



数据湖工厂

## 产品简介

文档版本 01

发布日期 2020-12-08

华为技术有限公司



**版权所有 © 华为技术有限公司 2022。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。

---

## 目录

---


1 产品概述.....	1
2 产品优势.....	2
3 应用场景.....	3
4 产品功能.....	5
5 权限管理.....	7
6 与其他服务的关系.....	14
7 约束限制.....	16
8 区域和可用区.....	17
9 配额说明.....	19

# 1 产品概述

数据湖工厂服务（Data Lake Factory，简称数据开发模块）是华为云大数据重要的平台产品，它可管理多种大数据服务，提供一站式的大数据开发环境、全托管的大数据调度能力，极大降低用户使用大数据的门槛，帮助用户快速构建大数据处理中心。

使用数据开发模块，用户可进行数据管理、数据集成、脚本开发、作业开发、作业调度、运维监控等操作，轻松完成整个数据的处理分析流程。

图 1-1 DLF 流程



数据管理、数据集成、脚本开发、作业开发、作业调度、运维监控的详细说明请参见[产品功能](#)。

# 2 产品优势

---

## 一站式云上数仓建设

支持一站式建设云上数仓，完成数据集成、脚本开发、作业开发、作业调度、运维监控、数据管理等操作，无须切换多个工具。

## 数据湖开发

支持管理DWS、DLI等多种大数据服务，在同一作业中可实现数据在不同类型数据服务中的编排与调度，实现真正的数据湖开发。

## 丰富的数据开发类型

支持多人在线协作开发，脚本开发可支持SQL、Shell在线编辑、实时查询；作业开发可支持CDM、SQL、MR、Shell、MLS、Spark等多种数据处理节点。

## 强大的作业调度能力


提供丰富的调度配置策略与海量的作业调度能力；支持时间周期调度、事件驱动调度、手工调度等多种调度方式。

# 3 应用场景

## 云上数仓快速搭建

通过数据开发模块将线下数据迁移到华为云上，将数据集成到华为云大数据服务中，并在数据开发模块中进行数据开发。


图 3-1 场景示例图



## 数据分析业务流自动化

通过数据开发模块实现数据导入、清洗、机器学习、数据回传、报表生成端到端流程自动化，把业务搬上自动化流水线。


图 3-2 场景示例图



## 海量日志轻松分析挖掘

通过 DIS 将日志数据接入到 OBS 存储（或者 Cloud Search 服务），然后通过数据开发模块服务编写数据开发脚本和数据挖掘脚本，实现海量日志分析和挖掘。

图 3-3 场景示例图



# 4 产品功能

## 数据管理

- 支持管理DWS、DLI、MRS Hive等多种数据仓库。
- 支持可视化和DDL方式管理数据库表。

## 数据集成

与云数据迁移服务（CDM）无缝集成，依托CDM的强力支撑，支持20多种异构数据源之间可靠高效的数据传输，轻松实现多数据源集成到数据仓库。

## 脚本开发

- 提供在线脚本编辑器，支持多人协作进行SQL、Shell脚本在线代码开发和调测。
- 支持使用变量和函数。

## 作业开发

- 提供图形化设计器，支持拖拉拽方式快速构建数据处理 workflow。
- 预设数据集成、SQL、MR、Spark、Shell、机器学习等多种任务类型，通过任务间依赖完成复杂数据分析处理。
- 支持导入和导出作业。

## 资源管理

支持统一管理在脚本开发和作业开发使用到的file、jar、archive类型的资源。

## 作业调度

支持单次调度、周期调度和事件驱动调度，周期调度支持分钟、小时、天、周、月多种调度周期。

## 运维监控

- 支持对作业进行运行、暂停、恢复、终止等多种操作。
- 支持查看作业和其内各任务节点的运行详情。

- 支持配置多种方式报警，作业和任务发生错误时可及时通知相关人，保证业务正常运行。

# 5 权限管理

如果您需要对华为云上购买的数据湖工厂服务（Data Lake Factory）资源，给企业中的员工设置不同的访问权限，以达到不同员工之间的权限隔离，您可以使用统一身份认证服务（Identity and Access Management，简称IAM）进行精细的权限管理。该服务提供用户身份认证、权限分配、访问控制等功能，可以帮助您安全的控制华为云资源的访问。

通过IAM，您可以在华为云账号中给员工创建IAM用户，并使用策略来控制他们对华为云资源的访问范围。例如您的员工中有负责软件开发的人员，您希望他们拥有数据湖工厂服务（Data Lake Factory）的使用权限，但是不希望他们拥有删除数据湖工厂服务等高危操作的权限，那么您可以使用IAM为开发人员创建用户，通过授予仅能使用数据湖工厂服务，但是不允许删除数据湖工厂服务的权限策略，控制他们对数据湖工厂服务资源的使用范围。

如果华为云账号已经能满足您的要求，不需要创建独立的IAM用户进行权限管理，您可以跳过本章节，不影响您使用数据湖工厂服务的其它功能。

IAM是华为云提供权限管理的基础服务，无需付费即可使用，您只需要为您账号中的资源进行付费。关于IAM的详细介绍，请参见《[IAM产品介绍](#)》。

## DLF 权限

默认情况下，新建的IAM用户没有任何权限，您需要将其加入用户组，并给用户组授予策略或角色，才能使得用户组中的用户获得对应的权限，这一过程称为授权。授权后，用户就可以基于被授予的权限对云服务进行操作。

DLF部署时通过物理区域划分，为项目级服务，需要在各区域（如华北-北京1）对应的项目（cn-north-1）中设置相关权限，并且该权限仅对此项目生效，如果需要所有区域都生效，则需要所有项目都设置权限。访问DLF时，需要先切换至授权区域。

如[表5-1](#)所示，包括了DLF的所有系统策略权限。

权限根据授权精细程度分为角色和策略。

- 角色：IAM最初提供的一种根据用户的工作职能定义权限的粗粒度授权机制。该机制以服务为粒度，提供有限的服务相关角色用于授权。由于华为云各服务之间存在业务依赖关系，因此给用户授予角色时，可能需要一并授予依赖的其他角色，才能正确完成业务。角色并不能满足用户对精细化授权的要求，无法完全达到企业对权限最小化的安全管控要求。
- 策略：IAM最新提供的一种细粒度授权的能力，可以精确到具体服务的操作、资源以及请求条件等。基于策略的授权是一种更加灵活的授权方式，能够满足企业

对权限最小化的安全管控要求。如不允许某用户组删除作业，仅允许操作作业基本操作，如创建作业，查询作业列表等。DLF支持的API授权项请参见[权限策略和授权项](#)。

表 5-1 DLF 系统权限

系统角色/策略名称	描述	策略类别
DLF FullAccess	数据湖工厂服务所有权限	系统策略
DLF Development	数据湖工厂服务的开发者权限，拥有该权限的用户能使用DLF进行脚本开发与作业编排，但是不具备对工作区的增删改权限。	系统策略
DLFOperationAnd MaintenanceAccess	数据湖工厂服务的运维人员权限，拥有该权限的用户可以对DLF的脚本与作业等资源进行运维，但不具备对各种资源的增删改权限。	系统策略
DLF ReadOnlyAccess	数据湖工厂服务的只读权限，拥有该权限的用户仅能查看DLF的资源。	系统策略
DLF Administrator	数据湖工厂服务管理员	系统角色

表5-2列出了DLF常用操作与系统权限的授权关系，您可以参照该表选择合适的系统权限。

表 5-2 常用操作与系统权限的授权关系

操作	DLF FullAccess	DLF Development	DLF OperationAndMaintenanceAccess	DLF ReadOnlyAccess	DLF Administrator
查询工作区	√	√	√	√	√
创建工作区	√	x	x	x	√
更新工作区	√	x	x	x	√
删除工作区	√	x	x	x	√
查询环境变量	√	√	√	√	√
更新环境变量	√	√	x	x	√

操作	DLF FullAccess	DLF Development	DLF OperationAndMaintenanceAccess	DLF ReadonlyAccess	DLF Administrator
导入环境变量	√	√	x	x	√
导出环境变量	√	√	x	x	√
查询表	√	√	√	√	√
创建表	√	√	x	x	√
更新表	√	√	x	x	√
删除表	√	√	x	x	√
查询数据库	√	√	√	√	√
创建数据库	√	√	x	x	√
更新数据库	√	√	x	x	√
删除数据库	√	√	x	x	√
查询模式	√	√	√	√	√
创建模式	√	√	x	x	√
更新模式	√	√	x	x	√
删除模式	√	√	x	x	√
查询目录	√	√	√	√	√
创建目录	√	√	x	x	√
更新目录	√	√	x	x	√
删除目录	√	√	x	x	√
查询解决方案	√	√	√	√	√
创建解决方案	√	√	x	x	√
更新解决方案	√	√	x	x	√

操作	DLF FullAccess	DLF Development	DLF OperationAndMaintenanceAccess	DLF ReadonlyAccess	DLF Administrator
删除解决方案	√	√	x	x	√
导入解决方案	√	√	√	x	√
导出解决方案	√	√	√	x	√
启动解决方案	√	√	√	x	√
停止解决方案	√	√	√	x	√
查询脚本列表	√	√	√	√	√
创建脚本	√	√	x	x	√
更新脚本	√	√	x	x	√
删除脚本	√	√	x	x	√
脚本语法检查	√	√	√	x	√
执行脚本	√	√	√	x	√
取消执行脚本	√	√	√	x	√
导入脚本	√	√	√	x	√
导出脚本或脚本执行结果	√	√	√	x	√
查询作业信息	√	√	√	√	√
创建作业	√	√	x	x	√
更新作业	√	√	x	x	√
删除作业	√	√	x	x	√
重命名作业	√	√	x	x	√
导入作业	√	√	√	x	√

操作	DLF FullAccess	DLF Development	DLF OperationAndMaintenanceAccess	DLF ReadonlyAccess	DLF Administrator
导出作业	√	√	√	x	√
校验作业定义的合法性	√	√	√	x	√
测试运行作业	√	√	√	x	√
启动作业	√	√	√	x	√
停止作业	√	√	√	x	√
暂停作业	√	√	√	x	√
恢复执行作业	√	√	√	x	√
查询作业实例	√	√	√	√	√
重跑作业实例	√	√	√	x	√
停止作业实例	√	√	√	x	√
强制成功作业实例	√	√	√	x	√
继续执行作业实例	√	√	√	x	√
启用作业节点	√	√	√	x	√
禁用作业节点	√	√	√	x	√
重跑作业节点	√	√	√	x	√
跳过执行作业节点	√	√	√	x	√
暂停作业节点	√	√	√	x	√
恢复执行作业节点	√	√	√	x	√

操作	DLF FullAccess	DLF Development	DLF OperationAndMaintenanceAccess	DLF ReadonlyAccess	DLF Administrator
强制成功作业节点	√	√	√	x	√
查询数据连接	√	√	√	√	√
创建数据连接	√	√	x	x	√
更新数据连接	√	√	x	x	√
删除数据连接	√	√	x	x	√
测试数据连接的连通性	√	√	x	x	√
导入数据连接	√	√	√	x	√
导出数据连接	√	√	√	x	√
查询资源列表	√	√	√	√	√
创建资源	√	√	x	x	√
更新资源	√	√	x	x	√
删除资源	√	√	x	x	√
上传资源	√	√	x	x	√
导出资源	√	√	√	x	√
导入资源	√	√	√	x	√
查询备份信息	√	√	√	√	√
启动备份	√	√	√	x	√
停止备份	√	√	√	x	√
查询通知列表	√	√	√	√	√
创建通知	√	√	x	x	√

操作	DLF FullAccess	DLF Development	DLF OperationAndMaintenanceAccess	DLF ReadonlyAccess	DLF Administrator
更新通知	√	√	x	x	√
删除通知	√	√	x	x	√
查询补数据列表	√	√	√	√	√
创建补数据任务	√	√	x	x	√
停止补数据任务	√	√	√	x	√

# 6 与其他服务的关系

---

## MapReduce 服务

数据开发模块服务的大数据类型节点（如SparkSQL）运行在MapReduce服务（MapReduce Service, MRS）中。

## 对象存储服务

数据开发模块服务支持从对象存储服务（Object Storage Service, 简称OBS）导入数据，同时数据开发模块还利用OBS存储数据、结果、日志文件，以及用户程序。

## 关系型数据库

数据开发模块服务支持将数据存储于关系型数据库（Relational Database Service, RDS）中，以及执行RDS数据处理操作。

## 数据加密服务

数据加密服务（Data Encryption Workshop, DEW）用于加密和解密数据开发模块中数据连接的用户密码和密钥。

## 数据仓库服务

数据开发模块服务支持将数据存储于数据仓库服务（Data Warehouse Service, DWS）中，以及执行DWS数据处理操作。

## 云数据迁移

数据开发模块服务依赖云数据迁移（Cloud Data Migration, CDM）实现数据迁移相关的处理。

## 机器学习服务

数据开发模块服务依赖机器学习服务（Machine Learning Service, MLS）实现机器学习相关的处理。

## 数据湖探索

数据开发模块服务依赖数据湖探索（Data Lake Insight, DLI）实现数据探索相关的数据处理。

## 云搜索服务

数据开发模块服务依赖云搜索服务（Cloud Search Service）实现云搜索相关的数据处理。

## 消息通知服务

数据开发模块服务的通知管理功能依赖消息通知服务（Simple Message Notification, SMN）发送作业信息给用户。

## 实时流计算服务

数据开发模块依赖实时流计算服务（Cloud Stream Service, CS）实现实时流式大数据分析。

## 表格存储服务

数据开发模块支持将数据存储于表格存储服务（CloudTable Service, CloudTable）中。

## 数据接入服务

数据开发模块依赖数据接入服务（Data Ingestion Service, DIS）实现数据转储相关的数据处理。

## 统一身份认证服务

统一身份认证服务（Identity and Access Management, IAM）为数据开发模块提供了鉴权功能。

# 7 约束限制

---

使用数据开发模块前，您需要认真阅读并了解以下使用限制。

- 建议使用支持的浏览器版本登录数据开发模块。
  - Google Chrome: 54.0及更高版本

# 8 区域和可用区


## 什么是区域、可用区？

我们用区域和可用区来描述数据中心的位置，您可以在特定的区域、可用区创建资源。

- 区域（Region）：从地理位置和网络时延维度划分，同一个Region内共享弹性计算、块存储、对象存储、VPC网络、弹性公网IP、镜像等公共服务。Region分为通用Region和专属Region，通用Region指面向公共租户提供通用云服务的Region；专属Region指只承载同一类业务或只面向特定租户提供业务服务的专用Region。
- 可用区（AZ，Availability Zone）：一个AZ是一个或多个物理数据中心的集合，有独立的风火水电，AZ内逻辑上再将计算、网络、存储等资源划分成多个集群。一个Region中的多个AZ间通过高速光纤相连，以满足用户跨AZ构建高可用性系统的需求。

图8-1阐明了区域和可用区之间的关系。

图 8-1 区域和可用区



目前，华为云已在全球多个地域开放云服务，您可以根据需求选择适合自己的区域和可用区。更多信息请参见[华为云全球站点](#)。

## 如何选择区域？

选择区域时，您需要考虑以下几个因素：

- 地理位置

一般情况下，建议就近选择靠近您或者您的目标用户的区域，这样可以减少网络时延，提高访问速度。不过，在基础设施、BGP网络品质、资源的操作与配置等方面，中国大陆各个区域间区别不大，如果您或者您的目标用户在中国大陆，可以不用考虑不同区域造成的网络时延问题。

香港、曼谷等其他地区和国家提供国际带宽，主要面向非中国大陆地区的用户。如果您或者您的目标用户在中国大陆，使用这些区域会有较长的访问时延，不建议使用。

- 在除中国大陆以外的亚太地区有业务的用户，可以选择“亚太-曼谷”或“亚太-新加坡”区域。
- 在非洲地区有业务的用户，可以选择“南非-约翰内斯堡”区域。
- 在欧洲地区有业务的用户，可以选择“欧洲-巴黎”区域。

- 资源的价格

不同区域的资源价格可能有差异，请参见[华为云服务价格详情](#)。

## 区域和终端节点

当您通过API使用资源时，您必须指定其区域终端节点。有关华为云的区域和终端节点的更多信息，请参阅[地区和终端节点](#)。

# 9 配额说明

---

目前默认每个用户最多可以创建1000个作业。

## 说明

作业使用时涉及到的其他资源服务，请参见其他服务的配额。