Recherche d'information par le contenu

Master2 - Partage de données à grande échelle - GMIN307

Alexis JOLY - alexis.joly@inria.fr

November 1st 2012

Planning

15 Octobre: cours

13:15 - 14:45 Recherche d'information par le contenu I (principes, applications, malédiction de la dimension, méthodes de partitionnement)

15:00 - 16:30 Recherche d'information par le contenu II (présentation de deux librairies: FLANN et VLFeat, Présentation détaillée des arbres KD aléatoires (randomized kd-trees), Présentation détaillée de LSH et ses variantes)

22 Octobre: TP

13:15 – 16:30 Recherche approximative des k plus proches voisins via LSH et Hadoop

Pré-requis: TP Reza Akbarinia - Installation de Hadoop et Eclipse

Planning

13 Novembre: cours

13:15 - 14:45 Recherche d'information par le contenu I (principes, applications, malédiction de la dimension, méthodes de partitionnement)

15:00 - 16:30 Recherche d'information par le contenu II (structures d'indexation et de recherche approximatives, étude détaillée de LSH et du M-tree, algorithmes de marche dans les graphes)

20 Novembre: TP

13:15 – 16:30 Recherche approximative des k plus proches voisins via LSH et Hadoop

Pré-requis: TP Reza Akbarinia - Installation de Hadoop et Eclipse

Introduction, Principes et Applications de la recherche par le contenu

Introduction

Recherche d'Informati

uniquement le **conten**

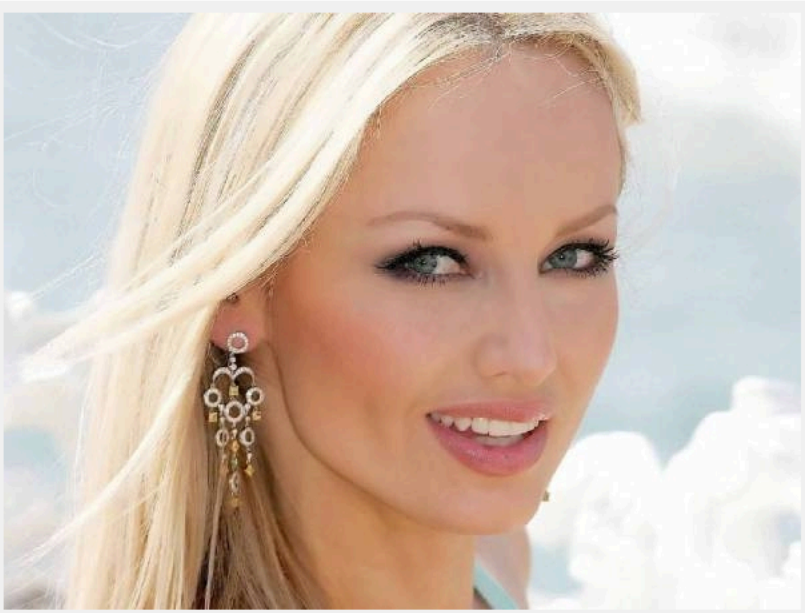

"pizza aux anchois"

Pas de reconnaissance d'image pour Google.

L'unique objectif du test est de valider le fait que l'image ci-dessus se positionnera dans GG images pour la requête « pizza aux anchois ». Il n'y a pas de raison que ce ne soit pas le cas. Pour le moment, Google ne reconnait pas les images, mais il prend en compte l'environnement textuel de celles-ci pour en déterminer le sujet. Et l'environnement ici, il est bien plus orienté **pizzéria** que mannequinat.

Maintenant, au train ou vont les évolutions techniques de la reconnaissance d'image, il y a fort à parier que les moteurs sauront un de ces jours différencier la jolie dame ci-dessus d'une vulgaire pizza.

Que dire d'autre sur cette pizza ?

On peut dire comme pour notre test que cette recette de pizza ne fait pas l'unanimité. En effet, les anchois sont accueillis comme un met délicat par certains, et comme le pire pour les papilles par d'autres.

Pour les hurluberlus qui voudraient en savoir plus sur ce sujet, passez voir ici, mais globalement, on s'en fiche un peu, tout ce qui nous intéresse, c'est de voir comment notre pizza va prendre chez le roi des moteurs.

La recette de la pizza aux anchois

Introduction

L'indexation et le **recherche** par le **contenu visuel** exploite l'information **contenue dans les images**

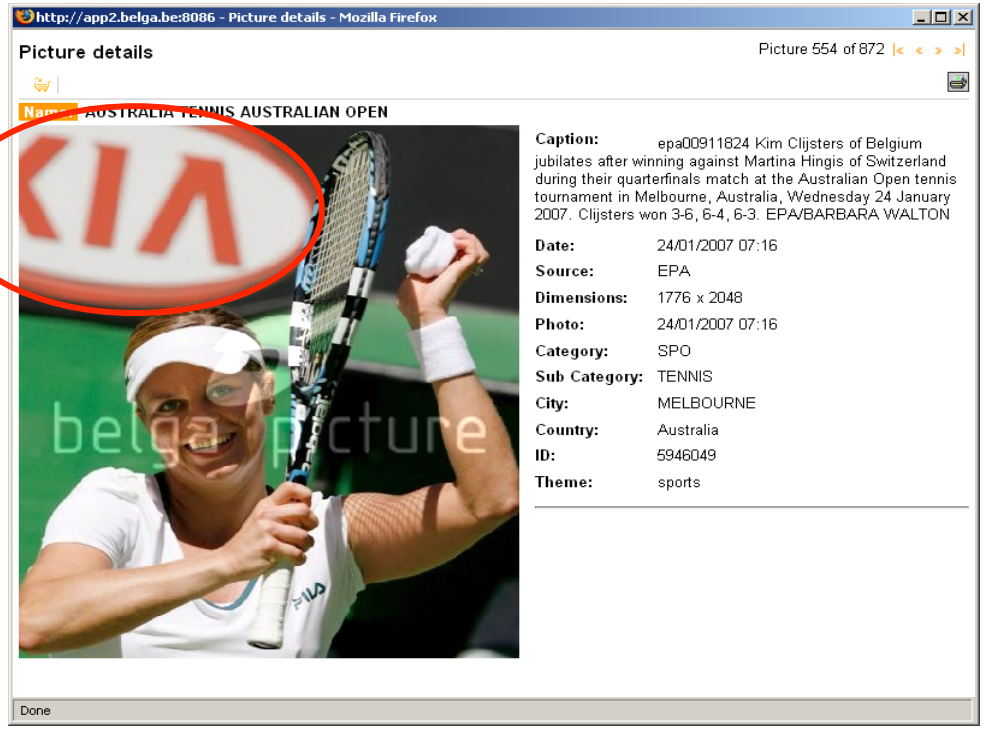

Introduction

Approches Content-to-text

→ Reconnaissance d'objets, de visages, de textes (OCR)

→ Speech-to-text, reconnaissance de locuteurs

Utilisation d'outils classiques d'indexation et de recherche de données

Approches Content-based

→ Utilisation de **descripteurs** (***signatures*** ou ***features***) = des vecteurs calculés à partir du contenu visuel ou audio caractérisant les couleurs, les formes, les fréquences, etc.

→ Requête par l'exemple (Shazam, Google similarity search, Goggles)

→ Query-by-window, Query-by-sketch, Query-by-singing, Query-by-tapping

Introduction

Approches Content-to-text

→ Reconnaissance d'objets, de visages, de textes (OCR)

→ Spee

Utilisatio

Approc

→ Utilisa ir du
conte
fréqu

→ Requ

→ Quer ping

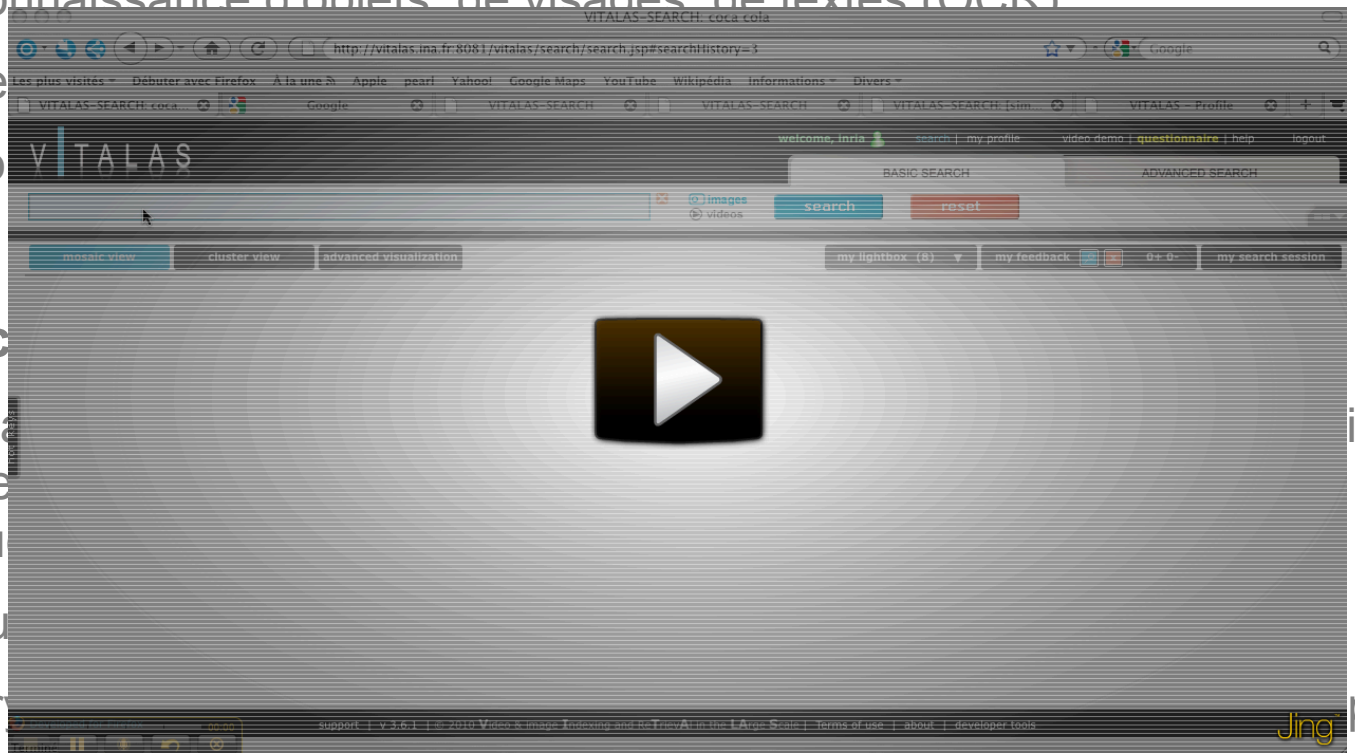

Principe 1/4

Des signatures du contenu visuel

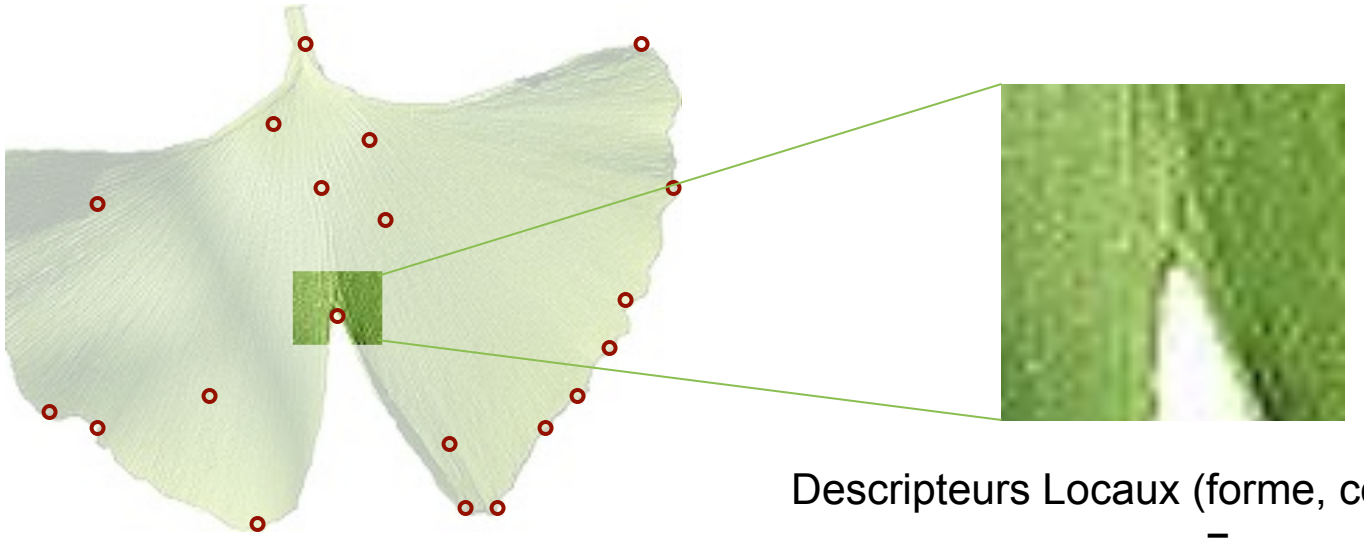

Descripteurs Locaux (forme, couleur, texture)
=
Vecteurs de grande Dimension (128, 1024, etc.)

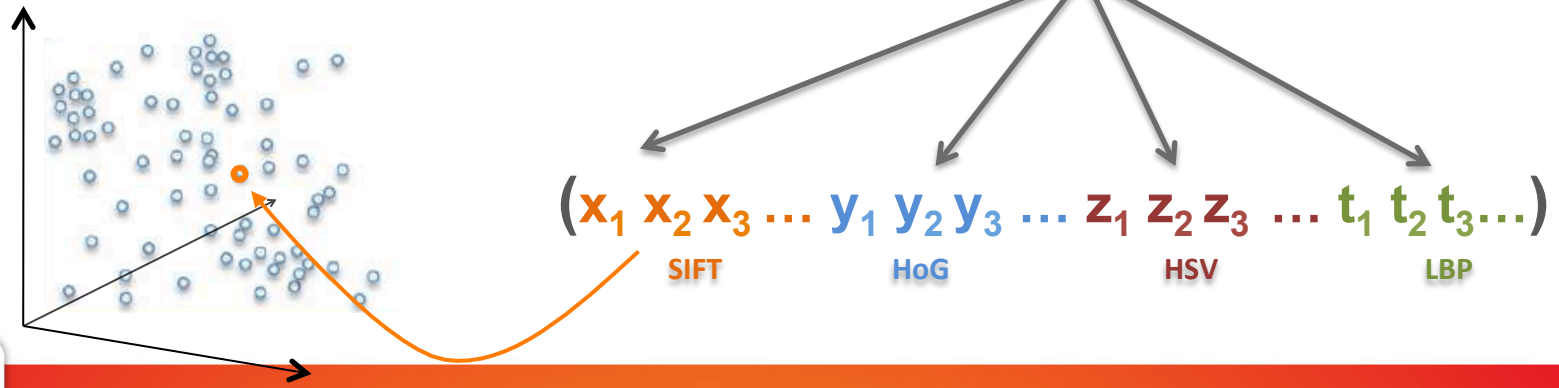

Principe 2/4

ou du contenu audio

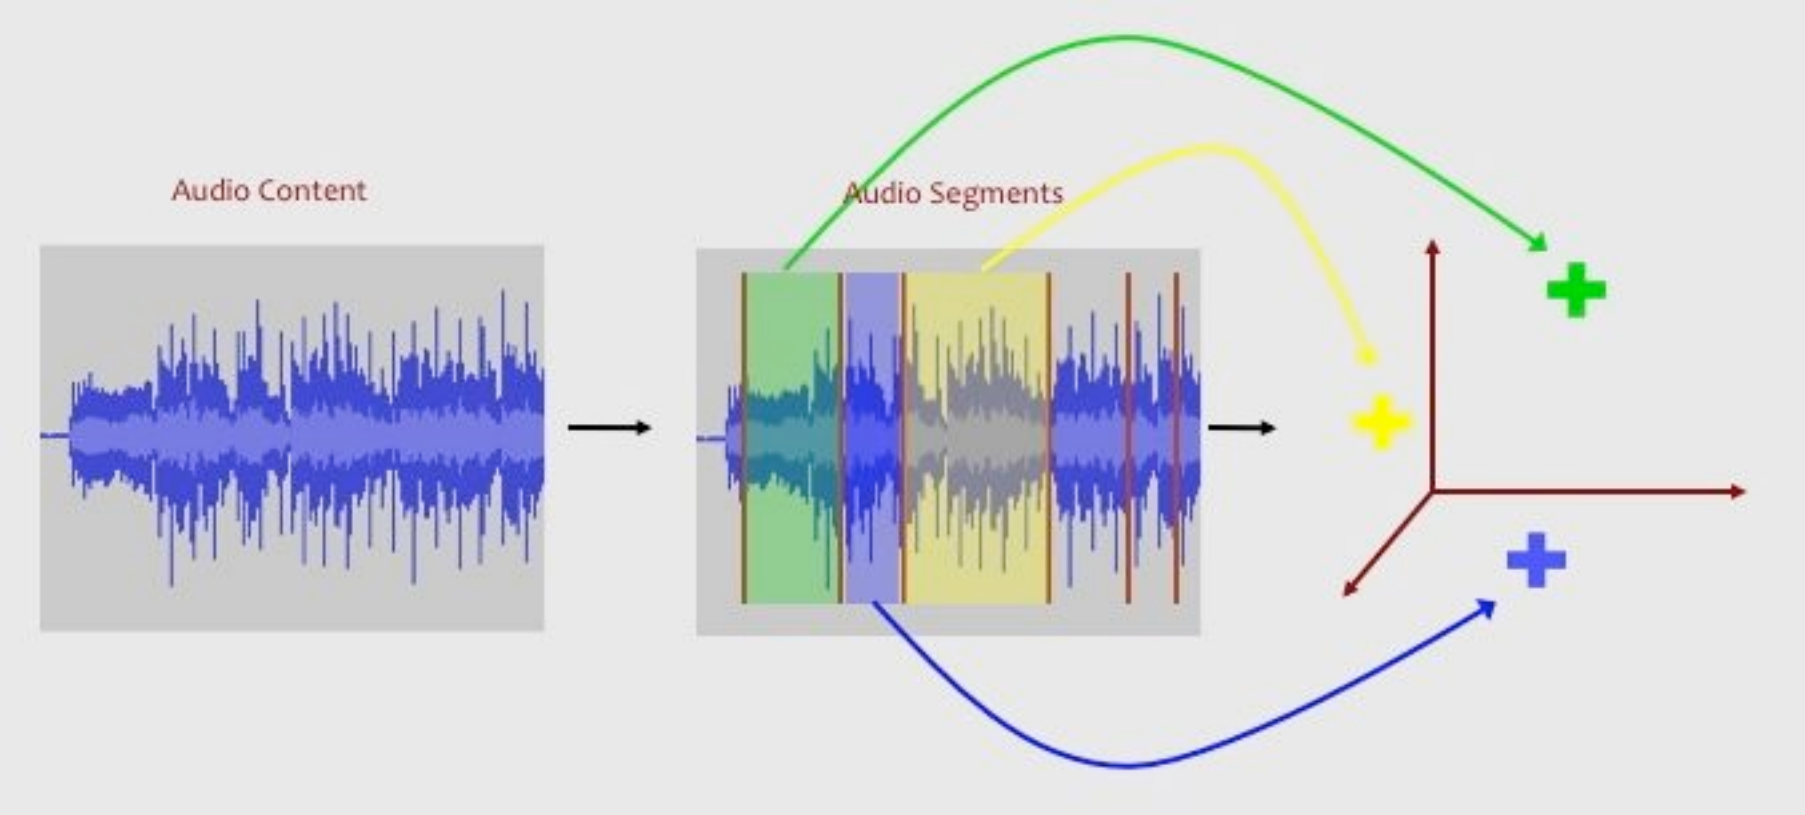

Principe 3/4

Des techniques d'indexation

Objectif: comparer **efficacement** une **signature requête** avec les **signatures de la base**

Problème: des **centaines de milliards** de comparaisons de vecteurs si on les traite exhaustivement + croissance exponentielle

Solution = structures d'indexation, **VQ**, **hachage**, **compression**, **codage**, **encapsulation, regroupement,** etc.

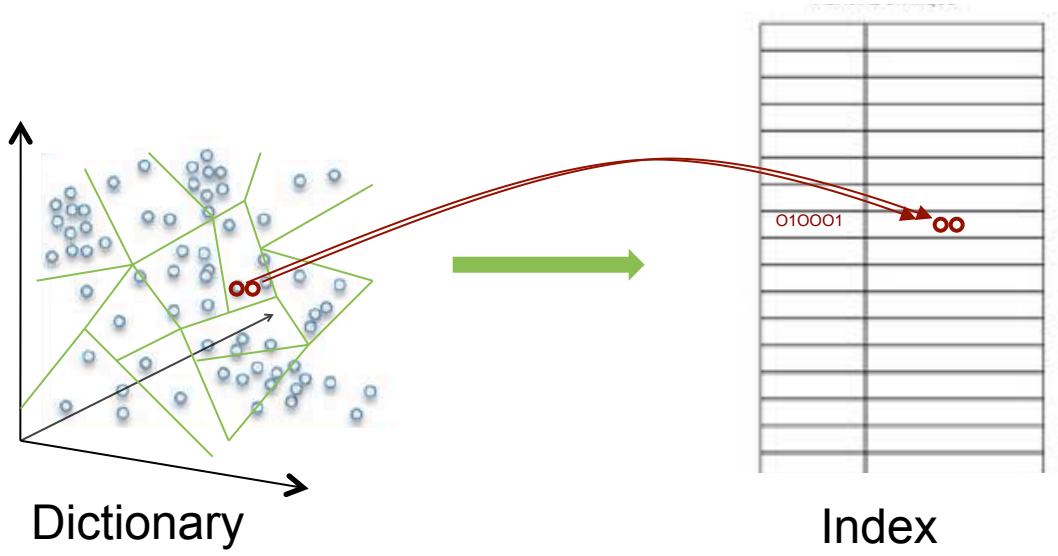

Principe 4/4

Des algorithmes de recherche par similarité efficaces et scalables

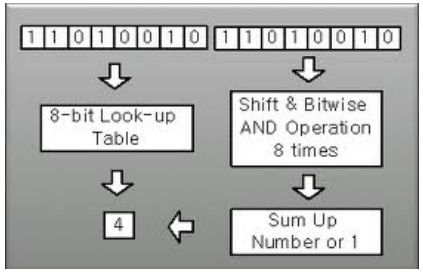

LUT-based Hamming distance

multi-probe queries in hash tables

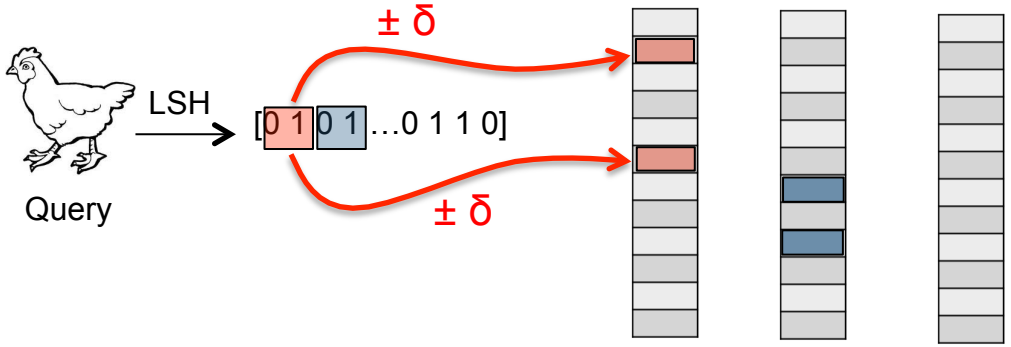

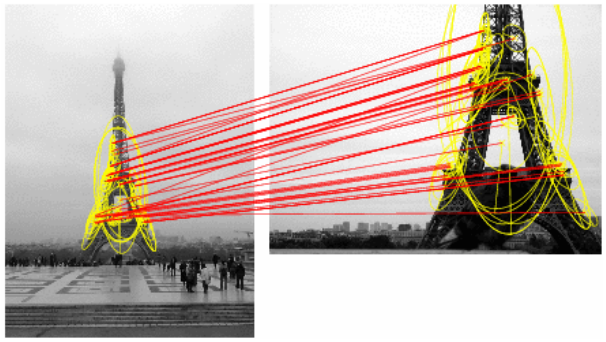

Weak geometry (σ,θ)

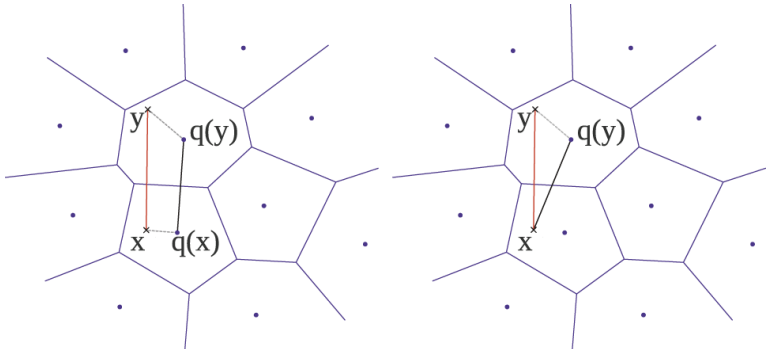

Asymetric distance

Les applications 1/5

Détection de copies vidéo par le contenu

Monitoring de flux TV ou Web en temps-réel

15 M de vidéos indexées chez Youtube, 500 000 h de TV à l'INA

Forte robustesse aux attaques & transformations

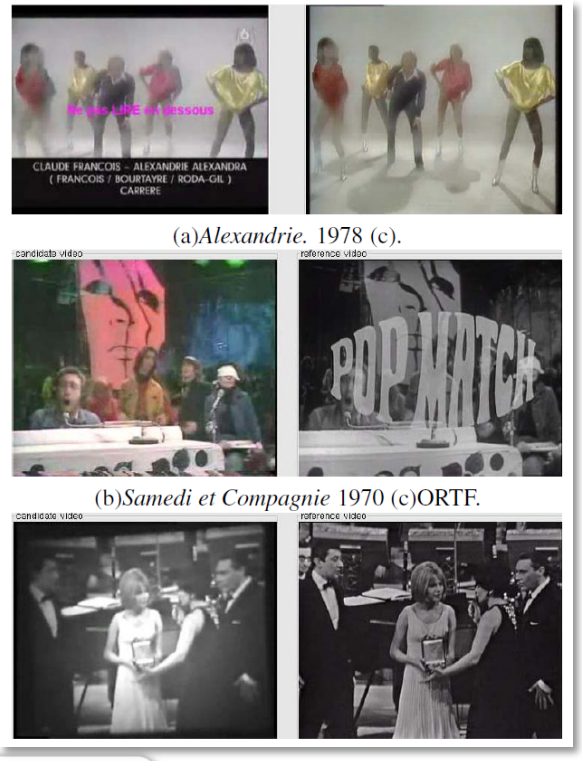

(a)*Alexandrie.* 1978 (c).

(b)*Samedi et Compagnie* 1970 (c)ORTF.

Les applications 2/5

Identification de chansons / musiques

Shazam > 10 Millions de titres

MusicID > 40 Millions titres

Query-by-humming (plus compliqué)

SoundHound >10 Millions de titre

Les applications 3/5

Recherche d'images similaire (ou near-duplicates)

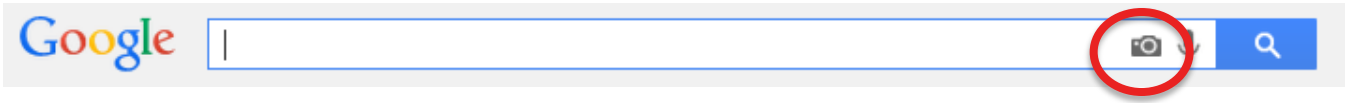

Google > 50 Milliards d'images

LTU > 100 Millions images

Reverse image search

Tineye > 3 Milliards d'images

Mobile search

Kooaba > 10M images

Goggles > ??

Les applications 4/5

L'identification des végétaux

Pl@ntNet > 3800 espèces

LeafSnap > 250 espèces

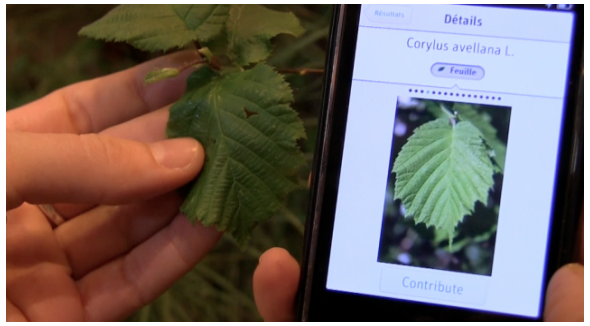

L'identification des animaux

Encore à l'état de recherche

Reconnaissance de chants d'oiseaux

Vidéosurveillance de poissons dans les récifs

Suivi de baleines (images de la queue)

Life Cle 2014

Les applications 5/5

Découverte d'évènements par contenu visuel

1. Dans les médias sociaux

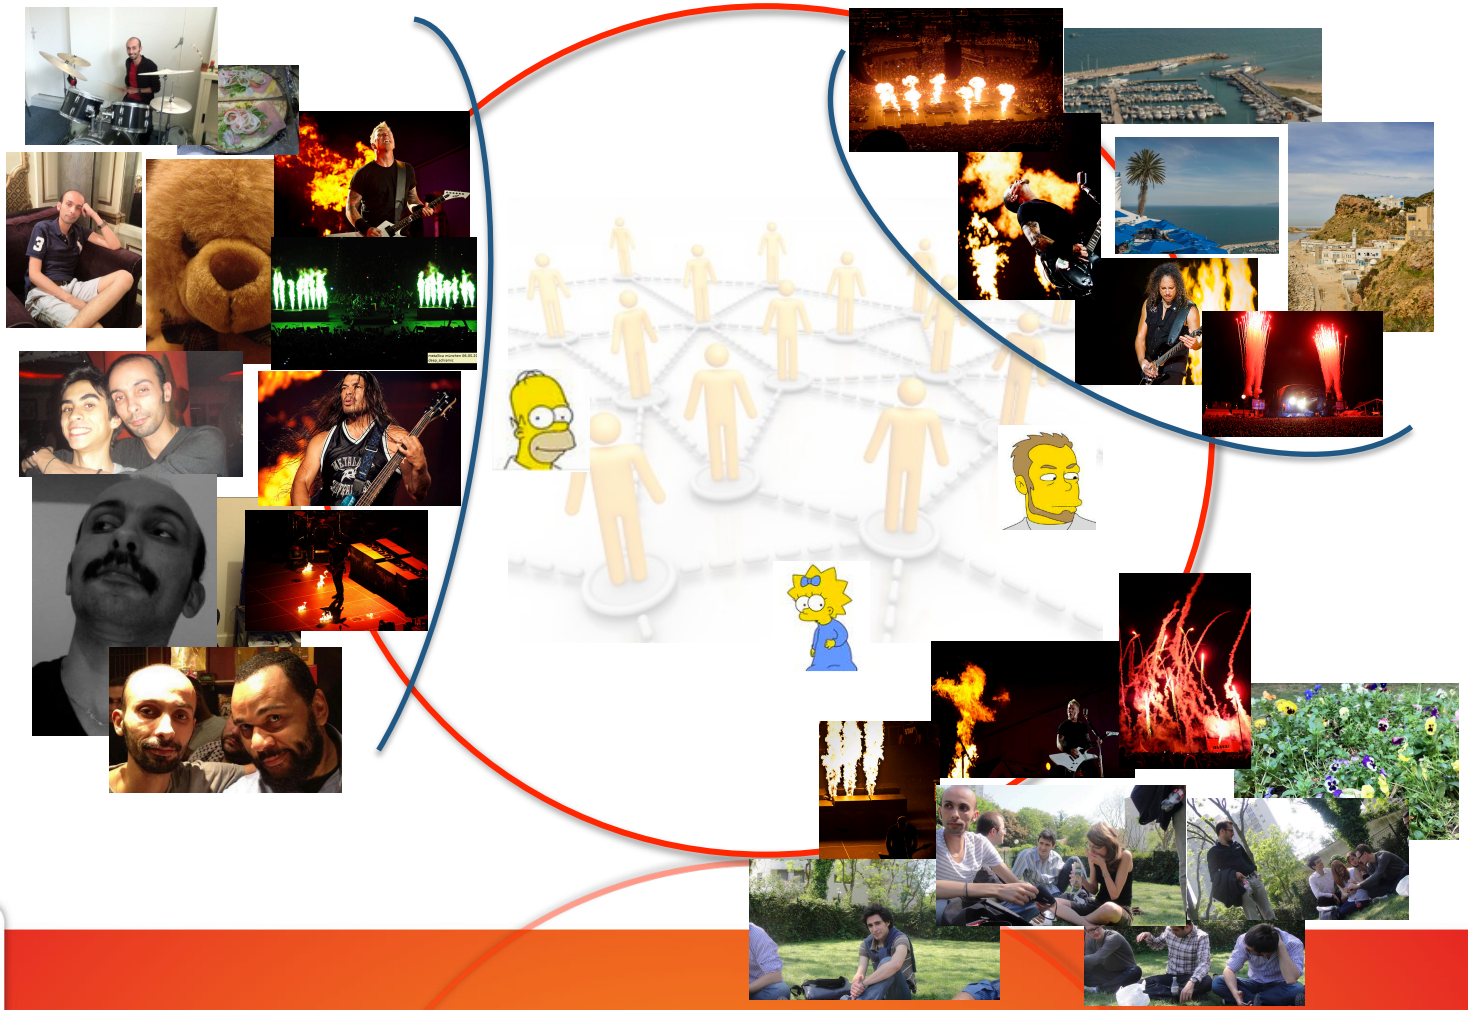

Les applications 5/5

Découverte d'évènements par contenu visuel

1. Dans les médias sociaux
2. A travers différents médias (TV, web , AFP)

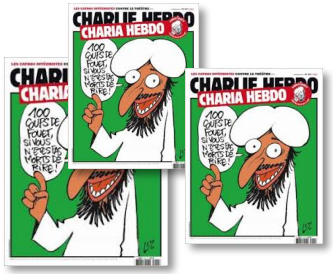

Arte TV

Lemonde

corto74.blogspot.com

Quelques descripteurs de contenu et mesures de similarité associées

- Cas d'école: Histogramme HSV

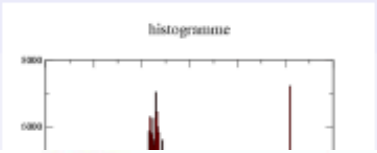

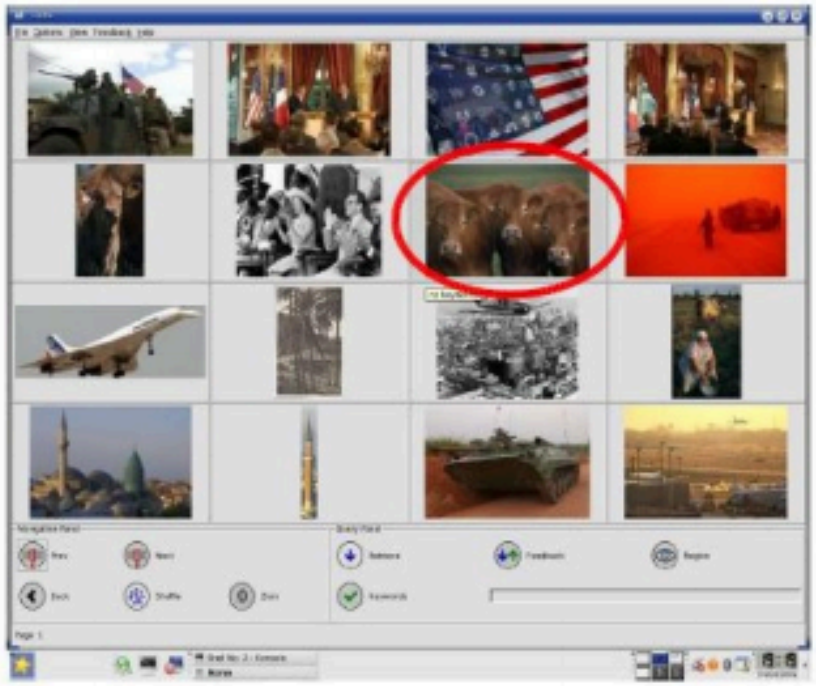

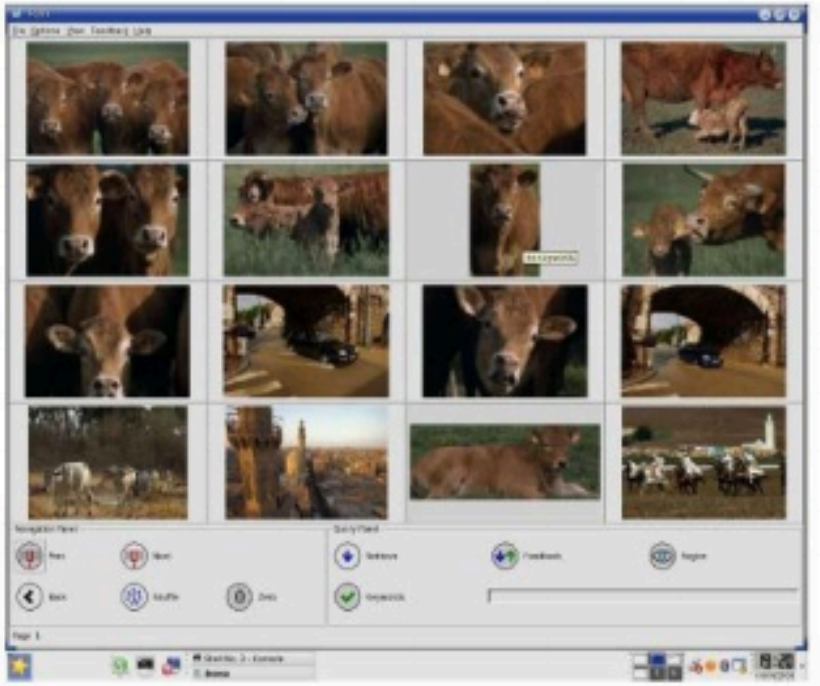

La détection de points ou de régions d'intérêt

Détection de points d'intérêt par différence de Gaussienne

Grille dense

Détecteur de Harris

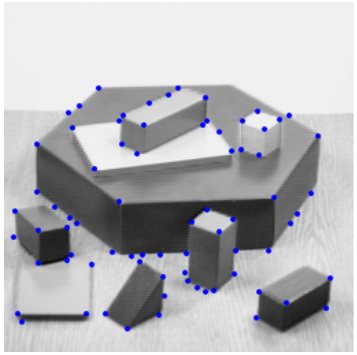

Maximaly Stable Extremal Regions

Difference of Gaussians

Superpixels

Les descri

Calculés autc

- **SIFT** (Lowe, 20(que L2

```
133.92 135.88 14.38 -2.732
 3 12 23 38 10 15 78 20 39 67 42 8 12 8 39 35 118 43 17 0
 0 1 12 109 9 2 6 0 0 21 46 22 14 18 51 19 5 9 41 52
 65 30 3 21 55 49 26 30 118 118 25 12 8 3 2 60 53 56 72 20
 7 10 16 7 88 23 13 15 12 11 11 71 45 7 4 49 82 38 38 91
 118 15 2 16 33 3 5 118 98 38 6 19 36 1 0 15 64 22 1 2
 6 11 18 61 31 3 0 6 15 23 118 118 13 0 0 35 38 18 40 96
 24 1 0 13 17 3 24 98
132.36 99.75 11.45 -2.910
 94 32 7 2 13 7 5 23 121 94 13 5 0 0 4 59 13 30 71 32
 0 6 32 11 25 32 13 0 0 16 51 5 44 50 0 3 33 55 11 9
 121 121 12 9 6 3 0 18 55 60 48 44 44 9 0 2 106 117 13 2
 1 0 1 1 37 1 1 25 80 35 15 41 121 3 0 2 14 3 2 121
 51 11 0 20 93 6 0 20 109 57 3 4 5 0 0 28 21 2 0 5
 13 12 75 119 35 0 0 13 28 14 37 121 12 0 0 21 46 5 11 93
 29 0 0 3 14 4 11 99
102.33 26.00 13.65 2.815
```

Métrique pour comparer deux vecteurs SIFT =
Distance L2 = distance Euclidienne

$$\mathrm{d}(\mathbf{p},\mathbf{q}) = \mathrm{d}(\mathbf{q},\mathbf{p}) = \sqrt{(q_1-p_1)^2+(q_2-p_2)^2+\cdots+(q_n-p_n)^2}$$

$$= \sqrt{\sum_{i=1}^{n}(q_i-p_i)^2}.$$

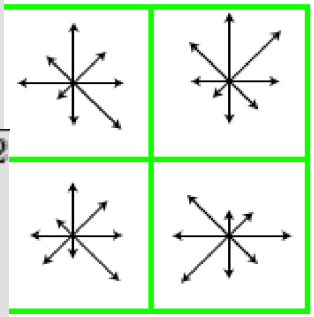

- Autres: SURF, BRIEF, Local Binary Pattern

```
 19 10 3 1 29 94 54 54
88.61 134.04 13.25 2.721
 27 56 20 6 9 21 12 17 33 120 114 6 4 8 8 0 41 106 23 9
 19 42 3 0 45 54 13 0 14 26 1 3 45 12 6 22 24 22 29 35
 61 52 8 1 35 92 55 23 120 106 0 0 16 24 5 35 92 4 0 0
 33 40 9 30 81 74 22 31 4 2 5 8 52 77 34 9 39 37 15 32
 120 38 3 0 5 17 28 120 41 5 19 10 7 32 89 63 34 27 4 0
 0 6 33 17 40 60 29 0 0 8 23 22 120 113 79 5 0 0 2 16
 9 21 120 58 0 1 10 3
```

- SIFT + some c

Les descripteurs audio les plus utilisés

Calculés sur segments fixes ou variables

- **MFCC** (Lowe, 2004), **dimension = 13** (valeurs float), L2

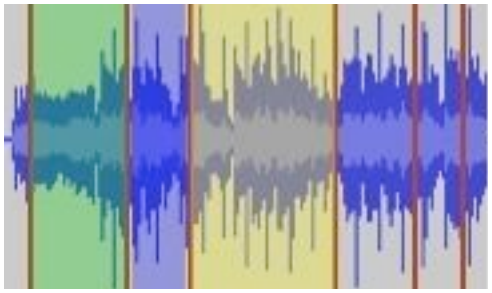

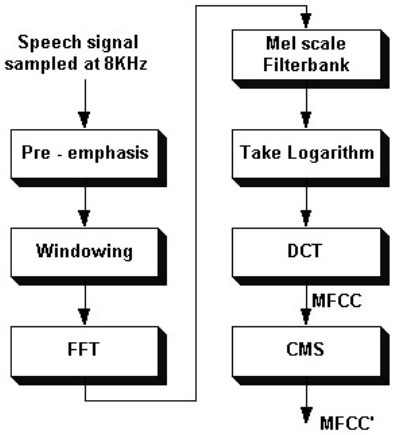

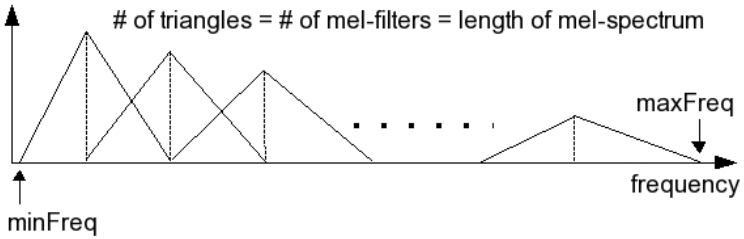

- **Autres**: Linear Predictor Coefficients, Line Spectral Frequency, Loudness coefficients, OBSI, etc.
- MFCC + many others available in **Yaafe**

Représentation vectorielle de documents textes

Documents et requêtes représentées par des vecteurs de fréquence d'apparition des mots

$$d_j = (w_{1,j}, w_{2,j}, \ldots, w_{t,j})$$
$$q = (w_{1,q}, w_{2,q}, \ldots, w_{t,q})$$

Taille du dictionnaire (nombre de mots possibles) = dimension de l'espace de description (jusqu'à plusieurs centaines de milliers)

Mesure de similarité = **Produit scalaire** ou **Cosine measure**

$$\mathbf{q}^\top.\mathbf{d} = \sum_{i=1}^{n} q_i.d_i = \|\mathbf{q}\| \,.\, \|\mathbf{d}\| \,.cos(\mathbf{q}, \mathbf{d})$$

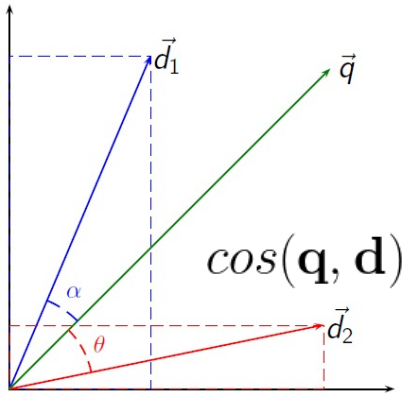

$$cos(\mathbf{q}, \mathbf{d}) = \frac{\mathbf{q}^\top.\mathbf{d}}{\|\mathbf{q}\| \,.\, \|\mathbf{d}\|}$$

NB: La grande majorité des composantes étant nulles, on utilise en pratique une représentation parcimonieurse des vecteurs, e.g:

q: (id_mot1, frequence_mot1) (id_mot2, frequence_mot2)

Un exemple de chaîne complète d'indexation et de recherche par le contenu

Pl@ntNet: un exemple de système réel de recherche par le contenu visuel

L'application mobile Pl@ntNet

iPhone

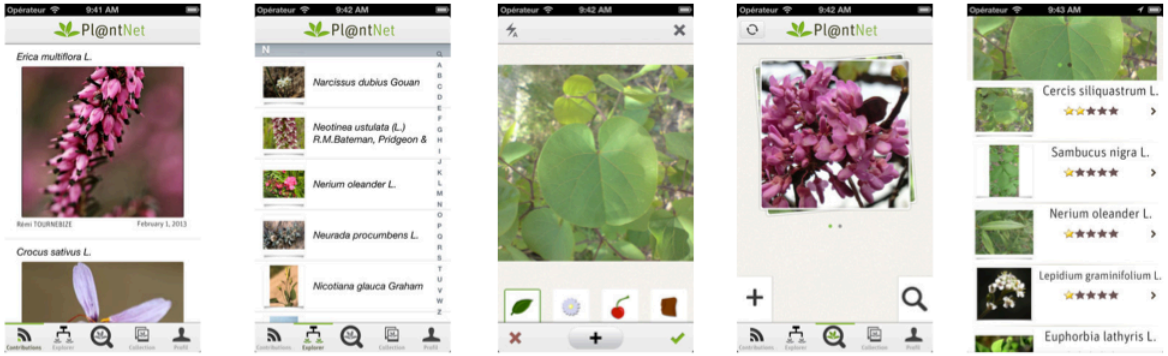

Pl@ntNet: un exemple de système réel de recherche par le contenu visuel

Indexation

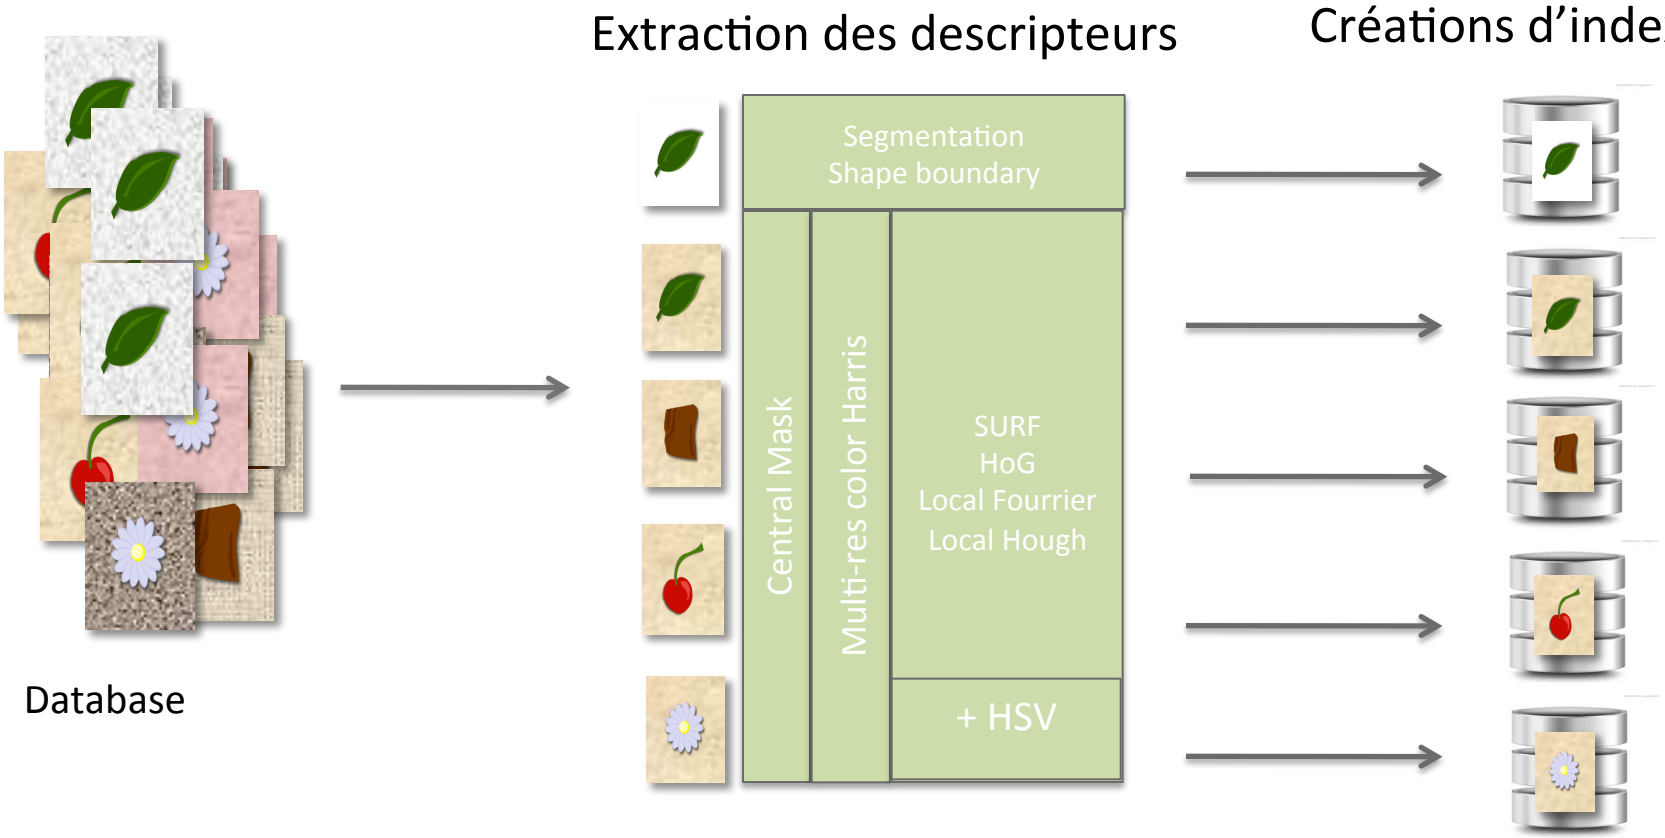

Pl@ntNet: un exemple de système réel de recherche par le contenu visuel

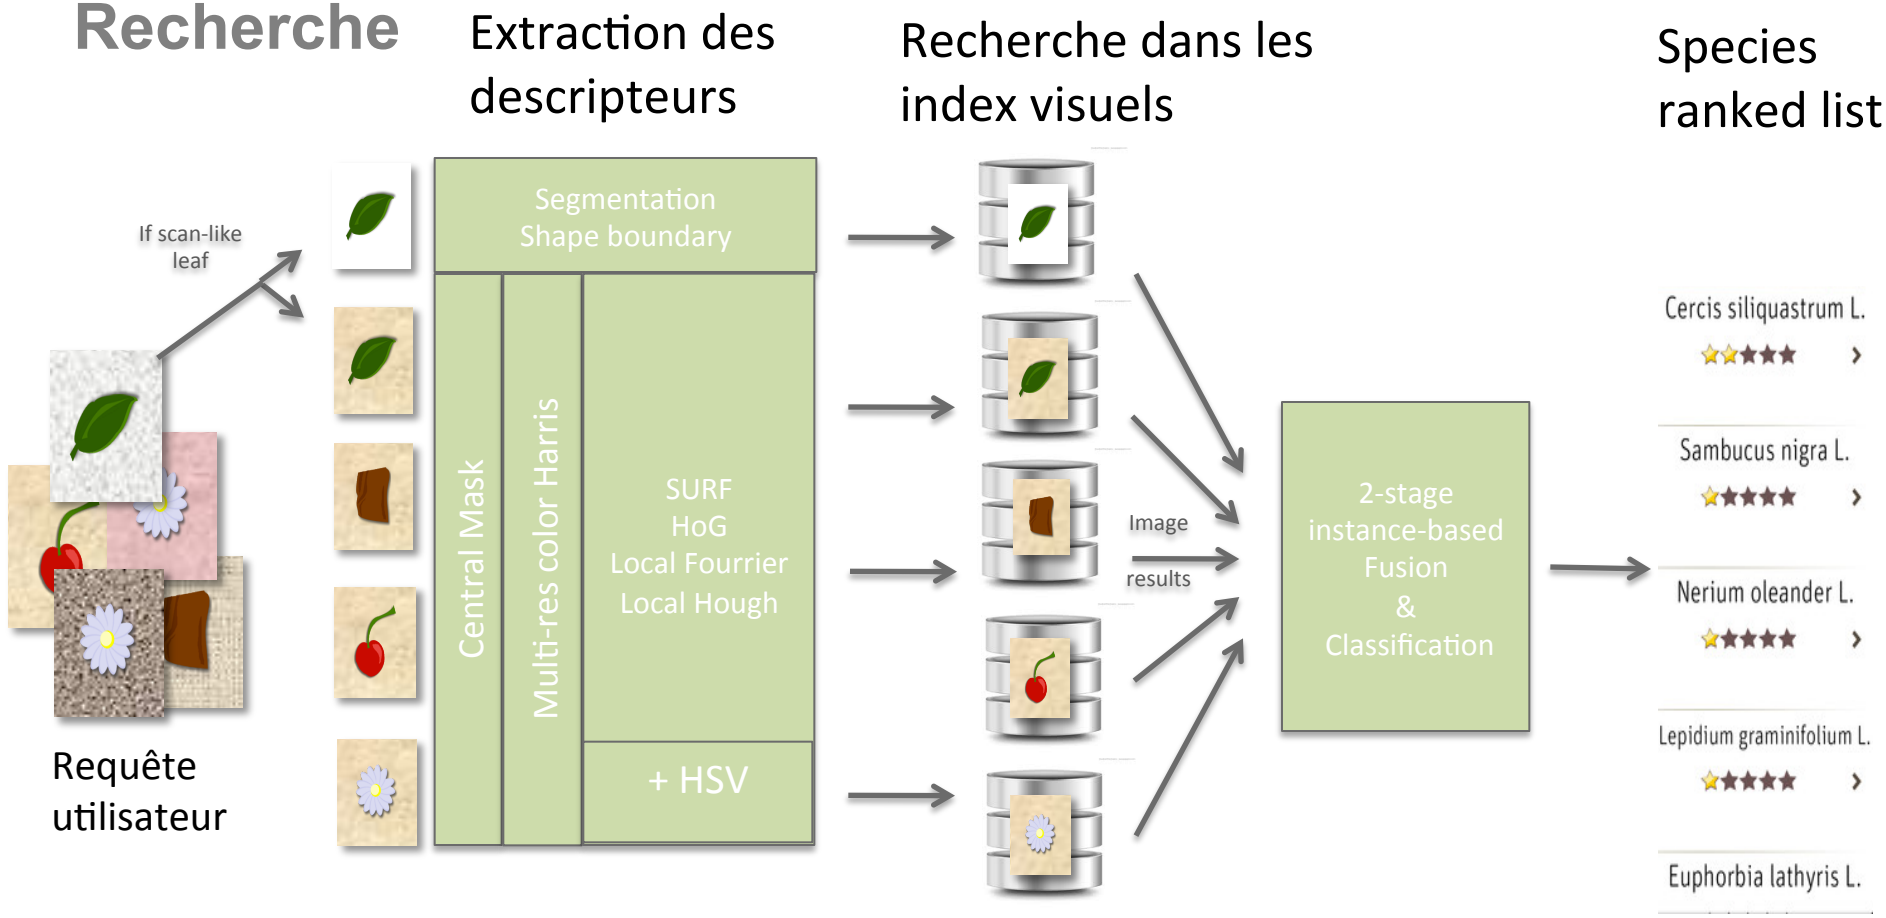

Pl@ntNet: un exemple de système réel de recherche par le contenu visuel

Recherche d'une image dans un index visuel (appariement)

1. Pour chaque descripteur local, on recherche les descripteurs les plus similaires dans la base

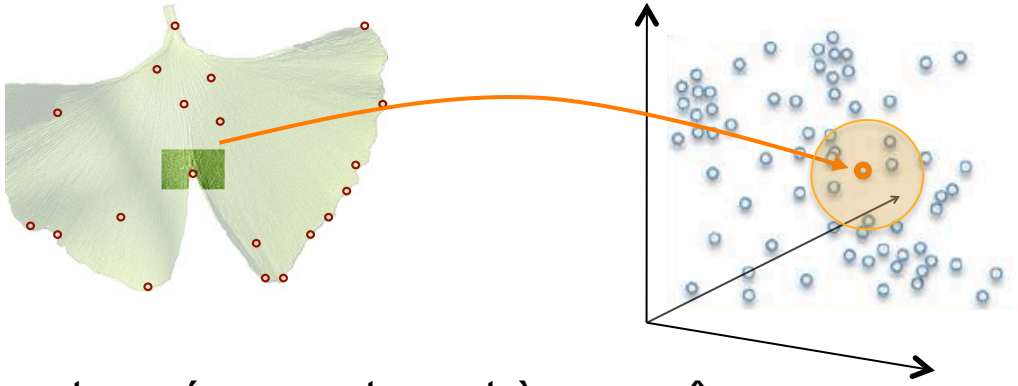

2. On regroupe les descripteurs retrouvés appartenant à une même image de la base
3. On compte le nombre de descripteurs retrouvés par image (= le nombre d'appariements)
4. On trie les images retrouvées par nombre d'appariements décroissants

Pl@ntNet: un exemple de système réel de recherche par le contenu visuel

Des listes d'images à la liste d'espèce

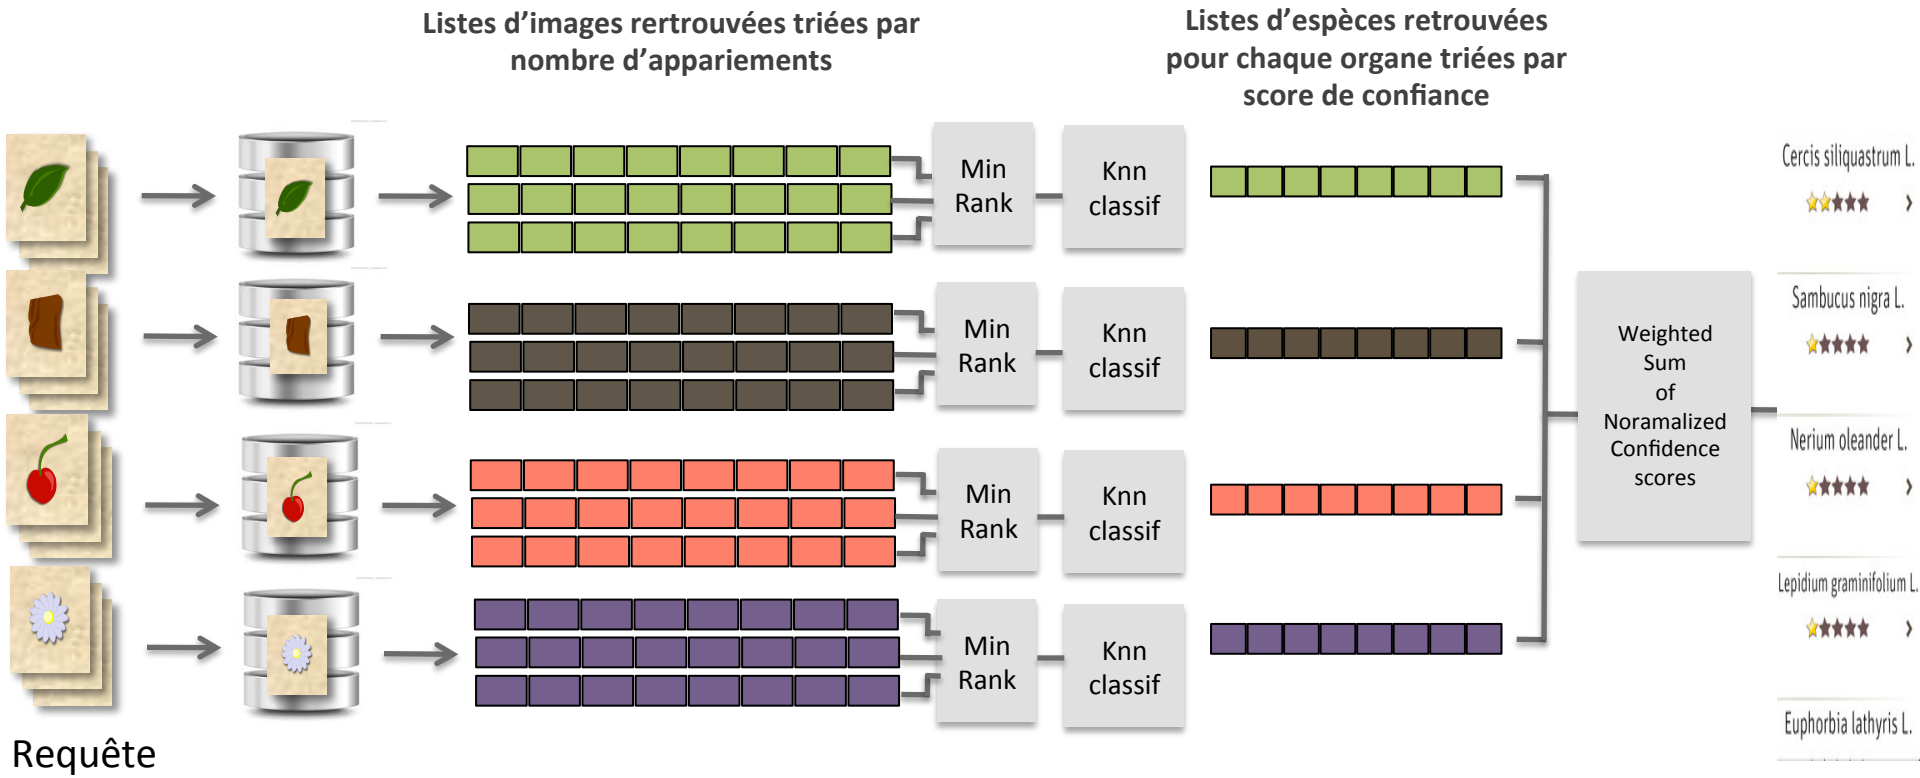

Pl@ntNet: un exemple de système réel de recherche par le contenu visuel

Enrichissement de la base: insertion des descripteurs dans les index (toutes les nuits, uniquement sur images validées)

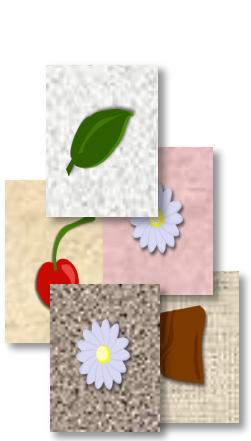

Requête utilisateur validée par le réseau d'utilisateurs

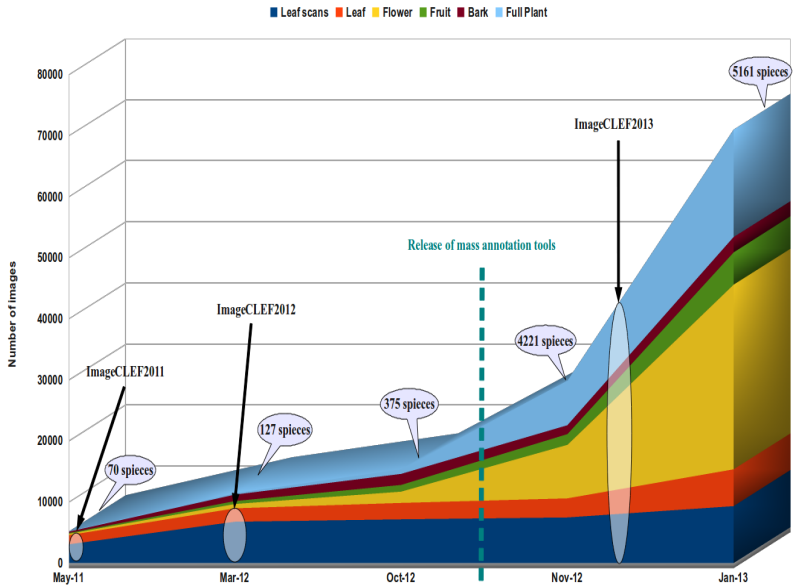

Méthode de recherche exhaustive et malédiction de la dimension

Le problème

Recherche du (ou des k) plus proches voisins

Espace de recherche: Espace $\mathbb{U}$, fonction similarité σ
Entrée: database $S = \{p_1, \ldots, p_n\} \subseteq \mathbb{U}$
Requête: $q \in \mathbb{U}$
Tâche: trouver $\text{argmax}_{p_i}\ \sigma(p_i, q)$

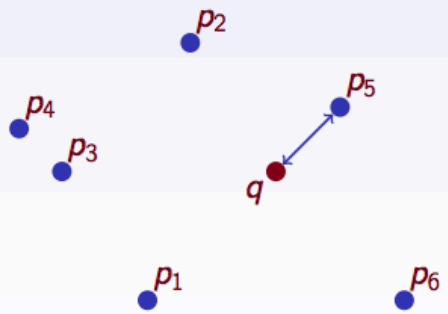

Exemple

→ Desc. SIFT, dim=128, L2

→ 100K images x 1000 SIFT
=
100M de vecteurs SIFT

Problème fondamental abordé depuis l'époque de Voronoi (1908)

Il n'existe pas de solution exacte de complexité sous-linéaire en particulier pour les grandes dimensions

La recherche exhaustive

1. **Principe: parcours exhaustif de tous les vecteurs de la base et calcul de toutes les distances à la requête**

```
for (int i=1; i<n ; i++) ComputeDistance(q,X[i]);
```

2. **Recherche des top-k dans la liste des distances**

- méthode naïve: on insère les éléments < i,dist[i]> dans un container (une liste de Map.Entry par exemple) et on utilise un sort

```
for (int i=1; i<n ; i++) {
        list.add(<i, d(q,X[i])>); //insertion du n-iéme élément
}

sort(list, comparator); //tri du container

for (int j=1; j<k ; j++)    knn.add(j,list.get(j)); //extraction des k premiers éléments
```

Problème = sort est un algorithme de complexité O(n log n) qui peut être trop coûteux pour une recherche temps réel

La recherche exhaustive

1. **Principe: parcours exhaustif de tous les vecteurs de la base et calcul de toutes les distances à la requête**

```
for (int i=1; i<n ; i++) ComputeDistance(q,X[i]);
```

2. **Recherche des top-k dans la liste des distances**

- méthode plus efficace: on met à jour progressivement les top-k en conservant la position et la distance du k-nn courant

```
dist_max_knn=MAX_DIST;
for (int i=1; i<n ; i++) {
        if (ComputeDistance(q,X[i]) < dist_max_knn) {   //si on a trouvé un meilleur voisin
            list.add(<i, d(q,X[i])>); //insertion dans la liste des knn
            [dist_max_knn,index_max_knn]=SearchFurthestElementInList(list); // cherche nouveau max O(k)
            if (i>k) list.remove(index_max_knn);//retire nouveau  max
        }
}
```

La complexité est O(n.k) dans le pire des cas mais en pratique beaucoup plus rapide car de moins en moins de meilleurs voisins

Problème = ne marche pas lorsque k est trop grand k>>log(n)

La recherche exhaustive

1. Parcours exhaustif de tous les vecteurs de la base et calcul de toutes les distances à la requête

```
for (int i=1; i<n ; i++) dist[i]=d(q,X[i]);
```

2. Recherche des top-k dans la liste des distances

   - méthode pour k grand (>>log N): on utilise un Max heap ou une PriorityQueue

```
public class PriorityQueue<E>
extends AbstractQueue<E>
implements Serializable
```

An unbounded priority queue based on a priority heap. The elements of the priority queue are ordered according to their natural ordering, or by a `Comparator` provided at queue construction time, depending on which constructor is used. A priority queue does not permit `null` elements. A priority queue relying on natural ordering also does not permit insertion of non-comparable objects (doing so may result in `ClassCastException`).

→ provides O(log(n)) time for the enqueing and dequeing methods: add & poll;

La recherche exhaustive

1. Parcours exhaustif de tous les vecteurs de la base et calcul de toutes les distances à la requête

```
for (int i=1; i<n ; i++) dist[i]=d(q,X[i]);
```

2. Recherche des top-k dans la liste des distances

- méthode pour k grand (>>log N): on utilise un Max heap ou une PriorityQueue

```
PriorityQueue<DistElt> TopKqueue = new PriorityQueue<DistElt>();
for (int i=1; i<n ; i++)  {
      TopKqueue.add(new DistElt(i, ComputeDistance(q,X[i]) ) );
      if (i>k) TopKqueue.poll();
}
```

Complexité **O(n log k)**

Les structures d'indexation métriques et multi-dimensionelles (1980-2000)

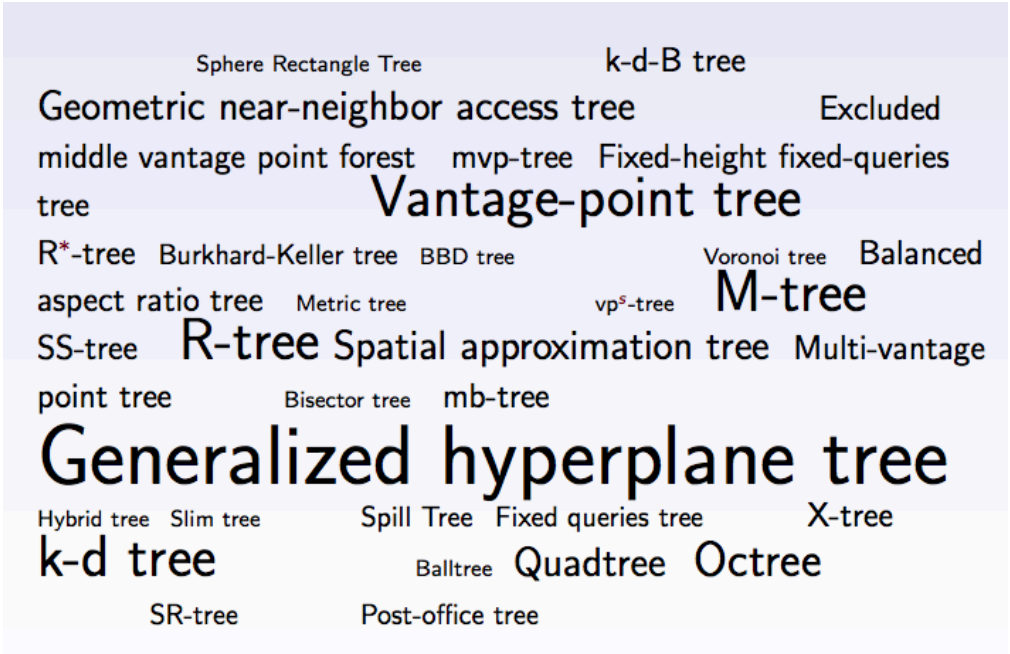

R-tree

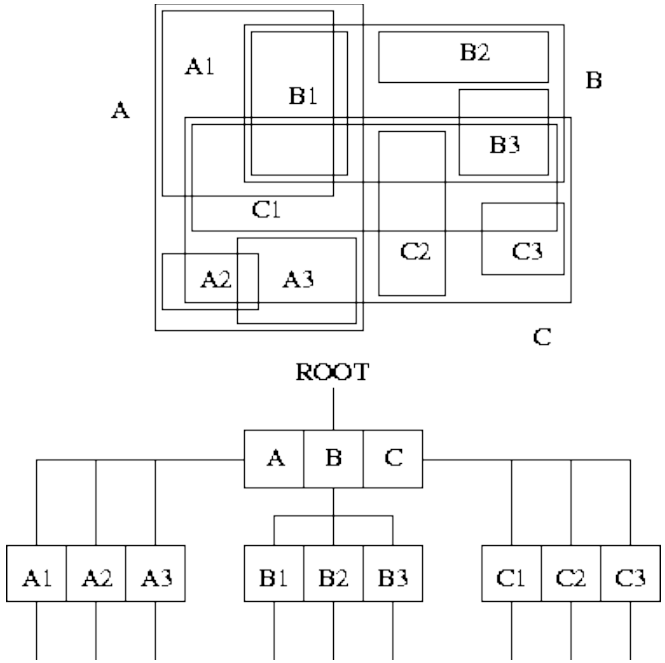

Weber a montré en 1998 qu'elles étaient moins efficaces que la recherche exhaustive pour dim > 16 (environ)

Curse of dimensionality (malédiction de la dimensionalité)

Lorsque la dimension de l'espace devient très grande il faut parcourir toutes les cellules de la partition pour être sûr de retrouver les k-nn exacts

- Assume 5000 points uniformly distributed in the unit hypercube and we want to apply 5-nn. Suppose our query point is at the origin.
  - In 1-dimension, we must go a distance of 5/5000 = 0.001 on the average to capture 5 nearest neighbors
  - In 2 dimensions, we must go $\sqrt{0.001}$ to get a square that contains 0.001 of the volume.
  - In d dimensions, we must go $(0.001)^{1/d}$

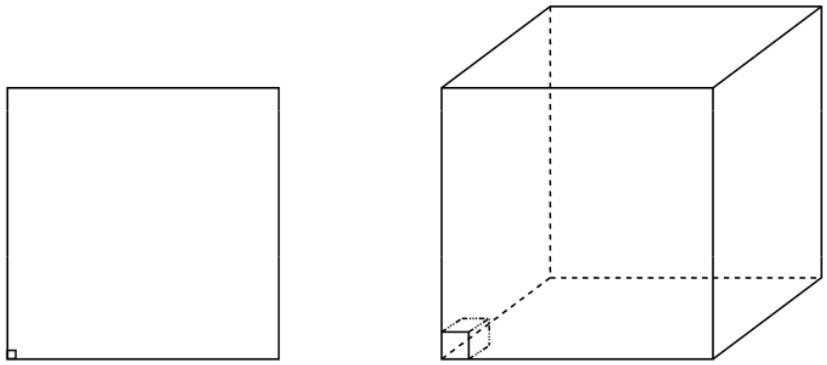

Curse of dimensionality (malédiction de la dimensionalité)

La quantification binaire illustre bien l'aspect combinatoire du problème en grande dimension

$[0.1,0.6,0.8,...,0.9,0.2]$ → $[0,1,1,...,1,0]$ →

d d

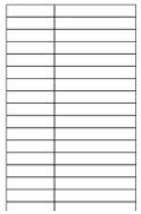

Recherche à un rayon prés **r ≈ α.d** (en nb de bits dans l'espace d'arrivée)

Nb de cases à visiter n(d) = $C_d^r = \frac{d!}{r!(d-r)!}$

$\frac{n(d+1)}{n(d)} > 1$ et $\frac{n(d+1)}{n(d)} \approx \frac{1}{(1-\alpha)}$ → n(d): suite géométrique et donc une croissance exponentielle

Exemple: d=1000, alpha=0.05 → **n(d)=9.46e+84**

En pratique on utilise des méthodes approximatives et des heuristiques

Changements d'espace

- techniques de réduction de la dimension

Algorithmes de regroupement

Compression/quantification (avec perte)

- Hachage
- Hamming embedding

Algorithmes de recherche approximatifs

- à epsilon près
- statistiques
- heuristiques

Les changements d’espace

Techniques de réduction de la dimension

Analyse en composantes principales
Projections aléatoires

} Les deux plus utilisées

Autres techniques linéaires:
Analyse en composante indépendantes
Multilinear subspace learning
Latent semantic analysis

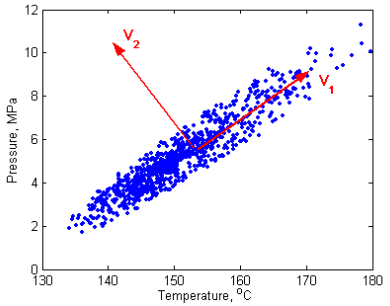

Techniques non linéaires:
Isomap
Kernel PCA
Autoencoder (réseaux de neurones)
Manifold learning
…

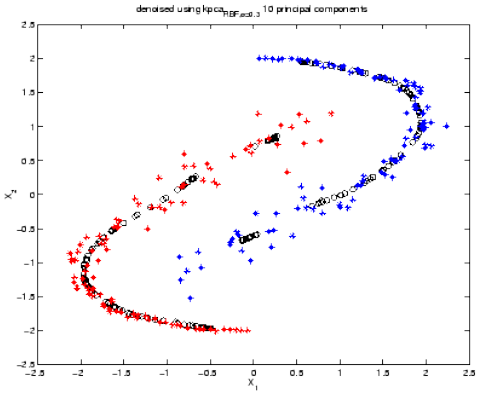

Analyse en composantes principales

$$y = Ax$$

$y \in R^k$ $\qquad$ $x \in R^d$

A = matrice de projection d x k

Constituée des k vecteurs propres de $Cov(X) = X^T X$

ayant les valeurs propres les plus grandes

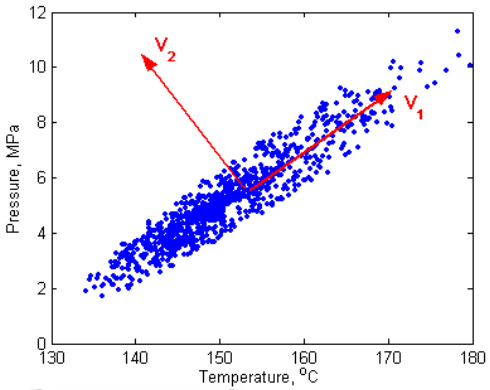

Intérêt:

Rotation puis conservation des axes de variance maximale

+

Décorrélation (la nouvelle matrice de corrélation est diagonale)

Analyse en composantes principales

$$y = Ax$$

$y \in R^k$ $x \in R^d$

A = matrice d x k

Méthode de calcul de A:

1) Centrage des données X ← X-μ_X

μ_X=centre de gravité des données

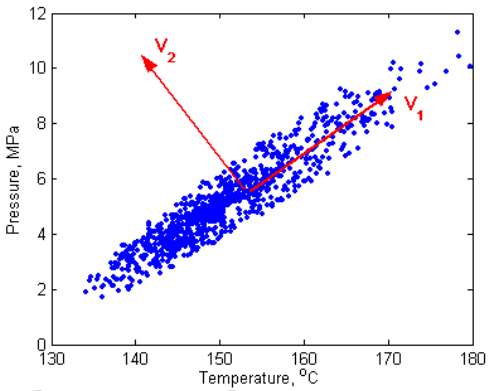

Analyse en composantes principales

$$y = Ax$$

$y \in R^k$ $x \in R^d$

A = matrice d x k

Méthode de calcul de A:

2) Calcul de la matrice de covariance sur un échantillon de n vecteurs → $O(n^2.d^2)$

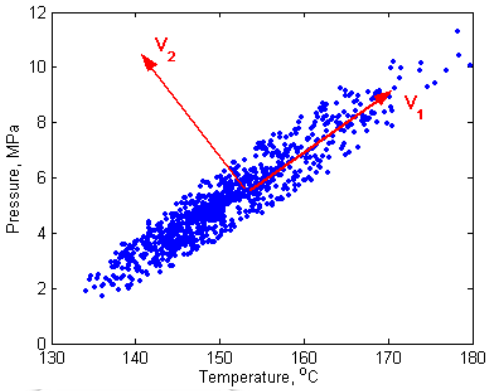

$$Cov = X^T X$$

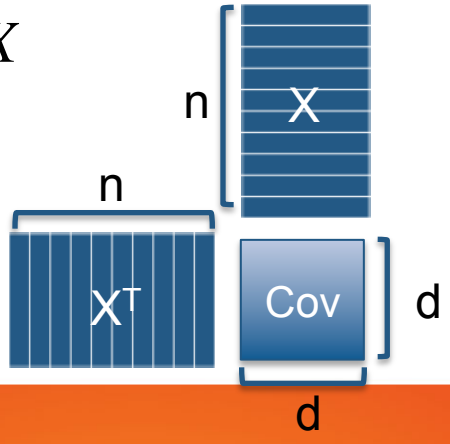

$$Cov(i,j) = \sigma^2_{i,j}$$

$$Cov(i,i) = \sigma^2_i$$

Analyse en composantes principales

$$y = Ax$$

$y \in R^k$ $x \in R^d$

A = matrice d x k

Méthode de calcul de A:

3) Diagonalisation de la matrice de covariance

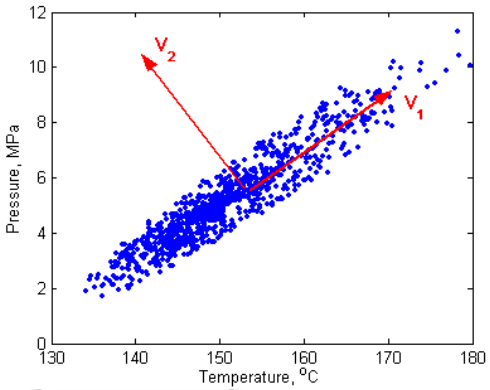

$$Cov = P^T \Delta P$$

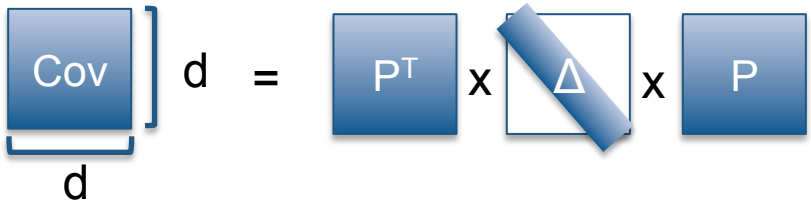

Analyse en composantes principales

$$y = Ax$$

$y \in R^k$ $x \in R^d$

A = matrice d x k

Méthode de calcul de A:

4) On ne conserve que les k vecteurs propres ayant les valeurs propres les plus élevées

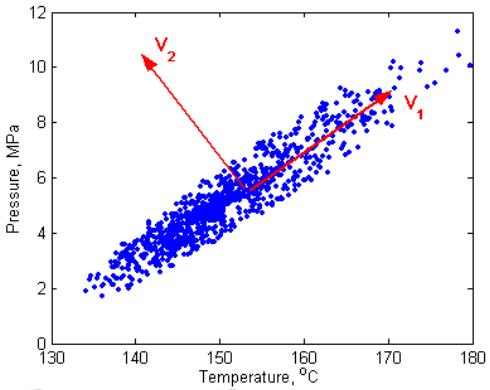

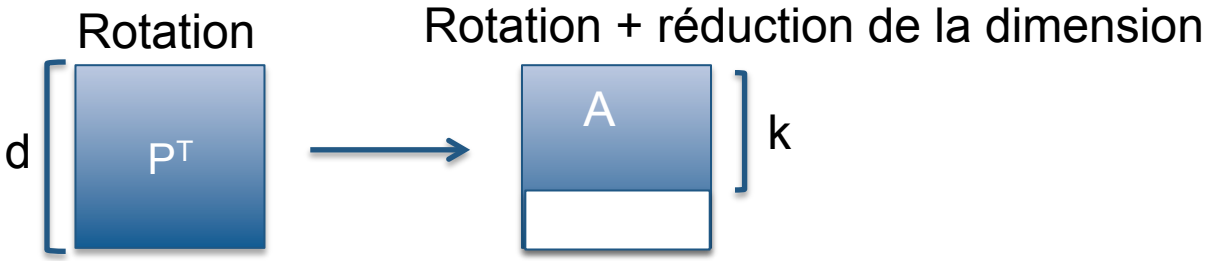

Projections aléatoires

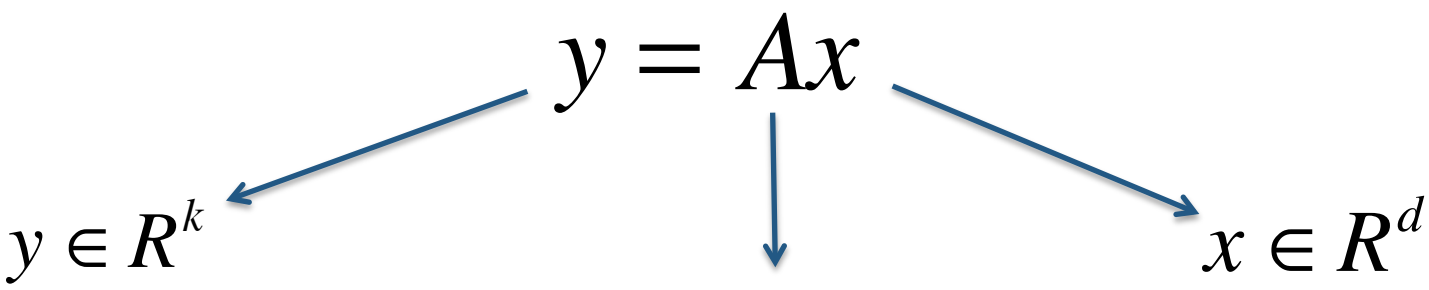

$A = randn(d,k)$

= i.i.d sampled from Gaussian N(0,1)

Un corollaire du lemme de Johnson-Lindenstrauss affirme qu'une telle transformation tend à préserver le produit scalaire

Corollary 2.1. *Let $u, v \in \mathbb{R}^d$ and that $\|u\| \leq 1$ and $\|v\| \leq 1$. Let $f = \frac{1}{\sqrt{k}} Ax$ where A is a $k \times d$ matrix, where each entry is sampled i.i.d from a Gaussian $N(0,1)$ (or from $U(-1,1)$). Then,*

$$\Pr(|u \cdot v - f(u) \cdot f(v)| \geq \epsilon) \leq 4e^{-(\epsilon^2 - \epsilon^3)k/4}$$

Projections aléatoires

$$y = Ax$$

$y \in R^k$ $x \in R^d$

$$A = randn(d,k)$$

= i.i.d sampled from Gaussian N(0,1)

Intuitivement, c'est le jeu de la roue. La probabilité que l'axe tiré aléatoirement sépare q et v est fonction de leur angle

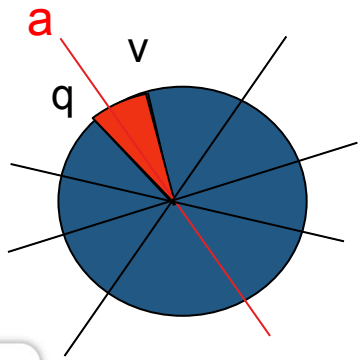

$$\Pr\left[h_w(q) \neq h_w(v)\right]_w = angle(q,v)/\pi = \frac{1}{\pi}\cos^{-1}\left(q^T v\right)$$

Comparaison

$$y = Ax$$

ACP

Projection aléatoire

Décorrélation = réduction de la dimension plus effective

Premières composantes très bonnes

Calcul plus coûteux de A et dépendant des données

C'est un apprentissage avec des problèmes possibles de généralisation à d'autres données

Universalité = aucune dépendance aux données

Pas de calcul de A (tables)

Pas de composante a priori plus utile que d'autres

Composantes non décorrélées = réduction moins effective

Combiner projections aléatoires et orthogonalisation

$$y = Ax$$

$y \in R^k$ $x \in R^d$

A = matrice d x k orthoganale générée aléatoirement

Procédure de construction de **A**:

1. Matrice kxd aléatoire Gaussienne: **G**
2. Factorisation QR de G:

Matrice orthogonale

$$Q^T Q = I$$

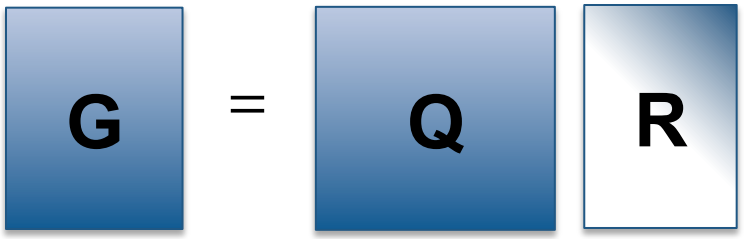

3. Conserver les k premières lignes de Q

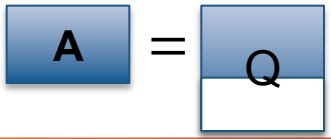

Les méthodes de partitionnement et de quantification

Quantification scalaire binaire

La plus simple = binarisation de chaque composante du vecteur

$$z_j = sign(x_j)$$

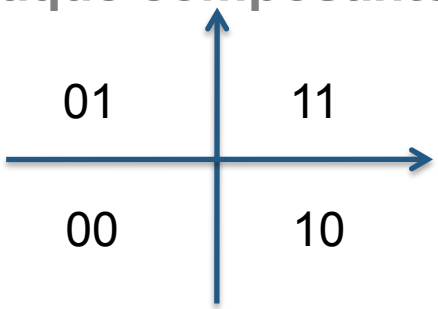

Utilisée en générale après centrage et normalisation des données ou changement d'espace

Ex1, après une ACP:

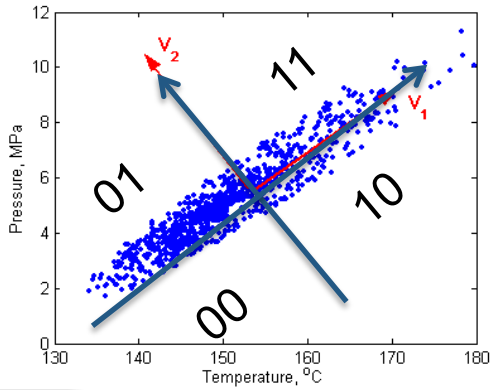

Ex2, après projections aléatoires

$$z = sign(Ax + b)$$

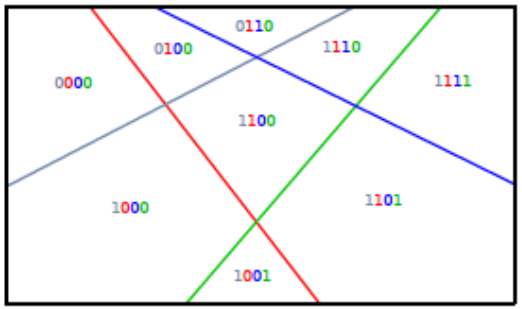

= LSH (Locality Sensitive Hashing)

Quantification scalaire binaire

Avantage: produit des hash codes binaires très compactes et très efficaces pour le stockage, l'adressage ou le calcul de distances

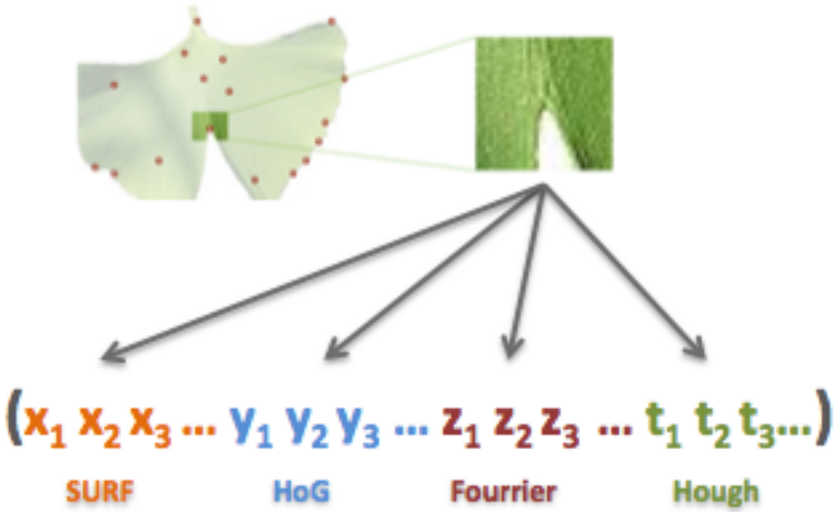

Changement d'espace
+
Binarisation

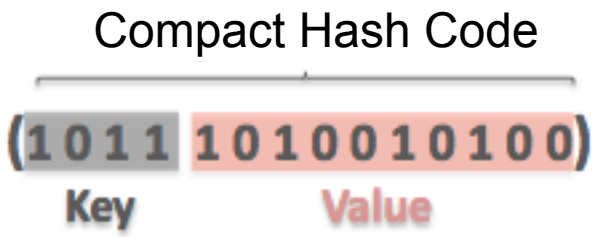

Table de hâchage
(=liste inversée):

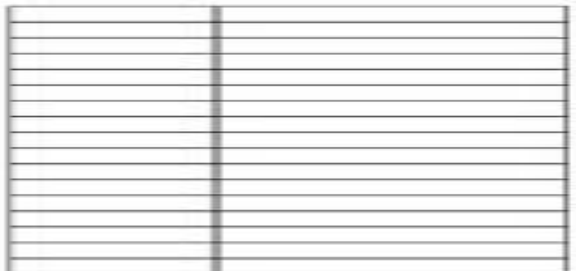

Quantification scalaire binaire

Avantage: produit des hash codes binaires très compactes et très efficaces pour le stockage, l'adressage ou le calcul de distances

Hamming embedding: on remplace les distances dans l'espace vectoriel d'origine par une distance de Hamming dans l'espace binarisé d'arrivée

$d(q,v) \rightarrow d_H(z(q),z(v))$

z(q) = 1 hash code = [0 1 0 1 0 1 1 0 …0 0 1 0]

⊕

z(v) = 1 hash code = [1 0 1 1 1 1 0 1 …0 1 0 0]

On verra que dans certains cas, $d_H(z(q),z(v))$ converge vers $d(q,v)$ lorsqu'on augmente le nombre de bits

La distance de Hamming peut-être de 10 à 100 fois plus rapide qu'une distance naïve dans l'espace d'origine

Quantification scalaire binaire

Avantage: produit des hash codes binaires très compactes et très efficaces pour le stockage, l'adressage ou le calcul de distances

1. Nombreuses méthodes très efficaces de calcul de la distance de Hamming

- Utilisation de Look-Up Tables (LUT): typiquement par blocs de 8 ou 16 bits

$$d_H(z(q),z(v)) = \sum d_H(z_i^8(q), z_i^8(v))$$

Chaque bloc n'a que 2^8 valeurs possibles pour une requête q donnée. Ces valeurs peuvent être pré-calculées et stockées dans une table dont la clé est le hash code $z_i^8(v)$

- Instructions assembleurs, e.g. SSE pop-count compte le nombre de bits à 1 de manière extrêmement efficace

$$d_H(z(q),z(v)) = POPCNT(NOR(z(q),z(v)))$$

Quantification scalaire binaire

Avantage: produit des hash codes binaires très compactes et très efficaces pour le stockage, l'adressage ou le calcul de distances

2. Données plus compactes = moins de sorties de cache

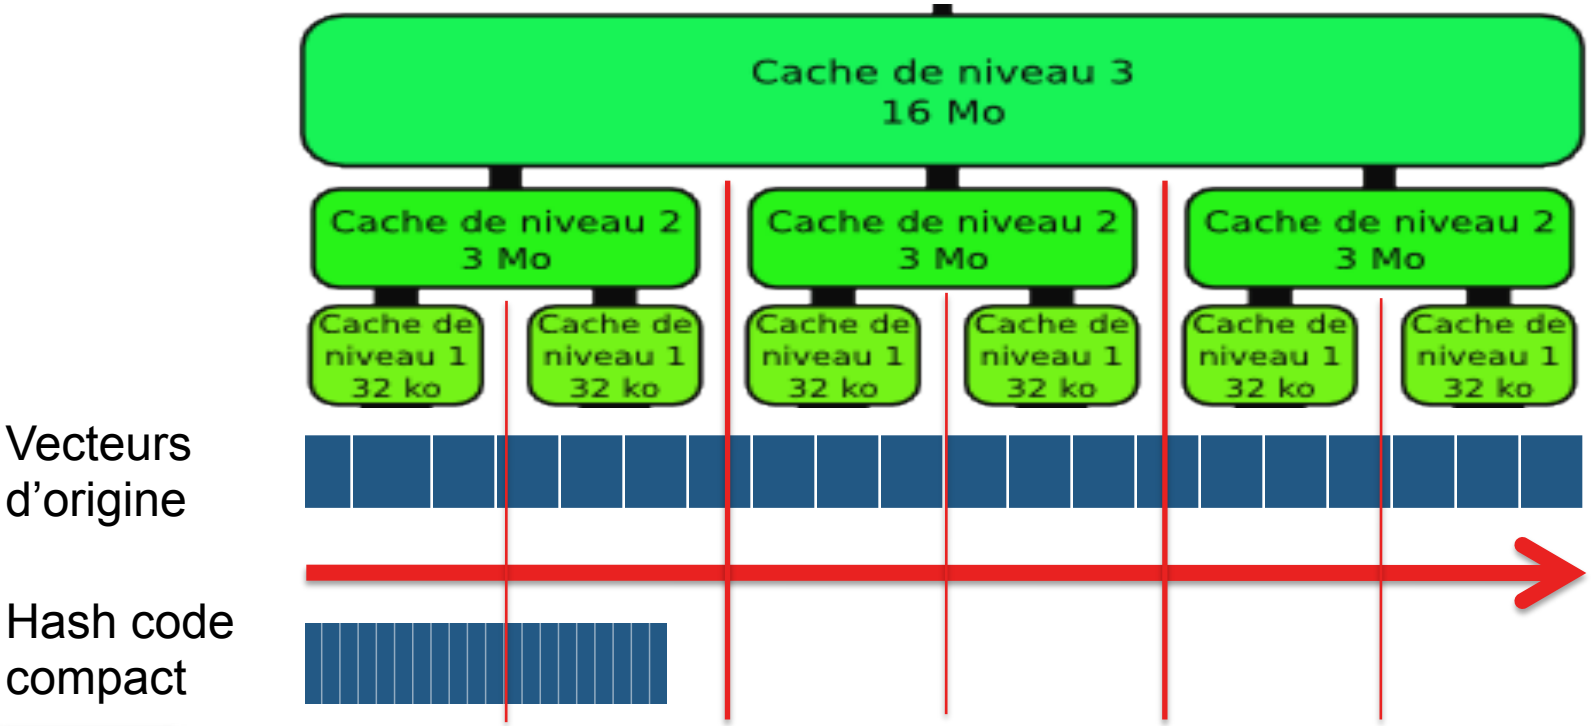

La recherche exhaustive dans le cas binarisé

Il n'y a que **d valeurs possibles pour la distance** (d bits max diffèrent entre deux hash codes). La distance peux donc servir de clé dans une multiMap:

```
MultiMap match_map = new MultiHashMap();
for (i=1; i<n ; i++)  match_map.put(ComputeDistance(q,X[i]), i);//rempli la MultiMap O(n)

dist=0; nb_nn=0;
While (nb_nn<k) {
        nb_nn+=match_map .get(m)); // accède aux éléments par distance croissante
        dist++;
}
```

Complexité linéaire O(n+d)≈O(n) meilleure que O(n log n), O(n.k), O(n log k)

Grilles et lattices

Avantage: Les mêmes que quantification scalaire binaire mais avec une erreur de quantification qui peut être plus faible

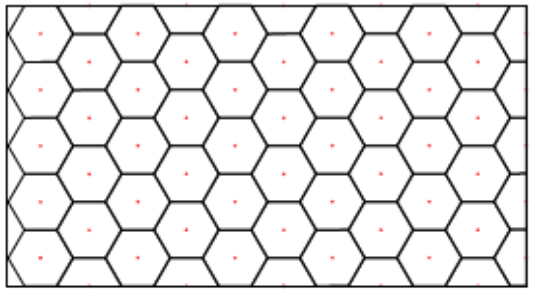

FIGURE 2.2 – Exemple d'un treillis hexagonal

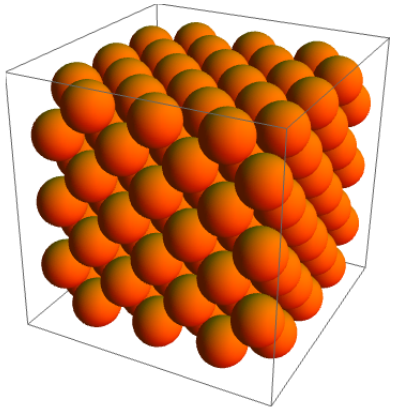

Leech lattices

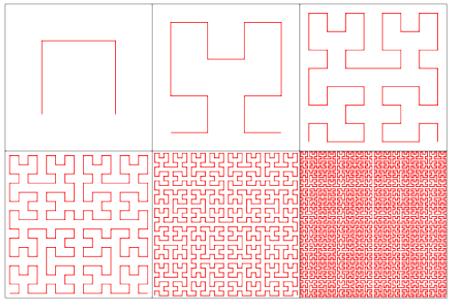

Space-filling curves

Inconvénients: Temps d'encodage peut être beaucoup plus long & la gain sur l'erreur de quantification dépend des données et peut être faible au final

Les méthodes de partitionnement par regroupement de données (clustering)

Contrairement aux méthodes de quantification scalaires ou vectorielles vues précédemment, le partitionnement dépend des données

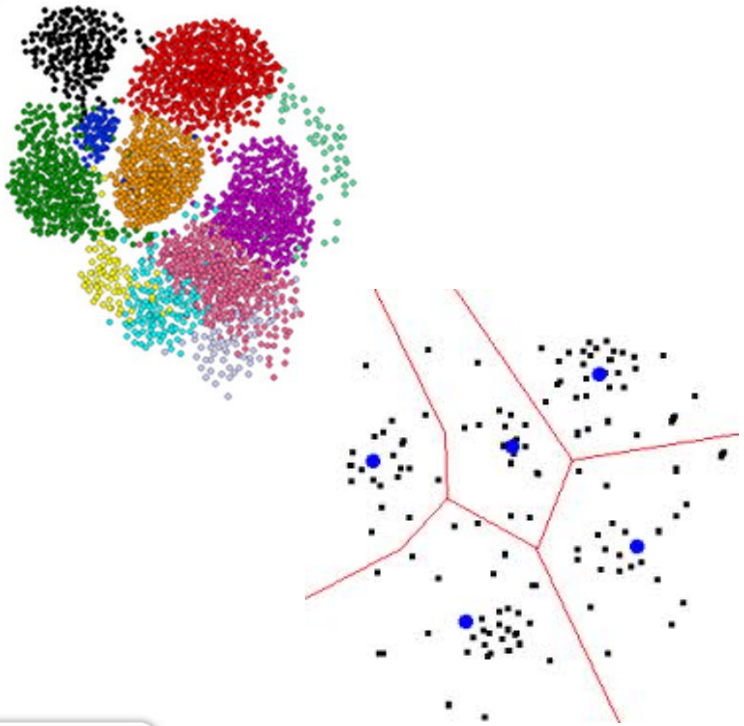

Des centaines de méthodes de clustering dans la littérature:

- Avec ou sans recouvrement
- Nombre de cluster fixes ou non
- Espace euclidien ou non
- Approches hiérarchiques ou non
- Approches probabilistes ou non
- Semi-supervisées (pair-wise constraints)
- Complexité

Un des problèmes les plus transversaux de tout l'informatique

Les méthodes de partitionnement par regroupement de données (clustering)

Algo le plus utilisée en recherche d'information par le contenu = k-means

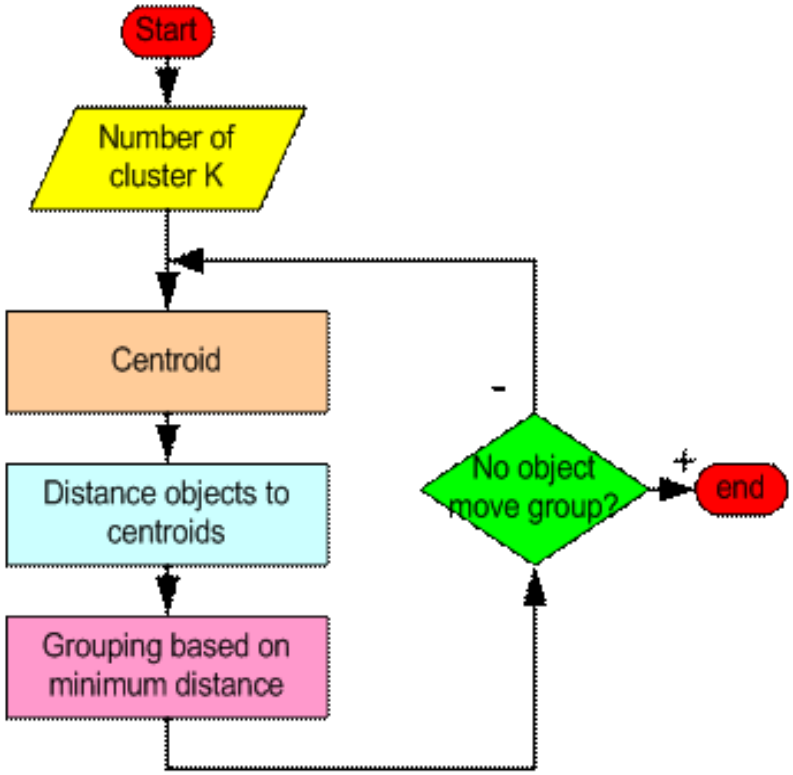

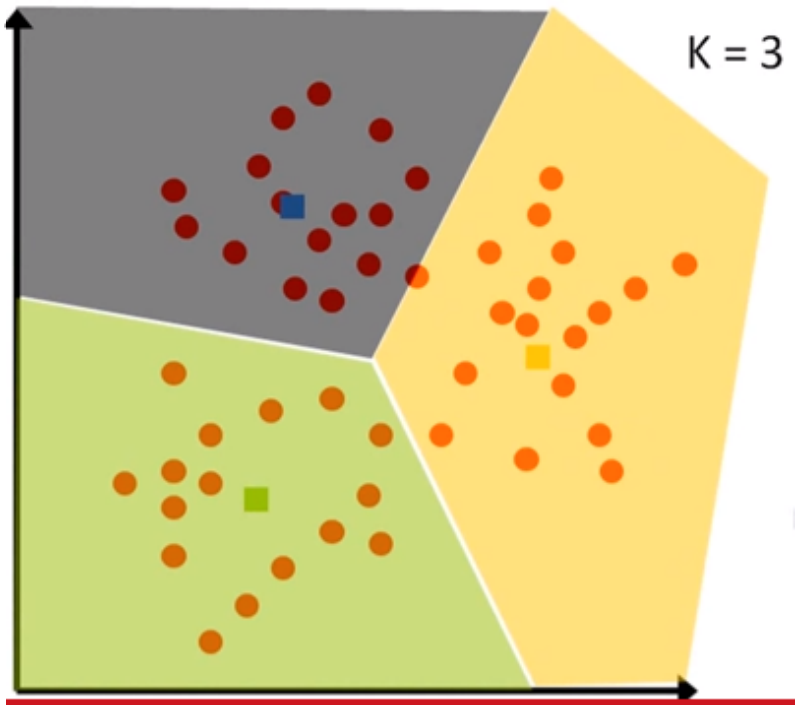

Les méthodes de partitionnement par regroupement de données (clustering)

Algo le plus utilisée en recherche d'information par le contenu = k-means

Intérêts:

- Adaptibilité aux données
- Minimisation de l'erreur de quantification L2
- Complexité d'apprentissage raisonable O(k.N)
- Contrôle de la taille de la partition

Inconvénients:

- Temps d'encodage O(k) devient problématique lorsque k est grand
- Utile pour partitionner les données mais pas pour compresser finement (pas assez d'information !!)

Les méthodes de partitionnement par regroupement de données (clustering)

K-means énormément utilisé pour partitionner les espaces de descripteurs visuels locaux

On parle de **mots visuels** pour qualifier les partitions produites

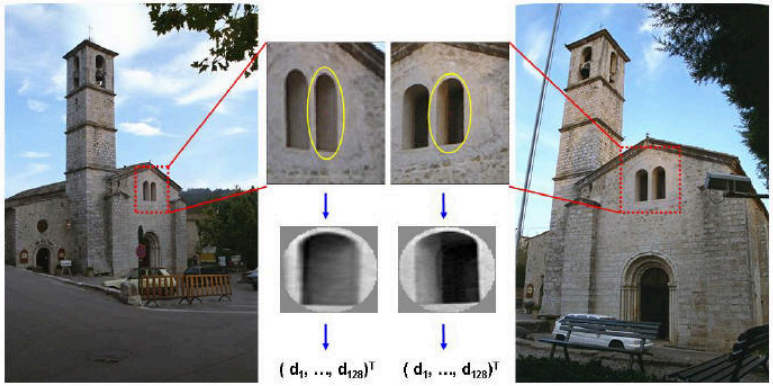

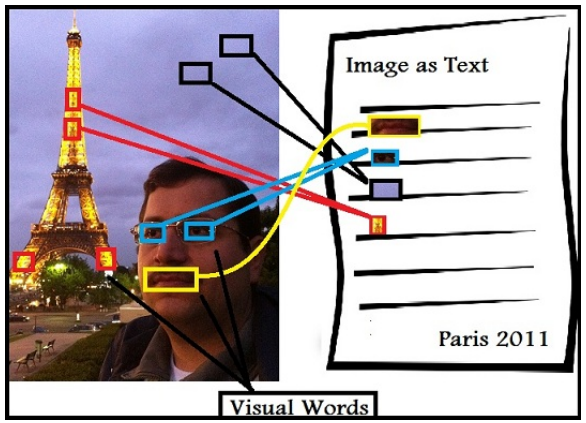

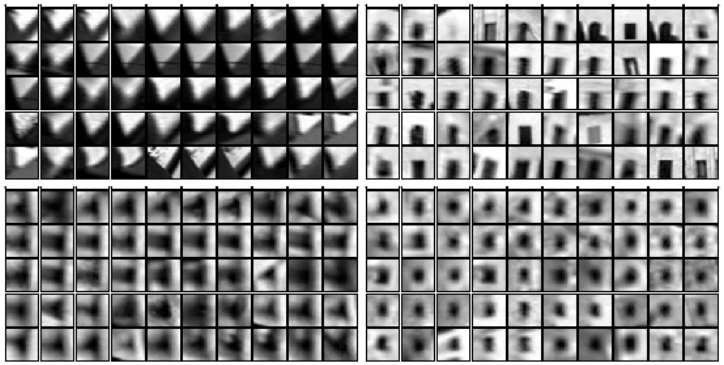

Les méthodes de partitionnement par regroupement de données (clustering)

K-means énormément utilisé pour partitionner les espaces de descripteurs visuels locaux

Une image = un **sac de mots visuels** par analogie au texte

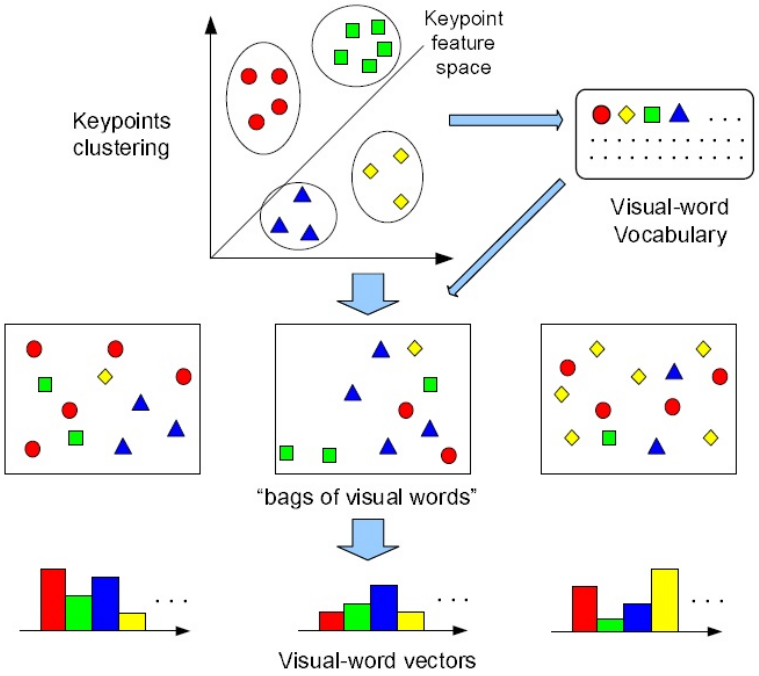

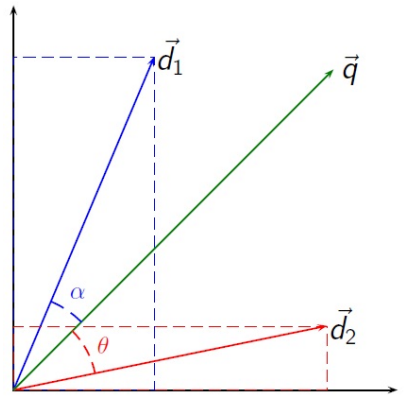

$$d_j = (w_{1,j}, w_{2,j}, \ldots, w_{t,j})$$
$$q = (w_{1,q}, w_{2,q}, \ldots, w_{t,q})$$

Les méthodes de partitionnement par regroupement de données (clustering)

Expectation Maximisation et mixtures de gaussiennes beaucoup utilisées en audio

Même principe itératif que k-means mais on estime les paramètres d'une gaussienne multi-dimensionelles au lieu de uniquement les coordonnées du centroïd

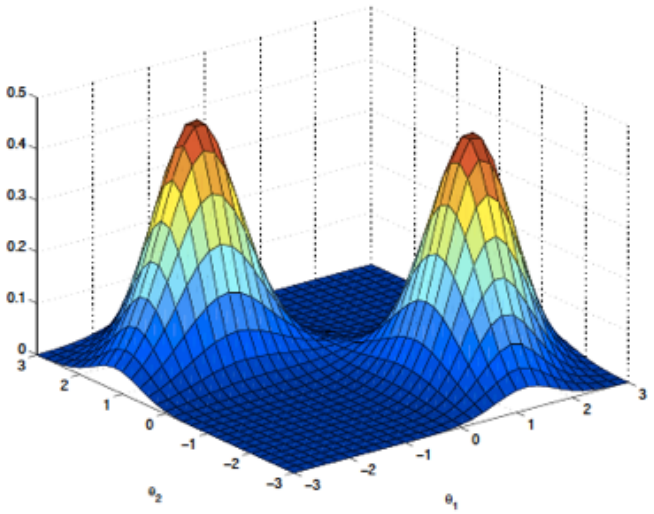

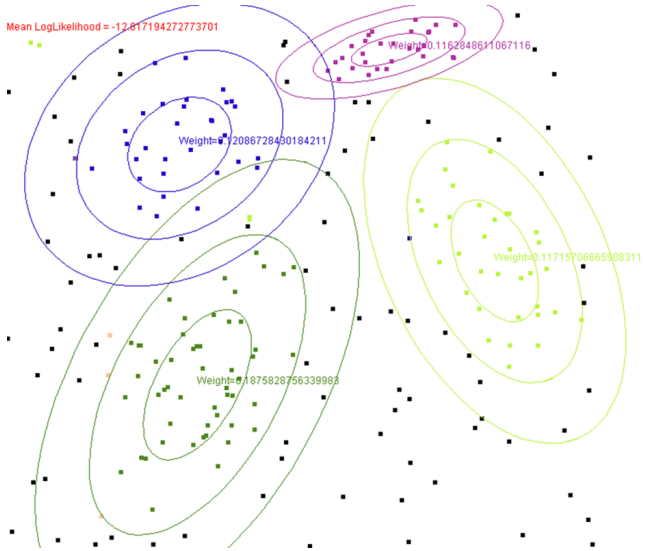

Les méthodes de partitionnement par regroupement de données (clustering)

Expectation Maximisation et mixtures de gaussiennes beaucoup utilisées en audio

Modèle beaucoup plus fin des données (idéale pour reconnaissance de locuteurs, speech-to-text, etc.), mais plus couteux pour indexation, compression, etc.

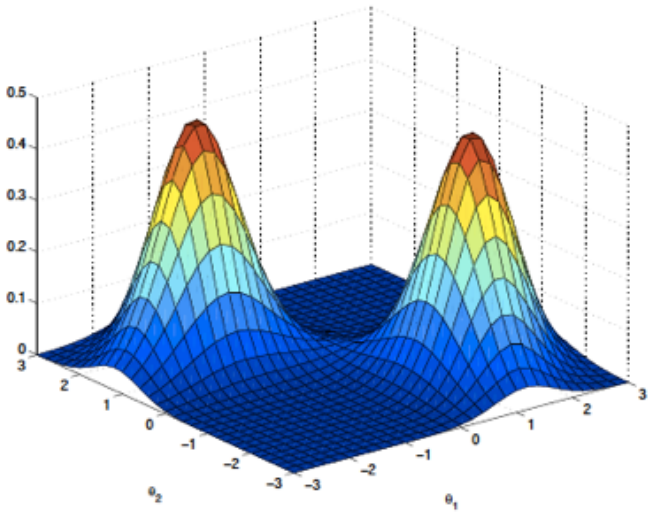

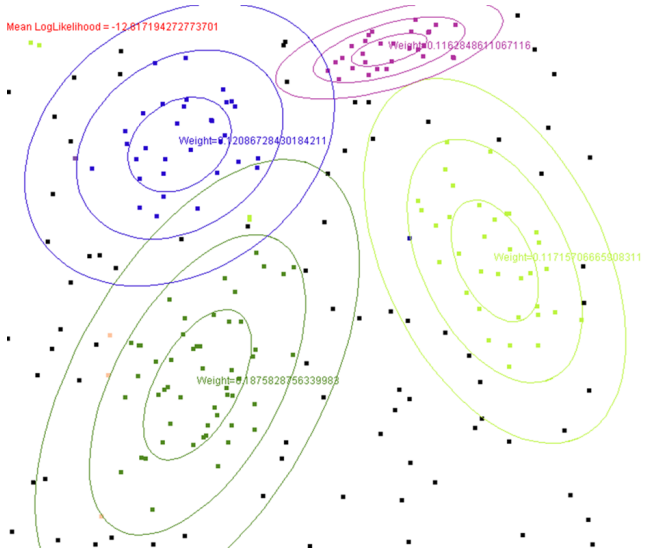

Les méthodes de partitionnement hiérarchiques

De nombreuses méthodes à base d'arbres existent mais la plupart ne sont pas utilisés pour la recherche par le contenu à cause de la malédiction de la dimension

Quad-tree: 2^d new buckets at each split !!

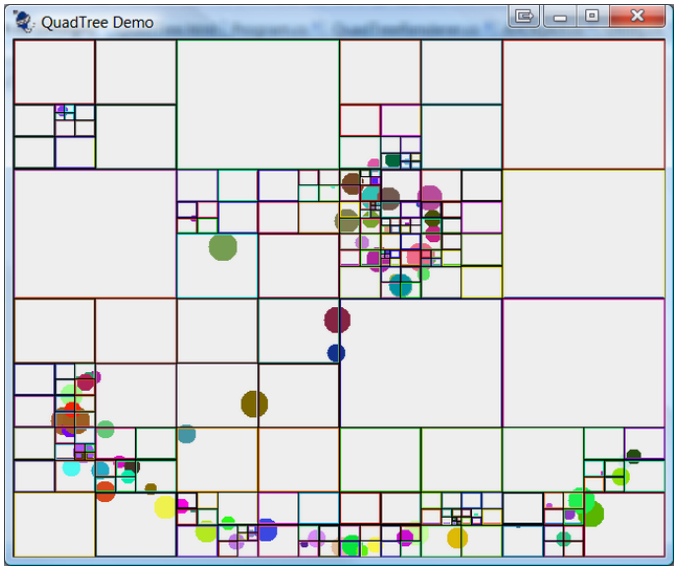

R-tree: Bounding box rectangulaires tendent à couvrir tout l'espace lorsque d est très grand

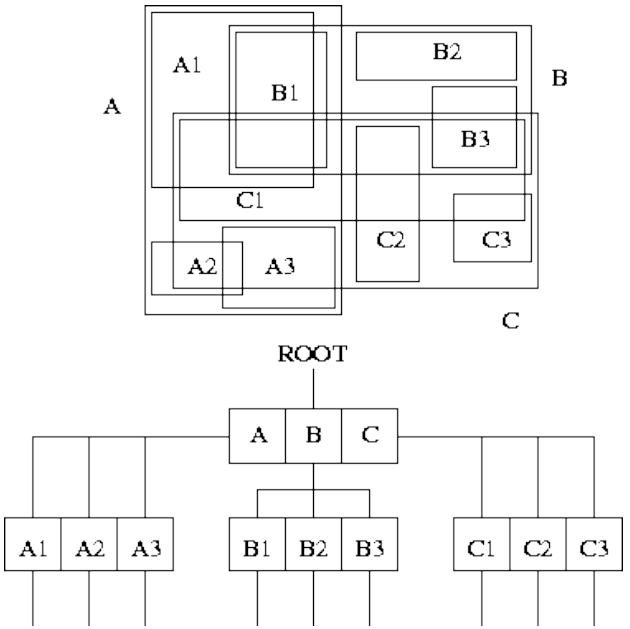

Les méthodes de partitionnement hiérarchiques

Le M-tree (Metric Tree) est encore utilisé dans certaines applications de recherche d'information par le contenu

Intérêt: Le M-tree utilise uniquement des points pivots et des distances à ces points pour partitionner les données. On peux indéxer n'importe quels objets (même non vectoriel) associés à une métrique respectant l'inégalité triangulaire

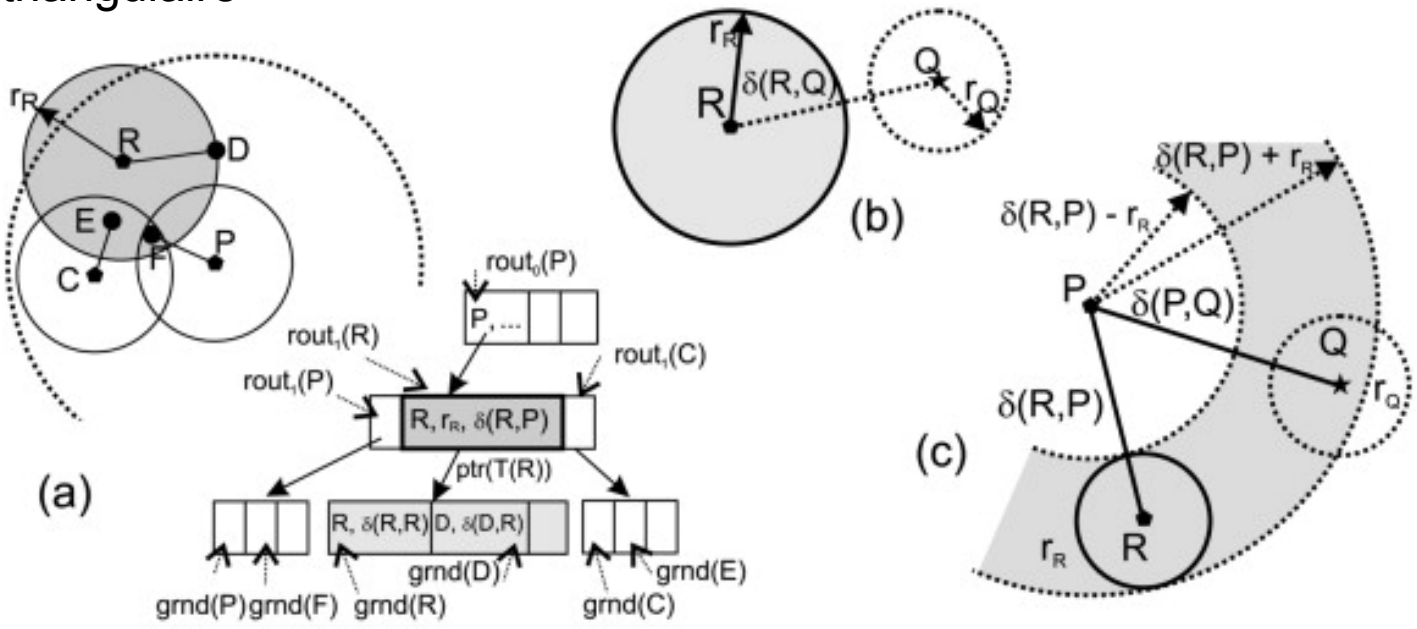

Les méthodes de partitionnement hiérarchiques

Le M-tree (Metric Tree) est encore utilisé dans certaines applications de recherche d'information par le contenu

Intérêt: insertions ou supressions dynamiques de complexité logarithmiques

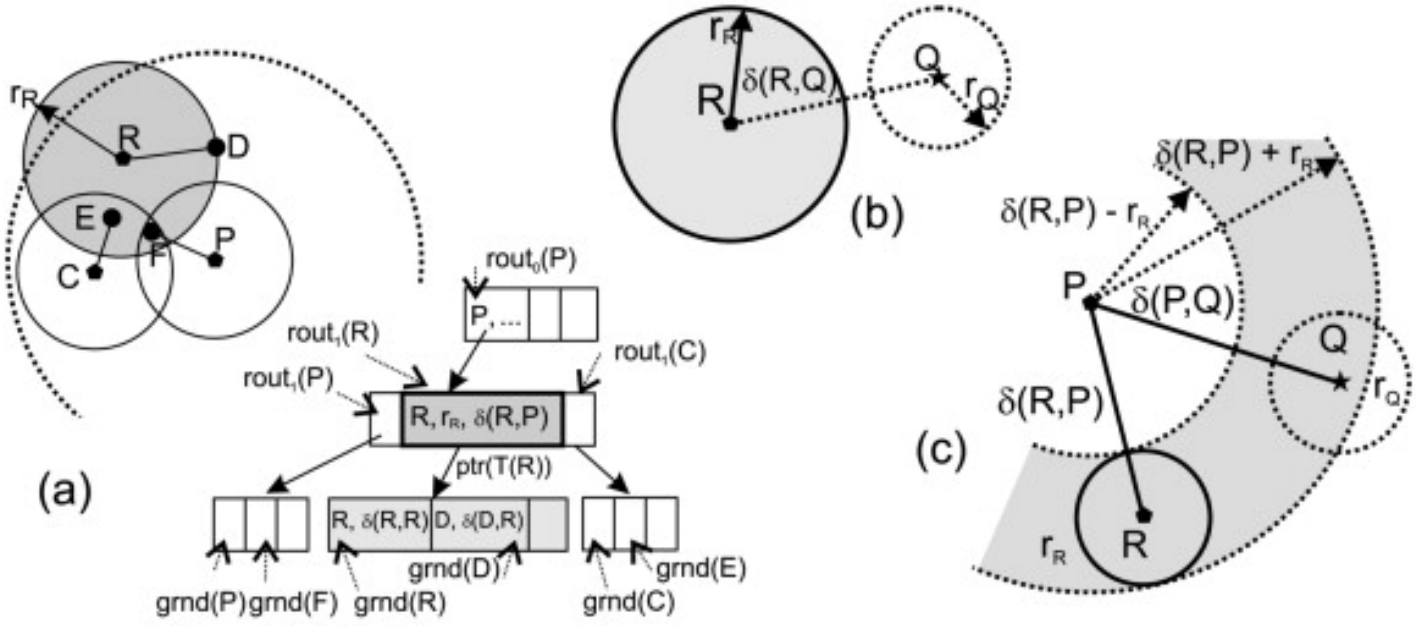

Les méthodes de partitionnement hiérarchiques

Le M-tree (Metric Tree) est encore utilisé dans certaines applications de recherche d'information par le contenu

Intérêt: Le M-tree souffre tout de même de la malédiction de la dimension et n'est rentable qu'avec des algorithmes de recherche approximatifs de type (1+ε)-approximatives (cf. chapitre algorithmes de recherche)

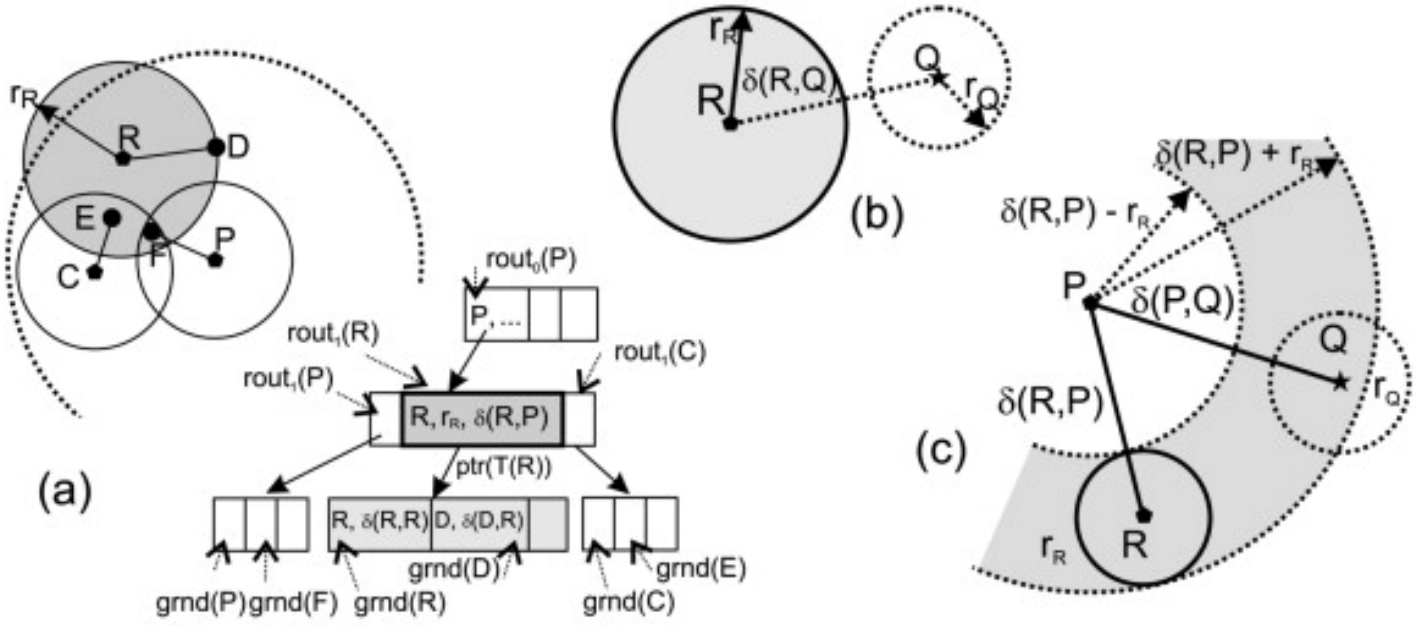

Les méthodes de partitionnement hiérarchique

Le kd-tree est utilisé pour la recherche d'image par le contenu (e.g. dans la librairie FLANN)

kd-tree classique:

A chaque niveau i, partitionne l'ensemble courant en deux parties égales par un hyperplan orthogonal à l'axe i mod d

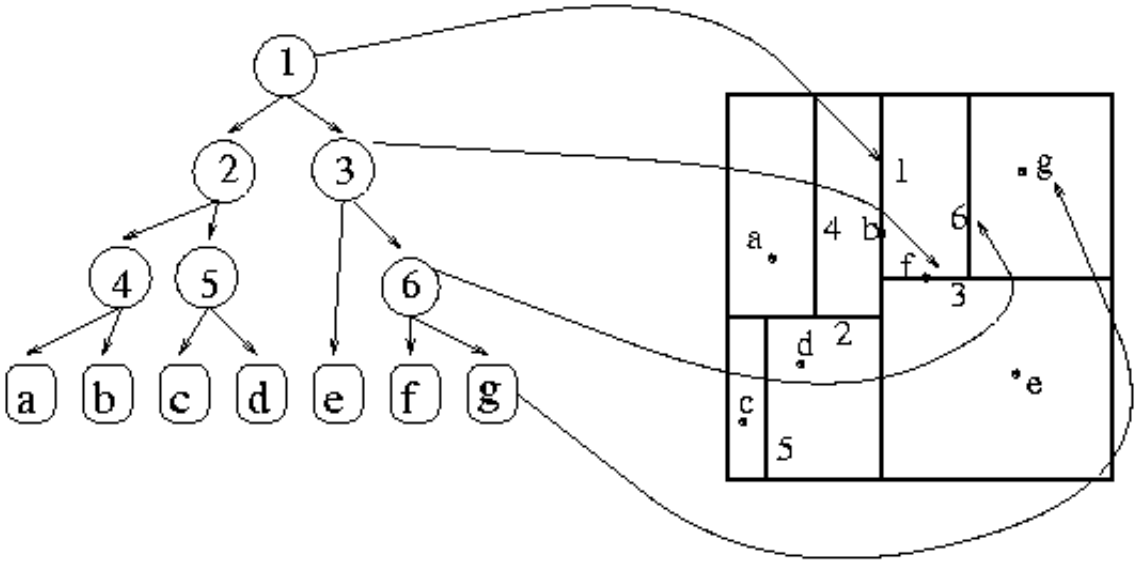

Les méthodes de partitionnement hiérarchique

Le kd-tree est utilisé pour la recherche d'image par le contenu (e.g. dans la librairie FLANN)

Randomized kd-trees:

En très grande dimension, on utilise plutôt une forêt d'arbres dans lesquels le choix de la dimension se fait aléatoirement parmis les d'≤d dimensions ayant la plus grande variance

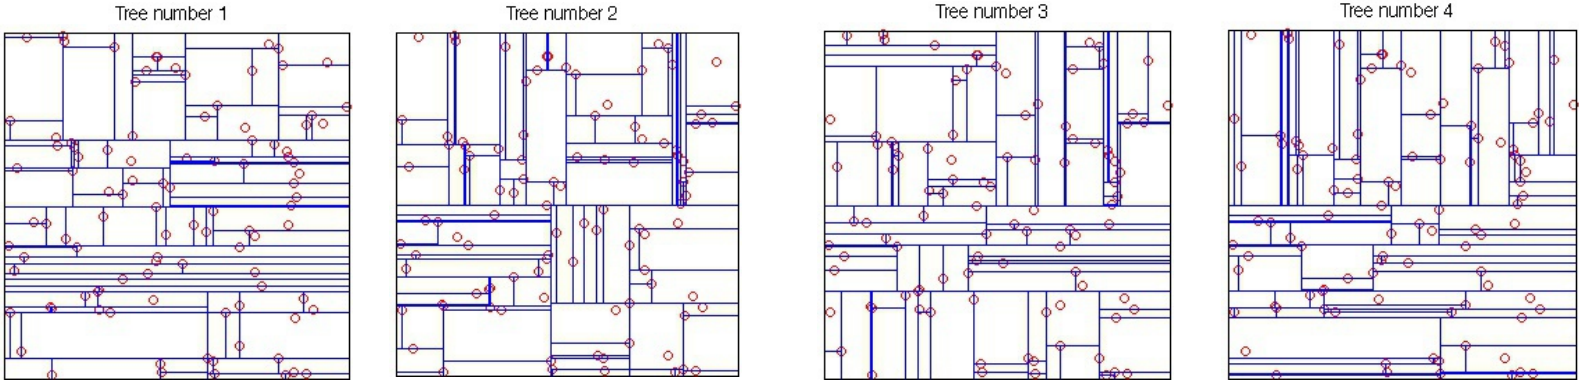

Les méthodes de partitionnement hiérarchique

Hierarchical K-means

On applique un K-Means avec un très faible nombre de cluster (K =10 par exemple), puis on recommence un nouveau K-Means sur chaque sous-ensemble de descripteurs créés par les K clusters.

L'algorithme itère ensuite jusqu'à obtention d'un nombre de clusters total suffisant. Ce nombre étant égal à K^n, avec n le nombre d'itérations.

HKM permet de réduire la complexité de l'algorithme à O(N logK) au lieu de O(NK).
Bien que beaucoup plus efficace en termes de temps de calcul, HKM ne produit pas d'aussi bons résultats de clustering qu'un K-Means standard.

Les méthodes de partitionnement dans des sous espaces

On découpe l'espace d'entrée en plusieurs sous espaces de dimension moindre puis on partitionne chaque sous espace

Exemple: Kmeans Product Quantizer

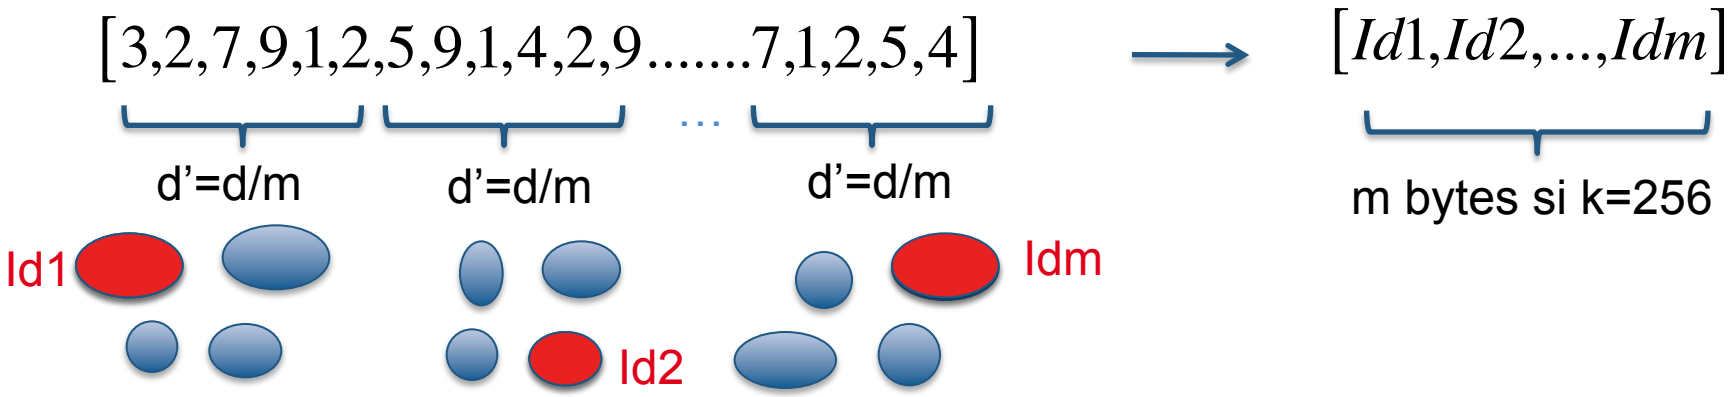

Les méthodes de partitionnement dans des sous espaces

Exemple: Kmeans Product Quantizer

→ avantage vs. kmeans classique = on peux créer des partitions (vocabulaires) de très grande taille sans problème de temps d'encodage ou d'espace mémoire

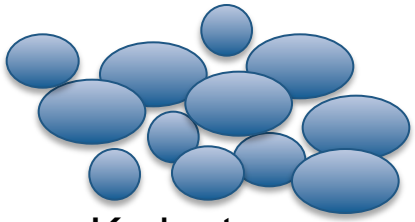

K clusters

= **K régions**

Construction O(**K**nd)
Encodage O(**K**d)
Mémoire O(**K**d)

↓ K→ m.k d→d'=d/m

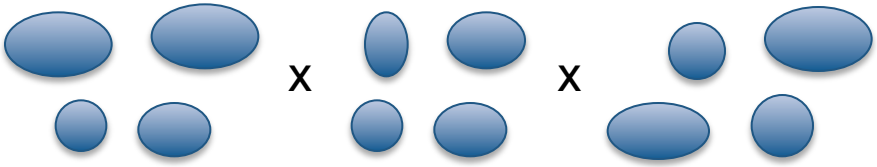

k clusters x k clusters x k clusters

= **k^m régions**

Construction O(**k**nd)
Encodage O(**k**d)
Mémoire O(**k**d)
k<<K

e.g. k:256, m:8, d:128 => 18.10^{18} régions

Les structures d’index et algorithmes de recherche associées

Tableaux de vecteurs quantifiés et recherche exhaustive à deux étages

On cherche un ensemble de voisins dans l'espace quantifié puis on raffine dans l'espace d'origine

Filtrage

$dist_z(z(q),z(v_i))$

Z(q) →

O(d') au lieu de O(d)

Raffinement

$dist(q,v_j)$

q →

Le filtrage dans l'espace quantifié peux se faire de plusieurs façons:
- Les k' plus proches voisins avec k'>>k voulu dans l'espace d'origine
- A un rayon près
  - méthode exact parfois possible (borne inf sur la bucket)
  - méthode probabiliste parfois possible (lsh: projections aléatoires)

Les distances asymétriques

On peux ne pas quantifier la requête et utiliser une distance asymétrique avec les vecteurs quantifiés de l'index

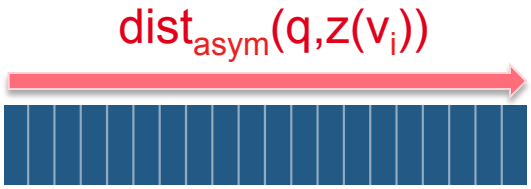

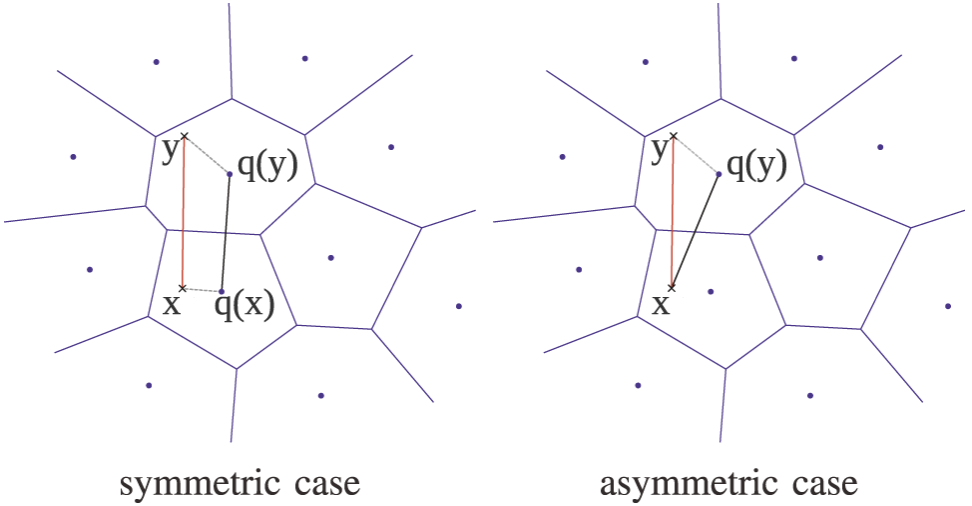

symmetric case asymmetric case

Avantage: meilleure approximation de la distance dans l'espace d'origine sans augmentation de l'espace mémoire de l'index

Inconvénient: en général un peu plus lent que distance de Hamming

Les tables et listes inversées

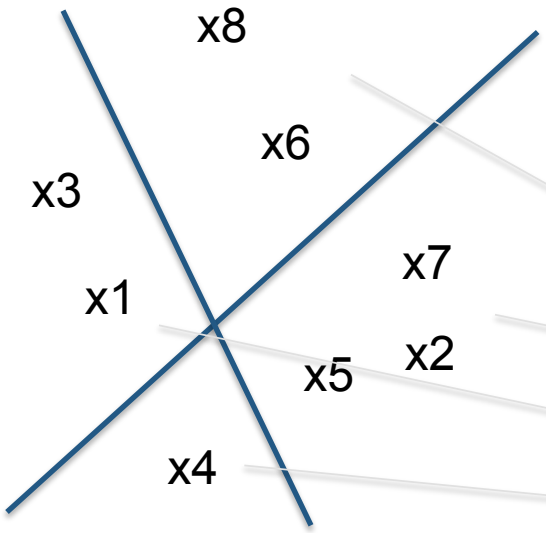

Clé=identifiant d'une région de la partition= 1 valeur dans l'espace quantifiée

Clé	Valeur (ensemble de vecteurs)
z1	Id6:X6,Id8:X8
z2	Id2:X2, Id5:X5, Id7:X7
z3	Id1:X1,Id3:X3
z4	Id4:X4

Zj peut être:
- Un identifiant de cluster (par exemple mot visuel)
- Un hash code binaire (stocké sous forme de string
- Une position dans une grille
- Un identifiant de feuille dans un arbre
- …

Les tables et listes inversées: accès simple

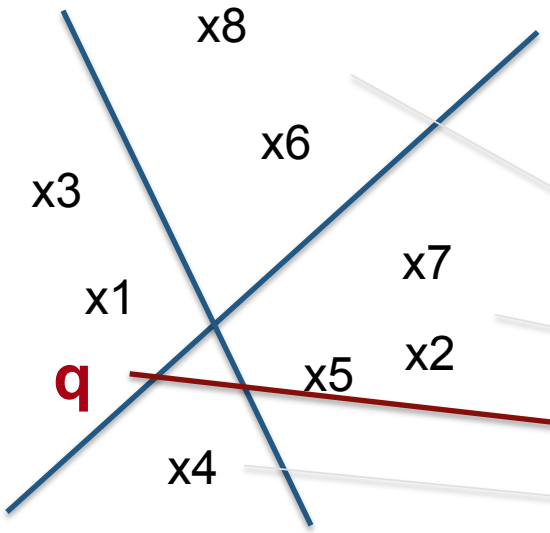

Parcours exhaustif des vecteurs d'une seule bucket

Clé	Valeur (ensemble de vecteurs)
z1	Id6:X6,Id8:X8
z2	Id2:X2, Id5:X5, Id7:X7
z3	Id1:X1,Id3:X3
z4	Id4:X4

Calcul des distances et recherche des nn

Avec ou sans calcul des distances pour affiner la recherche (knn ou range)

Très efficace, mais qualité faible en grande dimension quelle que soit la méthode de partitionnement:
- malédiction de la dimension
- beaucoup de plus proches voisins n'appartiennent pas à z(q)
- Taille de la partition = compromis entre qualité et efficacité

Les tables et listes inversées: accès mutiples

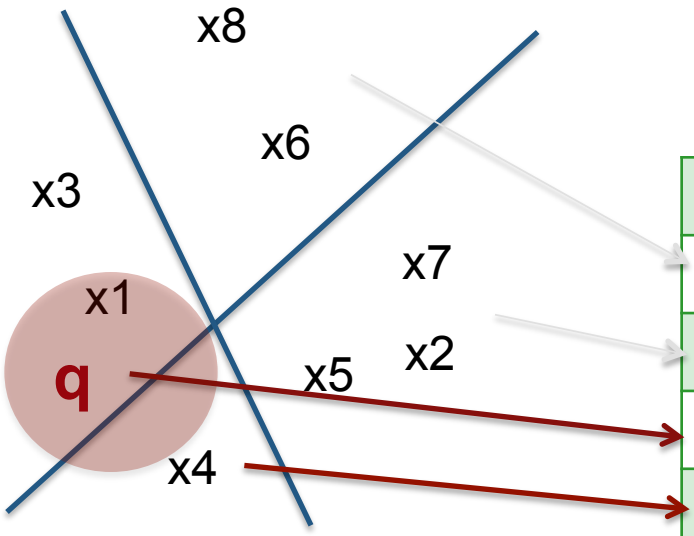

Parcours exhaustif des vecteurs de plusieurs buckets voisines

Clé	Valeur (ensemble de vecteurs)
z1	Id6:X6,Id8:X8
z2	Id2:X2, Id5:X5, Id7:X7
z3	Id1:X1,Id3:X3
z4	Id4:X4

Calcul des distances et recherche des nn

Calcul des distances et recherche des nn

Amélioration du rappel en visitant les buckets voisines. La détermination des buckets voisines dépend du type de partition et peux se faire de plusieurs façons:
- Les k plus proches (typiquement pour kmeans, compromis qualité / temps de calcul ajustable en ligne)
- à un rayon près (pas toujours possible, danger: nombres de bucket peut être énorme)
- probabiliste (par apprentissage ou théorique dans le cas de projections aléatoires → étude détaillée de LSH)

Les tables et listes inversées: tables multiples

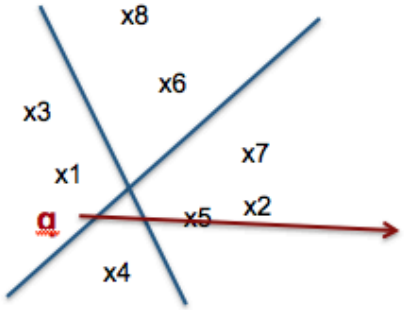

Clé	Valeur (ensemble de vecteurs)
z1	Id6:X6,Id8:X8
z2	Id2:X2, Id5:X5, Id7:X7
z3	Id1:X1,Id3:X3
z4	Id4:X4

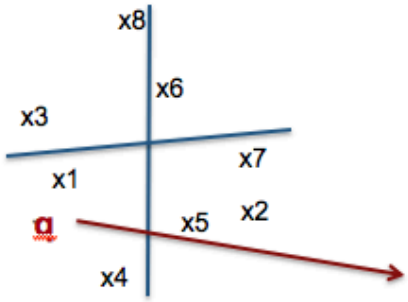

Clé	Valeur (ensemble de vecteurs)
z1	Id3:X3,Id8:X8
z2	Id6:X6
z3	Id2:X2, Id5:X5, Id7:X7
z4	Id1:X1, Id4:X4

La manière de construire plusieurs tables dépend du type de partition:
- Plusieurs kmeans sur des données d'apprentissage différentes
- Plusieurs ensembles de projections aléatoires (cf. LSH)
- Analyse en composantes principales sur des sous-espaces

Peut être plus efficace que les accès multiples (moins d'accès au final) mais nécessite plus de mémoire pour stocker toutes les tables

Les tables et listes inversées: indexation dense

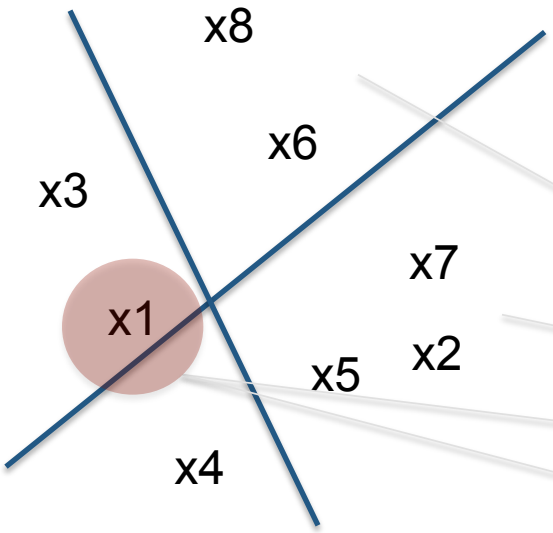

Indexation dans plusieurs buckets voisines, accès unique pendant le search

Clé	Valeur (ensemble de vecteurs)
z1	Id3:X3, Id6:X6,Id8:X8
z2	Id2:X2, Id5:X5, Id6:X6, Id7:X7
z3	Id1:X1,Id3:X3, Id4:X4
z4	Id1:X1, Id4:X4

- On troque du temps de calcul contre de la mémoire
- La mémoire requise peux devenir très grande pour certaines partitions
- La détermination des buckets voisines peux se faire de plusieurs manières (k plus proches, rayon, probabiliste)
- Particulièrement utilisée avec partition kmeans (

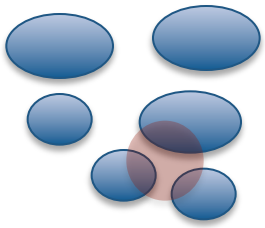

Les arbres (pour méthodes de partitionnement hiérarchiques)

Base $S = \{p_1, \ldots, p_n\}$
représentée par un arbre:

- Chaque noeud est un sous-ensemble de S
- La racine est S entier
- L'ensemble père est entièrement couvert par les ensembles fils
- Chaque noeud contient une "description" de son sous-arbre fournissant une **borne** inférieure pour $d(q, \cdot)$ dans le sous-ensemble correspondant

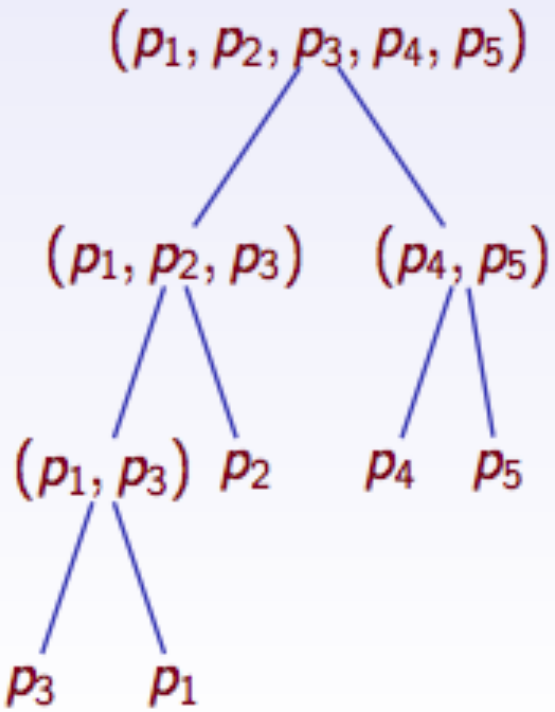

Les arbres (pour méthodes de partitionnement hiérarchiques)

Branch and Bound: Recherche à un rayon près

Objectif: Trouver tous les p_i tels que $d(p_i, q) \leq r$:

1. Parcours en profondeur de l'arbre (algorithme récursif)
2. A chaque noeud, calcul de la borne inférieure du sous-ensemble correspondant
3. Elimination des branches avec une borne inférieure supérieure à r

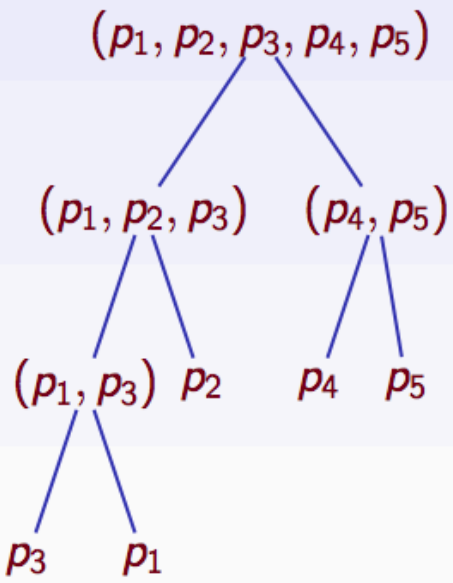

Les arbres (pour méthodes de partitionnement hiérarchiques)

B&B: Recherche du plus proche voisin

Objectif: trouver $\text{argmin}_{p_i}\ d(p_i, q)$:

1. Choisir aléatoirement un p_i, initialiser $p_{NN} := p_i, r_{NN} := d(p_i, q)$
2. Commencer une recherche à r_{NN} près
3. Lorsque l'on rencontre un p' tel que $d(p', q) < r_{NN}$, mise à jour $p_{NN} := p', r_{NN} := d(p', q)$

Les arbres (pour méthodes de partitionnement hiérarchiques)

B&B: Best Bin First

Objectif: trouver $\text{argmin}_{p_i}\ d(p_i, q)$:

1. Choisir aléatoirement un p_i, initialiser $p_{NN} := p_i, r_{NN} := d(p_i, q)$
2. Mettre le noeud racine dans une **queue d'inspection**
3. Répéter: choisir le noeud de la queue d'inspection ayant la borne inférieure la plus petite, calculer les bornes inf. des sous-ensembles fils
4. Insérer dans le queue les fils dont la borne inf. est inférieure à r_{NN} ; éliminer les branches des autres fils
5. Lorsque l'on rencontre un p' tel que $d(p', q) < r_{NN}$, mise à jour $p_{NN} := p', r_{NN} := d(p', q)$

Les arbres (pour méthodes de partitionnement hiérarchiques)

En dimension >15, seuls des algorithmes de recherche approximatifs permettent d'être plus rapide qu'une recherche exhaustive (malédiction de la dimension)

Requêtes à un rayon r près $(1+\epsilon)$-approximatives:
s'il y a au moins un $p \in S$: $d(q,p) \leq r$ retourne des p' : $d(q,p') \leq (1+\epsilon)r$

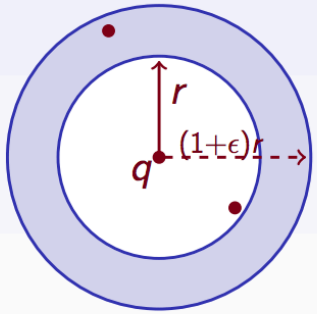

C'est une borne max sur l'erreur relative entre le(s) point(s) retrouvé(s) et le(s) knn exact

$$\frac{d(q,p') - d(q,p)}{d(q,p)} \leq \varepsilon$$

Les arbres (pour méthodes de partitionnement hiérarchiques)

Quand utiliser des arbres ?

- Dimensionalité modérée (<128)
- Taille de base modérée (<1M de vecteur)
- Lorsque les données arrivent de manière incrémentale
- Lorsqu'il y a des besoins d'insertion/suppression dynamique

Les arbres ne sont en revanche pas adaptés aux très grandes tailles de base notamment lorsque l'accélération du temps de recherche reste le facteur primordial

- Surcoût mémoire pour stocker la structure
- Parcours d'arbre plus coûteux que des accès dans une table (sauts mémoires, sorties de cache, des « if », etc.)

Les graphes de similarité

Pré-calcule du graphe complet de similarité ou de voisinage entre les objets de la base + recherche de requêtes externes par des algorithmes de marche dans les graphes

Construction du graphe

- Calcul $O(N^2)$ si recherche exhaustive exacte
- Calcul $O(N^{1+\gamma})$ avec des méthodes de recherche approximatives
- Taille mémoire $O(N^{2)}$ si graphe complet

→ Plutôt pour base statique de taille modérée (et/ou données déjà organisées sous forme de graphe)

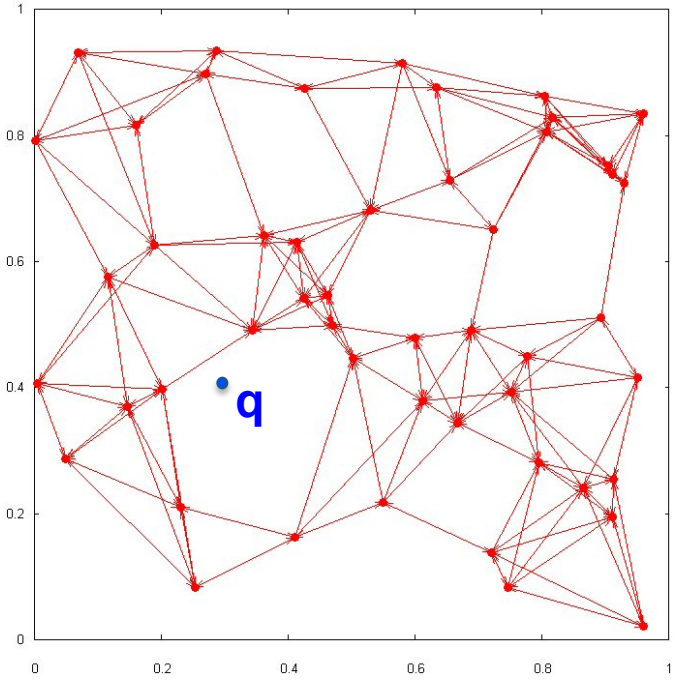

Les graphes de similarité

Exemple: Algorithme d'Orchard (très utilisé dans réseaux P2P)

Preprocessing: Orchard'91

Pout tous les objets $p_i \in S$ construire une liste $L(p_i)$ de tous les autres objets triés par leur similarité à p_i

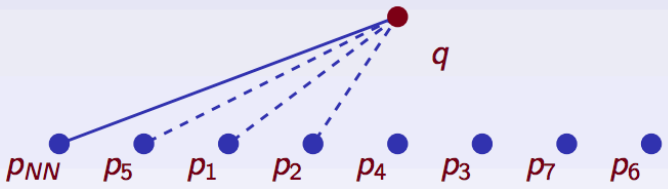

Traitement requête:

- Commencer avec un objet aléatoire p_{NN}
- Inspecter les membres $p' \in L(P_{NN})$ de gauche à droite
- Si $d(p', q) < d(p_{NN}, q)$, update $p_{NN} := p'$
- Condition d'arrêt: On trouve un p' tel que $d(p', q) \geq 2d(p_{NN}, q)$

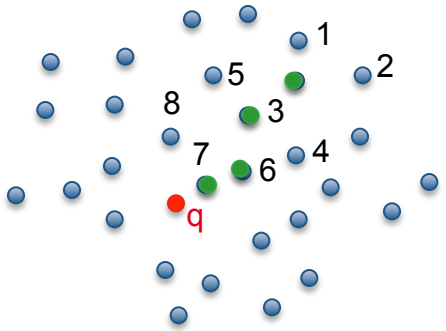

Les approches combinées à deux étages (coarse-to-fine)

On peux utiliser une quantification grossière sous forme de table ou d'arbre et des approches de quantifications vectorielles plus fines à l'intérieur des buckets

Exemple: k-means + ACP locale + Hamming Embedding

4 clusters zi

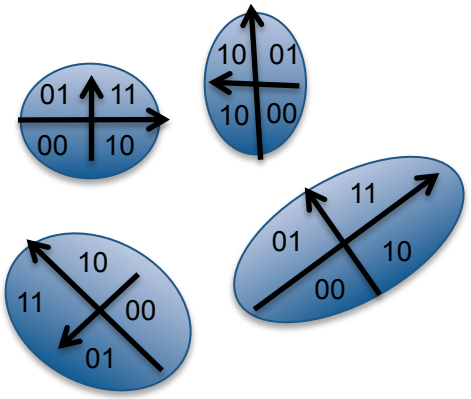

Id cluster	Ensemble de vecteurs quantifiés appartenant au cluster
z1	Id6:01001, Id8:10101
z2	Id2:00110, Id5:11110, Id7:00000
z3	Id1:01001,Id3:10101
z4	Id4:10100

- La quantification binaire s'adapte à chaque cluster et est au final plus efficace qu'une ACP globale
- Au moment de la requête, on détermine d'abord le cluster puis on quantifie avec la bonne matrice de projection

Les approches combinées

On peux imaginer beaucoup de combinaisons… nombreux travaux de recherche porte sur le sujet

- Randomized KD-tree pour filtrer + quantification fine avec projection aléatoire et ACP
- Kmeans normal pour construction table + indexation fine avec product quantizer
- ACP binarisée pour construction table + projections aléatoires pour quantification fine des vecteurs
- Possibilité de faire plus de 2 étages de quantification (coarse-to-fine)
- Construction de graphes de similarité approximatifs sur vecteurs quantifiés puis raffinement lors de la marche, etc.