

# StreamSets Data Collector 5.7.1 : Dockerの展開とWebSocketパイプラインの作成

本ガイドでは、StreamSets Data Collector 5.7.1をDockerコンテナに展開する手順、およびWebSocketに接続して受信したデータをローカルに保存するパイプラインの作成方法を説明します。

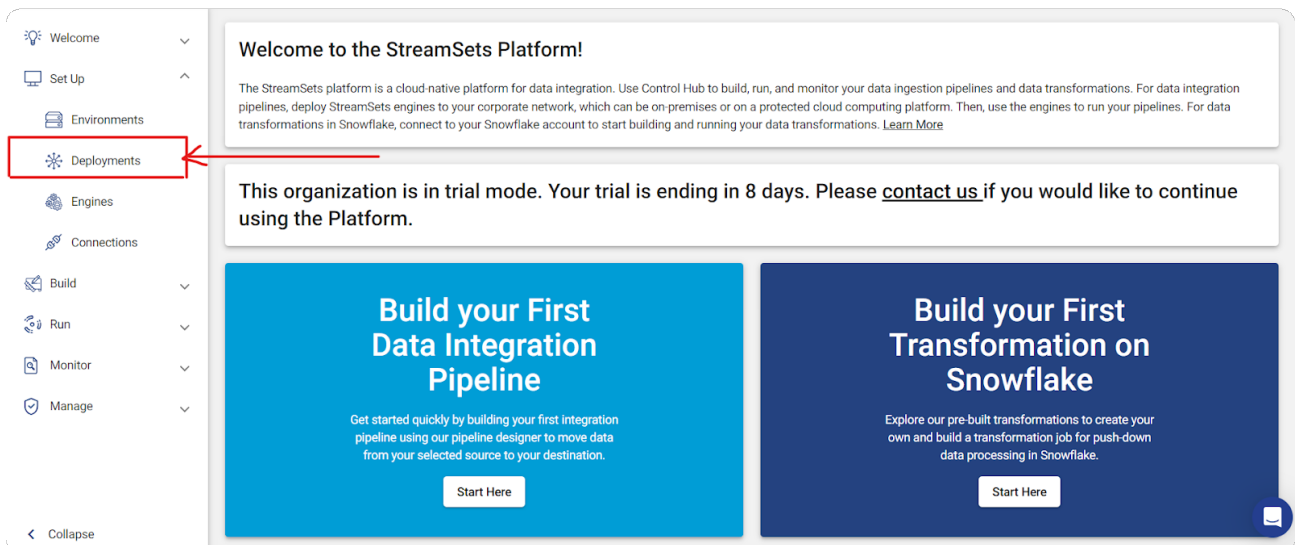
## 前提条件：

- お使いのマシンにDockerがインストールされていること（[Docker](#)をダウンロードしてインストールしてください）。
- StreamSetsのアカウント。

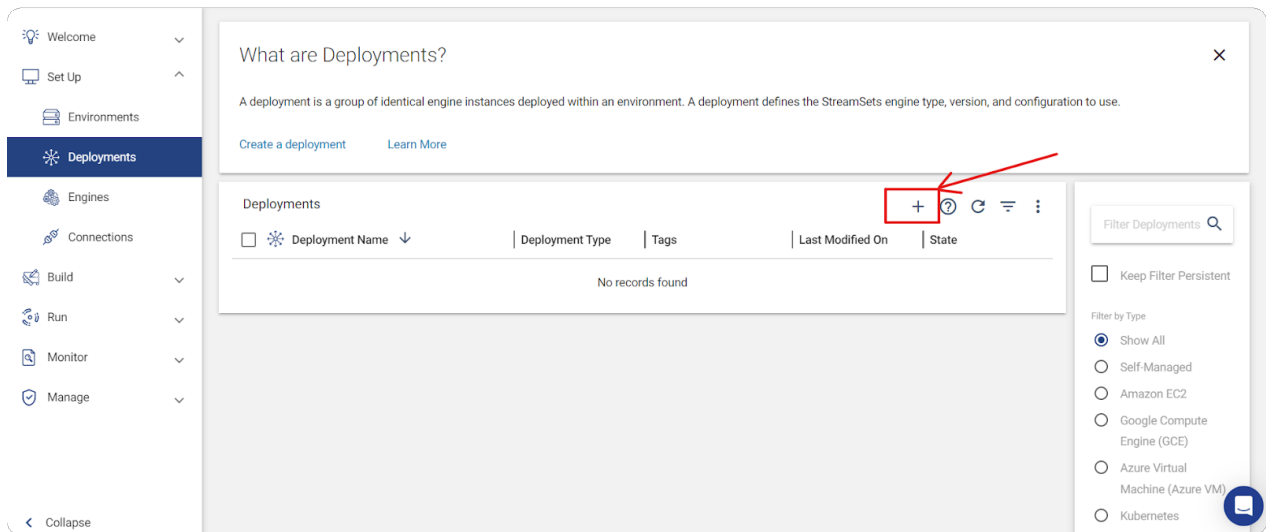
## StreamSets Data Collectorの展開

### ステップ1：Data CollectorのDeployment設定

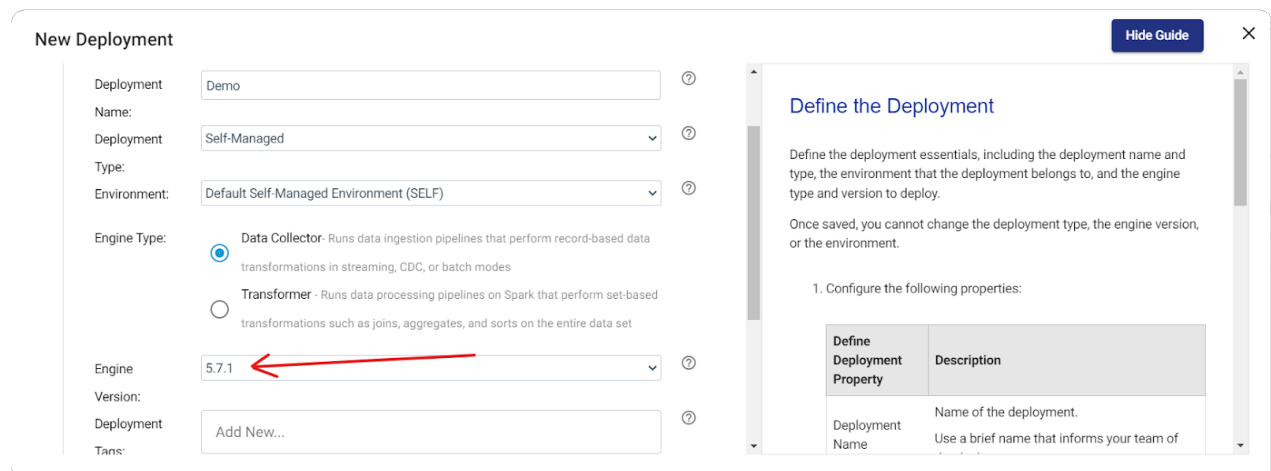
- ログイン後、サイドバーで「Deployment」を選択します。



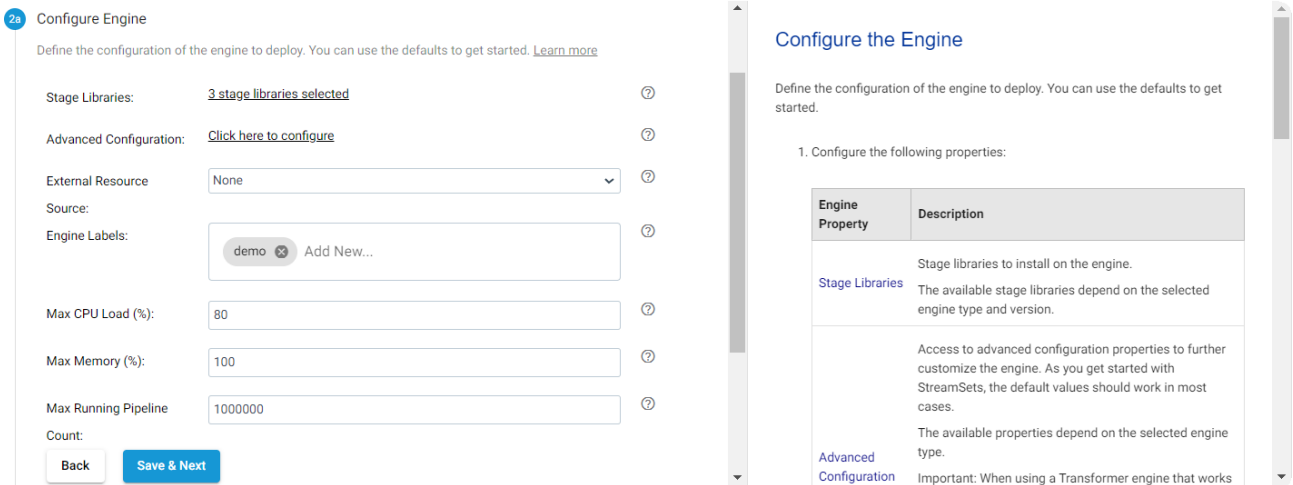
- 以下のように「+」をクリックして新しい展開（Deployment）を開始します。



- 「Engine」で現在の安定版リリースであるバージョン 5.7.1 を選択し、ご使用の要件に従って定義された展開を完了します。「Save & Next」ボタンをクリックします。



- エンジンの設定をお使いの仕様に合わせ、「Save & Next」ボタンを選択します。



**Configure Engine**

Define the configuration of the engine to deploy. You can use the defaults to get started. [Learn more](#)

Stage Libraries: **3 stage libraries selected** ⓘ

Advanced Configuration: [Click here to configure](#) ⓘ

External Resource Source: None ⓘ

Engine Labels: demo ⓘ Add New...

Max CPU Load (%): 80 ⓘ

Max Memory (%): 100 ⓘ

Max Running Pipeline Count: 1000000 ⓘ

**Back** **Save & Next**

---

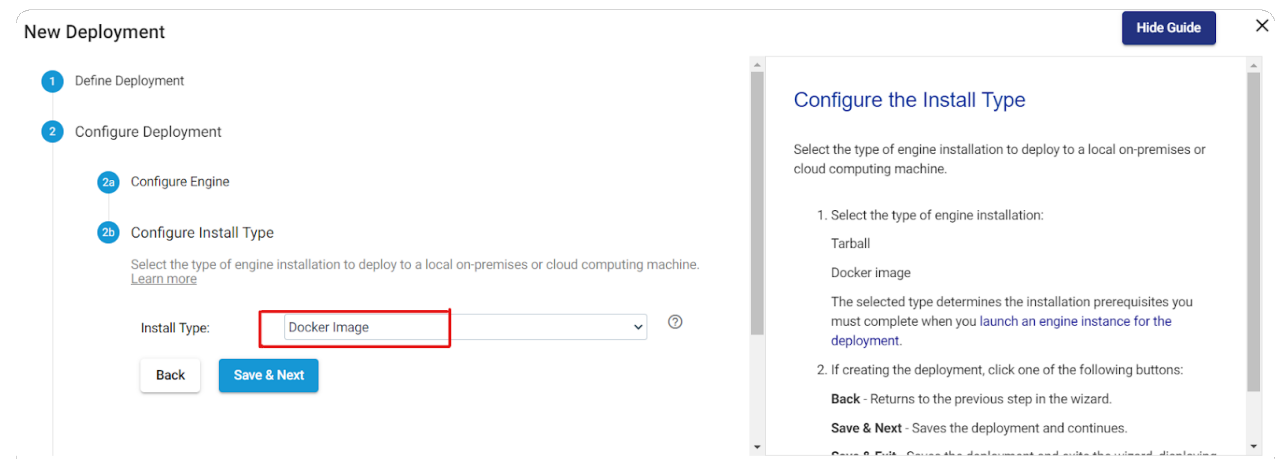
**Configure the Engine**

Define the configuration of the engine to deploy. You can use the defaults to get started.

1. Configure the following properties:

Engine Property	Description
Stage Libraries	Stage libraries to install on the engine. The available stage libraries depend on the selected engine type and version.
Advanced Configuration	Access to advanced configuration properties to further customize the engine. As you get started with StreamSets, the default values should work in most cases. The available properties depend on the selected engine type. Important: When using a Transformer engine that works

- インストールの種類として「Docker Image」を選択し、「Save & Next」ボタンをクリックします。



**New Deployment** **Hide Guide** ✕

1 Define Deployment

2 Configure Deployment

2a Configure Engine

2b **Configure Install Type**

Select the type of engine installation to deploy to a local on-premises or cloud computing machine. [Learn more](#)

Install Type: Docker Image ⓘ

**Back** **Save & Next**

---

**Configure the Install Type**

Select the type of engine installation to deploy to a local on-premises or cloud computing machine.

1. Select the type of engine installation:

- Tarball
- Docker image

The selected type determines the installation prerequisites you must complete when you [launch an engine instance for the deployment](#).

2. If creating the deployment, click one of the following buttons:

- Back** - Returns to the previous step in the wizard.
- Save & Next** - Saves the deployment and continues.
- Save & Exit** - Saves the deployment and exits the wizard. (partially visible)

- 展開の共有設定をカスタマイズして他のユーザーやグループにアクセスを許可します。「Save & Next」ボタンをクリックします。

#### 4 Review & Launch

To install and launch an engine instance, first set up a machine that meets the [minimum system requirements](#). Verify that Docker is running, select how to run the engine, then copy and run the generated command on the machine. [Learn more](#)

Run engine in foreground <sup>i</sup>

Run engine in background <sup>i</sup>

```
docker run -d -e http_proxy=-e https_proxy=-e
STREAMSETS_DEPLOYMENT_SCH_URL=https://eu01.hub.streamsets.com -e
STREAMSETS_DEPLOYMENT_ID=39dfa816-b6d5-455e-8032-a4ed25902be7:ec39590a-a34b-11ee-b630-
8b127bb30db7 -e
STREAMSETS_DEPLOYMENT_TOKEN=[REDACTED]
[REDACTED]
[REDACTED]
[REDACTED] -e ENGINE_SHUTDOWN_TIMEOUT=10 streamsets/datacollector:5.7.1
```

Check Engine Status after running the script

- 「Start & Generate Install Script」ボタンをクリックします。

#### New Deployment

##### 4 Review & Launch

Successfully created the deployment 'Demo.' Start the deployment to generate an install script to launch Data Collector.

Exit

Start & Generate Install Script

#### Share the Deployment

By default, the deployment can only be seen by you. Share the deployment with other users and groups to grant them access to it.

- In the **Select Users and Groups** field, type a user email address or a group name.
- Select users or groups from the list, and then click **Add**.  
The added users and groups display in the **User / Group** table.
- Modify permissions as needed. By default, each added user or group is granted the following permissions:

**Read** - View the details of the deployment and of all engines managed by the deployment. Restart or shut down individual engines managed by the deployment in the Engines view.

**Write** - Edit, start, stop, and delete the deployment. Delete engines



- Dockerが起動していることを確認してから、以下のコマンドをコピーしてください。このコマンドをwindows/Ubuntu/macのターミナルに貼り付けると、エンジンが起動します。

#### 4 Review & Launch

To install and launch an engine instance, first set up a machine that meets the [minimum system requirements](#). Verify that Docker is running, select how to run the engine, then copy and run the generated command on the machine. [Learn more](#)

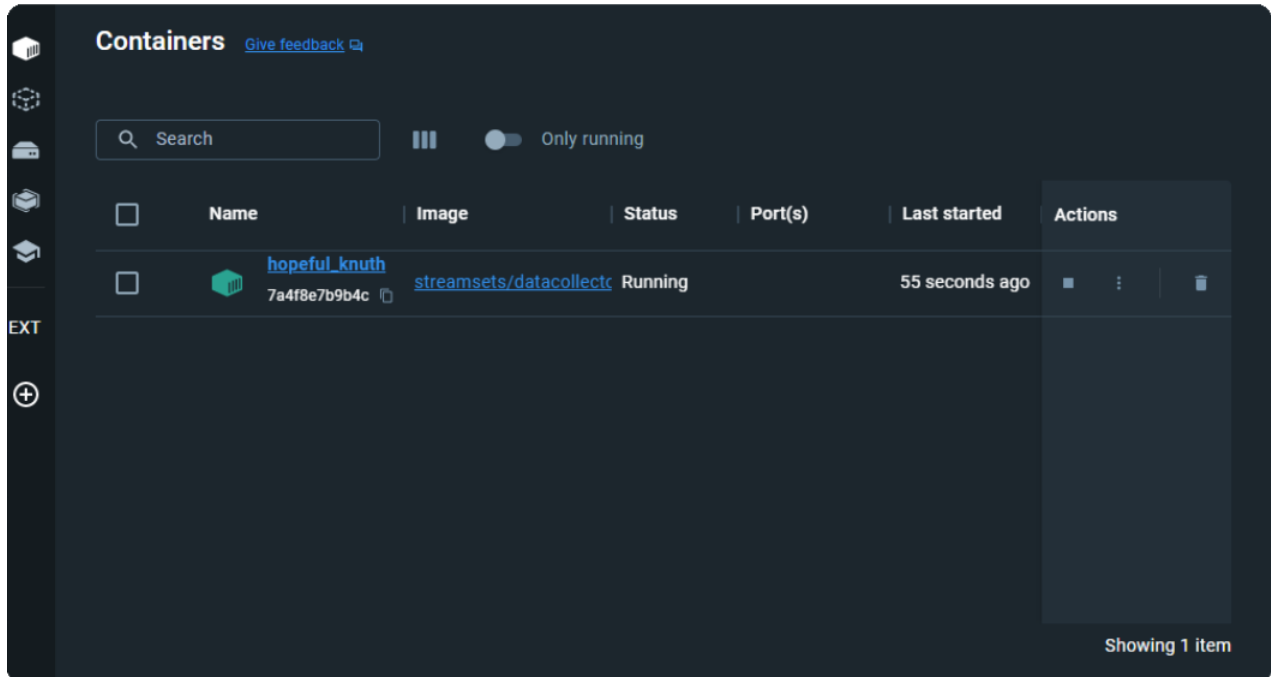
- Run engine in foreground ⓘ
- Run engine in background ⓘ

```
docker run -d -e http_proxy= -e https_proxy= -e
STREAMSETS_DEPLOYMENT_SCH_URL=https://eu01.hub.streamsets.com -e
STREAMSETS_DEPLOYMENT_ID=39dfa816-b6d5-455e-8032-a4ed25902be7:ec39590a-a34b-11ee-b630-
8b127bb30db7 -e
STREAMSETS_DEPLOYMENT_TOKEN=
-e ENGINE_SHUTDOWN_TIMEOUT=10 streamsets/datacollector:5.7.1
```



Check Engine Status after running the script

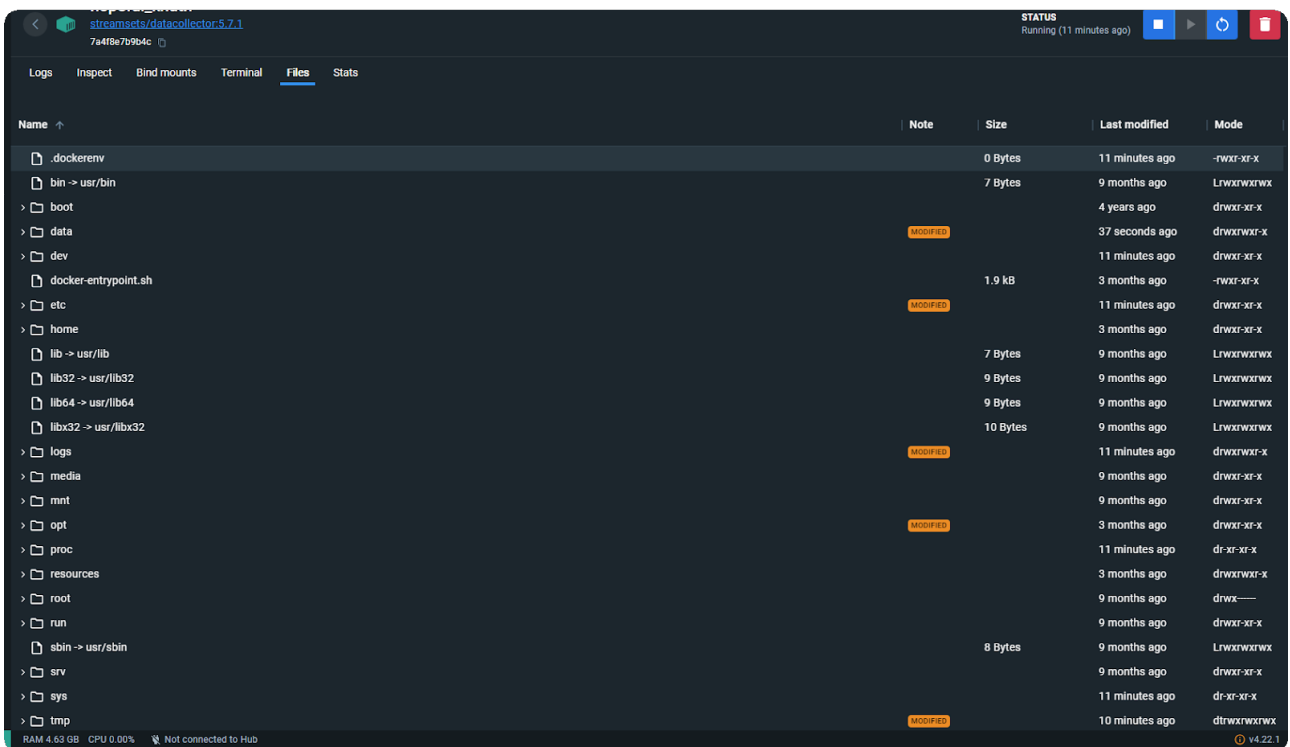
- コンテナがアクティブになっていることを確認します。以下のスクリーンショットの通り、Docker Desktop内で実行中のコンテナを確認してください。



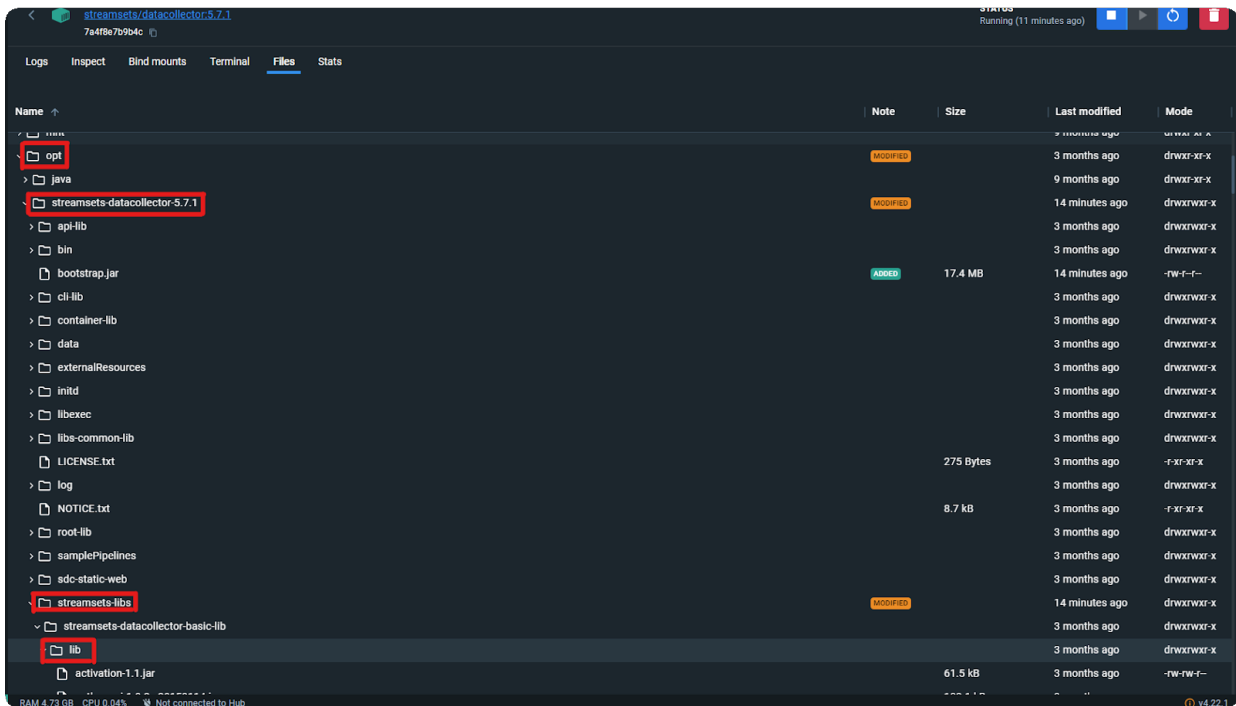
## ステップ2： Data Collectorの詳細設定

WhoisXML APIのWebSocketを活用するために、データコレクターの設定をカスタマイズしてください。

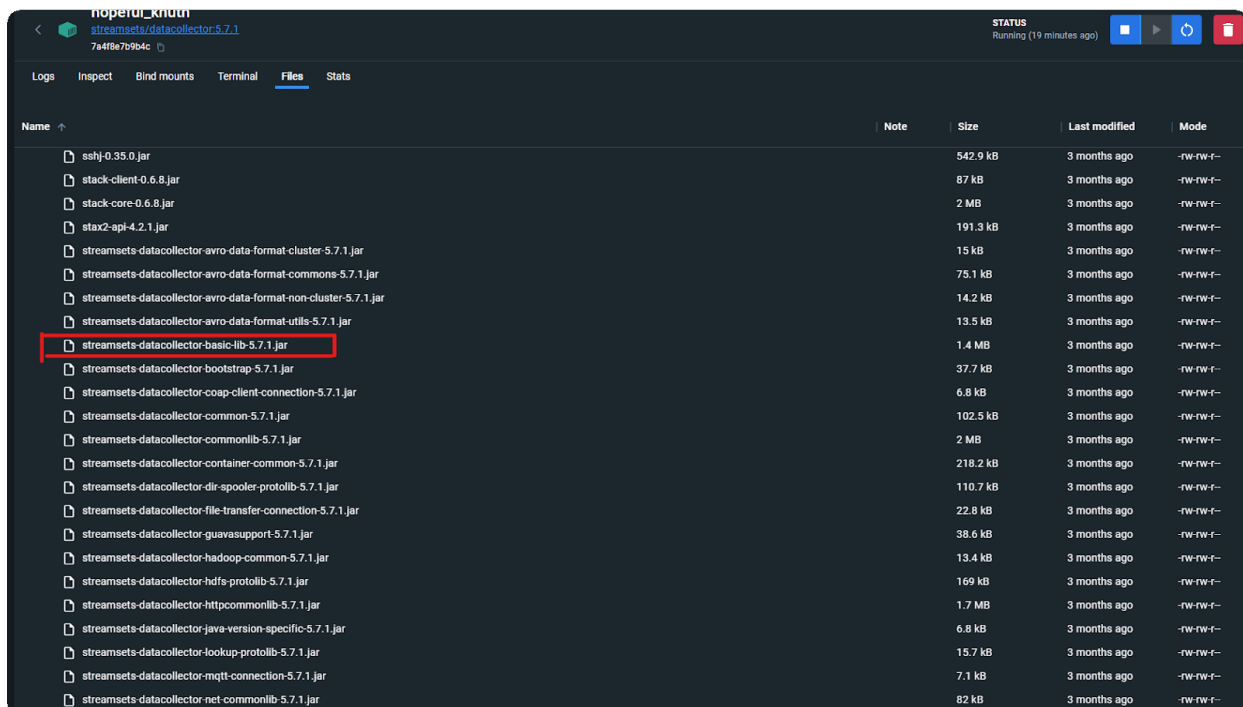
- ビルドされたjarファイルは[こちら](#)からダウンロードできます。ダウンロード後、Dockerコンテナ内の既存のファイルを新しく取得したファイルで置き換えます。ファイルのシームレスな置き換えには、Docker Desktopが効率的で便利です。



- ディレクトリ `/opt/streamsets-datacollector-5.7.1/streamsets-libs/streamsets-datacollector-basic-lib/lib` に移動します。



- このディレクトリに、「streamsets-datacollector-basic-lib-5.7.1.jar」というjarファイルがあるはずですが。



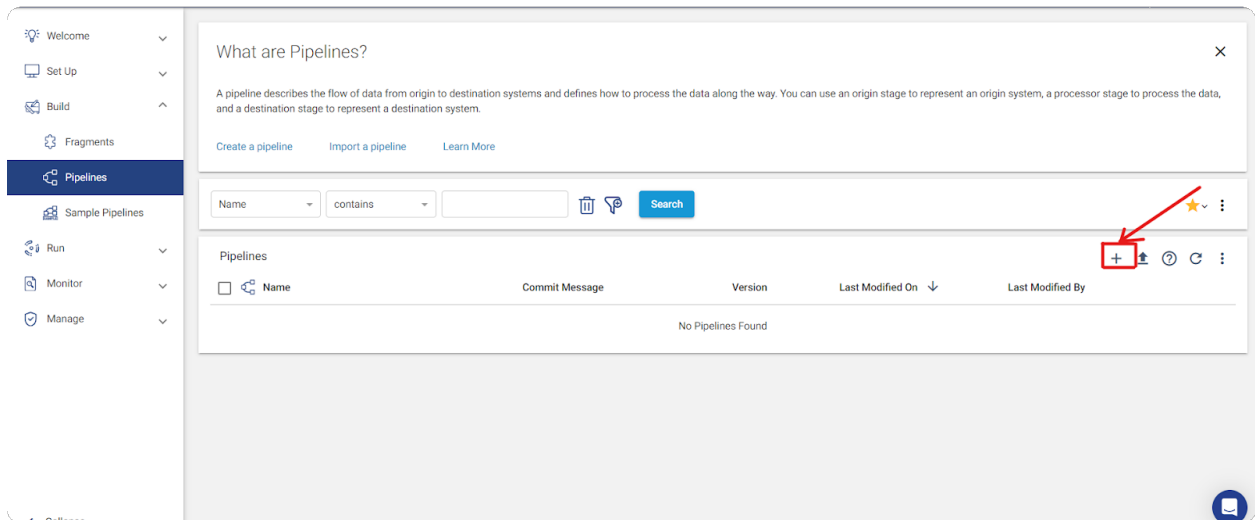
- 既存のファイルをダウンロードしたファイルで置き換えます。または、ダウンロードしたファイルをこの場所にドラッグすれば、簡単に直接置き換えることができます。
- Data Collector/Containerを再起動します。



## パイプラインの作成

### ステップ3：パイプラインのセットアップ

- StreamSets UIでサイドバーから「Build」を選択し、次に「Pipelines」を選択します。以下のように「+」ボタンをクリックしてパイプラインを開始します。



- 新しいパイプラインをお使いの仕様に合わせてカスタマイズし、「Next」ボタンをクリックして進みます。

#### New Pipeline

##### 1 Define Pipeline

Define the pipeline name, the type of engine for the pipeline, and whether to start with a blank canvas or with a sample pipeline. [Learn more](#)

Name:

Description:

Engine Type:

- Data Collector - Runs data ingestion pipelines that perform record-based data transformations in streaming, CDC, or batch modes
- Transformer - Runs data processing pipelines on Spark that perform set-based transformations such as joins, aggregates, and sorts on the entire data set
- Transformer for Snowflake - Runs data processing pipelines on Snowflake

Start with:

- Blank Pipeline
- Sample Pipeline

Cancel

Next

Hide Guide

#### Define the Pipeline

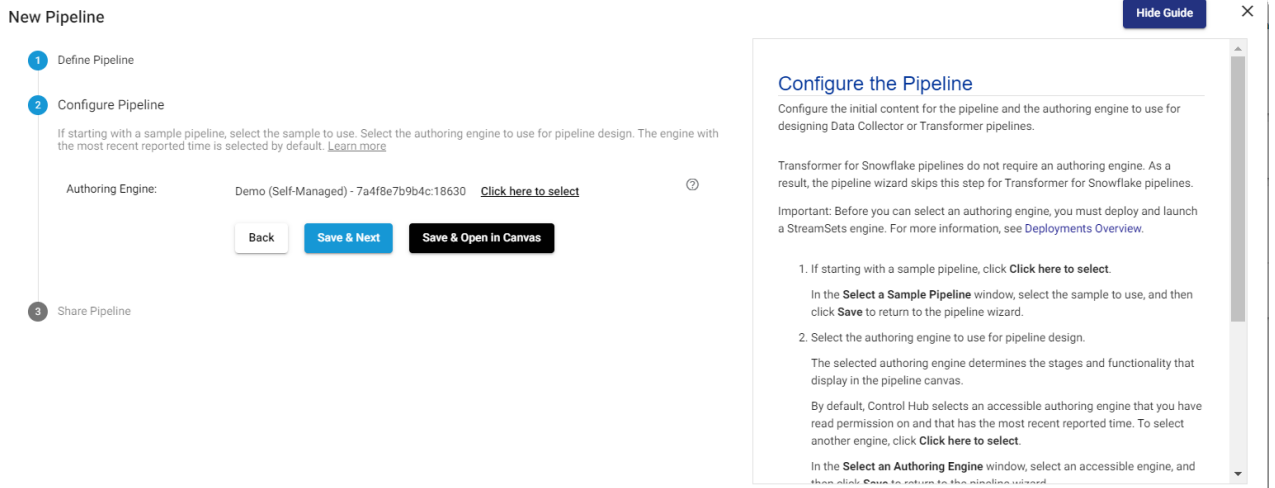
Define the pipeline essentials, including the pipeline name, the type of engine for the pipeline, and how to start building the pipeline.

Important: Before you can define a Data Collector or Transformer pipeline, you must deploy and launch an engine. For more information, see [Deployments Overview](#).

1. Enter the following information to define the pipeline:

Property	Description
Name	Name of the pipeline. Use a brief name that informs your team of the pipeline use case.
Description	Optional description. Use the description to add additional details about the pipeline use case.
	Type of engine for the pipeline. Select the engine type to use for your pipeline use case:

- パイプラインの設定を調整して指定のデータコレクタを選択し、「Save & Open in Canvas」ボタンをクリックします。



New Pipeline

1 Define Pipeline

2 Configure Pipeline

If starting with a sample pipeline, select the sample to use. Select the authoring engine to use for pipeline design. The engine with the most recent reported time is selected by default. [Learn more](#)

Authoring Engine: Demo (Self-Managed) - 7a4f8e7b9b4c:18630 [Click here to select](#)

Back Save & Next Save & Open in Canvas

3 Share Pipeline

### Configure the Pipeline

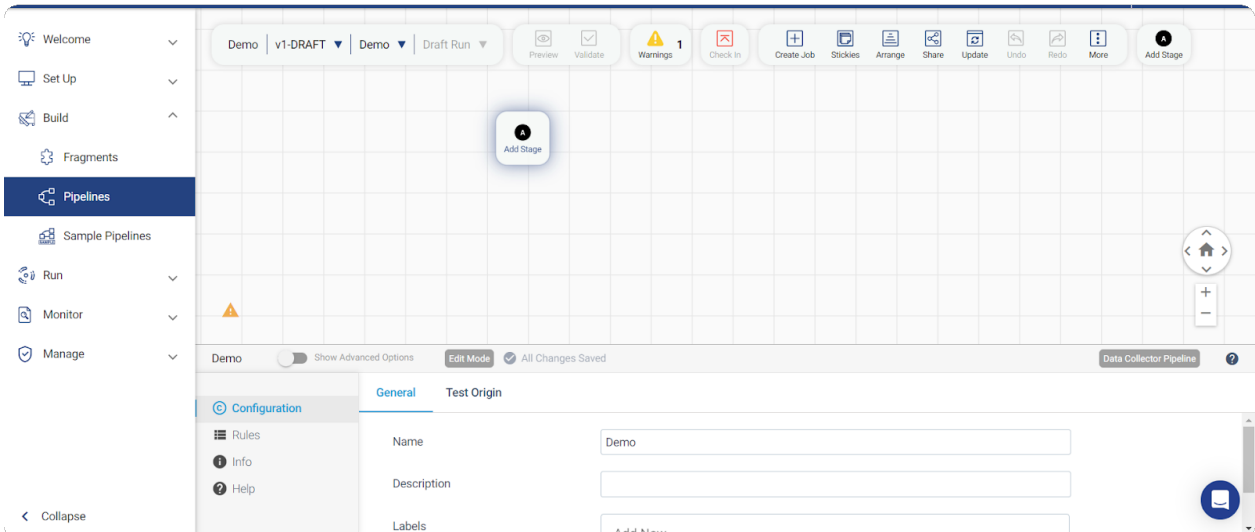
Configure the initial content for the pipeline and the authoring engine to use for designing Data Collector or Transformer pipelines.

Transformer for Snowflake pipelines do not require an authoring engine. As a result, the pipeline wizard skips this step for Transformer for Snowflake pipelines.

Important: Before you can select an authoring engine, you must deploy and launch a StreamSets engine. For more information, see [Deployments Overview](#).

1. If starting with a sample pipeline, click [Click here to select](#).  
In the **Select a Sample Pipeline** window, select the sample to use, and then click **Save** to return to the pipeline wizard.
2. Select the authoring engine to use for pipeline design.  
The selected authoring engine determines the stages and functionality that display in the pipeline canvas.  
By default, Control Hub selects an accessible authoring engine that you have read permission on and that has the most recent reported time. To select another engine, click [Click here to select](#).  
In the **Select an Authoring Engine** window, select an accessible engine, and then click **Save** to return to the pipeline wizard.

- 以下のようなユーザーインターフェース (UI) が表示されます。



Welcome

Set Up

Build

Fragments

Pipelines

Sample Pipelines

Run

Monitor

Manage

Demo | v1-DRAFT | Demo | Draft Run

Preview Validate Warnings 1 Check In Create Job Stickers Arrange Share Update Undo Redo More Add Stage

Add Stage

Demo Show Advanced Options Edit Mode All Changes Saved Data Collector Pipeline

Configuration

Rules Info Help

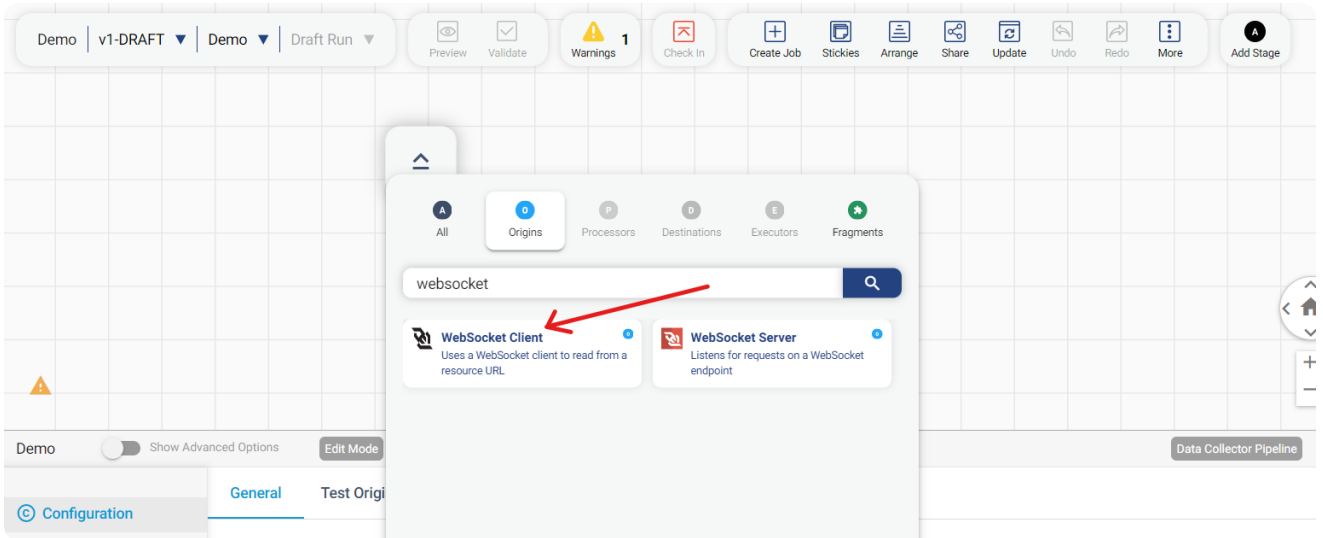
General Test Origin

Name Demo

Description

Labels Add New

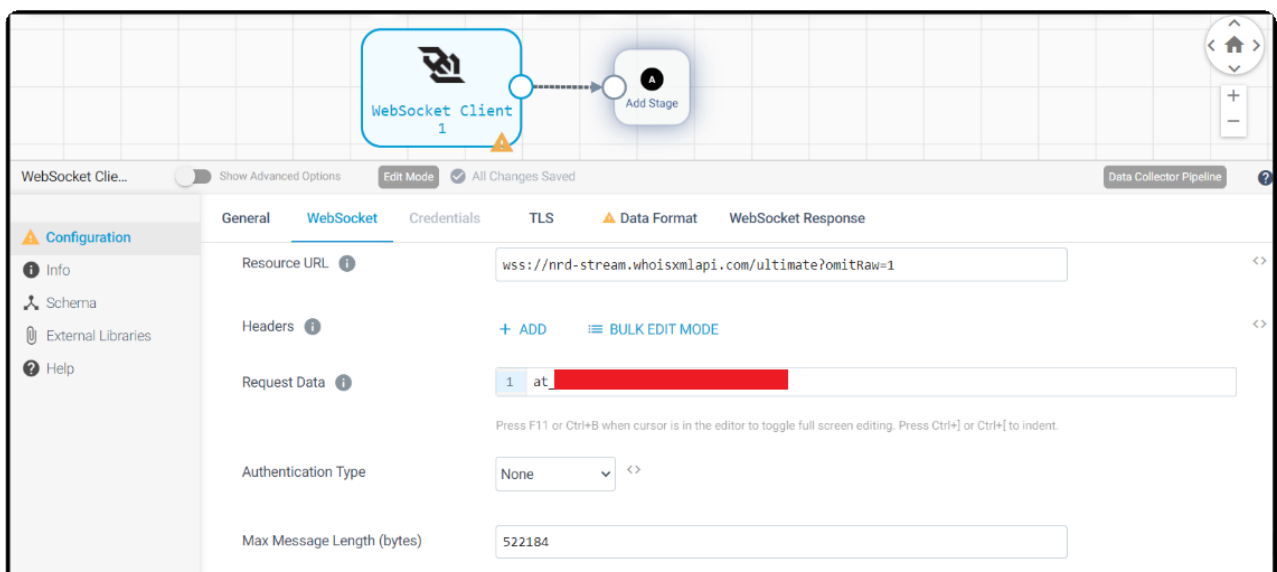
- 「Add Stage」ボタンをクリックし、「WebSocket」を検索して「WebSocket Client」を選択します。



WebSocketステージを選択し、適宜設定します：

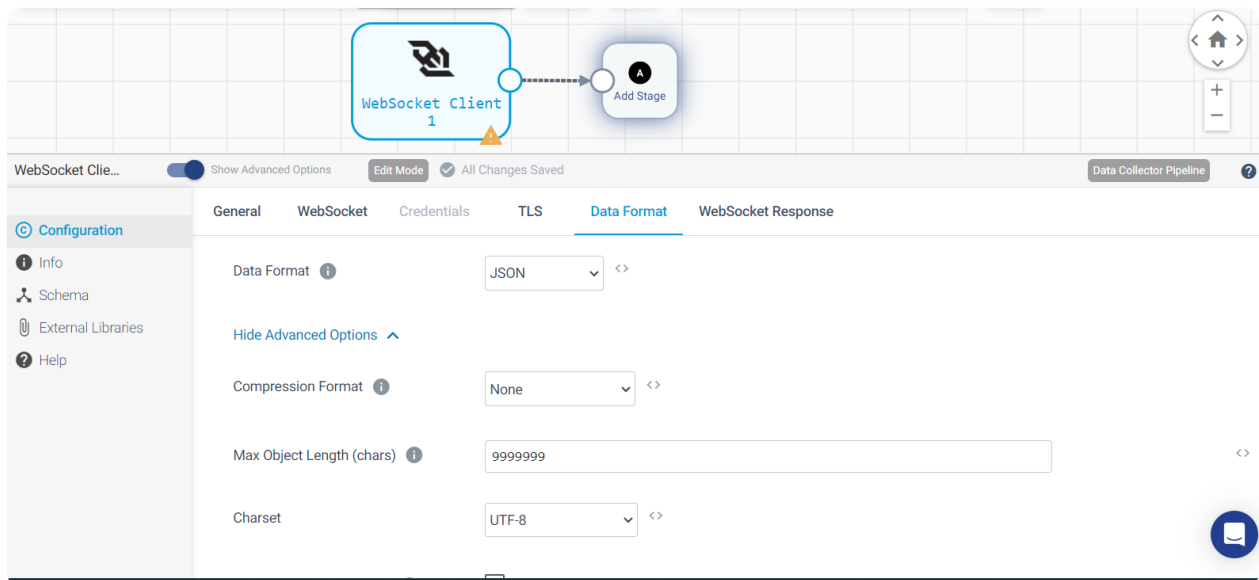
## WebSocketの設定

- Resource URLを入力
- Request Dataを入力（WHOIS APIキーが入ります）
- Max Message Length (bytes) として最小522184 を入力

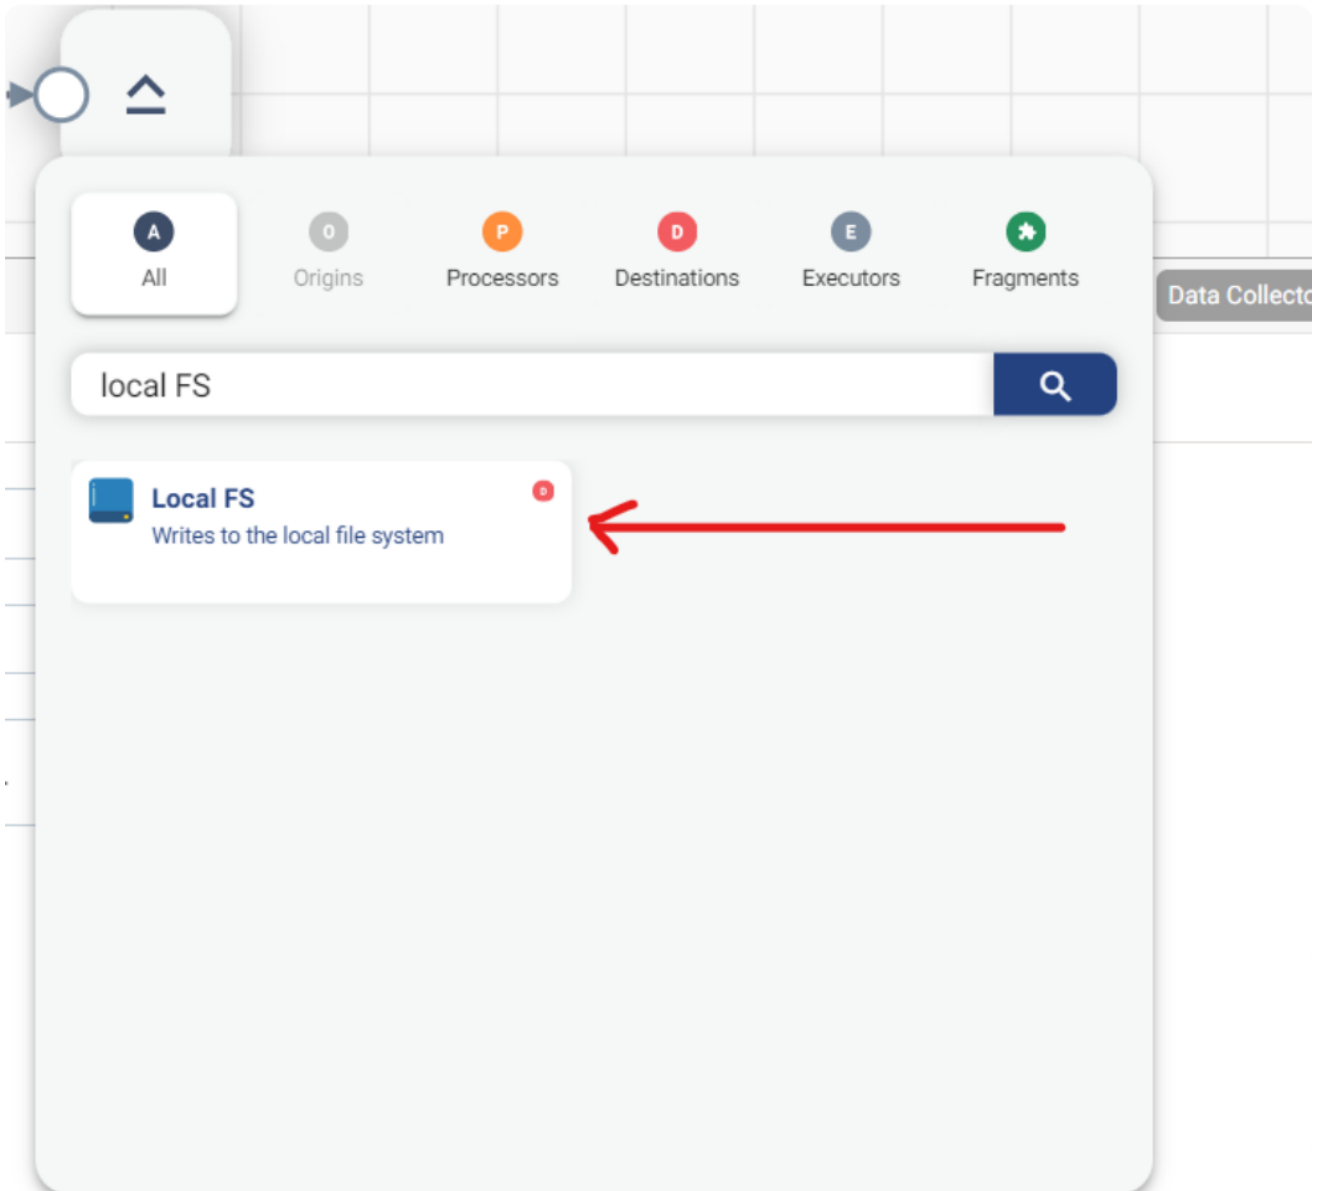


## Data Formatの設定

- Data FormatとしてJSONを選択
- Max Object Length (chars)として9999999を入力（必要に応じて変更できます）



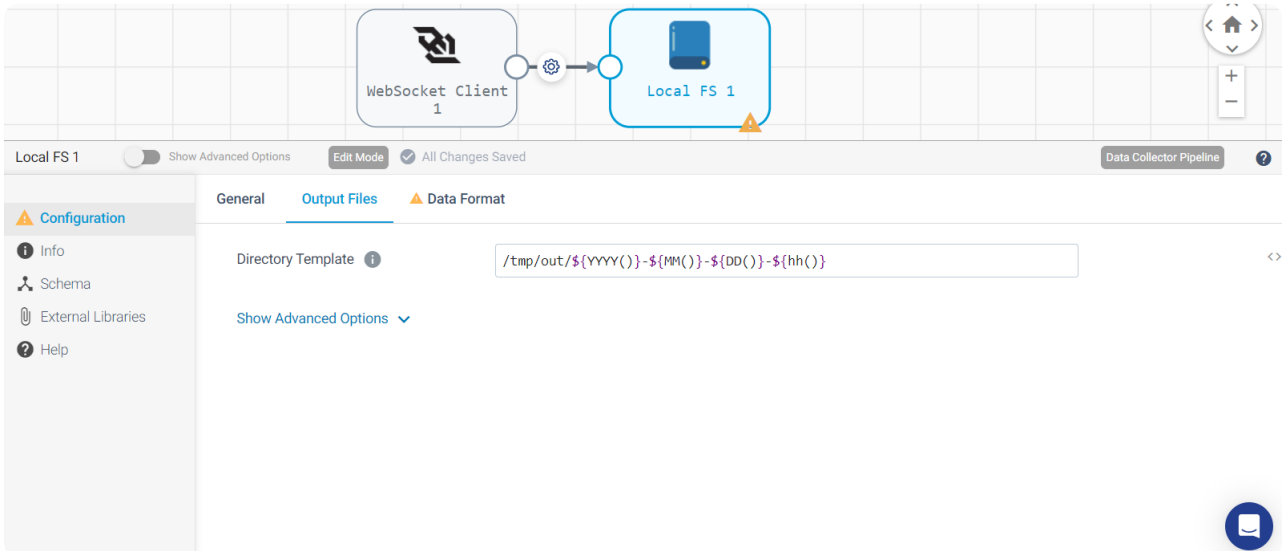
- UIの「Add Stage」ボタンでステージを追加し、「Local FS」ステージを選択します。



## Local FSの設定

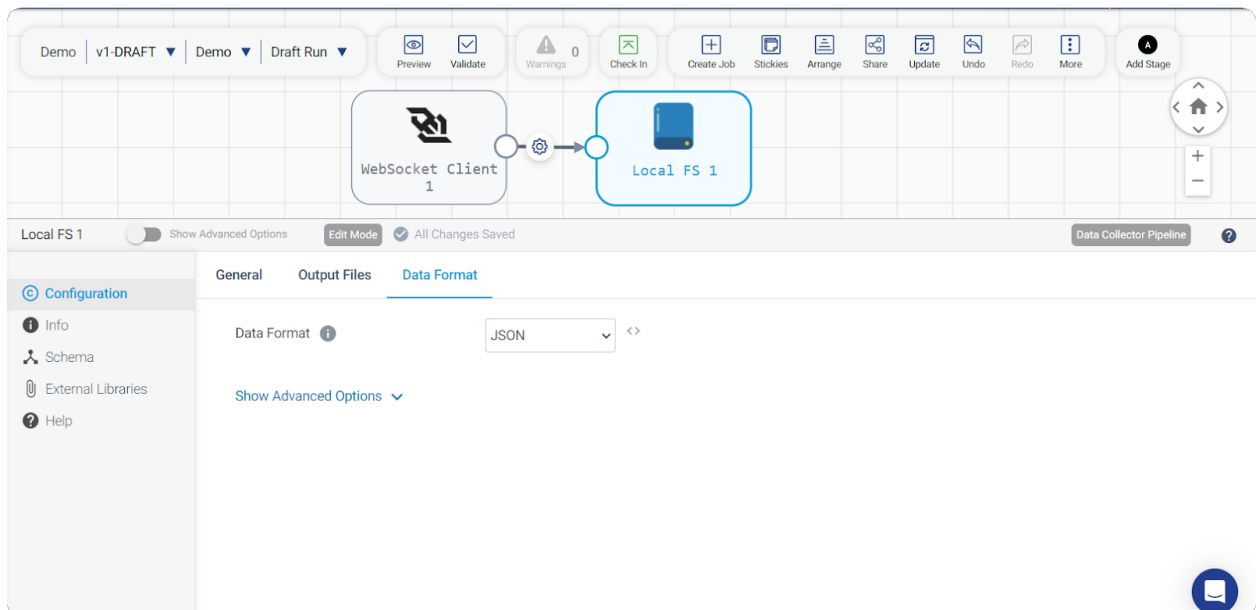
「Local FS」ステージを選択し、要件に従って設定します。

- 希望する出力ファイルの場所を「Directory Template」に入力します。



要件に応じて「Data Format」に必要な設定を入力します。

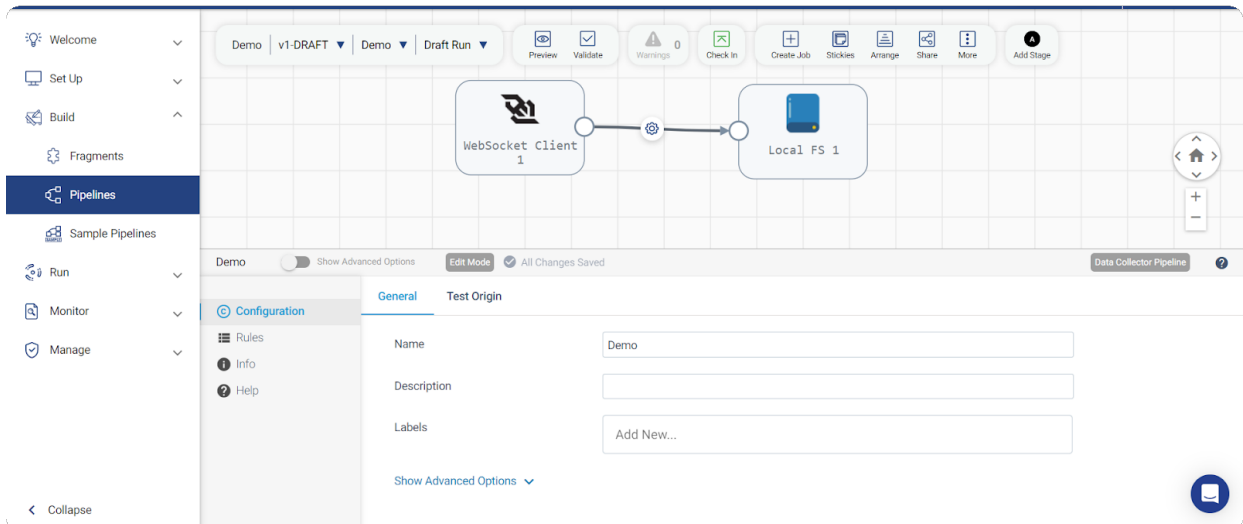
- 「Data Format」としてJSONを選択します。



設定後、「Validate」ボタンをクリックしてパイプラインを検証し、エラーを特定して修正しま

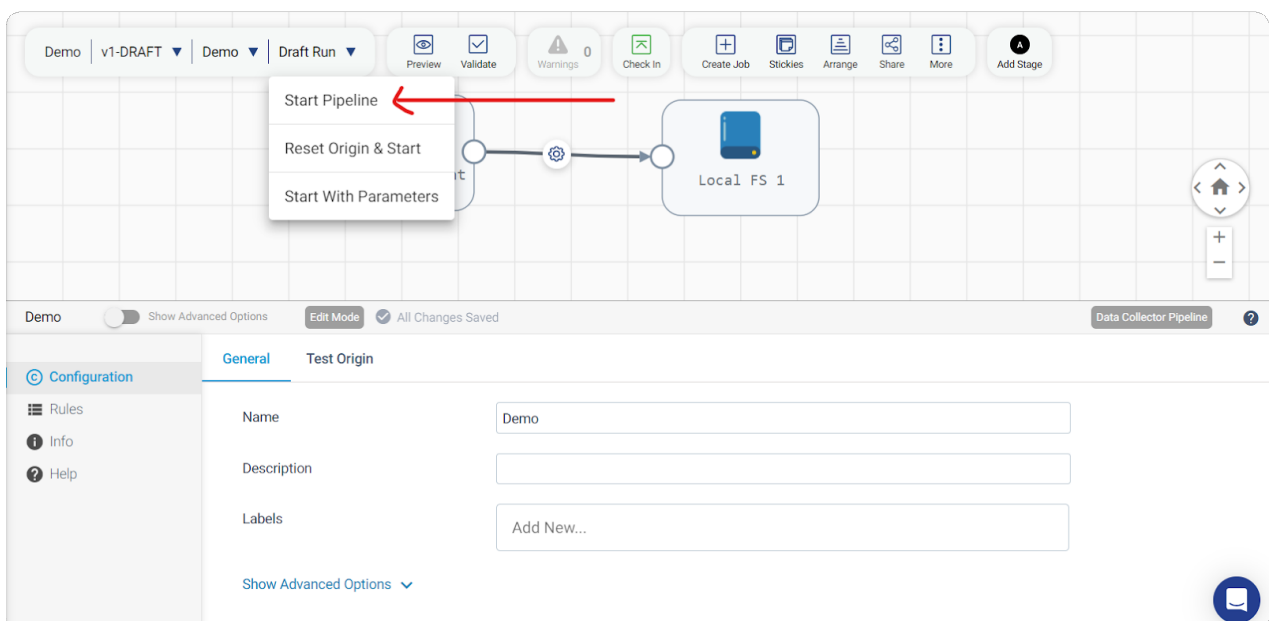
す。パイプラインの最終状態は、以下の例のようになります。

## 最終ステップ



## パイプラインの実行

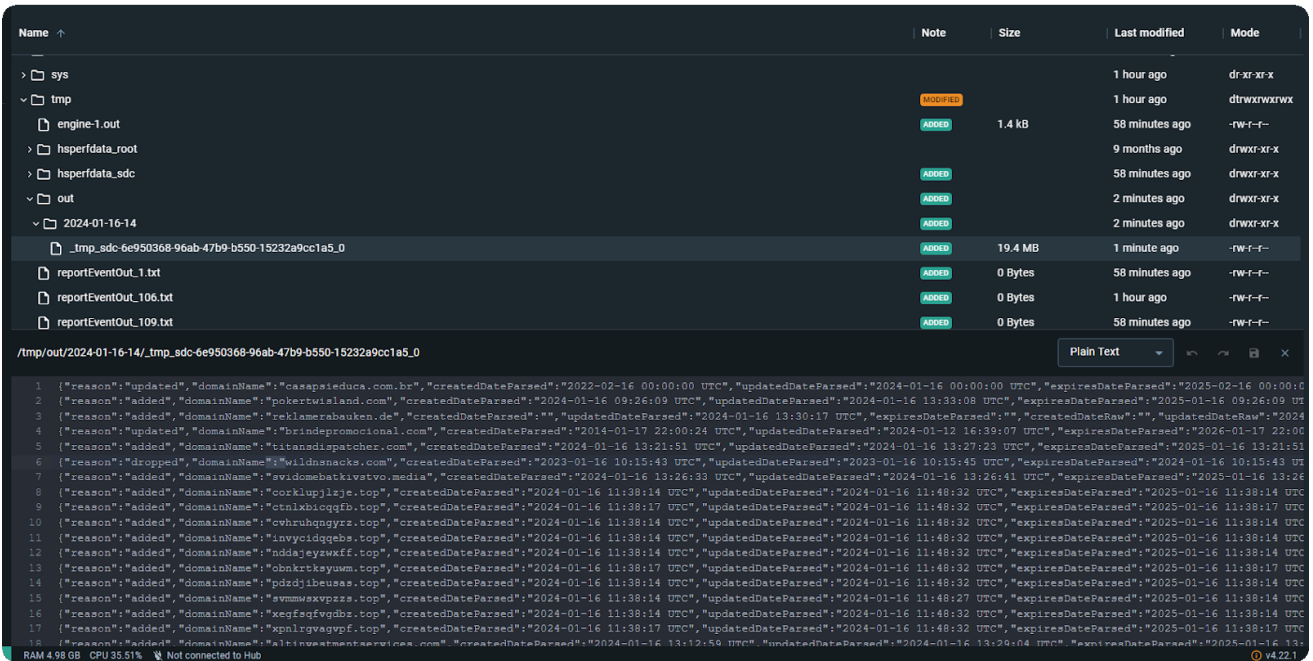
UIで「Draft Run」、「Start Pipeline」を選択してパイプラインを実行します。



上記の手順が完了した後、パイプラインを起動すると、下図のようなUIが表示されます。



Docker コンテナ内では、WebSocket から取得したデータを含むファイルが指定したディレクトリに作成されていることを確認できます。





## まとめ

本ガイドでは、**Docker**を使用して**StreamSets UI**でパイプラインをセットアップおよび実行する手順を概説しました。**WebSocket Client**の設定から**Local FS**ステージの定義に至る各ステップを踏むことで、最終的にデータ処理のパイプラインを構築できます。検証ステップはパイプラインの整合性を保証するもので、実行に成功すると、**UI**が**Docker**コンテナ内の指定されたディレクトリ内に出力ファイルを表示します。本ガイドで示した手順により、合理化されたデータ処理パイプラインの作成、設定、実行を正常に行い、効果的なデータ統合および管理を実現できます。