Übung

Data Warehouses

Wintersemester 2000/2001

Extraktion, Transformation, Laden

Datenflußparadigma

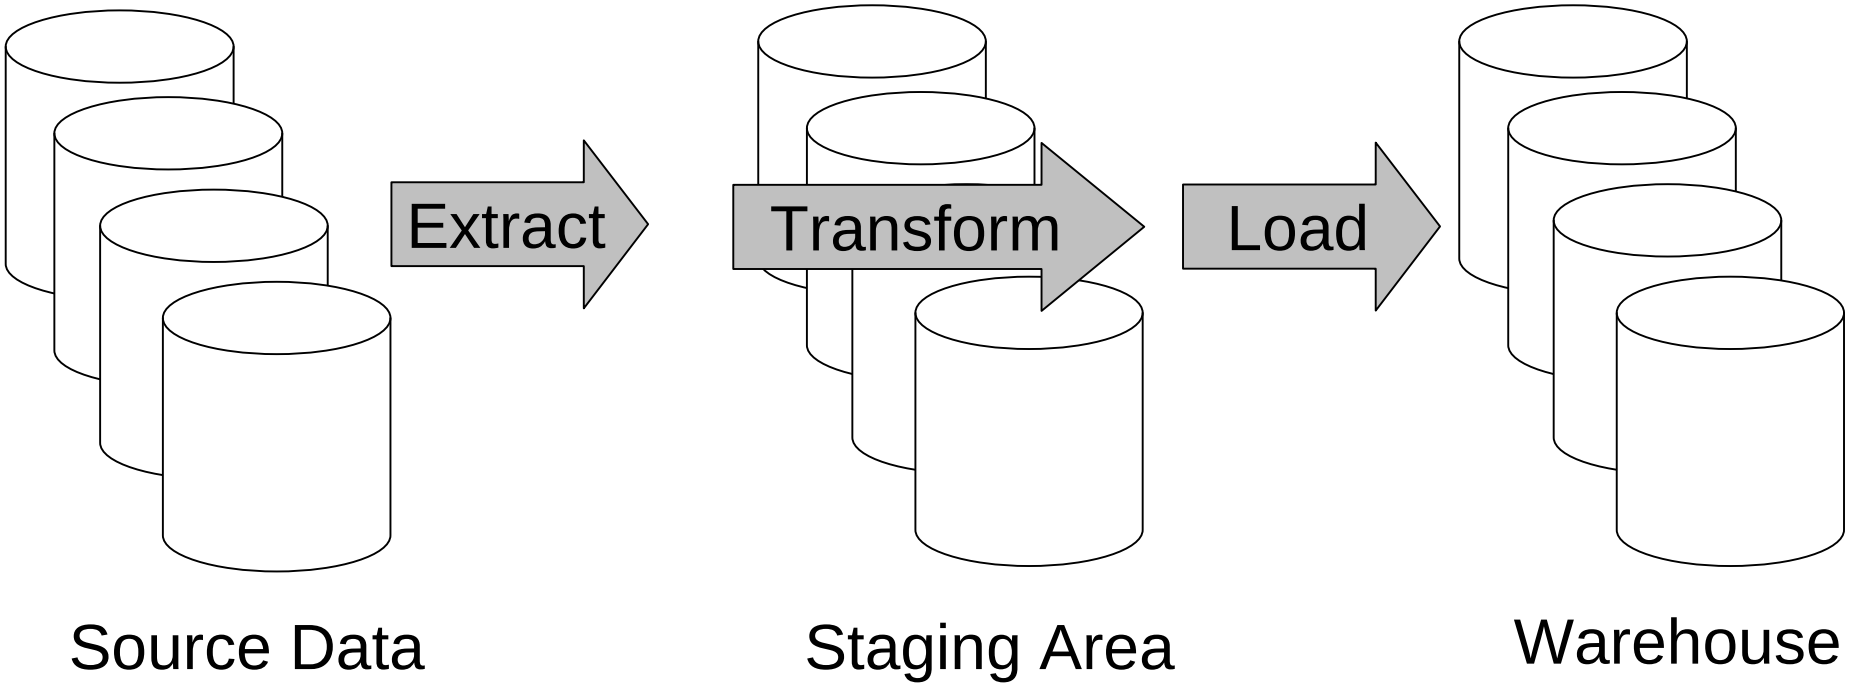

Source Data

- Einbinden von Datenquellen
  - Relationale Datenbanken (Oracle, SQL-Server...)
  - Flat Files
- Builder speichert Definitionen der Datenquellen als „Source Module“

Staging Area

- Bereich, in dem der Transformationsprozeß vor dem Laden in das Warehouse stattfindet
  - Bereinigung (cleaning)
  - Anpassung (editing)
  - Integration
  - Berechnung
- Builder speichert Definitionen und Mappings als „Warehouse Module“

Adminstration Mode

- Anlegen, Umbenennen und Löschen von Projekten
- Ändern der Eigenschaften von Projekten
- Verwalten von Integratoren (z. Zt. Nur RDBMS und Flat Files)

Project Mode

- Verwalten von Definitionen für
  - Data Warehouse Schemata
  - Datenquellen
  - Operationen zur Transformation
  - Mapping der Datenquellen über Transformatoren auf Zieltabellen
  - Generieren und Ausführen von Skripten

Transformation Mode

- Anlegen und Ändern von Transformationen
- Modifizieren der Eigenschaften von Source Modules oder Warehouse Modules

Data Source Module

- Modul für Oracle-Datenbanken anlegen
  - Datenbankverknüpfung anlegen
  - Tabellendefinitionen importieren
- Modul für Flat-Files anlegen
  - Verzeichnispfad angeben
  - Textdateien mit Metadaten Wizard einbinden
- Für eine graphische Darstellung:
  (Source Module Toolbar → View → Schema)

Entwicklungsstand

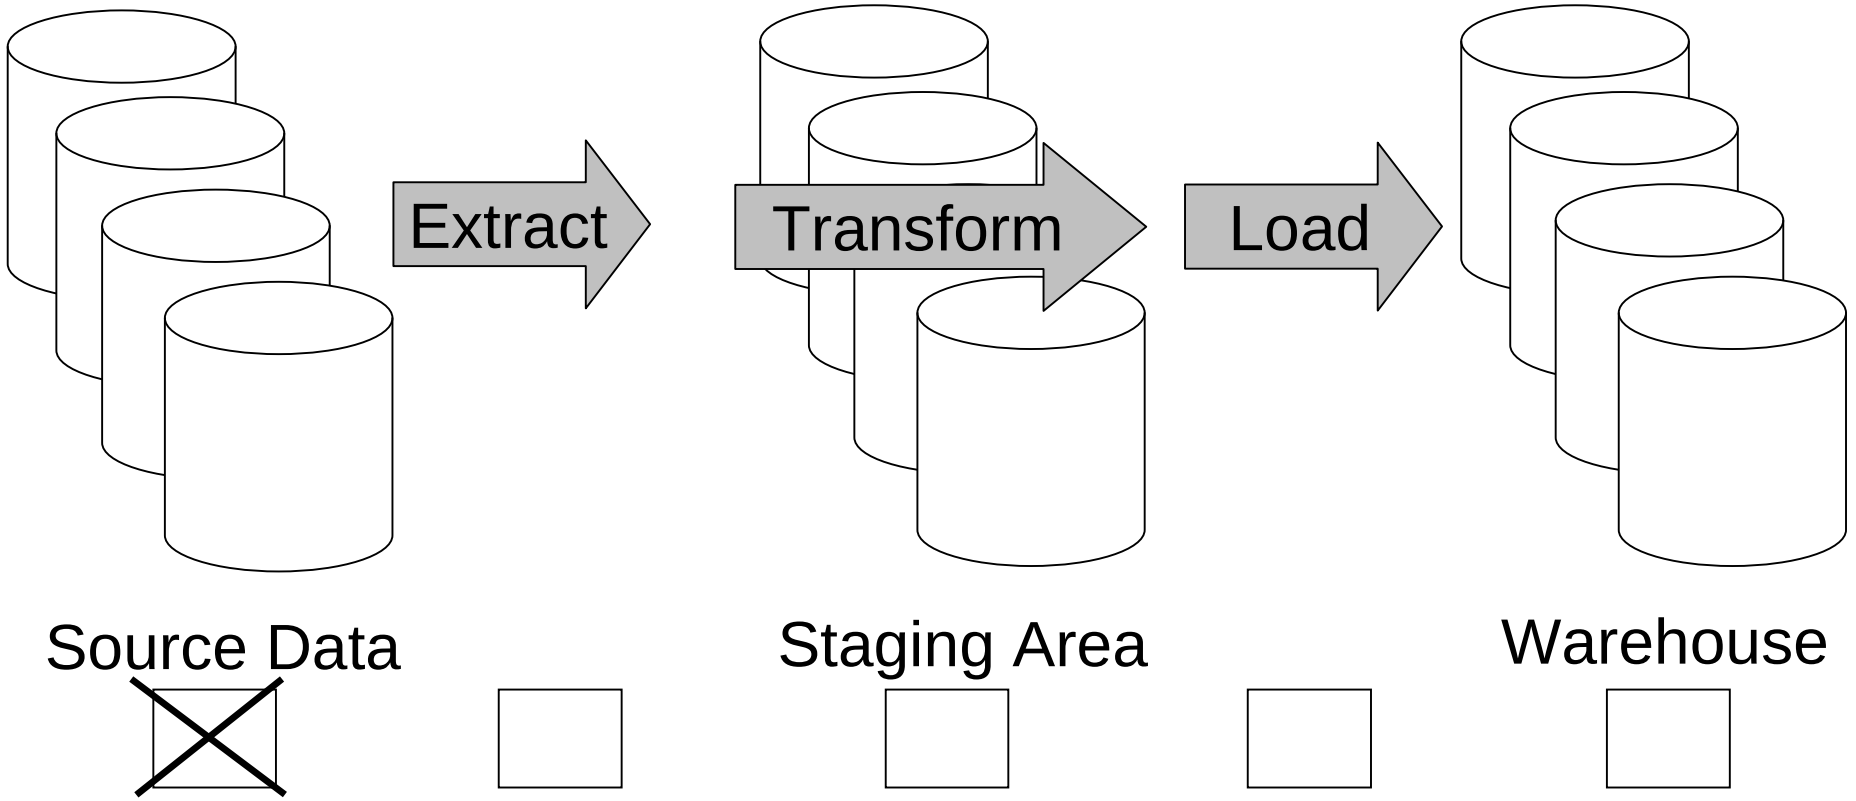

Schema der Staging Area

- Ähnelt oft den Datenquellen
- Erzeugung der künstlichen Schlüssel für die Dimensionen
  - Künstliche Schlüssel sind eindeutig (meist Sequenz)
  - Ursprünglicher Primärschlüssel bleibt erhalten
- Stage One: Faktentabelle mit Referenz auf die ursprünglichen Primärschlüssel
- Stage Two: Faktentabelle, erzeugt durch Star-Join bei Projektion auf die Kennzahlen und künstlichen Schlüssel

Beispiel einer Staging Area

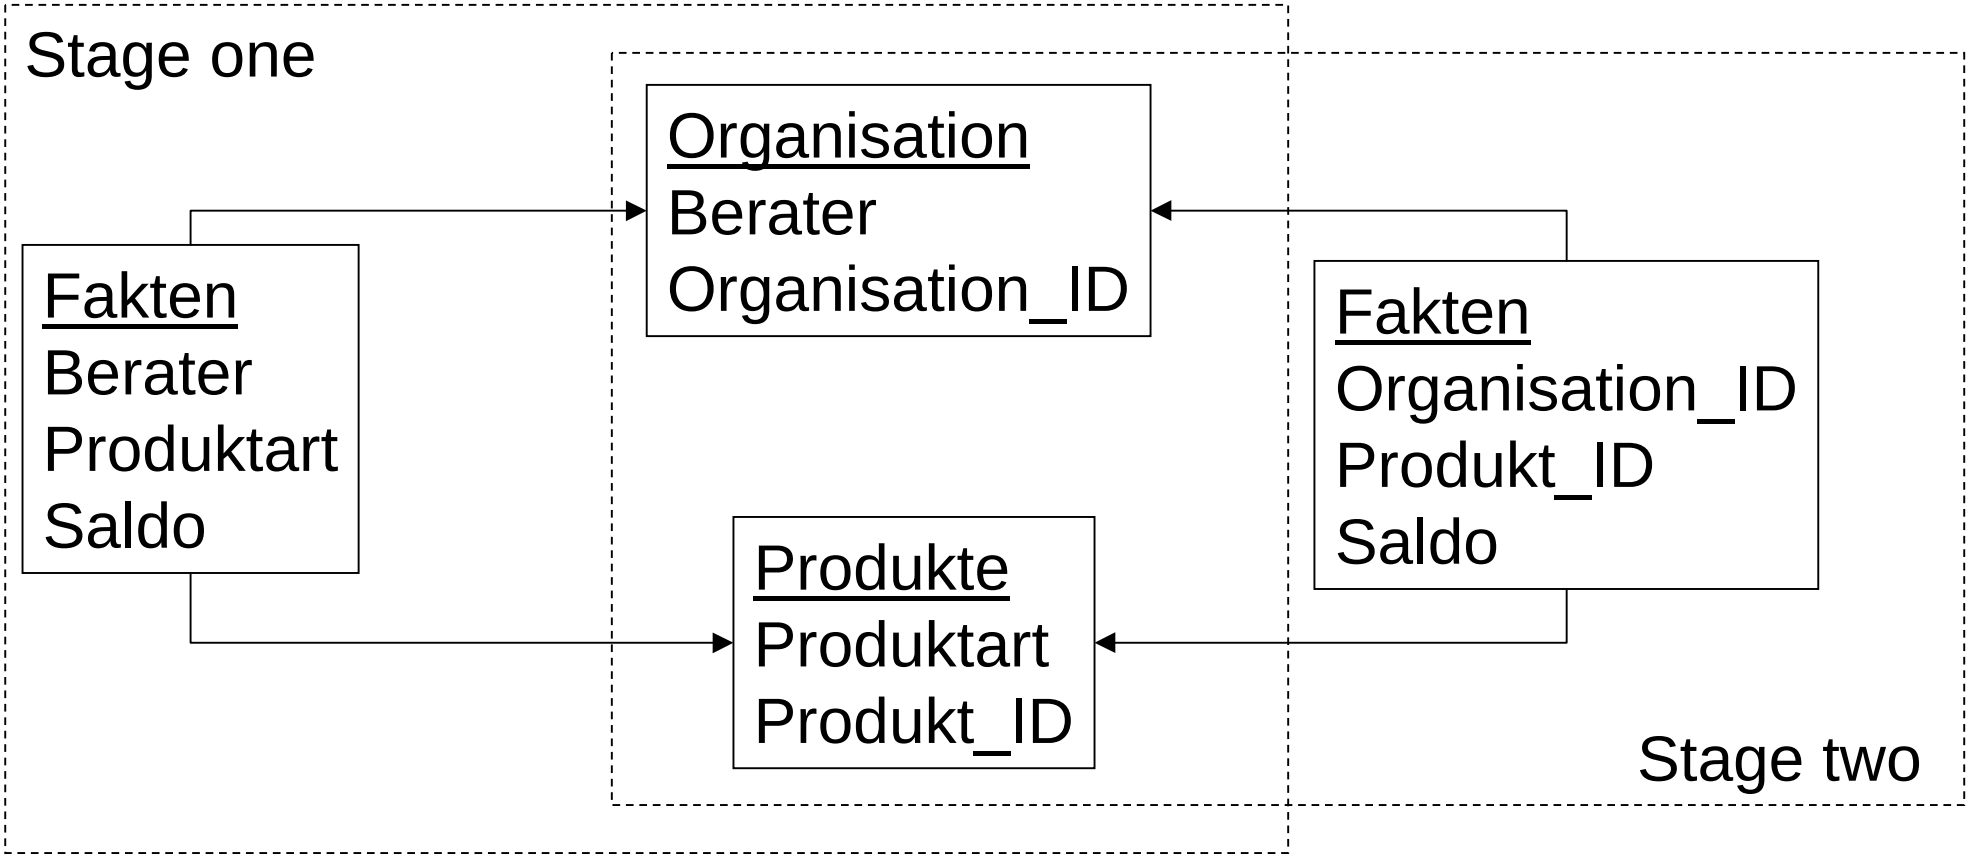

Anlegen der Staging Area

- Staging Area ist ein Transformationsziel $\Rightarrow$ Speicherung im Warehouse Module
- Möglichkeiten der Speicherung
  - Zieldatenbank (im eigenen oder allg. Schema)
  - Zwischendatenbank (bspw. aus Performancegründen lokal)
  - System einer der Datenquellen (unüblich)

Mapping von Datenquellen auf die Staging Area

- Auswählen des Warehouse Moduls der Staging Area $\rightarrow$ Mappings $\rightarrow$ Create Mapping
- Offnen des Mappings, Hineinziehen der Datenquelle (select from existing tables)
- Mit Shift-Drag in das Zielschema kopieren $\rightarrow$ Create-Like wizard

Fertigstellen des Mappings

- Künstl. Schlüssel (Warehouse Key) hinzufügen
  - Columns → Add (NUMBER)
  - Constraints → Add → Primary Key
- Vervollständigen der Tabellendefinition
  - Eindeutiger ntürlicher Schlüssel (s.o., aber Unique Key)
  - Filtern von Spalten

Erzeugen des Warehouse Keys

- Bei relationalen Quellen
  - Create Sequence
  - Drop Secondary Source auf Mapping Definition
  - Drop NEXTVAL der Sequence auf Warehouse Key
- Bei Flat Files
  - Create Local Variable
  - Variablenname muß SEQ sein, Syntax SEQUENCE(MAX, 1)

Erzeugen des Mappings für die Faktentabelle (Stage 1)

- Create-Like Wizard aufrufen und Tabelle mit Transaktionsdaten in die Staging Area kopieren
- Spalten für die natürlichen Schlüssel aller Dimensionstabellen der Staging Area anlegen
- Fremdschlüssel für die natürlichen Schlüssel der Dimensionen Eindeutigkeit für den eigenen definieren.
- Überflüssige Spalten entfernen
- Bei mehreren Quellrelationen über Secondary Source einbinden (Foreign Keys notwendig)

Erzeugen des Mappings für die Faktentabelle (Stage 2)

- Tables → Create Table (Faktentabelle Stage 2)
- Anfügen der Spalten
- Mapping anlegen
  - Keine Source Modules
  - Add Table (from existing tables) (Fakten 1 und 2)
  - Drop Fakten 1 auf Fakten 2 (rechte Maustaste)
  - Dimensionstabellen als Secondary Sources einbinden

Entwicklungsstand

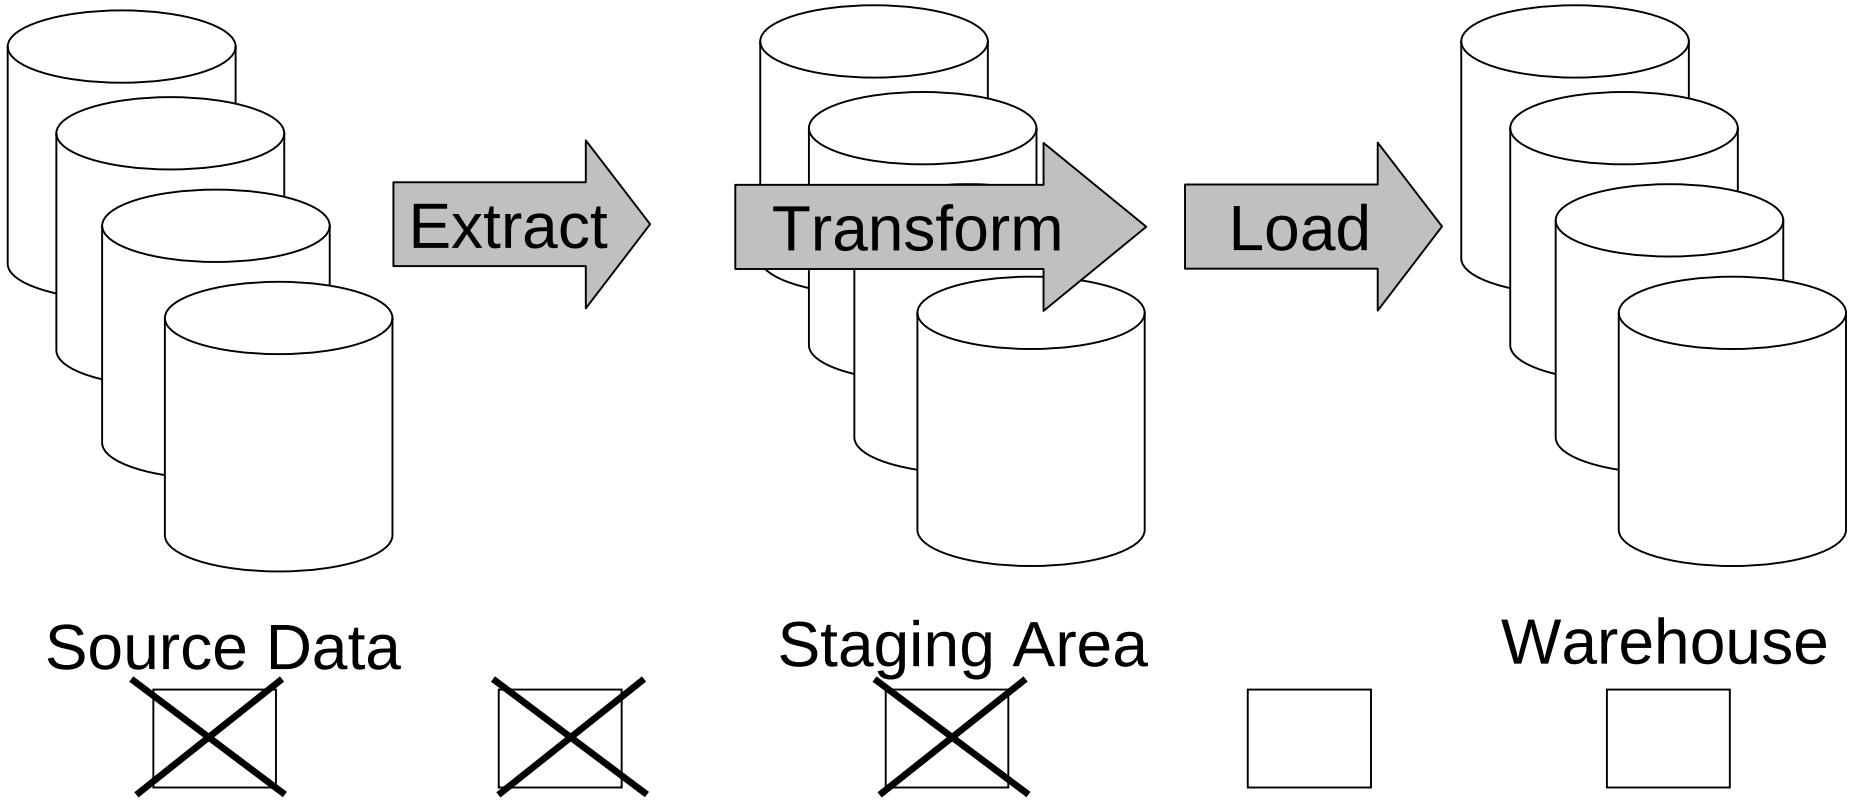

Warehouse Module

- Neues Projekt anlegen und in dieses wechseln
- Neues Warehouse Module zur Abbildung des Warehouse-Modells anlegen und Eigenschaften einstellen
- Bestandteile definieren:
  - Dimensionen (Sonderfall: Zeitdimension)
  - Faktentabelle(n)
  - Später: (Materialized) Views
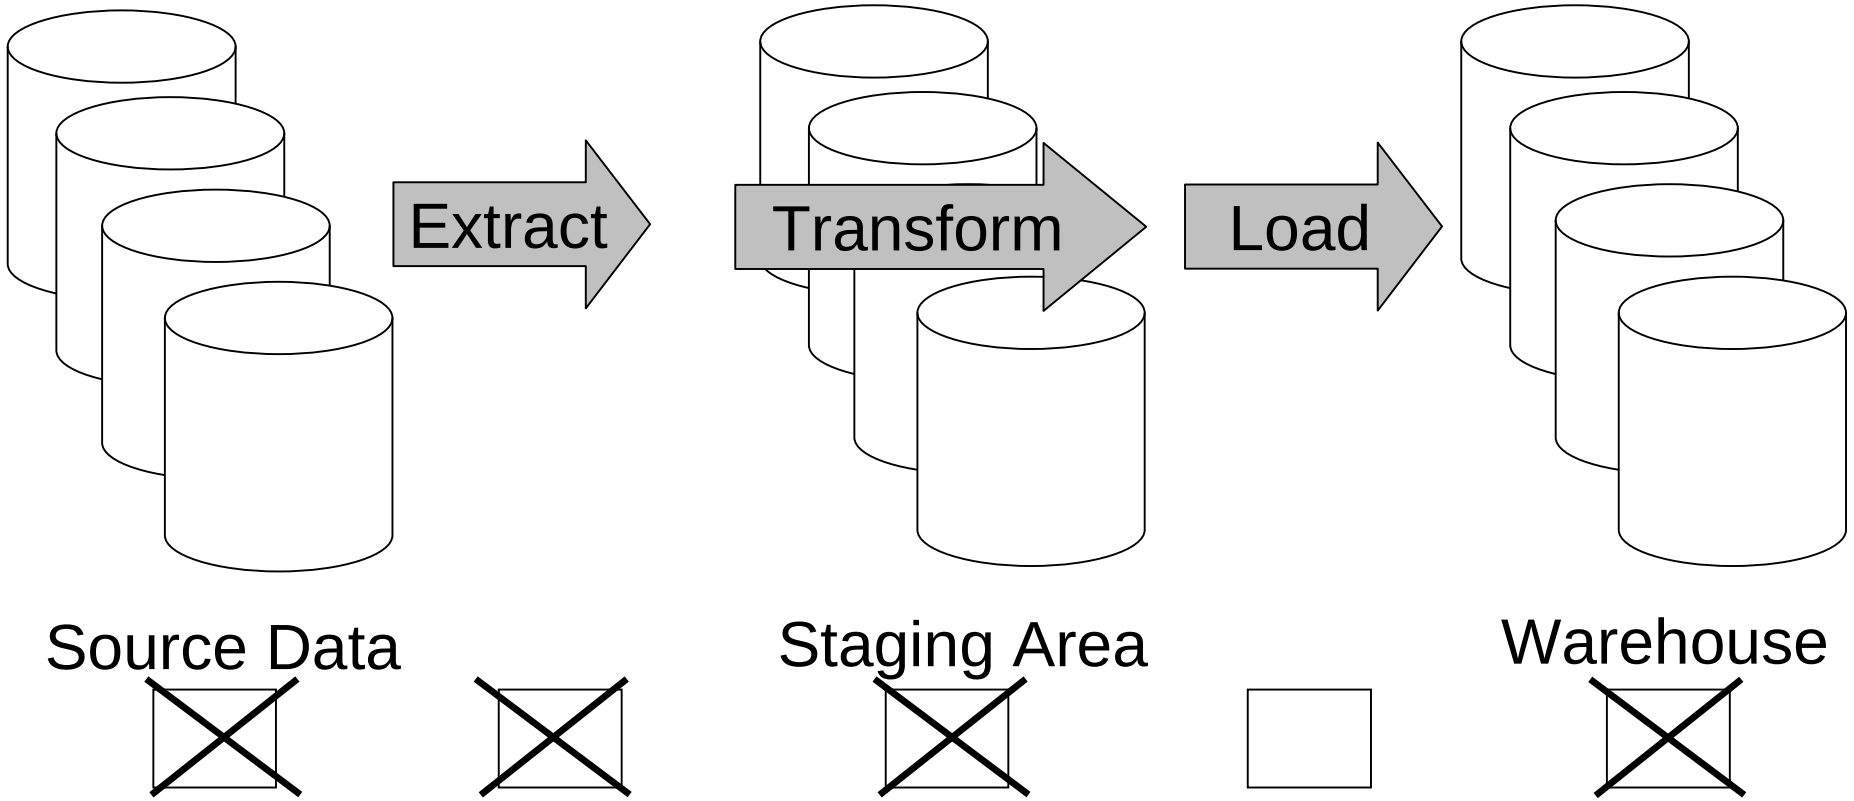
Entwicklungsstand