Oracle Data Warehouse –
Datenbank basierte ETL-Prozesse

Reduzieren Sie Ihre Ladezeiten auf ¼!

ORACLE
DATA WAREHOUSE

Das Thema

Datenbank-basierte ETL-Prozesse

- Verlagerung der ETL-Prozesse in die Datenbank
- Datenbank fungiert als ETL-Server
- Daten werden möglichst wenig bewegt
- Kurze Ladezeiten

Das große Klagen

Bzgl. System-Nutzen

- Lieferzeiten der Daten zu lange (Latenzen)
- Zu schwerfällig bei Änderungen
- Informationen mehrfach vorhanden
- Fehlende unternehmensweite Sichten
- Nicht die richtigen Informationen für die Anwender
- Anwender haben zu wenig unmittelbaren Einfluss auf die Daten

Bzgl. Maintenance und Technik

- Immer teuerer
- Maintenance-Aufwand zu hoch / Personal
- Explodierende Datenmengen -> Storage- / Ladezeitenthematik

Was definieren wir als ETL-Prozesse?

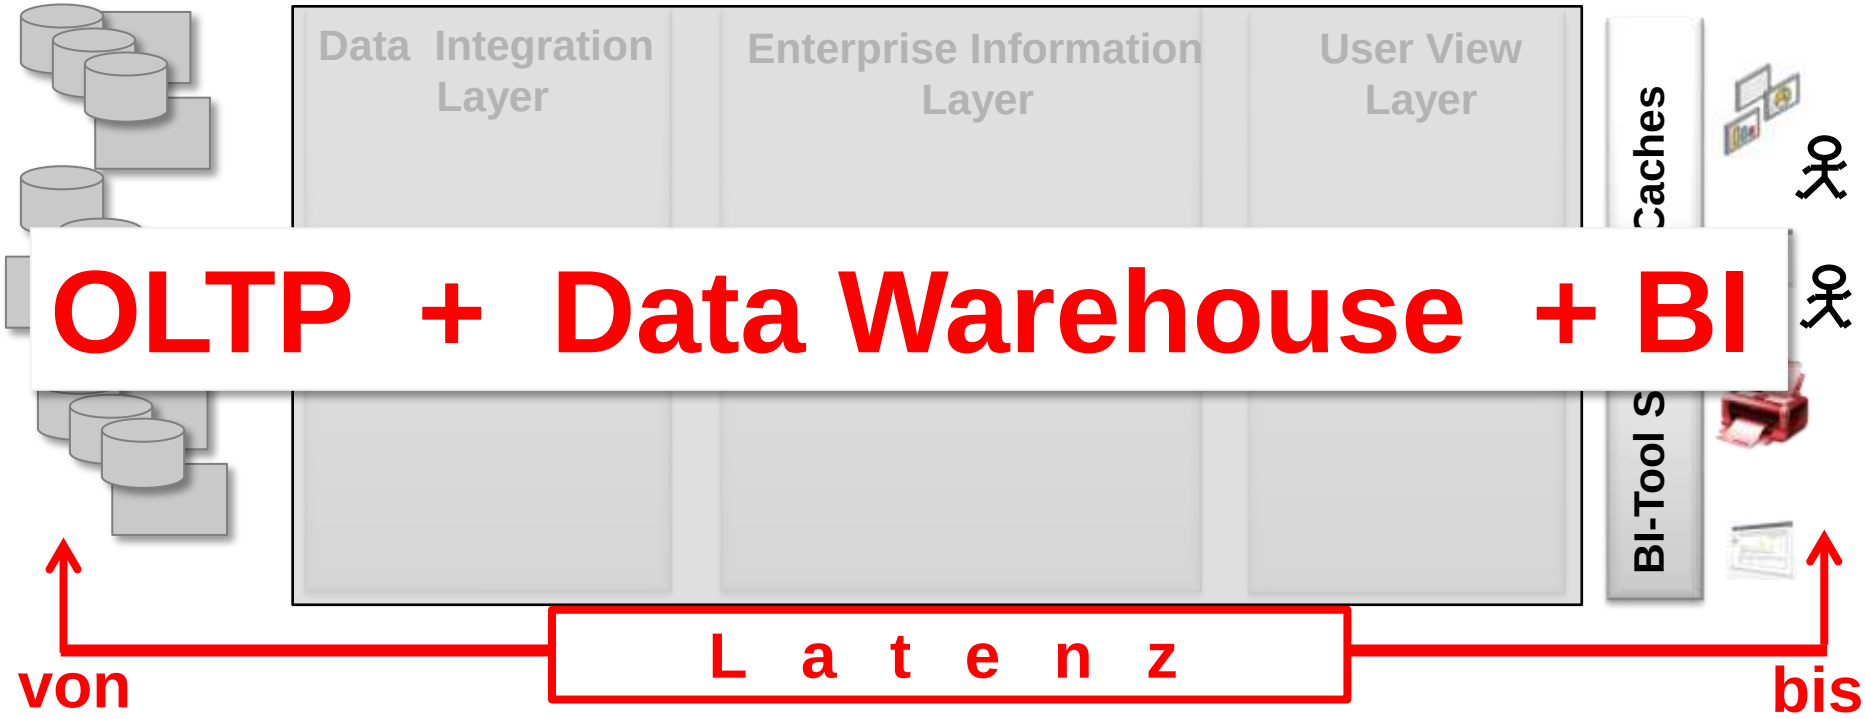

Reduzieren Sie Ihre Ladezeiten auf ¼!

Ziele eines effizienten ETL-Prozesses

- **Ressource-schonend**
  - Rechenzeit, Storage
- **Schnell änderbar und pflegbar**
- **Kurze Laufzeiten**
- **Erzeugen von stimmigen Abfrage-Ergebnissen**
- **Erleichterung für BI-Tools**

....

Allgemeine Regeln

- Schichtenmodell als Orientierung nutzen
- Auf die spezifischen Anforderungen und Situationen in den jeweiligen Schichten reagieren
- Transformationen so früh wie möglich im Verlauf des Schichtenmodells
- Alle Schichten innerhalb derselben Datenbank
- Daten nur dann bewegen, wenn sich qualitativ etwas verändert.
- Nur diejenigen Daten laden, die wirklich benötigt werden

- Prüfungen an wenigen Stellen konzentrieren
- Bei Data Marts prüfen, ob sie permanent bereit gehalten werden

Angemessen in den Situationen agieren

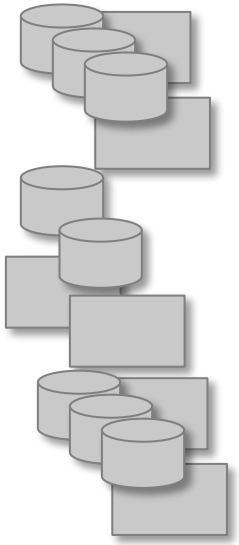

Data Integration Layer

Keine Daten

Enterprise Information Layer

Referenzdaten
Stammdaten
Bewegungsdaten
(granulare Transaktionsdaten)

User View Layer

Dimensionen
Fakten
Vor-berechnete Kennzahlen

R: Referenztabellen
T: Transfertabellen
S: Stammdaten
B: Bewgungsdaten
D: Dimensionen
F: Fakten

Die Organisation des ETL-Prozesses

Richtig selektieren

Data Integration Layer

Die Masse aller Prüfungen

Enterprise Information Layer

Stamm-Referenzdaten aktualisieren

Nur denormalisierende Joins

User View Layer

Möglichst viele Kennzahlen in die Datenbank

Repository
(Glossar, alle Objekte)

Für alle Aktionen den frühest möglichen Punkt finden

Angemessen in den Situationen agieren

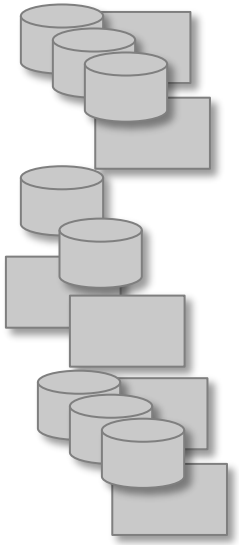

Data Integration Layer

Temporäre Daten

Enterprise Information Layer

20% Volumen f. viele Kleine Tabellen

80% Volumen f. wenige große Tabellen
=> partitioniert

User View Layer

Wieder herstellbare Daten

Verfahren für schnelles ETL in der Datenbank

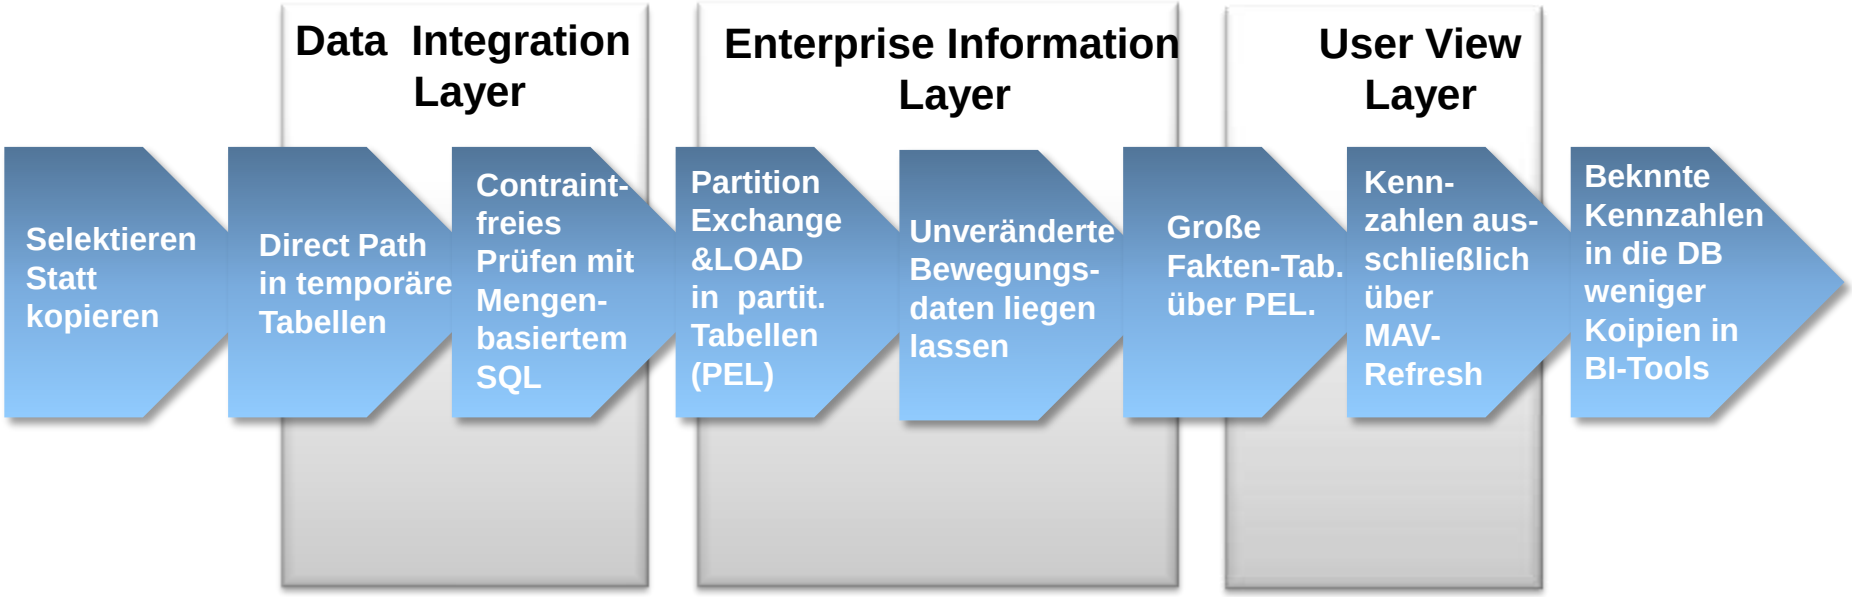

Die Quellen

Selektieren statt kopieren

- **Nur die Daten laden, die gebraucht werden**
- **Keine 1:1 Kopien in die Integrations-Schicht**
- **Nach Möglichkeit vor Eintritt in die Datenbank Prüfungen durchführen**
- **Bereits geprüfte Daten nicht mehr prüfen**

Nicht so ....sondern

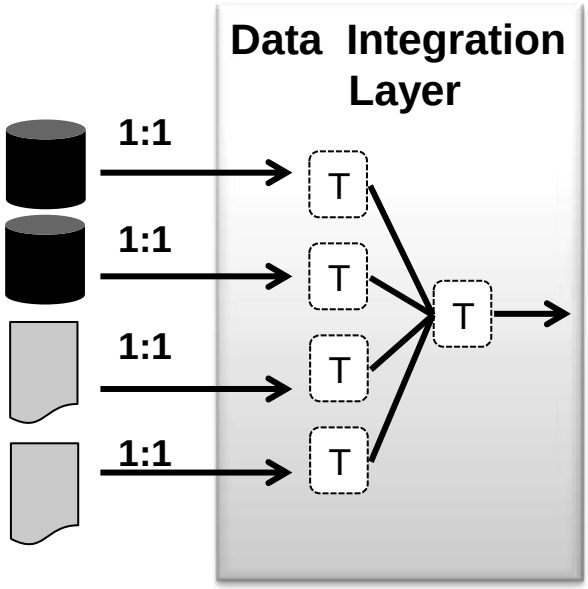

Warum?

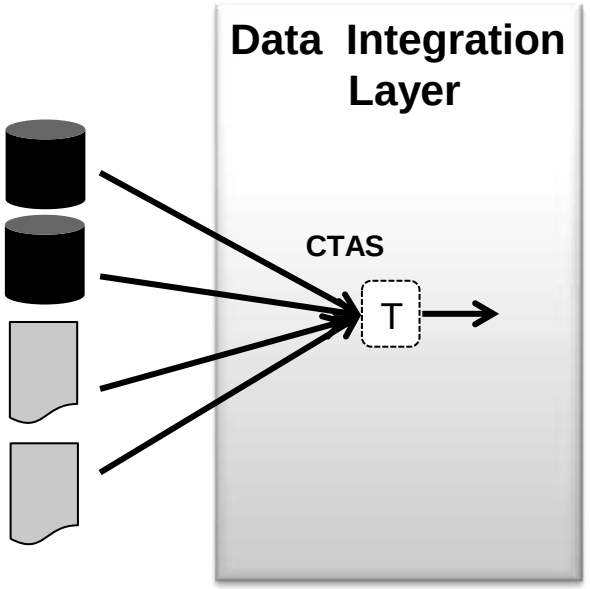

Logik so früh wie möglich

Der „Einstieg“

Direct Path Load in temporäre Tabellen

- **Direct Path Load**
  - Ohne Undo und Spacemanagement
  - Create Table As Select ..... (CTAS)
  - Insert /*+ APPEND */ .....
  - SQLLoader oder External Table
- **Temporäre Tabellen**
  - Helfen bei der Organisation
  - können beliebig modifiziert werden
  - können beliebig gelöscht werden

Direct Path

Direct Path in temporäre Tabellen

- **Direct Path Load**
  - Ohne Undo und Spacemanagement
  - Create Table As Select ..... (CTAS)
  - Insert /*+ APPEND */ .....
  - SQLLoader oder External Table
- **Temporäre Tabellen werden neu aufgebaut**
  - können beliebig modifiziert werden
  - können beliebig gelöscht werden

Es gibt 6 Prüf-Kategorien

A — Attribut-bezogene Regeln

1. Not Null / Pflichtfelder
2. Formatangaben
   a) numeric
   b) Alphanumerisch
   c) Date
   d) Masken
3. Div. Check Constraint
4. Wertbereiche
   – Ober-/Untergrenzen / Wertelisten

B — Satz-bezogene Regeln

5. Abhängigkeiten von Werten in anderen Attributen desselben Satzes

C — Satz-übergreifende Regeln

6. Primary Key / Eindeutigkeit
7. Aggregat – Bedingungen
   a) Ober- Untergrenzen von Summen
   b) Anzahl Sätze pro Intervall usw.
8. Rekursive Zusammenhänge
   Verweise auf andere Sätze derselben Tabelle (Relation)

D — Tabellen-über greifende Regeln

9. Foreign Key
   a) Child-Parent (Orphan)
   b) Parent-Child
10. Aggregat – Bedingungen
    a) Ober- Untergrenzen von Summen
    b) Anzahl Sätze pro Intervall usw.
11. Referenz-Zusammenhänge
    – Verweise auf Sätze einer anderen Tabelle (Relation)

E — Zeit-/ Zusammenhang-bezogene Regeln

12. Zeitinvariante Inhalte (z. B. Anz. Bundesländer)
13. Zeitabhängige Veränderungen
14. Über die Zeit mit anderen Daten korrelierende Feldinhalte

F — Verteilungs-/Mengen-bezogene Regeln

15. Verteilung
    a) Arithmetische Mittel
    b) Varianz / Standardabweichungen
16. Qualitätsmerkmale und Mengen

Mengen-basierte Prüfungen mit SQL

Attribut-bezogene Regeln

A

1. Not Null / Pflichtfelder
2. Formatangaben
   a) numeric
   b) Alphanumerisch
   c) Date
   d) Masken
3. Div. Check Constraint
4. Wertbereiche
   – Ober-/Untergrenzen / Wertelisten

```
select
   bestellnr,
   case
     when -- wenn Feld BESTELLNR nicht numerisch
       REGEXP_LIKE(BESTELLNR, '[^[:digit:]]')
     then 1
     else 0
   End Num_Check_bestellnr
from bestellung;
```

Satz-bezogene Regeln

B

5. Abhängigkeiten von Werten in anderen Attributen desselben Satzes

```
select
CASE
  WHEN (F1 = 3 and F2 = F3 + F4)
  then 1
  ELSE 0
end
from fx
```

Satz-übergreifende Regeln

C

6. Primary Key / Eindeutigkeit
7. Aggregat – Bedingungen
   a) Ober- Untergrenzen von Summen
   b) Anzahl Sätze pro Intervall usw.
8. Rekursive Zusammenhänge
   Verweise auf andere Sätze derselben Tabelle (Relation)

```
insert   /*+ APPEND */  into err_non_unique_bestellung
    select  bestellnr from
          (select
                count(bestellnr) n,
                bestellnr
           from bestellung
           group by bestellnr)
           where n > 1;
```

Umgang mit SQL und PL/SQL im DB-ETL

So nicht ...

```
Create or replace procedure Proc_A
V1              number;
V2              number;
V3              varchar2;
V4              varchar2;
....
Cursor  CS as select  s1,s2 from tab_src;
Begin
  open CS;
  loop
     fetch CS into  v1,v2,...;
      select f1 into v3 from tab1;
      select f1 into v4 from tab2;
        insert into Ziel _tab s1,s2,s3,s4
      values(v1,v2,v3,v4);
  end;
end;
```

Aber z. B. so ...

```
insert into  ziel
  select f1, f2, f3, f4 from
      (with CS as
            select s1 v1,s2 v2 from tab_src
      Select tab1.f1 f1 ,tab2.f2 f2, CS.s1 f3,CS.s2 f4
          from tab1,tab2,CS
      Where...
);
```

Exchange Partition

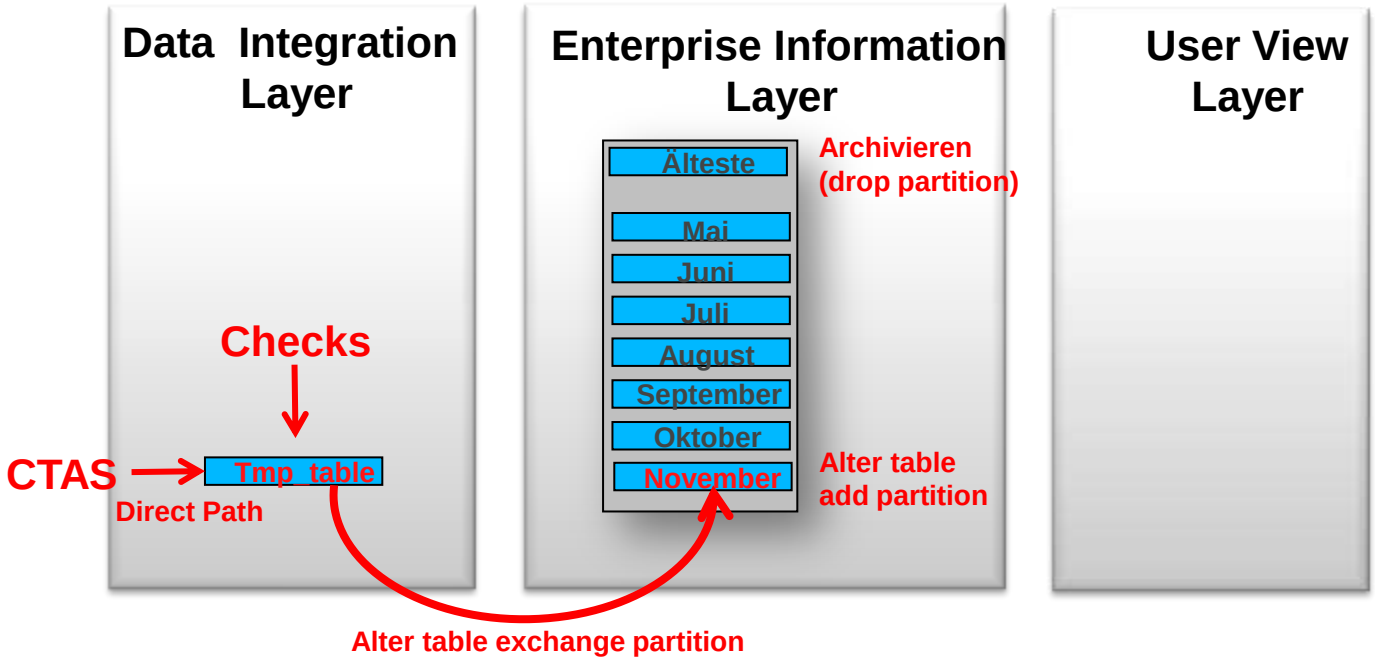

Minimales Bewegen

Große unveränderte Tabellen liegen lassen

Zugriff auf beide Schichten

Security mit Bordmittel anstatt durch Kopieren lösen

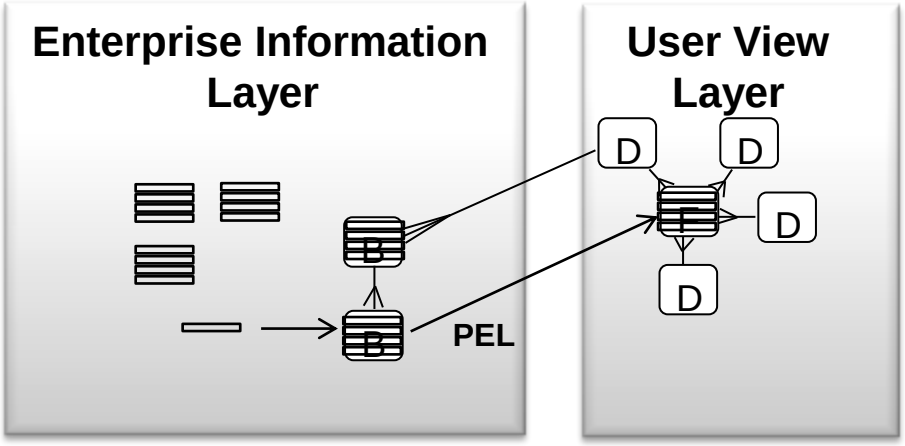

Aufbau Fakten-Tabellen

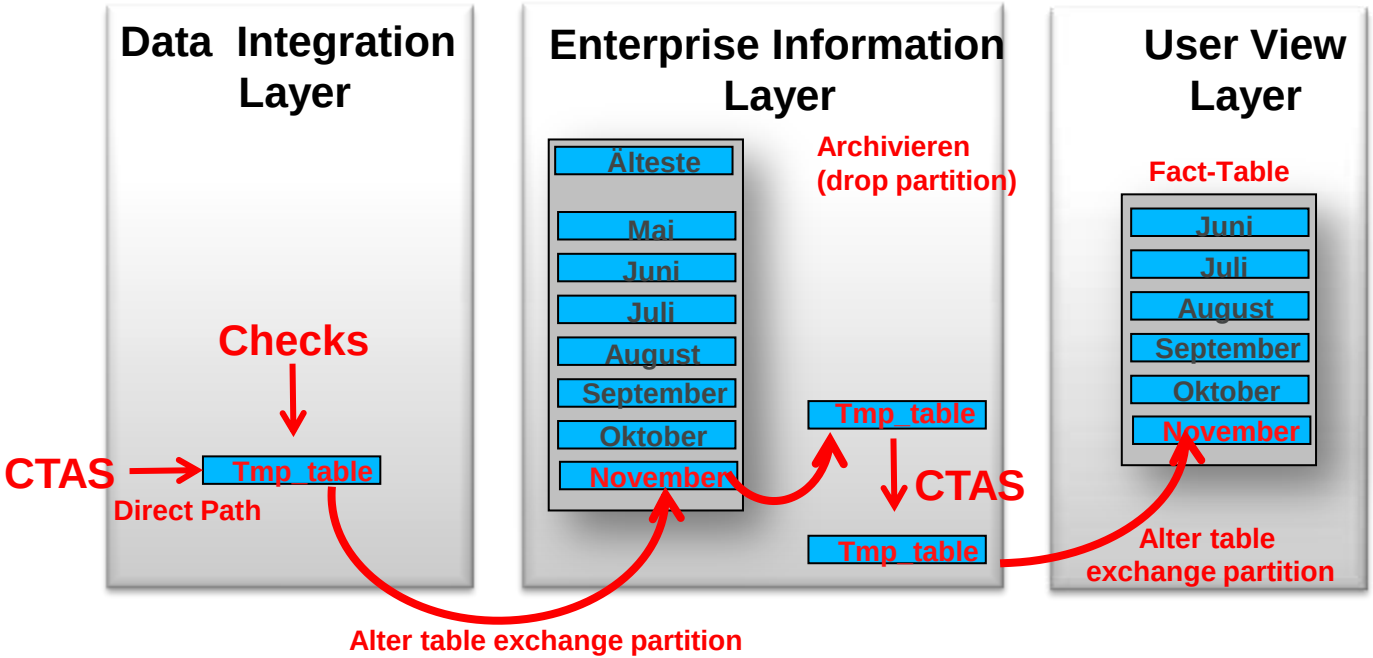

Kennzahlen

Kennzahlen nur als Materialized Views

Automatisches Refresh anstatt ETL

Standardisierte und stimmige Kennzahlen

Wiederverwenden von bereits aggregierten Daten

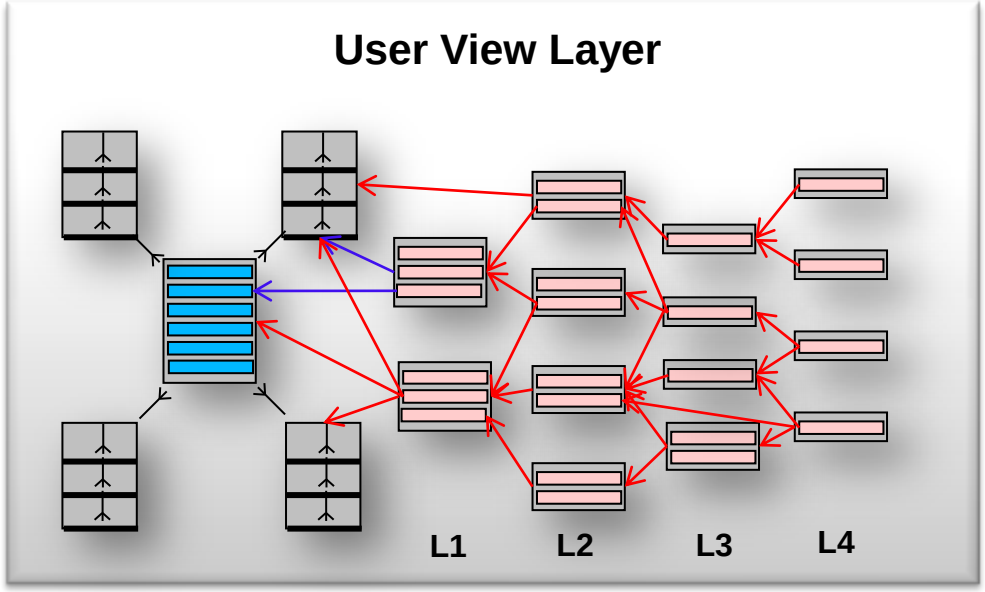

Der Weg in die BI-Tools

So viel wie möglich in der DB vorbereiten

Verhindert unnötiges Kopieren

Keine Verlagerung von Pseudo-ETL in die BI-Tools

Standardisierte Kennzahlen

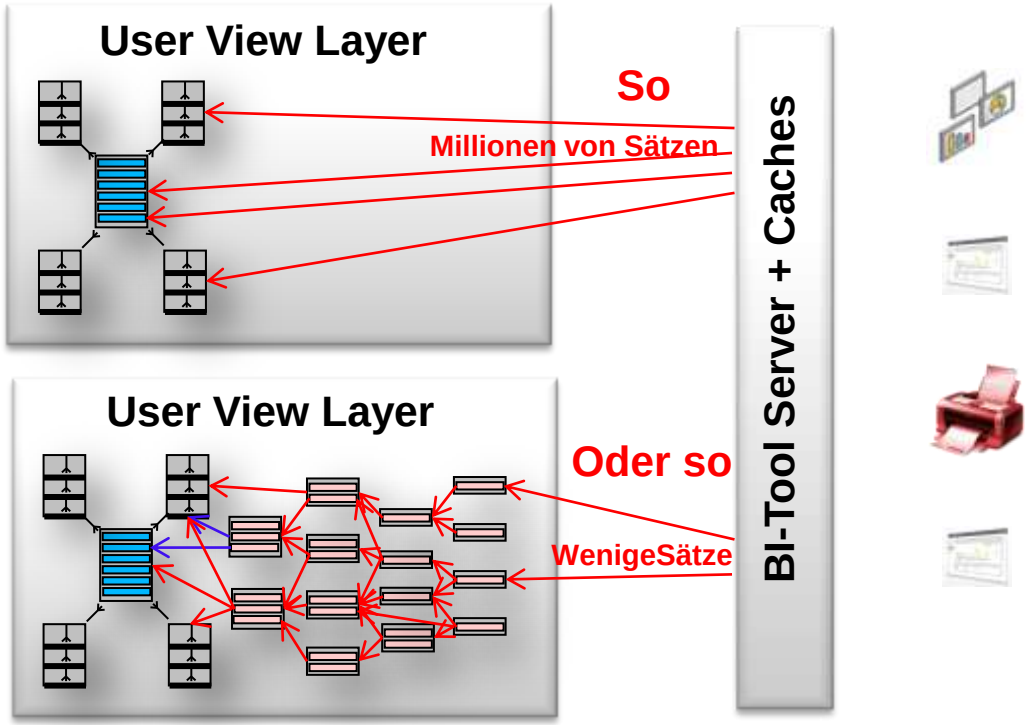

Weitere Einflussfaktoren und Techniken

- **Parallelisierung** **-> abhängig von Hardware**
  -> direktes Steuern über Hints
- **Aktuelle Statistiken** **-> Source Tabellen**
  -> auch während des ETL-Laufes
- **Ausnutzen des Cache-Effektes**
  -> Organisieren der Abarbeitungsreihenfolge
  -> Eventuell Query-Result-Cache nutzen
- **Vermeiden von großen Join-Tabellen**
  -> eventuell kleine Join-Tabelle mit wenigen Spalten

Weitere Einflussfaktoren und Techniken

- Schnelle mengen-basierte Prüfungen kommen zuerst, teuere Prüfungen (Feld-Prüfungen) zuletzt durchführen
- Möglichst viel Hauptspeicher für Join-Operationen mit großen Tabellen
- Sort-Area-Size hoch setzen
- Blocksize auf 16 bzw. 32 K
- PCTfree auf Null setzen
- Partition Change Tracking (PCT) für inkrementelles Refresh der MAVs

Keine unnötige Daten-Transporte ...

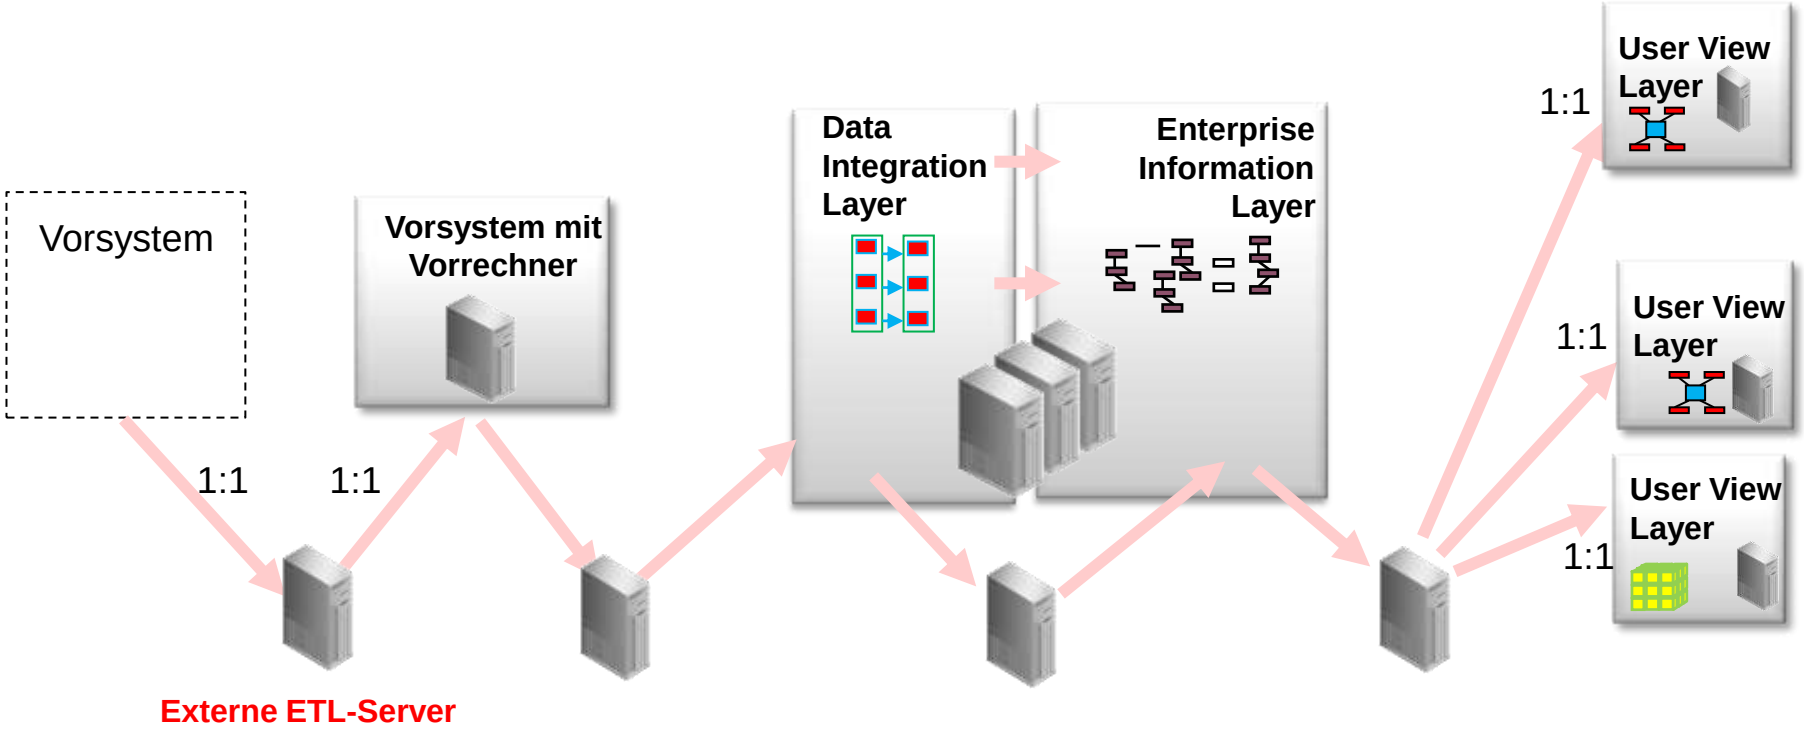

... sondern kurze Wege

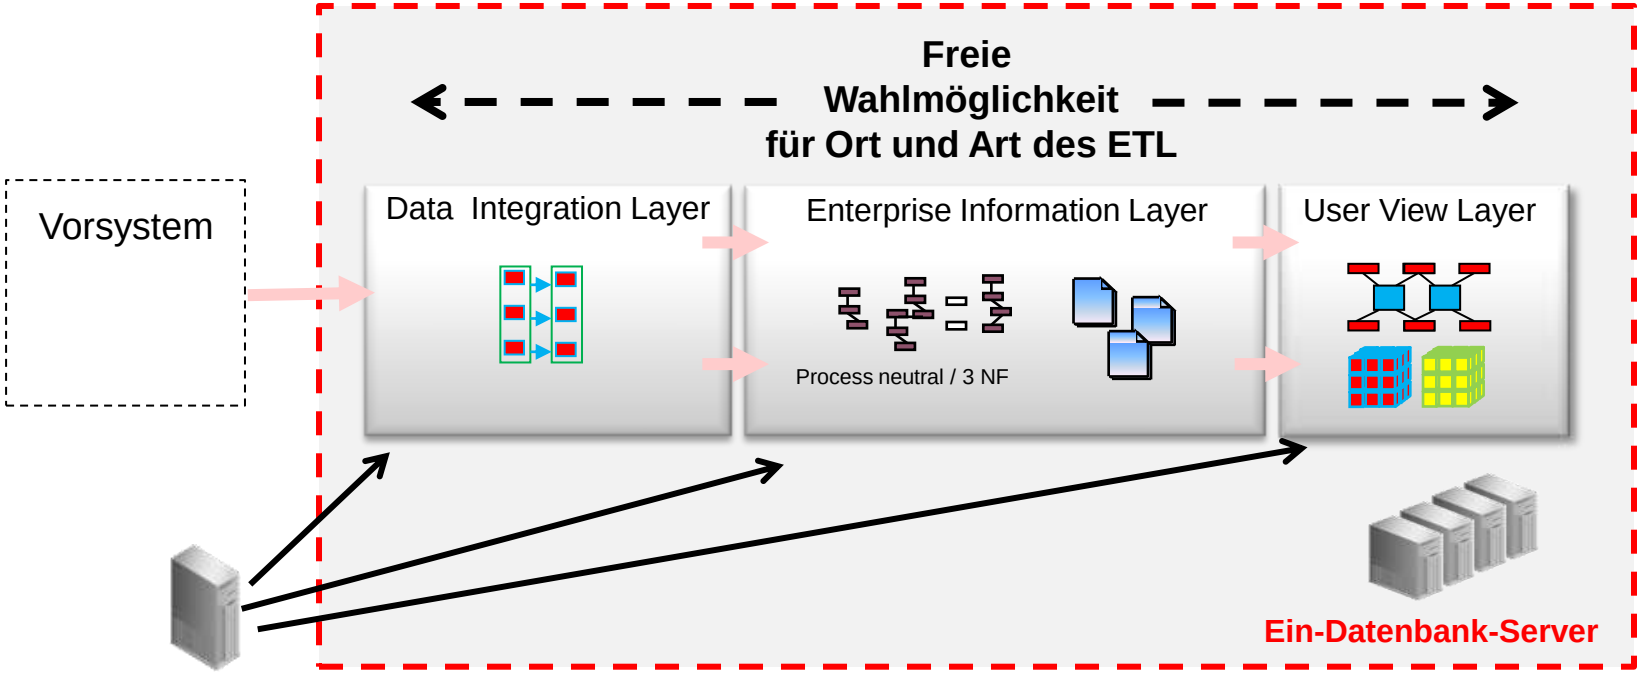

Zusammenfassung der wichtigsten Techniken

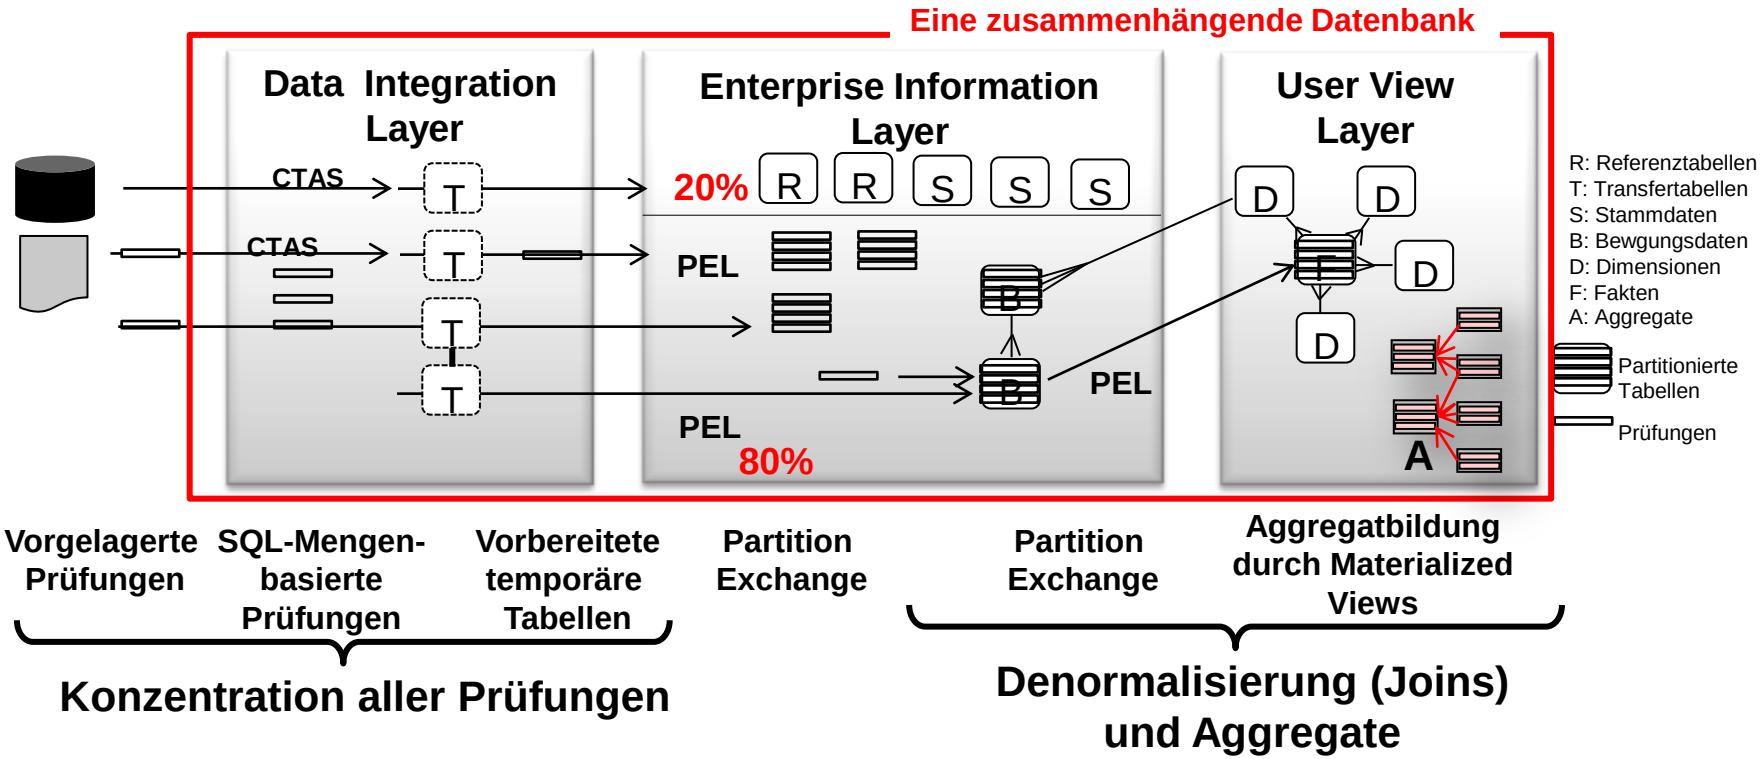

CTAS : Create Table As Select

PEL : Partition Exchange and Load

DATA WAREHOUSE