数据湖探索

版本规划

文档版本	01
发布日期	2025-08-15

华为技术有限公司

商标声明


和其他华为商标均为华为技术有限公司的商标。
本文档提及的其他所有商标或注册商标，由各自的所有人拥有。

注意

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

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

安全声明

漏洞处理流程

华为公司对产品漏洞管理的规定以“漏洞处理流程”为准，该流程的详细内容请参见如下网址：
https://www.huawei.com/cn/psirt/vul-response-process
如企业客户须获取漏洞信息，请参见如下网址：
https://securitybulletin.huawei.com/enterprise/cn/security-advisory

目 录

1 DLI 计算引擎版本生命周期

版本号说明

DLI计算引擎版本号：格式为**计算引擎名称 x.y.z**，其中计算引擎分为Flink和Spark，版本号具体含义如图1-1所示。

图 1-1 DLI 计算引擎版本号

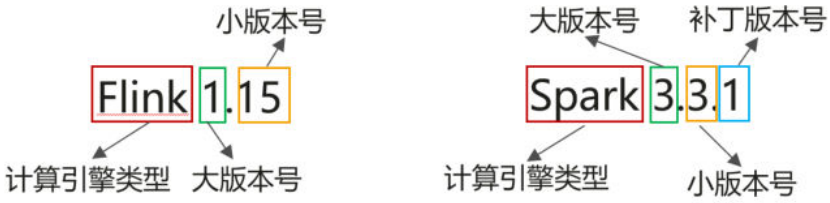

版本支持情况

- Flink计算引擎推荐版本：Flink 1.15。
- Spark计算引擎推荐版本： Spark 3.3.1。

说明

不建议长期混用不同版本的Spark/Flink引擎。

- 长期混用不同版本的Spark/Flink引擎会导致代码在新旧版本之间不兼容，影响作业的执行效率。
- 当作业依赖于特定版本的库或组件，长期混用不同版本的Spark/Flink引擎可能会导致作业因依赖冲突而执行失败。

计算引擎版本生命周期

表1-1给出了DLI计算引擎版本生命周期，帮助您规划自己的版本更新节奏。

说明

- EOM：End of Marketing，停止该版本的销售。所有新购资源不再支持选择EOM的版本的引擎。
- EOS：End of Service & support，停止该版本的服务，建议您在执行作业时选择最新版本的引擎。在该日期之后，不再提供该软件版本的任何技术服务支持。

表 1-1 DLI 计算引擎版本生命周期

计算引擎类型	版本名称	状态	EOM时间	EOS时间
Flink	**DLI Flink 1.15**	**已发布**	**2026年6月30日**	**2027年6月30日**
	DLI Flink 1.12	EOS	2023年12月31日	2024年12月31日
	DLI Flink 1.11	EOS	2022年6月30日	2023年12月31日
	DLI Flink 1.10	EOS	2022年6月30日	2023年12月31日
	DLI Flink 1.7	EOS	2021年12月31日	2022年12月31日
Spark	**DLI Spark 3.3.1**	**已发布**	**2026年6月30日**	**2027年6月30日**
	DLI Spark 3.1.1	EOS	2023年12月31日	2024年12月31日
	DLI Spark 2.4.5	EOS	2023年12月31日	2024年12月31日
	DLI Spark 2.3.2	EOS	2022年6月30日	2023年12月31日

2 Flink 1.15 版本说明

数据湖探索（DLI）遵循开源Flink计算引擎的发布一致性。本文介绍Flink 1.15版本所做的变更说明。

更多Flink 1.15版本说明请参考**Release Notes - Flink Jar 1.15**、**Flink OpenSource SQL1.15版本使用说明**。

Flink 1.15 版本发布时间

版本名称	发布时间	状态	EOM时间	EOS时间
DLI Flink 1.15	2023年6月	已发布	2026年6月30日	2027年6月30日

更多版本支持信息请参考**DLI计算引擎版本生命周期**。

Flink 1.15 版本说明

- Flink 1.15版本在语法设计上实现了更高的兼容性，与主流开源技术标准保持一致。
- Flink 1.15版本新增读写Hive、Hudi等Connector。
- Flink 1.15版本数据同步迁移场景，优先推荐使用DataArts的数据集成。
- Flink 1.15版本支持集成DEW-CSMS凭证管理，提供隐私保护方案。
- Flink 1.15版本支持Flink Jar作业最小化提交。

说明

Flink Jar作业最小化提交是指Flink仅提交作业必须的依赖项，而不是整个Flink环境。通过将非Connector的Flink依赖项（以flink-开头）和第三方库（如Hadoop、Hive、Hudi、Mysql-cdc）的作用域设置为provided，可以确保这些依赖项不会被包含在Jar作业中，从而实现最小化提交，避免依赖包与flink内核中依赖包冲突：

- 仅Flink 1.15版本支持Flink Jar作业最小化提交，通过在运行优化参数中配置flink.dli.job.jar.minimize-submission.enabled=true可以开启最小化提交。
- Flink相关依赖作用域请使用provided，即在依赖中添加<scope>provided</scope>。主要包含org.apache.flink组下以flink-开头的非Connector依赖。
- Hadoop、Hive、Hudi、Mysql-cdc相关依赖，作用域请使用provided，即在依赖中添加<scope>provided</scope>。
- Flink源代码中只有明确标注了@Public或者@PublicEvolving的才是公开供用户调用的方法，DLI只对这些方法的兼容性做出产品保证。

3 Flink 1.12 版本说明

数据湖探索（DLI）遵循开源Flink计算引擎的发布一致性。本文介绍Flink 1.12版本所做的变更说明。

更多Flink 1.12版本说明请参考**Release Notes - Flink 1.12**。

Flink 1.12 版本发布时间

版本名称	发布时间	状态	EOM时间	EOS时间
DLI Flink 1.12	2021年12月	EOS	2023年12月31日	2024年12月31日

更多版本支持信息请参考**DLI计算引擎版本生命周期**。

Flink 1.12 版本说明

- Flink 1.12新增支持DataGen源表、DWS源表、JDBC源表、MySQL CDC源表、Postgres CDC源表、Redis源表、Upsert Kafka源表、Hbase源表。
- Flink 1.12新增支持小文件合并功能。
- Flink 1.12新增支持Redis维表、RDS维表。

4 Spark 3.3.1 版本说明

数据湖探索（DLI）遵循开源Spark计算引擎的发布一致性。本文介绍Spark 3.3.1版本所做的变更说明。

更多Spark 3.3.1版本说明请参考**Spark Release Notes**。

Spark 3.3.1 版本发布时间

版本名称	发布时间	状态	EOM时间	EOS时间
DLI Spark 3.3.1	2023年6月	已发布	2026年6月30日	2027年6月30日

更多版本支持信息请参考**DLI计算引擎版本生命周期**。

Spark 3.3.1 版本说明

表4-1列举了Spark 3.3.1 版本主要的功能特性。

更多版本新特性及性能优化请参考**Release Notes - Spark 3.3.1**。

表 4-1 Spark 3.3.1 版本优势

特性	说明
Native性能加速	Spark查询语句性能提升。
元数据访问性能提升	提升Spark在处理大数据时的元数据访问性能，提高数据处理流程效率。
提升OBS committer小文件写性能	提升对象存储服务（OBS）在处理小文件写入时的性能，提高数据传输效率。
动态Executor shuffle数据优化	提升资源扩缩容的稳定性，当shuffle文件不需要时清理Executor。

特性	说明
支持配置小文件合并	使用SQL过程中，生成的小文件过多时，会导致作业执行时间过长，且查询对应表时耗时增大，建议对小文件进行合并。 参考**如何合并小文件**完成合并小文件。
支持修改非分区表或分区表的列注释	修改非分区表或分区表的列注释。
支持统计SQL作业的CPU消耗	支持在控制台查看“CPU累计使用量”。
支持容器集群Spark日志跳转查看	需要在容器查看日志。
支持动态加载UDF（公测）	无需重启队列UDF即可生效。
Spark UI支持火焰图	Spark UI支持绘制火焰图。
优化SQL作业NOT IN语句查询性能	NOT IN语句查询性能提升。
优化Multi-INSERT语句查询性能	Multi-INSERT语句查询性能提升。

5 Spark 3.1.1 版本说明

数据湖探索（DLI）遵循开源Spark计算引擎的发布一致性。本文介绍Spark 3.1.1版本所做的变更说明。

更多Spark 3.1.1版本说明请参考**Spark Release Notes**。

Spark 3.1.1 版本发布时间

版本名称	发布时间	状态	EOM时间	EOS时间
DLI Spark 3.1.1	2021年12月	EOS	2023年12月31日	2024年12月31日

更多版本支持信息请参考**DLI计算引擎版本生命周期**。

Spark 3.1.1 版本说明

下表列举了Spark 3.1.1 版本主要的功能特性。

更多版本新特性请参考**Release Notes - Spark 3.1.1**。

- 【SPARK-33050】：Apache ORC升级到1.5.12。
- 【SPARK-33092】：增强子表达式消减。
- 【SPARK-33480】：支持char/varchar数据类型。
- 【SPARK-32302】: 部分谓词下推优化。
- 【SPARK-30648】：支持JSON datasource表谓词下推。
- 【SPARK-32346】：支持avro datasource表谓词下推 。
- 【SPARK-32461】：shuffle hash join优化。
- 【SPARK-32272】：添加SQL标准命令SET TIME ZONE。
- 【SPARK-21492】：修复排序合并加入中的内存泄漏。
- 【SPARK-27812】：K8S客户端版本提升到4.6.1。

说明

DLI从Spark 3.x版本开始不支持内置地理空间查询函数。

6 Spark 2.4.5 版本说明

数据湖探索（DLI）遵循开源Spark计算引擎的发布一致性。本文介绍Spark 2.4.5版本所做的变更说明。

更多Spark 2.4.5版本说明请参考**Spark Release Notes**。

Spark 2.4.5 版本发布时间

版本名称	发布时间	状态	EOM时间	EOS时间
DLI Spark 2.4.5	2021年12月	EOS	2023年12月31日	2024年12月31日

更多版本支持信息请参考**DLI计算引擎版本生命周期**。

Spark 2.4.5 版本说明

表6-1列举了Spark 2.4.5版本主要的功能特性。

更多版本新特性请参考**Release Notes - Spark 2.4.5**。

表 6-1 Spark 2.4.5 版本优势

特性	说明
支持配置小文件合并	使用SQL过程中，生成的小文件过多时，会导致作业执行时间过长，且查询对应表时耗时增大，建议对小文件进行合并。 参考**如何合并小文件**完成合并小文件。
支持修改非分区表或分区表的列注释	修改非分区表或分区表的列注释。
支持统计SQL作业的CPU消耗	支持在控制台查看“CPU累计使用量”。

特性	说明
支持容器集群Spark日志跳转查看	需要在容器查看日志。
支持动态加载UDF（公测）	无需重启队列UDF即可生效。
Spark UI支持火焰图	Spark UI支持绘制火焰图。
优化SQL作业NOT IN语句查询性能	NOT IN语句查询性能提升。
优化Multi-INSERT语句查询性能	Multi-INSERT语句查询性能提升。

7 Spark 2.4.x 与 Spark 3.3.x 版本差异对比

7.1 Spark 2.4.x 与 Spark 3.3.x 版本在 SQL 队列的差异对比

DLI整理了Spark 2.4.x与Spark 3.3.x版本在SQL队列的差异，便于您了解Spark版本升级后SQL队列上运行的作业在适配新版本引擎时的影响。

histogram_numeric 函数的返回值的类型不同

- **说明：**

  Spark SQL中的histogram_numeric函数返回一个结构体数组（x,y），不同版本的引擎x的类型不同。

  - **Spark2.4.x**：Spark 3.2或更早版本中，x为double类型。
  - **Spark 3.3.x**：x类型等于函数输入值的类型。

- **升级引擎版本后是否对作业有影响：**

  有影响，涉及相关用法需要适配。

- **示例代码**：

  准备数据：

  ```
  create table test_histogram_numeric(val int);
  INSERT INTO test_histogram_numeric VALUES(1),(5),(8),(6),(7),(9),(8),(9);
  ```

  执行sql：

  ```
  select histogram_numeric(val,3) from test_histogram_numeric;
  ```

  - Spark 2.4.5

    ```
    [{"x":1.0,"y":1.0},{"x":5.5,"y":2.0},{"x":8.200000000000001,"y":5.0}]
    ```

  - Spark 3.3.1

    ```
    [{"x":1,"y":1.0},{"x":5,"y":2.0},{"x":8,"y":5.0}]
    ```

Spark 3.3.x 不再支持使用“0$”指定第一个参数

- **说明：**

  format_string(strfmt, obj, ...) 和 printf(strfmt, obj, ...) 中的 strfmt 将不再支持使用“0$”指定第一个参数，第一个参数应始终由“1$”引用当使用参数索引来指示参数在参数列表中的位置。

  - **Spark2.4.x**：%0和%1均可表示第一个参数。

  - **Spark 3.3.x：**不再支持%0。
- **升级引擎版本后是否对作业有影响：**

  有影响，请作业中如涉及使用%0需修改以适配Spark 3.3.x。
- **示例代码1**：

  执行sql：

```
SELECT format_string('Hello, %0$s! I\'m %1$s!', 'Alice', 'Lilei');
```

  - Spark 2.4.5

```
Hello, Alice! I'm Alice!
```

  - Spark 3.3.1

```
DLI.0005: The value of parameter(s) 'strfmt' in `format_string` is invalid: expects %1$, %2$ and so on, but got %0$.
```

- **示例代码2**：

  执行sql：

```
SELECT format_string('Hello, %1$s! I\'m %2$s!', 'Alice', 'Lilei');
```

  - Spark 2.4.5

```
Hello, Alice! I'm Lilei!
```

  - Spark 3.3.1

```
Hello, Alice! I'm Lilei!
```

Spark 3.3.x 版本中空字符串无引号。

- **说明：**

  默认情况下，空值在CSV数据源中，2.4.5版本空字符串为""，升级到spark3.3.1后空字符串无引号。

  - **Spark2.4.x**：空值在CSV数据源中为""。
  - **Spark 3.3.x：**空值在CSV数据源中无引号。

    如需在Spark 3.3.x版本中恢复Spark2.4.x的格式，可以通过设置spark.sql.legacy.nullValueWrittenAsQuotedEmptyStringCsv为 true来实现。
- **升级引擎版本后是否对作业有影响：**

  有影响，导出orc文件中null值存储形式不同。
- **示例代码**：

  准备数据：

```
create table test_null(id int,name string) stored as parquet;
insert into test_null values(1,null);
```

  导出csv查看文件内容

  - Spark 2.4.5

```
1,""
```

  - Spark 3.3.1

```
1,
```

describe function 返回结果不同

- **说明：**

  如果function不存在，describe function会执行失败。

  - **Spark2.4.x**：DESCRIBE函数仍然可以运行并打印“Function:func_name not found”
  - **Spark 3.3.x：**函数不存在的提示信息变更为失败。

- **升级引擎版本后是否对作业有影响：**

  有影响，describe function 相关API的返回信息不同。

- **示例代码**：

  执行sql：

  ```
  describe function dli_no(dli_no不存在)
  ```

  - Spark 2.4.5

    执行成功，function_desc内容：

    ```
    Function:func_name not found
    ```

  - Spark 3.3.1

    执行失败，DLI.0005:

    ```
    Undefined function: dli_no……
    ```

返回信息明确告知不支持指定表外部属性

- **说明：**

  表外部属性`external`变为保留。如果指定外部属性，某些命令将执行失败。

  - **Spark2.4.x**：通过 `CREATE TABLE ... TBLPROPERTIES`和`ALTER TABLE ... SET TBLPROPERTIES`指定external属性，命令执行成功，但实际上external属性被静默忽略，表依然是managed table。
  - **Spark 3.3.x：**

    通过 `CREATE TABLE ... TBLPROPERTIES`和`ALTER TABLE ... SET TBLPROPERTIES`指定external属性，命令将会失败。

    如需在Spark 3.3.x版本中恢复Spark2.4.x的使用方式，可以通过设置spark.sql.legacy.notReserveProperties为 true来实现。

- **升级引擎版本后是否对作业有影响：**

  有影响，涉及相关用法需要适配。

- **示例代码**：

  执行sql：

  ```
  CREATE TABLE test_external(id INT,name STRING) TBLPROPERTIES('external'=true);
  ```

  - Spark 2.4.5

    执行成功。

  - Spark 3.3.1

    ```
    DLI.0005: The feature is not supported: external is a reserved table property, please use CREATE EXTERNAL TABLE.
    ```

新增支持解析“+Infinity”、“+INF”和“-INF”类型字符串的值

- **说明：**

  - **Spark2.4.x**：当从定义为FloatType 或 DoubleType的JSON属性读取值时，Spark2.4.x仅支持解析“Infinity”和“-Infinity”。
  - **Spark 3.3.x：**当从定义为FloatType 或 DoubleType的JSON属性读取值时，Spark 3.3.x除了支持解析“Infinity”和“-Infinity”之外，还支持解析字符串“+Infinity”、“+INF”和“-INF”。

- **升级引擎版本后是否对作业有影响：**

  功能增强，无影响

默认配置 spark.sql.adaptive.enabled=true

- **说明：**
  - **Spark2.4.x**：在Spark 2.4.x版本中，默认情况下spark.sql.adaptive.enabled配置项的值是false，即自适应查询执行（Adaptive Query Execution，简称AQE）特性是关闭的。
  - **Spark 3.3.x：**从Spark 3.3.x-320版本起开始默认开启AQE特性，即spark.sql.adaptive.enabled配置项的值是true。
- **升级引擎版本后是否对作业有影响：**

  DLI功能增强，spark.sql.adaptive.enabled的默认参数值发生变化。

SHOW TABLES 输出的 schema 的变化

- **说明：**

  SHOW TABLES的输出schema从database: string变成了namespace: string。
  - **Spark2.4.x**：SHOW TABLES的输出schema是database: string。
  - **Spark 3.3.x：**

    SHOW TABLES的输出schema从database: string变成了namespace: string。

    其中对于内置catalog，namespace字段被命名为database；对于v2 catalog没有isTemporary字段。

    如果你希望在Spark 3.3.x版本中恢复到Spark 2.4.x版本的样式，可以通过将spark.sql.legacy.keepCommandOutputSchema设置为true来实现。
- **升级引擎版本后是否对作业有影响：**

  有影响，请排查作业中与SHOW TABLES有关的使用方法，并按上述说明适配新版本的使用要求。
- **示例代码**：

  执行sql：

  ```
  show tables;
  ```

  - Spark 2.4.5

    ```
    database    tableName    isTemporary
    db1         table1        false
    ```

  - Spark 3.3.1

    ```
    namespace    tableName    isTemporary
    db1           table1        false
    ```

SHOW TABLE EXTENDED 输出的 schema 变化

- **说明：**

  SHOW TABLE EXTENDED的输出schema从database: string变成了namespace: string。
  - **Spark2.4.x**：SHOW TABLE EXTENDED的输出schema是database: string。
  - **Spark 3.3.x：**
  - SHOW TABLE EXTENDED的输出schema从database: string变成了namespace: string。

    其中对于内置catalog，namespace字段被命名为database；对于v2 catalog没有变化。

    如果你希望在Spark 3.3.x版本中恢复到Spark 2.4.x版本的样式，可以通过将spark.sql.legacy.keepCommandOutputSchema设置为true来实现。

- **升级引擎版本后是否对作业有影响：**

  有影响，请排查作业中与SHOW TABLES有关的使用方法，并按上述说明适配新版本的使用要求。

- **示例代码**：

  执行sql：

  ```
  show table extended like 'table%';
  ```

  – Spark 2.4.5

  ```
  database    tableName    isTemporary    information
  db1         table1         false          Database:db1...
  ```

  – Spark 3.3.1

  ```
  namespace    tableName    isTemporary    information
  db1          table1         false          Database:db1...
  ```

表刷新对依赖项缓存的影响

- **说明：**

  升级Spark 3.3.x版本后表刷新会清除表的缓存数据，但保持依赖项缓存。

  – **Spark2.4.x**：在Spark 2.4.x版本中，当执行表刷新操作（如REFRESH TABLE）时，不会保留依赖项（例如视图）的缓存数据。

  ```
  ALTER TABLE .. ADD PARTITION
  ALTER TABLE .. RENAME PARTITION
  ALTER TABLE .. DROP PARTITION
  ALTER TABLE .. RECOVER PARTITIONS
  MSCK REPAIR TABLE
  LOAD DATA
  REFRESH TABLE
  TRUNCATE TABLE
  spark.catalog.refreshTable
  ```

  – **Spark 3.3.x：**升级Spark 3.3.x版本后表刷新会清除表的缓存数据，但保持依赖项缓存。

- **升级引擎版本后是否对作业有影响：**

  升级新版本引擎后会增加原有依赖项的缓存数据。

表刷新对依赖该表的其他缓存操作的影响

- **说明：**

  – **Spark2.4.x**：Spark2.4.x中，刷新表时，只有当表本身被缓存时，才会触发引用该表的所有其他缓存的uncache操作。

  – **Spark 3.3.x：**升级新版本引擎后不管表本身是否有缓存，只要刷新表，那么依赖该表的其他缓存都会执行uncache操作。

- **升级引擎版本后是否对作业有影响：**

  DLI功能增强，保证表刷新操作能对缓存生效，提高程序健壮性。

ADD PARTITION 新增支持使用类型化文字

- **说明：**

  – **Spark2.4.x**：

  在Spark 2.4.x版本中，使用ADD PARTITION时，如果使用类型化文字（例如date'2020-01-01'），分区值会被解析为字符串值date'2020-01-01'，会生成一个非法的日期值，因此会添加一个值为null的分区。

  正确的做法是使用字符串值，例如ADD PARTITION(dt = '2020-01-01')

  - **Spark 3.3.x**：在Spark 3.3.x版本中，对分区操作支持使用类型化文字，支持使用ADD PARTITION(dt = date'2020-01-01')，并且可以正确地将分区值解析为日期类型，而不是字符串。

- **升级引擎版本后是否对作业有影响：**

  有影响，ADD PARTITION中对于类型化文字的处理方式的变化。

- **示例代码**：

  准备数据：

```
create table test_part_type (id int,name string,pt date) PARTITIONED by (pt);
insert into test_part_type partition (pt = '2021-01-01') select 1,'name1';
insert into test_part_type partition (pt = date'2021-01-01') select 1,'name1';
```

  执行sql：

```
select id,name,pt from test_part_type;
（配置参数spark.sql.forcePartitionPredicatesOnPartitionedTable.enabled为false)
```

  - Spark 2.4.5

```
1 name1 2021-01-01
1 name1
```

  - Spark 3.3.1

```
1 name1 2021-01-01
1 name1 2021-01-01
```

DayTimeIntervalType 的映射类型变化为 Duration

- **说明：**

  在ArrowWriter和ArrowColumnVector开发者API中，从Spark 3.3.x版本开始，Spark SQL中的DayTimeIntervalType类型被映射到Apache Arrow的Duration类型。

  - **Spark2.4.x**：DayTimeIntervalType被映射到Apache Arrow的Interval类型。
  - **Spark 3.3.x**：DayTimeIntervalType被映射到Apache Arrow的Duration类型。

- **升级引擎版本后是否对作业有影响：**

  有影响，DayTimeIntervalType的映射类型发生变化。

日期差值返回结果的类型变化

- **说明：**

  date减法表达式（如 date1 - date2 ）返回DayTimeIntervalType的值

  - **Spark2.4.x**：返回CalendarIntervalType。
  - **Spark 3.3.x**：返回DayTimeIntervalType。

    恢复之前的行为，将 spark.sql.legacy.interval.enabled 设置为 true

- **升级引擎版本后是否对作业有影响：**

  有影响，日期差值返回结果默认类型变化。

单位到单位间隔的映射类型的变化

- **说明：**

  - **Spark2.4.x**：Spark2.4.x版本中单位到单位的间隔（如 INTERVAL '1-1' YEAR TO MONTH ）和单位列表间隔（如 INTERVAL '3' DAYS '1' HOUR ）将转换为CalendarIntervalType类型。

- **Spark 3.3.x**：在Spark 3.3.x版本中，单位到单位的间隔（如 INTERVAL '1-1' YEAR TO MONTH）和单位列表间隔（如 INTERVAL '3' DAYS '1' HOUR）将转换为 ANSI 间隔类型：YearMonthIntervalType或DayTimeIntervalType类型。

  在Spark 3.3.x版本中如果希望恢复到Spark2.4.x之前的映射类型，可以通过设置配置项

  spark.sql.legacy.interval.enabled为true来实现。

- **升级引擎版本后是否对作业有影响：**

  有影响，映射后的数据类型发生变化。

timestamps 减法表达式返回值类型变化

- **说明：**
  - **Spark2.4.x**：timestamps减法表达式，如select timestamp'2021-03-31 23:48:00'- timestamp'2021-01-01 00:00:00'返回CalendarIntervalType类型的值。
  - **Spark 3.3.x**：timestamps减法表达式，如select timestamp'2021-03-31 23:48:00'- timestamp'2021-01-01 00:00:00'返回DayTimeIntervalType类型的值。

    在Spark 3.3.x版本中如果希望恢复到Spark2.4.x之前的映射类型，可以通过设置配置项spark.sql.legacy.interval.enabled为true来实现。
- **升级引擎版本后是否对作业有影响：**

  有影响，映射后的数据类型发生变化。

不再支持混合使用年月字段和日时间字段

- **说明：**
  - **Spark2.4.x**：单位列表间隔文字可以混合使用年月字段（YEAR 和 MONTH）和日时间字段（WEEK、DAY、...、MICROSECOND）。
  - **Spark 3.3.x**：单位列表间隔文字不能混合使用年月字段（YEAR 和 MONTH）和日时间字段（WEEK、DAY、...、MICROSECOND）。提示无效输入。

    在Spark 3.3.x版本中如果希望恢复到Spark2.4.x之前的使用方式，可以通过设置配置项spark.sql.legacy.interval.enabled为true来实现。
- **升级引擎版本后是否对作业有影响：**

  有影响。

CREATE TABLE .. LIKE .. 命令不能使用保留属性

- **说明：**

  CREATE TABLE .. LIKE .. 命令不能使用保留属性
  - **Spark2.4.x**：Spark2.4.x版本中在执行CREATE TABLE .. LIKE .. 命令时可以使用保留属性。

    例如：TBLPROPERTIES('location'='/tmp') 不会改变表的位置但会创建一个无效属性。
  - **Spark 3.3.x**：Spark 3.3.x版本中CREATE TABLE .. LIKE .. 命令不能使用保留属性，

例如使用TBLPROPERTIES('location'='/tmp')或TBLPROPERTIES('owner'='yao')会直接失败。

- **升级引擎版本后是否对作业有影响：**

  有影响。

- **示例代码1**：

  准备数据：

  ```
  CREATE TABLE test0(id int, name string);
  CREATE TABLE test_like_properties LIKE test0 LOCATION 'obs://bucket1/test/test_like_properties';
  ```

  执行sql：

  ```
  DESCRIBE FORMATTED test_like_properties;
  ```

  - Spark 2.4.5

    正常显示location

  - Spark 3.3.1

    正常显示location

- **示例代码2：**

  准备数据：

  ```
  CREATE TABLE test_like_properties0(id int) using parquet LOCATION 'obs://bucket1/dbgms/test_like_properties0';
  CREATE TABLE test_like_properties1 like test_like_properties0 tblproperties('location'='obs://bucket1/dbgms/test_like_properties1');
  ```

  执行sql：

  ```
  DESCRIBE FORMATTED test_like_properties1;
  ```

  - Spark 2.4.5

    ```
    DLI.0005:
    mismatched input 'tblproperties' expecting {<EOF>, 'LOCATION'}
    ```

  - Spark 3.3.1

    ```
    The feature is not supported: location is a reserved table property, please use the LOCATION clause to specify it.
    ```

包含自动生成的别名时创建视图失败

- **说明：**
  - **Spark2.4.x**：Spark2.4.x版本中如果语句中包含自动生成的别名，则正常执行且无提示信息。
  - **Spark 3.3.x：**Spark 3.3.x版本中如果语句中包含自动生成的别名，则创建/更改视图将失败。

    在Spark 3.3.x版本中如果希望恢复到Spark2.4.x之前的使用方式，可以通过设置配置项spark.sql.legacy.allowAutoGeneratedAliasForView为true来实现。

- **升级引擎版本后是否对作业有影响：**

  有影响。

- **示例代码：**

  准备数据：

  ```
  create table test_view_alis(id1 int,id2 int);
  INSERT INTO test_view_alis VALUES(1,2);
  ```

  执行sql：

  ```
  create view view_alis as select id1 + id2 from test_view_alis;
  ```

  - Spark 2.4.5

执行成功

- Spark 3.3.1
  报错
  ```
  Not allowed to create a permanent view `view_alis` without explicitly assigning an alias for expression (id1 + id2)
  ```
  如果在Spark 3.3.1版本添加如下参数后，执行SQL成功。
  ```
  spark.sql.legacy.allowAutoGeneratedAliasForView = true
  ```

日期加减时间字段间隔后的返回值类型的变化

- **说明：**

  date +/-只有日期时间字段（如date'2011-11-11'）的间隔+间隔12小时返回类型变化。

  - **Spark2.4.x**：在Spark 2.4.x中，当对定义为FloatType或DoubleType的JSON属性进行日期加减操作时，例如date'2011-11-11'加上或减去一个时间间隔（如12小时），返回的类型是日期（DateType）。
  - **Spark 3.3.x**：Spark 3.3.x版本中，对于同样的操作，返回的类型变为时间戳（TimestampType），用于保持与Hive的兼容性。

- **升级引擎版本后是否对作业有影响：**

  有影响。

- **示例代码：**

  执行sql：

  ```
  select date '2011-11-11' - interval 12 hour
  ```

  - Spark 2.4.5
    ```
    2011-11-10
    ```
  - Spark 3.3.1
    ```
    1320897600000
    ```

Spark SQL 支持 Char/Varchar 类型

- **说明：**

  - **Spark2.4.x**：在Spark2.4.x版本中，Spark SQL表字段不支持Char/Varchar类型，当指定为Char/Varchar类型时会强制转换为String类型。
  - **Spark 3.3.x**：Spark SQL表字段支持CHAR/CHARACTER和VARCHAR类型。

- **升级引擎版本后是否对作业有影响：**

  无影响。

- **示例代码：**

  准备数据：

  ```
  create table test_char(id int,name varchar(24),name2 char(24));
  ```

  执行sql：

  ```
  show create table test_char;
  ```

  - Spark 2.4.5
    ```
    create table `test_char`(`id` INT,`name` STRING,`name2` STRING)
    ROW FORMAT...
    ```
  - Spark 3.3.1
    ```
    create table test_char(id INT,name VARCHAR(24),name2 VARCHAR(24))
    ROW FORMAT...
    ```


空值分区的查询语句不同

- **说明：**
  - **Spark2.4.x**：

    Spark 3.0.1或更早版本中，如果分区列是字符串类型，则将其解析为其文本表示形式的字符串文本，例如字符串“null”。

    通过part_col='null'查询空值分区的数据。
  - **Spark 3.3.x：**

    `PARTITION(col=null)`始终在分区规范中解析为null，即使分区列是字符串类型。

    通过part_col is null查询空值分区的数据。
- **升级引擎版本后是否对作业有影响：**

  有影响，涉及对空值分区的查询需要适配
- **示例代码：**

  准备数据：

  ```
  CREATE TABLE test_part_null (col1 INT, p1 STRING) USING PARQUET PARTITIONED BY (p1);
  INSERT INTO TABLE test_part_null PARTITION (p1 = null) SELECT 0;
  ```

  执行sql：

  ```
  select * from test_part_null;
  ```

  - Spark 2.4.5

    ```
    0 null
    ```

    Spark 2.4.5版本执行select * from test_part_null where p1='null'可查到分区数据。
  - Spark 3.3.1

    ```
    0
    ```

    Spark 3.3.1版本执行select * from test_part_null where p1 is null才可查询到数据。

对分区表数据的处理方式不同

- **说明：**

  datasourcev1分区外表，路径下已经存在不带uuid的分区路径数据。

  执行insert overwrite partition操作，Spark 3.3.x会清除之前不带uuid的分区数据，Spark2.4.x不会清理。
  - **Spark2.4.x**：

    保留不带uuid分区路径下数据。
  - **Spark 3.3.x：**

    会删除不带uuid分区路径下数据。
- **升级引擎版本后是否对作业有影响：**

  有影响，会清理脏数据。
- **示例代码：**

  准备数据：

  obs://bucket1/test/overwrite_datasource下创建pt=pt1目录，并导入一个parquet数据文件。

  ```
  create table overwrite_datasource(id int,name string,pt string) using parquet PARTITIONED by(pt)
  LOCATION 'obs://bucket1/test/overwrite_datasource';
  SELECT * FROM overwrite_datasource1 where pt='pt1'两个版本均查询不到数据。
  ```


执行sql：

```
insert OVERWRITE table overwrite_datasource partition(pt='pt1') values(2,'aa2');
```

- Spark 2.4.5

  保留了pt=pt1目录。

- Spark 3.3.1

  删除了pt=pt1目录。

导出 CSV 文件时保留特殊字符的引号

- **说明：**
  - **Spark2.4.x**：

    在Spark 2.4.x版本中，导出CSV文件时，如果字段值中包含特殊字符如换行符（\n）和回车符（\r），并且这些特殊字符被引号（例如双引号"）包围，Spark会自动处理这些引号，在导出的CSV文件中舍弃这些引号。

    例如，字段值"a\rb"在导出时不会包含引号。

  - **Spark 3.3.x：**

    在Spark 3.3.x版本中，优化了对于CSV文件的导出处理，如果字段值中包含特殊字符，并且这些特殊字符被引号包围，Spark会保留这些引号。

    例如：字段值"a\rb"在导出时，引号仍被保留在最终的CSV文件中。
- **升级引擎版本后是否对作业有影响：**

  对查询结果无影响，但导出文件样式有影响。
- **示例代码：**

  准备数据：

  ```
  create table test_null2(str1 string,str2 string,str3 string,str4 string);
  insert into test_null2 select "a\rb", null, "1\n2", "ab";
  ```

  执行sql：

  ```
  SELECT * FROM test_null2;
  ```

  - Spark 2.4.5

    ```
    a b  1 2 ab
    ```

  - Spark 3.3.1

    ```
    a b  1 2 ab
    ```

  导出查询结果到obs，查看csv文件内容：

  - Spark 2.4.5

    ```
    a
    b,"",1
    2",ab
    ```

  - Spark 3.3.1

    ```
    "a
    b",,"1
    2",ab
    ```

新增支持自适应 Skip partial agg 功能的配置

- **说明：**

  Spark 3.3.x版本中新增支持自适应Skip partial agg功能，即当Partial Agg效果不佳时，可以直接跳过，避免Partial Agg带来的额外性能消耗。相关参数：

  - spark.sql.aggregate.adaptivePartialAggregationEnabled：用于控制是否启用自适应Skip partial agg功能。当设置为true时，Spark会根据运行时的统计数据动态决定是否跳过部分聚合。

  - spark.sql.aggregate.adaptivePartialAggregationInterval：该参数用于配置分析间隔，即在处理了多少行数据之后，Spark会进行一次分析，用来决定是否需要跳过部分聚合。
  - spark.sql.aggregate.adaptivePartialAggregationRatio：该参数是判断是否跳过的阈值，用于判断“已处理的group分组/已处理的行数”的比例。如果这个比例大于配置的阈值，则认为预聚合效果不好，此时Spark可以选择跳过部分聚合，避免进一步的性能损失。

  在使用时系统先按照spark.sql.aggregate.adaptivePartialAggregationInterval配置的间隔进行分析，当处理的行数到达间隔之后，再计算”已处理的group分组/已处理的行数”，如果比例大于配置的阈值，则认为预聚合效果不好，此时可以直接选择跳过。

- **升级引擎版本后是否对作业有影响：**

  DLI功能增强。

新增支持 Parallel Multi-Insert

- **说明：**

  Spark 3.3.x版本中新增支持Parallel Multi-Insert，如果SQL存在multi-insert的场景，在同一个SQL里插入到多个表中，这类SQL在Spark开源本身是串行处理的，性能受到制约。针对这类SQL，Spark 3.3.x版本中DLI新增支持multi-insert并行化的优化处理，可以让所有的insert都并发执行，提升处理性能。

  在使用时需配置开启以下功能开关（默认关闭）：

  spark.sql.lazyExecutionForDDL.enabled=true

  spark.sql.parallelMultiInsert.enabled=true

- **升级引擎版本后是否对作业有影响：**

  DLI功能增强，增强multi-insert并行化特性，提升作业运行的可靠性。

新增支持 Enhance Reuse Exchange

- **说明：**

  Spark 3.3.x版本中新增支持Enhance Reuse Exchange，SQL的对应plan存在sort merge join可重用的条件，通过打开相应开关 spark.sql.execution.enhanceReuseExchange.enabled，可以实现SMJ plan node 重用。

  在使用时需配置开启以下功能开关（默认关闭）：

  spark.sql.execution.enhanceReuseExchange.enabled=true

- **升级引擎版本后是否对作业有影响：**

  DLI功能增强。

TIMESTAMP 类型字段读取差异

- **说明：**

  TIMESTAMP类型字段读取差异，对于Asia/Shanghai时区，时间在1900-01-01 08:05:43之前的值，Spark 2.4.5版本写入后Spark 3.3.1版本读取值与Spark 2.4.5版本读取值不同。

  - **Spark2.4.x**：

    以Asia/Shanghai时区的 1900-01-01 00:00:00 为例，通过Spark 2.4.5版本队列写入，Spark 2.4.5版本读取后得到的值为 -2209017600000。

- **Spark 3.3.x：**

  以Asia/Shanghai时区的 1900-01-01 00:00:00 为例，通过Spark 2.4.5版本队列写入，Spark 3.3.1版本配置 **spark.sql.parquet.int96RebaseModeInRead=LEGACY**，读取后得到的值为 -2209017943000。

- **升级引擎版本后是否对作业有影响：**

  有影响，需要评估TIMESTAMP类型字段的使用方式。

- **示例代码：**

  在SQL界面配置：

  ```
  spark.sql.session.timeZone=Asia/Shanghai
  ```

  - Spark 2.4.5

    ```
    create table parquet_timestamp_test (id int, col0 string, col1 timestamp) using parquet;
    insert into parquet_timestamp_test values (1, "245", "1900-01-01 00:00:00");
    ```

    执行SQL读取数据：

    ```
    select * from parquet_timestamp_test;
    ```

    查询结果：

    ```
    id   col0    col1
    1    245     -2209017600000
    ```

  - Spark 3.3.1

    ```
    spark.sql.parquet.int96RebaseModeInRead=LEGACY
    ```

    执行SQL读取数据：

    ```
    select * from parquet_timestamp_test;
    ```

    查询结果：

    ```
    id   col0    col1
    1    245     -2209017943000
    ```

- **配置项说明**：

  这些配置项提供了Spark如何处理DATE, TIMESTAMP类型字段中特定的时间（在外推格里历和儒略历之间有争议的时间），例如：对于Asia/Shanghai时区，指的是在1900-01-01 08:05:43之前的值的处理方式。

  说明

  有歧义的时间：

  1. 在特定时间之前。例如，对于Asia/Shanghai时区，指的是在1900-01-01 08:05:43之前的值；
  2. 且数据文件的元数据中未明确标注使用何种历法进行存储的情况。例如，Spark 3.3.x版本部分情况写入时会在数据文件中记录使用的历法，此时该时间不属于有歧义的时间。

  - **Datasource parquet表配置项说明**

表 7-1 Spark 3.3.1 Datasource parquet 表配置项

配置项	默认值	描述
spark.sql.parquet.int96RebaseModeInRead	LEGACY（Spark SQL默认配置）	读取Parquet文件中INT96类型的TIMESTAMP字段时生效。 ● **EXCEPTION**: 遇到有歧义的时间会抛出报错，读取操作将失败。 ● **CORRECTED**: Spark 不会进行重新调整，而是按照原样读取日期/时间戳。 ● **LEGACY**: Spark 会将日期/时间戳从传统的混合模式（儒略历 + 格里历）日历重新调整到外推格里历。 该配置项仅在 Parquet 文件的写入信息（如 Spark、Hive）未知时才生效。
spark.sql.parquet.int96RebaseModeInWrite	LEGACY（Spark SQL默认配置）	写入Parquet文件中INT96类型的TIMESTAMP字段时生效。 ● **EXCEPTION**: 遇到有歧义的时间会抛出报错，写入操作将失败 ● **CORRECTED**: Spark 不会进行重新调整，而是按照原样写入日期/时间戳 ● **LEGACY**: 当写入 Parquet 文件时，Spark 会将日期/时间戳从外推格里历重新调整到传统的混合模式（儒略历 + 格里历）。

配置项	默认值	描述
spark.sql.parquet.datetimeRebaseModeInRead	LEGACY（Spark SQL默认配置）	读取DATE、TIMESTAMP_MILLIS、TIMESTAMP_MICROS逻辑类型的字段生效。 • **EXCEPTION**: 遇到有歧义的时间会抛出报错，读取操作将失败。 • **CORRECTED**: Spark 不会进行重新调整，而是按照原样读取日期/时间戳。 • **LEGACY**: Spark 会将日期/时间戳从传统的混合模式（儒略历 + 格里历）日历重新调整到外推格里历。 该配置项仅在 Parquet 文件的写入信息（如 Spark、Hive）未知时才生效。
spark.sql.parquet.datetimeRebaseModeInWrite	LEGACY（Spark SQL默认配置）	写入DATE、TIMESTAMP_MILLIS、TIMESTAMP_MICROS逻辑类型的字段生效。 • **EXCEPTION**: 遇到有歧义的时间会抛出报错，写入操作将失败 • **CORRECTED**: Spark 不会进行重新调整，而是按照原样写入日期/时间戳 • **LEGACY**: 当写入 Parquet 文件时，Spark 会将日期/时间戳从外推格里历重新调整到传统的混合模式（儒略历 + 格里历）。

- **Datasource avro表配置项说明**

表 7-2 Spark 3.3.1 Datasource avro 表配置项

配置项	默认值	描述
spark.sql.avro.datetimeRebaseModeInRead	LEGACY（Spark SQL默认配置）	读取DATE、TIMESTAMP_MILLIS、TIMESTAMP_MICROS逻辑类型的字段生效。 ● **EXCEPTION**: 遇到有歧义的时间会抛出报错，读取操作将失败。 ● **CORRECTED**: Spark 不会进行重新调整，而是按照原样读取日期/时间戳。 ● **LEGACY**: Spark 会将日期/时间戳从传统的混合模式（儒略历 + 格里历）日历重新调整到外推格里历。 该配置项仅在 Avro 文件的写入信息（如 Spark、Hive）未知时才生效。
spark.sql.avro.datetimeRebaseModeInWrite	LEGACY（Spark SQL默认配置）	写入DATE、TIMESTAMP_MILLIS、TIMESTAMP_MICROS逻辑类型的字段生效。 ● **EXCEPTION**: 遇到有歧义的时间会抛出报错，写入操作将失败 ● **CORRECTED**: Spark 不会进行重新调整，而是按照原样写入日期/时间戳 ● **LEGACY**: 当写入 Avro 文件时，Spark 会将日期/时间戳从外推格里历重新调整到传统的混合模式（儒略历 + 格里历）。

from_unixtime 函数差异

- **说明：**
  - **Spark2.4.x**：
    以Asia/Shanghai时区的 -2209017600 为例，返回值为1900-01-01 00:00:00。
  - **Spark 3.3.x：**
    以Asia/Shanghai时区的 -2209017943 为例，返回值为 1900-01-01 00:00:00。
- **升级引擎版本后是否对作业有影响：**
  有影响，需要检查使用该函数的场景。
- **示例代码：**
  在SQL界面配置：
  ```
  spark.sql.session.timeZone=Asia/Shanghai
  ```
  - Spark 2.4.5
    执行SQL读取数据：
    ```
    select from_unixtime(-2209017600);
    ```
    查询结果：
    ```
     1900-01-01 00:00:00
    ```
  - Spark 3.3.1
    执行SQL读取数据：
    ```
    select from_unixtime(-2209017600);
    ```
    查询结果
    ```
    1900-01-01 00:05:43
    ```

unix_timestamp 函数差异

- **说明：**
  对于Asia/Shanghai时区，小于1900-01-01 08:05:43的值。
  - **Spark2.4.x**：
    以Asia/Shanghai时区的 1900-01-01 00:00:00 为例，返回值为 -2209017600。
  - **Spark 3.3.x：**
    以Asia/Shanghai时区的 1900-01-01 00:00:00 为例，返回值为 -2209017943。
- **升级引擎版本后是否对作业有影响：**
  有影响，需要检查使用该函数的场景。
- **示例代码：**
  在SQL界面配置：
  ```
  spark.sql.session.timeZone=Asia/Shanghai
  ```
  - Spark 2.4.5
    执行SQL读取数据：
    ```
    select unix_timestamp('1900-01-01 00:00:00');
    ```
    查询结果：
    ```
     -2209017600
    ```


- Spark 3.3.1

  执行SQL读取数据：

  ```
  select unix_timestamp('1900-01-01 00:00:00');
  ```

  查询结果

  ```
  -2209017943
  ```

7.2 Spark 2.4.x 与 Spark 3.3.x 版本在通用队列的差异对比

DLI整理了Spark2.4.x与Spark 3.3.x版本在通用队列的差异，便于您了解Spark版本升级后通用队列上运行的作业在适配新版本引擎时的影响。

log4j 依赖从 1.x 版本修改为 2.x 版本

- **说明：**

  log4j依赖从1.x版本修改为2.x版本

  - **Spark2.4.x**：log4j依赖1.x版本（社区不再支持）。
  - **Spark 3.3.x**：log4j依赖2.x版本。
- **升级引擎版本后是否对作业有影响：**

  有影响

Spark 3.3.x 不支持 v1 表

- **说明：**

  Spark2.4.x支持datasourcev1、datasourcev2表。Spark 3.3.x不支持v1表。

  具体说明请参考**DLI datasourceV1表和datasourceV2表**。

  - **Spark2.4.x**：支持datasourcev1、datasourcev2表。
  - **Spark 3.3.x**：不支持支持datasourcev1表。
- **升级引擎版本后是否对作业有影响：**

  有影响，建议在Spark 2.4.5版本整改到v2表后再升级Spark 3.3.1，具体操作指导可以参考**DLI datasourceV1表和datasourceV2表**的中的示例。

默认情况下空的 input split 不创建 partition

- **说明：**
  - **Spark2.4.x**：默认情况下空的input split将创建partition。
  - **Spark 3.3.x**：默认情况下空的input split不创建partition。

    Spark 3.3.x时spark.hadoopRDD.ignoreEmptySplits=true。
- **升级引擎版本后是否对作业有影响：**

  有影响，需要判断是否使用分区名做业务判断。

eventlog 的压缩格式设置为 zstd

- **说明：**

  Spark 3.3.x版本中，spark.eventLog.compression.codec的默认值被设置为zstd，Spark在压缩事件日志时将不再支持使用spark.io.compression.codec的参数值。

  - **Spark2.4.x**：使用spark.io.compression.codec的参数值作为eventlog的压缩格式。

  - **Spark 3.3.x**：spark.eventLog.compression.codec默认设置为zstd。
- **升级引擎版本后是否对作业有影响：**

  有影响，eventlog的压缩格式发生变化。

spark.launcher.childConectionTimeout 修改

- **说明：**
  - **Spark2.4.x**：配置名为spark.launcher.childConectionTimeout
  - **Spark 3.3.x**：配置名修改为spark.launcher.childConnectionTimeout
- **升级引擎版本后是否对作业有影响：**

  有影响，配置参数名称变化。

Spark 3.3.x 不再支持将 Apache Mesos 作为资源管理器

- **说明：**
  - **Spark2.4.x**：Spark 2.4.x版本中使用Apache Mesos作为资源管理器。
  - **Spark 3.3.x**：Spark 3.3.x不再支持将Apache Mesos作为资源管理器。
- **升级引擎版本后是否对作业有影响：**

  功能增强，Spark 2.4.x版本中使用Mesos作为资源管理器，升级到Spark 3.3.x后，你需要考虑切换到其他资源管理器。

Spark 3.3.x 会在应用程序自行终止时删除 K8s driver

- **说明：**Spark 3.3.x会在应用程序自行终止时删除K8s driver。
- **升级引擎版本后是否对作业有影响：**

  功能增强，升级到Spark 3.3.x后，对于之前依赖于Kubernetes作为资源管理器的作业会有影响。Spark 3.3.x在应用程序终止时会自动删除driver pod可能会影响到作业的资源管理和清理流程。

Spark 3.3.x 支持自定义 k8s 的调度器

- **说明：**
  - **Spark2.4.x**：不支持使用指定Kubernetes调度器来管理Spark作业的资源分配和调度。
  - **Spark 3.3.x**：Spark 3.3.x支持自定义k8s的调度器。
- **升级引擎版本后是否对作业有影响：**

  功能增强，支持自定义调度器管理资源的分配和调度。

Spark 将不可为 null 的模式转换为可空

- **说明：**

  在Spark 2.4.x版本中，当用户指定的schema包含不可为空的字段时，Spark会将这些不可为null的模式转换为可空的。

  但是在Spark 3.3.x版本中，Spark尊重用户指定的schema中的nullability，即如果字段被定义为不可为空，Spark会保持该配置要求，不会自动转换为可空的字段。
  - **Spark2.4.x**：在Spark 2.4.x版本中，当用户指定的schema包含不可为空的字段时，Spark会将这些不可为null的模式转换为可空的。

  - **Spark 3.3.x**：Spark不会自动转换为可空的字段。

    如果希望在Spark 3.3.x版本中恢复到Spark 2.4.x版本的执行方式，您可以通过将 spark.sql.legacy.respectNullabilityInTextDatasetConversion设置为true来实现。

- **升级引擎版本后是否对作业有影响：**

  有影响。

- **示例代码**：

  执行sql：

```
spark.read.schema(StructType(
StructField("f1", LongType, nullable = false) ::
StructField("f2", LongType, nullable = false) :: Nil)
).option("mode", "DROPMALFORMED").json(Seq("""{"f1": 1}""").toDS).show(false);
```

  - Spark 2.4.5

```
|f1 |f2 |
+---+---+
|1  |0  |
```

  - Spark 3.3.1

```
|f1 |f2  |
+---+----+
|1  |null|
```

Spark scala 版本变更

- **说明：**

  Spark scala版本变更。

  - **Spark2.4.x**：Spark scala版本为2.11。
  - **Spark 3.3.x**：Spark scala版本升级到2.12。

- **升级引擎版本后是否对作业有影响：**

  有影响，jar需要升级scala版本编译。

PySpark 支持 python 版本变更

- **说明：**

  PySpark支持python版本变更。

  - **Spark2.4.x**：PySpark支持python版本范围2.6+版本到3.7+版本。
  - **Spark 3.3.x**：PySpark支持Python版本范围3.6及以上版本。

- **升级引擎版本后是否对作业有影响：**

  依赖版本变化，有影响，需要排查是否涉及。

PySpark-pandas 支持版本变更

- **说明：**

  - **Spark2.4.x**：在Spark 2.4.x版本中，PySpark并没有要求指定Pandas的版本。
  - **Spark 3.3.x**：从Spark 3.3.x版本开始，PySpark需要0.23.2或更高版本的pandas才能使用pandas相关功能，如toPandas、 createDataFrame from pandas DataFrame等。

- **升级引擎版本后是否对作业有影响：**

  依赖版本变化，有影响，需要排查是否涉及。

PySpark-PyArrow 支持版本变更

- **说明：**
  - **Spark2.4.x**：在Spark 2.4.x版本中，PySpark并没有要求指定PyArrow的版本。
  - **Spark 3.3.x：**从Spark 3.3.x版本开始，PySpark需要0.12.1或更高版本的PyArrow才能使用PyArrow相关功能，如Pandas_udf、toPandas等。
- **升级引擎版本后是否对作业有影响：**

  依赖版本变化，有影响，需要排查是否涉及。

以 command 命名 DataFrameWriter 触发的查询

在Spark 3.2.x版本中，当DataFrameWriter触发的查询执行被发送给QueryExecutionListener时，这些查询的名称总是被设置为command。而在Spark 3.1及更早版本中，这些查询的名称可能是save、insertInto或saveAsTable之一，这取决于具体的操作。

- **说明：**

  DataFrameWriter触发的查询执行在发送到QueryExecutionListener时，始终以command命名
  - **Spark2.4.x**：名称为save、insertInto、saveAsTable中的一个
  - **Spark 3.3.x：**command命名
- **升级引擎版本后是否对作业有影响：**

  有影响

DATE、TIMESTAMP 类型字段读取差异

- **说明：**

  DATE、TIMESTAMP类型字段读取差异，对于Asia/Shanghai时区，时间在1900-01-01 08:05:43之前的值，Spark 2.4.5版本写入后Spark 3.3.1版本读取值与Spark 2.4.5版本读取值不同。
  - **Spark2.4.x**：

    以Asia/Shanghai时区的 1900-01-01 00:00:00 为例，通过Spark 2.4.5版本队列写入，Spark 2.4.5版本读取后得到的值为 1900-01-01 00:00:00。
  - **Spark 3.3.x：**

    以Asia/Shanghai时区的 1900-01-01 00:00:00 为例，通过Spark 2.4.5版本队列写入，Spark 3.3.1版本配置**spark.sql.parquet.int96RebaseModeInRead=LEGACY**，读取后得到的值为 1900-01-01 00:00:00，但是配置**spark.sql.parquet.int96RebaseModeInRead=CORRECTED**时，读取后得到的值为1900-01-01 00:05:43。
- **升级引擎版本后是否对作业有影响：**

  有影响，需要评估DATE、TIMESTAMP类型字段的使用方式。
- **示例代码：**

  在作业中配置：

  ```
  spark.sql.session.timeZone=Asia/Shanghai
  ```
  - Spark 2.4.5


```
spark.sql("create table parquet_timestamp_test (id int, col0 string, col1 timestamp) using parquet");
spark.sql("insert into parquet_timestamp_test values (1, '245', '1900-01-01 00:00:00')");
```

执行SQL读取数据：

```
spark.sql("select * from parquet_timestamp_test").show();
```

查询结果：

```
+---+----+-------------------+
| id|col0|               col1|
+---+----+-------------------+
|  1| 245|1900-01-01 00:00:00|
+---+----+-------------------+
```

- Spark 3.3.1

```
spark.sql.parquet.int96RebaseModeInRead=LEGACY
```

执行作业读取数据：

```
spark.sql("select * from parquet_timestamp_test").show();
```

查询结果

```
+---+----+-------------------+
| id|col0|               col1|
+---+----+-------------------+
|  1| 245|1900-01-01 00:00:00|
+---+----+-------------------+
```

可以再更换配置：

```
spark.sql.parquet.int96RebaseModeInRead=CORRECTED
```

并重新执行SQL进行读取：

```
spark.sql("select * from parquet_timestamp_test").show();
```

查询结果：

```
+---+----+-------------------+
| id|col0|               col1|
+---+----+-------------------+
|  1| 245|1900-01-01 00:05:43|
+---+----+-------------------+
```

- **配置项说明**：

  这些配置项提供了Spark如何处理DATE, TIMESTAMP类型字段中特定的时间（在外推格里历和儒略历之间有争议的时间），例如：对于Asia/Shanghai时区，指的是在1900-01-01 08:05:43之前的值的处理方式。

  说明

  有歧义的时间：

  1. 在特定时间之前。例如，对于Asia/Shanghai时区，指的是在1900-01-01 08:05:43之前的值；
  2. 且数据文件的元数据中未明确标注使用何种历法进行存储的情况。例如，Spark 3.3.x版本部分情况写入时会在数据文件中记录使用的历法，此时该时间不属于有歧义的时间。

  - **Datasource parquet表配置项说明**

表 7-3 Spark 3.3.1 Datasource parquet 表配置项

配置项	默认值	描述
spark.sql.parquet.int96RebaseModeInRead	EXCEPTION （Spark作业默认配置）	读取Parquet文件中INT96类型的TIMESTAMP字段时生效。 ● **EXCEPTION**: 遇到有歧义的时间会抛出报错，读取操作将失败。 ● **CORRECTED**: Spark 不会进行重新调整，而是按照原样读取日期/时间戳。 ● **LEGACY**: Spark 会将日期/时间戳从传统的混合模式（儒略历 + 格里历）日历重新调整到外推格里历。 该配置项仅在 Parquet 文件的写入信息（如 Spark、Hive）未知时才生效。
spark.sql.parquet.int96RebaseModeInWrite	EXCEPTION （Spark作业默认配置）	写入Parquet文件中INT96类型的TIMESTAMP字段时生效。 ● **EXCEPTION**: 遇到有歧义的时间会抛出报错，写入操作将失败 ● **CORRECTED**: Spark 不会进行重新调整，而是按照原样写入日期/时间戳 ● **LEGACY**: 当写入 Parquet 文件时，Spark 会将日期/时间戳从外推格里历重新调整到传统的混合模式（儒略历 + 格里历）。

配置项	默认值	描述
spark.sql.parquet.datetimeRebaseModeInRead	EXCEPTION （Spark作业默认配置）	读取DATE、TIMESTAMP_MILLIS、TIMESTAMP_MICROS逻辑类型的字段生效。 • **EXCEPTION**: 遇到有歧义的时间会抛出报错，读取操作将失败。 • **CORRECTED**: Spark 不会进行重新调整，而是按照原样读取日期/时间戳。 • **LEGACY**: Spark 会将日期/时间戳从传统的混合模式（儒略历 + 格里历）日历重新调整到外推格里历。 该配置项仅在 Parquet 文件的写入信息（如 Spark、Hive）未知时才生效。
spark.sql.parquet.datetimeRebaseModeInWrite	EXCEPTION （Spark作业默认配置）	写入DATE、TIMESTAMP_MILLIS、TIMESTAMP_MICROS逻辑类型的字段生效。 • **EXCEPTION**: 遇到有歧义的时间会抛出报错，写入操作将失败 • **CORRECTED**: Spark 不会进行重新调整，而是按照原样写入日期/时间戳 • **LEGACY**: 当写入 Parquet 文件时，Spark 会将日期/时间戳从外推格里历重新调整到传统的混合模式（儒略历 + 格里历）。

- **Datasource avro表配置项说明**

表 7-4 Spark 3.3.1 Datasource avro 表配置项

配置项	默认值	描述
spark.sql.avro.datetimeRebaseModeInRead	EXCEPTION （Spark作业默认配置）	读取DATE、TIMESTAMP_MILLIS、TIMESTAMP_MICROS逻辑类型的字段生效。 ● **EXCEPTION**: 遇到有歧义的时间会抛出报错，读取操作将失败。 ● **CORRECTED**: Spark 不会进行重新调整，而是按照原样读取日期/时间戳。 ● **LEGACY**: Spark 会将日期/时间戳从传统的混合模式（儒略历 + 格里历）日历重新调整到外推格里历。 该配置项仅在 Avro 文件的写入信息（如 Spark、Hive）未知时才生效。
spark.sql.avro.datetimeRebaseModeInWrite	EXCEPTION （Spark作业默认配置）	写入DATE、TIMESTAMP_MILLIS、TIMESTAMP_MICROS逻辑类型的字段生效。 ● **EXCEPTION**: 遇到有歧义的时间会抛出报错，写入操作将失败 ● **CORRECTED**: Spark 不会进行重新调整，而是按照原样写入日期/时间戳 ● **LEGACY**: 当写入 Avro 文件时，Spark 会将日期/时间戳从外推格里历重新调整到传统的混合模式（儒略历 + 格里历）。

from_unixtime 函数差异

- **说明：**
  - **Spark2.4.x**：
    以Asia/Shanghai时区的 -2209017600 为例，返回值为1900-01-01 00:00:00。
  - **Spark 3.3.x：**
    以Asia/Shanghai时区的 -2209017943 为例，返回值为 1900-01-01 00:00:00。
- **升级引擎版本后是否对作业有影响：**
  有影响，需要检查使用该函数的场景。
- **示例代码：**
  在作业中配置：

```
spark.sql.session.timeZone=Asia/Shanghai
```

  - Spark 2.4.5
    执行以下语句读取数据：

```
select from_unixtime(-2209017600);
```

    查询结果：

```
+-----------------------------------------------+
|from_unixtime(-2209017600, yyyy-MM-dd HH:mm:ss)|
+-----------------------------------------------+
|                            1900-01-01 00:00:00|
+-----------------------------------------------+
```

  - Spark 3.3.1
    执行以下语句读取数据：

```
select from_unixtime(-2209017600);
```

    查询结果

```
+-----------------------------------------------+
|from_unixtime(-2209017600, yyyy-MM-dd HH:mm:ss)|
+-----------------------------------------------+
|                            1900-01-01 00:05:43|
+-----------------------------------------------+
```

unix_timestamp 函数差异

- **说明：**
  对于Asia/Shanghai时区，小于1900-01-01 08:05:43的值。
  - **Spark2.4.x**：
    以Asia/Shanghai时区的 1900-01-01 00:00:00 为例，返回值为 -2209017600。
  - **Spark 3.3.x：**
    以Asia/Shanghai时区的 1900-01-01 00:00:00 为例，返回值为 -2209017943。
- **升级引擎版本后是否对作业有影响：**
  有影响，需要检查使用该函数的场景。
- **示例代码：**
  在作业中配置：

```
spark.sql.session.timeZone=Asia/Shanghai
```


- Spark 2.4.5

  执行以下语句读取数据：

  ```
  select unix_timestamp('1900-01-01 00:00:00');
  ```

  查询结果：

  ```
  +-------------------------------------------------------+
  |unix_timestamp(1900-01-01 00:00:00, yyyy-MM-dd HH:mm:ss)|
  +-------------------------------------------------------+
  |                                            -2209017600|
  +-------------------------------------------------------+
  ```

- Spark 3.3.1

  执行以下语句读取数据：

  ```
  select unix_timestamp('1900-01-01 00:00:00');
  ```

  查询结果

  ```
  +-------------------------------------------------------+
  |unix_timestamp(1900-01-01 00:00:00, yyyy-MM-dd HH:mm:ss)|
  +-------------------------------------------------------+
  |                                            -2209017943|
  +-------------------------------------------------------+
  ```

7.3 DLI datasourceV1 表和 datasourceV2 表

什么是 DLI datasourcev1 表和 DLI datasourcev2 表?

- DLI datasource v1表（以下简称V1表）：DLI的Datasource表格式，建表/插入/truncate命令使用DLI自定义的command，表的数据路径为$tablepath/UUID/数据文件。

  图 7-1 DLI datasource v1 表

  

- DLI datasource v2表（以下简称V2表）：spark开源的Datasource表，建表/插入/truncate命令使用spark开源的command，表的数据路径为$tablepath/数据文件。

图 7-2 DLI datasource v2 表

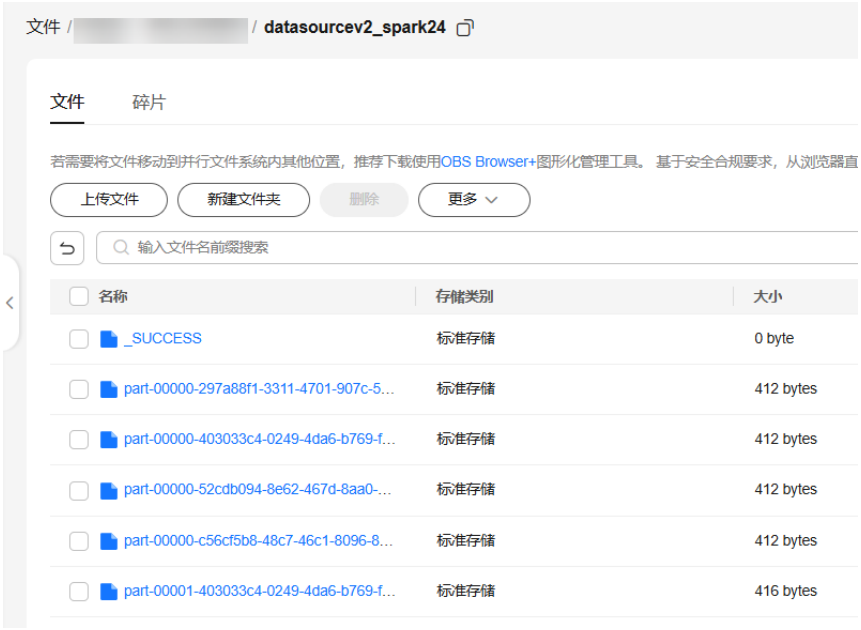

DLI 各 Spark 版本对 V1、V2 表兼容性

表 7-5 DLI 各 Spark 版本对 V1、V2 表兼容列表

表类型	Spark 2.3 SQL队列	Spark 2.3 通用队列	Spark2.4 SQL队列	Spark2.4 通用队列	Spark 3.1 SQL队列	Spark 3.1 通用队列	Spark 3.3 SQL队列	Spark 3.3 通用队列
V1表	√	√	√	√	√	√	√	部分支持
V2表	×	×	√	√	×	×	√	√

表 7-6 Spark3.3 通用队列语法支持列表

表类型	select	create table	create table like	CTAS	insert into	insert overwrite	load data	alter table set location	truncate table
V1表	√	√	√	×	×	×	×	×	×
V2表	√	√	√	√	√	√	√	√	√

怎么确认当前用户创建的表是 v1 还是 v2 表?

1. 使用datasource语法建表：

```
CREATE TABLE IF NOT EXISTS table_name (id STRING) USING parquet;
```

2. 执行show create table查看TBLPROPERTIES下的"verison"字段的值

"v1"为V1表；"v2"则为V2表。

如需修改V1表为V2表请提交工单联系客户支持获取操作帮助。

升级示例

说明

升级Spark引擎和修改数据表时，如新建队列时切换了计算资源类型可能会导致计费资源的费用变化。

- 如果原队列使用的是弹性资源池类型的计算资源，那么新建队列不涉及计算资源的费用变化。
- 如果原队列使用的是非弹性资源池的类型的计算资源，那么使用弹性资源池资源新建队列后计算资源的费用将发生变化，具体情况以计算资源的价格详情为准。

- **示例1：使用SQL队列，将Spark版本从Spark 2.4.x升级至Spark 3.3.1对数据表的版本有影响吗?**

  不需要，Spark 2.4.x的SQL队列支持V1表和V2表，因此升级Spark版本只需要考虑Spark版本对SQL语法的兼容性。

- **示例2：使用通用队列，将Spark版本从Spark 2.4.x升级至Spark 3.3.1对数据表的版本有影响吗?**

  Spark 2.4.x通用队列支持V1表和V2表，但Spark 3.3.x通用队列不支持V1表。

  因此如需将Spark版本从Spark 2.4.x升级至Spark 3.3.1需经过以下步骤：

  a. 将Spark 2.4.x的V1表修改为V2表。
  b. 升级Spark 2.4.x的V2表升级为Spark 3.3.1的V2表。
     同时还需考虑Spark jar作业API语法的兼容性。

  表 7-7 DLI 各 Spark 版本对 V1、V2 表兼容列表

表类型	Spark2.4 通用队列	Spark3.3 通用队列
V1表	√	部分支持
V2表	√	√

- **示例3：使用通用队列，怎样将Spark 2.3.2的V1表升级为Spark 3.3.1的V2表?**

  Spark 2.3.2通用队列不支持V2表，Spark 3.3.1通用队列不支持V1表：

  a. 将Spark 2.3.2的V1表升级至Spark 2.4.5的V1表。
  b. 将Spark 2.4.5的V1表修改为V2表。
  c. 升级Spark 2.4.5的V2表升级为Spark 3.3.1的V2表。
     同时还需考虑Spark jar作业API语法的兼容性。

表 7-8 DLI 各 Spark 版本对 V1、V2 表兼容列表

表类型	Spark2.3 通用队列	Spark2.4 通用队列	Spark3.3 通用队列
V1表	√	√	部分支持
V2表	×	√	√

7.4 Spark 2.4.x 与 Spark 3.3.x 版本授权差异说明

在**Spark2.4.x**升级**Spark 3.3.x**后，部分SQL语法对权限的要求有所变化。需要您在IAM管理控制台“角色或策略授权”的操作界面修改自定义策略，以满足Spark 3.3.x版本的SQL语法的权限要求。避免因权限缺失导致在Spark 3.3.x版本执行SQL作业报错或失败。

本节操作介绍使用Spark 2.4.x与Spark 3.3.x版本SQL语句对授权操作的差异。修改自定义策略的方法可以参考**DLI自定义策略修改示例**。

SQL 作业指定 currentdb 场景的权限要求

- **Spark 3.3.x**：Spark 3.3.x提交SQL作业的接口，在指定currentdb时需要添加该数据库的DISPLAY_DATABASE权限，兼容DISPLAY_ALL_DATABASE权限。
- **Spark2.4.x**：不涉及。

执行操作分区相关的语句的权限要求

- **Spark3.3.1**：操作分区相关的语句需要添加SHOW_PARTITIONS权限。

  授权对象为分区表时，如果对指定列授予SELECT权限，还需要同时对表授予SHOW_PARTITIONS权限。请注意SHOW_PARTITIONS权限是表级别的权限，需要额外对表进行授权操作。

  执行操作分区相关的语句包括：

  - 分区表相关操作

    例如对分区表执行的insert、load、select等操作。
  - 分区相关操作

    常见的执行操作分区相关的语句请参考**分区相关Spark SQL语法**。
- **Spark2.4.x**：不涉及。

执行操作数据相关语句的权限要求

- **Spark3.3.1**：操作数据相关语句需要添加ALTER权限。

  INSERT TABLE

  INSERT OVERWRITE TABLE

  相关语句使用说明请参考**插入数据**。

  TRUNCATE TABLE

  相关语句使用说明请参考**清空数据**。
- **Spark2.4.x**：不涉及。

修改表相关语句的权限变化

- **Spark3.3.1**：修改表相关语句统一归为ALTER权限。
- **Spark2.4.x**：ALTER根据SQL语句细分为以下权限：
  - ALTER_TABLE_SET_PROPERTIES,
  - ALTER_TABLE_UNSET_PROPERTIES,
  - ALTER_TABLE_RENAME,
  - ALTER_TABLE_SERDE_PROPERTIES,
  - ALTER_TABLE_SET_LOCATION,
  - ALTER_TABLE_ADD_COLUMNS,
  - ALTER_TABLE_CHANGE_COLUMN,
  - ALTER_TABLE_ADD_PARTITION,
  - ALTER_TABLE_RENAME_PARTITION,
  - ALTER_TABLE_DROP_PARTITION,
  - ALTER_TABLE_RECOVER_PARTITION

执行 function 相关语句的权限要求

- **Spark3.3.1**：执行以下FUNCTION相关语句时还需要新增DESCRIBE_FUNCTION权限。
  - CREATE FUNCTION
  - DROP FUNCTION
  - USE FUNCTION

  了解FUNCTION相关操作语法请参考**创建函数**。
- **Spark2.4.x**：不涉及。

View 表对权限要求的变化

为了便于理解View表对权限要求的变化，我们给出一个简单的View表的查询示例：

- 用户A创建了表Table1。
- 用户B基于Table1创建了视图View1。
- 赋予用户C Table1的查询表权限后，用户C查询View失败。

不同版本的Spark引擎对View表的权限要求不同：

- **Spark2.4.x**：用户C具备View查询权限，且用户B具备Table1的查询权限。

  对权限的要求如下：
  - 用户B具备的权限：View1的管理员权限、Table1的查询权限（当前缺失）。
  - 用户C具备的权限：Table1的查询表权限。

  针对该场景请补充用户B对Table1的查询表权限后，用户C重试查询View1。
- **Spark 3.3.x**：用户C具备View查询权限，且用户C具备Table1的查询权限。

  对权限的要求如下：
  - 用户C具备的权限：Table1的查询表权限。View1的查询权限（当前缺失）。

  针对该场景请补充用户C对View1的查询权限后，用户C重试查询View1。

DLI 自定义策略修改示例

以下为自定义策略仅为修改示例，权限内容的差异点参考下述内容，按需修改具体的权限策略。

- Resource中可以按需指定具体的数据库和表名称。如对所有数据库进行修改可以删除Resource片段。
- Action中如果为只读操作可以删除“dli:table:alter”。

了解更多**DLI自定义策略**。

```
{
   "Version": "1.1",
   "Statement": [
      {
         "Effect": "Allow",
         "Action": [
            "dli:table:showPartitions",
      "dli:database:describeFunction",
            "dli:database:displayDatabase",
            "dli:database:displayAllTables",
      "dli:table:alter"
         ],
         "Resource": [
            "dli:*:*:database:databases.dbname",
      "dli:*:*:table:databases.dbname.tables.tblName"
         ]
      }
   ]
}
```