

Data Lake Architektur

ANALYSE



Zugänglich über
- Web Browser
- Client
Applikationen

Die proaktiven Methoden
der Analyse sind

- Predictive Modellierung
- Descriptive Modellierung
- Data Mining
- Text Mining
- Statistische/ Quantitative Analyse
- Simulation & Optimierung

Vom Endanwender erstellte Skripte sollten skalierbar und parallelisierbar sein. Die Verarbeitung von großen Datenmengen muss für diverse Workload-Kategorien wie

- Abfragen
- ETL
- Analytik
- Maschinelles Lernen
- Maschinenübersetzung
- Bildverarbeitung
- Sentimentanalyse

durch den Einsatz bestehender Bibliotheken gewährleistet sein.

ENTERPRISE DATA LAKE




Daten Veredelungs-
prozess während
des lesens



Transformieren
relevanter Daten in
Datensätze



Data Warehouse
mit leseoptimierten
Strukturen



DATENINTEGRATION



Zur ordnungsgemäßen Integration müssen folgende Management-
funktionen dem User zur Verfügung gestellt werden:

- Starten von lokalen und remote gespeicherten Paketen
- Stoppen von lokalen und remote laufenden Paketen
- Überwachung von lokalen und remote laufenden Paketen
- Importieren und Exportieren von Paketen
- Paketspeicher verwalten
- Anpassen von Speicherordnern
- Stoppen von laufenden Paketen, wenn Dienste gestoppt werden
- Anzeigen der Event Logs

Im EDL (Enterprise Data Lake) werden
die Fragen beantwortet



- Was wird geschehen?
- Was wird geschehen wenn wir etwas ändern?

Daten werden beim lesen verwandelt
und veredelt, in kuratierte Datensätze
transformiert um schlussendlich in
verschiedenen Schemas abgespeichert
und als Data Warehouses zur
Verfügung gestellt zu werden.
Die Nutzer sind hauptsächlich Data
Scientists, Business Analysten und
Fachanwender.

Die Datenintegration extrahiert und
lädt die Daten hauptsächlich (EL statt
ETL). Transformationen gilt es zu
vermeiden.

Dadurch werden die Daten in ihrer
nativen Form im Enterprise Data Lake
gespeichert.
So wird dem Endanwender die
Orchestrierung und das Streamen von
Daten möglich gemacht.

DATENQUELLEN



Es sollten alle Typen von
Datenbanken in Betracht gezogen
werden, um das größte
Wertschöpfungspotential zu erhalten.

- Relationale
- Analytische (OLAP)
- Key-value
- Column-family
- Grafen
- Dokument

Die Daten sollten idealerweise in
Rohform und nicht verdichtet
vorliegen.

Der Data Lake ist ein großes,
leicht zugängliches,
zentralisiertes Repository
von großen Mengen an
strukturierten und
unstrukturierten Daten. Die
Daten werden nicht
klassifiziert, wenn sie im
Repository gespeichert
werden, da der Wert der
Daten am Anfang nicht klar
ist.

Data Lake Architecture

ANALYZE



Accessible via

- web browser
- Client applications

The proactive methods used for analysis are



- Predictive Modeling
- Descriptive Modeling
- Data Mining
- Text Mining
- Statistical/ Quantitative Analysis
- Simulation & Optimization

The analysis tools should be simple and extensible that allows you to write code once and have it automatically parallelized for the scale you need. Process GB of data for diverse workload categories such as

- Querying
- ETL
- Analytics
- Machine learning
- Machine translation
- Sentiment analysis

by leveraging existing libraries.

ENTERPRISE DATA LAKE



The purpose of the EDL (enterprise data lake) is to answer the questions

- What will happen?
- What will happen if we change this one thing?

Data will be transformed and refined on read, transformed into curated data sets to be finally stored in different schemas and made available as data warehouses. The users are mainly data scientists, business analysts and professional users.



DATA INTEGRATION

To run the integration properly, the following **management capabilities** have to be provided:

- Starting remote and locally stored packages
- Stopping remote and locally running packages
- Monitoring remote and locally running packages
- Importing and exporting packages
- Managing package storage
- Customizing storage folders
- Stopping running packages when the service is stopped
- Viewing the Event log

The data integration does mainly extract and load the data (EL instead of ETL). There should be no to minimal transformation during the integration. Hereby the data will be stored in a near-native format to the data lake. Orchestration and streaming data accommodation becomes possible for the end user.

DATA SOURCES



All types of databases should be considered, such as

- Relational
- analytical (OLAP)
- Key-value
- Column-family
- Graph
- Document

to have the biggest data potential.

Leverages the power of on-premise technologies and the cloud for storage and capture. The data should be ideally offered in a native format.

The Data Lake is a **large, easily accessible, centralized repository of large amounts of structured and unstructured data**. The data is not classified when stored in the repository because the value of the data is not clear at the beginning.