/v1/workspaces/{workSpaceId}/endpoints/{endPointId}/rayservice/fruit' --header "X-Auth-Token: $(cat test.json)" --header 'Content-Type: application/json' --data-raw '{"MANGO": 31}'
```

得到推理结果：9

图 2-24 运行 Ray 服务推理

```
$ curl -s -k --location -X POST 'https://fabric-  
6799-4c4f-818d-8e6 /endpoints/821411e2-1b69-436a-9e37-ad969e9 /rayservice/fruit' --header "X-Auth  
-Token: $(cat test.json)" --header 'Content-Type: application/json' --data-raw '["MANGO", 3]'
```

-----结束

查看 Ray 服务的 Dashboard

步骤1 登录DataArtsFabric工作空间管理台。

步骤2 选择已创建的工作空间，单击“进入工作空间”，选择“资源与资产 > Ray服务”。


步骤3 在“Ray服务”页面，单击目标Ray服务名称。

步骤4 在“Ray服务详情”页面的“概览”页签，单击“Dashboard”右侧的“立即查看”，进入Ray服务的Dashboard，查看推理服务具体信息。

图 2-25 Dashboard 入口



图 2-26 Dashboard 详情



----结束

2.4.4 删除 Ray 服务

前提条件

已有至少一个Ray服务。具体操作，请参见[创建Ray服务](#)。

操作步骤



Ray服务一旦删除所有记录都会被清理掉，且无法恢复。请谨慎操作。

步骤1 登录[DataArtsFabric工作空间管理台](#)。

步骤2 选择已创建的工作空间，单击“进入工作空间”，选择“资源与资产 > Ray服务”。

步骤3 在需要删除的Ray服务右侧，单击“更多 > 删除”，在“删除Ray服务”对话框，输入**DELETE**，单击“确定”。

----结束

3 DataArtsFabric SQL

3.1 DataArtsFabric SQL 使用流程

DataArtsFabric SQL使用流程如表3-1所示。

表 3-1 操作流程

操作步骤	说明
准备工作	注册华为账号并开通华为云，实名认证，为账户充值，已开通LakeFormation、OBS权限并进行了委托确认。
创建工作空间	创建一个新的工作空间，此步骤为可选，如果使用已创建的工作空间可直接跳过。
创建SQL端点	创建一个新的SQL端点，此步骤为可选，如果使用公共端点可直接跳过。
规划并创建OBS桶并导入数据	创建OBS桶及文件夹，用于数据存储。
规划并创建Catalog、数据库	在LakeFormation界面进行Catalog、数据库的创建，并指定OBS桶目录。
查询数据	在SQL编辑器界面进行SQL查询。


3.2 管理 SQL 端点

3.2.1 创建 SQL 端点

在使用DataArtsFabric SQL服务的时候除了使用公共端点，用户也可以自己创建端点。这些端点是属于用户个人，其他用户不可见。

步骤1 登录华为云DataArtsFabric控制台，选择进入工作空间。


步骤2 左侧选择“资源与资产 > SQL端点”。



步骤3 单击“创建端点”"，输入“端点名称”、“描述”、“预热资源数”，选择“启用公共端点”，完成我的端点创建。

创建SQL端点的基本信息

参数名称	说明
名称	必填，SQL端点名称。 长度为1-64，不支持重复名称。 只能包含中文、字母、数字、下划线、中划线、点、空格。
描述	可选，SQL端点的描述信息。 长度为0-1024。不支持^!<>=&"等特殊字符。
预热资源数	必填，SQL端点的预热资源数。最小为50，最大为5000。
启用公共端点	启用时，当预热资源不足，自动调度到公共端点。




----结束

3.2.2 修改 SQL 端点


在使用DataArtsFabric SQL服务的时候，用户可以修改自己创建的端点。


步骤1 登录华为云DataArtsFabric控制台，选择进入工作空间。

步骤2 左侧选择“资源与资产 > SQL端点”。



步骤3 单击端点卡片，进入端点详情，单击“编辑SQL端点”，修改内容后保存。






----结束


3.2.3 删除 SQL 端点

步骤1 登录华为云DataArtsFabric控制台，选择进入工作空间。

步骤2 左侧选择“资源与资产 > SQL端点”。



步骤3 单击端点卡片右上角删除按钮并确认，完成我的端点删除。




----结束


3.2.4 查询 SQL 端点详情

步骤1 登录华为云DataArtsFabric控制台，选择进入工作空间。

步骤2 左侧选择“资源与资产 > SQL端点”。



步骤3 单击端点卡片，查看端点详情。




----结束

3.2.5 查询 SQL 作业历史

步骤1 登录华为云DataArtsFabric控制台，选择进入工作空间。

步骤2 左侧选择“资源与资产 > SQL端点”。



步骤3 单击端点卡片，在端点详情页选中“SQL作业历史”。

state	sql	start_time	end_time	status
20250521-18:30:12	hmap performance select * from ...	20250521 18:30:12	20250521 18:30:12	成功
20250521-18:30:12	hmap performance select * from ...	20250521 18:30:12	20250521 18:30:12	成功
20250521-18:30:12	hmap performance select * from ...	20250521 18:30:12	20250521 18:30:12	成功
20250521-18:30:12	hmap performance select * from ...	20250521 18:30:12	20250521 18:30:12	成功
20250521-18:30:12	hmap performance select * from ...	20250521 18:30:12	20250521 18:30:12	成功
20250521-18:30:12	hmap performance select * from ...	20250521 18:30:12	20250521 18:30:12	成功
20250521-18:30:12	hmap performance select * from ...	20250521 18:30:12	20250521 18:30:12	成功
20250521-18:30:12	hmap performance select * from ...	20250521 18:30:12	20250521 18:30:12	成功
20250521-18:30:12	hmap performance select * from ...	20250521 18:30:12	20250521 18:30:12	成功
20250521-18:30:12	hmap performance select * from ...	20250521 18:30:12	20250521 18:30:12	成功

----结束

3.3 使用 SQL 编辑器

支持通过SQL编辑器连接DataArtsFabric SQL进行SQL操作。

步骤1 登录华为云DataArtsFabric控制台，选择进入工作空间

步骤2 左侧选择“开发与生产 > SQL编辑器”，选择LakeFormation实例、LakeFormation Catalog、SQL端点后，即可运行SQL。也可以开启“会话模式”，保留执行会话，在需要频繁间歇运行SQL的场景下，可以节省创建会话的时间。

图 3-1 运行 SQL




图 3-2 开启“会话模式”






图 3-5 打开驱动管理器



步骤3 在“驱动管理器”对话框，单击“新建”打开创建新驱动窗口。

图 3-6 驱动管理器



步骤4 切换至“库”标签页。选择“添加工件”，将步骤1中获取的Maven坐标复制到依赖声明中并单击“确定”，添加单击“找到类”，在自动弹出的界面中单击“下载”，之后选择自动弹出的“org.postgresql.Driver”，最后单击“确定”即可。

图 3-7 添加 Maven 依赖




图 3-8 下载 Maven 依赖





图 3-9 设置驱动类




步骤5 切换至“设置”标签页，输入以下参数，其中“驱动名称”可以任意选取，“驱动类型”选择Generic，类名在导入驱动的jar包之后会自动加载。

URL模板：

```
jdbc:fabricsql://{host}[:{port}]/[{database}]
```

单击“确定”，添加DataArtsFabric SQL的驱动。

图 3-10 设置 DataArtsFabric SQL 驱动




步骤6 创建完成后，单击“新建连接”，选择上一步添加的驱动，单击“下一步”。

图 3-11 新建连接




图 3-12 选择数据库



步骤7 在“主要”页签，填入主机、数据库名称（用户名及密码无需填写）。之后切换到“驱动属性”页签，填入表1所示必要参数。单击“完成”。

图 3-13 “主要”页签



步骤8 设置连接属性。切换到“驱动属性”页签





表 3-2 DataArtsFabric SQL 连接参数

属性名称	说明	是否必填	获取方式
AccessKeyID	认证凭证ID	必填	创建永久访问密钥或获取用户的临时访问密钥和securitytoken
SecretAccessKey	认证密钥	必填	
securityToken	STSToken	可选（临时AK/SK需要）	
workspaceId	工作空间ID	必填	DataArtsFabric工作空间管理平台>查看详情
endpointId	端点ID	必填	查询SQL端点详情
lakeformation_instance_id	Lakeformation实例ID	必填	规划并创建Lakeformation实例、Catalog、数据库中创建的Lakeformation信息
PGDBNAME	Lakeformation Catalog名称	必填	

步骤9 通过以上步骤将数据库连接添加完成后，单击下拉箭头，即可展示数据库中的Schema列表。

图 3-15 JDBC 方式连接 DataArtsFabric SQL



步骤4 在“URL”中输入JDBC的URL，“方言”选择PostgreSQL。

JDBC URL模板：

```
jdbc:fabricsql://<host>[:<port>]/<database>
```

例如：

```
jdbc:fabricsql://example.com:1234/database
```

参数名	含义
host	DataArtsFabric SQL地址。
port	端口号（可选）。
database	数据库名称（必填），可任意填写。

另外需配置“属性文件”用于认证鉴权。单击“浏览”，选择编写好的属性文件。属性文件拓展名为.properties，此处命名为serverless.properties，完成后，单击“登录”。

属性文件示例如下：

```
AccessKeyID=YOUR_AK
SecretAccessKey=YOUR_AK
securityToken=YOUR_STOKEN
workspaceId=YOUR_WORKSPACE
endpointId=YOUR_ENDPIONT_ID
```

```
lakeformation_instance_id=YOUR_LF_ID
PGDBNAME=YOUR_CATALOG
```

 **说明**

用户名、密码无需填写。

图 3-16 配置连接信息

其他数据库(JDBC)

1

JURL:

jdbc:fabricsql://

2

方言:

PostgreSQL

输入服务器登录信息:

用户名(U):

密码(P):

属性文件:

3

serverless.properties

浏览...

登录

属性名称	备注	是否必填	获取方式
AccessKeyId	认证凭证ID	必填	创建永久访问密钥或获取用户的临时访问密钥和securitytoken
SecretAccessKey	认证密钥	必填	
securityToken	STSToken	可选（临时AK/SK需要）	
workspaceId	工作空间ID	必填	DataArtsFabric工作空间管理平台>查看详情
endpointId	端点ID	必填	查询SQL端点详情
lakeformation_instance_id	Lakeformation实例ID	必填	规划并创建Lakeformation实例、Catalog、数据库中创建的Lakeformation信息
PGDBNAME	Lakeformation Catalog名称	必填	

----结束

3.4.3 获取 JDBC

JDBC驱动程序用于连接DataArtsFabric SQL，用户可以通过以下方式获取JDBC。

通过 Maven 仓库获取

复制Maven库信息，并将其添加到pom.xml文件中。

在pom.xml文件中添加如下Maven坐标：

```
<dependency>
  <groupId>com.huaweicloud.dws</groupId>
  <artifactId>huaweicloud-dws-jdbc</artifactId>
  <version>8.5.1</version>
</dependency>
```

4 大模型推理场景

4.1 大模型推理场景介绍

常见的大模型包括大语言模型、多模态大模型、文生图大模型等，其中大语言模型支持文本生成，可以根据用户输入的提示词（prompt）进行推理，可广泛应用于以下领域：

- 问答系统：大语言模型可以处理自然语言，理解用户的意图，回答用户提出的问题。
- 内容生产：大语言模型可以基于给定的文本或主题生成连贯的文章、故事、对话等。
- 文本摘要：大语言模型可以对长文本进行摘要，提取关键信息，方便用户快速了解文本内容。
- 机器翻译：大语言模型可以处理多种语言之间的翻译任务，实现跨语言交流。

当前DataArtsFabric提供以下两种方式进行推理：

- **用公共推理服务进行推理**：DataArtsFabric提供基于开源大语言模型（Qwen2、GLM4等）的公共推理服务，用户可以在推理端点查看公共端点，选择自己想用的端点进行开通，然后就可以在试验场使用公共推理服务。该方式无需部署，开通后即可使用常见的开源大模型进行推理。
- **创建我的推理服务进行推理**：DataArtsFabric支持用户创建自己专属的推理服务进行部署，用户可以上传自己的大语言模型，也可以使用公共的大语言模型进行部署。在DataArtsFabric模型页面创建的模型是仅自己可见，其他用户不可见。用户可以查看和删除模型，也可以对模型版本进行管理，包括新增、查看和删除模型版本。

4.2 大模型推理使用流程

DataArtsFabric平台提供了一个Serverless化的从数据到模型部署的AI全流程开发体验，针对每个环节，其使用是相对独立自由的。本章节梳理了DataArtsFabric使用流程详解，您可以选择其中一种方式完成AI开发。

表 4-1 使用流程说明

流程	说明	详细指导
创建工作空间	创建一个工作空间，后续所有的能力都承载在工作空间中。	创建工作空间
创建端点	创建一个端点，根据业务类型不同，创建不同类型的端点。	创建推理端点
注册模型	用户可以将存储在OBS的微调模型文件，在模型管理的界面注册为自己的微调模型。	创建模型
部署服务	DataArtsFabric支持部署用户基于基模型微调的微调模型	创建推理服务
访问服务	微调模型部署完成后，用户可以使用DataArtsFabric提供的推理接口直接进行推理。	使用推理服务进行推理

4.3 用公共推理服务进行推理

4.3.1 查看公共推理服务

推理端点试用期内，可以直接使用公共推理服务进行推理。目前的公共推理服务是基于开源大模型部署的，列表如下（实际的推理服务以服务为准）：

表 4-2 公共推理服务

名称	描述	免费额度	最大上下文长度	prompt模板长度	最大输出token
QWEN_2_72B	Qwen2在包括语言理解、生成、多语言能力、编码、数学和推理在内的多个基准测试中，超越了大多数以前的开放权重模型，与专有模型表现出竞争力。该模型参数规模为720亿。	公测期间提供100万token免费配额，超过配额不可用，也没办法再购买；有效期为服务开通90天内，超过时间则失效。	16k	23	16360

4.3.2 开通推理服务

对于公共推理服务，用户需要先申请开通，开通后才可以使用。开通公共推理服务之后用户会获得一定的免费配额，并在一定的时间内有效，超过将无法使用。如果用户想继续使用，建议部署推理服务使用。

前提条件

- 已有可正常使用的华为云账号。
- 已有至少一个正常可用的工作空间。

操作步骤

- 步骤1** 登录[DataArtsFabric工作空间管理台](#)。
- 步骤2** 选择已创建的工作空间，单击“进入工作空间”，选择“推理端点 > 公共端点”，进入“公共推理端点”页面。
- 步骤3** 试用期内的公共推理端点，会有运行中标志。公共端点页面可查看已经开通的公共推理端点。

图 4-1 查看开通的推理端点



----结束

4.3.3 在试验场进行推理

DataArtsFabric提供了试验场，方便用户在页面上选择推理服务进行推理。试验场支持流式推理，支持用户配置max_tokens等不同的推理参数，还支持不同的推理服务对比。

约束与限制

使用公共推理服务时的通用约束限制如下：

- **Token配额约束：**每种公共推理服务都有免费配额限制，超过配额不可用，也无法再购买。每种公共推理服务的配额为当前用户在当前局点下所有工作空间共享；
- **时间约束：**有效期为服务开通90天内，超过时间则失效。同一个推理服务在不同工作空间下面开通，以首次开通为准。
- **不同的模型有不同的上下文长度约束，**请见表[公共推理服务](#)。

- 不保证SLA，如果想要更高的性能，建议创建自己的推理服务进行推理；

前提条件

- 已有可正常使用的华为云账号。
- 已有至少一个正常可用的工作空间。
- 已开通公共推理服务，开通流程请参见[开通推理服务](#)。

操作步骤

步骤1 登录[DataArtsFabric工作空间管理台](#)。

步骤2 选择已创建的工作空间，单击“进入工作空间”。


步骤3 在左侧菜单栏中选择“推理服务> 公共推理服务”，进入“公共推理服务”页面。

图 4-2 查看公共推理服务



步骤4 单击“测试场”，进入“测试场”页面，进行推理操作。

图 4-3 试验场推理界面



步骤5 调节推理参数（可选）。

如果想调节推理的一些参数，可以单击高级配置来调节推理的max_tokens等参数。参数列表如下。

表 4-3 推理参数说明

名称	说明
max_tokens	要在聊天完成中生成的最大token数。不同公共推理服务支持的最大max_tokens不一样，具体参考公共推理服务介绍。
temperature	Temperature是用于调整随机程度的数字。介于0和2之间。较高的值（如0.8）将使输出更随机，而较低的值（如0.2）将使输出更集中和确定性。
top_p	核心采样，用于控制AI模型根据累积概率考虑的标记范围。
frequency_penalty	数字介于-2.0和2.0之间。频率惩罚，控制文本中词汇的重复度，避免生成文本中某些词汇或短语出现过于频繁。正值会根据它们在文本中的现有频率惩罚新令牌，从而降低模型逐字重复同一行的可能性。
presence_penalty	数字介于-2.0和2.0之间。存在惩罚，控制文本中话题的重复度，避免在对话或文本中反复讨论相同的主题或观点。正值会根据到目前为止它们是否出现在文本中来惩罚新令牌，从而增加模型谈论新主题的可能性。

图 4-4 配置推理参数



步骤6 对比多个推理服务（可选）。

如果您想对比多个推理服务，DataArtsFabric也提供了推理服务的对比功能。您可以单击右上角的“新增对比”按钮进行新增，最多支持3个推理服务进行对比。

图 4-5 推理服务对比



----结束

4.4 创建我的推理服务进行推理

4.4.1 创建模型

在DataArtsFabric部署推理服务的时候除了使用公共模型，用户也可以自己创建模型。用户可以在DataArtsFabric模型页面创建模型，这些模型是属于用户个人，其他用户不可见。

约束与限制

创建模型的通用约束如下：

- 需要是DataArtsFabric支持的基模型，否则不支持，基模型列表如下：

表 4-4 基模型列表

基模型类型	描述
QWEN_2_72B	Qwen2在包括语言理解、生成、多语言能力、编码、数学和推理在内的多个基准测试中，超越了大多数以前的开放权重模型，与专有模型表现出竞争力，参数规模为720亿。
GLM_4_9B	GLM-4-9B是智谱AI推出的最新一代预训练模型GLM-4系列中的开源版本。在语义、数学、推理、代码和知识等多方面的数据集测评中表现出较高的性能，参数规模为90亿。
LLAMA_3_8B	作为Llama系列的第三代模型，Llama3在多个基准测试中实现了全面领先，性能较为优异。该模型参数规模为80亿。该模型使用了大规模的中文数据进行预训练，扩大了中文字符集的覆盖范围。
LLAMA_3_70B	作为Llama系列的第三代模型，Llama3在多个基准测试中实现了全面领先，性能较为优异。该模型参数规模为700亿。
LLAMA_3.1_8B	Llama3.1是首个公开可用的模型，在常识、可操纵性、数学、工具使用和多语言翻译等方面有不错的表现。它支持高级用例，例如长篇文本摘要、多语言对话智能体和编码助手。该模型使用了大规模的中文数据进行预训练，扩大了中文字符集的覆盖范围。该模型参数规模为80亿。
LLAMA_3.1_70B	Llama3.1是首个公开可用的模型，在常识、可操纵性、数学、工具使用和多语言翻译等方面已接近顶级AI模型。它支持高级用例，例如长篇文本摘要、多语言对话智能体和编码助手。该模型参数规模为700亿。

- 模型格式需要为safetensors的格式。safetensors是Huggingface推出的一种可靠、易移植的机器学习模型存储格式，用于安全地存储Tensor，而且速度快。样例如下：

图 4-6 模型文件样例

对象名称	存储类别	大小	最后修改时间	操作
.gitattributes	标准存储	1.48 KB	2024/09/14 10:07:35 GMT...	下载 删除 ...
.gitattributes.metadata	标准存储	104 bytes	2024/09/14 10:07:36 GMT...	下载 删除 ...
.gitignore	标准存储	1 byte	2024/09/14 10:07:36 GMT...	下载 删除 ...
LICENSE	标准存储	6.73 KB	2024/09/14 10:07:36 GMT...	下载 删除 ...
LICENSE.metadata	标准存储	104 bytes	2024/09/14 10:07:37 GMT...	下载 删除 ...
README.md	标准存储	6.40 KB	2024/09/14 10:07:37 GMT...	下载 删除 ...
README.md.metadata	标准存储	104 bytes	2024/09/14 10:07:37 GMT...	下载 删除 ...
config.json	标准存储	663 bytes	2024/09/14 10:07:37 GMT...	下载 删除 ...
config.json.metadata	标准存储	103 bytes	2024/09/14 10:07:37 GMT...	下载 删除 ...
generation_config.json	标准存储	242 bytes	2024/09/14 10:07:38 GMT...	下载 删除 ...
generation_config.json.metadata	标准存储	103 bytes	2024/09/14 10:07:38 GMT...	下载 删除 ...
merges.txt	标准存储	1.59 MB	2024/09/14 10:07:38 GMT...	下载 删除 ...

格式要求可以参考模型样例，地址如下：

基模型类型	模样例名称	模型来源
LLAMA_3_8B	Llama 3 8B Chinese Instruct	https://www.modelscope.cn/models/FlagAlpha/Llama3-Chinese-8B-Instruct
LLAMA_3_70B	Llama 3 70B	https://huggingface.co/meta-llama/Meta-Llama-3-70B-Instruct
LLAMA_3.1_8B	Llama 3.1 8B Chinese Chat	https://modelscope.cn/models/XD_AI/Llama3.1-8B-Chinese-Chat
LLAMA_3.1_70B	Llama 3.1 70B	https://huggingface.co/meta-llama/Llama-3.1-70B-Instruct
QWEN_2_72B	Qwen 2 72B Instruct	https://huggingface.co/Qwen/Qwen2-72B
GLM_4_9B	Glm 4 9B Chat	https://huggingface.co/THUDM/glm-4-9b-chat


前提条件

- 已有可正常使用的华为云账号。
- 已有至少一个正常可用的工作空间。
- 已创建用于存储模型的OBS桶及文件夹，上传好符合要求的模型文件，并且模型存储的OBS桶与DataArtsFabric在同一区域。具体请参见[创建OBS桶](#)。

操作步骤


- 步骤1** 登录[DataArtsFabric工作空间管理台](#)。
- 步骤2** 选择已创建的工作空间，单击“进入工作空间”。
- 步骤3** 在左侧菜单栏中选择“资源与资产 > 模型”，进入“模型”管理页面。

图 4-7 进入模型管理页面



- 步骤4** 单击“创建模型”，进入“创建模型”页面。

图 4-8 进入创建模型页面



步骤5 填写模型基本信息，包括名称、描述等，并选择模型文件的OBS路径，然后单击“立即创建”，详细描述请见：

表 4-5 创建模型的基本信息

参数名称	说明
模型名称	必填，模型的名称。 长度为1-64，不支持重复名称。 只能包含中文、字母、数字、下划线、中划线、点、空格。
模型描述	可选，模型的描述信息。 长度为0-1024。不支持^!<>=&""等特殊字符。
版本名称	必填，版本的名称。 长度为1-64，不支持重复名称。 只能包含中文、字母、数字、下划线、中划线、点、空格。
版本描述	可选，版本的描述信息。 长度为0-1024。不支持^!<>=&""等特殊字符
基模型类型	必选，基模型的类型，描述具体请见 基模型列表 。
模型文件路径	必填，模型文件路径。目前支持OBS路径，该路径需要当前用户有读取的权限。

图 4-9 创建我的模型





图 4-10 选择模型的 OBS 路径



步骤6 再次单击“我的模型”，即可在模型列表中看见刚创建的模型。

图 4-11 在模型列表中查看创建的模型



----结束

4.4.2 管理模型

在DataArtsFabric创建模型后，用户可以查看和删除模型，也可以对模型版本进行管理，包括新增、查看和删除模型版本。


前提条件

- 已有可正常使用的华为云账号。
- 已有至少一个正常可用的工作空间。
- 已创建用于存储模型的OBS桶及文件夹，上传好符合要求的模型文件，并且模型存储的OBS桶与DataArtsFabric在同一区域。具体请参见[创建OBS桶](#)。

操作步骤

- 步骤1** 登录[DataArtsFabric工作空间管理台](#)。
- 步骤2** 选择已创建的工作空间，单击“进入工作空间”。
- 步骤3** 在左侧菜单栏中选择“资源与资产> 模型”，进入“模型”管理页面。

图 4-12 进入模型管理页面



- 步骤4** 查看当前模型下面的版本列表；您可以使用该版本，即设置为当前版本。

图 4-13 模型版本列表入口





图 4-14 查看模型版本列表



步骤5 （可选）新增模型版本。

如果您的模型有迭代更新，可以选择新增模型版本。

在我的模型页面，单击操作列“新增模型版本”，填写基本信息后，单击“新增版本”即可完成新增。

模型版本新增后不支持修改。新增模型的基本信息如下：

表 4-6 创建模型版本的基本信息

参数名称	说明
版本名称	必填，版本的名称。 长度为1-64，不支持重复名称。 只能包含中文、字母、数字、下划线、中划线、点、空格。
版本描述	可选，版本的描述信息。 长度为0-1024。不支持^!<>=&""等特殊字符。
模型文件路径	必填，模型文件路径。目前支持OBS路径，该路径需要当前用户有读取的权限。

图 4-15 新增模型版本入口





图 4-16 新增模型版本



步骤6 （可选）删除模型版本。

您也可以删除不想要的模型版本。

单击页面操作列的“删除”按钮，再次确认后进行删除。

图 4-17 删除模型入口




图 4-18 删除模型



----结束

4.4.3 创建推理端点

用户在创建推理服务之前，需要先创建推理端点。创建推理端点的时候可以配置最大资源数，然后在推理端点之上创建推理服务，推理端点上的所有推理服务的总资源数不能超过推理端点的最大资源数，方便用户控制推理端点的资源使用量；

前提条件

- 已有可正常使用的华为云账号。
- 已有至少一个正常可用的工作空间。

操作步骤

- 步骤1 登录DataArtsFabric工作空间管理台。
- 步骤2 选择已创建的工作空间，单击“进入工作空间”，选择“资源与资产->推理端点”。
- 步骤3 单击右上角的“创建推理端点”。参照创建推理端点的基本信息填写端点的名称、描述、资源规格和数量等基本信息，单击“创建”。

图 4-19 进入推理端点创建页面




表 4-7 创建推理端点的基本信息

参数名称	说明
名称	必填，推理端点名称。 长度为1-64，不支持重复名称。 只能包含中文、字母、数字、下划线、中划线、点、空格。
描述	可选，推理服务的描述信息。 长度为0-1024。不支持^!<>=&"等特殊字符。
算力单元类型	使用算力单元类型来过滤具体资源规格。
资源规格	必填，资源规格，不同的资源规格支持不同的模型。
预热资源数	目前只支持0，推理端点的预热资源数。
最大资源数	必填，推理端点的最大资源数。最大值不能小于1，最大为1000。同时最大资源数不能小于预热资源数。

图 4-20 创建推理端点

推理端点 / 创建推理端点

< | 创建推理端点

基础设置

端点名称

请输入

描述（可选）

请输入

0/1,000

资源配置（模型单元）

算力单元类型

标准型 增强型

资源规格 ?

请选择

基础算力单元数

0

预热资源数 ?


- 0 +

最大资源数

- 1 +

步骤4 返回“资源与资产 > 推理端点”页面，选择“我的端点”即可查看已创建的端点。

图 4-21 推理端点



----结束

4.4.4 创建推理服务

在DataArtsFabric进行推理的时候，除了选择已有的公共推理服务进行推理，用户也可以部署自己的推理服务进行推理。

在DataArtsFabric部署推理服务的时候需要先有模型，您可以使用前面自己创建的模型，为了方便您操作，DataArtsFabric也默认提供了一些开源的公共模型，相关列表如下：

表 4-8 公共模型

模型名称	简介	基模型类型	算力要求 (MU)	最大上下文长度	prompt模板长度	最大输出 token
Qwen 2 72B Instruct	Qwen2在包括语言理解、生成、多语言能力、编码、数学和推理在内的多个基准测试中，超越了大多数以前的开放权重模型，与专有模型表现出竞争力。该模型参数规模为720亿。	QWEN_2_72B	8	16k	23	16360
Glm 4 9B Chat	GLM-4-9B是智谱AI推出的最新一代预训练模型GLM-4系列中的开源版本。在语义、数学、推理、代码和知识等多方面的数据集测评中表现出较高的性能。该模型参数规模为90亿。	GLM_4_9B	2	32k	16	32751

Prompt模板长度为系统prompt，不管用户输入什么，系统都会将prompt模板加入到输入中。最大上下文长度包括prompt模板长度、用户最大输入token长度和最大输出token之和。

用户可以在模型导航栏下查看公共模型信息，可以使用公共模型部署推理服务，但是不允许删除公共模型。

约束与限制

部署推理服务时的通用约束限制如下：

- 推理服务资源规格最小值为1，最大值为100。
- 部署推理服务的时候选择的推理端点下的推理服务资源最大值不能超过推理端点的最大资源数。

前提条件

- 已有可正常使用的华为云账号。
- 已有至少一个正常可用的工作空间。具体操作，请参见[创建工作空间](#)。
- 已创建推理端点。具体操作，请参见[创建推理端点](#)。
- 已创建用于推理的模型。具体操作，请参见[创建模型](#)。

操作步骤

- 步骤1** 登录[DataArtsFabric工作空间管理台](#)。
- 步骤2** 选择已创建的工作空间，单击“进入工作空间”，在左侧菜单栏中选择“开发与生产->推理服务”
- 步骤3** 在“推理服务”页面的“我的推理服务”页签右上角，单击“创建推理服务”，进入创建页面。
- 步骤4** 填写创建推理服务的名称、描述等基本信息，并选择推理端点和模型。模型可以选择公共模型或者我的模型。然后配置资源最小值和最大值。详细描述请见下表。

表 4-9 创建推理服务参数说明

参数		是否必选	说明
基础配置	推理服务名称	是	推理服务名称。 长度为1-64，不支持重复名称。只能包含中文、字母、数字、下划线、中划线、半角句号（.）、空格。
	描述	否	推理服务的描述信息。 长度为0-1024，不支持^!<>=&""等特殊字符。
	模型类型	是	支持选择“我的模型”或“公共模型”。
	模型	是	“模型类型”选择“我的模型”时，在下拉框选择用户已创建的模型。关于如何创建模型，请参见创建模型。 “模型类型”选择“公共模型”时，在下拉框选择公共推理服务。
	模型版本	是	“模型类型”选择“我的模型”时，在下拉框选择用户已创建模型的版本。

参数		是否必选	说明
	推理端点	是	在下拉框选择用户创建的推理端点。关于如何创建推理端点，请参见 创建推理端点 。
实例运行配置	资源规格	是	资源规格，需要与推理端点的规格保持一致，否则不支持。
	最小值	是	推理服务的最小实例数，即使没有请求，也会创建最小的实例数。最小值不能小于1，最大为100。推理服务会根据不同的请求负载，在最小实例数和最大实例数之间进行自动扩缩。
	最大值	是	推理服务的最大实例数。最大值不能小于1，最大值为100。同时最大值不能小于最小值，并且最大值应该小于等于所选推理端点的最大资源数。同一推理端点下的所有推理服务的最大资源数之和应该小于等于所选推理端点的最大资源数。推理服务会根据不同的请求负载，在最小实例数和最大实例数之间进行自动扩缩。请求增加后，推理服务的实例数量不会超过最大值。

图 4-22 创建推理服务-公共模型





图 4-23 创建推理服务-我的模型



- 步骤5** 填写完成后，单击“立即创建”即可。
- 步骤6** 在“推理服务”s"页面，可查看已创建的推理服务。
- 结束

4.4.5 使用推理服务进行推理

部署完推理服务之后，用户可以在试验场选择已有的推理服务进行推理，也可以调用API进行推理，具体请参考API文档（API链接到API参考）。下面是使用试验场进行推理的步骤：


前提条件

- 已有可正常使用的华为云账号。
- 已有至少一个正常可用的工作空间。
- 已创建推理服务。

操作步骤

- 步骤1** 登录[DataArtsFabric工作空间管理台](#)。
- 步骤2** 选择已创建的工作空间，单击“进入工作空间”，在左侧导航栏选择“开发与生产 > 试验场”。
- 步骤3** 单击“试验场”"，进入“试验场”"页面，进行推理。

图 4-24 选择公共推理服务进行推理




步骤4 （可选）参数调节。

如果需要调节推理的一些参数，可以单击高级配置来调节推理的max_tokens等参数。参数说明如下：

表 4-10 推理参数说明

名称	说明
max_tokens	要在聊天完成中生成的最大token数。不同公共推理服务支持的最大max_tokens不一样，具体参考公共推理服务介绍。
temperature	Temperature是用于调整随机程度的数字。介于0和2之间。较高的值（如0.8）将使输出更随机，而较低的值（如0.2）将使输出更集中和确定性。
top_p	核心采样，用于控制AI模型根据累积概率考虑的标记范围。
frequency_penalty	数字介于-2.0和2.0之间。频率惩罚，控制文本中词汇的重复度，避免生成文本中某些词汇或短语出现过于频繁。正值会根据它们在文本中的现有频率惩罚新令牌，从而降低模型逐字重复同一行的可能性。
presence_penalty	数字介于-2.0和2.0之间。存在惩罚，控制文本中话题的重复度，避免在对话或文本中反复讨论相同的主题或观点。正值会根据到目前为止它们是否出现在文本中来惩罚新令牌，从而增加模型谈论新主题的可能性。


图 4-25 配置推理参数



步骤5 （可选）多个推理对比。

如果需要对比多个推理服务时，可以单击右上角的“新增对比”按钮进行新增，最多支持3个推理服务进行对比。

图 4-26 对比



----结束

4.4.6 删除推理服务

当您不想使用推理服务的时候，您可以删除自己创建的推理服务。


前提条件

- 已有可正常使用的华为云账号。
- 已有至少一个正常可用的工作空间。
- 已创建推理服务。

操作步骤


- 步骤1** 登录[DataArtsFabric工作空间管理台](#)。
- 步骤2** 选择已创建的工作空间，单击“进入工作空间”，选择“开发与生产 > 推理服务”。
- 步骤3** 选择想要删除的推理服务，单击其操作栏的“删除”按钮进行删除。

图 4-27 触发推理服务删除



- 步骤4** 在弹出的二次确认界面确认后，输入“DELETE”后单击“确认”，即可完成删除。

图 4-28 确认删除推理服务



----结束

4.4.7 删除推理端点

前提条件

- 已有可正常使用的华为云账号。
- 已有至少一个正常可用的工作空间。
- 已创建推理端点。

操作步骤

- 步骤1** 登录[DataArtsFabric工作空间管理台](#)。
- 步骤2** 选择已创建的工作空间，单击“进入工作空间”，选择“资源与资产->推理端点”。
- 步骤3** 单击想要删除的推理端点右上角的垃圾桶标记，确认后删除推理端点。

图 4-29 推理端点



----结束

4.5 通过 AOM 查看全量指标


为使用户更好地掌握推理实例资源的使用情况，云服务平台将指标上报到了应用运维管理AOM，用户可以通过应用运维管理AOM查询资源使用情况。

前提条件

- 已有可正常使用的华为云账号。
- 已有至少一个正常可用的工作空间。
- 已有至少一个推理实例。

操作步骤

- 步骤1** 登录应用运维管理平台。
- 步骤2** 选择指标预览，指标源选择Prometheus_AOM_Default。



步骤3 全量指标中输入指标名称进行查询。

表 4-11 监控指标

指标名称	描述
mu_usage	该指标用于展示当前推理实例的实际MU使用量 单位：个数。

----结束

5 运维管理

5.1 设置消息通知

消息通知功能用于通知用户其作业的执行情况。

前提条件

- 已有可正常使用的华为云账号。
- 已有至少一个正常可用的工作空间。
- 需要配置FABRIC_SMN_POLICY委托，具体操作参考[配置DataArtsFabric云服务委托权限](#)。

操作步骤

步骤1 登录[DataArtsFabric工作空间管理台](#)。

步骤2 选择已创建的工作空间，单击“进入工作空间”，选择“运维管理->消息通知”。

步骤3 单击右上角的创建通知，参照[创建通知参数说明](#)设置参数，后单击“立即创建”。

图 5-1 创建通知

< | 创建通知

消息通知

消息通知

已开启消息通知服务

消息通知主题

请选择smn消息主题

创建SMN主题

通知事件

请选择通知事件

消息类型

请选择消息类型

消息来源匹配样式

正则表达式

请输入匹配消息来源名称的正则表达式，可输入多个，以逗号分隔。
例：spark-job.*,python-job.*machine-learning-01.*

表 5-1 创建通知参数说明

参数	是否必选	说明
消息通知主题	是	在SMN中创建的主题，最终的消息会发送到对应的主题中。
通知事件	是	何时进行消息通知，分为： - 成功时通知 - 失败时通知 可以全选
消息类型	是	当前只支持选择作业，会对作业执行结果进行通知。

参数	是否必选	说明
消息来源匹配样式	是	需要匹配的消息来源，支持正则表达式 作业场景：作业名称的正则匹配。 例如：存在作业名称为test-job的作业，则可以填写test-j.*，test-job等方式进行匹配。

步骤4 创建成功后，可以在消息通知列表中看到已经创建的消息通知，单击消息来源后的数字可以看到当前配置的消息来源。

说明

相同的主题，通知事件、通知类型不同的消息来源会合并到一条记录中。

----结束

5.2 删除消息通知

消息通知功能用于通知用户其作业的执行情况。当不需要时，可以通过删除操作删除通知。

前提条件

- 已有可正常使用的华为云账号。
- 已有至少一个正常可用的工作空间。
- 需要配置FABRIC_SMN_POLICY委托，具体操作参考[配置DataArtsFabric云服务委托权限](#)。
- 已有至少一个消息通知。

操作步骤

步骤1 登录[DataArtsFabric工作空间管理台](#)。

步骤2 选择已创建的工作空间，单击“进入工作空间”，选择“运维管理->消息通知”。

步骤3 单击消息来源后的数字，在弹框中选择需要删除的消息类型，单击“删除”，确认后即可删除通知。

图 5-2 删除通知

消息类型	消息来源匹配样式	操作
job	asdfasdf	删除

----结束