Análisis de Paper AJAX

"Declarative cleaning your data using AJAX"

Tratando de enfocarlo en el modelado del proceso como Grafo

Introducción

- Problema: limpieza de información.
- Contexto:
  - Estructuración de información poco estructurada
  - Number of Sources:
    - Single data source
    - Multiple sources
- Modelado como: grafo de transformación de información.

Quality & Anomalies

- Quality: *"Data quality concerns arise when correcting anomalies ..."*
- Data Cleaning: *"The main goal of a data cleaning process is to eliminate anomalous data ..."*
- Anomalies:
  - The absence of universal keys = Object Identity Problem ?
  - Missing Values
  - The use of different data formats

Quality & Anomalies (II)

- Anomalies:
  - The existence of data entry errors ("John Smith", "Joh Smith")
  - The presence of inconsistencies in data
- Data Cleaning (II): *"Dealing with these problems is globally called the data cleaning process"*

Ex. of Cleaning process in DW

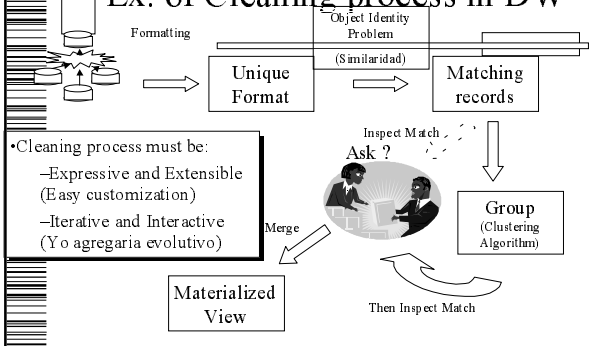

AJAX

- Is a **framework** (librería de funciones)
  - Extensiones:
    - Mas funciones en la libreria
    - Mas algoritmos de clustering
- Provides a **declarative** and **extensible language** (SQL + algunas primitivas)
- **Optimizations** (SQL Query Engine + external home-grown execution engine) (Producto Cartesiano)
- **Data Lineage** (debugger)

Cleaning as a Directed Acyclic Graph

- Directed Acyclic Graph of Atomic Transformations ***(Process)***
  - Each one accepts as input the data flow(s) from previous transformation(s)
  - And returns one or more data flows
  - Tienen restricciones sobre la salida.
- Five types of atomic Transformations ***(Process Types)***:
  - Mapping: Standardizes data formats
  - Matching: Pairs of records that refer to the same object
  - Clustering: Group together matching pairs
  - Merging: Collapses each individual cluster
  - SQL View: An SQL join or union
- Complex Transformations ***(Sub-Process)***: Is a sequence of one or more atomic transformations

Example of Graph

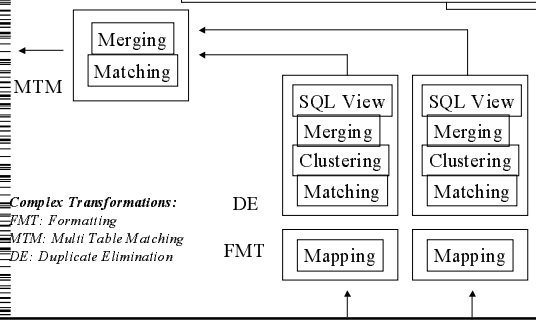

Data Cleaning Program

<data cleaning program>::
(<declaration of complex type>)*
(<registration of functions and algoritms>)*
(<declaration of input data flow>)+
(<transformation definition>)+

<transformation definition>::
<CREATE>(**<MAPPING>|<MERGING>|<CLUSTERING>|<MERGING>|<SQLVIEW>**) **<output data flow>**
(<FROM>**<input data flow>**+)
....
(**<CONSTRINT>**(<expresion><DEP><expresion> ....

Definen primitivas pero dan la posibilidad de incorporar mas.

Atomic Transformations (Primitivas) & User Interaction

- Biblioteca de Transformaciones Atomicas
  - Data Mapping, Data Matching, Matching for Duplicate Elimination, Matching for Multi-Table Matching, etc.
- Interactua con el usuario
  - Mecanismo excepciones (Java like).
  - Al final de cada transformacion manejo excepciones.
  - Tipos de excepciones: Anticipadas / No Anticipadas.
  - Handle:
    - insert/delete/modify la tupla de la excepcion
    - modificar la definicion de la transformacion

Comparacion de AJAX vs. SQL

- Clustering & Merging no tienen equivalente (Dice que logicamente en SQL no se pueden llamar algoritmos externos de clustering y tampoco esta la idea de consolidar tuplas en una sola).
- SQL no tiene excepciones (si hay error stop).
- Optimizacion (SQL99 soporta lenguaje procedural pero la optimizacion no explota esto).

AJAX Architecture

- La divide en:
  - Repositorios:
    - "Data Repository" (store input/output data),
    - "Library of Functions" (para transformaciones),
    - "Library of Algorithms" (para clustering)
  - Unidades operacionales:
    - "Analizer" (parse program),
    - "Optimizer" (chose plan),
    - "Execution Engine" (execute transformation),
    - "Explainer" (audit, continua ...)

AJAX Arquitecture (II)

- Explainer (saber que pasa con los datos)
  - Debug o
  - Refinar el proceso
    - Acciones:
      - Cambio (errores en la construccion del proceso)
      - Modificaciones locales (toco los datos origen)
    - "Incremental Cleaning" (solo lo menciona)

Optimizations

- Mixed Evaluation (parte dentro / parte fuera del DBMS)
- Operation re-ordering (subir .)
- Neighborhood Hash Join (similarity, distancia con posibles tuplas de Join)
- Short-Circuited Computation (lazy evaluation)
- Cached Computation (Cache para funciones externas)
- Parallel Computation (Uso de paralelismo y replicacion)

Related Work

- Main Approaches for Cleaning Data
  - Dedicated Application Program
    - Solucion no flexible (refinamiento = reprogramacion).
    - No aprobecha capacidades de las BD (p.e. Join).
    - Optimizaciones son dejadas al programador.
  - Normalization functions (se pueden integrar)
    - Solo para campos estandarizables (p.e. US address).
    - Diccionarios pre-construidos.
  - Multi-Pass Neighborhood Method (Se puede hacer)
    - Repetir 2 pasos (elegir clave, comparar con los cercanos)
  - Interleave discovery of data with their correction
    - Tradicionalmente 2 pasos Analisis (data mining) y Limpieza.
    - AJAX se concentra en limpieza.

Productos Comerciales

- Fixed key based matching strategy, usually variants of the multi-pass neighborhood method.
- Matching/Clustering/Consolidation are not all supported by every tool.
- Criterios limitados por lo que el producto soporta.
- Do not enterely support the user interaction during the cleaning process.
- En general no soportan lenguages de especificacion.
- Backtracking no es soportado.

Ideas Interesantes

- Transformaciones complejas . Primitivas Complejas
- Lenguaje de definicion de primitivas
- Excepciones para manejo de errores e imprevistos.
- Refinamiento de proceso mediante trace (componente Explainer)

Conclusiones

- Hay ideas interesantes que se pueden extrapolar a las primitivas y los procesos de carga.
- El modelado del proceso como grafo es mas bien titulo (porque en el abstract ?).
- Se focalizan en describir el framework y el lenguaje de consulta, tambien dan un overview de las principales tecnicas de optimizacion.
- A corto plazo se proponen:
  - Estudiar la creacion de diccionarios durante el proceso.
  - Estudiar refinamientos del proceso de limpieza (incremental cleaning)

Conclusiones (II)

- A largo plazo se proponen:
  - Un nuevo conjunto de transformaciones que permitan integrar informacion estadistica y metodos de aprendizaje para analizar la informacion y ayudar al usuario.

Referencias interesantes

- W, Cohen. Some practical observations on integration of Web information. In WebDB'99 Workshop in conj. With ACM SIGMOD, 1999.