

Expresiones regulares y MSO

Teorema (Büchi): Un lenguaje de palabras L es regular si y sólo si L es definible por una fórmula en MSO.

MSO es una buena alternativa para el caso de lenguajes regulares sobre palabras.

- ¿Qué pasa en el caso de documentos XML?

Teorema (Thatcher & Wright): Un lenguaje de árboles L es regular si y sólo si L es definible por una fórmula en MSO.

¡MSO es el nuevo objetivo!

- Nótese que es costoso evaluar una consulta en MSO.

¿Es suficiente con Regular XPath?

Nótese que Regular XPath $\not\subseteq$ Conditional XPath.

- $(\text{child}/?section/\text{child}/?section)^*$ es una consulta en Regular XPath que no puede ser expresada en Conditional XPath.

¿Basta con Regular XPath para capturar MSO?

Teorema [GM05, BSSS06]: Hay una consulta en MSO que **no** es expresable en Regular XPath.


¿Existe un lenguaje eficiente que capture MSO?

Monadic Datalog

Este lenguaje utiliza **reglas datalog** para definir un conjunto de nodos.

- A diferencia de XPath, este lenguaje no construye caminos, sino que extrae nodos que satisfacen alguna propiedad.

Dado árbol T :



Representamos T usando los predicados **extensionales**: **root**, **leaf**, **label_{db}**, **label_{book}**, **label_{author}**, **firstchild**, **nextsibling**, **lastsibling**.

Monadic Datalog

Donde:

$$\begin{aligned}\text{root} &= \{\varepsilon\} \\ \text{leaf} &= \{2, 0 \cdot 0, 1 \cdot 0\} \\ \text{label}_{db} &= \{\varepsilon\} \\ \text{label}_{book} &= \{0, 1, 2\} \\ \text{label}_{author} &= \{0 \cdot 0, 1 \cdot 0\} \\ \text{firstchild} &= \{(\varepsilon, 0), (0, 0 \cdot 0), (1, 1 \cdot 0)\} \\ \text{nextsibling} &= \{(0, 1), (1, 2)\} \\ \text{lastsibling} &= \{2, 0 \cdot 0, 1 \cdot 0\}\end{aligned}$$

Monadic Datalog

Para definir una consulta usamos predicados **intensionales**.

- Estos predicados son **unarios**.

Ejemplo: La siguiente consulta extrae el conjunto de hijos de la raíz

$$Q(x) \leftarrow \text{root}(y), \text{firstchild}(y, x).$$
$$Q(x) \leftarrow Q(y), \text{nextsibling}(y, x).$$

Monadic Datalog: Semántica

Semántica de Monadic Datalog: Menor punto fijo.

Para todo i :

$$Q_{i+1}(x) \leftarrow \text{root}(y), \text{firstchild}(y, x).$$

$$Q_{i+1}(x) \leftarrow Q_i(y), \text{nextsibling}(y, x).$$

Entonces:

Monadic Datalog: Semántica

Semántica de Monadic Datalog: Menor punto fijo.

Para todo i :

$$Q_{i+1}(x) \leftarrow \text{root}(y), \text{firstchild}(y, x).$$

$$Q_{i+1}(x) \leftarrow Q_i(y), \text{nextsibling}(y, x).$$

Entonces:

$$Q_0 = \emptyset$$

Monadic Datalog: Semántica

Semántica de Monadic Datalog: Menor punto fijo.

Para todo i :

$$Q_{i+1}(x) \leftarrow \text{root}(y), \text{firstchild}(y, x).$$

$$Q_{i+1}(x) \leftarrow Q_i(y), \text{nextsibling}(y, x).$$

Entonces:

$$Q_0 = \emptyset$$

$$Q_1 = \{0\}$$

Monadic Datalog: Semántica

Semántica de Monadic Datalog: Menor punto fijo.

Para todo i :

$$Q_{i+1}(x) \leftarrow \text{root}(y), \text{firstchild}(y, x).$$

$$Q_{i+1}(x) \leftarrow Q_i(y), \text{nextsibling}(y, x).$$

Entonces:

$$Q_0 = \emptyset$$

$$Q_1 = \{0\}$$

$$Q_2 = \{0, 1\}$$

Monadic Datalog: Semántica

Semántica de Monadic Datalog: Menor punto fijo.

Para todo i :

$$Q_{i+1}(x) \leftarrow \text{root}(y), \text{firstchild}(y, x).$$

$$Q_{i+1}(x) \leftarrow Q_i(y), \text{nextsibling}(y, x).$$

Entonces:

$$Q_0 = \emptyset$$

$$Q_1 = \{0\}$$

$$Q_2 = \{0, 1\}$$

$$Q_3 = \{0, 1, 2\}$$

Monadic Datalog: Semántica

Semántica de Monadic Datalog: Menor punto fijo.

Para todo i :

$$Q_{i+1}(x) \leftarrow \text{root}(y), \text{firstchild}(y, x).$$

$$Q_{i+1}(x) \leftarrow Q_i(y), \text{nextsibling}(y, x).$$

Entonces:

$$Q_0 = \emptyset$$

$$Q_1 = \{0\}$$

$$Q_2 = \{0, 1\}$$

$$Q_3 = \{0, 1, 2\}$$

$$Q_4 = \{0, 1, 2\}$$

Monadic Datalog: Algunos ejemplo

Conjunto de libros que aparecen como hijos de la raíz:

$$Q(x) \leftarrow P(x), \text{label}_{book}(x).$$

$$P(x) \leftarrow \text{root}(y), \text{firstchild}(y, x).$$

$$P(x) \leftarrow P(y), \text{nextsibling}(y, x).$$

Conjunto de libros que tienen al menos un autor:

$$Q(x) \leftarrow P_1(x), \text{label}_{book}(x).$$

$$P_1(x) \leftarrow \text{firstchild}(x, y), P_2(y).$$

$$P_2(x) \leftarrow \text{label}_{author}(x).$$

$$P_2(x) \leftarrow P_2(y), \text{nextsibling}(x, y).$$

Monadic Datalog: Complejidad

En general es costoso evaluar una consulta en Datalog .

- ¿Por qué queremos usar Monadic Datalog?

Teorema [GK04]: Es posible evaluar una consulta Q en Monadic Datalog sobre un árbol T en tiempo $O(|T| \cdot |Q|)$.

Veamos el algoritmo ...

Primer paso: Crear instancia ground

$$Q(x) \leftarrow P(x), \text{label}_{book}(x).$$

$$P(x) \leftarrow \text{root}(y), \text{firstchild}(y, x).$$

$$P(x) \leftarrow P(y), \text{nextsibling}(y, x).$$

Primer paso: Crear instancia ground

$$Q(x) \leftarrow P(x), \text{label}_{book}(x).$$

$$P(x) \leftarrow \text{root}(y), \text{firstchild}(y, x).$$

$$P(x) \leftarrow P(y), \text{nextsibling}(y, x).$$

Primer paso: Crear instancia ground

$$Q(\varepsilon) \leftarrow P(\varepsilon), \text{label}_{book}(\varepsilon).$$

$$Q(0) \leftarrow P(0), \text{label}_{book}(0).$$

$$Q(1) \leftarrow P(1), \text{label}_{book}(1).$$

$$Q(2) \leftarrow P(2), \text{label}_{book}(2).$$

$$Q(0.0) \leftarrow P(0.0), \text{label}_{book}(0.0).$$

$$Q(1.0) \leftarrow P(1.0), \text{label}_{book}(1.0).$$

$$P(x) \leftarrow \text{root}(y), \text{firstchild}(y, x).$$

$$P(x) \leftarrow P(y), \text{nextsibling}(y, x).$$

Primer paso: Crear instancia ground

$Q(0) \leftarrow P(0), \text{label}_{book}(0).$

$Q(1) \leftarrow P(1), \text{label}_{book}(1).$

$Q(2) \leftarrow P(2), \text{label}_{book}(2).$

$P(x) \leftarrow \text{root}(y), \text{firstchild}(y, x).$

$P(x) \leftarrow P(y), \text{nextsibling}(y, x).$

Primer paso: Crear instancia ground

$$Q(0) \leftarrow P(0).$$

$$Q(1) \leftarrow P(1).$$

$$Q(2) \leftarrow P(2).$$

$$P(x) \leftarrow \text{root}(y), \text{firstchild}(y, x).$$

$$P(x) \leftarrow P(y), \text{nextsibling}(y, x).$$

Primer paso: Crear instancia ground

$$Q(0) \leftarrow P(0).$$

$$Q(1) \leftarrow P(1).$$

$$Q(2) \leftarrow P(2).$$

$$P(x) \leftarrow \text{root}(y), \text{firstchild}(y, x).$$

$$P(x) \leftarrow P(y), \text{nextsibling}(y, x).$$

Primer paso: Crear instancia ground

$$Q(0) \leftarrow P(0).$$

$$Q(1) \leftarrow P(1).$$

$$Q(2) \leftarrow P(2).$$

$$P(\varepsilon) \leftarrow \text{root}(y), \text{firstchild}(y, \varepsilon).$$

$$P(0) \leftarrow \text{root}(y), \text{firstchild}(y, 0).$$

$$P(1) \leftarrow \text{root}(y), \text{firstchild}(y, 1).$$

$$P(2) \leftarrow \text{root}(y), \text{firstchild}(y, 2).$$

$$P(0.0) \leftarrow \text{root}(y), \text{firstchild}(y, 0.0).$$

$$P(1.0) \leftarrow \text{root}(y), \text{firstchild}(y, 1.0).$$

$$P(x) \leftarrow P(y), \text{nextsibling}(y, x).$$

Primer paso: Crear instancia ground

$$Q(0) \leftarrow P(0).$$

$$Q(1) \leftarrow P(1).$$

$$Q(2) \leftarrow P(2).$$

$$P(0) \leftarrow \text{root}(\varepsilon), \text{firstchild}(\varepsilon, 0).$$

$$P(0.0) \leftarrow \text{root}(0), \text{firstchild}(0, 0.0).$$

$$P(1.0) \leftarrow \text{root}(1), \text{firstchild}(1, 1.0).$$

$$P(x) \leftarrow P(y), \text{nextsibling}(y, x).$$

Primer paso: Crear instancia ground

$$Q(0) \leftarrow P(0).$$

$$Q(1) \leftarrow P(1).$$

$$Q(2) \leftarrow P(2).$$

$$P(0) \leftarrow \text{root}(\varepsilon), \text{firstchild}(\varepsilon, 0).$$

$$P(x) \leftarrow P(y), \text{nextsibling}(y, x).$$

Primer paso: Crear instancia ground

$$Q(0) \leftarrow P(0).$$

$$Q(1) \leftarrow P(1).$$

$$Q(2) \leftarrow P(2).$$

$$\textcolor{red}{P(0)} \leftarrow$$

$$P(x) \leftarrow P(y), \texttt{nextsibling}(y, x).$$

Primer paso: Crear instancia ground

$$Q(0) \leftarrow P(0).$$

$$Q(1) \leftarrow P(1).$$

$$Q(2) \leftarrow P(2).$$

$$P(0) \leftarrow$$

$$P(x) \leftarrow P(y), \text{nextsibling}(y, x).$$

Primer paso: Crear instancia ground

$$Q(0) \leftarrow P(0).$$

$$Q(1) \leftarrow P(1).$$

$$Q(2) \leftarrow P(2).$$

$$P(0) \leftarrow$$

$$P(\varepsilon) \leftarrow P(y), \text{nextsibling}(y, \varepsilon).$$

$$P(0) \leftarrow P(y), \text{nextsibling}(y, 0).$$

$$P(1) \leftarrow P(y), \text{nextsibling}(y, 1).$$

$$P(2) \leftarrow P(y), \text{nextsibling}(y, 2).$$

$$P(0.0) \leftarrow P(y), \text{nextsibling}(y, 0.0).$$

$$P(1.0) \leftarrow P(y), \text{nextsibling}(y, 1.0).$$

Primer paso: Crear instancia ground

$Q(0) \leftarrow P(0).$

$Q(1) \leftarrow P(1).$

$Q(2) \leftarrow P(2).$

$P(0) \leftarrow$

$P(1) \leftarrow P(0), \text{nextsibling}(0, 1).$

$P(2) \leftarrow P(1), \text{nextsibling}(1, 2).$

Primer paso: Crear instancia ground

$$Q(0) \leftarrow P(0).$$

$$Q(1) \leftarrow P(1).$$

$$Q(2) \leftarrow P(2).$$

$$P(0) \leftarrow$$

$$P(1) \leftarrow P(0).$$

$$P(2) \leftarrow P(1).$$

Primer paso: Crear instancia ground

$$Q(0) \leftarrow P(0).$$

$$Q(1) \leftarrow P(1).$$

$$Q(2) \leftarrow P(2).$$

$$P(0) \leftarrow$$

$$P(1) \leftarrow P(0).$$

$$P(2) \leftarrow P(1).$$

Segundo Paso: Calcular menor punto fijo

Ahora calculamos el menor punto fijo de la instancia ground.

Instancia ground:

- Tamaño: $O(|T| \cdot |D|)$.
- Tiempo para calcular menor punto fijo: $O(|T| \cdot |D|)$.

Monadic Datalog: Expresividad

Teorema [GK04]: Sobre árboles se tiene que $\text{MSO} = \text{Monadic Datalog}$.

¡Monadic Datalog es un buen lenguaje!

- Ha sido usado exitosamente en la practica [GKB⁺04].

Monadic Datalog: Expresividad

Ejercicio: Demuestre que toda consulta en Monadic Datalog puede ser expresada en MSO.

Ejercicio: Sea $\Sigma = \{a, b\}$. Construya una consulta $Q(x)$ en Monadic Datalog tal que para todo Σ -árbol T se tiene que ε está en la respuesta a Q sobre T si y sólo si T contiene un número par de nodos con etiqueta a .

Referencias

- [BSSS06] Mikolaj Bojanczyk, Mathias Samuelides, Thomas Schwentick, and Luc Segoufin. On the expressive power of pebble automata. In *ICALP*, 2006.
- [Cod72] E. F. Codd. Relational completeness of data base sublanguages. In: *R. Rustin (ed.): Database Systems: 65-98, Prentice Hall and IBM Research Report RJ 987, San Jose, California*, 1972.
- [GK04] Georg Gottlob and Christoph Koch. Monadic datalog and the expressive power of languages for web information extraction. *JACM*, 51(1):74–113, 2004.
- [GKB⁺04] Georg Gottlob, Christoph Koch, Robert Baumgartner, Marcus Herzog, and Sergio Flesca. The lixto data extraction project - back and forth between theory and practice. In *PODS*, pages 1–12, 2004.
- [GKP05] Georg Gottlob, Christoph Koch, and Reinhard Pichler. Efficient algorithms for processing xpath queries. *TODS*, 30(2):444–491, 2005.
- [GM05] Evan Goris and Maarten Marx. Looping caterpillars. In *LICS*,

pages 51–60, 2005.

- [Mar04a] Maarten Marx. Conditional xpath, the first order complete xpath dialect. In *PODS*, pages 13–22, 2004.
- [Mar04b] Maarten Marx. Xpath with conditional axis relations. In *EDBT*, pages 477–494, 2004.
- [Mar05] Maarten Marx. First order paths in ordered trees. In *ICDT*, pages 114–128, 2005.