



Departamento de Ciencias de la Computación
UNIVERSIDAD DE CHILE

Principles of Dataspace Systems

Alon Halevy

Michael Franklin

David Maier


Maíra Marques Samary
Santiago, 21 de octubre de 2010

Agenda

- Motivación
- Desafíos
- Definiciones
- Ejemplos
- Data Integration
- Propiedades
- Respuestas de Consultas
- Introspección
- Respuestas

La web esta se tornando semántica

- Forms (millones)
- Buscadores verticales (centenas)
- Esquemas de anotaciones (facebook, flickr, games)



Motivación

- Demanda en administrar heterogéneas y múltiples fuentes de datos con distintos modelos de datos (DBMS)

Desafíos

- ⦿ Encontrar fuentes de datos relevantes
- ⦿ Dar acceso a búsquedas y consultas
- ⦿ Trazar el origen
- ⦿ Determinar la validez de la información

Definiciones

- Data Space Management System (DSMS) - abstracción para la administración de datos en ese escenario



EJEMPLOS

Personal Information Management (PIM)

- Ofrecer acceso y manipulación sencillos de toda la información de la computadora de una persona.
 - Hoy esta limitada a consultas de palabras

Personal Information Management (PIM)

- Aplicación de los principios de Dataspace:
 - Herramienta PIM debe dar acceso a toda la información en la computadora y no solamente la implícita o explícita en el conjunto elegido
 - No se puede asumir que los usuarios van a invertir su tiempo en integrar los datos de varias fuentes

Contenidos en la web


- Contenido no estructurado
 - >20% contenido porno
 - >40% contenido spam

Aplicación de los principios de Dataspaces:

- Necesidad de una herramienta de búsqueda que acepte palabras llave y seleccione fuentes estructuradas relevantes
- Combine las respuestas estructuradas y no estructuradas de una misma manera


DATA INTEGRATION

Data Integration



DataSpace x Data Integration

- ⦿ Data Integration necesita una integración semántica antes que cualquier servicio sea ofrecido.
- ⦿ Dataspace sería la evolución de las arquitecturas de integración
- ⦿ Dataspace entrega funcionalidades básicas sobre todas las fuentes de datos sin importar como es la integración entre ellas.



PROPIEDADES

Propiedades de Dataspaces

- ⦿ Trabajar con datos y aplicaciones en muchos formatos y debe ser accesible a través de muchos sistemas con distintas interfaces.
- ⦿ Tiene que ofrecer una manera integrada de búsquedas, consultas, actualizaciones y administración. Al mismo tiempo que el mismo dato tiene que ser accesible y modificable por un interfaz nativa del sistema de hosting

Propiedades de Dataspaces

- ⦿ Varios niveles de servicio y en algunos casos puede retornar “best-effort” o respuestas aproximadas.
- ⦿ Debe ofrecer herramientas y caminos para crear una integración mas justa de los datos en el espacio se necesario.

Participantes y relaciones

- El modelo de un Dataspace es un conjunto de participantes y relaciones
 - Participantes - fuentes de datos individuales (xml, txt, csc, databases)
 - Relaciones – pueden ser dos o mas participantes

RESPUESTAS DE CONSULTAS

Consultas

- ⦿ Hechas en distintos lenguajes
- ⦿ Consideran todos los datos relevantes en el Dataspace sin importar el modelo de datos, a menos que sea especificado de otra manera

Respuestas

- Ranqueadas
- Heterogénea
- Fuentes como respuestas
- Iterativa
- Reflectada

Desafíos en términos de modelos de datos y consultas

- ① Desarrollo de un modelo formal para estudiar las respuestas de las consultas en Dataspaces
- ① Desarrollo de métodos para responder consultas de múltiples fuentes que no se basen solamente en aplicar un conjunto de semántica correcta

INTROSPECCIÓN

Introspección

● Introspección es una necesidad en Dataspaces

- Incerteza
- Inconsistencia
- Linaje

Incerteza

- El exacto estado del mundo no es conocido.
- El objetivo de una base de datos incierta es representar un conjunto de los posibles estados del mundo (mundos posibles)



Incerteza – A-tupla

(Karina Powers, {345-9934 | 345-9935})

(George Flores, 674-9912)

- Teléfono de Karina es uno de los dos
- Si George tiene un teléfono su numero es conocido
- ⦿ No son cerradas por los operadores relacionales

Incerteza – X-tupla

(Karina Powers, 345-9934, 345-9935
|(Karina Powers, 345-9935, 345-9934)

- No sabemos cual es el teléfono de Karina y cual es el fax
- ⦿ No son cerradas por los operadores relacionales

Incerteza – C-tabla

Karina Powers	456-3214	$X = 1$
Karina Powers	654-1234	$X \neq 1$
Karina Powers	456-4444	$X \neq 1$

- Existen dos mundos de acuerdo con los valores de x
- ⊙ Son cerradas por los operadores relacionales
- ⊙ Chequear si un conjunto de tuplas I es un posible mundo para D es un problema Np-completo


Inconsistencias

- ◉ Es la incerteza de cual valor es el correcto
- ◉ Bases de datos inconsistente trabajan con situaciones donde hay datos confrontantes
- ◉ Considerar los distintos tipos de reparación
- ◉ El conjunto de mundos posibles corresponde a las distintas reparaciones



Linaje

- Externa – tuplas inseridas
- Interna – tuplas de respuestas a consultas
 - Árbol de prueba
 - Para consultas con agregación o negación no existe una definición obvia de linaje



Desafíos en términos de incerteza, inconsistencia y linaje

- Desarrollar formalismo que sea capaz de modelar incerteza, inconsistencia y linaje

RESPUESTAS

Respuestas

- ⦿ ¿Que es una buena respuesta para una consulta?
 - Relevancia para la consulta
 - Certeza de la respuesta
 - Completitud y precisión
 - Tempo de latencia máximo en la respuesta

Desafíos en términos de respuestas

- ① Definir métricas para comparar la calidad de las respuestas y de los conjuntos de respuestas de los Dataspaces
- ① Técnicas eficientes de procesamiento de consultas

Desafíos en términos de la atención humana

- ① Desarrollar métodos para capturar la interacción de las actividades de los en los Dataspaces
- ① Analizar esas actividades para crear relaciones significativas entre fuentes en los Dataspaces

Thank You!

