

Concepción de Sistemas de Información

Instituto de Computación – Facultad de Ingeniería – Universidad de la República

SEMINARIO

Estudio de modelos y técnicas de workflow en vista a la definición de un proceso para la carga y mantenimiento de data warehouses

Presentación día 13 con fecha 23/07/2001

Artículo: Efficient Resumption of Interrupted Warehouse Loads

Expositor: Pablo Morales

1

Efficient Resumption of Interrupted Warehouse Loads

Wilburt Juan Labio, Janet L. Wiener, Hector Garcia-Molina, Vlad Gorelik

Presentación de una algoritmo (DR) de recuperación ante fallas en el proceso de carga y refresco del data warehouse.

Dos características principales:

1. No impone un overhead en el tiempo de carga normal
2. Utiliza únicamente ciertas propiedades básicas de las transformaciones

2

Idea general y estrategia

Otros Algoritmos:

- Rehacer toda la carga
- Dividir la entrada en lotes y procesarlos en secuencia
- Tomar “snapshots” periódicos del estado del workflow de carga
- Dividir el workflow en estados (identificarlos) y guardar resultados intermedios

3

Idea general y estrategia

Algoritmo DR:

- No hay overhead en el proceso de carga normal
- No es necesario modificar los procesos de transformación
- Quién codifica los elementos de transformación (wrappers, etc) debe declarar si éstos cumplen alguna propiedades simples
- Explota la semántica del workflow de carga para ser selectivo al reasumir luego de una falla

4


Aportes

- Presentación del marco que describe los procesos de carga normales y con fallas identificando ciertas propiedades
- Presentación del algoritmo DR que filtra tuplas de entrada ASAP
- Conclusiones

5

Proceso de carga normal

Ejemplo de carga




Definición:

Secuencia de tuplas: $\tau = [t_p, t_n]$; con atributos $[a_p, a_n]$

6

Proceso de carga normal


Representación del workflow de carga con un Grafo Acíclico Dirigido (DAG):



7

DAG

Notación:



X : Componente

Y : Componente

Y_X : Parámetro de entrada del componente Y producido por X

Y_O : Parámetro de salida del componente Y

Y_X : Secuencia que instancia el parámetro de entrada Y_X

Y_O : Secuencia que instancia el parámetro de salida Y_O

$Y(\dots Y_X \dots) = Y_O$: Y produce Y_O procesando Y_X (y otras secuencias)

W : Secuencia que se carga en el warehouse en ausencia de fallas

8

Proceso de carga con falla

Tipos de fallas:

El algoritmo hace foco en fallas a nivel de sistema y no a nivel lógico

Observación:

Ante cualquier falla de cualquier componente solo un prefijo de la secuencia W es cargado en el warehouse

Datos para re- asumir la carga:

- El prefijo de la secuencia de entrada al warehouse W
- Procedimientos provistos por los *extractors*
GetAllReordered(), GetAll(), GetSubSet(),
GetSuffix()

9

Proceso de carga con falla

Propiedades para re- asumir la carga:

(Same-set(Y)) If Y is an extractor then Same-set(Y) = true if Y uses GetAll or GetAllReordered during resumption. Otherwise, Same-set(Y) = true if Y_X : Same-set(X) and, given the same sets of input tuples, Y produces the same set of output tuples.

En general, se deben contestar estas dos preguntas para evitar el re-proceso de tuplas:


- Para una tupla dada del warehouse, cuales de las tuplas de Y_X contribuyen a ella.
- Cuándo es seguro filtrar esas tuplas de Y_X

10

Proceso de carga con falla

Definición:

(Contributes, Contributors) Given transform Y, let $Y(\dots Y_X \dots) = Y_O$ and $Y(\dots Y'_X \dots) = Y'_O$. Also let $Y_X = [x_1, \dots, x_i, x_{i+1}, \dots, x_n]$ and $Y'_X = [x_1, \dots, x_{i-1}, x_{i+1}, \dots, x_n]$. $\text{Contributes}(x_i, y_j) = \text{true}$, if $y_j \in Y_O$ and $y_j \in Y'_O$. Otherwise, $\text{Contributes}(x_i, y_j) = \text{false}$.
 $\text{Contributors}(Y_X, y_j) = \mathcal{T}$, where $\text{IsSubsequence}(\mathcal{T}, Y_X)$ and $(x_i \in \mathcal{T} : \text{Contributes}(x_i, y_j))$ and $(x_i \in Y_X : \text{Contributes}(x_i, y_j) \rightarrow x_i \in \mathcal{T})$.




11

Proceso de carga con falla – Filtrado Seguro

Propiedad:

map-to-one(Y_X)

Given transform Y with input parameter Y_X , Y_X is map-to-one if $Y_X, Y_O, x_i \in Y_X, (Y(\dots Y_X \dots) = Y_O) \rightarrow (\dots y_j \in Y_O \text{ such that } \text{Contributes}(x_i, y_j) \text{ and } \text{Contributes}(x_i, y_k) \text{ and } j \neq k)$.



12


Proceso de carga con falla – Filtrado Seguro

Definición:

Subset-feasible(Y_X)

Given transform Y with input parameter Y_X , Subset-feasible(Y_X) = true if Y is the warehouse inserter.

Otherwise, Subset-feasible(Y_X) = true if Y_X is map-to-one and, $Z_Y : \text{Subset-feasible}(Z_Y)$. Otherwise, Subset-feasible(Y_X) = false.



13


Proceso de carga con falla – Filtrado Seguro

Propiedad:

suffix-safe(Y_X)

Given $\mathcal{T} = [t1::tn]$, let $\text{First}(\mathcal{T}) = t1$, $\text{Last}(\mathcal{T}) = tn$, and $t_i \prec_{\mathcal{T}} t_j$ if t_i is before t_j in $\mathcal{T}$ or $i = j$. Given transform Y with input parameter Y_X , Y_X is suffix-safe if, $Y_X; \cdot y_j; yj+1 \cdot Y_O : (Y (::: Y_X :::) = Y_O) (\text{Last}(\text{Contributors}(Y_X, yj)) \cdot Y_X \text{First}(\text{Contributors}(Y_X, yj+1)))$.

If $\text{Contributors}(Y_X, yj) = []$ or $\text{Contributors}(Y_X, yj+1) = []$, then Y_X is not suffix-safe.



14

Proceso de carga con falla – Filtrado Seguro


Definición:

Prefix-feasible(Y_X)

Given transform Y with input parameter Y_X ,

Prefix-feasible(Y_X) = true if Y is the warehouse inserter.

Otherwise, Prefix-feasible(Y_X) = true if Y_X is suffix-safe and, $Z_Y : \text{Prefix-feasible}(Z_Y)$. Otherwise, Prefix-feasible(Y_X) = false.




15

Proceso de carga con falla – Filtrado Seguro

Propiedad:

in-det-out(Y)

Transform Y is in-det-out if Y produces the same output sequence whenever it processes the same input sequences.




16

Proceso de carga con falla – Filtrado Seguro

Propiedad:

set-to-seq(Y_X)

Given transform Y with input parameter Y_X , Y_X is set-to-seq if (Y is in-det-out) and ($Y_X; Y'_X : ((Y_X \text{ and } Y'_X \text{ have the same set of tuples) and (all other input parameters of } Y \text{ receive the same sequence))) \cdot Y (::: Y_X :::) = Y (::: Y'_X :::))$.



17

Proceso de carga con falla – Filtrado Seguro

Definición:

Same-seq(Y_X)

If X is an extractor then Same-seq(Y_X) = true if X uses the GetAll re-extraction procedure.

Otherwise, Same-seq(Y_X) = true if X is in-det-out and, $X_V : (\text{Same-seq}(X_V) \text{ or } (X_V \text{ is set-to-seq and Same-set}(V)))$. Otherwise, Same-seq(Y_X) = false.

Observación: Dado un path desde una fuente hasta un componente Y , para que se cumpla Same-seq(Y_X) exijo que todos los componentes del path sean in-det-out, y si uno no lo es, entonces exijo que el siguiente sea set-to-seq (más fuerte)

18

Proceso de carga con falla – Ident. Contribuyentes

Objetivo: Identificar las tuplas de una secuencia Y_X que son contribuyentes a una tupla del warehouse w_k

Idea: Matchear los atributos que Y_X y w_k tienen en común

19


Proceso de carga con falla – Ident. Contribuyentes

Propiedades a satisfacer para poder identificar los contribuyentes:

no-hidden-contributor(Y_X)

Given transform Y with input parameter Y_X , no-hidden-contributors(Y_X) if, Y_X, Y_O, y_j, x_i . Contributors(Y_X, y_j), $a \in (\text{Attrs}(Y_X) \cup \text{Attrs}(Y_O))$: ($Y :: Y_X :: a = Y_O$) $\wedge$ ($x_i.a = y_j.a$).

No-hidden-contributor(Y_X)



20

Proceso de carga con falla – Ident. Contribuyentes

Propiedades a satisfacer para poder identificar los contribuyentes:

Definición:

$\text{CandAttrs}(Y_X, P)$

Let P be a path from input parameter Y_X to the warehouse.

There are three possibilities for $\text{CandAttrs}(Y_X, P)$:

1. If Y is the warehouse inserter, then $\text{CandAttrs}(Y_X, P) = \text{Attrs}(Y_X)$.
2. If $\neg \text{no-hidden-contributors}(Y_X)$, then $\text{CandAttrs}(Y_X, P) = []$.
3. Else $\text{CandAttrs}(Y_X, P) = \text{CandAttrs}(Z_Y, P') \cup \text{Attrs}(Y_X)$, where $P = [Y_X Z_Y :: W]$, and P' is P excluding Y_X .

21

Proceso de carga con falla – Ident. Contribuyentes

Propiedades a satisfacer para poder identificar los contribuyentes:

Propiedad:

no-spurious-output(Y)

A transform Y produces *no spurious output* if, input parameters Y_X, Y_X, Y_O, y_j, Y_O : ($Y :: Y_X :: a = Y_O$) $\wedge$ ($\text{Contributors}(Y_X, y_j) \cup []$).

22

Proceso de carga con falla – Ident. Contribuyentes

Observaciones:

no-hidden-contributor(Y_X) = Se cumple si todas las tuplas de entrada Y_X que contribuyen a una tupla de salida y_j matchean con y_j en $\text{Attrs}(Y_X) \cup \text{Attrs}(Y_O)$

$\text{CandAttrs}(Y_X, P)$ = Todos los atributos presentes en el path P desde Y_X al warehouse. Estos atributos identifican a los potenciales contribuyentes de una tupla final w_k

$\text{idAttrs}(Y_X)$ = Conjunto de atributos utilizados para identificar los contribuyentes de Y_X a la tupla del warehouse w_k . Los contribuyentes serán los que matcheen con w_k en $\text{idAttrs}(Y_X)$

23

Proceso de carga con falla – Ident. Contribuyentes

Por lo tanto:

Dados w_k y $\text{CandAttrs}(Y_X, P)$ puedo identificar a los potenciales contribuyentes de w_k en Y_X .

Dados w_k y $\text{idAttrsPath}(Y_X, P)$ puedo identificar a los contribuyentes de w_k en Y_X .

24

Proceso de carga con falla – Ident. Contribuyentes




Figure 7: Example Component DAG




Figure 8: Component DAG with Replicated Outputs

1. $\text{IdAttrs}(Y_X) = \text{KeyAttrs}(Y_X)$ if $\text{KeyAttrs}(Y_X) \subseteq \text{CandAttrs}(Y_X, P)$ and both Y and Z satisfy the no-spurious-output property.
2. $\text{IdAttrs}(Y_X) = \text{KeyAttrs}(W_Z)$ if $\text{KeyAttrs}(W_Z) \subseteq \text{CandAttrs}(Y_X, P)$.
3. $\text{IdAttrs}(Y_X) = \text{IdAttrs}(Z_Y)$ if $\text{IdAttrs}(Z_Y) \subseteq \text{CandAttrs}(Y_X, P)$.

25

Proceso de carga con falla – Ident. Contribuyentes

Definición:

$\text{IdAttrsPath}(Y_X, P), \text{IdAttrs}(Y_X)$

Let P be the only path from Y_X to the warehouse.

There are three possibilities for $\text{IdAttrsPath}(Y_X, P)$ (i.e., $\text{IdAttrs}(Y_X)$).

1. If $(\text{KeyAttrs}(Y_X) \subseteq \text{CandAttrs}(Y_X, P))$ and $Z_Y \subseteq P : Z_Y$ has no spurious output tuples), then $(\text{IdAttrsPath}(Y_X, P) = \text{KeyAttrs}(Y_X))$.
2. Otherwise, let $Z_Y \subseteq P$ but $Z_Y \not\subseteq Y_X$. Let P' be the path from Z_Y to the warehouse. If $(\text{IdAttrsPath}(Z_Y, P') \subseteq [])$ and $\text{IdAttrsPath}(Z_Y, P') \subseteq \text{CandAttrs}(Y_X, P)$, then $(\text{IdAttrsPath}(Y_X, P) = \text{IdAttrsPath}(Z_Y, P'))$.
3. Otherwise $\text{IdAttrsPath}(Y_X, P) = []$.

26