




Passage à l'échelle de la recherche et de la fouille de contenus multimédia

Michel Crucianu (CEDRIC – CNAM)
michel.crucianu@cnam.fr
avec des contributions de
Laurent Amsaleg (IRISA) et Frédéric Précioso (ENSEA)

2 juillet 2010 Assises GDR I3 1



Plan de la présentation

- 1. Recherche et fouille de données multimédia : exemples**
2. Typologie des besoins et nature des problèmes
3. Passage à l'échelle de la recherche par similarité
4. Passage à l'échelle de la fouille
5. Apports et implications de la distribution

2 juillet 2010 Assises GDR I3 2



Contexte

- Production de contenus numériques
 - ◆ Grand public : démocratisation de l'imagerie numérique
 - ◆ Industrie audiovisuelle : mondialisation des programmes
 - ◆ Spécialisés : satellite, vidéosurveillance, imagerie médicale
 - Stockage numérique
 - ◆ Forte diminution du coût par gigaoctet → démocratisation stockage
 - ◆ Croissance de la vitesse d'accès
 - Transmission / diffusion numérique
 - ◆ Augmentation des débits
 - ◆ Forte diminution du coût → démocratisation diffusion / partage
- Très grands volumes de données multimédia à exploiter
- Distribution à grande échelle des sources de données



2 juillet 2010

Assises GDR I3

3

Cédric

Besoins des utilisateurs

- Recherche par similarité
 - ◆ Requête par l'exemple
 - ◆ Recherche interactive
- Structurer une base multimédia
 - ◆ Partitionnement → résumé
 - ◆ Détection de liens
- Développer et appliquer des modèles pour
détection / reconnaissance



2 juillet 2010

Assises GDR I3

4

Cédric

Surveillance de flux vidéo

- Détection de copies vidéo : recherche par similarité
- « Copie » : version modifiée d'un contenu original (changements photométriques, géométriques, temporels, post-production)
- Exemple de volumétrie
 - ◆ Plus de 400 000* heures vidéo numérisée à l'INA
 - ◆ Plus de 400 flux audiovisuels accessibles en France (hors Internet)




2 juillet 2010

Assises GDR I3

5



Structuration de collection vidéo



Source : DailyMotion

Source : DailyMotion



2 juillet 2010


Assises GDR I3

6



Structuration de collection vidéo

- Contexte grande archive de contenu professionnel (exemple : l'INA)
 - ◆ Segmentation, étiquetage (détection génériques)
 - ◆ Aide à l'annotation
 - ◆ Analyse de bruit média et de notoriété
 - ◆ Analyse des offres média
- Contexte site partage vidéo
 - ◆ Nettoyage (élimination doublons)
 - ◆ Structuration : sélection des représentants, identification vidéos caractéristiques
 - ◆ Mutualisation / filtrage de mots clés entre versions
 - ◆ Nouveaux outils navigation/visualisation



2 juillet 2010

Assises GDR I3

7

Cédric

Fouille d'images satellitaires

- Découverte de motifs dans des collections d'images satellitaires
 - ◆ Méthodes non supervisées
 - ou
 - ◆ Apprentissage interactif
- Exemple de volumétrie pour Pleiades (2 satellites)
 - ◆ 1 image : env. 1,6 Gpixel (20 x 20 km, résolution 50 cm)
 - ◆ Jusqu'à 1 000 000 km² par jour



© Google Earth



2 juillet 2010

Assises GDR I3


8

Cédric

Description du contenu

- Séparation et description de caractéristiques
 - ◆ Image : couleurs, textures, formes
 - ◆ Vidéo : couleurs, textures, formes, mouvement

- Identification de « composantes »
 - ◆ Image : régions homogènes, points d'intérêt, configurations ; objets, visages, ...
 - ◆ Vidéo : *shots*, régions à mouvement cohérent; scènes, personnes, objets, ...



<http://www-rocq.inria.fr/imedia>



2 juillet 2010

Assises GDR I3



9

Cédric

Description du contenu

- Séparation et description de caractéristiques
 - ◆ Audio : temporelles, spectrales
 - ◆ Description résumée ou séquence de descriptions

- Identification de « composantes »
 - ◆ Audio : séparation/segmentation voix/musique/bruit, événements sonores (exemples : but, explosion)



2 juillet 2010

Assises GDR I3

10

Cédric

Évaluation de la similarité

- Dimension / complexité des descriptions
 - ◆ Vecteurs de grande dimension (souvent > 50)
 - ◆ Graphes (ex. : image ~ graphe de régions)
- Complexité des opérations de comparaison
 - ◆ S'appliquent à des objets composés
 - Ensemble ↔ (sous-)ensemble
 - Séquence ↔ (sous-)séquence
 - ◆ Nécessitent la mise en correspondance
 - Images, vidéo : configurations de points d'intérêt, avec transformations géométriques
 - Audio : séquences, avec dilatation/compression



2 juillet 2010

Assises GDR I3

11

Cédric

Plan de la présentation

1. Recherche et fouille de données multimédia : exemples
2. **Typologie des besoins et nature des problèmes**
3. Passage à l'échelle de la recherche par similarité
4. Passage à l'échelle de la fouille
5. Apports et implications de la distribution



2 juillet 2010

Assises GDR I3

12

Cédric

Recherche par l'exemple

- Nature du critère à satisfaire (q est la requête)

- Recherche par intervalle (*range query*)

$$Range_r(q) = \{x \in \mathcal{D} \mid \forall i, |x_i - q_i| \leq r_i\}$$




- Recherche dans un rayon (ϵ -*sphere query* ou *within distance query*)

$$Sphere_\epsilon(q) = \{x \in \mathcal{D} \mid d(x, q) \leq \epsilon\}$$

- Recherche des k plus proches voisins (*kppv*, *kNN*)

$$kNN(q) = \{x \in \mathcal{D} \mid |kNN(q)| = k \wedge \forall y \in \mathcal{D} - kNN(q), d(y, q) \geq d(x, q)\}$$

- N données \Rightarrow complexité $O(N)$?



2 juillet 2010

Assises GDR I3

13


Cédric

Jointure par similarité

- Jointure avec seuil de distance θ , ensembles $\mathcal{D}_1, \mathcal{D}_2$ avec N_1 et respectivement N_2 éléments


$$K_\theta = \{(x, y) \mid x \in \mathcal{D}_1, y \in \mathcal{D}_2, d(x, y) \leq \theta\}$$

\Rightarrow complexité $O(N_1 \times N_2)$?



- Auto-jointure : $\mathcal{D}_1 \equiv \mathcal{D}_2$

\Rightarrow complexité $O(N^2)$?



(variante sans seuil de distance : jointure *top-k*)



2 juillet 2010


Assises GDR I3

14

Cédric



Décision

- **k plus proches voisins**
 1. Trouver les kppv
 2. Vote majoritaire, avec ou sans seuil d'ambiguïté



- **Machine à noyaux**
 - ◆ Fonction de décision

$$f^*(\mathbf{x}) = \sum_{i=1}^N \alpha_i^* y_i K(\mathbf{x}, \mathbf{x}_i) + b^*$$
 - ⇒ complexité $O(N)$?
 - or, noyaux locaux ⇒ seuls comptent les voisins dans un rayon



$$K(-u) = K(u), \quad \int_{-\infty}^{\infty} K(u) du = 1$$



2 juillet 2010

Assises GDR I3


15

Cédric

Apprentissage


- **Supervisé, v-SVM**
 - ◆ Problème de minimisation

$$\begin{cases} \min_{\alpha} \sum_{i,j=1}^N \alpha_i \alpha_j y_i y_j K(\mathbf{x}_i, \mathbf{x}_j) \\ 1/N \geq \alpha_i \geq 0, \quad 1 \leq i \leq N \\ \sum_{i=1}^N \alpha_i y_i = 0 \\ \sum_{i=1}^N \alpha_i \geq \nu \end{cases}$$



⇒ complexité $O(N^2)$?
 or, noyaux locaux ⇒ seuls comptent les voisins dans un rayon

$$K(-u) = K(u), \quad \int_{-\infty}^{\infty} K(u) du = 1$$



2 juillet 2010


Assises GDR I3

16

Cédric

Apprentissage

- Semi-supervisé : tenir compte aussi des données non-étiquetées
 - ◆ Transduction avec SVM : trouver l'étiquetage qui maximise la marge
 - ◆ Quelles données non-étiquetées peuvent avoir le plus fort impact ?
 - Actif : sélectionner pour étiquetage les données « les plus informatives »
 - ◆ Approche classique : choisir les données les plus ambiguës (+ non redondantes)
- Trouver les données proches de la frontière !
 ⇒ complexité $O(M)$? (N données non-étiquetées)



2 juillet 2010

Assises GDR I3

17

Cédric

Estimation de densité

- Noyaux K centrés sur $\mathbf{x}_i, 1 \leq i \leq N$

- ◆ Fonction de densité


$$f(\mathbf{x}) \propto \sum_{i=1}^N K(\mathbf{x}, \mathbf{x}_i)$$

⇒ complexité $O(N)$?


or, noyaux locaux ⇒ seuls comptent les voisins dans un rayon

$$K(-u) = K(u), \quad \int_{-\infty}^{\infty} K(u) du = 1$$

(valable également pour modèles paramétriques avec N composantes)



© Duda, Hart, Stork 2001



2 juillet 2010


Assises GDR I3

18


Cédric

Quantification, classification

- Nombre fixé c de centres, N données
 \Rightarrow complexité $O(c \times N)$



- Nombre de centres dépendant des données
 $\Rightarrow \sim N^{1/3}$ centres
 \Rightarrow complexité $O(N^{4/3})$, $O(N \log M)$ ou $O(N^2)$?
 (selon la méthode)



2 juillet 2010

Assises GDR I3

19

Cédric

Une typologie des problèmes

1. Requête de même nature que les objets de la base
 - ◆ Recherche par l'exemple, décision, estimation de densité, etc.
 - ◆ Objectif : $O(M) \rightarrow O(\log M)$ ou $O(1)$
 2. Regroupement par similarité
 - ◆ Jointure par similarité, apprentissage supervisé à noyaux, *N-body problems* [RLWG09], quantification, classification
 - ◆ Objectif : $O(N^2) \rightarrow O(N)$ ou $O(N \log M)$
 3. Requête = frontière
 - ◆ Apprentissage actif, apprentissage semi-supervisé
 - ◆ Objectif : $O(M) \rightarrow O(\log M)$ ou $O(1)$
- Remarque générale : ordre de complexité \geq taille résultat !



2 juillet 2010

Assises GDR I3

20

Cédric

Passage à l'échelle

- Volume de données
 - ◆ Coûts à considérer
 - Calculs de distances (ou noyaux)
 - Transferts E/S (coût dominant pour volumes très élevés)
 - Minimiser : coût total, temps de réponse
 - Distribution (solution et problème)
 - ◆ Variable spécifique : nombre de sources de données
 - Minimiser : coût total, temps de réponse, trafic réseau
- Éviter les comparaisons sans potentiel
- Distribution : maximiser le parallélisme utile




2 juillet 2010

Assises GDR I3

21

Cédric

Hiérarchie de stockage



* Disk tests were carried out on a freshly booted machine (a Windows 2003 server with 64GB RAM and eight 15,000RPM SAS disks in RAID5 configuration) to eliminate the effect of operating-system disk caching. SSD test used a latest generation Intel high-performance SATA SSD.



2 juillet 2010

Assises GDR I3

22

Cédric

Principe général des approches


(N données \Rightarrow recherche exhaustive $O(N)$)

■ Hypothèses

1. Seules les données « proches » sont utiles
2. Peu de données sont proches
3. Les données proches sont bien plus proches que les autres

■ Illustration : regroupement hiérarchique

- ◆ 1 nœud \rightarrow 1 page disque
- ◆ Parcours de l'arbre en partant de la racine
- ◆ Idéalement $O(\log N)$ nœuds traversés
 - $\Rightarrow O(\log N)$ calculs de distance
 - $\Rightarrow O(\log N)$ échanges E/S
- $\Rightarrow 2 N$ données \rightarrow coût $\log N + \text{cst.}$!



2 juillet 2010

Assises GDR I3

23

Cédric

Plan de la présentation

1. Recherche et fouille de données multimédia : exemples
2. Typologie des besoins et nature des problèmes
3. **Passage à l'échelle de la recherche par similarité**
4. Passage à l'échelle de la fouille
5. Apports et implications de la distribution



2 juillet 2010

Assises GDR I3

24

Cédric

Typologie des structures d'index

- Selon la nature des données
 - ◆ Espace vectoriel \Rightarrow coordonnées, centres de gravité, densités de probabilité, etc.
 - ◆ Espace métrique non vectoriel \Rightarrow distances seulement
- Selon la méthode de réduction de l'espace de recherche
 - ◆ Partitionnement de l'espace : k-d-B-tree, LSD-tree...
 - ◆ Partitionnement des données : R-tree, SR-tree, M-tree...
 - ◆ Filtrage des données : VA-file, LPC-file...
 - ◆ Mixtes



2 juillet 2010



Assises GDR I3

25

Cédric

Illustration : arbre métrique

- Regroupement hiérarchique des données basé sur la métrique d
- Rejet de sous-arbre : critère issu de l'inégalité triangulaire
 - ◆ Sous-arbre $N(o_n)$: objets o tels que $d(o, o_n) \leq r_n$
 - ◆ Requête q de rayon s
 - ◆ $d(q, o_n) > r_n + s \Rightarrow d(q, o) > r_n + s - r_n = s \Rightarrow$ rejet sous-arbre $N(o_n)$



2 juillet 2010

Assises GDR I3


26

Cédric

Malédiction de la dimension

(curse of dimensionality)

- N données $\in [0, 1]^d$, distribution uniforme, division de l'espace
 - ⇒ Nombre de cellules augmente exponentiellement avec d
 - ⇒ Nombre de données par cellule diminue exponentiellement avec d , nombreuses cellules sont vides
- Données proches des hypersurfaces externes : probabilité d'être à moins de δ de la frontière est $1 - (1 - 2\delta)^d$
 - ⇒ 1 requête coupe de nombreuses cellules
 - ⇒ Séparation difficile entre cellules



2 juillet 2010

Assises GDR I3


27




Malédiction de la dimension

- Concentration des mesures : avec l'augmentation de la dimension, la variance de la distribution des distances diminue
 - ⇒ Pour partitionnement des données : plus d'intersections entre partitions ⇒ intérêt d'un index diminue \ recherche exhaustive !
 - ⇒ Cas extrême : kppv encore significatifs ? Classification significative ?

Données uniformes : variation de la distribution des distances avec la dimension



© Paolo Ciaccia



2 juillet 2010

Assises GDR I3

28



Recherche approximative ?

- L'approximation convient très bien à certaines applications
 - ◆ Illustration : recherche par l'exemple (similarité calculée ↔ perçue)
 - ◆ kppv approximatifs : soit $r_k = \max_{x \in kNN(q)} d(x, q)$ alors

$$kNN_{a(\beta)}(q) = \{x \in \mathcal{D} \mid |kNN_{a(\beta)}(q)| = k \wedge \forall x \in kNN_{a(\beta)}(q), d(x, q) \leq (1 + \beta)r_k\}$$
 - ◆ Avantage : gain potentiellement très significatif en efficacité !
- Structures d'index ↔ recherche approximative
 - ◆ Définies pour recherche exacte, admettant recherche approximative
 - ◆ Dédiées à la recherche approximative : LSH, PP-index, SASH...



2 juillet 2010

Assises GDR I3



29

Cédric

Recherche approximative

- kppv approximatifs : arrêt précoce car toute amélioration limitée à β est inutile
- Bases difficiles (faible variance de la distribution des distances)
 - ◆ ppv sont éloignés de la requête
 - ◆ Nombreuses partitions en intersection avec la requête, mais intersections (presque) vides
 - ⇒ Estimer $r_{q,\delta}$ tel que

$$P\{\exists o : d(q, o) \leq r_{q,\delta}\} \leq \delta$$
 arrêt dès que $b \leq (1 + \beta)r_{q,\delta}$



2 juillet 2010

Assises GDR I3

30

Cédric

Locality Sensitive Hashing (LSH)

(hachage sensible à la similarité)

- Domaine \mathcal{D} , ensemble de clés \mathcal{Q} , métrique $d_{\mathcal{H}} : \mathcal{D} \times \mathcal{D} \rightarrow \mathbb{R}^+$
- $\mathcal{H} = \{h : \mathcal{D} \rightarrow \mathcal{Q}\}$ fonctions de hachage $(r, \varepsilon, p_1, p_2)$ -sensibles si

$$\forall x, y \in \mathcal{D}, \quad d_{\mathcal{H}}(x, y) \leq r \Rightarrow P_{h \in \mathcal{H}}(h(x) = h(y)) \geq p_1$$

$$d_{\mathcal{H}}(x, y) > r \Rightarrow P_{h \in \mathcal{H}}(h(x) = h(y)) < p_2$$
 (pour $r, \varepsilon > 0, p_1 > p_2 > 0$)
- Recherche par similarité avec LSH
 1. Hachage de chaque objet de la base et stockage ensemble (même case) des objets de même clé
 2. Hachage de l'objet-requête, lecture de la case associée à la clé
 3. Retour comme réponse des objets de cette case (avec ou sans sélection ultérieure par calcul des distances)



2 juillet 2010


Assises GDR I3

31

Cédric

LSH : utilisation pratique

1. Concaténation de fonctions = intersection des cases issues des différentes fonctions (\rightarrow 1 table de hachage) \Rightarrow meilleure précision (meilleure sélectivité, moins de faux positifs)
2. Plusieurs tables de hachage indépendantes, réunion des cases issues de tables différentes dans lesquelles la requête se trouve \Rightarrow meilleur rappel (moins de faux négatifs)



2 juillet 2010

Assises GDR I3

32


Cédric

Multi-probe LSH


- Bon rappel avec LSH \Leftarrow nombreuses tables : occupation mémoire



- *Multi-probe* [LJW07] : dans chaque table échantillonner aussi les cases voisines, avec probabilité \propto proximité



- Comparaison



[LJW07]

2 juillet 2010



Assises GDR I3

33



A posteriori multi-probe LSH

- *Multi-probe* LSH : voisinage d'une case B définie par les fonctions de hachage, indépendamment des données !
- *A posteriori multi-probe* LSH [JB08]
 - ◆ Estimer probabilité *a posteriori* de trouver des réponses pertinentes dans chaque case voisine
 - ◆ Choisir le minimum de cases telles que Somme de leurs probabilités > seuil de rappel α



[JB08]

2 juillet 2010

Assises GDR I3

34



LSH : conclusion

- Avantages
 - ◆ Complexité recherche $\sim O(1)$
 - ◆ Métriques variées (entre vecteurs, ensembles, séquences...)
 - ◆ Adaptable au fonctionnement avec stockage externe
 - ◆ Accès optimisé par rapport à la distribution (*a posteriori multi-probe*)
 - ◆ Hachage peut être optimisé par rapport à une distribution conditionnelle (hachage « sémantique », hachage spectral,...)
- Difficultés
 - ◆ Recherche approximative
 - ◆ Peu adapté aux distributions très non uniformes
 - ◆ Filtrage peu efficace si nombre fonctions de hachage \ll dimension intrinsèque des données
 - ◆ Coût spatial très élevé si dimension intrinsèque élevée



2 juillet 2010


Assises GDR I3

35

Cédric

Recherche : conclusion

- Très nombreuses structures d'index [Sam06]
- Études comparatives systématiques et complètes ?
 - ◆ Vaste ensemble de structures d'index
 - ◆ Grandes bases diverses, distributions variées (et représentatives ?)
 - ◆ Plusieurs types de recherche exacte et approximative



- Autres critères à prendre en compte
 - ◆ Fonctionnement avec un haut débit de requêtes
 - ◆ Facilité d'exécution parallèle



2 juillet 2010

Assises GDR I3

36

Cédric

Plan de la présentation

1. Recherche et fouille de données multimédia : exemples
2. Typologie des besoins et nature des problèmes
3. Passage à l'échelle de la recherche par similarité
4. **Passage à l'échelle de la fouille**
5. Apports et implications de la distribution



2 juillet 2010

Assises GDR I3


37

Cédric

Jointure par similarité

■ Application directe de la recherche par similarité

- ◆ Chaque objet devient une requête
- ◆ Arbre $\rightarrow O(N \log N)$; LSH $\rightarrow O(N)$



■ Regrouper le travail pour objets-requête similaires

- ◆ Parcours en parallèle de deux arbres $\rightarrow O(N)$
mais construction d'arbre $O(N \log N)$!
- ◆ Partitionnement par LSH et jointure intra-cases
méthode approximative !

(rappel : ordre de complexité \geq taille résultat !)



2 juillet 2010

Assises GDR I3

38


Cédric

Algorithme à base de deux arbres


- Idée : parcourir en parallèle deux arbres de recherche

- ◆ Test d'exclusion de 2 sous-arbres

$$d(c_1, c_2) > r_1 + r_2 + \theta$$



- Jointure : algorithme doublement récursif avec 2 arbres



- Auto-jointure : algorithme doublement récursif avec 1 seul arbre



2 juillet 2010

Assises GDR I3


39

Cédric

Algorithme à base de deux arbres


- *N-body problems* [RLWG09]

$$\forall \mathbf{x}_i, f(\mathbf{x}_i) = \sum_{j=1}^N K(\mathbf{x}_i, \mathbf{x}_j)$$



- Principe : approximation par algorithme doublement récursif

- ◆ Approximation : différences finies (Gregory-Newton)
 - ◆ Borne sur l'approximation ↔ borne sur la distance
 - ◆ À chaque étape, les calculs de noyau sont faits s'il n'y a pas exclusion des noeuds



2 juillet 2010

Assises GDR I3

40

Cédric



Illustration LSH pour jointure

- Quantification de l'espace de description en cellules → chaque case est définie par un triplet de cellules [PCS09]
- Triplets de points définis par les k ppv dans l'image
- Accélération théorique

$$a = \frac{C_{2^h}^l}{(C_L^l)^2}$$

- Information géométrique pour plus de sélectivité

$$\rho = \frac{d(q, 1^{\text{er}} \text{ ppv})}{d(q, 2^{\text{nd}} \text{ ppv})}$$



2 juillet 2010

Assises GDR I3

41

Cédric

Jointure : conclusion

- Nombreux travaux sur le passage à l'échelle de la classification automatique, peu sur la jointure par similarité, *N-body problems*
- Diverses méthodes exploitent des spécificités des données (distribution particulière, données creuses)
- Extension possible aux ordres supérieurs
- Tenir compte dès le départ de la totalité des critères définissant la similarité (exemple : configurations géométriques)



2 juillet 2010

Assises GDR I3

42

Cédric

Requête = frontière

- Potentiel : apprentissage actif, apprentissage semi-supervisé
- Données les plus proches de la frontière
 - ◆ Indexation dans l'espace de description : la frontière est complexe
 - Classification hiérarchique (méthode approximative)
 - Index spatial (méthode exacte)
 - ◆ *Feature space M-tree* : dans l'espace d'arrivée, frontière = hyperplan
- Problème lié : données les plus éloignées de la frontière
 - ◆ *Kernel VA-file* : construction fichier d'approximation (*VA-file*) dans l'espace d'arrivée
 - ◆ *Kernel indexer (KDX)* : indexation des données sur une sphère (dans l'espace d'arrivée) pour noyaux $\forall \mathbf{x}, K(\mathbf{x}, \mathbf{x}) = \text{cst}$.



2 juillet 2010


Assises GDR I3

43

Cédric

FSM-tree et requête hyperplan

- Méthode
 - ◆ Discrimination par machine à noyaux (SVM, KDA...)
 - ◆ Construction *M-tree* dans l'espace d'arrivée
 - ◆ Frontière = hyperplan → requête *kNN* avec un hyperplan
 - ◆ *Kernel trick* : calculs dans l'espace de description !
 - ◆ Large classe de noyaux conditionnellement définis positifs



2 juillet 2010



Assises GDR I3

44

Cédric

FSM-tree et requête hyperplan

- Distance à l'hyperplan : $d(Q, o_e) = \frac{|\sum_i \alpha_i y_i K(o_e, x_i) + b|}{\sqrt{\sum_{i,j} \alpha_i \alpha_j y_i y_j K(x_i, x_j)}}$
- ($f(o_e) = \sum_i \alpha_i y_i K(o_e, x_i) + b$ étant la fonction de décision de la SVM)
- Principe d'élagage (test de rejet d'un sous-arbre) :
 - Si $d(Q, o_e) > r_e + s$ alors le nœud n'est pas conservé pour exploration ultérieure
- Comment éviter plus de calculs de distances :



$d(Q, o_e) + d(o_e, o_n) \geq d(Q, o_n)$ mais $d(Q, o_e) + d(Q, o_n) \not\geq d(o_e, o_n)$
 $\Rightarrow d(Q, o_e) \geq d(Q, o_n) - d(o_e, o_n)$ ($d(Q, o_e) \not\geq |d(Q, o_n) - d(o_e, o_n)|$), donc
 si $d(Q, o_n) - d(o_e, o_n) > r_e + s$ alors $d(Q, o_e) > r_e + s$



2 juillet 2010


Assises GDR I3

45




FSM-tree : évaluation

- Base : *Amsterdam Library of Object Images* (110 000 images)



Calculs de distance avec PAC-NN + FSM-tree vs. recherche exhaustive



Évolution précision avec recherche exacte et avec PAC-NN + FSM-tree



2 juillet 2010

Assises GDR I3

46



Requête frontière : conclusion

- Difficultés spécifiques
 - ◆ Espace de description : frontière complexe
 - ◆ Espace d'arrivée : concentration des mesures → moindre sélectivité
 - ◆ Requête frontière moins sélective que requête objet
du moins dans l'espace des données !
- Résultats médiocres de la recherche exacte avec index, la recherche approximative peut améliorer sensiblement l'efficacité
- Problème encore largement ouvert !



2 juillet 2010

Assises GDR I3

47

Plan de la présentation

1. Recherche et fouille de données multimédia : exemples
2. Typologie des besoins et nature des problèmes
3. Passage à l'échelle de la recherche par similarité
4. Passage à l'échelle de la fouille
5. **Apports et implications de la distribution**



2 juillet 2010

Assises GDR I3

48

Distribution

- Pourquoi ?
 - ◆ Multiplier les ressources pour traiter des problèmes difficiles
 - Puissance de calcul
 - Capacité mémoire !
 - ◆ Les données sont distribuées (et doivent le rester)
- Cas extrêmes de systèmes distribués
 - ◆ *Cluster* : architecture bien identifiée, réseau haut débit, contrôle centralisé
 - ◆ Pair-à-pair : inhomogène, autonomie connexion/déconnexion, contrôle distribué



2 juillet 2010

Assises GDR I3

49

Cédric

Quelques faits

- Hiérarchie des bandes passantes
 - ◆ Mémoire vive ~ 2,5 – 20 Go/s
 - ◆ Réseau (très) local ~ 125 Mo/s – 1,25 Go/s
 - ◆ Ligne dédiée haut débit ~ 1,25 Go/s
 - ◆ Via Internet ~ 0,1 – 1 Mo/s
 - ◆ Disque (accès séquentiel) ~ 50 Mo/s
- Augmentation bande passante ~ (réduction latence)²



2 juillet 2010

Assises GDR I3

50

Cédric

Recherche distribuée

- Quelques questions
 1. Comment localiser des données dans un système distribué ?
 - Index distribué, à construire et maintenir !
 2. Comment équilibrer la charge ?
 - En tenir compte dans le choix de la structure d'index
 3. Comment maximiser le parallélisme ?
 - En tenir compte dans le choix de la structure d'index
- Quelques exigences
 - ◆ Disponibilité : départ de pairs, pannes locales de réseau
 - ◆ Fraîcheur de l'index : arrivées / départs pairs, données
 - ◆ Qualité de recherche : temps de réponse, précision, couverture
 - ◆ Efficacité système : utilisation parcimonieuse des ressources, coût maintenance / coût recherches



2 juillet 2010


Assises GDR I3

51

Cédric

Distributed Hash Tables

- Hachage consistant : arrivée / départ d'un nœud engendre peu de changements dans les associations clés \leftrightarrow nœuds
- Double hachage
 - ◆ Donnée \rightarrow clé
 - ◆ ID nœud \rightarrow clé
 } même espace de clés !



2 juillet 2010

Assises GDR I3


52

Cédric

Chord

■ Solution DHT

- ◆ Clés sur m bits $\rightarrow [0, 2^m-1]$
- ◆ Organisation logique en anneau
- ◆ Clé k affectée au nœud (pair) **successeur**(k) = pair ayant la clé la plus faible $\geq k$



2 juillet 2010


Assises GDR I3

© Dan Vodislav
53

Cédric

Chord : recherche

- Naïve : chaque pair (p au total) connaît uniquement son successeur et lui transmet la clé k s'il ne la stocke pas $\rightarrow O(p)$
- Optimisée : chaque pair i a une table
 - ◆ Entrée j = adresse pair **successeur**($i+2^{j-1}$)
 - \rightarrow Taille table $O(\log p)$
 - ◆ Chaque pair transmet au pair (qu'il connaît) de clé aussi élevée que possible $\leq k$
 - \rightarrow Recherche $O(\log p)$



2 juillet 2010

Assises GDR I3

© Dan Vodislav
54


Cédric

M-Chord

- Principe [NZ06]
 - ◆ Linéarisation de l'espace métrique (variante *iDistance*)
 - ◆ Distribution sur un support *Chord*
- Linéarisation : partitionnement des données en n groupes C_i de « centres » p_i , calcul clé

$$iDist(x) = d(p_i, x) + i \cdot c$$

- ◆ Pour c assez grand, les clés des points de C_i sont dans $[i \cdot c, (i+1) \cdot c]$
- ◆ Les données sont stockées dans un B⁺-tree suivant les clés



2 juillet 2010

Assises GDR I3


55

Cédric

M-Chord : *iDistance*

- Recherche dans un rayon : sélection clusters C_i pour lesquels $d(p_i, q) - \epsilon \leq R_i$, calcul de $d(x, q)$ pour tout point des intervalles

$$[i \cdot c + d(p_i, q) - \epsilon, i \cdot c + \min\{R_i, d(p_i, q) + \epsilon\}]$$



2 juillet 2010

Assises GDR I3

56

Cédric

M-Chord : support Chord


- Transposition des clés *iDistance* dans le domaine *Chord* $[0, 2^m)$ avec h

$$mchord(x) = h[d(p_i, x) + i \cdot c]$$

- Distribution sur le support *Chord*

- Stockage des distances avec les objets pour filtrage supplémentaire : $d(x, q)$ n'est pas calculée si

$$|d(p_i, x) - d(p_i, q)| > \varepsilon$$



2 juillet 2010

Assises GDR I3


57

Cédric

M-Chord : construction, recherche

- Construction
 - ◆ Initialisation : sur un seul nœud, on trouve les centres et la fonction h
 - ◆ Activation d'un nouveau nœud : *split* à partir d'un nœud actif
- Insertion donnée : calcul de la clé et insertion *Chord*
- Recherche dans un rayon : sélection intervalles avec *iDistance*, identification nœuds suivant *Chord*

- Recherche *kNN*
 1. Trouver (heuristique) k objets proches
 2. ε -query avec le rayon du $k^{\text{ème}}$ objet



2 juillet 2010


Assises GDR I3

58

Cédric

M-Chord : performances

- Évaluation : 200 000 objets, 300 machines sur réseau local...
 1. VEC : objets = vecteurs de dimension 45 ; distance euclidienne
 2. TTL : objets = titres, sous-titres livres et périodiques ; distance *edit*



[NZ06]



2 juillet 2010

Assises GDR I3

59

Cédric

Recherche distribuée : conclusion

- $O(\log p)$ x latence réseau \leftrightarrow interactivité ?
 - tables de routage $O(1)$ en temps \Rightarrow espace $O(p)$
 - ◆ 10^6 paires $\rightarrow \sim 10$ Mo, c'est peu !
 - mais en pair-à-pair coût excessif de la maintenance des tables !
 - Approche exploitable uniquement si arrivées / départs rares
- Couverture (rappel) dans un contexte pair-à-pair ?
 - Pair-à-pair : inutile de s'intéresser à la recherche exacte !



2 juillet 2010

Assises GDR I3

60

Cédric

Distribution : conclusion

- Recherche interactive
 - ◆ Peu compatible avec un environnement pair-à-pair ?
 - ◆ Réalisable si arrivées / départs rares !
- Fouille : pas de contre-indication
- Évolution des approches
 - ◆ Cluster/grid : un processeur qui se libère reçoit des données et un traitement (→ transport des données)
 - ◆ Cloud : données persistantes traitées localement ; réplication pour garantir la persistance



2 juillet 2010

Assises GDR I3

61

Cédric

Conclusion générale

- Passage à l'échelle : la prise de conscience est récente dans une grande partie de la communauté
 - Emploi souvent peu critique de méthodes « prises sur l'étagère »
 - Résultats rarement conformes aux attentes
 - Focalisation sur un ensemble très restreint de problèmes
- Résultats théoriques ? Oui, sous hypothèses très restreintes...
 - Évaluation sur « données représentatives »
 - Obtenir de telles données
 - Expérimentalement : caractéristiques données ↔ résultats méthodes
 - ⇒ Compréhension des liens, résultats théoriques



2 juillet 2010

Assises GDR I3

62

Cédric

Conclusion générale

- Principaux besoins de la communauté à court terme
 - ◆ Données : corpus de très grande taille (mais pb. de droits, d'accès...)
 - ◆ Campagnes d'évaluation : critères incluant le passage à l'échelle
- Quelques initiatives
 - ◆ En Europe : CHORUS2 (action de coordination, WP Évaluation)
 - ◆ Internationale : TRECVID commence à y être sensible



2 juillet 2010

Assises GDR I3

63

Merci pour votre attention !



2 juillet 2010

Assises GDR I3

64

Bibliographie

- [BGP10] P. Bruneau, M. Gelgon, and F. Picarougne. Parsimonious reduction of Gaussian mixture models with a variational-Bayes approach. *Pattern Recognition*, vol. 43, pp. 850-858, 2010.
- [DII04] M. Datar, N. Immorlica, P. Indyk, and V. S. Mirrokni. Locality-sensitive hashing scheme based on p -stable distributions. In *SCG'04: Proc. 20th annual Symposium on Computational Geometry*, pages 253–262, New York, NY, USA, 2004. ACM.
- [KKZ09] H. Kriegel, P. Kröger, and A. Zimek. Clustering high-dimensional data: a survey on subspace clustering, pattern-based clustering, and correlation clustering. *ACM Trans. Knowl. Discov. Data* 3, 1 (Mar. 2009), 1-58.
- [NZ06] D. Novak, and P. Zezula. M-Chord: a scalable distributed similarity search structure. *Proc. InfoScale'06*, pp. 19–28, 2006.
- [PCS09] S. Poullot, M. Crucianu, and S. Satoh. Indexing local configurations of features for scalable content-based video copy detection. In *LS-MMRM: 1st Workshop on Large-Scale Multimedia Retrieval and Mining, with ACM Multimedia 2009*, pages 43–50, New York, NY, USA, 2009. ACM.
- [RLWG09] P. Ram, D. Lee, W. March, A. Gray. Linear-time Algorithms for Pairwise Statistical Problems. In *NIPS 2009*, pp. 1527-1535.



2 juillet 2010

Assises GDR I3

65

Cédric

Bibliographie

- [Sam06] H. Samet. *Foundations of Multidimensional and Metric Data Structures*. Morgan Kaufmann, San Francisco, CA, USA, 993 p. 2006.
- [SZ03] J. Sivic and A. Zisserman. Video Google: A text retrieval approach to object matching in videos. In *Proc. 9th IEEE Intl. Conf. on Computer Vision (ICCV'03)*, pp. 1470-1477, Washington, DC, USA, 2003. IEEE Computer Society.



2 juillet 2010

Assises GDR I3

66

Cédric