

Comprendre les données visuelles à grande échelle

ENSIMAG
2019-2020

KartEEK Alahari & Diane Larlus
17 octobre 2019



Organisation du cours

- 17/10/19 cours 1 - Diane
- 24/10/19 cours 2 - Karteek
- 07/11/19 cours 3 - Karteek
- 14/11/19 cours 4 - Diane
- 28/11/19 cours 5 - Karteek
- 05/12/19 cours 6 - Karteek
- 12/12/19 cours 7 - Diane
- 19/12/19 cours 8 - Diane

Vacances d'hiver

- 09/01/20 cours 9 - Diane + présentation articles 1 & 2 + quizz
- 16/01/20 cours 10 - Diane + présentation articles 3 & 4 + quizz
- 23/01/20 cours 11 - Karteek + présentation articles 5 & 6 + quizz
- 30/01/20 cours 12 - Karteek + présentation articles 7 & 8 + quizz

Attention: la salle change régulièrement

Cours 4: Recherche d'images - suite et fin

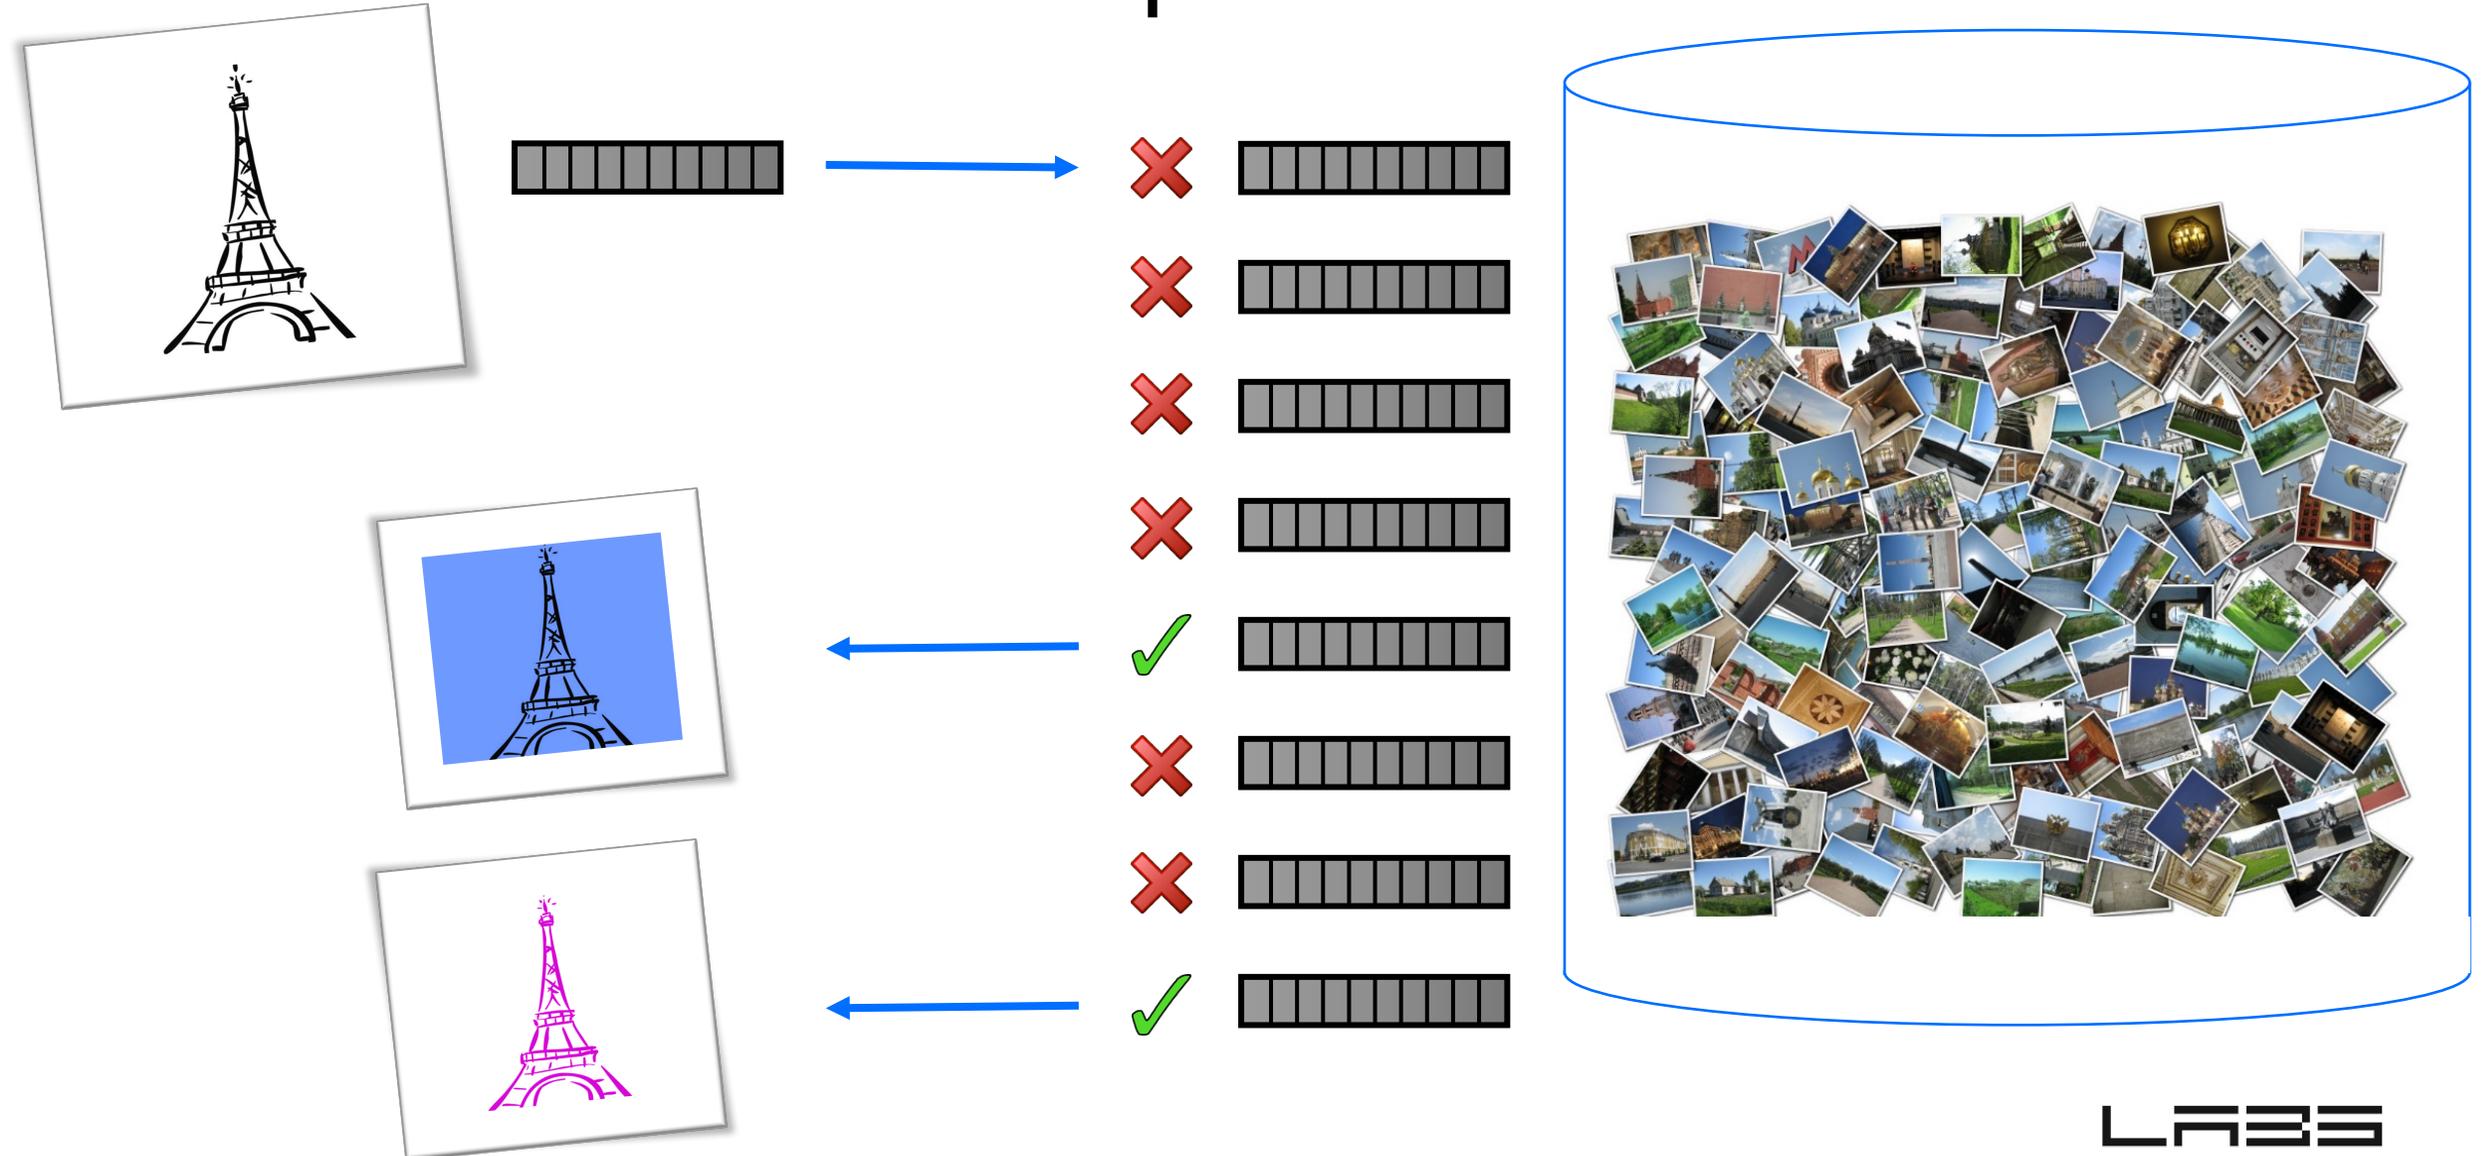
Comprendre les données visuelles à grande échelle
14 novembre 2019

Recherche visuelle d'images – rappel du cours 1

Comprendre les données visuelles à grande échelle

Cours 4: recherche d'images, 14 novembre 2019

Visual Search - Principle



Inherent ambiguity

What can the user mean with such a single query?

Application dependent!

Cours 1

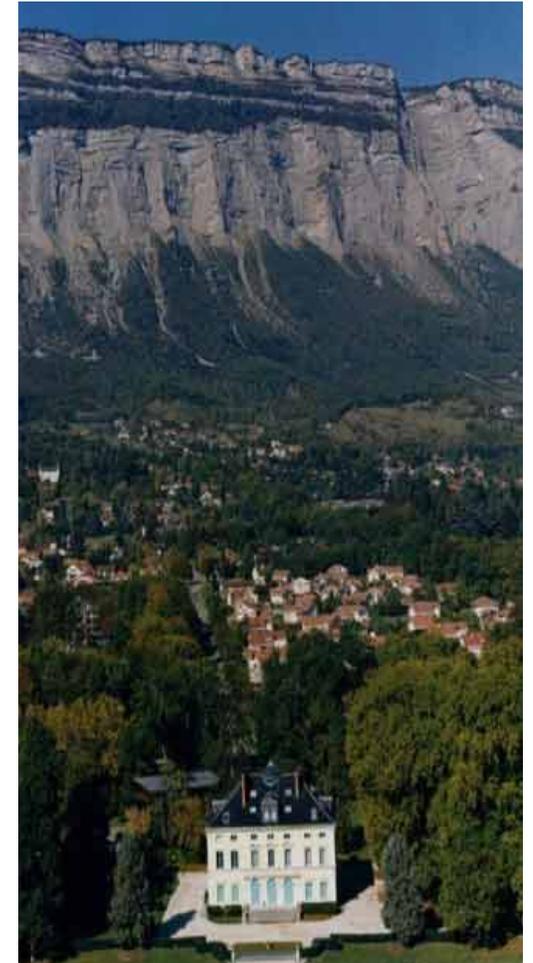


- **Inject prior information**
 - Hand-crafting detectors / descriptors to obtain some properties (repeatability, invariance, discrimination, compactness, etc.)
- **Leverage training**
 - Provided with training data, learn a descriptor appropriate for the task

Ce cours

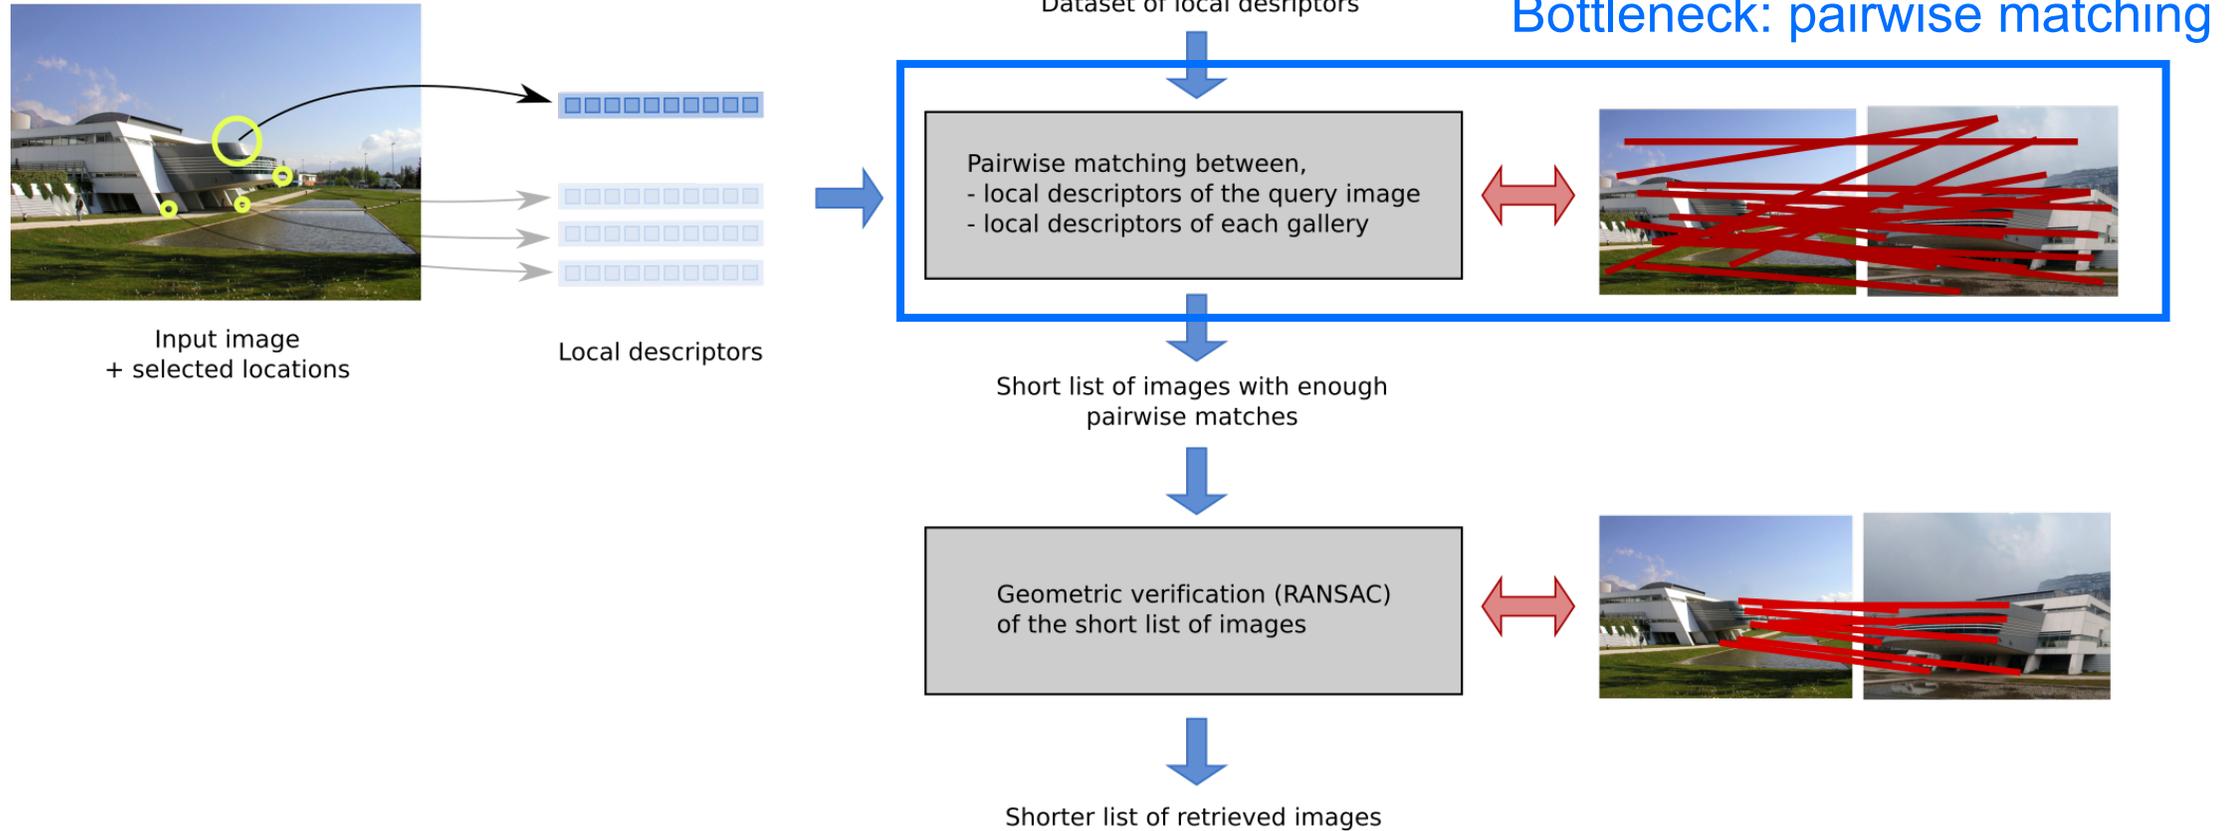
Rappel cours 1 !

Rappel: variation d'apparence d'une instance d'objet donné



Local representations

Summary of the pipeline



Scaling the first selection process

1) Efficient approximate nearest neighbor search on local descriptors

- Randomized K-d trees and variants
 - Priority queue to examine most promising first
- Locality-Sensitive Hashing (LSH)
 - Randomized hashing technique
 - Data-dependent variants: spectral hashing, semantic hashing

[Silpa-Anan & Hartley 2008,
Chum et al 2008, Muja & Lowe. 2009]

[Indik & Motwani, 1998, Weiss et al NIPS08,
Salakhutdinov & Hinton, SIGIR07]

2) Quantize local descriptor space into a visual codebook

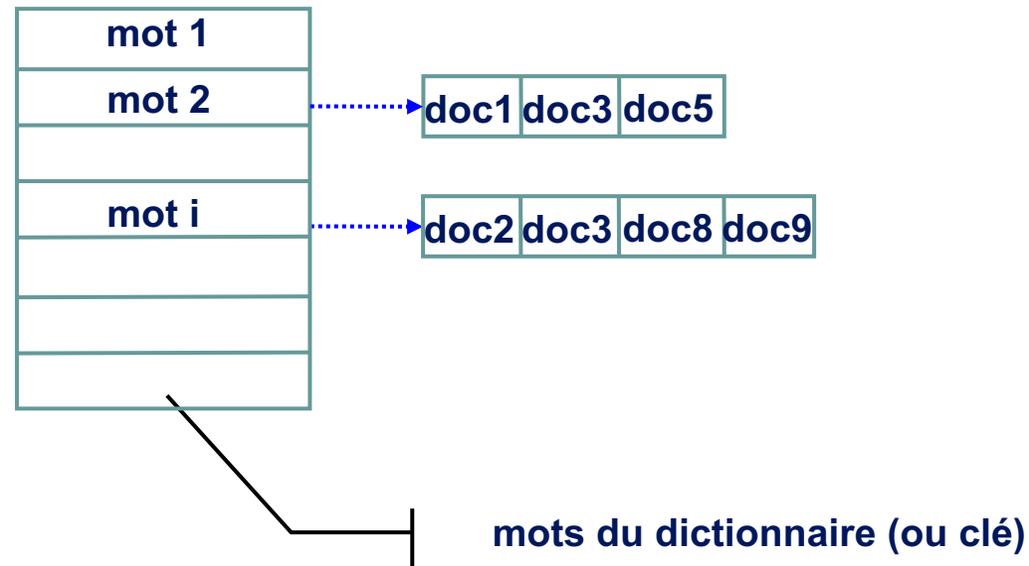
- Uses **inverted files** to store the descriptors
- Efficient image matching

Plan de la suite

- Concept de fichier inversé: motivation
- Exemple d'utilisation d'un fichier inversé dans le cas de la recherche de texte
- Comment créer un vocabulaire visuel pour utiliser cette technique avec des représentations locales d'images
- Application d'un fichier inversé au cas de la recherche d'images

Fichier inversé (*inverted file*)

- Cette structure liste des éléments qui ont une valeur donnée pour un attribut
- Exemple courant d'utilisation : requêtes sur documents textuels (mails, ...)



- La requête consiste à récupérer la liste des documents contenant le mot
 - ▶ coût proportionnel au nombre de documents à récupérer

Recherche de documents textuels (2)

- Exemple
 - ▶ vocabulaire = {"vélo", "voiture", "déplace", "travail", "école", "Grenoble"}
 - ▶ espace de représentation: \mathbb{R}^6
 - ▶ "Grenoble est une belle ville. Je me déplace à vélo dans Grenoble"

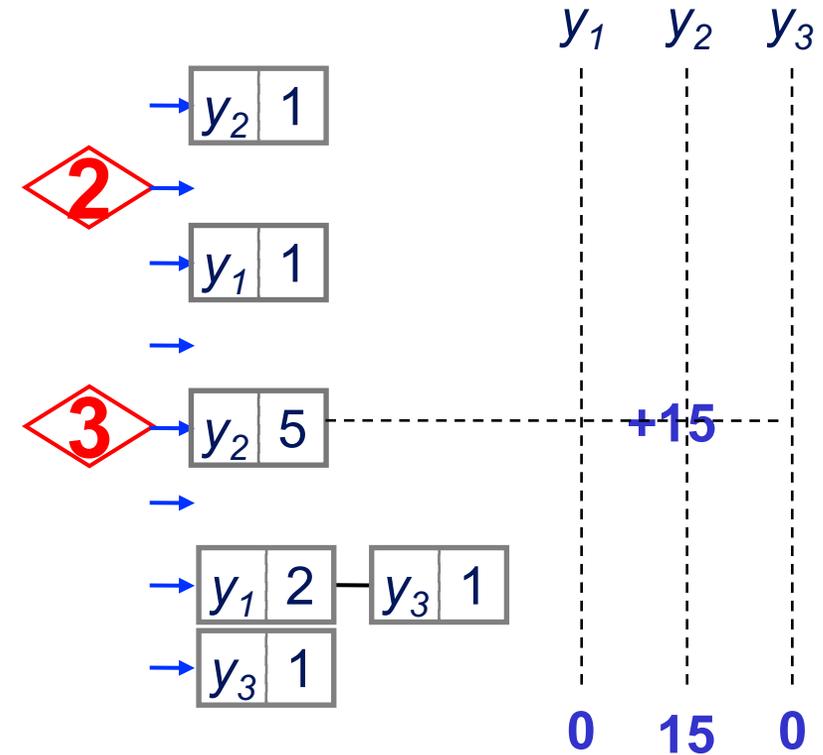
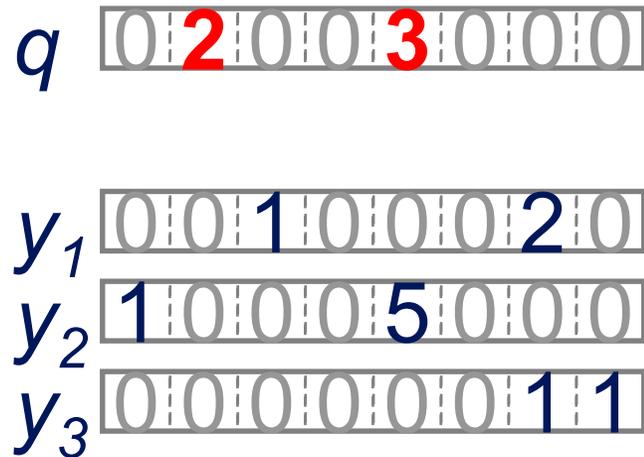
$$f=(1/4,0,1/4,0,0,1/2)^t$$

- Recherche de document = trouver les vecteurs les plus similaires à un document requête, représenté par le vecteur q
 - ▶ au sens d'une mesure de (dis-)similarité, en particulier le produit scalaire

Rappel cours 1 !

Fichier inversé : distances entre vecteurs creux

- La **requête** q et les **éléments de la base** Y sont des vecteurs creux
- Fichier inversé: calcul efficace du produit scalaire (en fait, toute distance L_p)
- Exemple pour le produit scalaire



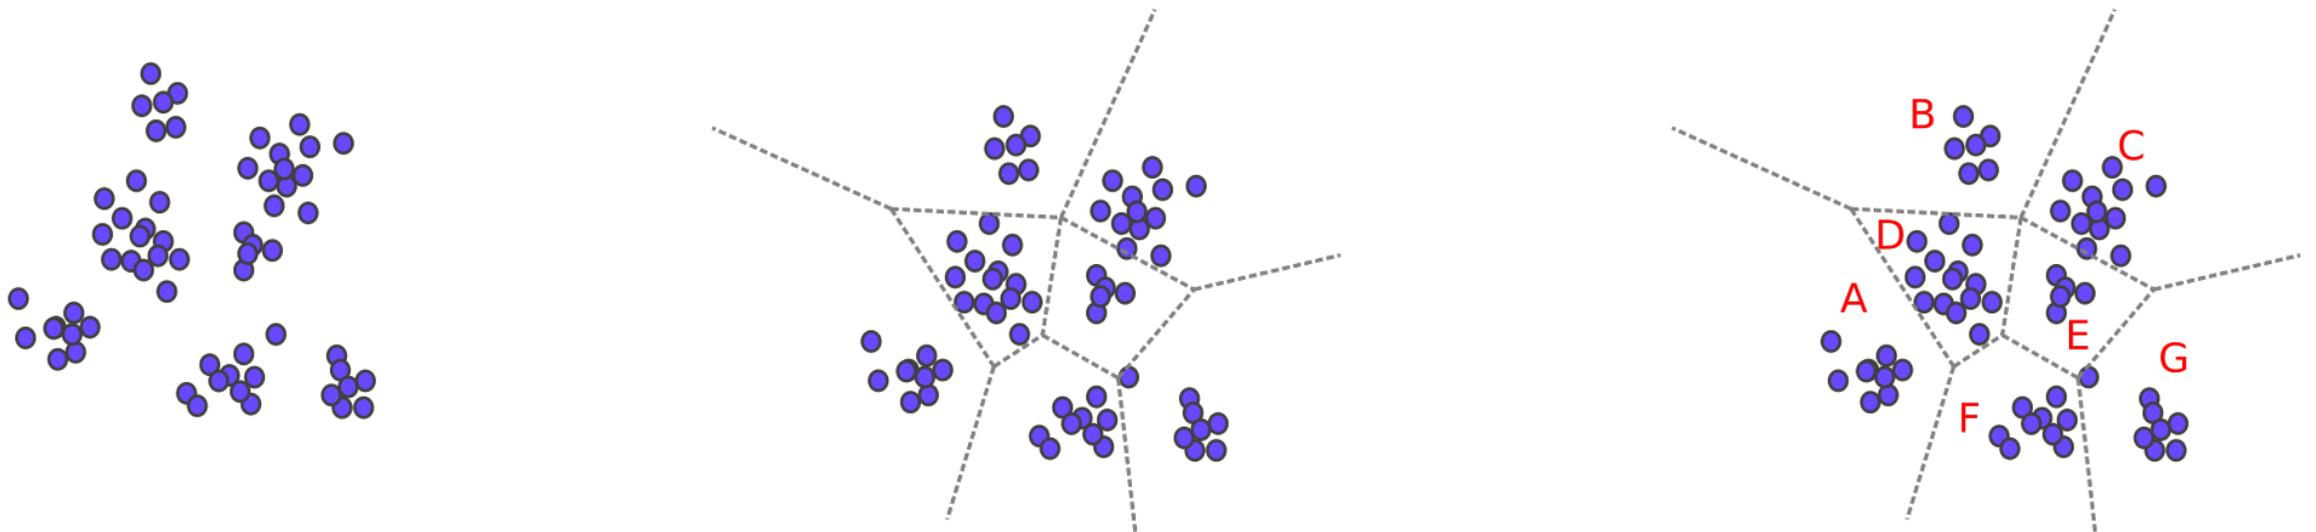
Recherche de documents visuels

- **Problème:** l'espace des descripteurs locaux est continu (par exemple l'espace des SIFT)
 - ▶ Il existe potentiellement une infinité de descripteurs locaux possibles
 - ▶ Il n'existe pas de concept de vocabulaire = 'ensemble de mots' pour les *patches* d'images tel que c'est le cas pour le texte
- Solution: créer un **vocabulaire visuel** !
 - Aussi appelé *visual vocabulary* or *visual codebook* dans la littérature
 - Construction par quantification de l'espace des descripteurs locaux

Quantization: principle

Principle:

- Discretize the local descriptor space, e.g. SIFT descriptors
- 2 descriptors match i.i.f. they fall in the same bin
- this creates a visual codebook, similar to the textual codebook seen before

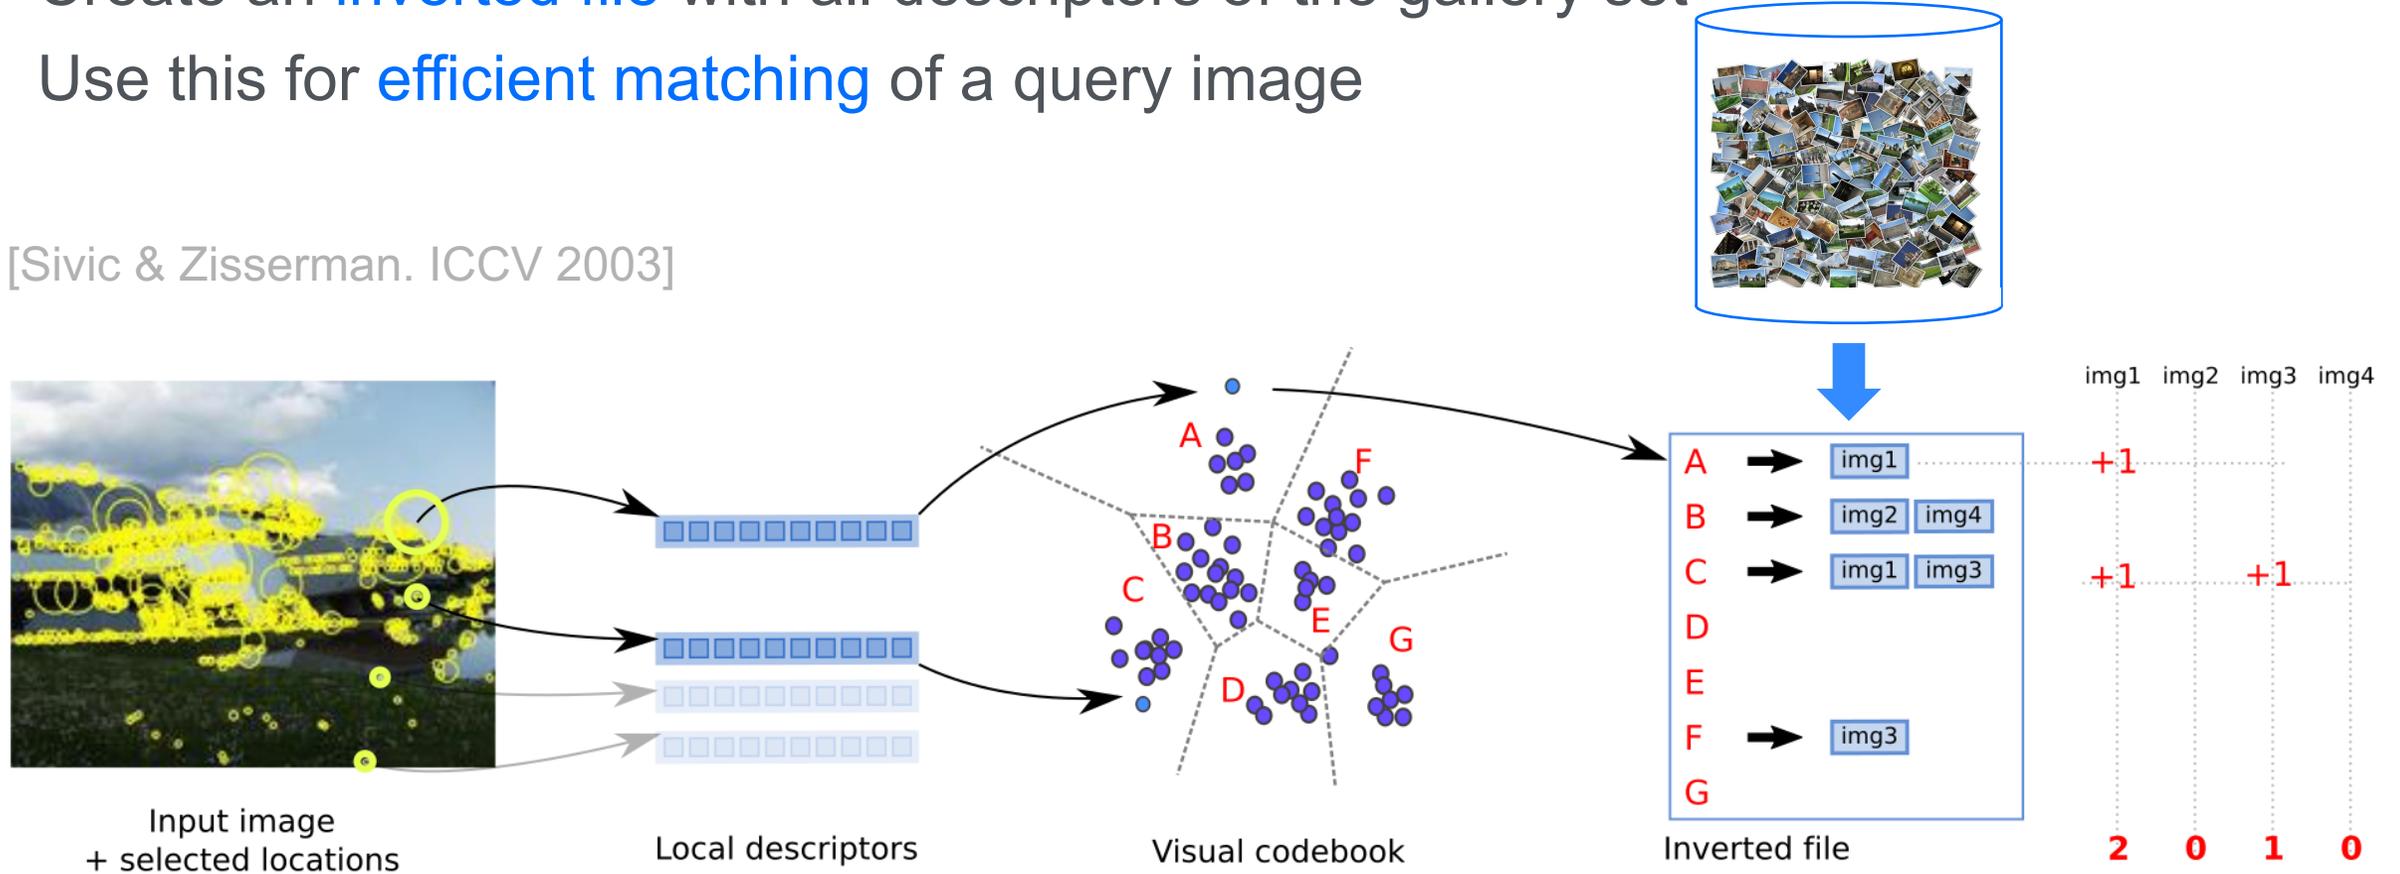


Leverage quantization for efficient retrieval

Create an **inverted file** with all descriptors of the gallery set

Use this for **efficient matching** of a query image

[Sivic & Zisserman. ICCV 2003]



Description locale des images : résumé et commentaires

- **Les différentes étapes**

- ▶ Sélection de points ou de régions d'intérêt (ex: Harris ou Harris-Affine)
- ▶ Calcul des descripteurs pour chacune de ces régions (ex: SIFT, CS-LBP)
- ▶ Algorithme de mise en correspondance entre images (ex: calcul exhaustif des distances entre paires de descripteurs, utilisation d'un fichier inversé)
- ▶ Vérification de la cohérence géométrique (ex: RANSAC)

Description locale des images : résumé et commentaires

- **Commentaires sur les représentations locales**

- ▶ En pratique: cette approche donne de très bons résultats
- ▶ **Principales limitations:**
 - ▶ il faut apparier les descripteurs d'une image avec tous les descripteurs de la base d'image → c'est très lent !
 - ▶ Il faut stocker tous les descripteurs locaux des images dans la base
 - ▶ la vérification de la cohérence géométrique est relativement lente → on ne peut l'utiliser que pour un sous-ensemble d'images *a priori* plus pertinentes

- **Approche alternative**

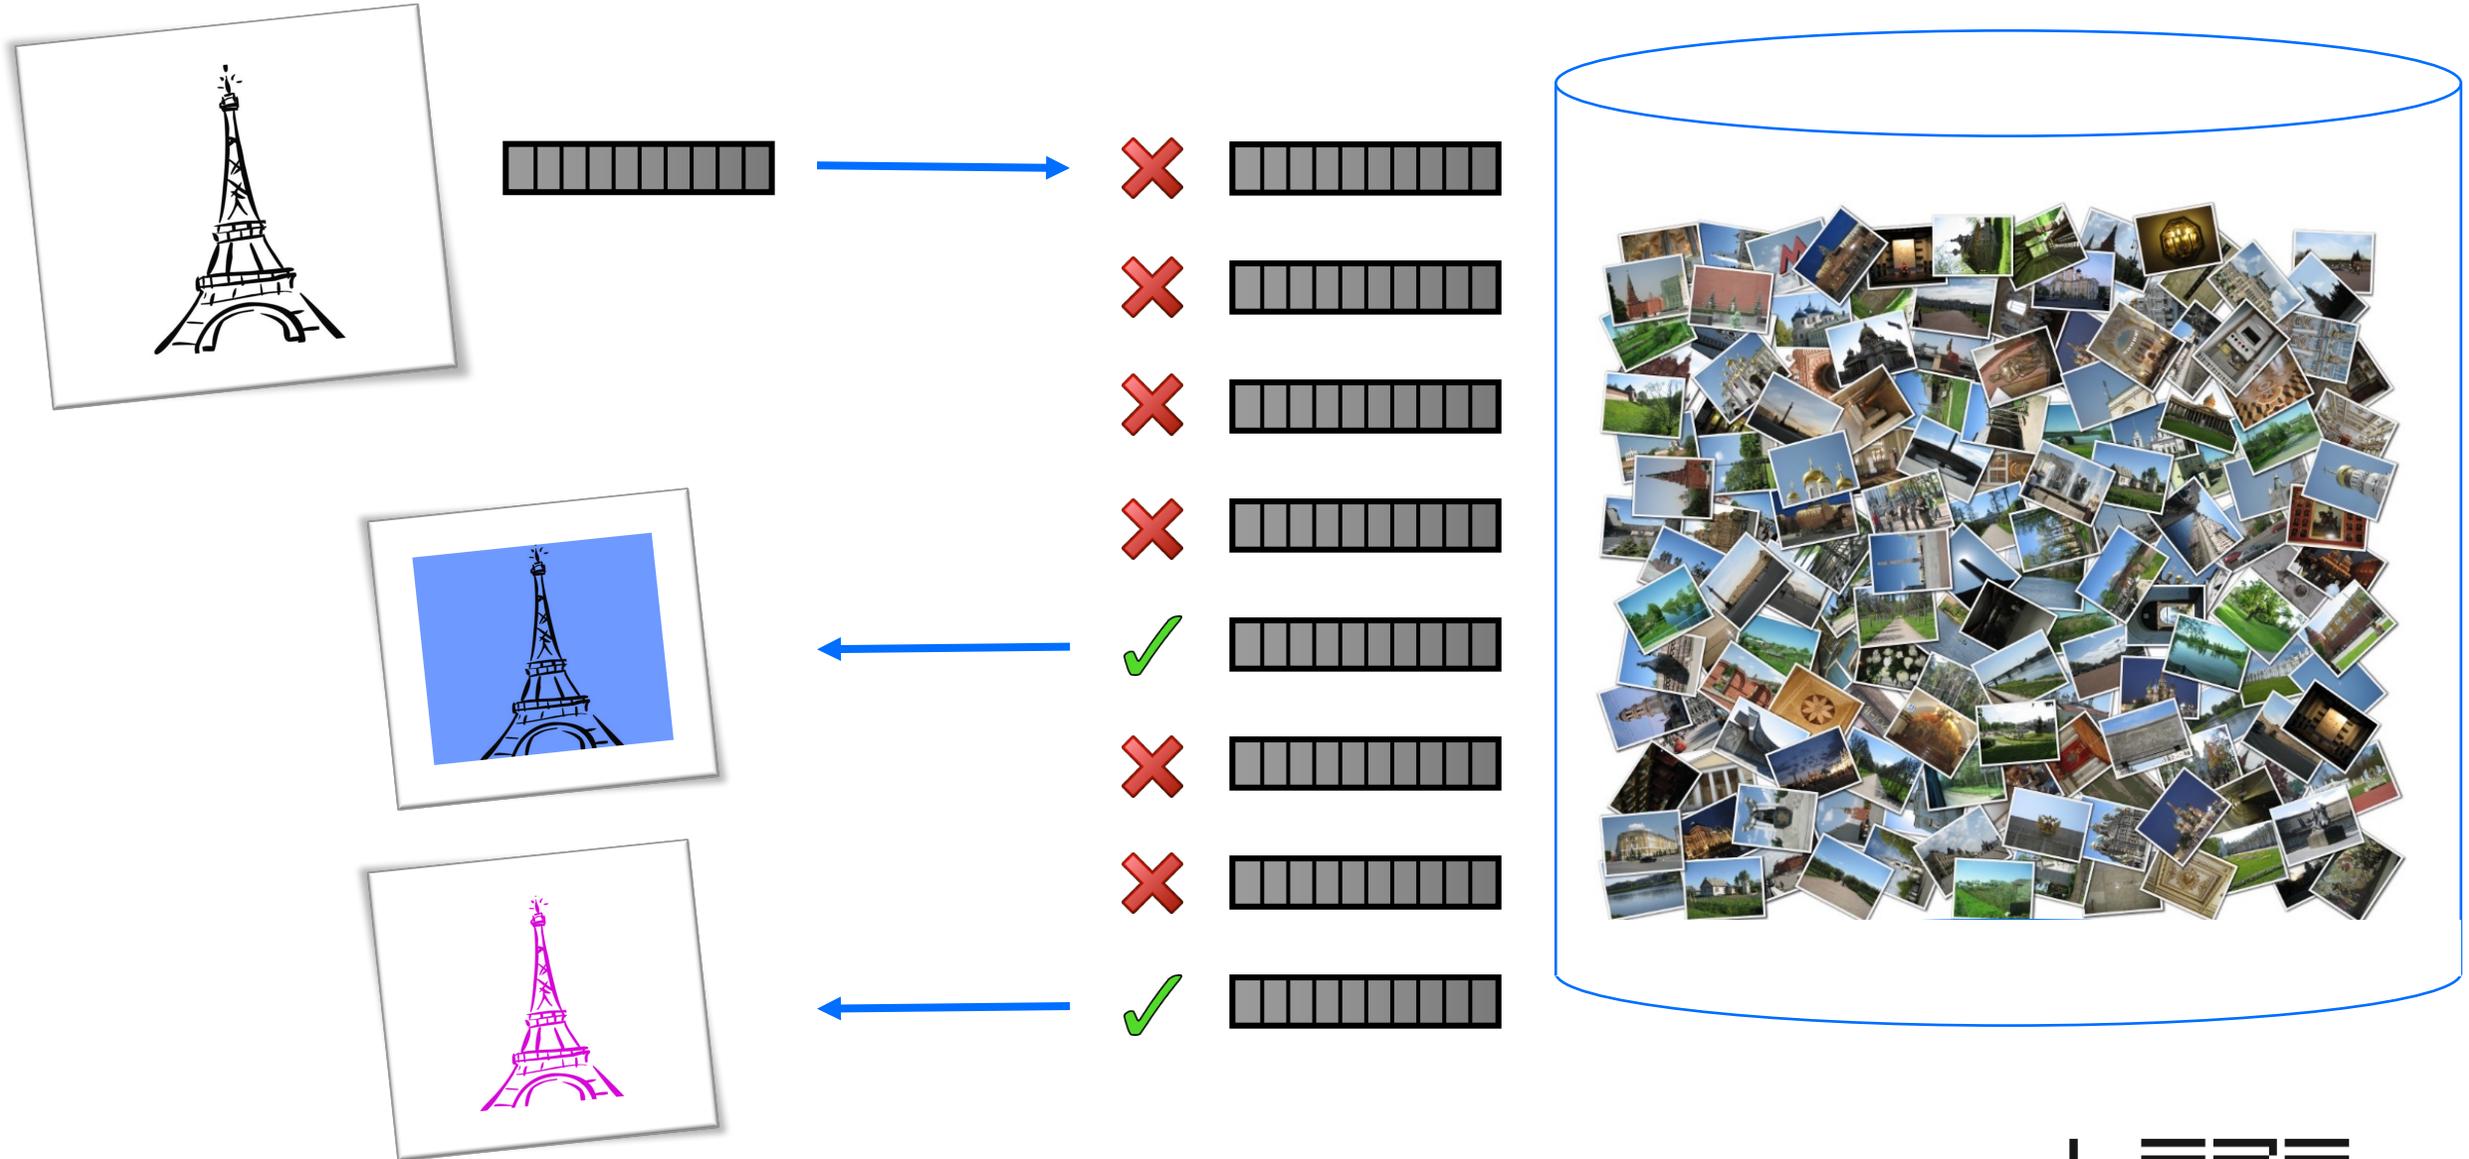
- ▶ Utilisation de **descripteurs globaux** qui agrègent les descripteurs locaux individuels en un descripteur global par image
 - ▶ Les descripteurs locaux ne sont plus stockés, seul le descripteur agrégé l'est
- ▶ Le calcul de la similarité entre images se fait par comparaison directe des descripteurs globaux
 - ▶ Possibilité d'utiliser des similarités très efficaces
- ▶ **Descripteurs globaux:**
 - ▶ **Sacs-de-mots** (cours 2 + ce cours)
 - ▶ **VLAD** et **Fisher Vector** (qui seront présentés plus tard dans le cours)

Notions de similarité, de mesures, et d'évaluation

Comprendre les données visuelles à grande échelle

Cours 4: recherche d'images, 14 novembre 2019

Comment évaluer un système de recherche d'information ?



Prérequis pour l'évaluation d'un tel système

- Avoir à disposition
 - ▶ un ensemble de **test** (base dans laquelle on recherche)
 - ▶ un ensemble de **requêtes** (peuvent être incluses dans la base de test)
 - ▶ une **vérité terrain** (*ground truth*) pour chaque couple (requête, élément de la base) qui répond à la question : est-ce que l'élément de la base est pertinent pour la requête considérée ?

- Remarques (similaires aux remarques précédentes, mais pour le cas de la recherche d'images)
 - ▶ pour comparer deux méthodes, les mêmes ensembles de test et de requêtes doivent être utilisés
 - bases de tests partagées par les chercheurs du domaine
 - ▶ Ex: Oxford, Paris (<https://github.com/filipradenovic/revisitop>)
 - compétition avec introduction de nouvelles bases de test
 - ▶ Ex. Landmarks Retrieval 2018 & 2019 (<https://www.kaggle.com/c/landmark-retrieval-challenge>)
 - ▶ la taille de ces ensembles doit être suffisamment grande pour diminuer la variance de l'évaluation
 - ▶ attention bases trop faciles / trop difficiles → diminue la sensibilité

Précision/rappel (début)

- Soit E un ensemble d'objets (par exemple de textes, d'images, ou de vidéos) muni d'une mesure q telle que
 - ▶ pour $x, y \in E$, $q(x,y) = 0$ si y est pertinent pour x
 $q(x,y) = 1$ sinon

Remarque: on suppose ici la symétrie de la relation q

- Cette mesure est la vérité terrain
- Exemple : x et y sont deux images
 $q(x,y) = 0$ si x et y contiennent le même objet
 $q(x,y) = 1$ sinon
- Soit un ensemble $E' \subset E$, et $x : x \in E$ et $x \notin E'$
 - ▶ E' : ensemble dans lequel on effectue la recherche
 - ▶ x : la requête

Précision/rappel (suite)

- Le système de recherche est paramétré pour retourner plus ou moins de résultats, entre 1 et $\#E'$.
- Compromis :
 - ▶ plus on retourne de résultats, plus on a de chance de retourner tous les objets pertinents de la base
 - ▶ en général, moins on en retourne, plus le taux d'objets retournés et qui sont pertinents est élevé
- Ces deux notions sont couvertes par les mesures de **précision** et de **rappel**

Précision/rappel (suite)

- Soit R l'ensemble des résultats retournés, de cardinal $\#R$
- Soit P l'ensemble des résultats pertinents dans E' pour x , c-a-d

$$P = \{ y \in E' / q(x,y) = 0 \}$$

- Soit A l'ensemble des résultats retournés et qui sont pertinents
- $$A = \{ y \in R / q(x,y) = 0 \}$$

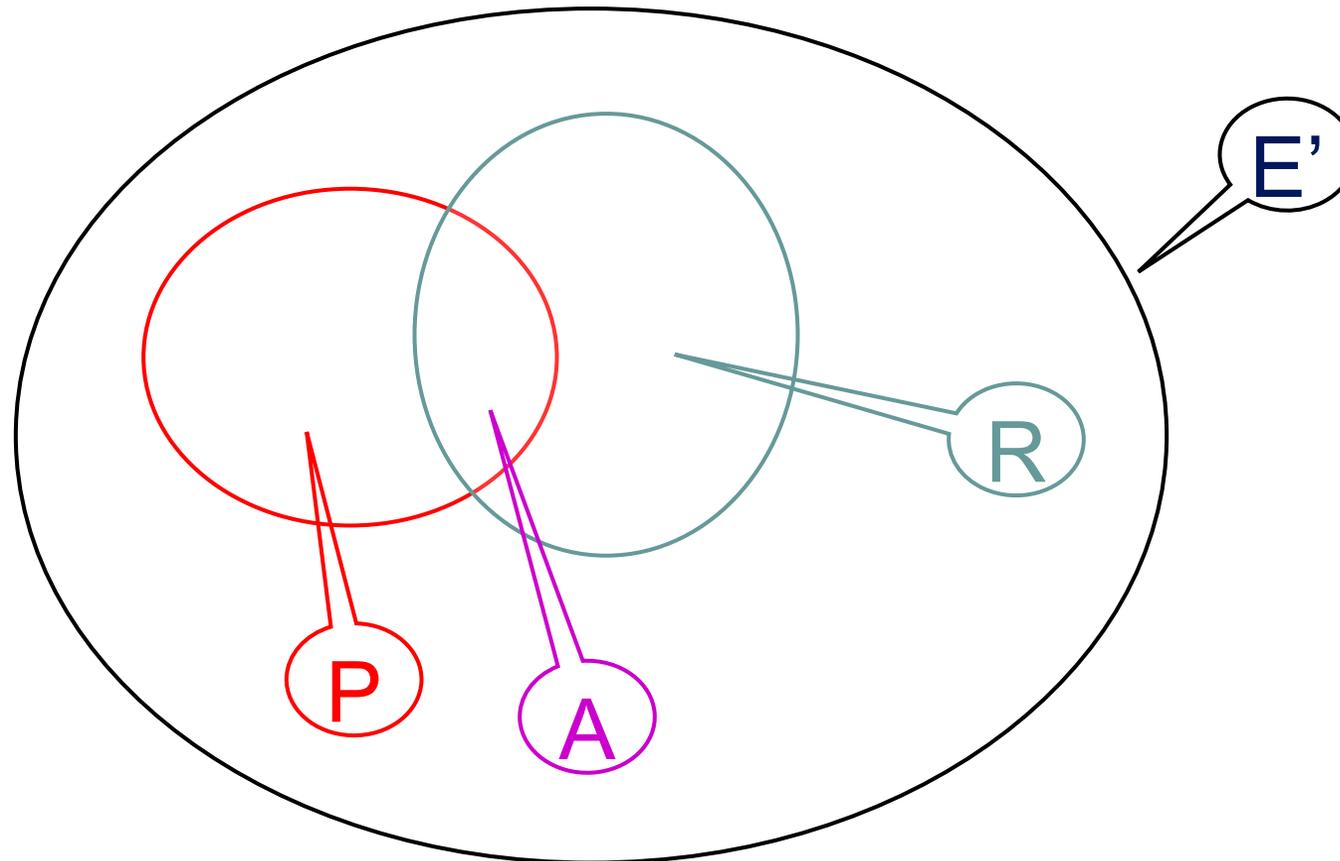
DEFINITION : la **précision** = $\#A / \#R$ est le taux d'éléments qui sont pertinents parmi ceux qui sont retournés par le système

DEFINITION : le **rappel** = $\#A / \#P$ est le taux d'éléments pertinents qui sont retournés par le système parmi les pertinents

- La performance du système peut être décrite par une courbe précision/rappel, en faisant varier la taille de l'ensemble des résultats retournés

Précision/rappel (suite et presque fin)

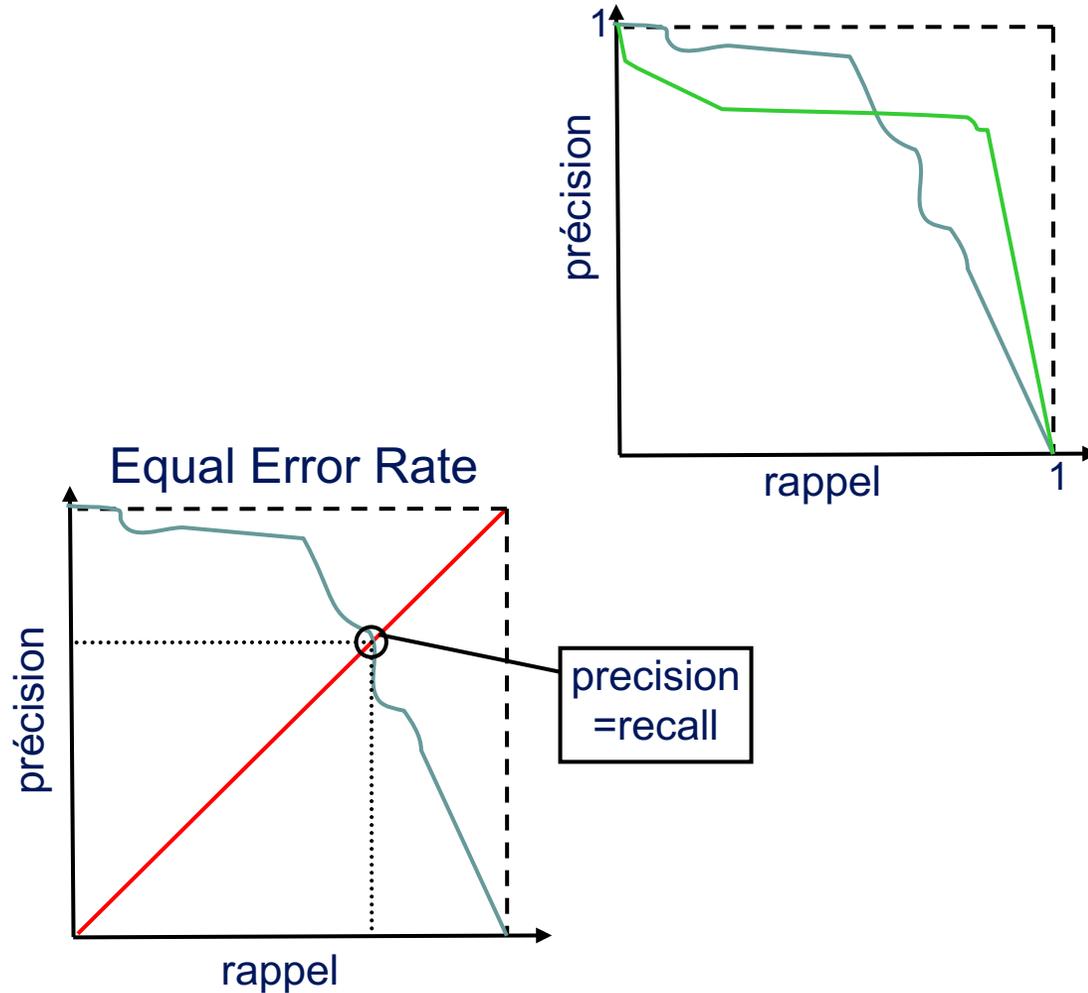
- Remarques :
 - ▶ P est indépendant de la paramétrisation.
 - ▶ R varie en fonction de la paramétrisation (qui retourne + ou – de résultats)



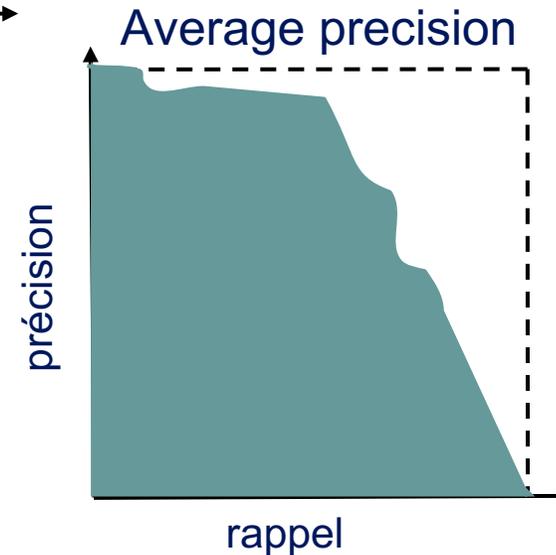
Précision/rappel (suite)

- *Equal Error Rate* et *Average Precision*:

réduire la courbe précision-rappel à une mesure de performance



Quelle est la meilleure méthode ?



Exercice : système de recherche d'objets

- Pour la requête et les résultats triés suivants : tracer la courbe précision/rappel, calculer la précision moyenne (*Average Precision*)

Proposition: faire l'exercice chez vous – me demander si un problème



1

2

3

4

5



6

7

8

9

10



Et la pertinence ?

DEFINITION: la **pertinence** d'un système (pour une paramétrisation donnée) est le taux d'objets qui sont correctement jugées, c'est-à-dire

$\text{pertinence} = (\text{vrais positifs} + \text{vrais négatifs}) / \text{taille de la base}$

- En recherche d'information (image, texte, etc.)
c'est une **mauvaise** mesure de la qualité du système
 - ▶ en général, la plupart des objets ne sont pas pertinents
 - ▶ un système qui renverrait systématiquement "négatif" serait quasiment imbattable avec cette mesure
- Intérêt d'avoir des courbes (par exemple PR) pour l'évaluation
 - ▶ dépend de l'utilisation : certains utilisateurs cherchent la précision (ex: requête sur Google), d'autres un grand rappel possible (recherche de contenu piraté)
 - ▶ *operating point*: choisir le bon point de fonctionnement du système

Mesures et protocoles d'évaluation : conclusion

- Difficulté de trouver une bonne mesure
 - ▶ elle doit être adaptée à ce que l'on compare (ex: vecteurs, loi de probabilité, etc.)
 - ▶ elle doit répondre à l'objectif recherché
- Évaluation d'un système de recherche dans des données visuelles
 - ▶ méthodes identiques à celles utilisées en texte
 - ▶ utilisation de courbes plutôt que de scalaires (peuvent être interprétées en fonction du besoin)
 - ▶ n'intègrent pas les mesures de similarité, juste leur rang!

Représentations globales

Comprendre les données visuelles à grande échelle
Cours 4: recherche d'images, 14 novembre 2019

Description globale

- **Une description globale** est une représentation de l'image dans son ensemble, sous la forme d'un vecteur de taille fixe
- **Caractéristiques**
 - ▶ **un** vecteur de description par objet visuel
 - ▶ mesure de (dis-)similarité définie sur l'espace de ces descripteurs

Agrégation de descripteurs locaux

- Définir un descripteur global à partir de l'ensemble des descripteurs locaux d'une image
 - ▶ Compact, et plus facile à manipuler que les descripteurs locaux de départ
- Contraintes
 - ▶ Des images similaires doivent avoir des représentations similaires
 - ▶ Des images dissimilaires doivent avoir des représentations dissimilaires
- Compromis
 - ▶ Robustes aux transformations (échelle, occultation, éclairage, etc.)
 - ▶ Informatifs (bonne description du contenu)
 - ▶ Efficaces à calculer, à stocker, à manipuler

Agrégation de descripteurs locaux

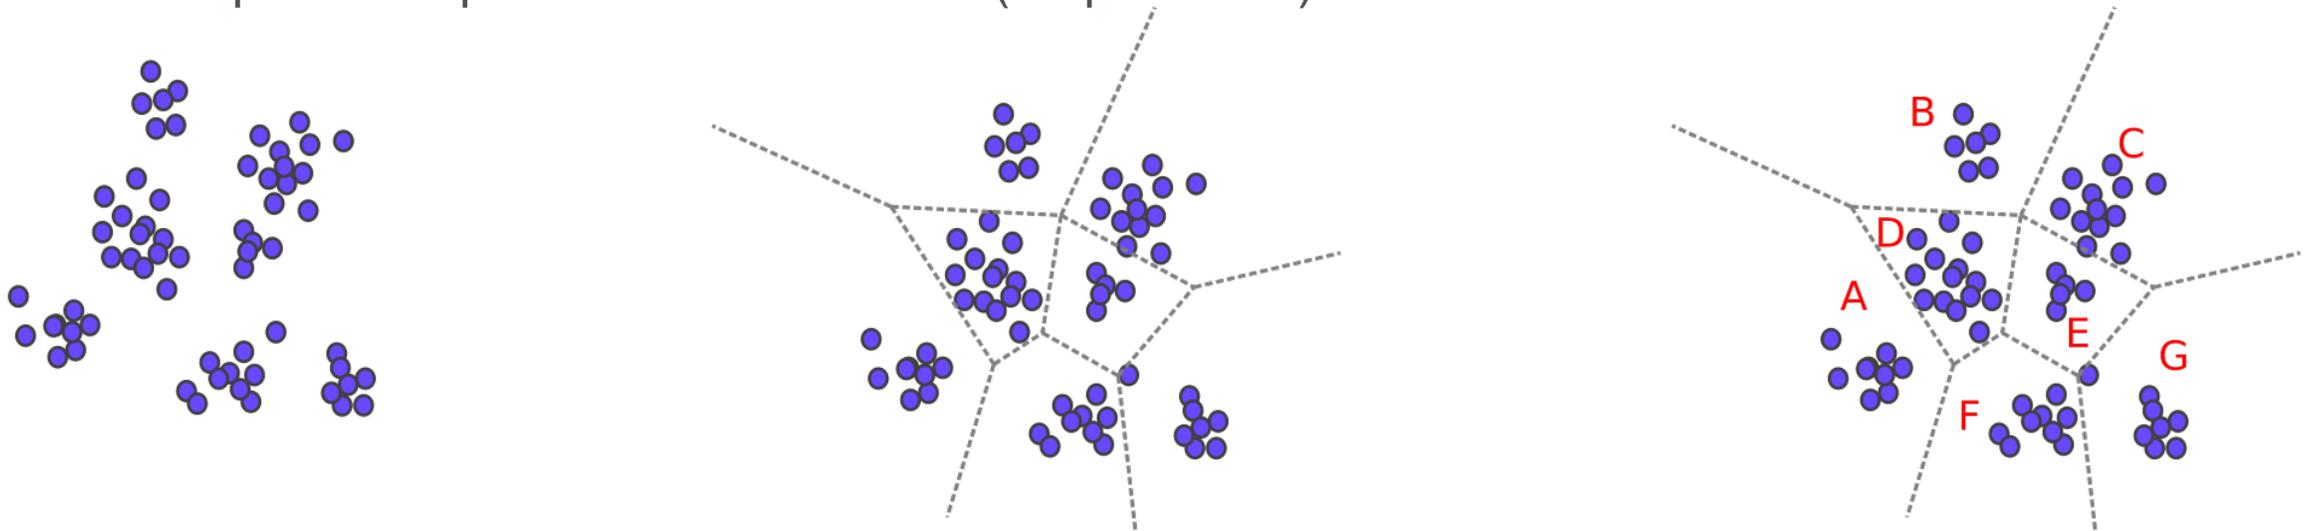
- La base: « *bag-of-features* », « *bag-of-patches* »
 - ▶ *bag* = on perd l'ordre, la géométrie.
On utilise des ensembles non-ordonnés de descripteurs locaux.
- Quantification: représentation par sac-de-mots, ou *bag-of-words* (BoW, aussi appelée *bag-of-visual-words* ou BoV)
 - ▶ On suppose une transformation : descripteur local -> index entier (par un algorithme de quantification vectorielle = *clustering*)
 - ▶ Cette transformation peut être vue comme la création d'un vocabulaire visuel
 - ▶ Histogramme de ces entiers = descripteur global

Agrégation de descripteurs locaux

Utilisation d'un **vocabulaire visuel**

Etapes:

- Discrétisation de l'espace des descripteurs, par exemple avec un algorithme de *clustering*
- Chaque descripteur est associé à un (ou plusieurs) mot visuel

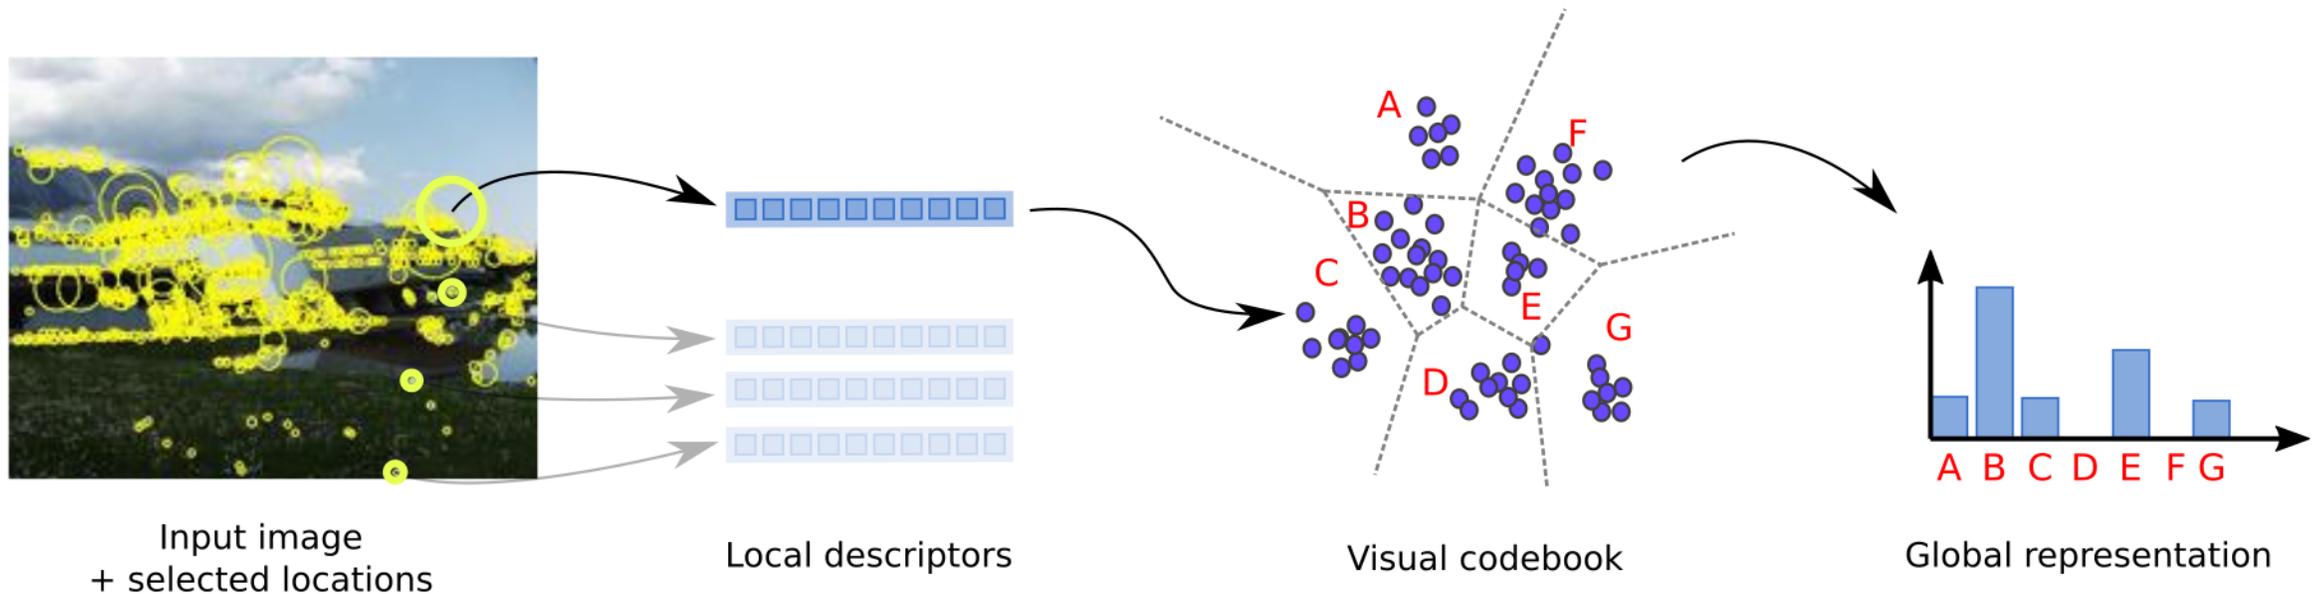


From quantization to bag-of-visual-features

Principle

- Extract local descriptors
- Convert local descriptors into visual words, using a visual codebook
- Represent images as a histogram of occurrences

[Sivic & Zisserman. ICCV 2003]
[Csurka et al. ECCV SLCV 2004]



Lien avec la partie sur les représentations locales

Début de ce cours

- Construction d'un vocabulaire visuel pour la construction d'un fichier inversé pour une recherche rapide

Ici

- Construction d'un vocabulaire visuel afin de pouvoir d'agréger les descripteurs locaux en une représentation globale
 - Les descripteurs locaux n'ont pas besoin d'être gardés en mémoire
 - Seule la représentation globale est conservée
 - Extrêmement compact, mais
 - pas de vérification géométrique possible,
 - perte totale des informations géométriques,
 - quantification = perte d'information -> représentation « grossière » (*coarse*)

Teaser

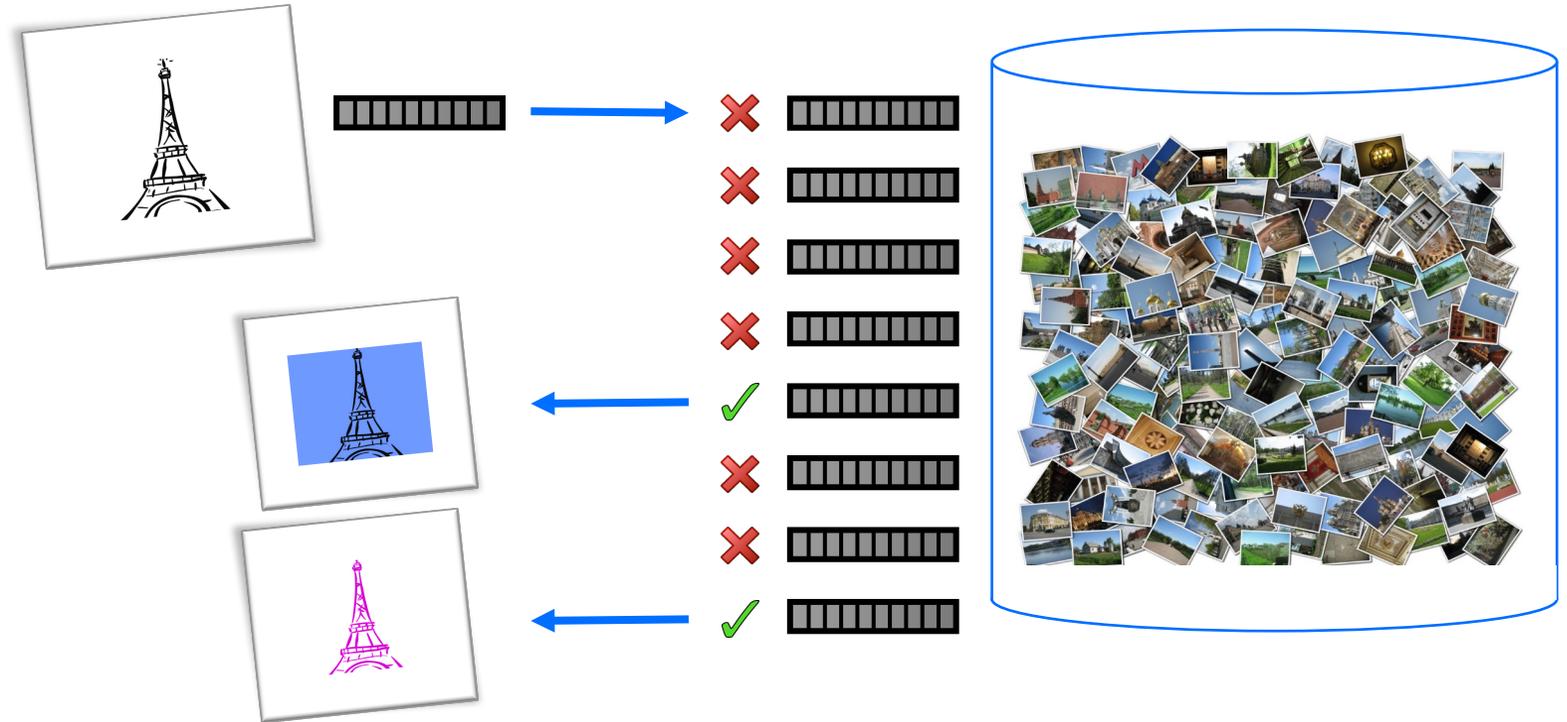
Dans le cours 7,
nous verrons comment construire des améliorations de la
représentation par « sacs-de-mots », qui donnent de meilleurs
résultats à un faible coût additionnel

Représentation d'images par apprentissage profond

Comprendre les données visuelles à grande échelle

Cours 4: recherche d'images, 14 novembre 2019

Object Search *a.k.a. Instance-Level Retrieval*



Families of representations

- Local representations
- Global representations
- **Deep representations**

Corresponding similarity measures

Représentation par apprentissage profond – première version

Principe

- Entraîner un réseau de neurones (ex: CNN) sur une tâche de classification
 - Par exemple pour la classification à 1000 classes sur ImageNet
- Utiliser ce réseau comme une “boîte noire” pour extraire des représentations d’images
 - la sortie d’une des couches (traditionnellement l’avant dernière) est utilisée comme représentation
- Eventuellement normaliser ces représentations
- Les comparer avec une mesure de similarité simple, comme le produit scalaire

Motivation

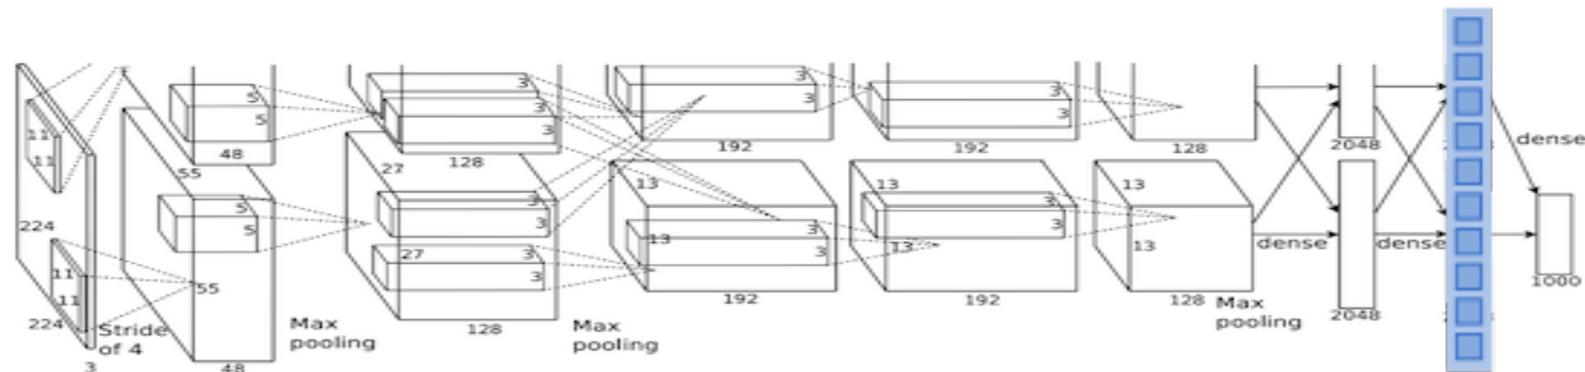
- Un bon modèle de classification capture des informations sémantiques et devrait permettre de bien représenter les images pour la tâche de recherche aussi

Représentation par apprentissage profond – première version

L'architecture CNN pré-entraînée pour la classification est utilisée comme un extracteur de représentation

- Les représentations sont compactes and rapides au moment du test!

AlexNet



[Krizhevsky et al. NIPS 2012]



Input image



Limitations de cette approche naïve

Limitations évidentes

- Le réseau a été entraîné pour de la classification, sur des catégories génériques, or on veut reconnaître précisément des objets
 - Généralisation intra-class vs discrimination entre les différentes instances d'une classe
- L'architecture des réseaux utilisés pour la classification prend en général en entrée des images de faible résolution et de taille fixe (distorsion des images)
- En pratique, ce type d'approche a donné des résultats décevants

Solution

- Améliorer toutes les étapes et spécialiser l'approche à la tâche de recherche d'images:
[méthodes récentes par apprentissage profond](#)

Repenser les approches par apprentissage profond pour la recherche d'images

- **Une base d'apprentissage appropriée**, i.e. labélisée à l'échelle de l'instance et non de la catégorie d'objet. Correction des erreurs d'annotations si besoin.
- **Changer l'architecture** pour apprendre les détails: architecture qui accepte toute taille et rapport d'échelle d'images, même les images avec une grande résolution
- **Changer la méthode d'apprentissage**: apprendre explicitement pour la recherche d'images plutôt que d'apprendre à classifier. Cela nécessite une modification de l'architecture comme de la fonction de coût

Training for visual search

What can be improved?

1. Training data:

Public landmark dataset is very noisy, needs to be cleaned automatically

2. Architecture:

Small details are important for instance level retrieval: need to accommodate high resolution, undistorted images during training

3. Training objective:

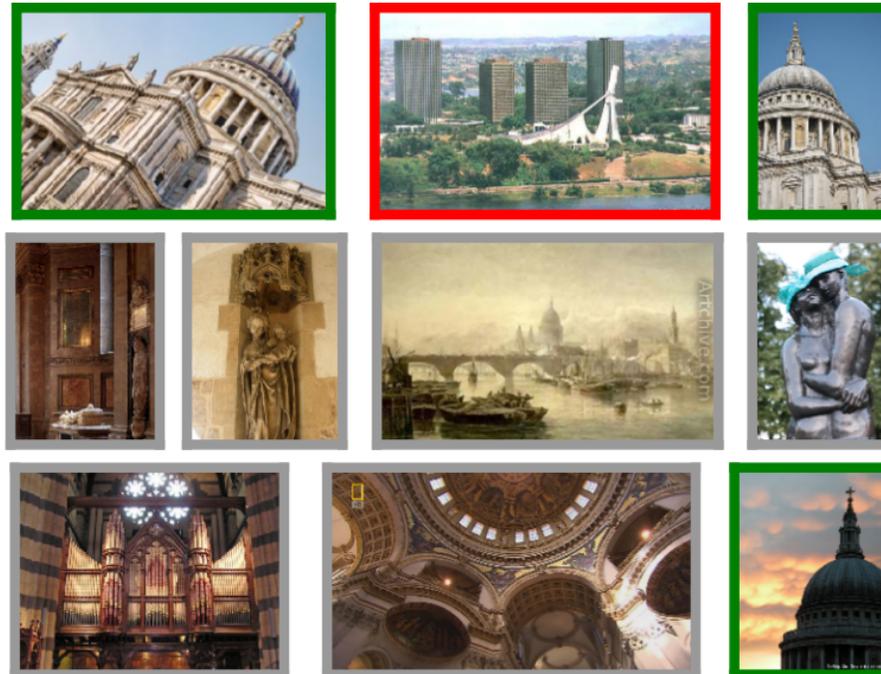
We should train explicitly for retrieval, not for classification

1. Training Data

Public dataset of landmark images

[Gordo et al. ECCV 16, IJCV17]

- ~200K images
- ~600 different landmarks (Rome colosseum, Big Ben...)
- Many annotation errors

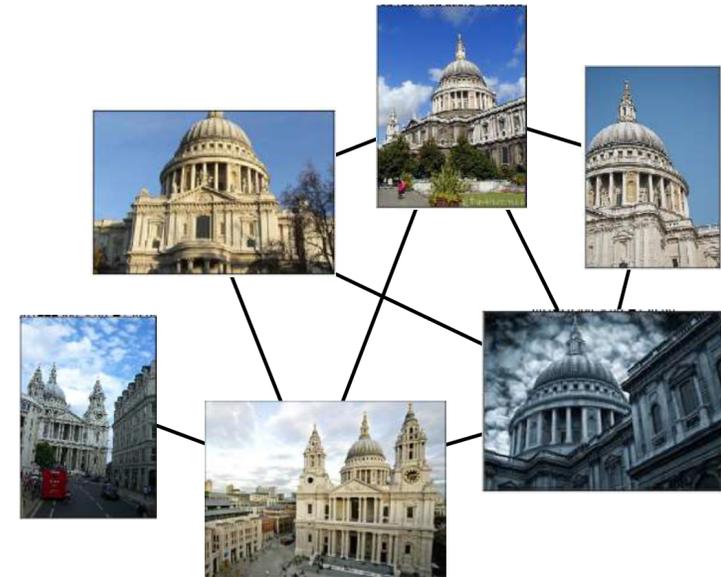


1. Training Data

Nettoyage automatique de la base d'images existantes

[Gordo et al. ECCV 16, IJCV17]

- Utilisation d'une méthode standard basée sur des descripteurs locaux d'images pour connecter les images pertinentes
 - Détection de point d'intérêt: Hessien-Affine
 - Description des régions sélectionnées avec SIFT
 - Appariement entre les descripteurs d'images
 - Vérification géométrique avec RANSAC
- Construction d'un graphe
 - Seule la plus grosse composante connectée par classe est conservée



Résultat

- Sous-ensemble (40K) d'images spatialement vérifiées
- Annotation approximative de la boîte englobante des objets

2. Architecture

Utilisation d'une architecture qui conserve les détails de l'image

Le **R-MAC** est un descripteur global d'image qui combine

- l'utilisation d'un réseau pré-entraîné pour la classification pour extraire une description dense des images
- L'extraction de représentations par région
- L'agrégation de ces représentations par région en une représentation finale

[Tolias et al, ICLR16]

2. Architecture


R-MAC descriptor

[Tolias et al, ICLR16]

Input image



Local features



2. Architecture

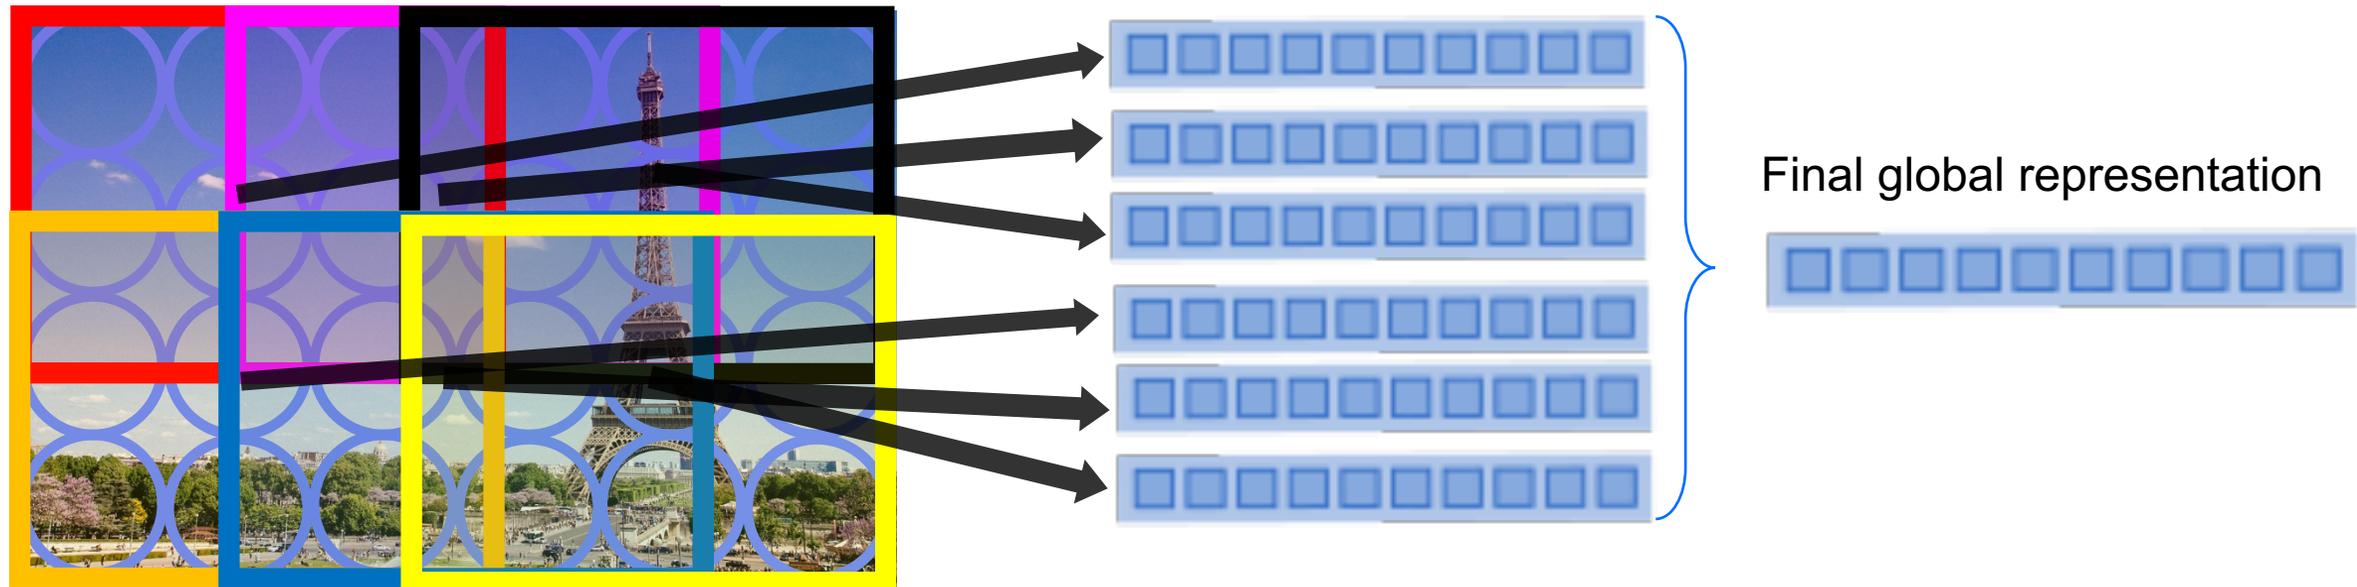
R-MAC descriptor

[Tolias et al, ICLR16]

Advantages

- no aspect ratio distortion
- can encode high resolution images
- fast comparison with the dot product

○ Local features



2. Architecture

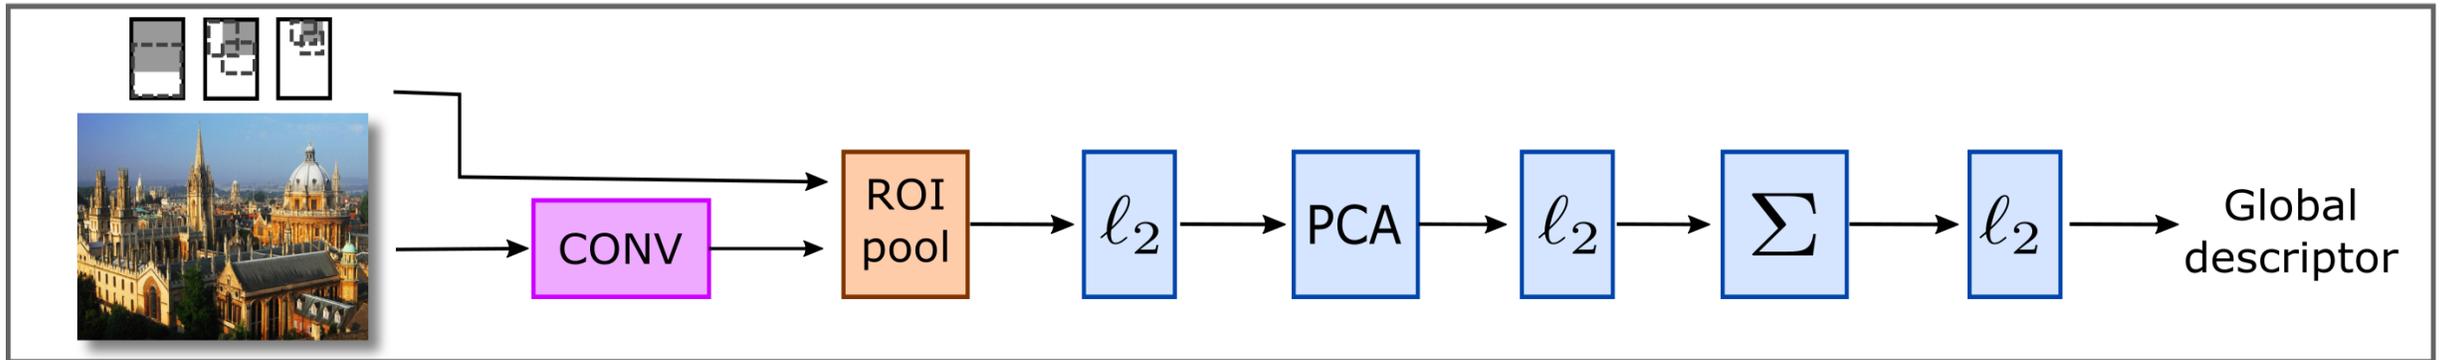
R-MAC descriptor

- CNN as a local feature extractor

Two key observations

[Gordo et al. ECCV 16, IJCV17]

1. The aggregation steps can be integrated inside the network:

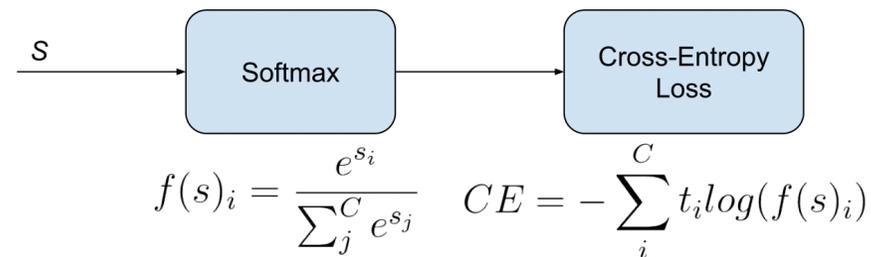


2. Every step is differentiable \rightarrow the model can be trained end-to-end!

3. Training for retrieval

Learning to rank

- Historiquement, les méthodes ont entraîné leurs réseaux de neurone avec une fonction de coût appropriée pour la classification (ex: softmax loss)

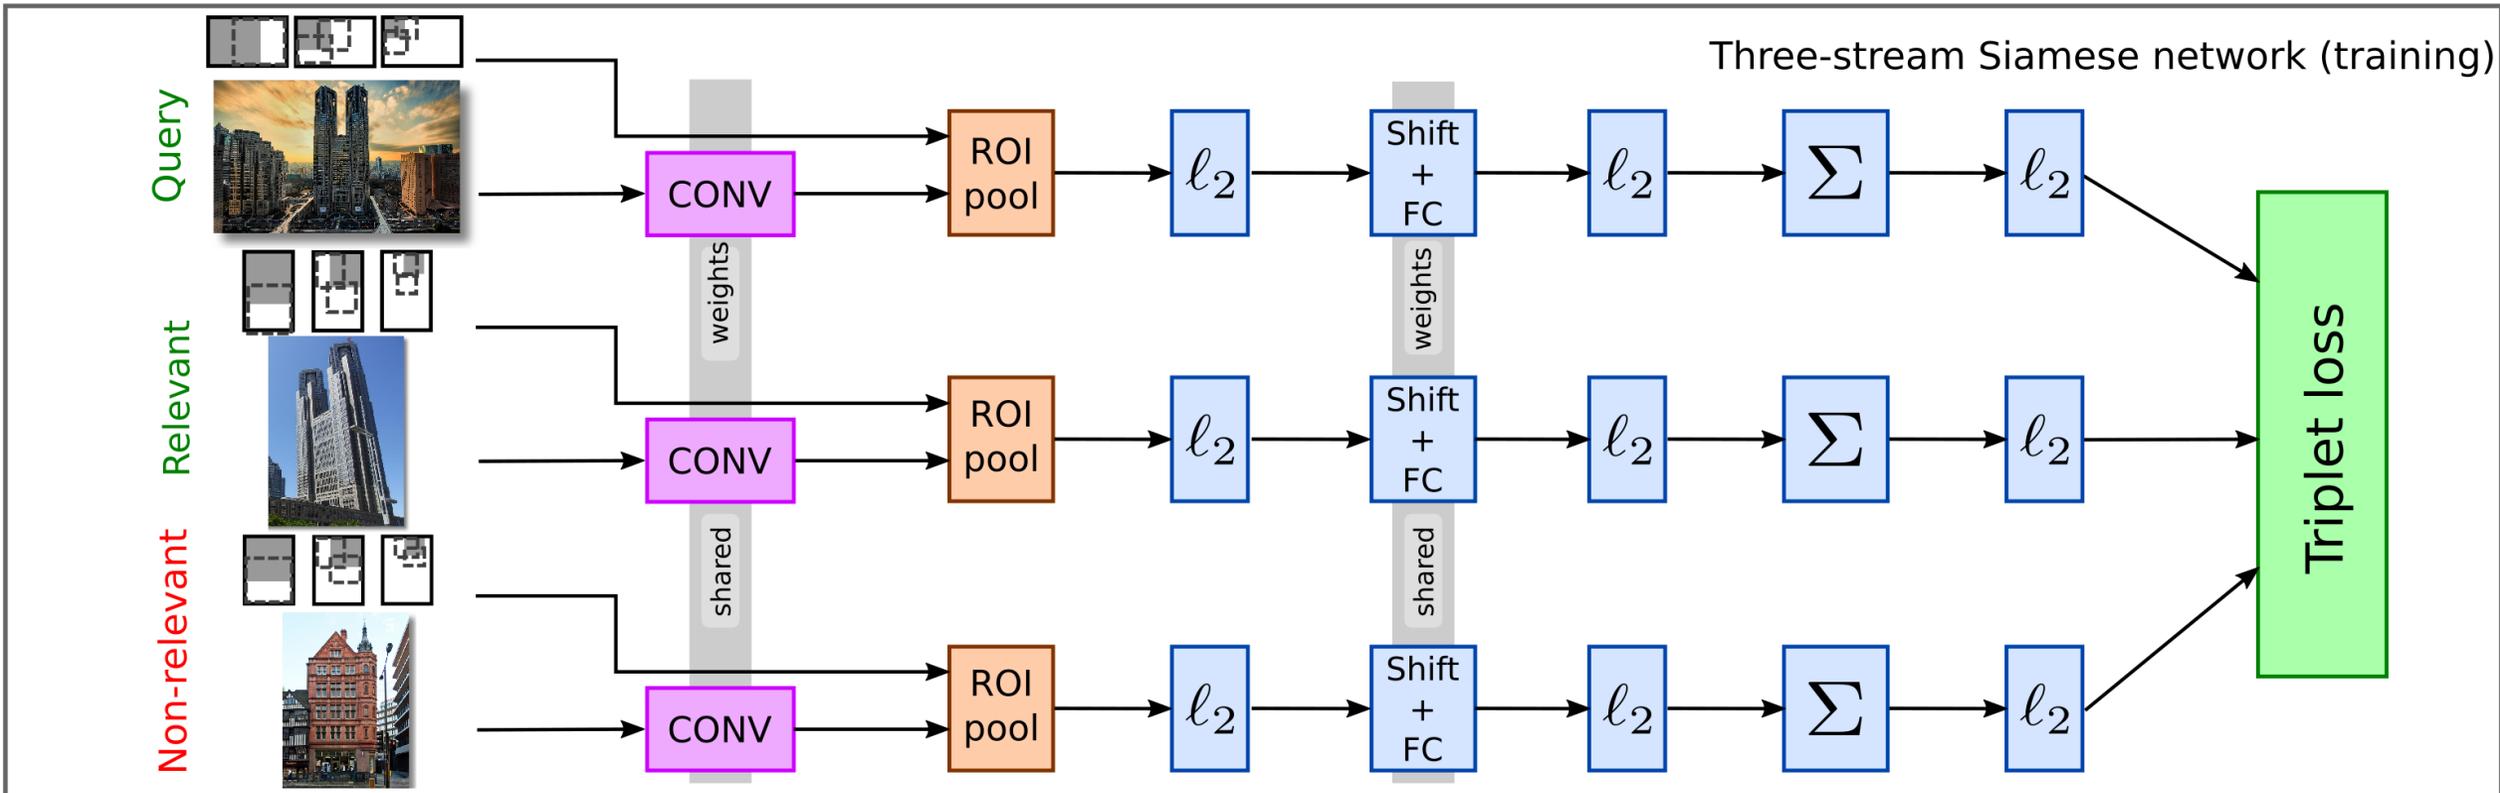


- Problème: on ne souhaite pas reconnaître la classe, mais, étant donnée une image, ordonnée les images de la base de la plus pertinente à la moins pertinente
- Solution: considérer une fonction de coût qui s'intéresse directement au rang des images. Cela demande de modifier l'architecture du réseau d'apprentissage (architecture siamoise)
- Exemple de fonction de coût de ce type
 - Contrastive** (perte contrastive) [Radenovic et al. ECCV 16, PAMI18]
 - Triplet** (fonction d'erreur de triplets) [Gordo et al. ECCV 16, IJCV17]
-> exemple choisi dans la suite

3. Training for retrieval

[Gordo et al. ECCV 16, IJCV17]

Learning to rank



3. Training for retrieval

[Gordo et al. ECCV 16, IJCV17]

Triplet loss

$$L_v(q, d^+, d^-) = \frac{1}{2} \max(0, m - \phi_q^T \phi_+ + \phi_q^T \phi_-)$$

Query



Relevant



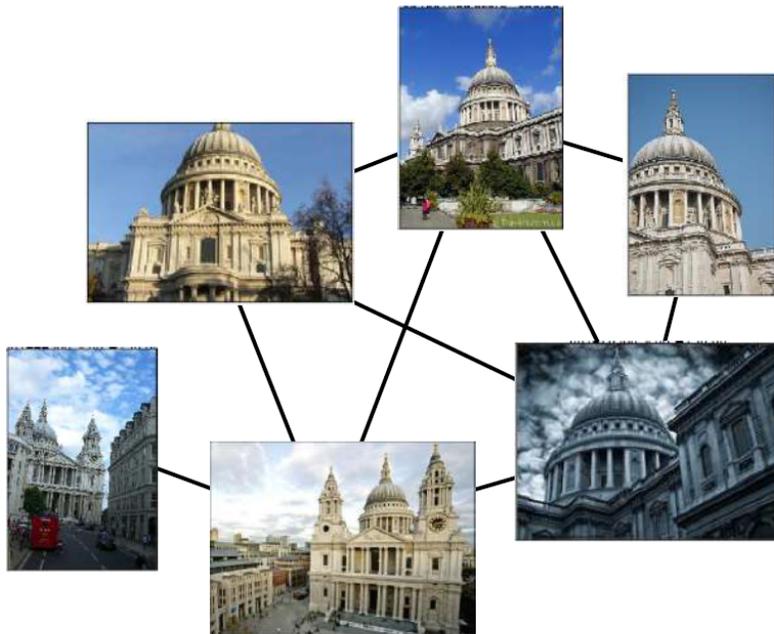
Non-relevant



Summary

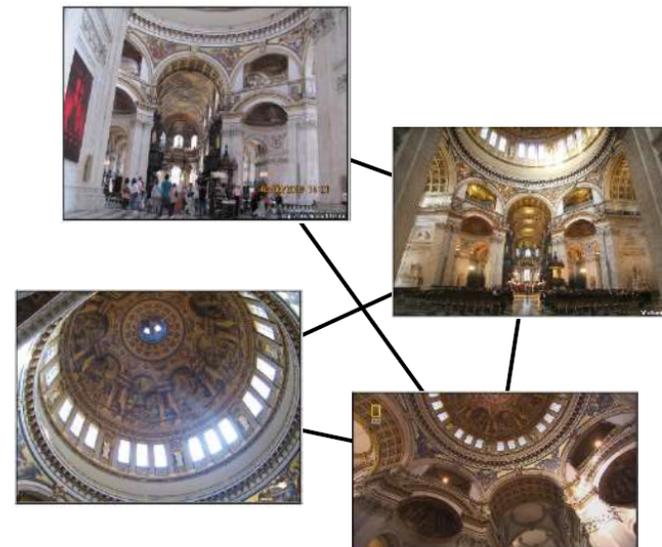
Problems:

1. Features from ImageNet are not good at intra-class discrimination



Solutions:

1. Train on an **automatically cleaned** dataset of landmarks



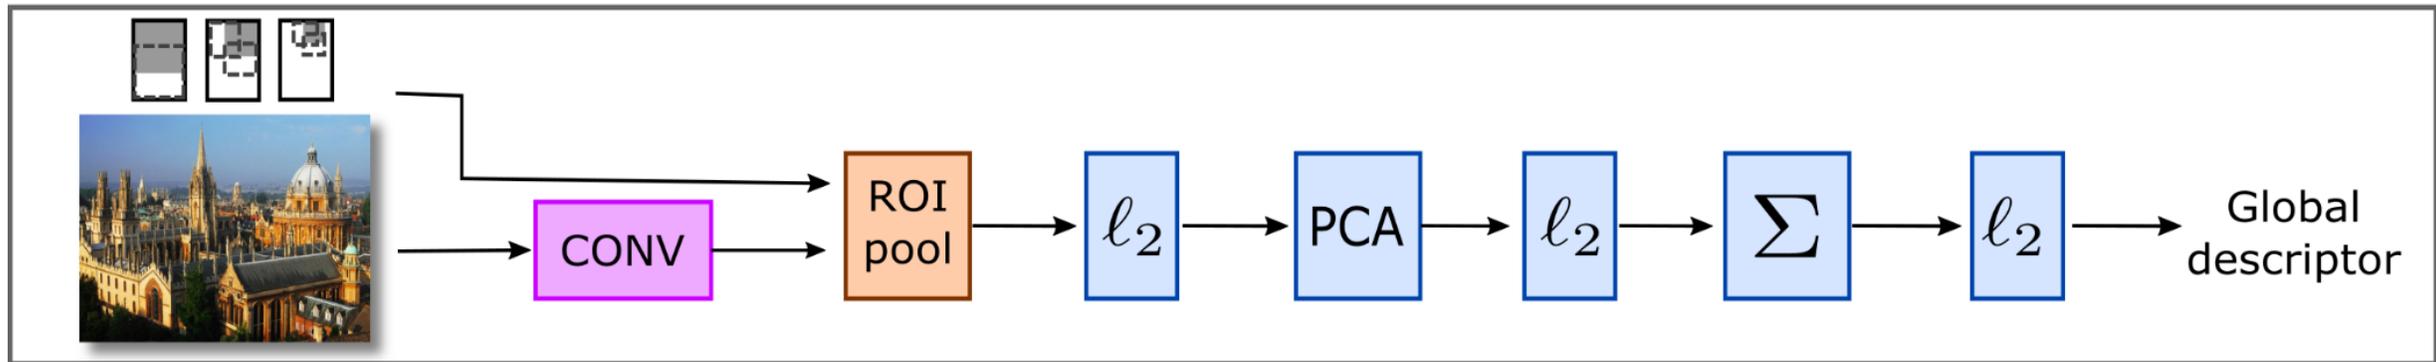
Summary

Problems:

1. Features from ImageNet are not good at intra-class discrimination
2. Usual architectures work on small crops of the image and at low resolution

Solutions:

1. Train on an **automatically cleaned** dataset of landmarks
2. Use an **architecture that preserves image details**



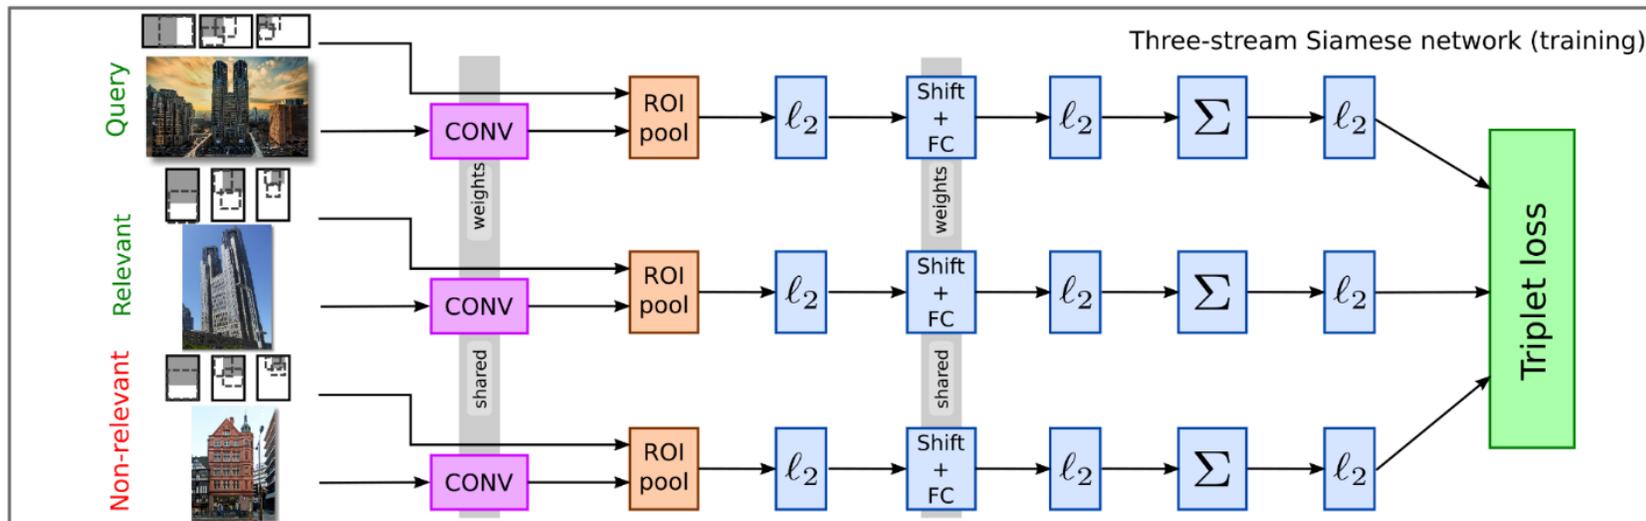
Summary

Problems:

1. Features from ImageNet are not good at intra-class discrimination
2. Usual architectures work on small crops of the image and at low resolution
3. Networks are typically trained for classification

Solutions:

1. Train on an **automatically cleaned** dataset of landmarks
2. Use an **architecture that preserves image details**
3. Train network with a **ranking loss**



Evaluation on standard benchmarks

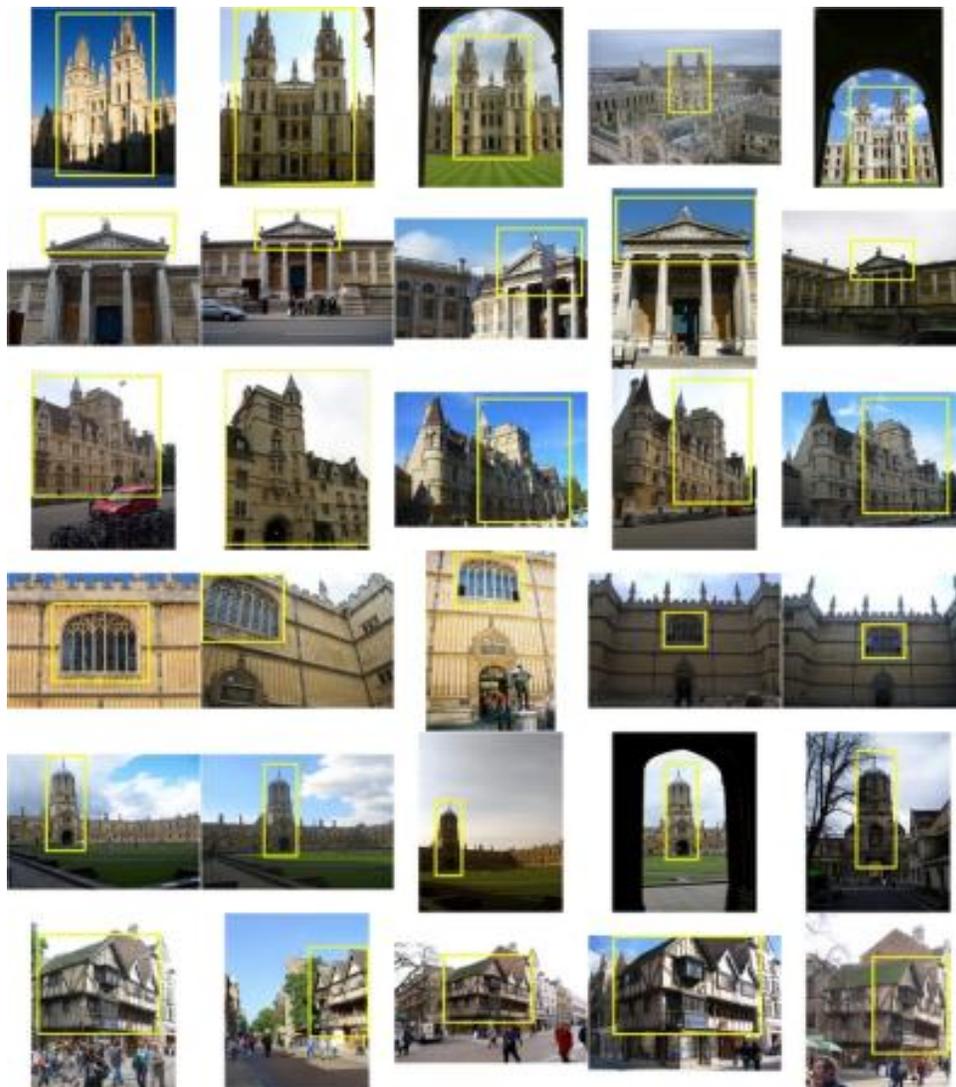
Oxford dataset

- 5,000 images
- 55 queries
- 11 landmarks

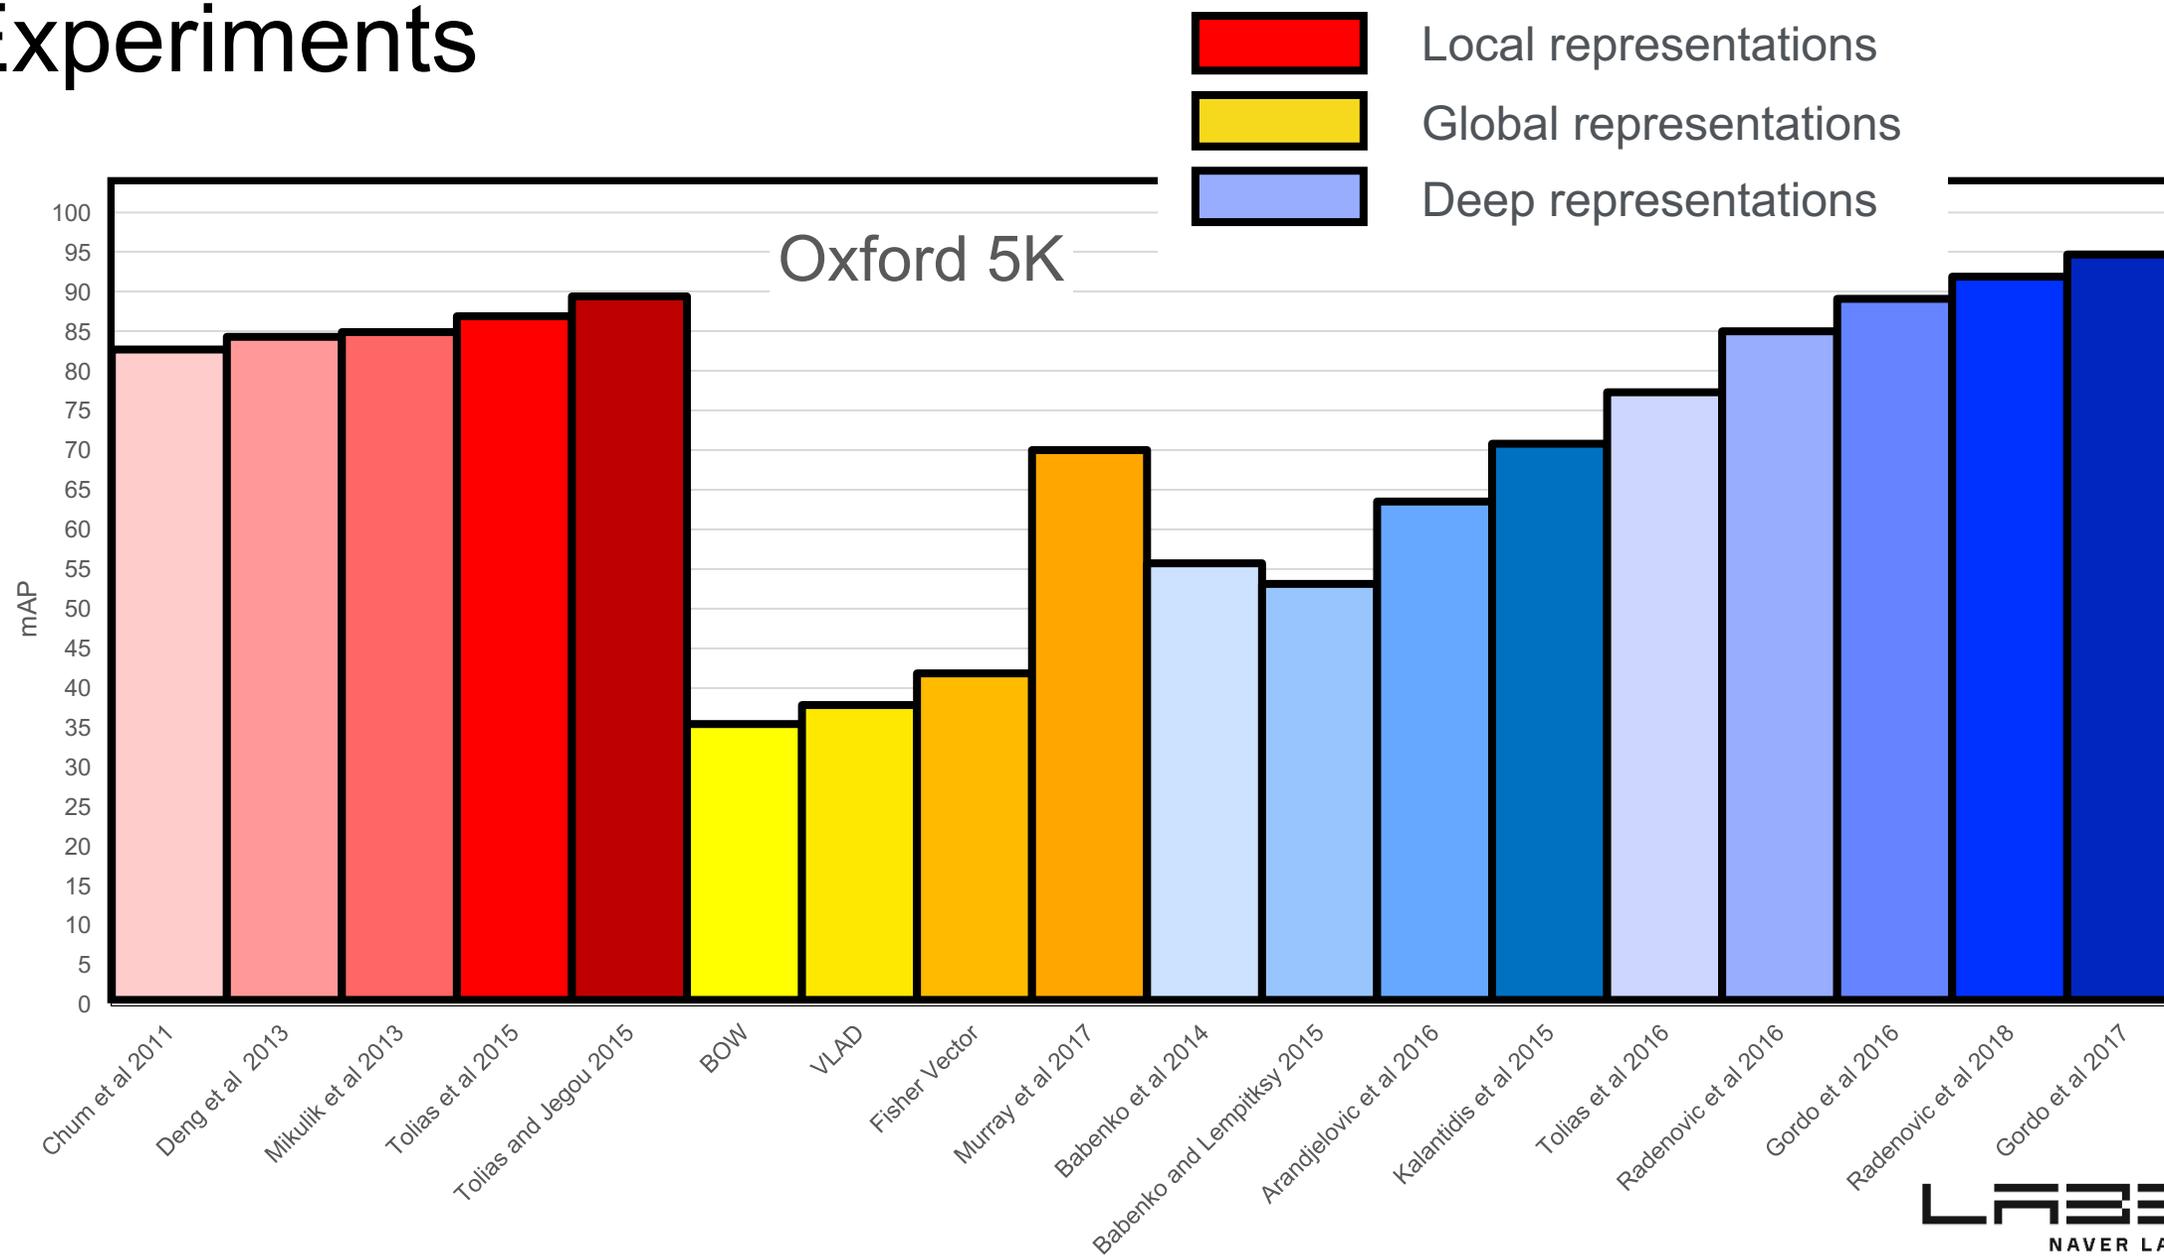
Evaluation

- mean Average Precision (mAP)

[Philbin et al. CVPR07]



Experiments

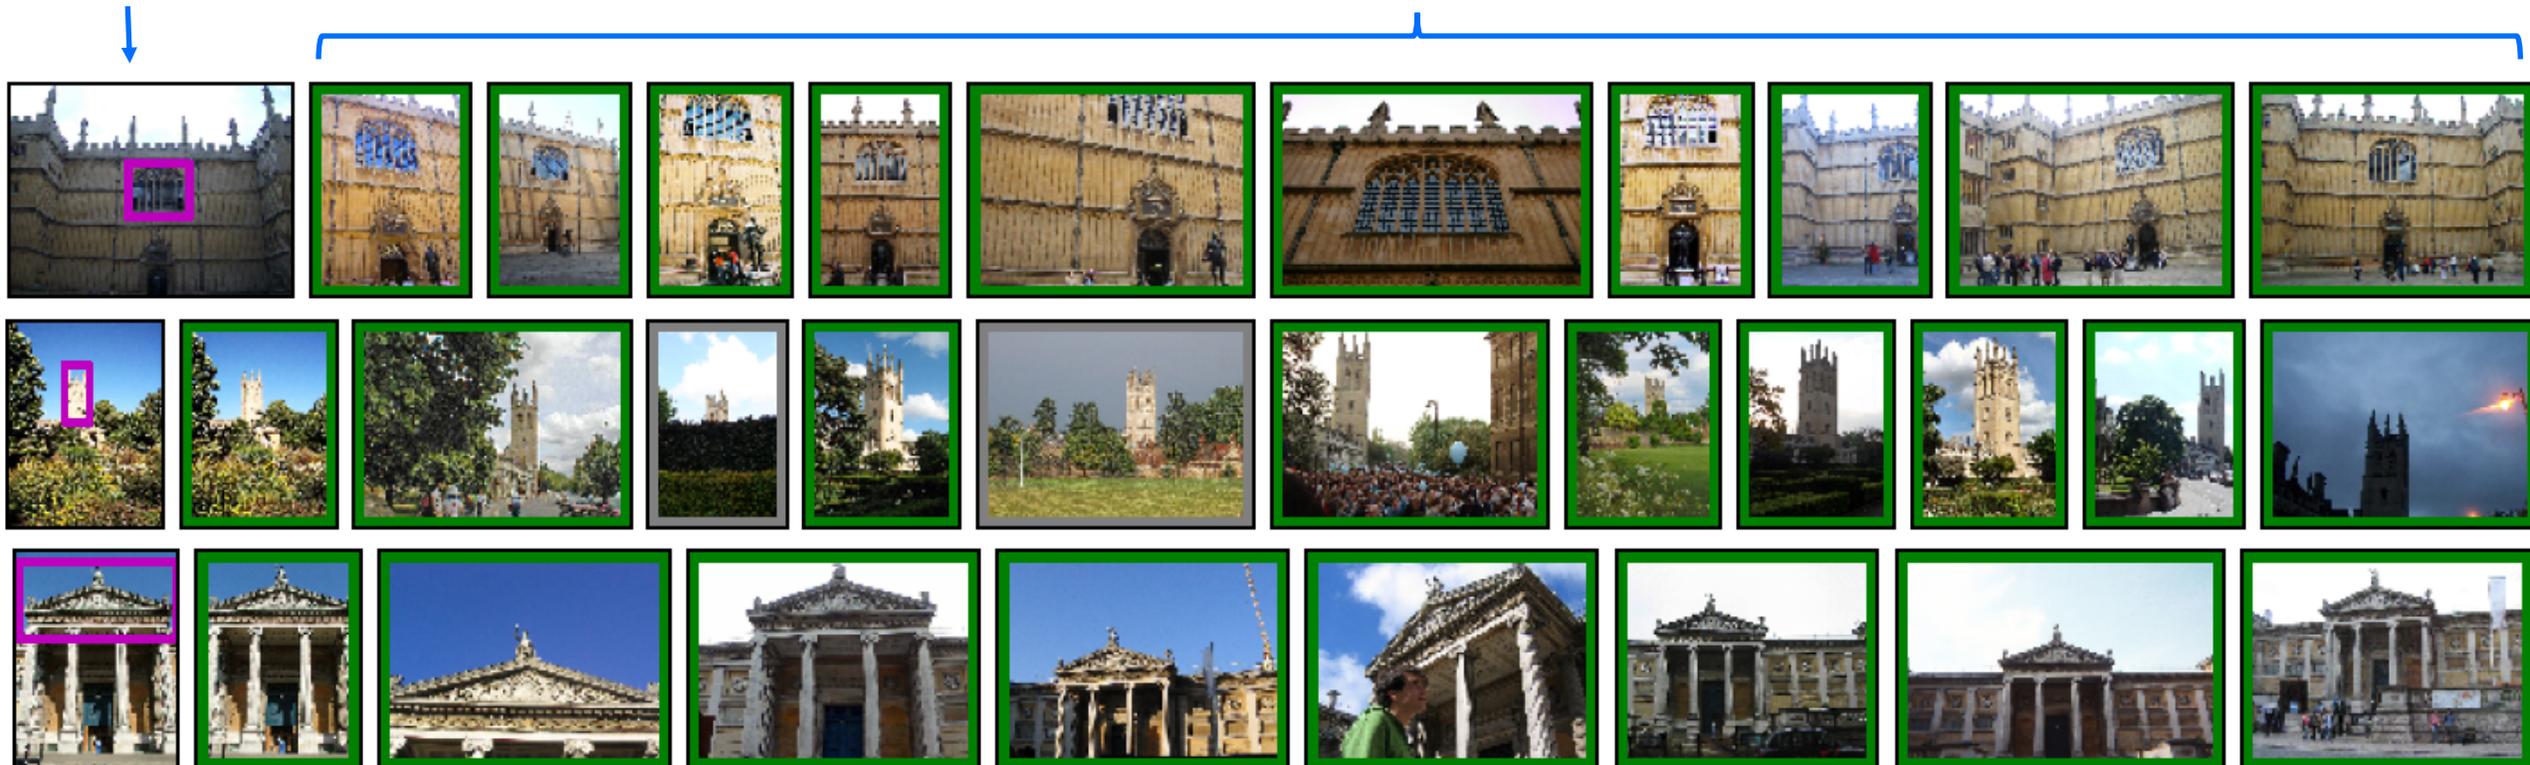


Qualitative results

[Gordo et al. ECCV 16, IJCV17]

query

top retrieved



Impact of fine-tuning an ImageNet model

Where do conv5 neurons fire?

[Gordo et al. ECCV 16, IJCV17]

Before



After



Impact of fine-tuning an ImageNet model

Where do conv5 neurons fire?

[Gordo et al. ECCV 16, IJCV17]

Before



After



Représentations locales par apprentissage profond

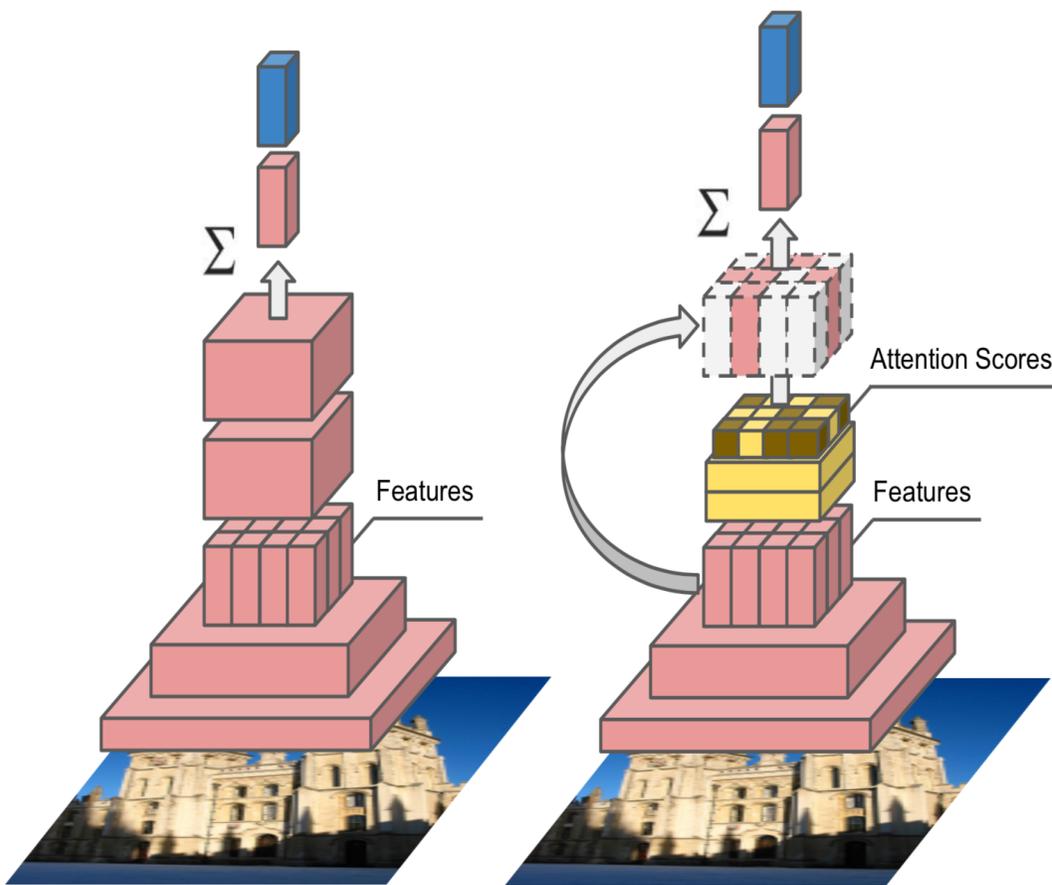
[Noh et al. ICCV17]

Principle

- **Dense Localized Feature Extraction:** fully convolutional network, trained for the task
- **Attention-based Keypoint Selection:** a technique to effectively select a subset of the features
- Note: keypoint selection comes after descriptor extraction
- Selected regions can be used for geometrical verification

Advantages

- “deep version” of local approaches: drop-in replacement for keypoint detectors and descriptors
- Good results on large-scale datasets



(a) Descriptor Fine-tuning

(b) Attention-based Training