

盘古大模型

用户指南

文档版本

01

发布日期

2025-07-28



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 盘古大模型服务使用流程..... 1

2 准备工作..... 4

2.1 申请试用 ModelArts Studio 大模型开发平台..... 4

2.2 订购盘古大模型服务..... 4

2.3 配置服务访问授权..... 9

2.4 创建并管理工作空间..... 10

2.4.1 工作空间介绍..... 10

2.4.2 创建并管理工作空间..... 10

2.4.3 管理工作空间成员..... 13

3 在模型广场查看模型..... 18

4 使用数据工程构建数据集..... 21

4.1 数据工程介绍..... 21

4.2 数据工程使用流程..... 25

4.3 数据集格式要求..... 26

4.3.1 文本类数据集格式要求..... 26

4.3.2 图片类数据集格式要求..... 29

4.3.3 视频类数据集格式要求..... 44

4.3.4 音频类数据集格式要求..... 47

4.3.5 气象类数据集格式要求..... 48

4.3.6 其他类数据集格式要求..... 50

4.4 导入数据至盘古平台..... 50

4.5 加工数据集..... 53

4.5.1 数据集加工场景介绍..... 53

4.5.2 加工文本类数据集..... 55

4.5.2.1 加工文本类数据集..... 56

4.5.2.2 合成文本类数据集..... 59

4.5.2.3 标注文本类数据集..... 67

4.5.2.4 配比文本类数据集..... 73

4.5.3 加工图片类数据集..... 76

4.5.3.1 加工图片类数据集..... 76

4.5.3.2 标注图片类数据集..... 80

4.5.3.3 配比图片类数据集..... 85

4.5.4 加工视频类数据集.....	87
4.5.4.1 加工视频类数据集.....	87
4.5.4.2 标注视频类数据集.....	89
4.5.5 加工气象类数据集.....	93
4.5.6 加工音频类数据集.....	95
4.5.6.1 加工音频类数据集.....	95
4.5.6.2 标注音频类数据集.....	97
4.5.7 加工其他类数据集.....	99
4.5.8 管理加工算子.....	101
4.5.8.1 系统预置加工算子介绍.....	101
4.5.8.1.1 文本类加工算子介绍.....	101
4.5.8.1.2 视频类加工算子介绍.....	116
4.5.8.1.3 图片类加工算子介绍.....	125
4.5.8.1.4 气象类加工算子介绍.....	132
4.5.8.1.5 音频类加工算子介绍.....	132
4.5.8.2 自定义数据集加工算子.....	136
4.5.9 管理加工后的数据集.....	146
4.5.10 管理加工任务资源.....	147
4.5.11 加工任务生成数据集.....	147
4.6 发布数据集.....	148
4.6.1 数据集发布场景介绍.....	148
4.6.2 发布文本类数据集.....	150
4.6.2.1 评估文本类数据集.....	150
4.6.2.2 发布文本类数据集.....	152
4.6.3 发布图片类数据集.....	154
4.6.3.1 评估图片类数据集.....	154
4.6.3.2 发布图片类数据集.....	156
4.6.4 发布视频类数据集.....	158
4.6.4.1 评估视频类数据集.....	158
4.6.4.2 发布视频类数据集.....	160
4.6.5 发布音频类数据集.....	161
4.6.6 发布气象类数据集.....	162
4.6.7 发布其他类数据集.....	163
4.6.8 管理发布后的数据集.....	164
4.7 数据集格式转换.....	165
4.7.1 使用限制.....	165
4.7.2 格式转换操作流程.....	166
4.7.3 转换算子说明.....	168
4.8 数据工程常见报错与解决方案.....	173
5 开发 Deepseek 大模型.....	176
5.1 Deepseek 大模型介绍.....	176
5.2 使用数据工程构建 Deepseek 大模型数据集.....	177

- 5.3 训练 Deepseek 大模型..... 178
 - 5.3.1 创建 Deepseek 大模型训练任务..... 178
 - 5.3.2 查看 Deepseek 大模型训练状态与指标..... 187
 - 5.3.3 发布训练后的 Deepseek 大模型..... 189
 - 5.3.4 管理 Deepseek 大模型训练任务..... 189
- 5.4 压缩 Deepseek 大模型..... 189
- 5.5 部署 Deepseek 大模型..... 190
- 5.6 评测 Deepseek 大模型..... 191
 - 5.6.1 创建 Deepseek 大模型评测数据集..... 191
 - 5.6.2 创建 API 服务（可选）..... 194
 - 5.6.3 创建 Deepseek 大模型评测任务..... 199
 - 5.6.4 查看 Deepseek 大模型评测报告..... 204
 - 5.6.5 管理 Deepseek 大模型评测任务..... 206
- 5.7 调用 Deepseek 大模型..... 207
- 6 开发提示词工程..... 209**
 - 6.1 什么是提示词工程..... 209
 - 6.2 获取提示词模板..... 210
 - 6.3 撰写提示词..... 211
 - 6.3.1 创建提示词工程..... 211
 - 6.3.2 撰写提示词..... 211
 - 6.3.3 预览提示词效果..... 213
 - 6.4 横向比较提示词效果..... 213
 - 6.4.1 设置候选提示词..... 214
 - 6.4.2 横向比较提示词效果..... 214
 - 6.5 批量评估提示词效果..... 215
 - 6.5.1 创建提示词评估数据集..... 216
 - 6.5.2 创建提示词评估任务..... 217
 - 6.5.3 查看提示词评估结果..... 218
 - 6.6 发布提示词..... 219
- 7 开发 Agent 应用..... 220**
 - 7.1 Agent 开发平台介绍..... 220
 - 7.1.1 平台简介..... 220
 - 7.1.2 应用场景..... 222
 - 7.1.3 功能概述..... 223
 - 7.1.4 使用流程..... 225
 - 7.2 使用百宝箱中预置的 Agent 应用..... 226
 - 7.3 应用搭建与配置..... 227
 - 7.3.1 快速搭建 Agent 应用..... 227
 - 7.3.2 为 Agent 应用提升技能..... 233
 - 7.3.2.1 配置插件..... 233
 - 7.3.2.2 配置 workflow..... 235
 - 7.3.2.3 配置知识库..... 237

7.3.2.4 配置 MCP..... 238

7.3.2.5 提升 Agent 应用对话体验..... 239

7.3.2.6 调试 Agent 应用..... 241

7.3.3 使用 API 调用 Agent 应用..... 244

7.3.4 管理 Agent 应用..... 246

7.4 workflow 开发与配置..... 249

7.4.1 workflow 介绍..... 249

7.4.2 创建工作流..... 250

7.4.2.1 创建工作流..... 250

7.4.2.2 调试与发布 workflow..... 252

7.4.2.3 对话型 workflow 和任务型 workflow..... 254

7.4.2.4 workflow 节点配置参考..... 256

7.4.2.4.1 开始和结束节点..... 256

7.4.2.4.2 大模型节点..... 259

7.4.2.4.3 知识检索节点..... 261

7.4.2.4.4 意图识别节点..... 263

7.4.2.4.5 插件节点..... 268

7.4.2.4.6 判断节点..... 272

7.4.2.4.7 代码节点..... 275

7.4.2.4.8 消息节点..... 277

7.4.2.4.9 提问器节点..... 278

7.4.2.4.10 循环节点..... 282

7.4.2.4.11 变量赋值节点..... 284

7.4.2.4.12 变量聚合节点..... 286

7.4.2.4.13 输入节点..... 288

7.4.2.4.14 workflow 节点..... 289

7.4.2.4.15 MCP 服务节点配置说明..... 290

7.4.2.4.16 Agent 节点配置说明..... 292

7.4.3 通过 API 调用 workflow..... 294

7.4.4 管理工作流..... 296

7.5 插件开发与配置..... 298

7.5.1 插件介绍..... 298

7.5.2 创建插件..... 298

7.5.2.1 基于 API 创建一个插件..... 299

7.5.2.2 通过 JSON 文件导入插件..... 301

7.5.3 管理插件..... 302

7.6 知识库开发与配置..... 302

7.6.1 知识库介绍..... 303

7.6.2 创建知识库及上传文档..... 305

7.6.3 知识库命中测试..... 306

7.6.4 管理知识库..... 307

7.7 MCP 服务开发与配置..... 307

7.7.1 MCP 服务介绍..... 307

7.7.2 创建 MCP 服务..... 307

7.7.3 管理 MCP 服务..... 314

7.7.4 开通 MCP 服务..... 315

7.8 Agent 开发常见报错与解决方案..... 316

8 管理空间资产..... 321

8.1 盘古大模型空间资产介绍..... 321

8.2 管理盘古数据资产..... 321

8.3 管理盘古模型资产..... 324

8.4 管理盘古组件资产..... 325

9 管理资源池..... 326

9.1 创建边缘资源池..... 326

1 盘古大模型服务使用流程

盘古大模型服务简介

盘古大模型服务包含盘古基础大模型、盘古行业大模型与ModelArts Studio大模型开发平台。凭借“模型+开发平台”的产品组合，助力各行业客户实现一站式的大模型开发与应用能力。

ModelArts Studio大模型开发平台是盘古大模型服务推出的包括数据管理、模型训练、模型部署于一体的综合平台，专为开发和应用大模型而设计，旨在为开发者提供简单、高效的大模型开发和部署方式。平台配备数据工程、模型开发、应用开发三大工具链，帮助开发者充分利用盘古大模型的功能。

- **数据工程工具链**：数据是大模型训练的核心基础。数据工程工具链作为平台的重要组成部分，具备数据获取、数据加工和数据发布等功能，确保数据的高质量与一致性。工具链能够高效收集并处理各种格式的数据，满足不同训练任务的需求，并提供强大的数据存储和管理能力，为大模型训练提供坚实的数据支持。
- **模型开发工具链**：模型开发工具链是盘古大模型服务的核心组件，提供从模型创建到部署的一站式解决方案，涵盖模型训练、压缩、部署、评测、调用等功能，保障模型的高效应用。
- **应用开发工具链**：应用开发工具链是盘古大模型平台的重要模块，支持提示词工程、Agent开发，显著加速大模型应用的开发流程，帮助企业快速应对复杂业务需求。

数据工程使用流程

ModelArts Studio大模型开发平台提供了数据工程能力，帮助用户构造高质量的数据集，助力模型进行更好地预测和决策。

数据工程使用流程见[图1-1](#)、[表1-1](#)。

图 1-1 数据工程使用流程图




表 1-1 数据工程使用流程表

流程	子流程	说明
准备工作	申请试用盘古大模型服务	盘古大模型为用户提供了服务试用，用户可根据所需提交试用申请，申请通过后才可以使用盘古大模型功能。
	订购盘古大模型服务	正式使用盘古大模型服务前，需要完成服务的订购操作。
	配置服务访问授权	为了能够正常的存储数据、训练模型，需要用户配置盘古访问OBS的权限。
	创建并管理盘古工作空间	平台支持用户自定义创建工作空间，并进行空间的统一管理。
导入数据至盘古平台	创建导入任务	将存储在OBS服务中的数据导入至平台统一管理，用于后续加工或发布操作。
加工数据集	加工数据集	通过专用的加工算子对数据进行预处理，确保数据符合模型训练的标准和业务需求。不同类型的数据集使用专门设计的算子，例如去除噪声、冗余信息等，提升数据质量。
	合成数据集	利用预置或自定义的数据指令对原始数据进行处理，并根据设定的轮数生成新数据。该过程能够在一定程度上扩展数据集，增强训练模型的多样性和泛化能力。
	标注数据集	为无标签数据集添加准确的标签，确保模型训练所需的高质量数据。平台支持人工标注和AI预标注两种方式，用户可根据需求选择合适的标注方式。数据标注的质量直接影响模型的训练效果和精度。
	配比数据集	数据配比是将多个数据集按特定比例组合并生成为“加工数据集”的过程。通过合理的配比，确保数据集的多样性、平衡性和代表性，避免因数据分布不均而引发的问题。

流程	子流程	说明
发布数据集	评估数据集	平台预置了多种数据类型的基础评估标准，用户可根据需求选择预置标准或自定义评估标准，从而精确优化数据质量，确保数据满足高标准，提升模型性能。
	发布数据集	数据发布是将单个数据集发布为特定格式的“发布数据集”，用于后续模型训练等操作。 平台支持发布的数据集格式为标准格式、盘古格式。 ● 标准格式：平台默认的格式。该格式的数据集可发布为资产，但不可应用于盘古大模型的开发中。 ● 盘古格式：训练盘古大模型时，需要发布为该格式。当前仅文本类、图片类数据集支持发布为盘古格式。

2 准备工作

2.1 申请试用 ModelArts Studio 大模型开发平台

盘古大模型服务为用户提供了服务试用，需提交试用申请。

试用申请步骤如下：

1. 登录ModelArts Studio大模型开发平台。
2. 单击“试用咨询”，进入华为云售前咨询页面。

图 2-1 申请试用



3. 填写姓名、联系电话等用户信息，单击“提交申请”进行表单预约。

2.2 订购盘古大模型服务

订购说明

ModelArts Studio大模型开发平台支持订购**模型资产**、**数据资源**、**训练资源**、**推理资源**，支持模型资产的包年/包月订购、资源的包年/包月和按需计费订购。

- 模型资产：**模型资产**可用于模型开发、应用开发等模块。当前支持订购NLP大模型。
- 数据资源：**数据通算单元**适用于数据加工，用于正则类算子加工、**数据智算单元**适用于数据加工，用于AI类算子加工，**数据托管单元**适用于数据工程，用于存储数据集。
- 训练资源：**训练单元**可用于所有大模型的模型训练、模型压缩功能。

- 推理资源：**推理单元**可用于NLP、CV大模型的模型推理功能，**模型实例**可用于科学计算大模型的模型推理功能。

订购场景

ModelArts Studio大模型开发平台提供**免费模型**、**付费模型**，订购相应的模型和资源后支持在平台使用**数据工程**功能，**模型开发**功能，**Agent**功能。

用户可以基于使用场景进行按需进行订购。

表 2-1 订购场景介绍

编号	场景	场景说明
1	数据场景	仅订购数据资源不订购模型，支持数据的加工、合成、标注、配比等场景。
2	推理场景	纯推理场景，用户可以使用免费模型或订购模型资产（可选）+推理资源，部署后进行推理。
3	训推场景	支持模型的训练和推理，订购模型资产（可选）+训练资源+推理资源，支持用户使用已订购的付费模型或免费模型进行训练，将训练后的模型部署后再进行推理，获得更好的效果。
4	Agent场景	订购模型资产（可选）+训练资源（可选）+推理资源，支持使用已订购的付费模型或免费模型部署后在Agent中使用。

场景1：数据场景，仅使用数据工程的能力

订购“数据通算单元”、“数据智算单元”用于数据的加工、合成、标注、配比存储等场景，订购数据托管单元用于数据存储（包括数据集，prompt模板等）。

图 2-2 数据资源



场景2：推理场景，使用已订购的付费模型或模型广场的免费模型，进行模型部署推理操作

订购“ModelArts Studio-推理单元（NLP）”用于NLP大模型免费和付费模型的部署推理。

图 2-3 推理场景



场景3：训推场景，订购模型资产+训练资源+推理资源，支持用户训练和部署模型

订购“ModelArts Studio-训练单元”，使用已订购的付费模型或模型广场的免费模型进行模型训练操作，训练完成后进行模型部署。


图 2-4 训练资源



场景4：Agent场景，使用已经部署的模型用于Agent应用

订购模型资产（可选）+训练资源（可选）+推理资源，支持使用已订购的付费模型或免费模型部署后在Agent中使用。

图 2-5 Agent 应用



订购步骤

1. 使用主账户登录ModelArts Studio大模型开发平台，单击“立即订购”进入“订购”页面。
2. 在“开发场景”中勾选需要订购的大模型（可多选），页面将根据勾选情况适配具体的订购项。

图 2-6 选择开发场景



3. 参考表2-2，分别完成数据资源、训练资源和推理资源的订购。

表 2-2 资源订购说明

资源名称	订购项	适用场景	计费方式
数据资源	ModelArts Studio-数据托管单元	用于数据存储（包括数据集，prompt模板等）。	包年/包月
	ModelArts Studio-数据通算单元	适用于数据加工，用于正则类算子加工。 不同数据加工算子所需数据资源类型详见 系统预置加工算子介绍 。	按需（时长）计费、包年/包月
	ModelArts Studio-数据智算单元	适用于数据加工，用于AI类算子加工。 不同数据加工算子所需数据资源类型详见 系统预置加工算子介绍 。	按需（时长）计费、包年/包月
训练资源	ModelArts Studio-训练单元	用于所有模型的模型训练、模型压缩。	按需（时长）计费、包年/包月

资源名称	订购项	适用场景	计费方式
推理资源	ModelArts Studio-推理单元（NLP）	适用于NLP大模型在基础平台和Agent开发的推理服务场景。	包年/包月

续订模型资产

ModelArts Studio大模型开发平台支持以**包年/包月**方式续订模型资产，即在当前订购的模型资产基础上延长使用时间。

续订模型资产的步骤如下：

- 1. 登录ModelArts Studio大模型开发平台，单击页面右上角“订购管理”。
- 2. 在“订购管理”页面，单击“模型订购”页签，在订阅模型列表单击操作列“续订”。
- 3. 在“续费管理”页面根据提示完成模型资产的续费操作。

退订模型资产

退订模型资产的步骤如下：

- 1. 登录ModelArts Studio大模型开发平台，单击页面右上角“订购管理”。
- 2. 在“订购管理”页面，单击“模型订购”页签，在订阅模型列表单击操作列“退订”。

说明

模型资产退订后不影响运行中的模型训练、压缩、评测、部署等任务，但退订之后将无法再选择该模型创建任务，请谨慎操作。

退订属于高危操作，在退订模型资产前，请确保您已保存所有必要的数据和进度，以避免不必要的损失。

增购模型资产

ModelArts Studio大模型开发平台支持增购模型资产，即在当前模型资产基础上订购新的模型资产，增购完成后支持使用多个模型资产。

增购模型资产的步骤如下：

- 1. 登录ModelArts Studio大模型开发平台，单击页面右上角“订购管理”。
- 2. 在“订购管理”页面，单击右上角“新增订购”。
- 3. 在“订购”页面，参考[订购步骤](#)完成新的模型资产增购。

续订资源

ModelArts Studio大模型开发平台支持以**包年/包月**方式续订数据资源、训练资源、推理资源，即在当前资源基础上延长使用时间。

续订资源的步骤如下：

1. 登录ModelArts Studio大模型开发平台，单击页面右上角“订购管理”。
2. 在“订购管理”页面，单击“资源订购”页签，在资源列表单击操作列“续订”。
3. 在“续费管理”页面根据提示完成资源的续费操作。

说明

按需计费方式暂不支持续订。

退订资源

退订资源的步骤如下：

1. 登录ModelArts Studio大模型开发平台，单击页面右上角“订购管理”。
2. 在“订购管理”页面，单击“资源订购”页签，在资源列表单击操作列“退订”。

说明

退订后会停止运行中的服务，且之后将无法再选择该资源使用。

退订属于高危操作，请确保您已保存所有必要的数据和进度，以避免不必要的损失。

扩缩容资源

ModelArts Studio大模型开发平台支持数据资源、训练资源、推理资源的扩缩容，即在当前资源的基础上扩充或缩小对应的资源。

资源扩缩容的步骤如下：

1. 登录ModelArts Studio大模型开发平台，单击页面右上角“订购管理”。
2. 在“订购管理”页面，单击“资源订购”页签，在资源列表单击操作列“扩缩容”。
3. 在“扩缩容”页面完成当前资源的扩缩容操作，平台将根据扩缩容前后的规格差异支付或退还费用差价。

说明

缩容可能会影响进行中的任务以及后续任务的创建，缩容前，请先确认需要缩容的资源已释放。

2.3 配置服务访问授权

配置 OBS 访问授权

ModelArts Studio大模型开发平台使用对象存储服务（Object Storage Service，简称OBS）进行数据存储，实现安全、高可靠和低成本存储需求。因此，为了能够顺利进行存储数据、训练模型等操作，需要用户配置访问OBS服务的权限。

配置OBS访问授权步骤如下：

1. 登录ModelArts Studio大模型开发平台首页。
2. 配置OBS访问授权。
 - 方式1：在首页顶部单击“此处”，在弹窗中选择授权项，并单击“确认授权”。

图 2-7 配置 OBS 访问授权



- 方式2：单击首页右上角“设置”，在“授权管理”页签，单击“一键授权”。

2.4 创建并管理工作空间

2.4.1 工作空间介绍

工作空间功能旨在为用户提供灵活、高效的资产管理与协作方式。平台支持用户根据业务需求或团队结构，自定义创建独立的工作空间。

每个工作空间在资产层面完全隔离，确保资产的安全性和操作的独立性，有效避免交叉干扰或权限错配带来的风险。用户可以结合实际使用场景，如不同的项目管理、部门运营或特定的研发需求，划分出多个工作空间，实现资产的精细化管理与有序调配，帮助用户高效地规划和分配任务，使团队协作更加高效。

此外，平台配备了完善的角色权限体系，覆盖超级管理员、管理员、模型开发工程师等多种角色。通过灵活的权限设置，每位用户能够在其对应的权限范围内安全高效地操作平台功能，从而最大程度保障数据的安全性与工作效率。

2.4.2 创建并管理工作空间

约束限制

如果当前用户所在用户组未获取**全部云服务管理员(Tenant Administrator)**授权，则无法创建工作空间。


创建空间前，如果需要获取**全部云服务管理员(Tenant Administrator)**授权，请参考**创建用户组**及**创建盘古子用户**步骤，赋予当前用户组“全部云服务管理员(Tenant Administrator)”权限，或创建具有“全部云服务管理员(Tenant Administrator)”权限的用户组和对应用户。

创建工作空间

创建工作空间步骤如下：

1. 登录ModelArts Studio大模型开发平台，在“我的空间”模块，单击“创建空间”。

图 2-8 我的空间



2. 填写空间名称、描述，单击“确认”，完成空间的创建。

图 2-9 创建空间



3. 单击创建好的空间，进入ModelArts Studio大模型开发平台。
- 如果用户具备多个空间的访问权限，可在页面左上角单击  切换空间。

图 2-10 切换空间
大模型开发平台



管理盘古工作空间

盘古工作空间支持用户查看当前空间详情，修改空间名称与描述，还可以对不需要的空间实现删除操作。

1. 登录ModelArts Studio大模型开发平台，在“我的空间”模块，单击进入所需空间。

图 2-11 我的空间



2. 单击左侧导航栏的“空间管理”，在“空间设置”页签可执行如下操作：
- 修改当前空间名称与描述。

- 可查看当前空间的创建时间。

- 单击右上角“删除”，可删除当前空间。

说明

删除空间前请确保当前空间不再进行使用。

2.4.3 管理工作空间成员

如果您需要为企业员工设置不同的访问权限，以实现功能使用权限和资产的权限隔离，可以为不同员工配置相应的角色，以确保资产的安全和管理的高效性。

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（子用户）进行权限管理，您可以[跳过本章节](#)，不影响您使用盘古的其他功能。

您可以使用统一身份认证服务（IAM）并结合ModelArts Studio大模型开发平台提供的“成员管理”功能实现子用户精细的权限管理。

创建用户组

管理员可以创建用户组，并给用户组授予策略或角色，然后将用户加入用户组，使用户组中的用户获得相应的权限。

创建用户组的步骤如下：

1. 使用主账号登录**IAM服务控制台**。
2. 左侧导航栏中，选择“用户组”页签，单击右上方的“创建用户组”。

图 2-12 创建用户组



- 在“创建用户组”页面，输入“用户组名称”，单击“确定”，创建用户组。
- 返回用户组列表，单击操作列的“授权”。

图 2-13 用户组授权




5. 参考表2-3，在搜索框中搜索授权项，为用户组设置权限，选择后单击“下一步”。

表 2-3 授权项

授权项	说明
Agent Operator	拥有该权限的用户可以切换角色到委托方账号中，访问被授权的服务。
Tenant Administrator	全部云服务管理员（除IAM管理权限）。
Security Administrator	统一身份认证服务（除切换角色外）所有权限。

图 2-14 添加用户组权限



6. 设置最小授权范围。
- 根据授权项策略，系统会自动推荐授权范围方案。
- 可以选择“所有资源”，即用户组内的IAM用户可以基于设置的授权项使用账号中所有的企业项目、区域项目、全局服务资源。
 - 可以选择“指定区域项目资源”，如指定“西南-贵阳一”区域，即用户组内的IAM用户仅可使用该区域项目中的资源。
 - 可以选择“全局服务资源”，即服务部署时不区分区域，访问全局级服务，不需要切换区域，全局服务不支持基于区域项目授权。如对象存储服务（OBS）、内容分发网络（CDN）等。
- 选择完成后，单击“确定”。

图 2-15 设置最小授权范围



7. 单击“完成”，完成用户组授权。

图 2-16 完成授权



创建盘古子用户

创建盘古子用户步骤如下：

1. 使用主账号登录IAM服务控制台。
2. 左侧导航窗格中，选择“用户”页签，单击右上方的“创建用户”。

图 2-17 创建用户




3. 配置用户基本信息，单击“下一步”。
- 配置用户信息时，需要勾选“编程访问”，如果未勾选此项，会导致IAM用户无法使用盘古服务API、SDK。

图 2-18 配置用户基本信息



4. 将用户添加至创建用户组步骤中创建的用户组，单击“创建用户”，完成IAM用户的创建。

图 2-19 加入用户组




添加盘古子用户至工作空间

在添加盘古子用户至工作空间前，请先完成创建盘古子用户。

1. 登录ModelArts Studio大模型开发平台。
2. 进入需要添加子用户的空间，在空间内单击左侧导航栏“空间管理”，并进入“成员管理”页签。
3. 如图2-20，以添加子用户为“模型开发工程师”角色为例。在搜索框中搜索子用户名称，在“请选择角色”选项栏中设置用户角色，设置完成后单击右侧“添加”，将该用户添加至本空间。

图 2-20 添加成员为“模型开发工程师”角色




修改盘古子用户权限

当需要修改空间内某个子用户权限时可以按如下步骤操作：

1. 登录ModelArts Studio大模型开发平台。
2. 进入需要修改子用户权限的空间，在空间内单击左侧导航栏“空间管理”，在“角色管理”页签，可以查看各角色名称及其权限的描述。

图 2-21 角色管理



3. 单击进入“成员管理”页签。
4. 如图，以授权子用户“模型开发工程师”权限为例。单击用户列表操作栏的“编辑”，勾选需要赋予用户的角色，单击“确认”。

图 2-22 授权子用户“模型开发工程师”权限



移除盘古子用户

当需要删除空间内某个子用户时，可以按如下步骤操作：

- 1. 登录ModelArts Studio大模型开发平台。
- 2. 进入需要删除子用户的空间，在空间内单击左侧导航栏“空间管理”，并进入“成员管理”页面。
- 3. 单击用户列表操作栏的“删除”。

图 2-23 成员管理



- 4. 单击“确定”进行二次确认，即可删除空间子用户。

图 2-24 删除操作二次确认



3 在模型广场查看模型

ModelArts Studio平台模型广场页面提供一站式的模型资源库，您可以依据业务需求选择合适的模型执行训练推理任务。

模型广场左侧区域是搜索与筛选区，支持客户勾选不同筛选条件，过滤出所需要的模型；并且支持按照关键字搜索模型。右侧区域是模型展示区，以卡片的形式展示模型内容，包括模型名称、模型描述、应用场景标签，支持单击“查看详情”，进入模型详情页，查看版本号、版本描述、版本详情等信息，支持单击“训练”或者“部署”，单击跳转到模型训练或模型部署界面，对该模型创建训练或部署任务。

平台支持的大模型清单请参见《产品介绍》“模型能力与规格 > 三方大模型”章节。

访问模型广场

1. 登录ModelArts Studio大模型开发平台，在“我的空间”模块，单击空间名称进入操作空间。

图 3-1 我的空间



2. 在左侧导航栏中选择“模型广场”。
3. 在“模型广场”页面左侧区域，可以按照“模型类型”、“模型系列”、“应用场景”、“支持功能”、“订阅类型”进行模型筛选。


表 3-1 模型筛选说明

筛选项	说明
模型类型	包括大语言类型、CV大模型、科学计算大模型等。
模型系列	包括盘古基础大模型。
应用场景	包括长文本推理、逻辑推理、语义分割、物体检测、深度思考、文本生成、数据分析、意图分类等。
支持功能	包括支持训练、支持推理。
订阅类型	包括免费和付费。

查看模型版本信息

在“模型广场”中，鼠标指向目标模型，单击“查看详情”，进入到模型详情界面，查看模型详情。

图 3-2 模型广场




模型详情界面展示信息分为模型介绍以及版本列表页。模型介绍页主要展示对应模型的介绍内容、模型使用申明、平台服务协议。版本列表页展示当前模型下多个版本的特性介绍。

图 3-3 模型介绍



图 3-4 版本列表



训练、部署模型

参考开发各大模型章节，模型训练和部署的操作步骤。

体验模型功能

对于已有模型进行部署操作。平台提供预置部署服务，可直接单击“体验中心”体验模型功能，对于没有提供预置服务的模型，需要到“模型开发 > 模型部署”页面进行模型部署。

1. 在左侧导航栏中选择“模型开发 > 模型部署”，单击界面右上角“创建部署”。
2. 在“创建部署”页面，选择模型来源、模型类型，完成部署参数设置，启动模型部署。
部署完成后，模型广场界面对应模型的卡片会展示“立即体验”按钮，单击后跳转到“体验中心”体验模型功能。

4 使用数据工程构建数据集

4.1 数据工程介绍

数据工程介绍

数据工程是ModelArts Studio大模型开发平台（下文简称“平台”）为用户提供的一站式数据处理与管理功能，旨在通过系统化的数据获取、加工、发布等过程，确保数据能够高效、准确地为大模型的训练提供支持，帮助用户高效管理和处理数据，提升数据质量和处理效率，为大模型开发提供坚实的数据基础。

数据工程包含的具体功能如下：

- **数据获取：**数据获取是数据工程的第一步，支持将不同来源和格式的数据导入平台，并生成“原始数据集”。
 - 支持的接入方式：通过OBS服务导入数据。
 - 支持的数据类型：文本、图片、视频、音频、气象、其他。
 - 自定义格式：用户可以根据业务需求上传自定义格式的数据，提升数据获取的灵活性和可扩展性。

通过这些功能，用户可以轻松将大量数据导入平台，为后续的数据加工和模型训练等操作做好准备。

- **数据加工：**平台提供了数据加工、数据合成、数据标注、数据配比的加工操作，旨在确保原始数据能够满足各种业务需求和模型训练的标准，生成“加工数据集”。
 - **数据加工：**数据加工旨在通过使用数据集加工算子对数据进行预处理操作，针对不同类型的数据集，平台设计了专用的加工算子，以确保数据符合模型训练的标准和业务需求。
 - **数据合成：**数据合成利用预置或自定义的数据指令对原始数据集进行处理，并根据设定的轮数生成新的数据。
 - **数据标注：**数据标注旨在为无标签的数据集添加准确的标签，标注数据的质量直接影响模型的训练效果和精度。针对不同数据集平台支持人工标注与AI预标注两种形式。

其中，图片Caption、视频Caption标注项支持AI预标注功能。
 - **数据配比：**将多个数据集按照特定比例关系组合为一个“加工数据集”的过程，确保数据的多样性、平衡性和代表性。

通过数据加工操作，平台能够有效清理噪声数据、标准化数据格式，提升数据集的整体质量。

- **数据发布：**平台提供了数据发布操作，支持发布不同模态及不同格式的数据集，并生成“发布数据集”。
 - 数据发布：将单个数据集发布为特定格式的“发布数据集”的过程，用于后续模型训练等操作。
支持发布的数据集格式为标准格式、盘古格式（适用于训练盘古大模型时）。目前，仅文本类和图片类数据集支持发布为“盘古格式”。
- **数据管理：**平台提供了数据集管理，数据评估操作，旨在管理各类型数据集以及通过数据质量评估确保数据满足大模型训练的多样性、平衡性和代表性需求，并促进数据的高效流通与应用。
 - 数据集：管理“原始数据集”、“加工数据集”、“发布数据集”等不同类别的数据集。
 - 数据评估：数据评估通过对数据集进行系统的质量检查，依据评估标准评估数据的多个维度，旨在发现潜在问题并加以解决。

在集成了数据获取、数据加工、数据发布功能外，平台还支持对原始数据集、加工数据集、发布数据集、数据合成指令进行一站式管理。在大规模数据集的构建过程中，ModelArts Studio大模型开发平台的数据工程功能为用户提供了极大的灵活性和高效性，确保了数据处理的各个环节都能紧密协作，快速响应不断变化的业务需求和技术要求。

平台支持的数据类型

ModelArts Studio大模型开发平台支持的数据类型见[表4-1](#)各类型数据格式详细要求请参考[数据集格式要求](#)。

表 4-1 平台支持的数据类型

数据类型	数据内容	支持的文件格式
文本类	文档	txt、mobi、epub、docx、pdf
	网页	html
	预训练文本	jsonl
	单轮问答	jsonl、csv
	单轮问答（人设）	jsonl、csv
	多轮问答	jsonl
	多轮问答（人设）	jsonl
	问答排序	jsonl、csv
	偏好优化 DPO	jsonl

数据类型	数据内容	支持的文件格式
	偏好优化 DPO（人设）	jsonl
图片类	仅图片	jpg、jpeg、png、bmp、tar包
	图片+Caption	• 图片格式支持：jpg、jpeg、png、bmp，所有图片需保存为tar包。 • Caption格式支持：jsonl，jsonl文件仅支持UTF-8编码。
	图片+QA对	• 图片格式支持：jpg、jpeg、png、bmp，所有图片需保存为tar包。 • QA对格式支持：jsonl，jsonl文件仅支持UTF-8编码。
	物体检测	• 图片格式支持：jpg、jpeg、png、bmp、tif、tiff • 标注格式支持：xml
	图像分类	• 图片格式支持：jpg、jpeg、png、bmp、tif、tiff • 标注格式支持：txt
	异常检测	• 图片格式支持：jpg、jpeg、png、bmp • 标注格式支持：txt
	语义分割	• 图片+xml： - 图片格式支持：jpg、jpeg、png、bmp - 标注文件格式：xml • 原始图片+标注图片+json - 图片格式支持：jpg、jpeg、png、bmp - 标注文件格式：标注图片+json • 原始图片+标注图片+txt - 图片格式支持：jpg、jpeg、png、bmp - 标注文件格式：标注图片+txt • 原始图片+标注图片：原始/标注图片格式支持：jpg、jpeg、png、bmp • 图片+png
	姿态估计	• 图片+json - 图片格式支持：jpg、jpeg、png、bmp - 标注格式支持：json • 图片+xml - 图片格式支持：jpg、jpeg、png、bmp - 标注格式支持：xml，图片与标注文件一一对应

数据类型	数据内容	支持的文件格式
	实例分割	• 图片格式支持：jpg、jpeg、png、bmp • 标注格式支持：xml
	变化检测	• 图片格式支持：jpg、jpeg、bmp • 标注格式支持：png
视频类	视频	mp4、avi
	视频+标注	• 视频格式支持：mp4、avi。 • 标注文件格式：jsonl，jsonl文件仅支持UTF-8编码。
	视频分类	文件格式支持视频+txt，视频格式支持：mp4、avi。标注文件格式：txt，视频与标注文件一一对应。
	事件检测	• 视频格式支持：mp4、avi，每个视频时长大于128s，FPS>=10 • 标注格式支持：json，视频与标注文件可以一对一，也可以多对一。
音频类	仅音频	mp3、flac、wav、opus、aac、m4a。所有音频可以放在多个文件夹下，每个文件夹下可以同时包含多种格式的音频。
	音频+标注	• 音频格式支持：mp3、flac、wav、opus、aac、m4a。 • 标注文件格式：jsonl。 注意：jsonl文件仅支持UTF-8编码。
气象类	气象数据	nc、cdf、netcdf、gr、gr1、grb、grib、grib1、grib2、grib2、grib2
其他类	自定义	支持构建用户自定义场景下所需的数据集类型。

各类数据支持的操作

各类型数据支持的数据工程操作见[表4-2](#)。

表 4-2 各类数据支持的操作

数据类型	数据获取	数据加工	数据合成	数据标注	数据配比	数据评估	数据发布
文本类	√	√	√	√	√	√	√
图片类	√	√	-	√	√	√	√
音频类	√	√	-	√	-	-	√

数据类型	数据获取	数据加工	数据合成	数据标注	数据配比	数据评估	数据发布
气象类	√	√	-	-	-	-	√
其他类	√	-	-	-	-	-	√

4.2 数据工程使用流程

高质量数据是推动大模型不断迭代和优化的根基，它的质量直接决定了模型的性能、泛化能力以及应用场景的适配性。只有通过系统化地准备和处理数据，才能提取出有价值的信息，从而更好地支持模型训练。因此，数据的获取、加工、合成、标注、配比、评估、发布等环节，成为数据开发中不可或缺的重要步骤。

数据工程操作流程见图4-1、表4-3。

图 4-1 数据集构建流程图




表 4-3 数据集构建流程表

流程	子流程	说明
导入数据至盘古平台	创建导入任务	将存储在OBS服务中的数据或本地数据导入至平台统一管理，用于后续加工或发布操作。
加工数据集	加工数据集	通过专用的加工算子对数据进行预处理，确保数据符合模型训练的标准和业务需求。不同类型的数据集使用专门设计的算子，例如去除噪声、冗余信息等，提升数据质量。
	合成数据集	利用预置或自定义的数据指令对原始数据进行处理，并根据设定的轮数生成新数据。该过程能够在一定程度上扩展数据集，增强训练模型的多样性和泛化能力。

流程	子流程	说明
	标注数据集	为无标签数据集添加准确的标签，确保模型训练所需的高质量数据。平台支持人工标注和AI预标注两种方式，用户可根据需求选择合适的标注方式。数据标注的质量直接影响模型的训练效果和精度。
	配比数据集	数据配比是将多个数据集按特定比例组合并生成为“加工数据集”的过程。通过合理的配比，确保数据集的多样性、平衡性和代表性，避免因数据分布不均而引发的问题。
发布数据集	评估数据集	平台预置了多种数据类型的基础评估标准，用户可根据需求选择预置标准或自定义评估标准，从而精确优化数据质量，确保数据满足高标准，提升模型性能。
	发布数据集	数据发布是将数据集发布为特定格式的“发布数据集”，用于后续模型训练等操作。 平台支持发布的数据集格式为标准格式、盘古格式。 ● 标准格式：平台默认的格式。该格式的数据集可发布为资产，但不可应用于盘古大模型的开发中。 ● 盘古格式：训练盘古大模型时，需要发布为该格式。当前仅文本类、图片类数据集支持发布为盘古格式。

4.3 数据集格式要求

4.3.1 文本类数据集格式要求

ModelArts Studio大模型开发平台支持创建文本类数据集，创建时可导入多种形式的数
据，具体格式要求详见[表4-4](#)。

表 4-4 文本类数据集格式要求

文件内容	文件格式	文件要求
文档	txt、mobi、epub、docx、pdf	从OBS导入：单个文件大小不超过50GB，文件数量不限制。 本地上传：单个文件大小不超过10M，文件数量最多100个。
网页	html	从OBS导入：单个文件大小不超过50GB，文件数量不限制。 本地上传：单个文件大小不超过10M，文件数量最多100个。

文件内容	文件格式	文件要求
预训练文本	jsonl	- jsonl格式：text表示预训练所使用的文本数据，具体格式示例如下： <code>{"text": "盘古大模型，是华为推出的盘古系列AI大模型，包括NLP大模型、多模态大模型、CV大模型、科学计算大模型、预测大模型。"} </code> - 从OBS导入：单个文件大小不超过50GB，文件数量不限制。 本地上传：单个文件大小不超过10M，文件数量最多100个。
单轮问答	jsonl、csv	- jsonl格式：数据由问答对构成，context、target分别表示问题、答案，具体格式示例如下： <code>{"context": "你好，请介绍自己", "target": "我是盘古大模型"} </code> - csv格式：csv文件的第一列对应context，第二列对应target，具体格式示例如下： <code>"你好，请介绍自己","我是盘古大模型"</code> - 从OBS导入：单个文件大小不超过50GB，文件数量不限制。 本地上传：单个文件大小不超过10M，文件数量最多100个。
单轮问答（人设）	jsonl、csv	- jsonl格式：system表示人设，context、target分别表示问题、答案。 <code>{"system": "你是一个机智幽默问答助手", "context": "你好，请介绍自己", "target": "哈哈，你好呀，我是你的聪明助手。"} </code> - csv格式：csv文件的第一列对应system，第二三列分别对应context、target。 <code>"你是一个机智幽默问答助手","你好，请介绍自己","哈哈，你好呀，我是你的聪明助手。"</code> - 从OBS导入：单个文件大小不超过50GB，文件数量不限制。 本地上传：单个文件大小不超过10M，文件数量最多100个。
多轮问答	jsonl	- jsonl格式：数组格式，至少由一组问答对构成。形式为<code>[{"context": "context内容1", "target": "target内容1"}, {"context": "context内容2", "target": "target内容2"}]</code>，其中context、target分别表示问题、答案。 <code>[{"context": "你好", "target": "你好，请问有什么可以帮助你？"}, {"context": "请介绍一下华为云的产品。", "target": "华为云提供包括但不限于计算、存储、网络等产品服务。"}]</code> - 从OBS导入：单个文件大小不超过50GB，文件数量不限制。 本地上传：单个文件大小不超过10M，文件数量最多100个。



文件内容	文件格式	文件要求
多轮问答 (人设)	jsonl	- jsonl格式：数组格式，至少由一组问答对构成。system表示人设，context、target分别表示问题、答案。 [{"system":"你是一位书籍推荐专家"}, {"context":"你好", "target":"嗨！你好，需要点什么帮助吗？"}, {"context":"能给我推荐点书吗？", "target":"当然可以，基于你的兴趣，我推荐你阅读《自动驾驶的未来》。"}] - 从OBS导入：单个文件大小不超过50GB，文件数量不限制。 本地上传：单个文件大小不超过10M，文件数量最多100个。
问答排序	jsonl、csv	- jsonl格式：context表示问题，targets答案1、2、3表示答案的优劣顺序，最好的答案排在最前面。 { "context":"context内容", "targets":["回答1", "回答2", "回答3"] } - csv格式：csv文件的第一列对应context，其余列为答案。 "问题","回答1","回答2","回答3" - 从OBS导入：单个文件大小不超过50GB，文件数量不限制。 本地上传：单个文件大小不超过10M，文件数量最多100个。
偏好优化 DPO	jsonl	- jsonl格式：context表示问题，target表示期望的正确答案，bad_target表示不符合预期的错误答案。 单轮问答 { "context": ["你好，请介绍自己"], "target": "我是盘古大模型", "bad_target": "我不会回答" } 多轮问答 { "context": ["你好，请介绍自己", "我是盘古大模型", "请介绍一下有哪些产品。"], "target": "提供包括但不限于计算、存储、网络等产品服务。", "bad_target": "我不会回答" } - 从OBS导入：单个文件大小不超过50GB，文件数量不限制。 本地上传：单个文件大小不超过10M，文件数量最多100个。

文件内容	文件格式	文件要求
偏好优化 DPO（人 设）	jsonl	- jsonl格式：system表示人设，context表示问题，target表示期望的正确答案，bad_target表示不符合预期的错误答案。 带人设单轮 { "system": "你是一位机智幽默的问答助手", "context": ["你好，请介绍自己"], "target": "哈哈，你好呀，我是你的聪明助手，怎么帮到你？", "bad_target": "我不会回答"} 带人设多轮 { "system": "你是一位机智幽默的问答助手", "context": ["你好，请介绍自己", "哈哈，你好呀，我是你的聪明助手，怎么帮到你？", "请介绍一下有哪些产品。"], "target": "我们产品种类繁多，不仅涵盖计算、存储和网络，还有更多选择哦！", "bad_target": "我不会回答"} - 从OBS导入：单个文件大小不超过50GB，文件数量不限制。 本地上传：单个文件大小不超过10M，文件数量最多100个。


4.3.2 图片类数据集格式要求

ModelArts Studio大模型开发平台支持创建图片类数据集，创建时可导入多种形式的数
据，具体格式要求详见[表4-5](#)。

表 4-5 图片类数据集格式要求

文件内容	文件格式	文件要求
仅图片	tar、图片目录	● 图片：支持jpg、jpeg、png、bmp类型。  ● tar：tar包内图片支持jpg、jpeg、png、bmp图片类型。  ● 从OBS导入：单个压缩包大小不超过50GB(只支持tar类型的压缩包)，单个文件大小不超过50GB，文件数量不限制。 本地上传：单个压缩包大小不超过10M(只支持tar类型的压缩包)，单个文件大小不超过10M，文件数量最多100个

文件内容	文件格式	文件要求
图片+Caption	图片支持tar, Caption支持jsonl	● 图片：图片以tar包格式存储，可以多个tar包。tar包存储原始的图片，每张图片命名要求唯一（如abc.jpg）。图片支持jpg、jpeg、png、bmp格式。 ● jsonl：图片描述jsonl文件放在最外层目录，一个tar包对应一个jsonl文件，文件内容中每一行代表一段文本，形式为： <pre>{"image_name":"图片名称 (abc.jpg) ","tar_name":"tar包名称 (1.tar) ","caption":"图片对应的文本描述"}</pre> ● 从OBS导入：单个压缩包大小不超过50GB(只支持tar类型的压缩包)，单个文件大小不超过50GB，文件数量不限。 本地上传：单个压缩包大小不超过10M(只支持tar类型的压缩包)，单个文件大小不超过10M，文件数量最多100个。 
图片+QA对	图片支持tar, QA对支持jsonl	● 图片：图片以tar包格式存储，可以多个tar包。tar包存储原始的图片，每张图片命名要求唯一（如abc.jpg）。图片支持jpg、jpeg、png、bmp格式。 ● jsonl：图片描述jsonl文件放在最外层目录，一个tar包对应一个jsonl文件，文件内容中每一行代表一段文本，形式为： <pre>{"image_name":"图片名称 (abc.jpg) ","tar_name":"tar包名称 (1.tar) ","conversations":[{"question":"问题1","answer":"回答1"},{"question":"问题2","answer":"回答2"}]}</pre> ● 从OBS导入：单个压缩包大小不超过50GB(只支持tar类型的压缩包)，单个文件大小不超过50GB，文件数量不限。 本地上传：单个压缩包大小不超过10M(只支持tar类型的压缩包)，单个文件大小不超过10M，文件数量最多100个 

文件内容	文件格式	文件要求
物体检测	PASCAL VOC	- 由图片文件和对应的标注文件构成，标注文件需要满足PASCAL VOC文件格式。要求用户将标注对象和标注文件存储在同一目录，并且相互对应，如标注对象文件名为“IMG_2.jpg”，那么标注文件的文件名应为“IMG_2.xml” - 图片支持jpg、jpeg、png、bmp、tif、tiff格式，标注文件为xml格式，标注文件说明请参见物体检测数据集标注文件说明。 - 从OBS导入：单个文件大小不超过50GB，文件数量不限制。 
图像分类	图片+txt	- 由图片文件和对应的标注文件构成，要求用户将标注对象和标注文件存储在同一目录，并且相互对应。 - 图片支持jpg、jpeg、png、bmp、tif、tiff格式，标注文件为txt格式，标注文件说明请参见图像分类数据集标注文件说明。 - 从OBS导入：单个文件大小不超过50GB，文件数量不限制。 

文件内容	文件格式	文件要求
实例分割	图片+xml	- 文件存放方式要求满足万物分割/实例分割格式。 - 图片格式支持：jpg、jpeg、png、bmp，标注格式支持：xml - 基于PASCAL VOC矩形框格式进行标识，标注和图片同名并放在同一文件夹下。 - xml标注文件的详细说明请参见实例分割数据集标注文件说明。 - 从OBS导入：单个文件大小不超过50GB，文件数量不限制。 

物体检测数据集标注文件说明

该说明适用于[表4-5](#)中的物体检测标注文件格式。

物体检测数据集支持格式为ModelArts PASCAL VOC 1.0。

要求用户将标注对象和标注文件存储在同一目录，并且一一对应，如标注对象文件名为“IMG_20180919_114745.jpg”，那么标注文件的文件名应为“IMG_20180919_114745.xml”。

物体检测的标注文件需要满足PASCAL VOC格式，PASCAL VOC是一个公开的图像标注数据集，它提供了一个统一的XML格式来存储标注信息。PASCAL VOC文件格式包含图像目录、图像文件、图像尺寸、图像中目标信息等元素，详细格式说明请参见[表4-6](#)。

OBS文件上传示例：

```
dataset-import-example
├── IMG_20180919_114732.jpg
├── IMG_20180919_114732.xml
├── IMG_20180919_114745.jpg
├── IMG_20180919_114745.xml
├── IMG_20180919_114945.jpg
└── IMG_20180919_114945.xml
```

标注文件（.xml文件）示例：

```
<?xml version="1.0" encoding="UTF-8" standalone="no"?>
<annotation>
  <folder>NA</folder>
  <filename>bike_1_1593531469339.png</filename>
  <source>
    <database>Unknown</database>
```

```
</source>
<size>
  <width>554</width>
  <height>606</height>
  <depth>3</depth>
</size>
<segmented>0</segmented>
<object>
  <name>Dog</name>
  <pose>Unspecified</pose>
  <truncated>0</truncated>
  <difficult>0</difficult>
  <occluded>0</occluded>
  <bndbox>
    <xmin>279</xmin>
    <ymin>52</ymin>
    <xmax>474</xmax>
    <ymax>278</ymax>
  </bndbox>
</object>
<object>
  <name>Cat</name>
  <pose>Unspecified</pose>
  <truncated>0</truncated>
  <difficult>0</difficult>
  <occluded>0</occluded>
  <bndbox>
    <xmin>279</xmin>
    <ymin>198</ymin>
    <xmax>456</xmax>
    <ymax>421</ymax>
  </bndbox>
</object>
</annotation>
```

表 4-6 PASCAL VOC 格式说明

字段	是否必选	说明
folder	是	表示图像所在的目录名称。
filename	是	被标注文件的文件名。
size	是	表示图像的像素信息。 - width：必选字段，图像的宽度。 - height：必选字段，图像的高度。 - depth：必选字段，图像的通道数。
segmented	是	表示是否用于分割，取值为0或1。0表示没有分割标注，1表示有分割标注。

字段	是否必选	说明
object	是	目标对象信息，包括被标注物体的类别、姿态、是否被截断、是否识别困难以及边界框信息，多个物体标注会有多个object体。 • name：必选字段，标注内容的类别。 • pose：必选字段，标注内容的拍摄角度。 • truncated：必选字段，取值0或1，表示标注内容是否被截断（0表示被截断、1表示没有截断）。 • occluded：必选字段，取值0或1，表示标注内容是否被遮挡（0表示未遮挡、1表示遮挡） • difficult：必选字段，取值0或1，表示标注目标是否难以识别（0表示容易识别、1表示难易识别）。 • confidence：可选字段，标注目标的置信度，取值范围0-1之间，越接近1，表示标注越可信。 • bndbox：必选字段，标注框的类型，可选值请参见表4-7。

表 4-7 标注框类型描述

type	形状	标注信息
point	点	点的坐标。 <x>100<x> <y>100<y>
line	线	各点坐标。 <x1>100<x1> <y1>100<y1> <x2>200<x2> <y2>200<y2>
bndbox	矩形框	左上和右下两个点坐标。 <xmin>100<xmin> <ymin>100<ymin> <xmax>200<xmax> <ymax>200<ymax>

type	形状	标注信息
polygon	多边形	各点坐标。 <x1>100<x1> <y1>100<y1> <x2>200<x2> <y2>100<y2> <x3>250<x3> <y3>150<y3> <x4>200<x4> <y4>200<y4> <x5>100<x5> <y5>200<y5> <x6>50<x6> <y6>150<y6>
circle	圆形	圆心坐标和半径。 <cx>100<cx> <cy>100<cy> <r>50<r>

图像分类数据集标注文件说明

该说明适用于[表4-5](#)中的图片分类标注文件格式。

图像分类数据集支持格式为ModelArts image classification 1.0。

要求用户将标注对象和标注文件存储在同一目录，并且一一对应，标注文件txt中可以放单标签，也可以放多标签。

- 当目录下存在对应的txt文件时，以txt文件内容作为图像的标签。

示例如下所示，import-dir-1和import-dir-2为导入子目录。

```
dataset-import-example
├── import-dir-1
│   ├── 10.jpg
│   ├── 10.txt
│   ├── 11.jpg
│   ├── 11.txt
│   ├── 12.jpg
│   └── 12.txt
└── import-dir-2
    ├── 1.jpg
    ├── 1.txt
    ├── 2.jpg
    └── 2.txt
```

单标签的标签文件示例，如1.txt文件内容如下所示。

猫

多标签的标签文件示例，如2.txt文件内容如下所示。

猫
狗

异常检测数据集标注文件说明

该说明适用于表4-5中的异常检测标注文件格式。

要求用户将标注文件和图片存于同一文件夹。

- 当目录下存在对应的txt文件时，以txt文件内容作为正常或异常的标签。

示例如下所示：

```
dataset-import-example
├── IMG_20180919_114732.jpg
├── IMG_20180919_114732.txt
├── IMG_20180919_114745.jpg
└── IMG_20180919_114745.txt
```

异常标签的标签文件示例，如IMG_20180919_114732.txt文件内容如下所示。

```
abnormal
```

正常标签的标签文件示例，如IMG_20180919_114745.txt文件内容如下所示。

```
normal
```

姿态估计标注 json 文件说明

该说明适用于表4-5中的姿态估计标注文件格式。

姿态估计标注基于开源coco人物关键点标注格式对数据集进行标注，需包含annotations，train，val文件夹。annotations文件夹下用train.json和val.json记录训练集和验证集标注，train和val文件夹下保存具体的图片，示例如下所示：

```
├── annotations
│   ├── train.json
│   └── val.json
├── train
│   └── IMG_20180919_114745.jpg
└── val
    └── IMG_20180919_114945.jpg
```

具体的json标注文件具体示例：

```
{
  "images": [
    {
      "license": 2,
      "file_name": "000000000139.jpg",
      "coco_url": "",
      "height": 426,
      "width": 640,
      "date_captured": "2013-11-21 01:34:01",
      "flickr_url": "",
      "id": 139
    }
  ],
  "annotations": [
    {
      "num_keypoints": 15,
      "area": 2913.1104,
      "iscrowd": 0,
      "keypoints": [
        427,
        170,
        1,
        429,
        169,
        2,
        0,
        0,
        0,
        0,
        0,
        0,
        0,
        0,
        0
      ]
    }
  ]
}
```



```
0,
434,
168,
2,
0,
0,
0,
441,
177,
2,
446,
177,
2,
437,
200,
2,
430,
206,
2,
430,
220,
2,
420,
215,
2,
445,
226,
2,
452,
223,
2,
447,
260,
2,
454,
257,
2,
455,
290,
2,
459,
286,
2
],
"image_id": 139,
"bbox": [
  412.8,
  157.61,
  53.05,
  138.01
],
"category_id": 1,
"id": 230831
},
],
"categories": [
  {
    "supercategory": "person",
    "id": 1,
    "name": "person",
    "keypoints": [
      "nose",
      "left_eye",
      "right_eye",
      "left_ear",
      "right_ear",
      "left_shoulder",
      "right_shoulder",
      "left_elbow",
```

```
    "right_elbow",
    "left_wrist",
    "right_wrist",
    "left_hip",
    "right_hip",
    "left_knee",
    "right_knee",
    "left_ankle",
    "right_ankle"
  ],
  "skeleton": [
    [
      16,
      14
    ],
    [
      14,
      12
    ],
    [
      17,
      15
    ],
    [
      15,
      13
    ],
    [
      12,
      13
    ],
    [
      6,
      12
    ],
    [
      7,
      13
    ],
    [
      6,
      7
    ],
    [
      6,
      8
    ],
    [
      7,
      9
    ],
    [
      8,
      10
    ],
    [
      9,
      11
    ],
    [
      2,
      3
    ],
    [
      1,
      2
    ],
    [
      1,
```

```
      3
    ],
    [
      2,
      4
    ],
    [
      3,
      5
    ],
    [
      4,
      6
    ],
    [
      5,
      7
    ]
  ]
}
]
```

表 4-8 COCO 格式说明

字段	是否必选	说明
images	是	图片信息。
license	否	图像的许可证标识符。
file_name	是	图像的文件名。
coco_url	否	图像在COCO官方数据集中的URL。
height	是	图像的高度，以像素为单位。
width	是	图像的宽度，以像素为单位。
date_captured	否	图像捕获的日期和时间。
flickr_url	否	图像在Flickr网站上的URL。
id	是	图像的唯一标识符。
annotations	是	标注信息。
num_keypoints	是	标注的关键点数量。
area	是	边界框的面积，以像素平方为单位。
iscrowd	是	表示标注是否为复杂的群体场景（如拥挤的人群）。0表示不是拥挤场景，1表示是拥挤场景。
keypoints	是	标注的关键点坐标及其可见性，按顺序列出所有关键点，每个关键点用三个数值表示 [x, y, v]。x和y是关键点的像素坐标，v是可见性（0：不可见且不在图像中；1：不可见但在图像中；2：可见且在图像中）。

字段	是否必选	说明
image_id	是	与该标注相关联的图像的ID，必须与images字段中的id对应。
bbox	是	目标物体的边界框，用[x, y, width, height]表示，其中，x, y是边界框左上角的坐标，width和height是边界框的宽度和高度。
category_id	是	标注类别的ID，对于人体姿态估计，通常为1（表示person）。
id	是	标注的唯一标识符。
categories	是	标注类型信息。
supercategory	是	类别的上级分类，通常为person。
id	是	类别的唯一标识符，对于人体姿态估计，通常为1。
name	是	类别的名称，通常为person。
keypoints	是	关键点的名称列表，COCO格式中通常定义了17个关键点，如nose、left_eye、right_eye、left_ear、right_ear、left_shoulder、right_shoulder、left_elbow、right_elbow、left_wrist、right_wrist、left_hip、right_hip、left_knee、right_knee、left_ankle、right_ankle。
skeleton	是	定义骨架连接的列表，用于表示关键点之间的连接关系。每个连接用一对关键点索引表示，如 [1, 2]，表示鼻子（nose）到左眼（left_eye）的连线。

实例分割数据集标注文件说明

该说明适用于[表4-5](#)中的实例分割标注文件格式。

要求用户将标注对象和标注文件存储在同一个目录，并且一一对应，如标注对象文件名为“IMG_20180919_114745.jpg”，那么标注文件的文件名应为“IMG_20180919_114745.xml”。

实例分割的标注文件需要满足PASCAL VOC格式，PASCAL_VOC是一个公开的图像标注数据集，它提供了一个统一的XML格式来存储标注信息。PASCAL_VOC文件格式包含图像目录、图像文件、图像尺寸、图像中目标信息等元素，详细格式说明请参见[表4-9](#)。

OBS文件上传示例：

```
dataset-import-example
  IMG_20180919_114732.jpg
  IMG_20180919_114732.xml
```

IMG_20180919_114745.jpg
IMG_20180919_114745.xml

标注文件（.xml文件）示例：

```
<annotation>
<folder>NA</folder>
<filename>0001.jpg</filename>
<source>
  <database>Unknown</database>
</source>
<size>
  <width>2560</width>
  <height>1440</height>
  <depth>3</depth>
</size>
<segmented>1</segmented>
<mask_source></mask_source>
<object>
  <name>aggregate</name>
  <pose>Unspecified</pose>
  <truncated>0</truncated>
  <difficult>0</difficult>
  <mask_color>238,130,238</mask_color>
  <occluded>0</occluded>
  <polygon>
    <x1>657.0</x1>
    <y1>357.0</y1>
    <x2>645.0</x2>
    <y2>351.0</y2>
    <x3>624.0</x3>
    <y3>352.0</y3>
    <x4>616.0</x4>
    <y4>353.0</y4>
  </polygon>
</object>
</annotation>
```

表 4-9 PASCAL VOC 格式说明

字段	是否必选	说明
folder	是	表示图像所在的目录名称。
filename	是	被标注文件的文件名。
size	是	表示图像的像素信息。 - width：必选字段，图像的宽度。 - height：必选字段，图像的高度。 - depth：必选字段，图像的通道数。
segmented	是	表示是否用于分割，取值为0或1。0表示没有分割标注，1表示有分割标注。

字段	是否必选	说明
object	是	目标对象信息，包括被标注物体的类别、姿态、是否被截断、是否识别困难以及边界框信息，多个物体标注会有多个object体。 • name：必选字段，标注内容的类别。 • pose：必选字段，标注内容的拍摄角度。 • truncated：必选字段，取值0或1，表示标注内容是否被截断（0表示被截断、1表示没有截断）。 • occluded：必选字段，取值0或1，表示标注内容是否被遮挡（0表示未遮挡、1表示遮挡） • difficult：必选字段，取值0或1，表示标注目标是否难以识别（0表示容易识别、1表示难易识别）。 • confidence：可选字段，标注目标的置信度，取值范围0-1之间，越接近1，表示标注越可信。 • bndbox：必选字段，标注框的类型，可选值请参见表4-10。

表 4-10 标注框类型描述

type	形状	标注信息
point	点	点的坐标。 <x>100<x> <y>100<y>
line	线	各点坐标。 <x1>100<x1> <y1>100<y1> <x2>200<x2> <y2>200<y2>
bndbox	矩形框	左上和右下两个点坐标。 <xmin>100<xmin> <ymin>100<ymin> <xmax>200<xmax> <ymax>200<ymax>

type	形状	标注信息
polygon	多边形	各点坐标。 <x1>100<x1> <y1>100<y1> <x2>200<x2> <y2>100<y2> <x3>250<x3> <y3>150<y3> <x4>200<x4> <y4>200<y4> <x5>100<x5> <y5>200<y5> <x6>50<x6> <y6>150<y6>
circle	圆形	圆心坐标和半径。 <cx>100<cx> <cy>100<cy> <r>50<r>

4.3.3 视频类数据集格式要求

ModelArts Studio大模型开发平台支持创建视频类数据集，创建时可导入多种形式的
数据，具体格式要求详见[表4-11](#)。

表 4-11 视频类数据集格式要求

文件 内容	文件 格式	文件要求
视频	mp 4或 avi	- 支持mp4、avi视频格式上传，所有视频可以放在多个文件夹下，每个文件夹下可以同时包含mp4或avi格式的视频。 - 从OBS导入：单个文件大小不超过50GB，文件数量不限制。

文件内容	文件格式	文件要求
视频+标注	视频+json	data dir 001.mp4 002.mp4 003.avi annotation.jsonl

● 视频格式支持：mp4、avi

● 标注文件格式：jsonl，jsonl文件仅支持UTF-8编码。

示例如下所示：

具体的jsonl标注文件参考：

```
{  
  "video_fn": "13/ad098173-af09-48fe-95c3-e72fd629688e.mp4"视频相对路径，  
  "prompt": "A person pours a clear liquid from a bottle into a shot glass, then lifts the glass to their mouth and drinks the shot. The background includes a red coat and other indistinct background elements."视频摘要生成（简略），  
  "long_prompt": "A person is seen pouring a clear liquid from a green glass bottle into a small glass. The individual is wearing a white shirt with a lace collar and a beige cardigan. The background appears to be a cozy indoor setting, possibly a cafe or a restaurant, with red and white elements visible, such as a red coat hanging on the wall and a white table. The person carefully pours the liquid, ensuring it is filled to the brim of the glass. The liquid is clear and has some green leaves floating in it. The person then holds the glass up, possibly to show the contents or to prepare for a drink."视频摘要生成（详细）  
}
```


文件内容	文件格式	文件要求
事件检测	视频+json	数据源样本为avi、mp4格式，标注文件为json格式。必须包含两个及以上后缀名字为avi或者mp4的文件，视频与标注文件可以一对一，也可以多对一。 每个视频时长要大于128s，FPS>=10，且测试集训练集都要有视频。支持视频的格式包括常见的mp4/avi格式文件，每个视频时长要大于128s，FPS>=10，用annotation.json对文件进行标注。 从OBS导入：单个文件大小不超过50GB，文件数量不限制。 示例如下所示： 视频+json（多对一）  视频+json（一对一）  具体的json标注文件参考： <pre>{ 'version': 'dataset_name_v.x.x',// 数据集版本信息。 'classes': [category1',category2', ...]',// 所有类别名称的列表，每个类别对应一个 label， 用于标注视频中的事件或动作。 'database': { 'video_name':{ // 训练集 train 测试集 test。 'subset': 'train', 'duration': 1660.3, // 视频总时长 seconds。 'fps': 30.0,// 视频帧率。 'width': 720,// 视频宽度，单位像素。 'height': 1280,// 视频高度，单位像素。 'ext': 'mp4',//视频文件扩展名。 // 标注 34.5, 42.4 分别表示起始时间和结束时间，单位为s。 // label 表示分类，必须是classes列表中的一个元素，表示该视频片段对应的事件或 动作类型。 'annotations': [{'label': 'category1', 'segment': [34.5, 42.4]}, {'label': 'category1', 'segment': [124.4, 142.9]}, ...] } } }</pre>

文件内容	文件格式	文件要求
		<pre>}, 'video_name':{ 'subset': xxx,//视频文件名称，不包括扩展名。 'duration': xxx, 'fps': xxx, 'width': xxx, 'height': xxx, 'ext': xxx, 'annotations': [{'label': xxx, 'segment': xxx}, {'label': xxx, 'segment': xxx}, ...] }, ... }</pre>
视频分类	视频+txt	- 从OBS导入：单个文件大小不超过50GB，文件数量不限制。 - 视频格式支持：mp4、avi，标注文件格式：txt，视频与标注文件一一对应。 示例如下所示： 

4.3.4 音频类数据集格式要求

ModelArts Studio大模型开发平台支持创建音频类数据集，创建时可导入多种形式的
数据，具体格式要求详见[表4-12](#)

表 4-12 音频类数据集格式要求

文件内容	文件格式	文件要求
仅音频	音频	- 格式支持：mp3、flac、wav、opus、aac、m4a。所有音频可以放在多个文件夹下，每个文件夹下可以同时包含多种格式的音频。 - 从OBS导入：单个文件大小不超过50GB，文件数量不限制。

文件内容	文件格式	文件要求
音频+标注	音频+jsonl	• 音频格式支持：mp3、flac、wav、opus、aac、m4a。 标注文件格式：jsonl。 • 从OBS导入：单个文件大小不超过50GB，文件数量不限制。 示例如下所示： data dir 001.mp3 002.flac 003.wav annotation.jsonl 具体的jsonl标注文件参考： <pre>{ "audio_name": "dir/16k_16bit_1channel_2s.flac", "caption": "1" } { "audio_name": "dir/16k_16bit_1channel_2s.mp3", "caption": "2" } { "audio_name": "dir/16k_16bit_1channel_2s.opus", "caption": "3" } { "audio_name": "dir/16k_16bit_1channel_2s.wav", "caption": "4" }</pre>

4.3.5 气象类数据集格式要求

ModelArts Studio大模型开发平台支持导入气象类数据集，该数据集当前包括**海洋气象数据**。

海洋气象数据通常来源于气象再分析。气象再分析是通过现代气象模型和数据同化技术，重新处理历史观测数据，生成高质量的气象记录。这些数据既可以覆盖全球范围，也可以针对特定区域，旨在提供完整、一致且高精度的气象数据。

再分析数据为二进制格式，具体格式要求详见[表4-13](#)。

表 4-13 气象类数据集格式要求

文件内容	文件格式	文件样例
气象-天气数据	nc、cdf、netcdf、gr、gr1、grb、grib、grib1、grib2、gr2、grb2、grib2	- 从OBS导入：单个文件大小不超过50GB，文件数量不限制。 天气数据通常包含全球或区域性的气象变量，如温度（T）、气压（P）、风速（U、V）等。在文件中，这些变量可能按时间、地理范围和气压层次进行组织。示例如下： <pre>{ "geo_range": { "lat": [-90.0, 90.0], "lon": [0.0, 360.0] }, "time_range": [1640995200000, 1641164400000], "total_size": 7376211808, "surface_features": ["P", "T", "U", "V"], "upper_air_layers": ["1000hPa", "100hPa", "150hPa", "175hPa", "200hPa", "250hPa", "300hPa", "400hPa", "500hPa", "500hPa", "600hPa", "700hPa", "850hPa", "925hPa"], "upper_air_features": ["Q", "T", "U", "V", "Z"] }</pre> - geo_range：定义了数据覆盖的地理范围，纬度（lat）从-90.0到90.0，经度（lon）从0.0到360.0。 - time_range：数据的时间范围，时间戳格式为毫秒数。 - total_size：数据文件的总大小，单位为字节。 - surface_features：地表特征变量列表，例如气压（P）、温度（T）、风速（U、V）。 - upper_air_layers：高空气压层列表，例如1000hPa、100hPa等。 - upper_air_features：高空特征变量列表，例如湿度（Q）、温度（T）、风速（U、V）、高度（Z）。
气象-海洋数据	nc、cdf、netcdf、gr、gr1、grb、grib、grib1、grib2、gr2、grb2、grib2	- 从OBS导入：单个文件大小不超过50GB，文件数量不限制。 - 海洋数据通常包含全球或区域性的海洋变量，如温度（T）、气压（P）、风速（U、V）等，具体格式示例如下 <pre>{ "geo_range": { "lat": [-90.0, 90.0], "lon": [0.0, 360.0] }, "time_range": [1640995200000, 1641164400000], "total_size": 7376211808, "surface_features": ["SSH", "T", "P", "U", "V"], "under_sea_layers": ["0m", "6m", "10m", "20m", "30m", "50m", "70m", "100m", "125m", "150m", "200m", "250m", "300m", "400m", "500m"], "under_sea_features": ["T", "U", "V", "S"] }</pre> - geo_range：定义了数据覆盖的地理范围，纬度（lat）从-90.0到90.0，经度（lon）从0.0到360.0。 - time_range：数据的时间范围，时间戳格式为毫秒数。 - total_size：数据文件的总大小，单位为字节。 - surface_features：海表特征变量列表，例如海表高度（SSH）、温度（T）、风速（U、V）。 - under_sea_layers：深海层列表，例如500m、400mPa等。 - under_sea_features：深海特征变量列表，例如海盐（S）、温度（T）、海流速率（U、V）。

文件内容	文件格式	文件样例
气象-生态数据	nc、cdf、netcdf、gr、gr1、grb、grib、grb1、grib1、gr2、grb2、grib2	- 从OBS导入：单个文件大小不超过50GB，文件数量不限制。 生态数据通常包含总叶绿素浓度（Tca）、叶绿素浓度（Chl）、硅藻浓度（Dia）等生态变量。示例如下： <pre>{"geo_range": {"lat": ["-90.0", "90.0"], "lon": ["0.0", "360.0"]}, "time_range": ["1640995200000", "1641164400000"], "total_size": 7376211808, "surface_features": ["Tca", "Chl", "Dia", "Coc", "Cya", "Irn", "Nit", "MLD"]}</pre> - geo_range：定义了数据覆盖的地理范围，纬度（lat）从-90.0到90.0，经度（lon）从0.0到360.0。 - time_range：数据的时间范围，时间戳格式为毫秒数。 - total_size：数据文件的总大小，单位为字节。 - surface_features：生态特征列表，例如总叶绿素浓度（Tca）、叶绿素浓度（Chl）、硅藻浓度（Dia）。
气象-海浪数据	nc、cdf、netcdf、gr、gr1、grb、grib、grb1、grib1、gr2、grb2、grib2	- 从OBS导入：单个文件大小不超过50GB，文件数量不限制。 海浪数据通常包有效波高（SWH）。示例如下： <pre>{"geo_range": {"lat": ["-90.0", "90.0"], "lon": ["0.0", "360.0"]}, "time_range": ["1640995200000", "1641164400000"], "total_size": 7376211808, "surface_features": ["SWH"]}</pre> - geo_range：定义了数据覆盖的地理范围，纬度（lat）从-90.0到90.0，经度（lon）从0.0到360.0。 - time_range：数据的时间范围，时间戳格式为毫秒数。 - total_size：数据文件的总大小，单位为字节。 - surface_features：海浪特征：有效波高（SWH）。

4.3.6 其他类数据集格式要求

除文本、图片、视频、气象、预测类数据集外，平台还支持导入其他类数据集，即用户训练模型时使用的自定义数据集。

其他类数据集支持[加工其他类数据集](#)与[发布其他类数据集](#)操作。

从OBS导入：单个文件大小不超过50GB，文件数量不限制。

本地上传：单个文件大小不超过10M，文件数量最多100个。

4.4 导入数据至盘古平台

数据集是一组用于处理和分析的相关数据样本。

用户将存储在OBS服务中的数据或本地数据导入至ModelArts Studio大模型开发平台后，将生成“原始数据集”被平台统一管理，用于后续加工或发布操作。

创建导入任务


创建导入任务前，请先按照[数据集格式要求](#)提前准备数据。

平台支持使用OBS服务导入数据，请详见[通过控制台快速使用OBS](#)。

创建导入任务步骤如下：


1. 登录ModelArts Studio大模型开发平台，在“我的空间”模块，单击空间名称进入操作空间。

图 4-2 我的空间




2. 在左侧导航栏中选择“数据工程 > 数据获取 > 导入任务”，单击界面右上角“创建导入任务”。
3. 在“创建导入任务”页面，选择“数据集类型”、“文件格式”和“导入来源”。
4. 导入来源选择“OBS”，单击“”，在“存储位置”弹窗中选择需导入的数据，单击“确定”。

图 4-3 选择导入的数据



导入来源可选择“本地上传”，单击“添加文件”，选择需要导入的文件。

图2 本地上传



5. 填写“数据集名称”和“描述”，可选择填写“扩展信息”。
扩展信息包括“数据集属性”与“数据集版权”：
 - 数据集属性。可以给数据集添加行业、语言和自定义信息。
 - 数据集版权。训练模型的数据集除用户自行构建外，也可能会使用开源的数据集。数据集版权功能主要用于记录和管理数据集的版权信息，确保数据的使用合法合规，并清晰地了解数据集的来源和相关的版权授权。通过填写这些信息，可以追溯数据的来源，明确数据使用的限制和许可，从而保护数据版权并避免版权纠纷。
6. 单击页面右下角“立即创建”，回退至“导入任务”页面，在该页面可以查看数据集的任务状态，若状态为“运行成功”，则数据导入成功。
7. 导入后的数据集可在“数据工程 > 数据管理 > 数据集 > 原始数据集”中查看。

📖 说明

如果任务状态为“运行失败”，可能由以下原因导致：

- 文件后缀校验不通过，需要检查文件后缀是否一致。例如，选择创建csv格式的数据集时，文件后缀应为“.csv”。
- 文件内容校验不通过，需要检查上传的文件数据格式是否正确。可以在“创建导入任务”页面下载数据样例进行比对。

管理原始数据集

数据导入成功后，可对原始数据集进行统一管理，支持的操作如下：查看数据集的基本信息、数据血缘、操作记录以及对下载、删除数据集等操作。

1. 登录ModelArts Studio大模型开发平台，单击进入操作空间。
2. 在左侧导航栏中选择“数据工程 > 数据管理 > 数据集 > 原始数据集”，单击需要查看的数据集名称。
 - 查看数据集基本信息。在“基本信息”页签，可以查看数据详情、数据来源以及扩展信息。
 - 在拓展信息内，可以根据用户需求设置数据集属性，包括数据集属性名称、行业、语言、自定义标签。
 - 下载原始数据集。在“数据预览”页签，可以查看数据内容，单击右上角“下载”即可下载原始数据集。
 - 查看数据血缘。在“数据血缘”页签，可以查看当前数据集所经历的完整操作，如加工、标注等。
 - 查看操作记录。在“操作记录”页签，可以查看当前数据集的操作记录，如创建该数据集的时间、状态、操作人员等。

3. 删除原始数据集。单击操作列的“删除”，并在弹窗中单击“确定”。

说明

删除“原始数据集”属于高危操作，删除前，请确保该数据集不再使用。

4.5 加工数据集

4.5.1 数据集加工场景介绍

数据加工介绍

ModelArts Studio大模型开发平台提供数据加工功能，涵盖了数据加工、数据合成和数据标注关键操作，旨在确保原始数据符合业务需求和模型训练的标准，是数据工程中的核心环节。

- **数据加工**

通过专用的加工算子对数据进行预处理，确保数据符合模型训练的标准和业务需求。不同类型的数据集使用专门设计的算子，例如去除噪声、冗余信息等，提升数据质量。此外，用户还可以创建自定义算子，针对特定业务场景和模型需求，灵活地进行数据加工，从而进一步优化数据处理流程，提高模型的准确性和鲁棒性。

- **数据合成**

利用预置或自定义的数据指令对原始数据进行处理，并根据设定的轮数生成新数据。该过程能够在一定程度上扩展数据集，增强训练模型的多样性和泛化能力。

- **数据标注**

为无标签数据集添加准确的标签，确保模型训练所需的高质量数据。平台支持人工标注和AI预标注两种方式，用户可根据需求选择合适的标注方式。数据标注的质量直接影响模型的训练效果和精度。

- **数据配比**

数据配比是将多个数据集按特定比例组合为一个加工数据集的过程。通过合理的配比，确保数据集的多样性、平衡性和代表性，避免因数据分布不均而引发的问题。

通过这些数据加工操作，平台能够有效清理噪声数据、标准化数据格式，并优化数据集的整体质量。数据加工不仅仅是简单的数据处理，它还会根据数据类型和业务场景进行有针对性的优化，从而为模型训练提供高质量的输入，提升模型的表现。

数据加工意义

数据加工在大模型开发中具有至关重要的作用，具体体现在以下几个方面：

- **提高数据质量**

原始数据往往包含噪声、缺失值或不一致性，这会直接影响模型训练效果。通过数据加工操作，可以有效去除无效信息、填补缺失数据，确保数据的准确性与一致性，从而提高数据质量，为模型训练提供可靠的输入。

- **扩展数据集的多样性和泛化能力**

在数据量不足或样本不平衡的情况下，数据合成可以生成新数据，扩展数据集的规模和多样性。通过增加数据的多样性，能够提升模型在各种场景下的泛化能力，增强其对未知数据的适应性。

- 增强模型训练的有效性**

高质量的数据是训练好模型的基础。数据加工不仅仅是对数据的简单处理，更是根据不同数据类型和业务需求进行有针对性的优化，使数据更符合训练标准，提高训练效率和精度。
- 确保业务需求对接**

不同业务场景和模型应用对数据有不同的要求。数据加工能够根据特定业务需求进行定制化处理，确保数据满足应用场景的需求，从而提高数据和模型的匹配度，提升业务决策和模型预测的准确性。
- 提升数据处理效率**

通过平台提供的自动化加工功能，用户可以高效完成大规模数据的预处理工作，减少人工干预，提升数据处理的一致性和效率，确保整个数据工程流程的顺畅运行。
- 确保数据质量和适配性**

通过数据配比，确保数据集满足大模型训练的高标准。这不仅包括数据规模的要求，还涵盖了数据质量、平衡性和代表性的保证，避免数据不均衡或不具备足够多样性的情况，进而提高模型的准确性和鲁棒性。
- 提高数据的多样性和代表性**

通过合理的数据配比，帮助用户按特定比例组合多个数据集，确保数据集在不同任务场景下的多样性和代表性。这样可以避免过度偏向某一类数据，保证模型能够学习到多种特征，提升对各种情况的适应能力。

总体而言，数据加工不仅提升了数据处理的效率，还可通过优化数据质量和针对性处理，支持高效的模型训练。通过数据加工，用户能够快速构建高质量的数据集，推动大模型的成功开发。

支持数据加工的数据集类型

当前支持数据加工操作的数据集类型见[表4-14](#)。

表 4-14 支持数据加工操作的数据集类型

数据集模态	数据集类型	数据加工	数据合成	数据标注	数据配比
文本类	文档	√	-	-	√
	网页	√	-	-	√
	预训练文本	√	√	-	√
	单轮问答	√	√	√	√
	单轮问答+人设	√	√	√	√
	多轮问答	√	-	√	√
	多轮问答+人设	√	-	√	√
	问答排序	√	-	√	√
	偏好优化DPO	-	-	-	√

数据集模态	数据集类型	数据加工	数据合成	数据标注	数据配比
	偏好优化DPO +人设	-	-	-	√
图片类	仅图片	√	-	√	√
	图片+Caption	√	-	√	√
	图片+QA对	√	-	√	√
	物体检测	-	-	-	-
	图像分类	-	-	-	-
	异常检测	-	-	-	-
	语义分割	-	-	-	-
	姿态估计	-	-	-	-
	实例分割	-	-	-	-
	变化检测	-	-	-	-
视频类	视频	√	-	√	-
	视频+标注	-	-	-	-
	视频理解	√	-	√	-
	事件检测	-	-	-	-
	视频分类	-	-	-	-
音频类	仅音频	√	-	√	-
	音频+标注	-	-	-	-
气象类	气象数据	√	-	-	-
预测类	时序（分类）	-	-	-	√
	时序（回归）	-	-	-	-
	结构化（分类）	-	-	-	√
	结构化（回归）	-	-	-	-
其他类	其他类	√（仅可使用自定义算子进行数据加工）	-	-	-

4.5.2 加工文本类数据集


4.5.2.1 加工文本类数据集

加工文本类数据集任务前，请先完成数据导入操作，具体步骤请参见[导入数据至盘古平台](#)。

创建文本类数据集加工任务步骤如下：

1. 登录ModelArts Studio大模型开发平台，在“我的空间”模块，单击进入所需空间。

图 4-4 我的空间




2. 在左侧导航栏中选择“数据工程 > 数据加工 > 加工任务”，单击界面右上角“创建加工任务”。
3. 在“创建加工任务”页面，选择需要加工的文本类数据集，单击“下一步”。
4. 进入“加工步骤编排”页面。对于文本类数据集，可选择的加工算子请参见[文本类加工算子介绍](#)。

a. 在左侧“添加算子”分页勾选所需算子。根据实际场景，可以选择一个或多个。
平台支持选择预置算子或自定义算子，如果使用自定义算子，创建步骤见[自定义数据集加工算子](#)。

b. 在右侧“加工步骤编排”页面配置各算子参数，可拖动右侧“⋮”以调整算子执行顺序。

图 4-5 算子编排



- c. 在编排过程中，可单击右上角“保存为新模板”将当前编排流程保存为模板。后续创建新的数据加工任务时，可直接单击“选择加工模板”进行使用。
- 若选择使用加工模板，将删除当前已编排的加工步骤。

图 4-6 选择加工模板



5. 加工步骤编排完成后，单击“下一步”进入“任务配置界面”。
- 资源配置
- 单击展开资源配置，可以设置任务资源。也支持自定义参数配置，单击“添加参数”，输入参数名称和参数值。

表 4-15 参数配置

参数名称	参数说明
numExecutors	Executor的数量，默认值2。Executor是运行在工作节点上的进程，它负责执行具体的task任务，并将计算结果返回给Driver。每个Executor每个核同时能跑一个task任务，所以增加了Executor的个数相当于增大了任务的并发度。在资源充足的情况下，可以相应增加Executor的个数，以提高运行效率。 numExecutors * executorMemory最小值为4，最大值为16。
executorCores	每个Executor进程使用的CPU内核数量，默认值2。每个Executor多个核同时能跑多个task任务，相当于增大了任务的并发度。但是由于所有核共用Executor的内存，所以要在内存和核数之间做好平衡。 numExecutors * executorMemory最小值为4，最大值为16。executorCores和executorMemory的比例需要在1:2~1:4之间。

参数名称	参数说明
executorMemory	每个Executor进程使用的内存数量，默认值4。 Executor的内存主要用于任务执行、通信等。当一个任务很大的时候，可能需要较多资源，因而内存也可以做相应的增加；当一个任务较小运行较快时，就可以增大并发度减少内存。 executorCores和executorMemory的比例需要在1:2~1:4之间。
driverCores	驱动程序进程使用的CPU内核数量，默认值2。 Driver负责任务的调度，和Executor之间的消息通信。 driverCores和driverMemory的比例需要在1:2~1:4之间。
driverMemory	驱动程序进程使用的内存数量，默认值4。Driver负责任务的调度，和Executor之间的消息通信。当任务数变多，任务平行度增大时，Driver内存都需要相应增大。 driverCores和driverMemory的比例需要在1:2~1:4之间。

图 4-7 资源配置

资源配置

参数配置

numExecutors
- 2 + 个

driverCores
- 2 + 个

自定义参数配置
+ 添加参数
您最多可以添加 10 个参数

executorCores
- 2 + 个

driverMemory
- 4 + GB

executorMemory
- 4 + GB

- 自动生成加工数据集
- 勾选，配置生成加工数据集的信息，如图4-8；单击右下角“确定”，平台将启动配比任务。配比任务运行成功后自动生成加工数据集。
- 不勾选，单击右下角“确定”，平台将启动配比任务。配比任务运行成功后手动生成加工数据集。

图 4-8 自动生成加工数据集

☒ 自动生成加工数据集

启用后任务运行成功自动生成加工数据集，可用于下游数据集发布；如关闭需在加工任务列表操作生成

数据集名称


描述

请输入

0/100

- 扩展信息（可选）
可选择行业、语言信息，或自定义数据集属性。

图 4-9 扩展信息



6. 单击“启动加工”。当数据加工任务运行成功后，状态将从“运行中”变为“运行成功”，表示数据已经完成加工。

说明

- 在完成数据加工后，如果无需使用数据标注、数据合成功能，可直接在“加工任务”页面单击操作列“生成”，生成加工数据集。
- 加工后的数据集可在“数据工程 > 数据管理 > 数据集 > 加工数据集”中查看。

4.5.2.2 合成文本类数据集

数据合成是利用预置或自定义的数据指令对原始数据集进行处理，并根据设定的轮数生成新的数据。

当前，数据合成功能支持合成单轮问答、单轮问答（人设）、问答排序、偏好优化DPO、偏好优化DPO（人设）类型的数据。


创建文本类数据集合成任务

合成文本类数据集任务前，请先完成数据导入操作，具体步骤请参见[导入数据至盘古平台](#)。

创建文本类数据集合成任务步骤如下：

1. 登录ModelArts Studio大模型开发平台，在“我的空间”模块，单击进入所需空间。


图 4-10 我的空间



2. 在左侧导航栏中选择“数据工程 > 数据加工 > 合成任务”，单击界面右上角“创建合成任务”。

3. 在“创建合成任务”页面，选择需要合成的数据集，选择合成内容与预期合成条数，如图4-11，系统指定预期合成条数则为数据集初始数据条数。

图 4-11 创建合成任务预期合成数据条数配置



如果合成前的数据集类型与合成后的数据集类型相同，可选择开启“将源数据集整合至合成后数据”，在合成任务运行完成后，将生成的数据与原始数据集合并，单击“下一步”。

4. 进入“合成编排”页面，完成合成步骤编排。
- 在左侧“添加指令”页面可选择预置指令或自定义指令，支持指令复制。
 - 预置指令。平台为用户提供了多种预置指令，便于用户执行合成任务，请详见[预置数据指令介绍](#)。
 - 自定义指令。平台支持编排用户自定义指令。自定义指令的创建详见[创建自定义数据合成指令](#)。

- 指令选择完成后，单击“确定”，并配置指令参数。

如图4-12，展示了预训练文本类数据集的合成指令参数配置示例，该合成任务实现利用预训练文本生成问答对。

图 4-12 预训练文本类数据集合成指令参数配置示例

合成步骤编排(2)

1

根据文本生成问题

根据用户输入的上下文，生一个问题。可用于文本生成QA对的合成编排

模型

预置服务 /

配置超参

指令

该指令为预置指令，无需编辑

输入变量

text 参考文本

数据选择 自定义 context

输出变量

question 生成的问题

2

根据文本生成回答

根据用户输入的上下文和问题，生成相应回答。可实现事实遵从的合成

模型

预置服务 /

配置超参

指令

该指令为预置指令，无需编辑

输入变量

text 参考资料

数据选择 自定义 context

question 用户问题

数据选择 自定义 question

输出变量

answer 回答

结束

合成后：单轮问答数据，数据内容key值为 context target

context 问题

target 回答

question (指令1)

answer (指令2)

说明：请从开始和指令产生的结果中，选择最终的目标数据变量，并与该变量变量匹配

- 指令编排完成后，单击右上角“启用调测”，可以对当前编排的指令效果进行预览。
- 5. 指令调测完成后，单击右下角“下一步”，进入“任务配置”页面。
 - 选择是否勾选自动生成加工数据集。
勾选，配置生成加工数据集的信息，如图2 自动生成加工数据集；单击右下角“创建并启动”，平台将启动合成任务。合成任务运行成功后自动生成加工数据集。

不勾选，单击右下角“创建并启动”，平台将启动合成任务。合成任务运行成功后手动生成加工数据集。

图 4-13 自动生成加工数据集

☒ 自动生成加工数据集

启用后任务运行成功自动生成加工数据集，可用于下游数据集发布；如关闭需在加工任务列表操作生成

数据集名称

描述

请输入

0/100

- 填写数据集名称、描述和扩展信息（扩展信息为可选项，主要包括行业、语言和自定义信息）。

6. 当数据合成任务运行成功后，状态将从“运行中”变为“运行成功”，表示数据已经完成合成操作。

说明

在完成数据合成后，若无需使用数据标注、数据配比功能，可直接在“合成任务”页面单击操作列“生成”，生成加工数据集。
生成的加工数据集可在“数据工程 > 数据管理 > 数据集 > 加工数据集”中查看。

预置数据指令介绍

ModelArts Studio平台的数据合成功能为用户提供了预置指令，用户可以在“数据工程 > 数据加工 > 合成任务 > 管理合成指令 > 系统预置”查看指令详情，如图4-14，单击“调测”可查看调测指南，如图4-15，帮助用户更好地使用该指令。
预置的数据指令清单详见表4-16。

图 4-14 指令详情

指令详情

?

基于提问生成作答要求 预置 | 生成问题

调测

该指令根据输入的问题，使大模型泛化一个相应问题的作答要求，该要求与原问题内容不直接相关。该指令可根据作答要求回答问题的指令进行编排，实...

变量信息

输入变量

变量名称	变量类型	变量描述
question	string	问题

输出变量

变量名称	变量类型	变量描述
newInstruct	string	生成的作答要求

图 4-15 调测指南



表 4-16 预置数据指令清单

指令分类	指令名称	指令描述
生成问题	问题改写为更低难度	该指令可以通过用户输入的问题，使大模型按要求生成一个难度更低、更为简单的问题。
	问题改写为更高难度	该指令通过用户输入的问题，使大模型按要求生成一个难度更高、更为复杂的问题。
	基于提问生成作答要求	该指令根据输入的问题，使大模型泛化一个相应问题的作答要求，该要求与原问题内容不直接相关。该指令可与根据作答要求回答问题的指令进行编排，实现风格多样回答的合成。
	根据样例生成相似问题_few-shot	该指令通过用户输入的多个问题样例，生成一个或多个与样例风格相匹配的新问题。
	根据文本生成问题	根据用户输入的上下文，生一个问题。可用于文本生成QA对的合成编排
	问题改写	改写问题，生成更复杂的问题，可用于指令泛化
生成回答	回答改写	根据用户指定人设，改写回答的风格，不改变回答内容。可与人设泛化指令编排，实现问答对泛化

指令分类	指令名称	指令描述
	根据文本生成回答_遵循要求	根据用户指定的指令要求和问题，根据输入的上下文生成相应回答。可与指令泛化进行编排，实现事实遵循类问答对泛化
	问题生成回答	根据提问，生成回答
	根据文本生成回答_扮演指定人设	根据用户指定的人设和问题，根据输入的上下文生成相应回答。可与人设泛化指令编排，实现事实遵循类问答对泛化。
	问题生成回答_扮演指定人设	根据用户指定的人设和问题，生成相应回答。可与人设泛化指令编排，实现问答对泛化。
	根据文本生成回答	根据用户输入的上下文和问题，生成相应回答。可实现事实遵从的合成
生成问答对	文本生成问答对_判断题	该指令能够从用户提供的参考文本中构建出一个判断题，同时给出其正确回答。
	文本生成问答对_填空题	该指令能够从用户提供的参考文本中构建出一个填空题，同时给出其正确回答。
	文本生成问答对_单选题	该指令能够从用户提供的参考文本中构建出一个包含四个选项的单选题，同时给出其正确回答
	文本生成问答对_多选题	该指令能够从用户提供的参考文本中构建出一个包含四个选项的多选题，同时给出其正确回答。
	文本生成问答对_问答题	该指令能够从用户提供的参考文本中构建出一个问题，同时给出其相应回答。
	根据文本抽取问答对_金融场景	根据用户输入的金融类文档进行问答对的抽取。
生成人设	根据问题生成人设	根据用户输入的问题生成一个人物设定。
其他	BadCase问题泛化	该指令通过用户提供的badcase问题和回答，利用大模型生成在类似情景下可能犯错的攻击性问题。用户可指定生成的攻击性问题个数，个数不超过10。
	根据答案推导解题思路	指令通过用户输入的问题和回答，利用大模型生成包含相应解题思路的回答。
	指令泛化	根据用户指定风格，进行指令泛化。可与指定要求类的问答对生成相关指令编排，实现问答对泛化


创建自定义数据合成指令

平台支持用户创建自定义数据合成指令。

本章节将以“生成主题散文”的场景为例，详细介绍自定义数据合成指令的配置步骤。

1. 登录ModelArts Studio大模型开发平台，在“我的空间”模块，单击进入所需空间。

图 4-16 我的空间



2. 在左侧导航栏中选择“数据工程 > 数据加工 > 合成任务 > 管理合成指令”，在“自定义”页签，单击“创建指令”。
3. 在“创建指令”弹窗中，输入名称与描述，单击“确定”，进入配置合成指令页面。
4. 选择变量标识符为“双大括号{{}}”，输入指令为“请以{{topic}}为主题，写一篇字数不超过{{num}}的散文。”单击“识别”，再单击“确定”。

图 4-17 配置指令

指令

请在文本指令中输入变量识别符。将变量填写在变量识别符中，点击识别即可识别新增变量。
变量样例：{{question}}

变量识别符

双大括号{{}}

指令内容

请以{{topic}}为主题，写一篇字数不超过{{num}}的散文。

5. 按照表4-17进行变量配置。

表 4-17 数据指令变量配置

变量类型	变量名称	变量类型	变量描述
输入变量	topic	string	主题
	num	string	字数
输出变量	output	string	散文

其中，输出变量的“变量描述”字段为大模型理解的内容，需仔细填写。

图 4-18 配置变量

输入变量

添加变量需要填写变量于指令中并点击识别。

变量名称	变量类型 ?	变量描述 (可选)
topic	string (字符串)	主题
num	string (字符串)	字数

输出变量

变量名称	变量类型 ?	变量描述 ?	
output	string (字符串)	散文	删除

+ 添加变量

6. 调测数据指令。
- 在“调试 > 模型”中，选择指令所需的模型，单击“配置超参”可自定义设定超参数值。

- 在“调试 > 输入”中，可通过给变量赋值来查看效果。

图 4-19 指令调测

^ 输入

topic 主题

秋天2/1,000

num 字数

1003/1,000

生成结果

生成



output 散文

秋风起，叶舞黄金地。霜降时，收获满盈怀。夕阳下，稻香飘万里。静谧中，思绪随秋去。

7. 调试完成后，单击“立即创建”，创建该数据指令。
- 成功创建的数据指令将在“管理合成指令 > 自定义”页面中展示。

4.5.2.3 标注文本类数据集

创建文本类数据集标注任务

标注文本类数据集任务前，请先完成数据导入操作，具体步骤请参见[导入数据至盘古平台](#)。

数据标注功能支持创建标注任务、标注数据集（标注作业）、审核标注后的数据集（审核作业）与管理标注任务（任务管理）。其中，不同角色权限支持的功能及展示的前端界面略有差异，详见[表4-18](#)。


表 4-18 不同角色支持的数据标注任务权限清单

角色名称	创建标注任务	标注作业任务	审核作业任务	任务管理任务
超级管理员	√	√	-	√
管理员	√	√	-	√
标注管理员	√	√	-	√
标注作业员	-	√	-	-
标注审核员	-	-	√	-

创建文本类数据集标注任务步骤如下：

1. 登录ModelArts Studio大模型开发平台，在“我的空间”模块，单击进入所需空间。

图 4-20 我的空间



2. 在左侧导航栏中选择“数据工程 > 数据加工 > 标注任务”，单击页面右上角“创建标注任务”。


3. 在“创建标注任务”页面选择需要标注的文本类数据集，并选择标注项。选择标注项时，不同类型的数据文件对应的标注项有所差异，可基于页面提示进行选择。
- 其中，“单轮问答”标注项支持“AI辅助标注”功能，若开启该功能，需要选择已部署的NLP服务作为AI辅助标注模型。
4. 可选择开启“多人作业”功能，开启后，可选择多人协同完成作业，并增加审核功能可供选择。参考[表4-19](#)配置标注分配与审核。

表 4-19 标注分配与审核配置

参数类型	参数名称	参数说明
标注分配	标注员	添加标注人员与数量。
标注审核	是否审核	- 否，标注后不进行审核操作。 - 是，审核员会检查标注员的标注内容，若发现问题，审核员可注明原因并驳回标注数据，标注员需重新标注。
	审核员	添加审核人员与数量。
	审核要求	- 全部审核：要求审核员对全部数据，逐条进行人工审核，才能完成审核任务。 - 可部分审核：审核员在审核一部分数据后，发现标注质量均很高，则可以一键提交剩余待审核数据，默认审核通过，即可完成审核任务。

5. 配置完成后，单击“完成创建”。
6. 在“标注任务”页面，单击当前标注任务操作列的“作业”，可执行标注作业任务。
- 其中，对于“标注作业员”角色，可单击“标注”执行标注作业任务。
- 如果需要将该标注任务移交给其他人员，可以单击“移交”，并设置移交人员以及移交数量，单击“确定”。
7. 进入标注页面后，逐一对数据进行标注。
- 如[图4-21](#)，以标注单轮问答数据为例，需要逐一确认问题（Q）及答案（A）是否正确，如果问题或答案不正确，可以对其进行二次编辑。

图 4-21 文本类数据集标注示例



8. 一条数据标注完成后，单击“提交”可继续标注剩余数据。所有数据标注完成后，页面会出现标注任务成功的提示。

说明

在完成数据标注后，如果无需进行标注审核，可直接在“标注任务 > 任务管理”页签单击“生成”，生成加工数据集。

生成的加工数据集可在“数据工程 > 数据管理 > 数据集 > 加工数据集”中查看。

AI 辅助功能介绍

标注任务中，标注员对单条数据可选择地执行标注数据的智能生成，具体操作如下。


- 步骤1** 在“创建标注任务”页面，选择数据集、开启AI辅助并选择模型后单击“完成创建”。

图 4-22 AI 辅助功能




步骤2 在“标注任务”页面，单击任务名称对应操作列的“作业”，可进入标注界面。

图 4-23 标注任务




步骤3 单击“设置”按钮，修改AI标注模型后单击“确定”。

图 4-24 设置




步骤4 单击“重新生成”，生成新的答案。

图 4-25 重新生成



步骤5 单击“一键应用”，重新生成的内容将会被显示在答案框里。

图 4-26 一键应用



----结束

审核标注后的文本类数据集

如果在[创建文本类数据集标注任务](#)时启用了标注审核功能，则在完成标注后可以审核标注结果。对于审核不合格的数据可以填写不合格原因并驳回给标注员重新标注。

该操作需要具备[标注审核员](#)角色权限。

审核文本类数据集标注结果的步骤如下：

1. 登录ModelArts Studio平台，在“我的空间”模块，单击进入所需空间。

图 4-27 我的空间



2. 在左侧导航栏中选择“数据工程 > 数据加工 > 标注任务”。
3. 单击“审核”可进入审核页面审核数据。
如果需要将该审核任务移交给其他人员，可以单击“移交”，并设置移交人员以及移交数量，单击“确定”。
4. 进入审核页面后，可通过单击“通过”或“不通过”逐一对数据进行审核，直至所有数据审核完成。

说明

在完成数据标注审核后，需在“数据工程 > 标注任务”页面单击“生成”，生成加工数据集。
生成后的加工数据集可在“数据工程 > 数据管理 > 数据集 > 加工数据集”中查看。

管理标注后的文本类数据集

平台支持超级管理员、管理员、标注管理员对标注的数据集进行如下操作：

- 生成：在完成数据标注审核后，需超级管理员、管理员、标注管理员角色在“标注任务”页面的操作列单击“生成”，生成加工数据集。
生成后的加工数据集可在“数据工程 > 数据管理 > 数据集 > 加工数据集”中查看。
- 结束：管理员角色可在“标注任务”页面的操作列单击“更多 > 结束”，结束当前标注任务。
- 编辑：如果该标注任务支持“AI辅助标注”和“审核”功能，管理员角色可在“标注任务”页面的操作列单击“更多 > 编辑”，选择是否开启“AI辅助标注”功能并选择“审核要求”。
- 删除：管理员角色可在“标注任务”页面的操作列单击“更多 > 删除”，删除当前标注任务。

4.5.2.4 配比文本类数据集

数据配比是将多个数据集按照特定比例关系组合并发布为“发布数据集”的过程，确保数据的多样性、平衡性和代表性。

如果单个数据集已满足您的需求，可跳过此章节至[发布文本类数据集](#)。

创建文本类数据集配比任务

创建文本类数据集配比任务步骤如下：

- 登录ModelArts Studio大模型开发平台，在“我的空间”模块，单击进入所需空间。

图 4-28 我的空间



- 在左侧导航栏中选择“数据工程 > 数据加工 > 配比任务”，单击界面右上角“创建配比任务”。

3. 在“数据集模态”页签选择需要做数据配比的对应数据集模态，支持文本、图片、预测类数据集做数据配比任务，如图2 数据集模态所示。

图 4-29 数据集模态



4. 在“选择数据集”页签选择需要配比的文本类数据集（至少选择两个），单击“下一步”。
5. 在“数据配比”页面，支持两种配比方式，“按数据集”和“按标签”。
- 按数据集：可以设置不同数据集的配比数量，如图4-30输入待配比数据集配比条数。

图 4-30 按“数据集”方式配比填写示例

数据配比					
配比方式					
按数据集 按标签					
从所选的 2 个数据集，通过配比生成一个新的加工数据集					
数据集名称	数据集状态	数据集大小	记录数	配比数量(条)	配比比例
prbc_20250611_83262	加工数据集	4MB	1,048	1,048	97.76%
预训练-001	原始数据集	763KB	24	24	2.24%
总加工数据集				1,072	100%

- 按标签：该场景适用于通过数据打标类加工算子进行加工的文本类数据集，具体标签名称与标签值可在完成加工文本类数据集操作后，进入数据集详情页面获取。
- 填写示例如图4-31所示。

图 4-31 “按标签”配比方式填写示例

配比方式

按数据集

按标签

根据每条记录中的标签信息，进行数据筛选。标签键和标签值可从原始、加工数据集预览界面的标签信息获得。


编号	标签名称	数值/字符串类	标签值
1	pre_classification	in	教育,健康

6. 数据配比完成后，单击右下角“下一步”，进入资源配置，并选择是否勾选自动生成加工数据集。
- 资源配置：
- 单击^展开资源配置，可以设置任务资源。也支持自定义参数配置，单击添加参数，输入参数名称和参数值。

表 4-20 参数配置

参数名称	参数说明
numExecutors	Executor的数量，默认值2。Executor是运行在工作节点上的进程，它负责执行具体的task任务，并将计算结果返回给Driver。每个Executor每个核同时能跑一个task任务，所以增加了Executor的个数相当于增大了任务的并发度。在资源充足的情况下，可以相应增加Executor的个数，以提高运行效率。 numExecutors * executorMemory最小值为4，最大值为16。
executorCores	每个Executor进程使用的CPU内核数量，默认值2。每个Executor多个核同时能跑多个task任务，相当于增大了任务的并发度。但是由于所有核共用Executor的内存，所以要在内存和核数之间做好平衡。 numExecutors * executorMemory最小值为4，最大值为16。executorCores和executorMemory的比例需要在1:2~1:4之间。
executorMemory	每个Executor进程使用的内存数量，默认值4。Executor的内存主要用于任务执行、通信等。当一个任务很大的时候，可能需要较多资源，因而内存也可以做相应的增加；当一个任务较小运行较快时，就可以增大并发度减少内存。 executorCores和executorMemory的比例需要在1:2~1:4之间。
driverCores	驱动程序进程使用的CPU内核数量，默认值2。Driver负责任务的调度，和Executor之间的消息通信。 driverCores和driverMemory的比例需要在1:2~1:4之间。
driverMemory	驱动程序进程使用的内存数量，默认值4。Driver负责任务的调度，和Executor之间的消息通信。当任务数变多，任务平行度增大时，Driver内存都需要相应增大。 driverCores和driverMemory的比例需要在1:2~1:4之间。

图 4-32 资源配置



自动生成加工数据集：

勾选，配置生成加工数据集的信息，如图 [自动生成加工数据集](#)；单击右下角“确定”，平台将启动配比任务。配比任务运行成功后自动生成加工数据集。

不勾选，单击右下角“确定”，平台将启动配比任务。配比任务运行成功后手动生成加工数据集。

图 4-33 自动生成加工数据集

☒ 自动生成加工数据集

启用后任务运行成功自动生成加工数据集，可用于下游数据集发布；如关闭需在加工任务列表操作生成

数据集名称

描述

请输入

0/100

扩展信息（可选）：
可选择行业、语言信息，或自定义数据集属性。

图 4-34 扩展信息

扩展信息

数据集属性（可选）

行业

请选择

语言

请选择

自定义

请输入

7.

单击“确定”后，页面将返回至“配比任务”页面，配比任务运行成功后，状态将显示为“运行成功”。
8.

单击操作列“生成”，将生成“发布数据集”。
- 发布数据集可在“数据工程 > 数据管理 > 数据集 > 发布数据集”中查看。

4.5.3 加工图片类数据集

4.5.3.1 加工图片类数据集

加工图片类数据集任务前，请先完成数据导入操作，具体步骤请参见[导入数据至盘古平台](#)。


创建图片类数据集加工任务

创建图片类数据集加工任务步骤如下：

1.

登录ModelArts Studio大模型开发平台，在“我的空间”模块，单击进入所需空间。

图 4-35 我的空间



2. 在左侧导航栏中选择“数据工程 > 数据加工 > 加工任务”，单击界面右上角“创建加工任务”。
3. 在“创建加工任务”页面，选择需要加工的图片类数据集，单击“下一步”。
4. 进入“加工步骤编排”页面。对于图片类数据集，可选择的加工算子请参见[表 4-31](#)。
 - a. 在左侧“添加算子”分页勾选所需算子。根据实际场景，可以选择一个或多个。
平台支持选择预置算子或自定义算子，如果使用自定义算子，创建步骤见[自定义数据集加工算子](#)。
 - b. 在右侧“加工步骤编排”页面配置各算子参数，可拖动右侧“”以调整算子执行顺序。

图 4-36 算子编排



- c. 在编排过程中，可单击右上角“保存为新模板”将当前编排流程保存为模板。后续创建新的数据加工任务时，可直接单击“选择加工模板”进行使用。
若选择使用加工模板，将删除当前已编排的加工步骤。


图 4-37 选择加工模板



5. 加工步骤编排完成后，单击“下一步”进入“任务配置界面”。
- 资源配置

单击 $\vee$ 展开资源配置，可以设置任务资源。也支持自定义参数配置，单击“添加参数”，输入参数名称和参数值。

图 4-38 资源配置



详细参数说明见[表4-21](#)。

表 4-21 参数配置

参数名称	参数说明
numExecutors	Executor的数量，默认值2。Executor是运行在工作节点上的进程，它负责执行具体的task任务，并将计算结果返回给Driver。每个Executor每个核同时能跑一个task任务，所以增加了Executor的个数相当于增大了任务的并发度。在资源充足的情况下，可以相应增加Executor的个数，以提高运行效率。 numExecutors * executorMemory最小值为4，最大值为16。

参数名称	参数说明
executorCores	每个Executor进程使用的CPU内核数量，默认值2。每个Executor多个核同时能跑多个task任务，相当于增大了任务的并发度。但是由于所有核共用Executor的内存，所以要在内存和核数之间做好平衡。 numExecutors * executorMemory最小值为4，最大值为16。executorCores和executorMemory的比例需要在1:2~1:4之间。
executorMemory	每个Executor进程使用的内存数量，默认值4。Executor的内存主要用于任务执行、通信等。当一个任务很大的时候，可能需要较多资源，因而内存也可以做相应的增加；当一个任务较小运行较快时，就可以增大并发度减少内存。 executorCores和executorMemory的比例需要在1:2~1:4之间。
driverCores	驱动程序进程使用的CPU内核数量，默认值2。Driver负责任务的调度，和Executor之间的消息通信。 driverCores和driverMemory的比例需要在1:2~1:4之间。
driverMemory	驱动程序进程使用的内存数量，默认值4。Driver负责任务的调度，和Executor之间的消息通信。当任务数变多，任务平行度增大时，Driver内存都需要相应增大。 driverCores和driverMemory的比例需要在1:2~1:4之间。

- 自动生成加工数据集
勾选，配置生成加工数据集的信息，如图4-39；单击右下角“确定”，平台将启动配比任务。配比任务运行成功后自动生成加工数据集。
不勾选，单击右下角“确定”，平台将启动配比任务。配比任务运行成功后手动生成加工数据集。

图 4-39 自动生成加工数据集

☒ 自动生成加工数据集

启用后任务运行成功自动生成加工数据集，可用于下游数据集发布；如关闭需在加工任务列表操作生成

数据集名称

描述

请输入

0/100

- 扩展信息（可选）
- 可选择行业、语言信息，或自定义数据集属性。

图 4-40 扩展信息

扩展信息

数据集属性（可选）

行业

请选择

语言

请选择

自定义

请输入

6. 单击“启动加工”。当数据加工任务运行成功后，状态将从“运行中”变为“运行成功”，表示数据已经完成加工。

说明

- 在完成数据加工后，如果无需使用数据标注、数据合成功能，可直接在“加工任务”页面单击操作列“生成”，生成加工数据集。
- 加工后的数据集可在“数据工程 > 数据管理 > 数据集 > 加工数据集”中查看。

4.5.3.2 标注图片类数据集

创建图片类数据集标注任务

标注图片类数据集任务前，请先完成数据导入操作，具体步骤请参见[导入数据至盘古平台](#)。

数据标注功能支持创建标注任务、标注数据集（标注作业）、审核标注后的数据集（审核作业）与管理标注任务（任务管理）。其中，不同角色权限支持的功能及展示的前端界面略有差异，详见[表4-22](#)。

表 4-22 不同角色支持的数据标注任务权限清单

角色名称	创建标注任务	标注作业任务	审核作业任务	任务管理任务
超级管理员	√	√	-	√
管理员	√	√	-	√
标注管理员	√	√	-	√
标注作业员	-	√	-	-
标注审核员	-	-	√	-

创建图片类数据集标注任务步骤如下：

1. 登录ModelArts Studio大模型开发平台，在“我的空间”模块，单击进入所需空间。

图 4-41 我的空间



2. 在左侧导航栏中选择“数据工程 > 数据加工 > 标注任务”，单击页面右上角“创建标注任务”。
3. 在“创建标注任务”页面选择需要标注的图片类数据集与标注项。
如果选择“图片Caption”标注项，则可开启“AI预标注”功能。AI预标注将自动生成标注内容，不会覆盖原始数据集，供标注人员参考，以提高标注效率。
4. 可选择开启“多人作业”功能，开启后，可选择多人协同完成作业，并增加审核功能可供选择。参考表4-23配置标注分配与审核。

表 4-23 标注分配与审核配置

参数类型	参数名称	参数说明
标注分配	标注员	添加标注人员与数量。
	标注要求	选择标注项为“图片Caption”且开启AI预标注功能时，可设置以下两种方式的“标注要求”： - 选择“全部标注”：要求标注人员需要对全部的数据进行人工标注后才可提交标注结果。 - 选择“可部分标注”：允许标注人员在确认AI预标注满足要求后，直接使用AI预标注功能完成数据集的标注并提交标注结果。
标注审核	是否审核	- 否，标注后不进行审核操作。 - 是，审核员会检查标注员的标注内容，若发现问题，审核员可注明原因并驳回标注数据，标注员需重新标注。
	审核员	添加审核人员与数量。
	审核要求	- 全部审核：要求审核员对全部数据，逐条进行人工审核，才能完成审核任务。 - 可部分审核：审核员在审核一部分数据后，发现标注质量均很高，则可以一键提交剩余待审核数据，默认审核通过，即可完成审核任务。

5. 配置完成后，单击“完成创建”。
6. 在“标注任务”页面，单击当前标注任务的“作业”，可执行标注作业任务。
其中，对于“标注作业员”角色，可单击“标注”执行标注作业任务。
如果需要将该标注任务移交给其他人员，可以单击“移交”，并设置移交人员以及移交数量，单击“确定”。
7. 进入标注页面后，逐一对数据进行标注。
8. 一条数据标注完成后，单击“提交”可继续标注剩余数据。所有数据标注完成后，页面会出现标注任务成功的提示。
如果在创建标注任务时设置了“AI预标注 > 可部分标注”，则可在标注部分数据后，单击右上角的“提交全部标注数据”，让AI大模型自动标注剩余数据。

 说明


在完成数据标注后，如果无需进行标注审核，可直接在“数据标注 > 任务管理”页面单击“生成”，生成加工数据集。
生成的加工数据集可在“数据工程 > 数据管理 > 数据集 > 加工数据集”中查看。

AI 预标注功能介绍

标注任务开始前，系统对当前任务中的所有数据批量智能生成标注数据，具体操作如下。


步骤1 在“创建标注任务”页面，选择数据集、开启AI预标注后单击“完成创建”。

图 4-42 AI 预标注功能



步骤2 在“标注任务”页面，单击任务名称对应操作列的“作业”，可进入标注界面。

图 4-43 标注任务



步骤3 复制“预标注Caption”框中的内容并粘贴至上面的“Caption描述”框中，可对Caption进行修改后单击右上角的“提交”。

图 4-44 预标注 Caption



----结束

审核标注后的图片类数据集

如果在[创建图片类数据集标注任务](#)时启用了标注审核功能，则在完成标注后可以审核标注结果。对于审核不合格的数据可以填写不合格原因并驳回给标注员重新标注。

该操作需要具备[标注审核员](#)角色权限。

审核图片类数据集标注结果的步骤如下：

1. 登录ModelArts Studio平台，在“我的空间”模块，单击进入所需空间。

图 4-45 我的空间



2. 在左侧导航栏中选择“数据工程 > 数据加工 > 标注任务”。
3. 单击“审核”可进入审核页面审核数据。
- 如果需要将该审核任务移交给其他人员，可以单击“移交”，并设置移交人员以及移交数量，单击“确定”。
4. 进入审核页面后，可通过单击“通过”或“不通过”逐一对数据进行审核，直至所有数据审核完成。

说明

在完成数据标注审核后，需在“数据标注 > 任务管理”页面单击“生成”，生成加工数据集。生成的加工数据集可在“数据工程 > 数据管理 > 数据集 > 加工数据集”中查看。

管理标注后的图片类数据集

平台支持超级管理员、管理员、标注管理员对标注的数据集进行如下操作：

- 生成：在完成数据标注审核后，需超级管理员、管理员、标注管理员角色在“标注任务”页面的操作列单击“生成”，生成加工数据集。
生成后的加工数据集可在“数据工程 > 数据管理 > 数据集 > 加工数据集”中查看。
- 结束：管理员角色可在“标注任务”页面的操作列单击“更多 > 结束”，结束当前标注任务。
- 编辑：如果该标注任务支持“AI辅助标注”和“审核”功能，管理员角色可在“标注任务”页面的操作列单击“更多 > 编辑”，选择是否开启“AI辅助标注”功能并选择“审核要求”。

- 删除：管理员角色可在“标注任务”页面的操作列单击“更多 > 删除”，删除当前标注任务。

4.5.3.3 配比图片类数据集

数据配比是将多个数据集按照特定比例关系组合并发布为“发布数据集”的过程，确保数据的多样性、平衡性和代表性。


如果单个数据集已满足您的需求，可跳过此章节至[发布图片类数据集](#)。

创建图片类数据集配比任务

创建图片类数据集配比任务步骤如下：

1. 登录ModelArts Studio大模型开发平台，在“我的空间”模块，单击进入所需空间。

图 4-46 我的空间



2. 在左侧导航栏中选择“数据工程 > 数据加工 > 配比任务”，单击界面右上角“创建配比任务”。
3. 在“数据集选择”页签选择需要配比的图片类数据集（至少选择两个），单击“下一步”。
4. 在“数据配比”页面，可以设置不同数据集的配比数量，单击“下一步”。
5. 数据配比完成后，单击右下角“下一步”，进行资源配置，并选择是否勾选自动生成加工数据集。
 - 资源配置
单击 ^ 展开资源配置，可以设置任务资源。也支持自定义参数配置，单击“添加参数”，输入参数名称和参数值。

表 4-24 参数配置

参数名称	参数说明
numExecutors	Executor的数量，默认值2。 numExecutors * executorMemory最小值为4，最大值为16。

参数名称	参数说明
executorCores	每个Executor进程使用的CPU内核数量，默认值2。 numExecutors * executorMemory最小值为4，最大值为16。executorCores和executorMemory的比例需要在1:2~1:4之间。
executorMemory	每个Executor进程使用的内存数量，默认值4。 executorCores和executorMemory的比例需要在1:2~1:4之间。
driverCores	驱动程序进程使用的CPU内核数量，默认值2。 driverCores和driverMemory的比例需要在1:2~1:4之间。
driverMemory	驱动程序进程使用的内存数量，默认值4。 driverCores和driverMemory的比例需要在1:2~1:4之间。

图 4-47 资源配置

资源配置

参数配置

numExecutors

-

2

+

个

executorCores

-

2

+

个

executorMemory

-

4

+

GB

driverCores

-

2

+

个

driverMemory

-

4

+

GB

自定义参数配置

+ 添加参数

您还可以添加 10 个参数

- 自动生成加工数据集
- 勾选，配置生成加工数据集的信息，如图4-48；单击右下角“确定”，平台将启动配比任务。配比任务运行成功后自动生成加工数据集。
- 不勾选，单击右下角“确定”，平台将启动配比任务。配比任务运行成功后手动生成加工数据集。

图 4-48 自动生成加工数据集

☒ 自动生成加工数据集

启用后任务运行成功自动生成加工数据集，可用于下游数据集发布；如关闭需在加工任务列表操作生成

数据集名称

描述


请输入

0/100

- 扩展信息（可选）

可选择行业、语言信息，或自定义数据集属性。

图 4-49 扩展信息



6. 单击“确定”，页面将返回至“数据配比”页面，配比任务运行成功后，状态将显示为“运行成功”。
7. 单击操作列“生成”，将生成“发布数据集”。
- 发布数据集可在“数据工程 > 数据管理 > 数据集 > 发布数据集”中查看。

4.5.4 加工视频类数据集


4.5.4.1 加工视频类数据集

加工视频类数据集任务前，请先完成数据导入操作，具体步骤请参见[导入数据至盘古平台](#)。

创建视频类数据集加工任务

1. 登录ModelArts Studio大模型开发平台，在“我的空间”模块，单击进入所需空间。

图 4-50 我的空间



2. 在左侧导航栏中选择“数据工程 > 数据加工 > 加工任务”，单击界面右上角“创建加工任务”。
3. 在“创建加工任务”页面，选择需要加工的视频类数据集，单击“下一步”。
4. 进入“加工步骤编排”页面。对于视频类数据集，可选择的加工算子请参见[表 4-30](#)。
- a. 在左侧“添加算子”分页勾选所需算子。根据实际场景，可以选择一个或多个。
- 平台支持选择预置算子或自定义算子，如果使用自定义算子，创建步骤见[自定义数据集加工算子](#)。

- b.

在右侧“加工步骤编排”页面配置各算子参数，可拖动右侧“”以调整算子执行顺序。
- c.

在编排过程中，可单击右上角“保存为新模板”将当前编排流程保存为模板。后续创建新的数据加工任务时，可直接单击“选择加工模板”进行使用。
- 若选择使用加工模板，将删除当前已编排的加工步骤。

图 4-51 选择加工模板



5. 加工步骤编排完成后，单击“下一步”进入“任务配置”界面。
- 自动生成加工数据集

勾选，配置生成加工数据集的信息，如图4-52；单击右下角“确定”，平台将启动配比任务。配比任务运行成功后自动生成加工数据集。

不勾选，单击右下角“确定”，平台将启动配比任务。配比任务运行成功后手动生成加工数据集。

图 4-52 自动生成加工数据集

☒ 自动生成加工数据集

启用后任务运行成功自动生成加工数据集，可用于下游数据集发布；如关闭需在加工任务列表操作生成

数据集名称

描述

请输入

0/100

- 扩展信息（可选）
- 可选择行业、语言信息，或自定义数据集属性。

图 4-53 扩展信息

扩展信息

数据源属性 (可选)

行业

请选择

国家

请选择

自定义

请输入

6. 单击“启动加工”。当数据加工任务运行成功后，状态将从“运行中”变为“运行成功”，表示数据已经完成加工。

说明

- 在完成数据加工后，如果无需使用数据标注、数据合成功能，可直接在“加工任务”页面单击操作列“生成”，生成加工数据集。
- 加工后的数据集可在“数据工程 > 数据管理 > 数据集 > 加工数据集”中查看。

4.5.4.2 标注视频类数据集

创建视频类数据集标注任务

标注视频类数据集任务前，请先完成数据导入操作，具体步骤请参见[导入数据至盘古平台](#)。

数据标注功能支持创建标注任务、标注数据集（标注作业）、审核标注后的数据集（审核作业）与管理标注任务（任务管理）。其中，不同角色权限支持的功能及展示的前端界面略有差异，详见[表4-25](#)。

表 4-25 不同角色支持的数据标注任务权限清单

角色名称	创建标注任务	标注作业任务	审核作业任务	任务管理任务
超级管理员	√	√	-	√
管理员	√	√	-	√
标注管理员	√	√	-	√
标注作业员	-	√	-	-
标注审核员	-	-	√	-

创建视频类数据集标注任务步骤如下：

1. 登录ModelArts Studio大模型开发平台，在“我的空间”模块，单击进入所需空间。

图 4-54 我的空间



2. 在左侧导航栏中选择“数据工程 > 数据加工 > 标注任务”，单击页面右上角“创建标注任务”。
3. 在“创建标注任务”页面选择需要标注的视频类数据集与标注项，单击“下一步”。
- 如果选择“视频Caption”标注项，则可开启“AI预标注”功能。AI预标注将自动生成标注内容，不会覆盖原始数据集，供标注人员参考，以提高标注效率。
4. 可选择开启“多人作业”功能，开启后，可选择多人协同完成作业，并增加审核功能可供选择。参考表4-26配置标注分配与审核。

表 4-26 标注分配与审核配置

参数类型	参数名称	参数说明
标注分配	标注员	添加标注人员与数量。
标注审核	是否审核	- 否，标注后不进行审核操作。 - 是，审核员会检查标注员的标注内容，若发现问题，审核员可注明原因并驳回标注数据，标注员需重新标注。
	审核员	添加审核人员与数量。
	审核要求	- 全部审核：要求审核员对全部数据，逐条进行人工审核，才能完成审核任务。 - 可部分审核：审核员在审核一部分数据后，发现标注质量均很高，则可以一键提交剩余待审核数据，默认审核通过，即可完成审核任务。

5. 配置完成后，单击“完成创建”。
6. 在“标注任务”页面，单击当前标注任务的“作业”，可执行标注作业任务。
- 其中，对于“标注作业员”角色，可单击“标注”执行标注作业任务。
- 如果需要将该标注任务移交给其他人员，可以单击“移交”，并设置移交人员以及移交数量，单击“确定”。

7. 进入标注页面后，逐一对数据进行标注。
8. 一条数据标注完成后，单击“提交”可继续标注剩余数据。所有数据标注完成后，页面会出现标注任务成功的提示。
- 如果在创建标注任务时设置了“AI预标注 > 可部分标注”，则可在标注部分数据后，单击右上角的“提交全部标注数据”，让AI大模型自动标注剩余数据。

说明

在完成数据标注后，如果无需进行标注审核，可直接在“数据标注 > 任务管理”页面单击“生成”，生成加工数据集。


生成的加工数据集可在“数据工程 > 数据管理 > 数据集 > 加工数据集”中查看。

AI 预标注功能介绍

标注任务开始前，系统对当前任务中的所有数据批量智能生成标注数据，具体操作如下。


步骤1 在“创建标注任务”页面，选择数据集、开启AI预标注后单击“完成创建”。

图 4-55 AI 预标注功能




步骤2 在“标注任务”页面，单击任务名称对应操作列的“作业”，可进入标注界面。

图 4-56 标注任务



步骤3 “Caption描述”框中已AI智能生成描述，可对Caption进行修改后单击右上角的“提交”。

图 4-57 Caption 描述



----结束

审核标注后的视频类数据集

如果在**创建视频类数据集标注任务**时启用了标注审核功能，则在完成标注后可以审核标注结果。对于审核不合格的数据可以填写不合格原因并驳回给标注员重新标注。

该操作需要具备**标注审核员**角色权限。

审核视频类数据集标注结果的步骤如下：

- 1. 登录ModelArts Studio平台，在“我的空间”模块，单击进入所需空间。

图 4-58 我的空间



- 2. 在左侧导航栏中选择“数据工程 > 数据加工 > 标注任务”。
- 3. 单击“审核”可进入审核页面审核数据。
如果需要将该审核任务移交给其他人员，可以单击“移交”，并设置移交人员以及移交数量，单击“确定”。
- 4. 进入审核页面后，可通过单击“通过”或“不通过”逐一对数据进行审核，直至所有数据审核完成。

说明

在完成数据标注审核后，需在“数据标注 > 任务管理”页面单击“生成”，生成加工数据集。
生成的加工数据集可在“数据工程 > 数据管理 > 数据集 > 加工数据集”中查看。

管理标注后的视频类数据集

平台支持超级管理员、管理员、标注管理员对标注的数据集进行如下操作：

- 生成：在完成数据标注审核后，需超级管理员、管理员、标注管理员角色在“标注任务”页面的操作列单击“生成”，生成加工数据集。
生成后的加工数据集可在“数据工程 > 数据管理 > 数据集 > 加工数据集”中查看。
- 结束：管理员角色可在“标注任务”页面的操作列单击“更多 > 结束”，结束当前标注任务。
- 编辑：如果该标注任务支持“AI辅助标注”和“审核”功能，管理员角色可在“标注任务”页面的操作列单击“更多 > 编辑”，选择是否开启“AI辅助标注”功能并选择“审核要求”。
- 删除：管理员角色可在“标注任务”页面的操作列单击“更多 > 删除”，删除当前标注任务。

4.5.5 加工气象类数据集

加工气象类数据集任务前，请先完成数据导入操作，具体步骤请参见[导入数据至盘古平台](#)。

创建气象类数据集加工任务

创建气象类数据集加工任务步骤如下：

1. 登录ModelArts Studio大模型开发平台，在“我的空间”模块，单击进入所需空间。

图 4-59 我的空间



2. 在左侧导航栏中选择“数据工程 > 数据加工 > 加工任务”，单击界面右上角“创建加工任务”。

3. 在“创建加工任务”页面，选择需要加工的气象类数据集，单击“下一步”。
4. 进入“加工步骤编排”页面。对于气象类数据集，可选的加工算子请参见表 4-32。

a. 在左侧“添加算子”分页勾选所需算子。根据实际场景，可以选择一个或多个。
平台支持选择预置算子或自定义算子，如果使用自定义算子，创建步骤见自定义数据集加工算子。

b. 在右侧“加工步骤编排”页面配置各算子参数，可拖动右侧“⋮”以调整算子执行顺序。

图 4-60 算子编排



- c. 在编排过程中，可单击右上角“保存为新模板”将当前编排流程保存为模板。后续创建新的数据加工任务时，可直接单击“选择加工模板”进行使用。
若选择使用加工模板，将删除当前已编排的加工步骤。

图 4-61 选择加工模板



5. 加工步骤编排完成后，单击“下一步”进入“任务配置界面”。
- 自动生成加工数据集

勾选，配置生成加工数据集的信息，如图4-62；单击右下角“确定”，平台将启动配比任务。配比任务运行成功后自动生成加工数据集。

不勾选，单击右下角“确定”，平台将启动配比任务。配比任务运行成功后手动生成加工数据集。

图 4-62 自动生成加工数据集

☒ 自动生成加工数据集

启用后任务运行成功自动生成加工数据集，可用于下游数据集发布；如关闭需在加工任务列表操作生成

数据集名称

描述

请输入

0/100

- 扩展信息（可选）
- 可选择行业、语言信息，或自定义数据集属性。

图 4-63 扩展信息

扩展信息

数据集属性（可选）

行业

语言

自定义

请选择

请选择

请输入

6. 单击“启动加工”。当数据加工任务运行成功后，状态将从“运行中”变为“运行成功”，表示数据已经完成加工。

说明

- 在完成数据加工后，如果无需使用数据标注、数据合成功能，可直接在“加工任务”页面单击操作列“生成”，生成加工数据集。
- 加工后的数据集可在“数据工程 > 数据管理 > 数据集 > 加工数据集”中查看。

4.5.6 加工音频类数据集

4.5.6.1 加工音频类数据集

加工音频类数据集任务前，请先完成数据导入操作，具体步骤请参见[导入数据至盘古平台](#)。

创建音频类数据集加工任务

1. 登录ModelArts Studio大模型开发平台，在“我的空间”模块，单击进入所需空间。

图 4-64 我的空间



2. 在左侧导航栏中选择“数据工程 > 数据加工 > 加工任务”，单击界面右上角“创建加工任务”。
3. 在“创建加工任务”页面，选择需要加工的音频类数据集，单击“下一步”。
4. 进入“加工步骤编排”页面。对于音频类数据集，可选的加工算子请参见[音频类加工算子介绍](#)。

a. 在左侧“添加算子”分页勾选所需算子。根据实际场景，可以选择一个或多个。
平台支持选择预置算子或自定义算子，如果使用自定义算子，创建步骤见[自定义数据集加工算子](#)。

b. 在右侧“加工步骤编排”页面配置各算子参数，可拖动右侧“”以调整算子执行顺序。

c. 在编排过程中，可单击右上角“保存为新模板”将当前编排流程保存为模板。后续创建新的数据加工任务时，可直接单击“选择加工模板”进行使用。
若选择使用加工模板，将删除当前已编排的加工步骤。

图 4-65 选择加工模板



5. 加工步骤编排完成后，单击“启动加工”，将启动加工任务。

当数据加工任务运行成功后，状态将从“运行中”变为“运行成功”，表示数据已经完成加工。

说明

在完成数据加工后，如果无需使用数据标注功能，可直接在“加工任务”页面单击操作列“生成”，生成加工数据集。
加工后的数据集可在“数据工程 > 数据管理 > 数据集 > 加工数据集”中查看。

4.5.6.2 标注音频类数据集

创建音频类数据集标注任务

标注音频类数据集任务前，请先完成数据导入操作，具体步骤请参见[导入数据至盘古平台](#)。

数据标注功能支持创建标注任务、标注数据集（标注作业）、审核标注后的数据集（审核作业）与管理标注任务（任务管理）。其中，不同角色权限支持的功能及展示的前端界面略有差异，详见[表1 不同角色支持的数据标注任务权限清单](#)。


表 4-27 不同角色支持的数据标注任务权限清单

角色名称	创建标注任务	标注作业任务	审核作业任务	任务管理任务
超级管理员	√	√	-	√
管理员	√	√	-	√
标注管理员	√	√	-	√
标注作业员	-	√	-	-
标注审核员	-	-	√	-

创建音频类数据集标注任务步骤如下：

- 1. 登录ModelArts Studio大模型开发平台，在“我的空间”模块，单击进入所需空间。

图 4-66 我的空间



2. 在左侧导航栏中选择“数据工程 > 数据加工 > 标注任务”，单击页面右上角“创建标注任务”。
3. 在“创建标注任务”页面选择需要标注的音频类数据集与标注项，单击“下一步”。
4. 可选择开启“多人作业”功能，开启后，可选择多人协同完成作业，并增加审核功能可供选择。参考表4-28配置标注分配与审核。

表 4-28 标注分配与审核配置

参数类型	参数名称	参数说明
标注分配	标注员	添加标注人员与数量。
标注审核	是否审核	- 否，标注后不进行审核操作。 - 是，审核员会检查标注员的标注内容，若发现问题，审核员可注明原因并驳回标注数据，标注员需重新标注。
	审核员	添加审核人员与数量。
	审核要求	- 全部审核：要求审核员对全部数据，逐条进行人工审核，才能完成审核任务。 - 可部分审核：审核员在审核一部分数据后，发现标注质量均很高，则可以一键提交剩余待审核数据，默认审核通过，即可完成审核任务。

5. 配置完成后，单击“完成创建”。
6. 在“标注任务”页面，单击当前标注任务的“作业”，可执行标注作业任务。
其中，对于“标注作业员”角色，可单击“标注”执行标注作业任务。
如果需要将该标注任务移交给其他人员，可以单击“移交”，并设置移交人员以及移交数量，单击“确定”。
7. 进入标注页面后，逐一对数据进行标注。
8. 一条数据标注完成后，单击“提交”可继续标注剩余数据。所有数据标注完成后，页面会出现标注任务成功的提示。

 说明


在完成数据标注后，如果无需进行标注审核，可直接在“数据标注 > 任务管理”页面单击“生成”，生成加工数据集。
生成的加工数据集可在“数据工程 > 数据管理 > 数据集 > 加工数据集”中查看。

审核标注后的音频类数据集

如果在创建音频类数据集标注任务时启用了标注审核功能，则在完成标注后可以审核标注结果。对于审核不合格的数据可以填写不合格原因并驳回给标注员重新标注。
该操作需要具备标注审核员角色权限。
审核音频类数据集标注结果的步骤如下：

1. 登录ModelArts Studio平台，在“我的空间”模块，单击进入所需空间。

图 4-67 我的空间



- 2. 在左侧导航栏中选择“数据工程 > 数据加工 > 标注任务”。
- 3. 单击“审核”可进入审核页面审核数据。
如果需要将该审核任务移交给其他人员，可以单击“移交”，并设置移交人员以及移交数量，单击“确定”。
- 4. 进入审核页面后，可通过单击“通过”或“不通过”逐一对数据进行审核，直至所有数据审核完成。

说明

在完成数据标注审核后，需在“数据标注 > 任务管理”页面单击“生成”，生成加工数据集。
生成的加工数据集可在“数据工程 > 数据管理 > 数据集 > 加工数据集”中查看。

管理标注后的音频类数据集

- 平台支持超级管理员、管理员、标注管理员对标注的数据集进行如下操作：
- 生成：在完成数据标注审核后，需超级管理员、管理员、标注管理员角色在“标注任务”页面的操作列单击“生成”，生成加工数据集。
生成后的加工数据集可在“数据工程 > 数据管理 > 数据集 > 加工数据集”中查看。
 - 结束：管理员角色可在“标注任务”页面的操作列单击“更多 > 结束”，结束当前标注任务。
 - 编辑：如果该标注任务支持“AI辅助标注”和“审核”功能，管理员角色可在“标注任务”页面的操作列单击“更多 > 编辑”，选择是否开启“AI辅助标注”功能并选择“审核要求”。
 - 删除：管理员角色可在“标注任务”页面的操作列单击“更多 > 删除”，删除当前标注任务。

4.5.7 加工其他类数据集


加工其他类数据集任务前，请先完成数据导入操作，具体步骤请参见[导入数据至盘古平台](#)。

创建其他类数据集加工任务

创建其他类数据集加工任务步骤如下：

1. 登录ModelArts Studio大模型开发平台，在“我的空间”模块，单击进入所需空间。

图 4-68 我的空间



2. 在左侧导航栏中选择“数据工程 > 数据加工 > 加工任务”，单击界面右上角“创建加工任务”。
3. 在“创建加工任务”页面，选择需要加工的其他类数据集，单击“下一步”。
4. 进入“加工步骤编排”页面。

a. 在左侧“添加算子”分页勾选所需算子。根据实际场景，可以选择一个或多个。
对于其他类数据集，平台仅支持选择自定义算子，其创建步骤见[自定义数据集加工算子](#)。

b. 在右侧“加工步骤编排”页面配置各算子参数，可拖动右侧“”以调整算子执行顺序。

c. 在编排过程中，可单击右上角“保存为新模板”将当前编排流程保存为模板。后续创建新的数据加工任务时，可直接单击“选择加工模板”进行使用。
若选择使用加工模板，将删除当前已编排的加工步骤。

图 4-69 选择加工模板



5. 加工步骤编排完成后，单击“启动加工”，将启动加工任务。
当数据加工任务运行成功后，状态将从“运行中”变为“运行成功”，表示数据已经完成加工。
6. 在完成数据加工后，在“加工任务”页面单击操作列“生成”，生成加工数据集。
加工后的数据集可在“数据工程 > 数据管理 > 数据集 > 加工数据集”中查看。

4.5.8 管理加工算子

4.5.8.1 系统预置加工算子介绍

4.5.8.1.1 文本类加工算子介绍

数据加工算子为用户提供了多种数据操作能力，包括数据提取、过滤、转换、打标签等。这些算子能够帮助用户从海量数据中提取出有用信息，并进行深度加工，以生成高质量的训练数据。

平台支持文本类数据集的加工操作，分为数据提取、数据转换、数据过滤、数据打标四类，文本类加工算子能力清单见[表4-29](#)。

表 4-29 文本类加工算子能力清单

算子分类	算子名称	算子描述
数据提取	WORD内容提取	从Word文档中提取文字，并保留原文档的目录、标题和正文等结构，不保留图片、表格、公式、页眉、页脚。
	TXT内容提取	从TXT文件中提取所有文本内容。
	CSV内容提取	从CSV文件中读取所有文本内容，并按该文件内容类型模板KEY值生成匹配的JSON格式数据。
	PDF内容提取	从PDF中提取文本，转化为结构化数据，支持文本、表格、公式等内容提取。
	JSON内容提取	提取JSON文件中的键值对信息。
	HTML内容提取	基于标签路径提取HTML数据内容，并将其他与待提取标签路径无关的内容删除。
	电子书内容提取	从电子书中提取出所有文本内容。
数据转换	个人数据脱敏	对文本中的手机号码、身份证件、邮箱地址、url链接、国内车牌号、IP地址、MAC地址、IMEI、护照、车架号等个人敏感信息进行数据脱敏，或直接删除敏感信息。

算子分类	算子名称	算子描述
	符号标准化	查找文本中携带的非标准化符号进行标准化、统一化转换。 - 统一空格：将所有Unicode空格（如U+00A0、U+200A）转换为标准空格（U+0020）。 - 全角转半角：将文本中的全角字符转换为半角字符。 - 标点符号归一化，支持统一格式的符号如下： - {"? " : "\? \? " } - 数字符号归一化。
	自定义正则替换	数据条目不变下，使用自定义正则表达式替换文本内容。 示例如下： - 去除“参考文献”以及之后的内容：<code>\n参考文献[\s\S]*</code> - 针对pdf的内容，去除“0 引言”之前的内容，引言之前的内容与知识无关：<code>[\s\S]{0, 10000}0 引言</code> - 针对pdf的内容，去除“1.1Java简介”之前的与知识无关的内容：<code>[\s\S]{0, 10000} 1\ 1Java简介</code>
	日期时间格式转换	自动识别日期、时间、星期，同时根据选择的格式进行统一转换。
数据过滤	异常字符过滤	查找数据集每一条数据中携带的异常字符，并将异常字符替换为空值，数据条目不变。 - 不可见字符，比如U+0000-U+001F。 - 网页标签符号<style></style>。 - 特殊空格：<code>[\u2000-\u2009]</code>
	自定义正则过滤	删除符合自定义正则表达式的数据。
	自定义关键词过滤	剔除包含关键词的数据。
	敏感词过滤	对文本中涉及黄色、暴力、政治等敏感数据进行自动检测和过滤。
	文本长度过滤	按照设置的文本长度，保留长度范围内的数据进行。
	冗余信息过滤	按照段落粒度，删除文本中的冗余信息，不改变数据条目。 例如图注表注和参考文献。

算子分类	算子名称	算子描述
	N-gram特征过滤	用于判断文档重复度，根据特征N值计算文档内词语按N值组合后的重复此时，可通过以下两种算法比较结果是否大于特征阈值，大于特征阈值的文档删除。 - top-gram过滤：计算重复最多的gram占总长度的比例，大于特征阈值则删除。 - gram重复率过滤：计算所有重复的gram占总长度的比例，大于特征阈值则删除。
	段落特征过滤	根据如下特征过滤： - 段落重复率。 - 重复段落长度占比。 - 非中文字符占比。
	句子特征过滤	该算子将文档中的标点符号作为句子分隔符，统计每句字符长度，若文档平均字符长度大于设置字符，则保留，反之则删除整篇文档。根据如下特征过滤： 待保留的平均句长。
	词语特征过滤	词个数表示按照系统词库，对文档进行分词，分词后统计词的总个数，平均词长度为所有词的长度总和除以词总个数，两者都满足则保留当前文档。根据如下特征过滤： - 待保留的词个数。 - 待保留的平均词长度。
	段落结尾不完整句子过滤	按照句子的过滤粒度，自动识别段落结尾处的内容是否完整，如果不完整，则过滤。
	广告数据过滤	按照句子的过滤粒度，删除文本中包含广告数据的句子。
	QA对过滤	过滤包含以下情况的QA对： - 问题不是string格式。 - 回答为空。 - 回答无意义。
	语种过滤	通过语种识别模型得到文档的语言类型，筛选所需语种的文档。
	全局文本去重	检测并去除数据中重复或高度相似的文本，防止模型过拟合或泛化性降低。
	SFT通用语义质量评分	通过LLM对SFT数据质量做通用语义检查和打分，并可根据打分阈值进行过滤。
	SFT规则质检过滤	通过所选规则对SFT数据质量进行检查并过滤。

算子分类	算子名称	算子描述
	SFT思维链质量评分	通过LLM对SFT数据中的思维链做质量检查和打分，并可根据打分阈值进行过滤。
数据打标	预训练文本分类	针对预训练文本进行内容分类，例如新闻、教育、健康等类别，支持分析语种包括：中文、英文。
	通用质量评估	针对文本进行通用质量的评估，例如流畅度、清晰度、丰富度等。
	问题时效性评估	判断问题是否具有时效性，并给出判断原因。
	回答质量评分	针对微调数据集的回答进行质量评分，例如逻辑连贯性、事实正确性等。
	语法质量评估	针对文本进行语法质量的评估，例如相关性、规范性等。

WORD 内容提取

- 适用的文件格式：“文档 > docx”。
- 各参数说明：
待提取内容类型：从Word文档中提取文字，并保留原文档的目录、标题和正文等结构，不保留图片、表格、公式、页眉、页脚。
- 参数配置样例：
不需要配置参数，默认保留原文档的目录、标题和正文等结构，不保留图片、表格、公式、页眉、页脚。
- 提取样例：
`{"fileName":"JAVA从入门到精通.docx","text":"JAVA是一种跨平台....." }`

TXT 内容提取

- 适用的文件格式：“文档 > txt”。
- 各参数说明：
待提取内容类型：默认全文提取成一行记录，也可以选择按段落提取，根据填写的分隔符，将文本切分成多行，每个分隔符以“|”分隔,分隔符最大长度100个字符。
- 提取样例：
`{fileName:"TXT文档名.txt","text":"这是第一行。" }`

CSV 内容提取

- 适用的文件格式：“文本 >单轮问答、单轮问答（人设）、问答排序”。
- 各参数说明：
待提取内容类型：从CSV文件中读取所有文本内容，并按该文件内容类型模板KEY值生成匹配的JSON格式数据。

- 参数配置样例：
不需要配置参数。
- 提取样例：
若提取CSV样式如："你好，请介绍自己，我是盘古大模型"，则提取内容输出为：
{ "context":"你好，请介绍自己","target":"我是盘古大模型" }

PDF 内容提取

- 适用的文件格式：“文档 > pdf”
- 各参数说明：
待提取内容类型：默认保留文本、表格、公式和标题，支持选择需要保存的类型，未选择的类型将去除。
精细化内容提取：是否支持版面分析完识别是图片的内容再次进行版面分析提取。
- 参数配置样例：




- 提取样例：
{ "fileName":"JAVA从入门到精通.pdf","text":"JAVA是一种跨平台....." }

JSON 内容提取

- 适用的文件格式：“文本 > 预训练文本、单轮问答、单轮问答（人设）、多轮问答、多轮问答（人设）、问答排序、偏好优化DPO、偏好优化DPO（人设）”。
- 各参数说明：
待提取内容类型：读取所有文本中的键值对信息。
- 参数配置样例：
不需要配置参数。
- 提取样例：
{ "context":"你好，请介绍自己", "target":"我是盘古大模型" }

HTML 内容提取

- 适用的文件格式：“文本 > 网页”
- 各参数说明：
待提取内容类型：文件编码格式默认UTF-8，支持选择GB2312格式。默认提取BODY，支持用户自定义修改;可以提取多个标签，标签之间逗号分隔，例如A，B，C即提取A或者B或者C标签的内容。
- 参数配置样例：



- 提取样例：

```
{"text":"#\n我是盘古大模型\n盘古大模型是一个先进的人工智能模型，致力于为各行各业提供智能化的解决方案。","fileName":"网页.html"}
```

电子书内容提取

- 适用的文件格式：“文档 > mobi/epub”。
- 各参数说明：
待提取内容类型：从mobi/epub格式的电子书中提取出所有文本内容。
- 参数配置样例：
不需要配置参数。
- 提取样例：

```
{"fileName":"JAVA从入门到精通.epub","text":"JAVA是一种跨平台....."}
```

个人数据脱敏

- 适用的文件格式：“文本类”。
- 各参数说明：
待转换内容类型：对文本中的手机号码、身份证件、邮箱地址、url链接、国内车牌号、IP地址、MAC地址、IMEI、护照、车架号等个人敏感信息进行数据脱敏，默认全部勾选，也可以选择部分。
- 参数配置样例：



- 转换样例：
加工前: "数据来自www.test.com"
加工后: "数据来自*****"


符号标准化

- 适用的文件格式：“文本类”。
- 各参数说明：
待转换内容类型：支持对文本中携带的非标准化符号进行标准化、统一化转换，待标准化符号有空格、全角符号、标点符号、数字符号，默认全部勾选，过滤粒度为字符。
- 参数配置样例：



自定义正则替换

- 适用的文件格式：“文本类”。
- 各参数说明：
待转换内容类型：数据条目不变下，使用自定义正则表达式替换文本内容。
- 参数配置样例：



- 转换样例：
加工前: {"text": "这是aeiou正文内容aeiou测试aeiou。"}
加工后: {"text": "这是11111正文内容11111测试11111。"}

日期时间格式转换

- 适用的文件格式：“文本类”。
- 各参数说明：
待转换内容类型：自动识别日期、时间、星期，同时根据选择的格式进行统一转换。转换类型包括日期格式、时间格式、星期格式，默认全都勾选，也支持选择部分进行转换。
- 参数配置样例：



- 转换样例：
加工前: {"text": "今天是2025年3月3号，周一，早上雨真大。"}
加工后: {"text": "今天是2025-03-03 00:00:00，星期一，早上雨真大。"}

异常字符过滤

- 适用的文件格式：“文本类”。
- 各参数说明：
待过滤内容类型：查找数据集每一条数据中携带的异常字符，并将异常字符替换为空值，数据条目不变。异常字符过滤类型包括不可见字符、表情符、网页标签、特殊符号、乱码字符、特殊空格，默认全都勾选，也支持选择部分进行过滤。
- 参数配置样例：



- 过滤样例：
加工前: {"text": "测试异常。<style></style>哈哈。限时特惠!©"}
加工后: {"text": "测试异常 。哈哈。 限时特惠!"}

自定义正则过滤


- 适用的文件格式：“文本类”。
- 各参数说明：
待过滤内容类型：按自定义正则表达式进行匹配过滤，过滤粒度支持按字符、段落进行过滤，默认勾选字符。
- 参数配置样例：



- 过滤样例：
比如过滤掉参考文献之后的内容。
加工前: {"text": "这是正文内容。参考文献[1]作者1,文章1,期刊1,2021.[2] 作者2,文章2,期刊2,2022."}
加工后: {"text": "这是正文内容。"}

自定义关键词过滤

- 适用的文件格式：“文本类”。
- 各参数说明：
待过滤内容类型：过滤粒度支持按字符、段落、文档进行过滤，默认勾选字符。
待删除的关键词路径支持从obs中导入关键词，以及文本录入。
- 参数配置样例：



- 过滤样例：
比如按关键词测试进行过滤。
加工前: {"text": "关键词测试这是一条测试数据。"}
加工后: {"text": "关键词这是一条数据。"}

敏感词过滤

- 适用的文件格式：“文本类”。
- 各参数说明：
待过滤内容类型：对文本中涉及黄色、暴力、政治等敏感数据进行自动检测和过滤，需要预置敏感词。过滤粒度支持按字符、段落、文档进行过滤，默认勾选字符
- 参数配置样例：

2

 **敏感词过滤** 对文本中涉及黄色、暴力、政治等敏感数据进行自动检测和过滤。

过滤粒度

☒ 字符 ☐ 文档 ☐ 段落

- 过滤样例：
加工前: {"text": " 嫖客啊fuck测试"}
加工后: {"text": "啊测试"}

文本长度过滤

- 适用的文件格式：“文本类”。
- 各参数说明：
待过滤内容类型：按照设置的文本长度，保留长度范围内的数据。默认待保留字符的长度范围为100-1000字符，支持修改。
- 参数配置样例：

2

 **文本长度过滤** 保留文本长度在指定范围内的数据

待保留字符的长度范围

100

-

1,000

字符

- 过滤样例：
加工前: {"text": " 测试长度"}
加工后: {"text": " "}

冗余信息过滤

- 适用的文件格式：“文本类”。
- 各参数说明：
待过滤内容类型：按照段落粒度，删除文本中的冗余信息，不改变数据条目。支持过滤的内容类型包括图注表注、参考文献，默认全都勾选，也支持选择部分。

N-gram 特征过滤

- 适用的文件格式：“文本类”。

- 各参数说明：
待过滤内容类型：按照文档过滤粒度，可以选择top-gram过滤和gram重复率过滤，默认勾选top-gram过滤。其中top-gram过滤方式特征N值默认2，特征阈值默认0.18，gram重复率过滤方式特征N值默认2，特征阈值默认0.15，支持修改。
- 参数配置样例：

2 N-gram特征过滤 根据选择的算法进行内容过滤，不满足设定条件，则过滤

过滤粒度

选择N-gram特征过滤算法

☒ 文档

☒ top-gram过滤

☐ gram重复率过滤

特征N值: 2

特征阈值: 0.18

特征N值: 2

特征阈值: 0.15

- 过滤样例：
加工前: {"text": "醒醒，今天星期天，今天不上班，今天放假，明天星期一，明天上班。"}
加工后: {"text": ""}

段落特征过滤

- 适用的文件格式：“文本类”。
- 各参数说明：
待过滤内容类型：按照文档过滤粒度，根据段落重复率、重复段落长度占比、非中文字符占比进行过滤，如果没有同时满足则过滤。默认值分别为段落重复率小于等于65%、重复段落长度占比小于等于65%、非中文字符占比1-50%，支持修改。
- 参数配置样例：

2 段落特征过滤 根据设定的条件进行内容过滤，如果没有同时满足，则过滤

过滤粒度

段落重复率

重复段落长度占比

非中文字符占比

☒ 文档

小于等于: 65 %

小于等于: 65 %

1 - 50 %

- 过滤样例：
加工前: {"text": "传说中，狐狸只对那些心地纯洁、愿望真诚的人显现。它会在月光下优雅地出现，用那双闪烁着智慧光芒的眼睛注视着来者。只有当狐狸感受到来者的真诚和纯洁，它才会开口说话，询问他们的愿望。然而，愿望的实现并非没有代价。每一个愿望的实现都需要付出相应的代价。这个代价可能是珍贵的记忆，可能是深爱的事物，甚至可能是生命的一部分。因此，村民们在许愿之前，必须慎重考虑，是否愿意承担这样的代价。传说中，狐狸只对那些心地纯洁、愿望真诚的人显现。它会在月光下优雅地出现，用那双闪烁着智慧光芒的眼睛注视着来者。只有当狐狸感受到来者的真诚和纯洁，它才会开口说话，询问他们的愿望。然而，愿望的实现并非没有代价。每一个愿望的实现都需要付出相应的代价。这个代价可能是珍贵的记忆，可能是深爱的事物，甚至可能是生命的一部分。因此，村民们在许愿之前，必须慎重考虑，是否愿意承担这样的代价。"}
加工后:

句子特征过滤

- 适用的文件格式：“文本类”。
- 各参数说明：
待过滤内容类型：按照文档过滤粒度，根据待保留的平均句长进行过滤，如果不满足则过滤。待保留的平均句长默认值为大于等于10个字符，支持修改。

参数配置样例：

2 句子特征过滤 根据设定的条件进行内容过滤，如果没有满足，则过滤

过滤粒度

待保留的平均句长

☒ 文档

大于等于： 10 字符

算子说明：将文档中的标点符号作为句子分隔符，统计每句字符长度，若文档平均字符长度大于设置字符，则保留，反之则删除整篇文档

过滤样例：

加工前: { “text”:"在一个小村庄里，有一个传说。传说中，每当满月之夜，村庄的森林里会出现一只神秘的狐狸。” }
加工后: {“text” :“”}

词语特征过滤

- 适用的文件格式：“文本类”。
- 各参数说明：
待过滤内容类型：按照文档过滤粒度，根据待保留的词个数（默认50-100000字符）、待保留的平均词长度（默认50-100000字符）进行过滤，如果没有同时满足则过滤。支持修改默认值。
- 参数配置样例：

2 词语特征过滤 根据设定的条件进行内容过滤，如果没有同时满足，则过滤

过滤粒度

待保留的词个数 ①

待保留的平均词长度 ②

☒ 文档

50 - 100,000 字符

50 - 100,000 字符

算子说明：词个数表示按照系统词库，对文档进行分词，分词后统计词的总个数，平均词长度为所有词的长度总和除以词总个数，两者都满足则保留当前文档

- 过滤样例：
加工前: {“text”:"传说中，狐狸只对那些心地纯洁、愿望真诚的人显现。”}
加工后: {“text”：“ ”}

段落结尾不完整句子过滤

- 适用的文件格式：“文本类”。
- 各参数说明：
待过滤内容类型：按照句子的过滤粒度，自动识别段落结尾处的内容是否完整，如果不完整，则过滤。
- 参数配置样例：

2 段落结尾不完整句子过滤 自动识别段落结尾处内容是否完整，如果不完整，则过滤

过滤粒度

☒ 句子

- 过滤样例：
加工前:"JAVA是一种面向对象的程序设计语言。使用JAVA语言。”
加工后：“JAVA是一种面向对象的程序设计语言。”

广告数据过滤

- 适用的文件格式：“文本类”。
- 各参数说明：
待过滤内容类型：按照句子的过滤粒度，删除文本中包含广告数据的句子。
- 参数配置样例：



- 过滤样例：
加工前: {"text": "※具体优惠信息! ※购买我们的产品, 享受高达50%的折扣!
点击链接获取低价:<https://example.com>不要错过这个机会, 赶快行动吧!"}
加工后: {"text": ""}

QA 对过滤

- 适用的文件格式：“文本类”。
- 各参数说明：
待过滤内容类型：过滤问题不是string格式、回答为空、回答无意义的QA对。
- 参数配置样例：
不需要配置参数。



- 过滤样例:
加工前: { "text": " [{"context": "你好", "target": "对对对"} , {"context": "列表", "target": ""}] }
加工后: { "text": " [{"context": "你好", "target": "对对"}] }

语种过滤

- 适用的文件格式：“文本类”。
- 各参数说明：
待过滤内容类型：按照文档过滤粒度，根据待保留语种、待删除阈值文档字段进行过滤，如果满足则过滤。待保留语种默认中文，支持选择英文，待删除阈值文档默认值小于0.65，支持修改。
- 参数配置样例：



- 过滤样例：
加工前: {"text": "Hello, my name is Li Ming. I am excited to introduce myself and share a bit about who I am."}
加工后: {"text": ""}

全局文本去重

- 适用的文件格式：“文本类”。
- 各参数说明：
待过滤内容类型：检测并去除数据中重复或高度相似的文本，防止模型过拟合或泛化性降低。
- 参数配置样例：
不需要配置参数。
- 过滤样例：
加工前: [{"fileName": "文本1.txt", "text": "传说中，狐狸只对那些心地纯洁、愿望真诚的人显现。"}, {"fileName": "文本2.txt", "text": "传说中，狐狸只对那些心地纯洁、愿望真诚的人显现。"}]
加工后: [{"fileName": "文本1.txt", "text": "传说中，狐狸只对那些心地纯洁、愿望真诚的人显现。"}]

SFT 通用语义质量评分

- 适用的文件格式：“文本类-单轮问答、单轮问答（人设）、问答排序”。
- 各参数说明：
待过滤内容类型：通过LLM对SFT数据质量做通用语义检查和打分，并可根据打分阈值进行过滤。需要选择模型，是否过滤字段取值是与否，默认为否，阈值取值范围在0.0~10.0之间，小于该值的样本将被过滤掉。阈值默认值为6，支持修改。
- 过滤样例：
加工前: {"system": "你是一个计算达人", "context": "根据给定的两个城市之间的距离，计算旅行所需的时间。起始城市：北京，目的地城市：上海，距离：1318公里。\\n", "target": "根据不同出行方式，北京到上海的旅行时间不同。如果乘坐高铁，大约需要5-6小时；如果乘坐飞机，大约需要2小时左右；如果驾车，大约需要13-14小时左右。"} {"system": "你是一个问答小能手", "context": "在给定的一篇文章中，找到特定关键词的出现次数。\\n文章：今年世界杯期间，许多人会熬夜观看比赛。\\n关键词：世界杯\\n", "target": "关键词\\\"世界杯\\\"在文章中出现了1次。"}
加工后: {"context": "在给定的一篇文章中，找到特定关键词的出现次数。\\n文章：今年世界杯期间，许多人会熬夜观看比赛。\\n关键词：世界杯\\n", "filter": 0.0, "qa_quality_score": {"reason": "大模型正确地识别出关键词\\\"世界杯\\\"在文章中出现了1次，并且给出了正确的答案。", "score": 10.0}, "system": "你是一个问答小能手", "target": "关键词\\\"世界杯\\\"在文章中出现了1次。"}]

SFT 规则质检过滤

- 适用的文件格式：“文本类-单轮问答、单轮问答（人设）、问答排序”。
- 各参数说明：
待过滤内容类型：通过所选规则对SFT数据质量进行检查并过滤。过滤规则包括内容是字符串、长文本被截断、内容不完整、中英文混杂、繁简混杂、包含重复内

容、包含特殊符号、括号不对齐、重复pattern、乱码符号、中英文回复不统一、敏感模型身份、没有慢思考，默认全部勾选，也可以选择部分规则。是否过滤字段取值是和否，默认为否。

- 过滤样例：

加工前：{"context":"你好，请介绍自己","target":"我是盘古hello world"}

{"context":"诗仙指的是哪位诗人","target":"你好！繁體字在這裡"}

加工后：

SFT 思维链质量评分

- 适用的文件格式：“文本类-单轮问答、单轮问答（人设）、问答排序”。

- 各参数说明：

待过滤内容类型：通过LLM对SFT数据中的思维链做质量检查和打分，并可根据打分阈值进行过滤。需要选择模型，是否过滤字段取值是和否，默认值为否，阈值取值范围在0.0~10.0之间，小于该值的样本将被过滤掉。阈值默认值为6，支持修改。数据判断规则、数据打分规则支持编辑，最大字符1000。

- 过滤样例：

加工前：{"context":"context内容","targets":["hello""hi","你好"]}

加工后：{"context":"context内容""targets":["hello""hi","你好"],"qa_cot_score":
{{"result":"错误","score":0.0,"reason":["模型回答不相关"]},{
"result":"错误","score":0.0,"reason":["回答不相关"]},{
"result":"错误","score":0.0,"reason":["模型回答不相关"]}}}

预训练文本分类

- 适用的文件格式：“文本类-预训练文本”。

- 各参数说明：

待打标内容类型：针对预训练文本进行内容分类，例如新闻、教育、健康等类别，支持分析语种包括：中文、英文，默认中文。

- 参数配置样例：

2  预训练文本分类 针对预训练文本进行内容分类，例如新闻、教育、健康等等

待分析的文本语种

☒ 中文 ☐ 英文

- 打标样例：

{"fileName":"新闻打标测试.docx","text": " 本报北京3月3日电(记者徐佩玉)中国人民银行发布的今年1月份金融市场运行情况显示，1月份，我国债券市场共发行各类债券51027.5亿元。其中，国债发行10185.0亿元,地方政府债券发行5575.7亿元，金融债券发行7042.1亿元，公司信用类债券发行12791.7亿元，信贷资产支持证券发行27.3亿元，同业存单发行15147.8亿元。\\n 截至1月末,我国债券市场托管余额178.2万亿元。其中，银行间市场托管余额156.9万亿元，交易所市场托管余额21.3万亿元。\\n在债券市场对外开放方面,截至1月末，境外机构在中国债券市场的托管余额4.2万亿元，占中国债券市场托管余额的比重为2.3%。其中，境外机构在银行间债券市场的债券托管余额4.1万亿元：分券种看，境外机构持有国债2.0万亿元、占比48.8%，同业存单1.1万亿元、占比25.8%，政策性银行债券0.9亿元、占20.8%。\\n","pre_classification":"经济"}

通用质量评估

- 适用的文件格式：“文本类-预训练文本”。
- 各参数说明：
待打标内容类型：针对文本进行通用质量的评估，例如流畅度、清晰度、丰富度等。需要选择模型、行业，其中行业支持手输。
- 参数配置样例：

2 通用质量评估 针对文本进行通用质量的评估，例如流畅度、清晰度、丰富度等

模型选择

行业

Pangu-NLP-

请输入

- 打标样例：

```
{"fileName":"新闻打标测试.docx","text":" 本报北京3月3日电(记者徐佩玉)中国人民银行发布的今年1月份金融市场运行情况显示,1月份,我国债券市场共发行各类债券51027.5亿元。其中,国债发行10185.0亿元,地方政府债券发行5575.7亿元,金融债券发行7042.1亿元,公司信用类债券发行12791.7亿元,信贷资产支持证券发行27.3亿元,同业存单发行15147.8亿元。\\n 截至1月末,我国债券市场托管余额178.2万亿元。其中,银行间市场托管余额156.9万亿元,交易所市场托管余额21.3万亿元。\\n在债券市场对外开放方面,截至1月末,境外机构在中国债券市场的托管余额4.2万亿元,占中国债券市场托管余额的比重为2.3%。其中,境外机构在银行间债券市场的债券托管余额4.1万亿元;分券种看,境外机构持有国债2.0万亿元、占比48.8%,同业存单1.1万亿元、占比25.8%,政策性银行债券0.9万亿元、占比20.8%。\\n","generalscore":{"教育价值":"5","清洁度":"5","isIncorrect":"false","毒性":"false","丰富度":"5","流畅度":"5","knowledge":"5"}}
```

问题时效性评估

- 适用的文件格式：“文本类-单轮问答”。
- 各参数说明：
待打标内容类型：判断问题是否具有时效性，并给出判断原因。需要选择模型。
- 参数配置样例：

2 问题时效性评估 判断问题是否具有时效性，同时给出判断原因

模型选择

Pangu-NLP-↑

- 打标样例：

```
{"context":"1-1-2江苏的省会在哪里?","target":"南京","timeliness_classification":0}
```

回答质量评分

- 适用的文件格式：“文本类-单轮问答”。
- 各参数说明：

待打标内容类型：针对微调数据集的回答进行质量评分，例如逻辑连贯性、事实正确性等。需要选择模型。

- 参数配置样例：

2

 回答质量评分 针对微调数据集的回答进行质量评分，例如逻辑连贯性、事实正确性等

模型选择

Pangu-NLP-I

- 打标样例：

```
{"context":"1-2-1中国的首都是哪里? ", "target":"北京","answer score":{"逻辑连贯性":10,"综合得分":10,"满足用户需求":10,"完备性":10,"事实正确性":10}}
```

语法质量评估

- 适用的文件格式：“文本类-单轮问答”。
- 各参数说明：

待打标内容类型：针对文本进行语法质量的评估，例如相关性、规范性等。需要选择模型。
- 参数配置样例：

2

 语法质量评估 针对文本进行语法质量的评估，例如相关性、规范性等等

模型选择

Pangu-NLP-I

- 打标样例：

```
{"target":"北京","context":"1-2-1中国的首都是哪里?","grammar score":{"回复与问题不相关":0,"事实错误":0,"违反逻辑规则":0,"语言不规范":0,"语句截断":0,"不当的多语混用":0,"无意义的重复":0}}
```

4.5.8.1.2 视频类加工算子介绍

数据加工算子为用户提供了多种数据操作能力，包括数据提取、过滤、转换、打标签等。这些算子能够帮助用户从海量数据中提取出有用信息，并进行深度加工，以生成高质量的训练数据。

平台支持视频类数据集的加工操作，分为数据提取、数据过滤、数据打标三类，视频类加工算子能力清单见[表4-30](#)。

表 4-30 视频类加工算子能力清单

算子分类	算子名称	算子描述
数据提取	镜头拆分	根据视频中的镜头场景变化将长视频拆分为短视频片段，如果某个镜头片段的长度超过设定的时间阈值，该镜头片段将按时长进行进一步拆分。

算子分类	算子名称	算子描述
数据转换	添加水印	为视频添加全屏文字水印。
	视频裁剪	视频裁剪是裁剪掉视频中不必要的元素，比如字幕、Logo、水印、边框和密集文字，同时过滤掉那些裁剪后面积比例超出预设阈值的视频文件；使用前需要先执行字幕、logo、水印、边框、密集文字识别算子。
数据过滤	视频元数据过滤	根据视频元数据（帧率、分辨率和视频时长）进行过滤，仅保留符合选定条件的视频。注：电影标准帧率为24或30FPS。
	视频宽高比过滤	根据视频的宽高比进行过滤。宽高比是指视频图像的宽度和高度之间的比率。
数据打标	色情视频检测算子	给色情视频内容打标签
	暴恐视频检测算子	给暴恐视频内容打标签
	视频涉政评分算子	给涉政视频内容打标签
	运动幅度评分	通过计算每个像素在每一帧中的移动范围进行评分，识别运动幅度过快（如>100光流）或过慢（如≤2光流）的视频，数值越大表示运动越快。
	质量评分	对视频的基础质量（清晰度、亮度、模糊、画面抖动重影、低光过曝、花屏等）进行评分。分值范围(0, 1)，数值越高质量越好，评分>0.05可认为是视频基础质量较高的视频。
	美学评分	从内容（吸引人，清晰度）、构图（目标物位置良好）、颜色（有活力，令人愉悦）、光线（光线明显有对比度）、轨迹（连续、稳定）等维度评价视频美感得分。分值范围(0, 1)，数值越高美感越好，评分>0.95可视为视频基础质量较高的视频。
	水印识别	识别视频中是否包含水印。
	字幕识别	识别视频中是否包含字幕。
	Logo识别	识别视频中是否包含Logo。
	视频黑边识别	识别视频中是否包含黑边。
	密集文字识别	识别视频中是否包含密集文字，超出密集文字面积占比阈值的视频可视为密集文字视频，一般默认裁剪面积占比≥7%为密集文字视频。
	视频分类（InterVid eo2）	通过算子返回视频的标签分类，L1存在7类，L4存在700类。

算子分类	算子名称	算子描述
	视频摘要生成（简略）	通过对视频进行抽帧，通过模型推理生成简短的视频摘要描述。
	视频摘要生成（详细）	通过对视频进行抽帧，通过模型推理生成详细的视频摘要描述。

镜头拆分

- 适用的文件格式：“视频>mp4 / avi”。
- 各参数说明：
需要拆分的视频：筛选出分辨率、时长、帧率同时满足筛选标准的视频进行镜头拆分。
视频拆分后规格：单视频切片最大时长支持自定义；若首轮拆分切片时长超过设定值，则会进一步做拆分，最终拆分结果均小于等于设定阈值。

添加水印

- 适用的文件格式：“视频>mp4 / avi”。
- 各参数说明：
水印文本：string类型，需要全屏添加的水印文本。

视频裁剪


- 适用的文件格式：“视频>mp4 / avi”。
- 各参数说明：
裁剪项：自定义选择裁剪项，裁剪掉视频中字幕/Logo/水印/边框/密集文字等无用信息。
裁剪面积占比过滤：裁剪视频面积/原始视频面积的值即裁剪面积占比，超出设定阈值的视频将被过滤，默认值为30%。

视频元数据过滤


- 适用的文件格式：“视频>mp4 / avi”。

视频宽高比过滤

- 适用的文件格式：“视频>mp4 / avi”。
- 各参数说明：
待过滤宽高比阈值：超出“宽高比阈值”的视频将被过滤掉。阈值范围为(1, 10)，可输入小数点后一位。
过滤样例：
原视频数据集：
共有两个视频，第一个宽高比为1.77，第二个宽高比为1.79



设置宽高比阈值为1.78，经算子处理过后



仅保留宽高比为1.79的视频

色情视频检测算子

- 适用的文件格式：“视频>mp4 / avi”。
- 算子说明：给色情视频内容打标签
- 参数配置样例：
不需要配置参数。
- 检测样例：
检测结果以video_anti_porn对象存储在标注文件中：
suggestion:对文件检测是否通过的结果，pass代表审核通过无相应的问题；review代表需要人工复核，您可以按照您的审核策略选择放通还是拦截；block代表待审文件存在问题。

confidence:模型结果检测的置信度（注意这里的置信度代表模型给出建议的置信度）。如果suggestion为pass，则为零；如果suggestion为review/block，则为0-1。

label:模型检测出的具体色情标签，如果未检测出则为空

```
描述信息
{
  "file_name": "Porn_bad.mp4",
  "video_anti_porn": {
    "results": [
      {
        "category": "porn",
        "confidence": 0.736,
        "label": "porn"
      }
    ],
    "suggestion": "review"
  },
  "time": "00:00:03"
}
```

暴恐视频检测算子

- 适用的文件格式：“视频>mp4 / avi”。
- 算子说明：给暴恐视频内容打标签
- 参数配置样例：

不需要配置参数。

- 检测样例：检测结果以video_anti_terrorism对象存储在标注文件中：

suggestion:对文件检测是否通过的结果，pass代表审核通过无相应的问题；review代表需要人工复核，您可以按照您的审核策略选择放通还是拦截；block代表待审文件存在问题。

confidence:模型结果检测的置信度（注意这里的置信度代表模型给出建议的置信度）。如果suggestion为pass，则为零；如果suggestion为review/block，则为0-1。

label:模型检测出的具体暴恐标签，如果未检测出则为空

描述信息

```
{
  "file_name": "terrorism_bad.mp4",
  "video anti terrorism": {
    "results": [
      {
        "category": "terrorism",
        "confidence": 0.9961,
        "label": "bloody"
      }
    ],
    "suggestion": "block"
  },
  "time": "00:00:16"
}
```

视频涉政评分算子

- 适用的文件格式：“视频>mp4 / avi”。

- 算子说明：

给涉政视频内容打标签

- 参数配置样例：

不需要配置参数。

- 检测样例：

检测结果以video_anti_politics对象存储在标注文件中：

suggestion:对文件检测是否通过的结果，pass代表审核通过无相应的问题；review代表需要人工复核，您可以按照您的审核策略选择放通还是拦截；block代表待审文件存在问题。

result:模型对文件检测的具体返回内容，包含suggestion、confidence、label三个子标签；可以一条或多条

confidence:模型结果检测的置信度（注意这里的置信度代表模型给出建议的置信度）。如果suggestion为pass，则为零；如果suggestion为review/block，则为0-1。

label:模型检测出的具体涉政标签，如果未检测出则为空。

```

描述信息
{
  "file_name": "police01.mp4",
  "video_politics": {
    "results": [
      {
        "category": "politics",
        "confidence": 0.736,
        "label": "politics"
      }
    ],
    "suggestion": "review"
  },
  "time": "00:01:54"
}

```

运动幅度评分

- 适用的文件格式：“视频>mp4 / avi”。
- 评分说明：
识别运动幅度过快或过慢的视频，数值越大表示运动越快。运动幅度 > 100光流可视为运动过快，运动幅度 ≤ 2光流可视为运动过慢。
- 评分样例：jsonl文件中显示运动幅度评分：

[illegible]

质量基础评分

- 适用的文件格式：“视频>mp4 / avi”。
- 评分说明：
对视频的基础质量（清晰度、亮度、模糊、画面抖动重影、低光过曝、花屏等）进行评分。分值范围(0, 1)，数值越高质量越好，评分>0.05可认为是视频基础质量较高的视频。
- 评分样例：jsonl文件中显示质量评分：clip_quality_value：质量分

- 适用的文件格式：“视频>mp4 / avi”。
- 评分说明：
从内容（吸引人，清晰度）、构图（目标物位置良好）、颜色（有活力，令人愉悦）、光线（光线明显有对比度）、轨迹（连续、稳定）等维度评价视频美感得分。分值范围(0, 1)，数值越高美感越好，评分>0.95可视为视频美感较高的视频。
- 评分样例：jsonl文件中显示美学评分：clip_esthetics_value：美学分

- 评分样例: jsonl文件中显示美学评分: clip_esthetics_value: 美学分

[illegible]

- 适用的文件格式：“视频>mp4 / avi”。
- 算子说明：
识别视频中是否包含水印。
- 识别样例：jsonl文件中显示是否识别水印：consist_watermark值为1表示识别到水印，值为0表示未识别到水印。

- 识别样例: jsonl文件中显示是否识别水印: consist_watermark值为1表示识别到水印, 值为0表示未识别到水印。

[illegible]

- 适用的文件格式：“视频>mp4 / avi”。
- 算子说明：
识别视频中是否包含字幕。
- 识别样例：jsonl文件中显示是否识别字幕：consist_subtitle值为1表示识别到字幕，值为0表示未识别到字幕。

- 识别样例：jsonl文件中显示是否识别字幕：consist_subtitle值为1表示识别到字幕，值为0表示未识别到字幕。

[illegible]

- 适用的文件格式：“视频>mp4 / avi”。
- 算子说明：
识别视频中是否包含Logo。
- 识别样例：jsonl文件中显示是否识别logo：consist_logo值为1表示识别到Logo，值为0表示未识别到Logo。

- 识别样例：json文件中显示是否识别logo：consist_logo值为1表示识别到Logo，值为0表示未识别到Logo。

- 适用的文件格式：“视频>mp4 / avi”。
- 算子说明：
识别视频中是否包含黑边。
- 识别样例：border_value为1表示识别出黑边，值为0表示未识别出黑边

- 适用的文件格式：“视频>mp4 / avi”。
- 参数说明：
密集文字面积占比：超出密集文字面积占比阈值的视频可视为密集文字视频，一般默认裁剪面积占比≥7%为密集文字视频。
- 识别样例：jsonl文件中显示是否识别密集文字：consist_densetext值为1表示识别到密集文字，值为0表示未识别到密集文字。

- 适用的文件格式：“视频>mp4 / avi”。
- 算子说明：
自动对短视频内容进行分类，并生成相应的标签
- 参数配置样例：
无需配置参数
- 分类标注样例：
描述信息中显示视频的各级分类：
category_L1_cn:一级分类
category_L4_cn:四级分类

- 适用的文件格式：“视频>mp4 / avi”。
- 算子说明：
通过对视频进行抽帧，通过模型推理生成详细的视频摘要描述


- 参数配置样例：
 无需参数配置
- 打标样例：描述信息中long_prompt字段代表详细的视频摘要。



视频摘要生成（简略）

- 适用的文件格式：“视频>mp4 / avi”。
- 算子说明：
 通过对视频进行抽帧，通过模型推理生成简略的视频摘要描述。
- 参数配置样例：
 无需参数配置
- 打标样例：描述信息中prompt字段代表简略的视频摘要。

图 4-70 打标样例



4.5.8.1.3 图片类加工算子介绍

数据加工算子为用户提供了多种数据操作能力，包括数据提取、过滤、转换、打标签等。这些算子能够帮助用户从海量数据中提取出有用信息，并进行深度加工，以生成高质量的训练数据。

平台提供了图文类、图片类加工算子，算子能力清单见表4-31。

表 4-31 图片类加工算子能力清单

算子分类	算子名称	算子描述
数据提取	图文提取	提取图文压缩包中的JSON文本和图片，并对图片进行结构化解析（BASE64编码），方便图文加工算子使用。
数据过滤	图片元数据过滤	基于图片宽高、文件大小、宽高比阈值进行图片/图文数据清洗。
	图文文本长度过滤	过滤文本长度不在“文本长度范围”内的图文对。一个中文汉字或一个英文字母，文本长度均计数为1。
	图文文本语言过滤	通过语种识别模型得到图文对的文本语种类型，“待保留语种”之外的图文对数据将被过滤。 注：语种识别模型有小概率的误判可能性。
	图文去重	- 基于结构化图片去重图文。 - 判断相同文本对应不同的图片数据是否超过“单文本最大图片数阈值”阈值，如果超过则随机删除多余图片，仅保留阈值以内的图文数量。
	图片去重	通过把图片结构化处理后，过滤重复的图片/图文对数据。
数据打标	色情图像检测算子	给图像算子打标签
	危情图像检测算子	给危情图片内容打标签
	暴恐图像检测算子	过滤暴恐图像
数据转换	图文异常字符过滤	将文本数据中携带的异常字符替换为空值，数据条目不变。 - 不可见字符，例如U+0000-U+001F - 网页标签符号<p>
	添加水印	为图像覆盖以特定角度排列、具有固定间距的半透明水印文字

图文提取

- 适用的文件格式：
tar+jsonl；所有图片保存为tar包。图片格式支持：jpg、jpeg、png、bmp。图片文本保存为一份jsonl文件，jsonl文件中图片名称必须要与tar包中的图片名称一致。
- 各参数说明：
待提取内容类型：提取图文压缩包中的JSON文本和图片；并对图片进行结构化解析。
- 参数配置样例：
不需要配置参数。

图片元数据过滤

- 适用的文件格式：
jpg、jpeg、png、bmp
tar：所有图片保存为tar包。tar包含图片支持：jpg、jpeg、png、bmp图片类型。
- 各参数说明：
待过滤内容类型：
最小宽高：宽或高任意一边低于此设置值，图片会被过滤
最小文件大小：文件大小低于该文件大小会被过滤，单位为B

图文文本长度过滤

- 适用的文件格式：
tar+jsonl：所有图片保存为tar包。图片支持：jpg、jpeg、png、bmp图片类型
图片文本保存为一份jsonl文件，jsonl文件中图片名称必须要与tar包中的图片名称一致
- 各参数说明：
待过滤内容类型：过滤文本长度不在”文本长度范围”内的图文对。一个中文汉字或一个英文字母，文本长度统计为1。

图文文本语言过滤

- 适用的文件格式：
tar+jsonl：所有图片保存为tar包。图片支持：jpg、jpeg、png、bmp图片类型
图片文本保存为一份jsonl文件，jsonl文件中图片名称必须要与tar包中的图片名称一致
- 各参数说明：
待过滤内容类型：提取图文压缩包中的JSON文本和图片，并对图片进行结构化解析（BASE64编码），方便图文加工算子使用

图文去重

- 适用的文件格式：
tar+jsonl：所有图片保存为tar包。图片支持：jpg、jpeg、png、bmp图片类型
图片文本保存为一份jsonl文件，jsonl文件中图片名称必须要与tar包中的图片名称一致
- 各参数说明：
待过滤内容类型：
 - a. 基于结均化图片去重图文。
 - b. 判断相同文本对应不同的图片数据是否超过单文本最大图片数阈值，如果超过则随机删除多余图片，仅保留阈值以内的图文数量。

图片去重

- 适用的文件格式：
jpg、jpeg、png、bmp

tar: 所有图片保存为tar包。tar包含图片支持: jpg、jpeg、png、bmp图片类型;

- 各参数说明:
待过滤内容类型: 通过把图片结构化处理后, 过滤重复的图片/图文对数据
- 参数配置样例:
不需要配置参数

色情图像检测算子

- 适用的文件格式:
jpg、jpeg、png、bmp
tar: 所有图片保存为tar包。tar包含图片支持: jpg、jpeg、png、bmp图片类型;
- 各参数说明:
待打标内容类型: 对图片的涉黄程度进行评分, 分数越高越危险。评分范围(0. 100), 默认评分 ≥ 50 分的视频可视为涉黄视频。
- 参数配置样例:
不需要配置参数
- 检测样例:
检测结果以image_porn对象存储在标注文件中:
suggestion:对文件检测是否通过的结果, pass代表审核通过无相应的问题;
review代表需要人工复核, 您可以按照您的审核策略选择放通还是拦截; block代表待审文件存在问题。
confidence:模型结果检测的置信度(注意这里的置信度代表模型给出建议的置信度)。如果suggestion为pass, 则为零; 如果suggestion为review/block, 则为0-1。
label:模型检测出的具体色情标签, 如果未检测出则为空。

描述信息

```
{
  "tar_name": "data.tar",
  "file_name": "1259.jpg",
  "image_format": "jpg",
  "height": 336,
  "width": 336,
  "size": 24438,
  "base_id": "2d6dcc7c-2ee0-4928-95a8-97ece90c1134",
  "wh_ratio": 1,
  "image_porn": {
    "results": [
      {
        "category": "porn",
        "confidence": 0.9956,
        "label": "sexy"
      }
    ],
    "suggestion": "block"
  },
  "filter": 0
}
```

危情图像检测算子

- 适用的文件格式：
jpg、jpeg、png、bmp
tar: 所有图片保存为tar包。tar包含图片支持：jpg、jpeg、png、bmp图片类型；
- 各参数说明：
待打标内容类型：给危情图片内容打标签
- 参数配置样例：
不需要配置参数
- 检测样例：检测结果以image_danger对象存储在标注文件中：
suggestion:对文件检测是否通过的结果，pass代表审核通过无相应的问题；review代表需要人工复核，您可以按照您的审核策略选择放通还是拦截；block代表待审文件存在问题。
confidence:模型结果检测的置信度（注意这里的置信度代表模型给出建议的置信度）。如果suggestion为pass，则为零；如果suggestion为review/block，则为0-1。
label:模型检测出的具体危情标签，如果未检测出则为空。

描述信息

```
{
  "tar_name": "data.tar",
  "file_name": "图片1.png",
  "image_format": "png",
  "height": 720,
  "width": 466,
  "size": 893658,
  "base_id": "14ef093e-1ff8-4757-bc15-0963b51ca56a",
  "wh_ratio": 0.6472222222,
  "image_danger": {
    "results": [
      {
        "category": "terrorism",
        "confidence": 0.9941,
        "label": "riot"
      }
    ],
    "suggestion": "block"
  },
  "filter": 0
}
```

暴恐图像检测算子

- 适用的文件格式：
jpg、jpeg、png、bmp
tar：所有图片保存为tar包。tar包含图片支持：jpg、jpeg、png、bmp图片类型；
- 各参数说明：
待打标内容类型：过滤暴恐图像
- 参数配置样例：
不需要配置参数
- 检测样例：检测结果以image_terrorism对象存储在标注文件中：
suggestion:对文件检测是否通过的结果，pass代表审核通过无相应的问题；review代表需要人工复核，您可以按照您的审核策略选择放通还是拦截；block代表待审文件存在问题。
confidence:模型结果检测的置信度（注意这里的置信度代表模型给出建议的置信度）。如果suggestion为pass，则为零；如果suggestion为review/block，则为0-1。
label:模型检测出的具体暴恐标签，如果未检测出则为空

描述信息

```
{
  "tar_name": "data.tar",
  "file_name": "BA202310100126_6_0_Im0.png",
  "image_format": "png",
  "height": 279,
  "width": 652,
  "size": 59206,
  "base_id": "47c0346e-6dd8-47b6-89e6-1dabab4384e6",
  "wh_ratio": 2.3369175627,
  "image_terrorism": {
    "results": [
      {
        "category": "terrorism",
        "confidence": 0.9941,
        "label": "riot"
      }
    ],
    "suggestion": "block"
  },
  "filter": 0
}
```

图文异常字符过滤

- 适用的文件格式：
tar+jsonl：所有图片保存为tar包。图片支持：jpg、jpeg、png、bmp图片类型
图片文本保存为一份jsonl文件，jsonl文件中图片名称必须要与tar包中的图片名称一致
- 各参数说明：
待转换内容类型：将文本数据中携带的异常字符替换为空值，数据条目不变。
- 参数配置样例：
不需要配置参数

添加水印

- 适用的文件格式：
jpg、jpeg、png、bmp
tar：所有图片保存为tar包。tar包含图片支持：jpg、jpeg、png、bmp图片类型；
- 各参数说明：
水印文本：String类型，水印文本。
- 转换样例：
打标分数以element字段存储于jsonl格式文件中。

4.5.8.1.4 气象类加工算子介绍

平台支持气象类数据集的加工操作，气象类加工算子能力清单见表4-32。

表 4-32 气象类加工算子能力清单

算子分类	算子名称	算子描述
科学计算	气象预处理	将二进制格式的气象数据文件转换成结构化JSON数据。

气象预处理

- 适用的文件格式：
式：.nc、.cdf、.netcdf、.gr、.gr1、.grb、.grib、.grib1、.grib1、.gr2、.grb2、.grib2。
- 算子说明：将二进制格式的气象数据文件转换成结构化JSON数据。
- 参数配置样例：
- 过滤样例：
加工后：

```
["total_size": 145364716, "geo_range": {"lon": [0.0, 360.0], "lat": [-90.0, 90.0]}, "time_range": [1641146400000, 1641146400000], "forcing_types": ["TERRAIN_HEIGHT", "SOIL_TYPE", "LAND_MASK", "OCEAN_MASK"], "surface_features": [], "surface_constants": [{"TERRAIN_HEIGHT", "SOIL_TYPE", "LAND_MASK", "OCEAN_MASK"}, {"upper_air_layers": [{"1000hPa", "1000hPa", "1500hPa", "1750hPa", "2000hPa", "2500hPa", "3000hPa", "4000hPa", "5000hPa", "500hPa", "6000hPa", "7000hPa", "8500hPa", "9250hPa"}, {"upper_air_features": [{"Q", "T", "U", "V", "Z"}], "under_sea_features": [], "under_sea_depths": []}]
```

4.5.8.1.5 音频类加工算子介绍

平台支持音频类数据集的加工操作，音频类加工算子能力清单见表4-33。

表 4-33 音频类加工算子能力清单

算子分类	算子名称	算子描述
数据转换	噪声添加	给音频添加噪声
	噪声抑制	移除音频中的纯噪声片段并进行降噪。
	音调变化	调整原始音频的音调
	混响减少	减少声音在空间中的混响效果，提高语音可懂度。
	语音匿名化	对音频进行匿名化处理，匿名化后的音频与原始说话人音色和声纹有明显区分度。
	语音降噪	对原始音频进行降噪，且只考虑噪声与人声叠加的情况，对于纯噪声音频或者纯噪声片段，不做约束。
	语速调整	调整音频中的说话速度。

算子分类	算子名称	算子描述
数据打标	语音风格转换	对原始音频依据给定的目标风格进行转换。
	音频量化编码	将一个高分辨率的含有头信息的音频文件，通过音频编解码技术、量化压缩技术转换成 16k 采样率 alaw/ulaw/pcm/wav 文件。
	语音语种识别标注	识别音频中说话人所使用的语种，并给出相应的置信度。
	普通话语音转文本	将普通话语音快速转化为文本，以丰富人机交互场景。
	语音情绪识别标注	识别输入音频中说话人的情绪。
	语音端点检测	检测音频中多段人声各自的起止时间。
	噪声水平评估	对含有人声片段的音频进行质量打分。
	静默片段检测	识别音频中的静音片段及置信度，并给出静音片段的占比。
	多说话人语音识别	识别音频内容，返回每个说话人说话的起止时间及对应内容。
	个人隐私对话识别	给个人隐私语音内容打标签。
	违禁语音检测	给违禁语音内容打标签。
	政治敏感语音识别	给政治敏感语音内容打标签。
	色情语音内容检测	给色情语音内容打标签。

噪声添加

- 适用的文件格式：纯音频，60s内采样率16k的wav音频文件。
- 算子说明：给音频添加噪声
- 各参数说明：
噪声类型：添加的噪声类型，混合噪声为高斯噪声与椒盐噪声的叠加
信噪比: 正常声音信号强度与噪声信号强度的比值

噪声抑制

- 适用的文件格式：纯音频，30s内采样率16k、位深16bit单通道的wav音频文件。
- 算子说明：移除音频中的纯噪声片段并进行降噪。
- 参数配置样例：
不需要配置参数。

音调变化

- 适用的文件格式：纯音频，60s内的音频文件。
- 算子说明：调整原始音频的音调
- 各参数说明：
音调：音调参数

混响减少

- 适用的文件格式：纯音频，60s内采样率16k的wav音频文件。
- 算子说明：减少声音在空间中的混响效果，提高语音可懂度。
- 参数配置样例：
不需要配置参数

语音匿名化

- 适用的文件格式：纯音频，30s内采样率16k、位深16bit单通道的wav音频文件。
- 算子说明：对音频进行匿名化处理，匿名化后的音频与原始说话人音色和声纹有明显区分度。
- 参数配置样例：
不需要配置参数

语音降噪

- 适用的文件格式：纯音频，采样率16k、位深16bit单通道的wav音频文件。
- 算子说明：对原始音频进行降噪，且只考虑噪声与人声叠加的情况，对于纯噪声音频或者纯噪声片段，不做约束。
- 参数配置样例：
不需要配置参数

语速调整

- 适用的文件格式：纯音频，60s内的wav音频文件。
- 算子说明：调整音频中的说话速度。
- 各参数说明：
语速：语速参数，取值在 0.5~2 之间

语音风格转换

- 适用的文件格式：纯音频，50MB内的音频文件。
- 算子说明：对原始音频依据给定的目标风格进行转换。
- 各参数说明：
语音风格：转换后的语音风格

音频量化编码

- 适用的文件格式：纯音频，100MB内的音频文件。
- 算子说明：将一个高分辨率的含有头信息的音频文件，通过音频编解码技术、量化压缩技术转换成 16k 采样率 alaw/ulaw/pcm/wav 文件。

- 参数配置样例：
不需要配置参数

语音语种识别标注

- 适用的文件格式：纯音频，60s内采样率16k、位深16bit的wav音频文件。
- 算子说明：识别音频中说话人所使用的语种，并给出相应的置信度。
- 参数配置样例：
不需要配置参数

普通话语音转文本

- 适用的文件格式：纯音频，60s内的音频文件。
- 算子说明：将普通话语音快速转化为文本，以丰富人机交互场景。
- 各参数说明：
标点：识别结果是否添加标点符号
数字转换：是否将语音中的数字识别为阿拉伯数字
是否分词信息：识别结果是否包含分词结果信息

语音情绪识别标注

- 适用的文件格式：纯音频，60s内采样率16k、位深16bit的wav音频文件。
- 算子说明：识别输入音频中说话人的情绪。
- 参数配置样例：
不需要配置参数

语音端点检测

- 适用的文件格式：纯音频，600s内采样率16k、位深16bit的wav音频文件。
- 算子说明：检测音频中多段人声各自的起止时间。
- 参数配置样例：
不需要配置参数

噪声水平评估

- 适用的文件格式：纯音频，60s内采样率16k、位深16bit的wav音频文件。
- 算子说明：对含有人声片段的音频进行质量打分。
- 参数配置样例：
不需要配置参数

静默片段检测

- 适用的文件格式：纯音频，600s内采样率16k、位深16bit的音频文件。
- 算子说明：识别音频中的静音片段及置信度，并给出静音片段的占比。
- 参数配置样例：
不需要配置参数

多说话人语音识别

- 适用的文件格式：纯音频，1小时内、单通道的音频文件。
- 算子说明：识别音频内容，返回每个说话人说话的起止时间及对应内容。
- 各参数说明：
标点：识别结果是否添加标点符号
数字转换：是否将语音中的数字识别为阿拉伯数字
分词信息：识别结果是否包含分词结果信息
话者分离：识别结果是否包含说话人信息
语速：识别结果是否包含说话人语速信息

个人隐私对话识别

- 适用的文件格式：纯音频，60s内的音频文件。
- 算子说明：给个人隐私语音内容打标签。
- 参数配置样例：
不需要配置参数

违禁语音检测算子

- 适用的文件格式：纯音频，60s内的音频文件。
- 算子说明：给违禁语音内容打标签。
- 参数配置样例：
不需要配置参数

政治敏感语音识别

- 适用的文件格式：纯音频，60s内的音频文件。
- 算子说明：给政治敏感语音内容打标签。
- 参数配置样例：
不需要配置参数

色情语音内容检测算子

- 适用的文件格式：纯音频，60s内的音频文件。
- 算子说明：给色情语音内容打标签。
- 参数配置样例：
不需要配置参数

4.5.8.2 自定义数据集加工算子

除了预置的加工算子外，ModelArts Studio平台还支持用户创建自定义加工算子，以满足特定的数据处理需求和业务场景，用户可以根据实际情况灵活定义处理逻辑，进一步提升模型训练的效果和适应性。

约束限制

该功能仅对包年/包月订购用户开放。

图 4-71 申请试用



图 4-72 包年包月资源




创建“自定义加工算子”

创建自定义加工算子步骤如下：

1. 登录ModelArts Studio大模型开发平台，在“我的空间”模块，单击进入所需空间。

图 4-73 我的空间



2. 在左侧导航栏中选择“数据工程 > 数据加工 > 加工任务”，单击界面右上角“管理加工算子”。
3. 在“加工算子管理 > 自定义”页面，单击右上角“创建自定义算子”。
4. 在“创建自定义算子”页面，单击“下载样例”可查看算子配置文件与算子包的规格说明，使用 OBS 服务上传算子配置文件与算子包，设置空间可见性后，单击右下角“确定”，完成自定义算子的创建。

图 4-74 创建自定义算子

加工任务 / 管理加工算子 / 创建自定义算子

< | 创建自定义算子

算子上传

算子配置文件上传

OBS

输入OBS存储路径或点击浏览选择位置

文件大小不超过1MB 下载样例

算子包上传

OBS

输入OBS存储路径或点击浏览选择位置

文件大小不超过20GB 下载样例

空间可见性

☒ 本空间

☐ 全空间

算子在指定空间可见

5. 创建成功的自定义算子可在[加工文本类数据集](#)、[加工图片类数据集](#)、[加工视频类数据集](#)、[加工气象类数据集](#)、[加工其他类数据集](#)时选择使用。

查看算子详情：

单击算子名称，查看算子详情信息。

算子配置文件规范

表 4-34 基本信息配置规范

参数名称	类型	是否必填	描述	约束
id	string	是	算子英文简称。	以英文字符开头，可包含英文字符、阿拉伯数字和下划线“_”，字符长度不超过128，超过部分自动截断。 算子更新配置时不可修改id。 全空间可见算子id全空间唯一，本空间可见算子id在当前空间下唯一。
name	string	是	算子展示名称。	字符长度不超过128，超过部分自动截断。

参数名称	类型	是否必填	描述	约束
description	string	否	算子描述。	字符长度不超过2000，超过部分自动截断。
author	string	否	开发者名称。	字符长度不超过128，超过部分自动截断
tags	tags object	是	算子标签，用于分类筛选。	见表4-35。
labels	Array of label objects	否	打标算子输出的标签。	见表 label配置规范。
runtime	runtime object	是	算子运行配置。	见表4-36。
arguments	Array of argument objects	否	算子输入参数列表。	见表4-38。

表 4-35 tag 配置规范

参数名称	类型	是否必填	描述	约束
language	Array of strings	是	算子支持处理的数据语种列表，例如zh，en等。	单个字符串长度不超过32，超过部分自动截断。 填写国际语种简码。
format	Array of strings	是	算子支持处理的数据集文件格式后缀列表，例如json，csv，mp4等。	单个字符串长度不超过32，超过部分自动截断。
category	string	是	算子类别。	单选，可选取值如下： - 数据提取 - 数据抽样 - 数据转换 - 数据过滤 - 数据去重 - 数据打标 - 其他

参数名称	类型	是否必填	描述	约束
modal	Array of strings	是	算子支持处理的数据模态列表。	多选，可选取值如下： - TEXT（文本） - IMAGE（图片） - VIDEO（视频） - AUDIO（音频） - OTHER（含气象、预测）
custom	Array of strings	否	用户自定义算子标签列表。	单个字符串长度不超过32，超过部分自动截断。

表 4-36 runtime 配置规范

参数名称	类型	是否必填	描述	约束
cpu-arch	Array of strings	是	算子运行支持的CPU架构列表。	多选，可选取值如下： - ARM - X86
xpu-devices	Array of strings	否	算子运行的支持卡设备型号列表，当算子运行涉及NPU时必填。	可选取值如下： - SNT9B 当参数runtime.resources中存在某个resource的npn个数大于0的情况时，该参数必填，可选值为SNT9B。
environment	string	是	算子包类型，仅支持纯python算子包类型。	单选，可选取值如下： - PYTHON
entrypoint	string	是	算子运行的启动命令。	字符长度不超过128，超过部分自动截断。 当environment=python时填写固定名称process.py，暂不支持修改。
auto-data-loading	boolean	是	是否自动加载数据	当值为true时，由框架处理输入输出；当值为false时，由用户自己处理输入输出。
resources	Array of resource objects	否	算子单实例运行所需的资源大小配置列表。	当environment=python时必填。

表 4-37 resource 配置规范

参数名称	类型	是否必填	描述	约束
cpu	integer	是	单实例默认CPU资源量（单位：vCPU）。	用户需结合实际订购的通算单元数量进行配置。
memory	integer	是	单实例默认memory资源量（单位：MB）。	用户需结合实际订购的通算单元数量进行配置。
npu	integer	否	单实例默认NPU资源量（单位：卡）。	用户需结合实际订购的智算单元规格和数量进行配置。

表 4-38 argument 配置规范

参数名称	类型	是否必填	描述	约束
key	string	是	参数id，参数列表内必须唯一。	字符长度不超过128，超过部分自动截断。
name	string	是	参数展示名称。	字符长度不超过128，超过部分自动截断。
type	string	是	参数类型。	单选，可选取值如下： - STRING - FLOAT - INT - ENUM（单选） - LIST（复选） - OBS（前端使用，选择OBS文件的前端组件参数） - BOOLEAN
tips	string	否	参数说明。	字符长度不超过2000，超过部分自动截断。
min	float	否	参数最小值。当type= INT或FLOAT时选填。	浮点数最多保留4位小数。
max	float	否	参数最小值。当type= INT或FLOAT时选填。	浮点数最多保留4位小数。

参数名称	类型	是否必填	描述	约束
between	boolean	否	参数是否为范围型数值参数。当 type= INT 或 FLOAT时选填，默认为false。	-
items	Array of item objects	否	参数枚举项列表。当type= ENUM / LIST时必填。	当type= ENUM /LIST时该参数必填且枚举项个数至少为1。
required	boolean	否	参数是否必填。	填写true或者false。
visible	boolean	否	参数是否前端可见。	填写true或者false。
default	string	否	参数默认值。	当visible=false且 requires=true时必须填默认值。 多个默认值时用逗号分隔，例如“SD,HD”。 数值范围型参数默认值格式为"min;max"。

表 4-39 item 配置规范

参数名称	类型	是否必填	描述	约束
name	string	是	枚举项名称。	字符长度不超过128，超过部分自动截断。
value	string	是	枚举项对应的值。	字符长度不超过128，超过部分自动截断。
tips	string	否	枚举项描述或说明。	字符长度不超过2000，超过部分自动截断。

表 4-40 label 配置规范

参数名称	类型	是否必填	描述	约束
key	string	是	标签的key值。	字符长度不超过128，超过部分自动截断，key值在不同算子间唯一。
name	string	是	标签的名称。	字符长度不超过128，超过部分自动截断。

参数名称	类型	是否必填	描述	约束
type	string	是	标签的类型。	枚举值，单选，仅支持STRING、NUMERIC、ENUM、OBJECT
min	float	否	标签最小值	当type为NUMERIC型时必填。
max	float	否	标签最大值	当type为NUMERIC型时必填。
items	Array of labelItem objects	否	标签枚举列表	当type为ENUM型时必填。
dimensions	Array of labelDimension objects	否	标签一级维度	当type为OBJECT型必填。

表 4-41 labelItem 配置规范

参数名称	类型	是否必填	描述	约束
name	string	是	枚举名称。	字符长度不超过128，超过部分自动截断。
value	string	是	枚举值。	字符长度不超过128，超过部分自动截断。

表 4-42 labelDimension 配置规范

参数名称	类型	是否必填	描述	约束
key	string	是	二级标签key。	字符长度不超过128，超过部分自动截断。
name	string	是	二级标签名称。	字符长度不超过128，超过部分自动截断。
type	string	是	二级标签类型。	枚举值，单选，仅支持STRING、NUMERIC、ENUM
min	float	否	二级标签的最小值。	当type为NUMERIC型时必填。

参数名称	类型	是否必填	描述	约束
max	float	否	二级标签的最大值。	当type为NUMERIC型时必填。
items	Array of labelItem objects	否	二级标签的枚举列表。	当type为ENUM型时必填。

算子配置文件是一个YAML文件，用于描述算子的基本信息、功能参数、运行环境以及资源需求等。算子配置文件示例如下：

```
id: video_clip #【必填】算子英文简称，英文字母开头，只能包含英文字符、数字和下划线，最多128个字符，超过做截断
name: 视频Clip切分 #【必填】算子展示名称，最多128个字符，超过做截断
description: 将长视频按镜头切分为多个片段。 #算子描述，不超过2000个字符
author: "xxx Technology Co., Ltd." #可选，开发者或团队名称，例如 "Data Team"，不超过128个字符
tags: #【必填】算子标签，用于特定场景分类筛选
  language: #【必填】算子支持处理的语言类型，语言简码，多选，选项只能选择国际标准语言简码，不超过32个字符
    - zh
    - en
    - ...
  format: #【必填】算子支持处理的数据集文件格式，多选，不超过32个字符
    - JSONL
    - TXT
    - CSV
    - HTML
    - MOBI
    - EPUB
    - DOCX
    - PDF
    - MP4
    - AVI
    - ...
  category: #【必填】算子类型，用于前台的算子分类展示，单选，选项固定如下
    - 数据提取
    - 数据抽样
    - 数据转换
    - 数据过滤
    - 数据去重
    - 数据打标
    - 其他
  modal: #【必填】算子支持处理的数据模式。多选，选项固定如下
    - TEXT
    - IMAGE
    - VIDEO
    - AUDIO
    - OTHER
  custom: #用户自定义算子标签，多选，不超过32个字符
    - 数据增强
    - 预标注
    - ...
runtime:
  cpu-arch: #【必填】支持的CPU列表
    - ARM
    - X86
  xpu-devices: #算子支持的卡设备型号，可多选，选项固定如下【涉及NPU必填】
    - SNT9B
  resources: #单实例默认资源量，当算子包类型为python时必填。
    - cpu: 16 #对应CPU处理器类型
      memory: 256
    - cpu: 8 #对应NPU处理器类型
```

```
memory: 1024 # 单位MB
npu: 1
environment: python # 【必填】算子包类型，支持python（纯python算子包）类型。
entrypoint: process.py # 【必填】当environment=python时固定名称process.py，暂不支持修改
#所有的业务参数均为算子的输入参数，参数的数据类型包含：STRING、FLOAT、INT、ENUM（单选框）、LIST（复选框）、OBS
arguments:
# STRING类型参数示例
- key: filter_keywords # 【必填】
  name: 过滤关键词
  type: STRING
  tips: 命中的关键词所在的样本将会被过滤，多个关键词以英文字符","分隔。 #界面tips
  required: true
  visible: true
  default: 大保健 #参数默认值,可选，多个默认值使用,隔开

# INT/FLOAT数值范围类型参数示例
- key: length_of_characters # 【必填】
  name: 过滤时长范围
  type: FLOAT # 【必填】当type=int/float时，between字段为必填。
  between: true # 是否取数值范围，当type=int/float时，between字段为必填。
  min: 1.0 #参数最小值的范围，可选；float最多【4位小数】，超过做截断
  max: 500.0 #参数最大值的范围，可选
  tips: 过滤时长范围包含填入的边界值，float类型，单位：字符。文本长度在指定范围内的样本将被保留。 #界面tips
  required: true
  visible: true
  default: 100.0;300.0 #可选，参数最大最小值的默认值，可选，未填写时使用"min;max"作为默认

# INT/FLOAT数值类型参数示例
- key: max_cropping_area_ratio
  name: 最大裁剪面积占比
  type: FLOAT
  between: false # 是否是范围型，默认为false
  min: 0.0 #参数最小值的范围
  max: 100.0 #参数最大值的范围
  tips: 值在0.0~100.0之间，float类型，单位：%。裁剪面积占比（裁剪视频面积/原始视频面积）大于该值的样本将被过滤掉。
  visible: true
  required: true
  default: 100 #参数默认值

# ENUM类型参数示例
- key: font_conversion
  name: 文本字体转换
  type: ENUM #单选
  items:
    - name: 简体转繁体
      value: traditional
    - name: 繁体转简体
      value: simplified
  required: true
  visible: true
  default: simplified

# LIST类型参数示例
- key: resolution
  name: 分辨率
  type: LIST #可多选
  items: #参数选项，ENUM/LIST类型必填
    - name: 流畅 # 【必填】
      value: SM # 【必填】
      tips: 480>分辨率≥360
    - name: 标清
      value: SD
      tips: 720>分辨率≥480
    - name: 高清
      value: HD
      tips: 1080>分辨率≥720
```

```
required: true
visible: true
default: SD,HD # 多个默认值使用,隔开

# OBS类型参数示例
- key: sensitive_word
  name: 敏感词库文件OBS路径
  type: OBS
  tips: 敏感词库文件。
  required: true
  visible: true
  default: NLP/system_resource/sensitive_word.csv # 默认词库的OBS路径。
# BOOLEAN类型参数示例
- key: parse_all
  name: 是否解析所有文件
  type: BOOLEAN
  items:
    - name: 是
      value: true
    - name: 否
      value: false
  visible: true
  required: true
  default: false
```

算子包规范

Python算子包

假设算子包名称为video_clip.tar，算子包解压后目录结构：

```
+--- video_clip # 与tar包名称保证一致
| +--- program_package # python算子目录
| | +--- install.sh # 安装脚本，可选
| | +--- process.py # 算子代码，必填
```


4.5.9 管理加工后的数据集

完成数据加工、数据合成、数据标注或数据配比任务的数据集，在对应任务列表执行“生成”操作，将生成“加工数据集”被平台统一管理，并用于后续的发布任务。

平台支持对加工数据集查看基本信息、数据血缘等管理操作，具体步骤如下：

- 1. 登录ModelArts Studio大模型开发平台，在“我的空间”模块，单击进入所需空间。

图 4-75 我的空间



2. 在左侧导航栏中选择“数据工程 > 数据管理 > 数据集 > 加工数据集”。
3. 单击数据集名称查看加工数据集的基本信息、数据预览、数据血缘以及操作记录。
 - 在“基本信息”页签，可以查看数据详情、数据来源以及扩展信息。在拓展信息内，可以根据用户需求设置数据集属性，包括数据集属性名称、行业、语言、自定义标签。
 - 在“数据预览”页签可查看加工后的数据内容。
 - 在“数据血缘”页签查看该数据集所经历的操作，如导入、合成等操作。
 - 在“操作记录”页签可以查看数据集所经历的操作及状态等信息。
4. 单击操作列的“删除”，可删除不需要的数据集。
 - 如果需要恢复删除的数据集，可单击右上角“显示已删除数据”，被删除的数据集将在列表显示，可将数据集恢复。
 - 如果需要彻底删除数据集，可单击数据集名称进入详情页，确认数据集内容后彻底删除该数据集。

 说明

删除“加工数据集”属于高危操作，删除前，请确保该数据集不再使用。

4.5.10 管理加工任务资源

与MRS相关的加工任务、发布任务在创建时，可以进行任务资源的参数配置，具体的参数可见[表1 任务资源参数清单](#)。

表 4-43 任务资源参数清单


参数名称	参数描述
executorCores	Spark应用每个Executor的CPU核数。
numExecutors	Spark应用Executor的个数。
executorMemory	Spark应用的Executor内存，参数配置例如：2G，2048M。
driverCores	Spark应用Driver的CPU核数。该配置项会替换“sc_type”中对应的默认参数。
driverMemory	Spark应用的Driver内存，参数配置例如：2G，2048M。

4.5.11 加工任务生成数据集

加工任务详情页面增加生成数据集相关提示。


1. 当加工任务执行结束且没有生成数据集时，页面提供生成数据集按钮。

图 4-76 生成数据集按钮



2. 当任务无生成数据集且处理生成数据集中状态时，提供刷新按钮。

图 4-77 刷新按钮



3. 当加工任务最新一次执行任务成功，且没有生成最新数据集时，页面提示：任务数据已经刷新，如果要保存最新结果，请单击生成加工数据集。

4.6 发布数据集

4.6.1 数据集发布场景介绍

数据发布介绍

ModelArts Studio大模型开发平台提供的数据发布功能涵盖数据评估和数据发布操作，旨在通过数据质量评估，确保数据满足大模型训练的多样性、平衡性和代表性需求，促进数据的高效流通和应用。

数据发布不仅包括将数据发布为适合使用的格式，还要求根据任务需求评估数据集效果，确保数据集在规模、质量和内容上符合模型训练的标准。

- **数据评估**
平台预置了多种数据类型的基础评估标准，用户可根据需求选择预置标准或自定义评估标准，从而精确优化数据质量，确保数据满足高标准，提升模型性能。
- **数据发布**

数据发布是将数据集发布为特定格式的“发布数据集”，用于后续模型训练等操作。支持的发布格式为标准格式、盘古格式（适用于训练盘古大模型时）。目前，仅文本类和图片类数据集支持发布为“盘古格式”。

通过这些功能，平台能够帮助用户科学管理和发布数据集，确保数据集质量符合大模型训练的需求，从而提高后续模型训练的效果。

数据发布意义

数据发布不仅仅是将数据转换为不同格式，还包括根据任务需求评估数据集效果，确保数据在规模、质量和内容上满足训练标准。具体而言，数据发布具备以下几个重要意义：

- 多格式支持**
对于文本类、图片类数据集，平台支持多种数据发布格式，包括“标准格式”、“盘古格式”，以满足不同训练任务的需求。通过这些格式的转换，用户可以确保数据与特定模型（如盘古大模型）兼容，并优化训练效果。
- 提高训练效率**
发布符合标准的数据集可以大幅提升数据处理效率，减少后续调整工作，帮助用户快速进入模型训练阶段。

数据集发布是数据工程中的关键环节，确保数据集符合模型训练要求。通过平台提供的数据发布功能，用户能够根据具体任务需求，灵活选择数据发布格式，保证数据的兼容性与一致性，从而为后续模型训练和应用部署打下坚实基础。

支持数据发布的数据集类型

支持数据发布的数据集类型见[表4-44](#)。

表 4-44 支持数据发布的数据集类型

数据类型	数据评估	数据发布
文本类	√	√
图片类	√	√
视频类	√	√
气象类	-	√
预测类	-	√
其他类	-	√

ModelArts Studio大模型开发平台支持将**文本类、图片类数据集**发布为两种格式：

- 标准格式**：适用于广泛的数据使用场景，满足大多数模型训练的标准需求。该格式的数据集将发布到资产中，但下游模型开发不可见。
- 盘古格式**：专为盘古大模型训练设计的格式，确保数据集在盘古模型训练中的兼容性和一致性。该格式的数据集将被用于ModelArts Studio大模型开发平台的模型开发功能使用。

除文本类、图片类数据集外，其余类型的数据集当前仅支持发布为标准格式。

4.6.2 发布文本类数据集

4.6.2.1 评估文本类数据集

发布文本类数据集前，ModelArts Studio大模型开发平台支持对数据集进行评估操作，帮助用户优化数据质量，确保数据满足高标准，提升模型性能。

如果无需使用数据评估操作，可跳过此章节至[发布文本类数据集](#)。

创建文本类数据集评估标准

ModelArts Studio大模型开发平台针对文本类数据集预设了一套基础评估标准，涵盖了数据准确性、完整性、一致性、格式规范等多个维度，用户可以直接使用该标准或在该标准的基础上创建评估标准。

若您希望使用平台预置的评估标准，可跳过此章节至[创建文本类数据集评估任务](#)。

创建文本类数据集评估标准步骤如下：

1. 登录ModelArts Studio大模型开发平台，在“我的空间”模块，单击进入所需空间。

图 4-78 我的空间



2. 在左侧导航栏中选择“数据工程 > 数据管理 > 数据评估”，在“人工评估标准”页签，平台预置了文本类数据集评估标准“NLP数据质量标准 V1.0”，单击评估标准名称，可以查看具体的评估项。

图 4-79 预置文本类数据集评估标准



- 3. 在“人工评估标准”页面，单击“创建自定义标准”，选择预置标准作为参考项，并填写“评估标准名称”和“描述”。
- 4. 编辑评估项。
用户可以基于实际需求删减评估项，或创建自定义评估项。创建自定义评估项时，需要将评估类别、评估项、评估项说明填写清晰，填写时确保描述无歧义。
- 5. 单击“完成创建”以创建评估标准。
评估标准创建完成后可以在“人工评估标准”页面查看创建的评估标准，并支持编辑与删除操作。

创建文本类数据集评估任务


平台仅支持对“加工数据集”执行评估操作。

创建文本类数据集评估任务前，请参考[加工文本类数据集](#)，生成一个“加工数据集”。

创建文本类数据集评估任务步骤如下：

- 1. 登录ModelArts Studio大模型开发平台，在“我的空间”模块，单击进入所需空间。

图 4-80 我的空间



2. 在左侧导航栏中选择“数据工程 > 数据管理 > 数据评估”，单击界面右上角“创建评估任务”。
3. 选择需要评估的加工数据集，并设置抽样样本的数量。
4. 单击“下一步”，选择评估标准。单击“下一步”设置评估人员，单击“下一步”填写任务名称。
5. 单击“完成创建”，将返回至“数据评估”页面，评估任务创建成功后状态将显示为“已创建”。
6. 单击操作列的“评估”，进入评估页面。
7. 在评估页面，可参考评估项对当前数据的问题进行标注，且满足则单击“通过”，不满足则单击“不通过”。

如图4-81，对于文本类数据集而言，可选中问题内容后，右键标记数据问题。

图 4-81 标记数据集问题



8. 全部数据评估完成后，在“人工评估”页面可查看评估进展为“100%”。单击操作列“报告”，可查看数据集质量评估报告。

4.6.2.2 发布文本类数据集

数据发布是将数据集发布为特定格式的“发布数据集”的过程，用于后续模型训练等操作。

文本类数据集支持发布的格式为：

- **标准格式：**数据工程功能支持的原始格式。

标准格式的示例如下，其中，**context**和**target**是键值对。
`{"context": "你好，请介绍自己", "target": "我是盘古大模型"}`


● **盘古格式：**训练盘古大模型时，需要将数据集格式发布为“盘古格式”。

盘古格式的示例如下，其中，**context**和**target**是键值对。与标准格式不同，**context**是一个数组。
`{"context": ["你好，请介绍自己"], "target": "我是盘古大模型"}`
- 创建文本类数据集发布任务
- 创建文本类数据集发布任务步骤如下：
1. 登录ModelArts Studio大模型开发平台，在“我的空间”模块，单击进入所需空间。
- 文档版本 01 (2025-07-28)

版权所有 © 华为云计算技术有限公司

152

图 4-82 我的空间



- 2. 在左侧导航栏中选择“数据工程 > 数据发布 > 发布任务”，单击界面右上角“创建发布任务”。
- 3. 在“创建发布任务”页面，选择数据集模式，如“文本 > 预训练文本”类型的数据集。

图 4-83 选择数据集模式



- 4. 选择数据集，单击“下一步”。
 - 5. 在“基本配置”中选择数据用途、数据集可见性、使用场景。
- 由于数据工程需要支持对接盘古大模型，为了使这些数据集能够被这些大模型正常训练，平台支持发布不同格式的数据集。

当前支持标准格式、盘古格式：


- **标准格式**：数据工程功能支持的原始格式。该格式的数据集可发布到资产中，但下游模型开发不可见。在“使用场景”为“其他”使用。
- **盘古格式**：使用盘古大模型训练时所需要使用的数据格式，该数据集将被用于ModelArts Studio大模型开发平台的模型开发中使用。在“使用场景”为“STUDIO模型训练”时使用。

说明

如果使用该数据集训练盘古大模型，请将选择格式配置为**盘古格式**。

- 6. 填写数据集名称、描述，设置扩展信息后，单击“下一步”，进入任务配置。
 - 7. 任务配置可以进行资源配置。
- 下拉高级设置，可以设置任务资源。也支持自定义参数配置，单击添加参数，输入参数名称和参数值。

图 4-84 资源配置



8. 任务配置完毕后，单击“确定”，发布数据集。当任务状态显示为“运行成功”时，说明数据发布任务执行成功，生成的“发布数据集”可在“数据工程 > 数据管理 > 数据集 > 发布数据集”中查看。

4.6.3 发布图片类数据集

4.6.3.1 评估图片类数据集

发布图片类数据集前，ModelArts Studio大模型开发平台支持对数据集进行评估操作，帮助用户优化数据质量，确保数据满足高标准，提升模型性能。

如果无需使用数据评估操作，可[跳过此章节至发布图片类数据集](#)。

创建图片类数据集评估标准

ModelArts Studio大模型开发平台针对图片类数据集预设了一套基础评估标准，涵盖了图像清晰度、分辨率、标签准确性、图像一致性等多个质量维度，用户可以直接使用该标准或在该标准的基础上创建评估标准。

若您希望使用平台预置的评估标准，可[跳过此章节至创建图片类数据集评估任务](#)。

创建图片类数据集评估标准步骤如下：

1. 登录ModelArts Studio大模型开发平台，在“我的空间”模块），单击进入所需空间。

图 4-85 我的空间



2. 在左侧导航栏中选择“数据工程 > 数据管理 > 数据评估”，在“人工评估标准”页签，平台预置了图片类数据集评估标准“图片数据质量标准 V1.0”，单击评估标准名称，可以查看具体的评估项。

图 4-86 预置图片类数据集评估标准



3. 在“人工评估标准”页面，单击“创建自定义标准”，选择预置标准作为参考项，并填写“评估标准名称”和“描述”。
4. 编辑评估项。
用户可以基于实际需求删减评估项，或创建自定义评估项。创建自定义评估项时，需要将评估类别、评估项、评估项说明填写清晰，填写时确保描述无歧义。
5. 单击“完成创建”以创建评估标准。
评估标准创建完成后可以在“人工评估标准”页面查看创建的评估标准，并支持编辑与删除操作。

创建图片类数据集评估任务


平台仅支持对“加工数据集”执行评估操作。

创建图片类数据集评估任务前，请参考[加工图片类数据集](#)，生成一个“加工数据集”。

创建图片类数据集评估任务步骤如下：

1. 登录ModelArts Studio大模型开发平台，在“我的空间”模块，单击进入所需空间。

图 4-87 我的空间



- 在左侧导航栏中选择“数据工程 > 数据管理 > 数据评估”，单击界面右上角“创建评估任务”。
- 选择需要评估的加工数据集，并设置抽样样本的数量。
- 单击“下一步”，选择评估标准。单击“下一步”设置评估人员，单击“下一步”填写任务名称。
- 单击“完成创建”，将返回至“数据评估”页面，评估任务创建成功后状态将显示为“已创建”。
- 单击操作列的“评估”，进入评估页面。
- 在评估页面，可参考评估项对当前数据的问题进行标注，且满足则单击“通过”，不满足则单击“不通过”。
- 全部数据评估完成后，在“人工评估”页面可查看评估进展为“100%”。单击操作列“报告”，可查看数据集质量评估报告。

4.6.3.2 发布图片类数据集

数据发布是将数据集发布为特定格式的“发布数据集”的过程，用于后续模型训练等操作。

图片类数据集支持发布的格式为：


- 标准格式：**如图4-88，平台默认的格式。该格式的数据集可发布到资产中，但下游模型开发不可见。

图 4-88 图片类数据集标准格式示例



- 盘古格式：**如图4-89，训练盘古大模型时，需要将数据集格式发布为“盘古格式”，该数据集将被用于ModelArts Studio大模型开发平台的模型开发中使用。

图 4-89 图片类数据集盘古格式示例




创建图片类数据集发布任务

创建图片类数据集发布任务步骤如下：

- 登录ModelArts Studio大模型开发平台，在“我的空间”模块，单击进入所需空间。

图 4-90 我的空间



- 2. 在左侧导航栏中选择“数据工程 > 数据发布 > 发布任务”，单击界面右上角“创建发布任务”。
- 3. 在“创建发布任务”页面，选择数据集模式，如“图片 > 图片+Caption”类型的数据集。

图 4-91 选择数据集模式



- 4. 选择数据集，单击“下一步”。
 - 5. 在“基本配置”中选择数据用途、数据集可见性、适用场景。
- 由于数据工程需要支持对接盘古大模型，为了使这些数据集能够被这些大模型正常训练，平台支持发布不同格式的数据集。

当前支持标准格式、盘古格式：


- **标准格式：**数据工程功能支持的原始格式。该格式的数据集可发布到资产中，但下游模型开发不可见。
- **盘古格式：**使用盘古大模型训练时所需要使用的数据格式，该数据集将被用于ModelArts Studio大模型开发平台的模型开发中使用。

说明

如果使用该数据集训练盘古大模型，请将发布格式配置为**盘古格式**。

- 6. 根据数据集是否进行拆分，勾选“数据集拆分”。如勾选，设置好训练集和验证集的比例，如图4-92所示：

图 4-92 数据集拆分示例



7. 填写数据集名称、描述，设置扩展信息后，单击“确定”执行数据集发布操作。
当任务状态显示为“运行成功”时，说明数据发布任务执行成功，生成的“发布数据集”可在“数据工程 > 数据管理 > 数据集 > 发布数据集”中查看。
8. 单击任务id，可以查看发布任务详情。发布任务详情界面包含“基本信息”和“日志管理”2个tab页，其中基本信息又包含“任务详情”、“配置信息”、“数据来源”、“生成数据集”几个部分。在“生成数据集”表格的记录数列表中，展示训练集和验证集各自的数量，如图4-94所示。

图 4-93 查看任务详情



图 4-94 生成数据集表格示例

生成数据集

数据集名称	数据集状态	数据集类型	文件格式	数据集大小	记录数	数据集属性
pub_20250811_4898	文本	原始文本	JSONL	763KB	24	-

4.6.4 发布视频类数据集

4.6.4.1 评估视频类数据集

发布视频类数据集前，ModelArts Studio大模型开发平台支持对数据集进行评估操作，帮助用户优化数据质量，确保数据满足高标准，提升模型性能。

如果无需使用数据评估操作，可跳过此章节至[发布视频类数据集](#)。

创建视频类数据集评估标准

ModelArts Studio大模型开发平台针对视频类数据集预设了一套基础评估标准，涵盖了视频的清晰度、帧率、完整性、标签准确性等多个质量维度，用户可以直接使用该标准或在该标准的基础上创建评估标准。

若您希望使用平台预置的评估标准，可跳过此章节至[创建视频类数据集评估任务](#)。

创建视频类数据集评估标准步骤如下：

1. 登录ModelArts Studio大模型开发平台，在“我的空间”模块，单击进入所需空间。

图 4-95 我的空间



2.
- 在左侧导航栏中选择“数据工程 > 数据管理 > 数据评估”，在“人工评估标准”页签，平台预置了视频类数据集评估标准“视频数据质量标准 V1.0”，单击评估标准名称，可以查看具体的评估项。

图 4-96 预置视频类数据集评估标准



3.
- 在“人工评估标准”页面，单击“创建自定义标准”，选择预置标准作为参考项，并填写“评估标准名称”和“描述”。
4.
- 编辑评估项。
用户可以基于实际需求删减评估项，或创建自定义评估项。创建自定义评估项时，需要将评估类别、评估项、评估项说明填写清晰，填写时确保描述无歧义。
5.
- 单击“完成创建”以创建评估标准。
评估标准创建完成后可以在“人工评估标准”页面查看创建的评估标准，并支持编辑与删除操作。

创建视频类数据集评估任务


平台仅支持对“加工数据集”执行评估操作。

创建视频类数据集评估任务前，请参考[加工视频类数据集](#)，生成一个“加工数据集”。

创建视频类数据集评估任务步骤如下：

1. 登录ModelArts Studio大模型开发平台，在“我的空间”模块，单击进入所需空间。

图 4-97 我的空间



2. 在左侧导航栏中选择“数据工程 > 数据管理 > 数据评估”，单击界面右上角“创建评估任务”。
3. 选择需要评估的加工数据集，并设置抽样样本的数量。
4. 单击“下一步”，选择评估标准。单击“下一步”设置评估人员，单击“下一步”填写任务名称。
5. 单击“完成创建”，将返回至“数据评估”页面，评估任务创建成功后状态将显示为“已创建”。
6. 单击操作列的“评估”，进入评估页面。
7. 在评估页面，可参考评估项对当前数据的问题进行标注，且满足则单击“通过”，不满足则单击“不通过”。
8. 全部数据评估完成后，在“人工评估”页面可查看评估进展为“100%”。单击操作列“报告”，可查看数据集质量评估报告。

4.6.4.2 发布视频类数据集

数据发布是将数据集发布为特定格式的“发布数据集”的过程，用于后续模型训练等操作。


视频类数据集当前仅支持发布为“标准格式”。

创建视频类数据集发布任务

创建视频类数据集发布任务步骤如下：

1. 登录ModelArts Studio大模型开发平台，在“我的空间”模块，单击进入所需空间。

图 4-98 我的空间



- 2. 在左侧导航栏中选择“数据工程 > 数据发布 > 发布任务”，单击界面右上角“创建发布任务”。
- 3. 在“创建发布任务”页面，选择数据集模式，如“视频 > 仅视频”类型的数据集。

图 4-99 选择数据集模式



- 4. 选择数据集，单击“下一步”。
- 5. 在“基本配置”中选择数据用途、数据集可见性、适用场景。当前视频类数据集仅支持发布标准格式。
- 6. 填写数据集名称、描述，设置扩展信息后，单击“确定”执行数据集发布操作。
当任务状态显示为“运行成功”时，说明数据发布任务执行成功，生成的“发布数据集”可在“数据工程 > 数据管理 > 数据集 > 发布数据集”中查看。

4.6.5 发布音频类数据集

数据发布是将数据集发布为特定格式的“发布数据集”的过程，用于后续模型训练等操作。


音频类数据集当前仅支持发布为“标准格式”。

创建音频类数据集发布任务

创建音频类数据集发布任务步骤如下：

1. 登录ModelArts Studio大模型开发平台，在“我的空间”模块，单击进入所需空间。

图 4-100 我的空间



2. 在左侧导航栏中选择“数据工程 > 数据发布 > 发布任务”，单击界面右上角“创建发布任务”。
3. 在“创建发布任务”页面，选择数据集模式，如“音频 > 仅音频”类型的数据集。

图 4-101 选择数据集模式




4. 选择数据集，单击“下一步”。
5. 在“基本配置”中选择数据用途、数据集可见性、适用场景。当前音频类数据集仅支持发布标准格式。
6. 填写数据集名称、描述，设置扩展信息后，单击“确定”执行数据集发布操作。当任务状态显示为“运行成功”时，说明数据发布任务执行成功，生成的“发布数据集”可在“数据工程 > 数据管理 > 数据集 > 发布数据集”中查看。

4.6.6 发布气象类数据集

操作步骤如下：

1. 登录ModelArts Studio大模型开发平台，在“我的空间”模块，单击进入所需空间。

图 4-102 我的空间



2. 在左侧导航栏中选择“数据工程 > 数据发布 > 发布任务”，单击界面右上角“创建发布任务”。
3. 在“创建发布任务”页面，选择数据集模态，如“气象 > 气象数据”类型的数据集。

图 4-103 选择数据集模态




4. 选择数据集，单击“下一步”。
5. 在“基本配置”中选择数据用途、数据集可见性。
6. 填写数据集名称、描述，设置扩展信息后，单击“确定”执行数据集发布操作。
当任务状态显示为“运行成功”时，说明数据发布任务执行成功，生成的“发布数据集”可在“数据工程 > 数据管理 > 数据集 > 发布数据集”中查看。

4.6.7 发布其他类数据集

操作步骤如下：

1. 登录ModelArts Studio大模型开发平台，在“我的空间”模块，单击进入所需空间。

图 4-104 我的空间



2. 在左侧导航栏中选择“数据工程 > 数据发布 > 发布任务”，单击界面右上角“创建发布任务”。
3. 在“创建发布任务”页面，选择数据集模式，如“其他 > 自定义”类型的数据集。

图 4-105 选择数据集模式



4. 选择数据集，单击“下一步”。
5. 在“基本配置”中选择数据用途、数据集可见性。
6. 填写数据集名称、描述，设置扩展信息后，单击“确定”执行数据集发布操作。
当任务状态显示为“运行成功”时，说明数据发布任务执行成功，生成的“发布数据集”可在“数据工程 > 数据管理 > 数据集 > 发布数据集”中查看。


4.6.8 管理发布后的数据集

完成数据配比、或数据流通任务的数据集，在对应任务列表执行“生成”操作，将生成“发布数据集”被平台统一管理，并用于后续的发布任务。

平台支持对发布数据集查看基本信息、数据血缘等管理操作，具体步骤如下：

1. 登录ModelArts Studio大模型开发平台，在“我的空间”模块，单击进入所需空间。

图 4-106 我的空间



2. 在左侧导航栏中选择“数据工程 > 数据管理 > 数据集 > 发布数据集”。
3. 单击数据集名称查看发布数据集的基本信息、数据预览、数据血缘以及操作记录。
 - 在“基本信息”页签，可以查看数据详情、数据来源以及扩展信息。在拓展信息内，可以根据用户需求设置数据集属性，包括数据集属性名称、行业、语言、自定义标签。
 - 在“数据预览”页签可查看发布后的数据内容。
 - 在“数据血缘”页签查看该数据集所经历的操作，如导入、合成、训练等操作。
 - 在“操作记录”页签可以查看数据集所经历的操作及状态等信息。
4. 单击操作列的“删除”，可删除不需要的数据集。
 - 如果需要恢复删除的数据集，可单击右上角“显示已删除数据”，被删除的数据集将在列表显示，可将数据集恢复。
 - 如果需要彻底删除数据集，可单击数据集名称进入详情页，确认数据集内容后彻底删除该数据集。

说明

删除“发布数据集”属于高危操作，删除前，请确保该数据集不再使用。

4.7 数据集格式转换

4.7.1 使用限制

支持转换的数据集类型

自定义数据集结构：支持图片后缀（jpg、jpeg、png、bmp、tif、tiff）


假设自定义数据集文件名称为：test_自定义数据集


```
+---test_自定义数据集
| +--- 图片001 # python算子目录
| +--- 图片002 # python算子目录
| +--- 图片003 # python算子目录
| +--- CSV文件
```

支持转换的 CV 数据集类型

仅支持自定义数据集转换成图片（物体检测、图像分类）数据集。


图 4-107 导入自定义数据集



4.7.2 格式转换操作流程

- 1. 登录ModelArts Studio平台，在“我的空间”模块，单击进入所需空间。

图 4-108 我的空间



- 2. 在左侧导航栏中选择“数据工程 > 数据获取 > 导入任务”，单击右上角“创建导入任务”。
- 3. 在“创建导入任务”页面选择其他--自定义，导入需要转换数据集，如图4-109所示。

图 4-109 数据导入



- 4. 返回导航栏，选择“数据工程 > 数据加工 > 加工任务 > 管理加工算子 > 创建自定义算子”，如图4-110所示。

图 4-110 创建自定义算子

加工任务 / 管理加工算子 / 创建自定义算子

< | 创建自定义算子

算子上传

算子配置文件上传

OBS

输入OBS存储路径或点击浏览选择位置

文件大小不超过1MB 下载样例

算子包上传

OBS

输入OBS存储路径或点击浏览选择位置

文件大小不超过20GB 下载样例

空间可见性

☒ 本空间 ☐ 全空间

算子在指定空间可见

5. 传入对应的YML文件和TAR包，构建格式转换算子。
6. 返回导航栏，选择“数据工程 > 数据加工>加工任务> 创建加工任务”。
7. 选择数据集和转换算子，开始格式转换加工任务。

说明

1. 物体检测和图像分类支持jpg、jpeg、bmp、png、tif、tiff格式。
2. csv格式为UTF-8 且读取内容在第一个sheet页。

4.7.3 转换算子说明

转换算子构建包括：①YML配置文件 ②实现功能的python脚本TAR包

①YML文件示例：

```
### python算子示例

id: FormatConvert2
name: 自定义算子格式转化
description: 自定义算子格式转化
author: Huawei Cloud Technology Co., Ltd.
tags:
  language:
    - zh
    - en
  format:
    - CSV
    - TIF
  category: 数据转换
  modal:
    - IMAGE
runtime:
  cpu-arch:
    - X86
```

```
resources:
  - cpu: 1
    memory: 4096
  environment: python
  entrypoint: process.py
  auto-data-loading: false # 是否需要自动加载数据
arguments:
  - key: operateType
    name: 操作类型
    type: ENUM #单选
    items:
      - name: 物体检测
        value: object_detection
      - name: 图像分类
        value: image_classification
    required: true
    visible: true
    default: object_detection
    """
  return "parquet"
```

②TAR包:

假设算子包名称为operator-package.tar，算子包解压后目录结构：

```
+---operator-package
| +--- program_package # python算子目录
| | +---dependency
| | | +---requirements.txt #需求说明，可选
| | +--- install.sh # 安装脚本，可选
| | +--- process.py # 算子代码，必填
```

实现格式转换功能的process.py文件

```
import PIL.Image
import PIL.ImageOps
import numpy as np
import ast
import os
import pandas as pd
import xml.etree.ElementTree as ET
from xml.dom import minidom
import PIL
import moxing as mox
import ma_utils as utils

logger = utils.FileLogger.get_logger()

import argparse

arg_parser = argparse.ArgumentParser()
arg_parser.add_argument("--operateType", type=str, required=True, help="")
arg_parser.add_argument("--input_obs_path", type=str, required=True, help="")
arg_parser.add_argument("--output_obs_path", type=str, required=True, help="")

def prettify_xml(elem):
    rough_string = ET.tostring(elem, 'utf-8')
    reparsed = minidom.parseString(rough_string)
    return reparsed.toprettyxml(indent=" ")

def create_pascal_voc_xml(folder, filename, path, width, height, depth, objects, deu, db, dp, ls, lv, lse, lc, srct,
```

```
        srct, src, srr, rct, rrt, rc, rr, dest_engine_uuid=None):
    annotation = ET.Element('annotation')
    # 目的端引擎uuid
    dest_engine_uuid = ET.SubElement(annotation, 'DEST_ENGINE_UUID')
    dest_engine_uuid.text = deu
    # 目的端桶(逻辑分区)
    dest_engine_uuid = ET.SubElement(annotation, 'DEST_BUCKET')
    dest_engine_uuid.text = db
    # 目的端路径
    dest_path = ET.SubElement(annotation, 'DEST_PATH')
    dest_path.text = folder
    # 文件名称
    filename_element = ET.SubElement(annotation, 'FILE_NAME')
    filename_element.text = filename
    # 标签组全路径
    dest_path = ET.SubElement(annotation, 'DEST_PATH')
    dest_path.text = dp
    # 标签组全路径
    label_value = ET.SubElement(annotation, 'LABEL_VALUE')
    label_value.text = lv
    # 标签形状 点 / 线 / 矩形(两点) / 矩形(bbox) / 矩形(中心点) / 多边形 / 轮廓
    label_shape = ET.SubElement(annotation, 'LABEL_SHAPE')
    label_shape.text = ls
    # 标签形状 点 / 线 / 矩形(两点) / 矩形(bbox) / 矩形(中心点) / 多边形 / 轮廓
    label_coordinate = ET.SubElement(annotation, 'LABEL_COORDINATE')
    label_coordinate.text = lc
    # 源端记录创建时间
    rec_time = ET.SubElement(annotation, 'SOURCE_REC_CREATE_TIME')
    rec_time.text = srct
    # 源端记录修改时间
    rec_rev_time = ET.SubElement(annotation, 'SOURCE_REC_REVISE_TIME')
    rec_rev_time.text = srrt
    # 源端记录创建人
    rec_ctor = ET.SubElement(annotation, 'SOURCE_REC_CREATOR')
    rec_ctor.text = src
    # 源端记录修改人
    rec_r_ctor = ET.SubElement(annotation, 'SOURCE_REC_REVISOR')
    rec_r_ctor.text = srr
    # 源端记录创建时间
    d_cd_time = ET.SubElement(annotation, 'REC_CREATE_TIME')
    d_cd_time.text = rct
    # 记录修改时间
    r_time = ET.SubElement(annotation, 'REC_REVISE_TIME')
    r_time.text = rrt
    # 记录创建人
    rec_c = ET.SubElement(annotation, 'REC_CREATOR')
    rec_c.text = rc
    # 记录修改人
    recd_time = ET.SubElement(annotation, 'REC_REVISOR')
    recd_time.text = rr
    tree = ET.ElementTree(annotation)
    return tree
def create_pascal_voc_xml1(folder, filename, path, width, height, depth, objects):
    annotation = ET.Element('annotation')

    folder_element = ET.SubElement(annotation, 'folder')
    folder_element.text = folder

    filename_element = ET.SubElement(annotation, 'filename')
    filename_element.text = filename

    path_element = ET.SubElement(annotation, 'path')
    path_element.text = path

    source = ET.SubElement(annotation, 'source')
    database = ET.SubElement(source, 'database')
    database.text = 'Unknown'

    size = ET.SubElement(annotation, 'size')
```

```
width_element = ET.SubElement(size, 'width')
width_element.text = str(width)
height_element = ET.SubElement(size, 'height')
height_element.text = str(height)
depth_element = ET.SubElement(size, 'depth')
depth_element.text = str(depth)

segmented = ET.SubElement(annotation, 'segmented')
segmented.text = '0'

for obj in objects:
    obj_element = ET.SubElement(annotation, 'object')
    name_element = ET.SubElement(obj_element, 'name')
    name_element.text = obj['name']

    pose = ET.SubElement(obj_element, 'pose')
    pose.text = 'Unspecified'

    truncated = ET.SubElement(obj_element, 'truncated')
    truncated.text = '0'

    difficult = ET.SubElement(obj_element, 'difficult')
    difficult.text = '0'

    bndbox = ET.SubElement(obj_element, 'bndbox')
    xmin = ET.SubElement(bndbox, 'xmin')
    xmin.text = str(obj['xmin'])
    ymin = ET.SubElement(bndbox, 'ymin')
    ymin.text = str(obj['ymin'])
    xmax = ET.SubElement(bndbox, 'xmax')
    xmax.text = str(obj['xmax'])
    ymax = ET.SubElement(bndbox, 'ymax')
    ymax.text = str(obj['ymax'])

tree = ET.ElementTree(annotation)
return tree

def get_value(row, name):
    value = " " if pd.isna(row[name]) else str(row[name])
    return value

def copy_local_to_obs(local_file_path, obs_file_path):
    mox.file.copy(local_file_path, obs_file_path)

def csv_to_pascal_voc(args, csv_file, local_tif_file_path_dict, local_output_file_dir):
    operate_type = getattr(args, 'operateType', 'object_detection')
    logger.info(operate_type)
    df = pd.read_csv(csv_file)
    grouped = df.groupby('FILE_NAME')

    for filename, group in grouped:
        if local_tif_file_path_dict.get(filename, None):
            if operate_type == 'object_detection':

                objects = []
                for _, row in group.iterrows():
                    bndbox = ast.literal_eval(row['LABEL_COORDINATE'])
                    label = row['LABEL_VALUE']
                    obj = {
                        'name': label,
                        'xmin': bndbox[0],
                        'ymin': bndbox[1],
                        'xmax': bndbox[2],
                        'ymax': bndbox[3]
                    }
                    objects.append(obj)
```

```

width, height, depth = 0, 0, 0

folder = os.path.join(row['DEST_BUCKET'], row['DEST_PATH'])
path = os.path.join(folder, filename)
# real_path = os.path.join(test_root, path)
with PIL.Image.open(local_tif_file_path_dict.get(filename)) as img:
    width, height = img.size
    depth = len(img.getbands())
tree = create_pascal_voc_xml1(folder, filename, path, width, height, depth, objects)
pretty_xml = prettify_xml(tree.getroot())

local_output_xml_file_path = os.path.join(local_output_file_dir, os.path.splitext(filename)[0] +
.xml')
with open(local_output_xml_file_path, 'w', encoding='utf-8') as f:
    f.write(pretty_xml)
fname = replacetype(filename, '1')
copy_local_to_obs(local_output_xml_file_path, os.path.join(args.output_obs_path, fname))
copy_local_to_obs(local_tif_file_path_dict.get(filename), os.path.join(args.output_obs_path,
filename))
elif operate_type == 'image_classification':
    for _, row in group.iterrows():
        logger.info(f'-----循环row--')

        lv = get_value(row, 'LABEL_VALUE')
        txtstr = create_pascal_voc_txt(lv)
        fname = replacetype(filename, '2')
        local_output_txt_file_path = os.path.join(local_output_file_dir, fname)
        with open(local_output_txt_file_path, 'w', encoding='utf-8') as f:
            f.write(txtstr)
        copy_local_to_obs(local_output_txt_file_path,
            os.path.join(args.output_obs_path, fname))
        copy_local_to_obs(local_tif_file_path_dict.get(filename), os.path.join(args.output_obs_path,
filename))

def replacetype(filename, type):
    if type == '1':
        filename = filename.replace('.jpg', '.xml')
        filename = filename.replace('.bmp', '.xml')
        filename = filename.replace('.jpeg', '.xml')
        filename = filename.replace('.png', '.xml')
        filename = filename.replace('.JPG', '.xml')
        filename = filename.replace('.BMP', '.xml')
        filename = filename.replace('.JPEG', '.xml')
        filename = filename.replace('.PNG', '.xml')
    elif type == '2':
        filename = filename.replace('.jpg', '.txt')
        filename = filename.replace('.bmp', '.txt')
        filename = filename.replace('.jpeg', '.txt')
        filename = filename.replace('.png', '.txt')
        filename = filename.replace('.JPG', '.txt')
        filename = filename.replace('.BMP', '.txt')
        filename = filename.replace('.JPEG', '.txt')
        filename = filename.replace('.PNG', '.txt')
    return filename

def create_pascal_voc_txt(lv):
    # tree='DEST_ENGINE_UUID:'+deu+'\n'+ 'DEST_BUCKET:'+db
    # txttree = 'DEST_ENGINE_UUID:' + deu + '\n' + 'DEST_BUCKET:' + db + '\n' + 'DEST_PATH:' + dp + '\n' +
    'LABEL_SET:' + ls + '\n' + 'LABEL_VALUE:' + lv + '\n' + 'LABEL_SHAPE:' + lse + '\n' + 'LABEL_COORDINATE:' +
    lc + '\n' + 'SOURCE_REC_CREATE_TIME:' + src + '\n' + 'SOURCE_REC_REVISOR:' + srr + '\n' + 'REC_CREATE_TIME:' + rct +
    '\n' + 'REC_REVISOR:' + rrt + '\n' + 'REC_C_CREATEOR:' + rc + '\n' + 'REC_REVISOR:' + rr
    txttree = lv

    return txttree

```

```
class Process:
    def __init__(self, args):
        # 创建本地目录用以存储从obs传入的文件
        self.local_input_file_dir = r'/tmp/obs_input/'
        os.makedirs(self.local_input_file_dir, exist_ok=True)
        # 创建本地目录用以存储处理后的文件，从而传输到obs
        self.local_output_file_dir = r'/tmp/obs_output/'
        os.makedirs(self.local_output_file_dir, exist_ok=True)
        # 设置参数，针对算子控制参数，设置默认值
        self.args = args
        self.input_obs_path=args.obs_input_path
        self.output_obs_path=args.obs_output_path
        self.args.input_obs_path=args.obs_input_path
        self.args.output_obs_path=args.obs_output_path
        logger.info(f'-----算子执行-----')

    def __call__(self, input):
        # 获取obs路径下的文件名
        file_name_list = mox.file.list_directory(self.args.input_obs_path, recursive=False)
        file_path_dict = {file_name: os.path.join(self.args.input_obs_path, file_name) for file_name in
file_name_list}
        # 对每个文件进行处理
        local_tif_file_path_dict, local_csv_file_path = {}, "
        for file_name, obs_file_path in file_path_dict.items():
            # 将文件从obs复制到本地

#         if file_name.endswith('.jpg'):
#             local_tif_file_path = os.path.join(self.local_input_file_dir, file_name)
#             logger.info(f'-----4'+local_tif_file_path)
#             local_tif_file_path_dict[file_name] = local_tif_file_path
#             mox.file.copy(obs_file_path, local_tif_file_path)
#         else:
#             local_csv_file_path = os.path.join(self.local_input_file_dir, file_name)
#             logger.info(f'-----5'+local_csv_file_path)
#             mox.file.copy(obs_file_path, local_csv_file_path)

        if file_name.endswith('.csv'):

            local_csv_file_path = os.path.join(self.local_input_file_dir, file_name)
            mox.file.copy(obs_file_path, local_csv_file_path)
        else:
            local_tif_file_path = os.path.join(self.local_input_file_dir, file_name)
            local_tif_file_path_dict[file_name] = local_tif_file_path
            mox.file.copy(obs_file_path, local_tif_file_path)

        csv_to_pascal_voc(self.args, local_csv_file_path, local_tif_file_path_dict, self.local_output_file_dir)
```

4.8 数据工程常见报错与解决方案

数据工程常见报错及解决方案请详见[表4-45](#)。

表 4-45 数据工程常见报错与解决方案

功能模块	常见报错	解决方案
数据获取	File format mismatch, require [{0}].	请检查创建数据集时使用的数据，与平台要求的文件内容格式是否一致。

功能模块	常见报错	解决方案
	Verification failed. Please check the content format is consistent with the template requirements.	请检查创建数据集时使用的数据，与平台要求的文件内容格式是否一致。
	content type [%s] not support, only [%s] support.	数据集中的内容不支持，请保证上传的数据格式与平台要求的一致。
	get obs bucket folders error.	请检查OBS服务是否正常，是否可以访问OBS桶数据。
数据加工	dataset is not online.	数据加工使用的数据集未上线，请先执行上线操作。
	invalid obs path.	请检查数据集对应的OBS路径是否有效，是否可正常访问。
数据标注	annotate data not exist.	请检查标注数据集是否存在，是否被删除。
	obs url invalid.	请检查数据集对应的OBS路径是否有效，是否可正常访问。
	data management query dataset data invalid.	请检查标注数据集是否存在，是否被删除。
	dataset obs file empty.	检查数据集文件是否还存在于原先的OBS桶中。
	download obs file failed.	请检查网络是否正常，是否可以访问OBS桶中的数据。
数据评估	annotate type is invalid.	请检查上传的数据中，使用的数据标注类型、数据标注要求与平台要求的是否一致。
	annotate data not exist.	待评测数据不存在，请检查数据是否导入成功，OBS桶是否为空。
	obs url invalid.	请检查数据集对应的OBS路径是否有效，是否可正常访问。
	standard item not exist.	请检查评估标准是否存在，是否被删除。
	the corresponding data has been marked as deleted.	请检查评估数据是否被删除。
	the current data not exist.	请检查评估数据是否存在，是否被删除。

功能模块	常见报错	解决方案
	dataset file type does not match standard file type.	请检查上传的数据集文件类型与平台要求的标准文件类型是否一致。
	data management query dataset data invalid.	请检查数据集中是否有异常格式的数据。
	dataset obs file empty.	检查数据集文件是否还存在于原先的OBS桶中。
数据发布	Dataset [%s] is not found.	请检查数据集是否存在。
	Dataset [%s] status is invalid.	请检查数据集状态是否正常。

5 开发 Deepseek 大模型

5.1 Deepseek 大模型介绍

平台预置DeepSeek-R1-32K及DeepSeek-V3-32K模型。

DeepSeek-R1

DeepSeek-R1满血版671B参数模型，在数学、代码、自然语言处理能力比肩OpenAI o1正式版。DeepSeek-R1-32K-0.0.1版本支持推理部署。

平台已预置推理服务，用户可通过体验中心或者API调用该推理服务。

直接部署模型时，已预置最优模型，无需进行压缩后再部署。

表 5-1 推理特性

推理精度	INT8
序列长度	32K
起推规格（推理单元）	16
并发	256

DeepSeek-V3

DeepSeek-V3为MoE模型，671B参数，激活37B，在长文本、代码、数学、百科、中文能力上表现优秀。DeepSeek-V3-32K-0.0.1版本支持推理部署。

直接部署模型时，已预置最优模型，无需进行压缩后再部署。

表 5-2 推理特性

推理精度	INT8
序列长度	32K

推理精度	INT8
起推规格（推理单元）	16
并发	256

5.2 使用数据工程构建 Deepseek 大模型数据集

构建 Deepseek 大模型数据集流程

在ModelArts Studio平台中，使用数据工程构建三方大模型数据集流程见[表5-3](#)。

表 5-3 三方大模型数据集构建流程

流程	子流程	说明	操作指导
导入数据至盘古平台	创建导入任务	将存储在OBS服务或本地的数据导入至平台统一管理，用于后续加工或发布操作。 说明 执行导入操作时，数据集类型需要选择“单轮问答数据”。	导入数据至盘古平台
加工其他类数据集	加工其他类数据集	通过自定义加工算子对数据进行预处理，确保数据符合模型训练的标准和业务需求。	加工其他类数据集
发布其他类数据集	发布其他类数据集	数据发布是将单个数据集发布为特定格式的“发布数据集”，用于后续模型训练等操作。	发布其他类数据集

DeepSeek 数据集要求

表 5-4 DeekSeek 模型数据集格式

模型类型	训练类型	数据量	数据集格式	数据说明
DeepSeek-R1-32K DeepSeek-V3-32k	预训练	大于15B tokens	jsonl	jsonl格式：text表示预训练所使用的文本数据，具体格式示例如下： {"text": "盘古大模型，包括NLP大模型、多模态大模型、CV大模型、科学计算大模型、预测大模型。"}
DeepSeek-V3-32k	微调训练（单轮问答）	1万~100万条数据	jsonl	jsonl格式：数据由问答对构成，context、target分别表示问题、答案，具体格式示例如下： {"context": "你好，请介绍自己", "target": "我是盘古大模型"}

模型类型	训练类型	数据量	数据集格式	数据说明
DeepSeek-R1-32K	微调训练（单轮问答）	1万~100万条数据	jsonl	jsonl格式：数据由问答对构成，context、target分别表示问题、答案，target中除了模型回答外，需要添加<think>\n思考过程\n</think>，表示模型的思考过程信息。 <pre>{"context":"问题","target":"<think>\n思考过程\n</think>\n\n模型回答"}</pre> 示例： <pre>{"context":"2+2等于多少？","target":"<think>\n根据基本算术定义，2与2相加即合并两个数值；\n通过实物计数（如2个苹果加2个苹果）或数轴移动（0→2→4）验证；\n符合自然数公理体系（如2的后继为3，再后继为4）。\n</think>\n\n**答案： ** 2+2=4"}</pre>

5.3 训练 Deepseek 大模型

5.3.1 创建 Deepseek 大模型训练任务

预训练

创建Deepseek大模型预训练任务步骤如下：

1. 登录ModelArts Studio大模型开发平台，在“我的空间”模块，单击进入所需空间。

图 5-1 我的空间



2. 在左侧导航栏中选择“模型开发 > 模型训练”，单击右上角“创建训练任务”。
3. 在“创建训练任务”页面，参考表5-5完成训练参数设置。

表 5-5 Deepseek 大模型预训练参数说明

参数分类	训练参数	参数说明
训练配置	选择模型	可以修改如下信息： - 来源：选择“模型广场”。 - 类型：选择“大语言模型”，并选择训练所用的基础模型和版本（选择 DeepSeek-V3-32K或者DeepSeek-R1-32K具体版本）。
	训练类型	选择“预训练”。
	高级设置 checkpoints	checkpoints：在模型训练过程中，用于保存模型权重和状态的机制。 - 关闭：关闭后不保存checkpoints，无法基于checkpoints执行续训操作。 - 自动：自动保存训练过程中的所有checkpoints。 - 自定义：根据设置保存指定数量的checkpoints。
训练参数	训练轮数	epochs，训练中遍历数据集的次数。
	学习率	learning_rate，控制模型参数训练步长的更新幅度，学习率过大可能会导致模型难以收敛，过小可能会导致收敛速度过慢。
	数据批量大小	batch_size，控制每个训练步长的样本量，数值越大，梯度会越稳定，但是同时也会使用更大的显存，受硬件限制可能会OOM，并延长单次训练时长。
	序列长度	sequence_length，训练单条数据的最大长度，超过该长度的数据在训练时将被截断。
	热身比例	warmup，控制热身阶段占整体训练的比例，可以使训练的热身阶段内学习率较小，模型慢慢趋于稳定，之后按预设学习率进行训练，模型收敛速度更快，效果更佳。
	学习率衰减比率	lr_decay_ratio，控制学习率的参数，可以使模型更稳定地收敛，最小不会低于学习率x学习率衰减比率的值，若学习率不衰减则配置为1。
	权重衰减系数	weight_decay，是一种对模型参数值大小进行衰减的正则化方法，防止模型过拟合，提高模型泛化能力。
	模型保存策略	save_checkpoint_steps/save_checkpoint_epoch，训练过程中是按迭代步数，还是训练轮数保存Checkpoint文件。
	模型保存间隔	save_checkpoint_steps，训练过程中每隔多少个训练步长保存一次模型Checkpoint文件。 save_checkpoint_epoch，训练过程中每个多少训练轮数保存一次模型Checkpoint文件。

参数分类	训练参数	参数说明
	模型保存个数	checkpoints：在模型训练过程中，用于保存模型权重和状态的机制。 ● 关闭：关闭后不保存checkpoints，无法基于checkpoints执行续训操作。 ● 全部：自动保存训练过程中的所有checkpoints。 ● 自定义：根据设置保存指定数量的checkpoints。
训练数据配置	训练集	选择训练模型所需的数据集。
资源配置	计费模式	选择训练当前任务的计费模式。
	训练单元	选择训练模型所需的训练单元。 当前展示的完成本次训练所需要的最低训练单元要求。
	单实例训练单元数	选择单实例训练单元数。
	实例数	选择实例数。
订阅提醒	订阅提醒	该功能开启后，系统将在任务状态更新时，通过短信或邮件将提醒发送给用户。
发布模型	开启自动发布	开启自动发布后，模型训练完成的最终产物会自动发布为空间资产，以便对模型进行压缩、部署、评测等操作或共享给其他空间。
基本信息	名称	训练任务名称。
	描述	训练任务描述。


4. 参数填写完成后，单击“立即创建”。
5. 创建好训练任务后，页面将返回“模型训练”页面，可随时查看当前任务的状态。

全量微调

创建Deepseek大模型全量微调任务步骤如下：

1. 登录ModelArts Studio大模型开发平台，在“我的空间”模块，单击进入所需空间。

图 5-2 我的空间



2. 在左侧导航栏中选择“模型开发 > 模型训练”，单击界面右上角“创建训练任务”。
3. 在“创建训练任务”页面，参考表5-6完成训练参数设置。

表 5-6 Deepseek 大模型全量微调参数说明

参数分类	训练参数	参数说明
训练配置	选择模型	可以修改如下信息： - 来源：选择“模型广场”。 - 类型：选择“大语言模型”，并选择训练所用的基础模型和版本（选择 DeepSeek-V3-32K或者DeepSeek-R1-32K具体版本）。
	训练类型	选择“微调”。
	训练目标	选择“全量微调”。 全量微调：在模型进行有监督微调时，对大模型的所有参数进行更新。
	高级设置	checkpoints：在模型训练过程中，用于保存模型权重和状态的机制。 - 关闭：关闭后不保存checkpoints，无法基于checkpoints执行续训操作。 - 自动：自动保存训练过程中的所有checkpoints。 - 自定义：根据设置保存指定数量的checkpoints。
训练参数	训练轮数	epochs，训练中遍历数据集的次数。
	学习率	learning_rate，控制模型参数训练步长的更新幅度，学习率过大可能会导致模型难以收敛，过小可能会导致收敛速度过慢。

参数分类	训练参数	参数说明
	数据批量大小	batch_size，控制每个训练步长的样本量，数值越大，梯度会越稳定，但是同时也会使用更大的显存，受硬件限制可能会OOM，并延长单次训练时长。
	序列长度	sequence_length，训练单条数据的最大长度，超过该长度的数据在训练时将被截断。
	热身比例	warmup，控制热身阶段占整体训练的比例，可以使训练的热身阶段内学习率较小，模型慢慢趋于稳定，之后按预设学习率进行训练，模型收敛速度更快，效果更佳。
	学习率衰减比率	lr_decay_ratio，控制学习率的参数，可以使模型更稳定地收敛，最小不会低于学习率x学习率衰减比率的值，若学习率不衰减则配置为1。
	权重衰减系数	weight_decay，是一种对模型参数值大小进行衰减的正则化方法，防止模型过拟合，提高模型泛化能力。
	模型保存策略	save_checkpoint_steps/save_checkpoint_epoch，训练过程中是按迭代步数，还是训练轮数保存Checkpoint文件。
	模型保存间隔	save_checkpoint_steps，训练过程中每隔多少个训练步长保存一次模型Checkpoint文件。 save_checkpoint_epoch，训练过程中每个多少训练轮数保存一次模型Checkpoint文件。
	模型保存个数	checkpoints：在模型训练过程中，用于保存模型权重和状态的机制。 ● 关闭：关闭后不保存checkpoints，无法基于checkpoints执行续训操作。 ● 全部：自动保存训练过程中的所有checkpoints。 ● 自定义：根据设置保存指定数量的checkpoints。
数据配置	训练集	选择训练模型所需的数据集。
资源配置	计费模式	选择训练当前任务的计费模式。
	训练单元	选择训练模型所需的训练单元。 当前展示的完成本次训练所需要的最低训练单元要求。
	单实例训练单元数	选择单实例训练单元数。
	实例数	选择实例数。
订阅提醒	订阅提醒	该功能开启后，系统将在任务状态更新时，通过短信或邮件将提醒发送给用户。

参数分类	训练参数	参数说明
发布模型	是否开启自动发布	关闭，训练完成后手动发布到模型资产 开启，配置可见性、模型名称和描述
基本信息	名称	训练任务名称。
	描述	训练任务描述。

说明

不同模型训练参数默认值存在一定差异，请以前端页面展示的默认值为准。


4. 参数填写完成后，单击“立即创建”。
5. 创建好训练任务后，页面将返回“模型训练”页面，可随时查看当前任务的状态。

LoRA 微调

创建Deepseek大模型LoRA微调任务步骤如下：

1. 登录ModelArts Studio大模型开发平台，在“我的空间”模块，单击进入所需空间。

图 5-3 我的空间



2. 在左侧导航栏中选择“模型开发 > 模型训练”，单击界面右上角“创建训练任务”。
3. 在“创建训练任务”页面，参考表5-7完成训练参数设置。

表 5-7 Deepseek 大模型 LoRA 微调参数说明

参数分类	训练参数	参数说明
训练配置	选择模型	可以修改如下信息： - 来源：选择“模型广场”。 - 类型：选择“大语言模型”，并选择训练所用的基础模型和版本（选择 DeepSeek-V3-32K或者DeepSeek-R1-32K具体版本）。
	训练类型	选择“微调”。
	训练目标	选择“LoRA微调”。 LoRA微调：在模型有监督微调过程中，冻结预训练好的模型权重参数，在保留自注意力模块中原始权重的基础上，对权重矩阵进行低秩分解，训练过程中只更新低秩部分的参数。
训练参数	训练轮数	epochs，训练中遍历数据集的次数
	学习率	learning_rate，控制模型参数训练步长的更新幅度，学习率过大可能会导致模型难以收敛，过小可能会导致收敛速度过慢。
	数据批量大小	batch_size，控制每个训练步长的样本量，数值越大，梯度会越稳定，但是同时也会使用更大的显存，受硬件限制可能会OOM，并延长单次训练时长。
	序列长度	sequence_length，训练单条数据的最大长度，超过该长度的数据在训练时将被截断。
	热身比例	warmup，控制热身阶段占整体训练的比例，可以使训练的热身阶段内学习率较小，模型慢慢趋于稳定，之后按预设学习率进行训练，模型收敛速度更快，效果更佳。
	学习率衰减比率	lr_decay_ratio，控制学习率的参数，可以使模型更稳定地收敛，最小不会低于学习率x学习率衰减比率的值，若学习率不衰减则配置为1。
	权重衰减系数	通过在损失函数中加入与模型权重大小相关的惩罚项，鼓励模型保持较小的权重，防止过拟合或模型过于复杂。
	Lora矩阵的秩	LoRA_rank，在Lora矩阵中，Rank的值用于衡量矩阵的复杂度和信息量。数值较大，增强模型的表示能力，但会增加训练时长；数值越小可以减少参数数量，降低过拟合风险。
数据配置	训练集	选择训练模型所需的数据集。
资源配置	计费模式	选择训练当前任务的计费模式。

参数分类	训练参数	参数说明
	训练单元	选择训练模型所需的训练单元。 当前展示的完成本次训练所需要的最低训练单元要求。
	单实例训练单元数	选择单实例训练单元数。
	实例数	选择实例数。
订阅提醒	订阅提醒	该功能开启后，系统将在任务状态更新时，通过短信或邮件将提醒发送给用户。
发布模型	是否开启自动发布	关闭，训练完成后手动发布到模型资产 开启，配置可见性、模型名称和描述
基本信息	名称	训练任务名称。
	描述	训练任务描述。

说明

不同模型训练参数默认值存在一定差异，请以前端页面展示的默认值为准。


4. 参数填写完成后，单击“立即创建”。
5. 创建好训练任务后，页面将返回“模型训练”页面，可随时查看当前任务的状态。

QLoRA 微调

创建Deepseek大模型全量微调任务步骤如下：

1. 登录ModelArts Studio大模型开发平台，在“我的空间”模块，单击进入所需空间。

图 5-4 我的空间



2. 在左侧导航栏中选择“模型开发 > 模型训练”，单击界面右上角“创建训练任务”。
3. 在“创建训练任务”页面，参考表5-8完成训练参数设置。

表 5-8 Deepseek 大模型 QLoRA 微调参数说明

参数分类	训练参数	参数说明
训练配置	选择模型	可以修改如下信息： - 来源：选择“模型广场”。 - 类型：选择“大语言模型”，并选择训练所用的基础模型和版本（选择 DeepSeek-V3-32K或者DeepSeek-R1-32K具体版本）。
	训练类型	选择“微调”。
	训练目标	选择“QLoRA微调”。 QLoRA微调：Qlora是一种高效微调大语言模型的技术，结合了量化和低秩适配器（Low-Rank Adaptation），旨在显著降低显存占用，同时保持模型性能，适用于资源受限的场景。
训练参数	训练轮数	epochs，训练中遍历数据集的次数。
	学习率	learning_rate，控制模型参数训练步长的更新幅度，学习率过大可能会导致模型难以收敛，过小可能会导致收敛速度过慢。
	数据批量大小	batch_size，控制每个训练步长的样本量，数值越大，梯度会越稳定，但是同时也会使用更大的显存，受硬件限制可能会OOM，并延长单次训练时长。
	序列长度	sequence_length，训练单条数据的最大长度，超过该长度的数据在训练时将被截断
	热身比例	warmup，控制热身阶段占整体训练的比例，可以使训练的热身阶段内学习率较小，模型慢慢趋于稳定，之后按预设学习率进行训练，模型收敛速度更快，效果更佳。
	学习率衰减比率	lr_decay_ratio，控制学习率的参数，可以使模型更稳定地收敛，最小不会低于学习率x学习率衰减比率的值，若学习率不衰减则配置为1。
	权重衰减系数	weight_decay，是一种对模型参数值大小进行衰减的正则化方法，防止模型过拟合，提高模型泛化能力。
	Lora矩阵的秩	LoRA_rank，在Lora矩阵中，Rank的值用于衡量矩阵的复杂度和信息量。数值较大，增强模型的表示能力，但会增加训练时长；数值越小可以减少参数数量，降低过拟合风险。

参数分类	训练参数	参数说明
数据配置	训练集	选择训练模型所需的数据集。
资源配置	计费模式	选择训练当前任务的计费模式。
	训练单元	选择训练模型所需的训练单元。 当前展示的完成本次训练所需要的最低训练单元要求。
	单实例训练单元数	选择单实例训练单元数。
	实例数	选择实例数。
订阅提醒	订阅提醒	该功能开启后，系统将在任务状态更新时，通过短信或邮件将提醒发送给用户。
发布模型	是否开启自动发布	关闭，训练完成后手动发布到模型资产 开启，配置可见性、模型名称和描述
基本信息	名称	训练任务名称。
	描述	训练任务描述。

 说明

不同模型训练参数默认值存在一定差异，请以前端页面展示的默认值为准。

4. 参数填写完成后，单击“立即创建”。
5. 创建好训练任务后，页面将返回“模型训练”页面，可随时查看当前任务的状态。

5.3.2 查看 Deepseek 大模型训练状态与指标

查看模型训练状态

模型启动训练后，模型的训练任务状态请在“模型训练”页面进行查看。单击任务名称可以进入详情页查看训练指标、训练任务详情和训练日志。

表 5-9 训练状态说明

训练状态	训练状态含义
初始化	模型训练任务正在进行初始化配置，准备开始训练。
排队中	模型训练任务正在排队，请稍等。
运行中	模型正在训练中，训练过程尚未结束。

训练状态	训练状态含义
停止中	模型训练正在停止中。
已停止	模型训练已被用户手动停止。
失败	模型训练过程中出现错误，需查看日志定位训练失败原因。
已完成	模型训练已完成。

查看训练指标

对于训练状态为“已完成”的任务，单击任务名称，可在“训练结果”页面查看训练指标。

表 5-10 训练指标说明

模型	训练指标	指标说明
三方大模型	训练损失值 (Training Loss)	训练损失值是一种衡量模型预测结果和真实结果之间的差距的指标，通常情况下越小越好。 一般来说，一个正常的Loss曲线应该是单调递减的，即随着训练的进行，Loss值不断减小，直到收敛到一个较小的值。


获取训练日志

单击训练任务名称，可以在“日志”页面查看训练过程中产生的日志。

对于训练异常或失败的任务可以通过训练日志定位训练失败的原因。

训练日志可以按照不同的节点（训练阶段）进行筛选查看。分布式训练时，任务被分配到多个工作节点上进行并行处理，每个工作节点负责处理一部分数据或执行特定的计算任务。日志也可以按照不同的工作节点（如worker-0表示第一个工作节点）进行筛选查看。

图 5-5 获取训练日志



5.3.3 发布训练后的 Deepseek 大模型

Deepseek大模型训练完成后，需要执行发布操作，操作步骤如下：

1. 登录ModelArts Studio平台，在“我的空间”模块，单击进入所需空间。
2. 在左侧导航栏中选择“模型开发 > 模型训练”，单击模型名称进入任务详情页。
3. 单击进入“训练结果”页签，单击“发布”。
4. 填写资产名称、描述，选择对应的可见性，单击“确定”发布模型。

发布后的模型会作为模型资产同步显示在“空间资产 > 模型”列表中。

5.3.4 管理 Deepseek 大模型训练任务

在训练任务列表中，任务创建者可以对任务进行克隆（复制训练任务）、重试（重新训练任务）和删除操作。

1. 登录ModelArts Studio平台，在“我的空间”模块，单击进入所需空间。

图 5-6 我的空间



2. 在左侧导航栏中选择“模型开发 > 模型训练”，可进行如下操作：
 - 克隆：单击操作列的“克隆”，可以复制当前训练任务。
 - 重试：单击操作列的“重试”，可以编辑运行失败的节点，重试该节点的训练。
 - 删除：单击操作列的“删除”，可以删除当前不需要的训练任务。

5.4 压缩 Deepseek 大模型

模型在部署前，通过模型压缩可以降低推理显存占用，节省推理资源提高推理性能。通过对三方大模型的压缩，可以减小模型的存储大小，降低功耗，并提高计算速度。

1. 登录ModelArts Studio平台，在“我的空间”模块，单击进入所需空间。

图 5-7 我的空间



2.
- 在左侧导航栏中选择“模型开发 > 模型压缩”，单击界面右上角“创建压缩任务”。参考表5-11创建模型压缩任务。

表 5-11 模型压缩任务参数说明

参数类别	参数名称	说明
压缩配置	模型来源	选择“三方大模型”。
	基础	选择需要进行压缩的模型，可使用来自资产的模型或作业模型。
	压缩策略	选择INT8压缩策略。
资源配置	选择资源池	选择模型压缩任务所使用的资源池。
订阅提醒	订阅提醒	该功能开启后，系统将在任务状态更新时，通过短信或邮件将提醒发送给用户。
发布模型	是否开启自动发布	关闭，训练完成后手动发布到模型资产。 开启，配置可见性、模型名称和描述。
基本信息	任务名称	模型压缩任务的名称。
	压缩后模型名称	设置压缩后的模型名称。（开启自动发布，无该配置项）
	描述	模型压缩任务的描述。

3.
- 参数填写完成后单击“立即创建”创建模型压缩任务。

5.5 部署 Deepseek 大模型

模型训练完成后，可以启动模型的部署操作。

1. 登录ModelArts Studio平台，进入所需空间。
2. 在左侧导航栏中选择“模型开发 > 模型部署”，单击界面右上角“创建部署”。
3. 在“选择模型”页面，选择“模型广场 > 大语言模型 > 模型”，单击“确定”进入“创建部署”页面。
4. 在“创建部署”页面，参考[表5-12](#)完成部署参数设置，启动模型部署。

表 5-12 三方大模型部署参数说明

参数分类	部署参数	参数说明
部署配置	选择模型	可以修改如下信息： - 来源：选择“模型广场”。 - 类型：选择“大语言模型”，并选择需要进行部署的模型和版本。
	部署方式	云上部署：算法部署至平台提供的资源池中。
	Deployed_model	通过V2版本推理接口调用该推理服务时的唯一标识。
安全护栏	开启并同意授权	安全护栏保障模型调用安全。
	版本选择	当前支持安全护栏基础版，内置了默认的内容审核规则。
资源配置	计费模式	限时免费。
	实例数	设置部署模型时所需的实例数，单次部署服务时，部署实例个数建议不大于10，否则可能触发限流导致部署失败。
订阅提醒	订阅提醒	该功能开启后，系统将在任务状态更新时，通过短信或邮件将提醒发送给用户。
基本信息	服务名称	设置部署任务的名称。
	描述（选填）	设置部署任务的描述。

5. 参数填写完成后，单击“立即部署”。

5.6 评测 Deepseek 大模型

5.6.1 创建 Deepseek 大模型评测数据集

效果优秀的模型需要保证模型拥有良好的泛化能力，即模型不仅要在已给定的数据（训练数据）上表现良好，还要能够在未见过的数据上也达到类似的效果。为了实现这一目标，模型评测是必不可少的环节。在收集评估数据集时，必须保持数据集的独立性和随机性，确保收集到的数据能够代表现实世界的样本数据。这有助于避免对评

估结果产生偏见，从而更准确地反映模型在不同情景下的表现。通过使用评估数据集对模型进行评估，开发者可以了解模型的优缺点，从而找到优化方向。

Deepseek大模型支持人工评测、自动评测两种评测模式。

- 人工评测：通过人工创建的评测数据集和评测指标项对模型生成的回答进行评测，评测时需要人工基于创建好的评测项对模型回答进行打分，评测完成后会基于打分结果生成评测报告。
- 自动评测：包含“基于规则”与“基于大模型”两种评测规则。
 - 基于规则（相似度/准确率）自动对模型生成的回答进行评测。用户可使用评测模板中预置的专业数据集进行评测，或者自定义评测数据集进行评测。支持的预置数据集如表5-13。
 - 基于大模型，使用大模型对被评估模型的生成结果进行自动化打分，适用于开放性或复杂问答场景，包含评分模式与对比模式。

表 5-13 预置评测集

数据集类别	数据集	说明
通用知识与技能	常用知识	评测模型对于日常生活基本知识和信息的掌握程度，包括历史、地理、文化等多个方面的基础认知。
	数学能力	评测模型解决数学问题的能力，包括算数运算、代数方程求解、几何图形分析能力等。
	逻辑推理	评测模型根据已知信息进行合理推断和分析的能力，涉及演绎，归纳等多种逻辑思维过程。
	长文本	评测大模型阅读和理解较长篇幅文本材料的能力，包括提取关键信息、总结概括等内容。
	中文能力	评测大模型在中文语言和文化背景下的高级知识和推理能力。
领域知识	金融领域	评测大模型在金融领域的能力，包括快速理解和解释复杂的金融概念，风险预测和数据分析，投资建议以及金融决策支持等。

评测集支持从本地上传、OBS 文件和数据工程数据集导入

1. 登录ModelArts Studio平台，进入所需空间。
2. 在左侧导航栏中选择“评测中心 > 评测集管理”，单击界面右上角“创建评测集”。
3. 在“创建评测集”页面选择所需要的“文件内容”、“文件格式”、“导入来源”，并单击“选择路径”上传数据文件。

图 5-8 评测集导入

评测集导入

模型类型

NLP

大语言大模型

文件格式

jsonl

csv

excel

下载样例

导入来源

本地上传

OBS

数据工程

添加文件

本地上传仅支持10MB大小的上传，超过该大小请上传OBS后再导入

基本信息

评测集名称

Caseset-2025-05-15-1747297653

描述 (可选)

请输入描述

0/100

数据工程数据集创建

评测数据集的创建步骤与训练数据集一致，本章节仅做简单介绍，详细步骤请参见[使用数据工程构建Deepseek大模型数据集](#)。

1. 登录ModelArts Studio平台，进入所需空间。

2. 在左侧导航栏中选择“数据工程 > 数据获取 > 导入任务”，单击界面右上角“创建导入任务”。

3. 在“创建导入任务”页面选择所需要的“文件内容”、“文件格式”、“导入来源”，并单击“选择路径”上传数据文件。

Deepseek大模型评测数据集支持的格式见[表5-14](#)。

表 5-14 评测数据集格式

模型类型	评测数据集格式
Deepseek大模型	文本-单轮问答-jsonl格式
Deepseek大模型	其他-自定义-csv格式

说明

- NLP多轮问答评测场景，请在左侧导航栏中选择"数据工程-数据获取-其他"，按照以下格式导入csv多轮问答评测集。

序号,轮数,问题,参考回复

1,1,你好,你好，请问有什么可以帮助你？

1,2,请介绍一下华为云的产品,华为云提供包括但不限于计算、存储、网络等产品服务
4. 上传数据文件后，填写“数据集名称”与“描述”，单击“立即创建”。

5. 在左侧导航栏中选择“数据工程 > 数据发布 > 发布任务”，单击界面右上角“创建发布任务”。
6. 在“创建发布任务”页面选择数据集模态并选择数据集文件。
7. 单击“下一步”，选择发布格式，填写名称，选择数据集可见性，单击“确定”。

📖 说明

如果评测盘古大模型，需要在发布数据集时，将数据集格式发布为“盘古格式”。

5.6.2 创建 API 服务（可选）

API管理模块可以对评测服务的API进行管理，在创建评测任务的时候选择评测服务即可。可以对API进行创建、编辑、删除。

1. 登录ModelArts Studio平台，在“我的空间”模块，单击进入所需空间。

图 5-9 我的空间



2. 在左侧导航栏中选择“评测中心 > API管理”，单击界面右上角“创建API”。
3. 定义API名称、组织机构，并选择模型类型，单击“提交”。

图 5-10 创建 API

×

创建API

名称

组织机构

模型类型

大语言大模型

描述 (可选)

0/100

取消 提交

4. API创建好以后，通过右侧新增版本来定义API的信息，可以新建多个版本。
5. 单击“新增版本”，并配置模型版本、并发数、QPM、URL、Param、Body、Response。
 - a. 模型版本：自定义。
 - b. 并发数：可以根据模型的性能进行配置，范围1~32。
 - c. QPM：可以根据模型的性能进行配置，范围1~5000。
 - d. URL：模型推理地址。
 - e. Param：用户可以根据接口需要配置，可选，可以定义header和请求参数信息。
 - f. Body(自定义请求体)：推理请求体，可以自定义也可以选择预置的openai或者tgi结构。
 - g. Response(响应体)：通过jsonpath的形式定义怎么获取响应体里面的内容。jsonpath语法的作用是从响应体的json字段中提取出所需的数据。

图 5-11 新增版本

新增版本

基本信息

模型名称

pangu

组织机构

pangu

模型版本

V1

模型类型

NLP

接口信息

并发数

-

1

+

QPM

-

1

+

URL

https://127.0.0.1:8080/chat

Param

header

▼

content-type

xxxx

⊖

query

▼

name

value

⊖

query

▼

name

value

⊕

Body

openai

▼

{"model":"model","messages":[{"role":"user","content":"mes


🔗

Response

\$.response

6. 创建API版本后，需要验证API是否可用，只有验证通过的API才可以进行评测。在“API管理”页面单击创建好的API任务名称，单击“接口验证”输入问题后查看接口是否有响应内容输出。

图 5-12 接口验证



创建 API 服务示例

本示例中使用已经部署，且正常运行的盘古NLP模型创建API服务。

1. 在“模型开发 > 模型部署”页面，找到已部署的NLP模型，单击服务名称，在详情页复制API URL。
2. 在左侧导航栏中选择“评测中心 > API管理”，单击界面右上角“创建API”。定义API名称、组织结构，模型类型选择NLP大模型。
3. API创建好以后，通过右侧新增版本来定义API的信息，可以新建多个版本。单击“新增版本”，参考表5-15完成配置。

表 5-15 配置 API 服务

参数	填写说明
模型版本	可自定义。
并发数	设置为1。
QPM	设置为1。
URL	填写获取到的API URL。
Param	共填写两个参数，均设置为header类型。 参数1：参数名X-AUTH-TOKEN，参数值为Token值，参考《API参考》文档“如何调用REST API > 认证鉴权”章节获取Token。 参数2：参数名Content-Type，参数值application/json。

参数	填写说明
Body	选择自定义，填写内容： {"model": "model", "messages": [{"role": "user", "content": "{{message}}"}], "max_tokens": 1024, "temperature": 0.7, "top_p": 0.95, "presence_penalty": 0.5, "frequency_penalty": 0.5, "stream": false}
Response	填写： \$.choices[0].message.content

图 5-13 配置 API 服务

新增版本 ✕

基本信息

模型名称
yanshou-test

组织机构
yanshou

模型版本
v1

模型类型
NLP

接口信息

并发数
1

QPM
1

URL
https://8.28.11.173:31004/v1/c3140321fbc4401fa3aa571976cbebc/deployments/42751f7a-c

Param

headerX-AUTH-TOKENxxxxxxxxxxxx

headerContent-Typeapplication/json

+ 添加

Body

自定义{"model": "model", "messages": [{"role": "user", "content": "{

Response

\$.choices[0].message.content

5.6.3 创建 Deepseek 大模型评测任务

创建NLP大模型评测任务前，请确保已完成[创建Deepseek大模型评测数据集](#)操作。
预训练的NLP大模型不支持评测。

文档版本 01 (2025-07-28)

版权所有 © 华为云计算技术有限公司


199

创建 Deepseek 大模型自动评测任务（基于规则）

创建NLP大模型自动评测任务步骤如下：

1. 登录ModelArts Studio大模型开发平台，在“我的空间”模块，单击进入所需空间。

图 5-14 我的空间



2. 在左侧导航栏中选择“评测中心 > 评测任务”，单击界面右上角“创建自动评测任务”。
3. 在“创建自动评测任务”页面，参考表 DeepseekNLP大模型自动评测任务参数说明（基于规则）完成部署参数设置。

表 5-16 Deepseek 大模型自动评测任务参数说明（基于规则）

参数分类	参数名称	参数说明
选择服务	模型类型	选择“NLP大模型”。
	服务来源	支持已部署服务、外部服务两种选项。单次最多可评测10个模型。 - 已部署服务：选择部署至ModelArts Studio平台的模型进行评测。 - 外部服务：通过API的方式接入外部模型进行评测。选择外部服务时，需要填写外部模型的接口名称、接口地址、请求体、响应体等信息。 - 请求体支持openai、tgi、自定义三种格式。openai格式即是由OpenAI公司开发并标准化的一种大模型请求格式；tgi格式即是Hugging Face团队推出的一种大模型请求格式。 - 接口的响应体需要按照jsonpath语法要求进行填写，jsonpath语法的作用是从响应体的json字段中提取出所需的数据。

参数分类	参数名称	参数说明
评测配置	评测规则	选择“基于规则”：基于规则自动打分，即基于相似度/准确率进行打分，对比模型预测结果与标注数据的差异，适合标准选择题或简单问答场景。
	评测数据集	- 预置评测集：使用预置的专业数据集进行评测。 - 单个评测集：由用户指定评测指标（F1分数、准确率、BLEU、Rouge）并上传评测数据集进行评测。选择“单个评测集”时需要上传待评测数据集。
	评测结果存储位置	模型评测结果的存储位置。
基本信息	评测任务名称	填写评测任务名称。
	描述	填写评测任务描述。


4. 参数填写完成后，单击“立即创建”，回退至“评测任务 > 自动评测”页面。
5. 当状态为“已完成”时，可以单击操作列“评测报告”查看模型评测结果，包括模型详细的得分以及评测明细。

创建 Deepseek 大模型自动评测任务（基于大模型）

创建Deepseek大模型自动评测任务步骤如下：

1. 登录ModelArts Studio大模型开发平台，在“我的空间”模块，单击进入所需空间。

图 5-15 我的空间



2. 在左侧导航栏中选择“评测中心> 评测任务”，单击界面右上角“创建自动评测任务”。

3. 在“创建自动评测任务”页面，参考表5-17完成部署参数设置。

表 5-17 Deepseek 大模型自动评测任务参数说明（基于大模型）

参数分类	参数名称	参数说明
选择服务	模型类型	选择“大语言模型”。
	服务来源	支持已部署服务、外部服务两种选项。单次最多可评测10个模型。 - 已部署服务：选择部署至ModelArts Studio平台的模型进行评测。 - 外部服务：通过API的方式接入外部模型进行评测。选择外部服务时，需要填写外部模型的接口名称、接口地址、请求体、响应体等信息。 - 请求体支持openai、tgi、自定义三种格式。openai格式即是由OpenAI公司开发并标准化的一种大模型请求格式；tgi格式即是Hugging Face团队推出的一种大模型请求格式。 - 接口的响应体需要按照jsonpath语法要求进行填写，jsonpath语法的作用是从响应体的json字段中提取出所需的数据。
评测配置	评测规则	选择“基于大模型”：使用能力更强的大模型对被评估模型的生成结果进行自动化打分，适用于开放性或复杂问答场景。
	选择模式	- 评分模式：裁判模型将根据设置的评分标准对模型推理结果自动进行打分 - 对比模式：裁判模型将对两个模型在每个评测题目上的表现，选择win、lose、tie展示对比结果，对比模式下服务来源必须选择2个服务，默认所选择的第一个服务作为基准模型。
	打分 Prompt	- 评分模式下默认为score_prompt，该Prompt包含当前场景的标准回复，将Prompt在评分环节输入至裁判模型中进行打分。 - 对比模式下默认为arena_prompt，该Prompt包含当前场景的标准回复，意图让裁判模型比较两个服务的优劣。 在此过程中，用户可在右侧“变量”中修改metric评价维度等指标。您可对评分指标和评分步骤等内容进行修改
	评测数据集	选择需要评测的数据集。NLP多轮问答场景仅支持基于大模型自动评测，可选择多轮问答评测数据集。
	评测结果存储位置	模型评测结果的存储位置。

参数分类	参数名称	参数说明
裁判员配置	裁判模型	支持选择已部署的服务或外部服务。
	打分规则	打分规则支持自定义配置，裁判模型将根据设定的规则对模型结果进行打分或对比。
基本信息	评测任务名称	填写评测任务名称。
	描述	填写评测任务描述。


4. 参数填写完成后，单击“立即创建”，回退至“评测任务 > 自动评测”页面。
5. 当状态为“已完成”时，可以单击操作列“评测报告”查看模型评测结果，包括模型详细的得分以及评测明细。

创建 DeepSeek 大模型人工评测任务

创建NLP大模型人工评测任务步骤如下：

1. 登录ModelArts Studio大模型开发平台，在“我的空间”模块，单击进入所需空间。

图 5-16 我的空间



2. 在左侧导航栏中选择“评测中心> 评测任务”，单击界面右上角“创建人工评测任务”。
3. 在“创建人工评测任务”页面，参考表5-18完成部署参数设置。

表 5-18 DeepSeek 大模型人工评测任务参数说明

参数分类	参数名称	参数说明
选择服务	模型类型	选择“NLP大模型”。
	服务来源	支持已部署服务、外部服务两种选项。单次最多可评测10个模型。 - 已部署服务：选择部署至ModelArts Studio平台的模型进行评测。 - 外部服务：通过API的方式接入外部模型进行评测。选择外部服务时，需要填写外部模型的接口名称、接口地址、请求体、响应体等信息。 - 请求体支持openai、tgi、自定义三种格式。openai格式即是由OpenAI公司开发并标准化的一种大模型请求格式；tgi格式即是Hugging Face团队推出的一种大模型请求格式。 - 接口的响应体需要按照jsonpath语法要求进行填写，jsonpath语法的作用是从响应体的json字段中提取出所需的数据。
评测配置	评测指标	由用户自定义评测指标并填写评测标准。
	评测数据集	待评测的数据集。
	评测结果存储位置	模型评测结果的存储位置。
基本信息	评测任务名称	填写评测任务名称。
	描述	填写评测任务描述。


4. 参数填写完成后，单击“立即创建”，回退至“评测任务 > 人工评测”页面。
5. 当状态为“待评测”时，可以单击操作列“在线评测”进入评测页面。
6. 依据页面提示对评估效果区域进行评测打分，全部数据评测完成后单击“提交”。
7. 在“人工测评”页面，评测任务的状态将显示为“已完成”，单击操作列“评测报告”查看模型评测结果。

5.6.4 查看 Deepseek 大模型评测报告

评测任务创建成功后，可以查看大模型评测任务报告，具体步骤如下：

1. 登录ModelArts Studio大模型开发平台，在“我的空间”模块，单击进入所需空间。

图 5-17 我的空间



2. 在左侧导航栏中选择“模型开发 > 模型评测 > 任务管理”。
3. 单击操作列“评测报告”，在“评测报告”页面，可以查看评测任务的基本信息及评测概览。
其中，各评测指标说明详见[Deepseek大模型评测指标说明](#)。
4. 导出评测报告。

a. 在“评测报告 > 评测明细”页面，单击“导出”，可选择需要导出的评测报告，单击“确定”。

b. 单击右侧“导出记录”，可查看导出的任务ID，单击操作列“下载”，可将评测报告下载到本地。

Deepseek 大模型评测指标说明

Deepseek大模型支持自动评测与人工评测，各指标说明如[表5-19](#)、[表5-20](#)、[表5-21](#)。

表 5-19 Deepseek 大模型自动评测指标说明-不使用预置评测集

评测指标（自动评测-不使用评测模板）	指标说明
F1_SCORE	精准率和召回率的调和平均数，数值越高，表明模型性能越好。
BLEU-1	模型生成句子与实际句子在单字层面的匹配度，数值越高，表明模型性能越好。
BLEU-2	模型生成句子与实际句子在词组层面的匹配度，数值越高，表明模型性能越好。
BLEU-4	模型生成结果和实际句子的加权平均精确率，数值越高，表明模型性能越好。
ROUGE-1	模型生成句子与实际句子在单个词的相似度，数值越高，表明模型性能越好。

评测指标（自动评测-不使用评测模板）	指标说明
ROUGE-2	模型生成句子与实际句子在两个词的相似度，数值越高，表明模型性能越好。
ROUGE-L	模型生成句子与实际句子在最长公共子序列的相似度，数值越高，表明模型性能越好。
PRECISION	问答匹配的精确度，模型生成句子与实际句子相比的精确程度，数值越高，表明模型性能越好。

表 5-20 Deepseek 大模型自动评测指标说明-使用预置评测集

评测指标（自动评测-使用评测模板）	指标说明
评测得分	每个数据集上的得分为模型在当前数据集上的通过率；评测能力项中若有多个数据集则按照数据量的大小计算通过率的加权平均数。
综合能力	综合能力是计算所有数据集通过率的加权平均数。

表 5-21 Deepseek 大模型人工评测指标说明

评测指标（人工评测）	指标说明
准确性	模型生成答案正确且无事实性错误。
average	模型生成句子与实际句子基于评估指标得到的评分后，统计平均得分。
goodcase	模型生成句子与实际句子基于评估指标得到的评分后，统计得分为5分的占比。
badcase	模型生成句子与实际句子基于评估指标得到的评分后，统计得分1分以下的占比。
用户自定义的指标	由用户定义的指标，如有用性、逻辑性、安全性等。


5.6.5 管理 Deepseek 大模型评测任务

管理评测任务

在评测任务列表中，任务创建者可以对任务进行克隆（复制评测任务）、启动（重启评测任务）和删除操作。

1. 登录ModelArts Studio大模型开发平台，在“我的空间”模块，单击进入所需空间。

图 5-18 我的空间



2. 在左侧导航栏中选择“评测中心 > 评测任务”，可进行如下操作：
- 克隆。单击操作列的“克隆”，可以复制当前状态为“已完成”评测任务。
 - 启动。单击操作列的“启动”，可以重启运行失败的评测任务。
 - 删除。单击操作列的“删除”，可以删除当前状态为“已完成”的不需要的评测任务。

说明

删除属于高危操作，删除前请确保当前任务不再需要。

5.7 调用 Deepseek 大模型

获取三方模型 API 请求地址

API请求地址由API接口域名+API访问路径（URI）拼接形成。
模型部署成功后，可以通过如下接口调用三方模型。

表 5-22 Deepseek 模型接口（以文本补全为例）

API分类	API访问路径（URI）
Deepseek-xxx	{api-url}/generate

API接口域名可以在“模型开发 > 模型部署”页面获取，获取方式如下：

1. 登录ModelArts Studio平台，进入所需空间。
2. 在左侧导航栏中选择“模型开发 > 模型部署”，单击模型名称在“详情”页面获取API接口域名。
只有处于“运行中”状态的模型才可以正常调用。

图 5-19 获取 Deepseek 模型 API 接口域名



3. 获取API接口域名后，结合API访问路径拼接成完整的API接口。


获取 Token

参考《API参考》文档“如何调用REST > API认证鉴权”章节获取Token。

使用 API 调用 Deepseek 大模型

- 1. 在Postman中新建POST请求，并填入API请求地址。
- 2. 参考图5-20填写2个请求Header参数。
 - 参数名为Content-Type，参数值为application/json。
 - 参数名为X-Auth-Token，参数值为获取Token中获取的Token值。


图 5-20 填写三方模型 API



3. 在Postman中选择“Body > raw”选项，参考以下代码填写请求Body。

```
{
  "prompt": "你好",
  "temperature": 0,
  "max_tokens": 100
}
```

图 5-21 填写三方模型请求 Body



4. 单击Postman界面“Send”按钮，发送请求。

6 开发提示词工程

6.1 什么是提示词工程

提示词工程简介

提示词工程（Prompt Engineering）是一个较新的学科，应用于开发和优化提示词（Prompt），帮助用户有效地将大语言模型用于各种应用场景和研究领域。掌握提示词工程相关技能将有助于用户更好地了解大语言模型的能力和局限性。

提示词工程不仅是关于设计和研发提示词，它包含了与大语言模型交互和研发的各种技能和技术。提示工程在实现和大语言模型交互、对接，以及理解大语言模型能力方面都起着重要作用。用户可以通过提示词工程来提高大语言模型的安全性，还可以赋能大语言模型，如借助专业领域知识和外部工具来增强大语言模型的能力。

提示词基本要素

您可以通过简单的提示词（Prompt）获得大量结果，但结果的质量与您提供的信息数量和完善度有关。一个提示词可以包含您传递到模型的指令或问题等信息，也可以包含其他种类的信息，如上下文、输入或示例等。您可以通过这些元素来更好地指导模型，并因此获得更好的结果。提示词主要包含以下要素：

- **指令**：希望模型执行的特定任务或指令，如总结、提取、生成等。
- **上下文**：包含外部信息或额外的上下文信息，引导语言模型更好地响应。
- **输入数据**：用户输入的内容或问题。
- **输出指示**：指定输出的类型或格式。

提示词所需的格式取决于您希望语言模型完成的任务类型，并非所有以上要素都是必须的。


提示词工程使用流程

ModelArts Studio大模型开发平台可以辅助用户进行提示词撰写、比较和评估等操作，并对提示词进行保存和管理。

表 6-1 功能说明

功能	说明
提示词工程任务管理	提示词工程平台以提示词工程任务为管理维度，一个任务代表一个场景或一个调优需求，在提示词工程任务下可以进行提示词的调优、比较和评估。 提示词工程任务管理支持工程任务的创建、查询、修改、删除。
提示词撰写	提示词调优支持对提示词文本的编辑、提示词变量设置、提示词结果生成和调优历史记录管理。
提示词候选	提示词候选支持用户对调优后初步筛选的提示词进行候选管理，每个工程任务下可以保存上限9个候选提示词，进一步基于候选提示词进行比较和评估。
提示词比较	提示词比较支持选择两个候选提示词对其文本和参数进行比较，支持对选择的候选提示词设置相同变量值查看效果。
提示词评估	提示词评估以任务维度管理，支持评估任务的创建、查询、修改、删除。支持创建评估任务，选择候选提示词和需要使用的变量数据集，设置评估算法，执行任务自动化对候选提示词生成结果和结果评估。
提示词管理	提示词管理支持用户对满意的候选提示词进行保存管理，同时支持提示词的查询、删除。

图 6-1 提示词工程使用流程



6.2 获取提示词模板

平台提供了多种任务场景的提示词模板，可以帮助用户更好地利用大模型的能力，引导模型生成更准确、更有针对性的输出，从而提高模型在特定任务上的性能。

在创建提示词工程前，可以先使用预置的提示词模板，或基于提示词模板进行改造。如果提示词模板满足不了使用需求可再单独创建。

提示词模板可在平台“Agent 开发 > 提示词工程 > 提示词模板”中获取。

6.3 撰写提示词

6.3.1 创建提示词工程

通过精心设计和优化提示词，可以引导大模型生成用户期望的输出。提示词工程任务的目标是通过设计和实施一系列的实验，来探索如何利用提示词来提高大模型在各种任务上的表现。

撰写提示词前需要先创建提示词工程，用于对提示词进行统一管理。

1. 登录ModelArts Studio大模型开发平台，进入所需空间。
2. 在左侧导航栏中选择“Agent开发 > 提示词工程 > 提示词开发”，单击界面右上角“创建工程”。
3. 输入工程名称、描述，选择行业、标签后。单击“确定”完成工程创建。

图 6-2 创建提示词工程



6.3.2 撰写提示词

提示词是用来引导模型生成的一段文本。撰写的提示词应该包含任务或领域的关键信息，如主题、风格、格式等。

撰写提示词时，可以设置提示词变量。即在提示词中通过添加占位符`{{ }}`标识表示一些动态的信息，让模型根据不同的情况生成不同的文本，增加模型的灵活性和适应性。例如，将提示词设置为“你是一个旅游助手，需要给用户介绍旅行地的风土人情。请介绍下`{{location}}`的风土人情。”在评估提示词效果时，可以通过批量替换`{{location}}`的值，来获得模型回答，提升评测效率。

同时，撰写提示词过程中，可以通过设置模型参数来控制模型的生成行为，如调整温度、核采样、最大Token限制等参数。模型参数的设置会影响模型的生成质量和多样性，因此需要根据不同的场景进行选择。


1. 登录ModelArts Studio大模型开发平台，进入所需空间。
2. 在左侧导航栏中选择“Agent开发 > 提示词工程 > 提示词开发”。
3. 在工程任务列表页面，找到所需要操作的工程任务，单击该工程任务右侧“撰写”。

图 6-3 提示词工程



4. 在提示词撰写区域输入提示词文本，可以插入若干个变量，变量需要使用占位符 `{{ }}` 标识。

图 6-4 撰写提示词



5. 撰写完成后，单击“确定”，平台会自动识别插入的变量。提示词中识别的变量将展示在变量定义区域。
- 变量名称可以进行修改，如添加备注信息以便更好理解变量的作用。

图 6-5 变量定义



说明

变量定义区域展示的是整个工程任务下定义的变量信息，候选提示词中关联的变量也会进行展示，候选提示词相关操作请参见[设置候选提示词](#)。

同一个提示词工程中，定义的变量不能超过20个。

6. 在“模型”区域，单击“设置”，设置提示词输入的模型和模型参数。

图 6-6 模型设置



6.3.3 预览提示词效果

提示词撰写完成后，可以通过输入具体的变量值，组成完整的提示词，查看不同提示词在模型中的使用效果。

1. 在撰写提示词页面，找到页面右侧变量输入区域，在输入框中输入具体的变量值信息。
- 输入变量值后预览区域会自动组装展示提示词。也可以直接选择已创建的变量集填入变量值信息，变量集是一个excel文件，每行数据是需要输入的变量值信息，可以通过“导入”功能进行上传。

图 6-7 效果预览



2. 单击“查看效果”，输出模型回复结果，用户可以基于预览的效果调整提示词文本和变量。

6.4 横向比较提示词效果

6.4.1 设置候选提示词

用户可以将效果较好的提示词设为候选提示词，并对提示词进行比对，以查看其效果。

 说明

每个工程任务下候选提示词上限9个，达到上限9个时需要删除其他候选提示词才能继续添加。

1. 登录ModelArts Studio大模型开发平台，进入所需空间。
2. 在左侧导航栏中选择“Agent开发 > 提示词工程 > 提示词开发”。
3. 在工程任务列表页面，找到所需要操作的工程任务，单击该工程任务右侧“撰写”。

图 6-8 提示词工程



- 在提示词撰写区域，单击“设为候选”，将当前撰写的提示词设置为候选提示词。
候选状态的提示词将保存至左侧导航栏的“候选”中。

图 6-9 设为候选



6.4.2 横向比较提示词效果

将设置为候选的提示词横向比对，获取提示词的差异性和效果。

1. 登录ModelArts Studio大模型开发平台，进入所需空间。
2. 在左侧导航栏中选择“Agent 开发 > 提示词工程 > 提示词开发”。

3. 在工程任务列表页面，找到所需要操作的工程任务，单击该工程任务右侧“撰写”。

图 6-10 提示词工程




4. 在“撰写”页面，选择左侧导航栏中的“候选”。在候选列表中，勾选需要进行横向比較的提示词，并单击“横向比较”。

图 6-11 横向比较



5. 进入到横向比较页面，下拉页面至“提示词效果比较”模块，比较提示词的效果，输入相同的变量值，查看两个提示词生成的结果。

图 6-12 横向比对提示词效果



6.5 批量评估提示词效果

6.5.1 创建提示词评估数据集

批量评估提示词效果前，需要先上传提示词变量数据文件用于创建对应的评估数据集。

提示词变量是一种可以在文本生成中动态替换的占位符，用于根据不同的场景或用户输入生成不同的内容。其中，变量名称可以是任意的文字，用于描述变量的含义或作用。

提示词评估数据集约束限制

- 上传文件限xlsx格式。
- 数据行数不小于10行，不大于50行。
- 数据不允许相同表头，表头数量小于20个。
- 数据单条文本长度不超过1000。

 说明

创建数据集时会对相关限制条件进行校验。

数据参考格式如下：

表 6-2 数据参考格式

key1	key2	key3	result
组1-v1	组1-v2	组1-v3	组1-r
组2-v1	组2-v2	组2-v3	组2-r
组3-v1	组3-v2	组3-v3	组3-r

表 6-3 数据示例

comment	result
字打错了怎么修改？	中性
这个效果不太好	消极
我喜欢这个样式	积极
请问你是有什么心事吗？	中性

创建提示词评估数据集

1. 登录ModelArts Studio大模型开发平台，进入所需空间。
2. 在左侧导航栏中选择“Agent 开发 > 提示词工程 > 提示用例管理”，单击页面右上角“创建提示用例集”。

图 6-13 提示用例管理



3. 在“创建数据集”页面完成数据集的上传。

图 6-14 创建提示词评估数据集



6.5.2 创建提示词评估任务

选择候选提示词进行批量自动化评估，步骤如下：

- 1. 登录ModelArts Studio大模型开发平台，进入所需空间。
- 2. 在左侧导航栏中选择“Agent 开发 > 提示词工程 > 提示词开发”。
- 3. 在工程任务列表页面，找到所需要操作的工程任务，单击该工程任务右侧“撰写”。
- 4. 在“撰写”页面，选择左侧导航栏中的“候选”。在候选列表中，勾选需要进行横向比对的提示词，并单击“创建评估”。


图 6-15 创建评估



5. 选择评估使用的变量数据集和评估方法。
- 评估用例集：根据选择的数据集，将待评估的提示词和数据集中的变量自动组装成完整的提示词，输入模型生成结果。

- 评估方法：根据选择的评估方法，对模型生成结果和预期结果进行比较，并根据算法给出相应的得分。

图 6-16 创建提示词评估任务



6. 单击“确定”，评估任务自动进入执行状态。

6.5.3 查看提示词评估结果

1. 评估任务创建完成后，会跳转至“评估”页面，在该页面可以查看评估状态。

图 6-17 查看提示词评任务状态



2. 单击“评估名称”，进入评估任务详情页，可以查看详细的评估进度，例如在图 6-18中有10条评估用例，当前已评估8条，剩余2条待评估。

图 6-18 查看评估进展



3. 评估完成后，可以查看每条数据的评估结果。
- 在评估结果中，“预期结果”表示变量值（问题）所预设的期望回答，“生成结果”表示模型回复的结果。通过比对“预期结果”、“生成结果”的差异可以判断提示词效果。

6.6 发布提示词

通过**横向比较提示词效果**和**批量评估提示词效果**，如果找到高质量的提示词，可以将这些提示词发布至“提示词模板”中。

1. 在提示词“候选”页面，选择质量好的提示词，并单击“保存到模板库”。

图 6-19 保存提示词至模板库



2. 进入“Agent 开发 > 提示词工程 > 提示词模板”页面，查看发布的提示词。

7 开发 Agent 应用

7.1 Agent 开发平台介绍

7.1.1 平台简介

Agent，即智能体，能够根据用户指令或预设规则自主执行任务。它通常具备一定的智能和决策能力，可以模拟人类的思考和行为模式，自动完成诸如信息检索、数据分析、任务调度等复杂操作。广泛应用于客服、自动化办公、数据分析等场景，Agent通过学习和优化不断提升自身性能，为用户提供高效、便捷的服务。

Agent开发平台为开发者提供了一套完整的工具和框架，用于创建、配置和管理 Agent。Agent开发平台支持零代码/低代码混合开发。用户可通过可视化界面编排 workflow（集成大模型、知识检索、插件等节点），快速配置意图识别、任务路由、代码执行等能力，实现Agent应用的高效开发与规模化落地。

零代码：轻松创建Agent应用

- 提示词智能生成：平台内置智能提示词生成功能，即使没有大模型基础，也能快速生成适合的提示词，轻松指引智能体完成任务。
- 丰富技能配置：提供多样化的技能配置选项，涵盖知识库、插件、工作流等。添加技能如同搭积木，只需简单单击和选择，就能让智能体掌握新本领，比如接入特定领域的知识库，使其成为该领域的专家。
- 快速创建与运行：整个创建流程极其简便，几步操作就能让智能体上线工作。从构思想法到实际应用，大幅缩短时间，让零代码用户也能快速拥有专属的智能助手。

低代码：灵活搭建复杂工作流

- 可视化工作流设计：采用直观的图形化界面，将各种功能封装成节点，如大模型节点、意图识别节点等。开发者只需像拼图一样拖拽和连接节点，就能构建复杂的工作流，所见即所得，逻辑清晰可见。
- 代码增强灵活性：在节点间适当支持代码编写，为有编程经验的开发者提供更多定制空间。比如在代码节点添加几行数据处理代码，就能实现特殊的数据转换，满足个性化需求。

为什么选择 Agent 开发平台

- **丰富的插件集成能力**

Agent开发平台通过丰富的插件生态持续扩展智能体的能力边界。平台预置了"文件处理"、"代码解释器"等十几种实用插件，做到开箱即用，更开放自定义插件创建能力，开发者可将企业内部API、第三方工具或自研函数封装为插件，通过简单的参数配置即可让智能体调用。

- **灵活的知识库管理**

平台提供智能化的知识库系统，支持开发者构建专属数据资产库。无论是本地文档（支持PDF、Doc、PPT等格式）、网页数据还是结构化数据库，均可快速导入知识库。智能体会自动学习这些数据并建立索引，实现精准的知识检索与内容生成（例如上传行业报告后，Agent可自动生成竞品分析报告）。

- **模块化 workflow 设计**

平台采用“零代码+低代码”的可视化开发模式，支持开发者通过拖拽节点快速搭建复杂任务流。提供包括自然语言处理、逻辑判断、代码执行等近百种标准化组件，满足从简单问答到多步骤任务的开发需求（例如构建一个包含需求分析、方案设计、成本核算的智能客服工作流）。

- **全链路Agent开发支持**

平台内置完整的开发调试体系，从代码编写、插件测试到工作流验证，提供全生命周期支持。开发者可实时观测Agent执行过程中的每一步操作，查看插件调用结果及推理过程，并通过分层日志分析快速定位问题（例如追踪智能客服在处理用户投诉时的对话逻辑与数据调用路径）。

- **灵活的MCP服务**

MCP服务以通用的“标准语言”把工具、数据通过“MCP服务器”的方式供给（一次开发、无限连接），可以更高效、更便捷地实现AI智能体与成千上万的外部工具与数据的互通。

平台架构

Agent开发平台提供了一站式AI应用搭建能力，平台提供多种能力组合，支持构建不同复杂度的Agent开发场景。

基础通用能力

Agent开发平台支持多个租户共同使用并统一进行管理，支持会话的管理，查看历史对话记录，Agent支持发布成API。

核心功能模块

- **工作台：**工作台支持直接创建零代码应用、支持通过工作流编排应用，支持通过插件管理创建自定义插件并接入应用，支持创建MCP服务，支持创建和管理知识库。
- **应用百宝箱：**应用百宝箱包含了应用市场、工作流市场、外部应用，支持各种应用开箱即用。
- **插件市场：**插件市场预置了10+各种类型的插件，如"文件处理"、"代码解释器"等，做到开箱即用。
- **MCP服务市场：**预置多种外部MCP接口，便于用户便捷调用。

应用场景

Agent支持多种应用场景：

- 知识工程类场景，通过挂载知识库应用于如金融、医疗等专业领域。
- 动态规划类场景，应用于聊天机器人、工具调用等场景。
- 流程编排类场景，通过组件库、工作流编排应用于复杂业务场景。

如何使用 Agent 开发平台

- [快速搭建Agent应用](#)

7.1.2 应用场景

当前，基于Agent开发平台可以构建两种类型的Agent(智能体)，一种是针对文本生成、文本检索的知识型Agent，如搜索问答助手、代码生成助手等，执行主体在大模型；另一种是针对复杂 workflows 场景的流程型Agent，如金融分析助手、网络检测助手等。

- **应用：**以大模型为任务执行核心，用户通过配置Prompt、知识库、插件等信息，实现工具自主规划与调用，优点是可零码开发，对话过程更为智能，缺点是当大模型受到输入限制，难以执行链路较长且复杂的流程。

- 应用场景：

i. 智能客服

- **场景：**电商售前咨询、售后问题解答。
- **应用方式：**通过配置Prompt和知识库，大模型直接理解用户问题（如退货政策、商品参数查询），调用插件获取订单信息，快速生成自然语言回复。
- **优势：**无需复杂流程设计，能处理开放式提问，对话体验更接近真人。

ii. 教育辅导

- **场景：**个性化学习答疑、知识点讲解。
- **应用方式：**结合学科知识库和大模型推理能力，学生通过对话提问（如数学题解析），模型实时生成解题步骤并反馈。
- **优势：**零代码快速覆盖多学科需求，灵活适应不同提问方式。

iii. 医疗咨询

- **场景：**症状初步分析、健康建议。
- **应用方式：**用户描述症状后，模型基于医学知识库生成可能病因，调用插件获取药品信息或推荐就医科室。
- **优势：**交互自然，可快速迭代更新知识库以适配最新医疗指南。

- **工作流：**以工作流为任务执行核心，用户通过在画布上对节点进行“拖拉拽”即可搭建出任务流程，场景的节点包括大模型节点、意图识别节点、提问器节点、插件节点、判断节点、代码节点、消息节点，优点是可扩展能力强，用户适当使用低码开发，缺点是对话交互智能度不高，复杂场景下分支多，难以维护。

- 应用场景

i. 金融风控

- **场景：**贷款审批、反欺诈审核。
- **工作流设计：**通过节点串联实现多步骤审核（如调用征信接口→大模型分析收入证明→判断节点触发人工复核）。

- **优势：**流程透明可控，分支条件清晰（如不同额度触发不同审批路径），避免大模型幻觉干扰关键决策。
- ii. **供应链管理**
 - **场景：**库存预警与自动补货、物流异常处理。
 - **workflow设计：**通过代码节点对接ERP系统，判断节点识别库存阈值，触发补货插件或邮件通知节点。
 - **优势：**复杂规则（如供应商优先级、物流延迟策略）可通过分支节点精准实现，稳定性高于纯模型驱动。
- iii. **政务审批**
 - **场景：**企业资质申报、惠民补贴发放。
 - **workflow设计：**串联意图识别节点（分类用户需求）、提问器节点（补全材料）、代码节点（验证数据合规性），最终由消息节点反馈结果。
 - **优势：**标准化流程减少人为错误，分支节点可覆盖政策差异化要求（如不同地区补贴标准）。

7.1.3 功能概述

Agent开发平台提供一站式智能体构建解决方案，通过零代码编排工具让开发者快速创建AI应用，支持画布式节点设计应对复杂业务场景。平台可以集成盘古大模型及DeepSeek等第三方模型，提供角色设定、插件扩展、工作流编排等功能，支持知识库管理、RAG检索和智能提示词优化，确保交互精准可靠。同时支持通过API、网页多渠道发布，助力开发者高效打造专业级智能体应用。

编排能力

表 7-1 Agent 平台编排能力

功能	说明
编排模式	支持用户以零代码操作方式，快捷创建agent，5分钟完成1个原生AI应用创建。 提供灵活的画布式节点编排，让agent能够准确解决复杂的业务场景问题
模型选择	平台提供盘古大模型，支持多款第三方多款模型，DeepSeek等第三方深度思考模型在Agent开发平台已完成适配。

角色指令

Agent平台可通过角色指令设定拟人化特征，提升交互真实感。平台预置了角色指令模板，也可以通过智能添加的方式让大模型输出一个更佳的角色prompt，角色的设定便于开发者打造高度拟人化的语音交互场景。

技能

Agent的核心能力源于其技能体系，开发者可通过集成插件、设计工作流等方式不断扩展模型的功能范围。

表 7-2 Agent 平台技能

功能	说明
插件	您可以通过 API 无缝连接各类平台和服务，快速扩展智能体的功能，平台提供了丰富的内置插件，开箱即用；同时也支持自定义插件开发，将任意API封装成工具，灵活调用。更多信息，参考 插件介绍 。
知识库	提供开箱即用的企业级RAG服务，覆盖管理、测试、检索策略配置全功能。
工作流	工作流是构建复杂功能逻辑的可视化工具，通过灵活组合多个任务节点，能够设计多步骤的自动化流程，从而显著增强智能体应对复杂任务的能力。更多信息，参考 工作流介绍 。

提示词工程

平台提供prompt模板与开发工具，使任何人都可无门槛开发出高质量的prompt指令。

表 7-3 提示词功能

功能	说明
提示词撰写	撰写提示词，并将评估表现较好的提示词设为候选。支持导入提示词示例；支持模型设置；支持提示词中变量定义；支持效果预览；支持历史记录。
提示词比较	支持选择候选提示词进行比较（差异性比较、效果比较）。
提示词评估	支持构建评估用例集，采用多种评估方法对prompt质量进行评估，选择最优的prompt。
提示词使用	指令配置和工作流大模型节点，支持保存和引用prompt模板。

对话体验

Agent开发对话体验支持全程可视化，通过调试能力快速定位与优化配置。

表 7-4 Agent 平台对话体验

功能	说明
Agent Logo	Agent的品牌标识，用于视觉识别，通常体现其功能或个性。
开场白	Agent与用户交互时的初始欢迎语，设定对话基调并引导用户，支持用户自定义配置。
推荐问题	每次对话开始预设的典型提问示例，帮助用户快速了解智能体的能力范围，支持用户自定义配置。
追问	与Agent对话时主动提出的跟进问题，用于澄清需求或深化交互。
预览调试	实时测试和优化Agent功能的工具，展示运行的结果与调用详情。

发布渠道

Agent支持不同的发布方式和渠道，支持发布成API或发布至网页，通过这两种发布方式，Agent可快速落地到实际业务中，兼顾技术集成与终端用户体验。

表 7-5 Agent 平台发布渠道

功能	说明
API	将Agent封装成标准化API接口，供开发者直接调用，适用于需要与其他系统（如企业内部应用、第三方服务）深度集成的场景。
网页	生成可独立访问的Web页面（如H5或PC端页面），用户通过浏览器即可交互，适用于直接面向终端用户的场景（如客服聊天窗口、营销导购助手）。
应用百宝箱	管理账号将Agent应用发布至平台内置的应用百宝箱中，方便平台用户快速调用。

7.1.4 使用流程

如何玩转Agent，使用Agent平台创建应用，使用流程分为以下六步：

- 步骤1 熟悉平台，Agent平台预置了应用百宝箱，可在百宝箱中体验和熟悉各种应用，当然您也可以参考帮助文档学习相关内容；
- 步骤2 创建前准备，在创建Agent之前您可以先创建需要使用到的工作流、插件、知识库、MCP服务，接入需要使用的模型，并可以使用prompt工程提前写好prompt模板；
- 步骤3 开始创建，应用分为两种，一种为零代码应用，一种为低代码（工作流）应用，零代码应用可以基于创建的插件、知识库等直接进行添加；低代码应用支持通过拖拉拽节点的方式自定义编排应用；

步骤4 [调试应用](#)或[调试并发布工作流](#)。应用调试完成后可直接使用，编排好工作流支持直接发布成应用或工作流至个人空间；

步骤5 通过API调用支持使用我们创建的Agent；

步骤6 配置与管理，通过调用详情查看Agent应用使用情况并根据实际情况做相应的优化。

----结束

7.2 使用百宝箱中预置的 Agent 应用

预置 Agent 应用（应用百宝箱）

应用百宝箱提供了丰富的预置Agent应用，覆盖通用、医疗、金融、政务等多个行业场景。这些应用基于大模型能力开发，提供开箱即用的AI功能，帮助用户快速完成智能工单总结、政务公文摘要、医疗病历生成、金融话术推荐等任务，提升业务效率。

预置应用分类

通用场景

适用于跨行业的通用AI能力，如智能问答、文档总结等。

医疗场景

- 数字病历生成-诊疗建议：根据患者医学记录（对话、病情描述等）生成初步诊断建议。
- 数字病历生成-主诉病史：自动提取患者主诉、现病史、既往史等信息。
- 数字病历生成-查体：基于医学记录（对话、检查单等）生成查体报告。

金融场景

- 智能坐席助手-工单总结：自动总结电话/客服对话，避免用户重复描述问题。
- 金融坐席助手-前情摘要总结：优化坐席转接流程，快速生成对话摘要。
- 金融坐席助手-活动推荐话术：基于银行业务活动，智能生成营销话术。

政务场景

- 政务公文摘要：快速生成公文核心摘要，提高办公效率。
- 公文标签生成：自动提取公文关键标签，便于分类检索。

外部应用（第三方AI能力）

- 盘古大脑知识问答助手：提供意图识别、纠错改写、知识增强问答等智能对话能力。
- 知网·AI学术研究助手：结合大模型与知网资源，支持科研检索、研读、创作全流程。
- 知网·AI智能写作：辅助撰写调研报告、技术方案、工作总结等文档。
- 知网·政知通智能辅政系统：提供公文生成、政策比对、决策辅助等功能。
- 知网·律境法律大模型：支持法律问答、智慧办案、合规审查等法律AI应用。

如何使用预置应用

1. 进入Agent开发平台后，在导航栏选择“应用百宝箱”。
2. 通过分类筛选（通用、医疗、金融、政务）找到目标应用。单击目标应用（如“中英文互译”）。
3. 根据提示输入需要Agent应用生成的内容。
4. 在应用的右上部分，单击“复制到工作台”，这样就可以复制此应用为自己所用。

7.3 应用搭建与配置

7.3.1 快速搭建 Agent 应用

整体概述

随着人工智能技术的不断进步，大模型在医疗领域的应用逐渐成熟。通过结合医学知识库、自然语言处理和智能交互技术，医疗问诊助手智能体能够为患者提供初步的健康咨询、症状分析和诊断建议，同时减轻医生的工作负担，提升医疗服务效率。

本教程将指导你如何在Agent开发平台上搭建一个医疗问诊助手，用于获取健康建议。

Agent 应用问答效果

与医疗问诊助手Agent进行对话时，可以模拟医生的问诊方式，逐步引导用户给出症状信息，并给出健康建议。

图 7-1 Agent 应用问答效果



步骤 1：创建 Agent 应用

1. 登录Agent开发平台。
2. 单击“工作台 > 应用”，在页面右上角单击“创建应用”菜单。
3. 输入应用名称和应用描述，为应用选择一个图标作为头像。
4. 单击“确认”。

创建应用后，直接进入应用编排页面。您可以：

- 在左侧**提示词**面板中描述应用的身份和任务。
- 在中间**技能**面板为应用配置各种扩展能力。
- 在中间**对话体验**面板为应用设置各种对话配置。
- 在右侧**预览调试**面板中，实时调试应用。

图 7-2 创建应用

×

创建应用

应用名称

医疗问诊助手

应用描述

医疗问诊助手，模拟医生进行问诊，询问患者的病情，并给出建议和治疗方案

34/256



取消 确定


步骤 2：编写提示词

配置应用的第一步就是编写**提示词**，也就是应用的人设与回复逻辑。应用的**提示词**定义了应用的基本人设，此人设会持续影响应用在所有会话中的回复效果。建议在人设与回复逻辑中指定模型的角色、任务描述、约束条件、执行步骤和输出格式等。

在应用配置页面的**提示词**面板中输入提示词。例如医疗问诊助手的提示词可以设置为：

```
你是一名私人数字健康管理师。你能够和医生一样进行问诊，询问患者的病情，并给出建议和治疗方案。
\n\n\n
要求：\n
1. 专注于疾病、症状、检查、药物等相关询问，\n
2. 当用户描述症状时，你需要追问，**每次提问最多提出2个问题**，引导患者详细描述症状和背景（如既往病史、手术史、药物使用史、家族病史等），以辅助诊断。\n
3. 当患者信息足够或你已全面理解患者的主要问题及症状发展后，直接总结病情，建议必要的检查、治疗方案和就诊科室。\n
4. 确保回答准确、简洁，直接相关患者当前健康状况或问题，避免偏题。\n
5. **不重复历史对话中的问题**。如患者未回答某问题，不再追问。\n
6. **不重复患者描述的症状**。确保对话内容新颖且相关。\n
7. 你返回的内容不应该超过100字，注意每句话应该换行。\n
8. **严禁回答医学知识以外的问题，如闲聊、娱乐等**。\n
请严格遵守以上规则，仅提供**必要的、简洁的**回答。
```


图 7-3 编写提示词



您可以使用平台的**智能优化提示词**功能对上述的提示词进行优化。

图 7-4 智能优化提示词



优化后的结果如下：

```
## 人设
- 角色：私人数字健康管理师
- 专业技能：疾病诊断、症状分析、检查建议、药物治疗建议

## 任务描述
- 目标：通过问诊，了解患者的病情，提供必要的建议和治疗方案。
- 积极影响：帮助用户更好地理解自己的健康状况，提供针对性的医疗建议。

## 约束条件
- 专注于疾病、症状、检查、药物等相，了解患者的病情，提供必要的建议和治疗方案。
- 每次提问最多提出2个问题。
- 不重复历史对话中的问题。
- 不重复患者描述的症状。
- 回答不超过100字，每句话换行。
- 严禁回答医学知识以外的问题。

## 执行步骤
1. 询问患者的主要症状。
2. 根据患者描述，追问相关背景信息（既往病史、手术史、药物使用史、家族病史等）。
3. 总结病情，建议必要的检查、治疗方案和就，了解患者的病情，提供必要的建议和治疗方案。

## 输出格式
- 风格：准确、简洁、直接相关患者当前健康状况或问题。
- 字数：不超过100字。
- 格式：每句话换行。
```


步骤 3：为 Agent 添加技能（可选）

如果模型能力可以基本覆盖应用的功能，则只需要为应用编写提示词即可。但是如果你为应用设计的功能无法仅通过模型能力完成，则需要为应用添加技能，拓展它的能力边界。例如模型的训练数据是互联网上的公开数据，模型通常不具备垂直领域的专业知识，如果应用涉及专业领域知识的智能问答场景，你需要为其添加专属的知识库，解决模型专业领域知识不足的问题，更多详情请参考[为Agent应用提升技能](#)章节。

作为医疗问诊助手机器人，模型能力基本可以实现我们预期的效果。但如果你希望为医疗问诊助手添加更多技能，例如遇到模型无法回答的问题时，通过搜索引擎查找答案，那么可以为智能体添加一个web搜索插件。

1. 在编排页面的技能区域，单击**插件**功能对应的 + 图标。
2. 在**添加插件**页面，搜索 **WebSearch**，选中插件后单击“确定”即可完成添加。

图 7-5 添加插件



3. 修改**提示词**中的人设与回复逻辑，指示应用使用 **WebSearch** 插件来回答自己不确定的问题。否则，应用可能不会按照预期调用该工具。


图 7-6 修改提示词

```
## 执行步骤
1. 询问患者的主要症状。
2. 根据患者描述，追问相关背景信息（既往病史、手术史、药物使用史、家族病史等）。
3. 总结病情，建议必要的检查、治疗方案和就诊了解患者的病情，提供必要的建议和治疗方案。
4. 遇到你无法回答的问题时，请使用websearch插件搜索答案
```

步骤 4：设置开场白、推荐问题、追问


1. 添加开场白。
- 您可以为应用添加一个开场白，该开场白将气泡内作为应用开场白展示给用户。你也可以使用开场白菜单右侧的“智能添加”按钮自动用生成开场白。

图 7-7 添加开场白




2. 添加推荐问题。
- 您可以为应用添加一些预置的推荐问题。可以为该医疗问诊助手添加一些推荐问题，例如“我想增加肌肉量，怎么办？”“最近有点咳嗽”，“我肚子疼”等。你也可以单击推荐问题菜单右侧的“智能添加”按钮自动产生一些推荐问题。

图 7-8 添加推荐问题



3. 设置追问。
- 在每轮回复后，默认根据对话内容提供提问建议，您可以使用开关按钮启动或关闭追问功能。同时您也可以自定义追问生成规则。例如：

图 7-9 设置追问



步骤 5：调试 Agent 应用

配置好应用后，就可以在预览调试区域中测试应用是否符合预期。

图 7-10 调试 Agent



7.3.2 为 Agent 应用提升技能

7.3.2.1 配置插件

Agent开发平台提供了一个丰富的插件生态系统，以增强智能体的功能。插件是一种工具集，一个插件即是一个API工具。目前，平台集成了类型丰富的插件，包括文件处理、代码解释器、全网热搜榜、高德地图等工具，这些插件能够帮助开发者快速为智能体添加特定功能。此外，平台还支持创建自定义插件，允许开发者将已有的API能力通过参数配置的方式快速集成到智能体中，进一步丰富其功能。

使用限制

表 7-6 插件限制说明

类别	说明
最大插件数量	最大数量不超过20个
插件URL	URL协议只支持HTTP和HTTPS
请求方法	插件服务的请求方式，POST或GET

添加预置插件

应用支持添加插件技能，可添加“预置插件”和“个人插件”。

如果需要添加“个人插件”，请确保已完成创建个人插件操作。

添加插件的步骤如下：

1. 在“技能 > 插件”模块，单击“+”。
2. 在“添加插件”窗口，选择预置插件，在预置插件右侧单击“+”进行添加，再单击“确定”。
3. 添加插件后，可在“技能 > 插件”中查看当前已添加的插件。

图 7-11 添加预置插件



创建个人插件

1. 在“技能 > 插件”模块，单击“+”。
2. 在“添加插件”窗口，选择个人插件，在个人插件右侧单击“+”进行添加，再单击“确定”。
3. 若还未创建个人插件，可在右上角单击“创建插件”，创建后再添加。
4. 添加插件后，可在“技能 > 插件”中查看当前已添加的插件。创建插件详细过程请参见[插件开发与配置](#)。

图 7-12 添加个人插件



移除插件

- 1. 在“技能 > 插件”模块，在已添加的插件右侧单击 。
- 2. 页面提示插件删除成功则表示插件已移除。

图 7-13 移除插件



7.3.2.2 配置 workflow

工作流是Agent开发平台中用于设计和实现复杂任务自动化的核心工具，它通过任务编排、条件判断以及多种组件的协同功能，帮助开发者高效处理复杂任务。工作流中包含大模型节点、知识检索节点、意图识别节点、判断节点、代码节点等多种节点，每个节点都具有特定的功能，能够处理数据、执行任务和运行算法。通过可视化设计，开发者可以清晰地看到数据的流转过程和任务的执行顺序，从而完成复杂的Agent任务编排。

添加 workflow

应用支持添加 workflow 技能。工作流支持通过画布编排的方式，使用插件、大模型等不同节点的组合，从而实现复杂、稳定的业务流程编排。

如果需要添加 workflow，请确保已完成编排 workflow 操作，编排 workflow 详细过程请参见[工作流开发与配置](#)。

添加 workflow 的步骤如下：

- 1. 在“技能 > workflow”模块，单击“

文档版本 01 (2025-07-28)

版权所有 © 华为云计算技术有限公司


235

图 7-14 添加 workflow



3. 添加插件工作流后，可在“技能 > 工作流”中查看当前已添加的工作流。


图 7-15 已添加工作流



移除工作流

1. 在“技能 > 工作流”模块，在已添加的工作流右侧单击。
2. 页面提示“删除工作流成功”则表示工作流已移除。

图 7-16 移除工作流



7.3.2.3 配置知识库

知识库是Agent开发平台中用于存储、管理和检索领域知识的核心组件，它通过结构化存储、智能检索以及动态更新机制，为Agent提供精准的信息支持。知识库支持doc, pdf, pptx, xlsx, csv等多种格式上传，通过多源知识融合和向量化处理，知识库可实现对复杂语义的理解和推理，从而为Agent的决策、问答和任务执行提供可靠的知识支撑。开发者能够灵活配置知识来源、更新策略和检索方式，确保Agent在不同场景下快速调用精准信息，完成智能化服务。

添加知识库

应用支持添加知识库。发送消息时，应用能够引用知识库中的内容回答用户问题，当前仅支持关联1个知识库。

如果需要添加知识库，请确保已完成创建知识库操作，创建知识库详细操作请参见[知识库开发与配置](#)。

添加知识库的步骤如下：


- 1. 在“知识库”模块，单击“+”。
- 2. 在“添加知识库”窗口，单击“+”进行添加，再单击“确定”。

图 7-17 添加知识库



- 3. 添加知识库后，可在“知识库”中查看当前已添加的知识库。

图 7-18 已添加知识库



知识库命中测试

平台支持对创建的知识库进行命中测试，以评估知识库的效果和准确性。

知识库命中测试步骤如下：

- 1. 在“工作台 > 知识库”页面，单击所需知识库，进入知识库基本信息页面，单击右上角“命中测试”。

- 在文本框中输入问题，单击“命中测试”，页面下方将根据不同的检索方式，展示多条匹配的内容，并按照匹配分值降序排列。
用户可以根据分值与匹配到的信息数量来评估当前知识库是否满足需求。

知识库召回策略

- 在“知识库”模块，单击“”对知识库进行高级配置，包括相关度阈值、topk召回数量与FAQ直出阈值。
 - 相关度阈值：超过相关度阈值的搜索结果会提交给大模型进行总结，否则被过滤，可以参考知识库中命中测试的相关度分值调整该阈值。
 - topk召回数量：召回的相关性阈值top切片数量，如topk召回数量为5，则相关性阈值为前5的切片将被召回提交给大模型总结。
 - FAQ直出阈值：知识库中有得分超过该阈值的FAQ会被召回，此时不再检索知识库内的文档。如果没有满足阈值要求的FAQ，则会继续检索知识库内的文档。可以参考知识库FAQ命中测试结果调整该阈值。取值范围为0~1。

图 7-19 知识库高级配置



7.3.2.4 配置 MCP


Agent应用支持添加MCP服务技能，可添加“预置服务”和“个人服务”。添加MCP服务可以为应用配备更多技能，建议MCP服务数量不超过5个。

如果需要添加“个人服务”，请确保已完成[创建MCP服务](#)操作。

添加 MCP 服务

- 在“技能 > MCP服务”模块，单击“”。

图 7-20 配置应用 MCP 服务



2. 在“添加MCP服务”窗口，选择“预置服务”或“个人服务”，单击“添加”进行添加，再单击“确定”。

图 7-21 添加



3. 添加MCP服务后，可在“技能 > MCP服务”中查看当前已添加的MCP服务。


7.3.2.5 提升 Agent 应用对话体验

配置开场白

开场白是用户进入Agent后首先看到的引导信息，能够帮助用户迅速了解Agent的功能和用途，明确如何与Agent进行有效交互。开场白需要简洁明了，语气友好并且表述清晰。

- 在“对话体验 > 开场白”中，可填写开场白，也可单击“智能添加”智能添加开场白。
例如，“您好！我是您的智能助手，很高兴为您提供帮助。请告诉我，今天有什么我可以为您做的吗？”

图 7-22 配置开场白



对话体验

开场白

智能添加

输入开场白，该描述将在气泡内作为应用开场白展示给用户

0/500

配置推荐问题

推荐问题：推荐问题是用户首次与应用互动时，应用主动展示的一些问题或话题建议，提供预设选项，减少用户打字负担。

- 在“对话体验 > 推荐问题”中，可填写推荐问题，也可单击“智能添加”智能添加推荐问题。推荐问题至多配置3条。

例如，“请告诉我您需要什么帮助？如：帮我预定会议室、帮我查询天气预报。

图 7-23 配置推荐问题



对话体验

开场白

智能添加

输入开场白，该描述将在气泡内作为应用开场白展示给用户

0/500

推荐问题

智能添加

请输入

配置追问

追问：在每轮回复后，默认根据对话内容提供提问建议，可以挖掘用户的潜在需求。

- 在“对话体验 > 追问”中，可选择是否开启“追问”功能，若开启，模型在每轮回复后，默认根据对话内容提供提问建议。

图 7-24 配置追问

对话体验

开场白

智能添加

输入开场白，该描述将在气泡内作为应用开场白展示给用户

0/500

推荐问题

智能添加

请输入

追问

在每轮回复后，默认根据对话内容提供提问建议，您也可以自定义追问生成规则

追问prompt ?

- 问题应该与你最后一轮的回复紧密相关

- 问题不要与上文已经提问或者回答过的内容重复

- 每句话只包含一个问题，但也可以不是问句而是一句指令

- 推荐你有能力回答的问题

85/500

7.3.2.6 调试 Agent 应用

开发者可以在Agent应用搭建完成后，直接与Agent进行对话，实时观察其执行过程和响应效果，并根据需要对配置进行优化和调整。平台全链路调试功能，允许开发者查看每条用户请求从输入到响应的完整流程，从而精准定位问题并快速调整配置。

调试 Agent 应用

创建应用后，平台支持对应用执行过程的进行预览与调试。

调试应用的步骤如下：

1. 在页面右上角单击模型右边的“ ∨ ”，参考表7-7配置大模型参数。

表 7-7 大模型参数配置

参数	说明
模型选择	选择要使用的大模型，不同的模型效果存在差异。

参数	说明
模式选择	用于配置大模型的输出多样性。 包含取值： • 精确的：模型的输出内容严格遵循指令要求，可能会反复讨论某个主题，或频繁出现相同词汇。 • 平衡的：平衡模型输出的随机性和准确性。 • 创意性的：模型输出内容更具多样性和创新性，某些场景下可能会偏离主旨。 • 自定义：自定义大模型输出的温度和核采样值，生成符合预期的输出。
温度	调高温度会使得模型的输出更多多样性和创新性，反之，降低温度会使输出内容更加遵循指令要求但减少多样性，取值范围为0到1之间。 • 调高温度，会使得模型的输出更多多样性和创新性。 • 降低温度，会使输出内容更加遵循指令要求但减少多样性。 在基于事实的问答场景，可以使用较低的回答随机性数值，以获得更真实和简洁的答案；在创造性的任务例如小说创作，可以适当调高回答随机性数值。建议不要与核采样同时调整。
核采样	模型在输出时会从概率最高的词汇开始选择，直到这些词汇的总概率累积达到核采样值。核采样值可以限制模型选择这些高概率的词汇，从而控制输出内容的多样性，取值范围为0.1到1之间。

2. 在右侧“预览调试”的文本框中输入对话，应用将根据对话生成相应的回答。
3. 在调试过程中，单击右上角“调试”，可以查看当前会话或历史会话的运行结果与调用详情。

图 7-25 查看调试结果



调试信息说明

在调试台中有两个页面：运行结果页面、调用详情页面。

- 运行结果
运行结果中可以看到应用的执行开始时间、结束时间、运行时间等信息，还能看到输入和输出信息。对于性能的情况有个直观的认识。



- 调用详情
在触发应用时，调用链中展现具体事件的详细信息，包括触发的组件、事件耗时、事件的输入和输出信息等。便于开发者快速的追溯操作顺序并精准定位问题。



7.3.3 使用 API 调用 Agent 应用


Agent开发平台支持将创建好的应用进行API调用。在调用应用前，请先参考[为Agent应用提升技能](#)，完成创建应用操作。

获取调用路径

应用的调用路径获取步骤如下：

1. 登录ModelArts Studio平台，单击“AGENT开发”进入Agent开发平台。
2. 在“工作台 > 应用”页面，单击所需应用的“...” > 调用路径”。

图 7-26 获取应用调用路径 1



3. 在“调用路径”页面，单击“复制路径”即可获取调用路径。
- 其中，conversation_id参数为会话ID，唯一标识每个会话的标识符，可将会话ID设置为任意值，使用标准UUID格式，例如：下图中的:conversation_id可以替换成550e8400-e29b-41d4-a716-446655440000。

图 7-27 获取应用调用路径 2




获取 Token

参考《API参考》文档“如何调用REST API > 认证鉴权”章节获取Token。

使用 Postman 调用 API

1. 在Postman中新建POST请求，并填入应用的API接口。
2. 填写请求Header参数。
 - 参数名为Content-Type，参数值为application/json。
 - Header参数X-Auth-Token为必填项，参数值为[获取Token](#)中获取的Token值。

图 7-28 填写请求 Header



3. 在Postman中选择“Body > raw”选项，请求Body填写示例如下。其中，query参数为用户提出的问题，作为应用的输入。
- ```
{
 "query": "介绍下北京的景点"
}
```
4. 单击Postman界面“Send”，发送请求。当接口返回状态为200时，表示应用API调用成功，响应示例如下：
- ```
data:{"event":"start","createdTime":1744636611503}

data:{"event":"message","content":"北京","createdTime":1744636611816}

data:{"event":"message","content":"是","createdTime":1744636611854}

data:{"event":"message","content":"中国的","createdTime":1744636611890}
```



```
data:{"event":"message","content":"首都","createTime":1744636611925}

...

data:{"event":"message","content":"随时","createTime":1744636624119}

data:{"event":"message","content":"告诉我","createTime":1744636624154}

data:{"event":"message","content":"。","createTime":1744636624190}

data:{"event":"statistic_data","latency":{"overall":13.17},"createTime":1744636624265}

data:{"event":"summary_response","content":"北京是中国的首都，拥有丰富的历史文化遗产和现代化的城市景观。以下是一些著名的旅游景点推荐：\n\n### 历史文化景点\n- **故宫** - 特色: 世界上最大的宫殿复合体，明清两代的皇宫，展示了中国古代的建筑艺术和皇家文化。 - 建议: 建议预留至少半天时间参观，最好提前在线购票以避免排队。 \n- **天安门广场** - 特色: 世界上最大的城市广场，周围有人民英雄纪念碑、毛主席纪念堂等重要建筑。 - 建议: 早晨或傍晚时分参观，可以避免人流高峰。 \n- **颐和园** - 特色: 中国保存最完整的皇家园林，以昆明湖和万寿山为基础，融合了江南园林的设计风格。 - 建议: 适合全家出游，可以乘坐游船游览昆明湖。 \n\n### 现代景点\n- **鸟巢和水立方** - 特色: 2008年北京奥运会的主要场馆，现在成为了北京的标志性建筑。 - 建议: 晚上参观可以看到灯光秀，非常壮观。 \n- **798艺术区** - 特色: 集合了众多艺术展览和创意工作室，是艺术爱好者的天堂。 - 建议: 适合下午或傍晚时分参观，可以在此享受艺术氛围。 \n- **三里屯** - 特色: 北京最时尚的购物和娱乐区，有众多国际品牌店和餐厅。 - 建议: 适合晚上前往，体验北京的夜生活。 \n\n希望这些信息对您的旅行计划有所帮助！如果您需要更详细的行程规划或其他信息，请随时告诉我。", "role": "assistant", "createTime": 1744636624266}

data:{"event":"done","createTime":1744636624276}
```

7.3.4 管理 Agent 应用

在Agent平台中创建应用之后，可以管理工作台中的应用，例如删除或者复制自己创建的应用ID以及查看调用路径。

删除应用

📖 说明

- 只有应用的所有者可以删除应用。
- 删除应用时虽然不会同步删除应用资源库中的所有资源，但应用不可恢复，请谨慎操作。

删除应用的操作步骤如下：

- 登录Agent开发平台。
- 在左侧菜单栏，单击“工作台”。

图 7-29 工作台




3. 在工作台开发空间，选择待删除的应用，单击应用的右上部分展开功能列表，选择删除。

图 7-30 删除 Agent 应用



4. 弹出的对话框中单击确定。

图 7-31 删除二次确认



复制 ID

对于Agent应用除了具有页面操作的能力之外，还具有Chat API调用能力，对于AppID获取就十分必要。该ID为调用Agent应用接口的agent_id字段。

```
POST /v1/{project_id}/agents/{agent_id}/conversations/{conversation_id}
```

复制ID的操作步骤如下：

1. 登录Agent开发平台。
2. 在左侧菜单栏，单击“工作台”。

图 7-32 工作台



3. 在工作台开发空间，单击应用的右上部分展开功能列表，选择复制ID。

图 7-33 复制 ID



4. 弹出复制成功对话框，即可完成复制。



调用路径

调用路径可为Agent应用的API接口。详细API调用过程请参见[使用API调用Agent应用](#)。

图 7-34 获取调用路径



7.4 工作流开发与配置

7.4.1 工作流介绍

工作流是一系列相互关联的步骤，用于实现业务逻辑或完成特定任务。它为应用/智能体的数据流动和任务处理提供了一个结构化框架。

平台提供一个可视化画布，可以通过拖拽节点迅速搭建工作流。同时，支持在画布实时调试工作流。在工作流画布中，可以清晰地看到数据的流转过程和任务的执行顺序。

工作流节点介绍

Agent开发平台的工作流由多个节点构成，节点是组成工作流的基本单元。平台支持多种节点，包括开始、结束、大模型、意图识别、提问器、插件、判断、代码、知识检索和消息节点等节点。

创建工作流时，每个节点需要配置不同的参数，如输入和输出参数等，开发者可通过拖、拉、拽可视化编排更多的节点，实现复杂业务流程的编排，从而快速构建应用。

工作流方式主要面向目标任务包含多个复杂步骤、对输出结果成功率和准确率有严格要求的复杂业务场景。

在编排工作流时，可以使用以下节点进行功能设计，详情请参考[工作流节点配置参考](#)章节。

- 开始节点：开始节点是工作流的起始节点，用户输入的信息由开始节点传入。
- 结束节点：结束节点是工作流的最终节点，用于定义整个工作流的输出信息。

- 大模型节点：用于在工作流中引入大模型能力。
- 意图识别节点：用于根据用户的输入进行意图分类并导向后续不同的处理流程。
- 提问器节点：提供了在对话过程中向用户收集更多信息的能力。
- 插件节点：用于引入API插件，根据节点的输入，执行用户定义的插件，将插件执行结果作为节点的输出。
- 判断节点：编排应用时作为分支切换节点，可以根据输入满足的判断条件，指定执行对应的工作流分支。
- 代码节点：用于引入代码执行器，根据节点的输入，执行指定Python代码，节点的输出是代码执行的结果信息。
- 知识检索节点：可以根据输入参数从指定知识库内召回匹配的信息。
- 消息节点：定义一段文本内容，在工作流的执行过程中向用户发送该内容的消息。
- 循环节点：循环节点用于重复执行一系列任务。
- 变量赋值节点：变量赋值节点用于在循环执行过程中动态设置中间变量。
- 变量聚合节点：变量聚合节点能够将多路分支的输出变量整合为一个，方便下游节点统一配置。
- 输入节点：输入节点用于在工作流运行时收集用户输入。
- 工作流节点：实现工作流嵌套工作流的效果。
- MCP服务节点：MCP服务节点是工作流中实现第三方能力调用的核心组件之一。作为功能扩展的重要载体，该节点允许通过调用MCP服务来执行特定功能任务。每个MCP服务实质上是一个工具集合，可以提供模块化服务来拓宽工作流的能力边界，完成更复杂的任务。
- Agent节点：Agent节点提供了使用大模型的能力以及大模型工具调用的能力，可在节点中配置已部署的模型，用户可以通过编写Prompt、绑定插件让模型处理相应任务。

7.4.2 创建工作流

7.4.2.1 创建工作流

工作流是一系列相互关联的步骤，用于实现业务逻辑或完成特定任务。可以在智能体和应用搭建中通过工作流实现特定的任务或指令。无论是在智能体还是应用中使用工作流，都需要先创建一个可运行的工作流。

步骤 1：创建工作流

1. 登录Agent开发平台。
2. 单击左侧导航栏“工作台”，在“工作流”页签，单击右上角“创建工作流”。
3. 在“创建工作流”页面，[选择工作流类型](#)。填写工作流名称、英文名称与工作流描述。
4. 单击页面左下角的图片可修改工作流图标，单击“确定”，进入工作流编排页面。
初始状态下工作流包含**开始节点**和**结束节点**。
 - **开始节点**用于启动工作流。
 - **结束节点**用于返回工作流的运行结果。

图 7-35 创建工作流



步骤 2：编排 workflow

创建工作流后，在画布中添加节点，并按照任务执行顺序连接节点。
工作流内置了**多种基础节点**供您使用，同时还可以添加**插件节点**来执行特定任务。

- 1. 在左侧面板中选择要使用的节点（版本不同，节点可能会有差异，以当前的版本为准）。
- 2. 将各个节点相连接。
- 3. 配置节点的输入和输出参数。

图 7-36 编排 workflow





7.4.2.2 调试与发布 workflow

试运行 workflow

Agent开发平台支持对整个 workflow 进行试运行，也支持对 workflow 的单个节点进行调试。


- 试运行 workflow：
 - a. [workflow编排完成后](#)，单击右上角“试运行”，在对话框中输入问题，等待返回试运行结果。
 - b. 在试运行过程中，可以单击右上角“ 调试”查看调试结果，包括运行结果与调用详情。

图 7-37 调试结果示例



- 单节点调试，以调试“意图识别”节点为例：
 - a. 在 workflow 编排页面，单击意图识别节点的“”，进入单节点调试页面。
 - b. 编写输入参数内容，单击“开始运行”。

图 7-38 编写输入参数内容



- c. 可在“运行结果”页面查看当前节点的运行结果。
- d. 若运行成功，节点处也将显示“运行成功”字样。

图 7-39 单节点调试运行成功示例




发布 workflow

工作流试运行成功后，可对其进行发布，便于后续使用。

在工作流编排页面，单击右上角“发布”，输入版本号与描述，单击“发布”。

图 7-40 发布



7.4.2.3 对话型工作流程和任务型工作流程

平台提供了两种类型的工作流，即对话型工作流程和任务型工作流程，用户可以针对不同的任务或场景选择适合的工作流进行搭建。

对话型工作流程、任务型工作流程区别

工作流包含两种类型：

- 对话型工作流程。面向多轮交互的开放式问答场景，基于用户对话内容提取关键信息，输出最终结果。适用于客服助手、工单助手、娱乐互动等场景。
- 任务型工作流程。面向自动化处理场景，基于输入内容直接输出结果，无中间的对话交互过程。适用于内容生成、批量翻译、数据分析等场景。

说明

任务型工作流程不支持配置**输入节点、消息节点、提问器节点和Agent节点**。

图 7-41 任务型 workflow




表 7-8 区别说明

差异项	对话型工作流	任务型工作流
适用场景	客服助手、工单助手、娱乐互动等场景。	内容生成、批量翻译、数据分析等场景。
节点	支持输入节点、消息节点、提问器节点。	不支持输入节点、消息节点、提问器节点。
试运行方式	试运行界面与任务型工作流不同。 若“开始”节点有多个参数，先对除query参数外的参数进行配置，然后再以对话框口的形式进行试运行。	若“开始”节点有多个参数，在试运行时，需要对多个输入参数同时进行配置。

常见问题

对话型工作流、任务型工作流是否可以相互转换？

答：不可以。

7.4.2.4 工作流节点配置参考

7.4.2.4.1 开始和结束节点

开始节点用于开启触发一个工作流，结束节点用于返回一个工作流的最终结果。

开始节点

开始节点是一个工作流的起始节点，用于设定启动工作流所需的输入参数。开始节点只有输入参数，没有输出等其他参数。开始节点中默认有一个输入参数query，表示用户在本轮对话中输入的原始内容。你也可以按需添加其他参数，用于下游节点的输入。



开始节点参数配置说明如下：

- **数据类型：**开始节点支持配置String、Number、Boolean、Object、File、Array多种类型的输入参数，其中Object类型参数最多支持3层嵌套。
- **参数描述：**参数的描述信息，帮助模型理解传入参数的含义。将 workflow 绑定到智能体中使用时，模型会自动分析用户的Query，将Query中表达的信息填入对应的参数中。
- **是否必选：**参数是否必选。若未指定必选参数，workflow 无法执行。将 workflow 绑定到智能体中使用时，如果用户Query中缺少必选参数，则不会触发 workflow 调用。
- **参数默认值：**您可以设置输入参数的默认值，默认值将会回显到试运行界面的输入框中，其中Object类型参数的默认值需输入Json数据，后台会校验Json数据和参数定义的一致性后赋值。示例如下图所示。



开始

工作流的起始节点，包含用户输入信息，触发工作流

输入参数

参数名称	参数类型	描述 (可选)	必填
query	String	用户输入	☒
info	Obj...	个人信息	☒

默认值 (可选)

json

```
1 {  
2   "name": "xxq"  
3 }
```

结束节点

结束节点是工作流的最终节点，用于返回工作流运行后的结果。结束节点支持配置两种参数：输入参数和输出参数，分别对应两种返回方式，文本返回和变量返回。

结束

工作流的最终节点，用于返回工作流的运行结果

输入参数

参数名称	类型	值
result	引用	raw_output String

输出参数

参数名称	类型	值
info	引用	current_time String

指定回复

```
{{result}}  
|
```

结束节点参数配置说明如下：

输入参数：输入参数支持引用和输入两种类型，输入参数需要在指定回复的文本框中以{{variable_name}}的形式进行插入才能返回。

指定回复：您可以在文本框中编辑指定的回复内容，支持在文本中以{{variable_name}}的形式插入输入参数返回或直接返回输入参数。工作流的最终运行结果将按照指定回复中的内容返回。指定回复中不能插入输出参数。

输出参数：输出参数将以变量形式返回，支持引用和输入两种类型。工作流运行结束后会以 JSON 格式返回所有输出参数，适用于子工作流的场景。如果工作流直接绑定了智能体，对话中触发了工作流时，大模型会自动总结 JSON 格式的内容，并以自然语言回复用户。输出参数不能在指定回复中引用。

7.4.2.4.2 大模型节点

大模型节点提供了使用大模型的能力，可在节点中配置已部署的模型，用户可以通过编写Prompt、设置参数让模型处理相应任务。

大模型节点为**可选**节点，若无需配置，可跳过该步骤。

大模型节点配置步骤如下：

- 1. 拖动左侧“大模型”节点至画布中，单击该节点以打开节点配置页面。
- 2. 参照表7-9，完成大模型节点的配置。

表 7-9 大模型节点配置说明

配置类型	参数名称	参数说明
参数配置	输入参数	配置大模型处理需要的输入参数值，这些值会动态的添加到提示词中，默认设置的输入参数名为 query。 ● 参数名称：只允许输入字母、数字、下划线，且不能以数字开头。 ● 类型、值：支持“引用”和“输入”两种类型。 - 引用：支持用户选择工作流中已包含的前置节点的输出参数。 - 输入：将用户自定义的内容传递给大模型，设置为输入模式后，无论前置节点产生什么输出内容，都不会传递给大模型。

配置类型	参数名称	参数说明
	输出参数	该参数用于解析大模型节点的输出，并提供给后续节点的输出参数引用。 - 参数名称：参数的名称长度必须大于等于1个字符，并且字符只允许为下面三种类型： - 字母（A-Z或a-z） - 数字（0-9） - 特殊字符：_ 说明 用户自定义输出参数名称不允许与内置输出参数rawOutput同名。大模型节点有一个内置输出参数rawOutput，代表该节点未经解析的原始输出，与大模型节点相连的后序节点可以直接引用该输出。 - 参数类型：输出参数的类型，可选String、Integer、Number、Boolean。 - 描述：对于该输出参数的描述。 - 输出格式：支持输出的格式包括文本、Markdown、JSON。 文本：大模型原始内容输出，仅支持一个参数，默认为raw_output，支持修改名称； Markdown：期望模型输出markdown格式内容时选择。仅支持一个参数，默认为raw_output，支持修改名称； JSON：要求模型按Json格式响应；支持添加多个参数；
模型配置	模型选择	选择模型接入模块已配置的大语言模型。
	核采样	模型在输出时会从概率最高的词汇开始选择，直到这些词汇的总概率累积达到核采样值，核采样值可以限制模型选择这些高概率的词汇，从而控制输出内容的多样性。建议不要与温度同时调整。
	温度	用于控制生成结果的随机性。调高温度，会使得模型的输出更具多样性和创新性；降低温度，会使输出内容更加遵循指令要求，但同时也会减少模型输出的多样性。
提示词配置	提示词	配置输入给大模型的提示词，用于指导模型更好的完成任务。配置提示词时，支持使用{{variable}}格式引用当前节点输入参数中已定义好的参数。最终替换后的内容会传递给模型。
	记忆	是否打开记忆功能；打开后可记录多轮对话的内容，默认关闭。

图 7-42 大模型节点配置示例



3. 节点配置完成后，单击“确定”。
4. 连接大模型节点和其他节点。

7.4.2.4.3 知识检索节点

知识检索节点可以基于用户的输入，从指定知识库内召回匹配的信息，并将匹配结果以列表形式返回。该节点支持选择用户创建的知识库，创建步骤请详见[创建知识库](#)。

知识检索节点配置步骤如下：


1. 拖动左侧“知识检索”节点至画布中，单击该节点以打开节点配置页面。
2. 连接知识检索节点和其他节点。
3. 参照[表7-10](#)，完成大模型节点的配置。

表 7-10 知识检索节点配置说明

配置类型	参数名称	参数说明
参数配置	输入参数	● 参数名称：输入参数固定只有1个，参数名称为query且不可修改，类型是字符串，表示待知识检索的问题。 ● 类型、值：支持“引用”和“输入”两种类型。 - 引用：支持用户选择工作流中已包含的前置节点的输出变量值，限制String类型，适用于需要从前置节点输出中获取知识检索问题的场景。 - 输入：支持用户自定义输入问题，适用于知识检索问题固定的场景。

配置类型	参数名称	参数说明
	输出参数	知识检索节点的输出是一个对象数组，参数名是 output_list，表示所有满足检索要求的知识切片。数组中对象有三个属性： - document_name，知识切片所在的知识文档名称。 - content，知识切片的内容。 - score，知识切片的匹配度得分，output_list中的元素按照得分由高到低排序。 后续节点引用该输出参数，可以引用output_list，此时将获取全量的检索结果，包括文档名、切片内容和分数。也可以直接引用切片的属性，比如content，此时将获取output_list中第一条记录的切片内容。
知识库	知识库	支持选择用户所创建的知识库。
	相关度阈值	得分低于相关度阈值的搜索结果会被过滤，可以参考知识库命中测试的相关度分值调整该阈值。 取值范围为0~1。
	topk召回数量	从知识库中召回的最大切片数量，如topk召回数量为5，则得分不在前5的切片将被过滤。 取值范围为1~50。
	FAQ直出阈值	知识库中有得分超过该阈值的FAQ会被召回，此时不再检索知识库内的文档。如果没有满足阈值要求的FAQ，则会继续检索知识库内的文档。可以参考知识库FAQ命中测试结果调整该阈值。 取值范围为0~1。

图 7-43 知识检索节点配置示例



4. 节点配置完成后，单击“确定”。

7.4.2.4.4 意图识别节点

意图识别节点主要是让应用理解用户自然语言表达的意图或目的，可用于需要对用户问题进行分类，或者提供综合类功能有不同分支处理的场景。

意图识别节点通过对用户输入进行推理分析，匹配预定义的意图关键字类别，并根据匹配结果引导至相应的处理流程，该节点通常位于工作流的前置位置。

意图识别节点支持普通模式或高级模式运行。

- 普通模式：适用于对少量意图进行分类的场景
- 高级模式：适用于对大量可归类意图进行分类的场景

意图识别节点为**可选**节点，若无需配置，可跳过该步骤。

意图识别节点配置步骤如下：


1. 拖动左侧“意图识别”节点至画布中，单击该节点以打开节点配置页面。
2. 参照表7-11，完成意图识别节点的配置。

表 7-11 意图识别节点配置说明

配置类型	参数名称	参数说明
模型配置	模型选择	用于配置进行意图识别的大模型，可选择平台已接入的任一模型。
	温度	用于控制生成结果的随机性。调高温度，会使得模型的输出更具多样性和创新性；降低温度，会使输出内容更加遵循指令要求，但同时也会减少模型输出的多样性。
	核采样	模型在输出时会从概率最高的词汇开始选择，直到这些词汇的总概率累积达到核采样值，核采样值可以限制模型选择这些高概率的词汇，从而控制输出内容的多样性。建议不要与温度同时调整。
参数配置	输入参数	● 参数名称：默认名称input，为固定值，不可编辑。 ● 类型、值：支持“引用”和“输入”两种类型。 - 引用：支持用户选择工作流中已包含的前置节点的输出变量值。 - 输入：支持用户自定义取值。
	输出参数	固定输出classification_id和name参数。 ● classification_id：识别意图的对应序号。 ● name：识别意图的具体内容。
意图配置	意图	用于配置相关意图关键字信息，用户可以添加意图，意图类别默认为意图1、意图2...，意图数量最多为20个。 在意图输入框中输入意图描述信息，描述信息为针对该类别的描述语句或者关键词，也将作为大模型进行推理和分类的依据。

配置类型	参数名称	参数说明
	其他意图	用于控制用户输入意图无法识别的场景，如果推理分析后无法匹配预定义的意图分类，会默认走其他意图对应分支执行后续流程。
高级配置	提示词	高级可选配置项，提供进阶开发者修改提示词，如果不配置将会使用系统默认值。提示词的撰写可能影响到意图识别节点的准确性。
	历史对话轮次	选择是否打开历史对话引用功能，默认为0即不会引用对话历史，配置N轮即可记录N轮对话的内容。
	辅助识别	开启辅助识别后，优先通过知识库分类样例的精确匹配进行意图识别，提升意图识别节点的分类能力。 - 意图样例知识库：开启辅助识别，用户需要先创建分类样例知识库，并选择配置该知识库。 - 匹配阈值：当分类样例的匹配度低于设置阈值时，会采用默认的大模型进行意图识别分类。阈值范围为0到1。

图 7-44 意图识别节点配置示例




- 节点配置完成后，单击“确定”。
- 连接意图识别节点和其他节点。

示例：

以提供综合功能，对用户问题进行不同分支处理的工作流为例，通过意图识别节点对用户输入进行分类，流转至不同的功能模块进行处理。

比如提供翻译功能的工作流，节点配置如下：

- 意图识别节点：工作流将用户问题分为翻译、闲聊两个类别，节点的意图配置添加意图1的类别描述为“文本翻译”，类别后面连接翻译插件节点，实现翻译功能；意图2的类别描述为“用户闲聊”，类别后面连接大模型节点，实现闲聊功能；默认的其他意图类别后面连接消息节点，在消息节点中配置默认回复内容，实现未识别意图场景下的兜底回复。



高级模式

当意图分支比较多（100+）时，建议使用高级模式；在独立的页面配置意图分支信息，通过选择子工作流的交互方式完成业务配置。

配置步骤：

- 配置意图包。
 - 单击平台左侧菜单“配置管理>意图管理”页面的“创建意图包”。
 - 在意图包中单击+添加意图分类，分类信息包含名称和示例。

图 7-45 配置意图包



- 拖动左侧“意图识别”节点至画布中，单击该节点以打开节点配置页面。切换为“高级模式”。
- 参照意图模式配置说明，完成配置。

表 7-12 意图识别节点配置说明

配置类型	参数名称	参数说明
模型配置	模型选择	用于配置进行意图识别的大模型，可选择平台已部署的任一模型。
	温度	用于控制生成结果的随机性。调高温度，会使得模型的输出更具多样性和创新性；降低温度，会使输出内容更加遵循指令要求，但同时也会减少模型输出的多样性。
	核采样	模型在输出时会从概率最高的词汇开始选择，直到这些词汇的总概率累积达到核采样值，核采样值可以限制模型选择这些高概率的词汇，从而控制输出内容的多样性。建议不要与温度同时调整。
参数配置	输入参数	- 参数名称：默认名称input，为固定值，不可编辑。 - 类型、值：支持“引用”和“输入”两种类型。 - 引用：支持用户选择工作流中已包含的前置节点的输出变量值。 - 输入：支持用户自定义取值。
	输出参数	固定输出classification_id和name参数。 - classification_id：识别意图的对应序号。 - name：识别意图的具体内容。
意图配置	意图包	选择前面已经配置的意图包。
高级配置	提示词	高级可选配置项，提供进阶开发者修改提示词，如果不配置将会使用系统默认值。提示词的撰写可能影响到意图识别节点的准确性。
	记忆	选择是否打开记忆功能，默认关闭。若开启记忆，可记录多轮对话的内容。

图 7-46 意图识别节点配置示例



- 4. 节点配置完成后，单击“确定”。
- 5. 单击意图动作节点，配置分支对应的处理逻辑。

图 7-47 配置处理逻辑



- 6. 配置子工作流的输入参数。

图 7-48 配置输入参数



- 7. 单击确定，完成意图动作节点配置。
- 8. 连接意图动作节点和其他节点。

7.4.2.4.5 插件节点

插件节点是工作流中实现第三方能力调用的核心组件。作为功能扩展的重要载体，该节点允许通过调用插件来执行特定功能任务。每个插件实质上是经过标准化封装的API工具集合，提供即插即用的模块化服务，拓宽工作流的能力边界，完成更复杂的任务。

插件类型包括预置插件和个人插件。

- 预置插件：平台预置了代码解释器插件，能够执行输入的代码，得到运行结果。支持开发者直接将插件添加到工作流或应用中，丰富其能力。
- 自定义插件：平台允许开发者创建自定义插件，支持将API通过配置方式快速创建为插件，提供给工作流或应用调用。

插件节点为**可选**节点，若无需配置，可跳过该步骤。


插件节点配置

1. 拖动左侧“插件”节点至画布中，在“个人插件”或“预置插件”页签单击“+”，将插件添加至画布中。
预置插件为平台内置的插件，个人插件为用户自定义的插件，创建插件步骤详见[创建插件](#)。
2. 连接插件节点和其他节点。
3. 单击画布中已添加的“插件”节点，参照[表7-13](#)，完成插件节点的配置。

表 7-13 插件节点配置说明

配置类型	参数名称	参数说明
参数配置	输入参数	● 参数名称：从插件元信息中导入，用户无需手动添加。 ● 类型、值：支持“引用”和“输入”两种类型。 - 引用：支持用户选择工作流中已包含的前置节点的输出变量值，适用于需要从前置节点输出中获取插件入参的场景。 - 输入：支持用户自定义取值，适用于插件入参取值固定的场景。
	输出参数	输出参数所有信息从插件元信息中自动导入，用户无需手动修改。
异常配置	-	“异常配置”开关，作为插件节点的兜底配置，当插件执行异常时，支持配置兜底返回，避免整个工作流运行失败： ● 关闭时，该功能不起作用。 ● 开启时，填写“默认输出”，默认输出的参数需要与插件“输出参数”一致。当工作流插件节点运行正常时，该配置对后续节点没有影响。当工作流运行到插件节点出现异常时，工作流不会中止，继续运行后续节点。如果后续节点引用了插件节点的输出内容，则使用“默认输出”的内容。

图 7-49 插件节点配置示例



4. 节点配置完成后，单击“确定”。

示例：使用已部署的大模型创建插件

- 步骤1 部署一个服务，如部署Deepseek大模型。
并获取三方模型API请求地址。
- 步骤2 在平台创建插件，填写基本信息。

图 7-50 基本信息

1 基本信息

2 配置信息

3 参数信息

插件名称

test0715

插件英文名称

test0715

插件描述

test0715

仅我可见

☐

取消

下一步

步骤3 配置插件URL等请求信息。

图 7-51 配置信息

✓ 基本信息

2 配置信息

3 参数信息

插件URL

https://mastudio.com/v1/8c116cd9a81/deployments/88ab5

请求方式

POST

请求头

Key	Value
Content-Type	application/json

+ 添加请求头

权限校验

☐ 无需鉴权

☒ API Key

密钥位置

☒ Header ☐ Query

参数列表

参数名称	参数值
X-Auth-Token	*****

+ 添加参数

上一步

下一步

步骤4 根据API接口信息配置参数信息并单击“插件调测”。

确认无误后，单击“确定”即可创建插件。

图 7-52 参数信息

基本信息

配置信息

3 参数信息

请求参数

插件调试

参数封装

参数列表

参数名称	中文名称	参数类型	位置	默认值	描述	参数校验	必填
messages	信息	Arra...	Body	请输入	信息	☐	☒
role	角色	String	Body	请输入	角色	☐	☒
content	内容	String	Body	请输入	内容	☐	☒

+ 添加参数

响应参数

流式响应

参数封装

参数列表

参数名称	参数描述	参数类型	是否提取
message	信息	String	☒

+ 添加参数

上一步

确定

步骤5 在工作流中可以使用该插件。

拖动左侧“插件”节点至画布中，在“个人插件”页签单击“+”，将插件添加至画布中。

文档版本 01 (2025-07-28)

版权所有 © 华为云计算技术有限公司

271

图 7-53 使用插件



----结束

7.4.2.4.6 判断节点

判断节点是一个IF-ELSE节点，提供了多分支条件判断的能力，用于设计分支流程，实现逻辑判断功能。

判断节点中每个条件分支支持添加多个判断条件（且、或），同时支持添加多个条件分支。

当向该节点输入参数时，节点会逐个条件分支判断输入是否符合分支中预设的条件，符合则执行对应分支后的工作流程，如果没有符合条件的分支，则执行“ELSE”对应的工作流分支。

判断节点为**可选**节点，若无需配置，可跳过该步骤。

判断节点配置步骤如下：

- 1. 拖动左侧“判断”节点至画布中，单击该节点以打开节点配置页面。
- 2. 参照表7-14，完成判断节点的配置。

表 7-14 判断节点配置说明

配置类型	参数名称	参数说明
参数配置	IF	IF分支由[判断参数 比较条件 比较参数]组成一个条件表达式。 - 判断参数：条件表达式左边部分，需要选择来自前序节点的输出参数。 - 比较条件：条件表达式中间部分，当前支持的比较条件有：长度大于、长度大于等于、长度小于、长度小于等于、等于、不等于、包含、不包含、为空、不为空。针对不同的判断参数类型，前端将展示不同的比较条件。 - 比较参数：条件表达式右边部分，支持“引用”和“输入”两种类型。 - 引用：支持用户选择工作流中已包含的前置节点输出变量值。 - 输入：支持用户自定义取值。 - 添加条件：单击“+”，在当前条件分支中添加多个条件表达式，多个条件表达式之间通过“且”或“或”来连接。 - 单击“且”或“或”，可以切换该分支表达式的运算逻辑。
	ELSE	用于控制预设条件分支都不满足的场景，如果逐个分支判断都不符合条件，则默认走该分支执行后续工作流程。
	添加分支	可以添加新的条件分支ELSE IF，新分支的配置方式与IF分支相同。

图 7-54 判断节点配置示例



3. 节点配置完成后，单击“确定”。
4. 连接判断节点和其他节点。


示例：

以常见的String、Integer和Boolean类型条件判断为例，在开始节点中定义三种类型的参数，模拟判断节点的输入参数，实现对于不同类型参数在不同条件下的逻辑判断。


节点配置如下：

- 开始节点：定义三种类型参数，分别为String类型的string_key、Integer类型的int_key、Boolean类型的bool_key
- 判断节点：在IF条件分支中增加三个判断条件，条件表达式的判断参数分别引用开始节点上述的三种类型参数。对于不同类型的参数，前端展示的比较条件有所区别。


比如String类型为字符串相关的长度、包含和为空条件判断，示例中配置为判断string_key是否包含“abc”。



Integer类型为数值相关的大小等于条件判断，示例中配置为判断int_key是否大于6。



Boolean类型为true false条件判断，示例中配置为判断bool_key是否为true。



单击试运行，输入string_key: abcd、int_key: 7、bool_key: true查看效果



7.4.2.4.7 代码节点

代码节点支持编写Python代码来处理文本等复杂逻辑，生成业务期望的返回值。

代码节点为可选节点，若无需配置，可跳过该步骤。

代码节点配置步骤如下：

- 1. 拖动左侧“代码”节点至画布中，单击该节点以打开节点配置页面。
- 2. 参照表7-15，完成代码节点的配置。

表 7-15 代码节点配置说明

配置类型	参数名称	参数说明
参数配置	输入参数	配置代码运行需要的输入参数； ● 参数名称：只允许输入字母、数字、下划线，且不能以数字开头。 ● 类型、值：支持“引用”和“输入”两种类型。 - 引用：支持用户选择工作流中已包含的前置节点输出参数。 - 输入：支持用户自定义取值。
	输出参数	配置代码运行后需要输出的参数，需要与return返回的对象保持一致； ● 参数名称：只允许输入字母、数字、下划线，且不能以数字开头。 ● 参数类型：输出参数的类型，可选String、Integer、Number、Boolean等平台支持的类型。 ● 描述：对于该输出参数的描述。 ● 必填：选择当前输出参数是否必填。

配置类型	参数名称	参数说明
代码	-	编写Python代码片段，仅支持python系统库，不支持引入依赖包；代码配置示例如下： • 文本拼接示例代码。<pre>def main(args: dict) -> dict: # 注意在输入参数中定义名为input1的变量 input1 = args.get('input1') # 注意在输入参数中定义名为input2的变量 input2 = args.get('input2') res = { # 注意在输出参数中定义名为res的变量 "res": input1 + input2, } return res</pre> • 数学计算示例代码。<pre>def main(args: dict) -> dict: # 注意在输入参数中定义名为input1的变量 input1 = args.get('input1') try: input1 = int(input1) return { # 注意输出参数中定义res变量 'res': input1 * input1 } except Exception as e: return { # 注意输出参数中定义res变量 'res': "输入类型错误或者数字大小超出限制" }</pre> 说明 编写代码时不要更改第一行函数定义。

图 7-55 代码节点配置示例



3. 节点配置完成后，单击“确定”。

4. 连接代码节点和其他节点。

7.4.2.4.8 消息节点

消息节点可提供中间过程的消息输出能力，通过定义一段文本内容，在工作流执行过程中向用户发送该消息。

通常情况下，工作流会在执行完毕后通过结束节点输出最终的执行结果。当开发者想要在工作流执行过程中输出中间节点的结果，可以使用该节点。

消息节点为**可选**节点，若无需配置，可跳过该步骤。

消息节点配置步骤如下：

- 1. 拖动左侧“消息”节点至画布中，单击该节点以打开节点配置页面。
- 2. 参照表7-16，完成消息节点的配置。

表 7-16 消息节点配置说明

配置类型	参数名称	参数说明	配置示例（按场景写）
参数配置	输入参数	- 参数名称：只允许输入字母、数字、下划线，且不能以数字开头。 - 类型、值：支持“引用”和“输入”两种类型。 - 引用：支持用户选择工作流中已包含的前置节点的输出变量值。 - 输入：支持用户自定义取值。	在工作流运行到该节点时，如果想要向用户发送包含前置节点输入或输出参数的指定消息，可使用引用方式配置参数；如果想要向用户发送固定内容的指定消息，可使用输入方式配置参数。
指定回复	-	可撰写指定的回复信息，并支持以{{参数名称}}的形式插入变量。回复信息将在工作流执行到该节点时发送给用户。	例如想要在工作流执行过程中向用户发送前置知识检索节点的输出参数 "content"，就可以添加输入参数 "rep_out"，引用该"content"，并在指定回复中撰写：{{rep_out}}即可。

图 7-56 消息节点配置示例



3. 节点配置完成后，单击“确定”。
4. 连接消息节点和其他节点。

7.4.2.4.9 提问器节点

提问器节点为开发者提供了收集用户问题所需信息的功能。该节点会循环执行，直到收集到所有必需的信息为止。

提问器节点为**可选**节点，若无需配置，可跳过该步骤。

提问器节点配置步骤如下：

1. 拖动左侧“提问器”节点至画布中，单击该节点以打开节点配置页面。
2. 参照表7-17，完成提问器节点的配置。

表 7-17 提问器节点配置说明

配置类型	参数名称	参数说明
模式偏好	-	效果优先：效果优先模式下，会开启时间增强和反思功能，提参成功率更高，时延会增加。 - 时间增强：需要提取时间时，可以将自然语言的时间日期提取为YYYY-MM-DD HH:MM:SS标准格式的时间日期，比如：明天 12:30，提取为 2024-04-13 13:30:00 - 反思功能：数据提取之后，会让模型再判断一下是否提取正确，格式是否满足要求，不满足会尽量做一些修正。比如：期望提取电话号码，用户输入：我不记得电话号码，提取出：189*****，反思后会认为提取不正确，会继续追问 速度优先：速度优先模式下时延最低，提参成功率可能无法保障，速度优先模式下不开启时间增强和反思功能。

配置类型	参数名称	参数说明
模型配置	模型选择	选择执行此节点的模型，支持设置模型在此节点中的生成多样性等参数配置，使模型效果更符合你的预期。 提问器模型用于接收用户自然语言，提取用户配置的输出参数，效果优先时还用于提取结果反思和纠正。
	核采样	模型在输出时会从概率最高的词汇开始选择，直到这些词汇的总概率累积达到核采样值，核采样值可以限制模型选择这些高概率的词汇，从而控制输出内容的多样性。建议不要与温度同时调整。
	温度	用于控制生成结果的随机性。调高温度，会使得模型的输出更具多样性和创新性；降低温度，会使输出内容更加遵循指令要求，但同时也会减少模型输出的多样性。
参数配置	输入参数	设置需要添加到问题中的参数，参数值可以引用前置节点的输出参数，或设置为固定文本内容，可引用多个参数。 - 参数名称：只允许输入字母、数字、下划线，且不能以数字开头。 示例：输入参数为“pre_assigned_meeting_rooms”，希望用户在指定的多个选项中选出一个，后续问题配置为“有以下几个会议室供您选择：{{pre_assigned_meeting_rooms}}，请选择您想预订的会议室”。 - 类型、值：支持“引用”和“输入”两种类型。 - 引用：用户可以选择工作流中该节点的前置节点的输出变量作为取值。 - 输入：用户直接输入变量取值文本。

配置类型	参数名称	参数说明
	输出参数	该参数用于解析大模型节点的输出，并提供给后续节点的输入参数引用，支持多参数提取。 - 默认输出参数。 - USER_RESPONSE：用户原始输出。 - STATUS：提取状态。 0 正常成功提取，用户无确认。 10 正常成功提取，用户已确认。 100 取到部分参数，用户主动中断，已提参数报错，未提参数按格式置空。 101 取到部分参数，循环超轮次，已提参数报错，未提参数按格式置空。 201 大模型调用异常。 202 反思模块有错误。 - 参数提取：开启后，可增加需要提取的参数，参数可配置属性如下： - 参数名称：只允许输入字母、数字、下划线、短横线。 - 中文名称：不允许为空。 - 类型：输出参数的类型，可选String、Integer、Number、Boolean。 - 默认值：输出参数的默认值，大模型提取不到参数，并达到最大回复轮数时使用默认值。 - 描述：对于该输出参数的描述。 - 校验：开启后可自定义参数校验规则对输出参数规范性进行校验。规则包括参数名称、校验类型及校验规则。 - 提取：开启后该参数必须提取到或配置了默认值则使用默认值，关闭则该参数允许为空。 - 引用插件：参数提取可能是给插件使用，通过引用插件，可导入插件的参数信息及校验信息，提升配置效率。
问题配置	问题	该参数将在对话框中原样呈现给用户。如未配置此处，将由大模型根据输出参数描述，自动生成包含所有问题关键词的一个问题。 如：请问你的名字是什么。 可通过jinja语法在问题中使用输入参数 如：请问你是哪个班级的，可选班级有{{classes}}（ classes 先在input参数配置好）
	最大回复轮数	该参数用于设置与模型的最大交互次数，超过最大回复轮数还没有提取到参数则跳出提问者。
高级配置	允许用户退出交互	开启后，若用户在与提问器的对话交互中，表达“中止对话”类的意图，系统会自动结束当前提问，并跳转至结束节点。

配置类型	参数名称	参数说明
	提取参数完毕需要用户确认	开启后，若用户希望提问参数提取完毕后进行用户确认，则开启此功能。
	提取约束	提供大模型额外的约束信息，用于更准确的提取参数，例如指定被提取参数的格式要求。 举例：用户希望提取电话号码tel_number，约束里面可以写tel_number必须是11位数字
	追问模式	追问模式用来配置，在多次交互过程中，系统返回的参数追问语句生成模式。 - 默认：使用默认内置追问模板生成追问语句，每次追问内容相同。 - 智能追问：使用大模型生成语义良好，表达丰富的追问语句，每次追问内容丰富多变。 - 自定义追问：按照自定义模板配置生成追问语句。 '{unextracted_cn_field_names}'不可修改或删除。每次追问内容相同。 例如要提取名字和年龄参数 - 默认：请您提供名字，年龄相关的信息。 - 智能追问：您好，我们需要获取您的名字和年龄（模型生成，内容不固定） - 自定义追问：（自定义追问模板配置为：请问你的如下信息：{unextracted_cn_field_names}） 请问你的如下信息：名字，年龄
	示例配置	给大模型一段预期的参数提取示例，增强大模型对参数提取场景的理解。 模版： 输入query：我要坐飞机去呼和浩特学习培训 提取参数：{"location":"呼和浩特", "traveltool":"飞机"}
-	外部API改写	开启后，在调用大模型问答前将调用外部API完成对用户输入问题进行改写，改写API需满足如下要求： 1、POST请求且无需鉴权认证相关信息。 2、输入body体只包含text字段，例如：{"text": "需要改写的内容"}。 3、返回的结构体只包含text字段，例如：{"text": "改写后的内容"}。

图 7-57 提问器节点配置示例



- 3. 节点配置完成后，单击“确定”。
- 4. 连接提问器节点和其他节点。

7.4.2.4.10 循环节点

循环节点提供了循环执行节点的能力，可在循环体内配置需要循环的节点，用户可以通过在循环体内编排节点多次执行处理任务。

循环是一种常见的控制机制，用于重复执行一系列任务，直到满足某个条件为止。工作流提供循环节点，当需要重复执行一些操作，或循环处理一组数据时，可以使用循环节点实现。

循环节点为可选节点，若无需配置，可跳过该步骤。

循环节点配置步骤如下：


- 1. 拖动左侧“循环”节点至画布中，拖动其他需要循环执行的节点到循环体画布内部并编排（循环内执行需从循环输入节点开始，输出连接到循环输出节点，暂不支持交互式节点）。
- 2. 参照表7-18，完成循环节点的配置。

表 7-18 循环节点配置说明

配置类型	参数名称	参数说明
循环类型配置	使用数组循环	使用数组循环类似编程语言中的 for 语法结构。遍历循环用于遍历一个已知的序列，对序列中的每个元素执行一系列相同的步骤。 使用数组循环时，需要指定 arr_loop_var 的值，此参数仅支持引用上游节点的输出，且必须为数组格式。使用数组循环模式下执行循环节点时，循环的次数取决于循环数组引用的数组长度。 使用数组循环时，循环节点会遍历数组中的每个元素，每次循环都会将当前循环到的元素赋值给内置变量。内置变量仅限循环节点内部使用。目前支持的内置变量如下： • item：数组元素，即当前循环到的数组元素。 • index：数组索引，index+1 为当前循环的轮次。
	指定循环次数	指定循环次数模式通常用于批量、顺序处理数据的场景，需要同时设置循环次数。 循环次数默认为 5 次，支持设置为 1~1000 次。 使用参考： 回合制游戏，3局2胜可将循环次数设置为3。 网络爬虫爬取前1000个商品信息，循环次数设置为1000。
变量配置	循环数组	此参数只有在使用数组循环时支持配置，名称固定为 arr_loop_var，仅支持引用上游节点输出。
	中间变量	循环节点支持设置中间变量，此变量可作用于每一次循环。中间变量通常和循环体中的设置变量节点搭配使用，在每次循环结束后为中间变量设置一个新的值，并在下次循环中使用新值。 • 参数名称：只允许输入字母、数字、下划线，且不能以数字开头。 • 类型、值：支持“引用”和“输入”两种类型。 - 引用：支持用户选择工作流中已包含的前置节点的输出变量值。 - 输入：支持用户自定义取值。
	输出参数	循环节点的输出参数可设置为循环体的执行结果集合，表示当数组中所有元素运行完毕之后，将所有循环的运行结果打包输出给下游。也支持设置为中间变量的取值。

配置类型	参数名称	参数说明
终止条件	表达式	分支由[判断参数 比较条件 比较参数]组成一个条件表达式。 - 判断参数：条件表达式上半部分，需要选择来自前序节点的输出参数。 - 比较条件：条件表达式左侧，当前支持的比较条件有：长度大于、长度大于等于、长度小于、长度小于等于、等于、不等于、包含、不包含、为空、不为空。针对不同的判断参数类型，前端将展示不同的比较条件。 - 比较参数：条件表达式下半部分，支持“引用”和“输入”两种类型。 - 引用：支持用户选择工作流中已包含的前置节点输出变量值及全局配置中的记忆变量。 - 输入：支持用户自定义取值。 - 添加条件：单击“+”，在当前条件分支中添加多个条件表达式，多个条件表达式之间通过“且”或“或”来连接。 - 单击“且”或“或”，可以切换该分支表达式的运算逻辑。

图 7-58 循环节点配置示例



3. 节点配置完成后，单击“确定”。
4. 连接循环节点和其他节点。

7.4.2.4.11 变量赋值节点

变量赋值节点配置说明

变量赋值节点，将特定的值赋给变量，可以实现数据的动态更新和传递，使工作流能够根据实时数据做出相应的处理和决策；变量设置节点也支持在循环节点内部使用，

通过变量设置节点，将特定的值赋给中间变量，可以实现循环过程中数据的动态更新和传递。

变量赋值节点配置步骤如下：

1. 拖动左侧“变量赋值”节点至画布中，单击该节点以打开节点配置页面。
2. 连接变量赋值节点和其他节点。
3. 参照表7-19，完成变量赋值节点的配置。

表 7-19 变量赋值节点配置说明

配置类型	参数名称	参数说明
循环节点外变量赋值节点配置	变量赋值	变量赋值节点变量名称仅支持全局配置中记忆变量引用，值可支持引用或者输入两种。 类型、值：支持“引用”和“输入”两种类型。 - 引用：支持用户选择工作流中已包含的前置节点的输出变量值以及全局配置的中的记忆变量。 - 输入：支持用户自定义取值。
循环节点中变量赋值配置	变量赋值	变量赋值节点支持在循环体内部引用，只支持更改循环体中间变量的值，被赋值变量仅支持选择中间变量，值可支持引用或输入两种。适用于循环过程中动态更新中间变量，自定义循环逻辑中进行参数传递的场景。 类型、值：支持“引用”和“输入”两种类型。 - 引用：中间变量的值需要引用上游节点输出时勾选此项，支持用户选择工作流中已包含的前置节点的输出变量值以及循环体内置变量，包括index、item（数组循环）以及中间变量，适用于循环过程中修改中间变量的值为变量的场景。 - 输入：支持用户自定义取值，适用于循环过程中修改中间变量的值为固定值场景。

图 7-59 变量赋值节点配置示例



图 7-60 变量赋值节点在循环节点中配置示例



4. 节点配置完成后，单击“确定”。
5. 连接变量赋值节点和其他节点。

7.4.2.4.12 变量聚合节点

变量聚合节点能够对多个分支的输出进行聚合处理，方便后置节点统一配置。

如果 workflows 中设计了多个分支，往往需要一个节点来汇总所有分支的输出结果。在这种场景下，你可以使用变量聚合节点聚合多路分支的输出变量，变量聚合节点会读取多路分支中第一个不为空的值，供流程下游的节点使用和操作，不用额外处理未运行分支的输出结果，简化了数据流的管理。

变量聚合节点为可选节点，若无需配置，可跳过该步骤。

变量聚合节点配置步骤如下：

1. 拖动左侧“变量聚合”节点至画布中，单击该节点以打开节点配置页面。
2. 参照表7-20，完成变量聚合节点的配置。

表 7-20 变量聚合节点配置说明

配置类型	参数名称	参数说明	配置示例（按场景写）
参数配置	输出参数	- 参数名称：固定为 Group1，如果有多个分组则根据分组数量递增为 Group2、Group3 等。 - 参数类型：取决于对应聚合分组的变量数据类型。	/
聚合策略	-	通过指定策略对每个分组中的所有变量进行聚合处理，同一组内的变量实施相对应的聚合策略。 目前聚合策略仅支持设置为“返回每个分组中第一个非空值”，支持拖动变量、调整变量位置。例如组内按顺序设置三个变量 output1、output2 和 output3，将其聚合为一个变量 Group1，如果 ouput1 不为空，则用 output1 的值为 Group1 赋值；如果 ouput1 为空，则取 ouput2 的值，依次类推。	目前聚合策略仅支持设置为“返回每个分组中第一个非空值”。

配置类型	参数名称	参数说明	配置示例（按场景写）
聚合分组	-	默认只有一个分组 Group1，对应一个输出变量 Group1。分组中所有变量类型相同。如果需要输出多个变量，可以添加多个分组，依次递增为 Group2、Group3等。	/
聚合变量	-	在聚合分组中选择需要聚合的变量，每个分组只能聚合一种数据类型的变量。例如将多个 String 类型的变量聚合为一个 String 变量、将多个 Integer 类型的变量聚合为一个 Integer 变量。	例如判断节点或意图识别节点会将 workflow 拆分为多路分支，每次执行时，workflow 会根据判断条件或用户意图决定运行其中某一个分支，此时未执行的其他分支输出变量为空。你可以将多路分支都连接到变量聚合节点，并设置一个输出变量。无论哪条分支被执行，其结果都能通过这个变量被引用与访问，避免了下游节点对相同语义输出变量的重复定义。

图 7-61 变量聚合节点配置示例



3. 节点配置完成后，单击“确定”。
4. 连接变量聚合节点和其他节点。

7.4.2.4.13 输入节点

输入节点提供 workflow 运行过程中的信息输入。

在比较复杂的工作流场景中，某些节点的执行往往需要额外的用户输入。如果前置节点中没有获取到这些信息，你可以添加一个输入节点来主动收集信息。workflow 执行到输入节点时会暂时中断，直到此节点收集到必要的用户输入。

输入节点为**可选**节点，若无需配置，可跳过该步骤。

输入节点配置步骤如下：

1. 拖动左侧“输入”节点至画布中，单击该节点以打开节点配置页面。
2. 参照表7-21，完成变量输入节点的配置。

表 7-21 输入节点配置说明

配置类型	参数名称	参数说明	配置示例（按场景写）
参数配置	输入参数	支持配置一个或多个输入参数，且输入参数可被后置节点引用。 ● 参数名称：只允许输入字母、数字、下划线，且不能以数字开头。 ● 参数类型：可选String、Integer、Number、Boolean、Object、Array、File 类型。 ● 描述：对于该输入参数的描述。	当配置一个或多个输入参数后，workflow 运行到该节点时会暂时中断，直到用户填写所有输入参数，且每个输入参数均可被后置节点引用。 例如插件节点需要一个输入参数："city"，可通过在该插件节点的前置节点中配置一个输入节点用于填写"city"的具体值，再在插件节点的"city"参数处引用输入节点相应参数即可。

图 7-62 输入节点配置示例



3. 节点配置完成后，单击“确定”。
4. 连接输入节点和其他节点。

7.4.2.4.14 workflow节点

workflow节点，实现workflow嵌套workflow的效果。

在一个workflow中，你可以将另一个workflow作为其中的一个步骤或节点，实现复杂任务的封装。例如将常用的、标准化的任务处理流程封装为不同的子workflow，并在主workflow的不同分支内调用这些子workflow执行对应的操作。workflow嵌套可实现复杂任务的模块化拆分和处理，使workflow编排逻辑更加灵活、清晰、更易于管理。

workflow节点配置步骤如下：

1. 拖动左侧“workflow”节点至画布中，单击该节点以打开节点配置页面。
2. 参照[表1 workflow节点配置说明](#)，完成workflow节点的配置。

表 7-22 workflow节点配置说明

配置类型	参数名称	参数说明
参数配置	输入参数	• workflow节点的输入结构取决于子workflow定义的输入结构，不支持自定义设置 • 在workflow节点中你需要为输入参数指定数据来源，支持设置为固定值或引用上游节点的输出参数。
	输出参数	• workflow节点的输出结构取决于子workflow定义的输出结构，不支持自定义设置。 • response_content为workflow固定输出参数

图 7-63 workflow节点配置示例-子 workflow



图 7-64 workflow节点配置示例-workflow节点（输入和输出对应子 workflow 的输入和输出）



3. 节点配置完成后，单击“确定”。
4. 连接 workflow 节点和其他节点。

7.4.2.4.15 MCP 服务节点配置说明

MCP服务节点是 workflow 中实现第三方能力调用的核心组件之一。作为功能扩展的重要载体，该节点允许通过调用 MCP 服务来执行特定功能任务。每个 MCP 服务实质上是一个工具集合，可以提供模块化服务来拓宽 workflow 的能力边界，完成更复杂的任务。

MCP 服务类型包括预置服务和个人服务。

- 预置服务：平台预置了"高德地图"、"车票查询工具"、"必应搜索"等多种实用 MCP 服务，开通后可以一键集成调用。支持开发者在 workflow 或应用中添加预置 MCP 服务，丰富其能力。
- 个人服务：平台允许开发者创建自定义 MCP 服务，支持将 MCP 服务地址通过配置方式快速创建为自定义 MCP 服务，提供给 workflow 或应用调用。

MCP 服务节点为可选节点，若无需配置，可跳过该步骤。

MCP 服务节点配置步骤如下：


1. 拖动左侧“MCP服务”节点至画布中，在“个人服务”或“预置服务”页签单击“+”，将MCP服务添加至画布中，其中有些“预置服务”不能直接添加，需要单击“立即开通”，开通服务后即可添加至画布中。
- 预置服务为平台内置的MCP服务。

- 个人服务为用户创建的自定义MCP服务，创建MCP服务步骤详见[创建MCP服务](#)。
2. 连接MCP服务节点和其他节点。
3. 单击画布中已添加的“MCP服务”节点，参照[表1 MCP服务节点配置说明](#)，完成MCP服务节点的配置。

表 7-23 MCP 服务节点配置说明

配置类型	参数名称	参数说明
参数配置	工具	支持从当前MCP服务所包含的工具列表中选择一个作为 workflow 运行到该节点时会执行的工具。
	输入参数	● 参数名称、类型：从插件元信息中导入，用户无需手动添加。 ● 值：支持“引用”和“输入”两种类型。 - 引用：支持用户选择 workflow 中已包含的前置节点的输出变量值和全局配置中的记忆变量，适用于需要从前置节点输出中获取插件入参的场景。 - 输入：支持用户自定义取值，适用于MCP服务入参取值固定的场景。
	输出参数	输出参数所有信息从MCP服务元信息中自动导入，用户无需手动配置。

图 7-65 MCP 服务节点配置示例



4. 节点配置完成后，单击“确定”。

7.4.2.4.16 Agent 节点配置说明

Agent节点提供了使用大模型的能力以及大模型工具调用的能力，可在节点中配置已部署的模型，用户可以通过编写Prompt、绑定插件让模型处理相应任务。

Agent节点为可选节点，若无需配置，可跳过该步骤。

Agent节点配置步骤如下：

- 1. 拖动左侧“Agent”节点至画布中，单击该节点以打开节点配置页面。
- 2. 参照表7-24，完成变量输入节点的配置。

表 7-24 Agent 节点配置说明

配置类型	参数名称	参数说明
模型配置	模型选择	选择执行此节点的模型，支持设置模型在此节点中的生成多样性等参数配置，使模型效果更符合你的预期。
	核采样	模型在输出时会从概率最高的词汇开始选择，直到这些词汇的总概率累积达到核采样值，核采样值可以限制模型选择这些高概率的词汇，从而控制输出内容的多样性。建议不要与温度同时调整。
	温度	用于控制生成结果的随机性。调高温度，会使得模型的输出更具多样性和创新性；降低温度，会使输出内容更加遵循指令要求，但同时也会减少模型输出的多样性。
参数配置	输入参数	● 参数名称：只允许输入字母、数字、下划线，且不能以数字开头。 ● 类型、值：支持“引用”和“输入”两种类型。 - 引用：支持用户选择工作流中已包含的前置节点的输出变量值和全局配置中的记忆变量。 - 输入：支持用户自定义取值。
	插件	可绑定手动创建的插件或预制插件，当模型识别到需要调用工具来完成任务时，会根据用户的输入提取参数完成插件调用，并总结插件执行结果。
	系统提示词	配置输入给大模型的系统提示词，用于指导模型更好的完成任务。配置提示词时，支持使用{{variable}}格式引用当前节点输入参数中已定义好的参数。最终替换后的内容会传递给模型。
	输出参数	输出参数为Agent节点最后一轮的输出。
终止条件	最大迭代轮次	该参数用于设置与模型的最大交互次数，超过最大回复轮数还没有提取到参数则跳出Agent节点。
	插件执行成功	该参数开启后可绑定插件，当执行该插件成功后跳出Agent节点。

配置类型	参数名称	参数说明
	识别到用户有退出意图	该参数开启后识别到用户输入有退出意向时，跳出Agent节点。

图 7-66 Agent 节点配置示例

Agent

利用大语言模型进行目标规划、拆解、工具调用和迭代，自主完成任务

参数配置

参数名称

类型

值

role

输入

智能客服

插件

高德天气

高德天气，根据用户输入的 adcode，查询目标区域当前/未来的天气情况，数据...

提示词配置

系统提示词

你是一个{{role}}，你需要有耐心帮客户解决问题

终止条件

最大迭代轮次

用户与大模型的对话超出设置的最大轮次即可退出

1

5

10

15

20

-

9

+

次

插件执行成功

取消

确定

3. 节点配置完成后，单击“确定”。
4. 连接Agent节点和其他节点。

7.4.3 通过 API 调用 workflow


workflow试运行成功后，可以使用API调用该workflow。

获取调用路径

workflow的调用路径获取步骤如下：

1. 登录ModelArts Studio平台，单击“AGENT开发”进入Agent开发平台。
2. 在“工作台 > workflow”页面，单击所需workflow的“...” > 调用路径”。

图 7-67 获取workflow调用路径-1



3. 在“调用路径”页面，单击“复制路径”即可获取调用路径。
其中，conversation_id参数为会话ID，唯一标识每个会话的标识符，可将会话ID设置为任意值，使用标准UUID格式，例如：下图中的:conversation_id可以替换成550e8400-e29b-41d4-a716-446655440000。

图 7-68 获取workflow调用路径-2



获取 Token

参考《API参考》文档“如何调用REST API > 认证鉴权”章节获取Token。

使用 Postman 调用 API

1. 在Postman中新建POST请求，并填入工作流的调用路径，详见[获取调用路径](#)。

2. 填写请求Header参数。

参数名为Content-Type，参数值为application/json。

Header参数X-Auth-Token为必填项，参数值为[获取Token](#)中获取的Token值。
- 图 7-69 填写请求 Header
-
3. 在Postman中选择“Body > raw”选项，请求Body填写示例如下。

其中， inputs参数为用户提出的问题，作为工作流的输入。工作流有插件时，添加plugin_configs参数， plugin_id参数为插件ID，获取方式详见[管理插件](#)。
- 带插件请求

```
{
  "inputs": {
    "query": "你好"
  },
  "plugin_configs": [
    {
      "plugin_id": "xxxxxxxx",
      "config": {
        "key": "value"
      }
    }
  ]
}
```

不带插件请求

```
{
  "inputs": {
    "query": "介绍下北京"
  }
}
```
4. 单击Postman界面“Send”，发送请求。当接口返回状态为200时，表示应用API调用成功。
- 工作流带有提问器节点时返回示例如下所示。
- ```
{
 "conversation_id": "2c90493f-803d-431d-a197-57543d414317",
 "messages": [
 {
 "role": "assistant",
 "content": "你好"
 }
],
 "status": {
 "code": 1,
 "desc": "succeeded"
 },
 "start_time": 1734336269313,
 "end_time": 1734336270908
}
```
- 工作流不带提问器节点时的返回示例如下所示。
- ```
{
  "conversation_id": "2c90493f-803d-431d-a197-57543d414317",
  "outputs": {

```
- 文档版本 01 (2025-07-28)

版权所有 © 华为云计算技术有限公司

295

```
{
  "responseContent": "你好！有什么我可以帮助你的吗？",
},
"messages": [],
"status": {
  "code": 1,
  "desc": "succeeded"
},
"start_time": 1734337068533,
"end_time": 1734337082545
}
```

7.4.4 管理工作流

Agent开发平台支持对工作流执行复制、获取工作流ID、删除、导入、导出操作。

获取工作流 ID、删除工作流

1. 登录Agent开发平台。
2. 进入“工作台 > 工作流”页面。
3. 单击“...” > 复制”，可复制当前工作流。
4. 单击“...” > 复制ID”，可获取当前工作流ID。
5. 单击“...” > 删除”，可删除当前工作流。

图 7-70 获取工作流 ID、删除工作流



说明


删除应用属于高危操作，删除前，请确保该工作流不再使用。

导出、导入工作流

平台支持导出和导入工作流。导出工作流时，将同步导出工作流关联的插件等配置。

1. 登录Agent开发平台。
2. 进入“工作台 > 工作流”页面。
3. 导出工作流。
 - a. 单击页面右上角“导出”。

图 7-71 导出




- b. 在“导出工作流”页面选择工作流，单击“导出”。工作流将以一个jsonl格式的文件下载至本地。

图 7-72 导出工作流




4. 导入工作流。
- a. 单击页面右上角“导入”。

图 7-73 导入



- b. 在“导入”页面，单击“选择文件”选择需要导入的jsonl文件。
- c. 选择导入文件后，选择解析内容。
平台将自动解析jsonl文件。如果解析的文件在平台中已存在，勾选该文件将自动覆盖平台现有文件。
- d. 单击“导入”，导入成功的工作流将在“工作台 > 工作流”页面中展示。

图 7-74 导入



7.5 插件开发与配置

7.5.1 插件介绍

在Agent开发平台中，插件是大模型能力的重要扩展。通过模块化方式，插件能够为大模型提供更多专业技能和复杂任务处理能力，使其在多样化的实际场景中更加高效地满足用户需求。

通过插件接入，用户可以为应用赋予大模型本身不具备的能力。插件提供丰富的外部服务接口，当任务执行时，模型会根据提示词感知适用的插件，并自动调用它们，从外部服务中获取结果并返回。这样的设计使得Agent能够智能处理复杂任务，甚至跨领域解决问题，实现对复杂问题的自动化处理。

Agent开发平台支持两种类型的插件：

- 预置插件：平台为开发者和用户提供了预置插件，直接可用，无需额外开发。例如，平台提供的“Python解释器插件”能够根据用户输入的问题自动生成Python代码，并执行该代码获取结果。此插件为Agent提供了强大的计算、数据处理和分析功能，用户只需将其添加到应用中，即可扩展功能。
- 自定义插件：为了满足更个性化的需求，平台允许开发者创建自定义插件，支持将API通过配置方式快速创建为插件，并供Agent调用。这样，开发者可以根据特定需求为应用增加专属功能。

7.5.2 创建插件

7.5.2.1 基于 API 创建一个插件

创建插件

创建插件的步骤如下：

1. 登录Agent开发平台。
2. 单击左侧导航栏“工作台”，在“插件”页签，单击右上角“创建插件”。
3. 在“创建插件”页面，填写插件名称与插件描述，设置是否“仅我可见”（设置后仅插件创建者可见）。单击图片可上传插件图标，单击“下一步”。
4. 在“配置信息”页面，参照表7-25完成信息配置。

表 7-25 插件信息配置说明

参数名称	参数说明
插件URL	插件服务的请求URL地址。 • URL协议只支持HTTP和HTTPS。 • 系统会校验URL地址是否为标准的URL格式。 • URL对应的IP默认不应为内网，否则会导致注册失败。
请求方式	插件服务的请求方式，POST或GET。
权限校验	选择调用API时是否需要通过鉴权才可以调用。 • 无需鉴权：API可以公开访问，不需要任何形式的身份验证或授权。 • API Key：在调用API时提供一个唯一的API Key进行鉴权。需填写密钥位置，即密钥是从Header中读取还是Query中读取。并设置API Key的密钥鉴权参数名和密钥值。
请求头	填写API的请求头信息，例如： • Key: Content-Type • Value: application/json

图 7-75 API 请求信息配置示例

创建插件

您在使用本产品创建自定义插件的操作，属于用户自主行为，如因创建恶意攻击插件引发的问题和风险，由用户自行承担 不再提示

基本信息

2 配置信息

参数信息

插件URL

http://ip:port

请求方式

POST

请求头

Key

Content-Type

Value

application/json

+ 添加请求头

权限校验

无需鉴权

API Key

密钥位置

Header

Query

参数列表

参数名称

请输入

参数值

请输入

+ 添加参数

说明

自定义插件使用HTTP服务，不增加鉴权方式可能存在安全风险。

5. 单击“下一步”，在“参数信息”页面，参照表7-26完成参数配置。

表 7-26 插件参数配置说明

参数类型	参数名称	参数说明
请求参数	参数封装	开启后，会将请求参数封装为一个列表（数组）结构，可适配入参为数组格式的插件接口。 示例：原参数列表：{"a":"string", "b":1}，开启封装后的参数列表：[{"a":"string", "b":1}]
	参数名称	参数的名称，参数名称会作为大模型解析参数含义的依据。
	中文名称	该参数的中文名称。
	参数类型	该参数值的数据类型，String、Integer、Number等多种类型支持选择。
	位置	当前参数在请求信息中的位置，可选Body、Headers或Query。
	默认值	参数的默认值。

参数类型	参数名称	参数说明
	描述	参数的描述，尽可能准确的描述参数的含义和要求，可提升 Agent 提取参数的准确率。
	参数校验	可设置当前参数的校验规则。
	必填	指定该参数是否为必填项。
响应参数	参数封装	开启后，会将请求参数封装为一个列表（数组）结构，可适配入参为数组格式的插件接口。 示例：原参数列表：{"a":"string", "b":1}，开启封装后的参数列表：[{"a":"string", "b":1}]
	参数名称	响应参数的名称，参数名称会作为大模型解析大模型输出结果的依据。
	参数描述	响应参数的名称，参数描述会作为大模型解析大模型输出结果的依据。
	参数类型	该参数值的数据类型，String、Integer、Number等多种类型支持选择。
	是否提取	开启后则该参数必须提取到，关闭则该参数允许为空或者使用默认值。

图 7-76 填写 API 请求、响应参数

创建插件

您在使用本产品创建自定义插件的操作，属于用户自主行为。如因创建恶意攻击插件引发的问题和风险，由用户自行承担 不再提示

基本信息

配置信息

参数信息

请求参数

参数封装

参数列表

参数名称	中文名称	参数类型	位置	默认值	描述	参数校验	必填
请输入	请输入	String	Body	请输入	请输入	☐	☒

+ 添加参数

响应参数

参数封装

参数列表

参数名称	参数描述	参数类型	是否提取
请输入	请输入	String	☒

+ 添加参数

流式响应

7.5.2.2 通过 JSON 文件导入插件

平台支持通过JSON文件形式导入插件。

1. 登录Agent开发平台。
2. 进入“工作台 > 插件”页面。
3. 导入插件。
 - a. 单击页面右上角“导入”。
 - b. 在“导入”页面，单击“选择文件”选择需要导入的jsonl文件。
 - c. 选择导入文件后，选择解析内容。

平台将自动解析jsonl文件。如果解析的文件在平台中已存在，勾选该文件将自动覆盖平台现有文件。
 - d. 单击“导入”，导入成功的插件将在“工作台 > 插件”页面中展示。

7.5.3 管理插件

Agent开发平台支持对插件执行获取插件ID、删除、导入、导出操作。

获取插件 ID、删除插件

1. 登录Agent开发平台。
2. 进入“工作台 > 插件”页面。
3. 单击“ > 复制ID”，可获取当前插件ID。
4. 单击“ > 删除”，可删除当前插件。

说明

删除插件属于高危操作，删除前，请确保该插件不再使用。

导出、导入插件

平台支持导出和导入插件。

1. 登录Agent开发平台。
2. 进入“工作台 > 插件”页面。
3. 导出插件。
 - a. 单击页面右上角“导出”。
 - b. 在“导出插件”页面选择工作流，单击“导出”。插件将以一个jsonl格式的文件下载至本地。
4. 导入插件。
 - a. 单击页面右上角“导入”。
 - b. 在“导入”页面，单击“选择文件”选择需要导入的jsonl文件。
 - c. 选择导入文件后，选择解析内容。

平台将自动解析jsonl文件。如果解析的文件在平台中已存在，勾选该文件将自动覆盖平台现有文件。
 - d. 单击“导入”，导入成功的插件将在“工作台 > 插件”页面中展示。

7.6 知识库开发与配置

7.6.1 知识库介绍

平台提供了知识库功能来对文本文档等数据进行向量化存储、知识检索，支持为应用、工作流提供检索增强能力。无论是文本文档、演示文稿，还是电子表格文件，用户都可以轻松地将数据导入知识库，无需额外的转换或格式处理。

知识库支持导入以下格式的本地文档：

表 7-27 支持的文档格式

文档类型	约束说明	大小要求
知识文档	支持上传常见文本格式，包括：.doc, .docx, .pdf, .pptx, .ppt, .xlsx, .xls, .csv, .wps, .png, .jpg, .jpeg, .bmp, .gif, .tiff, .tif, .webp, .pcx, .ico, .psd, .dps, .et, .txt, .ofd, .md格式	• 单个文档上传限制最大10M
FAQ	支持按照模板上传文本，模板文件类型为Word及Excel。模板文件说明见 EXCEL模板格式 ， Word模板格式 。	• 单个Excel文件最大为10M，数据条数10000条，文件中不允许空行，空行后的数据将被忽略。 • 单个word文件最大为128M，须按照模板格式填写，【QUESTION】标题中为问题，内容为对应答案。文档中图片支持格式为png, .jpg, .jpeg。

EXCEL 模板格式

表 7-28 EXCEL 模板样例

答案	问题	相似问题1 (非必填)	相似问题2 (非必填)	相似问题3 (非必填)	相似问题4 (非必填)	目录 (非必填)	标签 (非必填, 逗号分隔)
云搜索服务（Cloud Search Service，简称 CSS）是一个基于 Elasticsearch 且完全托管的在线分布式搜索服务，为用户提供结构化、非结构化文本、以及基于 AI 向量的多条件检索、统计、报表。	什么是云搜索服务	什么是华为云搜索服务	云搜索服务是什么	华为云搜索服务是什么	什么是 CSS	-	-
云搜索服务可以帮助网站和 APP 搭建搜索框，提升用户的搜索体验；也可以用于搭建日志分析平台，助力企业实现数据驱动运维，数据驱动运营；它的向量检索能力可以帮助客户快速构建基于 AI 的图搜、推荐、语义搜索等丰富的应用。	云搜索服务有什么应用场景	云搜索服务有哪些应用场景	云搜索服务有什么作用	云搜索服务的作用有哪些	CSS 的作用有哪些	-	-
公有云提供了 Web 化的服务管理平台，即管理控制台和基于 HTTPS 请求的 API（Application programming interface）管理方式。	云搜索服务有哪些访问方式	云搜索服务提供了什么访问方式	如何访问云搜索服务	如何访问 CSS	-	-	-

Word 模板格式


Word 格式知识库模板将所有知识通过问答对的方式写入 word 文档，每一个 Q&A 对应一个标题对。问题以【QUESTION】开头，文本属性设置为“标题一”。答案另起一行，文本属性设置为“正文”。

7.6.2 创建知识库及上传文档

创建知识库

1. 登录Agent开发平台。
2. 单击左侧导航栏“工作台”，在“知识库”页签，单击右上角“创建知识库”。

图 7-77 创建知识库



3. 在知识库创建界面填写基础信息、向量精排模型配置、解析切分策略配置：
 - 基本信息：配置知识库图标，填写名称、描述。
 - 模型配置：选择向量及精排模型。
 - 解析配置：配置文档解析。
 - 拆分配置：配置文档拆分。
4. 配置完成后，单击“确定”，完成知识库创建。

上传文档

1. 登录Agent开发平台。
2. 单击左侧导航栏“工作台”，在“知识库”页签，单击进入知识库详情。
3. 在知识库详情中选择需要上传的文档类型：
 - 知识文档：
 - i. 在模型详情“知识文档”页签，单击“上传”进入文档上传页面；
 - ii. 单击“点此上传”上传本地文件至知识库；
 - iii. 支持上传.doc, .docx, .pdf, .pptx, .ppt, .xlsx, .xls, .csv, .wps, .png, .jpg, .jpeg, .bmp, .gif, .tiff, .tif, .webp, .pcx, .ico, .psd, .dps, .et, .txt, .ofd, .md格式的文档；
 - iv. 要求单个文件不超过10M；
 - v. 支持单次上传文件个数不超过300个。
 - FAQ文档
 - i. 在模型详情“FAQ文档”页签，单击“上传”进入FAQ上传页面；
 - ii. 单击“点此上传”上传本地文件至知识库，要求按照模板上传文本，支持下载FAQ模板；
 - iii. 要求单个excel文件最大为10M，数据条数10000条，文件中不允许空行，空行后的数据将被忽略；

- iv. 单个word文件最大为10M；
- v. 支持单次上传文件个数不超过300个。

图 7-78 上传文档



说明

知识库创建完成后，如果想在当前知识库中继续上传文件，可单击该知识库进入详情页面，选择对应的页签，继续上传文档。

配置完成的文档解析、分段策略支持修改，可进入知识库详情页，单击“高级设置”进行修改。修改后，可以对文档重新进行解析切分。

7.6.3 知识库命中测试

平台支持对创建的知识库进行命中测试，以评估知识库的效果和准确性。

命中测试通过将用户的查询与知识库中的内容进行匹配，最终输出与查询相关的信息，并根据匹配的程度进行排序。

知识库命中测试步骤如下：

1. 登录Agent开发平台。
2. 进入“工作台 > 知识库”页面，单击所需知识库，进入知识库基本信息页面，单击右上角“命中测试”。
3. 在文本框中输入问题，单击“命中测试”，页面下方将根据不同的检索方式，展示多条匹配的内容，并按照匹配分值降序排列。
4. 单击“查看历史”，可以查看用户输入的历史问题。

图 7-79 查看历史



7.6.4 管理知识库

新增、删除知识库中的文档

1. 登录Agent开发平台。
2. 进入“工作台 > 知识库”页面。
3. 单击所需知识库，进入详情页面。
 - 新增知识库中知识文档。单击右上角“继续上传”，可上传本地文档至当前知识库。
 - 删除知识库中知识文档。在“知识文档”中单击操作列“删除”可删除当前知识文档。

开启、关闭知识库

1. 登录Agent开发平台。
2. 进入“工作台 > 知识库”页面。单击知识库片上更多按钮，查看当前知识库状态，单击开启/停用按钮进行操作
3. 单击所需知识库，进入详情页面。单击右上角开启/停用按钮，进行操作。

说明

仅知识库为开启状态，才能应用、工作流中引用该知识库。

停用已经被应用、工作流引用的知识库，会导致检索结果返回空值，请谨慎操作。

获取知识库 ID、删除知识库

1. 登录Agent开发平台。
2. 进入“工作台 > 知识库”页面。
 - 单击“...” > 复制ID”，可获取当前知识库ID。
 - 单击“...” > 删除”，可删除当前知识库。

说明

删除属于高危操作，删除前，请确保该知识库不再使用。

7.7 MCP 服务开发与配置

7.7.1 MCP 服务介绍

MCP (Model Context Protocol, 模型上下文协议) 是由 Anthropic 推出的一种开放标准，旨在统一大型语言模型 (LLM) 与外部数据源和工具之间的通信协议。

MCP 的主要目的在于解决当前 AI 模型因数据孤岛限制而无法充分发挥潜力的难题，MCP 使得 AI 应用能够安全地访问和操作本地及远程数据，为 AI 应用提供了连接万物的接口。

7.7.2 创建 MCP 服务

开发者可以在“控制台”选择“Agent开发 > MCP服务市场”使用预置的各类MCP服务，也可以选择“Agent开发 > 工作台”的“MCP服务”选项创建MCP服务。华为云

ModelArts Studio支持在智能体应用、工作流应用开发过程中，一键添加MCP服务，增强Agent工具调用能力。

使用官方预制 MCP 服务

1. 登录ModelArts Studio大模型开发平台，在“我的空间”模块，单击进入所需空间。

图 7-80 我的空间




2. 在左侧导航栏中选择“Agent开发”，跳转至Agent开发平台。
3. 选择“Agent开发 > MCP服务市场”。

图 7-81 MCP 服务市场



4. 通过属性类型筛选，或通过搜索MCP服务名称找到目标服务。单击目标服务，进入服务详情界面。

图 7-82 服务详情界面




5. 根据MCP服务开通提示，进行相应的操作，如该MCP服务需要API Key认证，输入API Key之后，单击确认开通该MCP服务。

创建自定义 MCP 服务

如果您已有可用的工具和API资源，则可以使用MCP服务器来配置您的MCP扩展。完成MCP服务器构建后，只需要在Agent开发平台配置对应的工具即可创建自己的MCP服务。

1. 登录ModelArts Studio大模型开发平台，在“我的空间”模块，单击进入所需空间。

图 7-83 我的空间



2. 在左侧导航栏中选择“Agent开发”，跳转至Agent开发平台。
3. 在右侧导航栏中选择“MCP服务”，单击“创建MCP服务”，进入创建MCP页面。
4. 在“创建MCP服务”页面，参考表7-29配置“MCP服务名称”、“英文名称”、“MCP服务地址”、“描述”以及“权限校验”选项后，单击“测试并下一步”。

表 7-29 MCP 服务信息配置说明

参数名称	参数说明
MCP服务名称	MCP服务中文名，中文名称为该MCP服务对外呈现的友好名称。
英文名称	MCP服务英文名，英文名称为该MCP服务在系统内部交互的唯一标识符，在API调用、系统间通信，代码引用等场景下使用。需确保同一个租户下唯一。
MCP服务地址	MCP服务SSE地址。 - 服务URL地址只支持HTTP和HTTPS。 - 系统会校验URL地址是否为标准的URL格式。 - URL对应的IP默认不应为内网，否则会导致注册失败。 说明 支持网站公开的MCP服务，也支持用户自行创建的MCP服务。
描述	MCP服务描述。
仅我可见	是否仅创建者可见。
权限校验	选择调用MCP服务时是否需要通过认证才可以调用。 - 无需鉴权：MCP服务可以公开访问，不需要任何形式的身份验证或授权。 - API Key：在调用MCP服务时提供唯一的API Key进行鉴权。 需填写密钥位置，即密钥信息是设置在Header中还是设置在Query中。并设置API Key的密钥鉴权参数名和密钥值。 说明 若服务地址中包含有认证信息，建议使用平台的权限校验（API Key）功能。

图 7-84 创建 MCP 服务




图 7-85 权限校验示例

权限校验

无需鉴权

API Key

密钥位置

Header

Query

参数列表

参数名称

key

参数值


123

+ 添加参数

取消

测试并下一步

图 7-86 连通性测试成功示例



5. 测试完成，单击确认完成MCP服务创建。


使用 MCP 服务

在Agent开发平台中，开发者可以在开发智能体应用、工作流应用时，添加预置和自定义创建的MCP服务。

- 在智能体应用开发时配置MCP服务：
步骤一：进入Agent开发平台后，在导航栏选择“工作台”。

步骤二：在右侧导航栏中选择“应用”，单击创建“创建应用”，进入创建应用开发页面。


步骤三：在应用开发页面，技能配置，MCP服务模块，单击添加，进入MCP服务选择页面。



步骤四：从官方服务、个人服务中所需要的MCP服务。

步骤五：单击确定，完成MCP服务添加。

步骤六：在右侧调试模块，对话框输入问题，如大模型MCP服务，对话界面展示可展示调用详情。




- **在工作流应用中开发时配置MCP服务：**

步骤一：进入Agent开发平台后，在导航栏选择“工作台”。

步骤二：在右侧导航栏中选择“工作流”，单击“创建工作流”，进入工作流开发页面。

步骤三：在工作流开发页面，在左侧导航栏选中MCP节点，拖拽至工作流编排画布。

步骤四：在MCP选择弹窗中，从预置服务、个人服务中所需要的MCP服务。



步骤五：单击“添加”，完成MCP服务添加。


7.7.3 管理 MCP 服务

Agent开发平台支持对用户自定的MCP服务进行编辑、删除操作。

编辑 MCP 服务


1. 登录ModelArts Studio大模型开发平台，在“我的空间”模块，单击进入所需空间。

图 7-87 我的空间



2. 在左侧导航栏中选择“Agent开发”，跳转至Agent开发平台。
3. 进入“工作台 > MCP服务”页面。
4. 单击MCP服务名称，进入详情页面，单击右上角“编辑”。

图 7-88 编辑 MCP 服务



删除 MCP 服务

1. 登录ModelArts Studio大模型开发平台，在“我的空间”模块，单击进入所需空间。

图 7-89 我的空间



2. 在左侧导航栏中选择“Agent开发”，跳转至Agent开发平台。
3. 进入“工作台 > MCP服务”页面。
- 单击“*** > 删除”，可删除当前的MCP服务。

说明

删除属于高危操作，删除前，请确保该MCP服务不再使用。


7.7.4 开通 MCP 服务

部分官方预置MCP服务需要开通后才能使用。

1. 登录Agent开发平台。
2. 进入“MCP服务市场”页面。

3. 查看服务开通状态如图7-90。

图 7-90 预置服务开通状态



4. 单击MCP服务卡片，进入开通页面进行服务开通如图7-91。

图 7-91 服务开通



7.8 Agent 开发常见报错与解决方案

工作流常见错误码与解决方案

工作流常见报错及解决方案请详见表7-30。

表 7-30 工作流节点常见报错与解决方案

模块名称	错误码	错误描述	解决方案
开始节点	101501	开始节点全局配置未传入值。	开始节点错误，请联系客服解决。
结束节点	101531	结束节点初始化失败。	检查结束节点配置，可能为校验报错。
	101532	结束节点模板拼接失败。	先检查模板占位符与输入是否匹配，请联系客服解决。
	101533	结束节点流式处理失败。	请联系客服解决。

模块名称	错误码	错误描述	解决方案
大模型节点	101561	大模型节点初始化失败。	检查大模型节点配置，可能为校验报错。
代码节点	101591	代码组件初始化失败。	检查代码节点配置，可能为校验报错。
	101592	代码节点安全沙箱请求失败。	请联系客服解决。
	101593	代码节点安全沙箱执行失败。	检查代码的语法是否有误，检查是否用到了未引用的变量。
	101594	代码组件安全沙箱其他报错。	请联系客服解决。
	101595	代码节点执行失败未知错误。	请联系客服解决。
消息节点	101651	消息组件初始化失败。	检查消息节点配置，可能为校验报错。
	101652	消息节点缺少模板信息。	配置消息节点的提示词模板。
	101653	消息节点模板拼接错误。	先检查模板占位符与输入是否匹配，若仍无法解决，请联系客服解决。
	101654	消息组件执行失败。	请联系客服解决。
	101655	消息组件异步执行失败。	请联系客服解决。
意图识别节点	101098	意图识别prompt模板请求失败。	检查模板占位符与输入是否匹配。
	101097	意图识别调用大模型的prompt不符合模型输入的规范。	检查输入的prompt格式，消息的角色和内容。
	101096	意图识别调用大模型失败。	检查消息的格式，内容以及大模型服务是否正常。
	101095	意图识别用户query输入/引用解析失败。	检查用户query格式和内容。
	101094	意图识别prompt模板构建失败。	检查内置模板以及输入的system prompt格式与内容。

模块名称	错误码	错误描述	解决方案
提问器节点	101043	当单个提问器内的对话轮数超过预设轮数上限时触发该错误码，对话状态回到开始节点状态。	可通过调大对话轮数上限解决。
	101047	初始化深度定制前后处理模块失败时触发该错误码。	可检查护栏配置是否符合要求。
	101048	执行深度定制用户回复改写（前处理）失败时触发该错误码。	可检查前处理护栏代码。
	101049	执行深度定制大模型生成的参数取值改写（后处理）失败时触发该错误码。	可检查后处理护栏代码。
	101050	执行默认护栏（时间参数解析）失败时触发该错误码。	可检查支持处理的时间类型是否超出支持范围。
	102053	提示词模板有误时触发该错误码。	检查提示词模板是否格式有误。
	103004	大模型推理失败时触发该错误码。	请检查模型服务是否可以正常运行。
插件节点	101741	插件组件初始化失败。	检查插件组件配置，可能为校验报错。
	101742	workflow 插件节点参数类型转换时出错。	根据error message确定具体转换出错的参数名称，并确认类型是否正确。
	101743	workflow 插件节点的input在插件定义中不存在。	检查插件定义和对应的组件定义是否匹配。
	101744	插件定义了response，但实际插件执行结果与定义不一致。	检查插件response定义和实际插件执行结果是否匹配。
	101745	workflow 插件节点执行出错。	插件执行出错，可以根据具体的error message信息定位。如果message无有效信息，说明该错误属于未捕获到的异常。
	105001	插件执行时发生了无法捕获的异常。	检查插件本身是否可用。

模块名称	错误码	错误描述	解决方案
	105004	插件定义时check param error。	根据对应error message信息确定具体出错的参数定义。
	105005	插件定义不合法。	插件定义时的数据不合法，例如字段定义超出最长长度，具体根据error message判断。
	105008	插件内部错误。	请联系客服解决。
	105010	插件运行时鉴权出错。	可根据error message信息确定具体出错的鉴权问题，并检查鉴权信息的传递和插件鉴权定义是否正确。
	105011	插件运行返回的响应代码非200。	可根据报信息查看实际的http返回码。
	105012	插件request请求超时。	插件请求超时，检查插件服务。
	105013	插件返回结果过大。	当前支持10M大小的返回，超过此大小会报错。
	105014	插件request proxy error。	请检查插件服务是否有问题导致无法连接。
认证鉴权	110000	认证失败。	查看认证配置。
	110001	用户信息获取失败。	查看用户信息是否正确配置。
工作流	112501	工作流认证失败。	查看认证配置。
	112502	缺少必要参数。	从打印日志可以看出当前缺失何种参数。
	112503	工作流连接数据库失败。	请联系客服解决。
	112504	缺少必要权限。	查看当前用户权限。
	112513	工作流流程中存在死循环。	检查工作流画布。
	112514	工作流被引用，无法删除。	查看知识型应用中是否引用了该工作流。
	112600	workflow ir转化失败	需要查看工作流配置是否正确。

模块名称	错误码	错误描述	解决方案
	112941	获取workflow对话历史失败	请联系客服解决。

8 管理空间资产

8.1 盘古大模型空间资产介绍

在ModelArts Studio大模型开发平台的空间资产中，包括数据和模型两类资产。这些资产为用户提供了集中管理和高效操作的基础，便于用户实现统一查看和操作管理。

- **数据资产：**用户已发布的数据集将作为数据资产存放在空间资产中。用户可以查看数据集的详细信息，包括数据格式、大小、配比比例等。同时，平台支持数据集的删除等管理操作，使用户能够统一管理数据集资源，以便在模型训练和分析时灵活调用，确保数据资产的规范性与安全性。
- **模型资产：**平台提供的模型资产涵盖了预置或训练后发布的模型，所有这些模型将存放于空间资产中进行统一管理。用户可查看预置模型的历史版本和操作记录，还可以执行模型的进一步操作，包括训练、压缩、部署等。此外，平台支持导出和导入盘古大模型的功能，使用户能够将其他局点的盘古大模型迁移到本局点，便于模型资源共享。

8.2 管理盘古数据资产

数据资产介绍

数据资产是指在平台中被纳入管理、存储并可供使用的数据集。

数据资产包含以下两种形式：

- **用户自行发布的数据集。**
用户可以通过“数据工程 > 数据发布 > 发布任务”功能将数据集发布为数据资产。发布的数据集支持查看详细信息、编辑、删除以及发布至AI Gallery等操作。
- **从AI Gallery订阅的数据资产。**
除了用户自行发布的数据集，平台还提供了从AI Gallery中订阅数据资产的功能。AI Gallery提供了模型、数据集、AI应用等AI数字资产的共享，为企业级或个人开发者等群体，提供安全、开放的共享及交易环节。

发布数据资产至 AI Gallery

1. 登录ModelArts Studio大模型开发平台，在“我的空间”模块，单击进入所需空间。

图 8-1 我的空间



2. 在左侧导航栏中选择“空间资产 > 数据”。
3. 单击数据资产（状态为“未发布到Gallery”）操作列的“发布到Gallery”，对数据资产进行发布。
4. 在“发布到AI Gallery”页面填写AI Gallery资产名称与描述，选择可订阅区域约束与可看范围，单击“确定”，发布数据资产至AI Gallery。
5. 数据资产列表页将显示发布数据资产的状态：
 - 如果状态为“发布中”，表示该资产正在同步至AI Gallery，请耐心等待。
 - 如果状态为“发布成功”，表示该资产已同步至AI Gallery，可单击操作列“查看发布信息”以查看该资产的发布信息。
 - 如果状态为“发布失败”，表示该资产未成功同步至AI Gallery，可单击“发布到Gallery”重新对数据资产进行发布。

从 AI Gallery 订阅数据资产

1. 登录ModelArts Studio大模型开发平台，在“我的空间”模块，单击进入所需空间。

图 8-2 我的空间



2.

在左侧导航栏中选择“空间资产 > 数据”。
3.

单击右上角“订阅数据”，在“从AI Gallery订阅”页面选择需订阅的数据资产，单击“下一步”。
4.

填写资产名称与资产描述后，单击“确定”实现数据资产的订阅。
5.

数据资产列表页将显示订阅数据资产的状态：

-

如果状态为“订阅中”，表示该资产正从AI Gallery同步中，请耐心等待。

-

如果状态为“订阅成功”，表示该资产已从AI Gallery订阅成功，可单击操作列“查看订阅信息”以查看该资产的订阅信息。

-

如果状态为“订阅失败”，表示该资产未成功从AI Gallery订阅，可单击“重新订阅”重新从AI Gallery订阅数据资产。
6.


订阅成功后的数据资产，将在“数据工程 > 数据管理> 数据集 > 原始数据集”中显示，可执行后续的数据加工及发布操作。

管理数据资产

1.

登录ModelArts Studio大模型开发平台，在“我的空间”模块，单击进入所需空间。

图 8-3 我的空间



2.

在左侧导航栏中选择“空间资产 > 数据”。
3.

单击“任务发布”页签，可对用户自行发布的数据集执行以下操作：

-

查看基本信息。单击具体数据资产，可查看资产的配比详情、数据详情等基本信息。

-

发布至Gallery。单击操作列的“发布至Gallery”，可发布数据资产至AI Gallery。

-

查看发布信息。单击“查看发布信息”，查看该资产的发布信息（该操作需提前发布该数据资产至AI Gallery）。

-

编辑属性。单击操作列的“更多 > 编辑属性”，可编辑数据资产的名称、描述以及资产可见性。

-

删除。单击操作列的“更多 > 删除”，可删除当前数据资产。

-

取消发布至Gallery。单击操作列的“更多 > 取消发布至Gallery操作”，可将已发布至AI Gallery的数据资产取消发布（该操作需提前发布该数据资产至AI Gallery）。

4. 单击“AI Gallery”页签，可对从AI Gallery订阅的数据资产执行以下操作：
- 查看订阅信息。单击具体数据资产或操作列的“查看订阅信息”，查看该资产的名称描述等订阅信息。

- 编辑属性操作。单击操作列的“更多 > 编辑属性”，可编辑数据资产的名称、描述以及资产可见性。

- 删除操作。单击操作列的“更多 > 删除”，可删除当前数据资产。

- 重新订阅。如果订阅失败，单击操作列的“重新订阅”，可重新从AI Gallery订阅所需数据资产。

8.3 管理盘古模型资产

模型资产介绍

用户在平台中可试用、已订购或训练后发布的模型，将被视为模型资产并存储在空间资产内，方便统一管理与操作。用户可以查看模型的所有历史版本及操作记录，从而追踪模型的演变过程。同时，平台支持一系列便捷操作，包括模型训练、压缩和部署，帮助用户简化模型开发及应用流程。这些功能有助于用户高效管理模型生命周期，提高资产管理效率。

模型资产包含以下两种形式：

- **预置模型。**

用户在平台中可试用、已订购的预置模型。
- **用户自行发布的模型。**

用户可以将训练完成的模型发布为模型资产。发布的模型支持查看详细信息、编辑属性、删除等操作。

管理模型资产

1. 登录ModelArts Studio大模型开发平台，在“我的空间”模块，单击进入所需空间。

图 8-4 我的空间



2. 在左侧导航栏中选择“空间资产 > 模型”。
3. 单击“其他空间”页签，在模型列表，单击模型，可对其他空间的模型资产执行以下操作：

- 查看模型历史版本。在“版本列表”页面，可查看模型的各个版本。
- 训练、压缩、部署操作。在“版本列表”页面，可对不同版本模型执行训练、压缩或部署操作。单击相应按钮，将跳转至相关操作页面。
- 查看操作记录。在“操作记录”页面，可查看当前模型的操作记录。
- 单击“本空间”页签，可对用户在当前空间发布的模型执行以下操作：
 - 查看模型信息。单击模型名称，进入模型信息页面，可产模型的基本信息与操作记录。
 - 编辑属性。单击操作列的“编辑属性”，可修改模型资产名称、描述以及资产可见性。
 - 训练、压缩、部署。可在模型列表页面，对模型执行训练、压缩或部署操作。单击相应按钮，将跳转至相关操作页面。

8.4 管理盘古组件资产

管理组件资产

1. 登录ModelArts Studio平台，在“我的空间”模块，单击进入所需空间。

图 8-5 我的空间



2. 在左侧导航栏中选择“空间资产 > 组件”，可以查看“本空间”、“其他空间”、“预置”的组件资产。
3. 单击“本空间”页签，可对用户在当前空间发布的组件执行编辑属性、删除操作。

9 管理资源池

9.1 创建边缘资源池

边缘部署是指将模型部署到用户的边缘设备上，这些设备通常是用户自行采购的服务器，通过ModelArts服务纳管为边缘资源池，然后利用盘古大模型服务将模型部署到这些边缘资源池中。

ModelArts边缘节点是ModelArts平台提供的用于部署边缘服务的终端设备。创建边缘资源池之前需先创建ModelArts边缘节点。节点创建完成后，同步下载证书和边缘Agent固件，及时将固件复制到节点上，并执行注册命令完成设备的注册。

创建边缘资源池的流程见[表9-1](#)。

表 9-1 创建边缘资源池

操作步骤	说明
准备工作	说明创建边缘资源池的前期准备。
步骤1：注册边缘算力节点	说明注册边缘资源池节点步骤。
步骤2：搭建边缘服务器集群	说明搭建边缘服务器集群的步骤。
步骤3：安装Ascend插件	说明安装Ascend插件指导。
步骤4：创建证书	说明创建负载均衡所需证书步骤。
步骤5：创建负载均衡	说明创建负载均衡步骤。

说明

- ModelArts Studio大模型开发平台当前仅部分模型支持边缘部署，详见《产品介绍》“模型能力与规格”章节。
- 使用边缘部署功能需要在ModelArts服务中开通“边缘资源池”功能，该功能为**白名单特性**，需要联系ModelArts客服进行开通。
- 创建边缘资源池操作较为复杂，建议联系盘古客服进行协助。

准备工作

本章节的边缘部署操作以largemodel集群为例，示例集群信息如下表。

表 9-2 示例集群信息

集群名	节点类型	节点名	规格	备注
largemodel	controller	ecs-edge-XXXX	鲲鹏通用计算型 8vCPUs 29GiB rc3.2xlarge.4镜像 EulerOS 2.9 64bit with ARM for Tenant 20230728 base 2.9.15	公网IP: 100.85.220.207 root密码: / CPU架构: aarch64 (登录设备, 执行arch命令查看)
	worker	bms-panguXXXX	CPU:Kunpeng 内存: 24*64GB DDR4 RAM(GB) 本地磁盘: 3*7.68TB NVMe SSD 扩展配置: 2*100GE +8*200GE 类型: physical.kat2e.48xlarge.8.3 13t.ei.pod101 euler2.10_arm_sdi3_1980b_hc_sdi5_b080_20230831v2	公网IP: 100.85.216.151 root密码: / CPU架构: aarch64 (登录设备, 执行arch命令查看)

1. 依赖包下载。

- docker下载: <https://download.docker.com/linux/static/stable>
选择对应cpu架构下载, docker版本选在19.0.3+。

- K3S下载: <https://github.com/k3s-io/k3s/releases/tag/v1.21.12%2Bk3s1>
按照对应cpu架构下载二进制文件以及air-gap镜像。
2. npu驱动和固件安装。

执行命令**npusmi info**查看驱动是否已安装。如果有回显npu卡信息, 说明驱动已安装。
3. hccn tool网卡配置。

a. 执行如下命令, 查看是否有回显网卡信息。如果有, 则说明网卡已经配置, 否则继续操作下面步骤。

cat /etc/hccn.conf

b. 执行如下命令, 查看npu卡数。

npusmi info

c. 执行如下命令 (地址自行配置) :
- 文档版本 01 (2025-07-28)

版权所有 © 华为云计算技术有限公司

327

```
hccn_tool -i 0 -ip -s address 192.168.0.230 netmask 255.255.255.0
hccn_tool -i 1 -ip -s address 192.168.0.231 netmask 255.255.255.0
hccn_tool -i 2 -ip -s address 192.168.0.232 netmask 255.255.255.0
hccn_tool -i 3 -ip -s address 192.168.0.233 netmask 255.255.255.0
hccn_tool -i 4 -ip -s address 192.168.0.234 netmask 255.255.255.0
hccn_tool -i 5 -ip -s address 192.168.0.235 netmask 255.255.255.0
hccn_tool -i 6 -ip -s address 192.168.0.236 netmask 255.255.255.0
hccn_tool -i 7 -ip -s address 192.168.0.237 netmask 255.255.255.0
```

- d. 执行命令`cat /etc/hccn.conf`，确保有如下回显网卡信息，则配置完成。

```
[root@bms-panq k3s]# hccn_tool -i 0 -ip -s address 192.168.0.230 netmask 255.255.255.0
[root@bms-panq k3s]# hccn_tool -i 1 -ip -s address 192.168.0.231 netmask 255.255.255.0
[root@bms-panq k3s]# hccn_tool -i 2 -ip -s address 192.168.0.232 netmask 255.255.255.0
[root@bms-panq k3s]# hccn_tool -i 3 -ip -s address 192.168.0.233 netmask 255.255.255.0
[root@bms-panq k3s]# hccn_tool -i 4 -ip -s address 192.168.0.234 netmask 255.255.255.0
[root@bms-panq k3s]# hccn_tool -i 5 -ip -s address 192.168.0.235 netmask 255.255.255.0
[root@bms-panq k3s]# hccn_tool -i 6 -ip -s address 192.168.0.236 netmask 255.255.255.0
[root@bms-panq k3s]# hccn_tool -i 7 -ip -s address 192.168.0.237 netmask 255.255.255.0
[root@bms-panq k3s]#
[root@bms-panq k3s]# cat /etc/hccn.conf
address_0=192.168.0.230
netmask_0=255.255.255.0
address_1=192.168.0.231
netmask_1=255.255.255.0
address_2=192.168.0.232
netmask_2=255.255.255.0
address_3=192.168.0.233
netmask_3=255.255.255.0
address_4=192.168.0.234
netmask_4=255.255.255.0
address_5=192.168.0.235
netmask_5=255.255.255.0
address_6=192.168.0.236
netmask_6=255.255.255.0
address_7=192.168.0.237
netmask_7=255.255.255.0
[root@bms-panqu30037210 k3s]#
```

4. 配置NFS网盘服务。

大模型采用镜像+模型分开的方式部署时，需要有一个节点来提供nfs网盘服务，创建部署时通过nfs挂载的方式访问模型。

步骤 1：注册边缘算力节点


1. 进入ModelArts服务，选择所需空间。
2. 在左侧列表中选择“资源管理 > 边缘算力节点 (Edge Node)”，在“节点”页签中，单击“创建”。

图 9-1 边缘算力节点 (Edge Node)



3. 在“创建边缘节点”页面中，填写节点名称，配置AI加速卡与日志信息。
- 如果节点有npu设备需选择“AI加速卡 > Ascend”，并选择加速卡类型。
 - 如果节点没有加速卡，则选择“AI加速卡 > 不使用”。

图 9-2 配置边缘节点参数



4. 基本信息配置完成后，单击“确定”，单击“立即下载”，下载设备证书和Agent固件，并将设备证书与Agent固件分别重命名为license.tgz、hilens-agent.tgz。

图 9-3 下载所需证书



步骤 2：搭建边缘服务器集群

1. 执行如下命令，生成docker证书。
bash cluster_install-ascend.sh generate_docker_cert --pkg-path=/home/hilens/pkgsg
- 说明

请注意，该命令只需执行一次，如果已有相关证书，请跳过该步骤。
2. 基于准备工作与步骤1：注册边缘算力节点，按照以下目录结构存放下载文件，注意修改下载文件的命名。其中，docker下的certs证书会自动生成，一般无需修改。
pkgs // 包目录，用户自行命名
docker
 docker.tgz // docker 二进制文件，要求版本>19.0.3
 certs // 使用generate命令生成的证书，指定--pkg-path后会自动创建到certs目录
 ca.crt
 server.crt
 server.key
k3s
 k3s // k3s可执行文件
 agent
 images
 k3s-airgap-images-[arm64|amd64].tar.gz //k3s离线镜像
hilens-agent
 hilens-agent.tgz // hilens agent固件包
 license.tgz // hilens 设备license
3. 工作节点执行命令如下：
bash -x cluster_install-ascend.sh --pkg-path=/home/hilens/pkgsg --node-type=worker --host-ip=192.168.0.209
主控节点执行命令如下：
bash -x cluster_install-ascend.sh --pkg-path=/home/hilens/pkgsg --node-type=controller --host-ip=192.168.0.150
- cluster_install-ascend.sh脚本主要用于安装docker、hdad和k3s，请联系盘古客服获取。
 - pkg-path是步骤2中整合的安装包文件目录。
 - host-ip是设备在集群中的ip，一般为内网ip。
 - node-type是集群节点类型。其中，worker表示工作节点，controller表示主控节点。
4. 在服务器执行如下命令，判断docker是否安装成功。

```
systemctl status docker
```

```
[root@bms-pangu ~]# systemctl status docker
● docker.service - Docker Application Container Engine
   Loaded: loaded (/usr/lib/systemd/system/docker.service; enabled; vendor preset: disabled)
   Active: active (running) since Wed 2023-11-01 14:23:17 CST; 2h 32min ago
     Docs: https://docs.docker.com
    Main PID: 1629388 (dockerd)
      Tasks: 65
     Memory: 31.0M
    CGroup: /system.slice/docker.service
            └─1629388 /usr/bin/dockerd -H fd://
              └─1629412 containerd --config /var/run/docker/containerd/containerd.toml --log-level info
```

5. 在服务器执行如下命令，判断edge agent是否安装成功。
hdactl info

```
[root@bms-pangu ~]# hdactl info
{
  "device_info": {
    "device_id": "hilens-flbf45d27c464413b6b53fa40d9alc0d",
    "device_ip": "192.168.0.209",
    "device_name": "edgeNode-910b",
    "device_type": "General ARM Device",
    "domain": "",
    "is_active": true,
    "obs": "",
    "projectId": "51faela6ef804316abeaadb80e302339"
  },
  "dm": {
    "state": "success",
    "connect_err": "",
    "last_message": {
      "topic": "pong",
      "timestamp": 1698829033
    },
    "channel_available": true,
    "address": "wss://modelarts-dev.cn-north-7.myhuaweicloud.com/v3/login"
  }
}
```

6. 配置NFS网盘服务。

a. 安装NFS服务

该步骤需要设备联网下载软件依赖包。

■ Ubuntu系统

在线安装：

```
sudo apt install nfs-kernel-server
```

■ Euler OS系统

在线安装：

```
sudo yum install nfs-utils
```

📖 说明

若需离线安装，请联系盘古客服。

■ 防火墙需要打开rpc-bind和nfs的服务（可选）：

```
sudo firewall-cmd --zone=public --permanent --add-service={rpc-bind,mountd,nfs}
sudo firewall-cmd --reload
```

b. 创建网盘共享目录

该路径的存储空间能够存储大模型文件。此处设置/var/docker/hilens作为网盘根目录，将会在容器里访问该路径。执行：

```
sudo mkdir -p /var/docker/hilens
```

该路径的访问权限需设置为：1000:100（与/etc/exports配置保持一致），执行：

```
sudo chmod 750 /var/docker/hilens chown -R 1000:100 /var/docker/hilens
```

查看权限，执行：

```
ls -l /var/docker | grep hilens
```

c. **添加网盘访问权限**

配置nfs-server访问白名单和网盘共享文件的路径。执行：

```
sudo vim /etc/exports
```

添加如下配置：

```
/var/docker/hilens 172.xxx.0.0/24(rw,no_all_squash,anonuid=1000,anongid=100,fsid=0)
```

172.xxx.0.0/24为集群内网IP网段（登录主控节点，使用hdactl info命令查看IP地址。比如查得IP地址为172.16.0.22，可配置为172.16.0.0/24网段）。

其中，

- /var/docker/hilens：网盘根目录路径。
- 192.168.0.0/24：客户端IP范围，表示IP在192.168.0.0/24范围的所有节点，都可以访问 /var/docker/hilens 。* 代表所有，即没有限制。也可以填写具体某个节点的IP。
- rw：权限设置，可读可写。
- anonuid：为映射的匿名用户id，anongid为映射的匿名用户组，也就是挂载进容器后，在容器中看到的文件属主。
- no_all_squash：可以使用普通用户授权。

执行:wq命令保存设置后，刷新nfs配置。执行：

```
exportfs -rv
```

d. **启动NFS和rpcbind**

设置服务开机启动、启动服务：

```
systemctl enable nfs-server && systemctl enable rpcbind && systemctl start rpcbind nfs-server
```

执行如下命令，验证以上配置内容是否正确。如下图，表示配置正确，即NFS服务安装成功。

```
showmount -e localhost
```

e. **验证NFS配置（可选）**

在非NFS服务节点创建目录：

```
sudo mkdir ~/data
```

执行挂载NFS：

```
sudo mount -t nfs 192.168.xx.xxx:/var/docker/hilens ~/data
```

挂载后，可以使用以下命令查看：

```
mount
```

回显如下，则成功：

```
...  
...  
192.168.0.150:/var/docker/hilens on ~/data type nfs4
```

f. **测试NFS功能**

在客户端向共享目录创建一个文件：

```
cd ~/data  
sudo touch a
```

在NFS服务端192.168.0.150查看所创建的文件：

```
cd /var/docker/hilens  
ls -l
```

g. yum源配置

如果yum install使用正常，请忽略该章节。

i. 配置yum内源地址

o 备份yum配置

```
mkdir -p /etc/yum.repos.d/bak/ mv -f /etc/yum.repos.d/*.repo /etc/yum.repos.d/bak/
```

o x86 eulerOS配置

```
cat> /etc/yum.repos.d/his-mirrors.repo<<"EOF" [EulerOS_2.10_base]
name=EulerOS_2.10_base baseurl=http://his-mirrors.huawei.com/install/euleros/2.10/os/
x86_64/ gpgkey=file:///etc/pki/rpm-gpg/RPM-GPG-KEY-EulerOS gpgcheck=0 enabled=1
[EulerOS_2.10_devel_tool] name=EulerOS_2.10_devel_tool baseurl=http://his-
mirrors.huawei.com/install/euleros/2.10/devel_tools/x86_64/ gpgkey=file:///etc/pki/rpm-
gpg/RPM-GPG-KEY-EulerOS gpgcheck=0 enabled=1 [EulerOS_2.10_updates]
name=EulerOS_2.10_updates baseurl=http://his-mirrors.huawei.com/install/euleros/2.10/
updates/x86_64/ gpgkey=file:///etc/pki/rpm-gpg/RPM-GPG-KEY-EulerOS gpgcheck=0
enabled=1 EOF yum clean all && yum makecache > /dev/null 2>&1
```

o arm eulerOS系统配置

```
cat> /etc/yum.repos.d/his-mirrors.repo<<"EOF" [EulerOS_2.10_base]
name=EulerOS_2.10_base baseurl=http://his-mirrors.huawei.com/install/euleros/2.10/os/
aarch64/ gpgkey=file:///etc/pki/rpm-gpg/RPM-GPG-KEY-EulerOS gpgcheck=1 enabled=1
[EulerOS_2.10_devel_tool] name=EulerOS_2.10_devel_tool baseurl=http://his-
mirrors.huawei.com/install/euleros/2.10/devel_tools/aarch64/ gpgkey=file:///etc/pki/rpm-
gpg/RPM-GPG-KEY-EulerOS gpgcheck=1 enabled=1 [EulerOS_2.10_updates]
name=EulerOS_2.10_updates baseurl=http://his-mirrors.huawei.com/install/euleros/2.10/
updates/aarch64/ gpgkey=file:///etc/pki/rpm-gpg/RPM-GPG-KEY-EulerOS gpgcheck=1
enabled=1 EOF yum clean all && yum makecache > /dev/null 2>&1
```

ii. 配置DNS

```
cat >> /etc/resolv.conf<<"EOF" nameserver 10.189.32.59 nameserver 10.72.55.103
nameserver 10.98.48.39 EOF
```

证书一般自动下载，但是有遇到有的服务器没有自动安装或者已经安装有问题情况下，直接复制执行即可。

```
cat > /etc/pki/rpm-gpg/RPM-GPG-KEY-EulerOS <<"EOF" -----BEGIN PGP PUBLIC KEY
BLOCK----- mQENBFx4vK4BCACrQ4PA8ZEz5XH08bfh9rlms
+QDZsJYhqqIXWx4qsZ8dAqDWLH
O2Dm0HYk17xVwTzJXUYH9rz1gn2bGa5At4xTpH7FHMDpNG8DfwC6UpMKEmGgvy/S
OfL4fl6Yq2tCHAx3LrHXO9PGigafz5XMDtByS14ixOR4M/w8lalPEyN0BfGC6DQ5
PZIXMPDOc5VW1NhxwH0uOyHH1LITKBAEifTQa8+3ZY54PWVbBxOcCCS63FOTn
pk0wWuwm2JqozDBxV/w8Ty0c25+y4FTiUGzOj2e/3K1ls+Zs/tTxf8asKpFH/dYN
ffXmdkPLDCHRGkTyrLPdghoFmVg4XhrOhsf/ABEBAAG0LkV1bGVyT1MgKEV1bGVy
T1MgMi4wIFNQCkgPGV1bGVyb3NAaHVhd2VpLmNvbT6JAVQEEwEIA04WQ54wSv5
6CWQOEUVIHBxp+kP4ux1vAUCXH8rglbAwUJA8JnAAULCQgHAgYVCgkICWIEFglD
AQIeAQIXgAAKCRBxp+kP4ux1vN/UB/4jy2kRiFznSxfWz5SX0szLOf1FgDssdRZG
xASHonAJqrV19mkG2pNTkgip9LZQsCqLbxj5FV+TMm1o+6jubd9qRPePlV2Tpc0T
m3cDmpcZbW/XrFh4dLdN644TKDAPcK8TK/wOepFVtjhx1Qc8o+8nuoFhmsMoKkf
AA1DYDDCZbpbqMQwMV3yKh002CFRlCnVMylqOi8U+FrYfphnsYfujXpKu9g+FmO6
ju0xVhxyFOVCEicamKiel3ZS9z06+PIFL3KP/nKC7pu0tfaxogJjCh8y+ZIF/FJU
ygHpZYKQJyJNO8Do7AucudbruOxqGqhD2BIBtX1JNP/hkKj4w+OJuQENBFx4vK4B
CAD1SYnEWn0mf3umbucovVYHayWJqErB3ia+Ykq3InKvIORf1reiCRVvuse2wZr
cnPWEKeRE7tTEIZ5hCuLYQzaqngqVkwqLbRR6vtxiDhTWNngJH9+GuokgjtQ3/7T
AXH7AwG57OPp6vvaiazCDJhy5t3Vr1snWkiwWkJR2GFRkuwKu7FDLjc1n2dx4zLF
zRZJa5TTAR1zrHWgVwLxgq0+eJHWq7eHFw1SBjmc4Vs4z/QI+Q+3rkVBiQcmr11 /
XQz9ZePdOl/8fCuNh4l480c7AFIft8lvKBP6Kh+jShxbED2NjpRv04MhV6SyA69 idx/
VKtPJMRcRg3phyuuCedrABEBAAGJATwEGAEIACYWIS4wSv56CWQOEUVIHBx p
+kP4ux1vAUCXH8rglbDAUJA8JnAAAKCRBxp+kP4ux1vBGeB/4ubYvz6/apb+i
MCtRluA15PWEwVFTVfKirvEliY4fAjw5HslfrnN4FV/OCTIRHecuNBNBfLT78DoK
08x7fYtEBqIN6pDanjsSwbPhuzhz6m4C/GWLqqDi8SCaVTQslqKc2QHjr7CaBluo GRIB84/pOq
+kGAnMZPhCjy52K9x5zRpq6zTUpV5XPeLCBn6Kc8GW1Lk6K1eXsn09
Kdlhb9JqTdtQx0eOS1p0fJlTb68Pj406IY1J6FaXmMTcYvep6HhVATQGBPDulepd
BK12nQEDrezkGR5vH9nMraQuZTvADuRFFgQvZQ5QMYAzMa0RhQTHKMOWCMq8mBq7
3Csgrxwa =kXkt -----END PGP PUBLIC KEY BLOCK----- EOF
```

7. 配置hda.conf配置文件信息

- a. 登录nfs服务节点，执行如下命令：

```
vi /etc/hilens/hda.conf
```
- b. 增加如下配置：

```
hilens.nfs.server.ip=192.168.0.150  
hilens.nfs.mount.dir=/home/mind/model  
hilens.nfs.source.dir=/var/docker/hilens
```

其中，**server.ip**是nfs存储节点内网ip，**mount.dir**是大模型默认挂载路径，**source.dir**是大模型下载路径。
- c. 配置完成后，执行如下命令重启固件：

```
systemctl restart hdad
```
8. 进入ModelArts服务，选择所需空间。进入“边缘资源池Edge > 节点”，在当前设备节点操作列单击“激活”，节点状态将从“未激活”转为“已激活”。
9. 进入“边缘资源池 > 资源池”，单击“创建”。填写资源池名称，选择“ModelArts边缘节点”，在“主控节点”处单击“添加”，选择要添加的主控节点，单击“确定”。

图 9-4 添加主控节点



10. 在“工作节点”处单击“添加”，选择要添加的工作节点，单击“确定”。

图 9-5 添加工作节点



11. 单击“立即创建”，可在资源池列表中查看节点的状态。如果状态为“运行中”，则创建成功。
12. 在主控节点执行如下k8s命令，验证边缘池创建结果：

a. 执行如下命令建立软连接。

```
ln -s /home/k3s/k3s /usr/bin/kubectl
```

- b. 执行如下命令查看节点状态。

```
kubectl get node -o wide
```

- c. 如果所有节点状态STATUS为“Ready”，则说明集群创建成功。

```
[root@ecs-edge:~]# kubectl get node -o wide
NAME                                CONTAINER_RUNTIME  STATUS    ROLES    AGE    VERSION    INTERNAL-IP    EXTERNAL-IP    OS-IMAGE    KERNEL-VERSION
billeus-9dba6985e5444629958f4a5cc07c1b2  Ready    control-plane,master  7m58s    v1.21.12+k3s1    192.168.0.150    <none>    EulerOS 2.0 (SP9)    4.19.90-vhulk2103.1.0.h1060.eul
hileus-f1bf45d27c464132dbb527e40dbaic8d  Ready    <none>    7m46s    v1.21.12+k3s1    192.168.0.209    <none>    EulerOS 2.0 (SP10)    4.19.90-vhulk2211.3.0.h1543.eul
[root@ecs-edge:~]#
```

步骤 3：安装 Ascend 插件

详情请参考官方文档：https://www.hiascend.com/document/detail/zh/mindx-dl/60rc2/clusterscheduling/clusterschedulingig/clusterschedulingig/dlug_installation_001.html

步骤 4：创建证书

如图9-6，如果在ModelArts Studio平台“首页 > 设置”中的“边缘资源池”页签提示无可用的证书，可以参考以下方法创建证书。

图 9-6 无可用的证书



1. 准备一台Linux系统的服务器（已安装OpenSSL），依次执行以下命令制作证书。执行命令时会提示输入至少四位数的密码，例如：123456，需记住密码后续步骤会使用。

1. 生成server.key命令：

```
openssl genrsa -des3 -out server.key 2048
```

2. 生成不加密的server.key：

```
openssl rsa -in server.key -out server.key
```

3. 生成ca.crt命令：

```
openssl req -new -x509 -key server.key -out ca.crt -days 3650
```

4. 生成server.csr命令：

```
openssl req -new -key server.key -out server.csr
```

5. 生成server.crt命令：

```
openssl x509 -req -days 3650 -in server.csr -CA ca.crt -CAkey server.key -CAcreateserial -out server.crt
```

图 9-7 命令执行示例

```
.....+++++
e is 65537 (0x010001)
Enter pass phrase for server.key:
Verifying - Enter pass phrase for server.key:
[root@ecs-arm test]# openssl rsa -in server.key -out server.key
Enter pass phrase for server.key:
writing RSA key
[root@ecs-arm test]# openssl req -new -x509 -key server.key -out ca.crt -days 3650
You are about to be asked to enter information that will be incorporated
into your certificate request.
What you are about to enter is what is called a Distinguished Name or a DN.
There are quite a few fields but you can leave some blank
For some fields there will be a default value,
If you enter '.', the field will be left blank.
-----
Country Name (2 letter code) [AU]:
State or Province Name (full name) [Some-State]:
Locality Name (eg, city) []:
Organization Name (eg, company) [Internet Widgits Pty Ltd]:
Organizational Unit Name (eg, section) []:
Common Name (e.g. server FQDN or YOUR name) []:
Email Address []:
[root@ecs-arm test]# openssl req -new -key server.key -out server.csr
You are about to be asked to enter information that will be incorporated
into your certificate request.
What you are about to enter is what is called a Distinguished Name or a DN.
There are quite a few fields but you can leave some blank
For some fields there will be a default value,
If you enter '.', the field will be left blank.
-----
Country Name (2 letter code) [AU]:
State or Province Name (full name) [Some-State]:
Locality Name (eg, city) []:
Organization Name (eg, company) [Internet Widgits Pty Ltd]:
Organizational Unit Name (eg, section) []:
Common Name (e.g. server FQDN or YOUR name) []:
Email Address []:

Please enter the following 'extra' attributes
to be sent with your certificate request
A challenge password []:
An optional company name []:
[root@ecs-arm test]# openssl x509 -req -days 3650 -in server.csr -CA ca.crt -CAkey server.key -CAcreateserial -out server.crt
Signature ok
subject=C = AU, ST = Some-State, O = Internet Widgits Pty Ltd
Getting CA Private Key
[root@ecs-arm test]#
[root@ecs-arm test]#
[root@ecs-arm test]#
[root@ecs-arm test]#
[root@ecs-arm test]# ls
ca.crt  ca.srl  server.crt  server.csr  server.key
[root@ecs-arm test]#
```

2. 证书制作完成后，执行ls命令可查看生成的证书文件。证书文件与ModelArts Studio平台中证书填写项对应关系如下。
- ca.crt -- CA
server.crt -- CERT
server.key -- KEY
3. 在ModelArts Studio平台首页，单击右上角“设置”，在“资源池管理 > 边缘资源池”页签单击“创建证书”，填写相应证书参数及描述。

图 9-8 证书密钥

更新时间

2025-01-17 16:27

2025-01-14 11:22

描述

--

--

创建证书

证书名称

studio-ssl-svr

密钥

密钥键

密钥值

CA ?

CERT ?

KEY ?

描述 (可选)

请输入描述

0/100

取消

确定

4. 可通过view命令查看证书密钥值，例如view server.crt。输入ModelArts Studio平台的密钥值需要经过base64加密（echo -n "复制的密钥值内容" | base64）。

步骤 5：创建负载均衡

在边缘资源池创建完成后，需要返回ModelArts Studio平台“首页 > 设置”中为边缘池创建负载均衡、创建监控插件。

创建负载均衡步骤如下：

1. 登录ModelArts Studio平台，单击右上角“设置”。
2. 在“资源池管理 > 边缘资源池”页签查看已经创建的边缘资源池，单击操作列“创建负载均衡”。
3. 填写负载均衡名称（按mas-xxx命名填写），设置侦听端口（取值在30000到40000之间）和协议类型（调用推理模型时使用http还是https请求）。设置完成后单击“确定”。

图 9-9 创建负载均衡

