阿里云
消息队列 Kafka

生态对接

文档版本：20190914

法律声明

阿里云提醒您在阅读或使用本文档之前仔细阅读、充分理解本法律声明各条款的内容。如果您阅读或使用本文档，您的阅读或使用行为将被视为对本声明全部内容的认可。

1. 您应当通过阿里云网站或阿里云提供的其他授权通道下载、获取本文档，且仅能用于自身的合法合规的业务活动。本文档的内容视为阿里云的保密信息，您应当严格遵守保密义务；未经阿里云事先书面同意，您不得向任何第三方披露本手册内容或提供给任何第三方使用。
2. 未经阿里云事先书面许可，任何单位、公司或个人不得擅自摘抄、翻译、复制本文档内容的部分或全部，不得以任何方式或途径进行传播和宣传。
3. 由于产品版本升级、调整或其他原因，本文档内容有可能变更。阿里云保留在没有任何通知或者提示下对本文档的内容进行修改的权利，并在阿里云授权通道中不时发布更新后的用户文档。您应当实时关注用户文档的版本变更并通过阿里云授权渠道下载、获取最新版的用户文档。
4. 本文档仅作为用户使用阿里云产品及服务的参考性指引，阿里云以产品及服务的”现状“、“有缺陷”和“当前功能”的状态提供本文档。阿里云在现有技术的基础上尽最大努力提供相应的介绍及操作指引，但阿里云在此明确声明对本文档内容的准确性、完整性、适用性、可靠性等不作任何明示或暗示的保证。任何单位、公司或个人因为下载、使用或信赖本文档而发生任何差错或经济损失的，阿里云不承担任何法律责任。在任何情况下，阿里云均不对任何间接性、后果性、惩戒性、偶然性、特殊性或刑罚性的损害，包括用户使用或信赖本文档而遭受的利润损失，承担责任（即使阿里云已被告知该等损失的可能性）。
5. 阿里云网站上所有内容，包括但不限于著作、产品、图片、档案、资讯、资料、网站架构、网站画面的安排、网页设计，均由阿里云和/或其关联公司依法拥有其知识产权，包括但不限于商标权、专利权、著作权、商业秘密等。非经阿里云和/或其关联公司书面同意，任何人不得擅自使用、修改、复制、公开传播、改变、散布、发行或公开发表阿里云网站、产品程序或内容。此外，未经阿里云事先书面同意，任何人不得为了任何营销、广告、促销或其他目的使用、公布或复制阿里云的名称（包括但不限于单独为或以组合形式包含”阿里云”、Aliyun”、“万网”等阿里云和/或其关联公司品牌，上述品牌的附属标志及图案或任何类似公司名称、商号、商标、产品或服务名称、域名、图案标示、标志、标识或通过特定描述使第三方能够识别阿里云和/或其关联公司）。
6. 如若发现本文档存在任何错误，请与阿里云取得直接联系。

通用约定

格式	说明	样例
	该类警示信息将导致系统重大变更甚至故障，或者导致人身伤害等结果。	 **禁止:** 重置操作将丢失用户配置数据。
	该类警示信息可能导致系统重大变更甚至故障，或者导致人身伤害等结果。	 **警告:** 重启操作将导致业务中断，恢复业务所需时间约10分钟。
	用于补充说明、最佳实践、窍门等，不是用户必须了解的内容。	 **说明:** 您也可以通过按Ctrl + A选中全部文件。
>	多级菜单递进。	设置 > 网络 > 设置网络类型
粗体	表示按键、菜单、页面名称等UI元素。	单击 确定。
`courier` 字体	命令。	执行 `cd /d C:/windows` 命令，进入Windows系统文件夹。
*## *	表示参数、变量。	`bae log list --instanceid` *`Instance_ID`*
[]或者[a|b]	表示可选项，至多选择一个。	`ipconfig` *`[-all|-t]`*
{}或者{a|b}	表示必选项，至多选择一个。	`swich` *`{stand | slave}`*

目录

1 消息队列 for Apache Kafka 搭配云 HBase 和 Spark 构建一体化数据处理平台

云 HBase X-Pack 是基于 Apache HBase、Phoenix、Spark 深度扩展，融合 Solr 检索等技术，支持海量数据的一站式存储、检索与分析。融合云 Kafka + 云 HBase X-Pack 能够构建一体化的数据处理平台，支持风控、推荐、检索、画像、社交、物联网、时空、表单查询、离线数仓等场景，助力企业数据智能化。

下图是业界广泛应用的大数据中台架构，其中 HBase 和 Spark 选择云 HBase X-Pack。产品详情请参见 X-pack Spark 分析引擎立即购买>>

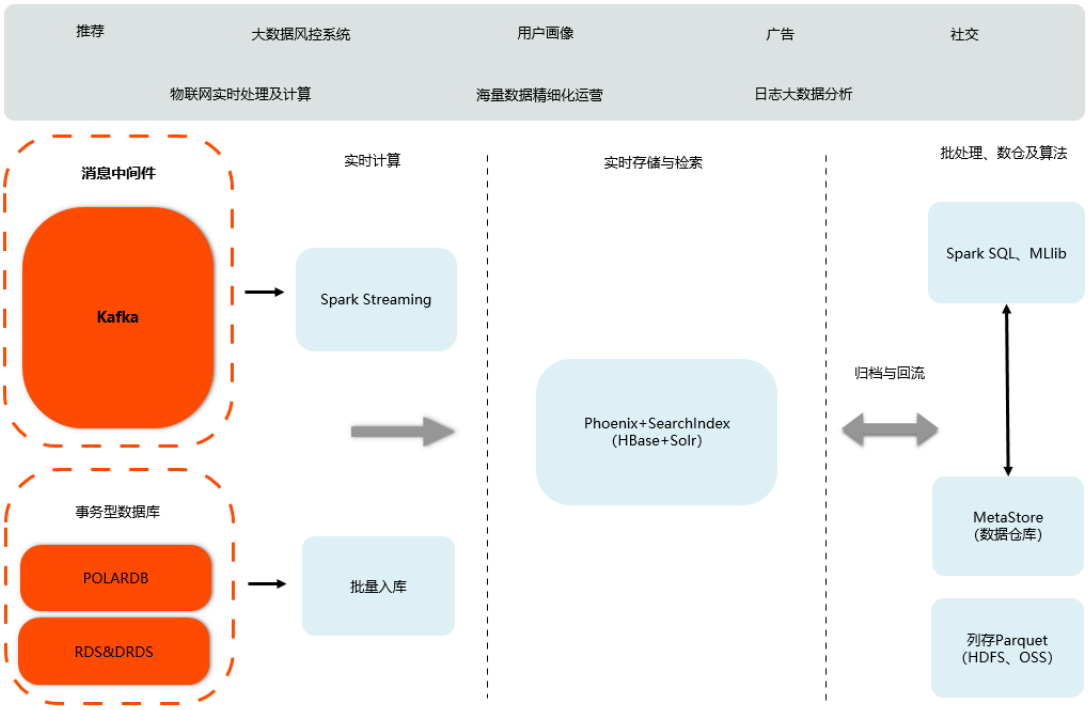

- 消息流入：Flume、Logstash 或者在线库的 Binlog 流入消息中间件 Kafka。
- 实时计算：通过 X-Pack Spark Streaming 实时的消费 Kafka 的消息，写入到云 HBase 中对外提供在线查询。
- 实时存储与检索：云 HBase 融合 Solr 以及 Phoenix SQL 层能够提供海量的实时存储，以及在线查询检索。
- 批处理、数仓及算法：在线存储 HBase 的数据可以自动归档到 X-Pack Spark 数仓。全量数据沉淀到 Spark 数仓（HiveMeta），做批处理、算法分析等复杂计算，结果回流到在线库对外提供查询。

该套方案的实践操作请参见 Spark 对接 Kafka 快速入门。同时，有云 HBase 和 Spark 的示例代码请参见 Demo。

2 使用 DTS 将数据库数据同步至消息队列 for Apache Kafka

使用数据传输服务 DTS（Data Transmission Service）的数据同步功能，您可以将通过专线/VPN 网关/智能网关接入的数据库的数据同步至消息队列 for Apache Kafka 集群，扩展消息处理能力。

立即购买消息队列 for Apache Kafka>>

具体的前提条件、注意事项、操作步骤等信息，请参见#unique_5。

当您操作到#unique_5/unique_5_Connect_42_section_v5h_m5c_zgb时，请注意以下事项：

字段	说明
实例类型	选择通过专线/VPN网关/智能网关接入的自建数据库。
对端专有网络	选择消息队列 for Apache Kafka 实例的 VPC。
IP 地址	选择消息队列 for Apache Kafka 实例接入点的任意一个 IP 地址即可，目前仅仅支持填写单个 IP 地址。
端口	选择消息队列 for Apache Kafka 实例接入点对应 IP 的对应端口。
数据库账号	非必填项。
数据库密码	非必填项。
Topic	获取 Topic 列表后选择对应 Topic，Topic 建议创建单个分区，以便保证全局顺序。
Kafka版本	选择消息队列 for Apache Kafka 实例对应的开源版本，目前主要是 0.10 版本。

说明：

当前 DTS 仅支持通过默认接入点导入数据到消息队列 for Apache Kafka，假设消息队列 for Apache Kafka 实例的默认接入点为“172.16.X.X1:9092,172.16.X.X2:9092,172.16.X.X3:9092”，选择第一个 IP 地址和端口填写即可，也即上表中的 IP地址填写 “172.16.X.X1”，端口填写 “9092”。

配置结果如下图所示。

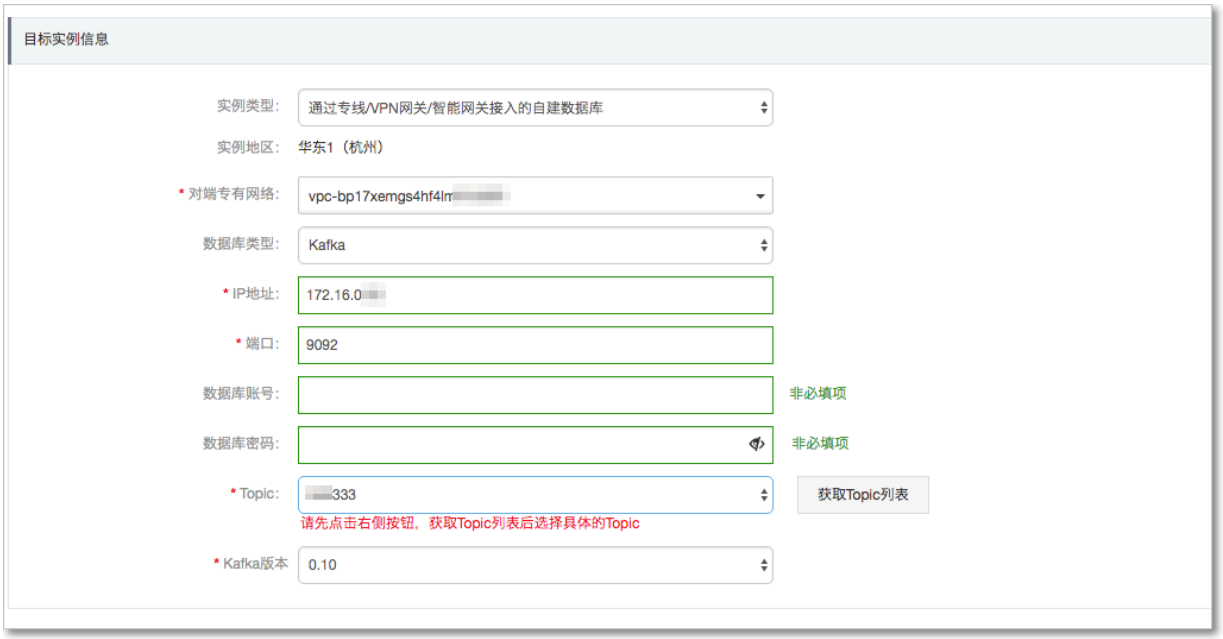
目标实例信息
实例类型:
通过专线/VPN网关/智能网关接入的自建数据库
实例地区:
华东1（杭州）
* 对端专有网络:
vpc-bp17xemgs4hf4lm
数据库类型:
Kafka
* IP地址:
172.16.0
* 端口:
9092
数据库账号:
非必填项
数据库密码:
非必填项
* Topic:
333
获取Topic列表
请先点击右侧按钮，获取Topic列表后选择具体的Topic
* Kafka版本
0.10

3 将消息队列 for Apache Kafka 数据迁移至大数据计算服务 MaxCompute

本文介绍如何使用 DataWorks 数据同步功能，将消息队列 for Apache Kafka 集群上的数据迁移至阿里云大数据计算服务 MaxCompute，方便您对离线数据进行分析加工。

前提条件

在开始本教程前，确保您已完成以下操作：

- 确保消息队列 for Apache Kafka 集群运行正常。本文以部署在华东1（杭州）地域（Region）的集群为例。
- 开通 MaxCompute。
- 开通 DataWorks 。
- #unique_8。本文以在华东1（杭州）地域创建名为 bigdata_DOC 的项目为例。

示例如下。

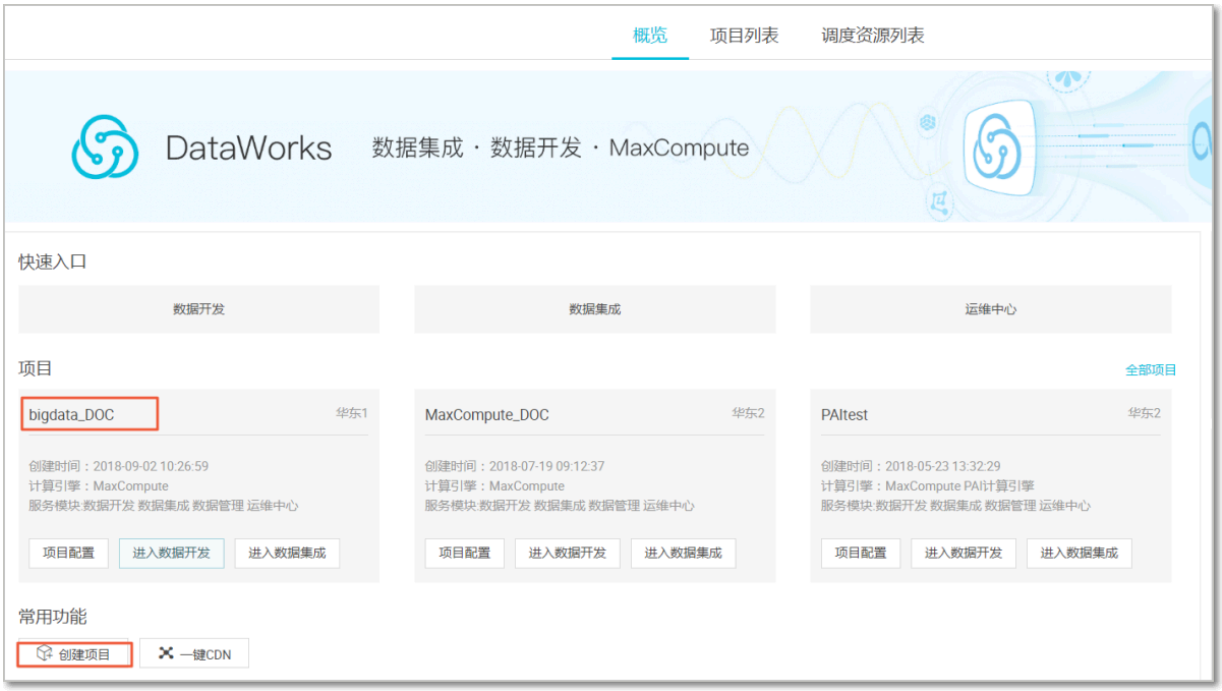

背景信息

大数据计算服务 MaxCompute（原 ODPS）是一种大数据计算服务，能提供快速、完全托管免运维的 EB 级云数据仓库解决方案。

DataWorks 是基于 MaxCompute 计算和存储，提供工作流可视化开发、调度运维托管的一站式海量数据离线加工分析平台。在数加（一站式大数据平台）中，DataWorks 控制台即为

MaxCompute 控制台。MaxCompute 和 DataWorks 一起向用户提供完善的 ETL 和数仓管理能力，以及 SQL、MR、Graph 等多种经典的分布式计算模型，能够更快速地解决用户海量数据计算问题，有效降低企业成本，保障数据安全。

本教程旨在帮助您使用 DataWorks，将消息队列 for Apache Kafka 中的数据导入至 MaxCompute，来进一步探索大数据的价值。

步骤一：准备 Kafka 数据

1. 登录消息队列 for Apache Kafka 控制台创建 Topic 和 Consumer Group，分别命名为 testkafka 和 console-consumer。具体步骤参见#unique_9。本示例中，Consumer Group console-consumer 将用于消费 Topic testkafka 中的数据。
2. 向 Topic testkafka 中写入数据。由于 Kafka 用于处理流式数据，您可以持续不断地向其中写入数据。为保证测试结果，建议您写入 10 条以上的数据。您可以直接在控制台使用发送消息功能来写入数据，也可以使用消息队列 for Apache Kafka 的 SDK 收发消息。详情参见使用 SDK 收发消息。
3. 为验证写入数据生效，您可以在控制台#unique_11，看到之前写入 Topic 中的数据。

步骤二：创建 DataWorks 表

您需创建 DataWorks 表，以保证大数据计算服务 MaxCompute 可以顺利接收消息队列 for Apache Kafka 数据。本例中为测试便利，使用非分区表。

1. 登录 DataWorks 控制台，在工作空间区域，单击目标工作空间的进入数据开发。

2. 在左侧导航栏单击表管理，然后单击新建图标。

3. 在新建表对话框，输入表名 testkafka，然后单击提交。
4. 在创建的表页面，单击 DDL模式。
5. 在 DDL模式对话框，输入以下建表语句，单击生成表结构。

```
CREATE TABLE `testkafka` (
    `key` string,
    `value` string,
    `partition1` string,
    `timestamp1` string,
    `offset` string,
    `t123` string,
    `event_id` string,
    `tag` string
```

```
) ;
```

建表语句中的每一列对应 DataWorks 数据集成 Kafka Reader 的默认列。

- key：表示消息的 Key。
- value：表示消息的完整内容 。
- partition：表示当前消息所在分区。
- headers：表示当前消息 headers 信息。
- offset：表示当前消息的偏移量。
- timestamp：表示当前消息的时间戳。

您还可以自主命名，详情参见配置 Kafka Reader。

6. 单击提交到生产环境。

   详情请参见#unique_13。

步骤三：同步数据

1. #unique_14。此处创建的 ECS 实例将用以完成数据同步任务。
2. 登录 DataWorks 控制台，在工作空间区域，单击目标工作空间的进入数据开发。
3. 在左侧导航栏，选择数据开发 > 业务流程 > 数据迁移。
4. 右键选择数据集成 > 新建数据集成节点 > 数据同步。
5. 在新建节点对话框，输入节点名称（即数据同步任务名称），然后单击提交。
6. 在创建的节点页面，选择数据来源的数据源为 Kafka ，选择数据去向的数据源为ODPS，选择您在步骤二：创建 DataWorks 表中创建的表。完成上述配置后，请单击框中的按钮，转换为脚本模式，如下图所示。

7. 配置脚本，示例如下。

```
{
    "type": "job",
    "steps": [
        {
```

```
            "stepType": "kafka",
            "parameter": {
                "server": "47.xxx.xxx.xxx:9092",
                "kafkaConfig": {
                    "group.id": "console-consumer"
                },
                "valueType": "ByteArray",
                "column": [
                    "__key__",
                    "__value__",
                    "__partition__",
                    "__timestamp__",
                    "__offset__",
                    "'123'",
                    "event_id",
                    "tag.desc"
                ],
                "topic": "testkafka",
                "keyType": "ByteArray",
                "waitTime": "10",
                "beginOffset": "0",
                "endOffset": "3"
            },
            "name": "Reader",
            "category": "reader"
        },
        {
            "stepType": "odps",
            "parameter": {
                "partition": "",
                "truncate": true,
                "compress": false,
                "datasource": "odps_first",
                "column": [
                    "key",
                    "value",
                    "partition1",
                    "timestamp1",
                    "offset",
                    "t123",
                    "event_id",
                    "tag"
                ],
                "emptyAsNull": false,
                "table": "testkafka"
            },
            "name": "Writer",
            "category": "writer"
        }
    ],
    "version": "2.0",
    "order": {
        "hops": [
            {
                "from": "Reader",
                "to": "Writer"
            }
        ]
    },
    "setting": {
        "errorLimit": {
            "record": ""
        },
        "speed": {
```

```
                "throttle": false,
                "concurrent": 1
            }
        }
}
```

8. 在脚本页面，单击配置任务资源组，选择步骤 1 中创建的自定义资源组，然后单击运行图标。

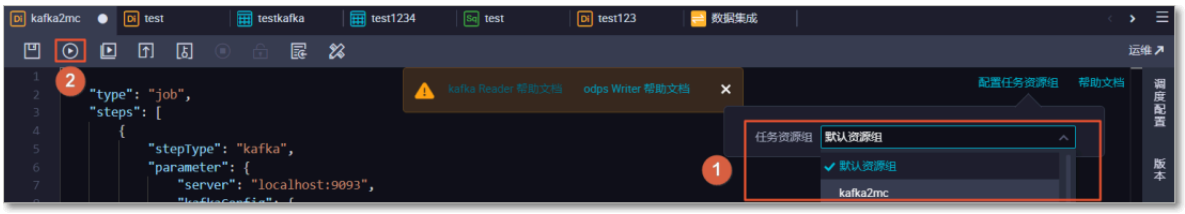

预期结果

完成运行后，运行日志中显示运行成功。

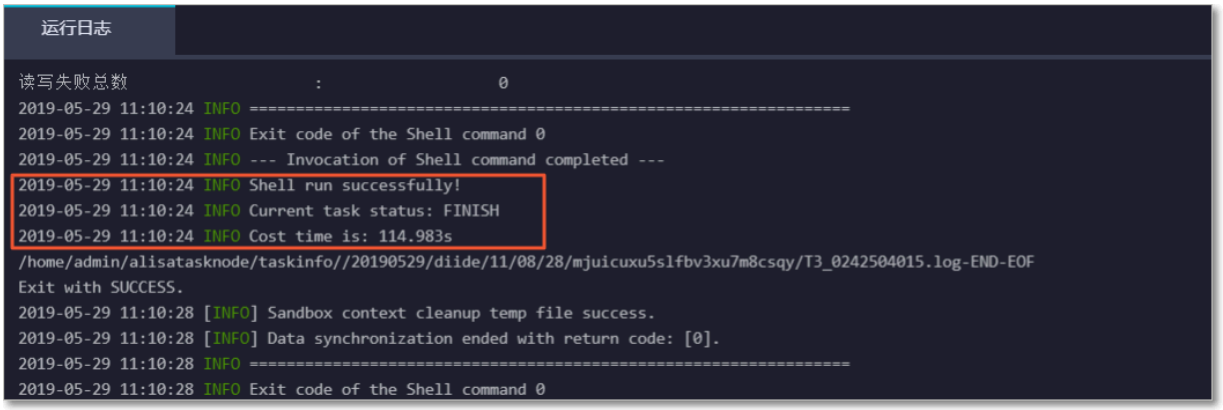

后续步骤

您可以新建一个数据开发任务运行 SQL 语句，查看当前表中是否已存在从 Kafka 同步过的数据。本文以`select * from testkafka`为例，具体步骤如下：

1. 在左侧导航栏，选择数据开发 > 业务流程。
2. 右键选择数据开发 > 新建数据开发节点 > ODPS SQL。
3. 在新建节点对话框，输入节点名称，然后单击提交。
4. 在创建的节点页面，输入`select * from testkafka`，然后单击运行图标。

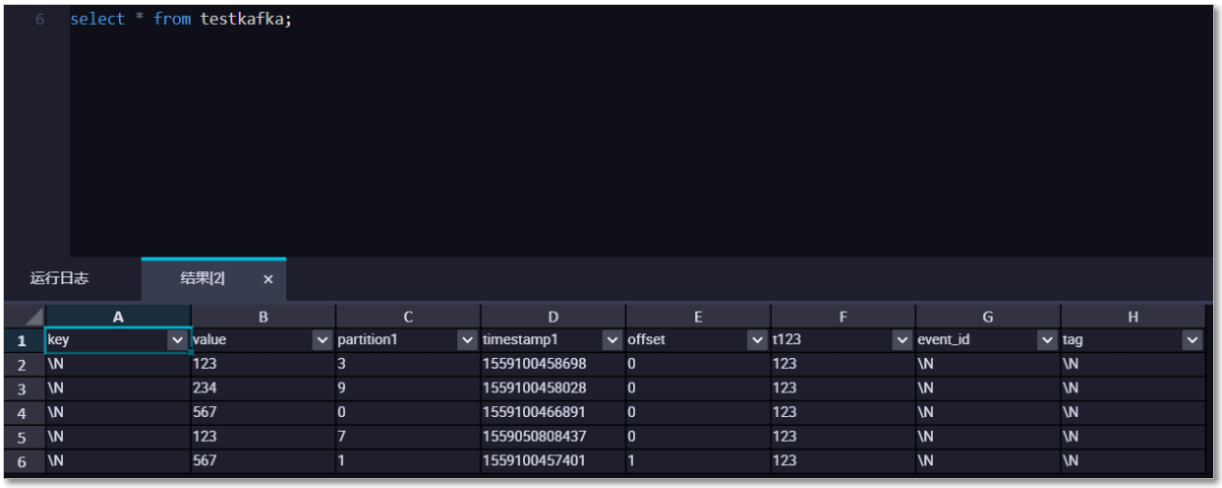

```
6  select * from testkafka;
```

运行日志　结果[2] ×

	A	B	C	D	E	F	G	H
1	key	value	partition1	timestamp1	offset	t123	event_id	tag
2	\N	123	3	1559100458698	0	123	\N	\N
3	\N	234	9	1559100458028	0	123	\N	\N
4	\N	567	0	1559100466891	0	123	\N	\N
5	\N	123	7	1559050808437	0	123	\N	\N
6	\N	567	1	1559100457401	1	123	\N	\N