

Data Engineering in der Praxis

- Prozessschritte und Herausforderungen -

Die **Data Science** beschäftigt sich mit der Analyse umfangreicher Datensätze. Je nach Anwendungsbereich und Aufgabenstellung ist dabei ein unterschiedlicher Workflow erforderlich, um aus den Rohdaten die gewünschten Informationen extrahieren zu können.

Das **Data Engineering** hat das Ziel, den Data-Science-Workflow möglichst effizient und skalierbar zu gestalten. Die Prozessschritte und Herausforderungen, welche dabei zu berücksichtigen sind, werden in diesem Poster überblicksartig dargestellt.

Mögliche Aufgabenstellungen in der Data-Science

Optimierung von Betriebsabläufen

- Reduktion des Energieverbrauchs in Produktionsstätten
- Verkürzung der Wartezeit für Patienten in Kliniken

 Maschinen-Sensoren
GPS-Tags von Mitarbeitern

Vorhersage von Kundenverhalten

- Generieren interessenabhängiger Produkt- bzw. Jobempfehlungen

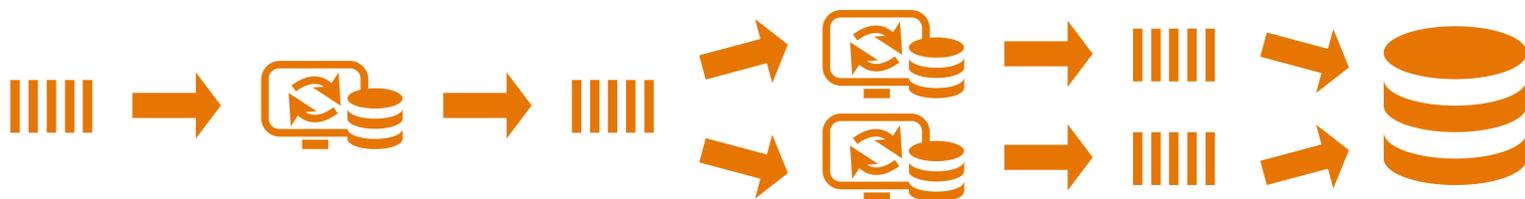
 Aufzeichnung von Applikations- / Website-Nutzerdaten

Automatisierung von Unternehmensprozessen

- Automatisches Prüfen von Rechnungen
- Automatisches Filtern von Nachrichtenmeldungen

 Text- und Bilddateien z.B. aus Emails und Websites

Die Rohdatenquellen generieren einen aus Ereignissen bestehenden Datenstrom



Echtzeitanalyse des Datenstroms

- Anwenden vorab definierter Abfragen auf den Datenstrom
- erfordert schnellen Datenzugriff

Aufteilung des Datenstroms zur Performancesteigerung

- Herausforderung: Management der Systemzustände zur Wahrung der Datenkonsistenz

Speicherung des Datenstroms im Data Lake

- Vorhalten der Daten für komplexere Aufbereitungs- und Analyseschritte im Batch-Processing

Erzeugen eines Data-Warehouse durch Aufbereitung der Rohdaten aus dem Data Lake

- Entfernen von **Duplikaten** und fehlerhaften Daten
- Erkennen von **Lücken** im Datensatz, ggf. Einfügen von Approximationen



- **Aggregation des Datensatzes**, Entfernen nicht benötigter Daten
- **Anpassen der Datenstruktur** an die geplante Analyse

Information Retrieval & Predictive Analytics

Lineare Modelle

- z.B. Ermitteln der Schlüsselfaktoren des Energiebedarfs



Matrix Factorization

- z.B. zum Generieren von Produktempfehlungen



Supervised Machine Learning

- z.B. für Bild- und Textanalyse

▸ Erzeugen / Training geeigneter Modelle

▸ Anwenden der Modelle und Bewerten der Modellperformance

▸ Verbessern der Modelle



Visualisierung und Anwendung der gewonnenen Information

Josafat-Mattias Burmeister

Bachelorstudent im Studiengang IT-Systems-Engineering
Hasso Plattner Institut Potsdam

E-Mail: josafat-mattias.burmeister@student.hpi.de