머신 러닝을 위한 엔터프라이즈 DW 데모
IIAS with SparkML

강성희 실장
Korea Client Technical Professional

Hybrid Data Management Platform
Data & AI
IBM Korea

Data and AI Forum by IBM

Modernizing Data Warehouse Infrastructure (Checklist Report 2018. TDWI 인용)

- ✓ Diversify your portfolio of data platform to satisfy the data requirements of the modern warehouse
- ✓ Modernize your data warehouse with cloud and hybrid platform strategies
- ✓ Modernize data warehouse hardware for greater speed and scale, lower costs, and innovative best practices
- ✓ Coordinate data warehouse modernization with business modernization and analytics modernization
- ✓ Adjust data management best practice to fit modern data warehouse and analytics
- ✓ Leverage multivendor partnership

Analyzing with Spark :
Apache Spark Cluster 를 이용한 Modernization

Analyzing with Spark :
Apache Spark Cluster 를 이용한 Modernization

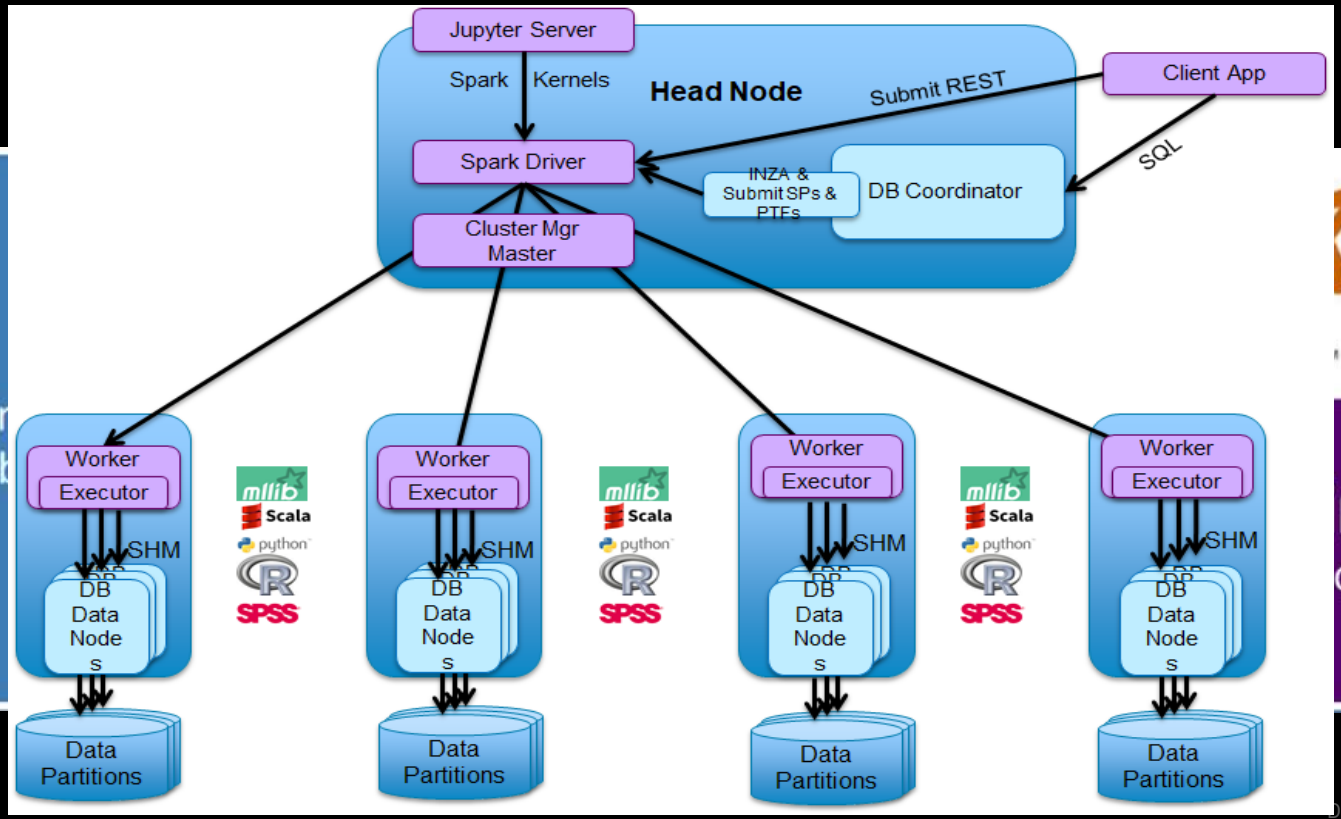

IIAS/Db2 Warehouse 에서 Spark 사용의 개요

- R/Python/Java/Scala with Spark 소스를 spark job submit tool, Stored Procedure, Rest API 를 사용하여 실행
- Spark 소스는 데이터베이스 내에서 데이터를 분석하고 결과를 다시 Table 로 저장함
- Spark Cluster 와 DBMS MPP 엔진이 각 노드별로 colocation 되어 있어 application 이 partition 별로 병렬처리하기에 이상적임

IIAS/Db2 Warehouse 내에서 Spark Application 접근 방법

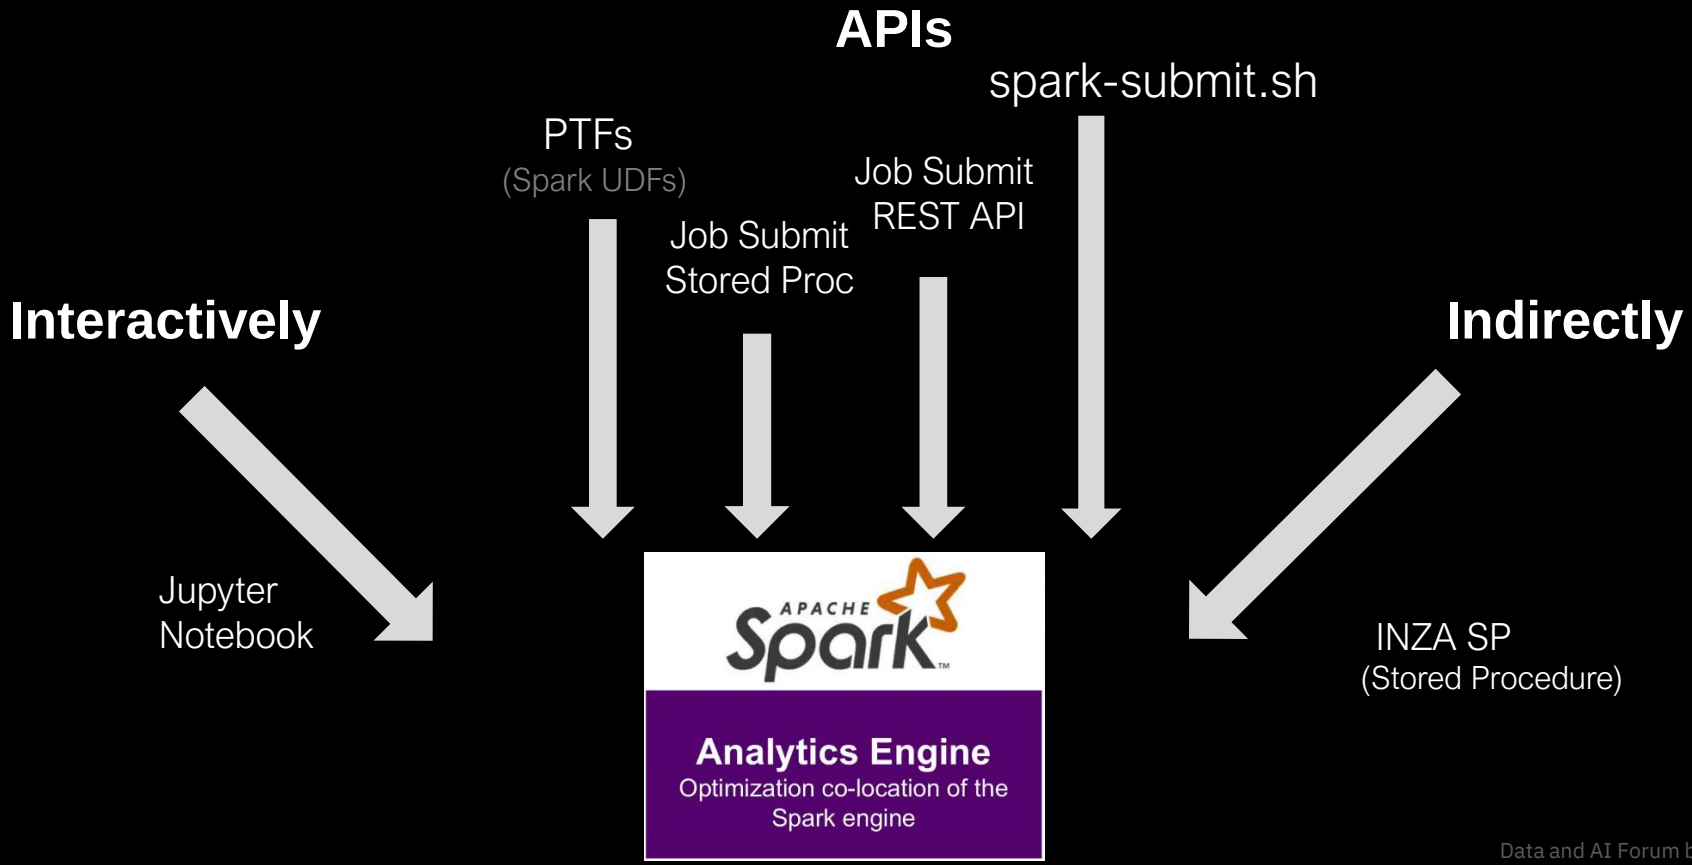

IIAS/Db2 Warehouse Spark 연동의 개요

- 데이터베이스 서버내에 Spark 연동 모듈과 엔진을 내장. 최근 많이 사용되는 오픈 소스 기반의 분석 을 수행

❑ Database 서버 내에서 별도 구성 없이 Spark 기반의 데이터에 예측모델, 머신 러닝 등을 수행 할 수 있다

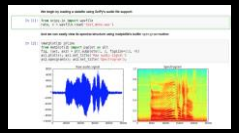

❑ 알고리즘을 SQL 인터페이스를 통해 Parallel/Scalable 한 환경에서 수행할 수 있다

❑ SQL 인터페이스에서 SP를 통한 머신러닝 Job 구동

❑ ELT에 활용하여 복잡한 데이터 추출, 변환, 저장 수행

❑ IoT 데이터 같은 스트리밍 소스 실시간 변경 / 데이터베이스 저장

❑ 최근 Object Storage에 저장하는 JSON, CSV, or Parquet 같은 데이터를 변환 처리, 저장

❑ Rest API를 통한 파이썬 데이터 처리 작업 수행processing via REST

데모시나리오 요약

Spark ML 수행

1) spark_submit.sh command line 호출
2) Stored Procedure 를 통한 호출
3) REST API 를 이용한 호출

모니터링

결과 확인

Job 수행 예>
1. spark-submit.sh 를 이용한 Job 호출

$ spark-submit.sh idax_example.jar --class com.ibm.idax.spark.examples.ReadWriteExampleKMeans

```
[bluadmin@node07 - Db2wh bin]$ ./spark-submit.sh ../examples/jars/idax_examples.jar --class com.ibm.idax.spark.examples.ReadWriteExampleKMeans
--- dashDB spark-submit.sh ---
Status: submitted
Description: The application was submitted.
Submission ID: 20190902010418365000
ExitCode:
Message:
```

Job 모니터링 예>
spark-submit.sh --list-app

$ spark-submit.sh --list-apps

```
[bluadmin@node07 - Db2wh bin]$ ./spark-submit.sh --list-apps
--- dashDB spark-submit.sh ---

SubmissionID            ApplicationID               Status
--------------------    ------------------------    -------
20190905033959200000    app-20190905034003-0000     running
20190903013806777000    app-20190903013810-0000     ended
20190903013951069000    app-20190903013954-0001     ended
20190904134209367000    app-20190904134213-0002     ended

[bluadmin@node07 - Db2wh bin]$ ./spark-submit.sh --list-apps
--- dashDB spark-submit.sh ---

SubmissionID            ApplicationID               Status
--------------------    ------------------------    -------
20190903013806777000    app-20190903013810-0000     ended
20190903013951069000    app-20190903013954-0001     ended
20190904134209367000    app-20190904134213-0002     ended
20190905033959200000    app-20190905034003-0000     ended
```

Job 모니터링 예>
Web console 모니터링

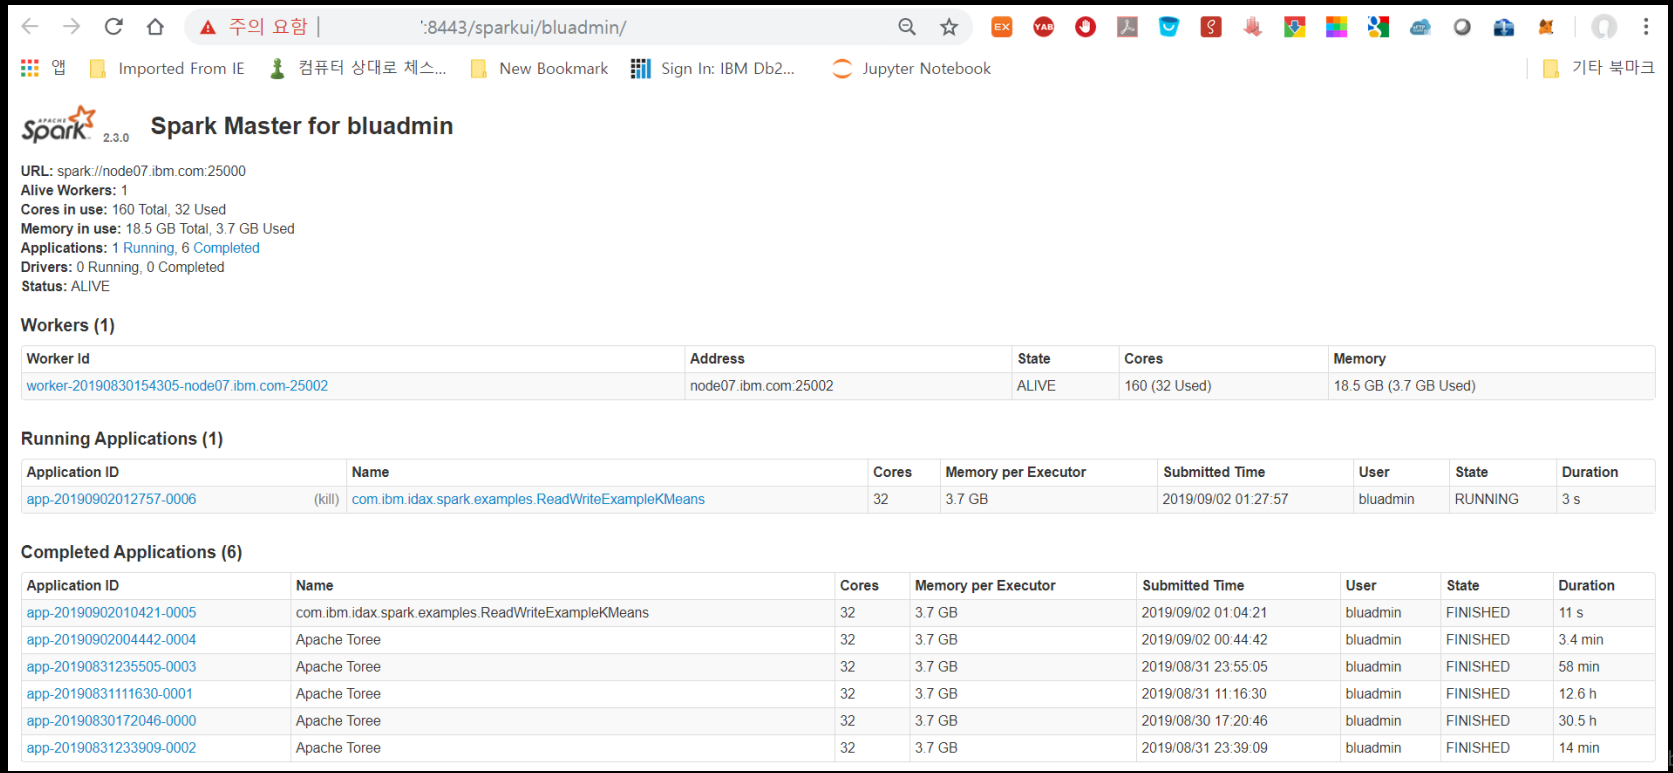

데모시나리오
2. SP 이용

db2 => CALL IDAX.SPARK_SUBMIT(?, 'appResource=idax_examples.jar | mainClass=com.ibm.idax.spark.examples.ReadWriteExampleKMeans');,

```
db2 => CALL IDAX.SPARK_SUBMIT(?, 'appResource=idax_examples.jar | mainClass=com.ibm.idax.spark.examples.ReadWriteExampleKMeans');

  Value of output parameters
  --------------------------
  Parameter Name  : SUBMISSION_ID
  Parameter Value : 20190905224617142000

  Return Status = 0
db2 => quit
```

데모시나리오
3. REST API 이용

$ curl -k --user "bluadmin":"bluadmin" -X POST "https://10.12.13.97:8443/dashdb-api/analytics/public/apps/submit" --header "Content-Type:application/json;charset=UTF-8" -d '{"appResource":"idax_examples.jar","mainClass":"com.ibm.idax.spark.examples.ReadExample"}'

```
[bluadmin@node07 - Db2wh bin]$ curl -k --user "bluadmin":"bluadmin" -X POST "https://10.12.13.97:8443/dashdb-api/analytics/public/apps/submit" --header "Content-Type:application/json;charset=UTF-8" -d '{"appResource":"idax_examples.jar","mainClass":"com.ibm.idax.spark.examples.ReadExample"}'

{"statusDesc":"The application was submitted.","submissionId":"20190905230600480000","exitInfo":{"code":"","details":[],"message":"","messageDB":""},"resultCode":200,"applicationId":"app-20190905230604-0006","username":"bluadmin","status":"submitted"}
[bluadmin@node07 - Db2wh bin]$
[bluadmin@node07 - Db2wh bin]$
[bluadmin@node07 - Db2wh bin]$
[bluadmin@node07 - Db2wh bin]$
[bluadmin@node07 - Db2wh bin]$ ./spark-submit.sh --list-apps
--- dashDB spark-submit.sh ---

SubmissionID           ApplicationID             Status
---------------------  ------------------------  -------
20190905033959200000   app-20190905034003-0000   ended
20190905034452659000   app-20190905034456-0001   ended
20190905150225236000   app-20190905150229-0002   ended
20190905224153221000   app-20190905224157-0000   ended
20190905224617142000   app-20190905224621-0001   ended
20190905230143818000   app-20190905230147-0002   ended
20190905230249799000   app-20190905230253-0003   ended
20190905230409565000   app-20190905230413-0004   ended
20190905230544802000   app-20190905230548-0005   ended
20190905230600480000   app-20190905230604-0006   ended
```

데모시나리오
3. REST API 이용

$ curl -k --user "bluadmin":"bluadmin" -X POST "https://10.12.13.97:8443/dashdb-api/analytics/public/apps/submit" --header "Content-Type:application/json;charset=UTF-8" -d '{"appResource":"idax_examples.jar","mainClass":"com.ibm.idax.spark.examples.ReadExample"}'

```
[bluadmin@node07 - Db2wh bin]$ curl -k --user "bluadmin":"bluadmin" -X POST "https://10.12.13.97:8443/dashdb-api/analytics/public/apps/submit" --header "Content-Type:application/json;charset=UTF-8" -d '{"appResource":"idax_examples.jar","mainClass":"com.ibm.idax.spark.examples.ReadExample"}'

{"statusDesc":"The application was submitted.","submissionId":"20190905230600480000","exitInfo":{"code":"","details":[],"message":"","messageDB":""},"resultCode":200,"applicationId":"app-20190905230604-0006","username":"bluadmin","status":"submitted"}
[bluadmin@node07 - Db2wh bin]$
[bluadmin@node07 - Db2wh bin]$
[bluadmin@node07 - Db2wh bin]$
[bluadmin@node07 - Db2wh bin]$
[bluadmin@node07 - Db2wh bin]$ ./spark-submit.sh --list-apps
--- dashDB spark-submit.sh ---

SubmissionID           ApplicationID             Status
---------------------  ------------------------  -------
20190905033959200000   app-20190905034003-0000   ended
20190905034452659000   app-20190905034456-0001   ended
20190905150225236000   app-20190905150229-0002   ended
20190905224153221000   app-20190905224157-0000   ended
20190905224617142000   app-20190905224621-0001   ended
20190905230143818000   app-20190905230147-0002   ended
20190905230249799000   app-20190905230253-0003   ended
20190905230409565000   app-20190905230413-0004   ended
20190905230544802000   app-20190905230548-0005   ended
20190905230600480000   app-20190905230604-0006   ended
```

IBM Integrated Analytics System

Netezza Heritage + New Hardware + Data Science + Cloud Ready

기존 모델의 장점은 더 강화

Simplicity (간편성)

- **인덱스 관리 불필요 :** Storage Index / Zonemap / 자동압축 / No Admin
- **물리적 모델링 없이 바로 사용 :** Load & Go / 성능개선용 물리모델설계 불필요

Performance (성능)

- **고성능 하드웨어 :** 더 빠른 CPU, 더 많은 Cache,더 큰 Memory
- **Micro latency Flash Storage :** I/O 지연 없는 데이터 전송
- **In-Memory 기술** : 컬럼기반의 인메모리 기술로 N3001대비 수배 성능향상
- **신뢰성 높은 스토리지 :** 2-Dimensional flash RAID (99.999% 신뢰있는 하드웨어 컴포넌트)

In-Place Expansion (확장)

- **모듈 방식 확장 :** Server + Storage 증설
- **스토리지 확장 지원 :** Storage 증설

M4002

최신 기술 적용

In-Memory (인메모리 기술)

- **집계 및 분석에 용이한 컬럼기반 데이터베이스 기술** : IBM의 BLU기술을 이용하여 성능 및 기술 안정성 확보
- **속도 향상 :** Analytic Query PDA N3001대비 수배 성능향상
- **리소스 최적화 :** I/O를 최소화 하고 CPU사용률을 절감

Analytic Tool (분석을 위한 툴)

- **데이터 분석가를 위한 환경 :** 분석에 필요한 머신러닝 Lib, Jupyter Notebook, Rstudio등을 기본 탑재하여 Analytic Sandbox 분석환경 구축 지원
- **외부 Spark 과의 연계**

Cloud Ready

- **SW Defined Analytic DW** : 동일한 구성으로 Public Cloud, Private Cloud, On-prem DW 구성가능
- **공통 SQL 엔진 :** 공통 엔진 / 공통 SQL 사용으로 상호 이관이 빠르고 용이함

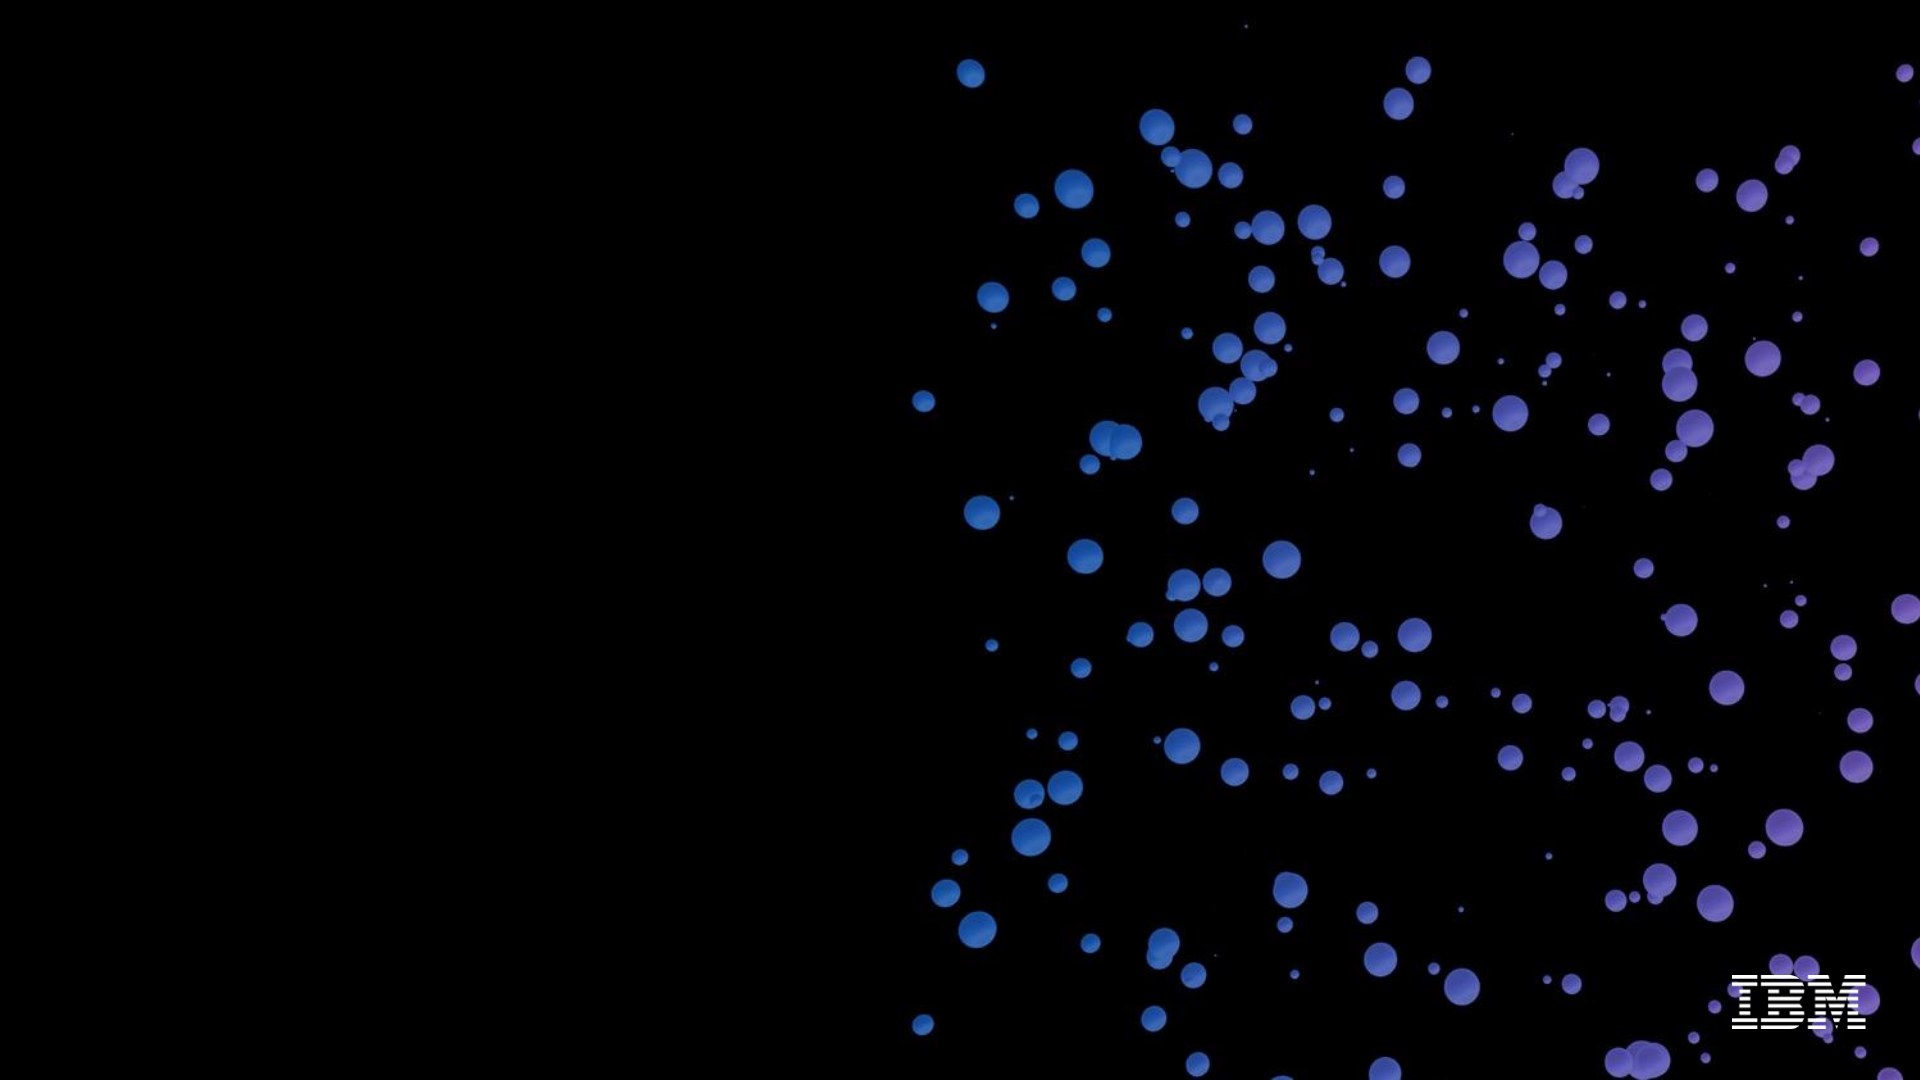
IBM