

Primitivas de Transformacion

Propuesta de procesamiento de instancias utilizando SQL.

Introduccion

- Es una modificacion a la propuesta de Adriana de forma de exponer que las primitivas son expresables con SQL.
- Se redujo el planteo inicial:
 - No considerando las expresiones en Algebra Relacional correspondientes.
 - No se ataca el tema de la definicion de los esquemas (DDL).

P1 - Identity

- Entrada:
 - *Esquema origen:* R . Rel
- Procesamiento:
 - $P1 = \text{select } * \text{ from } R$

Es necesario tener una sentencia SQL para esto ?

P2 - Data Filter

- Entrada:
 - *Esquema origen:* $R(A_1, \dots, A_n)$. Rel
 - *Conjunto de atributos a filtrar:* X . $\{A_1, \dots, A_n\}$
- Pre-procesamiento:
 - $A' = \{A'_1, \dots, A'_m\} = \{A_1, \dots, A_n\} - X$
- Procesamiento:
 - $P2 = \text{select } A'_1, \dots, A'_m \text{ from } R$

P3 - Temporalization

- Entrada:
 - *Esquema origen:* R . Rel
 - *Valor de tiempo:* t . Time
- Procesamiento:
 - $P2 = \text{select } *, t \text{ from } R$

P4.1 - Version Digits

- Entrada:
 - *Esquema origen:* $R(A_1, \dots, A_n)$. Rel / A_1 . X . $\text{Att}_k(R)$
 - *Numero de versión:* n . String.
- Procesamiento⁽¹⁾:
 - $P4.1 = \text{select } n \parallel A_1, \dots, A_n \text{ from } R$

P4.2 - Key Extension

■ Entrada:

- *Esquema origen:* $R(A_1, \dots, A_n) \text{ . Rel}$

■ Procesamiento:

- $P1 = \text{select } * \text{ from } R$

P5 - Foreign Key Update

■ Entrada:

- *Esquema origen:* $R(A_1, \dots, A_n) \text{ . Rel}$
- *Esquema de la clave foránea:* $T(B_1, \dots, B_m) \text{ . Rel}$
- *Antigua clave foránea:* $X \text{ . } \{A_1, \dots, A_n\}$
- *Nueva clave foránea:* $Y \text{ . } \{B_1, \dots, B_m\}$
- *Esquema de correspondencias:* $S(C_1, \dots, C_j) \text{ . Rel, } \{C_1, \dots, C_j\} = (X \cup Y)$

■ Pre-procesamiento:

- $V = \{V_1, \dots, V_j\} / V = Y \cup (\{A_1, \dots, A_n\} - X)$

■ Procesamiento:

- $P5 = \text{select } V_1, \dots, V_j \text{ from } R, S \text{ where } R.X = S.X$

P6.1 - DD-Ading 1-1

■ Entrada:

- *Esquema origen:* $R(A_1, \dots, A_n) \text{ . Rel}$
- *Función de calculo:* $f(X) / X \text{ . } \{A_1, \dots, A_n\}$

■ Procesamiento:

- $P6.1 = \text{select } *, f(X) \text{ from } R$

P6.2 - DD-Ading N-1

■ Entrada:

- *Esquemas origen:* $R(A_1, \dots, A_n), R_1(A'_1, \dots, A'_n), \dots, R_n(A^n_1, \dots, A^n_n) \text{ . Rel}$
- *Función de calculo:* $f(X) / X \text{ . } (\{A_1, \dots, A_n\} \cup \{A'_1, \dots, A'_n\} \cup \dots \cup \{A^n_1, \dots, A^n_n\})$
- *Atributos de Join:* $Y \text{ . } \{A_1, \dots, A_n\} \text{ . } Y' \text{ . } \{A'_1, \dots, A'_n\} \text{ . } \dots \text{ . } Y^n \text{ . } \{A^n_1, \dots, A^n_n\}$

■ Procesamiento:

- $P6.2 = \text{select } A_1, \dots, A_n, f(X) \text{ from } R, R_1, R_2, \dots, R_n$
where $R.Y = R_1.Y'$ and $R_1.Y' = R_2.Y''$ and ... and $R_{(n-1)}.Y^{(n-1)} = R_n.Y^n$

P6.3 - DD-Ading N-N

■ Entrada:

- *Esquemas origen:* $R(A_1, \dots, A_n), R_1(A'_1, \dots, A'_n), \dots, R_n(A^n_1, \dots, A^n_n) \text{ . Rel}$
- *Expresión de agregación:* $e(X) / X \text{ . } (\{A'_1, \dots, A'_n\} \cup \dots \cup \{A^n_1, \dots, A^n_n\})$
- *Atributos de Join:* $Y \text{ . } \{A_1, \dots, A_n\} \text{ . } Y' \text{ . } \{A'_1, \dots, A'_n\} \text{ . } \dots \text{ . } Y^n \text{ . } \{A^n_1, \dots, A^n_n\}$
- *Atributos de agregación:* $Z \text{ . } (\{A'_1, \dots, A'_n\} \cup \dots \cup \{A^n_1, \dots, A^n_n\})$

■ Procesamiento:

- $P6.3 = \text{select } A_1, \dots, A_n, e(X) \text{ from } R, R_1, R_2, \dots, R_n$
where $R.Y = R_1.Y'$ and $R_1.Y' = R_2.Y''$ and ... and $R_{(n-1)}.Y^{(n-1)} = R_n.Y^n$ group by $A_1, \dots, A_n, Z$

P7 - Attribute Adding

■ Entrada:

- *Esquema origen:* $R \text{ . Rel}$
- *Valores de los atributos a agregar:* $\{b_1, \dots, b_n\}$

■ Procesamiento:

- $P7 = \text{select } *, b_1, \dots, b_n \text{ from } R$

P8 - Hierarchy Roll Up

■ Entrada:

■ Esquemas origen:

- $R_1(A_1, \dots, A_n) \text{ .Rel}_M / A \text{ . } \{A_1, \dots, A_n\} \text{ . } A \text{ . Att}_{FK}(R_1, R_2)$
- $R_2(B_1, \dots, B_n) \text{ .Rel}_J / A \text{ . } \{B_1, \dots, B_n\} \text{ . } A \text{ . Att}_{FK}(R_2)$

■ Atributos de medida: $Z = \{Z_1, \dots, Z_k\} = \text{Att}_M(R_1), Z \text{ . } \{A_1, \dots, A_n\}$

■ Agregaciones de los atributos: $\{e_1(Z_1), \dots, e_k(Z_k)\}$

■ Nivel de la jerarquía: $B / B \text{ . } \{B_1, \dots, B_n\} \text{ . } B \text{ . Att}_D(R_2)$

■ Atributos que por su granularidad salen de R_1 : $X / X \text{ . } \{A_1, \dots, A_n\} \text{ . } X \text{ . } (\text{Att}_D(R_1) \cup \text{Att}_M(R_1))$

P8 - Hierarchy Roll Up (II)

■ Atributos que por su granularidad salen de R_2 : $Y / Y \text{ . } \{B_1, \dots, B_n\} \text{ . } Y \text{ . Att}_D(R_2)$

■ Indica si genera nueva jerarquía: $\text{agg_h} \text{ . Boolean}$

■ Pre-procesamiento:

■ $V = \{V_1, \dots, V_m\} / V = (((\{A_1, \dots, A_n\} - A) \cup B) - X) - Z$

■ $V' = \{V'_1, \dots, V'_m\} / V' = \{B_1, \dots, B_n\} - Y$

■ Procesamiento:

■ $P8 = \text{select } V_1, \dots, V_m, e_1(Z_1), \dots, e_k(Z_k) \text{ from } R_1, R_2 \text{ where } R_1.A = R_2.A \text{ group by } V_1, \dots, V_m$

■ Si se indica agg_h :

- $P8b = \text{select distinct } V'_1, \dots, V'_m \text{ from } R_2$

P9 - Aggregate Generation

■ Entrada:

■ Esquemas origen: $R(A_1, \dots, A_n) \text{ .Rel}_M$

■ Atributos de medida: $Z = \{Z_1, \dots, Z_k\} = \text{Att}_M(R), Z \text{ . } \{A_1, \dots, A_n\}$

■ Agregaciones de los atributos: $\{e_1(Z_1), \dots, e_k(Z_k)\}$

■ Atributos que salen de R : $X / X \text{ . } \{A_1, \dots, A_n\} \text{ . } X \text{ . } (\text{Att}_D(R) \cup \text{Att}_M(R))$

■ Pre-procesamiento:

■ $V = \{V_1, \dots, V_m\} / V = (\{A_1, \dots, A_n\} - X) - Z$

■ Procesamiento:

■ $P9 = \text{select } V_1, \dots, V_m, e_1(Z_1), \dots, e_k(Z_k) \text{ from } R \text{ group by } V_1, \dots, V_m$

P10 - Data Array Creation

■ Entrada:

■ Esquema origen: $R(A_1, \dots, A_n)$

■ Atributo de valores predefinidos: $A \text{ . } \{A_1, \dots, A_n\}$

■ Expresión agregación: $e(A)$

■ Pre-procesamiento:

■ $V = \{V_1, \dots, V_m\} / V = \text{select distinct } A \text{ from } R$

■ $B = \{B_1, \dots, B_p\} = \text{Att}_M(R)$

■ $N = \{N_{ij} / N_{ij} = "V_i" \parallel " " \parallel "B_j", i=1..m, j=1..p\}$

■ $K = \{K_1, \dots, K_{n-1}\} = \{A_1, \dots, A_n\} - B - \{A\}$

P10 - Data Array Creation (II)

■ Procesamiento:

■ $T_1 = \text{select } K_1, \dots, K_{n-1}, e(B_1) \text{ as } N_{11}, \dots, e(B_p) \text{ as } N_{p1} \text{ from } R \text{ where } A = V_1 \text{ group by } K_1, \dots, K_{n-1}$

...

■ $T_m = \text{select } K_1, \dots, K_{n-1}, e(B_1) \text{ as } N_{1m}, \dots, e(B_p) \text{ as } N_{pm} \text{ from } R \text{ where } A = V_m \text{ group by } K_1, \dots, K_{n-1}$

■ $P10 = \text{select } K_1, \dots, K_{n-1}, N_{11}, \dots, N_{pm} \text{ from } T_1, \dots, T_m \text{ where } T_1.K = T_2.K \text{ and } \dots \text{ and } T_{m-1}.K = T_m.K$

P11.1 - Vertical Partition

■ Entrada:

■ Esquema origen: $R \text{ . Rel}$

■ Atributos que nunca cambian: $Y \text{ . Att}(R)$

■ Atributos que algunas veces cambian: $Z \text{ . Att}(R), Z \text{ . } Y = \dots$

■ Atributos que cambian muchas veces: $W \text{ . Att}(R), W \text{ . } Y = \dots, W \text{ . } Z = \dots$

■ Pre-procesamiento:

■ $Y' = \{Y'_1, \dots, Y'_n\} / Y' = \text{Att}_Y(R) \text{ . } Y$

■ $Z' = \{Z'_1, \dots, Z'_n\} / Z' = \text{Att}_Z(R) \text{ . } Z$

■ $W' = \{W'_1, \dots, W'_n\} / W' = \text{Att}_W(R) \text{ . } W$

P11.1 - Vertical Partition (II)

■ Procesamiento:

- P11.1.1 = select $Y'_1, \dots, Y'_n$ from R
- P11.1.2 = select $Z'_1, \dots, Z'_n$ from R
- P11.1.3 = select $W'_1, \dots, W'_n$ from R

P11.2 - Horizontal Partition

■ Entrada:

- *Esquema origen:* R . Rel
- *Condición de Historización:* $c(X) \wedge X \in \text{Att}(R)$

■ Procesamiento:

- P11.2.1 = select * from R where $c(X)$
- P11.2.2 = select * from R where $\text{not}(c(X))$

P12.1 - De-Normalized Hierarchy Generation

■ Entrada:

- *Esquemas origen:* $R_1, \dots, R_n$. Rel
- *Atributos de la Jerarquía:* $J = \{J_1, \dots, J_m\}$
- *Clave de la Jerarquía:* $k \in \{J_1, \dots, J_m\}$

■ Pre-procesamiento:

- $S' = \{S'_1, \dots, S'_n\} = (\text{Att}(R_1) - J) \cup k$
- ...
- $S^n = \{S'_1, \dots, S'_n\} = (\text{Att}(R_n) - J) \cup k$
- $s_{(i+1)} = \text{Att}(R_i) \cap J \cap \text{Att}(R_{i+1}), i=1..(n-1)$

P12.1 - De-Normalized Hierarchy Generation (II)

■ Procesamiento:

- P13.0 = select distinct $J_1, \dots, J_m$ from $R_1, \dots, R_n$ where $R_1.s_{12} = R_2.s_{12}$ and ... and $R_{(n-1)}.s_{(n-1)n} = R_n.s_{(n-1)n}$
- P13.1 = select $S'_1, \dots, S'_n$ from R_1 , P13.0 where $R_1.k = \text{P13.0.k}$
- ...
- P13.n = select $S'_1, \dots, S'_n$ from R_n , P13.0 where $R_1.k = \text{P13.0.k}$

P12.2 - Snowflake Hierarchy Generation

■ Entrada:

- *Esquemas origen:* $R_1, \dots, R_n$. Rel
- *Conjunto ordenado de atributos de la Jerarquía:* $J = \{J_1, \dots, J_m\}$
- *Clave de la Jerarquía:* $k \in \{J_1, \dots, J_m\}$

■ Pre-procesamiento:

- $S' = \{S'_1, \dots, S'_n\} = (\text{Att}(R_1) - J) \cup k$
- ...
- $S^n = \{S'_1, \dots, S'_n\} = (\text{Att}(R_n) - J) \cup k$
- $s_{(i+1)} = \text{Att}(R_i) \cap J \cap \text{Att}(R_{i+1}), i=1..(n-1)$

P12.2 - Snowflake Hierarchy Generation (II)

■ Procesamiento:

- T1 = select distinct $J_1, \dots, J_m$ from $R_1, \dots, R_n$ where $R_1.s_{12} = R_2.s_{12}$ and ... and $R_{(n-1)}.s_{(n-1)n} = R_n.s_{(n-1)n}$
- P13.J1 = select distinct J_1, J_2 from $R_1, \dots, R_n$ where $R_1.s_{12} = R_2.s_{12}$ and ... and $R_{(n-1)}.s_{(n-1)n} = R_n.s_{(n-1)n}$
- ...
- P13.J(m-1) = select distinct $J_{(m-1)}, J_m$ from $R_1, \dots, R_n$ where $R_1.s_{12} = R_2.s_{12}$ and ... and $R_{(n-1)}.s_{(n-1)n} = R_n.s_{(n-1)n}$
- P13.1 = select $S'_1, \dots, S'_n$ from R_1 , T1 where $R_1.k = \text{T1.k}$
- ...
- P13.n = select $S'_1, \dots, S'_n$ from R_n , T1 where $R_1.k = \text{T1.k}$

P12.3 - Free Decomposition – Hierarchy Generation

- Entrada:
 - *Esquemas origen:* $R_1, \dots, R_n$. Rel
 - *Conjunto ordenado de atributos de la Jerarquía:* $J = \{J_1, \dots, J_m\}$
 - *Descomposición de la Jerarquía:* $D = \{D_i / D_i = \{J_1^i, \dots, J_p^i\} \text{ , } J, i=1..p\}$
 - *Clave de la Jerarquía:* $k \text{ , } \{J_1, \dots, J_m\}$
- Pre-procesamiento:
 - $S^1 = \{S_1^1, \dots, S_n^1\} = (Att(R_1) - J) \text{ , } k$
 - ...
 - $S^n = \{S_1^n, \dots, S_n^n\} = (Att(R_n) - J) \text{ , } k$
 - $s_{(i+1)}^j = Att(R_i) \text{ , } J \text{ , } Att(R_{i+1}), i=1..(n-1)$

P12.3 - Free Decomposition – Hierarchy Generation (II)

- Procesamiento:
 - $T1 = \text{select distinct } J_1, \dots, J_m \text{ from } R_1, \dots, R_n \text{ where } R_1.s_{12} = R_2.s_{12} \text{ and } \dots \text{ and } R_{(n-1)}.s_{(n-1)n} = R_n.s_{(n-1)n}$
 - $P13.J1 = \text{select distinct } J_1^1, \dots, J_p^1 \text{ from } R_1, \dots, R_n \text{ where } R_1.s_{12} = R_2.s_{12} \text{ and } \dots \text{ and } R_{(n-1)}.s_{(n-1)n} = R_n.s_{(n-1)n}$
 - ...
 - $P13.Jp = \text{select distinct } J_1^p, \dots, J_p^p \text{ from } R_1, \dots, R_n \text{ where } R_1.s_{12} = R_2.s_{12} \text{ and } \dots \text{ and } R_{(n-1)}.s_{(n-1)n} = R_n.s_{(n-1)n}$
 - $P13.1 = \text{select } S_1^1, \dots, S_n^1 \text{ from } R_1, T1 \text{ where } R_1.k = T1.k$
 - ...
 - $P13.n = \text{select } S_1^n, \dots, S_n^n \text{ from } R_n, T1 \text{ where } R_n.k = T1.k$

P13 - Minidimension Break Off

- Entrada:
 - *Esquema origen:* R . Rel
 - *Función de clave:* f
 - *Atributos de la mini dimensión:* $X = \{X_1, \dots, X_n\} \text{ , } Att(R)$
- Pre-procesamiento:
 - $\{R_1, \dots, R_m\} = Att(R) - X$
- Procesamiento:
 - $T1 = \text{select } f \text{ as } F, * \text{ from } R$
 - $P13.1 = \text{select } F, X_1, \dots, X_n \text{ from } T1$
 - $P13.2 = \text{select } F, R_1^1, \dots, R_m^1 \text{ from } T1$

P14 - New Dimension Crossing

- Entrada:
 - *Esquema origen:* R_1, R_2 . Rel
 - *Atributos de Join:* $A, A \text{ , } Att(R_1), A \text{ , } Att(R_2)$
 - *Atributos que se excluyen de R_1 :* $Y_1 \text{ , } Att(R_1)$
 - *Atributos que se excluyen de R_2 :* $Y_2 \text{ , } Att(R_2)$
- Pre-procesamiento:
 - $Y_1' = \{y_1', \dots, y_n'\} = Att(R_1) - Y_1$
 - $Y_2' = \{y_1'', \dots, y_m''\} = Att(R_2) - Y_2$
- Procesamiento:
 - $P14 = \text{select distinct } y_1', \dots, y_n', y_1'', \dots, y_m'' \text{ from } R_1, R_2 \text{ where } R_1.A = R_2.A$

Posibles líneas de trabajo

- Definición mas formal de la semántica de las primitivas.
- Tentativa de implementación de carga por cada primitiva.
- Completar el trabajo sobre Algebra Relacional.
- Encarar el tema de propiedades de las primitivas.
- Encarar el tema sobre DDL
 - Lenguaje para expresar esto ?

Dudas que surgieron

- Cuando se define mal la aplicación de una primitiva y por ejemplo se pierde la clave primaria que pasa ?
 - Esto se asume como un error del diseñador y no se verifica el error ?
 - O se imponen restricciones que se verifican al definir la primitiva que llevan a que estos errores no se cometan ?. Esta alternativa tiene el aspecto importante de que impacta el diseño.
- Existe la sospecha de que unas primitivas se pueden definir en función de las otras



Conclusiones

- Todas las primitivas expuestas son expresables utilizando unicamente SQL, si bien es necesario cierto pre-procesamiento y los datos son parametricos en los esquemas de entrada.
- Hay algunas lineas de trabajo posible, habria que estudiar como atacarlas.