État des recherches

Pierre Senellart

TELECOM ParisTech

27 juin 2008

XML probabiliste

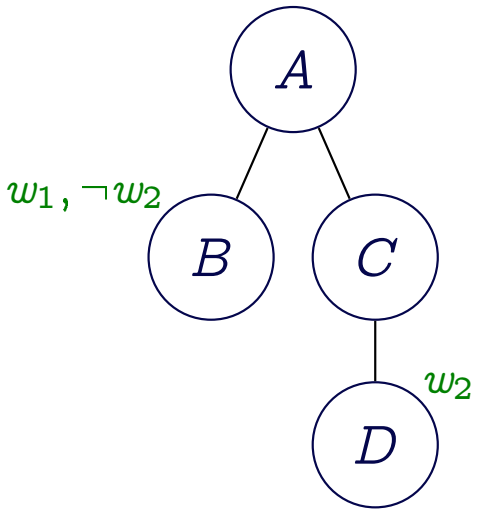

sémantique →

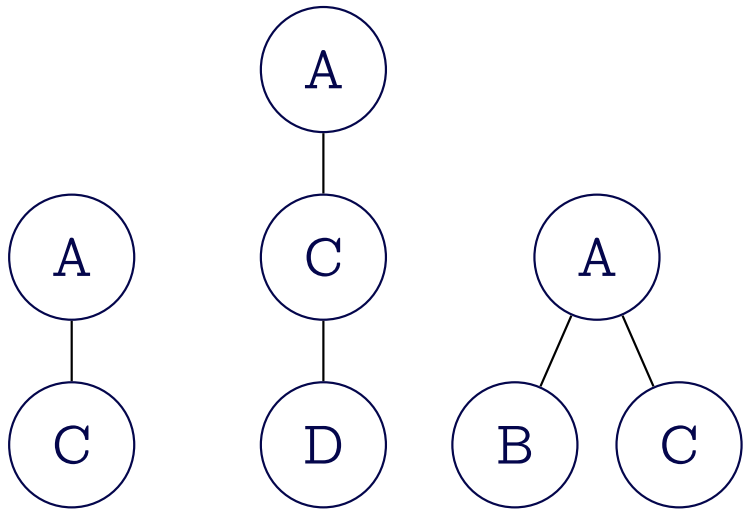

$p_1 = 0.06$ $p_2 = 0.70$ $p_3 = 0.24$

Event	Prob.
w_1	0.8
w_2	0.7

Collaboration avec Serge Abiteboul (INRIA Saclay), Benny Kimmelfeld (Hebrew University of Jerusalem).

XML probabiliste

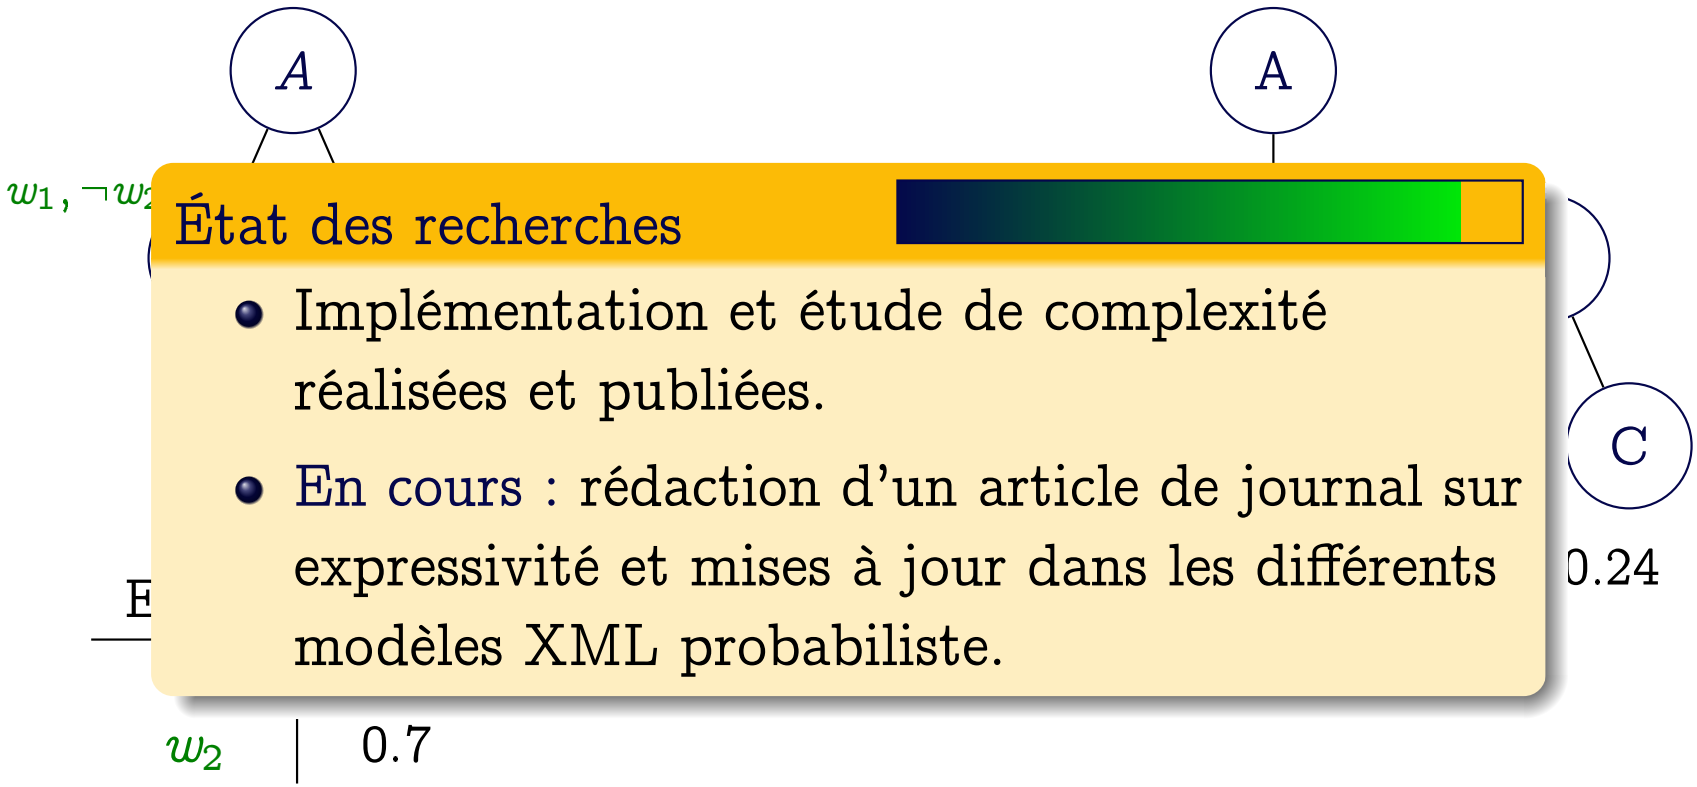

État des recherches

- Implémentation et étude de complexité réalisées et publiées.
- En cours : rédaction d'un article de journal sur expressivité et mises à jour dans les différents modèles XML probabiliste.

Collaboration avec Serge Abiteboul (INRIA Saclay), Benny Kimmelfeld (Hebrew University of Jerusalem).

Correspondance de schémas à partir d'instances

R
a
b
c
d

R'	
a	a
b	b
c	a
d	d
g	h

$$\forall x \; R(x) \rightarrow R'(x, x)$$

R' prédit

a	a
b	b
c	c
d	d

Collaboration avec Georg Gottlob, University of Oxford.

Correspondance de schémas à partir d'instances

R
a
b
c
d

R'	
a	a
b	b
c	a
d	d
g	h

$$\forall x\ R(x) \wedge x \neq c \rightarrow R'(x, x)$$

R' prédit

a	a
b	b
d	d

Collaboration avec Georg Gottlob, University of Oxford.

Correspondance de schémas à partir d'instances

R
a
b
c
d

R'	
a	a
b	b
c	a
d	d
g	h

$$\forall x\ R(x) \wedge x \neq c \rightarrow R'(x, x)$$

$$R'(c, a)$$

R' prédit

a	a
b	b
c	a
d	d

Collaboration avec Georg Gottlob, University of Oxford.

Correspondance de schémas à partir d'instances

R
a
b
c
d

R'	
a	a
b	b
c	a
d	d
g	h

$$\forall x\ R(x) \wedge x \neq c \rightarrow R'(x, x)$$

$$R'(c, a)$$

$$R'(g, h)$$

R' prédit

a	a
b	b
c	c
d	d
g	h

Collaboration avec Georg Gottlob, University of Oxford.

Correspondance de schémas à partir d'instances

R
a
b
c
d

R'	
a	a
b	b
c	a
d	d
g	h

$$\forall x\ R(x) \wedge x \neq c \rightarrow R'(x,x)$$
$$\exists y_1 \exists y_2\ R'(y_1,y_2) \wedge y_1 = c \wedge y_2 = a$$
$$\exists y_1 \exists y_2\ R'(y_1,y_2) \wedge y_1 = g \wedge y_2 = h$$

R' prédit

a	a
b	b
c	c
d	d
g	h

Collaboration avec Georg Gottlob, University of Oxford.

Correspondance de schémas à partir d'instances

R
a
b
c
d

R'	
a	a
b	b
c	a
d	d
g	h

$$\forall x\ R(x) \wedge x \neq c \rightarrow R'(x, x)$$
$$\exists y_1 \exists y_2\ R'(y_1, y_2) \wedge y_1 = c \wedge y_2 = a$$
$$\exists y_1 \exists y_2\ R'(y_1, y_2) \wedge y_1 = g \wedge y_2 = h$$

Coût : 17

R' prédit

a	a
b	b
c	c
d	d
g	h

Collaboration avec Georg Gottlob, University of Oxford.

Correspondance de schémas à partir d'instances

R
a
b

R'	
a	a
b	b

État des recherches

- Étude détaillée de complexité
- En cours : amélioration de certains résultats, rédaction de papier journal
- Possibles prolongements : étude des liens avec la programmation logique inductive

$\exists y$

$\exists y_1$

édit

a	
b	
c	c
d	d
g	h

Collaboration avec Georg Gottlob, University of Oxford.

Extraction d'informations depuis des pages de résultat

Showing results 1 through 25 (of 94 total) for all:xml

1. cs.LO/0601085 [abs, ps, pdf, other] :
Title: **A Formal Foundation for ODRL**
Authors: Riccardo Pucella, Vicky Weissman
Comments: 30 pgs, preliminary version presented at WITS-04 (Workshop on Issues in the Theory of Security), 2004
Subj-class: Logic in Computer Science; Cryptography and Security
ACM-class: H.2.7; K.4.4

2. astro-ph/0512493 [abs, pdf] :
Title: **VOFilter, Bridging Virtual Observatory and Industrial Office Applications**
Authors: Chen-zhou Cui (1), Markus Dolensky (2), Peter Quinn (2), Yong-heng Zhao (1), Francoise Genova (3) ((1)NAO China, (2) ESO, (3) CDS)
Comments: Accepted for publication in ChJAA (9 pages, 2 figures, 185KB)

3. cs.DS/0512061 [abs, ps, pdf, other] :
Title: **Matching Subsequences in Trees**
Authors: Philip Bille, Inge Li Goertz
Subj-class: Data Structures and Algorithms

4. cs.IR/0510025 [abs, ps, pdf, other] :
Title: **Practical Semantic Analysis of Web Sites and Documents**
Authors: Thierry Despeyroux (INRIA Rocquencourt / INRIA Sophia Antipolis)
Subj-class: Information Retrieval

5. cs.CR/0510013 [abs, pdf] :
Title: **Safe Data Sharing and Data Dissemination on Smart Devices**
Authors: Luc Bouganim (INRIA Rocquencourt), Cosmin Cremarenco (INRIA Rocquencourt), François Dang Ngoc (INRIA Rocquencourt, PRISM - UVSQ), Nicolas Dieu (INRIA Rocquencourt), Philippe Pucheral (INRIA Rocquencourt, PRISM - UVSQ)
Subj-class: Cryptography and Security; Databases

Collaboration avec l'équipe-projet Mostrare, INRIA Lille.

Extraction d'informations depuis des pages de résultat

Showing results 1 through 25 (of 94 total) for all:xml

1. cs.LO/0601085 [abs, ps, pdf, other] :
Title: **A Formal Foundation for ODRL**
Authors: Riccardo Pucella, Vicky Weissman
Comments: 30 pgs, preliminary version presented at WITS-04 (Workshop on Issues in the Theory of Security), 2004
Subj-class: Logic in Computer Science; Cryptography and Security
ACM-class: H.2.7; K.4.4

2. astro-ph/0512493 [abs, pdf] :
Title: **VOFilter, Bridging Virtual Observatory and Industrial Office Applications**
Authors: Chen-zhou Cui (1), Markus Dolensky (2), Peter Quinn (2), Yong-heng Zhao (1), Francoise Genova (3) ((1)NAO China, (2) ESO, (3) CDS)
Comments: Accepted for publication in ChJAA (9 pages, 2 figures, 185KB)

3. cs.DS/0512061 [abs, ps, pdf, other] :
Title: **Matching Subsequences in Trees**
Authors: Philip Bille, Inge Li Goertz
Subj-class: Data Structures and Algorithms

4. cs.IR/0510025 [abs, ps, pdf, other] :
Title: **Practical Semantic Analysis of Web Sites and Documents**
Authors: Thierry Despeyroux (INRIA Rocquencourt / INRIA Sophia Antipolis)
Subj-class: Information Retrieval

5. cs.CR/0510013 [abs, pdf] :
Title: **Safe Data Sharing and Data Dissemination on Smart Devices**
Authors: Luc Bouganim (INRIA Rocquencourt), Cosmin Cremarenco (INRIA Rocquencourt), François Dang Ngoc (INRIA Rocquencourt, PRISM - UVSQ), Nicolas Dieu (INRIA Rocquencourt), Philippe Pucheral (INRIA Rocquencourt, PRISM - UVSQ)
Subj-class: Cryptography and Security; Databases

Collaboration avec l'équipe-projet Mostrare, INRIA Lille.

Extraction d'informations depuis des pages de résultat

Showing results 1 through 25 (of 94 total) for all:xml

1. cs.LO/0601085 [abs, ps, pdf, other] :
Title: **A Formal Foundation for ODRL**
Authors: Riccardo Pucella, Vicky Weissman
Comments: 30 pgs, preliminary version presented at WITS-04 (Workshop on Issues in the Theory of Security), 2004
Subj-class: Logic in Computer Science; Cryptography and Security
ACM-class: H.2.7; K.4.4

2. astro-ph/0512493 [abs, pdf] :
Title: **VOFilter, Bridging Virtual Observatory and Industrial Office Applications**
Authors: Chen-zhou Cui (1), Markus Dolensky (2), Peter Quinn (2), Yong-heng Zhao (1), Francoise Genova (3) ((1)NAO China, (2) ESO, (3) CDS)
Comments: Accepted for publication in ChJAA (9 pages, 2 figures, 185KB)

3. cs.DS/0512061 [abs, ps, pdf, other] :
Title: **Matching Subsequences in Trees**
Authors: Philip Bille, Inge Li Goertz
Subj-class: Data Structures and Algorithms

4. cs.IR/0510025 [abs, ps, pdf, other] :
Title: **Practical Semantic Analysis of Web Sites and Documents**
Authors: Thierry Despeyroux (INRIA Rocquencourt / INRIA Sophia Antipolis)
Subj-class: Information Retrieval

5. cs.CR/0510013 [abs, pdf] :
Title: **Safe Data Sharing and Data Dissemination on Smart Devices**
Authors: Luc Bouganim (INRIA Rocquencourt), Cosmin Cremarenco (INRIA Rocquencourt), François Dang Ngoc (INRIA Rocquencourt, PRISM - UVSQ), Nicolas Dieu (INRIA Rocquencourt), Philippe Pucheral (INRIA Rocquencourt, PRISM - UVSQ)
Subj-class: Cryptography and Security; Databases

- Première annotation imprécise et incomplète grâce à la connaissance du domaine.
- Affinage par généralisation structurelle du document (champs aléatoires conditionnels, appliqués de manière non supervisée !).
- Permet d'obtenir sans intervention humaine un extracteur (*wrapper*) des résultats.

Collaboration avec l'équipe-projet Mostrare, INRIA Lille.

Extraction d'informations depuis des pages de résultat

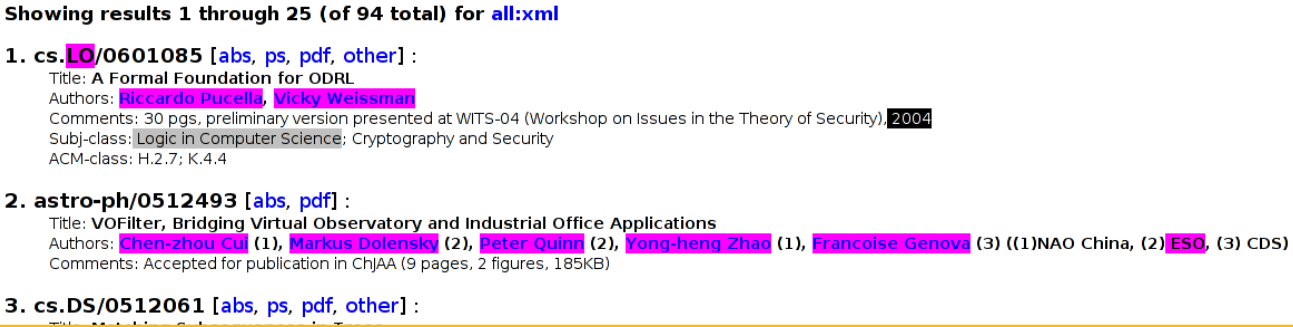

Showing results 1 through 25 (of 94 total) for all:xml

1. cs.LO/0601085 [abs, ps, pdf, other] :
Title: **A Formal Foundation for ODRL**
Authors: Riccardo Pucella, Vicky Weissman
Comments: 30 pgs, preliminary version presented at WITS-04 (Workshop on Issues in the Theory of Security), 2004
Subj-class: Logic in Computer Science; Cryptography and Security
ACM-class: H.2.7; K.4.4

2. astro-ph/0512493 [abs, pdf] :
Title: **VOFilter, Bridging Virtual Observatory and Industrial Office Applications**
Authors: Chen-zhou Cui (1), Markus Dolensky (2), Peter Quinn (2), Yong-heng Zhao (1), Francoise Genova (3) ((1)NAO China, (2) ESO, (3) CDS)
Comments: Accepted for publication in ChJAA (9 pages, 2 figures, 185KB)

3. cs.DS/0512061 [abs, ps, pdf, other] :

État des recherches

- Premières expériences réalisées, résultats satisfaisants, article en cours de revue
- À venir : expériences sur d'autres domaines, amélioration du cadre d'apprentissage pour obtenir de meilleurs résultats

- F… l
  c…
- Affinage par généralisation structurelle du document (champs aléatoires conditionnels, appliqués de manière non supervisée !).
- Permet d'obtenir sans intervention humaine un extracteur (*wrapper*) des résultats.

Collaboration avec l'équipe-projet Mostrare, INRIA Lille.

Prédiction de PageRank

- Le score (PageRank) d'une page Web évolue au cours du temps.
- Coûteux de parcourir tout le Web afin de mettre à jour ces scores.
- Possibilité de prévoir ces évolutions, en identifiant des tendances récurrentes ?

Collaboration avec Michalis Vazirgiannis, Athens University of Economics and Business.

Prédiction de PageRank

- Le score (PageRank) d'une page Web évolue au cours du temps
- C r ces s
- P t

État des recherches

- Bon résultats avec des modèles de Markov cachés
- Poster publié, papier en cours de revue

Collaboration avec Michalis Vazirgiannis, Athens University of Economics and Business.

Réponse à des requêtes avec vues et restrictions d'accès

- Quels services (du Web caché) interroger pour répondre à une requête d'un utilisateur ?
- Service, Requête : règle Datalog
- Différences avec interrogation classique de base de données :
  - L'information ne peut être obtenue que par des vues (Local As View)
  - Restriction sur les accès à ces vues (binding patterns)
  - Information incomplète et imprécise
  - Types imbriqués

Collaboration avec Serge Abiteboul, INRIA Saclay.

Réponse à des requêtes avec vues et restrictions d'accès

- Quels services (du Web caché) interroger pour répondre à u
- S
- D

nées :

État des recherches

- Modèle défini
- Pas de solution évidente
- Beaucoup de littérature sur des thèmes voisins, mais ne répondant pas exactement au problème
- En cours : exploration du côté de Magic, Minicon, Inverse-Rules...

Collaboration avec Serge Abiteboul, INRIA Saclay.

Archivage du Web et datation

Estimer la date de dernière modification d'une page :

- Timestamp et ETag HTTP
- Timestamp dans le contenu (max des timestamps ?)
- Comparaison avec une ancienne version, sans tenir compte des différences non significatives (hachage du texte uniquement, shingling, distance d'édition...)
- Méta-information sémantique (RSS, sitemaps, timestamp de documents PDF ou Word...)

Collaboration avec le Max Planck Institut für Informatik (Sarrebruck) et European Archive (Paris).

Archivage du Web et datation

Estimer la date de dernière modification d'une page :

- T
- T
- C … mpte
  d
  u
- M … mp de
  d

État des recherches

- Différentes sources d'informations répertoriées
- À venir : expérimentation systématique de la qualité de ces sources, pour définir une stratégie de datation
- Gros crawls du Web à disposition (European Archive)

Collaboration avec le Max Planck Institut für Informatik (Sarrebruck) et European Archive (Paris).

Corroboration de données entre sources

Comment utiliser la redondance des faits déclarés par différentes sources (p. ex., sur le Web) pour estimer la confiance en ces faits ?

- Graphe bipartite source/fait
- Certaines sources nient des faits
- Certains faits sont incompatibles (dépendances fonctionnelles)
- etc.

Collaboration avec Amélie Marian (Rutgers University) & Serge Abiteboul (INRIA Saclay).

Corroboration de données entre sources

Comment utiliser la redondance des faits déclarés par différentes source[illegible] faits ?

- C
- C
- C
  f
- e

État des recherches

- Modèle et algorithmes à peu près élaborés dans certains cas (PageRank en biparti, OPIC avec cash négatif)
- En cours : implémentation, expérimentations
- À venir : généralisations, dépendances fonctionnelles souples, etc.

Collaboration avec Amélie Marian (Rutgers University) & Serge Abiteboul (INRIA Saclay).

Gestion d'incertitude dans le DataRing

- DataRing : base de données semi-structurées auto-administrée
- Problème spécifique : gestion d'incertitude (existence d'informations, mesures imprécises, etc.)

Proposition de projet ANR DataRing (Atlas, Gemo, LIG, LIRMM).

Gestion d'incertitude dans le DataRing

- DataRing : base de données semi-structurées
  a
- P
  d

État des recherches

- À faire : à peu près tout ! Basé sur XML probabiliste ?