智能电表数据分析平台方案

部署手册

易珂

版本：v1.0.0

最后更新时间: 2020 年 12 月

Copyright (c) 2021 by Amazon.com, Inc. or its affiliates.

目　录

目　录 **2**

背景 **2**

解决方案描述 **3**

使用场景 **3**

系统架构 **3**

架构图 3
部署服务 4

部署说明 **5**

部署前提 5
登陆到您的账户 5

快速部署 **6**

启动 AMAZON CLOUDFORMATION 堆栈 6
指定堆栈配置细节 6
配置堆栈选项 7
审核 7

开始使用 **8**

下载电表耗能数据集 8
将数据集上传至 S3 桶 9
增加天气数据集（可选，默认不添加） 9
触发 AMAZON GLUE 工作流 10
查看已训练模型 11
重新训练模型（可选） 12
调用 API 14

FAQ **18**

附录 **19**

CLOUDFORMATION 堆栈参数 19
数据集格式 22
GITHUB 地址 22

背景

本部署指南详细描述了如何在云上使用 Amazon CloudFormation 模板部署基于数据湖、人工智能和无服务架构的智能电表数据分析平台，旨在为水电，风电，天然气，光伏发电等公共能源公司和智能仪表公司，提供历史异常电量查询，异常仪表查询，仪表

汇聚数据查询和未来电量消耗预测等功能，数据源则来自电表数据管理系统（MDM）或类似系统。

解决方案描述

智能电表数据分析平台利用 Amazon S3，RedShift，Glue 等服务构建的数据湖实现对现有 MDM 系统仪表数据的存储，清洗，汇聚和查询，结合 Amazon Step Function 和 Amazon SageMaker 实现 ML 模型构建，部署的自动化，通过 Amazon API Gateway，Lambda 构建的无服务架构将数据查询，汇聚，预测等能力通过 RESTful API 形式提供给客户，为客户提供历史异常电量查询，异常仪表查询，仪表汇聚数据查询和未来电量消耗预测等功能。

使用场景

该解决方案旨在帮助希望改善其智能电表投资回报率的能源和仪表行业客户，从而提供替代其原有 MDMS（电表数据管理解决方案）。传统的 MDMS 系统已经使用了 15 年以上，并且大多数仅有帐单核对的功能，通过 Amazon 数据湖，AI 和无服务架构可为客户深度挖掘数据价值，创造更多增值场景。

系统架构

架构图

该解决方案可在由西云数据运营的 亚马逊云科技（宁夏）区域或由光环新网运营的亚马逊云科技（北京）区域中部署。

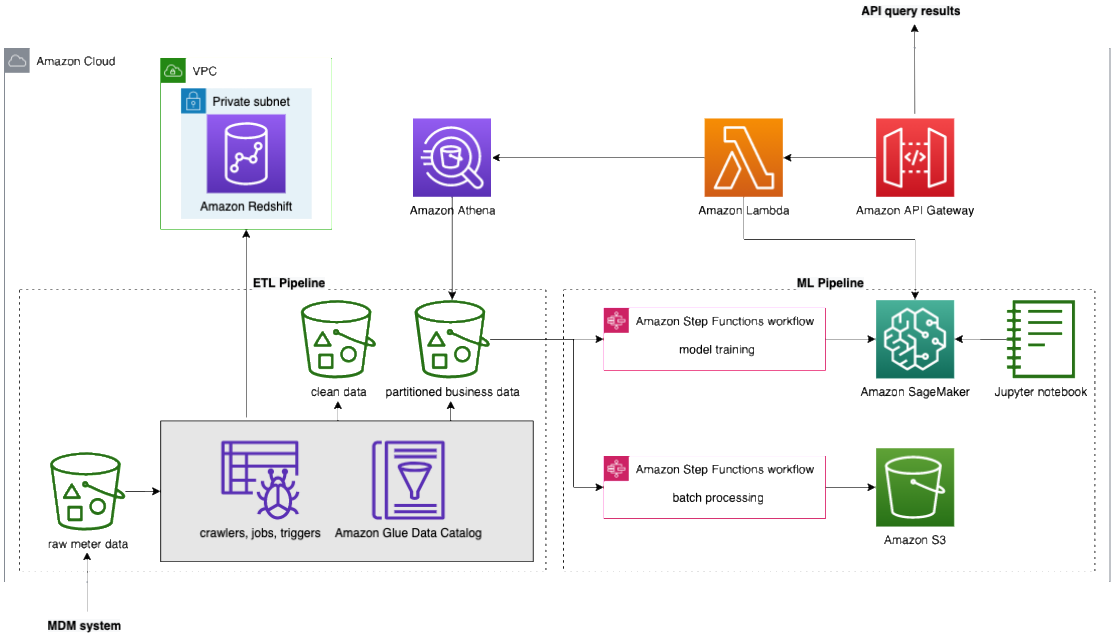

部署服务

该解决方案将自动部署以下服务：

- 依据 Amazon 最佳实践，新建或者复用配置有私有子网的虚拟私有云（VPC）
- 私有子网中的 Amazon Redshift 集群，用于存储业务数据以进行分析，可视化和前端展示。
- 数据的提取，转换和加载（ETL）流程，包括
    - Amazon Simple Storage Service（Amazon S3），用于存储来自 MDM 或类似系统的注入数据，其中原始仪表数据，清洗数据和分区的业务数据分别存储在独立的 S3 桶中。
    - Amazon Glue 工作流，包括爬虫程序，任务程序和事件触发，用于对传入的原始仪表数据进行爬取并转换为所需格式的干净数据和分区的业务数据。
- Amazon Glue 数据目录，用于存储有关仪表数据的元数据和源信息。
- 机器学习服务：
    - 两个 Amazon Step Functions 工作流，包括 1）模型训练，使用分区的业务数据来构建 ML 模型；2）批处理，使用分区的业务数据和模型中的数据作为预测基础。
    - Amazon S3，用于存储处理后的数据。

    - Amazon SageMaker，用于实时预测能耗。
    - 有示例代码的 Jupyter 笔记本，用于执行数据分析和数据可视化。
- Amazon Lambda 通过 Amazon Athena 查询分区的业务数据或调用 SageMaker 部署的服务节点，对外通过 RESTful API 的形式提供查询结果。
- Amazon API Gateway 提供历史异常电量查询，异常仪表查询，仪表汇聚数据查询和未来电量消耗预测等功能。

部署说明

部署前提

- 确保您的数据已在 MDMS（仪表数据管理系统）收集完毕
- 确保您的账户有足够的配额来创建以下资源：

Amazon 服务	该方案使用配额
VPCs	1
Amazon Identity and Access Management (IAM) roles	7
Amazon S3 buckets	6
Amazon Glue crawlers	4
AmazonGlue jobs	3
Amazon SageMaker notebook instances	1
Amazon SageMaker endpoints	1
Amazon Lambda functions	9
Amazon API Gateway endpoints	1
Amazon Redshift instances	1
Amazon Step Functions state machines	3

- 针对该解决方案所创建的 Amazon Redshift 集群，默认我们会给您新建一个 VPC 来进行部署，如果您选择您已有的 VPC，确保准备好对应的网络配置比如 CIDR。

登陆到您的账户

使用具有必需权限的 IAM 用户角色，通过 https://console.amazonaws.cn/登录到您的亚马逊云科技账户。

快速部署

本文的步骤主要针对在运行在由西云数据运营的 亚马逊云科技（宁夏）区域或由光环新网运营的 亚马逊云科技（北京）区域中部署该解决方案，您可以使用以下链接快速启动一个 Amazon CloudFormation 堆栈来部署和管理整个方案：

启动 Amazon CloudFormation 堆栈

点击宁夏和北京区域链接，打开亚马逊云科技管理控制台（如果还没登录会先跳转到登录页面，登录后进入模板启动页面）。默认情况下，此模板在宁夏区域启动，您同时可以使用控制台右上方的区域选择链接，以在其他区域部署该方案。然后单击下面的按钮以启动 Amazon CloudFormation 模板。

Launch Stack

指定堆栈配置细节

在此您需要填入需要创建的 Amazon RedShift 集群的用户名，密码，指定 VPC 网络的可用区。如果您选择在宁夏区域（cn-northwest-1）部署，其他配置采用默认值即可，之

后点击【下一步】到堆栈选项。

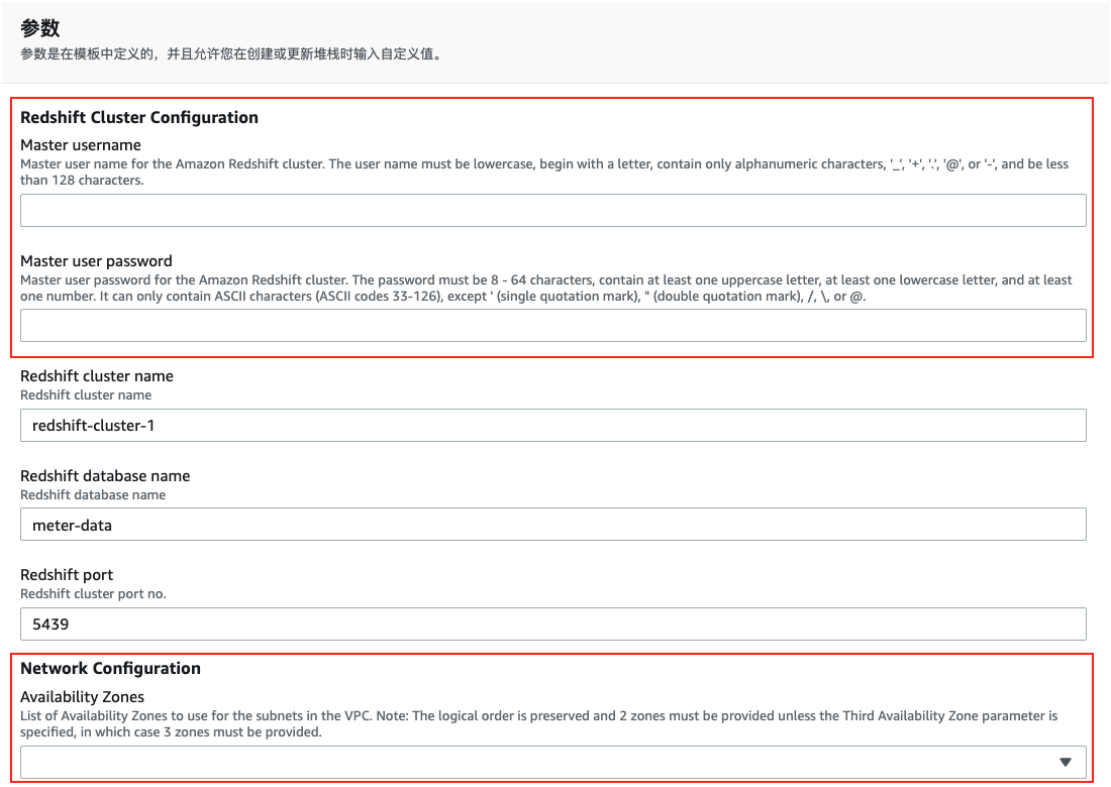

如果您选择在北京区域（cn-north-1）部署，请将下列默认配置字段中的 cn-northwest-1 修改成 cn-north-1，其他配置采用默认值即可，之后点击【下一步】到堆栈选项。

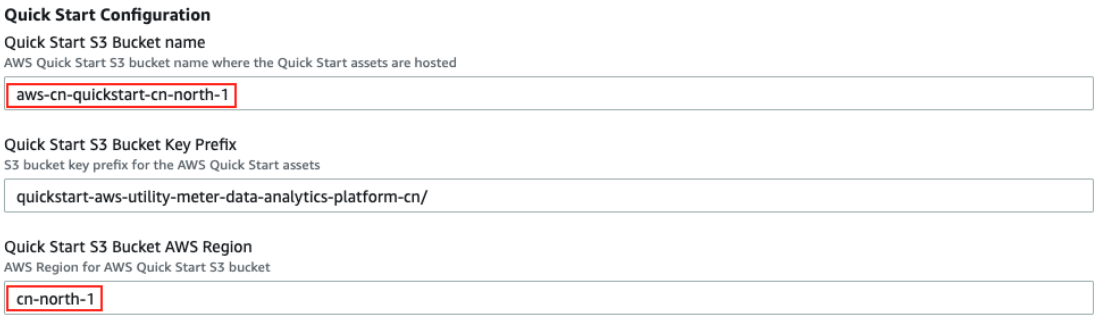

配置堆栈选项

该步骤按照默认值并点击【下一步】进入审核。

审核

勾选如下复选框，然后点击【创建堆栈】。

亚马逊云科技 西云数据运营宁夏区域 光环新网运营北京区域

等待约 30 分钟，堆栈创建完成后您可以看到父堆栈和嵌套堆栈的创建状态，点击【输出】标签栏您将看到创建的资源细节。

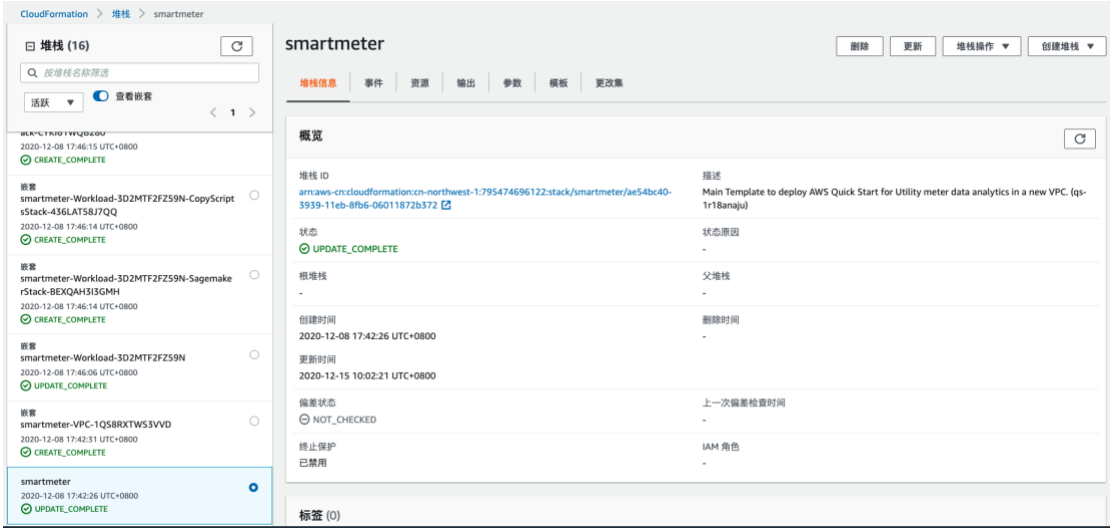

开始使用

下载电表耗能数据集

从 SmartMeter Energy Consumption Data in London Households 下载适用该方案的数据集，注意该数据集总大小为 10G 左右，包括 1.67 亿条智能电表数据，其中提供了单体 csv 文件（10G 左右）和 168 个较小的 csv 文件（每个文件 66M 左右）下载的选项，如果您希望简单试用，建议下载较小的 csv 文件，在接下来的步骤挑选部分数据集上传。

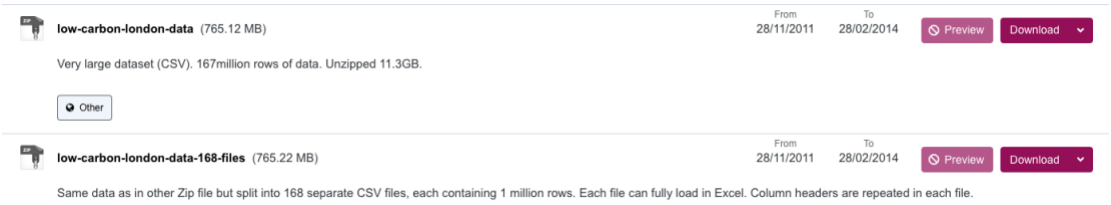

将数据集上传至 S3 桶

进入 S3 服务界面，点击搜索 landingzone 关键字，选取之前创建的 S3 桶。

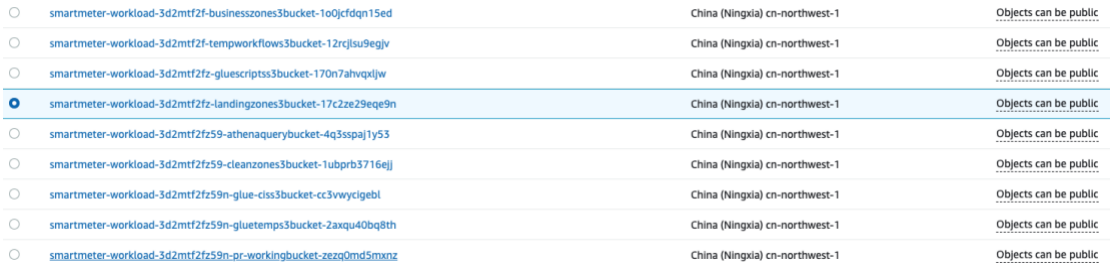

将之前下载的 csv 文件解压上传。

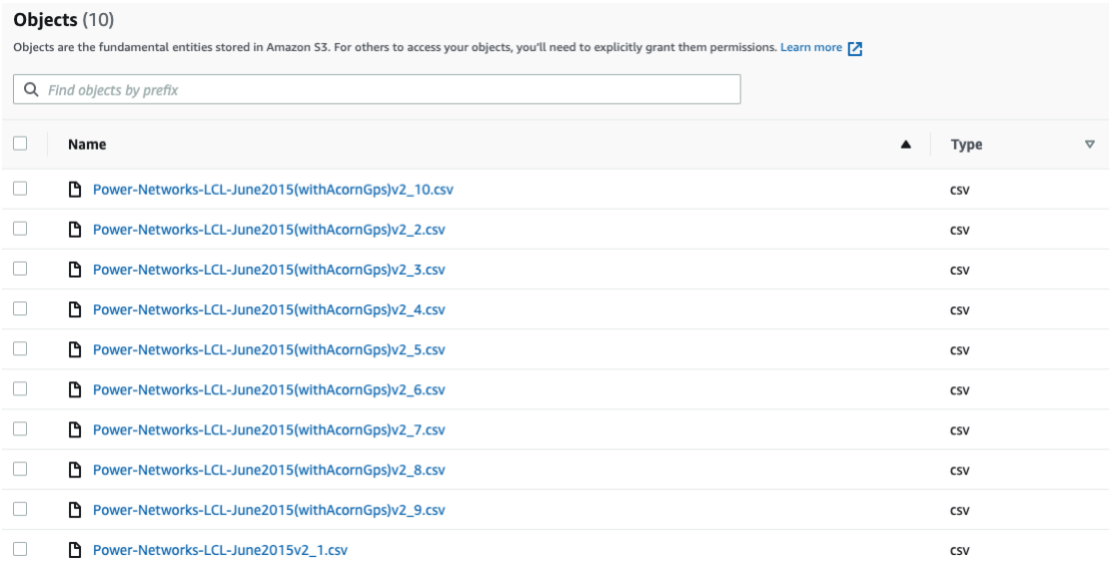

增加天气数据集（可选，默认不添加）

从这里下载使用该方案的天气数据，创建对应的 Amazon S3 桶（如 smartmeter-bj-weather-data）并上传，然后登陆到 Amazon Athena 界面，在新查询标签栏下添加如下 SQL 语句以创建天气相关的 Amazon Glue 表项。

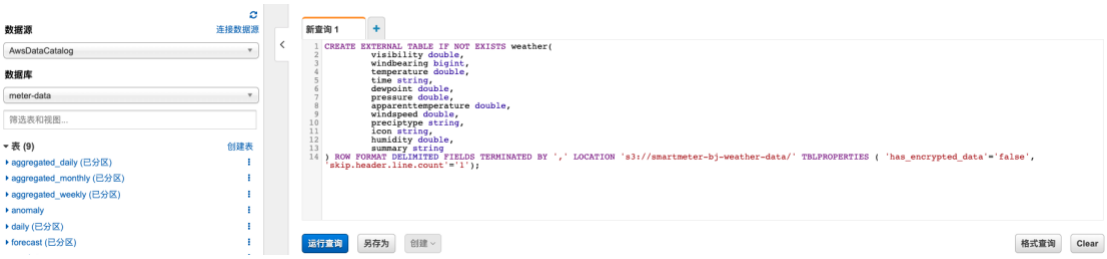

直接将下述 SQL 语句（斜体标示）拷贝粘贴，注意替换其中字段 *smartmeter-bj-weather-data* 为您为天气数据创建的 S3 桶名称

CREATE EXTERNAL TABLE IF NOT EXISTS weather (

visibility double,

windbearing bigint,

temperature double,

time string,

dewpoint double,

pressure double,

apparenttemperature double,

windspeed double,

preciptype string,

icon string,

humidity double,

summary string

) ROW FORMAT DELIMITED FIELDS TERMINATED BY ',' LOCATION 's3://smartmeter-bj-weather-data/' TBLPROPERTIES ('has_encrypted_data'='false', 'skip.header.line.count'='1');

触发 Amazon Glue 工作流

数据准备完毕之后，登陆 Amazon Glue 界面，打开工作流程选项，选择模版创建好的工作流程，点选运行触发后续的数据 ETL 清洗流程。

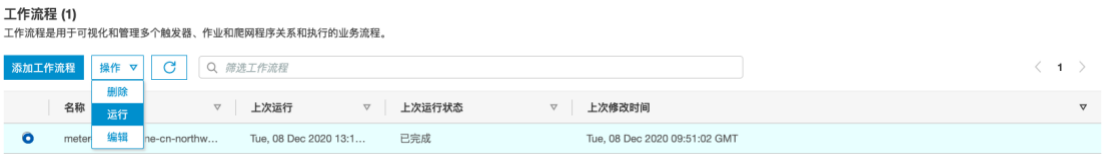

点击【运行】后勾选历史记录选择对应的执行任务，然后点选“查看运行详细信息“可以查看对应工作流程的执行状态。

工作流程执行状态显示如下

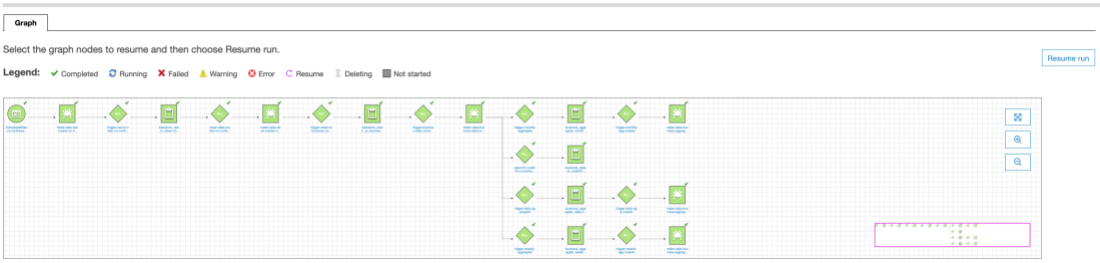

待任务完成之后您可以回到 Amazon Glue 主界面，查看对应的表项是否已经创建完成。

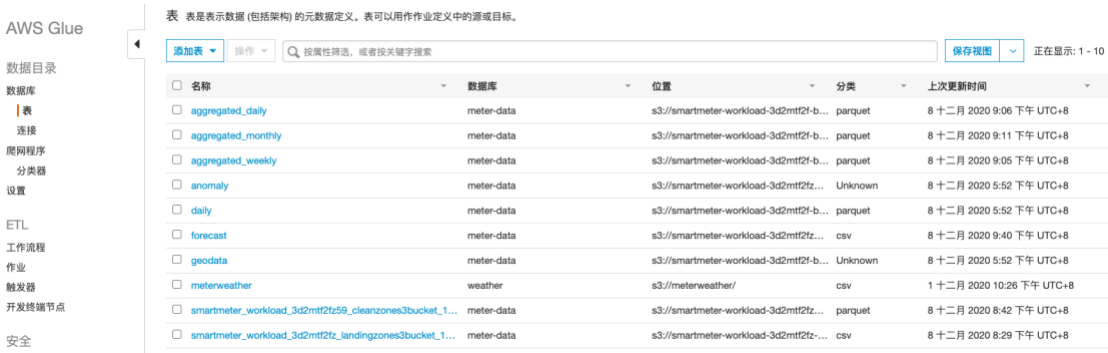

查看已训练模型

数据经由 Amazon Glue 清洗，分区之后会自动触发 Step Function 工作流创建对应的 SageMaker 实例，模型和用于推理的终端节点。登陆 SageMaker 界面，利用创建好的 SageMaker 实例，您可以登陆进实例利用 Jupyter 开始调用里面预制好的功能，如历史异常电量查询，异常仪表查询，仪表汇聚数据查询和未来电量消耗预测等功能。

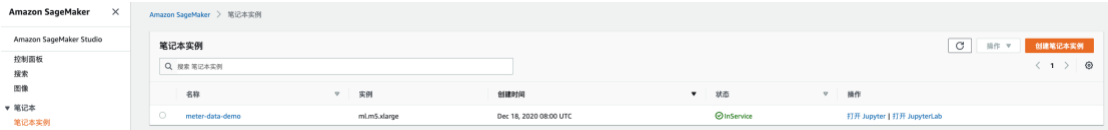

亚马逊云科技
西云数据运营宁夏区域
光环新网运营北京区域

记录到终端节点的名称（如 ml-endpoint-f2f2a4e3-8dec-4444-8d53-e0eca6a1da1f）在后续 RESTFul API 的调用中您将用做请求参数。

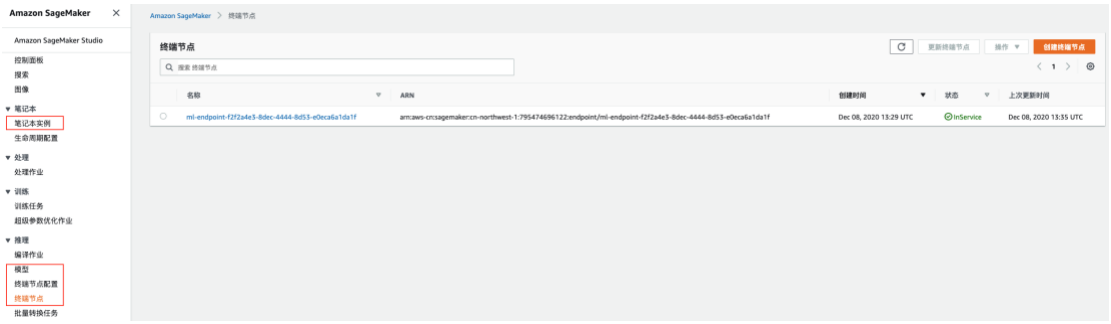

重新训练模型（可选）

该方案创建了模型部署的自动化流程，包括模型训练工作流和批处理工作流，ETL 处理完毕后的数据将成为模型训练的数据集和训练集。每当有新的数据添加进 S3 桶（landingzone）后，您可以重新运行整个 Amazon CloudFormation 以重新处理数据集并进行模型的重新训练，您也可以按照不同时间频率（每天/每周/每月）分别运行每个 Amazon Step Function 工作流，以下是具体步骤：

手动触发 Amazon Step Function 工作流

数据 ETL 完毕之后，登陆进 Amazon Step Function 界面，触发流程进行接下来的模型训练，部署和更新。

点选包含 PredictionPipelineStateMachine 的状态机，点击【启动执行】

在弹出的对话框中输入如下参数，利用该参数来定义数据的批处理分区大小，预测的周期时长，模型名称，终端节点部署的实例类型等。

```
{
 "Meter_start": 1,
 "Meter_end": 100,
```

"Data_start": "2013-06-01",
"Data_end": "2014-01-01",
"Batch_size": 25,
"Forecast_period": 7,
"ModelName": "ml-model-customized ",
"Endpoint_instance_type": "ml.m5.xlarge"
}

该工作流程执行完毕后，我们进一步执行下一个工作流程来实现模型的重新训练，超参调优和模型部署。

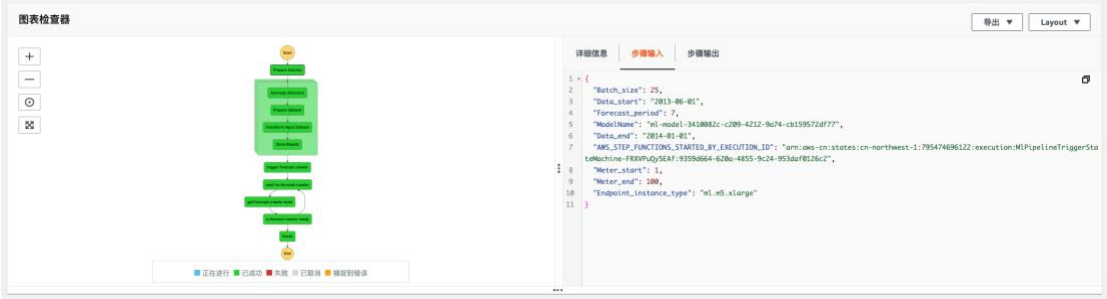

点选包含 InitialTrainingStateMach-的状态机，在【定义】选项栏中设置需要调整的超参，然后点击【启动执行】

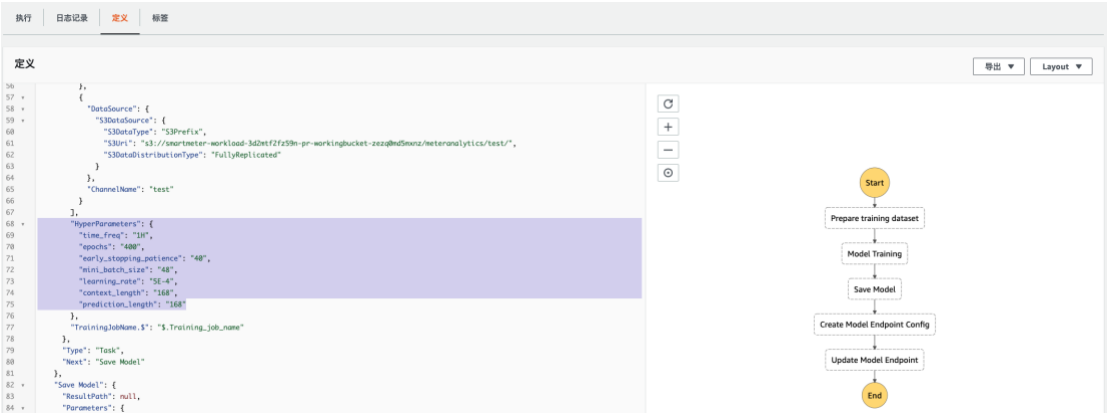

待工作流程执行完毕之后您可以重新跳转至 SageMaker 界面检查新生成的模型和服务节点。

亚马逊云科技 | 西云数据运营宁夏区域
光环新网运营北京区域

调用 API

基于 Amazon API Gateway， Lambda， Step Function 构建的无服务架构将数据查询， 汇聚， 预测等能力通过 RESTful API 形式提供， 您可以跳转至 Amazon API Gateway 界面，点击【阶段】获取到 API 调用的 URL 信息

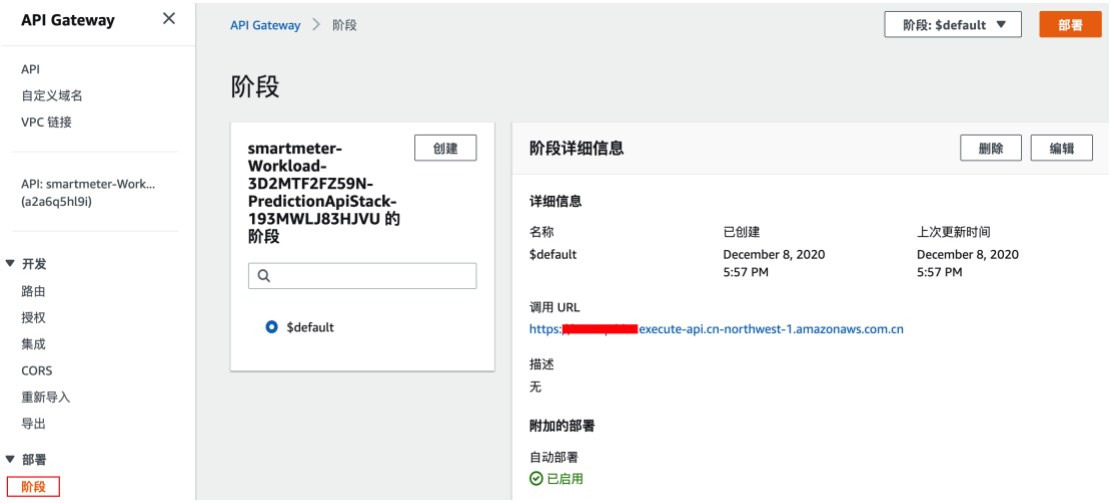

目前 API 提供的功能包括：

- 获取指定时间范围内所有或指定智能电表的异常数据， 调用形式， 参数描述以及对应的 URL 格式和返回内容如下：

调用参数	参数描述
meter_id	智能电表 id
data_start	异常检测开始时间
data_end	异常检测结束时间
outlier_only	显示所有的智能电表数据（outlier_only=0）仅显示存在异常用量的智能电表数据（outlier_only=1）

URL 格式：

GET https://xxxxxxxx.execute-api.cn-northwest-1.amazonaws.com/anomaly/<meter_id>?data_start=<>&data_end=<>&outlier_only=<>

亚马逊云科技 西云数据运营宁夏区域 光环新网运营北京区域

返回内容：


```
{
  "meter_id":{
    "1":"MAC000005",
    "2":"MAC000005"
  },
  "ds":{
    "1":"2013-01-02",
    "2":"2013-01-07"
  },
  "consumption":{
    "1":5.7,
    "2":11.436
  },
  "yhat_lower":{
    "1":3.3661955822,
    "2":3.5661772085
  },
  "yhat_upper":{
    "1":9.1361769262,
    "2":8.9443160402
  },
  "anomaly":{
    "1":0,
    "2":1
  },
  "importance":{
    "1":0.0,
    "2":0.217880724
  }
}
```


- 获取指定智能电表的年度，月度或每天用电量

调用参数	参数描述
aggregation level	按照每天/周/月汇聚数据
year	指定需要获取数据的年份

meter_id	指定智能电表 id

URL 格式：

GET https://xxxxxx.execute-api.cn-northwest-1.amazonaws.com/consumption/<daily|weekly|monthly>/<year>/<meter_id>

返回内容：


```
[
  [
    "MAC001595",
    "20130223",
    3.34
  ],
  [
    "MAC001595",
    "20130221",
    5.316
  ],
  [
    "MAC001595",
    "20130226",
    4.623
  ]
]
```


- 预测指定时间范围内所指定的智能电表的未来使用量

调用参数	参数描述
meter_id	需要进行预测的智能电表 id
data_start	预测所使用数据集的开始时间
data_end	预测所使用数据集的结束时间
ml_endpoint_name	Sagemaker 所创建的终端节点

URL 格式：

亚马逊云科技 西云数据运营宁夏区域 光环新网运营北京区域

GET https://xxxxxxxx.execute-api.cn-northwest-1.amazonaws.com/forecast/<meter_id>?data_start=<>&data_end=<>

返回内容：


```
{
  "consumption":{
    "1380585600000":0.7684248686,
    "1380589200000":0.4294368029,
    "1380592800000":0.3510326743,
    "1380596400000":0.2964941561,
    "1380600000000":0.3064994216,
    "1380603600000":0.4563854337,
    "1380607200000":0.6386958361,
    "1380610800000":0.5963768363,
    "1380614400000":0.5587928891,
    "1380618000000":0.4409750104,
    "1380621600000":0.4719932675
  }
}
```


- 获取指定时间范围内所有异常状态的智能电表 ID 和位置

调用参数	参数描述
start_date_time	指定需要查询开始时间
end_date_time	指定需要查询的结束时间

URL 格式：

GET https://xxxxxxxx.execute-api.cn-northwest-1.amazonaws.com/outage?start_date_time=<>&end_date_time=<>

返回内容：


```
{
  "Items":[
    {
      "meter_id":"MAC000138",
      "reading_date_time":"2013-01-03 09:30:00.000",
```

```
    "date_str":"20130103",
    "lat":40.7177325,
    "long":-74.043845
  },
  {
    "meter_id":"MAC000139",
    "reading_date_time":"2013-01-03 10:00:00.000",
    "date_str":"20130103",
    "lat":40.7177325,
    "long":-74.043845
  }
]
}
```


FAQ

1. 该方案部署展示的数据集来源是哪里，是真实数据吗？

   智能电表采集数据：https://data.london.gov.uk/dataset/smartmeter-energy-use-data-in-london-households

   天气数据：https://www.kaggle.com/jeanmidev/smart-meters-in-london?select=weather_hourly_darksky.csv

2. 该方案展示的数据集格式，如何同我们现有生产系统适配？

   当前的初始数据集 schema 以及清洗后用作业务的 schema 见附录数据集格式。针对客户的生产系统适配，需要考虑：1）如果实际业务 schema 可以复用，则仅需修改 Amazon Glue 中初始数据集 ETL 的相应流程，如果实际业务 schema 存在差异，则需要修改 Amazon Glue 中 ETL 的所流程包括数据的 partition 和 aggregation，以及 API 网关后端逻辑和 SageMaker 训练流程；2）如果客户的生产系统存在多数据格式，则需要在 Amazon Glue 分别进行数据格式的 ETL 适配，推荐方式为固定后端业务数据的 schema，保证前端不同数据格式进行 ETL 后都可复用该 schema，从而最小化后端如 API 网关和 SageMaker 的适配工作，前端不同数据格式的适配工作可通过合作伙伴，联合开发等方式实现；3）上传到 S3 的数据格式目前支持 JSON，CSV，Parquet，ORC，Avro 和 Grok

亚马逊云科技 | 西云数据运营宁夏区域 光环新网运营北京区域

3. 该方案的费用如何？

   该解决方案包括 Amazon Glue，SageMaker，RedShift，S3，Step Functions，Lambda，API Gateway，其中费用集中在 Glue（用于数据 ETL）和 SageMaker（用于模型训练部署），其中 Glue 主要按照 ETL 任务使用的数据处理单元 (DPU) 数量向您收取小时费用（3.021 小时/小时）SageMaker 是主要是针对运行 SageMaker 实例收取的费用（1.898 元/小时）

4. 该方案用来预测智能电表未来用量的算法是什么？

   该方案采用 DeepAR 来实现基于智能电表历史读取数据，天气数据，地理位置等多维数据集来实现基于时间轴的智能电表未来用量预测。DeepAR 是一个自回归循环神经网络，使用递归神经网络(RNN)结合自回归(AR)来预测标量（一维）时间序列。针对应用中具有代表性单元的多个相似时间序列，DeepAR 会结合多个相似的时间序列，通过深度递归神经网络学习不同时间序列内部的关联特性，使用多元或多重的目标个数来提升整体的预测准确度。DeepAR 最后产生一个可选时间跨度的多步预测结果，单时间节点的预测为概率预测，默认输出 P10，P50 和 P90 三个值。

附录

CloudFormation 堆栈参数

参数名称	参数默认值	参数描述
Amazon Redshift 配置		
Master user name (MasterUsername)	用户输入	Amazon Redshift 集群的主用户名。用户名必须小写，以字母开头，仅包含字母数字字符“ _”，“ +”，“。”，“ @”或“-”，并且少于 128 个字符。

亚马逊云科技 西云数据运营宁夏区域 光环新网运营北京区域

Master user password (MasterUserPassword)	用户输入	Amazon Redshift 集群的主用户密码。密码必须为 8-64 个字符，包含至少一个大写字母，至少一个小写字母和至少一个数字。它只能包含 ASCII 字符（ASCII 代码 33-126），除了'（单引号），“（双引号），/，\或@。
Amazon Redshift cluster name (ClusterName)	redshift-cluster-1	Redshift 集群名称
Amazon Redshift database name (DBName)	meter-data	Redshift 数据库名称
Amazon Redshift port (RedshiftPort)	5439	Redshift 端口号
Amazon VPC 网络配置		
Availability Zones (AvailabilityZones)	用户输入	VPC 中的子网要使用的可用区列表。根据 Amazon 最佳实践，您必须提供两个区域。如果指定了第三个可用区参数，则还必须提供该区。
VPC CIDR (VPCCIDR)	10.0.0.0/16	VPC 中的 CIDR（无类别域间路由）
Private subnet 1A CIDR (PrivateSubnet1ACIDR)	10.0.0.0/19	可用区 1 中的私有子网 1A 对应的 CIDR （无类别域间路由）
Private subnet 2A CIDR (PrivateSubnet2ACIDR)	10.0.32.0/19	可用区 2 中的私有子网 2A 对应的 CIDR （无类别域间路由）
Remote access CIDR block (RemoteAccessCIDR)	0.0.0.0/0	可访问 Redshift 集群的 CIDR（无类别域间路由）
Amazon Glue 配置		

亚马逊云科技 西云数据运营宁夏区域 光环新网运营北京区域

Transformer that reads the landing-zone data (LandingzoneTransformer)	London	定义原始数据 ETL 的转换方式，该方案采用的公开数据集地址参见 FAQ
Create landing-zone bucket (CreateLandingZoneS3Bucket)	Yes	Yes，默认创建包含 landingzone 前缀的 S3 桶用作原始数据的存储；No，自定义 S3 桶的名称用作原始数据存储
Landing-zone S3 bucket (LandingZoneS3BucketName)	空字符	如果 Create landing-zone bucket 您填入的是 No，在此处填入您自定义的 S3 桶名称，否则默认留空
Number of meters (NoOfMeters)	1-50000	原始数据集包含的智能电表数量，用于为 Amazon Glue 工作任务配置适当数量的 DPU。默认值为 1-50000，适用于样本数据集或评估目的。对于具有更大规模智能电表部署的生产部署，请选择“ 50001 及更多”。
Amazon S3 配置		
Quick Start S3 bucket name (QSS3BucketName)	aws-cn-quickstart-cn-northwest-1	如果您希望将官方模版拷贝至自己定义的 S3 桶中，请在此指定对应的 S3 桶名称。注意此存储桶名称可以包含数字，小写字母，大写字母和连字符，但不能以连字符（-）开头或结尾。
Quick Start S3 key prefix (QSS3KeyPrefix)	quickstart-aws-utility-meter-data-	如果您希望将官方模版拷贝至自己定义的 S3 桶中，请在此指定对应的 S3 桶前缀。该前缀可以包括数

亚马逊云科技 西云数据运营宁夏区域 光环新网运营北京区域

	analytics-platform-cn/	字，小写字母，大写字母，连字符（-）和正斜杠（/）。
Quick Start S3 bucket Region (QSS3BucketRegion)	cn-northwest-1	官方模版和自定义模版所在的区域，官方模版默认在宁夏区域（cn-northwest-1）

数据集格式

原始数据集如下：

Field	Type	Format
lclid	string	
stdortou	string	
datetime	string	yyyy-MM-dd HH:mm:ss.SSSSSSS
kwh/hh (per half hour)	double	0.000
acorn	string	
acorn_grouped	string	

ETL 后数据集格式如下：

Field	Type	Mandatory	Format
meter_id	String	X	
reading_value	double	X	0.000
reading_type	String	X	AGG|INT
reading_date_time	Timestamp	X	yyyy-MM-dd HH:mm:ss.SSS
date_str	String	X	yyyyMMdd
obis_code	String		
week_of_year	int		
month	int		
year	int		
hour	int		
minute	int		

GitHub 地址

您可以访问我们的 GitHub 地址来下载模版进行部署，或者按照您的需求定制其中的 ETL 脚本，训练算法等，同时欢迎您提交您的反馈和建议。

亚马逊云科技 西云数据运营宁夏区域 光环新网运营北京区域