Asakusaソースコードリーディング #4 - Asakusa Test Driver

2011/08/26

川口 章 (@apirakun)

本日の内容

- A Brief History of Asaksa Test Driver
  - TestDriverが誕生するまで (～ver 0.1)
  - TestDriverのリアーキテクト (～ver 0.2)
  - TestDriverのこれから
- Asakusa CI on AWS
- Source Code Reading
  - TestDriver ver 0.2 API

自己紹介

- 川口 章 (@apirakun)
  - Asakusa Frameworkの活動
    - Asakusa Test Driverの設計/実装
    - CI環境のメンテナンス (Jenkins)
    - ソースリポジトリ管理 (GitHub)
    - ビルド・リリース管理 (Maven)
    - ドキュメントの公開 (Sphinx)
    - 開発環境・デプロイ周り (misc.)
  - 普段の仕事
    - SI:Web系の自動テストツール開発
    - 流通ミドルウェアの技術サポート

リソース

- Source Code (branch:0.2-develop)
  - https://github.com/asakusafw/asakusafw/tree/0.2-develop
    - asakusa-test-driver
    - asakusa-test-modelator
    - asakusa-test-data-provider
    - asakusa-thundergate-test-modelator
- Documents (アプリケーションのテスト)
  - http://asakusafw.s3.amazonaws.com/documents/0.2/release/ja/html/testing/index.html

「Hadoopで基幹バッチ」に耐え得るテストフレームワークとして

TestDriverが誕生するまで (～ver 0.1)

Review

Asakusa Frameworkの構成

- 各種DSLを起点とした構成

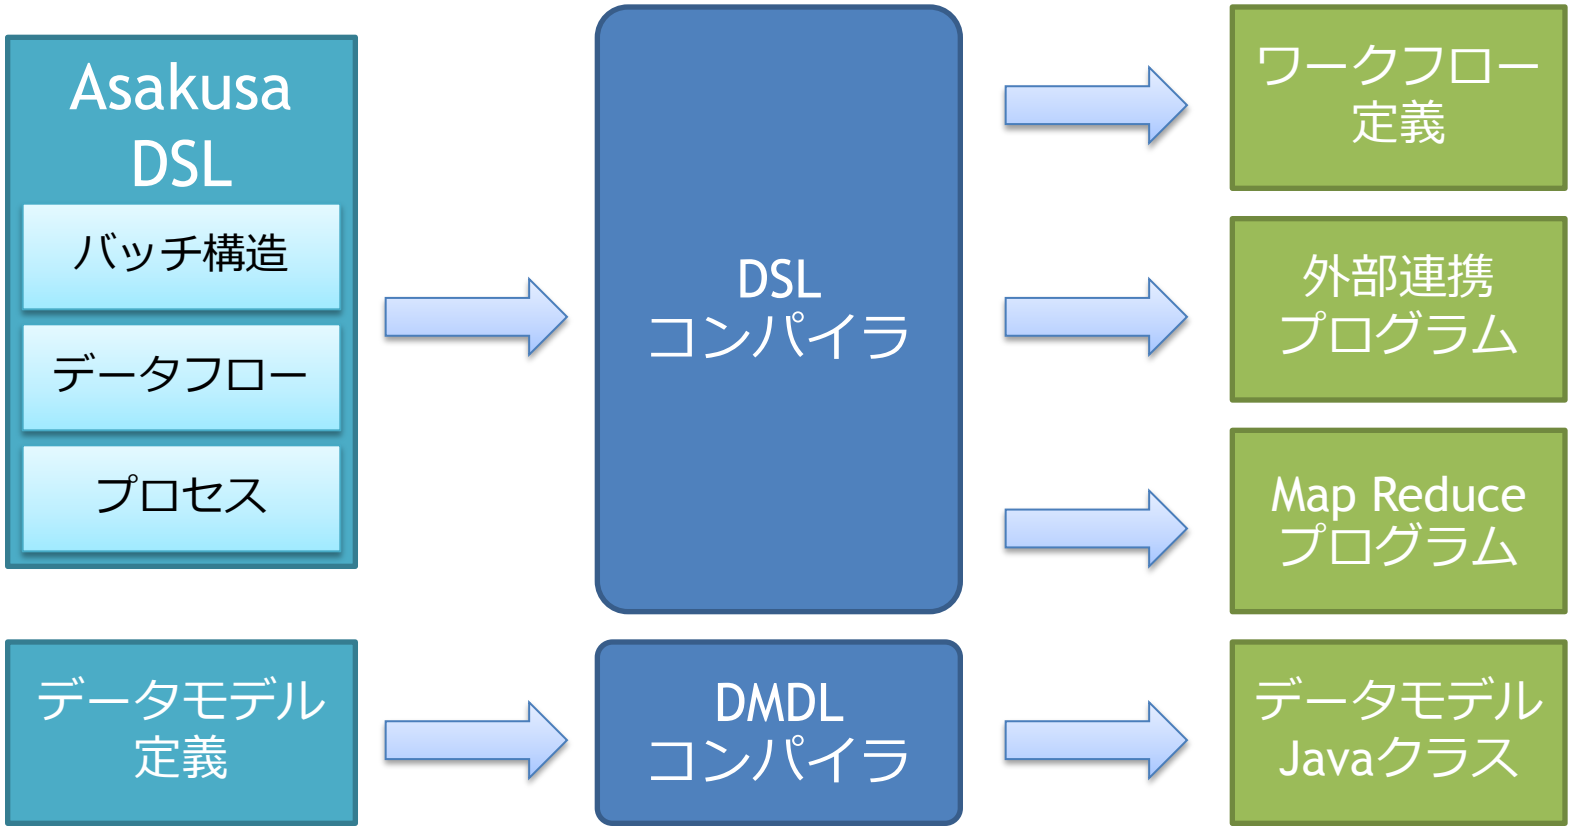

Review

各種DSLの構造

- 層ごとに書くべきことが異なる

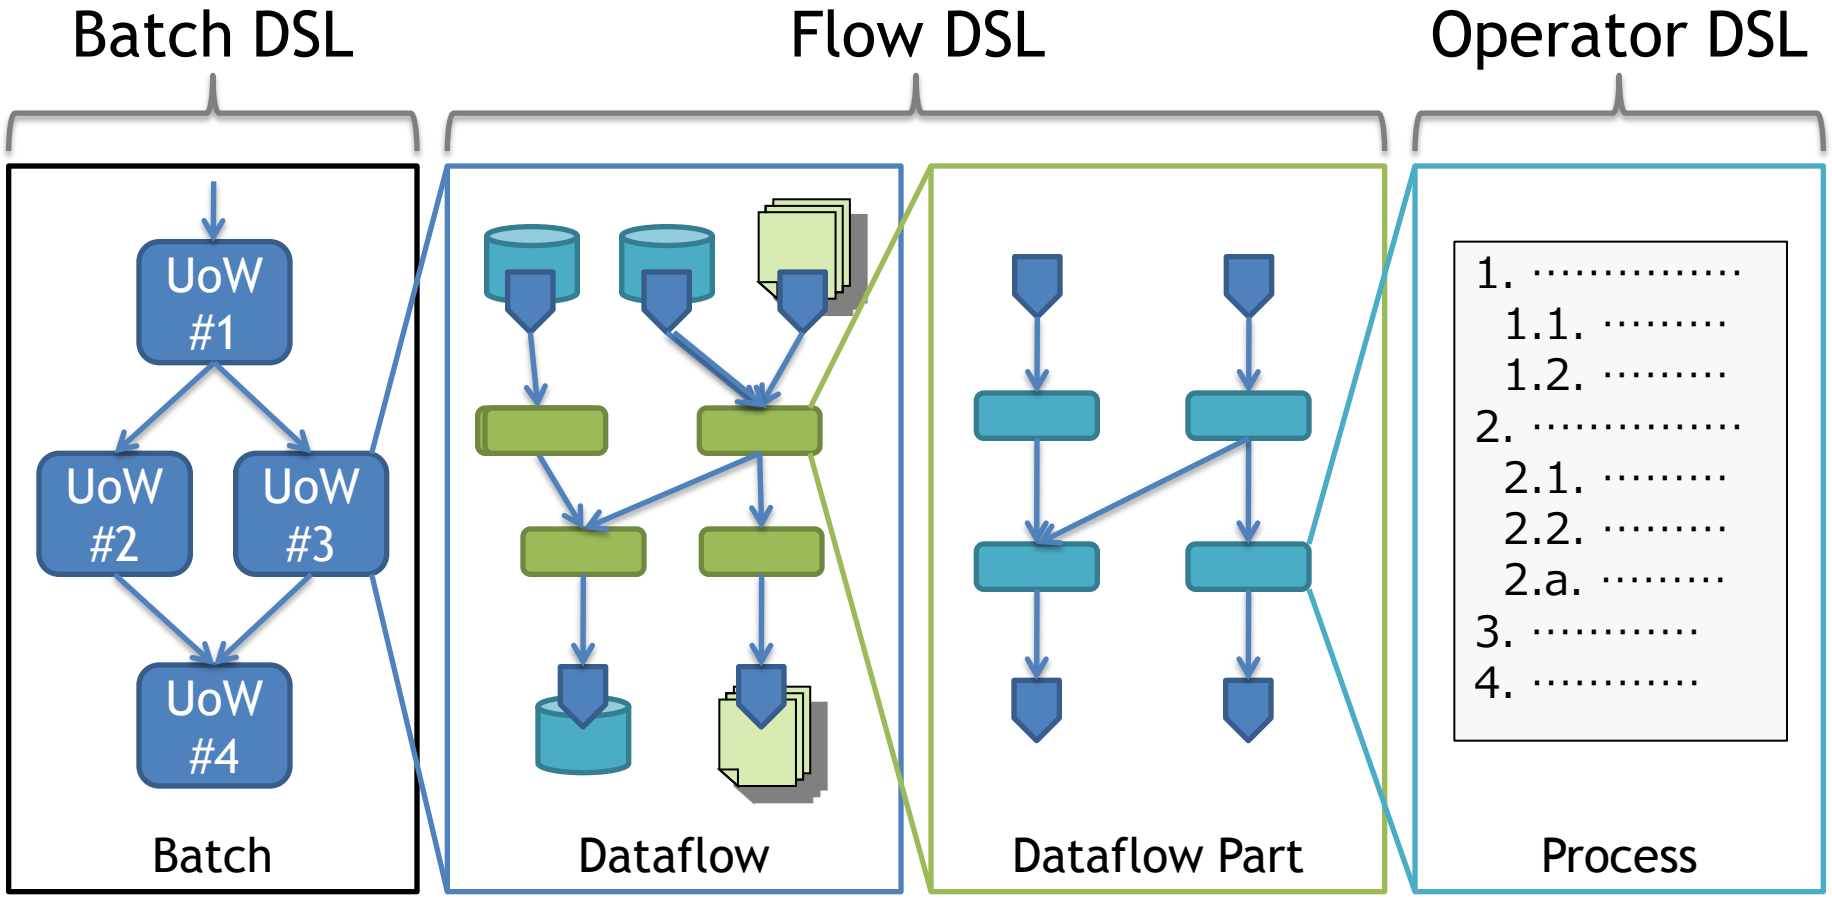

DSLに対するテスト戦略

- 各DSL毎のテスト方法を提供
  - Operator
  - FlowPart
  - JobFlow
  - Batch
- テストデータの作成方法を提供
  - データモデル定義をベースにする
  - 複雑なデータモデルに対応する

DSL毎のテスト方針 <1/2>

- Operatorのテスト
  - 通常のJavaクラスに対するテスト
  - 少数のModelに対する入力/検証
- FlowPartのテスト
  - DSLをコンパイルして生成されるMapReduce Jobに対するテスト
  - 入出力データの実体はSequenceFile
  - 多数のModelに対する入力/検証

DSL毎のテスト方針 <2/2>

- JobFlowのテスト
  - 外部インターフェース機能(ThunderGate)と連携したテスト
- Batchのテスト
  - ワークフローエンジン連携機能と連携したテスト
    - 試験的ワークフロー実行機能(experimental.sh)と連携したテスト

テストデータの作成方法 <1/2>

- Model自動生成機能との連携
  - Modelと乖離しないテストデータのTemplateを作成
- 多数の複雑なModelに対する入出力の定義
  - いろいろ議論があったがExcelで
- 緻密なテスト検証方法を提供
  - テーブル毎/カラム毎に対する検査条件の指定
  - DBの定義とは別に検査用のキーカラムを指定
  - DBUnitでやろうとすると大変なことを簡単に

テストデータの作成方法 <2/2>

- DB以外のテストデータ生成・検証
  - Hadoopのシーケンスファイル
    - テスト実装者にはデータ実体の違いを隠蔽したい

テスタビリティの追求 <1/5>

- テストが自動化出来る
  - CIに乗せることを前提とした方式検討
  - 必要な機能はなにか - 何を自動化するのか
    - テストデータの生成・セットアップ
    - バッチコンパイル・デプロイ
    - ThunderGate・HadoopJobの実行
    - CI Serverとの連携方式
  - 過剰な機能はなにか - 何を自動化しないのか
    - 迅速なフィードバックとテストの価値を天秤にかける

テスタビリティの追求 <2/5>

- 同じ方法でテスト出来る
  - 各種DSLの仕組みの違いを出来るだけ隠蔽
  - FlowPartとJobFlow のデータ入出力
    - SequencFile/DB上のテーブル
  - JobFlowとBatch のテスト対象の実行方法
    - hadoopコマンド/experimental.sh

テスタビリティの追求 <3/5>

- テスト実装を迷わせない
  - テスト用APIの設計
    - シンプルなAPI
    - 強い制約
    - ある程度の汎用性は犠牲に

テスタビリティの追求 <4/5>

- 通常のJava開発と同様にテスト出来る
  - Eclipse上でテストも書ける
  - JUnit上でテストが実行出来る

テスタビリティの追求 <5/5>

- ローカルでテストが出来る
  - 当初はあきらめていた
    - CI環境でのみ
    - 疑似分散モード前提
  - Windows上でHadoopが動作しない
    - Linux開発環境(AsakusaSDK)を提供
  - 疑似分散モードはフィードバックが遅い
    - スタンドアロンモード対応

Asakusa Test Driver (0.1)

- TestDriver(0.1)が提供するもの
  - testdriver.XXXTestDriver
    - FlowPart-/JobFlow-/Batch-
- 特徴
  - Ashigel Compiler/HadoopJob/ThunderGateの実行を隠蔽
  - ModelGeneratorから緻密なテストデータ定義が可能なテストデータのTemplate(Excel)を生成
  - 各種DSLで同じようにテスト出来るシンプルなAPI
  - テストが自動化出来る
  - スタンドアロンモードで動作

本資料ではパッケージ名の
com.asakusafw は省略

TestDriverのさらなる成長を目指して

TestDriverのリアーキテクト

TestDriver(0.1)が出来ないこと

- 汎用性がない
  - ThunderGate決め打ち:ThunderGate以外の外部連携を使った場合のテスト手段を提供出来ない
  - Excel決め打ち:Excel以外でテストデータを定義する手段を提供していない
- 0.1の実装上に拡張を行うのは困難
  - 0.1の良いところを維持しつつ、TestDriverの内部を拡張可能にするためにリファクタリング(リアーキテクト)することに

Asakusa Test Driver (0.2)

- NewAPIの提供
  - testdriver.XXXTester
    - FlowPart-/JobFlow-/Batch-
- 特徴
  - ThunderGate以外の外部連携に対応
    - ファイルインターフェース
  - Excel以外のテストデータ入出力に対応
    - デフォルトはJSONとExcelを提供
    - Excelフォーマットも0.1細かく改善(Calcも使える)
  - SPIで拡張可能
    - Ashigel Compilerに似た拡張戦略

TestDriver(0.2)のテスト実装例

- ジョブフローのテスト実装例

```
@Test
public void testExample() {
    JobFlowTester tester = new JobFlowTester(getClass());
    tester.input("shipment", Shipment.class)
        .prepare("shipment.xls#input");
    tester.input("stock", Stock.class)
        .prepare("stock.xls#input");
    tester.output("shipment", Shipment.class)
        .verify("shipment.xls#output", "shipment.xls#rule");
    tester.output("stock", Stock.class)
        .verify("stock.xls#output", "stock.xls#rule");
    tester.runTest(StockJob.class);
}
```

TestDriver(0.2)のテストデータ定義

- テストデータ定義シート例

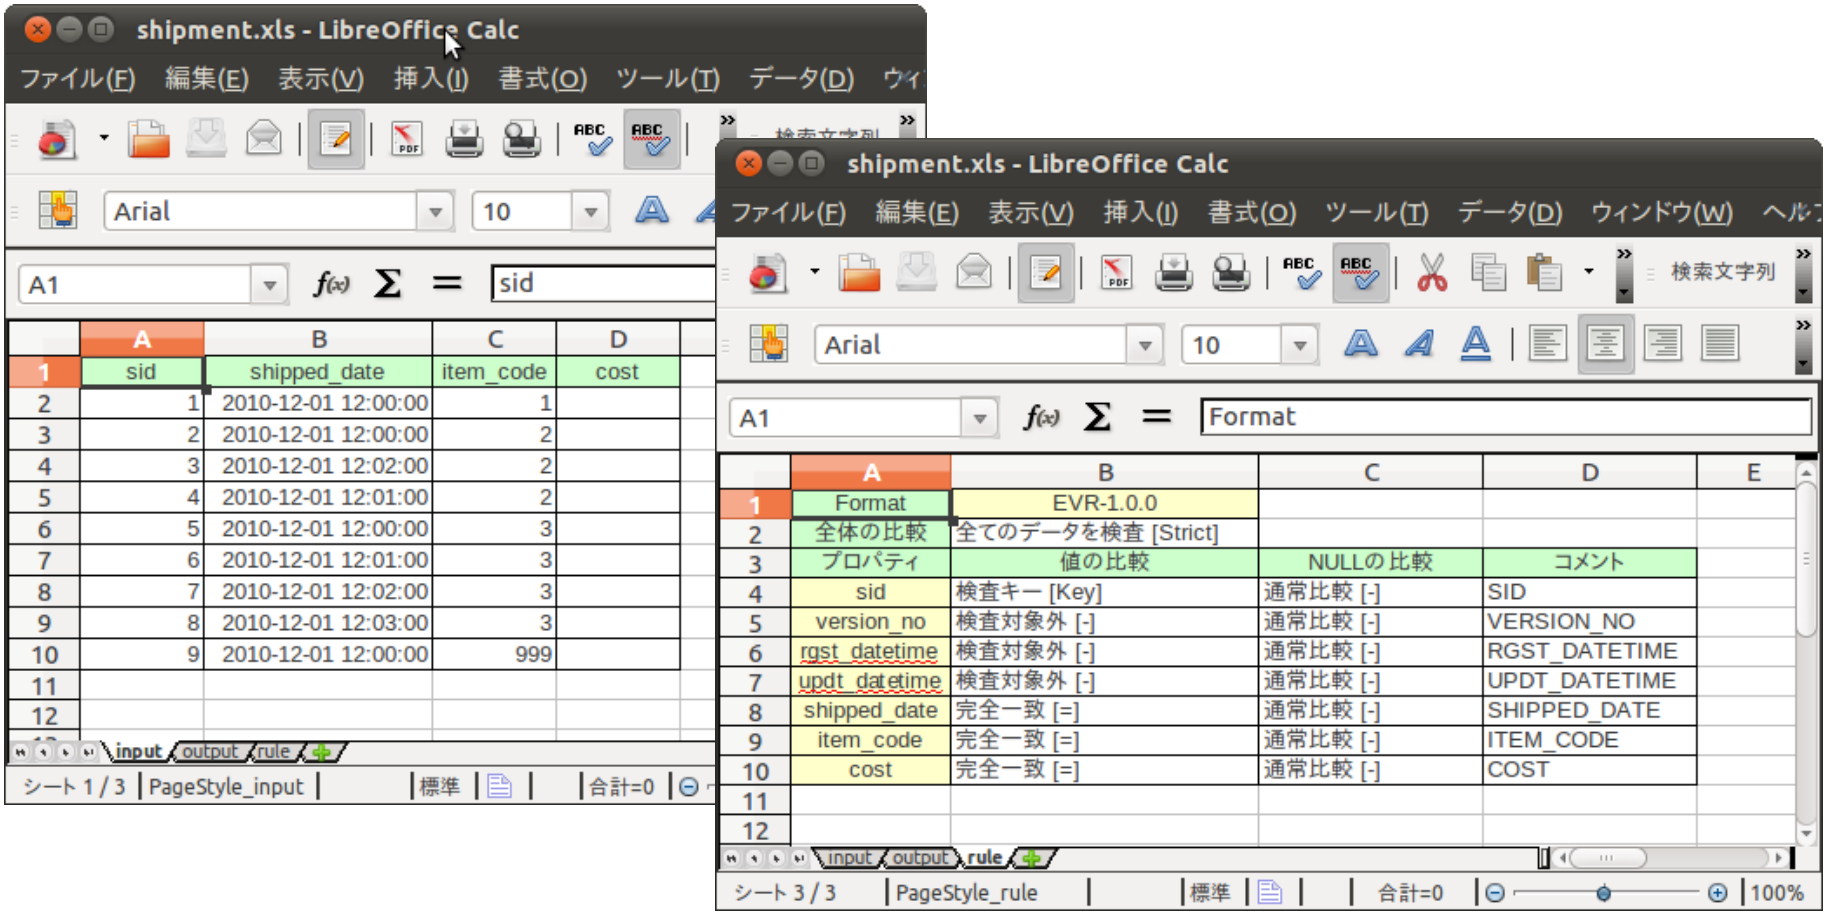

TestDriver(0.2)のアーキテクチャ概要

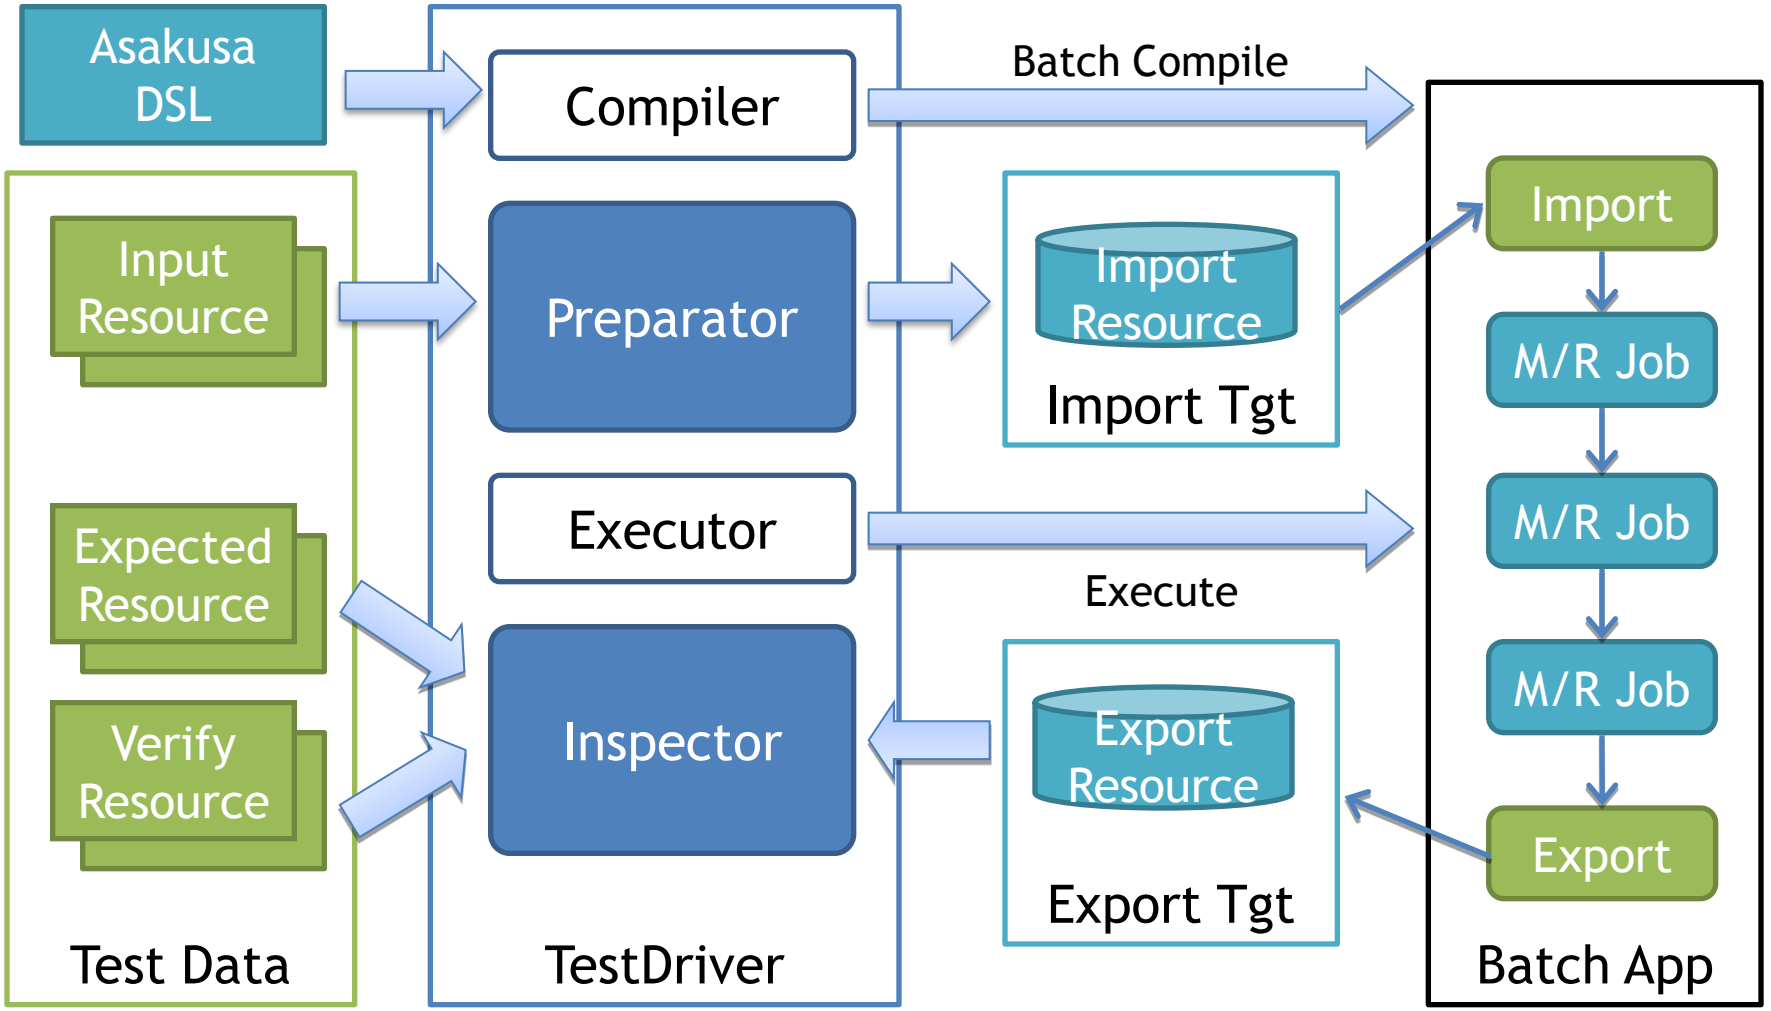

さらなる進化に向けて

これからのTestDriver

テストを短時間で終了させる

- Distributed Testing
  - 複数のマシンでテストを並列実行させてテストを短時間で終了させる
- Cloud Testing
  - AWSと連携

検証機能の強化

- Define the relationship between input and output
  - データの移動が発生するだけの項目は「この項目は入力モデルのこれと等しい」というように定義したい
    - MOVE文のテスト
  - テストデータの定義から仕様(テストの観点)を追いやすくする

テストデータ作成の自動化

- テストデータパターンを定義する
  - テストデータ定義にテストデータパターンを記述し、パターンから生成されたテストデータに対してテストドライバを流す

Asakusa Framework の CI環境

Asakusa CI on AWS

Asakusa FrameworkのCI環境

- AWS(EC2/S3)上にCI環境を構築しています
  - http://ec2-175-41-241-89.ap-northeast-1.compute.amazonaws.com/jenkins/

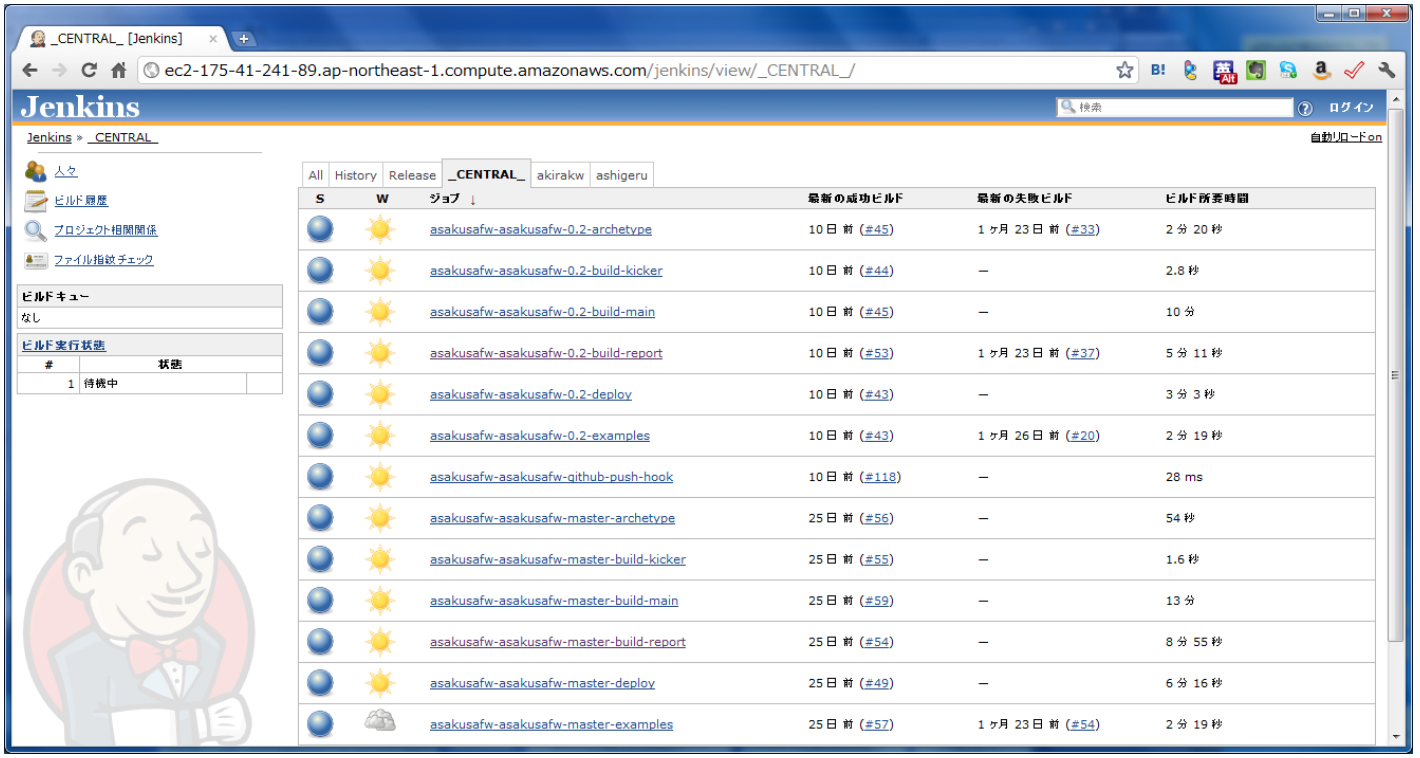

Asakusa CI環境の構成

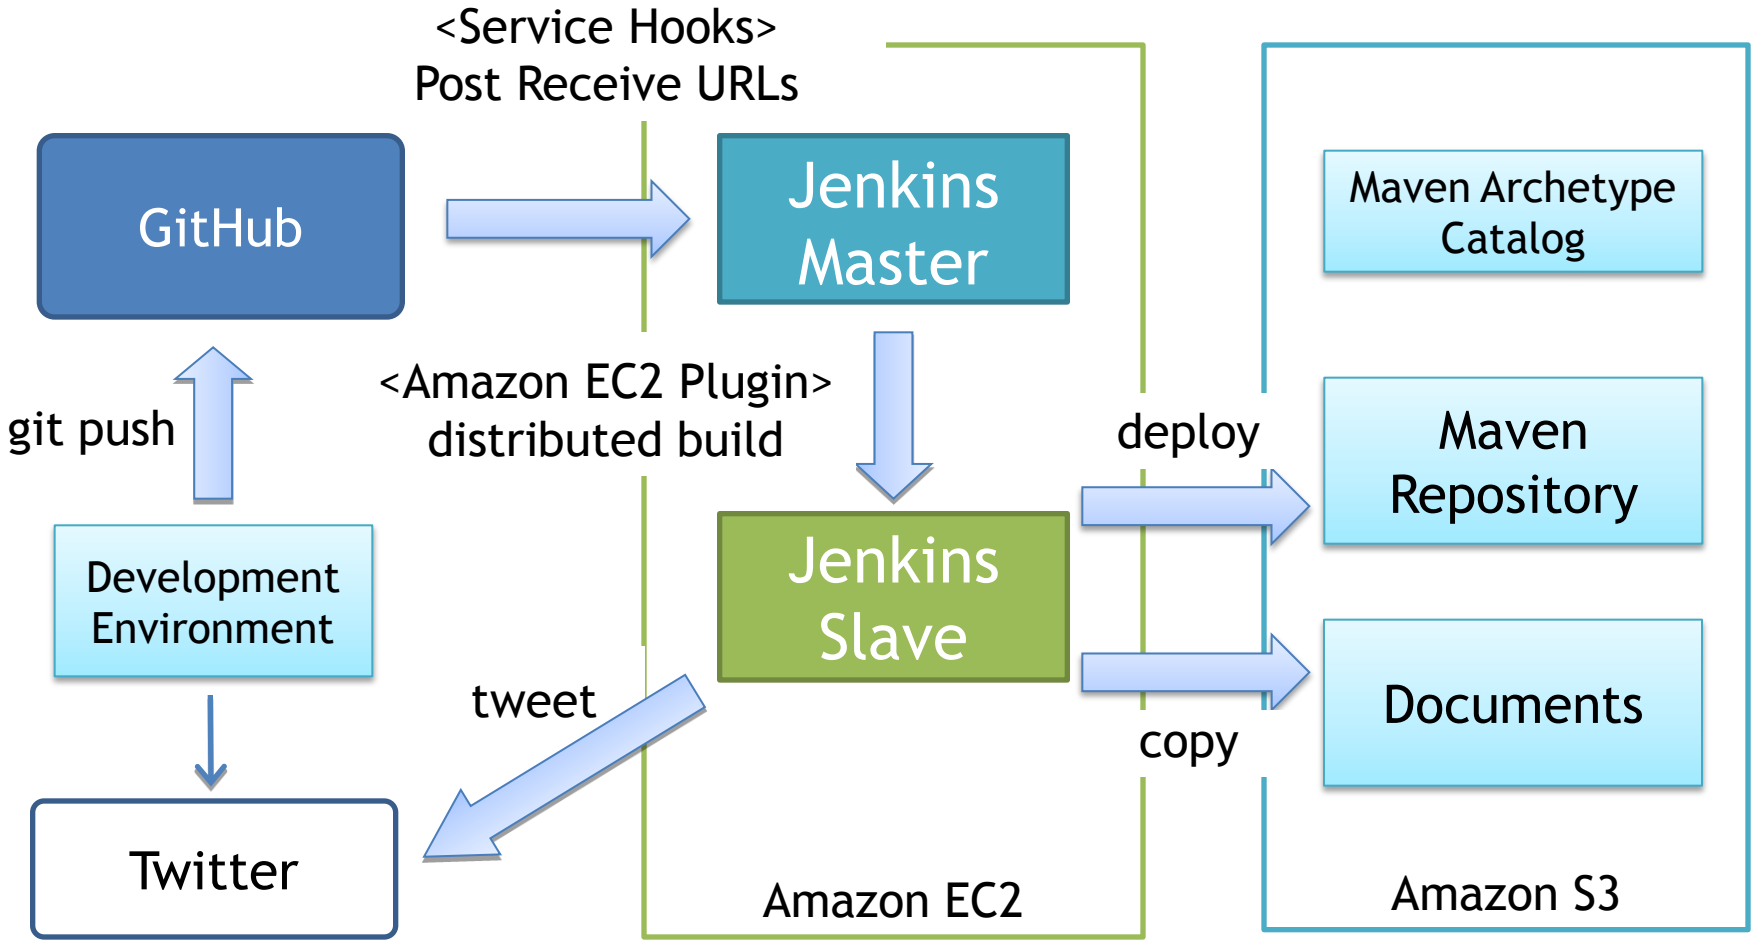

MasterとSlave

- Jenkins Master
  - マイクロインスタンスを常に稼働させておく
  - JenkinsのWebフロントエンドとしてのみ使用
- Jenkins Slave
  - 主要なビルド処理はすべてここで実行
  - High-CPUミディアムインスタンスを実行時に起動
    - スモールインスタンスのほぼ半分の時間でビルドが完了
- Amazon EC2 Plugin
  - JenkinsスレーブをEC2のAMIとして起動する
  - Idleが30分続くと自動的に停止
  - CIサーバのランニングコスト:月々1,000円～2,000円

Jenkins Amazon EC2 Plugin

- Jenkins Slaveとして起動するAMIを指定

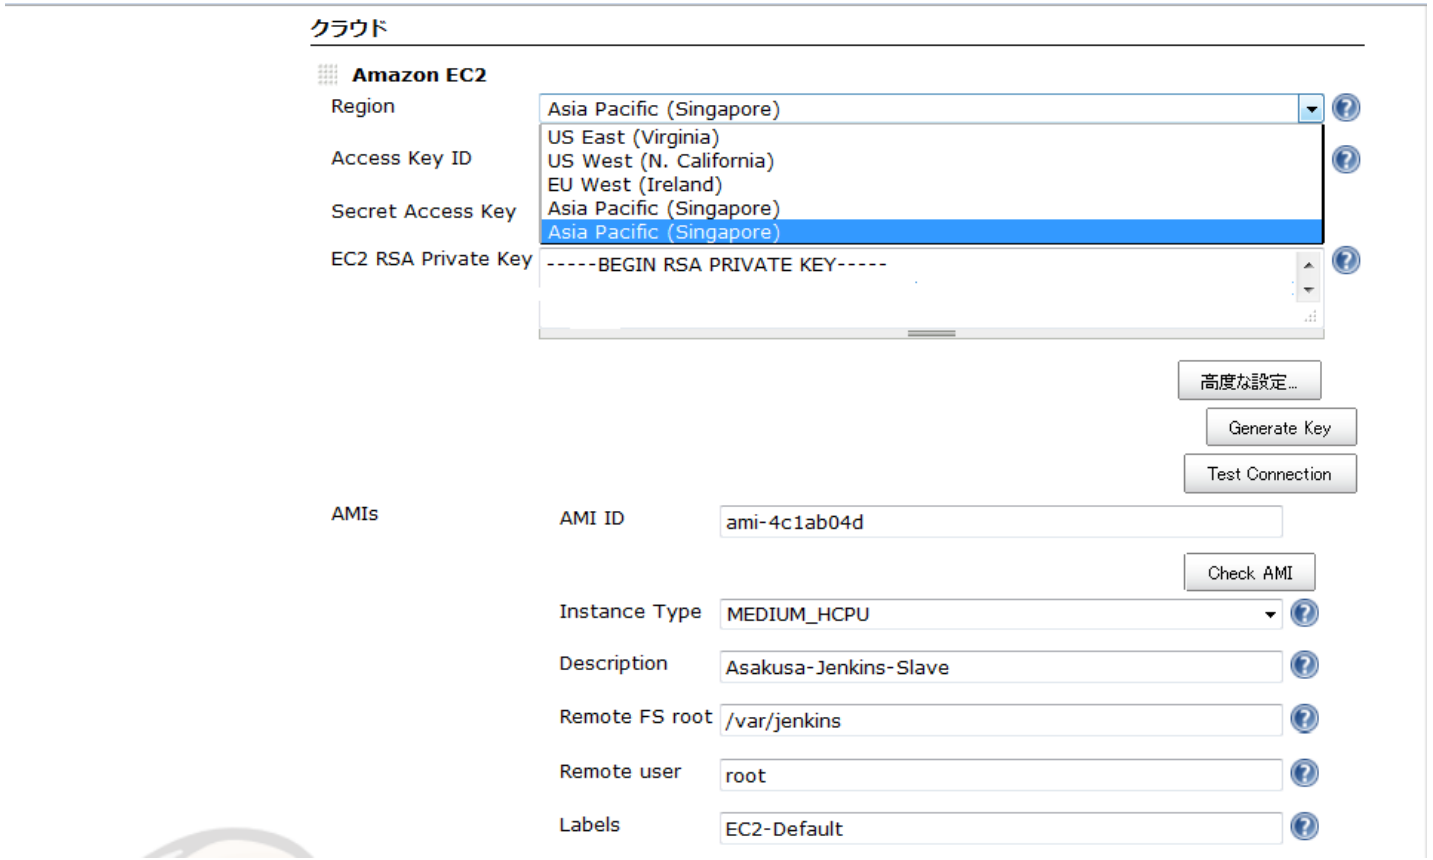

GitHubとJenkinsの連携

- GitHubからJenkinsへpush通知
  - GitHubの「Post Receive URLs」を利用
    - git pushを受けると即時にJenkinsに対してget
  - git pushしたブランチだけをビルドする
    - Post Receive URLs はRequest URLが固定
      - 特定のJenkins Jobを起動することしか出来ない
    - 窓口用のJobで受けて、下流のJobにビルドする可能性があるブランチを定義したJobをすべて紐付け
      - これで一応出来るが、ムダなビルドが多数発生
    - Jenkinsの「Downstream-Ext Plugin」を利用
      - リポジトリに変更がない場合ビルドを中止出来る

Build Pipeline

- ビルドからリリースまでの処理を多段のジョブで実行

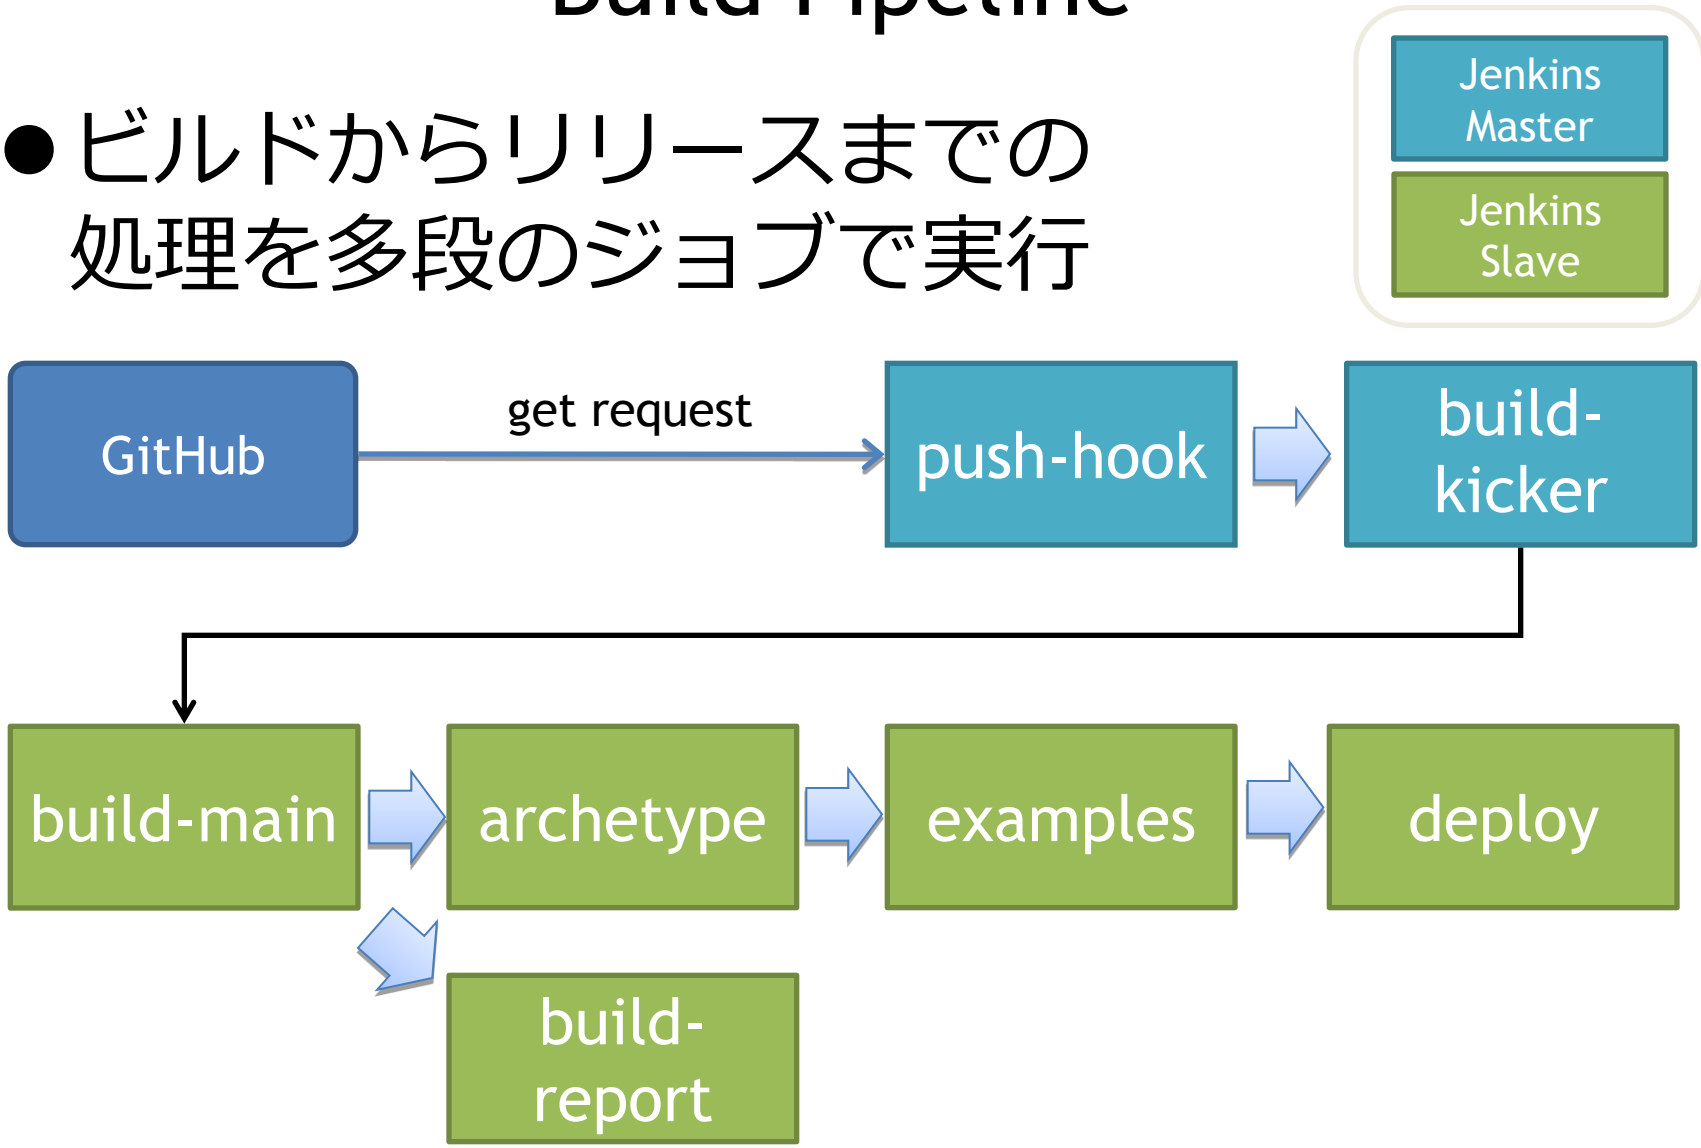

ビルド結果のフィードバック

- Twitterプラグイン
  - @asakusa_ci

拡張ポイントを中心に

Asakusa Test Driver Source Code Reading

TestDriver(0.2)のアーキテクチャ概要(再掲)

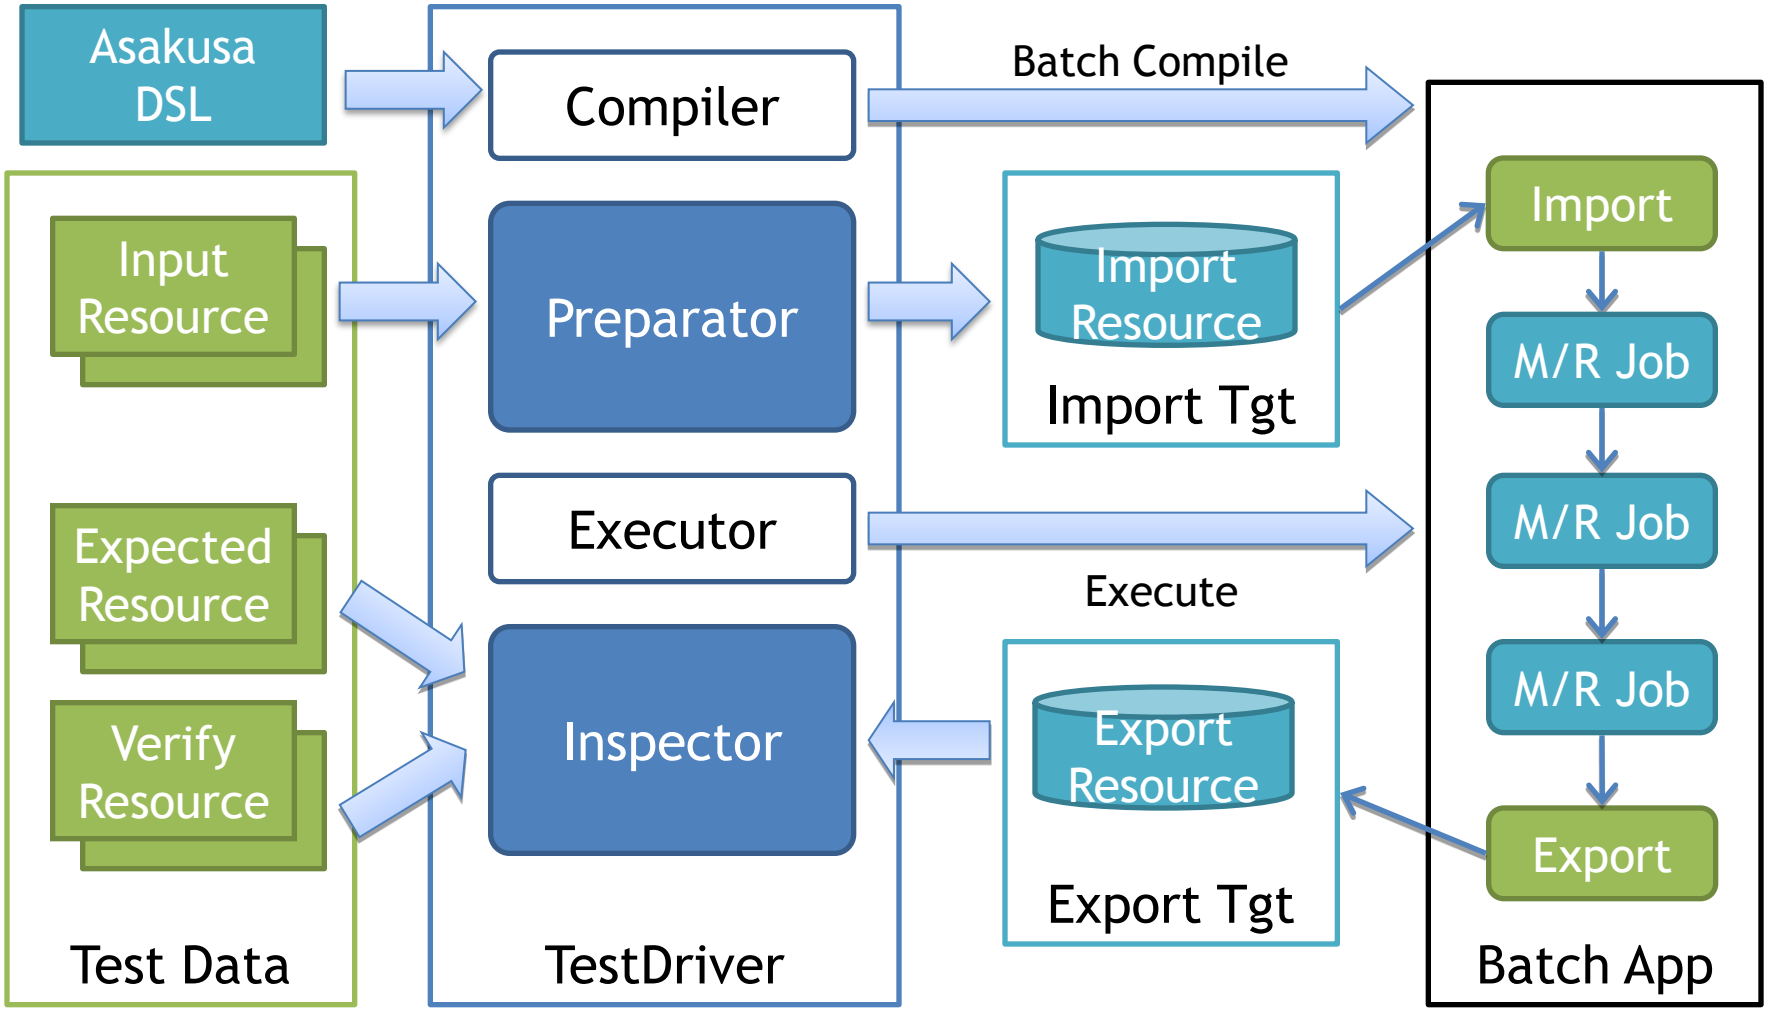

Compilerを詳しく

- テスト対象のDSLをバッチコンパイル
  - Ashigel Compilerの呼出
    - DirectFlowCompiler
    - DirectBatchCompiler
      - Asakusaソースコードリーディング#1 を参照
  - TestDriverでは簡易実行計画を扱う
    - ステージの実行計画をトポロジカルソート
    - 逐次実行

Preparatorを詳しく

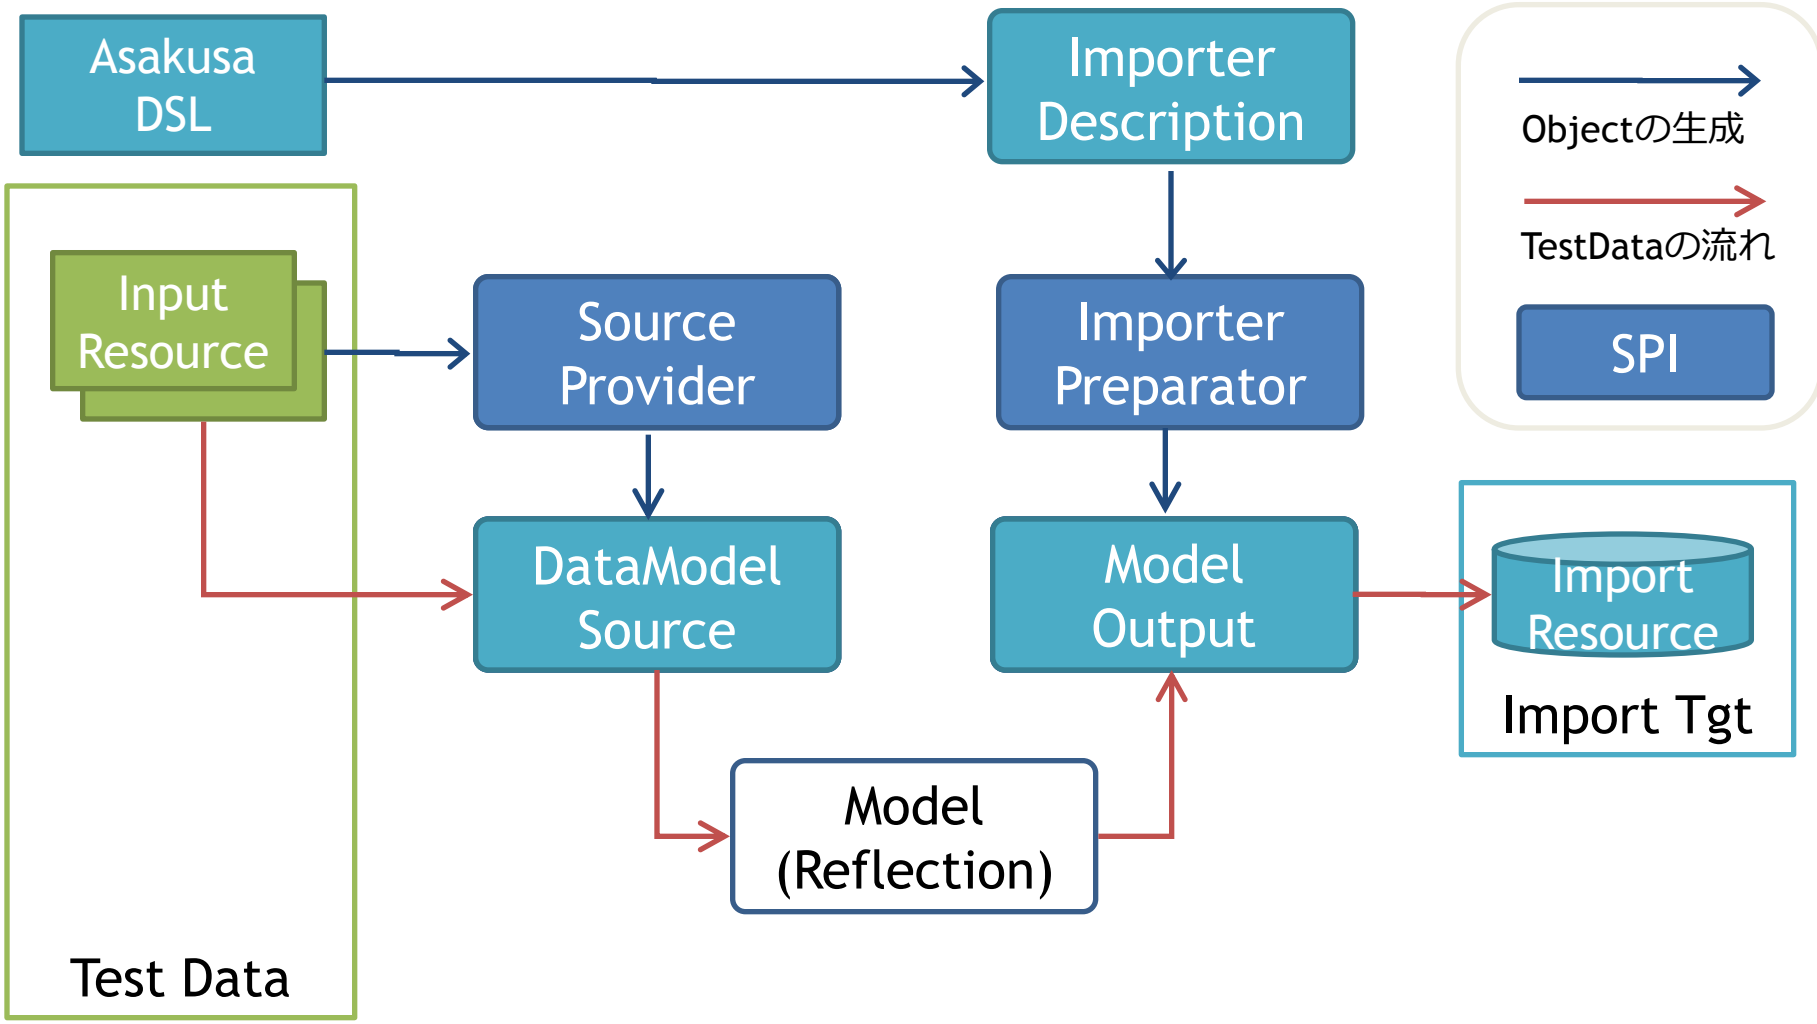

SPIで拡張可能な部品

- testdriver.core.SourceProvider
  - URIに対応するModelのデータソース(DataModelSource)を提供
  - ver0.2.1時点では以下の実装を提供
    - testdriver.json.JsonSourceProvider
    - testdriver.excel.ExcelSheetSourceProvider

SPIで拡張可能な部品

- testdriver.core.ImporterPreparator
  - Import対象に対応したモデル出力オブジェクト(ModelOutput)を提供
  - ver0.2.1時点では以下の実装を提供
    - testdriver.file.FileImporterPreparator
    - testdriver.bulkloader.BulkloaderImporterPreparator

ThunderGate/Excelデータの場合

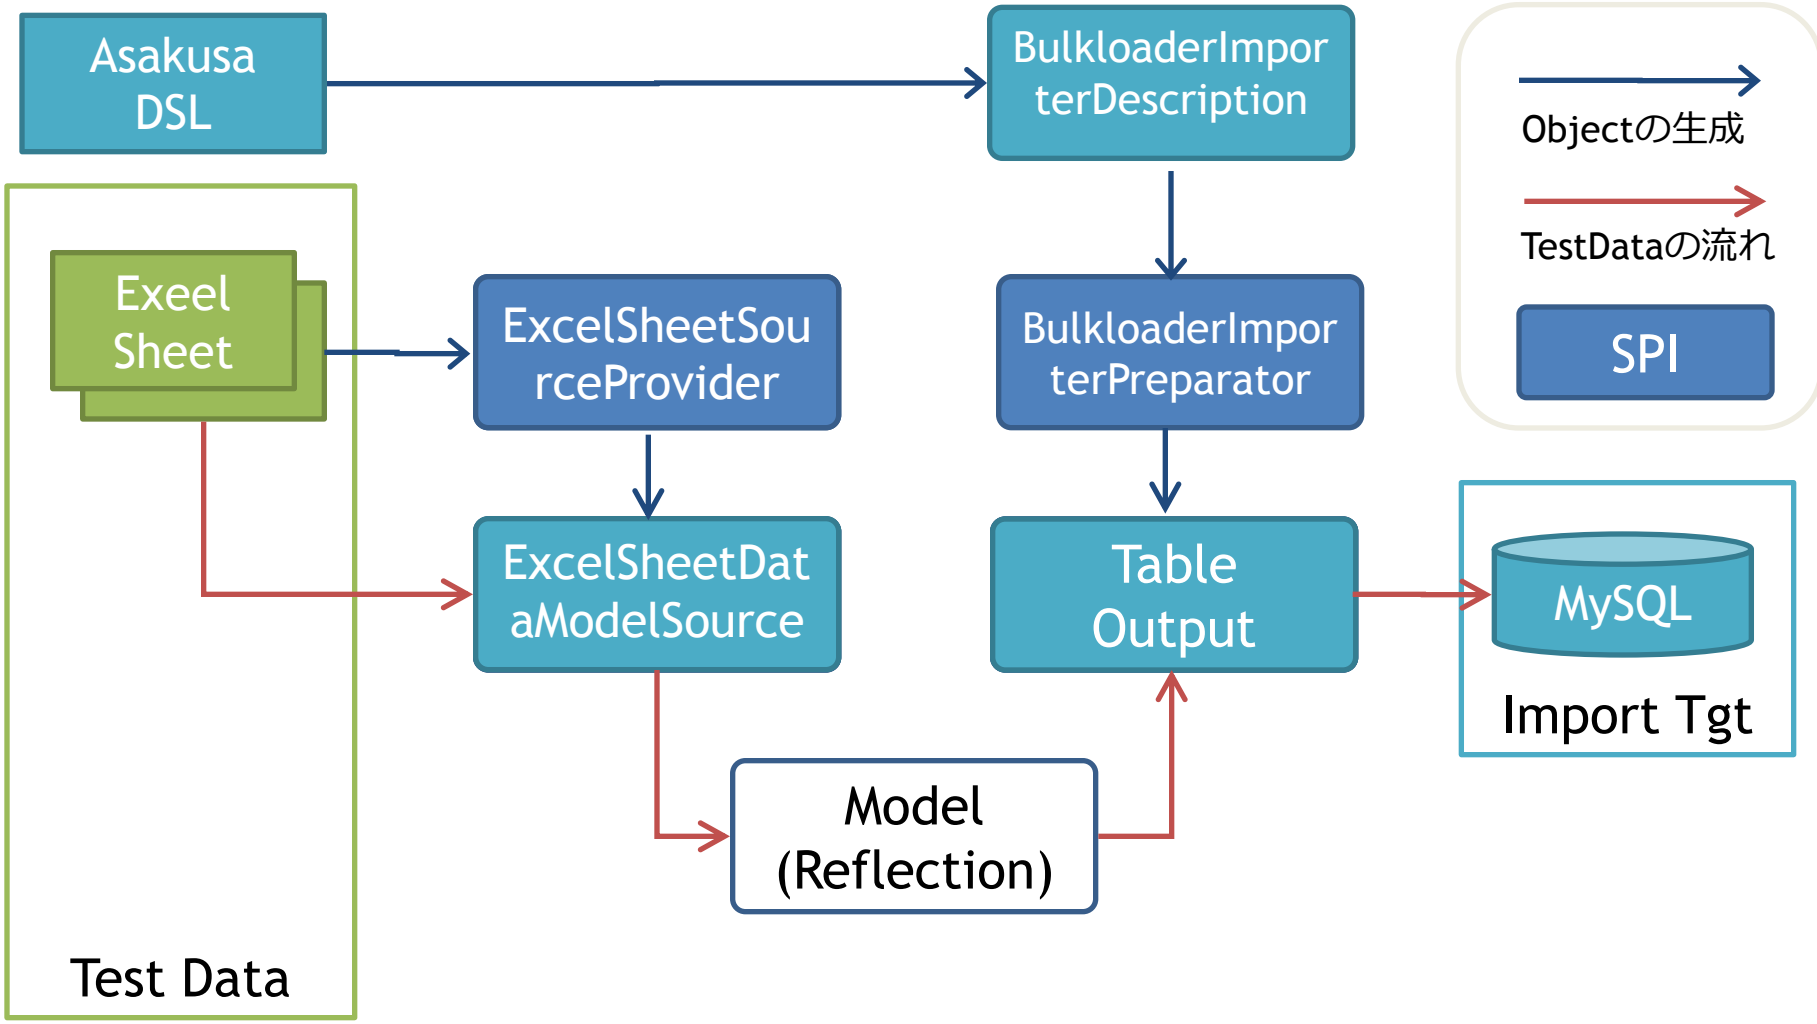

Executorを詳しく

- ステージに対応するコマンドを順次実行
  - JobflowInfo
  - ExternalIoCommandProvider
    - ver0.2.1時点ではOS(Linux)依存のコマンドを出力

Inspectorを詳しく

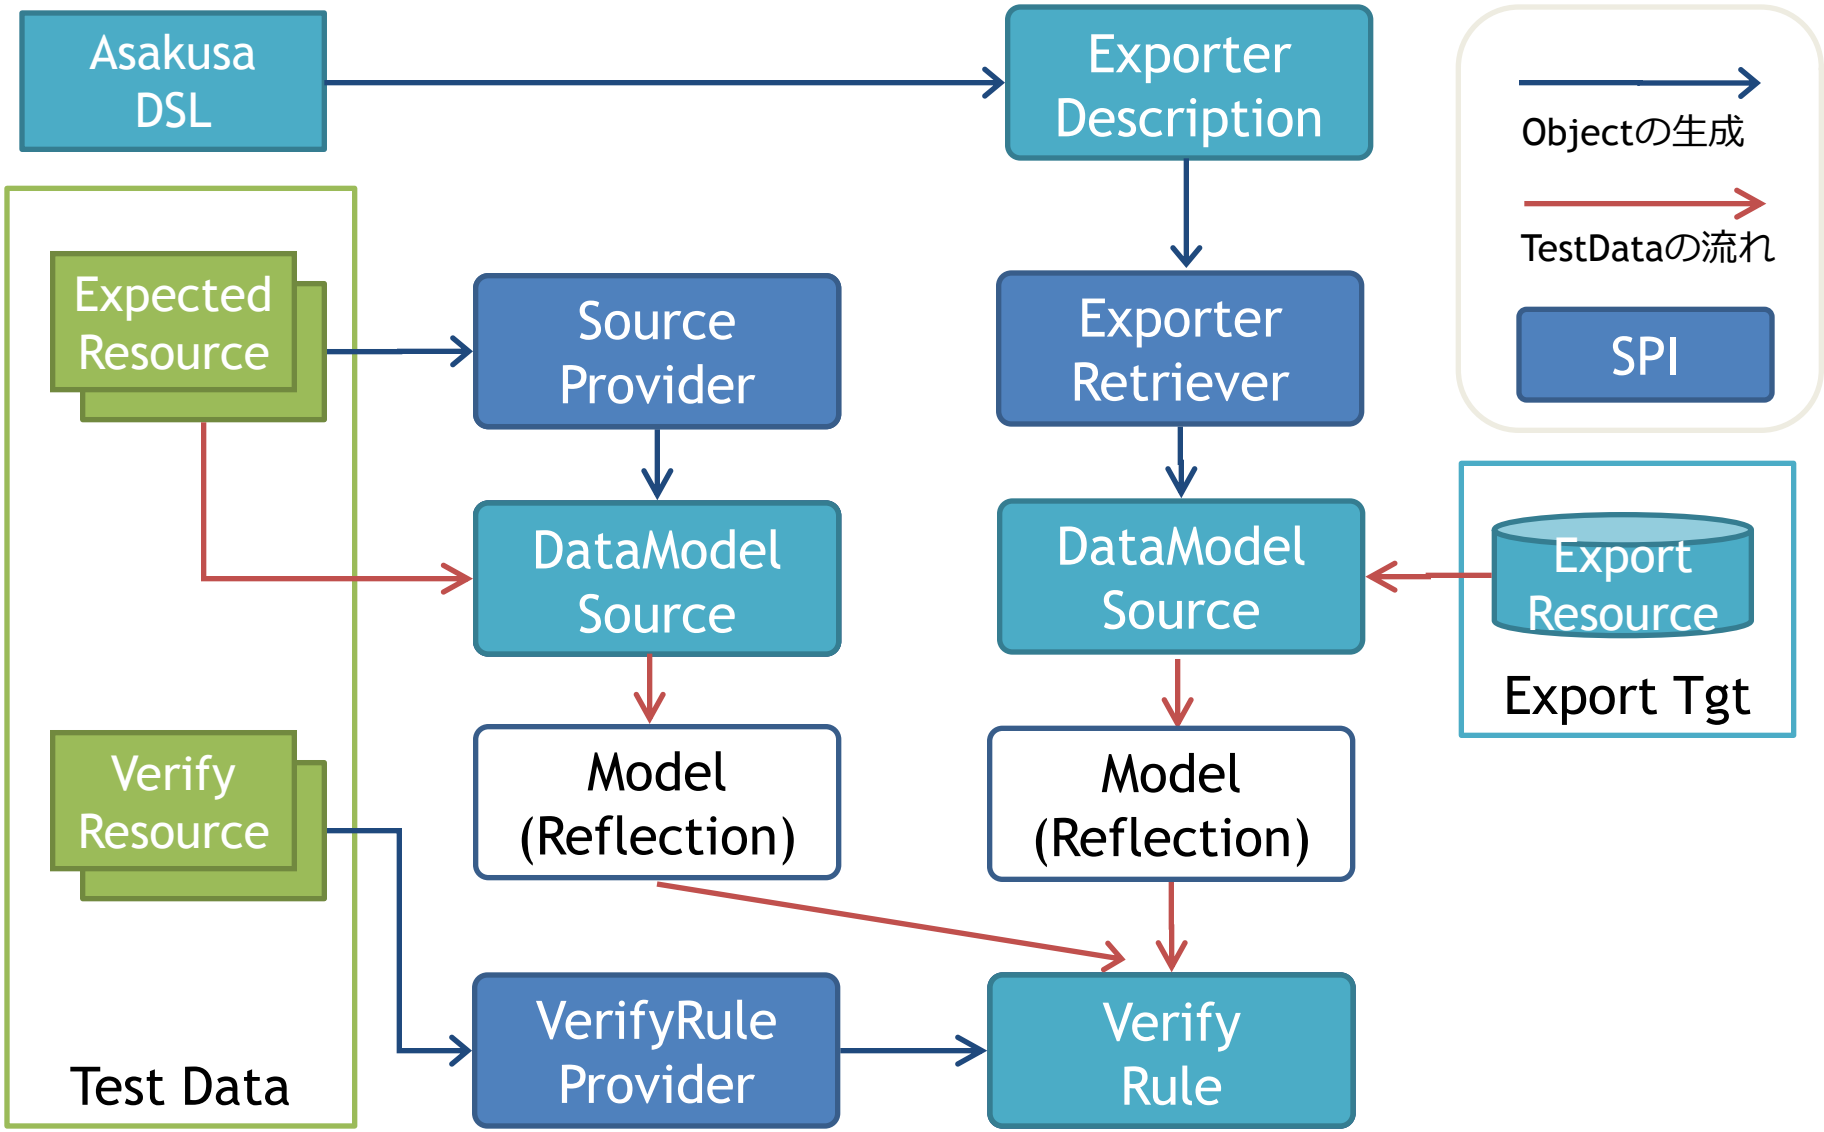

SPIで拡張可能な部品

- testdriver.core.ExporterRetriever
  - Export対象に対応したModelのデータソース(DataModelSource)を提供
  - ver0.2.1時点では以下の実装を提供
    - testdriver.file.FileExporterRetriever
    - testdriver.bulkloader.BulkloaderExporterRetriever

SPIで拡張可能な部品

- testdriver.core.VerifyRuleProvider
  - URIに対応する検証ルール解析オブジェクト(VerifyRule)を提供
  - ver0.2.1時点では以下の実装を提供
    - testdriver.excel.ExcelSheetRuleProvider
  - 検証ルールをJavaで記述することも可能
    - testdriver.core.ModelVerifier

拡張してみる

- 例:期待値をデータベースに定義する
  - モチベーション
    - Excelのレコード数の上限を超える
    - 既存システムのテーブルデータをそのままテストデータに活用
    - ツールでテストデータを作りやすいかも

SourceProviderを追加

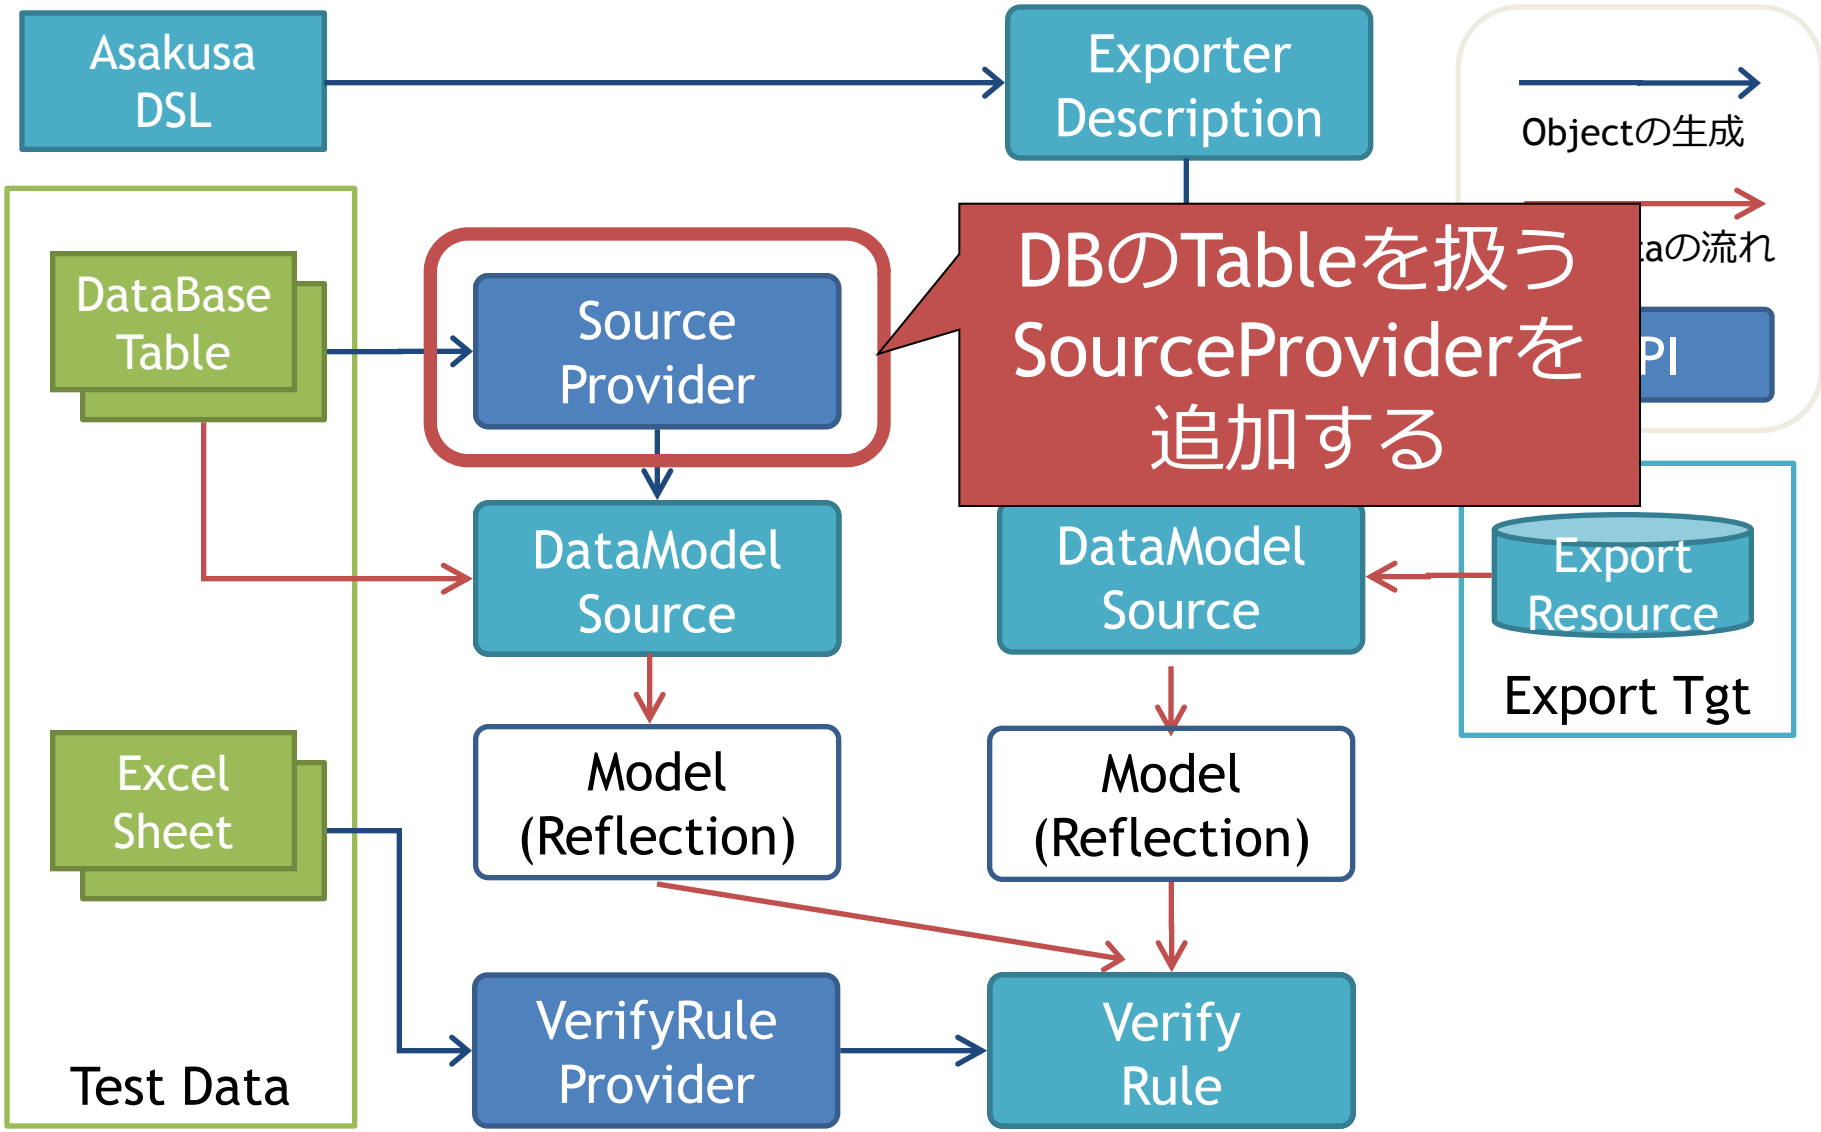

実はあります

- Issue#64:Enable to input expect data from database table.
  - https://github.com/asakusafw/asakusafw/issues/64
- 修正内容
  - TableSourceProviderを追加
    - testdriver.bulkloader.TableSourceProvider
  - SPIの定義ファイルを追加
    - src/main/resources/META-INF/services/com.asakusafw.testdriver.core.SourceProvider
- 使い方
  - URIに以下の文字列を指定
    - “bulkloader:<target_name>:<table_name>”
    - 例:”bulkloader:asakusa:ORDER”