

Von Chaos zu Erfolg

Datenqualität beherrschen

Sebastian Löfflath & Tim Bossenmaier



Sebastian Löfflath



Cloud Architect

@



Tim Bossenmaier



Data & Software Engineer

@



Sebastian Löfflath



sebastianloefflath




Tim Bossenmaier



bossentti

Motivation



**Nur drei Prozent der
Unternehmensdaten
erfüllen Qualitäts-
standards^[1]**

Agenda

- Was ist Datenqualität?
- Datenqualität sicherstellen: Cui Bono?
- Maßnahmen & Strategien



Was ist Datenqualität?

Keine einheitliche Definition

“conformance to requirements”

(Crosby 1979)

“We define high-quality data as data that is fit for use by data consumers”

(Strong 1997)

“data is [...] of high quality [...] if they are fit [...] in operations, decision making and planning”

(Redman 2016)

Unser
Verständnis

“**Datenqualität**
bezieht sich auf die
Fähigkeit von
Daten, die **reale**
Welt wider-
uspiegeln und die
**Entscheidungs-
findung** zu
unterstützen.”

Dimensionen von Datenqualität nach DAMA



Vollständigkeit

Grad des Vorhandenseins der Attribute einer Datenentität (bspw. Tabelle).

- Wie viele der Attribute sind gefüllt ($\neq \text{NULL}$)?
- in Abhängigkeit des konkreten Anwendungsfalls

ID	Name	Industrie	Umsatz (Mio USD)
1	Walmart	Retail	611 289
2	Amazon	null	513 983
3	Exxon	null	null

Name 100 %
Industrie 33,3 %
Umsatz 66,7 %

Kardinalität...

beschreibt den Grad an existierenden Duplikaten.

verschiedene Grade existieren nebeneinander:

- **Hoch:** Attribute haben einen hohen Anteil an einmaligen Werten
Beispiele: IDs, E-Mail Adressen, Handy-Nummern, ...
- **Mittel:** Attribute mit seltenen Duplikaten
Beispiele: Postleitzahl, Produktgruppen, Kostenstelle, ...
- **Gering:** Attribute mit häufigen Duplikaten
Beispiele: Statuscodes, Flags, ...

Sicherheit

Data Security beinhaltet den Schutz von Daten vor zerstörerischen Akteuren.

- inkl. Schutz vor unautorisierten Zugriffen durch Benutzer & Systeme
- betrifft den kompletten Lebenszyklus der Daten
- Bedrohungen wie Hackerangriffe, Betrug oder Malware
- Daten stehen jedem im Unternehmen zur Verfügung, der Zugang zu ihnen benötigt

Rechtzeitigkeit...

bezieht sich auf die Aktualität der Daten und ob die aktuellste Version verfügbar ist, wenn sie gebraucht wird

- Grad zu dem Daten mit der realen Welt übereinstimmen
- hängt von der Kritikalität des Geschäfts und den Auswirkungen ab
- Gewinnt zunehmend an Bedeutung, entscheidend für echtzeitnahe Entscheidungsfindung

**Wieso gibt es
Probleme mit der
Datenqualität?**

Ursachen für mangelnde Datenqualität I

Manuelle Fehler

Größte Quelle für schlechte Datenqualität: manuelles Pflegen/
Eintragen von Daten



Fehlende Anreize

kaum Anreize, die Verantwortung für die Datenqualität zu übernehmen



Analyse-Fokus

Daten-Teams: SQL und Python



Ursachen für mangelnde Datenqualität II

Organisations-Silos führen zu Daten-Silos

fehlender abteilungsübergreifender Austausch



Unterschiedliche Nutzung & Interpretation von Daten

Verwendung entgegen des ursprünglichen Erhebungszwecks



Datenqualität nimmt über Zeit ab

Unternehmen ändern und entwickeln sich über die Zeit und mit ihnen die produzierten Daten





- Shadow Data Teams
- Duplicate Data Warehouse
- Marketing buying their own data analytics solutions
- etc

Data Governance

Ursachen für fehlende Datenqualität - Takeaway

Ursachen sind vielfältig



Es gibt nicht die eine Stelle an der nachgebessert werden kann.


Datenqualität ist eine Unternehmensaufgabe



... und keine IT Angelegenheit. Datenqualität erfordert, dass Unternehmen Verantwortung übernehmen und Verbesserungen vorantreiben.

Datenqualität sicherstellen: Cui Bono?

Data Driven Company



Auswirkungen mangelnder Datenqualität

Finanzielle Auswirkungen

erhöhte operative Kosten, verlorener Umsatz, verpasste Möglichkeiten



Auswirkungen auf den Geschäftsbereich

Verfehlten von Erwartungen, Rückgang von Vertrauen, Fehlentscheidungen



Auswirkungen auf die Produktivität

Effizienz leidet, erhöhte Zykluszeiten



Compliance Auswirkungen

erhöhte finanzielle und compliance Risiken, Verstoß gegen Rahmenbedingungen



Kosten von Datenqualität - Prävention lohnt sich

1 - 10 - 100 Regel



Maßnahmen & Strategien

Datenqualität beherrschen



sichtbare
Qualitätsprobleme

verdeckte
Qualitätsprobleme

Data Profiling

sichtbare und verdeckte Qualitätsprobleme finden



Data Profiling



OSS Tools wie Deequ und GreatExpectations unterstützen beim Profiling

Basic Daten KPIs


#Zeilen, #Spalten, Dateigröße,
%NULL-Werte, %Leerwerte,
#einzigartigeElemente, Duplikate des Primary Keys, ...

Kategorische Daten KPIs

#Kategorien, Histogram, ...

Numerische Daten KPIs

Mittel, Min, Max, Varianz, ...







Data Contracts

Data Contracts sind Vereinbarungen zwischen Softwareingenieuren, die über eigene Dienste verfügen, und Datenkonsumenten, die wissen, wie das Unternehmen funktioniert, um gut modellierte, hochwertige und vertrauenswürdige Daten zu generieren.

- Aufbrechen von Silos zwischen Datenproduzenten und Datenkonsumenten
- Konsumenten definieren Schema gemäß ihren Anforderungen
 - losere Kopplung
- kann sich im Laufe der Zeit ändern unter Maßgabe der Kompatibilität
- sind in erster Linie ein kultureller Wandel hin zu einer datenzentrierten Zusammenarbeit

Data Contracts

backward-compatible

Schema update zuerst im Konsument

erlaubte Änderungen des Data Contracts:

- hinzufügen von optionalen Feldern
- löschen eines Feldes



Data Contracts

forward-compatible

Schema update zuerst im Produzent

erlaubte Änderungen des Data Contracts:

- hinzufügen von Feldern
- löschen von optionalen Feldern



Data Contracts - Tools




kafka



Eigener Ansatz



**Bestehendes
Produkt**




Schema Registry...

ist zentraler Speicher für die Verwaltung und Validierung von Schemata für thematische Nachrichtendaten und für die Serialisierung und Deserialisierung der Daten.

- festgelegtes Schema auf das sich Konsumenten und Produzenten verlassen
- Konsument kennt immer das dazugehörige Schema
- sorgt für Konsistenz der Daten
- Versionierung der Schemata ermöglicht Kompatibilität
- Validierung der Schemata beim Schreiben




Confluent Schema Registry




AWS Glue Registry




GCP Pub Sub




Replay - Adapter





Replay - Adapter





Data Quarantining





De-Deduplizierung

Häufiges Problem bei event-basierten Datenquellen: **at-least-once** Garantie


Methoden für De-Duplizierung:

- Stateful **dropDuplicates** bei Spark Streaming
- **Upsert** als Schreibstrategie verwenden




Falls kein eindeutiger Schlüssel vorhanden
-> Hash-Wert über eine Menge an identifizierenden Spalten berechnen

Datum	Land	Appname	Downloads
01.10.23	DE	DataQuality+	520
02.10.23	DE	DataQuality+	310



Key	Datum	...
c325c10	01.10.23	...
38ec90b	02.10.23	...






Zugriffsrechte

- Zugriffsrechte auf Schemata, Tabellen und Views sollte wohl überlegt sein
- Welches Aggregationslevel wird auf Konsumentenseite benötigt?
- Logging von Zugriffen
- Zusätzlich: Spalten-basierte Zugriffsrechte



databricks



AWS Lake Formation



GCP Big Query



Apache Superset

Fazit



Ende zu Ende



Tools



Schritt für Schritt

Vielen Dank!



Sebastian Löfflath
Cloud Architect

sebastian.loefflath@inovex.de

Ludwig-Erhard-Allee 6
76131 Karlsruhe



Tim Bossenmaier
Data & Software Engineer

tim.bossenmaier@bytefabrik.ai
+49 176 8779 0585

Haid-und-Neu Straße 10-14
76131 Karlsruhe



Bytefabrik.AI

Materialien

Southekal, Prashanth (2023): Data Quality - Empowering Businesses with Analytics and AI. Wiley, New Jersey.

Meier, Kolja & Spitzer Marcel (2023): Hohe Qualität vom Anfang bis zum Ende - Digital Future, Folge 17. <https://digital-future.podigee.io/17-neue-episode>


Estuary (2023): What Is Data Quality? Dimensions, Standards, & Examples.
<https://estuary.dev/data-quality>

PayPal (2023): Template for Data Contract.
<https://github.com/paypal/data-contract-template>

Sanderson, Chad (2022): The Rise of Data Contracts.
<https://dataprodsubstack.com/p/the-rise-of-data-contracts>

SeattleDataGuy (2023): Is Everyone's Data Infrastructure A Mess?
<https://seattledataguy.substack.com/p/is-everyones-data-infrastructure>

Fragen ?



THAT FEELING YOU GET WHEN



LET ME INTRODUCE YOU TO



CAN'T HAVE DATA QUALITY
ISSUES



DUPPLICATES, YOU HAVE.



BackUp: Data Contract in DataHub



DataHub Town Hall

Sept 28, 2023