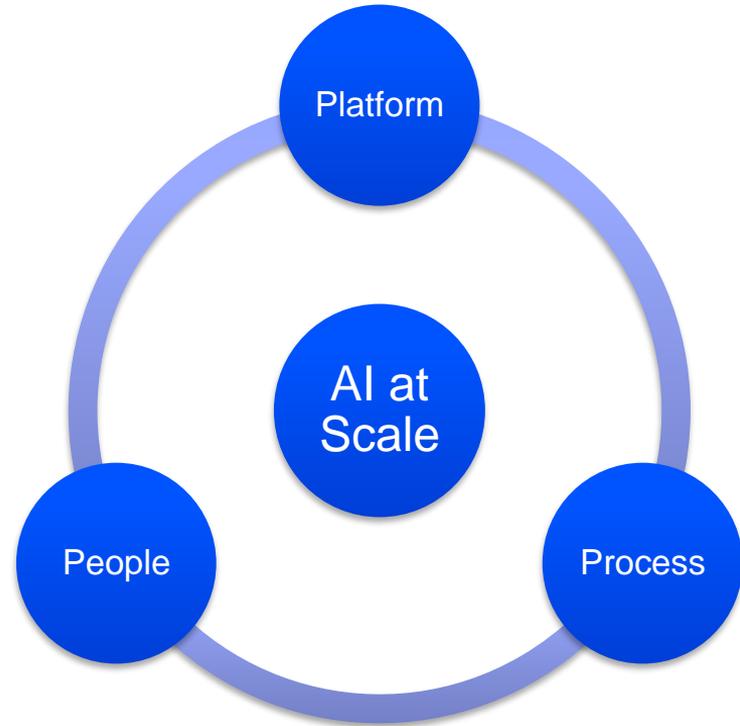


데이터 통합 관리 플랫폼으로 만나는 AI

Cloud Pak for Data



2021, Apr
Data & AI
JeongKwon Lee (jkwonl@kr.ibm.com)

시장 동향

CIO는 **인프라구조에 대한 현대화** 필요하다고 생각합니다.

cannot be achieved by **lifting and shifting** applications...

인프라구조
현대화를
시도하는
이유



Source: McKinsey expert interviews (N=52)

CEO는 **디지털 혁신을** 최 우선 순위로 여기고 있습니다.

to jump start **growth, speed** time to market, and foster **innovation**...

84%

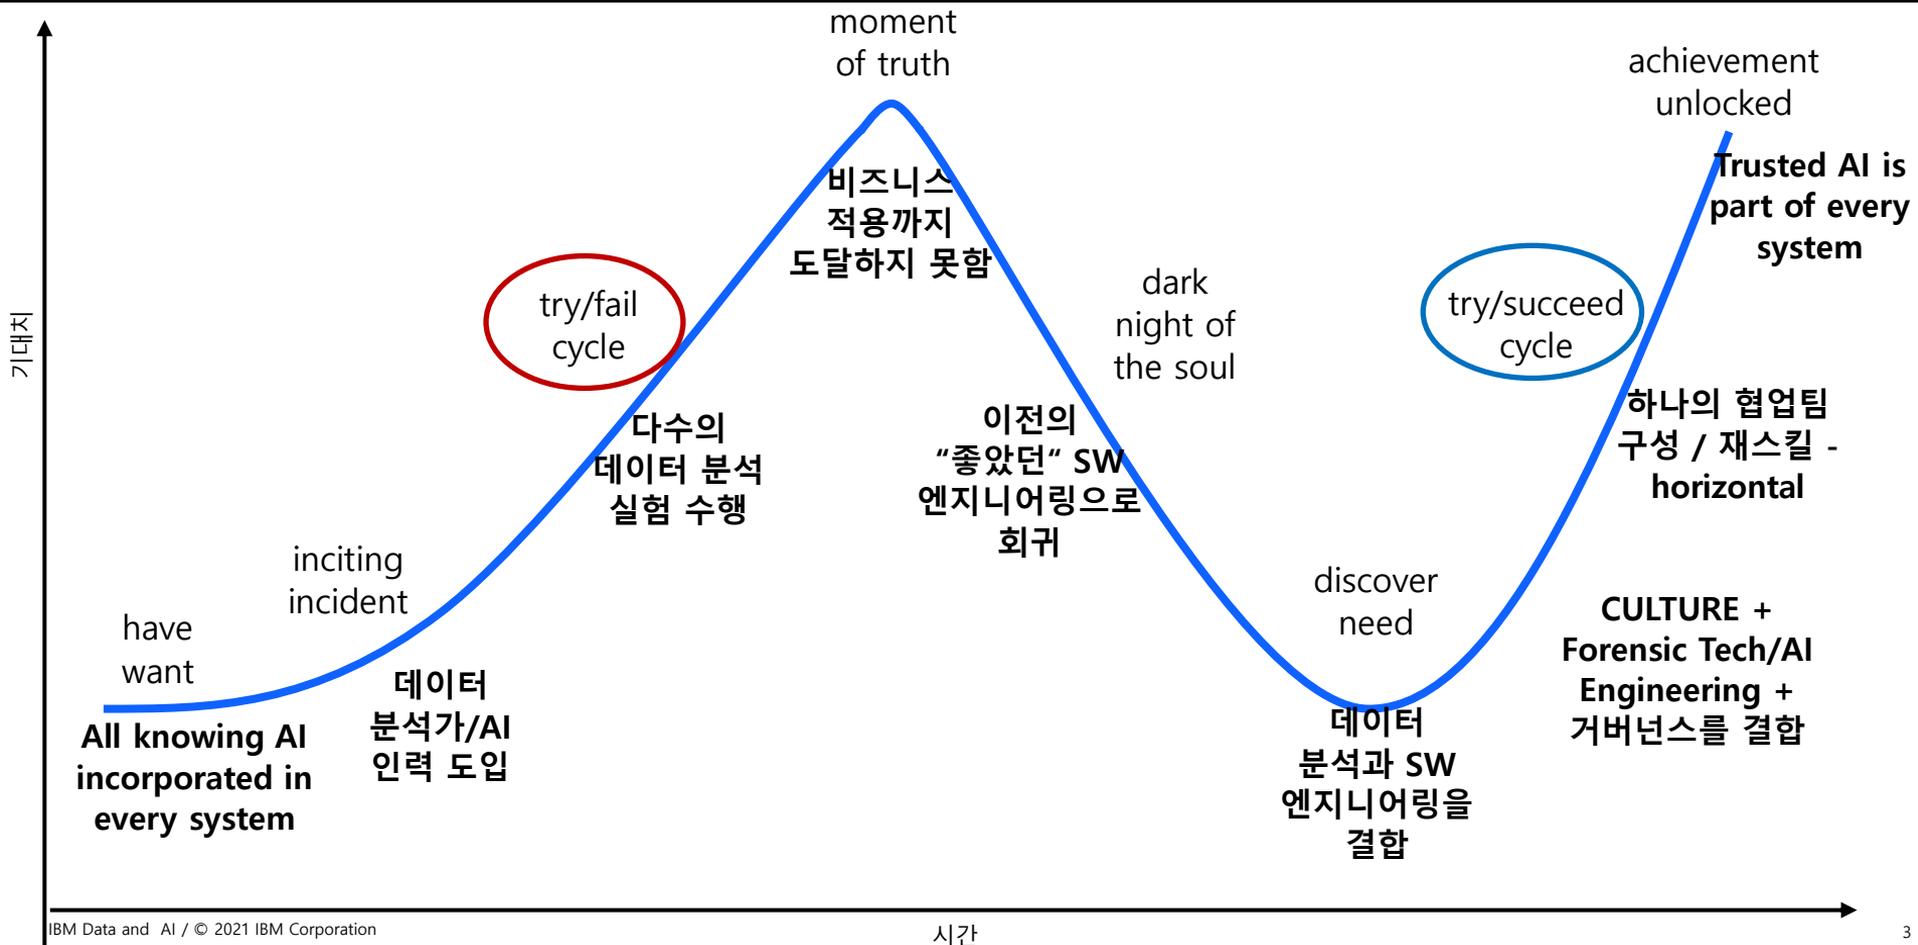
의 글로벌 리더들은 **AI의 확산** 없이는 성장 목표를 달성할 수 없다고 말하고 있습니다.

75%

의 글로벌 리더들은 **AI의 활용** 없이는 5년 내에 비즈니스 리스크에 직면한다고 생각하고 있습니다.

Source: Accenture, "AI – Built to Scale" Report (October 2019)

A typical AI story arc



초기 단계의 AI/ML model 생성은 다음과 같이 보입니다...

Build AI assets

Connect data

Analyze data

Prepare data

Build models

Train models

Visualize & evaluate
models

Test for Bias,
Fairness



Data
engineer



Data
scientist

But this is not the
complete AI lifecycle!

AI 운영을 위한 단계들



Scope AI project(s)

Explore, prioritize, select use cases – feasibility vs impact

Detail selected use case(s) – KPIs, data, workflow, success criteria

Technical design: tools, infrastructure, data details, approach

DataOps

All: Define sources & needs

Provider: Set up catalog for discovery, lineage, curation, access rules

Steward: Create data policies & access

Consumer: Find, understand, add, explore, review, share

Build AI assets

Connect data

Analyze data

Prepare data

Build models

Train models

Visualize & evaluate models

Test for Bias, Fairness

ML Ops – Deploy

Review, 3rd party oversight, unit tests, validation, approve deployable version

Deploy model to ML runtime engine

Monitor & evaluate model execution

Manage against thresholds

Validation reports

Manage and Trust

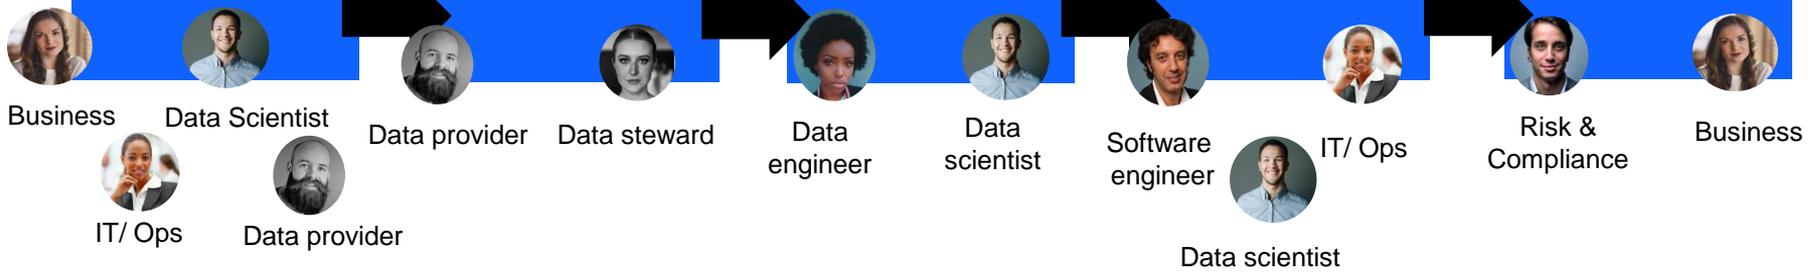
Configure monitoring

Configure integration with other systems

Monitor and manage:

1. Quality
2. Performance
3. Custom metrics
4. Bias/fairness
5. Accuracy & Data Drift

Explain on demand



There is no AI without IA

Artificial
Intelligence

Information
Architecture

“ No amount of AI algorithmic sophistication will overcome a **lack of data** [architecture]

Data collection & preparation is the most time consuming and **difficult part of AI**



MIT Sloan

”

Sources: 2018 MIT Sloan Report “Reshaping business with AI”

Data-AI 통합 플랫폼 요구 사항

최근의 데이터와 AI는 상호 유기적인 관계로 빠르게 변화하는 비즈니스에 민첩하게 대응하기 위해서 다음과 같은 요구사항들을 필요로 하고 있습니다.



플랫폼 현대화

Cloud Native,
Kubernetes

- 디지털 혁신을 위한 **빠른 provisioning** 과 **확장** 가능한 플랫폼
- 환경 변화 대응을 위한 **Hybrid Multi Cloud** 지원
- 다양한 요구 사항을 수렴할 수 있는 **컨테이너 기반 플랫폼**



데이터 관리

컴퓨팅과
스토리지 분리

- 정형/비정형을 포함한 분석에 필요한 **데이터의 Hub 역할**을 위한 **데이터 저장소** 구축
- 컴퓨팅과 스토리지 영역을 분리하여 업무 증가 및 워크로드에 따른 **유연한 확장성** 제공



데이터 거버넌스

Data Catalog,
Self-Service

- 데이터 생산자와 소비자 간의 협업을 위한 **DataOps** 지원
- 비즈니스를 위한 데이터 준비를 위해 **거버넌스 체계**
- 셀프 서비스 분석을 위한 **데이터 디스커버리 환경**

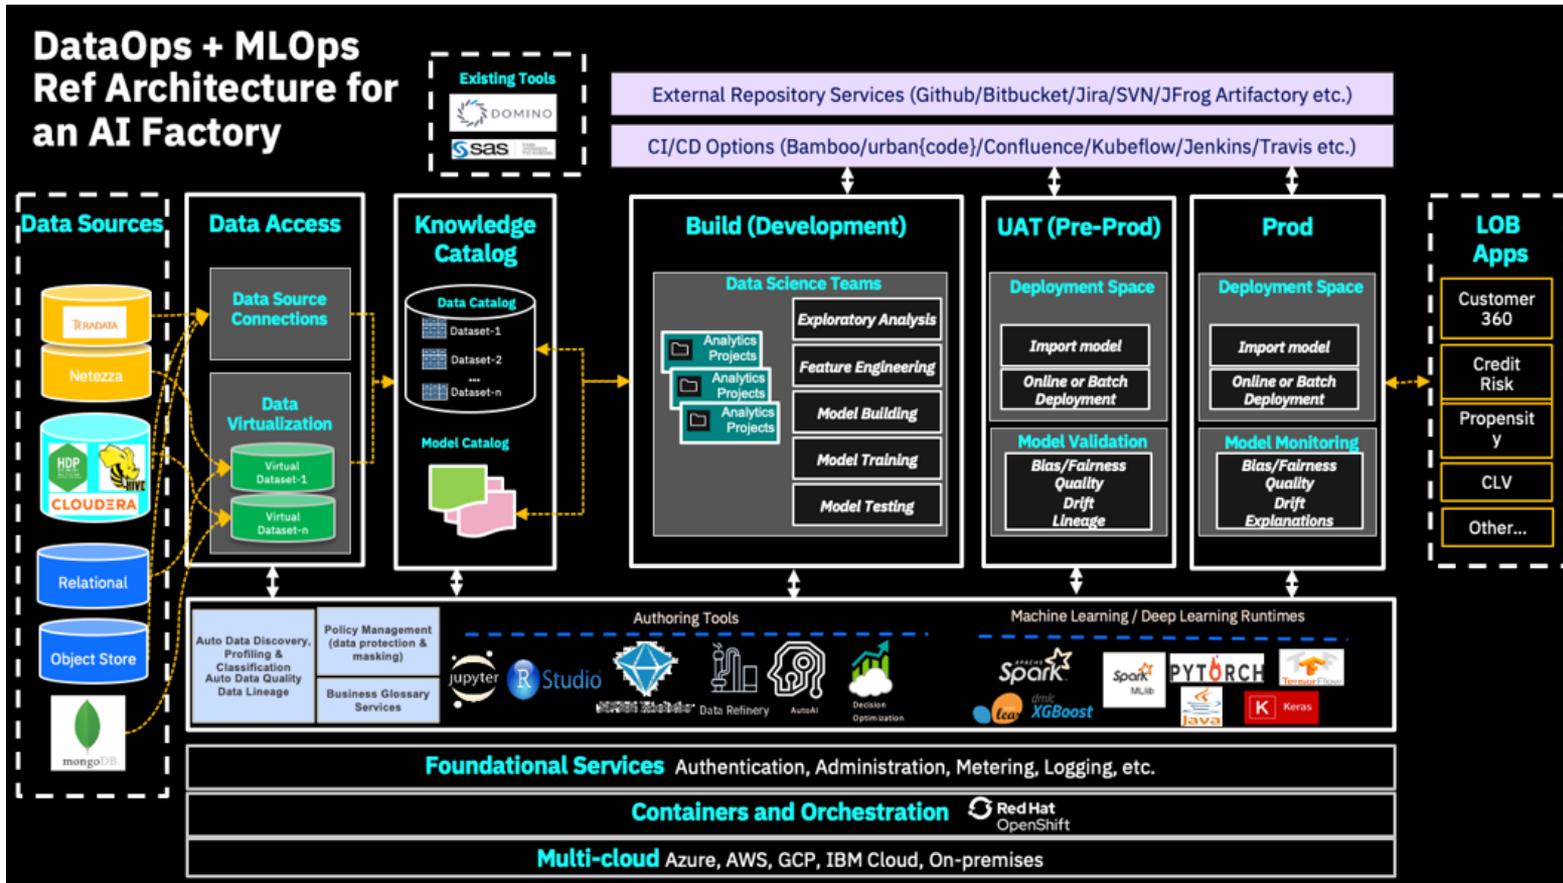


AI 운영 관리

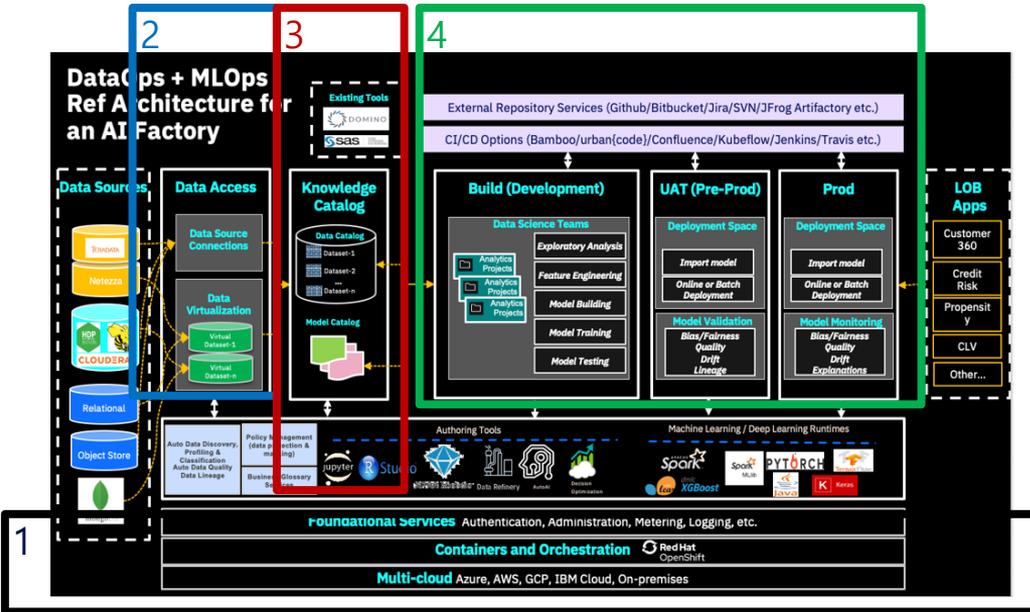
Operationalize
Data Science & AI

- 분석 모델 생성, 관리, 거버넌스를 포함하는 **AI 운영**을 위한 기술 도입
- 개방성과 최신 트렌드 반영을 위해 **오픈 AI 기술 반영**
- 분석 모델의 효율성을 높이기 위한 **Auto AI** 기술 활용

AI를 위한 Reference Architecture



AI를 위한 Reference Architecture > 아키텍처 구현 시 고려 사항



1 플랫폼 현대화 : 컨테이너 기반 아키텍처를 통해 하이브리드 멀티 클라우드 지원하고 다양한 기능들을 통합하여 관리할 수 있는 통합 플랫폼 역량 필요

2 데이터 현대화 : 컴퓨팅 영역과 스토리지 영역을 분리를 통해 유연성과 확장성을 확보 (고성능 데이터 마트를 위해서는 일체형 또는 on-premise 형태로 구축하는 것이 유리합니다.)

3 데이터 거버넌스 : DataOps (메타 데이터 관리, 데이터 카탈로그, 데이터 리니지, 검색 등)를 통해 데이터의 품질 확보 및 거버넌스 체계 수립

4 AI 운영 관리 : MLOps (ML/DL 라이프 사이클 관리 - 모델 생성, 배포, 운영, 모니터링)를 통해 AI 거버넌스 환경 구축

플랫폼 현대화 Cloud Native, Kubernetes	데이터 현대화 컴퓨팅과 스토리지 분리	데이터 거버넌스 Data Catalog, Self-Service	AI 운영 관리 Operationalize Data Science & AI

Cloud Pak for Data – End-to-End Data-AI 플랫폼

Cloud Pak for Data는 AI 플랫폼 구현에 필요한 여러 구성 요소들을 MSA 기반으로 구현하여 필요한 서비스만 선별적으로 선택하여 구성하는 것을 지원합니다.

플랫폼 현대화
Cloud Native,
Kubernetes

데이터 현대화
컴퓨팅과
스토리지 분리

데이터 거버넌스
Data Catalog,
Self-Service

AI 운영 관리
Operationalize
Data Science & AI



App 개발자 | 비즈니스 파트너 | 데이터 엔지니어 | 데이터 스튜어드 | 데이터 분석가 | 비즈니스 사용자

확장성 : APIs, 파트너 에코 시스템, 가속기, 솔루션

Collect

- 데이터 가상화
- SQL/NoSQL 저장소
- 이벤트 수집
- 스트리밍 분석
- 동적 스파크 클러스터

Organize

- 데이터 가공
- 데이터 품질 / 분류
- 정책 / 룰
- 데이터 카탈로그
- 셀프 서비스 탐구 / 분석

Analyze and Infuse

- 비즈니스 리포팅
- 데이터 분석과 시각화
- AI 라이프 사이클 자동화
- AI Apps
- 인더스트리 가속기

필요한 서비스를
선별적으로
선택하여 구성
가능

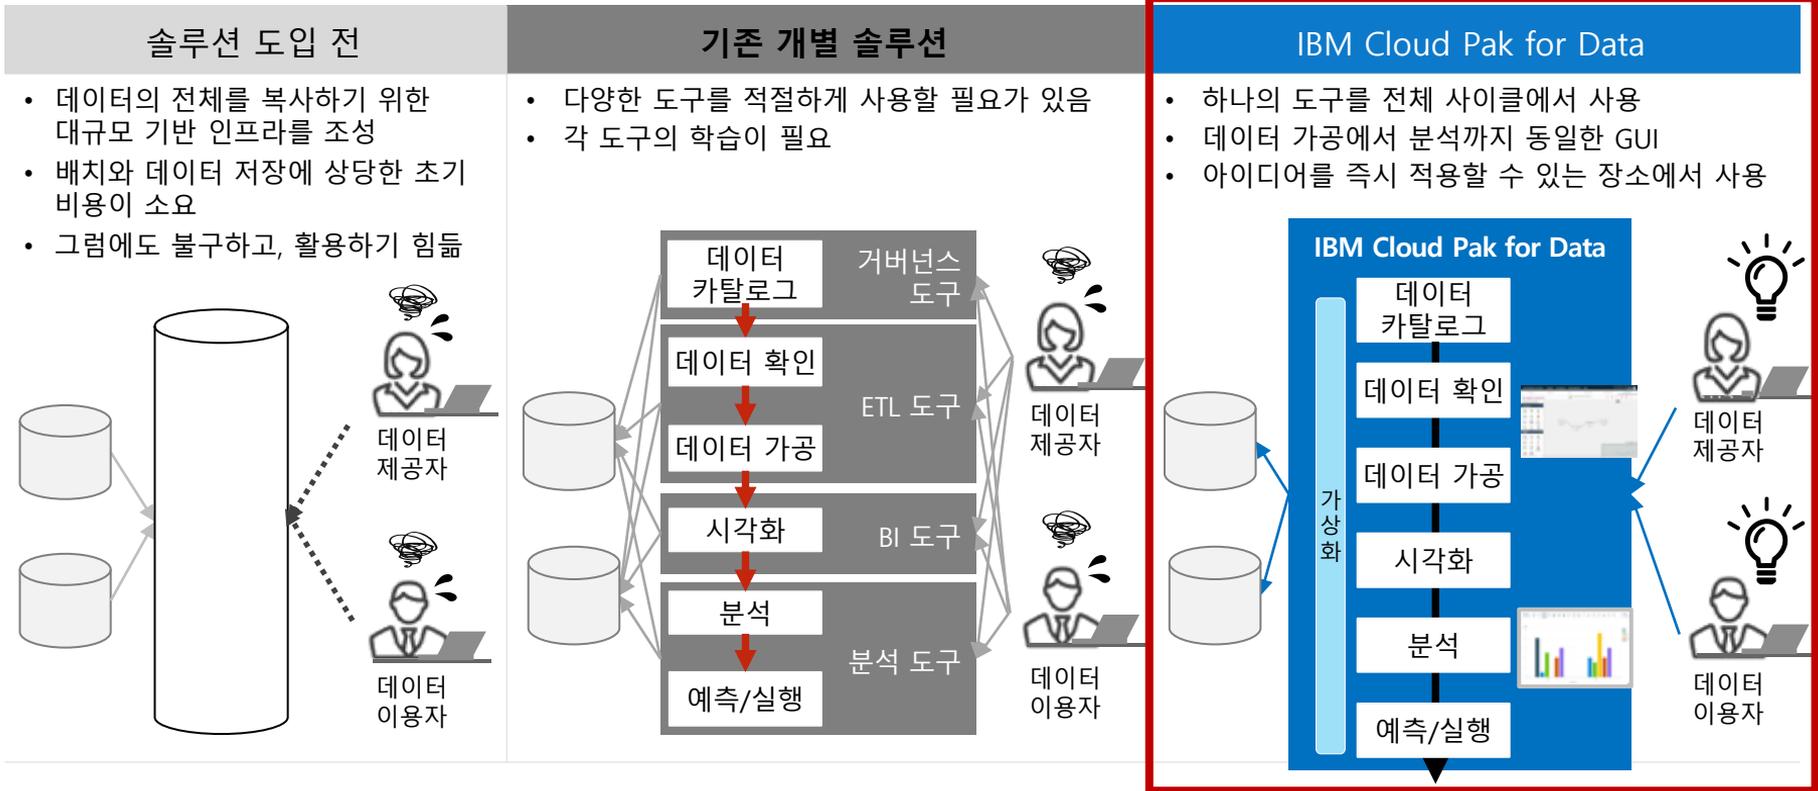
주요 서비스

- 사용자 접근 관리
- 보안 관리 / RBAC
- 볼륨 관리
- 모니터링 / 미터링
- 서비스 프로비저닝
- 오퍼레이터
- 모니터링 / 진단
- 백업 / 이관

Red Hat OpenShift

IBM Cloud | AWS | MS Azure | Google Cloud | Hyperconverged system

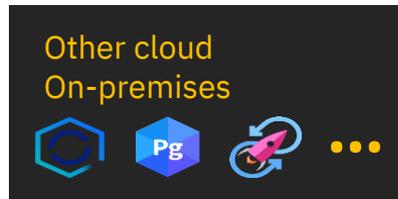
지금까지의 분석 솔루션은 다양한 도구를 사용했기 때문에 데이터 제공자와 이용자는 별도의 노력과 시간이 필요했으나, IBM Cloud Pak for Data는 기존의 분석 솔루션 개념을 재정의하여 **단일 GUI에서 전체 분석 사이클을 지원하고 최적화합니다.**



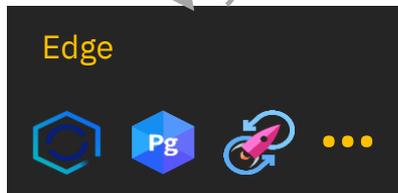
플랫폼 현대화 > anywhere, Distributed Analytics



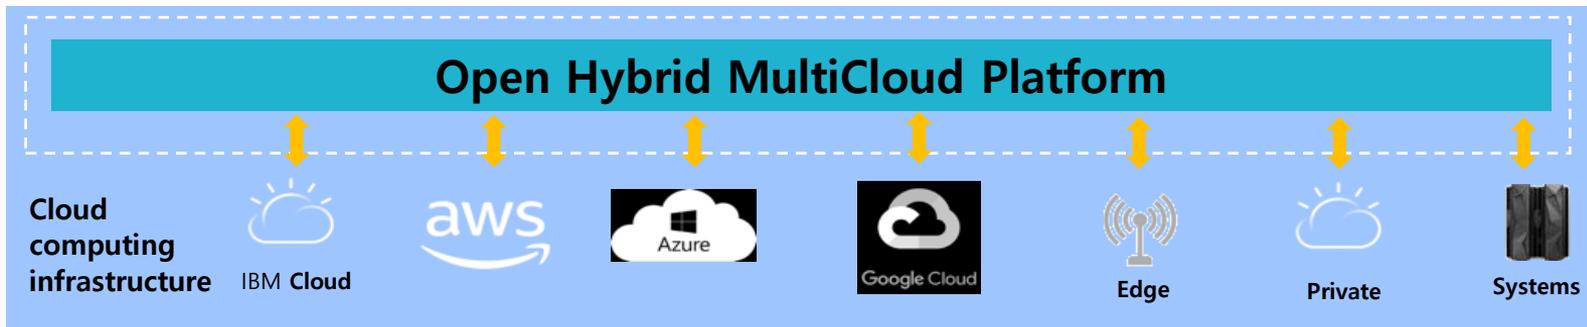
IBM Cloud Pak for Data는 특정 플랫폼 환경에 종속되지 않고, 다양한 인프라에 데이터 자산을 활용할 수 있도록 멀티 클라우드 환경을 지원하고, 데이터 있는 곳에 분석이 수행되는 **Distributed Analytics**을 지원하고 있습니다.



IBM Cloud Satellite enables analytics consistency to siloed, disparate data sources



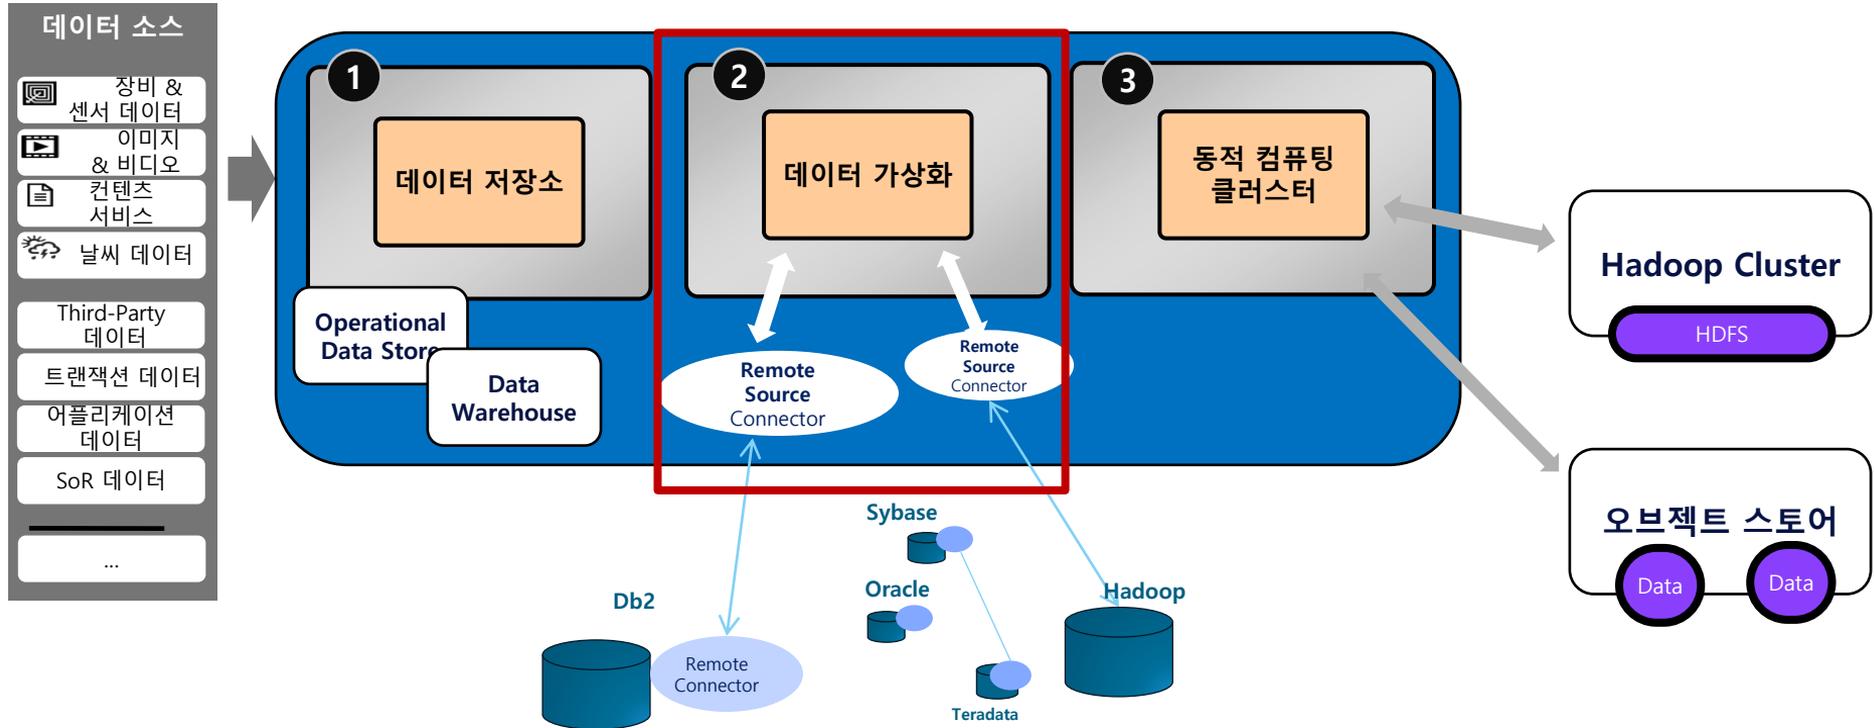
Streaming data – deploy local containerized, elastic analytics via IBM Cloud Satellite



데이터 현대화 > 다양한 데이터 처리 방안

다양한 데이터 유형과 소스 및 워크로드를 지원하기 위해서는

다양한 데이터 처리 방안 (1 : 데이터 저장소 구현, 2 : 데이터 가상화 구현, 3 : 동적 컴퓨팅 클러스터 환경)이 필요합니다.



데이터 현대화 > 데이터 가상화

IBM Cloud Pak for Data는 기업 내/외부에 산재해 있는 다양한 데이터 소스들에 대해 데이터 가상화 기술을 통해 단일화된 Single Access Point을 제공하여 데이터 접근 가능성을 높여 줍니다.

가상화 장점

- 데이터 복제가 필요 없어 데이터 중복이 발생하지 않아 스토리지 비용 절감
- **Single Data View**를 제공하여 사용자들은 데이터 소스의 위치를 고려할 필요 없음
- 실시간 데이터 액세스가 가능하여 빠른 인사이트 지원
- 캐싱 기능을 통해 On-demand 가상 데이터 마트 구성 지원
- 데이터가 있는 곳으로 작업을 **Push Down**하여 기존 데이터 이동 방식 대비 빠른 성능

소스 연결

데이터 가상화

성능을 위한 캐시

Single View SQL 조회

Table 1: STOCK_TRANSACTIONS_CUSTID

Column Name	Data Type
<input checked="" type="checkbox"/> CUSTID	INTEGER
<input checked="" type="checkbox"/> PRICE	DECIMAL
<input checked="" type="checkbox"/> QUANTITY	INTEGER
<input checked="" type="checkbox"/> SYMBOL	<input checked="" type="checkbox"/> VARCHAR
<input checked="" type="checkbox"/> TX DATE	DATE

Cache storage

- 100.0 GB AVAILABLE
- Active data caches 0.0 KB
- Inactive data caches 0.0 KB

Responsiveness 14 TOTAL QUERIES

SQL editor

```

*Untitled - 1 | Ohio Customers |
1 -- Ohio Customers
2 WITH MAX_VOLUME(AMOUNT) AS (
3   SELECT MAX(VOLUME) FROM FOLDING_STOCK_HISTORY
4   WHERE SYMBOL = 'OZJA'
5 )
6 HIGHDATE(TX_DATE) AS (
7   SELECT TX_DATE FROM FOLDING_STOCK_HISTORY, MAX_VOLUME
8   WHERE SYMBOL = 'OZJA' AND VOLUME = M.AMOUNT
9 )
10 CUSTOMERS_IN_OHIO(CUSTID) AS (
11   SELECT C.CUSTID FROM TRADING_CUSTOMERS C
12   WHERE C.STATE = 'OH'
13 )
14 TOTAL_BUY(CUSTID,TOTAL) AS (
15   SELECT C.CUSTID, SUM(SH.QUANTITY * SH.PRICE)
16   FROM CUSTOMERS_IN_OHIO C, FOLDING_STOCK_TRANSACTIONS SH,
17   WHERE SH.CUSTID = C.CUSTID AND
18   SH.TX_DATE = HO.TX_DATE AND
19   QUANTITY > 0
    
```

LASTNAME TOTAL

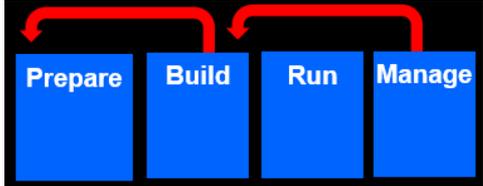
Noble	12242.05
Wynn	8548.02
Cherry	6763.50
Hurley	5121.76
Lara	4759.64

데이터 거버넌스 > DataOps의 필요성

기업은 하이브리드 통합 거버넌스 모델을 기반으로 신뢰성 있는 분석 기초를 세워 비즈니스 프로세스에 효율성과 투명성을 가져와 정보 자산에 대한 통찰력을 높이고 규제 준수를 강화할 수 있습니다.

- ### 데이터 관련 기업의 Challenge
- ✓ 인사이트 및 예측 불가
 - ✓ **Garbage성 데이터의 존재**
 - ✓ 새로운 유형의 데이터 소싱의 어려움
-
- ✓ 고가의 데이터 소유 비용
 - ✓ Data Lake의 부재
 - ✓ **데이터 준비에 장시간 소요**
 - ✓ **데이터 사일로 (Silos)**
-
- ✓ 방화벽 내/외부의 데이터
 - ✓ **기존 데이터의 신뢰 및 품질 문제**
 - ✓ 점점 더 많아지는 규제 및 준수 사항
 - ✓ **개인 정보 보호**

with DataOps
(DevOps for Data + Data Operations)



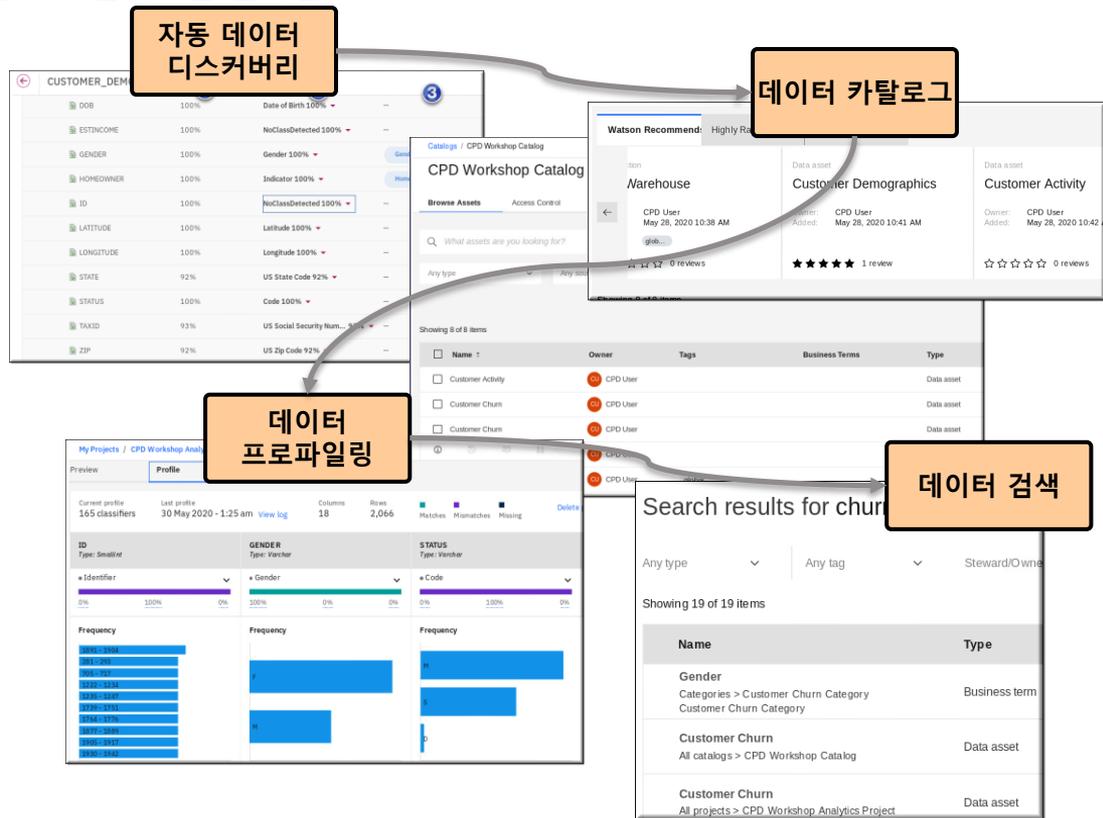
데이터 거버넌스 > 자동 디스커버리/카탈로그



IBM Cloud Pak for Data는 머신 러닝 기반의 자동화 알고리즘을 통해 데이터의 품질/메타 정보/계보/카탈로그 등을 통해 데이터 소비자에게 신뢰 있는 데이터를 제공하여 분석의 신뢰도를 높여줍니다.

자동 디스커버리/카탈로그 장점

- 자동 디스커버리와 데이터 프로파일링을 통해 **데이터의 품질 확보**
- 자동 데이터 분류 기능을 통해 비즈니스 메타와 자동 매핑을 수행하여 **거버넌스 비용 감소**
- 데이터 소스와 사용자 간의 데이터 게이트 웨이 역할을 수행하여 **데이터 사용 추적 용이**
- 데이터 카탈로그와 데이터 검색 기능을 제공하여 **셀프 서비스 분석 환경 지원**



분석 모델의 개발에서 모델의 배포 및 관리, 모델의 성능 유지를 위한 모니터링까지 반복적인 모델 작업의 자동화를 위한 **AI 라이프 사이클**에 대한 관리를 지원해야 합니다.

Trusted AI를 위한 Challenge

Bias



학습 데이터와 AI 모델은 편향되어질 수 있습니다.

Quality



AI/ML 라이프 사이클 동안 잘 관리되어야 합니다.

Drift



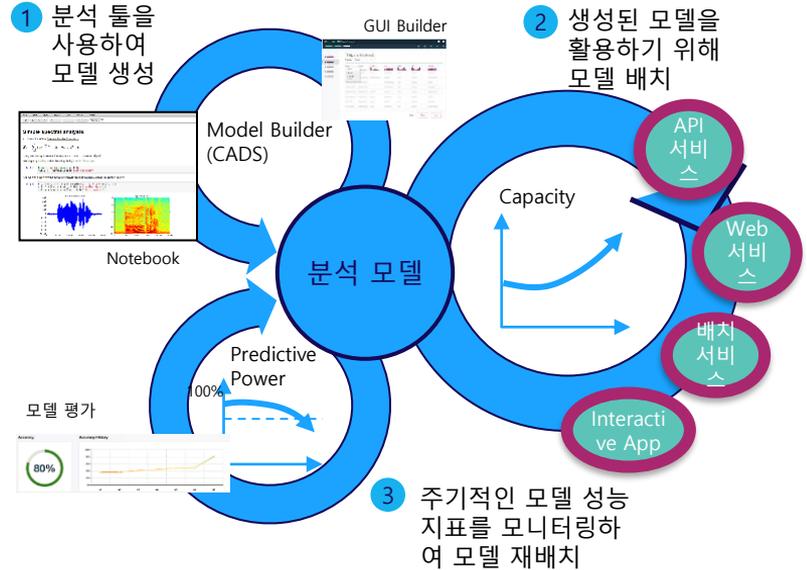
입력 데이터의 변화가 모델에 부정확한 결과를 야기할 수 있습니다.

Explainability



전통적인 통계 모델은 해석 및 설명이 단순합니다.

AI 라이프 사이클 관리 통합 스택 구현



AI 운영 관리 > AutoAI



IBM Cloud Pak for Data의 AutoAI는 AI를 위한 AI 기능으로 수 주에서 수 개월이 소요되는 모델 분석 과정을 수 분 내에 수행할 수 있게 해 주어 개발 생산성을 향상시킵니다.

AutoAI 장점



자동 데이터 준비와 모델 개발을 통해 **개발 생산성 향상**



코딩 없이 몇 번의 클릭으로 시작할 수 있어 **스킬 갭을 보완**



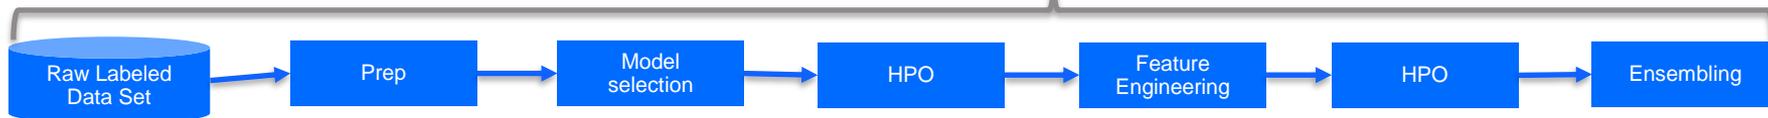
모든 곳에 AI를 활용할 수 있어 **더 많은 Use Case를 발굴**



자동 Feature Engineering을 통해 **주요 변수 예측력 증대**



파이프라인의 후보 모델 비교를 통해 **최적의 모델 선정**



AI 운영 관리 > 모델 모니터링 - OpenScale

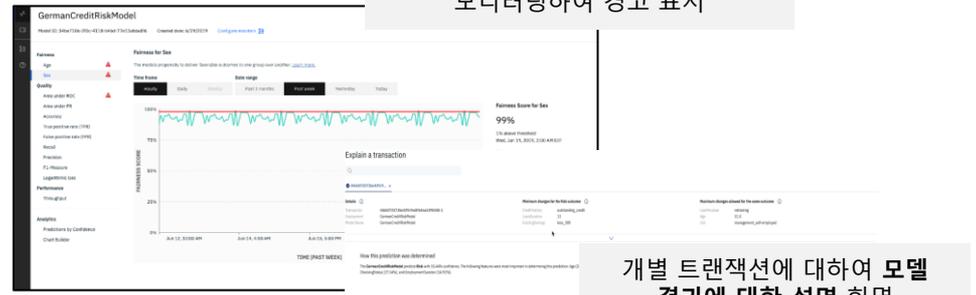


IBM Cloud Pak for Data의 Watson OpenScale은 Trusted AI를 위해 AI 모델 검증 및 모니터링 기능은 물론, payload 데이터를 기반으로 하여 더 나은 모델을 추천하는 기능도 지원하고 있습니다.

OpenScale 장점

- **Bias 편향성 감지** : Bias의 원인을 명확하게 밝히고, 이를 완화하기 위한 지표 및 데이터 제공
- **Explanability 설명성** : 개별 트랜잭션에 대한 이력 및 중요 속성에 대한 디테일을 포함하여 설명
- **Drift 이상현상 감지** : 시간이 지나면서 트레이닝 데이터와 실제 데이터 패턴과의 차이로 정확도가 떨어지는 것을 분석
- 무의식적 Bias를 좀 더 잘 이해할 수 있게 됨
- AI 도입 시 신뢰성을 제고

특정 Feature에 대하여 Bias가 있는지 모니터링하여 경고 표시



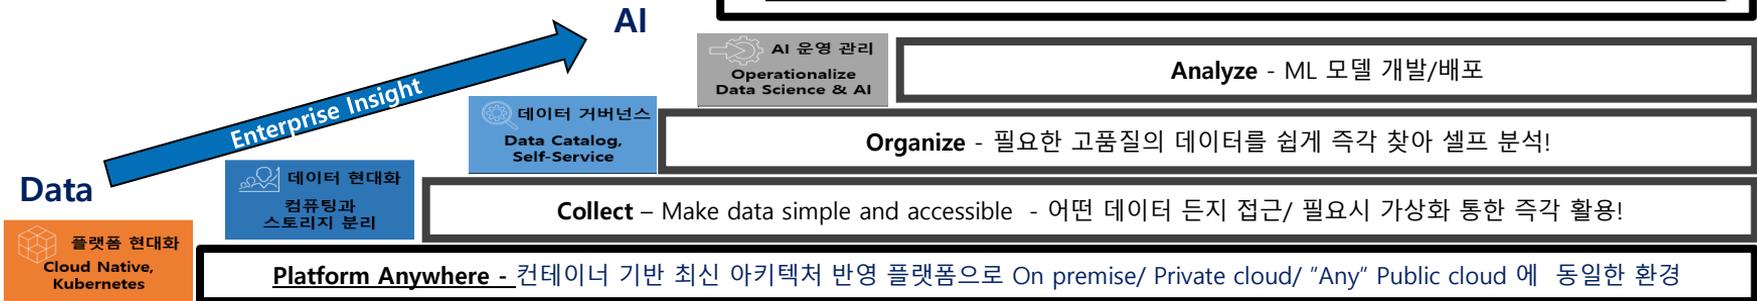
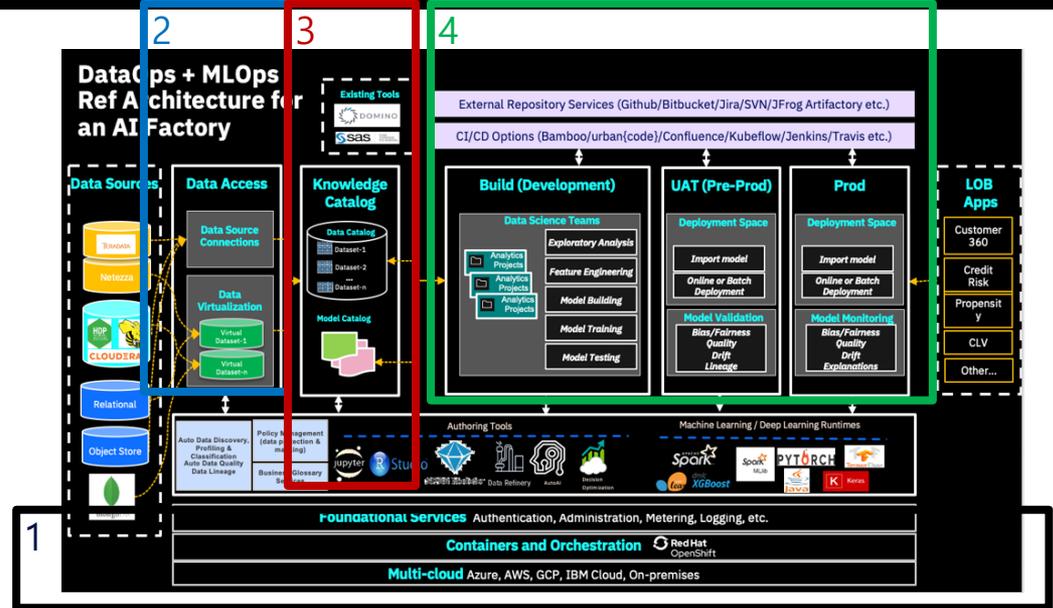
개별 트랜잭션에 대하여 모델 결과에 대한 설명 화면



갑작스런 성능 저하(Drift)와 관련하여 추이에 대한 그래프 및 통계 화면

Summary > 통합 플랫폼 구현

성공적인 AI 구현을 위해서는
 플랫폼/데이터의 현대화 + DataOps + MLOps가
 하나의 단일화된 환경으로 구성되는
통합 플랫폼 구현이 필수적입니다.



IBM®