Smart Tech Korea 2022

Data Science 및 Machine Learning을 위한 데이터브릭스 활용 사례

Clodcus

ML pipeline workflow

일반적인 머신러닝의 워크플로우는 다음과 같습니다.

ML pipeline workflow

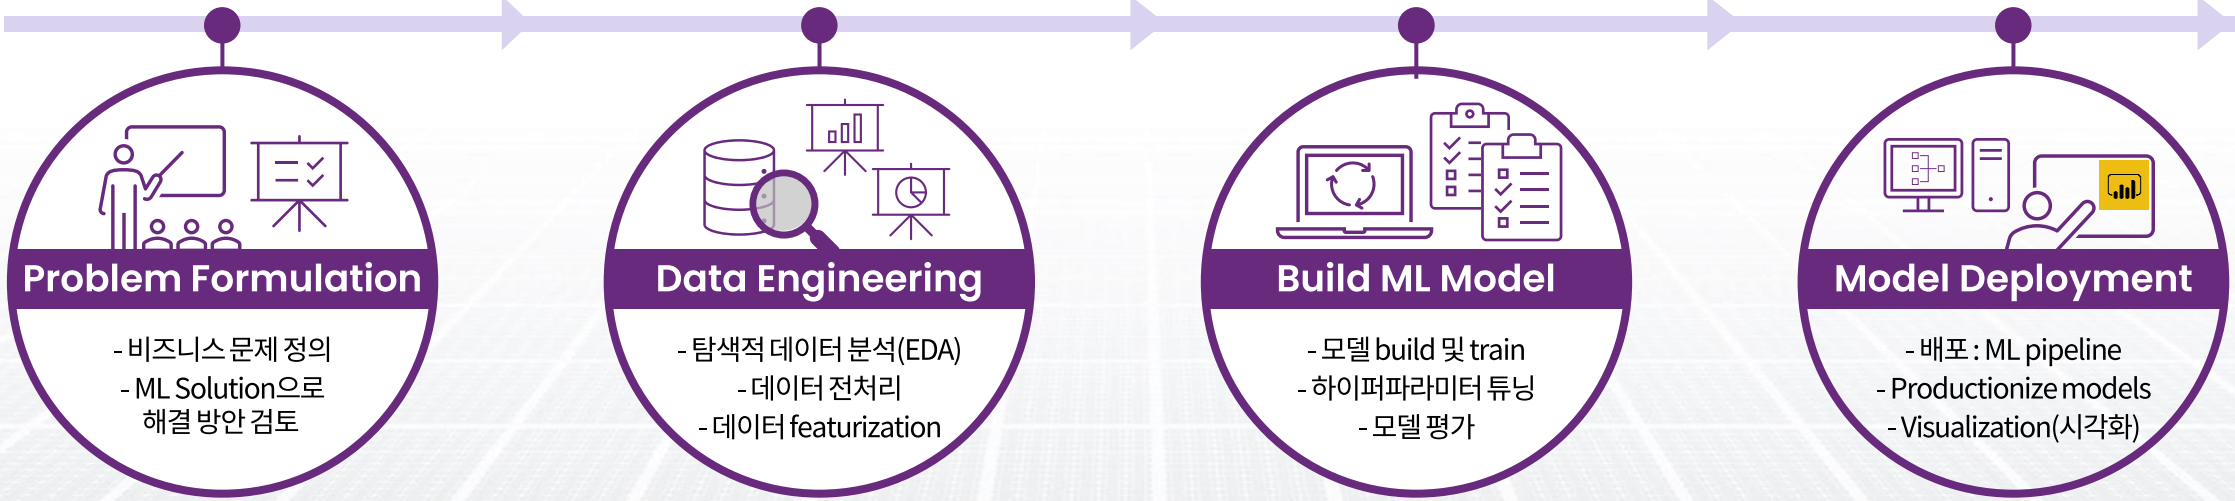

Databricks ML pipeline workflow

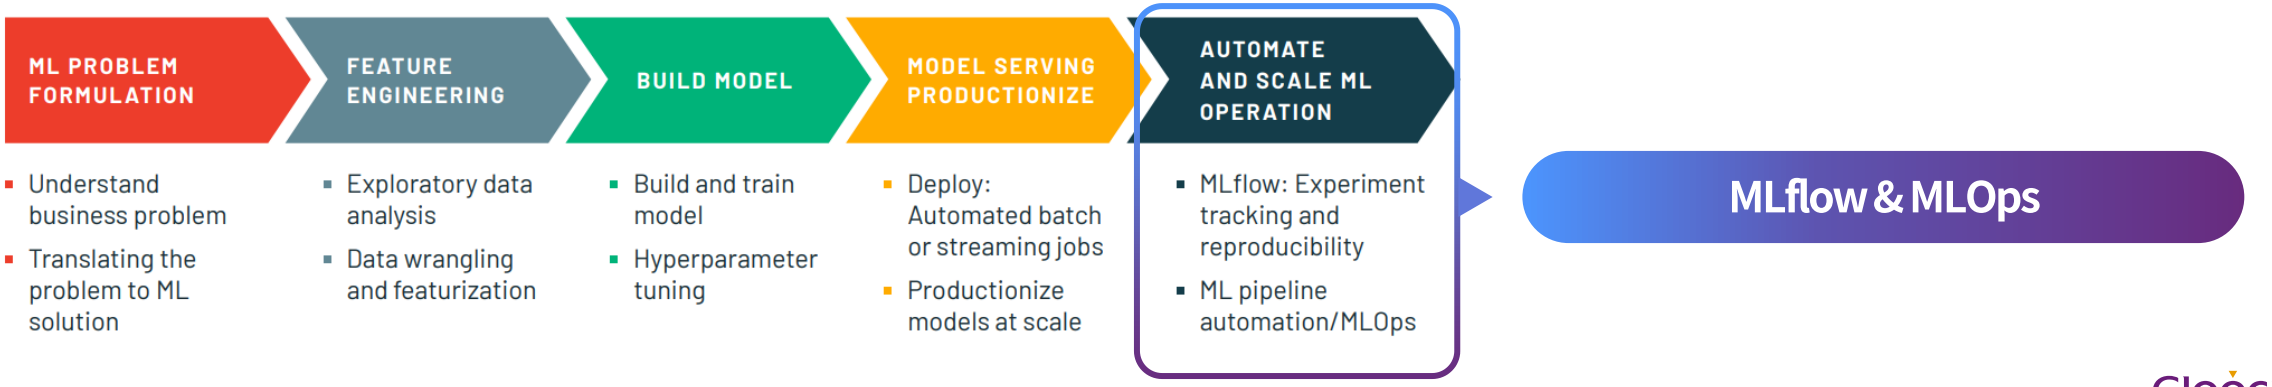

AI & ML 활용

Scenario

1. A사에 대한 시나리오(아키텍처)

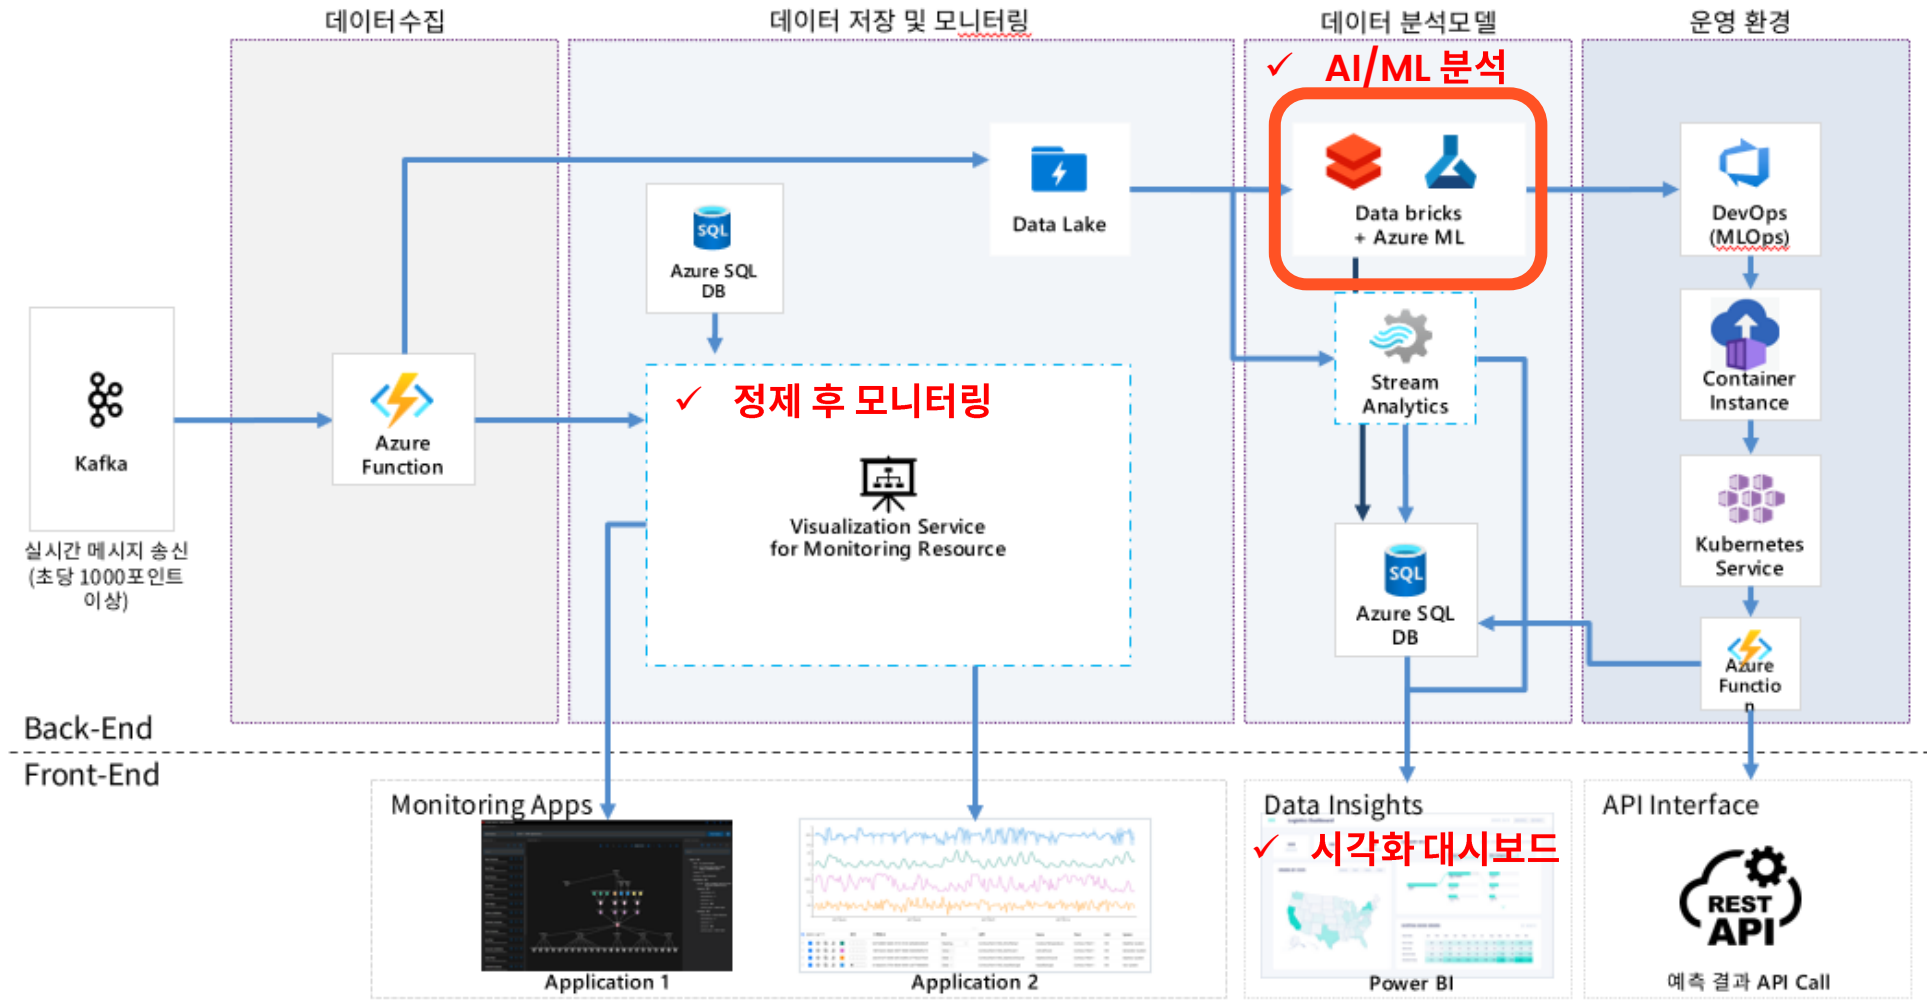

Scenario

1. A사에 대한 시나리오

프로젝트 진행 중 주의 사항 및 Pain Point

1) 방대한 데이터 양, 두 가지 모델링

- 다양한 분석법이나 공통된 실험을 공유하거나 co-work해야 되는 환경이 필요

2) 체계적인 실험 관리

- 많은 ML 실험에 대한 생성 파일(모델, 로그, config)의 체계적인 관리 필요

3) 최적의 모델 서칭, 다양한 모델 실험

- 부족한 정보에 대한 다양한 Regression 모델의 테스트 필요

4) 다중 태스크의 스케줄링

- 매 주 단위로 모델 최신화 요구, 데이터 특징상 일 단위 데이터 갱신 필요

5) 시각화 대시보드 구성

- 편리한 bi 솔루션의 연동 필요

6) 요청된 데이터의 inference

- 외부 시스템과의 유연한 연동

1) 방대한 데이터 양, 두 가지 모델링

팀원들 간에 다양한 분석 결과나 공통된 실험을 공유할 수 있고, co-work 환경을 지원합니다.

Collaborative data science with multi languages and tools

Databricks의 노트북으로 EDA, 데이터 분석, 모델 학습 등을 협업할 수 있다.

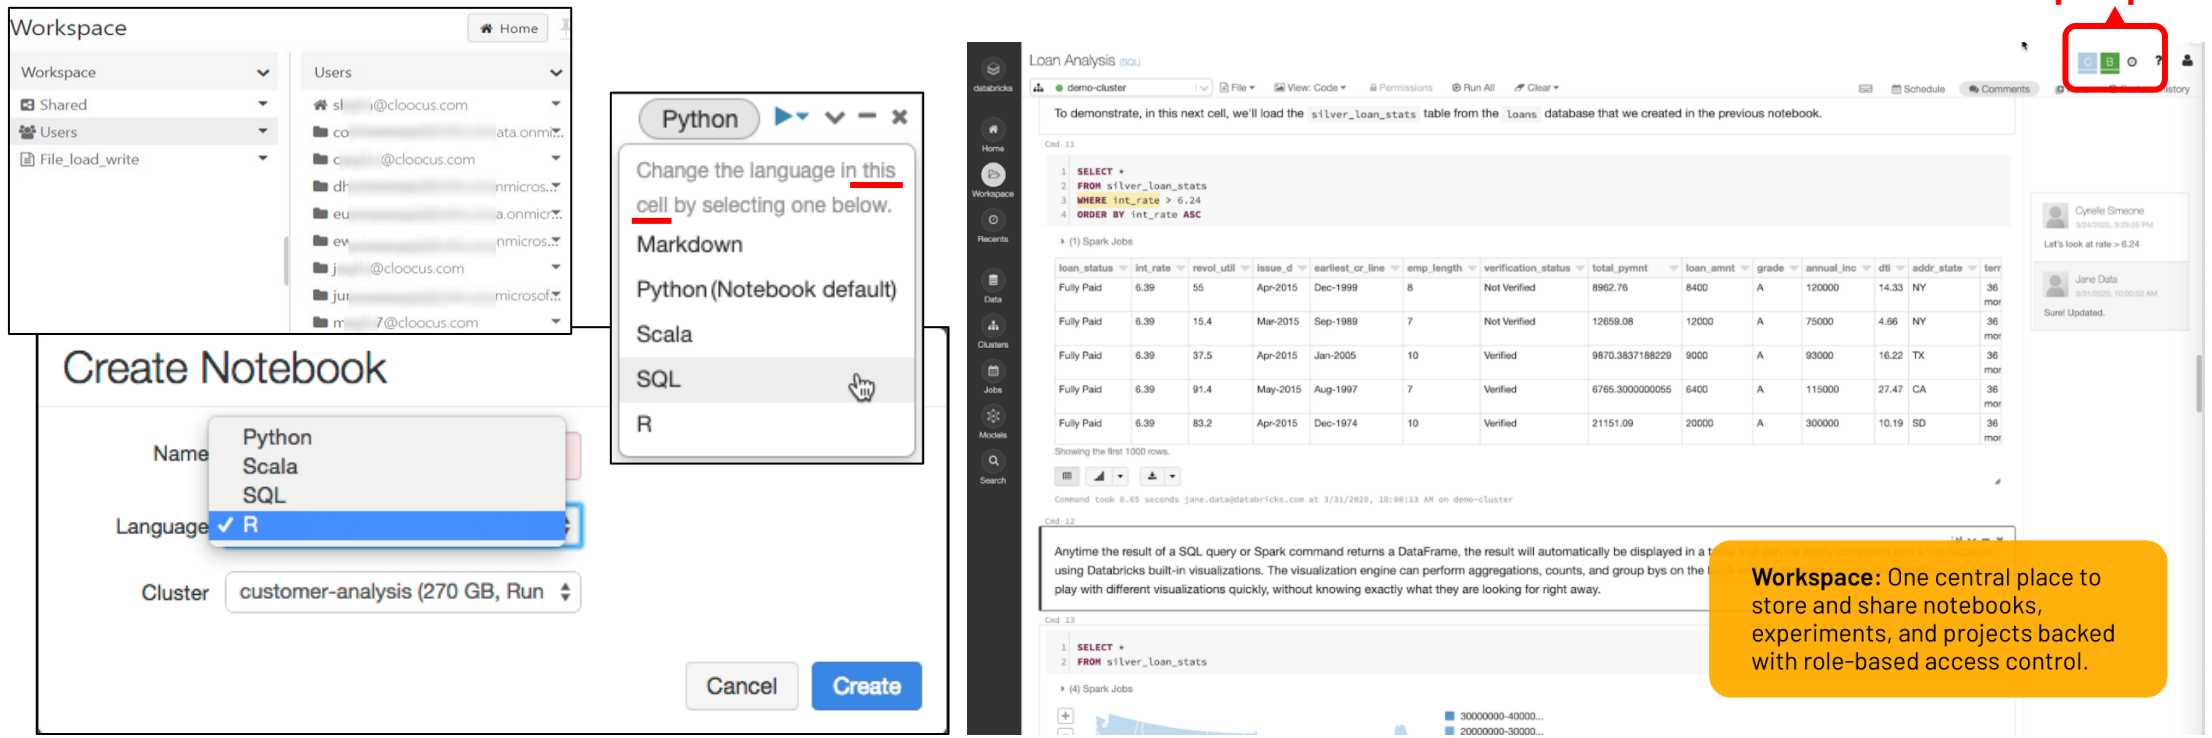

2) 체계적인 실험 관리

많은 ML 실험에 대한 생성 파일(모델, 로그, config 등)을 체계적으로 관리 할 수 있습니다.

Efficient end-to-end ML Pipeline

Databricks는 mlflow를 기본적으로 제공하여 쉽게 ML의 lifecycle을 관리할 수 있습니다.

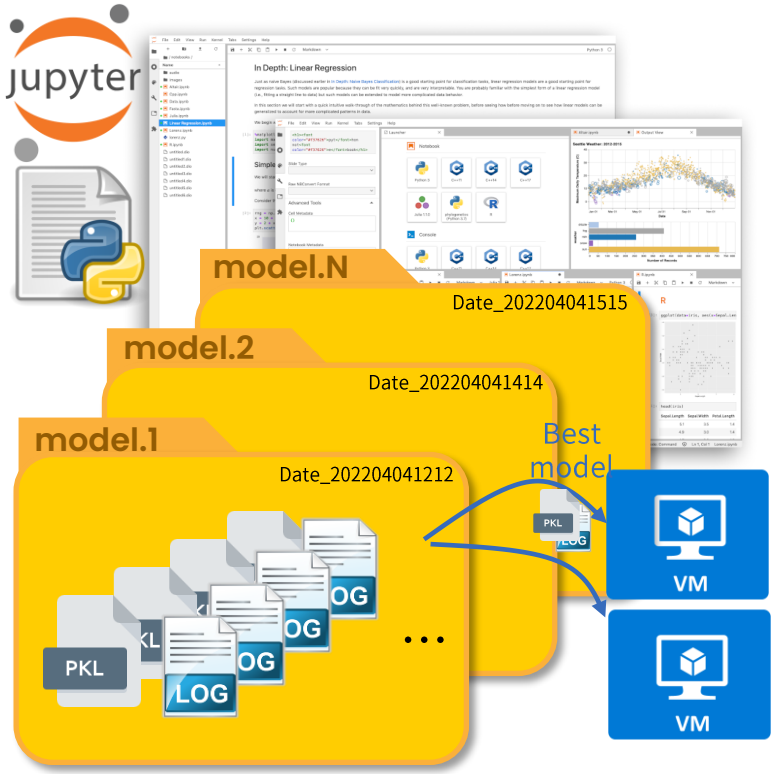

mlflow on databricks

Tracking
Record and query experiments: code, data, config, results

Projects
Packaging format for reproducible runs on any platform

Models
General format for sending models to diverse deploy tools

3) 최적의 모델 서칭, 다양한 모델 실험

다양한 Regression 모델을 빠르게 테스트 할 수 있게 AutoML notebook을 제공합니다.

A “Glass box” approach to AutoML

Databricks의 AutoML은 실행된 결과에 대한 수정 가능한 노트북을 제공하여 쉽고 빠르게 baseline 모델을 튜닝 할 수 있습니다.

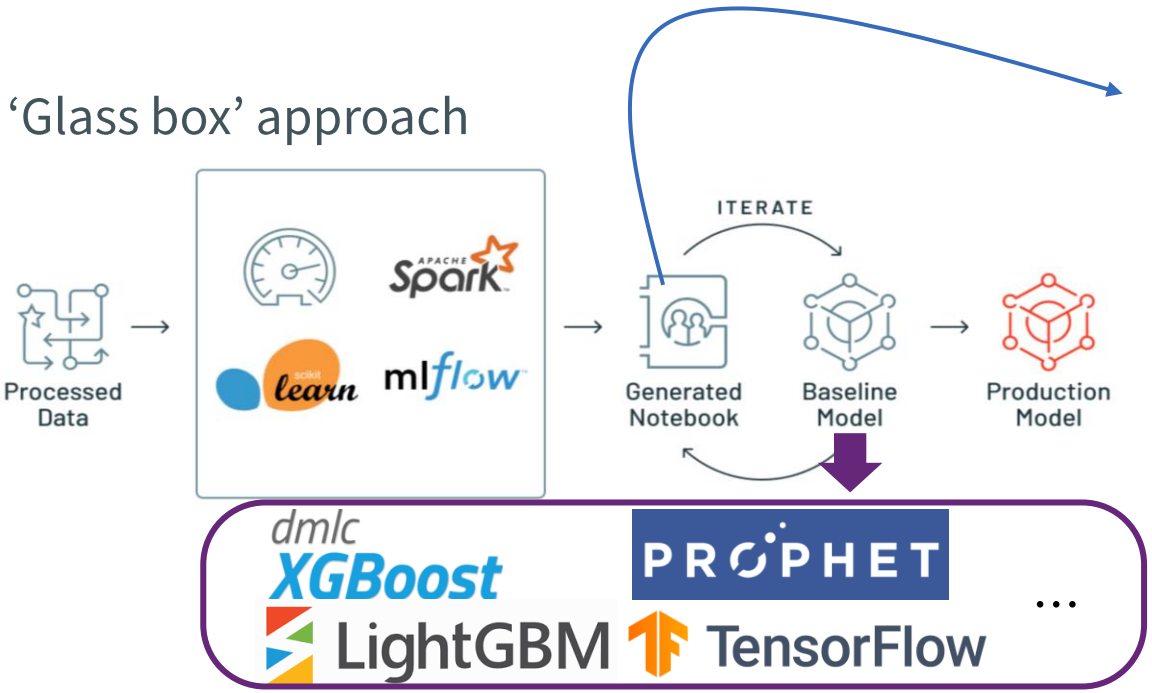

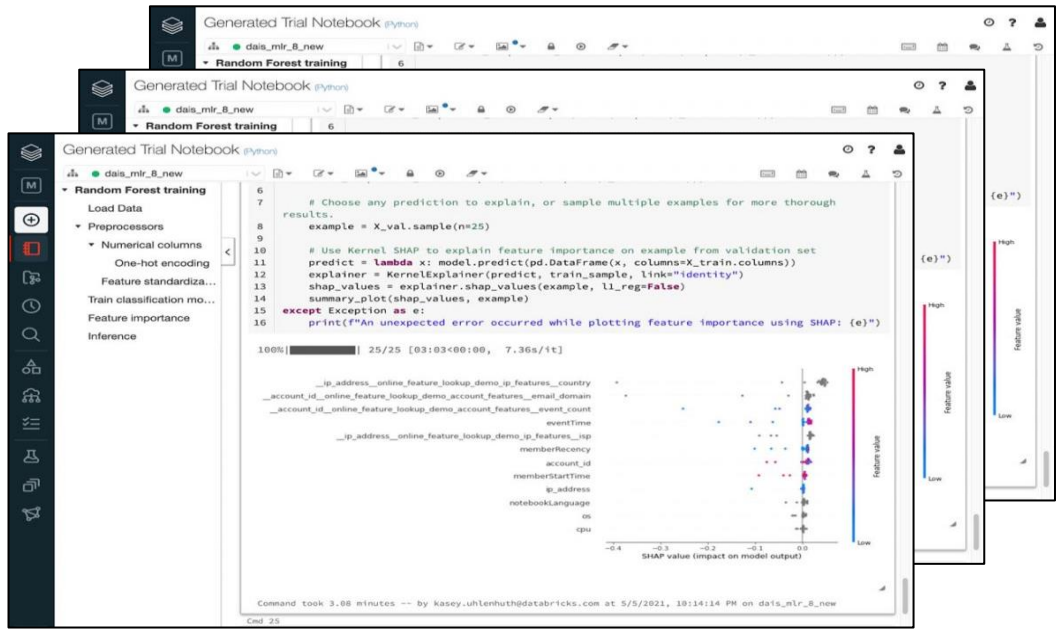

Generated notebooks

4) 다중 태스크의 스케줄링

주 단위,일 단위의 다양한 작업 스케줄링을 쉽게 구현하고 관리할 수 있습니다.

Orchestrate Multiple Tasks with Databricks Jobs

Databricks는 job 기능을 통해 원하는 task를 주기적으로 관리할 수 있습니다.

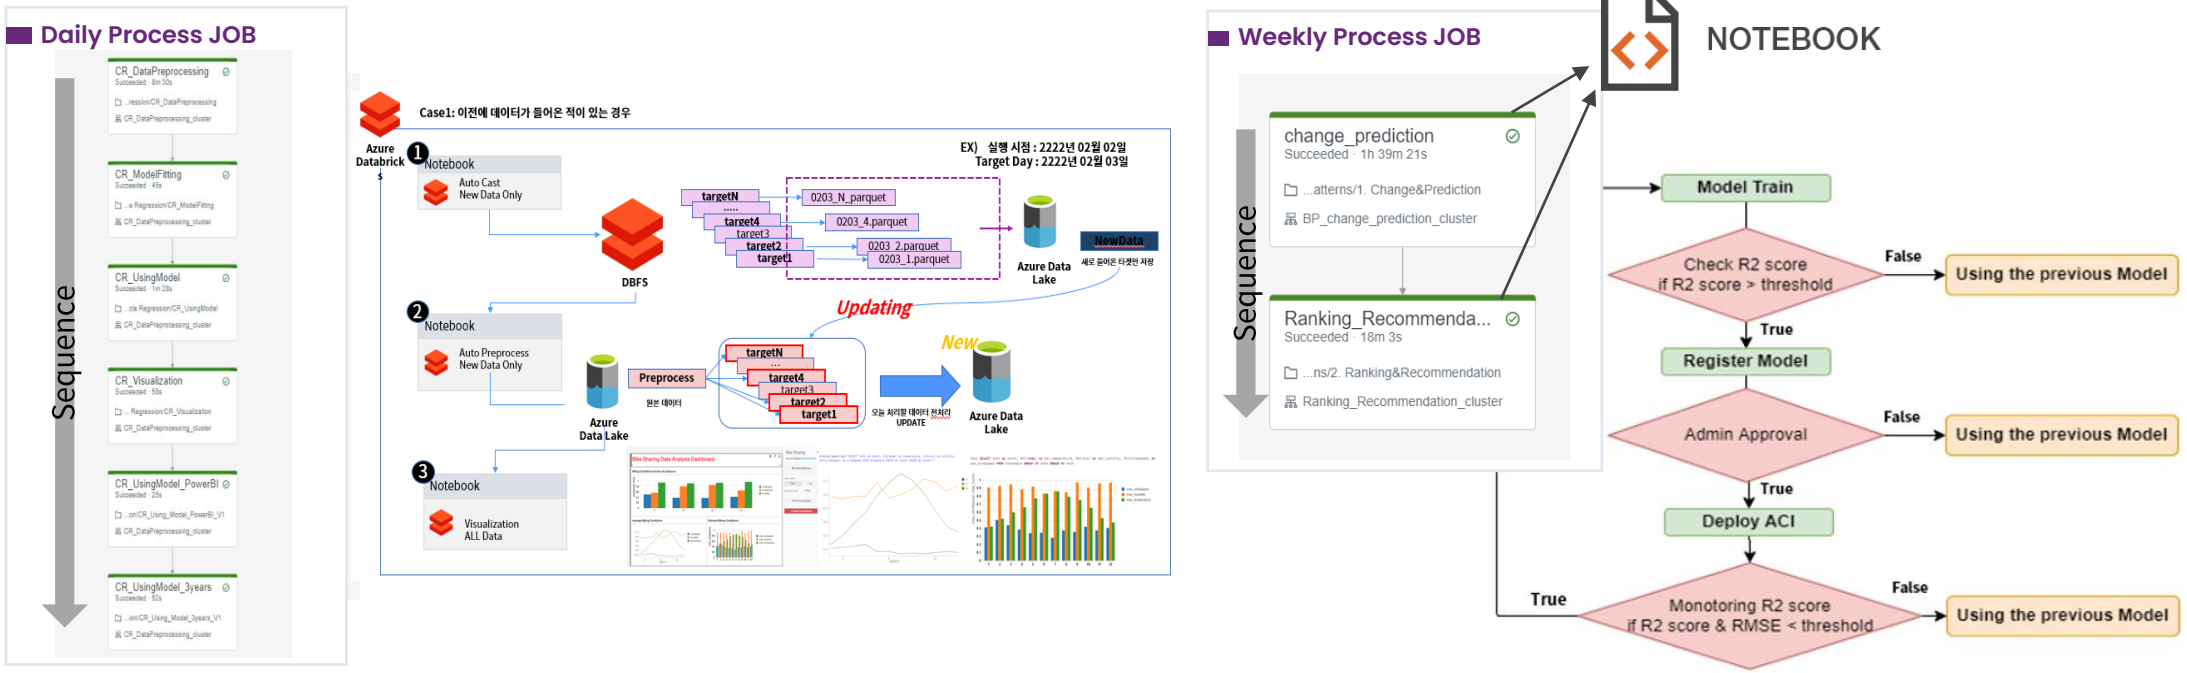

5) 시각화 대시보드 구성

Databricks를 통해 편리하게 bi 솔루션의 연동을 할 수 있습니다.

Navigate tables and views to start visualizing data

Databricks의 native connector를 통해 시각화 대시보드를 쉽게 구현할 수 있습니다.

- ☑ 거버넌스 수립
- ☑ 데이터 기반 의사결정

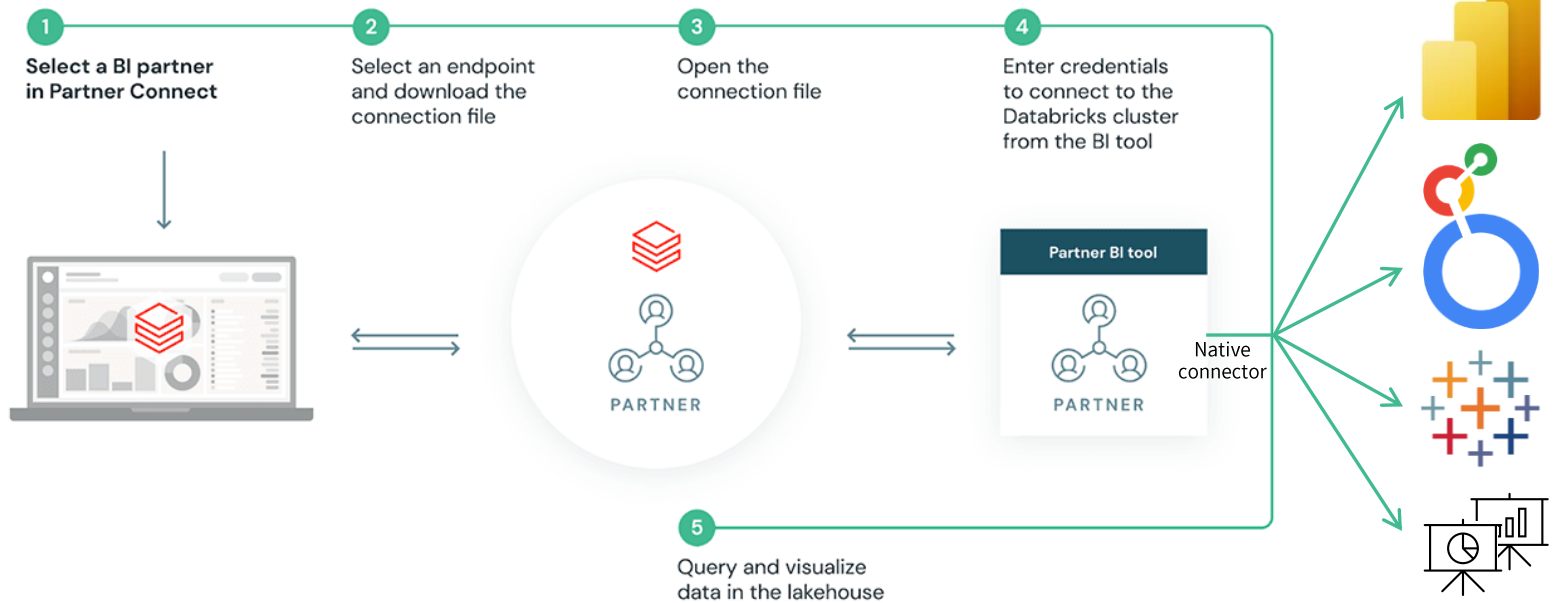

6) 요청된 데이터의 inference

Databricks는 외부 시스템과의 유연한 연동이 가능합니다.

Model Serving on Databricks

Databricks은 등록한 모델에 대한 REST API endpoint를 제공하여 모델을 원하는 서비스에 배포할 수 있습니다.

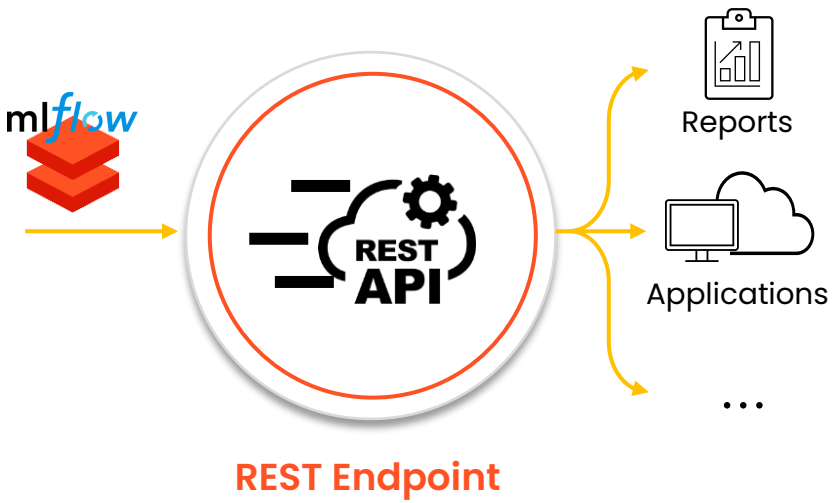

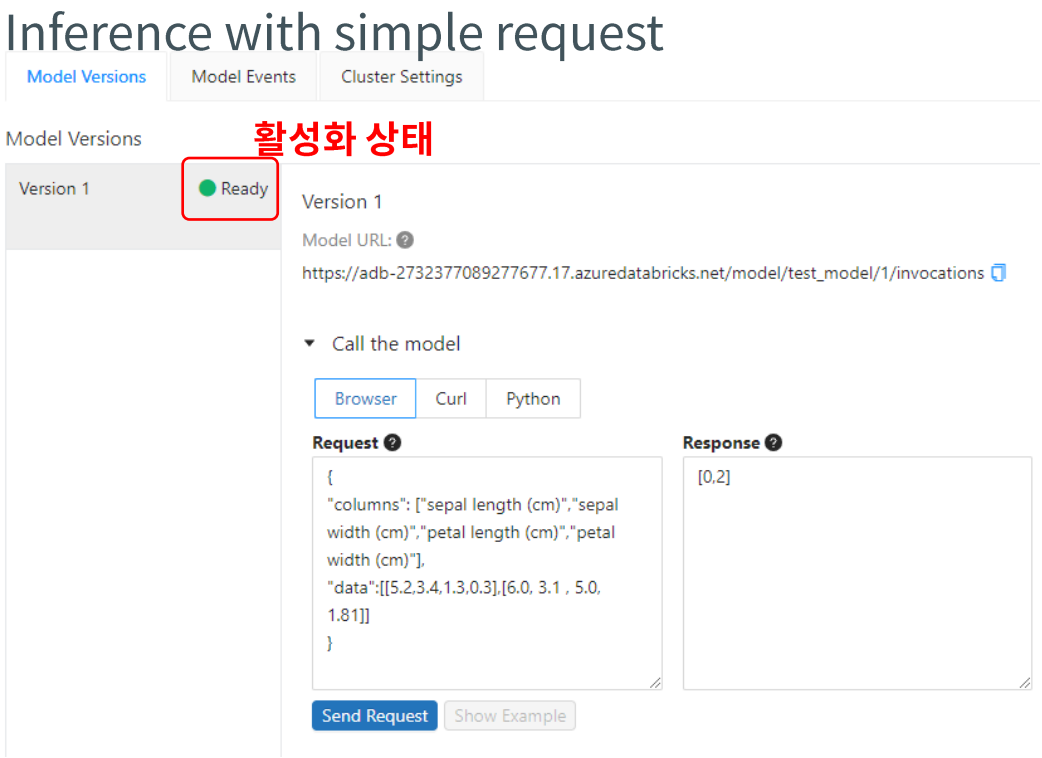

결론

이렇게 프로젝트를 진행하며 발생하는 다양한 상황과 pain points를 Databricks를 통해 쉽게 해결할 수 있습니다.

클라우드와 함께하는 AI / ML 서비스

1) 방대한 데이터 양, 두 가지 모델

- 다양한 분석법이나 공통된 실험을 공유하거나 co-work해야 되는 환경이 필요

2) 체계적인 실험 관리

- 많은 ML 실험에 대한 생성 파일(모델, 로그, config)의 체계적인 관리 필요

3) 최적의 모델 서칭, 다양한 모델 실험

- 부족한 데이터에 대한 다양한 Regression 모델의 테스트 필요

4) 다중 태스크의 스케줄링

- 매 주 단위로 모델 최신화 요구, 데이터 특징상 일 단위 데이터 갱신 필요

5) 시각화 대시보드 구성

- 편리한 bi 솔루션의 연동 필요

6) 요청된 데이터의 inference

- 외부 시스템과의 유연한 연동

Demo

1. Azure Databricks **AutoML**
2. Azure Databricks **MLflow**

Smart Tech Korea 2022

빅데이터 분석을 위한 데이터 레이크하우스 파이프라인

Cloocus

BIGDATA?? HOW TO??

ELT?

ETL PIPELINE?

Data Lake?

Data Warehouse?

Real Time DATA?

데이터 관리 방법?

시각화 해야 하는데..

Lakehouse?

AI & ML..

데이터는 가지고 있는데..

TYPICAL DATA PIPELINE

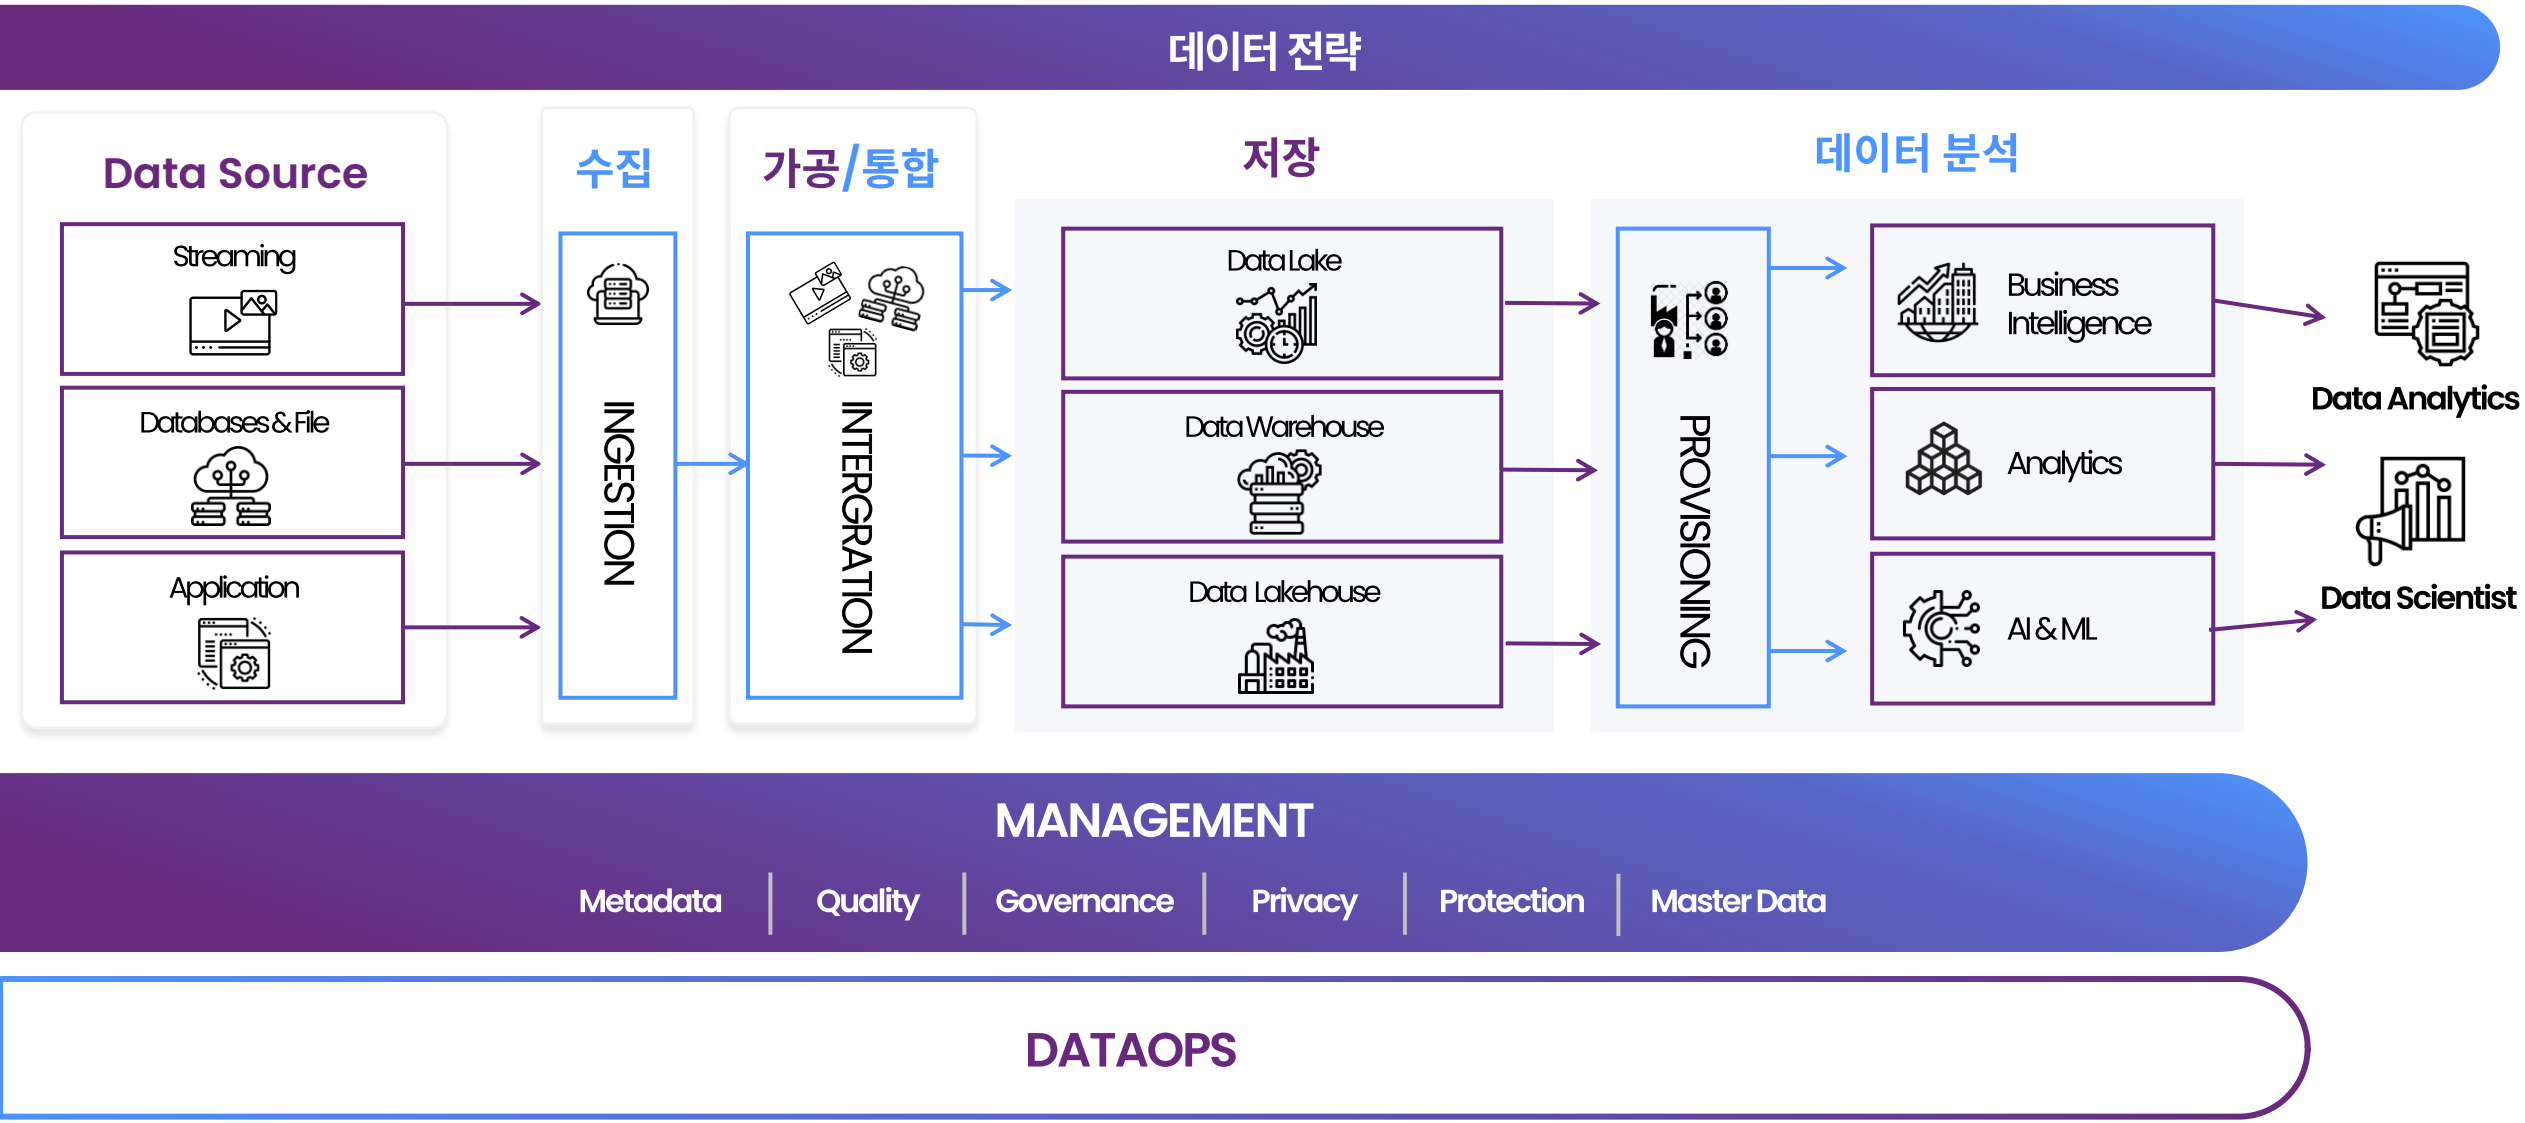

데이터 활용 문제

데이터 웨어하우징 | 데이터 엔지니어링 | 스트리밍 | DS & ML

사일로화된 기술 스택 때문에 점점 더 복잡해지는 데이터 아키텍처

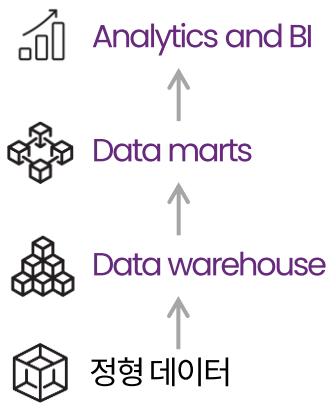

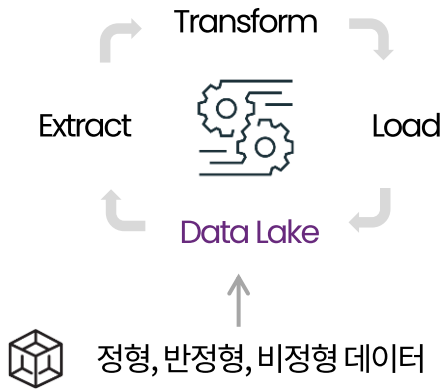

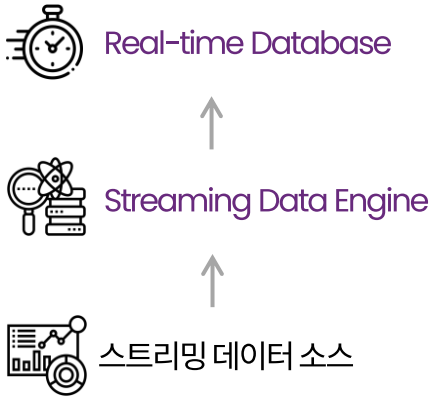

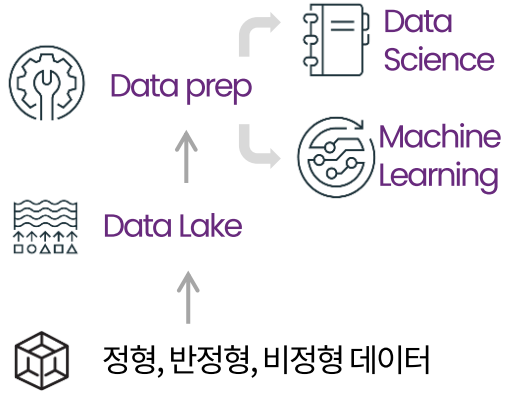

데이터 활용 문제

데이터 웨어하우징

- Amazon Redshift
- Azure Synapse
- Snowflake
- SAP
- Teradata
- Google BigQuery
- IBM Db2
- Oracle Autonomous Data Warehouse

데이터 엔지니어링

- Hadoop
- Amazon EMR
- Google Dataproc
- Apache Airflow
- Apache Spark
- Cloudera

스트리밍

- Apache Kafka
- Apache Flink
- Azure Stream Analytics
- Tibco Spotfire
- Apache Spark
- Amazon Kinesis
- Google Dataflow
- Confluent

DS & ML

- Jupyter
- Azure ML Studio
- Domino Data Labs
- TensorFlow
- Amazon SageMaker
- MatLAB
- SAS
- PyTorch

연결되지 않은 시스템 및 독점적 데이터 포맷은 통합 난이도를 높임

사일로화된 기술 스택 때문에 점점 더 복잡해지는 데이터 아키텍처

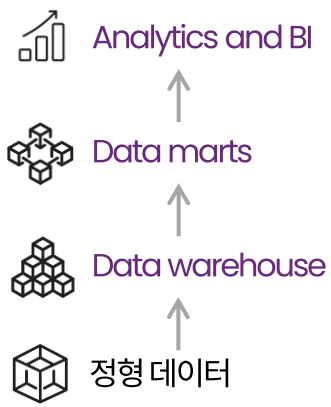

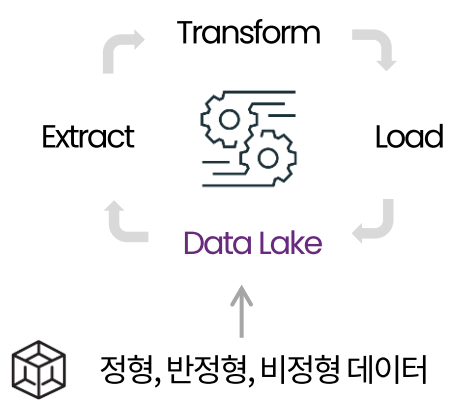

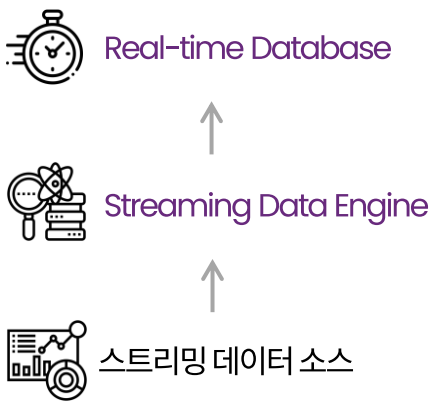

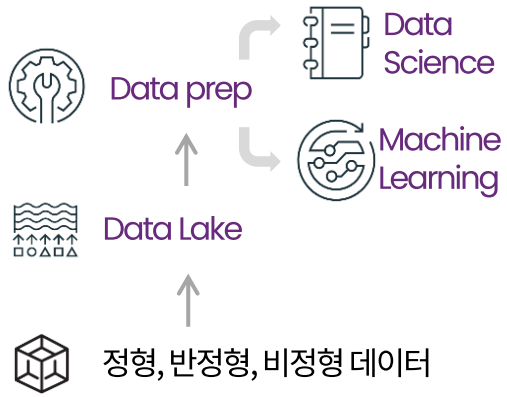

데이터 활용 문제

데이터 웨어하우징 | 데이터 엔지니어링 | 스트리밍 | DS & ML

사일로화된 데이터 팀의 생산성 감소, 협업 난이도 상승

Data Analytics

Data Engineer

Data Engineer

Data Sclentist

연결되지 않은 시스템 및 독점적 데이터 포맷은 통합 난이도를 높임

Amazon Redshift	Teradata
Azure Synapse	Google BigQuery
Snowflake	IBM Db2
SAP	Oracle Autonomous Data Warehouse

Hadoop	Apache Airflow
Amazon EMR	Apache Spark
Google Dataproc	Cloudera

Apache Kafka	Apache Spark
Apache Flink	Amazon Kinesis
Azure Stream Analytics	Google Dataflow
Tibco Spotfire	Confluent

Jupyter	Amazon SageMaker
Azure ML Studio	MatLAB
Domino Data Labs	SAS
TensorFlow	PyTorch

사일로화된 기술 스택 때문에 점점 더 복잡해지는 데이터 아키텍처

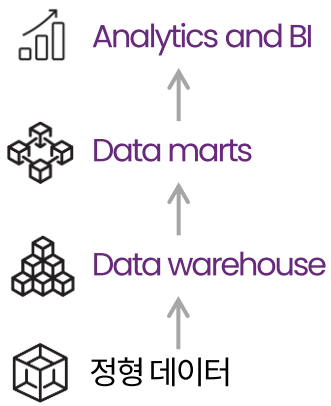

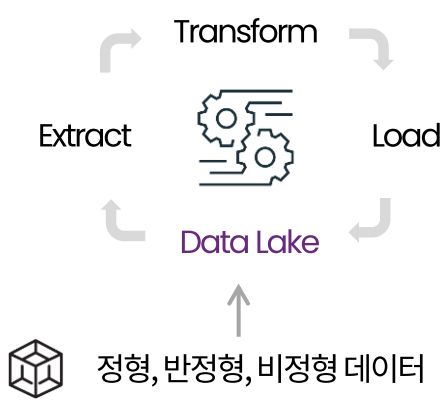

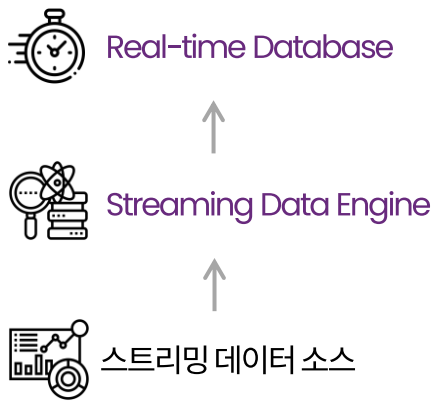

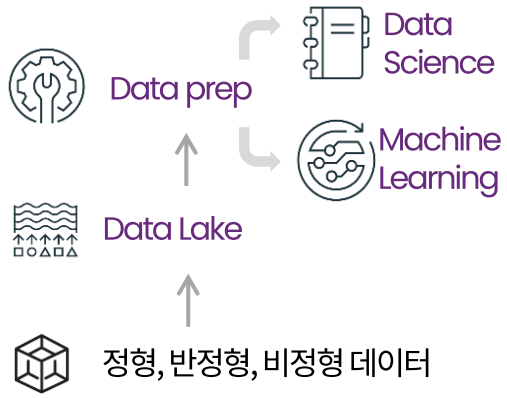

LakeHouse??

Data Warehouse

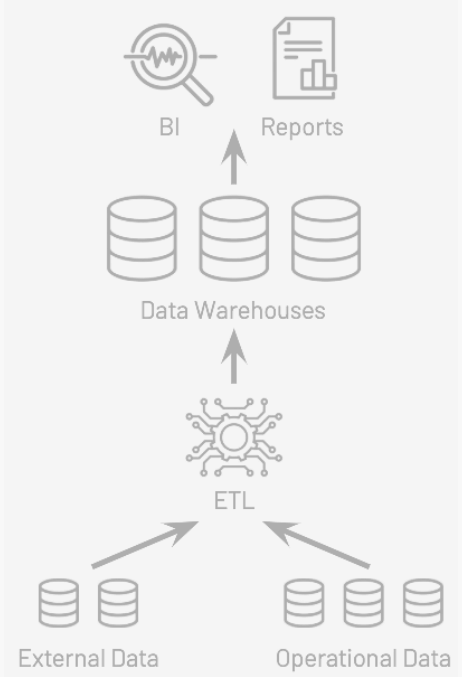

성능, 관리성, 편의성

Data LakeHouse

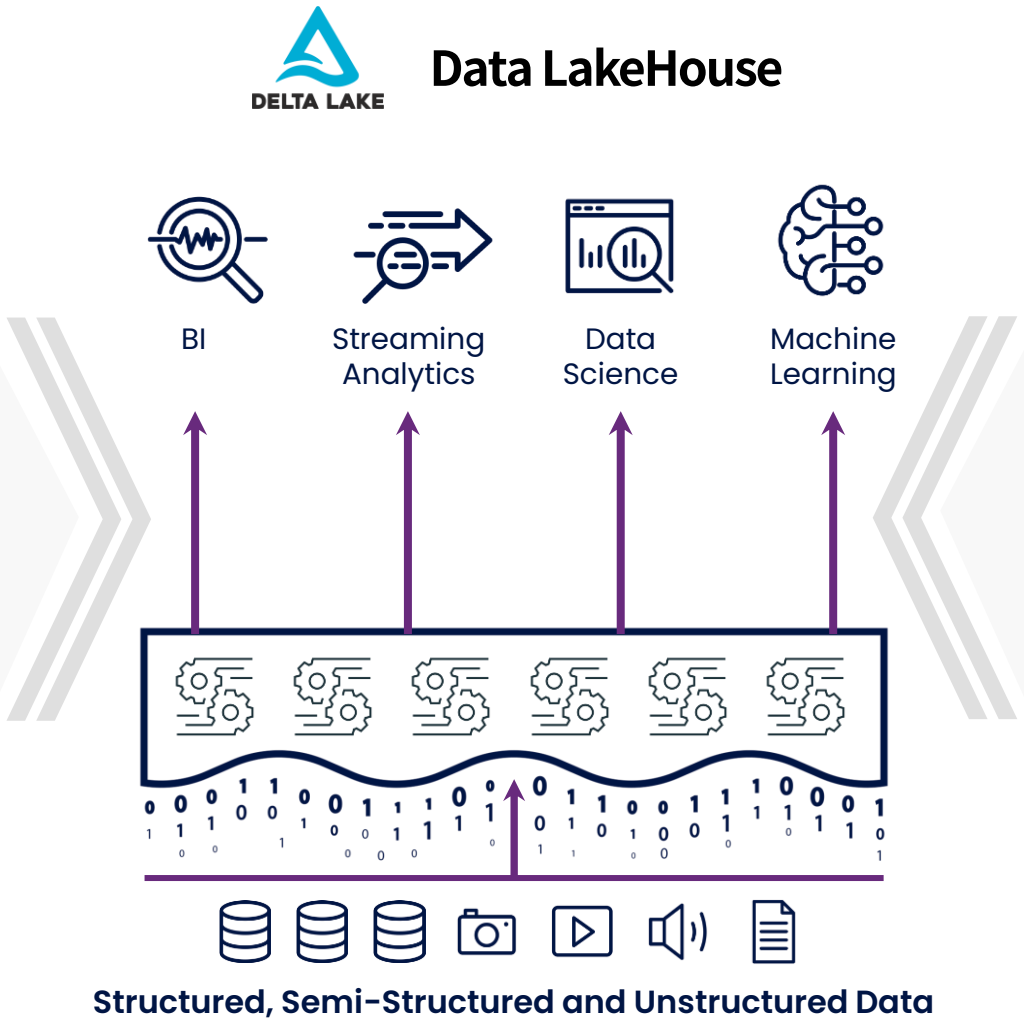

Data Lake

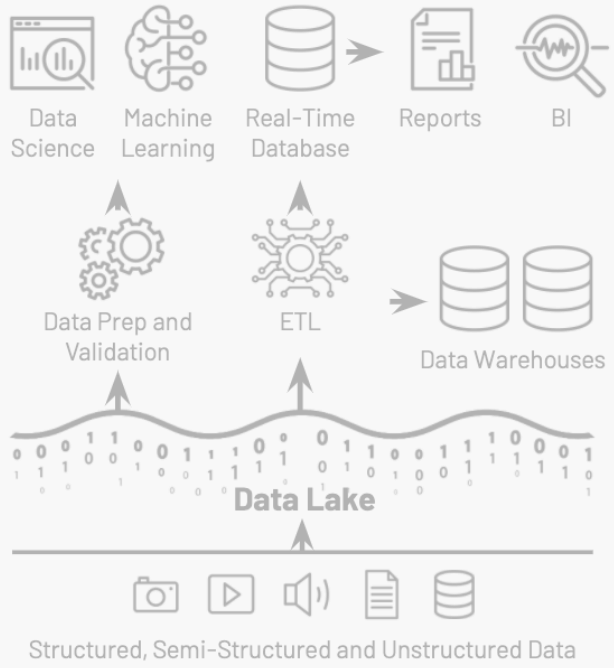

확장성, 낮은 비용, 개방성

Delta Live Table

Delta Live Tables understands and coordinates data flow between your queries

SQL, Python, R, Scala 등 Spark Engine 기반의 언어를 사용하여 ETL PIPELINE을 생성 및 관리

Delta Live Tables Pipeline

```
CREATE LIVE TABLE raw_data as SELECT * FROM cloud_files("/data","json")
```

```
CREATE LIVE TABLE clean_data as SELECT ... FROM LIVE. raw_data
```

```
@dlt.table
def scord_records():
return read("clean_data").map(lambda d: model_score(d))
```

Data

raw_data → clean_data → scored_records

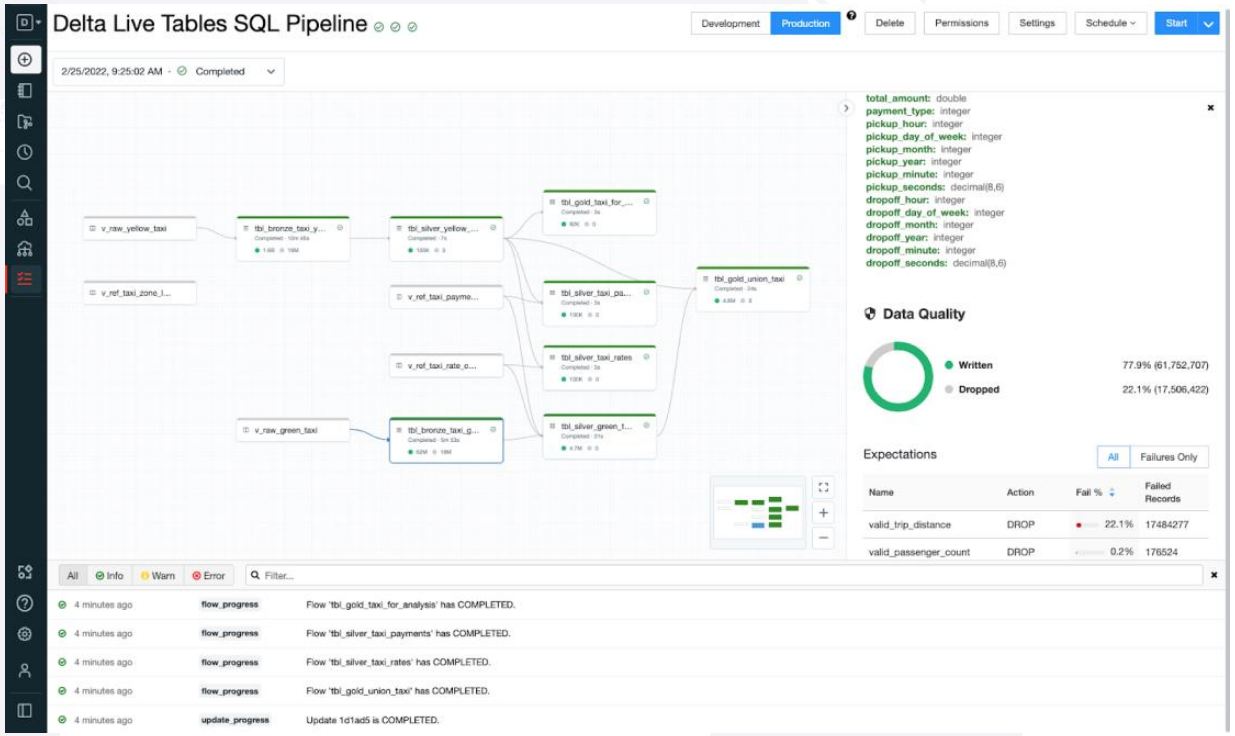

각 Flow 별 데이터 의존성을 확립할 수 있음 (ex : Apache Airflow)

Demo

- Delta Live Table Demo

Thank you!

Cloócus