



ICDE 2009国際会議報告

石川佳治
名古屋大学

目次

- ICDE 2009について
- 全体の傾向
- クラウドコンピューティング
- セキュリティ・プライバシー
- スカイライン問合せ
- トップk問合せ・ランク集約
- キーワードに基づく問合せ・マイニング
- Most Cited Papers in ICDE 2009

ICDE 2009について

■ ICDEとは

- ◆ International Conference on Data Engineering
- ◆ IEEE主催
- ◆ ACM SIGMOD, VLDBに並ぶデータベース分野の主要会議
- ◆ 2005年には東京で開催

■ ICDE 2009

- ◆ 2009年3月29日～4月2日, 上海にて
- ◆ <http://i.cs.hku.hk/icde2009/>

■ 先端的データベースとWeb技術動向講演会 (ACM SIGMOD日本支部大会)

- ◆ 6月13日, 東工大にて
- ◆ ICDE2009の報告あり

基調講演

■ *Search Computing*

Stefano Ceri (Politecnico di Milano, Italy)

- ◆ サーチコンピューティングについて

■ *Why can't I find my data the way I find my dinner?*

David Carlson (International Polar Year Program Office, UK)

- ◆ 国際極年プロジェクトについて

■ *Data Management in the Cloud*

Raghu Ramakrishnan (Yahoo!)

- ◆ Yahoo!におけるクラウド研究開発

ワークショップ

- DBRank: Ranking in Databases
 - ◆ ランク付け問合せ
- WISS: Workshop on Information & Software Services
 - ◆ 情報・ソフトウェアサービス
- SMDB: Self-Managing Database Systems
 - ◆ データベースの自律的管理
- MOUND: Management and Mining of Uncertain Data
 - ◆ 不確実なデータの管理・マイニング
- M3SN: Modeling, Managing, and Mining of Evolving Social Networks
 - ◆ ソーシャルネットワーク

Areas in Research Track

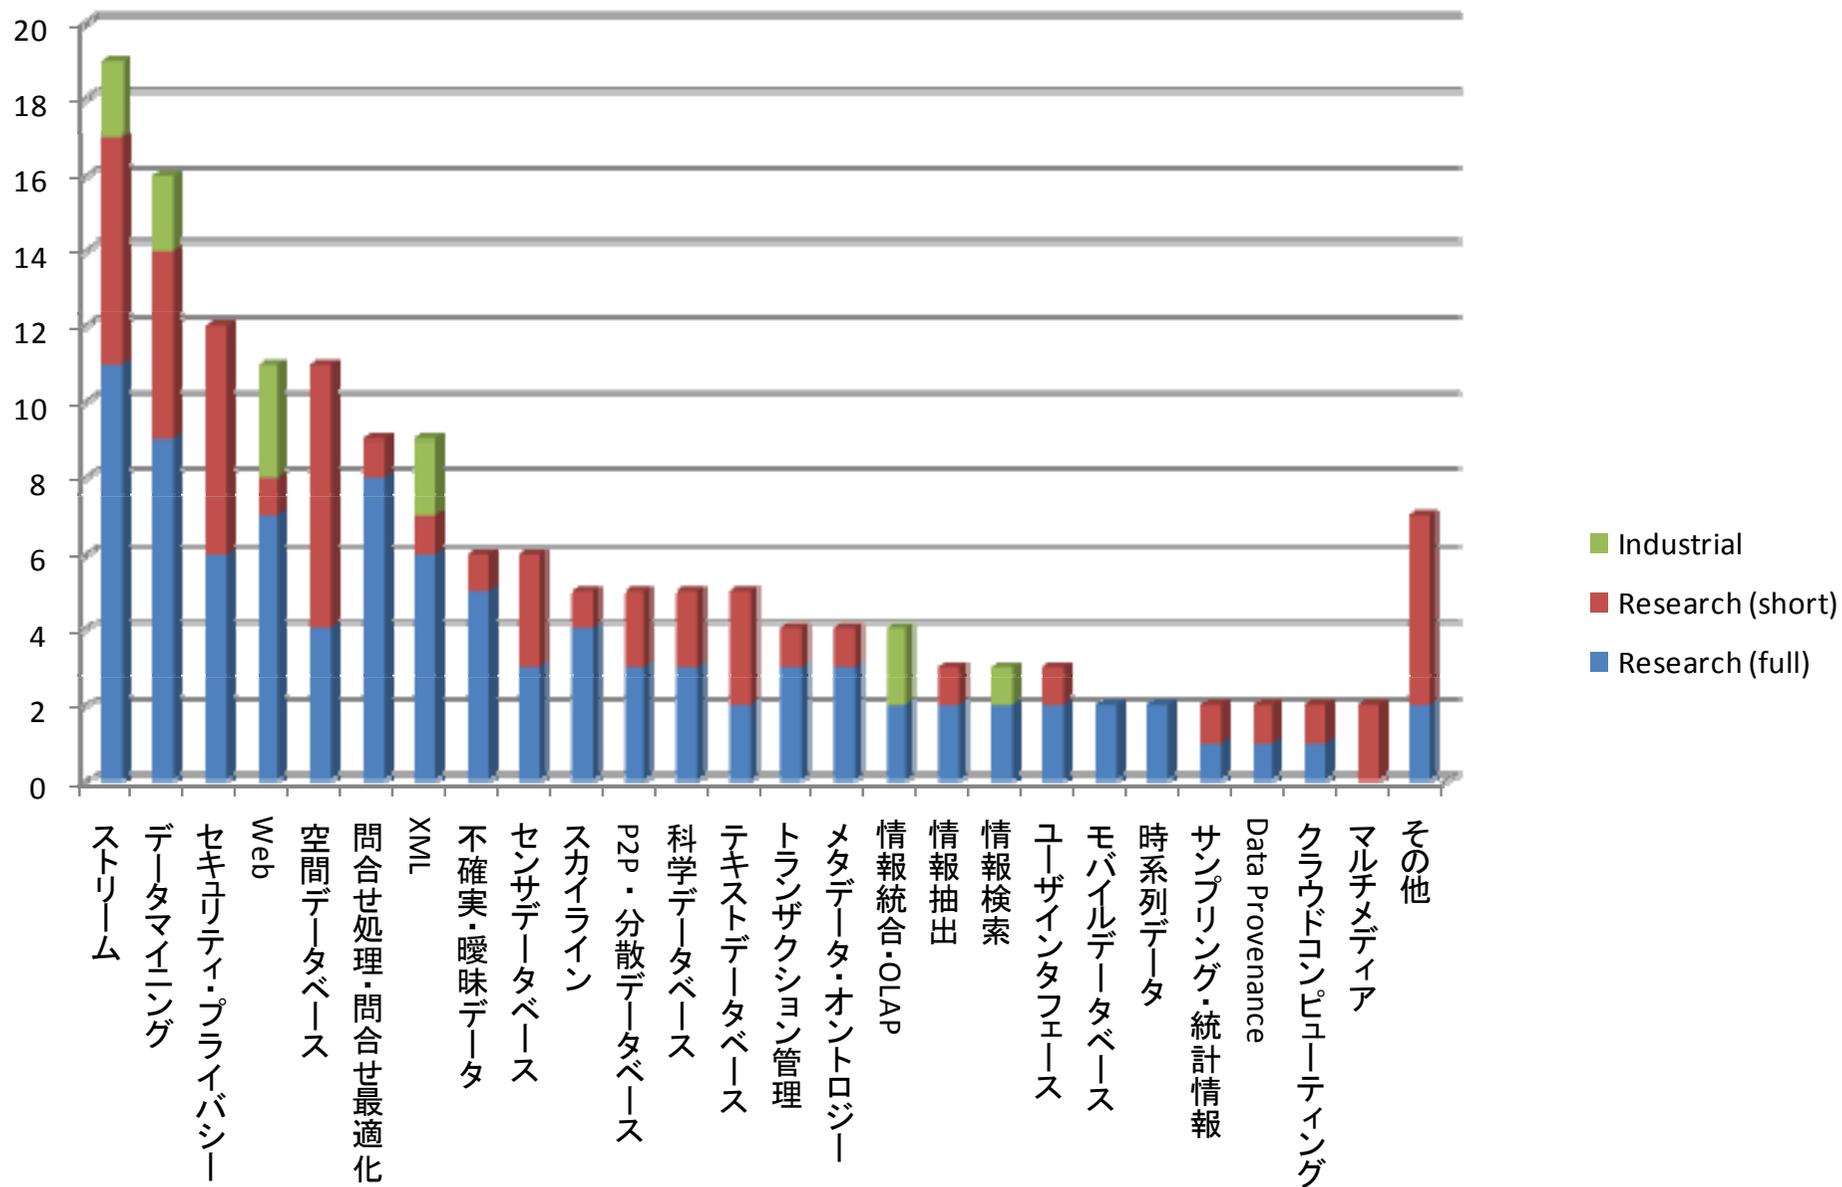
■ 14のエリアを設定

- ◆ データの近似, 不確実データ, 確率的DB
- ◆ 情報統合, メタデータ管理, 相互可用性
- ◆ データマイニング
- ◆ プライバシーとセキュリティ
- ◆ ストリーム, センサネットワーク
- ◆ データウェアハウス, OLAP, データグリッド
- ◆ ユーザインタフェース, 情報可視化
- ◆ 個人化, 社会情報管理, 注釈・キュレーション
- ◆ 問合せ処理, 問合せ最適化, チューニング
- ◆ 科学DB, バイオインフォマティクス
- ◆ トランザクション, ワークフロー, DBアーキテクチャ
- ◆ ユビキタス, モバイル, 分散, P2Pデータベース
- ◆ Webデータ管理
- ◆ XMLデータ管理

目次

- ICDE 2009について
- 全体の傾向
- クラウドコンピューティング
- セキュリティ・プライバシー
- スカイライン問合せ
- トップk問合せ・ランク集約
- キーワードに基づく問合せ・マイニング
- Most Cited Papers in ICDE 2009

トピックごとの論文数



全体の傾向

■ 継続的にホットな話題

- ◆ ストリーム処理, XML: 各論へ(狭く深く)
- ◆ データマイニング
 - グラフマイニング(リンク解析), データクリーニング, 曖昧・匿名データからのマイニングなど
- ◆ Web: Webコミュニティ, インターネット広告

■ 最近の話題

- ◆ セキュリティ・プライバシー
- ◆ 不確実・曖昧データ
- ◆ スカイライン問合せ
- ◆ センサデータベース
- ◆ Data Provenance / Lineage: データの来歴を管理: 信頼性の確保
- ◆ クラウドコンピューティング / DaaS (Database as a Service)

目次

- ICDE 2009について
- 全体の傾向
- クラウドコンピューティング
- セキュリティ・プライバシー
- スカイライン問合せ
- トップk問合せ・ランク集約
- キーワードに基づく問合せ・マイニング
- Most Cited Papers in ICDE 2009

クラウド環境での大規模データ管理

- 分散コンピューティングを基盤とするアプローチ
 - ◆ 大規模並列化によるスケーラビリティ
- キーベースのアクセス
 - ◆ Google: GFS, BigTable, MapReduce
 - ◆ Yahoo!: Hadoop & hBase
- SQLのサポート
 - ◆ SCOPE (Microsoft), Pig Latin (Yahoo!), Dryad (Microsoft), Clustra (Wisconsin U)
- トランザクションのサポート
 - ◆ PNUTS (Yahoo!), Database on S3 (ETH Zurich), Cassandra (Facebook)

提供するモデル・機能
一貫性の支援などに違い

K.S. Candan, W.-S. Li, T. Phan, M. Zhou,
Frontiers in Information and Software as Services
ICDE 2009 WISS Workshop

DaaS (Database as a Service)

- データベースをサービスとして提供
 - ◆ 例: MySQLをクラウドを介して利用
 - ◆ 通常のRDBMSとして見える: 新たな学習は不要
- スケーラビリティをどう実現するか？
 - ◆ **Multi-tenant Data Management**
- 実現のアプローチ
 - ◆ Database Space: DBMSを共有, データは別々
 - ◆ タグ付け (Tagging): タプルの所有者を表す属性を追加し, 複数のテーブルを一つにまとめる
 - ◆ スキーマ統合: 複数のスキーマを一つにマッピング [1]

[1] Aulbach, Grust, Jacobs, Kemper, Rittinger,
*Multi-tenant Databases for Software as a Service:
Schema-Mapping Techniques*, SIGMOD 2008.

ICDE 2009論文紹介 : M-Store

- Hui, Jiang, Li, Zhou, *Supporting Database Applications as a Service*
- M-Store について: タグ付け方式を採用
- 分析
 - ◆ 一つのDBMSインスタンスで多数のテーブルを支援する方式はスケーラブルでない
 - 各テーブルごとの管理情報(主記憶上で管理)やバッファ領域が累積
 - 50,000テーブル程度が限界?
 - ◆ 複数のテーブルを一つの物理テーブルで実現する方式が有望

M-Storeのアイデア

- タグ付け方式を採用: 類似したテーブルを統合

| TID | Eno | Name | Age | Phone | Salary | Office |
|-----|-----|-------|------|----------|--------|-----------|
| A | 053 | Jerry | 35 | NULL | NULL | NULL |
| A | 089 | Jacky | 28 | NULL | NULL | NULL |
| B | 023 | Mary | NULL | 98674520 | NULL | Shanghai |
| B | 077 | Ball | NULL | 22753408 | NULL | Singapore |
| C | 131 | Big | 40 | NULL | 8000 | London |
| C | 088 | Tom | 36 | NULL | 6500 | Tokyo |

Sparse Wide Tableの格納構造はe-コマースのデータベースでも重要

- ◆ 疎なテーブル
 - 単純な実装ではNULLの格納コスト大

- M-Storeのアプローチ

- ◆ MySQLをベース
- ◆ テナントのNULL属性を考慮したレコードのパッキング

| | | | | | | |
|----|----|------|-----|------|----------|----------|
| 20 | 15 | 1111 | 023 | Mary | 98674520 | Shanghai |
|----|----|------|-----|------|----------|----------|

↑
ヘッダ (tid, length, bitmap)



目次

- ICDE 2009について
- 全体の傾向
- クラウドコンピューティング
- 不確実なデータ・確率的データベース
- セキュリティ・プライバシー
- スカイライン問合せ
- トップ k 問合せ・ランク集約
- キーワードに基づく問合せ・マイニング
- Most Cited Papers in ICDE 2009

不確実・曖昧なデータ (Uncertain/Imprecise Data)

■ さまざまな要因で発生

- ◆ センサデータ
- ◆ 科学データベース：実験・観察の結果
- ◆ Webなどからの情報収集の結果
- ◆ 入力ミス, プライバシー, 近似処理, ...

■ 例：Trio (Stanford大) [1]：不確実なデータを表現可能

| (witness, car) | |
|---|-------------|
| (Amy, Honda) : 0.5 (Amy, Toyota) : 0.3 (Amy, Mazda) : 0.2 | 確信度 (確率) |
| (Betty, Acura) : 0.6 | ? |

ORを指定

Maybe Tupleであることを表現

[1] Widom, Trio: *A System for Integrated Management of Data, Accuracy, and Lineage*, CIDR 2005.

ICDE 2009の論文紹介

- Agrawal, Widom, *Confidence-Aware Join Algorithms*
 - ◆ 信頼度が伴うデータベースにおける結合問合せの処理手法
 - ◆ 信頼度によるトップ k 問合せもしくはは閾値ベースの問合せ
 - ◆ 信頼度の低いタプルは出力不要: 新たな手法の必要性
- Cormode, Garofalakis, *Histograms and Wavelets on Probabilistic Data*
 - ◆ Best Paper Award
 - ◆ 確率が伴うデータ集合の要約法
 - ◆ 例: $\langle 1, 1/2 \rangle, \langle 2, 1/3 \rangle, \langle 2, 1/4 \rangle, \langle 3, 1/2 \rangle$

値 確率
↓ ↓

可能世界とその出現確率: これをヒストグラム or ウェーブレットで要約

| | | | | | | | | | | | | |
|----------------|-------------|-----|------|------|------|------|-----|------|------|------|------|-----|
| W | \emptyset | 1 | 12 | 122 | 123 | 1223 | 13 | 2 | 22 | 23 | 223 | 3 |
| $\text{Pr}[W]$ | 1/8 | 1/8 | 5/48 | 1/48 | 5/48 | 1/48 | 1/8 | 5/48 | 1/48 | 5/48 | 1/48 | 1/8 |

目次

- ICDE 2009について
- 全体の傾向
- クラウドコンピューティング
- 不確実なデータ・確率的データベース
- セキュリティ・プライバシー
- スカイライン問合せ
- トップk問合せ・ランク集約
- キーワードに基づく問合せ・マイニング
- Most Cited Papers in ICDE 2009

セキュリティ・プライバシーの研究

■ 主な研究課題

- ◆ プライバシー保護技術
- ◆ データベース監査 (Auditing) : ログをもとに不正な動作を監視・記録
- ◆ アクセス権管理

■ 例: プライバシーを保護したデータ出版 (Data Publishing)

| 年齢 | 性別 | ZIP | 病名 |
|----|----|-------|------|
| 23 | 男 | 11000 | 肺炎 |
| 27 | 男 | 13000 | 消化不良 |
| 35 | 男 | 59000 | 消化不良 |
| 59 | 男 | 12000 | 肺炎 |
| 61 | 女 | 54000 | かぜ |
| 65 | 女 | 25000 | 胃炎 |
| 65 | 女 | 25000 | かぜ |
| 70 | 女 | 30000 | 気管支炎 |

汎化による
匿名化



ℓ-多様性の例
(ℓ = 2):
Bobの個人情報を
知っていても
高々 1/ℓ の確率
でしか病名が
特定できない

| 年齢 | 性別 | ZIP | 病名 |
|---------|----|---------------|------|
| [21,60] | 男 | [10001,60000] | 肺炎 |
| [21,60] | 男 | [10001,60000] | 消化不良 |
| [21,60] | 男 | [10001,60000] | 消化不良 |
| [21,60] | 男 | [10001,60000] | 肺炎 |
| [61,70] | 女 | [10001,60000] | かぜ |
| [61,70] | 女 | [10001,60000] | 胃炎 |
| [61,70] | 女 | [10001,60000] | かぜ |
| [61,70] | 女 | [10001,60000] | 気管支炎 |

相関ルールからの プライバシー情報の導出(1)

- Zhu, Wang, Du, *Deriving Private Information from Association Rule Mining Results*
- 相関ルール集合 (minsup = 0.3, minconf = 0.8)
 - ◆ 学歴 = 博士 \Rightarrow 給料 = 50K+ (conf = 0.83, sup = 0.42)
 - ◆ 学歴 = 博士 \wedge 性別 = 女性 \Rightarrow 給料 = 50K+ (conf = 1, sup = 0.33)
 - ◆ 性別 = 女性 \Rightarrow 給料 = 50K+ (conf = 0.89, sup = 0.67)
- 何が導出できるか
 - ◆ 博士号をもつ人の83%は50K以上の収入
 - ◆ 女性で博士号をもつと100%で50K以上の収入
 - ◆ 博士号をもった男性の中に低収入の人がいる
 - ◆ ...

相関ルールからの プライバシー情報の導出(2)

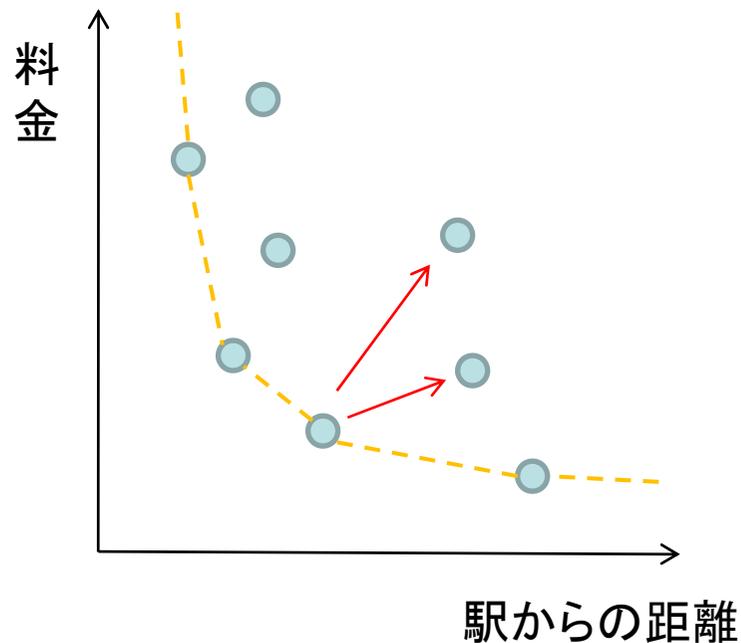
- **逆頻出アイテム集合マイニング** (inverse frequent itemset mining) の一種
- 相関ルールの集合から, プライバシー属性に関する確率を推定
 - ◆ 例: $\Pr(\text{給料} = 50\text{K}+ \mid \text{学歴} = \text{博士} \wedge \text{性別} = \text{男性})$
- **アプローチ**
 - ◆ 相関ルールを組み合わせる
 - ◆ 存在しない相関ルールも考慮
 - ◆ 相関ルール集合だけでは元データを完全に復元できるわけではないので, さまざまな可能性が存在
 - ◆ **最大エントロピー法**を用いて, 相関ルールの制約のもとで **妥当な** 確率を導出

目次

- ICDE 2009について
- 全体の傾向
- クラウドコンピューティング
- 不確実なデータ・確率的データベース
- セキュリティ・プライバシー
- スカイライン問合せ
- トップ k 問合せ・ランク集約
- キーワードに基づく問合せ・マイニング
- Most Cited Papers in ICDE 2009

スカイライン問合せ

- 例: 宿泊ホテルの候補を探す



- ◆ **スカイライン**: 他のどのオブジェクトにも支配されないオブジェクトの集合

- **スカイライン問合せ**

- ◆ Kossmann らが提案 [1]
- ◆ 一般の設定に関しては、空間索引を利用するBBSアルゴリズム [2] が高速
- さまざまな状況・対象について拡張
 - ◆ 複数の判断基準がある際の意思決定などに活用
 - ◆ 半順序の支配関係の利用がキーポイント

[1] Börzsönyi, Kossmann, Stocker: *The Skyline Operator*, ICDE 2001.

[2] Papadias, Tao, Fu, Seeger: *An Optimal and Progressive Algorithm for Skyline Queries*, SIGMOD 2003.

ICDE 2009論文: 代表的スカイライン

■ Tao, Ding, Lin, Pei, *Distance-based Representative Skyline*

■ k 個の代表的なスカイライン
オブジェクトを求める

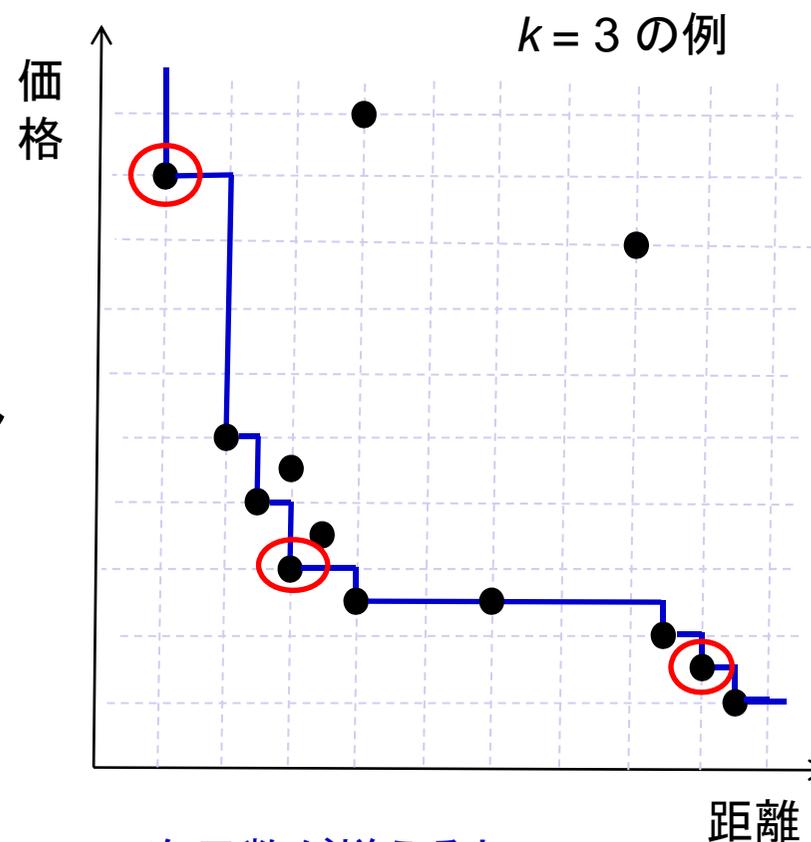
- ◆ スカイライン全体を求める
必要はない

■ 基準: 任意の代表スカイライン
点から非代表スカイライン点
への最大距離

$$Er(K, S) = \max_{p \in S - K} \{ \min_{p' \in K} \|p, p'\| \}$$

を最小化

- ◆ S : スカイライン全体集合
- ◆ K : k 個の代表

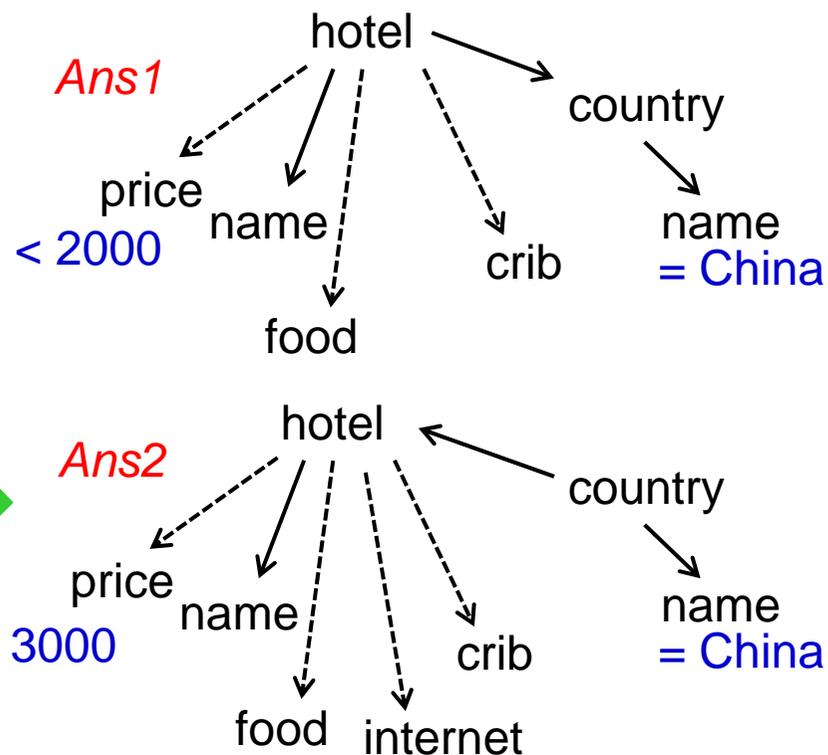
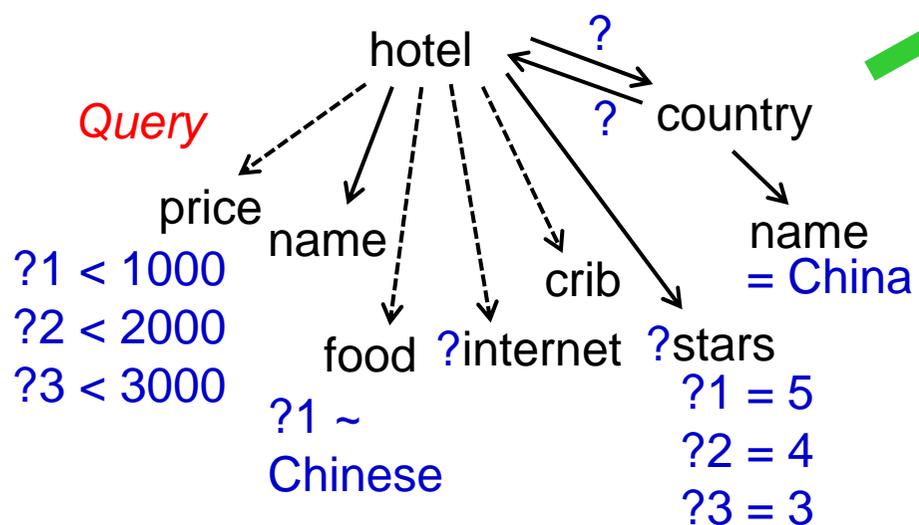


次元数が増えると
スカイライン点
急速に増えるので
代表点の考え方は有効

XMLにおけるスカイライン問合せ

- Cohen, Shiloach, *Flexible XML Querying using Skyline Semantics*

- 木のパターンで好みを記述



XMLの構造および値に関する
好みの点で他に支配されないなら
スカイラインに属する

目次

- ICDE 2009について
- 全体の傾向
- クラウドコンピューティング
- 不確実なデータ・確率的データベース
- セキュリティ・プライバシー
- スカイライン問合せ
- トップ k 問合せ・ランク集約
- キーワードに基づく問合せ・マイニング
- Most Cited Papers in ICDE 2009

トップk問合せ・ランク集約

■ トップk問合せの動機

- ◆ ユーザは必ずしもすべてのデータを必要としない
- ◆ ランク付けして上位k件を提示
- ◆ スカイライン問合せとも共通する動機

■ 多くの研究が存在 [1]

- [1] Ilyas, Baskales, Soliman, *A Survey of Top-k Query Processing Techniques in Relational Databases*, ACM Computing Surveys, 40(4), 2008.
- [2] Fagin, Lotem, Naor, *Optimal Aggregation Algorithms for Middleware*, PODS 2001 / JCSS 2003.

■ ランク集約 (Rank Aggregation)

- ◆ 複数システムからのランク付け問合せ結果を集約
- ◆ FaginによるTAアルゴリズム [2]が有名

■ ICDE2009の論文:

Soliman, Ilyas, *Ranking with Uncertain Scores*

- ◆ スコアに曖昧性があるデータ(例: レストランAの満足度は [5-8])に基づくランク付け

目次

- ICDE 2009について
- 全体の傾向
- クラウドコンピューティング
- 不確実なデータ・確率的データベース
- セキュリティ・プライバシー
- スカイライン問合せ
- トップ k 問合せ・ランク集約
- キーワードに基づく問合せ・マイニング
- Most Cited Papers in ICDE 2009

データベース上のキーワード問合せ

- 例: 問合せ {maxtor, netvista}
- キーワードを含むタプルを外部キーで結合しランク付け

Hristidis, Gravano, Papakonstantinou, *Efficient IR-style Keyword Search over Relational Databases*, ICDE 2002.

Complaints

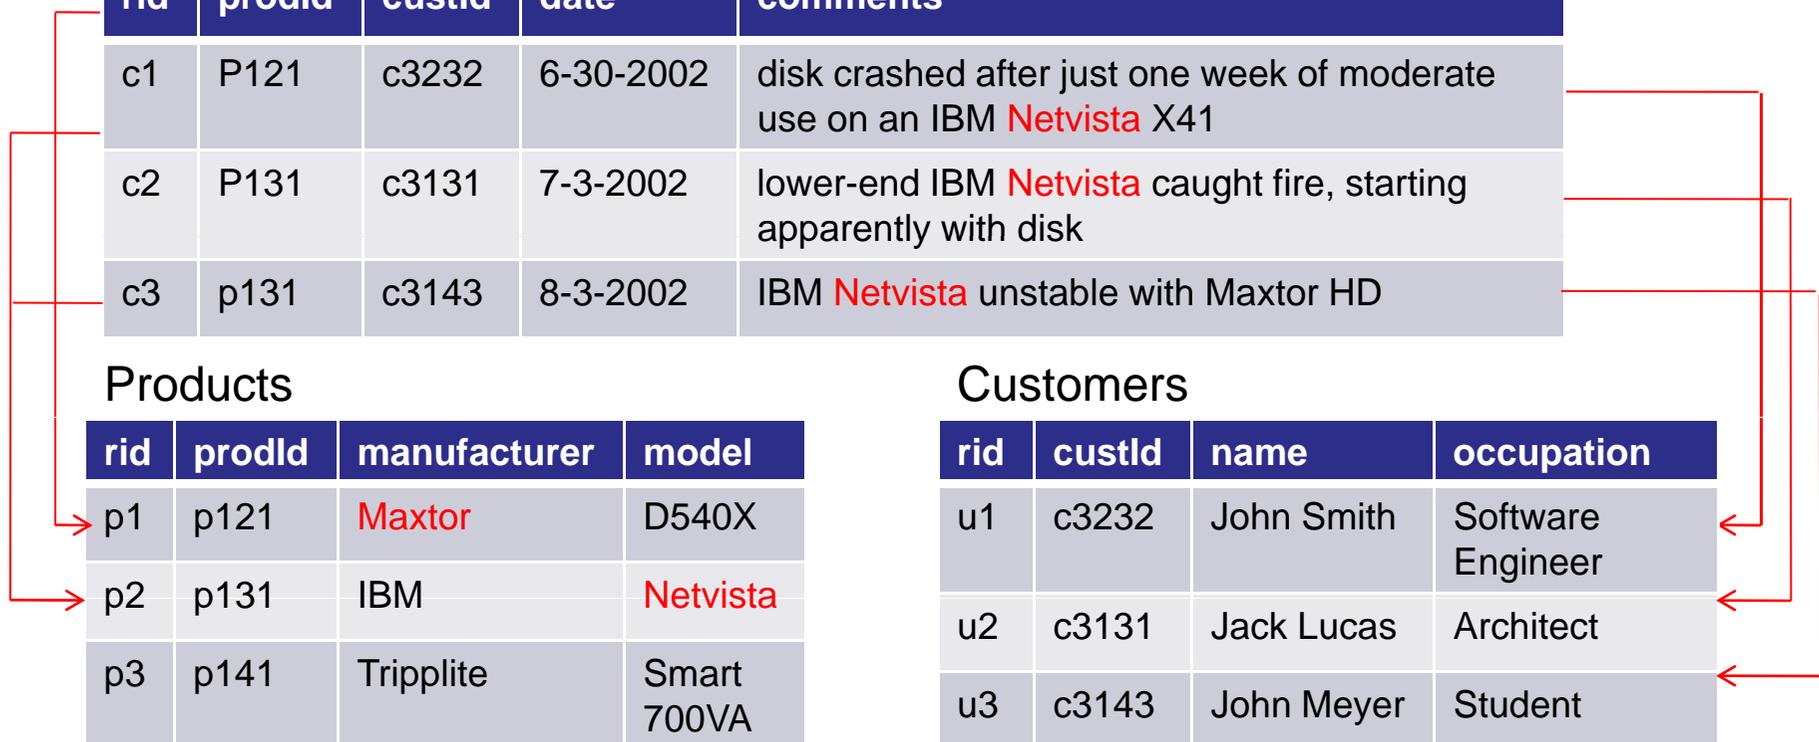
| rid | prold | custld | date | comments |
|-----|-------|--------|-----------|--|
| c1 | P121 | c3232 | 6-30-2002 | disk crashed after just one week of moderate use on an IBM Netvista X41 |
| c2 | P131 | c3131 | 7-3-2002 | lower-end IBM Netvista caught fire, starting apparently with disk |
| c3 | p131 | c3143 | 8-3-2002 | IBM Netvista unstable with Maxtor HD |

Products

| rid | prold | manufacturer | model |
|-----|-------|---------------|-----------------|
| p1 | p121 | Maxtor | D540X |
| p2 | p131 | IBM | Netvista |
| p3 | p141 | Tripplite | Smart 700VA |

Customers

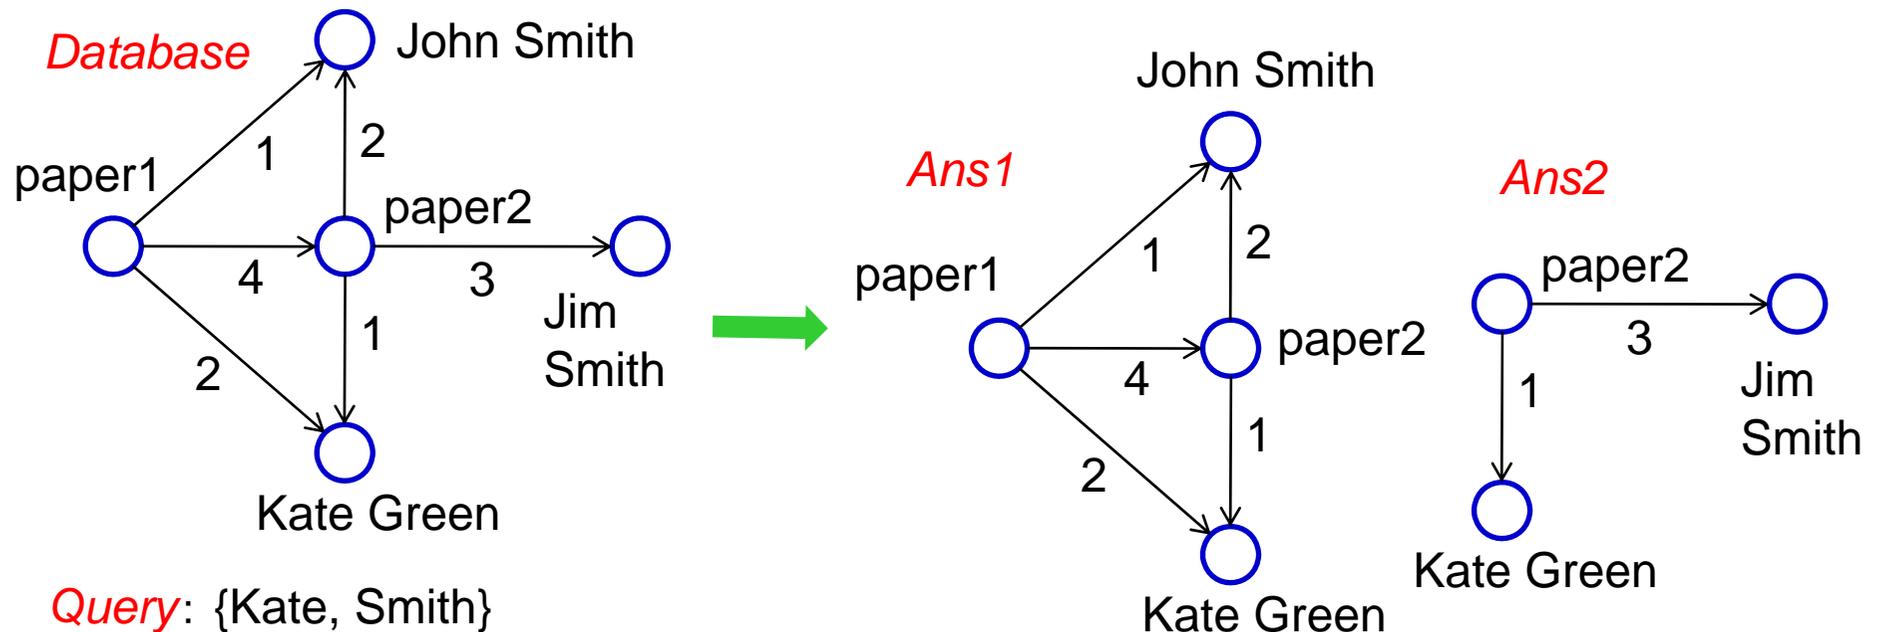
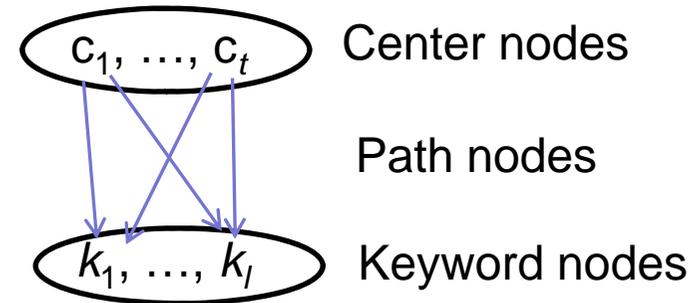
| rid | custld | name | occupation |
|-----|--------|------------|-------------------|
| u1 | c3232 | John Smith | Software Engineer |
| u2 | c3131 | Jack Lucas | Architect |
| u3 | c3143 | John Meyer | Student |



ICDE 2009論文: キーワードによる RDB中のコミュニティ検索

- Qin, Yu, Chang, Tao, *Querying Communities in Relational Databases*
- RDBをグラフとみる
 - ◆ ノード = タプル(テキスト属性含む)
 - ◆ 辺: 外部キーによる参照. 辺には重みが存在

コミュニティ構造



目次

- ICDE 2009について
- 全体の傾向
- クラウドコンピューティング
- 不確実なデータ・確率的データベース
- セキュリティ・プライバシー
- スカイライン問合せ
- トップk問合せ・ランク集約
- キーワードに基づく問合せ・マイニング
- **Most Cited Papers in ICDE 2009**

Most Cited Papers in ICDE 2009 (1)

- Fagin, Lotem, Naor, *Optimal Aggregation Algorithms for Middleware*, PODS 2001 / JCSS 2003. [15] ランク集約
- He, Wang, Yang, Yu, *BLINKS: Ranked Keyword Search on Graphs*, SIGMOD 2007. [10] キーワードサーチ
- Börzsönyi, Kossmann, Stocker, *The Skyline Operator*, ICDE 2001. [9] スカイライン問合せ
- Bhalotia, Hulgeri, Nakhe, Chakrabarti, Sudarshan, *Keyword Searching and Browsing in Databases Using BANKS*, ICDE 2002. [8] キーワードサーチ
- Hristidis, Papakonstantinou, *DISCOVER: Keyword Search in Relational Databases*, VLDB 2002. [8] キーワードサーチ

Most Cited Papers in ICDE 2009 (2)

- Dalvi, Suciu, *Efficient Query Evaluation on Probabilistic Databases*, VLDB 2004 / VLDBJ 2007. [8] 不確実・曖昧DB
- Li, Ooi, Feng, Wang, Zhou, *EASE: 3-in-1 Keyword Search Method for Unstructured, Semi-Structured Data*, SIGMOD 2008. [7] キーワードサーチ
- Liu, Yu, Meng, Chowdhury, *Effective Keyword Search in Relational Databases*, SIGMOD 2006. [7] キーワードサーチ
- Madden, Franklin, Hellerstein, Hong, *TAG: A Tiny Aggregation Service for Ad-hoc Sensor Networks*, OSDI 2002. [7] センサネットワーク
- 引用の総数ではスカイライン問合せ, 不確実・曖昧データ, セキュリティ・プライバシー, ストリーム処理などが上位