



PinkDB & DataVault

Prinzipien hinter PinkDB und deren Anwendung auf eine DataVault Datenarchitektur

Einleitung

- SmartDB und PinkDB
- DataVault Datenarchitektur mit PinkDB
- Take-Away
 - Modellgetriebene Entwicklung
 - Nutze relationale Stärken
 - Stick to the pattern



Me



Torsten Glunde

Solution Architect DWH and BI

- <http://alligator-company.com> seit 2002
- Consultant seit 1994
- BI/DWH seit 2002
- DataVault Evangelist seit 2009



https://www.xing.com/profile/Torsten_Glunde/cv



@tglunde



www.linkedin.com/in/torsten-glunde-097aba8





<http://www.oraclethoughts.com/>



<https://www.salvis.com/blog/>




<https://danischnider.wordpress.com/>




<https://stevenfeuersteinonplsql.blogspot.com/2018/05/the-smartdb-resource-center.html>

SmartDB – OLTP Applikationen



Probleme mit Middleware außerhalb der DB

- Stabilität des Technologie Stacks
C++, C#, Java, JavaScript
 - SQL ist tabiler
- Entwicklungs- und Wartungskosten
Fehler finden in mehreren Ebenen
Benötigen wir wirklich OO?
Wartung mehrerer Systeme
- Performance und Skalierbarkeit
Experiment im Labor:



	Java/JDBC	PL/SQL row-by-row	PL/SQL set-based
DB-CPU	437	204	7
APP-CPU	217	0 (n/a)	0 (n/a)
Total	654	204	7

**Almost 100X
Just think about this...**




SmartDB

- PL/SQL „hard shell“ API
- API hangeschrieben
- Connect User besitzt keine Datenbankobjekte
- Connect User can execute PL/SQL API units only
- Transaktionskontrolle in der DB
- Set-based SQL

```
begin Pkg.Bulk_Insert(:Rows); end;
```




Und Data Warehousing?



Und Data Warehousing?

ETL oder in-DB Verarbeitung

- Vorteile der DB ausnutzen
- ETL/Middleware fällt weg
- Wartung und Betrieb vereinfachen
- Set-based anstatt Row-By-Row






PinkDB Paradigm

Prinzipien


- Set-based
- View-API
- Fast



PinkDB Paradigm

Struktur


- Connect User besitzt keine Datenbankobjekte
- API Schema: Datenzugriff, gespeicherte Objekte und Views, **keine Tabellen**
- Data – speichert Informationen in vom Datenmodell definierten Struktur



PinkDB Paradigm

Features


- Set-based
 - Gute Performance
 - Ausnahme: Aktualisierung wenigen Sätzen von UI
- Datenbank unabhängig
- Schnell
- Ausnahmen von der Regel müssen dokumentiert werden



PinkDB Paradigm


Unterschiede zu SmartDB

- Datenbank unabhängig
- Views erlaubt
- **Generatoren erlaubt**
- Data – speichert Informationen in vom Datenmodell definierten Struktur




DataVault Implementierung

- Lademuster in DataVault sind Set-based
- Automat generiert DataVault Datenschema
- Schema API?
- Soft Rules?



The „Great Divide“ in DataVault?




Quelle abgerufen am 23.10.2018: https://en.wikipedia.org/wiki/Continental_Divide_of_the_Americas

Anforderung



Fachseite

Technik






Anforderung



Fachseite

Technik



Speichern
Historisieren
Automatisieren
Nachvollziehbarkeit






Anforderung



Fachseite





Technik




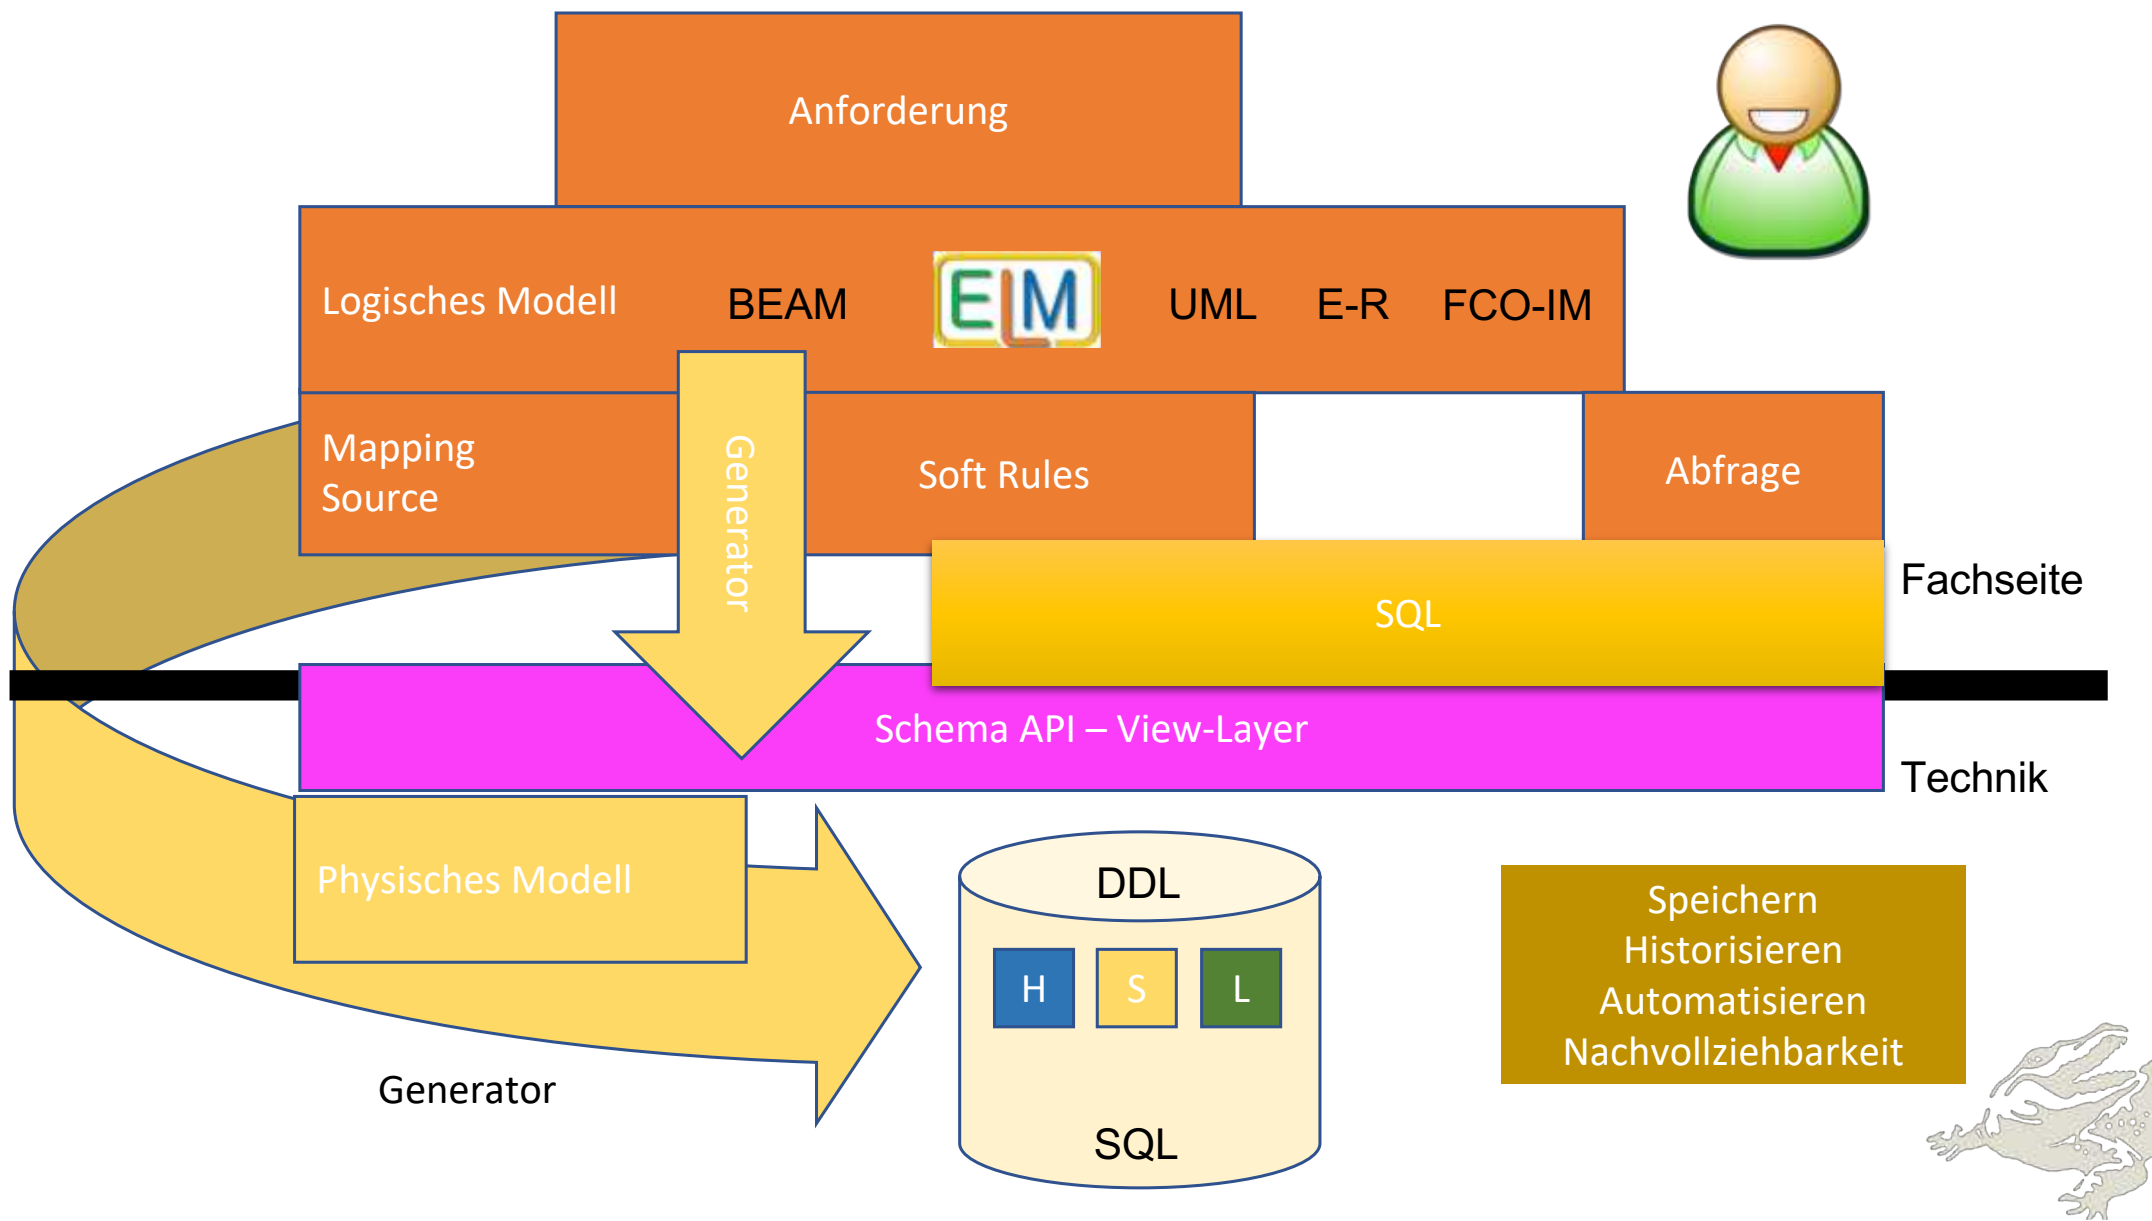
Speichern
Historisieren
Automatisieren
Nachvollziehbarkeit













Schema API – View Layer

- Einheitlicher Zugriff auf DataVault
- Information Hiding
- Zugriffsschicht, Soft Rules und Nutzerzugriffe basieren auf dem selben, logischen Modell
- Optimierung der SQL an zentraler Stelle
- Generierbar aus dem Modell




PinkDB und DataVault



- Model Driven
 - Strukturierte Modellierung ermöglicht Automation
 - Generierung von Data Vault
 - Generierung der Zugriffsschicht
- Set Based
 - Lademuster
 - Zugriffs-View in API Schema
 - Information Hiding
- Vereinfachung der Infrastruktur
 - Einfache Lineage über SQL / View ermöglicht GDPR
 - Reduktion der Wartungskosten
 - Einfache Fehlersuche, Einfaches Skillset
 - SQL / relationales Modell als stabile Schnittstelle
- Algorithmen nah an den Daten



PinkDB und DataVault



- Was ist mit Fehlerbehandlung und Hard Rules?
 - Fehlertolerante SQL (Functions ON-Error, Default Werte)
 - DQ-Regeln und DQ-Bewertung Downstream, nachgelagert, Error Mart
 - Landing in Hadoop / mittels Kafka und Flink
- Prozesssteuerung
 - DataVault ermöglicht parallele Beladung und damit einfache Steuerung
 - SoftRules müssen Abhängigkeiten berücksichtigen
- Fehlende Flow-Control in SQL
 - Einfache Muster erfordern keine komplexe Flow-Control
- ETL Werkzeuge benötigen keine Datenbankkenntnisse
 - Datenbankkenntnisse sind essentiell






Architekturvorteile von Data Vault

Versprechen von DataVault

- Flexibilität für Änderungen
 - Inkrementell
- Effiziente Historisierung
- Effiziente Lademuster
 - Automatisierbar
 - Insert Only
 - Hohe Parallelität
- Nachvollziehbarkeit

Datenarchitektur



Take-Away

Don'ts

- ETL – im Sinne von satzweiser Verarbeitung ist nicht zukunftsfähig
- ETL – im Sinne von Middleware außerhalb der Datenhaltung
- Fehlerbehandlung, Datenqualität in Muster integrieren
 - Separation of Concerns wahren
- Werkzeuge als Strategie zu behandeln
 - sollten austauschbar sein
- Bestehende ETL Frameworks wiederverwenden

Dos

- **Modellgetriebene Entwicklung**
- **Datenarchitektur und deren Nachhaltigkeit ist strategisch**
 - Regelwerk aufstellen, dokumentieren und nachhalten
- **Bleib bei den Mustern, Set-Based**
- **DYMD - Dont Move Your Data, Vorsicht mit ETL**
- **Automation ist der Schlüssel**
 - Vorsicht bei der Werkzeugauswahl





PinkDB & DataVault

Vielen Dank für die Aufmerksamkeit

