“Modeling ETL Activities as Graphs” (Vassiliadis, Simitsis, Skiadopoulos) y posicionamiento de la propuesta de “Primitivas de Transformación de Esquemas”

“Modeling ETL Activities…”

- Introduccion
- El “Architecture Graph”
- Explotación del Architecture graph
- ARKTOS
- Conclusiones

Introduccion

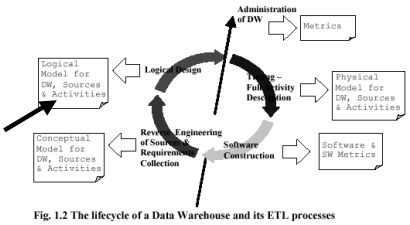

Fig. 1.2 The lifecycle of a Data Warehouse and its ETL processes

El trabajo se centra en el diseño lógico del escenario de ETL de un DW.

Introduccion

- Estado del arte:
  - Herramientas ETL
  - Ajax
  - Articulo de Workflow para ETL, de Mokrane
  - Otros trabajos de Vassiliadis sobre procesos de DW, metadata y calidad
- Pero…
  - Estos enfoques no han considerado en profundidad la *estructura interna de las actividades de ETL.*

Introduccion

- Contribuciones
  - Definición de un modelo lógico formal como abstracción lógica de procesos ETL
    - Incluye depositos de datos, actividades ETL y sus componentes (son todas entidades)
  - Reducción del modelo a un grafo, *Architecture Graph*
    - Las *entidades* anteriores son *nodos*, y las *relaciones* (4 tipos) entre ellas son las *aristas*.
  - Explotación del *Architecture Graph*
    - Transformaciones del grafo (zoom in/out)
    - Importance metrics: *dependence* y *resposibility*

El “Architecture Graph”

- Definiciones previas
- Escenario ETL
- Ejemplo
- Architecture Graph
- Ejemplo (cont.)

Definiciones previas

- Nodos
  - Tipos de datos
  - Tipos de funciones
  - Constantes
  - Atributos
  - Actividades
  - Conj. de registros
  - Funciones

  } **terminos**

  Esquema: lista finita de atributos
- Aristas (relaciones entre nodos)
  - Part-of
  - Instance-of
  - Proveedor
  - Regulador
  - Proveedor derivado

Nodos

- **Data Type** - nombre, dominio
- **Attributes** - nombre, tipo de datos
- **RecordSet** - nombre, esquema, extension
- **Function Type** - nombre, tipos de datos de parametros, tipo de datos de resultado.
- **Function** - instancia de un tipo de funcion
- **Activities**
  - Terminologia de [WfMC98] para procesos/programas
  - Abstracciones lógicas representando parte/modulos completos de código
  - Usan sentencias SQL para representar la semantica de las actividades

Aristas

- **Part-of -** Relaciona atributos y parámetros con actividades, conj. de registros o funciones
- **Instance-of -** Relacion entre data/function type y sus instancias
- **Provider -** Relaciones 1:N entre atributos (provider-consumer). Se define con nombre, mapping.
- **Regulator -** Relaciones entre los parametros de las actividades y los terminos que las instancian (populate).
- **Derived provider -** Caso particular de provider, cuando output attributes se derivan de la combinacion de input attributes y parametros.

Activities

- Actividad, descripta formalmente por:
  - *Name*
  - *Input Schema*
    - Recibe los datos del data provider
  - *Output Schema*
    - "placeholder" para las tuplas que pasan el chequeo de la activ.
  - *Rejections Schema*
    - "placeholder" para las tuplas que no pasan el chequeo de la act.
  - *Parameter list* (esquema, atributo, funcion o cte.)
  - *Output Operational Semantics* (SQL)
  - *Rejection Operational Semantics* (por def. la neg. del ant.)

Escenario ETL

- Consiste de
  - Name
  - Activities
  - RecordSets (fuente)
  - Targets
    - tablas del DW que seran pobladas por las actividades
  - Provider Relationships
    - Relaciones "provider" entre actividades y recordsets del escenario
- Intuitivamente
  - Conj. de actividades presentadas en un grafo en una secuencia de ejecución.

Ejemplo de Escenario

Source	Recordset Name	Recordset Schema
S_1	S_1.PARTSUPP	PKEY, DATE, QTY, COST
S_2	S_2.PARTSUPP	PKEY, QTY, COST
DSA	DS.PS_NEW$_1$	PKEY, DATE, QTY, COST
	DS.PS_OLD$_1$	PKEY, DATE, QTY, COST
	DS.PS$_1$	PKEY, DATE, QTY, COST
	DS.PS_NEW$_2$	PKEY, QTY, COST
	DS.PS_OLD$_2$	PKEY, QTY, COST
	DS.PS$_2$	PKEY, QTY, COST
DW	DW.PARTSUPP	PKEY, SUPPKEY, DATE, QTY, COST
	LOOKUP_PS	PKEY, SOURCE, SKEY
	V1	PKEY, DAY, MIN_COST
	V2	PKEY, MONTH, AVG_COST
	TIME	DAY, MONTH, YEAR

Fig. 2.2 The schemata of the source databases and of the data warehouse

Ejemplo de Escenario

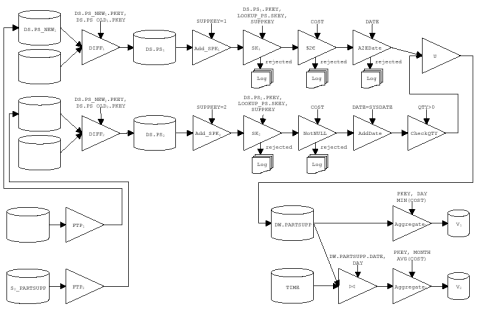

Architecture Graph

- El Architecture Graph y el escenario
  - El AG contiene todas las actividades y depositos de datos del escenario, junto con sus componentes
  - El AG captura el flujo de datos dentro del ambiente ETL
  - El AG da la informacion de
    - tipos de las entidades
    - regulacion de la ejecucion del escenario

Dominios y notacion

	Entity	Model-specific	Scenario-specific
Built-in	Data Types	$\mathbf{D}^1$	**D**
	Function Types	$\mathbf{F}^1$	**F**
	Constants	$\mathbf{C}^1$	**C**
User-provided	Attributes	$\mathbf{\Omega}^1$	$\mathbf{\Omega}$
	Functions	$\mathbf{\Phi}^1$	$\mathbf{\Phi}$
	Schemata	$\mathbf{S}^1$	**S**
	RecordSets	$\mathbf{RS}^1$	**RS**
	Activities	$\mathbf{A}^1$	**A**
	Provider Relationships	$\mathbf{Pr}^1$	**Pr**
	Part-Of Relationships	$\mathbf{Po}^1$	**Po**
	Instance-Of Relationships	$\mathbf{Io}^1$	**Io**
	Regulator Relationships	$\mathbf{Rr}^1$	**Rr**
	Derived Provider Relationships	$\mathbf{Dr}^1$	**Dr**

Fig. 3.1 Formal definition of domains and notation

Notacion grafica (AG)

Data Types	Black ellipsis	Integer
Function Types	Black squares	$2€
Constants	Black cycles	1
Attributes	Hollow ellipsoid nodes	PKEY

RecordSets	Cylinders	R
Functions	Gray squares	my$2€
Parameters	White squares	rate
Activities	Triangles	SK

Part-Of Relationships	Simple edges annotated with diamond*	
Instance-Of Relationships	Dotted arrows (from instance towards the type)	
Regulator Relationships	Dotted edges	

Provider Relationships	Bold solid rrows (from provider to consumer)	
Derived Provider Relationships	Bold dotted arrows (from provider to consumer)	

* We annotate the part-of relationship among a function and its return type with a directed edge, to distinguish it from the rest of the parameters.

Ejemplo (cont.)

- Activities: *Add_SPK*$_1$ y *SK*$_1$
- Partes del grafo
  - Atributos y relaciones part-of
  - Data types y relaciones instance-of
  - Parametros y relaciones regulator
  - Relaciones provider
  - Relaciones derived provider

Atributos y relaciones part-of

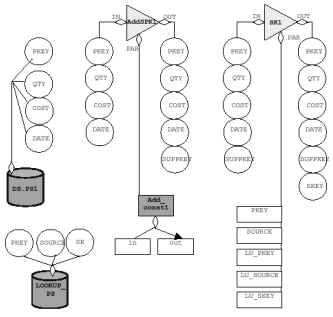

Data types y relaciones instance-of

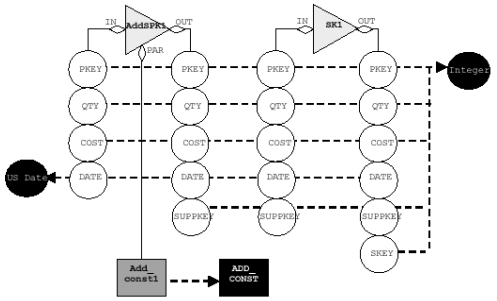

Parametros y relaciones regulator

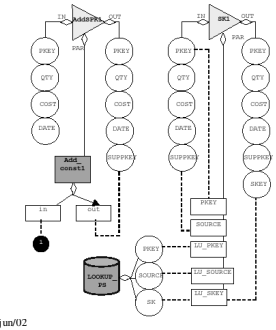

Relaciones provider

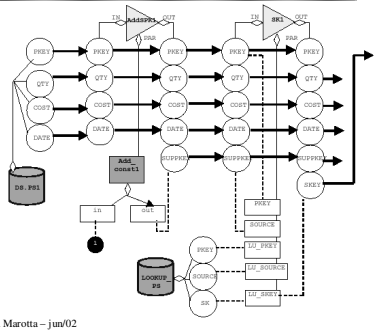

Relaciones derived provider

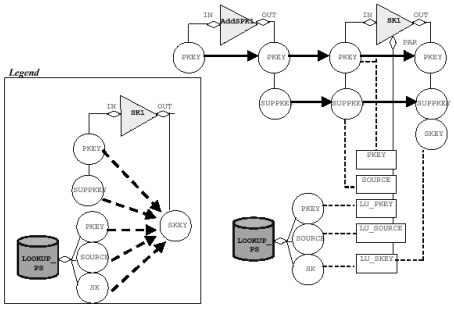

Explotación del AG

- Graph transformations
  - "zoom-out" para eliminar la sobrecarga de información (gran cantidad de atributos).
  - Subgrafo crítico que incluye solo las entidades necesarias para la poblacion de los "target recordsets" del escenario.
- Importance metrics
  - Se asignan a los nodos para medir cuan crucial es su existencia para la ejecucion del escenario
  - *local dependency*, *local responsibility*, *local degree*

Importance metrics

- Local dependency (in-degree)
  - Numero de nodos que deben ser activados para poblarlo
- Local responsibility (out-degree)
  - Cuantos nodos esperan por él para ser activados
- Local degree
  - La suma de los anteriores
- Transitividad
- Estas medidas no son aplicables solo a atributos. Tambien a actividades y recordsets.

ARKTOS - Herramienta

- Objetivos
  - Facilidades graficas y declarativas para la definicion de tareas de limpieza y transformacion de DW
  - Medicion de calidad de datos (factores de calidad)
  - Ejecucion optimizada de secuencias complejas de tareas
- Metamodelo
  - El presentado anteriormente + *Error Type*, *Policy*, *Quality Factors*
- ***Transformation and cleaning primitives***

Primitivas

- Operaciones primitivas para soportar el proceso ETL
- Personalilzadas por el usuario
  - Input, output, data stores, policy, quality factors

Primitive Operation	SQL statement	SEMANTICS clause shortcuts
UNIQUENESS VIOLATION	SELECT * FROM <table> GROUP BY <attribute> HAVING COUNT(*) > 1	<table>.<attribute>
NULL EXISTENCE	SELECT * FROM <table> WHERE <attribute> IS NULL	<table>.<attribute>
DOMAIN MISMATCH~	SELECT * FROM <table> WHERE <attribute> NOT IN <domain specification>	<table>.<attribute> NOT IN <domain specification>
PRIMARY KEY VIOLATION	SELECT * FROM <table> GROUP BY (<attribute_1,...,attribute_n>) HAVING COUNT(*) > 1	<table>.(<attribute_1, ..., attribute_n>)
REFERENCE VIOLATION	SELECT * FROM <table> WHERE <attribute> NOT IN (SELECT <target_attribute> FROM <target_table>)	<table>.<attribute> NOT IN <target_table>.<target_attribute>
FORMAT MISMATCH~~	SELECT APPLY(<reg_exp>,<attribute>) FROM <table> WHERE APPLY(<reg_exp>,<attribute>)	TARGET APPLY(<reg_exp>,<attribute>) SOURCE APPLY(<reg_exp>,<attribute>)
PUSH	Arbitrary SQL query	Arbitrary SQL query

~ works for intervals of numbers and strings
~~ where <reg_exp> is PERL regular expression acting as a formatting function

Definicion de actividades

- Graficamente
  - Paleta con las actividades provistas por ARKTOS
- Declarativamente
  - 2 lenguajes
    - XADL
      - XML-based Activity Definition Language
    - SADL
      - Simple Activity Definition Language

Conclusiones – [VASS02]

- Diseño logico de escenario ETL
- Modelo logico formal y "Architecture Graph"
- "Importance metrics"
- Herramienta ARKTOS para modelar y ejecutar escenarios
- Primitivas para las tareas comunes
- Resultados son parte de un proyecto mas grande
  - Referencian: "Conceptual modeling for ETL Processes"

Trabajo futuro – [VASS02]

- Optimizacion
- Proveer primitivas de transformacion mas ricas
- "It would be nice if the research community could provide formal design guidelines (in the sense of normal forms or extra integrity constraints) for the engineering of ETL processes."

Frases célebres – [VASS02]

- Sobre VM
  - "… viewing the DW as a set of layered, materilized views is a very simplistic view."
  - "… insufficient to describe the structure and contents of a DW."
- Sobre evolución
  - "… the interesting problem is how to design the scenario in order to achieve effectiveness, efficiency and tolerance of the impacts of evolution."
  - "Dependence and responsibility are crucial measures for the engineering of the evolution of the ETL env."

Posicionamiento de las Primitivas de Transformacion de Esquemas

- Algunos enfoques… y el nuestro
- Como nos podemos posicionar?
- Ejemplo
- Conclusiones ?

Algunos enfoques… y el nuestro

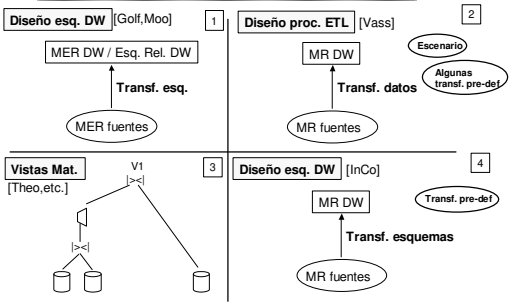

Cómo nos podemos posicionar?

- Diagnóstico
  - Las propuestas 1 y 2 estan totalmente desconectadas.
  - La propuesta de diseño no se preocupa por los procesos ETL y la propuesta para ETL no menciona su relacion con el diseño del esquema de DW, por ejemplo, cómo deduce las actividades a realizar?
  - Las propuestas tipo 1 no resuelven la construccion de estructuras "complejas" de DW (historicos, dimension versioning, datos calculados, etc.), que a la vez son comunes.

Cómo nos podemos posicionar?

- "Filling the gap between DW schema design and the corresponding ETL processes design"
- Un mecanismo para diseño logico de DW que ofrece 2 ventajas:
  - Facilidades para diseñar estructuras complejas de DW
  - Permite la deduccion semi-automatica de un "Architecture Graph" [Vass].

Ejemplo

- Una de las estrategias de diseño para Dimension Versioning era aplicar *Temporalization* haciendo que el nuevo atributo forme parte de la clave.

Diseño del esquema:

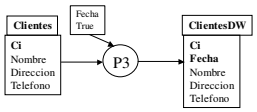

Ejemplo cont.

Generaria:

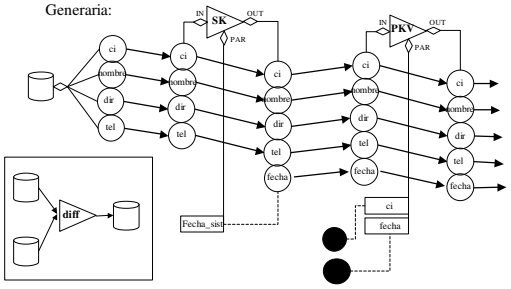

Conclusiones ?